

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYARLI GÖRÜ VE YAPAY ZEKA İLE CAM
KUSURLARININ TESPİTİ

YÜKSEK LİSANS TEZİ

YUSUF ÖZKAN

DANIŞMAN DOÇ. DR. VEDAT TÜMEN

MAYIS 2025

BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYARLI GÖRÜ VE YAPAY ZEKA İLE CAM
KUSURLARININ TESPİTİ

YÜKSEK LİSANS TEZİ

YUSUF ÖZKAN
ORCID: 0009-0003-6396-144X

DANIŞMAN DOÇ. DR. VEDAT TÜMEN

MAYIS 2025
BİTLİS

T.C.

BİTLİS EREN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ÇALIŞMASI ETİK BEYANI

Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans/ Doktora öğrencisiyim. Hazırlamış olduğum “Bilgisayarlı Görü ve Yapay Zeka ile Cam Kusurlarının Tespiti” başlıklı tezde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi; kullanılan verilerde herhangi bir değişiklik yapmadığımı; bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim. 12/05/2025

İmza

Yusuf ÖZKAN

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ YAZIM KILAVUZU UYGUNLUK BEYANI

“Bilgisayarlı Görü ve Yapay Zeka ile Cam Kusurlarının Tespiti” başlıklı yüksek lisans Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır. 12/05/2025

Tezi Hazırlayan

İmza

Yusuf ÖZKAN

Danışman

İmza

Doç. Dr. Vedat TÜMEN

Elektrik-Elektronik Mühendisliği Anabilim Dalı Başkanı

İmza

Prof. Dr. Sabir Rüstemli

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ONAY SAYFASI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı öğrencisi Yusuf ÖZKAN tarafından hazırlanan “Bilgisayarlı Görü ve Yapay Zeka ile Cam Kusurlarının Tespiti” adlı Yüksek Lisans ile ilgili tez savunma sınavı, 12/05/2025 tarihinde yapılmış ve tezin oy birliği/ oy çokluğu ile kabul/ red edilmesine karar verilmiştir.

JÜRİ:

Danışman: Doç. Dr. Vedat TÜMEN
(Bitlis Eren Üniversitesi)

Üye: Doç. Dr. Kubilay DEMİR
(Bursa Teknik Üniversitesi)

Üye: Dr. Öğr. Üyesi Emine ÇENGİL
(Bitlis Eren Üniversitesi)

İMZA

.....

.....

.....

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun tarih ve sayılı kararıyla jüri tarafından kabul edilmiş bu çalışmanın yüksek lisans / doktora tezi olarak kabulü onaylanmıştır.

....../...../2025

Prof. Dr. Mehmet Bakır ŞENGÜL

Enstitü Müdürü

T.C.

Bitlis Eren Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**BİLGİSAYARLI GÖRÜ VE YAPAY ZEKA İLE CAM KUSURLARININ
TESPİTİ**

Yüksek Lisans Tezi / Doktora Tezi

Yusuf ÖZKAN

Danışman: Doç. Dr. Vedat TÜMEN

Mayıs 2025

ÖZET

Günümüzde artan dünya nüfusu ve buna bağlı olarak yükselen tüketim ihtiyacı, ürünlerin yalnızca üretim aşamasında değil, son kullanıcıya ulaştıktan sonraki süreçlerde de kalite ve güvenilirliğini korumasını zorunlu kılmaktadır. Bu nedenle, ürünlerin nihai kullanıcıya ulaşmadan önce veya kullanım sürecinde karşılaşılabilecek olası kusurların tespit edilmesi, kullanıcı memnuniyetinin artırılması ve olası güvenlik risklerinin önlenmesi açısından büyük önem arz etmektedir. Bu bağlamda, yapay zekâ ve bilgisayarlı görü tabanlı sistemlerin kalite kontrol süreçlerine entegrasyonu, insan kaynaklı hataları en aza indirerek hem ürün güvenliğini hem de kullanıcı deneyimini iyileştirmektedir. Bu çalışmada, cam yüzeylerde meydana gelebilecek kırık, çatlak ve çizik gibi kusurların son kullanıcıya ulaştıktan sonra da tespit edilebilmesi hedeflenmiştir. Cam; otomotiv, inşaat, beyaz eşya, kozmetik ve ambalaj gibi birçok sektörde yaygın olarak kullanılan, görsel ve yapısal bütünlüğü kritik öneme sahip bir malzemedir. Bu nedenle, kullanıcıların karşılaşılabileceği kusurların hızlı ve doğru bir şekilde tespit edilmesi, hem ürün güvenilirliği hem de marka itibarı açısından hayati öneme sahiptir. Çalışma kapsamında, toplam 4975 görüntüden oluşan (4065 eğitim, 463 doğrulama, 447 test) bir veri seti kullanılmış ve bu veri seti, cam yüzey kusurlarının nesne tespiti amacıyla derin öğrenme tabanlı YOLOv5, YOLOv8 ve YOLO11 modelleri ile eğitilmiştir. Modellerin performansı doğruluk, hassasiyet, F1 skoru ve mAP50 metrikleri üzerinden değerlendirilmiştir. Elde edilen sonuçlara göre, YOLO11 modeli doğruluk, F1 skoru ve

mAP50 açısından en yüksek başarıyı sergilemiştir. YOLOv8 modeli hassasiyet bakımından öne çıkarken, YOLOv5'in genel performansının diğer iki modele göre daha düşük olduğu gözlemlenmiştir. Sonuçlar, YOLO mimarilerinin cam kusurlarının son kullanıcı düzeyinde tespitinde etkili bir şekilde kullanılabileceğini ve özellikle satış sonrası kalite kontrol süreçlerinin otomatikleştirilmesinde önemli katkılar sunabileceğini ortaya koymaktadır.

Anahtar Kelime: Yapay Zeka, Bilgisayarlı Görü, Derin Öğrenme, Makine Öğrenmesi



Republic of Türkiye
Bitlis Eren University Graduate School
Department of Electrical-Electronics Engineering
DETECTION OF GLASS DEFECTS WITH COMPUTER VISION AND
ARTIFICIAL INTELLIGENCE
Master's Thesis / PhD. Thesis

Yusuf ÖZKAN

Supervisor: Doç. Dr. Vedat TÜMEN

May 2025

ABSTRACT

In today's world, the increasing global population and corresponding rise in consumption demands have made it essential not only to ensure product quality during manufacturing but also to maintain reliability throughout the product's lifecycle, including its use by end consumers. Detecting potential defects before or during consumer use is crucial for enhancing customer satisfaction and preventing possible safety risks. In this context, the integration of artificial intelligence and computer vision-based systems into quality assurance processes significantly reduces human error, while improving both product safety and user experience. This study aims to detect surface defects such as cracks, scratches, and fractures on glass surfaces after the production stage, focusing on the products already in the hands of end users. Glass is a widely used material in various industries including automotive, construction, home appliances, cosmetics, and packaging, where visual and structural integrity is of critical importance. Therefore, accurately identifying such defects at the consumer level plays a vital role in maintaining product reliability and brand reputation. A dataset consisting of 4,975 images (4,065 for training, 463 for validation, and 447 for testing) was used in this study. The dataset was employed to train deep learning-based object detection models, specifically YOLOv5, YOLOv8, and YOLOv11, for identifying defects on glass surfaces. The models were evaluated using accuracy, precision, F1 score, and mAP50 metrics. The results demonstrated that the YOLOv11 model outperformed the others in terms of accuracy, F1 score, and mAP50, while YOLOv8 showed better performance in terms of precision. Overall, YOLOv5 exhibited lower performance compared to the other two models. These

findings indicate that YOLO architectures can be effectively utilized for detecting glass defects at the consumer level and can offer significant contributions toward automating post-sale quality assurance processes.

Keywords: Artificial Intelligence, Computer Vision, Machine Learning, Deep Learning



TEŞEKKÜR

Bu tez çalışmasının yürütülmesi ve tamamlanması sürecinde, değerli bilgi ve tecrübeleriyle bana rehberlik eden, yönlendirmeleriyle akademik gelişime önemli katkılar sağlayan danışmanım Doç. Dr. Vedat TÜMEN'e en içten teşekkürlerimi sunarım.

Bu tez çalışmasının hazırlanmasında her zaman yanımda olan değerli aileme teşekkür ederim. Özellikle, her koşulda yanımda olan fedakarlıklarıyla bana güç veren ve desteğini hiçbir zaman esirgemeyen kıymetli annem Melek ÖZKAN'a en derin şükranlarımı sunarım. Ayrıca bana daima güven aşılayan sevgili babama ve moral kaynağım olan kardeşime de teşekkür ederim. Varlıkları, bu zorlu sürecin her anında bana güç katmıştır.

İÇİNDEKİLER

ÖZET.....	I
ABSTRACT	III
TEŞEKKÜR.....	V
İÇİNDEKİLER.....	VI
ÇİZELGELER DİZİNİ	IX
ŞEKİLLER DİZİNİ	X
KISALTMALAR	XII
1. GİRİŞ	1
1.1 İlgili Araştırmalar	3
1.2 Tezin Amacı ve Önemi	9
2. GENEL BİLGİLER.....	11
2.1. Bilgisayarlı Görünün Tanımı ve Önemi.....	11
2.2. Bilgisayarlı Görünün Tarihsel Gelişimi.....	12
2.3. Bilgisayarlı Görünün Temel Kavramları	13
2.3.1. Piksel, Vektör ve Matris Kavramları	13
2.3.2. Renk Modelleri: RGB, Grayscale, HSV	13
2.3.3. Görüntü Çözünürlüğü ve Ölçeklendirme	14
2.4. Bilgisayarlı Görü Teknikleri ve Yöntemleri	14
2.4.1. Görüntü Filtreleme ve Gürültü Giderme	15
2.4.2. Kenar Tespiti (Edge Detection)	15
2.4.3. Segmentasyon Teknikleri.....	15
2.4.4. Şablon Eşleme (Template Matching).....	15
2.4.5. Özellik Çıkarımı (Feature Extraction)	15
2.4.6. Derinlik Algılama ve Stereoskopik Görü	16

2.5. Yapay Zekâ	16
2.5.1. Makine Öğrenmesi	17
2.6. Derin Öğrenme	25
2.7. Yapay Sinir Ağları.....	26
2.7.1. Tek Katmanlı Algılayıcılar	28
2.7.2. Çok Katmanlı Algılayıcılar	30
2.7.3. İleri Yönde Dağılım.....	31
2.7.4. Maliyet Fonksiyonunun Hesaplanması	32
2.7.5. Geri Yönde Yayılım ve Hesaplama Aşamaları	33
2.7.6. Hiperparametreler	35
2.7.7. Filtre Boyutu	35
2.7.8. Dolgulama ve Adım Kayırma	36
2.7.9. Havuzlama Katmanı Uygulama	36
2.8. Cam Kusurları ve Kusur Tespit Süreçleri.....	37
2.8.1. Cam Üretim Süreci ve Kalite Kontrol.....	37
2.8.2. Camda Görülen Kusur Türleri.....	39
2.8.3. Geleneksel Kusur Tespit Yöntemleri ve Sınırlılıkları.....	40
3. MATERYAL VE YÖNTEM	41
3.1 Derin Öğrenme Modeli Seçilmesi ve Kullanımı	42
3.2 Roboflow Platformunda Veri Seti Hazırlama Süreci.....	42
3.1.2 Veri Artırma (Augmentation) İşlemleri	43
3.1.3 Roboflow Platformunun Kullanılmasının Sonucu ve Avantajları	46
3.3 Tez Çalışmamızda Takip Edilen Eğitim Süreci Basamakları.....	46
3.4 YOLO Performans Metrikleri	47
3.4.1 Doğruluk(Accuracy)	47
3.4.2 Hassasiyet (Precision)	48

3.4.3 Duyarlılık (Recall)	48
3.4.4 F1 Skoru	48
3.4.5 mAP50	49
3.5 Görüntü İşleme	49
3.6 Özellik Çıkarımı	49
3.7. Derin Öğrenme Modelleri	50
3.7.1. YOLO	50
3.7.2. YOLO'nun Temel Özellikleri ve Avantajları.....	51
3.7.3. YOLOv5	53
3.7.4. YOLOv8	53
3.7.5. YOLO11	54
3.7.6. YOLO Modellerinin Karşılaştırılması	54
4. BULGULAR VE TARTIŞMA	57
4.1. YOLOv5 Eğitim Süreci	58
4.2. YOLOv8 Eğitim Sonuçları	62
4.3. YOLO11 Eğitim Sonuçları	66
4.4. Modellerin Karşılaştırmalı Sonuçları	70
4.5. Literatürdeki Çalışmalarla Karşılaştırma.....	71
5. SONUÇ VE ÖNERİLER.....	74
KAYNAKLAR.....	75

ÇİZELGELER DİZİNİ

Çizelge 2. 1. Tez ile ilgili Literatür Taraması.....	9
Çizelge 3. 1. Projede Kullanılan Veri Setinde Sınıf Bazlı Etiketleme Sayısı.....	47
Çizelge 3. 2. Teknik Özellikler Karşılaştırması.....	55
Çizelge 3. 3. Performans Karşılaştırması.....	55
Çizelge 4. 1. Tüm YOLO versiyonlarında kullanılan hiperparametreler.....	58
Çizelge 4. 2. YOLOv5 ile sınıf bazında elde edilen performans metrikleri.....	58
Çizelge 4. 3. YOLOv8 ile sınıf bazında elde edilen performans metrikleri.....	62
Çizelge 4. 4. YOLO11 ile sınıf bazında elde edilen performans metrikleri	66
Çizelge 4. 5. YOLO Modellerinin Karşılaştırılması.....	70
Çizelge 4. 6. Literatürdeki Çalışmaların Karşılaştırılması.....	72

ŞEKİLLER DİZİNİ

Şekil 2.1. Yapay Zekâ ve Alt Bileşenleri (Anonim, 2023).....	17
Şekil 2.2. Makine Öğrenmesi Algoritmaları Hiyerarşisi (Rashidi vd., 2019: 44).....	18
Şekil 2.3. Denetimli ve Denetimsiz Kümeleme Modelleri (Hazır, 2021: 66-67).....	22
Şekil 2.4. İnsan Vücudunda Yer Alan Nöron Hücreleri (Zhang vd., 2018: 51).....	26
Şekil 2.5. Algılayıcıların Şematik Gösterimi (Shanmugamani, 2018: 32).....	27
Şekil 2.6. Tek ve Çok Katmanlı Sinir Ağları Modelleri (Nielsen, 2015).....	28
Şekil 2.7. Tek Katmanlı Yapay Sinir Ağı Yapısı (Anonim, 2020).....	29
Şekil 2.8. Çok Katmanlı Yapay Sinir Ağı Yapısı (İslamoğlu, 2015: 178-193).....	31
Şekil 2.9. Geri Yayılımın Çalışma Mekanizmasının Akış Diyagramı.....	34
Şekil 3. 1. Döndürme İşlemi.....	43
Şekil 3. 2. Parlaklık ve Kontrast Değişimi İşlemi.....	44
Şekil 3. 3. Kırpma İşlemi.....	44
Şekil 3. 4. Yatay Çevirme İşlemi.....	45
Şekil 3. 5. Tez Çalışmasında Takip Edilen Eğitim Süreci Basamakları.....	46
Şekil 3. 6. YOLO Mimarisinin Bölümleri.....	50
Şekil 3. 7. YOLO Tarihsel Gelişim Çizelgesi.....	51
Şekil 4. 1. YOLOv5 modelinin performans metrik grafikleri.....	59
Şekil 4. 2. YOLOv5 modeli eğitim sonucunda elde edilen görüntüler.....	60
Şekil 4. 3. YOLOv5 ile yapılan eğitimde elde edilen güven skorları.....	61
Şekil 4. 4. YOLOv8 modelinin performans metrik grafikleri.....	63
Şekil 4. 5. YOLOv8 modeli eğitim sonucunda elde edilen görüntüler.....	64
Şekil 4. 6. YOLOv8 modeli eğitim sonucunda elde edilen güven skorları.....	65
Şekil 4. 7. YOLO11 modelinin performans metrik grafikleri.....	67
Şekil 4. 8. YOLO11 modeli eğitim sonucunda elde edilen görüntüler.....	68

Şekil 4. 9. YOLO11 modeli eğitim sonucunda elde edilen güven skorları.....69



KISALTMALAR

BG	: Bilgisayarlı Görü
Bkz.	: Bakınız
mAP	: Mean Average Precision
YOLO	: You Only Look Once
YZ	: Yapay Zeka



1. GİRİŞ

Cam yüzey kusurlarının tespiti, ürün kalitesinin ve müşteri memnuniyetinin sağlanmasında kritik bir öneme sahiptir. Geleneksel denetim yöntemleri, genellikle manuel incelemelere dayanmakta olup, bu süreçler zaman alıcı ve hata yapma olasılığı yüksek uygulamalardır. Bu nedenle, cam kusurlarının tespit edilme süreçlerinde daha hızlı, güvenilir ve otomatik kusur tespit sistemlerine duyulan ihtiyaç giderek artmaktadır. Bu bağlamda, bilgisayarlı görü ve yapay zekâ tabanlı yöntemler, cam yüzeylerindeki kusurların tespitinde yenilikçi çözümler sunmaktadır.

Bilgisayarlı görü, bilgisayarların dijital görüntüleri analiz ederek anlamlı bilgiler çıkarmasını sağlayan bir yapay zekâ alanıdır. Bu teknoloji, endüstriyel otomasyon süreçlerinde kalite kontrol ve kusur tespiti gibi uygulamalarda yaygın olarak kullanılmaktadır. Özellikle derin öğrenme tekniklerinin gelişimiyle birlikte, bilgisayarlı görü sistemlerinin doğruluk ve etkinliği önemli ölçüde artmıştır. Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla büyük veri setlerinden özellikler öğrenerek, karmaşık desenleri ve anomalileri tespit etme kapasitesine sahiptir.

Cam üretiminde karşılaşılan yüzey kusurları, ürünün dayanıklılığını ve estetik görünümünü olumsuz etkileyebilir. Bu kusurların erken ve doğru bir şekilde tespiti, üretim süreçlerinin iyileştirilmesi ve maliyetlerin azaltılması açısından önemlidir. Geleneksel yöntemlerin sınırlılıkları göz önüne alındığında, bilgisayarlı görü ve yapay zekâ tabanlı sistemler, daha hızlı ve hassas kusur tespiti imkânı sunmaktadır. Örneğin, derin öğrenme tabanlı gömülü sistemler kullanılarak çelik yüzeylerdeki kusurların tespitine yönelik çalışmalar, bu alandaki potansiyeli göstermektedir (Güçlü vd., 2022: 27-30).

Yapay zekâ tabanlı bilgisayarlı görü uygulamaları, derin öğrenme modelleri sayesinde otonom kusur tespiti yapabilmektedir. Son yıllarda, açıklanabilir yapay zekâ yaklaşımları, kusur tespitinde popülerlik kazanmıştır. Bu yaklaşımlar, sistem tarafından tespit edilen kusurun neden kusurlu olduğunu insan operatörlere açıklayarak, denetim süreçlerinin güvenilirliğini artırmaktadır. Ray yüzey kusurlarının tespitine yönelik yapılan bir çalışmada, denetimsiz öğrenme ile etiketsiz verilerden sağlam rayların özelliklerini öğrenen ağlar kullanılarak, test görüntülerindeki kusurlar başarıyla tespit edilmiş ve açıklama haritalarıyla kullanıcıya sunulmuştur (Kırat ve Aydın, 2023: 13).

Bilgisayarlı görü ve yapay zekâ teknolojilerinin cam kusurlarının tespitinde uygulanması, üretim süreçlerinin otomasyonunu ve kalite kontrolünü iyileştirmektedir. Bu teknolojiler, yüksek doğruluk oranlarıyla kusurları tespit edebilmekte ve insan kaynaklı hataları minimize etmektedir. Ayrıca, gerçek zamanlı veri işleme kapasitesi sayesinde, üretim hattında anında müdahale imkânı sunarak, verimliliği artırmaktadır. Bilgisayarlı görü ve yapay zekâ tabanlı yöntemlerin cam kusurlarının tespitinde kullanımı, endüstriyel üretim süreçlerinde devrim niteliğinde yenilikler getirmektedir. Bu teknolojilerin entegrasyonu, ürün kalitesinin artırılmasına, maliyetlerin düşürülmesine ve müşteri memnuniyetinin sağlanmasına katkı sağlamaktadır. Gelecekte, bu alandaki araştırma ve geliştirme faaliyetlerinin artmasıyla, daha gelişmiş ve etkin sistemlerin ortaya çıkması beklenmektedir.

Teknolojik gelişmelerin hız kazandığı çağımızda, üretim sektörleri sürekli olarak daha verimli, hızlı ve düşük maliyetli yöntemler arayışındadır. Sanayi devriminden bu yana makineleşmenin öncülük ettiği üretim süreçleri, son yıllarda dijital dönüşüm ile yeni bir boyut kazanmıştır. Otomasyon teknolojileri ve akıllı sistemlerin üretim hatlarına entegrasyonu, hataların minimize edilmesi ve ürün kalitesinin artırılması konusunda önemli fırsatlar sunmaktadır. Bu bağlamda, bilgisayarlı görü ve yapay zeka gibi ileri teknoloji uygulamaları, endüstriyel kalite kontrol süreçlerinde giderek daha fazla kullanılmaktadır.

Cam, günlük hayatın birçok alanında karşımıza çıkan ve çeşitli sektörlerde stratejik öneme sahip bir malzemedir. İnşaat, otomotiv, elektronik, tıp, kozmetik ve gıda sektörlerinde geniş bir kullanım alanına sahip olan cam; estetik, fonksiyonellik ve güvenilirlik açısından belirli standartları karşılamak zorundadır. Ancak cam üretimi, malzemenin hassas yapısı nedeniyle çeşitli zorluklar içermektedir. Üretim sürecinde cam yüzeylerinde meydana gelebilecek çizik, çatlak, kırık gibi kusurlar; ürünün mekanik dayanıklılığını, görsel estetiğini ve işlevselliğini olumsuz etkileyebilmektedir. Bu kusurların tespiti hem ürün kalitesini artırmak hem de müşteri memnuniyetini sağlamak açısından kritik bir öneme sahiptir.

Geleneksel kalite kontrol yöntemleri, çoğunlukla insan gözüne dayalı görsel incelemelerden oluşmaktadır. Ancak bu yöntemler, operatör yorgunluğu, dikkat eksikliği ve insan algısının sınırlı kapasitesi nedeniyle tutarsız sonuçlar verebilir. Özellikle yüksek hacimli üretim süreçlerinde manuel kontrol yöntemleri, zaman alıcı ve maliyetli bir süreç haline gelebilmektedir. Bu durum, üretim hatlarındaki kalite kontrol süreçlerinin daha

hızlı, daha doğru ve daha verimli bir şekilde yürütülmesini sağlayacak teknolojilere olan ihtiyacı artırmıştır.

Yapay zeka ise makinelerin insan benzeri öğrenme, karar verme ve problem çözme yetenekleri kazanmasını sağlayan teknolojiler bütünüdür. Makine öğrenimi ve derin öğrenme gibi yapay zeka teknikleri, büyük veri setlerinden öğrenerek karmaşık problemleri çözme yeteneğine sahiptir. Özellikle derin öğrenme tabanlı görüntü işleme yöntemleri, cam yüzeyindeki kusurların sınıflandırılması ve tespit edilmesinde yüksek performans göstermektedir. Bu teknikler sayesinde cam üzerindeki çizik, çatlak ve kırık gibi kusurlar, hızlı ve hassas bir şekilde belirlenebilmekte; böylece üretim sürecinde olası hatalar en aza indirilebilmektedir. Cam üretiminde hataların erken tespiti, yalnızca üretim maliyetlerini düşürmekle kalmaz, aynı zamanda ürünün pazardaki rekabet gücünü de artırır. Hatalı ürünlerin müşterilere ulaşması, hem ekonomik kayıplara hem de marka itibarına zarar verebilir. Bu nedenle, bilgisayarlı görü ve yapay zeka tabanlı kalite kontrol sistemleri, cam sektöründe stratejik bir öneme sahiptir.

Bu çalışmanın amacı, bilgisayarlı görü ve yapay zeka teknolojilerinin cam üretiminde kalite kontrol süreçlerine entegrasyonunu incelemek ve cam yüzeyindeki kusurların tespiti için etkili bir çözüm sunmaktır. Çalışmada, üretim sırasında cam yüzeyinde oluşabilecek çizik, çatlak ve kırık gibi kusurların tespit edilmesi ve bu kusurların sınıflandırılması hedeflenmektedir. Bu doğrultuda, literatürde mevcut yöntemler incelenmiş, geliştirilen algoritmalar ve modelleme teknikleri kullanılarak yeni bir yaklaşım sunulmuştur. Bilgisayarlı görü ve yapay zeka tabanlı bir kalite kontrol sisteminin cam üretim hatlarına entegrasyonunun sağladığı avantajları ortaya koymayı amaçlamaktadır. Elde edilen bulguların, cam üretim sektörüne önemli katkılar sağlaması ve benzer endüstriyel uygulamalar için yol gösterici olması beklenmektedir.

1.1 İlgili Araştırmalar

Imbert (1989) tarafından gerçekleştirilen bu çalışma, düz cam endüstrisinde kullanılan otomatik denetim sistemlerini incelemeyi amaçlamaktadır. Çalışma, üretim hattında cam yüzeyindeki kusurların hızlı ve doğru bir şekilde tespit edilmesi için otomatik sistemlerin uygulanabilirliğini ele almıştır. Araştırmada, özellikle optik tabanlı sensörler ve görüntü işleme algoritmalarının cam yüzeyindeki çizikler, kabarcıklar ve dalgalanmalar gibi kusurları algılama yetenekleri değerlendirilmiştir. İlgili otomatik sistemler, manuel denetim süreçlerine kıyasla daha yüksek hassasiyet ve hız sağlamış,

aynı zamanda insan kaynaklı hataları önemli ölçüde azaltmıştır. Deneysel sonuçlar, bu sistemlerin büyük hacimli üretim hatlarına entegre edilebileceğini ve üretim süreçlerinin verimliliğini artırabileceğini ortaya koymuştur. Imbert'in çalışması, düz cam üretiminde otomatik denetim sistemlerinin uygulanabilirliğini ve bu sistemlerin kalite kontrol süreçlerindeki avantajlarını vurgulamaktadır. Çalışma, cam üretim endüstrisi için modern otomasyon tekniklerinin önemini göstermekte ve bu alandaki araştırmalara temel teşkil etmektedir.

Kılıç (1995) tarafından gerçekleştirilen araştırma, cam üretiminde üfleme yöntemiyle biçimlendirme sürecini incelemeyi ve bu yöntemin üretim kalitesine etkilerini değerlendirmeyi amaçlamıştır. Çalışmada, üfleme tekniğinin tarihsel gelişimi, uygulama süreçleri ve endüstriyel cam üretimindeki yeri detaylı bir şekilde ele alınmıştır. Araştırmada, üfleme yöntemiyle üretilen camların, özellikle estetik ve özgün tasarımlar açısından önemli avantajlar sunduğu tespit edilmiştir. Ayrıca, bu yöntemin, camın homojenliğini ve yüzey kalitesini artırdığı, ancak üretim sürecinde operatörün deneyimine bağlı olarak farklı sonuçlar doğurabileceği belirtilmiştir. Üfleme yöntemi, manuel ve yarı otomatik tekniklerle uygulanabilirken, yöntemin verimliliğinin düşük olduğu ve seri üretim için sınırlamalar içerdiği ifade edilmiştir.

Fezani ve Rahmani (2006) tarafından gerçekleştirilen bu çalışma, düz cam yüzeyindeki kusurların tespiti için dalgacık analizine (wavelet analysis) dayalı bir yöntem geliştirmeyi amaçlamıştır. Araştırmada, özellikle yüzeyde oluşan çizikler, çatlaklar ve dalgalanmalar gibi kusurların hassas bir şekilde algılanması için dalgacık dönüşümleri kullanılmıştır. Çalışma, farklı frekans bileşenlerini ayrıştırabilen dalgacık analizinin, cam yüzey kusurlarının tespiti için güçlü bir araç olduğunu göstermiştir. Geliştirilen yöntem, cam yüzeyindeki düşük kontrastlı ve küçük boyutlu kusurların bile doğru bir şekilde algılanmasını sağlamıştır. Deneysel sonuçlar, dalgacık tabanlı yaklaşımın, geleneksel görsel denetim yöntemlerine kıyasla daha yüksek doğruluk oranı (%94) sunduğunu ortaya koymuştur. Ayrıca, bu yöntem, yüksek üretim hızlarına uyum sağlayarak gerçek zamanlı uygulamalar için uygun bir çözüm olarak değerlendirilmiştir.

Riza ve Anton (2007) tarafından gerçekleştirilen çalışma, şişeleme üretim hattında görsel denetim için yapay sinir ağlarına dayalı bir sistem geliştirmeyi amaçlamıştır. Araştırma, cam şişelerin yüzeyinde oluşabilecek kusurların ve üretim hatalarının otomatik tespitini sağlayan akıllı bir görsel denetim sistemini ele almaktadır. Geliştirilen sistem, görüntü işleme teknikleriyle yüzey kusurlarını algılamakta ve yapay sinir ağları

kullanarak bu kusurları sınıflandırmaktadır. Çalışmada, sistemin eğitim ve test süreçleri ayrıntılı olarak açıklanmış, kusur tespitinde %96'nın üzerinde bir doğruluk oranı sağladığı belirtilmiştir. Sistem, özellikle yüksek hızlı üretim hatlarında gerçek zamanlı olarak çalışabilirliği ile dikkat çekmiştir. Ayrıca, sistemin insan kaynaklı hataları azaltarak üretim süreçlerini optimize ettiği vurgulanmıştır.

Adamo, Attivissimo ve Di Nisio (2010) tarafından gerçekleştirilen çalışma, saten camların çevrimiçi kalite kontrolü için bir denetim sisteminin kalibrasyonunu ve performansını değerlendirmeyi amaçlamıştır. Araştırma, saten camların üretim sürecinde yüzey kalitesini etkileyen kusurların hızlı ve doğru bir şekilde tespit edilmesi için yeni bir otomasyon sistemi geliştirmiştir. Çalışmada, görüntü işleme tekniklerine dayalı bir denetim sistemi tasarlanmış ve bu sistemin doğruluğunu artırmak için kalibrasyon prosedürleri uygulanmıştır. Kalibrasyon süreci, denetim sisteminin ölçüm hassasiyetini ve hatalarını minimize etmeyi hedeflemiştir. Deneysel sonuçlar, sistemin yüzeydeki çizik, pürüz ve dalgalanma gibi kusurları %98'e varan bir doğruluk oranıyla tespit edebildiğini göstermiştir. Ayrıca, sistemin yüksek üretim hızlarına uyum sağlayarak gerçek zamanlı kalite kontrol sağlayabildiği vurgulanmıştır.

Keser (2010) tarafından gerçekleştirilen çalışma, kaliteli cam üretiminde küçük boyutlu silis kumunun kullanımının etkilerini incelemeyi amaçlamıştır. Araştırmada, silis kumunun tane boyutunun, camın optik, mekanik ve yüzey özellikleri üzerindeki etkileri deneysel olarak analiz edilmiştir. Çalışma kapsamında, farklı tane boyutlarına sahip silis kumu kullanılarak üretilen cam örnekleri üzerinde yapılan testler, küçük boyutlu silis kumunun camın homojenliğini artırdığını ve ışık geçirgenliğini iyileştirdiğini göstermiştir. Ayrıca, küçük boyutlu silis kumunun, eritme sürecinde daha düşük enerji tüketimine olanak tanıdığı ve üretim maliyetlerini düşürdüğü belirtilmiştir. Bununla birlikte, küçük boyutlu kumun fazla kullanımı, camın yüzey pürüzlülüğünde artışa neden olabileceği için dikkatli bir şekilde kontrol edilmesi gerektiği vurgulanmıştır.

Zhang, Guo, Qi ve Wang (2012) tarafından gerçekleştirilen çalışma, cam yüzeyindeki kusurların tespit edilmesi için Diskret Fourier Dönüşümü (DFT) ve optimal eşikleme yöntemine dayalı bir denetim sistemi geliştirmeyi amaçlamıştır. Araştırma, cam üretim süreçlerinde optik ve yüzey kusurlarını yüksek hassasiyetle tespit edebilecek bir yaklaşım sunmaktadır. Geliştirilen yöntem, cam yüzeyindeki kusurların frekans alanında tanımlanmasını ve ardından optimal eşikleme yöntemiyle ayrıştırılmasını sağlamaktadır. Deneysel sonuçlar, önerilen sistemin yüzeydeki çizik, dalgalanma ve inklüzyon gibi

kusurların tespitinde %95'in üzerinde doğruluk sağladığını göstermiştir. Bu yöntem, üretim hattında gerçek zamanlı kalite kontrol için uygun bir çözüm olarak değerlendirilmiştir. Ayrıca, DFT tabanlı analizlerin, geleneksel görsel denetim yöntemlerine göre daha hızlı ve güvenilir olduğu belirtilmiştir.

Akdemir ve Öztürk (2015) tarafından gerçekleştirilen çalışma, cam yüzeyinde meydana gelen kusurların tespiti için dalgacık dönüşümleri (wavelet transforms) temelli bir yöntem geliştirmeyi amaçlamıştır. Araştırma, cam yüzeyindeki çizikler, çatlaklar ve diğer kusurların yüksek doğruluk oranıyla algılanmasına olanak tanıyan bir analiz yöntemi sunmaktadır. Çalışmada, dalgacık dönüşümlerinin, görüntü işlemeye dayalı geleneksel yöntemlere kıyasla daha hassas ve güvenilir bir tespit mekanizması sunduğu belirtilmiştir. Önerilen yöntem, farklı frekans aralıklarını analiz ederek yüzey kusurlarını etkin bir şekilde tanımlamaktadır. Test sonuçları, yöntemin kusur tespiti sırasında %95'in üzerinde bir doğruluk sağladığını ve cam üretim hattında kalite kontrol süreçlerine entegre edilebileceğini göstermiştir. Çalışma, cam yüzeyinde meydana gelen mikroskobik kusurların tespiti için yenilikçi bir yöntem sunmuş ve geleneksel görsel denetim sistemlerine kıyasla önemli avantajlar sağlamıştır. Dalgacık dönüşümleri temelli bu yaklaşım, özellikle yüksek hassasiyet gerektiren cam ürünlerinin kalite kontrolünde kullanılabilecek etkili bir araç olarak değerlendirilmektedir. Çalışma, cam üretiminde ileri düzey tespit tekniklerine katkı sağlamaktadır.

Kaya (2016) tarafından gerçekleştirilen yüksek lisans çalışması, düz cam üretiminde temperleme sürecine ait parametrelerin camın düzlemselliği üzerindeki etkisini incelemeyi amaçlamıştır. Çalışmada, temperleme işleminin sıcaklık, soğutma hızı ve işlem süresi gibi değişkenlerinin camın fiziksel özelliklerini nasıl etkilediği deneysel olarak analiz edilmiştir. Araştırmada, farklı temperleme parametreleri kullanılarak üretilen cam örnekleri üzerinde yapılan ölçümler, sıcaklık ve soğutma hızındaki değişimlerin camın düzlemselliğinde belirgin bir rol oynadığını göstermiştir. Yüksek soğutma hızları ve uygun sıcaklık aralıklarının, camın düzlemselliğini koruyarak optik ve mekanik özelliklerini iyileştirdiği tespit edilmiştir. Buna karşın, sıcaklık dalgalanmaları ve dengesiz soğutma süreçleri, camın düzlemselliğinde bozulmalara yol açmıştır. Çalışma, temperleme sürecinin parametrelerinin camın yüzey kalitesi ve düzlemselliği üzerindeki kritik etkisini ortaya koymuş ve üretim süreçlerinde bu parametrelerin optimizasyonunun önemini vurgulamıştır. Araştırma bulguları, cam üretiminde kaliteyi

artırmaya yönelik pratik öneriler sunmuş ve temperleme sürecinin kontrolüne dair literatüre önemli bir katkı sağlamıştır.

Xiaomian ve Yufeng (2018) tarafından gerçekleştirilen çalışma, cam yüzeyindeki kalite kusurlarını tespit etmek için makine görüşü tabanlı bir denetim sistemi geliştirmeyi amaçlamıştır. Araştırma, geleneksel manuel kontrol yöntemlerine kıyasla, makine görüşünün cam yüzey kusurlarını daha hızlı ve doğru bir şekilde tespit edebileceğini ortaya koymuştur. Çalışmada geliştirilen sistem, yüzeydeki çatlaklar, kabarcıklar ve çizikler gibi kusurları algılamak için görüntü işleme algoritmalarını kullanmıştır. Deneysel sonuçlar, makine görüşü tabanlı sistemin %97'nin üzerinde bir doğruluk oranı sağladığını ve üretim süreçlerinde daha verimli bir kalite kontrol imkânı sunduğunu göstermiştir. Ayrıca, bu yaklaşımın, üretim hattındaki yüksek hızlara uyum sağlayarak gerçek zamanlı hata tespiti gerçekleştirebildiği belirtilmiştir.

Liang ve arkadaşları (2019) tarafından gerçekleştirilen çalışma, derin öğrenme tabanlı bir çerçeve kullanarak cam kapların gerçek zamanlı incelenmesini sağlayan kapsamlı bir sistem geliştirmeyi amaçlamıştır. Çalışmada, cam kapların üretim hattında karşılaşılabilecek yüzey kusurları ve yapısal hataların otomatik olarak tespit edilmesini sağlayan bir sistem tasarlanmıştır. Bu sistem, derin öğrenme algoritmalarını entegre ederek, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları ve işlem hızı sunmaktadır. Araştırmada geliştirilen sistem, cam kaplarda kabarcıklar, çatlaklar ve şekil bozuklukları gibi kusurları algılamak için optimize edilmiştir. Sistem, üretim sürecindeki yüksek hızlara rağmen gerçek zamanlı çalışabilirliği ile dikkat çekmiştir. Elde edilen sonuçlar, derin öğrenme tabanlı çerçevenin, hata tespitinde %98'in üzerinde bir doğruluk oranı sağladığını göstermiştir. Bu doğruluk, üretim hattındaki kalite kontrol süreçlerini önemli ölçüde iyileştirme potansiyeline işaret etmektedir. Liang ve arkadaşlarının çalışması, cam üretiminde kalite kontrol süreçlerinin modern teknolojilerle nasıl optimize edilebileceğini göstermiştir. Derin öğrenme tabanlı bu yaklaşım, yüksek hacimli üretim yapan işletmelerde kalite standartlarını artırmaya yönelik önemli bir adım olarak değerlendirilmektedir. Çalışma, bu alanda yapılacak gelecekteki araştırmalara önemli bir referans niteliği taşımaktadır.

Öztürk (2019) tarafından gerçekleştirilen yüksek lisans çalışması, endüstriyel cam üretiminde kullanılan CAD/CAM (Bilgisayar Destekli Tasarım ve Bilgisayar Destekli Üretim) sistemlerinin sanatsal cam üretimine olan etkilerini incelemeyi amaçlamıştır. Çalışmada, CAD/CAM teknolojilerinin sanatsal cam üretim süreçlerinde nasıl

kullanıldığı, üretim kalitesini ve tasarım özgürlüğünü nasıl etkilediği değerlendirilmiştir. Araştırmada, CAD/CAM sistemlerinin, sanatsal cam tasarımlarında yüksek hassasiyet ve detay sunarak geleneksel yöntemlere kıyasla önemli avantajlar sağladığı tespit edilmiştir. Ayrıca, bu teknolojiler sayesinde, karmaşık geometrik formların ve özgün tasarımların daha kısa sürede ve hatasız bir şekilde üretilebildiği belirtilmiştir. CAD/CAM uygulamaları, üretim süreçlerinde zaman ve maliyet tasarrufu sağlamasının yanı sıra, üretim verimliliğini artırmada da etkili bulunmuştur.

Bükücü ve Görkem (2020) tarafından gerçekleştirilen çalışma, cam ürünlerde gerçek zamanlı hata tespiti yapabilen yeni bir prototip geliştirmeyi amaçlamıştır. Araştırmada, cam yüzeyindeki kusurların otomatik olarak tespit edilmesine olanak tanıyan bir sistem tasarlanmış ve bu sistemin etkinliği test edilmiştir. Prototip, özellikle üretim hattındaki kusurların algılanmasında yüksek doğruluk oranları sunan görüntü işleme algoritmalarını temel almıştır. Bulgular, geliştirilen sistemin, çizikler, kabarcıklar ve yüzey pürüzleri gibi kusurları gerçek zamanlı olarak algılayabildiğini ve geleneksel manuel yöntemlere kıyasla daha hızlı ve doğru sonuçlar ürettiğini göstermiştir. Çalışmada ayrıca, otomatik sistemlerin insan kaynaklı hata oranlarını önemli ölçüde azalttığını vurgulanmıştır. Sistem, üretim süreçlerinde kalite kontrol etkinliğini artırmak için umut vaat etmektedir. Araştırma, cam üretim süreçlerinde otomatik hata tespit teknolojilerinin uygulanabilirliğini ortaya koymuş ve bu teknolojilerin, özellikle yüksek hacimli üretim yapan işletmelerde kalite kontrol süreçlerini optimize etmek için önemli bir potansiyele sahip olduğunu göstermiştir. Bu çalışma, otomatik hata tespitine yönelik literatüre önemli bir katkı sağlamaktadır. Literatür taraması Çizelge 2.1’de gösterilmiştir.

Çizelge 2. 1. Tez ile ilgili Literatür Taraması

Çalışma	Konu	İçerik	Sonuç
Imbert (1989)	Düz cam endüstrisinde otomatik denetim	Cam yüzeyindeki kusurların optik sensörler ve görüntü işleme algoritmaları ile tespiti	Manuel denetime göre daha hızlı olduğu sonucu elde edilmiştir.
Kılıç (1995)	Cam üretiminde üfleme	Üfleme tekniğinin tarihçesi, uygulamaları ve üretim kalitesine etkisi	Özgün tasarımlar sağlarken, operatör deneyimine bağlı değişkenlik
Fezani ve Rahmani (2006)	Düz cam yüzeyindeki kusurların dalgacık analizi ile tespiti	Çizik, çatlak ve dalgalanmaların dalgacık dönüşümleri ile algılanması	%94 doğruluk oranı ile yüksek hassasiyet
Rıza ve Anton (2007)	Şişeleme hattında yapay sinir ağları ile görsel denetim	Yüzey kusurlarının görüntü işleme ve yapay sinir ağları ile tespiti	%96 doğruluk oranı ve gerçek zamanlı uygulama
Adamo, Attivissimo ve Di Nisio(2010)	Saten camlarda kalite kontrol sistemi	Görüntü işleme tabanlı denetim ve sistem kalibrasyonu	%98 doğruluk oranı ve gerçek zamanlı kalite kontrol
Keser (2010)	Silis kumunun kaliteli cam üretimine etkisi	Silis kumunun tane boyutunun camın özelliklerine etkisi	Homojenlik ve ışık geçirgenliği artışı, enerji tasarrufu
Zhang, Guo, Qi ve Wang (2012)	DFT ve optimal eşikleme yöntemi ile cam kusur tespiti	Frekans analizleri ve eşikleme ile kusurların belirlenmesi	%95 doğruluk oranı ve hızlı kalite kontrol
Akdemir ve Öztürk (2015)	Cam yüzey kusurlarının dalgacık dönüşümü ile analizi	Dalgacık dönüşümleri ile çizik ve çatlak tespiti	%95 doğruluk oranı ve mikroskobik kusurların algılanması
Kaya (2016)	Temperleme sürecinin cam düzlemselliğine etkisi	Temperleme parametrelerinin fiziksel özelliklere etkisi	Yüksek soğutma hızının düzlemselliği artırması
Xiaomian ve Yufeng (2018)	Makine görüşü tabanlı cam denetim sistemi	Çatlak, kabarcık ve çiziklerin görüntü işleme ile tespiti	%97 doğruluk oranı ve hızlı denetim
Liang ve ark. (2019)	Derin öğrenme tabanlı cam kap denetimi	Derin öğrenme algoritmaları ile yüzey kusurlarının tespiti	%98 doğruluk oranı ve gerçek zamanlı hata tespiti
Öztürk (2019)	Sanatsal cam üretiminde CAD/CAM teknolojileri	Sanatsal cam tasarımlarında hassasiyet ve detay artışı	Tasarım özgürlüğü ve maliyet verimliliği
Bükücü ve Gökem (2020)	Cam ürünlerde otomatik hata tespiti	Gerçek zamanlı görüntü işleme temelli hata tespit sistemi	%98 doğruluk oranı ve manuel yöntemlerden üstünlük

1.2 Tezin Amacı ve Önemi

Günümüzde artan dünya nüfusu ve bununla birlikte yükselen tüketim ihtiyacı, yalnızca üretim aşamasında değil, ürünlerin son kullanıcıya ulaştıktan sonraki süreçlerinde de kalite ve güvenilirlik gereksinimini artırmıştır. Özellikle cam gibi kırılğan ve hassas yapıya sahip malzemelerde, kullanıcıya ulaşan ürünlerde meydana gelebilecek çizik, çatlak veya kırık gibi kusurlar hem görsel kaliteyi düşürmekte hem de kullanıcı güvenliği açısından risk oluşturmaktadır. Bu nedenle, ürünlerin kullanım sürecinde de

kontrol altında tutulması ve olası kusurların erken aşamada tespit edilmesi önemli bir gereklilik haline gelmiştir. Bu çalışmanın temel amacı, son kullanıcıya ulaşmış cam yüzeylerde oluşabilecek kusurların (çizik, çatlak, kırık vb.) bilgisayarlı görü ve yapay zekâ destekli sistemler aracılığıyla otomatik olarak tespit edilmesini sağlamaktır. Böylece, manuel kontrollerden kaynaklı insan hataları ortadan kaldırılarak daha güvenilir, hızlı ve sürdürülebilir bir kalite kontrol süreci oluşturulması hedeflenmektedir. Bu amaç doğrultusunda, 4065 eğitim, 463 doğrulama ve 447 test görüntüsünden oluşan toplam 4975 görüntülük bir veri seti hazırlanmış ve bu veri seti YOLOv5, YOLOv8 ve YOLOv11 gibi güncel derin öğrenme tabanlı nesne tespiti algoritmaları ile eğitilmiştir. Modellerin başarıları; doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), F1 skoru ve mAP50 gibi performans metrikleri üzerinden karşılaştırılmıştır. Bu tez çalışması, cam yüzey kusurlarının son kullanıcı aşamasında tespitiyle hem kullanıcı memnuniyetine katkı sağlamayı hem de ürün güvenliğini artırmayı amaçlamaktadır. Ayrıca, satış sonrası kalite kontrol süreçlerinin dijitalleştirilerek daha verimli ve akıllı hale getirilmesine yönelik önemli bir adım niteliği taşımaktadır.

2. GENEL BİLGİLER

2.1. Bilgisayarlı Görünün Tanımı ve Önemi

Bilgisayarlı görü, dijital görüntülerden bilgi çıkarma sürecini otomatize ederek, makinelerin insan gibi görsel algılama yeteneklerine sahip olmasını hedefleyen bir teknoloji alanıdır. Bu disiplin, makinenin dijital ortamda sunulan görüntüleri analiz etmesini ve bu görüntüler içindeki objeleri, metinleri veya çeşitli modelleri tanımasını sağlar. İnsan gözünün görebildiği detayları algılayabilen makineler, bu sayede nesneleri tanıyabilir, sınıflandırabilir, hataları tespit edebilir ve özgün analizler yapabilir (Yeadon, 1992: 6).

Bilgisayarlı görü teknolojisi, geniş bir yelpazede endüstriyel ve tüketici uygulamalarında kullanılır. Otomotiv sektöründen sağlık hizmetlerine, güvenlik sistemlerinden akıllı telefon uygulamalarına kadar birçok alanda hayati önem taşır. Örneğin, otonom araçlar çevrelerini anlamak ve trafikte güvenli bir şekilde hareket etmek için bilgisayarlı görü tekniklerine bağımlıdır. Tıbbi görüntüleme ve teşhiste, bilgisayarlı görü kullanılarak yapılan analizler, doktorlara hastalıkları teşhis etme ve tedavi planları oluşturma konusunda yardımcı olur. Ayrıca güvenlik kameraları, bilgisayarlı görü yardımıyla şüpheli aktiviteleri tespit edip uygun birimlere bilgi verebilir (LeVeau, 2014: 2014: 161). Bu teknoloji, görüntü işleme tekniklerini temel alır ve bu teknikleri daha ileri düzeyde algoritmalarla birleştirerek makinelerin karmaşık görsel bilgileri işlemesine olanak tanır. Bilgisayarlı görünün ana hedeflerinden biri, elde edilen görsel bilgileri kullanarak makinenin kendiliğinden öğrenmesi ve adaptasyonunu sağlamaktır. Bu, özellikle yapay zekâ ve makine öğrenmesi alanlarıyla yakından ilişkilidir. Geliştirilen algoritmalar, makinelerin görüntüleri derinlemesine analiz etmesini ve bu analizlerden sonuçlar çıkarmasını mümkün kılar. Bu süreçte, karmaşık karar verme mekanizmaları, makinelerin veriye dayalı kararlar almasını ve bu kararları uygulamalarını sağlayacak şekilde tasarlanmıştır (Ikeuchi, 2021: 33-35). Bilgisayarlı görü, dijital çağın vazgeçilmez teknolojilerinden biri haline gelmiş ve makinelerin görsel dünyayı anlamasını ve insanlara daha etkili şekilde hizmet etmesini sağlamıştır. Her geçen gün gelişen bu alan, gelecekte teknolojinin daha da entegre olduğu bir dünya için temel taşlardan biri olarak kabul edilmektedir.

2.2. Bilgisayarlı Görünün Tarihsel Gelişimi

Bilgisayarlı görü, çoğu kaynakta 1966 yılında Marvin Minsky, Seymour Papert, Gerald Joy Sussman ve MIT'nin yapay zekâ ekibi tarafından başlatılan Yaz Görü Projesi sırasında gelişmiştir. Bu projede, görsellerin otomatik olarak yüzey ve şekil özelliklerine göre nasıl segmente edilebileceği araştırılmıştır. 1970'lerin sonrasında, bilgisayarlı görü teknolojisi büyük gelişmeler kaydetmiş olmasına rağmen, bu ilk laboratuvar çalışmaları birçok teknik zorluğu da beraberinde getirmiştir. Sorular ortaya çıkmıştır: Kamera görüşü insan görüşünden ne kadar farklıdır? Bilgisayarlı görü ne kadar insan görüşüne yaklaştırılmalıdır ve bunun sonuçları neler olabilir? İnsan görüşü bir bilgisayar tarafından modellenilebilir ve genelleştirilebilir mi? En çok bellek ve güç tüketimi ne zaman ve nerede gerçekleşir? Bilgisayarlı görü, karmaşıklık ve hataları nasıl çözebilir?

1980 yılında, Fukushima sinir ağları modelini geliştirerek bu sorulara cevap aramaya başlamıştır. Bu model, kendini düzenleyebilen ve öğretmensiz öğrenme yeteneğine sahip olarak tanıtılmıştır (Fukushima, 1980: 193-202). Amacı, objeleri geometrik şekillerine göre tanımlamaktır. 1998 yılında, Lecun ve ekibi, geliştirdikleri evrişimli sinir ağları (CNN) modelini kullanarak el yazılarını tanımlama konusunda önemli bir başarı elde etmiştir (Lecun vd., 1998: 2278-2324). 2012'de, Toronto Üniversitesi'nden bir grup araştırmacı, yapay zekâ ve bilgisayarlı görü projelerine yeni bir soluk getiren AlexNet isimli sinir ağı algoritmasını geliştirmişlerdir. AlexNet, büyük veri setlerini daha kısa sürede ve daha az hata ile tanımlama konusunda başarılı olmuştur (Krizhevsky vd., 2012: 1097-1105).

Önceki çalışmalarda nesne tanıma için kullanılan sınıflandırıcılar genellikle belirli nesne tanımlama ihtiyaçlarına göre modifiye ediliyordu. Bu yöntemde, nesne tanıma işlemi, uzamsal bağlamda sınırlayıcı kutular ve bu kutulara ilişkin sınıf olasılıkları kullanılarak bir regresyon problemi olarak ele alınmaktadır. Bir defada çalıştırıldığında, tek bir sinir ağı tüm görüntüden doğrudan sınırlayıcı kutuları ve sınıf olasılıklarını belirlemektedir. Bu sistem saniyede 45 kare işleyebilirken, daha hızlı ve küçük bir versiyon olan Fast YOLO ise saniyede 155 kare işleyebilmektedir. Diğer algoritmalara kıyasla yer belirleme hataları daha yüksek olsa da yanlış pozitif çıkarma oranı daha düşüktür. Tek bir evrişimli sinir ağı, bir kare üzerinde eş zamanlı olarak birden fazla sınır kutusu ve sınıf olasılığını tahmin edebilir. YOLO'nun diğerlerinden farklı olan özelliği, görüntüyü tek seferde tamamen görebilmesi ve bu sayede birden fazla nesneyi aynı anda tanımlayabilmesidir (Redmon vd., 2016: 779-788).

2.3. Bilgisayarlı Görünün Temel Kavramları

Bilgisayarlı görü, bilgisayarların dijital görüntülerden bilgi çıkararak insan benzeri görü yeteneğine yaklaşmasını amaçlayan bir alandır. Temel kavramlar, bilgisayarlı görü tekniklerinin özüne inerek bu alandaki algoritmaların geliştirilmesine olanak tanır. Bu bölümde piksel, vektör ve matris kavramları; renk modelleri ve görüntü çözünürlüğü ile ölçeklendirme ele alınacaktır.

2.3.1. Piksel, Vektör ve Matris Kavramları

Bilgisayarlı görü, dijital görüntülerin temel birimleri olan piksel (pixel) kavramı üzerine inşa edilir. Piksel, "picture element" ifadesinden türemiş olup bir görüntünün en küçük parçasıdır ve genellikle bir renk veya parlaklık değerini ifade eder (Stockman ve Shapiro, 2001: 11-15). Pikseller bir araya gelerek dijital görüntü matrislerini oluşturur. Bu matrisler, bilgisayarlı görü algoritmalarının analiz ettiği veri yapılarını tanımlar. Bir dijital görüntü, piksellerin düzgün bir dizi veya matris halinde düzenlenmesiyle tanımlanabilir. Matris, her bir satır ve sütununda piksel değerlerini saklar ve bu değerler gri tonlama görüntülerinde 0–255 arasında değerler alabilir (Ballard ve Brown, 1982: 13-14). Renkli görüntülerde ise her bir piksel genellikle RGB renk modelindeki bileşenlerle tanımlanır. Vektör kavramı ise bilgisayarlı görü algoritmalarında özellikle özellik çıkarma ve sınıflandırma aşamalarında kritik bir rol oynar. Bir vektör, bir görüntünün belirli özelliklerini temsil eden bir dizi sayıdan oluşur. Bu vektörler, özellikle nesne tanıma veya hareket algılama gibi çalışmalarda, bilgisayarın görüntüyü anlamlandırmasına yardımcı olur (Forsyth ve Ponce, 2002: 22). Son olarak, bilgisayarlı görüde matris ve vektör hesaplamaları, algılama sistemlerinin temelini oluşturur. Bu yapılar üzerine kurulan algoritmalar, görüntünün geometrik şekilleri ve dokuları gibi karmaşık özelliklerini çıkarabilir (Arslan, 2023: 59-71).

2.3.2. Renk Modelleri: RGB, Grayscale, HSV

Bilgisayarlı görüde renk modelleri, bir görüntünün piksel değerlerini belirli bir formatta tanımlamak için kullanılır. En yaygın renk modelleri RGB (Red, Green, Blue), Grayscale ve HSV (Hue, Saturation, Value) modelleridir. RGB Renk Modeli: RGB renk modeli, ışık tabanlı renk oluşturma sisteminde kullanılır ve her bir pikselin kırmızı, yeşil ve mavi bileşenlerden oluşan bir renk kombinasyonu ile ifade edilmesini sağlar (Ballard ve Brown, 1982: 13-14). Bu model, bilgisayarlı görü algoritmalarında yaygın bir şekilde kullanılır; örneğin, YOLO gibi nesne algılama modelleri, görüntüleri RGB formatında

analiz eder (Redmon vd., 2016: 779-788). Grayscale renk modeli ise gri tonlama modelinde her piksel, 0 ile 255 arasında bir deęer alır. Bu model, genellikle hesaplama yükünü azaltmak ve özellik çıkarmada odaklanılacak bilgiyi sadeleştirmek için tercih edilir (Nalbant ve Uyanık, 2021: 9-12). Grayscale formatı, sınıflandırma ve şekil tanıma gibi uygulamalarda etkili bir çözüm sunar. HSV renk modeli ise HSV modelinde renkler tonu (Hue), doygunluğu (Saturation) ve parlaklığı (Value) ile ifade edilir. Bu model, renkler arasındaki farklılıkları algılamak için kullanılır ve özellikle nesne izleme gibi uygulamalarda kullanılır (Blehm vd., 2005: 253-262). Renk modelleri arasındaki seçim, uygulanacak algoritmanın amacına baęlıdır. Her model, belirli şartlar altında bilgisayarlı görü algoritmalarının performansını optimize etmek için kullanılabilir (Ikeuchi, 2021: 33-35).

2.3.3. Görüntü Çözünürlüğü ve Ölçeklendirme

Bir dijital görüntünün çözünürlüğü, görüntünün birim alanındaki piksel sayısı ile belirlenir. Çözünürlük, görüntünün detay seviyesi ve netliği üzerinde önemli bir rol oynar. Yüksek çözünürlük, daha fazla detay sağlarken hesaplama maliyetlerini artırabilir (Blehm vd., 2005). Ölçeklendirme, görüntünün boyutlarını değiştirerek istenen bir çözünürlük seviyesi elde etme işlemidir. Bu, özellikle nesne tanıma ve izleme gibi uygulamalarda önemlidir, çünkü farklı boyutlardaki nesnelerin tanınması ölçekleme yoluyla optimize edilebilir (Randolph, 2017: 253-262). Görüntünün çözünürlüğü ve ölçeklendirme arasındaki denge, algoritmanın başarı oranını etkiler. Örneğin, Lecun ve ekibinin el yazıları tanıma başarısında, doğru çözünürlük seviyesinin kullanılması etkili olmuştur (Lecun vd., 1998: 77). Benzer şekilde, AlexNet gibi modeller, büyük veri setlerinde çözünürlük ve ölçekleme optimizasyonunu başarıyla kullanarak daha doğru sonuçlar elde etmiştir. Çözünürlük ve ölçeklendirme, bilgisayarlı görü sistemlerinin performansını artırmak ve algoritmaları optimize etmek için kritik bir öneme sahiptir (Büyükarıkan ve Üncü, 2019: 228-240).

2.4. Bilgisayarlı Görü Teknikleri ve Yöntemleri

Bilgisayarlı görü, görüntü işleme ve yapay zekâ tekniklerini bir araya getirerek çeşitli problemlere çözüm sunan disiplinler arası bir alandır. Bu bölümde, bilgisayarlı görü tekniklerinin bazı temel yöntemleri akademik kaynaklar ışığında ele alınacaktır.

2.4.1. Görüntü Filtreleme ve Gürültü Giderme

Görüntü filtreleme ve gürültü giderme, bilgisayarlı görünün temel adımlarından biridir. Bu işlem, görüntüde bulunan rastgele gürültülerin azaltılması ve görüntü kalitesinin artırılması için gerçekleştirilir. Özellikle inşaat sektöründe, bu tür teknikler yapı yüzeylerinin analizi gibi uygulamalarda sıklıkla kullanılmaktadır (Xu vd., 2021: 3383-3397). Ayrıca, trafik analizi gibi alanlarda da bu yöntemlerle görüntülerin daha doğru işlenmesi sağlanmaktadır (Buch vd., 2011: 920-939). Temel olarak median filtresi ve Gaussian filtresi gibi yöntemler kullanılmaktadır (Cyganek ve Siebert, 2011: 11).

2.4.2. Kenar Tespiti (Edge Detection)

Kenar tespiti, bir görüntüdeki nesnelerin sınırlarını belirlemek için kullanılan önemli bir tekniktir. Canny, Sobel ve Laplacian gibi yöntemler, kenar tespitinde yaygın olarak kullanılmaktadır (Meer, 2004: 3-4). Özellikle üretim sektöründe, nesne tanıma ve sınıflandırma süreçlerinde kenar tespitine dayalı algoritmalar önemli bir rol oynamaktadır (Zhou vd., 2022: 105-117). Bu teknikler, görüntü üzerinde geometrik şekilleri algılamada yüksek doğruluk sunmaktadır (Solak ve Altınışık, 2018: 56-65).

2.4.3. Segmentasyon Teknikleri

Segmentasyon, bir görüntüyü farklı bölgelerine ayırarak nesneleri veya özellikleri izole etmeye yönelik bir tekniktir. Yapay zekâ temelli segmentasyon yöntemleri, özellikle tarım alanında ürün sınıflandırma ve rekolte tahmini gibi uygulamalarda başarıyla kullanılmaktadır (Işık vd., 2022: 80-88). Ayrıca, k-means ve otsu eşikleme gibi klasik yöntemler de bu süreçte sıklıkla tercih edilmektedir (Solak ve Altınışık, 2018: 56-65).

2.4.4. Şablon Eşleme (Template Matching)

Şablon eşleme, bir görüntü içinde belirli bir nesnenin veya desenin varlığını tespit etmek için kullanılan etkili bir tekniktir. Bu yöntem, nesne tespiti ve takibi gibi uygulamalarda geniş bir kullanım alanına sahiptir (Öncü, 2014: 3-4). Özellikle oyuncak şekillerinin tespitinde şablon eşleme yöntemlerinin etkili olduğu gösterilmiştir (Dersuneli vd., 2021: 1290-1303). Bu teknik, hedef nesnenin önceden tanımlanmış bir şablon ile karşılaştırılmasını içerir.

2.4.5. Özellik Çıkarımı (Feature Extraction)

Özellik çıkarımı, görüntüdeki önemli bilgilerin tanımlanması ve analizi için gerekli olan bir adımdır. Özellikle nesne tanıma ve yüzey analizinde, bu teknik

bilgisayarlı görü uygulamalarının temelini oluşturur (Cyganek ve Siebert, 2011: 11). Bu alanda kullanılan yöntemler, SIFT (Scale-Invariant Feature Transform) ve SURF (Speeded-Up Robust Features) gibi algoritmaları içerir (Meer, 2004: 3-4).

2.4.6. Derinlik Algılama ve Stereoskopik Görü

Derinlik algılama, görüntülerdeki üç boyutlu bilgilerin çıkarılması amacıyla kullanılan bir tekniktir. Stereoskopik görüntüleme, iki farklı perspektiften alınan görüntüleri birleştirerek derinlik algısını oluşturur (Wöhler, 2009: 33-34). Bu yöntemler, insansız hava araçlarının navigasyonu ve otomotiv endüstrisinde çarpışma önleme sistemlerinde yaygın olarak kullanılmaktadır (Mahadevkar vd., 2022: 42).

2.5. Yapay Zekâ

İnsan zekâsı, bize verilen akıl ve zekâ aracılığıyla çevremizde gerçekleşen olayları değerlendirme ve bu olaylara tepki verme yeteneğine sahiptir. Makineler ise kendilerine entegre edilen sensörler ve kameralar aracılığıyla çevresel uyarıcılara karşı tepki gösterir; bu, mesafe ölçümü, sıcaklık algılama ve görüntü işleme gibi işlevleri içerir. Bu çerçeveden bakıldığında, makinelerin de insanlara benzer, ancak daha basit bir zekâ seviyesine sahip oldukları söylenebilir (Dalgın, 2023: 11-15). Günümüzde, Nesnelerin İnterneti (IoT) teknolojisi sayesinde makineler, insan duyularını taklit eder şekilde çevrelerindeki olayları algılayabilir ve bu verileri işleyerek insanlar için faydalı sonuçlar üretebilir. İnsanlar, yaşadıkları dünyada kendilerini koruma, yaşamı sürdürme, sanat yaratma ve duygusal bağlar kurma gibi çeşitli becerilere sahipken; makineler ise hesaplama, büyük verileri hızlı ve doğru bir şekilde işleme ve analiz etme gibi konularda insanlara destek olmaktadır. Görüntü işleme teknikleri de benzer bir yaklaşımla işler; kameralar aracılığıyla toplanan görüntüler, deneysel çalışmalarda olduğu gibi eğitim ve test gruplarına ayrılarak işlenir. Bu verilerden elde edilen bilgiler, makinelerin karar verme süreçlerinde kullanılır.

Yapay zekâ alanının temelleri, 1950'li yıllarda matematikçi Alan Turing tarafından atılmış ve Turing testleri ile düşünebilen ve karar verebilen makinelerin geliştirilmesi fikri ortaya konmuştur. O zamandan bu yana yapay zekâ, konuşma, görme ve bilgi işleme gibi alanlarda hızla gelişmiştir. İnsanlar, karşılaştıkları yeni durumlar karşısında önceki tecrübelerinden faydalanarak karar verirken, yapay zekâ da benzer bir şekilde önceden toplanan verilere dayanarak işlem yapar. Öğrencilerin sınavlara hazırlanması gibi, yapay zekâ da önceden işlenmiş bilgileri kullanarak yeni sorunlara

özmler retir (Dawson, 2007: 5). Yapay zekâ alışmaları, genel olarak insan düşnce srelerinin makineler tarafından modellenenebilmesi olarak tanımlanır ve bu sreler hiyerarşik olarak yapay zekâ ve alt bileşenleri iinde şematize edilebilir. Bu teknolojik gelişmeler, makinelerin insan benzeri düşnme, muhakeme ve karar verme yeteneklerini taklit etmelerine olanak tanır. Şekil 2.1’de yapay zekâ ve kapsamındaki alt bileşenler hiyerarşik bir şekilde şematize edilmiştir




Şekil 2.1. Yapay Zekâ ve Alt Bileşenleri (Anonim, 2023)

Şekil 2.1, Yapay Zeka (YZ), Makine Öğrenmesi (MÖ) ve Derin Öğrenme (DÖ) arasındaki ilişkiyi açıklayan üç katmandan oluşan bir görselleştirmedir. En geniş katman olan Yapay Zekâ, bilgisayarların insan davranışlarını taklit etmesini sağlayan genel bir teknoloji olup, makinelerin problem çözme, karar verme ve öğrenme gibi görevleri gerçekleştirmesini amaçlar. Bunun bir alt kümesi olan Makine Öğrenmesi, verilerden öğrenmeyi ve deneyimlerle gelişmeyi sağlayan algoritmalar ve istatistiksel yöntemlerden oluşur, dolayısıyla YZ’nin gerçekleştirilmesinde kritik bir araçtır. En iteki katman ise Makine Öğrenmesinin daha özel bir alt kümesi olan Derin Öğrenme olup, yapay sinir ağlarını temel alarak çok katmanlı modellerle karmaşık öğrenme problemlerini çözmeye odaklanır ve özellikle büyük veri ile hesaplama gücü sayesinde son yıllarda popüler hale gelmiştir. Bu hiyerarşik yapı, Yapay Zekâ alanının genişliğini ve i ie geen alt bileşenlerini sade ve anlaşılır bir şekilde ifade etmektedir.

2.5.1. Makine Öğrenmesi

Makine öğrenmesi, yapay zekanın çeşitli fonksiyonları arasında öğrenme ve tanıma gibi temel işlemleri gerçekleştirmek için kullanılan bir dizi uygulamadan oluşur. Bu süreç, insanların önceden edinilmiş bilgilere dayanarak karar verme sürecine benzer

şekilde, toplanan bilgileri işler ve çeşitli algoritmalar aracılığıyla karşılaştırmalar yaparak en uygun sonuçlara ulaşmayı hedefler (Dalgın, 2023: 11-15). Yapay zekâ algoritmaları, geleneksel otonom sistemlerin aksine, oluşturulan veri setlerinden elde edilen deneyimleri kullanarak yeni girdileri tanıma, işleme ve öğrenilen bilgileri yeni durumlarda uygulayabilme yeteneğine sahiptir. Bu sürecin geliştirilmesi ve insansı öğrenme süreçlerinin makineler tarafından taklit edilmesi makine öğrenmesi olarak adlandırılır (Yılmaz, 2021: 1-3). Makine öğrenmesinin temeli, insan zekasını taklit edebilmek için tasarlanmış matematiksel algoritmalar üzerine kuruludur (Costa vd., 2015: 15-17). Bu algoritmalar, bir sorunu toplanan verilere uygun bir yapay zekâ modeli kullanarak çözme yöntemi olarak işlev görür. Aynı zamanda, büyük veri olarak adlandırılan ve Big Data denilen veri havuzları, verilere hızlı ve etkin bir şekilde erişim gibi yeni zorlukları da beraberinde getirmiştir (Suthaharan, 2014: 70-73). Sınıflandırma, yani classification tekniği sayesinde büyük veriler etkin bir şekilde kategorize edilerek veri erişimi kolaylaştırılmaktadır. Makine öğrenmesine ait alt algoritmaların gösterimi Şekil 2.2’de yapılmıştır.



Şekil 2.2. Makine Öğrenmesi Algoritmaları Hiyerarşisi (Rashidi vd., 2019: 44)

Şekil 2.2, makine öğrenmesi algoritmalarını ve türlerini üç ana kategoriye ayırarak farklı türdeki problemlere uygun yöntemleri gösteren bir hiyerarşiyi sunmaktadır. Denetimli öğrenme, etiketlenmiş veri setleriyle çalışarak modelin giriş verileriyle doğru çıktı arasında bağlantı kurmasını sağlar; sınıflandırma (örneğin, e-postaların spam olup olmadığını belirleme) ve regresyon (örneğin, bir evin fiyatını tahmin etme) bu yöntemin başlıca örnekleridir. Denetimsiz öğrenme, etiketsiz veri setleriyle çalışarak verilerdeki

gizli yapıları keşfetmeyi amaçlar; kümeleme (örneğin, müşteri davranışlarına göre segmentlere ayırma) ve boyutsal küçültme (örneğin, PCA kullanarak verileri özetleme) gibi teknikleri içerir. Pekiştirmeli öğrenme ise, bir ajanın bir ortamda hareket ederek ödül veya ceza yoluyla öğrenmesini sağlar ve amacı uzun vadeli ödülü maksimize eden bir politika öğrenmektir; buna örnek olarak, bir robotun bir labirentten çıkmayı öğrenmesi verilebilir. Bu hiyerarşi, makine öğrenmesi algoritmalarını problemlere göre sınıflandırarak hangi durumlarda hangi yaklaşımın kullanılacağını anlamayı kolaylaştırır; özetle, hedef çıktılar biliniyorsa denetimli öğrenme, verilerdeki gizli yapılar aranıyorsa denetimsiz öğrenme, bir ajan çevreyle etkileşim kurarak öğreniyorsa pekiştirmeli öğrenme yöntemi tercih edilir.

2.5.1.1. Denetimli Öğrenme

Makine öğrenimi, verilerden insan müdahalesi olmaksızın öğrenme yeteneği gösterebilen ve yeni deneyimler karşısında çözümler üretebilen programlardır. Özellikle denetimli makine öğrenimi, mevcut verilere ve bu verilere dayalı kanıtlara dayanarak tahminler yapma yöntemini benimser. Bu öğrenme biçiminde, model, önceden bilinen girdi veri setlerini ve bu verilere karşılık gelen çıktıları kullanarak eğitilir. Böylece model, yeni verilere ilişkin doğru tahminler yapacak şekilde hazırlanır. Denetimli öğrenme, tahmin etmeye çalışılan çıktı için bilinen verilerin bulunduğu durumlarda tercih edilen bir yöntemdir (Nizam ve Akın, 2014:16). Bu yöntem, öğrenme sürecinde veriler arasındaki ilişkileri anlamak ve yeni verilere karşı öngörülerde bulunmak için ideal bir çerçeve sunar.

2.5.1.1.1 Sınıflandırma Teknikleri

Sınıflandırma, girdi verilerinin belirli kategorilere ayrılması sürecidir (Tecim vd., 2022: 132-147). Bu süreçte, örneğin yürütülen bir araştırmada çilek bitkisine ait resimlerden oluşan bir veri seti kullanılmış ve çileklerin olgunluk durumlarına göre; olgun, yarı olgun, tam olgun ve olgunlaşmamış olarak etiketlenmiştir. Bu etiketleme, algoritmaların verileri belirli sınıflara göre eğitmesine olanak tanır ve makine, bu sınıflandırmayı temel alarak öğrenim sürecini gerçekleştirir. Eğitim sonrasında, makine yeni verileri de aynı sınıflandırma kriterlerine göre kategorize eder. Verilerin sınıflandırılabilmesi için, bu verilerin öncelikle etiketlenmesi ve kategorize edilebilmesi gereklidir. El yazısı tanıma gibi uygulamalar bu bağlamda bir örnek teşkil eder. El yazısı tanıma algoritmaları, harfleri, sembolleri ve sayıları tanıyabilmek için sınıflandırma

tekniklerini yaygın bir şekilde kullanır. Sınıflandırma için kullanılan yaygın algoritmalar arasında destek vektör makinesi (SVM), karar ağaçları, k-en yakın komşu, Naive Bayes, diskriminant analizi, lojistik regresyon ve sinir ağları bulunmaktadır (Harman, 2021: 7-13). Bu algoritmalar, farklı veri türlerini ve yapılarını dikkate alarak, verileri etkin bir şekilde sınıflandırarak kullanıcıya sunmaktadır. Bu yöntemler, gelişmiş analitik yetenekleri sayesinde, makine öğrenimi uygulamalarında önemli bir yere sahiptir.

2.5.1.1.2. Regresyon Teknikleri

Regresyon analizi, bağımlı ve bağımsız değişkenler arasındaki ilişkileri tahmin etmek amacıyla kullanılan istatistiksel bir yöntemdir. Regresyon yöntemleri, farklılık göstermekle birlikte, temel olarak klasik optimizasyon teorisine dayanır. Bu teori, en iyi değeri bulmayı hedefler ve genellikle doğrusal denklem sistemlerinin çözümü için en uygun sonucu elde etmeyi amaçlar (Dalgın, 2023: 11-15). Özellikle sayısal sinyal işleme ve benzeri sayısal odaklı disiplinlerde, çoğu pratik regresyon problemi, doğrusal denklem sistemlerinin çözümü için optimal çözümleri bulmayı gerektirir. Bu nedenle, araştırmacılar doğrusal regresyon yöntemlerini veri özelliklerini tanımlamak için kullanır ve bu süreçte yöntemin daha çok teorik yönlerine odaklanırlar (Cadzow, 2002. 9-10). Regresyon analizinin iki temel türü olan basit doğrusal regresyon ve çoklu doğrusal regresyon vardır. Basit doğrusal regresyon, tek bir açıklayıcı değişken ile yanıt değişkeni arasındaki doğrusal ilişkiyi incelemek için kullanılır. Eğer yanıt değişkeni ile birden fazla açıklayıcı değişken arasındaki ilişki, doğrusal veya eğrisel olarak tanımlanmak istenirse, bu durum çoklu doğrusal regresyon analizi ile ele alınır (Okur, 2009: 44). Bu yöntemler, çeşitli bilimsel ve ticari uygulamalarda değişkenler arasındaki ilişkileri belirlemek ve gelecekteki değerleri tahmin etmek için sıklıkla tercih edilir.

2.5.1.2. Denetimsiz Öğrenme


Denetimsiz öğrenme, makine öğrenmesi disiplinlerinden biri olarak, etiketsiz veya tanımsız veriler üzerinden anlamlı bilgiler elde etmeyi amaçlar. Bu yöntemde, veri setinde önceden belirlenmiş bir çıktı veya yanıt değişkeni bulunmaz; dolayısıyla algoritma, girdi verilerini analiz ederek veri içindeki gizli yapıları veya düzenleri keşfetmeye çalışır. Bu süreç, verilerin ortak özelliklere sahip alt gruplara ayrılmasına dayanır ve bu gruplar kendi içinde benzer, birbirlerinden ise farklı özellikler gösterir (Bulut vd., 2014: 77-79). Kümeleme, denetimsiz öğrenme yaklaşımlarından en yaygın olanlarından biridir ve verileri benzerliklerine göre gruplara ayırır. Örneğin, bir

pazarlama veri tabanında müşterilerin alışveriş davranışlarına göre segmentlere ayrılması, kümeleme algoritması kullanılarak gerçekleştirilebilir. Bu metodoloji, veriler arasındaki ilişkileri anlamak ve belirli örüntüleri tanımlamak için oldukça etkilidir (Ganioğlu vd., 2024: 880-894). Kümeleme yöntemleri arasında K-means, hiyerarşik kümeleme ve DBSCAN gibi çeşitli algoritmalar bulunmaktadır. K-means algoritması, veri noktalarını K sayıda kümeye ayırırken, hiyerarşik kümeleme, verileri adım adım daha küçük kümeler halinde bölerek bir ağaç yapısı oluşturur. DBSCAN ise yoğunluk bazlı bir yaklaşım sergileyerek, yoğunluk açısından farklılık gösteren veri bölgelerini ayırt eder (Kırat ve Aydın, 2023: 13). Denetimsiz öğrenme, özellikle büyük veri setlerindeki gizli yapıları ortaya çıkarmada ve veri madenciliği uygulamalarında kritik bir rol oynar. Bu yaklaşım, veri bilimcilerin ve analistlerin, verileri etiketleme ihtiyacı olmadan doğrudan içgörüler elde etmelerine olanak tanır. Ayrıca, alışveriş sepeti analizi, sosyal ağ analizi, genetik kümeleme ve görüntü segmentasyonu gibi çok çeşitli alanlarda uygulamalar sunmaktadır (Ganioğlu vd., 2024: 880-894).

2.5.1.2.1 Kümeleme

Kümeleme yöntemi, denetimsiz öğrenme kapsamında sıklıkla başvuru alan tekniklerden biridir ve etiketlenmemiş, kategorize edilmemiş veriler üzerinden yapılar veya modeller oluşturmayı amaçlar. Bu yöntem, veri setlerinde doğal olarak var olan gruplamaları veya kümeleri (clusters) keşfetmek için tasarlanmıştır. Algoritmalar, verileri analiz ederek içlerinde benzer özellikler gösteren veri noktalarını gruplandırır ve bu sayede veri seti içerisindeki doğal yapıları ortaya çıkarır. Küme sayısı ve sınıf çeşitliliği, veri setinin özelliklerine ve analiz amaçlarına göre değişkenlik gösterebilir. Kümeleme algoritmaları, bu değişkenlikleri dikkate alarak farklı sayıda ve çeşitte kümeler oluşturabilir. Örneğin, veri setindeki farklılıkların yoğunluğuna bağlı olarak daha az veya daha fazla sayıda küme belirlenebilir. Ayrıca, kümeleme işleminde, oluşturulan grupların detay seviyelerinin ayarlanması da mümkündür. Bu, özellikle çeşitli uygulama senaryolarında faydalı olabilir; zira analistler veya araştırmacılar, spesifik ihtiyaçlara göre kümeler arasındaki ayrıntı düzeyini artırabilir veya azaltabilir. Bu esneklik, kümeleme yönteminin veri keşif süreçlerinde geniş bir uygulama yelpazesi sunmasını sağlar (Atalay ve Çelik, 2017: 22-25). Bu yöntem, pazar segmentasyonu, sosyal medya analizi, tıbbi görüntüleme ve biyoenformatik gibi alanlarda değerli içgörüler sunarak, büyük ve karmaşık veri setlerinin anlaşılmasında kritik rol oynar. Kullanıcıların özgün ihtiyaçlarına göre ayarlanabilir olması, kümeleme tekniklerinin esnek ve güçlü araçlar olarak ön plana

çıkmasını sağlar. Şekil 2.3 denetimli ve denetimsiz kümeleme modelleri için örnek görseller verilmiştir.



Şekil 2.3. Denetimli ve Denetimsiz Kümeleme Modelleri (Hazır, 2021: 66-67)

Şekil 2.3, makine öğrenmesi algoritmalarını ve türlerini üç ana kategoriye ayırarak farklı türdeki problemlere uygun yöntemleri gösteren bir hiyerarşiyi sunmaktadır. Denetimli öğrenme, etiketlenmiş veri setleriyle çalışarak modelin giriş verileriyle doğru çıktı arasında bağlantı kurmasını sağlar; sınıflandırma (örneğin, e-postaların spam olup olmadığını belirleme) ve regresyon (örneğin, bir evin fiyatını tahmin etme) bu yöntemin başlıca örnekleridir. Denetimsiz öğrenme, etiketsiz veri setleriyle çalışarak verilerdeki gizli yapıları keşfetmeyi amaçlar; kümeleme (örneğin, müşteri davranışlarına göre segmentlere ayırma) ve boyutsal küçültme (örneğin, PCA kullanarak verileri özetleme) gibi teknikleri içerir. Pekiştirmeli öğrenme ise, bir ajanın bir ortamda hareket ederek ödül veya ceza yoluyla öğrenmesini sağlar ve amacı uzun vadeli ödülü maksimize eden bir politika öğrenmektir; buna örnek olarak, bir robotun bir labirentten çıkmayı öğrenmesi verilebilir. Bu hiyerarşi, makine öğrenmesi algoritmalarını problemlere göre sınıflandırarak hangi durumlarda hangi yaklaşımın kullanılacağını anlamayı kolaylaştırır; özetle, hedef çıktılar biliniyorsa denetimli öğrenme, verilerdeki gizli yapılar aranıyorsa denetimsiz öğrenme, bir ajan çevreyle etkileşim kurarak öğreniyorsa pekiştirmeli öğrenme yöntemi tercih edilir.

2.5.1.2.1.1. K-Ortalama

K-means, yinelemeli bir kümeleme algoritmasıdır ve veri setlerini belirlenen "K" sayıda kümeye ayırmak için kullanılır. Başlangıçta, kullanıcı tarafından istenilen sayıda küme (K) belirlenir. Bu sayı, algoritmanın çalışması süresince sabit kalır ve veri noktaları

bu K gruplarına atanır. K-means algoritması, her bir yinelemede veri noktalarını en uygun kümeye yerleştirmeye çalışarak, küme içi varyansı en aza indirmeyi hedefler (Dalgın, 2023: 11-15). K'nin büyüklüğü, kümelenen grupların detay düzeyini doğrudan etkiler. Daha yüksek bir K değeri, genellikle daha fazla sayıda küçük grupların oluşmasına ve dolayısıyla daha detaylı bir ayrım yapılmasına olanak tanır. Ancak, K'nin çok yüksek seçilmesi bazen verilerin aşırı parçalanmasına ve anlamlı gruplandırmaların kaybedilmesine neden olabilir. Bu nedenle, K değerinin seçimi, veri setinin yapısını ve analiz hedeflerini dikkate alınarak yapılmalıdır (Yükseltürk vd., 2004: 118-133). K-means algoritması, başlangıç noktalarının seçimine duyarlıdır ve farklı başlangıç noktaları, farklı sonuçlar üretebilir. Bu sebeple, algoritmanın uygulanması sırasında çeşitli başlangıç noktaları denenebilir veya algoritmanın daha gelişmiş versiyonları olan K-means++ gibi yöntemler tercih edilebilir ki bu yöntemler başlangıç küme merkezlerini daha etkili bir şekilde seçer. Bu sayede algoritmanın kararlılığı ve performansı artırılmış olur.

2.5.1.2.1.2. Hiyerarşik Kümeleme

Hiyerarşik kümeleme, verileri bir ağaç yapısı şeklinde, hiyerarşik olarak sınıflandıran bir yöntemdir (Karakaya, 2021: 55). Bu yöntem, veri noktalarını alt kümeler şeklinde bölerek çalışır ve genellikle tek bağlantı (single linkage), tam bağlantı (complete linkage) veya ortalama bağlantı (average linkage) gibi çeşitli bağlantı yöntemlerini kullanmaktadır. Tek bağlantı yöntemi, kümeler arasındaki en yakın elemanlar arası mesafeyi dikkate alırken, tam bağlantı, kümeler arasındaki en uzak elemanlar arası mesafeyi kullanır. Ortalama bağlantı ise, iki küme arasındaki tüm elemanlar arası mesafelerin ortalamasını alır. Bu farklı bağlantı yöntemleri, kümelenme sürecinin doğasını ve sonuçlarını önemli ölçüde etkileyebilir. Hiyerarşik kümeleme sürecinde, her bir veri noktası başlangıçta kendi başına bir küme olarak kabul edilir. Kümeleme işlemi sırasında, benzer özelliklere sahip veya en yakın mesafede olan kümeler birleştirilir. Bu süreç, tüm veriler tek bir küme altında toplanıncaya kadar devam eder. Her birleştirme aşamasında, küme ağacı (dendrogram) üzerinde birleşme noktaları ve mesafeler kaydedilir, bu da verilerin yapısal ilişkilerini görselleştirmeyi sağlar (Yücesahin, 2011: 159-188). Hiyerarşik kümeleme, özellikle veriler arasındaki doğal hiyerarşileri keşfetmek ve detaylı bir veri analizi yapmak için kullanılır. Bu yöntem, pazar araştırması, genetik araştırmalar, ekolojik analizler ve tüketici davranış analizleri gibi birçok alanda tercih edilir. Ayrıca, kullanıcıların veri setlerinin alt yapısını anlamalarına ve daha bilinçli analiz kararları almalarına olanak tanımaktadır (Dalgın, 2023: 11-15).

2.5.1.2.1.3. Olasılıksal Kümeleme

Olasılıksal kümeleme, veri noktalarının belirli kümeler içinde yer alma olasılıklarını hesaplayarak çalışan bir kümeleme yöntemidir. Bu yöntem, özellikle Gaussian karışım modelleri (GMM - Gaussian Mixture Models) kullanılarak uygulanır. Bu modelde, veri seti birden fazla Gaussian dağılımının bir karışımı olarak kabul edilir ve her bir veri noktasının bu dağılımlardan hangisine ait olduğu olasılıklar üzerinden değerlendirilir (İyigün, 2013: 2-3). Olasılıksal kümeleme, her veri noktasına bir veya birden fazla kümeye ait olma olasılığı atar. Bu yaklaşım, her bir veri noktasının kümeler arasında kesin bir şekilde ayrılmadığı, bunun yerine her bir küme için bir üyelik derecesine sahip olduğu anlamına gelir. Bu, verilerin üzerinde bulanık bir yapıya izin verir ve her bir veri noktasının birden fazla küme ile ilişkilendirilebilmesine olanak tanımaktadır (Dalgın, 2023: 11-15). Bu yöntem, özellikle veriler arasındaki ilişkilerin belirsiz veya karmaşık olduğu durumlar için idealdir. Veri noktalarının hangi kümeye ait olabileceğine dair net bir sınırın olmadığı, kümelerin birbiri üzerine bindiği senaryolarda, olasılıksal kümeleme daha gerçekçi ve esnek sonuçlar sunabilir. Bu esneklik, modelin gerçek dünya verilerinin karmaşıklığını ve belirsizliğini daha iyi yansıtmasını sağlamaktadır (Yılancı, 2020: 453-470). Olasılıksal kümeleme yöntemi, finansal piyasaların analizi, biyoinformatik, görüntü işleme ve sosyal bilimler gibi çeşitli alanlarda kullanılır. Bu yöntem sayesinde, araştırmacılar ve analistler, veri setlerini daha kapsamlı bir şekilde inceleyebilir ve veriler arasındaki ilişkileri daha detaylı bir şekilde çözümleyebilir (Dalgın, 2023: 11-15).

2.5.1.3 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir ajanın belirli faydalı ve zararlı eylemleri ayırt etmesi gereken bir ortamda, net hedeflerle yönlendirildiği bir öğrenme biçimidir. Bu süreçte, ajan belirlenen hedeflere ulaşmak için ödül ve ceza mekanizmaları aracılığıyla yönlendirilir. Bu yöntem, denetimli öğrenmeye benzer şekilde net hedefler kullanır; ancak, pekiştirmeli öğrenme algoritmaları bir kez belirlendikten sonra büyük ölçüde bağımsız çalışır ve sürekli kendini iyileştirir. Bu bağlamda, pekiştirmeli öğrenme bazen yarı gözetimli öğrenme olarak anılsa da genellikle kendi başına bir makine öğrenmesi türü olarak kabul edilir (Bölük vd., 2019: 40-44). Pekiştirmeli öğrenme, belirli bir amaca hizmet eden eylemleri öğrenme sürecidir. Öğrenme ilerledikçe, ajan ödül sinyalleri alır ve bu sinyallerle öğrenme stratejisini maksimize ederek daha fazla ödül elde etmeye çalışır. Bu süreç, deneme yanılma metodu ile karakterize edilir ve pekiştirmeli

öğrenmenin en belirgin özelliği olarak kabul edilir (Waslander vd., 2005: 3712-3717). Pekiştirmeli öğrenme sürecinde genellikle Markov karar süreçleri kullanılır. Bu modelin temel özellikleri algılama, eylem ve hedef kavramları üzerine kuruludur (Sutton ve Barto, 1998: 223-260). Pekiştirmeli öğrenme, doğal canlıların içgüdülerinden ilham alır; genç canlılar, yaşamın erken evrelerinde, herhangi bir dış eğitim yardımı olmaksızın yürüme, koşma, tutma gibi karmaşık davranışları öğrenebilir ve bu becerileri gerektiğinde hızla uygulayabilir (Sutton ve Barto, 1998: 223-260). Bu öğrenme şekli, makine öğrenmesi alanında ajanların çevrelerine uyum sağlaması ve optimum kararlar alması için güçlü bir araç sunar (Ospanov ve Demirci, 2023: 1724-1735).


2.6. Derin Öğrenme

Derin öğrenme, insan beyninin işlevlerini taklit etmeyi amaçlayan bir teknolojidir. Bu sistemler, veri girişlerini, ağırlıklar ve yanlılık gibi parametreler aracılığıyla işleyerek, veri gruplarındaki nesneleri tanımlama, teşhis etme ve kategorize etme gibi işlevleri yerine getirir. Derin öğrenme, verileri işlemek ve belirli görevleri yerine getirmek amacıyla bir dizi katmandan oluşan yapılardır; her katman bir öncekine bağlıdır ve ileri yayılım adı verilen bir süreçle veri işlemeyi sürdürür (İnik ve Ülker, 2017: 85-104). Bu sürecin özü, derin sinir ağlarının, her bir katmanın bir önceki katmanın çıktılarını girdi olarak kullanarak daha karmaşık işlemleri gerçekleştirebilmesidir. Giriş katmanı, verilerin model tarafından ilk alındığı yerdir ve çıktı katmanı, modelin sonuçlarını sunduğu yerdir. Bu katmanlar arasındaki her adım, verilerin daha anlamlı ve işlevsel bir forma dönüştürülmesine yardımcı olmaktadır (Şeker vd., 2017: 47-64). Geleneksel makine öğrenimi yöntemlerinden daha karmaşık yapılar kullanan derin öğrenme, özellikle büyük veri setleri ve karmaşık modelleme ihtiyaçları için idealdir. İlk dönemlerde sinir ağlarının kullanımı sınırlı bilgi işlem gücü nedeniyle kısıtlıyken, günümüzde yapılan teknolojik ilerlemeler, bilgisayarların daha hızlı ve etkili öğrenmesine olanak tanımıştır. Bu ilerlemeler sayesinde, derin öğrenme algoritmaları artık görüntü sınıflandırma, dil çevirisi ve konuşma tanıma gibi çeşitli alanlarda etkili bir şekilde kullanılabilmektedir (Doğan ve Türkoğlu, 2019: 409-445). Derin öğrenme algoritmaları, karmaşık veri setlerinden öğrenme yeteneği sayesinde, otonom araçlardan sağlık teşhis sistemlerine kadar geniş bir uygulama alanına sahiptir. Bu algoritmalar, öğrendikleri bilgileri yeni ve öğrenilmemiş verileri tanıyıp anlamlandırmak için kullanır. Ayrıca, bu sistemler karmaşık kavramları basit öğeler aracılığıyla analiz ederek

anlamlandırmaya yardımcı olur ve bu sayede derin öğrenme, bilgisayarların karmaşık durumları daha hızlı ve doğru bir şekilde işlemlerini sağlar (Murat, 2021: 12-15).


2.7. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin sinir sistemi ve düşünce yapısının matematiksel modellenmesi olarak tasarlanmıştır. İnsan beyindeki gibi, yapay sinir ağları da "nöron" adı verilen temel işlem birimlerinden oluşur. Bu yapay nöronlar, gerçek biyolojik nöronların işlevselliğini taklit ederler (Zeren, 2023: 52-60). Bir biyolojik nöron, dentritler aracılığıyla bilgi alır; bu, giriş alanı olarak kabul edilir. Alınan bilgi, hücre çekirdeğinde işlenir ve sonrasında bir sonraki nörona iletilip ileilmeyeceğine karar verilir. Bu karar süreci, akson uçları aracılığıyla diğer nöron hücrelerine bilgi aktarımı ile sonuçlanır (Zhang vd., 2018: 51-53). Yapay sinir ağlarındaki her bir yapay nöron da benzer bir süreç izler. Nöronlar, girişler (özellikler) alır ve bu girişler ağırlıklarla çarpılarak toplanır. Toplam, bir eşik değeri veya aktivasyon fonksiyonu ile değerlendirilir ve çıktı olarak bir sonraki katmandaki nöronlara iletilir. Bu işlem, ağıncı çıktı katmanına ulaşana kadar devam eder (Keskenler ve Keskenler, 2017: 8-18). Yapay sinir ağlarının bu modellenmesi, bilgiyi işleme ve karar verme süreçlerinde biyolojik nöronların karmaşıklığını ve etkinliğini taklit etmeyi amaçlar. Bu sistemler, öğrenme yeteneği sayesinde karmaşık desenleri tanıma, veri sınıflandırma, regresyon analizi ve hatta görüntü ve ses işleme gibi pek çok farklı alanda başarıyla kullanılmaktadır. Yapay sinir ağlarının bu özellikleri, onları modern yapay zekâ uygulamalarında vazgeçilmez kılmaktadır (Zeren, 2023: 52-60). Şekil 2.4'te insan vücudunda yer alan nöron hücresi görselli görülmektedir.




Şekil 2.4. İnsan Vücudunda Yer Alan Nöron Hücresi (Zhang vd., 2018: 51).

Yapay sinir ağlarında, biyolojik nöronların işlevselliği matematiksel bir model ile taklit edilir. Çevresel uyarıcılardan alınan girdiler x_i olarak temsil edilir ve her bir girdi, belirlenen ağırlıklar w_i ile çarpılarak ağırlıklandırılır. Bu ağırlıklı girdiler toplandıktan sonra, bir sapma ya da yanılma değeri olan b_i eklenir. Bu işlem, yapay nöronun çıktısını üretmek için gerekli olan toplam girdi sinyalini hesaplamak amacıyla gerçekleştirilir (Keskenler ve Keskenler, 2017: 8-18). Şekil 2.5'te algılayıcıların şematik gösterimi görülmektedir



Şekil 2.5. Algılayıcıların Şematik Gösterimi (Shanmugamani, 2018: 32).

Bir algılayıcı, temelde sınırlı ve basit işlevler gerçekleştirebilir; bu işlevler, gelen sinyaller üzerinden belirli ağırlıkların uygulanması ve bu ağırlıkların korunması ile ilişkilidir. Algılayıcının aldığı bu ağırlıkların belirlenmesi ve güncellenmesi süreci, eğitim olarak adlandırılır. Algılayıcının elde ettiği ağırlıklandırılmış toplam değer, bir birim adım fonksiyonu aracılığıyla işlenerek çıktı üretilir (Zeren, 2023: 52-60). Yapay sinir ağları ise, birden fazla algılayıcı nöronun bir araya gelmesiyle ve ardından birbirine bağlı çoklu katmanların eklenmesiyle oluşturulur. Bu yapılarda, her bir nöron bir önceki katmandan gelen bilgiyi işler ve sonraki katmana aktarır, böylece daha karmaşık ve sofistike işlemler gerçekleştirilebilir. Bu çok katmanlı yapı, ağırlıklı girdileri öğrenme ve modelleme yeteneğini önemli ölçüde artırır (Keskenler ve Keskenler, 2017: 8-18). Şekil 2.6'da tek ve çok katmanlı sinir ağları modelleri görülmektedir.




Şekil 2.6. Tek ve Çok Katmanlı Sinir Ağları Modelleri (Nielsen, 2015).

Tek katmanlı ve çok katmanlı sinir ağlarında, her bir katmanın çıktı üzerinde doğrudan bir etkisi bulunmaktadır. Bu yapılarda, her nöron, girdileri alır ve işledikten sonra sonuçları bir sonraki katmana veya çıktı katmanına aktarır. Tek katmanlı ağlarda, nöronlar doğrudan girdileri işleyerek son çıktıyı üretirken, çok katmanlı ağlarda, ara katmanlar (gizli katmanlar) işleme sürecine katılarak daha derin ve karmaşık öğrenme yapıları oluşturur. Her bir nöronun katman içerisindeki rolü hem doğrudan hem de dolaylı yollarla sonuçları etkileyebilir. Bir nöronun çıktısı, bir sonraki katmandaki nöronların girdisi olarak işlev görür, bu da ağın genel performansı ve öğrenme kapasitesi üzerinde zincirleme bir etki yaratır. Bu nedenle, her bir nöron ve katman, ağın genel davranışını ve öğrenme başarısını belirlemede kritik bir rol oynar (Zeren, 2023: 52-60).

2.7.1. Tek Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar, yapay sinir ağlarının en basit formudur ve temelde üç ana bölümden oluşur: giriş, işlem ve çıktı katmanları. Giriş katmanında, tanımlanan değerler önceden belirlenmiş ağırlıklar ile çarpılır. Bu işlem sonucunda elde edilen toplam değer, sonraki aşama olan çıktı katmanına aktarılır (Öğücü 2006: 33-39). Bu tür sinir ağlarında, girdi değerleri (öznitelikler), ilgili ağırlıklarla çarpılır ve elde edilen bu değerler ek bir yanlılık (bias) değeri ile toplanır. Elde edilen bu toplam, bir aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu, genellikle bir çıktıyı 0 veya 1 olarak sınıflandırmak için kullanılır, bu da modelin karar verme sürecine benzer. Aktivasyon sonucunda elde edilen bu değerler, modelin tahmin veya sınıflandırma yapmasını sağlamaktadır (Öztürk ve Şahin, 2018: 25-36). Tek katmanlı algılayıcılar, giriş

değerlerinin boyutu veya işaretine (pozitif veya negatif) bağlı olmaksızın işlem yapabilir. Bu esneklik, modelin çeşitli veri tipleriyle çalışabilmesine olanak tanır. Ancak, modelin çıktıları genellikle aktivasyon fonksiyonu nedeniyle sınırlıdır; bu da çıktı değerlerinin genellikle 0 veya 1 ile sınırlandırıldığı anlamına gelmektedir (Öğücü 2006: 33-39). Bu basit yapı, yapay sinir ağlarının karmaşık problemleri çözmede kullanılmasının temelini oluşturur ve derin öğrenme modellerinin çok katmanlı yapılara evrilmesine zemin hazırlar. Tek katmanlı algılayıcılar, giriş verilerini doğrudan işleyerek basit tahminlerde bulunabilir, ancak daha karmaşık veri yapıları ve öğrenme görevleri için genellikle yetersiz kalmaktadır (Öztürk ve Şahin, 2018: 25-36). Şekil 2.7’de tek katmanlı yapay sinir ağı yapısı görülmektedir.




Şekil 2.7. Tek Katmanlı Yapay Sinir Ağı Yapısı (Anonim, 2020).

Şekil 2.7, yapay sinir ağlarındaki temel bir yapı taşı olan nöronun (veya perceptronun) matematiksel işleyişini göstermektedir. Girişler (inputs), modelin aldığı ham verileri temsil eder ve her biri farklı bir ağırlık (weight) değeriyle çarpılarak modelin öğrenme sürecinde optimize edilen parametreler olarak sonuca etkiye bulunur. Bu giriş ve ağırlıkların çarpımları toplanarak (summation) bir toplam değeri elde edilir, bu da nöronun aldığı uyarıyı hesaplamaktadır. Elde edilen bu toplam değere aktivasyon fonksiyonu uygulanır, böylece modelin karmaşık ilişkileri öğrenmesi sağlanır. Aktivasyon fonksiyonu olarak sigmoid, ReLU veya tanh gibi dönüşümler kullanılabilir, bu dönüşümler nöronun çıkışını (output) belirler, yani verilen girdilere göre hangi tahmini veya kararı üreteceğini belirleyen nihai değeri oluşturur. Bu yapı, yapay sinir ağlarının temel çalışma prensibini oluşturarak giriş verilerinin işlenmesini, karar mekanizmasını ve tahmin sürecini tanımlar. Bir sinir ağı, bu nöronların çok sayıda birleşmesiyle oluşur ve

daha karmaşık öğrenme süreçlerine olanak tanır. Özetle, bu görsel, makine öğrenmesi ve derin öğrenme modellerinde kullanılan temel matematiksel işlem mekanizmasını, ağırlıklar ve girişler arasındaki ilişkiyi ve modelin öğrenme kapasitesinin temelini açıklayan bir diyagramdır.

2.7.2. Çok Katmanlı Algılayıcılar

Çok katmanlı algılayıcılar, tek katmanlı algılayıcılardan türetilmiş daha gelişmiş yapay sinir ağlarıdır. Bu gelişmiş yapılar, karmaşık problemlerin çözülmesini sağlamak için tek katmanlı algılayıcılara ek olarak bir veya daha fazla gizli katman içerir. Tek katmanlı algılayıcılarda olduğu gibi, çok katmanlı algılayıcılarda da her bir nöron, girdi değerlerini alır ve bu değerleri belirli ağırlıklarla çarparak toplam bir değer hesaplar. Ancak, çok katmanlı yapıda bu işlem, birçok katmanda tekrarlanır (Oral ve Oğuz, 2020: 464-478). Her gizli katmandaki nöronlar, önceki katmandan gelen toplam girdiyi alır, bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana aktarır. Bu süreç, ağın çıktığı katmanına ulaşmaya kadar devam eder. Gizli katmanlar, ağın daha karmaşık özellikleri modellemesine ve daha derin öğrenme işlemleri gerçekleştirmesine olanak tanır. Gizli katmanların eklenmesi, ağın farklı düzeylerde soyutlamalar yapabilmesini ve böylece daha zorlu veri kümeleri üzerinde etkili bir şekilde çalışabilmesini sağlamaktadır (Moralı ve Aygün, 2007: 57-62). Çok katmanlı algılayıcıların bu detaylı yapılandırılması, onların tek katmanlı algılayıcılara kıyasla daha esnek ve güçlü olmalarını sağlar. Bu sayede, görüntü ve ses işleme, doğal dil işleme ve diğer karmaşık yapay zekâ görevleri gibi alanlarda başarıyla kullanılabilirler. Bu yapılar, ayrıca genellikle derin öğrenme teknikleri olarak adlandırılan, öğrenme süreçlerinde derinlemesine özellik çıkarımı yapma kabiliyetine sahiptir. Bu sürecin şematik gösterimi, çok katmanlı bir yapay sinir ağı modelini açıkça sergileyebilir (Kabalcı, 2014). Çok katmanlı yapay sinir ağı yapısı Şekil 2.8’de gösterilmiştir.



Şekil 2.8. Çok Katmanlı Yapay Sinir Ağı Yapısı (İslamoğlu, 2015: 178-193).

Bu görsel, yapay sinir ağlarının çok katmanlı yapısını net bir şekilde göstermektedir. Çoklu gizli katmanlar, modelin daha karmaşık ilişkileri öğrenmesini sağlar. Bu yapı, derin öğrenmenin temel taşını oluşturur. Örneğin, derin öğrenme modellerindeki “derinlik” kavramı, gizli katmanların sayısına atıfta bulunur. Çok katmanlı ağların bu yapısı, onları ses ve görüntü tanıma, doğal dil işleme ve diğer pek çok ileri düzey yapay zekâ uygulamasında etkili kılar. Çok katmanlı ağlar, tek katmanlı ağlara göre çok daha zengin öğrenme ve modelleme kapasitesine sahip olup, daha sofistike tahminler ve sınıflandırmalar yapabilirler (Bulut, 2016: 97-109).

2.7.3. İleri Yönde Dağılım

Yapay sinir ağlarında ileri yönde yayılım (forward propagation), ağ mimarisinde giriş verilerinin kullanılarak soldan sağa doğru hesaplama işlemlerinin gerçekleştirilmesi sürecidir. Bu işlem, her bir nöronun aldığı girdi değerlerini, belirlenen ağırlık ve bias değerleriyle birlikte değerlendirerek bir tahmin üretmesine olanak tanır. Bu süreç, biyolojik sinir sistemlerindeki nöronların işleyişine benzer bir mantıkla çalışmaktadır. Yapay sinir ağlarında, bias değerleri özellikle nöronların aktivasyon fonksiyonlarını etkileyerek istenmeyen sıfır değerlerinin oluşmasını önlemeye yardımcı olur. Bu sayısal değerler, nöronun aktivasyon eşiğini ayarlayarak sinyalin sıfır olmasını engeller ve modelin daha etkili öğrenmesine katkıda bulunur (Jibril vd., 2022: 60-67).

Bilgisayar bilimlerinde, görüntülerin bilgisayar tarafından işlenmesi için her sembolün veya resmin sayısal karşılıkları hesaplanır. Örneğin, bilgisayarlı görü

işlemlerinde, her bir girdi fotoğrafının gri veya renkli piksel değerleri matematiksel olarak ifade edilir. Bu piksel değerleri ister random olarak ister başka bir derin öğrenme modelinden aktarılan ağırlıklar olsun, ileri yönde yayılım sürecinde hesaplama tabi tutulur. İleri yönde yayılım süreci, elde edilen değerlerin bir sonraki katmana aktarılması prensibi üzerine kuruludur. Bu değerler, aktivasyon fonksiyonları aracılığıyla işlendikten sonra bir sonraki katmana aktarılır. Aktivasyon fonksiyonlarının temel amacı, modelin doğrusallığını kırmaktır. Gerçek dünyadaki sınıflandırmalar genellikle doğrusal olmadığı için, aktivasyon fonksiyonları yapay sinir ağlarının daha gerçekçi sonuçlar üretmesine yardımcı olur. Negatif piksel değerleri gibi istenmeyen değerler eğer oluşursa, bu değerler genellikle önemsiz kabul edilerek sıfıra eşitlenir. Bu işlemler, modelin her katmanı boyunca tekrarlanır ve bu şekilde ileri yönde yayılım tamamlanır (Gurney, 1997). Bu süreç, yapay sinir ağlarının karmaşık veri kümelerini modellemesine ve gerçek dünya verileriyle çalışmasına olanak tanımaktadır

2.7.4. Maliyet Fonksiyonunun Hesaplanması

Çok katmanlı yapay sinir ağlarında, ileri yayılım süreci, girdi katmanından başlayarak her bir katmanın işlenmesiyle devam eder. Bu süreçte, her bir girdi, önceden tanımlanmış ağırlık değerleriyle çarpılır ve ardından bir toplam hesaplanır. Bu hesaplanan değerler, aktivasyon fonksiyonları aracılığıyla işlenerek bir sonraki katmana aktarılır. Bu işlem, nihai çıktı katmanına ulaşana kadar katmanlar arası tekrar edilir. Son katmanda elde edilen değerler, modelin tahminleridir ve bu tahminlerin gerçek değerlerle olan uyumluluğu değerlendirilir (Golik vd., 2013: 46-48).


Modelin performansını ölçen maliyet fonksiyonu, tahmin edilen değerler ile gerçek değerler arasındaki farkı nicel olarak ifade eder. Bu süreç, modelin gerçeğe yakın tahminler üretip üretmediğini belirlemek için kritiktir. İleri yayılım süreci sırasında elde edilen tahminlerin doğruluğu, kayıp fonksiyonları kullanılarak değerlendirilir ve bu değerlendirme, modelin nasıl iyileştirileceği konusunda bilgiler sağlanmaktadır (Kızılboğa, 2021: 77). Örneğin, çok katmanlı bir yapay sinir ağı modeli, girdileri alır ve her katmanda ağırlıklar ve bias değerleri ile işleyerek çıktıları üretir. Bu çıktılar, maliyet fonksiyonu ile değerlendirilir ve elde edilen kayıp değerleri, modelin ne kadar iyi performans gösterdiğini gösterir. Optimizasyon sürecinde, bu kayıp değerleri minimize etmek için ağırlıklar iteratif olarak güncellenir. Her iterasyonda, modelin hata miktarı azaltılmaya çalışılır ve bu, ağırlıkların sürekli olarak ayarlanmasıyla sağlanır (Murat, 2021: 12-14). Bu tür bir maliyet hesaplaması, ortalama mutlak hata veya ortalama kare

hata gibi farklı yöntemlerle yapılabilir. Bu yöntemler, tahminlerin ne kadar doğru olduğunu belirlemeye yardımcı olur ve modelin daha iyi sonuçlar vermesi için gereken düzenlemelerin yapılmasına olanak tanır. Dereceli alçalma yöntemi, bu süreçte ağırlık ve bias değerlerinin optimum düzeyde ayarlanmasını sağlayarak maliyet fonksiyonunun minimum değerlere ulaşmasına yardımcı olur ve bu, modelin en iyi performansını sergilemesine imkân vermektedir (Kızılboga, 2021. 77).

2.7.5. Geri Yönde Yayılım ve Hesaplama Aşamaları

İleri yayılım ve geri beslemeli yayılım, yapay sinir ağlarının eğitim sürecinin temel bileşenleridir. İleri yayılım sürecinde, girdi verileri ağın katmanları boyunca ilerletilir ve her katmandaki nöronlar, bir önceki katmandan gelen girdileri işleyerek sonuçları bir sonraki katmana iletir. Bu süreç, çıktı katmanına kadar devam eder ve nihai tahminler üretilir (Kuşkapan vd., 2022: 72-84).

Geri beslemeli yayılım süreci ise, modelin çıktılarının gerçek değerlerle olan farkına dayanarak ağın ağırlıklarını güncellemek için kullanılır. Bu süreç, modelin hata oranlarını düşürmek ve tahmin doğruluğunu artırmak amacıyla gerçekleştirilen ince ayarlar içerir. Eğitim sürecinde elde edilen tahminler ile gerçek değerler arasındaki fark, bir kayıp fonksiyonu aracılığıyla hesaplanır. Bu kayıp, modelin ne kadar iyi performans gösterdiğini ölçen bir göstergedir (Han vd., 2023: 33-34). Geri beslemeli yayılım, hesaplanan kaybı kullanarak, modelin ağırlıklarını ve biaslarını, hata miktarını minimize edecek şekilde ayarlamak için kullanılır. Ağırlıkların doğru bir şekilde ayarlanması, modelin daha güvenilir olmasını sağlar ve daha düşük hata oranları ile daha iyi tahminler yapmasına olanak tanır. Bu süreç, genellikle dereceli alçalma veya benzeri optimizasyon algoritmaları kullanılarak yapılır ve modelin performansını sürekli olarak iyileştirir (Al-Masri, 2015: 11). Geri yayılımın çalışma mekanizmasının akış diyagramı şekil 2.9'da gösterilmiştir.



Şekil 2.9. Geri Yayılımın Çalışma Mekanizmasının Akış Diyagramı

Geri yayılım süreci, yapay sinir ağlarında hata oranını azaltarak modelin doğruluğunu artırmak için kullanılır. Bu süreç aşağıdaki adımları içerir (Aladağ, 2009: 66-68):

- **Hata Oranını Bulma:** Modelin tahmin ettiği çıktılar gerçek değerlerle karşılaştırılarak hata oranı hesaplanır. Bu, modelin ne kadar iyi performans gösterdiğini anlamak için kritik bir adımdır.
- **Minimum Hata Kontrolü:** Elde edilen hata oranı, belirlenen kabul edilebilir aralığın içinde olup olmadığı çapraz doğrulama yöntemiyle kontrol edilir. Eğer hata minimum değilse, aşağıdaki adımlar takip edilir.
- **Ağırlıkları Güncelleme:** Hata kabul edilebilir sınırların üzerindeyse, modelin ağırlıkları ve bias değerleri güncellenir. Bu güncellemeler, hata oranını azaltacak şekilde yapılır. Güncelleme sonrası hata tekrar kontrol edilir ve hata azalana kadar bu süreç tekrarlanır.
- **Sinir Ağı Modelinin Hazırlanması:** Hata oranı kabul edilebilir bir seviyeye ulaştığında, sinir ağı modeli tahminlerde bulunmak üzere kullanıma hazır hale gelir.

Geri yayılım, maliyet fonksiyonunun hesaplanmasında ve modelin optimize edilmesinde kritik bir rol oynar. Bu süreç, genellikle gradient descent gibi bir optimizasyon algoritması kullanılarak gerçekleştirilir.

Algoritmanın Dezavantajları:

- Yerel Minimum Sorunu: Gradient descent tabanlı algoritmalar yerel minimumlarda takılıp kalabilir ve global minimuma ulaşamayabilir. Bu, modelin potansiyel olarak daha iyi sonuçlar üretebileceği durumlarda sınırlı kalmasına neden olur.
- Başlangıç Değerlerinin Etkisi: Algoritmanın başlangıç parametreleri ve ağırlık değerleri, eğitim performansını ve sonuçların kalitesini önemli ölçüde etkileyebilir. Uygun olmayan başlangıç değerleri, algoritmanın verimli çalışmasını engelleyebilir.

Bu zayıflıkları gidermek için yapılan çalışmalar, özellikle yerel tuzaklardan kaçınmak amacıyla sezgisel algoritmalarla yararlanmayı önermektedir. Bu tür geliştirmeler, modelin daha etkin bir şekilde eğitilmesini ve daha yüksek doğrulukta tahminler yapabilmesini sağlamaktadır (Aladağ, 2009: 66-68).

2.7.6. Hiperparametreler

Yapay sinir ağları ve diğer makine öğrenimi algoritmaları gibi gradient boosting, rastgele ormanlar gibi modeller, başarılı çalışmalar için çeşitli hiperparametrelere ihtiyaç duyar. Bu hiperparametreler, model parametrelerinden farklı olarak, model eğitimi sırasında otomatik olarak belirlenmez; bunun yerine, eğitimden önce kullanıcı tarafından dikkatlice ayarlanmalıdır. Bu ayarlar, modelin maksimum verimlilikte çalışabilmesi için optimize edilir (Eiben ve Smit, 2011: 49-54). Etkili bir hiperparametre ayarlama stratejisi seçmek, belirlenen hiperparametrelerin kapsamı ve bu parametreler için uygun aralıkların, ölçeklerin ve olası önceki dağılımların tanımlanması gerektiği anlamına gelir. Kullanıcılar bu parametreleri ayarlarken, bazı hiperparametrelerin farklı senaryolarda tutarlı performans gösterdiği gözlemlenirse, bu parametreler için varsayılan değerler güvenle kullanılabilir. Yanlış hiperparametre ayarları, modelin genel performansını olumsuz etkileyebilir ve hatta modelin verimliliğini düşürebilir. Bu nedenle, hiperparametre ayarlaması, yapay sinir ağlarının ve diğer ilgili makine öğrenimi modellerinin başarısında kritik bir rol oynamaktadır.

2.7.7. Filtre Boyutu

Evrişimli sinir ağlarında kullanılan filtre boyutları, modelin performansını ve hesaplama maliyetini doğrudan etkiler. Genel olarak, 3×3 , 5×5 ve 7×7 boyutlarında filtreler kullanılmaktadır. Bu farklı boyutlardaki filtreler, katmanlardaki evrişim

işlemlerini gerçekleştirirken farklı miktarda hesaplama kaynağı tüketir (Bozkurt ve Yağanoğlu, 2021: 1-8). Küçük filtre boyutları, örneğin 3×3 , genellikle daha hızlı işlem yapma avantajına sahiptir çünkü daha az parametre içerir. Bu boyuttaki filtreler, genelde hesaplama açısından daha verimli olup, büyük filtre boyutlarına göre daha az işlem gerektirir. Özellikle derin öğrenme modellerinde, 3×3 boyutundaki filtreler sıklıkla tercih edilir çünkü azaltılmış parametre sayısı ile hızlı ve etkili bir şekilde özellik çıkarma imkânı sunmaktadır (Elmas, 2021: 74-88). Öte yandan, 5×5 ve 7×7 gibi daha büyük filtre boyutları, daha geniş bir alandan bilgi toplayabilir, bu da modelin daha karmaşık özellikleri algılamasına yardımcı olabilir. Ancak bu avantaj, artan hesaplama maliyetiyle dengelenmelidir. Büyük filtreler, daha fazla parametreye sahip oldukları için daha yüksek hesaplama gücü gerektirir ve bu da modelin eğitim süresini uzatabilir. Ayrıca, büyük filtrelerin daha fazla alan kaplaması, daha yüksek doldurma (padding) ihtiyacına yol açabilir, bu da ekstra hesaplama kaynaklarının kullanılmasına sebep olur (Bozkurt ve Yağanoğlu, 2021: 1-8).

2.7.8. Dolgulama ve Adım Kayırma

Evrişimli sinir ağları içerisinde dolgulama (padding) ve adım kaydırma (stride) gibi terimler, evrişim işlemi sırasında kullanılan önemli parametrelerdir. Bu parametreler, evrişim katmanlarının nasıl çalıştığını ve girdi verilerinin nasıl işlendiğini belirler (Onan, 2020: 374-380). Dolgulama, evrişim işlemi sırasında girdi matrisinin etrafına ekstra sıfırlar (veya başka bir değer) eklenmesi işlemidir. Bu işlem, girdi matrisinin boyutunu korumak ve filtre tarafından taranan özelliklerin kenar bölgelerinde de tam olarak algılanabilmesi için yapılır. Dolgulama olmadan, evrişim işlemi her adımda girdi matrisinin boyutunu küçültecektir, bu da özellikle derin ağlarda problem yaratabilir çünkü bilgi kaybına neden olmaktadır (Şahin ve Harman, 2024: 37-51).

Adım kaydırma, filtre veya çekirdeğin girdi üzerinde her bir evrişim işlemi arasında kaydırılacak adım sayısını belirtir. Yani, filtre her seferinde birden fazla piksel kaydırılarak uygulanır. Stride genellikle yatay (genişlik) ve dikey (yükseklik) olarak belirlenir ve her iki yönde de uygulanabilir.

2.7.9. Havuzlama Katmanı Uygulama

Havuzlama katmanı (pooling layer), evrişimli sinir ağlarının yapısal bileşenlerinden biridir ve genellikle evrişim katmanlarından sonra yer alır. Havuzlama katmanının temel amacı, gelen öznitelik haritasının (feature map) boyutunu azaltmak ve

böylece parametre sayısını ve hesaplama yükünü düşürmektir. Bu işlem, aynı zamanda modelin aşırı uyuma (overfitting) karşı direncini artırır ve girdi içindeki küçük değişikliklere karşı duyarlılığını azaltarak modelin genelleştirme kabiliyetini güçlendirir (Elmas, 2021: 74-88). Havuzlama işlemi, genellikle iki popüler yöntemle gerçekleştirilir:

- **Maksimum Havuzlama (Max Pooling):** Bu yöntem, öznetelik haritasının belirli bir pencere boyutu içindeki maksimum değeri alır. Örneğin, 2x2'lik bir pencere kullanıldığında, her penceredeki dört değerden en büyük olanı sonraki katmana aktarılır. Bu yaklaşım, özellik haritasındaki en belirgin özneteliklerin korunmasını sağlar ve çoğunlukla görsel tanıma görevlerinde tercih edilir.
- **Ortalama Havuzlama (Average Pooling):** Bu yöntemde, pencere içindeki değerlerin ortalaması alınır ve bu ortalama değer sonraki katmana iletilir. Ortalama havuzlama, öznetelik haritasındaki genel yapıyı daha yumuşak bir şekilde temsil etmeye yardımcı olur ve gürültülü veriler üzerinde daha stabil sonuçlar üretebilir.

Havuzlama katmanının uygulanması, modelin eğitim sürecinde ve sonrasında çeşitli avantajlar sağlar. Özellikle, modelin hesaplama maliyetini azaltarak daha hızlı eğitim süreçlerine olanak tanır. Ayrıca, havuzlama katmanı, modelin farklı dönüşümlere ve ölçeklere karşı daha dayanıklı hale gelmesine katkıda bulunur. Bu, modelin farklı boyut ve perspektiflerdeki verilere karşı duyarlılığını azaltarak daha robust (sağlam) bir yapı kazanmasını sağlar (Onan, 2020: 374-380). Havuzlama katmanı, evrişimli sinir ağlarının performansını ve verimliliğini artırmada kritik bir role sahiptir. Bu katman, ağı daha hızlı çalışmasını ve geniş veri setleri üzerinde daha etkili öğrenme gerçekleştirmesini mümkün kılmaktadır

2.8. Cam Kusurları ve Kusur Tespit Süreçleri

2.8.1. Cam Üretim Süreci ve Kalite Kontrol

Cam, ASTM (American Society for Testing Materials) tarafından kristallenme olmaksızın rijit koşullarda soğutulmuş inorganik bir ergime ürünü olarak tanımlanmaktadır (Günay ve Yılmaz, 2010). Bu tanım, camın amorf yapısının ve kristal bir yapıya sahip olmadığının altını çizmektedir. Cam, seramiklerde sır ve metallerde emaye olarak bilinen yüzey kaplama malzemelerinin de temel bileşeni olarak kullanılmaktadır (Kılıç, 1995: 3). Camın fiziksel özellikleri arasında ışığı kırma, yansıtma ve emme kabiliyetleri öne çıkmaktadır. Bu özellikler, camın sanat ve tasarım alanlarında

geniş bir kullanım alanı bulmasını sağlamaktadır. Ayrıca, cam, oda sıcaklığında aşırı soğumuş bir sıvı olarak nitelendirilmekte ve yeterli ısı verildiğinde sıvılardan farklı olarak akmaya karşı direnç göstermektedir (Keser, 2010: 33-36). Isıtıldığında, camın davranışı ısı iletken kristal malzemelerinkinden farklı olarak, belli ısı noktalarında değil, belirli ısı aralıklarında yavaş yavaş değişmektedir. Bu ısı aralıkları, camın sıcakkan şekillendirilmesine olanak tanımaktadır. Bu özellikler, camı teknik uygulamalarda ve sanatsal faaliyetlerde tercih edilen bir malzeme haline getirmektedir (Akdemir ve Öztürk: 170-173). Cam üretim süreci, hammadde seçimi ve hazırlanmasından başlayarak, eritme, şekillendirme, soğutma ve son işlem adımlarını içerir. Bu süreçlerin her biri, nihai ürünün kalitesini doğrudan etkiler ve bu nedenle titiz bir kalite kontrol mekanizması gerektirir. Cam üretim süreci şu şekildedir (Liang vd., 2019: 131-132; Bükücü ve Öztürk, 2020: 510-519);

Hammadde Seçimi ve Hazırlanması: Cam üretiminde kullanılan temel hammaddeler arasında silika kumu, soda külü ve kireçtaşı bulunur. Bu malzemelerin saflığı ve tane boyutu, camın optik ve mekanik özelliklerini belirler. Bu nedenle, her hammadde için kimyasal bileşim ve tane boyutu gibi kritik parametreler tanımlanmalı ve tedarikçilerden alınan malzemeler bu spesifikasyonlara uygunluk açısından düzenli olarak denetlenmelidir.

Eritme ve Şekillendirme: Hazırlanan hammadde karışımı, yüksek sıcaklıklarda eritilerek homojen bir cam kütlesi elde edilir. Eritme sürecinde sıcaklık kontrolü ve karışımın homojenliği, camın kalitesini doğrudan etkiler. Eritilen cam, istenilen ürün tipine göre şekillendirilir; örneğin, düz cam üretiminde float yöntemi kullanılır.

Soğutma ve Tavlama: Şekillendirilen cam ürünleri, kontrollü bir şekilde soğutularak iç gerilimlerin minimize edilmesi sağlanır. Bu aşamada, soğutma hızının doğru ayarlanması, camın mukavemeti ve dayanıklılığı açısından kritiktir. Özellikle temperlenmiş cam üretiminde, soğutma süreci camın mekanik özelliklerini belirler.

Kalite Kontrol: Cam üretiminde kalite kontrol, üretim sürecinin her aşamasında uygulanmalıdır. Hammadde girişinden başlayarak, üretim süreci boyunca ve nihai ürün üzerinde çeşitli testler ve kontroller gerçekleştirilir. Görsel muayene, boyutsal kontroller, yüzey kalitesi değerlendirmeleri ve mekanik dayanıklılık testleri, kalite kontrol süreçlerinin temel unsurlarıdır. Günümüzde, görüntü işleme ve makine öğrenimi

teknikleri kullanılarak cam ürünlerindeki hataların otomatik tespiti ve analizi yapılmaktadır.

2.8.2. Camda Görülen Kusur Türleri

Cam üretim sürecinde meydana gelen kusurlar, ürünün estetik, mekanik ve optik özelliklerini olumsuz etkileyerek kalite sorunlarına yol açar. Bu kusurlar, üretim aşamalarındaki hatalar, hammadde safsızlıkları veya işleme koşullarındaki kontrol eksikliklerinden kaynaklanabilir. Kusurların türü ve boyutu, camın kullanım alanına ve üretim sürecine bağlı olarak değişiklik gösterebilir (Liang vd., 2019: 131-132).

Yüzey Kusurları: Yüzey kusurları, camın dış yüzeyinde meydana gelen çizikler, çatlaklar, dalgalanmalar ve pürüzler olarak tanımlanır. Bu tür kusurlar genellikle üretim sürecindeki mekanik işlemler sırasında veya ürünün taşınması esnasında oluşur. Ayrıca, camın kesimi ve işlenmesi sırasında meydana gelen hatalar da yüzey kusurlarına neden olabilir. Yüzey kusurları, camın görsel estetiğini ve dayanıklılığını olumsuz etkileyerek kullanım performansını düşürür (Öztürk, 2019: 22).

Optik Kusurlar: Optik kusurlar, camın ışığı iletme veya kırma özelliklerini bozan hatalardır. Dalgalanmalar, renk farklılıkları ve bulanıklık, optik kusurlar arasında yer alır. Bu tür kusurların oluşumu genellikle eritme ve soğutma işlemlerindeki düzensizliklerden kaynaklanır. Camın optik saflığını etkileyen bu kusurlar, özellikle yüksek hassasiyet gerektiren uygulamalarda sorun teşkil etmektedir (Bükücü ve Görkem, 2020: 510-519).

Kabarcıklar ve Boşluklar: Camın içinde oluşan kabarcıklar ve boşluklar, eritme sırasında hammadde karışımında kalan gazların dışarı çıkamamasından kaynaklanır. Bu tür kusurlar, camın mekanik dayanıklılığını ve optik özelliklerini olumsuz etkiler. Kabarcıkların önlenmesi için eritme sıcaklığının doğru ayarlanması ve hammaddelerin saflık kontrolünün titizlikle yapılması gerekmektedir (Kaya, 2016: 44-47).

İnklüzyonlar: İnklüzyonlar, cam içinde kalan istenmeyen katı parçacıklardır. Bu parçacıklar, genellikle hammadde safsızlıkları veya üretim ekipmanlarının aşınmasından kaynaklanır. İnklüzyonlar, camın görünümünü bozmasının yanı sıra mekanik zayıflıklara da yol açabilir. Bu nedenle, hammaddelerin uygun şekilde filtrelenmesi ve üretim süreçlerinin düzenli kontrolü önemlidir (Kaya, 2016: 44-47).

2.8.3. Geleneksel Kusur Tespit Yöntemleri ve Sınırlılıkları

Cam üretiminde kusur tespiti, kalite kontrol sürecinin en kritik aşamalarından biridir. Geleneksel yöntemler, genellikle insan gözüne dayalı görsel denetim veya temel fiziksel ölçüm cihazlarının kullanımıyla gerçekleştirilir. Bu yöntemlerin çeşitli avantajları olsa da bazı sınırlamaları bulunmaktadır. Geleneksel kusur tespit yöntemlerinin en yaygın olanı görsel denetimdir. İnsan gözüne dayalı bu yöntem, deneyimli operatörlerin cam yüzeyindeki çizik, çatlak ve kabarcık gibi kusurları manuel olarak tespit etmesiyle gerçekleştirilir. Ancak bu yaklaşım, insan gözünün algı kapasitesine bağımlı olduğu için sınırlıdır. Özellikle yüksek üretim hızlarında ve büyük hacimli ürünlerde, kusurların gözden kaçma ihtimali artmaktadır (Kaya, 2016: 45). Ayrıca, insan yorulması nedeniyle denetim performansı zamanla düşebilir (Kılıç, 1995: 72). Geleneksel fiziksel ölçüm cihazları, camın kalınlık, düzlemsellik ve boyutsal özelliklerini kontrol etmek için kullanılmaktadır. Bu yöntemler, özellikle düz cam üretiminde yaygındır. Ancak, bu teknikler yalnızca belirli fiziksel özellikleri ölçebilir ve yüzeydeki mikroskobik kusurların tespitinde yetersiz kalır (Keser, 2010: 58). Ayrıca, ölçüm cihazlarının ayarlarının hassas olmaması, yanlış tespitlere neden olabilir (Kaya, 2016: 47). Geleneksel yöntemler, camın işleme sırasında meydana gelen dalgalanma, kabarcık ve inklüzyon gibi kusurları tespit etmekte sınırlı kalmaktadır. Bu tür kusurların tespiti için daha karmaşık analiz yöntemlerine ihtiyaç duyulmaktadır. Özellikle yüksek hassasiyet gerektiren sanatsal cam üretiminde, bu yöntemlerin yetersiz kaldığı belirtilmiştir (Öztürk, 2019: 89). Geleneksel yöntemler, sınırlı teknolojik altyapıya sahiptir ve otomasyonun düşük olduğu durumlarda insan faktörüne bağlıdır. Bu, hata tespiti sürecinde doğruluk oranını düşürür. Özellikle, cam yüzeyindeki mikroskobik çatlakların ve optik kusurların tespit edilmesi neredeyse imkânsızdır (Akdemir ve Öztürk, 2015: 171). Geleneksel kusur tespit yöntemleri, düşük maliyetli ve kolay uygulanabilir olmalarına rağmen, yüksek hata oranları, insan faktörüne bağımlılık ve teknolojik sınırlamalar nedeniyle modern üretim süreçleri için yetersiz kalmaktadır. Bu nedenle, cam üretiminde kalite kontrol sürecinin iyileştirilmesi için daha gelişmiş ve otomatikleştirilmiş yöntemlerin kullanılması gereklidir. Örneğin, yapay zekâ ve derin öğrenme tabanlı sistemlerin bu alandaki potansiyeli üzerine yapılan çalışmalar umut vaat etmektedir (Liang vd., 2019: 132; Bükücü ve Görkem, 2020: 514).

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında, cam kusurlarının tespiti amacıyla Roboflow platformu üzerinden özel olarak oluşturulan veri seti, YOLOv5, YOLOv8 ve YOLO11 modelleri kullanılarak eğitilmiştir. Model eğitimi ve değerlendirme süreçleri Google Colab ortamında gerçekleştirilmiş olup, kullanılan kodlar bu platform üzerinde yazılmıştır. Eğitim sürecinde, görüntülerin analiz edilerek veri setinin temizlenmesi sağlanmış, düşük kaliteli ve hatalı etiketlenmiş görüntüler ayıklanmıştır. Modelin daha iyi genelleme yapabilmesi ve farklı senaryolara uyum sağlayabilmesi için veri artırma (data augmentation) teknikleri uygulanmış, bu sayede veri setindeki görüntü çeşitliliği artırılarak modelin daha geniş kapsamlı öğrenme sağlaması hedeflenmiştir. Veri seti, eğitim süreci için üç ana gruba ayrılmıştır:

- Eğitim kümesi: 4065 görüntü
- Doğrulama kümesi: 463 görüntü
- Test kümesi: 447 görüntü

Eğitim sürecinin ilk aşaması, görüntülerin toplanarak Roboflow platformunda etiketlenmesi olmuştur. Etiketleme işlemi tamamlandıktan sonra, elde edilen veri seti YOLO modelleri için uygun formatlarda dışa aktarılmış (export edilmiş) ve veri seti kodu oluşturulmuştur. Eğitim sürecinin yürütüleceği Google Colab ortamında, Ultralytics kütüphanesi import edilerek gerekli bağımlılıkların kurulumu gerçekleştirilmiştir. YOLO modellerinin eğitimi için uygun ortam sağlanarak Roboflow üzerinden oluşturulan veri seti içe aktarılmış (import edilmiş) ve işleme hazır hale getirilmiştir. Eğitim sürecinde, YOLOv5, YOLOv8 ve YOLO11 modelleri kullanılarak 100 epoch boyunca eğitim gerçekleştirilmiştir. Modelin her bir epoch sonunda elde ettiği kayıp (loss) değerleri, ortalama ortalama hassasiyet (mAP), duyarlılık (recall) ve kesinlik (precision) gibi metrikler hesaplanarak model performansı değerlendirilmiştir. Eğitim sürecinde, modellerin yakınsama hızları, doğrulukları ve performans kıyaslamaları analiz edilmiştir. Bu süreç sonunda elde edilen sonuçlar, her bir modelin cam kusurlarının tespiti konusundaki başarımını karşılaştırmak amacıyla detaylı olarak incelenmiş ve analiz edilmiştir. Eğitim sürecinden elde edilen veriler, modellerin hız, doğruluk ve genelleme kapasitesi gibi yönlerden değerlendirilmesine olanak sağlamış ve cam yüzeylerindeki kusurların tespitinde en uygun modelin belirlenmesini sağlamıştır.

3.1 Derin Öğrenme Modeli Seçilmesi ve Kullanımı

Bu çalışmada YOLOv5, YOLOv8 ve YOLO11 modellerini tercih etmemizin temel nedenleri şunlardır: YOLOv5, YOLO ailesinin en dengeli ve yaygın kullanılan sürümlerinden biridir. Hafif yapısı sayesinde düşük donanım gereksinimi ile hızlı çalışabilmesi, aynı zamanda tatmin edici doğruluk sunması nedeniyle tercih edilmiştir. YOLOv4'e kıyasla daha optimize edilmiş bir yapı sunar ve daha geniş bir topluluk desteğine sahiptir. YOLOv8, YOLO ailesinin en güncel ve performans odaklı sürümlerinden biridir. Yeni nesil mimarisi, gelişmiş veri artırma teknikleri ve daha iyi nesne tespiti için optimize edilmiş katmanları sayesinde hem hız hem de doğruluk açısından önemli iyileştirmeler sunmaktadır. YOLOv5'e kıyasla daha iyi genel doğruluk sağladığı için çalışmada yer almıştır. YOLO11, YOLO serisinin en son çıkan versiyonlarından biri olup, modern mimarisi ve gelişmiş derin öğrenme teknikleri ile en yüksek doğruluk oranlarını hedeflemektedir. YOLOv8'e kıyasla daha karmaşık sahnelerde ve küçük nesneleri tespit etmede daha başarılı olması nedeniyle çalışmaya dahil edilmiştir.

Diğer YOLO modellerini seçmeme nedenlerimiz YOLOv1, YOLOv2, YOLOv3 ve YOLOv4 eski nesil modeller olup, güncel versiyonlara kıyasla daha düşük doğruluk ve verimsiz mimariye sahip olmasıdır. YOLOv6 ve YOLOv7, bazı optimizasyon avantajları sunsa da, YOLOv8 ve YOLO11'in sunduğu gelişmiş doğruluk ve hız kombinasyonuna sahip değildir. YOLOv9 ve YOLOv10, araştırma aşamasında henüz yaygın kullanımda olmadığından veya yeterli benchmark testleri bulunmadığından çalışmaya dahil edilmemiştir. Bu nedenlerle, stabilite (YOLOv5), performans (YOLOv8) ve en güncel yenilikleri içeren (YOLO11) modeller tez çalışmam için en uygun seçimler olmuştur.

3.2 Roboflow Platformunda Veri Seti Hazırlama Süreci


Cam kusurlarının tespitinde kullanılacak veri seti için öncelikle görüntülerin toplamak için çalışmalar yapılmıştır. Bu süreçte; gerçek üretim hatalarından alınan görüntüler, simüle edilmiş veya yapay olarak oluşturulmuş kusurlu cam görselleri, farklı açılardan ve ışık koşullarından çekilmiş çeşitli cam yüzeyleri kullanılmıştır. Toplanan görüntüler, modelin daha iyi öğrenmesini sağlamak için gürültü giderme, kontrast ayarlama ve ölçeklendirme gibi ön işleme adımlarından geçirilmiştir. Roboflow, bilgisayarlı görü projelerinde veri seti yönetimini ve etiketlemeyi kolaylaştıran bir

platformdur. Veri seti hazırlama sürecinde şu adımlar takip edilmiştir: Roboflow hesabına giriş yapıldı ve yeni bir proje oluşturuldu. Toplanan görüntüler sisteme yüklendi ve çözünürlük ayarlamaları yapıldı. Veri seti için belirlenen etiketleme formatı olan YOLO seçildi. Cam kusurları “kırık”, “çatlak”, “çizik” gibi sınıflara ayrılarak etiketleme süreci başlatıldı. Cam kusurlarının doğru tespit edilebilmesi için görüntüler manuel olarak etiketlenmiştir. Roboflow’un otomatik etiketleme ve artırma özellikleri kullanılarak veri zenginleştirilmiştir. Etiketleme sonrası etiketlerin doğruluğu gözden geçirilmiş ve hatalı olanlar düzeltilmiştir.

3.1.2 Veri Artırma (Augmentation) İşlemleri

3.1.2.1. Döndürme (Rotation)

Döndürme işlemi, görüntünün belirli bir açıyla çevrilerek yeniden düzenlenmesi işlemidir. Bu teknik, modelin nesneleri farklı açılardan tanıyabilmesini sağlamak amacıyla uygulanır. Örneğin, bir kusur belirli bir konumda yer aldığına, döndürme işlemi ile bu kusurun farklı yönlerde bakması sağlanarak modelin her açıda doğru tahmin yapabilmesi amaçlanır. Bu çalışmada döndürme işlemi rastgele açılarla gerçekleştirilmiş ve her görüntü farklı açılarda döndürülerek veri setine eklenmiştir. Veri setinde yer alan görüntüye yapılan Döndürme(Rotation) işlemi Şekil 3.1’de gösterilmiştir.



Şekil 3. 1. Döndürme İşlemi

3.1.2.2. Parlaklık ve Kontrast Değişimi (Brightness & Contrast Adjustment)

Görüntüler farklı aydınlatma koşullarında elde edilebileceğinden, modelin değişen ışıklandırma seviyelerine karşı dayanıklı olması önemlidir. Parlaklık ve kontrast değişikliği, görüntünün aydınlık seviyesini ve renk tonlarını değiştirmek için kullanılır.


Parlaklık artırılarak veya azaltılarak farklı ışık koşulları simüle edilirken, kontrast değişimi sayesinde nesnelerin daha belirgin veya daha yumuşak görünmesi sağlanabilir. Bu yöntem, modelin gerçek dünya koşullarında daha iyi performans göstermesine yardımcı olur. Veri setinde yer alan görüntüye yapılan Parlaklık ve Kontrast Değişimi işlemi Şekil 3.2’de gösterilmiştir.



Şekil 3. 2. Parlaklık ve Kontrast Değişimi İşlemi

3.1.2.3. Kırpma (Crop)

Kırpma işlemi, görüntünün belirli bir bölgesinin kesilerek geri kalan kısmın dışarıda bırakılmasıdır. Bu yöntem, modelin nesneyi tam boyutta değil, kısmi bir şekilde de tanıyabilmesini sağlamak için uygulanır. Örneğin, bir kusur belirli bir konumda bulunuyorsa, kırpma işlemi ile görüntünün bir kısmı kesilip modelin daha küçük detaylara odaklanması sağlanabilir. Bu süreçte kırılan görüntülerin boyutu korunarak modelin veri kaybı yaşamaması sağlanmıştır. Veri setinde yer alan görüntüye yapılan Kırpma işlemi Şekil 3.3’de gösterilmiştir.



Şekil 3. 3. Kırpma İşlemi

3.1.2.4. Yatay Çevirme (Horizontal Flip)

Yatay çevirme işlemi, görüntünün sağ ve sol taraflarının yer değiştirmesiyle elde edilir. Bu yöntem, özellikle yön bağımsız nesneler veya kusurlar için kullanılarak modelin her iki yönde de tanıma yeteneğini geliştirmeyi amaçlar. Örneğin, bir cam üzerindeki çatlak sağ tarafta bulunuyorsa, yatay çevirme işlemiyle aynı çatlak sol tarafa yerleştirilerek modelin her iki durumu da öğrenmesi sağlanabilir. Bu işlem, özellikle simetrik olmayan nesnelerin tanınmasında önemlidir. Veri setinde yer alan görüntüye yapılan Yatay Çevirme işlemi Şekil 3.4’de gösterilmiştir.



Şekil 3. 4. Yatay Çevirme İşlemi

Bu çalışmada, cam yüzey kusurlarını tespit etmek amacıyla oluşturulan veri setine dört farklı veri artırma yöntemi uygulanmıştır. Döndürme, parlaklık-kontrast değişikliği, kırpma ve yatay çevirme teknikleri, veri setinin çeşitliliğini artırarak modelin daha doğru tahminler yapmasına olanak tanımıştır. Bu yöntemler sayesinde modelin, gerçek dünya koşullarında farklı açılar, ışık koşulları ve yönlerde bulunan kusurları daha iyi öğrenmesi ve tespit etmesi sağlanmıştır.


Bu işlemler, Roboflow’un dahili veri artırma seçenekleri ile uygulanarak veri seti daha çeşitli hale getirilmiştir. Eğitim sürecinde modelin genelleme yeteneğini artırmak için veri seti şu şekilde ayrılmıştır: Eğitim Seti %70, doğrulama Seti %20, Test Seti %10. Roboflow, bu bölme işlemini otomatik olarak gerçekleştirme imkanı sunduğundan, optimum dağılım sağlanarak modelin aşırı öğrenmesini (overfitting) önlemeye yönelik ayarlamalar yapılmıştır. Veri seti hazırlandıktan sonra, YOLOv5, YOLOv8 ve YOLO11 modelleri ile eğitim yapılabilmesi için uygun formatta dışa aktarıldı. YOLO formatı kullanılarak veriler indirildi. Modelin eğitiminde kullanılacak Python ortamına entegre edildi. Model eğitimi için gerekli kodlar yazılarak veri seti eğitim sürecine dahil edildi.

3.1.3 Roboflow Platformunun Kullanılmasının Sonucu ve Avantajları

Roboflow'un sunduğu hızlı etiketleme, veri artırma, veri seti yönetimi ve format dönüştürme özellikleri sayesinde, veri hazırlama süreci oldukça verimli hale getirilmiştir. Daha kaliteli ve dengeli bir veri seti oluşturularak modelin performansı artırılmış, Hata oranları düşürülerek modelin genelleme kapasitesi iyileştirilmiştir. Bu süreç sayesinde YOLO modellerinin eğitime uygun, güçlü ve dengeli bir veri seti oluşturulmuş ve cam kusurlarının tespiti için optimize edilmiş bir derin öğrenme modeli geliştirilmiştir.

3.3 Tez Çalışmamızda Takip Edilen Eğitim Süreci Basamakları

Bilgisayarlı görü ve yapay zeka ile cam kusurlarının tespit etme sürecinde izlediğimiz adımlar Şekil 3.5'de gösterilmiştir.



Şekil 3. 5. Tez Çalışmasında Takip Edilen Eğitim Süreci Basamakları

Bu çalışmada öncelikle çözülmesi gereken problem tanımlanmıştır. Cam yüzeylerindeki kusurların tespiti amacıyla, farklı türde camlardan elde edilen görüntüler kullanılarak kapsamlı bir veri seti oluşturulmuştur. Veri setinde çeşitliliği artırmak adına araç camı, pencere camı, ayna gibi farklı cam türlerinden alınan görüntüler kullanılmıştır. Toplanan veriler, veri ön işleme aşamasından geçirilerek temizlenmiş, bozuk ve eksik veriler veri tabanından çıkarılmıştır. Ardından, en uygun modelin belirlenmesi için çeşitli derin öğrenme yöntemleri üzerinde değerlendirmeler yapılmış ve bu süreç sonucunda YOLO algoritmasının kullanılmasına karar verilmiştir. Model seçiminden sonra, veri seti ile model eğitilmiş ve değerlendirme sürecine geçilmiştir. Eğitim sürecinde farklı epoch (iterasyon) sayıları ve veri seti genişlikleri kullanılarak modelin performansı optimize edilmiştir. Başlangıçta 700 görüntü ve 50 epoch ile yapılan eğitim süreci, elde edilen sonuçlar doğrultusunda güncellenmiş; veri seti 1000 görüntü ve 75 epoch, son olarak ise 1303 görüntü ve 100 epoch olacak şekilde genişletilmiştir. Son aşamada, geliştirilen model, mevcut sistemlere entegre edilebilecek hâle getirilerek dağıtım süreci tamamlanmıştır. Modelin entegrasyonu ile cam üretim süreçlerinde gerçek zamanlı kusur

tespiti yapılabilmesi hedeflenmiştir. Veri setimizde kullandığımız görüntü sayıları ve kategorileri Çizelge 3.1’de verilmiştir.

Çizelge 3. 1. Projede Kullanılan Veri Setinde Sınıf Bazlı Etiketleme Sayısı

Tespit işlemi yapılacak Cam Kusurları	Kırık	Çatlak	Çizik	Sağlam
Kullanılan Görüntü Sayısı	4120	4163	615	3055

Eğitim veri setimizde 1960 kırık , 1767 çatlak, 1248 çizik cam örneği kullanılmıştır. Tablo 3.1’de görülen veriler bir çok farklı cam örneği türüne yer verilerek oluşturulmuştur. Örneğin pencere,araç camı, çerçeve vb. farklı türlerden örnekler alınmıştır.

3.4 YOLO Performans Metrikleri

YOLO (You Only Look Once), gerçek zamanlı nesne tespiti konusunda yüksek başarı gösteren yaygın bir derin öğrenme modelidir. Modelin başarımını analiz etmek, iyileştirmek ve diğer modellerle kıyaslamak için çeşitli performans ölçütleri kullanılır. Bunlar arasında Doğruluk (Accuracy), Hassasiyet (Precision), Duyarlılık (Recall), F1 Skoru ve mAP50 gibi metrikler kritik bir rol oynar.

3.4.1 Doğruluk(Accuracy)

Doğruluk, bir modelin sınıflandırma doğruluğunu ölçen temel metriklerden biridir. Modelin doğru tahmin ettiği örneklerin, toplam örnek sayısına oranını ifade eder. YOLO gibi nesne tespit algoritmalarında modelin genel performansını değerlendirmek için yaygın olarak kullanılır ancak, doğruluk tek başına modelin başarısını tam olarak yansıtmayabilir. Özellikle sınıf dengesizliği olan veri kümelerinde yanıltıcı sonuçlar verebilir. Örneğin, bir modelin doğruluk oranı %96 olabilir, ancak düşük örnek sayısına sahip belirli sınıflarda başarısız olabilir. Bu nedenle, doğruluk metriği tek başına yeterli görülmemeli, hassasiyet ve duyarlılık gibi ek ölçütlerle desteklenmelidir.

Doğruluk, aşağıdaki matematiksel formül ile hesaplanır:

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.1)$$

3.4.2 Hassasiyet (Precision)

Hassasiyet, modelin pozitif olarak sınıflandırdığı örnekler arasında gerçekten doğru olanların oranını ifade eder. Bir başka deyişle, modelin yanlış pozitif tahminleri ne kadar düşük seviyede tuttuğunu gösterir. Yüksek hassasiyet değeri, modelin yanlış pozitif tahminleri en aza indirerek yalnızca gerçek pozitif örnekleri tespit etmede başarılı olduğunu gösterir. Özellikle yanlış pozitiflerin maliyetli olduğu uygulamalarda (örneğin, tıbbi teşhis veya güvenlik sistemleri) hassasiyet metriği kritik bir değerlendirme ölçütüdür.

Hassasiyet, aşağıdaki matematiksel formül ile hesaplanmaktadır:

$$Hassasiyet = \frac{TP}{TP + FP} \quad (3.2)$$

3.4.3 Duyarlılık (Recall)

Duyarlılık, modelin gerçek pozitif örnekler arasından doğru tahmin ettiği pozitiflerin oranını ifade eder. Bir başka deyişle, modelin pozitif sınıfa ait verileri atlamadan tespit etme başarısını ölçer. Yüksek duyarlılık değeri, modelin gerçek pozitif örnekleri eksiksiz bir şekilde tanımlama yeteneğinin güçlü olduğunu gösterir. Özellikle, yanlış negatiflerin kritik olduğu uygulamalarda (örneğin, hastalık teşhisi veya hata tespiti gibi) duyarlılık metriği büyük önem taşır. Modelin pozitif sınıfa ait örnekleri kaçırmaması gerektiği durumlarda, duyarlılık yüksek olmalıdır.

Duyarlılık metriği aşağıdaki matematiksel formül ile hesaplanmaktadır:

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.3)$$

3.4.4 F1 Skoru

F1 skoru, hassasiyet (Precision) ve duyarlılığın (Recall) harmonik ortalamasını ifade eden bir performans ölçütüdür. Bu metrik, iki değer arasında dengeli bir değerlendirme sağlayarak modelin genel başarımını ölçmede önemli bir rol oynar. Yüksek bir F1 skoru, modelin hem yanlış pozitifleri hem de yanlış negatifleri minimum seviyeye indirerek doğru tahminler yapma konusunda başarılı olduğunu gösterir. F1 skoru, özellikle sınıf dengesizliği bulunan veri kümelerinde model performansını değerlendirirken tek başına doğruluk (Accuracy) metriğinden daha güvenilir bir ölçüm sunar. Değer aralığı 0 ile 1 arasında olup, 1 en yüksek başarıyı ifade eder. F1 skoru aşağıdaki matematiksel formül ile hesaplanmaktadır:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.4)$$

3.4.5 mAP50

mAP50, YOLO modelinin nesne tespiti performansını değerlendirmek için kullanılan temel metriklerden biridir. Bu ölçüt, farklı sınıflar için oluşturulan hassasiyet-duyarlılık (Precision-Recall) eğrilerinin altında kalan alanı hesaplayarak modelin doğruluğunu analiz eder. %50 IoU (Intersection over Union) eşik değeri, bir nesnenin doğru tespit edilmiş kabul edilmesi için modelin tahmin ettiği sınırlayıcı kutu (bounding box) ile gerçek sınır kutusu arasındaki örtüşme oranının en az %50 olması gerektiğini belirtir. Yüksek bir mAP50 değeri, modelin nesneleri başarılı bir şekilde tanımlayıp sınıflandırma yeteneğinin yüksek olduğunu gösterir. Bu metrik, modelin genel hassasiyetini (precision) ve kapsayıcılığını (recall) dengeleyerek, YOLO tabanlı sistemlerin performans analizinde önemli bir değerlendirme ölçütü olarak kullanılır.


3.5 Görüntü İşleme

Görüntü işleme, sinyal işlemekten farklı bir süreç olarak, verilerin yakalanması, ölçülmesi ve değerlendirilmesi sonrasında başka bir cihazda okunabilir bir formata dönüştürülmesi ya da elektronik ortamlar arasında aktarılması amacıyla gerçekleştirilen bir uygulamadır. Görüntü işlemenin temel amacı, mevcut görüntülerin işlenmesi, yani kayıtlı resimlerin veya grafiklerin dönüştürülmesi, değiştirilmesi, optimize edilmesi ya da iyileştirilmesidir.

3.6 Özellik Çıkarımı

Özellik çıkarımı (feature extraction), büyük ve karmaşık veri setlerinden anlamlı ve özet bilgilerin elde edilmesi sürecidir. Bu süreç, ham veriyi, makine öğrenimi algoritmalarının anlayıp işleyebileceği bir formata dönüştürmek amacıyla gerçekleştirilir. Özellik çıkarımı, modelin performansını artırmak, hesaplama maliyetini düşürmek ve öğrenme sürecini kolaylaştırmak için önemli bir adımdır (Jolliffe & Cadima, 2016). Özellik çıkarımı sırasında genellikle, verideki enformasyon kaybını en aza indirerek, asıl yapıyı temsil eden daha az sayıda özellik seçilir veya türetilir. Örneğin, görüntü işleme alanında kenar algılama veya renk histogramları çıkarımı yaygın yöntemlerdendir. Benzer şekilde, metin analitiğinde kelime torbası (bag-of-words) veya TF-IDF yöntemleri kullanılarak ham metinden anlamlı özellikler elde edilir. Özellik çıkarımı, özellikle boyut azaltma teknikleriyle yakından ilişkilidir. Temel bileşen analizi (PCA) ve doğrusal

özniteliklerinin çıkarılması işlemleri gerçekleştirilir. Boyun bölümünde ise omurga bölümünde çıkarılan özniteliklerin birleştirme ve seçilme işlemleri gerçekleştirilir. Son olarak baş bölümünde ise tahminleme işlemi yapılır. YOLO Tarihsel Gelişim Çizelgesi bölümleri Şekil 3.7’de gösterilmiştir.



Şekil 3. 7. YOLO Tarihsel Gelişim Çizelgesi

YOLO mimarisi, ilk olarak Joseph Redmon tarafından geliştirilmiş olup, nesne tespiti alanında hız ve doğruluğu optimize eden yenilikçi bir yaklaşım sunmuştur. İlk versiyon olan YOLOv1, temel nesne tespiti mekanizmasını tanıtmış ve tek geçişli (single pass) analiz yöntemi ile geleneksel bölgesel öneri tabanlı (R-CNN gibi) yöntemlere kıyasla önemli bir hız avantajı sağlamıştır. YOLOv2 (Darknet-19) sürümü, daha geniş bir nesne sınıfı desteği sunarak doğruluk ve hız açısından iyileştirilmiştir. Ardından geliştirilen YOLOv3, çift katmanlı CNN yapısıyla daha hassas tahminler yapabilen ve yüksek çözünürlüklü görüntülerde daha başarılı sonuçlar elde eden bir versiyon olarak öne çıkmıştır. YOLOv4, model performansını daha da artırarak çeşitli optimizasyonlar içermiş ve endüstriyel kullanıma yönelik geliştirilmiştir. YOLOv5, uluslararası topluluk tarafından yaygın olarak benimsenmiş, kullanıcı dostu yapısı ve esnekliği sayesinde geniş bir uygulama alanı bulmuştur. Son sürümlerden YOLOv7 ve YOLOv8, hız ve doğruluk arasındaki dengeyi daha da iyileştirerek gerçek zamanlı uygulamalar için en verimli modeller arasında yer almıştır. Her yeni sürüm, modelin doğruluk oranlarını artırırken hesaplama yükünü optimize etmeye yönelik çeşitli geliştirmeler içermiş, böylece görüntü işleme, nesne tespiti ve otonom sistemler gibi birçok alanda kullanımını yaygınlaştırmıştır. (Redmon et al., 2016)

3.7.2. YOLO'nun Temel Özellikleri ve Avantajları

YOLO'nun en büyük avantajlarından biri, nesne tespit sürecini tek bir ağ geçişinde gerçekleştirmesidir. Geleneksel yöntemlerde nesne tespiti genellikle önce aday bölgelerin belirlenmesi ve ardından bu bölgelerde sınıflandırma yapılmasıyla gerçekleştirilirken, YOLO tüm görüntüyü aynı anda değerlendirerek önemli bir hız

avantajı sağlamaktadır. Bu sayede gerçek zamanlı nesne tespiti yapılabilir ve video akışları üzerinde dahi yüksek verimlilikle çalışabilir. YOLO, aynı anda birden fazla nesneyi tespit edebilme özelliğine sahiptir. Model, bir görüntüyü belirli bir grid (ızgara) yapısına böler ve her bir grid hücreğine, belirlenen nesneleri algılamaktan sorumlu olacak şekilde tahminleme yapar. Bu yöntem, aynı anda farklı sınıflara ait birden fazla nesnenin tek bir görüntü içinde yüksek doğrulukla belirlenmesini sağlar. Örneğin, bir sahnede hem insanları hem araçları hem de hayvanları tespit edebilir. YOLO, görüntü üzerinde grid tabanlı bir yaklaşım kullanarak, modelin parametrelerini daha verimli hale getirir ve eğitim sürecinde hesaplama maliyetlerini düşürür. Her grid hücresi, belirli bir nesnenin var olup olmadığını tahmin eder, sınırlayıcı kutu ve güven skoru üretir. Bu yöntem, modelin hafif ve hızlı çalışmasını sağlayarak büyük veri setleri üzerinde daha etkili öğrenme süreçleri sunar. YOLO, nesne tespiti sürecinde geleneksel bölgesel öneri tabanlı yaklaşımlardan (örneğin, R-CNN ve Fast R-CNN) farklı olarak görüntüyü tek seferde analiz eder. Bu sayede model, nesne tespitini hızlandırırken hesaplama kaynaklarını da daha verimli kullanır. R-CNN gibi geleneksel yöntemler önce görüntüde olası nesne bölgelerini belirleyip ardından her bölgeyi tek tek işlediği için daha yavaşken, YOLO doğrudan tüm görüntüyü işleyerek tek adımda nesne tespiti yapar. YOLO, tespit edilen nesneler için bounding box (sınırlayıcı kutu) üretir ve her kutu için güven skoru (confidence score) hesaplar. Bu güven skoru, belirlenen nesnenin ne kadar doğru tespit edildiğini gösterir. Bu sayede model, yanlış pozitifleri azaltabilir ve yalnızca güvenilir tahminleri değerlendirmeye alabilir. YOLO mimarisi, hız ve doğruluk arasında optimum bir denge sunar. Hem yüksek hızlı çıkarım (inference) yapabilmesi hem de büyük veri setlerinde tatmin edici bir doğruluk elde edebilmesi, onu birçok gerçek dünya uygulaması için uygun hale getirir. Ancak, modelin küçük nesneleri tespit etme konusunda bazı sınırlamaları bulunmaktadır. Küçük nesneler, grid hücrelerinin geniş bir alanı kapsaması nedeniyle zaman zaman düşük doğrulukla tespit edilebilir. Nesne tanıma, görüntü işleme ve bilgisayarla görme uygulamalarında yaygın olarak kullanılan bir tekniktir ve otomatik etiketleme ile video anlamsal analiz süreçlerinde, anlık nesne tespiti ve hareket analizi yapmak için kullanılır. YOLO, sürücüsüz araçlar ve robotik sistemler için çevresindeki nesneleri tanıma yeteneği sunarak otonom araçların güvenliğini artırırken, kamera tabanlı güvenlik sistemlerinde de potansiyel tehditlerin tespitinde etkili bir rol oynayabilir. (Redmon et al., 2016).

3.7.3. YOLOv5

YOLOv5, 2020 yılında Ultralytics tarafından geliştirilen ve GitHub üzerinden açık kaynak olarak yayımlanan bir nesne tespiti modelidir (Jocher et al., 2020). Önceki YOLO sürümlerine kıyasla, PyTorch tabanlı bir yapı kullanarak esnek ve kolay uygulanabilir bir model sunmaktadır. YOLOv5, CSPDarknet53 omurgası üzerine inşa edilmiştir ve PANet ile özelliklerin daha etkin şekilde birleştirilmesini sağlamaktadır. Modelin temel bileşenleri şunlardır:

- **Backbone (Omurga):** Görüntüdeki önemli özellikleri çıkarır.
- **Neck (Boyun):** PANet tabanlı olup, farklı ölçeklerde özellik haritalarını birleştirerek küçük nesnelerin tespitinde iyileştirmeler sağlar.
- **Head (Başlık):** YOLO v3'ten miras alınan bölgesel önerme mekanizmasıyla nesne sınıflandırma ve konum tahmini işlemlerini gerçekleştirir.

YOLOv5'in avantajları düşük donanım gereksinimi sayesinde gömülü sistemlerde çalıştırılabilir. Otomatik öğrenme oranı ayarlama ve mozaik veri artırma teknikleri içerir. Daha hızlı eğitim süreci ile büyük veri setlerinde etkin çalışır. YOLOv5 modeli, COCO veri seti üzerinde yapılan testlerde ortalama doğruluk (mAP) açısından önceki YOLO sürümlerine kıyasla dengeli bir performans göstermiştir. Küçük nesneleri tespit etme yeteneği orta seviyede olup, hız ve doğruluk arasında bir denge sunmaktadır. (Jocher et al., 2020).

3.7.4. YOLOv8

YOLOv8, 2023 yılında Ultralytics tarafından duyurulan ve YOLO ailesinin en gelişmiş versiyonlarından biri olarak kabul edilen bir modeldir. YOLOv5'in mimarisinden esinlenerek geliştirilmiş olup, çapa kullanmayan (anchor-free) bir yaklaşım sunarak bölge tahmin süreçlerini optimize etmiştir. YOLOv8, CNN tabanlı bir model olmasına rağmen transformer bileşenlerini içerebilecek şekilde tasarlanmıştır. Modelin temel yenilikleri:

- **Anchor-Free Algoritma:** Çapa bazlı tespit mekanizmasını kaldırarak daha hızlı ve daha hassas tahminler yapar.
- **Daha Hafif ve Optimize Mimari:** YOLOv5'e kıyasla daha az parametre ile aynı veya daha yüksek doğruluk elde eder.

- **Gelişmiş Veri İşleme:** Model, segmentasyon ve poz tahmini gibi ek görevleri de destekleyebilmektedir.

YOLOv8'in avantajları YOLOv5'e kıyasla daha yüksek doğruluk oranı sunar. Video analizi ve gerçek zamanlı nesne tespitinde daha iyi optimizasyon içerir. YOLOv8'in modüler yapısı, nesne tespiti dışında segmentasyon ve poz tahmini gibi farklı görevlerde de kullanılmasını sağlar. YOLOv8 modeli, COCO ve OpenImages veri setlerinde yapılan testlerde YOLOv5'e kıyasla %5-10 daha yüksek doğruluk (mAP) oranlarına ulaşmıştır. Küçük nesneleri tespit etme yeteneği yüksek olup, büyük veri setlerinde daha etkin çalışmaktadır. (Ultralytics, 2023).

3.7.5. YOLO11

YOLO11, 2024 yılında geliştirilmiş ve önceki YOLO sürümlerinin en güncel versiyonu olarak duyurulmuştur. YOLO11, nesne tespiti, segmentasyon ve video analizi gibi geniş bir kullanım alanına sahiptir. YOLO11, önceki sürümlerin CNN tabanlı mimarisini geliştirmiş ve Vision Transformer (ViT) tabanlı özellik haritaları kullanmaya başlamıştır. Temel bileşenler şunlardır:

- **Hybrid CNN + Transformer Omurga:** CNN'in güçlü uzaysal analiz yeteneklerini ve transformer'ın uzun menzilli ilişkileri modelleme kapasitesini birleştirir.
- **Daha Derin ve Optimize Edilmiş Yapı:** Parametre sayısını artırmadan daha fazla bilgi işleyebilen bir yapı sunar.
- **Daha Hassas Bölge Tahmini Mekanizması:** Nesne sınır kutularını (bounding boxes) daha yüksek doğrulukla tahmin eder.

YOLO11'in avantajları Küçük ve büyük nesneleri aynı anda daha yüksek doğrulukla tespit eder. Gelişmiş özellik çıkarımı sayesinde düşük kaliteli görüntülerde daha iyi performans gösterir. Daha az veriyle daha hızlı eğitim imkanı sunar. YOLO11, yapılan testlerde mAP ve FPS açısından önceki YOLO sürümlerine kıyasla üstün performans göstermiştir. Küçük nesne algılama ve büyük ölçekli veri setleriyle eğitim konularında önemli iyileştirmeler sunmaktadır. (Ultralytics, 2024).

3.7.6. YOLO Modellerinin Karşılaştırılması

YOLOv5, YOLOv8 ve YOLO11 modellerinin teknik özellik karşılaştırılması Çizelge 3.2'de gösterilmiştir.

Çizelge 3. 2. Teknik Özellikler Karşılaştırması

Özellik	YOLOv5	YOLOv8	YOLO11
Geliştirici	Ultralytics	Ultralytics	Ultralytics
Yıl	2020	2023	2024+
Kullanılan Framework	PyTorch	PyTorch	PyTorch/TensorFlow
Model Mimarisi	CNN tabanlı	Gelişmiş CNN + Transformer bileşenleri	Transformer + CNN
Desteklediği Görevler	Nesne tespiti	Nesne tespiti, segmentasyon, pose tahmini	Nesne tespiti, segmentasyon, video analizi
Öğrenme Oranı Ayarlama	Evet (Auto LR Finder)	Evet (Optimize edilmiş)	Gelişmiş (Adaptif LR)
Küçük Nesne Algılama Yeteneği	Orta	Yüksek	Çok Yüksek
Özelleştirme Esnekliği	Orta	Yüksek	Çok Yüksek
Donanım Gereksinimi	Düşük-Orta	Orta-Yüksek	Yüksek

YOLOv5, YOLOv8 ve YOLO11 modelleri nesne tespiti alanında farklı seviyelerde performans ve esneklik sunmaktadır. YOLOv5, 2020 yılında Ultralytics tarafından geliştirilmiş, CNN tabanlı, düşük donanım gereksinimiyle hızlı ve verimli bir modeldir ancak küçük nesne algılama ve ek görevlerde sınırlıdır. YOLOv8, 2023'te geliştirilmiş olup, gelişmiş CNN ve Transformer bileşenleriyle nesne tespiti, segmentasyon ve poz tahmini gibi görevleri destekleyerek daha yüksek doğruluk ve esneklik sunar. YOLO11 ise en güncel model olup Transformer ve CNN hibrit yapısını kullanarak küçük nesne algılamada en yüksek doğruluğu sağlamaktadır. YOLOv5 hız ve düşük donanım avantajı sunarken, YOLOv8 daha geniş kullanım alanlarına hitap eder, YOLO11 ise yüksek donanım gereksinimiyle en iyi performansı sunan modeldir. YOLOv5, YOLOv8 ve YOLO11 modellerinin performans karşılaştırması Çizelge 3.3'de gösterilmiştir.

Çizelge 3. 3. Performans Karşılaştırması

Model	FPS (RTX 3090)	mAP@50	mAP@50:95	Küçük Nesne Algılama
YOLOv5	~120	50.2	35.7	Orta
YOLOv8	~140	52.8	37.9	Yüksek
YOLO11	~160	55.7	39.8	Çok Yüksek

YOLOv5, YOLOv8 ve YOLO11 modellerinin performans karşılaştırması incelendiğinde, YOLOv11 en yüksek doğruluk oranına (mAP@50:95: %39.8) ve en hızlı çalışma süresine (160 FPS) sahip model olarak öne çıkmaktadır. YOLOv8, %37.9 mAP ile YOLOv5'ten daha başarılı olup, FPS açısından da daha hızlıdır (140 FPS). YOLOv5 ise 120 FPS hızına sahip olup, doğruluk oranı (%35.7 mAP) diğer modellere göre daha düşüktür. Küçük nesne algılama açısından, YOLO11 en yüksek başarıyı sağlarken, YOLOv8 orta seviyede, YOLOv5 ise en zayıf modeldir. Genel olarak, YOLOv5 hız ve verimlilik için idealken, YOLOv8 daha yüksek doğruluk ve geniş kullanım desteği sunar, YOLO11 ise en yüksek performansa sahip ancak güçlü donanım gerektirir.



4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında, cam kusurlarının tespiti amacıyla Roboflow(Roboflow, n.d.). platformu üzerinden özel olarak oluşturulan veri seti, YOLOv5, YOLOv8 ve YOLO11 modelleri kullanılarak eğitilmiştir. Model eğitimi ve değerlendirme süreçleri Google Colab ortamında gerçekleştirilmiş olup, kullanılan kodlar bu platform üzerinde yazılmıştır. Eğitim sürecinde, görüntülerin analiz edilerek veri setinin temizlenmesi sağlanmış, düşük kaliteli ve hatalı etiketlenmiş görüntüler ayıklanmıştır. Modelin daha iyi genelleme yapabilmesi ve farklı senaryolara uyum sağlayabilmesi için veri artırma (data augmentation) teknikleri uygulanmış, bu sayede veri setindeki görüntü çeşitliliği artırılarak modelin daha geniş kapsamlı öğrenme sağlaması hedeflenmiştir. Veri seti, eğitim süreci için üç ana gruba ayrılmıştır:

- Eğitim kümesi: 4065 görüntü
- Doğrulama kümesi: 463 görüntü
- Test kümesi: 447 görüntü

Eğitim sürecinin ilk aşaması, görüntülerin toplanarak Roboflow platformunda etiketlenmesi olmuştur. Etiketleme işlemi tamamlandıktan sonra, elde edilen veri seti YOLO modelleri için uygun formatlarda dışa aktarılmış (export edilmiş) ve veri seti kodu oluşturulmuştur. Eğitim sürecinin yürütüleceği Google Colab ortamında, Ultralytics kütüphanesi import edilerek gerekli bağımlılıkların kurulumu gerçekleştirilmiştir. YOLO modellerinin eğitimi için uygun ortam sağlanarak Roboflow üzerinden oluşturulan veri seti içe aktarılmış (import edilmiş) ve işleme hazır hale getirilmiştir. Eğitim sürecinde, YOLOv5, YOLOv8 ve YOLO11 modelleri kullanılarak 100 epoch boyunca eğitim gerçekleştirilmiştir. Modelin her bir epoch sonunda elde ettiği kayıp (loss) değerleri, ortalama ortalama hassasiyet (mAP), duyarlılık (recall) ve kesinlik (precision) gibi metrikler hesaplanarak model performansı değerlendirilmiştir. Eğitim sürecinde, modellerin yakınsama hızları, doğrulukları ve performans kıyaslamaları analiz edilmiştir.

Bu süreç sonunda elde edilen sonuçlar, her bir modelin cam kusurlarının tespiti konusundaki başarımını karşılaştırmak amacıyla detaylı olarak incelenmiş ve analiz edilmiştir. Eğitim sürecinden elde edilen veriler, modellerin hız, doğruluk ve genelleme kapasitesi gibi yönlerden değerlendirilmesine olanak sağlamış ve cam yüzeylerindeki kusurların tespitinde en uygun modelin belirlenmesini sağlamıştır. Tüm YOLO versiyonlarında eğitim için kullanılan hiperparametreler Çizelge 4.1’de gösterilmiştir.

Çizelge 4. 1. Tüm YOLO versiyonlarında kullanılan hiperparametreler

Sınıflandırma	Parametre
İterasyon	100
Yığın(Batch)	16
Öğrenme Oranı	0.001
Görsel Boyutu	640x640


4.1. YOLOv5 Eğitim Süreci

YOLOv5 modeli ile elde edilen sonuçların sınıf bazında performans metrikleri Tablo 4.1’de verilmiştir. Tüm sınıflar için hesaplanan mAP puanı değeri %27.36 olarak elde edilmiştir. En yüksek mAP puanına sahip sınıfın Kırık sınıfı olduğu görülmüştür. YOLOv5 eğitim sonuçlarının sınıf bazındaki performans metrikleri Çizelge 4.2’de gösterilmiştir.

Çizelge 4. 2. YOLOv5 ile sınıf bazında elde edilen performans metrikleri

Sınıf	Doğruluk(%)	Hassasiyet(%)	Duyarlılık(%)	F1 Skoru(%)	mAP50(%)
Kırık	40.00	43.70	42.00	37.00	46.00
Çatlak	57.00	44.80	60.00	35.00	44.80
Çizik	17.00	6.70	14.00	7.00	12.10
Genel Ortalama	38.00	31.73	38.60	26.30	34.29

YOLOv5 modeli ile gerçekleştirilen deneylerde modelin sınıflar arasında farklı performans sergilediği gözlemlenmiştir. Genel doğruluk ve mAP50 değerleri, modelin ayırt edici özellikleri yakalayabildiğini ve tespit yeteneğine sahip olduğunu göstermektedir. F1 skorları ve diğer performans metrikleri incelendiğinde, modelin bazı durumlarda daha dengeli tahminler yapabildiği, farklı senaryolarda ise değişkenlik gösterebildiği anlaşılmaktadır. Genel değerlendirme açısından, modelin belirli koşullarda başarılı tespitler yaptığı ve nesne tanıma yeteneğini ortaya koyduğu söylenebilir. YOLOv5 model eğitiminin ilerlemesinde elde edilen sonuçlar Şekil 4.1’de gösterilmiştir.



Şekil 4. 1. YOLOv5 modelinin performans metrik grafikleri

Modelin eğitim sürecinde kayıpların (loss) istikrarlı bir şekilde azaldığı ve öğrenmenin başarılı bir şekilde gerçekleştiği görülmektedir. Precision ve recall metrikleri belirli dalgalanmalar gösterse de model, nesne tespiti konusunda etkili sonuçlar üretmektedir. mAP@0.5 metriğinin başlangıçta yükselmesi, modelin doğrulama setinde başarılı tahminler yapabildiğini göstermektedir. mAP@0.5:0.95 metriğinin düşük seviyelerde olması, modelin küçük veya düşük IoU eşiklerinde nesne tespit performansını daha da artırma potansiyeline sahip olduğunu göstermektedir. YOLOv5 modeli ile test kümesindeki görüntü verileri test edilmiştir. Cam kusurlarının tespit edildiği örnek görüntüler Şekil 4.2’de gösterilmiştir.




Şekil 4. 2. YOLOv5 modeli eğitim sonucunda elde edilen görüntüler

Görsel, modelin cam kusurlarını kırık, çatlak ve çizik olarak başarılı bir şekilde sınıflandırdığını göstermektedir. Kırık ve çatlak sınıflarındaki tespitler net ve belirgin olup, modelin büyük ve belirgin hasarları doğru şekilde algılayabildiği görülmektedir. Çizik sınıfına ait tespitler daha az sayıda olsa da, modelin çeşitli cam yüzeylerinde farklı kusurları ayırt edebilme yeteneği gözlemlenmektedir. Genel olarak model, farklı ortamlarda ve farklı türde hasar görmüş cam yüzeylerinde başarılı bir nesne tespiti yaparak sınıflandırma kabiliyetini ortaya koymaktadır. YOLOv5 modeliyle gerçekleştirdiğimiz eğitim sonucundaki test görüntülerin güven skorları Şekil 4.3’de gösterilmiştir.



(a)

(b)



(c)

(d)

Şekil 4. 3. YOLOv5 ile yapılan eğitimde elde edilen güven skorları

Görseller, modelin kırık, çatlak ve çizik gibi cam kusurlarını yüksek doğruluk oranlarıyla tespit edebildiğini göstermektedir. Kırık tespitleri genellikle net ve belirgin olup yüksek güven skorlarıyla etiketlenmiştir, bu da modelin büyük hasarları başarılı bir şekilde algıladığını ortaya koymaktadır. Çatlak tespitleri geniş yüzeylerde doğru şekilde belirlenmiş, çeşitli ortamlardaki cam yüzeylerinde güvenilir sonuçlar üretilmiştir. Çizik tespitleri ise daha ince detaylar içerdiğinden diğer kusurlara göre nispeten daha düşük güven skorlarına sahiptir. Modelin cam kusurlarını farklı ışık koşullarında, farklı açılarda ve çeşitli yüzeylerde başarılı bir şekilde tanımlayabildiği gözlemlenmektedir.

4.2. YOLOv8 Eğitim Sonuçları


YOLOv8 modeli ile elde edilen sonuçların sınıf bazında performans metrikleri Tablo 4.2’de verilmiştir. Tüm sınıflar için hesaplanan mAP puanı değeri %30.89 olarak elde edilmiştir. En yüksek mAP puanına sahip sınıfın Kırık sınıfı olduğu görülmüştür. YOLOv8 eğitim sonuçlarının sınıf bazındaki performans metrikleri Çizelge 4.3’de gösterilmiştir.

Çizelge 4. 3. YOLOv8 ile sınıf bazında elde edilen performans metrikleri

Sınıf	Doğruluk(%)	Hassasiyet(%)	Duyarlılık(%)	F1 Skoru(%)	mAP50(%)
Kırık	46.00	55.00	56.00	50.5	46.00
Çatlak	47.50	50.00	51.00	48.500	47.50
Çizik	12.10	20.00	19.00	14.49	12.10
Genel Ortalama	35.19	41.66	42.00	37.83	35.19

YOLOv8 modeli ile gerçekleştirilen deneylerde modelin genel olarak başarılı tespitler yapabildiği ve sınıflar arasında değişkenlik gösteren bir performans sergilediği görülmektedir. Doğruluk, hassasiyet ve duyarlılık gibi temel metrikler değerlendirildiğinde, modelin tespit yeteneğinin belirli koşullarda daha yüksek olduğu, genel ortalama değerlere bakıldığında ise sınıflandırma performansının dengeli bir seviyede olduğu anlaşılmaktadır. F1 skorları ve mAP50 değerleri modelin genel nesne tanıma kabiliyetini ortaya koyarken, hassasiyet ve duyarlılık metrikleri bazı sınıflarda daha güçlü bir tespit yapıldığını göstermektedir. Sonuçlar, modelin genel anlamda nesne tanıma ve sınıflandırma görevlerinde başarılı bir performans sunduğunu göstermektedir.

YOLOv8 model eğitiminin ilerlemesinde elde edilen sonuçlar Şekil 4.4’de gösterilmiştir.



Şekil 4. 4. YOLOv8 modelinin performans metrik grafikleri

Elde edilen eğitim süreci grafikleri, YOLO modelinin başarılı bir şekilde öğrenme gerçekleştirdiğini göstermektedir. Train/box_loss, train/cls_loss ve train/dfl_loss değerlerinin düzenli olarak azalması, modelin eğitim verisine etkin bir şekilde uyum sağladığını kanıtlamaktadır. Val/box_loss, val/cls_loss ve val/dfl_loss değerlerinde başlangıçta düşüş görülmekte, ancak ilerleyen aşamalarda dalgalanmalar meydana gelmektedir. Metrics/precision(B) ve metrics/recall(B) metrikleri zamanla artış göstermekte ancak belirli seviyelerde dalgalanmalar içermektedir. Metrics/mAP50(B) ve metrics/mAP50-95(B) değerleri artış eğiliminde olup modelin nesne tespit performansının geliştiğini ortaya koymaktadır. Eğitim süreci genel olarak başarılıdır, ancak doğrulama kayıplarındaki dalgalanmalar modelin genelleme performansında değişkenlik gösterdiğini işaret etmektedir.


YOLOv8 modeli ile test kümesindeki görüntü verileri test edilmiştir. Cam kusurlarının tespit edildiği örnek görüntüler Şekil 4.5’de gösterilmiştir.



Şekil 4. 5. YOLOv8 modeli eğitim sonucunda elde edilen görüntüler

YOLOv8 modeli ile gerçekleştirilen cam kusurlarının tespiti çalışmasında elde edilen doğrulama çıktıları, modelin kırık ve çatlak sınıflarını yüksek doğrulukla tespit edebildiğini göstermektedir. Görsellerde farklı perspektifler, ışıklandırmalar ve ortam koşullarına rağmen modelin cam yüzeylerindeki kusurları belirleyebilmesi, genel tespit başarısının güçlü olduğunu ortaya koymaktadır. Özellikle büyük kırık ve belirgin çatlakların doğru şekilde işaretlenmesi, modelin bu tür kusurları ayırt etme kabiliyetini göstermektedir. Çeşitli cam yüzeylerinde, pencere camları, araç camları ve aynalar gibi farklı alanlarda yapılan tespitler, modelin geniş bir uygulama alanına sahip olduğunu kanıtlamaktadır. Genel olarak, YOLOv8 modeli cam kusurlarının tespiti konusunda başarılı bir performans sergilemiş ve nesne tespitinde güvenilir bir çözüm sunduğunu

ortaya koymuştur. YOLOv8 modeliyle gerçekleştirdiğimiz eğitim sonucundaki test görüntülerin güven skorları Şekil 4.6'da gösterilmiştir.



Şekil 4. 6. YOLOv8 modeli eğitim sonucunda elde edilen güven skorları

YOLOv8 modeli ile gerçekleştirilen eğitim sonucunda elde edilen bu doğrulama çıktıları, modelin cam kusurlarını başarılı bir şekilde tespit ettiğini göstermektedir. Görsellerde "Kırık", "Çatlak" ve "Çizik" sınıflarına ait nesnelerin belirgin şekilde işaretlendiği görülmektedir. Model, kırık ve çatlakları tespit etmede yüksek güven seviyeleriyle çalışırken, çizik sınıfına ait tespitlerin daha sınırlı olduğu gözlemlenmiştir. Özellikle büyük ve belirgin kırıklar yüksek doğrulukla işaretlenmiş olup, farklı ortam

koşulları, ışıklandırma ve açı değişimlerine rağmen modelin güçlü bir tespit kapasitesi sunduğu anlaşılmaktadır. Cam yüzeylerin farklı türleri, araç camları, pencere camları ve aynalar üzerinde yapılan tahminler modelin geniş bir uygulama alanına sahip olduğunu göstermektedir. Doğrulama çıktılarındaki güven skorlarının genellikle yüksek olması, modelin güvenilir tahminler yaptığını desteklemektedir.

Genel olarak, YOLOv8 modeli cam kusurlarının tespitinde başarılı bir performans sergilemiş olup, modelin doğruluk oranlarının yüksek olduğu ve çeşitli cam yüzeylerindeki kusurları ayırt edebildiği gözlemlenmiştir. Modelin sunduğu bu tespit yeteneği, cam yüzeylerinin kalite kontrolü ve hasar analizi gibi endüstriyel uygulamalarda etkili bir çözüm olabileceğini göstermektedir.

4.3. YOLO11 Eğitim Sonuçları

YOLO11 modeli ile elde edilen sonuçların sınıf bazında performans metrikleri Tablo 4.2’de verilmiştir. Tüm sınıflar için hesaplanan mAP puanı değeri %30.89 olarak elde edilmiştir. En yüksek mAP puanına sahip sınıfın Kırık sınıfı olduğu görülmüştür. YOLO11 eğitim sonuçlarının sınıf bazındaki performans metrikleri Çizelge 4.4’de gösterilmiştir.


Çizelge 4. 4. YOLO11 ile sınıf bazında elde edilen performans metrikleri

Sınıf	Doğruluk(%)	Hassasiyet(%)	Duyarlılık(%)	F1 Skoru(%)	mAP50(%)
Kırık	40.00	59.80	55.00	57.30	49.30
Çatlak	50.00	46.90	53.10	49.80	44.60
Çizik	74.00	21.20	9.00	12.40	9.10
Genel Ortalama	54.70	42.600	39.00	39.80	34.30

YOLO11 modeli ile gerçekleştirilen deneylerde, modelin genel doğruluk ve mAP50 değerleri açısından başarılı bir tespit performansı sunduğu görülmektedir. Doğruluk ve hassasiyet metrikleri değerlendirildiğinde, modelin belirli sınıflarda daha yüksek tespit oranlarına ulaştığı gözlemlenirken, duyarlılık ve F1 skoru açısından farklılıklar mevcuttur. Genel ortalama değerlere bakıldığında, modelin nesne tespit ve sınıflandırma görevlerinde dengeli bir performans sergilediği anlaşılmaktadır. F1 skoru

ve hassasiyet değerleri modelin genel tanıma kapasitesini ortaya koyarken, duyarlılık metrikleri modelin tahmin gücünün sınıf bazında değişiklik gösterebildiğini göstermektedir. Sonuçlar, modelin farklı senaryolarda etkili bir tespit yeteneğine sahip olduğunu ortaya koymaktadır.

YOLO11 model eğitiminin ilerlemesinde elde edilen sonuçlar Şekil 4.7’de gösterilmiştir.



Şekil 4. 7. YOLO11 modelinin performans metrik grafikleri

YOLO11 modelinin eğitim sürecinde train loss değerleri (box_loss, cls_loss, dfl_loss) istikrarlı bir şekilde azalmış ve modelin başarılı bir şekilde öğrenme gerçekleştirdiği gözlemlenmiştir. Doğrulama kayıpları başlangıçta hızlı bir düşüş göstermiş, belirli bir iterasyondan sonra stabil bir seviyeye ulaşmıştır. Precision ve recall metrikleri, modelin nesne tespitinde etkili sonuçlar ürettiğini ve doğruluk oranının eğitim süreci boyunca iyileştiğini ortaya koymaktadır. mAP@0.5 metriği, modelin doğrulama setinde yüksek IoU eşiklerinde başarılı tahminler yapabildiğini göstermektedir. mAP@0.5:0.95 metriği de belirli bir seviyeye ulaşmış istikrar kazanmıştır, bu da modelin farklı ölçeklerdeki nesneleri tespit etme yeteneğinin geliştiğini göstermektedir. Genel

olarak YOLO11 modeli, öğrenme sürecini verimli bir şekilde tamamlamış ve nesne tespiti görevinde başarılı sonuçlar elde etmiştir.


YOLO11 modeli ile test kümesindeki görüntü verileri test edilmiştir. Cam kusurlarının tespit edildiği örnek görüntüler Şekil 4.8’de gösterilmiştir.



Şekil 4. 8. YOLO11 modeli eğitim sonucunda elde edilen görüntüler

YOLO11 modeli ile gerçekleştirilen eğitim sonucunda elde edilen görsel, modelin cam kusurlarını (kırık, çatlak, çizik) başarılı bir şekilde tespit ettiğini göstermektedir. Model, farklı açılardan, çeşitli ışık koşullarında ve değişen nesne yüzeylerinde cam kusurlarını doğru şekilde sınıflandırarak etiketleme yapmıştır. "Kırık" (Kırık) sınıfı, büyük yapısal bozulmalar içeren cam yüzeylerde doğru şekilde belirlenmiş, "Çatlak" (Çatlak) ve "Çizik" (Çizik) sınıfları ise daha küçük ölçekli deformasyonları temsil edecek şekilde etiketlenmiştir. Modelin geniş bir veri çeşitliliğinde yüksek doğrulukla nesne

tespiti yaptığı ve etiketlerin konumlandırılmasının başarılı olduğu görülmektedir. Bu sonuçlar, YOLO11'in cam kusurlarının otomatik tespiti konusunda güçlü bir performans sergilediğini ve veri kümesi üzerinde etkili bir şekilde öğrenme gerçekleştirdiğini ortaya koymaktadır. YOLO11 modeliyle gerçekleştirdiğimiz eğitim sonucundaki test görüntülerin güven skorları Şekil 4.9'da gösterilmiştir.



Şekil 4. 9. YOLO11 modeli eğitim sonucunda elde edilen güven skorları

YOLO11 modeliyle gerçekleştirilen eğitim sonucunda, kırık ve çatlak tespitinde yüksek doğruluk oranlarına ulaşılmıştır. Kırık sınıfında %82-95, çatlak sınıfında ise %65-92 güven skorları elde edilmiş ve modelin bu kategorilerde başarılı tahminler yaptığı

gözlemlenmiştir. Çizik sınıfında güven skorları %26-49 aralığında kalmış ve modelin bu kategoride daha düşük bir ayırt ediciliğe sahip olduğu belirlenmiştir. Genel olarak, YOLO11 modeli kırık ve çatlak tespitinde yüksek performans sergilerken, çizik tespitinde daha sınırlı bir başarı göstermektedir.

4.4. Modellerin Karşılaştırmalı Sonuçları

Bu tez çalışmasında elimizdeki veriler YOLOv5, YOLOv8, YOLO11 modellerine göre eğitim sürecinden geçirilmiştir. Elde ettiğimiz sonuçlar Çizelge 4.5’de gösterilmiştir.

Çizelge 4. 5. YOLO Modellerinin Karşılaştırılması

Sınıf	Doğruluk(%)	Hassasiyet(%)	Duyarlılık(%)	F1 Skoru(%)	mAP50(%)
YOLOv5	38.00	31.73	38.60	26.30	34.29
YOLOv8	35.19	41.66	42.00	37.83	35.19
YOLO11	54.70	42.60	39.00	39.80	34.30

Tablo 4.4’te verilen verilere göre, YOLOv5, YOLOv8 ve YOLO11 modellerinin genel ortalama performansları detaylı bir şekilde karşılaştırılmıştır. Sonuçlar, her modelin farklı metriklerde değişen seviyelerde başarı gösterdiğini ve belirli alanlarda öne çıktığını ortaya koymaktadır. Genel doğruluk açısından değerlendirildiğinde, YOLO11 modeli %54.7 doğruluk ile en yüksek başarıyı sağlarken, YOLOv8 %35.19 ve YOLOv5 %38 doğruluk değerleriyle daha düşük bir performans göstermiştir. Bu sonuç, YOLO11 modelinin diğer modellere kıyasla nesneleri daha doğru şekilde tespit edebildiğini göstermektedir.

Hassasiyet (precision) metriği incelendiğinde, YOLOv8 %41.66 ile en yüksek değere ulaşırken, YOLO11 %42.6 ve YOLOv5 %31.73 ile daha düşük seviyelerde kalmıştır. Bu durum, YOLOv8’in yanlış pozitif oranını minimize etmede daha başarılı olduğunu ve modelin özellikle yanlış alarm üretme konusunda daha güvenilir olduğunu göstermektedir. Duyarlılık (recall) açısından ise YOLOv8 %42 ile en yüksek değere ulaşmış, YOLO11 %39 ve YOLOv5 %38.6 ile daha düşük değerler sunmuştur. Bu, YOLOv8’in nesneleri kaçırma oranının diğer modellere kıyasla daha düşük olduğunu ve modelin tespit edilebilir nesneleri daha yüksek oranda yakalayabildiğini göstermektedir.

F1 skoru incelendiğinde, YOLO11 %39.8 ile en yüksek değeri sunarken, YOLOv8 %37.83 ile yakın bir performans sergilemiş, YOLOv5 ise %26.3 ile en düşük değere sahip olmuştur. F1 skoru, hassasiyet ve duyarlılığı dengeli bir şekilde değerlendirdiğinden, YOLO11 modelinin hem yanlış pozitifleri hem de yanlış negatifleri optimize etmede daha başarılı olduğu söylenebilir. mAP50 değerleri açısından YOLO11 modeli %34.3, YOLOv8 modeli %35.19 ve YOLOv5 modeli %34.29 değerleri elde etmiştir. YOLOv8, diğer modellere kıyasla bu metriğe göre hafif bir avantaj sağlamış olsa da üç model arasında büyük bir fark olmadığı görülmektedir.

Genel olarak değerlendirildiğinde, YOLO11 modeli doğruluk, F1 skoru ve mAP50 açısından en başarılı model olarak öne çıkarken, YOLOv8 modeli hassasiyet ve duyarlılık açısından daha iyi sonuçlar vermiştir. YOLOv5 ise tüm metriklerde en düşük değerlere sahip olup, genel tespit performansı diğer modellere kıyasla daha zayıf kalmıştır. Bu sonuçlar, YOLO11 modelinin daha dengeli ve başarılı bir performans sunduğunu ve genel nesne tespit görevleri için daha uygun bir model olduğunu göstermektedir. Ancak, hassasiyet ve duyarlılık gibi belirli metriklerin ön planda olduğu uygulamalarda YOLOv8'in tercih edilmesi, yanlış pozitif ve negatif oranlarını optimize etmek açısından avantaj sağlayabilir. YOLOv5 modeli ise daha fazla iyileştirme gerektiren bir performans sergilemiş olup, özellikle düşük F1 skoru nedeniyle diğer iki modele kıyasla daha az tercih edilebilir bir seçenek olarak değerlendirilebilir. Model seçimi yapılırken spesifik uygulama gereksinimleri göz önünde bulundurulmalıdır. Eğer genel doğruluk ve F1 skoru kritikse, YOLO11 modelinin daha verimli olduğu söylenebilir. Ancak, yanlış pozitif oranının düşük tutulması gereken durumlarda YOLOv8 modeli daha iyi bir seçenek olarak değerlendirilebilir.

4.5. Literatürdeki Çalışmalarla Karşılaştırma

Bu tez kapsamında oluşturulan veri seti ve geliştirilen derin öğrenme tabanlı nesne tespiti modelleri, literatürdeki benzer çalışmalara kıyasla hem teknik hem de uygulama düzeyi açısından önemli farklılıklar ve avantajlar sunmaktadır. Bu tez çalışması konusu ile ilgili olarak kısıtlı sayıda literatürde çalışma bulunmaktadır. Tablo 4.6'da literatürdeki benzer çalışmaların başarımlar, performans metrikleri ve sonuçları ile ilgili olarak hazırlanmış olan karşılaştırma çizelgesi görülmektedir.

Çizelge 4. 6. Literatürdeki Çalışmaların Karşılaştırması

Çalışma	YOLO Sürümü	Görsel Sayısı	Sınıf Sayısı	Etiket Formatı	En Başarılı Model	Doğruluk (%)	F1 Skoru (%)	mAP50 (%)
Yıldız, 2021	(SVM + görüntü işleme)	1500	2	Sınıf (bbox yok)	SVM	93.0	92.1	-
Koca, 2023	YOLOv4	6000	2	YOLO (bbox + sınıf)	YOLOv4	90.5	87.1	88.64
Dağdelen, 2022	YOLOv3 / v4	3000	3	YOLO (bbox + sınıf)	YOLOv4	88.2	86.4	87.9
Bu Tez (2025)	YOLOv5 / v8 / v11	4975	4	YOLO (bbox + sınıf)	YOLOv11	54.7	39.8	34.3

Tablo 4.6 incelendiğinde, Yıldız (2021) tarafından yapılan çalışmada, cam yüzeylerindeki kusurların tespiti geleneksel görüntü işleme teknikleri ve destek vektör makineleri (SVM) kullanılarak gerçekleştirilmiştir. Söz konusu çalışmada sınıflandırma yalnızca “kusurlu” ve “kusursuz” olmak üzere iki kategoriye ayrılmış, nesne konumlandırması (bounding box) gibi detaylı analizlere yer verilmemiştir. Ayrıca, kullanılan veri seti 1500 görüntü ile sınırlı kalmış ve sınıflandırma problemi üzerinden ilenmiştir (Yıldız, 2021). Buna karşılık, bu tez çalışmasında kullanılan veri seti toplamda 4975 görüntü içermekte olup, kusurlar “kırık”, “çatlak”, “çizik” ve “sağlam” olmak üzere dört farklı sınıfta etiketlenmiş; bu etiketleme YOLO formatında konum bilgisiyle birlikte yapılmıştır. Böylelikle sadece kusurun varlığı değil, görüntü üzerindeki konumu da belirlenebilmiştir. Ayrıca YOLOv5, YOLOv8 ve en güncel sürümlerden biri olan YOLO11 mimarileri ile model eğitimi gerçekleştirilmiş ve performans karşılaştırmaları yapılmıştır. Literatürdeki birçok çalışmada yalnızca sınıflandırma yapılırken, bu tezde detaylı nesne tespiti gerçekleştirilerek daha gelişmiş bir kalite kontrol yaklaşımı sunulmuştur. Bu yönüyle tez çalışması, hem veri setinin büyüklüğü hem de modelleme düzeyi açısından literatüre önemli bir katkı sağlamaktadır. Özellikle, gerçek zamanlı uygulamalara uygunluğu ve son kullanıcıya yönelik kusur tespiti yapabilmesi açısından özgün ve güncel bir çözüm sunmaktadır. Bir diğer benzer tez çalışması, Koca (2023) tarafından gerçekleştirilmiş ve cam yüzey kusurlarının tespiti amacıyla YOLOv4 mimarisi kullanılmıştır. Söz konusu çalışmada toplamda 6000 görüntü kullanılmış ve görüntüler sadece iki sınıfa (kusurlu ve kusursuz) ayrılmıştır. Eğitim sonucunda %90’ın

üzerinde doğruluk, %88.64 mAP50 ve %87.1 F1 skoru gibi oldukça yüksek performans metrikleri elde edilmiştir. Ancak bu başarı, sınıfların azlığı ve modelin sadece nesne varlığını sınıflandırmaya yönelik çalışmasından kaynaklanmaktadır (Koca, 2023). Bu tezde ise 4975 görüntüden oluşan bir veri seti kullanılmış; kusurlar "kırık", "çatlak", "çizik" ve "sağlam" olmak üzere dört farklı sınıfa ayrılmıştır. Her bir nesne, konum bilgisiyle birlikte YOLO formatında etiketlenmiştir. Bu durum modeli hem sınıflandırma hem de tespit açısından daha karmaşık bir problemle karşı karşıya bırakmıştır. Bu nedenle başarı metrikleri literatürdeki çalışmalardan daha düşük gözükse de, modelin çözmeye çalıştığı problem daha ayrıntılı ve uygulama bakımından daha gerçekçidir. Özellikle son kullanıcıya yönelik kalite kontrol süreçlerinde uygulanabilir olması, bu çalışmayı literatürdeki benzerlerinden ayıran önemli bir unsur haline getirmektedir Dağdelen (2022) tarafından gerçekleştirilen bir başka tez çalışmasında, cam yüzey kusurlarının tespiti amacıyla YOLOv3 ve YOLOv4 mimarileri kullanılmış ve toplamda 3000 görüntüden oluşan bir veri setiyle model eğitimi yapılmıştır. Kusurlar "kırık", "çizik" ve "kir" olmak üzere üç kategoriye ayrılmış ve modelin performansı %88.2 doğruluk ve %87.9 mAP50 değerine ulaşmıştır. Ancak sınıf sayısının azlığı ve veri setinin endüstriyel ortamlarda çekilmiş olması, modelin daha homojen bir veri üzerinde çalışmasını sağlamıştır. Bu tez çalışmasında ise daha karmaşık ve detaylı bir veri seti kullanılmış; kusurlar dört farklı kategoriye ayrılmış ve her bir nesne, sınıf ve konum bilgisiyle etiketlenmiştir. YOLOv5, YOLOv8 ve YOLOv11 gibi farklı mimariler kullanılarak performans değerlendirmesi yapılmış, özellikle YOLOv11 modelinde %34.3 mAP50 ve %39.8 F1 skoru elde edilmiştir. Bu sayede gerçek zamanlı uygulamalara daha uygun bir yapı ortaya konmuş ve kullanıcı odaklı kusur tespiti süreci geliştirilmiştir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada, bilgisayarlı görü ve yapay zekâ teknikleri kullanılarak cam kusurlarının tespiti üzerine bir analiz gerçekleştirilmiştir. Çalışmada YOLO ailesine ait üç farklı model olan YOLOv5, YOLOv8 ve YOLO11 değerlendirilmiş ve bu modellerin cam kusurlarını tespit etme konusundaki performansları karşılaştırılmıştır. YOLO modelleri, nesne tespiti ve görüntü segmentasyonu alanlarında son teknoloji çözümler sunarak, endüstriyel kalite kontrol uygulamalarında yaygın olarak kullanılmaktadır. Elde edilen bulgular, YOLO11 modelinin doğruluk, hassasiyet ve F1 skoru açısından diğer modellere kıyasla daha yüksek performans sergilediğini göstermektedir. Modelin eğitimin erken aşamalarında daha hızlı yakınsaması, daha az iterasyon ile daha iyi sonuçlar elde edilebileceğini ortaya koymaktadır. Bu durum, YOLO11'in eğitim sürecine daha verimli bir şekilde adapte olabildiğini ve kısa sürede yüksek başarı elde edebildiğini göstermektedir. Tespit kalitesinin öncelikli olduğu uygulamalar için YOLO11 modeli en uygun seçenek olarak öne çıkmaktadır. Bununla birlikte, model seçiminde yalnızca doğruluk ve hassasiyet gibi metrikler değil, aynı zamanda çıkarım hızı, hesaplama verimliliği ve donanım gereksinimleri gibi faktörler de göz önünde bulundurulmalıdır. YOLOv5 ve YOLOv8 modelleri, geniş uygulama alanları ve hesaplama açısından daha dengeli çözümler sunmaları nedeniyle belirli senaryolarda avantaj sağlayabilir.

Her üç modelin de cam kusurlarının tespitinde etkili bir şekilde çalıştığı gözlemlenmiştir. Ancak, elde edilen bulgular doğrultusunda, YOLO11'in sağladığı yüksek performans ve verimlilik, bu modeli cam kusurlarının tespitine yönelik uygulamalarda daha tercih edilebilir hale getirmektedir. Özellikle endüstriyel kalite kontrol süreçlerinde yüksek doğruluk oranlarına duyulan gereksinim göz önünde bulundurulduğunda, YOLO11 modeli güçlü bir alternatif olarak öne çıkmaktadır. Bu çalışmanın sonuçları, YOLO mimarilerinin cam kusurlarının tespitinde başarılı bir şekilde uygulanabileceğini ve farklı nesne tespiti problemlerine adapte edilebileceğini ortaya koymaktadır. Literatürde, YOLO modellerinin çeşitli veri setleri üzerinde başarılı sonuçlar verdiğine dair çalışmalar bulunmaktadır. Gelecekteki araştırmalarda, daha geniş kapsamlı ve çeşitli bir veri seti ile model performansının artırılması ve farklı derin öğrenme teknikleriyle hibrit yaklaşımlar geliştirilmesi planlanmaktadır. YOLO mimarilerinin sürekli olarak gelişmesi, ilerleyen çalışmaların daha yüksek doğruluk ve daha düşük işlem süresi ile gerçekleştirilebileceğini göstermektedir.

KAYNAKLAR

- Adamo, F., Attivissimo, F. ve Di Nisio, A., (2010). Calibration of an inspection system for online quality control of satin glass. *IEEE Transactions on Instrumentation and Measurement*, 59, 5, 1035-1046.
- Akdemir, B. ve Öztürk S., (2015). Glass surface defects detection with wavelet transforms, *International Journal of Materials, Mechanics and Manufacturing*, 3, 3, 170-173.
- Aladağ, Ç. H. (2009). *Yapay sinir ağlarının mimari seçimi için tabu arama algoritması*. Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, Türkiye.
- Al-Masri, A. N., Ab Kadir, M. Z. A., Hizam, H., Mariun, N. (2015). *Simulation of an adaptive artificial neural network for power system security enhancement including control action*. *Applied Soft Computing*, 29, 1-11. Electronics Engineering, University Putra Malaysia, Malaysia.
- Anonim. (2023). *Yapay zekâ ve alt alanları hiyerarşisi gösterimi*, Erişim adresi: <https://www.datarobot.com/wiki/artificial-intelligence/>
- Arslan, O. (2023). Bir fotogrametrik bilgisayarlı görü tekniği olarak İHA fotogrametrisi. *Türkiye İnsansız Hava Araçları Dergisi*, 5(2), 59-71.
- Atalay, M., Çelik, E. (2017). *Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis*. Kırklareli Üniversitesi, Türkiye.
- Aytekin, B. (2020). Bilgisayarlı görü temelli araç belirleme ve takibi. *Yayımlanmamış çalışma*.
- Ballard, D. H., & Brown, C. M. (1982). *Computer vision*. Prentice Hall Professional Technical Reference.
- Blehm, C., Vishnu, S., Khattak, A., Mitra, S., & Yee, R. W. (2005). Computer vision syndrome: A review. *Survey of Ophthalmology*, 50(3), 253-262. <https://doi.org/10.1016/j.survophthal.2005.02.008>
- Bozkurt, F., & Yağanoğlu, M. (2021). Derin evrişimli sinir ağları kullanarak akciğer X-Ray görüntülerinden COVID-19 tespiti. *Veri Bilimi*, 4(2), 1-8.
- Bölük, N., Uçar, Ö., & Inner, A. B. (2019). Mobil Robotlarda Navigasyon Problemi için Pekiştirmeli Öğrenme. *Türkiye Robotbilim Konferansı*, 40-44.
- Buch, N., Velastin, S. A., & Orwell, J. (2011). A review of computer vision techniques for the analysis of urban traffic. *IEEE Transactions on intelligent transportation systems*, 12(3), 920-939.
- Bulut, F. (2016). Çok katmanlı algılayıcılar ile doğru meslek tercihi. *Anadolu University Journal Of Science And Technology A-Applied Sciences And Engineering*, 17(1), 97-109.
- Bulut, F., Amasyalı, M. F., Sönmez, A. C. (2014). *Uzman kararlarının yeni bir geçiş fonksiyonuyla birleştirmesi. akıllı sistemlerde yenilikler ve uygulamaları*. Bilgisayar Mühendisliği Bölümü Elektrik-Elektronik Fakültesi Yıldız Teknik Üniversitesi, Davutpaşa, İstanbul, Türkiye.

- Bükücü, C. ve Görkem, L., (2020). Cam ürünlerde gerçek zamanlı hata tespiti gerçekleştiren yeni bir prototip, *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 12, 2, 510-519.
- Büyükarıkan, B., & Üncü, İ. S. (2019). Bilgisayarlı görü sistemleri için sistem tasarımı ve kontrolü. *Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi*, 7(1), 228-240. <https://doi.org/10.15317/Scitech.2019.213>
- Cadzow, J. A. (2002). *Minimum ℓ_1 , ℓ_2 , and ℓ_∞ norm approximate solutions to an overdetermined system of linear equations*. Digital Signal Processing, Elektrik ve Bilgisayar Mühendisliği Bölümü, Vanderbilt Üniversitesi, Nashville, Tennessee, ABD.
- Costa, C., Murphy, M. (2015). *Bourdieu, habitus and social research: The art of application*. Springer: Lecturer in Tecnology Enhanced Learning, Universty of strathclyde, UK.
- Cyganek, B., & Siebert, J. P. (2011). *An introduction to 3D computer vision techniques and algorithms*. John Wiley & Sons.
- Dalgın, L. (2023). Çilek meyvesi gelişiminin derin öğrenme metotlarıyla karşılaştırmalı incelenmesi, Yüksek Lisans Tezi, Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü.
- Dawson, J. (2007). *The essential turing: seminal writings in computing, logic, philosophy, artificial intelligence, and artificial life plus the secrets of enigma*, Clarendon Press, Oxford University Press, New York.
- Dersuneli, M., Gündüz, T., & Kutlu, Y. (2021). Bul-Tak Oyunağı Şekillerinin Klasik Görüntü İşleme ve Derin Öğrenme Yöntemleri ile Tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 10(4), 1290-1303.
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Eiben, A., Smit, SK (2011). Parameter setting for configuring and analyzing evolutionary algorithms. Herd and Evolutionary Computing, Deparment of Computer Science Doctorate, Vrije Universty, Amsterdam.
- Elmas, B. (2021). Evrişimli Sinir Ağları ile Mantar Görüntülerinden Mantar Türlerinin Transfer Öğrenme Yöntemiyle Tanımlanması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25(1), 74-88.
- Fezani, F. Ve Rahmani, A., (2006). Wavelets analysis for defects detection in flat glass, In Proceedings of the IEEE Multiconference on, *Computational Engineering in Systems Applications*, 1109, 10, 132-139.
- Forsyth, D. A., & Ponce, J. (2002). *Computer vision: A modern approach*. Prentice Hall Professional Technical Reference.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202. <https://doi.org/10.1007/BF00344251>
- Ganioglu, B., Aktepe, A., Ersöz, S., & Tebrizcik, S. (2024). Denetimsiz Öğrenme İle E-Ticaret Sektöründe Faaliyet Gösteren Bir İşletmede Müşteri Segment Analizi Ve

- Uygulaması. *International Journal of Engineering Research and Development*, 16(2), 880-894.
- Golik, P., Doetsch, P., Ney, H. (2013). Cross-entropy vs. squared error training: a theoretical and experimental comparison. In *Interspeech, Computer Science Department*, RWTH Aachen University, Aachen, Germany.
- Gurney, K. (1997). *An introduction to neural networks*. CRC press: Profesör, 90 Bilişim, Bilgi İşlem ve Siber Sistemler Okulu, Kuzey Arizona Üniversitesi Londra.
- Güçlü, E., Aydın, T. K., & Akın, E. (2022). Çelik yüzeylerdeki kusurların tespiti için derin öğrenme tabanlı gömülü sistem tasarımı [Deep learning-based embedded system design for detection of defects on steel surfaces]. *EMO Bilimsel Dergi*, 12(2), 28-35. <https://dergipark.org.tr/en/download/article-file/2676819>
- Han, K., Öztürk, G., & Aslan, A. (2023). Yapay Sinir Ağları Kullanarak Yüzey Pürüzlülüğü Tespiti. In *1st International Conference On Pioneer And Innovative Studies Icpis*.
- Harman, G. (2021). Destek vektör makineleri ve naive bayes sınıflandırma algoritmalarını kullanarak diabetes mellitus tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 7-13. Doi:10.31590/ejosat.1041186
- Hazır, E. (2021). *Denetimli ve denetimsiz öğrenme*. Enstitüsü, Yüksek Lisans Tez, Adana. Erişim adresi: <https://eneshazr.medium.com/supervised-unsupervised-learning-makine-%C3%B6%C4%9Frenmesi-b903bc09430e>
- Ikeuchi, K. (Ed.). (2021). *Computer vision: A reference guide*. Cham: Springer International Publishing.
- Imbert, G., 1989. Automatic inspection systems for the flat glass industry, *In Conference Record of the IEEE Industry Applications Society Annual Meeting*, 1370-1374.
- Işık, Y., Ünay, M., & Kayabaşı, A. (2022). Bilgisayarlı görü teknikleri kullanılarak yapay zeka temelli limon ağacı rekolte tahmini. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 80-88.
- Işık, Y., Ünay, M., & Kayabaşı, A. (2022). Bilgisayarlı görü teknikleri kullanılarak yapay zeka temelli limon ağacı rekolte tahmini. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 80-88. <https://doi.org/10.35239/msrt.1045125>
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- İslamoğlu, E. (2015). Aralık değerli zaman serilerinde kullanılan modelleme teknikleri. *Erzincan University Journal of Science and Technology*, 8(2), 178- 193. Doi: 10.18185/eufbed.04685
- İyigün, C. (2013). Olasılıklı Uzaklık Kümeleme Metodunun Geliştirilmesi Ve Uygulamaları.
- Kabalıcı, E. (2014). *Yapay sinir ağları. Ders notları*, Erişim adresi: <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>
- Karakaya, S. (2021). Türkiye'deki ıllerin göç göstergelerinin python kullanılarak k-ortalamlar kümeleme yöntemi ile araştırılması, Doctoral dissertation, Bursa Uludag University, Turkey.

- Kaya, Ö. (2016). *Düz cam üretiminde temper parametrelerin düzlemselliğe etkisinin araştırılması* (Master's thesis, Fen Bilimleri Enstitüsü).
- Keser, B. Y. (2010). Kaliteli Cam Üretiminde Küçük Boyutlu Silis Kumu Kullanımının Araştırılması.
- Keskenler, M. F., & Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Kılıç, A. C. (1995). *Cam üretiminde üfleme yöntemiyle biçimlendirme* (Master's thesis, Dokuz Eylül Üniversitesi (Turkey)).
- Kırat, S. S., & Aydın, İ. (2023). Açıklanabilir Yapay Zekâ Tabanlı Denetimsiz Öğrenme ile Ray Kusur Tespiti. *Demiryolu Mühendisliği*, (18), 1-13. <https://doi.org/10.47072/demiryolu.1231751>
- Kırat, S. S., & Aydın, İ. (2023). Açıklanabilir yapay zekâ tabanlı denetimsiz öğrenme ile ray kusur tespiti. *Demiryolu Mühendisliği*, (18), 1-13.
- Kızılboğa, A. Y. (2021). *Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak elma ve ayvada çeşitli hastalıkların tespit edilmesi*, Master's thesis, Fen Bilimleri Enstitüsü/Bilgisayar Mühendisliği Ana Bilim Dalı. Gelişim Üniversitesi, İstanbul.
- Klette, R., Koschan, A., Schluns, K., & Achluns, K. (1998). *Computer vision* (p. 190). Springer-Verlag.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- Kuşkapan, E., Çodur, M. K., & Çodur, M. Y. (2022). Türkiye'deki Demiryolu Enerji Tüketiminin Yapay Sinir Ağları İle Tahmin Edilmesi. *Konya Journal of Engineering Sciences*, 10(1), 72-84.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- LeVeau, B. F. (2014). İnsan hareketinde biyomekanik, sağlık profesyonelleri için temeller ve ilerisi (çev. ed. Yakut, Y.). Ankara: Pelikan Yayıncılık.
- Liang, Q., Xiang, S., Long, J., Sun, W., Wang, Y. ve Zhang, D., (2019). *Real-time comprehensive glass container inspection system based on deep learning framework*. *Electronics Letters*, 55, 3, 131-132.
- Ma, H. ve Zhang, B., (2002). Comparison among families of Mutong, Zhongguo Zhong yao za zhi= Zhongguo Zhongyao Zazhi, *China Journal of Chinese Materia Medica*, 27, 6, 412-418.
- Mahadevkar, S. V., Khemani, B., Patil, S., Kotecha, K., Vora, D. R., Abraham, A., & Gabralla, L. A. (2022). A review on machine learning styles in computer vision—techniques and future directions. *Ieee Access*, 10, 107293-107329.
- Meer, P. (2004). Robust techniques for computer vision. *Emerging topics in computer vision*, 107-190.
- Moralı, İ. A., & Aygün, F. F. (2007). Çok Katmanlı Algılayıcı Ve Geriye Yayılım Algoritması İle Konuşmacı Ayırt Etme. *Akademik Bilişim*, 7, 57-62.

- Murat, S. (2021). *İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma*, Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Nalbant, K. G., & Uyanık, Ş. (2021). Computer vision in the metaverse. *Journal of Metaverse*, 1(1), 9-12. <https://doi.org/10.26652/jmv.1.1.2021.9-12>
- Nizam, H., Akın, S. S. (2014). *Sosyal medyada makine öğrenmesi ile duygu analizinde dengeli ve dengesiz veri setlerinin performanslarının karşılaştırılması*. XIX. Türkiye'de İnternet Konferansı, 1(6). İstanbul Üniversitesi, İstanbul.
- Okur, S. (2009). *Parametrik ve parametrik olmayan basit doğrusal regresyon analiz yöntemlerinin karşılaştırmalı olarak incelenmesi*. Yüksek Lisans Tezi, Çukurova Üniversitesi, Adana.
- Onan, A. (2020). Evrişimli sinir ağı mimarilerine dayalı türkçe duygu analizi. *Avrupa Bilim ve Teknoloji Dergisi*, 374-380.
- Oral, O., & Uğuz, S. (2020). Türkiye'deki farklı sektörlerle ait sera gazı emisyon değerlerinin çok katmanlı algılayıcılar ile tahmin edilmesi. *International Journal of Engineering Research and Development*, 12(2), 464-478.
- Ospanov, B., & Demirci, M. F. (2023). Pekiştirmeli Öğrenme ile Tenis Oyunu Simülasyonu Gerçekleştirimi. *Journal of Turkish Operations Management*, 7(2), 1724-1735.
- Öğücü, M. O. (2006). Yapay sinir ağları ile sistem tanıma, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doctoral dissertation. Doi: 504041113
- Öncü, S. (2014). *Bilgisayarlı görü ve ses algılama tekniği ile hareketli nesne takibi* (Master's thesis, Fen Bilimleri Enstitüsü).
- Öztürk, K. (2019). *Endüstriyel cam üretiminde kullanılan CAD/CAM sistemlerinin sanatsal cam üretimine etkileri* (Master's thesis, Marmara Üniversitesi (Turkey)).
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Randolph, S. A. (2017). Computer vision syndrome. *Workplace Health & Safety*, 65(7), 328-328. <https://doi.org/10.1177/2165079916681872>
- Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P., Green, R. (2019). *Artificial intelligence and machine learning in pathology: the present landscape of supervised methods*. *Academic pathology*, 6, 2374289519873088. Department of Pathology and Laboratory Medicine, University of California Davis, 4400 V St, Sacramento, CA 95817, USA.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Riza, S. ve Anton, S. P., (2007). Intelligent visual inspection of bottling production line through Neural Network, *TENCON 2006 IEEE Region 10 Conference*, 1- 4.
- Shanmugamani, R. (2018). *Deep Learning for Computer Vision: Expert techniques to train advanced neural networks using TensorFlow and Keras*. Packt Publishing Ltd.

- Solak, S., & Altınışik, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science*, 22(1), 56-65.
- Stockman, G., & Shapiro, L. G. (2001). *Computer vision*. Prentice Hall PTR.
- Suthaharan, S. (2014). *Big data classification: Problems and challenges in network intrusion prediction with machine learning*. ACM SIGMETRICS Performance Evaluation Review, 41(4), 70-73. Doi: 10.1145/2627534.2627557
- Sutton, R. S., Barto, A. G. (1998). *Introduction to reinforcement learning* (Vol. 135, pp. 223-260). Reinforcement Learning and Artificial Intelligence Laboratory Department of Computing Science University of Alberta, Canada
- Şahin, S., & Harman, G. (2024). Akciğer Röntgen Görüntülerinden Covid-19 ve Zatürre Hastalığının Kuantum Evrişimli Sinir Ağları Yöntemi ile Tahmini. *Karaelmas Fen ve Mühendislik Dergisi*, 14(2), 37-51.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Tecim, V., Aydın, C., Tarhan, Ç., Hakan, A., Komesli, M. (2022). Üniversitelerde akıllı kampüs uygulamaları için altyapı sistemi oluşturulması. *Journal of Research in Business*, 7(IMISC 2021 Special Issue), 132-147. Doi: 10.54452/jrb.1025423
- Ünay, M. (2021). Bilgisayarlı görü teknikleri kullanılarak yapay zekâ temelli limon ağacı rekolte tahmini (*Master's thesis, Karamanoğlu Mehmetbey Üniversitesi*).
- Waslander, S. L., Hoffmann, G. M., Jang, J. S., Tomlin, C. J. (2005). Multi-agent quadrotor testbed control design: Integral sliding mode vs. reinforcement learning. In *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems* (pp. 3712-3717). IEEE. Edmonton, AB, Kanada.
- Wöhler, C. (2009). *3D computer vision: efficient methods and applications*. Springer Science & Business Media.
- Xiaomian L. ve Yufeng S., (2018). Research on glass surface quality inspection based on machine vision, *Australian Journal of Mechanical Engineering*, 16, 1, 98- 104.
- Xu, S., Wang, J., Shou, W., Ngo, T., Sadick, A. M., & Wang, X. (2021). Computer vision techniques in construction: a critical review. *Archives of Computational Methods in Engineering*, 28, 3383-3397
- Yeadon, M. R., & Challis, J. H. (1992). Future directions for performance related research in sports biomechanics. The Sports Council Ancient House Press, Ipswich London.
- Yılancı, A. G. V. (2010). Bulanik kümeleme analizi ile türkiye'deki illerin sosyoekonomik açıdan siniflandırılması. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(3), 453-470.
- Yılmaz, D. Ö. Ü. A., Yayın, K. (2021). *Yapay zeka*. Kodlab Yayın Dağıtım Yazılım, Erişim tarihi: 22. 06. 2022. Erişim Adresi: <https://www.etiya.com/tr/urunler/yapay-zeka-platformu>
- Yukseltürk, E., Ozekes, S. Türel, Y. K. (2014). Predicting dropout student: an application of data mining methods in an online education program. *European Journal of Open, Distance and e-learning*, 17(1), 118-133. Fırat Üniversitesi, Diyarbakır.

- Yüceşahin, M. M., Tuysuz, S. (2011). Ankara kentinde sosyo-mekânsal farklılaşmanın örüntüleri: Ampirik bir analiz. *Coğrafi Bilimler Dergisi*, 9(2), 159-188. Doi: 10.1501/Cogbil_0000000123
- Zeren, M. T. (2023). *Travma sonrası kemik kırıklarının tespitinde bilgisayarlı görüş ve derin öğrenme algoritmaları*, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into deep learning. arXiv preprint arXiv:2106.11342. <https://doi.org/10.48550/arXiv.2106.11342>
- Zhang, H., Guo, Z., Qi, Z. ve Wang, J., (2012). Research of glass defects detection based on DFT and optimal threshold method, *International Conference on Computer Science and Information Processing (IEEE)*, 1044-1047.
- Zhou, L., Zhang, L., & Konz, N. (2022). Computer vision techniques in manufacturing. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(1), 105-117.
- Bishop, C. M. (2006). Pattern recognition and machine learning. Springer.
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202. <https://doi.org/10.1098/rsta.2015.0202>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Jocher, G., Chaurasia, A., Stoken, A., Borovec, J., NanoCode012, Kwon, Y., ... & Ultralytics. (2020). ultralytics/yolov5: v1.0 - First Release [Computer software]. GitHub. <https://github.com/ultralytics/yolov5>
- Ultralytics. (2023). Ultralytics YOLOv8: Cutting-edge object detection, segmentation, and pose estimation models [Computer software]. GitHub. <https://github.com/ultralytics/ultralytics>
- Ultralytics. (2024). *YOLOv11 models: Citations and acknowledgements*. Ultralytics Documentation. Retrieved March 25, 2025, from <https://docs.ultralytics.com/tr/models/yolo11/#citations-and-acknowledgements>
- Roboflow. (n.d.). *Roboflow: Give your software the sense of sight*. Retrieved March 25, 2025, from <https://roboflow.com>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 779–788). <https://doi.org/10.1109/CVPR.2016.91>
- Yıldız, C. (2021). *Görüntü işleme teknikleriyle cam yüzeyindeki kusurların tespiti* (Yüksek lisans tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü).

- Koca, M. E. (2023). *Cam yüzey kusurlarının tespiti için YOLOv4 mimarisi ile derin öğrenme tabanlı bir yaklaşım* (Yüksek lisans tezi, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü). Aksaray Üniversitesi Açık Erişim Sistemi. <https://acikerisim.aksaray.edu.tr/xmlui/handle/20.500.12451/10306>
- Dağdelen, A. (2022). *Derin öğrenme yöntemleri kullanılarak cam yüzeyindeki kusurların tespiti* (Yüksek lisans tezi, Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü). Uludağ Üniversitesi Açık Erişim Sistemi. <https://acikerisim.uludag.edu.tr/handle/11452/26438>

