

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DELİK DELME ESNASINDA MALZEME YÜZEYİNDE OLUŞAN ÇAPAKLARIN
GÖRÜNTÜ İŞLEME İLE İNCELENMESİ VE KESME PARAMETRELERİNİN
OPTİMİZASYONU

Mikail KIRĞIL

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Yüksek Lisans Programı

EKİM 2025

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**DELİK DELME ESNASINDA MALZEME YÜZEYİNDE OLUŞAN ÇAPAKLARIN
GÖRÜNTÜ İŞLEME İLE İNCELENMESİ VE KESME PARAMETRELERİNİN
OPTİMİZASYONU**

Mikail KIRĞIL

DANIŞMAN

Doç. Dr. Ali ERÇETİN

II. DANIŞMAN

Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Yüksek Lisans Programı

EKİM 2025

ONAY

Mikail KIRĞIL tarafından hazırlanan “**Delik Delme Esnasında Malzeme Yüzeyinde Oluşan Çapakların Görüntü İşleme ile İncelenmesi ve Kesme Parametrelerinin Optimizasyonu**” adlı tez çalışması 06/10/2025 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği ile Bandırma Onyedü Eylül Üniversitesi Lisansüstü Eğitim Enstitüsü Mekatronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Doç. Dr. Ali ERÇETİN

(Danışman)

Doç. Dr. Fatih AKKOYUN

(Üye)

Dr. Öğr. Üyesi Oğuzhan DER

(Üye)

İmza

Bu tezin kabulü, Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun .../.../2025 gün ve/.... sayılı kararı ile onaylanmıştır.

Prof. Dr. Serhat DUMAN

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Delik Delme Esnasında Malzeme Yüzeyinde Oluşan Çapakların Görüntü İşleme İle İncelenmesi Ve Kesme Parametrelerinin Optimizasyonu**” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 06/10/2025

Mikail KIRĞIL
İmza

ÖNSÖZ

Sanayide artan üretim hızına ve çeşitliliğine bağlı olarak ürün kalitesinin korunması, maliyetlerin azaltılması ve süreçlerin sürdürülebilir şekilde iyileştirilmesi giderek daha büyük önem taşımaktadır. Özellikle talaşlı imalat süreçlerinde ortaya çıkan çapak oluşumu, ölçüsel doğruluğu bozmakta, yüzey bütünlüğünü olumsuz etkilemekte ve üretim süresini uzatarak verimliliği düşürmektedir. Endüstri 4.0 yaklaşımı ile birlikte üretim hatlarında süreçlerin dijital olarak izlenmesi ve kalite kontrol adımlarının yapay zekâ destekli yöntemlerle güçlendirilmesi kaçınılmaz hale gelmiştir.

Bu tez çalışmasında, AA6013 alüminyum alaşımı üzerinde gerçekleştirilen delme deneylerinden elde edilen mikroskop görüntüleri kullanılarak çapak oluşumunun YOLO tabanlı görüntü işleme ve makine öğrenmesi yöntemleri ile incelenmesi amaçlanmıştır. Çalışma kapsamında farklı veri setleri oluşturulmuş, artırma stratejileri ve karar eşiği ayarları sistematik olarak test edilmiştir. Böylece modelin çapak sınıflarını ayırt etme başarımı değerlendirilmiş, elde edilen sonuçlar üretim süreçlerinde uygulanabilirlik açısından tartışılmıştır.

Bu tez çalışması sırasında, konunun belirlenmesinden sonuçların olgunlaştırılmasına kadar her aşamada bilgi, rehberlik ve desteklerini esirgemeyen değerli danışmanlarım Doç. Dr. Ali ERÇETİN ve Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN'a en içten teşekkürlerimi sunarım. Ayrıca araştırmanın yürütülmesine sağladıkları maddi destek için Bandırma Onyedi Eylül Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne (Proje No: BAP-24-1010-002) teşekkür ederim.

Bugünlere gelmemde en büyük paya sahip olan annem Üveyiş ve babam Sait'e, yoğun akademik süreç boyunca sabır ve destekleriyle yanımda olan tüm aile fertlerime, her koşulda motivasyonumu yüksek tutan ev arkadaşlarıma ve katkılarıyla bana güç veren değerli arkadaşlarım Emin Feyzi ve Ömer'e gönülden teşekkür ederim.

Tezimin, imalat süreçlerinde çapak oluşumunun azaltılmasına ve imalat kalitesinin artırılmasına yönelik akademik literatüre ve uygulamaya katma değer sunması dileğiyle.

ÖZET

YÜKSEK LİSANS TEZİ

DELİK DELME ESNASINDA MALZEME YÜZEYİNDE OLUŞAN ÇAPAKLARIN GÖRÜNTÜ İŞLEME İLE İNCELENMESİ VE KESME PARAMETRELERİNİN OPTİMİZASYONU

Mikail KIRĞIL

Bandırma Onyediy Eylül Üniversitesi

Lisansüstü Eğitim Enstitüsü

Mekatronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ali ERÇETİN

İkinci Danışman: Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN

Ekim 2025, 77 sayfa

Son yıllarda üretim teknolojilerinde kalite ve verimliliğin artırılmasına yönelik çalışmaların hız kazanması, özellikle talaşlı imalat süreçlerinde otomatik hata tespiti ve sınıflandırma yöntemlerinin tercih edilmesine yol açmıştır. Görüntü işleme ve yapay zekâ tabanlı yaklaşımların gelişmesiyle birlikte, klasik çapak ölçüm ve elle kontrol yöntemlerine alternatif olarak düşünülen derin öğrenme modelleri; daha hızlı, daha düşük maliyetli ve daha tekrarlanabilir çözümler sunmaları nedeniyle öne çıkmaktadır.

Bu tez çalışmasında, AA6013 alüminyum alaşımında delik delme işlemleri sonrasında oluşan çapakların, mikroskop görüntülerinden oluşturulan veri kümeleri üzerinde YOLOv10n modeli ile sınıflandırılması amaçlanmıştır. Çalışmada orijinal veri setinin yanı sıra modelin genelleme kabiliyetini artırmak için orijinal veri setine sırasıyla; yatay çevirme (YÇ), 180° döndürme (D180°) ve bunların kombinasyonları olan (ÇD) uygulanarak veri seti artırılmıştır. Bununla beraber her bir veri setine, modelin hassasiyetini ve seçiciliğini değerlendirmek için farklı karar eşiği (k.e. = 0,25 ve 0,65) değerleri uygulanmıştır. Bu veri setlerine yapılan eğitimlerde iyi–

orta-kötü sınıfları tahmin edilmiş, doğruluk (Accuracy), kesinlik (Precision), duyarlık (Recall) ve F1 skoru gibi başarı metrikleri hesaplanmıştır.

Kurulan sistemin değerlendirilmesi sonucunda, en yüksek performansın düşük karar eşiği ve en fazla veri seti adedine sahip olan Veri Seti 8’de (Accuracy=0,985; F1=0,977), artırmaz veya tekil artırmalı Veri Seti 1-4 aralığında, başarıda belirgin düşüş yaşandığı, kombinasyonlu artırımların olduğu Veri Seti 5-7 aralığında ise, genelleme kabiliyetini iyileştirdiği görülmüştür. Ayrıca eşik değerinin yükselmesiyle Recall’un azaldığı ve yanlış negatiflerin (FN) arttığı tespit edilmiştir. Çalışmada, eğitimden elde edilen model kamera sistemi ile gerçek zamanlı uygulamaya entegre edilerek çapak sınıfının anlık olarak ekranda gösterilmesi sağlanmıştır.

Elde edilen sonuçlar, geliştirilen yaklaşımın endüstriyel üretim hatlarında ve kalite kontrol uygulamalarında kullanılabilir olduğunu göstermektedir. Bu kapsamda sistem, planlama ve süreç mühendislerine; düşük/orta eşik değerleriyle ve kombinasyonlu veri artırma stratejileriyle, hızlı ve güvenilir çapak sınıflandırma için uygulanabilir bir yöntem olarak önerilmektedir.

Anahtar kelimeler: Alüminyum delme, çapak sınıflandırma, YOLOv10, görüntü işleme, gerçek zamanlı kalite kontrol.

ABSTRACT

M.Sc. THESIS

INVESTIGATION OF BURRS FORMED ON THE MATERIAL SURFACE DURING DRILLING WITH IMAGE PROCESSING AND OPTIMIZATION OF CUTTING PARAMETERS

Mikail KIRÇIL

**Bandırma Onyedi Eylül University
Institute of Graduate Studies
Department of Mechatronics Engineering**

Supervisor: Assoc. Prof. Ali ERÇETİN

Co-Supervisor: Assist. Prof. Dr. Süleyman Gökhan TAŞKIN

October 2025, 77 pages

In recent years, efforts to improve quality and efficiency in manufacturing technologies have accelerated, leading to the adoption of automated defect detection and classification methods, particularly in machining processes. With the advancement of computer vision and artificial intelligence approaches, deep learning models have emerged as an alternative to conventional burr measurement and manual inspection methods, offering faster, more cost-effective, and more repeatable solutions.

In this thesis study, the aim is to classify the burrs formed after drilling operations on AA6013 aluminum alloy using the YOLOv10n model on datasets created from microscope images. In addition to the original dataset, the dataset was augmented by applying horizontal flipping (HF), 180° rotation (R180°), and their combinations (CF) to the original dataset to improve the model's generalization ability. Furthermore, different decision threshold values (k.e. = 0.25 and 0.65) were applied to each dataset to evaluate the model's sensitivity and selectivity.

During training on these datasets, good–medium–poor classes were predicted, and performance metrics such as accuracy, precision, recall, and F1 score were calculated.

As a result of evaluating the established system, the highest performance was achieved with dataset 8, which had the lowest decision threshold and the largest number of data sets (Accuracy=0.985; F1=0.977). A significant decrease in success was observed in non-augmented or single-augmented Datasets from 1 to 4, while combined augmentations improved generalization ability by datasets from 5 to 7. Furthermore, it was determined that Recall decreased and false negatives (FN) increased as the threshold value increased. In the study, the model camera system obtained from training was integrated into real-time application, enabling the instant display of the spatter class on the screen.

The results demonstrate that the proposed approach can be applied in industrial production lines and quality control processes. Accordingly, the system is recommended to planning and process engineers as a practical method for fast and reliable burr classification, particularly by using low/medium confidence thresholds and combined data augmentation strategies.

Keywords: Aluminum Drilling, Burr Classification, YOLOv10, Computer Vision, Real-Time Quality Control

İÇİNDEKİLER

	Sayfa
ÖZET	I
ABSTRACT	III
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	IX
TABLO LİSTESİ.....	XI
SİMGE VE KISALTMA LİSTESİ	XII
1. GİRİŞ	1
1.1 Literatür Araştırması	2
1.1.1 Alüminyum Alaşımları.....	2
1.1.1.1 Alaşım Numaralandırma Sistemi	3
1.1.1.2 Alüminyum Alaşımları İçin Temper Sınıflandırması.....	3
1.1.2 Talaşlı İmalat İşlemleri	4
1.1.2.1 Frezeleme İşlemi.....	4
1.1.2.2 Tornalama İşlemi	4
1.1.2.3 Delme İşlemi.....	5
1.1.3 Delik Delme İşlemleri ve Yüzey Analizi	5
1.1.3.1 Çapak Oluşumu ve Etkileri.....	7
1.1.4 Çapak Analizi ve Genel Ölçüm Uygulamaları.....	7
1.1.4.1 Çapak Oluşum Mekanizması ve Çeşitleri.....	8
1.1.4.2 Delik Delmede Çapaklar: Tipik Problemler.....	8
1.1.4.3 Çapakların Analizi ve Ölçümü	8
1.1.4.4 Kesme Parametrelerinin Optimizasyonu (Devir/İlerleme) ve Katman Duyarlı Kontrol	9
1.1.5 Klasik Ölçümler ve Deneysel Yaklaşımlar	9

1.2	Görüntü İşleme Tabanlı Çapak İncelemesi ve Ölçüm Yöntemleri	10
1.2.1	Kenar/Kontur-Temelli İşleme	10
1.2.2	Endüstriyel Parça Ölçümü, Fotogrametri ve Robotik Uygulamalar	11
1.2.3	İncelemeler, Yeni Algoritmalar ve Doğruluk Sonuçları	11
1.2.4	Kompozitlerde Çapak Tahmini.....	12
1.3	Derin Öğrenme ve YOLO Tabanlı Kusur Tespiti	12
1.4	Başarı Metrikleri ve Değerlendirme Ölçütleri	13
1.5	Tezin Gerekçesi ve Amacı	14
2.	MATERYAL VE YÖNTEM	16
2.1	DeneySEL Düzenek ve İşleme Parametreleri.....	16
2.2	Görüntüleme ve Kayıt Süreci	17
2.3	Veri Etiketleme Protokolü	18
2.4	DeneySEL Sınıf Dağılımları ve Çapak Eğilimi	19
2.5	Veri Artırma.....	20
2.6	Veri Setleri.....	20
2.7	Eğitim Parametreleri.....	22
2.8	Model Performans Metrikleri.....	22
2.8.1	Karışıklık Matrisi ve Temel Kavramlar.....	22
2.8.2	Doğruluk (Accuracy).....	23
2.8.3	Kesinlik (Precision)	24
2.8.4	Duyarlılık (Recall)	24
2.8.5	F1 Skoru	24
2.8.6	Mevcut Tez Çalışmasına Yönelik Yaklaşım.....	25
2.9	Çalışma Akışı.....	25
2.10	YOLOv10n Modeli Eğitim ve Test Akışı.....	26
2.10.1	Eğitim Kümesi (Train Set).....	26
2.10.2	Doğrulama Kümesi (Validation Set).....	26

2.10.3	Test Kümesi (Test Set)	26
2.10.4	Sonuçların Değerlendirilmesi	26
3.	BULGULAR VE TARTIŞMA.....	28
3.1	Ön Çalışma Analiz ve Bulguları	28
3.2	Deneyisel Çalışmalar	29
3.2.1	En Başarılı Veri Setine Ait (Veri Seti 8, K.E. = 0,25) Gerçek ve Model Tahminlerinin Karşılaştırmalı Analizi	29
3.2.2	Veri Seti Bazlı Bulgular	32
3.2.2.1	Veri Seti 1 (K.E. = 0,65)	33
3.2.2.2	Veri Seti 1 (K.E. = 0,25)	34
3.2.2.3	Veri Seti 2 (k.e. = 0,65)	35
3.2.2.4	Veri Seti 2 (k.e. = 0,25)	37
3.2.2.5	Veri Seti 3 (k.e. = 0,65)	38
3.2.2.6	Veri Seti 3 (k.e. = 0,25)	39
3.2.2.7	Veri Seti 4 (k.e. = 0,65)	41
3.2.2.8	Veri Seti 4 (k.e. = 0,25)	42
3.2.2.9	Veri Seti 5 (k.e. = 0,65)	43
3.2.2.10	Veri Seti 5 (k.e. = 0,25)	45
3.2.2.11	Veri Seti 6 (k.e. = 0,65)	46
3.2.2.12	Veri Seti 6 (k.e. = 0,25)	47
3.2.2.13	Veri Seti 7 (k.e. = 0,65)	49
3.2.2.14	Veri Seti 7 (k.e. = 0,25)	50
3.2.2.15	Veri Seti 8 (k.e. = 0,65)	51
3.2.2.16	Veri Seti 8 (k.e. = 0,25)	53
3.2.3	Bulgulara Göre Veri Setlerin Genel Değerlendirilmesi	56
3.2.4	Tüm veri setlerini kapsayan karşılaştırmalı grafikler	57
3.2.4.1	Makro metrikler (Accuracy, Precision, Recall, F1)	58

3.2.4.2	TP–TN–FP–FN dağılımları	59
3.2.4.3	Hata oranları	60
3.2.4.4	Tüm veri setlerinin orta sınıfa ait f1 skorları	61
3.2.4.5	Trend grafikler	62
3.2.4.6	Yığılmış oran grafiği	64
3.2.4.7	Genel değerlendirme	65
3.3	Tartışma.....	65
4.	SONUÇLAR.....	68
4.1	Genel Sonuçlar	68
4.2	Çalışmanın Katkıları	69
4.3	Gelecek Çalışma Önerileri	69
5.	KAYNAKLAR	70

ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 3-1: Parametre-1 görüntü işleme (a) öncesi ve (b) sonrası; parametre-2 görüntü işleme (c) öncesi ve (d) sonrası; parametre-3 görüntü işleme (e) öncesi ve (f) sonrası; (g) modelin eğitim grafikleri; (h) modelin doğrulama grafikleri.....	29
Şekil 3-2: 360 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları.....	30
Şekil 3-3: 715 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları.....	31
Şekil 3-4: 535 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları.....	32
Şekil 3-5: Veri Seti 1 (k.e. = 0,65) için karışıklık matrisi	34
Şekil 3-6: Veri Seti 1 (k.e. = 0,25) için karışıklık matrisi	35
Şekil 3-7: Veri Seti 2 (k.e. = 0,65) için karışıklık matrisi	36
Şekil 3-8: Veri Seti 2 (k.e. = 0,25) için karışıklık matrisi	38
Şekil 3-9: Veri Seti 3 (k.e. = 0,65) için karışıklık matrisi	39
Şekil 3-10: Veri Seti 3 (k.e. = 0,25) için karışıklık matrisi	40
Şekil 3-11: Veri Seti 4 (k.e. = 0,65) için karışıklık matrisi	42
Şekil 3-12: Veri Seti 4 (k.e. = 0,25) için karışıklık matrisi	43
Şekil 3-13: Veri Seti 5 (k.e. = 0,65) için karışıklık matrisi	44
Şekil 3-14: Veri Seti 5 (k.e. = 0,25) için karışıklık matrisi	46
Şekil 3-15: Veri Seti 6 (k.e. = 0,65) için karışıklık matrisi	47
Şekil 3-16: Veri Seti 6 (k.e. = 0,25) için karışıklık matrisi	48
Şekil 3-17: Veri Seti 7 (k.e. = 0,65) için karışıklık matrisi	50
Şekil 3-18: Veri Seti 7 (k.e. = 0,25) için karışıklık matrisi	51
Şekil 3-19: Veri Seti 8 (k.e. = 0,65) için karışıklık matrisi	52
Şekil 3-20: Veri Seti 8 (k.e. = 0,25) için karışıklık matrisi	54
Şekil 3-21: Makro ortalama başarı metriklerinin veri setlere göre değişim grafiği	58
Şekil 3-22: TP–TN–FP–FN dağılım grafiği.....	59
Şekil 3-23: FP/(TP+FP) hata oranının, veri setlerine ve karar eşiklerine göre değişim grafiği.....	60
Şekil 3-24: FN/(TP+FN) hata oranının, veri setlerine ve karar eşiklerine göre değişim grafiği.....	61
Şekil 3-25: Orta sınıfa ait F1 değerlerinin veri setlerine ve karar eşiklerine göre grafiği.....	62

Şekil 3-26: Makro Precision değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği.....	63
Şekil 3-27: Makro Recall değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği	63
Şekil 3-28: Makro F1 değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği..	64
Şekil 3-29: Accuracy değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği ...	64
Şekil 3-30: TP/TN/FP/FN oranlarının veri setlerine göre %100 yığılmış grafiği.....	65



TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 1-1: Alüminyum alaşım serilerinin genel özellikleri ve uygulama alanları [17]	2
Tablo 2-1: Delik delme işleminde uygulanan parametreler	17
Tablo 2-2: Devir hızına göre delik sınıfı dağılımları ve ortalama çapak şiddeti	19
Tablo 2-3: Tez bağlamında TP–FP–TN–FN anlamları	23
Tablo 3-1: Veri Seti 1 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	33
Tablo 3-2: Veri Seti 1 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	35
Tablo 3-3: Veri Seti 2 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	36
Tablo 3-4: Veri Seti 2 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	37
Tablo 3-5: Veri Seti 3 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	39
Tablo 3-6: Veri Seti 3 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	40
Tablo 3-7: Veri Seti 4 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	41
Tablo 3-8: Veri Seti 4 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	43
Tablo 3-9: Veri Seti 5 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	44
Tablo 3-10: Veri Seti 5 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	45
Tablo 3-11: Veri Seti 6 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	47
Tablo 3-12: Veri Seti 6 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	48
Tablo 3-13: Veri Seti 7 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	49
Tablo 3-14: Veri Seti 7 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	51
Tablo 3-15: Veri Seti 8 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri	52
Tablo 3-16: Veri Seti 8 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri	53
Tablo 3-17: Tüm veri setlerine ait precision, recall, f1-score ve accuracy değerleri.....	56

SİMGE VE KISALTMA LİSTESİ

Simgeler

n	: Devir sayısı
f	: İlerleme hızı
V _c	: Kesme hızı
Ø	: Çap
IoU	: Intersection over union
µm	: Mikrometre
mm	: Milimetre
Dev/dak	: Devir/dakika
Al	: Alüminyum


Kısaltmalar

Açıklama

AA	: Alüminyum Alaşımı
ÇD	: Çevirme–Döndürme Kombinasyonu
D180°	: Saat Yönünde 180° Döndürme
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
K.E.	: Karar Eşiği
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
YÇ	: Yatay Çevirme
YOLO	: You Only Look Once (Nesne Algılama Yöntemi)
YOLOv10n	: YOLO v10 modelinin nano varyantı

1. GİRİŞ

Alüminyum, hafifliği, yüksek özgül dayanımı, korozyon direnci, kolay şekillendirilebilirliği, iyi elektriksel ve ısıl iletkenliği ile günümüzde en yaygın kullanılan endüstriyel metallere biri olarak öne çıkmaktadır [1]. Alüminyum, otomotiv, yapı ve inşaat, elektrik-elektronik, ulaşım, denizcilik ve havacılık endüstrileri gibi pek çok alanda geniş bir kullanım yelpazesine sahip olması nedeniyle stratejik öneme sahip bir mühendislik malzemesi olarak değerlendirilmektedir [2]. Piyasa öngörülleri, 2018 yılında 147,2 milyar dolar seviyesinde bulunan küresel alüminyum pazarının 2026 yılına kadar 189,8 milyar dolara ulaşacağını göstermektedir [2]. Özellikle otomotiv sektöründe alüminyum kullanımındaki artış dikkat çekmektedir. 1970'lerde bir otomobilde ortalama 35 kg alüminyum kullanılırken, bu miktarın 2025 yılı itibarıyla yaklaşık 250 kg'a çıkacağı tahmin edilmektedir [3]. Günümüzde ise bazı binek araçların toplam ağırlığının %40'ına kadarının alüminyumdan oluştuğu rapor edilmektedir [4]. Havacılık endüstrisinde ise tipik bir yolcu uçağının kütlesinin yaklaşık %80'inin alüminyum alaşımlarından meydana geldiği bildirilmektedir. Şekil 1.4'te tipik bir yolcu uçağı yapısında alüminyum alaşımlarının oranı gösterilmektedir [4].



Şekil 1-1: Ticari yolcu uçaklarında alüminyum kullanımı [4]

Alüminyum alaşımlarının yumuşak yapısı ve yüksek ısıl iletkenlik özelliği, şekillendirilebilirliği artırmakta, takım aşınmasını azaltmakta ve talaş kaldırma sırasında oluşan ısının hızlı bir şekilde uzaklaştırılmasına imkân sağlamaktadır [5]. Bu özellikler, alüminyum alaşımlarının frezeleme, tornalama ve delik delme gibi talaşlı imalat uygulamalarında yaygın

olarak tercih edilmesine zemin hazırlamakta ve farklı işleme yöntemlerinde verimliliği artırmaktadır. Talaşlı imalat içerisinde önemli bir yere sahip olan delik delme işlemleri ise, uygulamaların yaklaşık üçte birini oluşturmaktadır [6,7]. Mekanik üretim süreçlerinde ekonomik açıdan da kritik bir rol üstlenmektedir [8]. Ancak kesme hızının delik ekseninde sıfıra yaklaşması ve sürtünmeye bağlı ısınma, delik çıkışında çapak oluşumuna yol açmaktadır [9,10]. Özellikle küçük bileşenlerin işlendiği durumlarda çapakların alınması daha zor olmaktadır. Bu durum hem zaman kaybına hem de maliyet artışına neden olmaktadır [11]. Çapak alma işlemlerinin toplam üretim maliyetinin yaklaşık %30'unu [12,13], toplam işleme süresinin %40'ından fazlasını oluşturabileceği rapor edilmektedir [14]. Tüm bu nedenlerle, delme sonrası yüzey kusurlarının hızlı, güvenilir ve tekrarlanabilir şekilde incelenmesi ve kesme parametrelerinin buna uygun olarak optimize edilmesi büyük önem taşımaktadır.

1.1 Literatür Araştırması

1.1.1 Alüminyum Alaşımları

Alüminyum alaşımları, mekanik özelliklerin geliştirilmesi amacıyla farklı alaşım elementlerinin eklenmesiyle elde edilmektedir. Amerikan Alüminyum Birliği tarafından başlıca yedi seri altında sınıflandırılmaktadır. Tablo 1.1'de bu seriler, ana alaşım elementleri ve uygulama alanlarıyla birlikte verilmiştir [15,16].

Tablo 1-1: Alüminyum alaşım serilerinin genel özellikleri ve uygulama alanları [17]

Seri	Ana Alaşım Elementleri	Uygulama Alanları
1XXX	%99'dan yüksek saflıkta ticari alüminyum	Kimya endüstrisi, elektrik-elektronik
2XXX	Bakır	Havacılık, yüksek işlenebilirlik
3XXX	Manganez	Anodizasyon, kaynak
4XXX	Silisyum	Kaynak teli, mimari uygulamalar
5XXX	Magnezyum	Denizcilik, korozyon direnci
6XXX	Magnezyum ve Silisyum	Otomotiv, iyi şekillendirilebilirlik
7XXX	Çinko	Havacılık, yüksek mukavemet
8XXX	Diğer elementler (ör. lityum)	Demir, nikel, Al-Li alaşımları

1.1.1.1 Alaşım Numaralandırma Sistemi

Alüminyum alaşımlarında kullanılan numaralandırma sistemine göre, 1. rakam, alaşımın temel türünü göstermektedir. 2. rakam, “0” dışındaki değerlerde alaşımın değişikliğini/modifikasyonunu ifade eder. 3. ve 4. rakamlar, ilgili alüminyum alaşımındaki saflık derecesini belirtmektedir [17].

1.1.1.2 Alüminyum Alaşımları İçin Temper Sınıflandırması

Alüminyum alaşımlarının ısıtılma işlem ve mekanik işlem durumlarını tanımlamak için kullanılan ek harfler “F, H, O, T, W” ile ifade edilmektedir [17].

- F: İşlenmiş
- O: Tavlanmış (yalnızca dövme ürünler için)
- W: Çözeltiye alınmış
- H: Soğuk şekillendirilmiş (işlemle sertleştirilmiş)
- T: Yapay yaşlandırma ile sertleştirilmiş

T alt sınıfları:

T1: Üretim sıcaklığından soğutulmuş ve doğal yaşlandırılmış

T2: Üretim sıcaklığından soğutulmuş, soğuk şekillendirilmiş ve doğal yaşlandırılmış

T3: Çözeltiye alınmış, soğuk şekillendirilmiş ve doğal yaşlandırılmış

T4: Çözeltiye alınmış ve doğal yaşlandırılmış

T5: Üretim sıcaklığından soğutulmuş ve yapay yaşlandırılmış

T6: Çözeltiye alınmış ve yapay yaşlandırılmış

T7: Çözeltiye alınmış ve aşırı yaşlandırma ile stabilize edilmiş

T8: Çözeltiye alınmış, soğuk şekillendirilmiş ve yapay yaşlandırılmış

T9: Çözeltiye alınmış, yapay yaşlandırılmış ve soğuk şekillendirilmiş

T10: Üretim sıcaklığından soğutulmuş, soğuk şekillendirilmiş ve yapay yaşlandırılmış [17].

Bu tez çalışması kapsamında kullanılan AA6013 alüminyum alaşımı, alüminyum alaşımları içerisinde yer alan 6XXX serili (Mg-Si esaslı) bir alaşımdır. Yüksek şekillendirilebilirlik, iyi kaynaklanabilirlik ve korozyon direncindeki üstünlükleri sayesinde

özellikle otomotiv ve havacılık endüstrisinde yaygın olarak kullanılmaktadır [15]. Literatürde, bu seriye ait alaşımların ısıtma işlemi uygulanmasıyla mekanik özelliklerinin önemli ölçüde geliştirildiği görülmektedir. Özellikle T6 temper koşulunda yüksek dayanım ve iyi işlenebilirlik sağladığı vurgulanmaktadır [16].

1.1.2 Talaşlı İmalat İşlemleri

Talaşlı imalat, kesici bir takım aracılığıyla iş parçasından talaş kaldırılması esasına dayanan temel bir üretim yöntemidir. Bu süreç yalnızca parçaların geometrik doğruluğunu değil, aynı zamanda yüzey pürüzlülüğü, mekanik bütünlük ve üretim verimliliğini de doğrudan şekillendirmektedir. Kesme hızı, ilerleme, talaş derinliği, takım malzemesi ve geometrisi gibi parametreler ile soğutma/yağlama stratejileri, işlemin kalitesini belirleyen başlıca unsurlar arasında yer almaktadır [18,19].

Chen ve Tsao [6], ile Zhao [7], yaptıkları çalışmalarında talaşlı imalat içinde delik delmenin çok yaygın bir yer tuttuğunu incelemişlerdir. Li ve Shih [8], delmenin üretim ekonomisi açısından önemini vurgulamışlardır. Davim ve Jackson [20], delmenin havacılık başta olmak üzere biyomedikal, optik, elektronik ve otomotiv gibi sektörlerde temel bir işlem olarak konumlandığını belirtmişlerdir.

1.1.2.1 Frezeleme İşlemi

Frezeleme işlemi, kesici takımın iş parçası ile kesikli temas kurduğu ve değişken talaş kalınlığının olduğu bir talaş kaldırma yöntemidir. İşlem sırasında takım–iş parçası etkileşimi; devir sayısı, dış başına ilerleme, radyal/eksenel talaş derinliği ve takım yolu stratejisi gibi parametrelerden etkilenmektedir. Takım aşınması (yan yüzey, krater, kenar kırılması) ve yüzey topografyası, ısıtma-mekanik yüklerin yanı sıra kesici takım geometrisinin birleşik etkisi altında gelişmektedir [21,22].

1.1.2.2 Tortalama İşlemi

Tortalama işlemi, tek uçlu bir kesici takım aracılığıyla sürekli talaş oluşumuna dayalı bir işlemdir. Bu yöntemde kesme kuvvetleri, sıcaklık dağılımı ve talaş morfolojisi; ilerleme, kesme hızı, talaş derinliği, uç yarıçapı ve iş parçasının metalurjik özellikleri gibi faktörlerden

etkilenmektedir. Özellikle yan yüzey ve krater aşınması, yüzey kalitesini ve boyutsal doğruluğu olumsuz yönde etkilemektedir. Bu nedenle, literatürde üretim kalitesini süreklileştirmek amacıyla sinyal tabanlı, veri odaklı veya hibrit yaklaşımlara dayalı akıllı izleme sistemleri geliştirilmiştir [23,24].

1.1.2.3 Delme İşlemi

Delme işlemi, döner bir kesici takımın eksenel ilerlemesiyle gerçekleştirilen ve endüstride en yaygın kullanılan talaşlı imalat işlemlerinden biridir. Bu yöntemde en önemli kısıtlar, talaşın etkin biçimde tahliye edilmesi, ısının uzaklaştırılması ve takımın hassas biçimde yönlendirilmesidir. Özellikle derin delik delme ya da kompozit/anisotropik malzemelerde bu zorluklar daha belirgin hale gelmektedir. Delme işleminde karşılaşılan başlıca hatalar; çapak oluşumu, tabaka ayrılması (delaminasyon), boyutsal sapmalar ve yüzey pürüzlülüğü bozulmalarıdır. Bu sorunların azaltılması için kesme parametrelerinin (devir, ilerleme) optimize edilmesi, uygun takım ucu geometrilerinin seçilmesi, kademeli delme (peck drilling) stratejilerinin uygulanması ve etkin soğutma/yağlama yöntemlerinin kullanılması gerekmektedir. Güncel araştırmalar, sonlu elemanlar modelleri ile sürdürülebilirlik kriterlerini bir araya getirerek delik kalitesi, takım ömrü ve enerji tüketimi arasındaki dengeyi optimize etmeye odaklanmaktadır [25,26].

1.1.3 Delik Delme İşlemleri ve Yüzey Analizi

Havacılık endüstrisinde matkapla delik delme, uçak yapılarında milyonlarca deliğin açılmasını gerektiren montaj süreçlerinde (özellikle perçinli ve civatalı bağlantılarda) talaşlı imalat operasyonlarından biri olarak konumlanmaktadır [27]. Uçaklar hizmet ömürleri boyunca sürekli darbe ve titreşimlere maruz kaldığından, bu durum akma dayanımının altındaki çevrimsel yüklemelerle yorulma hasarını tetikleyebilmektedir [28]. Uygulamada bağlantı deliklerinin önemli bir kısmı pnömatik el matkaplarıyla manuel olarak açılmakta, takım gövde kaplaması yönünde ilerlerken talaş oluklar vasıtasıyla uzaklaştırılmaktadır. Bu süreç, yüksek eksenel kuvvetlerin oluşmasına ve kesme bölgesindeki ısının etkin biçimde dağıtılamamasına yol açmaktadır [29]. Takım–talaş–iş parçası arayüzündeki sürtünmeden kaynaklanan ısı yükü, yüzey pürüzlülüğünü ve gerilme yığılmalarını arttırmaktadır [30]. Özellikle gövde kaplamasındaki bağlantı delikleri, söz

konusu gerilme yoğunlaşmaları nedeniyle yorulma çatlakları için başlangıç bölgelerine dönüşebilmekte ve bu da yapısal ömür ile güvenilirliği düşürmektedir [31].

Metal esaslı hava aracı yapılarında yorulma ömrü; malzemenin özelliklerine, seçilen kesme parametrelerine ve kullanılan takım geometrisine bağlı olarak değişmektedir [32]. Takımın neden olduğu plastik deformasyon, yüzeyde artık gerilmelerin oluşumunu tetiklemekte ve bu gerilmeler işleme parametreleriyle doğrudan ilişki göstermektedir [33]. Literatürde, delik yüzeyindeki artık gerilmelerin parça kalınlığına bağlı olarak değiştiği ve çıkış tarafında girişe kıyasla daha yüksek değerlere ulaştığı rapor edilmiştir [34]. Ayrıca delik yüzeyinde mikro-sıvanma (smearing) ve çapak oluşumları gözlenebilmektedir. Bu durum, yüzeydeki mikro kusurları örterek erken arızaya zemin hazırladığı için havacılık uygulamalarında arzu edilmemektedir [35]. Bu nedenle bağlantı ömrü, doğrudan delik kalitesine bağlıdır ve delik kalitesi uygulanan delme performansının bir çıktısı olarak değerlendirilmelidir [36].

Havacılık yapılarında delik delmenin temel güçlüğü, delik kalitesine yönelik son derece sıkı gereksinimlerdir [37]. Başlıca kalite göstergeleri arasında delik yüzey pürüzlülüğü, çapak oluşumu ve boyutsal doğruluk (çap sapması ve dairesellik hataları dâhil) öne çıkmaktadır [38]. Bu kriterlerin karşılanamaması, montaj aşamasında çatlak başlatma riskini artırmakta ve parça reddine yol açabilmektedir [28]. Bu bağlamda sektörde delme masterları kullanılmaktadır. Böylelikle el tipi ünitelerin doğru konumlandırılması, deliklerin yüzeye dik açılması ve titreşim kaynaklı sapmaların sınırlandırılması mümkün kılınmaktadır [39]. Artan üretim talebiyle birlikte Airbus gibi üreticiler, yüksek adetlerde ve sıkı toleranslarda delik üretebilen otomatik sistemlere yönelmektedir [40]. Tolouei-Rad [41], yaptığı çalışmada aynı düzlemde çok sayıda deliğin eşzamanlı açımı için özel amaçlı tezgâhlar ve çoklu matkap kafalarının kullanımını tanımlamaktadır. Bu yaklaşımın delme süresini anlamlı ölçüde kısalttığını ve delik standardizasyonunu yükselttiğini belirtmektedir.

Son yıllarda havacılık yapılarında kuru delme uygulamalarının yaygınlaştığı gözlenmektedir. Bu yöntem, perçinleme öncesi temizlik ihtiyacını azaltarak yüksek nitelikte delikler elde edilmesine olanak sağlamaktadır [42]. Kuru işleme, kesme sıvısı tedarik ve bertaraf maliyetlerini ortadan kaldırdığı için ekonomik ve çevre dostu bir seçenek sunmaktadır [43–47]. Ayrıca kuru talaşların yeniden işlenebilmesi mümkünken, kesme sıvısı kullanılan durumlarda talaşın kimyasal katkılarla karışması ek temizleme süreçlerini zorunlu kılmaktadır [47]. Buna karşın, kuru kesme işlemi; takım aşınması ve yapışma (BUE) eğilimini artırarak takım ömrünü kısaltabilmekte ve toplam maliyeti yükseltebilmektedir [48]. Dolayısıyla havacılık endüstrisi, yalnızca malzeme seçimi açısından değil, takım geometrisi, takım malzemesi/kaplaması ile uygun

kesme parametrelerinin belirlenmesi bakımından da yüksek bir hassasiyet gerektirmektedir [49]. Bu çerçevede, son dönem akademik ve endüstriyel çalışmaların delme operasyonlarının performansını artırmaya odaklandığı görülmektedir [50].

1.1.3.1 Çapak Oluşumu ve Etkileri

Çapak oluşumu, talaşlı imalat ve özellikle delik delme işlemlerinde sık karşılaşılan ve istenmeyen bir olgudur [51]. Dornfeld vd. [51], delik delme sırasında özellikle çıkış bölgesinde takım geometrisi ve kesme koşullarına bağlı olarak çapak yüksekliği ve kalınlığının belirgin şekilde arttığını göstermişlerdir. Chen ve Tsao [6], farklı kaplamalı matkaplarla yaptıkları deneylerde artan itme kuvveti ve tork değerlerinin delik çıkışında çapak oluşumunu tetikleyen temel bir etken olduğunu ortaya koymuşlardır. Zhao [7] ise geliştirdiği kesme kuvveti ve güç modelleri ile delik çıkışı civarındaki yük ve sıcaklık koşullarının kenar deformasyonunu artırarak çapağa zemin hazırladığını teorik olarak açıklamıştır.

Çapakların varlığı ürün kalitesini önemli ölçüde düşürmekte, boyutsal doğruluğun bozulmasına, yüzey bütünlüğünün zayıflamasına ve yorulma ile korozyon hızının artmasına yol açmaktadır. Ayrıca, çapak alma (deburring) süreci üretim aşamalarına ek zaman ve maliyet getirmekte, bu da toplam üretim verimliliğini olumsuz etkilemektedir [20]. Bu nedenle, çapak oluşumunu önlemeye yönelik stratejiler kritik bir önem taşımaktadır. Kesme parametrelerinin (devir sayısı, ilerleme hızı) optimize edilmesi, uygun takım geometrilerinin seçilmesi, gelişmiş soğutma/yağlama tekniklerinin uygulanması ve işlem koşullarının sürdürülebilirlik kriterleri gözetilerek belirlenmesi hem çapak oluşumunun azaltılmasına hem de verimli ve yüksek kaliteli üretim çıktılarının elde edilmesine katkı sağlamaktadır.

1.1.4 Çapak Analizi ve Genel Ölçüm Uygulamaları

Biermann [52], çapakların işlenmiş yüzey kalitesi, boyutsal hassasiyet ve montaj performansı (ör. geçme bağlantılar, sızdırmazlık) üzerindeki olumsuz etkilerini vurgulamakta ve modern imalat planlamasında çapak önleme-kontrol stratejileri ile deburring maliyetlerinin birlikte ele alınması gerektiğini belirtmektedir.

1.1.4.1 Çapak Oluşum Mekanizması ve Çeşitleri

Ko [53], çalışmasında kesme kenarının çıkış bölgesinde plastik akmanın kesme/bükülme ile birleşerek yuvarlanma (rollover), Poisson ve kesme (cutoff) tiplerinde çapaklar üretebildiğini bildirmiştir. Baskın tipin mikroyapı, şekil değiştirme hızı ve takım kenar geometrisi tarafından belirlendiğini rapor etmiştir. Bulgular, bu mekanizmaların ısıl-mekanik alanlara duyarlı olduğunu ve kesme hızı, ilerleme, kenar yuvarlatma ve takım aşınması ile karakterin anlamlı biçimde değiştiğini göstermektedir [53].

Basak vd. [54], frezeleme, taşlama ve delmede çapak oluşum mekanizmalarını ve türlerini (devirme, Poisson, kesme, yırtılma) incelemiştir. Kesme hızı, ilerleme hızı, takım geometrisi ve iş parçası malzeme özelliklerinin çapak davranışını anlamlı biçimde etkilediğini açıklamışlardır [54].

1.1.4.2 Delik Delmede Çapaklar: Tipik Problemler

Yalçın [55] ve Karakılınç [56] çalışmalarında, delik delmede çıkış çapakları ile drill-cap oluşumunun delik kalitesini düşürdüğünü, deburring süresini uzattığını ve birleşik yapıların yorulma ömrünü azaltabildiğini ortaya koymuşlardır. Bu çalışmalar, Al-polimer-Al ve CFRP/Ti gibi yığılı yapılar ve lamine malzemelerde talaş tahliyesi ile tabaka arayüzü etkileşimlerinin özellikle tabaka geçişleri ve çıkış bölgesinde çapak şiddetini artırdığını göstermektedir.

Bissacco vd. [11], küçük ölçekli bileşenlerde çapak almanın daha güç olduğunu ve süreç maliyet-zaman yükünü artırdığını belirtmişlerdir. Almeida Filho vd. [12] ve Kaminise [13], çapak alma maliyet payının yüksekliğini ortaya koymuşlardır. Bahçe ve Özdemir [14], zaman payının üretkenliği düşürdüğünü vurgulamışlardır.

1.1.4.3 Çapakların Analizi ve Ölçümü

Mohammed vd. [57], çapak metriklerinin nicel belirlenmesinde yerinde (in-situ) yüksek hızlı görüntüleme, optik mikroskopi, kuvvet/akustik emisyon ölçümü ve 3B profilometri kombinasyonlarının etkili olduğunu göstermektedir. Aynı çalışma, otomatik 3B algılama ve makine öğrenmesi destekli denetim yaklaşımlarının ölçüm standardizasyonu ve süreç parametreleriyle ilişkilendirme açısından giderek daha fazla benimsendiğini rapor etmektedir [57].

Dornfeld vd. [51], 304L paslanmaz çeliğin yüzey frezelemede değişken takım geometrisinin çapak yüksekliği ve kalınlığı üzerindeki etkilerini incelemişlerdir. Radyal talaş açısı ve düzlem içi çıkış açısının kesici kenar çıkış sırası değiştirilerek, çapak boyutunun ve tipinin etkilendiği gösterilmiştir. Kutsal vd. [58], SiC takviyeli AlSi7Mg2 kompozitlerde farklı delme parametrelerinde delik çap değişimleri ve çıkış çapak yüksekliklerini koordinat ölçüm cihazıyla ölçmüşlerdir. Ölçümler sonucunda, çapakların minimize edilmesine yönelik parametre optimizasyonu gerçekleştirilmiştir [58].

1.1.4.4 Kesme Parametrelerinin Optimizasyonu (Devir/İlerleme) ve Katman Duyarlı Kontrol

Paramanik [59], sünek Al-alışımlarında orta kesme hızları ile düşük ilerlemelerin delik çıkışında termal yumuşamayı sınırlayarak çapak yüksekliğini azaltabildiğini göstermektedir. Aynı çalışma, lamine yapılarda kademeli delme (peck drilling), çıkışa yaklaşırken ilerleme azaltma ve katmana özgü parametre çizelgeleri ile cap/rollover oluşumunun etkin biçimde kontrol altına alınabildiğini bildirmektedir [59]. Basak vd. [54], kesme hızı–ilerleme–takım geometrisinin çapak oluşumuna etkilerini özetlemişlerdir. Katmanlı/yığınllı yapıların çıkış tarafındaki davranış farklılıklarının süreç planlamasında dikkate alınması gerektiği vurgulanmıştır [54].

1.1.5 Klasik Ölçümler ve Deneysel Yaklaşımlar

Çapak oluşumunun incelenmesinde literatürde farklı deneysel yöntemlerin kullanıldığı görülmektedir. Dornfeld vd. [51], 304L paslanmaz çeliğin yüzey frezelemede takım geometrisinin etkilerini araştırmışlardır. Radyal talaş açısı ve düzlem içi çıkış açısı değiştirilerek CNC tezgâhında deneyler gerçekleştirilmiştir. Çapak yüksekliği ve kalınlığını mikrometrelili mikroskop ile ölçülmüştür. Çıkış açısının artmasıyla çapak boyutlarının belirgin biçimde yükseldiği rapor edilmiştir. Elde edilen sonuçlar, takım geometrisinin çıkış sırasında oluşan çapak karakterini doğrudan şekillendirdiğini ortaya koymuştur [51]. Geier vd. [60], karbon fiber takviyeli polimer (CFRP) kompozitlerin işlenmesi sırasında çapak oluşum mekanizmalarını incelemişlerdir. Proses parametrelerinin etkisi ve kullanılan ölçüm teknikleri analiz edilmiştir. Yazarlar, özellikle görüntü kalitesi ve çapak geometrisinin karmaşıklığının ölçüm doğruluğu üzerinde kritik bir rol oynadığını ve başarı oranlarının bu faktörlere bağlı olarak ciddi ölçüde değişebildiğini göstermişlerdir [60].

Kutsal vd. [58], SiC takviyeli AlSi7Mg2 kompozitler üzerinde farklı delme parametreleri uygulamışlardır. Delik çapındaki sapmalar ve çıkış çapak yükseklikleri koordinat ölçüm cihazı kullanılarak belirlenmiştir. Çalışma, uygun parametre seçimi ile çapak oluşumunun minimize edilebileceğini göstermiştir. Bununla birlikte, manuel ölçümlerin zaman alıcı ve operatör hatalarına açık olduğu, 3B profilometri ölçümlerinin ise yüksek maliyetli olduğu ifade edilmiştir. Bu nedenle, hızlı ve düşük maliyetli görüntü işleme tabanlı yaklaşımların, çapak karakterizasyonunda önemli bir alternatif olarak değerlendirilebileceği vurgulanmıştır [58].

Ko ve Park yaptıkları çalışmada [61], mikro delme ve mikro kesme süreçlerinde konoskopik holografi, üçgenleme ve interferometri temelli ölçüm yöntemlerini değerlendirmişlerdir. Lazer sensörleri ve hassas hareket kontrolüyle kurulan otomatik sistemde, 50 µm üzeri delik çapakları ve ~10 µm boyutlu mikro köreltilmiş çapakların ölçümünde konoskopik holografının başarıyla uygulanabildiği gösterilmiştir [61].

1.2 Görüntü İşleme Tabanlı Çapak İncelemesi ve Ölçüm Yöntemleri

Bögrekci vd. [62], kullanıcı dostu arayüzler ve yüksek tekrarlanabilirlik sayesinde görüntü işlemenin hızlı ve doğru ölçüm sunduğunu ve kamera tabanlı kazanım, ön-işleme, segmentasyon ve kontur/özellik çıkarımı adımlarıyla pahalı/karmaşık donanım ihtiyacını azalttığını ve analiz kapsamını genişlettiğini ortaya koymaktadırlar. Akkoyun vd. [63], mikro-işleme çalışmalarında görüntü işlemenin manuel ölçümlere kıyasla daha kısa sürede ve daha düşük operatör bağımlılığıyla sonuç ürettiğini göstermişlerdir. Akkoyun vd. [64] farklı bir çalışmada ise, işleme parametreleri ile çapak oluşumu arasındaki ilişkinin nicel olarak çözümlenmesinde görüntü işlemenin etkili bir köprü görevi gördüğünü sunmuşlardır.

1.2.1 Kenar/Kontur-Temelli İşleme

Burr ve Morgan [65], Gaussian bulanık kenarları ve çubukları hareket ettirmek için bulanıklık ayırma eşiklerini araştırmışlar. Ölçümler, bilgisayar tarafından oluşturulan bir ekranda görüntü işleme teknikleri kullanılarak otomatik olarak elde edilmiştir. Deneyler için Cambridge araştırma sistemi olan VSG 2/3 grafik işlemcisi, Barco Calibrator II görsel ekranı ve loş bir oda kullanılmıştır. Ardışık olarak sunulan iki uyaran arasındaki daha bulanık aralık deneklerden seçmeleri istenmiştir. Eşikler, eşige odaklanan uyarlanabilir prosedürler aracılığıyla belirlenmiştir. Çalışmada, hareket ve pozlama süresinin bulanıklık ayırma eşikleri üzerindeki etkisi araştırılmış ve

hareketin hem kısa (40 ms) hem de daha uzun (150 ms) pozlamalar için eşikleri artırdığı tespit edilmiştir [65]. Akkoyun vd. [63], mikro-frezelemede kontur ve alt-piksel kenar konumlama teknikleriyle slot genişliği ve çapak kenar kalınlığının güvenle ayrıştırılabildiğini bildirmişlerdir.

1.2.2 Endüstriyel Parça Ölçümü, Fotogrametri ve Robotik Uygulamalar

Chen vd. [66], üretim sahasında edinim-ön-işleme-kenar-ölçüm ardışımıyla çapak tespiti ve boyutlandırmanın otomatikleştirilebildiğini, malzeme kalınlığı/mukavemeti ile strateji seçiminin çapak görünürlüğünü belirlediğini ve düşük mukavemet-ince et kalınlığında algılama eşiğinin yükseldiğini göstermektedir. Bajpai ve Kumar [67], hızlı mikro-frezelemede SEM destekli karakterizasyonu MATLAB tabanlı ölçüm betikleri ile birleştirerek üst çapak genişliğini güvenilir biçimde rapor etmişlerdir. Chiddarwar vd. [68], CMOS kameralar ve kademeli motor içeren bir görüntü toplama sistemiyle fotogrametri tabanlı otomatik ölçüm gerçekleştirmişlerdir. CAD modelleriyle yüzey karşılaştırması yapılmış ve %88,57-%98,50 doğruluk aralığı rapor edilmiştir. Rahul vd. [69], çoklu görünüşten alınan görüntülerle alüminyum alaşımlı iş parçalarında maksimum 1,2 mm'ye kadar çapakların kaydını ve robotik çapak alma yörüngesi planlamasını önermişlerdir. Ortalama 0,1818 mm konumlama hatası elde edilmiş ve toplam çapak alanının %95,34'ünün kapsanabildiği gösterilmiştir.

1.2.3 İncelemeler, Yeni Algoritmalar ve Doğruluk Sonuçları

Balázs ve Póka [70], erişilemeyen konturlar için geliştirdikleri algoritmayı dijital mikroskop-tezgâh entegrasyonu ve CMM doğrulaması ile sınayarak $\pm 0,06... \pm 0,10$ mm doğruluklara ulaşıldığını bildirmişlerdir. Akkoyun vd. [63], mikro-frezelemede otomatik görüntü işleme ile manuel ölçümleri karşılaştırdığında otomatik ölçümün kıyaslanamayacak ölçüde süreyi kısalttığını, operatör etkisini azalttığını ve tekrarlanabilirliği artırdığını göstermişlerdir. Akkoyun vd. [64], SLM-AISI 316L üzerinde işleme parametreleri ile çapak metrikleri arasında anlamlı korelasyonlar bularak parametre penceresi belirleme ve görsel denetimi standardize etme açısından görüntü işlemenin değerini vurgulamışlardır.

1.2.4 Kompozitlerde Çapak Tahmini

Geier vd. [71], kompozitlerde (özellikle CFRP) anizotropi ve lif–matris arayüzleri nedeniyle güçleşen çapak tahmini için, çoklu aydınlatma ve çift taraflı görüntü edinimiyle segmentasyon–gürültü giderme–lif grubu tespiti adımlarını içeren bir boru hattı önermişlerdir. Giriş/çıkış çapaklarının %64–%97 verimlilikle öngörülebildiğini ve ortalama toplam verimliliklerin 85 ± 6 ile 77 ± 7 düzeyinde hesaplamışlardır [71].

Akkoyun vd. [63,64] iki ayrı çalışmalarında klasik manuel/temaslı ölçümlerin zaman ve operatör değişkenliği sorunlarına karşın, görüntü işleme tabanlı yöntemlerin hız–doğruluk–tekrarlanabilirlik dengesini iyileştirerek parametre optimizasyonu, çevrim-içi kalite güvencesi ve robotik çapak alma işlemi için güçlü bir temel sağladığını vurgulamışlardır.

1.3 Derin Öğrenme ve YOLO Tabanlı Kusur Tespiti

Günümüzde, derin öğrenme yöntemlerinin kullanımı her alanda artış göstermiştir. Yapay zekâ, bilgisayarın veya makinenin, canlıların zeki şekilde karar verme mekanizmalarına benzer şekilde karar verme yeteneğine sahip olmasıdır. Yani, yapay zekâ, bilgisayarın insanlar gibi düşünmesini sağlar. Derin öğrenme ise, yapay sinir ağları ve benzeri makine öğrenme algoritmalarında bir veya daha fazla gizli katman kullanılarak oluşturulan bir çalışma alanıdır. Yani, en az bir adet yapay sinir ağının kullanıldığı ve birçok algoritma ile, bilgisayarın elindeki verilerden yeni veriler elde etmesidir. Derin öğrenme alanında kullanılan birçok algoritma bulunmaktadır. Bu algoritmalarından biri de YOLO (You Only Look Once) algoritmasıdır, bu algoritma, yüksek işleme hızından dolayı yüksek FPS (Frame Per Second) sağlamaktadır ve daha net sonuçlar vermektedir [72].

Wang vd. [73] çalışmalarında, çelik şerit yüzey hatalarının tespiti için YOLO-V7 tabanlı iyileştirilmiş bir model önermişlerdir. Çalışmada ağırlıksız BiFPN yapısı ve ECA dikkat mekanizması kullanılarak öznitelik birleştirme güçlendirilmiş, öznitelik kaybı azaltılmış, önemli kanallara odaklanılmış ve SIOU kayıp fonksiyonu ile ceza terimi yeniden tanımlanmıştır. Önerilen model, GC10-DET ve NEU-DET veri setlerinde sırasıyla %80,2 ve %81,9 mAP başarı oranlarına ulaşarak yüksek doğruluk ve hızla çelik şerit yüzey hataları tespit edilebilmiştir [73].

Li vd. [74], çelik şerit yüzey kusurlarının gerçek zamanlı tespiti için YOLO mimarisini temel alan bir derin sinir ağı geliştirmişlerdir. Soğuk haddelenmiş çelik şeritlerinden oluşan bir veri seti üzerinde eğittikleri ağ, %97,55 ortalama kesinlik ve %95,86 geri çağırma oranı

sergilemiştir. Ağ, 83 FPS hızına ulaşarak gerçek zamanlı çalışabilmiştir. Ayrıca kusur konumlarını ve boyutlarını da başarıyla tahmin edebilmiştir. Bu yaklaşım, çelik şerit kalite kontrolüne katkı sağladığı sonucuna varılmıştır [74].

Kou vd. [75], çelik şerit yüzeyindeki defektleri tespit etmek için YOLO-V3 tabanlı bir model geliştirmişlerdir. Serbest özellik seçim mekanizması ve özel tasarım yoğun konvolüsyon blokları kullanılarak özgün YOLO-V3 modeli iyileştirmişlerdir. Geliştirilen model, GC10-DET veri setinde %71,3, NEU-DET veri setinde %72,2 ortalama kesinlik (mAP) elde etmiş ve saniyede 64.5 kare hızına ulaşmıştır [75].

Zhao vd. [76], çelik yüzey kusurlarının tespiti için YOLOv5 mimarisine dayalı "RDD-YOLO" adlı yeni bir model önermişlerdir. Res2Net blokları ile özellik çıkarımı güçlendirilmiş, Çift Özellik Piramit Ağı (DFPN) ile düşük seviyeli özellikler yeniden kullanılmış ve ayrık bir başlık (decoupled head) kullanılarak sınıflandırma ve konumlandırma ayrılmıştır. Modelin başarısı, NEU-DET veri setinde %81,1, GC10-DET veri setinde %75,2 ortalama kesinlik elde etmesi ve YOLOv5'e göre sırasıyla %4,3 ve %5,8 iyileşme sağladığı görülmüştür [76].

Bu tez çalışmasında YOLOv10 modeli tercih edilmiştir. Çünkü önceki sürümlerine göre NMS-free mimarisi ve consistency dual assignment yaklaşımı sayesinde daha yüksek doğruluk ve daha düşük gecikme sunmaktadır [77,78]. Özellikle nano; YOLOv10n, daha az parametre ve düşük işlem yükü sayesinde sınırlı donanımlarda çalışmaya uygun, hafif ve hızlı bir versiyon olup gerçek zamanlı uygulamalar için öne çıkmaktadır [79].

1.4 Başarı Metrikleri ve Değerlendirme Ölçütleri

Makine öğrenmesi ve derin öğrenme tabanlı sınıflandırma modellerinin başarısı, yalnızca genel doğruluk oranı (accuracy) üzerinden değerlendirilmemekte; farklı hata türlerini dikkate alan kapsamlı performans metrikleri kullanılmaktadır [80].

Bu metrikler, modelin tahmin ettiği sonuçların gerçek etiketlerle olan uyumunu karışıklık matrisi (confusion matrix) aracılığıyla göstermektedir.

Karışıklık matrisi, dört temel bileşen üzerine kuruludur [80]:

- True Positive (TP): Gerçekte ait olduğu sınıfta yer alan örneğin, model tarafından da aynı sınıfta doğru şekilde tahmin edilmesi.
- False Positive (FP): Gerçekte ait olmadığı bir sınıfa, model tarafından yanlışlıkla atanması.
- True Negative (TN): Belirli bir sınıfa ait olmayan bir örneğin, model tarafından da o sınıfa dahil edilmemesi.

- False Negative (FN): Gerçekte belirli bir sınıfa ait bir örneğin, yanlış şekilde başka bir sınıf olarak değerlendirilmesi.

Bu temel kavramlardan türetilen başlıca performans metrikleri aşağıdaki gibi tanımlanır:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad [80]$$

$$\text{Precision} = TP / (TP + FP) \quad [80]$$

$$\text{Recall} = TP / (TP + FN) \quad [80]$$

$$F1 = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}) \quad [80]$$

Burada:

- Accuracy, modelin genel başarı oranını gösterir.
- Precision, modelin pozitif tahminlerinin ne kadarının doğru olduğunu ölçer.
- Recall, gerçekte pozitif olan örneklerin ne kadarının model tarafından doğru yakalandığını ifade eder.
- F1-Score, Precision ve Recall değerlerinin harmonik ortalamasıdır ve özellikle sınıf dengesizliği içeren veri setlerinde performansı en gerçekçi biçimde yansıtır [80].

Bu metrikler, literatürde özellikle endüstriyel kalite kontrol, yüzey hatası tespiti ve görsel inceleme tabanlı üretim sistemlerinde yaygın olarak kullanılmaktadır.

1.5 Tezin Gerekçesi ve Amacı

Günümüz endüstrisinde alüminyum alaşımlarının yaygın kullanımı, talaşlı imalatta delik delme operasyonlarının payını arttırmakta ve delik çıkışında oluşan çapak, yüzey bütünlüğü ile üretim verimliliği üzerinde kritik bir engel oluşturmaktadır. Günümüzde hafiflik, dayanım ve korozyon direnci gibi özellikleri nedeniyle alüminyum alaşımları birçok endüstri alanında tercih edilmektedir. Bu yaygın kullanım, özellikle imalat süreçlerinde talaşlı imalat yöntemlerinin önemini artırmaktadır. Bu bağlamda, talaşlı imalatta delik delme operasyonlarının payı da giderek artmaktadır. Diğer yandan, delik delme operasyonları neticesinde malzeme yüzeyinde oluşan çapak yüzey bütünlüğü ile üretim verimliliği üzerinde kritik bir engel oluşturmaktadır. Literatür araştırması neticesinde, çapakların klasik veya cihaz tabanlı yöntemlerle ölçümlerinin sağlandığı

belirlenmiştir. Bu yöntemler, operatöre bağımlı, yavaş ve maliyetli bir süreci beraberinde getirmektedir. Görüntü işleme ve derin öğrenme tabanlı yaklaşımlar ise hız ve nesnellik sağlayarak, insan hatasını en aza indirmekte ve ölçüm doğruluğunu arttırmaktadır. Bununla birlikte, endüstriyel ve kalite kontrol uygulamalarında daha verimli bir alternatif sunmaktadır.


Bu tez çalışması ise AA6013 alüminyum alaşımı üzerinde delik delme sonrası oluşan çapakların görüntü işleme ve YOLO tabanlı yöntemlerle analiz edilmesini ve elde edilen bulgulara dayalı kesme parametrelerinin optimize edilmesini içermektedir.



2. MATERYAL VE YÖNTEM

2.1 Deneysel Düzenek ve İşleme Parametreleri

Bu çalışmada delik yerleşim planı, öncelikle Şekil 2.1 (a)'daki gibi SolidWorks ortamında şematik olarak tasarlanmıştır. Daha sonra, 330×80×10 mm boyutlarındaki AA6013 alüminyum plaka üzerinde metal punch ile 180 adet işaretleme gerçekleştirilmiştir. Deney öncesinde iş mili salınım (run-out) ve hizalama kontrolü kadran göstergesi ile yapılmış, sapmalar üretici toleranslarının altında doğrulanmıştır. Bandırma Onyedü Eylül Üniversitesi Denizcilik Fakültesi bünyesinde mevcut olan sütunlu matkap tezgahında (Şekil 2.2), alüminyum plaka üzerinde işaretlenen noktalardan delik delme işlemleri uygulanmıştır (Şekil 2.1b). Delme işlemlerinde Tablo 2.1'de sunulan 3 farklı işleme parametresi kullanılmıştır. Her bir parametre için 60 delik olmak üzere toplamda 180 adet delik delme gerçekleştirilmiştir. İşlemler kuru kesme koşullarında uygulanmış ve delme işlemlerinde Ø6 mm çapında standart HSS matkap ucu kullanılmıştır.



Şekil 2-1: (a) Plaka üzerinde delik delme prosesinin Solidworks tasarımı, (b) delik delme işlemi uygulanmış AA6013 alüminyum plaka



Şekil 2-2: Sütunlu matkap tezgâhı

Tablo 2-1: Delik delme işleminde uygulanan parametreler

Deney No	Devir n (dev/dak)	Kesme Hızı Vc (m/dak)	İlerleme Hızı (mm/devir)
1 (60 delik)	360	6,79	0,3
2 (60 delik)	715	13,48	0,3
3 (60 delik)	535	10,08	0,3

2.2 Görüntüleme ve Kayıt Süreci

Delme işlemlerinden sonra her deliğin çıkış tarafındaki çapak bölgesi de kadrja alınacak şekilde Dino-Lite AM2111 dijital USB mikroskop ile ayrı ayrı fotoğrafları çekilmiştir (Şekil 2.3). Çekimlerde USB mikroskop tutucu kullanılarak kamera-yüzey mesafesi ve açı sabit tutulmuş, homojen aydınlatma ile yansıma ve gölge etkileri minimuma indirilmiştir. Görüntü eldesinde kullanılan Dino-Lite AM2111 mikroskopun entegre LED aydınlatması, deney ortamındaki dış ışık koşullarından bağımsız olarak sabit parlaklıkta çalışmaktadır. Deneyler sırasında çevresel ışık değişimleri test edilmiş, dış ortam ışıklandırmasının kamera aydınlatması üzerinde ölçülebilir bir etkisi olmadığı gözlemlenmiştir. Ölçeğin korunması amacıyla kalibrasyon cetveli ile mm/piksel değeri belirlenmiştir. Büyütme, pozlama ve beyaz dengesi sabitlenmiştir.

İzlenebilirlik için dosya adlandırması parametre-sıra mantığıyla yapılmıştır. İlk sayı parametre, ikinci sayı ilgili parametrede uygulanan delik sırasını belirtmektedir. Örneğin, 1. parametre 20. delik için (1-20) veya 3. parametre 12. delik için (3-12) isimlendirmesi kullanılmıştır.




Şekil 2- 3: Dino-Lite AM2111 USB mikroskop (mikroskop tutucu ile birlikte)

2.3 Veri Etiketleme Protokolü

Elde edilen 180 adet delik görüntüleri, çapak oluşumunun büyüklüğü ve yoğunluğu dikkate alınarak üç kalite sınıfında etiketlenmiştir:

- İyi: Çapaksız veya çok az çapak içeren delikler,
- Orta: Çıkış kenarında belirgin fakat sınırlı çapak yapısı bulunan delikler,
- Kötü: Çıkış kenarında yoğun plastik deformasyon ve yüksek çapak birikimi gözlenen delikler.

Etiketleme işlemi, kutu kapsama (bounding box) yöntemiyle, çapak sınırlarını tam kapsayacak şekilde ve gereksiz arka planı minimize edecek biçimde yapılmıştır. Üç bağımsız değerlendirici tarafından yürütülen süreçte, (i) her değerlendirici örnekleri ayrı ayrı etiketlemiş, (ii) farklılık gösteren etiketler grup görüşmesiyle tartışılarak ortak nihai etiket belirlenmiştir. Bu yöntem bireysel yanlılıkları azaltmayı ve veri setinin tutarlılığını artırmayı hedeflemiştir. Sonuç olarak, 180 delik görüntüsünün sınıflara göre dağılımı; İyi: 56, orta: 61, kötü: 63 şeklinde gerçekleşmiştir.



Şekil 2-4: Roboflow’da deliklerin, çapak büyüklüğüne göre etiketlenmesi; (a) iyi, (b) kötü
(c) orta


2.4 Deneysel Sınıf Dağılımları ve Çapak Eğilimi

Deneysel çalışmada kullanılan üç farklı devir hızında (360 dev/dak, 535 dev/dak ve 715 dev/dak) elde edilen deliklerin çapak sınıfları istatistiksel olarak değerlendirilmiş ve her parametre için ortalama çapak şiddeti hesaplanmıştır. Hesaplama, sınıflara uygun skorlar atanarak (İyi = 1, orta = 2, kötü = 3) yapılmış, tablo 2.2’de görüldüğü üzere her hız için ortalama skor değerleri elde edilmiştir.

Tablo 2-2: Devir hızına göre delik sınıfı dağılımları ve ortalama çapak şiddeti

Devir n (dev/dak)	İyi	Orta	Kötü	Toplam	Ortalama Skor
360	35	15	10	60	1,58
535	17	26	17	60	2,00
715	4	20	36	60	2,53


Şekil 2.5’te, her kesme parametresine ait deliklerin görsel inceleme sonucu belirlenen sınıf skorlarının ortalaması alınarak göreceli çapak şiddeti değişimi görülmektedir. 360 dev/dak hızında çapak oluşumu oldukça düşük seviyede gerçekleşmiş, kenar bütünlüğü büyük ölçüde korunmuştur. 535 dev/dak hızında çapak şiddeti orta düzeye yükselmiş, delik çıkış kenarlarında kısmi plastik deformasyon ve düzensiz çapak yapıları gözlenmiştir. 715 dev/dak hızında ise çapak şiddetinde belirgin bir artış meydana gelmiş, yüksek sıcaklık ve artan deformasyon etkisiyle çıkış kenarlarında kalın çapak tabakaları oluşmuştur. Bu eğilim, artan devir hızıyla birlikte kesme bölgesinde yükselen sıcaklık ve plastik akmanın, çapak oluşumunu kuvvetlendirdiğini göstermektedir.



Şekil 2-5: Devir hızına göre deliklerde gözlenen ortalama çapak şiddeti değişimi

2.5 Veri Artırma

Modelin farklı eğitim senaryolarında genelleme kabiliyetini artırmak amacıyla 180 adet orijinal görüntü, manuel veri artırma yöntemleriyle genişletilmiştir. Şekil 2.6'daki örnekte görüldüğü gibi; her orijinal görüntüye sırasıyla saat yönünde 180° döndürme (D180°), yatay çevirme (YÇ), Çevirme–döndürme kombinasyonu (ÇD) uygulanmış ve toplam görüntü sayısı 720'ye çıkarılmıştır. Artırmalar Roboflow üzerinde, train/val/test bölünmesinden önce uygulanmış; artırılmış görüntüler tüm alt kümelere (eğitim, doğrulama, test) dağıtılmıştır. Ham, etiketli ve artırılmış veriler standart klasör yapısı içinde saklanmıştır.



Şekil 2-6: Veri artırma adımlarına ait örnek görseller

2.6 Veri Setleri

Bu çalışmada, farklı veri artırma stratejileri ve karar eşiği (k.e.) değerleri kullanılarak sekiz temel veri seti ile toplamda onaltı oluşturulmuştur. K.e. değeri, modelin hassasiyetini ve seçiciliğini değerlendirmek için farklı senaryolarda (k.e. = 0,25 ve k.e. = 0,65) denenmiştir. Her veri setinin; veri kombinasyonu, toplam görüntü sayısı ve karar eşiği değerleri ile eğitim, doğrulama ve test oranları Şekil 2.7'de sunulmuştur.

- Veri Seti 1:
Yalnızca orijinal görüntülerden oluşmaktadır. Toplam 180 görüntü içermekte olup veri artırma uygulanmamıştır.
Karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak belirlenmiştir.
- Veri Seti 2:
Orijinal veriler YÇ (yatay çevirme) işlemiyle artırılmıştır. Böylece toplam 360 görüntü elde edilmiştir.
Karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak seçilmiştir.
- Veri Seti 3:
Orijinal veriler D180° (180° döndürme) artırmasıyla çoğaltılmıştır.

Toplam 360 görüntü kullanılmış olup, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak uygulanmıştır.

- Veri Seti 4:
Orijinal veriler ÇD (kombinasyonlu: YÇ + D180°) artırmasıyla genişletilmiştir.
Bu veri setinde 360 görüntü bulunmakta, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65'tir.
- Veri Seti 5:
Orijinal veriler YÇ + D180° artırımlarıyla oluşturulmuştur.
Toplam 540 görüntü elde edilmiş olup, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak belirlenmiştir.
- Veri Seti 6:
Orijinal veriler YÇ + ÇD artırımlarıyla genişletilmiştir.
Toplam 540 görüntü kullanılmış, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak seçilmiştir.
- Veri Seti 7:
Orijinal veriler D180° + ÇD kombinasyonu ile artırılmıştır.
Bu veri seti 540 görüntü içermekte olup, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak uygulanmıştır.
- Veri Seti 8:
Orijinal veriler YÇ + D180° + ÇD artırımlarıyla oluşturulmuştur.
Böylece toplam 720 görüntü elde edilmiş, karar eşiği değerleri k.e. = 0,25 ve k.e. = 0,65 olarak sınanmıştır.

Tüm veri setlerinde model mimarisi YOLOv10n, eğitim parametreleri ise 200 epoch, img size = 640, ve train/validation/test oranları sırasıyla %70 / %15 / %15 olarak sabit tutulmuştur.

Veri Seti	Veri Kombinasyonu	Karar Eşiği	Görüntü Sayısı	İmgsz	Model	Epochs	Train (%)	Validation (%)	Test (%)
Veri Seti 1	Orijinal	0.65	180	640	YOLOv10n	200	70	15	15
Veri Seti 1	Orijinal	0.25	180	640	YOLOv10n	200	70	15	15
Veri Seti 2	Orijinal + YÇ	0.65	360	640	YOLOv10n	200	70	15	15
Veri Seti 2	Orijinal + YÇ	0.25	360	640	YOLOv10n	200	70	15	15
Veri Seti 3	Orijinal + D180°	0.65	360	640	YOLOv10n	200	70	15	15
Veri Seti 3	Orijinal + D180°	0.25	360	640	YOLOv10n	200	70	15	15
Veri Seti 4	Orijinal + ÇD	0.65	360	640	YOLOv10n	200	70	15	15
Veri Seti 4	Orijinal + ÇD	0.25	360	640	YOLOv10n	200	70	15	15
Veri Seti 5	Orijinal + YÇ + D180°	0.65	540	640	YOLOv10n	200	70	15	15
Veri Seti 5	Orijinal + YÇ + D180°	0.25	540	640	YOLOv10n	200	70	15	15
Veri Seti 6	Orijinal + YÇ + ÇD	0.65	540	640	YOLOv10n	200	70	15	15
Veri Seti 6	Orijinal + YÇ + ÇD	0.25	540	640	YOLOv10n	200	70	15	15
Veri Seti 7	Orijinal + D180° + ÇD	0.65	540	640	YOLOv10n	200	70	15	15
Veri Seti 7	Orijinal + D180° + ÇD	0.25	540	640	YOLOv10n	200	70	15	15
Veri Seti 8	Orijinal + YÇ + D180° + ÇD	0.65	720	640	YOLOv10n	200	70	15	15
Veri Seti 8	Orijinal + YÇ + D180° + ÇD	0.25	720	640	YOLOv10n	200	70	15	15

Şekil 2-7: Tüm veri setlerinin özellik tablosunun görsel gösterimi

2.7 Eğitim Parametreleri

Bu çalışmada tüm veri setlerinde YOLOv10n mimarisi kullanılmıştır. Eğitimler, her veri seti için aynı hiperparametrelerle yürütülmüştür: 200 epoch, 8 batch size ve 640×640 px giriş boyutu. Öğrenme oranı ve optimizasyon algoritması (SGD) varsayılan değerlerde tutulmuştur. Modelin hassasiyet ve seçiciliğini değerlendirebilmek amacıyla, her veri setinde karar eşiği (k.e.) farklı senaryolar altında test edilmiştir. Tüm veri setlerinde k.e. = 0,25 ve k.e. = 0,65 değerleri uygulanmış, bu sayede düşük ve yüksek eşik koşullarındaki performans değişimleri gözlemlenmiştir. Ayrıca her veri setinde eğitim verisi %70, doğrulama verisi %15 ve test verisi %15 oranlarında olacak şekilde ayrılmıştır.

2.8 Model Performans Metrikleri

Bu çalışmada kullanılan YOLOv10n tabanlı sınıflandırma modelinin başarısı, yalnızca genel doğruluk oranı (accuracy) üzerinden değil, farklı hata türlerini de dikkate alan kapsamlı metriklerle değerlendirilmiştir.

Modelin “iyi”, “orta” ve “kötü” çapak kalitesi sınıflarını ayırt etme performansı, ayrıca yanlışlıkla arka plan (background) olarak işaretlenen örneklerin yanlış negatif (FN) kapsamında ele alınmasıyla analiz edilmiştir.

Bu yöntem, çapak tespiti probleminde modelin üretim gerçekliğine uygun hata davranışını ortaya koymayı amaçlamaktadır.

2.8.1 Karışıklık Matrisi ve Temel Kavramlar

Bu tez çalışması kapsamında, çapak sınıflandırma probleminde karışıklık matrisindeki kavramlar şu şekilde tanımlanmıştır (Tablo 2.3):

- True Positive (TP): Gerçekte “iyi”, “orta” veya “kötü” sınıfına ait bir deliğin, model tarafından da aynı sınıfta doğru biçimde tahmin edilmesidir.
- False Positive (FP): Gerçekte ait olmadığı bir sınıfa yanlışlıkla atanmış deliklerdir. Örneğin “iyi” bir deliğin model tarafından “kötü” olarak tahmin edilmesi bu duruma örnektir.
- True Negative (TN): Belirli bir sınıfa ait olmayan bir deliğin, model tarafından da o sınıfa dahil edilmemesidir.

Örneğin “orta” sınıfa ait olmayan bir deliğin “orta” olarak işaretlenmemesi TN olarak değerlendirilmiştir.

- False Negative (FN):

Gerçekte belirli bir sınıfa ait olan bir deliğin, model tarafından yanlış biçimde başka bir sınıfa ya da arka plan (background) olarak değerlendirilmesidir.

Bu çalışmada background tahminleri doğrudan FN olarak kabul edilmiştir, çünkü bu durum modelin çapağı gözden kaçırdığı anlamına gelmektedir.

Bu yaklaşım, FN’nin en kritik hata türü olduğunu vurgulamaktadır; çünkü gözden kaçan çapaklar, üretim kalitesi ve güvenliği açısından doğrudan olumsuz sonuçlar doğurabilmektedir.

Tablo 2-3: Tez bağlamında TP–FP–TN–FN anlamları

Kısaltma	Tez Bağlamındaki Anlamı	Örnek Durum	Etkisi
TP	Gerçek sınıf = Tahmin sınıfı	“Kötü” çapaklı delik → “Kötü” olarak tahmin	Doğru sınıflandırma
FP	Yanlış sınıfa atanmış delik	“İyi” delik “Kötü” olarak tahmin	Gereksiz işlem / yanlış uyarı
TN	Sınıfa ait olmayan delik doğru dışlanmış	“Orta” olmayan “Orta” olarak işaretlenmemiş	Normal durum
FN	Gerçek sınıf gözden kaçmış veya arka plan olarak değerlendirilmiş	“Kötü” delik, “Arka plan” veya “İyi” olarak tahmin	Kritik hata (kaçırılmış çapak)

2.8.2 Doğruluk (Accuracy)

Accuracy, modelin genel doğruluk eğilimini göstermek için kullanılmıştır ancak sınıf dengesizliği nedeniyle tek başına değerlendirme ölçütü olarak alınmamıştır [80].

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad [80]$$

2.8.3 Kesinlik (Precision)

Precision, özellikle gereksiz apak uyarılarının (FP) azaltılmasında nem tařımaktadır [80].

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad [80]$$

apak sınıflandırma bağlamında yanlış pozitifler, rneğın gerekte “iyi” olan bir deliğın “kt” olarak etiketlenmesi, gereksiz apak giderme iřlemlerine yol aabileceğinden retim sreci aısından nem tařımaktadır.

2.8.4 Duyarlılık (Recall)

Recall, gzden kaan apağın (FN) azaltılması aısından kritik nemdedir.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad [80]$$

Yanlış negatifler, yani apaklı bir deliğın “iyi” ya da “arka plan” olarak değeriendirilmesi, retim kalitesi zerinde kritik hata kaynağı oluřturduğundan Recall metriğı bu alıřmada byk nem arz etmektedir.

2.8.5 F1 Skoru

F1-Score, Precision ve Recall arasındaki dengeyi temsil ettiğı iin modelin genel bařarısını zetleyen temel metrik olarak kabul edilmiřtir. Sınıflar arasında dengesizliklerin bulunduğı apak sınıflandırma probleminde F1 skoru, model performansını en gereki řekilde ortaya koyan ltlerden biri olmuřtur.

$$\text{F1} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}) \quad [80]$$


Her veri seti ve karar eřiğı (k.e.) kombinasyonu iin bu metrikler hesaplanmıř, karřılařtırmalı sonular blm 3.2’deki deneysel alıřmalar kısmında detaylı biimde sunulmuřtur.

2.8.6 Mevcut Tez Çalışmasına Yönelik Yaklaşım

Bu tez kapsamında, arka plan olarak tahmin edilen örnekler yanlış negatif (FN) kapsamında değerlendirilmiştir. Böylece modelin başarısı, gerçek üretim koşullarında çapakların gözden kaçmasının yaratacağı kalite sorunlarını da dikkate alacak biçimde ölçülmüştür.

2.9 Çalışma Akışı

Çalışmanın bütün adımları, delik delme sürecinden model değerlendirmesine kadar uzanan bir iş akışı şeklinde organize edilmiştir. Bu süreç; delik delme, mikroskop görüntüleme, veri etiketleme, veri artırma, model eğitimi, karar eşiği ve nihai performans değerlendirmesini kapsamaktadır. Uygulamanın şematik akışı Şekil 2.8’de verilmiştir.



Şekil 2-8: Çalışma akışı

2.10 YOLOv10n Modeli Eğitim ve Test Akışı

Mevcut tez çalışmasında kullanılan YOLOv10n modeli, çapak sınıflarını öğrenebilmesi için özel olarak oluşturulan veri setiyle eğitilmiştir. Modelin eğitimi ve performans değerlendirmesi süreci Şekil 2.9'daki gibi üç aşamalı bir veri ayrımı ile gerçekleştirilmiştir.

2.10.1 Eğitim Kümesi (Train Set)

Veri setinin büyük bir bölümü eğitim için ayrılmıştır. Bu kümede yer alan görsellerdeki “İYİ”, “ORTA” ve “KÖTÜ” etiketleri, modelin sınıf ayrımlarını öğrenebilmesini sağlamıştır. Eğitim sürecinde model, kutu kaybı (box loss), sınıflandırma kaybı (cls loss) ve dağılım kaybı (dfl loss) gibi hata ölçütlerini minimize ederek çapakların görsel özelliklerini öğrenmiştir.

2.10.2 Doğrulama Kümesi (Validation Set)

Eğitim sırasında modelin performansını izlemek ve aşırı uyum (overfitting) riskini kontrol etmek amacıyla doğrulama kümesi kullanılmıştır. Bu küme, eğitimin her döneminde modelin görmediği örneklerden oluşmuş ve ara sonuçlar burada değerlendirilmiştir. Böylece modelin yalnızca ezber değil, genelleme yapıp yapmadığı anlaşılmıştır.


2.10.3 Test Kümesi (Test Set)

Modelin nihai performansını değerlendirmek için eğitim sürecinde hiç görmediği test görselleri kullanılmıştır. Bu aşamada model, yalnızca öğrendiği bilgiye dayanarak yeni görüntüleri “İYİ”, “ORTA” veya “KÖTÜ” olarak sınıflandırmıştır. Bazı durumlarda model güven eksikliği nedeniyle çapaklı delikleri “arka plan (background)” olarak değerlendirmiş, bu da yanlış negatif (FN) olarak kaydedilmiştir.

2.10.4 Sonuçların Değerlendirilmesi

Test kümesindeki tahminler, insan tarafından belirlenen gerçek etiketlerle karşılaştırılarak doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru gibi metrikler hesaplanmıştır. Ayrıca karışıklık matrisi (confusion matrix) yardımıyla hangi sınıfların doğru,

hangilerinin ise yanlış sınıflandırıldığı görsel olarak analiz edilmiştir. Bu akış sayesinde YOLOv10n modeli, eğitimde öğrendiği örüntüleri hiç görmediği veriler üzerinde sınanmış ve çapakların otomatik sınıflandırılmasında güvenilirlik düzeyi nesnel olarak ortaya konmuştur.



Şekil 2-9: YOLOv10n modeli eğitim ve test akışı

3. BULGULAR VE TARTIŞMA


3.1 Ön Çalışma Analiz ve Bulguları

Bu tez çalışmasında uygulanacak parametre ve uygulanacak data verilerinin ihtiyacının belirlenmesine yönelik ön çalışma gerçekleştirilmiştir. Tez deneysel sürecine geçilmeden önce, sınırlı sayıda delik üzerinde ön denemeler gerçekleştirilmiş ve elde edilen bulgular değerlendirilmiştir. Ön çalışma kapsamında, Roboflow ortamında çapak büyüklüğüne göre farklı sınıflarda etikelenen bazı delik görüntüleri ve aynı deliklerin model eğitimi sonrasındaki tahmin sınıfları karşılaştırmalı olarak incelenmiştir. Bu karşılaştırmalar Şekil 3.1’de görsel olarak sunulmuştur. Karşılaştırılan görseller, farklı kesme parametreleri altında delinmiş verilerdir. 1720 dev/dak–0,1 mm/dev koşulundaki delik “çok kötü”, aynı devirde 0,2 mm/dev ilerleme ile işlenen delik “normal” ve 1070 dev/dak–0,2 mm/dev koşulundaki delik “iyi” sınıfında yer almaktadır. Bu örnekler, ilerlemenin artmasının (aynı devirde) çapak oluşumunu azalttığını ve kaliteyi iyileştirdiğini gösterirken, daha düşük devir ile uygun ilerlemenin birlikte kullanılmasının ise çapak oluşumunu daha da sınırlayabildiğini göstermektedir. Model sonuçları incelendiğinde, üç deliğin de doğru sınıfta tahmin edildiği görülmüş ve böylece devir sayısı ile ilerleme hızının çapak oluşum kalitesine etkisi hem önceden yapılan görsel sınıflandırma hem de modelin eğitildikten sonra otomatik sınıflandırma performansı ile tutarlı biçimde olduğu anlaşılmıştır.

Şekil 3.1’deki eğitim sürecine ait kayıp fonksiyonları ve performans metrikleri incelendiğinde; kutu kaybı (box_loss), sınıf kaybı (cls_loss) ve dağılım kaybının (dfl_loss) artan epoch sayısı ile birlikte düzenli biçimde azaldığı; buna karşılık precision, recall ve mAP (mAP@50 ve mAP@50–95) değerlerinde yükseliş eğilimi olduğu görülmüştür. Bu bulgular, modelin çapakların konumunu daha doğru belirlediğini, sınıf ayrımlarını giderek daha iyi öğrendiğini ve farklı IoU eşiklerinde dahi güvenilir sonuçlar üretebildiğini göstermektedir (Şekil 3.1).

Sonuç olarak ön çalışma, sınırlı veri sayısına rağmen, delik delme parametrelerinin çapak oluşumu üzerindeki etkisini açıkça ortaya koymuş ve derin öğrenme tabanlı yaklaşımın bu tür yüzey kusurlarını başarıyla sınıflandırabildiğini doğrulamıştır. Tez çalışmasının gerçekleştirilebilmesi için; USB mikroskop görüntüsüne, çok sayıda delik görüntüsüne ait geniş bir veriye ve delici çok sayıda matkap ucuna ihtiyacının olması nedeniyle BAP-24-1010-002 nolu BAP projesinden destek alınmış ve tez çalışması görüntü temelli çok geniş veri üzerinde çalışılarak başarı ile tamamlanmıştır. Bu doğrulama, daha kapsamlı veri setleriyle yürütülecek ana çalışma

için yöntemsel bir temel sunmaktadır. Ayrıca, uygulanacak kesme parametreleri literatür araştırması yanında, uygulanan ön çalışma neticesinde belirlenmiştir [81].



Şekil 3-1: Parametre-1 görüntü işleme (a) öncesi ve (b) sonrası; parametre-2 görüntü işleme (c) öncesi ve (d) sonrası; parametre-3 görüntü işleme (e) öncesi ve (f) sonrası; (g) modelin eğitim grafikleri; (h) modelin doğrulama grafikleri.

3.2 Deneysel Çalışmalar


3.2.1 En Başarılı Veri Setine Ait (Veri Seti 8, K.E. = 0,25) Gerçek ve Model Tahminlerinin Karşılaştırmalı Analizi

Bu başlık altında sunulan şekillerdeki temsili örnekler, her parametre setinden modelin tahmin ettiği çıktılarına ait olup, modelin en yüksek başarı gösterdiği Veri Seti 8, K.E. = 0,25 modelinden alınmıştır. Bu modelden elde edilen görseller, modelin sınıf ayrımlarını doğru biçimde yapabildiğini göstermek amacıyla seçilmiştir. Modelin genel performansına ilişkin ayrıntılı değerlendirme ise bir sonraki bölümde nicel metrikler üzerinden sunulmuştur.

Her parametre setinden seçilen 10 temsili delik için modelin tahmin performansı görsel olarak karşılaştırılmıştır. Şekillerde sol tarafta, deneysel çalışma kapsamında Roboflow ortamında


yapılan gerçek etiketleme yer almakta olup delikler ait oldukları sınıfa göre kırmızı kutu ile işaretlenmiştir. Sağ tarafta ise modelin tahmin çıktısı gösterilmektedir. Bu tahminlerde kutular sınıfa göre renklendirilmiştir (örneğin, iyi sınıfı mavi, orta sınıfı beyaz, kötü sınıfı turkuaz ile gösterilmiştir). Ayrıca tahmin edilen kutuların üzerinde modelin güven skoru (confidence) değerleri yer almaktadır. Böylece görseller, gerçek sınıf ile tahmin edilen sınıfın örtüşüp örtüşmediğini açık biçimde ortaya koymaktadır. Modelin doğru sınıflandırdığı, yanlış etiketlediği veya hiçbir sınıf ataması yapmayarak arka plan olarak bıraktığı örnekler net şekilde izlenebilmektedir.

Şekil 3.2’de, 360 dev/dak – 0,30 mm/dev altında incelenen 10 deliğin 8’i model tarafından doğru sınıflandırılmıştır. Bir örnekte (1-26) gerçek sınıf iyi olmasına rağmen model tarafından orta olarak tahmin edilmiş, bir örnekte ise (1-59-H180) model tarafından, hiçbir sınıf olarak tahmin edilmemiş (arka plan) ve bu durum başarı metriklerinde (FN) olarak hesaba katılmıştır. Genel olarak düşük devirli deliklerde çapak morfolojisi daha düzenli olduğundan modelin doğru sınıflandırma başarısı yüksek çıkmış, sınıf kaçırma yalnızca sınır vakalarda gözlenmiştir.



Şekil 3-2: 360 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları


Şekil 3.3'te, 715 dev/dak – 0,30 mm/dev altında incelenen 10 deliğin 9'u model tarafından doğru sınıflandırılmıştır. Bir örnekte (2-H50) gerçek sınıf orta olmasına rağmen model tarafından iyi olarak tahmin edilmiştir. Bu parametre setinde kötü ve orta sınıflarındaki delikler yüksek güven skorlarıyla tespit edilmiştir. Orta-yüksek devir koşullarında çapak geometrisi daha değişken olmasına rağmen model genel olarak başarılı sonuçlar vermiştir.



Şekil 3-3: 715 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları

Şekil 3.4'te, 535 dev/dak – 0,30 mm/dev altında incelenen 10 deliğin tamamı model tarafından doğru sınıflandırılmıştır. İyi, orta ve kötü sınıfları arasındaki geçişler net biçimde ayırt

edilmiştir. Özellikle orta sınıf deliklerde tahmin güven skorlarının %80–98 aralığında olduğu gözlenmiştir. Bu sonuç, modelin orta devir hızında oluşan çapak morfolojisini başarılı şekilde ayırt edebildiğini göstermektedir.



Şekil 3-4: 535 dev/dak. – 0,30 mm/dev için 10 örneğin gerçek–tahmin karşılaştırmaları

3.2.2 Veri Seti Bazlı Bulgular

Tezde arka plan (background) sınıfı ayrı bir sınıf olarak değerlendirilmemiş, modelin çapak yerine arka planı seçtiği durumlar ilgili sınıfın FN (False Negative) hanesine eklenerek hesaplamalar yapılmıştır.

3.2.2.1 Veri Seti 1 (K.E. = 0,65)

Şekil 3.5'teki karışıklık matrisine göre model; İyi sınıfında 12/20 (1 → Orta, 7 → Arka Plan), Kötü sınıfında 8/12 (4 → Arka Plan), Orta sınıfında ise 10/22 (6 → İyi, 3 → Kötü, 3 → Arka Plan) oranında doğru tahmin üretmiştir. Hataların önemli bir bölümü Orta ↔ İyi/Kötü karışmaları ile, kısmen de arka plan olarak elenen örneklerden oluşmaktadır. Bu durum, sınırları belirsiz veya kontrastı düşük çapak görünümünde modelin sınıf ayırımında zorlandığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 12, FP = 6, FN = 8, TN = 28
- Kötü sınıfı: TP = 8, FP = 3, FN = 4, TN = 39
- Orta sınıfı: TP = 10, FP = 1, FN = 12, TN = 31

Toplamda TP = 30, FP = 10, FN = 24, TN = 98 olarak bulunmuştur.


Bu değerlere göre modelin; makro ortalama metrikleri:

Precision = %76,77, Recall = %57,37, F1-Score = %64,44, Accuracy = %55,56 olarak hesaplanmıştır (Tablo 3.1).

Arka plan (background) olarak değerlendirilen örnekler, ilgili sınıfların yanlış negatif (FN) kapsamında ele alınmıştır.

Tablo 3-1: Veri Seti 1 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	12	6	8	28	0,667	0,600	0,632	0,741
Kötü	8	3	4	39	0,727	0,667	0,696	0,870
Orta	10	1	12	31	0,909	0,455	0,606	0,759
Makro Ortalama					0,768	0,574	0,644	0,556



Şekil 3-5: Veri Seti 1 (k.e. = 0,65) için karışıklık matrisi

3.2.2.2 Veri Seti 1 (K.E. = 0,25)

Şekil 3.6'daki karışıklık matrisine göre model; İyi sınıfında 18/20 (1 → Orta, 1 → Arka Plan), Kötü sınıfında 11/12 (1 → Orta), Orta sınıfında ise 12/22 (6 → İyi, 3 → Kötü, 1 → Arka Plan) doğru tahmin üretmiştir. Hataların önemli bir bölümü Orta ↔ İyi/Kötü karışmalarından oluşmaktadır. Bu durum, sınırları belirsiz veya kontrastı düşük çapak görünümünde sınıf ayrımının zorlaştığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi: TP = 18, FP = 6, FN = 2, TN = 28
- Kötü: TP = 11, FP = 3, FN = 1, TN = 39
- Orta: TP = 12, FP = 2, FN = 10, TN = 30

Toplamda TP = 41, FP = 11, FN = 13, TN = 97 olarak bulunmuştur.


Bu değerlere göre modelin; makro ortalama metrikleri:

Precision = %79,8, Recall = %78,7, F1-Score = %77,7, Accuracy (makro) = %85,2 olarak hesaplanmıştır (Tablo 3.2).

Arka plan (background) olarak değerlendirilen örnekler, ilgili sınıfların yanlış negatif (FN) kapsamında ele alınmıştır.

Tablo 3-2: Veri Seti 1 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	18	6	2	28	0,75	0,9	0,818	0,852
Kötü	11	3	1	39	0,786	0,917	0,846	0,926
Orta	12	2	10	30	0,857	0,545	0,667	0,778
Macro Ortalama					0,798	0,787	0,777	0,852

**Şekil 3-6:** Veri Seti 1 (k.e. = 0,25) için karışıklık matrisi

3.2.2.3 Veri Seti 2 (k.e. = 0,65)

Şekil 3.7’deki karışıklık matrisine göre model; İyi sınıfında 12/21 (8 → Orta, 1 → Arka Plan), Kötü sınıfında 10/14 (1 → Orta, 3 → Arka Plan), Orta sınıfında ise 19/19 oranında doğru tahmin üretmiştir. Yanlışların toplam 13 örnekle sınırlı olduğu görülmektedir. Bunların dokuzu sınıflar arası karışma, dördü ise arka plan olarak elenmiştir. Bu durum, özellikle “iyi–orta” geçiş bölgesindeki örneklerde modelin benzer doku özelliklerinden etkilenerek kararsız kaldığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 12, FP = 0, FN = 9, TN = 33
- Kötü sınıfı: TP = 10, FP = 0, FN = 4, TN = 40

- Orta sınıfı: TP = 19, FP = 9, FN = 0, TN = 26

Toplamda TP = 41, FP = 9, FN = 13, TN = 99 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %89,3, Recall = %76,2, F1-Score = %79,0, Accuracy = %86,4 olarak hesaplanmıştır (Tablo 3.3).

Arka plan (background) olarak değerlendirilen örnekler, ilgili sınıfların yanlış negatif (FN) kapsamında ele alınmıştır.

Tablo 3-3: Veri Seti 2 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	12	0	9	33	1	0,571	0,727	0,833
Kötü	10	0	4	40	1	0,714	0,833	0,926
Orta	19	9	0	26	0,679	1	0,809	0,833
Macro Ortalama					0,893	0,762	0,79	0,864



Şekil 3-7: Veri Seti 2 (k.e. = 0,65) için karışıklık matrisi

3.2.2.4 Veri Seti 2 (k.e. = 0,25)

Şekil 3.8'deki karışıklık matrisine göre model; İyi sınıfında 13/21 (8 → Orta), Kötü sınıfında 12/14 (1 → Orta, 1 → Arka Plan), Orta sınıfında ise 19/19 oranında doğru tahmin üretmiştir. Yanlışların toplam 10 örnekle sınırlı olduğu görülmektedir. Bunların dokuzu sınıflar arası karışma (özellikle İyi → Orta) ve biri ise arka plan olarak elenmiştir. Bu durum, modelin özellikle “iyi” sınıfındaki düşük kontrastlı veya kısmen çapaklı bölgelerde, “orta” sınıfı ile karışma eğilimi gösterdiğini ortaya koymaktadır.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 13, FP = 0, FN = 8, TN = 33
- Kötü sınıfı: TP = 12, FP = 0, FN = 2, TN = 40
- Orta sınıfı: TP = 19, FP = 9, FN = 0, TN = 26

Toplamda TP = 44, FP = 9, FN = 10, TN = 99 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %89,3, Recall = %82,5, F1-Score = %83,2, Accuracy = %88,3 olarak hesaplanmıştır (Tablo 3.4).

Arka plan (background) olarak değerlendirilen örnekler, ilgili sınıfların yanlış negatif (FN) kapsamında ele alınmıştır.

Tablo 3-4: Veri Seti 2 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	13	0	8	33	1	0,619	0,765	0,852
Kötü	12	0	2	40	1	0,857	0,923	0,963
Orta	19	9	0	26	0,679	1	0,809	0,833
Macro Ortalama					0,893	0,825	0,832	0,883



Şekil 3-8: Veri Seti 2 (k.e. = 0,25) için karışıklık matrisi

3.2.2.5 Veri Seti 3 (k.e. = 0,65)

Şekil 3.9'daki karışıklık matrisine göre model; İyi sınıfında 18/28 (1 → Orta, 3 → Arka Plan), Kötü sınıfında 11/17 (5 → Arka Plan), Orta sınıfında ise 7/17 (6 → İyi, 1 → Kötü, 2 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 18 örnekle sınırlı olduğu görülmektedir. Bunların 8'i sınıflar arası karışma, 10'u ise arka plan (background) olarak elenmiştir. Bu durum, özellikle "orta" sınıfın bazı sınır örneklerinde modelin "iyi" sınıfına kayma eğilimi gösterdiğini ortaya koymaktadır.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 18, FP = 6, FN = 4, TN = 26
- Kötü sınıfı: TP = 11, FP = 1, FN = 5, TN = 37
- Orta sınıfı: TP = 7, FP = 1, FN = 9, TN = 37

Toplamda TP = 36, FP = 8, FN = 18, TN = 100 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %84,7, Recall = %64,8, F1-Score = %71,7, Accuracy = %84,0 olarak hesaplanmıştır (Tablo 3.5).

Arka plan olarak etiketlenen örnekler, ilgili sınıfların yanlış negatif (FN) değerlerine dahil edilmiştir.

Tablo 3-5: Veri Seti 3 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	18	6	4	26	0,75	0,818	0,783	0,815
Kötü	11	1	5	37	0,917	0,688	0,786	0,889
Orta	7	1	9	37	0,875	0,438	0,583	0,815
Macro Ortalama					0,847	0,648	0,717	0,84



Şekil 3-9: Veri Seti 3 (k.e. = 0,65) için karışıklık matrisi

3.2.2.6 Veri Seti 3 (k.e. = 0,25)

Şekil 3.10'daki karışıklık matrisine göre model; İyi sınıfında 20/22 (1 → Orta, 1 → Arka Plan), Kötü sınıfında 13/16 (3 → Orta), Orta sınıfında ise 7/16 (6 → İyi, 1 → Kötü, 2 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 14 örnekle sınırlı olduğu görülmektedir. Bunların 11'i sınıflar arası karışma (özellikle Orta → İyi) ve 3'ü background (arka plan) olarak elenmiştir. Bu durum, “orta” sınıfın düşük kontrastlı ve sınır geçişlerinde model tarafından “iyi” sınıfına kaydırıldığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 20, FP = 6, FN = 2, TN = 26
- Kötü sınıfı: TP = 13, FP = 1, FN = 3, TN = 37

- Orta sınıfı: TP = 7, FP = 4, FN = 9, TN = 34

Toplamda TP = 40, FP = 11, FN = 14, TN = 97 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %77,8, Recall = %72,0, F1-Score = %74,0, Accuracy = %84,6 olarak hesaplanmıştır (Tablo 3.6).

Arka plan (background) olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) kapsamında değerlendirilmiştir.

Tablo 3-6: Veri Seti 3 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	20	6	2	26	0,769	0,909	0,833	0,852
Kötü	13	1	3	37	0,929	0,812	0,867	0,926
Orta	7	4	9	34	0,636	0,438	0,519	0,759
Macro Ortalama					0,778	0,72	0,74	0,846



Şekil 3-10: Veri Seti 3 (k.e. = 0,25) için karışıklık matrisi

3.2.2.7 Veri Seti 4 (k.e. = 0,65)

Şekil 3.11'deki karışıklık matrisine göre model; İyi sınıfında 16/25 (5 → Orta, 4 → Arka Plan), Kötü sınıfında 9/15 (2 → Orta, 4 → Arka Plan), Orta sınıfında ise 9/21 (5 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 20 örnekle sınırlı olduğu görülmektedir. Bunların 7'si sınıflar arası karışma, 13'ü ise background (arka plan) olarak elenmiştir. Bu durum, özellikle yüksek karar eşiğinde (0,65), modelin belirsiz veya düşük kontrastlı çapak örneklerini “arka plan” olarak değerlendirme eğiliminin arttığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 16, FP = 0, FN = 9, TN = 29
- Kötü sınıfı: TP = 9, FP = 0, FN = 6, TN = 39
- Orta sınıfı: TP = 9, FP = 7, FN = 5, TN = 33

Toplamda TP = 34, FP = 7, FN = 20, TN = 101 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %85,4, Recall = %62,8, F1-Score = %71,0, Accuracy = %83,3 olarak hesaplanmıştır (Tablo 3.7).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-7: Veri Seti 4 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	16	0	9	29	1	0,64	0,78	0,833
Kötü	9	0	6	39	1	0,6	0,75	0,889
Orta	9	7	5	33	0,562	0,643	0,6	0,778
Macro Ortalama					0,854	0,628	0,71	0,833



Şekil 3-11: Veri Seti 4 (k.e. = 0,65) için karışıklık matrisi

3.2.2.8 Veri Seti 4 (k.e. = 0,25)

Şekil 3.12'deki karışıklık matrisine göre model; İyi sınıfında 18/25 (6 → Orta, 1 → Arka Plan), Kötü sınıfında 11/15 (4 → Orta), Orta sınıfında ise 13/24 (1 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 12 örnekle sınırlı olduğu görülmektedir. Bunların 10'u sınıflar arası karışma, 2'si background (arka plan) olarak elenmiştir. Bu durum, düşük karar eşiğinde (0,25), modelin çapak sınırlarını daha esnek değerlendirdiğini ve sınıflar arası geçişlerde kısmen karışma eğilimi gösterdiğini ortaya koymaktadır.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 18, FP = 0, FN = 7, TN = 29
- Kötü sınıfı: TP = 11, FP = 0, FN = 4, TN = 39
- Orta sınıfı: TP = 13, FP = 10, FN = 1, TN = 30

Toplamda TP = 42, FP = 10, FN = 12, TN = 98 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %85,5, Recall = %79,4, F1-Score = %79,5, Accuracy = %86,4 olarak hesaplanmıştır (Tablo 3.8).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-8: Veri Seti 4 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	18	0	7	29	1	0,72	0,837	0,87
Kötü	11	0	4	39	1	0,733	0,846	0,926
Orta	13	10	1	30	0,565	0,929	0,703	0,796
Macro Ortalama					0,855	0,794	0,795	0,864



Şekil 3-12: Veri Seti 4 (k.e. = 0,25) için karışıklık matrisi

3.2.2.9 Veri Seti 5 (k.e. = 0,65)

Şekil 3.13'deki karışıklık matrisine göre model; İyi sınıfında 24/30 (1 → Orta, 4 → Arka Plan), Kötü sınıfında 15/24 (5 → Orta, 4 → Arka Plan), Orta sınıfında ise 21/34 (1 → İyi, 6 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 21 örnekle sınırlı olduğu görülmektedir. Bunların 7'si sınıflar arası karışma, 14'ü ise background (arka plan) olarak elenmiştir. Bu durum, özellikle yüksek karar eşiğinde (0,65), modelin düşük kontrastlı veya sınır bölgelerinde yer alan çapak görsellerini arka plan olarak değerlendirme eğilimini artırdığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 24, FP = 1, FN = 5, TN = 51

- Kötü sınıfı: TP = 15, FP = 0, FN = 9, TN = 57
- Orta sınıfı: TP = 21, FP = 6, FN = 7, TN = 47

Toplamda TP = 60, FP = 7, FN = 21, TN = 155 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %91,3, Recall = %73,4, F1-Score = %80,7, Accuracy = %88,5 olarak hesaplanmıştır (Tablo 3.9).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-9: Veri Seti 5 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	24	1	5	51	0,96	0,828	0,889	0,926
Kötü	15	0	9	57	1	0,625	0,769	0,889
Orta	21	6	7	47	0,778	0,75	0,764	0,84
Macro Ortalama					0,913	0,734	0,807	0,885



Şekil 3-13: Veri Seti 5 (k.e. = 0,65) için karışıklık matrisi

3.2.2.10 Veri Seti 5 (k.e. = 0,25)

Şekil 3.14'deki karışıklık matrisine göre model; İyi sınıfında 25/32 (4 → Orta), Kötü sınıfında 17/24 (6 → Orta, 1 → Arka Plan), Orta sınıfında ise 25/38 (3 → İyi) oranında doğru tahmin üretmiştir. Yanlışların toplam 14 örnekle sınırlı olduğu görülmektedir. Bunların 13'ü sınıflar arası karışma, 1'i ise background (arka plan) olarak elenmiştir. Bu durum, düşük karar eşiğinde (0,25) modelin çapak bölgelerindeki ince sınırları daha duyarlı biçimde algıladığını, ancak “iyi” ve “orta” sınıfları arasında kısmi geçişler yaşandığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 25, FP = 3, FN = 4, TN = 49
- Kötü sınıfı: TP = 17, FP = 0, FN = 7, TN = 57
- Orta sınıfı: TP = 25, FP = 10, FN = 3, TN = 43

Toplamda TP = 67, FP = 13, FN = 14, TN = 149 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %86,9, Recall = %82,1, F1-Score = %83,3, Accuracy = %88,9 olarak hesaplanmıştır (Tablo 3.10).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-10: Veri Seti 5 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	25	3	4	49	0,893	0,862	0,877	0,914
Kötü	17	0	7	57	1	0,708	0,829	0,914
Orta	25	10	3	43	0,714	0,893	0,794	0,84
Macro Ortalama					0,869	0,821	0,833	0,889



Şekil 3-14: Veri Seti 5 (k.e. = 0,25) için karışıklık matrisi

3.2.2.11 Veri Seti 6 (k.e. = 0,65)

Şekil 3.15'teki karışıklık matrisine göre model; İyi sınıfında 28/34 (1 → Orta, 3 → Arka Plan), Kötü sınıfında 18/24 (5 → Arka Plan), Orta sınıfında ise 17/27 (2 → İyi, 1 → Kötü, 6 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 18 örnekle sınırlı olduğu görülmektedir. Bunların 4'ü sınıflar arası karışma, 14'ü ise background (arka plan) olarak elenmiştir. Bu durum, yüksek karar eşiğinde (0,65) modelin yüksek seçicilik gösterdiğini, ancak düşük kontrastlı veya sınır bölgesinde yer alan çapakları arka plan olarak dışlama eğilimi gösterdiğini ortaya koymaktadır.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 28, FP = 2, FN = 4, TN = 47
- Kötü sınıfı: TP = 18, FP = 1, FN = 5, TN = 57
- Orta sınıfı: TP = 17, FP = 1, FN = 9, TN = 54

Toplamda TP = 63, FP = 4, FN = 18, TN = 158 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %94,2, Recall = %77,0, F1-Score = %84,4, Accuracy = %90,9 olarak belirlenmiştir (Tablo 3.11).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-11: Veri Seti 6 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	28	2	4	47	0,933	0,875	0,903	0,926
Kötü	18	1	5	57	0,947	0,783	0,857	0,926
Orta	17	1	9	54	0,944	0,654	0,773	0,877
Macro Ortalama					0,942	0,77	0,844	0,909



Şekil 3-15: Veri Seti 6 (k.e. = 0,65) için karışıklık matrisi

3.2.2.12 Veri Seti 6 (k.e. = 0,25)

Şekil 3.16'daki karışıklık matrisine göre model; İyi sınıfında 30/35 (1 → Orta, 1 → Arka Plan), Kötü sınıfında 22/24 (1 → Arka Plan), Orta sınıfında ise 20/27 (3 → İyi, 1 → Kötü, 2 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 9 örnekle sınırlı olduğu görülmektedir. Bunların 5'i sınıflar arası karışma, 4'ü ise background (arka plan) olarak elenmiştir. Bu durum, düşük karar eşiğinde (0,25) modelin hem küçük hem de düşük kontrastlı çapak

örneklerini daha etkin yakaladığını, buna karşın sınıf sınırlarında sınırlı sayıda karışma yaşandığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 30, FP = 3, FN = 2, TN = 46
- Kötü sınıfı: TP = 22, FP = 1, FN = 1, TN = 57
- Orta sınıfı: TP = 20, FP = 1, FN = 6, TN = 54

Toplamda TP = 72, FP = 5, FN = 9, TN = 157 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %93,9, Recall = %88,8, F1-Score = %91,0, Accuracy = %94,2 olarak belirlenmiştir (Tablo 3.12).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-12: Veri Seti 6 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	30	3	2	46	0,909	0,938	0,923	0,938
Kötü	22	1	1	57	0,957	0,957	0,957	0,975
Orta	20	1	6	54	0,952	0,769	0,851	0,914
Macro Ortalama					0,939	0,888	0,91	0,942



Şekil 3-16: Veri Seti 6 (k.e. = 0,25) için karışıklık matrisi

3.2.2.13 Veri Seti 7 (k.e. = 0,65)

Şekil 3.17'deki karışıklık matrisine göre model; İyi sınıfında 31/37 (1 → Orta, 1 → Arka Plan), Kötü sınıfında 20/26 (4 → Orta, 1 → Arka Plan), Orta sınıfında ise 16/28 (4 → İyi, 1 → Kötü, 2 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 14 örnekle sınırlı olduğu görülmektedir. Bunların 10'u sınıflar arası karışma, 4'ü ise background (arka plan) olarak elenmiştir. Bu durum, yüksek karar eşiğinde (0,65) modelin seçiciliğini artırdığını, ancak “orta” sınıfta sınır geçişlerinden kaynaklanan karışmaların devam ettiğini göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 31, FP = 4, FN = 2, TN = 44
- Kötü sınıfı: TP = 20, FP = 1, FN = 5, TN = 55
- Orta sınıfı: TP = 16, FP = 5, FN = 7, TN = 53

Toplamda TP = 67, FP = 10, FN = 14, TN = 152 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarı metrikleri:

Precision = %86,7, Recall = %81,2, F1-Score = %83,6, Accuracy = %90,1 olarak belirlenmiştir (Tablo 3.13).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-13: Veri Seti 7 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	31	4	2	44	0,886	0,939	0,912	0,926
Kötü	20	1	5	55	0,952	0,8	0,87	0,926
Orta	16	5	7	53	0,762	0,696	0,727	0,852
Macro Ortalama					0,867	0,812	0,836	0,901



Şekil 3-17: Veri Seti 7 (k.e. = 0,65) için karışıklık matrisi

3.2.2.14 Veri Seti 7 (k.e. = 0,25)

Şekil 3.18'deki karışıklık matrisine göre model; İyi sınıfında 32/37 (1 → Orta), Kötü sınıfında 20/26 (5 → Orta), Orta sınıfında ise 18/29 (4 → İyi, 1 → Kötü) oranında doğru tahmin üretmiştir. Modelin tahminlerinde background (arka plan) olarak elenen herhangi bir örnek bulunmamaktadır. Yanlıkların toplam 11 örnekle sınırlı olduğu görülmektedir. Bunların tamamı sınıflar arası karışmalardan kaynaklanmıştır. Bu durum, düşük karar eşiğinde (0,25) modelin çapak örneklerinin tamamını bir sınıfla ilişkilendirebildiğini, dolayısıyla arka plan kayıplarını ortadan kaldırdığını göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 32, FP = 4, FN = 1, TN = 44
- Kötü sınıfı: TP = 20, FP = 1, FN = 5, TN = 55
- Orta sınıfı: TP = 18, FP = 6, FN = 5, TN = 52

Toplamda TP = 70, FP = 11, FN = 11, TN = 151 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarımlı metrikleri:

Precision = %86,4, Recall = %85,1, F1-Score = %85,4, Accuracy = %90,9 olarak belirlenmiştir (Tablo 3.14).

Arka plan olarak değerlendirilmiş örnek bulunmadığından, modelin tüm sınıflarda aktif tahmin üretme başarısı dikkat çekicidir.

Tablo 3-14: Veri Seti 7 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	32	4	1	44	0,889	0,97	0,928	0,938
Kötü	20	1	5	55	0,952	0,8	0,87	0,926
Orta	18	6	5	52	0,75	0,783	0,766	0,864
Macro Orta					0,864	0,851	0,854	0,909



Şekil 3-18: Veri Seti 7 (k.e. = 0,25) için karışıklık matrisi

3.2.2.15 Veri Seti 8 (k.e. = 0,65)

Şekil 3.19'daki karışıklık matrisine göre model; İyi sınıfında 37/40 (1 → Orta, 2 → Arka Plan), Kötü sınıfında 32/33 (1 → Arka Plan), Orta sınıfında ise 32/35 (1 → İyi, 2 → Arka Plan) oranında doğru tahmin üretmiştir. Yanlışların toplam 9 örnekle sınırlı olduğu görülmektedir. Bunların 4'ü sınıflar arası karışma, 5'i ise background (arka plan) olarak elenmiştir. Bu durum, yüksek karar eşiğinde (0,65) modelin yüksek seçicilik gösterdiğini, çapak sınırlarını

net biçimde ayırt edebildiğini ve küçük hatalar dışında oldukça kararlı tahminler ürettiğini göstermektedir.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 37, FP = 1, FN = 3, TN = 67
- Kötü sınıfı: TP = 32, FP = 0, FN = 1, TN = 75
- Orta sınıfı: TP = 32, FP = 1, FN = 3, TN = 72

Toplamda TP = 101, FP = 2, FN = 7, TN = 214 olarak bulunmuştur.


Bu değerlere göre modelin makro ortalama başarımları metrikleri:

Precision = %98,1, Recall = %93,6, F1-Score = %95,8, Accuracy = %97,2 olarak belirlenmiştir (Tablo 3.15).

Arka plan olarak tahmin edilen örnekler, ilgili sınıfların yanlış negatif (FN) değerleri kapsamında değerlendirilmiştir.

Tablo 3-15: Veri Seti 8 (k.e. = 0,65) için sınıf bazlı ve makro ortalama başarımları metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	37	1	3	67	0,974	0,925	0,949	0,963
Kötü	32	0	1	75	1	0,97	0,985	0,991
Orta	32	1	3	72	0,97	0,914	0,941	0,963
Macro Ortalama					0,981	0,936	0,958	0,972



Şekil 3-19: Veri Seti 8 (k.e. = 0,65) için karışıklık matrisi

3.2.2.16 Veri Seti 8 (k.e. = 0,25)

Şekil 3.20'deki karışıklık matrisine göre model, tüm sınıflarda yüksek tutarlılıkla tahmin gerçekleştirmiştir. Diyagonal hâkimiyet belirgindir; bu da modelin sınıf ayrımında güçlü bir genelleme kabiliyetine sahip olduğunu göstermektedir. Model; İyi sınıfında 39/40, Kötü sınıfında 33/33, Orta sınıfında ise 33/35 oranında doğru tahmin üretmiştir. Yanlışların yalnızca 3 örnekle sınırlı olduğu görülmektedir. Bunların 2'si sınıflar arası karışma (İyi → Orta ve Orta → İyi) olup, 1 örnek ise Orta sınıfının arka plan (background) olarak elenmesidir.

Bu veri seti, tüm veri setleri içinde en yüksek doğruluk ve kararlılığı sağlayan model olarak öne çıkmıştır. Düşük karar eşiği (0,25), modelin daha geniş bir güven aralığında tahmin yapmasına izin vermiş, bu da özellikle “Orta” sınıfının sınıf-içi çeşitliliğine rağmen yüksek genel başarı elde edilmesini sağlamıştır.

Modelin sınıf bazlı tahmin değerleri şu şekildedir:

- İyi sınıfı: TP = 39, FP = 1, FN = 1, TN = 67
- Kötü sınıfı: TP = 33, FP = 0, FN = 0, TN = 75
- Orta sınıfı: TP = 33, FP = 1, FN = 2, TN = 72


Toplamda TP = 101, FP = 2, FN = 7, TN = 214 olarak bulunmuştur.

Bu değerlere göre modelin makro ortalama metrikleri:

Precision = %98,2, Recall = %97,3, F1-Score = %97,7, Accuracy = %98,5 olarak hesaplanmıştır (Tablo 3.16).

Tablo 3-16: Veri Seti 8 (k.e. = 0,25) için sınıf bazlı ve makro ortalama başarı metrikleri

Sınıf	TP	FP	FN	TN	Precision	Recall	F1-Score	Accuracy
İyi	39	1	1	67	0,975	0,975	0,975	0,981
Kötü	33	0	0	75	1	1	1	1
Orta	33	1	2	72	0,970	0,943	0,957	0,972
Macro Ortalama					0,982	0,973	0,977	0,985



Şekil 3-20: Veri Seti 8 (k.e. = 0,25) için karışıklık matrisi

Bu çalışmada oluşturulan Veriseti-1’den Veriseti-8’e kadar olan sekiz farklı veri setine ait YOLOv10n model çıktıları, karışıklık matrisleri ve başarı metrikleri (Precision, Recall, F1-Score ve Accuracy) üzerinden ayrıntılı olarak incelenmiştir.

Tablo 3.17’de, her veri seti için iki farklı karar eşiği (0,25 ve 0,65) kullanılarak elde edilen temel performans metrikleri sunulmuştur.

F1-Score, modelin sınıflar arasındaki genel dengeyi en iyi şekilde yansıttığı için değerlendirmelerde ana metrik olarak tercih edilmiştir.

Buna karşın, accuracy değeri modelin genel doğruluk eğilimini destekleyici bir ölçüt olarak tabloda verilmiştir. Böylece hem sınıf bazlı hem de genel düzeyde performansın bütüncül bir şekilde karşılaştırılması sağlanmıştır.

Elde edilen bulgular aşağıda veri seti bazında sunulmaktadır.

- Veri Seti 1 (Orijinal):

Veri artırma uygulanmadığı için modelin genelleme kabiliyeti sınırlı kalmıştır. K.e. = 0,65’te $F1 = 0,644$ ve k.e. = 0,25’te $F1 = 0,777$ ile en düşük başarı grubu arasında yer almıştır. Özellikle “orta” sınıfta yüksek FN gözlenmiş, bu da modelin sade veriyle yüzey farklılıklarını öğrenmekte zorlandığını göstermektedir. Ama düşük karar eşiğinde yüksek karar eşiğine göre daha iyi sonuçlar vermiştir.

- Veri Seti 2 (Orişinal + YÇ):

Yatay çevirme artırmasıyla kısmi iyileşme sağlanmışır. 0,25 karar eşişinde $F1 = 0,832$ 'ye yükselmiş, ancak 0,65 eşişinde Recall'ın düşmesiyle $F1 = 0,790$ 'a gerilemiştir. “İyi” sınıfta doğruluk yüksek, “orta” sınıfta sınırlı karışma gözlenmiştir.

- Veri Seti 3 (Orişinal + D180°):

Döndürme artırması “kötü” sınıfta fayda sağlamış; ancak “orta” sınıfta yüksek FN değerleri görölmüşür. 0,25 eşişinde $F1 = 0,740$ iken 0,65 eşişinde $F1 = 0,717$ 'ye gerilemiştir. Döndürme tek başına dengenin sağlanması için yeterli olmamıştır.

- Veri Seti 4 (Orişinal + ÇD):

YÇ ve 180° kombinasyonu (ÇD) tek başına dengeli sonuç vermemiştir. 0,25 eşişinde $F1 = 0,795$ ile kabul edilebilir düzeyde başarı elde edilirken, 0,65 eşişinde $F1 = 0,710$ 'a düşmüştür. Özellikle yüksek eşişin etkisiyle “orta” sınıfta FN artışı belirgindir.

- Veri Seti 5 (Orişinal + YÇ + D180°):

Kombinasyonlu artırma ile sonuçlar toparlanmıştır. 0,25 eşişinde $F1 = 0,833$ 'e yükselmiş, 0,65 eşişinde ise $F1 = 0,807$ olarak gerçekleşmiştir. “İyi” sınıf güçlü kalmış, “orta” sınıfta kısmi karışmalar sürmüştür.

- Veri Seti 6 (Orişinal + YÇ + ÇD):

En dengeli setlerden biridir. 0,25 eşişinde $F1 = 0,910$ ile yüksek performans elde edilmiştir. 0,65 eşişinde FN artışı nedeniyle $F1 = 0,844$ 'e düşmüştür. Precision ve Recall dengesi en iyi şekilde korunmuştur.

- Veri Seti 7 (Orişinal + D180° + ÇD):

0,25 eşişinde $F1 = 0,854$ ile güçlü bir performans gösterilmiştir. 0,65 eşişinde $F1 = 0,836$ 'ya gerilese de sınıflar arası denge korunmuştur. Arka plan elenmesi gözlenmemiştir. Model tüm sınıfları tanımlayabilmiştir.

- Veri Seti 8- (Orişinal + YÇ + D180° + ÇD):

Tüm veri setleri arasında en yüksek başarı elde edilmiştir. 0,25 eşişinde $\rightarrow$ Accuracy = 0,985 ve $F1 = 0,977$. 0,65 eşişinde $\rightarrow$ Accuracy = 0,972 ve $F1 = 0,958$. Karışıklık matrisi

diyagonal hâkimiyet göstermekte, FN oranı çok düşüktür. Özellikle “orta” sınıfta bile dengeli sınıflandırma başarısı sağlanmıştır.

Tablo 3-17: Tüm veri setlerine ait precision, recall, f1-score ve accuracy değerleri

Veri Seti	Veri Kombinasyonu	Karar Eşiği	Precision	Recall	F1-Score	Accuracy
Veri Seti 1	Orijinal	0,65	0,768	0,574	0,644	0,555
Veri Seti 1	Orijinal	0,25	0,798	0,787	0,777	0,852
Veri Seti 2	Orijinal + YÇ	0,65	0,893	0,762	0,79	0,864
Veri Seti 2	Orijinal + YÇ	0,25	0,893	0,825	0,832	0,883
Veri Seti 3	Orijinal + D180°	0,65	0,847	0,648	0,717	0,84
Veri Seti 3	Orijinal + D180°	0,25	0,778	0,72	0,74	0,846
Veri Seti 4	Orijinal + ÇD	0,65	0,854	0,628	0,71	0,833
Veri Seti 4	Orijinal + ÇD	0,25	0,855	0,794	0,795	0,864
Veri Seti 5	Orijinal + YÇ + D180°	0,65	0,913	0,734	0,807	0,885
Veri Seti 5	Orijinal + YÇ + D180°	0,25	0,869	0,821	0,833	0,889
Veri Seti 6	Orijinal + YÇ + ÇD	0,65	0,942	0,77	0,844	0,909
Veri Seti 6	Orijinal + YÇ + ÇD	0,25	0,939	0,888	0,91	0,942
Veri Seti 7	Orijinal + D180° + ÇD	0,65	0,867	0,812	0,836	0,901
Veri Seti 7	Orijinal + D180° + ÇD	0,25	0,864	0,851	0,854	0,909
Veri Seti 8	Orijinal + YÇ + D180° + ÇD	0,65	0,981	0,936	0,958	0,972
Veri Seti 8	Orijinal + YÇ + D180° + ÇD	0,25	0,982	0,973	0,977	0,985

3.2.3 Bulgulara Göre Veri Setlerin Genel Değerlendirilmesi

Veri setlerine ait başarı metrikleri incelendiğinde, veri artırma stratejileri ve k.e. ayarlarının modelin başarımı üzerinde belirleyici olduğu görülmüştür. Tüm veri setlerinin topluca değerlendirilmesi şu sonuçları ortaya koymaktadır:

- En yüksek başarı, Veri Seti 8 ve k.e. = 0,25 ile elde edilmiştir. Accuracy = 0,985 ve F1 = 0,977 değerleri ile model, çapak sınıflarını en doğru şekilde ayırt etmiştir. Karışıklık matrisi diyagonal hâkimiyet göstermekte, özellikle “orta” sınıfta bile dengeli sınıflandırma başarısı gözlenmektedir.
- En düşük başarı, Veri Seti 1 ve k.e. = 0,65 ile elde edilmiştir. F1 = 0,644 ve Accuracy = 0,556 değerleriyle “orta” sınıfta yanlış sınıflandırma oranı artmış, FN değerleri belirgin biçimde yükselmiştir.
- Veri Seti 1–4 (artırmasız veya tekil artırmalı) modeller, düşük performans sergilemiştir. Bu durum, tekil artırımların (yalnız yatay çevirme veya yalnız döndürme) modelin genelleme yeteneğini sınırlı düzeyde geliştirdiğini göstermektedir.
- Veri Seti 5–7 (kombinasyonlu artırımlar) model başarımını kademeli biçimde toparlamış, özellikle Veri Seti 6 üzerinde F1 = 0,910 ve Accuracy = 0,942 ile oldukça yüksek performans elde edilmiştir. Bu veri seti hem Precision hem Recall bakımından dengeli sonuçlar üretmiştir.
- Karar eşiği değeri etkisi belirgindir.
 - Düşük eşiği (0,25) Recall’u artırmış, küçük ve soluk çapakların yakalanmasını kolaylaştırmıştır.
 - Yüksek eşiği (0,65) ise Recall’u düşürmüş, FN oranını artırmıştır.
- Sınıf bazlı performans incelendiğinde:
 - İyi sınıf, tüm veri setlerinde yüksek doğrulukla tahmin edilmiştir.
 - Kötü sınıf, genellikle orta düzeyde kalmış, bazı veri setlerinde (özellikle YÇ katkılı) iyileşme göstermiştir.
 - Orta sınıf, en kırılgan sınıf olmuş; Veri Seti 1 ve Veri Seti 4 de F1 değerlerinde belirgin düşüş gözlenmiştir.
- Genel eğilim; Veri Seti 1–4 aralığının düşük, Veri Seti 5–7 grubunun toparlanma, Veri Seti 8’in ise zirve dönemi olduğunu göstermektedir.

Bu sonuçlar, özellikle kombinasyonlu veri artırma stratejilerinin ve düşük eşiği değerlerinin model başarımını artırmada kritik rol oynadığını ortaya koymaktadır.

3.2.4 Tüm veri setlerini kapsayan karşılaştırmalı grafikler

Bu bölümde, veri setlerine ait model çıktıları toplu olarak değerlendirilmiş ve karşılaştırmalı grafikler ile sunulmuştur.

3.2.4.1 Makro metrikler (Accuracy, Precision, Recall, F1)


Şekil 3-23'te görüldüğü üzere, tüm veri setlerine ait makro ortalama metrikler topluca karşılaştırılmıştır. Grafik genelinde Veri Seti 8 serisi özellikle düşük eşikte en yüksek değerleri üretmiş, Accuracy=0,985 ve F1=0,977 ile modelin çapak sınıflarını en doğru şekilde ayırt ettiği veri seti olmuştur.

Eşik etkisi belirgindir. Eşik değeri yükseldikçe Recall değerleri kademeli biçimde azalmış, Precision ise yüksek seviyede korunmuştur. Bu durum, küçük ve soluk çapakların düşük eşik değerinde daha kolay yakalanabildiğini, yüksek eşikte ise kaçırıldığını göstermektedir.

Veri setleri 1-4 aralığında performans değerlerinde ciddi bir düşüş gözlenmiştir. Özellikle Veri Seti 4 ve k.e. = 0,65'te Recall ve F1 değerleri en düşük seviyeye inmiştir. Bu sonuç, artırımsız ya da tekil artırmalı veri setlerinin genelleme kabiliyetini sınırlı düzeyde geliştirdiğini ortaya koymaktadır.

Veri setleri 5-7 aralığında ise kısmi bir toparlanma eğilimi göstermiştir. Bu sürümlerde Accuracy ve F1 değerleri yeniden yükselmiş, özellikle Veri Seti 6 ve k.e. = 0,25'te F1=0,910 ile ikinci güçlü aday ortaya çıkmıştır. Bu sonuç, kombinasyonlu veri artırma stratejilerinin tekil artırmalara göre daha etkili olduğunu kanıtlamaktadır.

Genel olarak grafik, Veri Seti 8'de zirve noktası, veri setleri 1-4 aralığında performans kaybı dönemi, veri setleri 5-7'de ise toparlanma süreci olduğunu açıkça göstermektedir. Ayrıca Precision değerlerinin çoğu veri setlerde görece sabit kalması, Recall'un ise eşik artışıyla baskılanması modelin hata yapma eğilimlerinin farklı metrikler üzerinden dengelenebildiğini göstermektedir.



Şekil 3-21: Makro ortalama başarı metriklerinin veri setlere göre değişim grafiği


3.2.4.2 TP–TN–FP–FN dağılımları

Şekil 3.24 incelendiğinde, Veri Seti 8’de TP değerlerinin çok yüksek, FN değerlerinin ise oldukça düşük seviyelerde olduğu görülmektedir. Bu durum, özellikle düşük eşik değerinde modelin çapak sınıflarını başarıyla yakalayabildiğini ve sınıflar arası doğru sınıflandırmayı yüksek oranda sağladığını göstermektedir.

Veri Seti 1 ile birlikte TP ve TN değerlerinde ciddi bir düşüş yaşanmış, FN değerlerinde ise dikkat çekici artış görülmüştür. Benzer şekilde, Veri Seti 2 – Veri Seti 4’ün yüksek eşiklerin de yüksek FN değerleri öne çıkmıştır. Bu durum, tekil veri artırımlarıyla beraber yüksek eşik değerleri modelin genelleme kabiliyetini yeterince desteklemediğini ve özellikle orta sınıfta başarısızlığa yol açtığını ortaya koymaktadır.

Veri Seti 5 ile 7 arasında, TP ve TN değerleri yeniden artış göstermiş, FN değerleri kısmen azalmıştır. Özellikle Veri Seti 6 (k.e. = 0,25)’da TP ve TN değerlerinin belirgin biçimde yüksek olması, Veri Seti 6’nın, Veri Seti 8’den sonra en dengeli hata profiline sahip olduğunu göstermektedir. Buna karşılık Veri Seti 5 ve Veri Seti 6’da eşik yükseltilmesi, FN oranlarını yeniden artırmıştır.

Genel olarak grafik, düşük eşik değerlerinin FN oranını azaltarak doğru sınıflandırmayı artırdığını, yüksek eşik değerlerinin ise FN’yi yükselterek modelin kaçırma eğilimini artırdığını göstermektedir. Bu durum, pratik üretim süreçlerinde düşük eşik değerlerinin daha güvenli bir tercih olduğunu ortaya koymaktadır.



Şekil 3-22: TP–TN–FP–FN dağılım grafiği


3.2.4.3 Hata oranları

Şekil 3.23 ve Şekil 3.24 incelendiğinde, hata oranlarının veri setleri arası değişimi açıkça görülmektedir. Veri Seti 8 genel olarak en düşük hata oranlarını üretmiş; özellikle düşük k.e. değerinde hem $FP/(TP+FP)$ hem de $FN/(TP+FN)$ oranları %5'in altında kalmıştır. Bu durum, düşük eşik değerinin küçük ve soluk çapakların yakalanmasına imkân tanıdığını ve modelin hata oranlarını minimize ettiğini göstermektedir.


Eşik yükseldikçe, FP oranları sınırlı biçimde azalırken FN oranları belirgin şekilde artmıştır. Özellikle Veri Seti 1, Veri Seti 3 ve Veri Seti 4'ün yüksek eşik değerlerinde, FN oranlarının %25–35 seviyelerine çıktığı noktalar olarak öne çıkmaktadır. Bu durum, yüksek eşik değerlerinin modelin yanlış negatif (FN) üretme eğilimini artırdığını ve Recall değerlerini baskıladığını ortaya koymaktadır.

Veri Seti 6'da düşük eşikte FN oranı yeniden düşük seviyelere gerilemiş, FP oranı ise kontrol altında kalmıştır. Buna karşılık Veri Seti 5 ve Veri Seti 6'de eşik değerinin yükseltilmesi FN oranlarını tekrar artırmıştır.

Genel olarak bu grafikler, eşik değerinin modelin hata profili üzerindeki kritik etkisini göstermektedir. Düşük eşikler daha fazla FP üretme riski taşırsa da FN oranını düşürerek özellikle üretim güvenliği açısından daha avantajlı bir seçenek sunmaktadır.



Şekil 3-23: $FP/(TP+FP)$ hata oranının, veri setlerine ve karar eşiklerine göre değişim grafiği



Şekil 3-24: FN/(TP+FN) hata oranının, veri setlerine ve karar eşiklerine göre değişim grafiği

3.2.4.4 Tüm veri setlerinin orta sınıfa ait f1 skorları


Model için en kırılgan sınıf olan orta sınıfın f1 değerleri ayrı bir grafik ile sunulmuştur. İyi ve kötü sınıflar tüm veri setlerinde yüksek ve dengeli performans sergilediğinden ayrıca grafikte gösterilmemiştir.

Şekil 3.25 incelendiğinde, orta sınıfın model için en zorlayıcı sınıf olduğu açıkça görülmektedir. Veri Seti 8’de, özellikle 0,25 k.e.’de orta sınıfta oldukça yüksek F1 skor üretilmiş, bu da düşük eşik değerlerinin küçük ve belirsiz çapakların daha doğru sınıflandırılmasına katkı sağladığını göstermektedir.

Buna karşılık veri setleri 1-4’te orta sınıfta belirgin performans kaybı yaşanmıştır. Özellikle Veri Seti 2 ve Veri Seti 4’ün yüksek eşik değerlerinde, F1 değerlerinde %0,50–0,65 seviyelerine kadar düşmüş ve bu sonuç, tekil artırımların modelin genelleme kabiliyetini desteklemediğini ortaya koymuştur.

Veri setleri 5-7 ile birlikte orta sınıf performansı yeniden yükselme eğilimi göstermiştir. Özellikle Veri Seti 6 ve k.e. = 0,25’te, F1 değeri 0,85’e ulaşarak Veri Seti 8’den sonra en yüksek başarıya ulaşmış, kombinasyonlu artırma stratejilerinin orta sınıfta sınıflandırma doğruluğunu artırdığı görülmüştür.

Genel olarak grafik, orta sınıfın modelin performansını sınırlayan en kırılgan sınıf olduğunu ve bu sınıfta başarıyı artırmak için düşük eşik değerleri ile kombinasyonlu veri artırma stratejilerinin kritik rol oynadığını ortaya koymaktadır.



Şekil 3-25: Orta sınıfa ait F1 değerlerinin veri setlerine ve karar eşiklerine göre grafiği

3.2.4.5 Trend grafikler

Şekil 3-26 – 3-29’da, karar eşiği (K.E.) = 0,25 ve 0,65 değerlerinde elde edilen Makro Precision, Recall, F1 ve Accuracy metriklerinin veri setlerine göre değişim eğilimleri sunulmaktadır.

Precision değerleri (Şekil 3-26) genel olarak tüm veri setlerinde yüksek (0,8–1,0 aralığında) ve kararlı seyretmiştir. Karar eşiği 0,65 değerinde Precision oranları genellikle biraz daha yüksek olup özellikle Veri Seti 2, Veri Seti 6 ve Veri Seti 8’de maksimum seviyelere ulaşmıştır. Bu durum, yüksek eşiklerde modelin daha seçici davranarak yanlış pozitifleri azalttığını göstermektedir.


Recall değerleri (Şekil 3-27) karar eşiği artışıyla birlikte belirgin bir düşüş eğilimi göstermiştir. Düşük eşikte (K.E. = 0,25) hatırlama oranları daha yüksek olup özellikle Veri Seti 6 ve Veri Seti 8’de 0,9’un üzerine çıkmıştır. Buna karşın Veri Seti 1 ve Veri Seti 4’te yüksek eşikte (0,65) belirgin azalma gözlenmiş, bu da modelin bazı doğru örnekleri kaçırdığını (False Negative artışı) göstermektedir.

F1 skorları (Şekil 3-28), Precision ve Recall arasındaki dengeyi yansıttığından, eğriler iki eşik arasında orta seviyede farklılık göstermiştir. En yüksek F1 değerleri düşük eşikte Veri Seti 8’de (~1,0) ve ikinci sırada Veri Seti 6’da (~0,9) elde edilmiştir. Bu durum, bu veri setlerinin hem yüksek doğruluk hem yüksek hatırlama oranı sağladığını kanıtlamaktadır.


Accuracy değerleri (Şekil 3-29) incelendiğinde, genel olarak tüm veri setlerinde yüksek doğruluk oranları (0,8–1,0 aralığında) gözlenmiştir. Düşük karar eşğinde (K.E. = 0,25) model

genel olarak daha yüksek accuracy sağlamış, özellikle Veri Seti 8 diğer tüm kombinasyonlara kıyasla en yüksek performansa ulaşmıştır.


Genel olarak trend grafiklerinden elde edilen bulgular, düşük karar eşiğinin (K.E. = 0,25) modelin daha hassas ve kapsayıcı tahminler yapmasını sağladığını, yüksek eşiklerde (K.E. = 0,65) ise Precision'ın arttığı fakat Recall ve dolayısıyla F1'in azaldığını göstermektedir. Bu durum, eşik seçiminin modelin denge noktası üzerinde doğrudan etkili olduğunu ortaya koymaktadır.




Şekil 3-26: Makro Precision değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği



Şekil 3-27: Makro Recall değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği



Şekil 3-28: Makro F1 değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği



Şekil 3-29: Accuracy değerlerinin veri setlerine ve karar eşiklerine göre değişim grafiği

3.2.4.6 Yığılmış oran grafiği


Şekil 3-30'da tüm veri setleri için TP (True Positive), TN (True Negative), FP (False Positive) ve FN (False Negative) oranlarının %100 yığılmış biçimde dağılımı gösterilmektedir. Grafik, karar eşiği değerinin sınıflandırma doğruluğu üzerindeki doğrudan etkisini açık biçimde ortaya koymaktadır.

Genel olarak, K.E. = 0,25 değerinde yapılan tahminlerde TP ve TN oranlarının yüksek, FP ve FN oranlarının ise düşük olduğu görülmektedir. Bu durum, düşük karar eşiğinde modelin daha kapsayıcı bir tahmin stratejisi izlediğini göstermektedir.

Özellikle Veri Seti 8 (K.E.=0,25) ve Veri Seti 6 (K.E.=0,25) en yüksek doğru sınıflandırma oranlarına (TP + TN) ulaşmış, toplamda yaklaşık %95 – 97 doğruluk aralığında seyretmiştir. Bu veri setlerinde FP ve FN oranları minimal düzeydedir.

Buna karşın Veri Seti 1 (K.E.=0,65) ile Veri Seti 4 (K.E.=0,65)’te FN oranlarının belirgin biçimde arttığı görülmektedir. Bu artış, yüksek eşikte modelin daha katı karar verdiğini ve bazı doğru örnekleri gözden kaçırdığını (Recall azalışı) göstermektedir. FP oranları ise bu eşikte azalmış olup Precision’ın yükselmesine katkı sağlamıştır.

Sonuç olarak, yığılmış oran grafiği genel olarak düşük karar eşiğinin (K.E. = 0,25) modelin dengeli ve yüksek başarıda çalışmasını sağladığını; yüksek eşik değerinin (K.E. = 0,65) ise seçiciliği artırmasına rağmen bazı örnekleri yanlış sınıfa atadığını ortaya koymaktadır. Bu eğilim, trend grafiklerinde gözlenen Precision–Recall dengesini de doğrulamaktadır.



Şekil 3-30: TP/TN/FP/FN oranlarının veri setlerine göre %100 yığılmış grafiği

3.2.4.7 Genel değerlendirme

Karşılaştırmalı grafikler; Veri Seti 8 ve k.e. = 0,25 en yüksek başarıyı sağladığını, Veri Seti 1’den Veri Seti 4’e kadar belirgin performans kaybı yaşandığını ve Veri Seti 5’den Veri Seti 7’e kadar kısmi toparlanma görüldüğünü açıkça göstermektedir. Özellikle FN değerlerindeki değişim, karar eşiği ve veri artırma stratejilerinin model başarımında belirleyici faktörler olduğunu ortaya koymaktadır.

3.3 Tartışma

Bu tez çalışmasında elde edilen bulgular, delik delme operasyonlarında çapak oluşumunun tespiti ve sınıflandırılmasında derin öğrenme tabanlı yaklaşımların güçlü bir alternatif sunduğunu

göstermektedir. Özellikle Veri Seti 8 ve $K.E.=0,25$ değerinde elde edilen yüksek başarı oranları ($Accuracy=0,985$; $F1=0,977$) veri artırma stratejilerinin ve düşük eşik değerinin model başarımı üzerindeki kritik rolünü ortaya koymuştur.

Elde edilen sonuçlar, düşük karar eşığının (0,25) Recall oranını artırarak küçük ve soluk çapakların daha kolay algılanmasını sağladığını, buna karşılık yüksek eşik (0,65) değerinin FN oranlarını artırarak Recall'ı baskıladığını göstermiştir. Bu bulgular, literatürde Chen ve Tsao [6] ile Zhao [7] tarafından belirtilen, delik çıkışında çapak oluşumunun küçük ölçekli ve belirsiz yapılarda daha zor tespit edildiği yönündeki gözlemlerle örtüşmektedir.

Veri artırma stratejilerinin performans üzerindeki etkisi incelendiğinde, tekil artırımların (yatay çevirme, 180° döndürme, çevirme-döndürme) model başarımını sınırlı düzeyde artırdığı, buna karşın kombinasyonlu artırımların modelin genelleme kabiliyetini belirgin şekilde güçlendirdiği görülmüştür. Özellikle Veri Seti 6 ve Veri Seti 8 yüksek performans sağlamıştır. Bu durum, Dornfeld vd. [51] ve Kıvak [10]'ın çapak oluşumunun çok değişkenli bir olgu olduğu ve farklı kesme parametrelerinin birlikte değerlendirilmesi gerektiği yönündeki bulgularıyla uyumludur.

Sınıf bazlı analizler, iyi sınıfın tüm veri setlerinde yüksek doğrulukla tahmin edildiğini, kötü sınıfın orta seviyede performans gösterdiğini, orta sınıfın ise en kırılgan sınıf olduğunu ortaya koymuştur. Bu durum, çapak sınırlarının görsel ve geometrik olarak belirsizleştiği durumlarda sınıflar arası ayrımın zorlaştığını belirten Bissacco vd. [11] ve Almeida Filho vd. [12]'nin bulgularını desteklemektedir.

Hata oranları incelendiğinde özellikle Veri Seti 4 ve yüksek eşik (0,65) seviyelerinde FN oranlarının yükseldiği ve modelin genelleme kabiliyetinin azaldığı görülmüştür. Bu durum, eşik değeri arttıkça modelin duyarlılığının azaldığını ve küçük çapak yapılarının gözden kaçabildiğini göstermektedir. Üretim güvenliği açısından FN oranlarının kritik öneme sahip olduğu dikkate alındığında, düşük eşik değerlerinin (0,25) pratik uygulamalarda daha avantajlı olduğu söylenebilir.

Modelin sınıflandırma eğilimleri, deneysel kesme parametreleriyle fiziksel olarak da uyumluluk göstermektedir. Deneylerde 360 dev/dak parametresinde daha düşük, 715 dev/dak parametresinde ise daha yüksek çapak eğilimi gözlenmiştir. Bu eğilim, talaşlı imalatta kesme hızının artmasıyla birlikte sıcaklık ve itme kuvvetlerinin yükselmesi sonucu plastik deformasyonun artması ve dolayısıyla çapak oluşumunun yoğunlaşması yönündeki klasik açıklamalarla örtüşmektedir [9,41,44,51–54].

Sonu olarak, elde edilen bulgular hem modelin grntsel anlamda yksek sınıflandırma başarısı gsterdiğini hem de delme srecinin fiziksel gerekleriyle tutarlı tahminler rettiğini gstermektedir. Bu durum, geliştirilen YOLOv10 tabanlı sistemin endstriyel kalite kontrol srelerinde otomatik, hızlı ve gvenilir bir apak sınıflandırma yntemi olarak kullanılabileceğini kanıtlamaktadır.



4. SONUÇLAR

Bu tez kapsamında, AA6013 alüminyum alaşımı üzerinde gerçekleştirilen delik delme işlemleri sonrasında oluşan çapakların YOLOv10n tabanlı görüntü işleme teknikleriyle incelenmesi yapılmıştır. Farklı veri setleri (Veri Seti 1–Veri Seti 8) ve karar eşiği değerleri (0,25 ve 0,65) karşılaştırılarak modelin başarımı değerlendirilmiştir.

4.1 Genel Sonuçlar

- Veri Seti 8 (k.e. = 0,25), en yüksek başarı değerleri (Accuracy=0,985, F1=0,977) ile modelin çapak sınıflarını ayırt etmede en güvenilir yapı olduğu göstermiştir.
- Karar eşiği model başarımında belirleyici bir etkidir.
 - Düşük eşik (0,25), Recall’ı artırarak küçük ve soluk çapakların daha kolay yakalanmasını sağlamıştır.
 - Yüksek eşik (0,65), Precision’ı korurken FN oranlarını artırmış, dolayısıyla F1 değerini düşürmüştür.
- Veri artırma stratejileri model performansını doğrudan etkilemiştir.
 - Tekil artırımlar (YÇ, D180°, ÇD) sınırlı katkı sağlamıştır.
 - Kombinasyonlu artırımlar (Veri Seti 5-8), modelin genelleme yeteneğini artırmış özellikle “orta” sınıfın ayırımında iyileşme sağlamıştır.
- Sınıf bazlı analizlerde farklılıklar gözlenmiştir.
 - “İyi” sınıf en yüksek doğrulukla tahmin edilmiştir.
 - “Kötü” sınıf orta seviyede başarı göstermiştir.
 - “Orta” sınıf, görsel benzerlik ve etiket sınırı belirsizliği nedeniyle en zayıf kalmıştır.
- FN artışının model başarımı üzerindeki etkisi büyüktür. Özellikle yüksek eşikli veri setlerinde FN oranı artmış, bu da makro F1 skorlarını sınırlamıştır.
- Arka plan tahminlerinin FN olarak değerlendirilmesi, kaçan kusurların muhasebeleştirilmesini sağlamış ve kalite kontrol açısından daha gerçekçi bir analiz sunmuştur.
- Toplu grafik analizleri modelin gelişim sürecini açıkça göstermiştir: Veri Seti 1–4 arasında düşüş, 5–7 arasında toparlanma, 8’de ise maksimum performans gözlenmiştir.

4.2 Çalışmanın Katkıları

- YOLOv10n modeli, AA6013 malzemesinde delik delme sonrası çapak sınıflandırmasında ilk kez başarıyla uygulanmıştır.
- Model, geleneksel çapak ölçüm yöntemlerine kıyasla daha hızlı, operatör bağımsız ve tekrarlanabilir sonuçlar üretmiştir.
- Veri artırma stratejileri ve karar eşiği karşılaştırmaları sistematik biçimde analiz edilerek literatüre özgün bir katkı sağlanmıştır.
- “Arka plan = FN” yaklaşımı ile endüstriyel kalite kontrol için pratik bir değerlendirme yöntemi geliştirilmiştir.
- Modelin sınıflandırma davranışı, delme parametrelerinin çapak oluşumu üzerindeki bilinen etkileriyle fiziksel olarak tutarlı bulunmuştur.
- Çalışmanın bulguları, YOLOv10 mimarisinin metal işleme süreçlerinde kusur tespitinde kullanılabilirliğini doğrulamaktadır.

4.3 Gelecek Çalışma Önerileri

Daha geniş ve çeşitlendirilmiş veri setlerinin oluşturulması, çoklu ışıklandırma düzeneklerinin kullanılması, domain-spesifik artırma tekniklerinin (parlama, çizik sentezi vb.) uygulanması, “Orta” sınıfın alt sınıflara ayrılması (örneğin; orta-1, orta-2), IoU tabanlı konum doğruluğu analizleri, modelin gerçek zamanlı (edge AI) üretim hatlarına entegrasyonu, farklı malzeme ve takım geometrilerinde çapak oluşumunun incelenmesi önerilmektedir.

5. KAYNAKLAR

- [1] Parvizi, P., Jalilian, M., Mirazizi, P. S., Zangeneh, M. R., & Amidi, A. M. (2025). Mechanical and physical properties of aluminum and its alloys for electrical conductors: A review. *Next Materials*, 9, 101090. <https://doi.org/10.1016/j.nxmte.2025.101090>
- [2] Doshi, Y. (2020). Aluminum market outlook – 2026.
- [3] Bach, R. (2025). Aluminium in transport. Eriřim adresi: <https://www.aluminiumleader.com/application/transport/> (Eriřim Tarihi: 15.09.2025)
- [4] Mathers, G. (2002). Introduction to the welding of aluminium. İinde: The welding of aluminium and its alloys (ss. 1–9). Elsevier, Amsterdam.
- [5] Elgallad, E. M., Samuel, F. H., Samuel, A. M., & Doty, H. W. (2010). Machinability aspects of new Al–Cu alloys intended for automotive castings. *Journal of Materials Processing Technology*, 210(12–13), 1754–1766. <https://doi.org/10.1016/j.jmatprotec.2010.06.006>
- [6] Chen, W.-C., & Tsao, C.-C. (1999). Cutting performance of different coated twist drills. *Journal of Materials Processing Technology*, 88(1–3), 203–207. [https://doi.org/10.1016/S0924-0136\(98\)00396-3](https://doi.org/10.1016/S0924-0136(98)00396-3)
- [7] Zhao, H. (1994). Predictive models for forces, power and hole oversize in drilling operations. Doktora Tezi, University of Melbourne, Melbourne, Avustralya.
- [8] Li, R., & Shih, A. J. (2007). Finite element modeling of high-throughput drilling of Ti-6Al-4V. *Transactions of NAMRI/SME*, 35, 73–80.
- [9] Tönshoff, H. K., Spintig, W., König, W., & Neises, A. (1994). Machining of holes – Developments in drilling technology. *CIRP Annals*, 43(2), 551–561. [https://doi.org/10.1016/S0007-8506\(07\)60501-0](https://doi.org/10.1016/S0007-8506(07)60501-0)
- [10] Kıvak, T. (2012). Kesici takımlara uygulanan kriyojenik işlemin Ti-6Al-4V alařımının delinebilirlięi üzerindeki etkilerinin arařtırılması. Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [11] Bissacco, G., Hansen, H. N., & De Chiffre, L. (2006). Size effects on surface generation in micro milling of hardened tool steel. *CIRP Annals*, 55(1), 593–596. [https://doi.org/10.1016/S0007-8506\(07\)60490-9](https://doi.org/10.1016/S0007-8506(07)60490-9)
- [12] Almeida Filho, C. O. C. D., Batalha, G. F., Bordinassi, É. C., & Stipkovic Filho, M. (2004). Controle de rebarbaão e de foras de corte. *Máquinas e Metais*, 40, 104–119.

- [13] Kaminise, A. (2004). Estudo da formação de rebarbas no torneamento cilíndrico externo de aço-carbono ABNT 1045. Yüksek Lisans Tezi, Universidade Federal de Uberlândia, Uberlândia, Brezilya.
- [14] Bahçe, E., & Özdemir, B. (2021). Burr measurement method based on burr surface area. *International Journal of Precision Engineering and Manufacturing – Green Technology*, 8(5), 1287–1296. <https://doi.org/10.1007/s40684-020-00228-0>
- [15] Giasin, K. (2017). Machining fibre metal laminates and Al2024-T3 aluminium alloy. Doktora Tezi, University of Sheffield, Sheffield, Birleşik Krallık.
- [16] Campbell, F. C. (Ed.). (2008). *Elements of metallurgy and engineering alloys*. ASM International, Materials Park, OH, ABD.
- [17] Aamir, M., Giasin, K., Tolouei-Rad, M., & Vafadar, A. (2020). A review: Drilling performance and hole quality of aluminium alloys for aerospace applications. *Journal of Materials Research and Technology*, 9(6), 12484–12500. <https://doi.org/10.1016/j.jmrt.2020.09.003>
- [18] Abdelaoui, F. Z. El, Jabri, A., & Barkany, A. El. (2023). Optimization techniques for energy efficiency in machining processes – A review. *The International Journal of Advanced Manufacturing Technology*, 125(5–6), 2967–3001. <https://doi.org/10.1007/s00170-023-10927-y>
- [19] Abellán-Nebot, J. V., Vila Pastor, C., & Siller, H. R. (2024). A review of the factors influencing surface roughness in machining and their impact on sustainability. *Sustainability*, 16(5), 1917. <https://doi.org/10.3390/su16051917>
- [20] Davim, J. P., & Jackson, M. J. (2013). *Nano and micromachining*. Wiley, Hoboken, NJ, ABD.
- [21] Liu, Z., Yue, C., Li, X., Liu, X., Liang, S. Y., & Wang, L. (2020). Research on tool wear based on 3D FEM simulation for milling process. *Journal of Manufacturing and Materials Processing*, 4(4), 121. <https://doi.org/10.3390/jmmp4040121>
- [22] Hu, X., Qiao, H., Yang, M., & Zhang, Y. (2022). Research on milling characteristics of titanium alloy TC4 with variable helical end milling cutter. *Machines*, 10(7), 537. <https://doi.org/10.3390/machines10070537>
- [23] Colantonio, L., Equeter, L., Dehombreux, P., & Ducobu, F. (2021). A systematic literature review of cutting tool wear monitoring in turning by using artificial intelligence techniques. *Machines*, 9(12), 351. <https://doi.org/10.3390/machines9120351>

- [24] Gieysztor, E., Kowal, M., & Paprocka-Borowicz, M. (2021). Gait parameters in healthy preschool and school children assessed using wireless inertial sensor. *Sensors*, 21(19), 6423. <https://doi.org/10.3390/s21196423>
- [25] Hamed, M., Zhang, C., Khan, A. M., Saleem, M., & Musanur, M. D. (2024). Holistic review of drilling on CFRP composites: Techniques, FEM, sustainability, challenges, and advances. *The International Journal of Advanced Manufacturing Technology*, 135(5–6), 2661–2696. <https://doi.org/10.1007/s00170-024-14317-w>
- [26] Rajakumar, I. P. T., Hariharan, P., & Vijayaraghavan, L. (2012). Drilling of carbon fibre reinforced plastic (CFRP) composites – A review. *International Journal of Materials and Product Technology*, 43(1–4), 43–67. <https://doi.org/10.1504/IJMPT.2012.047647>
- [27] Aamir, M., Tolouei-Rad, M., Giasin, K., & Nosrati, A. (2019). Recent advances in drilling of carbon fiber–reinforced polymers for aerospace applications: A review. *The International Journal of Advanced Manufacturing Technology*, 105(5–6), 2289–2308. <https://doi.org/10.1007/s00170-019-04348-z>
- [28] Sun, D., Lemoine, P., Keys, D., Doyle, P., Malinov, S., Zhao, Q., Qin, X., & Jin, Y. (2018). Hole-making processes and their impacts on the microstructure and fatigue response of aircraft alloys. *The International Journal of Advanced Manufacturing Technology*, 94(5–8), 1719–1726. <https://doi.org/10.1007/s00170-016-9850-3>
- [29] Iyer, R., Koshy, P., & Ng, E. (2007). Helical milling: An enabling technology for hard machining precision holes in AISI D2 tool steel. *International Journal of Machine Tools and Manufacture*, 47(2), 205–210. <https://doi.org/10.1016/j.ijmachtools.2006.04.006>
- [30] Gu, W., Xu, H., Liu, J., & Yue, Z. (2009). Effect of drilling process on fatigue life of open holes. *Tsinghua Science and Technology*, 14(S1), 54–57. [https://doi.org/10.1016/S1007-0214\(10\)70031-6](https://doi.org/10.1016/S1007-0214(10)70031-6)
- [31] Liu, J., Xu, H. L., Zhai, H. B., & Yue, Z. F. (2010). Effect of detail design on fatigue performance of fastener hole. *Materials & Design*, 31(2), 976–980. <https://doi.org/10.1016/j.matdes.2009.08.016>
- [32] Everett, R. A., Jr. (2004). The effect of hole quality on the fatigue life of 2024-T3 aluminum alloy sheet (Report No. ARL-TR-3106). Aberdeen Proving Ground, MD, ABD.
- [33] Ralph, W. C., Johnson, W. S., Makeev, A., & Newman, J. C. (2007). Fatigue performance of production-quality aircraft fastener holes. *International Journal of Fatigue*, 29(7), 1319–1327. <https://doi.org/10.1016/j.ijfatigue.2006.10.016>

- [34] Elajrami, M., Benguediab, M., & Ronald, G. (2008). Effect of various drilling procedures on the fatigue life of rivet holes. *Synthese: Revue des Sciences et de la Technologie*, 19, 67–75.
- [35] Li, H., He, G., Qin, X., Wang, G., Lu, C., & Gui, L. (2014). Tool wear and hole quality investigation in dry helical milling of Ti-6Al-4V alloy. *The International Journal of Advanced Manufacturing Technology*, 71(9–12), 1511–1523. <https://doi.org/10.1007/s00170-013-5570-0>
- [36] Zhu, Z., Guo, K., Sun, J., Li, J., Liu, Y., Zheng, Y., & Chen, L. (2018). Evaluation of novel tool geometries in dry drilling aluminium 2024-T351/titanium Ti6Al4V stack. *Journal of Materials Processing Technology*, 259, 270–281. <https://doi.org/10.1016/j.jmatprotec.2018.04.044>
- [37] Giasin, K., & Ayvar-Soberanis, S. (2017). An investigation of burrs, chip formation, hole size, circularity and delamination during drilling operation of GLARE using ANOVA. *Composite Structures*, 159, 745–760. <https://doi.org/10.1016/j.compstruct.2016.10.015>
- [38] Aamir, M., Tu, S., Tolouei-Rad, M., Giasin, K., & Vafadar, A. (2020). Optimization and modeling of process parameters in multi-hole simultaneous drilling using Taguchi method and fuzzy logic approach. *Materials*, 13(3), 680. <https://doi.org/10.3390/ma13030680>
- [39] Hu, J., Zhang, K., Cheng, H., & Liu, S. (2015). Development of flexible drilling jig for wing-fuselage connection. *The Open Mechanical Engineering Journal*, 9, 460–466. <https://doi.org/10.2174/1874155X01509010460>
- [40] Fangmann, S. (2025). A better way to drill holes for aircraft. Erişim adresi: <https://www.engineersaustralia.org.au/News/better-way-drill-holes-aircraft> (Erişim Tarihi: 15.09.2025)
- [41] Tolouei-Rad, M. (2012). Intelligent analysis of utilization of special purpose machines for drilling operations. İçinde: Koleshko, V. M. (Ed.), *Intelligent systems* (ss. 297–320). InTech, Rijeka, Hırvatistan.
- [42] Klocke, F., & Eisenblätter, G. (1997). Dry cutting. *CIRP Annals*, 46(2), 519–526. [https://doi.org/10.1016/S0007-8506\(07\)60877-4](https://doi.org/10.1016/S0007-8506(07)60877-4)
- [43] Batzer, S., Haan, D., Rao, P., Olson, W., & Sutherland, J. (1998). Chip morphology and hole surface texture in the drilling of cast aluminum alloys. *Journal of Materials Processing Technology*, 79(1–3), 72–78. [https://doi.org/10.1016/S0924-0136\(97\)00324-5](https://doi.org/10.1016/S0924-0136(97)00324-5)

- [44] Sreejith, P. S., & Ngoi, B. K. A. (2000). Dry machining: Machining of the future. *Journal of Materials Processing Technology*, 101(1–3), 287–291. [https://doi.org/10.1016/S0924-0136\(00\)00445-3](https://doi.org/10.1016/S0924-0136(00)00445-3)
- [45] Carrilero, M. S., Bienvenido, R., Sánchez, J. M., Álvarez, M., González, A., & Marcos, M. (2002). A SEM and EDS insight into the BUL and BUE differences in the turning processes of AA2024 Al–Cu alloy. *International Journal of Machine Tools and Manufacture*, 42(2), 215–220. [https://doi.org/10.1016/S0890-6955\(01\)00112-2](https://doi.org/10.1016/S0890-6955(01)00112-2)
- [46] Wang, X. (2012). A study of tool wear in turning of pure aluminum and drilling of CFRP/titanium stacks. *Doktora Tezi*, Michigan State University, East Lansing, MI, ABD.
- [47] Dixit, U. S., Sarma, D. K., & Davim, J. P. (2012). *Environmentally friendly machining*. Springer US, Boston, MA, ABD. ISBN 978-1-4614-2307-2
- [48] Pattnaik, S. K., Bhoi, N. K., Padhi, S., & Sarangi, S. K. (2018). Dry machining of aluminum for proper selection of cutting tool: Tool performance and tool wear. *The International Journal of Advanced Manufacturing Technology*, 98(1–4), 55–65. <https://doi.org/10.1007/s00170-017-0307-0>
- [49] Berger, H., Kari, S., Gabbert, U., Rodriguez-Ramos, R., Bravo-Castillero, J., & Guinovart-Díaz, R. (2005). Calculation of effective coefficients for piezoelectric fiber composites based on a general numerical homogenization technique. *Composite Structures*, 71(3–4), 397–400. <https://doi.org/10.1016/j.compstruct.2005.09.038>
- [50] Altın Karataş, M., & Gökkaya, H. (2018). A review on machinability of carbon fiber reinforced polymer (CFRP) and glass fiber reinforced polymer (GFRP) composite materials. *Defence Technology*, 14(4), 318–326. <https://doi.org/10.1016/j.dt.2018.02.001>
- [51] Dornfeld, D. A., Kim, J. S., Dechow, H., Hewson, J., & Chen, L. J. (1999). Drilling burr formation in titanium alloy, Ti-6Al-4V. *CIRP Annals*, 48(1), 73–76. [https://doi.org/10.1016/S0007-8506\(07\)63134-5](https://doi.org/10.1016/S0007-8506(07)63134-5)
- [52] Biermann, D., & Hartmann, H. (2012). Reduction of burr formation in drilling using cryogenic process cooling. *Procedia CIRP*, 3, 85–90. <https://doi.org/10.1016/j.procir.2012.07.016>
- [53] Ko, S.-L., & Dornfeld, D. A. (1991). A study on burr formation mechanism. *Journal of Engineering Materials and Technology*, 113(1), 75–87. <https://doi.org/10.1115/1.2903385>
- [54] Jin, S. Y., Pramanik, A., Basak, A. K., Prakash, C., Shankar, S., & Debnath, S. (2020). Burr formation and its treatments — A review. *The International Journal of Advanced*

Manufacturing Technology, 107(5–6), 2189–2210. <https://doi.org/10.1007/s00170-020-05203-2>

- [55] Yalçın, B., Yüksel, A., Aslantaş, K., Der, O., & Erçetin, A. (2023). Optimization of micro-drilling of laminated aluminum composite panel (Al–PE) using Taguchi orthogonal array design. *Materials*, 16(13), 4528. <https://doi.org/10.3390/ma16134528>
- [56] Karakılınç, U., Ergene, B., Yalçın, B., Aslantaş, K., & Erçetin, A. (2023). Comparative analysis of minimum chip thickness, surface quality and burr formation in micro-milling of wrought and selective laser melted Ti64. *Micromachines (Basel)*, 14(6), 1160. <https://doi.org/10.3390/mi14061160>
- [57] Mohammed, A., Kvam, J., Onstein, I. F., Bakken, M., & Schulerud, H. (2023). Automated 3D burr detection in cast manufacturing using sparse convolutional neural networks. *Journal of Intelligent Manufacturing*, 34(1), 303–314. <https://doi.org/10.1007/s10845-022-02036-6>
- [58] Kutsal, İ. E. (2022). SiC takviyeli AlSi7Mg2 metal matrisli kompozit malzemelerin işlenebilirliğinin araştırılması. Yayınlanmamış Yüksek Lisans Tezi, Batman Üniversitesi, Batman, Türkiye.
- [59] Pramanik, A., Basak, A. K., Prakash, C., Shankar, S., & Chattopadhyaya, S. (2022). Sustainability in drilling of aluminum alloy. *Cleaner Materials*, 3, 100048. <https://doi.org/10.1016/j.clema.2022.100048>
- [60] Poór, D. I., Geier, N., Pereszlai, C., & Xu, J. (2021). A critical review of the drilling of CFRP composites: Burr formation, characterisation and challenges. *Composites Part B: Engineering*, 223, 109155. <https://doi.org/10.1016/j.compositesb.2021.109155>
- [61] Ko, S. L., & Park, S. W. (2006). Development of an effective measurement system for burr geometry. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 220(4), 507–512. <https://doi.org/10.1243/09544054JEM246>
- [62] Böğrekci, İ., Çerçi, Y., Demircioğlu, P., & Durakbaşı, M. N. (2013). Kesici takım endüstrisinde mühendislik uygulamaları ile mikro/nanoteknolojinin termal ve görüntü işleme ile analizi. *Mühendis ve Makina*, 55, 19–24.
- [63] Akkoyun, F., Ercetin, A., Aslantas, K., Pimenov, D. Y., Giasin, K., Lakshmikanthan, A., & Aamir, M. (2021). Measurement of micro burr and slot widths through image processing: Comparison of manual and automated measurements in micro-milling. *Sensors*, 21(13), 4432. <https://doi.org/10.3390/s21134432>
- [64] Akkoyun, F., Cevik, Z. A., Ozsoy, K., Ercetin, A., & Arpacı, I. (2023). Image processing approach to investigate the correlation between machining parameters and burr formation in

- micro-milling processes of selective-laser-melted AISI 316L. *Micromachines* (Basel), 14(7), 1376. <https://doi.org/10.3390/mi14071376>
- [65] Burr, D. C., & Morgan, M. J. (1997). Motion deblurring in human vision. *Proceedings of the Royal Society of London B: Biological Sciences*, 264(1380), 431–436. <https://doi.org/10.1098/rspb.1997.0061>
- [66] Chen, X., Shi, G., Xi, C., Zhong, L., Wei, X., & Zhang, K. (2019). Design of burr detection based on image processing. *Journal of Physics: Conference Series*, 1237, 032075. <https://doi.org/10.1088/1742-6596/1237/3/032075>
- [67] Kumar, M., & Bajpai, V. (2020). Experimental investigation of top burr formation in high-speed micro-milling of Ti6Al4V alloy. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 234(4), 730–738. <https://doi.org/10.1177/0954405419883049>
- [68] Pillai, A., Chiddarwar, S., Rahul, M. R., & Dalvi, M. (2021). Burr registration using image processing. İçinde: [Konferans bildirisi] (ss. 321–330). [Yayın bilgisi eksik].
- [69] Rahul, M. R., Bhute, R. Y., Chiddarwar, S. S., Dalvi, M., & Sahoo, S. R. (2021). Burr registration and trajectory planning of 3D workpiece using computer vision. İçinde: [Konferans bildirisi] (ss. 107–113). [Yayın bilgisi eksik].
- [70] Póka, G., & Balázs, B. Z. (2022). A robust digital image processing method for measuring the planar burr length at milling. *Journal of Manufacturing Processes*, 80, 706–717. <https://doi.org/10.1016/j.jmapro.2022.06.037>
- [71] Geier, N., Póka, G., Jacsó, Á., & Pereszlai, C. (2022). A method to predict drilling-induced burr occurrence in chopped carbon fibre reinforced polymer (CFRP) composites based on digital image processing. *Composites Part B: Engineering*, 242, 110054. <https://doi.org/10.1016/j.compositesb.2022.110054>
- [72] Özel, M. A., Baysal, S. S., & Şahin, M. (2021). Derin öğrenme algoritması (YOLO) ile dinamik test süresince süspansiyon parçalarında çatlak tespiti. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.952798>
- [73] Wang, Y., Wang, H., & Xin, Z. (2022). Efficient detection model of steel strip surface defects based on YOLO-V7. *IEEE Access*, 10, 133936–133944. <https://doi.org/10.1109/ACCESS.2022.3230894>
- [74] Li, J., Su, Z., Geng, J., & Yin, Y. (2018). Real-time detection of steel strip surface defects based on improved YOLO detection network. *IFAC-PapersOnLine*, 51(21), 76–81. <https://doi.org/10.1016/j.ifacol.2018.09.412>

- [75] Kou, X., Liu, S., Cheng, K., & Qian, Y. (2021). Development of a YOLO-V3-based model for detecting defects on steel strip surface. *Measurement*, 182, 109454. <https://doi.org/10.1016/j.measurement.2021.109454>
- [76] Zhao, C., Shu, X., Yan, X., Zuo, X., & Zhu, F. (2023). RDD-YOLO: A modified YOLO for detection of steel surface defects. *Measurement*, 214, 112776. <https://doi.org/10.1016/j.measurement.2023.112776>
- [77] Ultralytics. (2025). Models / YOLOv10. Erişim adresi: <https://docs.ultralytics.com/models/yolov10/> (Erişim Tarihi: 24.09.2025)
- [78] LearnOpenCV. (2025). YOLOv10. Erişim adresi: <https://learnopencv.com/yolov10/> (Erişim Tarihi: 24.09.2025)
- [79] Analytics Vidhya. (2024). YOLOv10 for real-time object detection. Erişim adresi: <https://www.analyticsvidhya.com/blog/2024/07/yolov10-for-realtime-object-detection/> (Erişim Tarihi: 24.09.2025)
- [80] Deep Learning Türkiye. (2025). Model performansını değerlendirmek – metrikler. Erişim adresi: <https://medium.com/deep-learning-turkiye/model-performansini-degerlendirmek-metrikler-cb6568705b1> (Erişim Tarihi: 24.09.2025)
- [81] Kırğıl, M., Taşkın, S. G., & Erçetin, A. (2025). Delik delme esnasında malzeme yüzeyinde oluşan çapakların görüntü işleme yöntemiyle incelenmesi. İçinde: II. BİLSEL Uluslararası Midas Bilimsel Araştırmalar Kongresi Bildirileri, Eskişehir, Türkiye (ss. 354–363).