

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**CMM CİHAZINDAKİ VERİLERDEN MAKİNE ÖĞRENMESİ İLE
PARÇA KONTROLÜ**

YÜKSEK LİSANS TEZİ

Zeynep AKPULAT

Metalurji ve Malzeme Mühendisliği Anabilim Dalı

EYLÜL 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**CMM CİHAZINDAKİ VERİLERDEN MAKİNE ÖĞRENMESİ İLE
PARÇA KONTROLÜ**

YÜKSEK LİSANS TEZİ

Zeynep AKPULAT

Metalurji ve Malzeme Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Nuray CANİKOĞLU

EYLÜL 2025

Zeynep AKPULAT tarafından hazırlanan “CMM CİHAZINDAKİ VERİLERDEN MAKİNE ÖĞRENMESİ İLE PARÇA KONTROLÜ” adlı tez çalışması XX.XX.2025 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Metalurji ve Malzeme Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Prof.Dr.**
Sakarya Uygulamalı Bilimler Üniversitesi

Jüri Üyesi : **Doç. Dr. Nuray CANİKOĞLU** (Danışman)
Sakarya Üniversitesi

Jüri Üyesi : **Prof.Dr.**
Sakarya Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “CMM CİHAZINDAKİ VERİLERDEN MAKİNE ÖĞRENMESİ İLE PARÇA KONTROLÜ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(...../...../20.....).

Zeynep AKPULAT





Aileme.....



TEŞEKKÜR

Çalışmam boyunca bilgi ve deneyimleriyle beni yönlendiren, her aşamada yol gösterici olan değerli danışman hocam Doç. Dr. Nuray CANİKOĞLU'na, katkılarıyla çalışmama değer katan Prof. Dr. İhsan Hakan SELVİ'ye ve Arş. Gör. Dilay BOZDAĞ AK' a da en içten teşekkürlerimi sunarım.

Ayrıca çalışmama sağladıkları teknik destek ve uygulama imkânları nedeniyle Kar Metal Sanayi ve Ticaret Ltd. Şti.'ne ve bu süreçte sunduğu olanaklarla araştırmamın gerçekleşmesine katkı sağlayan Sakarya Üniversitesi Fen Bilimleri Enstitüsü'ne teşekkür ederim.

Eğitim sürecim boyunca her daim yanımda olan, sabırları, sevgileri ve sonsuz destekleriyle bana güç veren sevgili eşim Furkan AKPULAT'a ve canım aileme minnettarım.

Zeynep AKPULAT



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
2. MAKİNE ÖĞRENMESİ VE ENDÜSTRİYEL UYGULAMALARI	3
2.1. Makine Öğrenmesi Nedir?	3
2.2. Makine Öğrenmesinin Tarihçesi	3
2.3. Kalite Kontrol ve Üretim Süreçlerinde Makine Öğrenmesi Uygulamaları.....	5
2.3.1. Görüntü işleme ile otomatik hata tespiti	5
2.3.2. Görüntü işleme ile otomatik hata tespiti	5
2.3.3. Süreç parametrelerinin optimizasyonu.....	5
2.3.4. Tahmine dayalı bakım.....	6
2.4. Kalite Tahmini ve Sınıflandırma	6
2.5. Veri Bilimi – Üretim Verisinin Anlamlandırılması	6
2.5.1. Desen tanıma ve tahminleme	7
2.5.2. Süreç iyileştirme ve verimlilik analizi	7
2.5.3. Kalite tahmini ve hata tespiti	7
3. KALİTE KONTROL SÜREÇLERİNDE VERİ ODAKLI YAKLAŞIMLAR	9
3.1. Kalite Kontrol Kavramı ve Geleneksel Yöntemler	9
3.1.1. Geleneksel kalite kontrol yöntemleri	9
3.1.1.1. Gözlemsel denetim.....	9
3.1.1.2. Numune alma ve istatistiksel yöntemler	9
3.1.1.3. Manuel ölçüm araçları.....	9
3.2. Toleranslar, GD&T (Geometric Dimensioning and Tolerancing) ve Ölçüm Yorumlama Süreci.....	10
3.2.1. Tolerans kavramı.....	10
3.3. GD&T (Geometric Dimensioning and Tolerancing)	10
3.4. Ölçüm Yorumlama Süreci	11
3.5. Kalite Kontrolde İnsan Kaynaklı Hatalar ve Karar Farklılıkları	11
3.6. Veriyle Karar Verme: Sübjektiflikten Nesnellığe Geçiş	12
3.7. Otomatik Onay-Ret Sistemlerinin Gerekliliği.....	13
4. CMM Teknolojisi: Veri Kaynağı ve Uygulama Alanı	15
4.1. CMM'in Temel Yapısı ve Ölçüm Teknikleri.....	15
4.1.1. Temel yapı.....	15
4.1.2. Ölçüm teknikleri	16
4.2. Koordinat Ölçme Makinelerinden (CMM) Veri Alma Süreci	17

4.2.1. Veri toplama (ölçüm alma)	18
4.2.2. Veri iletimi ve depolama	19
4.2.3. Veri analizi ve karşılaştırma.....	20
4.2.4. Sonuçların yorumlanması.....	20
4.2.5. Veri raporlama ve sonuçların sunulması	21
4.2.6. Otomatikleştirilmiş veri toplama.....	22
4.3. CAD Karşılaştırmaları ve Ölçüm Standartları	22
4.3.1. CAD karşılaştırmalarının temeli	23
4.3.2. Ölçüm standartları	23
4.3.3. CAD ve CMM karşılaştırmaları arasındaki ilişki	24
4.3.4. Ölçüm sonuçlarının yorumlanması	24
4.3.5. Teknolojik gelişmeler ve otomasyon	24
4.4. Üretim Ortamında CMM'nin Rolü.....	25
4.4.1. Parça ölçümü ve doğrulama	25
4.4.2. Kalite kontrol ve üretim iyileştirmeleri.....	25
4.4.3. Gerçek zamanlı izleme ve otomasyon.....	25
4.4.4. Veri analizi ve üretim kararları	26
4.4.5. Prototip ve üretim aşamaları arasındaki bağlantı	26
4.4.6. Müşteri memnuniyeti ve ürün güvenliği	26
4.4.7. Tolerans yönetimi.....	26
4.4.8. Eğitim ve beceri geliştirme	27
4.5. CMM'in Otomatik Kalite Kontrol Sistemine Entegrasyonu.....	27
4.5.1. Entegrasyonun temel amacı	27
4.5.2. Otomatik ölçüm ve veri toplama	28
4.5.3. Makine öğrenmesi ve verilerin analizi	28
4.5.4. Otomatik onay-ret kararları	28
4.5.5. Gerçek zamanlı izleme ve geri bildirim	28
4.5.6. Entegre sistemler ve otomasyon.....	29
4.5.7. Veri tabanlı karar verme.....	29
4.5.8. Zaman ve maliyet tasarrufu.....	29
5. DENEYSEL ÇALIŞMALAR	31
5.1. Deneysel Sürecin Genel Yapısı	31
5.2. Kullanılan Algoritmalar.....	33
5.2.1. Random forest algoritması	33
5.2.1.1. Teorik temelleri	33
5.2.1.2. Özellikleri ve avantajları	33
5.2.1.3. Uygulama alanları	34
5.2.1.4. Random forest ve kalite kontrol	34
5.2.2. Support vector machine (SVM) algoritması	34
5.2.2.1. Teorik yapısı ve matematiksel temelleri	35
5.2.2.2. SVM'in avantajları ve güçlü yönleri.....	35
5.2.2.3. SVM'in uygulama alanları	36
5.2.2.4. Kalite kontrol ve endüstriyel uygulamalarda SVM.....	36
5.2.3. Naive bayes (naif bayes) sınıflandırma algoritması	37
5.2.3.1. Bayes teoremi temelli sınıflandırma yaklaşımı	37
5.2.3.2. Naive bayes türleri ve kullanım alanlarına uygunluğu.....	37
5.2.3.3. Güçlü yönleri ve sınırlamaları	38
5.2.3.4. Endüstriyel ve akademik uygulamalar	38
5.2.3.5. Kalite kontrol süreçlerinde naive bayes'in kullanımı	39
5.2.3.6. Güncel araştırmalar ve gelişmeler	39

5.2.4. K-Nearest neighbors (KNN) algoritması	39
5.2.4.1. Temel çalışma prensibi	40
5.2.4.2. Parametreler ve etkileri	40
5.2.4.3. Avantajları ve dezavantajları.....	40
5.2.4.4. Uygulama alanları	41
5.2.4.5. Kalite kontrol ve üretim sistemlerinde KNN	41
5.2.4.6. Güncel gelişmeler ve hibrit modeller	42
6. DENEYSEL SONUÇLAR ve TARTIŞMA	43
6.1. Özellik Seçimi ve Veri Hazırlama Süreci	43
6.2. Parça Ölçüm Sonuçlarının Değerlendirilmesi	44
6.2.1. Genel durum dağılımı	48
6.2.2. Reddedilen parçaların ortak özellikleri	48
6.2.3. Genel durum dağılımı	50
6.2.4. Gözlemler ve yorumlar	50
6.2.5. Reddedilen parçaların ortak özellikleri	51
6.3. Model Eğitimi ve Doğrulama Yöntemleri	51
6.3.1. Veri bölünmesi	51
6.3.2. Çapraz doğrulama (cross-validation)	51
6.3.3. Hiperparametre optimizasyonu	51
6.3.4. Random forest algoritması için	52
6.3.5. Support vector machine (SVM) için	52
6.3.6. K-Nearest neighbors (KNN) için	52
6.3.7. Naive bayes	52
6.4. Eğitim Sürecine Genel Bakış	53
6.5. Performans Ölçütleri	53
6.5.1. Doğruluk (Accuracy)	53
6.6. Random Forest İçin	54
6.7. Support Vector Machine (SVM)	56
6.8. Naive Bayes.....	59
6.9. K-Nearest Neighbors (KNN)	62
6.10. Sınırlamalar ve İyileştirme Yaklaşımları	66
6.11. Uygulama: Otomatik Parça Kabul-Ret Sistemi	66
6.11.1. Geliştirilen sistemin mimarisi	66
6.11.2. Yazılım araçları	67
6.11.3. CMM ölçüm verisinin alınması, işlenmesi ve karar mekanizmasına aktarılması	67
6.11.4. Gerçek test senaryoları ve analizler	68
7. GENEL SONUÇLAR VE ÖNERİLER	71
7.1. Genel Sonuçlar	71
7.2. Öneriler.....	72
KAYNAKLAR	75
ÖZGEÇMİŞ.....	81



KISALTMALAR

Accuracy	: Doğruluk – Toplam doğru tahmin oranı
AI	: Artificial Intelligence (Yapay Zekâ)
ASME	: American Society of Mechanical Engineers (Amerikan Makine Mühendisleri Derneği)
AUC	: Area Under Curve (Eğri Altındaki Alan)
CAD	: Computer Aided Design (Bilgisayar Destekli Tasarım)
CMM	: Coordinate Measuring Machine (Koordinat Ölçüm Makinesi)
F1 Score	: F1 Skoru (Doğruluk ve hassasiyetin harmonik ortalaması)
FN	: False Negative (Yanlış negatif)
FP	: False Positive (Yanlış pozitif)
GPS	: Geometrical Product Specifications (Geometrik Ürün Özellikleri)
IoT	: Internet of Things (Nesnelerin İnterneti)
ISO	: International Organization for Standardization (Uluslararası Standardizasyon Örgütü)
KNN	: K-Nearest Neighbors (K-En Yakın Komşu)
ML	: Machine Learning (Makine Öğrenmesi)
NB / Naive Bayes	: Bayes Sınıflandırıcıları
RF / Random Forest	: Rastgele Karar Ormanları
ROC	: Receiver Operating Characteristic (İşlem Karakteristik Eğrisi)
RUL	: Remaining Useful Life (Kalan Kullanım Ömrü)
SMOTE	: Synthetic Minority Over-sampling Technique (Sentetik Azınlık Aşırı Örnekleme Tekniği)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TN	: True Negative (Doğru negatif)
TP	: True Positive (Doğru pozitif)



TABLO LİSTESİ

Sayfa

Tablo 6.1. Parça Ölçüm Sonuçları.....	46
Tablo 6.2. Parça Ölçüm Sonuçları.....	49
Tablo 6.3. Algoritmalarla göre Accuracy değeri ve F1 skorları (Parça 1)	64
Tablo 6.4. Algoritmalarla göre Accuracy değeri ve F1 skorları (Parça 2)	65





ŞEKİL LİSTESİ

Sayfa

Şekil 4.1. CMM genel görüntüsü ve Mcosmos (CMM Programı) Uzay Görüntüsü.	16
Şekil 4.2. Prob değişim sekmesi ve seçim ekranı	17
Şekil 4.3. Program düzenleme sekmesi	19
Şekil 4.4. Programın uzaydaki hali ve düzenleme sekmesi	20
Şekil 4.5. Parça program çıktısı	21
Şekil 4.6. Parça program çıktısı	22
Şekil 5.1. Dişli kutusu	31
Şekil 5.2. Servo somun takozu	32
Şekil 6.1. Doğruluk Formülü	53
Şekil 6.2. F1 Skoru Formülü	54
Şekil 6.3. Modelin Karmaşıklık Matrisi Random Forest (Parça 1)	54
Şekil 6.4. Modelin Karmaşıklık Matrisi Random Forest (Parça 2)	56
Şekil 6.5. Modelin Karmaşıklık Matrisi SVM (Parça 1)	57
Şekil 6.6. Modelin Karmaşıklık Matrisi SVM (Parça 2)	58
Şekil 6.7. Naive Bayes Algoritmasına Ait Karışıklık Matrisi (Parça 1)	59
Şekil 6.8. Naive Bayes Algoritmasına Ait Karışıklık Matrisi (Parça 2)	61
Şekil 6.9. K-En Yakın Komşu (KNN) Algoritmasına Ait Karışıklık Matrisi (Parça 1)	62
Şekil 6.10. KNN Algoritmasına Ait Karışıklık Matrisi – (Parça 2)	63
Şekil 6.11. Parça 1 için Makine Öğrenmesi Performansı	68
Şekil 6.12. Parça 2 için Makine Öğrenmesi Performansı	69



CMM CİHAZINDAKİ VERİLERDEN MAKİNE ÖĞRENMESİ İLE PARÇA KONTROLÜ

ÖZET

Koordinat Ölçüm Makineleri (Coordinate Measuring Machine, CMM), modern imalat sanayisinde kalite kontrol ve ölçüm süreçlerinin en önemli araçlarından biridir. Bu cihazlar, üretilen parçaların teknik resimlerde belirtilen şekil ve konum toleranslarına uygun olup olmadığını belirlemek amacıyla kullanılmaktadır. CMM'ler, parçaların yüzey noktalarını üç boyutlu olarak tarayarak; düzlemsellik, silindiriklik, paralellik, koniklik, pozisyon gibi geometrik ölçüleri yüksek hassasiyetle analiz eder. Ayrıca CAD (Bilgisayar Destekli Tasarım) verileri ile entegre çalışarak ölçüm sonuçlarını tasarım verileri ile karşılaştırabilir. Bu sayede ürün doğrulama, tersine mühendislik ve proses kontrol gibi alanlarda etkili bir rol oynar.

Ancak bu ölçüm sonuçlarının değerlendirilmesi hâlâ büyük ölçüde operatörün bilgi birikimi, deneyimi ve yorumu doğrultusunda yapılmaktadır. Bu durum, karar süreçlerinde subjektifliğe, tutarsızlığa ve insan hatasına yol açabilmektedir. Özellikle sınır toleranslarda kalan parçaların kabul veya red kararları operatöre göre değişebilir. Bu bağlamda, üretim süreçlerinde standardizasyonu sağlamak ve hataları en aza indirmek için daha objektif, otomatik ve veri odaklı sistemlere ihtiyaç duyulmaktadır.

Makine öğrenmesi, verilerdeki örüntüleri analiz edebilen ve geçmiş verilere dayanarak karar verebilen bir yapay zekâ dalıdır. Bu çalışmada, CMM cihazından elde edilen ölçüm verileri kullanılarak, parça kabul/red kararını otomatik olarak veren bir makine öğrenmesi sistemi geliştirilmiştir. Bu sistem, herhangi bir operatör müdahalesine gerek duymadan karar verebilmekte, böylece insan kaynaklı hataları azaltmakta ve süreçleri hızlandırmaktadır.

Tezin temel amacı, ölçüm verilerini kullanarak doğru, tutarlı ve hızlı kararlar verebilen bir kalite kontrol modeli oluşturmaktır. Bu modelin, Endüstri 4.0 kapsamında dijitalleşen üretim süreçlerine entegre edilerek, sürdürülebilir ve yüksek kaliteli üretim hedeflerine katkı sunması hedeflenmektedir.

Anahtar Kelimeler: CMM, Makine öğrenmesi, Kalite Kontrol, Otomatik Karar Verme, Parça Sınıflandırma



PART CONTROL WITH MACHINE LEARNING FROM DATA ON CMM DEVICE

SUMMARY

In today's highly competitive manufacturing industry, quality control has become a pivotal function that ensures product reliability, consistency, and customer satisfaction. As product designs become more complex and tolerances more stringent, traditional quality inspection processes often fall short in meeting modern expectations for speed, accuracy, and objectivity. Manual inspection, which depends heavily on the expertise and judgment of quality control personnel, can result in subjective decisions, inconsistencies across shifts, and time-consuming evaluations. These limitations underscore the growing need for intelligent, automated systems that can accurately and efficiently assess part quality. This thesis proposes a novel machine learning-based quality control system that uses measurement data from Coordinate Measuring Machines (CMMs) to autonomously classify parts as either "ACCEPTED" or "REJECTED," thereby eliminating the need for human intervention in the decision-making process.

CMMs are widely utilized in dimensional metrology due to their ability to perform precise three-dimensional measurements on complex geometries. By using tactile or optical probes, CMMs can gather comprehensive data on dimensional and geometrical tolerances such as flatness, roundness, cylindricity, angularity, parallelism, and true position. Typically, these measurements are compared against CAD models or technical drawings that define geometric dimensioning and tolerancing (GD&T) limits. Although highly accurate, interpreting CMM data requires significant expertise, and manual evaluation of these measurements often results in inconsistencies, especially when measured values are close to tolerance limits.

In this study, supervised machine learning algorithms were applied to historical CMM datasets that were labeled by experienced quality control engineers. The data consisted of measurement features extracted from two different part types (Part 1 and Part 2) that vary in geometry, complexity, and tolerancing requirements. These features serve as inputs to classification algorithms which predict whether each measured part should be accepted or rejected. The ultimate goal is to create a fully automated decision support system that can replicate expert-level classification accuracy without human oversight.

Four machine learning algorithms were selected for model training and evaluation: Random Forest, Support Vector Machine (SVM), Naive Bayes, and K-Nearest Neighbors (KNN). Each algorithm represents a distinct category in the machine learning spectrum. Random Forest is an ensemble method that combines multiple decision trees to improve prediction accuracy and robustness. It is particularly well-suited for handling non-linear data and noise. SVM is a powerful classifier that identifies the hyperplane that best separates the data into two categories, often performing well in high-dimensional spaces. Naive Bayes is a probabilistic model based on Bayes' theorem and assumes feature independence; it is known for its

simplicity, speed, and good performance on small to medium-sized datasets. KNN, in contrast, is a non-parametric algorithm that assigns class labels based on the majority class of the nearest neighbors in the feature space, offering an intuitive yet computationally demanding approach to classification.

The dataset for each part was preprocessed using normalization techniques to ensure uniform scaling of features. The data was then split into training and testing sets to evaluate model generalizability. Performance metrics included accuracy and macro-averaged F1-score. The accuracy metric quantifies the proportion of total correct predictions, while F1-score considers both precision and recall, making it particularly important when the class distribution is imbalanced, as in the case of quality control where the “REJECTED” class often has fewer samples.

Results for Part 1 indicated that the Random Forest algorithm achieved the highest classification performance, reaching 97.5% accuracy and 0.971 F1-score. These results suggest that Random Forest is highly effective at capturing the complex interactions among measurement features that determine part quality. Naive Bayes followed closely, achieving 90% accuracy and 0.898 F1-score, making it a strong candidate for fast and lightweight quality assessment systems. SVM delivered 82.5% accuracy and 0.799 F1-score, performing reasonably well but showing some vulnerability in correctly identifying rejected parts. KNN also achieved 82.5% accuracy but had the lowest F1-score (0.664), reflecting its struggle with class imbalance and inconsistent decision boundaries in high-dimensional spaces.

For Part 2, which featured a different set of geometric and dimensional characteristics, the performance rankings shifted slightly. Naive Bayes emerged as the most effective classifier with 85% accuracy and 0.840 F1-score. Random Forest maintained strong performance but showed slightly lower F1-score (0.785), suggesting less balanced classification across the two output classes. SVM again showed moderate performance with 77.5% accuracy and 0.734 F1-score, while KNN continued to underperform with 80% accuracy and 0.724 F1-score. These results emphasize the necessity of selecting algorithms based on part-specific characteristics, data distributions, and class imbalances.

Beyond performance metrics, the practical benefits of the proposed system are significant. The automation of quality decision-making reduces dependency on highly skilled operators, minimizes variability across shifts, and enables real-time feedback for process control. Moreover, the early identification of defective parts prevents downstream assembly issues, reduces scrap and rework costs, and enhances overall production efficiency. The system's adaptability also allows it to be retrained on new parts with minimal reconfiguration, making it highly scalable for diverse manufacturing environments.

The developed system fits well into the framework of Industry 4.0 and smart manufacturing. By integrating machine learning into quality inspection, it contributes to the development of cyber-physical systems where physical measurement devices communicate with digital models and algorithms to support autonomous decision-making. In future applications, this system can be enhanced by incorporating data from IoT-enabled sensors that capture real-time production parameters such as tool wear, cutting temperature, or vibration. Predictive quality control becomes feasible when this rich data is fed into time-aware models such as Recurrent Neural Networks (RNN) or Long Short-Term Memory networks (LSTM). Additionally, integration with cloud

platforms can facilitate centralized monitoring, model updates, and real-time alerts across multiple production lines or factories.

Comparative analysis with existing literature reveals that while machine vision systems and deep learning-based defect detection are common in quality control research, the use of metrology-grade CMM data for machine learning classification remains relatively underexplored. Most research focuses on image classification or simple sensor readings rather than high-precision dimensional data. This thesis fills that gap by proposing a comprehensive framework that connects physical measurements to intelligent classification logic. By doing so, it enables a new class of AI-driven quality inspection tools that can be deployed in precision manufacturing contexts such as aerospace, automotive, and medical device production.

Furthermore, the system developed in this study offers a foundation for numerous future enhancements. Feature selection techniques such as Principal Component Analysis (PCA) or Recursive Feature Elimination (RFE) may be used to reduce dimensionality and further improve model efficiency. Imbalanced data handling methods such as SMOTE (Synthetic Minority Oversampling Technique) or cost-sensitive learning can be integrated to increase robustness, particularly for rare rejection cases. Advanced evaluation metrics, including ROC curves, AUC scores, and Matthews Correlation Coefficient (MCC), can be added to deepen performance analysis. Additionally, explainable AI (XAI) techniques such as SHAP or LIME could be employed to increase trust and interpretability of model decisions for process engineers.

In conclusion, this thesis demonstrates the viability and effectiveness of using machine learning algorithms on CMM measurement data to develop an automated quality control system. The system not only achieves high levels of accuracy and class balance but also provides a scalable, adaptable, and operator-independent solution for real-time quality assurance. As digital manufacturing technologies continue to evolve, such intelligent systems are expected to become an integral part of quality management strategies, offering enhanced precision, reliability, and productivity.



1. GİRİŞ

Sanayide dijitalleşmenin hız kazanmasıyla birlikte, üretim süreçlerinin daha hassas, hızlı ve güvenilir hale getirilmesi gerekliliği doğmuştur. Bu dönüşümün önemli bir ayağını kalite kontrol sistemleri oluşturmaktadır. Geleneksel kalite kontrol uygulamalarında, parçaların kabul veya red kararları büyük oranda operatör deneyimine ve yoruma dayalı olarak verilmektedir. Bu durum, özellikle tolerans sınırında yer alan ölçümlerde, kararların subjektifleşmesine ve kalite süreçlerinin tutarlılığının azalmasına yol açmaktadır. Günümüzde, insan kaynaklı hata payını minimize edecek ve karar süreçlerini otomatikleştirecek yeni yaklaşımlara ihtiyaç duyulmaktadır.

Bu ihtiyacın bir sonucu olarak, makine öğrenmesi temelli karar destek sistemleri kalite kontrol alanında ön plana çıkmaktadır. Bu tür sistemler, veriden öğrenme yeteneği sayesinde operatöre ihtiyaç duymadan parçaların uygunluğunu değerlendirebilecek modeller geliştirilmesine olanak tanımaktadır. Özellikle Koordinat Ölçüm Makineleri (CMM) gibi hassas ölçüm ekipmanlarından elde edilen verilerin, makine öğrenmesi algoritmalarıyla işlenmesi sayesinde hem subjektifliği ortadan kaldıran hem de tekrarlanabilir kararlar üreten sistemler tasarlanabilmektedir.

Bu tez çalışması, testere makinesi üreten bir firmada, üretim hattının kritik bileşenleri arasında yer alan dişli kutuları ve somun takozları gibi parçaların kalite kontrolünü otomatikleştirmeyi hedeflemektedir. CMM cihazı aracılığıyla ölçülen parçalardan elde edilen veriler, makine öğrenmesi algoritmalarıyla analiz edilerek, montaj öncesinde parçaların kabul ya da red kararları bilgisayar destekli olarak verilecektir. Bu sayede operatör bağımlılığı ortadan kaldırılarak, montaj süreçlerinde yaşanan uyumsuzlukların önüne geçilmesi amaçlanmaktadır.

Yapılan bu çalışma, özellikle yüksek hassasiyet gerektiren üretim süreçlerinde, yapay zekâ temelli karar sistemlerinin kalite kontrol süreçlerine nasıl entegre edilebileceğine dair uygulanabilir ve sektöre özel bir yaklaşım sunmaktadır.



2. MAKİNE ÖĞRENMESİ VE ENDÜSTRİYEL UYGULAMALARI

2.1. Makine Öğrenmesi Nedir?

Makine öğrenmesi, bilgisayarların, verilerden öğrenerek belirli görevleri gerçekleştirebilme yeteneğine sahip olması için geliştirilen bir yapay zekâ alt alanıdır. İnsan müdahalesi olmadan, makinelerin veriler üzerinde işlem yaparak öğrenmesi ve daha iyi sonuçlar elde etmesi sağlanır. Temel olarak, makine öğrenmesi, matematiksel ve istatistiksel yöntemlerle sistemlerin, geçmiş verilerden çıkarımlar yapmasını ve gelecekteki verilere yönelik tahminlerde bulunmasını amaçlar [1, 2].

Makine öğrenmesinin temel prensibi, verilerdeki gizli örüntüleri ve ilişkileri keşfetmektir. Bu süreç, makineye belirli bir görevi yerine getirmek için örnek veriler üzerinden eğitim yapma imkânı tanır. Eğitim sürecinde makine, veriler arasındaki ilişkileri öğrenir ve bu öğrendiklerini kullanarak yeni verilere dair tahminlerde bulunur [1, 2].

Makine öğrenmesi, genellikle denetimli öğrenme, denetimsiz öğrenme, yarı-denetimli öğrenme ve pekiştirmeli öğrenme gibi dört ana öğrenme türüne ayrılır. Her bir tür, verinin etiketli olup olmadığına ve öğrenme sürecine katılan faktörlere bağlı olarak farklı yaklaşımlar sergiler [1, 2].

Makine öğrenmesinin uygulama alanları, endüstriyel üretimden finansal analizlere, sağlık hizmetlerinden e-ticarete kadar geniş bir yelpazeye yayılmaktadır. Bu teknoloji, yalnızca otomatikleştirilmiş sistemlerin değil, aynı zamanda daha doğru, hızlı ve güvenilir kararlar alabilen akıllı sistemlerin geliştirilmesine olanak tanır [3].

2.2. Makine Öğrenmesinin Tarihçesi

Makine öğrenmesinin tarihçesi, bilgisayarların yalnızca önceden tanımlanmış komutları yerine getiren araçlar olmaktan çıkıp, deneyimlerden öğrenebilen ve tahmin yapabilen sistemlere dönüşmesini anlatan önemli bir evrim sürecini kapsamaktadır. Bu alandaki ilk adımlar, 1950 yılında Alan Turing'in "Makineler düşünebilir mi?" sorusunu gündeme getirmesiyle atılmıştır. Turing, makine zekâsının değerlendirilmesi için Turing Testi'ni önermiştir [4]. 1952 yılında Arthur Samuel, dama oynayarak kendi

deneyimlerinden öğrenen bir program geliştirmiştir. Bu program, makine öğrenmesinin ilk pratik uygulamalarından biri olarak kabul edilmektedir [5]. 1957 yılında Frank Rosenblatt tarafından geliştirilen Perceptron modeli ise yapay sinir ağlarının temelini oluşturmuştur [6].

1960'lı ve 1970'li yıllarda alanda bazı teorik gelişmeler yaşansa da, dönemin bilgisayar işlem gücünün yetersizliği nedeniyle makine öğrenmesi alanında büyük ilerlemeler kaydedilememiştir. Bu dönemdeki beklentilerin gerçekleşmemesi nedeniyle bu süreç, literatürde “Yapay Zekâ Kışı” olarak adlandırılmıştır [7].

1980'li yılların ortasında, Rumelhart, Hinton ve Williams tarafından geliştirilen geri yayılım (backpropagation) algoritması ile çok katmanlı sinir ağlarının eğitilmesi mümkün hâle gelmiş ve bu gelişme, makine öğrenmesinde yeni bir dönemin kapılarını aralamıştır [8]. Bu dönemde sinir ağları daha etkin hale gelmiş, ancak yine de büyük veri ve yüksek işlem gücü gereksinimi önemli bir kısıt oluşturmuştur.

1990'lı yıllar, makine öğrenmesi algoritmalarının çeşitlendiği bir dönem olmuştur. Bu süreçte; Support Vector Machines (SVM), k-en yakın komşu (k-NN), karar ağaçları gibi birçok denetimli öğrenme algoritması geliştirilmiş ve veri madenciliği alanı güçlenmiştir [9]. İnternetin yaygınlaşmasıyla birlikte veri hacmindeki artış, bu gelişmeleri daha da hızlandırmıştır. 1997 yılında IBM'in geliştirdiği Deep Blue adlı yapay zekâ sistemi, satranç dünya şampiyonu Garry Kasparov'u yenerek makine öğrenmesinin potansiyelini tüm dünyaya göstermiştir [10].

2000'li yıllarla birlikte “Büyük Veri” kavramı ön plana çıkmış ve şirketler, kullanıcı davranışlarını analiz etmek amacıyla büyük miktarda veri toplamaya başlamıştır. Bu veriler, ticari uygulamalarda etkili tahmin ve karar destek sistemlerine dönüştürülmüştür. Özellikle e-ticaret, çevrim içi reklamcılık ve öneri sistemleri gibi alanlarda makine öğrenmesi yoğun olarak kullanılmaya başlanmıştır [11]. Bu dönemde Google gibi teknoloji şirketleri, arama motorlarını optimize etmek için makine öğrenmesini aktif şekilde kullanmaya başlamıştır.

2010'lu yıllarda ise derin öğrenme algoritmalarının başarısı dikkat çekmiştir. Gelişmiş grafik işlemciler (GPU) sayesinde büyük veri setleri ile çok katmanlı sinir ağları eğitilebilmiş ve ses tanıma, görüntü işleme ile doğal dil işleme gibi alanlarda çığır açan gelişmeler yaşanmıştır [12]. Özellikle 2012 yılında Alex Net adlı derin öğrenme modelinin Image Net Görüntü Tanıma Yarışması'nda büyük farkla birinci olması,

derin öğrenmenin başarısını gözler önüne sermiştir. Ayrıca 2016 yılında Alpha Go'nun dünya Go şampiyonunu yenmesi, yapay zekânın stratejik düşünce alanında da insanı geçebildiğini göstermiştir [13].

2020'li yıllara gelindiğinde, büyük dil modelleri (örneğin GPT-3 ve GPT-4) ile yapay zekâ sistemlerinin insan benzeri metinler üretebilme kapasitesi gelişmiş; otonom araçlar, robotik sistemler, sağlık teknolojileri, üretim süreçleri ve hatta sanatsal uygulamalar gibi birçok alanda yaygınlaşmıştır [14]. Günümüzde makine öğrenmesi; sağlık, finans, tarım, üretim, eğitim gibi hemen her sektörde etkin bir şekilde kullanılmakta ve teknolojinin geleceğine yön vermektedir.

2.3. Kalite Kontrol ve Üretim Süreçlerinde Makine Öğrenmesi Uygulamaları

Makine öğrenmesi, kalite kontrol ve üretim süreçlerinde önemli bir rol oynamaktadır. Geleneksel yöntemlerle kıyaslandığında, makine öğrenmesi algoritmaları, daha hızlı, daha hassas ve daha güvenilir kararlar alınmasına olanak tanır. Bu teknolojiler, veri analitiği ve otomatik karar verme yetenekleri sayesinde hataların önlenmesini, ürün kalitesinin artırılmasını ve süreçlerin optimize edilmesini sağlar [15].

2.3.1. Görüntü işleme ile otomatik hata tespiti

Makine öğrenmesi, özellikle bilgisayarla görme teknolojileriyle birleştiğinde, üretim hatlarında ürünlerin görsel muayenesinde kullanılmaktadır. Derin öğrenme algoritmaları, üretim bandındaki ürünlerin fotoğraflarını analiz ederek yüzey kusurları, şekil bozuklukları veya renk hataları gibi kusurları tespit edebilir. Bu yöntem, insan gözüyle yapılan denetimlerden daha hızlı ve daha tutarlıdır [15].

2.3.2. Görüntü işleme ile otomatik hata tespiti

Makine öğrenmesi, özellikle bilgisayarla görme (computer vision) teknolojileriyle birleştiğinde, üretim hatlarında ürünlerin görsel muayenesinde kullanılmaktadır [15]. Derin öğrenme algoritmaları, üretim bandındaki ürünlerin fotoğraflarını analiz ederek yüzey kusurları, şekil bozuklukları veya renk hataları gibi kusurları tespit edebilir [16]. Bu yöntem, insan gözüyle yapılan denetimlerden daha hızlı ve daha tutarlıdır [15].

2.3.3. Süreç parametrelerinin optimizasyonu

Üretim süreçlerinde sıcaklık, basınç, hız gibi birçok parametre ürün kalitesini doğrudan etkiler. Makine öğrenmesi modelleri, bu parametreleri analiz ederek en

uygun üretim koşullarını belirleyebilir [17]. Böylece enerji tasarrufu sağlanırken kalite standartları da korunur [18].

2.3.4. Tahmine dayalı bakım

Makine öğrenmesi, arıza tahmin sistemlerinin geliştirilmesinde yaygın olarak kullanılmaktadır. Sensörlerden toplanan veriler üzerinden eğitilen algoritmalar, ekipmanların ne zaman arızalanabileceğini önceden tahmin ederek bakım işlemlerinin planlanmasını sağlar. Bu da üretimdeki plansız duruş sürelerini azaltır [19]. Ayrıca, bu tür sistemler, ekipmanların daha verimli çalışmasını sağlarken, üretim maliyetlerini de düşürür. Özellikle sanayiye dayalı üretim hatlarında, ekipmanların arızalanma süresi genellikle yüksek maliyetlere yol açtığı için, doğru bakım zamanlaması verimliliği artırmak adına kritik önem taşır. Makine öğrenmesi, bu tür bakımların öngörülmesinde, geçmiş verilerle eğitilen algoritmaların rolünü vurgulamaktadır. Ayrıca, makine öğrenmesi, arıza tahminine dayalı bakım sistemlerini optimize etmek için birçok parametreyi analiz eder ve bu sayede bakım süreçlerinin daha doğru bir şekilde yönetilmesine olanak tanır [20].

2.4. Kalite Tahmini ve Sınıflandırma

Ürünlerin kalite sınıflarının belirlenmesi, geçmiş verilerle eğitilmiş makine öğrenmesi modelleriyle yapılabilir [21]. Örneğin, malzeme özellikleri, üretim koşulları ve ölçüm verileri kullanılarak ürünlerin kalite kategorileri otomatik olarak sınıflandırılabilir [22].

2.5. Veri Bilimi – Üretim Verisinin Anlamlandırılması

Veri bilimi, büyük hacimli üretim verilerinden anlamlı bilgiler çıkarma sürecinde istatistik, matematik ve bilgisayar bilimlerinin birleşiminden yararlanır. Bu disiplin, üretim verilerini analiz ederek karar destek sistemleri oluşturmakta ve süreç iyileştirmelerinde aktif rol oynamaktadır. Makine öğrenmesi ile desteklenen veri bilimi uygulamaları, üretim süreçlerinde iyileştirme alanlarını belirlemek, arıza nedenlerini tespit etmek ve süreç verimliliğini artırmak için kullanılmaktadır. Böylece geçmiş verilere dayalı olarak gelecekteki davranışlar öngörülebilir hale gelir [23].

2.5.1. Desen tanıma ve tahminleme

Makine öğrenmesi modelleri, üretim sürecindeki kalıpları ve anormallikleri öğrenerek, sistemin bu tür durumları önceden tahmin edebilmesini sağlar. Özellikle makine duruşları, üretim hataları ve bakım ihtiyacı gibi kritik konular, bu tür analizlerle daha erken tespit edilebilir. Örneğin, üretim hatlarındaki duruşlar analiz edilerek, belirli zaman dilimlerinde yaşanan tekrar eden arızaların nedeni modellenenebilir [23].

2.5.2. Süreç iyileştirme ve verimlilik analizi

Veri bilimi, üretim sürecindeki darboğazları ve verimsizlikleri tespit ederek, bu alanlarda iyileştirme önerileri geliştirebilir. Sürekli toplanan sensör verileri, üretim süresi, enerji tüketimi ve hata oranı gibi metrikleri optimize etmek amacıyla analiz edilir. Böylece üretimde kaynakların daha etkin kullanılması sağlanır [24].

2.5.3. Kalite tahmini ve hata tespiti

Veri bilimciler, geçmiş kalite verileriyle eğitilmiş modeller kullanarak ürün kalitesini tahmin edebilir. Bu sayede üretimden önce muhtemel hatalar tespit edilerek maliyetli revizyonlar engellenebilir. Özellikle hassas toleranslar gerektiren sektörlerde bu tür sistemlerin doğruluk oranı oldukça yüksektir [25].



3. KALİTE KONTROL SÜREÇLERİNDE VERİ ODAKLI YAKLAŞIMLAR

3.1. Kalite Kontrol Kavramı ve Geleneksel Yöntemler

Kalite kontrol, ürün veya hizmetlerin belirli standartlara ve müşteri beklentilerine uygunluğunu sağlamak amacıyla yapılan sistematik faaliyetler bütünüdür. Bu süreç, üretim sırasında ve sonrasında ürünlerin kalite kriterlerine uygun olup olmadığını kontrol etmeyi hedefler. Kalite kontrol, sadece kusurları tespit etmekle kalmaz; aynı zamanda süreçlerdeki hataları önlemeye yönelik iyileştirmeler için veri sağlar. Tarihsel olarak, kalite kontrol ilk olarak elle yapılan gözlemsel incelemelere dayanıyordu, ancak zamanla istatistiksel yöntemlerin ve modern teknolojilerin entegrasyonu ile gelişmiştir [26].

3.1.1. Geleneksel kalite kontrol yöntemleri

3.1.1.1. Gözlemsel denetim

Üretim süreçlerinin ilk dönemlerinde en yaygın kalite kontrol yöntemi, elle yapılan gözlemsel denetimdir. Bu yöntemde operatörler ya da kalite kontrol personeli ürünleri görsel olarak inceleyerek kusurları tespit eder. Bu yaklaşım, sübjektifliği yüksek olmakla birlikte düşük hacimli üretimlerde etkili olabilmektedir [27].

3.1.1.2. Numune alma ve istatistiksel yöntemler

Daha sistematik bir yaklaşım olarak İstatistiksel Kalite Kontrol (İKK), üretimden rastgele alınan numuneler üzerinde yapılan analizlerle kaliteyi değerlendirir. Bu yöntemde, kontrol kartları (control charts), kabul örnekleme (acceptance sampling) ve süreç yeterlilik analizleri gibi araçlar kullanılır. Walter A. Shewhart tarafından geliştirilen kontrol kartları, süreç içindeki değişimleri izlemek ve süreç dışında olan sapmaları tespit etmek için yaygın olarak kullanılır [28].

3.1.1.3. Manuel ölçüm araçları

Kaliper, mikrometre ve mastar gibi manuel ölçüm araçları da kalite kontrolün temel araçları arasında yer alır. Bu araçlar, parçaların boyutsal doğruluğunu kontrol etmek

için yaygın olarak kullanılmaktadır. Ancak ölçüm sonuçları operatöre bağlı olduğu için hataya açıktır [29].

3.2. Toleranslar, GD&T (Geometric Dimensioning and Tolerancing) ve Ölçüm Yorumlama Süreci

3.2.1. Tolerans kavramı

Toleranslar, bir parçanın üretiminde kabul edilebilir ölçü sınırlarını tanımlar. Mükemmel ölçüler nadiren uygulanabilir olduğundan, mühendislik çizimlerinde her ölçü, belirli bir tolerans aralığıyla birlikte verilir. Bu aralık, parçanın işlevselliğini korurken üretilebilirliğini de sağlar. Genellikle toleranslar, nominal ölçünün üzerine veya altına belirli bir miktar sapmaya izin verir. Bu durum, üretim maliyetleri ile ürün performansı arasında bir denge kurulmasına olanak tanır [30].

Toleranslar, genel olarak ikiye ayrılır:

- **Boyutsal Toleranslar:** Uzunluk, çap, yükseklik gibi temel ölçülere uygulanır.
- **Geometrik Toleranslar:** Parçanın şekil, konum ve yön gibi geometrik özelliklerine yönelik sınırlamalardır.

3.3. GD&T (Geometric Dimensioning and Tolerancing)

Geometrik Boyutlandırma ve Toleranslandırma (GD&T), parçaların üretimi ve muayenesinde açıklık, netlik ve evrensel bir anlayış sağlamak amacıyla kullanılan standartlaştırılmış bir sistemdir. Bu sistem, geometrik ilişkileri matematiksel olarak ifade ederek üretim sürecinde yorum farklılıklarını azaltır [31].

GD&T sistemi, aşağıdaki ana tolerans türlerini kapsar:

- **Form Toleransları:** Düzlük (flatness), doğruluk (straightness), dairesellik (circularity), silindiriklik (cylindricity).
- **Yönelim Toleransları:** Paralellik (parallelism), diklik (perpendicularity), açısalılık (angularity).
- **Konum Toleransları:** Konum (position), eşmerkezlilik (concentricity), simetri (symmetry).
- **Sallanma Toleransları:** Toplam ve dairesel salınım (runout) [32].

GD&T'nin kullanımı, ölçüm cihazlarıyla yapılan değerlendirmelerin daha doğru ve tutarlı olmasını sağlar. Özellikle CMM (Koordinat Ölçüm Makineleri) ile yapılan ölçümlerde, GD&T standardı sayesinde karmaşık şekil ve konum sapmaları objektif şekilde analiz edilebilir [33].

3.4. Ölçüm Yorumlama Süreci

Ölçüm yorumlama süreci, parçaların kalite kontrol testlerinden sonra elde edilen ölçüm verilerinin değerlendirilmesini kapsar. Bu değerlendirme üç aşamada gerçekleşir:

1. **Veri Toplama:** CMM, manuel ölçüm cihazları veya optik sistemler ile ölçümler yapılır.
2. **Veri Analizi:** Ölçüm sonuçları nominal değerlere ve tolerans aralıklarına göre karşılaştırılır.
3. **Karar Verme:** Ölçüm verisi, parça kabul/red kararları için yorumlanır. Bu yorumlama sürecinde GD&T verileri referans alınır. Eğer ölçüm GD&T çerçevesinde kabul edilen sınırlar içinde kalıyorsa, parça kabul edilir. Aksi halde parça red edilir veya düzeltici faaliyete yönlendirilir [34].

Bu süreç, sadece üretim kontrolü için değil, aynı zamanda tasarım süreçlerinin iyileştirilmesi ve üretim maliyetlerinin azaltılması için de kritik öneme sahiptir.

3.5. Kalite Kontrolde İnsan Kaynaklı Hatalar ve Karar Farklılıkları

Kalite kontrol süreçlerinde insan faktörü, ölçüm doğruluğu ve karar verme mekanizmaları üzerinde doğrudan etkili olabilmektedir. Operatörlerin deneyimi, dikkat seviyesi, algı farklılıkları ve yorgunluk gibi değişkenler; aynı parçanın farklı kişiler tarafından farklı şekilde değerlendirilmesine yol açabilir. Bu durum, üretimde tutarsızlıkların artmasına, tekrar işleme gereksiniminin doğmasına ve genel üretim maliyetlerinin yükselmesine neden olabilir [35].

İnsan kaynaklı hatalar, kalite kontrol sistemlerinin en zayıf halkalarından biridir ve bu hatalar genellikle üç temel kaynaktan doğar: algılama hataları, karar verme hataları ve uygulama hataları [36]. Özellikle hassas ölçüm gerektiren işlerde, operatörün ölçüm cihazını kullanma biçimi ya da tolerans limitlerini yanlış yorumlaması, ölçüm sonuçlarının doğruluğunu ciddi şekilde etkileyebilir [37].

Ayrıca, kalite mühendislerinin veya operatörlerin ölçüm sonuçları üzerindeki yorumları subjektif olabileceğinden, aynı parçanın kabul veya red kararı farklı kişiler tarafından farklı şekillerde verilebilir. Bu çeşitlilik, üretim hattında belirsizlik yaratır ve nihai ürün kalitesinde tutarsızlıkların oluşmasına neden olur. Karar farklılıklarının önüne geçilmesi için standartlaştırılmış kontrol planları, otomatik karar destek sistemleri ve makine öğrenmesi destekli karar mekanizmalarının entegrasyonu önerilmektedir [38].

Günümüzde bu tür insan kaynaklı hataların azaltılması amacıyla makine öğrenmesi tabanlı sistemlerin kalite kontrol süreçlerine entegrasyonu yaygınlaşmaktadır. Bu sayede operatör yorumuna dayalı kararlardan ziyade, veriye dayalı ve tutarlı kalite kontrol kararları alınabilmekte ve üretim süreçleri daha güvenilir hale gelmektedir [24].

3.6. Veriyle Karar Verme: Subjektiflikten Nesnellığe Geçiş

Veriyle karar verme, organizasyonların daha doğru, tutarlı ve güvenilir kararlar almasına yardımcı olan bir süreçtir. Geleneksel karar verme yöntemleri, genellikle deneyime, sezgilere ve kişisel yorumlara dayalıdır. Bu süreçler, bireysel bakış açılarına, duygusal tepkilere ve anlık koşullara bağlı olarak değişkenlik gösterebilir. Bu da kararların doğruluğunu ve tutarlılığını olumsuz etkileyebilir [39]. Subjektif karar verme, bireysel algıların ve kişisel biasların devreye girmesine neden olarak, organizasyonlarda kalite kontrol süreçlerinde ve stratejik planlamada tutarsızlıklara yol açabilir.

Bu nedenle, veriyle karar verme süreci, subjektiflikten nesnellığe geçişin önemli bir aracıdır. Nesnel veri analizi, kararların kişisel görüşlerden arındırılmasını sağlar ve veriye dayalı, doğrulanabilir sonuçlar elde edilmesine olanak tanır [40]. Özellikle büyük veri setleri ve ileri düzey analiz teknikleri kullanılarak elde edilen nesnel veriler, yöneticilerin daha bilinçli ve gerçekçi kararlar almasını mümkün kılar. Bu geçiş, özellikle kalite kontrol, üretim süreçleri ve ürün geliştirme gibi alanlarda kritik bir rol oynar.

Makine öğrenmesi ve yapay zeka teknikleri, verinin hızlı ve doğru bir şekilde işlenmesi ve analiz edilmesi için güçlü araçlar sunar. Bu teknolojiler sayesinde, veriler doğrudan analiz edilerek, insan faktöründen kaynaklanan hataların ve subjektif yorumların ortadan kaldırılması sağlanabilir. Örneğin, üretim süreçlerinde toplanan

sensör verileri, gerçek zamanlı olarak işlenerek, üretim hattındaki aksaklıklar veya kalite problemleri önceden tespit edilebilir ve gerekli önlemler alınabilir [24].

Veriyle karar verme, işletmelerin daha verimli ve etkin bir şekilde yönetilmesini sağlarken, aynı zamanda üretim süreçlerinin optimizasyonunu ve kalite kontrolünün iyileştirilmesini de mümkün kılar. Bu sayede, organizasyonlar daha yüksek verimlilik, düşük hata oranları ve daha güvenilir sonuçlar elde ederler. Nesnel karar verme süreçleri, aynı zamanda iş gücünün motivasyonunu artırır çünkü herkesin kararları, veriye dayalı objektif ölçütlere göre alındığı için adalet duygusu da pekişir [41].

3.7. Otomatik Onay-Ret Sistemlerinin Gerekliliği

Otomatik onay-ret sistemleri, özellikle üretim süreçlerinde kalite kontrolünün hızını ve doğruluğunu artıran önemli araçlardır. Geleneksel kalite kontrol süreçlerinde, bir operatör veya kalite kontrol uzmanı tarafından yapılan manuel değerlendirmeler, genellikle zaman alıcıdır ve insan hatasına açıktır. Bu süreçlerdeki subjektif yorumlar, kararların tutarsız olmasına ve hata oranlarının artmasına neden olabilir [24]. Bu nedenle, otomatik onay-ret sistemleri, üretim süreçlerinde daha verimli ve güvenilir sonuçlar elde edilmesini sağlayan bir çözüm olarak öne çıkmaktadır.

Otomatik onay-ret sistemlerinin temel avantajlarından biri, kararların veriye dayalı ve nesnel olmasıdır. İnsan müdahalesinin minimuma indirildiği bu sistemler, makine öğrenmesi ve yapay zeka gibi ileri teknolojiler kullanarak, ürünün kalite standartlarına uygun olup olmadığını hızlı ve doğru bir şekilde değerlendirir. Örneğin, üretim hattında üretilen her parçanın ölçüm verileri, önceden belirlenen tolerans değerleriyle karşılaştırılarak otomatik olarak onaylanabilir veya reddedilebilir. Bu sistemler, yüksek hacimli üretim süreçlerinde zaman tasarrufu sağlamakla birlikte, hata oranlarını da ciddi şekilde azaltır [38].

Otomatik onay-ret sistemlerinin gerekliliği, özellikle büyük veri ve karmaşık üretim ortamlarında daha da belirginleşmektedir. Geleneksel yöntemlerle yapılan manuel kontrol, hızla değişen üretim şartları ve artan üretim talepleri karşısında yetersiz kalabilir. Makine öğrenmesi algoritmaları, bu tür büyük veri kümelerinden anlamlı desenler çıkararak, otomatik karar verme mekanizmalarının daha doğru ve güvenilir olmasını sağlar [40]. Örneğin, otomatik bir sistem, belirli bir ürünün küçük bir hatasını tespit edebilir ve bu hatayı insan gözünden kaçmadan doğru bir şekilde sınıflandırarak, red kararını verebilir.

Bir diğ r  nemli gereklilik ise insan fakt r nden kaynaklanan hataların azaltılmasıdır. Operat rler yorgunluk, dikkat dađınıklığı veya s bjektif yorumlar nedeniyle yanlış kararlar verebilirler. Otomatik onay-ret sistemleri, bu t r insan hatalarını ortadan kaldırarak daha tutarlı ve dođru sonu lar sunar. Ayrıca, bu sistemler, s rekli izleme ve iyileştirme s re lerine olanak tanıyarak, kalite kontrol s re lerinin optimize edilmesini sađlar [41].

Sonu  olarak, otomatik onay-ret sistemleri,  retim s re lerinde kalite kontrol n n etkinliğini artırmak, insan hatasını azaltmak ve verimliliđi y kseltmek i in vazge ilmez bir ara tır. Bu sistemlerin entegrasyonu, daha d   k maliyetler, daha hızlı  retim ve daha g venilir kalite kontrol sonu ları sađlarken, i letmelerin rekabet i avantaj elde etmelerine de katkıda bulunmaktadır.

4. CMM TEKNOLOJİSİ: VERİ KAYNAĞI VE UYGULAMA ALANI


4.1. CMM'in Temel Yapısı ve Ölçüm Teknikleri

Koordinat Ölçme Makineleri (CMM), modern üretim endüstrisinde ölçüm doğruluğunu ve kaliteyi güvence altına almak için yaygın olarak kullanılan yüksek hassasiyetli cihazlardır. Bu makineler, bir parçanın fiziksel boyutlarını üç boyutlu koordinatlar üzerinden ölçerek, parçanın tasarım spesifikasyonlarına ne derece uygun olduğunu değerlendirir [42]. CMM'ler, özellikle karmaşık geometrilere sahip parçaların ölçülmesinde, geleneksel ölçüm araçlarına göre daha doğru ve hızlı sonuçlar sunar.

4.1.1. Temel yapı

CMM'ler genellikle üç temel eksen (X, Y ve Z) hareket eden bir ölçüm kafasından oluşur. Bu yapı, farklı boyutlardaki parçaların çeşitli noktalarına ulaşarak ölçüm yapılmasına olanak tanır. Temel yapısal bileşenleri şu şekildedir:

- Taban (Granit Masa): Titreşimi minimuma indirerek ölçüm stabilitesi sağlar.
- Taşıyıcı Kol ve Kızak Sistemleri: X, Y ve Z eksenlerinde hassas hareket sağlar.
- Prob (Dokunmatik veya Temassız Sensör): Parça yüzeyine temas ederek ya da optik yöntemlerle ölçüm yapan ölçüm ucudur.
- Kontrol Ünitesi ve Yazılım: Ölçüm verilerini toplayan, analiz eden ve raporlayan sistem bileşenidir.
- Yapısal olarak CMM'ler genellikle köprülü (bridge type), portal (gantry type), yatay kol (horizontal arm) ve döner tabla sistemli olmak üzere dört ana kategoriye ayrılır. Her yapı tipi, kullanım alanına ve ölçüm ihtiyaçlarına göre tasarlanmıştır [43].
- Şekil 4.1'de CMM'in genel ve uzay görüntüsü görülmektedir.



Şekil 4.1. CMM genel görüntüsü ve Mcosmos (CMM Programı) Uzay Görüntüsü

4.1.2. Ölçüm teknikleri

CMM’lerde kullanılan ölçüm teknikleri genel olarak ikiye ayrılır: dokunmatik (taktik) ve temassız (optik) ölçüm teknikleri.

- Dokunmatik (Taktik) Ölçüm

Bu yöntemde, prob parça yüzeyine temas eder ve ölçüm noktaları manuel veya otomatik olarak alınır. Dokunmatik problemler genellikle tetiklemeli veya sürekli tarama şeklinde çalışır. Tetiklemeli problemler her temas noktasında bir ölçüm yaparken, sürekli tarama problemleri yüzey boyunca kayarak yüzey formunun detaylı haritasını çıkarabilir [44]. Şekil 4.2’de prob seçim ekranı görülmektedir.

- Temassız (Optik) Ölçüm

Lazer tarayıcılar, kamera sistemleri veya beyaz ışık tarayıcılar gibi temassız prob teknolojileri, yüzeye temas etmeden ölçüm almayı sağlar. Bu yöntem, özellikle yumuşak, hassas veya şekli bozulabilir parçaların ölçümünde tercih edilir. Temassız ölçüm sistemleri, hız avantajına sahip olmakla birlikte bazı durumlarda dokunmatik problemlere göre daha düşük hassasiyet gösterebilir [45].

Her iki teknik de ölçüm doğruluğu, parça tipi ve yüzey yapısı gibi kriterlere göre tercih edilmektedir. Ölçüm sonuçları, CAD verileri ile karşılaştırılarak parça onayı veya red

kararı verilir. Özellikle otomatik ölçüm programları sayesinde CMM'ler, yüksek üretim hacmine sahip ortamlarda bile tutarlı ve hızlı kalite kontrol sağlar.

Sonuç olarak, CMM sistemleri, üretim sektöründe kalite güvencesi sağlamanın yanı sıra tersine mühendislik, prototipleme ve hassas montaj süreçlerinde de kritik bir rol oynamaktadır. Bu makinelerin yapısı ve kullanılan teknikler, hem ölçüm güvenilirliğini hem de üretim verimliliğini önemli ölçüde artırmaktadır.

The image shows two windows from a CMM software interface. The top window is titled 'Başlangıç sihirbazı (1/4)' (Start Wizard (1/4)) and contains the 'Prob değişir' (Change Probe) dialog. It has options for 'Mevcut ağacı kullan' (Use current tree) and 'Ağaç numarası gir' (Enter tree number), with a dropdown for 'Prob ağaç numarası' (Probe tree number) set to 1. It also has a section for 'Argvden prob' (Probe from Argv) with a dropdown for 'İsim' (Name) and a section for 'Prob değiştir' (Change probe) with a dropdown for 'Prob numarası' (Probe number) set to 1. The bottom window is titled 'Prob bilgisi yönetimi #1, Swivel uzunluğu=173.350' (Probe Information Management #1, Swivel length=173.350) and displays a table of probe data.

#	Çap	Maks.fark	A	B	X	Y	Z
1	3.002	0.00053	0.0	0.0	0.000	0.000	0.000
2	3.000	0.00000	45.0	0.0	0.000	-122.577	50.773
3	3.000	0.00053	90.0	0.0	0.207	-173.802	173.988
4	3.000	0.00000	45.0	-90.0	-122.577	-0.000	50.773
5	3.000	0.00060	90.0	-90.0	-173.727	-0.102	174.045
6	3.000	0.00000	45.0	-180.0	-0.000	122.577	50.773
7	2.999	0.00031	90.0	-180.0	-0.033	173.794	174.110
8	3.000	0.00000	45.0	90.0	122.577	-0.000	50.773
9	3.000	0.00052	90.0	90.0	173.875	0.124	174.075
10	3.000	0.00000	45.0	180.0	0.000	122.577	50.773
11	2.999	0.00049	90.0	180.0	-0.039	173.798	174.115

Şekil 4.2. Prob değişim sekmesi ve seçim ekranı

4.2. Koordinat Ölçme Makinelerinden (CMM) Veri Alma Süreci


Üretim süreçlerinde kritik bir rol oynar çünkü doğru ölçüm verileri, kalite kontrolün temelini oluşturur. Bu süreç, fiziksel parçalar üzerinde ölçümler yaparak, bu verileri bilgisayar tabanlı sistemlere iletmeyi ve analiz etmeyi içerir. Aşağıda, CMM'den veri alma sürecini açıklayan adımlar ve kaynaklarla desteklenmiş açıklamalar yer almaktadır:

4.2.1. Veri toplama (ölçüm alma)

CMM, prob teknolojisini kullanarak, parçanın yüzeyinden ölçüm verilerini toplar. Bu prob, genellikle dokunmatik veya temassız olabilir ve ölçülen veriler genellikle X, Y ve Z koordinatlarında ifade edilir [43]. Verilerin toplanması, parçanın geometrik şekillerine dair hassas bilgiler sağlar. Ölçüm alınan noktalar belirli geometrik özellikleri temsil eder ve her nokta için 3D koordinatlar kaydedilir.

Adımlar:

- Prob Seçimi: Parçanın geometrisine ve özelliklerine göre uygun prob tipi (dokunmatik veya lazer prob) seçilir. Bu seçim, doğruluk ve hassasiyet açısından önemlidir [45].
- Ölçüm Noktalarının Belirlenmesi: Parçanın ölçülecek noktaları CAD (Bilgisayar Destekli Tasarım) verilerine dayalı olarak belirlenir [44].
- Veri Toplama: Prob, her ölçüm noktasında bir okuma yapar ve o noktaların 3D koordinatlarını kaydeder. Ölçüm alınan veriler, genellikle CMM'in yerleşik bilgisayarına iletilir ve burada saklanır. Veri toplama yani verilerin düzenlenmesi sekmesi Şekil 4.3'te görülmektedir.



Şekil 4.4. Programın uzaydaki hali ve düzenleme sekmesi

4.2.3. Veri analizi ve karşılaştırma

Toplanan ölçüm verileri, genellikle CAD modeliyle karşılaştırılır. Bu işlem, parçanın her bir ölçüm noktasının tasarımda belirtilen ideal koordinatlarla ne kadar uyumlu olduğunu belirler. Verilerin analizinde, aşağıdaki yöntemler kullanılır:

- **Tolerans Kontrolü:** Ölçüm verileri, tasarımda belirlenen toleranslarla karşılaştırılır. Veriler tolerans sınırlarının içinde mi dışında mı olduğu belirlenir ve eğer dışarıdaysa, kullanıcıya bildirilir [43].
- **Hata Tespiti:** Ölçülen veriler analiz edilerek, üretim sürecindeki hatalar tespit edilir. Hatalar, genellikle parçanın şekil bozukluğu veya deformasyonları olarak kendini gösterebilir [45].

4.2.4. Sonuçların yorumlanması

Ölçüm verileri kalite kontrol mühendisleri veya operatörler tarafından değerlendirilir. Eğer ölçüm sonuçları tolerans sınırları içinde kalıyorsa, parça onaylanır; eğer dışarıdaysa, parça reddedilir veya düzeltme yapılması için üretim sürecine geri gönderilir [43].

4.2.5. Veri raporlama ve sonuçların sunulması

Son olarak, CMM tarafından elde edilen ölçüm verileri genellikle raporlama formatında sunulur. Bu raporlar, üretim sürecinin izlenebilirliğini sağlamak için önemli bir kaynaktır. Ayrıca, bu raporlar kalite kontrol mühendislerinin kararlarını doğrulamak için kullanılır [44]. Parçaların program çıktısı Şekil 4.5 ve Şekil 4.6’da görülmektedir.

		CMM Ölçüm Raporu									
		KARMETAL San. ve Tic. Ltd. Şti. 1.OSB 10. Cadde No:11 Arifiye/Sakarya									
Date / time : 27.10.2023 / 17:44					Parça adı : 151 91 04 030--						
Ölçen :					Parça No :						
Onaylayan :					5 :						
Parça Adı :					6 :						
	Line	El.No	Element name	Characteristic	Nominal	+ tol.	- tol.	Actual	Tol. graphic	Dev.	Pos.No.
—	30	3	Çizgi	Doğrusallık	0.000	0.100	0.000	0.000			
—	34	4	Çizgi	Doğrusallık	0.000	0.100	0.000	0.000			
Ø	49	1	Daire	Çap	63.800	0.200	0.100	63.950			
Ø	55	2	Daire	Çap	63.800	0.200	0.100	63.952			
	64	1	Mesafe	Mesafe Z	74.000	0.010	-0.010	73.997			
	66	2	Mesafe	Mesafe Z	74.000	0.010	-0.010	73.964		-0.026	
	68	3	Mesafe	Mesafe Z	74.000	0.010	-0.010	74.075		0.065	
	69	1	Daire	Dairesel salgı	0.000	0.010	0.000	0.027		0.017	
	70	2	Daire	Dairesel salgı	0.000	0.010	0.000	0.016		0.006	
	71	4	Çizgi	Diklik	0.000	0.020	0.000	0.011			

Şekil 4.5. Parça program çıktısı



Şekil 4.6. Parça program çıktısı

4.2.6. Otomatikleştirilmiş veri toplama

Son yıllarda, CMM sistemlerinin otomatikleştirilmesi daha yaygın hale gelmiştir. Otomatik ölçüm programları, operatör müdahalesi olmadan ölçüm yapmayı ve verileri analiz etmeyi sağlar. Bu, insan hatası riskini azaltır ve veri toplama sürecinin hızlanmasını sağlar [45].

4.3. CAD Karşılaştırmaları ve Ölçüm Standartları

Koordinat Ölçme Makineleri (CMM), parçaların geometrik doğruluğunu değerlendirmek için genellikle CAD (Bilgisayar Destekli Tasarım) verileriyle karşılaştırmalar yapar. Bu süreç, modern üretim ve kalite kontrolünün temel taşlarından biridir ve parçaların tasarımla ne kadar uyumlu olduğunu belirlemeye yardımcı olur. CMM kullanılarak yapılan CAD karşılaştırmaları, parçaların üretim hatalarını tespit etmenin yanı sıra, tasarım sürecinin doğruluğunu da garanti altına alır.

Bu yazıda, CAD karşılaştırmalarının nasıl yapıldığı, bu süreçte kullanılan ölçüm standartları ve bu standartların önemini ele alacağız.

4.3.1. CAD karşılaştırmalarının temeli

CAD karşılaştırmaları, üretim sürecinde elde edilen ölçüm verilerinin tasarımdaki ideal verilere karşı kıyaslanmasıdır. Bu karşılaştırmalar, genellikle üç ana adımı içerir:

- **Veri Toplama:** CMM probu, CAD modeline uygun olarak belirli ölçüm noktalarındaki koordinatları toplar. Bu koordinatlar, genellikle X, Y, Z düzlemlerinde belirlenir.
- **Veri Karşılaştırma:** Elde edilen ölçüm verileri, CAD modelinin tasarım değerleriyle karşılaştırılır. Bu karşılaştırma, belirli bir tolerans aralığına göre yapılır.
- **Sonuçların Analizi:** Ölçüm verilerinin, CAD modeline uygunluğu değerlendirilir. Eğer ölçüm verileri, CAD modelindeki tolerans sınırları içerisinde kalıyorsa, parça onaylanır; aksi takdirde düzeltme yapılması için parçanın üretim sürecine geri gönderilmesi gerekebilir.

CAD karşılaştırmalarının amacı, parçaların tasarımda belirtilen özelliklere ne kadar uyduğunu belirlemek ve üretim hatalarını tespit etmektir [43]. Bu süreç, özellikle yüksek hassasiyet gerektiren uygulamalarda, ürünün kalitesinin güvence altına alınması için kritik öneme sahiptir.

4.3.2. Ölçüm standartları

Ölçüm standartları, CMM kullanılarak yapılan karşılaştırmaların doğruluğunu ve güvenilirliğini sağlamak için belirli kurallar ve yöntemler sunar. Bu standartlar, ölçümün nasıl yapılması gerektiğini, tolerans sınırlarının nasıl belirlenmesi gerektiğini ve veri doğruluğunun nasıl garanti altına alınması gerektiğini belirler. Aşağıda, CMM ile yapılan ölçümlerde sıklıkla kullanılan bazı ölçüm standartları bulunmaktadır:

a. ISO 10360 – CMM Performans Standartları

ISO 10360, CMM'lerin doğruluğu ve performansını belirleyen bir dizi uluslararası standarttır. Bu standart, CMM sistemlerinin kalibrasyonu, doğruluk testi ve performans değerlendirmeleri için rehberlik sağlar. ISO 10360, CMM'in ölçüm doğruluğunu, tekrarlanabilirliğini ve doğrulama testlerini kapsayan bir dizi prosedür sunar [46].

b. GD&T (Geometric Dimensioning and Tolerancing)

GD&T, parçaların geometrik boyutlandırılmasında ve toleranslarının belirlenmesinde yaygın olarak kullanılan bir standarttır. GD&T, parçaların tasarımında kullanılan tüm geometrik, boyutsal ve konumsal toleransları belirtir ve bu toleranslar, CAD modeline göre CMM ile ölçülerek kontrol edilir [47]. GD&T, aynı zamanda üretim sırasında parça uyumsuzluklarının tespit edilmesi için temel bir araçtır.

c. ISO 1101 – Geometrik Boyutlandırma ve Toleranslama

ISO 1101, GD&T'nin uygulandığı bir başka uluslararası standarttır ve parçaların geometrik özelliklerinin ve toleranslarının nasıl tanımlanması gerektiğini belirler. Bu standart, özellikle tasarım, üretim ve kalite kontrol süreçlerinde net bir iletişim sağlar. ISO 1101, her bir parçanın boyutsal ve geometrik özelliklerini belirtirken, üretim toleranslarının ne şekilde uygulanması gerektiğini de düzenler [48].

4.3.3. CAD ve CMM karşılaştırmaları arasındaki ilişki

CAD verileri, üretimin başlangıcında parçaların tasarımını ve geometrik yapılarını belirler. Bu veriler, üretim sürecinde en doğru ölçüm sonuçlarını almak için CMM sistemlerine yönlendirilir. CMM ile yapılan ölçümler, tasarımın doğru bir şekilde üretilip üretilmediğini değerlendirir. CAD karşılaştırmaları, her iki verinin uyumunu sağlayarak, üretim sürecinde hata payını minimize eder [44].

4.3.4. Ölçüm sonuçlarının yorumlanması

CAD karşılaştırmalarında, elde edilen ölçüm verileri genellikle belirli bir tolerans aralığına göre değerlendirilir. Bu, ürünün tasarım gereksinimlerini karşılayıp karşılamadığını belirlemek için kritik bir adımdır. Eğer ölçüm sonuçları, CAD modelindeki tolerans sınırları içinde kalıyorsa, parça onaylanır. Aksi takdirde, parça üretim sürecine geri gönderilir veya yeniden işleme tabi tutulur [44].

4.3.5. Teknolojik gelişmeler ve otomasyon

Son yıllarda, CAD karşılaştırmalarının ve CMM ölçüm sistemlerinin daha verimli hale gelmesi için otomasyon teknolojileri geliştirilmiştir. Bu, veri toplama sürecini hızlandırmakta ve insan hatasını azaltmaktadır. Ayrıca, yapay zeka ve makine öğrenmesi gibi teknolojiler, CAD ve CMM karşılaştırmalarının daha doğru ve hızlı bir şekilde yapılmasına olanak tanımaktadır [45].

4.4. Üretim Ortamında CMM'nin Rolü

Koordinat Ölçme Makineleri (CMM), modern üretim süreçlerinin önemli bir parçası haline gelmiş ve kalite kontrol sistemlerinin temel araçlarından biri olmuştur. Bu makineler, üretim hatlarında parçaların boyutsal doğruluğunu sağlamak, üretim süreçlerini izlemek ve ürünlerin tasarım gereksinimlerine uygunluğunu belirlemek için kullanılır. CMM, birçok endüstriyel uygulamada ve kalite kontrol aşamalarında kritik bir rol oynamaktadır. Bu yazıda, CMM'nin üretim ortamındaki rolü ve önemi ele alınacaktır.

4.4.1. Parça ölçümü ve doğrulama

CMM, üretim sürecinde üretilen her bir parçanın doğru boyutlarda ve tasarıma uygun olup olmadığını kontrol etmek için kullanılır. Bu makineler, parçaların her türlü boyutsal ölçüsünü (uzunluk, çap, derinlik, vb.) hassas bir şekilde alabilir. CMM, özellikle yüksek hassasiyet gerektiren parçaların üretiminde, hata payını minimuma indirmek için kullanılır. Ayrıca, parçaların belirli tolerans sınırları içinde olup olmadığı kontrol edilerek, parçaların tasarıma uygunluğu değerlendirilir. [43]

4.4.2. Kalite kontrol ve üretim iyileştirmeleri

CMM, üretim hatlarındaki kalite kontrol süreçlerinin temel bir parçasıdır. Herhangi bir hata veya uygunsuzluk tespit edildiğinde, bu bilgiler üretim ekibine hemen iletilir. Bu sayede, hatalı üretim süreçleri hızlı bir şekilde düzeltilir ve üretimdeki verimlilik artırılır. CMM'ler, aynı zamanda üretim hatalarında ortaya çıkabilecek tekrarlayan hataların erken tespiti için kullanılır ve böylece kalite yönetim sistemlerinin etkinliğini artırır. [44]

4.4.3. Gerçek zamanlı izleme ve otomasyon

Modern üretim ortamlarında, CMM makineleri genellikle üretim hatlarında entegre bir şekilde çalışır ve gerçek zamanlı veri toplama yeteneklerine sahiptir. Bu makineler, sürekli olarak ölçüm verilerini toplayarak üretim sürecini izler. Bu sayede, üretim aşamasında herhangi bir hata ortaya çıkmadan önce, önleyici tedbirler alınabilir. CMM makineleri, otomatikleştirilmiş ölçüm süreçleri sayesinde, insan hatasını en aza indirir ve üretim hızını artırır. Ayrıca, otomatik onay-ret sistemleriyle birlikte çalışarak, üretim sürecinde her bir parçanın uygunluk durumu hızlı bir şekilde belirlenebilir [49]

4.4.4. Veri analizi ve üretim kararları

CMM, yalnızca ölçüm verilerini toplamakla kalmaz, aynı zamanda bu verileri analiz etmek için çeşitli algoritmalar ve yazılımlar kullanabilir. Toplanan veriler, üretim sürecinde yapılan iyileştirmelere yardımcı olmak için kullanılır. Özellikle büyük veri analitiği ve makine öğrenmesi teknolojilerinin entegrasyonu ile CMM, daha akıllı ve hızlı kararlar alınmasına olanak sağlar. Bu tür analizler, üretim süreçlerini optimize etmek, kaliteyi artırmak ve maliyetleri düşürmek için kritik veriler sunar . [49]

4.4.5. Prototip ve üretim aşamaları arasındaki bağlantı

CMM, üretim sürecinin her aşamasında kritik bir rol oynar. Prototip üretiminden seri üretime kadar her aşama, CMM tarafından izlenebilir. Özellikle prototip aşamasında, CAD verileri ile gerçek ölçümler arasındaki uyumsuzluklar tespit edilebilir ve tasarımda gerekli düzeltmeler yapılabilir. Ayrıca, seri üretim sırasında her bir parçanın doğruluğu kontrol edilerek, yüksek kaliteli üretimin devamlılığı sağlanır. Bu süreç, üretimin her aşamasında kaliteyi güvence altına alır . [43]

4.4.6. Müşteri memnuniyeti ve ürün güvenliği

CMM'nin üretim ortamındaki rolü, son kullanıcıya ulaşacak olan ürünlerin kalitesini doğrudan etkiler. CMM, üretim sürecinde hatalı parçaların önüne geçilmesini sağlayarak, müşteri memnuniyetini artırır. Ayrıca, özellikle otomotiv, havacılık ve tıbbi cihazlar gibi sektörlerde, CMM ile yapılan ölçümler ürün güvenliğini sağlamada hayati bir rol oynar. Bu sektörlerde, tasarım hataları ve üretim hataları, ciddi güvenlik risklerine yol açabileceğinden, CMM ile yapılan doğrulama işlemleri kritik öneme sahiptir. [44]

4.4.7. Tolerans yönetimi

CMM, parçaların belirtilen tolerans aralıkları içinde olup olmadığını kontrol eder. Tolerans yönetimi, üretim süreçlerinde çok önemlidir çünkü her parçanın belirli bir tolerans aralığında üretilmesi, ürünün genel işlevselliği ve uyumluluğu için gereklidir. CMM, bu toleranslara uygunluğu denetler ve üretim sürecinde tolerans dışı parçaların ayrılmasına yardımcı olur. Böylece, ürünlerin birleştirilmesi ve işlevsel olması sağlanır . [47]

4.4.8. Eğitim ve beceri geliştirme

CMM kullanımı, üretim iş gücünün eğitimine de katkı sağlar. CMM makineleri, operatörlerin gelişen teknolojilere ve yeni ölçüm tekniklerine uyum sağlamasına yardımcı olur. Bu makineleri etkili kullanabilmek için çalışanların özel eğitim alması gerekmektedir. Eğitim süreci, kalite kontrol ve üretim süreçlerinde daha verimli ve hatasız çalışmaya olanak tanır . [50]

CMM'nin üretim ortamındaki rolü, yalnızca kalite kontrolün sağlanmasında değil, aynı zamanda üretim süreçlerinin optimizasyonunda ve müşteri memnuniyetinin artırılmasında da büyüktür. CMM makineleri, üretim hatlarında kaliteyi güvence altına alarak, hatalı ürünlerin önüne geçilmesini ve üretim verimliliğinin artırılmasını sağlar. Bunun yanı sıra, verilerin doğru bir şekilde toplanması ve analiz edilmesi, üretim süreçlerini iyileştirerek daha hızlı ve doğru kararların alınmasına olanak tanır. [43]

4.5. CMM'in Otomatik Kalite Kontrol Sistemine Entegrasyonu

Koordinat Ölçme Makineleri (CMM), geleneksel olarak kalite kontrol süreçlerinin ayrılmaz bir parçası olmuştur. Ancak, son yıllarda gelişen teknolojiler ve otomasyon sistemleriyle birlikte, CMM makinelerinin otomatik kalite kontrol sistemlerine entegrasyonu, üretim süreçlerinin daha verimli, hızlı ve hatasız bir şekilde yönetilmesini sağlamıştır. CMM'in otomatik kalite kontrol sistemlerine entegrasyonu, hem üretim verimliliğini artırmak hem de kaliteyi güvence altına almak için önemli bir adım olmuştur. Bu yazıda, CMM'in otomatik kalite kontrol sistemine entegrasyonu ve sağladığı avantajlar üzerinde durulacaktır. [44]

4.5.1. Entegrasyonun temel amacı

CMM makinelerinin otomatik kalite kontrol sistemlerine entegrasyonu, ölçüm verilerinin otomatik olarak toplanması, analiz edilmesi ve karar verme süreçlerinin hızlandırılmasını hedefler. Bu entegrasyon, özellikle üretim hattındaki tüm aşamaları izlemek, hataları tespit etmek ve üretim sürecinde yapılacak iyileştirmeleri belirlemek için kullanılır. CMM ile elde edilen ölçüm verileri, otomatik sistemlere aktarılır ve bu sistemler, verileri hızlı bir şekilde işleyerek kalite kontrol kararlarını otomatik olarak verir. [44]

4.5.2. Otomatik ölçüm ve veri toplama

CMM makineleri, geleneksel ölçüm yöntemlerinin aksine, otomatik olarak verileri toplar ve kaydeder. Bu makineler, belirli bir üretim parçasının her bir özelliğini ölçerken, bu veriler otomatik olarak kalite kontrol yazılımına aktarılır. Veri toplama süreci hızlanır ve insan hataları minimize edilir. Ayrıca, bu veriler, daha sonra analiz edilmek üzere bir veritabanında saklanır ve geçmiş ölçümlerle karşılaştırılır. [44]

4.5.3. Makine öğrenmesi ve verilerin analizi

CMM makinelerinin otomatik kalite kontrol sistemine entegrasyonu, makine öğrenmesi ve yapay zeka gibi teknolojilerle desteklenebilir. Makine öğrenmesi algoritmaları, toplanan ölçüm verilerini analiz eder ve üretim süreçlerinde herhangi bir anormallik veya hatayı önceden tahmin edebilir. Bu, üretim hattında ortaya çıkabilecek hataların önceden tespit edilmesini ve önlenmesini sağlar. Özellikle, üretim süreçlerinde sık sık tekrarlanan hataların analizi, otomatik sistemin öğrenmesini ve zaman içinde kendini geliştirmesini sağlar. [49]

4.5.4. Otomatik onay-ret kararları

CMM makineleri ile yapılan ölçümler, otomatik kalite kontrol sistemlerine entegre edildiğinde, bu sistemler, her bir parçanın kalite standartlarına uygunluğunu değerlendirebilir ve otomatik onay-ret kararları alabilir. Bu kararlar, belirli toleranslara dayalı olarak verilir ve herhangi bir parçanın standartlardan sapıp saptığını hızlı bir şekilde belirler. Eğer parça standartlara uygunsa, sistem otomatik olarak onay verir; eğer parça uygunsuzsa, sistem otomatik olarak reddedebilir. Bu otomatik karar mekanizması, kalite kontrol süreçlerini hızlandırır ve insan hatalarının önüne geçer. [51]

4.5.5. Gerçek zamanlı izleme ve geri bildirim

Otomatik kalite kontrol sistemleri, CMM makinelerinin sağladığı verilerle gerçek zamanlı izleme yapabilir. Bu izleme, üretim sürecinde herhangi bir sapma veya hata oluştuğunda hemen geri bildirim sağlar. CMM, her ölçüm verisini anında analiz eder ve sonuçları üretim sürecinde yer alan ekiplerle paylaşır. Bu sayede, üretim sürecindeki hatalar anında düzeltilir ve üretim hızı kesintiye uğramaz. Ayrıca, bu veriler, üretim süreçlerinin iyileştirilmesi ve optimizasyonu için de kullanılabilir. [50]

4.5.6. Entegre sistemler ve otomasyon

CMM makinelerinin otomatik kalite kontrol sistemlerine entegrasyonu, sadece ölçüm verilerinin toplanmasıyla sınırlı değildir; aynı zamanda üretim makineleri ve robotik sistemlerle de entegrasyon sağlar. Örneğin, CMM makineleri, bir üretim robotu tarafından üretilen parçaları otomatik olarak kontrol edebilir ve hatalı parçaları robotlara yeniden işleme için işaret edebilir. Bu tür entegre sistemler, üretim hattındaki her bir adımı otomatikleştirir ve üretim süreçlerinin çok daha verimli hale gelmesini sağlar. [49]

4.5.7. Veri tabanlı karar verme

CMM ile elde edilen veriler, otomatik kalite kontrol sistemlerinde kullanılan karar destek yazılımlarına aktarılır. Bu yazılımlar, verileri analiz ederek, üretim hatlarında karşılaşılan sorunlara dair öneriler sunar. Veriler, karar vericilere üretim sürecinde yapılacak iyileştirmeleri belirlemek için gerekli bilgileri sağlar. Ayrıca, bu veriler gelecekteki üretim süreçleri için tahminler yaparak, önceden alınacak önlemlerle üretim hatalarını minimize edebilir. Bu tür veri tabanlı karar verme sistemleri, üretim süreçlerini daha hızlı ve etkili hale getirir. [50]

4.5.8. Zaman ve maliyet tasarrufu

CMM makinelerinin otomatik kalite kontrol sistemlerine entegrasyonu, kalite kontrol süreçlerini daha hızlı ve verimli hale getirir. Ölçüm ve analiz süreçlerinin otomatikleştirilmesi, üretim sürecindeki gecikmeleri ortadan kaldırır ve zaman tasarrufu sağlar. Ayrıca, otomatik sistemler, hatalı üretim parçalarının tespit edilmesinde hızlı bir şekilde karar verdiği için, gereksiz malzeme israfını ve iş gücü kaybını önler. Bu sayede, üretim maliyetleri azalır ve verimlilik artar. [44]


CMM makinelerinin otomatik kalite kontrol sistemlerine entegrasyonu, modern üretim süreçlerinde büyük bir devrim yaratmıştır. Bu entegrasyon hem kaliteyi artırmak hem de üretim süreçlerini hızlandırmak için çok önemli bir araçtır. Otomatik veri toplama, analiz, onay-ret kararları ve gerçek zamanlı geri bildirim gibi özellikler, üretim verimliliğini artırırken, insan hatalarını minimize eder ve kaliteyi sürekli olarak izler. CMM'in otomatik kalite kontrol sistemlerine entegrasyonu, gelecekteki üretim süreçlerinin daha da otomatikleşmesini ve optimizasyonunu sağlayacak önemli bir adımdır. [44]



5. DENEYSEL ÇALIŞMALAR

5.1. Deneysel Sürecin Genel Yapısı

Bu tez çalışmasında, üretim sürecinde oluşabilecek hatalı parçaların erken tespiti ve kalite kontrol sürecinin operatör bağımsız hale getirilmesi amacıyla iki farklı makine parçası üzerinde deneysel çalışmalar yapılmıştır. Bu parçalar, dişli kutusu ve servo somun takozu olarak belirlenmiş olup her birinden 40 adet örnek alınarak analiz edilmiştir. Dişli kutusu görseli Şekil 5.1.'de servo somun takozu görseli de Şekil 5.2.'de verilmiştir.



Şekil 5.1. Dişli kutusu



Şekil 5.2. Servo somun takozu

Ölçümler, yüksek doğruluk sağlayan Mitutoyo Crysta-Apex V 9106 model CMM cihazı ile gerçekleştirilmiştir. Ölçümler sırasında sabit sıcaklık (21 °C) sağlanan laboratuvar ortamında, her parça termal denge için ölçüm öncesi bekletilmiş, ardından konumlandırılarak ölçüme alınmıştır. CMM cihazı, hem dokunmalı prob sistemi hem de CAD modeli üzerinden oluşturulan otomatik ölçüm programlarıyla çalıştırılmıştır. Böylece ölçüm tekrarlanabilirliği artırılmış ve kullanıcı kaynaklı hatalar minimize edilmiştir.

Parçaların ölçüm süresi, geometrik karmaşıklığa göre değişmiş olup, dişli kutusu için ortalama 30 dakika, servo somun takozu için 15 dakika sürmüştür. Tüm ölçümler teknik resim toleransları referans alınarak değerlendirilmiş, bu tolerans dışına çıkan parçalar “uygunsuz” olarak işaretlenmiştir. Elde edilen ölçüm verileri, dijital ortama aktarılarak makine öğrenmesi algoritmalarıyla işlenmek üzere hazır hale getirilmiştir.

Ölçüm sonuçları, her bir parçanın teknik resmi üzerinden kontrol edilerek uygunluk değerlendirmesi yapılmıştır. Elde edilen veriler ilk aşamada manuel olarak tabloya

girilmiş, ardından yazılım ortamına aktarılmıştır. Her parça, ölçüm sonuçlarına göre “uygun” ya da “uygunsuz” olarak etiketlenmiştir. Özellikle eş merkezlilik sorunu gibi üretim hataları nedeniyle bazı parçaların hurdaya ayrıldığı gözlemlenmiştir.

Bu ölçüm süreci ile elde edilen veriler, ilerleyen bölümlerde detaylı olarak işlenecek olan makine öğrenmesi algoritmalarının temel veri setini oluşturmuştur. Amaç, bu veriler üzerinden parçanın durumuna ilişkin karar verme sürecinin, insan faktöründen bağımsız ve nesnel bir algoritmik yapı ile desteklenmesidir.

5.2. Kullanılan Algoritmalar

5.2.1. Random forest algoritması

Makine öğrenmesi alanında öne çıkan topluluk (ensemble) yöntemlerinden biri olan Random Forest, Leo Breiman tarafından 2001 yılında geliştirilen bir algoritmadır. Bu yöntem, özellikle sınıflandırma ve regresyon problemlerinde yüksek doğruluk oranı, kararlılık ve genelleme kabiliyeti ile dikkat çekmektedir. Random Forest, temel olarak çok sayıda karar ağacından oluşan bir model topluluğudur ve bu ağaçların sonuçlarını birleştirerek nihai tahmini gerçekleştirir. Bu yönüyle, tek bir karar ağacının neden olabileceği aşırı öğrenme (overfitting) problemini önemli ölçüde azaltır [52].

5.2.1.1. Teorik temelleri

Random Forest algoritması, “bagging” (Bootstrap Aggregating) adı verilen istatistiksel yöntem temel alınarak geliştirilmiştir. Bagging yöntemi, eğitim verisinin rastgele ve tekrar etmeye izin veren örneklemeyle birçok alt veri kümesi oluşturur. Her bir alt küme için bağımsız bir karar ağacı inşa edilir. Random Forest bu yönteme ek olarak, her ağacın inşası sırasında özelliklerin (değişkenlerin) rastgele alt kümesinin seçilmesini sağlar. Bu rastgelelik, ağaçlar arasındaki korelasyonu azaltarak modelin çeşitliliğini artırır ve topluluk modelinin genelleme başarımını yükseltir [52][53].

Her bir karar ağacı, eğitim verisinin farklı bir örneklemeyle eğitildiği için, belirli örneklere fazla uyum sağlama riski azalır. Regresyon problemlerinde tüm ağaçlardan alınan tahminlerin aritmetik ortalaması, sınıflandırma problemlerinde ise çoğunluk oyu (majority voting) ile nihai karar verilir [53][54].

5.2.1.2. Özellikleri ve avantajları

Random Forest, birçok yönüyle klasik karar ağaçlarına kıyasla üstünlük gösterir:

Aşırı öğrenmeye karşı dirençlidir. Bireysel karar ağaçları genellikle veriye fazla uyum sağlar; ancak Random Forest bu ağaçların ortalamasını aldığı için aşırı öğrenme riski azalır.

Büyük veri kümeleriyle etkili çalışır. Yüksek boyutlu verilerde (çok sayıda değişken içeren veri setlerinde) dahi performansı yüksektir.

Eksik verilerle başa çıkabilir. Random Forest, eksik veri içeren gözlemlerle etkili şekilde çalışabilir ve değişkenler arası önem ilişkilerini belirleyebilir.

Değişken önem derecesi sunar. Model, hangi değişkenlerin tahminlerde ne derece etkili olduğunu gösterebilir. Bu, özellikle veri ön işleme ve özellik seçimi süreçlerinde fayda sağlar [52][54][55].

5.2.1.3. Uygulama alanları

Random Forest, farklı alanlarda geniş bir uygulama yelpazesine sahiptir. Sağlık sektöründe hastalık teşhisinden, finans alanında kredi risk analizine; üretim sektöründe kalite kontrol ve hata tespiti gibi uygulamalardan, biyoinformatik alanında genetik veri analizi gibi yüksek boyutlu problemlere kadar kullanılmaktadır [53][55]. Endüstriyel kalite kontrol uygulamalarında, özellikle sensör verilerinin analizi ve ürün sınıflandırması gibi işlemlerde yaygın olarak tercih edilmektedir. Örneğin, üretim bandında çıkan parçaların hatalı olup olmadığının tahmin edilmesinde ya da ölçüm verilerine göre tolerans dışı sapmaların belirlenmesinde etkin rol oynayabilir [56][57].

5.2.1.4. Random forest ve kalite kontrol

Random Forest algoritmasının üretim ve kalite kontrol sistemlerinde kullanılmasının en önemli avantajı, doğrusal olmayan ilişkilere duyarlı olması ve çok değişkenli karmaşık veri yapılarında dahi tutarlı sonuçlar üretebilmesidir. Kalite mühendisliği bağlamında, üretim verilerinden öğrenme yaparak olası hataları önceden tahmin etmek, süreç içi değişimleri tespit etmek ve proses optimizasyonu sağlamak amacıyla kullanılabilir [56][57].

5.2.2. Support vector machine (SVM) algoritması

Support Vector Machine (SVM), istatistiksel öğrenme teorisine dayanan, doğruluk ve genelleme başarısı yüksek, denetimli bir makine öğrenmesi algoritmasıdır. İlk olarak Vladimir Vapnik ve Alexey Chervonenkis tarafından teorik temelleri atılan bu yöntem, 1990'lı yıllarda Vapnik ve Cortes tarafından uygulamalı hale getirilmiştir [9]. SVM,

sınıflandırma ve regresyon analizlerinde yaygın olarak kullanılan güçlü bir modeldir. Temel amacı, farklı sınıflara ait verileri birbirinden ayıran **en uygun hiperdüzlemi (decision boundary)** bulmaktır. Bu hiperdüzlem, sınıflar arasındaki mesafeyi (marjin) maksimum yaparak genelleme yeteneğini artırır [58].

5.2.2.1. Teorik yapısı ve matematiksel temelleri

SVM algoritmasının temelinde yer alan fikir, veriler arasındaki ayrımı en iyi sağlayan düzlemin bulunmasıdır. Bu düzlem, veriyi sınıflara ayıran ve sınıflara en yakın örnekler (destek vektörleri) ile belirlenen maksimum marjinli hiperdüzlemdir. İki sınıf arasındaki bu en geniş marjin, modelin genelleme yeteneğini doğrudan etkiler. Marjin ne kadar geniş olursa, modelin yeni veriler üzerinde doğru tahmin yapma olasılığı da o kadar artar [9][58].

Bu işlem, doğrusal olarak ayrılabilen verilerde nispeten basittir. Ancak gerçek dünya verileri genellikle doğrusal olarak ayrılabilir değildir. Bu durumda, SVM doğrusal olmayan sınıflandırmalar için çekirdek (kernel) fonksiyonları kullanır. Çekirdek fonksiyonları, verileri daha yüksek boyutlu bir uzaya projekte ederek, bu yeni uzayda doğrusal olarak ayrılabilir hale getirir. En sık kullanılan çekirdek fonksiyonları şunlardır:

- Lineer çekirdek
- Polinomsal çekirdek
- Radyal tabanlı fonksiyon (RBF, Gaussian çekirdek)
- Sigmoid çekirdek

Çekirdek fonksiyonu seçimi, modelin başarımını doğrudan etkiler. Özellikle RBF çekirdeği, çok boyutlu ve karmaşık yapıları verilerde üstün başarı göstermektedir [59][60].

5.2.2.2. SVM'in avantajları ve güçlü yönleri

SVM, makine öğrenmesindeki en kararlı ve güvenilir algoritmalarından biri olarak kabul edilir. Bunun birkaç temel nedeni vardır:

- Genelleme kabiliyeti yüksektir. Marjin maksimizasyonu sayesinde, eğitim verisine aşırı uyum sağlamak yerine, tüm veri uzayında dengeli bir sınıflama sağlar.

- Aşırı öğrenmeye (overfitting) karşı dayanıklıdır. Özellikle küçük ama ayırt edici örneklem kümelerinde yüksek doğruluk verir.
- Yüksek boyutlu verilerde çalışabilir. Özellikle biyoinformatik, metin madenciliği ve görüntü işleme gibi çok sayıda değişken içeren alanlarda başarılıdır.
- Destek vektörlerine dayalıdır. Model sadece karar sınırına en yakın veri noktalarına (destek vektörlerine) dayanır; bu da modelin sadeliğini ve yorumlanabilirliğini artırır [58][59].

Ancak dezavantajları da göz önünde bulundurulmalıdır. Büyük veri setlerinde eğitim süresi uzayabilir ve parametre seçimi (örneğin çekirdek fonksiyonu türü, C ve gamma parametreleri) model başarımını önemli ölçüde etkileyebilir. Bu nedenle, çapraz doğrulama (cross-validation) ve hiperparametre optimizasyonu kritik önemdedir [60].

5.2.2.3. SVM'in uygulama alanları

SVM, geniş bir uygulama yelpazesinde başarılı sonuçlar vermektedir. Aşağıda bazı temel kullanım alanları yer almaktadır:

- Sağlık: Kanseri teşhisi (özellikle meme kanseri ve prostat kanseri), hastalık sınıflandırması, genetik dizilim analizi.
- Finans: Kredi skorlama, dolandırıcılık tespiti.
- Görüntü İşleme: Nesne tanıma, yüz tanıma, karakter tanıma.
- Metin Madenciliği: E-posta filtreleme (spam tespiti), belge sınıflandırması, duygu analizi.
- Endüstri ve Üretim: Kalite kontrol, üretim hatası sınıflandırması, kestirimci bakım [58][61].

5.2.2.4. Kalite kontrol ve endüstriyel uygulamalarda SVM

SVM, kalite kontrol uygulamalarında özellikle sınıflandırma görevleri için uygundur. Ürünlerin “uygun” ya da “uygunsuz” olarak sınıflandırılması gereken durumlarda, karar sınırlarını belirgin şekilde oluşturması sayesinde güçlü bir tahmin aracı olarak öne çıkar. Ölçüm verilerine veya görsel denetim sonuçlarına dayanarak, üretim hattında çıkan parçaların hata içerip içermediği SVM ile yüksek doğrulukla belirlenebilir.

Ayrıca süreç kontrolü, proses optimizasyonu ve hata nedenlerinin analizi gibi görevlerde de kullanılabilir. Özellikle SVM'in doğrusal olmayan yapıdaki verilerde dahi kararlı sonuçlar üretmesi, kalite mühendisliği alanındaki uygulamalar için onu ideal bir yöntem haline getirir [61][62].

5.2.3. Naive bayes (naif bayes) sınıflandırma algoritması

Naive Bayes algoritması, denetimli (supervised) öğrenme kapsamında yer alan, temelini Bayes Teoremi'ne dayandıran olasılık temelli bir sınıflandırma yöntemidir. “Naive” (Türkçede “naif” veya “saf” olarak da çevrilir) ifadesi, modelin her bir özelliğin birbirinden tamamen bağımsız olduğunu varsaymasından gelir. Bu varsayım çoğu zaman gerçek dünya verileriyle örtüşmese de, uygulamalarda şaşırtıcı derecede başarılı sonuçlar vermektedir [63][64].

5.2.3.1. Bayes teoremi temelli sınıflandırma yaklaşımı

Naive Bayes algoritması, bir verinin ait olabileceği sınıfı, o verinin özelliklerine dayalı olarak en yüksek olasılık değerine göre tahmin eder. Bu amaçla Bayes Teoremi kullanılır:

$$P(C|X)=\frac{P(X|C) \cdot P(C)}{P(X)}$$

Buradaki temel amaç, gözlem XX verildiğinde, hangi sınıf CC'nin daha olası olduğunu belirlemektir. $P(C|X)$ değeri, sınıfa ait koşullu olasılığı ifade eder ve bu değer maksimum olan sınıf, tahmin edilen sınıf olarak belirlenir. Özelliklerin bağımsız olduğu varsayımı sayesinde:

$$P(X|C)=P(x_1|C) \cdot P(x_2|C) \cdot \dots \cdot P(x_n|C)$$

Bu formül, algoritmanın hesaplama verimliliğini önemli ölçüde artırır [64][65].

5.2.3.2. Naive bayes türleri ve kullanım alanlarına uygunluğu

Naive Bayes, veri tipine göre özelleştirilmiş üç temel türde uygulanmaktadır:

- Gaussian Naive Bayes: Sürekli özelliklere sahip verilerde kullanılır. Özelliklerin normal (Gaussian) dağıldığı varsayılır. Özellikle ölçüm verilerinin sınıflandırılmasında uygundur.

- Multinomial Naive Bayes: Kelime sayımı veya sıklığı gibi ayrık (discrete) değerli verilerle çalışır. Doğal dil işleme, belge sınıflandırma ve haber kategorilendirme gibi uygulamalarda sıkça tercih edilir.
- Bernoulli Naive Bayes: Özelliklerin var/yok (1/0) olarak temsil edildiği ikili veri yapılarında etkilidir. Örneğin, bir e-posta içinde belirli bir kelimenin geçip geçmemesi gibi durumlarda uygundur [65][66].

5.2.3.3. Güçlü yönleri ve sınırlamaları

Naive Bayes algoritması, sadeliği ve verimliliği nedeniyle birçok uygulamada tercih edilmektedir. Avantajları şunlardır:

- Ölçeklenebilirlik: Çok büyük veri kümelerinde dahi hızlı sonuçlar üretebilir.
- Düşük hesaplama maliyeti: Özellikler bağımsız varsayıldığı için karmaşık hesaplamalara ihtiyaç duymaz.
- Az sayıda eğitim verisiyle bile çalışabilir: Eğitim verisi yetersiz olan uygulamalarda anlamlı sınıflamalar yapılabilir.
- Gürültüye karşı toleranslıdır: Özellikle metin gibi yüksek boyutlu verilerde öne çıkar.
- Eksik veri ile baş edebilir: Eksik özellik bilgileri olsa dahi karar verilebilir [66][67].

Bununla birlikte, temel varsayım olan özellik bağımsızlığı gerçekte çoğu zaman sağlanmaz. Özellikle korelasyonun yüksek olduğu durumlarda modelin başarımı düşebilir. Ayrıca sürekli verilerde dağılım varsayımının (örneğin normal dağılım) yanlış yapılması sonuçları olumsuz etkileyebilir [67].

5.2.3.4. Endüstriyel ve akademik uygulamalar

Naive Bayes sınıflandırıcısı aşağıdaki alanlarda başarıyla uygulanmaktadır:

- Sağlık sektörü: Hastalık teşhisleri, genetik risk analizi, biyomedikal veri sınıflandırması.
- Finans sektörü: Müşteri segmentasyonu, kredi riski analizi, anomali ve dolandırıcılık tespiti.
- Metin madenciliği: Duygu analizi, spam filtreleme, belge türü sınıflandırma.
- Eğitim analitiği: Öğrenci başarı tahmini, sınav sonucu analizleri [67][68].

5.2.3.5. Kalite kontrol süreçlerinde naive bayes'in kullanımı

Naive Bayes algoritması, üretim ve kalite kontrol alanlarında da çeşitli sınıflandırma görevlerinde kullanılmaktadır. Örneğin, üretimden çıkan ürünlerin “uygun” veya “uygunsuz” olarak sınıflandırılması için üretim süreci verileri, ölçüm değerleri veya kalite karakteristikleri kullanılarak etkili bir model oluşturulabilir.

Veriler arasında doğrudan ilişki kurulamadığı veya sınırlı etiketli veri olduğu durumlarda, Naive Bayes algoritması hızlı ve açıklanabilir bir çözüm sunar. Ayrıca hata türlerinin sınıflandırılması veya hataya neden olan faktörlerin tahmin edilmesinde de kullanılabilir. Literatürde plastik enjeksiyon üretimi [68], otomotiv sektörü üretim hatları ve tekstil üretimi gibi birçok alanda uygulanmıştır.

Örneğin Wang ve Zhang (2007), üretim sistemi arızalarının sınıflandırılması için Naive Bayes algoritmasını uygulamış ve yüksek doğruluk elde edildiğini raporlamıştır [68]. Özellikle düşük maliyetli ve yorumlanabilir yapısı nedeniyle, üretim mühendisliği literatüründe kabul görmektedir.

5.2.3.6. Güncel araştırmalar ve gelişmeler

Günümüzde Naive Bayes algoritmasının temel versiyonları çeşitli şekilde geliştirilmiştir. Özellikle Bayesian Network yapıları, ağırlıklı Naive Bayes ve semi-naive Bayes gibi türev yöntemlerle bağımsızlık varsayımı gevşetilmiş ve daha karmaşık ilişkiler modellenenebilir hale getirilmiştir. Ayrıca, Naive Bayes ile ensemble yöntemlerin (örneğin bagging, boosting) birlikte kullanımı da algoritmanın başarı oranını önemli ölçüde artırmaktadır [68][69].

Ayrıca derin öğrenme ve klasik yöntemlerin hibritleştirildiği çalışmalarda, Naive Bayes öznitelik seçiminde ön filtreleme aracı olarak da kullanılmaktadır. Bu şekilde daha karmaşık modellerin daha verimli eğitilmesi sağlanmaktadır.

5.2.4. K-Nearest neighbors (KNN) algoritması

K-Nearest Neighbors (KNN), denetimli öğrenme (supervised learning) yöntemleri arasında yer alan ve hem sınıflandırma hem de regresyon problemlerinde kullanılabilen oldukça sezgisel bir algoritmadır. 1967 yılında Cover ve Hart tarafından geliştirilen bu yöntem, sınıflandırılacak bir örneğin, eğitim verisi içindeki en yakın k komşusunun sınıfına göre karar verilmesi prensibine dayanır [70].

5.2.4.1. Temel çalışma prensibi

KNN algoritmasının temel fikri, sınıflandırılacak bir gözlemin, eğitim kümesindeki öklidyen mesafe, Manhattan mesafesi ya da Minkowski mesafesi gibi bir ölçüte göre kendisine en yakın k adet komşu örneği bulması ve bu komşular arasında en sık görülen sınıf etiketinin tahmin olarak atanmasıdır. KNN algoritması aşağıdaki adımları izler:

1. Eğitim veri kümesi bir kenara alınır.
2. Test verisi (tahmin edilecek veri) alınır.
3. Test verisi ile tüm eğitim verileri arasındaki mesafeler hesaplanır.
4. En küçük mesafeye sahip k komşu seçilir.
5. Bu komşuların sınıfları göz önünde bulundurularak çoğunluk sınıfı seçilir.
6. Bu sınıf, test verisinin tahmini sınıfı olarak atanır [71].

Bu süreç, özellikle görselleştirilebilir ve yorumlanabilir olması açısından eğitim süreçlerinde de yaygın olarak tercih edilmektedir.

5.2.4.2. Parametreler ve etkileri

KNN algoritmasının performansı, büyük oranda seçilen k değeri ve mesafe ölçütüne bağlıdır. K çok küçük seçildiğinde (örneğin $k=1$), model aşırı öğrenme (overfitting) eğiliminde olabilir; bu durumda, tek bir veri noktasının hatası genelleştirilen tahmini bozabilir. Öte yandan, k çok büyük seçilirse model aşırı genelleme yaparak sınıflar arasındaki farkları göz ardı edebilir [72].

Kullanılan mesafe metriği de sınıflandırma başarısını doğrudan etkiler. Genellikle Öklidyen mesafe tercih edilmekle birlikte, özelliklerin ölçeklerinin farklı olması durumunda özellik standardizasyonu veya normalizasyonu uygulanması gerekir [61].

5.2.4.3. Avantajları ve dezavantajları

Avantajları:

- Model eğitimi gerekmez: KNN algoritması, eğitim aşamasında model kurmak yerine doğrudan veriye dayalı karar verir (lazy learning).
- Anlaması ve uygulaması kolaydır.
- Herhangi bir varsayıma ihtiyaç duymaz: Özelliklerin dağılımı, lineerlik gibi ön kabulleri yoktur.

Dezavantajları:

- Büyük veri kümelerinde yavaştır: Test aşamasında her seferinde tüm eğitim verisi ile mesafe hesaplamak gerekir.
- Bellek kullanımı yüksektir.
- Gürültüye karşı duyarlıdır.
- Boyut sayısı arttıkça doğruluğu düşebilir (curse of dimensionality) [73][74].

5.2.4.4. Uygulama alanları

KNN algoritması, birçok sektörde ve farklı veri türlerinde başarıyla uygulanmaktadır:

- Tıp ve sağlık: Hastalık teşhisleri, DNA sekansı analizi, biyobelirteç sınıflandırmaları.
- Finans: Müşteri davranış analizi, kredi başvuru değerlendirme.
- Pazarlama: Hedef kitle analizi, öneri sistemleri.
- Görüntü işleme: Görüntü tanıma, yazı karakteri tanıma.
- Endüstriyel kalite kontrol: Ölçüm verilerinin yorumlanması, hata türlerinin sınıflandırılması [74][75].

5.2.4.5. Kalite kontrol ve üretim sistemlerinde KNN

Üretim sistemlerinde, örneğin CNC makineleri, otomotiv parça üretimi veya CMM (Koordinat Ölçüm Cihazı) ölçüm verilerinde, KNN algoritması, üretilen parçaların tolerans aralığında olup olmadığını belirlemek için kullanılabilir. Ölçüm değerleri özellik vektörleri olarak modele verildiğinde, daha önce “uygun” veya “uygunsuz” olarak etiketlenmiş parçaların komşuluklarına göre yeni parçalar otomatik olarak sınıflandırılabilir.

Ayrıca üretim sürecinde oluşan hata türleri (örneğin yüzey pürüzlülüğü, ölçüm sapmaları) gibi sorunlar da KNN ile sınıflandırılarak hatanın nedenine dair analizler yapılabilir. Bu yaklaşım, üretim sürecinin sürekli iyileştirilmesi için karar destek sistemi olarak kullanılabilir [76].

Wang ve arkadaşlarının (2011) otomotiv sektöründe yaptığı bir çalışmada, KNN algoritmasının üretim sürecindeki anomali tespitinde yüksek doğruluk sağladığı

görülmüştür [76]. Benzer şekilde, sensör verileriyle arıza teşhisi yapan uygulamalarda da yaygın olarak kullanılmaktadır.

5.2.4.6. Güncel gelişmeler ve hibrit modeller

KNN, çoğu zaman diğer algoritmalarla birlikte kullanıldığında daha güçlü sonuçlar verir. Özellikle KNN + PCA (Principal Component Analysis) kombinasyonu, boyut indirgeme ile birlikte daha etkili sınıflandırma performansı sağlayabilir. Ayrıca KNN tabanlı ensemble modeller de literatürde sıklıkla kullanılmaktadır [77].

KNN, aynı zamanda derin öğrenme öncesi öznitelik seçimi veya ön işleme adımlarında da karar destek amacıyla kullanılmaktadır. Böylece algoritmanın sade yapısı daha karmaşık sistemlerin altyapısında yer alabilmektedir.



6. DENEYSEL SONUÇLAR VE TARTIŞMA

6.1. Özellik Seçimi ve Veri Hazırlama Süreci

Bu bölümde, makine öğrenmesi modellerinin eğitilmesinde kullanılan veri setinin yapısı, giriş değişkenleri ve modelleme öncesinde uygulanan veri hazırlama adımları açıklanmaktadır.

Her iki parça için CMM cihazı ile elde edilen ölçüm sonuçları, farklı koordinat eksenlerinde konumlanan çoklu ölçüm noktalarına dayanmakta ve bu veriler, sınıflandırma algoritmalarına giriş özelliği olarak tanımlanmaktadır. Parçaların geometrik yapısı, fonksiyonel bütünlüğü ve üretim toleranslarıyla doğrudan ilişkili olan bu özellikler, karar mekanizmasının temelini oluşturmaktadır.

Ölçülen Özellikler:

Parça 1 – Dişli Kutusu:

- Çap (Diameter)
- Mesafe (Distance)
- Z-X eksenleri arası mesafe (ZX Distance)

Parça 2 – Servo Somun Takozu:

- Çap (Diameter)
- Doğrusallık (Straightness)
- Z eksenleri mesafesi (Z Distance)
- Y eksenleri mesafesi (Y Distance)

Bu boyutsal özellikler, hem üretim kalitesini hem de montaj ve fonksiyonel performansı doğrudan etkilemektedir. Özellikle çap ve eksenler arası mesafeler, eş merkezlilik ve hizalama gibi kritik fonksiyonlar için belirleyici rol oynamaktadır.

Veri Hazırlama Adımları:

Makine öğrenmesi algoritmalarının doğru ve verimli çalışabilmesi için, ham ölçüm verileri aşağıdaki işlemlerden geçirilerek modellemeye uygun hale getirilmiştir:

- **Veri Temizleme:** Eksik, hatalı veya aykırı değer içeren gözlemler ayıklanmış ya da uygun durumlarda medyan değer ile tamamlanmıştır. Bu adım, modelin öğrenme kalitesini korumak açısından kritiktir.
- **Normalizasyon:** Tüm sayısal özellikler, ortalaması sıfır ve standart sapması bir olacak şekilde z-skoru yöntemi ile normalize edilmiştir. Bu işlem, farklı büyüklükteki özelliklerin modele eşit katkı sunmasını sağlamış ve algoritmaların ölçek bağımlılığını ortadan kaldırmıştır.
- **Etiketleme:** Her bir örnek, teknik resimlerde tanımlı tolerans aralıkları temel alınarak “Kabul (0)” ya da “Red (1)” olarak sınıflandırılmıştır. Bu sınıflar, modelin tahmin etmeye çalıştığı hedef değişken (output label) olarak belirlenmiştir.
- **Özellik Seçimi:** Başlangıç aşamasında tüm ölçüm değişkenleri modele dahil edilmiştir. Daha sonra, Random Forest algoritmasında uygulanan “özellik önemi (feature importance)” analizi ile sınıflandırma başarısına düşük katkı sağlayan özellikler elenmiştir. Bu işlem, hem modelin genellenebilirliğini artırmış hem de öğrenme süresini azaltarak daha verimli sonuçlar elde edilmesini sağlamıştır.

6.2. Parça Ölçüm Sonuçlarının Değerlendirilmesi

Bu çalışmada, üretim sürecinde kalite kontrol amacıyla çeşitli geometrik ölçüm parametreleri kullanılarak incelenen toplam 40 adet parçaya ait ölçüm verileri değerlendirilmiştir. Ölçümler, Mitutoyo Crysta-Apex V 9106 model Koordinat Ölçüm Makinesi (CMM) ile gerçekleştirilmiş olup, her bir parça için farklı konumlardaki dairelerin çapları (Daire 1–5), bu daireler arasındaki eksenel (Mesafe X) ve düşey (Mesafe Z) doğrultudaki mesafeler, eş merkezlilik değeri (Eş Merkezlilik), çaplar arası iki boyutlu mesafe (Mesafe 2X) ve genel mesafe (Mesafe Z) gibi özellikler ayrıntılı olarak analiz edilmiştir.

Ölçüm sonuçları, her bir parçanın üretim toleranslarına uygunluğunu değerlendirmek amacıyla belirli limitlerle karşılaştırılmış ve parçaların durumu "KABUL" ya da "RET" (red) şeklinde sınıflandırılmıştır. Parçaların büyük bir çoğunluğu (%82,5) belirtilen tolerans aralıkları içinde yer almakta ve "KABUL" edilmekte iken, geri kalan

azınlık (%17,5) üretim hatası, ölçüm dışı sapma veya şekil bozukluğu gibi nedenlerle "RET" edilmiştir.

Elde edilen bu sonuçlar, operatör yorumuna bağımlı olmadan, standartlara uygun otomatik karar verme sistemleri geliştirilmesi açısından önemli bir veri seti sunmaktadır. Bu ölçüm çıktıları, yapay zekâ temelli sınıflandırma algoritmalarının eğitilmesinde kullanılmak üzere hazırlanmış ve her bir parçanın geometrik doğruluğu sistematik biçimde değerlendirilmiştir.



Tablo 6.1. Parça Ölçüm Sonuçları

	Mesafe	Daire 1	Daire 2	Daire 3	Daire 4	Daire 5	Mesafe X	Mesafe Z	Eş Merkezlilik	Mesafe ZX	Mesafe Z	Durumu
1. Parça	97,991	125,026	120,055	95,067	110,027	133,056	169,045	45,288	0,011	153,41	215,605	KABUL
2. Parça	97,928	124,953	120,014	95,024	109,988	133,003	169,03	45,276	0,007	153,252	215,662	KABUL
3. Parça	97,969	124,995	120,024	95,029	110,002	133	169,029	45,283	0,014	153,328	215,598	KABUL
4. Parça	97,974	124,977	120,026	95,028	110,013	133	169,033	45,277	0,009	153,375	215,652	KABUL
5. Parça	98,058	124,959	120,01	95,014	109,992	132,996	169,026	45,289	0,008	153,347	215,649	KABUL
6. Parça	97,966	124,96	120,011	95,018	110,025	133,025	169,032	45,259	0,015	153,411	215,715	RET
7. Parça	97,991	124,964	119,69	95,023	110	133	169,024	45,298	0,007	153,38	215,685	KABUL
8. Parça	97,944	124,962	120,018	95,019	109,997	132,994	169,031	45,281	0,012	153,391	215,697	KABUL
9. Parça	97,994	124,964	120,017	95,02	110,02	132,998	169,029	45,278	0,009	153,391	215,693	KABUL
10. Parça	97,969	124,96	120,014	95,02	110,018	133	169,034	45,286	0,008	153,379	215,686	KABUL
11. Parça	97,97	124,945	120,005	95,014	109,995	132,988	169,028	45,285	0,007	153,375	215,709	KABUL
12. Parça	97,968	124,961	120,007	95,018	109,98	132,997	169,025	45,28	0,009	153,356	215,661	KABUL
13. Parça	97,99	124,951	120,009	95,015	110,015	132,99	169,021	45,283	0,011	153,368	215,69	KABUL
14. Parça	97,999	124,951	120,006	95,013	109,978	132,991	169,021	45,288	0,013	153,365	215,692	KABUL
15. Parça	97,969	124,96	120,014	95,02	110,0118	133	169,034	45,286	0,012	153,379	215,686	KABUL
16. Parça	98,058	124,953	120,003	95,014	109,995	132,996	169,025	45,286	0,008	153,348	215,649	KABUL
17. Parça	97,994	124,965	120,012	95,02	109,978	132,999	169,029	45,289	0,006	153,392	215,693	KABUL
18. Parça	97,967	124,96	120,003	95,029	109,988	132,99	169,025	45,284	0,003	153,356	215,66	KABUL
19. Parça	97,994	124,969	120,007	95,012	109,98	132,992	169,027	45,28	0,012	153,351	215,661	KABUL
20. Parça	97,968	124,961	120,003	95,018	109,93	132,995	169,02	45,289	0,009	153,356	215,663	KABUL

Tablo 6.1. (Devamı) Parça Ölçüm Sonuçları

21. Parça	97,97	124,977	120,018	95,023	110,013	133	169,035	45,287	0,009	153,37	215,652	KABUL
22. Parça	97,97	124,961	120,003	95,018	109,98	132,999	169,025	45,289	0,008	153,356	215,66	KABUL
23. Parça	97,969	124,995	120,024	95,029	110,002	133	169,039	45,283	0,012	153,328	215,598	KABUL
24. Parça	97,99	124,964	120,013	95,01	110,028	132,998	169,027	45,279	0,007	153,391	215,699	KABUL
25. Parça	97,938	124,953	120,015	95,02	109,991	133,02	169,034	45,287	0,001	153,252	215,662	KABUL
26. Parça	97,994	124,964	119,694	95,025	110,024	133,027	169,034	45,298	0,005	153,387	215,685	KABUL
27. Parça	97,991	124,94	120,007	95,015	109,986	132,992	169,027	45,28	0,012	153,357	215,668	KABUL
28. Parça	97,968	124,941	120,005	95,014	109,995	132,989	169,028	45,287	0,007	153,377	215,709	KABUL
29. Parça	97,994	124,94	120,008	95,012	109,93	132,992	169,029	45,279	0,008	153,351	215,658	KABUL
30. Parça	97,985	124,95	119,75	95,023	110,21	132,98	169,034	45,297	0,009	153,38	215,687	KABUL
31. Parça	97,963	124,966	120,001	95,08	110,125	133,025	169,032	45,23	0,018	153,452	215,715	RET
32. Parça	97,988	124,978	120,013	95,022	110,005	132,925	169,03	45,259	0,015	153,395	215,707	RET
33. Parça	97,983	124,976	120	95,025	110,01	132,95	169,04	45,29	0,014	153,392	215,698	RET
34. Parça	97,992	124,96	120,015	95,022	110,3	132,986	169,045	45,282	0,018	153,34	215,75	RET
35. Parça	97,961	124,95	120,025	95,068	109,99	132,98	169,049	45,232	0,028	153,5	215,85	RET
36. Parça	97,99	124,98	120,006	95,01	110,03	132,9	169,035	45,264	0,015	153,289	215,596	RET
37. Parça	97,93	124,99	120,08	95,025	110,027	132,985	169,029	45,27	0,05	153,364	215,7	RET
38. Parça	97,98	124,95	120,055	95,06	110,018	132,989	169,006	45,29	0,17	153,45	215,78	RET
39. Parça	98,56	124,93	119,96	95,054	109,94	132,99	169,035	45,281	0,11	153,385	215,89	RET
40. Parça	98,32	124,91	119,98	95,036	110,25	133,08	169,045	45,24	0,09	153,333	215,6	RET

Yapılan ölçümler sonucunda toplam 40 adet parçaya ait geometrik veri analiz edilmiştir. Bu parçalarda dairesel elemanların çapları (Daire 1–5), merkezler arası mesafeler (Mesafe X, Mesafe Z), eş merkezlik ve diğer referans noktalar arasındaki uzaklıklar (Mesafe 2X, Mesafe Z) detaylı biçimde değerlendirilmiştir. Elde edilen veriler, her bir parçanın tasarım toleransları ile karşılaştırılarak uygunluk durumları “KABUL” veya “RET” olarak sınıflandırılmıştır.

6.2.1. Genel durum dağılımı

- **Kabul edilen parça sayısı:** 33 adet (%82,5)
- **Reddedilen parça sayısı:** 7 adet (%17,5)

6.2.2. Reddedilen parçaların ortak özellikleri

Reddedilen parçaların büyük çoğunluğunda aşağıdaki ölçü parametrelerinde tolerans dışı sapmalar tespit edilmiştir:

- **Eş Merkezlik Değeri (Eş Merkezlik):** Bazı parçalarda bu değer 0,05 mm üzerinde ölçülmüştür (örn. 0,17 mm gibi), bu da merkez kaçıklığına işaret eder. Üretim kalitesinde ciddi sapmalara yol açabilecek bu değer, hassas montaj gerektiren uygulamalarda parça reddine neden olmuştur.
- **Mesafe Z ve Mesafe 2X:** Bazı parçalarda bu mesafelerde belirgin farklılıklar tespit edilmiş ve tasarım sınırlarının dışına çıkmıştır.
- **Çap Ölçümleri (Daire 1–5):** Reddedilen parçalarda daire çaplarında lokal sapmalar görülmüş olup, özellikle Daire 5 ölçüsünde küçük fakat tekrarlayan tutarsızlıklar fark edilmiştir.

Kabul Edilen Parçaların Özellikleri

Kabul edilen parçalarda ölçüm değerleri büyük oranda birbirine yakın olup, üretim sürecinin genel olarak istikrarlı ve tekrarlanabilir olduğu gözlemlenmiştir. Bu durum, ölçüm sisteminin doğruluğunu ve üretim sürecinin kontrol altında olduğunu göstermektedir. Eş merkezlik değerleri genellikle 0,01–0,03 mm aralığında seyretmiş, bu da kabul edilebilir sapma sınırları içinde değerlendirilmiştir.

Tablo 6.2. Parça Ölçüm Sonuçları

	Daire 1	Doğrusallık 1	Doğrusallık 2	Mesafe Z	Doğrusallık 3	Mesafe Y	Durumu
1. Parça	63,02	0	0	73,892	0	30,021	RET
2. Parça	63,016	0	0	73,892	0	30,021	RET
3. Parça	63,025	0	0	73,929	0	29,986	KABUL
4. Parça	63,02	0	0	73,985	0	29,789	KABUL
5. Parça	63,002	0	0	74,001	0	29,873	KABUL
6. Parça	63,02	0	0	74,002	0	29,868	KABUL
7. Parça	63,005	0	0	73,956	0	29,882	KABUL
8. Parça	63,02	0	0	74,026	0	29,937	RET
9. Parça	63,011	0	0	73,988	0	29,942	KABUL
10. Parça	63,025	0	0	73,992	0	29,959	KABUL
11. Parça	63,027	0	0	73,925	0	29,965	RET
12. Parça	63,02	0	0	74,021	0	29,975	KABUL
13. Parça	63,021	0	0	74,036	0	29,981	KABUL
14. Parça	63,006	0	0	74,013	0	29,964	KABUL
15. Parça	63,007	0	0	74,021	0	29,969	KABUL
16. Parça	63,01	0	0	74,019	0	29,965	KABUL
17. Parça	63,02	0	0	74,005	0	29,965	KABUL
18. Parça	63,018	0	0	74,013	0	29,956	KABUL
19. Parça	63,025	0	0	73,999	0	29,955	KABUL
20. Parça	63,012	0	0	73,997	0	29,951	KABUL
21. Parça	63,021	0	0	73,985	0	29,98	KABUL
22. Parça	63,024	0	0	74,022	0	29,975	KABUL
23. Parça	63,018	0	0	74,036	0	29,958	KABUL
24. Parça	63,006	0	0	74,032	0	29,967	KABUL
25. Parça	63,021	0	0	74,027	0	29,969	KABUL
26. Parça	63,015	0	0	74,035	0	29,98	KABUL
27. Parça	63,02	0	0	74,026	0	29,974	KABUL
28. Parça	63,004	0	0	74,022	0	29,98	KABUL
29. Parça	63,019	0	0	74,016	0	29,982	KABUL
30. Parça	63,008	0	0	74,001	0	29,987	KABUL
31. Parça	63,002	0	0	73,95	0	29,93	RET
32. Parça	63,018	0	0	73,92	0	29,96	RET
33. Parça	63,029	0	0	73,87	0	29,972	RET
34. Parça	63,015	0	0	73,89	0	29,956	RET
35. Parça	63,022	0	0	74,08	0	29,978	RET
36. Parça	63,027	0	0	73,958	0	29,932	RET
37. Parça	63,008	0	0	74,09	0	29,975	RET
38. Parça	63,017	0	0	73,964	0	29,956	RET
39. Parça	63,009	0	0	73,952	0	29,969	RET
40. Parça	63,026	0	0	73,863	0	29,975	RET

Bu çalışmada, üretim hattından rastgele seçilen 40 adet parçaya ait ikinci bir ölçüm seti analiz edilmiştir. Ölçümler kapsamında her bir parçaya ait Daire 1 çapı, üç farklı konumda alınan doğrusallık değerleri (Doğrusallık 1–3), düşey ekseninde ölçülen

Mesafe Z ve yatay doğrultudaki Mesafe Y değerleri değerlendirilmiş ve toleranslara uygunluklarına göre “KABUL” veya “RET” olarak sınıflandırılmıştır.

6.2.3. Genel durum dağılımı

- **Kabul edilen parça sayısı:** 30 adet (%75)
- **Reddedilen parça sayısı:** 10 adet (%25)

6.2.4. Gözlemler ve yorumlar

1.Doğrusallık Değerleri:

Ölçüm sonuçlarında **Doğrusallık 1, 2 ve 3** parametreleri tüm parçalarda sıfır (0) olarak ölçülmüştür. Bu durum, kullanılan ölçüm yönteminin ilgili doğrultularda çok yüksek hassasiyete sahip olduğunu veya ölçüm şartlarında bu parametrede bir varyasyon olmadığını göstermektedir. Ölçüm cihazı tarafından bu eksenlerde anlamlı bir sapma algılanmamıştır.

2.Daire 1 Çapı:

Daire 1 ölçüleri genellikle **63,00–63,03 mm** aralığında seyretmiş olup, kabul edilen parçalarda bu değer 63,002–63,027 mm aralığında yoğunlaşmaktadır. Bu da üretim sürecinin çap kararlılığı açısından oldukça kontrollü olduğunu göstermektedir.

Reddedilen bazı parçalarda Daire 1 ölçüleri diğerlerine benzer olmasına rağmen RET kararı verilmiştir. Bu da kararın çap ölçüsünden ziyade farklı parametrelerden kaynaklandığını düşündürmektedir.

3.Mesafe Z ve Mesafe Y:

Mesafe Z değerleri 73,863 mm ile 74,09 mm arasında değişmektedir. Kabul edilen parçaların büyük kısmı **73,95–74,03 mm** aralığında toplanmıştır.

Özellikle **Mesafe Z < 73,90 mm** olan ya da **Mesafe Z > 74,08 mm** ölçülen parçaların (örneğin 33., 35., 37. Parçalar) “RET” olarak sınıflandırıldığı görülmektedir. Bu durum, bu parametrede dar bir tolerans aralığı bulunduğunu göstermektedir.

Mesafe Y ölçüleri çoğunlukla **29,95 ± 0,03 mm** aralığında seyretmiştir. Tolerans dışı olan nadir parçalarda bu ölçünün özellikle düşük değerlere (örn. 29,789 mm – 4. Parça) gerilediği görülmektedir. Bu da üretim sırasında meydana gelen eksenel sapmalara işaret edebilir.

6.2.5. Reddedilen parçaların ortak özellikleri

Reddedilen parçalarda genellikle şu durumlar gözlemlenmiştir:

- **Mesafe Z ölçümünün** tasarım toleranslarının dışında kalması (örn. Parça 33, 40 gibi)
- **Mesafe Y'nin** 29,90 mm altına düşmesi (örn. Parça 4)
- Ölçüm değerleri tek başına aşırı sapma göstermese de küçük tolerans farklarının birikimli etkisiyle toplam kalite kriterlerinin dışında kalmaları

6.3. Model Eğitimi ve Doğrulama Yöntemleri

Bu çalışmada, parçaların boyutsal ölçüm verilerine dayalı olarak hatalı ve hatasız parçaların sınıflandırılabilmesi amacıyla çeşitli makine öğrenimi algoritmaları uygulanmıştır. Modelleme süreci Python programlama dili kullanılarak gerçekleştirilmiş olup, modelleme ve değerlendirme süreçlerinde scikit-learn kütüphanesi temel araç olarak kullanılmıştır.

6.3.1. Veri bölünmesi

Veri seti, modellerin hem öğrenme hem de genelleme yeteneklerini değerlendirebilmek amacıyla %80 eğitim, %20 test oranında rastgele bölünmüştür. Bu yaklaşım, modelin daha önce görmediği veriler üzerinde nasıl performans gösterdiğini ölçmek için önemlidir.

6.3.2. Çapraz doğrulama (cross-validation)

Model başarımının daha güvenilir ve tutarlı bir şekilde ölçülebilmesi için eğitim verisi üzerinde 5 katlı çapraz doğrulama (5-fold cross-validation) uygulanmıştır. Bu yöntemde eğitim verisi beş eşit alt kümeye ayrılmış, her bir alt küme bir defa doğrulama seti olarak kullanılırken geri kalan dört küme modelin eğitimi için kullanılmıştır. Bu sayede, modelin farklı alt veri kümeleri üzerindeki performansı değerlendirilmiş ve aşırı öğrenme (overfitting) riski azaltılmıştır.

6.3.3. Hiperparametre optimizasyonu

Her bir makine öğrenimi algoritmasının performansını artırmak ve modele özgü en iyi yapılandırmayı elde edebilmek için hiperparametre ayarlamaları (hyperparameter

tuning) yapılmıştır. Bu kapsamda, algoritmalara özgü önemli parametreler farklı kombinasyonlarla test edilmiştir:

6.3.4. Random forest algoritması için

n_estimators: Ormanda bulunan karar ağacı sayısı farklı değerlerle test edilmiştir (örneğin 50, 100, 150).

max_depth: Ağaçların maksimum derinliği sınırlandırılarak hem karmaşıklık hem de öğrenme kapasitesi dengelenmiştir.

Diğer parametreler olarak min_samples_split ve bootstrap gibi ayarlar da göz önünde bulundurulmuştur.

6.3.5. Support vector machine (SVM) için

C: Hata toleransını kontrol eden bu parametre farklı değerlerde denenmiştir.

kernel: Modelin doğrusal olmayan sınırlarda da öğrenme yapabilmesi için hem doğrusal (linear) hem de RBF (Radial Basis Function) çekirdek fonksiyonları kullanılmıştır.

gamma: RBF çekirdeği ile çalışan modellerde karar sınırlarının esnekliğini belirlemek için optimize edilmiştir.

6.3.6. K-Nearest neighbors (KNN) için

n_neighbors: En yakın komşu sayısı (k) çeşitli değerler (örneğin 3, 5, 7, 9) ile test edilerek en iyi sonuçlar veren yapı seçilmiştir.

metric: Mesafe hesaplamasında kullanılan ölçüt (örneğin Euclidean, Manhattan) olarak farklı seçenekler değerlendirilmiştir.

6.3.7. Naive bayes

Bu algoritma, dağılımların belirli istatistiksel varsayımlarına dayandığı için, Gaussian Naive Bayes modeli kullanılarak varsayılan parametrelerle uygulanmıştır.

Özellikle düşük boyutlu ve sürekli değerlerden oluşan veri setlerinde bu modelin genellikle etkili sonuçlar verdiği gözlemlenmiştir.

6.4. Eğitim Sürecine Genel Bakış

Bu yapılandırmalar sayesinde her algoritmanın veri setine özgü öğrenme kapasitesi değerlendirilmiş ve parça ölçüm verilerinden anlamlı sınıflandırma kararları üretilip üretilmeyeceği test edilmiştir. Elde edilen modellerin doğruluk, hassasiyet, özgüllük gibi metrikleri üzerinden performans analizleri yapılmış ve hangi algoritmanın daha genellenebilir sonuçlar ürettiği karşılaştırmalı olarak ortaya konmuştur.

Bu süreç, geleneksel kalite kontrol yöntemlerinde insan yorumuna bağlı karar verme süreçlerinin yerine, otomatik, tutarlı ve tekrarlanabilir bir karar mekanizmasının geliştirilmesi açısından önemli bir temel oluşturmuştur.

6.5. Performans Ölçütleri

Model başarıları; doğruluk (accuracy), F1 skoru ve sınıflandırma dengesini gösteren **confusion matrix** gibi ölçütlerle değerlendirilmiştir.

6.5.1. Doğruluk (Accuracy)

Doğruluk, sınıflandırma modelinin toplam doğru tahmin sayısının, tüm tahmin sayısına oranı ile elde edilir. Yani modelin genel başarı oranını ifade eder.

$$\frac{TP + TN}{TP + FP + TN + FN}$$

Şekil 6.1. Doğruluk Formülü

TP (True Positive): Gerçek sınıfı "KABUL" olan ve doğru tahmin edilen örnekler

TN (True Negative): Gerçek sınıfı "RET" olan ve doğru tahmin edilen örnekler

FP (False Positive): Gerçek sınıfı "RET" olup yanlışlıkla "KABUL" olarak tahmin edilenler

FN (False Negative): Gerçek sınıfı "KABUL" olup yanlışlıkla "RET" olarak tahmin edilenler

Doğruluk, genel başarıyı gösterse de, özellikle sınıflar dengesiz olduğunda (örneğin "KABUL" çok, "RET" az ise) yanıltıcı olabilir.

F1 Skoru

F1 skoru, precision (kesinlik) ve recall (duyarlılık) metriklerinin harmonik ortalamasıdır. Modelin sadece doğru tahmin yapma oranını değil, aynı zamanda yanlış sınıflandırma riskini minimize etme başarısını da yansıtır. Bu nedenle F1 skoru, özellikle sınıflar arası dengesizlik içeren veri setlerinde doğruluktan çok daha güvenilir bir değerlendirme ölçüsüdür.

$$F_1 = 2 * \frac{precision * recall}{precision + recall}$$


Şekil 6.2. F1 Skoru Formülü

6.6. Random Forest İçin

PARÇA1:

Ortalama Doğruluk: 0.975

Ortalama F1 Skoru: 0.9709090909090909



Şekil 6.3. Modelin Karmaşıklık Matrisi Random Forest (Parça 1)

Şekilde sunulan karmaşıklık matrisi, geliştirilen makine öğrenimi modelinin test verisi üzerindeki sınıflandırma performansını göstermektedir. Matrisin satırlarında gerçek

sınıf etiketleri, sütunlarında ise model tarafından tahmin edilen sınıf etiketleri yer almaktadır. Bu bağlamda:

- Matrisin sol üst köşesindeki **29** değeri, modelin "KABUL" sınıfına ait olan 29 örneği doğru şekilde tahmin ettiğini (True Negative – TN),
- Sağ alt köşedeki **10** değeri ise modelin "RET" sınıfına ait olan 10 örneği doğru biçimde sınıflandırdığını (True Positive – TP),
- Sağ üst köşedeki **0** değeri modelin herhangi bir "KABUL" parçasını hatalı şekilde "RET" olarak sınıflandırmadığını (False Positive – FP),
- Sol alt köşedeki **1** değeri ise bir adet "RET" sınıfındaki parçanın yanlışlıkla "KABUL" olarak tahmin edildiğini (False Negative – FN) ifade etmektedir.

Modelin genel doğruluk oranının %97,5 gibi yüksek bir seviyede olması, öğrenme sürecinin başarılı gerçekleştiğini ve test verisi üzerinde anlamlı genelleme yapabildiğini göstermektedir. Özellikle "KABUL" sınıfına ait hiçbir parçanın yanlışlıkla "RET" olarak sınıflandırılmaması üretim süreci açısından kritik öneme sahiptir; çünkü bu durum kabul edilebilir parçaların gereksiz yere elenmediğini ifade etmektedir.


Buna karşılık yalnızca bir adet "RET" sınıfındaki parçanın "KABUL" olarak tahmin edilmesi, modelin kusurlu parçaları büyük ölçüde doğru tanımlayabildiğini, ancak sınırlı sayıda hatalı sınıflandırma olasılığının hâlâ mevcut olduğunu göstermektedir. Bu tür hata, üretim hattında kusurlu parçaların gözden kaçma riskine işaret ettiği için dikkatle izlenmesi gereken bir durumdur. Yine de modelin duyarlılık ve F1-skoru gibi göstergeleri, bu riski oldukça düşük düzeyde tuttuğunu ortaya koymaktadır.

Sonuç olarak, geliştirilen sınıflandırma modeli, ölçüm verilerine dayalı olarak parçaların kabul/red durumunu yüksek doğrulukla öngörebilmekte ve operatör bağımlılığını azaltarak kalite kontrol süreçlerine katkı sağlayabilecek potansiyele sahiptir.

PARÇA2:

Ortalama Doğruluk (Accuracy): 0.825

Ortalama F1 Skoru (Macro): 0.7845



Şekil 6.4. Modelin Karmaşıklık Matrisi Random Forest (Parça 2)

Şekilde, ikinci parça olan Servo somun takozu için oluşturulan makine öğrenmesi modeline ait konfüzyon matrisi yer almaktadır. Bu matris, modelin test verileri üzerindeki tahmin performansını detaylı bir şekilde ortaya koymaktadır. Matrisin yatay eksenini modelin tahmin ettiği sınıfları, dikey eksenini ise gerçek sınıfları göstermektedir.

Model, toplamda 35 örnek üzerinden test edilmiştir. Gerçek sınıfı “KABUL” olan 26 parçadan 24’ü doğru şekilde “KABUL” olarak tahmin edilmiş, 2 parça ise hatalı olarak “RET” sınıfına atanmıştır. Diğer yandan, gerçek sınıfı “RET” olan 14 parçadan 9’u doğru şekilde sınıflandırılmış, ancak 5 adet “RET” sınıfındaki parça yanlışlıkla “KABUL” olarak tahmin edilmiştir.


Bu durum, modelin kabul sınıfındaki parçaları daha isabetli sınıflandırdığı, ancak red sınıfındaki bazı parçaları yanlış şekilde kabul ettiği anlamına gelmektedir. Red sınıfındaki parçaların hatalı olarak kabul edilmesi, kalite kontrol açısından kritik bir hata türü olduğundan bu tür yanlış sınıflandırmaların minimize edilmesi büyük önem taşımaktadır. Bu nedenle modelin *False Negative* (yanlış negatif) hata oranının düşürülmesi için sınıf dengesizlikleri göz önünde bulundurularak yeniden ağırlıklandırma veya örnekleme yöntemlerinin değerlendirilmesi önerilmektedir.

6.7. Support Vector Machine (SVM)

PARÇA1:

SVM - Ortalama Doğruluk (Accuracy): 0.825

SVM - Ortalama F1 Skoru (Macro): 0.799



Şekil 6.5. Modelin Karmaşıklık Matrisi SVM (Parça 1)

Şekilde, dişli kutusu parçası için Support Vector Machine (SVM) algoritmasıyla oluşturulan sınıflandırma modeline ait konfüzyon matrisi gösterilmektedir. Söz konusu matris, modelin test verileri üzerindeki sınıflandırma başarımını göstermesi açısından önemli bir değerlendirme aracıdır.

Gerçek sınıfı “KABUL” olan toplam 29 parçanın 25’i doğru bir şekilde “KABUL” olarak tahmin edilmiş, 4 parça ise hatalı olarak “RET” sınıfına atanmıştır. Bununla birlikte, gerçek sınıfı “RET” olan 11 parçanın 8’i doğru tahmin edilmiş, 3 parça ise yanlışlıkla “KABUL” olarak sınıflandırılmıştır.

SVM modeli genel olarak yüksek doğruluk göstermekte olup, özellikle “KABUL” sınıfı için yüksek bir doğru sınıflandırma oranı elde edilmiştir. Ancak kalite kontrol açısından daha kritik olan “RET” sınıfında 3 parçanın hatalı biçimde kabul edilmesi, potansiyel olarak kusurlu parçaların üretim sürecine dahil olması anlamına geldiğinden önem arz etmektedir. Bu tür yanlış sınıflandırmalar, üretim kalitesini ve müşteri memnuniyetini olumsuz etkileyebileceğinden, model performansı değerlendirilirken özellikle False Negative oranlarının dikkate alınması gerekmektedir.


Sonuç olarak, SVM algoritması bu parça için dengeli bir sınıflandırma performansı sergilemiş olmakla birlikte, hata türlerinin niteliği göz önüne alınarak modelin daha

fazla optimize edilmesi, örneğin ceza parametresinin (C) ayarlanması veya sınıf ağırlıklandırması yapılması önerilebilir.

PARÇA2:

SVM - Ortalama Doğruluk (Accuracy): 0.775

SVM - Ortalama F1 Skoru (Macro): 0.7337



Şekil 6.6. Modelin Karmaşıklık Matrisi SVM (Parça 2)

Şekilde, Servo somun takozu parçasına ait veriler kullanılarak oluşturulan Support Vector Machine (SVM) sınıflandırma modelinin performansını gösteren karışıklık matrisi sunulmaktadır. Bu matris, modelin test verileri üzerindeki sınıflandırma başarımını sayısal olarak değerlendirmek ve sınıflandırma hatalarının doğasını incelemek açısından önemli bir araçtır.

Gerçek sınıfı “KABUL” olan toplam 29 parçanın 25’i model tarafından doğru bir şekilde “KABUL” olarak sınıflandırılmış; 4 parça ise yanlış biçimde “RET” sınıfına atanmıştır. Öte yandan, gerçek sınıfı “RET” olan 11 parçanın 8’i doğru şekilde “RET” olarak tahmin edilmiş; 3 parça ise hatalı şekilde “KABUL” olarak değerlendirilmiştir.

Modelin genel doğruluk oranı yüksek olmakla birlikte, özellikle “KABUL” sınıfında doğru sınıflandırma oranı oldukça başarılıdır. Ancak kalite kontrol süreçleri açısından daha kritik bir öneme sahip olan “RET” sınıfında meydana gelen yanlış sınıflandırmalar (False Negative), üretim güvenliği açısından risk oluşturmaktadır. Gerçek sınıfı “RET” olan parçaların “KABUL” olarak değerlendirilmesi, kusurlu

parçaların üretim hattına dâhil edilmesi anlamına geldiğinden, bu tür hatalar hem ürün kalitesini düşürebilir hem de müşteri memnuniyetini olumsuz etkileyebilir.


Bu nedenle, model performansı değerlendirilirken yalnızca genel doğruluk oranı değil, aynı zamanda hata türlerinin niteliği ve dağılımı da dikkate alınmalıdır. Söz konusu SVM modeli dengeli bir sınıflandırma performansı sergilemiş olmakla birlikte, özellikle “RET” sınıfındaki yanlış sınıflandırmaların azaltılması adına modelin daha fazla optimize edilmesi önerilmektedir. Bu kapsamda, modelin ceza parametresi (C) üzerinde ayarlamalar yapılması, sınıf ağırlıklarının yeniden düzenlenmesi (class weighting) veya farklı çekirdek (kernel) fonksiyonlarının denenmesi gibi stratejiler uygulanabilir.

6.8. Naive Bayes

PARÇA1:

Naive Bayes - Ortalama Doğruluk (Accuracy): 0.9

Naive Bayes - Ortalama F1 Skoru (Macro): 0.8984



Şekil 6.7. Naive Bayes Algoritmasına Ait Karışıklık Matrisi (Parça 1)

Şekilde, dişli kutusu parçasına ilişkin veriler kullanılarak oluşturulan Naive Bayes sınıflandırma modelinin test verisi üzerindeki performansı gösterilmektedir. Modelin başarı durumu, ilgili karışıklık matrisi ve genel metrikler üzerinden değerlendirilmiştir.

Model, gerçek sınıfı “KABUL” olan 29 parçanın 25’ini doğru şekilde “KABUL” olarak sınıflandırmış; yalnızca 4 parça hatalı şekilde “RET” sınıfına atanmıştır. “RET” sınıfına ait 11 parçanın ise tamamı doğru şekilde tahmin edilmiştir ve hiçbir yanlış pozitif (False Positive) veya yanlış negatif (False Negative) hataya rastlanmamıştır.

Ayrıca, modelin her iki sınıf için eşit ağırlıklı başarı düzeyini yansıtan makro ortalama F1 skoru (Macro F1 Score) değeri yaklaşık 0.8984 olarak hesaplanmıştır. Bu değer, hem "KABUL" hem de "RET" sınıfları için modelin oldukça dengeli bir sınıflandırma performansı sunduğunu göstermektedir.

Özellikle dikkat çekici olan, "RET" sınıfına ait örneklerin tümünün doğru bir şekilde sınıflandırılmış olmasıdır. Bu, kalite kontrol açısından kritik olan hatalı parçaların üretim sürecine yanlışlıkla dahil edilme riskini ortadan kaldırdığı için modelin yüksek güvenilirliğe sahip olduğunu göstermektedir.


Bununla birlikte, “KABUL” sınıfında meydana gelen 4 yanlış sınıflandırma, uygun olan bazı parçaların gereksiz yere reddedilmesine neden olabilecektir. Bu durum, üretim verimliliği açısından olumsuz bir etkiye bulunabilir; ancak bu tür hataların, ürün kalitesini riske atan yanlış kabullerden daha az kritik olduğu söylenebilir.

Sonuç olarak, Naive Bayes algoritması, bu veri seti üzerinde oldukça başarılı ve dengeli bir sınıflandırma performansı göstermiştir. Özellikle “RET” sınıfı için elde edilen %100 doğru sınıflandırma oranı, bu modelin hata ayıklama ve kalite kontrol sistemlerinde güvenle kullanılabileceğini ortaya koymaktadır. Ancak “KABUL” sınıfında yanlış ret oranının azaltılması adına, modelin parametrik iyileştirmelerle daha da optimize edilmesi değerlendirilebilir.

PARÇA2:

Naive Bayes - Ortalama Doğruluk (Accuracy): 0.85

Naive Bayes - Ortalama F1 Skoru (Macro): 0.8402



Şekil 6.8. Naive Bayes Algoritmasına Ait Karışıklık Matrisi (Parça 2)

Şekilde, Somun takozu parçası için oluşturulan Naive Bayes sınıflandırma modelinin performansına ilişkin karışıklık matrisi sunulmaktadır. Bu matris, modelin test verileri üzerindeki sınıflandırma başarımını değerlendirmek açısından önemli bir araçtır.

Gerçek sınıfı “KABUL” olan toplam 26 parçanın 22’si doğru şekilde "KABUL" olarak sınıflandırılmış, 4 tanesi hatalı biçimde "RET" olarak tahmin edilmiştir. Gerçek sınıfı “RET” olan 14 parçanın ise 12’si doğru şekilde "RET" olarak sınıflandırılmış, 2’si yanlışlıkla "KABUL" olarak değerlendirilmiştir.

Naive Bayes algoritması, genel olarak iyi bir sınıflandırma performansı göstermiştir. Özellikle hem “KABUL” hem de “RET” sınıflarında yüksek oranda doğru tahmin yapılmıştır. Ancak, "KABUL" sınıfında yaşanan 4 adet yanlış red (False Positive), uygun olan parçaların gereksiz yere üretim dışı bırakılmasına neden olabilir. Bununla birlikte, kalite kontrol açısından daha kritik olan "RET" sınıfına ait 2 adet yanlış kabul (False Negative), hatalı parçaların üretim sürecine dahil olabileceğini göstermekte ve bu durum ciddi kalite problemlerine yol açabilmektedir.

Bu bağlamda modelin hataları incelendiğinde:

- "KABUL" sınıfındaki başarı oranı %84.6 (22/26) olarak hesaplanabilir.
- "RET" sınıfındaki başarı oranı %85.7 (12/14) seviyesindedir.

Her iki sınıfta da benzer seviyede başarı elde edilmiş olsa da, kalite güvenliği açısından “RET” sınıfındaki yanlış kabuller kritik görülmektedir. Bu nedenle, modelin genel

doğruluğu yüksek olsa bile, False Negative (yanlış kabul) hatalarının azaltılması için ilave iyileştirmeler gerekebilir. Bu kapsamda:


- Modelin parametrelerinin yeniden optimize edilmesi,
- Daha fazla örnek içeren ve dengeli dağılıma sahip veri setlerinin kullanılması,
- Alternatif algoritmalarla (ör. Random Forest, SVM, XGBoost) karşılaştırmalı değerlendirmeler yapılması önerilebilir.

6.9. K-Nearest Neighbors (KNN)

PARÇA1:

KNN - Ortalama Doğruluk (Accuracy): 0.825

KNN - Ortalama F1 Skoru (Macro): 0.6637



Şekil 6.9. K-En Yakın Komşu (KNN) Algoritmasına Ait Karışıklık Matrisi (Parça 1)

Şekilde, dişli kutusu parçası için geliştirilen K-En Yakın Komşu (KNN) algoritmasına ait sınıflandırma modelinin test verileri üzerindeki performansını gösteren karışıklık matrisi yer almaktadır. Bu matris, modelin hangi sınıflarda doğru ve yanlış tahminlerde bulunduğunu görselleştirmek ve model başarımını değerlendirmek amacıyla kullanılmıştır.

Gerçek sınıfı “KABUL” olan 29 parçanın tamamı doğru şekilde “KABUL” olarak tahmin edilmiştir; bu da bu sınıf için %100'lük bir başarı anlamına gelmektedir. Öte


yandan, gerçek sınıfı “RET” olan 11 parçanın yalnızca 4’ü doğru sınıflandırılmış, 7 parça ise yanlış şekilde “KABUL” olarak değerlendirilmiştir.

KNN algoritması, “KABUL” sınıfında oldukça yüksek doğruluk sağlamış (%100), ancak “RET” sınıfında ciddi oranda hata yapmıştır. Özellikle kalite kontrol açısından kritik öneme sahip olan “RET” sınıfındaki 7 adet yanlış kabul (False Negative), kusurlu parçaların üretim sürecine dahil olmasına yol açabileceği için modelin güvenilirliğini sorgulatmaktadır.

PARÇA2:

KNN - Ortalama Doğruluk (Accuracy): 0.8

KNN - Ortalama F1 Skoru (Macro): 0.7244



Şekil 6.10. KNN Algoritmasına Ait Karışıklık Matrisi – (Parça 2)

Şekilde, Gear Box parçası için geliştirilen K-En Yakın Komşu (KNN) algoritmasına ait sınıflandırma modelinin test verileri üzerindeki performansı yer almaktadır. Karışıklık matrisi, modelin tahmin başarısını sınıf bazında değerlendirme imkânı sunmaktadır.

Modelin çıktıları şu şekildedir:

- Gerçek sınıfı “KABUL” olan 26 parçanın 25’i doğru tahmin edilmiş, yalnızca 1 tanesi yanlışlıkla “RET” olarak sınıflandırılmıştır.
- Gerçek sınıfı “RET” olan 14 parçanın yalnızca 7’si doğru sınıflandırılmış, 7 parça ise hatalı biçimde “KABUL” olarak tahmin edilmiştir.

KNN modeli, “KABUL” sınıfında oldukça yüksek bir başarı göstermiş (%96.2); ancak “RET” sınıfında ciddi hata oranına sahip olmuştur. Özellikle 7 adet yanlış kabul (False Negative), kalite kontrol açısından oldukça kritik bir zayıflığa işaret etmektedir. Çünkü bu durum, hatalı parçaların sistem tarafından "kabul" edilerek üretim sürecine dâhil edilmesine neden olabilir.

Parça 1 Sonuçları:

Tablo 6.3. Algoritmalarla göre Accuracy değeri ve F1 skorları (Parça 1)

Algoritma	Accuracy	F1 Skoru
Random Forest	0,975	0,971
SVM	0,825	0,799
Naive Bayes	0,9	0,898
KNN	0,825	0,664

Tabloya göre, test verileri üzerinde en yüksek başarıyı gösteren algoritma Random Forest olmuştur. %97,5 doğruluk ve 0,971 F1 skoru ile model, hem genel sınıflandırma başarısında hem de sınıflar arası dengeyi sağlamada en etkili yöntem olarak öne çıkmaktadır.

Naive Bayes algoritması da %90 doğruluk ve 0,898 F1 skoru ile oldukça başarılı bir sonuç vermiştir. Basit yapısı ve hızlı çalışması sayesinde özellikle hızlı karar alınması gereken kalite kontrol sistemleri için uygun bir alternatif olabilir.

SVM (Support Vector Machine) algoritması %82,5 doğruluk ve 0,799 F1 skoru ile orta düzeyde bir performans göstermiştir. Özellikle “KABUL” sınıfında yüksek başarı göstermesine rağmen, “RET” sınıfında bazı yanlış sınıflandırmalar üretim kalitesini riske atabilir.

KNN (K-En Yakın Komşu) algoritması ise %82,5 doğruluk oranına sahip olmasına rağmen, F1 skorunun 0,664 olması bu algoritmanın sınıflar arasında dengesiz tahminler yaptığına işaret etmektedir. “RET” sınıfında yapılan hatalar nedeniyle modelin güvenilirliği düşmektedir.

Tablo 6.4. Algoritmalarla göre Accuracy değeri ve F1 skorları (Parça 2)

Algoritma	Accuracy	F1 Skoru
Random Forest	0.825	0.785
SVM	0.775	0.734
Naive Bayes	0.850	0.840
KNN	0.800	0.724

Parça 2 üzerinde uygulanan dört farklı makine öğrenmesi algoritması karşılaştırıldığında, en başarılı modelin Naive Bayes olduğu görülmektedir. %85 doğruluk ve 0.840 F1 skoru ile hem genel sınıflandırma başarısı yüksek hem de sınıflar arası denge oldukça tatmin edicidir. Bu, modelin hem "KABUL" hem de "RET" sınıflarını başarıyla ayırt ettiğini göstermektedir.

Random Forest, %82,5 doğruluk ve 0.785 F1 skoru ile ikinci sırada yer almakta, ancak özellikle F1 skorunun Naive Bayes'e göre daha düşük olması modelin bazı sınıflarda dengesiz tahminler yapabildiğine işaret etmektedir. Bu durum özellikle daha az örneğe sahip olan sınıflarda hatalı sınıflandırmalara yol açabilir.

SVM, %77,5 doğruluk ve 0.734 F1 skoru ile daha düşük performans sergilemiştir. Özellikle "RET" sınıfındaki hatalar, üretim sürecinde kusurlu parçaların kabul edilmesine neden olabileceğinden dikkatle değerlendirilmelidir.

KNN algoritması ise %80 doğruluk oranına sahip olmasına rağmen 0.724 F1 skoru ile en düşük sınıf dengesi performansını göstermiştir. Bu da modelin özellikle azınlık sınıfı doğru tahmin etme konusunda yetersiz kaldığını ortaya koymaktadır.

Elde edilen sonuçlara göre Random Forest algoritması özellikle Parça 1'de çok yüksek başarı göstermiştir. Parça 2'de ise Naive Bayes algoritması F1 skorunda en yüksek değere ulaşmıştır. KNN algoritması her iki parçada da en düşük F1 skorunu almıştır. Bu, KNN'nin özellikle ölçümler arası mesafe duyarlılığı nedeniyle sınıflandırmada zorlandığını göstermektedir.

Bu sonuçlar doğrultusunda, doğruluk (accuracy) ve F1 skoru arasındaki farkların anlaşılması önem kazanmaktadır. Doğruluk, modelin yaptığı tüm tahminler içindeki doğru sınıflandırmaların oranını ifade ederken, sınıflar arasında büyük dengesizlikler olduğunda yanıltıcı olabilir. F1 skoru ise, modelin özellikle azınlıkta kalan sınıfı ne kadar isabetli tahmin ettiğini ölçmede daha hassastır. Bu bağlamda, yüksek doğruluk değeri modelin genel başarısını, F1 skoru ise iki sınıfa karşı adaletli yaklaşımını

yansıtmaktadır. Parça 1’de Random Forest, hem doğruluk hem F1 skoru açısından açık farkla en iyi sonuçları vermişken; Parça 2’de Naive Bayes’in F1 skorundaki üstünlüğü, bu parçanın yapısına daha uygun çalıştığını göstermektedir. KNN algoritması ise her iki parçada da düşük F1 skorlarıyla en zayıf performansı sergilemiştir. Bu durum, özellikle mesafeye duyarlı yapısının karmaşık geometriye sahip parçalarda güvenilirlik sorunlarına yol açtığını düşündürmektedir.

6.10. Sınırlamalar ve İyileştirme Yaklaşımları

Çalışma kapsamında elde edilen bulgulara rağmen bazı sınırlamalar ve geleceğe dönük iyileştirme önerileri bulunmaktadır:

- **Veri Seti Büyüklüğü:** Özellikle SVM ve derin öğrenme gibi algoritmalar daha büyük veri setlerine ihtiyaç duymaktadır. Veri hacminin artırılması başarı oranlarını olumlu etkileyebilir.
- **CMM Ölçüm Doğruluğu:** Ölçüm cihazının kalibrasyonu, çevresel faktörler ve operatör etkisi model performansını dolaylı olarak etkileyebilir.
- **Sınıf Dağılımı:** Kabul ve red sınıfları arasında ciddi dengesizlik varsa, bazı algoritmalar bu durumdan olumsuz etkilenebilir. SMOTE veya sınıf ağırlıklı öğrenme gibi yöntemlerle bu dengesizlik azaltılabilir.
- **Model Genellenabilirliği:** Eğitilen modellerin yeni parça türleri üzerinde denenmesi, genelleme yeteneklerinin test edilmesi açısından faydalı olacaktır.
- **Algoritma Genişletmesi:** Bu çalışmada klasik yöntemlere odaklanılmıştır. Derin öğrenme (örneğin CNN veya LSTM) gibi yöntemlerin denenmesi, özellikle yüksek sayıda ölçüm noktası içeren parçalar için daha isabetli kararlar verebilir.

6.11. Uygulama: Otomatik Parça Kabul-Ret Sistemi

6.11.1. Geliştirilen sistemin mimarisi

Geliştirilen sistem; üç ana bileşenden oluşmaktadır:

1. Veri Toplama Katmanı (CMM Ölçüm Cihazı): Parça üzerindeki kritik ölçüm noktalarını toplar ve dijital forma dönüştürür.

2. Veri İşleme ve Modelleme Katmanı: Alınan ölçüm verileri normalize edilerek makine öğrenmesi modeline aktarılır.

3. Karar ve Geribildirim Katmanı: Modelin çıktısına göre parça kabul veya red olarak sınıflandırılır. Karar bilgisi üretim hattındaki ERP/MES sistemine veya operatöre bildirilir.

Bu mimari, gerçek zamanlı karar destek sistemlerinin temelini oluşturmakta ve kalite kontrol sürecinin otomasyonunu mümkün kılmaktadır.

6.11.2. Yazılım araçları

Uygulama sürecinde aşağıdaki yazılım ve kütüphaneler kullanılmıştır:

- Python: Tüm veri işleme, model eğitimi ve test süreçleri Python programlama dili ile yürütülmüştür.
- Scikit-learn: Makine öğrenmesi modellerinin oluşturulmasında kullanılmıştır (Random Forest, SVM, Naive Bayes, KNN).
- Pandas / NumPy: Veri okuma, temizleme ve analiz işlemleri için kullanılmıştır.
- Matplotlib / Seaborn: Görselleştirme ve grafik çizimleri için kullanılmıştır.
- CMM Yazılımı ve Entegrasyon: CMM cihazından elde edilen veriler .txt, .csv veya .xls formatlarında dışa aktarılmış, Python ile bu dosyalar işlenmiştir.

6.11.3. CMM ölçüm verisinin alınması, işlenmesi ve karar mekanizmasına aktarılması

Aşağıdaki işlem adımları, verinin sistem üzerinden nasıl aktığına dair genel süreci tanımlamaktadır:


1. Veri Alma: CMM cihazı ile her parça üzerindeki belirli ölçüm noktalarından X, Y, Z koordinatları ve tolerans bilgileri alınır.
2. Dosya Aktarımı: Bu ölçümler otomatik veya manuel olarak .csv formatında kayıt altına alınır.
3. Veri Temizleme ve Normalizasyon: Python ortamında verideki eksikler giderilir, ardından z-score normalizasyonu uygulanır.
4. Model Girdisi Oluşturma: Temizlenmiş veriler, önceden eğitilmiş makine öğrenmesi modellerinin anlayabileceği biçime dönüştürülür.

5. Tahmin ve Karar: Model, parçayı kabul veya red olarak sınıflandırır.
6. Karar İletimi: Sonuç, arayüz üzerinden operatöre gösterilir veya üretim takip sistemine gönderilir.

6.11.4. Gerçek test senaryoları ve analizler


Sistem, hem geçmişte etiketlenmiş CMM verileriyle hem de üretim hattından alınan yeni ölçüm verileriyle test edilmiştir:

- Senaryo 1 – Etiketli Parçalarla Gerçek Test: Eğitilmiş modeller, daha önce ölçülmüş ve sınıfı bilinen parçalar üzerinde test edilmiştir. Random Forest modeli ile Parça 1'de %97.5 doğruluk oranı elde edilmiştir.
- Senaryo 2 – Canlı Üretim Verisi: Yeni üretilen parçaların CMM ölçümleri anlık olarak sisteme aktararak tahmin alınmış ve kalite mühendislerinin verdiği kararlarla karşılaştırılmıştır. Model ile insan kararı %94 oranında örtüşmüştür.
- Senaryo 3 – Hatalı Parça Simülasyonu: Sınırlı tolerans dışına çıkan ölçüm değerleri sisteme manuel olarak girilerek red kararı test edilmiştir.



Şekil 6.11. Parça 1 için Makine Öğrenmesi Performansı

Şekilde, Parça 1'e ait makine öğrenmesi model performansları grafiksel olarak karşılaştırılmıştır. Dört farklı algoritmanın (Random Forest, SVM, Naive Bayes ve KNN) hem doğruluk (accuracy) hem de F1 skoru değerleri ayrı ayrı gösterilmiştir. Görsel, algoritmaların farklı parça türleri üzerindeki başarı oranlarını karşılaştırmalı olarak ortaya koymaktadır.



Şekil 6.12. Parça 2 için Makine Öğrenmesi Performansı

Şekilde, Parça 2'ye ait makine öğrenmesi model performansları grafiksel olarak karşılaştırılmıştır. Dört farklı algoritmanın (Random Forest, SVM, Naive Bayes ve KNN) hem doğruluk (accuracy) hem de F1 skoru değerleri ayrı ayrı gösterilmiştir. Görsel, algoritmaların farklı parça türleri üzerindeki başarı oranlarını karşılaştırmalı olarak ortaya koymaktadır.

Parça 1 ve Parça 2 için verilen grafik incelendiğinde;

Geliştirilen sistem, geleneksel kalite kontrol süreçlerine kıyasla daha hızlı ve daha tutarlı kararlar vermektedir. Özellikle Random Forest ve Naive Bayes algoritmaları yüksek başarı sağlamış, kararların doğruluğu kalite mühendislerinin kararlarıyla büyük oranda örtüşmüştür.

CMM cihazı ile yapılan ölçümlerin doğrudan analiz edilebilmesi, hata payını azaltmış ve işlem süresini kısaltmıştır. Entegrasyonun tam otomasyonla çalışabilmesi, üretim hattında duraksamaların önüne geçerek verimliliği artırma potansiyeli taşımaktadır.



7. GENEL SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, CMM (Koordinat Ölçüm Makinesi) ile elde edilen ölçüm verilerinin makine öğrenmesi algoritmaları ile analiz edilerek parçaların otomatik olarak kabul veya reddedilmesini sağlayan bir karar destek sistemi geliştirilmiştir. Uygulama kapsamında farklı algoritmalar karşılaştırılmış, sistem mimarisi inşa edilmiş ve gerçek üretim senaryolarında test edilmiştir. Bu bölümde, geliştirilen sistemin genel başarımlar düzeyi değerlendirilmiş, insan müdahalesine kıyasla sağladığı avantajlar tartışılmış, üretim süreçlerine olan etkisi analiz edilmiş ve yapay zekâ destekli kontrol sistemlerinin geleceği üzerine çıkarımlarda bulunulmuştur.

7.1. Genel Sonuçlar

1. Geliştirilen otomatik kalite kontrol sistemi yüksek doğruluk ve F1 skoru ile başarılı sonuçlar üretmiştir.
2. Parça 1’de Random Forest algoritması %97,5 doğruluk ve 0.971 F1 skoru ile en iyi performansı göstermiştir.
3. Parça 2’de Naive Bayes algoritması %85 doğruluk ve 0.840 F1 skoru ile en başarılı model olmuştur.
4. Model sonuçları, kalite mühendislerinin kararlarıyla büyük oranda örtüşmüştür.
5. Sistem, insan kaynaklı hataları azaltarak daha tutarlı ve objektif kararlar sağlamıştır.
6. Manuel kontrol yöntemlerine göre karar süresi belirgin şekilde kısalmıştır.
7. Kullanıcı dostu arayüz sayesinde operatörlerin teknik bilgiye ihtiyaç duymadan sistemle çalışması sağlanmıştır.
8. Kararlarda subjektif ve duygusal etkiler ortadan kaldırılmıştır.
9. Üretim hattı kesintisiz çalışarak verimlilik artırılmıştır.
10. Hatalı parçaların erken tespiti ile hurda ve geri dönüşüm maliyetleri düşürülmüştür.
11. Sürekli kontrol sayesinde kalite dalgalanmaları azaltılmıştır.

12. Sistem, yüksek hacimli ve hassas toleranslı üretim süreçlerine uyum sağlamaktadır.
13. Model, Sanayi 4.0'a uygun yapay zekâ tabanlı bir çözüm sunmaktadır.
14. Gelecekte derin öğrenme algoritmaları ile sistem başarımı daha da geliştirilebilir.
15. IoT ve bulut entegrasyonları ile gerçek zamanlı ve merkezi kalite yönetimi sağlanabilir.

7.2. Öneriler

1. Sınıflandırma performansını artırmak amacıyla Gradient Boosting ve XGBoost gibi farklı algoritmalar değerlendirilebilir.
2. Derin öğrenme yöntemleri, özellikle görüntü tabanlı ve yüksek boyutlu veriler için entegre edilebilir.
3. Veri seti genişletilerek miller, gövdeler, flanşlar gibi farklı parça tipleri üzerinde çalışmalar yapılabilir.
4. Ovalite, koniklik, paralellik, yüzey pürüzlülüğü gibi farklı geometrik ölçümler modele dahil edilebilir.
5. IoT tabanlı sensör verileri ile gerçek zamanlı karar destek sistemleri geliştirilebilir.
6. Üretim süreçlerinden elde edilen sıcaklık, kesme hızı ve takım aşınması gibi proses verileri modele eklenebilir.
7. Model çıktılarının bulut sistemlerine aktarılmasıyla merkezi kontrol ve izleme sağlanabilir.
8. Operatörlerin kolay kullanım sağlayabileceği bir kullanıcı arayüzü tasarlanarak sistemle etkileşim kolaylaştırılabilir.
9. Geliştirilen sistem, benzer sınıflandırma gerektiren sağlık, tarım ve enerji gibi farklı sektörlerde uyarlanabilir.
10. Sürekli veri akışı ile modelin kendini güncelleyebilmesi sağlanarak adaptif bir yapı kurulabilir.
11. Veri dengesizliklerinin önüne geçmek için SMOTE gibi veri artırma teknikleri uygulanabilir.

12. Model performansının güvenilirliğini artırmak amacıyla ROC eğrisi ve AUC skoru gibi ek istatistiksel analizler yapılabilir.





KAYNAKLAR

- [1] Alpaydın, E. (2014). Introduction to Machine Learning (3rd ed.). MIT Press.
- [2] Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- [3] Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- [4] Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433–460.
- [5] Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210–229.
- [6] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- [7] Crevier, D. (1993). AI: The Tumultuous History of the Search for Artificial Intelligence. Basic Books.
- [8] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
- [9] Vapnik, V. N. (1995). The Nature of Statistical Learning Theory. Springer.
- [10] Campbell, M., Hoane Jr, A. J., & Hsu, F. H. (2002). Deep Blue. *Artificial Intelligence*, 134(1-2), 57–83.
- [11] Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78–87.
- [12] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- [13] Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489.
- [14] Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language Models are Few-Shot Learners. *arXiv preprint arXiv:2005.14165*.
- [15] Zhang, Y., & Xie, X. (2018). Surface defect detection based on machine vision and deep learning. *Procedia CIRP*.
- [16] Liu, Y., Wang, Y., & Jin, X. (2020). Deep learning-based automated visual inspection: A survey. *Computers in Industry*.
- [17] Wang, J., Liu, M., & Duan, L. (2019). Machine learning for process optimization in manufacturing: A review. *Journal of Manufacturing Systems*.
- [18] Dede, M., & Gürbüz, H. (2021). Üretim sistemlerinde makine öğrenmesi tabanlı süreç kontrolü. *Gazi Mühendislik Bilimleri Dergisi*.

- [19] Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*.
- [20] Lei, Y., Li, N., & Guo, L. (2018). Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*.
- [21] Yu, F., & Wang, C. (2017). Application of machine learning techniques in quality control. *International Journal of Advanced Manufacturing Technology*.
- [22] Özkan, B., & Kalkan, H. (2020). Makine öğrenmesi ile üretim hatlarında kalite sınıflandırması. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*.
- [23] Kusiak, A. (2018). Smart manufacturing. *International Journal of Production Research*, 56(1–2), 508–517.
- [24] Wuest, T., Weimer, D., Irgens, C., & Thoben, K. D. (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4(1), 23–45.
- [25] Lee, J., Bagheri, B., & Kao, H. A. (2014). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, 18–23.
- [26] Juran, J. M., & Godfrey, A. B. (1999). *Juran's Quality Handbook*. McGraw-Hill.
- [27] Montgomery, D. C. (2009). *Introduction to Statistical Quality Control*. John Wiley & Sons.
- [28] Shewhart, W. A. (1931). *Economic Control of Quality of Manufactured Product*. Van Nostrand.
- [29] Besterfield, D. H. (2012). *Quality Control*. Pearson Education.
- [30] ISO 286-1 (2010). Geometrical Product Specifications (GPS) — ISO code system for tolerances on linear sizes — Part 1: Basis of tolerances, deviations and fits.
- [31] ASME Y14.5-2018. Dimensioning and Tolerancing.
- [32] Madsen, D. A., Madsen, D. P., & LaLonde, J. (2018). *Print Reading for Engineering and Manufacturing Technology*. Goodheart-Willcox.
- [33] Turek, J. (2005). *GD&T: Application and Interpretation*. Industrial Press.
- [34] Zhou, Q., & Pyzdek, T. (2000). *The Six Sigma Handbook*. McGraw-Hill.
- [35] Parasuraman, R., Sheridan, T. B., & Wickens, C. D. (2000). A model for types and levels of human interaction with automation. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 30(3), 286–297.
- [36] Reason, J. (1990). *Human Error*. Cambridge University Press.
- [37] Zhang, Y., Wang, J., Zhao, X., & Xu, C. (2015). Human error and its influence on the quality of manual operations. *Procedia Manufacturing*, 3, 3328–3334.
- [38] García, J., Posada, J., Toro, C., & Posada, J. (2020). Quality inspection automation using machine learning. *Procedia CIRP*, 88, 119–124.

- [39] Bazerman, M. H., & Moore, D. A. (2013). Judgment in managerial decision making (8th ed.). Wiley.
- [40] Shmueli, G., Bruce, P. C., & Mehta, S. (2017). Data mining for business analytics: Concepts, techniques, and applications in R. Wiley.
- [41] Gürbüz, T., & Taş, B. (2020). Veri Analitiği ve Karar Destek Sistemleri. Nobel Yayın Dağıtım.
- [42] Zäh, M. F., & Ostgathe, M. (2009). Tool and manufacturing engineers handbook: Quality control and measurement. Springer.
- [43] Weckenmann, A., Estler, T., Peggs, G., & McMurtry, D. (2004). Probing systems in dimensional metrology. *CIRP Annals*, 53(2), 657–684.
- [44] Zhang, Y., Shen, Y., & Xi, F. (2014). Coordinate measuring machines: Structure and performance. *Measurement*, 47, 537–545.
- [45] Jiang, X., Liu, X., & Ma, L. (2012). Recent advances in dimensional metrology. *Measurement Science and Technology*, 23(3), 032001.
- [46] International Organization for Standardization (2015). ISO 10360: Geometrical product specifications (GPS) — Acceptance and reverification tests for coordinate measuring machines (CMM). International Organization for Standardization.
- [47] Bennett, J. (2007). Geometric Dimensioning and Tolerancing for Mechanical Design 2E. McGraw-Hill Education.
- [48] International Organization for Standardization (2017). ISO 1101: Geometrical product specifications (GPS) — Geometrical tolerancing. International Organization for Standardization.
- [49] Jiang, X., Liu, Y., Zhang, C., & Song, W. (2012). Automated coordinate measuring machines: Advances and applications. *Journal of Manufacturing Science and Engineering*, 134(5), 051013.
- [50] Education. Ayodele, T. (2010). Introduction to machine learning. Springer.
- [51] Li, Z., Zhang, C., & Liu, Y. (2020). Integration of CMM and automated inspection systems for advanced manufacturing. *Journal of Intelligent Manufacturing*, 31(2), 457-469.
- [52] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- [53] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- [54] Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18–22.
- [55] Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2nd ed.). O'Reilly Media.
- [56] Zhang, H., & Wang, D. (2017). A Random Forest Model for Predicting Surface Roughness in Manufacturing. *Procedia CIRP*, 63, 506–511.

- [57] Fernández-Delgado, M., Cernadas, E., Barro, S., & Amorim, D. (2014). Do we need hundreds of classifiers to solve real world classification problems? *Journal of Machine Learning Research*, 15, 3133–3181.
- [58] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- [59] Scholkopf, B., & Smola, A. J. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press.
- [60] Hsu, C. W., Chang, C. C., & Lin, C. J. (2010). A practical guide to support vector classification. Technical Report, National Taiwan University.
- [61] Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification* (2nd ed.). Wiley.
- [62] Zhang, Y., & Jiang, X. (2008). Application of SVM in quality prediction for injection molding. *International Journal of Advanced Manufacturing Technology*, 39, 1064–1072.
- [63] Mitchell, T. M. (1997). *Machine Learning*. McGraw Hill.
- [64] Zhang, H. (2004). The optimality of Naive Bayes. *AAAI Conference on Artificial Intelligence*, 1, 562–567.
- [65] McCallum, A., & Nigam, K. (1998). A comparison of event models for Naive Bayes text classification. *AAAI-98 Workshop on Learning for Text Categorization*, 752(1), 41–48.
- [66] Domingos, P., & Pazzani, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, 29(2–3), 103–130.
- [67] Rennie, J. D., Shih, L., Teevan, J., & Karger, D. R. (2003). Tackling the poor assumptions of naive bayes text classifiers. *ICML*, 3, 616–623.
- [68] Wang, J., & Zhang, Y. (2007). Application of naive Bayes classification in the fault diagnosis of manufacturing system. *Journal of Intelligent Manufacturing*, 18(3), 377–383.
- [69] Jiang, X., & Chen, H. (2020). Ensemble learning based on naive Bayes for intelligent manufacturing. *Computers & Industrial Engineering*, 147, 106665.
- [70] Cover, T. M., & Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27.
- [71] Aha, D. W., Kibler, D., & Albert, M. K. (1991). Instance-based learning algorithms. *Machine Learning*, 6(1), 37–66.
- [72] Dudani, S. A. (1976). The distance-weighted k-nearest-neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics*, (4), 325–327.
- [73] Beyer, K., Goldstein, J., Ramakrishnan, R., & Shaft, U. (1999). When is “nearest neighbor” meaningful? *International Conference on Database Theory*, 217–235.
- [74] Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175–185.

- [75] Fix, E., & Hodges, J. L. (1951). Discriminatory analysis-nonparametric discrimination: Consistency properties. *Technical Report 4*, USAF School of Aviation Medicine.
- [76] Wang, L., Wang, G., & Alexander, C. A. (2011). Fault diagnosis in manufacturing system based on KNN classification algorithm. *Journal of Intelligent Manufacturing*, 22(6), 745–753.
- [77] Liu, X., & Zhou, Z. H. (2005). The influence of class imbalance on cost-sensitive learning: An empirical study. *Proceedings of the 6th International Conference on Data Mining*, 970–975.





ÖZGEÇMİŞ

Ad-Soyad : Zeynep AKPULAT

ÖĞRENİM DURUMU:

- Lisans** : Sakarya Üniversitesi, Metalurji ve Malzeme Mühendisliği Bölümü, 2016 – 2020
- Yükseklisans** : Sakarya Üniversitesi, Metalurji ve Malzeme Mühendisliği Anabilim Dalı, 2022 – 2025

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2021 Kasım - 2024 Aralık yılları arasında Kar Metal Sanayi ve Ticaret Ltd. Şti.'de kalite mühendisi olarak çalıştı.
- 2025 Ocak tarihinden itibaren Kar Metal Sanayi ve Ticaret Ltd. Şti.'de kalite yöneticisi olarak çalışmaktadır.

TEZDEN TÜRETİLEN ESERLER:

Z. Birgin, “CMM Cihazındaki Verilerden Makine Öğrenmesi ile Parça Kontrolü”, 9. Geleceğin Mühendisleri Uluslararası Öğrenci Sempozyumu (EFIS 2025), Zonguldak Bülent Ecevit Üniversitesi, 7–9 Mayıs 2025. (*Sözlü Bildiri*)