

**T.C.  
MANİSA CELAL BAYAR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YÜKSEK LİSANS TEZİ**

**ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ELEKTRİK MOTORLARI İÇİN MAKİNE ÖĞRENMESİ  
TEMELLİ ARIZA ANALİZİ**

**İlyas Güvenç PİRGE**

**Danışman  
Doç. Dr. İlhan BAŞTÜRK**

**MANİSA 2025**

**İLYAS  
GÜVENÇ  
PIRGE**

**ELEKTRİK MOTORLARI İÇİN MAKİNE ÖĞRENMESİ TEMELLİ  
ARIZA ANALİZİ**

**2025**

## TAAHHÜTNAME

Bu tezin Manisa Celal Bayar Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalında akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, tezin yazımında akademik ve etik kurallara aykırı herhangi bir yapay zekâ ve program kullanmadığımı beyan ederim.

**İlyas Güvenç PİRGE**



# ÖZET

## Yüksek Lisans Tezi

### Elektrik Motorları İçin Makine Öğrenmesi Temelli Arıza Analizi

İlyas Güvenç PİRGE

Manisa Celal Bayar Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman:  
Doç. Dr. İlhan BAŞTÜRK

Günümüzde endüstriyel tesislerde seri üretimin durmadan verimli bir şekilde devam etmesi oldukça önemli bir konudur. Üretim hatlarında yaşanabilecek herhangi bir arıza, uzun duruşlara neden olup üretim verimliliğini (Overall Equipment Effectiveness-OEE) olumsuz yönde etkilemektedir. Bu arızaların yaşanmasını önlemek için planlı bakım ve kestirimci bakım uygulamaları büyük bir öneme sahiptir.

Geleneksel bakım yöntemlerinin yanında günümüz endüstriyel teknolojilerinin etkisi ile özellikle endüstri 4.0'ın getirdiği yeni yöntemler ile kestirimci bakım uygulamaları, bakım çalışmaları içerisinde ön plana çıkmıştır. Uyarıcı bakım olarak da bilinen bu yöntem sayesinde üretim sistemlerinde bakım gerektiren bir arıza önceden tahmin edilerek bu durum yaşanmadan ve sistemi uzun bir süre durdurmadan önüne geçilebilmektedir.

Bu tez çalışmasında, bir gıda üretim tesisinin nişasta transfer sisteminde yer alan helezon motoru ve şanzıman grubundan alınan titreşim ve sıcaklık değerleri ile ortam sıcaklık ve nem parametreleri kullanılarak arıza analizleri, farklı modeller aracılığıyla yapılmıştır. Yapılan bu arıza analizleri sonucunda arıza kaynaklı uzun duruşların öngörülebilmesi üretim, zaman ve maliyet kayıpları ile sonuçlanabilecek arızaların engellenmesi açısından önem teşkil etmektedir. Bu analiz çalışmasında yapay zekâ metotları arasında yer alan makine öğrenmesi algoritmaları kullanılmıştır. Makine öğrenmesi algoritmaları kapsamında denetimli öğrenme yöntemlerinden olan k-en yakın komşu (K-Nearest Neighbor, KNN), karar ağacı (Decision Tree, DT), Naive Bayes (NB), destek vektör makineleri (Support Vector Machine, SVM), rassal orman (Random Forest, RF) ve XGBoost algoritmaları kullanılarak sistemlerin performans verileri karşılaştırılmıştır. Çalışma kapsamında ele alınan modellerde girdi verisi olarak ortam sıcaklık ve nem, motor sıcaklık ve titreşim ile redüktör sıcaklık ve titreşim parametreleri kullanılmıştır. Modelin arıza yok, arıza kısa duruş, arıza uzun duruş yakın ve uzun duruş büyük arıza olmak üzere dört çıktısı bulunmaktadır. Bu

veriler, bazı denetimli öğrenme algoritmaları kullanılarak Python programında analiz edilmiştir. Çalışmanın sonucunda XGBoost ve DT algoritmalarının daha yüksek doğruluk oranı verdiği tespit edilmiştir.

**Anahtar Kelimeler : Makine Öğrenmesi, Kestirimci Bakım, Denetimli Öğrenme, Veri Analizi, Sıcaklık, Titreşim ve Nem Ölçümü, Asenkron Motor, Redüktör**

**2025, 68 sayfa**



## **ABSTRACT**

**M. Sc. Thesis**

### **Machine Learning Based Fault Analysis For Electrical Motors**

**İlyas Güvenç PİRGE**

**Manisa Celal Bayar University**

**Graduate School of Education**

**Department of Electrical and Electronics Engineering**

**Supervisor : Assoc. Prof. Dr. İlhan Baştürk**

In modern industrial facilities, it is crucial for mass production to continue uninterrupted and efficiently. Any breakdowns that may occur on production lines can lead to extended downtimes, negatively impacting production efficiency (Overall Equipment Effectiveness - OEE). Planned maintenance and predictive maintenance practices are crucial in preventing these failures.

In addition to traditional maintenance methods, predictive maintenance practices have gained prominence in maintenance activities, especially with the influence of modern industrial technologies, including Industry 4.0. Through this method, also known as condition-based maintenance, potential faults requiring maintenance in production systems can be predicted in advance, allowing them to be addressed before they occur and without long system shutdowns.

In this thesis study, fault analyses were performed on the starch transfer system of a food production facility using vibration and temperature values obtained from spiral motor and gearbox as well as ambient temperature and humidity parameters. through different models. As a result of the fault analyses conducted, the ability to predict long downtimes caused by faults is crucial for preventing breakdowns that could lead to production, time, and cost losses. In this analysis study, machine learning algorithms, which are one of the artificial intelligence methods, have been used. Within the scope of machine learning algorithms, the performance data of the systems have been compared using supervised learning methods such as k-nearest neighbors (KNN), decision tree (DT), Naive Bayes (NB), support vector machines (SVM), random forest (RF), and XGBoost algorithms. In this study, the input data for the models included ambient temperature and humidity, motor temperature and vibration, as well as gearbox temperature and vibration parameters. The model has four outputs: no failure, short stop failure, long stop failure close, and major failure during the long stop. These data were analyzed using some supervised learning algorithms in a Python program.

As a result of the study, it was found that the XGBoost and DT algorithms provided higher accuracy rates.

**Keywords : Machine Learning, Predictive Maintenance, Supervised Learning, Data Analysis, Temperature, Vibration ve Humidity Measurement, Induction Motor, Gearbox**

**2025, 68 pages**



## ÖNSÖZ VE TEŞEKKÜR

Endüstriyel tesislerde üretim hatlarının maksimum verimle çalışması ve yüksek performans ile sürdürülebilirliği her zaman birinci öncelik olmuştur. Bu hatların herhangi bir ekipmanında oluşabilecek bir arıza; zaman, enerji ve üretim kaybına yol açabilir. Bu nedenle uzun duruşlara sebep olabilecek arızaları gerçekleşmeden önce tespit edebilmek büyük bir öneme sahiptir. Bu amaç doğrultusunda, arızaların önceden belirlenmesi için kullanılan analiz ve yöntemlerin teknoloji ile geliştirilmesi, kestirimci bakım kapsamında yapılan araştırmaların hedefi haline gelmiştir. Bu tez çalışmasında, sahadan ölçülen sıcaklık, vibrasyon ve nem verilerinin analizi ve sınıflandırılmasıyla arıza tahminlemesi yapılmıştır. Bu tahmin etme çalışmalarında denetimli öğrenme yöntemlerinden bazı metotlar kullanılmıştır. Elde edilen bulgularla, kullanılan metotların performans analizi yapılarak yüksek performans gösteren metotlar ortaya çıkarılmıştır.

Bu çalışmanın yürütülmesinde, değerli bilgileri ve tecrübelerini benimle paylaşan, kıymetli zamanını ayırıp sabırla ve ilgiyle bana rehberlik eden değerli danışman hocam sayın Doç. Dr. İlhan BAŞTÜRK'e, hayatımın her anında hem maddi hem de manevi olarak en büyük desteği veren annem Gülten PİRGE ve babam İsmail PİRGE'ye, yoğun iş temposuyla birlikte yürütmeye çalıştığım yüksek lisans çalışmalarım boyunca desteğini eksik etmeyen ablam Gözde FİDAN'a ve tez çalışmasında uygulamaların ve analizlerin yapılmasında destek olan üretici firmaya en içten teşekkürlerimi sunarım.

İlyas Güvenç PİRGE  
Manisa, 2025

## İÇİNDEKİLER

	Sayfa
ÖZET.....	IV
ABSTRACT .....	VI
ÖNSÖZ VE TEŞEKKÜR .....	VIII
SİMGELER VE KISALTMALAR DİZİNİ.....	XI
ŞEKİLLER DİZİNİ .....	XII
TABLOLAR DİZİNİ .....	XIV
GİRİŞ.....	1
1. LİTERATÜR ÖZETİ.....	3
2. ENDÜSTRİDE BAKIM YAKLAŞIMLARI .....	5
2.1. Proaktif (Önleyici) Bakım .....	7
2.2. Koruyucu (Periyodik) Bakım .....	7
2.3. Kestirimci (Uyarıcı) Bakım .....	8
2.4. Arıza Bakımı.....	9
2.5. Fırsat Bakımı .....	11
2.6. Jelly Nişasta Transfer Sistemi ve Bakım Yaklaşımları .....	11
3. MAKİNE ÖĞRENMESİ .....	14
3.1. Makine Öğrenmesi Metodunun Adımları .....	16
3.2. Makine Öğrenmesinde Kullanılan Algoritmalar .....	18
3.2.1. Denetimsiz Öğrenme .....	19
3.2.1.1. Kümeleme (Clustering) .....	19
3.2.1.2. İlişkilendirme (Association).....	20
3.2.2. Denetimli Öğrenme .....	21
3.2.2.1. Sınıflandırma .....	22
3.2.2.1.1. Karar Ağaçları Algoritması .....	22
3.2.2.1.2. En Yakın Komşu Algoritması .....	23
3.2.2.1.3. Naive Bayes Algoritması.....	25
3.2.2.1.4. Destek Vektör Makinesi Algoritması.....	26
3.2.2.1.5. Rastgele Orman Algoritması.....	27
3.2.2.1.6. Extreme Gradient Boosting Algoritması .....	29
3.2.2.2. Regresyon.....	30
3.3. Makine Öğrenmesi Değerlendirme Ölçütleri .....	30
3.3.1. Doğruluk (Accuracy) .....	31
3.3.2. Duyarlılık (Recall).....	31
3.3.3. Kesinlik (Precision) .....	31
3.3.4. F1 Skoru (F1 Score) .....	31
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	32
4.1. Titreşim Değerleri Tablosu ve Analizi .....	35

4.2.	Veri Seti.....	37
4.3.	Gereç ve Yöntemler .....	40
5.	SONUÇLAR VE ÖNERİLER .....	62
	KAYNAKLAR.....	63
	ÖZGEÇMİŞ .....	68



## SİMGELER VE KISALTMALAR DİZİNİ

<b>ARF</b>	Ayarlanabilir Rastgele Orman Algoritması
<b>ARM</b>	Birliktelik Kural Çıkarımı
<b>CM</b>	Düzeltilici Bakım
<b>DT</b>	Karar Ağacı Algoritması
<b>ERP</b>	Kurumsal Kaynak Planlaması
<b>FFT</b>	Hızlı Fourier Dönüşümü
<b>HP</b>	Beygir Gücü
<b>KNN</b>	k – En Yakın Komşu Algoritması
<b>LoRa</b>	Uzun Mesafe
<b>ML</b>	Makine Öğrenmesi
<b>MRP</b>	Malzeme İhtiyaç Planlaması
<b>MTTR</b>	Arıza Onarım Süresi
<b>NB</b>	Naive Bayes Algoritması
<b>OEE</b>	Toplam Ekipman Verimliliği
<b>PdM</b>	Kestirimci Bakım
<b>PM</b>	Önleyici Bakım
<b>RF</b>	Rassal/Rastgele Orman Algoritması
<b>RPM</b>	Dakikadaki Devir Sayısı
<b>RUL</b>	Kalan Faydalı Ömür
<b>SAP</b>	Systems Analysis and Program Development
<b>SL</b>	Denetimli Öğrenme
<b>SVM</b>	Destek Vektör Makineleri Algoritması
<b>TPM</b>	Toplam Üretken Bakım
<b>UL</b>	Denetimsiz Öğrenme
<b>XGBoost</b>	Extreme Gradient Boosting Algoritması

## ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2. 1. Endüstriyel Bakım Stratejileri .....	6
Şekil 2. 2. Bir Hamur Tankına Ait SAP’de Tanımlanmış Bakım Paketi .....	8
Şekil 2. 3. Bağlantı Gevşekliği Sonucu Yaşanan Ark Problemi .....	10
Şekil 2. 4. Deforme Olan Pompa Bağlantı Parçası Kaplin.....	10
Şekil 2. 5. Nişasta Şartlandırma Sistemi (Vorteks).....	12
Şekil 2. 6. Dikey ve Yatay Motorlu Helezon Grupları.....	13
Şekil 3. 1. Yapay Zeka Disiplinleri .....	14
Şekil 3. 2. ML ile Yapılan Arıza Tespit Çalışmalarının Dağılımı.....	15
Şekil 3. 3. Anomali Tespit Çalışmalarının Yayım Yerlerine Göre Dağılımı.....	16
Şekil 3. 4. Makine Öğrenmesi Sürecinin Akış Şeması.....	17
Şekil 3. 5. Makine Öğrenmesi Algoritmaları.....	18
Şekil 3. 6. Kümeleme (Clustering) Örneği .....	20
Şekil 3. 7. Sınıflandırma ve Regresyon Grafikleri .....	21
Şekil 3. 8. Karar Ağacı Algoritma Yapısı.....	23
Şekil 3. 9. K En Yakın Komşu Sınıflandırma Örneği .....	24
Şekil 3. 10. İki Veri Sınıfının Destek Vektörleri ile Ayrılması.....	27
Şekil 3. 11. DT ve RF Karşılaştırma Şeması .....	28
Şekil 3. 12. Karar Ağacı Algoritmalarının XGBoost’a Evrimi.....	29
Şekil 4. 1. Bir Problemin Arızaya Dönüşüm Süreci.....	33
Şekil 4. 2. Jelly Nişasta Transfer Helezon Sistemi.....	34
Şekil 4. 3. Çalışmanın Yapıldığı İşletme Sahası.....	35
Şekil 4. 4. Çalışmanın Blok Diyagramı.....	37
Şekil 4. 5. Advantech WISE-2410 Smart Sensör.....	40
Şekil 4. 6. Sıcaklık ve Titreşim Sensörünün Gövdeye Montajı.....	41
Şekil 4. 7. X ve Y Ekseninde Ölçülen Titreşim Verileri .....	42
Şekil 4. 8. Y ve Z Ekseninde Ölçülen Titreşim ve Gövde Sıcaklık Verileri .....	42
Şekil 4. 9. Datalogger Görünümü ve Çalışma Ortamına Montajı .....	43
Şekil 4. 10. Datalogger Kurulum Arayüzü .....	44
Şekil 4. 11. Sıcaklık ve Nem Değerlerine Ait Ölçüm Grafiği .....	44
Şekil 4. 12. NB Öznitelik Önem Derecesi .....	46
Şekil 4. 13. Motor ve Redüktör Vibrasyon Değişimi .....	46
Şekil 4. 14. Motor Vibrasyon ve Motor Gövde Sıcaklık Değişimi .....	46
Şekil 4. 15. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim% 70-%30) 47	47
Şekil 4. 16. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Test % 70-%30) ...48	48
Şekil 4. 17. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim% 80-%20) 48	48
Şekil 4. 18. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Test % 80-%20) ...49	49
Şekil 4. 19. DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim%70-%30) 49	49
Şekil 4. 20. DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30) ...50	50
Şekil 4. 21. DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim%80-%20) 50	50
Şekil 4. 22. DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %80-%20) ...51	51
Şekil 4. 23. RF Öznitelik Önem Derecesi.....	51
Şekil 4. 24. RF Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30) 52	52
Şekil 4. 25. RF Karışıklık Matrisi ve Değerlendirme Metrikleri (Test % 70-%30)....52	52
Şekil 4. 26. KNN Algoritmasında Komşu Sayısı ve Doğruluk Değeri Değişimi .....	53
Şekil 4. 27. KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim%70-%30)	53
.....	53

<b>Şekil 4. 28.</b> KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)	54
<b>Şekil 4. 29.</b> KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %80-%20)	54
<b>Şekil 4. 30.</b> KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %80-%20)	55
<b>Şekil 4. 31.</b> SVM Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)	55
<b>Şekil 4. 32.</b> SVM Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)	56
<b>Şekil 4. 33.</b> XGBoost Algoritmasında Öznitelik Önem Derecesi	56
<b>Şekil 4. 34.</b> XGBoost Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim)	57
<b>Şekil 4. 35.</b> XGBoost Karışıklık Matrisi ve Değerlendirme Metrikleri (Test)	57
<b>Şekil 4. 36.</b> Kullanılan Algoritmaların Performans Metrikleri	58
<b>Şekil 4. 37.</b> Uzun Duruşa (Class 3) Sebep Olan Dışli Arızası	59
<b>Şekil 4. 38.</b> Helezon Milindeki Rulman Boşluğu Arızası	60
<b>Şekil 4. 39.</b> Algoritmaların İşlem ve Tahmin Süreleri	61



## TABLULAR DİZİNİ

	<b>Sayfa</b>
<b>Tablo 2.1</b> Planlı ve Plansız Bakımın Karşılaştırılması.....	6
<b>Tablo 3.1.</b> Karışıklık Matrisi (Confusion Matrix, CM) Örneği.....	30
<b>Tablo 4.1.</b> Titreşim Şiddeti Değerlendirme Tablosu.....	36
<b>Tablo 4.2.</b> Modelde Kullanılan Sınıfların Tanımlamaları.....	37
<b>Tablo 4.3.</b> Çalışmada Kullanılan Veri Kümesinin Bir Bölümü.....	38
<b>Tablo 4.4.</b> Öznitelik Başlıklarının Tanımlamaları .....	39
<b>Tablo 4.5.</b> Motor ve Redüktörün Teknik Özellikleri .....	41
<b>Tablo 4.6.</b> Denetimli Öğrenme Algoritmalarının Performans Sonuçları .....	58



## GİRİŞ

Ülkemizde üretim sektöründe, endüstriyel işletmelerin rekabetçi olabilmeleri için üretim süreçlerinde verimliliklerini arttırmaları büyük önem taşımaktadır. Verimlilik, kısıtlı ve aynı kaynaklar ile daha fazla çıktı elde etme yetisidir. Verimliliğini arttırmak isteyen işletmeler, teknolojik faaliyetleri takip ederek hem üretim performanslarını arttırmak hem de bu süreç içerisinde oluşan maliyetlerini minimize etmek durumunda kalmışlardır. Bu değerlendirme, işletmeleri üretim hatlarının bakımlarını daha etkin ve verimli bir şekilde uygulayabilecekleri bir program oluşturmalarına yaklaştırmıştır. Aksi durum düşünüldüğünde, bakımların sürdürülebilir yapılmadığı tesislerde arıza duruşlar artacak ve buna bağlı olarak işçilik, malzeme, enerji ve zaman açısından büyük kayıplar yaşanacaktır. Bu çıkarımlar genel olarak değerlendirildiğinde seri üretimin olduğu tüm sektör ve işletmelerde etkin ve programlı bakımların yapılması önem arz etmektedir.

Bakım uygulamaları literatürde genel olarak iki başlık altında ele alınmaktadır. Bunlar düzeltici (Corrective Maintenance, CM) ve önleyici bakım (Preventive Maintenance, PM) olarak adlandırılmaktadır [1]. Düzeltici bakım, bir ekipman veya sistemin iş göremez hale geldiği veya arızalandığı esnada yapılan bakım türüdür. Bu tarz bakımlar, anlık olup arızanın kök sebebinin bulmak ve sorunu çözmek için yapılmaktadır. İçeriğinden de anlaşılacağı üzere düzeltici bakım, genellikle acil durumlarda anlık ve plansız bir şekilde gerçekleşmektedir. Ayrıca anlık duruşlar ve yedek parça tüketimi göz önünde bulundurulduğunda düzeltici bakımlar, işletmelere maliyet açısından bir yük oluşturmaktadır.

Önleyici bakım ise, ekipman veya üretim hatlarının periyodik olarak kontrol edilip temizlenerek arızaların oluşmasını önleyen bir bakım çeşididir. Bu tür bakımlar, işletmelerin yıllık çalışma takvimi kapsamında önceden belirlenip uygulanmaktadır. Planlı yapılan bir uygulama olduğu için bu tür bakımlarda, kontrol edilecek ve aksiyon alınacak noktalar önceden tespit edilmekte ve bu aksiyonlarda kullanılacak olası yedek parçalar da bakım öncesi hazırlanmaktadır.

Düzeltici ve önleyici bakımların amacı, ekipmanların çalışma süresini maksimize ederek üretim verimliliğini (OEE) arttırmak ve öngörülemeyen arızalar

sonucu oluşacak maliyeti azaltmaktır. İşletmeler, bu bakımları tesislerine entegre edip sürdürülebilir bir şekilde uygulayarak maksimum verimliliği hedeflemektedir.

Önleyici bakım yaklaşımları içerisinde ele alınan diğer bir konu ise kestirimci bakımdır [2]. Kestirimci bakım, ekipmanların arızalarını tahmin etmek ve önlemek amacıyla elde edilen verilerin analiz edilerek çıkarımların yapıldığı bir bakım türüdür. Bu tür bakım, düzeltici ve önleyici bakımlar ile ele alınarak tamamlayıcı bir şekilde uygulanmaktadır. Bu bakımlar, özellikle iki önemli noktada işletmelere yardımcı olmaktadır. Bunlardan birisi arıza meydana gelmeden, sorun ortaya çıkmadan önce kullanıcıya uyarı vermesi ve arıza oluşmadan tahmin edebilmesi, ikincisi ise ekipmanların faydalı ömürlerinin uzaması için en uygun bakım zamanlarının belirlenmesi ve bu bakımların sürdürülebilirliğinin sağlanmasıdır [2].

Kestirimci bakım (Predictive Maintenance, PdM) ekipmana ait belirli parametrelerin sürekli izlenmesi ve analiz edilmesiyle gerçekleşmektedir. Sensörlerden veya diğer veri izleme sistemlerinden elde edilen veriler kullanılarak değerlendirme yapılmaktadır. Bu analizler ile ilgili ekipmanların kalan faydalı ömrü (Remaining Useful Life, RUL) veya üretim hatlarının ileriye dönük performansları tahmin edilebilmektedir. Bu tahminleme çalışmalarında makine öğrenmesi (Machine Learning, ML) algoritmaları sıklıkla kullanılmaktadır. Makine öğrenmesine dayalı kestirimci bakım modelleri işletmelerde ekipman, işçilik, zaman ve enerji gibi kayıpların maliyetlerinden kurtarabilecek önemli bir nokta olmuştur.

Bu çalışmada, ölçülebilen bazı verilerin farklı modellere uygulanmasıyla arıza analizi yapılmıştır. Çalışma, gıda sektöründe yer alan bir işletmenin üretim tesisindeki ham madde transfer sisteminde bulunan helezon motor redüktör grubuna uygulanmıştır. Çalışma, helezonun tahrik grubuna yerleştirilen sıcaklık ve vibrasyon sensöründen ve çalışma ortamının sıcaklık ile nem değerlerini ölçen datalogger cihazından alınan veriler ile yapılmıştır. Makine öğrenmesi algoritmalarından denetimli öğrenme metotları kullanılarak Python programında modellerin arıza analiz performansları karşılaştırılmıştır.

## 1. LİTERATÜR ÖZETİ

Kestirimci bakım kapsamında literatürde birçok çalışma bulunmaktadır.

Tuğba Köprü, 2022’de yaptığı çalışmada üretim hattından aldığı dört ayrı titreşim verisi ile RPM ve akım verilerini kullanarak bir veri seti oluşturmuştur. Bu veri setini istatistiksel bir program üzerinde destek vektör makinaları ve karar ağacı algoritmaları ile analiz etmiştir. Yapılan analiz sonucunda karar ağacı algoritmasının daha yüksek doğruluk tahmini gerçekleştirdiği sonucuna varılmıştır [2].

Özcan Armağan Ayan, 2019’da yaptığı çalışmada titreşim analizi yöntemini kullanarak baca gazı fanında yaşanan balanssızlık arızası ve dış bilezik hasar tespitini yapmıştır. Bu tespitleri fanın çalışmasına ciddi bir tehlike oluşturmadan önce yaparak olası üretim kayıplarının ve ek bakım maliyetlerinin önüne geçmiştir [3].

Kürşat Tuncer 2022’de bir seramik fabrikasında toz emme görevini yapan fan motor tahrik grubunun üzerindeki 8 farklı noktadan (motor iç yatay, motor iç dikey, motor dış yatay, motor dış dikey, fan iç yatay, fan iç dikey, fan dış yatay, fan dış dikey) titreşim verilerini ölçerek balanssızlık problemini tespit etmiştir [4].

Hakan Ceyhan 2022 yılında yaptığı çalışmada endüstriyel alanda üretim yapan bir döküm makinesi üzerinde mikser motoru sürücü arıza zamanı tahmini için kestirimci bakım uygulamasını gerçekleştirmiştir. Uygulanan modellerin çıktılarını ele alındığında denetimli makine öğrenme modeli olan rastgele orman ile nispeten daha başarılı sonuçlar elde edildiği tespit edilmiştir [5].

Yusuf Kalemoglu, tez çalışmasında bir demir çelik tesisinin haddehanesinde bulunan bir tezgâhın, elektrik motorlarında sıcaklık ve titreşim ölçümleri ile kestirimci bakım uygulaması yapmıştır. Her motordan ön ve arka rulman sıcaklıkları, sargı sıcaklıkları, ön ve arka kapak titreşim verileri alınarak sisteme entegre etmiştir. Verilerin analizi aşamasında rulman arızası tespiti yapılmış ve onarılmıştır [6].

Erkan Sındır, bir asenkron motorun sıcaklık, titreşim ve akım değerlerini PLC yardımı ile sahadan toplamış ve veri tabanına aktararak test verilerinin oluşturulmasında kullanmıştır. Sahadan toplanan verilerin MATLAB uygulaması aracılığıyla analizi sonucunda bulanık mantık temelli çıkarım sistemi tasarlamıştır. Sisteme giriş değişkeni olarak verilen test verilerinin değerlendirilmesi sonucunda üretilen çıkış değişkeniyle sistemde çalışan asenkron motorun motor sağlığını belirlemiştir [7].

Mehmet Şahin, bir işletmedeki torna tezgahından belli bir zaman aralığında aldığı verileri Python programlama dilini kullanarak analiz etmiştir. Bu analiz esnasında anomali tespiti yapmak için aykırı değer, seviye yükseltme ve kayması, desen değişimi ve sezonluk düzen gibi farklı metotlar kullanmıştır [8].

Telat Akyaz, bir endüstriyel tesiste makinelerin titreşim, sıcaklık, ortam hava kalitesi ve güç tüketimi verilerini sahadan toplayarak bir bulut uygulamasına kaydeden taşınabilir ve modüler bir sistem tasarlamıştır. Toplanan verilerin optimizasyon çalışmasında MATLAB makine öğrenmesi ara yüzünü kullanmıştır [9].

Ercan Kızılay, demiryolu makas motorlarının emniyetli operasyonu ve gerçek zamanlı verilere dayalı olarak kestirimci bakım faaliyetlerinin entegrasyonu ile bir kontrol sistemi geliştirmiştir. Yaptığı tasarım çalışması ile emniyet yazılımlar geliştirip test sağlamıştır. Kontrol devresinde kestirimci bakım algoritması oluşturarak dataları analiz etmiştir [10].

Aykut Atapek, turbo jet motorlarının titreşimlerini ölçtüktan sonra bu verileri detaylı analiz ederek dört adet motor arızasının önceden tespit etmiştir [11].

Asad Asadzade, tez çalışmasında jet motorlarının kalan faydalı ömürlerini tahmin etmek için NASA tarafından sağlanan simülasyon veri setlerini kullanarak akış öğrenmeye dayalı ARF (Adaptive Random Forest) yöntemini uygulamıştır. Daha sonra aynı veri kümesinin kullanıldığı diğer çalışmalar ile karşılaştırmalar yapmıştır [12].

Halil Murat Karadayı, tez çalışmasında kestirimci bakım yöntemlerinden biri olan titreşim ölçümü yöntemiyle bir işletme için kritik olan pompa grubundan veriler olarak titreşim seyrini incelemiştir. Alınan ölçümlerin FFT spektrum analizini yapmıştır. Bu analiz ile ekipman arızı bir duruşa sebep olmadan önce arıza tespiti yapılabildiğini ortaya koymuştur [13].

V. İlhan Baykara, tez çalışmasında bir sistemde çalışmakta olan bir şanzımandan aldığı titreşim ölçümlerini analiz etmiş ve şanzımanın dişli çarklarında oluşan hasarları tespit etmiştir. Bu şekilde kestirimci bakım uygulayarak şanzımanın çok daha ciddi şekilde hasar alarak plansız duruşlara sebep olmasını engellemiştir [14].

Sadettin Orhan, rulmanlarla yataklanmış dönen makine elemanlarında titreşim analizi kullanarak kestirimci bakım uygulaması gerçekleştirmiştir. Elde ettiği titreşim verilerini frekans analizi metodu ile değerlendirerek dengesizlik, eksen kaçıklığı, mekanik gevşeklik ve rulman hasarlarını ilk oluşma anlarında belirlemeye çalışmıştır [15].

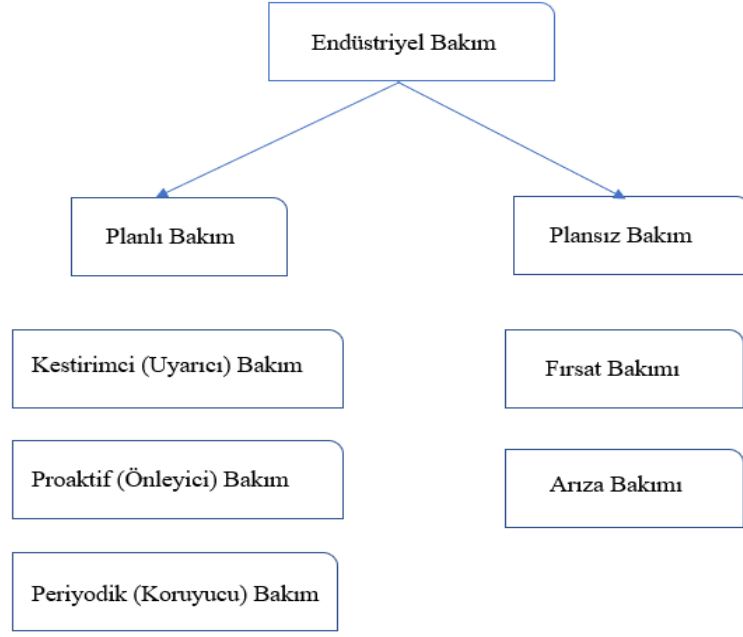
## 2. ENDÜSTRİDE BAKIM YAKLAŞIMLARI

Bakım kavramı ilk olarak düzeltici bakım olarak karşımıza çıkmıştır. Diğer bir adı arıza bakımı olan düzeltici bakım stratejisi, arızalar meydana geldikten sonra yapılan bakım faaliyetini kapsamaktadır. Bu bakım tekniği; ekipmanın arızaya geçmesinden sonra yapılan onarım işlemleri, ekipmanda meydana gelen arızadan etkilenerek daha büyük arızalara yol açılmaması için uygulanan arıza tespiti, düzeltici işlemler ve ayar gibi işlemleri kapsar. Ancak bu bakım metodunun çok maliyetli olması, arızaların öngörülemeyen bir zamanda yaşanması, gereğinden fazla malzeme ve işgücü kayıplarına sebep olması ve ekipman verimliliğinin ciddi oranlarda düşmesi gibi olumsuz yönlerinden dolayı bu bakım tekniği zamanla yerini planlı bakıma bırakmıştır [11].

Planlı bakım; herhangi bir arızanın yaşanmasını beklemezsiniz, belirli periyotlarla yapılan bakımı ifade eder. Genelde işletmeler yıl başlarında, üretim planlama, satış operasyon ve bakım planlama birimlerinin istişareleri sonucunda yıllık bakım planı hazırlarlar. Hazırlanan plan kapsamında yıl içinde bakım faaliyetleri sürdürülür, bu bakım planı arıza, duruş vs. ile ilişkisi olmaksızın devam eder. Yalnız üretim yaklaşımlarından olan toplam verimli bakımın da (TPM) konusu içerisine giren planlı bakım, işletmelere üretim verimliliği konusunda büyük yarar ve imkân sağlar. Üretimin kesintisiz ve yüksek kapasitede çalışmasını sağlayan bir faaliyettir [2]. Planlı bakım yaklaşımı; koruyucu bakım, önleyici bakım ve kestirimci bakım olmak üzere üç başlık altında incelenmektedir.

Endüstride bakım yaklaşımları, ekipmanların veya sistemlerin çalışma sürelerini ya da performanslarını optimize etmek için kullanılan çeşitli strateji ve yöntemlerdir. İşletmeler, bu yaklaşımları uygulayarak ekipmanları daha verimli bir şekilde kullanabilmekte, duruş sürelerini minimize ederek maliyetleri düşürebilmektedir.

Endüstrinin gelişimine paralel olarak sistem, malzeme, işgücü maliyetlerinde ve kaliteli ürün çıktısı ihtiyaçlarındaki artışlar, makinaların karmaşık yapısı işletmeler için uygun bakım politikalarının önemini artırmıştır [17]. Şekil 2.1.'de endüstriyel ortamda uygulanabilen bakım stratejileri görülmektedir.



**Şekil 2.1.** Endüstriyel Bakım Stratejileri

Planlı ve plansız bakımın ayrıntılı bir şekilde karşılaştırılması Tablo 2.1. 'de görülmektedir.

**Tablo 2.1.** Planlı ve Plansız Bakımın Karşılaştırılması [19]

Sıra	Parametreler	Plansız Bakım	Planlı Bakım
1	Arızalar	Yüksek	Düşük
2	Kesinti/Duruş	Yüksek	Düşük
3	Ürün Çıktısı	Düşük	Yüksek
4	Bakım Masrafları	Yüksek	Düşük
5	Ekipman/Tesisin güvenilirliği	Düşük	Yüksek
6	Tesis/Ekipman mevcudiyeti	Düşük	Yüksek
7	Ekipman/Tesis yüzdesinin kullanımı	Düşük	Yüksek
8	Yedeklerin stok kontrolü	Yok	Var
9	Arıza için önceden uyarı	Yok	Mümkün

## 2.1. Proaktif (Önleyici) Bakım

Ekipman veya sistemlerin arızalanmadan önce yapılacak düzenli bakım faaliyetleri ve tedbirlerini içeren bir bakım yaklaşımıdır. İşletmelerde otonom bakım olarak da bilinmektedir. Bu yaklaşımda, ekipmanların çalışma süresi boyunca periyodik olarak kontrol edilmesi, temizlenmesi, ayarlanması ve yağlanması gibi önleyici işlemler gerçekleştirilir. Önleyici bakımın amacı; ekipmanların performansını optimize ederek arızaların önüne geçmek ve ekipman verimliliğini artırmaktır. Proaktif bakım, bakım yöntemleri ile elde edilen teknik bilgileri, problemi tanımlamak ve arıza kaynağını izole etmek için kullanılır [18]. Bu bakım, genellikle belirlenmiş bir program dahilinde yapılmaktadır.

## 2.2. Koruyucu (Periyodik) Bakım

Koruyucu bakım, ekipmanların çalışma sürelerini ve performanslarını optimize etmek amacıyla düzenli olarak yapılması gereken bakım faaliyetleridir. Bu tür bakımlar, belirli bir periyotla planlanır ve önceden önlem olarak arızaların oluşmasını önlemek amacıyla gerçekleştirilir.

Koruyucu bakım, ekipmanların düzenli olarak kontrol edilmesi, temizlenmesi, yağlanması gibi işlemleri içermektedir. Ömrünü tamamlamış parçaların değiştirilmesi gibi aksiyonlar da koruyucu bakım kapsamında değerlendirilmektedir.

Bu tür bir bakımın amacı, beklenmeyen arızaların önüne geçmek ve ekipmanların daha uzun süre verimli bir şekilde çalışmasını sağlamaktır. Böylece arıza kaynaklı uzun duruşlar engellenerek üretim sürekliliği sağlanır ve maliyetler minimize edilir. Periyodik bakım yaklaşımında amaç, makineler arızalanana kadar değil, belirli aralıklarla bakıma alınarak periyodik kontrollerinin yapılması ve arıza meydana getirebilecek parçalarının değiştirilmesi esasına dayanır. Örneğin çalışma saati baz alınarak ya da yılda bir, ayda bir gibi zaman aralıkları belirlenerek bakımlar yapılabilir. Bakım aralıkları genellikle işletmenin geçmiş tecrübelerinden istatistiksel olarak belirlenir [16].

Koruyucu bakım ile ilgili kararlar genellikle risk analizi yapılarak alınır. Ekipmana ait geçmiş veriler ve deneyimler göz önünde bulundurularak en uygun bakım periyotları belirlenerek bir sistem oluşturulur. Oluşturulan bu sistemlerin dijital

ortamda takibi ise ERP (Kurumsal Kaynak Planlaması) yazılımları üzerinden sağlanır. İşletmelerde en sık kullanılan yazılımlardan biri olan SAP PM (Plant Maintenance) modülü ara yüzünde oluşturulmuş bir bakım paketi görseli Şekil 2.2.'de görülmektedir.

Bakım paketleri işlem gn.bakışı							
İşl	Altışl	İşlem tanımı	1	3	6	12	24
0010		İş Güvenliği Önlemleri Alınır	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0020		Gıda Güvenliği Önlemleri Alınır	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0030		Meyve suyu vanası fonksiyon testi	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0040		Maltoz vanası fonksiyon testi yapılır	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0050		Maltoz vanası conta değişimi yapılır	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
0060		Maltoz tankı pozisyoner varsa bağlantı	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0070		KM40 vanası fonksiyon testi yapılır	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0080		KM40 conta değişimi yapılır	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
0090		KM40 vanası pozisyoner varsa bağlantı	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0100		Jelatin vanası fonksiyon testi yapılır	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0110		İskarta vanası fonksiyon testi yapılır	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0120		Şeker helezonu motor bağlantı sıklık	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0130		Şeker helezonu redüktör yağı	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
0140		Şeker helezonu redüktör yağ seviye	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0150		Nişasta helezonu motor bağlantı sıklık	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0160		Nişasta helezonu redüktör yağı	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
0170		Nişasta helezonu redüktör yağ seviye	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0180		Mikser motor bağlantı sıklık kontrolü	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
0190		Mikser üstü yataklama rulman değişimi	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
0200		Mikser alt yataklama rulman değişimi	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>

**Şekil 2.2.** Bir Hamur Tankına Ait SAP 'de Tanımlanmış Bakım Paketi

SAP ara yüzünde tanımlanan bu görev listesindeki her bir bakım kalemi farklı bir zaman paketine bağlanmıştır. Şekilde görüleceği üzere, aylık (1), 3 aylık (3), 6 aylık (6), yıllık (12) ve iki yıllık (24) zaman paketleri bulunmaktadır. Sistemden bu paket aktive edildiğinde her bir bakım kalemi, tanımlanmış zaman dilimleri boyunca otomatik bir şekilde bakım ekibinin iş listesine yansımaktadır.

### 2.3. Kestirimci (Uyarıcı) Bakım

Kestirimci bakım bir ekipmanın arıza yapma olasılığını, hangi süre içerisinde arıza yapacağını, ekipmanın kalan kullanım ömrü hakkında bilgi vermek amacıyla ölçme, analiz, tecrübe ve izlenimlere dayalı bir kontrol ve bakım stratejisidir [11]. Kestirimci bakım, veri analizi ve izleme teknikleri kullanarak ekipmanlardaki

anormallikleri tespit etmekte ve potansiyel sorunları önceden belirleyerek uygun önlemlerin alınmasına yardımcı olmaktadır.

Kestirimci bakımın diğer bakım tekniklerine göre en büyük avantajı ölçümler ile makinadan alınan verilerin değerlendirilmesi ve üretimi durdurmaksızın anomali durumlarını yorumlayarak arızalar gerçekleşmeden periyodik bakımların planlanarak uygulanmasıdır [11]. Olası arıza kaynağı olan parçayı tespit etmek ve bu sorunu ortaya çıkaran parçadaki hatanın daha da artmaması için erken müdahale şansı doğar. Uyarıcı bakım uygulamalarının diğer bakım türlerinden ayıran en önemli özelliği, zaman veya problem temelli değil, mevcut durum temelli yaklaşımıdır [7].

Kestirimci bakımın avantajları şu şekilde sıralanabilir:

- Beklenmedik duruşların minimize edilmesi
- Ekipman ömrünün uzatılması
- Daha etkin kaynak kullanımı
- Maliyet tasarrufu
- Güvenlik riskinin azaltılması


Kestirimci bakım, günümüzde endüstri 4.0 teknolojilerinin gelişimiyle daha sık kullanılır hale gelmiştir. Veri analizi, makine öğrenmesi gibi ileri teknolojiler kestirimci bakıma destek olmaktadır.

Kestirimci bakım stratejilerini uygulamak, yapılan bakım yatırımının kendini amorti etme oranında önemli bir yarar sağlamaktadır. Ayrıca bakım maliyetlerinin %25-%30 oranında azaldığını, arıza sayısının %70 oranlarında düştüğünü, arızanın onarım süresinin (Mean Time To Repair, MTTR) %35-45 aralığında azaldığını göstermektedir [7].

## **2.4. Arıza Bakımı**

Herhangi bir uyarıcı sistem kullanılmadan ve belirli zaman dilimlerinde yapılmayan, arıza meydana geldikten sonra yapılan bakım onarım çalışmalarıdır [6]. Bu yaklaşım, makinelerin arızalanıp durmasına kadar herhangi bir müdahaleye uğramadan çalışması üzerine kuruludur [13]. Arıza gerçekleşikten sonra en kısa süre içerisinde problemin giderilmesini amaçlayan bir bakım çeşididir.

Bu bakımın gerçekleştirildiği işletmelerde plansızlık durumu da söz konusudur. Çünkü işletmede herhangi bir arızanın ne zaman olacağı bilinmeyeceği için her an arıza çıkabileceği fikri ile belirli bir program dahilinde çalışma yapılamamaktadır. Bu durum da bakım ekibinin acil müdahale ve onarım ekibi olarak çalışmasına neden olmaktadır [13]. Bakımların düzenli yapılmadığı durumlarda ortaya çıkan arızalardan bazı örnekler Şekil 2.3. ve Şekil 2.4.'te görülmektedir.



**Şekil 2.3.** Bağlantı Gevşekliği Sonucu Yaşanan Ark Problemi



**Şekil 2.4.** Deforme Olan Pompa Bağlantı Parçası Kaplin

Arıza durumunda yapılan bakım çalışmalarının genel olarak yeterli sayıda bakım personeli bulundurmeyen, küçük ölçekli veya kurumsallaşma yolunda çok fazla ilerleme gösteremeyen işletmelerde benimsendiği söylenebilir [6]. Bu tarz bakım çalışmalarının gözle görülen maliyeti düşürdüğü ancak sebep olduğu plansız duruşlar, zaman ve ürün kaybı gibi faktörler ile üretim maliyetlerini olumsuz yönde etkilediği bilinmektedir [6].

## **2.5. Fırsat Bakımı**

Ekipman veya makinelerin planlanmış bakımları dışında ortaya çıkan fırsatlar üzerine yapılan bakım faaliyetleridir. Bu yaklaşım, periyodik bakımın yanı sıra ekipman durumunu sürekli izleyerek ve herhangi bir anomali durumu tespit edildiğinde aksiyon alınarak gerçekleştirilmektedir.

Fırsat bakımı, beklenmedik duruş sürelerini en aza indirmek ve ekipman ömrünü uzatmak için önleyici bir tedbir olarak uygulanmaktadır. Farklı endüstriyel alanlarda kullanılabilen farklı yöntemlere sahip ekipmanlar için uygulanan bir yaklaşım olarak değerlendirilmektedir. Her ne kadar etkili de olsa tamamen planlama ya da rutin periyodik bakım yerine geçmez.

## **2.6. Jelly Nişasta Transfer Sistemi ve Bakım Yaklaşımları**

Yüksek üretim verimliliği ve daha kaliteli kalıplandırılmış nişastalı ürünlere olan talep, jelly üretim prosesinde nişastanın özel koşullandırılmış ortamda iklimlendirilmesini gerekli kılmıştır. Bunun için gerekli olan koşulların başında düşük nem ve optimum kalıp sıcaklığı gelmektedir. Bu amaçla nişastanın iklimlendirilmesi için özel nişasta şartlandırıcı üniteler geliştirilmiştir.

Nişasta şartlandırma, nişastada bulunan suyun termal yollarla uzaklaştırılmasını ve gerekli kalıplama sıcaklığına kadar soğutulmasını içermektedir.

Nişasta şartlandırma ünitesi (vorteks), nişastayı mekanik olarak kurutucu ve soğutucu boyunca tanımlanmış bir bekleme süresiyle yönlendiren bir sıyırıcı zincir taşıyıcı sistemine sahiptir. Bu sıyırıcılar, ısınır ve kurutucu içindeki nişastaya temaslı

ısıtma yoluyla ek ısı aktarır. Bu ısı transferi soğutucuda da gerçekleşir. Sonuç olarak kullanılan hava akışı miktarını azaltır ve nişastanın nem değeri stabilize edilir.

Nişasta, vorteks ile kalıplama hattı arasında bağlantıyı sağlayan dikey ve yatay pozisyonda konumlandırılmış birçok helezon konveyör aracılığıyla transfer edilmektedir. Her helezon konveyörünün tahrik grubu akuple bir redüktör ve asenkron motordan oluşmaktadır. Herhangi bir helezona ait tahrik grubunda yaşanacak olası bir arıza, nişasta transfer hattının sıkışmasına ve nişastanın kalıp baskı noktasına zamanında ulaşamamasına neden olmaktadır. Bu durum, üretim verimliliğini olumsuz yönde etki etmektedir. Bu nedenle uzun duruşlar yaşatabilecek bu alanda bazı verilerin analizi ile arızaların önceden tahmin edilebilmesi büyük önem taşımaktadır. Şekil 2.5.'te sıcak ve soğuk ünitelerden oluşan bir nişasta şartlandırıcı grubu yer almaktadır. Nemin dengelendiği bu grupta nişastayı kalıp noktasına ileten yatay ve dikey konumlanmış birçok spiral helezon bulunmaktadır. Bu helezonlar, Şekil 2.6.'da görülmektedir.



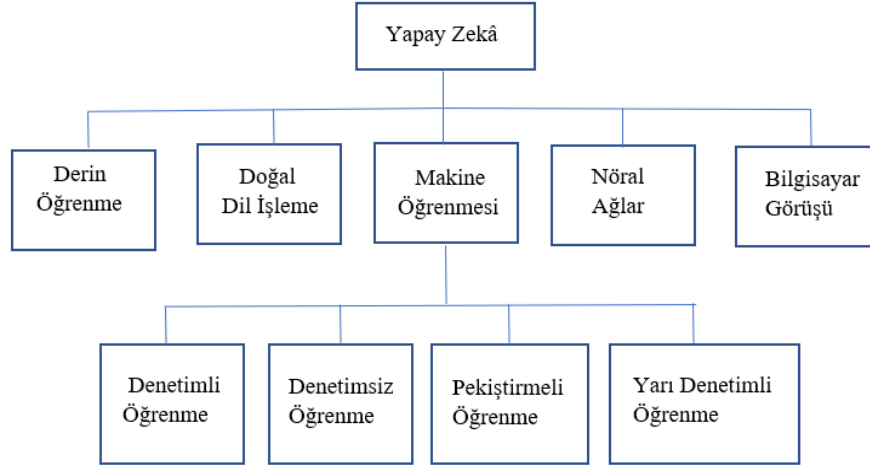
**Şekil 2.5.** Nişasta Şartlandırma Sistemi (Vorteks)



**Şekil 2.6.** Dikey ve Yatay Motorlu Helezon Grupları

### 3. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, yapay zekâ alanında alt bir disiplin olarak kabul edilmektedir. Bu disiplinin temel amacı, insan müdahalesi olmadan karmaşık problemleri analiz edip çözebilen otonom sistemler geliştirmektir. Bunun için çeşitli makine öğrenmesi algoritmaları kullanılmaktadır. Bunlar arasında denetimli öğrenme (Supervised Learning, SL), denetimsiz öğrenme (Unsupervised Learning, UL) ve pekiştirmeli/takviyeli öğrenme (Reinforcement Learning, RL) gibi farklı yaklaşımlar bulunmaktadır. Bakımdan üretime, satıştan robotiğe kadar birçok alanda toplanan veriler makine öğrenmesi algoritmaları ile yorumlanarak fayda sağlamaya çalışılmaktadır [2]. Şekil 3.1.'de makine öğrenmesine ait alt disiplinler görülmektedir [22].




Şekil 3.1. Yapay Zekâ Disiplinleri [22]

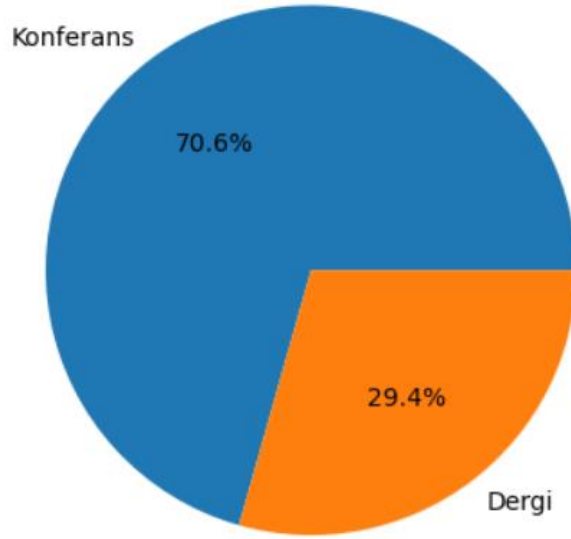
Yapay zekâ kapsamında makine öğrenimi, birçok alanda akıllı tahmin algoritmaları geliştirmek için güçlü bir araç olarak ortaya çıkmıştır. Makine öğrenmesi (ML) yaklaşımları, yüksek boyutlu ve çok değişkenli verileri işleme, kompleks ve birçok parametreye bağlı değişken ortamlarda veriler arasındaki ilişkileri ortaya çıkarma yetisine sahiptir [20]. Bu nedenle ML, kestirimci bakım (PdM) uygulamaları için güçlü tahmin yaklaşımları sağlar. Ancak bu uygulamaların performansı, uygun makine öğrenmesi algoritmasının belirlenmesine ve seçimine bağlıdır [21].

Makine öğrenmesi yöntemlerinin farklı alanlarda kullanılması insana olan gereksinimi önemli ölçüde azaltmıştır. İnsandan kaynaklı verim kaybı ya da hataların önüne geçilmiştir [2]. Kullanılan bu metotlar ile büyük veri setleri analiz edilerek kısa sürede daha etkin ve daha doğru kararlar verilebilmektedir.

Makine öğrenimi zamanla oluşan verileri analiz ederek gelecekte meydana gelebilecek durumları tahmin edebilen modeller yaratmak için çeşitli algoritmaları kapsamaktadır [23]. Bu kapsam, genellikle üç başlık altında incelenmektedir. Bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir. 2021-2024 yılları arasında gerçekleştirilen, ML yöntemleri kullanılarak yapılan motor rulman arızalarının tespiti ile ilgili çalışmaların yıllara ve yayım yerlerine göre dağılımı Şekil 3.2. ve Şekil 3.3.'te görülmektedir. Bu değerler, IEEE sitesinden yapılan taramayla elde edilmiştir. Şekil 3.2.'deki grafik incelendiğinde, son iki yılda anomali tespiti ile ilgili yapılan bilimsel çalışmalarda kayda değer bir artış görülmüştür. Şekil 3.3.'te yer alan dairesel grafik, bu yıllar arasında yapılan toplam 177 çalışmadan 125'inin (%70.6) konferans yayınlarında, 52'sinin (%29.4) ise bilimsel dergilerde yayımlandığını göstermektedir.



**Şekil 3.2.** ML ile Yapılan Arıza Tespit Çalışmalarının Dağılımı



**Şekil 3.3.** Anomali Tespit Çalışmalarının Yayın Yerlerine Göre Dağılımı

### 3.1. Makine Öğrenmesi Metodunun Adımları

Makine öğrenmesi yöntemi ile yapılan çalışmalarda veri kümesi büyük öneme sahiptir. Veri sayısının artması, verilerin işleme ve analizini zorlaştırmaktadır. Büyük verilere sahip makine öğrenmesi algoritmalarında analiz süreci birçok adımdan oluşmaktadır. Şekil 3.4.'te makine öğrenmesi akış şeması görülmektedir.

**Problem Belirleme:** Makine öğrenmesi çalışmasında ele alınacak konunun öncelikle belirlenmesi gereklidir. Sistemin öngörü yapacağı ve hangi verileri kullanarak tahminleme geliştireceği problem, netleştirilmelidir.

**Veri Toplama:** Probleme ilgili toplanan veriler excel (xls) ya da virgüllerle ayrılmış düz metin dosyaları formatında (csv) olabilir. Bu aşama, probleme ilgili makine öğrenmesi yöntemlerinin en doğru skoru vermesi adına önem teşkil etmektedir. Çünkü hazırlanacak veri tabanının ne kadar yoğun, fazla ve çeşitli olması öğrenme skorunu bir o kadar doğruluk payına yaklaştıracaktır.

**Verilerin Hazırlanması:** Makine öğrenme algoritmalarında kullanılacak veri kümesini oluşturan verilerin tutarlı ve mantıklı olması gereklidir. Veri tabanında tutarsız kalan veriler çıkarılmalıdır. Bu işlemlerden sonra elde kalan yorumlanabilir ve ölçülebilir verilerin algoritma akışında bir kısmı öğrenme/eğitim adımında, diğer

kısmı test yani değerlendirme adımında (literatürde %80 eğitim, %20 test ya da %70 eğitim, %30 test oranları ile çalışmalar mevcut) kullanılmalıdır.

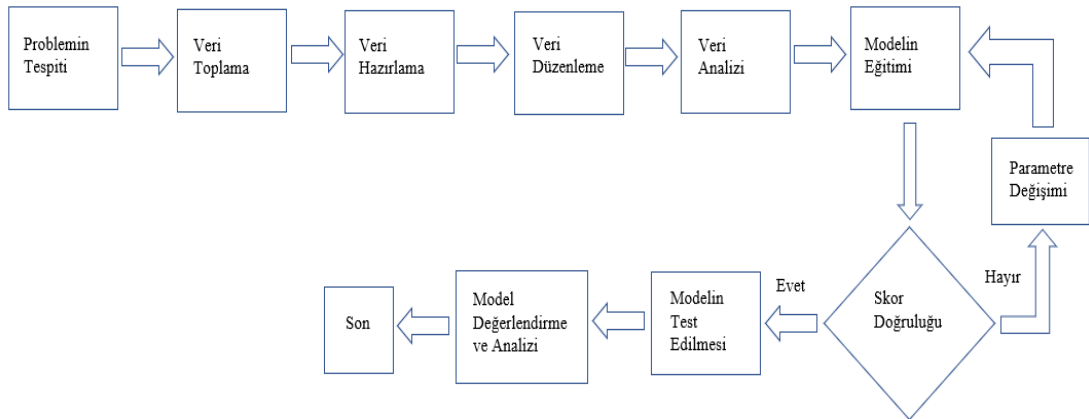
**Modelin Belirlenmesi:** En uygun veri analizi yöntemi olan algoritmanın seçildiği adımdır. Makine öğrenmesi sürecinde bazı modeller sayısal verilerin analiz edilmesinde bazıları ise görsel veya metinsel verilerin analizinde kullanılır [22]. Hazırlanan veri kümesine en uygun model seçimi yapılmalıdır.

**Eğitim:** Problemlerle ilgili toplanan verilerin seçilen uygun model ile eğitildiği aşamadır. Bu aşamada ayrılan eğitim verileri ile model eğitildikten sonra test verileri ile validasyon işlemi gerçekleştirilir. Modelin problemle ilgili öngörü yetisi, bu eğitim aşamasına bağlı olduğu için makine öğrenme aşamasının en kritik noktasıdır.

**Değerlendirme:** Seçilen modelin eğitildikten sonra, test verileri kullanılarak modelin verdiği tepkilerin analiz edildiği aşamadır. Çıkan sonuca göre model ya tekrar eğitim aşamasına dönecek ya da bir sonraki aşamaya geçecektir.

**Parametre Ayarlama:** Elde edilen çıktıların değerlendirilmesinden sonra sonuçların daha tutarlı ve güvenilir bir hale getirilip getirilmeyeceği açısından kontrol edilmesi gereklidir. Bu kontrol de modelin parametrelerinde değişiklikler yapılarak çıkan sonuçların farklılaştırılmasıyla sağlanır. Modelin yeniden eğitilerek daha hassas ve gerçeğe yakın tahminlemeler yapması amaçlanır.

**Tahmin:** Bu aşamada seçilen model, problemle ilgili tahminlerde bulunmaktadır. Bu tahminlerle modelin performans kriterleri (doğruluk, kesinlik, duyarlılık ve F1 skoru) analiz edilmektedir.

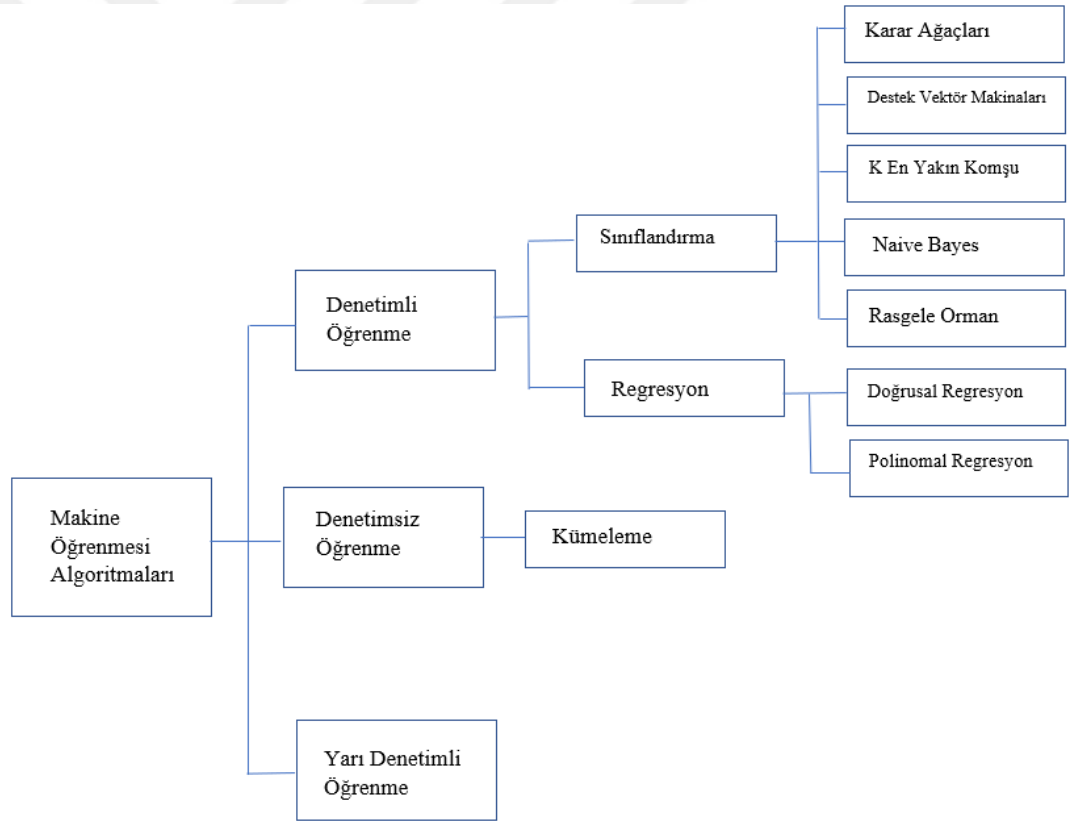


Şekil 3.4. Makine Öğrenmesi Sürecinin Akış Şeması

### 3.2. Makine Öğrenmesinde Kullanılan Algoritmalar

Makine öğrenmesinde kullanılan algoritmalar; büyük veri kümelerindeki ilişkileri ve mantıklı olan bağı bulmak, bu süreçte yaptığı analizler ile en iyi kararları ve tahminleri yapmak için sürekli eğitilmektedir. Makine öğrenmesi uygulamaları, farklı problemler analiz edildikçe gelişmekte ve ne kadar fazla veriye sahip olursa o kadar doğru sonuç üretmektedir.

Makine öğrenmesinin gruplandırması yapılırken modelin karar aşamasında kullandığı algoritmalar ve mantık dizini göz önünde bulundurulmuştur. Makine öğrenmesi algoritmaları literatürde Şekil 3.5.'te denetimli öğrenme, denetimsiz öğrenme ve yarı denetimli öğrenme olmak üzere üç başlık altında incelenmiştir.



Şekil 3.5. Makine Öğrenmesi Algoritmaları

### 3.2.1. Denetimsiz Öğrenme


Denetimsiz öğrenme, denetlenmesine ihtiyaç duymayan bir makine öğrenmesi modelidir [2]. Modeller, bir sistemi ya da düzeni yalnızca tanımlanmış verilere dayalı öğrenmez. Bu noktada denetimsiz öğrenme metotları devreye girmektedir. Denetimli öğrenme modelinde etiketlenmiş ya da tanımlanmış girdi ve çıktı verileri kullanılırken, denetimsiz bir öğrenme algoritması etiketsiz ya da tanımsız verileri tahmin etmek için tek başına çalışır.

Denetimli ve denetimsiz öğrenme modelleri arasındaki temel farklardan biri de algoritmaların öğrenme yöntemidir. Denetimli öğrenme modellerinde verileri kavrama ve analiz etmesi basittir çünkü bunu uygulama ve yapma ortamına sahiptir. Denetimsiz öğrenme yöntemlerinde ise eğitim seti verisi, tanımlanmamış ya da etiketlenmemiş verilerden oluşmaktadır.

Denetimsiz öğrenme, kümeleme ve ilişkilendirme olmak üzere iki bölümden oluşmaktadır.

#### 3.2.1.1. Kümeleme (Clustering)

Kümeleme, veri nesnelерinin bir grubun elemanlarının benzerliğini maksimize etme ve iki farklı gruptaki elemanların benzerliğini minimize etme ilkesine dayalı olarak gruplandırıldığı bir tekniktir. [42]. Bu tarz algoritmalar, veri kümesindeki parametreleri kendi alanındaki benzerliklerden yola çıkarak gruplamaya çalışır. Kümeleme işleminde amaç, verileri yorumlayarak benzerlikleri ortaya çıkarmak ve bu verileri gruplandırarak anlamlı veriler elde edebilmektir. Şekil 3.6.'da yer alan grafikte veri kümelerinin iki ve üç farklı küme olarak gruplandırıldığı görülmektedir.



Şekil 3.6. Kümeleme (Clustering) Örneği [43]

### 3.2.1.2. İlişkilendirme (Association)

Olayların birlikte gerçekleşme durumlarını analiz edip veriler arasında korelasyon kuran bir makine öğrenmesi yöntemidir. İlişki Kural Madenciliği (Association Rules Analysis, ARM), çok sayıda veri nesnesi arasındaki ilişkileri tanımlamak için kullanılmaktadır [44].

Günümüzdeki yaşanan teknolojik gelişmeler, bu algoritmanın da kullanım alanlarını oldukça etkilemiştir. Pazar sepeti analizi (Market Basket Analysis), ARM'nin tipik bir örneğidir. Bu yöntem, tüketicilerin sepetlerine koydukları çeşitli ürünler arasındaki korelasyonlarını analiz ederek tüketici satın alma alışkanlıklarını ortaya koyar [44]. Bu tür analiz ve tespit yöntemleri ile pazarlama şirketleri, tüketicilerin en çok satın aldığı ürün portföylerini belirleyerek iletişim ve satış kampanyalarını genişletme imkânı bulabilmektedir.


Bu tez çalışmasında, aşağıda detaylı bir şekilde anlatılan denetimli öğrenme algoritmaları kullanılmıştır.

### 3.2.2. Denetimli Öğrenme

Denetimli öğrenme; sisteme eğitim veri seti ve test veri setinin yüklenmesi, her bir veri için gerekli etiketlenmenin yapılması ve böylece girdi ile çıktı verileri arasında ilişki kurulması temeline dayanır [25]. Bu tarz öğrenme metodunda, tahminleme yapılabilmesi için sınıflandırma ve regresyon teknikleri kullanılmaktadır. Bu algorithmada en kritik nokta etiketli veri kümesinin kullanılmasıdır. Bu veriler, sisteme daha önce tüm özellikleri ve örüntüleri ile tanımlanmış spesifik datalardır.

Algoritma; etiketlenmiş, tanımlı eğitim verileri üzerinden girdi datalarını bir çıktı verisi ile ilişkilendirmek için arka planda fonksiyonlar bulmaya çalışır. Burada amaç, algoritmanın girdi ile çıktı arasında en iyi korelasyonu sağlayarak en iyi tahmini gerçekleştirmektir.

Denetimli öğrenme, genellikle sınıflandırma ve regresyon kökenli problemlere uygulanmaktadır. Buradaki temel fark; regresyon sıcaklık, nem, yaş, titreşim gibi kendini tekrar eden sürekli değerleri tahmin etmek için kullanılırken; sınıflandırmanın ise doğru veya yanlış, iyi ya da kötü, uygun ya da uygun değil gibi birbirinden bağımsız ayırık değerleri tahmin etmek için kullanılmasıdır. Şekil 3.7.'de sınıflandırma ve regresyon tasvirlerine ait örnek grafikler görülmektedir.



Şekil 3.7. Sınıflandırma ve Regresyon Grafikleri [26]

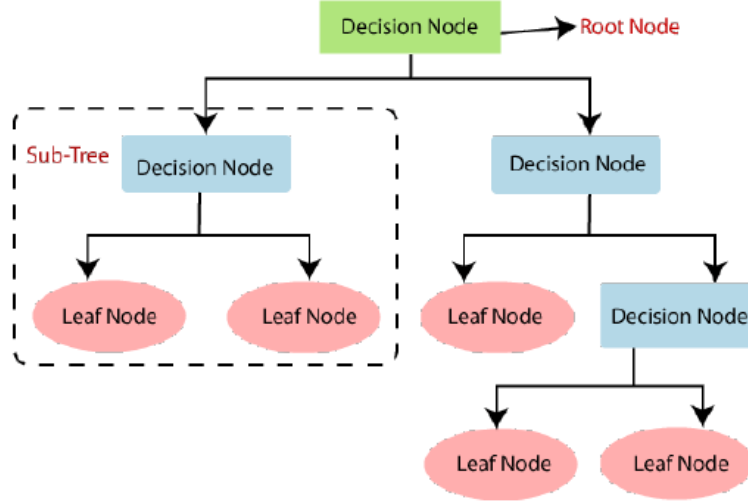
### 3.2.2.1. Sınıflandırma

Bir makine öğreniminde, bir veri kümesini farklı parametrelere bağlı olarak sınıflara ayırmayı amaçlayan bir algoritmadır. Endüstriyel uygulamalarda genellikle doğru/yanlış, uygun/uygun değil ya da herhangi bir ekipmanın arızalı ya da değil olarak sınıflandırılması yaygın olarak kullanılmaktadır. Sınıflandırma yöntemlerinde genellikle karar ağaçları, k-en yakın komşu, Naive Bayes, destek vektör makinesi ve rastgele orman algoritmaları tercih edilmektedir.

#### 3.2.2.1.1. Karar Ağaçları Algoritması

Karar ağaçları algoritması (DT), veri madenciliğinde uygulamasının ve anlaşılmasının kolay olması sebebiyle literatürde yaygın olarak kullanılan bir sınıflandırma algoritmasıdır [27]. Hem regresyon hem de sınıflandırma problemlerini çözmek için kullanılan en popüler denetimli makine öğrenme yöntemlerinden biridir.

Ağaç yapısı en üstten başlayarak kök, dal ve yapraklar olarak adlandırılmaktadır. Her dal üstteki köke bağlı olmak şartıyla dallar düğümlere bağlanır. Veride bulunan her bir öznelik, sınıflandırma sonrasında ağaçta bir düğüm noktasını temsil etmektedir [28]. Girdi verisinin bir gruplandırma algoritması aracılığıyla adım adım gruplara bölünmesine dayanır. Gruptaki tüm elemanlar aynı sınıf etiketine sahip olana dek gruplandırma işlemi devam eder. Literatürde en yaygın kullanılan karar ağacı algoritmaları ID3, C4.5, CHAID, CART algoritmalarıdır [27]. Şekil 3.8.'de karar ağacı algoritmasına ait bir akış diyagramı görülmektedir.




Şekil 3.8. Karar Ağacı Algoritma Yapısı [29]

### 3.2.2.1.2. En Yakın Komşu Algoritması

K-en yakın komşu (KNN), hem sınıflandırma hem de regresyon problemlerini çözmek için yaygın olarak kullanılan basit ama etkili bir algoritmadır. Temel çalışma prensibi sınıflandırılmamış örneklemin, en yakın komşularının bulunmasına ve benzer sınıflara göre tahminlerde bulunmasına dayanmaktadır.

Algoritma, mevcut tüm verileri analiz ettikten sonra yeni bir veri noktası için bu veri kümesindeki uzaklık açısından kendisine en yakın K veri noktasını bularak çalışma yapar. En yakın komşuları bulmak için veri setini tek tek taramak algoritmanın performansını düşürdüğü için tembel öğrenme yöntemi olarak da adlandırılır [27]. Bu nedenden dolayı KNN algoritması, büyük kapasiteli verilerde (big data) yavaş bir çalışma prosesine sahiptir.

KNN algoritması, belirli bir sınıfa atanmamış bir veriyi önceden sınıflandırılmış verilerden herhangi birisine olan uzaklığını referans alarak atama işlemini gerçekleştirir. Şekil 3.9.'da henüz sınıflandırılmamış bir veri noktası olan P, belirlenen k komşuluk değerine göre veri noktasından minimum uzaklığa göre bir sınıfa dahil edilmiştir [30].



Şekil 3.9. K En Yakın Komşu Sınıflandırma Örneği [27]

KNN algoritmasında, veri setindeki sınıfları belli olan veri kümelerinden yola çıkılarak tahmini yapılacak yeni verilerin mevcut verilere göre uzaklığı hesaplanır ve k sayıdaki komşuluklarına bakılır [27]. Sınıflandırılacak noktaya en yakın sınıf ve komşu noktaların mesafeleri bazı metotlar kullanılarak hesaplanır. Bu metotlara Öklid, Manhattan ve Minkowski yöntemleri örnek gösterilebilir. Öklid mesafesi Denklem 3.1’de verilmiştir [31].

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

(3.1)

Burada  $x_i$  ve  $y_i$  kartezyen koordinatlarındaki noktaları gösterirken  $n$  Öklid uzayını göstermektedir.

Diğer bir hesaplama yöntemi ise Manhattan mesafesidir. Bu, iki nokta arasındaki mesafeyi hesaplamanın en basit yöntemidir. Genellikle taksi mesafesi ya da şehir bloku mesafesi olarak da adlandırılmaktadır. Matematiksel bir deyişle, iki nokta arasındaki mutlak farkı hesaplar. Manhattan mesafesi Denklem 3.2’de verilmiştir [46].

$$d_{ij} = \sum_{k=1}^n |x_{ik} - y_{jk}|$$

(3.2)

Bu formülde;  $d$ ,  $i$  ile  $j$  arasındaki uzaklığı,  $i$  küme veri merkezini,  $j$  öznitelikteki veriyi,  $k$  her bir verinin simgesini,  $n$  veri miktarını,  $x_{ik}$   $k$ 'ye kadar olan küme merkezindeki veriyi ve  $y_{jk}$   $k$ 'ye kadar olan her bir veriyi temsil eder [46].

Minkowski mesafesi,  $p$  parametresi tarafından oluşturulan çeşitli uzaklık fonksiyonlarının bir sınıfıdır [47]. Hem Öklid hem de Manhattan mesafelerini içeren bir fonksiyondur. Minkowski mesafesi Denklem 3.3'te verilmiştir.

$$d_{MD} = \left( \sum_{i=1}^k (|x_i - y_i|)^p \right)^{1/p} \quad (3.3)$$

Bu formülde  $p$  değeri değiştirilerek farklı mesafe fonksiyonları belirlenebilir. Örneğin  $p=1$  durumunda Manhattan mesafesi,  $p=2$  durumunda ise Öklid mesafesi elde edilebilmektedir.

KNN algoritması, diğer denetimli metotlardan farklı olarak eğitim setine sahip değildir. Bu nedenle eğitim ve test verileri hemen hemen aynı kümedir. Eğitim ve test verilerinin aynı olmasından dolayı büyük veri kümelerinin analizi ve işlenmesinde genellikle tercih edilmemektedir.

### 3.2.2.1.3. Naive Bayes Algoritması

Adını ünlü matematikçi Thomas Bayes'den alan bir sınıflandırma algoritmasıdır. Bayes sınıflandırması, güçlü ve bağımsız varsayımıyla Bayes teoremine dayanan basit ve olasılık temelli bir tahmin yöntemidir [32]. NB sınıflandırması, olasılık prensibine göre tanımlı hesaplamalar ile sisteme girdi olarak iletilen verilerin sınıfını tespit etmeyi amaçlar. Bu sınıflandırıcı, Bayes teoremi temelinde çalışır ve her öznitelik için sınıf olasılıklarını hesaplar ve bu olasılıkları kullanarak en yüksek olasılığa sahip sınıfı tahmin eder [33]. Olasılığa dayalı bir sınıflandırma yaptığı için tembel bir öğrenme metodudur. Naive Bayes teoremi Denklem 3.4'te verilmiştir [34].

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3.4)$$

$P(A|B)$  = B olayı gerçekleştiğinde A olayının gerçekleşme olasılığı

$P(A)$  = A olayının gerçekleşme olasılığı

$P(B|A)$  = A olayı gerçekleştiğinde B olayının gerçekleşme olasılığı


$P(B)$  = B olayının gerçekleşme olasılığı

İstatistik ve bilgisayar bilimi çalışmalarında NB modelleri, Simple Bayes ve Independent Bayes dahil olmak üzere farklı isimler altında bilinir ve bütün bu isimler, sınıflandırıcının karar kuralında Bayes teoreminin kullanımına atıfta bulunmaktadır [27].

#### **3.2.2.1.4. Destek Vektör Makinesi Algoritması**

Destek vektör makinesi (SVM) algoritması, verilerin sınıflandırma problemlerini çözmek için kullanılmaktadır. Problem çözümü sürecinde bu algoritma, karar sınırı (decision boundary) olarak tanımlanan bir hiper düzlem oluşturur ve düzlemin her iki tarafındaki iki veri sınıfını ayırır. Destek vektör makinesi, destek vektörleri olarak adlandırılan uç vektörleri seçerek bunların hiper düzlemi oluşturmasına katkıda bulunur.

İki sınıfı en iyi ayıran doğrunun bölgeler arasında kaldığı alana marjin (margin) denir [24]. SVM'nin temel amacı, hiper düzlem ile kendisine en yakın destek vektörler arasındaki mesafeyi yani marjin bölgesini maksimize etmektir [24]. Marjin ne kadar geniş olursa SVM algoritması iki veri sınıfını o kadar doğru ve net ayırmaktadır.



**Şekil 3.10.** İki Veri Sınıfının Destek Vektörleri ile Ayrılması [35]

Şekil 3.10.'da görüldüğü üzere her iki veri kümesine de destek vektörleri çizilmiştir. Bu destek vektörlerini referans alarak SVM algoritması, en optimum doğruyu ( $w \cdot x + b = 0$ ) çizer. SVM algoritmasında sınıflar +1 veya -1 olarak belirlenir. Bundan dolayı karar doğrusu (hiper düzlem) üstünde kalan doğruya  $wx + b = 1$ , altında kalan doğruya  $wx + b = -1$  olarak yazılır [35].

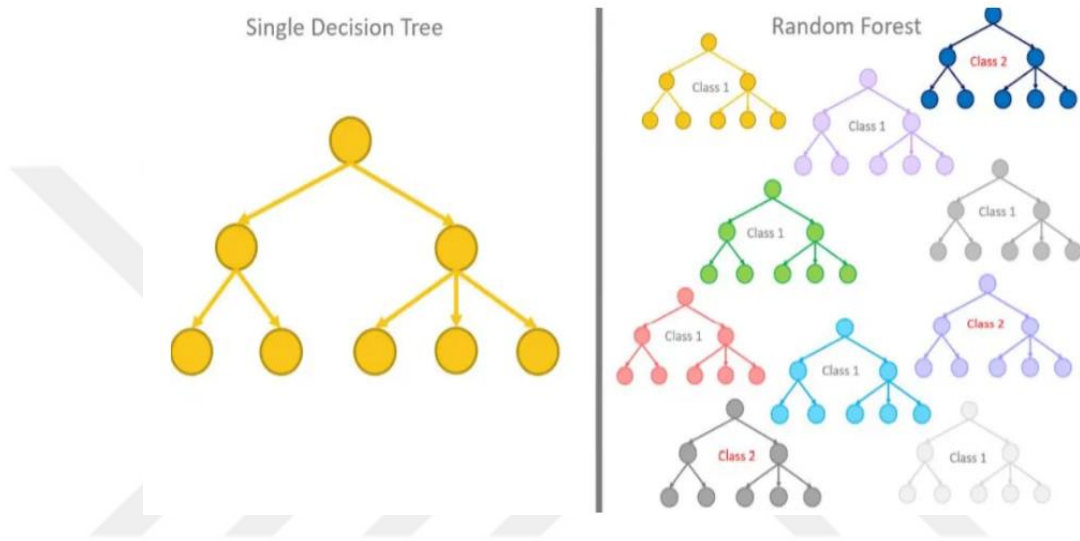
SVM algoritması, NB algoritmasına göre daha hızlı tahmin yapar ve daha yüksek doğruluk oranı sunabilmektedir. Yüksek doğruluk oranı sağlamanın yanı sıra yüksek boyutlu verilerde gösterdiği iyi performans ile avantaj sağlarken eğitim süresinin çok yüksek değerlere ulaşması dezavantaj olarak görülebilmektedir [36].

### 3.2.2.1.5. Rastgele Orman Algoritması

Rastgele orman (RF), eğitim aşamasında çok sayıda karar ağacı oluşturarak çalışan, sınıflandırma, regresyon ve diğer görevler için bir topluluk öğrenme yöntemidir [27]. Bu algoritma, basitliği ve kullanılabilirliği nedeniyle hem sınıflandırma hem de regresyon için en yaygın kullanılan makine öğrenimi algoritmalarından biridir [3].

RF algoritması pek çok özelliğe sahip verilerde tahmine dayalı modeller için başarılı sonuçlar veren bir denetimli öğrenme algoritmasıdır [38]. Bu algoritmada,

karar ağaçları rastgele seçilen veriler üzerinde oluşturulur ve her ağaçtan tahmin alınır [38]. Algoritma içerisinde kullanılan ağaç sayısı arttıkça doğruluğa yaklaşım oranı da artmaktadır. Karar ağaçları ile arasındaki ana fark, RF algoritmasında kök düğümü bulma ve düğümleri ayırma işlemlerinin rastgele olmasıdır. Ayrıca birden fazla karar ağacı yapısını da kullandığı için basit bir karar ağacından daha doğru tahminler üretebilmektedir.



Şekil 3.11. DT ve RF Karşılaştırma Şeması [38]

RF algoritmasında tek bir ağaçtan ziyade birden fazla ağaç yetiştirilerek süreç yürütülmektedir. RF modelinde orman oluşturma ve karar verme aşaması olmak üzere iki aşama vardır [39]. Bu model, DT ile elde ettiği çıktıları birleştirerek sonuca ulaşır. RF algoritması genellikle DT algoritmalarından daha iyi sonuçlar üretmesine rağmen, performans çıktıları eğitim veri setinde kullanılan etiketli veri miktarına bağlıdır [39]. RF algoritması, yüksek skorlu performans elde etmek için büyük ölçüde etiketlenmiş veri ihtiyacı duyar.

### 3.2.2.1.6. Extreme Gradient Boosting (XGBoost) Algoritması

Gradient Boosting çerçevesinin gelişmiş bir uygulamasını sunan bu algoritma, hesaplama verimliliği ve denetimli öğrenme sürecinde daha büyük bir model esnekliği sağlamak üzere tasarlanmıştır [40]. Bu algoritma, 2016 yılında Tianqi Chen ve Carlos Guestrin'in yayınladıkları makale ile ilk kez ortaya çıkmıştır. DT tabanlı bir algoritma olan XGBoost; yüksek tahmin gücüne ulaşabilmesi, aşırı öğrenmeye gereksinim duymaması, boş verileri dahi yönetebilmesi ve tüm bunları hızlı bir şekilde yapabilmesi ile diğer algoritmalarından ayrılmaktadır. Şekil 3.12.'de karar ağacı algoritmalarının zaman içinde XGBoost algoritmasına dönüşümü görülmektedir. XGBoost'un geliştirilmesi, veri bilimciler tarafından halen devam etmektedir ve Github'ta 500'den fazla katılımcısı, 5400'den fazla kod eklemesi bulunmaktadır [41].

XGBoost, veri kümesindeki her bir değişkene göre kazanç skorunu en yüksek yapacak şekilde olası tüm senaryolarda karar ağaçları kurar. XGBoost, ağacı oluştururken maksimum derinlik değerini kullanır. Oluşturulan ağaç aşağı yönde aşırı ilerleme gösterirse, budama gerçekleştirilir. Bu budama ile aşırı öğrenmenin (overfitting) önüne geçilir [41]. XGBoost algoritması, veride yer alan her değeri analiz etmek yerine veriyi parçalara bölerek çalışmaktadır. Böylece parça miktarı arttırıldıkça algoritma daha küçük aralıklara bakacağı için daha iyi tahminleme skorlarına sahip olabilmektedir.



Şekil 3.12. Karar Ağacı Algoritmalarının XGBoost'a Evrimi [41]

### 3.2.2.2. Regresyon

Regresyon algoritmaları, bir sistemdeki girdi verileri ile çıktı verileri arasındaki korelasyonu modelleyen istatistiksel bir yaklaşımdır. Regresyon analizinde bu korelasyonu tahmin etmek için istatistiğin birçok yöntemi kullanılmaktadır. En yaygın kullanılan regresyon yöntemleri; doğrusal regresyon, lojistik regresyon, kademeli regresyon ve sinir ağları şeklinde ifade edilebilir.

### 3.3. Makine Öğrenmesi Değerlendirme Ölçütleri

Literatür çalışmalarında kullanılan çeşitli makine öğrenmesi algoritmaları tarafından elde edilen sonuçların kalitesi, bazı kriterler baz alınarak değerlendirilmektedir. Sıkça kullanılan bu kriterler; doğruluk, kesinlik, duyarlılık ve F1-skor başlıkları altında incelenmektedir. Değerlendirme kriterleri, kullanılan makine öğrenmesi algoritmasının performansını özetleyen karışıklık matrisi olarak adlandırılan tablo ile ele alınmaktadır.

Karışıklık matrisi, sınıflandırma yapan uygulamalarda, gerçek ve tahmin edilen değerleri bir tablo üzerinden kolayca kıyaslayabilmek için kullanılmaktadır [41]. Tablo 3.1.'de bir karışıklık matrisi örneği görülmektedir.

**Tablo 3.1.** Karışıklık Matrisi (Confusion Matrix, CM) Örneği

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

- Gerçek Pozitif (TP): Gerçekte de doğru olan, doğru olarak tahmin edilen değerler,
- Gerçek Negatif (TN): Gerçekte yanlış olan, yanlış olarak tahmin edilen değerler,
- Yanlış Pozitif (FP): Gerçekte yanlış olan, doğru olarak tahmin edilen değerler,

- Yanlış Negatif (FN): Gerçekte doğru olan ama yanlış olarak tahmin edilen değerleri ifade etmektedir.

### 3.3.1. Doğruluk (Accuracy)

Sistemin doğru tahmin ettiği değerlerin tüm değerlere bölünmesiyle elde edilen katsayıdır ve Denklem 3.5'te gösterildiği gibi hesaplanmaktadır. Bu katsayı, 0 ile 1 arasında olup değer 1'e yaklaştıkça sistemin de başarısı artmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.5)$$

### 3.3.2. Duyarlılık (Recall)

Algoritmanın doğru olarak tahmin etmesi gereken değerlerin kaç tanesini doğru tahmin ettiğini belirten katsayıdır. Duyarlılık değeri, gerçekte doğru olan ve doğru olarak tahmin edilen değerlerin, tüm doğru değerlere bölünmesi ile elde edilmektedir [41]. Duyarlılık formülü, Denklem 3.6'da yer almaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.6)$$

### 3.3.3. Kesinlik (Precision)

Doğru olarak tahmin edilen değerlerin, gerçekte kaç tanesinin doğru olduğunu gösteren ifadedir. Kesinlik değeri, gerçekte doğru olan ve doğru olarak tahmin edilen değerlerin, doğru olarak tahmin edilen tüm değerlere bölünmesi ile elde edilmektedir [41]. Denklem 3.7'de kesinlik formülü görülmektedir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.7)$$

### 3.3.4. F1 Skoru (F1 Score)

F1 skoru, duyarlılık ve kesinlik değerlerinin harmonik ortalaması ile elde edilen bir katsayıdır. Eşit dağılıma sahip olmayan veri setlerinde başarılı sonuçlar elde

etmek için kullanılmaktadır [41]. F1 değeri, Denklem 3.8’de görülen formül ile hesaplanmaktadır.

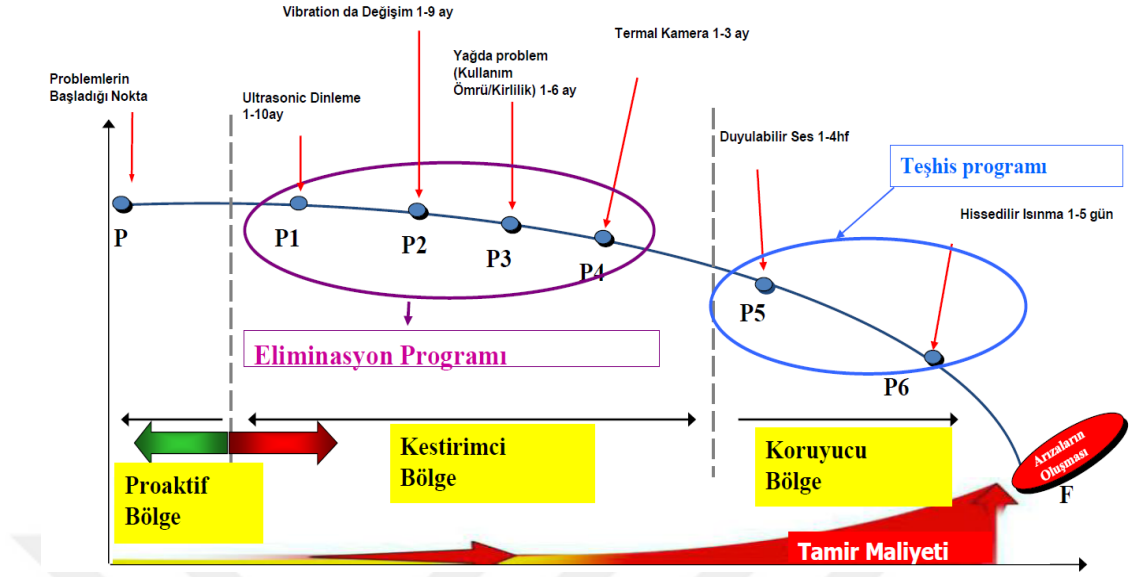
$$F1 \text{ Skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarluluk}}{\text{Kesinlik} + \text{Duyarluluk}} \quad (3.8)$$

#### 4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Sanayi tesislerinde üretim hatlarının sürdürülebilirliği için birçok bakım uygulanmaktadır. Bakım, üretim tesisini belirli koşullar içinde tutmak ve tesiste bulunan ekipmanların verimliliğini optimum düzeyde sürdürülmesini sağlamak için yapılan teknik faaliyetlerdir. Bakım yaklaşımları planlı ve plansız bakım olmak üzere iki başlık altında incelenmektedir. Planlı bakımlarda önleyici (proaktif) ve kestirimci (uyarıcı) metotlar kullanılarak arıza meydana gelmeden önce çalışmalar yapılırken, plansız bakımlarda fırsat ve arıza bakımları yaklaşımla arıza meydana geldikten sonra müdahale gerektiren çalışmalar yapılmaktadır.

Endüstrideki teknolojik gelişmelerle birlikte tesis, yedek parça ve işgücü maliyetlerindeki artışlar, üretim tesislerinde yer alan ekipmanların verimliliğini maksimum düzeyde tutma amacıyla yürütülen bakım politikalarının önemini artırmaktadır. Bakım politikalarının sürekliliği, yüksek üretim kalitesi ve üretim artışının sağlanması amacıyla önem arz etmektedir.

Üretimin devamlılığı, duruş ve bakım onarım maliyetleri göz önünde bulundurulduğunda önleyici bakım metotlarından biri olan kestirimci bakım faaliyetleri, işletmelerde genel ekipman etkinliğinin (OEE) maksimum seviyeye ulaştırabilme sürecinde oldukça önem gösterilen ve ilgi gören bir konuma gelmiştir. Kestirimci bakım, arıza gerçekleşmeden önce analiz ve ölçümler yaparak arızanın gerçekleşme ihtimalini ortaya çıkaran tahminlemeye dayanan bir bakım yöntemidir. Kestirimci bakım faaliyetleri ile ekipman arızalarında %45’e, bakım faaliyetlerinde %30’a kadar azalma sağlanırken, üretimdeki artış %25’leri bulmuştur. Ölçüm ve analizler aracılığıyla yapılan tahminleme çalışmalarında yapay zekâ yöntemlerinin bir alt dalı olan makine öğrenmesi algoritmaları en çok kullanılan yöntemlerden biri olmuştur.



Şekil 4.1. Bir Problemin Arızaya Dönüşüm Süreci [45]

Şekil 4.1.'de yatay eksen zamanı, dikey eksen ise arızanın oluşmasına karşı ekipmanın gösterdiği direnci ifade etmektedir. Grafikte görüldüğü üzere bir ekipmanda meydana gelen herhangi bir problem, kestirimci bölge kısmında ölçüm ve analizlerle arızaya dönüşmeden tespit edilebilirken, koruyucu bölge kısmında ise fiziki temas ya da duyu hissi ile fark edilerek anlık müdahale sonucu arıza oluşumu önlenmektedir.

Makine öğrenmesi genellikle denetimli, denetimsiz, pekiştirmeli ve yarı denetimli öğrenme olmak üzere dört başlık altında incelenmektedir. Makine öğrenmesine dayalı endüstriyel bakım uygulamaları, çoğunlukla olası arızaların kök

sebeap analizi ve üretim tesisindeki ekipmanların kalan faydalı ömür (RUL) tahminlerinde kullanılmaktadır.



**Şekil 4.2.** Jelly Nişasta Transfer Helezon Sistemi

Bu çalışma, gıda sektöründe yer alan bir firmanın bir yumuşak şeker (jelly) üretim hattında yapılmıştır. Yumuşak şeker hattında, nişastanın tepsi içinde baskı noktasına ulaşması oldukça önemlidir. Çünkü akışkan jelly karışımını bir arada tutacak olan tepsi içindeki uygun sıcaklık ve nem oranlarına sahip nişastanın varlığıdır. Nişasta, bağlayıcı özelliği ile bu karışımı bir arada tutma görevine sahiptir. Sıcak ve soğuk vorteks olarak adlandırılan şartlandırıcı sistemler, nişastanın belirli bir nem ve sıcaklık değerine getirildiği ünitelerdir. Bu ünitelerden kalıp baskı noktasına nişasta transfer işlemi, yatay ve dikey pozisyonda konumlandırılmış birçok konveyörlü helezon aracılığıyla yapılmaktadır. Bu transfer sistemine ait bir kesit Şekil 4.2.'de görülmektedir. Bu çalışmada helezonlardan birinin redüktör ve motor gövdesine yerleştirilen sensörler ve çalışma ortamına konulan datalogger (sıcaklık ve nem ölçer) üzerinden alınan veriler ile uzun duruşlara sebep olabilecek olası büyük arızaları tahmin etmek amaçlanmıştır.

Çalışmanın yapıldığı firma, Akhisar OSB'de yer alan, gıda sektöründe faaliyet gösteren ve Türkiye'nin en büyük yumuşak şeker üreticisi unvanına sahip, dünyada ise en çok çeşit üreten bir firmadır. 1998 yılında İstanbul'da faaliyet göstermeye başlayan firma, günümüzde üç ülkedeki üretim tesisi ve sekiz fabrikasıyla birlikte

yaklaşık 85 ülkeye ihracat gerçekleştirmektedir. Tüm tesislerinde ve satış şirketlerinde yaklaşık 3.500 kişiyi istihdam eden Kervan Gıda, Dünya'nın en iyi 100 şekerleme şirketi arasında kendi kategorisinde 6'ncı sırada yer almaktadır. Ölçüm ve analiz çalışmasının yapıldığı üretim sahası Şekil 4.3.'te görülmektedir.



Şekil 4.3. Çalışmanın Yapıldığı İşletme Sahası

#### 4.1. Titreşim Değerleri Tablosu ve Analizi

İşletmelerde yer alan motor, pompa ya da fan gibi ekipmanlar, arızaya girmeden önce belli uyarılar vererek anomali durumunu önceden bildirir. Bu uyarılar, genellikle gövde sıcaklığının artması, titreşim frekansının yükselmesi ya da ortama verdiği vibrasyon kaynaklı gürültü şeklinde karşımıza çıkmaktadır. Fan veya motor gibi ekipmanlarda titreşim parametresinin ölçüm ve analizi büyük arızaların tespitinde oldukça önemli bir yere sahiptir.

**Tablo 4.1.** Titreşim Şiddeti Değerlendirme Tablosu [4]

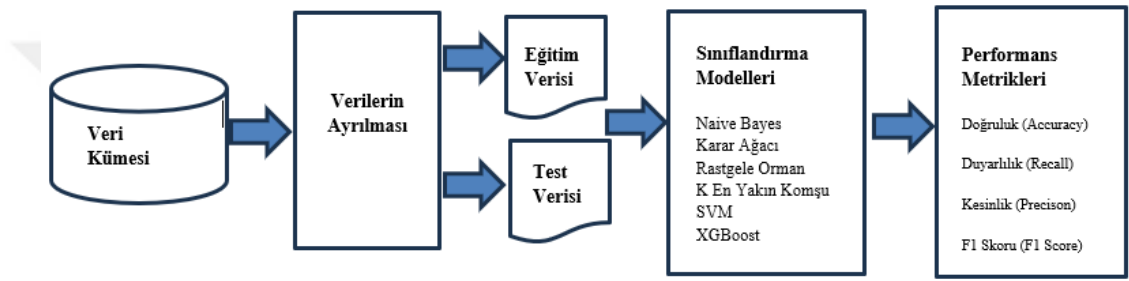
TİTREŞİM ŞİDDETİ DEĞERLENDİRME TABLOSU ISO 10816						
	MAKİNE		Sınıf I Küçük Makineler	Sınıf II Orta Makineler	Sınıf III Büyük Makineler	Sınıf IV Büyük Makineler
	in/s	mm/s				
Titreşim Hızı $V_{rms}$	0,01	0,28				
	0,02	0,45				
	0,03	0,71		<b>ÇOK İYİ</b>		
	0,04	1,12				
	0,07	1,8				
	0,11	2,8		<b>İYİ</b>		
	0,18	4,5				
	0,28	7,1		<b>DİKKAT</b>		
	0,44	11,2				
	0,7	18				
	0,71	28		<b>KABUL EDİLEMEZ</b>		
	1,1	45				

Tablo 4.1.'de görülen titreşim şiddeti değerlendirme tablosunda ekipmanlar güç değerlerine göre sınıflandırılmış ve titreşim değerleri derecelendirilerek uygun aralıklar belirlenmiştir. Sınıf 1 küçük makineler, gücü 15 kW'ın (20 HP) altında olan makinelerdir. Sınıf 2, 15 kW'tan 75 kW'a (20 HP-100 HP) kadar olan orta ölçekli motorlar ile 300 kW'a (400 HP) kadar rijit olarak monte edilmiş özel plakalı makineleri kapsamaktadır. Sınıf 3, ağır tahrik motorları ve özel plaka üzerine monte edilen döner kütleli makinelerdir. Sınıf 4 ise gücü 10 MW'dan daha büyük olan turbo jeneratör motorları ve gaz türbinlerini temsil etmektedir.

Yapılan ölçüm ve analiz çalışmalarında ele alınan motorun (1.1 kW) Sınıf 1'e ait olduğu görülmektedir. Ayrıca ölçülen titreşim değerleri tabloda belirtilen sınır değerleri ile karşılaştırılarak analiz edilmiştir. İlgili üretim hattının yaklaşık on yıldır 7/24 sürekli çalıştığı göz önünde bulundurulduğunda elde edilen verilerin analizinin ne kadar önemli olduğu ortaya çıkmaktadır.

## 4.2. Veri Seti

Bu çalışmada yumuşak şeker üretim hattında bulunan nişasta transfer sistemindeki helezon motoru için önceden oluşabilecek arızaların analizi yapılmıştır. Çalışma, helezonun tahrik grubuna yerleştirilen sıcaklık ve vibrasyon sensöründen ve çalışma ortamının sıcaklık ile nem değerlerini ölçen datalogger cihazından alınan veriler ile yapılmıştır. Ölçümler ile elde edilen 3124 veri, arıza tahminleme çalışmaları kapsamında bazı algoritmalar ile ele alınmıştır. Çalışmanın akış şeması Şekil 4.4.'te görülmektedir.



Şekil 4.4. Çalışmanın Blok Diyagramı

Sensörler ve datalogger aracılığıyla ölçümleri yapılan motor gövde sıcaklığı, motor titreşim, redüktör gövde sıcaklığı, redüktör titreşim, ortam sıcaklık ve ortam nem değeri olmak üzere altı adet girdi parametreleri gerçek zamanda oluşan arızaların üretim hattı üzerindeki etkisi göz önünde bulundurularak dört sınıfa ayrılmıştır. Bu dört sınıfın açıklaması Tablo 4.2.'de görülmektedir. Verilerin sınıflandırılmasında, gerçekleşen arızanın sebep olduğu onarım ve duruş süreleri etkin bir rol oynamaktadır. Tabloda sınıflandırması belirtilen bu veriler, işletme sahasında bulunan aynı motor ve redüktör grubundan elde edilmiştir. Duruş süreleri, işletmede daha önce yaşanan arızaların üretime olan etkisi göz önünde bulundurularak belirlenmiştir.

Tablo 4.2. Modelde Kullanılan Sınıfların Tanımlamaları

Class 0	Arıza yok. Her şey normal.
Class 1	Kısa duruş var. (0-15 dakika)
Class 2	Uzun duruş yakında. (15-45 dakika)
Class 3	Uzun duruş var. (45 dakika ve üzeri)

Ölçümlerle elde edilen veri setine ait bir kesit Tablo 4.3.'te görülmektedir. Veri kümesinde yer alan özneliklere ait açıklamalar Tablo 4.4.'te yer almaktadır.

**Tablo 4.3.** Çalışmada Kullanılan Veri Kümesinin Bir Bölümü

id	NID Vortex Sic (°C)	NID Vortex Nem (%rH)	MSic (°C)	RedSic (°C)	MVib (mm/sn)	RedVib (mm/sn)	Status
1	30,1	38,3	38,3	23,9	0,06	0,15	0
2	30,1	38,6	40,2	33	0,02	0,01	0
3	29,9	40,8	33,9	31	0,03	0,02	0
4	29,8	40,3	36,1	30	0,9	0,04	0
5	29,8	40,8	42,1	43,8	0,05	0,04	0
6	29	37,9	41,1	44,3	0,2	0,05	0
7	29,2	39	39,4	43,2	0,3	0,06	0
8	29	39,9	48,1	46,4	0,11	0,02	0
9	28,5	37,2	42,3	53	0,07	0,03	0
10	28,4	38	46,3	55,2	0,04	0,02	0
11	28,5	39,9	42,5	58,7	0,5	0,06	0
12	28,6	39,5	45,2	56,1	0,04	0,01	0
13	28,7	39,3	43,7	47,8	0,07	0,02	0
14	28,5	39,4	46,4	51,6	0,02	0,02	0
15	28,7	39	50,2	54,5	0,8	0,08	0
16	29	40,7	41,2	55,1	0,6	0,05	0
17	29,2	41	41,4	39,7	0,14	0,09	0
18	29	39,8	40,3	40,6	0,05	0,04	0
19	29,2	40	39,5	40,2	0,7	0,05	0
20	29,3	38,5	42,6	41,3	0,9	0,1	0
21	32	40,5	39,9	40,5	0,8	0,3	0
22	32,2	34,5	35,6	39,3	0,95	0,04	0
23	29,7	36,7	39,5	48,2	0,92	0,03	0
24	29,2	37	45,7	57,4	0,09	0,02	0
25	29,1	36,3	43,1	59,8	0,1	0,07	0

274	30,4	36,7	46,9	56,7	2,18	1,54	1
275	29,1	37,1	41,4	51,7	2,24	1,62	1
276	28,7	35,9	53,4	65,4	2,38	1,79	1
277	28,9	34,9	43,3	52,6	2,31	1,75	1
278	31,3	32,1	43,4	52,3	2,53	1,92	1
279	30,3	33,1	40,7	54,7	2,86	2,01	1
280	30,5	31,4	40,8	62,9	3,44	3,12	2
281	28,7	35,2	49,7	55,1	3,33	2,91	2
282	28,4	35,6	50,3	52,1	3,65	3,13	2
283	30,8	34,8	44,9	63,4	4,61	3,42	2
284	32	28,2	54,1	46,8	5,05	2,96	2
285	30,8	29	53,9	54,5	2,18	1,74	1
286	30,1	30,4	53,8	54	2,45	1,89	1

287	29,6	32,5	57,7	59,3	2,34	1,66	1
288	29,9	32,8	59,8	56,4	2,24	1,56	1
289	30	33,3	64,2	73,1	5,64	2,64	2
290	30,3	32,5	55,3	63,7	4,86	2,73	2
291	30,6	31,9	48,5	54,7	4,54	2,54	2
292	32,4	30,1	50,3	57,2	4,49	2,49	2
293	31,6	33	46,2	64,9	4,77	2,65	2
294	32,1	30,4	52,5	61,4	5,24	2,75	2
295	34,9	27,9	59,2	56,5	2,05	1,86	1
296	33,7	28,8	55,6	62,1	1,87	2,14	1
297	31,5	30,1	61,4	59,8	1,83	1,77	1
298	30,9	30,3	57,8	58,3	1,76	1,64	1

3109	30,9	34,9	57,7	66,1	3,57	2,54	2
3110	33,7	33,4	54,9	54,8	3,64	2,71	2
3111	35,3	30,6	50,2	49,1	3,72	2,82	2
3112	32,7	32,5	48,4	49,3	3,81	2,91	2
3113	32,6	33,3	43,4	42,5	4,24	3,26	2
3114	34	31,9	51,6	51,7	4,97	3,75	3
3115	35,9	30,2	50,1	48,1	5,03	3,88	3
3116	33,9	32	52,4	51	2,54	2,03	1
3117	33,4	31,7	51,9	53,7	3,63	2,66	2
3118	33,3	30,6	53,7	52,9	3,93	2,81	2
3119	37	28,6	57,1	58,2	3,54	2,78	2
3120	41,7	24,3	58,3	56,2	4,22	2,54	2
3121	42,8	22,9	53,7	52,1	4,29	2,79	2
3122	35,9	27,1	61,4	60,6	4,21	2,72	2
3123	34,2	29	51,9	54,6	2,48	1,66	1
3124	33,9	28,8	49,9	50,1	2,35	1,75	1

**Tablo 4.4. Öznitelik Başlıklarının Tanımlamaları**

<b>Öznitelik Başlığı</b>	<b>Tanımı</b>
NID Vortex Sic (°C)	Vorteks bölgesi çalışma ortam sıcaklığı
NID Vortex Nem(%rH)	Vorteks bölgesi çalışma ortam nemi
MSic (°C)	Motor gövde sıcaklığı
MVib (mm/sn)	Motor gövde titreşim değeri
RedSic (°C)	Redüktör (şanzıman) gövde sıcaklığı
RedVib (mm/sn)	Redüktör (şanzıman) gövde titreşim değeri

### 4.3. Gereç ve Yöntemler

Niřasta transfer sisteminde bulunan helezon motor ve řanzımanın (redüktör) sıcaklık ve vibrasyon bilgileri, řekil 4.5.'te verilen Advantech markasına ait üç eksenli ivmeölçer ve sıcaklık sensörü (WISE-2410) ile alınmıřtır.

Advantech smart sensörün özellikleri řu řekilde sıralanabilir.

- -20 ila 80 °C arasında çalışabilirlik
- VRMS, Kurtosis, Crest Factor, Peak değerleri ölçebilme
- IP66 korumalı tasarım ve pil ile beslenme
- Dahili anten, LoRaWAN desteęi
- LoRa (Long Range) uzun mesafe haberleşme desteęi
- ModBus TCP/OPC UA haberleşme protokolü alt yapısı



řekil 4.5. Advantech WISE-2410 Smart Sensör

Uygulamanın yapıldığı motor ve redüktörün teknik bilgileri Tablo 4.5.'te görölmektedir.

**Tablo 4.5.** Motor ve Redüktörün Teknik Özellikleri


Motor Tipi	Asenkron	Redüktör Tipi	Planet
Güç (kW)	1,1	Güç (kW)	1,1
Gerilim (V)	400	Devir (rpm)	352
Akım (A)	2,46	Ratio (i)	4,13
Devir (rpm)	1450	Montaj Pozisyonu	M4
cos Ø	0,76	Yağ Miktarı (lt)	0,8
Çalışma Tipi	Sürücü		

Sıcaklık ve vibrasyon verilerinin alındığı akıllı sensörün montajı Şekil 4.6.'da görüleceği üzere motor ve şanzıman gövdesine yapılmıştır.

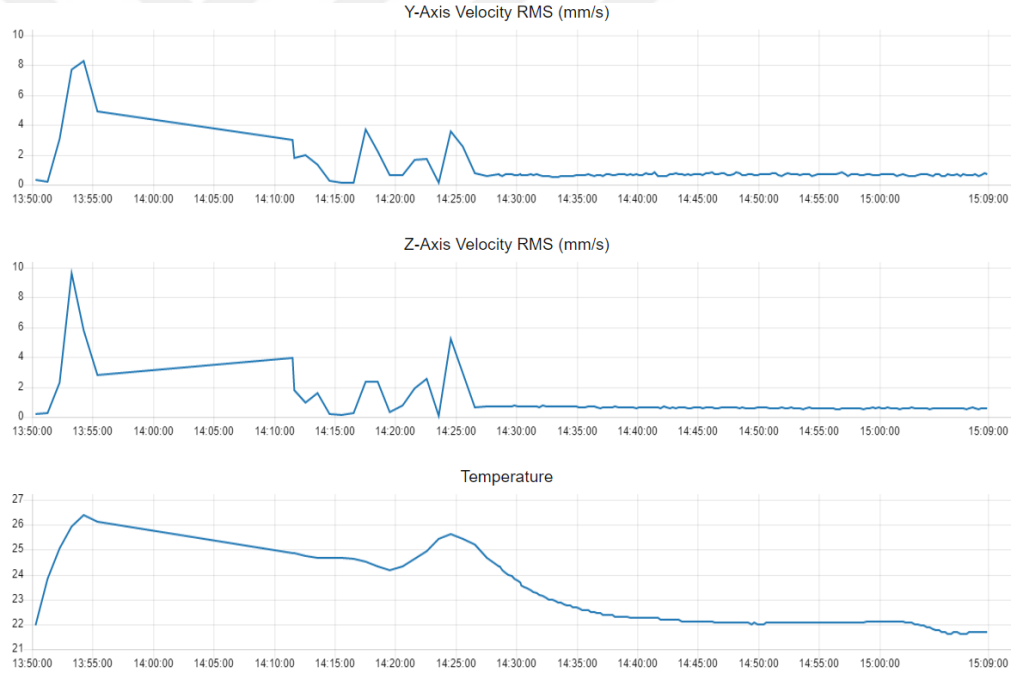


**Şekil 4.6.** Sıcaklık ve Titreşim Sensörünün Gövdeye Montajı

IP tanımlaması yapıldıktan sonra gateway aracılığıyla sahadan ölçümlenen veriler arayüz programı üzerinden alınmaya başlamıştır. İlgili noktalardan alınan sıcaklık ve vibrasyon verilerinin zamana bağlı değişimine ait kesitler Şekil 4.7. ve Şekil 4.8.'de görülmektedir.



**Şekil 4.7.** X ve Y Ekseninde Ölçülen Titreşim Verileri



**Şekil 4.8.** Y ve Z Ekseninde Ölçülen Titreşim ve Gövde Sıcaklık Verileri

Motor ve şanzımanın bulunduğu çalışma ortamına ait sıcaklık ve nem verileri ise Testo markasına ait 174H model datalogger ile kayıt altına alınmıştır.

Testo datalogger cihazın özellikleri şu şekilde sıralanabilir.

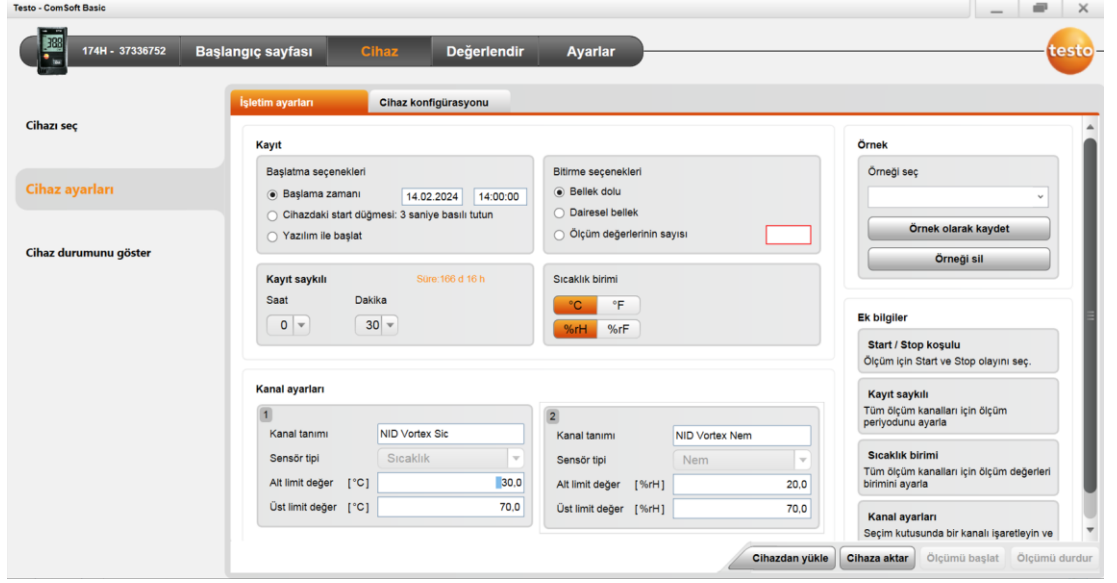
- -20 ila 70°C ölçüm aralığı
- $\pm 0,5^{\circ}\text{C}$  doğruluk (-20 ila 70°C)
- 0 ila 100 %rH nem ölçüm aralığı
- -20 ila 70°C çalışma sıcaklığı
- IP20 koruma sınıfı

Datalogger cihazının ekran görseli ve montaj noktası Şekil 4.9.'da görülmektedir.




**Şekil 4.9.** Datalogger Görünümü ve Çalışma Ortamına Montajı

Cihaz, belli bir süre boyunca montajının yapıldığı ortama ait verileri kaydetmiştir. Ölçüm aldığı bu veriler, Şekil 4.10.'da yer alan ComSoft Basic arayüz programı ile dijital ortama aktarılmıştır.



Şekil 4.10. Datalogger Kurulum Arayüzü



Şekil 4.11. Sıcaklık ve Nem Değerlerine Ait Ölçüm Grafiği

Ölçülen parametrelere ait grafiğin bir kesitinin görüldüğü Şekil 4.11.'de mavi renk ortam sıcaklığını ( $^{\circ}\text{C}$ ), kırmızı renk ise ortam nem değerini ( $\%r\text{H}$ ) ifade etmektedir.

Ölçümler sonucu elde edilen verilerin analizinde Python programı kullanılmıştır. Veri tabanını altı adet öznelik (ortam sıcaklık, ortam nem, motor gövde sıcaklık, motor gövde vibrasyon, şanzıman gövde sıcaklık ve şanzıman gövde vibrasyon) oluşturmaktadır. Toplam 3124 veri; NB, DT, RF, SVM, KNN ve XGBoost gibi denetimli öğrenme algoritmaları aracılığıyla %70'i eğitim, %30'u test verisi ve %80'i eğitim, %20'si test verisi olmak üzere farklı varyasyonlarla analiz edilerek arıza

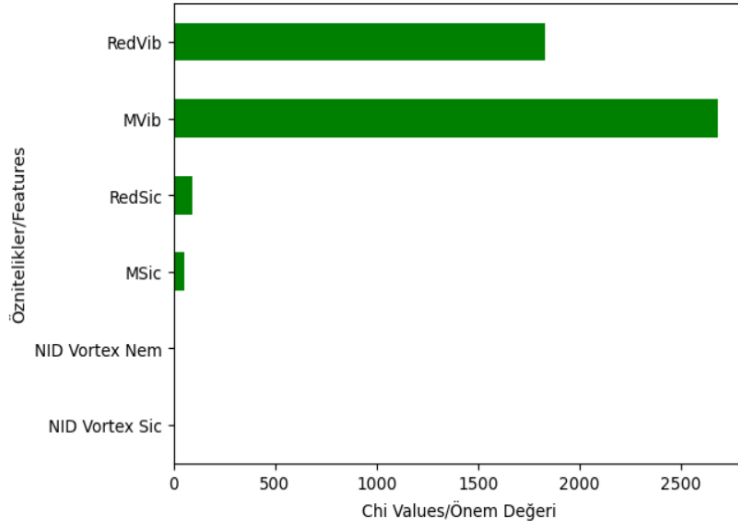
tahmini konusunda performans skorları karşılaştırılmıştır. Algoritmaların eğitim ve test verilerini belirlemede rastgele durum (random state) yöntemi kullanılmıştır.

NB algoritmasında, ilk aşamada altı özneliğin önem derecesi Ki-kare methodu ile belirlenmiştir. Ki-kare (Chi-Square), veri setinde yer alan özneliklerin önem derecesini belirlemek için kullanılan yöntemlerden biridir. Bu yöntem ile model performansının iyileştirilmesi ve eğitim süresinin azaltılarak verimliliğin artırılması amaçlanmaktadır [50]. Bu nedenle Ki-kare öznelik seçimi, sınıflandırma doğruluğunu artırma konusunda ön planda yer almaktadır. Ki-kare analizi, iki kategorik değişkenin bağımsız olup olmadığını değerlendirmek için kullanılan istatistiksel bir testtir. Ki-kare değeri, Denklem 4.1'e göre hesaplanmaktadır [50]. Bu eşitlikte,  $O_i$  gözlenen değeri,  $E_i$  beklenen değeri ve  $\chi^2$  değeri ise ki-kare değerini ifade etmektedir.


$$\chi^2 = \frac{\sum_i (O_i - E_i)^2}{E_i} \quad (4.1)$$

Veri setinde bulunan hedef değişken ve öznelik değerinin birbirinden bağımsız olması durumunda ilgili özneliğin modelin eğitimine olan etki derecesi az olacaktır ve bu öznelikler, küçük ki-kare değerine sahiptir. Bu analiz ile veri setinde bulunan tüm özneliklerin hedef değişken ile olan korelasyonu incelenerek azalan ki-kare değerine göre öznelik önem derecesi belirlenmektedir.

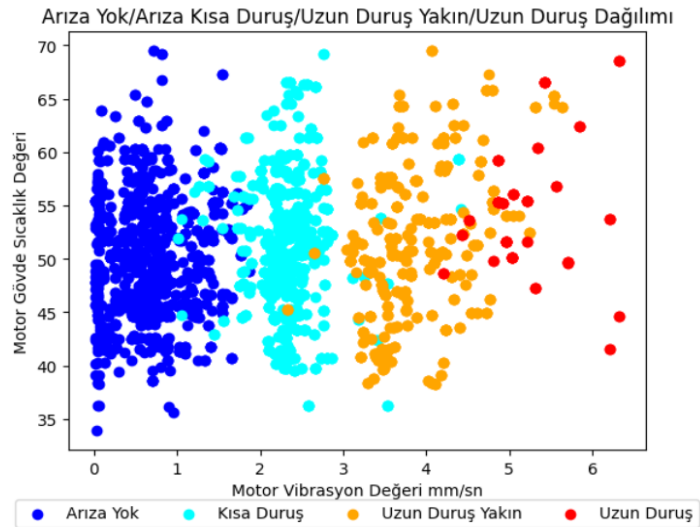
Bu çalışmada veri setini oluşturan altı özneliğin tamamı, algoritmaların performans analizinde etkin bir şekilde kullanılmıştır. Şekil 4.12.'de görüleceği üzere redüktör (şanzıman) vibrasyon (RedVib) ve motor vibrasyon (MVib) değerleri tahminleme konusunda ön plana çıkmıştır. Şekil 4.13.'te grafikte yatay eksen, motor gövde vibrasyon değerlerini; dikey eksen ise redüktör gövde vibrasyon değerlerini göstermektedir. Grafikte her iki vibrasyon değerinin zamanla arttıkça, tanımlı olduğu sınıfın da yüksek vibrasyon değerlerinin neden olduğu uzun duruş grubuna dönüştüğü görülmektedir. Bu yönden bakıldığında motor vibrasyon ve redüktör vibrasyon değerlerinin değişimine bakılarak verilerin sınıflandırmasında iki titreşim değerinin etkisi olduğu söylenebilir.



Şekil 4.12. NB Öznitelik Önem Derecesi



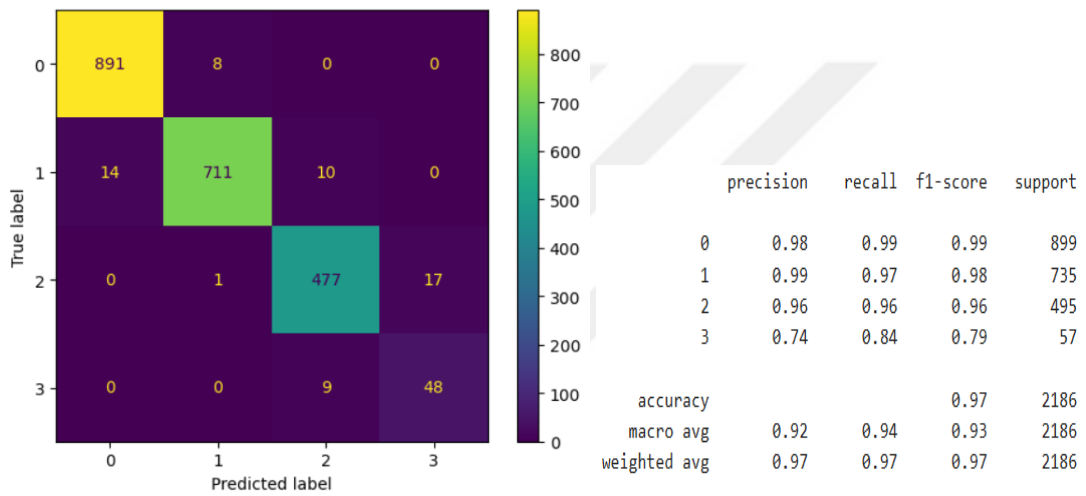
Şekil 4.13. Motor ve Redüktör Vibrasyon Değişimi



Şekil 4.14. Motor Vibrasyon ve Motor Gövde Sıcaklık Değişimi

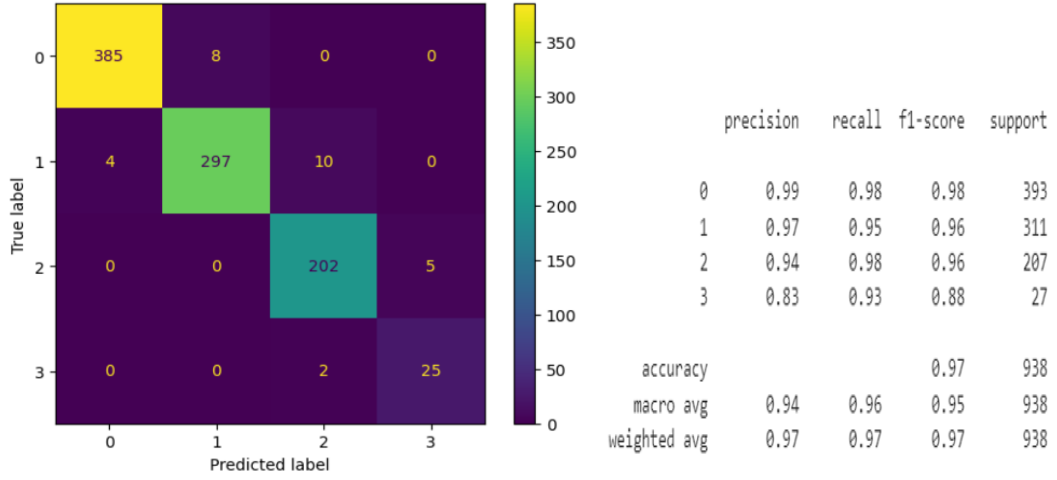
Şekil 4.14.'te grafik incelendiğinde sınıflandırma aşamasında dikey ekseninde yer alan motor gövde sıcaklık değeri artsa da aynı sınıf içerisinde yer aldığı, motor vibrasyon şiddetinin arttıkça ölçülen verilere ait sınıfların da değiştiği görülmektedir. Bu açıdan bakıldığında titreşim değerlerinin sınıflandırma sürecinde etkin bir rol oynadığı söylenebilir.

Veri setinin %70 eğitim, %30'u test verisi olarak ele alındığında NB algoritmasının eğitim verilerine ait karışıklık matrisi ve skor metrikleri Şekil 4.15.'te yer almaktadır. Değerlendirme metriğinde yer alan support sütunu, çalışmada ele alınan eğitim verilerinin sayısını temsil etmektedir.




Şekil 4.15. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)

Veri setinin %70 eğitim, %30'u test verisi olarak ele alındığında NB algoritmasının test verilerine ait karışıklık matrisi ve skor metrikleri Şekil 4.16.'da yer almaktadır. Değerlendirme metriğinde yer alan support sütunu, çalışmada ele alınan test verilerinin sayısını temsil etmektedir.




**Şekil 4.16.** NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)

Verilerin %80'i eğitim, %20'si test olarak ele alındığında NB algoritmasının eğitim verilerine ait karışıklık matrisi ve performans metrikleri Şekil 4.17.'de görülmektedir. İki durum karşılaştırıldığında, algoritmanın Class 3 verilerinin tahmininde %3'lük bir düşüş olduğu ancak tüm sınıfların ele alındığı ağırlıklı ortalamada performans skorlarında herhangi bir değişiklik olmadığı görülmüştür.




**Şekil 4.17.** NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %80-%20)

Verilerin %80'i eğitim, %20'si test olarak ele alındığında NB algoritmasının test verilerine ait karışıklık matrisi ve performans metrikleri Şekil 4.18.'de görülmektedir. İki durum karşılaştırıldığında, algoritmanın Class 3 verilerinin tahmininde skoru %88'den %86'ya düştüğü ancak tüm sınıfların ele alındığı ağırlıklı ortalamada performans skorlarında herhangi bir değişiklik olmadığı görülmüştür.



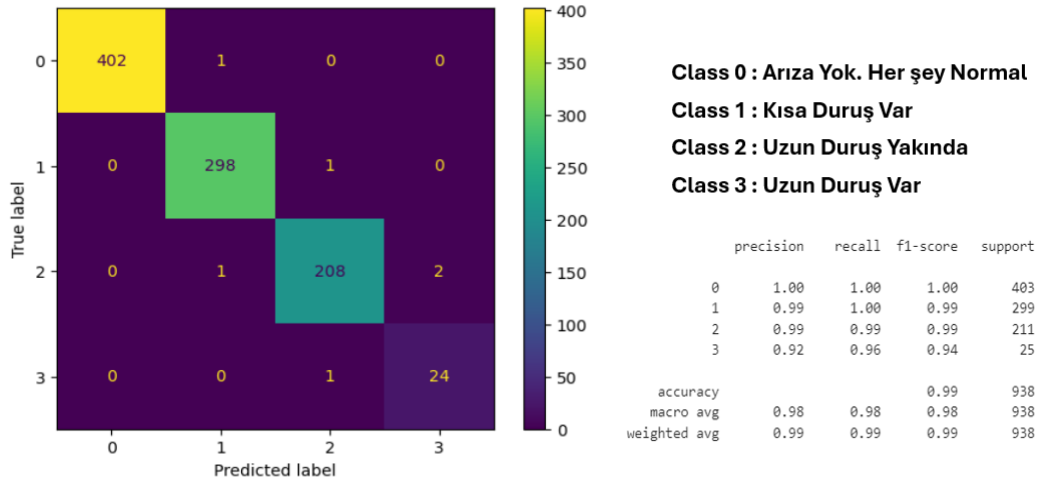
Şekil 4.18. NB Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %80-%20)

Veri setinin %70 eğitim, %30'u test verisi olarak ele alındığında DT algoritmasının eğitim verilerine ait karışıklık matrisi ve skor metrikleri Şekil 4.19.'da yer almaktadır.



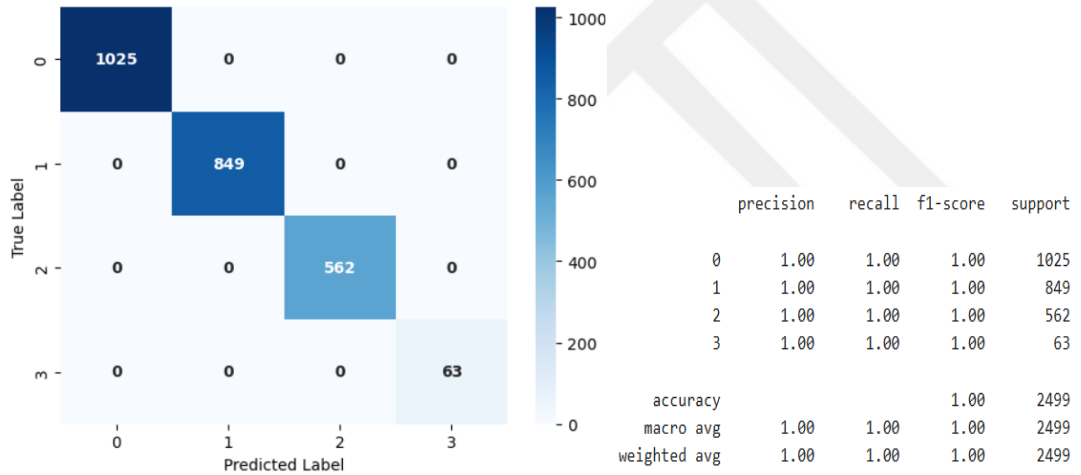
Şekil 4.19. DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)

Aynı veriler DT algoritması ile analiz edildiğinde Class 0 (arıza yok) verilerini NB algoritmasına göre daha başarılı tahmin ettiği Şekil 4.20.'de yer alan karışıklık matrisinde görülmektedir. Diğer sınıflarda NB göre yakın sonuçlar vermiştir [49].



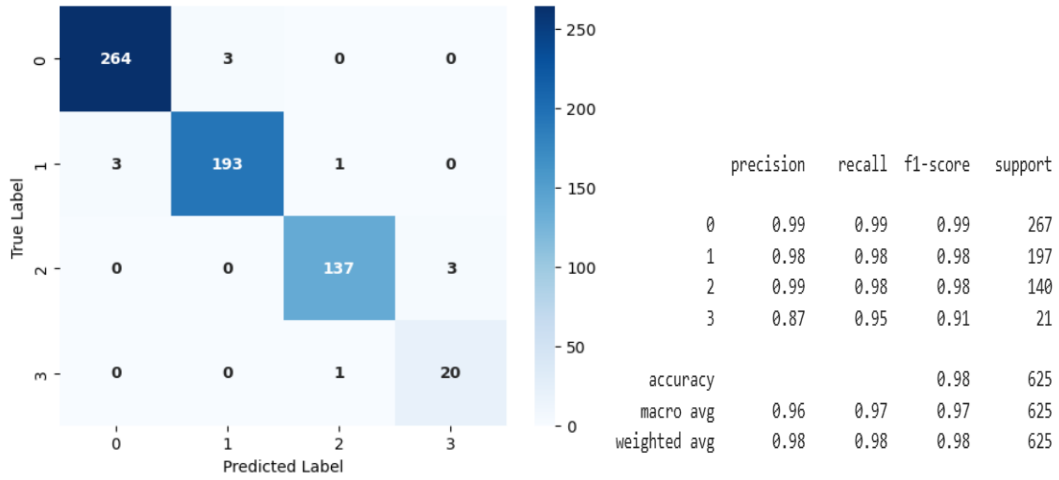
**Şekil 4.20.** DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)

Verilerin %80'i eğitim, %20'si test olarak ele alındığında DT algoritmasının eğitim verilerine ait karışıklık matrisi ve skor metrikleri Şekil 4.21.'de yer almaktadır.



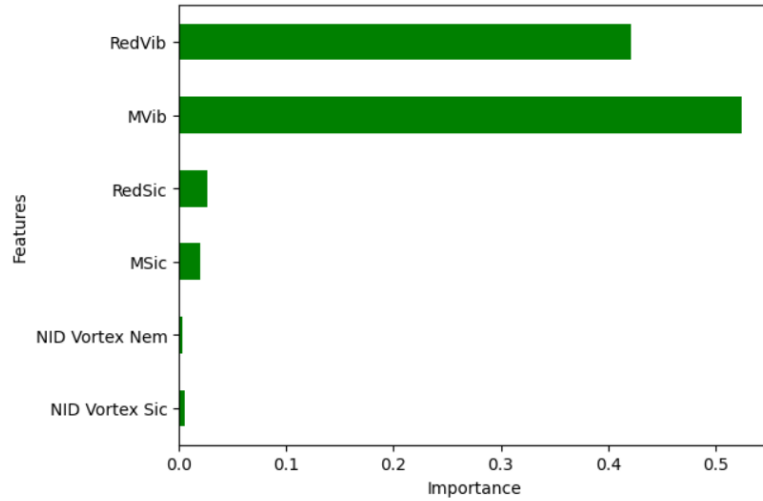
**Şekil 4.21.** DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %80-%20)

Verilerin %80'i eğitim, %20'si test olarak ele alındığında Şekil 4.22'de görüleceği üzere DT algoritmasının test verilerine ait genel performans skorunun %98 olarak ortaya çıkmıştır. Bu durum, DT algoritmasında verilerin %80-%20 olarak analiz edilmesi performans metriklerinde bir miktar düşüşe neden olduğunu göstermektedir.




**Şekil 4.22.** DT Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %80-%20)

Her iki karışıklık matrisini incelediğimizde DT algoritmasının verilerin sınıflandırma tahmininde eğitim setinin oldukça başarılı bir performans gösterdiği görülmektedir. Rastgele orman algoritması ile yapılan çalışmada özniteliklerin önem derecesi belirlenmiştir. Yapılan analizde Şekil 4.23.'te görüleceği üzere redüktör vibrasyon ve motor vibrasyon değerleri, algoritmanın tahmin etme sürecinde ön plana çıkmıştır.




**Şekil 4.23.** RF Öznitelik Önem Derecesi

RF algoritmasının eğitim verilerine ait karışıklık matrisi ve verilerin tahmini aşamasında gösterdiği performans çıktıları Şekil 4.24.'te görülmektedir. Gerçek zamanda ölçülen veri miktarının az olması, algoritmanın öğrenme sürecinde kullanacağı eğitim verilerini de etkilediği düşünülmektedir. Buna bağlı olarak eğitim setinde algoritma, Class 2 ve Class 3 ait verileri tam olarak ayırt edememiştir.




**Şekil 4.24.** RF Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)

RF algoritmasının test verilerine ait karışıklık matrisi ve verilerin tahmini aşamasında gösterdiği performans çıktıları Şekil 4.25.'te görülmektedir. RF metodu, gerçekte Class 3 sınıfına ait verileri Class 2 olarak tahmin etmiştir. Bu yanlış tahminlemenin sebebinin gerçek zamanda ölçülen veri sayısının az olmasından kaynaklı olabileceği düşünülmektedir. Diğer sınıflandırmalarda başarılı bir tahmin yürütmüştür [48].




**Şekil 4.25.** RF Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)

KNN algoritması ile ölçülen veriler analiz edildiğinde sisteme tanınan komşu sayısının doğruluk metriğine etki ettiği görülmüştür. Şekil 4.26.'daki grafiğe bakıldığında komşu sayısı arttıkça algoritmanın doğruluk skorunu olumsuz etkilediği çıkarımı yapılabilmektedir [49].




**Şekil 4.26.** KNN Algoritmasında Komşu Sayısı ve Doğruluk Değeri Değişimi

KNN algoritmasında komşu sayısı 27 olarak ele alındığında yapılan çalışma sonucunda elde edilen eğitim verilerine ait karışıklık matrisi ve skorları Şekil 4.27.'de görülmektedir. Class 2 ve Class 3 verilerinin Şekil 4.13'te de görüldüğü üzere iç içe olması, KNN algoritmasının Class 3 verilerinin tahmininde düşük performans göstermesine sebep olduğu düşünülmektedir.



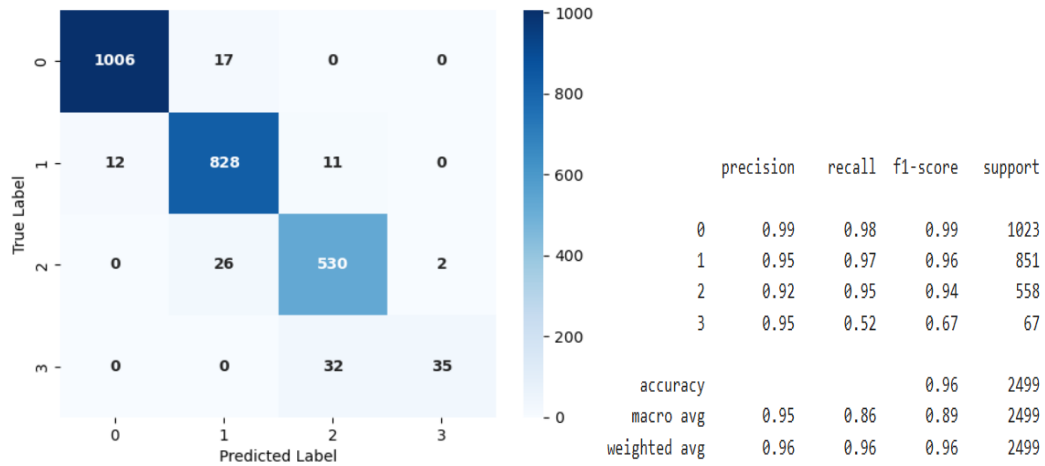
**Şekil 4.27.** KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)



Şekil 4.28. KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)


KNN algoritmasında komşu sayısı 27 olarak ele alındığında yapılan çalışma sonucunda elde edilen karışıklık matrisi ve skorları Şekil 4.28.'de görülmektedir. Buna göre algoritmanın Class 0-1-2 (arıza yok, kısa duruş, uzun duruş yakında) verilerinde tahmin performansının yüksek ancak önem derecesinin kritik olduğu, duruş maliyeti çıkaracak arızaları ifade eden Class 3 (uzun duruş var) verilerinde düşük performans göstermiştir [48].

Verilerin %80'i eğitim, %20'si test ve komşu sayısı 27 olarak ele alındığında KNN algoritmasının eğitim verilerine ait genel performans skoru ve karışıklık matrisi Şekil 4.29.'da görülmektedir. Verilerin %80-%20 olarak ele alınması, algoritmanın Class 3 verilerinin tahmininde performansını arttırdığını ancak tüm sınıfları kapsayan genel performans skorunda herhangi bir değişiklik yaratmadığını göstermektedir.




Şekil 4.29. KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %80-%20)

Verilerin %80'i eğitim, %20'si test ve komşu sayısı 27 olarak ele alındığında KNN algoritmasının Şekil 4.30.'da görüleceği üzere genel performans skorunun %96 olarak ortaya çıkmıştır. Bu durum, KNN algoritmasında verilerin %80-%20 olarak ele alınmasının performans metriklerinde %1'lik bir artışın gerçekleştiğini göstermektedir.




Şekil 4.30. KNN Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %80-%20)

SVM algoritması ile aynı veriler %70 eğitim verisi ve %30 test verisi olarak ele alındığında eğitim verilerine ait performans çıktıları Şekil 4.31.'de görülmektedir.



Şekil 4.31. SVM Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim %70-%30)


SVM algoritması ile aynı veriler %70 eğitim verisi ve %30 test verisi olacak şekilde analiz edilmiştir. Algoritmanın test verilerine ait performans çıktıları Şekil 4.32.'de görülmektedir. Bu çalışmada doğrusal (linear) SVM kullanılmıştır.



**Şekil 4.32.** SVM Karışıklık Matrisi ve Değerlendirme Metrikleri (Test %70-%30)


SVM algoritmasının karışıklık matrisi incelendiğinde 0,1 ve 2 sınıflarına ait tahminleme skorunun KNN algoritması kadar başarılı olduğu Class 3 verilerinde ise KNN algoritmasına göre daha iyi performans gösterdiği görülmüştür.

Son aşamada sahadan ölçümler sonucu elde edilen veriler, XGBoost algoritması ile analiz edilmiştir. Öncelikle, algortmada yer alan özneliklerin önem derecesi belirlenmiştir. Şekil 4.33.'te görüleceği üzere her bir özneliğin algoritmanın vereceği kararlar üzerinde etkisi bulunmaktadır.




**Şekil 4.33.** XGBoost Algoritmasında Öznelik Önem Derecesi

XGBoost algoritması ile aynı veriler %70 eğitim verisi ve %30 test verisi olarak ele alındığında eğitim verilerine ait performans çıktıları Şekil 4.34.'te görülmektedir. Algoritmanın, eğitim aşamasında gösterdiği tahmin performansı, test aşamasındaki performansını da olumlu yönde etkilemiştir.



Şekil 4.34. XGBoost Karışıklık Matrisi ve Değerlendirme Metrikleri (Eğitim)




Şekil 4.35. XGBoost Karışıklık Matrisi ve Değerlendirme Metrikleri (Test)

XGBoost algoritmasının Şekil 4.35.'te yer alan skorları incelendiğinde ele alınan tüm denetimli öğrenme yöntemleri arasında en başarılı performans gösteren algoritma olduğu görülmektedir. Özellikle uzun duruşlara neden olacak arızaları temsil eden Class 3 verilerini tahmin etme konusunda karar ağacı algoritmasına göre çok daha iyi bir başarı ortaya koymuştur [48].

Yapılan arıza analizi çalışmasında kullanılan denetimli öğrenme algoritmalarının performans metrikleri Tablo 4.6.'da görülmektedir. Tablo 4.6'da görülen sonuçlar, veri kümesinde yer alan dataların %70'i eğitim ve %30'u test verisi olacak şekilde elde edilmiştir.

**Tablo 4.6.** Denetimli Öğrenme Algoritmalarının Performans Sonuçları

Algoritma	Accuracy	Recall	Precision	F1-Score
KNN	0.95	0.95	0.95	0.94
Naive Bayes	0.97	0.97	0.97	0.97
SVM	0.97	0.97	0.97	0.97
Decision Tree	0.99	0.99	0.99	0.99
Random Forest	0.96	0.96	0.93	0.94
XGBoost	0.99	0.99	0.99	0.99



**Şekil 4.36.** Kullanılan Algoritmaların Performans Metrikleri

Şekil 4.36.'da yer alan grafiğe bakıldığında en yüksek skorun 0.99 ile DT ve XGBoost algoritmalarına ait olduğu görülmektedir. Ancak bir alt kırılım altında tekrar bu iki algoritma karşılaştırıldığında uzun duruşlara neden olan Class 3 verilerini tahmin etme açısından XGBoost algoritması bir adım öndedir. XGBoost; DT tabanlı bir algoritma oluşu, aşırı öğrenmeye ihtiyaç duymaması ve veri kümesinde yer alan anlamsız verileri

dahi yönetebilmesi gibi özellikleri ile ön plana çıkmaktadır [49]. Ayrıca her veriyi analiz etmek yerine onları parçalara bölerek çalışma mantığına sahiptir. XGBoost algoritmasının yüksek skorlar elde etmesi bu özellikleri ile yorumlanabilir. Verileri oluşturan özniteliklerin önem değerine bakmaksızın hepsini kriter olarak ele alması da bu performansını olumlu yönde etkilemiştir.

Yapılan arıza analizi çalışmasında motor ve şanzıman grubunun bulunduğu ortam sıcaklık ve nem değerlerinin arıza tahminleme modeline etkisinin oldukça az olduğu görülmüştür. Belirli örnekler dışında herhangi bir dişli arızası veya asenkron motora ait arıza analizinde ortam sıcaklık ve nem değerlerinin göz önünde bulundurulmasının sisteme herhangi bir etkisinin olmayacağı yorumu yapılabilir.



**Şekil 4.37.** Uzun Duruşa (Class 3) Sebep Olan Dişli Arızası


Şekil 4.37.'de görüldüğü gibi dişli sıyrması sonucu gerçekleşen arızaların ortam sıcaklık ve nem değerleri ile değil, helezon sisteminin taşıdığı mekanik yükün aşırı artışı ve buna bağlı olarak helezonun sıkışması ile meydana geldiği görülmüştür. Bu tip arızalar da dişli ya da motor gövdesinde titreşim ve sıcaklığın artması olarak karşımıza çıkmaktadır.



**Şekil 4.38.** Helezon Milindeki Rulman Boşluğu Arızası

Bir başka uzun duruşa neden olan anormal durum, Şekil 4.38.'de görüldüğü gibi milin dış yüzeyinin aşınması ile oluşan boşluktur. Zamanla oluşan bu boşluk, helezon milinin yataklamasını sağlayan rulmanın da göbeğini bozarak ciddi sorunlara yol açabilmektedir. Buna bağlı olarak da mil balanssızlığı sonucu ciddi arızalar yaşanabilmektedir.

Bu arıza analiz çalışmasında kullanılan denetimli öğrenme algoritmaları, arızayı öğrenme ve tahmin etme süreleri açısından da ayrıca karşılaştırılmıştır. Şekil 4.39.'da algoritmaların işlem ve tahmin sürelerini gösteren grafik yer almaktadır. Bu grafik incelendiğinde, SVM algoritmasının performans skoru başarılı olmasına rağmen eğitim süresinin de yüksek olması, algoritmanın işlem ve tahmin süresini de paralel olarak etkilediği görülmektedir. Ayrıca RF ve DT algoritmalarında karar ağacı aşamalarının yer alması ve her bir aşamada geçen süreler göz önünde bulundurulduğunda bu durumun tahmin ve işlem süresini de etkilediği çıkarımı yapılabilmektedir.



**Şekil 4.39.** Algoritmaların İşlem ve Tahmin Süreleri

Algoritmaların işlem ve tahmin sürelerinin karşılaştırma çalışmasında kullanılan bilgisayara ait özellikler aşağıda yer almaktadır.

- 13th Gen Intel® Core i5-13500H 2.60 Ghz İşlemci
- 16 GB (2x8GB) DDR4 RAM
- 64 Bit İşletim Sistemi (Windows 11 Pro)
- 500 GB SSD Depolama
- 230V – 19,5V / 11.8A Adaptör

## 5. SONUÇLAR VE ÖNERİLER

Yapılan bu çalışma, kullanılan denetimli öğrenme metotlarından XGBoost algoritmasının %99 performans skoru ile arıza tahmini konusunda en başarılı yöntem olduğunu göstermiştir. Ayrıca veri işleme ve tahmin süresi grafiğine bakıldığında, XGBoost algoritmasının bu yüksek skoru sistemi öğrenme ve tahmin etme açısından daha kısa bir sürede elde ettiği görülmüştür. Üretim prosesinde yaşanan uzun duruşların sistem üzerindeki etkileri (dişli sıyrılması, mil aşınması vb.) oluşturduğu sıcaklık ve titreşim değerleri ile etiketlenilmiştir. Sistemin ürettiği sayısal veriler, bu değerlere yaklaştığında bakım personelinin arızanın kök sebebini tespit etme ve onarım süresini minimize etmesinde yardımcı olmuştur. Uzun duruşlara neden olan arızaların gerçekleşmeden önce tespit edilmesi ile yaklaşık üç saat sürebilecek duruşlar ve buna bağlı olarak 7500 kg üretim kaybı engellenmiştir.

Bu çalışmada ayrıca veri kümesindeki değerler bazı algoritmalar üzerinde hem %70'i eğitim, %30 test ve %80'i eğitim, %20'si test olarak iki farklı varyasyonla ele alınmıştır. Eğitim verileri %10 oranında arttırıldığında bazı algoritmaların performans metriklerinde küçük oranlarda artış veya azalış olduğu bazılarında ise sabit kaldığı görülmüştür. Bu durumun algoritmaların çalışma yapısındaki farklılıklarla ilişkili olduğu yorumu çıkarılabilir.

İleriye yönelik yapılacak altyapı iyileştirme çalışmalarıyla haberleşme ağı genişletilebilir. TCP/IP protokolü yardımıyla işletmenin birçok kritik noktasından farklı veriler, sürekli çevrimiçi bir şekilde takip edilerek geniş kapsamlı bir izleme sistemi oluşturulabilir. XGBoost algoritmasının analiz sonuçları, son kullanıcının mevcut sistemde kullandığı MRP programı olan SAP'e entegrasyonu sağlanabilir.

Bu çalışma ile seri üretimin olduğu işletmelerde, üretim tesislerinde oluşabilecek ve uzun duruşlara sebep olabilecek arızaların önceden tahmin edilebilmesi açısından kestirimci bakım uygulamalarında makine öğrenmesi algoritmalarının ne kadar önemli olduğu ortaya çıkarılmıştır.

## KAYNAKLAR

1. Jimenez-Cortadi, A., Irigoien, I., Boto, F., Sierra, B., & Rodriguez, G. (2019). Predictive maintenance on the machining process and machine tool. *Applied Sciences*, 10(1), 224, doi:10.3390/app10010224.
2. Köprü, T. (2022). “Kestirimci Bakım Zamanlarının Makine Öğrenmesi Yöntemleriyle Tahminlenmesi: Demir Çelik Sektöründe Bir Uygulama” Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Karabük.
3. Ayan, Ö.A. (2019). “Döner Makine Elemanların Titreşim Analizi ile Kestirimci Bakımı” Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Edirne.
4. Tuncer, K. (2022). “Durum Bazlı Kestirimci Bakım Yöntemlerinden Titreşim Analizi ile Fanlardaki Dengesizlik Arızasının Tespiti ve Bakımı” Yüksek Lisans Tezi, Erciyes Üniversitesi Eğitim Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Kayseri.
5. Ceyhan, H. (2022). “Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım Uygulaması ve Modellemesi” Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul.
6. Kalemoglu, Y. (2023). “Haddehanelerde Sıcaklık ve Titreşim Ölçümü ile Kestirimci Bakım Uygulamaları” Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Karabük.
7. Sındır, E. (2022). “Endüstride Kullanılan Asenkron Bir Motorda Bulanık Mantık Temelli Kestirimci Bakım Uygulaması” Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Hatay.
8. Şahin, M. (2022). “Makine İmalat Sektöründe Kullanılan Takım Uçları İçin Yapay Zeka İle Kestirimci Bakım Uygulamaları” Yüksek Lisans Tezi, Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Tekirdağ.
9. Akyaz, T. (2022). “Bilgisayar Destekli Kestirimci Bakım Sisteminin Tasarlanması” Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Ana Bilim Dalı, İzmir.
10. Kızılay E. (2022). “Demiryolu Makas Motorlarının Kontrolü, Kestirimci Bakım ve Emniyet Analizi” Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Ana Bilim Dalı, İstanbul.
11. Atapek, A. (2022)., “Kestirimci Bakım Metotları İle Arızaların Tespit Edilmesi Ve J79 Turbojet Uçak Motorlarında Kestirimci Bakım Uygulamaları” Yüksek Lisans Tezi, Altınbaş Üniversitesi Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Bölümü, İstanbul.

12. Asadzade A. (2020). "Predictive Maintenance for Smart Industry" Yüksek Lisans Tezi, İzmir Yüksek Teknoloji Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İzmir.
13. Karadayı, H. M. (2011). "Titreşim Analizi ile Pompalarda Arıza Tespiti ve Kestirimci Bakım Uygulamaları" Yüksek Lisans Tezi, Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Balıkesir.
14. Baykara, V. İ. (2009). "Titreşim Analizi ile Şanzımanlarda Arıza Teşhisi ve Kestirimci Bakım" Yüksek Lisans Tezi, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Zonguldak.
15. Orhan, S. (2002). "Rulmanlarla Yataklanmış Dinamik Sistemlerin Titreşim Analizi ile Kestirimci Bakımı" Doktora Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Makine Ana Bilim Dalı, Kırıkkale.
16. Orhan, S., Aktürk, N., & Çelik, V. (2003). "Bir Santrifüj Pompa Rulmanlarının Çalışabilirliğinin Titreşim Analizi ile Belirlenmesi", Gazi Üniversitesi Fen Bilimleri Dergisi, 16(3), 543-552.
17. Kurgan, N. (2019). "Bakım Planlaması 2019". Erişim: 7 Ağustos 2024. [Çevrimiçi]. Erişim adresi: <https://avys.omu.edu.tr>
18. Denli, H. B. (2007). "Kestirimci Bakım ve Uygulamalarının İyileştirilmesi" Yüksek Lisans Tezi, Mersin Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Mersin.
19. Üçüncü, K. (2016). "OREN4031 Bakım Yönetimi – 11. Hafta: Bakım Yöntemleri" Karadeniz Teknik Üniversitesi, Orman Fakültesi, Orman Endüstri Mühendisliği. 108, 4-5. Erişim: 14 Eylül 2024. [Çevrimiçi]. Erişim adresi: <https://avesis.ktu.edu.tr/kucuncu/dokumanlar>
20. 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. doi: 10.1080/21693277.2016.1192517
21. Carvalho T. P., Soares, F. A., Vita, R., Francisco R. D. P., Basto, J. P., & Alcalá, S. G. (2019). "A Systematic Literature Review of Machine Learning Methods Applied To Predictive Maintenance". *Computers & Industrial Engineering*, 137. doi: 10.1016/j.cie.2019.106024
22. Ramachandran, K. K., Mary, A. A. S., Hawladar, S., Asokk, D., Bhaskar, B., & Pitroda, J. R. (2022). "Machine Learning and Role of Artificial Intelligence in Optimizing Work Performance and Employee Behavior" *Materials Today: Proceedings*, 51, 2327–2331, doi: 10.1016/j.matpr.2021.11.544
23. Arumugam, K., Swathi, Y., Sanchez, D. T., Mustafa, M., Phoemchalard, C., Phasinam, K., & Okoronkwo, E. (2022). "Towards Applicability of Machine Learning Techniques in Agriculture and Energy Sector". *Materials Today: Proceedings*, 51, 2260–2263, doi: 10.1016/j.matpr.2021.11.394
24. Kartal, C. (2020). "Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini", *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 9(2), 1394-1418, doi: 10.15869/itobiad.673015

25. Kızılkaya, Y. M., & Oğuzlar, A. (2018). "Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili ile Kıyaslanması", *Karadeniz Uluslararası Bilimsel Dergisi*, 37(37), 90-98. doi: 10.17498/kdeniz.405746
26. Belkacem, S. (2021). "Machine Learning Approaches to Rank News Feed Updates on Social Media" Doktora Tezi, Université des Sciences et de la Technologie Houari Boumediene Alger.
27. Güvenç, E., Sakal, M., Çetin, G., & Özkaraca O. (2022). "Öğrencilerin Dersteki Niteliklerinin Makine Öğrenmesi Teknikleri Kullanılarak Sınıflandırılması", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(3), 1359–1371. doi: 10.29130/dubited.1017202.
28. Pala, M. A., Çimen, M. E., Boyraz Ö. F., Yıldız, M. Z., & Boz, A. F. (2019). "Meme Kanserinin Teşhis Edilmesinde Karar Ağacı ve KNN Algoritmalarının Karşılaştırmalı Başarım Analizi", *Academic Perspective Procedia*, 2(3), 544-552, doi: 10.33793/acperpro.02.03.47
29. Hafeez, M. A., Rashid, M., Tariq, H., Abideen, Z. U., Alotaibi, S. S., & Sinky, M. H. (2021). "Performance improvement of decision tree: A robust classifier using tabu search algorithm", *Applied Sciences*, 11(15), 6728, doi: 10.3390/app11156728
30. Atallah D. M., Badawy M., El-Sayed A., & Ghoneim M. A. (2019). "Predicting Kidney Transplantation Outcome Based On Hybrid Feature Selection and Knn Classifier" *Multimedia Tools and Asslications*, 78, 20383-20407. doi: 10.1007/s11042-019-7370-5.
31. Güvenç E., Çetin G., & Koçak H. (2021). "Comparison of KNN and DNN Classifiers Performance in Predicting Mobile Phone Price Ranges" *Advances in Artificial Intelligence Research (AAIR)*, 1(1), 19-28.
32. Rochim, A. F., Kusumastuti, R., & Windasari, I. P. (2021). "Comparison of Feature Selection for Naive Bayes Classification Method in A Case Study of The Corona Virus Lockdown" *International Conference on Data Science and Its Applications*, 215-220. IEEE. doi:10.1109/ICoDSA53588.2021.9617471
33. Ayan, S., & Bilgin, T. T. (2024). "Uyku Sağlığı ile Yaşam Tarzı Arasındaki İlişkinin PCA, Naive Bayes ve Rastgele Orman Ağaçları Yöntemleri ile İncelenmesi ve Karşılaştırılması", *International Journal of Management Information Systems and Computer Science*, 8(1), 41-56, doi: 10.33461/uybisbbd.1415925
34. Jatoi, A., Sami, M., Nawaz M., & Baloch J. (2022). "An Intuitive Implementation of Course Recommendation System Based on Learner's Personality" *Acta Scientific Computer Sciences*, 4(5), 37-42.
35. Şengül, Z. (2022). "Nasdaq 100 Index Estimate With Machine Learning Algorithms", *Meriç Uluslararası Sosyal ve Stratejik Araştırmalar Dergisi*, 6(16), 124-143.
36. Güngör, A., Doğru, İ., Barışçı, N., & Toklu, S. (2023). "Malware Detection Using Image-based Features and Machine Learning Methods", *Gazi*

Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 38(3), 1781-1792. doi: 10.17341/gazimmfd.994289

37. Nahzat, S., & Yağanoğlu M. (2021). "Diabetes Prediction Using Machine Learning Classification Algorithms" *European Journal of Science and Technology*, (24), 53-59. doi:10.31590/ejosat.899716
38. Hatipoğlu, A., Güneri, Y., & Yılmaz, E. (2024). "A Comparative Predictive Maintenance Application Based on Machine and Deep Learning" *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39(2), 1037-1048. doi: 10.17341/gazimmfd.1221105
39. Yiğit, E. (2021). "Makine Öğrenmesi Kullanılarak Endüstriyel Pres Makinesi İçin Kestirimci Bakım Uygulaması" Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Ana Bilim Dalı, Kocaeli.
40. Trizoglou, P., Liu, X., & Lin, Z. (2021). "Fault Detection By An Ensemble Framework of Extreme Gradient Boosting (XGBoost) In The Operation Of Offshore Wind Turbines", *Renewable Energy*, 179, 945-962. doi: 10.1016/j.renene.2021.07.085
41. Kelle, A. C., & Yüce, H. (2022). "MQTT Trafiğinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması" *Journal of Materials and Mechatronics: A (JournalMM)*, 3(1), 50-62, doi:10.55546/jmm.995091
42. Doğan, C. (2024)., "Kümeleme Problemleri İçin Geliştirilmiş Tek Aday Optimizasyon Algoritması" Yüksek Lisans Tezi, Şeyh Edebalı Üniversitesi Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Bilecik.
43. Gao, C. X., Dwyer, D., Zhu, Y., Smith, C. L., Du, L., Folia, K. M., ... & Cotton, S. M. (2023). "An overview of clustering methods with guidelines for application in mental health research.", *Psychiatry Research*, 327, 115265. doi: 10.1016/j.psychres.2023.115265
44. Saxena, A., & Rajpoot, V. (2021). "A comparative analysis of association rule mining algorithms", *IOP Conference Series: Materials and Science Engineering*, 1099, 012032. doi: 10.1088/1757-899X/1099/1/012032
45. "TPM Bilgilendirme Eğitimi", (2022). Erişim: 12 Mayıs 2024. [Çevrimiçi]. Erişim adresi: [www.kaizenatolyesi.com.tr](http://www.kaizenatolyesi.com.tr)
46. Faisal, M., & Zamzami E. M. (2020). "Comparative analysis of inter-centroid K-Means performance using euclidean distance, Canberra distance and Manhattan distance", *Journal of Physics: Conference Series*, 1566(1), 012112, doi: 10.1088/1742-6596/1566/1/012112
47. Mailagaha Kumbure, M., & Luukka, P. (2022). "A generalized fuzzy k-nearest neighbor regression model based on Minkowski distance", *Granular Computing*, 7(3), 657-671. doi: 10.1007/s41066-021-00288-w
48. Pirge, İ. G., & Baştürk, İ. (2024). "KESTİRİMCİ BAKIM İLE ÜRETİM VERİMLİLİĞİNİN ARTIRILMASI", *EGE 12TH INTERNATIONAL*

CONFERENCE ON APPLIED SCIENCES PROCEEDING BOOK, 1977-1989.

49. Pirge, İ. G., & Baştürk İ. (2025). “Endüstriyel Tesislerde Makine Öğrenmesi ile Kestirimci Bakım ve Arıza Analizleri”, Karaelmas Fen ve Mühendislik Dergisi, 15(1), 119-133. Doi: 10.7212/karaelmasfen.1568736
50. Aksu, K. (2023). “Makine Öğrenmesi Yöntemleri Kullanılarak Üç Boyutlu Nokta Bulutlarının Sınıflandırılması” Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Geomatik Mühendisliği Ana Bilim Dalı, İstanbul.



## ÖZGEÇMİŞ

Adı Soyadı : İlyas Güvenç PİRGE

Doğum Yeri ve Yılı : Manisa

Medeni Hâli : Bekâr

Yabancı Dili : İngilizce, Almanca

E-Posta :

### Eğitim Durumu

Lise : Akhisar Anadolu Lisesi, 2010

Lisans : Süleyman Demirel Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 2010-2014

Yüksek Lisans : Manisa Celal Bayar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 2022-2025

### Mesleki Deneyim

Turelsan Elektrik, Elektrik-Elektronik Mühendisi, 2015

Kervan Gıda San. ve Tic. A.Ş., Planlı Bakım Yöneticisi, 2015-Halen