

**FPGA TABANLI HATA TESPİT VE SINIFLANDIRMA
SİSTEMİ TASARIMI**

**DESIGN OF AN FPGA BASED FAULT DETECTION AND
CLASSIFICATION SYSTEM**

İSMAİL PALIT

PROF. DR. ALİ ZİYA ALKAR

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim – Öğretim ve Sınav Yönetmeliğinin Elektrik ve Elektronik
Mühendisliği Anabilim Dalı İçin Öngördüğü

YÜKSEK LİSANS TEZİ

Olarak hazırlanmıştır.

ÖZET

FPGA TABANLI HATA TESPİT VE SINIFLANDIRMA SİSTEMİ TASARIMI

İsmail PALIT

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Prof. Dr. Ali Ziya ALKAR

Ocak 2024, 117 sayfa

Veriye dayalı bakım, durum izleme teknolojisini kullanarak elektromekanik sistemlerin sağlık durumlarına ilişkin çıkarımlar yapmak ve bakım planları üretmek olarak nitelendirilir. Durum izleme elektromekanik sistemler üzerinden toplanan fiziksel verileri, yerine göre regresyon ve sınıflandırma modelleri ile kullanarak, sistemlerin hata tespiti, hata sınıflandırması ve kalan faydalı ömür analizini gerçekleştirme işlemidir. Bu doğrultuda literatürdeki veri edinimi, sinyal işleme, makine öğrenmesi konularından yararlanılır. Veriye dayalı bakım üretim, otomotiv, demiryolu taşımacılığı, büyük iş makineleri, inşaat, tüketici elektroniği endüstrilerinde yaygın olarak kullanılmaktadır. Ancak veriye dayalı bakım yaklaşımının Savunma Sanayii alanındaki kullanımı kısıtlıdır. Bu tez çalışması kapsamında gerçek bir Savunma Sanayii ürününden, farklı sağlık durumlarında titreşim ve akım verileri toplanmıştır. Toplanan veriler öznelik çıkarımında ve farklı makine öğrenmesi modelleri geliştirmede kullanılmıştır. Destek Vektör Makinesi (*İng.* SVM), Karar Ağaçları (*İng.* DT), K-En Yakın Komşu (*İng.* KNN), Rastgele Orman (*İng.* RF) ve Doğrusal Regresyon (*İng.* LR) modellerinin farklı özneliklerle başarımları incelenmiştir. En başarılı sonucu veren SVM modeli FPGA içerisinde gerçekleştirilmiş ve FPGA tasarımının başarımları test edilmiştir. Tez çalışması sonucunda, bir veriye dayalı bakım çalışması gerçekleştirilmiş ve gerçek bir askeri mekanik sistem üzerinde uygulanmıştır.

Anahtar Kelimeler: Veriye dayalı bakım, Makine Öğrenmesi, FPGA, Durum izleme, SVM, Savunma Sanayii, Hata sınıflandırma.

ABSTRACT

DESIGN OF AN FPGA BASED FAULT DETECTION AND CLASSIFICATION SYSTEM

İsmail PALIT

Master of Science, Electrical and Electronics Engineering Department

Supervisor: Prof. Dr. Ali Ziya ALKAR

January 2024, 117 pages

Data-driven maintenance is defined as making inferences about the health status of electromechanical systems and producing maintenance plans using condition monitoring technology. Condition monitoring is the process of performing fault detection, fault classification and remaining useful life analysis of systems by using physical data, that is collected from electromechanical systems, with regression and classification models. In this regard, data acquisition, signal processing and machine learning subjects in the literature are utilized. Data-driven maintenance is widely used in the manufacturing, automotive, railway transportation, large construction equipment, construction and consumer electronics industries. However, the use of the data-driven maintenance approach in the Defense Industry is limited. Within the scope of this thesis study, vibration and current data were collected from a real Defense Industry product in different health conditions. The collected data was used in feature extraction and developing different machine learning models. The performance of Support Vector Machine (SVM), Decision Trees (DT), K-Nearest Neighbor (KNN), Random Forest (RF) and Linear Regression (LR) models with different features was examined. The SVM model that gave the most successful results was implemented in the FPGA and the performance of the FPGA design was tested. As a result of the thesis study, a data-driven maintenance study was carried out and applied on a real military mechanical system.

Keywords: Data-driven maintenance, Machine Learning, FPGA, Condition monitoring, SVM, Military Industry, Fault classification.

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
İÇİNDEKİLER	iii
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1 Bakım Yöntemleri.....	4
2.2 Veriye Dayalı Bakım	5
2.2.1 Veriye Dayalı Bakım Kullanım Alanları	9
2.2.2 Hata Tespiti.....	11
2.2.3 Hata Sınıflandırma	11
2.2.4 Kalan Faydalı Ömür Tespiti	14
2.2.5 Titreşim Analizi	16
2.2.5.1 Zaman Alanı Yaklaşımı	18
2.2.5.2 Frekans Alanı Yaklaşımı	19
2.2.5.3 Zaman – Frekans Alanı Yaklaşımı	20
2.2.6 Makine Öğrenmesi Teknikleri	21
2.2.6.1 Sınıflandırma	22
2.2.6.1.1 Destek Vektör Makinesi (SVM)	23
2.2.6.2 Ana Bileşen Analizi (PCA).....	26
2.2.6.3 Öznitelik Seçimi	26
2.3 Savunma Sanayi Ürünlerinde Mevcut Bakım Çalışmaları	27
2.4 FPGA Teknolojisinin Makine Öğrenmesi Alanındaki Kullanımı	28
3. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR.....	29
3.1 Makine Öğrenmesi Modelleri Performans Değerlendirmeleri	29
3.1.1 Veri Seti	29

3.1.1.1 Deneş Düzeneęi	29
3.1.1.2 Veri Edinimi	36
3.1.1.3 Veri Seti İçerięi	36
3.1.1.3.1 Ham Veri Seti	37
3.1.1.3.2 İşlenmiş Veri Seti	51
3.1.2 Yöntem	53
3.1.3 Model ve Öznitelik Seçimi Sonuçları	54
3.1.3.1 SVM Sınıflandırıcı İçin Sonuçlar	55
3.1.3.2 DT Sınıflandırıcı İçin Sonuçlar	62
3.1.3.3 KNN sınıflandırıcı İçin Sonuçlar	69
3.1.3.4 RF Sınıflandırıcı İçin Sonuçlar	78
3.1.3.5 LR Sınıflandırıcı İçin Sonuçlar	86
3.2 FPGA’de Hata Tespit ve Sınıflandırma Algoritmasının Uygulanması	93
3.2.1 FPGA Tasarım Adımları	94
3.2.1.1 Tasarım Kısıtları	94
3.2.1.2 Öznitelik Seçimi	94
3.2.1.3 Rastgele Eğitim ve Test Veri Setlerinin Oluşturulması	95
3.2.1.4 FPGA Tasarım Şeması	97
3.2.1.6 Makine Öğrenmesi Modeli Eğitimi	97
3.2.1.7 FPGA ile Öznitelik Çıkarımı	102
3.2.1.8 SVM Modelinin FPGA’de Gerçekleştirilmesi	103
3.2.2 FPGA Sentez Sonuçları	106
3.3 FPGA Üzerinde Hata Tespit ve Sınıflandırma Uygulaması Geliştirme Akışı	109
4. SONUÇLAR VE TARTIŞMA	111
4.1 Hata Tespit ve Sınıflandırma Sistemi Önerisi	111
4.2 Tez Çalışmasının Literatüre Katkısı	112
4.3 Gelecek Çalışmalar	112
5. KAYNAKLAR	114
EKLER	119
EK 1 – Veri Seti Bilgileri	119
EK 2 – Veri Seti Tanımlaması	121

ŞEKİLLER DİZİNİ

Şekil 2.1 Son 20 Yılda Makine Prognostiği Alanında Yapılan Çalışma Sayıları	6
Şekil 2.2 Genel Karar Modeli Diyagramı [20].....	6
Şekil 2.3 Veri İşleme Yöntemine Göre Durum İzleme Uygulamaları [23]	8
Şekil 2.4 Durum İzleme için Üç Tekniği Kullanan Gömülü Sistem [7].....	9
Şekil 2.5 Kalan Faydalı Ömür Analizi Aşamaları [3].....	15
Şekil 2.6 Makine Öğrenmesi Modelleri Taksonomisi [2].....	21
Şekil 2.7 Denetimli Öğrenme Sınıflandırma Teknikleri [28]	22
Şekil 2.8 Lineer Sınıflandırmada Destek Vektörleri ve Optimum Hiperdüzlem [20]	23
Şekil 2.9 Sınıf sayısına göre SVM karar fonksiyonu sayısı.....	25
Şekil 3.1 Helikoptere Entegre Füze Koruma Kapağı [46]	30
Şekil 3.2 İnsansız Deniz Aracına Entegre Füze Koruma Kapağı [47].....	31
Şekil 3.3 Kapak Mekanizması Şematiği	32
Şekil 3.4 Veri Toplama Düzenegi	32
Şekil 3.5 Testlerde Kullanılan Füze Koruma Kapağı ve İvmeölçer Yerleşimi.....	33
Şekil 3.6 Dewesoft SIRIUS HD Veri Edinim Aracı	33
Şekil 3.7 Piezotronics 356A16 3 Eksenli ICP İvmeölçer.....	34
Şekil 3.8 Dewesoft DSli-20A Akım Sensörü.....	34
Şekil 3.9 TTI PL303QMD	34
Şekil 3.10 Anahtarlama Devresi.....	34
Şekil 3.11 Sabitleyici Mengene ve Füze Koruma Kapağı	35
Şekil 3.12 Sınıf 2 Hata Durumu	38
Şekil 3.13 Sınıf 3 Hata Durumu	39
Şekil 3.14 Sınıf 4 Hata Durumu	39
Şekil 3.15 Sınıf 5 Hata Durumu	40
Şekil 3.16 Sınıf 6 Hata Durumu	40
Şekil 3.17 Ham Veri Örneği.....	41
Şekil 3.18 Ham Veri Seti İçerik Diyagramı	41
Şekil 3.19 Akım Grafiği.....	42
Şekil 3.20 X-Ekseni Titreşim Grafiği	42
Şekil 3.21 Y-Ekseni Titreşim Grafiği	43
Şekil 3.22 Z-Ekseni Titreşim Grafiği.....	43

Şekil 3.23 X-Eksenindeki Titreşim Verileri	44
Şekil 3.24 Y-Eksenindeki Titreşim Verileri	45
Şekil 3.25 Z-Eksenindeki Titreşim Verileri.....	46
Şekil 3.26 Akım Verileri.....	47
Şekil 3.27 X-Eksenindeki Titreşimin FFT Sonuçları	48
Şekil 3.28 Y-Eksenindeki Titreşimin FFT Sonuçları	49
Şekil 3.29 Z-Eksenindeki Titreşimin FFT Sonuçları.....	50
Şekil 3.30 Eksen Takımı.....	51
Şekil 3.31 Özniteliklerin SVM Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı.....	55
Şekil 3.32 İki Ana Bileşen ile Eğitilen SVM Modeli	57
Şekil 3.33 İki Ana Bileşen ile Eğitilen SVM Modeli Karışıklık Matrisi.....	57
Şekil 3.34 İki Öznitelik ile Eğitilen SVM Modeli	58
Şekil 3.35 İki Öznitelik ile Eğitilen SVM Modeli Karışıklık Matrisi	59
Şekil 3.36 RFE 10 - PCA 2 ile Eğitilen SVM Modeli	59
Şekil 3.37 RFE 10 - PCA 2 ile Eğitilen SVM Modeli Karışıklık Matrisi	60
Şekil 3.38 RFE 5 - PCA 2 ile Eğitilen SVM Modeli	61
Şekil 3.39 RFE 5 - PCA 2 ile Eğitilen SVM Modeli Karışıklık Matrisi	61
Şekil 3.40 Özniteliklerin DT Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı.....	62
Şekil 3.41 İki Ana Bileşen ile Eğitilen DT Modeli.....	64
Şekil 3.42 İki Ana Bileşen ile Eğitilen DT Modeli Karışıklık Matrisi	64
Şekil 3.43 İki Öznitelik ile Eğitilen DT Modeli	65
Şekil 3.44 İki Öznitelik ile Eğitilen DT Modeli Karışıklık Matrisi.....	65
Şekil 3.45 RFE 5 - PCA 2 ile Eğitilen DT Modeli	66
Şekil 3.46 RFE 5 - PCA 2 ile Eğitilen DT Modeli Karışıklık Matrisi.....	67
Şekil 3.47 RFE 10 - PCA 2 ile Eğitilen DT Modeli	67
Şekil 3.48 RFE 10 - PCA 2 ile Eğitilen DT Modeli Karışıklık Matrisi.....	68
Şekil 3.49 K Sabitine Göre KNN Modeli Doğruluk Puanları	69
Şekil 3.50 Özniteliklerin KNN Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı.....	70
Şekil 3.51 İki Ana Bileşen ile Eğitilen KNN Modeli	72
Şekil 3.52 İki Ana Bileşen ile Eğitilen KNN Modeli Karışıklık Matrisi.....	73

Şekil 3.53 İki Öznitelik ile Eğitilen KNN Modeli	73
Şekil 3.54 İki Öznitelik ile Eğitilen KNN Modeli Karışıklık Matrisi	74
Şekil 3.55 SFS 10 - PCA 2 ile Eğitilen KNN Modeli	75
Şekil 3.56 SFS 10 - PCA 2 ile Eğitilen KNN Modeli Karışıklık Matrisi	75
Şekil 3.57 SFS 5 - PCA 2 ile Eğitilen KNN Modeli	76
Şekil 3.58 SFS 5 - PCA 2 ile Eğitilen KNN Modeli Karışıklık Matrisi	77
Şekil 3.59 Özniteliklerin RF Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı	78
Şekil 3.60 İki Ana Bileşen ile Eğitilen RF Modeli	80
Şekil 3.61 İki Ana Bileşen ile Eğitilen RF Modeli Karışıklık Matrisi	81
Şekil 3.62 İki Öznitelik ile Eğitilen RF Modeli	82
Şekil 3.63 İki Öznitelik ile Eğitilen RF Modeli Karışıklık Matrisi	82
Şekil 3.64 RFE 10 - PCA 2 ile Eğitilen RF Modeli	83
Şekil 3.65 RFE 10 - PCA 2 ile Eğitilen RF Modeli Karışıklık Matrisi	83
Şekil 3.66 RFE 5 - PCA 2 ile Eğitilen RF Modeli	84
Şekil 3.67 RFE 5 - PCA 2 ile Eğitilen RF Modeli Karışıklık Matrisi	85
Şekil 3.68 Özniteliklerin LR Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı	86
Şekil 3.69 İki Ana Bileşen ile Eğitilen LR Modeli	88
Şekil 3.70 İki Ana Bileşen ile Eğitilen LR Modeli Karışıklık Matrisi	88
Şekil 3.71 İki Öznitelik ile Eğitilen LR Modeli	89
Şekil 3.72 İki Öznitelik ile Eğitilen LR Modeli Karışıklık Matrisi	89
Şekil 3.73 RFE 10 - PCA 2 ile Eğitilen LR Modeli	90
Şekil 3.74 RFE 10 - PCA 2 ile Oluşturulan LR Modeli Karışıklık Matrisi	91
Şekil 3.75 RFE 5 - PCA 2 ile Eğitilen LR Modeli	92
Şekil 3.76 RFE 5 - PCA 2 ile Eğitilen LR Modeli Karışıklık Matrisi	92
Şekil 3.77 Digilent BASYS-3 FPGA Geliştirme Kartı [48]	93
Şekil 3.78 Test Sistemi Kurulumu	94
Şekil 3.79 Model Eğitim ve Test Veri Seti Oluşturma Yöntemi	95
Şekil 3.80 FPGA Tasarım Şeması	97
Şekil 3.81 SVM Modeli Karar Sınırları	98
Şekil 3.82 SVM Modeli Karışıklık Matrisi	98
Şekil 3.83 SVM Sınıflandırıcı Karar Sınırları	99

Şekil 3.84 SVM Modeli Karışıklık Matrisi	100
Şekil 3.85 FPGA RMS hesaplama Modülü Durum Şeması	102
Şekil 3.86 FPGA Ortalama hesaplama Modülü Durum Şeması.....	103
Şekil 3.87 FPGA SVM Modeli Karışıklık Matrisi	105
Şekil 3.88 Hata Tespit ve Sınıflandırma Sistemi RTL Şeması.....	106
Şekil 3.89 Veri Ayrıştırıcı Modülü RTL Şeması	107
Şekil 3.90 RMS Hesaplama Modülü RTL Şeması	107
Şekil 3.91 Ortalama Hesaplama Modülü RTL Şeması.....	107
Şekil 3.92 SVM Sınıflandırıcı Modülü RTL Şeması.....	108
Şekil 3.93 FPGA Üzerinde Hata Tespit ve Sınıflandırma Uygulaması Geliştirme Akış Şeması.....	109

ÇİZELGELER DİZİNİ

Tablo 2-1 Ekipman Durumlarıyla İlgili Parametreler [7]	8
Tablo 2-2 Ana Durum İzleme Teknikleri ve Kullanım Alanları [4]	10
Tablo 2-3 Ekipman Durum İzleme Uygulamaları [7]	10
Tablo 2-4 Elektrik Makinelerindeki Ana Arızalar ve Arıza Göstergeleri [20]	17
Tablo 2-5 Zaman Alanı Öznitelikleri [10] [11]	18
Tablo 2-6 Frekans Alanı Öznitelikleri [11]	20
Tablo 3-1 Test Düzeneği Parçaları	29
Tablo 3-2 Ham Veri Seti Sınıfları/ Hata Durumları	37
Tablo 3-3 Ham Veri Seti İçeriği	37
Tablo 3-4 SVM (C = 100, kernel = linear) Modeli Doğruluk Puanları	56
Tablo 3-5 DT Modeli Doğruluk Puanları	63
Tablo 3-6 K Sabitine Göre KNN Modeli Doğruluk Puanları	69
Tablo 3-7 KNN Modeli Doğruluk Puanları	71
Tablo 3-8 RF Modeli Doğruluk Puanları	79
Tablo 3-9 LR Modeli Doğruluk Puanları	87
Tablo 3-10 Karar fonksiyonu matrisi içeriği	104
Tablo 3-11 FPGA Tasarımı Hafıza Kullanım Raporu	108

SİMGELELER VE KISALTMALAR

Kısaltmalar

AC	<i>İng.</i> Alternating Current
ALIS	<i>İng.</i> Autonomous Logistic Information System
ANN	<i>İng.</i> Artificial Neural Networks
CBM	<i>İng.</i> Condition Based Maintenance
DC	<i>İng.</i> Direct Current
DPR	<i>İng.</i> Dynamic Partially Reconfiguration
DT	<i>İng.</i> Decision Trees
FC	<i>İng.</i> Frequency Center
FDR	<i>İng.</i> Frequency Domain Reflectometry
FFT	<i>İng.</i> Fast Fourier Transform
FPGA	<i>İng.</i> Field Programmable Gate Array
GRA	<i>İng.</i> Gray Relational Analysis
IFT	<i>İng.</i> Inverse Fourier Transform
IMF	<i>İng.</i> Intrinsic Mode Functions
KLDA	<i>İng.</i> Kernel Linear Discriminant Analysis
KNN	<i>İng.</i> K-Nearest Neighbors
LBP	<i>İng.</i> Local Binary Patterns
LDA	<i>İng.</i> Linear Discriminant Analysis
LR	<i>İng.</i> Logistic Regression
LRU	<i>İng.</i> Line Replaceable Unit
PCA	<i>İng.</i> Principle Component Analysis
PDF	<i>İng.</i> Probability Distribution Function
PNN	<i>İng.</i> Probabilistic Neural Networks

PSD	<i>İng.</i> Power Spectral Density
PSO	<i>İng.</i> Particle Swarm Optimization
RBM	<i>İng.</i> Rule Based Methods
RFE	<i>İng.</i> Recursive Feature Elimination
RMS	<i>İng.</i> Root Mean Squared
RMSF	<i>İng.</i> Root Mean Squared Frequency
RUL	<i>İng.</i> Remaining Useful Life
RVF	<i>İng.</i> Root Variance Frequency
RWE	<i>İng.</i> Relative Wavelet Energy
SDA	<i>İng.</i> Sparse Discriminant Analysis
SFS	<i>İng.</i> Sequential Feature Selection
STFT	<i>İng.</i> Short Time Fourier Transform
SOM	<i>İng.</i> Self-Organizing Map
SPHM	<i>İng.</i> Structural Prognostics and Health Management
SVM	<i>İng.</i> Support Vector Machine
TDR	<i>İng.</i> Time Domain Reflectometry
UART	<i>İng.</i> Universal Asynchronous Receiver/Transmitter
USB	<i>İng.</i> Universal Serial Bus
vd.	Ve diğ erleri

1. GİRİŞ

Teşhis, meydana gelen hasarın tanımlanmasını ve ölçülmesini içerir. Bununla birlikte, planlanmamış bakım olaylarının ve/veya etkilerinin azaltılmasına yardımcı olarak mevcut bakım politikalarının iyileştirilmesine yardımcı olabilir [1]. Bu doğrultuda durum izleme sistemi, izlenen sistemde bir hata oluştuğundan sonra, sistemin sağlıklı durumda işlemediğini tespit edebilmelidir [2]. Veriye dayalı bakım yaklaşımında bakım kararı alınırken durum izleme teknolojilerinden yararlanır [1] [2] [3].

Güvenilirliğin ön planda olduğu sistemlerin bakım yöntemi olarak veriye dayalı bakım kullanımı giderek yaygınlaşmaktadır. Veriye dayalı bakım yöntemleri kullanılan sistemlere örnek olarak enerji santralleri, dağıtım şebekeleri, toplu taşıma sistemleri, haberleşme sistemleri verilebilir [4]. Klasik bakım faaliyetleri güvenilir ve kolay olmalarına rağmen, hata sinyali veren özniteliklerin büyük oranda değişmesinden ya da ancak farklı boyutta sonuçlara sebebiyet verebilecek hataların gerçekleşmesinden sonra aksiyon alınan faaliyetlerdir. Dolayısıyla zaman içinde gelişen hataları gerçekleşmeden tespit etme konusunda ideal çözüm değildir [5]. Endüstri 4.0 konseptinin yaygınlık kazanmasıyla, düzeltici bakım uygulamaları yerine önleyici bakım uygulamalarına geçiş ihtiyacı doğmuş, bu ihtiyaç veriye dayalı bakım uygulamalarının önemini arttırmıştır [6]. Mevcut durumda veriye dayalı bakım üretim, otomotiv, demiryolu taşımacılığı, büyük iş makineleri, inşaat, tüketici elektroniği endüstrilerinde yaygın olarak kullanılan elektronik, mekanik, pnömatik, hidrolik sistemler verilebilir. Bunların yanı sıra bilgi ağlarında meydana gelebilecek sızma ve benzeri girişimlerin tespiti için de veriye dayalı bakım yöntemlerinin kullanıldığı çalışmalar literatürde mevcuttur [6]. Kablo ağlarında kazalar ve ortam şartlarından kaynaklı anomaliler gerçekleşebilmekte ve bu anomaliler veriye dayalı bakım yöntemleri ile tespit edilebilmektedir [7] [8].

Veriye dayalı bakımda bakım kararı, durum izlemeye bağlıdır ve durum izleme: “hata tespiti”, “hata sınıflandırma” ve “kalan faydalı ömür kestirimi” olmak üzere 3 ana başlıkta incelenebilir [1] [2] [3]. Durum izleme: genel sinyal edinimi, veri ön işleme, öznitelik çıkarımı, sınıflandırma, hata tespiti olarak 5 adımda gerçekleştirilir [4] [9]. Veriler önce ön işleme aşamasından geçirilerek makine öğrenmesi modeline uygun hale getirilip, eğitilen model içerisinde değerlendirilir. Bu değerlendirmenin sonucunda ekipman performansı, süreç sağlığı, ekipman ve sürece dair teşhis ve belirtilere ilişkin çıkarımlara

varılır [7]. Bu bağlamda birçok veri toplama, sinyal işleme ve makine öğrenmesi yaklaşımları mevcuttur. Literatürdeki çalışmalarda durum izleme kapsamında sıkça süreç parametreleri ölçümü, titreşim analizi, yağ analizi, ısı analiz ve akustik analiz gerçekleştirilmiştir. Titreşim analizi ile devir makinelerindeki dengesizlik, yanlış hizalama, mekanik gevşeme, rulman bozulmaları ve hatta rulman, dişli, bıçak ve benzeri mekanik parçalardaki bozulan diş, rulman topu gibi alt parçaların sayısına kadar bilgi elde edilebilmektedir. Dolayısıyla titreşim analizi mekanik sistemlerin veriye dayalı bakım çalışmalarında en sık kullanılan tekniktir [4]. Titreşim sinyalini durum izleme kapsamında makine öğrenmesi modelleriyle kullanabilmek için zaman, frekans ve zaman – frekans alanı öznitelikler kullanılmaktadır. Zaman alanı istatistiksel öznitelikler başlıca: ortalama, azami değer, asgari değer, alan, toplam, kök kare ortalama, standart sapma, varyans, basıklık, çarpıklık, tepe faktörü ve form faktörüdür [2] [10] [11] [12] [13] Frekans alanı sinyalden elde edilebilecek başlıca frekans alanı istatistiksel öznitelikleri: Frekans Merkezi (FC) Kök Kare Ortalama Frekans (RMSF) Kök Varyans Frekans (RVF) olarak sıralanabilir. Başlıca zaman – frekans alanı öznitelikleri: Kısa Süreli Fourier Dönüşümü (STFT), Dalgacık Dönüşümü ve Dalgacık Ayırımı, Ampirik Mod Ayırma Tabanlı Hilbert Huang Dönüşümü, Wigner-Ville Dağıtımını, başlıkları altında incelenebilir [11].

Veriye dayalı bakım konseptinin savunma sanayi uygulamalarına ilişkin inceleme makalelerinin ve metodolojik tanımlamaların literatürde yeterince konu alınmadığı, kestirimci bakım, prognostik ve sağlık yönetimi konularında detaylı incelemeler mevcutken, veriye dayalı bakım adımları ve bu adımlar arasındaki bağlantılara dair sınırlı bilgi sağlandığı tespit edilmiştir [1]. Ancak savunma sanayiinin kapsadığı çoğu alanda bakım yöntemleri için, sensör ve bilgi teknolojilerindeki gelişmeler doğrultusunda Durum Bazlı Bakım (*İng.* CBM) konseptlerinin öneminin giderek arttığı görülmüştür [1] [14] [41]. Ayrıca uçak parçaları gibi önemli savunma sanayii ürünleri için önleyici bakım uygulamaları plansız bakımları ele almada yetersiz kaldığı görülmüştür [1].

Bu tez çalışması kapsamında gerçek bir savunma sanayi ürünü üzerinden farklı sağlık durumlarında toplanan titreşim ve akım verilerinin zaman ve frekans alanı istatistiksel özniteliklerinden oluşan veri seti oluşturulmuştur. Elde edilen veri setiyle, SVM, DT, KNN, RF ve LR makine öğrenmesi modellerini kullanan hata sınıflandırma modelleri geliştirilmiş, her bir model için istatistiksel özniteliklerin başarımı incelenmiştir. Deney

çalışmaları sonucunda, Z eksenindeki titreşimin kök kare ortalaması (*İng.* RMS) ve akım verisinin ortalama değerini kullanan, Destek Vektör Makinesi (*İng.* SVM) tabanlı sınıflandırıcı modeli FPGA üzerinde gerçekleştirilerek test edilmiştir. Test sonucunda, eldeki veri setiyle FPGA tasarımının % 98,076 başarı oranıyla, 1 sağlıklı durum ve 5 farklı hata durumundan oluşan 6 sınıfı birbirinden ayırabildiği görülmüştür.

Tezin bir sonraki bölümünde, “Genel Bilgiler” başlığı altında veriye dayalı bakım, titreşim analizi, makine öğrenmesi teknikleri ve Savunma Sanayiinde farklı platformlar için mevcut bakım yaklaşımlarına dair literatür taramasına yer verilmiştir. 3. Kısım olan “Tez Kapsamında Yapılan Çalışmalar” başlığı altında literatür taramasında ele alınan hata sınıflandırma yöntemlerini test etmek için gerçek bir Savunma Sanayi ürünüden toplanan fiziksel veriler ve oluşturulan veri seti tanımlanmıştır. Farklı makine öğrenmesi modelleriyle geliştirilen hata sınıflandırma modelleri için özneliliklerin etkinlikleri ve modellerin başarı puanları incelenmiştir. FPGA üzerinde çok sınıflı SVM sınıflandırma modeli geliştirme adımları tanımlanmış, FPGA geliştirme kartı üzerinde gerçekleştirilen testlerin sonuçlarına yer verilmiştir. Son kısımda “Sonuçlar ve Tartışma” başlığı altında FPGA üzerinde hata sınıflandırma uygulaması geliştirme adımları tanımlanmış, gelecek çalışmalara dair öngörüler verilmiştir.

2. GENEL BİLGİLER

Bu bölümde veriye dayalı bakım önde olmak üzere bakım yöntemleri, durum izleme konsepti çerçevesinde titreşim analizi, makine öğrenmesi, kullanım alanları ve FPGA teknolojisi hakkındaki literatür taraması bulgularına yer verilmiştir.

2.1 Bakım Yöntemleri

Literatürde bakım yöntemleri uygulanış biçimlerine göre 3 ana gruba ayrılır. Bu gruplar: düzeltici bakım, önleyici bakım ve kestirimci bakım gibi veriye dayalı bakım yaklaşımları olarak adlandırılır [4] [10] [15].

Düzeltilici bakım plansız bakım konseptidir ve sistem bozulana kadar bakım faaliyeti uygulanmaz. Ancak bozulduktan ya da sensör ölçümleri kritik seviyelere ulaştıktan sonra sistemi eski durumuna getirmek için düzeltici faaliyetler uygulanır. Ucuz ve kolay bir yöntem olsa da kritik makinelerin bakım konsepti olarak değerlendirilemez [4] [10] [15] [16].

Önleyici bakım planlı ve periyodik bir bakım türüdür. Sistemlerin zaman içindeki bozulmalarını periyodik olarak düzelterek sistemin genel durumunu iyi seviyede tutmayı amaçlar. Önleyici bakım planlaması maliyet, zaman ve hata göz önünde bulundurularak gerçekleştirilir. Ancak yine de yüksek üretim adedi beklentisi olan sistemlerde harcanacak para ve zaman göz önünde bulundurularak bakım çalışmaları göz ardı edilebilmektedir. Bakım çalışmasının aksatılmadan yapıldığı durumda bile arızalar beklenenden erken gerçekleşip büyük kayıplara yol açabilir. Aynı zamanda gerek olmayan durumlarda da bakım çalışması yapılabilmekte dolayısıyla zaman ve para kaybı söz konusu olmaktadır [4] [10] [15] [17].

Veriye dayalı bakım modern ölçüm ve sinyal işleme metotlarından yararlanır. Bu bakım konseptinde bakım faaliyeti yürütme kararı sistemden toplanan verilerle devamlı olarak sistem durumunu gözleyen veriye dayalı modeller tarafından alınır. Dolayısıyla bakım gerektirmeyen durumlarda gereksiz faaliyetlerin yürütülmesinin önüne geçilmiş, kritik sorunlara yol açabilecek hatalar erkenden tespit edilmiş ve anlık gerçekleşen hataların kaynağı tanımlanmış olur. Veriye dayalı bakım konseptinin dezavantajı başlangıçta diğer bakım konseptlerine göre daha fazla yatırım gerektirmesidir [4] [10] [15]. Literatürdeki

güncel çalışmalar maliyet ve fayda göz önünde bulundurulduğunda önleyici ve veriye dayalı bakım faaliyetlerinin düzeltici bakım faaliyetlerden daha etkili olduğunu göstermiştir. Bunun sebebi olarak kurulum maliyetinin yüksek olmasına rağmen, makine arızalarından ya da hatalı üretimlerden doğacak maliyetlerin önüne geçmeleriyle toplamda karlı bakım yöntemleri olmaları gösterilmiştir [18].


Klasik bakım faaliyetleri güvenilir ve kolay olmalarına rağmen, hata sinyali veren özneliklerin büyük oranda değişmesinden ya da ancak farklı boyutta sonuçlara sebebiyet verebilecek hataların gerçekleşmesinden sonra aksiyon alınan faaliyetlerdir. Dolayısıyla zaman içinde gelişen hataları gerçekleşmeden tespit etme konusunda ideal çözüm değillerdir [5]. Özellikle İkinci Dünya Savaşı yıllarında, Yöneylem Araştırması alanındaki gelişmelerin sonucunda veriye dayalı bakım çalışmalarının önü açılmıştır [19]. Endüstri 4.0 konseptinin yaygınlık kazanmasıyla, düzeltici bakım uygulamaları yerine önleyici bakım uygulamalarına geçiş ihtiyacı doğmuş, bu ihtiyaç veriye dayalı bakım uygulamalarının önemini arttırmıştır [6].

2.2 Veriye Dayalı Bakım

Bu bölümde durum izleme yöntemlerinden, kullanım alanından, durum izleme kapsamında sıkça kullanılan titreşim analizi ve makine öğrenmesi tekniklerinden bahsedilmiştir.

Makine arızalarının 99%'luk büyük bir bölümü oluşmadan önce belirli göstergeler aracılığıyla erken uyarı verir. Durum izleme bu göstergeleri düzenli ve sürekli takip ederek arızaların erken tespitini gerçekleştirmede yardımcı olur. Bunun yanı sıra veriye dayalı bakım, çalışan ve çevre güvenliğini artırması, yüksek güvenilirlik ve ulaşılabilirliğe sahip olması, fabrika ortamında kullanıldığı zaman ürün kalitesinde pozitif etki yapması, parça ve işçilikten tasarruf sağlaması, makinelerde enerji tasarrufu sağlaması gibi birçok avantaja sahiptir. Dolayısıyla, güvenilirliğin ön planda olduğu sistemlerin bakım yöntemi olarak veriye dayalı bakım kullanımı giderek yaygınlaşmaktadır. Veriye dayalı bakım yöntemleri kullanılan sistemlere örnek olarak enerji santralleri, dağıtım şebekeleri, toplu taşıma sistemleri, haberleşme sistemleri verilebilir [4]. Tüm bunlarla beraber makine prognostiği alanında yapılan araştırmalar Şekil 2.1 içerisinde görüleceği üzere yıllar içerisinde artarak devam etmiş ve 2019 yılında en yüksek seviyeye ulaşmıştır. Sonrasında düşüş görülse de hala çok sayıda çalışma


yapılmaya devam etmektedir. Şekil 2.1 içerisindeki veriler IEEE Xplore internet sitesinde “machine prognostics” anahtar kelimesini aratıp yıllara göre makale sayılarını kaydederek elde edilmiştir.



Şekil 2.1 Son 20 Yılda Makine Prognostiği Alanında Yapılan Çalışma Sayıları

Literatürde “Durum Tabanlı Bakım” (*İng.* CBM) olarak da adlandırılan veriye dayalı bakım yöntemleri veri toplama ve işleme tekniklerine göre aktif ve pasif olarak iki grupta değerlendirilir. Aktif yöntemlerde test edilen sisteme bakım ekipmanı tarafından sinyal gönderilerek yansıyan sinyallerin analiz edilmesi yoluyla performans değerlendirmesi yapılır. Pasif yöntemlerde sistemde mevcut olan ya da bakım uygulaması için sonradan yerleştirilen sensör verileri kullanılarak performans değerlendirmesi yapılır. Pasif yöntemlerde test edilen sisteme sinyal göndermek gibi herhangi bir dış müdahalede bulunulmaz [7].

Veriye dayalı bakımda temel yaklaşım bakım faaliyetini bakım ihtiyacı doğduğunda gerçekleştirmektir. Bakım ihtiyacı olduğu kararını verebilmek için makinenin geçmiş ve şimdiki durumunun bilinmesi gerekmektedir. Genel karar modeli diyagramı Şekil 2.2 içerisinde şematize edilmiştir.



Şekil 2.2 Genel Karar Modeli Diyagramı [20]

Makine durumunun tespit edilmesi ve sađlık durumu parametrelerinin ölçülmesini sađlamak amacıyla: dönüştürücüler, sinyal koşullayıcılar, veri edinim sistemleri, sinyal analiz sistemleri ve teşhis yazılımları kullanılır. Bu sistemler ve sađlık parametrelerinin ölçülmesi işlemi bir arada durum izleme olarak adlandırılır [21]. Literatürdeki çalışmalarda durum izleme kapsamında sıkça, süreç parametreleri ölçümü, titreşim analizi, yağ analizi, ısıl analiz ve akustik analiz gerçekleştirilmiştir [4].

Titreşim analizi erken uyarı verme konusunda başarılıdır ve sadece %8 yanlış alarm oranına sahiptir. Titreşim analizi ile devir makinelerindeki dengesizlik, yanlış hizalama, mekanik gevşeme, rulman bozulmaları ve hatta rulman, dişli, bıçak ve benzeri mekanik parçalardaki bozulan diş, rulman topu gibi alt parçaların sayısına kadar bilgi elde edilebilmektedir. Bu sebeplerden dolayı titreşim analizi mekanik sistemlerin durum izleme çalışmalarında en sık kullanılan tekniktir [4].

Titreşim analizi ile kombine şekilde kullanılabilen yağ analizi ile aşındırıcı, yapışkan, kesme, yorulma kayma aşınmaları, kavitasyon, parçacık sayısı, su içeriđi, viskozite, katı içeriđi, asit ve baz numarası tespit edilebilmektedir [4]. Makine arızasının emareleri titreşim profiline kolaylıkla yansır. Bu sebeple devir makinelerinin durum izleme uygulamalarında sıklıkla titreşim verisi kullanılmaktadır [22].

Termal analiz ile gevşek ya da paslanmış elektrik bağlantısı, ısıtma, havalandırma ve iklimlendirme sistemlerindeki kaçaklar, mekanik gevşeklik, yükleme sorunları ve bileşen hataları tespit edilebilir [4].

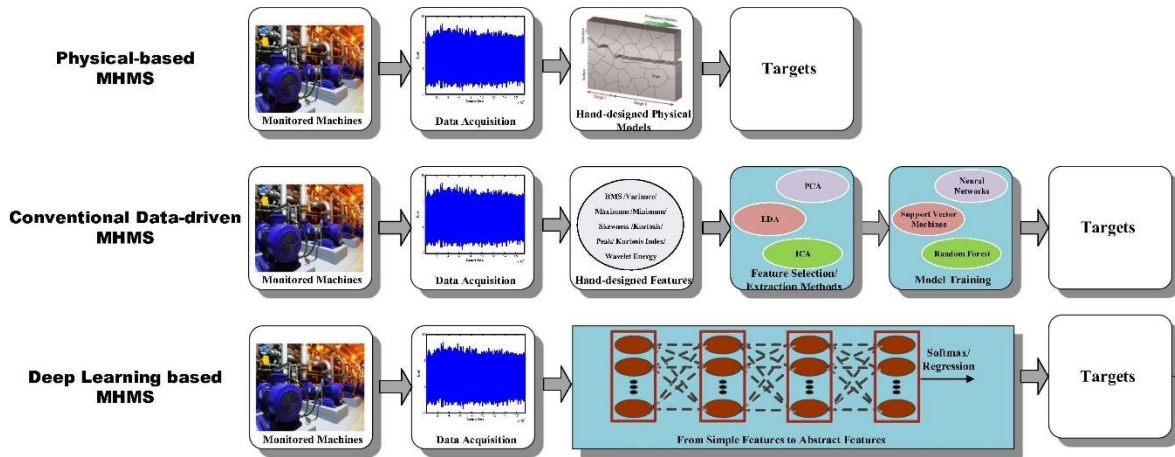
Akustik analiz ile basınç ve vakum sistemlerindeki kaçak, rulman sorunları, tanklarda ve boru sistemlerinde conta bütünlüğü, pompa kavitasyonları, şalt tertibatında korona deşarjı, kompresör vana analizi, elektrik arkı tespit edilebilir [4].

Durum izleme yöntemi, işlemin gerçekleştirileceđi sisteme göre şekillenir. Bu noktada belirleyici unsur elektromekanik sistemde var olan alt sistemler ve bunlardan toplanabilecek verilerdir. *Hashemian* [7], kestirimci bakımdaki yaygın yöntemleri derlediđi makalesinde elektromekanik sistemler içerisinde bulunan alt sistemler ve bu alt sistemlerden durum izleme için toplanabilecek parametreleri, Tablo 2-1 içerisinde verilen tabloda derlemiştir.

Tablo 2-1 Ekipman Durumlarıyla İlgili Parametreler [7]

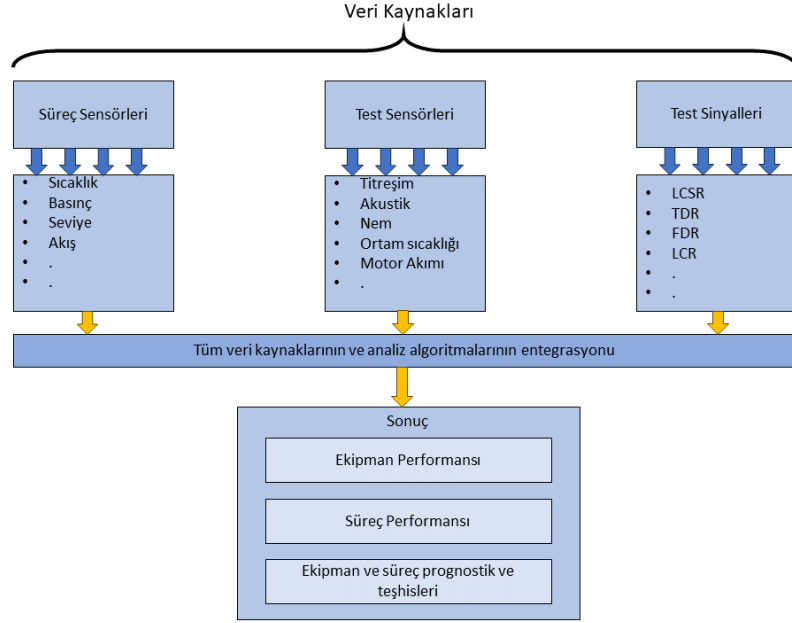
Ekipman	Titreşim	Nem	Ortam Sıcaklığı	Ortam Basıncı	Akustik Sinyal	Termografi	Motor Akımı	Yalıtkan Direnci	Elektriksel Kapasitans	Elektriksel İndüktans
Pompa	✓		✓	✓	✓	✓		✓		
Valf		✓		✓	✓					
Motor/Fan	✓		✓	✓	✓		✓	✓		✓
Isı Değiştirici	✓	✓	✓	✓	✓					
Buhar Türbini	✓	✓	✓	✓	✓					
Elektriksel & Elektronik Ekipman			✓			✓		✓	✓	✓
Kablo ve Konektörler			✓			✓		✓	✓	✓
Pompa Contası		✓		✓	✓			✓		
Borular / Yapılar	✓				✓					
Kompresör	✓				✓	✓	✓			

Veriye dayalı bakım kapsamında karar almada kullanılan anlamlı bilgileri edinme adımı olan durum izleme genel sinyal edinimi, veri ön işleme, öznelik çıkarımı, sınıflandırma, hata tespiti olarak 5 adımda gerçekleştirilir [4] [9]. Veriler önce ön işleme aşamasından geçirilerek makine öğrenmesi modeline uygun hale getirilip, eğitilen model içerisinde değerlendirilir. Bu değerlendirmenin sonucunda ekipman performansı, süreç sağlığı, ekipman ve sürece dair teşhis ve belirtilere ilişkin çıkarımlara varılır [7]. Literatürde farklı çalışmalar arasında en çok değişiklik gösteren unsur veri işleme yöntemidir. Veri işleme yöntemleri Şekil 2.3 içerisinde gösterildiği gibi: fiziksel model tabanlı, konvansiyonel veri işleme teknikleri ve derin öğrenme teknikleri olarak sınıflandırılmaktadır [23].



Şekil 2.3 Veri İşleme Yöntemine Göre Durum İzleme Uygulamaları [23]

Aşağıda verilen Şekil 2.4 içerisinde mevcut süreç parametreleri, pasif test sensörlerini ya da aktif test sinyallerini kullanarak gerçekleştirilen durum izleme akışı şematize edilmiştir.



Şekil 2.4 Durum İzleme için Üç Tekniği Kullanan Gömülü Sistem [7]

Titreşim, basınç, sıcaklık ve benzeri sensörlerden toplanan zaman serisi verilerde AC ve DC bileşenler bulunmaktadır. DC bileşeni, sürüklenme (*İng.* drift) kontrolü yapmak amacıyla kullanılırken, çıkışın AC bileşeni (gürültü) sensörün dinamik performansını doğrulamak ve algılama hattında tıkanıklıkları belirlemek için kullanılır. Dinamik performans parametrelerine örnek olarak tepki süresi verilebilir. Gürültü bileşeni analizi genellikle Hızlı Fourier Dönüşümünün (*İng.* FFT) yapılmasını içerir. Sonuçlar, AC sinyalinin Güç Spektral Yoğunluğu (*İng.* PSD) olarak bilinen bir spektrum şeklinde sunulur. Veriye dayalı bakımın kullanım alanlarından biri olan Çevrimiçi Kalibrasyon İzleme’de DC bileşen kullanılır. DC bileşendeki olağan dışı sürüklenme tespit edilerek kalibrasyona ihtiyaç duyan sensörler tespit edilir. Bu yöntemle sistem içerisindeki kalibrasyona tabii parçaların tümünü periyodik olarak kalibre etmek yerine, sadece normalden sapmalara uğrayan parçaları kalibre ederek zaman ve maliyet tasarrufu sağlanabilmektedir [7].

2.2.1 Veriye Dayalı Bakım Kullanım Alanları

Veriye dayalı bakım birçok kullanım alanına sahiptir. Bunlara örnek olarak: üretim, otomotiv, demiryolu taşımacılığı, büyük iş makineleri, inşaat, tüketici elektroniği endüstrilerinde yaygın olarak kullanılan elektronik, mekanik, pnömatik, hidrolik sistemler verilebilir. Bunların yanı sıra bilgi ağlarında meydana gelebilecek sızma ve

benzeri girişimlerin tespiti için de veriye dayalı bakım yöntemlerinin kullanıldığı çalışmalar literatürde mevcuttur [6].

Selçuk [4], kestirimci bakım tekniklerini incelediği makalesinde elektromekanik sistemlere göre durum izlemede kullanılacak analiz yöntemlerini Tablo 2-2 içerisinde toplamıştır.

Tablo 2-2 Ana Durum İzleme Teknikleri ve Kullanım Alanları [4]

Teknolojiler/ Uygulamalar	Pompalar	Elektrik Motorları	Dizel Jeneratörler	Kondenseler	Ağır Ekipmanlar/ Vinçler	Devre Kesiciler	Valfler	Isı Değiştiricileri	Elektriksel Sistemler	Transformatörler	Tanklar, Borular
Titreşim İzleme/ Analizi	✓	✓	✓		✓						
Yağlayıcı, Yakıt Analizi	✓	✓	✓		✓						✓
Açınma Partikül Analizi	✓	✓	✓		✓						
Rulman Sıcaklığı Analizi	✓	✓	✓		✓						
Performans İzleme	✓	✓	✓	✓				✓	✓		✓
Ultrasonik Gürültü Tespiti	✓	✓	✓	✓			✓	✓			✓
Ultrasonik Akış	✓			✓			✓	✓			
Kızılötesi Termografi	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Tahratsız Test				✓			✓	✓			✓
Görsel Muayene	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Yalıtkan Direnci		✓	✓			✓	✓	✓	✓	✓	
Motor Akım İmzası Analizi		✓									
Motor Devre Analizi		✓				✓			✓		
Polarizasyon Endeksi		✓	✓						✓		
Elektriksel İzleme									✓	✓	

Endüstrilere göre veriye dayalı bakım uygulama alanları Tablo 2-3 içerisindeki tabloda verilmiştir.

Tablo 2-3 Ekipman Durum İzleme Uygulamaları [7]

Endüstri	Proses optimizasyonu	Çalışan Güvenliği	Ekipman Sağlığı	Emisyon İzleme	Proses Teşhisi	Ekipman Performansı	Kaçat Tespiti	Kalibrasyon Doğrulama
Kimyasal	✓	✓	✓	✓	✓	✓	✓	✓
Petrokimya Rafineri	✓	✓	✓	✓	✓	✓	✓	✓
Kağıt Hamuru ve Kağıt Üretim	✓		✓		✓	✓		✓
Proses Tesisleri	✓	✓	✓	✓	✓	✓	✓	✓
Güç Üretimi	✓	✓	✓	✓	✓	✓	✓	✓
Eczacılık			✓			✓		✓
Alüminyum/ Metal		✓	✓		✓	✓		
Sağlık Hizmeti	✓	✓	✓			✓		✓
Savunma Sanayii		✓	✓		✓	✓		

Veriye dayalı bakım kullanımı devir makineleriyle sınırlı değildir. Örneğin modern sistemler için çok önemli olan kablo ağlarının bakım yöntemi olarak da veriye dayalı bakım kullanılmaktadır. Kablo ağlarında kazalar ve ortam şartlarından kaynaklı anomaliler gerçekleşebilmekte ve bu anomaliler durum izleme yöntemleri ile tespit edilebilmektedir [7] [8]. Aktif durum izleme yöntemleri kablo anomalilerinin tespiti için uygun yöntemlerdir. Aşağıda aktif kablo anomali tespit yöntemleri sıralanmıştır [7]:

- Sıcaklık sensörlerine gönderilen sinyalin tepki süresi analizi (LCSR tekniği).
- Zaman Alanı Reflektometrisi (*İng.* TDR) yöntemiyle kestirim uygulanacak kabloya sinyal gönderip yansıyan sinyalin belirli referans değerler ile karşılaştırarak empedans değişiminin tespit edilmesi yoluyla kablo açık devre, kısa devre, şant, nem girişi gibi anomalilerin ve yerlerinin tespiti.

- Kablo indüktans(L), kapasitans(C) ve direnç(R) değerleriyle LCR testi gerçekleştirip, Zaman Alanı Reflektometrisi yöntemiyle birlikte kablo yalıtımındaki kusurların tespiti.
- Frekans Alanı Reflektometrisi (*İng.* FDR) ve Ters Fourier Dönüşümü (*İng.* IFT) ile polimer yalıtımlı kabloların yalıtımı bozulan bölgelerinin tespiti [24].

Veriye dayalı bakımın kullanım alanlarından bir diğeri de Çevrimiçi Kalibrasyon İzleme'dir. Bu yöntemle sistem içerisindeki kalibrasyona tabi parçaların tümünü periyodik olarak kalibre etmek yerine, sadece normalden sapmalara uğrayan parçaları kalibre ederek zaman ve maliyet tasarrufu sağlanabilmektedir [7].

2.2.2 Hata Tespiti

Bozuluma uğrayan sistemlerin erken aşamada hata tespiti mümkün olabilir. Bozulma performans, güvenilirlik ve ömür süresini etkileyen geri alınamaz bir süreç olması sebebiyle hata durumu büyür ve daha büyük hata durumlarına sebebiyet verir. Dolayısıyla hatanın, mümkünse, erken aşamada tespiti sistemin yaşam süresini uzatmak açısından önemlidir [25].

Durum izleme sistemi, izlenen sistemde bir hata oluştuğundan sonra, sistemin sağlıklı durumda işlemediğini tespit edebilmelidir. Hata tespiti, hata sınıflandırması için bir önkoşul olmalıdır [2].

Regresyon ile durum izleme yapılabilir. Sistemden sağlıklı durumda toplanan verilerle regresyon modeli oluşturularak sinyallerin ve özneliklerin sağlıklı durumda farklı bileşen çıktılarıyla olan ilişkisi açığa çıkarılır. Yeni gelen veri bu modelle karşılaştırılır ve ardışık ölçümlerde sağlıklı sistem regresyon modelinden sapmalar tespit edilirse alarm verilir. Doğrusal modelden karmaşık doğrusal olmayan modellere kadar farklı regresyonlarla farklı detay seviyelerinde davranışlar yakalanabilir [2].

2.2.3 Hata Sınıflandırma

Tüm makine arızaları erken aşamada tespit edilir olmayabilir. Bu durumda hataları gerçekleşmeden tespit etmek kadar, gerçekleşen hataları sınıflandırmak, hata sonrasında aksiyon almayı hızlandıracağından bakım konsepti için oldukça önemlidir. Sistemlerden

farklı hata durumlarında veri toplanıp bu verilerden makine öğrenmesi teknikleriyle sınıflandırma modelleri oluşturulması ve aynı hata durumlarının ileriki zamanlarda tekrarlanması durumunda hata durumunu tespit etmek mümkündür. Teşhis, meydana gelen hasarın tanımlanmasını ve ölçülmesini içerir. Bununla birlikte, planlanmamış bakım olaylarının ve/veya etkilerinin azaltılmasına yardımcı olarak mevcut bakım politikalarının iyileştirilmesine yardımcı olabilir [1].

Aldeoes vd. [26], rulman arıza sınıflandırması için farklı makine öğrenmesi tekniklerini karşılaştırdıkları çalışmalarında Karar Ağaçları (*İng.* DT), Destek Vektör Makinesi (*İng.* SVM), K-En Yakın Komşu (*İng.* KNN), Topluluk Öğrenmesi ve Yapay Sinir Ağları (*İng.* ANN) metotlarını karşılaştırmış ve her bir arıza durumu için bu metotların başarımlarını incelemiştir. *Saha vd.* [27], kurdukları deney düzeneğini 4 farklı sağlık durumundaki rulman ile çalıştırıp, topladıkları titreşim verisini SVM ile sınıflandırmıştır. SVM başarımlarını Parçacık Sürüsü Optimizasyonu (*İng.* PSO) ile geliştirmiş ve bu modeli klasik KNN, DT ve Doğrusal Diskriminant Analizi (*İng.* LDA) ile karşılaştırmıştır. PSO-SVM modelinin diğer modeller karısındaki başarılı geldiği gösterilmiştir. *Soofi vd.* [28], Bayes Ağı, KNN, DT ve SVM tekniklerini, bu tekniklerin uygulama ve sorunlarını inceledikleri makalelerinde titreşim analizi ile elektromekanik sistemlerin hata sınıflandırmasında SVM kullanımı tercih edildiğini tespit etmiştir. *Banerjee vd.* [29], makalelerinde SVM ve Kısa Süreli Fourier Dönüşümü tekniklerini birlikte kullanarak sensör veri füzyonuna dayalı arıza sınıflandırma modeli tasarlamış, bu modelin kolay geliştirilebilmesi ve %95 oranındaki doğruluğu bakımından karmaşık elektromekanik sistemler için uygulanabilir olduğunu belirtmiştir. *Kuncan* [30], kurduğu test düzeneğinde farklı rulman hatalarına sahip konfigürasyonları, farklı dönüş hızlarıyla çalıştırarak 4 farklı veri seti elde etmiştir. Titreşim sinyallerinden 1-Boyutlu Yerel İkili Model (*İng.* 1D-LBP) sinyalleri elde etmiş ve istatistiksel öznitelik çıkarımını 1D-LBP sinyalleri üzerinden yapmıştır. Elde ettiği özniteliklerle Gri İlişkisel Analiz (*İng.* GRA), KNN, ANN, SVM, LDA ve Doğrusal Regresyon (*İng.* LR) sınıflandırıcılarının başarımlarını incelemiştir. Modellerin 4 farklı veri setindeki başarımlarının ortalamalarının GRA: %100, KNN: %89,755, ANN %90,112, SVM: %91,58, LDA: %90,545 ve LR: %88,382 olduğu görülmüştür. *Pacheco-Cherrez vd.* [12], Autoencoder, Üretken Rekabet Ağları (*İng.* GAN) ve SVM metotlarının arıza sınıflandırma literatüründe sıkça rastlanan ML metotları olduğunu tespit ettikleri çalışmalarında ses ve titreşim verilerini kullanarak sınıflandırma yapmıştır. Sınıflandırma için zaman ve frekans alanı özniteliklerini çıkarıp, bu öznitelikleri birlikte kullanmış ve

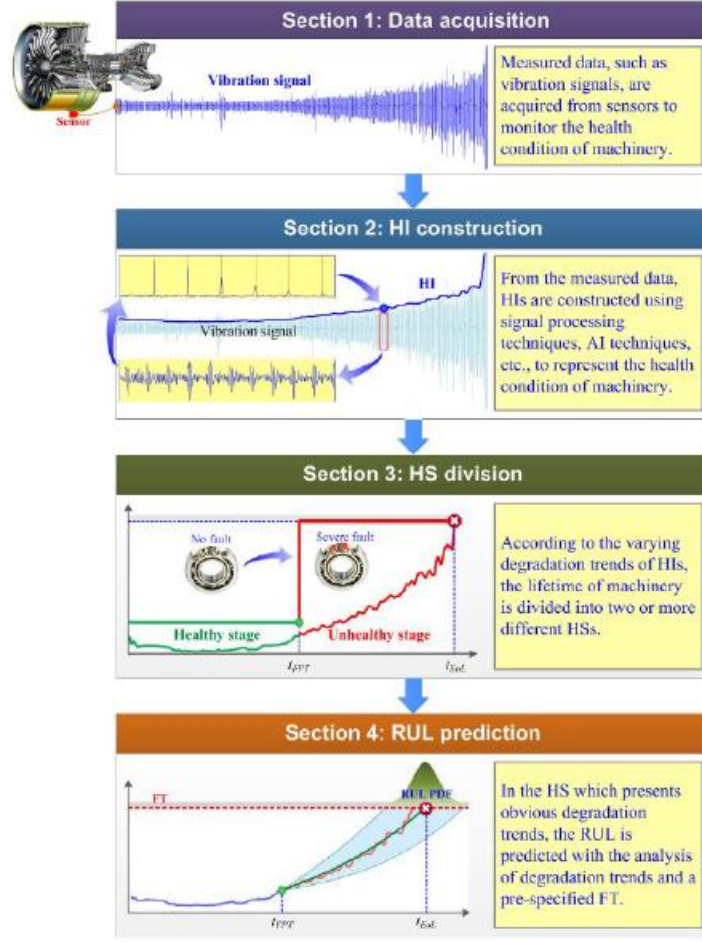
SVM, RWE ve LDA sınıflandırıcı modellerle testler gerçekleştirilmiştir. Testlerde en iyi sonuca akustik sinyal özniteliklerinin kullanan RWE sınıflandırıcının %96,79'luk başarımla en iyi performansı gösterdiği, SVM sınıflandırıcının %96,66 oranında olduğu ve sadece zaman alanı titreşim özniteliklerini kullanan LDA sınıflandırıcının literatürdeki tipik başarımla sayılan %95'lik başarımla altında kaldığı tespit edilmiş, *Altaf vd.* [31], çalışmalarında kurdukları, 4 farklı hata modu içeren test düzeneğinden topladıkları ses sinyallerini, zaman, frekans ve zaman-frekans alanı öznitelikleri çıkarmada kullanmışlardır. Öznitelikleri hesaplanan ses sinyalleri daha sonra KNN, SVM, Kernel Doğrusal Diskriminant Analizi (*İng.* KLDA) ve Seyrek Diskriminant Analizi (*İng.* SDA) metotlarıyla sınıflandırılmış ve bu metotların başarımları incelenmiştir. Çalışmada alan özniteliklerinin ayrı ayrı başarımları incelenmiş ve tek başına zaman alanı öznitelikleri kullanımının başarılı olmadığı, en yüksek başarımla KLDA sınıflandırıcı %66,2 seviyesinde olduğu tespit edilmiştir. Tek başına frekans alanı öznitelikleri kullanıldığında SDA sınıflandırıcı ile %98,6, tek başına zaman-frekans alanı özniteliklerle en yüksek başarımla yine KLDA sınıflandırıcı ile %81,9 olarak tespit edilmiştir. Çalışma grubu ses sinyalini bant-geçiren filtreden geçirerek KLDA başarımla oranını %99,1'e çıkartmıştır. *Dou vd.* [13], çalışmalarında 3 farklı hata durumu içeren (iç bilezik kusuru, dış bilezik kusuru, yuvarlanma elemanı kusuru) rulmanlardan toplanmış titreşim verilerinden zaman ve frekans alanı öznitelikleri çıkarmış, bu öznitelikleri kullanan KNN, PNN, PSO-SVM sınıflandırıcıları ve bir Kural Tabanlı Metot (RBM) ile başarımlarını incelemiştir. Çalışmanın sonucunda iki farklı veri seti için model başarımla sıralamasının değişmemesine rağmen, başarımlarının değiştiği gözlemlendi başarımla sırasının başarılıdan başarısız gidecek şekilde: PSO-SVM, Kural Tabanlı Yöntemler (*İng.* RBM), PNN, KNN olduğu belirtilmiştir. *Kotsiantis vd.* [32], makine öğrenmesiyle sınıflandırma tekniklerine dair detaylı incelemeler içeren makalelerinde, sınıflandırma tekniklerini karşılaştırırken dikkat edilmesi gereken asıl konunun bir öğrenme algoritmasının diğerlerine üstün olup olmaması değil, belirli bir yöntemin verilen bir uygulama problemi üzerinde diğerlerini önemli ölçüde geride bırakabilmesi olduğunu belirtmiştir.

Literatür araştırmasında makine öğrenmesi metotlarının başarımlarının, veri setine bağlı olduğu gözlemlenmiştir. Bu sebeple literatürde sıkça karşılaşılan makine öğrenmesi modelleri, bu tez çalışması kapsamında elde edilen veri seti ile test edilmiş ve en yüksek

başarımı gösteren SVM metodu seçilerek FPGA tabanlı hata tespit ve sınıflandırma tasarımına dahil edilmiştir.

2.2.4 Kalan Faydalı Ömür Tespiti

Bir durum izleme tekniği olan kalan faydalı ömür analizinde kullanılan en popüler üç model: benzerlik modeli, hayatta kalma modeli ve bozulma modelidir. Benzerlik modelinin oluşturulabilmesi için sağlıklı referans sistemden hatalı sisteme geçiş aşamasındaki benzer sistemlerin verileri mevcut olmalıdır. Benzer bir şekilde hayatta kalma modelinin oluşturulabilmesi için hatalı sistem verisinin mevcut olması gerekmektedir. Bu üç model arasında en popüler olan bozulma modelinin oluşturulabilmesi için yine sağlıklı sistemden hatalı sisteme geçiş aşamasındaki verilere ihtiyaç duyulmaktadır [10]. Kalan faydalı ömür analizi 4 adımda incelenen bir süreçtir. Bu adımlar Şekil 2.5 içerisinde gösterildiği gibi: veri edinimi, sağlık göstergelerinin oluşturulması, sağlıklı durum aşamasının belirlenmesi ve kalan faydalı ömür kestirimi olarak isimlendirilir [3].



Şekil 2.5 Kalan Faydalı Ömür Analizi Aşamaları [3]

Lei vd. [3], veri toplama işleminden kalan faydalı ömür kestirimine kadar tüm süreci ele aldıkları inceleme makalelerinde, bu 4 aşamayı ayrı ayrı incelemiştir. Durum izleme için gerekli temel bilgilerin elde edilmesi ve depolanması adımı olan veri edinimi adımı, izlenen sistemin üzerinden farklı sensör verileri toplanır. Bunun için gerekli veri edinim sistemi sensörlerden, veri iletim cihazlarından ve depolama cihazlarından oluşur. Genellikle ivmeölçerler, akustik sensörler, kızılötesi ısıölçerler, akım sensörü gibi sensörler kullanılır. Sağlık göstergesi oluşturma, prognostik model tasarımını basitleştirmek ve bu tasarımın doğruluk puanını arttırmak için önemli bir adımdır. Sensörlerden toplanan veriler makinenin sağlık durumuna ilişkin birçok bilgi içerir. Ancak makinenin bozulma sürecinin takip edilebilmesi için RMS, basıklık, çarpıklık gibi sağlık göstergeleri çıkarılmalıdır. Sağlık göstergeleri fiziksel ve sanal olarak ikiye ayrılabilir. RMS, basıklık gibi sensör verisinden istatistiksel olarak doğrudan elde edilebilen göstergeler fiziksel göstergeler sınıfına girer. Popüler bir boyut küçültme yöntemi olan PCA, Kendini Düzenleyen Harita (*Ing.* SOM), Mahalanobis Uzaklığı sanal

göstergeler arasında gösterilmiştir. Makinelerin sağlık göstergeleri genellikle arıza şiddetinin gelişmesiyle birlikte değişen bozulma eğilimleri sunar. Kalan faydalı ömür tahmininden önce makinelerin bozulma süreçleri, sağlık göstergelerinin değişen eğilimlerine göre farklı sağlık durumlarına bölünmelidir. Böylelikle Sağlık göstergelerinin sağlık bölümlerinin hangisi içinde kaldığına bakarak makinenin sağlık durumuna ilişkin çıkarım yapılabilir. Son adım olan kalan faydalı ömür kestirimi “mevcut zamandan faydalı ömrünün sonuna kadar olan süre” olarak tanımlanmıştır. Kalan faydalı ömür kestirimi için, fiziksel model tabanlı yaklaşımlar, istatistiksel model tabanlı yaklaşımlar, otoresif model yaklaşımları, rastgele katsayı modeli yaklaşımları, Wiener süreci modeli yaklaşımları gibi birçok yaklaşım mevcuttur.

2.2.5 Titreşim Analizi

Bir devir makinesi arıza ile karşılaştığı zaman bu arıza titreşim karakterinin referans değerinden sapmalara yol açar. Hata imzası olarak adlandırılan bu sapmalar sinyal işleme ve makine öğrenmesi yöntemleriyle değerlendirilip makinenin sağlık durumuyla ilgili karar almada kullanılabilir [13]. Elektrik motoru, kompresör, fan, türbin, pompa ve benzeri devir makineleri titreşim kaynaklı birçok makine arızası ile karşılaşabilir. Titreşimden kaynaklanan bu arızalar aynı zamanda titreşim profilini de etkilediğinden titreşim verisiyle arıza tespiti yapmak mümkündür. Dolayısıyla, devir makinelerinin sağlık durumlarının takibi için titreşim analizi önemli bir analiz yöntemidir. Bu arızalar aşağıda sıralanmıştır [10]:

- Kayış hasarı ve uyumsuzluk,
- Milin yanlış hizalanması,
- Kasnak eksantrikliği,
- Rulman hataları,
- Rulman yatağının bozulması,
- Şaftta çatlama,
- Dişli aşınması,
- Rulman iç yatak aşınması,
- Rulman dış yatak aşınması,

- Mekanik gevşeklik,
- Zayıf yağlama,
- Yer titreşimi,
- Bükülmüş mil,
- Komşu makine üzerindeki etki,
- Aerodinamik kuvvetler,
- Sürtünme.

Kudelina vd. [20], makalelerinde hata sinyallerini ve bu sinyallerin en kullanışlı olduğu hataları derledikleri Tablo 2-4 içerisinde verilen tabloda titreşim sinyalinde bulunan hata sinyallerinin en kapsayıcı sinyaller olduğunu ortaya koymuşlardır. Titreşim sinyali sargı kısa devresi, kırık rotor çubuğu ve eksantriklikte hatalarında başarılı sonuç verirken rulman hatalarında en başarılı sonucu verdiği ve tablodaki hiçbir hata durumunda başarısız sonuç vermediği görülmektedir.

Tablo 2-4 Elektrik Makinelerindeki Ana Arızalar ve Arıza Göstergeleri [20]

Hata Göstergeleri	Sargı Kısa Devresi	Kırık Rotor Çubukları	Eksantriklik	Rulman Hataları
Titreşim	✓	✓	✓	●
Akım	●	●	✓	●
Sıcaklık	✓	✓	✓	X
Manyetik Akı Değişimi	●	●	●	✓
Kimyasal Analiz	✓	X	X	X
Tork Değişimi	●	●	✓	X
Simgeler	Anlamları			
●	Durum izleme için en sık tercih edilen parametre.			
✓	Parametre durum izleme için kullanılabilir.			
X	Parametre durum izleme için kullanılamaz.			

Titreşim analizi, dişli ve rulman gibi makine parçalarında karşılaşılan hataların tipini ve boyutunu belirlemede kullanılan en yaygın analiz yöntemidir [26] [27]. Makine öğrenmesi teknikleriyle titreşim analizi yapmak için titreşim verisinden öznitelik çıkarımı yapılmalıdır. En kolay elde edilen titreşim verisi zaman serisi titreşim verisidir [10]. Öznitelik çıkarımı çok boyutlu zaman serisi sinyalinin boyutunu, sinyalin ayırt edici niteliklerini kaybetmeden azaltmak, sinyali gürültü ve korelasyonlardan arındırmak için gereklidir [33]. Zaman serisi titreşim verisinden zaman alanı öznitelikleri çıkarılmaktadır. Zaman alanındaki veriden Hızlı Fourier Dönüşümü (FFT) ile frekans alanına geçilmekte

ve frekans alanı öznitelikler FFT çıktısı olan frekans alanındaki sinyalden elde edilmektedir. Öznitelik çıkarımındaki sıkça kullanılan yaklaşımlar aşağıda belirtilmiştir.

2.2.5.1 Zaman Alanı Yaklaşımı

Zaman alanı sinyalin barındırdığı bilgiyi ortaya çıkaran öznitelikler: istatistiksel, histogram üst ve alt limitleri, otoregresif katsayılar, Hjort parametreleri, matematiksel morfoloji operatörleri başlıkları altında incelenebilir [11]. Titreşim sinyalleri arasındaki farkı açığa çıkarmak için sıkça kullanılan önemli zaman alanı istatistiksel öznitelikler başlıca: ortalama, azami değer, asgari değer, alan, toplam, kök kare ortalama, standart sapma, varyans, basıklık, çarpıklık, tepe faktörü ve form faktörüdür [2] [10] [11] [12] [13]. Bu özniteliklerin hesaplanış şekilleri aşağıda Tablo 2-5 içerisinde verilmiştir.

Tablo 2-5 Zaman Alanı Öznitelikleri [10] [11]

Öznitelik Adı	Hesaplama yöntemi
Ortalama	$\frac{1}{N} \sum_{i=1}^N x_i$
En düşük değer	$\max x_i $
En yüksek değer	$\min x_i $
Alan	$\max x_i - \min x_i $
Toplam	$\sum_{i=1}^N x_i$
Kök Kare Ortalama	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
Standart Sapma	$\sigma = \sqrt{\frac{1}{N} \sum_{i=2}^N (x_i - m)^2}$
Varyans	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - m)^2$

Basıklık	$\frac{\sum_{i=1}^N (x_i - m)^4}{(N - 1)\sigma^4}$
Çarpıklık	$\frac{\sum_{i=1}^N (x_i - m)^3}{(N - 1)\sigma^3}$
Tepe Faktörü	$\frac{\max x_i }{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$
Form Faktörü	$\frac{x_{max}}{m}$
Şekil Faktörü	$\frac{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}{\frac{1}{N} \sum_{i=1}^N x_i }$

RMS değeri, arıza ilerledikçe büyüyen bir değerdir. Ancak başlangıç seviyesindeki hataların tespiti için yeterli bir parametre değildir. Varyans, sinyalin ortalama değerinden dağılımını ölçen bir parametredir. Çarpıklık değeri sinyalin Olasılık Dağılım Fonksiyonu (*İng.* PDF) üzerindeki asimetrisini belirtir. Kurtosis PDF grafiğinin tepe noktasını ölçer. Normal durumda rulman için basıklık değeri 3 kabul edilmektedir. Tepe faktörü, yuvarlanma elemanı ve yuvarlanma yolunun teması sırasında ne kadar etki meydana geldiğini hesaplar.

2.2.5.2 Frekans Alanı Yaklaşımı

Frekans alanı özniteliklerin edinimi için öncelikle zaman serisi titreşim verisini frekans alanı sinyaline dönüştürmek gerekmektedir. Bu dönüşüm için sıkça Hızlı Fourier Dönüşümü'nden (*İng.* FFT) yararlanır. Frekans alanı öznitelikleri başlıca: istatistiksel, spektral çarpıklık, spektral basıklık, spektral entropi, Shannon entropi başlıkları altında incelenebilir. Frekans alanı sinyalden elde edilebilecek başlıca frekans alanı istatistiksel öznitelikleri: Frekans Merkezi (*İng.* FC) Kök Kare Ortalama Frekansı (*İng.* RMSF) Kök Varyans Frekansı (*İng.* RVF) olarak sıralanabilir. FC ve RMSF, ana frekansların konumlarındaki değişimleri gösterir. Bunu yanında RVF, güç spektrumunun yakınsamasını gösterir [11]. Yukarıda Bahsedilen frekans alanı özniteliklerin hesaplanış şekilleri aşağıda Tablo 2-6 içerisinde verilmiştir.

Tablo 2-6 Frekans Alanı Öznitelikleri [11]

Öznitelik Adı	Hesaplama Yöntemi
Frekans Merkezi (<i>İng.</i> FC)	$FC = \frac{\sum_{i=2}^N x'_i x_i}{2\pi \sum_{i=1}^N x_i^2}$
Kök Kare Ortalama Frekansı (<i>İng.</i> RMSF)	$RMSF = \sqrt{\frac{\sum_{i=2}^N (x'_i)^2}{4\pi^2 \sum_{i=1}^N x_i^2}}$
Kök Varyans Frekansı (<i>İng.</i> RVF)	$\sqrt{RMSF^2 - FC^2}$

2.2.5.3 Zaman – Frekans Alanı Yaklaşımı

Zaman – frekans alanı gösterimi, tek boyutlu zaman alanı sinyalini iki boyutlu zaman – frekans fonksiyonuna eşleme yapmak yoluyla elde edilir. Zaman – frekans alanı yaklaşım: Kısa Süreli Fourier Dönüşümü (*İng.* STFT), Dalgacık Dönüşümü ve Dalgacık Ayırımı, Ampirik Mod Ayırıştırma Tabanlı Hilbert Huang Dönüşümü, Wigner-Ville Dağıtımı, başlıkları altında incelenebilir. *Caesarendra vd.* [11], Durum İzleme kapsamında öznitelik çıkarımıyla ilgili geniş çaplı makalelerinde bu yöntemleri aşağıdaki şekillerde açıklamıştır:

STFT zaman alanı sinyali 2 boyutlu zaman-frekans alanı sinyaline dönüştürür. Bunun için zaman alanı sinyali eşit zaman dilimlerine bölünür ve her bölümün Fourier Dönüşümü hesaplanır. Böylece frekans alanı sinyalin zaman içerisindeki değişimi incelenebilir.

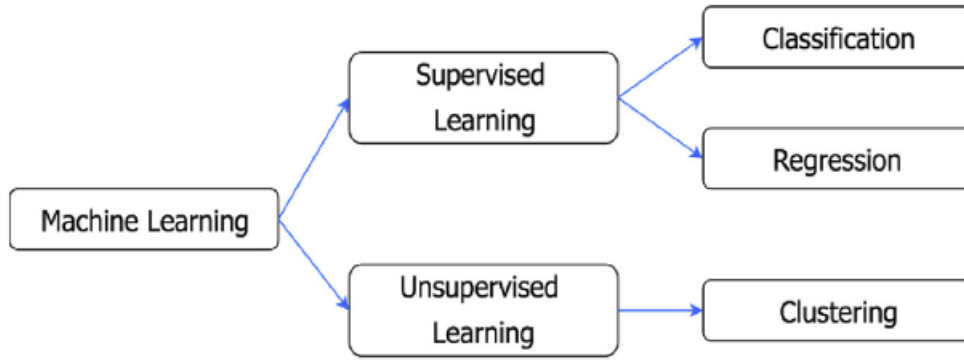
Dalgacık dönüşümünde temel fonksiyon olarak sinüzoidal fonksiyon yerine dalgacık fonksiyonu kullanılır. İç çarpım dönüşümünde zaman değişkenine ek olarak bir ölçek değişkenini de geliştirir.

Ampirik Mod Ayırıştırma, sarmalama tekniğine (Hilbert-Huang dönüşümüne (HHT)) dayalı olarak titreşim sinyalini yüksekten düşük frekans içeriğine, yani İçsel Mod Fonksiyonları'na (*İng.* IMF) çeşitli sinyallere ayırıştırır.

Wigner dağılımı, zamanla değişen ve durağan olmayan süreçler için güç spektrumu ile otokorelasyon fonksiyonu arasındaki ilişkiden türetilir. Korelasyon fonksiyonu, sonraki zamandaki fonksiyon ile sonraki zamandaki fonksiyonun çarpımıdır.

2.2.6 Makine Öğrenmesi Teknikleri

Makine öğrenmesinde mevcut sınırlı veriyle uzman müdahalesi olmadan öğrenen bir tümevarım modeli oluşturmak amaçlanır. Burada bahsedilen öğrenmeden kasıt, veri içerisinde birbirine tam olarak benzemeyen örnekler arasındaki ilişkileri ortaya çıkarmak için bir dizi model kümesi bulmaktır [2]. Makine öğrenme algoritmaları tarafından kullanılan her veri örneği, aynı özellik kümesi kullanılarak temsil edilir. Bu özellikler sürekli, kategorik veya ikili olabilir. Eğer örneklerin bilinen etiketleri (ilgili doğru çıktılar) ile verilirse, öğrenme denetimli olarak adlandırılır; bu, etiketlenmemiş örneklerin bulunduğu denetimsiz öğrenme ile karşılaştırıldığında gerçekleşir [32]. Denetimli öğrenmede amaçlanan, etiketli girdi verilerini kullanarak çıktı değişkenleri tahmin etmektir. Diğer başlık olan denetimsiz öğrenmede ise etiket içermeyen girdi veri kümesinden kümeleme, öneri sistemleri gibi çıkarımlar yapmaktır. Denetimli öğrenme kendi içinde regresyon (sayısal değişken) ve sınıflandırma (ayrım değişkeni) olarak iki gruba ayrılır. Bir modelin öğrenebilmesi için, modelin parametreleri belirli bir veri kümesine uydurmak amaçlanır. Bu doğrultuda model parametreleri eğitim veri seti ile yinelemeli bir şekilde güncellenerek önceden tanımlanmış bir fonksiyon minimize edilir [2].



Şekil 2.6 Makine Öğrenmesi Modelleri Taksonomisi [2]

Durum izleme kapsamında makine öğrenmesi hata tespit, hata sınıflandırma ve kalan faydalı ömür tespiti konularında veriye dayalı model geliştirmede kullanılmaktadır. Bu amaçla makine öğrenmesi konularından sınıflandırma, regresyon ve kümelemeden faydalanılır. Bu bölümde literatürdeki denetimli öğrenme tekniklerinden sınıflandırma,

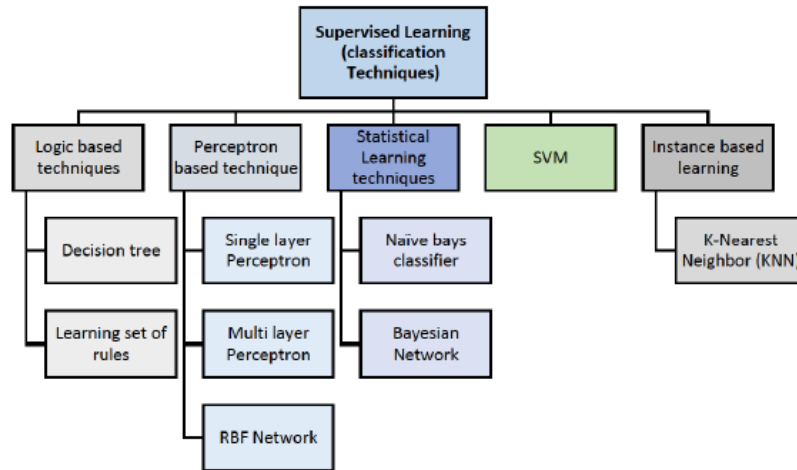
regresyon tekniklerinden ve bu teknikleri uygulayabilmek için gereken öznelik seçimlerinden bahsedilmiştir.

Durum izleme işleminde birçok makine öğrenmesi tekniği kullanılmaktadır. Bunların en sıklıkla kullanılan klasik makine öğrenmesi modelleri aşağıda belirtilmiştir [6] [9] [20]:

- Destek Vektör Makinesi (*İng.* SVM)
- K-En Yakın Komşu (*İng.* KNN)
- Karar Ağaçları (*İng.* DT)
- Rastgele Orman (*İng.* RF)
- Lojistik Regresyon (*İng.* LR)

2.2.6.1 Sınıflandırma

Bir denetimli öğrenme tekniği olan sınıflandırma veri örneklerinin grup üyeliklerini tahmin etmek için sıkça kullanılan bir makine öğrenmesi yaklaşımıdır. Yaygın kullanımı olan denetimli öğrenme sınıflandırma teknikleri Şekil 2.7 içerisinde de yer verilmiştir [28].



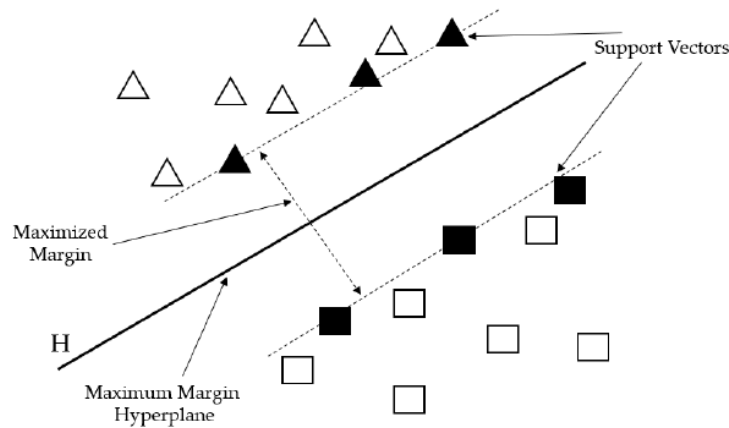
Şekil 2.7 Denetimli Öğrenme Sınıflandırma Teknikleri [28]

Denetimli öğrenmenin amacı, tahminci özelliklerin açısından sınıf etiketlerinin dağılımının özgün bir modelini oluşturmaktır. Elde edilen sınıflandırıcı daha sonra, tahminci özelliklerin değerlerinin bilindiği ancak sınıf etiketinin bilinmediği test örneklerine sınıf etiketleri atamak için kullanılır [32].

2.2.6.1.1 Destek Vektör Makinesi (SVM)

İlk olarak *Vapnik* [34] tarafından önerilen SVM, veriyi işleyen ve desenleri ayıran bir dizi birbirine bağlı denetimli öğrenme yöntemlerinden oluşur. Sınıflandırma ve regresyon çalışmaları için kullanılır [35]. SVM, bir hiperdüzlemin her iki tarafında bulunan ve iki veri kümesi için ayırıcı görevi gören bir kenar boşluğu (marjin) kavramına odaklanır. Temel amaç bu boşluğu maksimize etmek, böylece ayırıcı hiperdüzlem ile her iki taraftaki veri noktaları arasındaki mesafeyi arttırmaktır. Bu yaklaşımın beklenen genelleme hatasının üst sınırını en aza indirdiği gösterilmiştir [28] [32].

Lineer olarak ayrılabilir verilerin durumunda, en uygun ayırıcı hiperdüzlem bulunduğunda, hiperdüzlemin marjını paylaşan veri noktalarına destek vektör noktaları denir ve çözüm yalnızca bu noktaların lineer bir kombinasyonu olarak temsil edilir. Destek vektörleri ve optimum hiper düzlem Şekil 2.8 içerisinde gösterilmiştir. Diğer veri noktaları göz ardı edilir. Bu nedenle, bir SVM'in model karmaşıklığı, eğitim verilerinde karşılaşılan özelliklerin sayısından etkilenmez (SVM öğrenme algoritması tarafından seçilen destek vektör sayısı genellikle küçüktür). Bu nedenle SVM'ler, özellik sayısının eğitim örneklerinin sayısına göre büyük olduğu öğrenme görevleri ile başa çıkmak için uygundur [27] [32].



Şekil 2.8 Lineer Sınıflandırmada Destek Vektörleri ve Optimum Hiperdüzlem [20]

SVM, seçilen çekirdek fonksiyonuna göre giriş verilerini yüksek boyutlu öznelik uzayına eşler. Bu sayede doğrusal olarak ayrıştırılabilir olmayan verilerin işlenmesine olanak tanır. Dolayısıyla SVM kullanımında çekirdek fonksiyonu seçimi önemlidir. Çekirdek fonksiyonu seçiminde yaygın yöntem muhtemel çekirdek fonksiyonlarıyla

testler gerçekleştirmek ve çapraz-doğrulama yöntemiyle en iyi fonksiyonu seçmektir. SVM mantıklı bir çekirdek fonksiyonu seçimiyle tasarımcının kullanılan özneliliklerin detaylarına hakim olmadan da sınıflandırma yapabilmesine olanak sağlar [32].

Saha vd. [27], makalelerinde SVM hiperdüzlem denklemini şu şekilde açıklamıştır. Verilen herhangi bir $(v_1, v_1), (v_2, v_2), \dots, (v_n, v_n)$ veri kümesini ele alalım. v ve v' 'nin, destek vektörlerin ilgili veri noktalarını temsil ettiği $v_i \in R^n$ girdi olarak, $v_i \in (-1, +1)$, v_i ile ilişkili çıktı olarak ele alalım. Bu durumda Hiperdüzlem denklemi aşağıdaki şekildedir:

$$(\omega \cdot v) + b = 0, \quad (1.1)$$

Burada, ω N boyutlu bir vektördür ve b bir skalar değerdir. Daha genelleştirilmiş formlarda, $v_i = 1$ ve $v_i = -1$ için hiperdüzlemlerin denklemleri sırasıyla aşağıdaki gibi temsil edilebilir:

$$(\omega \cdot v_i) + b \geq 1 \quad (1.2)$$

$$(\omega \cdot v_i) + b \leq -1 \quad (1.3)$$

Herhangi bir pozitif marj için,

$$(\omega^T v_2) + b = +1 \quad (1.4)$$

Herhangi bir negatif marj için,

$$(\omega^T v_1) + b = -1 \quad (1.5)$$

(1.5) numaralı eşitlikten (1.4) numaralı eşitliği çıkarırsak, maksimum marjı aşağıdaki gibi elde ederiz:

$$\omega^T (v_2 - v_1) = 2 \quad (1.6)$$

$$\frac{\omega^T}{\|\omega\|} \cdot (v_2 - v_1) = \frac{2}{\|\omega\|} \quad (1.7)$$

Bu maksimize edilmesi gereken optimize edilmiş fonksiyondur. Hata optimizasyonu için, herhangi yeni test verisi v_i için (1.8) numaralı eşitsizlik elde edilir:

$$v_i * (\omega^T \cdot v_i) + b_i \geq 1 \quad (1.8)$$

Yukarıdaki durum sağlanmıyorsa, Bu durumda ω ve b 'yi hesaplayabilmek için hata terimini de dahil etmeliyiz.

$$(\omega^*, b^*) = \min \frac{\|\omega\|}{2} + C_i \sum_{i=1}^n \varepsilon_i \quad (1.9)$$

Burada C, hata cezası ve ϵ gevşek deęiřkendir.

SVM ikili sınıflandırma yöntemidir [36]. İki den fazla sınıf için tek bir SVM formülasyonu kullanmak yaygın bir yöntem deęildir. Bunun yerine birkaç ikili sınıflandırıcının bir kombinasyonu kullanılır. İki den fazla sınıfı SVM ile sınıflandırmak için ikili SVM sınıflandırıcı farklı stratejilerle kullanılmaktadır. Sıkça kullanılan stratejiler “bire karşı bir” (OvO) stratejisi ve “bire karşı geri kalanı” (OvR) stratejisidir [36] [37].

Bire karşı bir stratejisinde, sınıf sayısını N kabul ettięimiz durumda

$$N * (N - 1) / 2$$

İkili SVM sınıflandırıcı kullanılır. Bu sınıflandırıcıların her biri N farklı sınıfın birbiri arasındaki ikili sınıflandırıcılarıdır. Böylece her sınıf birbiri ile karşılaştırılmış ve test verisinden karşılaştırılan iki sınıftan hangisine ait olduęu tahmin edilir. Bu karşılařtırmaların her birinde kazanan sınıfın puanı bir arttırılır. Tüm karşılařtırmalar sonucunda en çok puanı olan sınıf çok sınıflı sınıflandırıcının tahmini olarak seęilir [36] [37]. Sınıf sayısına göre eęitilmesi gereken ikili SVM sınıflandırıcı sayısı Şekil 2.9 içerisinde verilmiřtir.



Şekil 2.9 Sınıf sayısına göre SVM karar fonksiyonu sayısı

Bire karşı geri kalanı stratejisini kullanan N sınıflı bir sınıflandırıcı için N farklı ikili sınıflandırıcı eęitilmelidir. Her bir sınıflandırıcı bir sınıfa karşı dięer tüm sınıfları ayırıtacak şekilde eęitilir. Sınıflandırıcı karar fonksiyonu sonuçları tüm sınıflandırıcılar

için hesaplanır ve en yüksek değerli karar fonksiyonuna sahip olan sınıf çok sınıflı sınıflandırıcının tahmini olarak seçilir [36] [37].

2.2.6.2 Ana Bileşen Analizi (PCA)

PCA, boyut küçültmede en sık kullanılan yöntemlerden biridir. PCA'de ana fikir, en büyük varyansa sahip yeni ortogonal özellik vektörlerini seçmektir. Üretilen yeni değişkenler, başlangıçtaki değişkenlerin doğrusal kombinasyonlarıyla elde edilir, başlangıçtaki özelliklerin birçoğunu içerir ve tahmin doğruluğunu etkileyen verilerin korelasyonunu da ortadan kaldırır. PCA, aşağıdaki 3 adımdan oluşur [38]:

1. Kovaryans matrisinin hesaplanması
2. Kovaryans matrisinin özdeğerlerinin ve özvektörlerinin alınması
3. Özvektörlerin birikimli katkısını bulunması ve temel bileşenlerin seçilmesi.

Ana bileşen sayısı kullanıcı tarafından belirlenebilir. Görselleştirmeyi kolaylaştırması açısından ana bileşen sayısı yaygın olarak 2 seçilir. Bu çalışmada farklı ana bileşen sayılarıyla model başarımları değerlendirilmiştir. Ana bileşen sayısı 2 olan testlerin karar sınırları ve veri örnekleri görselleştirilip sonuçlar kısmında paylaşılmıştır.

2.2.6.3 Öznitelik Seçimi

Öznitelik seçimi edinilen sinyalden, üzerinde çalışılacak olan sonuçla ilişkili değişkenleri seçme sürecidir. Bu süreç otomatik ya da yarı otomatik olarak yürütülebilir. Otomatik öznitelik seçimi sarıcı metotlar, gömülü metotlar ve filtre metotları olarak sınıflandırılabilir [2].

Sarıcı metotlarda yaklaşım, makine öğrenmesi modeline farklı öznitelik altkümelerini besleyip performans analizi yapmak ve çok sayıda denemenin sonunda en iyi performansı gösteren öznitelik altkümelerini seçmektir. Dolayısıyla, sarıcı metotlarda kullanılacak olan makine öğrenmesi modeli önceden belirlenmiş olmalıdır [39].

Gömülü metotlarda yaklaşım öznitelik seçimini model eğitim süreci içerisinde gerçekleştirmektir. Gömülü metotlar, veri setini eğitim ve test olarak ikiye bölmeden daha etkin bir şekilde kullanmaları ve daha hızlı sonuç vermeleri yönüyle sarıcı metotlara karşı daha avantajlıdır [39].

Filtre metotları modelden bağımsızdır. Bu yaklaşımda her öznelik ile bir sonuç (örneğin korelasyon) arasındaki ilişki nümerik olarak hesaplanır. Daha sonra önem sırasına göre bu öznelikler sıralanır ve ilk K tane öznelik seçilir. K sayısı, farklı modellerde sunduğu performans değerine göre seçilebilir [2] [40].

2.3 Savunma Sanayi Ürünlerinde Mevcut Bakım Çalışmaları

Savunma sanayii ürünü olan sistemler farklı kullanım durumları ve risk faktörleri içermeleri sebebiyle farklı bakım konseptlerine sahiptir. Ancak savunma sanayiinin kapsadığı çoğu alanda bakım yöntemleri için, sensör ve bilgi teknolojilerindeki gelişmeler doğrultusunda Durum Bazlı Bakım (*İng.* CBM) ve kestirimci bakım gibi veriye dayalı bakım konseptlerinin önemi giderek artmaktadır [1] [14] [41].

Mevcut bakım stratejilerinde özellikle havacılık sistemlerinin operasyona elverişli tutulması hedeflenir. Hem sivil hem askeri havacılık sistemlerin bakım programları çoğunlukla plansız bakım faaliyetlerine yol açabilecek sabit zaman aralıklı ve önleyici bakım programlarını kullanmaktadır. Ancak sensör teknolojisinin ve dijitalleşmenin ilerlemesiyle sistemlerin sağlık durumlarının teşhis edilebilmesi kolaylaşmıştır. Bunun sonucunda kestirimci bakım, prognostik ve sağlık yönetimi gibi kavramlar araştırma perspektifinden önem kazanmaya başlamıştır. Bunun yanı sıra önemli savunma sanayii ürünlerinden olan hava platformlarında önleyici bakım uygulamanın plansız bakımları ele almada yetersiz kaldığı görülmüştür. Yeni nesil askeri uçaklar için Yapısal Prognostik ve Sağlık Yönetimi (SPHM) sistemlerinde ilkel sensör verilerini izleme yönteminden uçtan uca entegre varlık yönetimine geçiş yaşanmaktadır. Buna örnek olarak Otonom Lojistik Bilgi Sistemini (ALIS) destekleyen, bilgi açısından zengin sistemlere sahip Lockheed Martin F-35 Lightning 2 Taarruz Uçağı verilebilir [1].

Bir diğer savunma sanayii ürün grubu olan silah ve zırhlı teçhizatların bakım yöntemi pasif yöntemlerden aktif yöntemlere geçmektedir. Bu sayede sistemin sağlık durumuna dair daha detaylı bilgi sahibi olmak ve sistemin savaşa hazırlık durumunu tayin etmek hedeflenir. Aktif bakım stratejileri CBM anlayışını benimser ve bu sayede yetersiz bakımdan kaynaklı hataları engellerken aşırı bakım riskini de ortadan kaldırır. Bilgi teknolojilerindeki gelişmeler zırhlı araçların bakım yöntemi olarak CBM kullanımını tetiklemektedir [14].

Modern savaş gemilerinin giderek daha fazla sayıda sensörle donatılıyor olması ve öğrenme algoritmalarının yaygınlaşarak veri analizini mümkün kılması, savaş

gemilerinde veriye dayalı bakım yaklaşımlarının kullanılmasının önünü açmıştır. Bu sebeple modern savaş gemilerinin bakım konsepti planlı periyodik bakımdan veriye dayalı bakıma doğru geçmektedir. Veriye dayalı yöntemler arızaların daha erken tespitini, daha iyi bakım planları yapmayı sağlamak ve düzeltici bakım yükünü hafifletmeleri sebebiyle tercih edilmektedir [41].

2.4 FPGA Teknolojisinin Makine Öğrenmesi Alanındaki Kullanımı

FPGA tasarımı karmaşık ve zaman alıcıdır ancak gelişen yüksek seviye sentez (*İng.* HLS) teknikleri tasarım ve doğrulama işlemlerini önemli derecede kolaylaştırmıştır. HLS tabanlı tasarım teknikleri veri niceleme, paralellik çıkarma, ardışık düzen oluşturma ve bellek bölümlenme dahil olmak üzere mimari optimizasyonları uygulamayı da kolaylaştırır [42].

Sınıflandırma modeli eğitimi çevrim içi ya da çevrimdışı olarak gerçekleştirilebilir ancak yeni edinilen veriyle sınıflandırma işlemi sıklıkla çevrim içi ve gerçek zamanlı olarak gerçekleştirilmelidir. Yüz tespiti, konuşma tanıma, biyoenformatik ve jeoistatistiksel analiz gibi uygulamalar gerçek zamanlı çevrim içi sınıflandırma gerektiren uygulamalara örnektir. Bu tür uygulamalarda karar fonksiyonunun hesaplanmasını hızlandırmak amacıyla paralel hesaplama kabiliyetine sahip FPGA teknolojisi kullanılabilir [43].

Gerçek zamanlı uygulamalarda, çevrim içi sınıflandırma amacıyla sıkça kullanılan, yüksek sınıflandırma başarımına sahip SVM, yoğun ve karmaşık hesaplama yükünden dolayı gömülü sistem tasarımları için zorlu bir görevdir. FPGA mimarisinin sunduğu paralel işlem kabiliyeti bu tür zorlu performans gereksinimlerini gömülü sistem uygulamalarında karşılanabilmesini sağlar. Bu bağlamda FPGA genel maksat işlemciler ve grafik işleme ünitelerine nazaran daha başarılı performans gösterir. Bunun sonucu olarak FPGA teknolojisi, SVM modeliyle gömülü sistemlerde sınıflandırma işleminde sıklıkla tercih edilir. [44] [45] SVM sınıflandırıcı için temel FPGA mimarileri şu şekilde sınıflandırılabilir [44]:

- Paralel boruhattı mimarileri.
- Sistolik dizi mimarileri.
- Dinamik kısmen yeniden yapılandırma (*İng.* DPR) mimarileri.
- Çarpansız mimariler.
- Geliştirme aracı tabanlı mimariler.
- Basamaklı sınıflandırma tabanlı mimariler.

3. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR

3.1 Makine Öğrenmesi Modelleri Performans Değerlendirmeleri

Bu çalışmada, FPGA ile hata tespit ve sınıflandırma işlemi gerçekleştirilmiştir. Bu amacı gerçekleştirmek için, “3.1.1 Veri Seti” başlığı altında içeriği belirtilen veri seti toplanmış ve Python programlama ortamında işlenerek makine öğrenmesi modelleriyle kullanılabilir hale getirilmiştir. Ardından literatürde sıkça rastlanan klasik makine öğrenmesi modellerinin bu veri seti ile başarımları test edilmiştir. Testler sonucunda bu veri setiyle en başarılı sonucu veren SVM modeli FPGA tasarımına dahil etmek için seçilmiştir.

3.1.1 Veri Seti

3.1.1.1 Deney Düzeneği

Deney düzeneğini oluşturan parçalar aşağıda Tablo 3-1 içerisinde belirtilmiştir.

Tablo 3-1 Test Düzeneği Parçaları

Parça	Marka/Model/Açıklama	Görsel
Kapak Sistemi	Roketsan A.Ş. üretimi füze koruma kapağı.	Bkz. Şekil 3.1
Veri Edinim Aracı	Dewesoft SIRIUS HD	Bkz. Şekil 3.6
Veri Edinim Aracı Kontrol Yazılımı	Dewesoft X 2023.3 (RELEASE 230525)	-
Titreşim Sensörü	Piezotronics 356A16 3 Eksenli ICP İvmeölçer	Bkz. Şekil 3.7
Akım Sensörü	Dewesoft DSIi-20A	Bkz. Şekil 3.8
Güç Kaynağı	TTI PL303QMD	Bkz. Şekil 3.9
Anahtarlama Devresi	Kapak açma kapama işlemini hızlı bir şekilde gerçekleştirebilmek için üretilen basit anahtarlama devresi.	Bkz. Şekil 3.10
Sabitleyici Mengene	Test sırasında füze koruma kapağını tutması için kullanılan mekanik sistem.	Bkz. Şekil 3.11

Deneyler kapsamında Roketsan A.Ş ürününü olan, Şekil 3.1 ve Şekil 3.2 içerisinde helikoptere ve insansız deniz aracına entegre görüntüleri verilen füze koruma kapağı sistemi üzerinden farklı durumlarda titreşim ve akım verisi toplanmıştır. Veri toplama işlemi için Şekil 3.4 içerisinde şematiği verilen test düzeneği kurulmuştur. Test düzeneği parçalarının detaylı açıklamaları Tablo 3-1 içerisinde mevcuttur. Test düzeneği kapsamında, kapak sistemi açılış hareketi doğrultusu yukarı yönde olacak şekilde mengene ile düz zemine sabitlenmiştir. Kapak sistemi üzerine Şekil 3.5 içerisinde gösterildiği şekilde titreşim sensörü yerleştirilmiştir. Kapak sisteminin güç gereksinimi DC güç kaynağı (Bkz. Şekil 3.9) ile karşılanmış, güç kaynağı ile kapak sistemi arasında basit bir anahtarlama devresi (Bkz. Şekil 3.10) kullanılmıştır. Ayrıca Güç kaynağının pozitif çıkışına seri akım sensörü (Bkz. Şekil 3.8) bağlanmıştır. Kapak üzerindeki titreşim sensörü (Bkz. Şekil 3.4) ve güç kaynağı çıkışındaki akım sensörü veri edinim aracına (Bkz. Şekil 3.6) bağlıdır. Bu araç, veri edinim aracı kontrol yazılımı ile USB arayüzünden bağlanan bilgisayar üzerinden kontrol edilmiştir. Titreşim ve akım sensörlerinden devamlı olarak toplanan veriler sadece akım RMS değerinin 0.02A üzerinde olduğu anlarda kayda alınmıştır. Dolayısıyla titreşim ve akım verileri sadece kapak sisteminin çalışır vaziyette olduğu zamanki verileri içerir.




Şekil 3.1 Helikoptere Entegre Füze Koruma Kapağı [46]

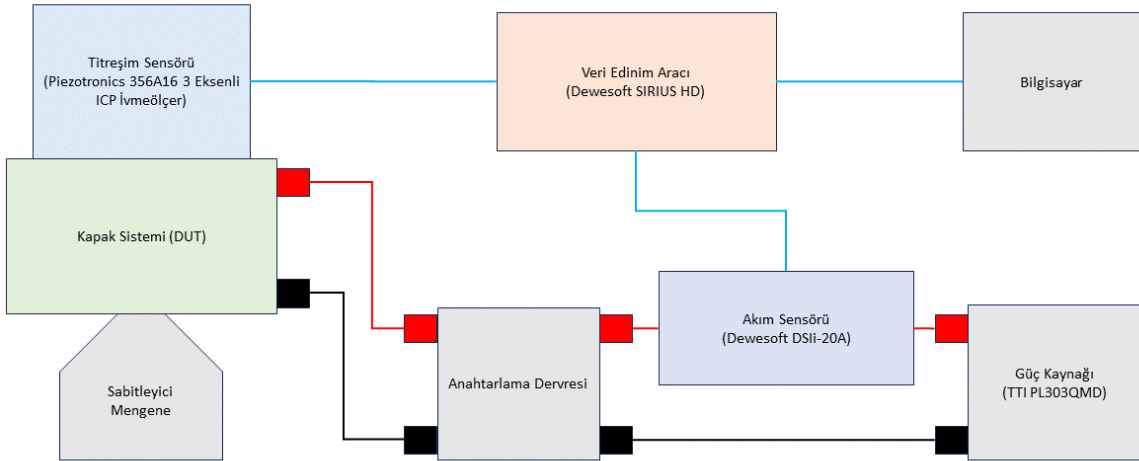


Şekil 3.2 İnsansız Deniz Aracına Entegre Füze Koruma Kapağı [47]


Kapak mekanizması Şekil 3.3 içerisinde görülebileceği üzere taşıyıcı/sabitleyici yatak, DC motor, dişli tork aktarım mekanizmaları, tork sınırlayıcı, balata, manuel tahrik dişlisi, vidalı mil, piston, kapak ve limit anahtarından oluşmaktadır. Pozitif doğru akım beslenmesiyle DC motor açılış hareketi yönünde harekete geçmektedir. DC motorun meydana getirdiği tork; tork sınırlayıcı mekanizmayı harekete geçirmektedir. Tork sınırlayıcı mekanizma balata aracılığıyla tork aktarım dişlisini harekete geçirmektedir. Tork aktarım dişlisi ana dişli ve ona birleşik olan vidalı mili harekete geçirmektedir. Vidalı mil dönme hareketini doğrusal harekete çevirmekte ve üzerindeki pistonu gövdenin içine doğru hareket ettirmektedir. Piston hareketi kapak sistemini açılış yönünde hareket ettirmektedir. DC motora negatif akım uygulanmasıyla işlem tam ters yönde çalışmakta ve kapak mekanizmasını kapanış yönünde hareket ettirmektedir. Açılış ve kapanış hareketlerinin tamamlandığı sinyali üretmek amacıyla 2 adet limit anahtarı kullanılmaktadır. Kapak sisteminin açılış ve kapanış hareketlerinin sınır değerlerinde, hareketin devam etmesi sonucunda mekanik sistemin aşırı yüklenerek hasara uğramasını engellemek amacıyla, tork aktarım dişlisi tork sınırlayıcı mekanizma ile tahrik edilmektedir. DC motorun devre dışı olduğu durumlarda kapağı istenilen yönde hareket ettirebilmek amacıyla manuel tahrik dişlisi mevcuttur. Kullanıcının manuel olarak oluşturduğu tork, manuel tahrik dişlisinin üzerinden manuel tahrik aktarım dişlisine, oradan vidalı mil ve ona birleşik olan ana dişliye iletilir. Vidalı milin hareketi sonucu kapak mekanizması açılış ya da kapanış yönünde hareket eder.



Şekil 3.3 Kapak Mekanizması Şematığı



Şekil 3.4 Veri Toplama Düzeneği



Şekil 3.5 Testlerde Kullanılan Füze Koruma Kapağı ve İvmeölçer Yerleşimi



Şekil 3.6 Dewesoft SIRIUS HD Veri Edinim Aracı



Şekil 3.7 Piezotronics 356A16 3 Eksenli ICP İvmeölçer



Şekil 3.8 Dewesoft DSli-20A Akım Sensörü



Şekil 3.9 TTI PL303QMD



Şekil 3.10 Anahtarlama Devresi



Şekil 3.11 Sabitleyici Mengene ve Füze Koruma Kapağı

Dewesoft X yazılımı içerisinde, aynı markanın ürünü olduğu için akım sensörü doğrudan algılanmıştır. Titreşim sensörünün (Bkz. Şekil 3.7) 3 eksen için gerekli hassaslık kalibrasyon ayarları sensör firmasının sağladığı bilgilere uygun şekilde aşağıdaki gibi gerçekleştirilmiştir. Ayrıca veri edinim sisteminin titreşim ve akım sensörü kanal ayarları da aşağıdaki gibi gerçekleştirilmiştir:

- Akım sensörü kanal ayarları:
 - Alan: 20A
 - Alçak Geçiş Filtresi: Kenar Yumuşatma Filtresi(IIR)
- Titreşim X-ekseni ayarları:
 - X-ekseni hassaslık: $9.71 \frac{mV}{m/s^2}$
 - Alçak Geçiş Filtresi: 4kHz
 - Filtre Tipi: Butterworth (2. derece)
 - Yüksek Geçiş Filtresi: 0.16 Hz
 - Birim: m/s^2
- Titreşim Y-ekseni ayarları:

- Y-ekseni hassaslık: $10.44 \frac{mV}{m/s^2}$
- Alçak Geçiş Filtresi: 4kHz
- Filtre Tipi: Butterworth (2. derece)
- Yüksek Geçiş Filtresi: 0.16 Hz
- Birim: m/s^2
- Titreşim Z-ekseni ayarları:
 - Z-ekseni hassaslık: $9.98 \frac{mV}{m/s^2}$
 - Alçak Geçiş Filtresi: 4kHz
 - Filtre Tipi: Butterworth (2. derece)
 - Yüksek Geçiş Filtresi: 0.16 Hz
 - Birim: m/s^2

3.1.1.2 Veri Edinimi

Titreşim ve akım sensörlerinden veri edinimi Dewesoft SIRIUS HD donanımı ve Dewesoft X yazılımı ile gerçekleştirilmiştir. Titreşim sensörü X, Y ve Z olarak isimlendirilen 3 eksende zaman serisi titreşim verisi üretirken akım sensörü 1 boyutlu zaman serisi veri üretmektedir. X, Y, Z eksenlerindeki titreşimler ve akımdan oluşan toplam 4 ölçüm 20000 hz örnekleme hızıyla örneklenmiştir. Dewesoft X yazılımı içerisinde akım verisinin RMS değeri de hesaplanarak toplamda örnekleme başına 5 değer elde edilmiştir. Son olarak başlangıçtan itibaren geçen zaman bilgisi de her bir örnekleme için kayıt altına alınmıştır. Böylece ham veri içerisindeki her bir veri örneği, açılma ya da kapanma hareketi başlayıp bitene kadar, bu 6 değeri kaydederek oluşturulmuştur. Bu değerler her bir açılış/kapanış hareketi için bir “CSV” dosyasına kaydedilmiştir.

3.1.1.3 Veri Seti İçeriği

Deney düzeneğinden toplanan veriler başlangıçta “ham veri setini” oluşturur. Sonrasında bu veriler makine öğrenmesi kapsamında kullanılabilme amacıyla işlenmiş ve “işlenmiş veri seti” elde edilmiştir.

3.1.1.3.1 Ham Veri Seti

Ham veri seti 6 farklı durumda toplanan titreşim ve motor akımı verisi içermektedir. Bu durumlar aşağıda Tablo 3-2 içerisinde sıralanmıştır:

Tablo 3-2 Ham Veri Seti Sınıfları/ Hata Durumları

Sınıf	Açıklama
Sınıf 1	Sağlıklı
Sınıf 2	Kapak üzerine ağırlık bağlı
Sınıf 3	Manuel tahrik dişlisi yanlış hizalı
Sınıf 4	Ana tahrik dişlisi hasarlı
Sınıf 5	Vidalı mil hasarlı
Sınıf 6	Tork sınırlayıcı gevşek

Bu durumlar yukarıda belirtilen sınıf numarası sırasına göre yaratılmıştır. Sınıf 4 ve Sınıf 5 kapsamında yaratılan deformasyonlar geri alınamaz olduğundan, Sınıf 5 ve Sınıf 6 durumlarında hatalar birikimsel olarak devam etmiştir. Dolayısıyla Sınıf 5 içerisinde ana tahrik dişlisi ve vidalı mil hasarlı, Sınıf 6 içerisinde ana tahrik dişlisi, vidalı mil hasarlı ve tork sınırlayıcı gevşektir.

Tablo 3-3 Ham Veri Seti İçeriği

Sınıf	Açılış Verisi	Kapanış Verisi	Toplam
Sınıf 1	150	150	300
Sınıf 2	150	150	300
Sınıf 3	43	42	85
Sınıf 4	150	150	300
Sınıf 5	150	150	300
Sınıf 6	150	150	300


Toplam:

793 Açılış hareketi ve 792 kapanış hareketinin titreşim ve akım verileri ham veri setini oluşturmaktadır.


Sınıf 1, sistemin herhangi bir hata durumu yaratılmamış halidir. Sınıf 2 füze koruma kapağı üzerinde çamur vb. birikimi sebebiyle ağırlık oluşumunun benzetimidir. Sınıf 2 hata benzetimi Şekil 3.12 içerisinde gösterildiği şekilde gerçekleştirilmiştir. Sınıf 3 manuel tahrik dişlisinin hizasında kayma olduğu durumdur. Sınıf 3 hata durumu Şekil 3.13 içerisinde gösterildiği şekilde oluşturulmuştur. Sınıf 4 ana tahrik dişlisinin hasarlı olduğu durumdur. Sınıf 4 hata durumu Şekil 3.14 içerisinde gösterildiği şekilde oluşturulmuştur. Sınıf 5 vidalı milin hasarlı olduğu durumdur. Sınıf 5 hata durumu Şekil 3.15 içerisinde gösterildiği şekilde oluşturulmuştur. Sınıf 6 tork sınırlayıcının gevşek olduğu durumdur. Sınıf 6 hata durumu Şekil 3.16 içerisinde gösterildiği şekilde oluşturulmuştur.



Şekil 3.12 Sınıf 2 Hata Durumu




Şekil 3.13 Sınıf 3 Hata Durumu



Şekil 3.14 Sınıf 4 Hata Durumu



Şekil 3.15 Sınıf 5 Hata Durumu



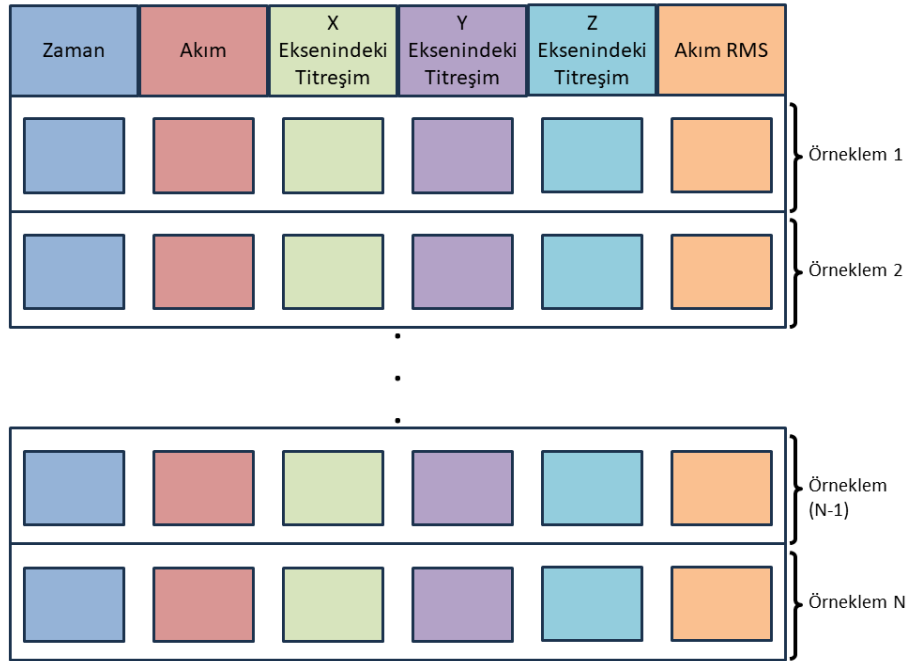
Şekil 3.16 Sınıf 6 Hata Durumu

Ham veri içerisindeki “Sınıf 1” içerisinde “açılış” hareketiyle elde edilen bir ham veri örneği Şekil 3.17 içerisinde gösterilmiştir. Ham veri seti içeriği diyagramı Şekil 3.18’de

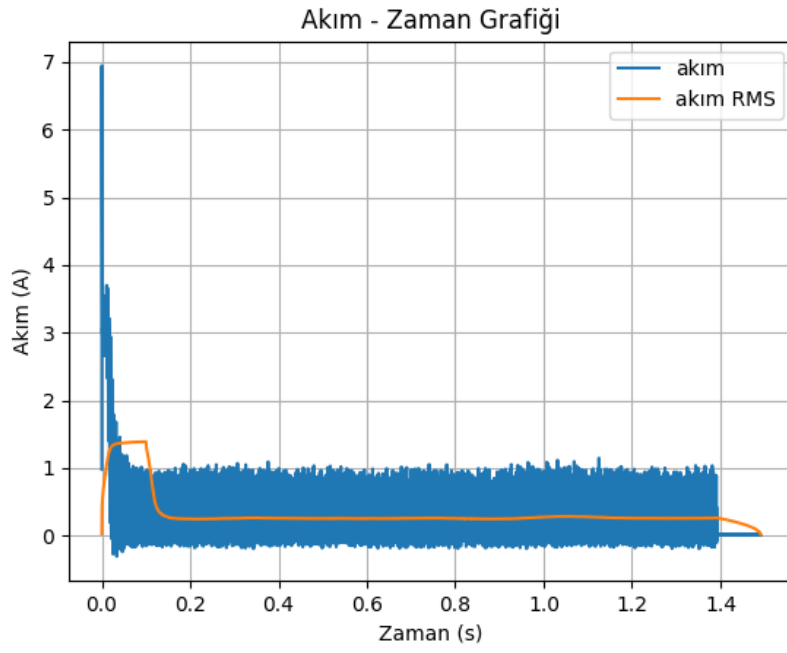
verilmiştir. Bu ham veri örneğine ait X, Y, Z eksenlerindeki titreşim, akım ve akım RMS grafikleri Şekil 3.19, Şekil 3.20, Şekil 3.21 ve Şekil 3.22 içerisinde verilmiştir.

```
Time,AI 1/current,AI 2/vibrationX,AI 3/vibrationY,AI 4/vibrationZ,Basic stat. 1/AI 1/current/RMS
0.00000000,0.98063862323761,-0.0871008187532425,0.192670688033104,-0.175751626491547,0.0271189864724874
0.00005000,5.79883289337158,-0.254323065280914,-0.0287992898374796,-0.417385548353195,0.132471188902855
0.00010000,6.94699573516846,-0.158443301916122,-0.350697189569473,-0.2718246281147,0.204154208302498
0.00015000,5.75284242630005,0.0351600758731365,-1.60855674743652,0.109979100525379,0.241301670670509
0.00020000,5.27286100387573,-0.0466781295835972,-4.57091617584229,-0.257171750068665,0.268566519021988
0.00025000,6.40692043304443,-0.337721467018127,-8.28608798980713,-1.21057522296906,0.304388284683228
0.00030000,5.75020694732666,-0.885909795761108,-10.6749505996704,-0.361677050590515,0.33043098449707
0.00035000,5.7356538772583,-1.5597630739212,-10.4559917449951,1.38851010799408,0.354448109865189
0.00040000,5.26837158203125,-2.0662522315979,-7.72950601577759,-0.192892715334892,0.373512089252472
0.00045000,5.07866191864014,-2.59869694709778,-2.91372323036194,-3.56277370452881,0.390394181013107
```

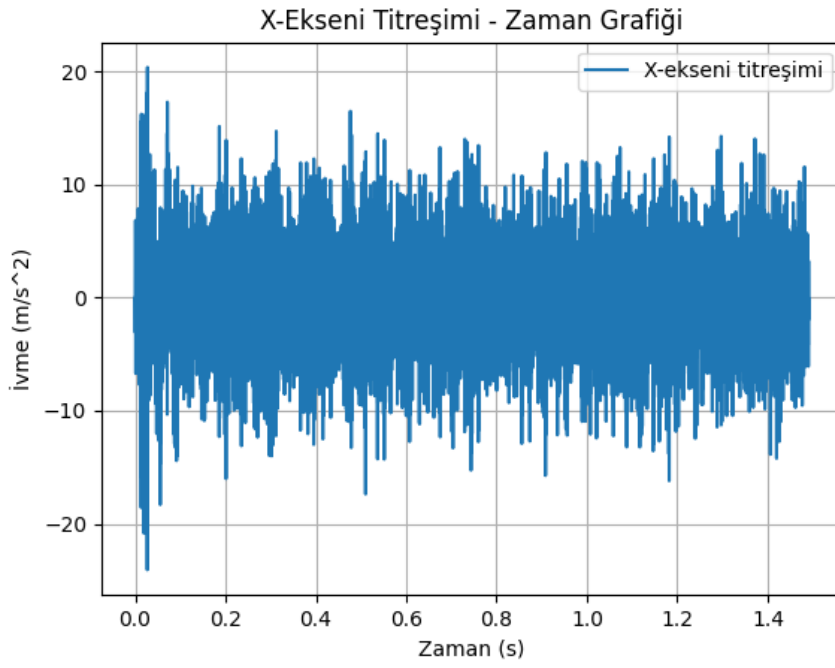
Şekil 3.17 Ham Veri Örneği




Şekil 3.18 Ham Veri Seti İçerik Diyagramı




Şekil 3.19 Akım Grafiđi



Şekil 3.20 X-Ekseni Titreşim Grafiđi



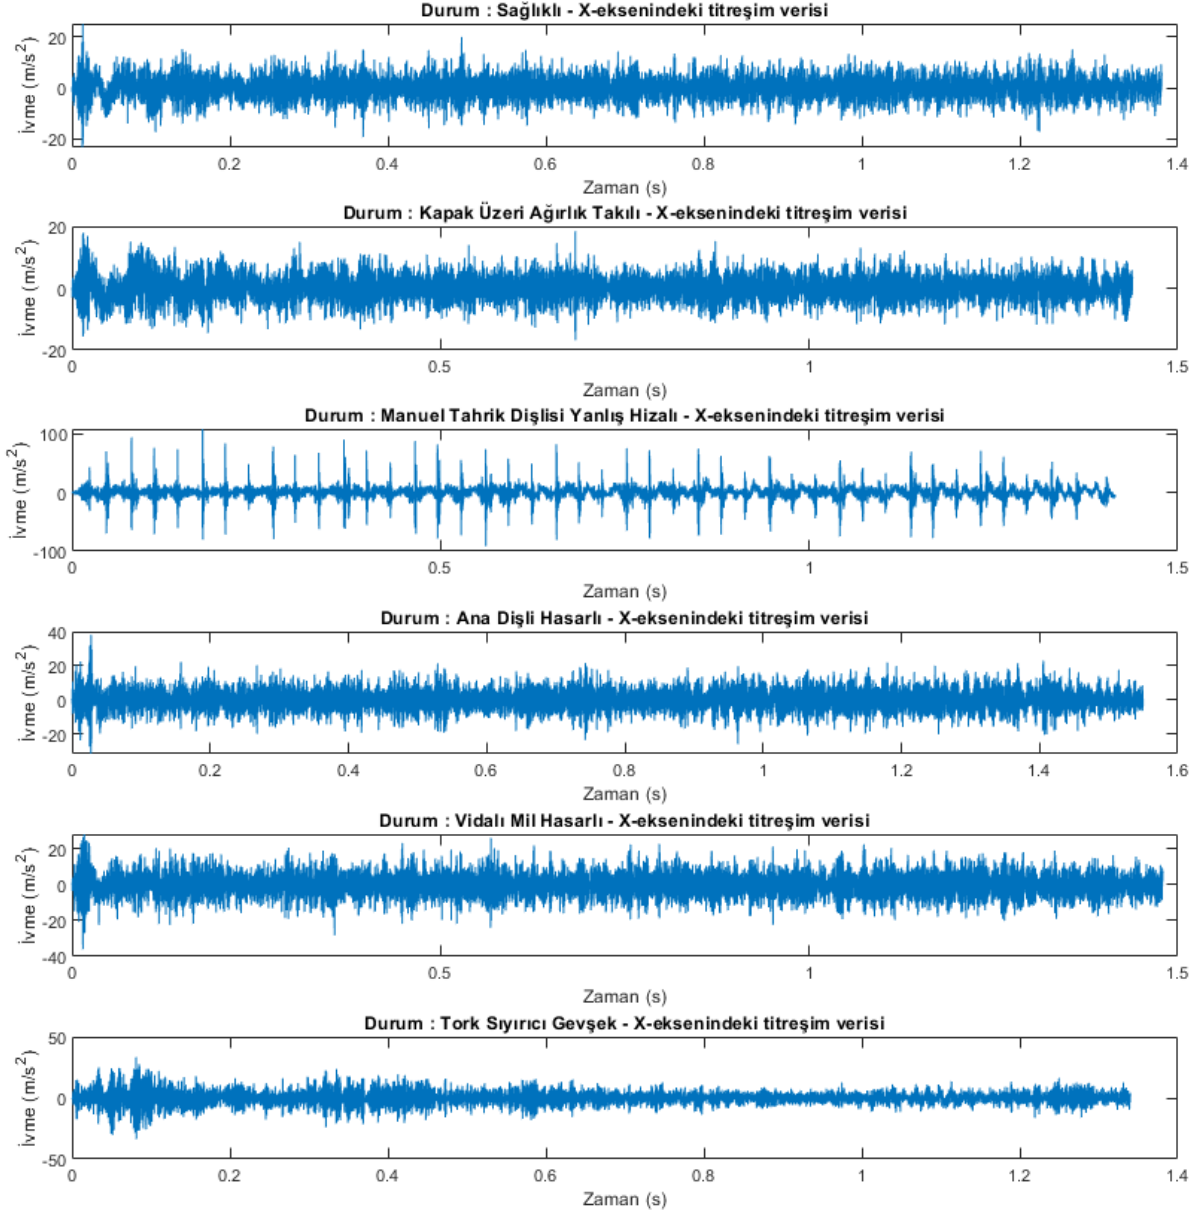
Şekil 3.21 Y-Ekseni Titreşim Grafiği



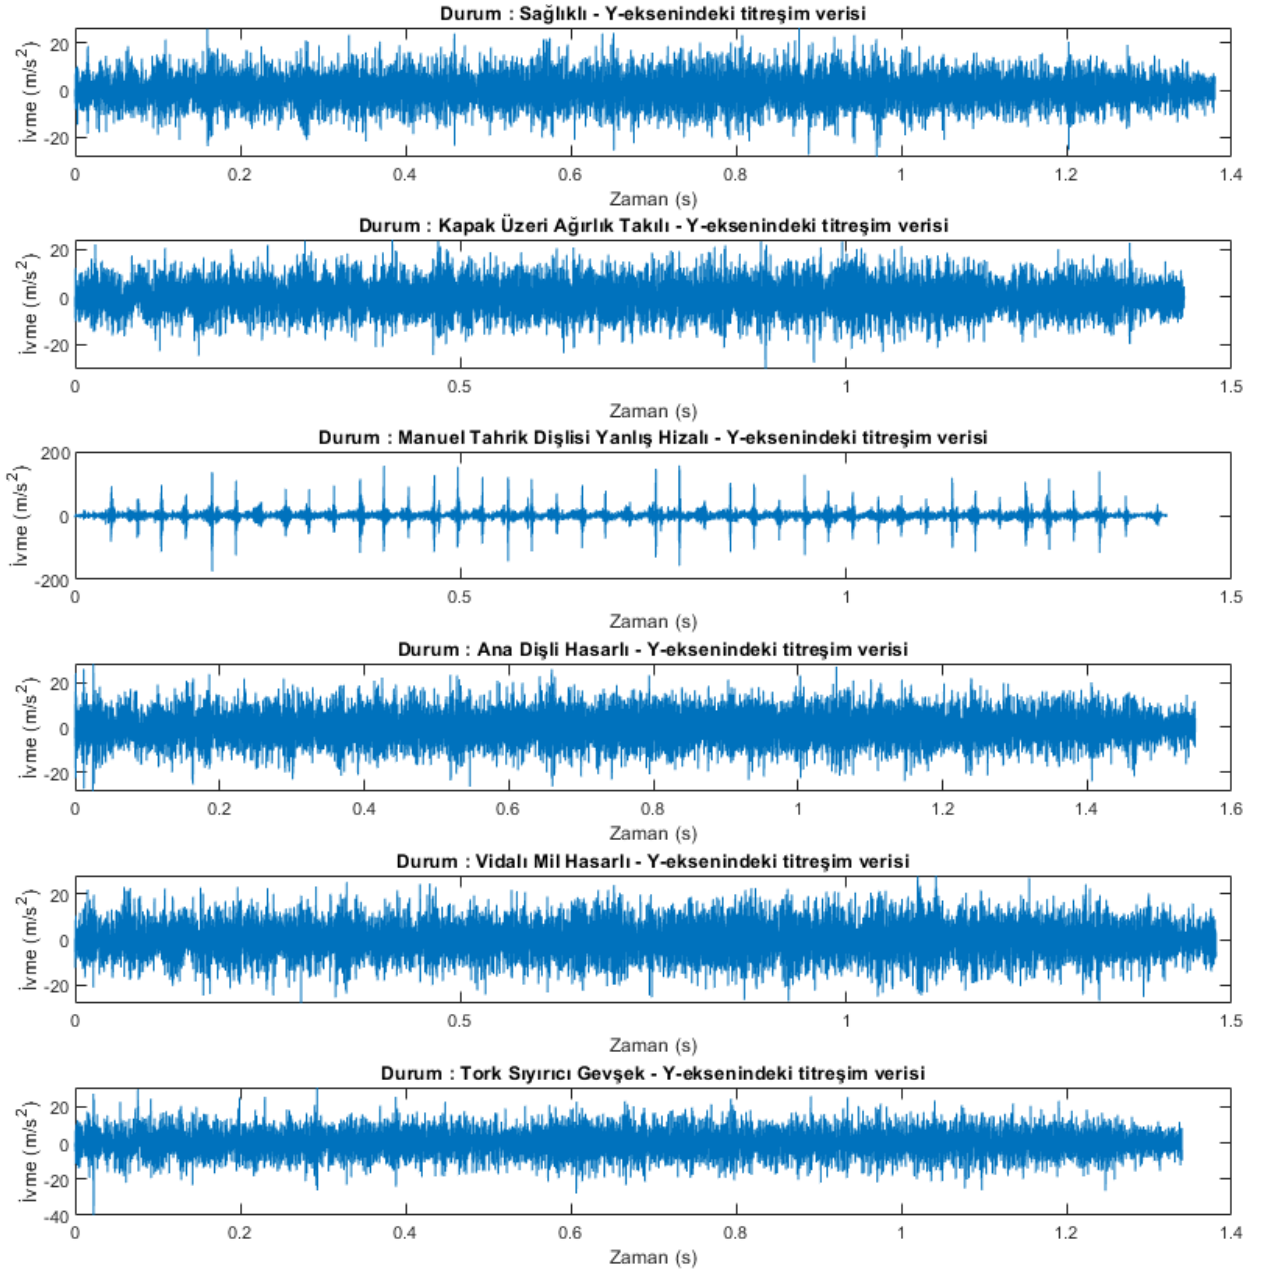
Şekil 3.22 Z-Ekseni Titreşim Grafiği

Şekil 3.17 içerisinde gösterilen ham veri örneğinde her sütun yukarıda bahsedilen bir değeri temsil etmektedir. Her satır bir 20000 Hz örneklem hızıyla kaydedilen bir örnekleme belirtir. Ham veri içerisinde "Time" olarak adlandırılan zaman verisi, veri toplama işlemine başlangıç anından itibaren geçen süreyi belirtir. Testler boyunca her bir hareket yaklaşık 1,5 – 2 saniye sürmüştür.

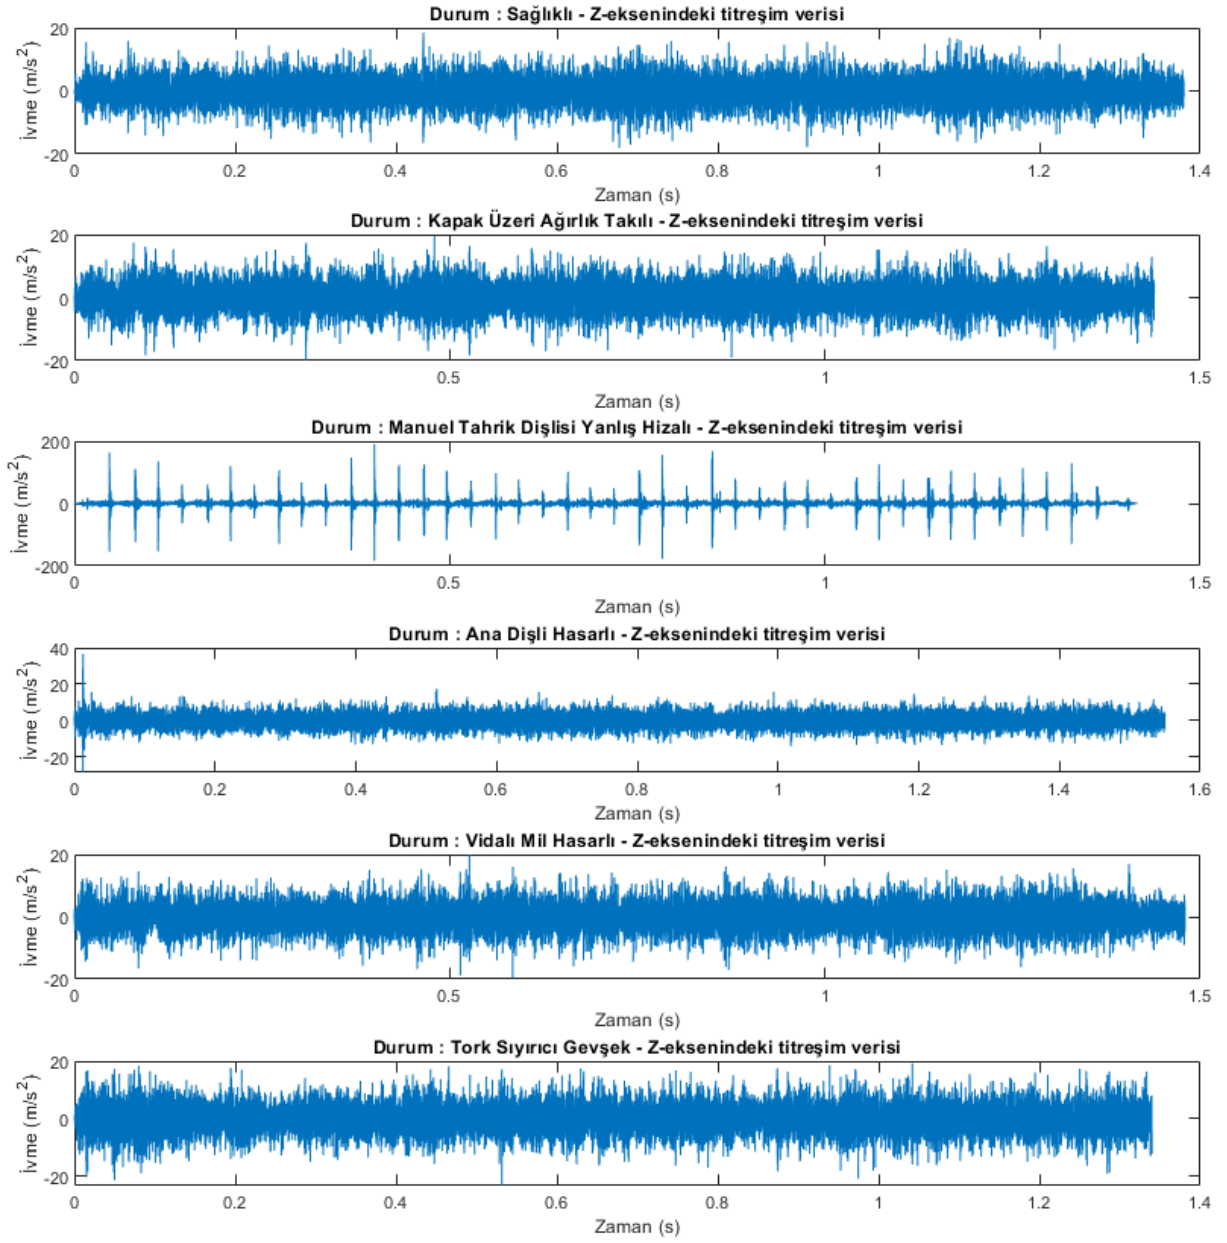
1 sağlıklı, 5 hata durumundan oluşan toplam 6 sınıftan seçilen kapak açılma verilerinin zaman alanı akım ve 3 eksenindeki titreşim verileri Şekil 3.23, Şekil 3.24, Şekil 3.25 ve Şekil 3.26 içerisinde verilmiştir. Aynı verilerin FFT ile elde edilen frekans alanı grafikleri Şekil 3.27, Şekil 3.28 ve Şekil 3.29 içerisinde verilmiştir. İvme sensörünün yerleşiminde göre eksen takımı Şekil 3.30 içerisinde verilmiştir.




Şekil 3.23 X-Eksenindeki Titreşim Verileri



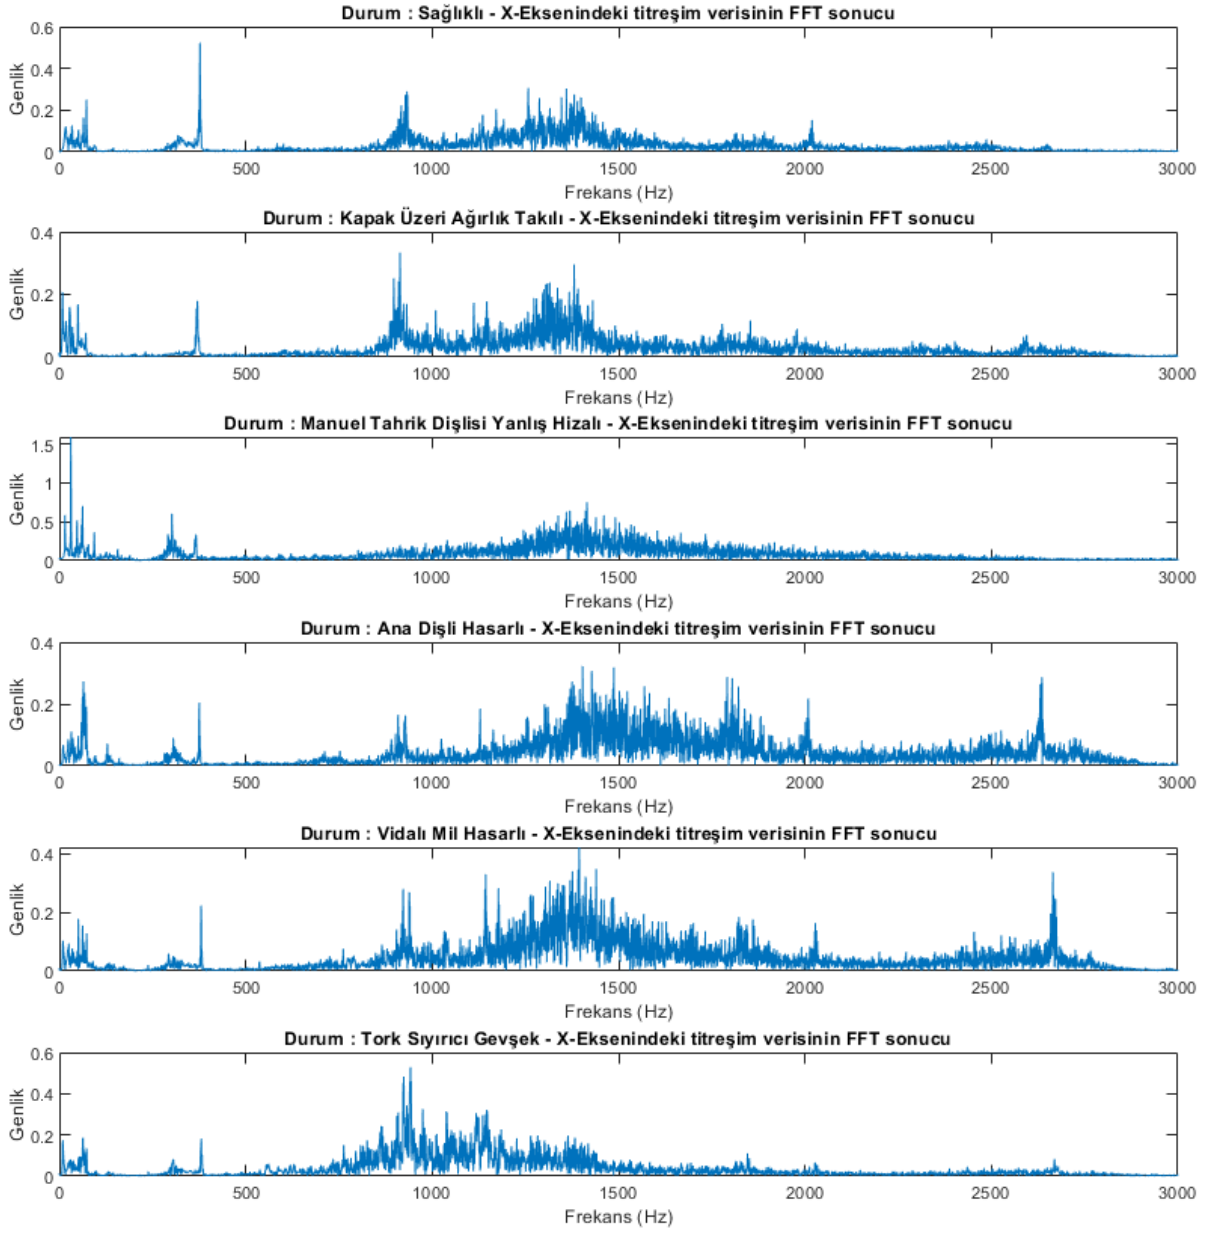
Şekil 3.24 Y-Eksenindeki Titreşim Verileri



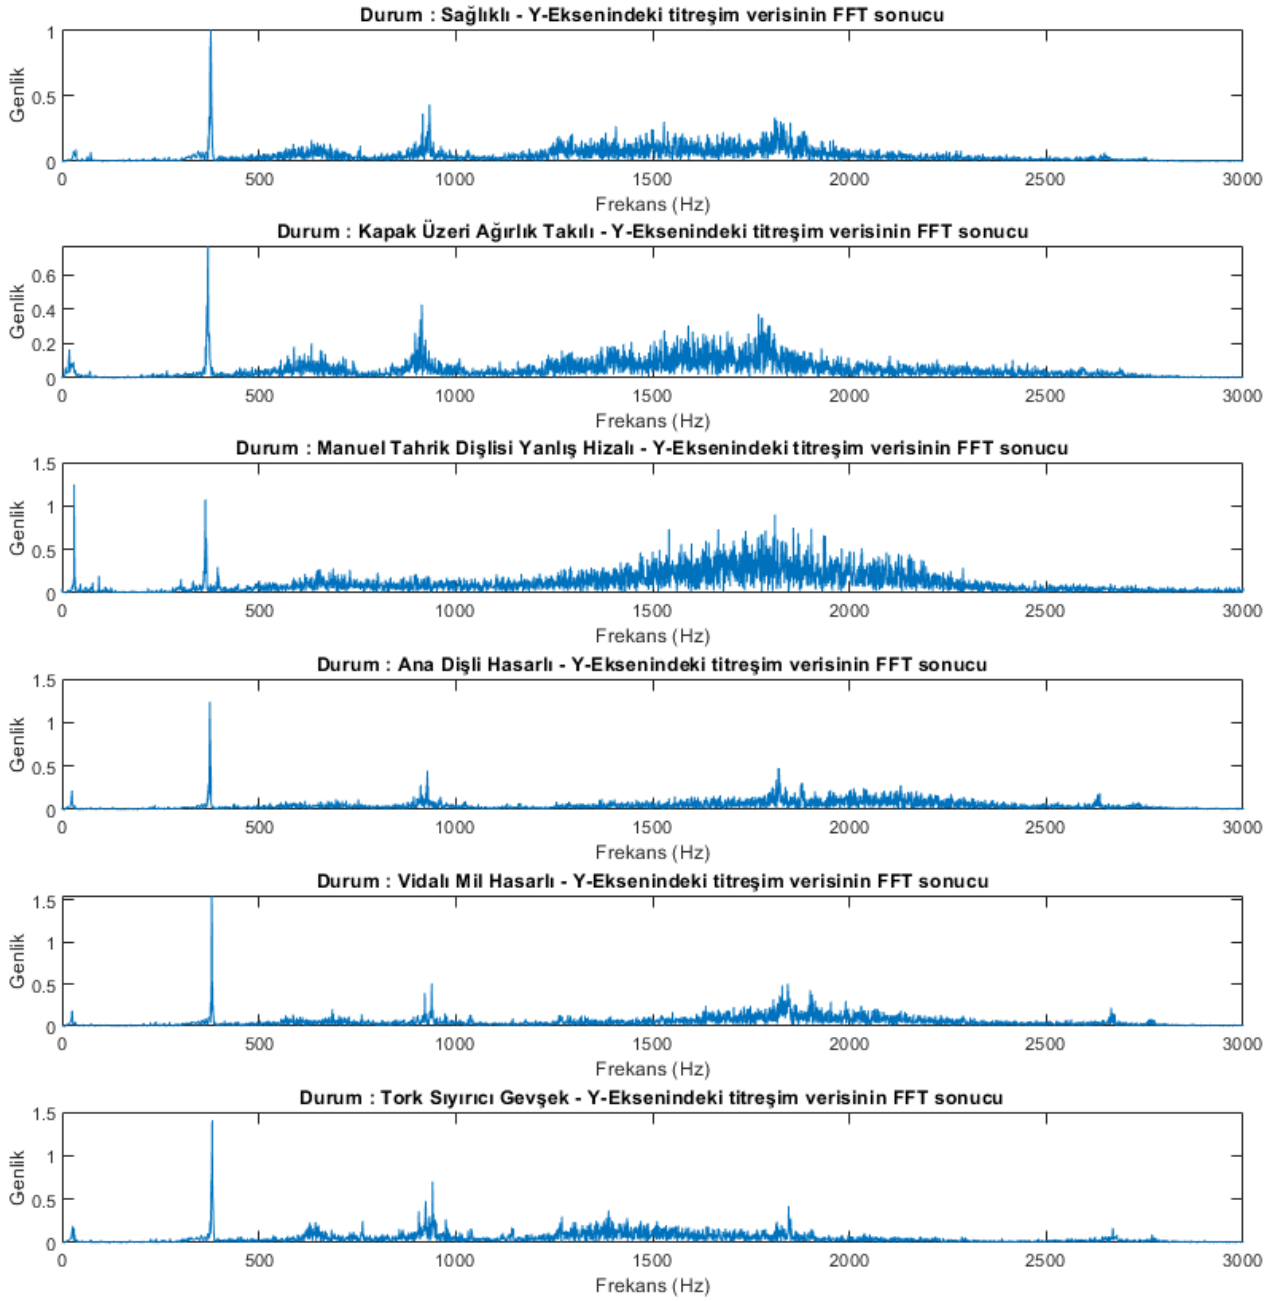
Şekil 3.25 Z-Eksenindeki Titreşim Verileri



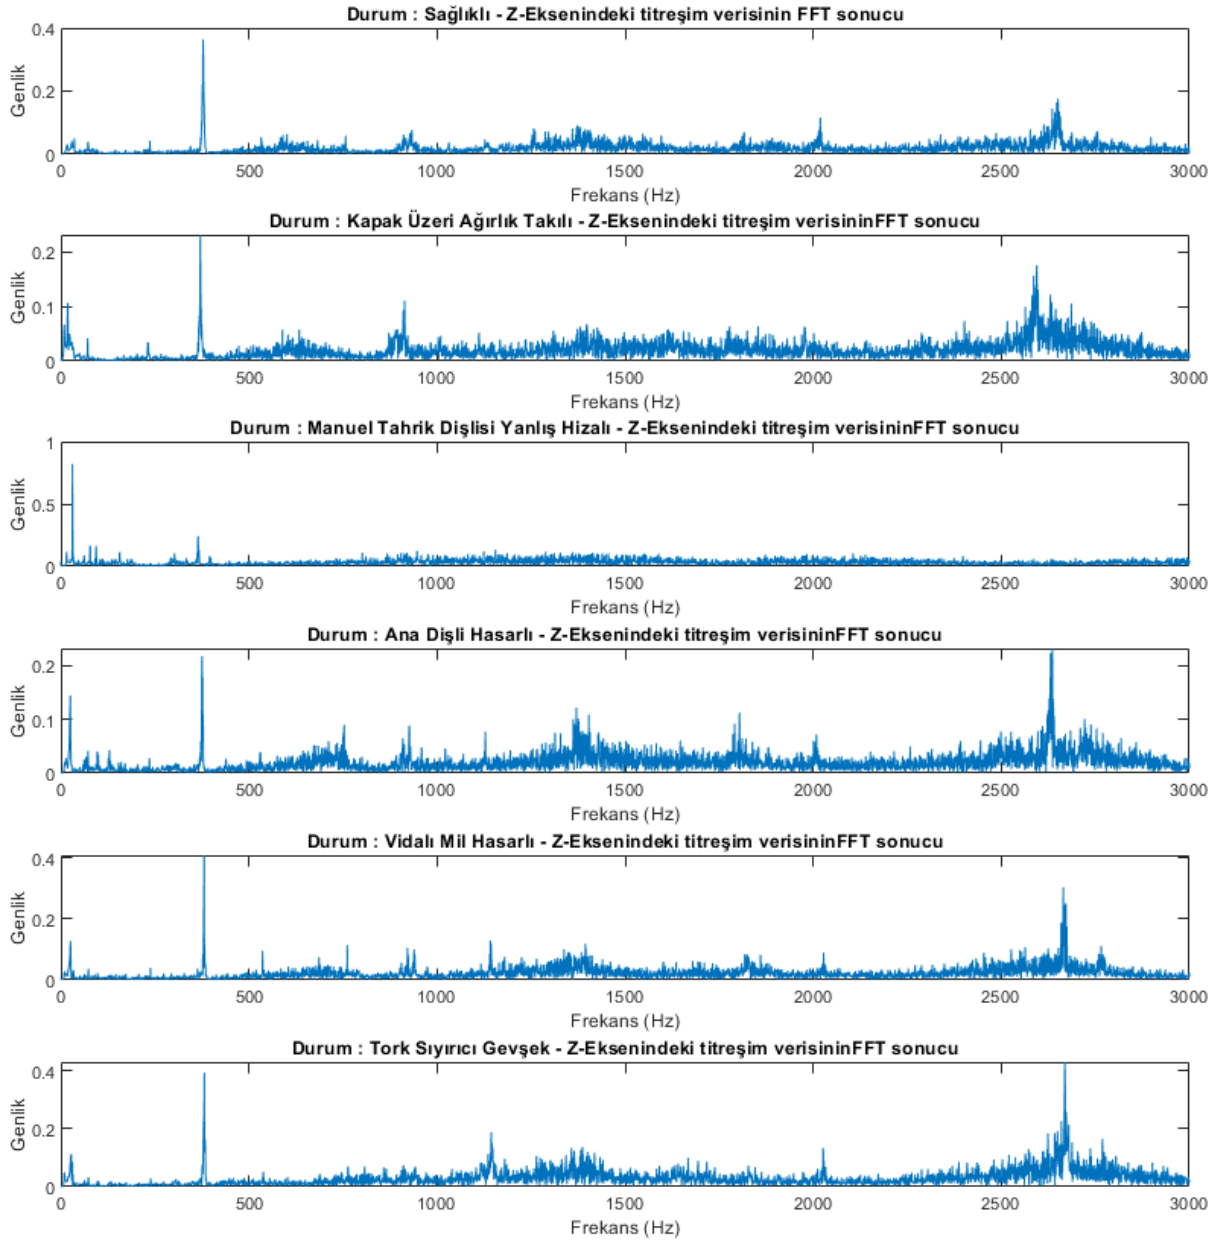
Şekil 3.26 Akım Verileri




Şekil 3.27 X-Eksenindeki Titreşimin FFT Sonuçları



Şekil 3.28 Y-Eksenindeki Titreşimin FFT Sonuçları



Şekil 3.29 Z-Eksenindeki Titreşimin FFT Sonuçları



Şekil 3.30 Eksen Takımı

3.1.1.3.2 İşlenmiş Veri Seti

“3.1.1.3.1 Ham Veri Seti” başlığı altında içeriği belirtilen ham veri edinim işlemi tamamlandıktan sonra, zaman serisi veri içeren ham veri örneklerinden zaman ve frekans alanı istatistiksel öznitelik çıkarımı yapılarak veri boyutu indirgenmiştir. Her eksendeki titreşim verisinden zaman ve frekans alanında istatistiksel öznitelikler çıkarılmış, akım RMS verisinden zaman alanı istatistiksel öznitelikler çıkarılmıştır. Bu öznitelikler:

- Zaman alanı öznitelikleri (Bkz. Tablo 2-5):
 - Basıklık
 - Ortalama
 - Çarpıklık
 - Varyans
 - Tepe Faktörü

- Standart Sapma
 - Toplam
 - Marj Faktörü
 - Tepe
 - RMS
- Frekans Alanı Öznitelikler (Bkz. Tablo 2-6):
 - Frekans Merkezi
 - RMS Frekans
 - Kök Varyans Frekansı

Öznitelik çıkarımı ile birlikte her bir veri örneği için “sınıf” (veri seti içerisindeki ismi: Class) ve “aksiyon” (veri seti içerisindeki ismi: action) sütunları eklenmiştir. Sınıf sütunu veri örneğinin Tablo 3-2 içerisinde tanımlanan 6 sınıftan hangisine ait olduğunu, aksiyon sütunu açılış ya da kapanış hareketlerinden hangisi sırasında toplandığını tanımlar. Zaman serisi verilerden zaman ve frekans alanı öznitelik çıkarımı ve etiketleme işlemi Python programlama dili, Pandas kütüphanesi ve Numpy kütüphanesi kullanarak gerçekleştirilmiştir.

Öznitelik çıkarımı ve etiketleme aşamasından sonra, $N \times 6$ (N değeri ver kayıt süresine göre değişkenlik göstermekte ve yaklaşık 29000 – 30000 arasındadır) boyutunda matrisler olan ham veri örnekleri, 1×55 boyutuna indirgenmiştir. Son olarak ham veri setini oluşturan tüm veri örneklerinden elde edilen öznitelik vektörleri arka arkaya sıralanarak makine öğrenmesi işleminde kullanmak amacıyla işlenmiş veri seti oluşturulmuştur.

İşlenmiş veri setindeki her bir satır, ham veri setindeki bir veri örneğinden çıkarılmış öznitelikleri belirtir. Başka bir deyişle işlenmiş veri setindeki her bir satır yukarıda ifade edilen 1×55 'lik vektöre tekabül eder ve dolayısıyla işlenmiş veri seti 1585×55 'lik bir matristir. Bu matrisin 53 sütunu öznitelikleri, son iki sütunu da sınıf ve aksiyon bilgilerini ifade eder.

İşlenmiş veri seti “EK-1 Veri Seti Bilgileri” içerisinde görüldüğü gibi 54 sütun ve 1585 satırdan oluşmaktadır. Veri setinde boş hücre bulunmamaktadır. Veri seti içerisinde

titreşim verisinin 3 ekseninde zaman ve frekans alanı öznitelikleri ve akım verisinin zaman alanı özniteliklerinin bulunduğu görülmüştür.

3.1.2 Yöntem

Durum izleme uygulamaları geliştirirken takip edilecek adımlar genellikle sırasıyla: veri edinim ve ön işleme, öznitelik seçimi ve çıkarımı, model seçimi ve doğrulamadır [2]. “3.1.1 Veri Seti” başlığı altında belirtilen titreşim ve akım verisi sırasıyla bu adımlardan geçmiş ve uygulamada kullanılacak olan makine öğrenmesi modeli ve öznitelikler seçilmiştir. Bu adımlar kısaca:

1. Veri Edinim ve Ön İşleme:

“3.1.1.2 Veri Edinimi” başlığı içerisinde belirtildiği şekilde, farklı sağlık durumlarında çalıştırılan askeri sistem üzerinden 3 eksenli titreşim verisi ve akım verisi toplanmıştır. Bu veriler daha sonra “3.1.1.3.2 İşlenmiş Veri Seti” başlığı altında belirtildiği gibi ön işleme aşamasından geçerek öznitelik çıkarımı yapılmış ve makine öğrenmesi teknikleriyle kullanıma hazır hale getirilmiştir. Bu aşama ve sonrasında işlenmiş veri seti standardize edilerek kullanılmıştır.

2. Ana Bileşen Analizi ve Öznitelik ve Seçimi:

Öznitelik seçiminde “2.2.6.3 Öznitelik Seçimi” başlığı altında belirtilen sarıcı metotlardan [39] olan RFE metodu kullanılmıştır. Bu adım, “2.2.3 Hata Sınıflandırma” başlığı altında belirtilen literatür taramasında sıkça rastlanan sınıflandırıcı modellerin her biri için aşağıdaki 3 yolla, farklı parametreler ile PCA ve öznitelik seçimi gerçekleştirilerek tekrarlanmıştır:

- Sadece PCA uygulayarak (farklı ana bileşen sayılarıyla tekrarlanmıştır)
- Sadece RFE uygulayarak (farklı öznitelik sayılarıyla tekrarlanmıştır)
- Önce RFE sonra PCA uygulayarak (farklı öznitelik ve ana bileşen sayılarıyla tekrarlanmıştır)

3. Doğrulama ve Model Seçimi:

“2.2.3 Hata Sınıflandırma” başlığı altında belirtilen literatür taramasında sıkça rastlanan sınıflandırıcı modellerin her biri için 100’er kere eğitim-test işlemi

gerçekleştirilmiş ve doğruluk puanlarının ortalaması alınmıştır. Ortalama doğruluk oranının en yüksek olduğu model ve öznitelikler seçilmiştir. İkinci adımda gerçekleştirilen her Ana Bileşen Analizi ve Öznitelik Seçimi için bu adım tekrarlanmıştır.

3.1.3 Model ve Öznitelik Seçimi Sonuçları


Bu bölümde SVM, DT, KNN, RF ve LR modellerinin işlenmiş veri setiyle yapılan eğitim/test sürecindeki doğruluk puanları incelenmiştir. Gözlemler sonucunda tüm modeller için en iyi sonucun PCA uygulamadan RFE ya da SFS ile 5 öznitelik seçimi gerçekleştirildiği durum olduğu görülmüştür. KNN için en iyi sonuç $K = 10$ seçildiği durumda elde edilmiştir. Doğruluk puanlarına göre sıralandığında en iyi sonucu %99,85 doğruluk puanıyla SVM vermiştir. SVM’i takiben sıralama LR (%99,61), KNN (%99,66), RF (%99,32) ve DT (%99,29) şeklinde olmuştur.

Öznitelik seçimi test ve eğitim veri setlerinin seçiminden etkilenmektedir. Bu sebeple hangi özniteliklerin sonuca en çok etki ettiğini tespit etmek amacıyla test ve eğitim veri setleri 100 kere rastgele seçilmiş ve her eğitim seti için RFE ve SFS (sadece KNN modeli için) yöntemleri ile en ekili öznitelikler seçilmiştir. Özniteliklerin sonuca etkisini ortaya koyabilmek amacıyla her RFE ve SFS sonrasında ilk 10 arasında giren öznitelikler tespit edilmiştir. Bu işlem aşağıda sonuçları belirtilen her bir makine öğrenmesi modeli için gerçekleştirilmiş ve makine öğrenmesi modellerine göre özniteliklerin etkinliği ortaya koyulmuştur.

Aşağıda farklı modellerle gerçekleştirilen testlerin sonuçları ve seçilen öznitelik sayısı ya da ana bileşen sayısı 2 olan modellerin karar sınırları ile karışıklık matrisleri gösterilmiştir. Görseller içerisinde 0’dan 5’e kadar sıralandığı görülen lejant değerleri sırasıyla Sınıf 1 – Sınıf 6’yı ifade etmektedir.

3.1.3.1 SVM Sınıflandırıcı İçin Sonuçlar

SVM modeli için özniteliklerin en başarılı 10 öznitelik arasında bulunma sıklığı Şekil 3.31 içerisinde gösterildiği gibidir.



Şekil 3.31 Özniteliklerin SVM Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı

Şekil 3.31 içerisinde görüldüğü üzere 100 deneme sonucunda SVM modeli için en başarılı 10 öznitelik aşağıda verildiği gibidir:

1. X eksenindeki titreşimin kök varyans frekansı (100)
2. X eksenindeki titreşimin kök kare ortalama frekansı (100)

3. Akım ortalama deęeri (100)
4. Z eksenindeki titreşimin standart sapması (95)
5. X yönündeki titreşimin kök kare ortalaması (92)
6. Z yönündeki titreşimin kök kare ortalaması (81)
7. X yönündeki titreşimin standart sapması (76)
8. Z yönündeki titreşimin kök varyans frekansı (74)
9. Akım varyansı (38)
10. Akım toplamı (38)

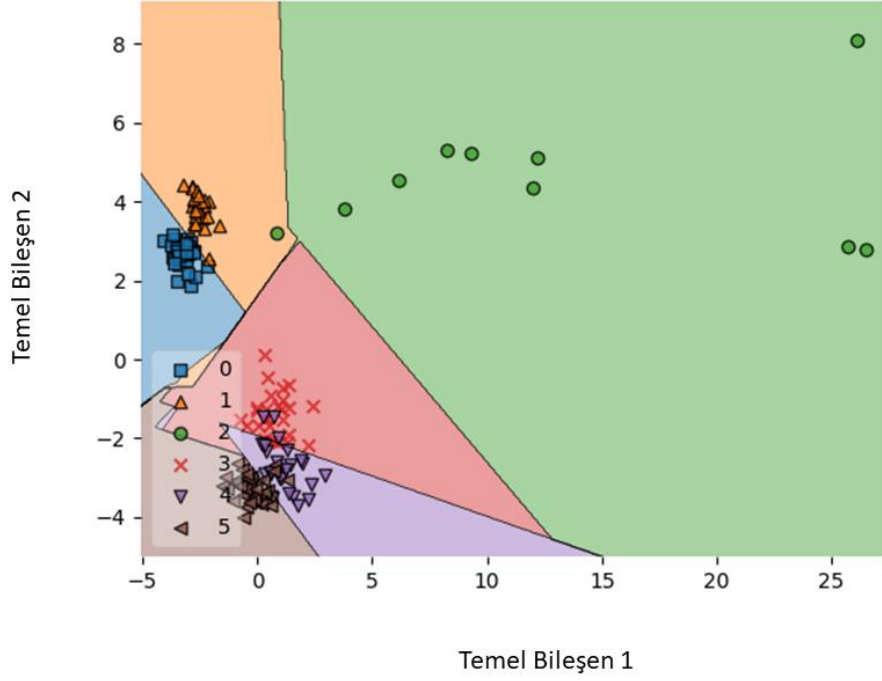
SVM sınıflandırma modeli ile yapılan testlerin sonuçları Tablo 3-4 içerisinde verilmiştir. Eğitilen SVM modelinde $C = 100$ seçilmiş, kernel = linear fonksiyonu kullanılmıştır.

Tablo 3-4 SVM ($C = 100$, kernel = linear) Modeli Doğruluk Puanları


SVM Sınıflandırıcı	Sadece PCA uygulandı	Ana bileşen sayısı = 2	Doğruluk puanı: %92,32
		Ana bileşen sayısı = 3	Doğruluk puanı: %93,84
		Ana bileşen sayısı = 5	Doğruluk puanı: %96,37
	Sadece RFE uygulandı	Öznitelik sayısı = 2	Doğruluk puanı: %99,25
		Öznitelik sayısı = 3	Doğruluk puanı: %99,29
		Öznitelik sayısı = 5	Doğruluk puanı: %99,85
	RFE ve PCA birlikte uygulandı	Ana bileşen sayısı = 10, Öznitelik sayısı = 2	Doğruluk puanı: %96,69
		Ana bileşen sayısı = 10, Öznitelik sayısı = 3	Doğruluk puanı: %99,59
		Ana bileşen sayısı = 5, Öznitelik sayısı = 2	Doğruluk puanı: %96,35

		Ana bileşen sayısı = 5, Öznitelik sayısı = 3	Doğruluk puanı: %99.72
--	--	---	------------------------

Sadece PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.32 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.33 içerisinde verilmiştir.



Şekil 3.32 İki Ana Bileşen ile Eğitilen SVM Modeli

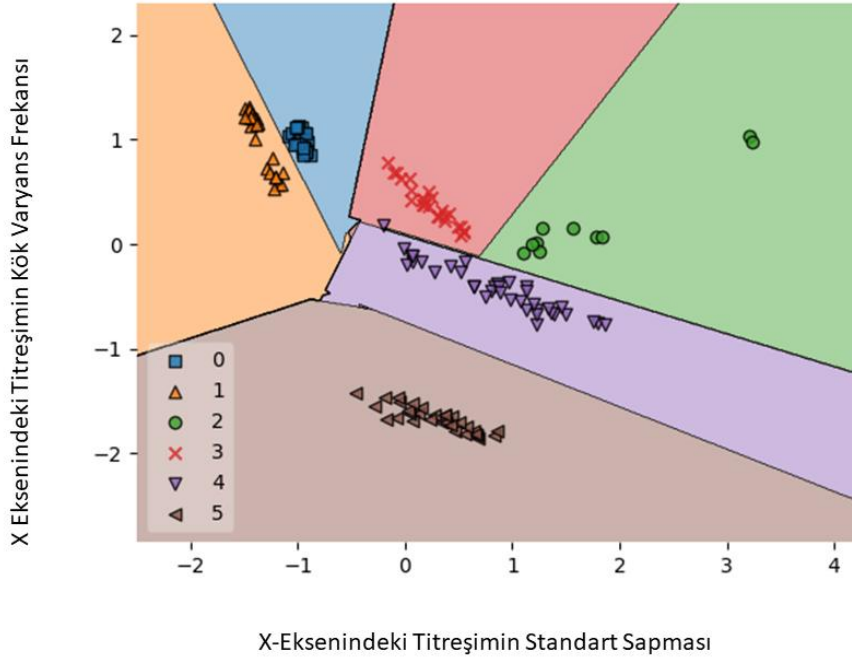


Şekil 3.33 İki Ana Bileşen ile Eğitilen SVM Modeli Karışıklık Matrisi


Sadece RFE uygulayıp, 2 öznelik seçilen son testin sonucunda Şekil 3.34 içerisinde gösterilen karar sınırları meydana gelmiştir. RFE sonucunda model başarımı için en etkili iki öznelik sırasıyla aşağıda verilmiştir:

1. “X eksenindeki titreşimin standart sapma değeri”
2. “X eksenindeki titreşimin kök varyans frekansı”

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.35 içerisinde verilmiştir.



Şekil 3.34 İki Öznelik ile Eğitilen SVM Modeli




Şekil 3.35 İki Öznitelik ile Eğitilen SVM Modeli Karışıklık Matrisi


Birlikte önce RFE uygulayıp 10 öznitelik seçilen ve sonrasında bu özniteliklere PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.36 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen 10 öznitelik aşağıdaki belirtilmiştir:

1. X eksenindeki titreşimin standart sapma değeri,
2. Z eksenindeki titreşimin standart sapma değeri,
3. X eksenindeki titreşimin kök kare ortalama değeri,
4. Z eksenindeki titreşimin kök kare ortalama değeri,
5. X eksenindeki titreşimin kök kare ortalama frekansı,
6. X eksenindeki titreşimin kök varyans frekansı,
7. Y eksenindeki titreşimin kök kare frekansı,
8. Z eksenindeki titreşimin kök varyans frekansı,
9. Akım ortalama değeri,
10. Akım standart sapma değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.37 içerisinde verilmiştir.



Şekil 3.36 RFE 10 - PCA 2 ile Eğitilen SVM Modeli




Şekil 3.37 RFE 10 - PCA 2 ile Eğitilen SVM Modeli Karışıklık Matrisi


Birlikte önce RFE uygulayıp 5 öznelik seçilen ve sonrasında bu özneliklere PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.38 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda belirtilmiştir:

1. X eksenindeki titreşimin standart sapma değeri,
2. X eksenindeki titreşimin kök kare ortalama frekansı,
3. X yönündeki titreşimin kök varyans frekansı,
4. Akım ortalama değeri,
5. Akım varyans değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.39 içerisinde verilmiştir.




Şekil 3.38 RFE 5 - PCA 2 ile Eğitilen SVM Modeli



Şekil 3.39 RFE 5 - PCA 2 ile Eğitilen SVM Modeli Karışıklık Matrisi

3.1.3.2 DT Sınıflandırıcı İçin Sonuçlar

DT modeli için özniteliklerin en başarılı 10 öznitelik arasında bulunma sıklığı Şekil 3.40 içerisinde gösterildiği gibidir.



Şekil 3.40 Özniteliklerin DT Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı

Şekil 3.40 içerisinde görüldüğü üzere 100 deneme sonucunda DT modeli için en başarılı 10 öznitelik aşağıda verildiği gibidir:

1. Akım varyansı (93)
2. Akım standart sapması (93)


3. Akım tepe faktörü (92)
4. Akım ortalama değeri (85)
5. Akım en düşük değeri (80)
6. Akım çarpıklık değeri (75)
7. Akım toplam değer (71)
8. X eksenindeki titreşimin kök kare ortalama frekansı (56)
9. Akım marj faktörü (56)
10. X eksenindeki titreşimin kök varyans frekansı (50)

DT Sınıflandırıcı ile yapılan testlerin sonuçları Tablo 3-5 içerisinde verilmiştir.


Tablo 3-5 DT Modeli Doğruluk Puanları

DT Sınıflandırıcı	Sadece PCA uygulandı	Ana bileşen sayısı = 2	Doğruluk puanı: %87,13
		Ana bileşen sayısı = 3	Doğruluk puanı: %91,34
		Ana bileşen sayısı = 5	Doğruluk puanı: %92,66
	Sadece RFE uygulandı	Öznelik sayısı = 2	Doğruluk puanı: %96,97
		Öznelik sayısı = 3	Doğruluk puanı: %98,69
		Öznelik sayısı = 5	Doğruluk puanı: %99,29
	RFE ve PCA birlikte uygulandı	Ana bileşen sayısı = 10, Öznelik sayısı = 2	Doğruluk puanı: %87,54
		Ana bileşen sayısı = 10, Öznelik sayısı = 3	Doğruluk puanı: %90,99
		Ana bileşen sayısı = 5, Öznelik sayısı = 2	Doğruluk puanı: %86,45
		Ana bileşen sayısı = 5, Öznelik sayısı = 3	Doğruluk puanı: %93,92

Sadece PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.41 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.42 içerisinde verilmiştir.



Şekil 3.41 İki Ana Bileşen ile Eğitilen DT Modeli




Şekil 3.42 İki Ana Bileşen ile Eğitilen DT Modeli Karışıklık Matrisi


Sadece RFE uygulayıp, 2 öznelik seçilen son testin sonucunda Şekil 3.43 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda belirtilmiştir:

1. X eksenindeki titreşimin kök varyans frekansı,
2. Z eksenindeki titreşimin kök kare ortalama frekansı.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.44 içerisinde verilmiştir.



Şekil 3.43 İki Öznitelik ile Eğitilen DT Modeli




Şekil 3.44 İki Öznitelik ile Eğitilen DT Modeli Karışıklık Matrisi


Önce RFE uygulayıp 5 öznitelik seçilen sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda Şekil 3.45 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznitelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin kök varyans frekansı,
2. Z eksenindeki titreşimin kök kare ortalama frekansı,
3. Akım ortalama değeri,
4. Akım marj faktörü,
5. Akım tepe değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.46 içerisinde verilmiştir.



Şekil 3.45 RFE 5 - PCA 2 ile Eğitilen DT Modeli

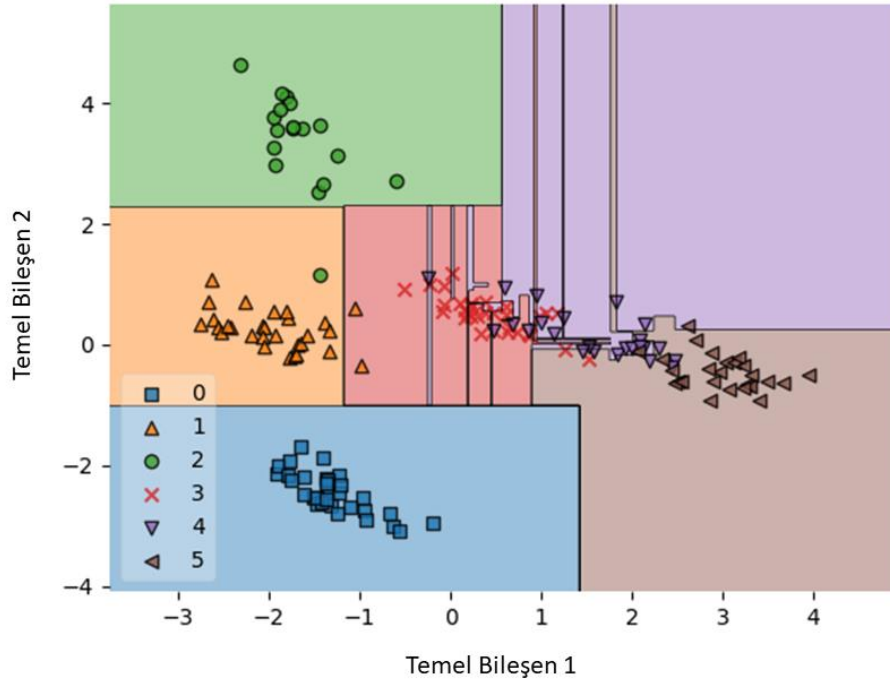


Şekil 3.46 RFE 5 - PCA 2 ile Eğitilen DT Modeli Karışıklık Matrisi


Önce RFE uygulayıp 10 öznitelik seçilen, sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda, Şekil 3.47 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznitelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin kök kare ortalaması,
2. X eksenindeki titreşimin kök varyans frekansı,
3. Y eksenindeki titreşimin kök kare ortalama frekansı,
4. Z eksenindeki titreşimin kök kare ortalama frekansı,
5. Akım basıklık değeri,
6. Akım en düşük değeri,
7. Akım ortalama değeri,
8. Akım çarpıklık değeri,
9. Akım varyansı,
10. Akım tepe faktörü.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.48 içerisinde verilmiştir.



Şekil 3.47 RFE 10 - PCA 2 ile Eğitilen DT Modeli




Şekil 3.48 RFE 10 - PCA 2 ile Eğitilen DT Modeli Karışıklık Matrisi

3.1.3.3 KNN sınıflandırıcı İçin Sonuçlar

KNN modelinde kullanılacak olan K sabitini seçmek için öznitelik seçimi yapılmadan tüm öznitelikler ile KNN modeli farklı K sabitleriyle test edilmiş ve Tablo 3-6 içerisindeki doğruluk puanları elde edilmiştir. En iyi sonucu veren K sabitinin K = 10 olduğu Şekil 3.49 içerisindeki gibi görülmüştür.

Tablo 3-6 K Sabitine Göre KNN Modeli Doğruluk Puanları


KNN Sınıflandırıcı	K = 3	Doğruluk puanı: %96.62
	K = 5	Doğruluk puanı: %96.97
	K = 10	Doğruluk puanı: %97.23
	K = 20	Doğruluk puanı: %96.36
	K = 30	Doğruluk puanı: %96.09
	K = 40	Doğruluk puanı: %95.91
	K = 50	Doğruluk puanı: %95.47
	K = 60	Doğruluk puanı: %94.41
	K = 80	Doğruluk puanı: %92.24
	K = 100	Doğruluk puanı: %90.98



Şekil 3.49 K Sabitine Göre KNN Modeli Doğruluk Puanları

K sabiti 10 olarak seçildikten sonra boyut azaltma işlemleriyle model test edilmiştir. KNN modeli için Sıralı Öznitelik Seçimi tekniği (İng. SFS) kullanılmıştır. Farklı öznitelik ve ana bileşen sayılarıyla yapılan test sonuçları Tablo 3-7 içerisinde verilmiştir.

KNN modeli için özniteliklerin en başarılı 10 öznitelik arasında bulunma sıklığı Şekil 3.50 içerisinde gösterildiği gibidir.



Şekil 3.50 Özniteliklerin KNN Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı

Şekil 3.50 içerisinde görüldüğü üzere 100 deneme sonucunda SVM modeli için en başarılı 10 öznelik aşağıda verildiği gibidir:


1. X eksenindeki titreşimin kök kare ortalama frekansı (100)
2. Z eksenindeki titreşimin basıklık değeri (98)
3. Z eksenindeki titreşimin varyansı (95)
4. X eksenindeki titreşimin varyansı (89)
5. Z eksenindeki titreşimin standart sapması (79)
6. Z eksenindeki titreşimin en düşük değeri (77)
7. X eksenindeki titreşimin standart sapması (67)
8. Z eksenindeki titreşimin kök kare ortalama frekansı (54)
9. X eksenindeki titreşimin kök varyans frekansı (51)
10. Y eksenindeki titreşimin varyansı (45)

Tablo 3-7 KNN Modeli Doğruluk Puanları


KNN Sınıflandırıcı	Sadece PCA uygulandı	Ana bileşen sayısı = 2	Doğruluk puanı: %91,81
		Ana bileşen sayısı = 3	Doğruluk puanı: %94,55
		Ana bileşen sayısı = 5	Doğruluk puanı: %96,02
	Sadece SFS uygulandı	Öznelik sayısı = 2	Doğruluk puanı: %99,25
		Öznelik sayısı = 3	Doğruluk puanı: %99,62
		Öznelik sayısı = 5	Doğruluk puanı: %99,66
	RFE ve PCA birlikte uygulandı	Ana bileşen sayısı = 10, Öznelik sayısı = 2	Doğruluk puanı: %90,82
		Ana bileşen sayısı = 10, Öznelik sayısı = 3	Doğruluk puanı: %98,11

		Ana bileşen sayısı = 5, Öznitelik sayısı = 2	Doğruluk puanı: %96,76
		Ana bileşen sayısı = 5, Öznitelik sayısı = 3	Doğruluk puanı: %99,49

Sadece PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.51 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.52 içerisinde verilmiştir.



Şekil 3.51 İki Ana Bileşen ile Eğitilen KNN Modeli




Şekil 3.52 İki Ana Bileşen ile Eğitilen KNN Modeli Karışıklık Matrisi


Sadece SFS uygulayıp, 2 öznelik seçilen son testin sonucunda Şekil 3.53 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin standart sapması,
2. X eksenindeki titreşimin kök kare ortalama frekansı,

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.54 içerisinde verilmiştir.



Şekil 3.53 İki Öznelik ile Eğitilen KNN Modeli




Şekil 3.54 İki Öznitelik ile Eğitilen KNN Modeli Karışıklık Matrisi


Önce SFS uygulayıp 10 öznitelik seçilen sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda Şekil 3.55 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznitelikler aşağıda verilmiştir:

1. Z eksenindeki titreşimin basıklık değeri,
2. Z eksenindeki titreşimin en düşük değeri,
3. X eksenindeki titreşimin varyansı,
4. Z eksenindeki titreşimin varyansı,
5. X eksenindeki titreşimin standart sapması,
6. Z eksenindeki titreşimin standart sapması,
7. X eksenindeki titreşimin kök kare ortalaması,
8. Z eksenindeki titreşimin kök kare ortalaması,
9. X eksenindeki titreşimin kök kare ortalama frekansı,
10. Z eksenindeki titreşimin kök kare ortalama frekansı.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.56 içerisinde verilmiştir.



Şekil 3.55 SFS 10 - PCA 2 ile Eğitilen KNN Modeli

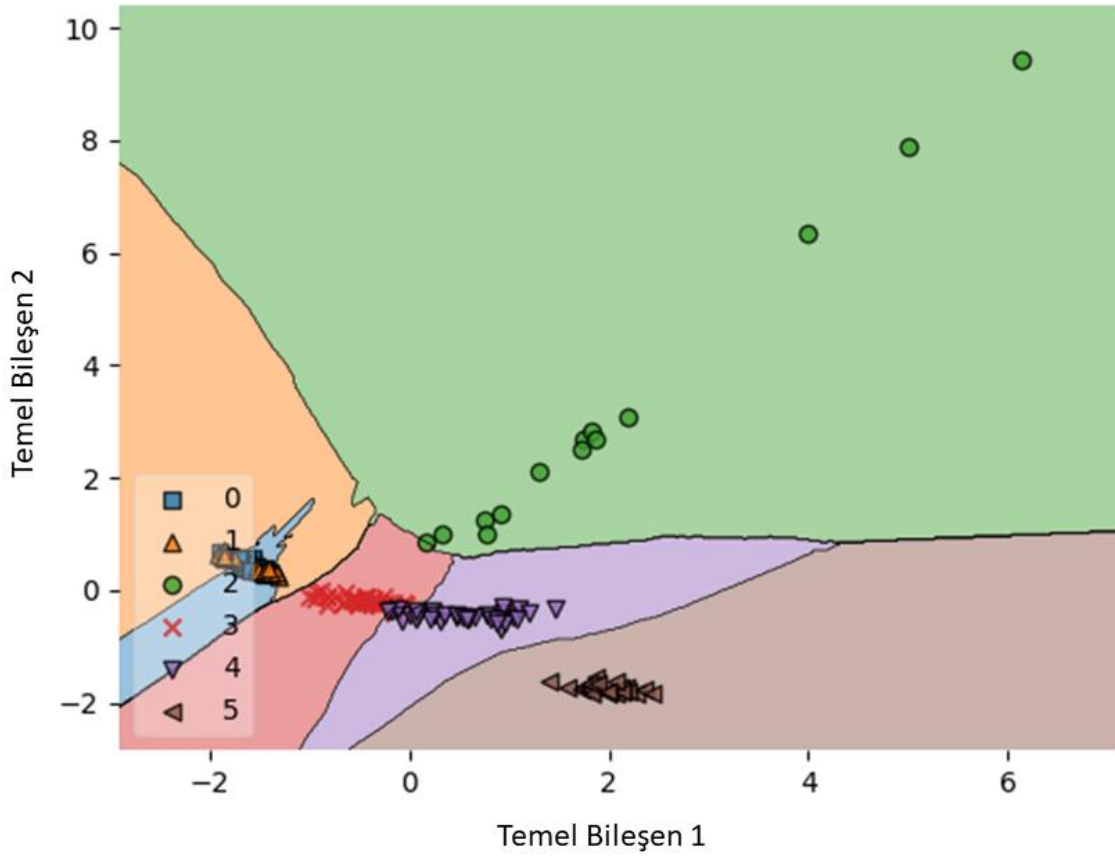


Şekil 3.56 SFS 10 - PCA 2 ile Eğitilen KNN Modeli Karışıklık Matrisi


Önce SFS uygulayıp 5 öznelik seçilen sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda Şekil 3.57 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. Y eksenindeki titreşimin basıklık değeri,
2. X eksenindeki titreşimin standart sapması,
3. Z eksenindeki titreşimin standart sapması,
4. X eksenindeki titreşimin kök kare ortalama frekansı,
5. Z eksenindeki titreşimin kök kare ortalama frekansı.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.58 içerisinde verilmiştir.




Şekil 3.57 SFS 5 - PCA 2 ile Eğitilen KNN Modeli



Şekil 3.58 SFS 5 - PCA 2 ile Eğitilen KNN Modeli Karışıklık Matrisi

3.1.3.4 RF Sınıflandırıcı İçin Sonuçlar

RF modeli için özniteliklerin en başarılı 10 öznitelik arasında bulunma sıklığı Şekil 3.59 içerisinde gösterildiği gibidir.



Şekil 3.59 Özniteliklerin RF Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı

Şekil 3.59 içerisinde görüldüğü üzere 100 deneme sonucunda RF modeli için en başarılı 10 öznitelik aşağıda verildiği gibidir:

1. X eksenindeki titreşimin kök kare ortalama frekansı (93)

2. Z eksenindeki titreşimin kök kare ortalama frekansı (91)
3. X eksenindeki titreşimin kök varyans frekansı (91)
4. Z eksenindeki titreşimin kök varyans frekansı (81)
5. Z eksenindeki titreşimin standart sapması (77)
6. X eksenindeki titreşimin standart sapması (76)
7. X eksenindeki titreşimin varyansı (73)
8. Akım en düşük değeri (61)
9. Akım ortalama değeri (52)
10. Y eksenindeki titreşimin kök varyans frekansı (21)


RF modeli ile yapılan testlerin doğruluk puanları Tablo 3-8 içerisinde verilmiştir. RF modeli oluşturulurken sklearn kütüphanesinin RandomForestClassifier modeli kullanılmış, model girdisi olarak max_depth = 5, n_estimators = 10, random_state = 0 seçilmiştir.

Tablo 3-8 RF Modeli Doğruluk Puanları


RF Sınıflandırıcı	Sadece PCA uygulandı	Ana bileşen sayısı = 2	Doğruluk puanı: %91
		Ana bileşen sayısı = 3	Doğruluk puanı: %93,46
		Ana bileşen sayısı = 5	Doğruluk puanı: %94,54
	Sadece RFE uygulandı	Öznitelik sayısı = 2	Doğruluk puanı: %97,89
		Öznitelik sayısı = 3	Doğruluk puanı: %98,55
		Öznitelik sayısı = 5	Doğruluk puanı: %99,32
	RFE ve PCA birlikte uygulandı	Ana bileşen sayısı = 10, Öznitelik sayısı = 2	Doğruluk puanı: %96,25
		Ana bileşen sayısı = 10, Öznitelik sayısı = 3	Doğruluk puanı: %97,81
		Ana bileşen sayısı = 5, Öznitelik sayısı = 2	Doğruluk puanı: %96,76

		Ana bileşen sayısı = 5, Öznitelik sayısı = 3	Doğruluk puanı: %98,23
--	--	---	------------------------

Sadece PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.60 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.61 içerisinde verilmiştir.



Şekil 3.60 İki Ana Bileşen ile Eğitilen RF Modeli




Şekil 3.61 İki Ana Bileşen ile Eğitilen RF Modeli Karışıklık Matrisi


Sadece RFE uygulayıp, 2 öznelik seçilen son testin sonucunda Şekil 3.62 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin varyansı,
2. X eksenindeki titreşimin kök kare ortalama frekansı.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.63 içerisinde verilmiştir.




Şekil 3.62 İki Öznitelik ile Eğitilen RF Modeli




Şekil 3.63 İki Öznitelik ile Eğitilen RF Modeli Karışıklık Matrisi

Önce RFE uygulayıp 10 öznitelik seçilen sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda Şekil 3.64 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.65 içerisinde verilmiştir.



Şekil 3.64 RFE 10 - PCA 2 ile Eğitilen RF Modeli




Şekil 3.65 RFE 10 - PCA 2 ile Eğitilen RF Modeli Karışıklık Matrisi


Önce RFE uygulayıp 5 öznelik seçilen sonrasında PCA ile 2 ana bileşen oluşturulan son testin sonucunda Şekil 3.66 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin kök kare ortalaması,
2. X eksenindeki titreşimin kök varyans frekansı,
3. Z eksenindeki titreşimin kök kare ortalama frekansı,
4. Z eksenindeki titreşimin kök varyans frekansı,
5. Akım en düşük değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.67 içerisinde verilmiştir.




Şekil 3.66 RFE 5 - PCA 2 ile Eğitilen RF Modeli



Şekil 3.67 RFE 5 - PCA 2 ile Eğitilen RF Modeli Karışıklık Matrisi

3.1.3.5 LR Sınıflandırıcı İçin Sonuçlar

LR modeli için özniteliklerin en başarılı 10 öznitelik arasında bulunma sıklığı Şekil 3.68 içerisinde gösterildiği gibidir.



Şekil 3.68 Özniteliklerin LR Modeli ile En Başarılı 10 Öznitelik Arasında Bulunma Sıklığı

Şekil 3.68 içerisinde görüldüğü üzere 100 deneme sonucunda LR modeli için en başarılı 10 öznitelik aşağıda verildiği gibidir:

1. Z eksenindeki titreşimin kök varyans frekansı (100)
2. Y eksenindeki titreşimin kök varyans frekansı (100)


3. X eksenindeki titreşimin standart sapması (100)
4. X eksenindeki titreşimin kök varyans frekansı (100)
5. X eksenindeki titreşimin kök kare ortalama frekansı (100)
6. Akım ortalama değeri (100)
7. Z eksenindeki titreşimin kök kare ortalama frekansı (99)
8. Akım toplam değeri (99)
9. Y eksenindeki kök kare ortalama frekansı (98)

LR modeli ile yapılan testlerin doğruluk puanları Tablo 3-9 içerisinde verilmiştir. LR modeli maksimum iterasyon sayısı 1000 olarak belirlenmiştir.


Tablo 3-9 LR Modeli Doğruluk Puanları

LR Sınıflandırıcı	Sadece PCA uygulandı	Ana bileşen sayısı = 2	Doğruluk puanı: %92,28
		Ana bileşen sayısı = 3	Doğruluk puanı: %94,76
		Ana bileşen sayısı = 5	Doğruluk puanı: %96,16
	Sadece RFE uygulandı	Öznitelik sayısı = 2	Doğruluk puanı: %96,11
		Öznitelik sayısı = 3	Doğruluk puanı: %99,25
		Öznitelik sayısı = 5	Doğruluk puanı: %99,61
	RFE ve PCA birlikte uygulandı	Ana bileşen sayısı = 10, Öznitelik sayısı = 2	Doğruluk puanı: %98,19
		Ana bileşen sayısı = 10, Öznitelik sayısı = 3	Doğruluk puanı: %99,58
		Ana bileşen sayısı = 5, Öznitelik sayısı = 2	Doğruluk puanı: %93,95
		Ana bileşen sayısı = 5, Öznitelik sayısı = 3	Doğruluk puanı: %99,69

Sadece PCA uygulayıp, 2 ana bileşen elde edilen son testin sonucunda Şekil 3.69 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.70 içerisinde verilmiştir.




Şekil 3.69 İki Ana Bileşen ile Eğitilen LR Modeli




Şekil 3.70 İki Ana Bileşen ile Eğitilen LR Modeli Karışıklık Matrisi

Sadece RFE uygulayıp, 2 öznelik seçilen son testin sonucunda Şekil 3.71 içerisinde gösterilen karar sınırları meydana gelmiştir. Bu model başarımına ilişkin karışıklık matrisi Şekil 3.72 içerisinde verilmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin kök varyans frekansı,
2. Y eksenindeki titreşimin kök varyans frekansı.



Şekil 3.71 İki Öznelik ile Eğitilen LR Modeli




Şekil 3.72 İki Öznelik ile Eğitilen LR Modeli Karışıklık Matrisi


Önce RFE uygulayıp 10 öznelik seçilen, sonrasında bu özneliklere PCA uygulayıp 2 ana bileşen oluşturulan testin sonucunda Şekil 3.73 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen Öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin standart sapması,
2. X eksenindeki titreşimin kök kare frekansı,
3. X eksenindeki titreşimin kök varyans frekansı,
4. Y eksenindeki titreşimin kök kare ortalama frekansı,
5. Y eksenindeki titreşimin kök varyans frekansı,
6. Z eksenindeki titreşimin kök kare ortalama frekansı,
7. Z eksenindeki titreşimin kök varyans frekansı,
8. Akım ortalama değeri,
9. Akım toplam değeri,
10. Akım tepe değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.74 içerisinde verilmiştir.



Şekil 3.73 RFE 10 - PCA 2 ile Eğitilen LR Modeli




Şekil 3.74 RFE 10 - PCA 2 ile Oluşturulan LR Modeli Karışıklık Matrisi


Önce RFE uygulayıp 5 öznelik seçilen, sonrasında bu özneliklere PCA uygulayıp 2 ana bileşen oluşturulan testin sonucunda Şekil 3.75 içerisinde gösterilen karar sınırları meydana gelmiştir. Seçilen öznelikler aşağıda verilmiştir:

1. X eksenindeki titreşimin kök kare ortalama frekansı,
2. X eksenindeki titreşimin kök varyans frekansı,
3. Y eksenindeki titreşimin kök varyans frekansı,
4. Z eksenindeki titreşimin kök varyans frekansı,
5. Akım ortalama değeri.

Bu model başarımına ilişkin karışıklık matrisi Şekil 3.76 içerisinde verilmiştir.



Şekil 3.75 RFE 5 - PCA 2 ile Eğitilen LR Modeli



Şekil 3.76 RFE 5 - PCA 2 ile Eğitilen LR Modeli Karışıklık Matrisi

3.2 FPGA’de Hata Tespit ve Sınıflandırma Algoritmasının Uygulanması

FPGA üzerinde durum izleme kapsamında hata tespit ve sınıflandırma uygulaması geliştirirken makine öğrenmesi eğitim aşaması çevrimdışı olarak, test aşaması çevrimiçi olarak gerçekleştirilmiştir. Durum izleme uygulaması Şekil 3.77 içerisinde gösterilen Digilent BASYS-3 FPGA geliştirme kartı üzerinde geliştirilmiştir.




Şekil 3.77 Digilent BASYS-3 FPGA Geliştirme Kartı [48]

Geliştirme kartı üzerindeki FPGA çipinin özellikleri aşağıda belirtilmiştir: [48]

- Xilinx Artix-7 FPGA (XC7A35T-1CPG236C)
- 5200 dilimde 33.280 mantık hücresi (her dilim dört adet 6 girişli LUT ve 8 flip-flop içerir)
- 1.800 Kbit hızlı blok RAM
- 90 DSP dilimi
- 450MHz'i aşan dahili saat hızları

FPGA kartı ile UART haberleşmesi üzerinden titreşim ve akım verilerinin paylaşılabilmesi için PL2023 USB – TTL dönüştürücü kullanılmıştır. FPGA programlama ve test sırasında titreşim, akım verilerini UART üzerinden göndermek için laptop bilgisayar kullanılmıştır. Test sistemi kurulumu Şekil 3.78 içerisinde verilmiştir.



Şekil 3.78 Test Sistemi Kurulumu

3.2.1 FPGA Tasarım Adımları

3.2.1.1 Tasarım Kısıtları

FPGA mimarisinin doğrudan ondalık sayı kullanmaya yönelik olmaması ve dolayısıyla ondalık sayı kullanımının uzmanlık gerektiren bir konu olması sebebiyle, FPGA içerisinde işlem yaparken titreşim ve akım verilerinin tam sayıya dönüştürülerek kullanılması bir tasarım kısıtı olarak kabul edilmiştir.

Frekans alanı öznitelikler ve standart sapma, varyans gibi istatistiksel öznitelikler, hesaplamaları sırasında hafıza gerektiren özniteliklerdir. Veri setinin 20 kHz örnekleme sıklığında yaklaşık 1,5 saniye boyunca toplanan verilerden oluştuğu ve her fiziksel sinyalin 32 bit işaretli tam sayı tipinde tutulduğu göz önünde bulundurulduğunda, tek bir fiziksel sinyal için (örneğin X eksenindeki titreşim sinyali) yaklaşık 120 K byte hafıza alanına ihtiyaç duyulmaktadır. Artix-7 FPGA çipinin özellikleri göz önünde bulundurulduğunda hafıza kullanımı ihtiyacı bulunmayan özniteliklerin seçilmesi bir tasarım kısıtı olarak kabul edilmiştir.

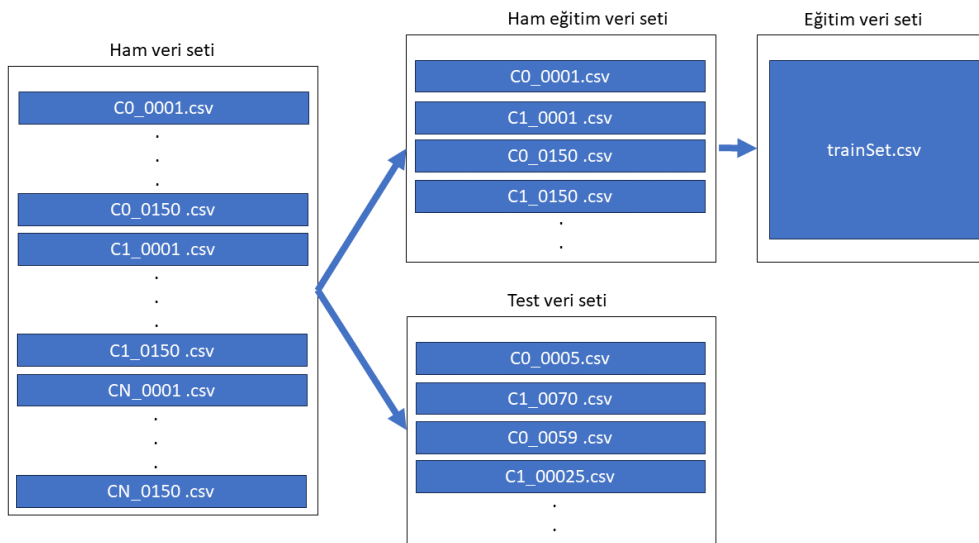
3.2.1.2 Öznitelik Seçimi

“3.2.1.1 Tasarım Kısıtları” başlığı altında belirtilen kısıtlar göz önünde bulundurularak, “3.1.3.1 SVM Sınıflandırıcı için Sonuçlar” başlığı altında belirtilen en etkili 10 öznitelik

arasından 3'ncü ve 4'üncü en etkili öznelik olan Akım verisinin ortalaması ve Z eksenindeki titreşimin RMS değeri seçilmiştir. Görselleştirme yapabilmek adına 2 öznelikte karar kılınmıştır.

3.2.1.3 Rastgele Eğitim ve Test Veri Setlerinin Oluşturulması

Makine öğrenmesi modeli geliştirirken, eğitim ve test veri setlerinin rastgele oluşturulması gerekmektedir “3.1.3 Model ve Öznelik Seçimi Sonuçları” başlığı altında belirtilen çalışma içerisinde ham veri setinden oluşturulan işlenmiş veri setinden rastgele seçilen eğitim veri seti makine öğrenmesi modelini eğitmede kullanılmaktadır. Test seti yine ham veri seti içerisinde elde edilmekte ve doğrudan öznelik çıkarımları yapılmış veriler eğitim ve test aşamalarında kullanılmaktadır. Bu aşamada öznelik çıkarımını FPGA içerisinde gerçekleştirebilmek için test ve eğitim veri setleri doğrudan ham veri setinden seçilmiş ve eğitim veri setinin öznelik çıkarımı gerçekleştirilmiştir. Test veri setiyle başka bir uygulama yapılmadan ham haliyle bırakılmıştır. Eğitim ve test veri setlerinin oluşturulma şekli Şekil 3.79 içerisinde şematize edilmiştir. Şekil 3.79 içerisinde görülebileceği üzere eğitim veri seti tek bir CSV dosyasından oluşmaktadır ve içerisindeki her bir satır, ham eğitim veri setindeki bir CSV dosyasından elde edilen öznelikleri ifade etmektedir. Test seti tasarım tamamlandıktan sonra FPGA tasarımını test ederken ham veri kullanabilmek ve dolayısıyla FPGA tasarımının öznelik çıkarımını da teste dahil edebilmek amacıyla ham veri sisteme girdi olarak verilmiştir.



Şekil 3.79 Model Eğitim ve Test Veri Seti Oluşturma Yöntemi

Öznitelik çıkarımı yaparken tasarım kısıtlarına dikkat edilmiştir. Bu doğrultuda tam sayı veri tipi ile hareket edebilmek ve ölçeklendirme sırasında veri kaybı yaşamamak adına, veri seti ölçeklendirme işlemleri öznitelik oluşturmadan önce gerçekleştirilmiştir. Eğitim veri seti içerisinde:

- Z eksenindeki titreşim verisinin RMS değeri ortalama değeri = 4,4938
- Z eksenindeki titreşim verisinin RMS değeri varyansı = 0,8605
- Akım verisinin ortalama değeri ortalaması = 0,3682
- Akım verisinin ortalama değeri varyansı = 0,011

Herhangi bir sayı dizisinin herhangi bir sabit ile çarpılması durumunda, o sayı dizisinin ortalama ve RMS değerlerinin de aynı sabitle çarpılmış olacağı göz önünde bulundurularak ölçeklendirme işlemi yukarıda belirtilen gözlemlere göre gerçekleştirilmiştir. Dolayısıyla Z eksenindeki titreşim verisi öznitelik çıkarımı öncesinde 10 ile, akım verisi öznitelik çıkarımı öncesinde 100 ile çarpılmış ve öznitelik ortalama değerleri aynı ölçeğe getirilmiştir.

Ham eğitim veri setinden eğitim veri setini oluştururken aşağıdaki adımlar takip edilmiştir:

1. Z eksenindeki titreşim verisi içerisindeki tüm değerler 10 ile çarpılarak tam sayıya çevrim sırasındaki veri kaybı indirgenmiş ve değerler tamsayıya yuvarlanmıştır.
2. Z eksenindeki titreşim verisi RMS değerleri hesaplanmış ve tam sayıya yuvarlanmıştır.
3. Akım verisi içerisindeki tüm değerler 100 ile çarpılarak tam sayıya çevrim sırasındaki veri kaybı indirgenmiş ve değerler tam sayıya yuvarlanmıştır.
4. Akım verisi ortalama değerleri hesaplanmış ve tam sayıya yuvarlanmıştır.

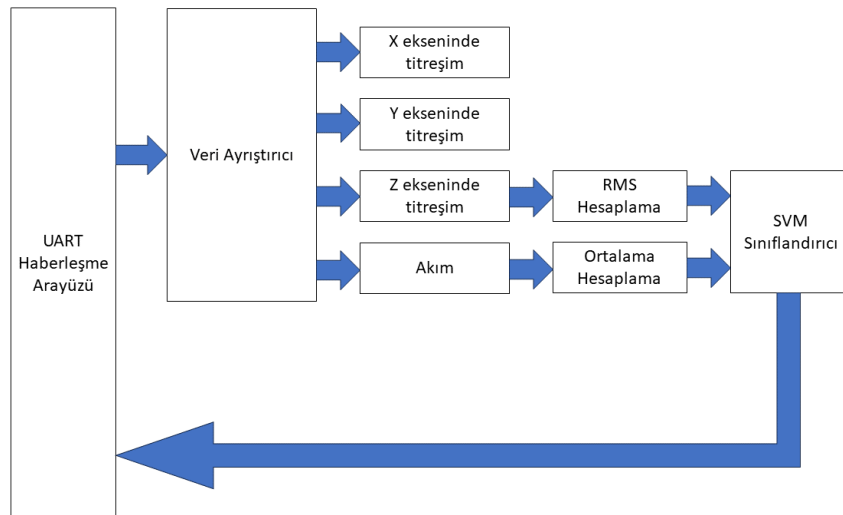
Yukarıdaki adımları geçekleştirdikten sonra eğitim veri seti içerisindeki

- Z eksenindeki titreşim verisinin RMS değeri ortalaması = 44.037
- Z eksenindeki titreşim verisinin RMS değeri varyansı = 86.3319
- Akım ortalama değeri ortalaması = 35.8305
- Akım ortalama değeri varyansı = 11.0907

olarak tespit edilmiştir.

3.2.1.4 FPGA Tasarım Şeması


Tasarım kısıtları göz önünde bulundurularak Şekil 3.80 içerisinde gösterilen tasarım şeması oluşturulmuştur. Test veri seti içerisindeki titreşim ve akım verileri serileştirilerek UART haberleşme arayüzü üzerinden FPGA'ye gönderilmektedir. FPGA içerisindeki UART modülü ile okunan veriler veri ayrıştırıcı modülünde ayrıştırılarak 3 eksendeki titreşim ve akım verileri elde edilmektedir. Elde edilen Z eksenindeki titreşim ve akım verileri öznitelik çıkarımı için RMS hesaplama ve ortalama hesaplama modüllerine iletilmektedir. Öznitelikler elde edildikten sonra, bu öznitelikler SVM sınıflandırıcı modülünde değerlendirilmekte ve değerlendirme sonucu UART haberleşme arayüzü üzerinden dış dünyaya gönderilmektedir.




Şekil 3.80 FPGA Tasarım Şeması

3.2.1.6 Makine Öğrenmesi Modeli Eğitimi

SVM sınıflandırıcı modeli, Python programlama ortamında sklearn kütüphanesi kullanılarak eğitilmiştir. SVM sınıflandırıcı modeli 2 farklı veri seti ile eğitilmiştir. Öncelikle ham veri setindeki verilerden, veri ölçeklendirmesi yapmadan, öznitelik çıkarımı yapıp, ardından öznitelik ölçeklendirmesi yapılarak elde edilen veri seti kullanılmıştır. Bu yöntemle oluşturulan modele ait karar sınırları Şekil 3.81 içerisinde gösterilmiştir. Elde edilen model % 98,71 başarımla 6 sınıflı birbirinden ayırmıştır. Model başarımına ilişkin karışıklık matrisi Şekil 3.82 içerisinde verilmiştir.




Şekil 3.81 SVM Modeli Karar Sınırları




Şekil 3.82 SVM Modeli Karışıklık Matrisi

SVM sınıflandırıcı “3.2.1.3 Rastgele Eğitim ve Test Veri Setlerinin Oluşturulması” başlığı altında tanımlanan veri seti ile eğitilmiştir. Model, Z eksenindeki titreşimin RMS değeri ve akım verisinin ortalama değeri öznitelikleri ile eğitilmiştir. Oluşturulan model test veri seti ile test edilmiş ve Şekil 3.83 içerisinde gösterildiği gibi karar sınırları oluşturulmuştur. Modeli başarımına ilişkin karışıklık matrisi Şekil 3.84 içerisinde verilmiştir. Python programlama ortamında yapılan test sonucunda, SVM sınıflandırıcı modelinin % 98.076 başarı ile 6 sınıfı birbirinden ayırabildiği görülmüştür.



Şekil 3.83 SVM Sınıflandırıcı Karar Sınırları



Şekil 3.84 SVM Modeli Karışıklık Matrisi

Aynı ham veri setinden farklı yöntemlerle elde edilen iki farklı veri seti kullanılarak oluşturulan makine öğrenmesi modelleri karşılaştırıldığında, başarımlarının ve karar sınırlarının benzer olduğu görülmüştür.

Tam sayılardan oluşan veri seti ile eğitilen SVM sınıflandırıcı modelinin öznelik katsayıları ve sapma değerleri elde edilerek FPGA tasarımında kullanmak için kaydedilmiştir. Bu değerlerden öznelik katsayı matrisi:

W =

$$\begin{bmatrix}
 [-0.40917184 & -1.5746762] \\
 [-0.52545451 & -1.20174845] \\
 [7.29297848 & -12.01732003] \\
 [-10.84523818 & -10.35684242] \\
 [-2.31680338 & -0.95366355]
 \end{bmatrix}$$

[-9.19633988 -0.9956913]
[4.40918905 1.44002115]
[9.16915628 4.7989231]
[-4.58037551 2.29843157]
[2.21156376 0.5482508]
[2.84243266 1.48766327]
[-3.89116323 12.70212928]
[-15.76007415 -4.00075824]
[-2.27977792 -0.34067034]
[-6.38028581 -1.82601497]]

Sapma matrisi:

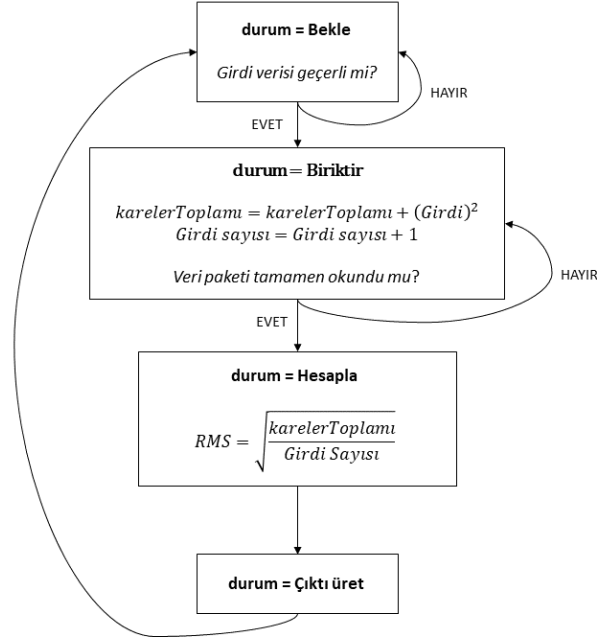
B =
[-0.26722227
-0.03929465
-4.7695594
-10.09570919
-0.3559897
2.18156985
0.88038829
-0.31162282
0.02358978
0.02482352
-0.78649697
-6.58268186
-8.73079804

-0.16215483

1.09343623]

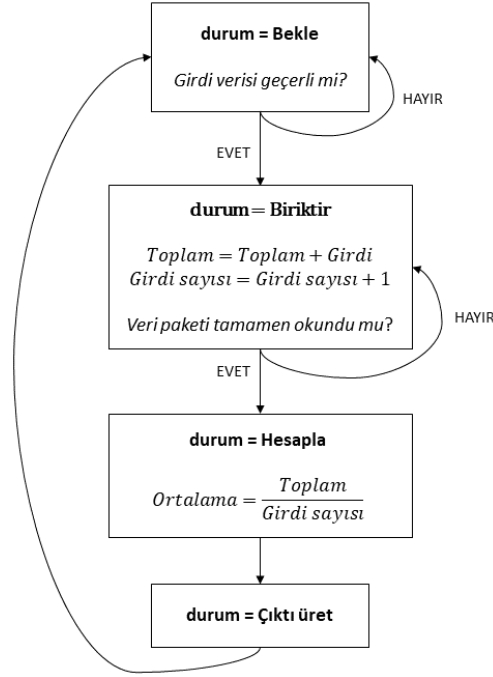
3.2.1.7 FPGA ile Öznitelik Çıkarımı

“3.2.1.2 Öznitelik Seçimi” başlığı altında belirtilen “Z eksenindeki titreşim verisinin RMS değeri” ve “akım verisinin ortalaması” öznitelikleri FPGA içerisinde hesaplanmakta ve SVM modülüne girdi olarak sağlanmaktadır. 32 bit işaretli tam sayı olarak UART kanalından okunan Z eksenindeki titreşim verileri Şekil 3.85 içerisinde durum şeması verilen RMS hesaplama modülüne girdi olarak sağlanır.



Şekil 3.85 FPGA RMS hesaplama Modülü Durum Şeması

Benzer şekilde 32 bit işaretli tam sayı olarak UART kanalından okunan akım verileri Şekil 3.86 içerisinde durum şeması verilen ortalama hesaplama modülüne girdi olarak sağlanır.



Şekil 3.86 FPGA Ortalama hesaplama Modülü Durum Şeması

Şekil 3.85 ve Şekil 3.86 görülebileceği üzere RMS ve ortalama değerler hafıza birimi kullanmadan veri akışı esnasında hesaplanmaktadır.

3.2.1.8 SVM Modelinin FPGA’de Gerçekleştirilmesi

“3.2.1.6 Makine Öğrenmesi Modeli Eğitimi” başlığı altında eğitilen model öznitelik katsayılarından ($W_{15 \times 2}$) ve bias ($b_{15 \times 1}$) değerlerinden oluşmaktadır. 6 sınıflı, OvO stratejisi kullanan SVM sınıflandırıcı tüm sınıfların birbiri arasında karşılaştırıldığı 15 karar fonksiyonu içermektedir. Dolayısıyla $W_{15 \times 2}$ matrisi her bir ikili sınıflandırıcı için öznitelik katsayılarını içeren 15 satır, 2 sütundan ve $b_{15 \times 1}$ matrisi her bir ikili sınıflandırıcı için sapma değerlerini içeren 15 satırdan oluşmaktadır.

$x_{2 \times 1}$ vektörünü yeni bir test verisinin öznitelikleri olan sırasıyla “Z eksenindeki titreşimin RMS değeri” ve “akım verisinin ortalama değeri” olarak ele alalım. Bu durumda çoklu sınıflandırıcı karar mekanizmasını oluşturmak için $d_{15 \times 1}$ karar fonksiyonu matrisi aşağıdaki gibi tanımlanmalıdır:

$$d_{15 \times 1} = W_{15 \times 2} * x_{2 \times 1} + b_{15 \times 1} \dots (2.1)$$

$d_{15 \times 1}$ matrisinin her bir satırı Tablo 3-10 içerisinde belirtildiği şekilde 15 farklı ikili SVM sınıflandırıcının karar fonksiyonu çıktılarını içerir.

Tablo 3-10 Karar fonksiyonu matrisi içeriği

Satır	Karşılaştırılan sınıflar	$d_i > 0$ durumunda seçilen sınıf	$d_i < 0$ durumunda seçilen sınıf
d_1	1, 2	1	2
d_2	1, 3	1	3
d_3	1, 4	1	4
d_4	1, 5	1	5
d_5	1, 6	1	6
d_6	2, 3	2	3
d_7	2, 4	2	4
d_8	2, 5	2	5
d_9	2, 6	2	6
d_{10}	3, 4	3	4
d_{11}	3, 5	3	5
d_{12}	3, 6	3	6
d_{13}	4, 5	4	5
d_{14}	4, 6	4	6
d_{15}	5, 6	5	6

Tablo 3-10 içerisinde $\{1, 2, 3, 4, 5, 6\}$ olarak nitelendirilen sınıflar Tablo 3-2 içerisinde tanımlanmıştır.

2.1 eşitliğinde kullanılan $W_{15 \times 2}$ ve $b_{15 \times 1}$ matrisleri ondalık sayılardan oluşmaktadır. Bu matrisler, “3.2.1.1 Tasarım Kısıtları” başlığı altında belirtildiği şekilde tam sayı olarak kullanırken oluşacak veri kaybını azaltmak amacıyla ölçeklendirilerek kullanılmıştır. $\bar{d}_{15 \times 1}$, $\bar{W}_{15 \times 2}$ ve $\bar{b}_{15 \times 1}$ matrislerini ölçeklendirilmiş $d_{15 \times 1}$, $W_{15 \times 2}$ ve $b_{15 \times 1}$ matrisleri ve c sayısını bir sabit sayı olarak ele alalım. Bu durumda:

$$\bar{d}_{15 \times 1} = c * d_{15 \times 1} \dots (2.2)$$

$$\bar{W}_{15 \times 2} = c * W_{15 \times 2} \dots (2.3)$$

$$\bar{b}_{15 \times 1} = c * b_{15 \times 1} \dots (2.4)$$

$$\bar{d}_{15x1} = \bar{W}_{15x2} * x_{2x1} + \bar{b}_{15x1} \dots (2.5)$$

$$c * d_{15x1} = c * W_{15x2} * x_{2x1} + c * b_{15x1} \dots (2.6)$$

(2.1) - (2.6) eşitliklerinden görüleceği üzere W_{15x2} ve b_{15x1} matrislerindeki ölçeklendirme karar fonksiyonunu aynı ölçekte etkilemektedir. İkili SVM karar fonksiyonu değerleri 0 ile karşılaştırıldığı için sonuç ölçeklendirmeden bağımsızdır. Başka bir deyişle (2.7) eşitsizliğinin sağlandığı her durumda (2.8) eşitsizliği sağlanmakta, aynı şekilde (2.9) eşitsizliğinin sağlandığı her durumda (2.10) eşitsizliği sağlanmaktadır. Bu durumda W_{15x2} ve b_{15x1} matrislerinin ondalık sayı – tam sayı çevriminde isteğe bağlı olarak deneme yanılma yöntemiyle belirlenen bir sayıyla ölçeklendirilebileceği sonucuna varılmıştır. Deneme yanılma yöntemiyle bu ölçek $c = 1000$ olarak seçilmiştir.

$$d_{15x1} > 0 \dots (2.7)$$

$$\bar{d}_{15x1} > 0 \dots (2.8)$$

$$d_{15x1} < 0 \dots (2.9)$$

$$\bar{d}_{15x1} < 0 \dots (2.10)$$

Ölçeklendirmeye elde edilen \bar{W}_{15x2} ve \bar{b}_{15x1} matrisleri FPGA donanımında SVM modülü içerisine gömülmüş ve bu matrisleri kullanan 15 karar fonksiyonu tanımlanmıştır. FPGA içerisinde hesaplanan özniteliklerin SVM modülüne iletilmesiyle 15 karar fonksiyonu hesaplanır ve her birinin sonucuna göre 6 sınıf puanlanır. Puanlama sonucunda en yüksek puana sahip sınıf seçilir ve sınıflandırma tamamlanmış olur.

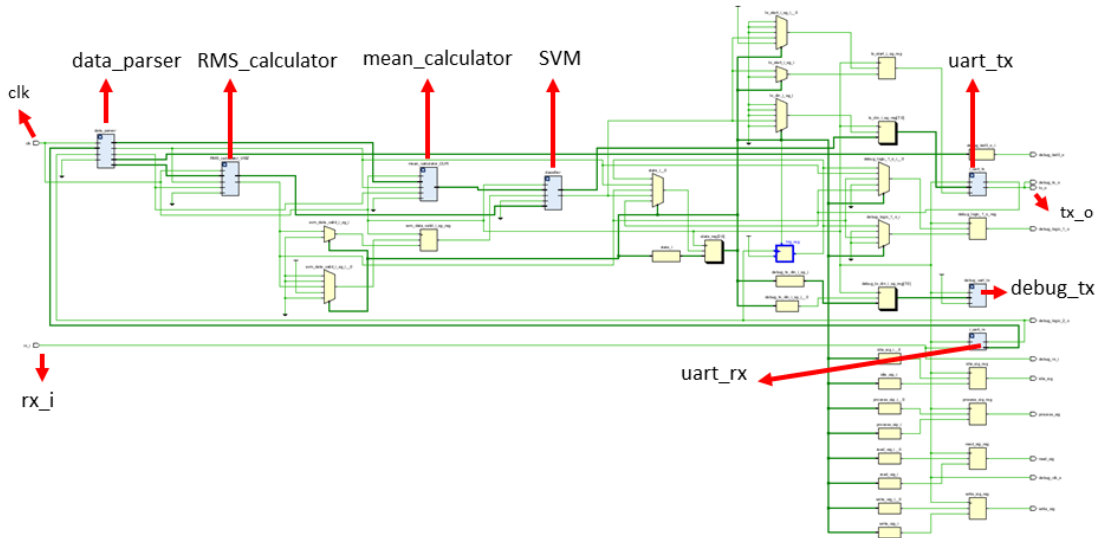
FPGA üzerinde gerçekleştirilen hata sınıflandırma tasarımı, rastgele seçilen test grubuyla yapılan test sonucunda % 98,076'lık bir başarımla göstermiştir. Bu başarımla Python ortamında, aynı test grubu ile gerçekleştirilen testlerle aynı sonuçtur. Model başarımla ilişkin karışıklık matrisi Şekil 3.87 içerisinde verilmiştir.

	SAĞLIKLI DURUM	KAPAK AĞIRLIK ALTINDA	MANUEL TAHRİK DİŞLİSİ YANLIŞ HİZALİ	ANA TAHRİK DİŞLİSİ HASARLI	VİDALI MİL HASARLI	TORK SİYİRİCİ GEVŞEK
SAĞLIKLI DURUM	29	0	0	0	1	0
KAPAK AĞIRLIK ALTINDA	0	23	0	0	0	0
MANUEL TAHRİK DİŞLİSİ YANLIŞ HİZALİ	0	0	11	0	0	0
ANA TAHRİK DİŞLİSİ HASARLI	0	0	0	32	1	0
VİDALI MİL HASARLI	0	0	0	1	35	0
TORK SİYİRİCİ GEVŞEK	0	0	0	0	0	23

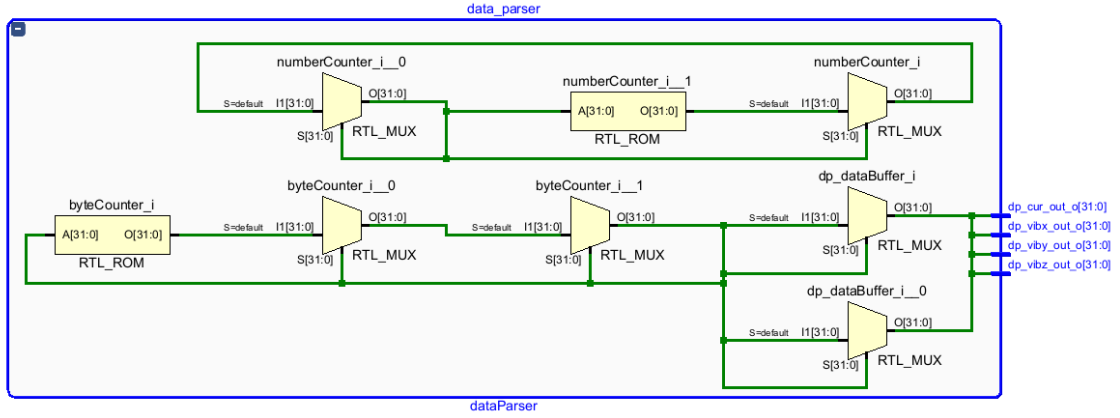
Şekil 3.87 FPGA SVM Modeli Karışıklık Matrisi

3.2.2 FPGA Sentez Sonuçları

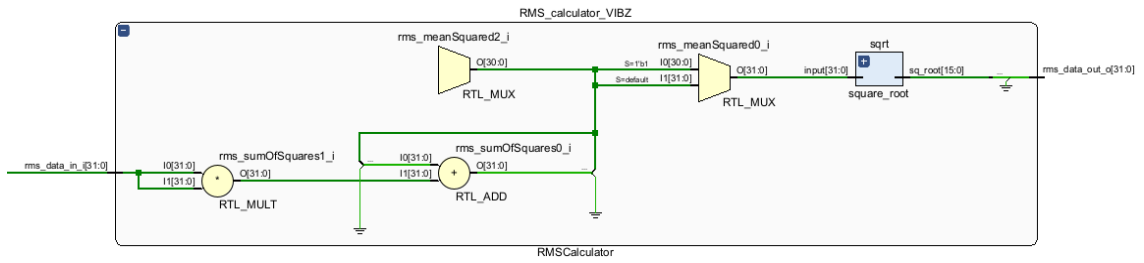
VHDL ile gerçekleştirilen hata tespit sınıflandırma uygulamasının RTL şeması Şekil 3.88 içerisinde verilmiştir. Şekil 3.88 içerisinde görülebileceği üzere, “rx_i” pini ile sisteme giren ve “uart_rx” modülü ile anlamlandırılan veriler, Şekil 3.89 içerisinde RTL şeması verilen “dataParser” modülü ile X, Y, Z yönlerindeki titreşim ve akım verileri olmak üzere 4 adet 32 bit tam sayı olarak ayrıştırılır. Z eksenindeki titreşim verisi Şekil 3.90 içerisinde RTL şeması verilen “RMSCalculator” modülüne iletilir. Akım verisi Şekil 3.91 içerisinde RTL şeması verilen “MeanClaculator” modülüne iletilir. “RMSCalculator” ve “MeanCalculator” modüllerinin çıktıları 32 bit tam sayı olarak Şekil 3.92 içerisinde RTL şeması verilen “SVM” modülüne iletilir. “SVM” modülü içerisinde karar fonksiyonları hesaplanır ve sınıf seçimi “MUX” kullanılarak belirlenir. Seçilen sınıf bilgisi 8 bit tam sayı olarak “uart_tx” modülü aracılığıyla “tx_o” pini üzerinden dış dünya ile paylaşılır. Tasarım sonucunda tasarım kısıtlarında belirtildiği şekilde Tablo 3-11 içerisinde görülebileceği üzere tasarım için ayrılmış hafıza yoktur.



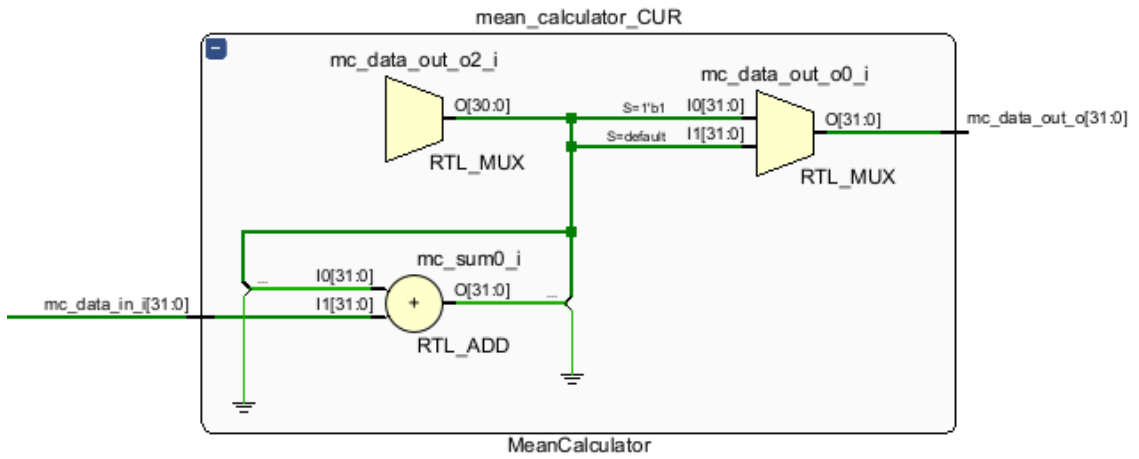
Şekil 3.88 Hata Tespit ve Sınıflandırma Sistemi RTL Şeması



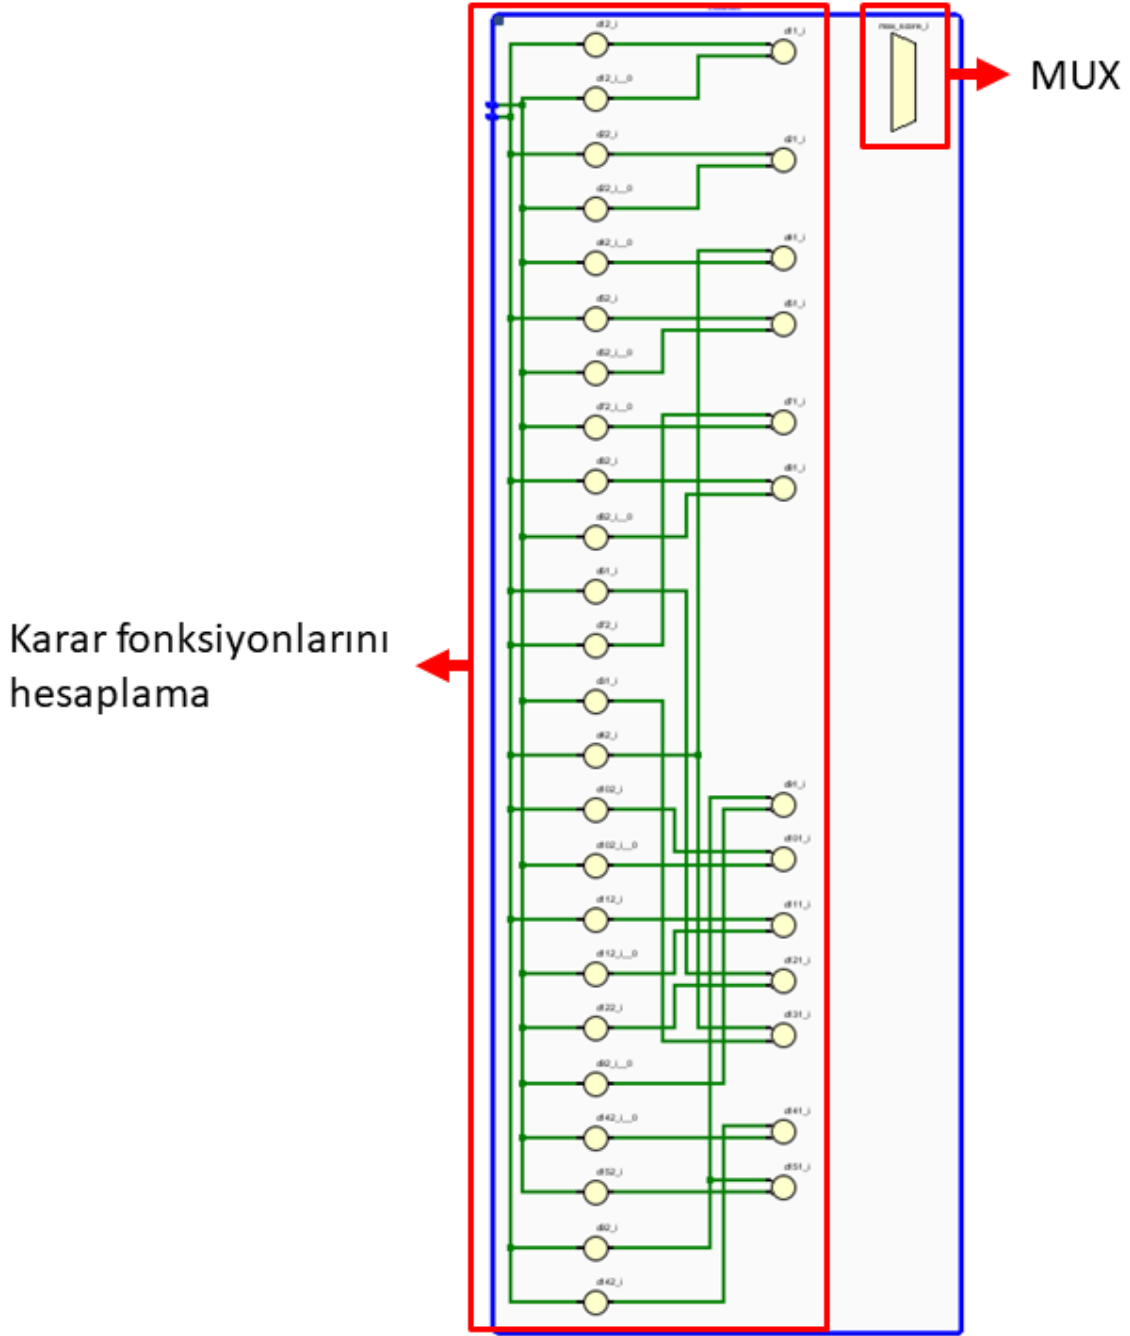
Şekil 3.89 Veri Ayrıştırıcı Modülü RTL Şeması



Şekil 3.90 RMS Hesaplama Modülü RTL Şeması



Şekil 3.91 Ortalama Hesaplama Modülü RTL Şeması



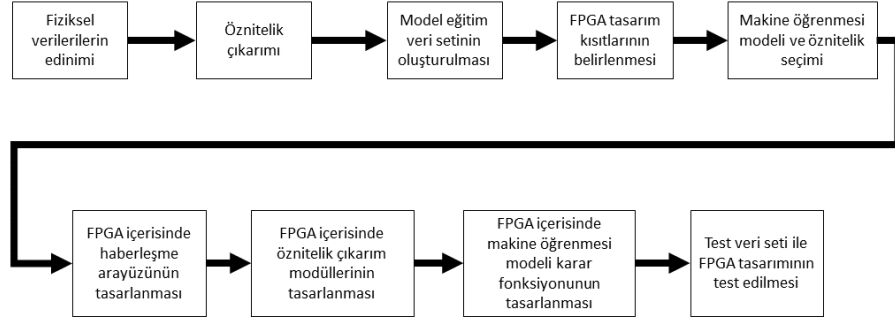
Şekil 3.92 SVM Sınıflandırıcı Modülü RTL Şeması

Tablo 3-11 FPGA Tasarımı Hafıza Kullanım Raporu

Site Type	Used	Fixed	Prohibited	Available	Util%
Block RAM Tile	0	0	0	50	0.00
RAMB36/FIFO*	0	0	0	50	0.00
RAMB18	0	0	0	100	0.00

3.3 FPGA Üzerinde Hata Tespit ve Sınıflandırma Uygulaması Geliştirme Akışı

Tez çalışması kapsamında FPGA tasarlanması sonucunda, saf FPGA çipi üzerinde hata sınıflandırma uygulaması geliştirmek için gerekli adımlar Şekil 3.93 içerisinde görülen akış şeması içerisinde derlenmiştir.



Şekil 3.93 FPGA Üzerinde Hata Tespit ve Sınıflandırma Uygulaması Geliştirme Akış Şeması

Akış şeması(Bkz. Şekil 3.93) aşağıdaki şekilde açıklanabilir:

1. FPGA üzerinde hata tespit ve sınıflandırma uygulaması geliştirebilmek için, uygulama kapsamında kullanılacak olan makine öğrenmesini eğitmek ve test etmek amacıyla veri seti oluşturmak gerekmektedir. Veri seti oluştururken üzerinde hata tespiti yapılacak olan sistemin farklı sağlık durumlarında fiziksel verileri toplanmalıdır. Her sağlık durumu için mümkün olduğunca fazla kez sistem belirli bir şekilde çalıştırılıp fiziksel veriler elde edilmelidir. Bu veriler:

- ivmeölçerler
- akustik sensörler
- kızılötesi ısıölçerler
- akım sensörü
- nem sensörü
- akış sensörü
- basınç sensörü

gibi sensörler [7] [3] kullanılarak edilebilir.

2. Fiziksel veriler kullanılarak zaman ve frekans alanı öznitelikler çıkartılmalıdır.

Sıklıkla kullanılan istatistiksel öznitelikler [2] [10] [11] [12] [13]:

- ortalama
- azami değer

- asgari deęer
 - alan
 - toplam
 - kök kare ortalama
 - standart sapma
 - varyans
 - basıklık
 - çarpıklık
 - tepe faktörü
 - form faktörü
 - frekans merkezi
 - kök kare ortalama frekansı
 - kök varyans frekansı
3. Elde edilen öznitelikler ve sınıf etiketleri ile veri seti oluşturulmalıdır [49]. Oluşturulan veri setindeki her bir öznitelik vektörü, bir sağlık durumundaki sistemi bir kez çalıştırmada elde edilen fiziksel verilerden oluşturulan öznitelikleri içerir.
 4. Makine öğrenmesi modelini bir FPGA çipine taşımak için öncelikle hafıza kapasitesi, hız ve benzeri tasarım kısıtları belirlenmelidir.
 5. Veri seti rastgele test ve eğitim veri setlerine ayrılmalı ve eğitim veri seti ile muhtemel makine öğrenmesi modelleri eğitilmelidir. Bu modeller test veri seti ile test edilmeli ve performans, hız, kolaylık gibi faktörler göz önünde bulundurularak bir makine öğrenmesi modeli seçilmelidir. Tasarım kısıtlarına uyan ve performans kriterlerini karşılayan bir makine öğrenmesi modeli oluşturulana kadar bu adım tekrarlanmalı ve tüm kriterleri karşılayan bir model seçilmelidir.
 6. Fiziksel veriyi FPGA'e aktarmak ve tahmin edilen sınıf bilgisini almak için bir haberleşme arayüzü belirlenmeli ve FPGA içerisinde tasarlanmalıdır.
 7. FPGA içerisinde seçilen makine öğrenmesi modeli içerisinde kullanılan özniteliklerin çıkarımı için öznitelik çıkarım modülleri tasarlanmalıdır.
 8. Eğitilen makine öğrenmesi modelinin karar fonksiyonu içerisinde kullandığı katsayı ve sapma sayıları modelden elde edilmeli ve FPGA içerisinde karar fonksiyonu oluşturmada kullanılmalıdır.

4. SONUÇLAR VE TARTIŞMA

Sunulan tez çalışması kapsamında üretim, otomotiv, demiryolu taşımacılığı, büyük iş makineleri, inşaat gibi birçok endüstride kritik makinelerin bakım yöntemi olarak kullanılan veriye dayalı bakım uygulamaları, hata tespit ve sınıflandırma konuları incelenmiştir. Gerçek bir savunma sanayii ürünü olan füze koruma kapağı üzerinden çeşitli sağlık durumlarında titreşim ve akım verisi toplanmıştır. Toplanan bu verilerden çıkarılabilecek zaman ve frekans alanı istatistiksel öznitelikler incelenmiş ve bu öznitelikler çıkarılarak işlenmiş veri seti elde edilmiştir. Daha sonra Python programlama ortamında farklı klasik makine öğrenmesi modelleri, farklı öznitelik seçimi ve boyut küçültme metotları kullanarak test edilmiş ve test sonuçları raporlanmıştır. Bu çalışmanın ardından seçilen makine öğrenmesi modeli ve özniteliklerle FPGA donanımı üzerinde VHDL donanım tanımlama dili ile sınıflandırıcı tasarımı gerçekleştirilmiş, gerçek donanım üzerinde bu model test edilmiştir. Bu bölümde deney çalışması sonucunda hata tespit ve sınıflandırma uygulaması kullanım önerisi sunulmuştur. Son olarak tez çalışmasının literatüre katkısı ve gelecek çalışmalar ele alınmıştır.

4.1 Hata Tespit ve Sınıflandırma Sistemi Önerisi

Tez çalışması kapsamında gelişen sensör ve makine öğrenmesi teknolojilerinin mümkün kıldığı durum izleme ve veriye dayalı bakım yöntemleri ile ilgili literatür taraması gerçekleştirilmiş, deney çalışmaları yapılmıştır. Bu çalışmaların sonucu olarak, veriye dayalı hata tespit ve sınıflandırma uygulamalarının mekanik askeri sistemlerin sağlık durumlarını daha kapsamlı tayin etmede faydalı olabileceği çıkarımına varılmıştır. Bu doğrultuda, tez kapsamında yapılan çalışmalar Python programlama ortamında geliştirilmiş, sonrasında VHDL donanım tanımlama dili ile FPGA üzerinde gerçekleştirilen hata sınıflandırma modeli, mekanik sistemler için hata tespit ve sınıflandırma uygulaması örneği olarak sunulmuştur.

Tez kapsamında gerçekleştirilen deneyler sonucunda FPGA teknolojisinin askeri sistemlerde hata tespit ve sınıflandırma uygulamalarında kullanımına ilişkin tasarım akışı tanımlanmıştır.

Bu tez çalışması sonucunda:

- Farklı sađlık durumlarında toplanan verilerle eđitilen hata sınıflandırma modelleriyle mekanik sistemlerin hata tespit ve sınıflandırma uygulamalarının tasarlanması,
- Genel olarak sistemlerin hata tespit ve sınıflandırma işlemlerinin gerçekleştirilmesi ve işleme hazırlık durumunun belirlenmesi,
- Sistemin tipine göre depo ya da hangarlarda periyodik olarak mekanik sistemlerin hata tespit ve sınıflandırma işlemini gerçekleştirmesi ve bakım kararlarının alınması

önerilmektedir.

4.2 Tez Çalışmasının Literatüre Katkısı

Sunulan tez çalışması kapsamında:

- Yaygın kullanım alanı olan veriye dayalı bakım konseptinin savunma sanayii ürünleri için muhtemel kullanım konsepti önerilmiştir.
- Deney çalışması için gerçek bir savunma sanayii ürününden titreşim ve akım verileri toplanmış ve bu veriler farklı makine öğrenmesi modellerinin performanslarını incelemek için kullanılmıştır.
- Durum izleme için titreşim ve akım verileri bir arada kullanılmıştır.
- Titreşim ve akım verilerinden elde edilebilecek istatistiksel öznitelikler derlenmiş, bu özniteliklerin makine öğrenmesi modellerine göre etkinlikleri incelenmiştir.
- FGPA donanımı üzerinde hata sınıflandırma modeli oluşturma akışı tanımlanmıştır.
- FPGA donanımı üzerinde çok sınıflı SVM sınıflandırıcı modeli tasarımı tanımlanmıştır.
- FPGA donanımı üzerinde titreşim ve akım verilerini kullanarak hata sınıflandırma modeli tasarlanmış ve test edilmiştir.

4.3 Gelecek Çalışmalar

Tez çalışması sonucunda, durum izleme teknolojisinin hata sınıflandırma yeteneđi kullanılarak hata tespit ve sınıflandırma uygulaması kullanım konsepti önerisi sunulmuş ve bu çalışma bir Savunma Sanayii ürününe yönelik uygulanarak etkinliđi araştırılmıştır.

Bu çalışmanın devamında:

- Durum izleme teknolojisinin regresyon ile hata tespiti yeteneđi farklı Savunma Sanayii ürünleri özelinde çalışılabilir, kullanım konseptleri üretilebilir.
- Durum izleme teknolojisinin kalan faydalı ömür kestirimi yeteneđi Savunma Sanayii ürünleri özelinde çalışılabilir, kullanım konseptleri önerilebilir.
- Farklı platformlarda (hava, kara, deniz araçları vb.) görev yapan farklı Savunma Sanayii ürünleri için veriye dayalı bakım uygulamaları incelenebilir.
- Titreşim ve akım sensörünün yanı sıra, akustik sensörler, basınç sensörleri ve benzeri sensörlerin etkinlikleri, Savunma Sanayii ürünleri özelinde, veriye dayalı bakım konsepti kapsamında incelenebilir.
- Yapay Sinir Ağları tabanlı modelleri kullanan veriye dayalı bakım uygulamaları Savunma Sanayii ürünleri özelinde incelenebilir.
- Sistem ve altsistem seviyelerinde, veriye dayalı karar mekanizmalarının operasyonel kullanım konsepti geliştirilebilir.
- Veriye dayalı karar mekanizmalarının savaş alanındaki etkinliđi simülasyonlarla ortaya koyulabilir.

5. KAYNAKLAR

- [1] M. J. Scott, W. J. C. Verhagen, M. T. Bieber ve P. Marzocca, "A Systematic Literature Review of Predictive Maintenance for Defence Fixed-Wing Aircraft Sustainment and Operations", *Sensors*, cilt 22, no. 18, 2022.
- [2] A. Stetco, F. Dinmohammadi, X. Zhao, V. Robu, D. Flynn, M. Barnes, J. Keane ve G. Nenadic, "Machine learning methods for wind turbine condition monitoring: A review", *Renewable Energy*, no. 133, pp. 620-635, 2019.
- [3] Y. Lei, N. Li, L. Guo, N. Li, T. Yan ve J. Lin, "Machinery health prognostics: A systematic review from data acquisition to RUL prediction", *Mechanical Systems and Signal Processing*, cilt 104, pp. 799-824, 2018.
- [4] S. Selcuk, "Predictive maintenance, its implementation and latest trends", *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, cilt 231, no. 9, pp. 1670-1679, 2017.
- [5] R. Isermann, "Model-based fault-detection and diagnosis – status and applications", *Annual Reviews in Control*, cilt 29, no. 1, pp. 71-85, 2005.
- [6] D. Divya, B. Marath ve M. S. Kumar, "Review of fault detection techniques for predictive maintenance", *Journal of Quality in Maintenance Engineering*, 2022.
- [7] H. M. Hashemian, "State-of-the-Art Predictive Maintenance Techniques", *IEEE Transactions on Instrumentation and measurement*, cilt 60, no. 1, pp. 226-236, 2011.
- [8] D. Haddad, A. Y. Kallel, N. E. B. Amara and O. Kanoun, "Soft Fault Characterization for Predictive Maintenance in Complex Cable Structures", in *2022 International Workshop on Impedance Spectroscopy (IWIS)*, 2022.
- [9] Y. E. Karabacak ve N. Gürsel Özmen, "Common spatial pattern-based feature extraction and worm gear fault detection through vibration and acoustic measurements", *Measurement*, no. 187, 2022.
- [10] D. K. Saha, S. Ahmed and M. S. Shaurov, "Different Machine Maintenance Techniques of Rotary Machine and Their Future Scopes: A Review", in *4th International Conference on Electrical Information and Communication Technology (EICT)*, IEEE, Khulna, 2019.

- [11] W. Caesarendra ve T. Tjahjowidodo, "A Review of Feature Extraction Methods in Vibration-Based Condition Monitoring and Its Application for Degradation Trend Estimation of Low-Speed Slew Bearing", *Machines*, 2017.
- [12] J. Pacheco-Cherrez, J. A. Fortoul-Díaz, F. Cortes-Santacruz, L. . M. Alosó-Valerdi ve D. I. Ibarra-Zarate, "Bearing fault detection with vibration and acoustic signals: Comparison among different machine learning classification methods", *Engineering Failure Analysis*, cilt 139, no. 106515, 2022.
- [13] D. Dou ve S. Zhou, "Comparison of four direct classification methods for intelligent fault diagnosis of rotating machinery", *Applied Soft Computing*, cilt 46, pp. 459-468, 2016.
- [14] Y. Li, A. Wang, Z. He and X. Yi, "Research on Maintenance Strategy Based on Health Status of Fire Control System", in *2020 Prognostics and Health Management Conference*, Besançon, 2020.
- [15] A. Sharma, G. Yadava ve S. Deshmukh, "A literature review and future perspectives on maintenance optimization", *Journal of Quality in Maintenance Engineering*, cilt 17, no. 1, pp. 5-25, 2011.
- [16] D. Özgür-Ünlüakın, B. Türkali, S. Ç. Aksezer ve A. Karacaörenli, "A DBN based reactive maintenance model for a complex system in thermal power plants", *Reliability Engineering & System Safety*, cilt 190, no. 106505, 2019.
- [17] E. I. Basri, I. H. A. Razak, H. Ab-Samat ve S. Kamaruddin, "Preventive maintenance (PM) planning: a review", *Journal of Quality in Maintenance Engineering*, cilt 23, no. 2, pp. 114-143, 2017.
- [18] D. Thomas ve B. Weiss, "Maintenance Cost and Advanced Maintenance Techniques in Manufacturing Machinery: Survey and Analysis", *International Journal of Prognostics and Health Management*, cilt 12, no. 1, 2021.
- [19] A. Garg ve S. Deshmukh, "Maintenance management: literature review and directions", *Journal of quality in maintenance engineering*, cilt 12.3, pp. 205-238, 2006.
- [20] K. Kudelina, T. Vaimann, B. Asad, A. Rasskolkin, A. Kallaste ve G. Demidova, "Trends and Challenges in Intelligent Condition Monitoring of Electrical Machines Using Machine Learning", *Applied Sciences*, cilt 11, no. 6, 2021.
- [21] A. R. Mohanty, "Machinery Condition Monitoring Principles and Practices", Broken Sound Parkway NW, Suite 300: CRC Press Taylor and Francis Group, 2015.

- [22] S. Kumar, M. Lokesha, K. Kumar ve S. K. R, "Vibration based Fault Diagnosis Techniques for Rotating Mechanical Components: Review Paper", *IOP Conf. Series: Materials Science and Engineering*, no. 376, 2018.
- [23] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang ve R. X. Gao, "Deep learning and its applications to machine health monitoring", *Mechanical systems and signal processing*, cilt 115, pp. 213-237, 2019.
- [24] Y. Ohki ve N. Hirai, "Effects of the structure and insulation material of a cable on the ability of a location method by FDR", *IEEE Transactions on Dielectrics and Electrical Insulation*, cilt 23, no. 1, pp. 77-84, February 2016.
- [25] Y. Wei, D. Wu ve J. Terpenney, "Robust Incipient Fault Detection of Complex Systems Using Data Fusion", *IEEE Transactions on Instrumentation and Measurement*, cilt 69, no. 12, pp. 9526-9534, December 2020.
- [26] Y. N. Aldeoes, P. Ghockle and S. Y. Sondkar, "Comparison of Machine Learning Algorithms for Bearing Failures Classification and Prediction", in *International Conference on Advances in Electrical and Computer Technologies*, Coimbatore, India, 2021.
- [27] D. K. Saha, H. Badihi and E. Hoque, "Development of Intelligent Fault Diagnosis Technique of Rotary Machine Element Bearing: A Machine Learning Approach", *Sensors*, vol. 22, no. 3, 2022.
- [28] A. A. Soofi ve A. Awan, "Classification Techniques in Machine Learning: Applications and Issues", *Journal of Basic & Applied Sciences*, cilt 13, pp. 459-465, 2017.
- [29] T. P. Banerjee ve S. Das, "Multi-sensor data fusion using support vector machine for motor fault detect", *Information Sciences*, cilt 217, pp. 96-107, 2012.
- [30] M. Kuncan, "An Intelligent Approach for Bearing Fault Diagnosis: Combination of 1D-LBP and GRA", *IEEE Access*, cilt 8, pp. 137517 - 137529, 2020.
- [31] M. Altaf, M. Uzair, M. Naeem, A. Ahmad, S. Badshah, J. A. Shah ve A. Anjum, "Automatic and Efficient Fault Detection in Rotating Machinery using Sound Signals", *Acoustic Australia*, cilt 47, pp. 125-139, 2019.
- [32] S. B. Kotsiantis, I. D. Zaharakis ve P. E. Pintelas, «Machine learning: a review of classification and combining techniques,» *Artificial Intelligence Review*, cilt 26, pp. 159-190, 2006.

- [33] B. Chakraborty, "Feature Selection and Classification Techniques for Multivariate Time Series," in *Second International Conference on Innovative Computing, Information and Control (ICICIC 2007)*, 2007.
- [34] V. N. Vapnik, "The Nature of Statistical Learning Theory", Springer science & business media, 1999.
- [35] D. J. Bordoloi ve R. Tiwari, "Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time–frequency vibration data", *MEasurement*, cilt 55, pp. 1-14, 2014.
- [36] C.-J. Lin ve C.-W. Hsu, "A comparison of methods for multiclass support vector machines", *IEEE Transactions on Neural Networks*, cilt 13, no. 2, pp. 415-425, 2002.
- [37] K.-B. Duan ve S. S. Keerthi, "Which Is the Best Multiclass SVM Method? An Empirical Study", *International Workshop on Multiple Classifier Systems*, pp. 278-285, 2005.
- [38] Q. Hang, J. Ynag ve L. Xing, "Diagnosis of Rolling Bearing Based on Classification for High Dimensional Unbalanced Data", *IEEE Access*, cilt 7, pp. 79159-79172, 2019.
- [39] I. Guyon ve A. Elisseeff, "An Introduction to Variable and Feature Selection", *Journal of Machine Learning Research* 3, cilt 1157, no. 1182, March 2003.
- [40] R. Kohavi ve G. H. John, "Wrappers for feature subset selection", *Artificial Intelligence* 97, 1997.
- [41] T. Wieger, P. Bart, C. Dennis, T. Maaïke, S. S. Shadia and Z. Jan, "Smart Maintenance for Modern Naval Ships", in *INEC 2022*, 2022.
- [42] X. Zhang, A. Ramachandran, Z. Chuanhao, D. He, W. Zuo, Z. Cheng, K. Rupnow ve D. Chen, "Machine Learning on FPGAs to Face the IoT Revolution", *IEEE/ACM International Conference on Computer-Aided Design (ICCAD)*, 2017.
- [43] M. Papadonikolakis ve C.-S. Bouganis, "A Novel FPGA-based SVM Classifier", *International Conference on Field-Programmable Technology*, 2010.
- [44] S. Afifi, H. GholamHosseini ve R. Sinha, "FPGA Implementations of SVM Classifiers: A Review", *SN Computer Science*, cilt 1, pp. 1-17, 28 Nisan 2020.
- [45] S. M. Afifi, H. GholamHosseini ve R. Sinha, "Hardware Implementations of SVM on FPGA: A State-of-the-Art Review of Current Practice", *International Journal of*

Innovative Science Engineering and Technology (IJSET), cilt 2, no. 11, Kasım 2015.

- [46] "Roketsan A.Ş.", [Çevrimiçi]. Mevcut:
<https://www.roketsan.com.tr/tr/urunler/umtas-uzun-menzilli-tanksavar-fuze-sistemi>. [Erişildi: Ocak 2024].
- [47] "MSI Dergi", Savunma Haber, Mayıs 2022. [Çevrimiçi]. Mevcut:
<https://www.savunmahaber.com/dearsan-salvo-sida-fuze-makinali-tufek-atis-testi/>. [Erişildi: Ocak 2024].
- [48] "digilent.com", digilent, [Çevrimiçi]. Mevcut:
<https://eu.mouser.com/new/digilent/digilent-basys-3-trainer-board/>. [Erişildi: 3 12 2024].
- [49] J. Tan, J. Yang, S. Wu, G. Chen ve J. Zhao, "A critical look at the current train/test split in machine learning", *arXiv preprint*, 2021.

EKLER

EK 1 – Veri Seti Bilgileri

. #	Column	Non-Null Count	Dtype
0	vibrationX_kurtosis	1585 non-null	float64
1	vibrationY_kurtosis	1585 non-null	float64
2	vibrationZ_kurtosis	1585 non-null	float64
3	vibrationX_min_value	1585 non-null	float64
4	vibrationY_min_value	1585 non-null	float64
5	vibrationZ_min_value	1585 non-null	float64
6	vibrationX_mean_value	1585 non-null	float64
7	vibrationY_mean_value	1585 non-null	float64
8	vibrationZ_mean_value	1585 non-null	float64
9	vibrationX_skewness_value	1585 non-null	float64
10	vibrationY_skewness_value	1585 non-null	float64
11	vibrationZ_skewness_value	1585 non-null	float64
12	vibrationX_variance	1585 non-null	float64
13	vibrationY_variance	1585 non-null	float64
14	vibrationZ_variance	1585 non-null	float64
15	vibrationX_crest_factor	1585 non-null	float64
16	vibrationY_crest_factor	1585 non-null	float64
17	vibrationZ_crest_factor	1585 non-null	float64
18	vibrationX_standard_deviation	1585 non-null	float64
19	vibrationY_standard_deviation	1585 non-null	float64
20	vibrationZ_standard_deviation	1585 non-null	float64
21	vibrationX_sum	1585 non-null	float64
22	vibrationY_sum	1585 non-null	float64
23	vibrationZ_sum	1585 non-null	float64
24	vibrationX_margin_factor	1585 non-null	float64
25	vibrationY_margin_factor	1585 non-null	float64
26	vibrationZ_margin_factor	1585 non-null	float64
27	vibrationX_peak	1585 non-null	float64
28	vibrationY_peak	1585 non-null	float64
29	vibrationZ_peak	1585 non-null	float64
30	vibrationX_rms	1585 non-null	float64
31	vibrationY_rms	1585 non-null	float64
32	vibrationZ_rms	1585 non-null	float64
33	vibrationX_frequency_center	1585 non-null	float64
34	vibrationX_rms_frequency	1585 non-null	float64
35	vibrationX_root_variance_frequency	1585 non-null	float64
36	vibrationY_frequency_center	1585 non-null	float64
37	vibrationY_rms_frequency	1585 non-null	float64
38	vibrationY_root_variance_frequency	1585 non-null	float64
39	vibrationZ_frequency_center	1585 non-null	float64
40	vibrationZ_rms_frequency	1585 non-null	float64
41	vibrationZ_root_variance_frequency	1585 non-null	float64
42	current_kurtosis	1585 non-null	float64

43	current_min_value	1585 non-null	float64
44	current_mean_value	1585 non-null	float64
45	current_skewness_value	1585 non-null	float64
46	current_variance	1585 non-null	float64
47	current_crest_factor	1585 non-null	float64
48	current_standard_deviation	1585 non-null	float64
49	current_sum	1585 non-null	float64
50	current_margin_factor	1585 non-null	float64
51	current_peak	1585 non-null	float64
52	current_rms	1585 non-null	float64
53	Class	1585 non-null	object
54	Action	1585 non-null	object

EK 2 – Veri Seti Tanımlaması

	count	mean	std	min	25%	50%	75%	max
vibrationX_kurtosis	1585.0	1.220398	1.769603	0.020208	0.332838	0.664939	1.463151	1.484189e+01
vibrationY_kurtosis	1585.0	0.568854	2.195222	-0.126367	0.067726	0.140064	0.235470	2.173206e+01
vibrationZ_kurtosis	1585.0	2.043307	8.539988	0.031651	0.287737	0.442949	0.784401	1.015929e+02
vibrationX_min_value	1585.0	-28.506271	16.306046	-110.399612	-36.162998	-22.284403	-17.457933	-9.761029e+00
vibrationY_min_value	1585.0	-30.624741	19.195094	-200.198288	-32.473225	-25.491108	-21.140728	-1.382442e+01
vibrationZ_min_value	1585.0	-28.004748	26.786452	-274.383545	-26.182917	-22.444916	-19.797449	-1.320726e+01
vibrationX_mean_value	1585.0	-0.001899	0.009956	-0.098121	-0.009385	-0.002611	0.006338	3.836520e-02
vibrationY_mean_value	1585.0	0.000359	0.008330	-0.101208	-0.002789	0.000854	0.004268	8.395553e-02
vibrationZ_mean_value	1585.0	0.001435	0.007799	-0.133729	-0.000955	0.001967	0.004471	5.820110e-02
vibrationX_skewness_value	1585.0	-0.009134	0.087182	-0.548928	-0.037832	-0.000474	0.034456	3.509013e-01
vibrationY_skewness_value	1585.0	0.008768	0.042448	-0.237194	-0.014646	0.008452	0.034432	3.059678e-01
vibrationZ_skewness_value	1585.0	-0.017451	0.101229	-1.299985	-0.021218	-0.004946	0.012894	2.637075e-01
vibrationX_variance	1585.0	26.893348	20.471494	6.986029	11.694476	19.112263	39.333998	1.367248e+02
vibrationY_variance	1585.0	40.423450	24.433017	13.922683	24.420111	34.419528	52.973437	2.453138e+02
vibrationZ_variance	1585.0	18.556360	19.378837	9.603885	12.918633	15.463241	19.080416	2.919837e+02
vibrationX_crest_factor	1585.0	5.423258	1.404633	3.613054	4.469207	5.037967	5.893985	1.196257e+01
vibrationY_crest_factor	1585.0	4.922969	1.446011	3.449772	4.100758	4.402737	5.100095	1.378211e+01
vibrationZ_crest_factor	1585.0	6.392249	2.613808	3.805637	4.806338	5.708357	6.987092	2.716955e+01
vibrationX_standard_deviation	1585.0	4.874853	1.769501	2.643110	3.419719	4.371757	6.271682	1.169294e+01
vibrationY_standard_deviation	1585.0	6.145816	1.629131	3.731311	4.941671	5.866816	7.278285	1.566250e+01
vibrationZ_standard_deviation	1585.0	4.144954	1.173278	3.099014	3.594250	3.932333	4.368114	1.708753e+01
vibrationX_sum	1585.0	-62.461330	279.797403	-2823.525475	-267.023124	-74.610319	163.786616	1.051744e+03
vibrationY_sum	1585.0	6.728663	238.575701	-3022.330760	-75.171074	22.597920	113.634570	2.579114e+03
vibrationZ_sum	1585.0	37.075812	224.721717	-4009.204895	-25.067556	52.956166	121.319116	1.645752e+03
vibrationX_margin_factor	1585.0	7.669645	1.986451	5.109630	6.320413	7.124761	8.335354	1.691763e+01
vibrationY_margin_factor	1585.0	6.962129	2.044969	4.878714	5.799348	6.226410	7.212624	1.949085e+01
vibrationZ_margin_factor	1585.0	9.040005	3.696483	5.381984	6.797188	8.072836	9.881240	3.842355e+01
vibrationX_peak	1585.0	27.903556	17.189382	9.958858	16.694696	20.764481	35.429405	1.375458e+02
vibrationY_peak	1585.0	31.608838	19.507348	13.645122	21.620420	26.233496	33.824261	1.897928e+02
vibrationZ_peak	1585.0	27.789374	25.669892	12.868333	19.909723	22.534935	26.796843	3.087738e+02
vibrationX_rms	1585.0	4.874863	1.769501	2.643110	3.419719	4.371760	6.271693	1.169297e+01
vibrationY_rms	1585.0	6.145821	1.629135	3.731312	4.941672	5.866821	7.278285	1.566259e+01
vibrationZ_rms	1585.0	4.144958	1.173291	3.099016	3.594252	3.932335	4.368116	1.708755e+01

vibrationX_frequency_center	1585.0	-0.001053	0.001555	-0.012383	-0.001727	-0.000010	0.000000	3.092507e-13
vibrationX_rms_frequency	1585.0	2182.492868	190.089259	1708.971705	2038.699267	2229.093250	2345.739140	2.552330e+03
vibrationX_root_variance_frequency	1585.0	2182.492868	190.089259	1708.971705	2038.699267	2229.093250	2345.739140	2.552330e+03
vibrationY_frequency_center	1585.0	-0.001004	0.001597	-0.011148	-0.001546	-0.000008	0.000000	3.484489e-13
vibrationY_rms_frequency	1585.0	2002.352844	93.551297	1840.280238	1935.538130	1984.130496	2068.637437	2.382609e+03
vibrationY_root_variance_frequency	1585.0	2002.352844	93.551297	1840.280238	1935.538130	1984.130496	2068.637437	2.382609e+03
vibrationZ_frequency_center	1585.0	-0.000739	0.001109	-0.006965	-0.001184	-0.000003	0.000000	6.257134e-13
vibrationZ_rms_frequency	1585.0	3863.059746	188.795628	3454.425897	3846.566127	3893.301806	3998.934331	4.412566e+03
vibrationZ_root_variance_frequency	1585.0	3863.059746	188.795628	3454.425897	3846.566127	3893.301806	3998.934331	4.412566e+03
current_kurtosis	1585.0	8.083986	1.212430	2.581382	7.223851	8.152734	8.935041	1.149103e+01
current_min_value	1585.0	0.029992	0.004147	0.020004	0.030112	0.030823	0.032323	4.133589e-02
current_mean_value	1585.0	0.353103	0.039355	0.280397	0.326231	0.347591	0.366545	5.061427e-01
current_skewness_value	1585.0	3.110146	0.185271	2.084767	2.989290	3.134169	3.242726	3.617816e+00
current_variance	1585.0	0.116900	0.033580	0.051592	0.085050	0.129983	0.143809	1.876347e-01
current_crest_factor	1585.0	3.205534	0.179408	2.547553	3.131198	3.243894	3.327178	3.533141e+00
current_standard_deviation	1585.0	0.338038	0.051303	0.227139	0.291632	0.360531	0.379221	4.331682e-01
current_sum	1585.0	9773.364632	1820.136389	5566.834457	8480.016556	9500.534122	10469.701110	1.684592e+04
current_margin_factor	1585.0	4.533310	0.253721	3.602784	4.428183	4.587558	4.705340	4.996616e+00
current_peak	1585.0	1.575878	0.150597	1.375270	1.403352	1.678458	1.708495	1.785854e+00
current_rms	1585.0	0.491631	0.037814	0.411019	0.456922	0.504944	0.520438	5.786304e-01