

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**





KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

ORCID : - - -

Trabzon

ÖNSÖZ

Teknolojideki ilerlemelere bağı olarak endüstride uygulanan kestirimci ve önleyici bakım faaliyetlerinde önemli gelişmeler yaşanmaktadır. Sonsuz vidalı redüktörler, başta üretim makineleri olmak üzere asansörler, yürüyen merdivenler, haddeleme makineleri vb. birçok sistemde avantajları nedeniyle tercih edilmektedir. Bu nedenle birçok işletmenin en önemli faaliyetleri arasında bu redüktörlerin kestirimci bakımı ön plana çıkmaktadır. Sonsuz vidalı redüktörler çalışma prensiplerinden ve yapılarından dolayı arızalanma potansiyeli yüksek sistemlerdir. Bu redüktörlerde meydana gelebilecek arızaların önceden tespit edilmesi ve buna göre tedbirlerin alınması, özellikle kesintisiz çalışması istenen sistemler ve tesisler açısından son derece önemlidir. Literatürde sonsuz vidalı redüktörlerin arızalarının tespit edilmesine yönelik bazı çalışmalar yapılmıştır. Ancak titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı, dinamik çalışma şartlarının göz önünde bulundurulduğu ve birbirinden farklı türdeki arızaların tespit edilmeye çalışıldığı, yapay zekâ tabanlı, sistematik ve karşılaştırmalı bir çalışmanın olmaması bu tez çalışmasının nedeni durumundadır.

Bu tez çalışmasının yapılması süresince hiçbir desteğini esirgemeyen danışman hocam Prof. Dr. Levent GÜMÜŞEL'e, hem tezin hem de yayınların şekillendirilmesindeki tüm yardımlarından dolayı Dr. Öğr. Üyesi Nurhan GÜRSEL ÖZMEN'e, beni yapay zekâ ile tanıştıran Prof. Dr. Hamdi Tolga KAHRAMAN'a, katkılarından dolayı Doç. Dr. Temel TÜRKER'e, Makine Mühendisliği Bölümü hocalarının tümüne, K.T.Ü. Fen Bilimleri Enstitüsüne, tez jürisi üyelerine, bana her türlü desteği veren Çaykur 100. Yıl Çay Paketleme Fabrikası Müdürlüğüne ve Çaykur Enerji Dairesi Başkanlığına, özellikle deney makinesinin yapımındaki yardımlarından dolayı iş hayatımdaki tüm değerli dostlarıma, üzerimde emeği çok büyük olan ve beni büyüten sevgili anne ve babama çok teşekkür ediyorum. Bu çalışmanın ortaya çıkması için çoğunlukla değerli eşim Bahar'a ve biricik kızım Derin'e harcamam gereken zamanı kullandım. Sabır ve anlayışları için onlara da çok teşekkür ediyorum.

Yunus Emre KARABACAK

Trabzon, 2021

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “SONSUZ VIDALI REDÜKTÖRLERDE YAPAY ZEKÂ TEKNİKLERİ İLE ARIZALARIN TESPİTİ VE SINIFLANDIRILMASI” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Levent GÜMÜŞEL'in sorumluluğunda tamamladığımı, verileri ve örnekleri kendim topladığımı, deneyleri ve analizleri ilgili laboratuarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 13/01/2021

Yunus Emre KARABACAK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	IX
SUMMARY.....	X
ŞEKİLLER DİZİNİ.....	XI
TABLolar DİZİNİ.....	XVII
SEMBOLLER DİZİNİ.....	XIX
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Kestirimci ve Önleyici Bakım.....	2
1.3. Dişli Çark Sistemleri ve Redüktörler.....	4
1.3.1. Sonsuz Vidalı Redüktörler.....	5
1.3.2. Sonsuz Vidalı Redüktörlerde (SVR) Meydana Gelen Arızalar.....	9
1.3.2.1. Aşınma.....	10
1.3.2.2. Yüzey Yorgunluğu.....	11
1.3.2.3. Kırılma.....	11
1.4. Sinyal Türleri ve Sinyal İşleme	12
1.4.1. Sinyal Kavramı ve Sinyal Türleri.....	12
1.4.2. Sinyal İşleme.....	17
1.4.3. Sinyal Analizi.....	18
1.4.3.1. Zaman Bölgesi	18
1.4.3.2. Frekans Bölgesi.....	21
1.5. Yapay Zekâ (YZ) ve Makine Öğrenmesi.....	25
1.5.1. Yapay Zekâ (YZ) Kavramı.....	25
1.5.2. Makine Öğrenmesi.....	26
1.6. Makinelerde Durum İzleme (MDİ).....	27

1.6.1.	Titreşime Dayalı Durum İzleme.....	27
1.6.2.	Akustik Durum İzleme.....	30
1.6.3.	Termal Görüntüye Dayalı Durum İzleme	31
1.6.4.	Diğer Durum İzleme Teknikleri.....	32
1.7.	Literatür Araştırması.....	33
1.7.1.	Modele Dayalı Yaklaşım.....	33
1.7.2.	Veriye Dayalı Yaklaşım.....	34
1.7.2.1.	Veriye Dayalı İstatistiksel Yaklaşım.....	35
1.7.2.2.	Yapay Zekâ (YZ).....	36
1.7.3.	Makinelerde Durum İzleme (MDİ) Teknikleri.....	41
1.7.3.1.	Titreşim Analizi ile MDİ.....	42
1.7.3.2.	Akustik Analiz ile MDİ.....	43
1.7.3.3.	Kızılötesi Termografi ile MDİ.....	44
1.7.3.4.	SVR ile İlgili Yapılmış Çalışmalar.....	44
1.8.	Tez Çalışmasının Amacı ve Literatüre Katkıları.....	46
1.9.	Özet.....	47
2.	YAPILAN ÇALIŞMALAR.....	50
2.1.	Deney Sistemi.....	50
2.1.1.	Mekanik Bileşenler.....	50
2.1.2.	Elektrik Kumanda Panosu.....	54
2.1.3.	Ölçüm Sistemi.....	58
2.1.3.1.	Hız Ölçümü.....	58
2.1.3.2.	Gerilim Ölçümü.....	59
2.1.3.3.	Titreşim Ölçümü.....	59
2.1.3.4.	Ses Ölçümü.....	61
2.1.3.5.	Veri Toplama Sistemi.....	63
2.1.3.6.	Termal Kamera.....	65
2.2.	Deneylerin Yapılışı.....	66
2.2.1.	SVR Çıkış Hızları ve Yükleme Oranları.....	66
2.2.2.	SVR Numuneleri ve Arıza Simülasyonları	67
2.3.	Bilgisayar Destekli Veri Toplama ve Sinyal İşleme.....	70
2.3.1.	Titreşim ve Ses Sinyallerinin Analizi	70
2.3.1.1.	Veri Toplama Parametreleri.....	70

2.3.1.2.	Sinyal İşleme Parametreleri.....	71
2.3.1.2.1.	Sinyallerin Filtrelenmesi.....	71
2.3.1.2.2.	Sinyal Ön İşleme - Senkron Ortalama Sinyal Tekniği.....	72
2.3.1.2.3.	Pencereleme Tekniği.....	73
2.3.1.3.	Öznitelik Çıkarma.....	73
2.3.1.3.1.	Zaman Bölgesi Analizi.....	73
2.3.1.3.2.	Frekans Bölgesi Analizi.....	76
2.3.2.	Termal Görüntülerin Analizi	78
2.4.	YZ ile Arıza Tespiti ve Sınıflandırılması.....	79
2.4.1.	YZ Yaklaşımı.....	79
2.4.2.	Çalışmalarda Kullanılan YZ Türleri.....	81
2.4.2.1.	Yapay Sinir Ağları (YSA).....	81
2.4.2.2.	Destek Vektör Makinesi (DVM).....	83
2.4.2.3.	K En Yakın Komşu (k-NN).....	84
2.4.2.4.	Adaptif Nöro-Bulanık Çıkarma (ANFIS).....	86
2.4.2.5.	Derin Öğrenme.....	89
2.4.3.	Sınıflandırma Performans Ölçütleri.....	93
2.5.	Matematiksel Model.....	94
3.	BULGULAR	99
3.1.	Titreşim Analizi Sonuçları.....	99
3.1.1.	Zaman Bölgesi.....	99
3.1.2.	Frekans Bölgesi.....	109
3.2.	Ses Analizi Sonuçları.....	116
3.2.1.	Zaman Bölgesi.....	116
3.2.2.	Frekans Bölgesi.....	124
3.3.	Termal Görüntü Analizi Sonuçları.....	129
3.4.	Yapay Zekâ (YZ) ile Arıza Tespiti ve Arızaların Sınıflandırılması.....	136
3.4.1.	Yapay Sinir Ağları (YSA)	136
3.4.1.1.	İkili Sınıflandırma: Arıza Tespiti.....	136
3.4.1.2.	Çoklu Sınıflandırma: Arıza Türünün Sınıflandırılması	147
3.4.2.	Destek Vektör Makinesi (DVM)	159
3.4.2.1.	İkili Sınıflandırma: Arıza Tespiti	159
3.4.2.2.	Çoklu Sınıflandırma: Arıza Türünün Sınıflandırılması.....	162

3.4.3.	K En Yakın Komşu (k-NN).....	166
3.4.3.1.	İkili Sınıflandırma: Arıza Tespiti.....	166
3.4.3.2.	Çoklu Sınıflandırma: Arıza Türünün Sınıflandırması.....	169
3.4.4.	Adaptif Nöro-Bulanık Çıkarım (ANFIS).....	172
3.4.4.1.	İkili Sınıflandırma: Arıza Tespiti.....	173
3.4.4.2.	Çoklu Sınıflandırma: Arıza Türünün Sınıflandırması.....	175
3.4.5.	Derin Öğrenme.....	177
3.4.6.	YZ Yaklaşımlarının Karşılaştırılması.....	183
4.	İRDELEME.....	185
4.1.	Deney Düzenine Ait İrdeleme.....	185
4.2.	Sinyal İşleme Prosedürü ve Matematiksel Modele Ait İrdeleme.....	186
4.3.	Bulgulara Ait İrdeleme	187
4.3.1.	Titreşim Analizi Sonuçlarına Ait İrdeleme.....	187
4.3.2.	Ses Analizi Sonuçlarına Ait İrdeleme.....	189
4.3.3.	Termal Görüntü Analizi Sonuçları Ait İrdeleme.....	190
4.3.4.	Yapay Zekâ İle Arıza Tespiti ve Arızaların Sınıflandırılmasına Ait İrdeleme.....	191
4.3.4.1.	Yapay Sinir Ağı Yaklaşımlarına Ait İrdeleme.....	191
4.3.4.2.	Destek Vektör Makinesi Yaklaşımlarına Ait İrdeleme.....	193
4.3.4.3.	K En Yakın Komşu Yaklaşımlarına Ait İrdeleme.....	194
4.3.4.4.	ANFIS Yaklaşımlarına Ait İrdeleme.....	195
4.3.4.5.	Derin Öğrenme Yaklaşımlarına Ait İrdeleme.....	196
4.3.4.6.	YZ Yaklaşımlarının Karşılaştırılmasına Ait İrdeleme.....	198
5.	SONUÇLAR.....	199
6.	ÖNERİLER.....	203
7.	KAYNAKLAR.....	204

ÖZGEÇMİŞ

Doktora Tezi

ÖZET

SONSUZ VIDALI REDÜKTÖRLERDE YAPAY ZEKÂ TEKNİKLERİ İLE
ARIZALARIN TESPİTİ VE SINIFLANDIRILMASI

Yunus Emre KARABACAK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Makine Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Levent GÜMÜŞEL
2021, 222 Sayfa

Sonsuz vidalı redüktörler (SVR) endüstrinin birçok alanında kullanılmaktadır. SVR'ler çalışma prensipleri gereği diğer redüktörlerden farklıdır ve daha çok arızalanma riski altındadır. Bu nedenle SVR'lerde meydana gelebilecek arızaların tespiti ve buna göre önlem alınması kesintisiz çalışması istenen sistemler ve tesisler için özellikle önemlidir. Bu amaçla bu çalışmada SVR'lerin kestirimci bakımına yönelik dinamik çalışma koşullarını taklit eden bir deney düzeneği geliştirilmiştir. Deney düzeneği ile sağlam ve arızalı SVR'ler üzerinden toplanan titreşim, ses ve termal görüntü verilerinden öznitelikler çıkarılmış ve arıza tespiti ve sınıflandırılması amacıyla kullanılmıştır. Titreşim ve ses verilerine ait zaman ve frekans bölgesinden çıkarılan öznitelikler ve termal görüntülere ait öznitelikler tek tek, ikili ve üçlü kombinasyonlarda kullanılarak elde edilen sonuçlar karşılaştırılmıştır. Çalışmalarda, yapay sinir ağları (YSA), destek vektör makinesi (DVM), k en yakın komşu (k-NN), ANFIS (adaptif nöro-bulanık arayüz sistemi) ve derin öğrenme algoritmaları arıza tespiti ve arıza türünün sınıflandırılması amacıyla kullanılmıştır. Titreşim, ses ve termal görüntü verilerinden çıkarılan özniteliklerin tek tek ve ikili kombinasyonlarda kullanılmasının sınıflandırma başarısını düşürdüğü gözlemlenmiştir. En yüksek sınıflandırma başarıları ölçüm verilerine ait özniteliklerin tümünün beraber kullanılmasıyla elde edilmiştir. Sonuçlar öznitelik seçiminin sınıflandırıcı performansını en üst düzeye çıkarmak için önemli bir adım olduğunu göstermiştir.

Anahtar Kelimeler: Arıza tespiti ve sınıflandırması, Sonsuz vidalı redüktör, Yapay zekâ, Titreşim ölçümü, Ses ölçümü, Termal görüntüleme

PhD. Thesis

SUMMARY

FAULT DETECTION AND CLASSIFICATION WITH ARTIFICIAL INTELLIGENCE
TECHNIQUES ON WORM GEARBOXES

Yunus Emre KARABACAK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Mechanical Engineering Graduate Program
Supervisor: Prof. Dr. Levent GÜMÜŞEL
2021, 222 Page

Worm gearboxes (WG) are frequently used in many areas of the industry. WG is different from other gearbox types and due to their working principles, they are under high risk of wear and fault. Therefore, detection of faults that may occur in WG and taking measures accordingly especially are important for systems and facilities that require uninterrupted operation. For this purpose, in this study an experimental setup which simulates different working conditions has been developed for condition monitoring studies of WG. Fault detection and classification were performed based on vibration, sound and thermal images data features which were acquired and processed from the healthy and faulty WG in the test rig. Apart from classical studies, time and frequency domain features vibration and sound signals and thermal images features were extracted and evaluated singularly, dual or triple forms. Commonly effective ANN (Artificial Neural Network), SVM (Support Vector Machines), k-NN (k-Nearest Neighbor), ANFIS (Adaptive Neuro Fuzzy Inference System) and deep learning classifiers were selected to detect fault and to classify types of faults. It has been determined that the fault detection and classification performances are low with the use of single feature sources. The highest classification performances for fault detection were observed when the features of all three sources used. The experimental results indicated that the selection of features is an important step to maximize the performances of classifiers.

Key Words : Fault detection and classification, Worm gerabox, Artificial intelligence, Vibration measurement, Sound measurement, Thermal imaging

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1.	Makine arıza oranlarının zamana göre değişimi.....	4
Şekil 1.2.	Dişli çarkların sınıflandırılması.....	5
Şekil 1.3.	Sonsuz vida mekanizması tipleri.....	6
Şekil 1.4.	İmalat sistemine göre sonsuz vida profil şekilleri.....	7
Şekil 1.5.	Sonsuz vida mekanizması için geometrik tanımlamalar.....	8
Şekil 1.6.	SVR.....	9
Şekil 1.7.	Aşınmış sonsuz vida (a) ve globoid çark (b).....	10
Şekil 1.8.	Globoid çarkta yüzey yorgunluğu.....	11
Şekil 1.9.	Globoid çarkta aşınma ve diş kırılması.....	12
Şekil 1.10.	Sinyal türleri.....	13
Şekil 1.11.	Deterministik periyodik sinyal örnekleri.....	13
Şekil 1.12.	Deterministik geçişli sinyal örnekleri.....	14
Şekil 1.13.	Yarı periyodik deterministik sinyal.....	14
Şekil 1.14.	Kaotik sinyal.....	15
Şekil 1.15.	Durağan random sinyal.....	15
Şekil 1.16.	Durağan olmayan random sinyal.....	16
Şekil 1.17.	Dönemli durağan random sinyal.....	16
Şekil 1.18.	Birinci dereceden Gauss olasılık yoğunluk fonksiyonu (a) ve ikinci dereceden Gauss olasılık yüzeyi (b).....	16
Şekil 1.19.	ASİ süreci.....	17
Şekil 1.20.	DSİ süreci.....	18
Şekil 1.21.	Makine öğrenmesi teknikleri.....	26
Şekil 1.22.	Tek serbestlik dereceli sönümlü zorlanmış titreşim.....	29
Şekil 1.23.	Termal kamera ile arıza tespiti.....	31
Şekil 1.24.	Modele dayalı arıza tespit ve sınıflandırma sistemi.....	34
Şekil 1.25.	Veriye dayalı bir modelin kuruluş adımları.....	35
Şekil 1.26.	MDİ’de kullanılan bazı YZ teknikleri.....	36
Şekil 2.1.	Deney sisteminin ana bileşenleri.....	51

Şekil 2.2.	Motor ve SVR ölçüleri (mm).....	52
Şekil 2.3.	Kaplin ölçüleri(mm) ve içyapısı.....	52
Şekil 2.4.	Yükleme ünitesi ölçüleri (mm) ve içyapısı.....	53
Şekil 2.5.	Soğutma fanı ve ölçüleri (mm).....	53
Şekil 2.6.	Deney düzeneğine ait genel ölçüler (mm).....	54
Şekil 2.7.	AC sürücü ve ölçüleri (mm)	55
Şekil 2.8.	5 Kademeli şalter bağlantı şeması	56
Şekil 2.9.	Yükleme sistemi için gerilim ve sıkma momenti ilişkisi	57
Şekil 2.10.	Hız kontrol ve yükleme kumanda sisteminin genel görünüşü.....	57
Şekil 2.11.	Dijital takometre/sayıcı (a) ve PNP yakınlık sensörü (b).....	58
Şekil 2.12.	PCB marka ICP® tipi ivmeölçer	60
Şekil 2.13.	İvmeölçerin redüktör üzerine montajı (a) ve zemin tespit civatası (b).....	61
Şekil 2.14.	Kapasitif mikrofon (a) ve elektrik diyagramı (b).....	62
Şekil 2.15.	Mikrofon konumu ve ses ölçümü.....	63
Şekil 2.16.	m+p VibPilot dinamik sinyal analizörü/kontrolör.....	64
Şekil 2.17.	Testo 880 termal kamera.....	65
Şekil 2.18.	Sağlam ve farklı arızalara sahip deney redüktörleri.....	68
Şekil 2.19.	Arıza tipleri; a) S, b) A1, c) A2, d) A3.....	68
Şekil 2.20.	Deneylerde kullanılan vida mekanizması numunelerinin ölçüleri.....	69
Şekil 2.21.	SVR için elde edilen ham titreşim sinyali.....	74
Şekil 2.22.	ÇK'nın aldığı değerler.....	75
Şekil 2.23.	BK'nın aldığı değerler.....	76
Şekil 2.24.	FFT işlemi.....	76
Şekil 2.25.	SVR için elde edilen GSY değişimi.....	77
Şekil 2.26.	Sağlam redüktörün termal görüntüsü.....	79
Şekil 2.27.	YZ yaklaşımı: a) arıza tespiti, b) arızanın sınıflandırılması	80
Şekil 2.28.	İki gizli katmanlı YSA	81
Şekil 2.29.	Arıza tespiti için seçilen YSA mimarisi.....	82
Şekil 2.30.	Arıza türünün sınıflandırılması için seçilen YSA mimarisi.....	82
Şekil 2.31.	DVM ile ikili bir sınıflandırma için en uygun hiper düzlem.....	83
Şekil 2.32.	k-NN sınıflandırıcı.....	85
Şekil 2.33.	ANFIS mimarisi	87
Şekil 2.34.	Arıza tespiti amacıyla kurulan ANFIS mimarisi.....	89

Şekil 2.35.	Derin öğrenme mimarisi.....	90
Şekil 2.36.	ROC eğrileri.....	94
Şekil 2.37.	Dinamik model (a) ve dişlilerde ortaya çıkan kuvvetler (b)	95
Şekil 3.1.	RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği.....	99
Şekil 3.2.	RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği.....	100
Şekil 3.3.	RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği.....	101
Şekil 3.4.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>RMS</i> değerleri	103
Şekil 3.5.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>SS</i> değerleri.....	104
Şekil 3.6.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>VAR</i> değerleri.....	105
Şekil 3.7.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>ÇK</i> değerleri.....	107
Şekil 3.8.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>BK</i> değerleri.....	108
Şekil 3.9.	RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	110
Şekil 3.10.	RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	110
Şekil 3.11.	RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	111
Şekil 3.12.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>FM</i> değerleri.....	113
Şekil 3.13.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>RMSF</i> değerleri.....	114
Şekil 3.14.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>VKF</i> değerleri.....	115
Şekil 3.15.	RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği.....	117
Şekil 3.16.	RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği.....	117
Şekil 3.17.	RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği.....	118
Şekil 3.18.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere	

	ait <i>RMS</i> değerleri.....	119
Şekil 3.19.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>SS</i> değerleri.....	120
Şekil 3.20.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>VAR</i> değerleri.....	121
Şekil 3.21.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>ÇK</i> değerleri.....	122
Şekil 3.22.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>BK</i> değerleri.....	123
Şekil 3.23.	$R\dot{C}H=30$ d/dk ve $YO=0\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	125
Şekil 3.24.	$R\dot{C}H=50$ d/dk ve $YO=50\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	125
Şekil 3.25.	$R\dot{C}H=70$ d/dk ve $YO=100\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen <i>GSY</i> grafiği.....	125
Şekil 3.26.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>FM</i> değerleri.....	126
Şekil 3.27.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>RMSF</i> değerleri.....	127
Şekil 3.28.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait <i>VKF</i> değerleri.....	128
Şekil 3.29.	$R\dot{C}H=30$ d/dk ve $YO=0\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler.....	129
Şekil 3.30.	$R\dot{C}H=50$ d/dk ve $YO=50\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler.....	130
Şekil 3.31.	$R\dot{C}H=70$ d/dk ve $YO=100\%$ için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler.....	130
Şekil 3.32.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $T_{min.}$ değerleri.....	132
Şekil 3.33.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $T_{mak.}$ değerleri.....	134
Şekil 3.34.	Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $T_{ort.}$ değerleri.....	135
Şekil 3.35.	YSA performans eğrisi.....	137
Şekil 3.36.	YSA'nın eğitim durumu ile ilgili istatistikler.....	138
Şekil 3.37.	Hata histogramı.....	138
Şekil 3.38.	Hata matrisleri.....	139

Şekil 3.39.	YSA ikili sınıflandırmaya ait ROC eğrileri.....	140
Şekil 3.40.	YSA yaklaşımlarına ait performans eğrileri.....	141
Şekil 3.41.	YSA yaklaşımlarına ait hata matrisleri.....	143
Şekil 3.42.	YSA yaklaşımlarına ait ROC eğrileri.....	144
Şekil 3.43.	YSA performans eğrisi.....	148
Şekil 3.44.	YSA'nın eğitim durumu ile ilgili istatistikler.....	149
Şekil 3.45.	Hata histogramı.....	149
Şekil 3.46.	Hata matrisleri.....	150
Şekil 3.47.	Arıza türünün tespitinde kullanılan YSA yaklaşımına ait ROC eğrileri.....	151
Şekil 3.48.	YSA yaklaşımlarına ait performans eğrileri.....	153
Şekil 3.49.	YSA yaklaşımlarına ait hata matrisleri.....	154
Şekil 3.50.	YSA yaklaşımlarına ait ROC eğrileri.....	155
Şekil 3.51.	Hata matrisi.....	160
Şekil 3.52.	Gerçek pozitif oranı ve yanlış negatif oranı.....	160
Şekil 3.53.	Pozitif tahmin edilen değerler ve yanlış bulgu oranı.....	161
Şekil 3.54.	A (a) ve S (b) redüktörleri için ROC eğrileri.....	162
Şekil 3.55.	Hata matrisi.....	163
Şekil 3.56.	Gerçek pozitif oranı ve yanlış negatif oranı.....	163
Şekil 3.57.	Pozitif tahmin edilen değerler ve yanlış keşif oranı.....	164
Şekil 3.58.	S (a) , A1 (b), A2 (c) ve A3 (d) redüktörleri için ROC eğrileri.....	165
Şekil 3.59.	Hata matrisi.....	167
Şekil 3.60.	Gerçek pozitif oranı ve yanlış negatif oranı.....	167
Şekil 3.61.	Pozitif tahmin edilen değer ve yanlış bulgu oranı.....	168
Şekil 3.62.	S (a) ve A (b) redüktörleri için ROC eğrileri.....	168
Şekil 3.63.	Hata matrisi.....	169
Şekil 3.64.	Gerçek pozitif oranı ve yanlış negatif oranı.....	170
Şekil 3.65.	Pozitif tahmin edilen değerler ve yanlış keşif oranı.....	171
Şekil 3.66.	S (a) , A1 (b), A2 (c) ve A3 (d) redüktörleri için ROC eğrileri.....	172
Şekil 3.67.	FIS eğitimine ait sonuçlar.....	174
Şekil 3.68.	FIS eğitimine ait sonuçlar.....	176
Şekil 3.69.	Titreşim ölçümlerine ait zaman dalga formu ve spektrogram görüntüleri.....	177

Şekil 3.70.	Ses ölçümlerine ait zaman dalga formu ve spektrogram görüntüleri.....	178
Şekil 3.71.	Farklı KSA yaklaşımları için doğruluk oranları.....	179
Şekil 3.72.	Farklı KSA yaklaşımları için kayıplar.....	179
Şekil 3.73.	KSA yaklaşımlarına ait hata matrisleri.....	180
Şekil 3.74.	Termal görüntü çözünürlüğünün yaklaşım başarısına etkisi.....	182



TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1.	Zaman bölgesindeki sinyal özniteliklerinden bazıları.....20
Tablo 1.2.	Bazı fonksiyonların Fourier dönüşümleri.....22
Tablo 2.1.	PCB marka 352C03 model ivmeölçerin bazı özellikleri.....59
Tablo 2.2.	Behringer ECM8000 mikrofon özellikleri.....62
Tablo 2.3.	m+p VibPilot dinamik sinyal analizörünün bazı teknik özellikleri.....64
Tablo 2.4.	Testo 880 termal kameraya ait bazı teknik özellikleri.....66
Tablo 2.5.	DeneYlerin gerçekleştirildiği redüktör çıkış hızları ve yükleme oranları.....67
Tablo 2.6.	Titreşim sinyallerine ait veri toplama parametreleri71
Tablo 2.7.	Sinyal filtreleme ile ilgili deneylerde kullanılan parametreler.....72
Tablo 2.8.	YZ yaklaşımına ait giriş ve çıkış parametreleri.....80
Tablo 2.9.	Farklı çekirdek fonksiyonlarına sahip DVM'lerin doğruluk oranları.....84
Tablo 2.10.	K-NN türleri ve doğruluk oranları.....86
Tablo 2.11.	Ön kümeleme parametreleri.....88
Tablo 2.12.	Arıza tespiti yaklaşımına ait ANFIS mimarisi ile ilgili özellikler.....88
Tablo 2.13.	Arıza türünün sınıflandırılması yaklaşımına ait ANFIS mimarisi ile ilgili özellikler.....89
Tablo 2.14.	Modifiye edilmiş GoogLeNet özellikleri.....91
Tablo 2.15.	Farklı derin öğrenme yaklaşımları için deneysel parametreler.....92
Tablo 2.16.	Hata matrisi93
Tablo 3.1.	YSA ile arıza tespitinde deneme sayısının yaklaşım performansına etkisi.....145
Tablo 3.2.	YSA ile arıza tespitinde nöron sayısının yaklaşım performansına etkisi.....146
Tablo 3.3.	Veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım performansına etkisi.....147
Tablo 3.4.	YSA ile arıza türünün tespitinde deneme sayısının yaklaşım performansına etkisi.....157
Tablo 3.5.	YSA ile arıza türünün tespitinde nöron sayısının yaklaşım performansına etkisi.....158

Tablo 3.6.	Veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım performansına etkisi.....	158
Tablo 3.7.	Sınıf etiketleri ve görsel verilerin miktarı.....	178
Tablo 3.8.	Örnek sayısının KSA yaklaşımlarının performansına etkisi.....	181
Tablo 3.9.	İkili sınıflandırma performans değerlerinin karşılaştırılması.....	183
Tablo 3.10.	Çoklu sınıflandırma performans değerlerinin karşılaştırılması.....	184
Tablo 4.1.	Li ve arkadaşları tarafından önerilen KSA yaklaşımları	197
Tablo 4.2.	Bu çalışmada önerilen KSA yaklaşımları	198



SEMBOLLER DİZİNİ VE KISALTMALAR

α_n ($^\circ$)	: Normal kavrama açısı
α_x ($^\circ$)	: Eksenel kavrama açısı
γ	: Eğim açısı
γ_{or} ($^\circ$)	: Ortalama helis açısı
γ_{xy} (f)	: Tutarlılık fonksiyonu
ω ($1/s$)	: Açısal hız
σ	: Standart sapma
σ^2	: Varyans
δ	: Boşluk miktarı
$\delta(t)$: Dirac delta fonksiyonu
ε	: Yayma oranı (emisivite)
ζ	: Sönüm oranı
φ	: Burulma açısı
ϕ	: Faz açısı
λ (m)	: Dalga boyu
τ (s)	: Zaman gecikmesi
ρ	: Sürtünme açısı
μ	: Sürtünme katsayısı
$\Delta\varphi$: Göreli açısal yer değiştirme
Δs	: Normal doğrultudaki yer değiştirme
a	: Yapay nöron
b	: Sabit
B	: Kullanışlı bant genişliği
b_1 (mm)	: Sonsuz vida boyu
b_2 (mm)	: Vida çarkı genişliği
c	: Sönüm katsayısı, göreceli açı

c (ms^{-1})	: Işıık hızı
c_f	: Tepe faktörü
d	: Burulma sönüm oranı
d_2 (mm)	: Vida çarkının bölüm çapı
d_{b1} (mm)	: Sonsuz vida dış çapı
d_{b2} (mm)	: Vida çarkı büyük diş dibi dairesi çapı
d_{D2} (mm)	: Vida çarkı büyük diş üstü dairesi çapı
d_M (mm)	: Sonsuz vida mil çapı
d_{or1} (mm)	: Sonsuz vida orta çapı
d_{i1} (mm)	: Sonsuz vida iç çapı
d_{i2} (mm)	: Vida çarkı küçük diş dibi dairesi çapı
D	: Sönüm oranı matrisi
e	: Gürültü ya da bozucu sinyali
f	: Nihai çıkış
F (Hz)	: Frekans
$f(t)$: Kuvvet
f_s	: Etkin örnekleme oranı
$G(s)$: Transfer fonksiyonu
$h(Js)$: Planck sabiti
$H(f)$: Frekans cevap fonksiyonu
$h(t)$: İmpuls cevap fonksiyonu
h_{i1} (mm)	: Sonsuz vida taban derinlik
h_{b1} (mm)	: Sonsuz vida dış başı yüksekliđi
h_{b2} (mm)	: Vida çarkı dış başı yüksekliđi
I (W / m^2)	: Ses yoğunluđu
J	: Atalet momenti, atalet momenti matrisi
k	: Yay sabiti, ölçülen örnek sayısı, burulma sertliđi, zaman adımı
k (WsK^{-1})	: Boltzmann sabiti
K	: Yay sabiti matrisi

M	: Moment, moment matrisi
N	: Blok boyutu
p (N / m^2)	: Ses basıncı
p_n (mm)	: Normal kesitteki adım
p_x (mm)	: Eksenel adım
p_z (mm)	: Toplam adım
$p(x, t)$: Olasılık yoğunluk fonksiyonu
r	: Yarıçap
$R_{xx}(\tau)$: Oto-korelasyon fonksiyonu
$R_{xy}(\tau)$: Çapraz-korelasyon fonksiyonu
$S_{ff}(\omega)$: Kuvvet fonksiyonunun güç spektrumu
$S_{xx}(f)$: Oto-güç spektrumu
$S_{xy}(f)$: Çapraz-güç spektrumu
s_f	: Form faktörü
$\text{sgn}(t)$: İşaret fonksiyonu
t (s)	: Zaman
T (K)	: Mutlak sıcaklık
T_0	: Temel periyot
$T_{mak.}$ ($^{\circ}C$)	: Maksimum sıcaklık
$T_{min.}$ ($^{\circ}C$)	: Minimum sıcaklık
$T_{ort.}$ ($^{\circ}C$)	: Ortalama sıcaklık
u	: Çevrim oranı
$u(t)$: Birim basamak fonksiyonu
$X(f)$: Frekans spektrumu
$x(t)$: Zaman alanı sinyali
\bar{x}	: Ortalama değer
x	: Giriş
W	: Ağırlık, N-boyutlu vektör
V(volt)	: Gerilim

y	: Çıkış
A1	: Aşınmış dişlilere sahip redüktör
A2	: Yüzey yorgunluğuna maruz kalmış dişlilere sahip redüktör
A3	: Dişli kırılmasına maruz kalmış redüktör
ANFIS	: Adaptif nöro-bulanık çıkarım
ASİ	: Analog sinyal işleme
A/D	: Analog/dijital dönüştürücü
BK	: Basıklık katsayısı (Kurtozis)
BNC	: Koaksiyel kablo ile kullanılan bir RF konektör türü
BS	: Ses basınç seviyesi
ÇE	: Çapraz entropi
ÇK	: Çarpıklık katsayısı
D	: Doğrulama
DA	: Diskriminant analizi
DFT	: Ayrık Fourier dönüşümü
DSİ	: Dijital sinyal işleme
DVM	: Destek vektör makinesi
DVR	: Destek vektör regresyonu
EAA	: Eğri altındaki alan
FFT	: Hızlı Fourier dönüşümü
FIS	: Bulanık arayüz sistemi
FM	: Frekans merkezi
G	: Gradyan
GK	: Gauss karışımı
GN	: Gerçek negatif
GP	: Gerçek pozitif
GSY	: Spektrum güç yoğunluğu
HK	: Hiyerarşik kümeleme
HZS	: Hibrit zeki sistem
ICP®	: Dâhili mikro-elektronik sistem ile çalışan sensör
IRT-KSA	: Termal görüntülere dayalı konvolüsyonel sinir ağı
KA	: Karar ağacı
K-NN	: K en yakın komşu

KO	: K ortalama
KÖ	: K örnekleme
KSA	: Konvolüsyonel sinir ağı
MDİ	: Makinelerde durum izleme
RÇH	: Redüktör çıkış hızı
RMS	: Ortalama karekök değeri
RMSF	: Frekans RMS değeri
ROC	: Alıcı işlem karakteristiği
ROT	: Rastgele orman tekniği
S	: Sağlam redüktör, sınıf
S-KSA	: Ses verilerine dayalı konvolüsyonel sinir ağı
SMB	: Koaksiyel kablo ile kullanılan bir RF konektör türü
SMM	: Saklı Markov modeli
SS	: Standart sapma
SVR	: Sonsuz vidalı redüktör
TF	: Tutarlılık fonksiyonu
T-KSA	: Titreşim verilerine dayalı konvolüsyonel sinir ağı
TS-KSA	: Titreşim ve ses verilerine dayalı konvolüsyonel sinir ağı
VAR	: Varyans
VKF	: Frekans varyansının karekökü
VM	: Veri madenciliği
XLR	: Balanslı (dengeli) bir konektör türü
YB	: Yalın Bayes
YN	: Yanlış negatif
YO	: Yükleme oranı
YP	: Yanlış pozitif
YS	: Ses yoğunluk seviyesi
YSA	: Yapay sinir ağı
YZ	: Yapay zekâ

1. GENEL BİLGİLER

1.1. Giriş

Teknolojik ilerlemelere bağı olarak endüstride uygulanan kestirimci ve önleyici bakım faaliyetlerinde önemli gelişmeler yaşanmaktadır. Makinelerin, sürekli üretimin olduğu fabrikalar, enerji üretim tesisleri, hava ve uzay araçları, savunma ve güvenlik alanları gibi kritik öneme sahip yerlerde kusursuz ve hatasız çalışmaları son derece önemlidir. Kritik yerlerde meydana gelen arızaların önemli maddi kayıplara ve üretim aksaklıklarına hatta can kayıplarına neden olabileceği dikkate alındığında kestirimci ve önleyici bakımın önemi ortaya çıkmaktadır. Bu açıdan birçok işletmenin en önemli faaliyetleri arasında kestirimci bakım işlemleri gelmektedir. Kestirimci bakım yöntemleri, çalışan makine durdurulmadan toplanan verilerin incelenmesi ve yorumlanması şeklinde uygulanır. Bu yorumlar neticesinde makinedeki arıza oluşumu tahmin edilmeye çalışılır ve bakım planları yapılarak söz konusu probleme müdahale edilir. Böylece makinenin çalışmasını durdurabilecek beklenmedik ve yıkıcı arızaların önüne geçilmeye çalışılır [1, 2].

Yürüyen merdivenler, haddeleme makineleri, asansörler, konveyör bantları, gıda makineleri, paketleme makineleri vb. sanayinin birçok yerinde kullanılan sonsuz vidalı redüktörler (SVR) çalışma prensiplerinden ve yapılarından dolayı aşınma ve arıza çıkarma potansiyeli yüksek sistemlerdir [3, 4]. Dolayısıyla ilgili makinelerin kestirimci bakım faaliyetlerinin planlanması esnasında bu redüktörlerin önemli ve ayrı bir yeri vardır. SVR'lerde meydana gelebilecek arızaların önceden tespit edilmesi ve buna göre tedbirlerin alınması, özellikle kesintisiz çalışması istenen sistemler ve tesisler açısından son derece önemlidir.

Günümüzde redüktör arızalarının erkenden tespiti için çeşitli yaklaşımlar kullanılmaktadır. Bunlar arasında öne çıkanlar ise titreşim analizi, ses analizi, aşınma kalıntısı analizi, motor akımı analizi vb. çeşitli fiziksel ölçümlerden elde edilen verilerin değerlendirilmesine dayanır. Özellikle titreşim verisinin değerlendirilmesi kestirimci bakım amacıyla en sık kullanılan yaklaşımdır. Son dönemlerdeki bazı çalışmalarda termal kamera görüntülerinin analizine dayalı olarak redüktör arızaları tespit edilmeye çalışılmaktadır [2]. Mevcut yaklaşımlar incelendiğinde redüktör arızalarının bahsedilen

verilerden (titreşim, akustik, termal görüntü vb.) birisinin veya ikisinin değerlendirilmesinden yola çıkılarak tespit edilmeye çalışıldığı görülmektedir. Bu yaklaşımları esas alan yöntem ve tekniklerle gerçekleştirilmiş uygulamalarda belirli ölçüde başarılı olursa da konunun önemi dikkate alındığında ciddi iyileştirmelere ihtiyaç duyulduğu anlaşılmaktadır. Üstelik mevcut yaklaşımların önemli bir eksikliği de sadece belirli bir arızanın olup olmadığının tespitine odaklanmalarıdır. Oysa birbirinden farklı arıza türlerinin teşhis edilip sınıflandırılması da kestirimci bakım açısından son derece önemlidir.

Redüktör arızalarının önceden tespiti ve sınıflandırılmasına yönelik eksiklikleri, zayıflıkları ve iyileştirme ihtiyacını sadece yaklaşımdan kaynaklanan problemlerle açıklamak mümkün değildir. Mevcut yaklaşımlar esas alınarak geliştirilen yöntem ve tekniklerin de başarıda veya başarısızlıkta önemli bir payı vardır. Örneğin titreşim verisini esas alan iki yöntemden birisi, doğrusal bir denklem ile karar verirken diğeri doğrusal olmayan sistemlerin modellenmesinde sıklıkla kullanılan yapay zekâ (YZ) tabanlı bir yöntemle karar verebilir. Farklı hızlar, farklı yükler ve farklı ortam sıcaklıkları göz önünde bulundurulduğunda böylesi dinamik çalışma koşulları altında çalışan bir redüktörün doğrusal bir sistem davranışı göstermeyeceği açıktır. O halde ikisi de aynı veriyi parametre olarak kullanan karar vericiden (iki farklı yöntem ve teknikten) doğrusal olmayan yöntemin (YZ tabanlı) daha başarılı tahminler üretmesi mümkün olacaktır.

Bu tez çalışmasında redüktör arızalarının tespit edilmesi amacıyla veri işleme aşamasında farklı veri toplama yöntemleri birlikte kullanılmış ve bütünden bir sonuca gidilmiş, bunu yaparken de farklı YZ tekniklerinden faydalanılmıştır. Tezde kullanılan yaklaşımın esası, şimdiye kadar yapılmış tezlerden farklı olarak, titreşim, ses ve görüntü verilerinin birlikte işlenmesi ve değerlendirilmesi ile redüktör arızalarının YZ tabanlı olarak hassas bir şekilde sınıflandırılmasıdır.

1.2. Kestirimci ve Önleyici Bakım

Kestirimci ve önleyici bakım faaliyetleri günümüzdeki endüstriyel işletmeler için bir zorunluluk haline gelmiştir. Bir işletmedeki bakım ve onarım masrafları o işletmenin tüm giderlerinin önemli bir bölümünü oluşturmaktadır. Bakım ve onarım bütçesinin çoğu da makine ve sistemlerin arızalarının giderilmesine harcanmaktadır [5].

Endüstriyel işletmelerdeki makinelerde genelde iki tip arıza meydana gelir. Bunlardan ilki kronik olanlardır. Kronik arızalar genelde küçük ve görünmez olmakla beraber sıklıkla meydana gelirler. İkinci tür arızalar ise yıkıcı tiptedir. Bu tip arızalar nadiren meydana gelmesine rağmen dramatik, hatta ölümcül olabilir. Kronik arızalar toplamda yıkıcı tipte olanlardan daha maliyetlidir. Her iki arıza tipi de çalışma programında ciddi aksamalara, ürün kalitesinin düşmesine, maliyetlerin yükselmesine ve makineyi kullanan operatörlere yönelik iş kazası risklerinin artmasına neden olur [6].


Üretim sürecinin aksamasıyla meydana gelen kayıp, genelde bakım maliyetlerinden çok daha fazladır. Düzenli bakım yapılan bir tesiste meydana gelen arıza sayısı azalacağından ve arızanın süresi en aza ineceğinden üretimdeki verimlilik artar ve makine operatörünün iş kazası geçirme riski azalır [6].

Tarihsel olarak en eski bakım uygulaması reaktif bakımdır. Reaktif bakımda makine arızalanana kadar herhangi bir işlem yapılmaz ve meydana gelen arızayı gidermek için tamirat yapılır. Bu bakım stratejisi operasyonun büyüklüğüne ve mevcut personel sayısına bağlı olarak makine duruşlarının önemli olmadığı tesislerde uygulanabilir. Korumucu ya da önleyici bakımda ise makinenin mevcut durumdaki kondisyonundan bağımsız olarak belirli zaman aralıklarında aşınması ya da bozulması muhtemel olan parçalar değiştirilir. Bu yöntemdeki bakım maliyetleri reaktif bakıma kıyasla daha düşüktür [5, 6].

Son yıllarda geliştirilmiş olan kestirimci bakım ya da durum izlemeye dayalı bakım ise en yeni stratejidir. Kestirimci bakım faaliyetlerinde makine arızaları çalışma esnasında sensörlerden toplanan sinyal verilerine dayalı olarak tespit edilir ve bakım gereksinimlerinin öngörülmesi sağlanır. Böyle bir bakım sistemi; yalnızca ani ve istenmeyen makine duruşlarının önüne geçmekle kalmaz ayrıca iş gücü planlamasının da verimli bir şekilde yapılmasını ve değiştirilecek parçanın önceden temin edilmesini mümkün kılar. Bütün bu faktörler, üretim maliyetlerini düşürmede çok önemli parametrelerdir [5, 6].

Şekil 1.1'de makine arıza oranlarının zamana göre değişiminin üç ana bölgeden oluştuğu görülmektedir. Bunlardan birincisi başlangıç bölgesi olup parçalar arasında alışma meydana gelir. Bu bölgede kullanım, montaj, tasarım vb. olası hatalardan dolayı arıza oranları yüksektir. İkinci bölge kullanışlı bölge olup bu bölgede arıza oranları düşer. Makinenin normal çalışma süresi olan kullanışlı bölgenin sonuna yani üçüncü bölgeye gelindiğinde arıza oranları tekrar artar. Bu artışın nedeni makinenin yıpranması, parçaların

yorulması, aşınması vb. olumsuzluklardır. Bu aşamada onarım masrafları ve üretim kayıpları artacağından makinenin yenilenmesi gerekir. Kestirimci bakım faaliyetlerinde makine arıza oranlarının zamanla değişimi dikkate alınmalı, eğer bakım ve onarım masrafları makinenin yenilenmesinden kaynaklanacak harcamadan yüksek ise makine yenilenmelidir [2].




Şekil 1.1. Makine arıza oranlarının zamana göre değişimi [2].

1.3. Dişli Çark Sistemleri ve Redüktörler

Dişli çark sistemleri güç ve hareket ileten makine elemanlarından olup endüstride oldukça sık kullanılan mekanizmalardır. En az iki dişli çarktan oluşan bu mekanizmalar tüm güç ve hız değerlerinde, oldukça yüksek bir verimde çalışabilirler. Buna rağmen maliyetleri göreceli olarak yüksektir [3, 7].

Şekil 1.2' de görüldüğü gibi dişli çark mekanizmaları millerin konumuna göre sınıflandırılabilir. Şekil 1.2 a)'da eksenleri aynı düzlemde ve birbirine paralel olan miller arasında güç ve hareket iletimini sağlayan silindirik veya alın dişli çark mekanizmaları görülmektedir. Şekil 1.2 b)'de eksenleri aynı düzlemde bulunan ve birbiri ile kesişen iki mil arasında hareket ve güç ileten konik dişli çark mekanizmaları görülmektedir. Şekil 1.2 c)'de ise spiral dişli çark mekanizmaları görülmektedir. Eksenleri aynı düzlemde olmayan

miller arasında güç ve hareket iletimi spiral dişli çark mekanizmaları ile gerçekleştirilir [7, 8]. Bu tez çalışmasının konusu olan sonsuz vida mekanizmaları bu grupta yer alır.



Şekil 1.2. Dişli çarkların sınıflandırılması [8].


1.3.1. Sonsuz Vidalı Redüktörler

Sonsuz vidalı redüktörler (SVR), güç ve hareket ileten ve millerinin eksen izdüşümleri birbirine dik ancak kesişmeyen iki dişliden oluşan sonsuz vida mekanizmalarını ihtiva ederler. Bu mekanizmalar silindirik veya globoid bir vida ile onun karşılığı olan bir çarktan meydana gelir [4, 7]. Kompakt ve hafif yapıda bir redüktör tasarımına imkân tanıyan ve bu nedenle yer tasarrufu sağlayan bu mekanizmalar, spiral dişli çarkların özel bir halidir. Spiral dişli çark mekanizmaları, diş yan yüzeylerinde oluşan

noktasal temas hali nedeniyle sadece düşük güç ve küçük çevrim oranlarında kullanılırlar. Bu gibi kısıtlamalar sonsuz vida mekanizmalarında yoktur [7, 8].

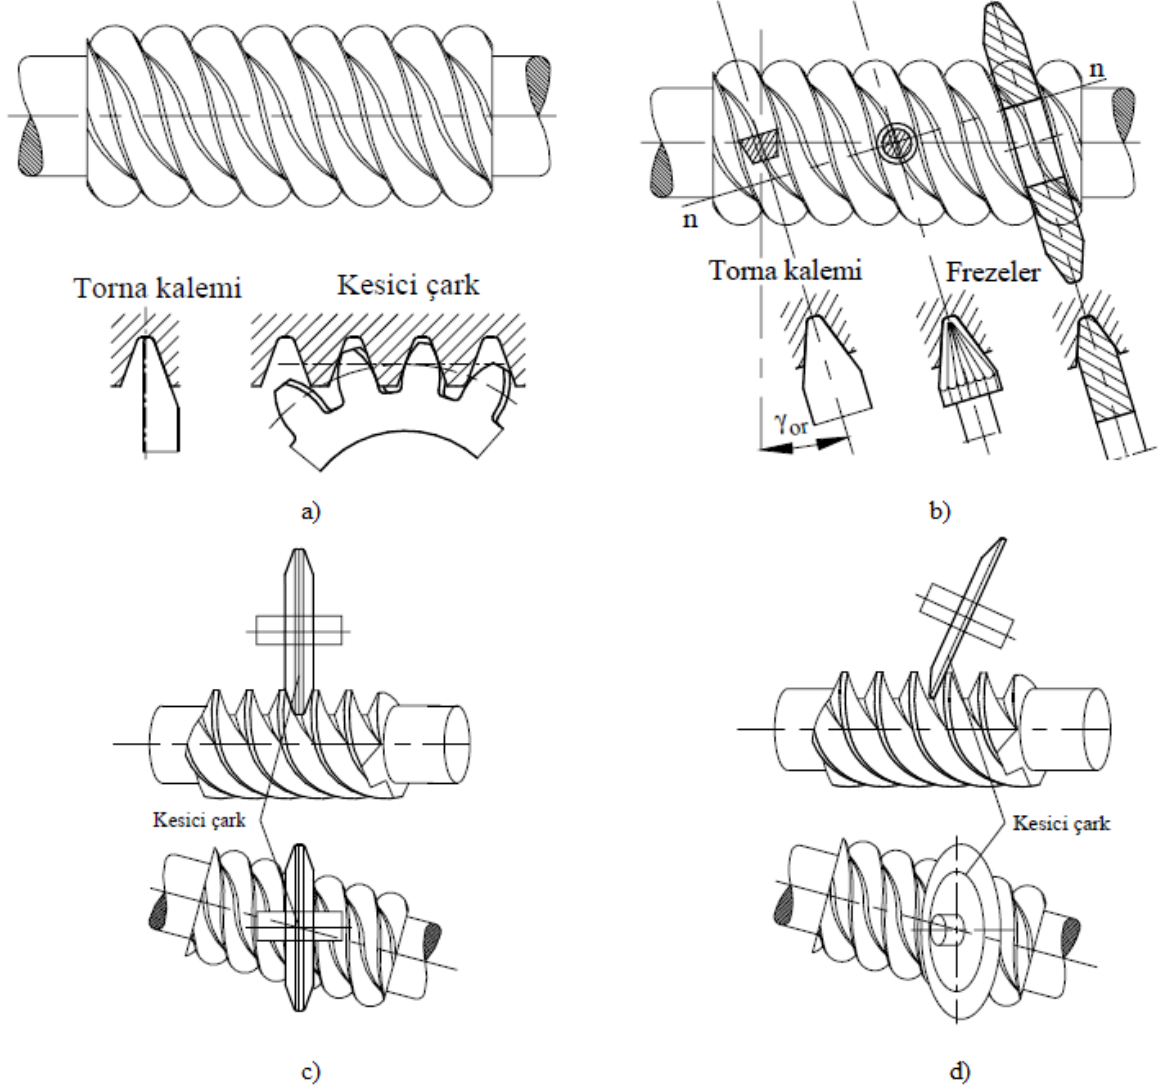
Sonsuz vida çelikten imal edilerek sertleştirilir ve taşlanır, çark ise fosfor veya alüminyum bronzundan üretilir. Büyük güçleri yüksek çevrim oranları ile iletebilen bu mekanizmalar uygun yataklama, yağlama ve soğutma teknikleri ile ağır işletme şartlarında verimli bir şekilde çalışabilirler [8].

Şekil 1.3'te sonsuz vida ve çark geometrisine göre birbirinden farklılık arz eden sonsuz vida mekanizması tipleri görülmektedir. Bu mekanizmalardan silindirik vida ve globoid çarktan oluşan tip (a) imalatı kolay olduğu için en çok tercih edilen ve kullanılan mekanizmadır [8]. Bu tezle ilgili deneysel çalışmalarda silindirik vida ve globoid çarktan oluşan mekanizmayı ihtiva eden redüktörler kullanılacaktır.



Şekil 1.3. Sonsuz vida mekanizması tipleri [8].


Şekil 1.4'te imalat sistemine göre sonsuz vida profilleri görülmektedir. Buna göre trapez şekilli aksenal kesite sahip sonsuz vidalar (a ve b), bu şekli verebilecek özel kesici takımlarla üretilir ve uygulamada nadiren kullanılır. Üretimleri ekonomik olduğundan pratikte daha çok kullanılan sonsuz vidalar ise evolvent şekilli kesite sahiptirler (c ve d) [4, 8, 9].



Şekil 1.4. İmalat sistemine göre sonsuz vida profil şekilleri [4].


Şekil 1.5 sonsuz vida mekanizması için kullanılan geometrik tanımlamaları göstermektedir. Buna göre d_{or1} sonsuz vidanın orta çapını, d_2 vida çarkının bölüm dairesi çapını, γ_{or} ortalama helis açısını, α_n normal kavrama açısını, p_x aksenal adımını, d_{b1} sonsuz vida dış çapını, d_{t1} sonsuz vida iç çapını, h_{t1} sonsuz vida taban derinliğini, h_{b1} sonsuz vida diş başı yüksekliğini, b_1 sonsuz vida boyunu, h_{b2} vida çarkı diş başı yüksekliğini, p_n normal kesitteki adımını, p_z toplam adımını, d_M sonsuz vida milinin çapını, d_{D2} vida çarkı büyük diş üstü dairesi çapını, d_{b2} vida çarkı büyük diş dibi dairesi çapını, d_{t2} vida çarkı

küçük diş dibi dairesi çapını, b_2 vida çarkı genişliğini ve α_x aksenal kavrama açısını temsil etmektedir [4, 9].



Şekil 1.5. Sonsuz vida mekanizması için geometrik tanımlamalar [4].

Şekil 1.6'da silindirik vida ve globoid çarktan oluşan bir mekanizma içeren SVR konstrüksiyonu görülmektedir [10]. İlgili iş makinesine güç ve hareket iletimi silindirik sonsuz vidanın (1) döndürdüğü globoid çark (2) ve bu çarka bağlı çıkış mili (3) ile gerçekleştirilir. Silindirik sonsuz vida ve globoid çark uygun rulmanlı yataklarla (4 ve 5) desteklenir ve yağ kaçaklarının önüne geçebilmek için özel contalar (6 ve 7) kullanılır. Redüktör gövdesi bir flanş (8) ve tespit vidaları (9) ile motor kapağına bağlanır. Gövdeye (12) bağlanan uç kapağı (10) ve yan flanş (11) rulmanlı yatakların ve contaların sabitlenmesini sağlar ayrıca bakım ve onarım işlerinde vida mekanizmasının sökülebilmesine olanak tanır. Son olarak iş makinesine yapılacak bağlantı için çıkış mili merkezine diş (13) açılmıştır.



Şekil 1.6. SVR [10].

1.3.2. Sonsuz Vidalı Redüktörlerde (SVR) Meydana Gelen Arızalar


SVR ve diğer dişli çark sistemlerinde meydana gelen arızaların incelenebilmesi için doğru analizler yapılması ve hataların gerçek kaynağının tespit edilmesi çok önemlidir. Meydana gelen arızanın kök nedeni, genellikle iletilen güç ve hareketin büyüklüğünden oldukça farklı bir etkidir. SVR kullanılan endüstriyel bir makinede meydana gelen arızanın kök nedeni makinenin tasarımı, makine bileşenlerinin imalatı, kurulumu, çevresel faktörler veya kullanım koşulları olabilir. Ayrıca aşırı yükleme ya da dengesiz montajdan kaynaklanan mekanik parça kırılmaları, yağsız çalışma veya yanlış yağ seçimi nedeniyle oluşan aşınmalar, tozlu ve kirli ortamda çalışmaya uygun olmayan sızdırmazlık elemanlarının seçimi vb. redüktör arızalarına neden olabilir. Arıza ne olursa olsun kırık, aşınmış ya da aşırı sıcak mekanik parçalar, aşırı ses ve titreşim düzeyi, yağ kaçağı ya da aşırı yüksek yağ sıcaklığı gibi anormallikler dikkatle incelenmeli ve tüm sistem gözden geçirilmelidir. Arıza kaynağının redüktör olduğu kesinleştikten sonra, silindirik sonsuz vida, globoid çark, rulmanlar, sızdırmazlık elemanları vb. redüktör bileşenlerine bakılmalıdır [11, 12].

Arızanın gerçek nedeninin tespit edilmediği durumlarda tasarımcı yeni ve boyutları daha büyük bir redüktör ile problemi gidermeye çalışabilir. Ancak bu geçerli bir çözüm olmadığından aynı arıza tekrar ortaya çıkar. Bu nedenle arızanın asıl nedeninin tespiti çok önemlidir [11].

Sonsuz vida mekanizması dişlilerinde görülen arızaların en temel biçimleri ise aşınma, yüzey yorgunluğu (pitting) ve diş kırılması (plastik deformasyon) şeklinde gerçekleşir. Bu üç temel arıza biçimi hem silindirik vida hem de globoid çarkta ortaya çıkabilir [12].

1.3.2.1. Aşınma

Sonsuz vida mekanizması için aşınma, birbiri ile eş çalışan sonsuz vida ve globoid çark arasındaki kayma hareketi ve sürtünmeden dolayı meydana gelen malzeme ve kütle kaybı süreci olarak tanımlanabilir. Bu aşınma adhezyon, abrazyon vb. farklı türlerde olabilir. Globoid çark nispeten daha yumuşak bir alaşımdan imal edildiği için sonsuz vidadan daha çok aşınır. Aşınma miktarı, temas bölgesindeki aşırı yük veya basınç, sıcaklık, yetersiz yağlama, yağlama yağı içinde bulunan yabancı ve sert parçacıklar ve diş yüzeylerinin pürüzlülüğü ile doğru orantılıdır. Ayrıca düşük çalışma hızlarında daha çok aşınma meydana gelir [12, 13]. Redüktörün maruz kaldığı şok yükler başta olmak üzere dinamik çalışma şartları, sık duruş ve kalkış gibi kullanımla ilgili diğer faktörler de aşınma miktarını artırır [12]. Şekil 1.7’de aşınmış bir sonsuz vida (a) ve globoid çark (b) görülmektedir.



Şekil 1.7. Aşınmış sonsuz vida (a) ve globoid çark (b) (Çaykur 100. Yıl Çay Paketleme Fabrikasının izni ile)

1.3.2.2. Yüzey Yorgunluğu

Yüzey yorgunluğu ya da pitting daha çok globoid çarkta görülen bir arıza tipidir ve dinamik yük altında çalışan çarkın diş yüzeylerinde meydana gelir. Bunun yanında sonsuz vida da yüzey yorgunluğuna maruz kalabilir. Globoid çark ve sonsuz vidada yüzey yorgunluğunun başlama sebebi, hiçbir dişli çarkın mükemmel ve pürüzsüz bir yüzeye sahip olmaması nedeniyle diş yüzeyleri üzerindeki gerilmelerin yoğunlaşması olarak açıklanmaktadır. Yüzeyde ve yüzeyin hemen altında sürekli tekrarlayan dinamik gerilmeler malzemenin yorulmaya karşı dayanım limitini aşar ve küçük bir çukur biçimine gelinceye kadar giderek genişleyen bir çatlak oluşur. Nihai noktada diş yüzeyinin farklı bölgelerinden kopan malzemeler birçok çukur meydana getirir. Bunun yanında, diş yüzeylerinde ortaya ilk çıkan çukurcuklar dengelenebilir, hatta kaybolabilir. Ancak bu durum zamanla artan genel aşınma miktarının önüne geçemez [12, 13].

Globoid çarkın ve sonsuz vidanın maruz kaldığı dinamik yükler ve çalışma süreleri, mekanizma dişlilerinin imal edilmesinde kullanılan malzeme çifti, diş yüzeyi geometrileri ve yağlamada kullanılan yağın tribolojik özellikleri yüzey yorgunluğunu etkileyen en önemli faktörler olarak sıralanabilir [12]. Şekil 1.8’de diş yüzeyleri yüzey yorgunluğuna maruz kalmış bir globoid çark görülmektedir.



Şekil 1.8. Globoid çarkta yüzey yorgunluğu (Çaykur 100. Yıl Çay Paketleme Fabrikasının izni ile)

1.3.2.3. Kırılma

Sonsuz vida mekanizması içindeki globoid çark ve vidanın diş kalınlıkları zaman içerisinde aşınma nedeniyle azalabilir. Bunun sonucunda azalan diş kesiti kalınlığı güç ve

hareket iletimi esnasında maruz kaldığı yükleri taşıyamaz ve kırılır. Diş kırılması sadece aşınma kaynaklı olmayabilir. Niteliksiz imalat, montaj hataları, mekanizmanın tasarlandığı yüklerden daha büyük ya da şok yükler nedeniyle diş kırılması meydana gelebilir [11, 12]. Şekil 1.9'da aşınmaya ve diş kırılmasına maruz kalmış bir globoid çark görülmektedir.



Şekil 1.9. Globoid çarkta aşınma ve diş kırılması (Çaykur 100. Yıl Çay Paketleme Fabrikasının izni ile)

1.4. Sinyal Türleri ve Sinyal İşleme

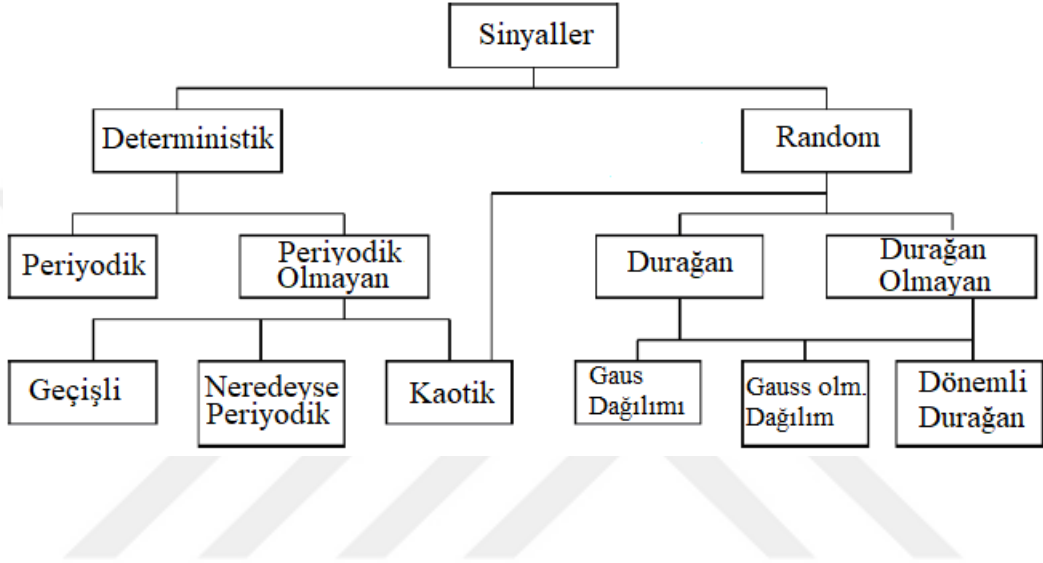
1.4.1. Sinyal Kavramı ve Sinyal Türleri

Kestirimci ve önleyici bakım faaliyetlerinin en önemli bileşeni, durumu izlenen sistemden elde edilen sinyallerin değerlendirilmesidir. Titreşim, ses ya da sıcaklık sinyalleri genellikle zaman içinde deterministik ya da deterministik olmayan bir şekilde değişen değerler dizisi olarak tanımlanır. Burada determinizm kavramı belirli ve kesin bir kurala göre davranmayı ifade eder. Gürültü kavramı ise sinyal ile benzerlik arz etmesine rağmen bilgi taşımayan ve istenmeyen fiziksel bir olaydır [14]. Sinyal işleme sürecinde fiziksel büyüklükler bir gözlemcinin değerlendirmesi için çoğu zaman elektrik sinyaline dönüştürülür [15].

Sinyal işleme veri toplamayı, toplanan veriyi işlemeyi ve yorumlamayı kapsayan bir süreçtir. Toplanan verilerin analiz edilebilmesi için, sinyal analizi veya zaman serisi analizi olarak adlandırılan geniş bir teori ve metodoloji birikimi mevcuttur. Analiz edilecek fenomenin ön bilgisine dayanarak bu metodolojilerden hangisi ya da hangilerinin seçileceğine karar verilir. Bunun yanında seçim işleminde sinyallerin nasıl


sınıflandırılacağı, modelin nasıl kurulacağı ve verilerin hangi şekilde toplanacağı gibi kriterler de önemlidir [15].

Şekil 1.10'da sinyal türleri görülmektedir. Buna göre sinyaller deterministik ve random olarak iki ana kategoride sınıflandırılabilir. Deterministik sinyallerin geçmiş, şimdiki ve gelecek değerleri herhangi bir belirsizlik olmadan, kesin olarak bilinebilirken random sinyaller için bu mümkün değildir [15, 16].




Şekil 1.10. Sinyal türleri [15].

Deterministik sinyalleri kendi içinde periyodik ve periyodik olmayan şeklinde ikiye ayırmak mümkündür. Sinüzoidal ya da üçgen dalga sinyali gibi şekli tam olarak düzenli zaman aralıklarında tekrarlayan sinyaller periyodik deterministik sinyaller olarak ifade edilebilir [16]. Şekil 1.11'de temel periyotları T_0 olan deterministik periyodik sinyal örnekleri görülmektedir [14].




Şekil 1.11. Deterministik periyodik sinyal örnekleri [14].

Periyodik olmayan deterministik sinyaller ise geçişli, yarı periyodik ve kaotik olarak üçe ayrılır. Periyodik olmayan geçişli deterministik sinyallerde sinyalin süresi ile ilgili bir kısıtlama söz konusudur. Çekiçle yapılan darbe testi deneyinde ölçülen sinyal geçişli sinyale bir örnektir. Şekil 1.12’de deterministik geçişli sinyal örnekleri görülmektedir [16].



Şekil 1.12. Deterministik geçişli sinyal örnekleri [16].


Yarı periyodik sinyaller ise son derece uzun periyotlara sahip olan deterministik sinyaller olarak düşünülebilir. Örneğin farklı frekanslara sahip iki farklı sinüs dalgasının birleşimi olan bir sinyal yarı periyodik deterministik bir sinyaldir ve dalga şekli asla kendini tekrarlamaz. Şekil 1.13’te yarı periyodik bir sinyal örneği görülmektedir [16].



Şekil 1.13. Yarı periyodik deterministik sinyal [16].

Deterministik bir sinyal periyodik bir sinyal türünden periyodik olmayan bir sinyal türüne eviriliyorsa kaotik ve görünüşte random bir davranış sergiler. Bu nedenle kaotik


sinyaller hem deterministik hem de random sinyal türü gurubunda yer alırlar [17]. Şekil 1.14'te kaotik bir sinyal örneği görülmektedir [18].




Şekil 1.14. Kaotik sinyal [18].

Random sinyaller de kendi içinde durağan ve durağan olmayan şeklinde ikiye ayrılırlar. Durağan random sinyaller *RMS* (kare ortalamalarının kökü), frekans aralığı gibi zamanla değişmeyen özellikleri ile karakterize edilir. Oysa durağan olmayan random sinyallerde bu özellikler zamanla değişir [19].


Dönemli durağan sinyaller periyodik bir altyapı taşıyan random sinyallerdir. Bu sinyaller periyodik değildir ancak istatistiksel özellikleri zamanın periyodik fonksiyonlarıdır [20]. Şekil 1.15'te durağan random sinyal, Şekil 1.16'da durağan olmayan random sinyal [16], Şekil 1.17'de ise dönemli durağan sinyal örneği görülmektedir [19].



Şekil 1.15. Durağan random sinyal [16].




Şekil 1.16. Durağan olmayan random sinyal [16].



Şekil 1.17. Dönemli durağan random sinyal [19].

Random sinyallerin diğer iki alt türü de değişkenlerin Gauss dağılımına sahip olup olmadığına bağlı olarak sınıflandırılır. Gauss dağılımı (veya normal dağılım), gerçek değerli random değişkenlerin dağılımını simetrik çan eğrisi şeklinde bir grafik olarak temsil eden fonksiyondur. Şekil 1.18’de birinci dereceden Gauss olasılık yoğunluk fonksiyonu (a) ve ikinci dereceden Gauss olasılık yüzeyi (b) görülmektedir [19].




Şekil 1.18. Birinci dereceden Gauss olasılık yoğunluk fonksiyonu (a) ve ikinci dereceden Gauss olasılık yüzeyi (b) [19].

1.4.2. Sinyal İşleme

Sinyal işleme, bir ortamdan elde edilen zaman serisi verilerini analiz veya geliştirme amacıyla değiştirme sanatı ve bilimidir. Sinyal işleme, geniş anlamda sinyaller olarak tanımlanan ve fiziksel, sembolik veya soyut formatta olabilen bilgilerin işlenmesi, iletilmesi, yükseltilmesi, geliştirilmesi, değiştirilmesi, aktarılması ve depolanmasına ilişkin teori, yöntem, uygulama ve algoritmaları içeren bir mühendislik bilimidir. Bütünsel bir süreç olan sinyal işlemede temsil, modelleme, analiz, sentez, algılama, ayıklama ve öğrenme gibi uygulamalarda matematiksel, istatistiksel, hesaplamalı, sezgisel ve dilbilimsel gösterim teknikleri kullanılır [21, 22].

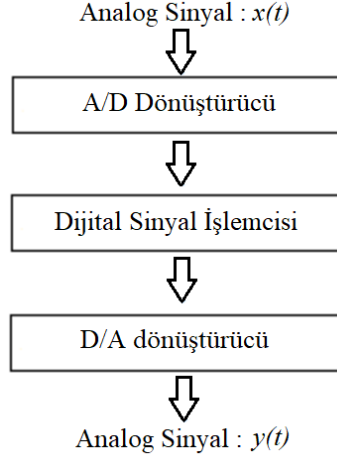
Genlik gibi fiziksel özelliklerinin uzayda, zamanda vb. değiştiği ve aktif/pasif elemanlar içeren elektrik devreleri kullanılarak işlenen analog sinyaller, pratikte en çok karşılaşılan sinyal türüdür. Analog sinyal işleme (ASİ) sürecinde sinyal doğrudan analog formda işlenir. Ayrıca giriş ve çıkışlar da analog türdedir. Şekil 1.19'da ASİ süreci görülmektedir [21, 22].



Şekil 1.19. ASİ süreci [21].

Dijital sinyal işleme (DSİ), analog sinyalin işlenmesi için alternatif bir yoldur. Bunun için analog ve dijital işlemci arasında olması gereken bir ara birime ihtiyaç vardır. Bu ara birim analog/dijital (A/D) dönüştürücü olarak bilinir. A/D dönüştürücünün çıkışı dijital bir sinyaldir ve bu sinyalin dijital işlemciye uygun olması gerekir. Ses, ışık, sıcaklık veya basınç gibi sinyaller gerçek dünyaya ait analog sinyallerdir. Bu sinyaller, dijital platformlarda A/D dönüştürücüler kullanılarak 1'ler ve 0'lardan oluşan dijital formatlara dönüştürülür. Dijital sinyal işlemcisi, sayısallaştırılmış bilgileri yakalayıp işler. Daha sonra, dijitalleştirilmiş bilgiler gerçek dünyada kullanılmak üzere tekrar analog formata dönüştürülür. Bu işlem D/A dönüştürücüler kullanılarak gerçekleştirilir. Bütün süreçler çok yüksek hızlarda gerçekleşir [21,22]. Şekil 1.20'de DSİ süreci görülmektedir [22].

Giriş sinyali üzerinde istenilen işlemin gerçekleştirilebilmesi için kullanılacak olan DSİ ünitesi büyük bir programlanabilir bilgisayar ya da küçük bir mikroişlemci olabileceği gibi sadece DSİ için tasarlanmış özel kablolu bir cihaz da olabilir [22].



Şekil 1.20. DSİ süreci [22].

1.4.3. Sinyal Analizi

Makinelere toplanan sinyallerden anlamlı bilgiler elde edebilmek için bu sinyallerin analiz edilmesi gerekir. SVR gibi mekanik sistemler için analizi yapılacak sinyaller (titreşim, ses vb.), durağan random sinyaller (Şekil 1.15) olarak göz önüne alınabilir. Durağan random sinyallerin analizi hem zaman hem de frekans bölgesinde (domain) yapılabilir.

1.4.3.1. Zaman Bölgesi

Genel olarak durağan random sinyallere ait olasılığa dayalı istatistiksel yapılarının zaman içinde değişmediği düşünülür. Bu nedenle, söz konusu sinyaller birçok uygulamada kısa zaman ölçekleri için durağanlık varsayımı yapılarak işlenir [15].

Olasılık kuramında random bir değişken için olasılık yoğunluk fonksiyonu $p(x, t)$ ile ifade edilir. Random bir sinyal sadece (1.1) ve (1.2) denklemlerindeki koşulları sağlıyorsa zayıf durağan veya basitçe durağan olarak ifade edilir. (1.1) numaralı denklemde sinyalin ortalaması ve varyansı sabittir. (1.2) numaralı denklemde ise, $p(x_1, t_1; x_2, t_2)$ sadece $(t_2 - t_1)$ zaman farkının bir fonksiyonudur. Eğer sinyal (1.3) numaralı denklemde verilen koşulu da sağlıyorsa tamamen durağan olduğu söylenebilir [16].

$$p(x, t) = p(x) \quad (1.1)$$

$$p(x_1, t_1; x_2, t_2) = p(x_1, t_1 + T; x_2, t_2 + T) \quad (1.2)$$

$$p(x_1, t_1; x_2, t_2; \dots; x_k, t_k) = p(x_1, t_1 + T; x_2, t_2 + T; \dots; x_k, t_k + T) \quad (1.3)$$

Sinyal işleme sürecindeki en önemli kavramlardan birisi evrişim (konvolüsyon) kavramıdır. Evrişim, üçüncü bir sinyal oluşturmak için iki sinyali birleştirmenin matematiksel bir yolu olarak bilinir. Şöyle ki; girişi $x(t)$, çıkışı $y(t)$ olan ve $h(t)$ ile temsil edilen bir lineer sistem için evrişim eşitliği aşağıdaki gibi yazılabilir. Burada “*” işareti evrişim operasyonunu temsil etmektedir [16].

$$x(t) * h(t) = y(t) \quad (1.4)$$

Evrişime benzer bir diğer sinyal işleme kavramı da bir sinyaldeki dalga formunu tespit etmenin en iyi yolu olan korelasyon (ilinti) kavramıdır. Eğer bir $x(t)$ sinyali kendisi ile ilintili ise otokorelasyon fonksiyonu ile, başka bir $y(t)$ sinyali ile ilintili ise çapraz korelasyon fonksiyonu ile ifade edilir. τ zaman gecikmesi olmak üzere, durağan random sinyaller için otokorelasyon (1.5, 1.6) ve çapraz korelasyon (1.7, 1.8) fonksiyonları aşağıdaki gibidir [16].

$$R_{xx}(\tau) = E[X(t)X(t + \tau)] \quad (1.5)$$

$$R_{xx}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)x(t + \tau)dt \quad (1.6)$$

$$R_{xy}(\tau) = E[X(t)Y(t + \tau)] \quad (1.7)$$

$$R_{xy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)y(t + \tau)dt \quad (1.8)$$

Titreşim veya ses sinyali gibi gözlemlenebilir fiziksel fenomenlerin ölçülebilir niteliklerine öznitelik (veya özellik) denir. Zaman bölgesinde yapılan pratik hesaplar sonucu elde edilen öznitelikler, sinyalin genel bir değerlendirmesi için çeşitli bilgiler elde etmemizi sağlar. Bu özniteliklerden bazıları Tablo 1.1’de görülmektedir [2].

Tablo 1.1. Zaman bölgesindeki sinyal özniteliklerinden bazıları [2].

Ortalama değer	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$
Maksimum değer	$x_{maks} = maks x_i $
Minimum değer	$x_{min} = min x_i $
Fark değer	$x_{fark} = x_{maks} - x_{min}$
Toplam değer	$x_{top} = \sum_{i=1}^N x_i$
Kare ortalamalarının kökü (RMS)	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
Standart sapma	$SS = \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
Varyans	$VAR = \sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$
Basıklık katsayısı (kurtozis)	$BK = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N-1)\sigma^4}$
Çarpıklık katsayısı	$\zeta K = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{(N-1)\sigma^3}$
Tepe faktörü	$c_f = \frac{x_{maks}}{x_{rms}}$
Form faktörü	$s_f = \frac{x_{rms}}{\bar{x}}$

Tablo 1.1’de görülen denklemler kullanılarak sinyalin zaman bölgesindeki öznitelikleri istatistiksel olarak hesaplanabilir. Buna göre sinyalin ortalama değerini (\bar{x}) bulmak için verilerin (x_i) toplamı veri sayısına (N) bölünür, maksimum (x_{maks}) ve minimum (x_{min}) değerlerinin farkı ise fark değerin (x_{fark}) elde edilmesini sağlar. Toplam değer (x_{top}), veriler toplanarak elde edilirken kare ortalamalarının kökü (RMS) ise verilerin karelerinin toplamının veri sayısına bölümünden elde edilen değerin karekökü alınarak hesaplanır. Standart sapma (σ , SS), verilerin ortalama değer etrafında ne kadar yayıldığını gösteren bir ölçüdür. Varyans (σ^2 , VAR) ise standart sapmanın karesi olarak göz önüne alınır. İstatistiksel olarak dağılımın üçüncü momenti çarpıklık katsayısı (ζK), dördüncü momenti ise basıklık katsayısıdır (BK). Son olarak tepe faktörü (c_f), maksimum değerin kare ortalamalarının köküne oranı iken form faktörü (s_f) de kare ortalamalarının kökünün ortalama değere oranı olarak ifade edilebilir.

1.4.3.2. Frekans Bölgesi

Durağan random sinyallerin frekans bölgesinde yapılan analizler sonucu makine içerisinde çalışan mekanik bileşenlere ait ya da meydana gelen bir arıza ile ilgili frekanslar tespit edilebilir. Çünkü sistem tarafından üretilen sinyalde her bir mekanik hareketin veya bileşen davranışının karakteristik bir frekansı vardır [2].

Frekans bölgesinde yapılan analiz (spektral analiz veya spektrum analizi) esasen bir sinyali logaritmik ya da doğrusal ölçekte çeşitli frekanslardaki bileşenlerine ayırma işlemidir. Fourier dönüşümleri, zaman bölgesindeki sinyalleri frekans bileşenlerine ayırarak zaman ve frekans bölgeleri arasındaki bağlantıyı ve temel ilişkiyi tanımlar. Fourier dönüşümleri aşağıdaki gibi yazılabilir. Burada $X(f)$ frekans spektrumunu, $x(t)$ ise zaman bölgesindeki sinyali temsil etmektedir [15].

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (1.9)$$

$$x(t) = \int_{-\infty}^{+\infty} X(f)e^{j2\pi ft} df \quad (1.10)$$

Tablo 1.2. Bazı fonksiyonların Fourier dönüşümleri [16].

Zaman Fonksiyonu, $x(t)$	Fourier Dönüşümleri, $X(f)$
$\delta(t)$, Dirac delta fonk.	1
1	$\delta(f)$
A, Sabit sayı	$A\delta(f)$
$u(t)$, Birim basamak fonk.	$\frac{1}{2}\delta(f) + \frac{1}{j2\pi f}$
$\delta(t - t_0)$	$e^{-j2\pi f t_0}$
$e^{j2\pi f_0 t}$ veya $e^{j\omega_0 t}$	$\delta(f - f_0)$
$\cos(2\pi f_0 t)$ veya $\cos(\omega_0 t)$	$\frac{1}{2}[\delta(f - f_0) + \delta(f + f_0)]$
$\sin(2\pi f_0 t)$ veya $\sin(\omega_0 t)$	$\frac{1}{2j}[\delta(f - f_0) - \delta(f + f_0)]$
$e^{-\alpha t }$	$\frac{2\alpha}{\alpha^2 + 4\pi^2 f^2}$
$\frac{1}{\alpha^2 + t^2}$	$\frac{\pi}{\alpha} e^{-\alpha 2\pi f }$
$x(t) = e^{-\alpha t} u(t)$	$\frac{1}{\alpha + j2\pi f}$
$x(t) = A; t < T, x(t) = 0; t > T$	$2AT \frac{\sin(2\pi f T)}{2\pi f T}$
$2Af_0 \frac{\sin(2\pi f_0 t)}{2\pi f_0 t}$ veya $A \frac{\sin(\omega_0 t)}{\pi t}$	$X(f) = A; f < f_0, X(f) = 0; f > f_0$
$\sum_{n=-\infty}^{\infty} c_n e^{j2\pi n f_0 t}$ veya $\sum_{n=-\infty}^{\infty} c_n e^{jn\omega_0 t}$	$\sum_{n=-\infty}^{\infty} c_n \delta(f - n f_0)$
$\text{sgn}(t)$, İşaret fonk.	$\frac{1}{j\pi f}$
$\frac{1}{t}$	$-j\pi \text{sgn}(f)$

(1.9) ve (1.10) denklemleri, sürekli zaman sinyaline ait olan Fourier dönüşümleridir. Eğer sinyal N adet veri içeren ayrık işaretli bir sinyal ise ayrık Fourier dönüşümleri (DFT) (1.11, 1.12) aşağıdaki gibi yazılabilir. Burada $X(k)$, ayrık sinyalin frekans spektrumunu, $x(n)$ ise zaman bölgesi fonksiyonunu temsil etmektedir [14].

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi kn/N} \quad k = 0, 1, 2, \dots, N-1 \quad (1.11)$$

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j2\pi kn/N} \quad n = 0, 1, 2, \dots, N-1 \quad (1.12)$$

DFT , ayrık ve sonlu zaman dizileri için hem zaman hem de frekans bölgelerinde tanımlı olan tek dönüşümdür. Hesaplanabilir bir dönüşüm olmasına rağmen, özellikle dizinin uzunluğu (N) büyük olduğu durumlarda, doğrudan uygulanması çok zordur. DFT hesaplamalarındaki bu karışıklığı indirgemek ve işlem fazlalığını azaltmak için çeşitli algoritmalar geliştirilmiştir. Tüm bu etkili algoritmalar genel olarak hızlı Fourier dönüşümü (FFT) algoritmaları olarak bilinirler [21]. FFT algoritmaları özellikle kısa zaman ölçekleri için durağan random sinyallerin frekans spektrumunun incelenmesinde kullanışlıdır.

Gerçek bir $x(t)$ sinyalinin Fourier dönüşümü karmaşık bir sayıdır: $X(f) = X_{ger.} + iX_{san.}$. Bu nedenle sinyalin spektrumu (1.13) ve (1.14) numaralı denklemlerde verildiği gibi gerçek (reel)/sanal formda veya (1.15) ve (1.16) numaralı denklemlerde verildiği gibi genlik/faz formunda gösterilebilir. Fourier dönüşümünün gerçek/sanal formundaki gösterimi için bir Nyquist diyagramı, genlik/faz formundaki gösterimi için de bir Bode diyagramı kullanılabilir [2].

$$X(f) = X_{ger.} + iX_{san.} \quad (1.13)$$

$$X(f) = |X(f)| e^{i\phi(f)} \quad (1.14)$$

$$|X(f)| = \sqrt{X_{ger.}^2 + X_{san.}^2} \quad (1.15)$$

$$\phi(f) = \tan^{-1} \frac{X_{san.}}{X_{ger.}} \quad (1.16)$$

Bir sinyalin içerdiği güç miktarı o sinyalin otogüç spektrumunun belirlenmesi ile uygun bir şekilde tespit edilebilir. $x(t)$ ile gösterilen bir sinyalin otogüç spektrumu $S_{xx}(f)$ ile ifade edilir ve (1.17) numaralı denklemde görüldüğü gibi sinyalin Fourier dönüşümünün $[X(f)]$ karmaşık eşleniği $[X^*(f)]$ ile çarpılması ile elde edilir. Otogüç spektrumu, otokorelasyon fonksiyonunun Fourier dönüşümüdür [2, 16].

$$S_{xx}(f) = X(f)X^*(f) = X_{ger.}^2 + X_{san.}^2 \quad (1.17)$$

Bir sinyalin frekans spektrumu üzerindeki güç dağılımı güç spektrum yoğunluğu (GSY) olarak ifade edilir. Geçişli bir sinyal için frekans spektrumu süreklidir ve bu tür sinyaller için GSY (1.18) numaralı denklemdeki gibi ifade edilir. Otogüç spektrumu ve GSY , gerçek niceliklerdir ve her iki büyüklük de bir sinyal tarafından taşınan enerjiye ilişkin pozitif ve skaler bilgileri ifade eder [2, 16].

$$GSY(f) = \frac{S_{xx}(f)}{f} \quad (1.18)$$

Bir sistemde $x(t)$ ve $y(t)$ olmak üzere iki sinyal mevcut olduğu durumda, sinyaller arasındaki ilişki hakkında kestirimde bulunmak için (1.19) numaralı denklemde ifade edilen çapraz güç spektrumu, yani $S_{yx}(f)$ kullanılır. Çapraz güç spektrumu genlik ve faza sahip olması açısından otogüç spektrumundan farklıdır ve karmaşık (kompleks) bir büyüklüktür. Çapraz güç spektrumu, çapraz korelasyon fonksiyonunun Fourier dönüşümüdür [2, 16].

$$S_{yx}(f) = Y(f)X^*(f) \quad (1.19)$$

Frekans bölgesinde, bir sistemin birim impulsa verdiği cevap ise frekans cevap fonksiyonu olarak ifade edilir ve $H(f)$ ile gösterilir. Frekans cevap fonksiyonu genliği ve

fazı olan karmaşık (kompleks) bir büyüklüktür ve sistemin dinamiğini karakterize etmek için kullanılır [2, 16].

$$H(f) = \frac{S_{yx}(f)}{S_{xx}(f)} \quad (1.20)$$

Son olarak $x(t)$ ve $y(t)$ durağan random sinyalleri arasındaki tutarlılık fonksiyonu (TF), 0 ila 1 arasında tanımlanan bir frekans bölgesi fonksiyonudur. TF, iki sinyal arasındaki korelasyonu, frekansın bir fonksiyonu olarak tanımlar ve sistemi tanımlamak/kimliklendirmek amacıyla deneylerden toplanan giriş ve çıkış verilerinin doğrulanmasında yaygın olarak kullanılır [19].

$$\gamma_{xy}^2(f) = \frac{|S_{xy}(f)|^2}{S_{xx}(f)S_{yy}(f)} \quad (1.21)$$

1.5. Yapay Zekâ (YZ) ve Makine Öğrenmesi

1.5.1. Yapay Zekâ (YZ) Kavramı

İnsan beyni, bilinen evrendeki en kompleks sistem olup son derece karmaşık işlemleri çok kısa bir süre içinde yapabilir. YZ kavramı da insana ait akıllı ve karmaşık davranışları taklit edip otomasyon teknolojileri alanında uygulamaya çalışan ve bilgisayar bilimlerinin teorik ve pratik ilkelerine dayanan bir kavramdır [23, 24].

Bilgisayarlar; YZ çalışmalarında, mantıksal işlemler, arama, muhakeme, örüntü tanıma, öğrenme, sezme, temsil ve gösterim, planlama veya başka türde bir sonuç çıkarma biçimini gerçekleştirmek için etkin bir şekilde kullanılmaktadır [24].

Uzman sistemler, bulanık mantık, optimizasyon problemlerine uygulanan doğal seçim yaklaşımına dayalı genetik algoritmalar, yapay nöronlardan oluşan ve beynin davranış modelini taklit eden yapay sinir ağları başlıca YZ tekniklerindedir. Günümüzde hayatın her alanında kullanılmaya başlayan, çevresindeki uyarılara duyarlı ve rasyonel davranış gösterebilen robotlar, bulanık mantığa dayalı bilgisayarlı görüş ve görüntü işleme sistemleri, ses tanıma ve doğal dil anlama uygulamaları, bilgisayar simülasyonuna dayalı

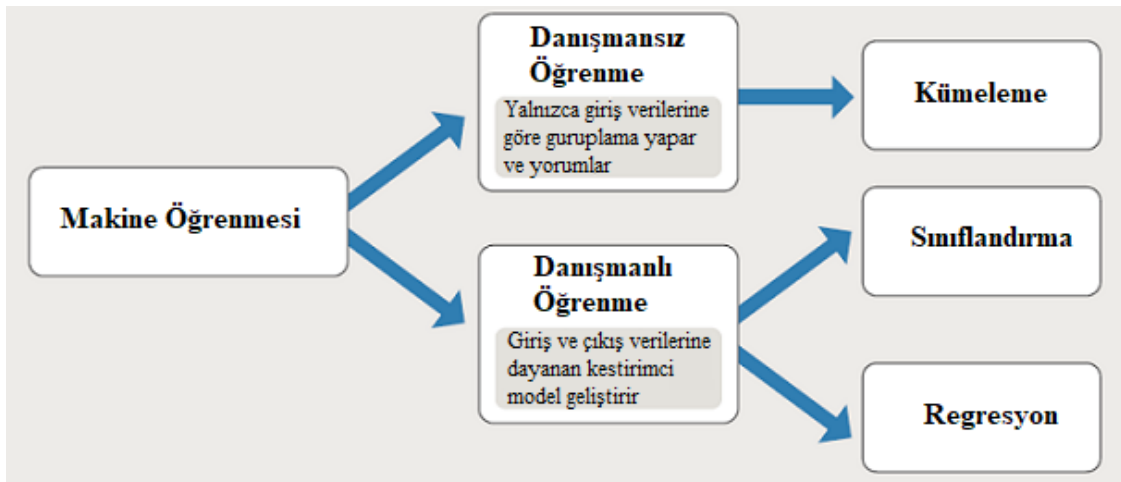
yapay yaşam modeli, rasyonel bir şekilde hareket edebilen özerk varlıklar olarak tanımlanabilecek akıllı araçlar (ajanlar), YZ tekniklerinin başlıca uygulama alanları olan örneklerdir [25].

1.5.2. Makine Öğrenmesi

Bilgisayar teknolojisindeki ilerlemelerle birlikte çok büyük miktarda verinin depolanması, işlenmesi ve fiziksel olarak çok uzak mesafelerden bir ağ vasıtasıyla bu verilere ulaşılması mümkün olmuştur. Saklanan verilerin analizi sonucu faydalı bilgiler elde edilebilir ve bu bilgiler tahminlerde bulunmak için kullanılabilir [26].

Makine öğrenmesi ya da yapay öğrenme yöntemlerinin büyük veri tabanlarına uygulanması veri madenciliği (VM) olarak bilinir. Veri madenciliğinde yüksek tahmin doğruluğuna sahip basit bir model oluşturabilmek için büyük miktarda veri işlenir. Matematiksel modellerin oluşturulmasında istatistik teorisi kullanılır ve bir örneklemden çıkarım yapılır. Makine öğrenmesi sadece bir veri tabanı problemi değildir aynı zamanda YZ'nin bir parçasıdır [26, 27].

Şekil 1.21'de görüldüğü gibi iki tür makine öğrenmesi vardır. Bunlardan ilki danışmanlı öğrenmedir. Bu teknik bir modeli bilinen giriş ve çıkış verileri üzerinden gelecekteki çıktıları tahmin edebilmesi için eğitir. Danışmansız öğrenme tekniği ise giriş verilerinde gizli örüntüler veya içsel yapılar bulmaya çalışır. Danışmanlı öğrenme, kestirimci modeller geliştirmek için sınıflandırma ve regresyon tekniklerini kullanırken, danışmansız öğrenme çıkarım yapmak için kümeleme tekniklerini kullanır [28].



Şekil 1.21. Makine öğrenmesi teknikleri [28].

Mühendislik problemlerinin çözülmesinde en çok kullanılan danışmanlı öğrenme ve YZ tekniklerinden başlıcaları yapay sinir ağları (YSA), bulanık mantık, destek vektör makinesi (DVM), diskriminant analizi (DA), yalın Bayes (YB) ve k en yakın komşu (k-NN) olarak sıralanabilir. K ortalama (KO), k örnekleme (KÖ), Gauss karışımı (GK) ve saklı Markov modeli (SMM) başlıca danışmansız makine öğrenmesi tekniklerinden olup kümeleme problemlerinde sıklıkla tercih edilmektedirler. Veri madenciliğinde karar ağacı (KA) hem sınıflandırma hem de regresyon modeli geliştirmek için kullanılabilen bir diğer tekniktir. Arama ve optimizasyon problemlerini çözmek için biyolojik organizmaların genetik yapı ve süreçlerini taklit eden genetik algoritma (GA) da mühendislik uygulamalarında sıklıkla başvurulan bir tekniktir [23-28].

Beynin yapısı ve işlevinden esinlenerek geliştirilmiş derin öğrenme, YSA olarak bilinen makine öğrenmesi algoritmalarının bir alt dalıdır. Çoğu derin öğrenme yöntemi, sinir ağı mimarilerini kullanır. Bu nedenle derin öğrenme modellerine genellikle derin sinir ağları adı da verilir. Buradaki “derin” terimi genellikle sinir ağındaki gizli katmanların sayısının çokluğunu ifade eder [29].

1.6. Makinelerde Durum İzleme (MDİ)

Makinelerde durum izleme (MDİ), kestirimci ve önleyici bakımın en önemli bileşenini oluşturmakla beraber operasyon sırasında makinelerin mevcut durumlarını izleme ve gelecekteki durumlarını tahmin etme stratejilerine dayanır. Buna göre MDİ, çalışma esnasında makinenin iç durumu hakkındaki bilgilerin harici olarak elde edilmesini, bu bilgilerin yorumlanmasını, değerlendirilmesini ve bu bilgilere dayanarak gelecek durumlarla ilgili öngörülerde bulunulmasını ifade eder [1].

1.6.1. Titreşime Dayalı Durum İzleme

Mekanik titreşim, bir sistemin bileşenleri arasındaki kinetik ve potansiyel enerjinin tekrarlı değişimi sonucunda ya da zorlayıcı bir dış kuvvet neticesi olarak meydana gelen ve bir denge konumu etrafında oluşan salınım hareketinin dışavurumu olarak ifade edilir. Şok ise kısa, ani ve tipik olarak yüksek yoğunluklu uyarımlardan kaynaklanan bir titreşim davranışdır [30].


Normal durumda her makine belirli bir titreşim düzenine sahiptir. Bu titreşim düzeni çoğunlukla makinenin çalışması esnasında dönen dişli çark, mil, rulman vb. parçalarla ve elektrik alanı gibi fiziksel büyüklüklerin periyodik hareketi ile doğrudan bağlantılıdır. Dinamik her bir makine bileşeni, kendi karakteristik frekansında, ölçülen titreşim sinyalinde kendini gösterir. Buna bağlı olarak, makinenin arızalanması halinde, normal durumdaki titreşim sinyali arızayı gösterebilecek şekilde değişir. Bu sayede işletmedeki makineden ölçülen titreşim sinyali analiz edilerek, arızalar tespit edilip sınıflandırılabilir [1, 2].

Bir makinede anormal titreşime neden olan arızalar genelde eksantrik parçalar, kaplin ve yatakların yanlış hizalanması, eğik miller, gevşek parçalar, aşınmış veya hasar görmüş dişliler, yıpranmış tahrik kayışları, eskimiş zincirler, bozulmuş rulmanlar veya kaymalı yataklar gibi mekanik bileşenlerle ilgili problemlerdir. Ayrıca tork değişimleri, elektromanyetik kuvvetler, aerodinamik kuvvetler, hidrolik kuvvetler, rezonans ve sürtünme de anormal titreşime neden olan etkenlerdendir. Birbirinden farklı gibi görünen mekanik arıza tipleri birkaç temel nedene indirgenebilir. Bunlar dengesizlik, yanlış hizalama, gevşeklik, eksantriklik ve istenmeyen bir dış kuvvet olarak sıralanabilir [31].

Titreşim davranışının karakteristiklerini belirleyen etken, titreşimi meydana getiren kuvvetin üretilme şeklidir. Farklı arıza tipleri, söz konusu arızanın tespit edilip sınıflandırılmasında kullanılacak kendine özgü titreşim karakteristiklerine sahiptir. Arızaların özgün titreşim karakteristiklerini belirleyen dört farklı tip kuvvet vardır. Bunlar titreşen sisteme etki eden zorlayıcı kuvvet, sistemin kütesinden kaynaklanan eylemsizlik kuvveti, sistemin rijitliği ile ilgili yay kuvveti ve sistemin sönüm kuvvetidir. Zorlayıcı dış kuvvet titreşime neden olurken kütle, yay ve sönüm kuvveti titreşimi kontrol edip dengelemeye veya en aza indirmeye çalışır [31].

Tüm makine bileşenleri ağırlık, yaylanma özelliği ve sönümlenmeye sahip olduğu için Şekil 1.22’de görülen tek serbestlik dereceli sönümlü zorlanmış sistem, arızaların neden olduğu titreşim davranışını temsil eden en basit benzeşim olarak düşünülebilir. MDİ çalışmalarında ivmeölçer vb. sensörler aracılığıyla toplanan random titreşim verileri bu benzeşim esas alınarak analiz edilebilir ve arızalı makine tespit edilebilir. Burada, $f(t)$ random uyarım, $x(t)$ hareket doğrultusu, m kütle, c sönüm katsayısı, k ise yay sabitidir. Buna göre, (1.22) ve (1.23) numaralı denklemler sistemin hareket denklemlerini, (1.24) impuls cevap fonksiyonunu, (1.25) transfer fonksiyonunu, (1.26) frekans cevap fonksiyonunu, (1.27) random $f(t)$ için otokorelasyon fonksiyonunun Fourier dönüşümü

olan otogüç spektrumunu, (1.28) ise sistem dinamikleri ve random $f(t)$ kuvvetinin güç spektrumuna (S_{ff}) verilen cevabın ortalama karesel değerini göstermektedir [32].



Şekil 1.22. Tek serbestlik dereceli sönümlü zorlanmış titreşim [32].

$$m \frac{d^2 x}{dt^2} + c \frac{dx}{dt} + kx = f(t) \quad (1.22)$$

$$\frac{d^2 x}{dt^2} + 2\zeta\omega_n \frac{dx}{dt} + \omega_n^2 x = f(t), \quad (\omega_n = \sqrt{\frac{k}{m}}, \zeta = \frac{c}{2\sqrt{km}}) \quad (1.23)$$

$$h(t) = \frac{1}{m\omega_d} e^{-\zeta\omega_n t} \sin \omega_d t, \quad (\omega_d = \omega_n \sqrt{1 - \zeta^2}) \quad (1.24)$$

$$G(s) = L[h(t)] = \frac{1}{ms^2 + cs + k} \quad (1.25)$$

$$G(j\omega) = H(\omega) = \frac{1}{k - m\omega^2 + c\omega j} \quad (1.26)$$

$$S_{xx}(\omega) = |H(\omega)|^2 S_{ff}(\omega) \quad (1.27)$$

$$E[x^2] = \int_{-\infty}^{\infty} S_{xx}(\omega) d\omega = \int_{-\infty}^{\infty} |H(\omega)|^2 S_{ff}(\omega) d\omega \quad (1.28)$$

1.6.2. Akustik Durum İzleme

Bir ses dalgası, en geniş anlamıyla katı, sıvı veya gaz olabilen elastik bir ortam içinde yayılan bir düzensizliktir. 20 kHz'den büyük ultrasonik (kulağın duyabileceği ses sınırının üstünde), 20 Hz ile 20 kHz arası sonik (kulağın duyabileceği ses sınırı aralığında), ve 20 Hz'in altında infrasonik (kulağın duyabileceği ses sınırının altında) frekansa sahip dalgalar bu tanıma dâhildir. Gürültü ise, bir insana rahatsız edici gelen ve istenmeyen bir ses olarak tanımlanır [33].

İyi bir kondisyona sahip makine veya tesis, akustik durum izleme teknikleriyle görüntülenebilecek istikrarlı bir ses spektrumuna sahiptir. Arızalardan dolayı makine veya tesis kondisyonunda olumsuz yönde gerçekleşen bir durum değişikliği olduğunda, söz konusu ses spektrumu da değişir. Sesi üreten kaynakların açık bir şekilde tanımlanması ve iyi kondisyonlu makine (veya tesis) ile arızalı makinenin ses spektrumlarının karşılaştırılması yoluyla olumsuz yönde gerçekleşen durum değişikliği net bir şekilde ortaya konabilir. Bu nedenle akustik emisyon analizine dayalı durum izleme teknikleri, makine ve tesislerdeki olumsuz yönde gerçekleşen değişikliklerin tespitinde yüksek hassasiyet ve güvenilirliğe sahip en etkili izleme yöntemlerinden biri olarak kabul edilmiştir [34].

Ses dalgası, ilerlediği ortamdaki parçacıkların hareketi ile ilgili titreşimsel bir fenomendir ve fiziksel bir ortamdan geçen tekrarlı yüksek ve düşük basınç alanlarının bir modelini oluşturduğu için bazen basınç dalgası olarak da isimlendirilir. Akustik ölçümlerde ses yoğunluğunu (I) ve ses basıncını (p) referans değerlerle (I_0, p_0) ilişkilendirmek standart bir uygulamadır. 1 kHz frekansındaki en zayıf duyulabilir sesin yoğunluğunu ve ortalama basınç dalgalanmalarını temsil eden bu değerler (1.29) ve (1.30) numaralı denklemlerde görülmektedir. Bu şekilde, yoğunluk (YS) ve basınç seviyeleri (BS) (1.31) ve (1.32) numaralı denklemlerde görüldüğü gibi desibel cinsinden elde edilir [34].

$$I_0 = 10^{-12} [W/m^2] \quad (1.29)$$

$$p_0 = 2 \times 10^{-5} [N/m^2] \quad (1.30)$$


$$YS = 10 \log(I/I_0) [dB] \quad (1.31)$$

$$BS = 20 \log(p / p_0) \text{ [dB]} \quad (1.32)$$

1.6.3. Termal Görüntüye Dayalı Durum İzleme

Kızılötesi termografi, termal görüntüleme cihazlarından temassız olarak verilerin toplanması ve analiz edilmesi ile ilgili bir bilimdir. Termal görüntüleme süreci, ilgili yüzeylerden alınan ışınımı termal görüntülere dönüştüren verimli ve yüksek çözünürlüklü kızılötesi kameraların kullanılabilirliği ile yıllar içinde oldukça gelişmiştir. Termal görüntüleme işleminde, kızılötesi ışınım yayan cisimlerden toplanan veriler sıcaklık dağılımı ifade edecek şekilde termograf adı verilen görüntülere dönüştürülür [35].

Kızılötesi termal görüntüleme yardımıyla pompalar, kompresörler, evaporatörler, rulmanlar, kaplinler, redüktörler, sızdırmazlık elemanları, kayış ve kasnak mekanizması gibi sistemlerdeki mekanik arızaların; elektrik motoru, jeneratör, şalter, sigorta, transformatör, priz, iletkenler gibi ekipmanlardaki elektriksel arızaların; ya da tank, boru tesisatı, vana, buhar kapağı, ısı izolasyonu gibi sistemlerdeki işletme arızalarının uzak ve güvenli bir mesafeden tespit edilmesi mümkündür. Bu sayede yüksek sıcaklık, muhtemel elektrik kaçakları, mekanik darbe vb. riskli durumlara maruz kalmadan arızanın tespit edilmesi mümkün olur [35, 36]. Şekil 1.23, elektriksel ve mekanik arızaların termal kamera ile görüntülenmesine bir örnektir.



Şekil 1.23. Termal kamera ile arıza tespiti; bir elektrik motorunda (a) ve bir rulmanlı yatakta (b) anormal ısınma [37].

Termografi çalışmalarında ölçülen ışınlam miktarı sadece cismin yüzey sıcaklığına bağlı değildir. Ölçülen cismin yayma oranı (emisivite) ve çevre sıcaklığı da ölçümleri etkilemektedir. Yayma oranı (ε), 0 ila 1 arasında değişmekle beraber bir cismin yüzeyinin enerjisi ışınlama yayma kabiliyeti olarak tanımlanır. Bir cismin birim yüzeyinden birim zamanda yayılan toplam ışınlam enerjisi, o cismin mutlak yüzey sıcaklığının dördüncü kuvvetiyle orantılıdır. Bu Stefan Boltzmann kanunu olarak bilinir ve $R [W/m^2]$ ışınlam (radyasyon), $T[K]$ mutlak sıcaklık, $\sigma = 5,67 \times 10^{-8} [W/m^2 K^4]$ Stefan Boltzmann sabiti ve ε yayma oranı olmak üzere aşağıdaki gibi yazılır [35].

$$R = \varepsilon \sigma T^4 \quad (1.33)$$

Bir cismin yaydığı ışınlam, o cismin fiziksel özelliklerine bağlıdır. Termal emisyon, dalga boyuna bakılmaksızın tüm ışınlamı tamamen absorbe edebilecek şekilde tanımlanmış siyah cisme referansla tanımlanır. Bir cismin yaydığı kızılötesi ışınlamın spektral özellikleri Planck yasası ile açıklanmıştır. Şöyle ki $h = 6,6256 \times 10^{-34} [Js]$ Planck sabiti, $k = 1,38054 \times 10^{-23} [WsK^{-1}]$ Boltzmann sabiti, $c = 2,9979 \times 10^8 [ms^{-1}]$ vakumdaki ışık hızı, $\lambda [m]$ dalga boyu, $T[K]$ ise mutlak sıcaklık olmak üzere Planck yasası (1.34) aşağıdaki gibi ifade edilir [35].

$$W(\lambda, T) = \frac{2\pi hc^2}{\lambda^5} \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]^{-1} \quad (1.34)$$

1.6.4. Diğer Durum İzleme Teknikleri

Titreşime dayalı durum izleme, akustik durum izleme ve kızılötesi termografi dışında kestirimci ve önleyici bakım faaliyetlerine yönelik başlıca teknikler; motor akımı sinyal analizi, aşınma kalıntısı analizi, eddy akımı testi, ultrasonik test, radyografi, sıvı penetrasyon testi, manyetik parçacık tekniği olarak sıralanabilir. Motor akımı sinyal analizi ve aşınma kalıntısı analizi dışındaki teknikler tahribatsız muayene yöntemleri olarak da bilinir. Tahribatsız muayene yöntemleri, kestirimci ve önleyici bakım faaliyetleri dışında periyodik denetimler, arızaların analiz edilmesi, kalite kontrol ve mevzuata uyumluluk için de uygulanır [2, 38].

Motor akımı sinyal analizi tekniğinde, motorun 3 ya da 1 fazdan çektiği akım bileşenlerinin ölçümü yapılır. Motorun çalışması sırasında eğer mekanik ya da elektriksel bir arıza meydana gelirse, motor besleme akımı bileşenlerinin harmonik içeriği de değişecektir. Sağlıklı elektrik motorundan alınan ölçümlerin referans kabul edilmesi ile birlikte fazlardan çekilen akım bileşenlerinin harmonik içeriklerindeki değişimler de arızaların göstergesi olarak kabul edilecektir [39, 40].

Aşınma kalıntısı analizi ise genellikle çevrimdışı olarak uygulanır. Laboratuvar ortamında incelenen yağ numuneleri içindeki katı parçacıklar belirlenir, yağın viskozitesi, nem miktarı, rengi vb. özellikler değerlendirilir. Yapılan bu incelemeler sonucunda makinenin durumu hakkında bir sonuca varılır [41].

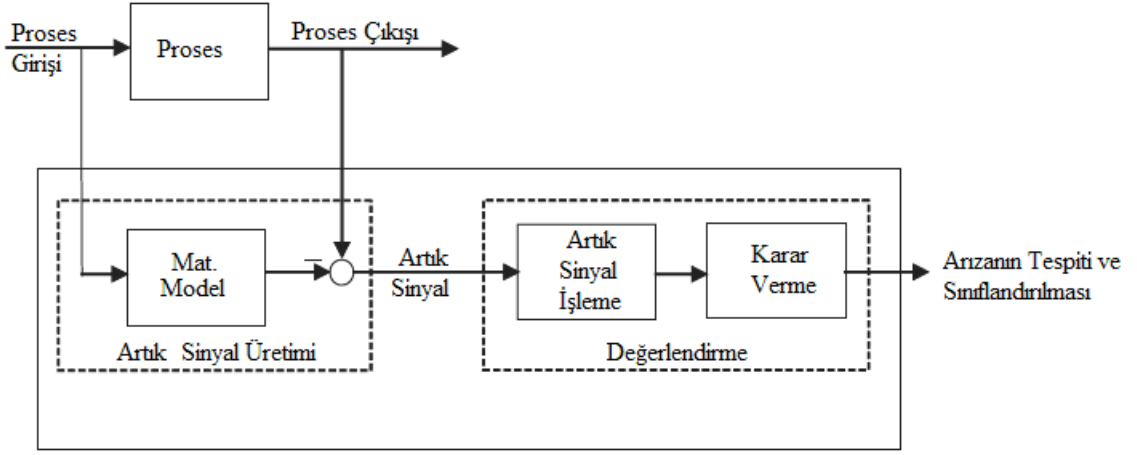
Son olarak endüstride sıklıkla kullanılan eddy akımı testi, ultrasonik test, radyografi ve manyetik parçacık tekniği gibi tahribatsız elektromanyetik muayene yöntemleri, incelenen malzemelerde herhangi bir kusur veya arıza olup olmadığının tespit edilmesi için elektromanyetik veya ses dalgalarının malzemenin içinden geçirilmesi ilkesine dayanır. Sıvı penetrasyon testi ise, floresan veya floresan olmayan boyaların kullanılarak malzemedeki kusur ve çatlakların tespit edilmesi ile ilgilidir [38, 42].

1.7. Literatür Araştırması

Makinelerin kestirimci ve önleyici bakım ve durum izleme faaliyetlerinde arızaların tespit edilmesi ve sınıflandırılmasına yönelik iki tür yaklaşımdan bahsedilebilir. Bunlardan modele dayalı yaklaşım veya beyaz kutu yaklaşımı olarak adlandırılan yaklaşım, deterministik bilgilere dayalı yöntemdir. İkincisi ise veriye dayalı yaklaşım veya siyah kutu yaklaşımı olarak adlandırılan stokastik yaklaşımdır [43, 44].

1.7.1. Modele Dayalı Yaklaşım

Modele dayalı arıza tespiti yaklaşımında Şekil 1.24'te sunulduğu gibi gözlemlenen sistemin matematiksel bir modeli kullanılır ve sistemdeki muhtemel hatanın söz konusu model parametrelerinde değişikliklere yol açacağı varsayılır. Bu yaklaşımda, artık bir sinyal üretmek için model çıktıları fiili sistem çıktıları ile karşılaştırılır. Üretilen artık sinyalin özelliklerine dayanarak potansiyel arıza durumları tanımlanır ve arızanın tespiti ve sınıflandırılması için kullanılacak faydalı bilgiler çıkarılır [43, 45].

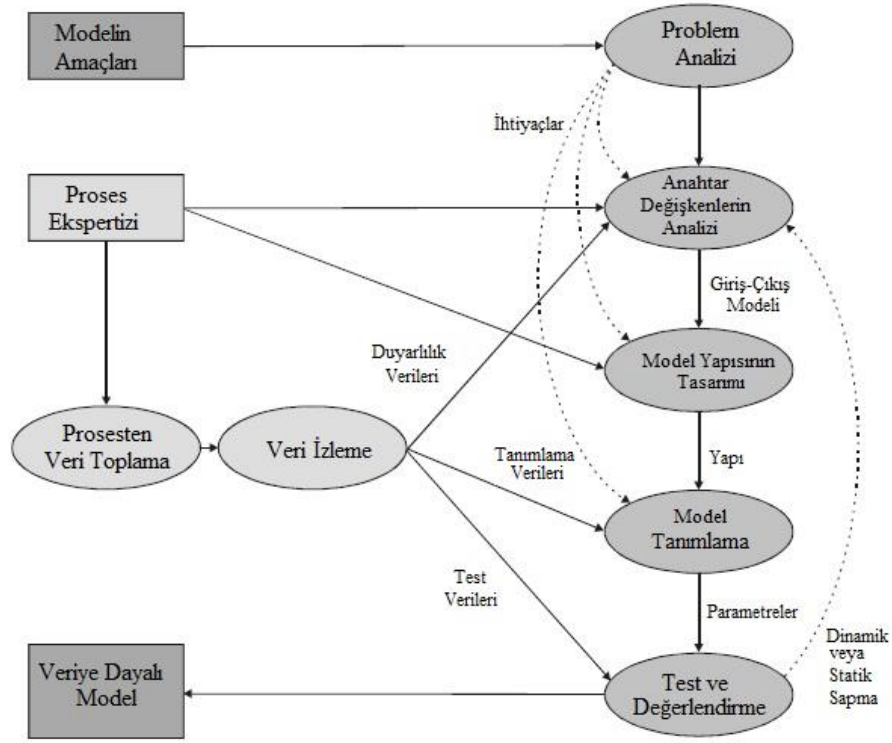


Şekil 1.24. Modele dayalı arıza tespit ve sınıflandırma sistemi [45].

Dişli çark sistemleri, rulmanlı yataklar vb. donanımların arızalarının modele dayalı olarak tespit edilmesi ile ilgili literatürde birçok araştırma mevcuttur. Parey ve arkadaşları [46] bir düz dişli çiftinin dinamik modellenmesini yapmış ve bölgesel diş arızasının erkenden saptanması için ampirik mod ayrıştırma temeline dayalı bir istatistiksel analiz uygulaması gerçekleştirmiştir. Mohammed ve arkadaşları [47] tek kademeli düz bir dişli çark sisteminin dinamik modellenmesi üzerinde çalışmış ve titreşim analizine dayalı olarak çatlak tespiti yapmıştır. Liang ve arkadaşları [48] ise bir planet dişli setindeki diş çatlağının tespiti için titreşim sinyaline dayalı bir model geliştirmiştir. Lei ve arkadaşları [49] da planet dişli mekanizması için kestirimci ve önleyici bakım ve arıza tespiti amacıyla titreşim sinyallerinden elde edilmiş spektral verilere ve cebirsel denklemlere dayalı olarak bir model kurmuştur. Ayrıca Venkatasubramanian ve arkadaşları [50] modele dayalı arıza tespit yöntemlerinin sistematik ve karşılaştırmalı bir incelemesini yapmıştır.

1.7.2. Veriye Dayalı Yaklaşım

Veriye dayalı yaklaşımlar, faaliyet veya süreci temsil eden bir model oluşturmak amacıyla ölçülen süreç verilerinden çıkarılan özelliklere bağlıdır. Bu tipteki yaklaşımlar, prosesle ilgili bilgi eksiklikleri nedeniyle açık bir matematiksel modelin inşa edilmesinin zor olduğu durumlarda tercih edilir [43, 51]. Şekil 1.25'te veriye dayalı bir modelin kuruluş adımları görülmektedir [52].



Şekil 1.25. Veriye dayalı bir modelin kuruluş adımları [52].

Bu yaklaşımlar genelde istatistiksel veya yapay zekâ (YZ) temelli tekniklere dayanmakla birlikte, süreç izleme ve arıza tespiti için endüstriyel proseslerde yaygın bir şekilde kullanılır [43, 51, 53-55].

Venkatasubramanian ve arkadaşları [56] veriye dayalı yaklaşımların göreceli olarak güçlü ve zayıf yönlerini ortaya koyan karşılaştırmalı bir çalışma yapmıştır. Bu çalışmaya göre tek bir yaklaşım, bir arıza tespit sisteminin sahip olması gereken tüm özelliklere sahip değildir ancak bazı yöntemler bir diğer yöntem için tamamlayıcı nitelikte olabilir. Böylece birbirini tamamlayan farklı yöntemler ile sınırlılıkların üstesinden gelebilecek özgün bir hibrit sistem geliştirilmiş olur.

1.7.2.1. Veriye Dayalı İstatistiksel Yaklaşım

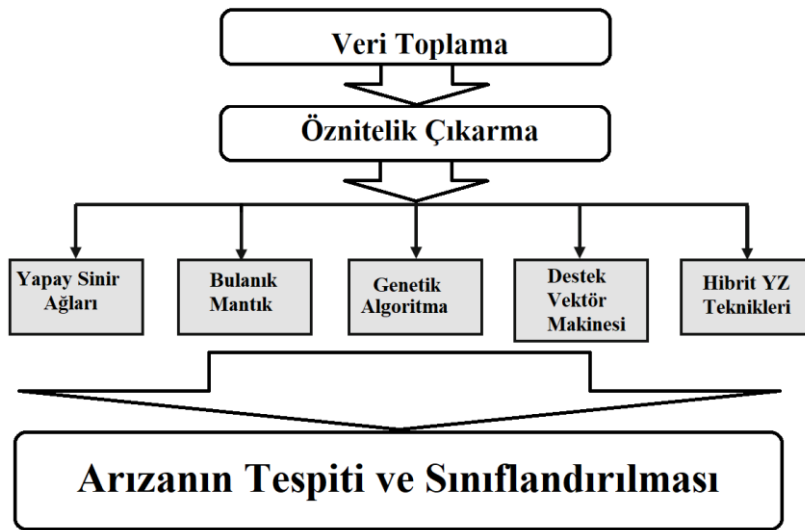
İstatistiksel yaklaşımlar, çoğunlukla verilerin istatistiksel özelliklerine dayanarak yapılan modellemeler ile ilgilidir. Bu yaklaşımla kurulan bir model veri kümesinden alınan test verileri ile test edilir. Bu yaklaşımda kullanılan teknikler karmaşıklık bakımından farklılık göstermektedir. Bilinen bir veri gurubunun yoğunluk fonksiyonunun

oluşturulmasına dayanan teknik, en basit olanıdır. Bir başka basit teknikte ise, örneklemin standart sapması ve ortalaması hesaplanır [57].

Kouadri ve Zelmat [58], bir arıza tespit modeli önermek için istatistiksel metodu ve ayrık dalgacık dönüşümünü kullanmıştır. Juliang ve arkadaşları [59] dişli çarkların titreşim sinyallerinin istatistiksel modellemesini yapmış ve bu modeli arızaların tespiti ve sınıflandırılmasına yönelik kullanmıştır. Baydar ve arkadaşları [60] ise helisel dişli çarkların durum izlemesi için çok değişkenli istatistiksel bir metodoloji sunmuştur. Zhang ve arkadaşları [61] da istatistiksel teknikleri rüzgâr türbinlerinin dişli kutularının kestirimci ve önleyici bakımına yönelik durum izleme çalışmalarında kullanmıştır.

1.7.2.2. Yapay Zekâ (YZ)

Son yıllarda, makinelerdeki arızaların tespiti ve sınıflandırılması ile ilgili çalışmalarda doğruluk ve verimliliğin artırılması için yapay sinir ağları, bulanık mantık ve destek vektör makineleri gibi YZ teknikleri yaygın olarak kullanılmaktadır. Bunların yanında makine öğrenmesi başlığı altında k en yakın komşu (k-NN), yalın Bayes (YB), karar ağaçları (KA) vb. YZ temelli birçok sınıflandırma, regresyon ve kümeleme tekniği vardır [28]. Akıllı arıza tespiti ve sınıflandırma işlemi için akış şeması Şekil 1.26'da verilmiştir. Asıl amaç, veriler toplandıktan ve önemli öznitelikler çıkarıldıktan sonra başlar [43].



Şekil 1.26. MDİ’de kullanılan bazı YZ teknikleri [43].

MDİ çalışmalarında en çok kullanılan YZ tekniklerinden biri olan yapay sinir ağları insan beyninin çalışma sistemini taklit eder [62, 63]. Literatürde dişli çark sistemleri, rulmanlı yataklar vb. mekanik donanımların arızalarının tespit edilmesi ve sınıflandırılmasına yönelik nöral ağların kullanıldığı birçok çalışma mevcuttur. Rafiee ve arkadaşları [64] çok katmanlı bir yapay sinir ağı kullanarak tipik bir dişli kutusundaki dişli çark ve rulmanların arızalarını tespit eden bir sistem geliştirmiştir. Yang ve arkadaşları [65] bir rüzgâr türbininin dişli kutusundaki farklı tipte arızaları nöral ağlara dayalı bir şekilde titreşim sinyallerinden faydalanarak tespit etmiş ve sınıflandırmıştır. Benzer bir şekilde rüzgâr türbinlerinin dişli kutularının nöral ağlara dayalı olarak durumunun izlenmesi ile ilgili başka çalışmalar da vardır [66-68].

Paya ve arkadaşları [69] bir ön işlemci olarak dalgacık dönüşümünü kullanmak suretiyle dönel makinelerde yapay sinir ağına dayalı arıza tespiti üzerine çalışmıştır. Yine dalgacık dönüşümü tekniğinin kullanıldığı nöral ağlara dayalı durum izlemesinin dişli kutularına uygulanması ile ilgili benzer başka çalışmalar da vardır [70, 71]. Dellemo [72] ise nöral ağlara dayalı olarak helikopter dişli kutularında arıza tespiti ve sınıflandırılması yapmıştır. Tian ve Zuo [73] bir dişli kutusundan deneysel olarak elde ettikleri titreşim verilerini kullanarak genişletilmiş ve tekrarlı bir yapay sinir ağına dayanan yeni bir yaklaşım önermiştir. Bartelmus ve arkadaşları [74] da yapay bir sinir ağının eğitimi için dişli kutusuna ait titreşim sinyalinin ön işlemlerini ve giriş değerlerinin seçimini gerçekleştirmiştir. Ayrıca Chen ve arkadaşları [75] tarafından dişli kutularında arıza tespiti için titreşim sinyallerinin kullanılmasıyla, çok katmanlı sinir ağlarına dayanan çoklu sınıflandırıcılar sunulmuştur.

Ayrıca ayrık dalgacık dönüşümü, amprik mod ayrıştırma vb. sinyal işleme tekniklerinden yararlanılarak nöral ağlarla arızaların erken dönemde tespiti için de bazı çalışmalar yapılmıştır [76, 77].

MDİ çalışmalarında kullanılan diğer bir YZ tekniği de bulanık mantıktır. Literatürde dişli çark sistemleri vb. mekanik donanımların arızalarının tespiti ve sınıflandırılmasına yönelik çıkarımda bulunmak için bulanık mantığın kullanıldığı bazı çalışmalar yapılmıştır [78]. Saravanan ve arkadaşları [79] bulanık mantık tekniğini kullanarak düz konik dişlilerin arızalarının titreşim sinyaline dayalı olarak tespiti üzerine çalışmıştır. Wu ve arkadaşları [80] ayrık dalgacık dönüşümü tekniği ve bulanık mantık çıkarımı ile titreşim sinyalini kullanarak değişik çalışma koşullarında dişlilerin arızalarını tanımlamıştır. Dempsey ve Afjeh [81] titreşim ve yağ kalıntı analizi ile yapılan arıza tespit

tekniklerini birleştirmek için bulanık mantığı kullanmıştır. Bunların dışında, makinelerde meydana gelen farklı arızaların sınıflandırılması [82] ve arızaların ilk oluşmaya başladığı erken dönemde tespit edilmesi [83] amacıyla bulanık mantık kullanılmıştır.

MDİ çalışmalarında destek vektör makineleri (DVM) yönteminin kullanımı yaygınlaşmıştır [84-86]. Bansal ve arkadaşları [87] frekans bölgesindeki titreşim verilerini kullanarak dişli çarklarda farklı türlerdeki arızaların tespiti amacıyla DVM tekniklerini kullanmıştır. Saravanan ve arkadaşları [88] ise bir konik dişli çark kutusunda DVM ve YSA tekniklerini kullanarak arıza tespiti yapmış ve elde ettikleri sonuçları karşılaştırmıştır. Wang ve arkadaşları [89] dişli çark arızalarından toplanan verileri DVM topluluk sınıflandırıcılarının deneysel analizini yapmak için kullanmıştır. Shen ve arkadaşları [90] tarafından farklı hata modellerini tanıyabilen çok sınıflı, DVM tabanlı genel bir çözücü önerilmiştir.

Danışmanlı bir makine öğrenmesi tekniği olan diskriminant analizi (DA)'de örüntü tanıma, MDİ ve diğer mühendislik uygulamalarında kullanılmaktadır [91, 92]. Liu ve arkadaşları [93] planet dişli mekanizmalarında oluşan arızaların seviyesinin tespiti için DA tekniğinden faydalanmıştır. Zhang ve Huang [94] ise DA tekniğini rulman arızalarının tespit edilmesi için kullanmıştır. Li ve arkadaşları [95] çalışmalarında dişli kutularında arızaların tespitine yönelik öznitelik çıkarma ve sınıflandırma yapmak için DA tekniklerini kullanmıştır. Başka bir çalışmada ise DA tekniğini hava kompresörlerinde mekanik arızaların tespiti için kullanmışlardır [96]. Yine Li ve arkadaşları [97] genelleştirilmiş DA tekniğine dayalı bir mekanik arıza sınıflandırma yaklaşımı önermiştir.

Yalın Bayes (YB) sınıflandırıcı, hesaplama verimliliği ve diğer olumlu özellikleri nedeniyle mühendislik uygulamalarında yaygın olarak kullanılan bir teknik olmuştur [98, 99]. Amaranth ve arkadaşları [100] yapmış oldukları çalışmada bir helisel dişli çark redüktöründen toplanan titreşim sinyali verilerinden çıkarılan istatistiksel özellikler aracılığıyla YB algoritmasını kullanarak arıza tespiti yapmıştır. Kumar ve arkadaşları [101] YB sınıflandırıcıları kullanılarak titreşim sinyali aracılığıyla rulmanlı yataklarda arıza tespiti yapmıştır. Saharma ve arkadaşları [102] da YB sınıflandırıcı ve Bayes net sınıflandırıcı ile ses sinyali kullanarak makaralı rulmanlarda arıza tespiti için karşılaştırmalı bir çalışma yapmıştır. Yu ve arkadaşları [103] ise dişli kutularında arıza tespiti için kombine akış grafikleri ve YB sınıflandırıcı kullanmıştır. YB algoritmaları ayrıca kesici takımlarda durum izleme çalışmaları için etkili bir şekilde kullanılmıştır [104].

K en yakın komşu (k-NN) tekniği de MDİ çalışmalarında karşılaşılan örüntü tanıma ve sınıflandırma problemlerinin çözümünde kullanılan tekniklerinden biridir [105, 106]. Literatürde k-NN sınıflandırma tekniğine dayalı olarak yapılmış bazı arıza tespit çalışmaları vardır. Lei ve Zuo [107] k-NN algoritmasını kullanarak dişli çarklarda çatlak seviyelerini tanımlamıştır. Wang [108] da benzer bir çalışmayı farklı motor hızlarında ve farklı yükler altında yapmıştır. Li ve arkadaşları [109] bağımsız bileşen analizi ve k-NN algoritmasını kullanarak dönel bir makinenin dişli kutusundaki arızalarının titreşim analizine dayalı olarak çok yönlü tespiti üzerine çalışmıştır. Tian ve arkadaşları [110] k-NN uzaklık analizi ile birlikte spektral kurtozis tabanlı öznitelik çıkarımını kullanarak motor rulmanlarında arıza tespiti yapmıştır.

K ortalama (KO), danışmansız bir makine öğrenmesi tekniği olup kümeleme problemlerinde sıklıkla tercih edildiği için MDİ uygulamalarında da kullanılmıştır [111, 112]. Benzer şekilde K örnekleme (KÖ), hiyerarşik kümeleme (HK) ve Gauss karışımı (GK) modeli de makinelerde rulmanlı yatakların ve dişli çarkların arızalarının tespit edilmesinde ve titreşim sinyallerinden öznitelik çıkarımı çalışmalarında kullanılmıştır [113-117].

Diğer bir kümeleme tekniği olan saklı Markov modeli (SMM), makinelerde arızaların tespit edilmesi çalışmalarında sıklıkla kullanılmaktadır [118, 119]. Zaidi ve arkadaşları [120] SMM tekniğini kullanarak DC marş motorlarında dişli çark arızalarının kestirimini yapmıştır. Cheng ve arkadaşları [121] lokal ortalama ayırma ve ayrık SMM tekniklerini kullanarak dişli kutularında arıza tespiti yapmıştır. Li ve arkadaşları [122] ise yarı SMM tekniği ile dişli çark ve mil sistemlerindeki gelişigüzel arızaların erkenden tespit edilmesi üzerine çalışmıştır. Miao ve arkadaşları [123] MDİ çalışmalarında DVM ile SMM tekniklerinin kullanımını karşılaştırmıştır. SMM tekniği ayrıca rulmanlı yataklarda [124], asenkron elektrik makinelerinde [125] ve kesici takımlarda [126] meydana gelen arızaların tespit edilmesi ve tanılanması çalışmalarında da kullanılmıştır.

Danışmanlı bir makine öğrenmesi tekniği olan karar ağacı (KA) hem sınıflandırma hem de regresyon uygulamalarında kullanılmıştır [127, 128]. KA ile makinelerde arıza tespitine yönelik bazı çalışmalar da yapılmıştır. Saravanan ve Ramachandran [129] ayrık dalgacık özellikleri ve KA sınıflandırma tekniği kullanarak konik dişli çark redüktöründe arıza tespiti yapmıştır. Muralidharan ve Sugumaran [130] monoblok santrifüj pompada arıza tespiti için KA algoritması ile sınıflandırma tekniğini ve dalgacık dönüşümünü kullanarak öznitelik çıkarma çalışması yapmıştır. Sun ve arkadaşlar [131] ise dönel

makinelere balans vb. arızaların tespiti için temel bileşen analizini ve KA algoritmasını kullanmıştır. Karabadji ve arkadaşları [132] da makinelereki dönen ekipmanların arızalarını tespit edebilmek için KA tekniğinin yapısını veri örneklemesine ve öznitelik seçimine dayalı olarak geliştirmeye çalışmıştır. Amaranth ve arkadaşları [133] ise ses sinyallerinden faydalanmak suretiyle KA tekniğini kullanarak rulmanlı yataklarda arıza tespiti yapmıştır.

Literatüre bakıldığında makinelere arızaların tespitine yönelik yapılan çalışmalarda ve diğer mühendislik uygulamalarında genetik algoritma (GA)'nın da kullanıldığı görülmektedir [43, 134]. Samanta [135] dişli çark sistemlerinde arıza tespiti için kullanılan GA tabanlı ve GA tabanlı olmayan sınıflandırıcıların (DVM ve YSA) performanslarını karşılaştırmıştır. Samanta ve arkadaşları [136] tarafından benzer bir çalışma da rulmanlı yataklar için yapılmıştır. Hajnayeb ve arkadaşları [137] dişli kutularında arıza tespiti için GA ve YSA tabanlı öznitelik seçimi yapmış ve bu iki tekniği birbiri ile karşılaştırmıştır. Cerrada ve arkadaşları [138] düz dişli çark sistemlerindeki arızaların tespiti için GA tabanlı öznitelik seçimini rastgele orman tekniği (ROT) ile birleştirmiştir. Zhang ve Randall [139] da GA ve hızlı kurtogramın kombinasyonuna dayanan bir arıza tespit sistemini makaralı rulmanlar için uygulamıştır. Bordoloi ve Tiwari [140] ise GA ve DVM entegrasyonu ile redüktörlerde optimal çoklu arıza sınıflandırması yapmıştır.

MDİ çalışmalarında yararlanılan hibrit zeki sistemler (HZZ) daha doğru bir sonuç ve daha iyi bir performans elde etmek için yukarıda bahsedilen YZ tekniklerinden en az ikisinin birleşimi olarak tanımlanabilir. Bir HZZ farklı YZ tekniklerinin avantajlarını birleştirebilir. HZZ'nin ana amacı, oluşturduğu YZ türlerinin zayıflıklarını azaltmak veya ortadan kaldırmak ve yeni bir yaklaşım tekniği ortaya koymaktır [43].

HZZ teknikleri ile makinelere arıza tespiti ve sınıflandırmasına yönelik birçok çalışma yapılmıştır. Lei ve arkadaşları [141] dişli çark sistemlerindeki farklı kategorilerde ve farklı seviyelerdeki arızaların tanımlanması için GA ve sınıflandırıcıların kullanıldığı çok boyutlu yeni bir HZZ önermiştir. Wu ve arkadaşları [141] ayırık dalgacık dönüşümü ve bir HZZ olan adaptif nöro-bulanık çıkarım (ANFIS) tekniği kullanarak dişli çarklarda arıza tanımlaması ve sınıflandırması yapmıştır. Yen ve Meesad [142] nöro-bulanık YZ tekniğini makinelere arızaların tespiti ve sınıflandırılmasına yönelik kullanmıştır. Balazinski ve arkadaşları [143] nöral ağ tabanlı bulanık çıkarım sistemi ile kesici takımlarda meydana gelen aşınmayı tespit etmek amacıyla durum izlemesi yapmıştır. Achiche ve arkadaşları

[144] da GA ile oluşturulmuş bulanık bilgi tabanlı bir HZS ile kesici takım aşınmasını izlemiştir. Wang ve arkadaşları [145] bir nöro-bulanık HZS tekniği ile dişli çark sistemlerinde arıza tespiti ve sınıflandırması yapmıştır. Zhang ve arkadaşları [146] çok ölçekli entropi ve ANFIS tekniklerini kullanarak rulmanlarda arıza tespiti ve teşhisi yapmıştır. Chen ve arkadaşları [147] ANFIS ve yüksek mertebeli parçacık filtrelemesine dayalı olarak makine durumunun kestirimi üzerine çalışmıştır. Lei ve arkadaşları [148] ise GA ile çoklu ANFIS kombinasyonuna dayalı olarak dönel makinelerde arıza tespiti yapmıştır. Pawar ve Ganguli [149] kırışlerde ve helikopter rotor kanatlarında hasar tespiti için GA ve bulanık sistemden oluşan bir HZS kullanmıştır.

En yeni makine öğrenmesi tekniklerinden biri olan nöral ağlara dayalı derin öğrenme, son zamanlarda arıza tespitinde de kullanılmaya başlanmıştır [29]. Jia ve arkadaşları [150] hem karakteristik veri madenciliğine hem de akıllı teşhis yöntemlerini uygulayan derin nöral ağlara dayalı yeni bir akıllı arıza tespit sistemi önermiş ve önerdikleri yöntemi çeşitli çalışma koşulları altında toplanan verilerle doğrulamıştır. Zhao ve arkadaşları [151] derin nöral ağlara dayalı olarak yüksek hızlı bir trenin taşıyıcı bileşenlerinde titreşim sinyali analizi ile arıza tespiti yapmıştır. Sun ve arkadaşları [152] asenkron motor arızalarının sınıflandırması için otomatik kodlayıcı (enkoder) tabanlı bir derin sinir ağı yaklaşımı önermiştir. Guo ve arkadaşları [153] ise derin nöral ağlara dayalı olarak rulmanlı yataklarda arızaların tespiti ve şiddetinin belirlenmesi üzerine çalışmıştır.

1.7.3. Makinelerde Durum İzleme (MDİ) Teknikleri

Hareketli bileşenlere sahip tüm makineler ses ve titreşim üretir ve her bir makine, konstrüksiyonu ve çalışma durumuna bağlı olarak belirli bir titreşim ve ses imzasına sahiptir. Makinenin çalışma durumu değiştiğinde titreşim ve ses imzası da değişir. Bu prensipten yararlanılarak makinelerde meydana gelen arızalar kritik hale gelmeden önce tespit edilebilir. Titreşim ve sese dayalı MDİ tekniklerinin temeli de budur. Buna göre ses ve titreşime dayalı MDİ tekniklerinin kullanılmasıyla arızanın varlığı, kök nedeni, şiddetinin derecesi tespit edilir ve giderilmesi için ilgili düzenlemeler yapılır, gerekli önlemler alınır [154].

Ses ve titreşim bilgisinin dışında makine bileşenlerinin sıcaklığı da yapısal sağlığın en yaygın göstergelerinden biridir. Arızalı mekanik parçalar, aşınmış bağlantılar, hasarlı makine bileşenleri vb. anormal sıcaklık dağılımına neden olur. Buna bağlı olarak kızılötesi

termografi tekniđi de söz konusu anormal sıcaklık dağılımının temassız ve gerçek zamanlı olarak tespit edilebileceđi bir MDİ aracı olarak yaygın hale gelmiştir [155].

1.7.3.1. Titreşim Analizi ile MDİ

Dişli çark vb. makine elemanlarında meydana gelen arızaların titreşim analizi ile tespitine yönelik literatürde birçok çalışma yapılmıştır. Zaman bölgesi, frekans bölgesi ve zaman-frekans bölgesi olmak üzere üç ana yaklaşım altında gruplandırılabilir çalışmalardan bazıları aşağıdaki gibidir [156].

Antoni ve Randal [157] tipik helikopter şanzımanları gibi güçlü dişli çark titreşim sinyallerinin üretildiđi sistemlerde titreşim analizine dayalı olarak makaralı rulmanların ürettiđi sinyalleri ayırt etmeye ve buna dayalı olarak arızaların tespitine çalışmıştır. Loutridis [158] yakın zamanda geliştirilmiş ampirik mod ayrıştırma şemasına dayalı olarak dişli çark arızalarının gelişimini izlemek için yeni bir yöntem sunmuştur. Fan ve Zuo [159] dişli çark sistemleri için Hilbert dönüşümü ve dalgacık paket dönüşümünü birleştiren yeni bir arıza tespit yöntemi önermiştir. Peng ve arkadaşları [160] geliştirilmiş Hilbert – Huang dönüşümü ve dalgacık dönüşümünü karşılaştırmış ve rulmanlarda arıza tespitine yönelik bir uygulama yapmıştır. Yu ve arkadaşları [161] makaralı rulmanlarda arıza tespiti için ampirik mod ayrıştırma ve Hilbert spektrumunun uygulamasını kullanmıştır. Liu ve arkadaşları [162] ampirik mod ayrıştırması ve Hilbert spektrumunu kullanılarak dişli çark redüktörlerinde arıza tespiti yapmıştır. Yang ve Makis [163] farklı yükleme koşulları altında çalışan bir dişli kutusu için dişli çark arızası oluşumunu tespit etmek ve yerini saptamak amacıyla model tabanlı yeni bir yaklaşım sunmuştur. Lewicki ve arkadaşları [164] titreşim ayrıştırma tekniklerini kullanarak planet dişli mekanizmalarında arıza tespiti yapmıştır. Xue ve Howard [165] planet dişli mekanizmalarında arıza tespiti için bir teşhis aracı olarak burulmadan kaynaklı titreşim sinyallerinin analizini yapmıştır. Dhamande ve Chaudhari [166] zaman-frekans yöntemine dayalı istatistiksel özellikleri kullanarak bileşik bir dişli-rulman arıza tespit sistemi için öznitelik çıkarma çalışması yapmıştır. Liu ve arkadaşları [167] tek kademeli bir planet dişli çark mekanizmasında yeni başlayan bir diş çatlađını titreşim sinyali modeline dayalı olarak tespit etmiştir. Li ve arkadaşları [168] bir düz dişli çark çiftinin sağlıklı ve arızalı durumlardaki titreşim davranışlarını incelemiştir. Ma ve arkadaşları [169] geniş diş temas yüzeyinin etkilerini göz önünde bulundurarak kırık bir dişli çark sisteminden titreşim analizine dayalı olarak çıkarılmış özniteliklerin analizini

yapmıştır. Samuel ve Pines [170] helikopter transmisyon sistemlerinde meydana gelen arızaların titreşim analizine dayalı olarak tespit edilmesinde kullanılan tekniklerin değerlendirmesini yapmıştır. Aherwar ve Khalid [171] dişli çark redüktörlerinin MDİ faaliyetlerinde kullanılan titreşim analizi tekniklerinin incelenmesini yapmıştır.

1.7.3.2. Akustik Analiz ile MDİ

Avantajları nedeniyle kestirimci ve önleyici bakım faaliyetlerinde akustik emisyon sinyaline dayalı MDİ tekniklerinin kullanılması son yıllarda giderek artmaktadır. Li ve He [172] akustik emisyonla dayalı ampirik mod ayrıştırma tekniğini kullanarak dönel makinelerde arızaların tespit edilmesi için bir metodoloji sunmuştur. Li ve arkadaşları [173] akustik emisyon (AE) sensörleri ile redüktörlerde meydana gelen arızanın konumunu tespit etmiştir. Gu ve arkadaşları [174] ayrık dalgacık dönüşümüne dayalı zarf analizi ile akustik emisyon sinyallerinin işlenmesi için bir yöntem önermiş ve bu yöntemi eksen kaçıklığı ve rulman arızalarının gözlenmesi ve erkenden tespit edilmesi amacıyla kullanmıştır. Akustik emisyon ve titreşim sensörleri kullanarak dişli kutularında arızaların tespitine yönelik karşılaştırmalı çalışmalar da yapılmıştır [175, 176, 177]. Bunun yanında akustik emisyon tekniklerini kullanarak dişliler üzerinde yeni oluşmaya başlayan arızaların tespit edildiği başka çalışmalar da vardır [178, 179]. Amarnath ve Krishna [180] dişliler ve makaralı rulmanlarda arıza tespiti için akustik sinyallerin ampirik mod ayrıştırmasını yapmıştır. Amarnath ve Krishna [181], bir diğer çalışmalarında ampirik mod ayrıştırma tabanlı istatistiksel parametre analizini kullanılarak, titreşim ve akustik sinyaller aracılığıyla helisel dişli çarklarda bölgesel arıza tespiti yapmıştır. Loutas ve arkadaşları [182] yapay olarak oluşturulmuş çatlaklara sahip tek kademeli bir dişli kutusunda titreşim ve akustik sinyallerin çevrimiçi olarak ölçülmesi ile arıza tespiti yapmıştır. Loutas ve arkadaşları [183] bir diğer çalışmalarında dönel makinelerde daha etkin bir MDİ için titreşim sinyali, akustik emisyon ve yağ birikintilerinin çevrimiçi izlenmesi ile kombine bir şekilde kullanımı üzerine çalışmıştır. Tan ve arkadaşları [184] ise düz dişliler için akustik emisyon, titreşim ve spektrometrik yağ analizinin arıza tespit kabiliyetleri üzerine karşılaştırmalı, deneysel bir çalışma yapmıştır. Jena ve Panigrahi [185] titreşim ve akustik sinyalleri kullanarak dişli kutularında otomatik olarak arızanın yerinin tespiti üzerine çalışmıştır. Delvecchio ve arkadaşları [186] içten yanmalı motorların vibro-akustik durum izlemesi ile ilgili hâlihazırda mevcut olan tekniklerin eleştirel bir değerlendirmesini

yapmıştır. Glowacz A. ve Glowacz Z. [187] akustik sinyaller kullanarak tek fazlı asenkron bir motorda stator arızalarının tespitini yapmıştır. Gao ve arkadaşları [188] da düşük hızlı ve ağır hizmet tipi dişli çarkların arızalarının tespitinde akustik emisyon tekniklerinin kullanılmasının incelemesini yapmıştır.

1.7.3.3. Kızılötesi Termografi ile MDİ

Kızılötesi termografi yaygın olarak kullanılan bir MDİ tekniğidir. Bagavathiappan ve arkadaşları [155] kestirimci ve önleyici bakım faaliyetlerinde kızılötesi termografinin kullanılması ile ilgili bir inceleme ve gözden geçirme çalışması yapmıştır. Leemans ve arkadaşları [189] dönel makinelerde çevrimiçi MDİ için kızılötesi termografinin performansını değerlendirmiştir. Moussa [190] kızılötesi termografi yardımı ile rulmanlarda arıza tespiti yapmıştır. Seo ve arkadaşları [191] da dinamik yükleme koşulları altındaki rulmanlarda oluşan arızaların tespiti için kızılötesi termografi tekniklerini kullanmıştır. Kim ve arkadaşları [192] ise kızılötesi termografi kullanarak rulmanlarda gerçek zamanlı bir hata izleme ve tespit metodu üzerinde çalışmıştır. Kızılötesi termografi rüzgâr türbinlerinin testinde ve kestirimci bakım faaliyetlerinde kullanılmaktadır [193, 194]. Bunların dışında elektrik makinelerinin ve elektronik cihazların arızalarının tespiti, kalite kontrolü vb. faaliyetlerde de kullanılmaktadır. Jadin ve Taib [195] kızılötesi termografi ile elektrikli ekipmanların güvenilirliğinin teşhis edilmesindeki son gelişmeleri değerlendirmiştir.

1.7.3.4. SVR ile İlgili Yapılmış Çalışmalar

Titreşim analizi, akustik analiz, termal görüntü analizi veya aşınma kalıntısı analizi gibi MDİ tekniklerinden biri veya birkaçı beraber sonsuz vidalı redüktörlerin kestirimci ve önleyici bakım faaliyetlerine yönelik çalışmalarda kullanılmıştır.

Peng ve Kessissoglou [196] titreşim analizi ve aşınma sonucu sonsuz vida mekanizmasının yağı içerisinde biriken kalıntıları analiz ederek arıza tespiti yapmak için birleşik bir yaklaşım geliştirdiler. SVR içeren deney sistemlerinden elde ettikleri verilerin analizi sonucunda, kullandıkları tekniklerin ayrı ayrı kullanılması durumunda arızaların sadece %40'ının tespit edebileceğini gözlemlediler. Her iki metodun kombinasyonu

sonucunda ise daha iyi ve güvenilir sonuçlara ulaşıldı. Ayrıca normal yağlama, eksik yağlama ve kirli yağ ile yağlama şeklinde üç farklı yağlama koşulunu da analiz ettiler.

Peng ve arkadaşları [197] bir diğer çalışmalarında SVR için titreşim analizi ve aşınma kalıntısı analizi arasındaki korelasyonu araştırdılar. Bunun için farklı yağlayıcılar ve farklı kontamine parçacıklar kullanmak suretiyle farklı yağlama koşulları altında bir dizi deneysel çalışma yaptıktan sonra titreşim verilerini ve yağ numunelerini topladılar ve sonuçları karşılaştırdılar.

Elforjani ve arkadaşları [198] sonsuz vida mekanizmasında meydana gelen arızaları tespit edebilmek için bir deney sistemi geliştirdiler. Aynı arıza için akustik emisyon ve titreşim analizi tekniklerini kullanarak incelemelerini yaptılar. Sonuçlar karşılaştırıldığında, arızanın tespit edilmesi kabiliyeti açısından akustik emisyon analizinin titreşim analizinden daha iyi sonuç verdiğini gözlemlediler.

Elesha ve arkadaşları [199] sonsuz vida mekanizmalarında meydana gelen yüzey yorgunluğu (pitting) aşınmasını titreşim analizi ile tespit etmeye çalışmıştır. Sonsuz vida mekanizmasındaki sürekli kayma hareketinden dolayı titreşim analizinin arıza tespiti amacıyla kullanılması göreceli olarak zordur. Bu nedenle, verinin normal dağılıp dağılmadığına ilişkin ipuçlarına sahip göstergelerden biri olan basıklık ve *RMS* değerleri hesaplanmıştır. Ayrıca özel basıklık, titreşim zarfı ve istatistiksel bir gösterge olan *FM4* parametrelerinin hesaplanmasıyla çalışmalarını geliştirdiler. Deneysel yürüyen merdivenlerde kullanılan üç adet SVR üzerinde çalıştılar. Basıklığın üç SVR arasında hiç bir fark göstermediğini buldular. *RMS* ve *FM4*'ün ise arızalı redüktör için daha yüksek değerler gösterdiğini tespit ettiler. Ayrıca üç yönde yapılan ölçümler sonucunda en hassas ölçüm yönünün dişlilerin kavrama yönü olduğunu, zarf ve özel basıklık ile redüktördeki arızanın tespit edilebileceğini ortaya koydular. Özel basıklığın sonsuz vida mekanizması için en ideal teşhis yöntemi olduğunu ifade ettiler.

Vähöja ve arkadaşları [200] yağ analizi ve titreşim analizini kullanarak SVR'lerde oluşan arızaları tespit etmeye çalışmış ve aşınma sonucu yağın içinde biriken kalıntıların analizi ile titreşim analizinin kombinasyonunun arıza tespitinde en iyi sonuçları verdiğini göstermiştir. Buna göre dişli arızası 3-2000 Hz frekans aralığında gözlemlenebilir. *RMS* ve istatistiksel bir gösterge olan *X4* değeri de dişli kutusunun arızasını gösterebilir. Basıklık 3-1000 Hz frekans aralığında sonsuz vida mekanizması için en hassas teşhis özelliğine sahiptir. Ayrıca aşınma kalıntılarının analizi için de yağ içindeki bakır ve demir konsantrasyonunun ölçülmesi yeterlidir. Bunun yanında sinyalin uzun süre ölçülmesinin ve

titreşim ölçümünün dişlilerin birbirini kavradığı noktaya en yakın mesafeden olmasının faydalı olduğunu ortaya koymuşlardır.

Ismon ve arkadaşları [201] yaptıkları çalışmada sonsuz vida mekanizması üzerinde hem titreşim analizi hem de sıcaklık değişimi ile ilgili incelemelere yer vermiştir. Üç farklı viskoziteye sahip yağlayıcı türü kullanılarak, farklı çalışma hızlarındaki titreşim sinyalleri ve sıcaklık değişimleri incelenmiştir. Çalışmanın sonucunda daha yüksek viskoziteli yağın titreşim genliğine daha az katkıda bulunduğu gözlenmekle beraber sonsuz vida mekanizması ile ilgili olarak yağlama yağının viskozitesi, titreşim seviyesi ve sıcaklık profili arasında bir korelasyon olduğu gözlenmiştir.

Wakar ve Demetgül [202] yapmış oldukları çalışmada sonsuz vida mekanizması içeren bir deney sistemi üzerinde farklı çalışma koşulları altında testler gerçekleştirmişlerdir. Bu çalışmada sonsuz vida mekanizmasının titreşim ve akustik emisyon sinyalleri normal ve arızalı durumlar, farklı hız ve yağ seviyeleri için incelenmiştir. Toplanan veriler filtrelendikten sonra hızlı Fourier dönüşümü (*FFT*) uygulanmıştır. Ayrıca tüm bu şartlardaki sıcaklık modellerini gözlemlemek için termal bir kamera da kullanılmıştır. Verilerin sınıflandırılması için çok katmanlı bir YSA geliştirilmiştir. Geliştirilen YSA modeli ile hız ve yağ seviyesi için öngörüle bulunmak mümkündür.

Ümütlü ve arkadaşları [203] YSA kullanarak bir SVR'de bölgesel yüzey yorgunluğu arızasının erken tespitine odaklanmıştır. Deney sisteminden elde edilen titreşim verileri çok sınıflı tanıma amaçlı kullanılan yapay sinir ağına girdi olarak kullanılmıştır.

Hızarcı ve arkadaşları [204] ise SVR'ler için akıllı bir MDİ sistemi geliştirmiştir. Bir mikrodenetleyici ile kontrol edilen sistem veri toplama, çeşitli titreşim analiz teknikleri, arıza tespiti ve görselleştirme adımlarından oluşmaktadır. Geliştirilen bu sistem ile sinyal işleme algoritmalarını kullanarak SVR'lerde arızaların tespitini yapmışlardır.

1.8. Tez Çalışmasının Amacı ve Literatüre Katkıları

Titreşim analizi, akustik analiz, termal görüntü analizi veya aşınma kalıntısı analizi gibi MDİ tekniklerinden biri veya birkaçı SVR'lerin kestirimci ve önleyici bakım faaliyetlerine yönelik literatürdeki çalışmalarda kullanılmıştır. Ancak yapılan bu çalışmalarda farklı arıza tiplerine (yüzey yorgunluğu, aşınma, kırılma vb.) sahip SVR'ler

için kestirimci ve önleyici bakıma yönelik titreşim analizi, akustik analiz ve termal görüntü analizinin birlikte kullanıldığı ve sonuçlarının değerlendirildiği bir çalışmaya rastlanmamıştır. Öte yandan, çalışma hızı ve yükü sistemin çalışması esnasında ortaya çıkan titreşimleri, ses şiddetini ve redüktör bileşenlerinin sıcaklığını doğrudan etkilemektedir. Bu nedenle mevcut yaklaşımların dinamik çalışma şartları göz önüne alınarak daha sistematik ve bütüncül olarak uygulanması gerekmektedir.

Bu tez çalışmasında SVR'lerin farklı yük ve hız şartları altında çalışmasını sağlayabilen bir deney sistemi geliştirilmiştir. Farklı arıza türlerine sahip SVR'lerden farklı çalışma koşulları altında toplanan titreşim ve ses sinyalleri hem zaman hem de frekans bölgesinde analiz edilerek öznitelik hesaplamaları yapılmıştır. SVR'den ayrıca termal kamera görüntüleri de toplanarak öznitelik hesapları yapılmıştır.

Titreşim, ses ve termal görüntü verilerinin kullanılmasıyla kurulan YSA, DVM, k-NN, ANFIS ve derin öğrenme yaklaşımları ile beraber redüktörlerin arızaları sınıflandırılmıştır. Hem arızanın tespiti hem de arıza türünün sınıflandırılmasına yönelik kurulan farklı YZ yaklaşımlarına ait sonuçlar sınıflandırma performansı ve doğruluğu açısından karşılaştırılmıştır.

1.9. Özet

Teknolojik ilerlemelere bağlı olarak endüstride uygulanan kestirimci ve önleyici bakım faaliyetleri de gelişmektedir. Bu faaliyetlerin en önemli adımlarından biri çalışan makinenin durdurulmadan verilerin toplanması, incelenmesi ve yorumlanmasıdır.

Sanayinin birçok yerinde kullanılan sonsuz vidalı redüktörler (SVR) çalışma prensiplerinden ve konstrüksiyonlarından dolayı sık sık arızalanan sistemlerdir. Bu yüzden bu redüktörlerin kestirimci ve önleyici bakım faaliyetleri diğer redüktör tiplerine göre daha dikkatli bir şekilde düzenlenmelidir. Söz konusu kestirimci bakım faaliyetlerinin en önemli adımı titreşime, akustik emisyonu ya da termal kamera görüntüsüne dayalı olarak durumunun izlenmesidir. Doğru durum izleme teknikleri ile takip edilen SVR'lerde meydana gelebilecek arızalar önceden tespit edilebilir ve bu doğrultuda gerekli önlemler alınabilir. Bunun sonucu olarak redüktörün çalıştığı makine veya tesisin daha verimli ve üretimin kesintisiz olacağı açıktır.

SVR'ler sonsuz vida ve çark olmak üzere iki farklı dişliden oluşan bir mekanizma içerirler. Bu redüktörler hafif ve kompakt olmaları nedeniyle endüstride sıklıkla

kullanılmaktadırlar. Aşınma, yüzey yorgunluğu (pitting) ve diş kırılması (plastik deformasyon) SVR'lerin içerdiği mekanizmalarda görülen arızaların en temel türleridir.

SVR'ler ile ilgili kestirimci ve önleyici bakım faaliyetlerinin en önemli bileşeni, durumu izlenen sistemden sinyallerin elde edilmesi ve değerlendirilmesidir. SVR'lerden toplanan sinyaller titreşim, ses ve sıcaklık gibi zamanla değişen ve bilgi taşıyan fiziksel fenomenlerdir. Bakım planı veya arızaları önlemeye yönelik alınacak tedbirler, bu sinyallerin değerlendirilmesi sonucu karara bağlanır.

Makinelerde durum izleme (MDİ) çalışmalarında kullanılan sinyaller deterministik ve random olarak iki ana kategoriye ayrılabilir. Bu sinyallerin işlenmesi veri toplamayı, toplanan veriyi işlemeyi ve yorumlamayı kapsayan bir süreçtir. Analog ve dijital olmak üzere iki tür sinyal işleme tekniği vardır.

Kullanım alanlarından biri makinelerde arızaların tespit edilmesi ve sınıflandırılması olan yapay zekâ (YZ), esasen insana ait akıllı ve karmaşık davranışları taklit edip bu davranışları otomasyon teknolojileri alanında uygulamaya çalışır. YZ çalışmalarında mantıksal işlemler, arama, muhakeme, örüntü tanıma, öğrenme, sezme, temsil ve gösterim, planlama veya başka türde bir sonuç çıkarma biçimini gerçekleştirmek için bilgisayar bilimlerinin teorik ve pratik ilkeleri etkin bir biçimde kullanılır. YZ türlerinden birisi olan makine öğrenmesi ise danışmanlı ve danışmansız olmak üzere iki guruba ayrılır. Bunlardan ilki olan danışmanlı öğrenme bir modeli, bilinen giriş ve çıkış verileri üzerinden gelecekteki çıktıları tahmin edebilmesi için eğitir. İkinci tür olan danışmansız öğrenme ise giriş verilerinde gizli örüntüler veya içsel yapılar bulmaya çalışır. İleri düzey bir makine öğrenmesi türü derin öğrenmede ise, bir model, herhangi bir öznitelik kullanmadan sınıflandırma görevini gerçekleştirmeyi doğrudan sinyallerden öğrenir.

MDİ, kestirimci ve önleyici bakımın en önemli bileşenini oluşturur ve operasyon sırasında makinelerin mevcut durumlarını görüntüleme ve gelecekteki durumlarını tahmin etme stratejilerine dayanır. Uygulamada titreşime dayalı, akustik ve termal kamera ile durum izleme başta olmak üzere birçok MDİ tekniği kullanılmaktadır. Motor akımı sinyal analizi, aşınma kalıntısı analizi, Eddy akımı testi, ultrasonik test, radyografi, sıvı panetrasyon testi ve manyetik parçacık tekniği diğer MDİ teknikleri olarak sıralanabilir.

Durum izleme çalışmalarından ilki olan deterministik yaklaşım bilgiye dayanır. Beyaz kutu yaklaşımı olarak da bilinen bu yaklaşım belirli bir matematiksel modeli baz alarak uygulanır. İkinci durum izleme yaklaşımı ise stokastik yaklaşım olarak

bilinmektedir. Stokastik yaklaşım türü veriye dayalı olmakla beraber siyah kutu yaklaşımı olarak da bilinmektedir. Stokastik yaklaşımlarda, prosesi temsil eden bir model oluşturmak amacıyla ölçümü yapılan süreç verileri kullanılır. Model, prosese ait giriş ve çıkış verileri kullanılarak geliştirilir. Bu yaklaşımlar çoğunlukla istatistiksel hesaplara veya yapay zekâ tabanlı tekniklere dayanır. İstatistiksel ve YZ tabanlı teknikler durum veya proses izleme ve arıza tespiti amacıyla endüstriyel uygulamalarda yaygın kullanım imkanı bulmuştur. Birçok YZ tekniği makinelerde arıza tespiti ve sınıflandırılması amacıyla da kullanılmaktadır. Yapay sinir ağları (YSA), destek vektör makinesi (DVM), bulanık mantık, genetik algoritma (GA), derin öğrenme ve hibrit teknikler başta olmak üzere birçok YZ türü kestirimci ve önleyici bakım uygulamalarında başarıyla kullanılmıştır.




2. YAPILAN ÇALIŞMALAR

2.1. Deney Sistemi

Bu doktora tez çalışmasında kullanılmak amacıyla tasarlanan deney düzeneği Çaykur 100. Yıl Çay Paketleme Fabrikası Müdürlüğünün izni ile Çaykur Fabrika atölyelerinde üretilmiş ve monte edilmiştir. Deney sistemi; elektrik kumanda panosu, 3 fazlı bir asenkron motora bağlı tek kademeli bir SVR ve yükleme cihazından oluşmaktadır. Ayrıca yükleme cihazı ile SVR arasında elastik elemanlı yıldız tipi bir kaplin bulunmaktadır.


2.1.1. Mekanik Bileşenler

Şekil 2.1' de deney sisteminin ana bileşenleri görülmektedir. Yükleme sistemi, motor ve redüktör civata bağlantılarıyla 40x40 mm kare profil ve 5 mm çelik sacdan imal edilmiş platforma (1) sabitlenmiştir. Deney sisteminde Volt marka, 0.55 kW, 1365 d/dk değerlerine sahip, 3 fazlı bir asenkron elektrik motoru (2) kullanılmıştır. Sabit stator ve dönen rotor olmak üzere iki temel bileşenden oluşan bu elektrik motoru, doğrudan şebekeden yol verilerek veya değişken hız sürücüsü ile beslenmek suretiyle kullanılabilir. Asenkron motor çevrim oranı $i=20$ olan Özteknin marka bir SVR'ye (3) mekanik olarak doğrudan bağlıdır. Deney sisteminde kullanılan SVR, giriş ve çıkış milleri arasındaki açının 90° olduğu sonsuz vida ve dişli kademesinden oluşan bir redüktördür. Fosforlu bronzdan imal edilmiş çarkla eş çalışan sertleştirilmiş ve taşlanmış çelik malzemedan üretilmiş vidalı mil uzun ömürlü ve verimli bir çalışma sağlamaktadır. SVR gövdesi alüminyum malzemedan metal enjeksiyon tekniği ile imal edilmiştir, bu sayede bir çok farklı türde montaj uygulamasına imkan tanır. SVR, platforma sökülebilir civatalar (4) ile monte edilmiştir. Bu civata bağlantıları sayesinde farklı arızalara sahip redüktörler ile deney yapmak mümkün hale gelmiştir. SVR çıkış mili ile yükleme sistemi giriş mili arasında 80 mm çapında, 30 Nm momente kadar yük taşıyabilen elastik elemanlı bir yıldız kaplin (5) mevcuttur. Bu kaplin karşılıklı iki adet erkek parçanın, bir adet yıldız şeklinde elastik ara parça ile birleştirilmesinden oluşmakta ve böylece SVR ile yükleme sistemi (6) arasındaki güç ve hareket iletiminin düzgün ve sürekli olmasını sağlamaktadır.




Şekil 2.1. Deney sisteminin ana bileşenleri


Deney sisteminde kullanılan yüklem üitesi (6) elektromanyetik tozlu bir fren/kavrama elemanıdır. 24 V doğru akımla çalışan ve 28 W bobin gücüne sahip EMF marka elektromanyetik yüklem sistemi 65 Nm torka kadar fren veya kavrama işlevini yerine getirebilmektedir. Elektromanyetik tozlu yüklem sistemi, sürtünmesiz bir şekilde çalışmakta ve elektronik gerilim kontrolü yardımıyla istenilen moment büyüklüğüne kademesiz geçiş yapabilmektedir. Yüklem sistemi, yapısı gereği çalışma esnasında ısınmaktadır. Bu nedenle 200x165 mm ölçülerinde salyangoz ve 50x80 mm ölçülerinde hava giriş kanalına sahip, 220 V monofaze elektrikle çalışan radyal bir fan (7), yüklem sisteminin sıcaklığı belirli bir seviyenin üzerine çıktığında devreye girerek sistemi aşırı ısınmaktan ve bozulmaktan korumaktadır. Radyal fan, yüklem üitesi ve elektrik motoru kablo kanallarına yerleştirilmiş özel kablolar aracılığıyla tüm sistemin kontrol edildiği 305x395 mm ölçülerindeki kumanda panosuna (8) bağlıdır. Şekil 2.2’ de motor ve redüktör çiftinin ölçüleri [205], Şekil 2.3’te yıldız kaplinin ölçüleri ve içyapısı [206], Şekil 2.4’te yüklem üitesinin ölçüleri ve içyapısı [207], Şekil 2.5’te soğutma fanı ve ölçüleri [208], Şekil 2.6’da ise deney sisteminin genel ölçüleri görülmektedir.




Şekil 2.2. Motor ve SVR ölçüleri (mm) [205].




Şekil 2.3. Kaplin ölçüleri (mm) ve içyapısı [206].



Şekil 2.4. Yükleme ünitesi ölçüleri (mm) ve içyapısı [207].



Şekil 2.5. Soğutma fanı ve ölçüleri (mm) [208].




Şekil 2.6. Deney düzeneğine ait genel ölçüler (mm)

2.1.2. Elektrik Kumanda Panosu

Deneyisel çalışmaları doğru bir şekilde gerçekleştirebilmek ve elde edilen sonuçları tutarlı bir biçimde karşılaştırabilmek için asenkron motorun dolayısıyla redüktörün çıkış hızının ve elektromanyetik fren yükünün sağlıklı bir şekilde kontrol edilmesi gerekmektedir. Bu amaç doğrultusunda elektrik kumanda panosunun tasarımı ve montajı yapılmıştır.


Deney sisteminde motor ve redüktör çıkış hızının kontrol edilmesi için kullanılan hız kontrol cihazı 0.75 kW gücünde, 220 V monofaze elektrikle çalışan Teco marka bir AC motor sürücüsüdür ve pano kapağına yerleştirilmiş dijital bir panel üzerinden ayarları yapılmaktadır (Şekil 2.7). Söz konusu hız kontrol cihazı asenkron motoru besleyen ve motor çıkış milinin istenilen hızda dönmesini sağlayan elektronik bir sürücü devresi içermektedir. Motor hızının kumanda edilmesi, motoru besleyen elektriğin geriliminin ve frekansının değiştirilmesiyle gerçekleştirilmektedir.



Şekil 2.7. AC sürücü ve ölçüleri (mm) [209].

Deneysel çalışmalarda, SVR'yi yüklemek amacıyla 0-24 V arası DC gerilim ile çalıştırılabilen elektromanyetik tozlu bir fren/kavrama sistemi [Şekil 2.1 (6)] kullanılmaktadır. Yükleme sisteminin beslenmesi, elektrik panosuna yerleştirilmiş Edi marka, 0.2 kW güce, 220 V giriş gerilimine ve çoklu çıkışa sahip, deney sistemi için özel olarak sipariş edilmiş bir transformatör ile sağlanmaktadır. Yükleme transformatörü 1 adet giriş ve 4 adet çıkış bağlantısına sahiptir. Transformatörün her bir çıkışı Opaş marka 380 V, 16 A 5 kademeli monofaze bir şaltere bağlıdır. Yükleme sistemine gidecek elektrik enerjisi dolayısıyla elektromanyetik tozlu fren/kavrama milindeki sıkma momenti bu kademeli şalter ile kumanda edilmektedir.


Fren/kavrama milindeki sıkma momenti, cihazın beslendiği gerilim (veya DC akım) ile doğru orantılıdır. Bu nedenle, gerilimin değiştirilmesi ile redüktörün farklı yükler altında çalıştırılması mümkün olmaktadır. Yükleme oranının değiştirilmesi Şekil 2.8’de görülen kademeli şalterin bağlantı şemasına göre yapılmaktadır [210]. Elektromanyetik tozlu fren/kavrama sistemi için uygulanan DC gerilim ve çekilen akıma bağlı olarak milde meydana gelen sıkma momenti neredeyse doğrusal olarak değişir ve çok hassas bir şekilde kontrol edilebilir. Bu nedenle bu cihazlar yük simülasyonlarında sıklıkla kullanılmaktadırlar [207, 211, 212].



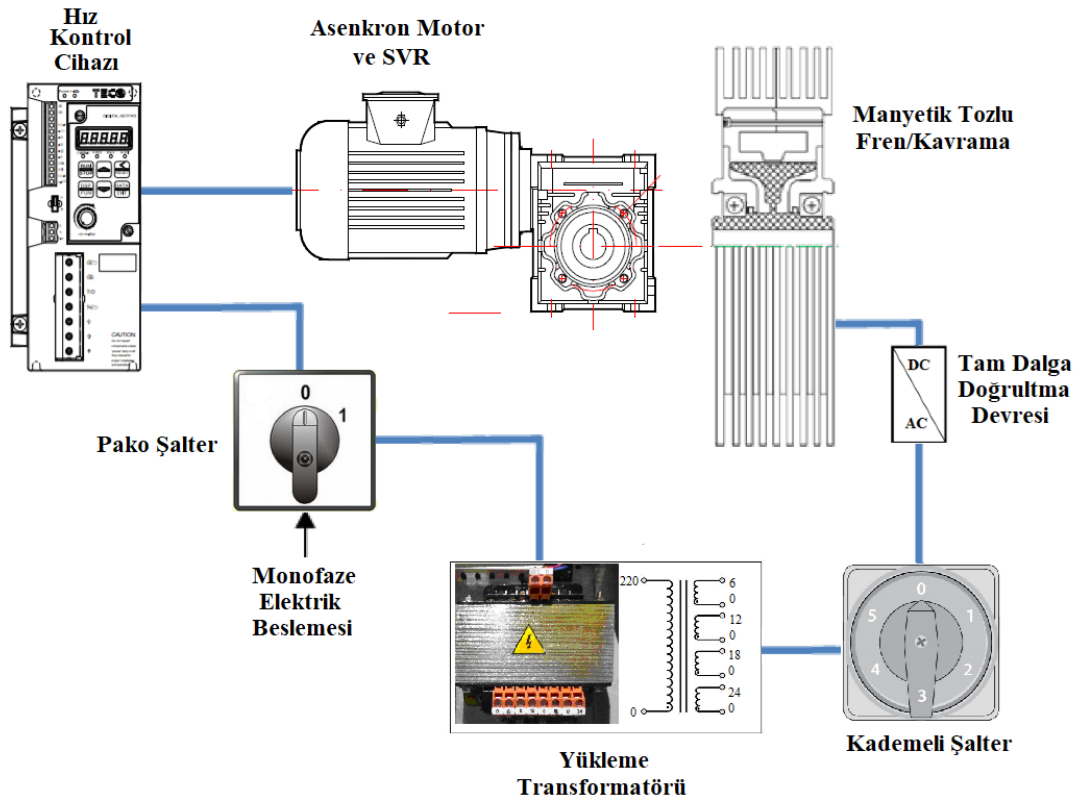
Şekil 2.8. 5 Kademeli şalter bağlantı şeması [210].

Şekil 2.9’da tozlu fren/kavrama sistemine uygulanan gerilim ve sıkma momenti arasındaki ilişki görülmektedir [211]. Yükleme sisteminin standart çalışma aralığı 0 – 24 V DC olduğundan [207], söz konusu gerilim-sıkma momenti ilişkisine istinaden redüktör farklı oranlardaki yükler ile yüklenebilir. Buna göre %25 yükleme durumu için 6 V DC, %50 yükleme durumu için 12 V DC, %75 yükleme durumu için 18 V DC ve %100 tam yükleme durumu için de 24 V DC gerilim ile fren/kavrama sistemi beslenmektedir.

Yükleme sistemini besleyen transformatör çıkışlarından alınan ve kademeli şalter ile kumanda edilerek fren/kavrama sistemine aktarılan elektrik AC türden olduğu için DC akıma dönüştürülmesi gerekmektedir. Bu amaçla kademeli şalter ve fren/kavrama sistemi arasında TT-T-ECHNI-C marka, KBPC3510 model, 35 A, 1000 V, köprü tipi, silikon bir tam dalga doğrultma devresi kullanılmıştır. Şekil 2.10’da hız kontrol ve yükleme kumanda sisteminin genel görünüşü görülmektedir.



Şekil 2.9. Yükleme sistemi için gerilim ve sıkma momenti ilişkisi [211].



Şekil 2.10. Hız kontrol ve yükleme kumanda sisteminin genel görünüşü

2.1.3. Ölçüm Sistemi

Deneyleerde redüktör çıkış milinin devir sayısı bir dijital takometre/sayıcı ve bir PNP yakınlık sensörü ile, yükleme sisteminin beslendiği gerilim miktarı ise programlanabilir bir AC/DC voltmetre ile ölçülmektedir. Bunun yanında redüktör üzerine bağlı bir ivmeölçer vasıtasıyla titreşim verileri, bir mikrofon aracılığıyla ses verileri ve son olarak bir kızılötesi kamera ile termal görüntüler elde edilmektedir.

2.1.3.1. Hız Ölçümü

Hız ölçümü için ENDA marka ECH7700 serisi dijital bir takometre/sayıcı (Şekil 2.11. a) ve PNP yakınlık sensörü (Şekil 2.11. b) kullanılmıştır.



a)



b)

Şekil 2.11. Dijital takometre/sayıcı (a) ve PNP yakınlık sensörü (b)

Programlanabilme imkanına sahip olan dijital takometre/sayıcı, 2x6 haneli göstergeye sahip olup periyot, zaman farkı, atım zamanı, devir sayısı ve hız ölçebilmektedir. Ayrıca giriş işareti 0.000001 ile 99.9999 arasında istenen bir değer ile çarpılarak kalibrasyon yapılmaktadır. Yakınlık sensörü tipi de PNP veya NPN olarak seçilebilmektedir [213].

2.1.3.2. Gerilim Ölçümü

Yükleme sistemi 0 – 24 V aralığında DC gerilim ile çalışmaktadır. Bu nedenle redüktör %0 yüklenirken 0 V, %25 yüklenirken 6 V, %50 yüklenirken 12 V, %75 yüklenirken 18 V ve %100 yüklenirken 24 V DC besleme gerilimi, ENDA marka EPV 242 serisi bir programlanabilir AC/DC voltmetre aracılığıyla ölçülmektedir.

2.1.3.3. Titreşim Ölçümü


Titreşim ölçümü için yaygın olarak kullanılan sensörler, piezo-elektrik ivmeölçerlerdir. Geniş bir frekans aralığında çalışabilen bu algılayıcılar, rulman, mil, dişli kutusu vb. farklı kaynakların ürettiği titreşimleri ölçmek için kullanılırlar. Piezo-elektrik ivmeölçerler, arızaların tespit edilmesi ve sınıflandırılması amacıyla düşük genlikli sinyalleri ölçmek için yüksek duyarlılığa, iyi bir ölçüm kararlılığına ve doğrusallığa sahiptirler. Ayrıca boyutlarının nispeten küçük olması nedeniyle montaj işlemleri kolaydır [6, 215].

Yapılan deneysel çalışmalarda PCB marka ICP® tipi sensör kullanılmıştır (Şekil 2.12. b). Söz konusu ivmeölçer 352C03 model olup algılayıcı elemanı seramik malzemeden yapılmıştır. Bunun yanında $1.02 \text{ mV}/(\text{m/s}^2)$ ($\pm 10\%$) duyarlılığa sahiptir ve $\pm 4900 \text{ m/s}^2$ genlik ya da $0.5\text{-}10000 \text{ Hz}$ ($\pm 5\%$) frekans aralığında ölçüm yapmaya imkân tanımaktadır. Ayrıca geniş bant çözünürlüğü $0.005 \text{ m/s}^2 \text{ RMS}$ 'dir. Tablo 2.1'de ivmeölçerin diğer bazı özellikleri görülmektedir [216].

Tablo 2.1. PCB marka 352C03 model ivmeölçerin bazı özellikleri [216].

Doğrusalsızlık (non-lineerlik)	$\leq 1 \%$
Enine duyarlılık	$\leq 5 \%$
Spektral gürültü (1 Hz)	$1080 (\mu\text{m/s}^2)/\sqrt{\text{Hz}}$
Spektral gürültü (10 Hz)	$245 (\mu\text{m/s}^2)/\sqrt{\text{Hz}}$
Spektral gürültü (100 Hz)	$78 (\mu\text{m/s}^2)/\sqrt{\text{Hz}}$
Spektral gürültü (1 kHz)	$39 (\mu\text{m/s}^2)/\sqrt{\text{Hz}}$


ICP® ivmeölçerler için gerekli olan dönüşümün ve iletimin gerçekleştirilebilmesi amacıyla çeşitli mekanik tasarımlar geliştirilmiştir. Deneysel çalışmalarda kullanılan ICP® tipi ivmeölçerlerin iç yapısı Şekil 2.12. a'da görülmektedir. Bu ivmeölçer, sismik bir kütleye bağlı seramik algılama kristallerinden meydana gelmiştir. Buna göre bir ön yüklem halkası veya saplama, rijit bir yapı oluşturmak ve lineer davranışı sağlamak için algılama elemanı takımına bir kuvvet uygular. İvmelenme esnasında, sismik kütle algılayıcı kristaller üzerinde mekanik bir gerilmeye neden olur. Bu gerilme de orantılı bir şekilde elektriksel çıkış geriliminin miktarını belirler. Çıkış gerilimi elektrotlar üzerinde toplanır ve ICP® içindeki mikro-elektronik devreye iletilir [215].



Şekil 2.12. PCB marka ICP® tipi ivmeölçer [215, 216].

ICP® tipi ivmeölçerlerin dâhili mikro-elektronik devreleri bir amplifikatör içerir. Bu özellikleri sayesinde ICP® tipine uyumlu bir veri toplama cihazına standart koaksiyel veya iki iletkenli kablo ile doğrudan bağlanabilirler. Bunun yanında bir sabit akım sinyal koşullandırıcısı kullanmak suretiyle diğer veri toplama cihazlarına da bağlanabilirler [217]. Yapılan deneysel çalışmalarda ivmeölçer, ICP® tipi sensörler ile uyumlu olan bir veri toplama cihazına standart koaksiyel kablo ile doğrudan bağlanmıştır.

Literatürde bulunan daha önceki çalışmalara göre, SVR'ler için en hassas titreşim ölçüm yönü dişlilerin kavrama yönüdür [199]. Bu nedenle ivmeölçer, Şekil 2.13 a)'da görüldüğü gibi redüktörün üst kısmına özel bir adhezif yapıştırıcı kullanılarak yapıştırılmıştır. İvmeölçer ile yapılan ölçümlerin daha sağlıklı, tekrarlanabilir ve tutarlı olması için deney sistemi ayaklarından zemine civatalar ile sabitlenmiştir.




Şekil 2.13. İvmeölçerin redüktör üzerine montajı (a) ve zemin tespit civatası (b)

İvmeölçerin redüktör üzerine montaj şekli, özellikle yüksek frekanslarda ölçüm performansını etkilemektedir. Adhezif yapıştırıcı ile montaj yapıldığı durumlarda, 30-40 kHz frekanstan sonraki ölçümlerinde hata oranı artmaktadır [216].

2.1.3.4. Ses Ölçümü

Mikrofonlar fiziksel bir ortam içerisinde yayılan ses dalgalarını elektrik sinyaline çevirmek için tasarlanmış cihazlardır. Ses ölçümü için genelde piezo-elektrik veya kapasitif mikrofonlar kullanılmaktadır. Deneysel çalışmalarda ses ölçümü için kapasitif mikrofon tercih edilmiştir (Şekil 2.14 a).

Şekil 2.14 b'de görüldüğü gibi bir kapasitif mikrofonda ses dalgaları mikrofona çarptığında, diyafram ileriye ve geriye doğru hareket eder. Bu hareket, kapasitans seviyesini değiştirir. Böylece mikrofon elemanına bağlı yüksek yük direncinde küçük voltaj değişiklikleri meydana gelir. Sonuç olarak akustik sinyale göre değişen bir elektrik sinyali üretilerek çıkışa iletilir [219].



Şekil 2.14. Kapasitif mikrofon (a) [218] ve elektrik diyagramı (b) [219].

Deneyisel çalışmalarda kullanılan kapasitif mikrofon Behringer marka, ECM8000 model hassas bir ölçüm mikrofonudur [220]. Bu tür mikrofonların diyaframı ve arka plakası dielektrik yapıdadır. Tablo 2.2’de deney mikrofonunun özellikleri görülmektedir [218].

Tablo 2.2. Behringer ECM8000 mikrofon özellikleri [218].

Tip	Kapasitif, her yöne doğru ölçüm
Direnç	600 Ohm
Duyarlılık	-60 dB
Frekans cevabı	15 Hz – 20 kHz
Bağlantı	Altın kaplama XLR (balanslı bir konnektör türü)
Fantom güç	+15 V +48 V arası

Deneyisel çalışmalarda InnoGear marka, I229 model, 1 kanallı, 48 V, XLR giriş ve çıkış bağlantılarına sahip bir fantom güç ünitesi kullanılmıştır. MDİ çalışmalarında akustik ölçümler yapmak ve redüktör içindeki arızanın net bir şekilde tespit edebilmek için kullanılan mikrofonların konumlandırıldığı yer kritik bir öneme sahiptir. Bu nedenle

mikrofonun ideal duruş konumu belirlenmelidir. Bu çalışmada, redüktör tipi, yükleme oranı, redüktör çıkış hızı vb. ölçümü etkileyebilecek tüm parametreler göz önüne alınarak farklı noktalarda deneme ölçümleri yapılmış ve ideal mikrofon konumu redüktör gövdesine 100 mm mesafede ve yatay doğrultu ile 60° açı yapacak şekilde tespit edilmiştir. Şekil 2.15'te mikrofon konumu ve ses ölçümü görülmektedir.

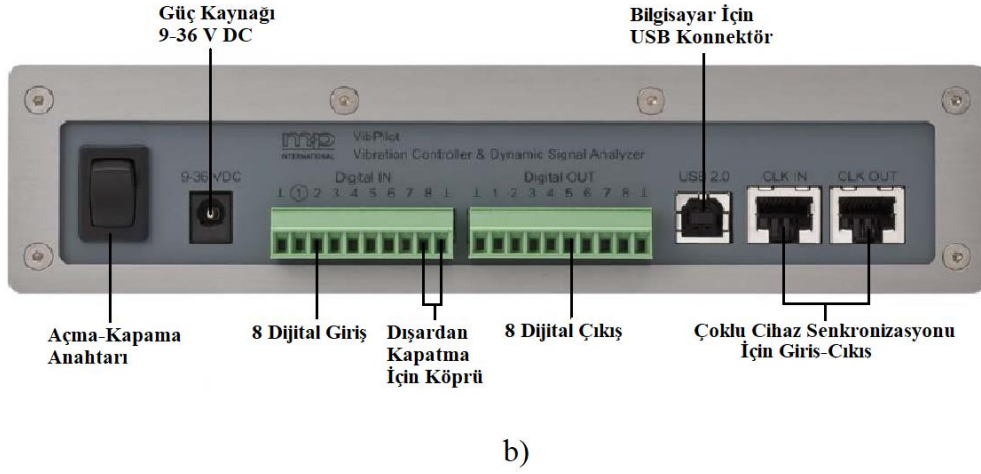
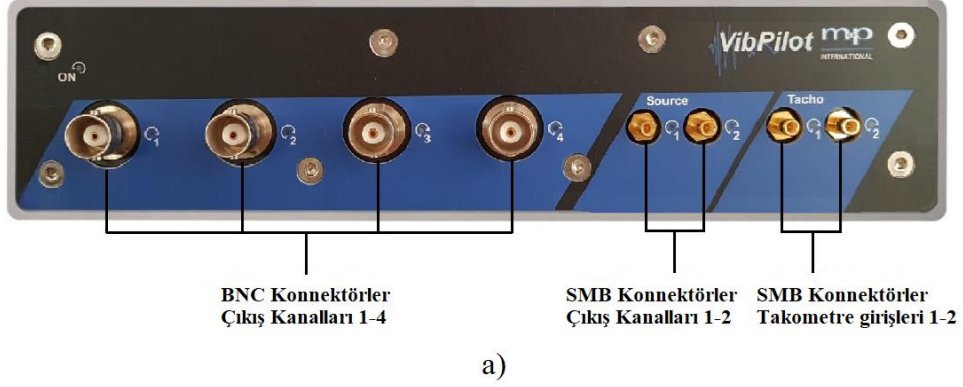


Şekil 2.15. Mikrofon konumu ve ses ölçümü

2.1.3.5. Veri Toplama Sistemi

Deneysel çalışmalarda titreşim ve ses verilerinin toplanması için m+p VibPilot marka bir veri toplama cihazı kullanılmıştır. Bu cihaz, deneylerde ivmeölçer ve mikrofondan gelen verileri toplamak ve izlemek için kullanılan bir dinamik sinyal analizörü ve kontrolördür. Cihaz, sensörlerden gelen analog verileri dijital verilere dönüştürmekte ve duyarlılığı ölçüsünde yeniden ölçeklendirerek bilgisayar aracılığıyla incelenmesine olanak tanımaktadır. m+p VibPilot sinyal analizörü yüksek hassasiyetli ölçüm kabiliyetine sahip bir cihazdır ve sinyal analizinde gerçek zamanlı çalışmaya ve sinyal işlemeye imkan tanıyan yeni nesil tümlşik devre teknolojisine dayanır. m+p VibPilot, 102.4 kHz eşzamanlı örnekleme hızına sahip bir cihaz olup 24 bit Sigma-Delta A/D dönüştürücüler vasıtasıyla 0-40 kHz frekans aralığına kadar ve 120 dB'i geçen sinyal-

gürültü oranı ile hassas ölçümlere imkan tanımaktadır. Şekil 2.16'da dinamik sinyal analizörü/kontrolörün ön (a) ve arka (b) panelleri görülmektedir [221].



Şekil 2.16. m+p VibPilot dinamik sinyal analizörü/kontrolör [221].


Tablo 2.3. m+p VibPilot dinamik sinyal analizörünün bazı teknik özellikleri [221].

Giriş gerilimi aralığı	-/+ 10 V
Aşırı yükleme koruması	10 V maks.
Giriş empedansı	1 M Ω
Bağlantı (eşleşme)	AC/DC, kanal başına değiştirilebilir
ICP güç kaynağı	4 mA, 24V, kanal başına değiştirilebilir

m+p VibPilot cihazının arka tarafında 8 adet dijital giriş ve 8 adet dijital çıkış bağlantısı vardır. 20 W güç tüketen m+p VibPilot cihazı kompakt bir gövdeye sahiptir ve fansız çalıştığı için ürettiği gürültü düzeyi ölçümleri olabildiğince az düzeyde etkilemektedir. Cihaz, dinamik sinyal analizi için bilgisayara kurulan m+p SO Analyzer yazılımı ile birlikte kullanılmaktadır.

2.1.3.6. Termal Kamera

Mutlak sıfır sıcaklığının ($-273\text{ }^{\circ}\text{C}$) üzerinde bir sıcaklığa sahip tüm cisimler kızılötesi ışınım yayarlar. Infrared ya da kızılötesi radyasyon olarak bilinen bu ışınım çeşidi insan gözü ile görülmez; ancak termal kameraların kullanılması ile elektrik sinyallerine çevrilip görülebilir hale getirilebilir. Arızaların tespit edilmesi amacıyla MDİ faaliyetlerinde kullanılan termal kameralar ile makine veya sistemler taranır ve söz konusu donanımların yaydıkları kızılötesi ışınım görünür termal görüntülere dönüştürülür. Bu termal görüntüler ile makine veya sistem sıcaklığının nicel ve/veya nitel analizi yapılır. Analiz sonucunda, eğer varsa termal anormallikler incelenir, arızanın tespiti yapılır ve böylece önleyici tedbirlerin erkenden uygulanmasını mümkün olur [222]. Yapılan deneysel çalışmalarda Testo marka 880 serisi bir termal kamera kullanılmıştır. Şekil 2.17’de Testo 880 termal kamera görülmektedir [223].



Şekil 2.17. Testo 880 termal kamera [223].

Testo 880, Yüzeylelerdeki sıcaklık dağılımını gösteren, görüntü yenileme sıklığı 9 Hz olan, 10 cm yakın mesafeye kadar manüel olarak odaklanabilen, elle taşınabilen ve dâhili bir dijital kameraya sahip termal görüntüleme cihazdır. Cihaz, 160x120 piksel bir detektöre ve 32°x24° açılı bir lense sahip olup termal duyarlılığı 0.1 °C'den küçüktür. Ayrıca içinde 1 GB kapasiteli bir SD veri depolama sistemi mevcuttur ve yaklaşık 800 ila 1000 termal görüntüyü depolayabilmektedir. Tablo 2.4'te termal kameranın diğer teknik özellikleri görülmektedir [223].

Tablo 2.4. Testo 880 termal kameraya ait bazı teknik özellikleri [223].

Geometrik çözünürlük	3.5 mrad
Spektral aralık	0-14 μm
Görüntü ekranı	3.5" LCD, kızılötesi
Renk paleti	8
Sıcaklık aralığı	-20 / +100 °C
Emisyon ayarı	9 ayrı malzeme programı

2.2. Deneylerin Yapılışı

2.2.1. SVR Çıkış Hızları ve Yükleme Oranları

Redüktörler dinamik yükleme koşulları altında çalışırlar. Bu nedenle ölçülen titreşim ya da ses sinyalindeki bir değişikliğin redüktör içindeki bir arızadan kaynaklandığını varsaymak her zaman geçerli bir yargı olmayabilir. Çünkü redüktörün maruz kaldığı yük ve çalışma hızındaki değişimler de ölçülen sinyali etkiler. Örneğin sinyal genliğindeki bir artış, yükleme oranının artmasından ya da belirli bir arızanın meydana gelmesinden kaynaklanabilir. Bu nedenle, redüktör arızalarının doğru bir şekilde tespit edilmesi ve sınıflandırılması için farklı çalışma koşullarının tümü göz önüne alınmalı ve ölçümler bu doğrultuda yapılmalıdır [6].

Literatürde SVR ile ilgili yapılan güncel çalışmalara bakıldığında, ölçümlerin sabit hızda, sabit yükte, hem sabit hız hem de sabit yükte veya hiç yükleme yapılmadan gerçekleştirildiği görülmektedir [198, 199, 201-204].

Bu çalışmada kullanılan sağlam ve farklı tip arızalara sahip deney redüktörleri farklı yük ve hız koşulları altında çalıştırılmış ve her bir koşul için titreşim ve ses ölçümü yapılmıştır. Ayrıca kızılötesi kamera kullanılarak tüm hız ve yükleme şartlarındaki termal görüntüler elde edilmiştir. Tablo 2.5 deneylerin yapıldığı yükleme oranlarını ve redüktör çıkış mili hızlarını göstermektedir.


Tablo 2.5. Deneylerin gerçekleştirildiği redüktör çıkış hızları ve yükleme oranları

	Redüktör Çıkış Hızı (RÇH)	Yükleme Oranları (YO)	Yapılan Ölçümler
Sağlam ve farklı arızalara sahip redüktörler	30 d/dk, 50 d/dk, 70 d/dk	%0, %25, %50, %75 ve %100	Titreşim ölçümü, ses ölçümü ve termal görüntüleme


2.2.2. SVR Numuneleri ve Arıza Simülasyonları

SVR dişlilerinde görülen arızaların en temel biçimleri aşınma, yüzey yorgunluğu (pitting) ve diş kırılmasıdır (plastik deformasyon). Bu üç temel arıza biçimi hem silindirik vida hem de globoid çarkta ortaya çıkmaktadır [12].

Bu çalışmada talaşlı imalat teknikleri kullanılarak SVR dişlilerinde görülen aşınma, yüzey yorgunluğu ve diş kırılması arızalarının yapay olarak taklidi yapılmıştır. Şekil 2.18'de sağlam (S) ve farklı arızalara (A1, A2 ve A3) sahip deney redüktörleri görülmektedir. Burada A1 aşınmış dişlilere sahip redüktör, A2 yüzey yorgunluğuna maruz kalmış dişlilere sahip redüktör ve A3 de dişli kırılmasına maruz kalmış redüktördür. Yapılan deneysel çalışmalarda S, A1, A2 ve A3 redüktörlerinin her biri için farklı çıkış hızlarında ve yükleme oranlarında titreşim ölçümü, ses ölçümü ve termal görüntüleme yapılmış ve veriler toplanmıştır. Şekil 2.19'da ise aşınma (a), yüzey yorgunluğu (b) ve diş kırılması (c) arızasına sahip A1, A2 ve A3 redüktörlerinin dişlileri görülmektedir.




Şekil 2.18. Sağlam ve farklı arızalara sahip deney redüktörleri



Şekil 2.19. Arıza tipleri; a) S, b) A1, c) A2, d) A3

Sağlam ve arızalı redüktörlerin tümü aynı tip ve boyutlarda seçildiği için içerdikleri dişli çarkların geometrik boyutları da aynıdır. Şekil 2.20'de deneysel çalışmalarda kullanılmış sonsuz vida ve dişli çarkın temel boyutları sunulmuştur. Buna göre sonsuz vida orta çapı $d_{or1} = 21 \text{ mm}$, vida çarkının bölüm dairesi çapı $d_2 = 78 \text{ mm}$, ortalama helis açısı $\gamma_{or} = 10^\circ$, normal kavrama açısı $\alpha_n = 20^\circ$, aksel adım $p_x = 6 \text{ mm}$, sonsuz vida dış çapı $d_{b1} = 25 \text{ mm}$, sonsuz vida iç çapı $d_{i1} = 15 \text{ mm}$, sonsuz vida taban derinliği $h_{t1} = 3 \text{ mm}$, sonsuz vida diş başı yüksekliği $h_{b1} = 2 \text{ mm}$, sonsuz vida boyu $b_1 = 32 \text{ mm}$, vida çarkı diş başı yüksekliği $h_{b2} = 2 \text{ mm}$, normal kesitteki adım $p_n = 5.88 \text{ mm}$, toplam adım $p_z = 12 \text{ mm}$, sonsuz vida mil çapı $d_M = 16 \text{ mm}$, vida çarkı büyük diş üstü dairesi çapı $d_{D2} = 82 \text{ mm}$, vida çarkı büyük diş dibi dairesi çapı $d_{b2} = 76 \text{ mm}$, vida çarkı küçük diş dibi dairesi çapı $d_{i2} = 72 \text{ mm}$, vida çarkı genişliği $b_2 = 16 \text{ mm}$, aksel kavrama açısı $\alpha_x = 63.4^\circ$ olarak tespit edilmiştir [4, 9].



Şekil 2.20. Deneylerde kullanılan vida mekanizması numunelerinin ölçüleri [4].

2.3. Bilgisayar Destekli Veri Toplama ve Sinyal İşleme

Deneyleerde elde edilen titreşim, ses ve termal görüntü verileri doğası gereği analogdur ve zamanda süreklilik arz eder. Bu nedenle analog veriler, veri toplama cihazları aracılığıyla dijital hâle dönüştürülmüş ve uygun sinyal işleme yazılımlarıyla bilgisayar ortamında analiz edilmiştir.

Yapılan çalışmalarda ses ve titreşim verilerinin toplanması için kullanılan m+p VibPilot sinyal analizörü ve termal görüntülerin toplanması için kullanılan Testo 880 kızılötesi kamera, analog/dijital (A/D) dönüştürücü özelliğine sahiptir [221, 223].

2.3.1. Titreşim ve Ses Sinyallerinin Analizi

Deneysel çalışmalarda toplanan ve dijital hale dönüştürülen titreşim ve ses sinyallerinin bilgisayar ortamında analiz edilebilmesi için m+p International SO Analyzer programı kullanılmıştır. SO Analyzer programı; ses, titreşim, şok vb. sinyallere ait verilerin gerçek zamanlı analizinde, paylaşılmasında ve standart formatlarda raporlanmasında kullanılan bir yazılımdır [224].

Yapılan deneylerde, ses ve titreşim ölçümlerinin her biri için veri kayıt başlığı belirlenmiş, mikrofon ve ivmeölçer parametreleri ayarlanmış, mühendislik birimleri seçilmiş, ölçüm hassasiyeti ve sinyal giriş tipi (random) belirlenmiştir. Bunun yanında örnekleme oranı, ölçüm için cihazın hazır duruma getirilmesi, ölçümün başlatılması, tetikleme gibi veri toplama ile ilgili parametreler ve ölçüm tipi, ölçüm ortalamalarının alınması, sonuç görüntüleme pencereleri gibi sinyal işleme ile ilgili parametreler SO Analyzer programı ile yapılandırılmıştır [224].

2.3.1.1. Veri Toplama Parametreleri

Örnekleme oranı, blok boyutu ve veri edinim süresi gibi veri toplama parametreleri, frekans bant genişliği, spektral çizgilerin sayısı ve frekans çözünürlüğü (veya aralığı) ile ilişkilidir. Örnekleme oranı, donanımın birim zamanda (saniyede) aldığı örneklerin sayısıdır. Sinyal örtüşmesinden kaçınmak için etkin örnekleme oranının, ilgilenilen frekans aralığındaki maksimum değerinin iki katına eşit veya daha büyük olarak seçilmesi gerekmektedir. Blok boyutu, veri toplama bloğundaki zaman örneklerinin sayısıdır. Edinim

süresi ise veri toplama bloğundaki toplam saniye sayısıdır ve her bir ölçümün yapıldığı süre zarfını ifade eder. Ayrıca frekans bant genişliği, A/D dönüştürücünün etkin örnekleme frekansının yarısı olarak belirlenir. Bunun yanında, spektral çizgilerinin sayısı, verilerin toplandığı bant genişliğindeki frekansların sayısı olarak; frekans çözünürlüğü ise söz konusu spektral çizgilerin aralığı olarak ifade edilir (Tablo 2.6.) [224].

Yapılan çalışmalarda, vida mekanizması numunelerinin geometrileri, çalışma hızları ve sahip olduğu arızalar göz önünde bulundurularak etkin örnekleme oranı ve uygun bant aralığı seçilmiş ve buna bağlı olarak blok boyutu belirlenmiştir. SO Analyzer yazılımı bu ayarlara istinaden frekans çözünürlüğünü, spektral çizgilerin sayısını ve veri edinim süresini otomatik olarak tayin etmektedir [224]. Tablo 2.6’da titreşim sinyallerine ait veri toplama parametreleri görülmektedir. Ses sinyallerine ait ana parametreler de $f_s=4096$ Hz, $B=1600$ Hz, $N=4096$ olarak titreşim sinyallerine benzer şekilde belirlenmiştir.

Tablo 2.6. Titreşim sinyallerine ait veri toplama parametreleri [224].

Etkin örnekleme oranı, $f_s=1600$ Hz	Zaman aralığı, $1/f_s=0.000625$ s Maksimum frekans, $f_s/2=800$ Hz Kullanışlı bant genişliği, $B = f_s / (2.56)=625$ Hz
Kullanışlı bant genişliği, $B=625$ Hz	Örnekleme oranı, $f_s = (2.56)xB=1600$ Hz Maksimum frekans, $(1.28)xB=800$ Hz
Blok boyutu, $N=2048$	Edinim zamanı, $N/f_s=1.28$ s Frekans aralığı, $f_s/N=0.78125$ Spektral çizgilerin sayısı, $N/2 + 1=1025$

2.3.1.2. Sinyal İşleme Parametreleri

2.3.1.2.1. Sinyallerin Filtrenmesi

Sinyal işleme sırasında, elde edilen veya ölçülen sinyallerin belirli bir frekans aralığında analiz edilmesi gerekmektedir. Bu nedenle sinyallere filtreleme işlemi uygulanır. Filtreleme, istenmeyen sinyal özelliklerini ya da bileşenlerini kısmen ya da tamamen ortadan kaldırmak için uygulanan bir işlemdir. Bu işlem hem analog hem de dijital sinyallere uygulanabilir. Alçak geçiren filtre uygulamalarında geçirme bandı alçak

frekans bölgesi, durdurma bandı ise yüksek frekans bölgesidir. Yüksek geçiren filtre uygulamasında ise bu durumun tam tersi söz konusudur. Bant geçiren filtre uygulamalarında sadece belirli bir frekans aralığındaki sinyallerin geçişine izin verilir. Bant durdurucu filtre uygulamalarında ise belirli bir frekans aralığındaki sinyaller durdurulur. Bazı uygulamalarda elektronik donanımı besleyen güç devresinden kaynaklanan ve büyüklüğü 50 Hz olan şebeke elektriğinin frekansı spektrum grafiğinde görülebilir. Bu tür bir frekans, bant durdurucu filtrelerin özel bir hali olan çentik filtreleri ile durdurulur [2, 14].

Yapılan ölçümlerde filtre uygulanan frekans aralığı ve filtre türü literatürdeki çalışmalar göz önünde bulundurularak belirlenmiştir [199, 200]. Seçilen frekans aralığında optimal bir düzlük istenilen durumlar için Butterworth tipi veya lineer faz istenilen durumlar için Bessel tipi filtre seçimi, SO Analyzer yazılımı ile mümkündür. Bessel tipi filtre geçişli sinyaller için uygun olduğu için yapılan çalışmalarda Butterworth tipi filtre tercih edilmiştir. Yapılan ölçümlerde, seçilen görüntüleme penceresi tipine bağlı olarak yalnızca spektral veri sonuçlarına uygulanan ve ilk birkaç *FFT* hattını sıfırlayan dijital AC filtre seçeneği de kullanılmıştır [224].

Tablo 2.7. Sinyal filtreleme ile ilgili deneylerde kullanılan parametreler.

Sinyal Türü	Filtre Türü	Frekans Aralığı (Hz)	Dijital AC Filtre
Titreşim	Butterworth, bant geçiren	2-800	Evet
Ses	Butterworth, bant geçiren	2-1900	Evet

2.3.1.2.2. Sinyal Ön İşleme - Senkron Ortalama Sinyal Tekniği

Toplanan titreşim ve ses sinyalleri ham halleriyle sabit olmayan gürültü bileşenleri içermektedir. Bu nedenle ham haldeki sinyallerin ön işleme aşamasından geçirilmesi gerekir. Analizi yapılan sistemin çalışmasıyla senkronize olmayan gürültü bileşenleri, senkron ortalama tekniğinin kullanılmasıyla sinyalden ayrılır. Bunun için belirli zaman aralıklarında ölçümü yapılan ses ve titreşim sinyallerin ortalamalarının alınması gerekmektedir [6]. Bu amaç doğrultusunda, SO Analyzer yazılımı kullanılarak sinyallerin senkron ortalaması elde edilmiştir [224].

2.3.1.2.3. Pencereleme Tekniđi

Sinyal işlemede frekans dağılımı, *GSY* vb. ölçümler yapılırken *FFT*'nin hesaplanması gerekmektedir. Ancak bu durum, sinyalin tamamen periyodik olmadığı veya veri edinim bloğunda tamamen gözlenmediđi durumlarda bir miktar veri kaybına neden olur. Bu olumsuzluk seçilen bir pencere fonksiyonu ile giderilir. *FFT* uygulamadan önce, görüntüleme pencerelerinden en uygun olanının seçilmesi ile bu veri kaybı en aza indirilir. Yapılan çalışmalarda genlik hata oranı en düşük görüntüleme penceresi olan Flattop fonksiyonu tercih edilmiştir [14, 224].


2.3.1.3. Öznitelik Çıkarma

Öznitelik çıkarımı, titreşim ve ses sinyallerine ait ham verileri nümerik özelliklere dönüştürme sürecini ifade eder. Otomatik ya da manuel olarak gerçekleştirilen bu süreçte ham veriler korunur. Sinyallerden çıkarılan ayırt edici özellikler olarak öznitelikler, ham sinyallerin doğrudan kullanımının uygun olmadığı makine öğrenmesi uygulamalarında kullanılabilir [28, 214].

2.3.1.3.1. Zaman Bölgesi Analizi

Redüktör arızalarının tespit edilmesi ve sınıflandırılması çalışmalarda kullanılan yaklaşımlardan birisi titreşim ve/veya ses sinyallerinin zaman bölgesindeki analizidir. Dışlı çark arızalarının tespit edilmesi için zaman bölgesinde analiz yapılırken sinyalin genliđi ve periyodu gibi zamana bađlı özelliklerinden faydalanılır. Bu özelliklerdeki beklenmeyen deđişimler, meydana gelen bir arıza ve arızanın kaynađı hakkında bilgi verir [6].

Şekil 2.21'de çıkış milinin hızı 50 d/dk olan ve %50 yüklenmiş sağlam SVR'den alınan zamana bađlı titreşim sinyali görölmektedir. Redüktörün ürettiđi zamana bađlı sinyalin random bir yapıda olduđu açıkça ortadadır. Bu nedenle yapılan çalışmalarda zaman bölgesindeki özniteliklerin çıkarılması için istatistiksel yöntemler kullanılmıştır. Bu amaçla, toplanan titreşim ve ses verilerinin kare ortalamalarının kökü (*RMS*), standart sapma (σ , *SS*), varyans (σ^2 , *VAR*), çarpıklık katsayısı (*ÇK*) ve kurtosis (*BK*, basıklık katsayısı) deđerleri elde edilmiştir.



Şekil 2. 21. SVR için elde edilen ham titreşim sinyali

RMS: Bir titreşim ya da ses sinyaline ait ham verilerin *RMS*'si, sinyali oluşturan değerlerin karelerinin aritmetik ortalamasının karekökü olarak tanımlanabilir. *RMS* değeri sinyalin enerjisinin ne kadar yüksek olduğu ile ilgili bir göstergedir ve tüm sinyal analizlerinde kullanılabilir [19, 214, 225]. Redüktörlerde meydana gelen arızalar da ölçülen sinyalin *RMS* değerinin yükselmesine neden olur [6]. Bu nedenle yapılan çalışmalarda, sinyallerin zaman bölgesindeki analizi için *RMS* değerleri hesaplanmıştır.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.1)$$

Standart sapma: Standart sapma (σ , *SS*), sinyale ait verilerin ortalama değer etrafında ne kadar yayıldığını veya saptığını gösteren bir ölçüdür. Düşük bir *SS* değeri, ham sinyali oluşturan verilerin ortalama değere yakınlığını ifade eder. *SS* değerinin yüksek olması da verilerin daha geniş bir aralığa yayıldığı anlamına gelir [16, 214, 226].

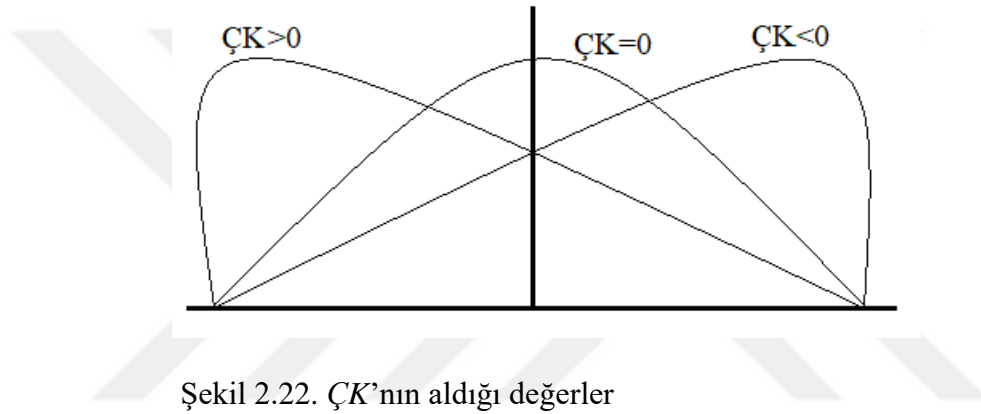
$$SS = \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (2.2)$$

Varyans: Normal dağılımın ikinci momenti olan varyans (σ^2 , *VAR*) ise standart sapmanın karesidir. Standart sapmaya benzer şekilde düşük *VAR* değeri ortalamaya yakınlığı, yüksek *VAR* değeri ise ortalamaya uzaklığı ifade eder. Hem *SS* hem de *VAR* dışı çarklarda arıza tespiti amacıyla zaman bölgesinde sinyal analizi yapılırken kullanılmıştır [214, 227].

$$VAR = \sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (2.3)$$

Çarpıklık katsayısı: İstatistiksel olarak normal dağılımın üçüncü momenti çarpıklık katsayısı (ÇK) olarak tanımlanır. Pozitif, negatif, sıfır veya tanımsız olabilen (Şekil 2.22) ÇK , random sinyal verilerinin dağılımının simetrik çan eğrisinden veya normal dağılımından uzaklığı veya bozulma derecesi olarak göz önüne alınır. Yani ÇK normal dağılım değerindeki asimetridir [19, 214, 228].

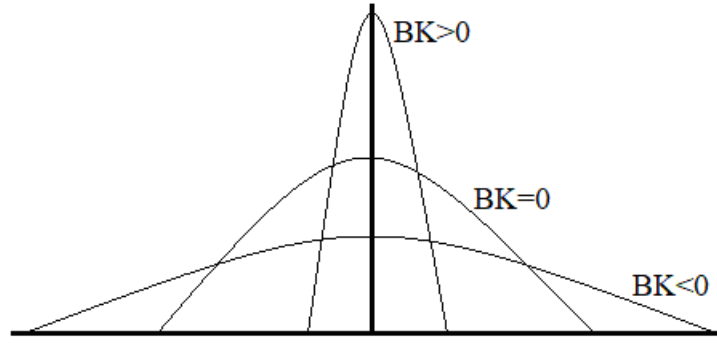
$$\text{ÇK} = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{(N-1)\sigma^3} \quad (2.4)$$



Şekil 2.22. ÇK 'nin aldığı değerler

Basıklık katsayısı (kurtozis): Basıklık katsayısı (BK), istatistiksel olarak normal dağılımın dördüncü momenti olarak tanımlanır. Şekil 2.23'te görüldüğü gibi negatif, pozitif ya da sıfır olabilen BK , random sinyal verilerinin dağılımının simetrik çan eğrisinden veya normal dağılımından daha tepeli (sivri) veya daha düz (basık) olmasının bir ölçüsü olarak ifade edilebilir. Bir diğer ifadeyle, olasılık yoğunluk fonksiyonunun dağılımın ortalaması etrafında ne kadar keskin bir şekilde arttığı ve azaldığı ile ilgili nicel bir göstergedir. Hem BK hem de ÇK , zaman bölgesinde arızaların tespit edilmesi amacıyla sinyal analizi yapılırken kullanılmıştır [16, 227, 228].


$$BK = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N-1)\sigma^4} \quad (2.5)$$



Şekil 2.23. BK 'nın aldığı değerler

2.3.1.3.2. Frekans Bölgesi Analizi

Frekans analizi veya spektrum analizi olarak da bilinen frekans bölgesinde analiz, redüktörlerde arıza tespiti ve sınıflandırılması amacıyla titreşim ve ses sinyallerinin analiz edilmesinde oldukça sık kullanılan bir yaklaşımdır [6, 226]. Deneysel olarak elde edilen titreşim ve ses verilerine, SO Analyzer programında frekans bölgesi analizi olarak *FFT* uygulanmıştır (Şekil 2.24).



Şekil 2.24. *FFT* işlemi [33].


SVR'den alınan zamana bağlı titreşim sinyaline *FFT* uygulanmasıyla elde edilen frekans dağılımı (2.6) numaralı denklem ile ifade edilebilir. Bu işlem sonucunda

redüktörün ürettiği sinyalin içerdiği her bir frekans bileşeni ve bu frekansların büyüklükleri tespit edilebilir.

$$FFT = X(f) \quad (2.6)$$

FFT işleminden yola çıkarak hesaplanan diğer bir fonksiyon da güç spektrum yoğunluğudur (*GSY*). Sinyalin frekans spektrumu üstündeki güç dağılımı olarak ifade edilen *GSY*, sinyal gücünün karesi alınarak hesaplanmaktadır. Eğer sinyalin Fourier dönüşümü yoksa öncelikle otoilinti [otokorelasyon, $R_{xx}(\tau)$] fonksiyonunun Fourier dönüşümü alınır, daha sonra güç spektrum yoğunluğu (*GSY*) hesaplanır. *GSY*, hangi frekans bileşenlerinin daha güçlü, hangi frekans bileşenlerinin daha zayıf olduğunu göstermektedir [2]. Şekil 2.25'te çıkış milinin hızı 50 d/dk olan ve %50 yüklenmiş sağlam SVR için *GSY* grafiği görülmektedir.

$$GSY(f) = \frac{X(f)X^*(f)}{f} = \frac{S_{xx}(f)}{f} \quad (2.7)$$



Şekil 2.25. SVR için elde edilen *GSY* değişimi

Genel olarak, dişli çark mekanizmalarının çalışma esnasında ürettikleri sinyaller birbiri ile eşleşen iki dişlinin etkisi nedeniyle açığa çıkan bir kavrama (ağ) frekansına sahiptir. Kavrama (ağ) frekansı ve bu frekansın harmonik bileşenleri, dişli veya dişliler üzerinde meydana gelen arızanın türü ve ciddiyeti hakkında bilgi verir. Ancak sonsuz vida mekanizması için kavrama (ağ) frekansı ve bu frekansın harmonik bileşenleri diğer dişli çark mekanizması tiplerine (helisel, konik, düz vb.) nazaran daha zor gözlemlenir. Çünkü sonsuz vida ve eşleştiği bronz dişli çark birbiri üzerinden kayarak ve birbirine sürtünerek hareket eder [199, 203, 204]. Bu nedenle yapılan çalışmalarda frekans bölgesindeki

özniteliklerin çıkarılması için istatistiksel yöntemler kullanılmıştır. Bu amaçla, toplanan titreşim ve ses sinyallerinin *FFT* ve *GSY* değerleri hesaplandıktan sonra elde edilen dağılım üzerinden frekans merkezi (*FM*) değerleri, (2.8) numaralı denklemde verildiği gibi hesaplanmıştır. *FM*, frekans spektrumunun birinci dereceden momenti olarak tanımlanabilir. Frekans *RMS* değeri (*RMSF*) ise (2.9) numaralı denkleme göre hesaplanmıştır. *RMSF*, frekans spektrumunu oluşturan değerlerin karelerinin aritmetik ortalamasının karekökü olarak ifade edilebilir. Frekans varyansının karekökü (*VKF*), (2.10) denkleminde verildiği gibi hesaplanmıştır. *VKF*, frekans spektrumunun ikinci dereceden momentidir [225-228].

$$FM = \frac{1}{N} \sum_{i=1}^N f_i \quad (2.8)$$

$$RMSF = \left(\frac{1}{N} \sum_{i=1}^N f_i^2 \right)^{1/2} \quad (2.9)$$

$$VKF = \left(\frac{1}{N} \sum_{i=1}^N (f_i - FM)^2 \right)^{1/2} \quad (2.10)$$

FM ve *RMSF* değerleri ana frekans bileşenlerinin değişmesi ile değişirken *VKF*, spektrumdaki dağılımın *FM* etrafında ne kadar yayıldığını göstermektedir [225, 228]

2.3.2. Termal Görüntülerin Analizi

Deneysel çalışmalarda toplanan ve sayısal hale dönüştürülen termal görüntülerin bilgisayar ortamında işlenmesi ve analiz edilmesi için Testo IRSoft programı kullanılmıştır. Bu program ile termal görüntülerdeki ölçüm noktaları istenildiği gibi ayarlanabilmekte, sıcak ve soğuk noktalar belirlenmekte, farklı malzemeler için farklı emisivite (yayma) oranları seçilebilmekte ve görüntü üzerindeki sıcaklıkları göstermek için belirli bir sınır değeri aşan kritik sıcaklıklar vurgulanabilmektedir [223].

Termal görüntüleme için seçilen öznitelikler maksimum ($T_{mak.}$), minimum ($T_{min.}$) ve ortalama ($T_{ort.}$) sıcaklıklar olarak belirlenmiştir. Sağlam ve arızalı redüktörlerin her birinden farklı yükler ve farklı devir sayıları altında termal görüntüler toplanmıştır. Şekil 2.26'da çıkış milinin hızı 50 d/dk olan ve %50 yüklenmiş sağlam SVR'nin termal görüntüsü görülmektedir. Toplanan görüntüler sıcaklığın en çok değiştiği alanlar dikkate alınarak Testo IRSof t programıyla analiz edilmiştir.



Şekil 2.26. Sağlam redüktörün termal görüntüsü


Farklı çalışma koşulları altında toplanan termal görüntülerden elde edilen $T_{mak.}(^{\circ}C)$, $T_{min.}(^{\circ}C)$ ve $T_{ort.}(^{\circ}C)$ sıcaklıkları, YZ ile arıza tespiti ve sınıflandırılması ile ilgili yapılan uygulamalarda öznitelik olarak kullanılmıştır.

2.4. YZ ile Arıza Tespiti ve Sınıflandırılması

2.4.1. YZ Yaklaşımı

SVR'lerde YZ ile arızaların tespit edilip sınıflandırılmasına yönelik yapılan çalışmalarda iki ayrı yaklaşım kullanılmıştır. Birinci yaklaşımda (Şekil 2.27 a), arıza durumu tespit edilmektedir. Burada amaç problemi iki sınıftan biri ile temsil etmektir. Bunlar redüktörde “arıza yok” (S) ve “arıza var” (A) şeklindeki sınıflardır. İkinci yaklaşımda ise (Şekil 2.27 b) arızanın sınıflandırılması yapılmaktadır. Bu kısımda,

problemin sonucu dört sınıftan biri ile temsil edilmektedir. Bunlar “arıza yok” (S), “arıza 1” (A1), “arıza 2” (A2) ve “arıza 3” (A3) şeklindedir. Kurulan YZ yaklaşımına ait giriş parametreleri, farklı çalışma koşulları altında toplanmış titreşim, ses ve termal görüntü verilerinden çıkarılan öz niteliklerdir. Giriş ve çıkış parametreleri ile ilgili detaylı bilgiler Tablo 2.8’de verilmiştir.



Şekil 2.27. YZ yaklaşımı: a) arıza tespiti, b) arızanın sınıflandırılması


Tablo 2.8. YZ yaklaşımına ait giriş ve çıkış parametreleri

GİRİŞ PARAMETRELERİ					HEDEF PARAMETRE	
Öz Nitelikler					Arızanın Tespiti ve Sınıflandırılması	
Yükleme Oranları (YO)		%0, %25, %50, %75 ve %100			Arıza Yok (S)	
Redüktör Çıkış Hızları (RÇH)		50 d/dk, 60 d/dk, 70 d/dk			Arıza 1 (A1)	
Titreşim		Ses		Termal Görüntü	Arıza Var (A)	
Zaman Bölgesi	Frekans Böl.	Zaman Bölgesi	Frekans Böl.	Maksimum, Minimum ve Ortalama Sıcaklık		
<i>RMS, SS, VAR, ÇK, BK</i>	<i>FM, RMSF, VKF</i>	<i>RMS, SS, VAR, ÇK, BK</i>	<i>FM, RMSF, VKF</i>	$T_{mak.}, T_{min.}, T_{ort.}$		
					Arıza 3 (A3)	

2.4.2. Çalışmalarda Kullanılan YZ Türleri

2.4.2.1. Yapay Sinir Ağları (YSA)

Arıza tespiti ve sınıflandırması amacıyla kullanılan en yaygın sınıflandırma algoritmalarından birisi YSA'dır. YSA, esasen bir dizi basit işlemciye dayanan bir YZ tekniğidir. Şekil 2.28'de iki gizli katmana sahip bir YSA görülmektedir. Buna göre x_1 , x_2 ve x_3 girişleri a_{21} , a_{22} ve a_{23} hesaplama birimlerini yani yapay nöronları, y ise çıkışı temsil etmektedir [24, 25, 229].



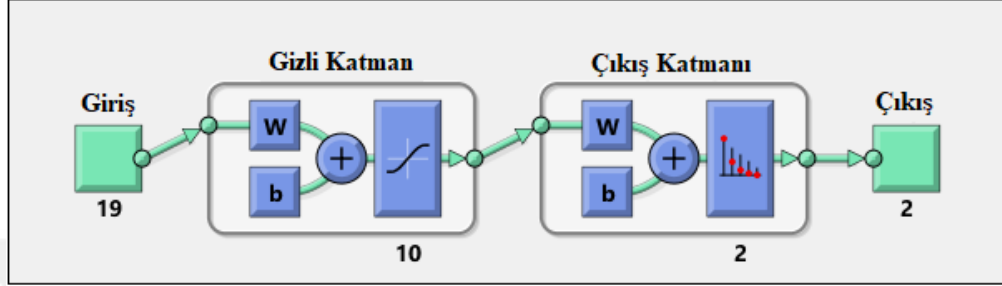
Şekil 2.28. İki gizli katmanlı YSA [229].

Denklem (2.11)'de görülen f , aktivasyon fonksiyonu olarak bilinir, b ise skaler bir büyüklüktür. W , YSA model parametresi veya ağırlık olup bilinen giriş-çıkış örüntülerine dayalı olarak yinelemeli (iteratif) bir eğitim prosedürü sonucu elde edilir. Nihai olarak YSA birçok yapay nöronu birbirine bağlar, bir nöronun çıkışı bir diğer nöronun girişidir [24, 25, 229].

$$y = f(W^T x) = f\left(\sum_{i=1}^3 W_i x_i + b\right) \quad (2.11)$$

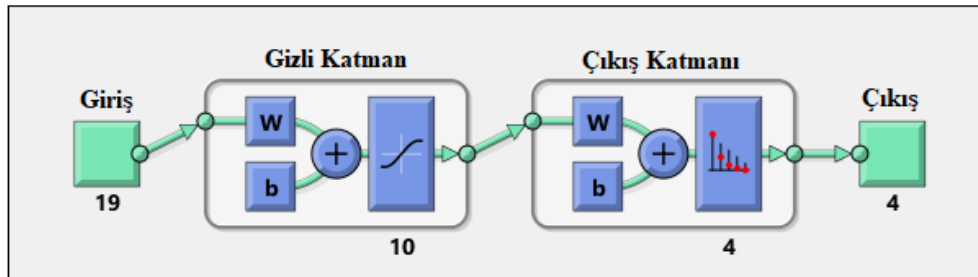
Yapılan çalışmalarda SVR'lerde ikili sınıflandırma yani arıza tespiti yapılırken 1 gizli katmana ve 1 çıkış katmanına sahip ileri beslemeli bir YSA mimarisi kullanılmıştır

(Şekil 2.29). Yapılan ön değerlendirmelerden sonra gizli katmandaki yapay sinir hücrelerinin sayısı 10 adet olarak belirlenmiştir. YSA ile arıza tespiti amacıyla kurulan mimaride 2 adet çıkış vardır. Arıza varlığının tespit edilmesi işleminde arıza sınıfının bilinmesine gerek olmadığından YSA çıkışları S (sağlam redüktör) ve A (arızalı redüktör) olarak ikiye ayrılmıştır.



Şekil 2.29. Arıza tespiti için seçilen YSA mimarisi

SVR'lerde arızanın sınıflandırılması yapılırken yani arızanın türü tespit edilirken de 1 gizli katmana ve 1 çıkış katmanına sahip ileri beslemeli bir YSA mimarisi kullanılmıştır (Şekil 2.30). Arıza tespiti için seçilen YSA mimarisine benzer şekilde yapılan ön değerlendirmelerden sonra gizli katmandaki yapay sinir hücrelerinin sayısı 10 adet olarak belirlenmiştir. YSA ile arızanın türü belirlenirken 4 çıkışlı bir mimari oluşturulmuştur. YSA çıkışları S (sağlam redüktör), A1 (aşınma), A2 (yüzey yorgunluğu) ve A3 (kırılma) olacak şekilde düzenlemiştir.



Şekil 2.30. Arıza türünün sınıflandırılması için seçilen YSA mimarisi

Hem arıza tespiti hem de arıza türünün sınıflandırılması için YSA yaklaşımı kurulurken veri seti eğitim, doğrulama ve test olmak üzere üç bölüme ayrılmıştır. Buna göre, yapılan ön çalışmalar sonucu arıza tespiti veya arıza türünün sınıflandırılması

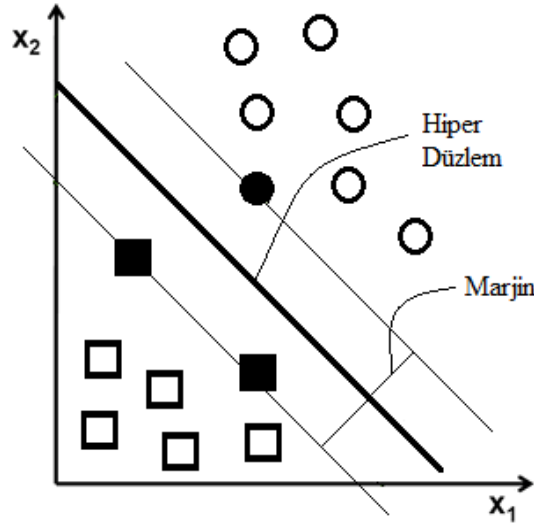
amacıyla kullanılan veri setinin %70'inin eğitim, %15'inin doğrulama ve %15'inin test için kullanılması uygun görülmüştür.

2.4.2.2. Destek Vektör Makinesi (DVM)

Denetimli bir makine öğrenmesi tekniği olan DVM, algoritmik olarak veri kümeleri arasında bir hiper düzlem oluşturmak suretiyle sınıflandırma işlemini gerçekleştirir. Karmaşık ve çok boyutlu bir sınıflandırma probleminin çözümü için uygun bir kernel fonksiyonu kullanılır ve problem daha yüksek boyutlu bir uzaya taşınarak çözülür [140, 230, 231].

$$y = f(x) = W^T x + b = \sum_{i=1}^N W_i x_i + b \quad (2.12)$$

Denklem (2.12)'de görülen x , girişi ve W , N -boyutlu vektörü temsil etmektedir; b ise skaler bir büyüklüktür. Şekil 2.31'de DVM ile ikili bir sınıflandırma örneği görülmektedir. Buna göre sınıflandırma için en uygun hiper düzlem, marjinin maksimum olduğu düzlemdir [229].



Şekil 2.31. DVM ile ikili bir sınıflandırma için en uygun hiper düzlem

SVR’lerde arıza tespiti amacıyla kullanılan DVM’nin S (sağlam redüktör) ve A (arızalı redüktör) olmak üzere 2 adet çıkış sınıfı vardır. DVM ile sınıflandırma problemlerinin çözümünde çekirdek (kernel) fonksiyonunun seçimi önem arz etmektedir. Tablo 2.9’da arıza tespiti yaklaşımında kullanılan farklı çekirdek fonksiyonlarına sahip DVM’lerin genel başarı oranları görülmektedir [28]. Buna göre S ve A redüktörlerinin sınıflandırılmasında kübik çekirdek fonksiyonuna sahip DVM tercih edilmiştir.

Tablo 2.9. Farklı çekirdek fonksiyonlarına sahip DVM’lerin doğruluk oranları

	Lineer DVM	İkinci Dereceden (Karesel) DVM	Kübik DVM	Gauss DVM
Doğruluk Oranı (%)	82.2	98.0	98.2	95.3
Kestirim Hızı (Gözlem/s)	11000	13000	13000	21000
Eğitim Zamanı (s)	10.46	9.25	9.08	9.81


SVR’lerde arıza türünün tespiti amacıyla kullanılan DVM yaklaşımının S, A1, A2 ve A3 olmak üzere 4 adet çıkış sınıfı vardır. DVM ile arıza türünün sınıflandırılmasında kullanılacak yaklaşım için kübik çekirdek (kernel) fonksiyonunun seçilmiştir.

Farklı oranlar kullanılarak yapılan ön değerlendirmeler sonucunda hem arızanın tespiti hemde arıza türünün sınıflandırılmasında kullanılacak veri setinin %75’lik kısmının eğitim, kalan %25’lik kısmının da doğrulama ve test için kullanılmasının uygun olduğu görülmüştür.

2.4.2.3. K En Yakın Komşu (k-NN)

K-NN genellikle bir veri kümesindeki örneklerin bu örneklere benzer özelliklere sahip diğer örneklere yakın olarak var olacağı prensibine dayanan, örnek tabanlı bir makine öğrenmesi algoritmasıdır. Eğer örnekler bir sınıflandırma etiketi ile belirlenmişse, sınıflandırılmamış bir örneğin etiketi, en yakın komşularının sınıfına bakılarak belirlenir [105, 107, 108, 229].

YZ ile arıza tespiti ve sınıflandırılması çalışmalarında kullanılan k-NN algoritması ile ilgili üç temel özellik söz konusudur. Bunlardan ilki ölçülen örneklerin sayısıdır. İkincisi, bu örnekler arasında, özel bir metriğe dayalı olarak yapılan mesafe ölçümüdür. Üçüncüsü ise sınıflandırma işlemi için kullanılan karar kuralıdır. Buna göre k-NN, verili bir örneğe (eğitim setine) dayalı olarak uzaklık metriğini kullanır ve en yakındaki k adet örneği arar [229]. Şekil 2.32'de görüldüğü gibi ortadaki yıldız sınıflandırılacak örnektir. Altıgen ve daireler ise eğitim setindeki iki farklı veri gurubunu temsil etmektedir. Eğer $k=5$ ise en yakın 5 komşu, $k=8$ ise en yakın 8 komşu göz önüne alınmak suretiyle sınıf belirlenir [106].



Şekil 2.32. k-NN sınıflandırıcısı [106].

SVR'lerde arıza tespiti amacıyla kullanılan k-NN algoritmasının S (sağlam redüktör) ve A (arızalı redüktör) olmak üzere 2 adet çıkış sınıfı vardır.

Farklı oranlar kullanılarak yapılan ön değerlendirmeler sonucunda hem arıza tespiti hem de arıza türünün sınıflandırılması amacıyla kullanılan k-NN yaklaşımlarına ait veri setlerinin %75'lik kısmının eğitim, kalan %25'lik kısmının da doğrulama ve test için kullanılmasının uygun olduğu görülmüştür. K-NN ile yapılan sınıflandırma işlemlerinde örnek sayısı, yakınlık metriği vb. özellikler doğru sınıflandırma oranını etkilemektedir.

Tablo 2.10'da farklı k-NN türleri ile yapılan sınıflandırma sonucu elde edilen başarı oranları görülmektedir [28]. Buna göre S ve A redüktörlerinin sınıflandırılmasında ince k-NN tercih edilmiştir.

Tablo 2.10. K-NN türleri ve doğruluk oranları

	İnce k-NN	Orta k-NN	Kaba k-NN	Kosinüs k-NN	Kübik k-NN	Ağır. k-NN
Doğruluk Oranı (%)	98.7	97.8	88.0	92.0	96.2	98.4
Kestirim Hızı (Gözlem/s)	45000	40000	27000	36000	3000	3900
Eğitim Zamanı (s)	0.328	0.082	0.099	0.092	0.382	0.819
Komşu Sayısı	1	10	100	10	10	10
Yakınlık Metriği	Öklidyen	Öklidyen	Öklidyen	Kosinüs	Mink.	Öklidyen
Yakınlık ağırlığı	Eşit	Eşit	Eşit	Eşit	Eşit	Ters Kare

SVR’lerde arıza türünün tespiti amacıyla kullanılan k-NN yaklaşımının S, A1, A2 ve A3 olmak üzere 4 adet çıkış sınıfı vardır. Çoklu sınıflandırma işlemi için ağırlıklandırılmış k-NN yaklaşımı tercih edilmiştir.

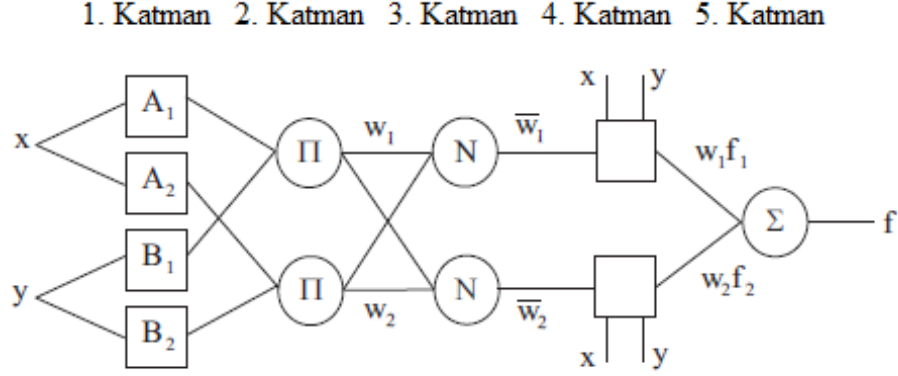
2.4.2.4. Adaptif Nöro-Bulanık Çıkarım (ANFIS)

Arıza tespiti ve sınıflandırması ile ilgili yapılan çalışmalarda bir hibrit zeki sistem (HZS) olan adaptif nöro-bulanık çıkarım (ANFIS) tekniği de kullanılmıştır. YZ tekniklerinden en az ikisinin birleşimi olarak tanımlanan hibrit zeki sistemler (HZS), farklı tekniklerinin avantajlarını birleştirmektedir [43]. Nöral ağlar ve bulanık mantığa dayalı ANFIS sistemi, öğrenme yeteneği, paralel işlem yapabilme, yapılandırılmış bilgi temsili vb. özellikleri ile YSA’dan ayrılır [23, 148, 232].

ANFIS mimarisi 5 katmandan oluşur ve her bir katman farklı bir görevi gerçekleştirir. Şekil 2.33’te görülen ANFIS mimarisi için iki giriş (x , y) ve bir çıkış (f) parametresi olduğunu varsayıldığında birinci dereceden Sugeno bulanık modeli için aşağıdaki kurallar yazılabilir [23, 232].

1. Kural: Eğer ($x = A_1$) ve ($y = B_1$) ise o halde $f_1 = p_1x + q_1y + r_1$,

2. Kural: Eğer ($x = A_2$) ve ($y = B_2$) ise o halde $f_2 = p_2x + q_2y + r_2$.



Şekil 2.33. ANFIS mimarisi [232].

ANFIS mimarisindeki w sembolü ağırlıkları temsil etmektedir. Nihai çıkış (f) ise denklem (2.13)'te görüldüğü gibi her bir kuralın ağırlıklarının ortalamasıdır [23, 232].

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} = \bar{w}_1 f_1 + \bar{w}_2 f_2 = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad (2.13)$$

Bu çalışmada ANFIS mimarisi için öznelik sütunlarından oluşan 19 giriş parametresi kullanılmıştır. ANFIS çıkış parametresi f ise sağlam veya arızalı redüktörleri temsil etmektedir.

SVR'lerde arıza tespiti amacıyla kullanılan ANFIS algoritması tek çıkış fonksiyonuna sahiptir. Bu nedenle arıza tespiti yapılırken veri setindeki S redüktörü 0 ile, A redüktörü de 1 ile temsil edilmektedir. Arıza türünün sınıflandırılması amacıyla kullanılan ANFIS algoritmasında ise veri setindeki S redüktörü 0, A1 redüktörü 1, A2 redüktörü 2 ve A3 redüktörü 3 ile temsil edilmektedir.

Farklı oranlar kullanılarak yapılan ön değerlendirmeler sonucunda hem arıza tespiti hem de arıza türünün sınıflandırılması amacıyla kullanılan yaklaşımlarında veri setinin %70'lik kısmının eğitim, %15'lik kısmının test ve kalan %15'lik kısmının da kontrol için kullanılmasının uygun olduğu görülmüştür.

ANFIS ile yapılan arıza tespiti ve sınıflandırılması işleminde kullanılan veri setinin yüksek boyutlu oluşu nedeniyle bulanık arayüz sistemi (FIS) oluşturmak için bir ön kümeleme işlemi yapılması gerekmektedir. Ön kümeleme işleminde giriş ve çıkış eğitim verileri eşlenerek küme sayısı ve küme merkezleri tahmin edilmektedir. Buna göre bulanık mantık kuralları, giriş üyelik fonksiyonu tipi ve sayısı, ayrıca çıkış üyelik fonksiyonu tipi otomatik olarak belirlenmektedir.

Tablo 2.11’de FIS oluşturmak için seçilen ön kümeleme parametreleri, Tablo 2.12’de arıza tespiti için kurulan ANFIS mimarisi ile ilgili özellikler ve Tablo 2.13’te ise arıza türünün sınıflandırılması için kurulan ANFIS mimarisi ile ilgili özellikler görülmektedir. Şekil 2.34’te de arıza tespiti yaklaşımına ait ANFIS mimarisi verilmiştir.

Tablo 2.11. Ön kümeleme parametreleri


Etki aralığı	0.5
Baskı faktörü	1.25
Kabul oranı	0.5
Ret oranı	0.15

Tablo 2.12. Arıza tespiti yaklaşımına ait ANFIS mimarisi ile ilgili özellikler

Düğüm sayısı	1462
Lineer parametre sayısı	720
Lineer olmayan parametre sayısı	1368
Toplam parametre sayısı	2088
Eğitilen veri çifti sayısı	1260
Kontrol edilen veri çifti sayısı	270
Bulanık mantık kuralı sayısı	36
FIS eğitimi	Hibrit

Tablo 2.13. Arıza türünün sınıflandırılması yaklaşımına ait ANFIS mimarisi ile ilgili özellikler

Düğüm sayısı	1542
Lineer parametre sayısı	760
Lineer olmayan parametre sayısı	1444
Toplam parametre sayısı	2204
Eğitilen veri çifti sayısı	1260
Kontrol edilen veri çifti sayısı	270
Bulanık mantık kuralı sayısı	38
FIS eğitimi	Hibrit



Şekil 2.34. Arıza tespiti amacıyla kurulan ANFIS mimarisi

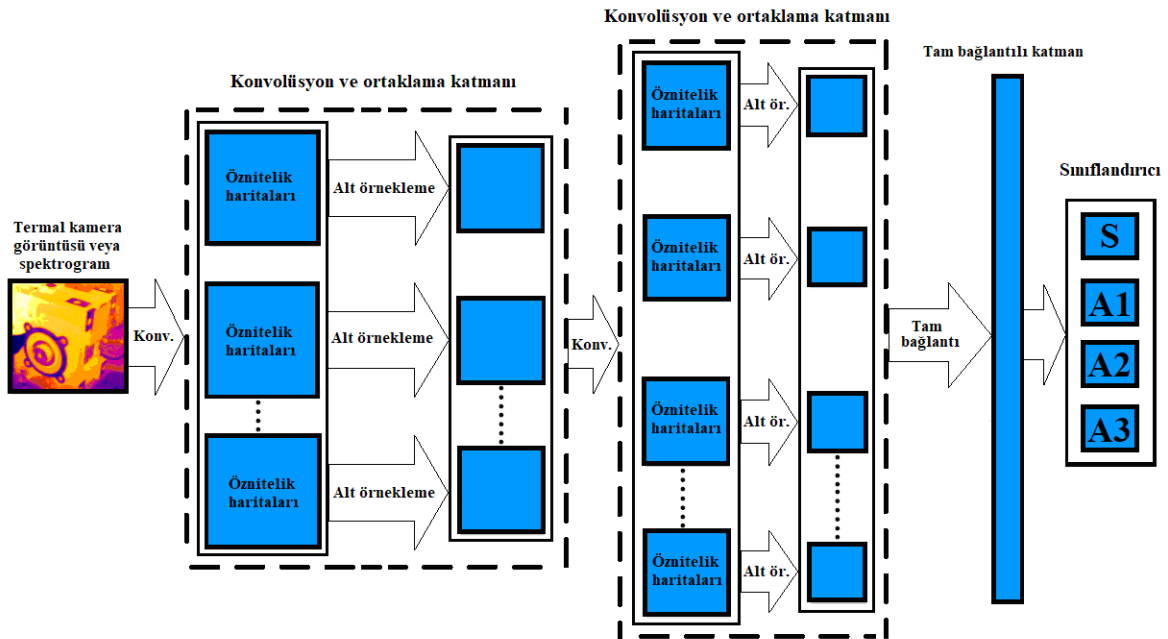
2.4.2.5. Derin Öğrenme

Yapılan çalışmalarda SVR'lerde arıza tespiti ve sınıflandırılması amacıyla kullanılan son YZ tekniği derin öğrenmedir. Derin öğrenmede karmaşık nöral ağ mimarisi

kullanılır ve arızanın tespiti amacıyla sınıflandırma işlemi, görsel sinyal verilerinin doğrudan kullanılmasıyla yapılır [29, 150-153].

Konvolüsyonel sinir ağı (KSA), en çok kullanılan derin öğrenme türlerinden biridir. Tipik bir KSA, iki tip katman halinde düzenlenmiştir: konvolüsyon katmanları ve alt örnekleme katmanları. Bu katmanlardan her biri belirli bir topografik yapıya sahiptir ve bu yapının her yerine dağılmış olan, birbirinden farklı bir dizi nöron içerir. Her bir nöron da bir önceki katmandaki nöronlarla irtibatlıdır. Şekil 2.35'te giriş, konvolüsyon, ortaklama katmanları, alt örnekleme katmanları, 1 ve 2 boyutlu öznelik haritaları, tam bağlantı katmanı ve sınıflandırıcıdan oluşan tipik bir derin öğrenme mimarisi görülmektedir. SVR ile ilgili yapılan çalışmalarda bu mimari kullanılmıştır [233].

Normal YSA'dan farklı olarak KSA, harita olarak adlandırılan 2 boyutlu veriler üzerinde çalışır. Konvolüsyon ve alt örnekleme katmanları, hesaplama süresini azaltacak ve kademeli olarak uzaysal ve şekilsel değişmezlik inşa edecek şekilde düzenlenmiştir [233].



Şekil 2.35. Derin öğrenme mimarisi

KSA mimarisindeki konvolüsyon katmanları esasen bir dizi filtreden meydana gelmiştir. Bu filtreler bir önceki katmandaki girdiyi bir dizi ağırlıkla çarpar ve öznelik haritası adı verilen bir çıktıyı oluşturur. Filtrelerdeki nöronlar giriş verisi noktalarına

bağlıdır ve bu noktalar ağırlıklarla çarpılır. Aynı filtredeki tüm nöronlar ağırlıklarını paylaştığı için KSA'nın optimizasyon süresi ve karmaşıklığı azalmış olur [29, 153, 233].

Alt örnekleme vasıtasıyla özniteliklerin ve ağ parametrelerin boyutunu azaltmak mümkündür. Bunun için, ortaklama katmanları konvolüsyon katmanlarının ardından gelir. Aktivasyon istatistiklerinin hesaplanmasında ise maksimum, minimum ve ağırlıklandırılmış olmak üzere üç farklı tip ortaklama fonksiyonu kullanılır. Bunlar arasında, maksimum ortaklama fonksiyonu, KSA mimarisinde en çok tercih edilen fonksiyondur. Son olarak, tam bağlantılı katman, konvolüsyon ve ortaklama katmanlarının kombinasyonlarını takip eder. Tam bağlantılı katman geleneksel sinir ağlarına benzediği için sınıflandırma problemlerine uygulanabilir [29, 153, 233].

Bu çalışmada derin öğrenme ile sınıflandırma yapılırken hiper parametreleri optimize edilmiş yani ön eğitilmiş bir konvolüsyonel sinir ağı (KSA) olan GoogLeNet kullanılmıştır. SVR ile ilgili çalışmalarda kullanılabilecek şekilde modifiye edilerek uygun hale getirelen GoogLeNet, 144 katmandan ve katmanlar arasındaki 170 bağlantıdan oluşmaktadır. GoogLeNet, ayrıca 224x224 çözünürlükteki görsel verileri giriş parametresi olarak kullanılmaktadır. Tablo 2.14. bu çalışmada kullanılan modifiye edilmiş GoogLeNet'e ait özellikleri göstermektedir.

Tablo 2.14. Modifiye edilmiş GoogLeNet özellikleri

Katman Derinliği	22
Katman Sayısı	144
Bağlantı Sayısı	170
Giriş Tipi	Görsel
Giriş Boyutu	224x224x3
Çıkış Tipi	Sınıflandırma
Çıkış Boyutu	4
Ağırlık Öğrenme Oranı Faktörü	10
Sapma Öğrenme Oranı Faktörü	10
Kayıp Fonksiyonu	Çapraz Entropi
Doğrulama frekansı	6 Hz
Öğrenme oranı	0.001

KSA sınıflandırıcısı için kullanılan sınıflar sağlam ve arızalı redüktörler olarak belirlenmiştir. Redüktör arızalarının tespiti ve sınıflandırılması için termal görüntüleme dayalı yaklaşım (IRT-KSA), titreşim sinyallerine dayalı yaklaşım (T-KSA), ses sinyallerine dayalı yaklaşım (S-KSA) ve ses sinyallerinin titreşim sinyalleri ile birlikte kullanıldığı yaklaşım (TS-KSA) olmak üzere dört farklı derin öğrenme yaklaşımı belirlenmiştir. Farklı derin öğrenme yaklaşımları için seçilen deneysel parametreler Tablo 2.15'te görülmektedir.

Tablo 2.15. Farklı derin öğrenme yaklaşımları için deneysel parametreler

IRT-KSA	T-KSA	S-KSA	TS-KSA	Arıza Tespiti ve Sınıflandırması	
Giriş Parametreleri				Çıkış Parametreleri	
Termal görüntüler	Titreşim sinyallerine ait spektrogramlar	Ses sinyallerine ait spektrogramlar	Titreşim ve ses sinyallerine ait spektrogramlar	S	
				Arızanın sınıflandırılması	A1
Eğitim, Doğrulama ve Test Oranları					A2
%50; %25; %25					A3
Yükleme Oranları (YO)		%0; %25; %50; %75; %100			
Redüktör Çıkış Hızı (RÇH)		30 d/dk; 50 d/dk; 70 d/dk			

IRT-KSA yaklaşımı için kullanılan termal kamera görüntüleri farklı çalışma koşulları altında toplanmış ve Tablo 2.15'te verilen eğitim, doğrulama ve test oranlarına göre ayrılmıştır. Titreşim ve ses verilerine dayalı yaklaşımların kurulmasında da aynı yol izlenmiştir. Ancak hem titreşim hem de ses verileri için öncelikle sinyallerin kısa süreli *FFT* dönüşümleri hesaplanmış ve farklı çalışma koşulları altındaki spektrogram görüntüleri elde edilmiştir. Spektrogramlar titreşim ve ses gibi sinyallerin frekans bileşenlerinin zaman içindeki değişimini görselleştirmek için kullanılmaktadır [19]. Bu nedenle, arızalı ve sağlam redüktörlerin sınıflandırılmasında titreşim ve ses spektrogramları KSA yaklaşımları için eğitim, doğrulama ve test verileri olarak Tablo 2.15'te belirtilen oranlarda kullanılmıştır.

2.4.3. Sınıflandırma Performans Ölçütleri

SVR’lerde arızaların tespit edilmesi amacıyla kullanılan YZ yaklaşımlarının sınıflandırma performanslarının değerlendirilmesinde hata matrisleri ve ROC (alıcı işlem karakteristiği) eğrileri kullanılmıştır.

Test verileri kullanılarak elde edilen hata matrisleri, YZ yaklaşımlarının performansının incelenmesinde kullanılan özel tablo düzenekleridir. Tablo 2.16’da biri pozitif, diğeri negatif sınıf olmak üzere ikili bir sınıflandırma yaklaşımına ait hata matrisi örneği görülmektedir. Bu bağlamda, tablonun dört hücresi gerçek pozitifler (GP), yanlış pozitifler (YP), gerçek negatifler (GN) ve yanlış negatifler (YN) olarak tanımlanır. Bu dört sınıflandırma sonucuna göre doğruluk (2.14), duyarlılık (2.15) ve özgüllük (2.16) olmak üzere üç farklı performansı ölçütü tanımlanabilir [234].

Tablo 2.16. Hata matrisi

Çıkış Sınıfı (Gerçek Sınıf)		Hedef Sınıfı	
		Pozitif	Negatif
	Pozitif	Gerçek Pozitif (GP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Gerçek Negatif (GN)


$$\text{Doğruluk} = GP / (GP + YP) \quad (2.14)$$

$$\text{Duyarlılık} = GP / (GP + YN) \quad (2.15)$$

$$\text{Özgüllük} = GN / (GN + YP) \quad (2.16)$$

YZ yaklaşımlarının sınıflandırma etkinliğini ya da kalitesini kontrol etmek için kullanılan bir diğer performans ölçütü ise ROC (alıcı işlem karakteristiği) eğrileridir. Bu amaçla YZ sınıflandırıcıdaki her bir sınıf için [0–1] aralığındaki çıkışlara eşik değerleri uygulanır. Her bir eşik için gerçek pozitif oranı ve yanlış pozitif oranı olmak üzere iki değer hesaplanır. ROC grafiklerinde eğri altında kalan alan (EAA) oranı ne kadar çoksa

sınıflandırma performansı da o kadar yüksektir (Şekil 2.36). Gerçek pozitif oranının 1 ve yanlış pozitif oranının 0 olduğu nokta yani kartezyen koordinat sisteminde [0,1] ile gösterilen yer mükemmel sınıflandırma performansını temsil etmektedir [234].



Şekil 2.36. ROC eğrileri

2.5. Matematiksel Model

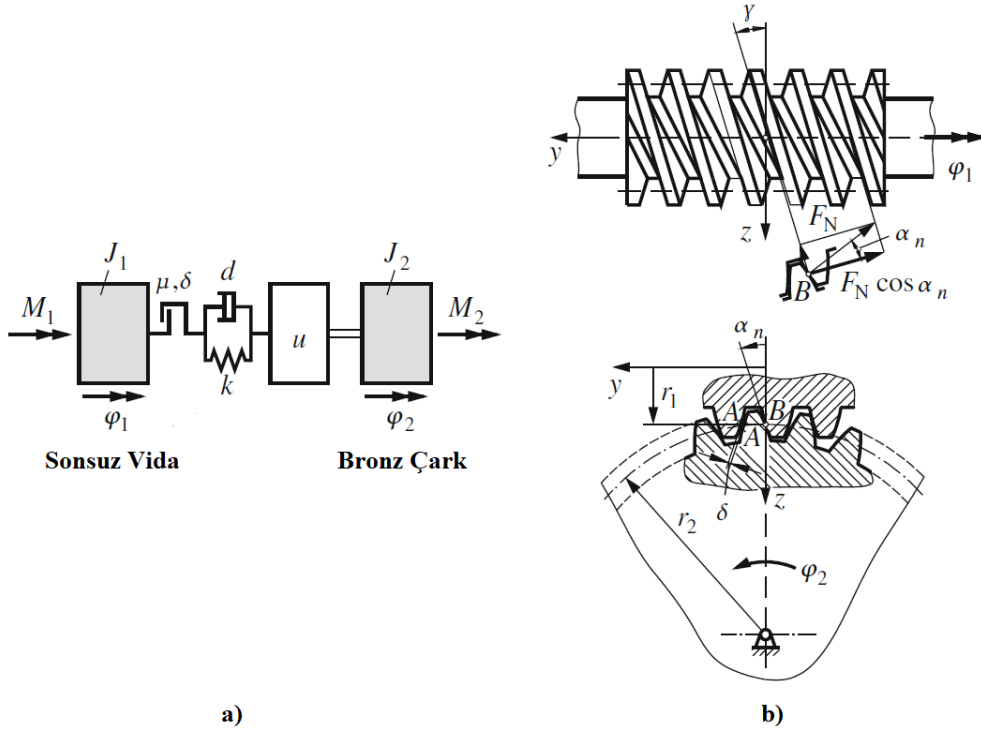
Dinamik bir sistemin çıkış sinyallerine ait değerler hem giriş sinyallerinin anlık değerlerine hem de sistemin geçmişteki davranışına bağlıdır. Buna göre dinamik sistem olarak ele alınacak SVR'nin titreşim davranışı da hem anlık yükleme oranına hem de bu yüklemenin ne kadar süredir yapıldığına bağlı olacaktır. SVR gibi sistemler için kullanılan dinamik modeller hem sürekli hem de ayrık zamanlı formda yazılabilir. Dinamik modellerin gösteriminde tipik olarak diferansiyel denklemler, durum-uzay denklemleri, transfer fonksiyonları vb. kullanılır [235].

Dinamik bir sistemin matematiksel modeli en temel düzeyde doğa yasalarına dayalı olarak veya deneysel veriler kullanılmak suretiyle kurulur. Newton'un hareket yasalarının kullanımı, titreşim hareketi yapan mekanik bir sistemin modellenmesinde en çok tercih edilen yöntemlerden biridir.

Literatürde SVR'ler için iki ya da daha yüksek serbestlik derecesine sahip bazı dinamik modeller geliştirilmiştir [236-238]. Şekil 2. 37'de SVR dişlileri için dinamik model (a) ve dişlilerde ortaya çıkan kuvvetler (b) görülmektedir [237]. Buna göre φ_1 ve φ_2

dişlilere ait açısıl yer değıştirme miktarları r_1 ve r_2 yarıçap değeri ve γ sonsuz vidanın eğim açısı olmak üzere mekanizmanın çevrim oranı (u) aşağıdaki gibi yazılabilir [237, 238].

$$u = \frac{\frac{d\varphi_1}{dt}}{\frac{d\varphi_2}{dt}} = \frac{r_2}{r_1 \tan \gamma} \quad (2.17)$$



Şekil 2.37. Dinamik model (a) ve dişlilerde ortaya çıkan kuvvetler (b) [237]

Şekil 2.37'ye göre SVR dişlilerine ait hareket denklemleri Newton'un ikinci kanuna istinaden aşağıdaki gibi yazılabilir. Burada J_1 ve J_2 atalet momentlerini M_1 ve M_2 giriş ve çıkış momentlerini, d kontak noktasındaki burulma sönüm oranını, k burulma sertliğini, c katsayıları ise göreceli açılıarı temsil etmektedir [237, 238].

$$J_1 \frac{d^2 \varphi_1}{dt^2} + dc_1 \left(\frac{d\varphi_1}{dt} - u \frac{d\varphi_2}{dt} \right) + kc_1 (\varphi_1 - u\varphi_2) = M_1 + \text{sign}(\Delta\varphi) kc_2 \frac{\delta}{2} \quad (2.18)$$

$$J_2 \frac{d^2 \varphi_2}{dt^2} + dc_3 \left(\frac{d\varphi_1}{dt} - u \frac{d\varphi_2}{dt} \right) + kc_3 (\varphi_1 - u\varphi_2) = M_2 - \text{sign}(\Delta\varphi) kc_4 \frac{\delta}{2} \quad (2.19)$$

Güç ve hareket iletimi esnasında dişler arasında oluşan boşluk (δ) dikkate alınarak temas noktasındaki $\Delta\varphi$ göreceli açısal yer değişimi ve Δs normal doğrultudaki yer değiştirme aşağıdaki gibi yazılabilir [237, 238].

$$\Delta\varphi = \varphi_1 - u\varphi_2 = \varphi_1 - \frac{r_2\varphi_2}{r_1 \tan \gamma} \quad (2.20)$$

$$\Delta s = \cos \alpha (r_1\varphi_1 \sin \gamma - r_2\varphi_2 \cos \gamma) = r_1 \cos \alpha \sin \gamma \Delta\varphi \quad (2.21)$$

Eğer $|\Delta s| \leq \delta/2$ ise sonsuz vida ve bronz çark dişlileri birbirine temas etmez ve her iki alt sistem birbirinden bağımsız hareket eder. Bu durumda $c_1 = c_2 = c_3 = c_4 = 0$ olur. Eğer $|\Delta s| > \delta/2$ ise sonsuz vida ve bronz çark dişlileri birbirini kavrar, güç ve hareket iletimi meydana gelir. Burada ρ sürtünme açısı olmak üzere sürtünme katsayısı $\mu = \tan \rho$ denklemi ile tanımlanır ve c katsayıları aşağıdaki gibi yazılır [237].

$$c_1 = \frac{r_1^2 \cos^2 \alpha \sin \gamma \sin[\gamma + \rho \text{sign}(\Delta\varphi) \text{sign}(\frac{d\varphi_1}{dt})]}{\cos \rho} \quad (2.22)$$

$$c_2 = \frac{r_1 \cos \alpha \sin[\gamma + \rho \text{sign}(\Delta\varphi) \text{sign}(\frac{d\varphi_1}{dt})]}{\cos \rho} \quad (2.23)$$

$$c_3 = \frac{r_1 r_2 \cos^2 \alpha \sin \gamma \cos[\gamma + \rho \text{sign}(\Delta\varphi) \text{sign}(\frac{d\varphi_1}{dt})]}{\cos \rho} \quad (2.24)$$

$$c_4 = \frac{r_2 \cos \alpha \cos[\gamma + \rho \text{sign}(\Delta\varphi) \text{sign}(\frac{d\varphi_1}{dt})]}{\cos \rho} \quad (2.25)$$

Dişli çarkların üzerindeki burulma momentleri ile göreceli açısal yer değişimleri arasında lineer olmayan bir ilişkinin var olduğu yukarıdaki denklemlerden görülmektedir. Eğer burulma momentlerinin ve c katsayılarının sabit olduğu kabul edilir ve $M'_1 = M_1 + \text{sign}(\Delta\varphi)kc_2 \frac{\delta}{2}$ ve $M'_2 = M_2 - \text{sign}(\Delta\varphi)kc_4 \frac{\delta}{2}$ tanımlamaları yapılırsa, (2.18) ve (2.19)'daki hareket denklemlerinin ikinci dereceden sabit katsayılı homojen olmayan lineer diferansiyel denklem sistemi oldukları varsayılabilir ve küçük salınım değerleri için geçerli olmak üzere bölgesel bir çözüm bulunabilir. Bu doğrultuda (2.18) ve (2.19)'daki denklemler matris formunda (2.25)'teki gibi yazılabilir.

$$\begin{bmatrix} J_1 & 0 \\ 0 & J_2 \end{bmatrix} \begin{bmatrix} \frac{d^2\varphi_1}{dt^2} \\ \frac{d^2\varphi_2}{dt^2} \end{bmatrix} + \begin{bmatrix} c_1d & -uc_1d \\ c_3d & -uc_3d \end{bmatrix} \begin{bmatrix} \frac{d\varphi_1}{dt} \\ \frac{d\varphi_2}{dt} \end{bmatrix} + \begin{bmatrix} c_1k & -uc_1k \\ c_3k & -uc_3k \end{bmatrix} \begin{bmatrix} \varphi_1 \\ \varphi_2 \end{bmatrix} = \begin{bmatrix} M'_1 \\ M'_2 \end{bmatrix} \quad (2.25)$$

$$[J] = \begin{bmatrix} J_1 & 0 \\ 0 & J_2 \end{bmatrix}; [D] = \begin{bmatrix} c_1d & -uc_1d \\ c_3d & -uc_3d \end{bmatrix}; [K] = \begin{bmatrix} c_1k & -uc_1k \\ c_3k & -uc_3k \end{bmatrix}; [M] = \begin{bmatrix} M'_1 \\ M'_2 \end{bmatrix} \quad (2.26)$$

Eğer (2.26)'deki tanımlamalar yapılırsa matris formundaki hareket denklemleri (2.27)'te olduğu gibi daha sade bir şekilde yazılabilir. Buradan yola çıkarak sistemin durum-uzay modeline ait durum (2.28) ve çıkış denklemi (2.29) aşağıdaki gibi elde edilir.

$$[J] \left\{ \frac{d^2\varphi}{dt^2} \right\} + [D] \left\{ \frac{d\varphi}{dt} \right\} + [K] \{\varphi\} = [M] \quad (2.27)$$

$$\frac{d\varphi}{dt} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ [-J^{-1}K] & [-J^{-1}D] \end{bmatrix} \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \frac{d\varphi_1}{dt} \\ \frac{d\varphi_2}{dt} \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ [-J^{-1}] \end{bmatrix} [M] \quad (2.28)$$

$$y = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \frac{d\varphi_1}{dt} \\ \frac{d\varphi_2}{dt} \end{bmatrix} \quad (2.29)$$

Kurulan SVR dinamik modelinin dişli çarkların açısal hızlarına, atalet momentlerine, geometrik ölçülerine, giriş ve çıkış momentlerine, motor momenti ve yükleme oranına, sertlik katsayılarına ve sönümlenme oranlarına, kontak bölgesindeki sürtünme katsayısına ve dişli çarklar arasındaki diş boşluğuna bağlı olduğu görülmektedir. Sadece dişli çark çiftinin hesaba katıldığı dinamik model iki serbestlik dereceli ve lineer olarak kabul edilip analiz yapılmıştır. Dişli çarkların yataklanmasında kullanılan rulmanların, redüktör gövdesinin, deney düzeneğindeki diğer mekanik elemanların, şase ve zemin bağlantılarının dikkate alınması ve yüksek serbestlik derecesinin seçilmesiyle daha gerçekçi bir dinamik model kurulabilir. Bunun yanında dişli çarklar arasındaki elastohidrodinamik yağlama rejiminin dinamik modele etkisi de göz önüne alınmalıdır. Ancak bu doğrultuda yapılacak ön kabullerin çokluğu ve analizlerin karmaşıklığı düşünüldüğünde, dinamik modelin kurulması için sistemin giriş ve çıkış sinyallerinin ölçülmesine dayalı bir metot olan sistem tanılamasının kullanılmasının daha uygun olduğu görülebilir [239-242]. Ancak sistem tanılama daha ileri düzey hesaplar ve detaylı ölçümler gerektirdiği için bu tez çalışmasının kapsamını aşmakta olup daha sonra yapılacak müstakil bir çalışmanın konusudur.


3. BULGULAR

3.1. Titreşim Analizi Sonuçları

Yapılan deneysel çalışmalarda sağlam, aşınma (A1), yüzey yorgunluğu (A2) ve dişli kırılması (A3) arızasına sahip SVR numuneleri üzerinden farklı çalışma koşulları altında ivmeölçer ile titreşim verileri toplanmıştır. Toplanan verilerin hem zaman hem de frekans bölgesinde analizi yapılmış ve her bir çalışma koşulu için kare ortalamalarının kökü (*RMS*), standart sapma (*SS*), varyans (*VAR*), çarpıklık katsayısı (*ÇK*), basıklık katsayısı (*BK*), frekans merkezi (*FM*), frekans *RMS* değeri (*RMSF*) ve frekans varyansının karekökü (*VKF*) hesaplanarak grafiklerle gösterilmiştir.

3.1.1. Zaman Bölgesi


Şekil 3.1’de RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden 0-1.3 s zaman aralığında elde edilen ham titreşim değişimleri görülmektedir.



Şekil 3.1. RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği

Şekilden görüldüğü gibi arızalı redüktörlerin ivme değerleri sağlam redüktörden daha yüksek çıkmıştır. 0–750 Hz frekans aralığında, S redüktörüne ait ivme değerleri -10 m/s^2 ile 20 m/s^2 arasında değişirken A1 redüktörüne ait ivme değerleri -38 m/s^2 ile 38 m/s^2 arasında değişmektedir. Ayrıca, A2 redüktörüne ait ivme değerlerinin -26 m/s^2 ile 30 m/s^2 arasında; A3 redüktörüne ait ivme değerlerinin ise -30 m/s^2 ile 32 m/s^2 arasında değiştiği görülmektedir.


Şekil 3.2’de RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden 0-1.3 s zaman aralığında elde edilen ham titreşim değişimleri görülmektedir. S redüktörüne ait ivme değerleri -28 m/s^2 ile 31 m/s^2 arasında değişirken A1 redüktörüne ait ivme değerleri -32 m/s^2 ile 40 m/s^2 arasında değişmektedir. Ayrıca, A2 redüktörüne ait ivme değerlerinin -35 m/s^2 ile 40 m/s^2 arasında; A3 redüktörüne ait ivme değerlerinin ise -40 m/s^2 ile 38 m/s^2 arasında değiştiği görülmektedir.



Şekil 3.2. RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği

Şekil 3.3’te RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden 0-1.3 s zaman aralığında elde edilen ham titreşim değişimleri görülmektedir. S redüktörüne ait ivme değerleri -30 m/s^2 ile 28 m/s^2 arasında değişirken A1 redüktörüne ait ivme değerleri -35 m/s^2 ile 39 m/s^2 arasında değişmektedir. Ayrıca, A2 redüktörüne ait ivme

değerlerinin -35 m/s^2 ila 38 m/s^2 arasında; A3 redüktörüne ait ivme değerlerinin ise -30 m/s^2 ila 39 m/s^2 arasında değiştiği görülmektedir.



Şekil 3.3. RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı titreşim grafiği

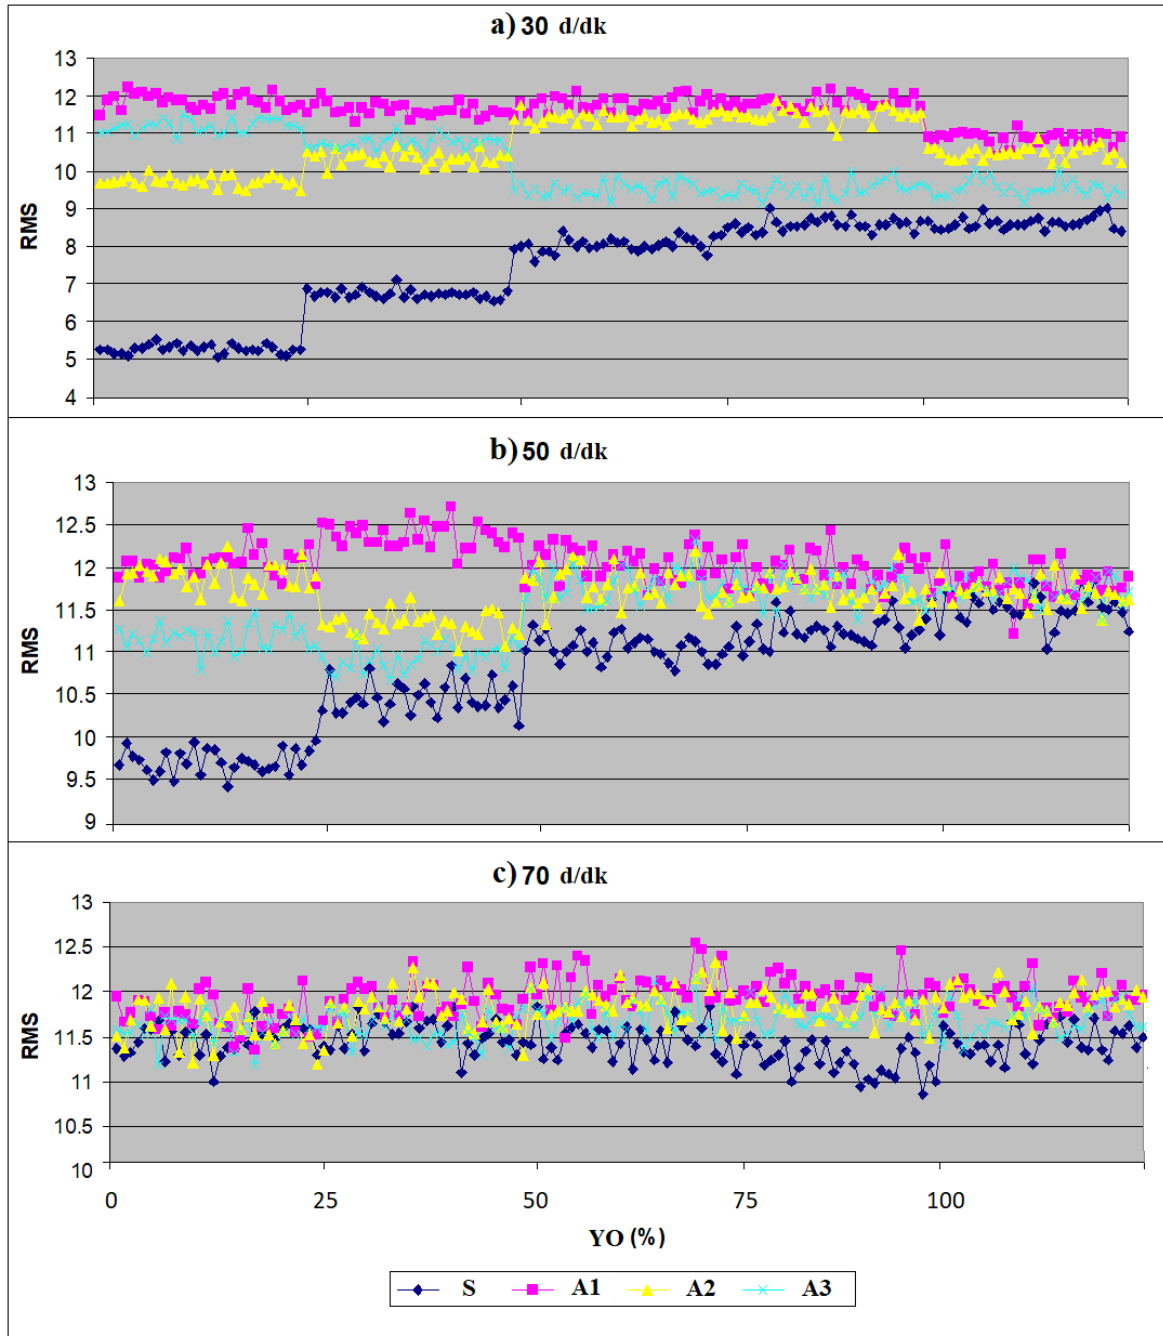
S redüktörü için YO ve RÇH artışı ivme değerlerini %98 oranında arttırmıştır. A1 redüktörü için YO ve RÇH artışı ivme değerlerini çok değiştirmemiştir. A2 redüktörü için YO ve RÇH artışı ivme değerlerini %30 oranında arttırmıştır. A3 redüktörü için YO ve RÇH artışı ivme değerlerini %10 oranında arttırmıştır. Bununla beraber yük ve hız artışı ile sağlam ve arızalı redüktörlerin ürettikleri sinyallerin genlikleri arasındaki fark gittikçe azalmaktadır. Söz konusu fark, RÇH=70 d/dk ve YO=% 0 durumu için %2'ye kadar düşmüştür. Grafiklerde gösterilenlerin haricindeki diğer RÇH ve YO oranları için de ölçümler yapılmış ancak grafik fazlalığı nedeniyle burada yer verilmemiştir.

Sırasıyla aşınma (A1), yüzey yorgunluğu (A2) ve dişli kırılması (A3) arızasına sahip redüktörler, tüm yük ve hız koşulları altında, sağlam (S) redüktöre kıyasla daha yüksek genlikli bir titreşim davranışı göstermiştir. Ayrıca tüm çalışma koşullarında A1 redüktöründen elde edilen sinyal genlikleri A2 redüktöründen daha yüksektir. A2 redüktöründen elde edilen sinyal genlikleri ise genel olarak A3 redüktöründen daha yüksektir.


Redüktörlere ait sınıflandırma yapabilmek amacıyla farklı çalışma koşulları altındaki sağlam ve arızalı redüktörlerden zaman bölgesine ait istatistiksel özellikler olan kare ortalamalarının kökü (*RMS*), standart sapma (*SS*), varyans (*VAR*), çarpıklık katsayısı (*ÇK*) ve kurtozis (basıklık katsayısı, *BK*) değerleri her bir çalışma durumu için ayrı ayrı hesaplanmıştır.

Redüktörler için 5 farklı YO (%0; %25; %50; %75; %100) ve 3 farklı RÇH (30 d/dk; 50 d/dk; 70 d/dk) oranı olması nedeniyle toplam $5 \times 3 = 15$ çalışma durumu vardır. Her bir çalışma durumu için 30 ayrı ölçüm yapıldığından, $15 \times 30 = 450$ adet titreşim sinyali ölçümü yapılmıştır. Bu ölçümlerin her birinden çıkarılan öznitelik değerleri Şekil 3.4, Şekil 3.5, Şekil 3.6, Şekil 3.7 ve Şekil 3.8'de verilmiştir.


Şekil 3.4 *RMS* değerlerinin, Şekil 3.5 *SS* değerlerinin ve Şekil 3.6 *VAR* değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Belirli bir yük ve hız durumunda *VAR* değeri *SS* değerinin karesi olduğundan, ayrıca *RMS* ve *SS* değerleri birbirine çok yakın çıktığı için üç öznitelik grafiği birlikte yorumlanabilir. Buna göre hem sağlam hem de arızalı redüktörlere ait *RMS*, *SS* ve *VAR* değerleri YO ve RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile farklı redüktörlere ait *RMS*, *SS* ve *VAR* değerleri arasındaki fark gittikçe azalmıştır. A1 redüktörüne ait *RMS*, *SS* ve *VAR* değerleri, genel olarak S redüktöründen %20 diğer redüktörlerden ise %10 daha yüksek çıkmıştır. A2 redüktörüne ait *RMS*, *SS* ve *VAR* değerleri ise ilk iki yük ve hız durumu (RÇH=30 d/dk, YO=%0 ve RÇH=30 d/dk, YO=%25) dışında A3 redüktöründen daha yüksektir. S redüktörüne ait *RMS*, *SS* ve *VAR* değerlerinin ise diğer redüktörlerden daha küçük olduğu görülmektedir. *RMS*, *SS* ve *VAR* büyüklükleri en küçük değerini RÇH=30 d/dk aralığında S redüktöründe, en büyük değerini ise RÇH=50 d/dk aralığında A1 redüktöründe almıştır. RÇH değeri 50 d/dk ve 70 d/dk olduğunda seçilen özniteliklerin (*SS*, *VAR*, *RMS*) ayırt etme kabiliyeti düşmektedir (Şekil 3.4-5-6).



Şekil 3.4. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *RMS* değerleri




Şekil 3.5. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait SS değerleri




Şekil 3.6. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait VAR değerleri

Şekil 3.7 $\dot{C}K$ değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Buna göre yük ve hız artışı ile beraber redüktörlerin $\dot{C}K$ değerleri de genel olarak azalmış ve birbirine yaklaşmıştır. RÇH=30d/dk ve RÇH=50d/dk aralığı için farklı YO'lardaki S redüktörüne ait $\dot{C}K$ değerlerinin diğer redüktörlerden 5 kat daha yüksek olduğu görülmektedir. RÇH=70d/dk içinse A3 redüktörüne ait $\dot{C}K$ değerleri diğer redüktörlerden daha yüksek çıkmıştır. A3 redüktörüne ait $\dot{C}K$ değerleri, RÇH=30 d/dk ve YO=%0 durumu dışındaki hız ve yük oranlarında A1 ve A2 redüktörlerinden ortalama olarak daha yüksektir. RÇH=30d/dk'daki çoğu yükleme durumu için A2 redüktörüne ait $\dot{C}K$ değerlerinin A1 redüktörüne ait değerlerden daha yüksek olduğu görülmektedir. $\dot{C}K$, en belirgin, ayırt edici değerlerini S redüktöründe, RÇH=30 d/dk aralığında, en küçük değerlerini ise aynı aralıkta A1 redüktöründe almıştır. Buna rağmen RÇH=50 d/dk ve RÇH=70 d/dk aralığı için farklı YO'larda A1 ve A2 redüktörlerine ait $\dot{C}K$ değerlerinin ayırt ediciliği düşük olarak gözlenmiştir.

Şekil 3.8 BK değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Buna göre yük ve hız artışı ile beraber redüktörlerin BK değerleri de genel olarak azalmış ve birbirine yaklaşmıştır. RÇH=30 d/dk için farklı YO'larda S redüktörüne ait BK değerleri diğer redüktörlerden 3 kat daha yüksektir. A1 ve A2 redüktörüne ait BK değerleri, RÇH=30 d/dk için ilk yükleme durumu haricinde A3 redüktöründen daha düşük ve birbirine yakındır. BK değerleri RÇH=30 d/dk ve YO=%0 durumu için S redüktöründe en yüksek düzeyine ulaşmıştır. Bunun yanında RÇH=50 d/dk ve RÇH=70 d/dk aralığı için farklı YO'larda tüm redüktörlerin BK değerlerinin ayırt ediciliği düşük olarak gözlenmiştir.



Şekil 3.7. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait ÇK değerleri



Şekil 3.8. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *BK* değerleri


Sağlam ve arızalı redüktörlerden elde edilen titreşim sinyallerinin zaman bölgesine ait istatistiksel özellikleri yani zaman bölgesindeki öznitelikler farklı çalışma koşullarından ve arızanın türünden etkilenmektedir.

3.1.2. Frekans Bölgesi


Zaman bölgesinde belirlenen öznitelikler farklı çalışma ve yükleme koşullarında yeterince ayırt edici olamadığından, frekans bölgesinden öznitelikler de çıkarılmıştır. Şekil 3.9, Şekil 3.10 ve Şekil 3.11 farklı yükleme oranları (YO) ve redüktör çıkış hızları (RÇH) için, 0-750 Hz frekans aralığında S, A1, A2 ve A3 redüktörlerinden elde edilen güç spektral yoğunluğu (GSY) dağılımlarını göstermektedir. Buna göre, hem yük ve hız artışı ile hem de arızanın meydana gelişiyile beraber GSY değerleri artmıştır.

Şekil 3.9'da görüldüğü gibi RÇH=30 d/dk ve YO=%0 için S redüktörüne ait en yüksek GYS değeri 140 Hz frekansında $0.5 \text{ (m/s}^2\text{)}^2\text{/Hz}$ olarak çıkmıştır. A1 ve A2 redüktörlerine ait GSY değerlerinde arızanın oluşumu ile beraber 0-700 Hz aralığında genel bir artış meydana gelmiştir. Bu aralıkta A1 redüktörüne ait en yüksek GYS değeri $1.3 \text{ (m/s}^2\text{)}^2\text{/Hz}$, A2 redüktörüne ait en yüksek GSY değeri ise $1.8 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'dir. A3 redüktörüne ait GSY grafiğinde ise arıza sonucu sadece 40 Hz civarında $14 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'lik aşırı bir değer artışı artış söz konusudur.

Şekil 3.10'da RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerine ait GSY dağılımları görülmektedir. RÇH ve YO'nun kademeli olarak arttırılmasıyla beraber özellikle 400-650 Hz aralığında S ve A1 redüktörlerine ait GSY değerlerinde genel bir artış olmuştur. Bu aralıkta S redüktörüne ait en büyük GSY değeri $1 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'dir. A1 redüktörüne ait en büyük GSY değeri ise $1.4 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'dir. A3 redüktörüne ait değerlerde 0-700 Hz aralığında genel bir yükseliş söz konusudur. Ancak 40 Hz frekansındaki değer $1 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'e düşmüştür. A3 redüktörüne ait en yüksek değer $1.6 \text{ (m/s}^2\text{)}^2\text{/Hz}$ olarak çıkmıştır. A2 redüktörüne ait değerlerde ise 200–700 Hz frekans aralığında genel bir artış söz konusudur. Bu aralıktaki en büyük GSY değeri $1 \text{ (m/s}^2\text{)}^2\text{/Hz}$ 'dir.




Şekil 3.9. RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği



Şekil 3.10. RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği

Şekil 3.11’de RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerine ait *GSY* dağılımları görülmektedir. RÇH ve YO’nun kademeli olarak arttırılmasıyla beraber özellikle 400-650 Hz aralığında S ve A1 redüktörlerine ait *GSY* değerlerinde genel bir artış olmuştur. Bu aralıkta S redüktörüne ait en büyük *GSY* değeri 1.2 (m/s²)²/Hz’dir. A1 redüktörüne ait en büyük *GSY* değeri ise 1.5 (m/s²)²/Hz’dir. A3 redüktörüne ait *GSY* değerleri özellikle 0-100 Hz aralığında artmış olup bu aralıktaki en yüksek değer 3.8 (m/s²)²/Hz olarak çıkmıştır. A2 redüktörüne ait değerlerde ise 200–700 Hz frekans aralığında genel bir artış söz konusudur. Bu aralıktaki en büyük *GSY* değeri 1.4 (m/s²)²/Hz’dir.




Şekil 3.11. RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği

Farklı çalışma koşulları altındaki sağlam ve arızalı redüktörlerden elde edilen frekans bölgesine ait *GSY* dağılımları üzerinden istatistiksel özellikler olan frekans merkezi (*FM*), frekans *RMS* değeri (*RMSF*) ve frekans varyansının karekökü (*VKF*) öznitelikler olarak hesaplanmıştır. Zaman bölgesinde yapılan hesaplara benzer şekilde, 5 farklı YO ve 3 farklı RÇH oranı olması nedeniyle 5x3=15 çalışma durumu için toplam 15x30=450 adet *GSY* dağılımı elde edilmiştir.


Şekil 3.12 *FM* değerlerinin *YO* ve *RÇH*'a göre değişimini göstermektedir. Buna göre *S* redüktörüne ait *FM* değerleri *YO* ve *RÇH* artışıyla beraber yaklaşık olarak 6 kat artmıştır. *A1* redüktörüne ait *FM* değerleri 0.35 civarında olup *YO* ve *RÇH* artışıyla beraber çok değişmemiştir ancak diğer redüktörlerin *FM* değerlerinden daha yüksektir. *A2* redüktörüne ait *FM* değerleri de *YO* ve *RÇH* artışıyla beraber genel olarak çok değişmemiştir. *A3* redüktörüne ait *FM* değerleri ise *RÇH*=30 d/dk ve *RÇH*=50 d/dk aralıkları için 0.2 ila 0.35 arasında değişmekte olup *S* redüktöründen daha yüksektir. Genel olarak yük ve hız artışı ile beraber farklı redüktörlere ait *FM* değerleri arasındaki fark gittikçe azalmış *RÇH*=70 d/dk aralığındaki ilk *YO*'larda bu fark en aza inmiştir. Bu nedenle *FM* değerlerinin *RÇH*=30 d/dk aralığındaki *YO*'lar için ayırt ediciliği yüksektir. Ancak *RÇH*=50 d/dk ve *RÇH*=70 d/dk aralığı için *YO* arttıkça *FM* değerlerinin ayırt ediciliği düşmektedir.

Şekil 3.13'te *RMSF* değerlerinin *RÇH* ve *YO*'ya göre değişimi görülmektedir. Genel olarak yük ve hız artışı ile beraber farklı redüktörlere ait *RMSF* değerleri arasındaki fark gittikçe azalmış, *RÇH*=70 d/dk, *YO*=%0 durumu için ayırt edicilik en aza inmiştir. *S* redüktörüne ait *RMSF* değerleri *YO* ve *RÇH* artışıyla beraber yaklaşık %40 oranında artmıştır. Bu redüktöre ait *RMSF* değerleri *RÇH*=30 d/dk aralığında 0.3 civarında iken, *RÇH*=70 d/dk aralığında ortalama olarak 0.55 seviyesine çıkmıştır. *A1* redüktörüne ait *RMSF* değerleri *YO* ve *RÇH* artışıyla beraber %10-15 oranında azalmıştır. *A2* redüktörüne ait *RMSF* değerleri de *YO* ve *RÇH* artışıyla beraber çok değişmemiştir. Bu redüktör için *RMSF* değerleri özellikle *RÇH*=30 d/dk aralığı için *A1* redüktöründen daha küçük, *S* redüktöründen daha büyüktür. *A3* redüktörüne ait *RMSF* değerleri *RÇH*=30 d/dk aralığında *YO* artışı ile %15-20 oranında azalmış, daha yüksek *YO* ve *RÇH* durumlarında çok değişmemiştir. *RMSF* değerleri *RÇH*=30 d/dk aralığında, en büyük ayırt edicilik özelliğine sahiptir. *YO* ve *RÇH* artışı ile birlikte *RMSF* değerlerinin ayırt ediciliği azalmaktadır.


Şekil 3. 14'de *VKF* değerlerinin *RÇH* ve *YO*'ya göre değişimi görülmektedir. *VKF* değerlerinin değişimi ve ayırt ediciliği *RMSF* değerlerine benzer şekilde çıkmıştır. Buna göre yük ve hız artışı ile beraber farklı redüktörlere ait *VKF* değerleri arasındaki fark gittikçe azalmış, *RÇH*=70 d/dk, *YO*=%0 durumunda bu fark en aza inmiştir. *YO* ve *RÇH* artışı *VKF* özneliliğinin ayırt edici özelliğini ortadan kaldırmaktadır.



Şekil 3.12. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *FM* değerleri



Şekil 3.13. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *RMSF* değerleri



Şekil 3.14. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait VKF değerleri

Sağlam ve arızalı redüktörlerden elde edilen titreşim sinyallerinin frekans bölgesine ait öznitelikleri de farklı çalışma koşullarından ve arızanın türünden etkilenmektedir.

3.2. Ses Analizi Sonuçları

Yapılan deneysel çalışmalarda sağlam ve farklı arızalara sahip SVR numuneleri üzerinden farklı yükleme oranları (YO) ve redüktör çıkış hızları (RÇH) için mikrofona ses verileri toplanmıştır. Toplanan verilerin hem zaman hem de frekans bölgesinde analizi yapılmış ve her bir çalışma koşulu için öznitelikler hesaplanarak grafiklerle gösterilmiştir.


3.2.1. Zaman Bölgesi

Farklı yükleme oranları (YO) ve redüktör çıkış hızları (RÇH) için, 0-1 s zaman aralığında S, A1, A2 ve A3 redüktörlerinden elde edilen ses basınç düzeylerine ait grafikler toplanmış ancak grafik fazlalığına neden olmamak için burada sadece RÇH=30 d/dk ve YO=%0; RÇH=50 d/dk ve YO=%50; RÇH=70 d/dk ve YO=%100 durumlarına ait grafikler verilmiştir.


Şekil 3.15'te RÇH=30 d/dk ve YO=%0 için redüktörlerinden elde edilen zamana bağlı ses basınç düzeyi grafikleri görülmektedir. Buna göre A3 redüktörü, 0-1900 Hz frekans bandında, 0-1 sn zaman aralığı için -25 dB ila 65 dB arasında değişen en yüksek ses basınç düzeylerine sahiptir. Aynı koşullar altında S redüktörü, -25 dB ila 60 dB arasında değişen en düşük basınç düzeylerine sahiptir. A2 redüktörüne ait basınç düzeyleri ise -13 dB ila 60 dB arasında değişmektedir ve genellikle A1'e ait değerlerden daha büyüktür.

RÇH=50 d/dk ve YO=%50 durumunda ise A3 redüktörü, aynı frekans ve zaman aralığı için -13 dB ila 75 dB arasında değişen en yüksek basınç düzeylerine sahiptir. Bu koşullar altında S redüktörü, -10.1 dB ila 68 dB arasında değişen en düşük basınç düzeylerine sahiptir. A2 redüktörüne ait değerler ise -9 dB ila 72 dB arasında değişmektedir ve genellikle A1'e ait değerlerden daha büyüktür (Şekil 3.16).


RÇH=70 d/dk ve YO=%100 durumu için tüm redüktörlere ait ses basınç değerleri en yüksek düzeyine ulaşmıştır. Bu koşullar altında maksimum ses basıncı S redüktörü için 75 dB; A1 redüktörü için 80 dB; A2 redüktörü için 89 dB; A3 redüktörü içinse 82 dB olarak ölçülmüştür (Şekil 3.17).



Şekil 3.15. RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği



Şekil 3.16. RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği




Şekil 3.17. RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen zamana bağlı ses basıncı grafiği

Yapılan ölçümlerde hem sağlam hem de arızalı redüktörlere ait ses basıncı düzeylerinin YO ve RÇH artışıyla beraber belirgin bir şekilde arttığı görülmüştür. Genel olarak A3 redüktörüne ait basınç değerleri A2 redüktöründen, A2 redüktörüne ait basınç değerleri de A1 redüktöründen daha büyüktür. S redüktörü en küçük değerlere sahip ses sinyallerini üretmiştir.


Ses verilerinin sınıflandırılabilmesi için istatistiksel özellikler olan kare ortalamalarının kökü (*RMS*), standart sapma (*SS*), varyans (*VAR*), çarpıklık katsayısı (*ÇK*) ve kurtosis (basıklık katsayısı, *BK*) değerleri öznitelikler olarak belirlenmiş ve titreşim analizindeki prosedüre benzer bir biçimde her bir çalışma durumu için ayrı ayrı hesaplanmıştır. Farklı YO ve RÇH değerlerindeki 15 çalışma durumu için 30'ar adet olmak üzere toplam 450 adet öznitelik verisi Şekil 3.18, Şekil 3.19, Şekil 3.20, Şekil 3.21 ve Şekil 3.22'deki grafiklerde görülmektedir.

Şekil 3.18 *RMS* değerlerinin YO ve RÇH'a göre değişimi göstermektedir. Buna göre redüktörlere ait *RMS* değerleri YO ve RÇH artışı ile beraber artmıştır. *RMS* değerleri S, A1, A2 ve A3 redüktörleri için farklı dağılım gösterdiğinden ayırt edici özelliği yüksektir.




Şekil 3.18. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *RMS* değerleri

Şekil 3.19 *SS* ve Şekil 3.20 *VAR* değerlerinin YO ve RÇH'a göre değişimi göstermektedir. Grafikler incelendiğinde, *SS* ve *VAR* değerlerinin S, A1, A2 ve A3 durumları için ayırt edici özelliklerinin tek başına yeterli olmadığı görülmektedir.




Şekil 3.19. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait SS değerleri



Şekil 3.20. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait VAR değerleri


Şekil 3.21 Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $\dot{C}K$ değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Genel olarak redüktörlerin

hepsi için tüm hız ve yük oranlarında ölçülen $\dot{C}K$ değerleri birbirine yakındır. Bu nedenle tek başına ayırt edici özellik olarak yeterli olmadığı görülmektedir.



Şekil 3.21. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $\dot{C}K$ değerleri

Şekil 3.22 Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait BK değerlerini göstermektedir. Burada da, BK değerinin tek başına ayırt edici özellik olarak yeterli olmadığı görülmektedir.




Şekil 3.22. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait BK değerleri

Sağlam ve arızalı redüktörlerden elde edilen ses sinyallerinin zaman bölgesine ait istatistiksel özellikleri yani zaman bölgesindeki öznitelikler farklı çalışma koşullarından ve arızanın türünden etkilenmektedir.

3.2.2. Frekans Bölgesi


Farklı yükleme oranları (YO) ve redüktör çıkış hızları (RÇH) için *GSY* grafikleri incelenmiş ve RÇH=30 d/dk, RÇH=50 d/dk ve RÇH=70 d/dk için farklı YO'larda S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* değişimleri Şekil 3.23, Şekil 3.24, Şekil 3.25'te sunulmuştur. Grafikler incelendiğinde, hem yük ve hız artışı ile hem de arızanın meydana gelişiyile beraber *GSY* değerlerinin değiştiği gözlenmiştir.




Şekil 3.23. RÇH=30 d/dk ve YO=0 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği

Özellikle RÇH değerinin artışı ile sağlam ve arızalı redüktörlerin 0-500 Hz bandında ürettiği *GSY* değerleri artmıştır. Hız ve yükleme oranı artışı ile beraber bu frekans aralığında A3 redüktörüne ait en büyük *GSY* değeri 37 dB/Hz'den 81 dB/Hz'e; A2 redüktörüne ait en büyük *GSY* değeri 46 dB/Hz'den 88 dB/Hz'e; A1 redüktörüne ait en

büyük *GSY* değeri de 39 dB/Hz'den 54 dB/Hz'e yükselmiştir. S redüktörüne ait en büyük *GSY* değeri de 36 dB/Hz'den 51 dB/Hz'e çıkmıştır.




Şekil 3.24. RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği




Şekil 3.25. RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen *GSY* grafiği


Farklı çalışma koşulları altındaki redüktörlerden elde edilen *GSY* ölçümlerinden frekans bölgesine ait istatistiksel özellikler olan frekans merkezi (*FM*), frekans *RMS* değeri (*RMSF*) ve frekans varyansının karekökü (*VKF*) değerleri öznitelik olarak her bir çalışma durumu için ayrı ayrı hesaplanmıştır (Şekil 3.26, Şekil 3.27, Şekil 3.28).



Şekil 3.26. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *FM* değerleri



Şekil 3.27. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait *RMSF* değerleri




Şekil 3.28. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait VKF değerleri

S, A1, A2 ve A3 redüktörüne ait *FM*, *RMSF* ve *VKF* değerleri YO ve RÇH artışı ile beraber benzer şekilde artmıştır. Bu nedenle birlikte değerlendirilebilirler. A3 redüktörüne ait *FM*, *RMSF*, *VKF* değerleri A2 redüktöründen ortalama olarak %2; A1 redüktöründen ortalama olarak %14; S redüktöründen ise ortalama olarak %21 daha yüksektir. *FM*, *RMS* ve *VKF* değerleri S, A1, A2 ve A3 redüktörleri için farklı dağılım gösterdiğinden ayırt edici özelliği yüksektir.


3.3. Termal Görüntü Analizi Sonuçları

Bu kısımda termal kamera görüntülerinden çıkarılan öznelikler ve bunlara ait irdemeler yer almaktadır. Farklı çalışma hızları ve yükleme oranlarında sıcaklık dağılımları incelenmiş ve görüntüler üzerinden her bir çalışma koşulu için öznelik olacak şekilde maksimum, minimum ve ortalama sıcaklık değerleri hesaplanarak grafiklerle gösterilmiştir.


Şekil 3.29, Şekil 3.30 ve Şekil 3.31, farklı yükleme oranları (YO) ve redüktör çıkış hızları (RÇH) için S, A1, A2 ve A3 redüktörlerinden elde edilen termal kamera görüntülerini göstermektedir.



Şekil 3.29. RÇH=30 d/dk ve YO=%0 için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler



Şekil 3.30. RÇH=50 d/dk ve YO=%50 için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler




Şekil 3.31. RÇH=70 d/dk ve YO=%100 için S, A1, A2 ve A3 redüktörlerinden elde edilen termal görüntüler

Tüm durumlar incelendiğinde hem sağlam hem de arızalı redüktörlere ait sıcaklık değerlerinin YO ve RÇH artışıyla beraber belirgin bir şekilde arttığı gözlenmiştir. Bununla beraber yük ve hız artışı ile sağlam ve arızalı redüktörlere ait sıcaklık dağılımları arasındaki fark gittikçe artmıştır. Söz konusu fark, RÇH=70 d/dk ve YO=% 100 durumunda en yüksek değerine ulaşmıştır. Sırasıyla aşınma (A1), yüzey yorgunluğu (A2) ve dişli kırılması (A3) arızasına sahip redüktörler, tüm yük ve hız koşulları altında, sağlam (S) redüktöre kıyasla daha fazla ısınmıştır. Ayrıca tüm çalışma koşullarında A1 redüktöründen elde edilen sıcaklık değerleri A2 redüktöründen, A2 redüktöründen elde edilen sıcaklık değerleri ise A3 redüktöründen daha yüksektir.

Farklı çalışma koşulları altındaki sağlam ve arızalı redüktörlerden elde edilen sıcaklık dağılımından $T_{min.}(^{\circ}C)$ (minimum sıcaklık), $T_{mak.}(^{\circ}C)$ (maksimum sıcaklık) ve $T_{ort.}(^{\circ}C)$ (ortalama sıcaklık) değerleri öznitelik olarak her bir çalışma durumu için ayrı ayrı hesaplanmıştır.

Farklı YO ve RÇH değerlerindeki 15 çalışma durumu için 30'ar adet olmak üzere toplam 450 adet termal görüntü elde edilmiştir. Termal görüntüler 5 saniye zaman aralıkları ile toplanmıştır. Termal görüntülerden çıkarılan sıcaklık öznitelikler titreşim ve ses analizindeki adımlar izlenerek grafiklere aktarılmıştır.

Şekil 3.32 $T_{min.}$ değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Buna göre hem sağlam hem de arızalı redüktörlere ait $T_{min.}$ değerleri YO ve RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile farklı redüktörlere ait $T_{min.}$ değerleri arasındaki fark gittikçe artmıştır. Hız ve yükleme oranı artışıyla beraber S redüktörüne ait $T_{min.}$ değeri 14.4 °C'den 16 °C'ye; A1 redüktörüne ait $T_{min.}$ değeri 13.6 °C'den 20 °C'ye; A2 redüktörüne ait $T_{min.}$ değeri 12.7 °C'den 18.3 °C'ye; A3 redüktörüne ait $T_{min.}$ değeri ise 14.9 °C'den 18 °C'ye çıkmıştır. En yüksek $T_{min.}$ değeri A1 redüktöründe, en küçük $T_{min.}$ değeri ise S redüktöründe gözlenmiştir. $T_{min.}$ değerleri S, A1, A2 ve A3 redüktörleri için farklı dağılım gösterdiğinden ayırt edici özelliği yüksektir.




Şekil 3.32. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait T_{min} değerleri


Şekil 3.33 $T_{mak.}$ değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Buna göre hem sağlam hem de arızalı redüktörlere ait $T_{mak.}$ değerleri YO ve RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile beraber farklı redüktörlere ait $T_{mak.}$ değerleri arasındaki fark gittikçe açılmıştır. A1 redüktörüne ait $T_{mak.}$ değeri yük ve hız artışıyla birlikte 75.9 °C'den 155 °C'ye çıkmıştır. A1 redüktörüne ait $T_{mak.}$ değerleri tüm çalışma koşullarında diğer redüktörlerden daha yüksektir. A2 redüktörüne ait $T_{mak.}$ değeri yük ve hız artışıyla birlikte 67.8 °C'den 122.2 °C'ye; A3 redüktörüne ait $T_{mak.}$ değeri de yük ve hız artışıyla birlikte 70.4 °C'den 101.7 °C'ye çıkmıştır. S redüktörüne ait $T_{mak.}$ değeri ise yük ve hız artışıyla birlikte 69.8 °C'den 91 °C'ye çıkmıştır. En yüksek $T_{mak.}$ değeri A1 redüktöründe, en küçük $T_{mak.}$ değeri ise S redüktöründe gözlenmiştir. $T_{mak.}$ değerleri S, A1, A2 ve A3 redüktörleri için farklı dağılım gösterdiğinden ayırt edici özelliği yüksektir.

Şekil 3.34 $T_{ort.}$ değerlerinin YO ve RÇH'a göre değişimini göstermektedir. Buna göre hem sağlam hem de arızalı redüktörlere ait $T_{ort.}$ değerleri YO ve RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile farklı redüktörlere ait $T_{ort.}$ değerleri arasındaki fark gittikçe açılmıştır. A1 redüktörüne ait $T_{ort.}$ değerlerinin tüm çalışma koşullarında diğer redüktörlerden daha yüksek olduğu görülmektedir. A1 redüktörüne ait $T_{ort.}$ değeri yük ve hız artışıyla birlikte 51 °C'den 116 °C'ye çıkmıştır. A2 redüktörüne ait $T_{ort.}$ değeri yük ve hız artışıyla birlikte 50.2 °C'den 91.8 °C'ye; A3 redüktörüne ait $T_{ort.}$ değeri de yük ve hız artışıyla birlikte 49 °C'den 77.8 °C'ye çıkmıştır. S redüktörüne ait $T_{ort.}$ değeri ise yük ve hız artışıyla birlikte 48.2 °C'den 69.1 °C'ye çıkmıştır. Buna göre A2 redüktörüne ait $T_{ort.}$ değerleri tüm çalışma koşullarında A3 redüktöründen daha büyüktür. S redüktörü en küçük $T_{ort.}$ değerlerine sahiptir.

Sağlam ve arızalı redüktörlerden elde edilen termal görüntüler incelendiğinde $T_{min.} (^{\circ}C)$, $T_{mak.} (^{\circ}C)$ ve $T_{ort.} (^{\circ}C)$ özniteliklerinin farklı çalışma koşullarından ve arızanın türünden etkilenmekle beraber, ayırt etme özelliklerinin üstün olduğu görülmektedir.



Şekil 3.33. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait $T_{mak.}$ değerleri



Şekil 3.34. Farklı çalışma koşulları altında sağlam ve arızalı redüktörlere ait T_{ort} değerleri

3.4. Yapay Zekâ (YZ) ile Arıza Tespiti ve Arızaların Sınıflandırılması

Yapılan deneysel çalışmalarda sağlam ve farklı arızalara sahip SVR numuneleri üzerinden farklı çalışma koşulları altında toplanan titreşim ve ses verilerinden ve ayrıca termal kamera görüntülerinden çıkarılan öznitelikler ikili sınıflandırma ile yapay zekâ (YZ) ile arızaların tespit edilmesi ve çoklu sınıflandırma ile arızaların gruplandırılması amacıyla kullanılmıştır.

YZ yaklaşımında kullanılan veri seti içerisinde toplam 19 adet öznitelik sütunu bulunmaktadır. Bu öznitelik sütunlarından 8 tanesi titreşim ölçümlerinden, 8 tanesi ses ölçümlerinden ve 3 tanesi de termal kamera görüntülerinden elde edilmiştir. Her bir öznitelik sütunu 450 satırlık veriden oluşmaktadır.

Buna göre S, A1, A2, A3 redüktörlerinden her biri 450 satıra ve 19 sütuna sahip bir matris ile temsil edilmektedir.

3.4.1. Yapay Sinir Ağları (YSA)

YSA ile arıza tespiti ve sınıflandırması esasında bir örüntü tanıma problemidir. Buna göre girişler yani öznitelik değerleri hedef kategorilerine göre sınıflandırılır. Hedef kategorileri sağlam ya da arızalı redüktörlerdir.


3.4.1.1. İkili Sınıflandırma: Arıza Tespiti

SVR'lerde arıza tespiti yapılırken 1 gizli katmana ve 1 çıkış katmanına sahip ileri beslemeli bir YSA mimarisi kullanılmıştır. Arıza varlığının tespit edilmesi işleminde arıza sınıfının bilinmesine gerek olmadığından YSA çıkışları S (sağlam redüktör) ve A (arızalı redüktör) olarak ikiye ayrılmıştır.

Şekil 3.35 eğitim döngü sayısına (D) karşılık hata değerlerinin değişimini gösteren YSA performans eğrisidir. Belirli bir rasgele değişken veya olaylar dizisi için iki olasılık dağılımı arasındaki farkın bir ölçüsü olarak tanımlanan çapraz entropi (ÇE) değerinin düşük olması eğitim ve doğrulama sürecinin başarılı olduğu anlamına gelmektedir.

Buna göre en iyi doğrulama 64 döngüde gerçekleşmiştir. Bu noktada çapraz entropi (ÇE) değeri 0.024575 olup en düşük değerindedir. Bu döngüden sonra aşırı uyum ya da aşırı öğrenme şeklinde tanımlanan olumsuzluğun önüne geçmek için eğitim

durdurulmuştur. Aşırı uyumlu ya da aşırı öğrenmiş modeller eğitim verilerine mükemmel bir şekilde uyum sağlarlar ancak gelecek verileri ya da yapılan yeni gözlemleri sınıflandırmadaki performansları düşüktür.



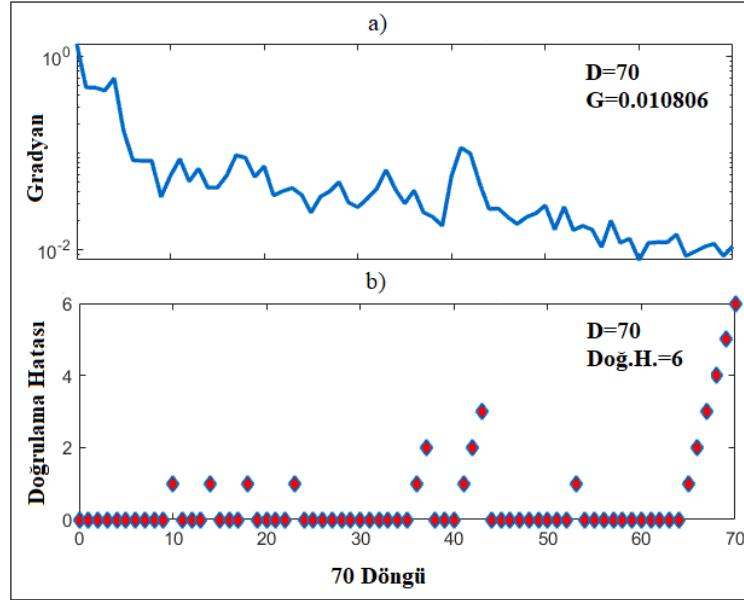
Şekil 3.35. YSA performans eğrisi

YSA'nın eğitim süreci ile ilgili istatistikler Şekil 3.36'da görülmektedir. Şekil 3.36 a) logaritmik olarak ölçülendirilmiş geri yayılım gradyanının döngü sayısına göre değişimini göstermektedir. Buna göre 70. döngüde gradyan değeri 0.010806 olarak gerçekleşmiştir. Şekil 3.36 b) ise 70 döngüde doğrulama hatasının 6'ya çıktığını göstermektedir. Bu noktada hedef fonksiyonu yerel minimum seviyesinin altına indiğinden eğitim süreci durdurulmuştur.


Şekil 3.37 eğitim, doğrulama ve test verileri için hata histogramını göstermektedir. Burada hata değerleri hedefler ile çıkışların farkı olarak gösterilmiştir. Histogramdaki her bir dikey çubuk veri setinin belirli bir bölümde bulunan örnek sayısını temsil etmektedir.

Şekil 3.38 eğitim, doğrulama, test ve genel hata matrislerini göstermektedir. Hata matrislerindeki satırlar çıkış sınıflarına yani öngörülen sınıflara karşılık gelirken sütunlar da hedef sınıflarına yani gerçek sınıflara karşılık gelmektedir. Yeşil renkli diyagonal hücreler doğru şekilde sınıflandırılmış verileri, kırmızı renkli diyagonal olmayan hücreler yanlış sınıflandırılmış verileri, açık gri renkli hücreler ise ait oldukları satır ya da sütundaki toplam yüzde oranlarını göstermektedir. Açık gri ve yeşil hücrelerin her birinde hem veri sayısı hem de veri sayısının yüzde oranı görülmektedir. Matrislerin sağ alt köşesindeki

koyu gri renkli hücreler ise yüzde olarak toplam doğruluk ya da yanlışlık oranlarını göstermektedir.



Şekil 3.36. YSA'nın eğitim durumu ile ilgili istatistikler



Şekil 3.37. Hata histogramı

		Eğitim Hata Matrisi			Doğrulama Hata Matrisi		
Çıkış Sınıfı	S	301 23.9%	8 0.6%	97.4% 2.6%	76 28.1%	3 1.1%	96.2% 3.8%
	A	2 0.2%	949 75.3%	99.8% 0.2%	0 0.0%	191 70.7%	100% 0.0%
		99.3% 0.7%	99.2% 0.8%	99.2% 0.8%	100% 0.0%	98.5% 1.5%	98.9% 1.1%
		S	A		S	A	
		Hedef Sınıfı			Hedef Sınıfı		
		Test Hata Matrisi			Genel Hata Matrisi		
Çıkış Sınıfı	S	68 25.2%	6 2.2%	91.9% 8.1%	445 24.7%	17 0.9%	96.3% 3.7%
	A	3 1.1%	193 71.5%	98.5% 1.5%	5 0.3%	1333 74.1%	99.6% 0.4%
		95.8% 4.2%	97.0% 3.0%	96.7% 3.3%	98.9% 1.1%	98.7% 1.3%	98.8% 1.2%
		S	A		S	A	
		Hedef Sınıfı			Hedef Sınıfı		

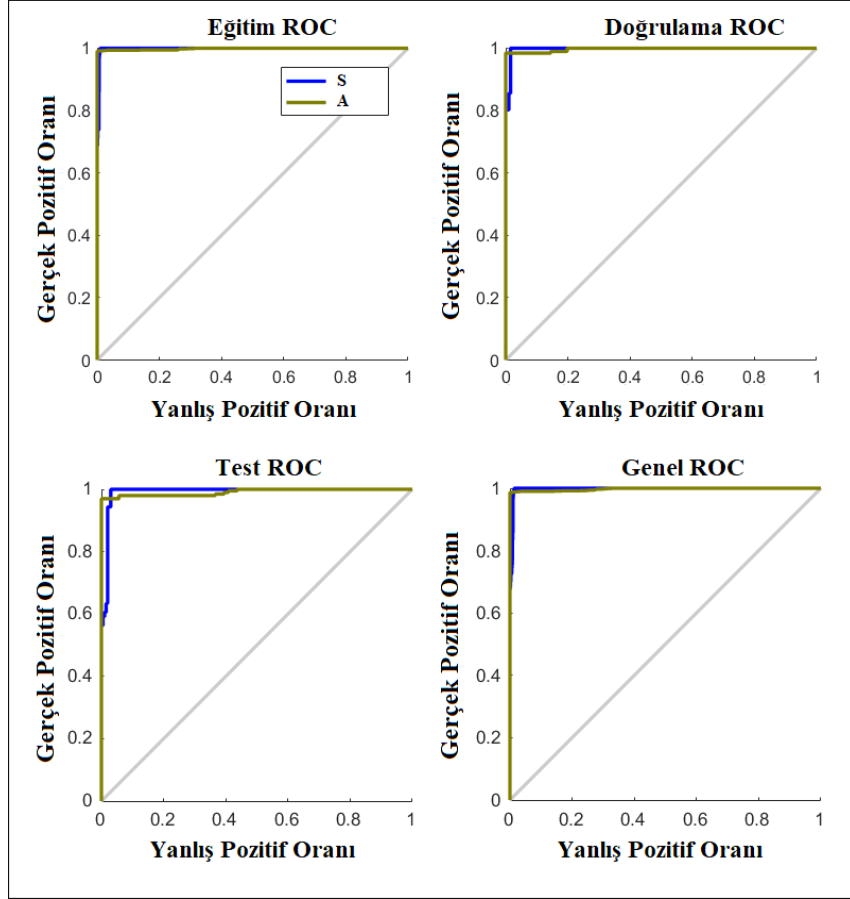
Şekil 3.38. Hata matrisleri

Hata matrislerine bakıldığında YSA yaklaşımına ait eğitim verilerinin %99.2 oranında, doğrulama verilerinin %98.9 oranında ve test verilerinin %96.7 oranında doğru sınıflandırıldığı görülmektedir. Genel hata matrisine bakıldığında ise S ve A redüktörlerine ait veriler %98.8 oranında doğru sınıflandırılmıştır. Yani arıza tespiti amacıyla kurulan YSA yaklaşımı %98.8 oranında başarılıdır. Buna karşılık YSA yaklaşımı %1.2 oranında yanlış sınıflandırma yapmıştır.

Şekil 3.39’da arıza tespiti için kurulan YSA yaklaşımına ait eğitim, doğrulama, test ve genel ROC eğrileri görülmektedir. Buna göre kurulan YSA yaklaşımının S ve A redüktörlerini sınıflandırmak için performans ölçütleri olan doğruluk, duyarlılık ve özgüllük değerleri sırasıyla 0.98, 0.96 ve 0.99’dur.

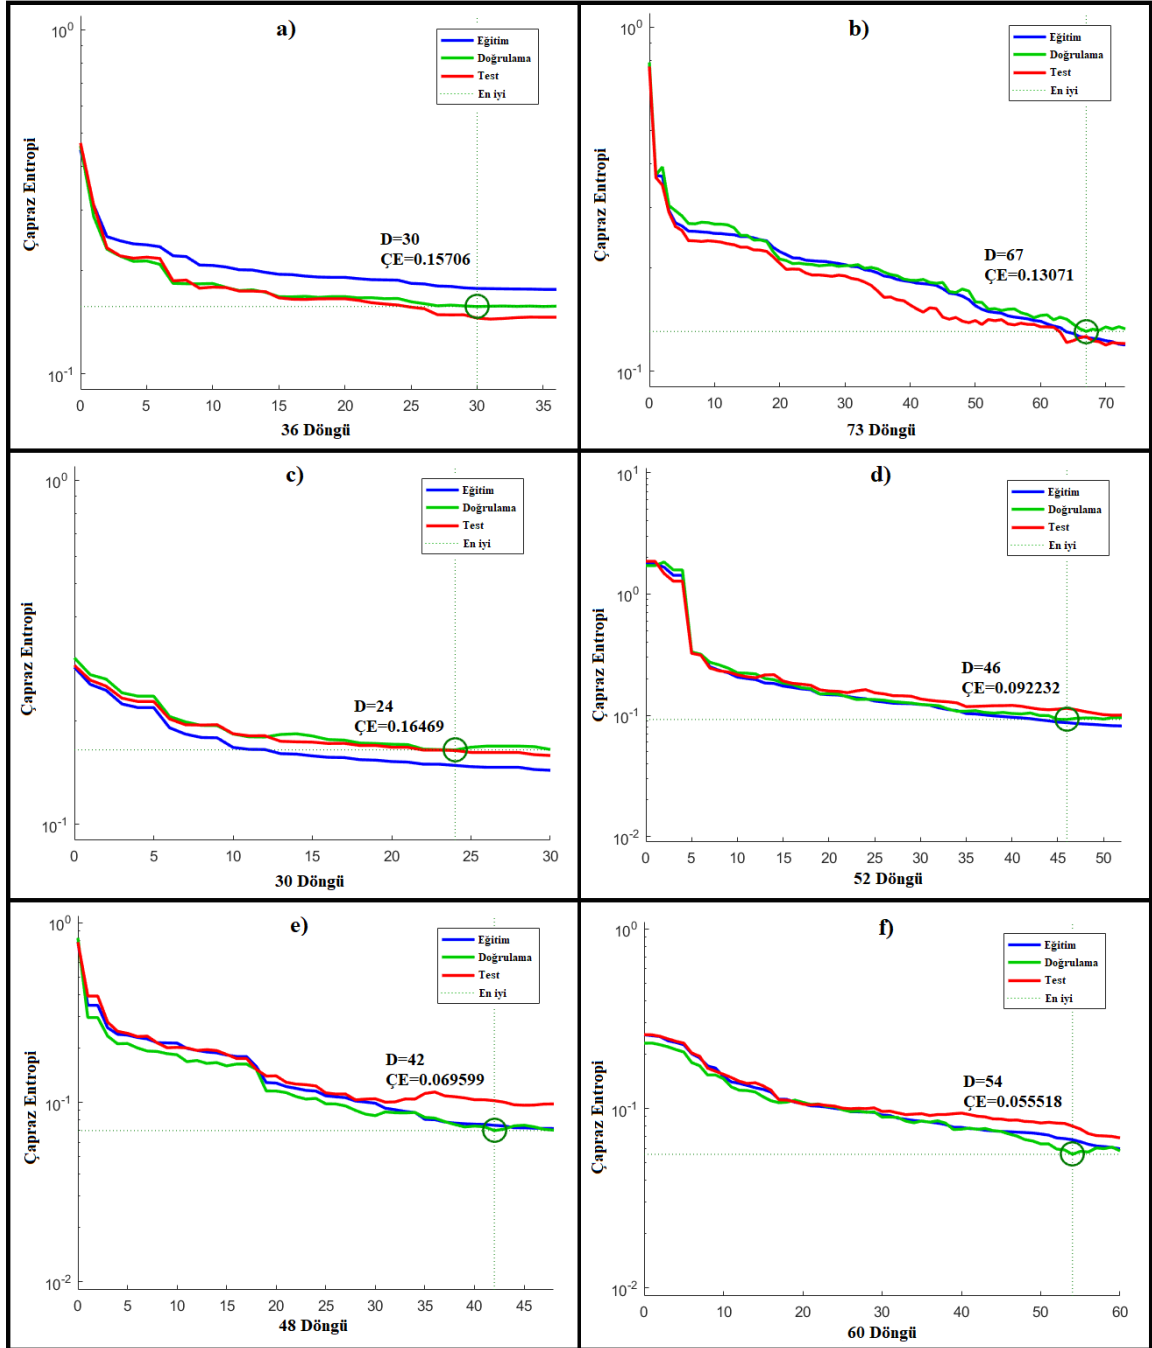
Arıza tespiti amacıyla kurulan YSA yaklaşımında farklı ölçüm verilerinden çıkarılan 19 adet öznelik sütunu beraber kullanılmış ve %98.8 oranındaki bir başarıyla S ve A redüktörleri sınıflandırılmıştır. Farklı ölçümlerden çıkarılan özneliklerin YSA yaklaşımına ait sınıflandırma performansına etkisi de farklıdır. Bu doğrultuda titreşim ölçümüne dayalı 8, ses ölçümüne dayalı 8 ve termal görüntülemeye dayalı 3 öznelik

sütunu ile ayrı ayrı ve ikili kombinasyonlarda veri setleri kurulmuş ve bütün öznelitliklerin kullanıldığı YSA yaklaşımı ile karşılaştırılmıştır.



Şekil 3.39. YSA ikili sınıflandırmaya ait ROC eğrileri

Şekil 3.40'ta ayrı ayrı ve ikili kombinasyonlarda titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımlarına ait performans eğrileri görülmektedir. Titreşim verilerine dayalı olarak kurulan YSA yaklaşımında en iyi doğrulama 30. döngüde gerçekleşmiş olup bu noktada çapraz entropi değeri 0.15706'dır. Ses verilerine dayalı olarak kurulan YSA yaklaşımı için en iyi doğrulama 67. döngüde gerçekleşmiş olup bu noktada çapraz entropi değeri 0.13071'dir. Termal görüntülere dayalı olarak kurulan YSA yaklaşımı 24 döngüde en iyi doğrulama değerine ulaşmıştır. Bu noktada çapraz entropi değeri 0.16469'dur. Titreşim ve ses verilerinin birlikte kullanıldığı YSA yaklaşımı 46 döngüde en iyi doğrulama değerine ulaşmış olup bu noktada çapraz entropi değeri 0.092232'dir.



Şekil 3.40. Titreşim (a), ses (b), termal görüntü (c), titreşim ve ses (d), titreşim ve termal görüntü (e), ses ve termal görüntü (f) verilerine dayalı YSA yaklaşımlarına ait performans eğrileri

Titreşim ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımı 42 döngü sonrasında en iyi doğrulama değerine ulaşmış olup bu noktada çapraz entropi değeri 0.069599'dur. Son olarak ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı ise 54 döngüde en iyi doğrulama değerine ulaşmıştır. Bu noktada çapraz entropi değeri 0.055518'dir.

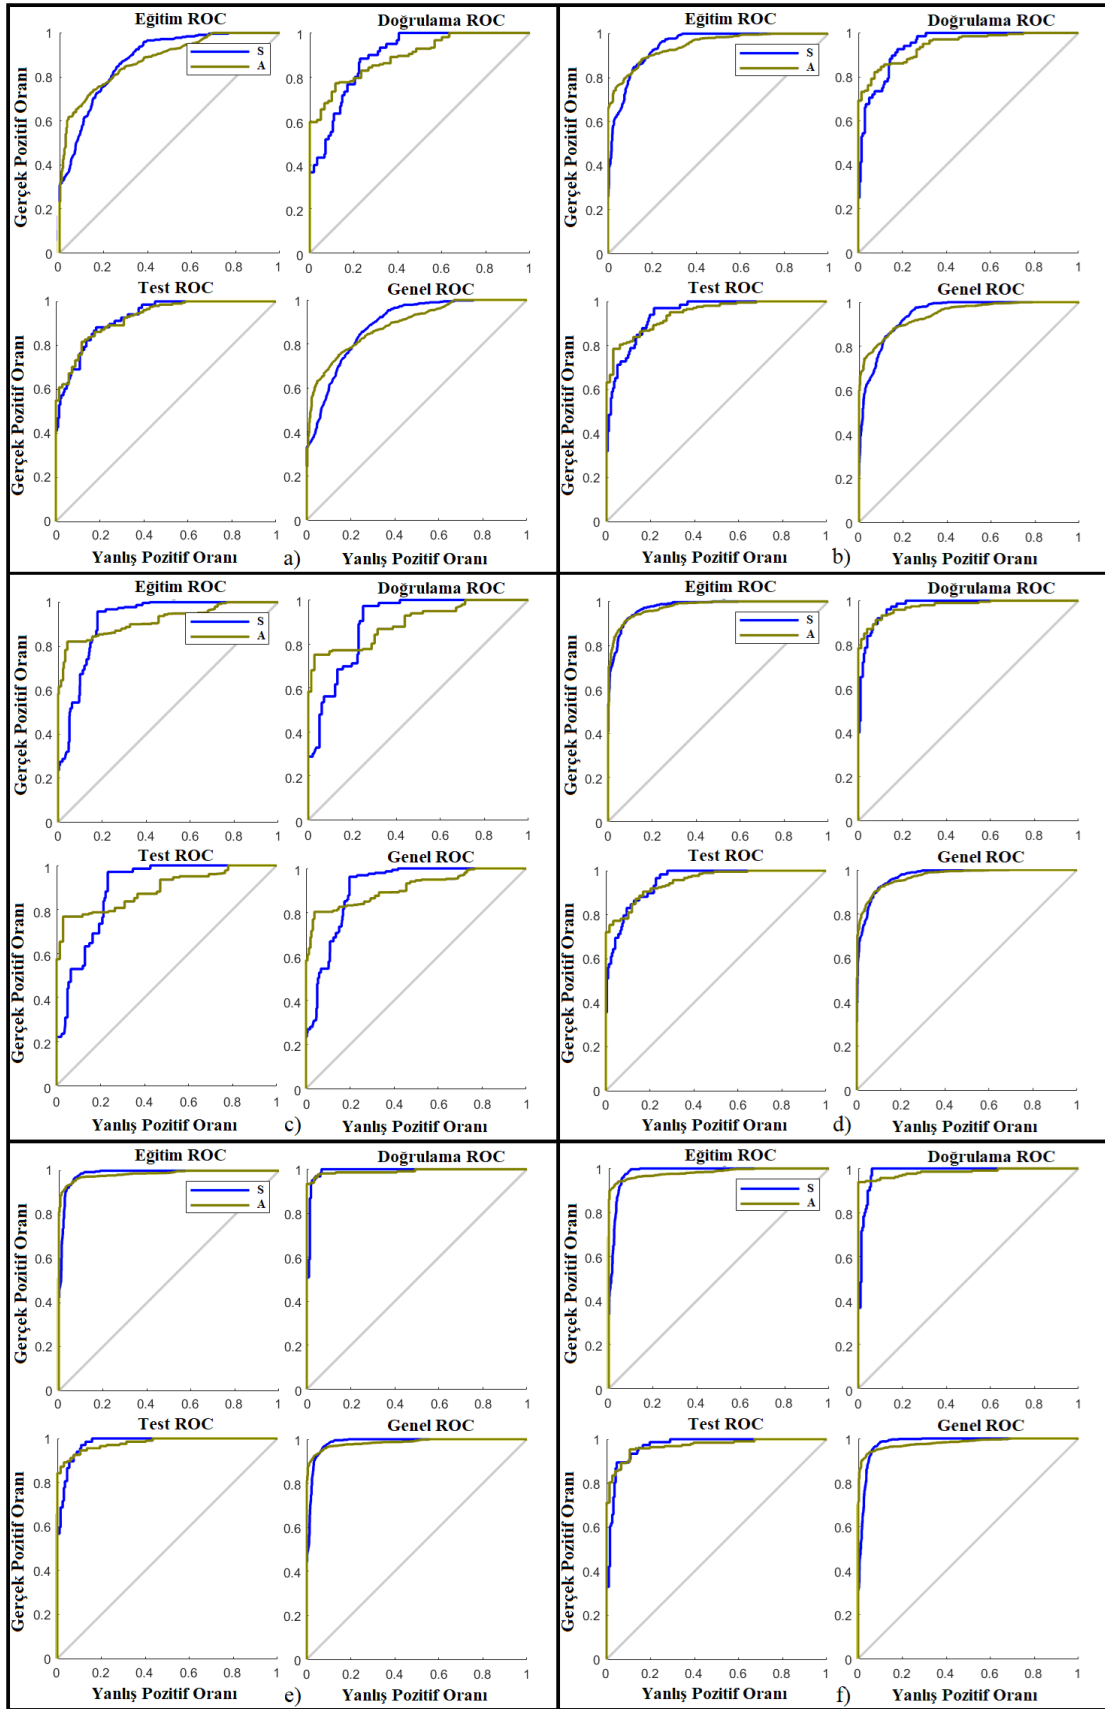
Şekil 3.35 ve Şekil 3.40 karşılaştırıldığında titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarının en düşük performansı sergilediği görülmektedir. Verilerin ikili kombinasyonlarda kullanılması YSA yaklaşımının performansını artırmaktadır. Titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı ise (Şekil 3.35) en yüksek performansı sergilemiştir.

Şekil 3.41'de ayrı ayrı ve ikili kombinasyonlarda titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımlarına ait hata matrisleri görülmektedir. Genel hata matrislerine bakıldığında titreşim verilerine dayalı olarak kurulan yaklaşımı S ve A redüktörlerine ait verileri %82.2 oranında doğru sınıflandırılmıştır. Ses verilerine dayalı olarak kurulan yaklaşımında ise bu oran %87.3'tür. Termal görüntü verilerinin kullanıldığı YSA yaklaşımı %83.2 oranında doğru sınıflandırma yapmıştır. Titreşim ve ses verilerinin birlikte kullanıldığı yaklaşımda doğru sınıflandırma oranı %91.2 olarak görülmektedir. Ses ve termal görüntü verilerine dayalı YSA yaklaşımına ait doğru sınıflandırma oranı %94.8 iken titreşim ve termal görüntü verilerine dayalı yaklaşım %93.8 oranında doğru sınıflandırma yapmıştır.

Şekil 3.38 ve Şekil 3.41 beraber incelendiğinde titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarının en düşük sınıflandırma oranına sahip olduğu görülmektedir. En düşük doğru sınıflandırma oranı titreşim verilerinin kullanıldığı yaklaşımda gerçekleşmiştir. Titreşim ve termal görüntü verilerinin ayrı ayrı kullanıldığı yaklaşımların doğru sınıflandırma başarıları birbirine yakındır. Verilerin ikili kombinasyonlarda kullanılması YSA yaklaşımının doğru sınıflandırma oranını yaklaşık %10 civarında artırmaktadır. Buna göre titreşim ve termal görüntü verilerinin beraber kullanıldığı yaklaşımın sınıflandırma başarısı ses ve termal görüntü verilerinin beraber kullanıldığı yaklaşımın başarısından %1 daha düşüktür. Titreşim ve ses verilerinin birlikte kullanıldığı YSA yaklaşımı ise diğer ikili kombinasyonlardan %2-3 daha düşük sınıflandırma başarısı göstermiştir. Titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı ise (Şekil 3.38) en yüksek sınıflandırma başarısına sahiptir (%98.8).

Çıkış Sınıfı	S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi			S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi					
		132	48	73.3%	26	11	70.3%		209	55	79.2%	50	17	74.6%			
		10.5%	3.8%	26.7%	9.6%	4.1%	29.7%		16.6%	4.4%	20.8%	18.5%	6.3%	25.4%			
	A	190	890	82.4%	34	199	85.4%	107	889	89.3%	18	185	91.1%				
		15.1%	70.6%	17.6%	12.6%	73.7%	14.6%	8.5%	70.6%	10.7%	6.7%	68.5%	8.9%				
		41.0%	94.9%	81.1%	43.3%	94.8%	83.3%	66.1%	94.2%	87.1%	73.5%	91.6%	87.0%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		
Çıkış Sınıfı	S	Test Hata Matrisi			Genel Hata Matrisi			S	Test Hata Matrisi			Genel Hata Matrisi					
		33	3	91.7%	191	62	75.5%		43	8	84.3%	302	80	79.1%			
		12.2%	1.1%	8.3%	10.6%	3.4%	24.5%		15.9%	3.0%	15.7%	16.8%	4.4%	20.9%			
	A	35	199	85.0%	259	1288	83.3%	23	196	89.5%	148	1270	89.6%				
		13.0%	73.7%	15.0%	14.4%	71.6%	16.7%	8.5%	72.6%	10.5%	8.2%	70.6%	10.4%				
		48.5%	98.5%	85.9%	42.4%	95.4%	82.2%	65.2%	96.1%	88.5%	67.1%	94.1%	87.3%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		
Çıkış Sınıfı	S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi			S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi					
		208	97	68.2%	50	28	64.1%		246	38	86.6%	66	13	83.5%			
		16.5%	7.7%	31.8%	18.5%	10.4%	35.9%		19.5%	3.0%	13.4%	24.4%	4.8%	16.5%			
	A	101	854	89.4%	23	169	88.0%	70	906	92.8%	9	182	95.3%				
		8.0%	67.8%	10.6%	8.5%	62.6%	12.0%	5.6%	71.9%	7.2%	3.3%	67.4%	4.7%				
		67.3%	89.8%	84.3%	68.5%	85.8%	81.1%	77.8%	96.0%	91.4%	88.0%	93.3%	91.9%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		
Çıkış Sınıfı	S	Test Hata Matrisi			Genel Hata Matrisi			S	Test Hata Matrisi			Genel Hata Matrisi					
		43	28	60.6%	301	153	66.3%		41	11	78.8%	353	62	85.1%			
		15.9%	10.4%	39.4%	16.7%	8.5%	33.7%		15.2%	4.1%	21.2%	19.6%	3.4%	14.9%			
	A	25	174	87.4%	149	1197	88.9%	18	200	91.7%	97	1288	93.0%				
		9.3%	64.4%	12.6%	8.3%	66.5%	11.1%	6.7%	74.1%	8.3%	5.4%	71.6%	7.0%				
		63.2%	86.1%	80.4%	66.9%	88.7%	83.2%	69.5%	94.8%	89.3%	78.4%	95.4%	91.2%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		
Çıkış Sınıfı	S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi			S	Eğitim Hata Matrisi			Doğrulama Hata Matrisi					
		292	32	90.1%	59	10	85.5%		279	42	86.9%	55	12	82.1%			
		23.2%	2.5%	9.9%	21.9%	3.7%	14.5%		22.1%	3.3%	13.1%	20.4%	4.4%	17.9%			
	A	30	906	96.8%	2	199	99.0%	35	904	96.3%	5	198	97.5%				
		2.4%	71.9%	3.2%	0.7%	73.7%	1.0%	2.8%	71.7%	3.7%	1.9%	73.3%	2.5%				
		90.7%	96.6%	95.1%	96.7%	95.2%	95.6%	88.9%	95.6%	93.9%	91.7%	94.3%	93.7%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		
Çıkış Sınıfı	S	Test Hata Matrisi			Genel Hata Matrisi			S	Test Hata Matrisi			Genel Hata Matrisi					
		58	10	85.3%	409	52	88.7%		68	10	87.2%	402	64	86.3%			
		21.5%	3.7%	14.7%	22.7%	2.9%	11.3%		25.2%	3.7%	12.8%	22.3%	3.6%	13.7%			
	A	9	193	95.5%	41	1298	96.9%	8	184	95.8%	48	1286	96.4%				
		3.3%	71.5%	4.5%	2.3%	72.1%	3.1%	3.0%	68.1%	4.2%	2.7%	71.4%	3.6%				
		86.6%	95.1%	93.0%	90.9%	96.1%	94.8%	89.5%	94.8%	93.3%	89.3%	95.3%	93.8%				
S			Hedef Sınıfı			S			Hedef Sınıfı			S			Hedef Sınıfı		
A			Hedef Sınıfı			A			Hedef Sınıfı			A			Hedef Sınıfı		

Şekil 3.41. Titreşim(a), ses(b), termal görüntü(c), titreşim ve ses(d), ses ve termal görüntü(e), titreşim ve termal görüntü(f) verilerine dayalı YSA yaklaşımlarına ait hata matrisleri



Şekil 3.42. Titreşim(a), ses(b), termal görüntü(c), titreşim ve ses(d), ses ve termal görüntü(e), titreşim ve termal görüntü(f) verilerine dayalı YSA yaklaşımlarına ait ROC eğrileri

Şekil 3.42’de ayrı ayrı ve ikili kombinasyonlarda titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımlarına ait ROC eğrileri görülmektedir. Şekil 3.42 ve Şekil 3.39 beraber incelendiğinde titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarına ait ROC eğrilerinde S ve A redüktörleri altında kalan alanların ikili kombinasyona dayalı yaklaşımlardan yaklaşık %10 daha az olduğu görülebilir. Verilerin ikili kombinasyonlarda kullanılması S ve A redüktörlerine ait alanları artırmaktadır. Titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımına ait ROC eğrilerine bakıldığında ise (Şekil 3.39) S ve A redüktörleri altında kalan alanların ikili kombinasyonlara dayalı yaklaşımlardan % 5–7 daha en yüksek olduğu görülür.

Tablo 3.1 YSA ile arıza tespitindeki deneme sayısının yaklaşım performansı parametrelerine ve başarı oranlarına etkisini göstermektedir.

Tablo 3.1 YSA ile arıza tespitinde deneme sayısının yaklaşım performansına etkisi

Deneme Sayısı	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
1	0.023633	99.4	99.6	98.5	99.3
2	0.024083	99.0	99.3	98.5	99.0
3	0.076179	95.0	92.6	94.4	94.6
4	0.024575	99.2	98.9	96.7	98.8
5	0.017256	99.0	98.9	97.8	98.8
6	0.036815	98.1	97.4	98.1	98.0
7	0.013718	98.6	99.6	97.0	98.5
8	0.023797	99.2	98.9	98.1	99.0
9	0.02589	99.0	97.4	98.5	98.7
10	0.030708	98.4	99.3	97.8	98.4
Ortalama	0.029665	98.5	98.2	97.5	98.3
Standart Sapma	0.017532	1.28966	2.119984	1.264208	1.352734

YSA ile arıza tespiti amacıyla kurulan yaklaşımda eğitim test ve doğrulama verileri rasgele seçildiği için her yeni sınıflandırma denemesine ait sonuçlar birbirine yakın olmakla beraber bir miktar farklılık arz etmektedir. Bu nedenle sınıflandırma işlemi 10 kez tekrarlanarak sonuçların ortalamaları ve standart sapmaları hesaplanmıştır [202, 234]. Buna göre ortalama çapraz entropi değeri 0.029665 olarak gerçekleşmiştir. Ayrıca eğitim başarı oranlarının ortalamasının %98.5, doğrulama başarı oranlarının ortalamasının %98.2, test başarı oranlarının ortalamasının %97.5 ve genel başarı oranlarının ortalamasının %98.3 olduğu görülmektedir. Sonuç olarak deneme sayısının artışı %98 civarında gerçekleşen genel başarı oranını çok değiştirmemektedir.

Arıza tespiti için seçilen YSA mimarisindeki gizli katmanda 10 adet nöron bulunmaktadır. Tablo 3.2’de farklı nöron sayıları ile kurulan YSA mimarilerine ait başarı oranları görülmektedir. Buna göre nöron sayısı 5 olarak seçildiğinde çapraz entropi değeri 0.031438, eğitim başarı oranı %98.0, doğrulama başarı oranı %98.1, test başarı oranı %96.3 ve genel başarı oranı %97.8 olarak çıkmıştır. Nöron sayısının 10 olarak seçilmesi durumunda başarı oranları artmış ve en yüksek düzeye gelmiştir. Nöron sayısının artırılmasıyla beraber başarı oranları %1 civarında düşmüştür.

Tablo 3.2 YSA ile arıza tespitinde nöron sayısının yaklaşım performansına etkisi

Nöron Sayısı	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
5	0.031438	98.0	98.1	96.3	97.8
10	0.024575	99.2	98.9	96.7	98.8
15	0.048957	98.7	96.7	98.5	98.3
20	0.044002	97.5	96.7	97.0	97.3
25	0.046401	98.5	96.3	96.3	97.8
30	0.045059	97.6	95.6	98.5	97.6

Arıza tespiti için seçilen YSA mimarisinde kullanılan veri seti için eğitim verilerinin oranı %70, doğrulama verilerinin oranı %15 ve test verilerinin oranı %15 olarak seçilmiştir. Tablo 3.3 veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım

performansına etkisini göstermektedir. Buna göre özellikle doğrulama ve test verilerinin oranı düştükçe yaklaşım performansı da yaklaşık %3 oranında azalmıştır.

Tablo 3.3. Veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım performansına etkisi

Veri Setindeki Dağılım (%)	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
50, 25, 25	0.047072	98.3	96.4	95.6	97.2
60, 20, 20	0.046571	98.7	97.2	97.8	98.2
70, 15, 15	0.024575	99.2	98.9	96.7	98.8
80, 10, 10	0.034778	97.4	98.3	96.1	97.4
90, 5, 5	0.071387	95.0	94.4	93.3	94.9


Sonuç olarak YSA ile SVR’lerde arıza tespiti amacıyla titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan yaklaşım için eğitim, doğrulama ve test oranları sırayla %70, %15, %15 olarak seçilmiştir. Yaklaşımın gizli katmanındaki nöron sayı 10 adet olarak belirlenmiştir. Buna göre yapılan çalışmalarda kurulan yaklaşımın S ve A redüktörlerini sınıflandırmadaki genel başarı oranının %98 civarında olduğu tespit edilmiş ve ROC eğrileri çizilmiştir. Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan YSA yaklaşımları sınıflandırma başarısı ve performans açısından farklılık göstermektedir. Verilerin ayrı ayrı kullanılması daha düşük bir yaklaşım performansına neden olmaktadır. İkili kombinasyonlarda kullanılan veriler ile kurulan yaklaşımların sınıflandırma başarısı daha yüksektir. Arıza tespitinde S ve A redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşımın tüm verilerin birlikte kullanıldığı YSA yaklaşımı olduğu performans grafikleri, hata matrisleri ve ROC eğrileri ile karşılaştırmalı olarak gösterilmiştir.

3.4.1.2. Çoklu Sınıflandırma: Arıza Türünün Sınıflandırılması

SVR’lerde arızanın sınıflandırması yapılırken yani arızanın türünün tespit edilmesinde 1 gizli katmana ve 1 çıkış katmanına sahip ileri beslemeli bir YSA mimarisi

kullanılmıştır. YSA çıkışları S (sağlam redüktör), A1 (aşınma), A2 (yüzey yorgunluğu) ve A3 (kırılma) olacak şekilde düzenlemiştir.

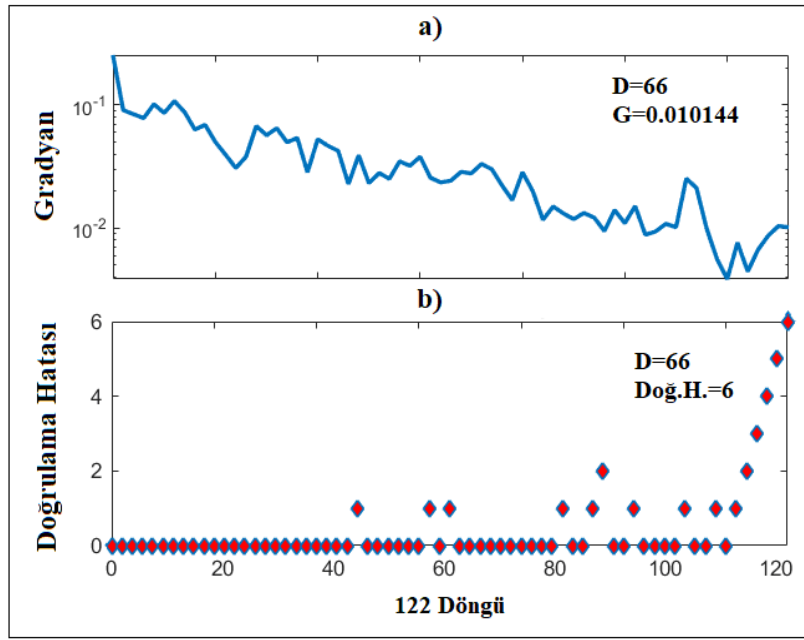
Şekil 3.43 arıza türlerinin tespiti için kurulan yaklaşım için eğitim döngü sayısına karşılık hata değerlerin değişimini gösteren YSA performans eğrisidir. Buna göre en iyi doğrulama 60. döngüde gerçekleşmiştir. Bu noktada çapraz entropi değeri 0,23833 olup en düşük değerindedir. Bu döngüden sonra aşırı uyum ya da aşırı öğrenme şeklinde tanımlanan olumsuzluğun önüne geçmek için eğitim durdurulmuştur.




Şekil 3.43. YSA performans eğrisi

Arıza türünün sınıflandırılması için kurulan YSA yaklaşımının eğitim süreci ile ilgili istatistikler Şekil 3.44'te görülmektedir. Şekil 3.44 a) logaritmik olarak ölçülendirilmiş geri yayılım gradyanının döngü sayısına göre değişimini göstermektedir. Buna göre 66. döngüde gradyan değeri 0.010144 olarak gerçekleşmiştir. Şekil 3.44 b) ise 66 döngüde doğrulama hatasının 6'ya çıktığını göstermektedir. Bu noktada hedef fonksiyonu yerel minimum seviyesinin altına indiğinden eğitim süreci durdurulmuştur.

Şekil 3.45 eğitim, doğrulama ve test verileri için hata histogramını göstermektedir. Burada hata değerleri hedefler ile çıkışların farkı olarak gösterilmiştir.



Şekil 3.44. YSA'nın eğitim durumu ile ilgili istatistikler



Şekil 3.45. Hata histogramı

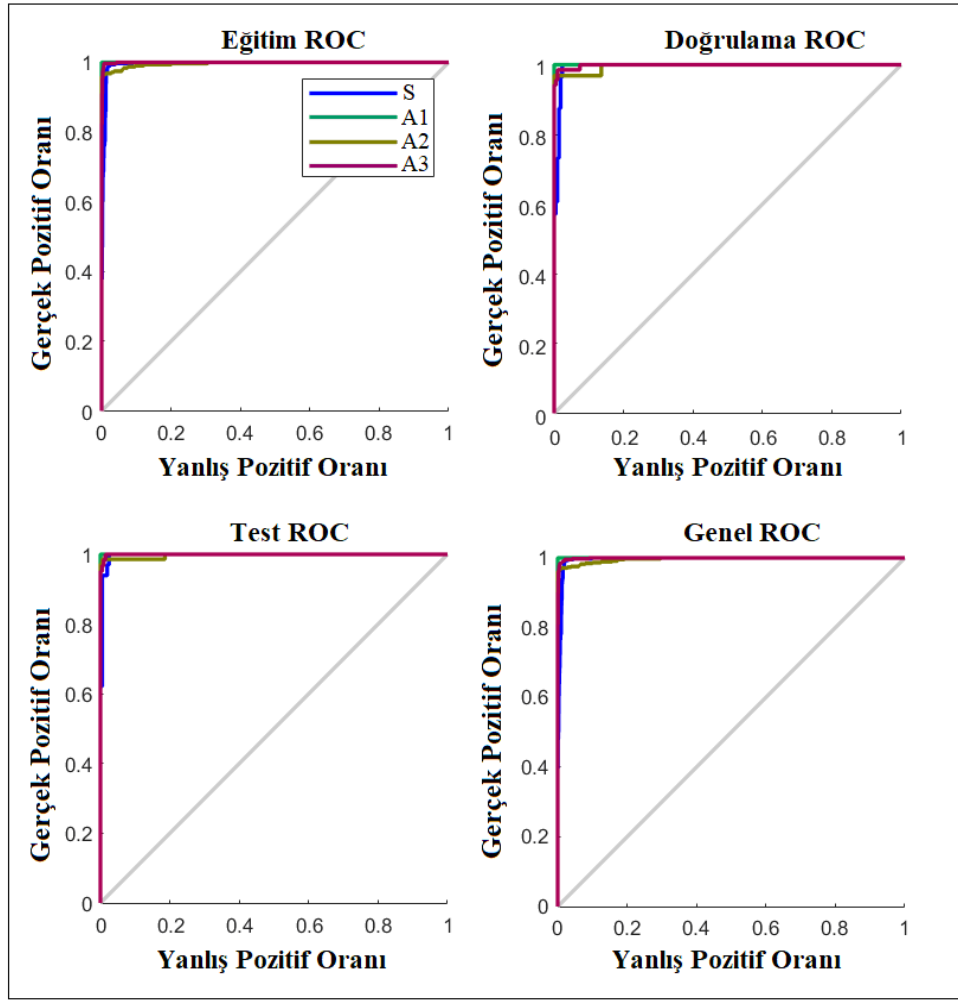
Şekil 3.46 kurulan YSA yaklaşımı için eğitim, doğrulama, test ve genel hata matrislerini göstermektedir. Buna göre S, A1, A2 ve A3 redüktörlerine ait eğitim verilerinin %98.2 oranında, doğrulama verilerinin %97.4 oranında ve test verilerinin %97.8 oranında doğru sınıflandırıldığı görülmektedir. Genel hata matrisine bakıldığında ise

sağlam ve arızalı redüktörlere ait veriler %98 oranında doğru sınıflandırılmıştır. Yani arıza türünün tespiti amacıyla kurulan YSA yaklaşımı %98 oranında başarılıdır. Buna karşılık YSA yaklaşımı %2 oranında yanlış sınıflandırma yapmıştır.

		Eğitim Hata Matrisi					Doğrulama Hata Matrisi					
Çıkış Sınıfı	S	322 25.6%	0 0.0%	13 1.0%	2 0.2%	95.5% 4.5%	S	55 20.4%	0 0.0%	2 0.7%	3 1.1%	91.7% 8.3%
	A1	1 0.1%	296 23.5%	0 0.0%	0 0.0%	99.7% 0.3%	A1	1 0.4%	82 30.4%	0 0.0%	0 0.0%	98.8% 1.2%
	A2	0 0.0%	0 0.0%	302 24.0%	2 0.2%	99.3% 0.7%	A2	0 0.0%	0 0.0%	61 22.6%	0 0.0%	100% 0.0%
	A3	5 0.4%	0 0.0%	0 0.0%	317 25.2%	98.4% 1.6%	A3	0 0.0%	0 0.0%	1 0.4%	65 24.1%	98.5% 1.5%
		98.2% 1.8%	100% 0.0%	95.9% 4.1%	98.8% 1.2%	98.2% 1.8%		98.2% 1.8%	100% 0.0%	95.3% 4.7%	95.6% 4.4%	97.4% 2.6%
		S	A1	A2	A3			S	A1	A2	A3	
		Hedef Sınıfı					Hedef Sınıfı					
		Test Hata Matrisi					Genel Hata Matrisi					
Çıkış Sınıfı	S	65 24.1%	0 0.0%	2 0.7%	3 1.1%	92.9% 7.1%	S	442 24.6%	0 0.0%	17 0.9%	8 0.4%	94.6% 5.4%
	A1	0 0.0%	72 26.7%	0 0.0%	0 0.0%	100% 0.0%	A1	2 0.1%	450 25.0%	0 0.0%	0 0.0%	99.6% 0.4%
	A2	1 0.4%	0 0.0%	69 25.6%	0 0.0%	98.6% 1.4%	A2	1 0.1%	0 0.0%	432 24.0%	2 0.1%	99.3% 0.7%
	A3	0 0.0%	0 0.0%	0 0.0%	58 21.5%	100% 0.0%	A3	5 0.3%	0 0.0%	1 0.1%	440 24.4%	98.7% 1.3%
		98.5% 1.5%	100% 0.0%	97.2% 2.8%	95.1% 4.9%	97.8% 2.2%		98.2% 1.8%	100% 0.0%	96.0% 4.0%	97.8% 2.2%	98.0% 2.0%
		S	A1	A2	A3			S	A1	A2	A3	
		Hedef Sınıfı					Hedef Sınıfı					

Şekil 3.46. Hata matrisleri

Şekil 3.47’de arıza türünün tespiti için kurulan YSA yaklaşımına ait eğitim, doğrulama, test ve genel ROC eğrileri görülmektedir. Buna göre kurulan YSA yaklaşımının tüm redüktörleri sınıflandırma başarısı birbirine yakın ve yüksektir (%98-100). Bunun yanında yaklaşımın A1 redüktörünü diğer redüktörlerden daha iyi sınıflandırdığı görülmektedir (%100).



Şekil 3.47. Arıza türünün tespitinde kullanılan YSA yaklaşımına ait ROC eğrileri

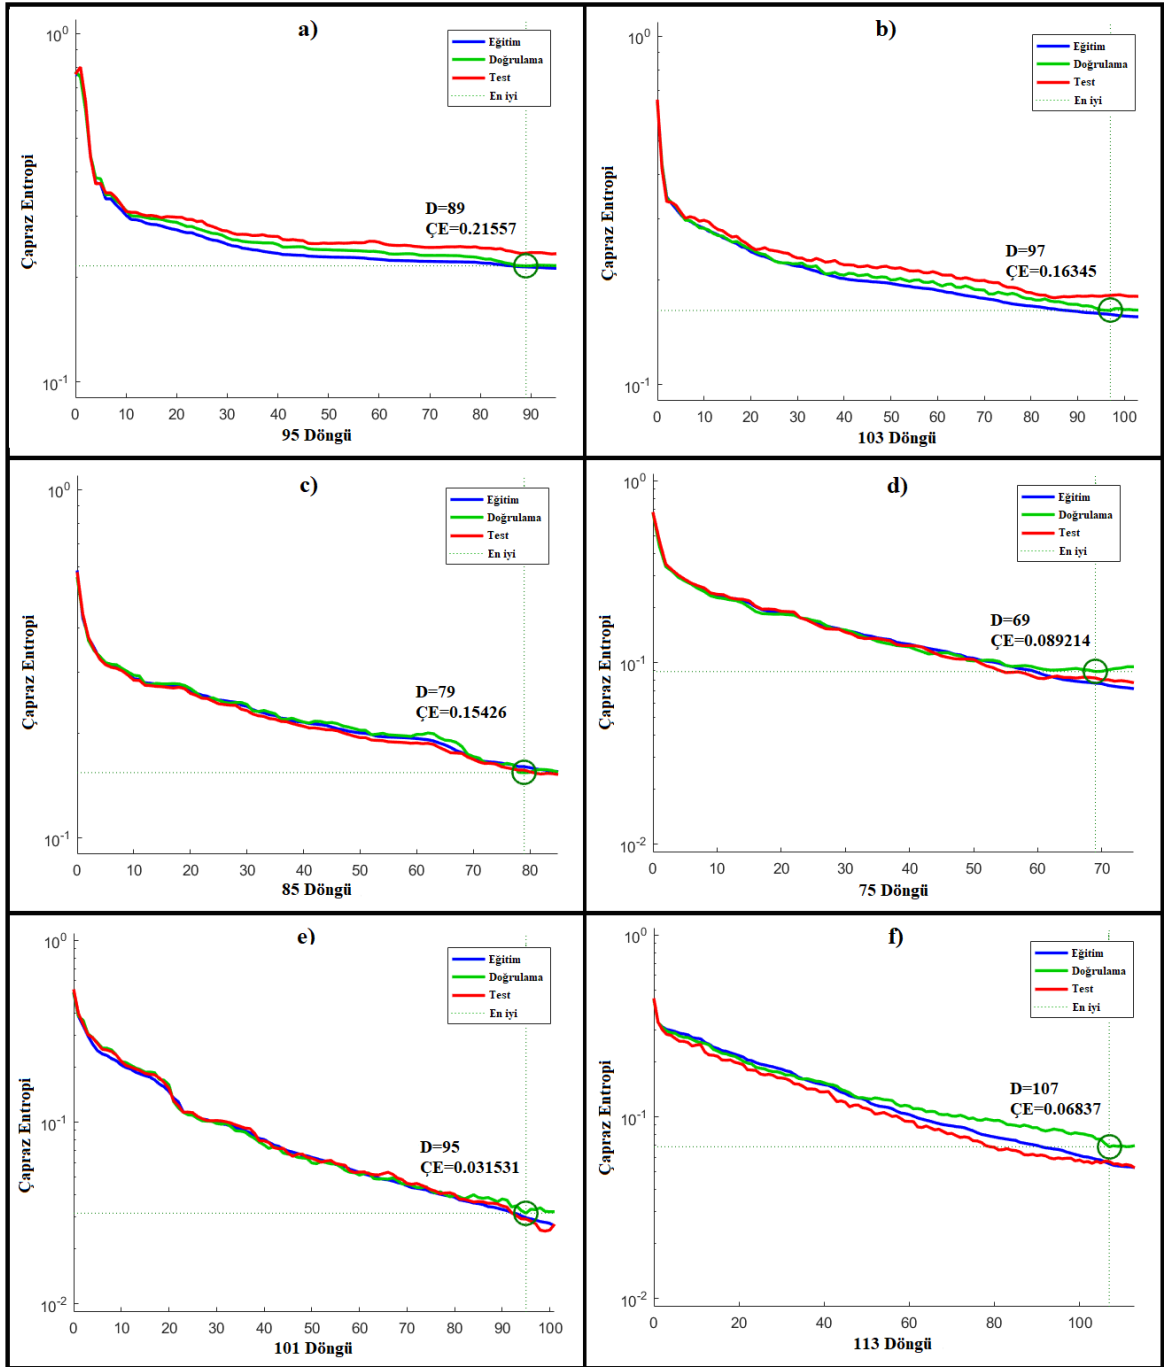
Arıza türünün tespiti amacıyla kurulan YSA yaklaşımında farklı ölçüm verilerinden çıkarılan 19 adet öznelik sütunu beraber kullanılmış ve %98 oranındaki bir başarıyla S, A1, A2 ve A3 redüktörleri sınıflandırılmıştır. Farklı ölçümlerden çıkarılan özneliklerin YSA yaklaşımına ait sınıflandırma performansına etkisi de farklıdır. Bu doğrultuda titreşim ölçümüne dayalı 8, ses ölçümüne dayalı 8 ve termal görüntülemeye dayalı 3 öznelik sütunu ile ayrı ayrı ve ikili kombinasyonlarda veri setleri kurulmuş ve bütün özneliklerin kullanıldığı YSA yaklaşımı ile karşılaştırılmıştır.

Şekil 3.48’de ayrı ayrı ve ikili kombinasyonlarda titreşim, ses ve termal görüntü verilerine dayalı olarak arıza türünün tespiti amacıyla kurulan YSA yaklaşımlarına ait performans eğrileri görülmektedir. Titreşim verilerine dayalı olarak kurulan YSA yaklaşımında en iyi doğrulama 89. döngüde gerçekleşmiş olup bu noktada çapraz entropi

değeri 0.21557'dir. Ses verilerine dayalı olarak kurulan YSA yaklaşımı için en iyi doğrulama 97. döngüde gerçekleşmiş olup bu noktada çapraz entropi değeri 0.16345'tir. Termal görüntülere dayalı olarak kurulan YSA yaklaşımı 79. döngüde en iyi doğrulama değerine ulaşmıştır. Bu noktada çapraz entropi değeri 0.15426'dır. Titreşim ve ses verilerinin birlikte kullanıldığı YSA yaklaşımı 69 döngüde en iyi doğrulama değerine ulaşmış olup bu noktada çapraz entropi değeri 0.089214'dür. Ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı ise 95 döngüde en iyi doğrulama değerine ulaşmıştır. Bu noktada çapraz entropi değeri 0.031531'dir. Son olarak titreşim ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımı 107 döngü sonrasında en iyi doğrulama değerine ulaşmış olup bu noktada çapraz entropi değeri 0.06837'dir.

Şekil 3.48 ve Şekil 3.43 karşılaştırıldığında titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarının en düşük performansı sergilediği görülmektedir. Verilerin ikili kombinasyonlarda kullanılması YSA yaklaşımının performansını %20-25 oranında artırmaktadır. Arıza türünün tespiti amacıyla titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı ise (Şekil 3.43) en yüksek performansı sergilemiştir.

Şekil 3.49'da ayrı ayrı ve ikili kombinasyonlarda arıza türünün tespiti amacıyla titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımlarına ait hata matrisleri görülmektedir. Genel hata matrislerine bakıldığında titreşim verilerine dayalı olarak kurulan yaklaşımın S, A1, A2 ve A3 redüktörlerine ait verileri %62.0 oranında doğru sınıflandırılmıştır. Ses verilerine dayalı olarak kurulan yaklaşımda ise bu oran %68.3'dir. Termal görüntü verilerinin kullanıldığı YSA yaklaşımı %71.9 oranında doğru sınıflandırma yapmıştır. Titreşim ve ses verilerinin birlikte kullanıldığı yaklaşımda doğru sınıflandırma oranı %86.9 olarak görülmektedir. Ses ve termal görüntü verilerine dayalı YSA yaklaşımına ait doğru sınıflandırma oranı %95.8 iken titreşim ve termal görüntü verilerine dayalı yaklaşım %92.0 oranında doğru sınıflandırma yapmıştır.



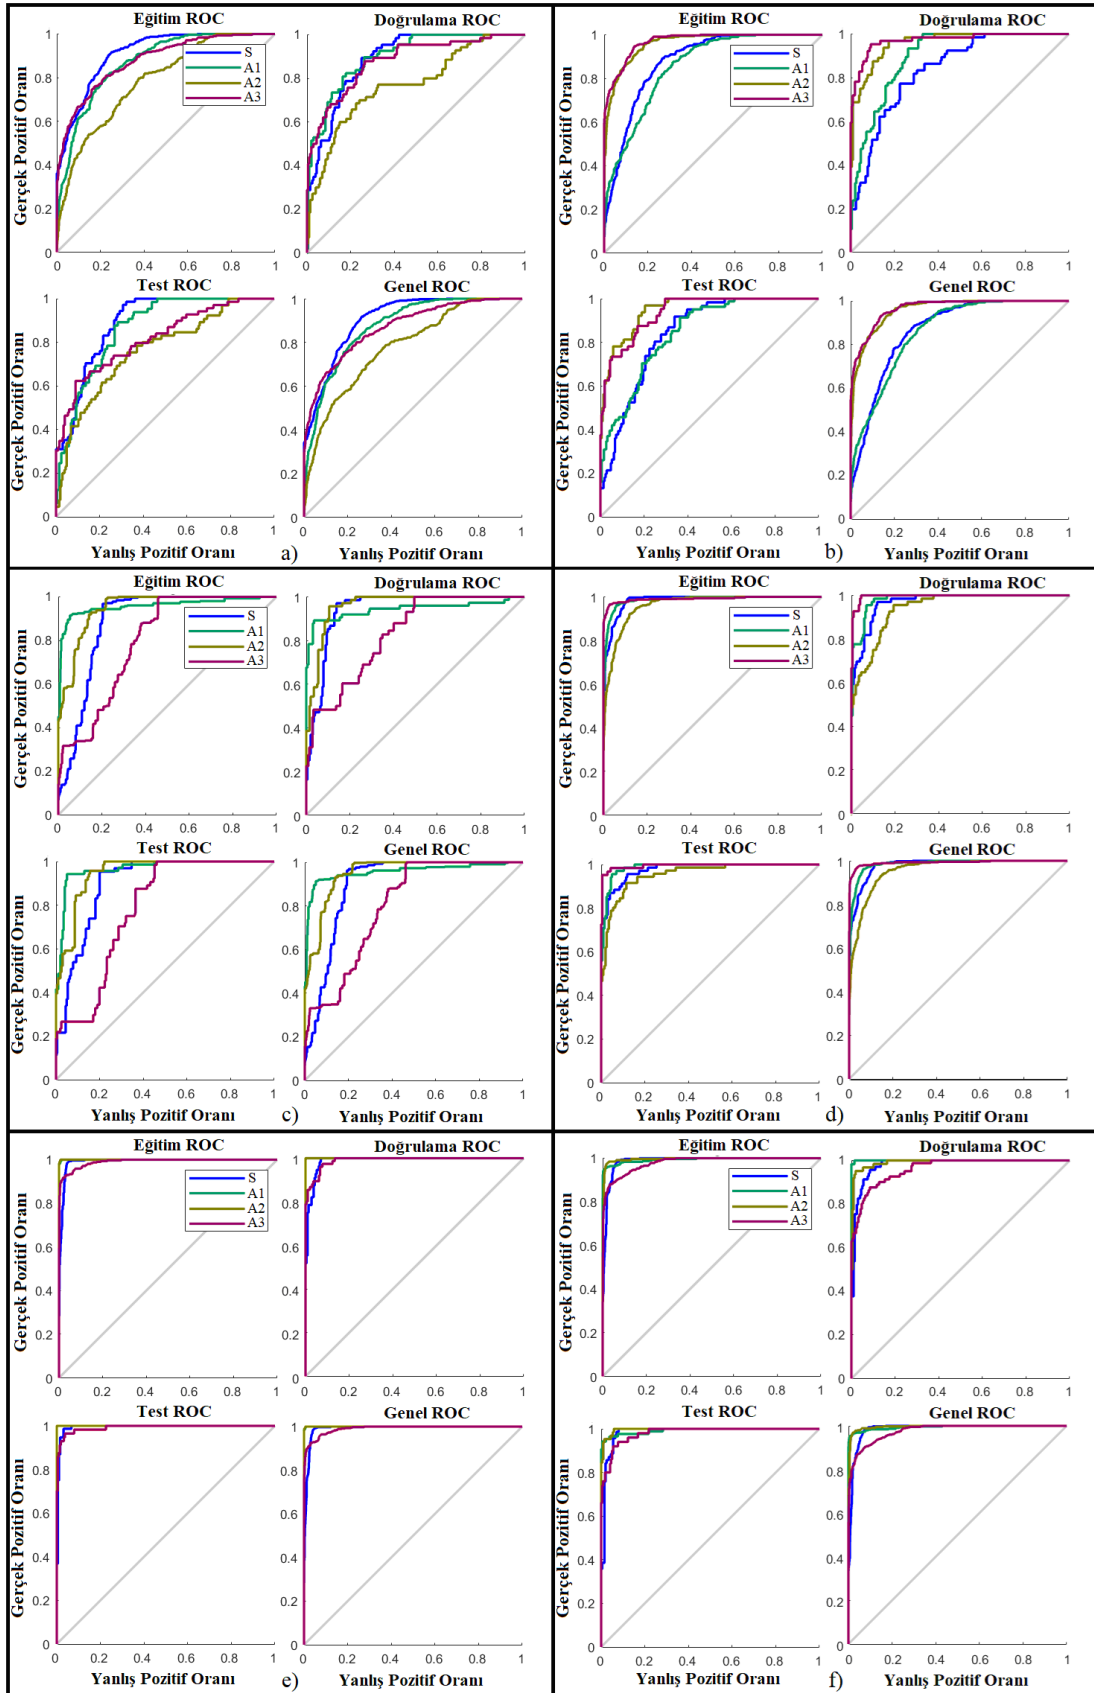
Şekil 3.48. Titreşim (a), ses (b), termal görüntü (c), titreşim ve ses (d), ses ve termal görüntü (e), titreşim ve termal görüntü (f) verilerine dayalı YSA yaklaşımlarına ait performans eğrileri

Çıkış Sınıfı	S A1 A2 A3	Eğitim Hata Matrisi					Doğrulama Hata Matrisi						
		224 17.8%	32 2.5%	35 2.8%	50 4.0%	65.7% 34.3%	48 17.8%	9 3.3%	11 4.1%	11 4.1%	60.8% 39.2%		
		4 0.3%	196 15.6%	94 7.5%	22 1.7%	62.0% 38.0%	0 0.0%	45 16.7%	19 7.0%	4 1.5%	66.2% 33.8%		
		38 3.0%	57 4.5%	153 12.1%	31 2.5%	54.8% 45.2%	6 2.2%	11 4.1%	29 10.7%	5 1.9%	56.9% 43.1%		
		47 3.7%	32 2.5%	33 2.6%	212 16.8%	65.4% 34.6%	12 4.4%	3 1.1%	11 4.1%	46 17.0%	63.9% 36.1%		
				71.6% 28.4%	61.8% 38.2%	48.6% 51.4%	67.3% 32.7%	62.3% 37.7%	72.7% 27.3%	66.2% 33.8%	41.4% 58.6%	69.7% 30.3%	62.2% 37.8%
Test Hata Matrisi					Genel Hata Matrisi								
50 18.5%	7 2.6%	8 3.0%	9 3.3%	67.6% 32.4%	322 17.9%	48 2.7%	54 3.0%	70 3.9%	65.2% 34.8%				
0 0.0%	40 14.8%	20 7.4%	9 3.3%	58.0% 42.0%	4 0.2%	281 15.6%	133 7.4%	35 1.9%	62.0% 38.0%				
5 1.9%	11 4.1%	27 10.0%	5 1.9%	56.3% 43.8%	49 2.7%	79 4.4%	209 11.6%	41 2.3%	55.3% 44.7%				
16 5.9%	7 2.6%	10 3.7%	46 17.0%	58.2% 41.8%	75 4.2%	42 2.3%	54 3.0%	304 16.9%	64.0% 36.0%				
				70.4% 29.6%	61.5% 38.5%	41.5% 58.5%	66.7% 33.3%	60.4% 39.6%	71.6% 28.4%	62.4% 37.6%	46.4% 53.6%	67.6% 32.4%	62.0% 38.0%
Hedef Sınıfı					Hedef Sınıfı								
a)					b)								
Çıkış Sınıfı	S A1 A2 A3	Eğitim Hata Matrisi					Doğrulama Hata Matrisi						
		279 22.1%	12 1.0%	12 1.0%	173 13.7%	58.6% 41.4%	63 23.3%	5 1.9%	0 0.0%	23 8.5%	69.2% 30.8%		
		7 0.6%	259 20.6%	27 2.1%	0 0.0%	88.4% 11.6%	1 0.4%	64 23.7%	5 1.9%	0 0.0%	91.4% 8.6%		
		0 0.0%	33 2.6%	242 19.2%	43 3.4%	76.1% 23.9%	0 0.0%	5 1.9%	57 21.1%	7 2.6%	82.6% 17.4%		
		31 2.5%	2 0.2%	28 2.2%	112 8.9%	64.7% 35.3%	4 1.5%	0 0.0%	8 3.0%	28 10.4%	70.0% 30.0%		
				88.0% 12.0%	84.6% 15.4%	78.3% 21.7%	34.1% 65.9%	70.8% 29.2%	92.6% 7.4%	86.5% 13.5%	81.4% 18.6%	48.3% 51.7%	78.5% 21.5%
Test Hata Matrisi					Genel Hata Matrisi								
56 20.7%	3 1.1%	1 0.4%	37 13.7%	57.7% 42.3%	398 22.1%	20 1.1%	13 0.7%	233 12.9%	59.9% 40.1%				
3 1.1%	58 21.5%	5 1.9%	0 0.0%	87.9% 12.1%	11 0.6%	381 21.2%	37 2.1%	0 0.0%	88.8% 11.2%				
0 0.0%	8 3.0%	60 22.2%	10 3.7%	76.9% 23.1%	0 0.0%	46 2.6%	359 19.9%	60 3.3%	77.2% 22.8%				
6 2.2%	1 0.4%	5 1.9%	17 6.3%	58.6% 41.4%	41 2.3%	3 0.2%	41 2.3%	157 8.7%	64.9% 35.1%				
				86.2% 13.8%	82.9% 17.1%	84.5% 15.5%	26.6% 73.4%	70.7% 29.3%	88.4% 11.6%	84.7% 15.3%	79.8% 20.2%	34.9% 65.1%	71.9% 28.1%
Hedef Sınıfı					Hedef Sınıfı								
c)					d)								
Çıkış Sınıfı	S A1 A2 A3	Eğitim Hata Matrisi					Doğrulama Hata Matrisi						
		306 24.3%	0 0.0%	0 0.0%	29 2.3%	91.3% 8.7%	52 19.3%	0 0.0%	0 0.0%	11 4.1%	82.5% 17.5%		
		0 0.0%	295 23.4%	3 0.2%	0 0.0%	99.0% 1.0%	0 0.0%	78 28.9%	0 0.0%	0 0.0%	100% 0.0%		
		0 0.0%	4 0.3%	321 25.5%	0 0.0%	98.8% 1.2%	0 0.0%	0 0.0%	60 22.2%	0 0.0%	100% 0.0%		
		12 1.0%	2 0.2%	0 0.0%	288 22.9%	95.4% 4.6%	4 1.5%	0 0.0%	0 0.0%	65 24.1%	94.2% 5.8%		
				96.2% 3.8%	98.0% 2.0%	99.1% 0.9%	90.9% 9.1%	96.0% 4.0%	92.9% 7.1%	100% 0.0%	100% 0.0%	85.5% 14.5%	94.4% 5.6%
Test Hata Matrisi					Genel Hata Matrisi								
70 25.9%	0 0.0%	0 0.0%	3 1.1%	95.9% 4.1%	428 23.8%	0 0.0%	0 0.0%	43 2.4%	90.9% 9.1%				
1 0.4%	71 26.3%	1 0.4%	0 0.0%	97.3% 2.7%	1 0.1%	444 24.7%	4 0.2%	0 0.0%	98.9% 1.1%				
0 0.0%	0 0.0%	65 24.1%	1 0.4%	98.5% 1.5%	0 0.0%	4 0.2%	446 24.8%	1 0.1%	98.9% 1.1%				
5 1.9%	0 0.0%	0 0.0%	53 19.6%	91.4% 8.6%	21 1.2%	2 0.1%	0 0.0%	406 22.6%	94.6% 5.4%				
				92.1% 7.9%	100% 0.0%	98.5% 1.5%	93.0% 7.0%	95.9% 4.1%	95.1% 4.9%	98.7% 1.3%	99.1% 0.9%	90.2% 9.8%	95.8% 4.2%
Hedef Sınıfı					Hedef Sınıfı								
e)					f)								
Çıkış Sınıfı	S A1 A2 A3	Eğitim Hata Matrisi					Doğrulama Hata Matrisi						
		292 23.2%	8 0.6%	0 0.0%	37 2.9%	86.6% 13.4%	65 24.1%	0 0.0%	0 0.0%	16 5.9%	80.2% 19.8%		
		0 0.0%	292 23.2%	10 0.8%	0 0.0%	96.7% 3.3%	0 0.0%	57 21.1%	1 0.4%	0 0.0%	98.3% 1.7%		
		0 0.0%	4 0.3%	306 24.3%	5 0.4%	97.1% 2.9%	0 0.0%	0 0.0%	58 21.5%	3 1.1%	95.1% 4.9%		
		19 1.5%	2 0.2%	8 0.6%	277 22.0%	90.5% 9.5%	4 1.5%	0 0.4%	3 1.1%	62 23.0%	88.6% 11.4%		
				93.9% 6.1%	95.4% 4.6%	94.4% 5.6%	86.8% 13.2%	92.6% 7.4%	94.2% 5.8%	98.3% 1.7%	93.5% 6.5%	76.5% 23.5%	89.6% 10.4%
Test Hata Matrisi					Genel Hata Matrisi								
62 23.0%	3 1.1%	0 0.0%	5 1.9%	88.6% 11.4%	419 23.3%	11 0.6%	0 0.0%	58 3.2%	85.9% 14.1%				
0 0.0%	81 30.0%	2 0.7%	0 0.0%	97.6% 2.4%	0 0.0%	430 23.9%	13 0.7%	0 0.0%	97.1% 2.9%				
0 0.0%	1 0.4%	60 22.2%	1 0.4%	96.8% 3.2%	0 0.0%	5 0.3%	424 23.6%	9 0.5%	96.8% 3.2%				
8 3.0%	1 0.4%	2 0.7%	44 16.3%	80.0% 20.0%	31 1.7%	4 0.2%	13 0.7%	383 21.3%	88.9% 11.1%				
				88.6% 11.4%	94.2% 5.8%	93.8% 6.3%	88.0% 12.0%	91.5% 8.5%	93.1% 6.9%	95.6% 4.4%	94.2% 5.8%	85.1% 14.9%	92.0% 8.0%
Hedef Sınıfı					Hedef Sınıfı								

Şekil 3.49. Titreşim (a), ses (b), termal görüntü (c), titreşim ve ses (d), ses ve termal görüntü (e), titreşim ve termal görüntü (f) verilerine dayalı YSA yaklaşımlarına ait hata matrisleri

Şekil 3.49 ve Şekil 3.46 beraber incelendiğinde titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarının S, A1, A2 ve A3 redüktörlerini daha düşük oranlarda (%60, %68.3, %71.9) sınıflandırabildiği görülmektedir. Arıza türünün tespiti amacıyla en düşük sınıflandırma oranı titreşim verilerinin kullanıldığı yaklaşımda gerçekleşmiştir (%60). Termal görüntü ve ses verilerinin kullanıldığı yaklaşımların doğru sınıflandırma başarıları birbirine çok yakınken (68.3, %71.9) titreşim verilerinin kullanıldığı yaklaşıma ait başarı daha düşüktür. Verilerin ikili kombinasyonlarda kullanılması YSA yaklaşımının doğru sınıflandırma başarısını %20-25 oranında artırmaktadır. Buna göre ses ve termal görüntü verilerinin beraber kullanıldığı yaklaşımın sınıflandırma başarısı titreşim ve termal görüntü verilerinin beraber kullanıldığı yaklaşımın başarısından %3.8 daha yüksektir. Titreşim ve ses verilerinin birlikte kullanıldığı YSA yaklaşımı ise diğer ikili kombinasyonlardan yaklaşık %10 daha düşük sınıflandırma başarısı göstermiştir. S, A1, A2 ve A3 redüktörlerini birbirinden ayırmak amacıyla titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımı (Şekil 3.46) en yüksek sınıflandırma başarısına sahiptir (%98).

Şekil 3.50'de ayrı ayrı ve ikili kombinasyonlarda titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan YSA yaklaşımlarına ait ROC eğrileri görülmektedir. Şekil 3.50 ve Şekil 3.47 beraber incelendiğinde titreşim, ses ve termal görüntü verilerinin ayrı ayrı kullanılmasıyla elde edilen YSA yaklaşımlarına ait ROC eğrilerinde S, A1, A2 ve A3 redüktörleri altında kalan alanların %20-25 daha az olduğu görülebilir. Verilerin ikili kombinasyonlarda kullanılması S, A1, A2 ve A3 redüktörlerine ait alanları bu oranlarda artırmaktadır. Titreşim, ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımına ait ROC eğrilerine bakıldığında ise (Şekil 3.47) S, A1, A2 ve A3 redüktörleri altında kalan alanların en yüksek oranda olduğu görülür (0.98).



Şekil 3.50. Titreşim(a), ses(b), termal görüntü(c), titreşim ve ses(d), ses ve termal görüntü(e), titreşim ve termal görüntü(f) verilerine dayalı YSA yaklaşımlarına ait ROC eğrileri

YSA ile arıza türlerinin tespiti amacıyla kurulan yaklaşımda eğitim test ve doğrulama verileri rastgele seçildiği için her yeni sınıflandırma denemesine ait sonuçlar birbirine yakın olmakla beraber bir miktar farklılık arz etmektedir. Bu nedenle S, A1, A2 ve A3 redüktörlerine ait sınıflandırma işlemi 10 kez tekrarlanarak sonuçların ortalamaları standart sapmalarıyla birlikte Tablo 3.4'te gösterilmiştir.

Tablo 3.4 YSA ile arıza türünün tespitinde deneme sayısının yaklaşım performansına etkisi

Deneme Sayısı	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
1	0.01314	99.1	97.8	97.0	98.6
2	0.01753	98.5	97.8	98.1	98.3
3	0.01544	98.8	98.1	98.5	98.7
4	0.015391	98.3	97.8	97.4	98.1
5	0.023833	98.2	97.4	97.8	98.0
6	0.005838	98.8	99.3	95.9	98.4
7	0.010195	98.5	99.3	98.5	98.6
8	0.009380	98.8	98.5	97.0	98.5
9	0.014039	98.9	98.5	97.4	98.6
10	0.020501	97.5	97.4	95.2	97.2
Ortalama	0.014529	98.54	98.19	97.28	98.3
Standart Sapma	0.00533	0.4599	0.6967	1.0716	0.4496

Buna göre ortalama çapraz entropi değeri 0.014529 olarak gerçekleşmiştir. Ayrıca eğitim başarı oranlarının ortalamasının %98.54, doğrulama başarı oranlarının ortalamasının %98.19, test başarı oranlarının ortalamasının %97.28 ve genel başarı oranlarının ortalamasının %98.3 olduğu görülmektedir. Sonuç olarak deneme sayısının artışı %98 civarında gerçekleşen genel başarı oranını çok değiştirmemektedir.

Arıza türünün tespiti için kurulan YSA mimarisindeki gizli katmanda 10 adet nöron bulunmaktadır. Tablo 3.5'te farklı nöron sayıları ile kurulan YSA mimarilerine ait başarı

oranları görülmektedir. Buna göre nöron sayısı 5 olarak seçildiğinde çapraz entropi değeri 0.047156, eğitim başarı oranı %96.4, doğrulama başarı oranı %95.2, test başarı oranı %93.3 ve genel başarı oranı %95.8 olarak çıkmıştır. Nöron sayısının 10 ve daha yüksek seçilmesi durumunda başarı oranı %98.7'ye kadar artmıştır.

Arıza türünün tespiti için kurulan YSA mimarisinde kullanılan veri seti için eğitim verilerinin oranı %70, doğrulama verilerinin oranı %15 ve test verilerinin oranı %15 olarak seçilmiştir. Tablo 3.6 veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım performansına etkisini göstermektedir. Buna göre, özellikle doğrulama ve test verilerinin oranı düşüğe yaklaşım performansı %91'e kadar gerilemiştir.

Tablo 3.5 YSA ile arıza türünün tespitinde nöron sayısının yaklaşım performansına etkisi

Nöron Sayısı	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
5	0.047156	96.4	95.2	93.3	95.8
10	0.023833	98.2	97.4	97.8	98.0
15	0.017563	98.3	97.4	97.0	98.0
20	0.02519	99.4	95.9	96.3	98.4
25	0.01666	98.1	97.8	97.8	98.0
30	0.01138	99.0	98.9	97.0	98.7

Tablo 3.6. Veri setindeki eğitim, doğrulama ve test oranlarının yaklaşım performansına etkisi

Veri Setindeki Dağılım (%)	Çapraz Entropi Değeri	Eğitim Başarı Oranı (%)	Doğrulama Başarı Oranı (%)	Test Başarı Oranı (%)	Genel Başarı Oranı (%)
50, 25, 25	0.01957	97.7	97.8	98.0	97.8
60, 20, 20	0.025429	98.9	97.2	96.9	98.2
70, 15, 15	0.023833	98.2	97.4	97.8	98.0
80, 10, 10	0.34299	96.0	97.2	95.0	96.0
90, 5, 5	0.078722	91.0	91.1	90.0	91.0

Sonuç olarak YSA ile SVR’lerde arıza türünün tespiti amacıyla titreşim, ses ve termal görüntü verilerine dayalı olarak kurulan yaklaşım için eğitim, doğrulama ve test oranları sırayla %70, %15, %15 olarak seçilmiştir. Yaklaşımın gizli katmanındaki nöron sayısı 10 adet olarak belirlenmiştir. Buna göre yapılan çalışmalarda kurulan yaklaşımın S, A1, A2 ve A3 redüktörlerini sınıflandırmadaki genel başarı oranının %98 civarında olduğu tespit edilmiş ve ROC eğrileri çizilmiştir. Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan YSA yaklaşımlarının sınıflandırma başarısı ve performansı farklılık göstermektedir. Verilerin ayrı ayrı kullanılması daha düşük bir yaklaşım performansına neden olmaktadır. İkili kombinasyonlarda kullanılan veriler ile kurulan yaklaşımların sınıflandırma başarısı daha yüksektir.

3.4.2. Destek Vektör Makinesi (DVM)

Sağlam ve arızalı redüktörlerin arıza tespiti ve sınıflandırması çalışmalarında kullanılan diğer bir danışmanlı öğrenme tekniği de DVM’dir. DVM, YSA’ya benzer şekilde girişleri yani öznitelik değerlerini hedef kategorilerine göre sınıflandırır. Burada hedef kategorileri sağlam ya da arızalı redüktörler olarak göz önüne alınmaktadır.

3.4.2.1. İkili Sınıflandırma: Arıza Tespiti

SVR’lerde arıza tespiti amacıyla kullanılan DVM’nin S (sağlam redüktör) ve A (arızalı redüktör) olmak üzere 2 adet çıkış sınıfı vardır.

Şekil 3.51 arıza tespiti amacıyla kurulan DVM’ye ait hata matrisini göstermektedir. Hata matrisindeki sütunlar çıkış sınıflarına yani tahmini yapılan sınıflara karşılık gelirken satırlar da hedef sınıflarına yani gerçek sınıflara karşılık gelmektedir. Koyu ve açık yeşil renkli hücreler doğru şekilde sınıflandırılmış verilerin sayısını, pembe renkli hücreler ise yanlış sınıflandırılmış verilerin sayılarını göstermektedir. Buna göre A redüktörüne ait 330, S redüktörüne ait 112 veri doğru sınıflandırılmıştır. Bunun yanında A redüktörüne ait 8 veri yanlış sınıflandırılmıştır.

Şekil 3. 52’de gerçek pozitif oranı ve yanlış negatif oranı görülmektedir. Buna göre A redüktörlerine ait verilerin %98’i doğru, %2’si yanlış sınıflandırılmıştır. S redüktörlerine

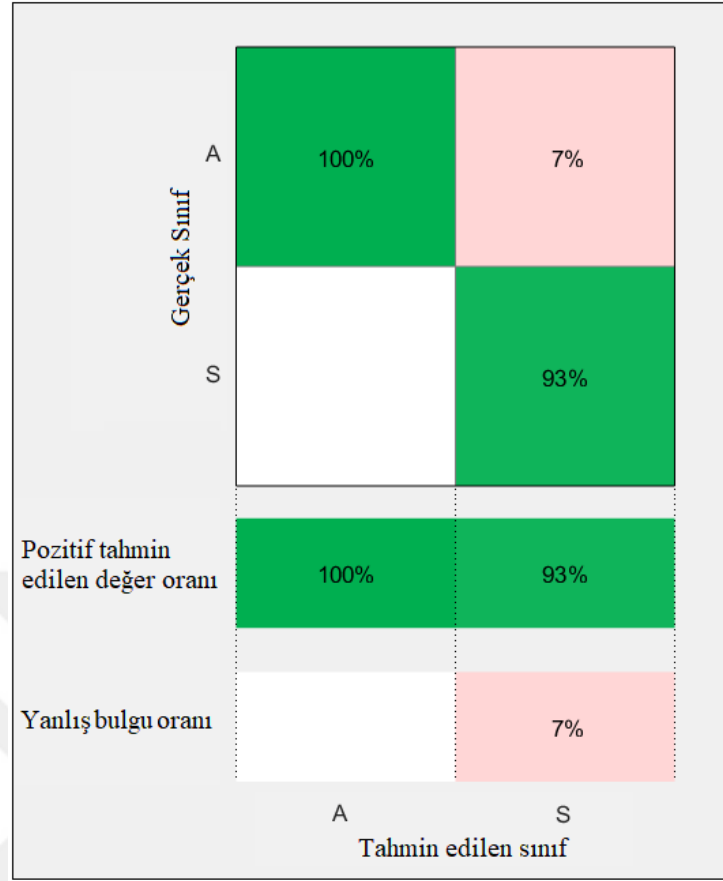
ait verilerin ise %100'ü doğru sınıflandırılmıştır. Şekil 3.53 ise pozitif tahmin edilen değerler ve yanlış bulgu oranlarını göstermektedir.

Gerçek Sınıf	A	330	8
	S		112
		A	S
		Tahmin Edilen Sınıf	

Şekil 3.51. Hata matrisi

Gerçek Sınıf	A	98%	2%	Gerçek Pozitif Oranı	98%	2%
	S		100%		Yanlış Negatif Oranı	100%
		A	S			
		Tahmin Edilen Sınıf				

Şekil 3.52. Gerçek pozitif oranı ve yanlış negatif oranı

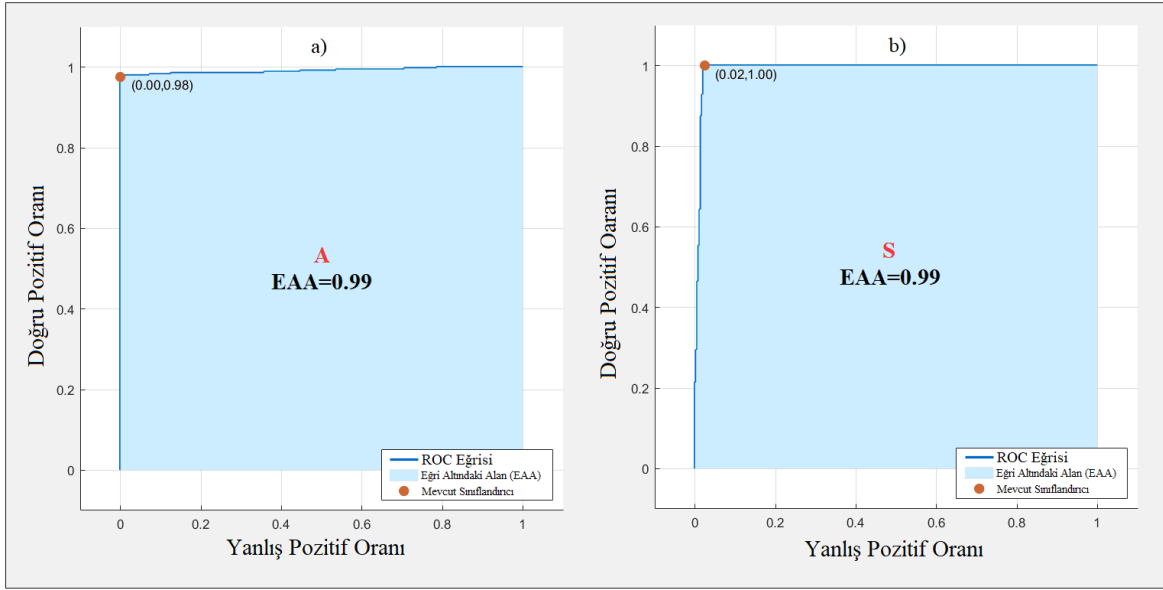


Şekil 3.53. Pozitif tahmin edilen değerler ve yanlış bulgu oranı

Şekil 3.54 A (a) ve S (b) redüktörleri için ROC eğrilerini göstermektedir. Buna göre ROC eğrileri altında kalan alanlara (EAA) bakıldığında S ve A redüktörleri için bu alanların birbirine eşit ve 0.99 olduğu görülebilir. Ancak söz konusu redüktörler için duyarlılık ve özgüllük değerleri farklıdır. Arıza tespiti amacıyla yapılan ikili sınıflandırma işleminde S redüktörü için duyarlılık değeri 1, özgüllük değeri 0.98'dir. Buna karşılık A redüktörü için özgüllük değeri 1, duyarlılık değeri 0.98'dir.

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan DVM yaklaşımları doğru sınıflandırma oranı açısından farklılık göstermektedir. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha düşük bir doğruluk oranına sebep olmaktadır (%60–90).

Arıza tespitinde S ve A redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşım tüm verilerin birlikte kullanıldığı DVM yaklaşımıdır. DVM yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel doğruluk oranının %98 civarında olduğu tespit edilmiştir.



Şekil 3.54. A (a) ve S (b) redüktörleri için ROC eğrileri

3.4.2.2. Çoklu Sınıflandırma: Arıza Türünün Sınıflandırması

SVR’lerde arıza türünün tespiti amacıyla kullanılan DVM yaklaşımının S, A1, A2 ve A3 olmak üzere 4 adet çıkış sınıfı vardır.

Şekil 3.55 arıza türünün sınıflandırılması amacıyla kurulan DVM yaklaşımına ait hata matrisini göstermektedir. Buna göre A1 redüktörüne ait 111, A2 redüktörüne ait 102, A3 redüktörüne ait 105 ve S redüktörüne ait 112 veri doğru sınıflandırılmıştır. Kırmızı bölgelerdeki veriler yanlış sınıflandırılmıştır.

Şekil 3.56’da yaklaşıma ait gerçek pozitif oranı ve yanlış negatif oranı görülmektedir. Buna göre A1 redüktörlerine ait verilerin %99’u doğru, %1’i yanlış, A2 redüktörlerine ait verilerin %90’ı doğru, %10’u yanlış, A3 redüktörlerine ait verilerin %93’ü doğru, %7’si yanlış, S redüktörlerine ait verilerin %100’ü doğru sınıflandırılmıştır.

Şekil 3.57 ise benzer şekilde pozitif tahmin edilen değerleri ve yanlış bulgu oranlarını göstermektedir.

Gerçek Sınıf	A1	111			1
	A2		102	1	10
	A3			105	8
	S				112
		A1	A2	A3	S
		Tahmin Edilen Sınıf			

Şekil 3.55. Hata matrisi

Gerçek Sınıf	A1	99%			1%	99%	1%
	A2		90%	1%	9%	90%	10%
	A3			93%	7%	93%	7%
	S				100%	100%	
		A1	A2	A3	S	Gerçek Pozitif Oranı	Yanlış Negatif Oranı
		Tahmin Edilen Sınıf					

Şekil 3.56. Gerçek pozitif oranı ve yanlış negatif oranı

Gerçek Sınıf	A1	100%			1%
	A2		100%	1%	8%
	A3			99%	6%
	S				85%
	Pozitif tahmin edilen değer oranı	100%	100%	99%	85%
Yanlış bulgu oranı			1%	15%	
		A1	A2	A3	S
		Tahmin Edilen Sınıf			

Şekil 3.57. Pozitif tahmin edilen değerler ve yanlış keşif oranı

Şekil 3.58 S (a) , A1 (b), A2 (c) ve A3 (d) redüktörlerini sınıflandırmak için kurulan DVM yaklaşımına ait ROC eğrilerini göstermektedir. Buna göre en düşük EAA değeri 0.98 olup A2 redüktörüne aittir. Yani yaklaşımın A2 redüktörünü sınıflandırmadaki başarısı diğer redüktörlerden daha düşüktür. A1 redüktörüne ait EAA değeri 1 olup diğer redüktörlerden daha yüksektir. Bu nedenle yaklaşımın bu redüktörü sınıflandırmadaki başarısı diğer redüktörlerden daha fazladır. A3 redüktörüne ait EAA değeri 1; S redüktörüne ait EAA değeri ise 0.99 olarak çıkmıştır. Genel olarak yaklaşımın tüm redüktörleri sınıflandırma başarısı birbirine yakın ve yüksektir. Ayrıca sağlam ve arızalı redüktörler için duyarlılık ve özgüllük değerlerinin birbirinden farklı olduğu görülmektedir. S redüktörü için duyarlılık değeri 1, özgüllük değeri 0.94; A1 redüktörü için duyarlılık değeri 0.99, özgüllük değeri 1; A2 redüktörü için duyarlılık değeri 0.9, özgüllük değeri 1; A3 redüktörü için duyarlılık değeri 0.93, özgüllük değeri 1'dir.



Şekil 3.58. S (a) , A1 (b), A2 (c) ve A3 (d) redüktörleri için ROC eğrileri

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan DVM yaklaşımları doğru sınıflandırma oranı açısından karşılaştırılmış ve farklılık arz ettiği görülmüştür. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha düşük bir doğruluk oranına sebep olmaktadır (%65–90).

Arıza türünün sınıflandırılmasında S, A1, A2 ve A3 redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşım tüm verilerin birlikte kullanıldığı DVM yaklaşımıdır. DVM yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel doğruluk oranının %99 civarında olduğu tespit edilmiştir. Hata matrislerine (Şekil 3.55, Şekil 3.56, Şekil

3.57) ve ROC eğrilerine (Şekil 3.58) bakıldığında yaklaşımın A1 ve A3 redüktörlerini sınıflandırmadaki başarısının diğer redüktörlerden daha yüksek olduğu görülebilir.

3.4.3. K En Yakın Komşu (k-NN)

Bu çalışmada örnek tabanlı bir makine öğrenmesi algoritması olan k-NN de arıza tespiti ve sınıflandırması amacıyla kullanılmıştır. K-NN sağlam ve arızalı redüktörlerden toplanan veri örneklerinin bu örneklere benzer özelliklere sahip diğer örneklere yakın olacağı prensibine göre sınıflandırma yapmaktadır. Örnekler sağlam ya da arızalı redüktör etiketi ile belirlendiği için sınıflandırılmamış bir örneğin etiketi de en yakın komşularının sınıfına bakılarak belirlenir.

3.4.3.1. İkili Sınıflandırma: Arıza Tespiti

SVR'lerde arıza tespiti amacıyla kullanılan k-NN algoritmasının S (sağlam redüktör) ve A (arızalı redüktör) olmak üzere 2 adet çıkış sınıfı vardır.

Şekil 3.59 arıza tespiti amacıyla kurulan k-NN yaklaşımına ait hata matrisini göstermektedir. Buna göre A redüktörüne ait 333, S redüktörüne ait 110 veri doğru sınıflandırılmıştır. Bunun rağmen A redüktörüne ait 5 ve S redüktörüne ait 2 veri yanlış sınıflandırılmıştır.

Şekil 3.60'ta gerçek pozitif oranı ve yanlış negatif oranı görülmektedir. Buna göre A redüktörlerine ait verilerin %99'u doğru, %1'i yanlış sınıflandırılmıştır. S redüktörlerine ait verilerin %98'i doğru, %2'si yanlış sınıflandırılmıştır.

Şekil 3.61 ise pozitif tahmin edilen değerler ve yanlış bulgu oranlarını göstermektedir.

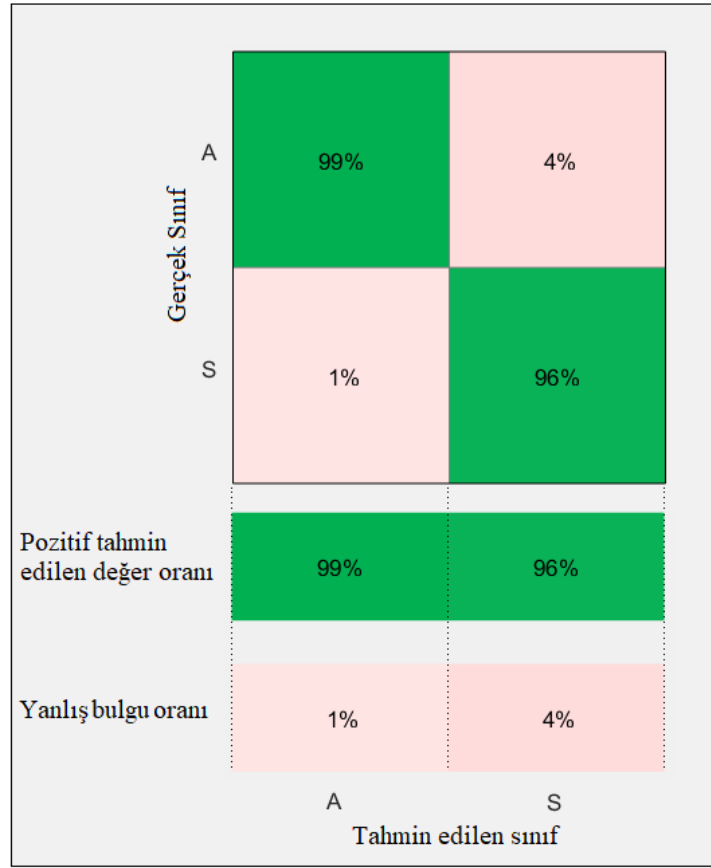
Şekil 3.62 S (a) ve A (b) redüktörleri için ROC eğrilerini göstermektedir. Buna göre ROC eğrileri altında kalan alanlara bakıldığında S ve A redüktörleri için bu alanların neredeyse eşit olduğu görülebilir (EAA=1). Ancak söz konusu redüktörler için duyarlılık ve özgüllük değerleri farklıdır. Arıza tespiti amacıyla sınıflandırma işleminde S redüktörü için duyarlılık değeri 0.98, özgüllük değeri 0.99'dur. Buna karşılık A redüktörü için duyarlılık değeri 0.99, özgüllük değeri 0.98'dir.

Gerçek Sınıf	A	333	5
	S	2	110
		A	S
		Tahmin Edilen Sınıf	


Şekil 3.59. Hata matrisi

Gerçek Sınıf	A	99%	1%		99%	1%
	S	2%	98%			
		A	S		Gerçek Pozitif Oranı	Yanlış Negatif Oranı
		Tahmin Edilen Sınıf				

Şekil 3.60. Gerçek pozitif oranı ve yanlış negatif oranı



Şekil 3.61. Pozitif tahmin edilen değer ve yanlış bulgu oranı



Şekil 3.62. S (a) ve A (b) redüktörleri için ROC eğrileri

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan k-NN yaklaşımları doğru sınıflandırma oranı açısından farklılık göstermektedir. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha düşük bir doğruluk oranına sebep olmaktadır (%60–85).

Arıza tespitinde S ve A redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşım tüm verilerin birlikte kullanıldığı k-NN yaklaşımıdır. K-NN yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel doğruluk oranının %98 civarında olduğu tespit edilmiştir.

3.4.3.2. Çoklu Sınıflandırma: Arıza Türünün Sınıflandırması

SVR’lerde arıza türünün tespiti amacıyla kullanılan k-NN yaklaşımının S, A1, A2 ve A3 olmak üzere 4 adet çıkış sınıfı vardır.

Şekil 3.63 arıza türünün sınıflandırılması amacıyla kurulan k-NN yaklaşımına ait hata matrisini göstermektedir. Buna göre A1 redüktörüne ait 112, A2 redüktörüne ait 107, A3 redüktörüne ait 111 ve S redüktörüne ait 109 veri doğru sınıflandırılmıştır. Kırmızı görünen bölgelerdeki veriler yanlış sınıflandırılmıştır.

Gerçek Sınıf	A1	112	1		
	A2		107		5
	A3		2	111	
	S		2	1	109
		A1	A2	A3	S
		Tahmin Edilen Sınıf			

Şekil 3.63. Hata matrisi

Şekil 3.64'te yaklaşıma ait gerçek pozitif oranı ve yanlış negatif oranı görülmektedir. Buna göre A1 redüktörlerine ait verilerin %99'u doğru, %1'i yanlış, A2 redüktörlerine ait verilerin %96'sı doğru, %4'ü yanlış, A3 redüktörlerine ait verilerin %98'i doğru, %2'si yanlış, S redüktörlerine ait verilerin %97'si doğru, %3'ü yanlış sınıflandırılmıştır. Şekil 3.65 ise benzer şekilde pozitif tahmin edilen değerleri ve yanlış bulgu oranlarını göstermektedir.

Gerçek Sınıf	A1	99%	1%			99%	1%
	A2		96%		4%	96%	4%
	A3		2%	98%		98%	2%
	S		2%	1%	97%	97%	3%
		A1	A2	A3	S	Gerçek Pozitif Oranı	Yanlış Negatif Oranı
		Tahmin Edilen Sınıf					

Şekil 3.64. Gerçek pozitif oranı ve yanlış negatif oranı

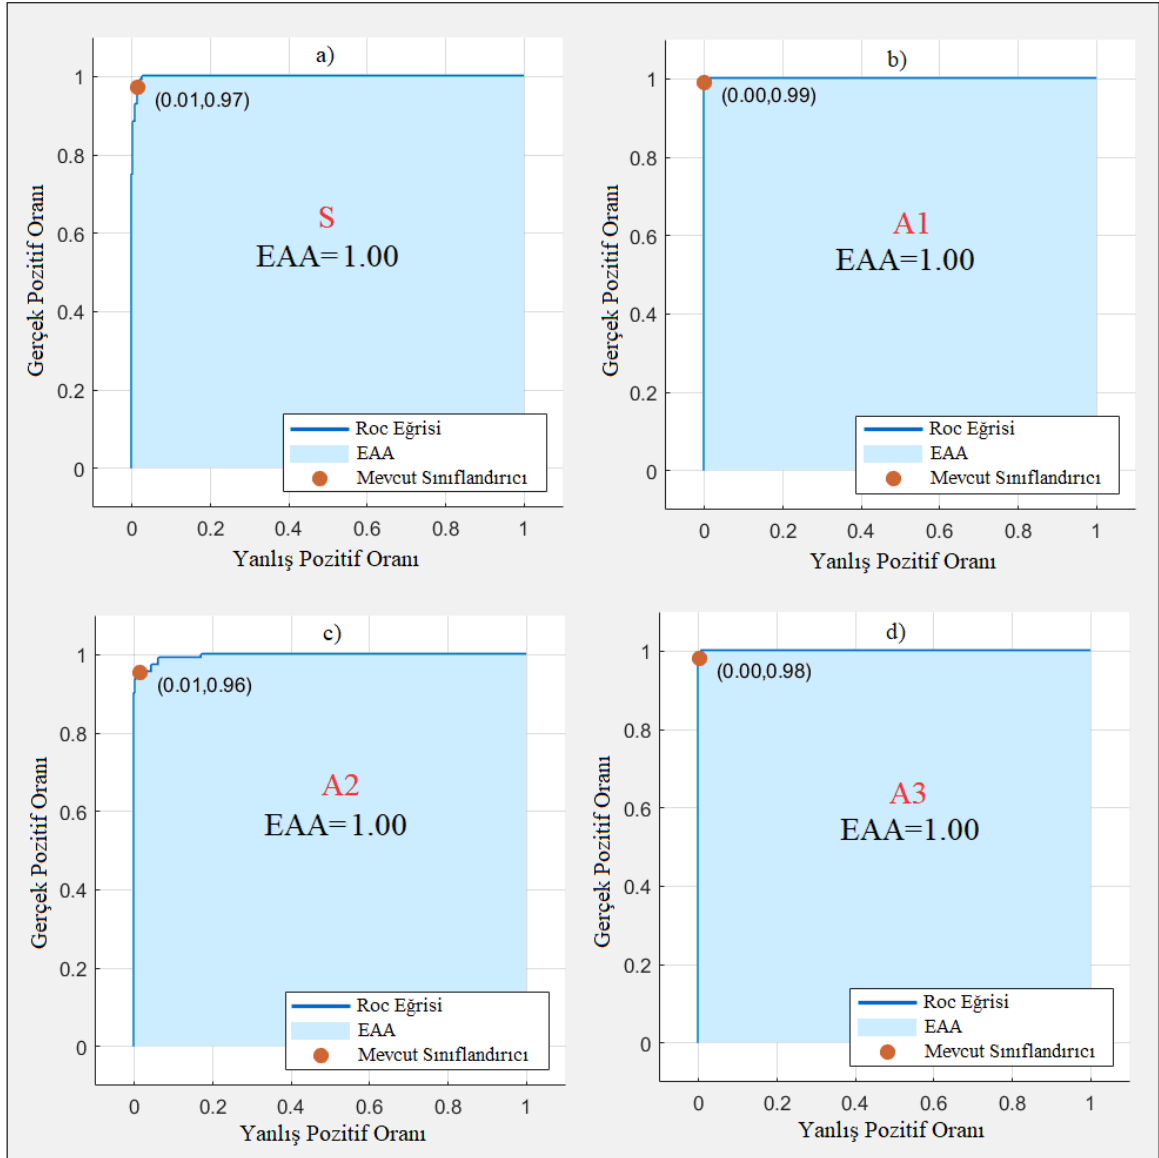
Şekil 3.66 S (a) , A1 (b) , A2 (c) ve A3 (d) redüktörlerini sınıflandırmak için kurulan k-NN yaklaşımına ait ROC eğrilerini göstermektedir. Buna göre yaklaşımın tüm redüktörleri sınıflandırma başarısı yüksek ve tüm EAA değerleri 1'dir. Ancak sağlam ve arızalı redüktörler için duyarlılık ve özgüllük değerlerinin birbirinden farklı olduğu görülmektedir. Buna göre S redüktörüne ait duyarlılık değeri 0.97, özgüllük değeri 0.99; A1 redüktörüne ait duyarlılık değeri 0.99, özgüllük değeri 1; A2 redüktörüne ait duyarlılık değeri 0.96, özgüllük değeri 0.99; A3 redüktörüne ait duyarlılık değeri 0.98, özgüllük değeri 1'dir.

Gerçek Sınıf	A1	100%	1%		
	A2		96%		4%
	A3		2%	99%	
	S		2%	1%	96%
Pozitif tahmin edilen değer oranı		100%	96%	99%	96%
Yanlış bulgu oranı			4%	1%	4%
		A1	A2	A3	S
		Tahmin Edilen Sınıf			

Şekil 3.65. Pozitif tahmin edilen değerler ve yanlış keşif oranı

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşım ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan k-NN yaklaşımları doğru sınıflandırma oranı açısından karşılaştırılmış ve farklılık arz ettiği görülmüştür. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha düşük bir doğruluk oranına sebep olmaktadır (%65–85).

Arıza türünün sınıflandırılmasında S, A1, A2 ve A3 redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşım tüm verilerin birlikte kullanıldığı k-NN yaklaşımıdır. K-NN yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel doğruluk oranının %97 civarında olduğu tespit edilmiştir. Hata matrislerine (Şekil 3.63, Şekil 3.64, Şekil 3.65) ve ROC eğrilerine (Şekil 3.66) bakıldığında yaklaşımın A1 redüktörünü sınıflandırmadaki başarısının diğer redüktörlerden daha yüksek olduğu görülebilir.



Şekil 3.66. S (a) , A1 (b), A2 (c) ve A3 (d) redüktörleri için ROC eğrileri

3.4.4. Adaptif Nöro-Bulanık Çıkarım (ANFIS)

Arıza tespiti ve sınıflandırması ile ilgili yapılan çalışmalarda bir hibrit zeki sistem (HZS) olan adaptif nöro-bulanık çıkarım (ANFIS) tekniği de kullanılmıştır.

Bu çalışmada ANFIS mimarisi için öznitelik sütunlarından oluşan 19 giriş parametresi kullanılmıştır. ANFIS çıkış parametresi f ise sağlam veya arızalı redüktörleri temsil etmektedir.

3.4.4.1. İkili Sınıflandırma: Arıza Tespiti

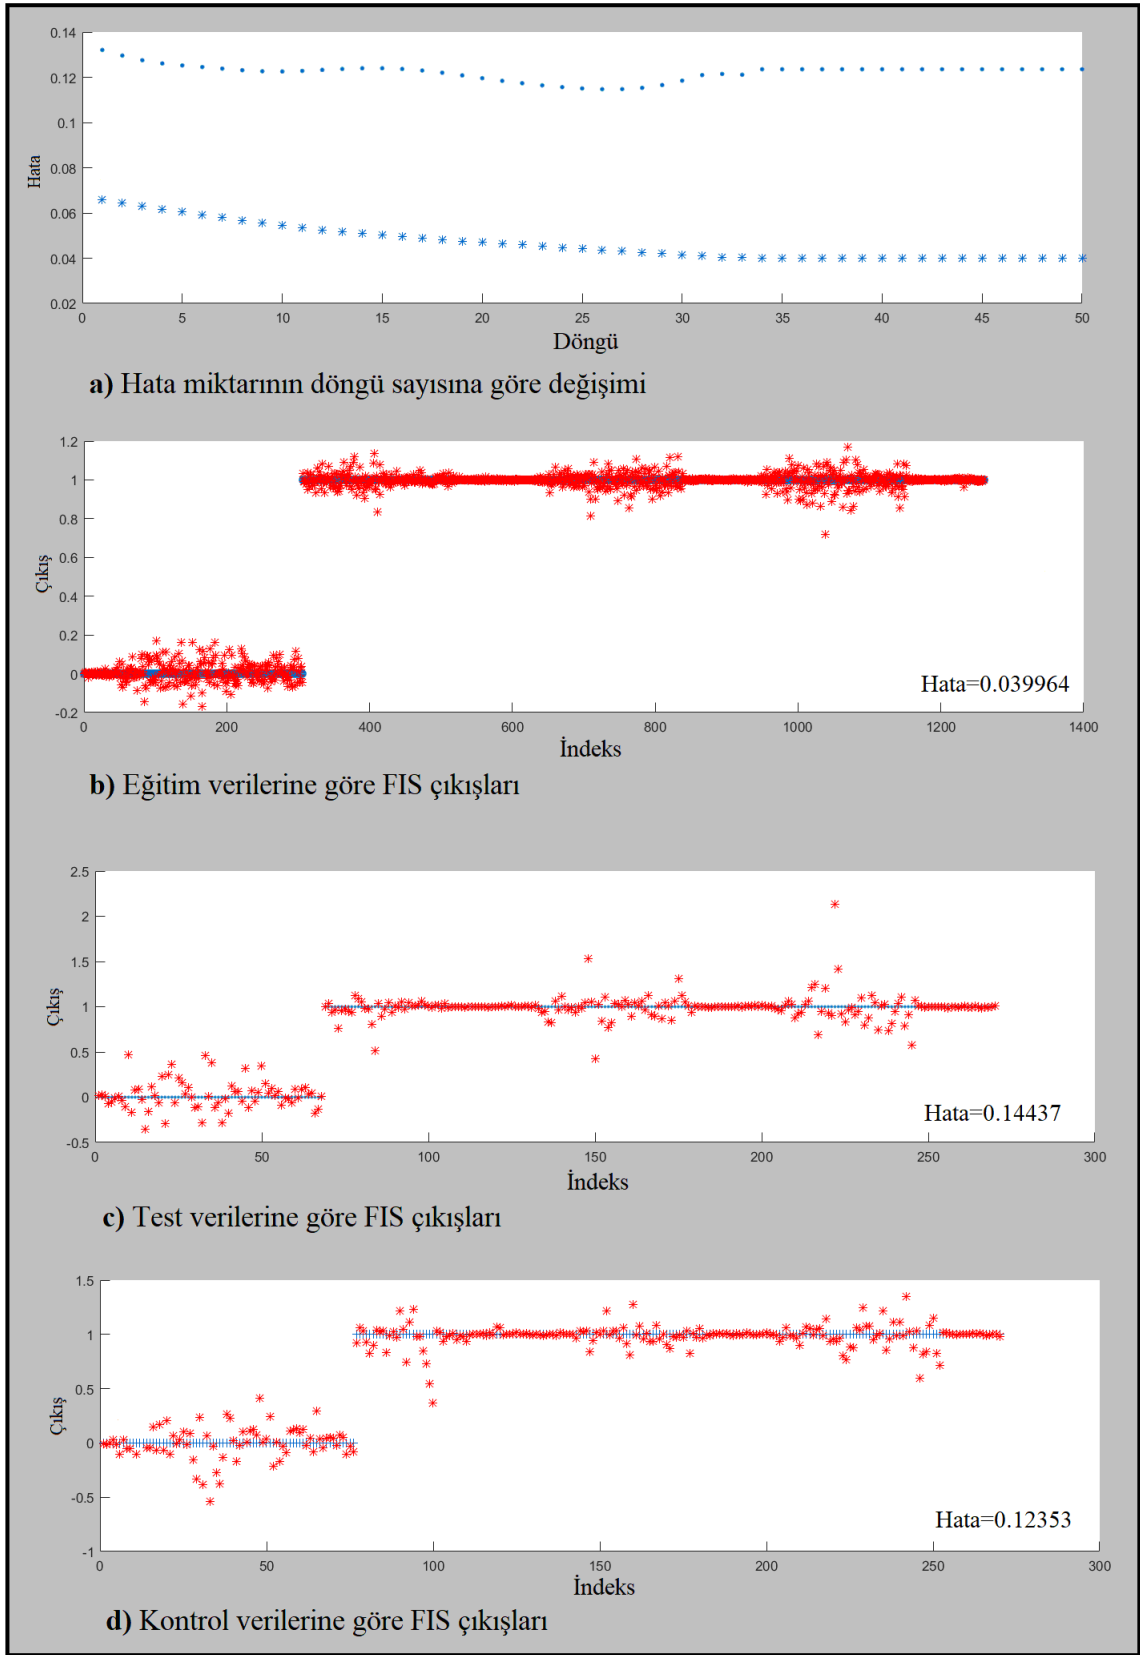
SVR'lerde arıza tespiti amacıyla kullanılan ANFIS algoritması tek çıkış fonksiyonuna sahiptir. Bu nedenle veri setindeki S redüktörü 0 ile, A redüktörü de 1 ile temsil edilmektedir.

Şekil 3.67 a) FIS eğitimi sürecinde çıkış değerlerinin hedef değerlerinden ne kadar saptığının bir ölçüsü olan ortalama karesel hata oranının döngü sayısına göre değişimini göstermektedir. Buna göre döngü sayısı arttıkça hata 0.039964 değerine kadar düşmüş, 40. döngüden sonra da sabit hale gelmiştir

Şekil 3.67 b), c) ve d) sırasıyla eğitim, test ve kontrol verilerine göre FIS çıkışlarını ve ortalama hata değerlerini göstermektedir. Grafiklerdeki kırmızı renkli semboller yaklaşıma ait FIS çıkışlarını, mavi renkli semboller ise hedeflenen çıkışları yani S ve A redüktörlerini temsil etmektedir. Buna göre eğitim veri seti için ortalama hata 0.039964, test veri seti için ortalama hata 0.14437, kontrol veri seti için ortalama hata 0.12353 olarak gerçekleşmiştir.

Şekilde sınıf etiketi altında kalan ve etiketten dışarı taşan veri sayıları göz önüne alınarak eğitim ve test başarı oranları hesaplanmıştır. Buna göre arıza tespiti için kurulan ANFIS yaklaşımının eğitim başarı oranı %85 ve test başarı oranı %70 olarak gerçekleşmiştir.

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı ANFIS yaklaşımı ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan yaklaşımlar hata oranı açısından farklılık göstermektedir. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha yüksek hata oranına ve %20–40 oranında daha düşük eğitim ve test başarısına sebep olmaktadır. Arıza tespitinde S ve A redüktörlerinin sınıflandırılması amacıyla kurulan en başarılı yaklaşım tüm verilerin birlikte kullanıldığı ANFIS yaklaşımıdır. ANFIS yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel hata oranının 0.03 civarında olduğu görülmüştür. Ayrıca eğitim başarı oranı %85 ve test başarı oranı %70 civarında değişmektedir.



Şekil 3.67. FIS eğitime ait sonuçlar

3.4.4.2. Çoklu Sınıflandırma: Arıza Türünün Sınıflandırması

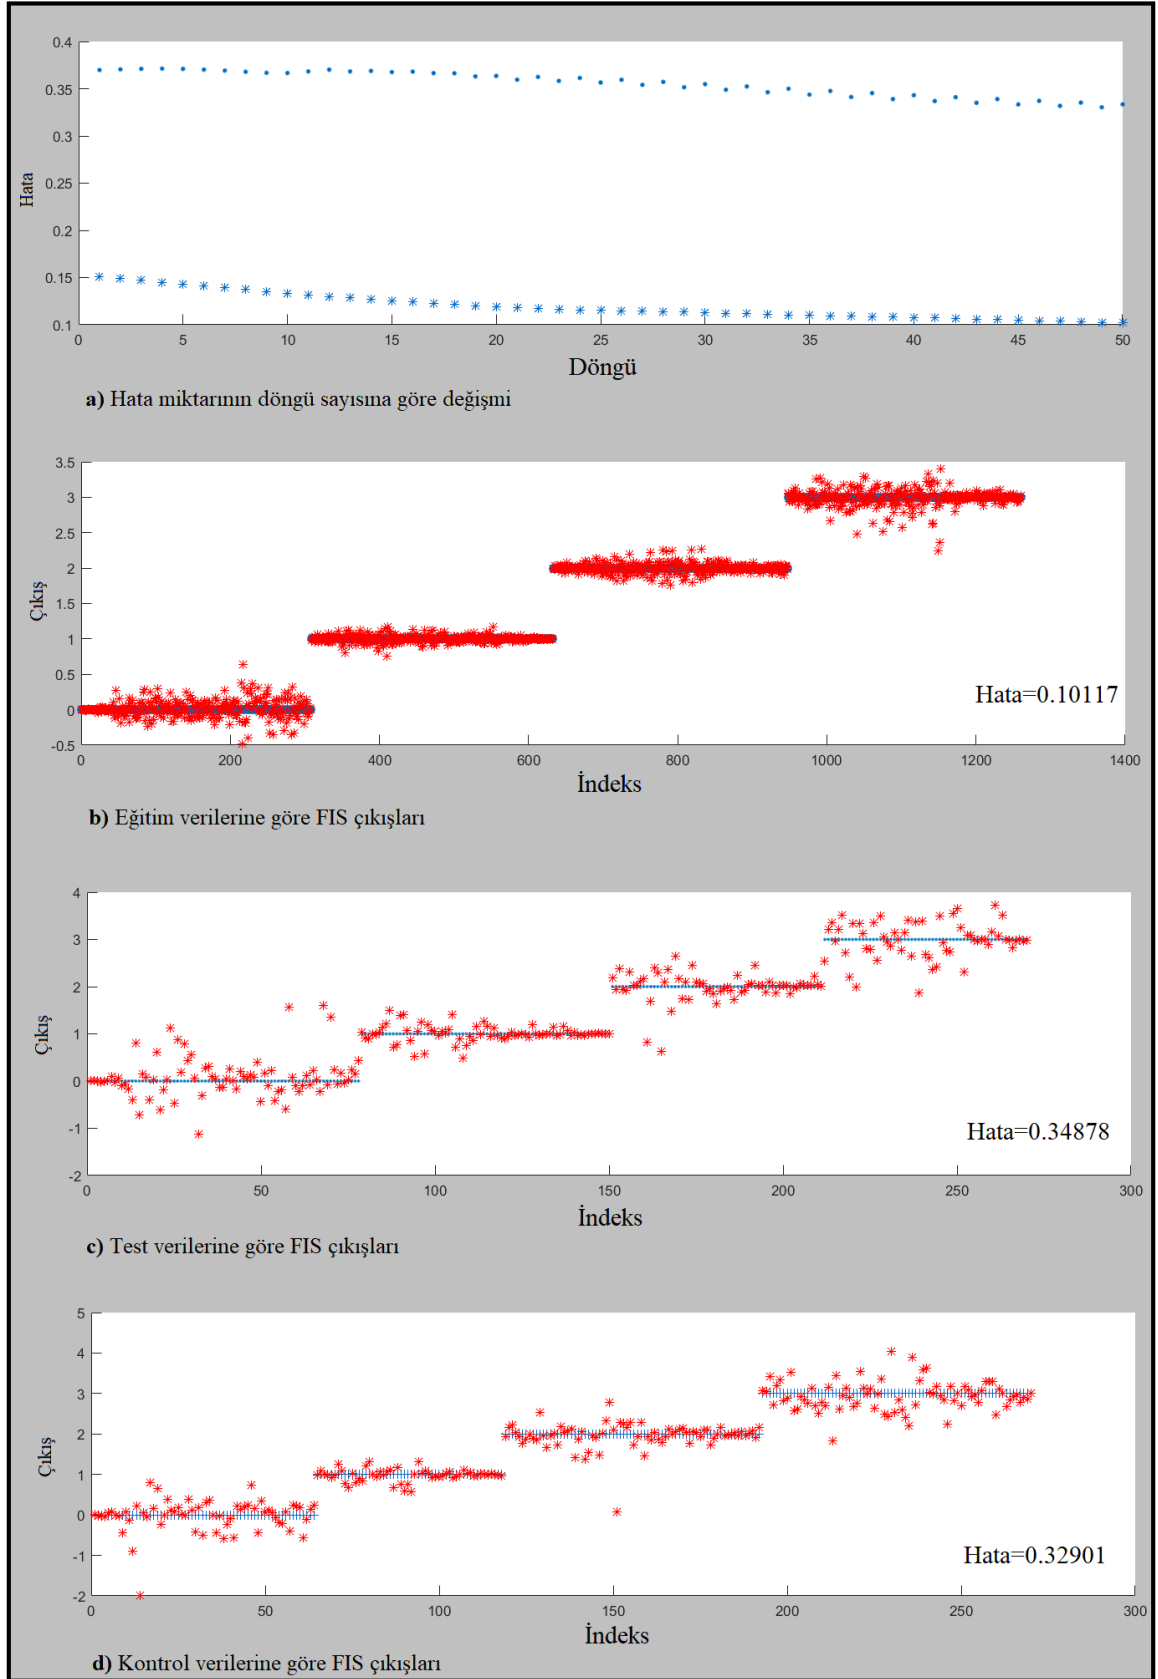
SVR'lerde arıza türünün sınıflandırılması amacıyla kullanılan ANFIS algoritması tek çıkış fonksiyonuna sahip olması nedeniyle veri setindeki S redüktörü 0, A1 redüktörü 1, A2 redüktörü 2 ve A3 redüktörü 3 ile temsil edilmektedir.

Şekil 3.68 a) FIS eğitimi sürecinde çıkış değerlerinin hedef değerlerinden ne kadar saptığının bir ölçüsü olan ortalama karesel hata oranının döngü sayısına göre değişimini göstermektedir. Buna göre döngü sayısı arttıkça hata 0.10117 değerine kadar düşmüş 45. döngüden sonra da sabit hale gelmiştir.

Şekil 3.68 b), c) ve d) sırasıyla eğitim, test ve kontrol verilerine göre FIS çıkışlarını ve ortalama hata değerlerini göstermektedir. Buna göre eğitim veri seti için ortalama hata 0.10117, test veri seti için ortalama hata 0.34878, kontrol veri seti için hata 0.32901 olarak gerçekleşmiştir.

Şekilde sınıf etiketi altında kalan ve etiketten dışarı taşan veri sayıları göz önüne alınarak eğitim ve test başarı oranları hesaplanmıştır. Buna göre arıza türünün tespiti için kurulan ANFIS yaklaşımının eğitim başarı oranı %76 ve test başarı oranı %55 olarak gerçekleşmiştir.

Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı yaklaşımlar ile bu verilerinin ayrı ayrı ve ikili kombinasyonlarda kullanılmasıyla kurulan ANFIS yaklaşımları hata oranı açısından farklılık göstermektedir. Verilerin ayrı ayrı ya da ikili kombinasyonda kullanılması daha yüksek hata oranına sebep olmakta ve yaklaşım başarı oranlarını %20–40 civarında düşürmektedir. Arıza tespiti ve arıza türünün sınıflandırılması amacıyla kurulan en başarılı yaklaşımlar tüm verilerin birlikte kullanıldığı ANFIS yaklaşımlarıdır. Arıza türünün sınıflandırılması için kurulan ANFIS yaklaşımı ayrı ayrı 10 defa eğitilmiş ve genel hata oranının 0.1 civarında olduğu görülmüştür. Ayrıca eğitim başarı oranı %76 ve test başarı oranı %55 civarında değişmektedir.



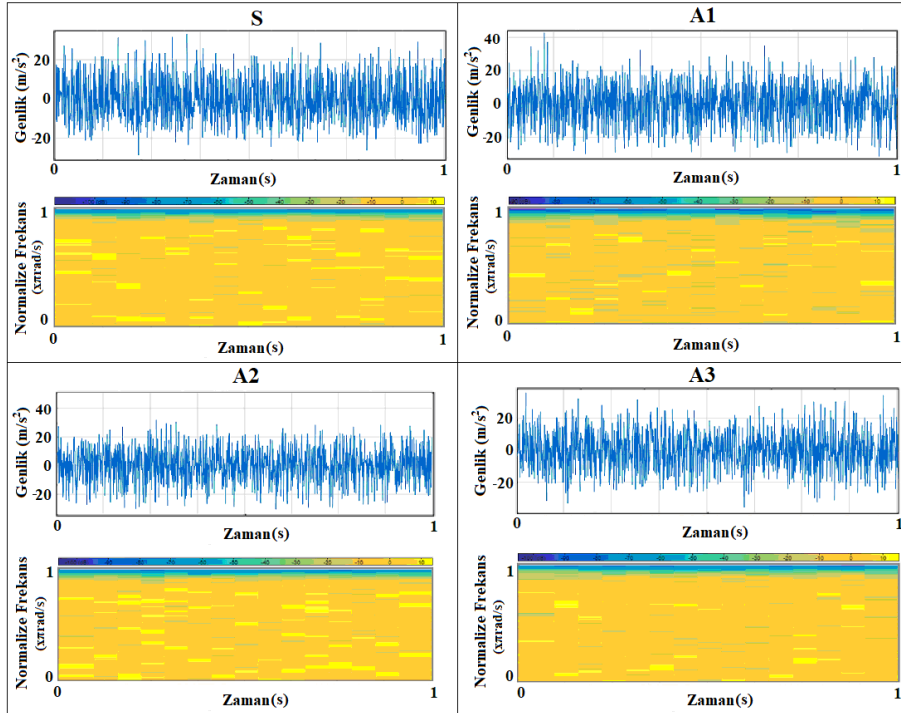
Şekil 3.68. FIS eğitimiine ait sonuçlar

3.4.5. Derin Öğrenme

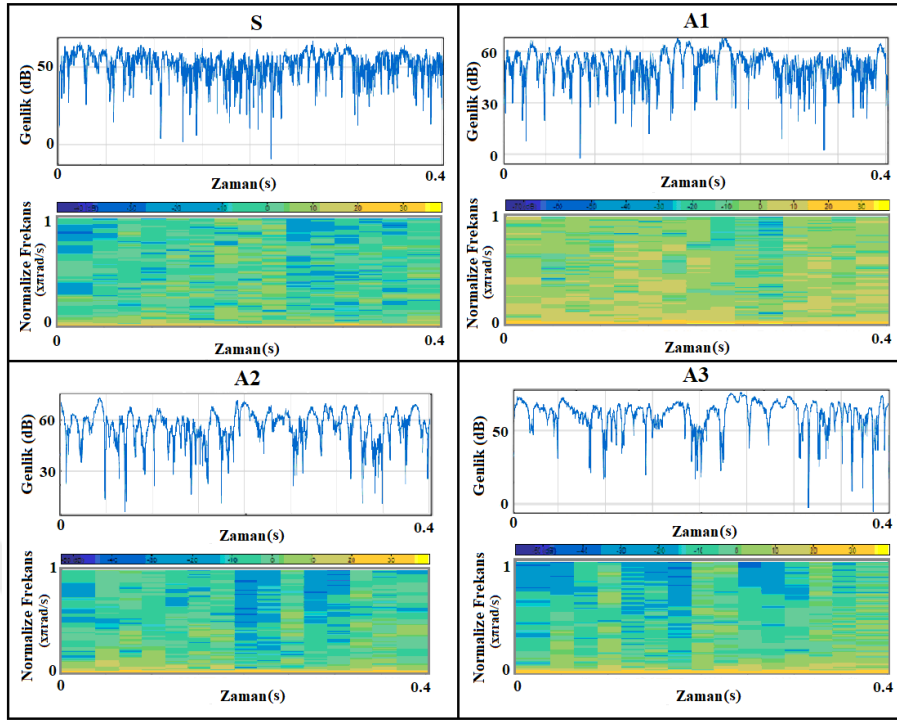
Arıza tespiti ve sınıflandırması ile ilgili yapılan çalışmalarda kullanılan algoritmaların sonucusu derin öğrenmedir.

Yapılan çalışmalarda her bir redüktör için farklı hız ve yükleme oranlarında toplanan 120 adet termal görüntü (dört redüktör için toplam 480) IRT-KSA yaklaşımının eğitimi, doğrulanması ve testi için kullanılmıştır. Benzer şekilde, 120 adet titreşim spektrogramı (dört redüktör için toplam 480) T-KSA yaklaşımı için ve 120 adet ses spektrogramı da (dört redüktör için toplam 480) S-KSA yaklaşımı için kullanılmıştır. TS-KSA yaklaşımının eğitimi, doğrulanması ve testi için de titreşim ve ses sinyallerinin spektrogram görüntüleri birlikte kullanılmıştır.

Şekil 3.69'da YO=%50 ve RÇH=50 d/dk için farklı redüktörlerden toplanan titreşim sinyallerinin zaman dalga formu ve spektrogram görüntüleri görülmektedir. Şekil 3.70'de ise YO=%50 ve RÇH=50 d/dk için farklı redüktörlerden toplanan ses sinyallerinin zaman dalga formu ve spektrogram görüntüleri görülmektedir. Farklı KSA yaklaşımlarının eğitimi, doğrulanması ve testi için kullanılan veri sayıları ve sınıf etiketleri Tablo 3.7'de verilmiştir.



Şekil 3.69. Titreşim ölçümlerine ait zaman dalga formu ve spektrogram görüntüleri




Şekil 3.70. Ses ölçümlerine ait zaman dalga formu ve spektrogram görüntüleri

Tablo 3.7. Sınıf etiketleri ve farklı KSA yaklaşımları için kullanılan görsel verilerin miktarı


Sınıf Etiketleri	Eğitim	Doğrulama	Test
S	60	30	30
A1	60	30	30
A2	60	30	30
A3	60	30	30

Şekil 3.71’de IRT-KSA, T-KSA, S-KSA ve TS-KSA yaklaşımları için eğitim sürecindeki iterasyon sayısına bağlı olarak doğruluk oranlarındaki değişim görülmektedir. Buna göre, termal görüntülere dayalı IRT-KSA yaklaşımının eğitim süreci sonunda en yüksek doğruluk oranına ulaştığı görülebilir. IRT-KSA yaklaşımı, 30 iterasyon ve 10 döngü (epok) sonrasında %100 doğruluk oranına ulaşmıştır. Aynı iterasyon ve döngü sayısında bu başarı oranı, T-KSA yaklaşımı için %87.5, S-KSA yaklaşımı içinse %81.67 olarak gerçekleşmiştir. Titreşim ve ses spektrogramlarının birlikte kullanıldığı TS-KSA yaklaşımının eğitim ve doğrulama başarısı ise %73.33 oranında kalmıştır.



Şekil 3.71. Farklı KSA yaklaşımları için doğruluk oranları

Şekil 3.72 farklı KSA yaklaşımlarının eğitim ve doğrulama sürecindeki kayıplarını göstermektedir. Kayıp kavramı, kestirimi yapılan çıkış ile gerçek çıkış arasındaki farkın nicel bir ölçüsü olarak ifade edilebilir. İterasyon sayısı arttıkça yaklaşımlara ait kayıplar azalmıştır. Bunun yanında, veri setinin uygunluğu ve yeterliliği hem kayıp miktarını hem de iterasyon sayısını azaltmaktadır. Buna göre, eğitim ve doğrulama süreci boyunca farklı KSA yaklaşımları içinde en yüksek kayıp miktarı TS-KSA yaklaşımı için gerçekleşmiştir. IRT-KSA yaklaşımına ait kayıp, 30 iterasyon ve 10 döngü (epok) sonunda 0'a düşmüştür.



Şekil 3.72. Farklı KSA yaklaşımları için kayıplar

KSA yaklaşımlarının testi için redüktörlerden toplanan görsel verilerin %25'i kullanılmıştır. Test sonucu IRT-KSA, T-KSA, S-KSA ve TS-KSA yaklaşımları için hesaplanan hata matrisleri Şekil 3.73'de görülmektedir.

		IRT-KSA					T-KSA				
Çıkış Sınıfı	A1	30 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	25 20.8%	1 0.8%	0 0.0%	11 9.2%	67.6% 32.4%
	A2	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%	5 4.2%	29 24.2%	0 0.0%	3 2.5%	78.4% 21.6%
	A3	0 0.0%	0 0.0%	30 25.0%	0 0.0%	100% 0.0%	0 0.0%	0 0.0%	30 25.0%	0 0.0%	100% 0.0%
	S	0 0.0%	0 0.0%	0 0.0%	30 25.0%	100% 0.0%	0 0.0%	0 0.0%	0 0.0%	16 13.3%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	83.3% 16.7%	96.7% 3.3%	100% 0.0%	53.3% 46.7%	83.3% 16.7%
		Hedef Sınıf				Hedef Sınıf					
		A1	A2	A3	S						
		S-KSA					TS-KSA				
Çıkış Sınıfı	A1	12 10.0%	0 0.0%	3 2.5%	0 0.0%	80.0% 20.0%	21 17.5%	11 9.2%	4 3.3%	5 4.2%	51.2% 48.8%
	A2	0 0.0%	29 24.2%	0 0.0%	0 0.0%	100% 0.0%	2 1.7%	12 10.0%	2 1.7%	4 3.3%	60.0% 40.0%
	A3	4 3.3%	0 0.0%	27 22.5%	0 0.0%	87.1% 12.9%	2 1.7%	1 0.8%	24 20.0%	0 0.0%	88.9% 11.1%
	S	14 11.7%	1 0.8%	0 0.0%	30 25.0%	66.7% 33.3%	5 4.2%	6 5.0%	0 0.0%	21 17.5%	65.6% 34.4%
		40.0% 60.0%	96.7% 3.3%	90.0% 10.0%	100% 0.0%	81.7% 18.3%	70.0% 30.0%	40.0% 60.0%	80.0% 20.0%	70.0% 30.0%	65.0% 35.0%
		Hedef Sınıf				Hedef Sınıf					
		A1	A2	A3	S						

Şekil 3.73. KSA yaklaşımlarına ait hata matrisleri

IRT-KSA yaklaşımı S, A1, A2 ve A3 redüktörleri için tüm test girişlerini doğru bir şekilde sınıflandırmıştır. IRT-KSA yaklaşımı için test 10 defa tekrarlanmış ve aynı sonuç elde edilmiştir. T-KSA yaklaşımına ait sonuçlara bakıldığında, doğru sınıflandırma oranının %83.3 olduğu ve S redüktörüne ait verilerin neredeyse yarısının yanlış


sınıflandırıldığı görülmektedir. S-KSA yaklaşımına ait test sonuçlarına bakıldığında ise verilerin %81.7'sinin doğru tahmin edildiği görülmektedir. Bu yaklaşım için, özellikle A1 redüktörünü sınıflandırma başarısı düşüktür. En düşük test başarı oranı TS-KSA yaklaşımına aittir. Bu yaklaşımda tüm örneklerin sadece %65'i doğru tahmin edilmiştir. TS-KSA yaklaşımı, A2 redüktörüne ait verileri büyük ölçüde yanlış sınıflandırmıştır. Titreşim ve ses spektrogram verilerinin yaklaşım başarısına etkisi termal kamera görüntülerinden daha az olduğu görülmektedir. Bunun nedeni, spektrogram verilerinin çalışma ve arıza durumlarını temsil başarısı termal görüntülerden daha az olduğu şeklinde ifade edilebilir.

Farklı sayıdaki görsel verilerle eğitilmiş ve test edilmiş KSA yaklaşımlarına ait başarı oranları Tablo 3.8'de verilmiştir. Buna göre, örnek sayısı arttıkça farklı KSA yaklaşımlarına ait eğitim, doğrulama ve test başarı oranları artmaktadır. Tüm yaklaşımlar için en yüksek eğitim ve test başarısı 120 örneğin kullanıldığı durumda gerçekleşmiştir. Farklı veri sayıları ile eğitilen IRT-KSA yaklaşımlarına ait başarı oranları diğer yaklaşımların tümünden daha yüksektir. Tablodan görülen bir diğer husus da, IRT-KSA yaklaşımına ait eğitim veri sayısı 30 veya 60 olsa bile, yaklaşım hâlâ yüksek oranda doğru sınıflandırma yapmaktadır. Artan eğitim ve doğrulama veri sayısı T-KSA, S-KSA ve TS-KSA yaklaşımlarına ait başarı oranlarını da ciddi bir biçimde etkilemektedir.

Tablo 3.8. Örnek sayısının KSA yaklaşımlarının performansına etkisi

KSA Yaklaşımları	Görsel Veri Miktarı	Eğitim ve Doğrulama Başarısı (%)	Test Başarısı (%)	Eğitim Zamanı (s)
IRT-KSA	30	90.63	89.3	122
IRT-KSA	60	95	90	123
IRT-KSA	120	100	100	366
T-KSA	30	59.38	57.1	129
T-KSA	60	65	61.7	145
T-KSA	120	87.50	83.3	456
S-KSA	30	59.38	42.9	127
S-KSA	60	58.33	41.7	142
S-KSA	120	81.67	81.7	395
TS-KSA	30	40.63	39.3	128
TS-KSA	60	46.67	55	147
TS-KSA	120	73.33	65	423

Yapılan çalışmalarda incelenen bir diğer konu da yaklaşımların eğitiminde kullanılan görsel verilerin çözünürlükleri ile ilgilidir. Görüntü çözünürlüğü, farklı giriş kaynaklarına, farklı görüntüleme cihazlarına veya farklı ortamlarda yapılan görüntüleme işlemine göre farklılık arz edebilir. Görüntü çözünürlüğündeki değişiklik görüntülerin içerdikleri görsel bilgileri de değiştirecektir. Bu doğrultuda, farklı çözünürlükteki termal kamera görüntüleri kullanılarak eğitilen IRT-KSA yaklaşımına ait başarı oranlarının değişimi Şekil 3.74'te verilmiştir. Buna göre, yaklaşımın eğitilmesinde kullanılan görsel verilerin çözünürlüğünün azalması durumunda yaklaşımın doğru sınıflandırma başarısı da düşmektedir.



Şekil 3.74. Termal görüntü çözünürlüğünün yaklaşım başarısına etkisi

Farklı hız ve yükleme oranlarında çalışabilen deney düzeneği ile gerçek çalışma koşulları daha iyi taklit edilebildiği için toplanan termal görüntüler ile kurulan IRT-KSA yaklaşımı, diğer yaklaşımlara nazaran daha başarılı sonuçlar ortaya koymuştur. Çalışma koşulları ve arızanın türü redüktör üzerindeki sıcaklık dağılımını ve termal görüntünün yapısını doğrudan etkilemektedir. Bu nedenle, IRT-KSA yaklaşımı diğer yaklaşımlara kıyasla daha yüksek oranda doğru sınıflandırma yapmıştır. IRT-KSA yaklaşımı sağlam ve arızalı redüktörleri %100 oranında doğru sınıflandırmıştır. Buna rağmen, T-KSA yaklaşımının sınıflandırma başarısı %83.3, S-KSA yaklaşımının sınıflandırma başarısı ise %81.7 olarak gerçekleşmiştir. TS-KSA yaklaşımı ise %65 doğru sınıflandırma oranıyla en düşük performansı sergilemiştir. Bu karşılaştırma, termal kamera görüntülerine dayalı KSA yaklaşımlarının, küçük veri setleri kullanılsa bile yüksek bir doğruluk payıyla,

özellikle çalışma sıcaklığının arızalardan etkilendiği sistemler ve makineler üzerinde arıza tespiti ve sınıflandırması amacıyla kullanılabileceği göstermektedir.

3.4.6. YZ Yaklaşımlarının Karşılaştırılması

Tüm YZ yaklaşımlarının kıyas edilmesi açısından Tablo 3.9 ve Tablo 3.10 çoklu ve ikili sınıflandırma yaklaşımlarına ait doğruluk, duyarlılık ve özgüllük değerlerini karşılaştırmaktadır.

Buna göre arıza tespiti amacıyla kuruyan YZ yaklaşımlarından YSA, DVM ve k-NN'in doğruluk değerleri 0.98'dir. ANFIS yaklaşımına ait doğruluk değeri ise 0.85'tir. YSA, DVM ve k-NN yaklaşımlarının S ve A redüktörlerini sınıflandırması ile ilgili duyarlılık ve özgüllük değerleri birbirine yakın olup 0.96 ile 1 arasında değişmektedir. En yüksek duyarlılık değeri 1 olarak DVM yaklaşımının S redüktörünü sınıflandırmasında elde edilmiştir. En düşük duyarlılık değeri ise 0.96 olarak YSA yaklaşımının S redüktörünü sınıflandırmasında elde edilmiştir. En yüksek özgüllük değeri 1 olarak DVM yaklaşımının A redüktörünü sınıflandırmasında, en düşük duyarlılık değeri ise 0.96 olarak YSA yaklaşımının A redüktörünü sınıflandırmasında elde edilmiştir.

Arızanın türünün sınıflandırılması amacıyla kuruyan YZ yaklaşımlara bakıldığında ise IRT-KSA yaklaşımına ait doğruluk, özgüllük ve duyarlılık değerlerinin 1 olduğu görülmektedir. YSA, DVM ve k-NN'in doğruluk değerleri 0.97 ile 0.99 arasında değişmektedir. Arıza türünün sınıflandırılması amacıyla kurulan ANFIS yaklaşımına ait doğruluk değeri ise 0.76'dır. En düşük doğruluk, özgüllük ve duyarlılık değerleri ise TS-KSA modelleri için gerçekleşir.

Tablo 3.9. İkili sınıflandırma yaklaşımlarının performans değerlerinin karşılaştırılması

Sınıflandırıcı	Doğruluk	Duyarlılık		Özgüllük	
		S	A	S	A
YSA	0.98	0.96	0.99	0.99	0.96
DVM	0.98	1	0.98	0.98	1
K-NN	0.98	0.98	0.99	0.99	0.98
ANFIS	0.85	-	-	-	-

Tablo 3.10. Çoklu sınıflandırma yaklaşımlarının performans değerlerinin karşılaştırılması

Sınıflandırıcı	Doğruluk			
YSA	0.98			
SVM	0.99			
K-NN	0.97			
ANFIS	0.76			
IRT-KSA	1			
T-KSA	0.83			
S-KSA	0.81			
TS-KSA	0.65			
	Duyarlılık			
	S	A1	A2	A3
YSA	0.94	0.99	0.99	0.98
SVM	1	0.99	0.90	0.93
K-NN	0.97	0.99	0.96	0.98
ANFIS	-	-	-	-
IRT-KSA	1	1	1	1
T-KSA	1	0.67	0.78	1
S-KSA	0.66	0.80	1	0.87
TS-KSA	0.65	0.51	0.60	0.88
	Özgüllük			
	S	A1	A2	A3
YSA	0.99	0.97	0.97	0.97
SVM	0.94	1	1	1
K-NN	0.99	1	0.99	1
ANFIS	-	-	-	-
IRT-KSA	1	1	1	1
T-KSA	0.80	0.90	0.85	0.77
S-KSA	0.90	0.81	0.75	0.79
TS-KSA	0.64	0.72	0.66	0.58

4. İRDELEME

4.1. Deney Düzenine Ait İrdeleme

Bu çalışmada endüstride sıklıkla kullanılan bir redüktör tipi olan SVR'lerin kestirimci ve önleyici bakımının en temel bileşeni olan durum izleme çalışmalarına yönelik bir deney düzeni geliştirilmiş ve bu deney düzeninden ses, titreşim ve termal görüntü verileri toplanarak YZ ile arıza tespiti ve sınıflandırılması yapılmıştır. Deney düzeni esasen elektrik kumanda panosu, asenkron motora bağlı bir SVR ve yükleme cihazından oluşmaktadır (Şekil 2.1). Deney düzeni farklı çıkış hızlarında ve farklı yükleme oranlarında çalıştırılabilmektedir. Endüstriyel bir SVR gerçek çalışma ortamında farklı hızlarda çalıştırılabilir ve farklı büyüklükteki yüklere maruz kalabilir. Bu nedenle sabit hız ve yük altında çalışan bir SVR'nin incelenmesi yalnızca sınırlı bir çalışma aralığının anlaşılmasına olanak tanır.

Literatürdeki SVR ile ilgili yapılmış çalışmalara bakıldığında, ölçümlerin ya sabit hızda ve/veya yükte veya herhangi bir yük olmadan yapıldığı görülmektedir [198, 199, 201-204]. Literatürden farklı olarak geliştirilen deney düzeni ile gerçek çalışma koşulları daha iyi taklit edilebilmektedir (Şekil 2.8). Deney düzeninin çıkış hızı kademesiz olarak istenilen hıza ayarlanabilmektedir. Bunun yanında deneylerde kullanılan SVR'ler, çoklu çıkışa sahip bir transformatör kullanılarak geliştirilen yük kumanda sistemi aracılığıyla 5 farklı yük oranı ile yüklenebilmektedir. Bu şekilde dinamik çalışma koşulları en iyi şekilde taklit edilmektedir.

Literatürdeki çalışmaların çoğu ile ilgili bir diğer husus da tek bir arıza çeşidinin dikkate alınması ve deneylerin bu doğrultuda yapılmasıdır. Oysa SVR'lerde adhezif ve abrazif aşınma, diş kırılması, yüzey yorgunluğu vb. farklı arıza türleri gözlemlenebilir. SVR'nin kullanıldığı tesis ya da makede iş akışının olumsuz etkilenmemesi için arızanın gerçek nedenini bulmak ve ortadan kaldırmak önem arz eder. Bu nedenle arızanın türü tespit edilmelidir. Örneğin yüzey yorgunluğuna maruz kalmış bir SVR için yanlış yağlama rejimi söz konusu olabilir. Böyle bir durumda ya farklı yağ seçilir ya da yağlama şartları iyileştirilir. Bir diğer örnek redüktör dişlisinin kırılması durumudur. Redüktörün bağlandığı makine ya da tesisat dolayısıyla maruz kaldığı mekanik yükün dinamik veya statik oluşu, yönü, büyüklüğü gibi faktörler bu arızaya neden olmuş olabilir. Sonuç olarak SVR'lerde

arıza türünün tespiti, makinedeki esas problemin bulunması ve giderilmesi açısından önemlidir. Bu nedenle yapılan çalışmalarda arıza tespiti ve arıza türünün sınıflandırılmasına yönelik iki ayrı yaklaşım geliştirilmiş, ölçümler ve analizler bu doğrultuda yapılmıştır. Arıza tespiti yaklaşımında arızanın varlığı ya da yokluğu araştırılmıştır. Bu yaklaşımda problemin hedef parametresi sağlam (S) ve arızalı (A) şeklindeki iki sınıftan biri ile temsil edilmiştir. İkinci yaklaşımda ise arızanın sınıflandırılması yapılmıştır. Bu yaklaşımda problemin hedef parametresi sağlam (S), aşınma (A1), yüzey yorgunluğu (A2) ve diş kırılması (A3) şeklindeki dört sınıftan biri ile temsil edilmiştir (Şekil 2.27). Arıza tespiti ve sınıflandırması için kurulan YZ yaklaşımlarına ait giriş parametreleri de bu redüktörlerden farklı çalışma koşulları altında toplanmış titreşim, ses ve termal görüntü verilerinden çıkarılan özneliliklerdir (Tablo 2.8, Tablo 2.9).

4.2. Sinyal İşleme Prosedürü ve Matematiksel Modele Ait İrdeleme

SVR ile ilgili yapılan çalışmalarda sağlam ve farklı arızalara sahip SVR numuneleri üzerinden farklı çalışma koşullarında ivmeölçer ile titreşim verileri, mikrofon ile ses verileri ve kızılötesi kamera ile termal görüntüler toplanmıştır.

Titreşim ve ses sinyalleri hem zaman hem de frekans bölgesinde analiz edilmiştir. Redüktörlerin ürettiği sinyaller random yapıda olduğundan her iki bölgede de istatistiksel teknikler kullanılmıştır. Bu doğrultuda zaman bölgesi için *RMS*, *SS*, *VAR*, *ÇK* ve *BK* değerleri hesaplanmıştır. Literatürdeki birçok çalışmada frekans bölgesi analizi yapılırken kavrama (ağ) frekansının ve bu frekansın harmonik bileşenlerinin kullanıldığı görülmektedir. Oysa SVR için kavrama frekansı ve bu frekansın harmonik bileşenleri diğer dişli çark mekanizması tiplerine kıyasla istikrarlı değildir ve daha zor gözlemlenir. Çünkü sonsuz vida ve eşleştiği bronz dişli çark birbiri üzerinden kayarak ve birbirine sürtünerek hareket etmektedir [199, 203, 204]. Bu nedenle titreşim ve ses sinyallerine *FFT* dönüşümü uygulandıktan sonra *GSY* dağılımları hesaplanmış ve frekans bölgesi için *FM*, *RMSF* ve *VKF* istatistiksel değerleri elde edilmiştir.

SVR'ler çalışma esnasında özellikle arıza durumunda yapıları gereği diğer tipteki redüktörlerden daha çok ısınabilirler. Bu nedenle yapılan çalışmalarda, sağlam ve arızalı redüktörlerin her birinden farklı yükler ve farklı devir sayıları altında termal görüntüler de toplanmıştır. Toplanan görüntülerden sıcaklığın en çok değiştiği alanlar dikkate alınarak

maksimum ($T_{mak.}$), minimum ($T_{min.}$) ve ortalama ($T_{ort.}$) sıcaklıklar elde edilmiştir. Bu sıcaklık değerleri titreşim ve ses sinyallerinden elde edilen diğer öznitelikler ile beraber arıza tespiti ve sınıflandırması amacıyla geliştirilen YZ yaklaşımlarının eğitilmesinde kullanılan veri setine eklenmiştir. Literatüre bakıldığında $T_{mak.}$, $T_{min.}$, ve $T_{ort.}$ sıcaklık dağılımlarının MDİ çalışmalarında öznitelik olarak kullanıldığı herhangi bir çalışma tespit edilememiştir [155, 202].

Yapılan çalışmalarda deney sisteminde kullanılan SVR'nin fizik yasalarına dayalı matematiksel modeli çıkarılmıştır. Newton'un ikinci yasasına dayalı olarak türetilen model hem matris formunda hem de durum uzay formunda verilmiştir (Denklem 2.25, 2.27, 2.28, 2.29). Modelin çıkarılışı esnasında yapılan ön kabuller ve literatürdeki çalışmalar dikkate alındığında, matematiksel model için titreşim ölçümlerine dayalı sistem tanılama yolunun tercih edilmesinin daha uygun olabileceği ancak bu modelin bu tezin kapsamını aştığı görülmüştür [237, 238].

4.3. Bulgulara Ait İrdeleme

4.3.1. Titreşim Analizi Sonuçlarına Ait İrdeleme

Yapılan çalışmalarda sağlam ve farklı arızalara sahip SVR numuneleri üzerinden farklı çalışma koşulları altında ivmeölçer ile titreşim verileri toplanmıştır. Söz konusu verilerin hem zaman hem de frekans bölgesinde analizi yapılmış ve her bir çalışma koşulu için öznitelikler hesaplanarak grafiklerle gösterilmiştir. Sonuç olarak hem sağlam hem de arızalı redüktörlere ait titreşim sinyali genliklerinin YO ve RÇH artışıyla beraber arttığı gözlemlenmiştir. Bununla beraber yük ve hız artışı ile sağlam ve arızalı redüktörlerin ürettikleri sinyallerin genlikleri arasındaki fark gittikçe azalmıştır. Sırasıyla A1, A2 ve A3 redüktörleri, tüm yük ve hız koşulları altında, S redüktörüne kıyasla daha yüksek genlikli bir titreşim davranışı sergilemiştir. Ayrıca tüm çalışma koşulları için A1 redüktöründen elde edilen sinyal genliklerinin A2 redüktöründen daha yüksek olduğu gözlemlenmiştir. A2 redüktöründen elde edilen sinyal genlikleri ise genel olarak A3 redüktöründen daha yüksek çıkmıştır.

S, A1, A2 ve A3 redüktörlerden toplanan titreşim sinyallerinin zaman bölgesine ait istatistiksel özellikleri diğer bir değişle zaman bölgesindeki öznitelikler farklı çalışma koşullarından ve arızanın türünden etkilendiği ortaya çıkmıştır. RÇH ve YO artışı ya da

arızanın varlığı ile beraber *RMS*, *SS* ve *VAR* değerleri artmıştır (Şekil 3.4, Şekil 3.5, Şekil 3.6). Buna rağmen arızanın varlığı veya yük ve hız artışı genel olarak *ÇK* ve *BK* değerlerini azaltmıştır (Şekil 3.7, Şekil 3.8). Hız ve yükleme oranlarının artışı ile birlikte farklı redüktörlere ait *RMS*, *SS*, *VAR*, *ÇK* ve *BK* değerleri arasındaki fark gittikçe azalmıştır. Bu nedenle *RMS*, *SS*, *VAR*, *ÇK* ve *BK* değerlerinin özellikle düşük *YO* ve *RÇH* durumları için ayırt ediciliği yüksek, yüksek *YO* ve *RÇH* durumları için ayırt ediciliği düşüktür.

Sağlam ve arızalı redüktörlerin titreşim sinyallerine ait frekans bölgesi grafikleri incelendiğinde *GSY* değerlerinin genel olarak *YO* ve *RÇH* artışıyla beraber arttığı görülebilir. Bununla beraber özellikle *RÇH=70 d/dk*'da sağlam ve arızalı redüktörlerin ürettikleri *GSY* değerleri arasındaki fark azalmıştır (Şekil 3.11). Bunun yanında A1, A2 ve A3 redüktörlerinin, *RÇH=70 d/dk* ve *YO=%0* durumu haricindeki tüm yük ve hız koşulları altında, S redüktörüne kıyasla daha yüksek *GSY* değerlerine sahip olduğu ortaya çıkmıştır. Ayrıca A1 redüktöründen elde edilen *GSY* değerlerinin A2 redüktöründen, A2 redüktöründen elde edilen *GSY* değerlerinin ise A3 redüktöründen genellikle daha yüksek olduğu görülmüştür. A3 redüktörüne ait yüksek *GSY* değerleri özellikle 0-100 Hz frekans aralığındadır. A3 redüktöründeki diş kırılması arızası bu frekans aralığında kendini belli etmektedir. Bunun yanında frekans bölgesindeki özniteliklerin de farklı çalışma koşullarından ve arızanın türünden etkilendiği görülmüştür. *FM* ve *RMSF* değerleri, *RÇH* ve *YO* artışı ile beraber S, A2 ve A3 redüktörleri için genel olarak artmış, A1 redüktörü içinse biraz azalmıştır (Şekil 3.12, Şekil 3.13). *VKF* değeri ise genel olarak arızanın varlığı veya yük ve hız artışı ile beraber S ve A2 redüktörleri için artmış buna rağmen A1 ve A3 redüktörleri için bir miktar azalmıştır (Şekil 3.14). Hız ve yükleme oranlarının artışı ile birlikte farklı redüktörlere ait *FM*, *RMSF* ve *VKF* değerleri arasındaki farkın gittikçe azaldığı gözlemlenmiştir. *RÇH=30 d/dk*'da sağlam ve arızalı redüktörlerin ürettiği sinyallere ait öznitelik değerlerinin farkları belirginken *RÇH=70 d/dk*'da bu değerlerin birbirine daha yakın olduğu gözlemlenmiştir. Bu nedenle özellikle düşük *RÇH* değerleri için bu özniteliklerin ayırt ediciliği yüksek, yüksek *RÇH* değerleri için düşüktür.

Literatüre bakıldığında belirli arıza türlerinin ürettiği titreşim sinyallerinin ve bu titreşim sinyallerinden çıkarılan özniteliklerin yük veya hız ile anlamlı bir korelasyon oluşturacak şekilde arttığı ya da azaldığını gösteren çalışmalar vardır [198-200, 202-204, 225, 227-229]. Ancak dinamik çalışma koşullarının dikkate alındığı, birbirinden farklı arızalara sahip 3 redüktör ve 1 sağlam redüktörden elde edilen titreşim sinyallerinin hem

zaman hem de frekans bölgesinde analizinin yapılıp karşılaştırıldığı sistematik bir çalışmaya rastlanmamıştır. Yapılan çalışmalarda RÇH artışı ile birlikte titreşim ölçümlerinden elde edilen özneliklerin ayırt ediciliklerinin düştüğü gözlemlenmiştir.

4.3.2. Ses Analizi Sonuçlarına Ait İrdeleme

Deneysel çalışmalarda S, A1, A2 ve A3 redüktörlerinden farklı çalışma koşulları altında mikrofon ile ses sinyalleri toplanmıştır. Toplanan sinyallerin hem zaman hem de frekans bölgesinde analizi yapılmış ve her bir çalışma koşulu için öznelikler hesaplanarak grafiklerle gösterilmiştir. Sonuç olarak hem sağlam hem de arızalı redüktörlere ait ses basıncı düzeylerinin YO ve RÇH artışıyla beraber arttığı gözlemlenmiştir. Bunun yanında A3 redüktörünün en yüksek, S redüktörünün ise en düşük ses basıncı değerlerini ürettiği gözlemlenmiştir. A2 redüktörü de A1 redüktöründen daha büyük ses basıncı değerleri üretmiştir.

S, A1, A2 ve A3 redüktörlerinden toplanan ses sinyallerinin zaman bölgesine ait istatistiksel özellikleri yani zaman bölgesindeki öznelikler farklı çalışma koşullarından ve arızanın türünden etkilenmiştir. RÇH ve YO artışı ile beraber *RMS*, *SS*, *VAR*, *CK* ve *BK* değerleri de değişmiştir (Şekil 3.18, Şekil 3.19, Şekil 3.20, Şekil 3.21, Şekil 3.22). Yapılan incelemelerde *RMS* değerlerinin ayırt ediciliğinin yüksek, *SS*, *VAR*, *CK* ve *BK* değerlerinin ise tek başına kullanıldıklarında düşük olduğu gözlemlenmiştir.

Redüktörlerin ürettiği ses sinyallerinin frekans bölgesinde incelenmesi için öncelikle *FFT* dönüşümü yapılmış ve *GSY* fonksiyonları hesaplanmıştır. Arızalı ve sağlam redüktörlere ait *GSY* değerlerinin genel olarak YO ve RÇH artışıyla beraber arttığı grafiklerle gösterilmiştir. Bununla beraber özellikle RÇH değerinin artışı ile sağlam ve arızalı redüktörlerin düşük frekanslarda ürettiği *GSY* değerleri artmıştır. Düşük frekans değerleri söz konusu olduğunda genel olarak A3 redüktörüne ait *GSY* değerleri A2 redüktöründen, A2 redüktörüne ait *GSY* değerleri ise A1 redüktöründen daha büyüktür. S redüktörü ise bu frekans aralığında en küçük *GSY* değerlerini üretmiştir. Ses sinyallerinin frekans bölgesine ait istatistiksel özellikleri olan *FM*, *VKF* ve *RMSF* değerleri RÇH ve YO artışı ile beraber artmıştır. Sonuç olarak S, A1, A2 ve A3 redüktörleri için hız ve yüklenme oranlarının değişimi farklı *FM*, *RMSF* ve *VKF* değerlerinin üretilmesine neden olmuştur. Dikkati çeken bir diğer husus da *VKF* ve *RMSF* değerlerinin birbirine çok yakın çıkmasıdır. Bunun nedeni *FM* değerlerinin küçüldükçe *VKF* ve *RMSF* değerleri birbirine

yaklaşmasıdır (Şekil 3.26, Şekil 3.27, Şekil 3.28). *FM*, *RMS* ve *VKF* değerleri S, A1, A2 ve A3 redüktörleri için farklı dağılım gösterdiğinden ayırt edici özelliği yüksektir.

Literatürdeki çalışmalara bakıldığında belirli arıza türlerinin ya da aynı arızanın farklı şiddetteki varyasyonlarının ürettiği akustik sinyallerinin ve bu sinyallerinden çıkarılan özniteliklerin yük veya hız ile anlamlı bir korelasyon oluşturacak şekilde değiştiği görülebilir [70, 72, 106, 172, 174, 202]. Bu çalışmada ise ses sinyalinin zaman ve frekans bölgesindeki istatistiksel analizlerine dayalı olarak farklı yük ve hız koşulları altında çalışan birbirinden farklı 4 SVR'nin sınıflandırılması için ilgili öznitelikler çıkarılmış ve arızanın türüne ve çalışma koşuluna göre nasıl değiştiği ortaya koyulmuştur.

4.3.3. Termal Görüntü Analizi Sonuçları Ait İrdeleme

Farklı arızalara sahip SVR numuneleri üzerinden farklı çalışma koşulları altında termal kamera ile toplanan görüntülerin sıcaklık dağılımları incelenmiş ve her bir durum için öznitelik olacak şekilde maksimum, minimum ve ortalama sıcaklık değerleri hesaplanarak grafiklerle gösterilmiştir (Şekil 3.32, Şekil 3.33, Şekil 3.34).

Buna göre hem sağlam hem de arızalı redüktörlere ait sıcaklık değerleri yani $T_{min.}(^{\circ}C)$, $T_{mak.}(^{\circ}C)$ ve $T_{ort.}(^{\circ}C)$ YO ve RÇH artışıyla beraber belirgin şekilde artmıştır. Bunun yanında yük ve hız artışı ile beraber bu sıcaklık dağılımları arasındaki fark da gittikçe açılmıştır. Bu fark RÇH=70 d/dk ve YO=%100 durumunda en yüksek seviyesine ulaşmıştır. En yüksek sıcaklıklar sırasıyla A1, A2 ve A3 redüktörlerinde gözlemlenmiştir. Tüm yük ve hız koşullarında S redüktörü diğer redüktörlerden daha az ısınmıştır. $T_{min.}(^{\circ}C)$, $T_{mak.}(^{\circ}C)$ ve $T_{ort.}(^{\circ}C)$ değerleri öznitelikler olarak farklı çalışma koşullarından ve arızanın türünden etkilenmekle beraber, ayırt edici özelliklerinin üstün olduğu görülmüştür.

Literatürde SVR dışındaki redüktör tiplerinin ve rulmanlı yatakların termal kamera ile görüntülenmesi ile ilgili bazı çalışmalar yapılmıştır [189, 192]; ancak bu çalışmalarda $T_{min.}(^{\circ}C)$, $T_{mak.}(^{\circ}C)$ ve $T_{ort.}(^{\circ}C)$ değerleri öznitelik olarak kullanılmamıştır. SVR'lerin termal kamera ile görüntülenmesine dair yapılan bir başka çalışmada ise termal görüntülerden hangi özniteliklerin çıkarıldığı ve bu özniteliklerin YZ eğitim veri setinde nasıl kullanıldığına dair bir bilgi verilmemiştir [202].

4.3.4. Yapay Zekâ ile Arıza Tespiti ve Arızaların Sınıflandırılmasına Ait İrdeleme

Deneysel çalışmalarda S, A1, A2 ve A3 redüktörleri üzerinden farklı çalışma koşulları altında toplanan titreşim, ses ve termal görüntü verilerinden çıkarılan öznitelikler yapay zekâ (YZ) ile arızaların tespit edilmesi ve sınıflandırılmasında kullanılmıştır. Bu amaçla kurulan YZ yaklaşımlarında kullanılan veri seti içerisinde toplam 19 adet öznitelik sütunu bulunmaktadır. Bu öznitelik sütunlarından 8 tanesi titreşim ölçümlerinden, 8 tanesi ses ölçümlerinden ve 3 tanesi de termal kamera görüntülerinden elde edilmiştir. Her bir öznitelik sütunu 450 satırlık veriden oluşmaktadır. Buna göre sağlam ve arızalı redüktörlerinden her biri 450 satıra ve 19 sütuna sahip bir matris ile temsil edilmiştir. Bu çalışmada YSA, DVM, k-NN, ANFIS ve derin öğrenme olmak üzere 5 ayrı algoritma kullanılarak arıza tespiti ve sınıflandırması ile ilgili YZ yaklaşımları kurulmuştur.

4.3.4.1. Yapay Sinir Ağı Yaklaşımlarına Ait İrdeleme

YSA ile arıza tespiti ve sınıflandırması, özünde bir örüntü tanıma problemi olduğu için girişler yani öznitelik değerleri hedef kategorilerine göre sınıflandırılmıştır. Buradaki hedef kategorileri sağlam (S) ya da arızalı (A1, A2, A3) redüktörlerdir. Hem YSA hem de diğer YZ türleri ile arıza tespiti amacıyla kurulan yaklaşımlarda ikili sınıflandırma, arıza türünün belirlenmesi amacıyla kurulan yaklaşımlarda ise dörtlü sınıflandırma yapılmıştır.

SVR'lerde YSA ile arıza tespiti ve sınıflandırılması yapılırken 1 gizli katmana ve 1 çıkış katmanına sahip ileri beslemeli mimariler kullanılmıştır. Yapılan değerlendirmelerden sonra gizli katmanlardaki yapay sinir hücrelerinin sayısı 10'ar adet olarak belirlenmiştir. YSA ile arıza tespiti amacıyla kurulan mimaride 2 adet (S ve A), arıza türünün sınıflandırılması amacıyla kurulan mimaride ise 4 adet (S, A1, A2, A3) çıkış vardır (Şekil 2.29, Şekil 2.30). Ayrıca her iki yaklaşım türü için kullanılan veri setinin %70'inin eğitim, %15'inin doğrulama ve %15'inin test için kullanılmasının uygun olduğu tespit edilmiştir.

YSA ile SVR'lerde arıza tespiti amacıyla sadece titreşim verilerine dayalı olarak kurulan yaklaşımın genel sonuçlarına bakıldığında S ve A redüktörlerine ait verilerin %82.2 oranında doğru sınıflandırıldığı görülmektedir. Ses verilerine dayalı olarak kurulan yaklaşımda ise bu oran %87.3'tür. Termal görüntü verilerinin kullanıldığı YSA yaklaşımı %83.2 oranında doğru sınıflandırma yapmıştır. Titreşim ve ses verilerinin birlikte

kullanıldığı yaklaşımda doğru sınıflandırma oranı %91.2 olarak görülmektedir. Ses ve termal görüntü verilerine dayalı YSA yaklaşımına ait doğru sınıflandırma oranı %94.8 iken titreşim ve termal görüntü verilerine dayalı yaklaşım %93.8 oranında doğru sınıflandırma yapmıştır (Şekil 3.41).

YSA ile SVR'lerde arıza türünün sınıflandırılması amacıyla kurulan yaklaşımlara bakıldığında titreşim verilerine dayalı olarak kurulan yaklaşımın S, A1, A2 ve A3 redüktörlerine ait verileri %62.0 oranında doğru sınıflandırdığı görülebilir. Ses verilerine dayalı olarak kurulan yaklaşımda ise bu oran %68.3'tür. Termal görüntü verilerinin kullanıldığı YSA yaklaşımı %71.9 oranında doğru sınıflandırma yapmıştır. Titreşim ve ses verilerinin birlikte kullanıldığı yaklaşımda doğru sınıflandırma oranı %86.9 olarak görülmektedir. Ses ve termal görüntü verilerine dayalı YSA yaklaşımına ait doğru sınıflandırma oranı %95.8 iken titreşim ve termal görüntü verilerine dayalı yaklaşım %92.0 oranında doğru sınıflandırma yapmıştır. Bu oranlar genel başarı oranlarıdır (Şekil 3.49).

Verilerin tek tek ve ikili guruplar halinde kullanıldığı yaklaşımlara ait hata matrisleri ve ROC eğrilerinden çıkan bir diğer sonuç da titreşim, ses ve termal görüntü verilerinin farklı arıza türlerinin tespit edilmesinde birbirinden farklı oranda etkili olduğudur. Şöyle ki, sadece titreşim veya ses verilerinin kullanıldığı ya da titreşim ve ses verilerinin birleştirilerek kullanıldığı YSA yaklaşımının A3 redüktörünü yani diş kırılması arızasına sahip redüktörü sınıflandırmadaki başarısı diğer redüktörleri sınıflandırmadaki başarısından daha yüksektir. Sadece termal görüntü verilerinin kullanıldığı YSA yaklaşımı ise A1 redüktörünü yani aşınma arızasına sahip redüktörü diğer redüktörlerden daha iyi tahmin etmiştir. Ses ve termal görüntü verilerinin beraber kullanıldığı YSA yaklaşımına bakıldığında A2 redüktörünün yani yüzey yorgunluğuna sahip redüktörün diğer redüktörlerden daha başarılı bir şekilde tahmin edildiği görülmektedir. Titreşim ve termal görüntü verilerine dayalı YSA yaklaşımı ise A1 redüktörünü en başarılı şekilde sınıflandırmıştır. Titreşim, ses ve termal görüntü verilerinin tümünün birlikte kullanıldığı YSA yaklaşımında da A1 redüktörünün diğer redüktörlerden daha iyi sınıflandırıldığı görülmektedir; ancak bu yaklaşımda tüm redüktörlerin sınıflandırılma başarısı birbirine yakın ve yüksektir (Şekil 3.46, Şekil 3.49).

Sağlam ve arızalı redüktörler için arıza tespiti ve arıza türünün sınıflandırılması çalışmalarında kurulan en başarılı yaklaşımların titreşim, ses ve termal görüntü verilerinin tümünün birlikte kullanıldığı YSA yaklaşımları olduğu performans grafikleri, hata matrisleri ve ROC eğrileri ile karşılaştırmalı olarak gösterilmiştir. Hem arıza tespiti hem de

arıza türünün sınıflandırılmasında kurulan YSA yaklaşımlarının %98 oranında doğru sınıflandırma yaptığı tespit edilmiştir (Şekil 3.38, Şekil 3.46). Verilerin ayrı ayrı ya da ikili guruplar halinde kullanılmasının yaklaşım başarısını düşürdüğü gözlemlenmiştir. Bunun yanında eğer veriler ayrı ayrı ya da ikili kullanılırsa belirli tür arızalar diğerlerinden daha başarılı tahmin edilmektedir (Şekil 3.46, Şekil 3.48, Şekil 3.49, Şekil 3.50). Ancak tüm verilerin kullanıldığı yaklaşımda redüktörlerin tümünün doğru sınıflandırılma oranı birbirine yakın ve yüksektir. Benzer sonuçlar DVM, k-NN, ANFIS ve derin öğrenme ile kurulan yaklaşımlar için de geçerlidir.

Literatürde YSA'nın redüktörlerde arıza tespiti ve sınıflandırılması amacıyla kullanıldığı birçok çalışma vardır [62, 65, 67, 69, 70, 202-204]. Bu çalışmalara bakıldığında titreşim, ses ve termal görüntü ölçümlerinden çıkarılan özniteliklerin beraber kullanıldığı, dinamik çalışma şartlarının hesaba katıldığı ve birbirinden farklı türde arızaların aynı anda sınıflandırılmaya çalışıldığı, karşılaştırmalı ve sistematik bir çalışmaya rastlanmamıştır. Buna ek olarak YSA ile ilgili yapılan çoğu çalışmada sadece bir ya da birkaç öznitelik veri seti oluşturulmasında kullanıldığı görülmektedir. Bu çalışmada ise 19 öznitelik kullanılarak veri seti oluşturulmuştur. Tekrarlı ölçümler sayesinde YSA yaklaşımlarının arıza tespit ve sınıflandırma performansı yüksek çıkmıştır.

4.3.4.2. Destek Vektör Makinesi Yaklaşımlarına Ait İrdeleme

S, A1, A2 ve A3 redüktörlerinde arıza tespiti ve sınıflandırılması amacıyla DVM ile yapılan çalışmalarda girişler yani öznitelik değerleri YSA'ya benzer şekilde hedef kategorilerine ayrılmıştır. Arıza tespitine ait yaklaşımda 2 adet, arıza türünün sınıflandırılmasına ait yaklaşımda ise 4 adet çıkış sınıfı vardır. Her iki yaklaşım için farklı oranlar kullanılarak yapılan değerlendirmeler sonucunda veri setinin %75'lik kısmının eğitim, kalan %25'lik kısmının da doğrulama ve test için kullanılmasının uygun olduğu tespit edilmiştir.

DVM ile yapılan çalışmalarda farklı çekirdek (karnel) fonksiyonları arasından en yüksek doğruluk oranını veren kübik çekirdek (karnel) fonksiyonu seçilmiştir (Tablo 2.9). Titreşim, ses ve termal görüntü verilerinin tümünün kullanıldığı arıza tespiti yaklaşımda A redüktörüne ait verilerin %98'i doğru, %2'si yanlış sınıflandırılmıştır. S redüktörüne ait verilerin ise %100'ü doğru sınıflandırılmıştır (Şekil 3.52). Bu yaklaşıma ait genel doğruluk oranı ise %98'dir. Arıza türünün sınıflandırıldığı yaklaşımda ise A1

redüktörlerine ait verilerin %99'u doğru, %1'i yanlış; A2 redüktörlerine ait verilerin %90'ı doğru, %10'u yanlış; A3 redüktörlerine ait verilerin %93'ü doğru, %7'si yanlış; S redüktörlerine ait verilerin %100'ü doğru sınıflandırılmıştır (Şekil 3.56). Bu yaklaşıma ait genel doğruluk oranı ise yaklaşık %99'dur. Yaklaşımın A1 redüktörünü yani aşınma arızasına sahip redüktörü doğru sınıflandırma oranı diğer arızaları sınıflandırma oranından daha yüksektir.

Literatüre bakıldığında YSA kadar olmasa da DVM'nin MDİ çalışmalarında kullanıldığı görülmektedir [84, 85, 123, 135]. Dişli çarklarda DVM kullanılarak yapılan bir başka çalışmada sadece titreşim verilerinin kullanıldığı ve farklı yükleme koşullarının dikkate alınmadığı görülmektedir [87].

4.3.4.3. K En Yakın Komşu Yaklaşımlarına Ait İrdeleme

k-NN ile sağlam ve arızalı redüktörlerin kestirimi yapılırken DVM yaklaşımlarına benzer şekilde öznitelik değerleri hedef kategorilerine göre sınıflandırılmıştır. Arıza tespitine ait k-NN yaklaşımında 2 adet, arıza türünün sınıflandırılmasına ait k-NN yaklaşımında ise 4 adet çıkış sınıfı vardır. Her iki yaklaşım için farklı oranlar kullanılarak yapılan değerlendirmeler sonucunda veri setinin %75'lik kısmının eğitim, kalan %25'lik kısmının da doğrulama ve test için kullanılmasının uygun olduğu tespit edilmiştir. K-NN ile yapılan sınıflandırma işlemlerinde örnek sayısı, yakınlık metriği vb. özellikler doğru sınıflandırma oranını etkilemektedir. Buna göre farklı k-NN türleri ile yapılan sınıflandırma sonucu elde edilen başarı oranlarına göre arıza tespiti için ince k-NN, arıza türünün sınıflandırılması içinse ağırlıklandırılmış k-NN tercih edilmiştir (Tablo 2.10).

K-NN ile arıza tespiti işleminde A redüktörlerine ait verilerin %99'u doğru, %1'i yanlış sınıflandırılmıştır. S redüktörlerine ait verilerin %98'i doğru, %2'si yanlış sınıflandırılmıştır (Şekil 3.60). Yaklaşımın genel başarı oranı %98'dir. Arıza türünün sınıflandırılmasında ise A1 redüktörlerine ait verilerin %99'u doğru, %1'i yanlış; A2 redüktörlerine ait verilerin %96'sı doğru, %4'ü yanlış; A3 redüktörlerine ait verilerin %98'i doğru, %2'si yanlış; S redüktörlerine ait verilerin %97'si doğru, %3'ü yanlış sınıflandırılmıştır (Şekil 3.64). Burada k-NN yaklaşımının aşınma arızasına sahip A1 redüktörünü daha yüksek oranda tahmin ettiği görülmektedir. Arıza türünün sınıflandırılmasında kullanılan k-NN yaklaşımının genel başarı oranı ise %97 olarak görülmüştür.

MDİ çalışmalarında k-NN'in diğer sınıflandırıcılardan daha az kullanıldığı literatürdeki çalışmalardan görülmektedir [110]. Sadece titreşim verileri kullanılarak k-NN ile dişli çarklar üzerine yapılan çalışmalarda ya aynı arızanın farklı ciddiye seviyeleri sınıflandırılmış ya da dinamik çalışma koşullarının tümü dikkate alınmadan ölçüm yapılmıştır [107, 109]. DVM ya da k-NN ile ilgili olarak literatürde sadece SVR'lere odaklanan herhangi bir çalışma tespit edilememiştir.

4.3.4.4. ANFIS Yaklaşımlarına Ait İrdeleme

Arıza tespiti ve sınıflandırması ile ilgili yapılan çalışmalarda bir hibrit zeki sistem (HZS) olan ANFIS tekniği de kullanılmıştır. Diğer YZ tekniklerinden farklı olarak ANFIS tek çıkışa sahiptir. Çıkış parametresi olan f , sağlam veya arızalı redüktörleri temsil etmektedir. Hem arıza tespiti hem de arıza türünün sınıflandırılması amacıyla kurulan ANFIS yaklaşımları için farklı oranlar kullanılarak yapılan ön değerlendirmeler sonucunda veri setinin %70'lik kısmının eğitim, %15'lik kısmının test ve kalan %15'lik kısmının da kontrol için kullanılmasının uygun olduğu tespit edilmiştir.

ANFIS ile yapılan çalışmalarda kullanılan veri setinin yüksek boyutlu oluşu nedeniyle bulanık arayüz sistemi (FIS) oluşturmak için bir ön kümeleme işlemi yapılmıştır. Ön kümeleme işleminde giriş ve çıkış eğitim verileri eşlenerek küme sayısı ve küme merkezleri tahmin edilmiştir. Buna göre bulanık mantık kuralları, giriş üyelik fonksiyonu tipi ve sayısı ayrıca çıkış üyelik fonksiyonu tipi otomatik olarak belirlenmiştir (Tablo 2.11, Tablo 2.12, Tablo 2.13).

ANFIS ile arıza tespiti yaklaşımında eğitim veri seti için ortalama hata 0.039964, test veri seti için ortalama hata 0.14437, kontrol veri seti için ortalama hata 0,12353 olarak gerçekleşmiştir (Şekil 3.67). Arıza tespit yaklaşımı için eğitim başarı oranı %85 ve test başarı oranı %70 olarak gerçekleşmiştir. Arıza türünün sınıflandırılması yaklaşımında ise eğitim veri seti için ortalama hata 0.10117, test veri seti için ortalama hata 0.34878, kontrol veri seti için hata 0.32901 olarak gerçekleşmiştir (Şekil 3.68). Arıza türünün sınıflandırıldığı yaklaşım için eğitim başarı oranı %76 ve test başarı oranı %55 olarak gerçekleşmiştir. Titreşim, ses ve termal görüntü verilerinin beraber kullanılması ANFIS yaklaşımlarının başarısını arttırmaktadır. FIS eğitimine ait sonuçlara bakıldığında ANFIS yaklaşımının en başarılı sınıflandırdığı redüktörün A1 olduğu görülmektedir.

ANFIS literatürde yapılmış bazı MDİ çalışmalarında sınıflandırıcı olarak kullanılmıştır [141, 142, 145, 146, 148]. Bu çalışmaların tümünde sadece titreşim ölçümüne dayalı yaklaşımlar kullanılmıştır. Bunun yanında dinamik çalışma şartları da göz önünde bulundurulmamıştır.

4.3.4.5. Derin Öğrenme Yaklaşımlarına Ait İrdeleme

Derin öğrenme ile SVR'lerde arıza tespiti ve sınıflandırılması amacıyla farklı yük oranları ve farklı hızlar altında titreşim spektrogramları, ses spektrogramları ve termal kamera görüntüleri toplanmış ve bu verilere dayalı olarak dört farklı derin öğrenme yaklaşımı (IRT-KSA, T-KSA, S-KSA, TS-KSA) kurulmuştur. IRT-KSA yaklaşımı kurulurken termal kamera görüntüleri; T-KSA yaklaşımı kurulurken titreşim spektrogramları; S-KSA yaklaşımı kurulurken ses spektrogramları; TS-KSA yaklaşımı kurulurken de titreşim ve ses spektrogramları kullanılmıştır (Tablo 2.15). Derin öğrenme yaklaşımları için veri setinin %50'si eğitim, %25'i doğrulama ve %25'i de test amacıyla kullanılmıştır (Tablo 2.15). Derin öğrenme ile arıza tespiti yapılırken hiper parametreleri optimize edilmiş bir KSA olan GoogLeNet kullanılmıştır (Tablo 2.14).

IRT-KSA, T-KSA, S-KSA ve TS-KSA yaklaşımlarına ait eğitim sürecine bakıldığında, ulaşılan doğruluk oranlarının, termal görüntülere dayalı IRT-KSA yaklaşımı için %100; T-KSA yaklaşımı için %87.5; S-KSA yaklaşımı için %81.67; TS-KSA yaklaşımı içinse %73.33 olduğu görülebilir (Şekil 3.71). KSA yaklaşımları için eğitim sürecindeki kayıplar da hesaplanmıştır. Buna göre IRT-KSA yaklaşımına ait kayıp 30 iterasyon sonunda 0'a düşmüştür (Şekil 3.72).

Derin öğrenme yaklaşımlarının test sonuçlarına bakıldığında IRT-KSA yaklaşımının S, A1, A2 ve A3 redüktörleri için tüm test girişlerini doğru bir şekilde sınıflandırdığı görülebilir (Şekil 3.73). T-KSA yaklaşımına ait test sonuçlarına bakıldığında, bu oranının %83.3 olduğu ve S redüktörüne ait verilerin yarısının yanlış sınıflandırıldığı görülebilir. S-KSA yaklaşımı ise verilerin %81.7'sini doğru tahmin etmiştir. Bu yaklaşımın A1 redüktörünü sınıflandırmadaki başarısı düşüktür. Test başarı oranı en düşük yaklaşım TS-KSA'dır (%65). TS-KSA yaklaşımı özellikle A2 redüktörüne ait verileri yanlış sınıflandırmıştır.

KSA yaklaşımlarının yüksek miktarda görsel veriyle daha iyi performans sağladıkları genel olarak kabul edilmektedir. Ancak sınırlı sayıda veri söz konusu olduğu

durumlarda da yüksek başarı oranı elde etmek mümkündür [244]. Yüksek maliyet ya da fazla veri toplamanın uygun olmadığı riskli durumlarda YZ eğitim sürecini iyileştirmenin bazı yolları vardır. İnce ayar yapmak bunlardan birisidir. Bu çalışmada kullanılan GoogLeNet mimarisi modifiye edilmiş, eğitimle ilgili tüm parametreler probleme uygun olacak şekilde belirlenmiş ve eğitim süreci buna göre şekillendirilmiştir (Tablo 2.14, Tablo 3.7, Tablo 3.8). Az sayıda görsel veri ile başarı oranını arttırmanın bir diğer yolu da veri büyütme ya da çoğaltma işlemidir. Bu çalışmada kullanılan GoogLeNet mimarisi ile girişlerin etiket değerleri değiştirilmeden görsel veriler büyütülmüş ve yeni verilerin elde edilmesi sağlanmıştır. 160x120 boyutundaki ham giriş görüntüleri, veri büyütme ile 224x224x3 boyutuna yükseltilmiştir. Çözünürlük değerindeki artış yaklaşımlara ait sınıflandırma performansını da arttırmıştır. Bu sonuçlar literatür ile uygunluk göstermektedir [245, 246]. Farklı çözünürlükteki termal kamera görüntüleri kullanılarak eğitilen IRT-KSA yaklaşımına ait başarı oranları Şekil 3.74'te verilmiştir.

KSA yaklaşımlarının farklı sayıdaki görsel verilerle eğitilmesi ve test edilmesi sonucunda örnek sayısının artışı ile beraber eğitim, doğrulama ve test başarısının da arttığı görülmüştür (Tablo 3.8). Farklı veri sayıları ile eğitilen IRT-KSA yaklaşımlarına ait başarı oranlarının diğer yaklaşımların tümünden daha yüksek olduğu gözlemlenmiştir.

Derin öğrenme ile arıza tespiti ve sınıflandırması güncel bir konudur ve bu doğrultuda literatürde yapılmış bazı çalışmalar ön plana çıkmaktadır. Ancak bu çalışmalarda ya sadece titreşim verilerine ait zaman ve frekans bölgesi görselleri kullanılmış ya da dinamik çalışma koşulları dikkate alınmamıştır [150, 243]. Bu çalışmada literatürden farklı olarak termal görüntüler, titreşim ve ses verilerine ait spektrogramlar çıkarılmış ve bu verilere dayalı olarak kurulan 4 farklı derin öğrenme yaklaşımı karşılaştırmalı olarak incelenmiştir. Özellikle termal görüntüler farklı yük ve hız koşullarından toplandığı ve dinamik çalışma şartlarını en iyi şekilde temsil ettiği için IRT-KSA yaklaşımının başarısı yüksek çıkmıştır. Tablo 4.1'de Li ve arkadaşları [243] tarafından önerilen KSA yaklaşımları, Tablo 4.2'de ise bu çalışmada önerilen KSA yaklaşımları görülmektedir.

Tablo 4.1. Li ve arkadaşları [243] tarafından önerilen KSA yaklaşımları

KSA Yaklaşımları	Test Başarı Oranı (%)	Eğitim Zamanı (s)
IRT-KSA	100	470
T-KSA	71.53	542

Tablo 4.2. Bu çalışmada önerilen KSA yaklaşımlar

KSA Yaklaşımları	Test Başarı Oranı (%)	Eğitim Zamanı (s)
IRT-KSA	100	366
T-KSA	83.3	456
S-KSA	81.7	395
TS-KSA	65	423

4.3.4.6. YZ Yaklaşımlarının Karşılaştırılmasına Ait İrdeleme

YZ yaklaşımlarının arıza tespitinde ve arıza türünün sınıflandırılmasında gösterdiği performansların karşılaştırılması için doğruluk, duyarlılık ve özgüllük değerleri hesaplanarak tablolar halinde sunulmuştur (Tablo 3.9, Tablo 3.10).

Arıza tespiti için kurulan YSA, DVM ve k-NN yaklaşımlarının doğruluk değerleri aynı (0.98) olup duyarlılık ve özgüllük değerleri de birbirinden çok farklı değildir. Bununla beraber en yüksek performans değerleri DVM yaklaşımında görülmüştür. Arıza tespiti için kurulan ANFIS yaklaşımının doğruluk değeri 0.85 olup diğer yaklaşımlardan daha düşüktür. Bu çalışmada nispeten yüksek boyutlu bir veri seti kullanıldığı için bulanık ara yüz sistemi (FIS) oluşturulması gerekmektedir. Bu amaçla yapılan ön kümeleme işlemi yaklaşımın başarısını ve performans değerlerini düşürmüştür. Bu nedenle ANFIS algoritmasının daha çok küçük boyutlu veri setlerinin kullanıldığı sınıflandırma problemlerinde veya optimizasyon uygulamalarında kullanılmasının daha uygun olduğu görülmüştür. Benzer sonuçlar arıza türünün sınıflandırılması amacıyla kurulan ANFIS yaklaşımında da görülmüştür.

Arıza türünün sınıflandırılmasında kullanılan en başarılı yaklaşım IRT-KSA yaklaşımı olup bu yaklaşımın doğruluk, duyarlılık ve özgüllük değerleri 1'dir. Performans değerleri en düşük yaklaşım olan TS-KSA'da titreşim ve ses verilerine ait spektrogram görüntüleri beraber kullanılmıştır. Çıkan sonuçlara göre titreşim ve ses verilerine ait spektrogram görüntülerinin beraber kullanılmasının yaklaşım performansını düşürdüğü gözlemlenmiştir. Daha yüksek performans değerlerinin elde edildiği KSA yaklaşımlarında aynı tür veri grubuna ait görüntüler kullanılmıştır. Bunun yanında çoklu sınıflandırma amacıyla kullanılan YSA, DVM ve k-NN yaklaşımlarına ait performans değerleri titreşim veya ses verilerine ait spektrogram görüntülerinin kullanıldığı KSA modellerinden daha yüksektir. Titreşim ve ses verilerinden öznelik çıkarılarak kurulan yaklaşımlar spektrogram görüntülerinin kullanıldığı KSA yaklaşımlarından daha başarılıdır.

5. SONUÇLAR

Bu tez kapsamında yapılan çalışmalar ve bu çalışmalardan elde edilen sonuçlar aşağıdaki gibi sıralanabilir:

1. SVR'lerin kestirimci ve önleyici bakımına yönelik yeni bir deney düzeneği geliştirilmiştir. Deney düzeneği ile sağlam ve farklı arızalara sahip 4 redüktörden ses, titreşim ve termal görüntü verileri toplanarak YZ ile arıza tespiti ve sınıflandırılması yapılmıştır.
2. Deney düzeneği farklı yükler altında ve farklı hızlarda çalıştırılabilmektedir. Bu şekilde gerçek çalışma koşulları en iyi şekilde taklit edilebilmektedir.
3. Arıza tespiti ve arıza türünün sınıflandırılmasına yönelik iki ayrı yaklaşım geliştirilmiş, ölçümler ve analizler bu doğrultuda yapılmıştır. Arıza tespiti yaklaşımında arızanın varlığı ya da yokluğu araştırılmıştır. Bu yaklaşımda problemin hedef parametresi sağlam (S) ve arızalı (A) şeklindeki iki sınıftan biri ile temsil edilmiştir. İkinci yaklaşımda ise arızanın sınıflandırılması yapılmıştır. Bu yaklaşımda problemin hedef parametresi sağlam (S), aşınma (A1), yüzey yorgunluğu (A2) ve diş kırılması (A3) şeklindeki dört sınıftan biri ile temsil edilmiştir.
4. Farklı çalışma koşulları altında toplanan titreşim, ses ve termal görüntü verilerinden çıkarılan öznitelikler arıza tespiti ve sınıflandırması için kurulan YZ yaklaşımlarının eğitimi, doğrulaması ve testi için kullanılmıştır.
5. Toplanan titreşim ve ses sinyalleri hem zaman hem de frekans bölgesinde analiz edilmiştir. Bu doğrultuda zaman bölgesi için *RMS*, *SS*, *VAR*, *ÇK* ve *BK* değerleri hesaplanmıştır. Ayrıca frekans bölgesi analizi için *FFT* dönüşümü uygulandıktan sonra *GSY* dağılımları hesaplanmış ve bu dağılım üzerinden *FM*, *RMSF* ve *VKF* istatistiksel değerleri elde edilmiştir.
6. Sağlam ve arızalı redüktörlerin her birinden farklı yükler ve farklı devir sayıları altında termal görüntüler toplanmıştır. Toplanan görüntülerden sıcaklığın en çok değiştiği alanlar dikkate alınarak maksimum ($T_{mak.}$), minimum ($T_{min.}$) ve ortalama ($T_{ort.}$) sıcaklıklar elde edilmiştir.

7. Deney sisteminde kullanılan SVR'nin fizik yasalarına dayalı matematiksel modeli çıkarılmıştır. Newton'un ikinci yasasına dayalı olarak türetilen model hem matris formunda hem de durum uzay formunda verilmiştir.
8. Titreşim analizi sonuçlarına göre hem sağlam hem de arızalı redüktörlere ait sinyal genlikleri YO ve RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile sağlam ve arızalı redüktörlerin ürettikleri sinyallerin genlikleri arasındaki fark gittikçe azalmıştır. S redüktörüne ait ivme değerleri arızalı redüktörlerden elde edilen ivme değerlerinden daha küçük çıkmıştır. En büyük ivme değerlerini A1 redüktörü üretmiştir. RÇH ve YO artışı ya da arızanın varlığı ile beraber *RMS*, *SS* ve *VAR* değerleri artmıştır. Buna rağmen arızanın varlığı veya yük ve hız artışı genel olarak *ÇK* ve *BK* değerlerini azaltmıştır. Yük ve hız artışı frekans bölgesindeki *GSY* değerlerini de arttırmıştır. Frekans bölgesinde A1, A2 ve A3 redüktörlerine ait *GSY* değerleri S redüktörüne kıyasla daha yüksek çıkmıştır. Frekans bölgesindeki özniteliklerin de farklı çalışma koşullarından ve arızanın türünden etkilendiği görülmüştür. Hız ve yükleme oranlarının artışı ile birlikte farklı redüktörlere ait *RMS*, *SS*, *VAR*, *ÇK*, *BK*, *FM*, *RMSF* ve *VKF* değerleri arasındaki farkın gittikçe azaldığı gözlemlenmiştir.
9. Ses analizi sonuçlarına göre hem sağlam hem de arızalı redüktörlere ait sinyal genlikleri YO ve RÇH artışıyla beraber artmıştır. Bunun yanında A3 redüktörünün en yüksek, S redüktörünün ise en düşük ses basınç değerlerini ürettiği gözlemlenmiştir. RÇH ve YO artışı ile beraber S, A1, A2 ve A3 redüktörlerine ait *RMS*, *SS*, *VAR*, *CK* ve *BK* değerleri de değişmiştir. Frekans bölgesine ait *GSY* değerlerinin genel olarak YO ve RÇH artışıyla beraber arttığı gözlemlenmiştir. En küçük *GSY* değerlerini S redüktörü üretmiştir. S, A1, A2 ve A3 redüktörleri için hız ve yükleme oranlarının değişimi, farklı *FM*, *RMSF* ve *VKF* değerlerinin üretilmesine neden olmuştur.
10. Sağlam ve arızalı redüktörlere ait sıcaklık değerleri, yani $T_{min.}(^{\circ}C)$, $T_{mak.}(^{\circ}C)$ ve $T_{ort.}(^{\circ}C)$, YO ve RÇH artışıyla beraber belirgin şekilde artmıştır. Bunun yanında yük ve hız artışı ile beraber bu sıcaklık dağılımları arasındaki fark da gittikçe açılmıştır. En yüksek sıcaklıklar sırasıyla A1, A2 ve A3 redüktörlerinde gözlemlenmiştir. Tüm yük ve hız koşullarında S redüktörü diğer redüktörlerden daha az ısınmıştır.
11. Titreşim ve ses analizi sonuçlarına göre hem sağlam hem de arızalı redüktörlere ait sinyal genlikleri RÇH artışıyla beraber artmıştır. Bununla beraber yük ve hız artışı ile sağlam ve arızalı redüktörlerin ürettikleri sinyallerin genlikleri arasındaki fark gittikçe

azalmıştır. Dolayısıyla titreşim ve ses sinyallerinden çıkarılan özniteliklerin ayırt edicilikleri düşük RÇH oranlarında daha yüksektir. Sadece titreşim ve/veya ses sinyallerine dayalı bir arıza tespit sistemi kurulacaksa özellikle düşük RÇH oranlarında (30 d/dk - 50 d/dk) veri toplanmalıdır. Termal görüntü analizi sonuçlarına bakıldığında da sağlam ve arızalı redüktörlere ait sıcaklık değerlerinin RÇH artışıyla beraber arttığı görülmektedir. Ancak titreşim ve ses sinyallerinden farklı olarak sıcaklık dağılımları arasındaki fark RÇH değeri arttıkça artmaktadır. Yani termal görüntülerden çıkarılan özniteliklerin yüksek hız ve yük oranlarında ayırt edicilikleri daha yüksektir. Bu nedenle termal görüntüleme yönteminin kullanılacağı bir arıza tespit sistemi kurulacaksa, yüksek RÇH oranlarında (50 d/dk - 70 d/dk) ve tam yükte çalışırken veri toplanmalıdır. Titreşim, ses ve termal görüntü verilerinin beraber kullanılmasıyla kurulacak arıza tespit sisteminde ise öznitelik ayırt edicilikleri için en ideal çalışma aralığı olan 50 d/dk RÇH oranı seçilmelidir.

12. Hem arıza tespiti hem de arıza türünün sınıflandırılmasında kullanılan YSA yaklaşımlarının %98 oranında doğru sınıflandırma yaptığı tespit edilmiştir. Verilerin ayrı ayrı ya da ikili guruplar halinde kullanılmasının yaklaşımın genel başarısını düşürdüğü gözlemlenmiştir.
13. Titreşim, ses ve termal görüntü verilerinin ayrı ayrı ya da ikili kombinasyonda kullanıldığı YSA yaklaşımları ile belirli tür arızalar diğerlerinden daha başarılı tahmin edilmektedir. Bu durum diğer YZ türleri için de geçerlidir.
14. Sağlam ve arızalı redüktörler için yapılan YSA tabanlı arıza tespiti ve sınıflandırılması çalışmalarında kurulan en başarılı yaklaşımların titreşim, ses ve termal görüntü verilerinin tümünün birlikte kullanıldığı yaklaşımlar olduğu karşılaştırmalı olarak gösterilmiştir. Bu yaklaşımlar için redüktörlerin tümünün doğru sınıflandırılma oranı birbirine yakın ve yüksektir. Bu durum diğer YZ türleri için de geçerlidir.
15. DVM ile yapılan çalışmalarda arıza tespitine ait yaklaşımın genel başarı oranı %98, arıza türünün sınıflandırıldığı yaklaşımın genel başarı oranı ise %99'dur.
16. K-NN ile yapılan çalışmalarda arıza tespitine ait yaklaşımın genel başarı oranı %98, arıza türünün sınıflandırıldığı yaklaşımın genel başarı oranı ise %97'dir.
17. Diğer YZ tekniklerinden farklı olarak tek çıkışa sahip ANFIS ile arıza tespiti yaklaşımında eğitim veri seti için ortalama hata 0.039964, test veri seti için ortalama hata 0.14437, kontrol veri seti için ortalama hata 0.12353 olarak gerçekleşmiştir. Ayrıca eğitim başarı oranı %85 ve test başarı oranı %70 olarak çıkmıştır. Arıza türünün

sınıflandırılması yaklaşımında ise eğitim veri seti için ortalama hata 0.10117, test veri seti için ortalama hata 0.34878, kontrol veri seti için hata 0.32901 olarak gerçekleşmiştir. Bu yaklaşımın eğitim başarı oranı %76 ve test başarı oranı %55'dir.

18. Termal görüntüler, titreşim ve ses spektrogramlarına dayalı olarak kurulan 4 adet KSA yaklaşımı karşılaştırmalı olarak incelenmiş ve sonuçlar literatürdeki yaklaşımlar ile kıyaslanmıştır. Yaklaşım başarı oranlarının, eğitim sürecine ve derin nöral ağ mimarisine ait parametrelere yapılan ince ayar ile ya da görsel verilere büyütme işleminin uygulanmasıyla arttırılabileceği gösterilmiştir. Derin öğrenme ile arıza tespiti ve sınıflandırılması yapılırken termal görüntülerin kullanıldığı IRT-KSA yaklaşımı ile %100 başarı oranına ulaşılmıştır.
19. Arıza tespiti ve sınıflandırması amacıyla kullanılan YZ yaklaşımlarının performanslarının değerlendirilmesi amacıyla doğruluk, özgüllük ve duyarlılık değerleri hesaplanmış ve karşılaştırılmıştır. IRT-KSA yaklaşımına ait doğruluk, özgüllük ve duyarlılık değerleri diğer yaklaşımlardan yüksek çıkmıştır. TS-KSA yaklaşımına ait performans değerleri ise diğer yaklaşımlardan daha düşük çıkmıştır.

6. ÖNERİLER

1. Geliştirilen deney düzeneğinin sistem tanılama yolu ile titreşim, ses veya termal görüntülere dayalı olarak matematiksel modeli kurulabilir.
2. Geliştirilen deney düzeneği ile rulman bozukluğu, yağ eksikliği (veya yağsız çalışma), aksenal ya da radyal düzgünsüzlük vb. arıza türlerinin YZ ile tespit edilip sınıflandırılmasına yönelik çalışmalar yapılabilir.
3. Geliştirilen deney düzeneği ile farklı ciddiyet derecesine sahip aynı tür arızanın YZ ile tespit edilip sınıflandırılmasına yönelik çalışmalar yapılabilir.
4. Geliştirilen deney düzeneği ile Diskriminant Analizi, Karar Ağaçları, Yalın Bayes gibi bu tez çalışmasında kullanılmayan YZ türleri ile S, A1, A2 ve A3 redüktörlerinde arıza tespiti ve sınıflandırılmasına yönelik çalışmalar karşılaştırmalı olarak yapılabilir.
5. Geliştirilen deney düzeneğinde kullanılan dişli çarklar plastik ya da daha farklı bir malzemeden imal edilmiş dişli çarklar ile değiştirilebilir. Bu doğrultuda titreşim, ses ya da termal görüntü analizi veya YZ çalışmaları yapılabilir.
6. Titreşim, ses ve termal görüntü analizinde kullanılan özniteliklerin sayısı arttırılabilir veya bu çalışmada kullanılmayan öznitelikler ile YZ tabanlı arıza tespiti ve sınıflandırılması yapılabilir.
7. Geliştirilen deney düzeneğinin kumanda sistemi modifiye edilerek daha geniş bir hız ve yükleme aralığında ölçümler yapılabilir. Bu ölçümlere dayalı olarak doğruluk, özgüllük ve duyarlılık oranları daha yüksek YZ yaklaşımları kurulabilir.
8. Geliştirilen deney düzeneği üzerinden yapılan ölçümler ile veriye dayalı istatistiksel arıza tespiti ve sınıflandırma yaklaşımları kurularak YZ sonuçları ile karşılaştırılabilir.

7. KAYNAKLAR

1. Randall, R., B., Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications, John Wiley & Sons Ltd., West Sussex, 2011.
2. Mohanty, A., R., Machinery Condition Monitoring: Principles and Practices, CRC Press, Taylor&Francis Group, Boca Raton, 2015.
3. Akkurt, M., Makine Elemanları 2. Cilt, Birsen Yayınevi, İstanbul, 2012.
4. Kutay, M., G., Dişli Çarklar ve Redüktörleri, Birsen Yayınevi, İstanbul, 2006.
5. Mobley, R., K., Maintenance Fundamentals, Second Edition (Plant Engineering), Elsevier Butterworth-Heinemann, Burlington, 2004.
6. Al-Arbi, S., K., Condition Monitoring of Gear Systems using Vibration Analysis, PhD Thesis, University of Huddersfield, West Yorkshire, 2012.
7. Akkurt M., Makine Elemanları Cilt I-II, Birsen Yayınevi, İstanbul, 2005.
8. Haberhauer, H. ve Bodenstern, F., Maschinenelemente, Gestaltung, Berechnung, Anwendung, 15., bearbeitete Auflage, Springer-Verlag, Berlin, 2009.
9. Wittel, H., Muhs, D., Jannasch, D. ve Voßiek, J., Roloff/Matek Maschinenelemente, Normung, Berechnung, Gestaltung, Springer-Verlag, Berlin, 2009.
10. BJ-Gear A/S, Worm Gear Manual, Skanderborg, 2013.
11. Radzevich, S., P., Dudley's Handbook of Practical Gear Design and Manufacture, Second Edition, CRC Press, Taylor & Francis Group, New York, 2012.
12. Crosher, W., P., Design and Application of the Worm Gear, Asme Press, New York, 2002.
13. Jeleska, D., Gears and Gear Drives, John Wiley and Sons Ltd. Publication, West Sussex, 2012.
14. Roberts, M., J., Signals and systems: analysis using transform methods and MATLAB 2nd ed., The McGraw-Hill Companies Inc., New York, 2012.
15. Havelock, D., Kuwano, S. ve Vorlander, M., Handbook of Signal Processing in Acoustics Volume 1, Springer Science+Business Media, New York, 2008.
16. Shin, K. ve Hammond, J., K., Fundamentals of Signal Processing for Sound and Vibration Engineers, John Wiley & Sons Ltd., West Sussex, 2008.
17. Leung, H., Chaotic Signal Processing, Society for Industrial and Applied Mathematics, Pennsylvania, 2014.

18. Edwards, C., H. ve Penney, D., E., Elementary Differential Equations Sixth Edition, Pearson Education Inc., New Jersey, 2008.
19. Crocker, M., J., Handbook of Noise and Vibration Control, John Wiley & Sons Inc., New Jersey, 2007.
20. Napolitano, A., Generalizations of Cyclostationary Signal Processing: Spectral Analysis and Applications, John Wiley & Sons, Ltd., West Sussex, 2012.
21. Ingle, V., K. ve Proakis, J., G., Digital Signal Processing Using MATLAB Third Edition, Cengage Learning, Stamford, 2012.
22. Proakis, J., G. ve Manolakis, D., G., Digital Signal Processing Principles Algorithms, and Applications Third Edition, Prentice-Hall International Inc., New Jersey, 1996.
23. Elmas, Ç., Yapay Zeka ve Uygulamaları, Seçkin Yayıncılık, Ankara, 2007.
24. Luger, G., F., Artificial Intelligence, Structures And Strategies For Complex Problem Solving 5th Edition, Addison-Wesley Pearson Education, Essex, 2005.
25. Jones, M., T., Artificial Intelligence: A Systems Approach, Infinity Science Press Llc, New Delhi, 2008.
26. Alpaydın, E., Introduction to Machine Learning, The MIT Press, Cambridge, 2004.
27. Clarke, B., Fokoue, E. ve Zhang, H., H., Principles and Theory for Data Mining and Machine Learning Springer Series in Statistics, Springer Science+Business Media Llc., New York, 2009.
28. The MathWorks, Statistics and Machine Learning Toolbox™ User's Guide, Natick MA, 2018.
29. The MathWorks, Introducing Deep Learning with MATLAB, Natick MA, 2018.
30. de Silva, C., W., Vibration Monitoring, Testing, and Instrumentation, Taylor & Francis Group Llc, New York, 2007.
31. Davies, A., Handbook of Condition Monitoring, Chapman & Hall, London, 1998.
32. Inman, D., J., Engineering Vibration Fourth Edition, Pearson Education Inc., New Jersey, 2014.
33. Ver, I., L. ve Beranek, L., L., Noise and Vibration Control Engineering : Principles and Applications, John Wiley & Sons, Inc., New Jersey, 2006.
34. Tiwari, R., Rotor Systems: Analysis and Identification, CRC Press Taylor & Francis, New York, 2018.

35. Prakash, R., V., *Infrared Thermography*, IntechOpen Limited, London, 2012.
36. Vollmer, M. ve Möllmann, K., P., *Infrared Thermal Imaging*, Wiley-Vch Verlag GmbH & Co. KGaA, Weinheim, 2010.
37. Fluke Corporation, *Fluke Ti Series Industrial Thermal Imagers*, 2018.
38. Mix, P., E., *Introduction to Nondestructive Testing : A Training Guide 2nd ed.*, John Wiley & Sons Inc., New Jersey, 2005.
39. Thomson, W., T. ve Culbert, I., *Current Signature Analysis For Condition Monitoring Of Cage Induction Motors: Industrial Application And Case Histories*, John Wiley & Sons Inc., New Jersey, 2017.
40. Miljkovic, D., Brief Review of Motor Current Signature Analysis, *HDKBR INFO Magazin*, 5, 1 (2015) 14–26.
41. Starr, A. ve Rao, B., K., N., *Condition Monitoring and Diagnostic Engineering Management*, Elsevier Science Ltd., Oxford, 2001.
42. Martin, J., G., Gil, G., J. ve Sanchez, E., V., Non-Destructive Techniques Based on Eddy Current Testing Review, *Sensors*, 11, 3 (2011) 2525-2565.
43. Jaber, A., A., *Design of an Intelligent Embedded System for Condition Monitoring of an Industrial Robot*, Springer International Publishing, Cham, 2017.
44. Park, H., G. ve Zak, M., *Gray-Box Approach for Fault Detection of Dynamical Systems*, *J. Dyn. Sys. Meas. Control*, 12, 3 (2003) 451-454.
45. Ding, S., X., *Model-based Fault Diagnosis Techniques Design Schemes, Algorithms and Tools*, Springer-Verlag, Berlin, 2008.
46. Parey, A., Badaoui, M., E., Guillet F. ve Tandon, N., Dynamic modelling of spur gear pair and application of empirical mode decomposition-based statistical analysis for early detection of localized tooth defect, *Journal of Sound and Vibration*, 294, 3 (2006) 547-561.
47. Mohammed, O., D., Rantatalo, M. ve Aidanpää, J., O., Dynamic modelling of a one-stage spur gear system and vibration-based tooth crack detection analysis, *Mechanical Systems and Signal Processing*, 54, 55 (2015) 293-305.
48. Liang, X., Zuo, M., J. ve Hoseini, M., R., Vibration signal modeling of a planetary gear set for tooth crack detection, *Engineering Failure Analysis*, 48 (2015) 185–200.
49. Lei, Y., Liu, Z., Lin, J. ve Lu, F., Phenomenological models of vibration signals for condition monitoring and fault diagnosis of epicyclic gearboxes, *Journal of Sound and Vibration*, 369 (2016) 266-281.

50. Venkatasubramanian, V., Rengaswamy, R., Yin, K. ve Kavuri, S., A review of process fault detection and diagnosis part I: quantitative model-based methods, Comput. Chem. Eng., 27 (2003) 293– 311.
51. Ding, S., X., Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems, Advances in Industrial Control, Springer-Verlag, London, 2014.
52. Roffel, B. ve Betlem, B., Process Dynamics and Control Modeling for Control and Prediction, John Wiley & Sons Ltd., West Sussex, 2006.
53. Ding, S., X., Data-Driven Design of Model-based Fault Diagnosis Systems, 8th IFAC Symposium on Advanced Control of Chemical Processes, Haziran 2012, Singapur, Bildiriler Kitabı: 45, 15, 840-847.
54. Qin, S., J., Statistical process monitoring: Basics and beyond, Journal of Chemometrics, 17 (2003) 480—502.
55. Qin, S., J., Data-driven fault detection and diagnosis for complex industrial processes, 7th IFAC Symposium on Fault Detection, Haziran-Temmuz 2009, Barselona, Bildiriler Kitabı: 42, 8, 1115-1125.
56. Venkatasubramanian, V., Rengaswamy, R., Kavuri, S., N. ve Yin, K., Review of process fault detection and diagnosis part III: Quantitative model-based methods, Computers and Chemical Engineering, 27 (2003) 327-346.
57. Markou, M. ve Singh, S., Novelty detection: a review—part 1: statistical approaches, Signal Processing, 83 (2003) 2481-2497.
58. Kouadri, A. ve Zelmat, M., A statistical procedure based on wavelets for fault detection applied on the three tank system, Journal of Statistics and Management Systems, 13, 5 (2010) 949-960.
59. Yin, J., Wang, W., Man, Z. ve Khoo, S., Statistical modeling of gear vibration signals and its application to detecting and diagnosing gear faults, Information Sciences, 259, 20 (2014) 295-303.
60. Baydar, N., Chen, Q., Ball, A. ve Kruger, U., Detection of incipient tooth defect in helical gears using multivariate statistics, Mechanical Systems and Signal Processing, 15 (2001) 303-321.
61. Zhang, Z., Verma, A. ve Kusiak, A., Fault analysis and condition monitoring of the wind turbine gearbox, IEEE Transactions on Energy Conversion, 27 (2012) 526-535.
62. Wang, S., C., Artificial Neural Network, In: Interdisciplinary Computing in Java Programming The Springer International Series in Engineering and Computer Science, Springer Science+Business Media, New York, 2003.
63. Davim, J., P., Machining of Hard Materials, Springer-Verlag, London, 2011.

64. Rafiee, J., Arvani, F., Harifi, A. ve Sadeghi, M., H., Intelligent condition monitoring of a gearbox using artificial neural network, Mechanical Systems and Signal Processing, 21, 4 (2007) 1746-1754.
65. Yang, S., Li, W. ve Wang, C., The intelligent fault diagnosis of wind turbine gearbox based on artificial neural network, International Conference on Condition Monitoring and Diagnosis, Nisan 2008, Beijing, Bildiriler Kitabı: 327 – 1330.
66. Bangalore, P. ve Tjernberg, L., B., An Artificial Neural Network Approach for Early Fault Detection of Gearbox Bearings, IEEE Transactions on Smart Grid, 6, 2 (2015) 980 – 987.
67. Huang, Q., Jiang, D., Hong, L. ve Ding, Y., Application of Wavelet Neural Networks on Vibration Fault Diagnosis for Wind Turbine Gearbox, International Symposium on Neural Networks, Eylül 2008, Berlin, Bildiriler Kitabı: 313-320.
68. Schlechtingen, M. ve Santos, I., F., Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection, Mechanical Systems and Signal Processing, 25, 5 (2011) 1849-1875.
69. Paya, B., A., Esat, I., I. ve Badi, M., N., M., Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor, Mechanical Systems and Signal Processing, 11, 5 (1997) 751-765.
70. Khazaei, M., Ahmadi, H., Omid, M., Banakar, A. ve Moosavian, A., Feature-level fusion based on wavelet transform and artificial neural network for fault diagnosis of planetary gearbox using acoustic and vibration signals, Insight - Non-Destructive Testing and Condition Monitoring, 55, 6 (2013) 323-330.
71. Wu, J., D. ve Chan, J., J., Faulted gear identification of a rotating machinery based on wavelet transform and artificial neural network, Expert Systems with Applications, 36, 5 (2009) 8862-8875.
72. Dellomo, M., R., Helicopter Gearbox Fault Detection: A Neural Network Based Approach, Journal of Vibration and Acoustics, 121, 3 (1999) 265-272.
73. Tian, T. ve Zuo, M., J., Health Condition Prediction of Gears Using a Recurrent Neural Network Approach, IEEE Transactions on Reliability, 59, 4 (2010) 700 – 705.
74. Bartelmus, W., Zimroz, R. ve Batra, H., Gearbox vibration signal pre-processing and input values choice for neural network training, AI-METH 2003, Kasım 2003, Gliwice, Bildiriler Kitabı: 5-7.
75. Chen, Z., Li, C. ve René-Vinicio, S., Multi-layer neural network with deep belief network for gearbox fault diagnosis, Journal of Vibroengineering, 17, 5 (2015) 2379-2392.

76. Bin, G., F., Gao, J., J., Li, X., J. ve Dhillon, B. S., Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network, Mechanical Systems and Signal Processing, 27 (2012) 696-711.
77. Saravanan, N. ve Ramachandran, K., I., Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN), Expert Systems with Applications, 37, 6 (2010) 4168-4181.
78. Ross, T., J., Fuzzy Logic With Engineering Applications, John Wiley & Sons Ltd., West Sussex, 2004.
79. Saravanan, N., Cholairajan, S. ve Ramachandran, K., I., Vibration-based fault diagnosis of spur bevel gear box using fuzzy technique, Expert systems with applications, 36, 2 (2009) 3119-3135.
80. Wu, J., D. ve Hsu, C., C., Fault gear identification using vibration signal with discrete wavelet transform technique and fuzzy–logic inference, Expert systems with applications, 36, 2 (2009) 3785-3794.
81. Dempsey, P., J. ve Afjeh, A., A., Integrating oil debris and vibration gear damage detection technologies using fuzzy logic, Journal of the American Helicopter Society, 49, 2 (2009) 109-116.
82. Zeng, L. ve Wang, H., P., Machine-fault classification: a fuzzy-set approach, The International Journal of Advanced Manufacturing Technology, 6, 1 (1991) 83-93.
83. Joentgen, A., Mikenina, L., Weber, R., Zeugner, A. ve Zimmermann, H., J., Automatic fault detection in gearboxes by dynamic fuzzy data analysis, Fuzzy Sets and Systems, 105, 1 (1999) 123-132.
84. Widodo, A. ve Yang, B., S., Support vector machine in machine condition monitoring and fault diagnosis, Mechanical systems and signal processing, 21, 6 (2007) 2560-2574.
85. Widodo, A., Kim, E., Y., Son, J., D., Yang, B., S., Tan, A., C., Gu, D. S., Choi, B., K. ve Mathew, J., Fault diagnosis of low speed bearing based on relevance vector machine and support vector machine, Expert systems with applications, 36, 3 (2009) 7252-7261.
86. Wang, L., Support Vector Machines: Theory and Applications, Springer-Verlag, Berlin, 2005.
87. Bansal, S., Sahoo, S., Tiwari, R. ve Bordoloi, D., J., Multiclass fault diagnosis in gears using support vector machine algorithms based on frequency domain data, Measurement, 46, 9 (2013) 3469-3481.

88. Saravanan, N., Siddabattuni, V., K. ve Ramachandran, K., I., Fault diagnosis of spur bevel gear box using artificial neural network (ANN) and proximal support vector machine (PSVM), Applied Soft Computing, 10, 1 (2010) 344-360.
89. Wang, S., J., Mathew, A., Chen, Y., Xi, L., F., Ma, L. ve Lee, J., Empirical analysis of support vector machine ensemble classifiers, Expert Systems with applications, 36, 3, (2009) 6466-6476.
90. Shen, C., Wang, D., Kong, F. ve Peter, W., T., Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier, Measurement, 46, 4 (2013) 1551-1564.
91. McLachlan, G., J., Discriminant Analysis and Statistical Pattern Recognition, John Wiley & Sons Inc, New Jersey, 2004.
92. Adil, M., Abid, M., Khan, A., Q., Mustafa, G. ve Ahmed, N., Exponential discriminant analysis for fault diagnosis, Neurocomputing, 171 (2016) 1344-1353.
93. Liu, Z., Qu, J., Zuo, M., J., Xu, H., Fault level diagnosis for planetary gearboxes using hybrid kernel feature selection and kernel Fisher discriminant analysis, The International Journal of Advanced Manufacturing Technology, 67, 5-8 (2013) 1217-1230.
94. Zhang, J., F. ve Huang, Z., C., Kernel Fisher discriminant analysis for bearing fault diagnosis, International Conference on Machine Learning and Cybernetics, Ağustos 2005, Guangzhou, Bildiriler Kitabı: 5, 3216-3220.
95. Li, W., H., Ding, K., Shi, T., L. ve Liao, G., L., Gear Fault Classification Using Kernel Discriminant Analysis, Key Engineering Materials, 321 (2006) 1556-1559.
96. Li, W., H., Shi, T., L. ve Yang, S., Z., Mechanical Fault Classification Using Nonlinear Discriminant Analysis, Journal of Vibration Engineering, 18, 2 (2005) 133-138.
97. Li, W., Shi, T., L. ve Yang, S., Z., An approach for mechanical fault classification based on generalized discriminant analysis, Frontiers of Mechanical Engineering in China, 1, 3 (2006) 292-298.
98. Sammut, C. ve Webb, G., I., Encyclopedia of Machine Learning, Springer Science+BusinessMedia LLC, New York, 2011.
99. Friedman, N., Geiger, D. ve Goldszmidt, M., Bayesian network classifiers, Machine learning, 29, 2-3 (1997) 131-163.
100. Amarnath, M., Jain, D., Sugumaran, V. ve Kumar, H., Fault diagnosis of helical gear box using naive Bayes and Bayes net, International Journal of Decision Support Systems, 1, 1 (2015) 4-17.

101. Kumar, H., Ranjit Kumar, T., A., Amarnath, M. ve Sugumaran, V., Fault diagnosis of bearings through vibration signal using Bayes classifiers, International Journal of Computer Aided Engineering and Technology, 6, 1 (2014) 14-28.
102. Sharma, R., K., Sugumaran, V., Kumar, H. ve Amarnath, M., A comparative study of naive Bayes classifier and Bayes net classifier for fault diagnosis of roller bearing using sound signal, International Journal of Decision Support Systems, 1,1 (2015) 115-129.
103. Yu, J., Huang, W. ve Zhao, X., Combined flow graphs and normal naive Bayesian classifier for fault diagnosis of gear box, Proceedings of the Institution of Mechanical Engineers Part C, Journal of Mechanical Engineering Science, 230, 2 (2016) 303-313.
104. Elangovan, M., Ramachandran, K., I. ve Sugumaran, V., Studies on Bayes classifier for condition monitoring of single point carbide tipped tool based on statistical and histogram features, Expert Systems with Applications, 37, 3 (2010) 2059-2065.
105. Kramer, O., K-Nearest Neighbors, In: Dimensionality Reduction with Unsupervised Nearest Neighbors, Intelligent Systems Reference Library, Springer, Berlin, 2013.
106. Pandya, D., H., Upadhyay, S., H. ve Harsha, S., P., Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN, Expert Systems with Applications, 40,10 (2013) 4137-4145.
107. Lei, Y. ve Zuo, M., J., Gear crack level identification based on weighted K nearest neighbor classification algorithm, Mechanical Systems and Signal Processing, 23,5 (2009) 1535-1547.
108. Wang, D., K-nearest neighbors based methods for identification of different gear crack levels under different motor speeds and loads: Revisited, Mechanical Systems and Signal Processing, 70 (2016) 201-208.
109. Li, Z., X., Yan, X., P., Yuan, C., Q. ve Li, L., Gear multi-faults diagnosis of a rotating machinery based on independent component analysis and fuzzy k-nearest neighbor, In Advanced Materials Research, 108 (2010) 1033-1038.
110. Tian, J., Morillo, C., Azarian, M., H. ve Pecht, M., Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with K-nearest neighbor distance analysis, IEEE Transactions on Industrial Electronics, 63, 3 (2016) 1793-1803.
111. Wu, J., Advances in K-means Clustering A Data Mining Thinking, Springer-Verlag, Berlin, 2012.
112. Yiakopoulos, C., T., Gryllias, K., C. ve Antoniadis, I., A., Rolling element bearing fault detection in industrial environments based on a K-means clustering approach, Expert Systems with Applications, 38, 3 (2011) 2888-2911.

113. Park, H., S. ve Jun, C., H., A simple and fast algorithm for K-medoids clustering, Expert systems with applications, 36, 2 (2009) 3336-3341.
114. Cerrada, M., Sánchez, R., V., Pacheco, F., Cabrera, D., Zurita, G. ve Li, C., Hierarchical feature selection based on relative dependency for gear fault diagnosis, Applied Intelligence, 44, 3 (2016) 687-703.
115. Nelwamondo, F., V., Marwala, T. ve Mahola, U., Early classifications of bearing faults using hidden Markov models, Gaussian mixture models, mel-frequency cepstral coefficients and fractals, International Journal of Innovative Computing, Information and Control, 2, 6 (2006) 1281-1299.
116. Heyns, T., Heyns, P., S. ve De Villiers, J., P., Combining synchronous averaging with a Gaussian mixture model novelty detection scheme for vibration-based condition monitoring of a gearbox, Mechanical Systems and Signal Processing, 32 (2012) 200-215.
117. Gharavian, M., H., Ganj, F., A., Ohadi, A., R. ve Bafroui, H., H., Comparison of FDA-based and PCA-based features in fault diagnosis of automobile gearboxes, Neurocomputing, 121 (2013) 150-159.
118. Bhar, R. ve Hamori, S., Hidden Markov Models Applications to Financial Economics, Kluwer Academic Publishers, Dordrecht, 2004.
119. Luo, A., Chen, S. ve Xv, B., Enhanced Map-Matching Algorithm with a Hidden Markov Model for Mobile Phone Positioning, ISPRS International Journal of Geo-Information, 6, 11 (2017) 327.
120. Zaidi, S., S., H., Aviyente, S., Salman, M., Shin, K., K. ve Strangas, E., G., Prognosis of gear failures in dc starter motors using hidden Markov models, IEEE Transactions on industrial Electronics, 58, 5 (2011) 1695-1706.
121. Cheng, G., Li, H., Hu, X., Chen, X. ve Liu, H., Fault diagnosis of gearbox based on local mean decomposition and discrete hidden Markov models, Proceedings of the Institution of Mechanical Engineers Part C, Journal of Mechanical Engineering Science, 231, 14 (2017) 2706-2717.
122. Li, X., Makis, V., Zuo, H. ve Cai, J., Optimal Bayesian control policy for gear shaft fault detection using hidden semi-Markov model, Computers & Industrial Engineering, 119 (2018) 21-35.
123. Miao, Q., Huang, H., Z. ve Fan, X., A comparison study of support vector machines and hidden Markov models in machinery condition monitoring, Journal of Mechanical Science and Technology, 21, 4 (2007) 607-615.
124. Zhou, H., Chen, J., Dong, G. ve Wang, R., Detection and diagnosis of bearing faults using shift-invariant dictionary learning and hidden Markov model, Mechanical systems and signal processing, 72 (2016) 65-79.

125. Georgoulas, G., Mustafa, M., O., Tsoumas, I., P., Antonino-Daviu, J., A., Climente-Alarcon, V., Stylios, C., D. ve Nikolakopoulos, G., Principal Component Analysis of the start-up transient and Hidden Markov Modeling for broken rotor bar fault diagnosis in asynchronous machines, Expert Systems with Applications, 40, 17 (2013) 7024-7033.
126. Zhu, K., San Wong, Y. ve Hong, G., S., Multi-category micro-milling tool wear monitoring with continuous hidden Markov models, Mechanical Systems and Signal Processing, 23, 2 (2009) 547-560.
127. Rokach, L. ve Maimon, O., Data Mining With Decision Trees Theory and Applications, World Scientific Publishing Co. Pte. Ltd., London, 2008.
128. Shaaban, S., M. ve Nabwey, H., A decision tree approach for steam turbine-generator fault diagnosis, International Journal of Advanced Science and Technology, 51 (2013) 59-66.
129. Saravanan, N. ve Ramachandran, K., I., Fault diagnosis of spur bevel gear box using discrete wavelet features and Decision Tree classification, Expert Systems with Applications, 36, 5 (2009) 9564-9573.
130. Muralidharan, V. ve Sugumaran, V., Feature extraction using wavelets and classification through decision tree algorithm for fault diagnosis of mono-block centrifugal pump, Measurement, 46,1 (2013) 353-359.
131. Sun, W., Chen, J. ve Li, J., Decision tree and PCA-based fault diagnosis of rotating machinery, Mechanical Systems and Signal Processing, 21, 3 (2007) 1300-1317.
132. Karabadi, N., E., I., Seridi, H., Khelf, I., Azizi, N. ve Boulkroune, R., Improved decision tree construction based on attribute selection and data sampling for fault diagnosis in rotating machines, Engineering Applications of Artificial Intelligence, 35 (2014) 71-83.
133. Amarnath, M., Sugumaran, V. ve Kumar, H., Exploiting sound signals for fault diagnosis of bearings using decision tree, Measurement, 46, 3 (2013) 1250-1256.
134. Sivanandam, S., N. ve Deepa, S., N., Introduction to Genetic Algorithms, Springer-Verlag, Berlin, 2008.
135. Samanta, B., Gear fault detection using artificial neural networks and support vector machines with genetic algorithms, Mechanical Systems and Signal Processing, 18, 3 (2004) 625-644.
136. Samanta, B., Al-Balushi, K., R. ve Al-Araimi, S., A., Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection, Engineering applications of artificial intelligence, 16, 7-8 (2003) 657-665.
137. Hajnayeb, A., Ghasemloonia, A., Khadem, S., E. ve Moradi, M., H., Application and comparison of an ANN-based feature selection method and the genetic

- algorithm in gearbox fault diagnosis, Expert Systems with Applications, 38, 8 (2011) 10205-10209.
138. Cerrada, M., Zurita, G., Cabrera, D., Sánchez, R., V., Artés, M. ve Li, C., Fault diagnosis in spur gears based on genetic algorithm and random forest, Mechanical Systems and Signal Processing, 70 (2016) 87-103.
 139. Zhang, Y. ve Randall, R., B., Rolling element bearing fault diagnosis based on the combination of genetic algorithms and fast kurtogram, Mechanical Systems and Signal Processing, 23, 5 (2009) 1509-1517.
 140. Bordoloi, D., J. ve Tiwari, R., Optimum multi-fault classification of gears with integration of evolutionary and SVM algorithms, Mechanism and Machine Theory, 73 (2014) 49-60.
 141. Wu, J., D., Hsu, C., C. ve Wu, G., Z., Fault gear identification and classification using discrete wavelet transform and adaptive neuro-fuzzy inference, Expert Systems with Applications, 36, 3 (2009) 6244-6255.
 142. Yen, G., G. ve Meesad, P., An effective neuro-fuzzy paradigm for machinery condition health monitoring, IEEE Transactions on Systems, Man, and Cybernetics, 31, 4 (2001) 523-536.
 143. Balazinski, M., Czogala, E., Jemielniak, K. ve Leski, J., Tool condition monitoring using artificial intelligence methods, Engineering Applications of Artificial Intelligence, 15, 1 (2002) 73-80.
 144. Achiche, S., Balazinski, M., Baron, L. ve Jemielniak, K., Tool wear monitoring using genetically-generated fuzzy knowledge bases, Engineering Applications of Artificial Intelligence, 15, 3-4 (2002) 303-314.
 145. Wang, W., Ismail, F. ve Golnaraghi, F., A neuro-fuzzy approach to gear system monitoring, IEEE transactions on Fuzzy Systems, 12,5 (2004) 710-723.
 146. Zhang, L., Xiong, G., Liu, H., Zou, H. ve Guo, W., Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference, Expert Systems with Applications, 37, 8 (2010) 6077-6085.
 147. Chen, C., Zhang, B., Vachtsevanos, G. ve Orchard, M., Machine condition prediction based on adaptive neuro-fuzzy and high-order particle filtering, IEEE Transactions on Industrial Electronics, 58, 9 (2011) 4353-4364.
 148. Lei, Y., He, Z., Zi, Y. ve Hu, Q., Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs, Mechanical systems and signal processing, 21, 5 (2007) 2280-2294.
 149. Pawar, P., M. ve Ganguli, R., Genetic fuzzy system for damage detection in beams and helicopter rotor blades, Computer methods in applied mechanics and engineering, 192, 16-18 (2003) 2031-2057.

150. Jia, F., Lei, Y., Lin, J., Zhou, X. ve Lu, N., Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, Mechanical Systems and Signal Processing, 72 (2016) 303-315.
151. Zhao, Y., Guo, Z., H. ve Yan, J., M., Vibration signal analysis and fault diagnosis of bogies of the high-speed train based on deep neural networks, Journal of Vibroengineering, 19, 4 (2017) 2456-2474.
152. Sun, W., Shao, S., Zhao, R., Yan, R., Zhang, X. ve Chen, X., A sparse auto-encoder-based deep neural network approach for induction motor faults classification, Measurement, 89 (2016) 171-178.
153. Guo, X., Chen, L. ve Shen, C., Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis, Measurement, 93 (2016) 490-502.
154. Devendiran, S. ve Manivannan, K., Vibration Based Condition Monitoring and Fault Diagnosis Technologies For Bearing and Gear Components-A Review, International Journal of Applied Engineering Research, 11, 6 (2016) 3966-3975.
155. Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J. ve Jayakumar, T., Infrared thermography for condition monitoring–A review, Infrared Physics & Technology, 60 (2013) 35-55.
156. Jagtap, V., A. ve Sonawane, P., R., A Review on Fault Detection of Gearbox by using Vibration Analysis, International Journal of Innovative Research in Science, Engineering and Technology, 6, 7 (2017) 14627- 14633.
157. Antoni, J. ve Randall, R., B., Differential diagnosis of gear and bearing faults, Journal of Vibration and Acoustics, 124, 2 (2002) 165-171.
158. Loutridis, S., J., Damage detection in gear systems using empirical mode decomposition, Engineering Structures, 26, 12 (2004) 1833-1841.
159. Fan, X. ve Zuo, M., J., Gearbox fault detection using Hilbert and wavelet packet transform, Mechanical Systems And Signal Processing, 20, 4 (2006) 966-982.
160. Peng, Z., K., Peter, W., T. ve Chu, F., L., A comparison study of improved Hilbert–Huang transform and wavelet transform: application to fault diagnosis for rolling bearing, Mechanical Systems And Signal Processing, 19, 5 (2005) 974-988.
161. Yu, D., Cheng, J. ve Yang, Y., Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings, Mechanical systems and signal processing, 19, 2 (2005) 259-270.

162. Liu, B., Riemenschneider, S. ve Xu, Y., Gearbox fault diagnosis using empirical mode decomposition and Hilbert spectrum, Mechanical Systems and Signal Processing, 20, 3 (2006) 718-734.
163. Yang, M. ve Makis, V., ARX model-based gearbox fault detection and localization under varying load conditions, Journal of Sound and Vibration, 329, 24 (2010) 5209-5221.
164. Lewicki, D., G., LaBerge, K., E., Ehinger, R., T. ve Fetty, J., Planetary gearbox fault detection using vibration separation techniques, 67th Annual Forum and Technology Display, Mays 2011, Virginia, Bildiriler Kitabı: NASA/TM—2011-217127.
165. Xue, S. ve Howard, I., Torsional vibration signal analysis as a diagnostic tool for planetary gear fault detection, Mechanical Systems and Signal Processing, 100 (2018) 706-728.
166. Dhamande, L., S. ve Chaudhari, M., B., Compound Gear-Bearing Fault Feature Extraction Using Statistical Features Based On Time-Frequency Method, Measurement, 125 (2018) 63–77.
167. Liu, X., Yang, Y. ve Zhang, J., Resultant vibration signal model based fault diagnosis of a single stage planetary gear train with an incipient tooth crack on the sun gear, Renewable Energy, 122 (2018) 65-79.
168. Li, Y., Ding, K., He, G. ve Lin, H., Vibration mechanisms of spur gear pair in healthy and fault states, Mechanical Systems and Signal Processing, 81 (2016) 183-201.
169. Ma, H., Pang, X., Feng, R., Song, R. ve Wen, B., Fault features analysis of cracked gear considering the effects of the extended tooth contact, Engineering Failure Analysis, 48 (2015) 105-120.
170. Samuel, P., D. ve Pines, D., J., A review of vibration-based techniques for helicopter transmission diagnostics, Journal of sound and vibration, 282, 1-2 (2005) 475-508.
171. Aherwar, A. ve Khalid, M., S., Vibration analysis techniques for gearbox diagnostic: a review, International Journal of Advanced Engineering Technology, 3, 2 (2012) 04-12.
172. Li, R. ve He, D., Rotational machine health monitoring and fault detection using EMD-based acoustic emission feature quantification, IEEE Transactions on Instrumentation and Measurement, 61, 4 (2012) 990-1001.
173. Li, R., Seçkiner, S., U., He, D., Bechhoefer, E. ve Menon, P., Gear fault location detection for split torque gearbox using AE sensors, IEEE Transactions on Systems, Man, and Cybernetics, Part C, 4, 6 (2012) 1308-1317.

174. Gu, D., An, Y. ve Choi, B., Detection of faults in gearboxes using acoustic emission signal, Journal of Mechanical Science and Technology, 25, 5 (2011) 1279.
175. Qu, Y., He, D., Yoon, J., Van Hecke, B., Bechhoefer, E. ve Zhu, J., Gearbox tooth cut fault diagnostics using acoustic emission and vibration sensors—A comparative study, Sensors, 14, 1 (2014) 1372-1393.
176. Baydar, N. ve Ball, A., A comparative study of acoustic and vibration signals in detection of gear failures using Wigner–Ville distribution, Mechanical systems and signal processing, 15, 6 (2001) 1091-1107.
177. Baydar, N. ve Ball, A., Detection of gear failures via vibration and acoustic signals using wavelet transform, Mechanical Systems and Signal Processing, 17, 4 (2003) 787-804.
178. Toutountzakis, T., Tan, C., K. ve Mba, D., Application of acoustic emission to seeded gear fault detection, NDT & E International, 38, 1 (2005) 27-36.
179. Eftekharnjad, B. ve Mba, D., Seeded fault detection on helical gears with acoustic emission, Applied acoustics, 70, 4 (2009) 547-555.
180. Amarnath, M. ve Krishna, I., P., Empirical mode decomposition of acoustic signals for diagnosis of faults in gears and rolling element bearings, IET Science, Measurement & Technology, 6, 4 (2012) 279-287.
181. Amarnath, M. ve Krishna, I., P., Local fault detection in helical gears via vibration and acoustic signals using EMD based statistical parameter analysis, Measurement, 58 (2014) 154-164.
182. Loutas, T., H., Sotiriades, G., Kalaitzoglou, I. ve Kostopoulos, V., Condition monitoring of a single-stage gearbox with artificially induced gear cracks utilizing on-line vibration and acoustic emission measurements, Applied Acoustics, 70, 9 (2009) 1148-1159.
183. Loutas, T., H., Roulias, D., Pauly, E. ve Kostopoulos, V., The combined use of vibration, acoustic emission and oil debris on-line monitoring towards a more effective condition monitoring of rotating machinery, Mechanical systems and signal processing, 25, 4 (2011) 1339-1352.
184. Tan, C., K., Irving, P. ve Mba, D., A comparative experimental study on the diagnostic and prognostic capabilities of acoustics emission, vibration and spectrometric oil analysis for spur gears, Mechanical Systems and Signal Processing, 21, 1 (2007) 208-233.
185. Jena, D., P. ve Panigrahi, S., N., Automatic gear and bearing fault localization using vibration and acoustic signals, Applied Acoustics, 98 (2015) 20-33.

186. Delvecchio, S., Bonfiglio, P. ve Pompoli, F., Vibro-acoustic condition monitoring of internal combustion engines: A critical review of existing techniques, Mechanical Systems and Signal Processing, 99 (2018) 661-683.
187. Glowacz, A. ve Glowacz, Z., Diagnosis of stator faults of the single-phase induction motor using acoustic signals, Applied Acoustics, 117 (2017) 20-27.
188. Gao, L., Zai, F., Su, S., Wang, H., Chen, P. ve Liu, L., Study and application of acoustic emission testing in fault diagnosis of low-speed heavy-duty gears, Sensors, 11,1 (2011) 599-611.
189. Leemans, V., Destain, M., F., Kilundu, B. ve Dehombreux, P., Evaluation of the performance of infrared thermography for on-line condition monitoring of rotating machines, Engineering, 3 (2011) 1030-1039.
190. Moussa, W., Thermography-Assisted Bearing Condition Monitoring, Doctoral dissertation, Ottawa-Carleton Institute for Mechanical and Aerospace Engineering, University of Ottawa, Ottawa, 2014.
191. Seo, J., J., Yoon, H., Ha, H., Hong, D., P. ve Kim, W., Infrared thermographic diagnosis mechanism for fault detection of ball bearing under dynamic loading conditions, Advanced Materials Research, 295 (2011) 1544-1547.
192. Kim, H., J., Hong, D., P. ve Kim, W., T., A Study on Real-Time Fault Monitoring Detection Method of Bearing Using the Infrared Thermography, Journal of the Korean Society for Nondestructive Testing, 33,4 (2013) 330-335.
193. Rumsey, M., A. ve Musial, W., Application of infrared thermography nondestructive testing during wind turbine blade tests, Journal of Solar Energy Engineering, 123, 4 (2001) 271-271.
194. Márquez, F., P., G., Tobias, A., M., Pérez, J., M., P. ve Papaelias, M., Condition monitoring of wind turbines: Techniques and methods, Renewable Energy, 46 (2012) 169-178.
195. Jadin, M., S. ve Taib, S., Recent progress in diagnosing the reliability of electrical equipment by using infrared thermography, Infrared Physics & Technology, 55, 4 (2012) 236-245.
196. Peng, Z. ve Kessissoglou, N., An integrated approach to fault diagnosis of machinery using wear debris and vibration analysis, Wear, 255, 7-12 (2003) 1221-1232.
197. Peng, Z., Kessissoglou, N., J. ve Cox, M., A study of the effect of contaminant particles in lubricants using wear debris and vibration condition monitoring techniques, Wear, 258, 11-12 (2005) 1651-1662.
198. Elforjani, M., Mba, D., Muhammad, A. ve Sire, A., Condition monitoring of worm gears, Applied Acoustics, 73, 8 (2012) 859-863.

199. Elasha, F., Ruiz-Cárcel, C., Mba, D., Kiat, G., Nze, I. ve Yebra, G., Pitting detection in worm gearboxes with vibration analysis, Engineering Failure Analysis, 42 (2014) 366-376.
200. Vähöja P., Lahdelma S. ve Leinonen J., On the Condition Monitoring of Worm Gears, 1st World Congress on Engineering Asset Management, Haziran 2006, Queensland, Bildiriler Kitabı: 332-343.
201. Ismon, M., Zaman, I. ve Ghazali, M., I., Condition Monitoring of Variable Speed Worm Gearbox Lubricated With Different Viscosity Oil, Applied Mechanics and Materials, 178-182 (2015) 773-774.
202. Waqar, T. ve Demetgul, M., Thermal analysis MLP neural network based fault diagnosis on worm gears, Measurement, 86 (2016) 56-66.
203. Ümütlü, R., C., Ozturk, H. ve Kiral, Z., Pitting detection in a worm gearbox using artificial neural networks, INTER-NOISE 2016, Ağustos 2016, Hamburg, Bildiriler Kitabı: 253, 6, 2718-2726.
204. Hizarci, B., Kiral, Z. ve Ozturk, H., Smart Condition Monitoring of Worm Gearboxes, INTER-NOISE 2016, Ağustos 2016, Hamburg, Bildiriler Kitabı :253, 6, 2727-2736.
205. Öztefen Redüktör Motor San. Tic. A. Ş., ESV Serisi Teknik Katalog, Konya, 2018.
206. Yavuzlar Mak. San. Tic. Ltd. Şti, Yıldız Tip Kaplinler, Bursa, 2017.
207. EMF, Elektromanyetik Fren Ve Kavrama Sistemleri Ürün Kataloğu, İstanbul, 2017.
208. Fanexfan, Sac Gövdeli Radyal Salyangozlar, İstanbul, 2016.
209. TECO Electric & Machinery Co. Ltd., S310 Microprocessor Controlled Inverter Motor Speed Regulator Operating Manual, Taipei City, 2018.
210. Opaş Elektrik, Kademeli Şalterler, Kocaeli, 2018.
211. Tekmatic, Magnetic Particle Brakes and Clutches, South Beloit, 2018.
212. IBD Wickeltechnik GmbH, Magnetspulverbremser & Kupplungen, Bad Oeynhausen, 2018.
213. ENDA, ECH Serisi Yukarı/Aşağı Sayıcı Ve Devir/Hız Ölçüm Cihazı, İstanbul, 2018.
214. Montgomery, D. C., ve Runger, G. C., Applied statistics and probability for engineers, John Wiley & Sons, New Jersey, 2018.
215. PCB Piezotronics Inc., Introduction to ICP® Accelerometers, New York, 2018.

216. PCB Piezotronics Inc., Model: 352C03 Installation and Operating Manual, New York, 2018.
217. PCB Piezotronics Inc., General Signal Conditioning Guide, New York, 2018.
218. Behringer, Measurement Microphone ECM8000, Willich, 2018.
219. Bosch Security Systems, Microphone Basics, Eindhoven, 2018.
220. Innogear, 1- Channel 48V Phantom Power Supply User Manual, 2018.
221. m+p International, m+p VibPilot User Manual, Hannover, 2012.
222. Testo SE & Co. KGaA, Testo 880, Lenzkirch, 2018.
223. Testo SE & Co. KGaA, Testo 880 Thermal Imager Instruction Manual, Lenzkirch, 2018.
224. m+p International, SO Analyzer Operating Manual , Hannover, 2009.
225. Caesarendra W. ve Tjahjowidodo T., A Review of Feature Extraction Methods in Vibration-Based Condition Monitoring and Its Application for Degradation Trend Estimation of Low-Speed Slew Bearing, Machines, 5 (2017) 21.
226. Dhamande, L., S. ve Chaudhari, M., B., Bearing fault diagnosis based on statistical feature extraction in time and frequency domain and neural network, International Journal of Vehicle Structures & Systems, 8, 4 (2016) 229.
227. Dhamande, L., S. ve Chaudhari, M., B., Detection of combined gear-bearing fault in single stage spur gear box using artificial neural network, 12th International Conference on Vibration Problems, Aralık 2015, Guwahati , Bildiriler Kitabı: 144, 759-766.
228. Xia, Z., Xia, S., Wan, L. ve Cai, S., Spectral regression based fault feature extraction for bearing accelerometer sensor signals, Sensors, 12,10 (2012) 13694-13719.
229. Liu, R., Yang, B., Zio, E. ve Chen, X., Artificial intelligence for fault diagnosis of rotating machinery: A review, Mechanical Systems and Signal Processing, 108 (2018) 33-47.
230. Chang, C., W., Lee, H., W. ve Liu, C., H., A Review of Artificial Intelligence Algorithms Used for Smart Machine Tools, Inventions, 3, 3 (2018) 41.
231. Nasiri, S., Khosravani, M., R. ve Weinberg, K., Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review, Engineering Failure Analysis, 81 (2017) 270-293.

232. Gonzalez, J., P., N., Castañon, L., E., G., Rabhi, A., El Hajjaji, A. ve Morales-Menendez, R., Vehicle Fault Detection and Diagnosis combining ANN and ANFIS, 7th IFAC Symposium on Fault Detection Supervision and Safety of Technical Processes, Haziran-Temmuz 2009, Barcelona, Bildiriler Kitabı: 42, 8, 1079-1084.
233. Chen, Z., Li, C. ve Sanchez, R., V., Gearbox fault identification and classification with convolutional neural Networks, Shock and Vibration, vol. 2015, Article ID 390134, (2015).
234. Sammut, C., ve Webb, G., I., Encyclopedia of machine learning and data mining, Springer, New York, 2017.
235. Ljung, L., System Identification Toolbox™ Getting Started Guide, The MathWorks Inc., Natick MA, 2019.
236. Zhao, F., Mei, X., Tao, T., Jiang, G. ve Zhou, Y., Fault diagnosis of a machine tool rotary axis based on a motor current test and the ensemble empirical mode decomposition method, Proc. IMechE, Part C: Journal of Mechanical Engineering Science, 225, 5 (2011) 1121–1129.
237. Dresig, H. ve Fidlin, A., Schwingungen mechanischer Antriebssysteme Modellbildung, Berechnung, Analyse, Springer-Verlag, Berlin, 2014.
238. Dresig, H., Schreiber, U. ve Rodionow, P., Stability analysis and simulation of the vibration behavior of worm gears in drive systems, ICMEM 2007, Kasım 2007, Wuxi, Bildiriler Kitabı: 24-28.
239. Tangirala, A., K., Principles of system identification: theory and practice, CRC Press, Boca Raton, 2014.
240. Esteves, M., S., A., System identification through ITSIE, University of Trás-os-Montes and Alto Douro, Vila Real, 2011.
241. Ljung, L., System Identification: Theory for the User, PTR Prentice Hall, New Jersey, 1999.
242. Ljung, L., System Identification Toolbox™ User's Guide, The MathWorks Inc., Natick MA, 2015.
243. Li, Y., Gu, J., X., Zhen, D., Xu, M. ve Ball, A., An Evaluation of Gearbox Condition Monitoring Using Infrared Thermal Images Applied with Convolutional Neural Networks, Sensors, 19, 9 (2019) 2205.
244. Barz, B., Denzler, J., Deep learning on small datasets without pre-training using cosine loss, The IEEE Winter Conference on Applications of Computer Vision, Mart 2020, Colorado, Bildiriler Kitabı: 1371-1380.

245. Dodge, S., Karam, L., Understanding how image quality affects deep neural Networks, Eighth international conference on quality of multimedia experience (QoMEX), Haziran 2016, Lisbon, Bildiriler Kitabı: 1-6.
246. Kannoja, S., P., Jaiswal, G., Effects of Varying Resolution on Performance of CNN based Image Classification: An Experimental Study, International Journal of Computer Sciences and Engineering, 6, 9 (2018) 451-56p.



ÖZGEÇMİŞ

Yunus Emre KARABACAK 31.08.1983 tarihinde Trabzon'un Akçaabat ilçesinde doğdu. İlk, orta ve lise öğrenimini Akçaabat'ta tamamladı. 2005 yılında K.T.Ü. Mühendislik Fakültesi, Makine Mühendisliği bölümünde lisans eğitimini, 2013 yılında ise K.T.Ü. Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalında yüksek lisans eğitimini tamamladı. 2006 yılında vatani görevini ifa edip bir müddet özel sektörde çalıştıktan sonra Çaykur Çay İşletmeleri Genel Müdürlüğüne Mühendis olarak atandı. Çaykur'a bağlı yaş çay işleme ve paketleme fabrikalarında 13 yıl boyunca Bakım Onarım Mühendisi olarak çalıştıktan sonra 2019 yılında Çaykur 100. Yıl Çay Paketleme Fabrikasına Kısım Müdürü olarak atandı. Halen bu görevine devam etmekte olup doktora çalışmalarını da sürdürmektedir. 3 adet SCI indeksli makalesi, 1 adet uluslararası konferans bildirisi, 1 adet ulusal konferans bildirisi ve 1 adet ulusal makalesi bulunan Yunus Emre KARABACAK İngilizce bilmektedir. Evli ve bir çocuk babasıdır.

Doktora tezi kapsamında 2 adet SCI makale, 1 adet uluslararası konferans bildirisi, 1 adet ulusal konferans bildirisi ve 1 adet ulusal makale üretilmiştir.

1. Karabacak, Y., E., Gürsel Özmen, N. ve Gümüşel, L., Worm gear condition monitoring and fault detection from thermal images via deep learning method, Maintenance and Reliability, 21, 3 (2020) 544–556. (SCI Exp.)
2. Karabacak, Y., E., Gürsel Özmen, N. ve Gümüşel, L., Artificial Intelligence Based Fault Detection and Classification on Worm Gears, International Journal of Precision Engineering and Manufacturing, (2020). (Hakem Inc.) (SCI Exp.)
3. Karabacak, Y., E., Gürsel Özmen, N. ve Gümüşel L., Sonsuz Vidalı Redüktörlerin Kestirimci ve Önleyici Bakım Çalışmalarına Yönelik Geliştirilmiş Bir Deney Düzenegi, International Conference on Artificial Intelligence and Applied Mathematics in Engineering, Antalya, Nisan 2019, Bildiriler Kitabı: 25-35.
4. Karabacak, Y., E., Kahraman H., T., Gümüşel L. ve Yılmaz, C., Rulmanlarda Bilezik Arızalarının Yapay Sinir Ağları ile Tespiti ve Sınıflandırılması, ASYU 2017, Antalya, Ekim 2017, Bildiriler Kitabı: 29.

5. Karabacak, Y., E., Kahraman H., T., GümüŖel L. ve Yılmaz, C., Rulmanlarda Bilezik Arızalarının Yapay Sinir Ağları ile Tespiti ve Sınıflandırılması, Akıllı Sistemler ve Uygulamaları Dergisi, 1, 1 (2018) 31-35.

