

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ASENKRON MOTOR RULMAN HATALARININ UZUN-KISA SÜRELİ BELLEK
TİPİ DERİN SİNİR AĐLARI İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

RUMEYSA HACER KILIÇ

TEZ DANIŐMANI
DOÇ. DR. EMRE DANDIL

BİLECİK, 2022

10457383

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ASENKRON MOTOR RULMAN HATALARININ UZUN-KISA SÜRELİ BELLEK
TİPİ DERİN SİNİR AĐLARI İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

RUMEYSA HACER KILIÇ

TEZ DANIŐMANI
DOĐ. DR. EMRE DANDIL

BİLECİK, 2022

10457383

BILECIK SEYH EDEBALI UNIVERSITY
INSTITUTE OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

**CLASSIFICATION OF INDUCTION MOTOR BEARING FAULTS USING LONG-
SHORT TERM MEMORY DEEP NEURAL NETWORKS**

MASTER'S THESIS

RUMEYSA HACER KILIÇ

THESIS ADVISOR
ASSOC. PROF. DR. EMRE DANDIL

BILECIK, 2022

10457383

BEYAN

Asenkron Motor Rulman Hatalarının Uzun-Kısa Süreli Bellek Tipi Derin Sinir Ağları ile Sınıflandırılması adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR	<input type="checkbox"/>	DESTEK ALINMAMIŞTIR	<input checked="" type="checkbox"/>
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

Rumeysa Hacer KILIÇ

11.04.2022

İmza

ÖN SÖZ

Bu tez çalışmasının her adımında, bilgi birikimleriyle yol gösteren ve manevi desteğini esirgemeyen danışmanım ve değerli öğretmenim Sayın Doç. Dr. Emre DANDIL'a değerli katkıları için teşekkürlerimi ve saygılarımı sunarım.

Tez yazım aşamasında ve tüm hayatım boyunca beni destekleyen ve yanımda olan aileme teşekkürlerimi sunarım.

Son olarak tez çalışmasında kullanılan verilerinin yer aldığı Case Western Reserve University (CWRU) veriseti ve Mendeley Rulman Titreşim verisetinin oluşturulmasında ve paylaşılmasında emeği geçen tüm bilim adamlarına teşekkürlerimi sunarım.

Rumeysa Hacer KILIÇ

11.04.2022

İmza

ÖZET

ASENKRON MOTOR RULMAN HATALARININ UZUN-KISA SÜRELİ BELLEK TİPİ DERİN SINIR AĞLARI İLE SINIFLANDIRILMASI

Asenkron motorlar güvenilir, hesaplı ve dayanıklı olmaları nedeniyle endüstride yaygın olarak tercih edilmektedir. Asenkron motorların rulman bileşenlerinin iç bilezik, bilye ve dış bilezik bölgelerinde sıklıkla hatalar meydana gelmektedir. Bu sebepten ötürü, asenkron motorlarının verimini arttırmak için rulman hatalarının önceden tespiti ve sınıflandırılması oldukça önemlidir. Bu tez çalışmasında, Case Western Reserve University (CWRU) rulman veriseti ile Mendeley Rulman Titreşim verisetindeki titreşim verileri kullanılarak, asenkron motor rulmanlarının iç bilezik, dış bilezik ve bilye bölgelerinde oluşan hatalarının otomatik sınıflandırılması için iki yönlü uzun-kısa süreli bellek tipi (IY-UKSB) tipi derin sinir ağlarına dayalı bir yöntem önerilmektedir. Tez kapsamında verisetleri üzerinde yürütülen deneysel analizlerde, sağlıklı (normal) ve sağlıklı olmayan (hatalı) rulmanlara ait titreşim verileri 128, 256, 512 ve 1024 gibi farklı boyutlarda pencerelere ayrılarak, anlık frekans ve spektral entropi gibi çeşitli özellik çıkarımı yöntemleri sonucunda elde edilen veriler ile önerilen IY-UKSB ağının performansı değerlendirilmiştir. Çalışmada normal ve hatalı rulman verilerinden hazırlanan veriseti üzerinde farklı pencere genişliklerinde test kümesi üzerinde IY-UKSB ağının doğruluğunun CWRU verisetinde ortalama %60 civarında kaldığı, Mendeley Rulman Titreşim verisetinde ise ortalama %75 civarında olduğu hesaplanmıştır. Normal ve hatalı rulman verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının ortalama doğruluğunun CWRU verisetinde ortalama %95'in üzerine, Mendeley Rulman Titreşim verisetinde ise %99'un üzerinde olduğu görülmüştür. Sonuç olarak, önerilen IY-UKSB ağının normal ve hatalı rulman titreşim verilerinin ayrımı için güçlü bir sınıflandırıcı olduğu değerlendirilmiştir. Çalışmanın diğer adımında hatalı verilerin konumunun sınıflandırılması ve hata büyüklüğünün sınıflandırılması da sağlanmıştır. Yapılan deneysel çalışmalarda özellik çıkarımı uygulanan IY-UKSB ile iki farklı veriseti üzerinde asenkron motor rulman hatalarının sınıflandırılmasında, yüksek performans elde edildiği doğrulanmıştır.

Anahtar Kelimeler: Asenkron motor, Rulman hataları, Sınıflandırma, Derin öğrenme, İki yönlü uzun-kısa süreli bellek (IY-UKSB).

ABSTRACT

CLASSIFICATION OF INDUCTION MOTOR BEARING FAULTS USING LONG-SHORT TERM MEMORY DEEP NEURAL NETWORKS

Induction motors are widely preferred in the industry because they are reliable, economical and durable. The various faults often occur in the inner ring, ball and outer ring regions of the bearing components of induction motors. Therefore, it is very important to detect bearing faults at an early stage in order to increase the efficiency of operation of induction motors. In this thesis, using Case Western Reserve University (CWRU) bearing dataset and Mendeley bearing vibration dataset, bi-directional long-short-term memory type (Bi-LSTM) deep neural networks are proposed for automatic classification of faults in the inner race, outer race and ball regions of induction motor bearings on vibration data. In the study, the performance of the proposed Bi-LSTM network is evaluated as a result of feature extraction using instantaneous frequency and spectral entropy, by dividing the vibration data of normal bearing and faulty bearing into windows of different sizes such as 128, 256, 512 and 1024. In the study, it is achieved that the accuracy of the Bi-LSTM network on the test set with different window widths on the dataset prepared from normal and faulty bearing data is around 60% on average in the CWRU dataset, while it is around 75% on the Mendeley Bearing Vibration dataset. In the classification of normal and faulty bearing data, the average accuracy of the Bi-LSTM network after feature extraction with instantaneous frequency and spectral entropy is obtained to be above 95% in the CWRU dataset and over 99% in the Mendeley Bearing Vibration dataset. As a result, the proposed Bi-LSTM network is considered to be a powerful classifier for the separation of faulty and normal bearing vibration data in induction motors. In the latter step of the study, classification of the location of the faulty data and classification of the fault size experiments are carried out. In the experimental studies, it has been confirmed that high performance is obtained in the classification of induction motor bearing errors on two different datasets with Bi-LSTM, where feature extraction is applied.

Keywords: Induction motor, Bearing faults, Classification, Deep learning, Bi-directional long-short-term memory (Bi-LSTM).

İÇİNDEKİLER

Sayfa

ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vii
SİMGELER VE KISALTMALAR LİSTESİ	x
1. GİRİŞ	1
1.1. Literatür Taraması.....	2
1.2. Tezin Genel Organizasyonu.....	6
1.3. Araştırma Sorusu ve Hipotez	6
2. ASENKRON MOTORLAR.....	8
2.1. Asenkron Motorlar.....	8
2.2. Rulman	9
2.3. Asenkron Motor Arızaları ve Tespiti.....	11
3. MATERYAL VE YÖNTEM.....	13
3.1. Case Western Reserve Üniversitesi Deney Düzeneği ve Veriseti	13
3.2. Mendeley Deney Düzeneği ve Rulman Titreşim Veriseti.....	17
3.3. İki Yönlü-Uzun Kısa Süreli Bellek (IY-UKSB)	19
3.4. Pencereleme Yöntemi	21
3.5. Özellik Çıkarımı	26
3.5.1.Spektrogram.....	26
3.5.2.Spektral Entropi	26
3.5.3.Anlık Frekans.....	27
4. DENEYSEL ÇALIŞMALAR.....	29
4.1. Case Western Reserve Üniversitesi Veriseti ile Yapılan Deneyler.....	31
4.1.1.Normal ve Hatalı Verinin Sınıflandırılması.....	32
4.1.2.Hata Konumuna Göre Sınıflandırma	35
4.1.3.Hata Büyüklüğüne Göre Sınıflandırma	39
4.2. Mendeley Rulman Titreşim Veriseti ile Yapılan Deneyler	48
5. TARTIŞMA	53
6. SONUÇ.....	59
KAYNAKÇA	60

TABLolar LİSTESİ

Sayfa

Tablo 3.1. CWRU rulman verisetinde deneysel çalışmalar için kullanılan üç fazlı asenkron motorun özellikleri	14
Tablo 3.2. Normal çalışan asenkron motordan alınan verilerin dağılımı	15
Tablo 3.3. 12K sürücü sonu hatalı rulman titreşim verilerinin dağılımı	16
Tablo 3.4. 12K fan sonu hatalı rulman titreşim verilerinin dağılımı	16
Tablo 3.5. Mendeley rulman titreşim verisetinin çalışma koşulları ve isimlendirilmesi.....	19
Tablo 4.1. Sağlıklı ve hatalı çalışan asenkron motor sınıflandırma performansı	34
Tablo 4.2. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı.....	37
Tablo 4.3. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken iç bilezik ve dış bilezik (@6:00) konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı	38
Tablo 4.4. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken bilye ve dış bilezik (@6:00) konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı	38
Tablo 4.5. 12K sürücü sonu yük 1 değerinde hata 0.028“ büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı.....	39
Tablo 4.6. 12K Sürücü sonu, bilye konumunda yük 1 için 0.007“ ve 0.014“ hata büyüklükleri için özellik çıkarımı öncesi ve sonrası verilerin sınıflandırılma performansı.....	41
Tablo 4.7. 12K Sürücü sonu, iç bilezik konumunda yük 1 için 0.007” ve 0.014” hata büyüklükleri için sınıflandırma performansı.....	42
Tablo 4.8. 12K Sürücü sonu, dış bilezik (@6:00) konumunda yük bir değerinde 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı	43
Tablo 4.9. 12K Sürücü sonu, bilye konumunda yük 1 değerindeyken 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma performansı.....	43

Tablo 4.10. 12K Sürücü sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma performansı	44
Tablo 4.11. 12K Fan sonu, bilye konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı.....	45
Tablo 4.12. 12K Fan sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı.....	45
Tablo 4.13. 12K Fan sonu, dış bilezik (@3:00) konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı	46
Tablo 4.14. 12K Fan sonu, bilye konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı.....	47
Tablo 4.15. 12K Fan sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı.....	47
Tablo 4.16. 12K Fan sonu, dış bilezik (@3:00) konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı	48
Tablo 4.17. Normal çalışan rulman ve iç bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı.....	50
Tablo 4.18. Normal çalışan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı.....	51
Tablo 4.19. İç bilezik hatası bulunan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı.....	51

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Standart bir asenkron motor ve bileşenleri	9
Şekil 2.2. Rulmanın yapısı	10
Şekil 2.3. Rulman hata çeşitleri	12
Şekil 3.1. CWRU verisetinde rulman titreşim verilerinin alındığı tümleşik deney düzeneği..	14
Şekil 3.2. Mendeley deney düzeneği.....	18
Şekil 3.3. UKSB ağlarında genel hücre yapısı.....	20
Şekil 3.4. İki yönlü UKSB (IY-UKSB) katman yapısı	21
Şekil 3.5. 1024'lük pencere ile bölünecek verilerin etiket sayıları	22
Şekil 3.6. 1024'lük pencere ile bölünen verilerin sinyal görüntüleri.....	22
Şekil 3.7. 512'lik pencere ile bölünecek verilerin etiket sayıları.....	23
Şekil 3.8. 512'lik pencere ile bölünen verilerin sinyal görüntüleri.....	23
Şekil 3.9. 256'lık pencere ile bölünecek verilerin etiket sayıları.....	24
Şekil 3.10. 256'lık pencere ile bölünen verilerin sinyal görüntüleri.....	24
Şekil 3.11. 128'lik pencere ile bölünen verilerin sinyal görüntüleri.....	25
Şekil 3.12. 128'lik pencere ile bölünen verilerin sinyal görüntüleri.....	25
Şekil 3.13. Hatalı ve hatasız rulman titreşim verilerinin spektrogram analizi.....	26
Şekil 3.14. İç bilezik ve bilyeden alınan rulman titreşim verilerinin spektral entropisi	27
Şekil 3.15. İç bilezik ve bilyeden alınan rulman titreşim verilerinin anlık frekans özelliği	28
Şekil 4.1. Tez çalışmasında uygulanan yöntemin adımları.....	30
Şekil 4.2. Tez kapsamında yürütülen deneysel çalışmaların adımları	32
Şekil 4.3. (a) Normal rulman verileri ve (b) hatalı rulmana ait iç bilezikten alınan 512 pencere genişliğinde titreşim sinyalleri	33
Şekil 4.4. Özellik çıkarımından önce doğruluk ve kayıp grafiği	33

Şekil 4.5. 1024 pencere boyutunda normal ve hatalı rulman verilerinin sınıflandırılması için oluşturulan IY-UKSB ağının eğitim aşamasında elde edilen doğruluk ve yaklaşık kayıp grafikleri	34
Şekil 4.6. (a) İç bilezik hatalı rulman verileri ve (b) Bilye hatalı rulmana ait iç 256'lık pencere genişliğinde titreşim sinyalleri	35
Şekil 4.7. Özellik çıkarımından önce IY-UKSB doğruluk ve kayıp değerleri.....	36
Şekil 4.8. Özellik çıkarımından sonra IY-UKSB doğruluk ve kayıp değerleri	36
Şekil 4.9. (a) 0.007“ hatalı rulman verileri ve (b) 0.014“ hatalı rulmana ait iç 256'lık pencere genişliğinde yük 2 durumunda iken iç bilezikten alınan titreşim sinyalleri.....	40
Şekil 4.10. Özellik çıkarımından önce IY-UKSB doğruluk ve kayıp değerleri.....	40
Şekil 4.11. Özellik çıkarımından sonra IY-UKSB doğruluk ve kayıp değerleri	41
Şekil 4.12. (a) Normal rulman verileri ve (b) İç bilezik hatalı rulmana ait 1024'lük pencere genişliğinde iken alınan titreşim sinyalleri.....	49
Şekil 4.13. Özellik çıkarımından önce IY-UKSB doğruluk ve kayıp değerleri.....	49
Şekil 4.14. Özellik çıkarımından sonra IY-UKSB doğruluk ve kayıp değerleri	50

GRAFİKLER LİSTESİ

	Sayfa
Grafik 5.1. Hata konumuna göre sınıflandırma doğruluk değerleri.....	53
Grafik 5.2. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri.....	54
Grafik 5.3. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri.....	54
Grafik 5.4. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri.....	55
Grafik 5.5. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri.....	56
Grafik 5.6. Hata büyüklüğüne göre sonuçların karşılaştırılması.....	56
Grafik 5.7. Hata büyüklüğüne göre sonuçların karşılaştırılması.....	57
Grafik 5.8. Hata konumuna göre sınıflandırma doğruluk değerleri.....	58

SİMGELER VE KISALTMALAR LİSTESİ

σ	:	Sigma
AC	:	Alternatif Akım (Alternating current)
CWRU	:	Case Western Reserve Üniversitesi (Case Western Reserve University)
DG	:	Doğruluk
DY	:	Duyarlılık
DN	:	Doğru Negatif
DP	:	Doğru Pozitif
DVM	:	Destek Vektör Makinesi
ESA	:	Evrşimsel Sinir Ağları
f_t	:	UKSB Ağında Unutma Kapısının Çıktısı
g_t	:	UKSB Ağında Güncelleme Hücresinin Çıktısı
HSV	:	Ton, Doygunluk ve Değer (Hue, Saturation and Value)
Hp	:	Beygir Gücü (Horse Power)
h_t	:	UKSB Ağında Bir Şimdiki Zaman Adımının Gizlilik Durumu
h_{t1}	:	UKSB Ağında Bir Birinci Zaman Adımının Gizlilik Durumu
h_{t2}	:	UKSB Ağında Bir İkinci Zaman Adımının Gizlilik Durumu
h_{t3}	:	UKSB Ağında Bir Üçüncü Zaman Adımının Gizlilik Durumu
h_{t4}	:	UKSB Ağında Bir Dördüncü Zaman Adımının Gizlilik Durumu
h_{t-1}	:	UKSB Ağında Bir Önceki Zaman Adımının Gizlilik Durumu
i_t	:	UKSB Ağında Giriş Kapısının Çıktısı
K	:	Saniyede 1000 devir
k-NN	:	K-En Yakın Komşu (K-Nearest Neighbor)
LSTM	:	Uzun Kısa Süreli Bellek (Long Short Term Memory – LSTM)
mm	:	Mili Metre
o_t	:	UKSB Ağında Çıkış Kapısının Çıktısı
RNN	:	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
SC	:	Seçicilik
t	:	UKSB Ağında Şimdiki Zaman Adımı
$t - 1$:	UKSB Ağında Bir Önceki Zaman Adımı
\tanh	:	Hiperbolik Tanjant
UKSB	:	Uzun Kısa Süreli Bellek
IY-UKSB	:	İki Yönlü Uzun Kısa Süreli Bellek (Bi-directional Long Short Term Memory – Bi-LSTM)

x_t	:	UKSB Ağında Şimdiki Zaman Adımının Girdisi
x_{t1}	:	UKSB Ağında Birinci Zaman Adımının Girdisi
x_{t2}	:	UKSB Ağında İkinci Zaman Adımının Girdisi
x_{t3}	:	UKSB Ağında Üçüncü Zaman Adımının Girdisi
x_{t4}	:	UKSB Ağında Dördüncü Zaman Adımının Girdisi
y_t	:	UKSB Ağında Şimdiki Zaman Adımının Çıktısı
y_{t1}	:	UKSB Ağında Birinci Zaman Adımının Çıktısı
y_{t2}	:	UKSB Ağında İkinci Zaman Adımının Çıktısı
y_{t3}	:	UKSB Ağında Üçüncü Zaman Adımının Çıktısı
y_{t4}	:	UKSB Ağında Dördüncü Zaman Adımının Çıktısı
YN	:	Yanlış Negatif
YP	:	Yanlış Pozitif
YSA	:	Yapay Sinir Ağları
”	:	İnç (2.54 cm uzunluğundaki uzunluk ölçüsü birimi)
°	:	Derece
@	:	Saat konumu

1. GİRİŞ

Asenkron motorlar günlük hayatta ve endüstride yaygın olarak kullanılmaktadır (Kılıç & Dandıl, 2021:509). Asenkron motorlarda dayanıklılık, etkin performans ve güvenilirlik asenkron motorlarda olması beklenen önemli unsurlardır (Benbouzid, 1999:1066; Zarei, 2012:151). Asenkron motorlar oldukça güvenilir ve uzun ömürlü olmalarına karşın, çalışmasını önemli derecede etkileyecek bazı hatalara da maruz kalabilmektedirler. Bundan dolayı, bu motorlar yaygın olarak kullanıldığından, oluşabilecek hataların önceden öngörülmesi ve gerekli önlemlerin alınması önemli hale gelmektedir (Kılıç & Dandıl, 2021:509). Asenkron motorlarda oluşan hatalar sıklıkla titreşim sinyallerinden tespit edilmekle birlikte, akım gibi farklı sinyaller de asenkron motorlarda meydana gelen hataların belirlenmesinde kullanılabilir (Benbouzid & Kliman, 2003:238). Asenkron motorlarda meydana gelen hatalar elektriksel veya mekanik olabilmektedir. Elektriksel hatalar çoğunlukla rotorda ve statorda meydana gelirken, mekanik hatalar ise çoğunlukla rulmanlarda ortaya çıkmaktadır. Bunun yanında, rulman hatalarının asenkron motorlarda oransal olarak en fazla karşılaşılan hata türü olduğu görülmektedir (Toma vd., 2020:1; Yeh vd., 2008:1005).

Rulmanlar asenkron motorların hareketli ve bilyeli elemanları olup; iç bilezik, dış bilezik ve kafes bileşenlerinden oluşur ve rotor ve mili desteği ile serbest dönme hareketi meydana getirir (Çalış vd., 2013:1). Ayrıca, rulmanlar asenkron motorlarda sürtünmeyi azaltarak makinenin çalışma performansını arttırmaktadır. Asenkron motor rulmanlarında meydana gelen hatalar endüstride çoğunlukla üretim kalitesini etkileyebilmektedir. . Asenkron motorlarda yaygın olan mekanik rulman hatalarına sürtünme, motor-yük dengesizliği, uygun olmayan yağlanma gibi başlıca nedenleri bulunmaktadır (Kılıç & Dandıl, 2021:509). Bu tip hatalardan dolayı, asenkron motor gereğinden fazla ısınır güç sarfiyatını arttırmaktadır ve asenkron motorda oluşan titreşim nedeniyle motorun performansı düşmektedir (Ünsal & Karakaya, 2015:70). Buna ek olarak, rulmanlarda oluşabilecek arızalar, asenkron motorda sürekli olarak rezonans meydana gelmesine de neden olabilmektedir. Bundan dolayı, rulmanlarda oluşacak hataların ilk evrelerde tespiti oldukça önemlidir.

Bu tez çalışmasında, asenkron motorlara ait rulman bileşeninin iç bilezik, dış bilezik ve bilye bölgelerinde meydana gelen hataların otomatik sınıflandırılması için, Case Western Reserve University (CWRU) rulman veriseti (CWRU, 2021) ve Mendeley Rulman Rulman Titreşim verisetindeki (Mendeley Data, 2021) rulman titreşim verilerinden yararlanarak, İY-UKSB (İki yönlü uzun kısa süreli bellek) tipi derin sinir ağları tabanlı bir yöntem önerilmektedir. Tez çalışması kapsamında, öncelikle verisetlerindeki normal rulmana ait

titreşim verileri ile farklı boyutlar ve yüklerdeki rulman hataları için iç bilezik, dış bilezik ve bilyeye ait titreşim verileri farklı büyüklüklerde (128, 256, 512 ve 1024) pencereleme ayrılmıştır. Ardından, eğitim ve test olmak üzere iki gruba ayrılan titreşim verilerinden anlık frekans ve spektral entropi ile özellik çıkarımı yapılarak deneysel analizler organize edilmiştir. Son aşamada ise, elde edilen bu özellikler yardımıyla IY-UKSB mimarisi kullanılarak normal ve hatalı rulman titreşim verilerinin yüksek doğruluk ile sınıflandırılması sağlanmıştır.

1.1. Literatür Taraması

Asenkron motorlarda karşılaşılabilecek rulman hatalarının önceden belirlenebilmesi için literatürde birçok çalışma bulunmaktadır. Yapılan çalışmalarda, Mendel ve arkadaşları (Mendel vd., 2009:1602) rulmanlarda oluşabilecek hataları frekans analizi yöntemiyle belirlemişlerdir. Silindirik masuralı rulman hatasını Yeşilyurt ve Özdemir (Yeşilyurt & Özdemir, 2015:1) kısa zamanlı fourier dönüşümü kullanarak belirlemişlerdir. Farklı bir çalışmada ise, Kompella ve arkadaşları (Kompella vd., 2016:411) rulman hatalarının belirlenmesinde dalgacık dönüşümü ve gürültü giderimi tabanlı bir yöntem kullanmışlardır. Demir ve Müştak (Demir & Müştak, 2021:571) ise çalışmalarında, rulman hatalarını titreşim ve gürültü analizi ile tespit etmeyi önermişlerdir. Çalışmalarında, titreşim ve gürültü verileri, zaman ve frekans düzleminde incelenerek, Hilbert dönüşümü ile zarf analizi yapılmış ve rulman hatalarının tespiti sağlanmıştır.

Geleneksel makine öğrenmesi yöntemleri ile de asenkron motorlarda oluşan rulman hatalarının tespiti için önerilen çalışmalar bulunmaktadır (Kılıç & Dandıl, 2021:509). Hatalı çalışan rulman verilerinin belirlenmesi için Konar ve Chattopadhyay (Konar & Chattopadhyay, 2011:4203) çalışmalarında dalgacık dönüşümü ve destek vektör makinası (DVM) ile bir yaklaşım önermişlerdir. Benzer olarak bir diğer çalışmada ise, rulmanlarda meydana gelen hatanın boyutunu Bayram ve arkadaşları (Bayram vd., 2013:986) yaptıkları çalışmalarında yapay sinir ağı (YSA) modeli kullanarak tespit etmişlerdir. Çalışmada geliştirilen YSA yaklaşımında, veriler belirli ağırlıklarla çarpılıp giriş verisi olarak kullanılmıştır ve farklı boyutlardaki rulman hataları sınıflandırılmıştır. Ayrıca gerçek hata değerini ortalama %2'lik hata oranı ile belirlendiğini gözlemlemişlerdir. Bir diğer çalışmada, sağlıklı çalışan rulmana ait titreşim verilerini Çalış ve arkadaşları (Çalış vd., 2013:1) zaman ve frekans düzlemindeki genlik değerlerinin analizi ile yapay bağışıklık sistemleri kullanarak hatanın yüzde değeri ve seviyesini belirlemişlerdir. Ayrıca titreşim verisinde hangi zaman aralığında hata olduğunu gözlemlemişlerdir. Amar ve arkadaşları (Amar vd., 2014:494)

yaptıkları çalışmalarında, yapay sinir ağı kullanarak titreşim spektrumu görüntülemişlerdir. Bu spektrum ile rulman hatası sınıflandırma yaklaşımını geliştirmişlerdir. Yaptıkları çalışmada titreşim spektrumu görüntüleme biçiminde karakteristik titreşimin spektral özelliklerinin görsel temsili güçlendirilerek bir hata sınıflandırıcı önerilmiştir. Asenkron motor rulman hatalarının sınıflandırılması için yapay sinir ağı tabanlı önerilen bir başka çalışmada, Zarei ve arkadaşları (Zarei vd., 2014:151) akıllı bir filtre kullanarak rulman hata tespiti ve YSA ile sınıflandırılması için titreşim analizi yapmışlardır. Titreşim sinyallerini doğrudan kullanmak yerine, filtrelenmiş titreşim sinyalinin bileşeni kullanıldığında daha iyi sonuçlar elde edildiğini gözlemlemişlerdir. Sürücünden beslenen asenkron motordaki sağlıklı çalışan rulmanın tespit edilmesi akım işaret analiziyle yapay sinir ağı modeli Akkurt ve Arabacı (Akkurt & Arabacı, 2019:122) tarafından kullanılmıştır ve çalışmalarında hatalı çalışan rulmanları başarılı bir şekilde sınıflandırmışlardır. Titreşim sinyali kullanarak Hwang ve arkadaşları (Hwang vd., 2015:1558) yaptıkları çalışmalarında, asenkron motorlar için DVM tabanlı rulman hatası belirleme yöntemi önermişlerdir. Önerilen yöntemde titreşim sinyallerinden arıza ile ilgili frekansların harmoniklerini arıza indeksleri olarak işleyen DVM (destek vektör makinesi) kullanarak sınıflandırma yapıldığında hata tespiti doğruluğunun yükseldiğini göstermişlerdir. Yapılan farklı bir çalışmada, sağlıklı çalışan rulman verilerinin tespiti için Toma ve arkadaşları (Toma vd., 2020:1884) genetik algoritma ve makine öğrenimli sınıflandırıcı önermişlerdir. Çalışmada, öncelikle istatistiksel özellikler motor akım verilerinden çıkarılmıştır. Ardından, genetik algoritma ile öznelik sayısını azaltılmış ve öznelik veritabanından en önemli özellikler seçilmiştir. Çalışmada, ayrıca rulman hatalarının sınıflandırılması için k-en yakın komşu algoritması (k-NN), karar ağacı ve rastgele orman yöntemleri seçilen özellikler kullanılarak eğitilmişlerdir. Deneysel çalışmalarda, üç sınıflandırma yöntemi ile oluşturulan melez kombinasyonun, sınıflandırma doğruluğunu arttırdığı ve karmaşıklığı azalttığı raporlanmıştır.

Asenkron motorlarda meydana gelen rulman hatalarının belirlenmesinde, görüntü işleme tekniklerinden de faydalanılmıştır. Al-Musawi ve arkadaşları (Al-Musawi vd., 2020:1) çalışmalarında, termal görüntü bölütlemesi yapmışlardır. Üç fazlı asenkron motorlarda iç bilezik, dış bilezik ve bilye konumlarındaki sağlıklı çalışan rulmanları belirlemişlerdir. Çalışmalarında görüntü bölütlemesine dayalı önerilen HSV (ton (hue), doygunluk (saturation) ve değer (value)) renk modelinin motor arızalarını doğru bir şekilde belirleyebildiğini göstermişlerdir.

Son yıllarda, güncel derin öğrenme tabanlı yaklaşımları da asenkron motor rulman hatalarının tespitinde kullanılmaktadır (Kılıç & Dandıl, 2021:509). Yaptıkları çalışmada Eren ve arkadaşları (Eren vd., 2019:179) asenkron motor rulman hatalarının belirlenmesinde evrimsel sinir ağları (ESA) mimarisini kullanmışlardır. Motor akım analizi kullanarak yaptıkları çalışmalarında Immovilli ve arkadaşları (Immovilli vd., 2019:452) uzun-kısa süreli bellek (UKSB) tipi sinir ağları ile rulman hatalarını belirlemişlerdir. Hibrit sistem geliştirerek rulman hatalarını belirleyen çalışmalarında, Jalayer ve arkadaşları (Jalayer vd., 2021:1) UKSB tipi sinir ağları, hızlı Fourier dönüşümü ve dalgacık dönüşümü yöntemlerini kullanmışlardır. Chen ve arkadaşları (Chen vd., 2021:971) yaptıkları çalışmalarında, ESA ve UKSB ile rulman asenkron motor hatalarının tespitini gerçekleştirmişlerdir.

Tek boyutlu, üçlü desenlerle yatak hatası sınıflandırması çalışmasında Kuncan ve arkadaşları (Kuncan, vd., 2019:346) yeni bir özellik çıkarımı yöntemi önerilmişlerdir. Yaptıkları çalışmada titreşim sinyali üzerindeki her bir değer için komşuları arasındaki karşılaştırılmalarından elde edilen kalıplar kullanılarak istatistiksel bir yaklaşım önermişlerdir. Arızanın hangi yataktan (iç bilezik, dış bilezik ve bilye) kaynaklandığını ve arızanın boyutunu (mm) belirlemeyi amaçlamışlardır. Rastgele Orman (Random Forest), k-NN, DVM, BayesNet ve YSA modelleri ile üçlü desenler kullanarak çeşitli sınıflandırma teknikleri kullanmışlardır. Kullanılan üç farklı verisetinde yüksek doğruluk başarımına ulaşmışlardır.

Bir hatta bağlı üç fazlı asenkron motorlardaki arızanın belirlenmesi için yapılan çalışmada Palácios ve arkadaşları (Palácios vd., 2016:1) çok etmenli yeni bir yaklaşım önermişlerdir. Yaptıkları çalışmada gözlemlenen arızalar; hatalı yataklar, sincap kafesli rotorlu çubuklarında kırılmalar ve stator sargı bobinleri arasındaki kısa devre ile ilgilidir. Akım sinyallerinin zaman alanındaki genliklerinin analiz ederek üç fazlı asenkron motorlar için çeşitli sinüzoidal güç ve mekanik yük koşulları altında farklı desen sınıflandırma yöntemleri kullanarak deneysel sonuçlar elde etmişlerdir. Önerdikleri bu yöntemle 1Hp ve 2Hp gücündeki motorlarla değerlendirilen durumlarda etkinliğini kanıtlayarak üç fazlı asenkron motorlarda rulman arıza tespiti için alternatif bir araç sağlamışlardır.

Çok sensörlü ve sınırlı veri durumunda asenkron motorlarda makine tabanlı arıza tespiti çalışmasında Gansgar ve arkadaşları (Gansgar vd., 2019:694) DVM kullanmışlardır. Öncelikle deneysel kurulumla akım ve titreşim verileri kaydedilmiştir. Bir dizi hata özelliği çıkarılmıştır. Çıkarılan özellikler Destek vektör makineleri ile işlenmiştir ve hata tespiti yapılmıştır. Sınırlı veri ile çalışılması gerektiğinde destek vektör makinelerinde yararlanılarak

geliştirilen bu çalışmada aynı hız ve yük durumunda performansın yüksek olduğu ara yük durumunda ve ara hız durumunda sonuçların cesaret verici olduğu gözlemlenmiştir.

Rulman arıza teşhisi için yerel ikili örüntü (LBP, local binary patterns) ile doku analizi çalışmasında Kaplan ve arkadaşları (Kaplan vd., 2020:1) yeni bir özellik çıkarımı önermişlerdir. Bu çalışmada yatak titreşim sinyalinin teşhisi için doku analizine dayalı yaklaşımda önerilmiştir. Yatak titreşim verileri ilk olarak gri tonlamalı görüntülere dönüştürülmüştür. Bu görüntüler kullanılarak LBP ve doku özellikleri tespit edilmiştir. Bu özellikler kullanılarak farklı makine öğrenme modelleri ile yatak titreşim sinyalleri sınıflandırılmıştır. Önerilen yaklaşımı test etmek için üç farklı veri seti kullanılmıştır.

Bulanık mantık, YSA ve genetik algoritma kullanılarak motor arıza yöntemleri hakkında yürütülen bir çalışmada Gao ve Osaka (Gao & Osaka, 2001:80) bu yöntemlerin avantaj ve dezavantajlarından bahsetmişlerdir. Bahsedilen yöntemlerin birlikte kullanıldığında daha net sonuçlar verdiğine değinmişlerdir.

Spektral baskınlık ve aşırı öğrenme makinesi ile motive edilen dönel makine arıza sınıflandırması çalışmasında Udmale ve arkadaşları (Udmale vd., 2019:1) geliştirdikleri sistemi iki veri seti üzerinde test etmişlerdir. Deneysel sonuçlar ve önerilen yöntem ile kompakt bir aşırı öğrenme makine mimarisi sağlamak için, aşırı öğrenme makine parametrelerini verimli bir şekilde optimize ettiğini ve hata sınıflandırma doğruluğunu geliştirdiğini gözlemlemişlerdir.

Rulman arızalarının makine öğrenmesi teknikleri ile sınıflandırılması çalışmasında Dükkancı (Dükkancı, 2019:44) akustik sinyal analizi ve çeşitli makine öğrenme teknikleri kullanılmıştır. Deney düzeneğinde AC (alternatif akım) motor 90° faz farkı ile stereo kayıt yapabilen bir kayıt cihazı kullanmışlardır. Bilyeler üzerinde yapay olarak arızalar oluşturulmuştur. Veri seti toplamak için deney düzeneği hatalı bilyelerin olduğu motorun akustik verileri kaydedilmiştir. MATLAB programı ile geliştirilen yazılımda hızlı fourier dönüşümü akustik verilerin zaman düzleminde frekans düzlemine dönüşümü gerçekleştirilmiştir. Frekans düzlemindeki verilere özellik çıkarımı uygulanmıştır. Elde ettikleri verilere makine öğrenmesi tekniği uygulayarak sınıflandırmayı gerçekleştirmişlerdir.

Bilyeli rulmanların neden olduğu titreşimin modellenmesi çalışmasında Arslan ve arkadaşları (Arslan vd., 2003:123) kütle-yay sistemi şaft-bilye modeli olarak kullanılmıştır. Bilye ve şaftın denklemleri elde edilmiş ve be denklemler radyal ve aksenal yönde çözülmüştür. Simülasyon programı kullanarak şaft ve bilye için elde edilen sonuçlar zaman ve

frekans düzleminde incelenmiştir. İç bilezik, dış bilezik ve bilye hatalarının titreşim üzerine etkisi simülasyon programı yardımıyla incelenmiştir. Hatalı ve hatasız durumdaki rulmanlar için elde edilen şaft ve bilye spektrumu kullanılarak hatanın türünü ve yerini tespit etmişlerdir.

Asenkron motorlarda rulman hatasının sınıflandırılması için ayırık dalgacık dönüşümü ve toplu makine öğrenmesi kullanılması çalışmasında Toma ve arkadaşları (Toma vd., 2020:18) öznelik çıkarımı yapılmıştır. Sınıflandırma için toplu makine öğrenme algoritması kullanılmıştır. Önerdikleri yöntemde yüksek doğruluk elde etmişlerdir.

1.2. Tezin Genel Organizasyonu

Bu tez çalışmasında, asenkron motorlarda karşılaşılan rulman hatalarının tespit edilmesi, hataların konumunun ve hata büyüklüğünün sınıflandırılması derin sinir ağları yöntemlerinden biri olan IY-UKSB kullanarak gerçekleştirilmiştir. Ayrıca, ağ performansı çeşitli özellik çıkarımı yöntemleri ile güçlendirilerek iki farklı deneysel veriseti üzerinde çalışmalar yapılmıştır.

Tez çalışmasının ilk bölümünde amaç, yöntem, benzer çalışmalar ve elde edilen sonuçlar hakkında öz bilgi verilmiştir.

İkinci bölümde asenkron motorlar, rulman bileşeni ve rulman hatalarından bahsedilmiştir.

Üçüncü bölümde materyal, veriseti özelliklerinden ve deney düzeneğine detaylı olarak değinilmiştir. Ayrıca bu bölümde kullanılan yöntem, IY-UKSB derin öğrenme ağı, pencereleme yöntemi ve özellik çıkarımından da bahsedilmiştir.

Dördüncü bölümde tez çalışması kapsamındaki deneysel çalışmalar sonucunda elde edilen buğular ve analizler sunulmuştur.

Beşinci ve son bölümde ise tez çalışması kapsamında elde edilen sonuçların analizi ve deneysel çalışmalar ile ulaşılan bulguların değerlendirilmesi gerçekleştirilmiştir.

1.3. Araştırma Sorusu ve Hipotez

Tez çalışmasında hatasız çalışan asenkron motor ile hatalı çalışan asenkron motordan elde edilen rulman titreşim verilerinin otomatik sınıflandırılıp sınıflandırılmayacağına soruna cevap aranmıştır. Aynı şekilde hatalı çalıştığı bilenen motorun hatanın konumunu ve büyüklüğünün yapay öğrenme yöntemleri ile sınıflandırılabileceği araştırma konusunu

oluřturmuřtur. Yapılan sınıflandırma alıřmasında kullanılan IY-UKSB'nin performansı arařtırılmıř ve IY-UKSB ye zellik ıkarma yntemleri ile glendirilebileceęi incelenmiřtir.

Tez alıřmasının hipotezinde, IY-UKSB derin sinir aęları kullanılarak, hatalı alıřan motor rulman titreřim verileriyle, saęlıklı alıřan rulman titreřim verilerinin ayırımının yksek bařarım oranı ile yapılabileceęi ngrlmřtir. Ayrıca hata konumunun ve hata byklęnn yine IY-UKSB derin sinir aęları kullanılarak bařarılı bir řekilde sınıflandırılabilceęi deęerlendirilmiřtir.




2. ASENKRON MOTORLAR

2.1. Asenkron Motorlar

Elektrik enerjisini mekanik enerjiye dönüştüren makinelerine asenkron motor denilmektedir (Şerifoğlu, 2007b:1). Asenkron makineler bir alternatif akım makinesi türüdür (Fitzgerald, vd, 2014:183). Asenkron motorlar sağlamlık, ucuzluk, yüksek hızda çalışabilmeleri ve daha az bakım gerektirmeleri nedeniyle en yaygın tercih edilen motor türüdür (Mohammed, 2021:1). Endüstride bulunan motorların %90'ı asenkron motorlardır (Mohammed, 2021:1). Asenkron motorlar alüminyum, demir ve bakır gibi ucuz malzemelerden imal edilir (Mohammed, 2021:1). Asenkron motorlarda stator ve rotor kısımları bulunur (Şerifoğlu, 2007a:100). Statorun oluşturduğu dönen manyetik alanın frekansının rotorun dönme frekansı ile aynı değilse asenkron motor aynı ise senkron motor denir (İpek, 2019:21). İndüksiyon stator ve rotor alanı boyunca hız kayması ile belirlenir ve asenkron motor rotora doğrudan bağlanmadan çalışabilir (Mohammed, 2021:1). Böylece fırça ve komütatöre gerek kalmaz ve bu nedenle düşük bakım maliyeti gerekir (Mohammed, 2021:1). Rotorun yapısına göre bilezikli ve sincap kafesli olmak üzere iki çeşit asenkron motor bulunmaktadır (Chapman, 2007:380). Faz sayısına göre de tek fazlı ve üç fazlı çeşitleri bulunmaktadır (Mohammed, 2021:1). Asenkron motorlar boru şeklindedir ve çevresinde yuvaya sahiptir (Mohammed, 2021:2). Bu yuvalarda eğrilik bulunmaktadır ve bu eğrilik rotor ve statorun dişlerinin manyetik olarak kilitlenmesini önler böylece motorun daha sessiz ve sorunsuz çalışmasını sağlar (Mohammed, 2021:2). Şekil 2.1.'de standart bir asenkron motor ve bileşenleri gösterilmiştir. Şekil 2.1.'deki asenkron motorun bileşenleri motor mili, motor shaftı, rulmanlar, rotor, rotor çubukları, motor taşıma halkası, sabit sargı, stator ve soğutucu fanıdır (Electrical Technology, 2022).

Asenkron motorlarda rotor bakır çubuklar, pirinç ve alüminyumdan oluşur, bu parçalar rotor iletkenleri olarak adlandırılır ve rotorun çevresindeki yuvalara takılır (Mohammed, 2021:2).



Şekil 2.2. Rulmanın yapısı

Rulmanlar makinelerin enerji dönüşümü için kullanılan en yaygın bileşen birimidir (Kaplan vd., 2020:1). Rulman iç bilezik ile dış bilezik arasında en az sürtünme ve kayıpla iş yapmayı sağlar. Rulmanlar makinenin hareketli ve sabit parçaları arasında ara yüz oluşturarak sürtünme kuvvetine maruz kalır (Kuncan vd., 2019:346). Rulmanın yuvarlama sırasında metal metale sürtünmesini engellemek için içerisine yağ doldurulur (Dükkancı, 2019:6). Rulman makinenin son derece yüksek hızlarda çalışmasına izin veren yüksek hassasiyetli bileşenidir (Kuncan vd., 2019:346). Makinenin performansı rulmanlarla direkt bağlantılıdır (Dükkancı, 2019). Rulman arızaları bulunduğu mekanizmayı bozması nedeniyle döner makinelerin en kritik parçalarıdır (Kuncan, 2019:346). Rulmanlarda oluşabilecek hatalar şu şekilde sıralanabilir; hatalı tasarım, asitler tarafından çürüme, uygunsuz yerleşim ve kötü yağlama (Abbasion vd., 2007:2933). Dış bilezik hataları genel olarak titreşim spektrum grafiğinde kendini belli ederken, iç bilezik hataları yan bantlar ve devir sayısında kendini belli eder (Karahana vd., 2005). Ayrıca, titreşim verileri sağlıklı ve sağlıklı çalışan rulman hakkında bilgi içerir (Udmele, 2019:4222). Daha yüksek titreşimin en olası nedeni bir rulman hatası olduğu ve özellikle harmoniklerin rulman hatası türünü temsil ettiği görülmüştür (Udmele, 2019:4222).

Rulmanlar arabalar, uçaklar, inşaat ekipmanları, elektrikli el aletleri gibi tüm dönel uygulamalarda kullanılabilir ve verimli makine ömrü için rulman hata tipi ve boyutunun tespit edilmesi önem taşır (Kuncan vd., 2019:346). Rulman kaynaklı arızayı doğru bir şekilde belirlemek için etkili bir yöntem geliştirilmelidir (Kaplan vd., 2020:1).


2.3. Asenkron Motor Arızaları ve Tespiti

Dış sisteme moment sağlamakla görevli asenkron motorun hareketi titreşime neden olur (Ayaz, 2002:29). Motor içindeki mil ve motor ile iş makinesi arasındaki bağlantı titreşimin iki temel kaynağıdır (Ayaz, 2002:29). Asenkron motorlarda oluşabilecek hatalar şu şekilde sınıflandırılabilir: sargı stator hatası, kırık rotor çubuğu, statik dinamik eksantriklik mil eğriliği, rulman hataları, eksenel kaçıklık ve mekanik dengesizlik (Bae vd., 2005:112). Asenkron motor arızalarının tespit edilmesinde kullanılan yöntemler; sıcaklık ölçümü, titreşim analizi, rulman yağ analizi ve akım analizi olarak sıralanabilir (Dandıl, 2010:2). Elektriksel ve mekanik arızaları ve bunların şiddetlerini tespit etmede en verimli sinyaller titreşim ve akım sinyalleridir (Gansgar vd., 2019:694). Hata teşhisi için kullanılmaya başlanan ilk yöntem sistemin matematik modeline dayalı parametre tahminleri ve bir eleman tarafın motorun sürekli takip edilmesidir (Dandıl, 2010:2). Asenkron motorda hata tespitinde bulanık mantık, YSA, genetik algoritma, zaman serileri ve veri madenciliği gibi bilgisayar destekli otomatik yöntemler de son yıllarda ön plana çıkmaktadır (Kayaalp, 2007:7). Bununla birlikte, son zamanlarda hata sınıflandırması için sinyal işleme ve yapay zekâ yöntemleri birlikte kullanılmaktadır (Udmale, 2019:4222). Asenkron motorlarda oluşan arızalar sıklıkla;

- %41 rulman arızaları,
- %27 stator yalıtımı ile ilgili,
- %10 stator ile ilgili diğer ve
- %12 diğer arızalar olarak gözlemlenmiştir (Yıldırım, 2006:3).

Titreşim algılayıcı yardımıyla elektrik motorundan alınan sinyal verileri zamanla değişen bir yapıya sahiptir ve bu sinyallerin frekans ve genlik değerleri sayısallaştırılıp incelenebilir (Dandıl, 2010:4). Titreşim algılayıcı yardımıyla motordan alınan titreşim verileri incelenerek herhangi bir hata olup olmadığı ve bu hatanın sebebi bulunabilir (Fidan, 2006:1). İzlenen parametrelerdeki ani değişimler motorun durumu hakkında anlamlı bilgiler içerir ve değişimleri takip etmek daha iyi bakım olanağı sağlar (Ayaz, 2002:1). Frekans analizi yaparak ölçülmüş ve kaydedilmiş sonuçlar makine bilinen bir durumda iken kaydedilmiş ölçümlerle karşılaştırılması yönteminin duyarlılığı oldukça yüksektir (Ayaz, 2002:4). Döner sistemlerde arızanın varlığı ve seviyesi titreşim sinyalleri kullanılarak belirlenebilir (Kuncan vd., 2019:346). Çalışan motordaki bir kusurun, arıza meydana gelmeden önce belirlenmesi, makine bakımı için karar verme süreçlerinde daha fazla güvenlik ve azalan maliyet sağlayabilir (Palácios vd., 2016:1). Arızalı bir rulman kısa süreli darbe sinyalleri üretir. Kötü

çevre koşulları, yanlış kullanım ve bakımın düzenli yapılmaması, iç bilezik bilye veya dış bilezik hatalarına neden olabilir (Dal, 2022:8). Şekil 2.3.'te rulman hata çeşitleri gösterilmiştir. Burada, literatürde tanımlanan en yaygın üç rulman arızası olan dış bilezik arızası, iç bilezik arızası ve bilye arızasını gösterilmektedir (Waziralilah vd, 2018:2).



Şekil 2.3. Rulman hata çeşitleri

Kaynak: (Waziralilah vd, 2018:2)

Asenkron motorda rulmanlarında, bilezikler ve bilyelerdeki ezilmelerle rulmanlardaki yük taşınmaktadır. Bu nedenle yükün kaç tane bilye tarafından taşındığı oldukça önemlidir. Rulmanlar yük taşırken aynı zamanda dönme hareketi yapmaktadır. Bu dönme hareketi sırasında rulmanın toplam katılığı bilye sayısı periyodik olarak sürekli değişmektedir (Karaçay, 2006:2). Geometrik olarak kusursuz bir şekilde sahip olsalar bile rulmanlar titreşim üretmektedirler. Rulmanlar tarafından üretilen bu titreşimler doğrusal olmayan bir karakteristik gösterirler (Karaçay, 2006:2).

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında, bilgisayar destekli bir yöntem ile farklı durumlara ait rulman titreşim verilerinin IY-UKSB derin sinir ağları kullanılarak birbirinden ayrılması (sınıflandırılması) sağlanmıştır. İki farklı açık veriseti üzerinde ikili sınıflandırma grupları oluşturulmuş ve birbirlerinden ayrılmaya çalışan titreşim verileri yüksek doğruluk skorları ile sınıflandırılmıştır.

Birinci verisetinde kullanılan veriler Case Western Reserve üniversitesinin (CWRU, 2021) veri tabanından alınmıştır. Birinci grupta çalışma yapılıyorken, hatalı çalışan rulman tespiti için önce sağlıklı çalışan asenkron motora ait veriler yüklenmiştir. Bu verisetinde, hatanın belirlenmesi için yapay olarak aşındırılmış, 12K devirde çalışan sürücü sonuna yerleştirilmiş asenkron motorun iç bilezik bilye ve dış bileziğin üç farklı konumundan alınan titreşim verileri kullanılmıştır. Hata konumuna göre sınıflandırma deneyinde ise aynı hata büyüklüğüne sahip ve aynı yükte çalışan asenkron motorun farklı bölgelerinden toplanan titreşim verileri kullanılmıştır. Hata büyüklüğüne göre sınıflandırılma çalışmasında aynı asenkron motora ait, eşit yüklerde çalışan, aynı konumdan alınmış farklı büyüklüklerdeki hataya sahip titreşim verileri alınmıştır.


İkinci verisetindeki rulman titreşim verileri Mendeley Rulman Titreşim veri tabanından alınmıştır (Mendeley Data, 2021). Bu verisetinde hatanın belirlenmesinde kullanılan titreşim verileri farklı pencere boyutlarında incelenmiştir.

Her iki verisetinde de tüm veriler öncelikle dört farklı pencere büyüklüğünde deneysel çalışmalarda incelenmiştir. Deneylerin ilk basamağında IY-UKSB kullanılarak sınıflandırma doğruluğu ölçülmüştür. İkinci basamağında ise titreşim verilerine spektral entropi ve anlık frekans özellik çıkarımı uygulanarak sinyallerin farklılıkları ön plana çıkarılarak ağ tekrar eğitilmiş ve yeni sonuçlar elde edilerek, doğruluklar değerlendirilmiştir.

3.1. Case Western Reserve Üniversitesi Deney Düzenegi ve Veriseti

Bu tez çalışmasında kullanılan asenkron motor rulman titreşim verileri (iç bilezik, bilye, dış bilezik) Case Western Reserve University (CWRU) rulman veriseti (CWRU, 2021)'den alınmıştır. Şekil 3.1.'de sunulan asenkron motor deneysel düzeneginde, titreşim sensörleri (akselerometre) rulmanın iç bilezik, bilye ve dış bilezik konumlarına yerleştirilmiştir. Buna ek olarak, rulmanın dış bileziği üzerinden üç farklı saat konumundan veriler de toplanmıştır. CWRU verisetinde hem normal (sağlıklı) rulman üzerinde, hem de yapay olarak aşındırılmış rulman üzerinde veri toplama süreci tekrar edilmiştir.

CWRU verisetindeki elektrik motorunun sürücü sonuna ve fan sonuna yerleştirilen titreşim ölçer (akselerometre) yardımıyla titreşim verileri ölçülmüştür. Ardından rulman üzerinde istenilen büyüklükler yapay hatalar oluşturulup titreşim verileri tekrar ölçülmüştür. Kaydedilen veriler zaman düzleminde incelenerek geliştiren yazılımla rulmanın hatalı ve hatasız olarak sınıflandırılması yapılmıştır. Şekil 3.1.'de CWRU verisetinde rulman titreşim verilerinin alındığı tümleşik deney düzeneği gösterilmiştir.



Şekil 3.1. CWRU verisetinde rulman titreşim verilerinin alındığı tümleşik deney düzeneği

Kaynak: (CWRU Data, 2021)

Tablo 3.1. CWRU rulman verisetinde deneysel çalışmalar için kullanılan üç fazlı asenkron motorun özellikleri

Özellik	Değer
Gücü (Hp)	2
Gerilim (V)	208-230
Akım (A)	1.5-3.0
Frekans (Hz)	60
Çalışma ortamı sıcaklığı (C ⁰)	40
Ağırlık (kg)	38.00
Devir sayısı (d/dk)	1800 (1720-1797)

CWRU veriseti, hem normal (sağlıklı/hatasız çalışan) rulman verilerini, hem de yapay olarak aşındırılmış hatalı çalışan rulman verilerini sunmaktadır. Deneysel düzende 2Hp gücündeki ve detayları Tablo 3.1.'de sunulan Reliance Electric firmasının IQPreAlert üç fazlı asenkron motoru kullanılmıştır. Asenkron motorun dönüş hızının dakikada 1725, 1750, 1772

ve 1769 devir olduğu durumlarda veriler kaydedilmiştir. Bu devirlerdeyken asenkron motor sırasıyla 3, 2, 1 ve 0 yük durumundadır.

Tablo 3.2’de CWRU verisetinde elektrik motorunun sağlıklı titreşim verilerinin yük durumuna göre dağılımı gösterilmiştir. Tablo 3.3. ve Tablo 3.4’te rulmanda farklı boyutlarda (0.007’’, 0.014’’, 0.021’’, ve 0.028’’) yapay olarak aşındırma yapılarak bilye, iç bilezik ve dış bilezik konumlarından sensörleri yardımıyla asenkron motorun titreşim verileri gösterilmiştir.

Tablo 3.2. Normal çalışan asenkron motordan alınan verilerin dağılımı

Normal Veriler	
Motor Yüğü	Veri
0	+
1	+
2	+
3	+

Asenkron motorun sürücü sonuna ve fan sonuna sensörleri yerleştirilerek CWRU rulman verisetinde titreşim verileri toplanmıştır ancak yapılan çalışmada sadece sürücü sonundan alınan rulman titreşim verileri kullanılmıştır. Sağlıklı veriler rulmanın sürücü sonunda tek bir noktadan toplanmıştır. Sağlıksız çalışan rulmanın titreşim verileri ise beş farklı noktadan toplanmıştır. Toplanan titreşim verilerinin konumları iç bilezik, dış bilezik ve bilyedir. Hatalı çalışan asenkron motorun sürücü sonundaki rulmana ait titreşim verileri her 12000 saniyede örnek içerecek şekilde, 5000 Hz, 1v/g özelliklerine sahip titreşim ölçer aracılığıyla toplanmıştır (Kılıç & Dandıl, 2021:510). Toplanan veriler yüksek bant genişliği ve 5 kHz kesme frekansı olan bir alçak geçiren filtre ile sınırlandırılmıştır (Kılıç & Dandıl, 2021:510). CWRU veriseti .mat dosyası olarak kaydedilmiştir (CWRU, 2021). Sağlıksız çalışan rulman verileri 0, 1, 2 ve 3 yük durumlarındadır. Dört farklı inç büyüklükte hataya sahiplerdir. Tablo 3.3.’de 12K sürücü sonu hatalı rulman titreşim verilerinin dağılımı gösterilmiştir. Kullanılabilen durumdaki veriler ‘+’ ile ifade edilirken kullanılamaz durumdaki veriler ‘-’ ile ifade edilmiştir. Tablo 3.3.’te dış bilezikten alınan titreşim verilerinin konumunu ifade etmek için saat @12:00, saat @3:00 ve saat @6:00 tanımlamaları kullanılmıştır.

Asenkron motor rulman verisetinin ikinci farklı opsiyonu olarak fan sonundan beş farklı konumdan veriler kullanılmıştır. Fan sonundan toplanan titreşim verileri her 12000 saniyede örnek içerecek şekilde, 5000 Hz, 1v/g özelliklerine sahip titreşim ölçer aracılığıyla bilim adamları tarafından ölçülmüştür. Toplanan veriler sınırlandırılmak için yüksek bant genişliği ve 5 kHz kesme frekansı olan bir alçak geçiren filtre kullanılmıştır. Araştırmacılar

tarafından toplanan veriler MATLAB (.mat) dosyası olarak kaydedilmiştir. 12K fan sonundan toplanmış hatalı veriler dört farklı yük durumundadır bunlar 3, 2, 1, ve 0'dır. Üç farklı inç büyüklükte oluşturulan yapay hatalara sahip rulmanlar çalıştırılıp titreşim verileri bilim insanları tarafından kaydedilmiştir. Tablo 3.4.'te fan sonundan alınan verilerin dağılımı gösterilmiştir. Sürücü sonundan toplanan verilerin gösterim şekli ile fan sonundan toplanan verilerin gösterim şekli aynıdır.

Tablo 3.3. 12K sürücü sonu hatalı rulman titreşim verilerinin dağılımı

Hatanın Büyüklüğü (inç)	Yük	İç Bilezik	Bilye	Dış Bilezik		
				@6:00	@3:00	@12:00
0.007''	0	+	+	+	+	+
	1	+	+	+	+	+
	2	+	+	+	+	+
	3	+	+	+	+	+
0.014''	0	+	+	+	-	-
	1	+	+	+	-	-
	2	+	+	+	-	-
	3	+	+	+	-	-
0.021''	0	+	+	+	+	+
	1	+	+	+	+	+
	2	+	+	+	+	+
	3	+	+	+	+	+
0.028''	0	+	+	-	-	-
	1	+	+	-	-	-
	2	+	+	-	-	-
	3	+	+	-	-	-

Tablo 3.4. 12K fan sonu hatalı rulman titreşim verilerinin dağılımı

Hatanın Büyüklüğü (inç)	Yük	İç Bilezik	Bilye	Dış Bilezik		
				@6:00	@3:00	@12:00
0.007''	0	+	+	+	+	+
	1	+	+	+	+	+
	2	+	+	+	+	+
	3	+	+	+	+	+
0.014''	0	+	+	+	+	-
	1	+	+	-	+	-
	2	+	+	-	+	-
	3	+	+	-	+	-
0.021''	0	+	+	+	-	-
	1	+	+	-	+	-
	2	+	+	-	+	-
	3	+	+	-	+	-

3.2. Mendeley Deney Düzeneđi ve Rulman Titreşim Veriseti


Titreşim sinyali analizi, rulman arıza tespiti için önemli bir araçtır. Rulmanlar genellikle zamanla deđişen dönüş hızı koşullarında çalışır. Mendeley Rulman Titreşim verisetinde, zamanla deđişen farklı hız koşulları altında farklı sağlık koşullarına sahip rulmanlardan ölçülen titreşim veri kümelerini Huang ve Baddour (Huang & Baddour, 2018:1745) tarafından toplamışlardır. Rulmanın koşulları, sağlıklı, iç bilezik hatalı ve dış bilezik hatalı şeklindedir. Veri kümesi için çalışma dönüş hızı koşulları, artan hız, azalan hız, artan sonra azalan hız ve azalan sonra artan hızı şeklindedir.

Veriler, zamanla deđişen dönüş hızı koşullarında çalışan rulmanlardan toplanmıştır. Bu veriseti, literatürde sabit hız koşulu altında toplanan mevcut veri setlerinden farklı olduğu için tercih edilmiştir. Mendeley Rulman Titreşim verileri, zamanla deđişen hız koşulları altında farklı koşullarına sahip rulmanların frekans özelliklerini analiz etmek için kullanılabilir (Huang & Baddour, 2018:1746). Veriler, zamanla deđişen hız koşulları altında arıza teşhisi yeni geliştirilmiş herhangi bir yöntemin etkinliğini değerlendirmek için de uygulanabilir (Huang & Baddour, 2018:1746).

Deneyler Huang ve Baddour (Huang & Baddour, 2018:1745) tarafından, bir SpectraQuest makine arıza simülatörü üzerinde gerçekleştirilmiştir. Şekil 3.2.'de deneysel kurulum gösterilmiştir. Şaft bir motor tarafından tahrik edilmiştir ve dönüş hızı bir AC sürücü tarafından kontrol edilmiştir. Mili desteklemek için iki adet bilyeli rulman monte edilmiştir, soldaki sağlıklı bir rulmandır ve sağdaki, farklı sağlık koşullarına sahip rulmanlarla deđiştirilen deneysel rulmandır. Titreşim verilerini toplamak için deneysel yatađın mahfazasına bir ivmeölçer yerleştirilmiştir. Ek olarak, şaft dönüş hızını ölçmek için artımlı bir kodlayıcı takılıdır.

Rulman arızaları, frekans alanında Arıza Karakteristik Frekansı gözlemlenerek tespit edilebilir ve teşhis edilebilir. Her arıza türü için, çalışma dönüş frekansıyla orantılı olan belirli bir frekansa sahiptir ve katsayı, taşıyıcı yapısal parametreler tarafından belirlenir. Bu verisetinde veriler, veri toplama kartları tarafından alınmıştır. İvmeölçer titreşim verilerini ölçmüştür ve kodlayıcı dönme hızı verilerini ölçmüştür. Örneklenen her veri kümesi iki kanal içerir ve her ikisi de *one.mat* dosyasına araştırmacılar tarafından kaydedilmiştir. 'Kanal_1 (Channel_1)', ivmeölçer tarafından ölçülen titreşim verileridir ve 'Kanal_2 (Channel_2)', kodlayıcı tarafından ölçülen dönüş hızı verileridir. Bu tez çalışmasında rulman hatalarının sınıflandırılması için 'Kanal_1 (Channel_1)' de bulunan titreşim verileri kullanılmıştır.

Hem 'Kanal_1 (Channel_1)' hem de 'Kanal_2 (Channel_2)' tüm deneylerde, sinyaller 200.000 Hz'de örneklenmiştir ve örnekleme süresi 10 s'dir. Mendeley rulman titreşim verisetinde toplam 36 veri seti mevcuttur. Veri kümesinin numaralandırılması Tablo 3.5.'te verilmiştir. Her bir veri kümesi için iki deney ayarı vardır: rulman durumu ve değişen hız durumu. Rulmanın durumları şunları içerir: hatalı normal, iç bilezik hatalı ve dış bilezik.



Şekil 3.2. Mendeley deney düzeneği

Kaynak: (Huang & Baddour, 2018:1746)

Rulman çalışma dönüş hızı durumları artan hız, azalan hız, artan sonra azalan hız ve azalan sonra artan hız şeklindedir. Bu nedenle, her ayar için 12 farklı durum vardır. Toplanan veri kümeleri hakkında daha iyi fikir verebilmek için Tablo 3.5.'te numaralandırılmış veri kümelerinin ayrıntılı çalışma koşulları ve isimlendirilmeleri aşağıda verilmiştir. İsimlendirme yapılıyorken normal, iç bilezik hatalı ve dış bilezik hatalı veriler sırasıyla H, I ve O olarak gösterilmiştir. Hız durumları ise artan hız, azalan hız olarak belirtilmiştir. Önce Artan Sonra Azalan hız ve Önce Azalan Sonra Artan hızlar sırasıyla A, B, C ve D şeklinde gösterilmiştir. Her koşul için deney Huang ve Baddour (Huang & Baddour, 2018:1747) tarafından 3 kere tekrar edilmiştir.

Mendeley Rulman Titreşim veriseti oluşturuluyorken verilerin gerçekliğini sağlamak için, her bir deney ayarı için toplamda 36 veri ile Huang ve Baddour (Huang & Baddour, 2018:1747) tarafından toplanmıştır.

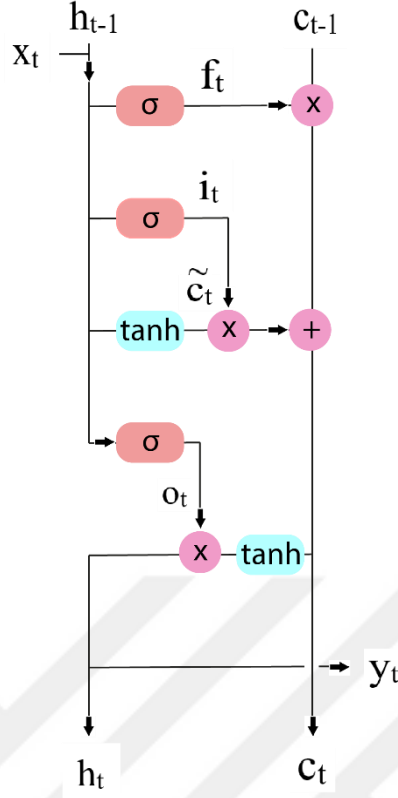
Tablo 3.5. Mendeley rulman titreşim verisetinin çalışma koşulları ve isimlendirilmesi

Rulman Durumu	Artan Hız	Azalan Hız	Önce Artan Sonra Azalan Hız	Önce Azalan Sonra Artan Hız
Normal	H-A-1	H-B-1	H-C-1	H-D-1
	H-A-2	H-B-2	H-C-2	H-D-2
	H-A-3	H-B-3	H-C-3	H-D-3
İç Bilezik Hatalı	I-A-1	I-B-1	I-C-1	I-D-1
	I-A-2	I-B-2	I-C-2	I-D-2
	I-A-3	I-B-3	I-C-3	I-D-3
Dış Bilezik Hatalı	O-A-1	O-B-1	O-C-1	O-D-1
	O-A-2	O-B-2	O-C-2	O-D-2
	O-A-3	O-B-3	O-C-3	O-D-3

3.3.İki Yönlü-Uzun Kısa Süreli Bellek (IY-UKSB)

Uzun kısa süreli bellek (UKSB) ağı ilk olarak Sepp Hochreiter ve Jürgen Schmidhuber tarafından (Hochreiter & Schmidhuber, 1997:1735) ortaya atılmıştır. UKSB zaman adımları arasındaki uzun zamanlı bağımlılıkları öğrenebilir. UKSB ağları derin öğrenme alanında kullanılan ve bir tür tekrarlayan sinir ağı mimarisidir (Kılıç & Dandıl, 2021:511). Hafıza birimlerinin bir araya toplayarak önceki hafızanın ne zaman unutacağını ve ne zaman güncelleneceğini öğrenerek gradyan yayılımından kaynaklanan patlayan-yayılan gradyan probleminin üstesinden gelebilir ve uzun vadeli bağımlılığı öğrenebilir (Tian vd., 2018:297).

UKSB ağlarının temel bileşenleri giriş katmanı ve UKSB katmanıdır ve giriş katmanında dizi veya zaman serileri şeklindeki verilerin ağa sunulur (Kılıç & Dandıl, 2021:511). UKSM tekrarlayan sinir ağları mimarisinde geliştirilmiştir ve bilginin yararlı olup olmadığını belirleyen bir işlemci içerir. UKSB katmanı ise dizi verilerinin zaman adımları arasındaki uzun vadeli bağımlılıklarını öğrenir (Kılıç & Dandıl, 2021:511). Şekil 3.3'te UKSB ağının hücre yapısı gösterilmiştir.



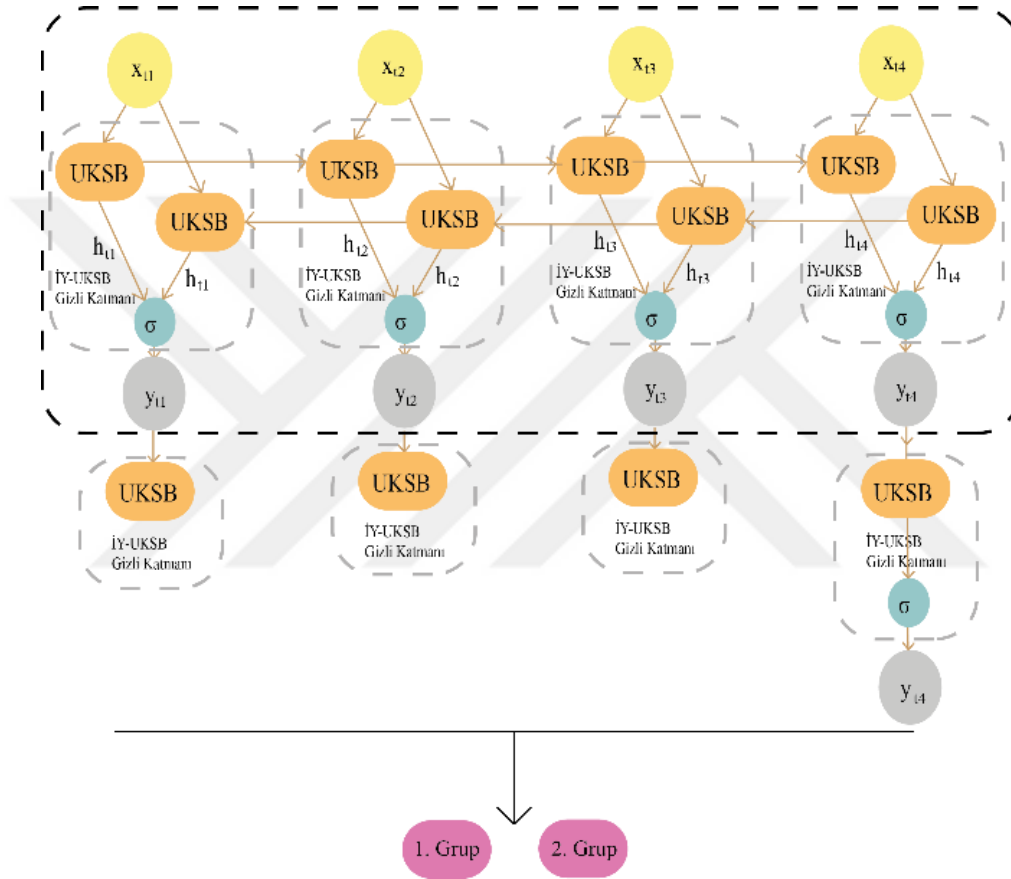
Şekil 3.3. UKSB ağlarında genel hücre yapısı

UKSB ağları zaman serisi verilerine dayanarak sınıflandırmak, işlemek ve tahmin yapmak için uygun bir yapıya sahiptir (Kılıç & Dandıl, 2021:511). UKSB ağları hem anlık veriyi hem de dizi verilerinin işleyebilirler. UKSB ağlarının kullanım alanları konuşma tanıma (Sak vd., 2014:1), ses tanıma (Graves vd., 2013:6645), el yazısı tanıma (Stuner vd., 2020:34407) olarak sıralanabilir.

UKSB ağlarında hafıza bloğu önemi yüksek olan bilgiyi hatırlar önemi düşük olan bilgiyi unuttur. İY-UKSB ağlarının çalışma şekli aynı anda iki UKSB ağının eğitilmesidir (Schuster & Paliwal, 1997:1). Hem ağın girdisi değiştirilmeden hem de zamana göre tersi alınmış hali ile kullanılmaktadır (Kılıç & Dandıl, 2021:511). Ağ bu çalışma şekliyle geçmiş ve gelecek ile ilgili bilgileri tutmaktadır. UKSB ağının yapısında kapılar bulunmaktadır. Bu kapılar şu şekilde sıralanabilir; unutma kapısı, giriş kapısı, güncelleme kapısı ve çıkış kapısı. Giriş ve unutma kapısı hücrenin durumu hakkında çalışır. Giriş kapısı seçici olarak bilginin kaydedilmesi görevini üstlenir. Unutma kapısı unutulacak bilginin belirlenmesinde görev almaktadır. Çıkış kapısı bilgiyi saklamakla görevlidir (Yu vd., 2019:33). UKSM ağındaki bu birimler aktivasyon sinyallerini alırlar.

Şekil 3.3'te t-1 bir önceki zaman adımını, gizlilik durumu ise $ht-1$ ile gösterilmiştir ve sigmoid aktivasyon fonksiyonu için bu denklemlerde ' σ ' kullanılmaktadır (Dandil & Karaca, 2020:426).

UKSB çeşitlerinden biri de çift yönlü UKSB (IY-UKSB)'dir. Tek yönlü UKSB ağlarından daha güçlü bir yapıya sahiptirler. Bu ağlar tüm girdi dizi bilgisini içerir. İki yönlü UKSB ağları dil algılama ve dağıtılmış gösterim özelliği çeşitli uygulamalarda kullanılabilirler.



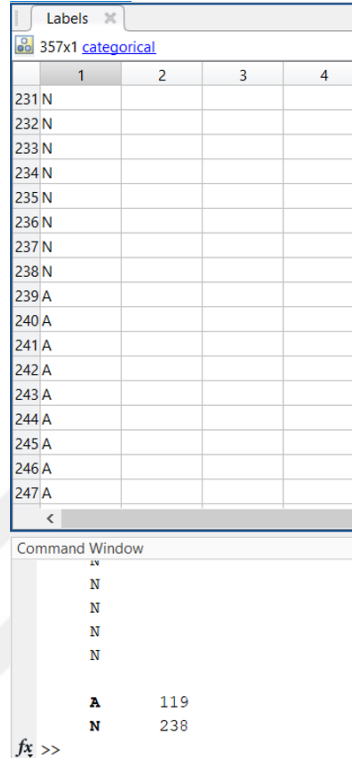
Şekil 3.4. İki yönlü UKSB (IY-UKSB) katman yapısı

Tez çalışması kapsamında geliştirilen IY-UKSB ağının mimarisi, sırasıyla giriş katmanı (sequenceInputLayer), IY-UKSB katmanı (bilstmLayer), tam bağlı katman (fullyConnectedLayer), softmax katmanı ve son olarak sınıflandırma katmanı (classificationLayer)'ndan oluşmaktadır (Kılıç & Dandil, 2021:511).

3.4. Pencereleme Yöntemi

Pencereleme küçük bir örneği inceleyerek örnek seçme ve modelleme için büyük veri kümesinin işlenmesini sağlar (Yüksel & Atmaca, 2019:75). Normal veri için yük boşa iken

alınan sağlıklı motor verisi kullanılmıştır. Hatalı veri için ise yine yük boşa iken bilye konumundan hata miktarını 0.021“ olan rulmanın titreşim verisi MATLAB programına yüklenmiştir. Şekil 3.5’te 1024’lük pencerelelere ayrılan normal ve hatalı motor verilerinin etiketleri sırasıyla ‘N’ ve ‘A’ olarak gözükmektedir.




	1	2	3	4
231 N				
232 N				
233 N				
234 N				
235 N				
236 N				
237 N				
238 N				
239 A				
240 A				
241 A				
242 A				
243 A				
244 A				
245 A				
246 A				
247 A				

```
Command Window
>>
N
N
N
N
N
A      119
N      238
fx >>
```


Şekil 3.5. 1024’lük pencere ile bölünecek verilerin etiket sayıları

Şekil 3.6’da 1024’lük pencerelelere bölünen normal ve sağlıklı sinyalin titreşim verisi görselleştirilmiştir.



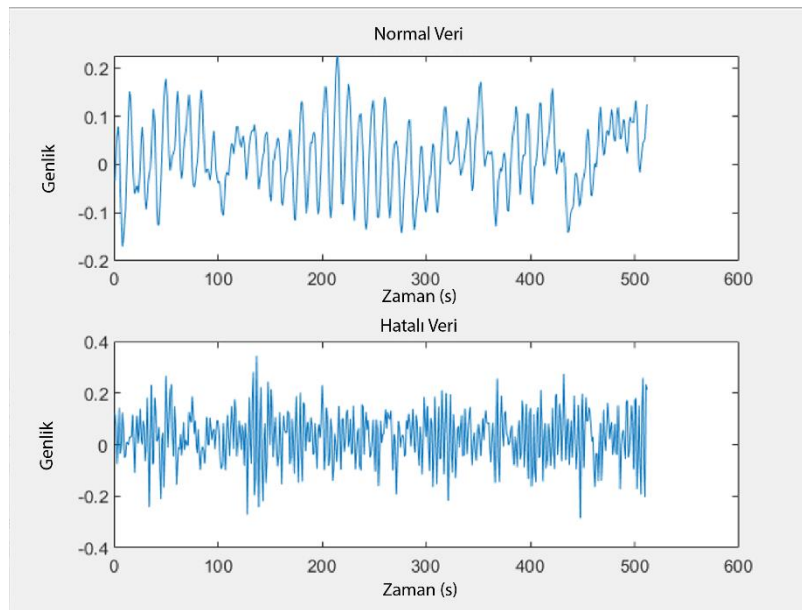
Şekil 3.6. 1024’lük pencere ile bölünen verilerin sinyal görüntüleri

Şekil 3.7.'de aynı titreşim sinyalleri MATLAB programına yüklenerek bu kez veriler 512'lik pencerelelere bölünmüştür.



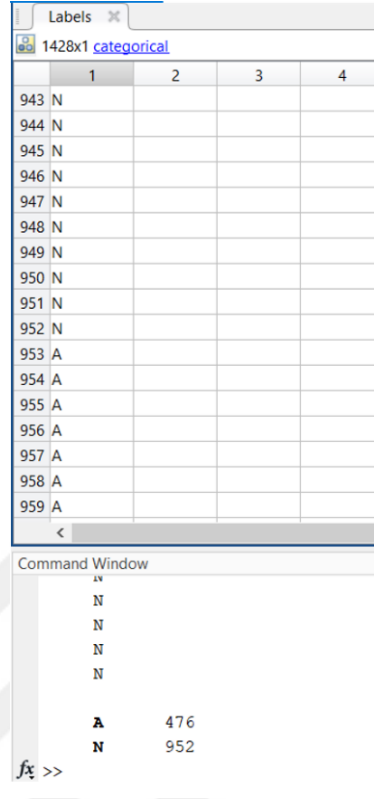
Şekil 3.7. 512'lik pencere ile bölünecek verilerin etiket sayıları

Şekil 3.8'de 512'lik pencerelelere bölünen sinyalin titreşim dalgaları gösterilmiştir.



Şekil 3.8. 512'lik pencere ile bölünen verilerin sinyal görüntüleri

Normal ve 0.021“ hatalı titreşim verileri 256’lık pencerelere bölünmüştür. Sağlıklı veriler ‘N’ hatalı veriler ‘A’ olarak isimlendirilmiştir. Şekil 3.9.’da 256’lık pencere ayrılan verilerin etiket sayıları gösterilmiştir.




	1	2	3	4
943	N			
944	N			
945	N			
946	N			
947	N			
948	N			
949	N			
950	N			
951	N			
952	N			
953	A			
954	A			
955	A			
956	A			
957	A			
958	A			
959	A			

```
Command Window
N
N
N
N
A      476
N      952
fx >>
```

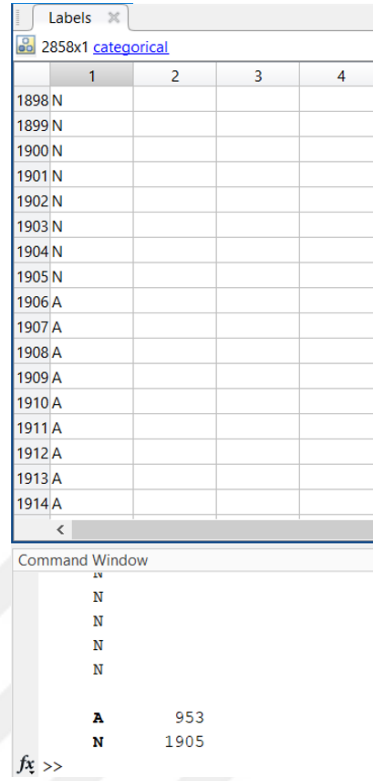
Şekil 3.9. 256’lık pencere ile bölünecek verilerin etiket sayıları

Şekil 3.10.’da 256’lık pencerelere bölünen verilerin titreşim sinyalleri görselleştirilmiştir.




Şekil 3.10. 256’lık pencere ile bölünen verilerin sinyal görüntüleri

Titreşim verileri deneyler için son olarak 126'lık pencerelere ayrılmıştır. Şekil 3.11'de normal veriler 'N' bilye konumundan alınan 0.021'' hatalı titreşim verileri 'A' olarak etiketlenmiştir.



Şekil 3.11. 128'lik pencere ile bölünen verilerin sinyal görüntüleri

Şekil 3.12'de 128 genişliğinde bir pencere ile normal ve hatalı titreşim verilerine ait sinyaller görselleştirilmiştir.



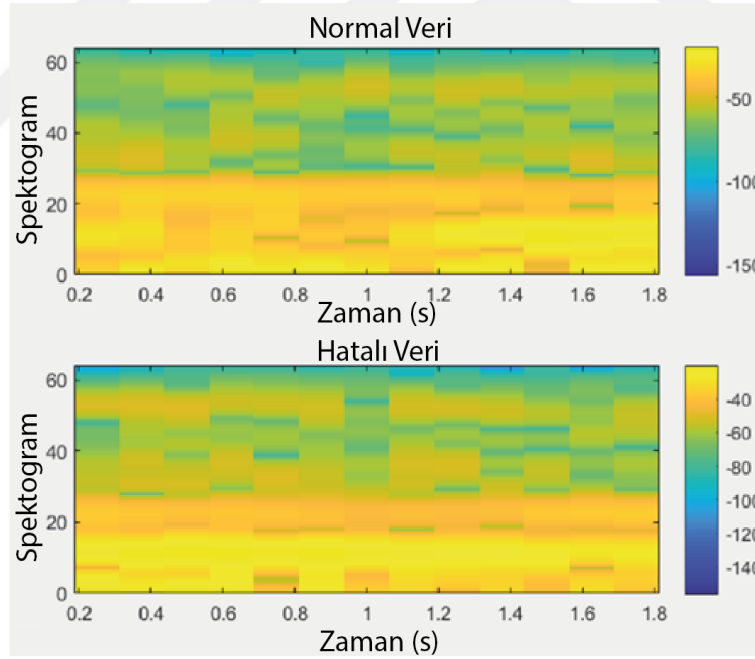
Şekil 3.12. 128'lik pencere ile bölünen verilerin sinyal görüntüleri

3.5.Özellik Çıkarımı

Bu tez çalışmasında, IY-IKSB ağının rulman titreşim verilerinin sınıflandırılmasındaki başarımını artırmak için spektrogram, anlık frekans ve spektral entropi ile özellik çıkarımı gerçekleştirilmiştir.

3.5.1. Spektrogram

Spektrogram bir sinyalin zaman ve frekans değerlerinin iki boyutlu görüntülenmesidir. Titreşim sinyallerinden kesin ve kararlı özellik çıkarımı arızanın belirlenmesinde kullanılan güncel bir yöntemdir (Kuncan vd., 2019:346). Hata sınıflandırmasının doğruluğunu arttırmak için baskın özellik seçimi zorlu bir görevdir (Udmale, 2019:1). Eğitim ve test verisinin sınıflandırılmasında performansın artması için özellik çıkarımı uygulanmıştır. Hangi özelliklerin çıkarılmasına karar vermek için her bir sinyal tipinin spektrogramı çıkarılır. Ardından titreşim verisine ait sinyalin elde edilen spektrogramına göre zaman düzleminde spektral entropi ve anlık frekans özellik çıkarımı yapılmıştır. Şekil 3.13'te hatalı ve hatasız rulman titreşim verilerinin spektrogram analizi gösterilmiştir.




Şekil 3.13. Hatalı ve hatasız rulman titreşim verilerinin spektrogram analizi

3.5.2. Spektral Entropi

Entropi kavramı ilk olarak 1948 yılında elektronik mühendisi ve matematikçi olan Claude Elwood Shannon tarafından ortaya atılmıştır (Shannon, 1948:379). Elwood entropi kavramını bir olay hakkında düzensizliğin ve belirsizliğin matematiksel ölçüsü olarak

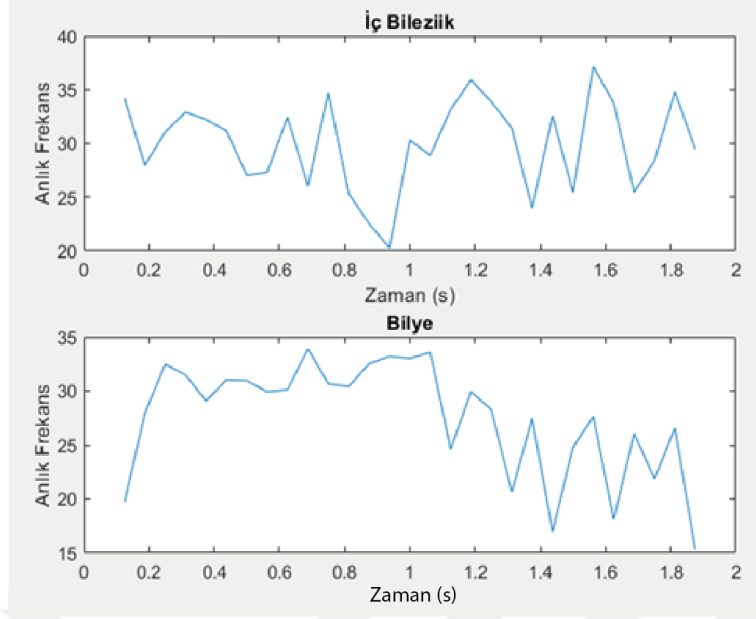
tanımlamıştır. Düzensiz sinyallerdeki düzensizlik derecesini belirleyen entropidir (Sabeti vd., 2009:264). Eğer bir sinyal düzgün olasılık değerine sahipse entropisi yüksek, düzensiz olasılık değerine sahipse entropisi alçak olacaktır (Sabeti vd., 2009:264). İşaret işlemede en çok kullanılan entropi çeşitleri; shannon, norm, eşik logaritmik enerji ve süre entropi olarak sıralanabilir (Toroman, 2016:59). Bir titreşim sinyalin spektrumunun düzlüğü spektral entropi ile ölçülebilir. Dalgalı spektruma sahip sinyalin spektral entropisi düşüktür. Düz spektrumlu sinyal yüksek entropiye sahiptir (Biçer, 2019:45). Şekil 3.14'te iç bilezik ve bilyeden alınan rulman titreşim verilerinin spektral entropisi görülmektedir.



Şekil 3.14. İç bilezik ve bilyeden alınan rulman titreşim verilerinin spektral entropisi

3.5.3. Anlık Frekans

Anlık frekans, doğrusal olmayan ve durağan olmayan süreçler için ayrıntılı mekanizmaları anlamak için gereklidir (Huang vd., 2019:177). Anlık frekans parametresi, zamana göre faz değişimleri olarak bilinir ve Hilbert dönüşümünü önermeden önce, yalnızca tek bileşenli verileri analiz etmek için kullanıldı (Sadeghi vd., 2019:4506). Şekil 3.15'te iç bilezik ve bilye hatalı rulman titreşim verilerinin anlık frekans özelliği görülmektedir.



Şekil 3.15. İç bilezik ve bilyeden alınan rulman titreşim verilerinin anlık frekans özelliği

4. DENEYSEL ÇALIŞMALAR

Bu tez çalışmasında IY-UKSB derin öğrenme ağı kullanılarak geliştirilen yazılım için MATLAB programı kullanılmıştır. Ayrıca, titreşim verilerine özellik çıkarımı uygulanarak IY-UKSB ağının sınıflandırma başarısı artırılmıştır. İki gruba ayrılan verilerin bir kısmı eğitim bir kısmı test için kullanılmıştır. Deneysel çalışmalarda, IY-UKSB ağı başarılı bir şekilde zaman düzleminde sınıflandırma problemine uygulanmıştır. Ayrıca, hatanın varlığı, konumu ve büyüklüğüne göre sınıflandırma için deneysel çalışmalar yapılmıştır. Şekil 4.1'de tez çalışmasında uygulanan yöntemin adımları verilmiştir.



Tez çalışmasında, her iki verisetindeki normal ve hatalı rulman verileri kullanılarak oluşturulan alt veriseti üzerinde 128, 256, 512 ve 1024 pencere genişliklerinde, öncelikle ağın eğitim aşaması tamamlanmıştır. Daha sonra test kümesi üzerinde IY-UKSB ağının normal ve hatalı rulman verilerini sınıflandırmadaki başarımlarını analiz edilmiştir. Buna karşın, tez kapsamında yürütülen deneysel çalışmalarda, IY-UKSB ağı rulman verilerini sınıflandırma doğruluğunun CWRU verisetinde ortalama %60 civarında, Mendeley Rulman Titreşim Verisetinde ise %75 civarında kalmıştır. Bu deneysel çalışmalarda, sınıflandırma doğruluğunun düşük olması nedeniyle, normal ve hatalı rulmanlara ait titreşim verilerinden anlık frekans ve spektral entropi ile özellik çıkarımı sağlanmıştır. Titreşim sinyallerinden özellik çıkarımı yapıldıktan sonra, IY-UKSB ağı yeniden eğitilerek ağın performansı yeniden değerlendirilmiştir. Titreşim verilerinden, anlık frekans ve spektral entropi ile özellik çıkarımı sonrasında, hatalı ve normal rulman verilerinin IY-UKSB ağı ile sınıflandırılmasında doğruluk oldukça yükselmiştir.

Çalışmada öncelikle, rulman titreşim verilerinin sınıflandırılması için önerilen IY-UKSB verileri sınıflandırma başarımı, Denklem (4.1), Denklem (4.2) ve Denklem (4.3)'da sunulan ve karmaşıklık matrislerindeki Doğru Pozitif (DP), Yanlış Negatif (FN), Doğru Negatif (DN), Yanlış Pozitif (YP) değerlerine bağlı olarak hesaplanan Doğruluk (DG), Duyarlılık (DY) ve Seçicilik (SC) performans kriterleri ile ölçülmüştür.

$$DG = \frac{(DP+DN)}{(DP+DN+YP+YN)} \quad (4.1)$$

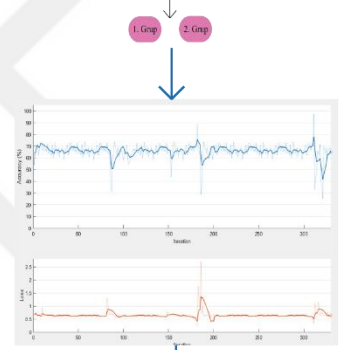
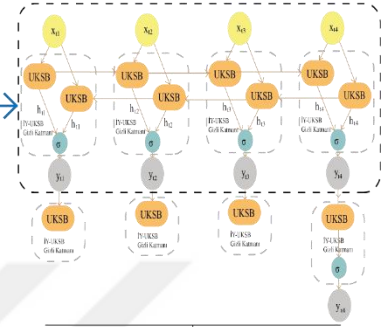

$$DY = \frac{DP}{(DP+YN)} \quad (4.2)$$

$$SC = \frac{DN}{(DN+YP)} \quad (4.3)$$




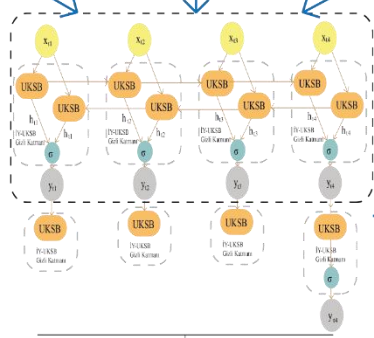

- 100.mat
- 105.mat
- 106.mat
- 107.mat
- 108.mat
- 109.mat
- 110.mat
- 111.mat
- 112.mat
- 118.mat
- 119.mat
- 120.mat
- 121.mat
- 122.mat
- 123.mat
- 124.mat
- 125.mat
- 130.mat
- 131.mat
- 132.mat
- 133.mat
- 135.mat
- 136.mat
- 137.mat
- 138.mat
- 144.mat
- 145.mat
- 146.mat

- Mendeley_HA1_IA11024.mat
- Mendeley_HA1_IA1128.mat
- Mendeley_HA1_IA1256.mat
- Mendeley_HA1_IA1512.mat
- Mendeley_HA1_OA11024.mat
- Mendeley_HA1_OA1128.mat
- Mendeley_HA1_OA1256.mat
- Mendeley_HA1_OA1512.mat
- Mendeley_IA1_OA11024.mat
- Mendeley_IA1_OA1128.mat
- Mendeley_IA1_OA1256.mat
- Mendeley_IA1_OA1512.mat



Test Doğruluk Karşılaştırmalı Matrisi

	Gerçek	Yanlış	
Çıktı Doğru	164 88.4%	21 10.6%	185 99%
Çıktı Yanlış	21 10.6%	202 99.4%	223 100%
	185 99%	223 100%	



Test Doğruluk Karşılaştırmalı Matrisi

	Gerçek	Yanlış	
Çıktı Doğru	164 88.4%	21 10.6%	185 99%
Çıktı Yanlış	21 10.6%	202 99.4%	223 100%
	185 99%	223 100%	

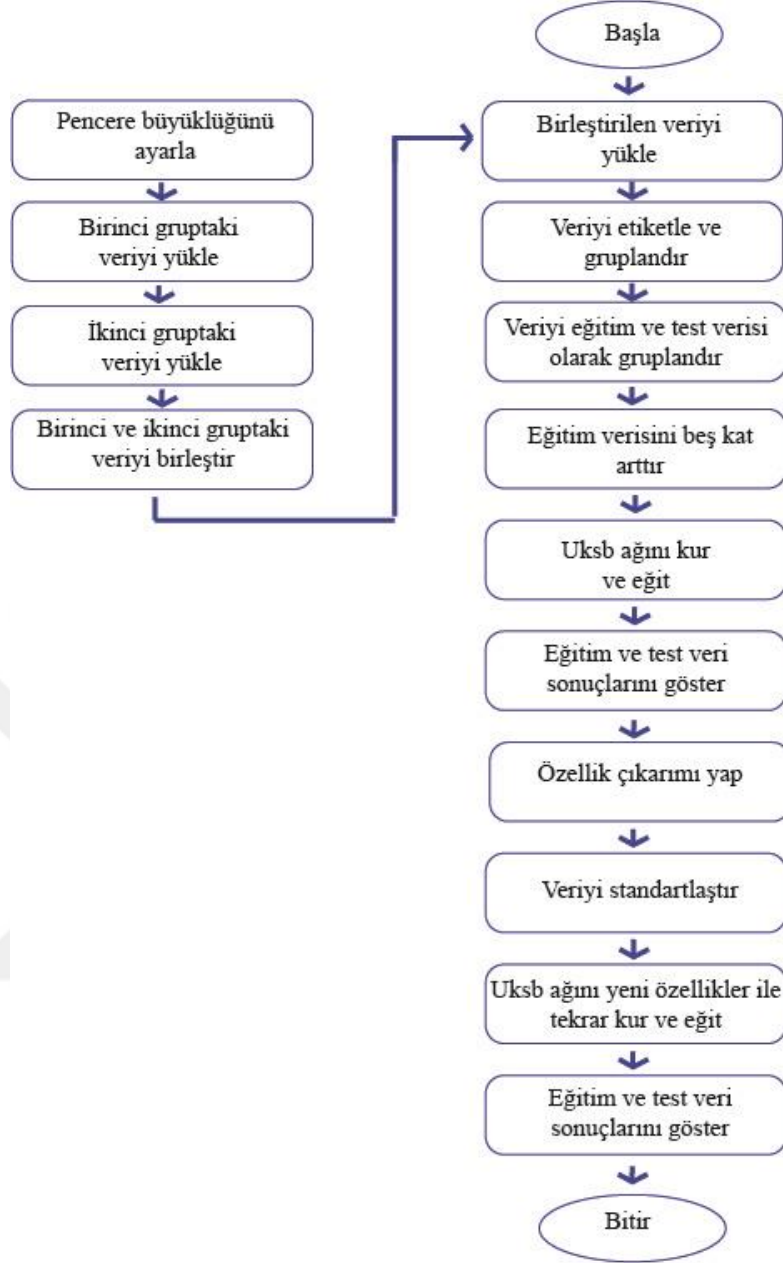
Şekil 4.1. Tez çalışmasında uygulanan yöntemin adımları

4.1. Case Western Reserve Üniversitesi Veriseti ile Yapılan Deneyler

Bu çalışmanın ilk adımında CWRU veri tabanından elde edilen normal çalışan rulmana ait titreşim verileri ve yapay olarak aşındırılan hatalı çalışan rulmana ait titreşim verileri kullanılmıştır. İkinci adımında hatalı olan verileri kendi aralarında farklı konumlardan alınmış ve üçüncü adımda ise yine hatalı olarak çalışan rulmanın farklı büyüklüklerdeki hatalarından alınmış titreşim verileri kullanılmıştır. Üç çalışma içinde toplanan veriler IY-UKSB derin sinir ağları ile otomatik sınıflandırılması için bir model oluşturulmuştur. Bu çalışmada, Intel(R) Core (TM) i7-9750H CPU @ 2.60GHz 2.60 GHz özelliklerine sahip işlemci kullanılmıştır. 16GB bellek ve NVIDIA Geforce GTX 1160 Ti ekran kartı kullanılmıştır. Kullanılan bilgisayar Windows 10 işletim sistemine sahiptir. MATLAB programlama dili ile deneysel analizler yapılmıştır.

Şekil 4.2.'de deneysel çalışmanın adımları gösterilmiştir. Çalışmada, deneysel analizler için kullanılan iki farklı gruba ait rulmanların her bir sinyal verisi birleştirilerek 128, 256, 512 ve 1024'lük pencerele bölünerek matrislere ayrılmıştır. Eğitim ve test verisi olarak iki gruba ayrılarak özellik çıkarımından önce ağın eğitimi yapıp sonuçlar kaydedilmiştir. Özellik çıkarımından sonra tekrar ağ eğitilmiş ve deney sonuçları karşılaştırılmıştır.

Her bir deneysel analizde, verilerin %70'i ağın eğitim aşaması için, kalan %30'u ise test aşaması için kullanılmıştır. Kullanılan ağın doğruluk değerini arttırabilmek için eğitim verileri 5 katına çıkarılmıştır. Veri arttırma işlemi test verisetine uygulanmamıştır. Yürütülen çalışmada epok sayısı 10 ve öğrenme katsayısı 0.01 olarak belirlenmiştir.

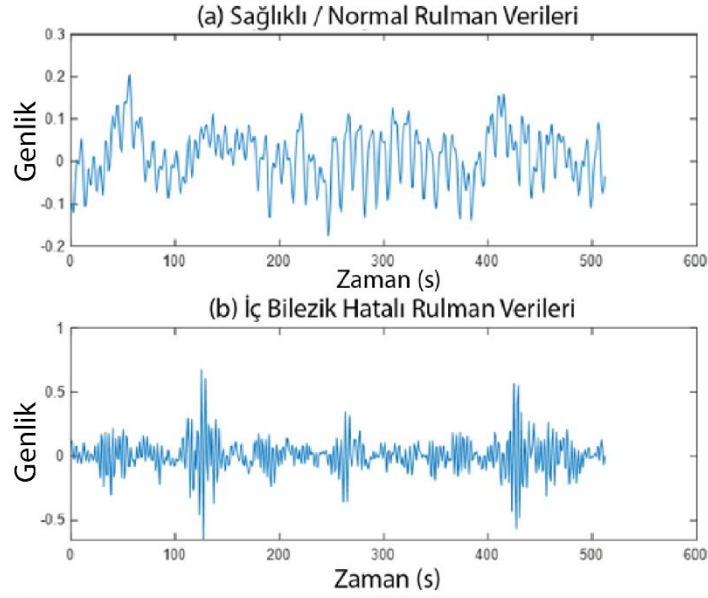


Şekil 4.2. Tez kapsamında yürütülen deneysel çalışmaların adımları

4.1.1. Normal ve Hatalı Verinin Sınıflandırılması


Deneysel çalışmanın açıklanması için eklenen görsellerde, normal çalışan rulmanın olduğu asenkron motor yük 1 durumundadır. Hatalı çalışan asenkron motor yük 1 durumundadır. Hata büyüklüğü 0.014''olarak seçilmiştir ve iç bilezik konumundan alınan veriler kullanılmıştır.

Şekil 4.3.(a)'da normal çalışan rulmana ait titreşim verisi gösterilmiştir. Şekil 4.3.(b)'de ise hatalı çalışan rulmana ait titreşim verisi gösterilmiştir. Görseldeki veri 512'lik pencerelere ayrılmıştır.



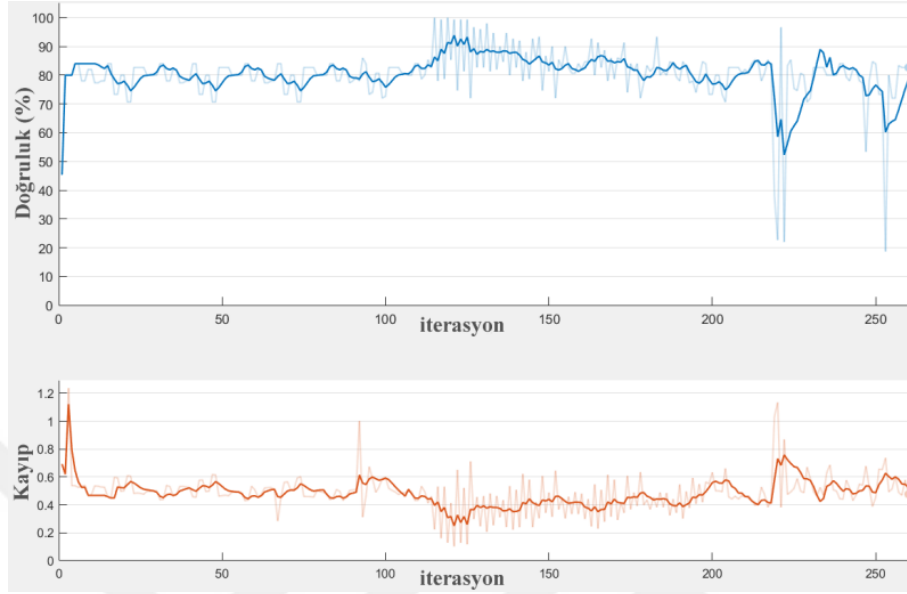
Şekil 4.3. (a) Normal rulman verileri ve (b) hatalı rulmana ait iç bilezikten alınan 512 pencere genişliğinde titreşim sinyalleri

Şekil 4.4'te yük boştaki hatalı ve hatasız verilerin özellik çıkarımından önce doğruluk ve kayıp değerleri gösterilmiştir. Şekildeki örnekte hatalı titreşim verisi bilye konumundan alınmıştır. Hata büyüklüğü 0.014 olarak seçilmiştir. Pencere büyüklüğü 512 olarak seçilmiştir.



Şekil 4.4. Özellik çıkarımından önce doğruluk ve kayıp grafiği

Şekil 4.5'te 1024 pencere boyutunda normal ve hatalı rulman verilerinin sınıflandırılması için oluşturulan İY-UKSB ağının eğitim aşamasında elde edilen doğruluk ve yaklaşık kayıp grafikleri gösterilmiştir.



Şekil 4.5. 1024 pencere boyutunda normal ve hatalı rulman verilerinin sınıflandırılması için oluşturulan İY-UKSB ağının eğitim aşamasında elde edilen doğruluk ve yaklaşık kayıp grafikleri


Tablo 4.1. Sağlıklı ve hatalı çalışan asenkron motor sınıflandırma performansı

Özellik çıkarımı olmadan İY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	1120	200	14	85	84.92	98.77	29.82
256	554	113	13	30	82.25	97.71	20.98
512	272	53	12	18	81.69	95.77	28.35
1024	134	27	8	8	80.23	94.37	22.86
Ortalama					82.27	96.66	25.50
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası İY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	1133	4	1	281	99.65	99.91	98.60
256	565	4	2	139	99.15	99.65	97.20
512	284	2	0	69	99.44	100	97.18
1024	141	1	1	34	98.87	99.30	97.14
Ortalama					99.28	99.72	97.53

Tablo 4.1.'de farklı pencere boyutlarında özellik çıkarımı öncesi ve özellik çıkarımı sonrası IY-UKSB ağının performansı verilmiştir. Normal ve hatalı rulman verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı öncesi IY-UKSB ağının ortalama doğruluk değeri %82.92 ortalama duyarlılık değeri % 96.66 ve ortalama seçicilik değeri %25.82 olarak hesaplanmıştır. Özellik çıkarımı sonrasında ise IY-UKSB ağının ortalama doğruluk değeri %99.28, ortalama duyarlılık değeri %99.72 ve ortalama seçicilik değeri %97.53 olarak elde edilmiştir.


4.1.2. Hata Konumuna Göre Sınıflandırma

Hata konumuna göre yapılan sınıflandırma çalışması için 12K sürücü sonu rulman verisetindeki 0.014'' ve 0.028'' hata büyüklüğüne sahip verilerin iç bilezik, bilye ve dış bilezik konumlarından alınmış hatalı veriler kullanılmıştır. Bu veriler kullanılarak hata belirlemeye deneyinde olduğu gibi IY-UKSB derin sinir ağları ile sınıflandırılmıştır. Şekil 4.6.'da iki farklı sinyal için de motorun yükü 2 durumdadır ve hata büyüklüğü 0.014'' olarak seçilmiştir. Pencere boyutu 256 olarak belirlenmiştir. Şekil 4.6.(a)'daki sinyal iç bilezik hatalı rulmandan alınmıştır. Şekil 4.6.(b)'deki sinyal bilye hatalı rulmandan alınmıştır.



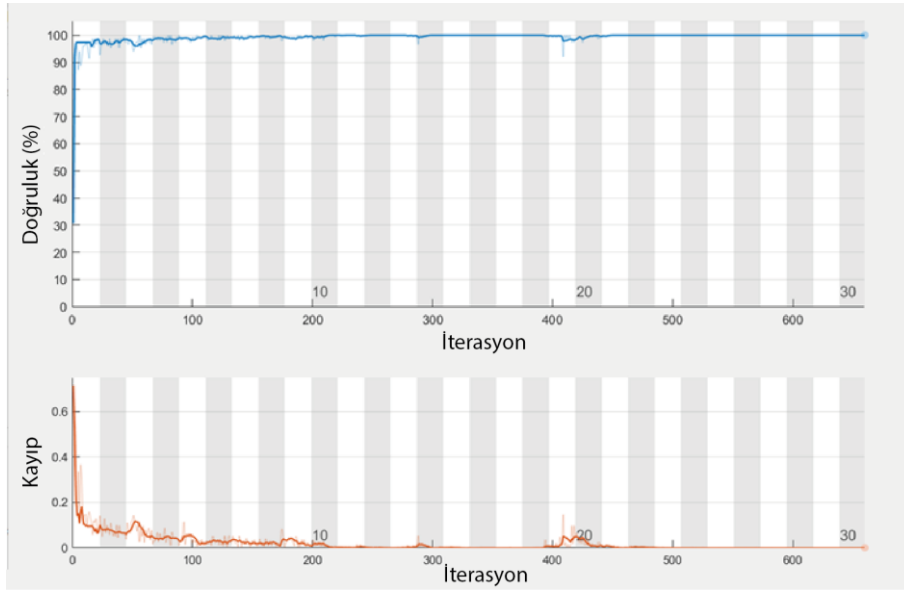
Şekil 4.6. (a) İç bilezik hatalı rulman verileri ve (b) Bilye hatalı rulmana ait iç 256'lık pencere genişliğinde titreşim sinyalleri

Hatalı verinin konumunu sınıflandırma deneysel çalışmasında özellik çıkarımı uygulanmadan önce IY-UKSB ağının eğitim aşamasında elde edilen doğruluk ve yaklaşık kayıp değerleri Şekil 4.7.'da gösterilmiştir. Doğruluk değeri yaklaşık %50 olarak elde edilmiştir.



Şekil 4.7. Özelliik çıkarımından önce İY-UKSB doğruluk ve kayıp deęerleri

İY-UKSB aęına spektral entropi ve anlık frekans özelliikler eklenerek aęın sinyal özelliiklerinden faydalanarak daha yüksek performansta doğruluk elde edilmeye çalışılmıştır. Şekil 4.8’de özelliik çıkarımından sonra aęın doğruluk ve kayıp deęerleri gösterilmiştir. Özelliik çıkarımı uygulandıktan sonra aęın performansının yükseldięi gözlemlenmiştir. Özelliik çıkarımı ile kayıp azalmış doğruluk değeri yükselmiştir. Özelliik çıkarımından sonra aę performansı yaklaşık %50’den %99’a varan doğruluk deęerlerine ulaşılmıştır.



Şekil 4.8. Özelliik çıkarımından sonra İY-UKSB doğruluk ve kayıp deęerleri

Tez çalışmasının ikinci araştırma konusunda, hata konumu belirleme deneylerinde verilerden oluşturulan veriseti üzerinde dört farklı pencere genişliklerinde test verileri üzerinde IY-UKSB ağının performansının ortalama %50 olarak elde edilmiştir. Hata konumuna göre rulman verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı ile ağın iyileştirilmesi sonrası IY-UKSB ağının ortalama doğruluk değeri %99.2 ortalama duyarlılık değeri %99.38 ve ortalama seçicilik değeri %99.03 skorlarına ulaştığı hesaplanmıştır. Tablo 4.2.’de 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin sınıflandırılmasının skorları verilmiştir.

Tablo 4.2. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	0	0	286	285	49.91	0	100
256	125	134	18	9	46.85	87.41	6.29
512	55	61	16	10	45.77	77.46	14.08
1024	0	0	35	36	50.7	0	100
Ortalama					48.3	41.21	55.09
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	279	7	7	278	97.54	97.55	97.54
256	143	0	0	143	100	100	100
512	71	1	0	70	99.29	100	98.59
1024	36	0	0	35	100	100	100
Ortalama					99.2	99.38	99.03

Tablo 4.3’te 12K sürücü sonu yük 1 değerinde hata 0.014’’ büyüklüğündeyken iç bilezik ve dış bilezik (@6:00) konumlarından alınan verilerin sınıflandırılma skorları verilmiştir. Özellik çıkarımı öncesi IY-UKSB ağının ortalama doğruluk değeri %62.29 iken özellik çıkarımı ile ağ performansı artırılarak ortalama doğruluk değeri %95.7’ye yükseltilmiştir.

Tablo 4.3. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken iç bilezik ve dış bilezik (@6:00) konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	206	202	80	83	50.61	72.02	29.12
256	143	141	0	2	50.69	100	1.39
512	8	9	63	62	49.29	11.26	87.32
1024	36	1	0	34	98.59	100	97.14
Ortalama					62.29	70.82	53.74
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	245	21	41	264	89.14	85.66	92.63
256	138	7	5	136	95.8	96.5	95.1
512	71	2	0	69	99.29	100	97.18
1024	36	0	0	36	98.59	100	97.14
Ortalama					95.7	95.54	95.51

Tablo 4.4. 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken bilezik ve dış bilezik (@6:00) konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	285	279	1	7	51.13	99.65	2.44
256	143	143	0	0	50	100	0
512	6	9	65	62	47.88	8.45	87.32
1024	32	30	4	6	55.55	88.88	16.66
Ortalama					51.14	74.24	26.6
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	281	0	5	286	99.12	98.25	100
256	143	0	0	140	100	100	100
512	71	0	0	71	100	100	100
1024	36	0	0	36	100	100	100
Ortalama					99.78	99.56	100

Tablo 4.4’te 12K sürücü sonu yük 1 değerinde hata 0.014“ büyüklüğündeyken bilezik ve dış bilezik (@6:00) konumlarından alınan verilerin sınıflandırılma performansı verilmiştir. Özellik çıkarımından önce ortalama doğruluk değeri %51.14 olarak elde edilmiştir. Özellik çıkarımından sonra bu değer %99.78 olarak elde edilmiştir. Özellik çıkarımı ağın performansını arttırmıştır.


Tablo 4.5'te 12K sürücü sonu yük 1 değerinde hata 0.028'' büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin sınıflandırılma performansı verilmiştir. Özellik çıkarımı ağı uygulanmadan önce ortalama doğruluk değeri %87.94 iken özellik çıkarımı ile ağı iyileştirildiğinde bu oran %100'e ulaşmıştır.

Tablo 4.5. 12K sürücü sonu yük 1 değerinde hata 0.028'' büyüklüğündeyken iç bilezik ve bilye konumlarından alınan verilerin özellik çıkarımı öncesi ve sonrası sınıflandırılma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	0	0	284	100	100	100
256	142	137	0	5	51.76	100	3.52
512	71	0	0	71	100	100	100
1024	35	0	0	35	100	100	100
Ortalama					87.94	100	75.88
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	0	0	284	100	100	100
256	142	0	0	142	100	100	100
512	71	0	0	71	100	100	100
1024	35	0	0	35	100	100	100
Ortalama					100	100	100


4.1.3. Hata Büyüklüğüne Göre Sınıflandırma

Hata büyüklüğünü sınıflandırma deney çalışması için 12K sürücü sonu rulman verisetindeki 0.007'', 0.014'' ve 0.028'' hata büyüklüğüne sahip verilerin iç bilezik, bilye ve dış bilezik konumlarından alınmış hatalı veriler kullanılmıştır. Şekil 4.9.'da yük 2 durumunda iken iç bilezikten alınan titreşim verilerinin sinyalleri verilmiştir. Şekil 4.9.(a)'da hata büyüklüğü 0.007'' ve şekil 4.9.(b)'de 0.014'' olarak verilmiştir. Görselleştirilen çalışmada tercih edilen pencere boyutu 256'dır.



Şekil 4.9. (a) 0.007“ hatalı rulman verileri ve (b) 0.014“ hatalı rulmana ait iç 256’lık pencere genişliğinde yük 2 durumunda iken iç bilezikten alınan titreşim sinyalleri

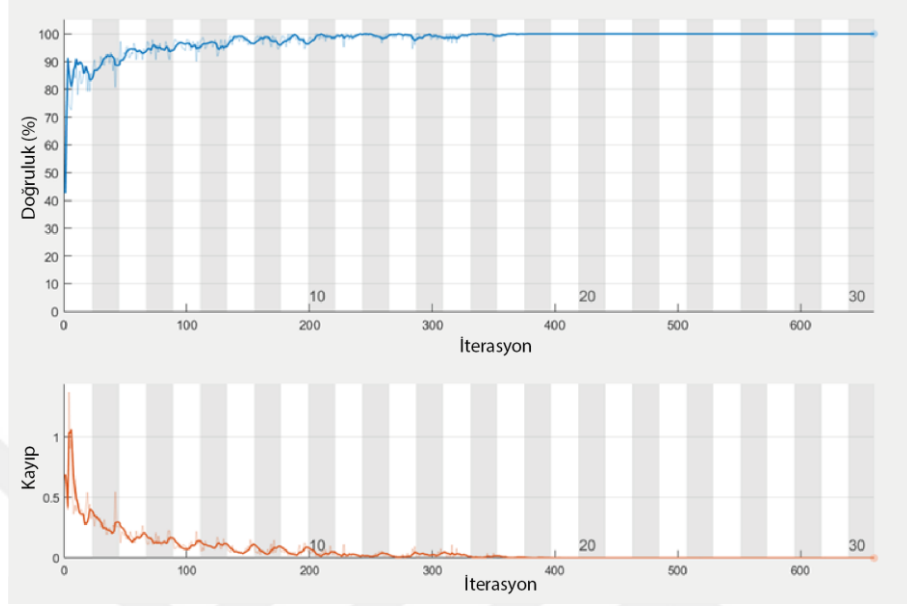
256 pencere boyutunda hatalı rulmana ait farklı büyüklüklerde alınan titreşim verilerinin sınıflandırılması için oluşturulan IY-UKSB ağının eğitim aşamasında elde edilen doğruluk ve yaklaşık kayıp değerleri şekil 4.10’da gösterilmiştir. Grafik yaklaşık %50 doğruluk oranı ile başlayıp %100 değerine kadar yükselmiştir.



Şekil 4.10. Özellik çıkarımından önce IY-UKSB doğruluk ve kayıp değerleri

IY-UKSB ağına spektral entropi ve anlık frekans özellikler eklenerek ağın sinyal özelliklerinden faydalanarak daha yüksek performansta doğruluk elde edilmeye çalışılmıştır.

Şekil 4.11.'de özellik çıkarımdan sonra hata büyüklüğünün sınıflandırılması deney çalışmasının doğruluk ve kayıp değerleri gösterilmiştir. Grafikte doğruluk değerinin %100 oranına ulaştığı görülmektedir.



Şekil 4.11. Özellik çıkarımından sonra IY-UKSB doğruluk ve kayıp değerleri

Tablo 4.6. 12K Sürücü sonu, bilye konumunda yük 1 için 0.007^{''} ve 0.014^{''} hata büyüklükleri için özellik çıkarımı öncesi ve sonrası verilerin sınıflandırılma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	236	284	0	0	45.33	100	0
256	84	44	59	98	63.85	58.74	69.01
512	67	59	4	12	55.63	94.36	16.9
1024	10	16	26	19	59.15	27.77	54.28
Ortalama					55.99	70.21	35.04
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	261	20	25	264	95.61	91.25	92.95
256	137	3	6	139	96.84	95.8	97.88
512	70	0	71	71	99.29	98.59	100
1024	36	0	0	35	100	100	100
Ortalama					97.93	96.41	97.7

Tez çalışması kapsamında üçüncü araştırma olarak, hata konumu belirleme deneylerinde oluşturulan veriseti üzerinde IY-UKSB ağının performansının ortalama %50

civarında kaldığı, ancak hata büyüklüğüne göre verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının ortalama doğruluk değeri %97.93, ortalama duyarlılık %96.41 ve ortalama seçicilik %97.7 değerlerine ulaştığı hesaplanmıştır.

12K Sürücü sonu, bilye konumunda yük 1 için 0.007'' ve 0.014'' hata büyüklükleri için sınıflandırma sonuçları Tablo 4.6'da gösterilmiştir. Özellik çıkarımı olmadan ulaşılan ortalama doğruluk değeri %55.99, ortalama duyarlılık %70.21 ve ortalama seçicilik %35.04 olarak elde edilmiştir. Özellik çıkarımı ağı modifiye edildikten sonra bu değerler ortalama doğruluk %97.93, ortalama duyarlılık %96.41 ve ortalama seçicilik %97.7 olarak elde edilmiştir.

12K Sürücü sonu, iç bilezik konumunda yük 1 için 0.007'' ve 0.014'' hata büyüklükleri için sınıflandırma sonuçları Tablo 4.7'de gösterilmiştir. IY-UKSB ağına özellik çıkarımı uygulamamdan önce ölçülen ortalama doğruluk değeri %72.28 iken özellik çıkarımı ağı uygulandıktan sonra elde edilen ortalama doğruluk değeri %95.35 olarak hesaplanmıştır.

Tablo 4.7. 12K Sürücü sonu, iç bilezik konumunda yük 1 için 0.007'' ve 0.014'' hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	0	0	215	286	50.08	0	100
256	142	0	1	143	99.64	99.3	100
512	71	0	0	71	100	100	100
1024	32	25	3	11	39.43	91.42	30.55
				Ortalama	72.28	72.68	82.63
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	260	39	25	247	88.79	91.22	86.36
256	138	8	5	135	95.45	96.5	94.4
512	68	1	3	70	97.18	95.77	98.59
1024	35	0	0	36	100	100	100
				Ortalama	95.35	95.87	94.83

12K Sürücü sonu, dış bilezik (@6:00) konumunda yük 1 için 0.007'' ve 0.014'' hata büyüklükleri için sınıflandırma sonuçları Tablo 4.8'de gösterilmiştir. IY-UKSB ağına özellik çıkarımı uygulamamdan önce ölçülen ortalama doğruluk değeri %66.32 iken özellik çıkarımı ağı uygulandıktan sonra elde edilen ortalama doğruluk değeri %99.56 olarak elde edilmiştir.

Tablo 4.8. 12K Sürücü sonu, dış bilezik (@6:00) konumunda yük bir değerinde 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	286	173	0	114	69.8	100	39.72
256	0	0	143	143	50	0	100
512	71	72	0	0	49.65	100	0
1024	36	3	0	33	95.83	100	91.66
Ortalama					66.32	75	57.84
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	285	5	1	282	98.95	99.65	98.25
256	142	1	1	142	99.3	99.3	99.3
512	71	0	0	72	100	100	100
1024	36	0	0	36	100	100	100
Ortalama					99.56	99.73	99.38

Tablo 4.9. 12K Sürücü sonu, bilye konumunda yük 1 değerindeyken 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	281	5	3	279	98.59	98.94	98.23
256	141	0	1	142	99.64	99.29	100
512	70	0	1	71	99.29	98.59	100
1024	35	0	0	35	100	100	100
Ortalama					99.38	99.2	99.55
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	0	0	284	100	100	100
256	142	0	0	142	100	100	100
512	71	0	0	71	100	100	100
1024	35	0	0	35	100	100	100
Ortalama					100	100	100

12K Sürücü sonu, bilye konumunda yük 1 için 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.9’da gösterilmiştir. Özellik çıkarımı olmadan ulaşılan ortalama doğruluk değeri %99.38, ortalama duyarlılık %99.2 ve ortalama seçicilik %99.55 olarak hesaplanmıştır. Özellik çıkarımı ağı modifiye edildikten sonra bu değerler ortalama doğruluk, ortalama duyarlılık ve ortalama seçicilik %100 olarak elde edilmiştir.

12K Sürücü sonu, iç bilezik konumunda yük 1 için 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.10’da gösterilmiştir. Deneysel çalışmanın sonucuna göre özellik çıkarımı olmadan doğruluk değeri %65.09 değerindedir. Özellik çıkarımı uygulandıktan sonra doğruluk değeri %99.69 değerine ulaştığı hesaplanmıştır. Özellik çıkarımından önce 256’lık pencere boyutunda en yüksek değer olan %99.64’e ulaşılmıştır. Özellik çıkarımından sonra pencere büyüklükleri arasında ciddi bir fark ölçülmemiştir.

Tablo 4.10. 12K Sürücü sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.028“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	0	0	284	286	50.17	0	100
256	141	0	1	143	99.64	99.29	100
512	46	36	25	35	57.04	64.78	49.29
1024	2	0	33	36	53.52	5.71	100
Ortalama					65.09	42.44	87.32
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	282	3	2	283	98.77	99.29	98.95
256	142	0	0	143	100	100	100
512	71	0	0	71	100	100	100
1024	35	0	0	36	100	100	100
Ortalama					99.69	99.82	99.73

12K Fan sonu, bilye konumunda yük 1 için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.11’de gösterilmiştir. Yapılan çalışmada özellik çıkarımı olmadan ortalama doğruluk değeri %54.89 olarak hesaplanırken özellik çıkarımı sonrası bu değer %94.36’ya yükselmiştir. Özellik çıkarımı ağın performansını arttırmıştır.

Tablo 4.11. 12K Fan sonu, bilye konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	285	283	0	0	50.17	100	0
256	3	1	140	140	50.35	2.09	99.29
512	42	19	29	52	66.19	59.15	73.23
1024	4	2	31	33	52.85	11.42	94.28
Ortalama					54.89	43.16	66.7
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	262	8	23	275	94.54	91.92	96.49
256	139	2	4	139	99.29	97.2	98.58
512	67	3	4	68	95.07	94.36	95.77
1024	30	3	5	32	88.57	85.71	91.42
Ortalama					94.36	92.29	95.56

Tablo 4.12. 12K Fan sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	284	0	0	50	100	0
256	142	142	0	0	50	100	0
512	0	0	71	71	50	0	100
1024	12	8	23	27	55.71	34.28	77.14
Ortalama					51.42	58.57	44.28
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	257	28	27	256	90.31	90.49	90.14
256	134	4	8	138	95.77	97.2	98.58
512	70	1	0	71	99.29	98.59	100
1024	35	0	0	35	100	100	100
Ortalama					96.34	74.32	97.18

12K Fan sonu, iç bilezik konumunda yük 1 için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.12’de gösterilmiştir. IY-UKSB ağında özellik çıkarımı olmadan ulaşılan doğruluk değeri %51.42 olarak elde edilmiştir. Aynı ağ anlık frekans ve spektral entropi ile özellik çıkarımından sonra %96.34 ortalama doğruluk değerine ulaşmıştır. Farklı pencere büyüklüklerinin doğruluk performansına etkisi gözlemlenmemiştir.

12K Fan sonu, dış bilezik (@3:00) konumunda yük 1 için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.13'te gösterilmiştir. Yapılan deneysel çalışmada özellik çıkarımından önce elde edilen ortalama doğruluk değeri %49.29, özellik çıkarımı ağı eklendikten sonra %96.47 olarak elde edilmiştir.

Tablo 4.13. 12K Fan sonu, dış bilezik (@3:00) konumunda yük bir değeri için 0.007“ ve 0.014“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	284	0	0	50	100	0
256	0	0	142	142	50	0	100
512	30	34	41	37	47.18	42.25	52.11
1024	0	0	35	35	50	0	100
Ortalama					49.29	35.56	63.02
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	247	23	37	261	89.43	86.97	91.9
256	139	3	3	139	97.88	97.88	97.88
512	70	1	1	70	98.59	98.59	98.59
1024	35	0	0	35	100	100	100
Ortalama					96.47	95.86	97.09

12K Fan sonu, bilye konumunda yük 1 için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.14'te gösterilmiştir. Özellik çıkarımı uygulanmadan ağın performansı %54.14 ortalama doğruluk değerine ulaşırken ağ özellik çıkarımı ile modifiye edildikten sonra %97.47 doğruluk değerine ulaşmıştır. Çeşitli pencere büyüklüklerinde ağın ortalama doğruluk değerinde yüksek farklılıklar gözlemlenmemiştir.

12K Fan sonu, iç bilezik konumunda yük 1 için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.15'te gösterilmiştir. IY-UKSB ağı özellik çıkarımı ile modifiye edilmeden önce ortalama %61.62 doğruluk değerine sahipken özellik çıkarımı ile ağ yenilendikten sonra % 99.2 ortalama doğruluk değerine sahiptir. Anlık frekans ve spektral entropinin ağı eklenmesi ağın ortalama doğruluk, duyarlılık ve seçicilik değerlerini arttırdığı gözlemlenmiştir.

Tablo 4.14. 12K Fan sonu, bilye konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	284	283	0	0	47.65	100	0
256	90	94	52	47	65.01	63.38	33.33
512	50	50	21	21	50	70.42	29.57
1024	10	5	25	30	57.14	28.57	85.71
Ortalama					54.95	83.16	37.15
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	271	14	13	269	95.26	95.42	95.05
256	139	1	2	140	98.93	98.58	99.29
512	71	0	0	71	100	100	100
1024	34	2	1	33	95.71	97.14	94.28
Ortalama					97.47	97.78	97.15

Tablo 4.15. 12K Fan sonu, iç bilezik konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	0	0	284	284	50	0	100
256	142	142	0	0	50	100	0
512	64	0	7	71	95.07	90.14	100
1024	5	4	30	31	51.42	14.28	88.57
Ortalama					61.62	51.1	72.14
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	281	5	3	279	98.59	98.94	98.23
256	139	0	3	142	99.64	97.88	99.29
512	69	0	2	71	98.59	97.18	100
1024	35	0	0	35	100	100	100
Ortalama					99.2	98.5	99.38

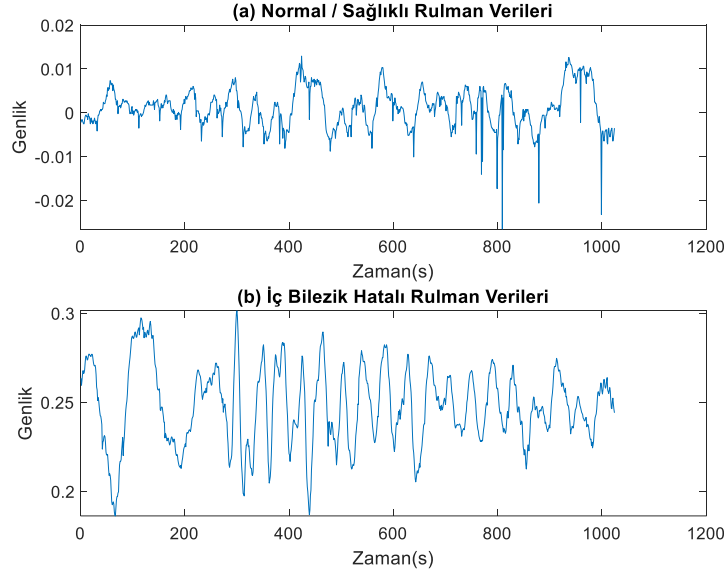
12K Fan sonu, dış bilezik (@3:00) konumunda yük 1 için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma sonuçları Tablo 4.16’da gösterilmiştir. Özellik çıkarımı IY-UKSB ağına eklenmeden önce ağın ortalama doğruluk değeri %61.03 olarak elde edilmiştir. Ağa özellik çıkarımı eklendikten sonra performansı artmış ve ortalama doğruluk değeri % 99.2 olarak elde edilmiştir.

Tablo 4.16. 12K Fan sonu, dış bilezik (@3:00) konumunda yük bir değeri için 0.007“ ve 0.021“ hata büyüklükleri için sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	0	0	283	284	47.65	0	100
256	142	142	0	0	50	100	0
512	64	0	7	71	95.07	90.14	100
1024	5	4	30	31	51.42	14.28	88.57
Ortalama					61.03	51.1	72.14
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	281	5	3	279	98.59	98.94	98.23
256	139	0	3	142	99.64	97.88	100
512	69	0	2	71	98.59	97.18	100
1024	35	0	0	35	100	100	100
Ortalama					99.2	98.5	99.55


4.2.Mendeley Rulman Titreşim Veriseti ile Yapılan Deneyler

Bu çalışmanın devamında Mendeley veri tabanından alınan normal ve hatalı çalışan rulman titreşim verileri kullanılmıştır. Mendeley veri tabanından alınan veriler IY-UKSB derin sinir ağları ile otomatik sınıflandırılması için bir model oluşturulmuştur. Bu çalışmada gerçekleştirilen deneysel çalışmalar, Intel(R) Core (TM) i7-9750H CPU @ 2.60GHz 2.60 GHz işlemci, 16GB bellek ve NVIDIA Geforce GTX 1160 Ti ekran kartına sahip Windows 10 işletim sistemiyle çalışan bir bilgisayarda gerçekleştirilmiştir. MATLAB programlama dili çalışmalar geliştirilmiştir. Mendeley veri seti ile yürütülen çalışmada, deneysel analizler için kullanılan veriler iki farklı gruba ayrılarak 128, 256, 512 ve 1024'lük pencerelere bölünmüştür. Şekil 4.2.'de (a) birinci grupta normal rulman verisinin titreşimi analizi görselleştirilmiştir ve (b) ikinci grupta iç bilezik hatası bulunan rulmana ait titreşim verisinin analizi görselleştirilmiştir. Seçilen rulmanın hız durumu artan olarak belirlenmiştir. Veriler 1024'lük pencerelere ayrılmıştır.




Şekil 4.12. (a) Normal rulman verileri ve (b) İç bilezik hatalı rulmana ait 1024'lük pencere genişliğinde iken alınan titreşim sinyalleri

Mendeley verileri 128, 256, 512 ve 1024'lük pencere genişliğine ayrılmıştır. Özellik çıkarımı uygulamadan önce veriler UKSB ağına verilmiştir. Mendeley verisetinin %70 i eğitim verisi olarak seçilirken %30' u test verisi olarak ayrılmıştır. Analiz sonucundaki verilerin doğruluk ve kayıp değerleri kaydedilmiştir. Şekil 4.13'te normal rulman veriseti ile iç bilezik hatalı verisetinin artan hız koşu altında UKSB ağındaki eğitimin doğruluk ve kayıp değerleri verilmiştir.



Şekil 4.13. Özellik çıkarımından önce İY-UKSB doğruluk ve kayıp değerleri

Sonuçlar kaydedildikten sonra ağa çeşitli özellik çıkarım yöntemleri eklenerek ağ güçlendirilmiştir. Spektral entropi ve anlık frekans ağa özellik olarak eklenmiştir. Özellik çıkarımının etkisini gözlemlemek için ağ yeniden kurulmuştur. Yenilenen modelde doğruluk ve kayıp değerleri kaydedilmiştir. Şekil 4.14'te üzerinde çalışılan örneğin özellik çıkarımından sonra doğruluk ve kayıp grafikleri verilmiştir.



Şekil 4.14. Özellik çıkarımından sonra IY-UKSB doğruluk ve kayıp değerleri

Normal çalışan rulman ve iç bilezik hatası bulunan rulman verisetine ait çalışmanın test sonuçları Tablo 4.17'de gösterilmiştir. Özellik çıkarımdan önce ortalama %78.66 oranında doğruluk değeri elde edilmiştir. Derin öğrenme ağına özellik çıkarımı uyguladıktan sonra ortalama doğruluk değeri %99.3 olarak elde edilmiştir.

Tablo 4.17. Normal çalışan rulman ve iç bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	2965	793	1783	3895	72.7	62.44	83.08
256	1893	633	451	1731	76.97	80.75	73.22
512	859	152	313	1020	80.16	73.29	87.03
1024	470	62	116	524	84.81	80.2	89.41
Ortalama					78.66	74.17	83.18
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	4655	41	21	4647	99.33	99.55	99.12
256	2334	8	9	2336	99.63	99.61	99.65
512	1168	40	0	1172	98.31	100	96.69
1024	586	1	0	585	99.91	100	99.82
Ortalama					99.3	99.79	98.82

Normal çalışan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı Tablo 4.18.'de verilmiştir. Özellik çıkarımı ağa uygulanmadan önce normal çalışan rulman veriseti ile dış bilezik hatası bulunan rulman verisinin ortalama doğruluk değeri %78.22 olduğu görülmüştür. Özellik çıkarımı uygulandıktan sonra ortalama doğruluk değeri %99.93 olarak bulunmuştur. Seçilen bu veriseti için özellik çıkarımından sonra doğruluk değerinin arttığı gözlemlenmiştir.

Tablo 4.18. Normal çalışan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı

Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	2965	799	1783	3889	72.63	62.44	82.95
256	1893	623	451	1721	77.09	80.75	73.42
512	859	172	313	1000	76.3	73.29	85.32
1024	470	73	116	513	83.87	80.2	87.54
Ortalama					78.22	74.17	82.31
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	4687	2	1	4686	99.96	99.97	99.95
256	2340	3	4	2341	99.85	99.82	99.87
512	1171	1	1	1171	999.91	99.91	99.91
1024	586	0	0	586	100	100	100
Ortalama					99.93	99.93	99.93

Tablo 4.19. İç bilezik hatası bulunan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı


Özellik çıkarımı olmadan IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	3791	1712	897	2971	72.15	80.86	63.44
256	2030	487	314	1857	82.91	86.6	79.22
512	883	364	289	808	72.17	75.34	68.94
1024	453	147	133	439	76.1	77.3	74.91
Ortalama					75.83	80.02	71.63
Anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının performansı							
Pencere boyutu	DP	YP	YN	DN	DG (%)	DY (%)	SC (%)
128	4688	0	0	4688	100	100	100
256	2337	6	7	2338	99.72	99.7	99.74
512	1171	3	1	1169	99.82	99.91	99.74
1024	586	1	0	585	99.91	100	99.82
Ortalama					99.86	99.9	99.82

Tablo 4.9.'da iç bilezik hatası bulunan rulman ve dış bilezik hatası bulunan rulman verisetinin özellik çıkarımı öncesi ve sonrası sınıflandırma performansı verilmiştir. Özellik çıkarımı uygulanamadan önce ortalama doğruluk değeri %75.83 iken bu değer özellik çıkarımı ağı uygulandıktan sonra %99.86 olarak hesaplanmıştır.



5. TARTIŞMA


Tez çalışması kapsamında yürütülen deneysel çalışmalarda, Grafik 5.1.'de görüldüğü gibi, özellik çıkarımı öncesi %62.29 yüzdesi ile en yüksek doğruluk değerine iç bilezik ve dış bilezik konumlarına göre yapılan sınıflandırma elde edilmiştir. Özellik çıkarımı sonrası ise %99.78 yüzdesi ile en yüksek doğruluk değerine bilye ve dış bilezik konumuna göre yapılan sınıflandırmada elde edilmiştir. Belirtilen doğruluk değerleri için sürücü sonundan alınan veriler kullanılmıştır. Motor yükü 1 olarak seçilmiştir. Hata büyüklüğü 0.014“ olan veriler kullanılmıştır.




Grafik 5.1. Hata konumuna göre sınıflandırma doğruluk değerleri

Hata büyüklüğüne göre yapılan sınıflandırma deneylerinde, sürücü sonundan alınan verilerde anlık frekans ve spektral entropi ile özellik çıkarımı sonrası ortalama doğruluk değeri %98.05, ortalama duyarlılık değeri %97.8 ve ortalama seçicilik değeri %97.8 olarak elde edilmiştir. Bu çalışmada anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının hata büyüklüğüne göre seçilen rulman titreşim verilerinin sınıflandırılmasında performansının yüksek olduğu gözlemlenmiştir. Verilerin farklı pencere boyutlarında sınıflandırılmasında ağın performansının belirgin bir şekilde değişmediği gözlemlenmiştir.

Fan sonundan alınan verilerde özellik çıkarımı ile birlikte IY-UKSB ağının ortalama %98.05 doğruluk, %92.87 duyarlılık ve %97.65 seçicilik değerlerine ulaştığı kaydedilmiştir. Fan sonundan alınan verilerde de anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının hata büyüklüğüne göre rulman titreşim verilerinin sınıflandırılmasında performansın yüksek olduğu gözlemlenmiştir.



Grafik 5.2. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri




Grafik 5.3. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri

Grafik 5.2.’de ise, özellik çıkarımı öncesi %72.28 yüzdesi ile en yüksek doğruluk değerine iç bilezik konumundan alınan verilerle yapılan sınıflandırma elde edildiği gösterilmiştir. Özellik çıkarımı sonrası ise en yüksek doğruluk değerine %99.56 yüzdesi ile dış bilezik konumundan alınan sınıflandırmada elde edilmiştir. Belirtilen doğruluk değerleri


için sürücü sonundan alınan veriler kullanılmıştır. Motor yükü 1 olarak seçilmiştir. Hata büyüklüğü 0.007 ve 0.014“ olan veriler kullanılmıştır. Veriler sürücü sonundan alınmıştır.

Grafik 5.3.'de özellik çıkarımı öncesi %100 doğruluk değeriyle bilye konumundan alınan verilerle yapılan sınıflandırma elde edildiği gösterilmiştir. Özellik çıkarımı sonrası ise en yüksek doğruluk değerine %99.69 yüzdesi ile iç bilezik konumundan alınan sınıflandırmada elde edilmiştir. Belirtilen doğruluk değerleri için sürücü sonundan alınan veriler kullanılmıştır. Motor yükü 1 olarak seçilmiştir. Hata büyüklüğü 0.007“ ve 0.028“ olan veriler kullanılmıştır.




Grafik 5.4. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri

Grafik 5.4.'de özellik çıkarımı öncesi %63.92 doğruluk değeriyle iç bilezik konumundan alınan verilerle yapılan sınıflandırma elde edildiği gösterilmiştir. Özellik çıkarımı sonrası ise en yüksek doğruluk değerine 96.47 yüzdesi ile dış bilezik konumundan alınan sınıflandırmada elde edilmiştir. Belirtilen doğruluk değerleri için fan sonundan alınan veriler kullanılmıştır. Motor yükü 1 olarak seçilmiştir. Hata büyüklüğü 0.007“ ve 0.014“ olan veriler kullanılmıştır.



Grafik 5.5. Hata büyüklüğüne göre sınıflandırma doğruluk değerleri




Grafik 5.6. Hata büyüklüğüne göre sonuçların karşılaştırılması

Grafik 5.5.'de özellik çıkarımı öncesi %61.62 doğruluk değeriyle iç bilezik konumundan alınan verilerle yapılan sınıflandırma elde edildiği gösterilmiştir. Özellik çıkarımı sonrası ise en yüksek doğruluk değerine 99.2 yüzdesi ile hem iç bilezik hem de dış bilezik konumundan alınan verilerle yapılan sınıflandırmada elde edilmiştir. Belirtilen

doğruluk değerleri için fan sonundan alınan veriler kullanılmıştır. Motor yükü 1 olarak seçilmiştir. Hata büyüklüğü 0.007 “ ve 0.021“ olan veriler kullanılmıştır.

Grafik 5.6.’de sürücü sonu ve fan sonundan alınan veriler kullanılarak yapılan sınıflandırmanın doğruluk değerleri karşılaştırılmıştır. Sürücü sonundan alınan veriler ile yapılan sınıflandırma bilye ve dış bilezik hatası bulunan rulmanlarda sürücü sonuna göre daha yüksek doğruluk değeri ile tespit edilmiştir. İç bilezik hatası bulunan ve fan sonundan alınan verilerde ise sürücü sonundan alınan verilere göre daha yüksek doğruluk değerlerine ulaşıldığı gözlemlenmiştir. Yapılan sınıflandırma çalışmasında 0.007“ ile 0.014“ hata değerlerine sahip veriler kullanılmıştır.




Grafik 5.7. Hata büyüklüğüne göre sonuçların karşılaştırılması

Grafik 5.7.’de açık yeşil ile gösterilen alanlarda hata büyüklüğü 0.007“ ve 0.014“ olan verilerin sınıflandırılması yapılmıştır. Koyu yeşil alanlarda ise alanlarda hata büyüklüğü 0.007“ ve 0.028“ olan verilerin sınıflandırılması yapılmıştır. Hata miktarı arasındaki fark arttıkça hem bilye konumundan alınan verilerde hem de iç bilezik konumundan alınan verilerde sınıflandırma doğruluk değerlerinin arttığı grafikte gözlemlenmiştir.

Mendeley rulman titreşim veriseti ile yapılan çalışmalarda anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının ortalama doğruluk, duyarlılık ve seçicilik değerlerinin %98’in üzeri olduğu hesaplanmıştır. Mendeley veriseti için anlık frekans ve spektral entropi ile özellik çıkarımı olmadan da IY-UKSB ağının hatalı ve normal rulman

titreşim verilerinin sınıflandırılmasında yüksek performansla çalıştığı gözlemlenmiştir. Çeşitli pencere büyüklüklerinin deneysel çalışmada farklı sonuçlar ürettiği gözlemlenmemiştir.



Grafik 5.8. Hata konumuna göre sınıflandırma doğruluk değerleri

Grafik 5.8.'de görüldüğü gibi, özellik çıkarımı öncesi en düşük değer % 75.83 doğruluk değeri ile iç bilezik ve dış bilezik hatalı sınıflandırma çalışmasında elde edilmiştir. Özellik çıkarımından sonra doğruluk değeri %99.86'ye yükseldiği görülmüştür. Özellik çıkarımı sonrasında verilerin sınıflandırılmasında ağırlık performansının arttığı gözlemlenmiştir.

6. SONUÇ

Bu tez çalışmasında yapılan deneylerde, asenkron motor rulman hatasının belirlenmesi ve sınıflandırılması için IY-UKSB ağı tabanlı bir yaklaşım kullanılmıştır. İki ayrı verisetinde yürütülen deneysel çalışmalar için, titreşim verilerinden anlık frekans ve spektral entropi ile özellik çıkarımı yapılarak, önerilen yaklaşımın sınıflandırma doğruluğunun artırılması sağlanmıştır.

Tez çalışmasında, CWRU verisetindeki rulmanlar farklı büyüklüklerde hatalara sahiptir. Bu verisetinde, sağlıklı ve hatalı rulman verilerinden oluşturulan veriseti üzerinde 128, 256, 512 ve 1024 pencere büyüklüklerinde test kümesi üzerinde IY-UKSB ağının doğruluğunun ortalama %60 civarında kaldığı gözlemlenmiştir. Sağlıklı ve sağlıklı rulman verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı sonrasında IY-UKSB ağının ortalama doğruluğunun CWRU verisetinde %95'in üzerine çıktığı tespit edilmiştir. Aynı şekilde, sağlıklı (normal) ve sağlıklı (hatalı) rulmanlara ait titreşim verileri 128, 256, 512 ve 1024 gibi farklı boyutlarda pencere genişliklerinde IY-UKSB ağının doğruluğunun Mendeley Rulman Titreşim verisetinde ise ortalama %75 civarında olduğu hesaplanmıştır. Normal ve hatalı rulman verilerinin sınıflandırılmasında anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının ortalama doğruluğunun Mendeley Rulman Titreşim verisetinde ise %99'un üzerinde olduğu görülmüştür.

Sonuç olarak, bu tez çalışmasında, anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının hatalı ve normal rulman titreşim verilerinin sınıflandırılmasında güçlü bir ayırım imkânı sağladığı gözlemlenmiştir. Ayrıca her iki verisetinde de sınıflandırma performansına farklı boyuttaki pencere büyüklüklerinin (128, 256, 512 ve 1024) ciddi bir farklılık yaptığı gözlemlenmemiştir. CWRU verisetinde hata konumuna göre yapılan sınıflandırma deneylerinde anlık frekans ve spektral entropi ile özellik çıkarımı sonrası IY-UKSB ağının ortalama doğruluk değeri %98.67, ortalama duyarlılık değeri %98.16 ve ortalama seçicilik değeri %98.63 değerlerine ulaştığı hesaplanmıştır.

KAYNAKÇA

- Abbasion, S., Rafsanjani, A., Farshidianfar, A., & Irani, N.** (2007). Rolling element bearings multi-fault classification based on the wavelet denoising and support vector machine. *Mechanical systems and signal processing*, 21(7), 2933-2945.
- Akkurt, İ., & Arabacı, H.** (2019). Sürücüden Beslenen Asenkron Motorlarda Rulman Arızalarının Stator Akımı Kullanarak Tespiti. *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 1(2), 122-134.
- Aksu, H.** (2019). *Silindirik Makaralı Rulmanlarda Elastohidrodinamik Film Kalınlığının Teorik Olarak İncelenmesi*. (Yüksek Lisans Tezi). Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Konstrüksiyon Ve İmalat Anabilim Dalı, Bursa.
- Al-Musawi, A., K., Anayi, F., & Packianather, M.** (2020). Three-Phase Induction Motor Fault Detection Based On Thermal Image Segmentation. *Infrared Physics & Technology*, 104, 103140.
- Amar, M., Gondal, I., & Wilson, C.** (2014). Vibration spectrum imaging: A novel bearing fault classification approach. *IEEE transactions on Industrial Electronics*, 62(1), 494-502.
- Arslan, H., Orhan, S., & Aktürk, N.** (2003). Bilyalı Rulman Hasarlarının Neden Olduğu Titreşimlerin Modellenmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 18(4), 123-146.
- Ayaz, E.** (2003). *Elektrik Motorlarında Dalgacık Analizi Yaklaşımı ile Rulman Arıza Tanısı Veve Yapay Zeka Tabanlı Bir Durum İzleme Sistemi*. (Doktora Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bae, H., Kim, Y. T., Lee, S. H., Kim, S., & Lee, M. H. vd.** (2005). Fault Diagnostic of Induction Motors For Equipment Reliability and Health Maintenance Based Upon Fourier and Wavelet Analysis. *Artificial Life Robotics*, 9, 112-116.
- Bayram, S., Kaplan, K., Kuncan, M. & Ertunç, H. M.** (2013). Bilyeli Rulmanlarda Zaman Uzayında İstatistiksel Öznitelik Çıkarımı Ve Yapay Sinir Ağları Metodu İle Hata Boyutunun Kestirimi. *Paper Presented At The Otomatik Kontrol Ulusal Toplantısı*, 26-28 Eylül 2013, Malatya.
- Benbouzid, M.** (1999). Bibliography On Induction Motors Faults Detection And Diagnosis. *IEEE Transactions On Energy Conversion*, 25 Temmuz 14(4), 1065-1074.
- Benbouzid, M., & Kliman, G., B.** (2003). What Stator Current Processing-Based Technique To Use For Induction Motor Rotor Faults Diagnosis?. *IEEE Transactions On Energy Conversion*, 28 Mayıs, 18(2), 238-244.
- Biçer, A.** (2019). *MR spektroskopisi verileri üzerinde beyin tümörlerinin bilgisayar destekli otomatik sınıflandırılması*. (Yüksek Lisans Tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü., Bilecik.
- Case Western Reserve University (CWRU).** (2021). Case Western Reserve University Bearing Data Center. [Erişim: 27.11.2021, <https://engineering.case.edu/bearingdatacenter>].
- Chapman, S., J.,** (2007). *Elektrik Makinealarının Temelleri*. 380. (Çev.) Erhan Akın Akın, E., & Ahmet OrhanOrhan, A., Çağlayan Kitabevi, İstanbul.

- Chen, X., Zhang, B., & Gao, D.** (2021). Bearing fault diagnosis base on multi-scale CNN and LSTM model. *Journal of Intelligent Manufacturing*, 32, 971-987.
- Çalış, A., Çakır, A., & Dandil, E.vd.** (2013). Artificial immunity-based induction motor bearing fault diagnosis. *Turkish Journal of Electrical Engineering and Computer Science*, 21(1), 1-25.
- Dal, B.** (2022). *Asenkron motorlarda rulman hatalarının erken tespiti için 1B-evrimsel sinir ağının FPGA üzerinde uygulaması.* (Yüksek Lisans Tezi). İzmir Ekonomi Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı, İzmir.
- Dandil, E.** (2010). *Yapay Bağışıklık ile Asenkron Motor Hata Teşhisi.* (Yüksek Lisans Tezi). Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- Dandil, E., & Karaca, S.** (2020). MR Spektroskopi Sinyalleri Kullanılarak LSTM Derin Sinir Ağları ile Beyinde Sahte Tümörlerin Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 426-433.
- Demir, H. G., & Müştak, O.** (2021). Rulman Hasarlarının Titreşim ve Gürültü Analizi ile Tespiti. *Avrupa Bilim ve Teknoloji Dergisi* (25), 571-581.
- Dükkancı, A.** (2019). *Rulman Arızalarının Makine Öğrenmesi Teknikleri Kullanılarak Sınıflandırılması.* (Yüksek Lisans Tezi). Mehmet Akif Ersoy Üniversitesi, Fen Bilimleri Enstitüsü Malzeme Teknolojileri Mühendisliği Anabilim Dalı, Burdur.
- Electrical Technology** (2022). Three-Phase Induction Motor, Construction, Working, Types & Applications. [Erişim: 10.04.2022, <https://www.electricaltechnology.org/2020/05/three-phase-induction-motor.html>].
- Eren, L., Ince, T., & Kiranyaz, S.** (2019). A Generic İntelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN classifier. *Journal of Signal Processing Systems*, 91(2), 179-189.
- Fidan, H.,** (2006). *Dalgacık Dönüşümü Tekniği ile Motor Arıza Tespiti.* (Yüksek Lisans Tezi). Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Elektronik Bilgisayar Eğitimi Anabilim Dalı, Isparta.
- Fitzgerald, A., E., Kingsley, C., & Umans, S. D.** (2014). *Elektrik Makineleri.*: 183., (Çev.) Sırrı Sunay Gürleyük., Palme Yayıncılık, Ankara.
- Gangsar, P., & Tiwari, R.** (2019). A Support Vector Machine Based Fault Diagnostics Of Induction Motors For Practical Situation Of Multi-Sensor Limited Data Case. *Measurement*, 135, 694–711.
- Gao, X., & Ovaska, S.** (2001). Soft Computing Methods in Motor Fault Diagnosis. *Applied Soft Computing*, 1, 73-81.
- Graves, A., Mohamed, A. R., & Hinton, G.** (2013). Speech recognition with deep recurrent neural networks. *IEEE international conference on acoustics.*, pp. 26-31 Mayıs, Kanada6645-6649.
- Herborn, K., A., McElligott, A. G., Mitchell, M. A., Sandilands, V., Bradshaw, B., & Asher, L.** (2020). Spectral Entropy Of Early-Life Distress Calls As An İlceberg İndicator Of Chicken Welfare. *J. R. Soc. Interface*, 17(167), 2020008617: 20200086.

- Hochreiter, S., & Schmidhuber, J.** (1997). Long Short-Term Memory. *Neural computation*, 9(8), 1735-1780.
- Huang, H., & Baddour, N.** (2018). Bearing vibration data collected under time-varying rotational speed conditions. *Data in brief*, 21, 1745-1749.
- Huang, N., E., Wu, Z., Long, S. R., Arnold, K. C., Chen, X., & Blank, K.** (2009). On Instantaneous Frequency. *Advances In Adaptive Data Analysis*, 1(02), 177-229.
- Hwang, D., H., Youn, Y. W., Sun, J. H., Choi, K. H., Lee, J. H., & Kim, Y. H.** (2015). Support Vector Machine Based Bearing Fault Diagnosis For Induction Motors Using Vibration Signals. *Journal of Electrical Engineering and Technology*, 10(4), 1558-1565.
- Immovilli, F., Lippi, M., & Cocconcelli, M.** (2019). Automated bearing fault detection via long short-term memory networks. *IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives*, 27-30 Ağustos, Fransa.
- İpek, S. N.** (2019). *Analysis Of Resonance Overvoltages İn Medium Voltage Level With Six-Step İnduction Motor Drive.* (Yüksek Lisans Tezi)., Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Jalayer, M., Orsenigo, C., & Vercellis, C.** (2021). Fault detection and diagnosis for rotating machinery: A model based on convolutional LSTM, Fast Fourier and continuous wavelet transforms. *Computers in Industry*, 125, 103378.
- Kaplan, K., Kaya, Y., Kuncan, M., Minaz, M. R., & Ertunç, H. M.** (2020). An Improved Feature Extraction Method Using Texture Analysis With LBP For Bearing Fault Diagnosis. *Applied Soft Computing*, 87, 106019.
- Karaçay, T.** (2006). *Açısal temaslı rulmanlarla yataklanmış şaftların dinamiği ve rulman hatalarının deneysel analizi.* (Doktora Tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, akine Mühendiliği Ana Bilim Dalı, Ankara.
- Karahan, M. F.** (2005). *Titreşim Analizi ile Makinalarda Arıza Teşhisi.* (Yüksek Lisans Tezi). Celal Bayar Üniversitesi, Fen Bilimleri Enstitüsü, Makina Mühendisliği Anabilim Dalı, Manisa.
- Kartal, M. Y.** (2018). *3 Faz Asenkron Motor Verimlilik ve Yenileme Karlılık Analizi.* (Yüksek Lisans Tezi). Muğla Sıtkı Koçman Üniversitesi, Fen Bilimleri Enstitüsü, Muğla.
- Kayaalp, K.** (2007). *Asenkron Motorlarda Veri Madenciliği İle Hata Tespiti.* (Yüksek Lisans Tezi). Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Elektronik Bilgisayar Eğitimi Anabilim Dalı, Isparta.
- Kılıç, R. H. & Dandıl, E.** (2021). Asenkron Motor Rulman Hatalarının Uzun-Kısa Süreli Bellek Tipi Derin Sinir Ağları ile Otomatik Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 508-513 .
- Kim, Bae., H., Kim, Y. T., Lee, S. H., Kim, S., & Lee, M. H.** (2005). Fault Diagnostic of Induction Motors For Equipment Reliability and Health Maintenance Based Upon Fourier and Wavelet Analysis. *Artificial Life Robotics*, 9, 112-116.
- Kompella, K., D., Mannam, V. G. R., & Rayapudi, S. R.** (2016). DWT based bearing fault detection in induction motor using noise cancellation. *Journal of Electrical Systems and Information Technology*, 3(3), 411-427.

Konar, P., & Chattopadhyay, P. (2011). Bearing Fault Detection Of İnduction Motor Using Wavelet And Support Vector Machines (SVMs). *Applied Soft Computing*, 11(6), 4203-4211.

Kuncan, M., Kaplan, K., Minaz, M. R., Kaya, Y., & Ertunç, H. M. (2020). A Novel Feature Extraction Method For Bearing Fault Classification With One Dimensional Ternary Patterns. *ISA Transactions* 100, 346–357.

Lessmeier, C., Kimotho, J. K., Zimmer, D., & Sextro, W. (2016). Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification. In *PHM Society European Conference*, Almanyana.

Mendel, E., Rauber, T. W., Varejão, F. M., & Batista, R. J. (2009). Rolling Element Bearing Fault Diagnosis İn Rotating Machines Of Oil Extraction Rigs. *17th European Signal Processing Conference*, 24-28 Ağustos, Birleşik Krallık, pp. 1602-1606.

Mendeley Data (2021). Bearing Vibration Data under Time-varying Rotational Speed Conditions. [Erişim:01.11.2021, <https://data.mendeley.com/datasets/v43hmbwxpm/1>].

Mohammed L., M. (2021). *Üç fazlı asenkron motorun STM32 kullanılarak kontrolü ve analizi.* (Yüksek Lisans Tezi)., Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.

Mustafa, M., Taib, M. N., Murat, Z. H., Sulaiman, N., & Aris, S. A. M. (2011). Classification Of EEG Spectrogram İmage With ANN Approach For Brainwave Balancing Application. *Int J Simul Syst Sci Technol* 12:29–36.

Palácios, R. H. C., da Silva, I. N., Goedel, A., & Godoy, W. F.odrigo H., (2016). A Novel Multi-Agent Approach To İdentify Faults İn Line Connected Three-Phase İnduction Motors. *Applied Soft Computing* 45, 1–10.

Sabeti, M., Katebi, S., & Boostani, R. (2009). Entropy and complexity measures for EEG signal classification of schizophrenic and control participants. *Artificial intelligence in medicine*, 47(3), 263-274.

Sadeghi, R. Samet, H., & Ghanbari, T. (2019). Detection of Stator Short-Circuit Faults in Induction Motors Using the Concept of Instantaneous Frequency Detection of Stator Short-Circuit Faults in Induction Motors Using the Concept of Instantaneous Frequency. *IEEE Transactions On Industrial Informatics*, 15(8), 4506-4515.

Sak, H., Senior, A., & Beaufays, F. (2014). Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128.ng*.

Schuster, M., & Paliwal, K., K. (1997). Bidirectional Recurrent Neural Networks. *IEEE Transactions On Signal Processing*, 45(11), 2673-2681.

Shannon, C. E. (1948). A mathematical theory of communication. *The Bell system technical journal*, 27(3), 379-423.

Stuner, B., Chatelain, C., & Paquet, T. (2020). Handwriting Recognition Using Cohort Of LSTM And Lexicon Verification With Extremely Large Lexicon. *Multimedia Tools And Applications*, 79(45), 34407-34427.

Şerifoğlu N. (2007a). *Elektrik Makinaları Senkron Makinalar ve Doğru Akım Makinaları: 100*, Nobel Yayın Dağıtım, Ankara.

- Şerifoğlu N.** (2007b). *Elektrik Makinaları Transformatörler ve Asenkron Makinalar : 1*, Nobel Yayın Dağıtım, Ankara.
- Thorsen, O., V., & Dalva, M., A.** (1995). Survey Of Faults On Induction-Motors In Offshore Oil Industry, Petrochemical Industry, Gas Terminals, And Oil Refineries. *IEEE transactions on industry applications*, IEEE Trans. Ind. Appl. 1995, 31(5), 1186–1196.
- Tian, Y., Zhang, K., Li, J., Lin, X., & Yang, B.** (2018). LSTM-based traffic flow prediction with missing data. *Neurocomputing*, 318, 297-305.
- Toma, R. N., Prosvirin, A. E., & Kim, J. M.** (2020). Bearing Fault Diagnosis Of Induction Motors Using A Genetic Algorithm And Machine Learning Classifiers. *Sensors*, 20(7), 1884.
- Toma, R., N., & Kim, J., M.** (2020). Bearing Fault Classification of Induction Motors Using Discrete Wavelet Transform and Ensemble Machine Learning Algorithms. *Applied Sciences Appl. Sci.* 2020, 10(15), 5251.
- Toraman, S.** (2016). *Kızılötesi Spektroskopisi Kullanılarak Kan Örneklerinden Kolon Kanserine Yönelik Özellik Çıkarımı*. (Doktora Tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü, ElazığDoktora Tezi.
- Udmale, S., S., & Singh, S., K.** (2019). Application of Spectral Kurtosis and Improved Extreme Learning Machine for Bearing Fault Classification. *IEEE Transactions On Instrumentation And Measurement*, 68(11), 4222-4233.
- Ünsal, A., & Karakaya, O.** (2015). Asenkron Motor Rotor Arızalarının Analizi. *Journal of Science and Technology of Dumlupınar University* (034), 69-86.
- Wang, Z., Zhou, J., Wang, J., Du, W., Wang, J., Han, X., & He, G.** (2019). A novel fault diagnosis method of gearbox based on maximum kurtosis spectral entropy deconvolution. *IEEE Access*, 7, 29520-29532.
- Waziralilah, N. F., Abu, A., Lim, M. H., Quen, L. K., & Elfakharany, A.** (2019). A Review on Convolutional Neural Network in Bearing Fault Diagnosis, *MATEC Web of Conferences*, 16 Ocak 2019.
- Yeh, C. C., Sizov, G. Y., Sayed-Ahmed, A., Demerdash, N. A., Povinelli, R. J., Yaz, E. E., & Ionel, D. M.** (2008). A reconfigurable motor for experimental emulation of stator winding interturn and broken bar faults in polyphase induction machines. *IEEE transactions on energy conversion*, 23(4), 1005-1014.
- Yeşilyurt, İ., & Özdemir, Ö.** (2015). Dengesiz Yüke Maruz Silindirik Masuralı Rulman Arızasının Kısa Zamanlı Fourier Dönüşümü Yardımıyla Belirlenmesi. *Uluslararası Katılımlı 17. Makina Teorisi Sempozyumu*, 14-17 Haziran, İzmir17, 1-8.
- Yıldırım, S.,** (2006). *Arıza Teşhisinde Destek Vektör Makinelerinin Kullanımı*. (Yüksek Lisans Tezi). Fırat Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Elazığ.
- Yu, R., Gao, J., Yu, M., Lu, W., Xu, T., Zhao, M., & Zhang, Z.** (2019). LSTM-EFG For Wind Power Forecasting Based On Sequential Correlation Features. *Future Generation Computer Systems*, 93, 33-42.

Yüksel, A. S., & Atmaca, Ş., (2019). Sürücü Davranışlarının Makine Öğrenmesi Algoritmaları ile Sınıflandırılmasında Pencereleme Yönteminin Etkisi. *Teknik Bilimleri Dergisi*, 9(2), 75-80.

Zarei, J. (2012). Induction Motors Bearing Fault Detection Using Pattern Recognition Techniques. *Expert systems with Applications*, 39(1), 68-73.

Zarei, J., Tajeddini, M. A., & Karimi, H. R. (2014). Vibration analysis for bearing fault detection and classification using an intelligent filter. *Mechatronics*, 24(2), 151-157.

Zheng, Z. & Xin G. (2019). Fault Feature Extraction of Hydraulic Pumps Based on Symplectic Geometry Mode Decomposition and Power Spectral Entropy. *Entropy* 21, 476.

