

**NASA RULMAN VERİSETİYLE GELİŞMİŞ DERİN
TRANSFER ÖĞRENME
YÖNTEMLERİ KULLANARAK RULMAN
HATALARININ ETKİN TESPİTİ**

Mert ÇELTİKOĞLU



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**NASA RULMAN VERİSETİYLE GELİŞMİŞ DERİN TRANSFER ÖĞRENME
YÖNTEMLERİ KULLANARAK RULMAN HATALARININ ETKİN TESPİTİ**

Mert ÇELTİKOĞLU
0000-0003-0509-9815

Doç. Dr. Pınar KIRCI
(Danışman)

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2023
Her Hakkı Saklıdır.

TEZ ONAYI

Mert ÇELTİKOĞLU tarafından hazırlanan “NASA RULMAN VERİSETİYLE GELİŞMİŞ DERİN TRANSFER ÖĞRENME YÖNTEMLERİ KULLANARAK RULMAN HATALARININ ETKİN TESPİTİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Pınar KIRCI

Başkan : Doç. Dr. Pınar KIRCI
0000-0002-0442-0235
Uludağ Üniversitesi,
Mühendislik Fakültesi,
Bilgisayar Mühendisliği Anabilim Dalı

İmza

Üye : Prof. Dr. Özgür Koray ŞAHİNGÖZ
0000-0002-1588-8220
İstanbul Biruni Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi,
Bilgisayar Anabilim Dalı

İmza

Üye : Doç. Dr. Gıyasettin ÖZCAN
0000-0002-1166-5919
Uludağ Üniversitesi,
Mühendislik Fakültesi,
Bilgisayar Mühendisliği Anabilim Dalı

İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././....

U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

16/02/2023

Mert ÇELTİKOĞLU

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığını ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Doç. Dr. Pınar KIRCI
16.02.2023

Mert ÇELTİKOĞLU
16.02.2023

ÖZET

Yüksek Lisans

NASA RULMAN VERİSETİYLE GELİŞMİŞ DERİN TRANSFER ÖĞRENME
YÖNTEMLERİ KULLANARAK RULMAN HATALARININ ETKİN TESPİTİ

Mert ÇELTİKOĞLU

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Pınar KIRCI

Endüstri alanında firmalar üretim faaliyetlerini gösterirken birçok makine kullanmaktadır. Bu makinelerin devamlılığının sağlanması ve oluşabilecek hata durumlarının doğru ve zamanında teşhis edilmesi firmalar açısından hayati önem taşımaktadır. Bu nedenle makine rulmanlarına belirli periyotlarda veya ihtiyaç dahilinde bakım yapılmalıdır.

Bu çalışmada, rulmanlarda oluşabilecek bozulmaların son yıllarda dikkat çeken sinir ağları teknikleri ile önceden tespiti üzerine bir analiz ve yaklaşım sunulmuştur. Bu noktada NASA Rulman Veriseti içerisinde bulunan rulman titreşim sinyalleri analiz edilirken, transfer öğrenme, derin öğrenme ve zaman-frekans dönüşümleri gibi teknolojileri içinde kullanan Evrişimli Sinir Ağları (ESA) kurulan sistemi doğrulamak için kullanılmıştır. NASA rulman veri seti içerisinde normal durum, dış bilezik yuvarlanma yolu hasarı, iç bilezik yuvarlanma yolu hasarı ve bilye hasarı durumlarına ait titreşim sinyalleri mevcuttur. Bu titreşim sinyalleri 2-Boyutlu dönüşüm ile görüntü haline getirilmektedir. 2-Boyutlu görüntüler içerisinden rulman arızalarını sınıflandırmak için AlexNet, GoogLeNet ve ResNet-50 evrişimli sinir ağları yöntemleri kullanılmıştır. Evrişimli sinir ağlarının performansının iyileştirilmesi için ise 2-boyutlu görüntüler zaman-frekans dönüşümleri uygulanmıştır.

Kurulan yapı ile elde edilen sonuçlarla eski çalışmalar karşılaştırıldığında sınıflandırma konusunda önerilen yöntemin ResNet-50 evrişimli sinir ağı modeliyle %99,46 seviyesinde doğruluk oranının olduğu gözlemlenmiştir.

Anahtar Kelimeler: Transfer Öğrenme, Derin Öğrenme, Önleyici Bakım, GoogLeNet, AlexNet, ResNet-50, Evrişimli Sinir Ağları, Rulman Arıza Tespiti, Zaman-Frekans Dönüşümü, NASA Rulman Veri Seti

2023, viii + 73 sayfa.

ABSTRACT

MSc Thesis

EFFECTIVE DETECTION OF BEARING ERRORS USING ADVANCED DEEP TRANSFER LEARNING METHODS WITH NASA BEARING DATASET

Mert ÇELTİKOĞLU

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assoc. Prof. Pınar KIRCI

Industrial companies use many machines during production activities. It is crucial to diagnose failures on occur time for sustainability of the machines. For this reason, periodical maintenance of machine bearings is needed.

In this study, an analysis and approach is presented on the pre-detection of the defects that may occur in bearings by using neural network techniques that takes attention in recent years. All stages in Convolutional Neural Networks such as transfer learning, deep learning and time-frequency transformations were applied on the NASA bearing dataset in order to analyze vibration data. The NASA bearing dataset contains vibration signals for normal state, outer ring raceway damage, inner ring raceway damage and ball damage states. These vibration signals are converted to images by 2D transformation. AlexNet, GoogLeNet and ResNet-50 Convolutional Neural Network methods were used to distinguish and classify bearing failures from 2D images. In order to improve the performance of Convolutional Neural Networks, time-frequency transformations of 2D images are applied.

When the results obtained with the established structure are compared with the previous studies, it was observed that there was a 99.46% validation accuracy by using ResNet-50.

Keywords: Transfer Learning, Deep Learning, Predictive Maintenance, GoogLeNet, AlexNet, ResNet-50, Convolutional Neural Networks, Bearing Fault Diagnostics, Time-Frequency Transformation, NASA Bearing Dataset

2023, viii + 73 pages.

TEŞEKKÜR

Gerçekleştirmiş olduğum tez çalışmamın her aşamasında yaklaşık iki yıl boyunca desteklerini benden esirgemeyen ve yaptığımız her toplantıda bana tecrübelerini aktaran saygıdeğer danışman hocam Doç. Dr. Pınar KIRCI'ya sonsuz teşekkürlerimi sunarım.

Tez çalışmamın gerçekleştirilmesinde her aşamada bana destek sağlayan TEKNOPAR Endüstriyel Otomasyon çalışanlarından Bilgin Umut DEVECİ, Perin ÜNAL, Özlem ALBAYRAK'a sonsuz teşekkürlerimi sunarım.

Makine sektöründe engin tecrübesiyle çalışmamın başından sonuna benden desteklerini esirgemeyen ve her zaman fikir alışverişinde bulunan Bekir KOCA'ya ayrıca teşekkürlerimi sunarım.

Tez çalışmamı bu günlere getirmemde teknik imkanların sağlanması konusunda desteğini benden esirgemeyen CITS Bilişim ve Yazılım A.Ş. firmasına ve tüm çalışma arkadaşlarıma çok teşekkür ederim. Kararsızlıklar yaşadığım konularda yapay zeka konusunda uzman olan çalışma arkadaşlarım Oğuzhan YÜCE ve Utku ASLAN'a ayrıca teşekkür ederim.

Tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili aileme teşekkürlerimi bir borç bilirim.

Yüksek lisansa başvuru sürecinden bu zamana dek desteğini benden hiçbir zaman esirgemeyen ve beni cesaretlendiren sevgili eşim Aylin ÇELTİKOĞLU'na teşekkürlerimi borç bilirim.

Bu tez özlemini derinden hissettiğim, kıymetli babam Suat ÇELTİKOĞLU'na ithaf edilmiştir.

Mert ÇELTİKOĞLU

16/02/2023

İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ.....	1
1.1. Tezin Amacı ve Kapsamı	3
1.2. Tezin Organizasyonu	4
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI	5
2.1. Rulman Hatalarının Etkin Tespitinde Kullanılan Yöntemler	5
2.2. Transfer Öğrenme (Öğrenme Aktarımı)	8
2.3. Derin Öğrenme.....	9
2.4. Zaman-Frekans Dönüşümü (TFT)	10
2.5. Sinir Ağları (Neural Networks).....	12
2.6. Evrişimli Sinir Ağları (ESA) Mimarileri	15
2.6.1. GoogLeNet.....	17
2.6.2. AlexNet	20
2.6.3. ResNet-50.....	23
2.7. Rulman Arıza Tespitinde Evrişimli Sinir Ağları Kullanımı	24
2.7.1. Rulman titreşim analizi	25
2.7.2. Rulman arıza tespiti	25
3. MATERYAL ve YÖNTEM.....	27
3.1. NASA Rulman Titreşim Veri Seti	28
3.1.1. Test mekanizması özellikleri ve genel yapısı.....	29
3.1.2. Genel veri yapısı	30
3.1.3. Veri Yapısı	30
3.2. Evrişimsel Sinir Ağları Süreçlerini Oluşturma	31
3.2.1. Ses sinyallerinin titreşim görüntülerine dönüştürülmesi.....	32
3.2.2. Zaman-frekans dönüşümlerinin uygulanması	32
3.2.3. Evrişimsel sinir ağlarının MATLAB ile uygulanması	47
3.2.4. Rulman arızalarının sınıflandırılması.....	50
4. BULGULAR.....	52
5. TARTIŞMA ve SONUÇ	62
KAYNAKLAR	65
ÖZGEÇMİŞ	73

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

f	Frekans
t	Zaman
$*$	Eşlenik Operatör
$T F(\tau, f)$	Zaman-Frekans Spektrumu
$x(t)$	Analiz Edilen Sinyal
$\psi_f(t)$	İç Çarpım Pencere Fonksiyonu
τ	Zaman Sabiti
$\psi_{\beta, \gamma}$	Mors Dalgacıkları
$\beta\gamma$	Dalgacığın Fourier Alanındaki Bant Genişliği
γ	Dalgacığın Şekli
ω	Radyan Cinst Frekans
s	Zaman Alanında Dalgacığın Sıkıştırılması veya Gerilmesi
$\phi_k(t)$	Anlık Faz
$A_k(t)$	Yavaş Değişen Genlik Bilgisi
η	Frekans İndeksi
P	Cauchy Ana Değeri (Hilbert-Huang)
∂	Dalgacığın Şekli
$g_w(k)$	Sıfır Merkezli Pencere İşlevi
f_w	Bölme Merkezi Frekansı
f_s	Örnekleme Oranı

Kısaltmalar

Açıklama

AA	Alternatif Akım
ADAM	Adaptif Moment Tahmini
AMA	Ampirik Mod Ayırıştırıcı
CNN	Evrişimli Sinir Ağları (Convolutional Neural Networks)
Conv	Evrişim
CQT	Sabit-Q Durağan Olmayan Gabor Dönüşümü
CWRU	Case Western Reserve University
DL	Derin Öğrenme (Deep Learning)
DTSD	Dalgacık Tabanlı Senkron Sıkıştırma Dönüşümü
DVM	Destek Vektör Makinesi
ESA	Evrişimli Sinir Ağları
FTSD	Fourier Tabanlı Senkron Sıkıştırma Dönüşümü
HHD	Hilbert Huang Dönüşümü
IoT	Nesnelerin İnterneti
KZFD	Kısa Zamanlı Fourier Dönüşümü
MFPT	Makine Hatası Önleme Teknolojisi
ML	Makine Öğrenimi (Machine Learning)
NASA Administration)	Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration)
ReLU	Doğrultulmuş Lineer Birim

ResNet	Artık Ağlar (Residual Network)
ROC	Alıcı İşlem Karakteristikleri (Receiver Operating Characteristic)
SDD	Sürekli Dalgacık Dönüşümü
SSD	Senkron Sıkıştırma Dönüşümü
SVM	Destek Vektör Makinesi
Tanh	Tanjant
TFT	Zaman-Frekans Dönüşümü (Time-Frequency Transform)
TL	Transfer Öğrenme (Transfer Learning)
WVD	Wigner-Ville Dağılımı

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Bilyeli rulmanlarda arıza durumlarının olduğu noktalar.....	2
Şekil 1.2. Makine bakım yaklaşımları.....	3
Şekil 2.1. Makine öğrenmesi ve transfer öğrenme arasındaki süreçlerin farklılıkları.....	8
Şekil 2.2. Makine öğrenmesi ve derin öğrenme karşılaştırması.....	10
Şekil 2.3. Zaman-frekans dönüşümünün basit gösterimi.....	12
Şekil 2.4. Sinir ağlarının genel yapısı.....	13
Şekil 2.5. Temel evrişimli sinir ağları mimarisi.....	15
Şekil 2.6. Önceden eğitilmiş ağların karşılaştırılması.....	16
Şekil 2.7. GoogLeNet başlangıç (Inception) bloğu yapısı.....	18
Şekil 2.8. GoogLeNet mimarisi.....	19
Şekil 2.9. AlexNet (sağ) ve LeNet (sol) Mimarileri.....	20
Şekil 2.10. Hiperbolik Tanjant, Sigmoid ve ReLU gösterimleri.....	21
Şekil 2.11. Eğitim ve test hatasında katman sayılarının etkisi.....	23
Şekil 2.12. ResNet-50 mimarisinin varsayılan ve çalışmada uygulanan modeli.....	24
Şekil 3.1. Nasa rulman veri seti test mekanizması yerleşimi.....	29
Şekil 3.2. Bizim tez çalışmasındaki girdi ve çıktı arasındaki tüm süreçlerin gösterimi.....	31
Şekil 3.3. NASA rulman veri seti ile sürekli dalgacık dönüşümü.....	35
Şekil 3.4. NASA rulman veri seti ile DTSD.....	37
Şekil 3.5. NASA rulman veri seti ile FTSD.....	39
Şekil 3.6. NASA rulman veri seti ile Wigner-Ville dağılımı.....	40
Şekil 3.7. NASA rulman veri seti ile Sabit-Q durağan olmayan gabor dönüşümü.....	42
Şekil 3.8. NASA rulman veri seti ile Hilbert Huang dönüşümü.....	44
Şekil 3.9. Normal durum ve iç yatak arızasının dağılım diyagramı Gösterimi.....	46
Şekil 3.10. Dış yatak arızalarının dağılım diyagramı gösterimi.....	46
Şekil 4.1. AlexNet ağı eğitim sonucu grafik görünümü.....	54
Şekil 4.2. GoogLeNet ağı eğitim sonucu grafik görünümü.....	55
Şekil 4.3. ResNet-50 ağı eğitim sonucu grafik görünümü.....	56
Şekil 4.4. Eğitim modellerinin test verileriyle oluşturduğu karışıklık matrisi (A: İç yatak arızası, B: Normal durum, C: Dış yatak arızası 1. Rulman, D: Dış yatak arızası 3. Rulman).....	57
Şekil 4.6. Uygulanan 3 evrişimli sinir ağının doğruluklarının karşılaştırılması.....	60
Şekil 4.7. Arıza tiplerine göre ağların doğruluk oranlarının dağılımı (A: İç yatak arızası, B: Normal durum, c: Dış yatak arızası 1. Rulman, D: Dış yatak arızası 3. Rulman).....	61

ÇİZELGELER DİZİNİ


		Sayfa
Çizelge 2.1.	Farklı çalışmaların önemli özelliklerinin karşılaştırılması.....	26
Çizelge 2.1.	Farklı çalışmaların önemli özelliklerinin karşılaştırılması (devam)	27
Çizelge 3.1.	Rexnord ZA-2115'nin karakteristikleri.....	29
Çizelge 3.2.	NASA rulman veri seti yapısı.....	30
Çizelge 3.3.	NASA rulman verilerinin özellikleri.....	31
Çizelge 4.1.	Çalışma gerçekleştirilen bilgisayar özellikleri.....	53
Çizelge 4.2.	Makine öğrenmesinde temel eğitim özellikleri.....	53

1. GİRİŞ

Gelişen teknolojiler ile birlikte yapay zeka konusunda, özellikle sinir ağları konusunda çalışmalar artarak devam etmektedir. Sinir ağları ve yapay zeka konularında yapılan çalışmaların endüstri alanına entegre edilmesiyle birlikte endüstriyel makineler kesintisiz ve minimum kayıp ile ürün üretme eğilimine geçmişlerdir. Bu eğilime geçmelerini sağlayan en temel etken ise makinelerin bakım periyotlarının zamanında ve doğru bir şekilde planlanmış olmasıdır. Makine bakımları yapılırken ilk dikkat edilmesi gereken noktalardan biri rulmanların titreşimsiz çalışmasıdır. Rulmanların çalışma tempolarından veya dış etmenlerden kaynaklı oluşan hatalar ve bu hataların oluşturduğu titreşim sinyalleri erken süreçte tespit edilip bakım yapılması gereklidir. Aksi takdirde bakım maliyet ve zaman açısından makina sahiplerine büyük zararlar oluşturabilir.

Makine öğrenmesi alanında yapılan çalışmalarda, kullanılan yöntemlerden en sık karşılaşılan yöntem derin öğrenme yöntemidir. Derin öğrenme, büyük veri işleme ve öğrenme yeteneklerine sahip bir mimaridir (LeCun, Y. ve ark. 2015). Endüstri, tıp, robotik, görüntü işleme, gibi geniş bir alanda kullanılmaktadır. Endüstri alanında kullanım ihtiyacı genellikle bakım odaklıdır. Günümüzde özellikle makinelere yerleştirilen sensörler ile saniye seviyelerinde makinelerden çok sayıda veriler alınmaktadır. Alınan bu veriler birleştirildiğinde büyük veri kavramı ortaya çıkmaktadır. Büyük veriler üzerinde derin öğrenme yöntemlerinin başarılı sonuçlar üretmesi, akıllı arıza teşhisi konusunda dikkat çekmektedir. Evrişimli sinir ağları derin öğrenme konusunun bir alt dalıdır ve makine rulman titreşimlerini incelerken sıklıkla kullanılmaktadır (Zhang, J. ve ark. 2020). Evrişimli sinir ağları, ilk olarak ham titreşim sinyallerini belirli ön işlemlerden geçirilerek arıza teşhisi gerçekleştirmek üzerine bir çalışma ortaya koymaktadır. Bu işlemi gerçekleştirirken titreşim sinyallerini, belirli saniye aralıklarında pencerelere bölmektedir ve her bir pencereye ayrı ayrı dönüşüm uygulamaktadır. Dönüşüm sonucunda elde edilen veriler, evrişimli sinir ağlarında eğitim verisi olarak kullanılmaktadır (Janssens, O. ve ark. 2016). Tez çalışması kapsamında ham titreşim sinyalleri iki boyutlu görselleştirme ile kullanılmıştır. Görselleştirilen sinyaller ile zaman, frekans ve genlik özellikleri detaylı olarak elde edilmiştir.

Derin transfer öğrenme yöntemleri, titreşim sinyallerinden elde edilmiş bir takım frekans grafiklerini anlamlandırarak rulmanlarda oluşabilecek bozulmaları daha verimli ve etkili bir şekilde tespit etmeye yardımcı olmaktadır (Jardine ve ark. 2006). Titreşim sinyalleri rulmanlardan çeşitli dinleme yöntemleri ile elde edilebilir. Özellikle bilyeli rulmanlardan dinlenen bu verilerden 3 temel hata durumu tespit edilmeye çalışılır. Şekil 1.1’de görüldüğü gibi bunlar iç bilezik yuvarlanma yolu arızası, dış bilezik yuvarlanma yolu hasarı ve bilye hasarıdır (Babouri ve ark. 2020).



Şekil 1.1. Bilyeli rulmanlarda arıza durumlarının oluştuğu noktalar (Kim, J. ve Kim, J. M.’nin 2020’deki çalışmasından değiştirilerek alınmıştır.)

Şekil 1.1.'de bilinen rulman arızalarından 3 tanesi görüntülenmektedir. Bu arızaların tespitinde oluşturulan model temelde 3 aşamadan oluşmaktadır. Bu aşamalar veri toplama, özellik çıkartma ve arıza sınıflandırmadır. Özellik çıkarma konusunda titreşim sinyallerinin zaman, frekans ve zaman-frekans analizlerine dayalı yöntemler ön plandadır (Gao, Z. ve ark. 2015). Özellik çıkarma işleminde, çalışma koşullarının zor ve karmaşık yapıda olması, durum izleme ve arıza teşhisinde zorluğa neden olmaktadır. Bu nedenle, verimli durum izleme ve etkili arıza teşhis yöntemleri, operasyonel güvenilirlik ve maliyet tasarrufu için anahtardır (Zhao, T. ve ark. 2019). Tez çalışması kapsamında etkin arıza teşhisi konusunda ResNet-50, GoogLeNet ve AlexNet gibi farklı evrişimli sinir ağları denenmiştir.

1.1. Tezin Amacı ve Kapsamı

Günümüzde gelişen teknoloji ile birlikte farklı sektörlerde kullanmak amacıyla birçok makine üretimi yapılmaktadır. Makineler içinde bulunan elemanlardan olan rulmanlar makinelerde çok yaygın bulunmaktadır. Makinelerin sağlıklı çalışması, içerisinde bulunan çok sayıda rulmanın sağlıklı çalışması ile doğru orantılıdır. Makinelerin sağlıklı, kayıpsız ve verimli çalışmasını sürdürebilmeleri için bu zamana kadar farklı yaklaşımlar uygulanmıştır. Bu yaklaşımlardan bazıları Şekil 1.2’de görülen yaklaşımlardır. Şekil 1.2’deki yaklaşımlardan olan kestirimci bakım, çalışma kapsamında üzerinde durulan yaklaşımdır (Jona, T. 2022).



Şekil 1.2. Makine bakım yaklaşımları (Jona, T.’nin 2022’deki çalışmasından değiştirilerek alınmıştır.)

Kestirimci bakım, yeni başlayan sorunları tespit etmek ve yıkıcı olabilecek arızaları önlemek amacıyla makinelerde rulman gibi sürekli dönen makine elemanlarının titreşimlerinin izlenmesidir (Moble, 2002).

Bu tez çalışmasının amacı, NASA Ames Araştırma Merkezi’nde makine titreşimlerinden elde edilmiş olan rulman veri seti kullanılarak oluşturulan evrişimli sinir ağları ile arıza durumlarının etkin bir şekilde tespit edilmesidir (J. Lee, H. ve ark. 2007). Evrişimli sinir ağları da kendi içerisinde zaman-frekans dönüşümü ve transfer öğrenme yöntemlerini uygulayarak, kurulan ağın doğruluk ve performans seviyelerini %99’a yakın seviyelere getirmeyi amaçlamaktadır. Rulman arızalarının erken teşhisi ile birlikte endüstriyel ortamlarda makinelerde oluşabilecek arızaların alt seviyelere indirgenmesi çalışmanın önemini arz etmektedir.

1.2. Tezin Organizasyonu

Tez kapsamında yapılan alıřmalar 5 temel bařlık ve onların alt bařlıklarından oluřacak řekilde kategorize edilmiřtir.

Giriř blmnde tezin amacı ve nemi yer almaktadır. Ayrıca tez organizasyonuna ait detaylar da aktarılmıřtır.

İkinci blmde, literatr arařtırması ve kullanılan makine ğrenmesi ve yapay zeka yntemleri bulunmaktadır. Bunların yanı sıra tez kapsamında uygulanan evriřimli sinir ağıları mimarileri yer almaktadır.

nc blmde, tez kapsamında kullanılan veri setinin bilgilendirilmesi, evriřimsel sinir ağılarının srelerini oluřturma adımları ve rulman arızalarının sınıflandırılması konularında bilgiler yer almaktadır.

Drdnc blmde, alıřma sonucunda elde edilen bulguların gsterimleriyle birlikte anlatımları yer almaktadır.

Beřinci blmde, tez alıřması kapsamında varılan sonular ve zm retilen noktalar yer almaktadır. Ayrıca yeni problem ve yeni arařtırma alanlarına iřaret edilmiřtir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Rulman arıza tespiti gelişen teknoloji ile birlikte birçok araştırmacı için merak konusu olmuştur. Rulmanlar makineler için en önemli ekipmanlardan biridir. Rulman arızalarının tespiti için makinelerde titreşim sinyalleri dinlenmeye başlanmıştır. Daha sonra makinelerden toplanan titreşim sinyalleri transfer öğrenme veya derin transfer öğrenme mimarileri kullanılarak anlamlı veriler ve çıkarımlar elde edilmeye başlanmıştır. Yapılan bu uygulamalar ile birlikte makine sektöründe erken arıza teşhisi ön plana çıkmıştır (Li, B. ve ark. 2000). Bu bölümde literatür araştırması ve transfer öğrenme yönteminden başlayarak rulman arıza tespitinden uygulanmasına kadar geçen sürecin teknik temelleri ele alınmıştır. Uygulanan tüm yöntemlerin denklemsel ve şekilsel anlatımlarıyla konular desteklenmiştir.

2.1. Rulman Hatalarının Etkin Tespitinde Kullanılan Yöntemler

Endüstriyel gelişmeler ve sektörden gelen talepler ile birlikte firmalar, müşteri taleplerine yanıt verebilmek için seri üretim süreçlerini arttırmaktadır. Bu artışla birlikte makinelerde oluşabilecek hata durumlarının önceden tespit edilmesi üreticiler için önemli bir hal almıştır. Bu nedenle hata tespiti alanında yapılan çalışmalar gün geçtikçe artmaktadır. Önleyici bakım konusu detaylı incelendiğinde Nandi, S. ve arkadaşlarının 2005'te yapmış olduğu çalışmaya göre makinelerde oluşan hataların %45-55 oranında dönen ekipmanlarda yani rulmanlarda arıza meydana geldiği gözlemlenmektedir. Günümüzde rulman arıza tespiti konusunda makine öğrenimi yöntemi, kullanılan en akıllı yöntemdir. Geleneksel makine öğrenmesi işlemi dört adımdan oluşmaktadır. Bunlar; veri toplama, özellik çıkarımı, özellik seçimi ve özellik sınıflandırmadır (Huang, 1996). Makine öğrenmesi yöntemlerinde sinyal analizinden görüntü analizine geçildiğinde yani 1 boyutlu sinyal verilerinden 2 boyutlu sinyal verilerine geçildiğinde doğruluk oranlarında artış gözlemlenmektedir. Buna örnek olarak, Zhang, W. ve ark. 2017'de yapmış olduğu çalışma verilebilir. Bu çalışmada, görüntü tipindeki sinyal verisini evrişimli sinir ağları içerisinde girdi olarak kullanarak ham veri kullanımına göre minimum %2 oranında fark olduğunu göstermektedir.

Makinelerden ölçümlerle elde edilen titreşim sinyalleri, sadece makine çalışma durumunu yansıtan faydalı bilgileri değil, aynı zamanda gürültülü sinyalleri de içerir. Bu nedenle, makinelerden alınan sinyallerdeki yalnızca yararlı özellikleri ayıklamak ve gereksiz bilgilerden kaçınmak önemlidir. Başlangıç aşamasında titreşim verilerinden elde edilen sinyaller zaman alanında sinyallerdir. Fakat frekans alanında ve zaman-frekans alanında da temsil edilebilirler. Buna bağlı olarak, titreşim sinyallerinin özelliklerini zaman alanında gösterimine Samanta ve Al-Balushi'nin 2003'te yapmış olduğu çalışma örnek gösterilebilir (Samanta, B. ve Al-Balushi, K. R. 2003). Frekans alanından çıkarıma ise Malhi ve Gao'nun 2004'te yapmış olduğu çalışma örnek gösterilebilir (Malhi, A. ve Gao, R. X. 2004). Günümüze yakın frekans alanında gerçekleştirilmiş olan çalışmalar incelendiğinde Fourier Dönüşümü'nün en popüler yöntemlerden biri olduğu Lin, H. C. ve arkadaşlarının 2016'da yaptıkları çalışma ile gözlemlenmektedir (Lin, H. C. ve ark. 2016). Her iki çalışmanın bir arada kullanılmasıyla birlikte zaman-frekans alanından Lou, X. ve Loparp, K.A.'nın 2004'te yapmış olduğu çalışma ve Yen, G. G. ve Lin, K. C.'nin 2000'de yapmış olduğu çalışma örnek gösterilebilir (Lou, X. ve Loparo, K. A. 2004 – Yen, G. ve Lin, K. 2000). Zaman-frekans alanında yapılan günümüze yakın çalışmalarından Li, C. ve arkadaşlarının 2016'da yapmış olduğu çalışmada Kısa Zamanlı Fourier Dönüşümü kullanıldığı gözlemlenmektedir (Li, C. ve ark. 2016).

Arızaların erken tespiti için yapılan kaynak sayılabilecek çalışmalar incelendiğinde, kurulan ağ ve uygulanan derin transfer öğrenme yöntemlerine ait birçok kavram ortaya atılmıştır. Bunlara örnek olarak, Bhadane, M. ve Ramachandran, K. I.'nın 2017'de yapmış olduğu çalışmada kurulan evrişimli sinir ağı, titreşim sinyallerinden elde edilen verileri istatistiksel olarak besleyerek sadece sınıflandırma özelinde kullanılmıştır. Bu sayede evrişimli sinir ağlarının, geleneksel yöntem olan Destek Vektör Makineleri (DVM) ve K-En Yakın Komşu Bulma sınıflandırma yöntemlerine göre daha iyi performans gösterdiğini kanıtlamıştır. Wen, L. ve arkadaşlarının 2017'de yaptıkları çalışmada zaman uzayında veri odaklı bir evrişimli sinir ağı yapısı kullanılmıştır. Burda titreşim sinyali gri ölçekli görsellere dönüştürülmüştür. Uygulanan yöntem ile gürültü dahil edilmeden %99,79'luk bir doğruluk oranı elde edilmiştir. Bu doğruluk değeri destek vektör makinesi, yapay sinir ağları gibi yöntemlerle karşılaştırılmış ve başarılı olduğu gözlemlenmiştir. Derin öğrenme konusunda zaman-frekans dönüşümünü kullanan


Verstraete, D. ve arkadaşları tarafından 2017’de gerçekleştirilen bir diğer çalışmada titreşim sinyalleri skalogram, spektrogram tipinde renkli görüntülere dönüştürülmüştür (Verstraete, D. ve ark. 2017). Her iki yöntem için de doğruluk oranı hesaplanmıştır. Skalogram için doğruluk oranı %98,8 iken spektrogram’da sonuç %98,7 seviyelerindedir. Burada eğitim konusundaki eksiklik ve gürültü eklenmemesi sonuçların doğruluk seviyelerinin yüksek olmasına neden olmaktadır. Tong, Z. ve arkadaşlarının 2018’de yapmış olduğu çalışmanın da konusu olan rulmanlarda arızanın erken tespiti, girdi olarak alınan verinin zaman, frekans veya zaman-frekans alanında çeşitli uygulamalarla tespiti hedeflenmektedir (Tong, Z ve ark. 2018). Bu uygulamalarda genellikle görüntülerden çıkarılan, özellik haritalarındaki bilgiler etiketli kaynak alandan, etiketlenmemiş hedef alana etkili bir şekilde aktarılır. Sonrasında sınıflandırma işlemi uygulanmış olur. Bu sınıflandırmalar sonrasında yeni gelecek deney verilerinde bu sınıflandırılmış veriler kullanılarak hızlı bir şekilde sonuca ulaşma hedeflenmektedir. Gürültü sinyallerinin birbirlerine eklenerek doğruluğun artırılmasını hedefleyen bir çalışma Hoang Duy-Tang ve Hee-Jun Kang tarafından 2019’da gerçekleştirilmiştir (Hoang, D. T. ve Kang, H. J. 2019). Bu çalışmada zaman uzayında titreşim sinyalleri gri ölçekli görsellere dönüştürülmüştür. Sisteme gürültü dahil edildikten sonra doğruluk oranı %99 civarına ulaşmıştır. Gelişmiş yöntemler dikkate alındığında Bhandari, B’nin 2021’de yapmış olduğu çalışmada makine rulmanlarındaki, pürüzlerden kaynaklı arızaların tespiti için spektrogram tabanlı titreşim sinyallerinin incelenmesi ile ilgili bir derin öğrenme yöntemi önerilmiştir (Bhandari, B. 2021). Bu çalışmanın yanı sıra Ni, Q. ve arkadaşlarının 2022’de yapmış olduğu çalışmada, Case Western Reserve University (CWRU)’nin rulman veri setiyle spektrogram tabanlı arıza teşhis yöntemi uygulanmıştır (Ni, Q. ve ark. 2022). Spektrogram yönteminde zaman alanı aktif olarak kullanılmaktadır. Genellikle incelenen örneklerde derin evrişimli sinir ağları yöntemleri sıklıkla kullanılmıştır. Bu nedenle derin evrişimli sinir ağları, makinelerin kestirimci bakımları konusunda odak noktası olmuştur.

Derin öğrenme tabanlı akıllı arıza teşhis yöntemleri, yapılan literatür araştırmalarında özellik çıkarma ve sınıflandırma konusunda başarılı sonuçlar vermiştir. Başarılı sonuçlar elde ederken hemen hemen tüm yöntemler büyük veri setleri ile çalışmıştır. Bunlardan en sık karşılaşılan veri setleri CWRU (Neupane, D. ve Jongwon S. 2020), NASA Rulman

Veri Seti (J. Lee ve ark. 2007) ve Makine Hatası Önleme Teknolojisi (MFPT)'dir (Bechhoefer, E. 2013). Tez çalışması kapsamında, daha önce yapılmış çalışmalarda az rastlanan ve aynı zamanda tez çalışmasında kurgulanan yapıya uygun olan “NASA Rulman Veri Seti” kullanılmıştır. Bundan sonraki bölümlerde literatür taramasında incelenen çalışmalar ve tez çalışmasında kullanılan yöntemler anlatılmaktadır.

2.2. Transfer Öğrenme (Öğrenme Aktarımı)

Transfer öğrenme bir makine öğrenme tekniğidir. Makine öğrenimini biraz açacak olursak, insanların öğrenme şeklini taklit etmek için verilerin ve algoritmaların kullanımına odaklanan ve doğruluğunu kademeli olarak artıran bir yapay zeka ve bilgisayar bilimi dalıdır (Anonim 2022a). Transfer öğreniminde amaç bir modelin bir hedef doğrultusunda eğitilmesi, geliştirilmesi ve yeniden farklı bir görevde kullanılabilmesidir (Hussain, M ve ark. 2018). Bu tanımlamalarla birlikte transfer öğrenmesi, bir ortamda öğrenilen verilerin başka bir ortamda uygulanması ile birlikte mevcut durumunu geliştirmesi demektir. Doğru bir deyişle daha az eğitim verisi ile daha yüksek başarı gösteren aynı zamanda daha hızlı öğrenen modeller geliştirerek bulunduğu ortamı geliştirmektedir (Goa, Y. ve ark. 2018). Bulunduğu ortamı geliştirdikten sonra daha önceden eğitilmiş olan bir model kolaylıkla başka bir model üzerinde uygulanabilmektedir. Bu sayede bir modeli sıfırdan eğitmek yerine önceden eğitilmiş bir kısmını kullanabilmektedir.




Şekil 2.1. Makine öğrenmesi ve transfer öğrenme arasındaki süreçlerin farklılıkları (Pan, S. J., & Yang, Q. 2010)'nin çalışmalarından değiştirilerek alınmıştır.)

Şekil 2.1’de de görüldüğü üzere geleneksel makine öğrenmesi yönteminde her görev için baştan sona tekrar tekrar öğrenme gerçekleştirilmektedir. Burada transfer öğrenme yöntemini diğerlerinden ayıran en güçlü özelliği kaynak olarak belirlenen görevlerden elde edilen sonuçları bilgi aktarımı için depolamasıdır. Bilgi aktarımı dediğimiz alanda tutulan bu bilgiler yeni görevlerde kullanılmaktadır.

2.3. Derin Öğrenme

Derin öğrenme en temelinde bir makine öğrenmesi yöntemidir. Günlük hayatta insan beyni, algı kanallarından aldığı bilgileri nasıl işliyor ise derin öğrenme de insan beyninin bu işleyişini aynı şekilde taklit eden bir makine öğrenmesinin alt kümesidir. Derin öğrenme içerisinde yer alan evrişimli sinir ağları görüntü veya nesne tanıma aynı zamanda sınıflandırma işlemleri için yaygın olarak kullanılan bir tür yapay sinir ağıdır. Derin öğrenme, kendisi ile birlikte bir evrişimli sinir ağı yöntemi kullanarak nesne tanıma fonksiyonunu gerçekleştirir. Derin öğrenme yöntemleri klasik makine öğrenmesi yöntemleri gibi özellik çıkartmak için herhangi bir insan kaynağına ihtiyaç duymazlar (Wang, J. ve ark. 2019). Sinir ağları yardımıyla otomatik olarak özellik çıkarımı yapabilirler. Bunun örneği Şekil 2.2’de görüntülenmektedir.



Şekil 2.2. Makine öğrenmesi ve derin öğrenme karşılaştırması (Wang, J. ve ark. 2019’da yaptıkları çalışmadan değiştirilerek alınmıştır.)

Derin öğrenme içerisinde evrimsel sinir ağları gibi birçok yöntemle özellik çıkarmak için faydalıdır. Makine öğrenimi mimarisi, mevcut verilerdeki modelleri çıkarır ve akıllı kararlar almak için bu modelleri yeni verilere uygular. Derin öğrenme ise verileri işlemek için derin öğrenme ağlarını kullanan bir makine öğrenimi alt kümesidir (Anonim 2022b). Bu da verilerin işlenmesi için otomatik bir yapıyı oluşturmuş olur. Bundan sonraki bölümlerde derin öğrenme alt konuları daha detaylı anlatılmaktadır.

2.4. Zaman-Frekans Dönüşümü (TFT)

Zaman-frekans dönüşümler, sinyal işleme işlemlerinde kullanılan zamanla değişen sinyallerin zaman içerisindeki spektral içeriklerine göre analiz etmek için kullanılan bir dönüşüm çeşididir (Scholl, S. 2021). Zaman-frekans dönüşümü, genellikle sinyal dosyalarının çevrilmesinde kullanılmaktadır. Zaman-frekans dönüşümü sinyal değerlerinin benzerliğini ölçerek sonuca ulaşmayı hedeflemektedir. Benzerlik değeri hesaplanırken iç çarpım yöntemi kullanılır (Chen, Q. ve ark. 2021). Benzerlik

hesaplamalarında herhangi bir vektör, iç çarpım yöntemiyle ortogonal taban dizilerine ayrıştırılabilir. Titreşim sinyallerini iç çarpım yoluyla ayrıştırarak farklı frekanslardaki titreşim sinyalinin genliğini yani frekans spektrumunu elde eder. Elde edilen frekans spektrumuna ait matematiksel işlem Denklem 2.1’de görüntülenmektedir.

$$X(f) = \int_{-\infty}^{\infty} x(t)(e^{j2\pi ft})^* dt = \langle x(t), e^{j2\pi ft} \rangle \quad (2.1)$$


Denklem 2.1’de yer alan $X(f)$, frekans spektrumunun sonucuna karşılık gelmektedir. $x(t)$ analiz edilen sinyali, $e^{j2\pi ft}$ trigonometrik tabanları ve $*$ sembolü ise eşlenik operatör durumunu ifade etmektedir.

Frekans-ortogonal tabanlı iç çarpımla elde edilen frekans spektrumu, titreşim sinyalinin frekans bölgesi değerini etkili bir şekilde gösterebilse de zaman bölgesi bilgisini dışarıda bırakır ve bu nedenle durağan olmayan yani zamanla değişen sinyaller için kullanımı uygun değildir (Wei, Z. ve ark. 2021). Durağan olmayan sinyallerin işlenmesi için zaman bağlamında düşünülmesi gerekir. Durağan olmayan sinyaller işlenirken, işlenecek sinyalin farklı zamanlarda ve farklı frekanslarda zaman-frekans spektrumunun elde edilmesi gerekmektedir. Zaman-frekans spektrumu Denklem 2.2’de görüldüğü gibi zaman-frekans-ortogonal tabanlı iç çarpımla elde edilmektedir.

$$TF(\tau, f) = \int_{-\infty}^{\infty} x(t) \psi_f^*(t - \tau) dt = \langle x(t), \psi_f(t - \tau) \rangle \quad (2.2)$$

Denklem 2.2’de $TF(\tau, f)$ fonksiyonu, zaman-frekans spektrumunu belirtir. $x(t)$ analiz edilen sinyali belirtir. $x(t)$, $\psi_f(t, \tau)_{f,t}$ denklemi ise zaman-frekans-ortogonal tabanlarını belirtir. $\psi_f(t)$ ise kompakt desteğe sahip iç çarpım pencere fonksiyonunu ifade etmektedir.

İç çarpım tabanlı zaman-frekans dönüşü fonksiyonunun aşama aşama anlatımı Şekil 2.3’te görüntülenmektedir.



Şekil 2.3. Zaman-frekans dönüşümünün basit gösterimi (Chen, Q. ve arkadaşlarının 2021'deki çalışmalarından değiştirilerek alınmıştır.)


Şekil 2.3'te görüntülenen giriş sinyali $x(t)$ ve farklı frekans seviyelerine sahip iç çarpım pencere fonksiyonu $\psi_f(t)$, τ tipindeki belirli bir zaman noktasında frekans spektrumunu elde etmek için evrişime tabi tutulur. Burada τ zaman noktasının hareketleriyle birlikte zaman-frekans spektrumu yavaş yavaş elde edilir. Tüm bu dönüşüm sırasında, sırasıyla zaman ve frekans alanında iç çarpım penceresi işlevinin odaklanma alanını ayarlamak için τ ve f parametreleri kullanılır. Bu girdi parametreleri ile zaman-frekans spektrumu elde edilmiş olur (Chen, Q. ve ark. 2021).

2.5. Sinir Ağları (Neural Networks)

Sinir ağları da günümüzdeki yaygın makine öğrenmesi yöntemlerinden bir tanesidir. Sinir ağlarını anlamak için ilk olarak insan beyninin çalışması incelenmelidir. İnsan beyni,

dışarıda karşılaştığı insanların yüzlerini veya konuşmalarını algı kanallarıyla tanımlar. Aynı zamanda kontrol kısmıyla ise yürüme ve temel vücut fonksiyonlarını gerçekleştirme gibi aktiviteleri gerçekleştirir. Beyin tüm bu işlemleri ihtiyaç anında aynı zamanda paralel olarakta gerçekleştirebilir (Abraham, A. 2005). Sinir ağlarının yapısı da insan beyninden esinlenerek ihtiyaç duyulan sistemlere veri işleme özelliğini öğreten bir makine öğrenmesi yöntemidir. İnsan beyninin çalışmasına benzeyen bu çalışma mantığı sayesinde sistemler, insan desteğine daha az ihtiyaç duyarak karar verme özelliğine sahip olurlar.

Şekil 2.4'te görüldüğü gibi sinir ağları temelde 3 katmandan oluşmaktadır. Bunlar giriş katmanı, çıkış katmanı ve gizli katmandır (Anonim 2020). Gizli katman sayısı bir veya birden fazla olabilir. Giriş katmanında veriler işlenir, analiz edilir veya sınıflandırılır. İşlem tamamlandığında bir sonraki katmana aktarılır. Gizli katmanda da analiz işlemi ve ayrıntılı bir işleme mekanizması mevcuttur. Çıktı katmanında ise işlenen her veriye ait bir sonuç durumu oluşur.



Şekil 2.4. Sinir ağlarının genel yapısı (James, C. 2022'den Türkçe 'ye çevrilerek alınmıştır.)

Katmanlar kendi içerisinde çok sayıda nöron içerir ve bu nöronlar birbirine bağlıdır. Nöronların birbirleri ile haberleşmesi için kendinden üst bir nöronun çıkışının belirli bir


eşik deęerinin üstünde olması gerekmektedir. Bu eşik deęerinden sonra düęüm aktifleşir ve veri iletilmiş olur (Anonim 2020).

Tez kapsamında sinir aęları içerisinde Evrişimli Sinir Aęları seçilmiştir. Bunun sebebi evrişimli sinir aęlarının görüntüler üzerinde uyguladığı filtreler sayesinde mekansal ve zamansal bağımlılıkları kullanarak başarıya ulaşmış olması ve rulman titreşim sinyallerindeki zamansal kavramının birbirleriyle örtüşüyor olmasıdır. Sinir aęlarının bilinen dięer tipleri aşağıdakilerdir (James, C. 2022);

- İleri Beslemeli Sinir Aęları (Feed-Forward Neural Networks)
- Özyinelemeli Sinir Aęları (Recurrent Neural Networks)
- Evrişimli Sinir Aęları (Convolutional Neural Networks)
- Evrişimsiz Sinir Aęları (Deconvolutional Neural Networks)
- Modüler Sinir Aęları (Modular Neural Networks)

2.7. Evrişimli Sinir Ağları (ESA) Mimarileri

Bir rulmanda arıza tespit edildiğinde, çalışma verilerini toplamak için makinenin farklı bölümlerine sensörler yerleştirilir. Bu sensörler çalışma prosedürünü işler ve belirler (Neupane, D. ve Jongwon S. 2020). Arıza tespit yöntemlerinin performansı, toplanan sinyallerin kalitesi, sinyal işlemenin etkinliği ve özellik çıkarma teknikleri ile belirlenir (Souza, R.M. ve ark 2021). Teknoloji gelişmeden önce bu tür makinelerin bakımları ancak bir makine arızası oluşuktan sonra yapıyordu. Bu tür arıza sonrası bakım yaklaşımı, genellikle ciddi makine arızalarına yol açarak maddi ve maddi olmayan kayıplara neden olmaktadır (Peng, Z. ve ark. 2002). Tüm bu nedenlerden dolayı, kayıpları en aza indirmek için makine sahiplerinin makine çalışma durumunu ve rulman durumunu izlemesi önemlidir.




Şekil 2.5. Temel evrişimli sinir ağları mimarisi (Ma, P. ve ark. 2019'daki çalışmasından değiştirilerek alınmıştır.)

Evrişimli sinir ağları, Şekil 2.5'te de görüldüğü gibi birçok katmanın birleşiminden oluşan bir sinir ağı çeşididir. Süreç giriş katmanı ile başlamaktadır. Giriş katmanından sonra gelen katman, evrişim katmanıdır. Bu katman evrişimli sinir ağları yapısının temel katmanıdır. Evrişim katmanı temel olarak girdi olarak gelen görsellerde özellik haritasını çıkarır. Evrişim katmanından sonra ortaklama katmanı gelir. Ortaklama katmanı

genellikle evriřim katmanları arasına eklenmektedir. Ortaklama katmanının temel görevi, hesaplama karmařıklıđını azaltmaktır. Bunu sađlarken girdi olarak alınan matrisin kanal sayısına etki etmeden yükseklik ve genişlik olarak boyutların küçültülmesini sađlar. Evriřim ve ortaklama katmanlarından sonra tam bađlı katman ile süreç devam etmektedir. Tam bađlı katman içerisinde vektör dönüşümleri yapılarak sınıflandırma modelleri gerçekleştirilir. Tam bađlı katman sonrasında çıkış katmanı ile süreç tamamlanır (Ma, P. ve ark. 2019).

Makine ve rulmanlardaki arızaların tespiti ve teşhisi için birçok sinyal işleme yaklaşımı, Makine Öğrenimi (ML) tabanlı yaklaşımlar ve Derin Öğrenme (DL) tabanlı yaklaşımlar önerilmiş ve uygulanmıştır (Bentivoglio, R. 2022). Bu arıza tespiti yaklaşımları içerisinde GoogLeNet, AlexNet ve ResNet-50 sinir ađlarına odaklanılmıştır. Bu yaklaşımların seçilmesinin sebebi Şekil 2.6’da görüntülenmektedir.




Şekil 2.6. Önceden eğitilmiş ađların karşılaştırılması (Pan, S. J., ve Yang, Q.’nin 2010’daki çalışmasından değiştirilerek alınmıştır.)

Evriřimli sinir ađları mimarileri, çok hızlı ve yüksek doğrulukta nesne tanımlayabildiđi için birçok farklı alanda başarı ile uygulanmıştır (Haykin, S. 2009). Şekil 2.6’da ResNet-50’nin genel olarak AlexNet’e kıyasla daha iyi bir tahmin doğruluđuna sahip olduđu

görülmektedir. GoogLeNet, Başlangıç modüllerini kullanan bir ağıdır. RestNet-50, evrişimli mimariyi kullanan ve eğitim süresinde oldukça iyi performans gösteren, önceden eğitilmiş bir ağıdır. ResNet-50 ile ResNet-18 aynı aileden geldiği için ve ResNet-50'nin doğruluk oranının daha yüksek olması sebebiyle ResNet-18 kullanılmamıştır. Çalışmada amaç birden fazla kaynak düzeyi gerektiren ağları karşılaştırabilmek ve yüksek doğruluk oranları elde edebilmektir. AlexNet ve GoogLeNet ağları Raspberry Pi gibi tek kartlı bilgisayarlarda eğitilebilir ve kullanılabilir. Ancak RestNet50 modern bilgisayarlarda eğitilebilir/kullanılabilir. Bunun sebebi gelişmiş bir ağ olması ve kaynak ihtiyacının çok olmasıdır. Bu projede farklı evrişimli sinir ağları yöntemlerinin kullanılması, rulman arızası sınıflandırılmasında farklı zaman-frekans görüntüleme yöntemlerinin performansı ve güvenilirliği hakkında fikir vermektedir. Görüntüleme yöntemi, titreşim sinyallerini net bir şekilde ayırırsa ağların performansı çok fazla değişmeyecektir. Bu bölümün geri kalan kısmında, bu çalışmada kullanılan ESA mimarileri ve görüntüleme yöntemlerinin özellikleri özetlenmiştir (Pan, S. J., ve Yang, Q. 2010).


2.7.1. GoogLeNet

GoogLeNet, 22 katman derinliğinde evrişimli bir sinir ağıdır. Havuzlama (pooling) katmanları da dahil edilirse toplamda 27 katmandan oluşmaktadır. GoogleNet mimarisi, kendisinden önceki ağlara ve günümüzdeki benzer ağlara kıyasla mevcut hesaplama verimliliğine sahip bir güç merkezi olarak tasarlanmıştır. GoogLeNet'in diğer ağlara kıyasla ana katkısı ağ gövdesinin tasarımıdır. Evrişim noktalarını seçme sorununu ustaca bir şekilde çözmektedir. Diğer ağ modelleri, 1×1 'den 11×11 'e kadar değişen ve hangi evrişimin en iyi olacağını belirlemeye çalışırken, GoogLeNet çok dallı evrişimleri basitçe birleştirmiş ve başarıya ulaşmıştır (Zhang, A. ve ark. 2021). Şekil 2.7'de GoogLeNet'in biraz basitleştirilmiş bir sürümünün başlangıç kısmı görüntülenmektedir.



Şekil 2.7. GoogLeNet başlangıç (Inception) bloğu yapısı (Zhang, A. ve ark. 2021)’nin çalışmalarından değiştirilerek alınmıştır.)

Şekil 2.7’nin içinde gösterildiği gibi, başlangıç bloğu dört paralel yoldan oluşur. İlk üç yol, farklı uzamsal boyutlardan bilgi ayıklamak için 1×1 , 3×3 ve 5×5 pencere boyutlarına sahip evrişimli katmanlar kullanır. Ortadaki iki kol ayrıca kanal sayısını azaltmak için girdiye 1×1 evrişim ekleyerek modelin karmaşıklığını azaltır. Dördüncü yol, 3×3 maksimum havuzlama (MaxPool) katmanı kullanır ve onun ardından kanal sayısını değiştirmek için 1×1 evrişim katmanı kullanır. Dört yol, girdi ve çıktıya aynı yüksekliği ve genişliği vermek için uygun dolguyu (appropriate padding) kullanır. Son olarak, her yol boyunca çıktılar kanal boyutu boyunca bitleştirilir ve bloğun çıktısını oluşturur. GoogLeNet modelinde görüntü, farklı boyutlardaki detayların farklı boyutlu filtreler ile verimli bir şekilde tanımlanmaktadır (Zhang, A. ve ark. 2021). Tanımlama işleminde farklı filtreler için farklı miktarlarda parametre atanabilmektedir.



Şekil 2.8. GoogLeNet mimarisi (Zhang, A. ve ark. 2021)'nin çalışmalarından değiştirilerek alınmıştır.)


GoogLeNet ağına verimliliğe ulaştığı yöntemlerden biri, aynı anda önemli uzamsal bilgileri korurken, girdi görüntüsünün en aza indirilmesidir. Şekil 2.7'de ilk evrişim (conv) katmanı, 7×7 boyutunda bir filtre kullanır. Bu katmanın birincil amacı, büyük filtre boyutlarını kullanarak girdi görüntüsünü bilgi kaybı olmadan anında küçültmektir (Cao, G. ve ark. 2020). Girdi görüntü boyutu (yükseklik ve genişlik), ikinci evrişim katmanında dört kat ve ilk başlangıç modülüne ulaşmadan önce sekiz kat azaltılır, ancak aynı zamanda daha fazla özellik haritası oluşturulur. İkinci dönüştürme katmanı iki derinliğe sahiptir ve boyut azaltmanın etkisi olarak 1×1 evrişim bloğundan yararlanır. 1×1 evrişim bloğu ile boyut azaltma, katmanların işlem sayısını azaltarak hesaplama yükünün azaltılmasına

olarak tanır. GoogLeNet mimarisi, Şekil 2.8’de gösterildiği gibi 9 kez (2 kez – 5 kez – 2 kez) başlangıç modülü içerir. Bazı başlangıç modülleri arasında, amacı girdiyi aşağı örneklemek olan iki maksimum havuzlama (MaxPool) katmanı vardır. Tüm bu aşamalar ile birlikte süreç tamamlanmaktadır (Khan, A. ve ark. 2020).

GoogLeNet’in önemli bir özelliği, eş zamanlı olarak gelişmiş doğruluk sağlarken, öncekilere göre hesaplamaların aslında daha az maliyetli olmasıdır. Bu durum hataları azaltarak bir ağı değerlendirme maliyetinden ödün veren çok daha bilinçli bir ağı tasarımı olduğunu göstermektedir (Khan, A. ve ark. 2020).

2.7.2. AlexNet


AlexNet, evrişim katmanları, havuzlama katmanları ve tam bağlı katmanlardan oluşan görüntü sınıflandırması için geliştirilen bir evrişimli sinir ağı modelidir. GoogLeNet ve ResNet-50 gibi özel bir yapısı yoktur. 227x227 boyutunda renkli görüntüleri kabul eden bir çeşit sıralı ağı mimarisidir. AlexNet ve en yakın yapıya sahip LeNet mimarilerinin karşılaştırılması Şekil 2.9’da gösterilmektedir.



Şekil 2.9. AlexNet(sağ) ve LeNet(sol) mimarileri (Zhang, A. ve ark. 2021)’nın çalışmalarından değiştirilerek alınmıştır.)

Şekil 2.9’da görülen AlexNet ve LeNet mimarileri tasarımsal olarak birbirlerine çok yakındır. İlk fark AlexNet, LeNet’ten daha derindir. AlexNet toplamda 25 katmandan oluşan önceden eğitilmiş bir ağıdır (Zhang, A. ve ark. 2021).

AlexNet, ağırlıkları olan 8 katman içerir. Bu katmanlardan ilk beş tanesi evrişimli, geri kalan 3 tanesi ise tam bağlı katmanlardır. AlexNet’in ilk katmanında evrişim pencere boyutu 11x11’dir. İkinci evrişim katmanında pencere boyutu 5x5’tir. Sonrasında ise 3x3 pencere boyutu ile sonuç elde edilir. Girdi kısmından tam bağlı kısma giden süreçte, birinci, ikinci ve beşinci evrişimli katmanlardan sonra mevcut AlexNet mimarisinde, 3x3 pencere boyutunda 2 adımdan oluşan maksimum havuzlama katmanı dahil edilir. Eklenen bu havuzlama katmanlarının en sonuncu aşama tamamlandığında 4096 çıkışlı 2 tane tam bağlı katman ile süreç devam eder. AlexNet’in kendinden önceki sinir ağıları ile farkı öğrenme modelinde çıktı belirlenirken Sigmoid veya Hiperbolik Tanjant (tanh) yöntemleri yerine Doğrutulmuş Lineer Birim (ReLU) adı verilen bilgilendirme fonksiyonunu kullanır. Aralarındaki farklar aşağıdaki denklemlerde gösterilmektedir (Upadhyayula, S. M., ve Venkataramanan, K. 2020).



Şekil 2.10. Hiperbolik Tanjant, Sigmoid ve ReLU gösterimleri (Upadhyayula, S. M., ve Venkataramanan, K.’nin 2020’deki çalışmasından değiştirilerek alınmıştır.)

Sigmoid, 0 ila 1 arasında çıktı üreten ve bu özelliğiyle en az tercih edilen bir aktivasyon fonksiyonudur. Sigmoid fonksiyonunun en büyük dezavantajı pürüzsüz eğrilere sahip olmasıdır. Şekil 2.10'daki eğrilerde giriş değerlerinde küçük değişiklik dahi yapılmış olsa çıktıya yansımaktadır (Goswani, D. 2019).

$$y = \frac{1}{1 + e^{(-x)}} \quad (2.3)$$

Şekil 2.10'da görülen Hiperbolik Tanjant fonksiyonu sürekli bir fonksiyondur. $[-1, +1]$ sınır değerleri arasında çıktı üretmektedir. Sigmoid'e göre daha fazla değer alabilir. Bu sayede oluşturulan bir sinir ağında kullanıldığında hızlı öğrenme özelliğine sahip olur (Goswani, D. 2019).

$$y = \frac{e^x - e^{(-x)}}{e^x + e^{(-x)}} \quad (2.4)$$

Doğrutulmuş Doğrusal Birimler fonksiyonu (ReLU), basit bir yaklaşıma sahiptir. 0 ile pozitif sonsuz aralığında değer alır. ReLU fonksiyonunun tercih sebebi Şekil 2.10'da görüldüğü gibi 0'dan büyük olan tüm girdilerinin sabit türev değerine sahip olmasıdır. Bu sebeple ağ eğitilirken daha hızlı bir şekilde süreç tamamlanır (Goswani, D. 2019).


$$y = \text{MAX}(x, 0) \quad (2.5)$$

AlexNet ağı, LeNet'e göre derin fakat GoogLeNet ve ResNet-50'ye göre derin değildir. Bu nedenle doğruluk anlamında gürültü sinyalleri ekleyerek performansı artırılabilir. AlexNet ve GoogLeNet modelleri çok fazla derinleştiğinde, sınıflandırma ve özellik çıkartma durumu giderek zorlaşmaktadır. Buradaki derinleşme hesaplama ve öğrenme işlemlerinin derinleşmesiyle açıklanmaktadır. Derinleşme beraberinde karmaşıklık getirmektedir. GoogLeNet ve AlexNet mimarilerinde işlemler karmaşık ve derin olduğunda doğruluk oranı düşmektedir. Bu noktada bir sonraki bölümde anlatılan ResNet-50 modeli ile derin ve karmaşık durumlarda, doğruluk oranının düşmemesi sağlanmıştır. ResNet-50 mimarisinde standart katman yapıları haricinde bu katmanlar arası bağlantıların nasıl olacağına dair bilgiler bulunmaktadır. Bu sayede hesaplama ve

öğrenme aşaması ne kadar derine giderse gitsin karmaşıklık durumunun oluşmasını büyük oranda önlemektedir (He, K. ve ark. 2016).


2.7.3. ResNet-50

ResNet-50, içerisinde 50 katman bulunduran ImageNet veri seti ile eğitilmiş bir çeşit evrişimli sinir ağı modelidir. Evrişimli sinir ağları içerisinde gelişmiş bir modeldir. Çıkış amacı CNN ağlarındaki performans düşüşünden kaynaklanan problemi çözmek olmuştur. En basit anlatımla performans düşüşünü önlemek için katmanlar arasına yeni kısayollar eklemektedir (He, K. ve ark. 2016). Bu kısayollar ağ derinleştikçe işleyişte çıkış kapısı olur ve bozulmayı büyük bir oranda önler. ResNet mimarisinde katmanların artırılmasında en büyük fayda Şekil 2.11’de açıkça görülmektedir.



Şekil 2.11. Eğitim ve test hatasında katman sayılarının etkisi (He, K. ve ark. 2016’daki çalışmasından değiştirilerek alınmıştır.)

Şekil 2.11’deki grafikler incelendiğinde 56 katmanlı evrişimli sinir ağı mimarisinin hem eğitim hem de test veri setlerinde 20 katmanlı evrişimli sinir ağı mimarisine göre daha fazla hata düzeltmeye sahip olduğu görülmektedir. Yani buradan anlaşılacağı üzere daha derin ağ, daha yüksek eğitim hatasına ve dolayısıyla test hatasına sahiptir (He, K. ve ark. 2016).



Şekil 2.12. ResNet-50 mimarisinin varsayılan ve çalışmada uygulanan modeli (Tang, Z. ve ark. 2020’deki çalışmasından değiştirilerek alınmıştır.)

Şekil 2.12’de görüldüğü gibi ResNet-50’de GoogLeNet gibi başlangıç katmanı bulunmamaktadır. Bu sayede Google Net’ten farklı olarak ResNet-50’de daha derin ve daha soyut olan özellikleri çıkarmak kolaydır (Tang, Z. ve ark. 2020). Belirli görüntülerin zaman-frekans görüntüleri üzerinde lokalizasyonu rulman arızası sınıflandırmasında önemli olmasından dolayı bizim çalışmamızda ResNet-50 ile en yüksek doğruluk elde edilmiştir.

2.8. Rulman Arıza Tespitinde Evrilimli Sinir Ağları Kullanımı

Rulmanlar makinelerin çalışmasını verimli bir şekilde sürdürebilmesi için gerekli olan makine elemanlarıdır. Rulmanlar genellikle farklı tiplerde ve boyutlarda bulunabilir. Rulmanlar çalışma anında belirli seviyelerde titreşimler üretmektedir. Bu titreşim sinyalleri farklı seviyelerde olabilir. Farklı seviyelerdeki bu titreşim sinyalleri ayrıştırıldığında rulmanın çalışma durumu elde edilmiş olur. Rulman arızalarının tespit edilmesinde ilk aşama titreşim analizidir. Arızaların oluşturmuş olduğu titreşim sinyalinin

miktarının tespiti ve buna sebep olan arıza durumunun izlenmesi evrişimli sinir ağları ile gerçekleştirilmektedir.

2.8.1. Rulman titreşim analizi

Titreşim sinyali, makinelerde bulunan rulman gibi mekanik aksamlardaki iç veya dış etmenlerden kaynaklı bozulmalarda oluşan sinyallerdir. Makinelerdeki farklı rulmanlardan alınan titreşim sinyalleri, farklı arızalar sebebiyle karmaşık sinyaller üretir. Bu sinyalleri yorumlamak için sinyallerin frekans bandına taşınması ve bununla birlikte spektrumlarının oluşması gerekmektedir. Titreşim analizi yapılırken Kalyoncu M.'nin 2006'daki çalışmasından da görüleceği gibi 2 durum dikkate alınmalıdır. Bunlar;

- **Frekans:** Belirli bir zaman periyodunda olayın oluş sayısıdır.
- **Genlik:** Titreşim sinyalinin boyutudur.

Frekans bilgisi incelendiğinde arıza bilgisi elde edilir. Genlik bilgisi incelendiğinde ise arızanın şiddeti hakkında bilgi içermektedir. Genliğin büyük olması şiddetin büyük olmasıyla doğru orantılı olduğu için arızanın fazla olduğu anlamına gelmektedir (Kalyoncu M. 2006).

2.8.2. Rulman arıza tespiti

Evrişimli sinir ağları, rulman arızalarında ilk kullanılmaya başlandığında arıza durumunu sınıflandırmak için kullanılmıştır. Zhao, J. ve arkadaşlarının 2021'de yapmış oldukları çalışma gibi günümüzdeki rulman arıza tespiti çalışmalarında istatistiksel olarak özellik çıkarma ve öğrenme durumları sıklıkla kullanılmaya başlanmıştır. Evrişimli sinir ağları genellikle diğer sinir ağlarına göre doğruluğu daha yüksek bir sinir ağıdır. Bu sebeple görüntü sınıflandırma, görüntü bölme, nesne tanıma gibi çeşitli görüntü ve video analizlerinde kullanılırlar (Aggarwal, C. C. 2018). Rulmanlardan alınan titreşim sinyalleri evrişimli sinir ağlarına girdi olmadan önce ilk olarak zaman-frekans düzleminde görsellere dönüştürülür. Bu görseller ile birlikte evrişimli sinir ağında işleyiş başlatılır. Önceki bölümlerde görüldüğü gibi evrişimli sinir ağları farklı katmanlardan oluşur.

Genellikle ilk aşama olan evrişimli katmanda girdi olarak gelen titreşim sinyallerinden karakter ayrıştırılması yapılır. Karakter ayrıştırılmasında bir takım parametreler elde edilir. Sonuç olarak bir öznitelik matrisi oluşturulmuş olur. Bu parametreler sonraki katmanlarda havuzlama işleminden geçirilir. Havuzlama işlemi sayesinde parametre sayısı azaltılır. Sonrasında tam bağlı katmana gelen veriler vektörlere dönüştürülür ve sınıflandırma işlemi için ön hazırlık gerçekleştirilmiş olur. Sınıflandırmalar sayesinde normal ve arızalı durumlar ayrıştırılır (Zhoa J. ve ark. 2021).

2.9. Benzer Yöntemlerin Karşılaştırılması

Çizelge 2.1’de gerçekleştirilen tez çalışmasına benzer sayılabilecek çalışmaların önemli özelliklerinin karşılaştırma tablosu görüntülenmektedir.

Çizelge 2.1. Farklı çalışmaların önemli özelliklerinin karşılaştırılması

Çalışma Sahibi	Uygulanan Mimari	Veri Seti	Alan Seçimi	Hedef	Doğruluk
Lu, Y. ve ark. 2020	Destek Vektör Makinesi (SVM)	NASA Rulman Veri Seti	Frekans	Yıpranma Seviyesi	%98,5
Akuruyejo, M. ve ark. 2020	Destek Vektör Makinesi (SVM)	NASA Rulman Veri Seti	Frekans	Kalan Faydalı Ömür (RUL)	Boş (Amaç kalan ömür hesabı olduğu için)
Zhang, W. ve ark. 2018	Derin Sinir Ağları	NASA ve CWRU Rulman Veri Seti	Zaman	Hata Tespiti	%98,35
Eren, L. ve ark. 2019	ESA	NASA ve CWRU Rulman Veri Seti	Zaman	Hata Tespiti	%93,90
Guo, L. ve ark. 2019	ESA	NASA ve CWRU Rulman Veri Seti	Zaman	Hata Tespiti	%86,30
Pinedo-Sanchez, L. A. ve ark. 2020	ESA	NASA Rulman Veri Seti	Zaman	Yıpranma Seviyesi	%98,84

Çizelge 2.1. Farklı çalışmaların önemli özelliklerinin karşılaştırılması (devam)

Zhang, R. ve ark. 2017	Derin Sinir Ağları (zaman bağlamında)	NASA ve CWRU Rulman Veri Seti	Zaman	Hata Tespiti	%94,4
Hu, Q. ve ark. 2007	Destek Vektör Makinesi (SVM)	NASA Rulman Veri Seti	Frekans	Hata Tespiti	%62,5
Sanakkayala, D. C. ve ark. 2022	ESA	NASA Rulman Veri Seti	Zaman-Frekans	Hata Tespiti	%94,89

3. MATERYAL ve YÖNTEM


Bu bölümde, deneysel çalışmalarda kullanılan NASA veri seti ve özelliklerine, evrişimli sinir ağları yöntemlerinin işleyişlerine ve uygulamalarına yer verilmiştir. İlk olarak veri setinde bulunan sayısal değerlerden anlamlı görseller oluşturma ile süreç başlar. Ardından, hata teşhisi için özellikleri çıkarmak ve öğrenmek için derin bir evrişimli sinir ağı modeli sunulur.

3.1. NASA Rulman Titreşim Veri Seti

Rulman veri seti, Ulusal Havacılık ve Uzay Dairesi (NASA) desteğiyle Cincinnati Üniversitesi'ndeki Akıllı Bakım Sistemleri Merkezi tarafından sağlanmıştır (J. Lee, H. ve ark. 2007). NASA Rulman veriseti laboratuvar ortamında 2003 yılında hazırlanmıştır. Fakat dijital ortamda Kaggle üzerinde 2020'de paylaşılmıştır (Tyagi, V. 2020). Önerilen yöntemi doğrulamak için bu veri seti kullanılmıştır. NASA rulman veri setinin seçilmesindeki etkenler yaygın olarak kullanılıyor olması ve etiket içermiyor olmasıdır. Etiket içermemesindeki avantaj rulmanlardaki aşınmanın düzeyine göre etiketleme yöntemini önermeye ve önerilen yöntemi kolayca doğrulamaya olanak sağlar (Pinedo-Sanchez, L.A. ve ark 2020). Cavalaglio, J. ve arkadaşlarının 2019'daki analizlerinde de görüldüğü gibi veriler rulmanların tüm kullanım ömrü süresince titreşim sinyalleri kaydedilmiştir. Bir başka deyişle makine durana kadar arıza durumlarının gelişimini aşama aşama incelemeye olanak sağlamıştır. Bu veri setinin ayrıca uzun süre çalıştırılması ve doğal yollarla aşınma durumunun meydana gelmesi sağlanmıştır. Yani herhangi bir dış etmenle rulmanlarda arıza durumu oluşturulmamıştır. Rulmanlarda yaşanan herhangi bir arıza durumu, önce titreşim verilerinde ardından ise sinyalin gücünde bir artış meydana getirmektedir (Cavalaglio, J ve ark. 2019). Ince, T. ve arkadaşlarının 2021'de gerçekleştirmiş olduğu çalışmada anlatıldığı gibi NASA Rulman Veri Seti oluşturulurken test ekipmanı bir süre çalıştıktan sonra sağlıklı rulmanlarda şiddete bağlı oluşan bozulmalar meydana gelmektedir. Sonrasında belirli testler ile bazı rulman arızaları tespit edilmektedir. Bu süreç tamamen doğal olarak ilerlemektedir. Herhangi bir dış etmen ile rulmanda bozulma işlemi gerçekleştirilmemiştir (Ince, T. ve ark. 2021).

3.1.1. Test mekanizması özellikleri ve genel yapısı

Test mekanizması tek bir mil boyunca yan yana yerleştirilmiş olan 4 adet rulmandan oluşmaktadır. Alternatif Akım (AA) motor ise bir kayış vasıtasıyla mile bağlanır ve dakikada 2000 devir sabit hızla mili hareket ettirir. Sistemin çalışmasında yağ sıcaklığını ve yağ akış düzeylerini düzenleyebilmek için yağ devresi eklenmiştir. Deney kapsamında rulmanların ömrü 100 milyon devir olarak değerlendirilmiştir (J. Lee, H. 2007). Bahsedilen bu temel yapı Şekil 3.1’de görüntülenmektedir.



Şekil 3.1. NASA rulman veri seti test mekanizması yerleşimi (J. Lee, H. ve arkadaşlarının 2007’de yaptıkları çalışmadan değiştirilerek alınmıştır.)

Mekanizma içerisinde kullanılan rulmanların modeli Rexnord ZA-2115’tir. Rulman’ın genel yapısı aşağıdaki Çizelge 3.1’de görüntülenmektedir.

Çizelge 3.1. Rexnord ZA-2115’nin karakteristikleri

Özellik Adı	Özellik Değeri
Bölüm Çapı	71,5 mm
Rulmanın Çapı	8,4 mm
Satır Başına Rulman Sayısı	16
Temas Açısı	15,17 derece
Statik Yük	26 690 newton

3.1.2. Genel veri yapısı

Veri paketi genelinde 3 ayrı veriseti vardır. Her veri seti kendi içerisinde bozulma durumu yaşanana kadar farklı farklı deneylere tabi tutulmuştur. Her veri seti belirli aralıklarla kaydedilen 1 saniyelik titreşim sinyallerinin verilerini barındıran bir metin dosyasından oluşur. Her dosya, örnekleme hızı 20 kHz olarak ayarlanmış 20480 noktadan oluşur (Qiu, H. ve ark. 2006). Oluşturulan veri setinin yapısı Çizelge 3.1’de verilmiştir. Veri seti elde edilmesinde kullanılan mekanizma her rulman için ayrı ayrı testlere tabi tutulmuştur ve her deney sonucunda rulmanların sağlık durumu kontrol edilmiştir.

Çizelge 3.2. NASA rulman veri seti yapısı

	Kanal Sayısı	Test Süresi	Kayıt Sıklığı	Test Sonucu Görülen Hatalar
Veri Seti 1	8	49 680 dakika (34 gün 12 saat)	10 dakikada bir	İç bilezik yuvarlanma yolu arızası (Rulman 3) Bilye Arızası (Rulman 4)
Veri Seti 2	4	9 840 dakika (6 gün 20 saat)	10 dakikada bir	Dış bilezik yuvarlanma yolu arızası (Rulman 1)
Veri Seti 3	4	44 480 dakika (31 gün 10 saat)	10 dakikada bir	Dış Bilezik yuvarlanma yolu arızası (Rulman 3)

Tez kapsamında hatalı durumu öngörebilmek için Veri Seti 1’in ilk 15 verisi sağlıklı durum olarak kabul edilmiştir. Veri Seti 1 dahil diğer tüm dosyalarda son 15 veri kaydı birleştirilerek bozulma durumu olduğu varsayılmıştır. Bu durumlar çerçevesinde simülasyonlar gerçekleştirilmiştir.

3.1.3. Veri yapısı

Hazırlanan 3 veriseti için 3 ayrı deney yapılmıştır. Bu 3 ayrı veriseti içerisinde 9463 adet metin dosyası içermektedir. Toplamda 6.53 GB boyuta sahiptir (Tyagi, V. 2020). İlk deneyde her rulman için iki ivmeölçer kullanılmıştır. İkinci ve üçüncü deneylerde ise sadece bir tane ivmeölçer kullanılmıştır. Tüm bu deneylerde toplanan veriler aşağıdaki Çizelge 3.3’te görüntülenmektedir.


Çizelge 3.3. NASA rulman verilerinin özellikleri

Deney Numarası	Örnek Sayısı	Özellik (Feature) Sayısı	Hatalı Rulman/lar
1	4 X 2156	4 X 20480	3. ve 4. Rulman
2	4 X 984	4 X 20480	1. Rulman
3	4 X 6324	4 X 20480	3. Rulman

Tez kapsamında önerilen yaklaşım sadece hatalı rulmanlar üzerinde eğitilmiş ve sonuçları incelenmiştir.

3.2. Evrişimsel Sinir Ağları Süreçlerini Oluşturma

Rulman arızalarının tespitinde kullanılan derin öğrenmenin alt kolu olan evrişimli sinir ağları incelendiğinde temelde 3 katman vardır. Evrişimli katman, havuzlama katmanları ve bağlı katmanlardır. Burada anahtar işlem evrişimli katmanlarda gerçekleşir. Bu aşamada tüm dönüşüm ve transfer öğrenme işlemleri gerçekleştirilir.



Şekil 3.2. Bizim tez çalışmasındaki girdi ve çıktı Arasındaki tüm süreçlerin gösterimi

Şekil 3.2'yi incelediğimizde giriş sinyali, NASA tarafından sağlanan ham rulman titreşim sinyalleridir. Bu ham veriler gürültü değerleri de içerebilir. Bu noktada veriler belirli zaman aralıklarında bölümlendirilerek anlamlı değerler çıkarılır. Bölümlendirilen veriler dönüşümler ile evrişimli sinir ağlarının uygulanabilmesi için hazırlanır. Daha sonra transfer öğrenme yöntemi ile sistem eğitilir ve hata durumlarının oluşması incelenir. Belirli reaksiyon gösteren sinyal değerleri sınıflandırılır ve hata durumları sınıflarına göre gözlemlenmeye çalışılır.

3.2.1. Ses sinyallerinin titreşim görüntülerine dönüştürülmesi

Ses sinyalleri makinelerden elde edilen titreşimlerin oluşturduğu sinyallerdir. Arıza tespitinde, zaman uzayında sinyallerle sonuçlar üretebilen birçok evrişimli sinir ağları bulunmasına rağmen, günümüzde iki boyutlu evrişimli sinir ağları yöntemleri daha fazla kullanılmaktadır. Görsel dönüşümlerde ilk olarak ses sinyalleri gri ölçekli görsellere dönüştürülmüştür. Ham sinyal ile gri ölçekli sinyal arasında karşılaştırma yapıldığında gri ölçekli görsellerin daha etkili bir şekilde özellik çıkarımında kullanıldığı görülmektedir (Chong Up 2011). Sonrasında iki boyutlu gri ölçekli sinyaller yerine renkli dönüşümler yapılarak sinyal dalgacıklarının, sınıflandırma işleminde daha etkili kullanıldığı gözlemlenmiştir (Lu, C. ve ark. 2016). Tek boyutlu sinyaller sezgisel bilgi içermez iken iki boyutlu sinyal görselleri sezgisel bilgi içermektedir. Sezgisel yani zengin bilgiler sayesinde sınıflandırma işlemlerinde hız ve verimlilik artmaktadır. Bundan sonraki bölümlerde tez çalışması kapsamında denenen tüm dönüşümlerin matematiksel anlatımı ve MATLAB (Moler, C. ve ark. 1982) uygulaması ile birlikte anlatılmaktadır.

3.2.2. Zaman-frekans dönüşümlerinin uygulanması

Zaman-frekans analizi, çakışma olmaksızın 1 Hz frekans çözünürlüğüyle bir saniyenin her bloğunda Kısa Süreli Fourier Dönüşümüne dayalıdır. Bu dönüşüm sayesinde logaritmik ölçekte spektrogramlar ile sonuçlar temsil edilmektedir. Elde edilen bu sonuçlar iki boyutlu görüntülere dönüştürülür. Diğer sinyal işleme ve görüntü verilerinin oluşturulması hakkında aşağıdaki bölümlerde detaylı bilgilendirme yapılmaktadır.

a) Spektrogram

Spektrogram, zaman düzleminde değişen bir titreşim sinyalinin frekans spektrumunun görsel olarak gösterimi olarak tanımlanır (Flandrin, P. 1998). Daha detaylandırarak olursak spektrogram, belirli bir dalga biçiminde sunulan çeşitli frekanslardaki bir sinyalin zaman içindeki gücünün veya genlik yüksekliğinin görsel bir temsilini sağlar. Spektrogramlar aynı zamanda enerji seviyelerinin zaman içinde nasıl değiştiğini de göstermektedir (Nanni, L. ve ark. 2018). Makine rulmanlarından elde edilen sinyallerin titreşimlerini ayırt etmek ve özelliklerini belirlemek için spektrogramlar kullanılmaktadır.

b) Sürekli dalgacık dönüşümü (SDD)

Dalgacık dönüşümü, sinyallerin zaman-frekans gösteriminin elde edilmesi için kullanılan bir çeşit dönüşüm fonksiyonudur (Hakan, A. L. P. ve ark. 2008). Sürekli dalgacık dönüşümü ise bir sinyali dalgacıklara yani sürekli bir zaman içerisinde oldukça küçük salınımlara ayırtırmak için kullanılır. Klasik Fourier Dönüşümü, bir sinyali sonsuz uzunluktaki sinüslere ve kosinüslere ayırtırır ve zaman boyunca yerelleştirme bilgisini etkili bir şekilde kaybeder. Sürekli Dalgacık Dönüşümü, Fourier dönüşümünün genelleştirilmiş halidir. Sürekli Dalgacık Dönüşümünde belirli bir değişken aralık, sinyal süresinde kaydırılır bu sayede başlangıç ve bitiş arasında faz spektrumu araştırılır (Büssow, R. 2007). SDD'ler genel olarak sinyallerin değişen özelliklerini haritalamak için ve ayrıca bir sinyalin durağan olup olmadığı durumlarda tercih edilir.

SDD yaklaşımında, genelleştirilmiş Mors dalgacıklarının üyelerinden bir zaman serisi sinyali oluşturulur. Mors dalgacıkları $\psi_{\beta,\gamma}$ olarak temsil edilmektedir. $\beta\gamma$ simgesi ise dalgacığın Fourier alanındaki bant genişliğini temsil etmektedir ve γ sembolü ise dalgacığın şeklini temsil etmektedir. Zamandaki Mors dalgacıklarının, frekans alanındaki tanımı Denklem 3.1'de görüntülenmektedir (Lilly, J. M. 2017).

$$\psi_{\beta,\gamma}(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \Psi_{\beta,\gamma}(\omega) e^{i\omega t} d\omega, \Psi_{\beta,\gamma}(\omega) = \alpha_{\beta,\gamma} \omega^{\beta} e^{-\omega^{\gamma}} \times \begin{cases} 1, & \omega > 0 \\ 1/2, & \omega = 0 \\ 0, & \omega < 0 \end{cases} \quad (3.1)$$


Denklem 3.1’deki ω sembolü radyan cinsinden frekanstır. $\alpha_{\beta,\gamma}$, dalgacıkları frekans alanında normalleştiren sabit bir değere karşılık gelmektedir ve Denklem 3.2’deki formüller tahmin işlemini gerçekleştirir.

$$\alpha_{\beta,\gamma} \equiv 2 \left(\frac{e\gamma}{\beta} \right)^{\beta/\gamma} \quad (3.2)$$

Denklem 3.1 ve Denklem 3.2’de yer alan formüller birleştirildiğinde sonuç olarak $x(t)$ sinyalinin sürekli dalgacık dönüşümü hesaplanır (Lilly, J. M. ve Olhede, S. C. 2008).

$$\begin{aligned} SDD(t, \omega) &\equiv \omega_{\beta,\gamma}(\tau, s) \equiv \int_{-\infty}^{\infty} \frac{1}{s} \psi_{\beta,\gamma}^* \left(\frac{t-\tau}{s} \right) x(t) dt \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{i\omega t} \Psi_{\beta,\gamma}^*(s\omega) X(\omega) d\omega \end{aligned} \quad (3.3)$$

Denklem 3.3’te görüntülenen $X(\omega)$ fonksiyonu $x(t)$ ’nin Fourier dönüşümüdür. * (yıldız) operatörü ise eşlenik işlemidir. Ölçek değişkeni olan s sembolü ise zaman alanında dalgacığın sıkıştırılması veya gerilmesi durumunu belirtir. Yeniden ölçeklendirilmiş frekans etki alanı dalgacığı $\Psi_{\beta,\gamma}^*(s\omega)$ genel bir maksimuma sahiptir. Burada $\omega_s = \omega_{\beta,\gamma}/s$ eşitliği ölçek frekansıdır (Lilly, J. M. 2017).



Şekil 3.3. NASA rulman veri seti ile sürekli dalgacık dönüşümü

Şekil 3.3.'te bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında SDD ile oluşturulan görseller görüntülenmektedir. Normal durum ile hatalı durumlar açık şekilde görüntülenmektedir. Dış yatak arızası ve iç yatak arızası için oluşturulan görsellerde benzerlik yakalandığı için bizim çalışmamızda arıza tespitinde tercih edilmemiştir.


c) Dalgacık tabanlı senkron sıkıştırma dönüşümü (DTSD-WSST)

Dalgacık Tabanlı Senkron Sıkıştırma Dönüşümü, makine titreşimleri ve fizyolojik sinyalleri gibi salınımlı modlara sahip çok bileşenli sinyalleri analiz etmek için kullanılan bir çeşit zaman-frekans analiz yöntemidir. Birçok salınım modlarına sahip olan bu sinyallerin çoğu, genlik modülasyonlu ve frekans modülasyonlu bileşenlerin toplamı olarak formülize edilebilir. Bu gösterim Denklem 3.4'te açıkça görüntülenmektedir (Mallat, S. 1999).

$$\sum_{k=1}^K A_k(t) \cos(2\pi\phi_k(t)) \quad (3.4)$$

Denklem 3.4'te bulunan $A_k(t)$ yavaş değişen genlik bilgisidir. $\phi_k(t)$ ise anlık fazdır. Genlik ve frekans değerinin zamanla değişmediği yerlerde hiçbir varyasyonun olmadığı tepesi kesik bir Fourier serisi, bu sinyallerin özel bir durumunu benzer şekilde ifade etmektedir.

Dalgacık dönüşümü ve diğer doğrusal zaman-frekans analiz yöntemleri, sinyali bir zaman-frekans atomları sözlüğü ile ilişkilendirerek bu sinyalleri bileşenlerine ayırır (Mallat, S. 1999). Dalgacık dönüşümleri, zaman-frekans atomu olarak bir ana dalgacığın çevrilmiş ve ölçeklenmiş versiyonlarını kullanır. Bahsi geçen bu zaman-frekans atomları, sinyal analizinin keskinliğini etkileyerek analiz sonucunu zayıflatır. Dalgacık senkronize edilmiş dönüşümü, ana dalgacığın yayılma etkilerini telafi etmek için sinyal enerjisini frekansta yeniden atayan bir zaman-frekans yöntemidir. Diğer zaman-frekans yöntemlerinden farklı olarak senkron-sıkıştırma işlemi yalnızca frekans yönünde enerjiyi yeniden atar (Daubechies, I. ve ark. 2011). Bu sayede sinyalin zaman çözünürlüğü korunmuş olur.



Şekil 3.4. NASA rulman veri seti ile DTSD

Şekil 3.4.'te bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında DTSD ile oluşturulan görseller görüntülenmektedir. Normal durum ile hatalı durumlar için oluşturulan bu görsellerin birbirlerine benzerlik oranları gözler görülür seviyelerde olduğu için bizim çalışmamızda tercih edilmemiştir. Şekil 3.4'teki gibi birbirine benzer görsellerin kullanımı doğruluk değerlerini her yöntem için birbirine yaklaştıracğından arıza tespiti zorlaşacaktır.

d) Fourier tabanlı senkron sıkıştırma dönüşümü (FTSD)

Genel olarak standart dönüşümler arasında yer alan Fourier dönüşümü ve Fourier Tabanlı Senkron Sıkıştırma Dönüşümü karşılaştırıldığında Fourier Dönüşümü, genellikle fiziksel sistemlerin veya sensörlerin tepkisini modellemek için kullanılan doğrusal yani zamanla değişmeyen filtrelerle doğrudan ilişkilidir (Rueda, A. ve Krishann, S. 2019). Buna karşın Senkron Sıkıştırma Dönüşümü (SSD) ise salınımlı modlara sahip çok bileşenli sinyalleri analiz etmek için kullanılabilen bir dönüşüm yöntemidir (Thakur, G. 2014). Senkron sıkıştırma dönüşümü, değiştirilmiş bir Kısa Zamanlı Fourier Dönüşümü'ne (KZFD) dayalı bir yöntemdir. FTSD'nin matematiksel hesabının gösterimi aşağıdaki denklemlerde görüntülenmektedir.


$$KZFD(\tau, \eta) = \int \omega(t - \tau)x(t)e^{-i\eta t} dt \quad (3.5)$$

Denklem 3.5'te bulunan η sembolü frekans indeksini temsil eder. $\omega(t)$ ise yerelleştirme için kullanılan pencere fonksiyonudur. İkisinin birleşiminden oluşan $\omega_s(\tau, \eta)$ fonksiyonu ise her indeks için Denklem 3.6'da görüldüğü gibi anlık frekans hesabını gerçekleştirir (Thakur, G. 2014).

$$\omega_s(\tau, \eta) = -i(KZFD(\tau, \eta))^{-1} \frac{\partial KZFD(\tau, \eta)}{\partial \eta} \quad (3.6)$$

Sonuç olarak Denklem 3.7'deki FTSD dönüşüm fonksiyonu elde edilmiş olur.

$$FTSD(t, \omega) = \frac{1}{\omega(0)} \int \delta(\omega - \omega_s(t, \eta)) KZFD(t, \eta) d\eta \quad (3.7)$$



Şekil 3.5. NASA rulman veri seti ile FTSD

Şekil 3.5.’te bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında FTSD ile oluşturulan görseller görüntülenmektedir. Görüntülerde hatalı durumlar genlik seviyelerine göre renklendirilmiştir. Şekil 3.5’te açıkça görüldüğü gibi hata oluştuğundaki genlik değerleri farklı arıza durumları için aynıdır. Bu nedenle bu yöntem bizim tez çalışmamızda tercih edilmemiştir.


e) Wigner-ville dağılımı (WVD)

Bilinen zaman-frekans dönüşümleri arasında sinyal işleme konusunda en eski yöntemdir. Geçmişte, nesne algılama ve görüntüleme için kullanılırken günümüzde sinyal analizi konusunda sıkça kullanılmaktadır (Allen ve Mills, 2004). Wigner-Ville potansiyel olarak zamanla değişen sinyallerin analizinde çok kullanışlı bir araçtır

(Bayrak, Y. ve ark. 2011). Wigner-Ville Dağılımı, harika bir zaman-frekans çözünürlüğü sağlar. Denklem 3.8’de matematiksel hesabına ait gösterim görüntülenmektedir.

$$\mathcal{W}_{f,g}(t, \omega) = \int_{-\infty}^{\infty} x(t + \tau/2) \bar{g}(t - \tau/2) e^{-i\omega\tau} d\tau \quad (3.8)$$

Denklem 3.8’deki $\mathcal{W}_{f,g}(t, \omega)$ fonksiyonu $x(t + \tau/2) \bar{g}(t - \tau/2)$ işlemini dönüştüren çekirdek fonksiyondur. τ sembolü ise sinyalin zaman düzeyindeki kaymasını ifade etmektedir (Li, Y. ve Zheng, X. 2008).



Şekil 3.6. NASA rulman veri seti ile Wigner-Ville dağılımı

Şekil 3.6.’da bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında Wigner-Ville Dağılımı ile oluşturulan görseller görüntülenmektedir. Görseller genlik seviyelerine göre renklendirilerek oluşturulmaktadır. Genlik değerinin yoğun olması durumunda

Wigner-Ville Dağılımı (Li, Y. ve Zheng, X. 2008) tercih edilmektedir. Bizim çalışmamızda elde edilen görseller incelendiğinde, genlik yoğunluğu düşük olduğu için tercih edilmemektedir.

f) Sabit-Q durağan olmayan gabor dönüşümü (CQT)


Sabit-Q Durağan Olmayan Gabor Dönüşümü, genellikle doğrusal olmayan ve durağan olmayan sinyaller için kullanılan bir çeşit zaman-frekans gösterimidir (Youngberg, J. ve Boll, S. 1978). Tanım içerisinde geçen Gabor Dönüşümü hem zaman hem de frekans lokalizasyon özelliklerini tek dönüşüm fonksiyonu ile bir araya getirmek için kullanılan bir çeşit (Kısa Zamanlı Fourier Dönüşümü olarak bilinen) spektrogramdır (Youngberg, J. ve Boll, S. 1978). Sabit-Q Durağan Olmayan Gabor Dönüşümü ses işleme için tasarlanmıştır. Dönüşüm işlemi, bir Q faktörü yani belirlenen her bir pencerenin merkez frekansının bant genişliğine oranıyla belirlenir. Matematiksel hesaplamasına ait gösterim aşağıda belirtilen denklemlerde görüntülenmektedir.

$$a_w(k) = g_w(k)e^{i2\pi k f_w / f_s}, k \in \mathbb{Z} \quad (3.9)$$

$$f_w / f_s = Q \text{ Faktör} \quad (3.10)$$

Denklem 3.9'daki $g_w(k)$ fonksiyonunun sıfır merkezli pencere işlevi olduğunda, bölme merkezi frekansı f_w 'dir. f ise örnekleme oranını ifade etmektedir. $a_w(k)$ 'nin eşleniği elde edildikten sonra, CQT Denklem 3.11'de belirtilen toplam bloğu ile hesaplanır.

$$CQT(t, w) = \sum_{k=0}^K x(k) a_w^*(k - t) \quad (3.11)$$



Şekil 3.7. NASA rulman veri seti ile Sabit-Q durağan olmayan gabor dönüşümü

Şekil 3.7.'de bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında Sabit-Q Durağan Olmayan Gabor Dönüşümü ile oluşturulan görseller görüntülenmektedir. Her durum için ayrı ayrı 1500'er görsel oluşturulmuştur. Oluşturulan görsellerin birbirlerine benzerliğinin yüksek olması sebebiyle bu yöntem tercih edilmemiştir.

g) Hilbert huang dönüşümü (HHD)

Hilbert Huang Dönüşümü, bir sinyal içerisindeki enerjinin veya gücün frekans boyunca nasıl dağıldığının açıklanmasını sağlar. Açıklanan dağılımlar, bir sinyalin anlık frekansını ve genliğini temel alırlar (Huang, N. E. ve ark. 1998). Hilbert-Huang dönüşümü durağan olan veya durağan olmayan durumlar için sonuçlar üretebilmektedir ve bu özelliği sayesinde hata sınıflandırılmasında yaygın olarak kullanılmaktadır. Hilbert-Huang Dönüşümü temelde iki adımdan oluşur. Bunlardan ilk adım aynı zamanda anahtar kısım Ampirik Mod Ayrıştırmasıdır (AMA). Ampirik

Mod Ayırıştırması, evrişimi kullanarak, İçsel Mod Fonksiyonlarını sinyalden çıkarmaya yardımcı olur. Bu aşamadan sonra AMA'ya Hilbert Dönüşümü uygulanır (Huang, N. E. ve ark. 1998). Aşağıdaki denklemlerde Hilbert-Haugh Dönüşümü 'nün matematiksel hesaplaması görüntülenmektedir.


$$y_i(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{x_i(\tau)}{t - \tau} d\tau \quad (3.12)$$

$$z_i(t) = x_i(t) + iy_i(t) = a_i(t)e^{i\theta_i(t)} \quad (3.13)$$

$$a_i(t) = |x_i(t) + iy_i(t)|, \theta_i(t) = \tan^{-1} \left(\frac{y_i(t)}{x_i(t)} \right) \quad (3.14)$$

$$HHD'nin Frekans Bileşeni (t, \omega) = \omega_i(t) = \frac{d\theta_i(t)}{dt} \quad (3.15)$$

Denklem 3.12'de görüntülenen P , Cauchy ana değeridir. $x_i(\tau)$ fonksiyonu ise kaydırılmış ampirik mod ayırıştırıcı çıkışıdır. Hilbert Dönüşümü 'nün sonucu $y_i(t)$ fonksiyonu ile ifade edilir. Bu formülden karmaşık bir eşlenik çift oluşturmak, Hilbert-Huang Dönüşümü 'nü sonuçlandırır (Huang, N. E. ve ark. 1998).



Şekil 3.8. NASA rulman veri seti ile Hilbert Huang dönüşümü

Şekil 3.8.'de bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında Hilbert Huang Dönüşümü ile oluşturulan görseller görüntülenmektedir. Oluşturulan görsellerde hata durumları etkin bir şekilde görüntülenmemektedir. Girdi sinyalinin doğrusal olmadığı durumlarda, Hilbert Huang Dönüşümü (Karatoprak, H. E. 2019) frekansları ayırmaya eğimli olduğu için hata durumunu etkin tespit edememektedir. Bizim tez çalışmamızda aynı frekanslarda farklı rulmanların sağlık durumları önemli olduğu için bu yöntem tercih edilmemektedir.


h) Dağılım diyagramı (Scattergram)

Dağılım diyagramı, kısa tanımıyla spektral katsayıları görselleştirme yöntemidir (Andén, J. ve Mallat, S. 2014). Dağılım diyagramı, normalde değişkenler arasındaki ilişkiyi gözlemlemek ve gözlemlediklerini görsel olarak göstermek için kullanılan bir çeşit analiz türüdür (Nanni, L. ve ark. 2018). Dağılım diyagramı dönüşümleri, farklı


dalgacıklarla hesaplanarak daha iyi frekans çözünürlüğü elde edilmeye çalışılır. Başlangıçta yatak hatası sınıflandırması için transfer öğrenme girdisi olarak kullanılması amaçlanmasa da dağılım diyagramlarının görüntü sınıflandırması için yararlı olduğu Andén, J., ve Mallat, S.'nin 2014'te yapmış olduğu çalışmada kanıtlanmıştır.

Dağılım diyagramı, evrişim ve modül işlemlerinin yinelemeli iterasyonlarıyla çok sıralı spektrum katsayılarını hesaplar. $\psi_{\lambda_1}, \psi_{\lambda_2}, \psi_{\lambda_3}, \dots, \psi_{\lambda_k}$ dalgacıkları ile konvolüsyondan sonra lineer olmamayı sağlayan modül işlemi devreye alınır. Bu işlemlerin çıktısı daha sonra ortalama almak için kullanılan düşük geçiş filtresi $\phi(t)$ ile evrilir. Farklı düşük geçişli filtreler, farklı zaman-frekans görüntüleri verir. Bu nedenle iki ayrı filtre kullanarak sonuçları doğrulamak gerekmektedir (Andén, J., ve Mallat, S. 2014).

Matlab'de yapılan çalışmada, 'FilterBank' özelliği 1'e atandığında, her bir hata/sağlamlık durumunun ortaya çıkan dağılım diyagramı görüntüleri Şekil 3.8'de görüntülenmektedir. Görsellerde normal ve arızalı durumların oluşturduğu sinyal farklılıkları açıkça görüntülenmektedir. Rulmanlar sağlıklı çalışmaya devam ettiğinde 1 kHz seviyelerinde sabit bir frekans mevcuttur. Bu frekans değerinin sağlıklı olmayan durumlarda dağıldığı gözlemlenmiştir. Bu dağılımlardan doğru tespitler çıkartmak için dağılım diyagramı yöntemi kullanılmıştır (Andén, J., ve Mallat, S. 2014).



Şekil 3.9. Normal durum ve iç yatak arızasının dağılım diyagramı gösterimi



Şekil 3.10. Dış yatak arızalarının dağılım diyagramı gösterimi

Şekil 3.9. ve Şekil 3.10'da bizim tez çalışmamızda hazırladığımız normal ve hatalı durumlara ait metin tipindeki titreşim sinyalleri kullanılarak, zaman-frekans alanında Dağılım Diyagramı ile oluşturulan görseller görüntülenmektedir. Oluşturulan görsellerde hata durumları ve sağlıklı durum gözle görülür seviyelerde birbirinden ayrılmaktadır. Dağılım diyagramının (Ambika, P. S. ve ark. 2019) diğer

yöntemlerden ayrılan özelliği iki farklı değişken durum arasında ilişkiyi etkin bir şekilde incelemesidir. Dağılım diyagramları, iki farklı değişken arasında doğrusal bir ilişki olup olmadığını incelemektedir. Eğer ilişki varsa iki değişken arasındaki ilişkinin yönünü ve gücünü belirlemektedir. Bizim tez çalışmasında kullanım tercihi, ilişkili gibi görülen iki farklı t zamanındaki sinyalin hatayı aynı sebeple oluşturup oluşturmadığının ayrıştırılmasıdır. İki farklı t zamanlarından oluşturulan dağılım diyagramları görüntülerinde ilişki noktalarının birbirlerine en yakın kümелendiği noktalarda ilişki en güçlü aşamadır. Bu durum incelendiğinde benzerlik uzaklaştıkça rulmanlar sağlıklı durumdan ayrılmaktadır. Bu sayede arıza durumların tespiti kolaylaşmaktadır. Dağılım diyagramı yöntemi, bu durumlar göz önünde bulundurulduğunda bizim tez çalışmamızda tercih edilmektedir.

3.2.3. Evrişimsel sinir ağlarının MATLAB ile uygulanması

Aşağıdaki adımlar MATLAB uygulamasında baştan sona sürecin işleyiş adımlarıdır. Süreç anlatılırken kodlama kısımlarında anahtar kısımlar belirtilmektedir.

Verinin Hazırlanması: Bu adımda NASA Rulman Veri Seti her rulman için girdi olabilecek şekilde hazırlanmaktadır. 204 800 adet titreşim sinyali içeren dört farklı metin dosyası hazırlanmıştır. Bu metin dosyaları normal durum, iç yatak arızası ve iki farklı rulmanda görülen dış yatak arızası durumlarının titreşim sinyallerini sayısal olarak içermektedir.

Verinin Görüntülere Dönüştürülmesi: Titreşim sinyalleri, derin öğrenme yöntemlerinin daha etkin kullanılabilmesi için zaman-frekans uzayında “Dağılım Diyagramı” yöntemiyle görsellere dönüştürülmektedir. Dağılım Diyagramı, bir önceki bölümde anlatılan sekiz dönüşüm içerisinde en yüksek doğruluğu vermektedir. Bu nedenle tercih edilmektedir.

Verinin Yüklenmesi: Matlab’ın içerisinde yer alan aşağıdaki komut ile görüntü sinyalleri eğitimde kullanılabilmek için Matlab çalışma alanına yüklenmektedir.

`imageDatastore("Scattergram","IncludeSubfolders",true,"LabelSource","foldernames");`

Yüklendikten sonra uygulanacak derin evrişimli sinir ağı yöntemlerinden giriş katmanlarında kabul edilen çözünürlük değerlerine göre artırılmış görüntü veri deposuna aşağıdaki komutla çevrilmiştir.

```
augTrain=augmentedImageDatastore([227 227], healthTrain);
```

```
augValidation=augmentedImageDatastore([227 227], healthValidation);
```

Bu çevrim eğitim ve doğrulama işlemleri için ayrı ayrı oluşturulmaktadır. ResNet ve GoogLeNet 224 x 224 çözünürlüğe sahip görselleri işleyebilirken AlexNet 227 x 227 çözünürlükteki görselleri işlemektedir.

Evrişimli Sinir Ağları'nın Yüklmesi: Bu aşamada Matlab'in "Derin Öğrenme Araç Kutusu" içerisinde yer alan "Derin Öğrenme Tasarımcısı" açılır. Buradan her ağı için ayrı ayrı çağırılmaktadır.

```
net = AlexNet | GoogLeNet | ResNet-50 |;
```

Veri Katmanı Kontrolleri: Evrişimli sinir ağı yüklendikten sonra ilk olarak veri (giriş) katmanındaki kabul edilen çözünürlük ile artırılmış görüntü veri depolarının eşit olup olmadığı kontrol edilmektedir ve uyumsuzluk durumu varsa düzenlenmektedir.

Tam Bağlantılı Katman Kontrolleri: Giriş katmanında hazırlanan dört farklı durum için tam bağlantılı katmanda çıkış boyutu dört olarak belirlenir. Uygulanan yöntemde sistemin yeniden öğrenmesi gerektiği için ağırlık öğrenme oranı ve sapma oranı değerleri 10 olarak belirlenmiştir (Satya, G. 2020).

Sınıflandırma Katmanı Kontrolleri: Bu katman aynı zamanda çıkış katmanıdır. Çıkış katmanı içerisinde dört farklı tipte kaç adet görsel yüklenmesi yapıldıysa, çıkış katmanının sayısı aynı oranda belirlenmektedir.

Eğitim Ayarları: İlk olarak optimizasyon yöntemi olarak Adaptif Moment Tahmini (Adam) seçilmektedir. Adam'ın seçilmesindeki sebep, ilk iterasyondan itibaren yüksek düzeltme işlemi uygulayarak hızlı bir şekilde sonuca yakınsama eğilimidir. Ayrıca bu yöntem ile gürültülü veri setleri kolaylıkla optimize edilmektedir. İlk Öğrenme Oranı 0.0001 olarak belirlenmektedir. Bunun sebebi ise görsellerdeki modeller küçük olduğu

için minimum noktalarını bulurken aşma (overshoot) ve sapma (diverge) durumlarından kaçınılması içindir (Srivasta, N. ve ark. 2014). Eğitim ayarlarından, parametre güncellemesinin gerçekleştiği ağı verilen toplam alt örnek sayısı, eğitim gerçekleştirilen bilgisayarın özelliklerinin çok yüksek olmaması sebebiyle 32 olarak belirlenmektedir. Bu işlemlerin kod olarak gösterim özeti aşağıda belirtilmektedir. Ayarlar tamamlandıktan sonra eğitim süreci başlamaktadır.

```
-Training options: {'Solver', 'InitialLearnRate','MiniBatchSize'};  
-net = trainNetwork(augimdsTrain, lgraph, options);
```

Doğruluk ve Kayıp Grafiği Oluşturma: Süreç tamamlandığında doğruluk ve kayıp grafiği oluşmaktadır. Bu grafikte eğitim süresi yaklaşık 1500 iterasyon ile tamamlanmaktadır. Ama isteğe göre doğruluk değeri erken aşamada tam doğruluğa ulaşırsa süreç durdurulabilir.

Eğitim Makinesi Kaynak Temizlemesi: Süreç tamamlandığında eğitim makinesindeki kullanılan kaynak durumları temizlenmektedir. Bu sayede sonuç raporlarını kıyaslarken tüketilecek kaynak için alan sağlanmaktadır.

Doğruluk Değerlerinin Karşılaştırılması: Eğitim tamamlandığında uygulanan evrişimli sinir ağlarının grafik olarak karşılaştırma örneklerinden bir tanesi aşağıdaki kod parçasığı ile belirtilmektedir.

```
plot(smooth(googlenetInfo.TrainingAccuracy(1:4)), 'LineWidth', 1.5)  
grid on  
ylim([0,120])  
plot(smooth(resnetInfo.TrainingAccuracy(1:4)), 'LineWidth', 1.5)  
plot(smooth(alexnetInfo.TrainingAccuracy(1:4)), 'LineWidth', 1.5)  
legend('ResNet-50', 'GoogLeNet', 'AlexNet')
```

3.2.4. Rulman arızalarının sınıflandırılması

Rulman arıza sınıflandırmasında derin sinir ağları kullanılabilmesi için veri seti boyutunun büyük olması gerekmektedir. Rulmanlarda arıza durumlarının oluşması uzun yıllar alabileceğinden birçok çalışmada dış etmenlerle yapay olarak arıza durumu oluşturulmuş rulmanlar kullanılmıştır. Araştırmacıların derin sinir ağları ile rulman arıza tespiti konusundaki araştırmalarında kullanabilmeleri için NASA ve Cincinnati Üniversitesi ortaklığında Akıllı İmalat Sistemleri Laboratuvarı'nda elde edilen rulman veri seti oluşturulmuştur (Lee, J. ve ark. 2007). Bu veri seti farklı yöntemlerin karşılaştırılmasında kullanılmak üzere standart bir hizmet sağlamaktadır. Rulman arızalarının karşılaştırılmasında, algılayıcılar tarafından elde edilen titreşim sinyalleri, rulmanların farklı dönüş hızlarında sağlıklı ve arızalı durumlardan toplanan sinyallerdir.

NASA Rulman Veri Seti ile önceden yapılmış olan çalışmalarda 7 farklı sağlıklı veya arızalı durum tespit edilmiştir (Qui, H. ve ark. 2006). Bu sağlıklı veya arızalı durumların isimleri aşağıda görüntülenmektedir.

- Erken Durum (Rulmanların ilk alıştırması)
- Normal Durum
- Şüpheli Durum (Rulmanların sağlık durumun kötüye gitmesi)
- Arızaya Yakın Durum (Rulman 1 ve 2'de arızalı olmayan fakat arızaya yakın olan durum)
- İç Yatak Arızası (Rulman 3)
- Yuvarlanma Elemanı Arızası (Rulman 4)
- Dış Yatak Arızası (Rulman 4)

Yukarıda görüntülenen rulman durumları incelendiğinde titreşim sinyalleri standart sinyal işleme yöntemleriyle ayırt edilemeyecek kadar birbirlerine yakındır. Bu noktada sinyallerin görüntülere dönüştürülmesi ve analiz edilmesi etkili bir yöntem olmaktadır. Hesaplama karmaşıklığını azaltma ve öğrenme algoritmasının performansını iyileştirmek için belirli etiketler seçilmesi gerekmektedir (Qui, H. ve ark. 2006).

Tez çalışması kapsamında NASA Rulman Veri Seti'nden alınan titreşim sinyalleri sınıflandırılarak arızalı ve arızasız durumlara karar verilmiştir. Arıza sınıflandırması için temelde iki yaklaşım vardır. İlk yaklaşım, sinyalden zaman alanı, frekans alanı ve faz alanı özelliklerini çıkartmaktır. İkinci yaklaşım ise çeşitli makine öğrenmesi ve derin sinir ağları kullanılarak özellik alanı üzerinde eğitim gerçekleştirir.

4. BULGULAR

Bu bölümde, AlexNet, ResNet-50 ve GoogLeNet olmak üzere üç farklı evrişimli sinir ağı yönteminin rulman arıza tespitinde nasıl uygulandığı ile ilgili yöntemler ve sonuçlar belirtilmektedir. Sonuçlar elde edilirken girdi olacak benzersiz görsellerin hazırlanması işlemiyle sürecin başlangıç kısmı belirtilmiştir. Hedeflenen modelin eğitimi için normal durum, iç yatak arızası ve farklı kanallarda oluşan iki dış yatak arızası için 6000 adet görsel kullanılmıştır. Bu 6000 adet görsel dört durum için 1500'er parçaya bölünmüştür. Sonrasında oluşturulan derin sinir ağları yöntemlerini doğrulamak için 7500 iç yatak arızası, 4500'er dış yatak arızası ve normal durumu güçlendirmek için 2500 adet normal durum görseli kullanılmıştır. Tüm bu görseller üç farklı sinir ağı yöntemi için ayrı ayrı eşit olarak uygulanmış ve sonuçları grafiksel olarak kaydedilmiştir. Tüm eğitim ve doğrulama işlemlerinde MATLAB R2022a programı kullanılmıştır.

Eğitim işlemlerinde MATLAB'ın makine öğrenmesi ve derin öğrenme kütüphanelerinden "Derin Ağ Tasarımcısı (Deep Network Designer)" kütüphanesi kullanılmıştır. Derin Ağ Tasarımcısı, kendi içerisinde birden fazla ağ yöntemi içermektedir. Ayrıca Derin Ağ Tasarımcısı, kullanıcı dostu arayüzü sayesinde içerisinde bulunan önceden eğitilmiş ağ katmanlarının özelliklerinin değiştirilmesinde kolaylık sağlamaktadır. Katman sayıları az olan ağ modellerinden AlexNet ile başlayarak %100'e yakın bir doğruluk elde edilmek istenmiştir. %100'e yakın başarı GoogLeNet ve ResNet-50 ağlarında yakalandığı için süreçte üç modelin uygulanması yeterli görülmektedir. Sinyal işleme için "Sinyal İşleme Araç Kutusu (Signal Processing Toolbox)" ve "Dalgacık Araç Kutusu (Wavelet Toolbox)" kullanılmıştır. Makine öğrenmesi ve model doğrulaması işlemlerinin sonuçlarını karşılaştırmak için "İstatistik ve Makine Öğrenimi Araç Kutusu (Statistics and Machine Learning Toolbox)" kullanılmıştır. Yöntemlerin uygulandığı dizüstü bilgisayarın özellikleri Çizelge 4.1'de belirtilmektedir.

Çizelge 4.1. Çalışma gerçekleştirilen bilgisayar özellikleri

Özellik Adı	Özellik Bilgisi
İşletim Sistemi	Microsoft Windows 10 Pro
İşlemci	Intel i7-10510U 1,80 GHz
Bellek Bilgisi	16 GB DDR4 2666 MHz
Hafıza Bilgisi	SK Hynix BC511 256 GB M.2
Modeli	HP EliteBook 840 G7


Tez kapsamında kullanılan görseller, girdi olarak evrişimli sinir ağlarına uygulanmadan önce ilgili evrişimli sinir ağının kabul ettiği pencere boyutuna göre düzenlenmektedir. İlk olarak işlem burada başlamaktadır. GoogLeNet ve AlexNet ağlarında 224 x 224'lük pencere boyutu kabul edilirken, AlexNet'de 227 x 227'lik pencere boyutu kabul edilmektedir. Bu bilgilerle girdi olacak görseller eğitim süreci başlamadan önce yeniden boyutlandırılmaktadır.

Tez kapsamında önerilen yaklaşımları doğrularken farklı zaman-frekans yöntemleri ile titreşim sinyallerinden görüntüler oluşturulmuştur. Zaman-frekans yöntemi olarak “Dağılım Diyagramı” seçilmiştir. Bu görüntüler Çizelge 4.2’de temel özellikleri görüntülenen, ResNet-50, GoogLeNet ve AlexNet adlarındaki evrişimli sinir ağlarında eşit olarak uygulanmıştır. Bu uygulamalar ile arıza durumunun tespiti hedeflenmektedir.

Çizelge 4.2. Makine öğrenmesinde temel eğitim özellikleri

Eğitim Özellikleri	AlexNet	GoogLeNet	ResNet-50
Öğrenme Oranı	10^{-4}	10^{-4}	10^{-4}
Mini Parti Boyutu	32	32	32
Optimize Edici	Uyarlanabilir Moment Tahmini (Adam)	Adam	Adam
Doğrulama Sıklığı	50	50	50
Dönem Sayısı	30	30	30
İterasyon Sayısı	1305	1305	1305


Mini Parti Boyutu'nun düşük olması donanım kaynaklarının tüketiminin daha az olmasıyla doğru orantılıdır. Çizelge 4.2'de belirtilen özelliklerin dışında kalan tüm parametreler Derin Ağ Tasarımcısı'nın varsayılan parametreleridir. Onlarla ilgili herhangi bir değişiklik yapılmamıştır. Eğitimlerde ilk hedef 50 iterasyon ile yakalanan doğruluk değerini karşılaştırmak olmuştur. Şekil 4.1'de AlexNet'e ait eğitim sürecinin doğruluk ve kayıp grafiği görüntülenmektedir.



Şekil 4.1. AlexNet ağı eğitim sonucu grafik görünümü

AlexNet ile eğitim işlemi gerçekleştirildiğinde 50 iterasyon tamamlandığında doğruluk değeri tam olarak başarılı seviyelere erişmemektedir. Aynı şekilde kayıp oranı sıfır seviyelerine düşmemiştir. Ancak iterasyon sayıları 100'lere geldiğinde sistem durağan hale gelmiş ve doğruluk değeri %99'ları bulmuştur. ResNet-50 ve GoogLeNet'te daha erken iterasyonlarda %99 seviyelerine ulaşılırken, AlexNet'te daha ileri iterasyonlarda %99'lara ulaşmasının sebebi, derinliğin az olması yani katman sayılarının daha az olması nedeniyle görüntü kümelerinden özellikleri öğrenmekte zorlanmasından kaynaklanmaktadır. Daha ileri iterasyonlarda yüksek doğruluk değerlerine ulaşması


zaman kaybına neden olmaktadır. Bu nedenle bir diğer model olan ve Şekil 4.2’de görüntülenen GoogLeNet ağ modeli eğitilmiştir.



Şekil 4.2. GoogLeNet ağı eğitim sonucu grafik görünümü

GoogLeNet mimarisinde 22 katman derinliği bulunmaktadır. Havuzlama katmanları da eklendiğinde 27 katman derinliğine sahip olmaktadır. GoogLeNet modelinde çok dallı evrişimler gerçekleştirilebilmektedir. Bu sayede aynı anda birden fazla işlem gerçekleştirilerek zamandan kazanç sağlanmaktadır. Şekil 4.2’de görüldüğü üzere süreç başladıktan sonra yirminci iterasyon civarına ulaştığında doğruluk değeri % 90 seviyelerine ulaşmış, aynı şekilde kayıp sayıları sıfır seviyelerine indirgenmiştir. AlexNet’te doğruluk değerinde düşüşler %5-%10 seviyelerine ulaşırken GoogLeNet’te maksimum %3-%4 seviyelerine düşmektedir. Yaklaşık olarak 60 iterasyon sonrasında %99,99 doğruluk seviyesi yakalanmış ve sürecin eğitiminin tamamlanması için erkenden doğruluğa erişilmiştir. GoogLeNet modelinde de katmanlarda derinlik arttırıldığında hesaplama ve öğrenme noktasında süreçler aksamaya uğramaktadır (Zhang, A. ve ark. 2021). Bu sorunu çözmek için Şekil 4.3’te görüntülenen ResNet-50 modeli tez çalışmasında uygulanmıştır. ResNet-50’de karmaşık süreçlerin çözülebilmesi ve


doğruluk değerine erken ulaşabilmek için katmanlar arası kısayollar ile geçişler sağlanmaktadır (Wen, L. ve ark. 2020).



Şekil 4.3. ResNet-50 ağı eğitim sonucu grafik görünümü

ResNet-50 mimarisinde, bir özellik öğrenildiğinde tekrar tekrar öğrenmeye ihtiyaç duymamaktadır. ResNet-50’de yer alan tüm katmanlar aynı zamanda katmanlar arası bağlantıyı içerisinde bulundurur. Bu sayede öğrenilmiş bilgileri kullanabilir. Sürekli yeni özellikler öğrenmeye odaklıdır. Bu özelliği sayesinde ResNet-50 eğitim süresini büyük oranda azaltmaktadır. Eğitim süresinin azalması beraberinde doğruluğu arttırmaktadır (He, K. ve ark. 2016). Şekil 4.3’te görüldüğü gibi eğitim başladıktan sonra henüz 5-10. iterasyonlar arasında %99,99’luk doğruluk değerini yakalamaktadır. Sonrasında ise doğruluk değeri maksimum %2 seviyesi kadar düşmektedir. Bu seviyelerin model eğitimi ve doğrulama işlemleri için tez çalışması kapsamında yeterli olduğu görüntülenmektedir. Yaklaşık olarak 10. iterasyondan sonra kurulan model, doğruluk düzleminde maksimum değerlere ulaştığı için erkenden doğruluğa ulaşabilmektedir.

Eğitim işlemlerinden sonra doğrulama işlemi için 7500 adet iç yatak arızası, 2500 adet normal durum, 4500 adet birinci rulmanda görülen dış yatak arızası ve 4500 adet ikinci rulmanda görülen dış yatak arızası görseli dağılım diyagramı yöntemiyle hazırlanmıştır. Hazırlanan görseller ile ilk olarak, eğitim verileri ve test verileri arasında hata matrisi oluşturulmuştur. Hata matrisi, makine öğrenmesi işlemlerinde oluşturulan tüm modellerin performans değerlerinin gerçek ve tahmin edilen değerler arasında karşılaştırmasını gerçekleştirmektedir (Şirin, E. 2017). Sonrasında oluşturulan matristen sıfır olmayan değerler çıkarılarak maksimum doğrulukta değerler elde edilmektedir.




Şekil 4.4. Eğitim modellerinin test verileriyle oluşturduğu karışıklık matrisi (A: İç yatak arızası, B: Normal durum, C: Dış yatak 1. rulman, D: Dış yatak 3. rulman)

Şekil 4.4'te görüldüğü gibi AlexNet'te % 75,70 oranında doğruluk değeri elde edilmiştir. Ondan daha iyi sonuç veren GoogLeNet ise % 98,80 oranında başarılı bir doğruluğa sahiptir. Fakat ResNet-50 ile ulaşılan **%99,46** doğruluk oranı tam başarıya en yakın değerdir ve tez çalışmasında başarılı olarak kabul edilmektedir. AlexNet modeline ait karışıklık matrisinde, daha önce model için eğitilmemiş test görselleri içerisinde 4448

adet görseli normal durum olarak algılaması AlexNet'in aşırı öğrenme (over fitting) durumunda olduğunu göstermektedir. Bu nedenle GoogLeNet ve ResNet-50 modellerinin eğitime ihtiyaç duyulmuştur.


Bizim gerçekleştirdiğimiz çalışmanın sonuçları, Sanakkayala, D. C. ve arkadaşlarının 2022'nin ortalarında yapmış olduğu çalışmanın sonuçları ile karşılaştırıldığında ikisinde de en iyi doğruluk değeri ResNet-50 modelinde alınmıştır. Sanakkayala ve ark. %94,89 doğruluk skoru elde ederken geliştirilen tez çalışması %99,46 oranına ulaşmıştır. Şekil 4.4'te görüldüğü gibi tez çalışmasında, eğitilen ResNet-50 modelinde çok fazla sayıda görsel ile doğrulama işlemi gerçekleştirilmiş ve sapma miktarının az olduğu gözlemlenmiştir. Diğer uygulanan yöntemlere göre farklı bir çalışma mantığı olan Zhang, B. ve arkadaşlarının 2019'da gerçekleştirmiş olduğu mekanizmada sinyaller herhangi bir transfer öğrenme veya görsel oluşturma olmadan doğrulama işlemi gerçekleştirmiştir. Doğruluk oranları karşılaştırıldığında Zhang, B. ve arkadaşlarının yapmış olduğu çalışma %92,037 test doğrulama oranına sahiptir. Gerçekleştirilen tez çalışmasında bu oranın %99,46 olmasını sağlayan etkenlerden biri de seçilen modelin standart sinyal işlemeye göre görsel verilerle beslenmesidir. Görsel veri kümelerinde, dönüşüm işlemlerinde etiketler oluşturularak ResNet-50 modeliyle daha derine doğrulama işlemleri gerçekleştirilebilir. Bu sayede görsel verilerle model eğitmenin, sinyal üzerindeki işlemlere karşı avantajlı olduğu görüntülenmektedir.

ROC (Receiver operating characteristic - Alıcı işlem karakteristikleri) Eğrisi, doğrulama testlerinde, eğitim verileri ve test verileri arasında güvenilir bir karşılaştırma yapmak için kullanılmaktadır. Karşılaştırma yapılırken performans verileri grafiklerde gösterilmektedir. Grafiklerde Doğru (Gerçek) Pozitif Oran ve Yanlış Pozitif Oran olmak üzere iki parametre bulunmaktadır (Ertorsun, A. ve ark. 2010). Şekil 4.5'te dört arızalı ve normal durumun her bir derin evrişimli sinir ağı modelinde doğrulandığı ROC eğrileri görüntülenmektedir. AlexNet diğer evrişimli ağlara göre daha başarısız olduğu için pozitif oranlarda sapma olduğu gözlemlenmektedir. ResNet-50, %99,99'a yakın bir doğruluk oranını elde ettiği için ise tüm durumlarda performansı en iyi olduğu açıkça görüntülenmektedir.



Şekil 4.5. Evrişimli sinir ağlarının hatalara göre ROC eğrisi


Sınıflandırma sonucunda birden fazla sınıf ortaya çıkması durumunda değerlendirme ölçümleri de değişmektedir. Bu değerlendirme ölçütleri arasında makine öğrenmesi uygulamalarında en çok kullanılan ve her sınıfın kendi doğruluklarının, toplam doğruluk ile ortalaması alındığında bulunan değer makro ortalama değeridir (Vaughan, D. 2022). Şekil 4.6.'de tüm evrişimli sinir ağlarının tek grafikte makro ortalama değerleri görüntülenmektedir.



Şekil 4.6. Uygulanan 3 evrişimli sinir ağının doğruluklarının karşılaştırılması

Şekil 4.6'da Makro ortalama değerleri hesaplanırken temelde, her sınıfın doğruluk değerinin eşit oranda sınıflara dağılımı incelenmektedir. Burada oluşturulan veri kümesinde sayıdan bağımsız olarak bir hesap gerçekleştirilmektedir. Bu sayede sonucun doğruluğu ispatlanmaktadır (Vaughan, D. 2022). Şekil 4.6'da da görüldüğü gibi doğru pozitif oranı 1'e ne kadar yakınsa sonuç o kadar iyidir. Yani grafik incelendiğinde kırmızı renkteki ResNet-50 modelinin verdiği sonucun diğerlerine kıyasla daha iyi olduğu görüntülenmektedir.

Şekil 4.6’da görülen ROC eğrisi altında kalan alan Eğrinin Altındaki Alan (AUC) olarak adlandırılmaktadır. AUC değeri 1’e ne kadar yakınsa kurulan model o kadar başarılıdır. AUC genellikle aynı veri seti ile eğitilmiş olan sinir ağıları modellerinin başarı değerlerinin karşılaştırılmasında kullanılmaktadır (Narkhede, S. 2018). Şekil 4.7’de AUC değerlerinin sütun grafiği gösterimi mevcuttur.



Şekil 4.7. Arıza tiplerine göre ağların doğruluk oranlarının dağılımı (A: İç yatak arızası, B: Normal durum, C: Dış yatak arızası 1. rulman, D: Dış yatak arızası 3. rulman)

AUC görünümünde, turkuaz renkle görüntülenen AlexNet’in normal durum ve birinci rulmanda görülen dış yatak arızasını tahmin etme oranı düşüktür. Bunun yanı sıra diğer iki yöntem GoogLeNet ve ResNet-50 yüksek başarı oranlarına sahiptir.

5. TARTIŞMA ve SONUÇ

Çalışma kapsamında NASA Rulman Veri Seti'nin içerisinde bulunan belirli titreşim sinyallerinin görsellere dönüştürülerek eğitim ve doğrulama süreçleri ilerletilmiştir. Oluşturulan görseller evrişimli sinir ağları kullanılarak bu veri setindeki başarıları gözlemlenmiştir. Bu çalışmada asıl savunulan nokta makine bakım ihtiyaçlarının erkenden tahmin edilerek, endüstriyel alanda makineden kaynaklı üretim kesintilerinin önüne geçmektir. Ses titreşimlerinden elde edilen görseller, ResNet-50, AlexNet ve GoogLeNet yöntemleri ile eğitilerek makinelerdeki önemli ekipmanlardan biri olan rulmanların standart çalışma ve arıza durumları simüle edilmiştir. Bundan sonra girdi olarak gelecek sinyaller, eğitilmiş sinyaller ile aralarındaki uyum açısından incelenerek doğrulama işlemine tabi tutulmaktadır. Sunulan yöntemlerden iki yöntem birbirlerine daha yakın süreçler üretse de bir tanesi daha başarılı olmayı başarmıştır. Başarılı olan yöntem ResNet-50 modelidir.

NASA Rulman Veri Seti tarafından elde edilen analog titreşim sinyalleri gerçekleştirilen çalışmada “Dağılım Diyagramı” ile görüntü sinyallerine dönüştürülmüştür. Dönüştürülen bu sinyaller eğitim süreçlerinden geçirilmiş ve dört farklı sağlık durumunda etiketlenmişlerdir. Bu etiketler eğitim setinde kullanılmayan sinyaller ile doğrulama işleminde kullanılmıştır. Eğitim ve doğrulama işlemlerinde aşağıdaki sonuçlar gözlemlenmiştir.

- Tüm eğitim ve doğrulama işlemlerinde MATLAB 2022a programı kullanılmıştır. İçerisinde birçok makine öğrenmesi araç kutusu olması ve süreçleri hızlandırması tercih sebebi olmuştur.
- Kullanılan zaman-frekans yöntemlerinden “Dağılım Diyagramı” diğer dönüşümlere göre doğruluk ve eğitim konularında daha etkili sonuçlar vermektedir.
- Giriş sinyalleri için normal durum, iç yatak ve iki farklı dış yatak arızası için 4 x 1500'er adet eğitim görseli kullanılmıştır. Bu aralıktaki veriler ile hızlı sonuçlar elde edilmektedir.

- Normal durum ve arıza durumlarından oluşturulan eğitim modelinde en yüksek doğruluk oranı ResNet-50’de **%99,46** olarak görüntülenmektedir. Doğruluk işlemi için yaklaşık olarak 19 000 adet görsel kullanılmıştır.
- Sinir ağı modeli oluşturulurken eğitim aşamasında görsel titreşim sinyallerinde, titreşimlerin çok sık kaydedilmesi ve bu nedenle birçok benzer görseller oluşmasından kaynaklı sınırlı sayılarda eğitim görseli hazırlanmıştır. Doğrulama için sistemi zorlayabilecek seviyelerde farklı boyutlarda ve farklı zamanlarda doğrulama işlemleri gerçekleştirilmiştir.
- Eğitim işlemlerinde kullanılan bilgisayarda kaynak özellikleri çok yüksek olmamasından kaynaklı eğitim işlemleri işlemci desteğiyle gerçekleştirilmektedir.
- Spektrogram kullanılmamasının sebebi belirli desibel seviyelerinde sabitlenmesi ve bilgi kaybı meydana getirmesidir.
- Evrişimli sinir ağlarının en büyük dezavantajı küçük veri girişi yapılırsa daha fazla tahmin işlemi gerçekleştireceğinden genellikle büyük miktardaki veriler ile harcanan zamana yakın bir zaman harcayacaktır. Bunun önüne geçmek için dengeli sayılarda girdi görselleri kullanılmıştır.
- NASA Rulman Veri Seti kullanan çalışmaların literatür araştırması yapıldığında genellikle kestirimci bakım uygulamalarında kullanıldığı gözlemlenmiştir. Bizim tez çalışmamızda bunun aksine hata oluşması durumunun etkin tespitiyle bakım kararı verilmesi konusunda NASA Rulman Veri Seti kullanılmıştır.

Elde edilen doğruluk oranları tez kapsamında kullanılan derin evrişimli sinir ağları modellerinde %100’lük başarıyı elde edememiştir. Bunu elde edebilmek için gelecekte ResNet-18, SqueezeNet ve Incetion-ResNet-V2 gibi farklı evrişimli sinir ağları ile sonuçlar değerlendirilebilir. Zaman-frekans dönüşümlerinde Stokwell Dönüşümü gibi farklı dönüşüm yöntemleri eklenebilir. Titreşim sinyallerine farklı gürültü verileri eklenerek başarı durumlarındaki değişimler değerlendirilebilir. Hazır veri seti kullanmak yerine NASA Rulman Veri Seti’nde yer alan düzeneğe benzer mantıkta bir düzenek kurularak rulmanlardan veriler alınabilir ve “Nesnelerin İnterneti (IoT)” aracılığıyla bir depoda biriktirilebilir. Gelecekte biriktirilen bu canlı veriler gerçek bir sistem simülasyonu devreye alınabilir.

Ek olarak evriřimli sinir aęlarının başarıya ulaşmasında ihtiyaç duyulan çok sayıda deney sayısı ihtiyacını aza indirmek için farklı derin öğrenme yöntemleri araştırılabilir. Bunun yanı sıra eğitim süreçlerinin işleyiş sürelerinin farkını görebilmek açısından farklı programlama dilleri örneęin Python kullanılarak benzer dönüşümler ve eğitim süreçleri yürütülebilir.

KAYNAKLAR

- Abraham, A. 2005. Artificial neural networks. Handbook of measuring system design.
- Aggarwal, C. C. 2018. Neural networks and deep learning. Springer, 10, 978-3.
- Akuruyejo, M., Kowontan, S., & Ali, J. B. 2018. A data-driven approach based health indicator for remaining useful life estimation of bearings. In 2017 18th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA) (pp. 284-289). IEEE.
- Allen, R. L., & Mills, D. 2004. Signal analysis: time, frequency, scale, and structure. John Wiley & Sons.
- Ambika, P. S., Rajendrakumar, P. K., & Ramchand, R. 2019. Vibration signal based condition monitoring of mechanical equipment with scattering transform. Journal of Mechanical Science and Technology, 33(7), 3095-3103.
- Andén, J., & Mallat, S. 2014. Deep scattering spectrum. IEEE Transactions on Signal Processing, 62(16), 4114-4128.
- Anonim 2020, Nöral Ağlar. <https://www.ibm.com/tr-tr/cloud/learn/neural-networks> – (Son Erişim Tarihi: 19.11.2022).
- Anonim 2022a, What is machine learning? <https://www.ibm.com/cloud/learn/machine-learning> - (Son Erişim Tarihi : 24.11.2022).
- Anonim 2022b, Sinir Ağı Nedir? <https://aws.amazon.com/tr/what-is/neural-network/> - (Son Erişim Tarihi: 05.12.2022).
- Babouri, M. K., Djebala, A., Ouelaa, N., Oudjani, B., & Younes, R. 2020. Rolling bearing faults severity classification using a combined approach based on multi-scales principal component analysis and fuzzy technique. The International Journal of Advanced Manufacturing Technology, 107(9), 4301-4316.
- Bayrak, Y., Yılmaz, Ş., Bayrak, E., & Aksoy, S. 2011. Farklı Yöntemlerle Deprem Kayıtlarının Zaman-Frekans Analizi. 1. Türkiye Deprem Mühendisliği ve Sismoloji Konferansı (ODTÜ – Ankara).
- Bechhoefer, E. 2013. Condition based maintenance fault database for testing diagnostics and prognostic algorithms. MFPT Data.
- Bentivoglio, R., Isufi, E., Jonkman, S. N., & Taormina, R. 2022. Deep learning methods for flood mapping: a review of existing applications and future research directions. Hydrology and Earth System Sciences, 26(16), 4345-4378.

- Bhadane, M., & Ramachandran, K. I. 2017. Bearing fault identification and classification with convolutional neural network. In 2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT) (pp. 1-5). IEEE.
- Bhandari, B. 2021. Comparative Study of Popular Deep Learning Models for Machining Roughness Classification Using Sound and Force Signals. *Micromachines*, 12(12), 1484.
- Büssow, R. 2007. An algorithm for the continuous Morlet wavelet transform. *Mechanical Systems and Signal Processing*, 21(8), 2970-2979.
- Cao, G., Zhang, K., Zhou, K., Pan, H., Xu, Y., & Liu, J. 2020, May. A feature transferring fault diagnosis based on WPDR, FSWT and GoogLeNet. In 2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) (pp. 1-6). IEEE.
- Cavalaglio Camargo Molano, J., Strozzi, M., Rubini, R., & Cocconcelli, M. 2019. Analysis of nasa bearing dataset of the university of cincinnati by means of hjorth's parameters. In International Conference on Structural Engineering Dynamics ICEDyn 2019.
- Chen, Q., Dong, X., Tu, G., Wang, D., Zhao, B., & Peng, Z. 2022. TFN: An Interpretable Neural Network with Time-Frequency Transform Embedded for Intelligent Fault Diagnosis. arXiv preprint arXiv:2209.01992.
- Chong UP 2011. Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two-dimension domain. *Stroj Vestn J Mech Eng* 57(9):655–666.
- Daubechies, I., Lu, J., & Wu, H. T. 2011. Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool. *Applied and computational harmonic analysis*, 30(2), 243-261.
- Eren L, Ince T, Kiranyaz S 2019. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier. *J Signal Process Syst* 91(2):179–189. <https://doi.org/10.1007/s11265-018-1378-3>.
- Ertorsun, A. D., Bağ, B., Uzar, G., & Turanoğlu, M. A. 2010. ROC (Receiver Operating Characteristic) Eğrisi Yöntemi İle Tanı Testlerinin Performanslarının Değerlendirilmesi. XII. Öğrenci Sempozyumu Çalışma Grubu Raporları. XII. Öğrenci Sempozyumu Çalışma Grubu Raporları.
- Flandrin, P. 1998. Time-frequency/time-scale analysis. Academic press.
- Gao, Z., Cecati, C., & Ding, S. X. 2015. A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE transactions on industrial electronics*, 62(6), 3757-3767.

- Gao, Y., & Mosalam, K. M. 2018. Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering*, 33(9), 748-768.
- Goswami, D. 2019. Comparison of Sigmoid, Tanh and ReLU Activation Functions. <https://www.aitude.com/comparison-of-sigmoidtanhand-relu-activation-f>, (Son Erişim Tarihi 19 Ağustos 2022)
- Guo, L., Lei, Y., Xing, S., Yan, T., & Li, N. 2019. Deep convolutional transfer learning network: a new method for intelligent fault diagnosis of machines with unlabeled data. *IEEE Trans Ind Electron* 66(9):7316–7325.
- Hakan, A. L. P., Akıncı, T. Ç., & Albora, M. 2008. Jeofizik Uygulamalarda Fourier Ve Dalgacık Dönüşümlerinin Karşılaştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 14(1), 67-76.
- Haykin, S. 2009. *Neural networks and learning machines*, 3/E. Pearson Education India.
- He, K., Zhang, X., Ren, S., & Sun, J. 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770- 778).
- Hoang, D. T., & Kang, H. J. 2019. Rolling element bearing fault diagnosis using convolutional neural network and vibration image. *Cognitive Systems Research*, 53, 42-50.
- Hu Q, He Z, Zhang Z, Zi Y 2007. Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble, vol 21. doi:<https://doi.org/10.1016/j.ymssp.2006.01.007>21, 705.
- Huang, D.-S. 1996. *Systematic theory of neural networks for pattern recognition*. Beijing 201: Publishing House of Electronic Industry of China.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Liu, H. H. 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995. <https://doi.org/10.1098/rspa.1998.0193>
- Hussain, M., Bird, J. J., & Faria, D. R. 2018. A study on cnn transfer learning for image classification. In *UK Workshop on computational Intelligence* (pp. 191-202). Springer, Cham.
- Ince, T., Malik, J., Devecioglu, O. C., Kiranyaz, S., Avci, O., Eren, L., & Gabbouj, M. 2021. Early bearing fault diagnosis of rotating machinery by 1d self-organized operational neural networks. *IEEE Access*, 9, 139260-139270.

J. Lee, H. Qiu, G. Yu, J. Lin, and Rexnord Technical Services 2007. IMS, University of Cincinnati. "Bearing Data Set", NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA

James, C. 2022. What Is a Neural Network?
<https://www.investopedia.com/terms/n/neuralnetwork.asp> – (Yayın Tarihi: 21.11.2022)

Janssens, O., Slavkovikj, V., Vervisch, B., Stockman, K., Loccufier, M., Verstockt, S., & Van Hoecke, S. 2016. Convolutional neural network based fault detection for rotating machinery. *Journal of Sound and Vibration*, 377, 331-345.

Jardine, A. K., Lin, D., & Banjevic, D. 2006. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7), 1483-1510.

Jona, T. 2022. Maintenance: Definitions, Benefits, and Application, 29 Ağustos 2022.
<https://safetyculture.com/topics/maintenance/> (Erişim Tarihi: 22.11.2022)

Kalyoncu, M. 2006. Titreşim analizi ile makina elemanları arızalarının belirlenmesi. *Mühendis ve Makina*, 47(552), 28-35.

Karatoprak, H. E. 2019. Improved hilbert huang transform supported by machine learning algorithms for signal analysis.

Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. 2020. A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53(8), 5455-5516.

Kim, J., & Kim, J. M. 2020. Bearing fault diagnosis using grad-CAM and acoustic emission signals. *Applied Sciences*, 10(6), 2050.

LeCun, Y., Bengio, Y., & Hinton, G. 2015. Deep learning. *nature*, 521(7553), 436-444.

Li, B., Chow, M. Y., Tipsuwan, Y., & Hung, J. C. 2000. Neural-network-based motor rolling bearing fault diagnosis. *IEEE transactions on industrial electronics*, 47(5), 1060-1069.

Li, C., Sanchez, V., Zurita, G., Lozada, M. C., & Cabrera, D. 2016. Rolling element bearing defect detection using the generalized synchrosqueezing transform guided by time–frequency ridge enhancement. *ISA transactions*, 60, 274-284.

Li, Y., & Zheng, X. 2008. Spectral decomposition using Wigner-Ville distribution with applications to carbonate reservoir characterization. *The Leading Edge*, 27(8), 1050-1057.

- Lilly, J. M. 2017. Element analysis: a wavelet-based method for analysing time-localized events in noisy time series. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 473(2200), 20160776.
- Lilly, J. M., & Olhede, S. C. 2008. Higher-order properties of analytic wavelets. *IEEE Transactions on Signal Processing*, 57(1), 146-160
- Lin, H. C., Ye, Y. C., Huang, B. J., & Su, J. L. 2016. Bearing vibration detection and analysis using enhanced fast Fourier transform algorithm. *Advances in Mechanical Engineering*, 8(10), 1687814016675080.
- Lou, X., & Loparo, K. A. 2004. Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical systems and signal processing*, 18(5), 1077-1095.
- Lu C, Wang Y, Ragulskis M, Cheng Y 2016. Fault diagnosis for rotating machinery: a method based on image processing. *PLoS ONE* 11(10):e0164111
- Lu Y, Xie R, Liang SY 2020. CEEMD-assisted kernel Support vector machines for bearing diagnosis. *Int J Adv Manuf Technol* 106:3063–3070
- Ma, P., Zhang, H., Fan, W., Wang, C., Wen, G., & Zhang, X. 2019. A novel bearing fault diagnosis method based on 2D *image* representation and transfer learning-convolutional neural network. *Measurement Science and Technology*, 30(5), 055402.
- Malhi, A., & Gao, R. X. 2004. PCA-based feature selection scheme for machine defect classification. *IEEE transactions on instrumentation and measurement*, 53(6), 1517-1525.
- Mallat, S. 1999. *A wavelet tour of signal processing*. Elsevier.
- Mobley, R. K. 2002. *An introduction to predictive maintenance*. Elsevier.
- Moler, C., Little, J., & Bangert, S. 1982. *MATLAB users' guide*. Albuquerque, NM, USA: University of New Mexico.
- Narkhede, S. 2018. Understanding AUC – ROC Curve. <https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5> - (Son Erişim Tarihi : 26.12.2022)
- Nandi, S., Toliyat, H. A., & Li, X. 2005. Condition monitoring and fault diagnosis of electrical motors—A review. *IEEE transactions on energy conversion*, 20(4), 719-729.
- Nanni, L., Costa, Y. M., Aguiar, R. L., Silla Jr, C. N., & Brahnam, S. 2018. Ensemble of deep learning, visual and acoustic features for music genre classification. *Journal of New Music Research*, 47(4), 383-397. <https://pnsn.org/spectrograms/what-is-a-spectrogram>
- Neupane, D., & Seok, J. 2020. Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review. *IEEE Access*, 8, 93155-93178.

- Ni, Q., Ji, J. C., Feng, K., & Halkon, B. 2022. A fault information-guided variational mode decomposition (FIVMD) method for rolling element bearings diagnosis. *Mechanical Systems and Signal Processing*, 164, 108216.
- Pan, S. J., & Yang, Q. 2010. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- Peng, Z., Chu, F., & He, Y. 2002. Vibration signal analysis and feature extraction based on reassigned wavelet scalogram. *Journal of Sound and Vibration*, 253(5), 1087-1100.
- Pinedo-Sanchez, L. A., Mercado-Ravell, D. A., & Carballo-Monsivais, C. A. 2020. Vibration analysis in bearings for failure prevention using CNN. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 42(12), 1-17.Chicago.
- Qiu, H., Lee, J., Lin, J., & Yu, G. 2006. Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics. *Journal of sound and vibration*, 289(4-5), 1066-1090.
- Rueda, A., & Krishnan, S. 2019. Augmenting dysphonia voice using Fourier-based synchrosqueezing transform for a CNN classifier. In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 6415-6419). IEEE.
- Samanta, B., & Al-Balushi, K. R. 2003. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical systems and signal processing*, 17(2), 317-328.
- Sanakkayala, D. C., Varadarajan, V., Kumar, N., Soni, G., Kamat, P., Kumar, S., ... & Kotecha, K. 2022. Explainable AI for Bearing Fault Prognosis Using Deep Learning Techniques. *Micromachines*, 13(9), 1471.
- Satya, G. 2020. What's The Role Of Weights And Bias In a Neural Network? - <https://towardsdatascience.com/whats-the-role-of-weights-and-bias-in-a-neural-network-4cf7e9888a0f>
- Scholl, S. 2021. Fourier, Gabor, Morlet or Wigner: Comparison of Time-Frequency Transforms. *arXiv preprint arXiv:2101.06707*.
- Souza, R. M., Nascimento, E. G., Miranda, U. A., Silva, W. J., & Lepikson, H. A. 2021. Deep learning for diagnosis and classification of faults in industrial rotating machinery. *Computers & Industrial Engineering*, 153, 107060.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. 2014. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Şirin, E. 2017. Hata Matrisini (Confusion Matrix) Yorumlama. <https://www.veribilimiokulu.com/hata-matrisini-confusion-matrix-yorumlama/> - Son Erişim Tarihi : 26.12.2022.

- Tang, Z., Li, M., & Wang, X. 2020. Mapping Tea Plantations from VHR Images Using OBIA and Convolutional Neural Networks. *Remote Sensing*, 12(18), 2935. doi:10.3390/rs12182935
- Thakur, G. 2014. The Synchrosqueezing transform for instantaneous spectral analysis. arXiv preprint arXiv:1404.7550.
- Tyagi, V. 2020. NASA Bearing Dataset (Prognostic Dataset for Predictive/Preventive Maintenance). <https://www.kaggle.com/datasets/vinayak123tyagi/bearing-dataset> Son Erişim Tarihi: 05.09.2022
- Tong, Z., Li, W., Zhang, B., Jiang, F., & Zhou, G. 2018. Bearing fault diagnosis under variable working conditions based on domain adaptation using feature transfer learning. *IEEE Access*, 6, 76187-76197.
- Upadhyayula, S. M., & Venkataramanan, K. 2020. Mathematical methods in deep learning. *Mathematical methods in interdisciplinary sciences*, 49-61.
- Vaughan, D. 2022. Multiclass averaging. <https://cran.r-project.org/web/packages/yardstick/vignettes/multiclass.html> - (Son Erişim Tarihi: 26.12.2022)
- Verstraete, D., Ferrada, A., Droguett, E. L., Meruane, V., & Modarres, M. 2017. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings. *Shock and Vibration*, 2017.
- Wang, J., Ma, Y., Huang, Z., Xue, R., & Zhao, R. 2019. Performance analysis and enhancement of deep convolutional neural network. *Business & Information Systems Engineering*, 61(3), 311-326.
- Wei, Z., Yuan, W., Li, S., Yuan, J., Bharatula, G., Hadani, R., & Hanzo, L. 2021. Orthogonal time-frequency space modulation: A promising next-generation waveform. *IEEE wireless communications*, 28(4), 136-144.
- Wen, L., Li, X., Gao, L., & Zhang, Y. 2017. A new convolutional neural network-based data-driven fault diagnosis method. *IEEE Transactions on Industrial Electronics*, 65(7), 5990-5998.
- Wen, L., Li, X., & Gao, L. 2020. A transfer convolutional neural network for fault diagnosis based on ResNet-50. *Neural Computing and Applications*, 32(10), 6111-6124.
- Yen, G. G., & Lin, K. C. 2000. Wavelet packet feature extraction for vibration monitoring. *IEEE transactions on industrial electronics*, 47(3), 650-667.
- Youngberg, J., & Boll, S. 1978. Constant-Q signal analysis and synthesis. In *ICASSP'78. IEEE International Conference on Acoustics, Speech, and Signal Processing (Vol. 3, pp. 375-378)*. IEEE.

- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. 2021. Dive into deep learning. arXiv preprint arXiv:2106.11342.
- Zhang, J., Sun, Y., Guo, L., Gao, H., Hong, X., & Song, H. 2020. A new bearing fault diagnosis method based on modified convolutional neural networks. *Chinese Journal of Aeronautics*, 33(2), 439-447.
- Zhang, R., Peng, Z., Wu, L., Yao, B., & Guan, Y. 2017. Fault diagnosis from raw sensor data using deep neural networks considering temporal coherence. *Sensors*, 17, 549–565.
- Zhang, W., Zhang, F., Chen, W., Jiang Y., & Song, D. 2018. Fault state recognition of rolling bearing based fully convolutional network. *Comput Sci Eng* 21(5):55–63.
- Zhao, D., Wang, T., & Chu, F. 2019. Deep convolutional neural network based planet bearing fault classification. *Computers in Industry*, 107, 59-66.
- Zhao, J., Yang, S., Li, Q., Liu, Y., Gu, X., & Liu, W. 2021. A new bearing fault diagnosis method based on signal-to-image mapping and convolutional neural network. *Measurement*, 176, 109088.

ÖZGEÇMİŞ

Adı Soyadı : Mert ÇELTİKOĞLU
Doğum Yeri ve Tarihi : Bursa / 06.05.1994
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Alanyurt İMKB Anadolu Teknik Lisesi
Lisans : Kocaeli Üniversitesi – Bilgisayar Mühendisliği
Yüksek Lisans : -

Çalıştığı Kurum/Kurumlar : Rexum Bilişim Hizmetleri, Ermaksan Optoelektronik ve AR-GE Merkezi, Coşkunöz Holding / CITS Bilişim Hizmetleri (Devam Ediyor)

İletişim (e-posta) : mrtceltikoglu@gmail.com

Yayınları : B. Deveci, M. Çeltikoğlu, P. Kirci, et al. "A Comparison of Deep Transfer Learning Methods on Bearing Fault Detection." FiCloud. 2021.