

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YAPAY ZEKÂ VE SİNYAL İŞLEME YÖNTEMLERİ İLE
RULMANLARDA TAŞLAMA YANIĞI HATASININ TESPİTİ**

DOKTORA TEZİ

Nurdoğan CEYLAN

Enstitü Anabilim Dalı : MEKATRONİK MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Sezgin KAÇAR

Temmuz 2023

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKÂ VE SİNYAL İŞLEME YÖNTEMLERİ İLE
RULMANLARDA TAŞLAMA YANIĞI HATASININ TESPİTİ

DOKTORA TEZİ

Nurdoğan CEYLAN

Enstitü Anabilim Dalı : MEKATRONİK
MÜHENDİSLİĞİ

Bu tez 14/07/2023 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Prof. Dr. İhsan PEHLİVAN	BAŞARILI
Üye: Doç. Dr. Sezgin KAÇAR	BAŞARILI
Üye: Doç. Dr. Ünal ÇAVUŞOĞLU	BAŞARILI
Üye: Dr. Öğr. Üyesi Mücahit SOYASLAN	BAŞARILI
Üye: Dr. Öğr. Üyesi Kaplan KAPLAN	BAŞARILI

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim

Nurdoğan CEYLAN

14/07/2023

TEŞEKKÜR

Doktora eğitimim boyunca bilgi ve deneyimlerinden yararlandığım, her konuda desteğini aldığım, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında beni yönlendiren değerli danışman hocam Doç. Dr. Sezgin KAÇAR'a teşekkürlerimi sunarım.

Lisans ve Lisansüstü eğitimim sırasında müracaat ettiğim her konuda beni destekleyen hocam Prof. Dr. Hüseyin Metin ERTUNÇ'a, teşekkür ederim.

Sakarya Uygulamalı Bilimler Üniversitesi Mekatronik Mühendisliği Bölümü önceki başkanı hocam Prof. Dr. Osman ELDOĞAN'a ve şimdiki bölüm başkanımız ve yüksek lisans danışman hocam Prof. Dr. Durmuş KARAYEL'e teşekkür ederim.

Lisansüstü eğitim ve iş süreçlerimin her aşamasında bana yol gösteren Dr. Öğr. Üyesi Mücahit SOYASLAN'a teşekkür ederim.

Ayrıca bu çalışmada kullanılan verilerin temini süreçlerinde bizlere gereken bütün yardımı gösteren Ortadoğu Rulman Sanayi ve Ticaret A.Ş. yetkililerine ve AR-GE müdürü Ozan MÜŞTAK Bey'e teşekkür ederim.

Eğitim hayatımda çok müstesna bir yeri olan Zübeyir GÜLLÜCE'ye, tükenmez bir öğretme heyecanı ve insani yaklaşımı ile eğitimcilik konusunda beni derinden etkileyen kıymetli hocam Şerif YORULMAZ'a ve şahsında bende emeği olan bütün öğretmenlerime teşekkür ederim.

Hayatımın her döneminde beni en yakından destekleyen abilerim Zinnur CEYLAN ve Harun CEYLAN'a, ablalarım Rüveyda CEYLAN ve Latife CEYLAN'a, eşim Zehranur CEYLAN ve kızım Nurefşan CEYLAN'a, biricik annem merhume Aliye CEYLAN ve kıymetli babam Mustafa CEYLAN'a teşekkür ederim.

İÇİNDEKİLER

BEYAN.....	iii
TEŞEKKÜR	i
İÇİNDEKİLER	ii
KISALTMALAR	v
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
ÖZET.....	ix
ABSTRACT	x

BÖLÜM 1.

GİRİŞ	1
1.1. Literatür Taraması	12
1.2. Tezin Tanıtımı ve Tezin Literatüre Katkısı	18
1.3. Araştırmanın Ekonomik Etkisi	21
1.4. Tez Organizasyonu	22

BÖLÜM 2.

AKUSTİK EMİSYON SENSÖRÜ İLE VERİ TOPLAMA VE VERİ SETİ	24
---	----

BÖLÜM 3.

VERİ SETİNİN ÖN İŞLEMESİ.....	35
3.1. Hilbert-Huang Dönüşümü(HHT).....	35
3.2. Kısa Dönem Fourier Dönüşümü (Short-Term Fourier Transform-STFT) 36	
3.3. Sürekli Dalgacık Dönüşümü (Continious Wavelet Transform-CWT,)	37

BÖLÜM 4.	
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAŞLAMA YANIĞININ TESPİTİ.....	39
4.1. Teorik Arka Plan.....	39
4.1.1. En yakın K komşuluğu (K-Nearest Neighbours-KNN).....	39
4.1.2. Destek vektör makineleri (Support Vector Machine-SVM) ile rulman hatalarının sınıflandırılması	43
4.2. Makine Öğrenmesi Yöntemleri ile Taşlama Yanığının Tesbitinde Kullanılan Metot.....	44
4.2.1. AE verilerinin ön işleme ile hatalı-normal veri setinin oluşturulması	46
4.2.2. ML Yöntemi ve hiperparametre seçimi	47
4.2.3. Uygulama sonuçları ve başarımlar metrikleri	47
 BÖLÜM 5.	
TASARLANAN LSTM AĞIYLA TAŞLAMA YANIĞININ TESPİTİ.....	52
5.2. Tasarlanan LSTM Ağı ile Taşlama Yanığının Tesbitinde Kullanılan Metot.....	54
5.2.1. AE Verilerinden entropi ve anlık frekans değerlerinin elde edilmesi ve verilerin ön işleme	56
5.2.1.1. Anlık frekans	56
5.2.1.2. Spektral entropi	56
5.2.2. Verilerin ön işleme	57
5.2.3. LSTM Ağının oluşturulması	58
5.2.4. LSTM Ağında taşlama yanığı tespiti.....	58
 BÖLÜM 6.	
ÖN-EĞİTİMLİ AĞLAR İLE TAŞLAMA YANIĞININ TESPİTİ	60
6.1. Teorik Arka Plan.....	60
6.1.1. Evrişimli sinir ağları (Convolutional Neural Networks-CNN).....	61
6.2. Öğrenme Aktarması (Transfer Learning-TL).....	63
6.3. Ön Eğitimli Ağlarda Taşlama Yanığının Tespiti.....	66
6.3.1. Metot	66
6.3.2. Ön eğitimli ağlarda ve tasarlanan 2D-CNN ağında kullanılan veri setinin oluşturulması	68
6.3.3. CWT, STFT ve HHT ile TF Görüntülerinin elde edilmesi.....	69
6.3.4. Ön eğitimli ağların parametreleri ve ön eğitimli ağlarda sınıflandırma	71

BÖLÜM 7.

TASARLANAN 2D-CNN AĞI İLE TAŞLAMA YANIĞININ TESPİTİ..... 81

7.1. Tasarlanan 2D-CNN Ağının Yapısı ve Ağ Parametreleri 81

7.2. 2D-CNN Ağıyla Taşlama Yanığının Tespiti 82

BÖLÜM 8.

SONUÇLAR VE DEĞERLENDİRMELER 85

8.1. ML Uygulamaları ve LSTM Uygulamalarına İlişkin Çıkarımlar 85

8.2. Ön Eğitimli Ağlar ve 2D-CNN Ağıyla Yapılan Uygulamalardan Elde
Edilen Sonuçlar..... 86

KAYNAKLAR 90

KISALTMALAR

AE	: Akustik Emisyon
ANN	: Artificial Neural Network
BP	: Backpropagation
CWT	: Continious Wavelet Transform (Sürekli Dalgacık Dönüşümü)
CL	: Convolution Layer (Evrişim Katmanı)
DL	: Deep Learning
HHT	: Hilbert-Huang Transform (Hilbert-Huang Dönüşümü)
KNN	: K-Nearist Neighbours (En Yakın K Komşuluğu)
LSTM	: Long-Short Term Memory
ML	: Machine Learning (Makine Öğrenmesi)
ORS	: Ortadoğu Rulman Sanayii ve Ticaret Anonim Şirketi
PL	: Pooling Layer (Depolama Katmanı)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ağları)
RNN	: Recursive Neural Network (Özyinelemeli Sinir Ağları)
ReLU	: Rectifier Linear Unit
TF	: Time-Frequency (Zaman-Frekans)
TFG	: Time-Frequency (Zaman-Frekans) Görüntüleri
TL	: Transfer Learning (Öğrenme Aktarması)
VS	: Veri Seti
YSA	: Yapay Sinir Ağları

TABLolar LİSTESİ

Tablo 1.1 : Mevcut literatür ve önerilen yöntemin karşılaştırılması.....	17
Tablo 2.1 : 100Cr6 Çeliğin kimyasal bileşimi ve mekanik özellikleri	25
Tablo 2.2 : Kistler 8152C1050500 sensörünün özellikleri	27
Tablo 2.3 : Taşlama diskinin teknik özellikleri.....	28
Tablo 2.4 : Makara taşlama deneylerinde kullanılan tezgah ayarları, deney sayıları ve dosya kayıt isimleri.....	29
Tablo 2.5 : Dış bilezik taşlama deneylerinde kullanılan tezgah ayarları, deney sayıları ve dosya kayıt isimleri.....	33
Tablo 4.1 : ML Uygulamaları için oluşturulan veri seti.....	47
Tablo 4.2 : K-NN Yöntemi hiperparametreleri ve farklı K-NN ağları için uygulama sonuçları	48
Tablo 4.3 : AMP-Veri Seti-1 ile yapılan SVM deneyleri	50
Tablo 5.1 : LSTM Uygulamaları için hazırlanan veri seti	58
Tablo 5.2 : LSTM Ağının katman yapısı	58
Tablo 5.3 : LSTM Ağında yapılan uygulama sonuçları.....	59
Tablo 6.1 : Ön-eğitilmiş ağların katman yapısı	65
Tablo 6.2 : Ön eğitilmiş ağlarda ve 2D-CNN ağında kullanılan veri seti	68
Tablo 6.3 : Ön eğitilmiş ağlarla ve 2D-CNN ağıyla yapılan uygulamalarında kullanılan CWT, STFT, HHT görüntü verilerinin kombinasyonları	70
Tablo 6.4 : Ön eğitilmiş ağların ağ parametreleri.....	72
Tablo 6.5 : Ön eğitilmiş ağlarla yapılan uygulamaların sınıflandırma başarımları	73
Tablo 6.6 : SqueezeNet ağında skalogram görüntülerinin sınıflandırılmasına ait başarımlar metrikleri	76
Tablo 6.7 : GoogleNet ağında spektrogram görüntülerinin sınıflandırılmasına ait başarımlar metrikleri	79
Tablo 7.1 : 2D-CNN Ağının katman yapısı ve katman özellikleri	82
Tablo 7.2 : 2D-CNN Ağının eğitim parametreleri	82
Tablo 7.3 : 2D-CNN ağıyla yapılan uygulamaların sonuçları	83
Tablo 7.4 : 2D-CNN ağında skalogram görüntülerinin sınıflandırılmasına ait başarımlar metrikleri	84
Tablo 8.1 : Tez kapsamında gerçekleştirilen derin öğrenme uygulamalarının maksimum ve minimum doğruluk değerleri	87
Tablo 8.2 : Literatürdeki çalışmalarla karşılaştırma	87

ŞEKİLLER LİSTESİ

Şekil 1.1 : Taşlama yanığının neden olduğu rulman hata modlarından kırılma hatasının gösterimi	2
Şekil 1.2 : Taşlama makinasında yapılan bir taşlama işlemi sırasında AE sensörü ile veri toplanması	4
Şekil 1.3 : Derin öğrenme modeli örneği ve basit temsili.....	7
Şekil 1.4 : Derin öğrenmenin yapay zekâ içerisindeki yeri.	9
Şekil 1.5 : Farklı Yapay Zekâ sistemlerinin birbiriyle ilişkilerini gösteren akış şeması	9
Şekil 1.6 : Rulman hata literatürünün sınıflandırılması	12
Şekil 1.7 : Verilerin elde edildiği taşlama tezgahı. a) taşlama diski b) akustik emisyon sensörü	19
Şekil 1.8 : ORS Laboratuvarlarında elde edilen akustik emisyon verileri.....	19
Şekil 2.1 : Toyo T-11LA88 iç taşlama makinesi	26
Şekil 2.2 : Kistler 8152C1050500 serisi AE sensörü	27
Şekil 2.3 : 41 Adet makara taşlaması deneyinden elde edilen AE sinyalleri.....	32
Şekil 2.4 : Dış bilezik taşlamasından elde edilen ae sinyalleri	34
Şekil 3.1 : STFT ve CWT nin TF çözünürlüğüne etkisi	38
Şekil 4.1 : Örnek veri seti.....	40
Şekil 4.2 : K=3 ile KNN ile örnek veri setinin sınıflarının tahmini.....	41
Şekil 4.3 : Farklı K değerleri için “a) K=1, b)K=3, c)K=9” K-NN tarafından oluşturulan karar sınırları	42
Şekil 4.4 : K=3 ile KNN ile örnek veri setinin sınıflarının tahmini.....	44
Şekil 4.5 : ML Yöntemlerinin uygulama adımları	45
Şekil 4.6 : ML Uygulama adımları gösterimi	46
Şekil 4.7 : Fine K-NN modeli tahminleri ve karışıklık matrisi.....	49
Şekil 4.8 : Fine Gauss SVM karışıklık matrisi.....	50
Şekil 5.1 : Bir RNN hücresi	52
Şekil 5.2 : Bir LSTM hücresi	53
Şekil 5.3 : Tasarlanan LSTM ağıyla taşlama yanığının tesbitinde kullanılan metodun uygulama adımları.....	55
Şekil 5.4 : Tasarlanan LSTM ağında yapılan sınıflandırma uygulamasına ait konfüzyon matrisi.....	59
Şekil 6.1 : CNN ağı katman yapısı.....	61
Şekil 6.2 : Evrişim İşleminin Gösterimi.....	62
Şekil 6.3 : Rulmanlarda taşlama yanığı tespiti işlem adımları.....	67
Şekil 6.4 : a) Uygulama 2 (SqueezeNet) eğitim süreci b) bu uygulamanın karışıklık matrisi.....	77
Şekil 6.5 : a) Uygulama 1 (SqueezeNet) eğitim süreci b) bu uygulamanın karışıklık matrisi.....	78

Şekil 6.6 : GoogleNet uygulama 1 eğitim süreci	79
Şekil 6.7 : GoogleNet uygulama 2 eğitim süreci	80
Şekil 7.1 : 2D-CNN ağında skalogram görüntülerinin sınıflandırılması uygulama 1 eğitim süreci	84



YAPAY ZEKÂ VE SİNYAL İŞLEME YÖNTEMLERİ İLE RULMANLARDA TAŞLAMA YANIĞI HATASININ TESPİTİ

ÖZET

Metal endüstrisinin ana işlemlerinden ve rulman üretiminin temel aşamalarından biri taşlamadır. Taşlama ile rulman parçalarının yüzey pürüzsüzlüğü ve boyutlandırma hassasiyeti artırılır. Ancak taşlama sırasında büyük miktarda ısı açığa çıkar. Bu ısının çoğu iş parçasına aktarılır. Bu durumda, iş parçasının yüzeyinde veya iç yapısında yanıklar oluşabilir. Bu yanıklar yüzey kalitesini bozmakta ve parçanın mekanik özellikleri zarar görmektedir. Yüzeyinde veya iç yapısında taşlama yanığı olan rulman parçaları, faydalı kullanım ömrün dolmadan kırılmakta veya çatlamaktadır. Rulmanlar dönen makinaların en temel yataklama elemanları olduğundan, rulmanda meydana gelen bir arıza makinenin bozulmasına sebep olacaktır. Bu nedenle rulman üretim süreçlerindeki kontrol aşamalarında taşlama yanığının tespiti önemlidir.

Taşlama yanığını tespit etmek için rulman üreticileri, bir çoğu tahribatlı yöntemler olan metalurjik yöntemler, gözle muayene veya sinyal işleme gibi dolaylı yöntemler kullanmaktadır. Metalurjik yöntemler gibi doğrudan yöntemler kesine en yakın sonuç vermesine karşın pahalı, zaman alıcı ve işleme sürecini durdurmaya gerektiren yöntemlerdir. Sinyal işleme gibi dolaylı yöntemler ise mutlak sonuç vermemekle birlikte ucuzdur, gerçek zamanlı sonuçlar üretebilirler ve tahribatsız yöntemlerdir.

Bu tezde, rulman parçalarında taşlama yanığının tespiti için sinyal işleme, derin öğrenme ve makine öğrenmesi temelli bir yöntem önerilmektedir. Öncelikle gerçek üretim koşullarında, bir taşlama makinasında, rulman parçaları taşlanırken, akustik emisyon sensörleriyle sinyaller toplanmıştır. Daha sonra bu sinyaller ya sinyal olarak kaydedilmiştir veya zaman-frekans gösterim yöntemleriyle görüntülere dönüştürülmüştür. Son adımda bu sinyal ve görüntüler derin öğrenme ve makine öğrenmesi yöntemleri ile hatalı-normal diye 2 sınıfa ayrılarak sınıflandırılmıştır. Sinyal olarak sınıflandırmak için uzun dönemli kısa süreli bellek, destek vektör makineleri ve en yakın K komşuluğu yöntemleri kullanılmıştır. Bu yöntemlerden elde edilen sonuçlara göre %93 doğruluk oranına ulaşılmıştır. Zaman-frekans görüntüleri ise farklı transfer learning ağları (Googlenet, Resnet-50, SqueezeNet ve Alexnet) ve tasarlanan yeni bir evrişimli sinir ağı kullanılarak yüksek doğrulukla sınıflandırılmıştır. Görüntü sınıflandırma uygulamalarında ise %100 doğruluk oranlarına ulaşılmıştır. Bu hem literatürdeki karşılaştırılabilir çalışmalara kıyasla hem de üretim süreçlerindeki testlere göre iyi bir sonuçtur.

Gerçek üretim koşullarından elde edilen verilerle, yapay zekâ ve sinyal işleme yöntemleri kullanılarak rulman parçalarında taşlama yanığının tespit edilmesi tezin literatüre temel katkısı olarak gösterilebilir.

Anahtar Kelimeler: Rulmanlarda Taşlama Yanığı Tespiti, Derin Öğrenme, Makine Öğrenmesi, Sinyal İşleme

DETECTION OF GRINDING BURN IN BEARINGS WITH ARTIFICIAL INTELLIGENCE AND SIGNAL PROCESSING METHODS

ABSTRACT

Grinding is one of the main processes of the metal industry and one of the key stages of bearing production. Grinding is a high and specific energy machining process widely used in the manufacture of components that require fine tolerances and smooth surfaces. Grinding improves the surface smoothness and dimensional accuracy of bearing parts. Almost all of the energy expended in the grinding process is converted into heat and transferred to the workpiece. This raises the temperature of the work surface. This can cause burns on the surface or internal structure of the workpiece and adversely affect the mechanical properties of the workpiece, such as tensile stress. These burns deteriorate the surface quality and the mechanical properties of the part suffer. Grinding burns are one of the main constraints when trying to improve the surface finish of the components being ground, because any change that improves the surface finish also increases the risk of grinding burns. Grinding burn is the oxidation of the machining surface caused by the high temperature generated on the workpiece surface during grinding. The causes affecting the formation of grinding burn can be listed as follows.

- Abrasive: The grain size and material of the abrasive used affect the formation of grinding burn. Fine grain abrasives increase the formation of grinding burn.
- Material to be machined: As the hardness of the material increases, the risk of grinding burn also increases.
- Application parameters: Parameters such as cutting speed, feed rate, contact pressure affect the formation of grinding burns. Increasing the cutting speed increases the risk of grinding burns, while decreasing the feed speed increases the risk of grinding burns. The effect of contact pressure on grinding burn is limited.

Since bearings are the most basic bearing elements of rotating machines, a bearing failure will affect the failure of the machine. Bearing parts with grinding burns on the surface or internal structure break or crack before the end of their useful life. Therefore, it is important to detect grinding burns during the control stages of bearing manufacturing processes.

Grinding burn detection is critical in bearing manufacturing to ensure that the final product is of high quality and can perform its intended function efficiently. If grinding burns are not detected during the manufacturing control stages, they can cause significant damage to the bearings, resulting in their failure and, eventually, the failure of the entire machine. As a result, detecting grinding burns early in the manufacturing process can aid in the prevention of such failures.

Metallurgical methods and visual inspection are commonly used methods for detecting grinding burns in bearing manufacturing. These methods are called direct detection methods. These are costly, time-consuming, and incapable of detecting threats in real time. For example, metallurgical methods necessitate the use of specialized equipment and trained personnel to examine bearing material samples, which is a time-consuming process that can cause delays in the manufacturing process. Similarly, visual inspection is dependent on the operator's visual acuity and experience, both of which can be subjective and error-prone. In summary, direct detection methods provide the closest accuracy, but are expensive, time-consuming and disadvantageous for real-time implementation.

In contrast, there is another detection method, called indirect detection methods, which is based on the measurement of the effects caused by the defect. In this method, the change in phenomena such as vibration, acoustic emission, force, electric current and voltage is measured and the defect is detected using signal processing, image processing and classification tools. Although this method is based on some estimation algorithms, it is an inexpensive, real-time and non-destructive detection method.

According to this method, signals are received with sensors related to the measured phenomenon. The received signals are digitized and transferred to the computer. These data about the measured phenomenon are evaluated with signal processing methods, image processing methods or artificial intelligence based algorithms to detect faulty signals. This is often a classification problem that requires the separation of erroneous signals from error-free signals. For this reason, signal or image classification methods are used after the signals are acquired.

One of the most commonly used measurement parameters in indirect methods is acoustic emission. Acoustic Emission are transient elastic waves produced by the rapid release of energy from a local source inside the material. Small frequency ranges can be successfully detected by acoustic emission measurement. It is a wise choice to use acoustic emission measurement for the detection of a fault type that affects particularly small frequency ranges.

In this thesis, a method based on signal processing, deep learning and machine learning is proposed for the detection of grinding burn in bearing parts. The proposed method begins with the use of acoustic emission sensors to collect signals during the grinding process of bearing parts under real-world production conditions. The acoustic emission data used in this study came from experiments carried out in the Ortadou Rulman Sanayi Research and Development laboratories. Experiments on outer ring grinding and roller grinding were carried out. By varying 10 different parameters of the grinding machine, 101 different measurements were obtained. During the experiments, measurements were taken from the grinding of 41 roller and 60 outer ring specimens. Of these measurements, 18 were of defective specimens and 83 were of normal specimens. The machine parameters were recorded for each measurement. During the measurements, the machining characteristics of the machine are changed according to the production scenario. Measurements were taken by changing 10 different features of the machine such as cutting speed, cutting pressure, sharpening frequency. Signals were obtained using a 4MHz sampling frequency. The bearing parts to which the collected signals belong to are recorded.

These bearing parts were then analyzed by some metallurgical methods and separated into those with grinding burns and those without grinding burns. Thus, it was determined which of the acoustic emission signals belonged to the sample with grinding burns and which belonged to the sample without grinding burns. Acoustic emission is a non-invasive monitoring technique that detects high-frequency stress waves produced by machining materials. These signals contain information about the material being machined and can be used to detect changes in its properties.

The next step in the proposed method is signal preprocessing. In this step, the signals are first divided into smaller sub-signals, where the faulty signals are divided into smaller sub-signals, and then the faulty and non-faulty signals are combined into a single data file and labeled with class names. These signals are then classified using machine learning methods specialized for signal classification and the long-term short-term memory method developed in this thesis.

Then, after some preprocessing steps, these signals were converted into images either as signals or with time-frequency representation methods and classified into 2 classes as faulty-normal. The images are then classified using deep learning techniques. For signal classification, the thesis employs a variety of algorithms, including Long Short-Term Memory (LSTM), Support Vector Machines (SVM), and K-Nearest Neighbor (KNN). According to the results obtained from these methods, 93% accuracy rate was achieved. For image classification, the thesis employs a variety of algorithms, including transfer learning networks such as Googlenet, Resnet-50, Squeezenet, and Alexnet. Additionally, a new CNN network is suggested in this thesis to categorize time-frequency pictures of signals obtained from bearing samples. In image classification applications, 100% accuracy was achieved. This is a good result both compared to comparable studies in the literature and to tests in production processes.

In some applications, there is either insufficient training data or additional training instances are not feasible. In these cases, pre-trained networks can be used. In order to achieve successful results in deep learning studies, a good data set is needed. For this reason, institutions that pioneer deep learning studies are conducting some studies to create data sets that can be used in these studies. In deep learning studies, one of the measures of the reliability of the method studied is the reliability of the data set. In this respect, training and testing one's own network using a data set widely used in the literature is a necessary step for the success of the related method. Transfer learning methods are preferred by researchers in terms of meeting this need.

Transfer learning is the use of previously trained neural networks. Googlenet, Resnet-50, Squeezenet, and Alexnet deep CNNs were pretrained for image recognition and then used to classify grinding burn signals using a time-frequency representation in this study. These networks perform a new task by utilizing transfer learning. The most common method for implementing transfer learning is to use pre-trained networks on the ImageNet data set.

In addition, in this thesis, a new CNN network is proposed to classify time-frequency images of signals obtained from bearing samples. The number of layers (depth of the network) and the width of each layer of the CNN network are considerably less than the transfer learning networks used in the thesis, which reduces the computational load of the network. Despite this, it has been shown that the accuracy values

achieved in transfer learning networks are also achieved in the designed CNN network. Achieving similar results with lower processing capacity is the prominent aspect of this network.

All these algorithms are trained using a labeled dataset of images with and without grinding burns, allowing them to learn the features that distinguish between the two categories.

Time-frequency images obtained from the signals were classified with high accuracy using different transfer learning networks (Googlenet, Resnet-50, Squeezenet and Alexnet) and a newly designed convolutional neural network. In most of the methods, 100% classification success was achieved.

Overall, the thesis's proposed method provides a non-destructive, low-cost, and real-time approach to detecting grinding burns in bearing parts. The method can provide highly accurate results by combining signal processing, deep learning, and machine learning techniques, reducing manufacturing time and cost while ensuring high-quality bearings that are reliable and long-lasting.

The main contribution of this thesis to the literature is the detection of grinding burns in bearing parts using artificial intelligence and signal processing methods with data obtained from real production conditions.

Keywords: Grinding Burn Detection in Bearings, Deep Learning, Machine Learning, Signal Processing

BÖLÜM 1. GİRİŞ

Taşılama, yüksek hızlarda çalışan, aşındırıcı bir taşılama diski ile iş parçasının yüzeyinden talaş kaldırma işlemidir. İş parçasının, yüzey kalitesini ve ölçülendirme doğruluğunu artırmak için metal endüstrisinde taşılama işlemi yapılmaktadır [1]. İnce toleranslar ve pürüzsüz yüzeyler gerektiren bileşenlerin imalatında yaygın olarak kullanılan, yüksek ve özel enerjili bir işleme prosesidir. Taşılama işleminde harcanan yaklaşık bütün enerji ısıya dönüştürülür ve taşılama bölgesi içinde konsantre edilir. Böylece çalışma yüzeyinde yüksek sıcaklığa yol açar. Bu yüksek sıcaklık, çekme gerilmesi, yüzey yanıkları gibi iş parçası ile ilgili sorunlara neden olabilir ve sonuç olarak iş parçasının kullanım ömrünü kısaltabilir [2].

Taşılama yanığı, taşılama işlemi sırasında işlenen yüzey ile aşındırıcı diskin temas alanında aşırı ısınma olarak tanımlanır ve oksidasyon yanması (Taşılama sırasında çalışma parçası yüzeyinde sıcaklığın artışına bağlı olarak işleme yüzeyinde oluşan oksitlenmedir.), termal yumuşama, artık gerilmeler ve yeniden sertleşme yanığı gibi çeşitli yüzey kusurlarına neden olur [3]. Demir bileşenli malzemelerde Fe_2O_3 , Fe_3O_4 , FeO 'ten oluşan oksit tabakaları şeklindedir [4]. Taşılama işlemi sırasında, yüzey kalitesini artıran tezgâh parametreleri, taşılama yanığı oluşma riskini de artırır. Bu bakımdan taşılama yanığı(TY), taşılama işleminde, yüksek verimlilik ve kalite açısından ana kısıtlardan biri olan yaygın bir termal hasar olgusudur [5]. Bu nedenle taşılama tezgâhının parametre ayarları yanık oluşmayacak sınırlara kadar iyileştirilebilir.


Taşılama kalitesini dolayısıyla taşılama yanığı oluşumunu etkileyen sebepler şu şekilde sıralanabilir:

- Aşındırıcı: Kaba tane kullanıldıkça yüzey pürüzlüğü artar. Alüminyum oksit, seramik oksit ve zirkonya alümina yakın derecelerde yüzey pürüzlüğü oluştururlar. Silikon karbür ile işlenen iş parçaları nispeten daha hassas bir yüzey elde edilmesini sağlar

- İşlenecek malzeme: Malzemenin yumuşaklığı arttıkça aynı tane büyüklüğü ile daha kaba yüzeyler elde edilir. Yağ veya yağlayıcı madde ekleyerek nispeten daha hassas bir yüzey elde edilir.
- Uygulama parametreleri: Kesim hızının artırılması veya besleme hızının azaltılması ile yüzey kalitesi iyileştirilmiş olur. Temas baskısının yüzey pürüzlüğü üzerinde çok az etkisi vardır[6].

Taşlama işlemi, işleme sürecinin son adımıdır ve toplam işleme maliyetinin yaklaşık %20-%25'ini oluşturur [7]. Bu nedenle bu aşamada oluşan bir hata, bundan önce oluşabilecek hatalardan daha fazla maliyet ve zaman kaybına yol açmaktadır. Bütün bunlar göz önüne alındığında, taşlama yanığının tespitinin önemi ortaya çıkmaktadır.

Taşlama yanığı, "ISO 15243:2004: Rulmanlar-Hasar ve Arızalar-Terimler, Özellikler ve Nedenler" standardında çatlak ve kırılma arızalarının nedenlerinden biri olarak gösterilmiştir. ISO 15243:2004 standardında, kırıklar ve çatlaklar, rulman arızasının ana modlarından biri olarak tanımlanmaktadır [8]. Şekil 1.1'de taşlama yanığının neden olduğu dış bilezikteki bir kırılma hatası şematize edilmiştir.



Şekil 1.1 : Taşlama yanığının neden olduğu rulman hata modlarından kırılma hatasının gösterimi


Makine durumunun izlenmesi, arıza tespit ve teşhisi bakım sistemindeki kilit unsurlardır. Bunlar günümüzde küresel ilgi görmektedir ve bakım maliyetlerini azaltma, yüksek verimlilik ve daha uzun süreli makine kullanılabilirliği konularında faydalı bulunmaktadır.

Rulmanlar dönen makinaların kritik parçalarından biridir. Rulmanlarda oluşan bir hata, makinenin diğer parçalarının işlemlerini etkilemekte, bütün makinenin bozulmasına sebep olmakta böylece maddi hasara ve zaman kaybına yol açmaktadır[9,10]. Örneğin indüksiyon makinalarında oluşan hataların %44'ü rulman hatalarından

kaynaklanmaktadır [11]. Dolayısıyla dönen makinaların güvenliğini ve güvenilirliğini artırmak için rulman hatalarına odaklanmak gerekir.

Rulmanların en önemli mekanik özelliklerinden biri yüzey pürüzsüzlüğüdür. Bu nedenle rulman üretiminde en önemli işlemlerden biri taşlamadır. Rulman parçalarının taşlaması sırasında, tezgâh istenen standartlara uygun parametrelerde ayarlanır ve belli sayılarda işlemten sonra tezgâh durdurularak taşlama yanığı kontrolü için numuneler alınır. Bu numuneler metalürjik yöntemler ve Magnetic Barkhausen Noise(MBN) gibi hata tespit yöntemleriyle incelenir [3]. Eğer numunelerde taşlama yanığı tespit edilirse, aynı tezgâh parametreleriyle işlenen bütün parçalar hurdaya ayrılır veya uzman çalışanlarca incelenmek üzere ikinci bir kontrol aşamasına alınır. Bu da üretim sürecinde zaman kaybına neden olur. Bu nedenle rulmanın kullanım ömrünü uzatmak, rulman üretim süreçlerinin kısa ve uygun maliyetli olmasını sağlamak ve kalite gerekliliklerini karşılamak için rulmanlarda taşlama yanığının tespit edilmesi gerekmektedir. Taşlama yanıklarını tespit etmek için metalürjik yöntemler ve Barkhausen gibi doğrudan yöntemler, işlenmiş malzemenin yüzey özelliklerine odaklanır. X-ışını kırınım ölçerler, taramalı elektron mikroskopları gibi ekipmanlar, işlenmiş yüzeylerde termal hasarın varlığını doğrudan incelemek için kullanılır [12]. Akustik emisyon (AE) tekniği, sinyal işleme ve yapay zekâ tabanlı yöntemler gibi dolaylı yöntemler de ise titreşim, ses, akustik emisyon, motor akımları gibi yüzey kusurlarının dolaylı etkilerine bakılarak hata tespit edilir [13]. Taşlama yanığının izlenmesi ve tespiti için; titreşim, elektrik, kuvvet, piezo membranlar, Barkhausen ve girdap akımları gibi farklı izleme fenomenlerinin örnekleri [14]'da gösterilmiştir. Akustik emisyon tekniği de, makine durumunun izlenmesi ve arıza teşhisinde kullanılan önemli yöntemlerden biridir. AE sinyallerini, frekans alanında ve zaman alanında analiz etmek için başka birçok analiz tekniği de kullanılabilir [15]. Akustik emisyon tekniği taşlama yanığı hata tespit yöntemi olarak kullanılmaktadır [16]. AE tekniği tahribatsız muayenenin çeşitli alanlarında çok faydalı bir araç olarak kabul edilir [17,18]. AE, malzemenin içinde lokalize bir kaynaktan hızlı enerji salınımı ile üretilen geçici elastik dalgaların üretilmesi anlamına gelir [19]. AE, bir malzeme, içyapısında deformasyona ve kırılmaya uğradığında oluşan elastik bir gerilim dalgasıdır [20]. AE sinyalleri takım ve malzeme arasındaki herhangi küçük bir etkileşim davranışından salınabilir [21]. AE'nin frekans aralığı, çevresel frekanslardan çok daha yüksektir [22]. Taşlama

sürecinin izlenmesi için AE sensörünün önemi [23]'te gösterilmiştir. Ayrıca taşlama işlemleri sırasında üretilen AE sinyalinin, iş parçasının yüzey durumu ile ilişkili olduğu [24]'te doğrulanmıştır. [20]'de AE tekniğinin; taşlama diski aşınması, talaşlı imalat yanıklarının, çatlakların tespiti vb. uygulamalarda kullanım örnekleri verilmiştir. Aguiar ve ark., çelik malzemedeki taşlama yanıklarını tespit etmeye çalışmıştır [25]. Çeşitli çalışmalar, dolaylı yöntemlerin, termal hasarları daha yüksek bir doğrulukla tespit edebildiğini göstermiştir [4, 26, 27]. Dolaylı yöntemler, termal hasar oluşumu sırasında titreşim, akustik emisyon (AE) ve gürültü gibi çeşitli fiziksel olayların meydana geldiği gerçeğine dayanmaktadır. Buna göre akustik emisyon sensörleriyle alınan sinyaller [28] veya sinyal görüntüleri [16], sinyal işleme ve/veya yapay zekâ (makine öğrenmesi, derin öğrenme) yöntemleriyle işlenir. Böylece hatalı ve hatasız rulman verileri farklı sınıflara ayrılarak hata tespit edilmektedir. Sensör tabanlı çalışmalar, tahribatsız tespit sağlamaları, sinyal ve görüntü işleme yöntemlerine olanak tanımları yönüyle öne çıkmaktadır. Şekil 1.2'de bir taşlama makinasında yapılan bir taşlama işlemi sırasında AE sensörü ile veri toplanması işlemi gösterilmektedir. Doğrudan yöntemler, dolaylı yöntemlerden daha kesindir ancak kullanılan ekipmanın maliyeti daha yüksektir. Ayrıca çoğu işleme süreci bir soğutma sıvısı varlığında gerçekleştirildiğinden, gerçek zamanlı izlemede doğrudan yöntemlerin uygulanması daha zordur [29].



Şekil 1.2 : Taşlama makinasında yapılan bir taşlama işlemi sırasında AE sensörü ile veri toplanması

Rulmanlarda hata analizi çalışmalarında en çok kullanılan veriler titreşim ve akustik emisyon verileridir [30]. Bu veriler sıralı verilerdir. Nitekim literatürde derin öğrenme

tabanlı rulman hata analizi çalışmalarında sıralı veri işleme tabanlı yinelemeli sinir ağları kullanılabilmektedir [31].

Ayrıca makinelerin, süreçlerin ve fenomenlerin dijital ikizlerinin üretildiği uygulamalar da mevcuttur. Bu alandaki gelişmeler, taşlama işleminin iyileştirilmesine de yardımcı olacağı öngörülmektedir [32].

Yapay zekanın ilk aşamalarında, insanlar için çözülmesi zor olan ancak biçimsel veya matematiksel kurallarla nispeten kolay tanımlanabilen problemler bilgisayarlar tarafından hızla çözülmüştür. Ancak, asıl zorluğun insanlar için kolay olan ancak günlük hayatta sürekli karşılaştığımız yüz tanıma veya konuşma tanıma gibi resmi veya matematiksel olarak tanımlanması zor olan problemlerin çözümünde yattığı anlaşılmıştır [33].

Derin öğrenme, nispeten sezgisel problemleri çözmek için önerilen bir yapay zeka yaklaşımıdır. Bu yaklaşım, bilgisayarların her bir kavramı daha temel kavramlarla ilişkilendirerek bir kavramlar hiyerarşisi öğrenmesini sağlar. Böylece, biçimsel kuralların insanlar tarafından manuel olarak girilmesine gerek kalmaz. Kavramlar hiyerarşisi, bilgisayarın daha basit kavramlara dayanarak karmaşık kavramlar oluşturmaya olanak tanır. Bu kavramların birbiri üzerine nasıl inşa edildiğini gösteren bir grafik oluşturursak, bu grafik çok katmanlı veya başka bir deyişle derin bir grafik haline gelir. Dolayısıyla bu yaklaşıma derin öğrenme adı verilmektedir [33].

Yapay zeka, makine öğrenimi ve derin öğrenme birbiriyle bağlantılı kavramlardır. Yapay zeka araştırmalarının önemli bir kısmı, bilinen yöntemler kullanılarak matematiksel olarak modellenmesi zor olan gerçek dünya problemlerini keşfetmeye odaklanmaktadır. Otomatik mantıksal çıkarım kurallarına benzeyerek çözümler geliştiren bilgisayar programları, bilgi tabanlı yapay zeka yöntemlerini kullanmaktadır. Bilgiye dayalı yapay zeka yöntemlerini kullanarak ham verilerden örüntüler çıkarma becerisi makine öğrenimi olarak adlandırılır [33]. Basit makine öğrenimi yöntemlerine örnek olarak mantıksal regresyon ve temel Naive Bayes (NB) verilebilir. Bu algoritmaların performansı büyük ölçüde verilen bilginin temsiline dayanır. Yapay zekanın göreve özel uygulamalarında, problem çözme için doğru şekilde türetilmiş bir özellik kümesi kullanılır. Örneğin, ses perdesine dayalı olarak bir konuşmacının erkek mi yoksa kadın mı olduğunun belirlenmesinde, ses aralığının temsili karar vermede

önemli bir özellik olarak kullanılabilir. Ancak, birçok görevde ayırt edici özelliğin belirlenmesi o kadar kolay değildir. Örneğin, bir görüntüden araba tanımlama probleminde, tekerleği bir özellik olarak temsil etmek zordur, çünkü arabanın görüntüdeki açısı, aydınlatma koşulları ve diğer faktörler, basit geometrisine rağmen tekerleğin piksel değerlerini etkiler. Bu tür sorunların makine öğrenimi ile çözülmesinde, özelliğin temsil edilmesinin yanı sıra katmanlardaki girdi temsili ile çıktı arasında bir eşleme kurulması gerekmektedir. Bu makine öğrenmesi yaklaşımı temsil öğrenmesi olarak adlandırılır [34].

Özellik çıkarma algoritmaları, gözlemlenen veriyi etkileyen değişkenleri ayırmayı amaçlar. Ayırt edici faktörler olarak kabul edilen bu değişkenler, toplanan verilerin tanımlanmasında önemli bir rol oynar. Örneğin, bir araba görüntüsünden güneş ışığının konumu, rengi veya parlaklığı gibi değişkenler özellik olarak çıkarılabilir. Ancak gerçek dünya problemlerinde, yapay zeka uygulamalarında çıkarılan özellikler, her bir değişken bileşenin toplanan veri üzerindeki etkisi nedeniyle genellikle istenen sonucu elde etmekte yetersiz kalmaktadır. Örneğin, kırmızı bir araba akşam saatlerinde siyaha çok yakın bir piksel değerine sahip olabilir veya aracın görünümü resmin çekildiği açıya bağlı olarak değişebilir. Birçok uygulamada, çıkarılan özelliklerin özellik çıkarımına tabi tutulan verilerdeki açısal değişkenlerden etkilenmemesi çok önemlidir. Bir başka örnek de, ham verideki konuşmacının aksanından kaynaklanan değişikliklerden etkilenmemesi gereken, aktarılacak içeriğin çıkarılmasıdır. Değişkenlerden etkilenen ham verilerden özellik çıkarmak, temsil öğrenmede özellikle zordur.

Derin öğrenme, özelliklerin temsili en basitleştirilmiş katmanlı biçimde çıktıya taşıyarak ham verideki performans düşüşünü hafifletir ve anlamsız değişkenlerin etkisini en aza indirir.

Temsili öğrenme yöntemleri yeni uygulama alanlarına daha hızlı adaptasyon sağlamanın yanı sıra klasik makine öğrenme yöntemlerine kıyasla daha iyi sonuçlar vermektedir. Bir temsil öğrenme algoritması, basit işlemlerin özellik kümesini dakikalar içinde ve karmaşık veri kümelerinin özelliklerini birkaç saat içinde çıkarabilir ve aksi takdirde bir araştırma grubu tarafından harcanacak zahmetli ve yorucu çabalardan tasarruf sağlar. En temel temsil öğrenme algoritması, giriş verisini farklı bir temsile dönüştüren bir kodlayıcı ve orijinal verinin temsilden yeniden oluşturulmasını sağlayan

bir kod çözücünden oluşan otomatik kodlayıcıdır (Auto Encoder). Otomatik kodlayıcı mimarilerinde, öğrenme süreci tamamlanana kadar kodlayıcı ve kod çözücü fonksiyonları birlikte kullanılır. Bu algoritma, giriş verisindeki gizli özellikleri temsil eden yeni bir özellik kümesi çıkarır[33, 34]. Özellik çıkarma algoritmaları, gözlemlenen veriyi etkileyen değişkenleri ayırmayı amaçlar. Ayırt edici faktörler olarak kabul edilen bu değişkenler, toplanan verilerin tanımlanmasında önemli bir rol oynar. Örneğin, bir araba görüntüsünden güneş ışığının konumu, rengi veya parlaklığı gibi değişkenler özellik olarak çıkarılabilir. Ancak gerçek dünya problemlerinde, yapay zeka uygulamalarında çıkarılan özellikler, her bir değişken bileşenin toplanan veri üzerindeki etkisi nedeniyle genellikle istenen sonucu elde etmekte yetersiz kalmaktadır.




Şekil 1.3 : Derin öğrenme modeli örneği ve basit temsili.

Şekil 1.3'te, derin öğrenme kullanılarak bir görüntüde nesne tanıma için kullanılacak basit temsiller gösterilmektedir. Bu gösterimler arasında kenarların varlığı ya da yokluğu, köşelerin ve eğrilerin varlığı ya da yokluğu ve nesne parçalarının varlığı yer

almaktadır [33]. Piksel kümeleri olarak düşünülebilecek görüntülerden bir eşleme fonksiyonu aracılığıyla nesneleri tanımlamak oldukça zordur. Bu nedenle derin öğrenme modelleri, tanımlı katmanları ve basit eşlemeleri ile bu zorluğu en aza indirir. Giriş katmanı, ham veriyi doğrudan aldığı için görünür katman olarak adlandırılır. Farklı özellikleri çıkaran birden fazla gizli katman vardır. Her gizli katman başka bir özellik kümesini temsil eder [34].

Temel derin öğrenme modeli Çok katmanlı algılayıcıdır (Multi Layer Perceptron). Çok katmanlı algılayıcılarda girdi ve çıktı arasındaki ilişkiyi haritalayan matematiksel bir fonksiyon vardır. Girdinin temsili farklı bir matematiksel fonksiyon olarak tasarlanırsa, çok katmanlı algılayıcılar temel bir derin öğrenme modeli olarak düşünülebilir. Derin öğrenmedeki bir diğer fikir ise bilgisayarlara çok adımlı bilgisayar programları öğretme yaklaşımıdır. Çalıştırılacak her komut kümesi bir katman olarak düşünüldüğünde, her komut kümesi bir temsile karşılık gelmektedir. Böylece girdiye ilişkin tüm bilgilerin tek bir katmanda temsil edilmesi yerine, girdiyi tanımlayan değişkenleri etkileyen faktörler kodlanmış olur. Bu da girdiye ilişkin bilgilerin her bir katmana özgü bilgilerde depolandığı bir temsil sağlar. Derin öğrenme, girdiye özgü içerik yerine işlenmiş ve organize edilmiş bir modelin elde edilmesini sağlar [33, 34].

Özetle, derin öğrenme, yapay zekanın bir alt alanı olan ve bilgisayarlara deneyim ve verilere dayalı olarak performanslarını ve bilgilerini geliştirme yeteneği kazandıran bir makine öğrenimi türüdür. Şekil 1.4, derin öğrenmenin yapay zeka içindeki konumunu bir Venn diyagramında göstermektedir.



Şekil 1.4 : Derin öğrenmenin yapay zekâ içerisindeki yeri.

Şekil 1.5 çeşitli yapay zeka teknikleri aracılığıyla çıktı elde etme adımlarını sunmaktadır[33]. Derin öğrenmeye dayalı yaygın olarak kullanılan üç derin sinir ağı yapısı vardır. Bunlar konvolüsyonel sinir ağları, derin inanç ağları ve yığılmış oto kodlayıcılardır.



Şekil 1.5 : Farklı Yapay Zekâ sistemlerinin birbiriyle ilişkilerini gösteren akış şeması

Günümüzde farklı işleri yapmak üzere özelleşmiş farklı derin öğrenme algoritmaları bulunmaktadır. Bu yöntemlerden bazıları; görüntü gibi iki veya daha fazla boyutlu veriler için evrişimsel sinir ağı(CNN) modelleri ve zaman serileri tabanlı veriler için sıralı modeller olarak sayılabilir. Sıralı modeller de temelde yinelemeli (Recurrent NN) ve özyinelemeli (Recursive NN) modeller olarak ayrılmaktadır.

Evrişimsel sinir ağları görüntü gibi mekanla ilişkisi olan verileri işlemek için kullanılır. Yinelemeli sinir ağları(RNN) da sıralı verileri işlemek için özelleştirilmiş sinir ağları ailesidir [35]. Yinelemeli sinir ağları (RNN) $x^{(1)}, \dots, x^{(T)}$ gibi sıra oluşturan verileri işlemek için kullanılmaktadır.

Yapay Sinir Ağları (YSA)'nın en basit formu, ileriye dönük bir sinir ağıdır(Feedforward Neural Network-FNN) ve veri giriş düğümlerinden, bir veya daha fazla gizli düğüm katmanını boyunca akar ve ardından düğümleri bir yönde çıkarır. Tekrarlayan bağlantılara sahip FNN, yinelemeli sinir ağı (RNN) olarak adlandırılır [33]. Yinelemeli sinir ağlarının (RNN) özel bir formu olan Uzun ömürlü-kısa dönem bellek (Long Short-Term Memory) ağları sıralı verilerin sınıflandırılmasında çoklukla kullanılmaktadır.

Rulmanlarda hata analizi çalışmalarında en çok kullanılan veriler titreşim ve akustik emisyon verileridir [30]. Bu veriler sıralı verilerdir. Bu nedenle bu tez kapsamında yinelemeli bir sinir ağı (RNN) modeli olan Uzun ömürlü-kısa dönem bellek (Long Short-Term Memory) modellerini içeren uygulamalar da yapılmıştır. Nitekim literatürde derin öğrenme tabanlı rulman hata analizi çalışmalarında sıralı veri işleme tabanlı yinelemeli sinir ağları sıklıkla kullanılmaktadır.

CNN büyük genişliğe ve yüksekliğe sahip görüntülere ölçeklenebilir ya da değişken boyuttaki görüntüleri işleyebilir. Bunun gibi Yinelemeli sinir ağları da sıra tabanlı veriler için olmayan ağların-CNN gibi- işleyebileceğinden daha büyük sıralı dizilere ölçeklenebilir ve bu dizileri işleyebilir [33].

Evrişimsel Sinir Ağı (CNN), üç çeşit katmandan oluşan ileri beslemeli bir sinir ağıdır. Bu katmanlar: Evrişim Katmanı (CL), Pooling (Havuzlama-Ortaklama) Katmanı (PL) ve Tam Bağlı Katman. Tam Bağlı Katman, geleneksel ileri beslemeli sinir ağı ile aynı yapıya ve çalışma şekline sahiptir. CNN'nin avantajları, CL'lerin ve PL'lerin yapıları ve operasyonlarındaki farklılıklardan ileri gelir. 2 boyutlu verilerin işlenmesi için CNN oldukça işlevseldir.


Derin öğrenme modelleri büyük miktarda etiketlenmiş veriye ihtiyaç duyar. Büyük miktarda etiketli veri toplamak maliyetli ve zaman alıcıdır. Bu dezavantajdan dolayı araştırmacılar önceden eğitilmiş derin öğrenme modellerini tercih etmektedirler. Önceden eğitilmiş modeldeki mevcut özellikler, yeni bir problemde kullanılmak üzere transfer öğrenme (Transfer Learning-TL) modellerine aktarılır. Böylece, hem TL modelinin büyük miktarda verilerle elde edilmiş üstün özellik seti kullanılır hem de ağı eğitimi süreci kısalmıştır. Ayrıca yüksek maliyetli donanım ihtiyaçlarına da gereksinim duyulmaz.

Öğrenme aktarması, yeni bir probleme çözüm bulmak için büyük veri kümeleriyle önceden eğitilmiş derin öğrenme ağlarını kullanma yöntemidir. Eğitim verilerinin yetersiz olduğu durumlarda, önceden eğitilmiş bir ağı kullanılması oldukça yaygın bir yaklaşımdır. Böylece, ağı eğitimi için gereken büyük veri seti ihtiyacı ortadan kalkar ve işlem maliyetleri düşer. Bu ağların eğitiminde kullanılan veri setinin büyüklüğü ve çeşitliliği sayesinde, bu ağlar yeni problemlere kolaylıkla adapte olabilir. Çalışmada kullanılan öğrenme aktarması için AlexNet, GoogleNet, ResNet-50 ve SqueezeNet ağları kullanılmıştır.

Yapay zeka teknikleri ile rulmanlarda hata tespit işlemi genel olarak şu dört adımdan oluşur: veri toplama, özellik çıkarımı, özellik seçimi ve sınıflandırma. Taşlama yanığını izlemek için, titreşim, elektrik akımı, kuvvet, piezoelektrik diyaframlar, endüksiyon akımı [14] ve akustik emisyon [16] sinyalleri kullanılır. İkinci adımda bu sinyallerden özellik çıkarımı yapılır. Yüksek doğruluklu bir sınıflandırma için öznelik çıkarıcı tasarımı çok önemlidir [36]. Sinyallerin özellikleri zaman alanından [37], frekans alanından [38] ve zaman-frekans alanından çıkarılabilir [39, 40]. Zaman-frekans özelliklerinin çıkarılabilmesi için sinyallerin zaman alanından zaman frekans alanına dönüştürülmesi gerekir. Bu dönüşüm için yaygın kullanılan yöntemler, continuous wavelet transform (CWT), Hilbert-Huang transform (HHT) [16], wavelet packet transform (WPT) [41], complex wavelet transform[42], short-term fourier transform (STFT) [43] gibi sinyal işleme yöntemleridir.

1.1. Literatür Taraması

Rulman hata literatüründe; (a) işleme koşullarının izlenmesi ve (b) hata tespit ve teşhis çalışmaları olmak üzere iki konu öne çıkmaktadır [44]. Hata tespit ve teşhis çalışmaları da temelde iki başlıkta incelenmiştir. Hata öncesi yöntemlerde, taşıma kuvvetlerinin ölçümü veya taşlanan yüzeylerin sıcaklık ölçümü yapılarak hatayı önlemek amaçlanmaktadır. Hata oluşuktan sonraki tespit yöntemleri ise direkt tespit yöntemleri ve dolaylı tespit yöntemleri olarak iki başlığa ayrılır. Manyetik Barkhausen Noise gibi direkt tespit yöntemleri, işlenen malzemenin metalürjik, mekanik ve yüzey özelliklerine odaklanır ve X-Ray kırınım ölçerler veya elektron mikroskobu gibi ölçü aletleriyle hatayı doğrudan tespit etmeye çalışır. Dolaylı yöntemler ise, titreşim, akustik emisyon, elektrik akımı gibi olgulara bakarak hatanın bu dolaylı etkilerini belirlemeye çalışır. Buna göre bu çalışmada önerilen tespit yöntemi hata ortaya çıktıktan sonra hatanın tespit edilmesini amaçlayan, dolaylı tespit yöntemleri içerisinde bulunmaktadır. Rulmanlardaki taşıma yanığı çeşitli yöntem ve ekipmanlar kullanılarak tespit edilir. Şekil 1.6'da mevcut literatürdeki rulman arıza tespit çalışmalarının sınıflandırılması gösterilmektedir.



Şekil 1.6 : Rulman hata literatürünün sınıflandırılması

Son yıllarda yapay zekâ alanındaki gelişmeler rulmanlarda hata tespit çalışmalarını da etkilemiş ve artan ivmede yapay zekâ temelli çalışmalarla rulman hatalarının tespit edildiği belirtilmiştir [45]. Günümüzde makine durum izlemesinde kullanılan Yapay

Zekâ (YZ) yöntemlerinden bazıları Genetik Algoritmalar (GA), Support Vector Machine (SVM), Bulanık Mantık (BM) ve Yapay Sinir Ağları (YSA) dır [46]. Neto ve ark., taşlama yanıklarını izlemek için akustik emisyon ve titreşim sinyalleri kullandılar. Veri toplamadan sonra, taşlama yanmasıyla daha güçlü ilişkili olan frekans bantlarını seçtiler ve YSA girdisi olarak kullandılar. Veriler yanma yok, yanma var ve yüksek yüzey pürüzlülüğü olmak üzere üç sınıfa ayrıldı. Sonuç olarak % 98,3 doğruluk elde edildiği belirtilmiştir [47]. Saravanapriyan ve ark., taşlama yanığının tespitinde yaygın kullanılan sensörleri (kuvvet, akustik, titreşim ve sıcaklık) farklı konumlarda yerleştirmenin yol açtığı sorunları engellemek için kompakt bir sensör ünitesinde bir araya getirdi. Bu sensörlerden topladığı verileri bir YSA modeliyle sınıflandırarak çevrimiçi olarak taşlama yanığının izlenebilirliğini gösterdi [48]. Wang vd., 52100 rulman çeliğinin taşlanması sırasında AE sensörleriyle topladığı verileri yapay bir sinir ağı (YSA) eğitmek için kullandı. Bu eğitilmiş YSA ile AE sinyallerini yanma var/yanma yok olarak sınıflandırdı [49]. Reser ve Reich, 21 numuneden topladıkları veri setini YSA temelli bir ağı eğitmede kullanarak dört sınıflı bir sınıflandırma uygulaması yapmışlardır. Az sayıda veri olmasına rağmen ağın başarılı sonuçlar elde ettiği belirtilmiştir [50]. Yang ve Yu taşlama yanıklarının otomatik olarak tespit edilmesi için destek vektör makinesine dayalı bir sınıflandırma ve tahmin sistemi oluşturmuştur [51]. Hinch ve Tkouat, çalışmalarında, evrimsel ve uzun ömürlü kısa dönem bellek (LSTM) kullanarak rulmanlarda faydalı kullanım ömür (RUL) tahmini yapmayı amaçlamışlardır [52]. Sanjay ve Bhirudb sıralı modeller temelli bir sinir ağı kullanarak rulman bilgileri tabanlı bir yöntemle dönen makinelerin çalışma durumunu izlemeye çalışmıştır [53]. Lei ve ark. rüzgar türbinlerinde hata teşhisi için uzun ömürlü kısa dönem bellek (LSTM) tabanlı bir ağ kullanmışlardır [54]. Liang ve ark. rulmanların faydalı kullanım ömür (RUL) tahmininde kullanılabilecek bir sağlık belirteci ortaya koymak için yinelemeli sinir ağı (RNN) tabanlı bir yöntem kullanmıştır [55]. Yang ve ark. LSTM ağları ile dönen makinalarda hata teşhis çalışmaları yapmıştır [56]. Zhao ve ark. RNN tabanlı ağlarla rulmanlarda faydalı kullanım ömür tahminine dönük uygulamalar yapmıştır [57]. Li ve ark. hata durumu değerlendirmesi(fault degradation) yaptıkları çalışmalarında LSTM ağları kullanmışlardır [58]. Hübner ve ark., taşlama yanıklarının gerçek zamanlı olarak tespit etmek için Convolutional Neural Network (CNN) kullanan bir yaklaşım sunmuştur. Çalışmada ki AE verileri, farklı kesme

koşulları altında N2711 kalite çelik malzemenin taşlanması sırasında toplanmıştır. AE sinyallerinin zaman-frekans görüntülerini oluşturmak için Sort Time Fourier Transform (STFT), Cross Wavelet Transform (CWT) ve Hilbert-Huang Transform (HHT)'u içeren üç farklı zaman-frekans analizi kullanılmıştır. Önerilen yöntemin performansı, YSA'lar ve SVM'leri içeren geleneksel makine öğrenimi yöntemleriyle karşılaştırılmıştır. Ayrıca sonuçlar, mevcut literatürde öne çıkan sonuçlarla da karşılaştırılmış ve önerilen yöntemin taşlama yanıklarının tespitinde ulaşılabilecek en iyi (state of the art) doğruluğa ulaştığı gösterilmiştir [16]. Kaufman ve ark., YZ tabanlı taşlama izlemesine ilişkin uygulama örneklerini değerlendirerek bu konuda genel bir çerçeve sunmuştur [59]. Wen ve ark. üç farklı veri setini transfer CNN (TCNN) ve ResNet-50 olarak adlandırılan yeni bir ağda sınıflandırdı ve sınıflandırma performanslarını karşılaştırmıştır [60]. [61]'de, rulman titreşim sinyalleri sürekli dalgacık dönüşümü (CWT) kullanılarak zaman-frekans görüntülerine dönüştürülmüştür. Görüntüler daha sonra içsel kusur özelliklerini çıkarmak için CNN kullanılarak işlendi ve bunları bir gcForest sınıflandırıcısına beslenmiştir. Önerilen yöntemin performansını değerlendirmek için Case Western Reserve Üniversitesi (CWRU) ve Xi'an Jiaotong Üniversitesi'nden (XJTU-SY) elde edilen deneysel rulman verileri kullanmıştır. Yazarlar, önerilen hibrit derin öğrenme modelinin algılama doğruluğu açısından CNN ve gcForest'tan daha iyi performans gösterdiğini ve pratik uygulamalarda faydalı olabileceğini öne sürdüler. Dong ve ark. gerçek sistemlerden yeterli verinin alınamadığı durumlar için bir yöntem geliştirdi. Önerilen yaklaşımda, oluşturulan büyük ve çeşitli simülasyon verileri ve ardından simülasyon verilerinden elde edilen tanı bilgisi, CNN ve parametre transfer prosedürleri kullanılarak gerçek dünya senaryosuna uygulanır. Üç arıza teşhisi vakası temelinde, önerilen yöntemin kullanılabilirliği gözden geçirilmiştir. Sonuçlar, önerilen yöntemin CNN'de simülasyon verilerine ve parametre transfer prosedürlerine dayalı olarak daha fazla aktarılabilir özellik öğrenebileceğini göstermektedir [62]. Grover ve Turk, bilyalı rulman elemanlarının titreşim sinyallerinden oluşturulan iki spektrumlu görüntülerin ince ayarını yapmak için önceden eğitilmiş dört ağ (Alexnet, VGG-19, Goog-LeNet ve ResNet-50) kullandı. Her ağ üç optimize edici kullanılarak eğitildi: Stokastik gradyan inişi (SGD), uyarlanabilir moment tahmini (Adam) ve Adamax [63]. Özcan ve ark. çok kanallı 1D-CNN ağı kullanarak, farklı hata büyüklükleri içeren titreşim verilerini başarıyla sınıflandırmıştır

[64]. Wang ve ark. Titreşim ve akustik emisyon verilerinden özellik çıkarımı yaparak, bu verileri birleştirmiştir. Bu birleştirilmiş verileri 1D-CNN ağında sınıflandırarak, titreşim ve akustik verileriyle ayrı ayrı sınıflandırma yapıldığı durumla karşılaştırmıştır. Füzyon edilmiş verilerin daha başarılı bir şekilde sınıflandırıldığını göstermiştir [65]. Daichao ve ark. 1D-CNN ve 2D-CNN kanalları içeren çok ölçekli sinir ağı olarak isimlendirdiği bir ağda, üç sınıflı bir titreşim veri setini sınıflandırmış ve bir support vector machine uygulamasıyla karşılaştırmıştır. Önerdiği çok ölçekli sinir ağında %98.58 doğrulukla verilerin sınıflandırıldığı belirtilmiştir [66]. Dhiraj ve ark. Case Western Reserve University (CWRU) bearing database titreşim verilerini kullanarak 1D-CNN ile 2D-CNN ağlarının karşılaştırmasını yapmıştır. Bu çalışmada sıralı veriler için 1D-CNN ağlarının daha yüksek skorlar elde ettiği gözlenmiştir [67]. Yine Dhiraj ve ark. Switchable Normalization based CNN (SN-CNN) adını verdikleri bir ağla CWRU bearing data base verilerini sınıflandırarak %99.4-%100 aralığında bir sınıflandırma başarımı elde etmişlerdir. Deneyler arasında daha fazla karşılaştırma yapabilmek için spectrogram görüntüleri de kullanılmıştır [68]. Eren ve ark. önerdikleri 1D-CNN tabanlı bir ağda ham titreşim verilerini sınıflandırmış, literatürdeki benzer çalışmalarla karşılaştırmışlardır [69]. Wang ve Gao ilk olarak Morlet tabanlı dalgacık dönüşümü ile titreşim verilerini spektrum görüntülerine dönüştürdü. Daha sonra, VGG19 transfer öğrenme modeli ile rulmanları bu görüntüleri %93,9 doğrulukla sınıflandırdılar [70]. Kaya ve ark. Üç farklı veri seti kullanarak, beş farklı transfer learning ağında (GoogleNet, AlexNet, ResNet, VGG16, VGG19) sınıflandırma yapmıştır. Öncelikle ham verilerden, CWT yöntemiyle skalogram görüntüleri elde edilmiş, bu görüntüler bahsi geçen ağlarda %96.67-%100 doğrulukla sınıflandırılmıştır [71]. Shao ve ark.. VGG16 modelini motor, dişli kutusu ve rulman verilerini içeren üç veri setini sınıflandırmada kullandı. İlk olarak bu üç veri setini TF görüntülerine dönüştürmüşlerdir. Daha sonra bu görüntüleri VGG16 modelini kullanarak sınıflandırmışlardır. Rulman veri seti için, %99.82 doğruluk elde etmişlerdir [72]. Mao ve ark. VGG16 transfer öğrenme ağı ile rulmanların sınıflandırmasını gerçekleştirdi. Araştırmacılar, önce ham titreşim verilerini Hilbert-Huang dönüşümü (HHT) ve hızlı Fourier dönüşümü (FFT) ile dönüştürmüşlerdir. Sonra, ham titreşim verileri, HHT ve FFT ile dönüştürülmüş verileri birleştirerek 3D bir veri oluşturmuşlardır. Bu veri ile VGG16 ağında yapılan uygulamada, rulman hata konumlarını kesin olarak tespit

ettiklerini belirtmişlerdir [73]. Lu ve ark. Alexnet ağını, CWRU veri setindeki beş farklı rulman arıza türünü belirlemek için kullandı. Bu titreşim verilerini FFT yöntemi ile spektrogram görüntülerine dönüştürdüler ve %99,7 başarı oranıyla rulman arıza tiplerini ayırt etmişlerdir [74]. Wang ve ark. FFT kullanarak, CWRU titreşim verilerini ve kendi kurdukları deney setinden elde ettikleri titreşim verilerini spektrogram görüntülerine dönüştürdü. Bu görüntüleri Resnet-50 ağına sınıflandırdılar. Sonuçta CWRU verilerini en yüksek %99,8 başarıyla, kendi setlerinden elde ettikleri verileri %99,23 başarıyla sınıflandırdılar [75]. Wen ve ark. çalışmalarında ResNet-50 modelini kullanmışlardır. Modeli üç farklı veri setinde test ettiler. Titreşim sinyallerini gri görüntülere dönüştürüp ResNet-50 ağına sınıflandırmışlardır. Paderborn rulman veri seti için %98,95, CWRU veri seti için %99,99 ve santrifüj pompa veri seti için %99,20 başarı elde ettiklerini belirtmişlerdir [60].

Bu çalışmada Ortadoğu Rulman Sanayii ve Ticaret A.Ş. (ORS) firmasının üretim hattındaki bir taşlama tezgahına yerleştirilen akustik emisyon sensörüyle taşlama tezgahından sinyaller elde edilmiştir. Veriler makara ve dış bilezik numunelerinin taşlanmasıyla elde edilmiştir. Sinyallerin bir kısmı yanık oluşmamış rulmanlara, bir kısmı yanık oluşmuş rulmanlara aittir. Bu sinyallerden Continious Wavelet Transform (CWT) ve Hilbert-Huang Transform (HHT) ve Short-Term Fourier Transform (STFT) yöntemleriyle zaman-frekans gösterimleri elde edilmiştir. Daha sonra bu görüntüler, bazı makine öğrenmesi yöntemleri, LSTM ağları ve AlexNet, GoogleNet, ResNet-50, SqueezeNet derin öğrenme ağlarında hatalı/normal olarak sınıflandırılmıştır. Ayrıca oluşturulan bir 2D-CNN ağına bu TF görüntüleri sınıflandırılmış ve TL uygulamalarıyla karşılaştırılmıştır. Sonuç olarak farklı veri setleri için yüksek test doğrulukları elde edilmiştir.

Tablo 1.1, mevcut literatür ve tezde konu edilen çalışmanın bir karşılaştırmasını göstermektedir.

Tablo 1.1 : Mevcut literatür ve önerilen yöntemin karşılaştırılması

Makale	Sinyal	Metot	Önerilen Yöntem ile Farkı
[47]	AE ve Titreşim	YSA	Sinyaller üzerinde özellik çıkarımı yapılır ve sinir ağına girdi olarak kullanılır. Önerilen yöntem, manuel özellik çıkarma gerekliliğini ortadan kaldırmaktadır.
[48]	Kuvvet, AE, Titreşim ve Sıcaklık	YSA	Sensörün doğru konuma yerleştirilmesi soruna çözüm aranmıştır. Önerilen yöntemde sensör gereksinimi daha azdır.
[49]	AE	YSA	Bu çalışmalarda ön işleme olarak özellik çıkarımının gerekli olduğu makine öğrenmesi yöntemi kullanılmıştır.
[50]	İşleme Parametreleri	YSA	Bu çalışma küçük bir veri seti ile gerçekleştirilmiştir.
[51]	AE	DVM	Bu çalışma da ön işleme olarak özellik çıkarımının gerekli olduğu makine öğrenmesi yöntemi kullanılmıştır.
[60]	Titreşim	Transfer CNN (Resnet-50)	Bu çalışmada, Resnet-50 ile titreşim verilerinden hatalı rulman tespiti yapılmaya çalışılmıştır. Kullanılan veri setindeki kusur, önerilen çalışmada tespit edilmeye çalışıldan çok daha büyüktür. Ayrıca yöntemleri de farklıdır.
[61]	Titreşim	CWT, CNN, gcForest	Bu çalışmada, CNN kullanılarak titreşim verilerinden hatalı rulmanlar tespit edilmeye çalışılmıştır. Kullanılan veri setlerindeki kusur, önerilen çalışmada tespit edilmeye çalışıldan çok daha büyüktür.
[63]	Titreşim	Alexnet, VGG-19, Goog-LeNet, and ResNet-50	Bu çalışma bir ince ayar çalışmasıdır. Her ağ, üç optimize edici kullanılarak eğitildi ve performansları karşılaştırıldı.

Tablo 1.1'e ek olarak aşağıdaki çıkarımları yapmak mümkündür. Çalışma literatürdeki çalışmalarla karşılaştırılmıştır. [16]'da farklı ağ yapılarının sınıflandırma performansı ölçülürken, bu çalışmada farklı makine parametrelerinin önceden eğitilmiş ağlardaki etkisi ölçülmüştür. Böylece farklı makine koşullarının taşlama yanığı üzerindeki etkisi araştırılmıştır. [48]'deki çalışmada farklı sensörlerden elde edilen verilerle sınıflandırma yapılırken bu çalışmada sadece AE sensörü kullanılmıştır. Böylece üretim süreçlerinde daha ekonomik ölçümler yapılabilir. [50]'deki çalışmada ise az miktarda veri ile ölçümler yapılmıştır. [60] ve [61]'deki çalışmalar deneysel çalışmalar için özel olarak oluşturulmuş veri setleri ile yapılmışken, bu çalışmada kullanılan veri seti taşlama makinesinin gerçek çalışma koşullarında çalıştırılması ile elde edilmiştir. [62]'de kullanılan verilerin bir kısmı simülasyonlar yoluyla elde edilmiştir.


Tartışılan çalışmalar genel olarak değerlendirildiğinde, sinyallerden, TF gösterimleri elde edilerek yapılan sınıflandırma uygulamalarının başarılı sonuçlar verdiği görülmektedir.

1.2. Tezin Tanıtımı ve Tezin Literatüre Katkısı

Bu tezin amacı üretim aşamasındaki rulman parçalarında oluşan taşlama yanığını sinyal işleme ve yapay zeka teknikleri kullanarak tespit etmektir. Bunun için gerçek işleme koşullarında rulman parçalarının taşlanması esnasında tezgahın uygun bir konumuna AE sensörü bağlanarak taşlanan rulman parçalarına ait AE verileri toplanmıştır. Bu veriler bilgisayara aktararak sinyallere dönüştürülmüştür. Daha sonra bu sinyallerden ya doğrudan LSTM ve Makine Öğrenmesi yöntemleri ile veya sinyallerin Zaman-Frekans gösterimleri (görüntüleri) elde edilerek CNN tabanlı ağlarda sınıflandırılması gerçekleştirilmiştir. Bu bakımdan teze konu edilen çalışma, dolaylı arıza tespit yöntemlerinden (Bkz. Şekil 1.6) Hata Sonrası Yöntemlerden yapay zekâ tabanlı bir uygulama örneğidir.


Taşlama yanığını tesbit etmek için yapılan ilk işlem veri toplamadır. Çalışmada taşlama malzemesinin AE verileri kullanılmıştır. Bu çalışmada kullanılan AE verileri (İlerleyen bölümlerde bu veriler hakkında daha detaylı bilgiler sunulmaktadır), Ortadoğu Rulman Sanayii ve Ticaret Anonim Şirketi (ORS) Araştırma ve Geliştirme laboratuvarlarında

yapılan deneylerden elde edilmiştir. Deneyler, dış bilezik taşlama ve makara taşlama ile gerçekleştirilmiştir. Şekil 1.7’de taşlama tezgahı gösterilmiştir.



Şekil 1.7 : Verilerin elde edildiği taşlama tezgahı. a) taşlama diski b) akustik emisyon sensörü

Taşlama makinesinin 12 farklı parametresi değiştirilerek 101 farklı ölçüm yapılmıştır. Sinyaller 4 MHz’lık bir örnekleme frekansı ile örneklenecek dijitalleştirilmiştir. Bu sinyallerden 2 örnek Şekil 1.8’de gösterilmiştir.



Şekil 1.8 : ORS Laboratuvarlarında elde edilen akustik emisyon verileri

İkinci aşamada sinyaller önce işlenmemiş sinyaller olarak bazı Makine Öğrenmesi metotları ve LSTM ağı ile sınıflandırılmıştır. Sonra ya özellik çıkarımı ile veya bazı

sinyal işleme yöntemleri ile işlenerek derin öğrenme ve makine öğrenmesi yöntemleri ile hatalı-normal olarak sınıflandırılmıştır.

Literatürde başarılı bir çok sıralı veri tipleri için geliştirilmiş sınıflandırma yöntemleri ve 2 boyutlu(görüntüler için) veri tipleri için geliştirilmiş sınıflandırma yöntemleri mevcuttur. Bu nedenle çalışma kapsamında hem sinyal sınıflandırma yöntemleri hem de görüntü sınıflandırma yöntemleri uygulanmıştır. Görüntü sınıflandırma yöntemlerini kullanabilmek için sinyallerden Zaman-Frekans gösterim yöntemleri ile Zaman-Frekans Görüntüleri (TFG) elde edilmiştir. Bu çalışmada kullanılan TFG elde etme yöntemleri sürekli dalgacık dönüşümü (CWT), kısa dönem Fourier dönüşümü (STFT) ve Hilbert-Huang dönüşümü (HHT) yöntemleridir.

Sinyallerden, TFG elde edildikten sonra bu görüntüler öğrenme aktarması yöntemi kullanılarak farklı CNN tabanlı ön eğitilmiş ağlarda ve yeni bir CNN ağında sınıflandırılmıştır.

Farklı işleme parametreleri, eğitim-test veri oranı ve normal-hatalı veri oranının sınıflandırma performansı üzerindeki etkilerini ölçmek için farklı veri kombinasyonları üzerinde ölçümler yapılmıştır. Ayrıca önceden eğitilmiş ağların yapısında ve bazı ağ parametrelerinde veri setine uygun hale getirmek ve sınıflandırma performansını artırmak için bazı değişiklikler yapılmıştır.

Sinyallerin sınıflandırıldığı makine öğrenmesi yöntemleri ile yapılan sınıflandırma uygulamalarında eğitim doğrulukları %100 başarımlar göstermesine karşın, test doğrulukları kabul edilebilir doğruluk değerlerine ulaşamamıştır. LSTM ağında yapılan sınıflandırmada %90-%92 aralığında bir sınıflandırma doğruluğu elde edilmiştir. başarımları elde edilmiştir.

Zaman-frekans görüntülerinin sınıflandırıldığı öğrenme aktarması ağlarında ve bu tez kapsamında tasarlanan 2D-CNN ağında %95,83-%100, aralığında bir doğruluk değeri elde edilmiştir. Bu oran Literatürde bir sınıflandırma probleminin çözümü için yeterli görülmektedir.

Çalışmadan elde edilen sonuçlar ve literatürdeki çalışmalar bir arada değerlendirildiğinde bu tez çalışmasının literatüre katkısı şu şekilde sıralanabilir.

1. Yapılan detaylı literatür taramasına göre gerçek taşlama koşullarından elde edilen verilerle rulman parçalarında taşlama yanığının tespit etmek için sinyal işleme ve yapay zeka yöntemlerine dayalı bir çalışma bulunmamaktadır.
2. Bu tez çalışmasında kullanılan veri seti özgündür. Taşlama yanığı genellikle kesme hızıyla ilişkilendirilir ve veri kümeleri, çeşitli kesme koşulları altında üretilen örnekleri içerir. Bununla birlikte, diğer işleme koşulları da taşlama yanığının gelişmesinde etkilidir. Bu çalışmada kullanılan veri seti 12 farklı taşlama makinesi özelliğini dikkate aldığından, kullanılan veri seti gerçek bir taşlama yanığının en iyi şekilde gösterme özelliğine sahiptir.
3. Yapılan uygulamalar veri setindeki bir çok işleme parametresinin taşlama yanığına etkisini ölçme imkanı vermektedir. Farklı makine ayarlarının sınıflandırma performansı üzerindeki etkileri karşılaştırılmıştır.
4. Gerçek taşlama koşulları altında toplanan sinyaller, transfer öğrenme ile kanıtlanmış sınıflandırma performansı ile Google Net, Alex Net, ResNet-50 ve Squeeze Net ağlarında sınıflandırılmıştır. Böylece literatüre göre yüksek bir doğruluk elde edilmiştir. Literatür araştırmasına göre, önceden eğitilmiş ağlarda daha önce rulman parçalarında taşlama yanığı tespiti yapılmamıştır.
5. Bu tez kapsamında rulman parçalarının taşlanması sırasında elde edilen AE sinyallerinin TFG'yi sınıflandırmak için yeni bir 2D-CNN ağı tasarlanmıştır ve bu ağda yapılan bazı uygulamalarda mevcut ön eğitilmiş ağlardan daha iyi sınıflandırma başarımları elde edilmiştir.

1.3. Araştırmanın Ekonomik Etkisi

Rulmanlar, dönen makine ve sistemlerin en önemli parçalarından biridir. Bu nedenle sektörel anlamda makine üretimi, otomotiv, beyaz eşya, enerji ve elektronik gibi birçok sektörde ürün girdisi olarak kullanılmaktadır. 2019 yılında dünya rulman ticaret hacmi 66,3 milyar USD olmuştur [32].

Rulman üretim süreci, sıcak-soğuk kesme-dövme, ısıtma işlemi, taşlama ve montaj olarak özetlenebilir. Taşlama sırasında oluşan hatanın maliyetine önceki aşamalarda oluşan maliyetler de dahildir. Bu aşamaların her birinin ardından ara ürünler kontrol edilir.

Taşlama yanığını oluşmadan tespit etmek için önerilen yöntemlerle günümüz koşullarında başarılı sonuçlar alınamamaktadır. Ancak taşlama yanığı oluşuktan sonraki süreçte ciddi ekonomik kayıplar olmaktadır. Bu kayıpları iki ana başlık altında incelemek mümkündür. Bu başlıklardan ilki taşlama yanığı hatasının tespiti için katlanılan maliyetler, ikincisi ise taşlama yanığının tespit edilmeden piyasaya sunulması sonucu oluşan maliyetlerdir. İlk başlığa bakıldığında; taşlama yanması tespit edilirse, üretim prosesi olarak taşlama yanmasının meydana geldiği parametrelerle üretilen rulman partisi kontrol edilmek üzere üretimden çekilir. Bu durum üretimde gecikmeye neden olmaktadır. Üretimden çekilen rulmanların kontrol edilebilmesi için işçilik maliyetleri oluşmaktadır. Ayrıca yanıkların kesin tespiti için yapılan muayene işlemlerinde ekstra maliyetler oluşmaktadır. Bu ekonomik kayıplar, sunulan çalışmada yöntemin üretim maliyetine doğrudan ekonomik katkısı olarak düşünülebilir. Taşlama yanığı tespit edilmeden piyasaya arz edilirse ekonomik kayıplar ve marka değerindeki aşınma çok daha fazla ekonomik zarara neden olabilir. Taşlama sonucu yanmış ürünün geri kazanılması için katlanılan lojistik maliyetlerin yanı sıra hatalı rulmanın kullanıldığı makine veya sistemdeki maddi kayıplar ve bu makine veya sistemlerin durması nedeniyle oluşan üretim ve bakım maliyetleri muazzam boyutlara ulaşabilmektedir. Bu açıdan bakıldığında, sunulan çalışmanın endüstriyel koşullarda %100'e yakın bir doğrulukla taşlama yanığını tespit edebilmesi, imalatçı firmalara önemli bir ekonomik katkı sağlamaktadır. Yani çalışmada sunulan yöntem ile oluşabilecek büyük ekonomik kayıpların önüne geçilebilir.

1.4. Tez Organizasyonu

Çalışmanın giriş bölümünde araştırmaya konu edilen problem tanıtılmış ve bu probleme ilişkin kavramlar tanımlanmıştır. Literatür taraması alt başlığında bu problemi çözmek için yapılan çalışmalar ele alınmış ve tez ile karşılaştırılmıştır. Yine giriş bölümünün alt bölümlerinde tezin literatüre katkıları listelenmiş ve ekonomik etkisi tartışılmıştır. Tezin ikinci bölümünde kullanılan veri setinin elde edilme aşamaları ve kullanılan ekipmanlar anlatılmış ve veri seti detaylıca tanıtılmıştır. Üçüncü bölümde veri setinin ön işleme aşaması ele alınmıştır. Bu bölümle birlikte artık kullanılan yöntemin adımları ele alınmaktadır. Dördüncü bölüm “makine öğrenmesi yöntemleri ile taşlama yanığının tespiti”, beşinci bölüm “LSTM ile taşlama yanığının tespiti”, altıncı bölüm “Ön-

Eđitimi Ađlar ile tařlama yanıđının tespiti” ve yedinci bđlđm “tasarlanan 2D-CNN ile yapılan alıřmalar” olmak ũzere sınıflandırma uygulamalarını konu edinmektedir. Sekizinci bđlđmde ise bu uygulamalardan elde edilen sonular deđerlendirilmiřtir.



BÖLÜM 2. AKUSTİK EMİSYON SENSÖRÜ İLE VERİ TOPLAMA VE VERİ SETİ

Rulman parçalarının üretim süreçlerinde temel kontrol işlemlerinden birisi de taşlama yanığı kontrolüdür. Bu tez de bu kontrol işlemi için yapay zeka ve sinyal işleme destekli bir yöntem önerilmektedir. Bu yöntem rulman hata tespit literatüründe dolaylı yöntemlerin, hata sonrası tespit yöntemleri içinde ele alınmaktadır. Yapay zeka ve sinyal işleme yöntemleri ile taşlama yanığı tespiti yapılabilmesi için dört aşamalı bir süreç takip edilmelidir. Bunlar; veri toplama-verilerin ön işlenmesi, özellik çıkarımı, özellik seçimi ve sınıflandırma. Bu bölümde bu tez de kullanılan verilerin toplanma süreci anlatılmaktadır.

Veri toplama işlemi Şekil 1.2'deki temsili görüntü ile gösterilmiştir. Buna göre rulman parçasının taşlanması sırasında, tezgahın uygun bir konumuna yerleştirilen AE sensörü ile taşlama sürecine ilişkin veri toplanmıştır. Bu analog veriler ön yükselteçten geçirilerek veri toplama kartına aktarılmıştır. Burada 4Mhz'lik örnekleme frekansı ile örneklenerek bu sinyaller dijitalleştirilmiş ve bilgisayara aktararak “.dat” uzantılı sinyal verileri olarak kaydedilmiştir.

Bu tezde kullanılan veriler, ORS rulmanlarının bilezik ve makara taşlama işlemleri sırasında elde edilmiştir. İşlenen parçalar ISO standardında 100Cr6 olarak isimlendirilen çelikten imal edilmiştir. ISO tanımlamasında 100Cr6 olarak isimlendirilen, AISI/SAE tanımlamasıyla 52100 olarak da bilinen 100Cr6 çeliği yüksek karbonlu bir krom rulman çeliğidir. Bu çeliğin mekanik özellikleri hakkında şu bilgiler verilebilir: Yüksek sertlik, iyi aşınma direnci ve yüksek mukavemet gibi mekanik özellikleri vardır. Bu mekanik özellikleri nedeniyle rulman parçalarının üretiminde tercih edilen malzemelerden biridir. Bilyalı ve makaralı rulmanların üretiminde yaygın olarak kullanılan bir malzemedir. Tablo 2.1.'de 100Cr6 çeliğin kimyasal bileşimi ve mekanik özellikleri verilmiştir [76].

Tablo 2.1 : 100Cr6 Çeliğin kimyasal bileşimi ve mekanik özellikleri

Element	Kimyasal Bileşimi	Özellik	Açıklama
Karbon (C)	%0,95-1,05	Sertlik	100Cr6 çeliği, yüksek karbon içeriği nedeniyle yüksek sertliğe sahiptir ve bu da aşınma direncini artırmaktadır.e katkıda bulunur.
Krom (Cr)	1.30-1.60%	Aşınma Direnci	İyi Aşınma Direnci: Aşınma ve aşınmaya karşı iyi direnç gösterir, bu da onu yüksek stres koşullarını içeren uygulamalar için uygun hale getirir.
Manganez (Mn)	0.25-0.45%	Mukavemet	Yüksek Mukavemet: Yüksek karbon ve krom içeriğinin kombinasyonu, çeliğe yüksek mukavemet ve tokluk sağlayarak ağır yüklere ve darbe kuvvetlerine dayanmasına olanak tanır.
Silisyum (Si)	0.15-0.35%	Yorulma Direnci	Mükemmel Yorulma Direnci: 100Cr6 çeliği iyi yorulma direncine sahiptir, bu da tekrarlayan stres döngülerine arıza olmadan dayanmasını sağlar.
Fosfor (P)	%0,025 (maksimum)	İyi Boyutsal Kararlılık	İyi Boyutsal Kararlılık: Aşırı sıcaklıklar ve dalgalı koşullar altında bile şeklini ve boyutsal kararlılığını korur.
Sülfür (S)	0,025 (maksimum)		

Verilerin elde edildiği rulman parçaları Toyo markasının T-11LA88 seri numaralı makinesidir. Makine, üreticisinin internet sitesinde şöyle tanıtılmaktadır: T-11LA88, Toyo'nun T-11L serisi iç taşlama makinelerinin merkezsiz bir modelidir. Aynı anda iki parça taşıyabilmektedir. Yer gereksinimlerini azaltır, enerji tasarrufu sağlar, maliyetleri düşürür ve aynı anda iki rulmanın içini taşıyarak yüksek verimlilik elde eder. Temel özellikleri aşağıda listelenmiştir.

- Ayrı giriş ve çıkış sürgün çiftleri ve iki rulman akışını senkronize etmek için özel bir cihaz, iki iş parçasının istikrarlı ve eşzamanlı olarak yüklenmesini sağlar.
- İki rulman oluğu (iç bileziğin dış yüzeyi) veya iki set iç bilezik iç yüzeyi aynı anda taşlanabilir. Bu, üretim çıktısını iki katına çıkarmayı kolaylaştırır.
- İki parçanın aynı anda taşlanması işletme maliyetlerini yarıya indirir [77].

Şekil 1.7'de Toyo T-11LA88'in iş parçası bağlanan kısmı ve taşlama taşı gösterilmektedir. Şekil 2.1'de ise üretici firma ürün tanıtım resmi gösterilmiştir.



Şekil 2.1 : Toyo T-11LA88 iç taşlama makinesi

Taşlanan rulman parçalarının taşlama süreci AE sinyalleri alınarak kaydedilmiştir. AE sinyallerini elde etmek için Kistler 8152C1050500 serisi sensör kullanılmıştır (bkz. Şekil 2.2). Sensörün temel parametreleri Tablo 2.2'de verilmiştir. Sensör, üreticisi Kistler tarafından şöyle tarif edilmektedir: Tip 8152C, sensör muhafazası, piezoelektrik algılama elemanı ve dahili empedans dönüştürücüden oluşan Piezotronlu akustik emisyon sensörleridir. Piezoelektrik seramikten yapılmış algılama elemanı ince bir çelik diyafram üzerine monte edilmiştir. Yapısı sensörün hassasiyetini ve frekans tepkisini belirler. Muhafazaya kaynaklanmış diyaframın bağlantı yüzeyi, AE sinyallerini ölçmek için hafifçe çıkıntılıdır. Böylece, montaj sırasında tam olarak tanımlanmış bir bağlantı kuvveti ortaya çıkar. Bu, AE iletimi için sabit ve tekrarlanabilir bir bağlantı sağlar. Algılama elemanı tasarım gereği muhafazadan akustik olarak izole edilmiştir ve bu nedenle harici gürültüye karşı iyi korunur [78].

Sensör tarafından alınan sinyaller ön yükselteçten geçirilerek bilgisayara aktarılır. Burada sinyaller dijitalleştirilerek kaydedilmektedir.



Şekil 2.2 : Kistler 8152C1050500 serisi AE sensörü [78].

Tablo 2.2 : Kistler 8152C1050500 sensörünün özellikleri

Özellikler	Birim	Değer(8152C1...0)
Dinamik Özellikler		
Frekans Aralığı	kHz	100-900
Duyarlılık	dBref 1V/(m/s)	48
Çevresel Özellikler		
Çalışma Sıcaklık Aralığı	°C	(-55)-(165)
Elektriksel Çıkış		
Voltaj	V	(-2)-(+2)
Akım	mA	2-4
Kaynak (Besleme)		
Voltaj	V	5-36
Akım	mA	3-6

Veri toplama sürecinin temel donanımlarından birisi de taşlama diskidir. Rulman parçaları taşlanırken kullanılan taşlama diskisi Meister 03_FSK-02-21 serisi taşlama diskidir. Taşlama diskinin özellikleri aşağıda verilmiştir (Bkz. Tablo 2.3).

Tablo 2.3 : Taşlama diskinin teknik özellikleri

Taşlama Diskinin Özellikleri	
Boyutlar	18x4.5x100 R=2.4 / R=13
Teknik Özellikler	55C/5 1000-45 V781 hp
Yüzey Kalitesi	Ra 0.1 ; Rz 1.0
Hız Bileşeni	370 rpm-500 rpm
Pasolar	6 / 2
Salınım açısı	2.2° / 2°

AE sensörünün çıkışından elde edilen analog sinyaller 4MHz'lik örnekleme frekansı ile örneklendirilerek 17s'lik sinyaller oluşturulmuştur. Bazı numunelerden daha uzun sinyaller alınmıştır. Veri toplamak için kullanılan program Tasler LTTPro Software yazılımıdır.

Üretici, programı şöyle tanıtmaktadır: LTTpro profesyonel bir kontrol ve görüntüleme yazılımıdır; 4.0 sürümünden itibaren kullanıcı arayüzünde çok sayıda iyileştirmenin yanı sıra çevrimiçi matematik işlevi de sunmaktadır. Profesyonel yazılım, ölçüm verilerini elde etmeye, analiz etmeye ve görselleştirmeye yardımcı olur. Tüm veriler doğrudan FAMOS, DASYLab, Diadem, MATLAB, Excel, vd. gibi dosya formatlarında kaydedilebilir [79].

Taşlama makinesinin farklı çalışma koşulları altında 41 makara ve 60 dış bilezik numunesinden ölçümler alınmıştır. Her ölçüm için tezgah parametreleri kaydedilmiştir.

Makara taşlamasına ait deneyler (Deney raporunda parça kodu 991603'tür) aşağıdaki gibi gerçekleştirilmiştir. Tablo 2.4'te yapılan deneylerde değiştirilen makine ayarları ve deneylere ilişkin diğer bilgiler bulunmaktadır.

Tablo 2.4 : Makara taşlama deneylerinde kullanılan tezgah ayarları, deney sayıları ve dosya kayıt isimleri

Deney No	Deney Adı	Seviye	Standart Parametre Değeri	Değiştirilen Parametre Değeri	Parça Kodlaması	Kayıt Kodlaması	Deney Sayısı	Yanık Oluştur Mu?
1	Standart	-	-	-	-	NORMAL_(n)	4	-
2	Elmaslama Hızı	Düşürüldü	0,16	0,05	EH(n)	ELMASHIZ(n)	3	Hayır
3	Kesme Basıncı	Düşürüldü	2 bar	0,5 bar	KB(n)	KESMEBSN(n)	3	Hayır
4	Kesme Hızı	Artırıldı	Kaba: 2400 Final: 1200	Kaba: 3200 Final: 2500	KH(n)	KESMEHIZ(n)	3	Hayır
5	İlerleme Hızı	Artırıldı	0,16	0,3	İH(n)	ILERHIZ(n)	3	Hayır
6	Parça Dönme Hızı	Düşürüldü	501 rpm	80 rpm	WP(n)	WPRPM(n)	8	Evet
7	Parça Dönme Hızı	Düşürüldü	501	80	SO 1	SPARK1	1	Evet
	Final Spark-out Süresi	Artırıldı	2 s	5 s				
8	Final Spark-out Süresi	Artırıldı	2 s (Detay A)	5 s (Detay B)	SO(n)	SPARK(n)	3	Hayır
9	Elmaslama Periyodu	Artırıldı	8	20	EC(n)	ELMCYC(n)	12	Hayır
10	Standart	-	-	-	-	CONT	1	Hayır

Tablo 2.4'ün açıklaması şu şekildedir:

Birinci sütun yapılan deneylerin numaralarını göstermektedir. Buna göre 10 farklı tezgâh ayarı değiştirilerek 10 farklı deney yapılmıştır. Birinci deneyin adı “Standart” olarak isimlendirilmiştir. Tablo2.4'ün ikinci sütunu deneylerin isimlerini, aynı zamanda tezgâhta değişen ayarların isimlerini içermektedir. Üçüncü sütun yani “Seviye” sütunu tezgâhta değiştirilen ayarın artırıldığını veya azaltıldığını belirtmektedir. “Standart Parametre Değeri” isimli dördüncü sütun ise tezgâh parametrelerinin standart durumdaki değerlerini yani değiştirilmeden önceki değerini göstermektedir. “Değiştirilen Parametre Değeri” sütunu tezgah parametrelerinde yapılan değişiklikten sonraki değerini göstermektedir. Örneğin Deney 3'te “Kesme Basıncı” 2 bar'dan 0,5 bar'a düşürülmüştür. Altıncı sütun ise işlenen parçaların hangi koşullarda işlendiğini kayıt altına almak için verilen kodları göstermektedir. Bu sayede numune teste gittiğinde hangi koşullar altında işlendiği kaydedilmiş olmaktadır. Yedinci sütun da işleme sırasında bilgisayara aktarılan AE sinyallerinin bilgisayarda kayıt kodlaması gösterilmiştir. Şekil 2.3'te bu kodlamalara göre dosya isimleri görülmektedir. Örneğin Deney 2 de işlenen 3 adet numuneye ait sinyaller bilgisayarda Stream_5_AE_ELMASHIZ1_0000.dat, Stream_6_AE_ELMASHIZ2_0000.dat, Stream_7_AE_ELMASHIZ3_0000.dat kodlarıyla kaydedilmiştir. Sekizinci sütun “Deney Sayısı” sütunudur. Ve aynı işleme parametreleri ile işlenen numune sayısını gösterir. Dokuzuncu ve son sütun numunelerde taşlama yanığı olup oluşmadığını ifade eder. Örneğin Deney 6'da işlenen 8 adet numunelerde taşlama yanığı oluşmuştur. Bunların hangi numunelere ait olduğu numunelerin üzerine işaretlenmiş ve bilgisayardaki kayıtlara aktarılmıştır. Tablo 2.4'te verilen 41 adet 100Cr6 çeliğinden imal edilmiş rulman makara numunelerine ait veri toplama deney raporları aşağıda detaylıca açıklanmıştır.

Deney 1'de “Standart Üretim” koşullarında 4 adet numune işlenerek ölçüm alınmıştır. Parçalarda taşlama yanığı oluşmadır. Dosyalar NORMAL_(n) olarak adlandırılmıştır.

Deney 2'de “Elmaslama Hızı” 0.1600'den 0.05'e düşürülerek 3 parça işlenmiştir. İşlenen parçalarda yanık oluşmamıştır. Numuneler EH 1 - 3 olarak kodlanmış ve elde edilen sinyaller ELMASHIZ(n) olarak adlandırılmıştır.

Deney 3'te "Kesme Basıncı" 2 bar'dan 0.5 bar'a düşürülerek 3 parça işlenmiştir. İşlenen hiçbir parçada yanık oluşmamıştır. Numuneler KB 1 - 3 olarak kodlanmış, elde edilen AE sinyalleri KESMEBSN(n) olarak adlandırılmıştır.

Deney 4'te "Kesme Hızı" kabada 2400'ten 3200'e, finalde 1200'den 2500'e çıkarılmıştır. Yine 3 parça işlenmiş ve parçalarda yanık oluşmamıştır. Numuneler KH 1 - 3 olarak kodlanarak elde edilen AE sinyalleri KESMEHIZ(n) olarak kaydedilmiştir.

Deney 5'te "İlerleme Hızı" 0.16'dan 0.3'e çıkarılarak 3 parça işlenmiştir. İşlenen parçalarda yanık oluşumuna rastlanmamıştır. Numuneler İH 1 - 3 olarak kodlanıp, elde edilen AE sinyalleri ILERHIZ(n) olarak adlandırılmıştır.

Deney 6'da "Parça Dönme Hızı" 501 rpm'den 80 rpm'e düşürülerek 8 parça işlenmiştir. Bütün parçalarda yanık oluşmuştur. Numuneler WP 1 – 8 olarak kodlanarak elde edilen AE sinyalleri WPRPM(n) olarak adlandırılmıştır.

Deney 7'de "Parça Dönme Hızı ve Final Spark-out Süresi" değiştirilmiştir. Ayna (işlenen numunenin bağlandığı tezgah parçası) hızı 501 rpm'den 80 rpm'e düşürülmüş, final spark-out süresi 2 saniyeden 5 saniyeye çıkarılmıştır. 1 parça işlenmiş ve numunede yanık oluşmuştur. Numune üzerine Yanık Hurda 80 d/dk yazılmış ve numuneden elde edilen AE sinyalleri SPARK1 olarak adlandırılmıştır.

Deney 8'de " Final Spark-out Süresi" 2 saniyeden 5 saniyeye çıkarılarak 3 numune işlenmiştir. Parça başına düşen süre 19 saniyeye çıktı. Parçalarda yanık oluşmamıştır. Numuneler SO 1 - 3 olarak kodlanmış ve numunelerden elde edilen AE sinyalleri n=2'den başlamak üzere SPARK(n) olarak adlandırılmıştır.

Deney 9'da "Elmaslama Periyodu" 8 parçadan 20 parçaya çıkarılmıştır. Ölçüme 9. parçadan başlanarak 12 parça ölçülmüştür. Parçalarda yanık oluşmamıştır. Son üç parça numune olarak alındı ve EC 1, 2, 3 olarak kodlandı. Dosyalar ELMCYC(n) olarak adlandırıldı.

Deney 10'da tezgah tekrar "Standart Üretim" koşullarına ayarlanarak parçalar işlenmiştir. İşlenen parçalarda yanık gözlenmedi. AE sinyalleri CONT(n) olarak adlandırıldı.

Sonuç olarak Şekil 2.3.'de görüntüsü verilen 41 adet makara taşlamasına ait sinyal kayıtları oluşturulmuştur. Bu sinyallere ait 2 örnek Şekil 1.8.'de görülmektedir.



Stream_1_ORS_AE_NORMAL_0000.dat	Stream_22_ORS_AE_WPRPM6_0000.dat
Stream_2_ORS_AE_NORMAL_2_0000.dat	Stream_23_ORS_AE_WPRPM7_0000.dat
Stream_3_ORS_AE_NORMAL_3_0000.dat	Stream_24_ORS_AE_WPRPM8_0000.dat
Stream_4_ORS_AE_NORMAL_4_0000.dat	Stream_25_ORS_AE_SPARK1_0000.dat
Stream_5_ORS_AE_ELMASHIZ1_0000.dat	Stream_26_ORS_AE_SPARK2_0000.dat
Stream_6_ORS_AE_ELMASHIZ2_0000.dat	Stream_27_ORS_AE_SPARK3_0000.dat
Stream_7_ORS_AE_ELMASHIZ3_0000.dat	Stream_28_ORS_AE_SPARK4_0000.dat
Stream_8_ORS_AE_KESMEBSN1_0000.dat	Stream_29_ORS_AE_ELMCYC1_0000.dat
Stream_9_ORS_AE_KESMEBSN2_0000.dat	Stream_30_ORS_AE_ELMCYC2_0000.dat
Stream_10_ORS_AE_KESMEBSN3_0000.dat	Stream_31_ORS_AE_ELMCYC3_0000.dat
Stream_11_ORS_AE_KESMEHIZ1_0000.dat	Stream_32_ORS_AE_ELMCYC4_0000.dat
Stream_12_ORS_AE_KESMEHIZ2_0000.dat	Stream_33_ORS_AE_ELMCYC5_0000.dat
Stream_13_ORS_AE_KESMEHIZ3_0000.dat	Stream_34_ORS_AE_ELMCYC6_0000.dat
Stream_14_ORS_AE_ILERHIZ1_0000.dat	Stream_35_ORS_AE_ELMCYC7_0000.dat
Stream_15_ORS_AE_ILERHIZ2_0000.dat	Stream_36_ORS_AE_ELMCYC8_0000.dat
Stream_16_ORS_AE_ILERHIZ3_0000.dat	Stream_37_ORS_AE_ELMCYC9_0000.dat
Stream_17_ORS_AE_WPRPM1_0000.dat	Stream_38_ORS_AE_ELMCYC10_0000.dat
Stream_18_ORS_AE_WPRPM2_0000.dat	Stream_39_ORS_AE_ELMCYC11_0000.dat
Stream_19_ORS_AE_WPRPM3_0000.dat	Stream_40_ORS_AE_ELMCYC12_0000.dat
Stream_20_ORS_AE_WPRPM4_0000.dat	Stream_41_ORS_AE_CONT_0000.dat
Stream_21_ORS_AE_WPRPM5_0000.dat	

Şekil 2.3 : 41 Adet makara taşlaması deneyinden elde edilen AE sinyalleri

İkinci olarak 680106 parça kodlu dış bilezik numuneleri Tablo 2.5'te verilen deney parametrelerine göre taşlanarak dış bilezik taşlama ölçümleri yapılmıştır. Bu ölçümlere ait tezgah parametreleri, dosya kayıt isimleri ve deney sayıları Tablo 2.5'te görülmektedir.


Tablo 2.5 : Dış bilezik taşlama deneylerinde kullanılan tezgah ayarları, deney sayıları ve dosya kayıt isimleri

Deney No	Deney adı	Seviye	Standart Parametre Değeri	Değiştirilen Parametre Değeri	Parça Kodlaması	Kayıt Kodlaması	Deney Sayısı	Yanık Oluştumu?
1	Elmaslama Hızı	Düşürüldü	4,48	1	EH(n)	ELMASHIZ(n)	3	Hayır
2	Kesme Basıncı	Düşürüldü	?	?	KH(n)	KESBSN(n)	3	Hayır
3	Kesme Hızı	Artırıldı	57 m/s	62,8 m/s	KB(n)	KESHIZ(n)	3	2 parçada
4	İlerleme Hızı	Artırıldı	-	-	İH(n)	ILERHIZ(n)	3	1 parçada
5	Spark-out Süresi	Artırıldı	0,29 (Detay C)	1: 0,58; 2:1,93; 3: 2,02; 4: 2,03 (Detay D)	SO(n)	SPARK(n)	4	Hayır
6	Standart	-	-	-	-	SPARK5	3	Hayır
7	Elmaslama Periyodu	Artırıldı	6	23	EP(n)	SPARK5	20	2 parçada
8	Elmas Kompanse Miktarı	Düşürüldü	30 µm	10 µm	EK(n)	ELMKOM(n)	3	1 parçada
9	Düşük Sertlikte Numune	Düşürüldü	60 HRC	30 HRC	Y(n)	HRC30	7	Hayır
10	Orta Sertlikte Numune	Düşürüldü	60 HRC	40 HRC	O(n)	HRC40	7	3 parçada
11	İç Kafa Devri	Düşürüldü	-	-	W(n)	YANIK1	2	Evet
12	Manyetik	Düşürüldü	-	-	MN(n)	YANIK2	2	Hayır

Tablo 2.4’e benzer şekilde Tablo 2.5’te aynı sütunlardan oluşmaktadır. Tablo 2.4’ten farkı tezgâh parametreleridir. Örneğin Deney 1’e ait tablo 2.5’teki rapor açıklaması şu şekildedir:

Deney 1’de “Elmaslama Hızı” 4.48’den 1’e düşürülerek 3 parça işlenmiştir. Parçalarda yanık oluşmamıştır. Numuneler EH 2 - 4 olarak kodlanmıştır. İşleme sırasında elde edilen AE sinyalleri ELMASHIZ(n) olarak adlandırılmıştır. Şekil 2.4’te bu dosyalar gösterilmiştir.

Sonuç olarak Şekil 2.4.’de görüntüsü verilen iç bilezik taşlamasına ait sinyal kayıtları oluşturulmuştur. Bu sinyallere ait örnekler Şekil 1.8.’de görülmektedir.



Şekil 2.4 : Dış bilezik taşlamasından elde edilen ae sinyalleri

BÖLÜM 3. VERİ SETİNİN ÖN İŞLEMESİ

3.1. Hilbert-Huang Dönüşümü(HHT)

Hilbert-Huang dönüşümü, durağan olmayan ve doğrusal olmayan verilerin zaman-frekans analizini gerçekleştirmek için güçlü bir araçtır. Hilbert-Huang dönüşümü, analiz edilen sinyalin özelliklerine dayanan ampirik mod ayrıştırma (EMD) olarak adlandırılan uyarlanabilir bir ayrıştırma yöntemi kullanır. EMD algoritması, intrinsic mod fonksiyonlarını (IMF'ler) elde etmek için kullanılır. IMF'ler aşağıdaki iki şartı sağlaması gereken tek bileşenli fonksiyonlardan oluşur[80].

- a) Zaman serisi boyunca, uç noktaların sayısı ile sıfır geçişlerin sayısı arasındaki fark sifıra eşit veya bir birim farka sahip olmalıdır.
- b) Zaman serisinin herhangi bir noktasında, yerel maksimumlar ile yerel minimumlar arasındaki ortalama değer sifıra eşittir.

EMD aracılığıyla IMF'lerin elde edilmesi işlemi yinelemeli bir yöntem olan aşağıda verilen eleme algoritması ile yapılır[81].

Adım 1: Verilen $x(t)$ sinyalinin yerel maksimum ve yerel minimum noktaları tanımlanır.

Adım 2: Üst $U(t)$ ve alt $L(t)$ uç noktalarını elde etmek için kübik spline kullanarak yerel ekstremumları enterpolasyon yapılır.

Adım 3: Üst ve alt uç noktaların yerel ortalama değerini hesaplayın: $m(t)=(U(t)+L(t))/2$

Adım 4: Yerel ortalama $m(t)$ 'yi orijinal sinyalden çıkarılır: $h_1(t)= X(t)-m(t)$

Adım 5: $x(t)$ sinyalini $h_1(t)$ ile değiştirin ve elde edilen sinyal yukarıda bahsedilen (a) ve (b) iki IMF koşulunu karşılayana kadar Adım 1-4 yinelenir.

Bu kriterlerden biri(a-b), eleme sürecini durdurmak için kullanılır: (M-1) tane IMF'yi çıkardıktan sonra, kalan, $r_M(z)$, bir IMF veya durağan bir fonksiyondur.

Orijinal sinyal daha sonra elde edilen IMF'lerin superpose edilmesiyle yeniden oluşturulabilir:

$$X(t) = \sum_{m=1}^{M-1} IME_m(t) + r_M(t) \quad (3.1)$$

burada Denklem 3.1'de M-1, IMF'lerin sayısıdır, yani sinyal (M-1) tane IMF'e ve bir kalan'dan oluşur.

EMD algoritmasının çalıştırılmasından sonra, her bir IMF'ye Hilbert dönüşümü (HT) uygulanır. Böylece bir dizi anlık genlik ve frekans elde edilmiş olur. Bu genlik ve frekanslar Hilbert-Huang spektrumunu oluşturmak için kullanılır. IMF'ye uygulanacak HT işlemi Denklem 3.2 ile tanımlanır.

$$y(t) = \frac{1}{\pi} P \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (3.2)$$

P: Cauchy ana değeri.

x(t) ve y(t) elde edildikten sonra, analitik sinyal Denklem 3.4 ile ifade edilebilir.

$$y(t) = \frac{1}{\pi} P \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (3.3)$$

$$z(t) = x(t) + iy(t) = a(t)e^{i\theta(t)} \quad (3.4)$$

$$a(t) = [x(t)^2 + y(t)^2]^{\frac{1}{2}} \text{ ve } \theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (3.5)$$

burada a(t) genlik ve θ(t) faz fonksiyonudur.

Bu durumda, anlık frekans Denklem 3.6 ile hesaplanır.

$$f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (3.6)$$

3.2. Kısa Dönem Fourier Dönüşümü (Short-Term Fourier Transform-STFT)

Fourier dönüşümü (FT), bir sinyali zaman alanından frekans alanına dönüştürür. Fourier dönüşümünde kullanılan ana fonksiyonlar karmaşık üstellerden oluştuğundan zaman boyutunda sınırlandırılmamıştır. Dolayısıyla sinyal zaman bileşenine ilişkin bilgi içermez. Fourier dönüşümünün bu sınırlamasını aşmak için, yani durağan olmayan

sinyalleri zaman domeninde sınırlamak için Kısa süreli Fourier dönüşümü (STFT) geliştirilmiştir [82]. STFT, durağan olmayan bir sinyalin frekans içeriğinin zaman içinde nasıl değiştiğini analiz etmek için kullanılır. STFT, FT uygulanarak elde edilmiş sinyali, bir pencereyle çarparak bir zaman sınırı ekler. Böylece FT sinyali bu sınırların dışında kaybolur. Bu sayede STFT hem zaman hem de frekans bilgisi sağlayabilir [83]. FT'den STFT'yi elde eden matematiksel işlem Denklem 3.7'deki gibi tanımlanır:

$$STFT(f, \tau) = \int_{-\infty}^{+\infty} s(t)w(t - \tau)e^{-2i\pi ft} dt \quad (3.7)$$


Burada $s(t)$; sinyal, $e^{-2i\pi ft}$, Fourier çekirdeği ve $w()$, τ zamanında merkezli analiz penceresidir.

STFT'de kullanılan analiz fonksiyonları, sınırlandırılmış karmaşık üstel fonksiyonlar olduğundan, Denklem 3.7 ile hesaplanan STFT katsayıları, belirli bir frekansa (f) sahip bir sinüzoidal ile analiz edilen sinyalin τ merkezli bir segmenti arasındaki benzerlik ölçüsü olarak yorumlanabilir[83].

STFT, analiz boyunca belirli sınırlar içerisinde kaldığından, seçilen sınırlar geniş olursa, tüm zaman-frekans düzlemlerinde zaman alanında kötü çözünürlük ve frekans alanında iyi çözünürlük elde edilir. Küçük sınırlar ise zaman alanında iyi çözünürlüğe ve frekans alanında kötü çözünürlüğe neden olur. Bu nedenle, STFT uygulaması, sınır genişliğini ayarlayarak zaman ve frekans alanlarındaki çözünürlük arasında bir optimizasyon gerektirir. STFT'nin bu sorununu çözmek adına dalgacık dönüşümü önerilmektedir[84].

3.3. Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform-CWT,)

Dalgacık terimini ilk olarak Grossmann ve Morlet kullanılmıştır [85]. WT, konuşma ve görüntü analizi ve veri sıkıştırma gibi çalışmalarda kullanılan bir sinyal işleme aracıdır. Bu çok-ölçekli yöntem, Şekil 1'de gösterildiği gibi, hem zaman hem de frekans alanında uygun bir çözünürlük verebilir. Çözünürlük sorunu, aynı pencere işlevinin birden çok küçültülmüş ve genişletilmiş formu uygulanarak çözülür. Bu küçültülmüş ve genişletilmiş pencere işlevlerine dalgacık denir. Bir dalgacığın genliği başlangıçta ve sonda sıfırdır. Ve belirli integrali sıfır olmalıdır. Dalgacıkların şekli ve özellikleri farklıdır. En yaygın dalgacıklar Haar, Daubechies, Meyer ve Morlet dalgacıklarıdır [84].



Şekil 9.1 : STFT ve CWT nin TF çözünürlüğüne etkisi

Sürekli dalgacık dönüşümü, pencere boyutunu daraltıp-genişleterek zaman-frekans çözünürlük problemini çözer. Böylece zaman-frekans düzleminde sabit bir çözünürlüğe sahip olan STFT'den farklı olarak, CWT çoklu çözünürlüklü analize izin verir.

Sürekli dalgacık dönüşümü, bir sinyali, ana dalgacığın (MW) kaydırılmış ve ölçeklenmiş (uzatılmış veya kısaltılmış) dalgacıklarıyla karşılaştırır. Bu sayede CWT, bir sinyalin frekansının zaman içinde nasıl değiştiğini analiz etmek için kullanılır. Bir sinyal ayrıca zaman alanından zaman-frekans alanına CWT aracılığıyla dönüştürülür.

CWT de analiz edilen ana fonksiyon (MW) bir dalgadır ve ψ ile gösterilir. CWT, ana dalgacığın ölçeği değiştirilip, ölçekli ana dalgacık zamana göre kaydırılıp, sinyalle çarpılır ve bu çarpım zamanla entegre edilerek hesaplanır. Yani CWT matematiksel olarak Denklem 3.8'deki gibidir:

$$CWT(a, b; f(t), \psi(t)) = \int_{-\infty}^{+\infty} f(t) \frac{1}{a} \psi^*\left(\frac{t-b}{a}\right) dt \quad (3.8)$$

Burada $*$ karmaşık eşlenik anlamına gelir. Ölçek parametresi a ve zamanda konumu b , sinyal $f(t)$ 'dir. Dönüştürülen sinyal, ölçek a ve zamanda konumu b 'ye bağlıdır. b parametresi, zaman konumundan sorumlu olan pencerenin sınırlarını belirler, a parametresi, frekans ile ters orantılıdır. Frekans çözünürlüğü ve zaman çözünürlüğünü kısıtlar. a sayısı ne kadar yüksek olursa, pencere o kadar genişler ve genel veya daha düşük frekanslar algılanır. Daha küçük bir a değeri, dalgacıkta daha hızlı bir değişime yol açar, bu nedenle sinyalin daha yüksek frekansları algılanır. Tüm pencereler, MW'nin küçültülmüş veya genişletilmiş örnekleridir. CWT'nin dezavantajı, veri noktalarının sayısındaki artıştır[84].

BÖLÜM 4. MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAŞLAMA YANIĞININ TESPİTİ

Bu bölümde, taşlama yanıının tespiti için akustik emisyon sensörüyle taşlama tezgahından toplanan veriler En Yakın K-Komşuluğu (K-Nearest Neighborhood-KNN) ve Destek Vektör Makineleri (Support Vector Machine-SVM) temelli makine öğrenmesi yöntemleri ile sınıflandırılmış, böylece taşlama yanıı tespit edilmiştir.




4.1. Teorik Arka Plan

4.1.1. En yakın K komşuluğu (K-Nearist Neighbours-KNN)

Makine öğrenmesi yöntemleri temel olarak dörde ayrılmaktadır. Bunlar denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenmedir[86]. K-NN bir denetimli öğrenme algoritmasıdır ve genellikle sınıflandırma veya korelasyon uygulamalarında kullanılır .

Yeni bir verinin hangi sınıfa ait olduğunu tahmin ederken, K-NN algoritması eğitim veri kümesindeki en yakın veri noktalarını, yani verinin "en yakın komşularını" bulur. Seçilen k komşunun sınıflandırılacak veriye olan uzaklığına bakar. Bu k mesafenin en küçük ortalamasına göre veriyi sınıflandırır. Şekil 4.1 iki sınıflı bir veri setini göstermektedir. Örneğin bu veri setinde 2 test verisinin hangi sınıfa ait olduğu tahmin edilecek olursa;


Şekil 4.2.'de K=3 olan bir modelin tahmin ettiği test verisinin hangi sınıfa ait olduğu ve modelin tahminleri gösterilmektedir. Buna göre; tahmin edilecek verinin en yakın 3 komşusu belirlenir. Bu komşulara olan uzaklıklar tek tek hesaplanır. Bunun için farklı hesaplama yöntemleri olsa da en yaygın kullanılanı Öklid uzaklık ölçümüdür. Bu uzaklıkların ortalaması alınarak en kısa olanın hangi sınıfa ait olduğuna karar verilir ve tahmin edilen değer o sınıfa ait olur.



Şekil 4.1 : Örnek veri seti

Şekil 4.2 : $K=3$ ile KNN ile örnek veri setinin sınıflarının tahmini 2 boyutlu veri kümeleri için, xy düzlemindeki tüm olası test noktaları için tahmini de görülebilir. Bu bölgedeki bir noktaya atanacak sınıfa göre düzlemi renklendiriyoruz. Bu, algoritmanın sınıf 1'e atadığı yer ile sınıf 2'ye atadığı yer arasındaki ayrım olan karar sınırını görmemizi sağlar.






Şekil 4.3 : Farklı K değerleri için “a) K=1, b) K=3, c) K=9” K-NN tarafından oluşturulan karar sınırları

Şekil 4.3. a) ($K=1$)’da görebileceğiniz gibi, tek bir komşu kullanmak, eğitim verilerini yakından takip eden bir karar sınırı ile sonuçlanır. Gittikçe daha fazla komşuyu göz önünde bulundurmak, daha düzgün bir karar sınırına yol açar. Daha yumuşak bir sınır, daha basit bir modele karşılık gelir. Başka bir deyişle, az sayıda komşu kullanmak yüksek model karmaşıklığına ve çok sayıda komşu kullanmak düşük model karmaşıklığına karşılık gelir. Komşu sayısının eğitim kümesindeki tüm veri noktalarının sayısı olduğu aşırı durumu göz önünde bulundurursanız, her test noktası tam olarak aynı komşulara (tüm eğitim noktaları) sahip olur ve tüm tahminler aynı olur; eğitim setinde en sık görülen sınıftır [87].

4.1.2. Destek vektör makineleri (Support Vector Machine-SVM) ile rulman hatalarının sınıflandırılması

SVM'nin ana motivasyonu, eğitim setindeki birkaç sınıfı, aralarındaki marjı en üst düzeye çıkaran bir yüzeyle ayırmaktır. Başka bir deyişle, SVM, bir modelin genelleme yeteneğini en üst düzeye çıkarmaya izin verir. Bu, bir modelin genelleme hatası üzerindeki bir sınırın en aza indirilmesine izin veren Yapısal Risk Minimizasyonu ilkesinin (SRM) amacıdır.

Veriler tam olarak iki sınıfa sahip olduğunda bir destek vektör makinesi kullanılabilir. Bir SVM, bir sınıfın tüm veri noktalarını diğer sınıfın veri noktalarından ayıran en iyi hiper düzlemi bularak verileri sınıflandırır. Bir SVM için en iyi hiperdüzlem, iki sınıf arasında en büyük marjı olan anlamına gelir. Kenar boşluğu, iç veri noktası olmayan hiperdüzlemin paralel maksimum genişliği anlamına gelir. Destek vektörleri, ayırma hiperdüzlemine en yakın olan veri noktalarıdır ve bu noktalar levhanın sınırındadır. Şekil 4.4, veri noktalarını ve bu tanımları göstermektedir[88].




Şekil 4.4 : K=3 ile KNN ile örnek veri setinin sınıflarının tahmini

Eğitim sırasında SVM, eğitim veri noktalarının her birinin iki sınıf arasındaki karar sınırını temsil etmek için ne kadar önemli olduğunu öğrenir. Tipik olarak, eğitim noktalarının yalnızca bir alt kümesi, sınıflar arasındaki sınırdaki bulunanlar karar sınırını tanımlamak için önemlidir. Bunlara destek vektörleri denir ve destek vektör makinesine adını verir. Yeni bir nokta için tahmin yapmak istenildiğinde destek vektörlerinin her birine olan mesafe ölçülür. Destek vektörüne olan mesafelere ve eğitim sırasında öğrenilen destek vektörlerinin önemine dayalı olarak bir sınıflandırma kararı verilir[87].

4.2. Makine Öğrenmesi Yöntemleri ile Taşlama Yanığının Tesbitinde Kullanılan Metot


Rulmanlarda arıza tespit çalışmalarında yapay zeka yöntemleri sıklıkla kullanılmaktadır. Bu yöntemler kullanılırken arızayı sayısallaştırmak için titreşim ve AE sinyalleri kullanılır. Bu sinyaller ön işleme tabi tutularak veya tutulmadan makine öğrenmesi veya derin öğrenme ağlarına girdi olarak verilir ve ağın bu girdileri sınıflandırması beklenir. Bu çalışmada temel olarak bu süreçler uygulanmıştır. İlk olarak Şekil 2.1.'de gösterilen rulman taşlama makinesinden AE sensörleri ile ham veri toplanmıştır. Daha sonra bu ham verilerden belirli büyüklükte parçalar alınarak ML'nin girişine uygun formatta matrisler oluşturulmuştur. Bu veriler ML yöntemleri ile

sınıflandırılarak ağların performans başarıları kaydedilir. Son aşamada ise ağların başarıları karşılaştırılır. Bu adımları gösteren akış şeması Şekil 4.5'te gösterilmiştir.



Şekil 4.5 : ML Yöntemlerinin uygulama adımları

Şekil 4.6’da ML uygulama adımları, uygulamada kullanılan veri örnekleri ve MATLAB araçları ile gösterilmiştir.



Şekil 4.6 : ML Uygulama adımları gösterimi

Metodun ilk adımında AE verilerinin elde edilmesi gerekmektedir ve Bölüm 2 de bu konu detaylıca açıklanmıştır.

4.2.1. AE verilerinin ön işleme ile hatalı-normal veri setinin oluşturulması

Veriler bilgisayara aktarıldıktan sonra sınıflandırma problemine uygun olarak veri seçimi yapılmıştır. Veriler ve içerikleri aşağıda açıklanmıştır.

Aynı Makine Parametreleri (AMP)-Veri Seti 1: Aynı işleme parametreleri ile işlenmiş normal rulman makarası örneklerinin verilerinden sıralı olarak 81 adet 1×65536 vektör alınarak bir matris halinde birleştirilmiştir. Bu matrisin boyutu 81×65536 'dır. Aynı şekilde, aynı işleme parametreleri ile işlenen hatalı rulman makarası verilerine ait 1×65536 boyutundaki diğer 81 vektör alınır ve bir matriste birleştirilir. Bu matrisin boyutu 81×65536 'dır. Bu iki matris daha sonra tek bir matriste birleştirilerek 162×65536 boyutunda bir matris oluşturulmuştur. Bu matris AMP-VS1 olarak adlandırılmıştır.

AMP-Veri Seti2: Veri Seti1'e benzer şekilde, aynı işleme parametreleriyle işlenen 92×65536 boyutundaki normal veriler ve 72×65536 boyutundaki hatalı veriler tek bir matriste birleştirilmiştir. Böylece AMP-VS2 adında 162×65536 boyutlu bir veri seti oluşturulmuştur.

AMP-Veri Seti3: Bu veri seti 126×65536 boyutlarındaki normal veriler ile 36×65536 boyutlarındaki hatalı verilerin birleşiminden oluşmaktadır. Normal verilerin ağırlığı

kademeli olarak artırılmıştır. Bunun nedeni ağın hassasiyet yeteneğini ölçecek bir veri kümesi oluşturmaktır. Bir diğer neden ise üretim koşullarındaki normal ürün/hatalı ürün oranına uygun bir veri seti oluşturmaktır. Çünkü gerçek üretim koşullarında normal numune sayısı kusurlu numune sayısından fazla olacaktır. Tablo 4.1. veri kümelerini göstermektedir.

Tablo 4.1 : ML Uygulamaları için oluşturulan veri seti

Veri Seti	Boyut	Hatalı	Normal
AMP-Veri Seti 1	162x65536	81x65536	81x65536
AMP-Veri Seti 2	162x65536	70x65536	92x65536
AMP-Veri Seti 3	162x65536	36x65536	126x65536

4.2.2. ML Yöntemi ve hiperparametre seçimi

Uygulamada ikinci olarak MATLAB Classification Learner aracından seçebileceğimiz hiperparametreler yani oluşturulan makine öğrenmesi algoritmasının parametreleri seçilir.

MATLAB Classification Toolbox'ta bir çok ML yöntemi bulunmaktadır. Bu tez kapsamında yapılan çalışmalar sonucunda K-NN ve SVM yöntemlerinin kullanılmasına karar verilmiştir.

K-NN algoritması için seçilen parametreler; komşuluk sayısı K değeri, regularizasyon yöntemi crossvalidation oranı, holdout (varsa veya yoksa) gibi temel parametrelerdir. Bu koşullar Tablo 4.2.'de her bir uygulama için verilmiştir.

SVM yöntemi için seçilen temel parametreler; regularizasyon yöntemi crossvalidation oranı, holdout (varsa veya yoksa) parametreleridir. Bu koşullar Tablo 4.3.'de her bir uygulama için verilmiştir.

4.2.3. Uygulama sonuçları ve başarımlar metrikleri

Makine öğrenmesi deneyleri Şekil 4.5'teki adımlara göre gerçekleştirilmiştir. Buna göre verilerin hazırlanması sırasında, veri setinden hatalı ve normal olduğu bilinen veriler seçilmiştir. Bu verilerden farklı büyüklüklerde veri parçaları (bkz. Tablo 4.1.)


oluşturulmuştur. Bu veri parçalarından hatalı ve hatasız olarak ayrı ayrı oluşturulan veri parçaları tek bir dosyada birleştirilir ve hatalı olanlar "HA", hatasız olanlar "NO" ile etiketlenir. Son durumda elimizde farklı boyutlarda veri matrisleri bulunmaktadır. Seçilen yöntemlerle yapılan uygulamalarda veriler sınıflandırılmıştır. Tablo 4.2. K-NN uygulama sonuçları ve parametrelerini, Şekil 4.7. ise Fine K-NN yönteminin konfüzyon matrisini göstermektedir.

Tablo 4.2 : K-NN Yöntemi hiperparametreleri ve farklı K-NN ağları için uygulama sonuçları

Veri Seti		AMP-Veri Seti 1				AMP-Veri Seti 2				AMP-Veri Seti 3	
Validation		Validation Yok		Crossvalidation (%5)		Holdout (%25)		ValidationYok		Validation Yok	
Metot	K	Doğruluk (%)	ES (Sn)	Doğruluk (%)	ES (Sn)	Doğruluk (%)	ES (Sn)	Doğruluk (%)	ES (Sn)	Doğruluk (%)	ES (Sn)
Fine KNN	1	100	3,23	53,7	23,37	52,5	4,08	100	3,95	58,6	15,21
Medium KNN	10	53,1	2,58	50	22,48	47,5	3,63	55,6	4,28	55,6	15,82
Course KNN	100	48,8	2,79	50	21,93	50	4,2	55,6	4,04	55,6	15,63
Cousine KNN	10	61,7	2,61	53,7	23,2	50	3,96	61,1	4,33	51,9	15,41
Cubic KNN	10	53,1	6,16	51,9	46,34	47,5	8,23	56,2	17,72	53,7	37,8
Weighted KNN	10	100	2,92	50	32,33	47,5	5,77	100	5,76	55,6	25,24

Algoritmalar seçilip çalıştırıldığında her bir algoritma için doğruluk değeri, sınıflandırma performansı, karışıklık matrisi, yayılım grafiği, işlem süresi gibi değerlendirme kriterlerine ulaşmak mümkündür. Şekil 4.7.'de Ağırlıklı K-NN algoritmasından elde edilen sonuçlara göre karışıklık matrisi verilmiştir. Algoritmanın doğru tahminleri ve yanlış tahminleri MATLAB Classification Learner Toolbox'ı tarafından oluşturulan yayılım grafiğinde gösterilmektedir. Veriler çok küçük hassasiyetle sıralandığı için ancak yayılım grafiği küçültülerek veya büyütülerek

görülebilmektedir. Doğru ve yanlış tahminleri görmek için başka bir grafikolan grafiksel karışıklık matrisine bakılabilir.



Şekil 4.7 : Fine K-NN modeli tahminleri ve karışıklık matrisi


Karışıklık(Konfüzyon) matrisinden True Positive(TP)/Negative(TN) ve False Positive(FP)/Negative(FN) tahminlerinin oranını elde etmek mümkündür. Bu oran üzerinden modelin "doğruluk" değeri hesaplanabilir. Uygulama bize bu hesabı doğrudan vermektedir. Karışıklık matrisinden "doğruluk" hesabı Denklem 4.1'deki gibi hesaplanır.

$$\text{Doğruluk(Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.1)$$

SVM uygulamalarında Tablo 4.1.'de verilen veriler Tablo 4.3.'te verilen SVM modelleri ile sınıflandırılmış ve ilgili başarı ölçümleri kaydedilmiştir. Fine Gauss SVM modeli için karışıklık matrisi Şekil 4.8.'de verilmiştir.

Tablo 4.3 : AMP-Veri Seti-1 ile yapılan SVM deneyleri

AMP- Veri Seti 1						
Validation	Validation Yok		Crossvalidation (%5)		Holdout(%25)	
Başarım Metrikleri	Doğruluk(%)	ES(Sn)	Doğruluk(%)	ES(Sn)	Doğruluk(%)	ES(Sn)
Linear SVM	86,4	9,78	51,9	12,7	67,5	3,17
Quadratic SVM	98,1	9,02	50,6	179,2	42,5	3,05
Qubic SVM	100	8,5	47,5	181,1	42,5	3,13
Fine Gaussian SVM	100	9,5	58	2,27	55	2,99
Medium Gaussian SVM	88,9	10,8	51,2	0,65	62,5	3,00
Coarse Gaussian SVM	77,2	10,2	47,5	0,67	60	3,05
Optimizable SVM	100	99,3	52,5	407	60	103



Şekil 4.8 : Fine Gauss SVM karışıklık matrisi

Tablo 4.2'deki K-NN yöntemi ile yapılan sınıflandırma uygulamalarına ve Tablo 4.3'te sonuçları verilen SVM yöntemi ile yapılan sınıflandırma uygulamalarına bakılırsa eğitim doğruluklarının %100 ve civarı değerlerde olmasına karşın çapraz doğrulama(crossvalidation) ve test doğrulama(holdout) doğruluklarının düşük olduğu görülecektir. Bu durum ağın eğitim sürecinde ezber yaptığı anlamına gelir. Veri dağılımı dikkate alındığında KNN ağında uygun bir ayırma düzlemi oluşturulmadığı, SVM yönteminde ise veri sınıflarını ayıracak uygun destek vektörleri ve hiperdüzlemi oluşturamadığını söyleyebiliriz.




BÖLÜM 5. TASARLANAN LSTM AĞIYLA TAŞLAMA YANIĞININ TESPİTİ

Bu bölümde; taşlama yanıının tespiti için ön işlem uygulanmış AE verileri, tez kapsamında tasarlanan LSTM derin öğrenme ağıyla sınıflandırılmış ve taşlama yanıı tespit edilmiştir.

5.1. Teorik Arka Plan:LSTM

Tekrarlayan Sinir Ağları (RNN), sıralı verileri işlemek için özelleşmiş bir sinir ağıları ailesidir[35]. Yani, bu ağılar $X=[x_1, x_2, \dots, x_n]$. $x_t \in R_k$ gibi sıralı verileri işlemek için kullanılır. $x_t \in R_k$ t zaman adımındaki girdidir. Şekil 5.1. bir RNN hücresini şematik olarak göstermektedir. f doğrusal olmayan bir fonksiyon, h_{t-1} t-1 adımındaki durum, x_t t zamanındaki girdi ve $h(t)$ Denklem 5.1'deki gibi ifade edilir.




Şekil 5.1 : Bir RNN hücresi

$$h_t = f(h_{t-1}, x_t) = f(Uh_{t-1} + Wx_t + b) \quad (5.1)$$

Burada $b \in R^d$, $U \in R^{d \times d}$ and $W \in R^{d \times k}$ bias, recurrent ve input ağırlıklarıdır ve hepsi öğrenilebilir parametrelerdir; n dizi uzunluğu, k girdi boyutu, d gizli boyut ve f sigmoid veya tanh gibi doğrusal olmayan bir fonksiyondur.

LSTM, Hochreiter ve Schmidhuber tarafından RNN'deki gradyan kaybolma problemini çözmek için önerilmiştir[31]. Şekil 5.1'deki RNN hücresinde $h(t)$ 'ye ek olarak, bir LSTM hücresinde t anına kadar ortaya çıkan bilgiyi saklayan bir hafıza birimi $c(t)$ vardır. $c(t)$ hücresinin davranışı üç kapı tarafından belirlenir. Bu kapılar giriş kapısı i_t , çıkış kapısı o_t ve unutma kapısı f_t 'dir. Bu kapılar matematiksel olarak Denklem 5.2, 5.3 ve 5.4'te verilmiştir. Bir LSTM hücresi grafiksel olarak Şekil 5.2'de gösterilmiştir.



Şekil 5.2 : Bir LSTM hücresi

$$i_t = \text{sigmoid}(U_i h_{t-1} + W_i x_t + b_i) \quad (5.2)$$

$$f_t = \text{sigmoid}(U_f h_{t-1} + W_f x_t + b_f) \quad (5.3)$$

$$o_t = \text{sigmoid}(U_o h_{t-1} + W_o x_t + b_o) \quad (5.4)$$

Bu değerler göz önünde bulundurularak Şekil 5.2'de verilen LSTM hücresinin çıkışı Denklem 5.5, 5.6 ve 5.7'ye göre hesaplanır.

$$k_t = \tanh(U_k h_{t-1} + W_k x_t + b_k) \quad (5.5)$$

$$C_t = f_t \times C_{t-1} + i_t \times k_t \quad (5.6)$$


$$h_t = o_t \times \tanh(C_t) \quad (5.7)$$

Burada $b \in \mathbb{R}^d$, $U \in \mathbb{R}^{d \times d}$ and $W \in \mathbb{R}^{d \times k}$ önyargı, tekrarlayan ve giriş ağırlıklarıdır ve $\times$ operatörü eleman-eleman çarpımını belirtir.

Şekil 5.2'deki diyagram bir t adımımda LSTM biriminde gerçekleştirilen işlemleri göstermektedir. Buna göre ilk olarak x_t ve h_{t-1} 'in bir fonksiyonu kullanılarak bir unutma kapısı f_t elde edilir. f_t 'nin değeri 1'e yaklaştığında, bir önceki hafıza hücresi C_{t-1} 'den gelen bilgi ile işlenir. İkinci olarak, $x(t)$ ve $h(t-1)$ 'in bir fonksiyonu olan giriş kapısı $i(t)$ elde edilir ve C_t bellek hücresine eklenir. Son olarak, çıkış kapısı yeni gizli durum h_t 'yi oluşturmak için bellek hücresinden ne alınması gerektiğine karar verir.

5.2. Tasarlanan LSTM Ağı ile Taşlama Yanığının Tesbitinde Kullanılan Metot

Rulmanlarda arıza tespit çalışmalarında derin öğrenme yöntemleri sıklıkla kullanılmaktadır. Bu yöntemler kullanılırken sinyaller veya görüntüler kullanılır. En sık kullanılan sinyaller AE sinyalleri ve titreşim sinyalleridir. AE ve titreşim sinyalleri sıralı veri içermektedir. Literatürde sıralı veriler için LSTM ağlarının başarılı sonuç verdiği belirtilmiştir. Bu yöntemle taşlama yanığı tespit edilirken, sinyaller elde edildikten sonra ön işleminden geçirilir veya geçirilmez, sonra derin öğrenme ağlarına girdi olarak verilir ve ağın bu girdileri sınıflandırması beklenir. Bu çalışmada temel olarak bu süreçler uygulanmıştır. İlk olarak Şekil 2.1'de gösterilen rulman taşlama makinesinden AE sensörleri ile ham veri toplanmıştır. Daha sonra bu ham verilerden belirli büyüklükte parçalar alınarak tasarlanan LSTM ağının girişine uygun formatta matrisler oluşturulmuştur. Bu veriler tasarlanan LSTM ağında sınıflandırılarak ağın başarımları kaydedilmiştir. Bu adımları gösteren akış şeması Şekil 5.3'te gösterilmiştir.



Şekil 5.3 : Tasarlanan LSTM ağıyla taşlama yanığının tesbitinde kullanılan metodun uygulama adımları

Metodun ilk adımında AE verilerinin elde edilmesi gerekmektedir ve Bölüm 2’de bu konu detaylıca açıklanmıştır.

5.2.1. AE Verilerinden entropi ve anlık frekans değerlerinin elde edilmesi ve verilerin ön işleme

5.2.1.1. Anlık frekans

Sinüzoidal bir sinyal veya sinüzoidal bir sinyal kümesi olarak ifade edilebilen sinyaller için frekans iyi tanımlanmış bir niceliktir. Ancak, gerçekte bazı sinyaller sinüzoidal değildir veya sinüzoidal bileşenlerden oluşmaz. Özellikle, durağan olmayan sinyaller sinüzoidal bileşenlere ayrıştırılmaya uygun değildir. Bu tür sinyaller için frekans kavramı yerine, sürecin zamanla değişen doğasını açıklamak için anlık frekans kavramı tanımlanmaktadır[89].

Bu çalışmada LSTM uygulamalarında ham verilerden veri parçaları oluşturulduktan sonra veri parçalarının entropi ve anlık frekans özellikleri çıkartılarak LSTM veri setleri oluşturulmuştur.

5.2.1.2. Spektral entropi

Bir sinyalin spektral entropisi (SE), spektral güç dağılımının bir ölçüsüdür. Kavram, bilgi teorisindeki Shannon entropisine veya bilgi entropisine dayanmaktadır. SE, sinyalin frekans alanındaki normalleştirilmiş güç dağılımını bir olasılık dağılımı olarak ele alır ve Shannon entropisini hesaplar. Bu bağlamda, Shannon entropisi sinyalin spektral entropisidir. Bu özellik, sorun giderme ve teşhiste özellik çıkarımı için yararlı olabilir [90]. SE ayrıca konuşma tanıma ve biyomedikal sinyal işlemede bir özellik olarak yaygın bir şekilde kullanılmaktadır. Spektral entropi denklemleri, bir sinyal için güç spektrumu ve olasılık dağılımı denklemlerinden ortaya çıkar. Bir $x(n)$ sinyali için güç spektrumu $S(m) = |X(m)|^2$ 'dir; burada $X(m)$, $x(n)$ 'nin ayrık Fourier dönüşümüdür. O halde olasılık dağılımı $P(m)$ 'dir (Bkz Denklem 5.8):

$$P(m) = \frac{S(m)}{\sum_i S(i)} \quad (5.8)$$

Spektral Entropi Denklem 5.9'da tarif edilmiştir:

$$H = - \sum_{m=1}^N P(m) \log_2 P(m) \quad (5.9)$$

Normalizasyon denklemi Denklem 5.10 ile ifade edilir:

$$H_n = - \frac{\sum_{m=1}^N P(m) \log_2 P(m)}{\log_2 N} \quad (5.10)$$

Burada N toplam frekans noktalarıdır. Payda, $\log_2 N$, frekans alanında eşit olarak dağıtılmış beyaz gürültünün maksimum spektral entropisini temsil eder. Bir zaman-frekans güç spektrogramı $S(t,f)$ biliniyorsa, olasılık dağılımı Denklem 5.11'deki gibi olur.

$$P(m) = \frac{\sum_t S(t,m)}{\sum_f \sum_t S(t,f)} \quad (5.11)$$

Spektral Entropi halâ Denklem 5.10 daki gibidir:

$$H = - \sum_{m=1}^N P(m) \log_2 P(m) \quad (5.12)$$

Bir zaman-frekans güç spektrogramı $S(t,f)$ verildiğinde anlık spektral entropiyi hesaplamak için, t zamanındaki olasılık dağılımı Denklem 5.13 teki gibi olmaktadır.

$$P(t, m) = \frac{S(t,m)}{\sum_f S(t,f)} \quad (5.13)$$

Yani t zamanındaki spektral entropi Denklem 5.14 ile elde edilir.

$$H(t) = - \sum_{m=1}^N P(t,m) \log_2 P(t,m) \quad (5.14)$$

5.2.2. Verilerin ön işleme

Makine öğrenmesi uygulamalarına benzer şekilde LSTM uygulamaları da veri hazırlama (veri seçimi-özellik çıkarımı), ağ parametrelerinin seçimi ve performans ölçümlerinden oluşmaktadır. LSTM uygulamaları için oluşturulan veri parçaları aşağıdaki gibidir: Hatalı ve normal örneklerden alınan verilerden farklı boyutlardaki veriler (bkz. Tablo 5.1.) seçilerek bir matriste toplanır ve hatalar "HA", normaller ise "NO" olarak etiketlenir. Daha sonra bu hatalı ve normal verilerin anlık frekans ve entropi özellikleri çıkarılır ve bu özellikler ana matrise eklenir. Böylece LSTM ağının eğitimi için kullanılacak veri seti elde edilmiştir.

Tablo 5.1 : LSTM Uygulamaları için hazırlanan veri seti

Veri Seti	Normal Boyut	Hatalı Boyut
Veri Seti 1	4000x[1x16500]	1000x[1x16500]
Veri Seti 2	4500x[1x10000]	1500x[1x10000]
Veri Seti 3	3300x[1x20000]	1000x[1x20000]

5.2.3. LSTM Ağının oluşturulması


İkinci adımda ise yeni bir LSTM ağı tasarlanarak, oluşturulan LSTM ağının hiperparametre seçimleri yapılır ve bu parametrelerle ağ oluşturulur. Oluşturulan ağın parametreleri Tablo 5.2'de verilmiştir.

Tablo 5.2 : LSTM Ağının katman yapısı

Katmanlar	Sayı/Değer
Sequence Input Layer	2
BiLSTM Layer	100
Dropout	0,3
LSTM Layer	80
Dropout	0,3
Fully Connected Layer	2
Softmax Layer	1
Classification Layer	1

5.2.4. LSTM Ağında taşlama yanığı tespiti

Bu aşamada MATLAB'da yazılan kodlar çalıştırılarak sonuçlar elde edilmiştir. LSTM ağı ile yapılan deneylerin sonuçları Tablo 5.3'te verilmiştir. Bu deneye ait karışıklık(konfüzyon) matrisi Şekil 5.4.'te verilmiştir.



Şekil 5.4 : Tasarlanan LSTM ağında yapılan sınıflandırma uygulamasına ait konfüzyon matrisi

Tablo 5.3'te %90,5, %91,33 ve %91,88 doğruuk değerleri elde edilmiştir. Bu değerler ağın iyileştirilmesi adına ümit vermektedir fakat yaygın kabul gören doğruluk değerleri %95 ve üzeri sonuçlardır. Makine öğrenmesi yöntemleri ile elde edilen test doğruluklarının aksine LSTM ağı ile yapılan sınıflandırma doğrulukları eğitim doğruluğu ile benzerlik göstermekte ve yüksek değerler vermektedir. Farklı veri kombinasyonlarında benzer doğruluk değerlerinin elde edildiği de not edilmelidir. İşlem zamanlarının Makine öğrenmesi uygulamalarına kıyasla uzunluğu ağın bir olumsuz yönü olarak gösterilebilir.

Tablo 5.3 : LSTM Ağında yapılan uygulama sonuçları

Veri Seti 1		Veri Seti 2		Veri Seti 3	
Doğruluk (%)	ES	Doğruluk (%)	ES	Doğruluk (%)	ES
91,8	41dk 45s	90,5	13dk	91,33	13dk 17s

BÖLÜM 6. ÖN-EĞİTİMLİ AĞLAR İLE TAŞLAMA YANIĞININ TESPİTİ

Bu bölümde, Ortadoğu Rulman Sanayii ve Ticaret A.Ş. üretim hattındaki bir taşlama tezgâhına yerleştirilen akustik emisyon sensörüyle taşlama tezgâhından elde edilen sinyaller, TF yöntemleri ile görüntülere dönüştürülerek ön eğitilmiş ağlarla sınıflandırılmıştır. Sinyallerin bir kısmı yanık oluşmamış rulman makaralarına, bir kısmı yanık oluşmuş rulman makaralarına aittir. Bu sinyallerden Continuous Wavelet Transform (CWT) ve Hilbert-Huang Transform (HHT) ve Short-Term Fourier Transform(STFT) yöntemleriyle zaman-frekans gösterimleri elde edilmiştir. Daha sonra bu görüntüler, AlexNet, GoogleNet, ResNet-50, SqueezeNet derin öğrenme ağlarında hatalı/normal olarak sınıflandırılmıştır. Sonuç olarak, skalogram görüntülerinin sınıflandırılmasında, SqueezeNet ağı, spektrogram görüntülerinin sınıflandırılmasında GoogleNet ağı ve Hilbert transform görüntülerinin sınıflandırılmasında ise AlexNet ağı başarılı sonuçlar vermiştir. Skalogram görüntülerinin sınıflandırılmasında, bir kez AlexNet, bir kez GoogleNet ve üç kez SqueezeNet ağından olmak üzere beş kez %100 sınıflandırma doğruluğu elde edilmiştir(Bkz. Tablo 6.3). Skalogram görüntülerinin sınıflandırılmasında en yüksek ikinci doğruluk oranı %97,96 ile AlexNet ağına yapılan sınıflandırma sonucunda elde edilmiştir. Spektrogram görüntülerinin sınıflandırılmasında bir kez AlexNet, üç kez GoogleNet ve iki kez SqueezeNet ağından olmak üzere altı farklı veri kombinasyonunda %100 sınıflandırma doğruluğuna ulaşılmıştır. İkinci en yüksek doğruluk oranı %97,96 ile SqueezeNet ağına yapılan sınıflandırmada elde edilmiştir.


6.1. Teorik Arka Plan

Bu bölümde ele alınan çalışmanın teorik arka planında sinyallerden TF görüntüleri elde etme yöntemleri olan CWT, STFT ve HHT zaman-frekans analiz yöntemleri ve evrişimli sinir ağları ve öğrenme aktarması konuları vardır. Bu konulardan TF analiz

yöntemleri Bölüm 3’te ele alınmıştır. Bu nedenle devam eden başlıklarda evrişimli sinir ağları ve öğrenme aktarması konuları ele alınacaktır.

6.1.1. Evrişimli sinir ağları (Convolutional Neural Networks-CNN)

Evrişimli ağlar, katmanlarından en az birinde evrişim işlemi kullanan basit sinir ağlarıdır[33]. Evrişim, bir tür doğrusal işlemidir ve matematiksel olarak Denklem 6.1’de tanımlanmıştır ve Şekil 6.2’de grafiksel bir gösterimi mevcuttur. Bir CNN ağ yapısı temelde evrişim katmanı, pooling katmanı ve tam bağlı katman bileşenlerinden oluşur. Şekil 6.1’de CNN ağlarının genel katman yapısı gösterilmiştir.



Şekil 6.1 : CNN ağ katman yapısı


Tamamen bağlı katman, standart bir ileri beslemeli sinir ağındaki FCL ile aynı şekilde yapılandırılmıştır ve benzer bir işlevi vardır. CNN'nin avantajları, evrişim katmanı (Convolution Layer-CL) ve biriktirme katmanı (Pooling Layer-PL) arasındaki yapısal ve fonksiyonel ayrımlardan kaynaklanmaktadır [9]. CL'lerin bağlı katmanlardan temel farkı, yoğun bağlı katmanların genel özellikleri öğrenmesine karşın, evrişim katmanları yerel özellikleri öğrenirler [91].

Bir CL, çok sayıda öğrenme çekirdeği olarak tanımlanan yapılardan oluşur. Her bir çekirdeğin eğitilebilir bir ağırlığı ve bir önyargısı vardır. Girdi verileri, CL katmanında evrişim işlemine tabi tutulur ve evrişim işleminin sonucu bir aktivasyon fonksiyonuna

beslenir. Bu aktivasyon fonksiyonunun çıkışı CL'in nihai çıktısıdır [92]. Denklem 6.1 evrişim katmanının işlevini matematiksel olarak tanımlar.

$$X_l^n = \sum_{c=1}^C (X_{l-1}^c * W_l^{(c,n)}) + B_l^n \quad (6.1)$$

Bu denklemde $*$ evrişim işlemidir. X_l^n, l . katmandaki n . özellik haritası; $X_{l-1}^c, l-1$. Katmanda giriş veri boyutunun c . Kanalına denk matristir. $W_l^{(c,n)}$, l . katmanda n . filtrenin c . Kanala bağlı ağırlık matrisidir. B_l^n l . katmandaki n . filtrenin bias matrisidir. Şekil 6.2'de evrişim işlemi gösterilmiştir.



Şekil 6.2 : Evrişim İşleminin Gösterimi

CNN'lerde en sık kullanılan aktivasyon fonksiyonu ReLU (Rectified Linear Unit)'dur. Fonksiyona pozitif bir giriş değeri verildiğinde bu değer aynısını, negatif bir giriş değeri verildiğinde ise sıfır döndürür. ReLU, sigmoid veya benzeri işlevlerle karşılaştırıldığında, CNN eğitim sürecini hızlandırır ve yok olan gradyan sorununu ortadan kaldırır [16]. Denklem 6.2'de ReLU işlevi tanımlanır.

$$X_l^n(i,j) = \max(0, X_{l-1}^n(i,j)) \quad (6.2)$$

CNN'lerde genelde CL'den sonra bir PL gelir. PL'nin amacı, önceki katman tarafından oluşturulan özellik haritalarının boyutunu küçültmektir. Evrişimli katmanın ardından,

havuzlama katmanları, gereksiz bilgileri kaldırmak için bir aşağı örnekleme prosedürünü uygular. Ayrıca, giriş boyutu düşürüldüğünden, hesaplama maliyetini azaltır. Denklem 6.3 havuzlama katmanının matematiksel fonksiyonudur.

$$X_l^n(i, j) = \max_{r=i}^{i+R} (\max_{s=j}^{s+J} (X_{l-1}^n(r, s))) \quad (6.3)$$

Bahsi geçen katmanlar çeşitli şekillerde birleştirilerek birçok farklı derin öğrenme yöntemi oluşturulur.

6.2. Öğrenme Aktarması (Transfer Learning-TL)

Öğrenme aktarması, yeni bir sorunu çözmek için büyük veri kümeleriyle önceden eğitilmiş derin öğrenme ağlarını kullanma yaklaşımıdır. Özellikle ağı eğitmek için yeterli veri olmadığında, önceden eğitilmiş bir ağ kullanmak yaygın bir yöntemdir. Bu sayede, hem ağın eğitimi için gereken veri seti ihtiyacı ortadan kalkar, hem de işlem maliyetlerini azalır. Bu ağların eğitiminde kullanılan veri setinin boyutu ve çeşitliliği sayesinde bu ağlar yeni problemlere kolaylıkla uyum sağlar. AlexNet, GoogleNet, ResNet-50 ve SqueezeNet bu çalışmada kullanılan TL ağlarıdır.

Bu ağlar, ImageNet[93] (AlexNet, GoogleNet, ResNet-50 ve SqueezeNet) veya Places365(GoogleNet)[94] veri setleri üzerinde eğitilmiş evrişimli sinir ağlarıdır. ImageNet veri setinde 1000 nesne kategorisi (klavye, fare, kalem ve hayvanlar gibi), Places365 veri setinde ise 365 farklı yer kategorisi (saha, park, pist ve lobi gibi) vardır. Sonuç olarak, bu ağlar birçok görüntü özelliğini öğrenmiştir. Ağlar, 224x224 (GoogleNet, ResNet-50) veya 227x227 (SqueezeNet ve AlexNet) boyutlarındaki görüntüleri kabul eder[95].

AlexNet ağ mimarisi Alex Krizhevsky tarafından tasarlandı ve 2012 yılında tanıtıldı. ImageNet sınıflandırma probleminin önceki son teknoloji çözümlerinden daha iyi performans gösterdi. Evrişim sürecinde GPU'dan yararlandı. Böylece, ağı daha hızlı ve daha verimli hale getirdi[96].

GoogleNet ağ mimarisi, Szegedy ve arkadaşlarının çalışmalarından ilhamla geliştirildi [97]. VGG-19'dan daha az parametresi varken, daha iyi performans göstermiştir. Bu ağda temel yaklaşım hem derinlik hem de genişlik açısından ağın boyutunu artırmaktır.

Böylece ağın öğrenme kapasitesinin artacağı hesaplanmıştır. Bununla birlikte bu durum önemli ölçüde işlem maliyeti oluşturmaktadır.

ResNet ağı da AlexNet ağı gibi ImageNet veri seti üzerinde geliştirilmiştir. VGG-19'dan sekiz kat daha derin bir ağıdır. Buna karşın daha az karmaşıktır. Derinliğinin bir sonucu olarak ortaya çıkan yaygın sorunlar, bozulma ve kaybolan gradyanlardır (doğruluk bir noktada doyuma ulaşır ve ardından hızla düşer). ResNet, üst üste istiflenmiş katmanlardan oluşur. Bu tasarım, girişi doğrudan çıkışa bağlamak için her katmanda bir kısayol kullanılmasıyla diğer ağlardan farklılaşır[98].

Squeeze Net, ImageNet veri tabanındaki bir milyondan fazla görüntü üzerinde eğitilmiş bir ağıdır. 68 katmandan oluşur. Önceden eğitilmiş ağ, görüntüleri 1000 nesne kategorisine sınıflandırabilir. Sonuç olarak, ağ, çok çeşitli görüntüler için zengin özellik gösterimlerini öğrenmiştir[99]. Tablo 6.1'de ön eğitilmiş ağların temel katmanları verilmiştir.





Tablo 6.1. Ön-eğitilmiş ağların katman yapısı

TL Nets	AlexNet Layers	Number	GoogleNet Layers	Number	ResNet-50 Layers	Number	SqueezeNet Layers	Number
	1*1InputImage Layer	1	1*1InputImage Layer	1	1*1InputImage Layer	1	1*1Imageinput Layer	1
	1*1Convolutional2D Layer	2	1*1Convolutional2D Layer	57	1*1Convolutional2D Layer	53	1*1Convolutional2D Layer	26
	1*1ReLU Layer	7	1*1ReLU Layer	57	1*1ReLU Layer	49	1*1ReLU Layer	26
	1*1MaxPooling2D Layer	3	1*1MaxPooling2D Layer	13	1*1MaxPooling2D Layer	1	1*1MaxPooling2D Layer	3
	1*1CrossChannelNormaliza tion Layer	2	1*1CrossChannelNormaliz ation Layer	2	1*1Addition Layer	16	1*1DepthConcetenations Layers	8
	1*1Grouped Convolutional2D Layers	3	1*1DepthConcetenations Layers	9	1*1Batch Normalization Layers	53	1*1GlobalAveragePoolin g2D Layer	1
Layers	1*1Dropout Layer	2	1*1GlobalAveragePooling 2D Layer	1	1*1GlobalAveragePoolin g2D Layer	1	1*1Dropout Layer	1
	1*1FullyConnected Layer	3	1*1Dropout Layer	1	1*1FullyConnected Layer	1	1*1SoftMax Layer	1
	1*1SoftMax Layer	1	1*1FullyConnected Layer	1	1*1SoftMax Layer	1	1*1ClassificationOutput Layer	1
	1*1ClassificationOutput Layer	1	1*1SoftMax Layer	1	1*1ClassificationOutput Layer	1		
			1*1ClassificationOutput Layer	1				

6.3. Ön Eğitimli Ağlarda Taşlama Yanığının Tespiti

6.3.1. Metot

Rulmanlarda hata tespiti için yapay zeka yöntemleri kullanılırken hatalı ve normal rulman örneklerinden genellikle, titreşim ve AE sensörleriyle sinyaller alınır. Bu sinyallerden uygun örneklem seçilir. Bu seçilen örnek sinyaller için genelde iki seçenek vardır; ya ön işlemleriz olarak makine öğrenmesi ve derin öğrenme yöntemleriyle sınıflandırılır ya da bazı sinyal işleme teknikleriyle işlenerek özellik çıkarımı yapıldıktan sonra sınıflandırılır. Yani işlem adımları temelde 4 adımdır: Veri toplama, veri seçme, özellik çıkarımı ve sınıflandırma. Bu çalışmada da temel olarak bu işlemler uygulanmıştır. İlk olarak Şekil 2.1'de gösterilen rulman taşlama makinesinden (Toyo 11LA88) AE sensörü (Kistler 8152C1050500) ile ham veriler toplanmıştır. Daha sonra bu ham verilerden başlık 6.3.2'de verilen kurallara göre AMP(Aynı Makine Parametreleri)-VS1(Veri Seti 1), VS2, VS3 ve FMP(Farklı Makine Parametreleri)-VS1, VS2, VS3 veri seti oluşturulmuştur. Üçüncü adımda bu 1 boyutlu sinyal veri setinden CWT, STFT, HHT yöntemleriyle 2 boyutlu sırasıyla skalogram, spektrogram ve Hilbert spektrum görüntüleri elde edilmiştir. Daha sonra bu görüntüler ön eğitimli ağlarda ve tez kapsamında oluşturulan Bölüm 7'de açıklanan 2D-CNN ağında sınıflandırılmıştır. Böylece hatalı ve normal numunelere ait görüntüler tespit edilmiş olur. Bu işlem adımları Şekil 6.3'te gösterilmektedir.



Şekil 6.3 : Rulmanlarda taşlama yanığı tespiti işlem adımları

6.3.2. Ön eğitimli ağlarda ve tasarlanan 2D-CNN ağında kullanılan veri setinin oluşturulması

Veriler bilgisayara aktarıldıktan sonra sınıflandırma problemine uygun olarak veri seçimi yapılmıştır. Şekil 6.3'ün 2. Adımı bu işlemi göstermektedir. Veriler Aynı Makine Parametreleri ile işlenmiş parçalara ait olan ve Farklı Makine Parametreleri ile işlenmiş parçalara ait olan sinyallerden sıralı veri seçimi yöntemi ile oluşturulmuştur. AMP ile işlenmiş parçalara ait sinyallerden veri seçimi başlık 4.2.1'de detaylıca açıklanmıştır. FMP ile işlenmiş rulman parçalarına ait sinyallerden veri seçimi ise şu şekilde yapılmıştır:

FMP-Veri Seti1, Veri Seti2, Veri Seti3: Farklı işleme parametreleri ile işlenmiş normal rulman makarası numunelerinin verilerinden 1x65536 boyutlarında sıralı olarak 81 vektör alınarak bir matris halinde birleştirilir. Bu matrisin boyutu 81x65536'dır. Aynı şekilde, farklı işleme parametreleri ile işlenen hatalı rulman makarası verilerine ait 1x65536 boyutlarındaki diğer 81 vektör alınır ve bir matriste birleştirilir. Bu matrisin boyutu 81x65536'dır. Bu iki matris daha sonra tek bir matriste birleştirilerek 162x65536 boyutunda bir matris oluşturulmuştur. Bu matris FMP-VS1 olarak adlandırılmıştır. Aynı şekilde, FMP-VS2 90x65536 normal veri matrisinin birleştirilmesiyle oluşturulmuştur farklı işleme parametreleri ve 72x65536 hata veri matrisi ile işlenmiştir. FMP-VS3 ise 126x65536 normal veri matrisi ve 36x65536 boyutundaki hatalı veri matrisinin birleştirilmesiyle oluşturulmuştur. Tablo 6.2 ham sinyallerden veri seçimi yöntemi ile elde edilmiş veri setini göstermektedir.

Tablo 6.2 : Ön eğitimli ağlarda ve 2D-CNN ağında kullanılan veri seti

Veri Setleri	Boyut	Hatalı	Normal
AMP-Veri Seti 1	162x65536	81x65536	81x65536
AMP- Veri Seti 2	162x65536	70x65536	92x65536
AMP- Veri Seti 3	162x65536	36x65536	126x65536
FMP- Veri Seti 1	162x65536	81x65536	81x65536
FMP- Veri Seti 2	162x65536	70x65536	92x65536
FMP- Veri Seti 3	162x65536	36x65536	126x65536

6.3.3. CWT, STFT ve HHT ile TF Görüntülerinin elde edilmesi

Sinyaller bilgisayara kaydedildikten sonra sinyallerin ön işleme ve sınıflandırma adımları MATLAB'da gerçekleştirilmiştir. MATLAB'ın çalıştırıldığı bilgisayarın özellikleri şöyledir; Intel (R) Core (TM) i5-5200U, CPU 2,20 GHz, RAM 8,00 GB.

Daha önce tanımlandığı gibi skalogram, bir sinyalin CWT katsayılarının mutlak değeridir. Sinyallerden zaman-frekans gösterimlerini çıkarmak için CWT hesaplanması gerekir. Sinyal hazırlama aşamasından sonra, MATLAB'da CWT hesaplanırken kullanılan bir filtre bankası fonksiyonu (*cwtfILTERbank*) aracılığıyla sinyallerden skalogram görüntüleri elde edilmiştir. *CwtfILTERbank* fonksiyonunun özellikleri şunlardır: Analitik Mors (3,60) dalgacı, filtre bankasının varsayılan dalgacıdır. *CwtfILTERbank*'ta sinyal uzunluğu 1000, örnekleme frekansı 128 Hz ve "voices per octav" 12'dir. Bu aşamada bu özelliklerdeki bir *cwtfILTERbank* fonksiyonu ile CWT yardımıyla skalogramlar oluşturulur.

Zaman içinde değişen sinyallerin frekans değişimini analiz etmek için kullanılan yöntemlerden biri de Kısa Zamanlı Fourier Dönüşümüdür (STFT). STFT, sinyalin zaman içindeki frekans değişimini gösteren spektrogram görüntülerini elde etmek için kullanılır. STFT hesaplandıktan sonra büyüklüğünün karesi hesaplanır ve böylece sinyalin spektrogramı elde edilir.

Hilbert-Huang dönüşümü, durağan olmayan ve doğrusal olmayan verilerin zaman-frekans analizini gerçekleştirmek için kullanışlıdır. Hilbert-Huang prosedürü MATLAB'da aşağıdaki adımlarda gerçekleşir:

1. *emd* fonksiyonu *x* veri kümesini belirli sayıda *imf*'ye (intrinsic mode functions) ayırır.
2. Analitik sinyali hesaplamak için *hilbert* fonksiyonu çalıştırılır.
3. *imfinse* fonksiyonuyla anlık enerji ve *imfinsf* ile anlık frekans değerleri hesaplanır.

Son olarak *hht* fonksiyonu çalıştırılırsa, sinyalin enerjisini zamanın ve frekansın bir fonksiyonu olarak çizdirir.

Şekil 6.3'ün 3. Adımı bu aşamaları ifade eder. Bu aşamada elimizde normal ve hatalı sinyallerin 224x224x3 ve 227x227x3 boyutunda skalogram, spektrogram ve hilbert

spektrum görüntülerinin sınıflandırılması ön eğitilmiş ağlarda yapılmıştır. Tablo 6.3.'te 1-12 arasında numaralandırılmış uygulamaların veri kombinasyonları gösterilmiştir. Buna göre görüntüler 3 farklı kombinasyonda (126 NO-36HA, 90NO-72HA ve 81NO-81HA) gruplandırılmıştır. Bu gruplar arasından %80 eğitim-%20 test olmak üzere rastgele 2 grup oluşturulmuştur. İlâveten eğitim ve test verisi oluştururken her seferinde aynı verileri test verisi olarak kullanıp sınıflandırma başarımları ölçülmüştür. Sonuçlarda önemli değişikliğe yol açmadığından, sınıflandırma başarımları test verisinin rastgele seçildiği durumlarda karşılaştırılmıştır. Ayrıca hatalı ve normal veriler önce aynı makine parametreleri ile işlenen veriler arasından, ardından farklı makine parametreleri arasından seçilmiştir (Bkz. Tablo 6.2). Bu verilerin Tablo 6.2'de verilen AMP-VS1, VS2, VS3 ve FMP-VS1, VS2, VS3 veri setinden elde edilen görüntü seti olduğu akılda tutulmalıdır.

Tablo 6.3 : Ön eğitilmiş ağlarla ve 2D-CNN ağıyla yapılan uygulamalarında kullanılan CWT, STFT, HHT görüntü verilerinin kombinasyonları

Uygulamalar	Farklı Makine Parametreleri	Aynı Makine Parametreleri	Normal Veri (Adet)	Hatalı Veri (Adet)	Eğitim Verisi (%)	Doğrulama Verisi (%)
1	X	✓	81	81	80	20
2	X	✓	81	81	70	30
3	X	✓	90	72	80	20
4	X	✓	90	72	70	30
5	X	✓	126	36	80	20
6	X	✓	126	36	70	30
7	✓	X	81	81	80	20
8	✓	X	81	81	70	30
9	✓	X	90	72	80	20
10	✓	X	90	72	70	30
11	✓	X	126	36	80	20
12	✓	X	126	36	70	30

6.3.4. Ön eğitilmiş ağların parametreleri ve ön eğitilmiş ağlarda sınıflandırma

Ön eğitilmiş ağlar ImageNet (1000 farklı kategorideki görüntü) veya Place 365 veri setiyle eğitilmişlerdir. Sınıf sayısı ve görüntü içeriği bakımından bu veri setlerine benzeyen veri setlerinin sınıflandırılmasında ön eğitilmiş ağların yeniden eğitilip son katmanlarının değiştirilmesine gerek olmayabilir. Fakat ImageNet veya Place365 veri setine benzemeyen veri setleri için ön eğitilmiş ağların yeniden eğitilmesi ve sınıf sayısına göre sınıflandırma ve çıkış katmanlarının değiştirilmesi gerekmektedir. Bu iki katman, önceki katmanlarda çıkarılan özelliklerin sınıf olasılıkları, bir kayıp değeri ve tahmin edilen etiketler hakkında bilgi içerirler. Bu iki katman, RGB Skalogram, spektrogram ve Hilbert spektrum görüntülerini sınıflandırmak üzere, yeni veriye uyarlanmış yeni katmanlarla değiştirilir. Örneğin, Google Net'te, 'loss3-sınıflandırıcı' tam bağlantılı katman yeni bir katmanla değiştirildi. Ayrıca drop out katmanının varsayılan olasılık değeri 0.5 iken, olasılık değeri 0.6 olan yeni bir katmanla değiştirildi. Tablo 6.1 ön eğitilmiş ağların katman yapısını, Tablo 6.4 ağ parametrelerini göstermektedir. İlgili ağların katman yapısında bahsi geçen değişiklikler yapıp ağ parametreleri Tablo 6.4'e göre ayarlandıktan sonra Tablo 6.3'teki veri kombinasyonlarına göre her bir ağ da, skalogram, spektrogram ve Hilbert spektrum görüntüleri sınıflandırılır. Öğrenme aktarması ağlarında yapılan sınıflandırma işlemi; 3 farklı görüntü kümesinde, 4 farklı ağda ve 12 farklı veri kombinasyonunda olmak üzere toplam 144 farklı uygulama yaparak gerçekleştirilmiştir. Bu uygulamaların sonuçları Tablo 6.5'te verilmiştir.

Tablo 6.4 : Ön eğitimli ağların ağ parametreleri

Alex Net(Parametre/Değer)		Google Net(Parametre/Değer)		ResNet-50(Parametre/Değer)		Squeeze Net(Parametre/Değer)	
Dropout Katmanlarının Olasılık Değeri	0.5	Dropout Katmanlarının Olasılık Değeri	0.6			Dropout Katmanlarının Olasılık Değeri	0.6
Mini Batch Boyutu	10	Mini Batch Boyutu	15	Mini Batch Boyutu	20	Mini Batch Boyutu	10
Max Epoh	6	Max Epoh	20	Max Epoh	20	Max Epoh	19
Giriş Öğrenme Oranı	0.0001	Giriş Öğrenme Oranı	0.0001	Giriş Öğrenme Oranı	0.0001	Giriş Öğrenme Oranı	0.0003
Loss Fonksiyonu	Crossentropyex	Loss Fonksiyonu	Crossentropyex	Loss Fonksiyonu	Crossentropyex	Loss Fonksiyonu	Crossentropyex
İşlem Donanımı	CPU	İşlem Donanımı	CPU	İşlem Donanımı	CPU	İşlem Donanımı	CPU
Ölçüm Kriteri	Doğruluk	Ölçüm Kriteri	Doğruluk	Ölçüm Kriteri	Accuracy	Ölçüm Kriteri	Doğruluk

Tablo 6.5 : Ön eğitilmiş ağırlarla yapılan uygulamaların sınıflandırma başarımları

T-F R	Continuous Wavelet Transform				Short-Term Fourier Transform				Hilbert-Huang Transform			
Ağlar	Alex Net	Google Net	ResNet-50	Squeeze Net	Alex Net	Google Net	ResNet-50	Squeeze Net	Alex Net	Google Net	ResNet-50	Squeeze Net
Uygulamalar	Doğruluk (%)				Doğruluk (%)				Doğruluk (%)			
1	100	100	87.5	90.62	96.88	100	84.38	100	50	43.75	53.13	53.13
2	97.92	97.5	81.25	100	83.33	93.75	79.17	95.83	50	52.08	60.42	54.17
3	93.75	90.63	81.25	93.75	96.88	93.75	87.5	100	46.88	43.75	65.63	62.5
4	97.96	95	85.75	100	95.92	95.92	95.92	97.96	57.14	48.98	55.1	61.22
5	93.75	93.75	87.5	96.88	100	100	87.5	96.88	78.13	78.13	71.88	75
6	89.80	95	83.67	100	93.88	100	87.76	77.55	67.35	77.55	75.51	77.55
7	50	71.88	62.5	53.12	46.88	56.25	40.63	40.63	46.88	62.5	46.88	40.63
8	47.92	70	47.92	54.17	52.08	62.5	43.75	45.83	54.17	52.08	52.08	45.83
9	43.75	75	62.5	50	59.38	68.75	56.25	56.25	65.63	59.38	34.38	56.25
10	46.94	72.5	42.86	53.06	57.14	65.31	63.27	55.1	53.06	53.06	34.38	55.10
11	78.13	75	78.13	78.12	78.13	78.13	78.13	78.13	81.25	78.13	78.13	78.13
12	77.55	77.5	77.55	77.55	77.55	77.55	77.55	77.55	77.55	77.55	79.59	77.55

Tablo 6.5'te, (her satırda) o uygulamanın en başarılı sonucu yeşil renkle işaretlenmiştir. En düşük başarıya sahip sonuç ise kırmızı ile işaretlenmiştir.

Tablo 6.3 ve Tablo 6.5'e birlikte bakıldığında, her bir uygulamanın açıklaması aşağıdaki gibidir:

İlk deneyde, aynı makine parametreleri ile işlenmiş rulman parçalarından toplanan akustik emisyon sinyalleri kullanılmıştır. Bu sinyallerden TF yöntemleri ile 162 adet, skalogram görüntüleri(CWT ile), spektrogram görüntüleri(STFT ile) ve Hilbert spektrum(HHT ile) görüntüleri elde edilmiştir. Bu görüntülerin 81 tanesi hatalı, 81 tanesi ise normal rulman parçalarına aittir. Bu 162 görüntünün %80'i eğitim verisi, %20'si ise test verisi olarak kullanılmıştır.

İkinci deneyde, aynı makine parametreleri ile işlenmiş rulman parçalarından toplanan akustik emisyon sinyalleri kullanılmıştır. Bu sinyallerden TF yöntemleri ile 162 adet, skalogram görüntüleri(CWT ile), spektrogram görüntüleri(STFT ile) ve Hilbert spektrum(HHT ile) görüntüleri elde edilmiştir. Bu görüntülerin 81 tanesi hatalı, 81 tanesi ise normal rulman parçalarına aittir. Bu 162 görüntünün %70'i eğitim verisi, %30'u ise test verisi olarak kullanılmıştır.

Tablo 6.5'te gösterildiği gibi, ilk 6 uygulama aynı makine parametreleri ile işlenmiş rulman parçalarından toplanan sinyallerin TF görüntüleri ile yapılmıştır. 7'den 12'ye kadar olan deneyler farklı makine parametrelerinden elde edilen verilerle gerçekleştirilmiştir. Buna göre, skalogram ve spektrogram görüntülerinin sınıflandırılmasında 1-6 uygulamaları literatürde kabul gören doğruluk değerini (%95 ve üstü) aşmıştır. Hilbert spektrum görüntülerinin sınıflandırılmasında ise 7-12 uygulamalarının başarımleri, 1-6 uygulamalarından daha büyük olmasına karşın literatürde kabul gören doğruluk değerlerine yaklaşamamıştır.

Tablo 6.5, 144 deneyin sınıflandırma performansını göstermektedir. Bu deneylerde 3 farklı TF yöntemi ile elde edilen görüntüler 4 farklı TL ağında sınıflandırılmıştır. Örneğin CWT ile elde edilen görüntülerin sınıflandırılmasında 1. Uygulama koşullarında en yüksek performans Alexnet ve Google Net'te, STFT ile elde edilen görüntülerin sınıflandırılmasında ise Google Net ve Squeeze Net'te elde edilmiştir. Ve her satırdaki en yüksek performanslar yeşil, en düşük başarılar ise kırmızı ile işaretlenmiştir. Tablo 6.4'teki diğer satırlar da buna göre okunabilir.

Deneylerden elde edilen en yüksek performanslar %95,92 -%100 arasında değişmektedir. Bu oranlar literatürde bir sınıflandırma probleminin çözüldüğüne karar verilen %95 ve üstü sonuçlara göre ORS taşıma veri setinde taşıma yanığının tespitinin TL ağlarıyla yapılabileceğini göstermektedir[91].

Bunun yanısıra farklı başarımların metriklerine bakıldığında da ağların sınıfları ayırma başarımları farklı şekillerde de değerlendirilebilir. Bu metriklerden başlıcaları kesinlik, duyarlılık, özgüllük ve F1 skorudur. Bu metrikler Denklem 6.1, 6.2, 6.3 ve 6.4'te tanımlanmıştır.

$$\text{Duyarlılık (Sensitivity, Recall)} = \frac{TP}{TP + FN} \quad (6.1)$$

$$\text{Özgüllük (Specivicity)} = \frac{TN}{TN + FP} \quad (6.2)$$

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (6.3)$$

$$\text{F1 Skor} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6.4)$$

Bu denklemlerde True Positive(TP), doğru tahmin edilen “NO” değerleri, True Negative(TN), doğru tahmin edilen “HA” değerlerini, False Positive yanlış tahmin edilen “NO” değerlerini ve False Negative(FN) ise yanlış tahmin edilen “HA” değerlerini temsil etmektedir.

Buna göre duyarlılık; “NO” yani hatasız olarak tahmin etmemiz gereken verilerin ne kadarını “NO” olarak tahmin ettiğimizi gösteren bir metriktir. Kesinlik (precision), “NO” olarak tahmin ettiğimiz verilerin ne kadarının gerçekten “NO” olduğunu ifade etmektedir. Özgüllük; “HA” yani hatalı olarak tahmin edilen “NO” yani normal verilerin bütün hatalı tahminlere oranını ifade etmektedir. F1 skor ise bir testin doğruluğunun bir ölçüsüdür, kesinlik ile duyarlılığın harmonik ortalamasıdır.


Tablo 6.6’da CWT ile elde edilen skalogram görüntülerinin sınıflandırılmasında başarılı sonuçlar veren Squeeze Net ağının en iyi ve en kötü (Literatüre göre kabul edilebilir sonuçların elde edildiği 1-6 uygulamalarına arasında) sınıflandırma başarımlarını gösterdiği uygulamaların başarımların metrikleri gösterilmektedir.

Tablo 6.6. SqueezeNet ağında skalogram görüntülerinin sınıflandırılmasına ait başarımların metrikleri


SqueezeNet					
CWT Maximum (Uygulama 2)			CWT Minimum (Uygulama 1)		
	Normal	Hatalı		Normal	Hatalı
TP	24	24	TP	13	16
FP	0	0	FP	0	3
FN	0	0	FN	3	0
TN	24	24	TN	16	13
Kesinlik	1	1	Kesinlik	1	0.8421
Duyarlılık	1	1	Duyarlılık	0.8125	1
Özgüllük	1	1	Özgüllük	1	0.8125
Doğruluk	1	1	Doğruluk	0.9062	0.9062
F1-Skor	1	1	F1-Skor	0.8965	0.9143

Squeeze Net ağında yapılan 2 nolu uygulamanın “Training Progress” grafiği ve karışıklık matrisi ise Şekil 6.4’te verilmektedir.

a)




b)




Şekil 6.4 : a) Uygulama 2 (SqueezeNet) eğitim süreci b) bu uygulamanın karışıklık matrisi

Squeeze Net ağında yapılan 1 nolu uygulamanın “Training Progress” grafiği ve karışıklık matrisi ise Şekil 6.5’te verilmektedir.

a)



b)




Şekil 6.5 : a) Uygulama 1 (SqueezeNet) eğitim süreci b) bu uygulamanın karışıklık matrisi

Tablo 6.7’de STFT ile elde edilen spektrogram görüntülerinin sınıflandırılmasında başarılı sonuçlar veren GoogleNet ağının en iyi ve en kötü (Literatüre göre kabul edilebilir sonuçların elde edildiği 1-6 uygulamalarına arasında) sınıflandırma başarımını gösterdiği uygulamaların başarım metrikleri gösterilmektedir.

Tablo 6.7 : GoogleNet ağında spektrogram görüntülerinin sınıflandırılmasına ait başarımlar metrikleri


GoogleNet					
STFT Maximum(Uygulama 1)			STFT Minimum(Uygulama 2)		
	Normal	Hatalı		Normal	Hatalı
TP	16	16	TP	23	22
FP	0	0	FP	2	1
FN	0	0	FN	1	2
TN	16	16	TN	22	23
Kesinlik	1	1	Kesinlik	0.9200	0.9565
Duyarlılık	1	1	Duyarlılık	0.9583	0.9167
Özgüllük	1	1	Özgüllük	0.9167	0.9583
Doğruluk	1	1	Doğruluk	0.9375	0.9375
F1-Skor	1	1	F1-Skor	0.9387	0.9361

Google Net ağında yapılan 1 nolu uygulamanın “Training Progress” grafiği Şekil 6.6’da verilmektedir.



Şekil 6.6 : GoogleNet uygulama 1 eğitim süreci

Google Net ağında yapılan 2 nolu uygulamanın “Training Progress” grafiği Şekil 6.7’de verilmektedir.



Şekil 6.7 : GoogleNet uygulama 2 eğitim süreci

Hilbert spektrumu görüntülerinin sınıflandırılmasında, literatürde kabul edilebilir doğruluk değerlerine ulaşılmadığından diğer başarımların metriklerinin ölçülmemiştir.

BÖLÜM 7. TASARLANAN 2D-CNN AĞI İLE TAŞLAMA YANIĞININ TESPİTİ

7.1. Tasarlanan 2D-CNN Ağının Yapısı ve Ağ Parametreleri

Literatürde CNN kullanarak rulmanlarda hata tespiti yapan çalışmalar incelendiğinde, tasarlanan CNN ağlarının 2-6 evrişimli katman ve 6×6 , 5×5 , 3×3 ve 2×2 gibi küçük filtreler kullandığı göze çarpmaktadır[100, 101, 102]. 11×11 gibi nispeten daha büyük filtreler daha seyrek kullanılmaktadır[103]. [16]'da aktarıldığına göre, evrişimli katmanların sayısını artırmak, CNN ağının giriş görüntüsünden daha karmaşık özellikleri tanımasını sağlamaktadır. Keçeli ve arkadaşlarının çalışmasına göre, evrişimli katmanlarda küçük filtrelerin kullanılması, CNN modelinin girdi görüntüsünden ince ayrıntıları yakalamasına izin verirken, büyük filtrelerin kullanılması girdi görüntüsündeki ayrıntıları dışarı bırakarak temel özelliklere odaklanmasını sağlar[104]. Bu tez kapsamında tasarlanan 2D-CNN mimarisinin detayları Tablo 7.1'de gösterilmektedir. Bu ağ mimarisi oluşturulurken literatürde skalogram, spektrogram ve Hilbert spektrum görüntülerini sınıflandırırken kullanılan ağ örnekleri incelenmiş ve CNN ağ mimarisinin temel katmanları kullanılarak örnek bir ağ geliştirilmiştir. Sonra bu örnek ağ üzerinden skalogram görüntülerine, spektrogram görüntülerine ve Hilbert spektrum görüntülerine göre ayrı ayrı ağ parametreleri ayarlanarak başarımleri ölçülmüştür. Her 3 görüntü çeşidini en iyi sınıflandıracak ortak bir ağ oluşturulmasa da, maksimum doğruluğun elde edildiği ağ mimarisi oluşturulmuştur. Bu ağ mimarisinin katman yapısı ve parametreleri ilerleyen bölümlerde ele alınmıştır.

Tablo 7.1 : 2D-CNN Ağının katman yapısı ve katman özellikleri

Katmanlar	Katman Özellikleri
Giriş	Skalogram Görüntüleri(224×224×3), Hilbert Spektrogram Görüntüleri(224×224×3), Spektrogram Spektrum Görüntüleri(224×224×3)
C1	Conv2D(32, 6×6)
BN1	Batch Normalization()
ReLU	
P1	maxPooling2D(2,2)
C2	Conv2D(64, 6×6)
BN2	Batch Normalization()
ReLU	
P2	maxPooling2D(2,2)
C3	Conv2D(128, 3×3)
BN3	Batch Normalization()
ReLU	
DO	0,2
FC	
SM	
Çıkış	

Taşıma yanığı sinyallerinden elde edilen skalogram, spektrogram ve Hilbert spektrumu görüntülerini sınıflandırmak için Tablo 6.3'teki veri kombinasyonları kullanılmıştır. Ağın eğitim parametreleri ise Tablo 7.2'de verilmiştir.

Tablo 7.2 : 2D-CNN Ağının eğitim parametreleri

Eğitim Parametreleri	Eğitim Seçenekleri/Değerleri
Eğitim Algoritması	SGDM (Stochastic Gradient Descent with Momentum)
Max Epoch	15
Giriş Öğrenme Oranı	0,0001

7.2. 2D-CNN Ağıyla Taşıma Yanığının Tespiti

Tablo 7.3'te 2D-CNN ağında yapılan sınıflandırma deneylerinin doğruluk başarımlarına göre sonuçları sunulmuştur. Yeşil renk o deneydeki en yüksek doğruluğu, kırmızı renk ise o deneydeki en düşük doğruluğu işaret etmektedir.

Tablo 6.3'te gösterildiği gibi, ilk 6 uygulama aynı makine parametreleri ile işlenmiş rulman parçalarından toplanan sinyallerin TF görüntüleri ile yapılmıştır. 7'den 12'ye

kadar olan deneyler farklı makine parametrelerinden elde edilen verilerle gerçekleştirilmiştir.

Tablo 7.3 : 2D-CNN ağıyla yapılan uygulamaların sonuçları

Ağ: 2D-CNN			
T-F Görüntüleri	Skalogram (CWT)	Spektrogram (STFT)	Hilbert Spektrum(HHT)
Uygulamalar	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)
1	100	100	43,75
2	95,83	50	37,5
3	100	96,88	50
4	96,88	71,43	59,18
5	93,75	87,5	78,12
6	83,67	77,55	73,47
7	50	43,75	40,62
8	50	62,5	45,83
9	56,25	50	53,12
10	44,90	57,14	53,06
11	78,12	79,41	78,12
12	77,55	76,92	77,55

Tablo 7.3'teki sonuçlara bakıldığında literatürde bir sınıflandırma probleminin çözüldüğünü Kabul eden başarımlar oranı olan %95 ve üstü değerlerin elde edildiği görülmektedir. Bu değerler skalogram ve spektrogram görüntülerinin sınıflandırılmasından elde edilmiştir. Bu değerler skalogram görüntüleri için uygulama 1'de %100, uygulama 4'te %96,88 dir. Spektrogram görüntüleri için ise uygulama 1'de %100 ve uygulama 3 için %96,88 olarak ölçülmüştür. Hilbert spectrum görüntülerinin sınıflandırılmasında ise literatürde Kabul gören doğruluk değerleri elde edilememiştir. Her 3 görüntü türünün sınıflandırılmaları karşılaştırılacak olursa, her bir very kombinasyonunda 3 ayrı görüntü türünün sınıflandırılmasına yani Tablo 7.3'teki her bir satıra bakacak olursak skalogram görüntülerinin sınıflandırma başarımları bir çok uygulamada daha yüksektir. Her satırdaki yeşil renkler bu durumu göstermektedir. Skalogram görüntülerinin sınıflandırma doğrulukları 1-6 (Bkz Tablo 6.3) very kombinasyonunda, yani aynı makine parametrelerinden elde edilen sinyallerden oluşturulan görüntülerin sınıflandırılmasında daha yüksektir. Bu durum TL ağıyla yapılan sınıflandırmada ortaya çıkan sonucu teyit etmektedir. Bu konuda yine TL


ağlarındaki duruma benzer şekilde, Hilbert spektrum görüntülerinde ise 7-12 uygulamalarının doğrulukları daha yüksektir. İşleme süreci izlenmesine dönük çalışmalar için bu durum yol gösterici olabilir.

Tablo 7.3'te sınıflandırma doğruluğu ölçüm metriğine göre öne çıkan skalogram görüntüleri sınıflandırma uygulamalarının kesinlik, duyarlılık, özgüllük ve F1 skor ölçütlerine göre başarımları verilmiştir. Tablodaki değerler 1-6 uygulamalarından minimum ve maksimum doğruluğun elde edildiği uygulama 1 ve uygulama 6'ya aittir.

Tablo 7.4 : 2D-CNN ağında skalogram görüntülerinin sınıflandırılmasına ait başarımlar metrikleri

2D-CNN					
CWT Maksimum(Uygulama 1)			CWT Minimum(Uygulama 6)		
	Normal	Hatalı		Normal	Hatalı
TP	16	16	TP	3	38
FP	0	0	FP	0	8
FN	0	0	FN	8	0
TN	16	16	TN	38	3
Kesinlik	1	1	Kesinlik	1	0.8260
Duyarlılık	1	1	Duyarlılık	0.2727	1
Özgüllük	1	1	Özgüllük	1	0.2727
Doğruluk	1	1	Doğruluk	0.8367	0.8367
F1-Skor	1	1	F1-Skor	0.4286	0.9048

2D-CNN ağında yapılan 1 nolu uygulamanın “Training Progress” grafiği Şekil 7.1’de verilmektedir.



Şekil 7.1 : 2D-CNN ağında skalogram görüntülerinin sınıflandırılması uygulama 1 eğitim süreci

BÖLÜM 8. SONUÇLAR VE DEĞERLENDİRMELER

Bu bölümde, Bölüm 4-5-6’da yapılan uygulamaların sonuçları ele alınacaktır.

8.1. ML Uygulamaları ve LSTM Uygulamalarına İlişkin Çıkarımlar

Bu tez çalışmasında yapılan farklı deneyleri, makine öğrenme yöntemlerini ve çalışma kapsamında oluşturulan LSTM derin öğrenme ağını karşılaştırmak mümkündür. Benzer şekilde K-NN ve SVM makine öğrenme yöntemleri de karşılaştırılabilir. Yine farklı K-NN yöntemlerini ve farklı SVM yöntemlerini kendi içlerinde karşılaştırmak mümkündür (Bkz. Tablo 4.2 ve Tablo 5.3).

Bölüm 4 ve Bölüm 5’te verilen uygulama sonuçlarına bakacak olursak çalışma ile ilgili aşağıdaki sonuçlara ulaşmak mümkündür:

1. Rulmanlarda taşıma yanık hatasının belirlenmesinde bu çalışma kapsamında uygulanan yöntemler arasında Makine Öğrenmesi yöntemi ile yapılan deneyler daha kısa eğitim süresi ve daha yüksek eğitim doğruluğu açısından ön plana çıkmaktadır. LSTM deneyleri ise daha yüksek test doğrulukları sağlamaktadır.
2. Makine öğrenmesi yöntemleri kendi aralarında karşılaştırılacak olursa, Veri Seti 1 veri parçası ile yapılan deneylerde Ağırlıklı K-NN yöntemi en yüksek eğitim doğruluğuna ulaşmıştır. Bu deneyi 9,22 saniyede tamamlamıştır. Bu performans değerlerinde diğer tüm yöntemlerden daha yüksek doğruluk elde edilmiştir. Ayrıca yeni veriler ile doğrulama yapıldığında test doğruluk değerleri düşmektedir. Bu da ağırlık miktarı uyum yaptığını göstermektedir.
3. Derin öğrenme yöntemlerinden biri olan LSTM ağlarının sıralı veriler için daha yüksek performans ölçütlerine ulaştığı bilinmektedir. Ancak rulman taşlamadan elde edilen bu AE veri kümesinde özellik çıkarımı uygulanmasına rağmen makine öğrenmesi yöntemleri daha kısa sürede daha yüksek eğitim doğruluğu elde etmiştir.

4. Makine öğrenmesi yöntemlerinde daha yüksek eğitim doğruluğu elde edilmesine rağmen, LSTM ağları daha yüksek test doğruluğuna sahiptir. Bu değerler için LSTM ağlarının yeni veri değerlerinde daha yüksek sınıflandırma doğruluğuna ulaşabildiği söylenebilir.

5. Yapılan araştırmalara göre; literatürde rulman taşlamadan elde edilen verilerle yapılmış bir uygulama bulunmamaktadır. Ancak deneysel koşullar altında oluşturulan çelik taşıma yanık verileri ile yapılan bazı çalışmalar mevcuttur. Bu deneylere kıyasla bu çalışmadaki makine öğrenmesi yöntemleri daha yüksek doğruluk değerlerine ulaşmaktadır. Literatürde sinyallerden zaman-frekans gösterimleri elde edilerek ön işleme tabi tutulmuştur. Bu çalışmada makine öğrenmesi yöntemleri ile yapılan deneyler ise belirli sayıda ham verinin örneklenmesi ile elde edilen daha kısa bir yolla oluşturulmuştur.

8.2. Ön Eğitimli Ağlar ve 2D-CNN Ağıyla Yapılan Uygulamalardan Elde Edilen Sonuçlar

Bu tez çalışmasında, taşıma rulman parçalarında taşıma yanıklarının tespiti için AE sinyallerinin zaman-frekans analizine dayanan CNN (2D-CNN ve Transfer Öğrenme) tabanlı bir sınıflandırma yapılmıştır. Deneysel veriler, farklı taşıma koşulları altında rulman makaralarının taşlanması sırasında elde edilmiştir. Bu sinyaller STFT, CWT ve HHT kullanılarak zaman-frekans görüntülerine dönüştürülmüştür. Bu görüntüler farklı transfer öğrenme ağları ve yazarlar tarafından geliştirilen 2D-CNN ağı kullanılarak sınıflandırılmış ve sınıflandırma performansı hem literatürdeki mevcut çalışmalarla hem de bu çalışmada uygulanan yöntemlerle karşılaştırılmıştır. Tablo 8.1 bu tez çalışması kapsamında yapılan derin öğrenme uygulamalarını kendi içinde karşılaştırmak için fikir verebilir. Makine öğrenmesi uygulamalardan elde edilen test doğrulukları oldukça düşüktür. Bu nedenle literatürde kabul edilenbilir sonuçların elde edildiği derin öğrenme yöntemlerine ilişkin sonuçlar bu tablo da verilmektedir. Tablo 8.1’de verilen sonuçlar ön eğitimli ağlar ve 2D-CNN ağı için Tablo6.3’teki 1-6 veri kombinasyonları için yapılan uygulamalardan seçilmiştir. Bunun nedeni daha önce bahsedildiği gibi bu uygulamalarda literatürce kabul edilebilir sonuçların elde edilmiş olmasıdır.

Tablo 2 : Tez kapsamında gerçekleştirilen derin öğrenme uygulamalarının maksimum ve minimum doğruluk değerleri

	LSTM	AlexNet	GoogleNet	ResNet-50	SqueezeNet	2D-CNN
Maksimum	91,8	100	100	95,92	100	100
Minimum	90,5	83,33	90,63	81,25	77,5	83,67

Tablo 8.2 ise literatürdeki mevcut çalışmaları, tercih edilen yöntemleri ve sınıflandırma performanslarını göstermekte ve bu tez çalışmasındaki sonuçlar ile karşılaştırmaktadır.

Tablo 32 : Literatürdeki çalışmalarla karşılaştırma

Makale	Ölçüm Fenomeni	Metot	Doğruluk
Kaya ve diğ.[71]	Titreşim	CWT ve Transfer Learning	%96,7-%100
Ceylan ve diğ. [105]	AE	CWT ve Transfer Learning	%50-%100
Kuncan [106]	Titreşim	1D-LBP, GRA	%94,22-%99,58
Shao ve diğ. [107]	Titreşim	Transfer Learning	%94,8-%99,6
Hübner ve diğ. [16]	AE	CWT, HHT, STFT, ANN,SVM, CNN	%90,2-%99,4
Wen ve diğ. [60]	Titreşim	Transfer CNN (Resnet-50)	%90,87-%100
Xu ve diğ. [61]	Titreşim	CWT, CNN, gcForest	%97,5-%99,79
Dong ve diğ. [62]	Titreşim	Alexnet, VGG-19, Goog-LeNet, and ResNet-50	%45,2-%98,9
Zhu ve diğ. [108]	Titreşim	Multi-scale fuzzy measure entropy (MFME), infinite feature selection (Inf-FS), SVM	%90,95-%100
Bu çalışma	AE	CWT,STFT,HHT, Transfer Laerning, 2D-CNN	%95,83-%100

Bölüm 6 ve Bölüm 7’den elde edilen sonuçlara dayanarak aşağıdaki çıkarımlar yapılabilir:

1. Zaman-frekans dönüşümü yöntemleriyle (STFT, CWT ve HHT) elde edilen AE sinyallerinin görüntüleri, taşlama yanığını tespit etmemizi sağlayan özellikler içerir. Bu özellikler, hatalı rulman parçalarını hatasız örneklerden ayırt etmek için derin CNN ağları tarafından öğrenilebilir.
2. Tablo 6.5 transfer öğrenme ağları ile yapılan 144 uygulamanın sonuçlarını listelemektedir.

1-6 (AMP): Aynı makine parametreleriyle yapılan deneyler. Tablo 6.3'nin 1-6. satırlarındaki her bir veri kombinasyonu ile 12 farklı uygulama, toplamda 72 farklı uygulama gerçekleştirilmiştir. Bu uygulamaların sınıflandırma doğruluğu skalogram ve spektrogram görüntüleri için %95,83-%100 aralığında elde edilmiştir. HHT ile elde edilen zaman frekans görüntülerinin sınıflandırma performansının daha düşük olduğu Tablo 6.3'ten görülebilir.

3. 7-12 (FMP): Farklı makine parametreleri ile yapılan deneyler. Tablo 6.3'nin 7-12. satırlardaki her bir veri kombinasyonu ile 12 farklı uygulama, toplamda 72 farklı uygulama gerçekleştirilmiştir. Bu uygulamaların sınıflandırma doğruluğu %34,38 ile %81,25 arasında değişmiştir. Bu değerler sınıflandırma probleminin çözüldüğü kabul edilen %95'e oldukça uzaktır. Bu nedenle farklı makine parametreleri ile işlenen rulman parçalarının sınıflandırılması doğru bir yaklaşım olmayacaktır. FMP'den elde edilen AE sinyallerinin HHT ile elde edilen zaman frekans görüntülerinin sınıflandırma performansının daha yüksek olduğu Tablo 6.5'ten görülebilir. Fakat bu oranlar da yine kabul edilebilir sınıflandırma başarımlarına ulaşmaktan oldukça uzaktır.

4. AMP'den elde edilen AE sinyallerinin CWT ve STFT görüntülerinin sınıflandırılması daha yüksek doğruluk sağlamaktadır. FMP'den elde edilen AE sinyallerinin HHT görüntülerinin sınıflandırılmasının daha yüksek doğruluk sağladığı görülmektedir.

5. CWT görüntülerinin sınıflandırılmasında Squeeze Net ağı öne çıkmaktadır. Tablo 6.5'ten de görüleceği üzere CWT görüntülerinin sınıflandırılmasında 4 deneyde %100 sınıflandırma başarısı elde edilmiştir.

6. STFT görüntülerin sınıflandırılmasında Google Net ağı öne çıkmaktadır. Tablo 6.5'ten de görüleceği üzere STFT görüntülerin sınıflandırılmasında 3 deneyde %100 sınıflandırma başarısı elde edilmiştir.

7. HHT görüntülerin sınıflandırılmasında Alex net ağı öne çıkmaktadır. Tablo 6.5'ten de görüleceği üzere HHT görüntülerin sınıflandırılmasında en yüksek doğruluk %81,25 ile AlexNet ağından elde edilmiştir.

8. Son durumda, ResNet ağının skalogram, spektrogram ve Hilbert spektrum görüntülerinin sınıflandırılmasında diğer transfer öğrenme ağlarına göre daha kötü sonuçlar verdiği Tablo 6.5'ten görülebilir. Hilbert spektrumundan elde edilen sınıflandırma performansının CWT ve STFT görüntülerinin sınıflandırılmasından elde

edilen görüntülerin sınıflandırma performansından daha düşük olduğu da Tablo 6.5'ten görülmektedir.

9. Tez kapsamında oluşturulan 2D-CNN ağında CWT görüntülerinin sınıflandırılmasında 2 kez %100 sınıflandırma performansına ulaşılmıştır. Ağın hem katman yapısı hem de işlem sayısı transfer öğrenme ağlarına göre oldukça azdır. Buna rağmen benzer doğruluk oranlarına ulaştığı Tablo 7.3'ten görülebilir.

Rulman parçalarında taşlama yanığı tespit edilirken, kullanılan zaman-frekans dönüşümü yöntemlerinden STFT ve CWT CNN mimarisine dayalı modellerde girdi olarak görüntü sağlayabilir, çünkü tüm veri kombinasyonlarında test veri kümesi üzerinde yüksek sınıflandırma performansları göstermiştir. HHT ile elde edilen Hilbert spectrum görüntülerinde ise güvenilir sonuç üretme başarısı gözlenememiştir. En yüksek sınıflandırma performansının %100'ü CWT ve STFT ile elde edilen görüntüleri girdi olarak kullanan transfer öğrenme ağlarında ve bu tez çalışmasında oluşturulan 2D-CNN ağında elde edilmiştir. Bu sonuç literatürde bildirilen diğer sonuçlardan üstün veya eşdeğerdir (bkz. Tablo 8.2). Tüm bu sonuçlar göz önünde bulundurulduğunda, CNN tabanlı modeller taşlama yanığının yüksek doğrulukla tespit edilmesi amaçlandığında kullanılabilir. Bununla birlikte, CNN'ler zaman alan özellik çıkarma adımına ihtiyaç duymama avantajına sahiptir.

Bütün bu sonuçlar dikkate alınacak olursa teze konu olan rulman üretim sürecinde taşlama yanığının tespiti için önerilen yöntemin kullanılabileceği söylenebilir. Bu yöntem kullanılarak özellikle taşlama işlemi sırasında yapılan yanık tespit işlemlerinde gerçekleştirilen örneklem seçiminde daha kestirimci bir seçim yapılabilir. Bu da hem hurda miktarını azaltacaktır, hem de üreticilerin talebine uygun olarak son kullanıcıya hatasız ürün tedariki konusunda daha güvenilir sonuçlar sağlayacaktır.

KAYNAKLAR

- [1] Teixeira, P. H. O., Rego, R. R., Pinto, F. W., de Oliveira Gomes, J., and Löpenhaus, C., (2019), Application of Hall effect for assessing grinding thermal damage, *J. Mater. Process. Technol.*, vol. 270, pp. 356–364. doi: 10.1016/j.jmatprotec.2019.02.019.
- [2] Deiva Nathan, R., Vijayaraghavan, L. and Krishnamurthy, R. (1999) In-process monitoring of grinding burn in the cylindrical grinding of steel, *J. Mater. Process. Technol.*, vol. 91, no. 1, pp. 37–42, doi: 10.1016/S0924-0136(98)00408-7.
- [3] Guo, W., Li, B., Shen, S. and Zhou, Q. (2019), An intelligent grinding burn detection system based on two-stage feature selection and stacked sparse autoencoder, *Int. J. Adv. Manuf. Technol.*, vol. 103, no. 5–8, pp. 2837–2847, doi: 10.1007/s00170-019-03748-5.
- [4] Kwak J. S. and Ha, M. K. (2004), Neural network approach for diagnosis of grinding operation by acoustic emission and power signals, *J. Mater. Process. Technol.*, vol. 147, no. 1, pp. 65–71, doi: 10.1016/j.jmatprotec.2003.11.016.
- [5] Liu, Q., Chen, X. and Gindy, N. (2006), Investigation of acoustic emission signals under a simulative environment of grinding burn, *Int. J. Mach. Tools Manuf.*, vol. 46, no. 3–4, pp. 284–292, doi: 10.1016/J.IJMACHTOOLS.2005.05.017.
- [6] Şahin Y. and Yalcinkaya, S. (2016), Application of Taguchi Technique to Surface-Grinding of Mold Steel, *Key Eng. Mater.*, vol. 689, pp. 7–11, doi: 10.4028/www.scientific.net/KEM.689.7.
- [7] Malkin S. and Guo, C. (2008), *Grinding Technology: Theory and Application of Machining with Abrasives*, Industrial Press,
- [8] SKF, (2017), *Bearing damage and failure analysis Contents*, Bear. damage Fail. Anal., pp. 106,
- [9] Hoang D. T. and Kang, H. J. (2019), A survey on Deep Learning based bearing fault diagnosis, *Neurocomputing*, vol. 335, pp. 327–335, doi: 10.1016/j.neucom.2018.06.078.
- [10] Yang, B., Lei, Y., Jia, F. and Xing, S. (2019), An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings, *Mech. Syst. Signal Process.*, vol. 122, pp. 692–706, doi: 10.1016/j.ymssp.2018.12.051.

- [11]Georgoulas, G., Loutas, T., Stylios, C. D. and Kostopoulos, V. (2013), Bearing fault detection based on hybrid ensemble detector and empirical mode decomposition, *Mech. Syst. Signal Process.*, vol. 41, no. 1–2, pp. 510–525, doi: 10.1016/J.YMSSP.2013.02.020.
- [12]Yünlü, L., Çolak, O. and Kurbanoglu, C. (2014), Taguchi DOE analysis of surface integrity for high pressure jet assisted machining of Inconel 718, *Procedia CIRP*, vol. 13, pp. 333–338, doi: 10.1016/j.procir.2014.04.056.
- [13]Lauro, C. H., Brandão, L. C., Baldo, D., Reis, R. A. and Davim, J. P. (2014), Monitoring and processing signal applied in machining processes - A review, *Meas. J. Int. Meas. Confed.*, vol. 58, pp. 73–86, doi: 10.1016/j.measurement.2014.08.035.
- [14]Gao, Z., Lin, J., Wang, X. and Liao, Y. (2019), Grinding Burn Detection Based on Cross Wavelet and Wavelet Coherence Analysis by Acoustic Emission Signal, *Chinese J. Mech. Eng. (English Ed.)*, vol. 32, no. 1, doi: 10.1186/s10033-019-0384-0.
- [15]Rubio, E. M., Teti, R. and Baciú, I. L. (2006), Advanced signal processing in acoustic emission monitoring systems for machining technology, *Intell. Prod. Mach. Syst.*, pp. 1–6, doi: 10.1016/B978-008045157-2/50008-0.
- [16]Hübner, H. B., Duarte, M. A. V. and da Silva, R. B. (2020), Automatic grinding burn recognition based on time-frequency analysis and convolutional neural networks, *Int. J. Adv. Manuf. Technol.*, vol. 110, no. 7–8, pp. 1833–1849, doi: 10.1007/s00170-020-05902-w.
- [17]Mba D. and Rao, R. B. K. N. (2006), Development of acoustic emission technology for condition monitoring and diagnosis of rotating machines: Bearings, pumps, gearboxes, engines, and rotating structures, *Shock Vib. Dig.*, vol. 38, no. 1, pp. 3–16, doi: 10.1177/0583102405059054.
- [18]Al-Ghamd A. M. and Mba, D. (2006), A comparative experimental study on the use of acoustic emission and vibration analysis for bearing defect identification and estimation of defect size, *Mech. Syst. Signal Process.*, vol. 20, no. 7, pp. 1537–1571, doi: 10.1016/J.YMSSP.2004.10.013.
- [19]Acoustic Emission: Standards and Technology Update (ASTM Special Technical Publication, 1353) <<https://epdf.tips/acoustic-emission-standards-and-technology-update-astm-special-technical-publica.html>>, erişim tarihi: 26.12.2018.
- [20]Inasaki, I. (1998), Application of acoustic emission sensor for monitoring machining processes, *Ultrasonics*, doi: 10.1016/S0041-624X(97)00052-8.
- [21]Lee, S. H. (2012), Analysis of ductile mode and brittle transition of AFM nanomachining of silicon, *Int. J. Mach. Tools Manuf.*, vol. 61, pp. 71–79, doi: 10.1016/j.ijmachtools.2012.05.011.

- [22] Bi, G., Liu, S., Su, S. and Wang, Z. (2021), Diamond grinding wheel condition monitoring based on acoustic emission signals, *Sensors (Switzerland)*, vol. 21, no. 4, pp. 1–17, doi: 10.3390/s21041054.
- [23] Karpuschewski, B., Wehmeier, M. and Inasaki, I. (2000), Grinding monitoring system based on power and acoustic emission sensors, *CIRP Ann. - Manuf. Technol.*, vol. 49, no. 1, pp. 235–240, doi: 10.1016/S0007-8506(07)62936-9.
- [24] Aguiar, P. R., Crus, C. E. D., Paula, W. C. F. and Bianchi, E. C. (2008), *Advances in Robotics, Automation and Control*, InTech.
- [25] Aguiar, P. R., Serni, P. J. A., Dotto, F. R. L. and Bianchi, E. C. (2006), In-process grinding monitoring through acoustic emission, *J. Brazilian Soc. Mech. Sci. Eng.*, vol. 28, no. 1, pp. 118–124, doi: 10.1590/S1678-58782006000100014.
- [26] Liu, Q., Chen, X. and Gindy, N. (2005), Fuzzy pattern recognition of AE signals for grinding burn, *International Journal of Machine Tools and Manufacture*, vol. 45, no. 7–8, pp. 811–818, doi: 10.1016/j.ijmachtools.2004.11.002.
- [27] Dotto, F. R. L., de Aguiar, P. R., Bianchi, E. C., Flauzino, R. A., Castelhana, G. de O. and Pansanato, L. (2003), Automatic detection of thermal damage in grinding process by artificial neural network, *Rev. Esc. Minas*, vol. 56, no. 4, pp. 295–300, doi: 10.1590/s0370-44672003000400013.
- [28] Griffin, J. M. (2015), Traceability of acoustic emission measurements for micro and macro grinding phenomena—characteristics and identification through classification of micro mechanics with regression to burn using signal analysis, *Int. J. Adv. Manuf. Technol.*, vol. 81, no. 9–12, pp. 1463–1474, doi: 10.1007/s00170-015-7210-3.
- [29] Teti, R., Jemielniak, K., O'Donnell, G. and Dornfeld, D. (2010), Advanced monitoring of machining operations, *CIRP Ann. - Manuf. Technol.*, vol. 59, no. 2, pp. 717–739, doi: 10.1016/j.cirp.2010.05.010.
- [30] Cerrada, M. et al., (2018), A review on data-driven fault severity assessment in rolling bearings, *Mech. Syst. Signal Process.*, vol. 99, pp. 169–196, doi: 10.1016/j.ymssp.2017.06.012.
- [31] Sepp H. and Jurgen, S. (1997), 1997Hochreiter_LSTM, *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780.
- [32] Sridhar, P., Mannherz, D. and de Payrebrune, K. M. (2021), Modelling and analysis of topographic surface properties of grinding wheels, *J. Manuf. Mater. Process.*, vol. 5, no. 4, pp. 1–29, doi: 10.3390/jmmp5040121.
- [33] Goodfellow, I., Bengio, Y. and Courville, A. (2018), *Derin Öğrenme*, Buzdağ Yayinevi.
- [34] LeCun, Y., Bengio, Y. and Hinton, G. (2015), Deep learning, *Nature*, vol. 521, no. 7553, pp. 436–444, doi: 10.1038/nature14539.

- [35]Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986), Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. doi: 10.1038/323533a0.
- [36]Zhao, Z. Q., Huang, D. S. and Sun, B. Y. (2004), Human face recognition based on multi-features using neural networks committee, *Pattern Recognit. Lett.*, vol. 25, no. 12, pp. 1351–1358, doi: 10.1016/j.patrec.2004.05.008.
- [37]Samanta B. and Al-Balushi, K. R. (2003), Artificial neural network based fault diagnostics of rolling element bearings using time-domain features, *Mech. Syst. Signal Process.*, vol. 17, no. 2, pp. 317–328, doi: 10.1006/mssp.2001.1462.
- [38]Malhi A. and Gao, R. X. (2004), PCA-based feature selection scheme for machine defect classification, *IEEE Trans. Instrum. Meas.*, vol. 53, no. 6, pp. 1517–1525, doi: 10.1109/TIM.2004.834070.
- [39]Yen, G. G., Member, S. and Lin, K. (2000), Wavelet Packet Feature Extraction for Vibration Monitoring, *IEEE Transactions On Industrial Electronics*, vol. 47, no. 3, pp. 650–667.
- [40]Lou X. and Loparo, K. A. (2004), Bearing fault diagnosis based on wavelet transform and fuzzy inference, *Mech. Syst. Signal Process.*, vol. 18, no. 5, pp. 1077–1095, doi: 10.1016/S0888-3270(03)00077-3.
- [41]Hemmati, F., Orfali, W. and Gadala, M. S. (2016), Roller bearing acoustic signature extraction by wavelet packet transform, applications in fault detection and size estimation, *Appl. Acoust.*, vol. 104, pp. 101–118, doi: 10.1016/j.apacoust.2015.11.003.
- [42]Van M. and Kang, H. J. (2015), Two-stage feature selection for bearing fault diagnosis based on dual-tree complex wavelet transform and empirical mode decomposition, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, vol. 230, no. 2, pp. 291–302, doi: 10.1177/0954406215573976.
- [43]Li, C., Sanchez, V., Zurita, G., Cerrada Lozada, M. and Cabrera, D. (2016), Rolling element bearing defect detection using the generalized synchrosqueezing transform guided by time–frequency ridge enhancement, *ISA Trans.*, vol. 60, pp. 274–284, doi: 10.1016/J.ISATRA.2015.10.014.
- [44]He, B., Wei, C., Ding, S. and Shi, Z. (2019) A survey of methods for detecting metallic grinding burn, *Measurement: Journal of the International Measurement Confederation*, vol. 134. pp. 426–439, doi: 10.1016/j.measurement.2018.10.093.
- [45]Hamadache, M., Jung, J. H., Park, J. and Youn, B. D. (2019), A comprehensive review of artificial intelligence-based approaches for rolling element bearing PHM: shallow and deep learning, *JMST Adv.*, vol. 1, no. 1–2, pp. 125–151, doi: 10.1007/s42791-019-0016-y.
- [46]Hassan Ali, Y., Abd Rahman, R. and Raja Hamzah, R. I. (2014), Acoustic emission

signal analysis and artificial intelligence techniques in machine condition monitoring and fault diagnosis: A review, *J. Teknol. (Sciences Eng., vol. 69, no. 2, pp. 121–126, 2014, doi: 10.11113/jt.v69.3121.*

- [47] Neto, R. F. G., Marchi, M., Martins, C., Aguiar, P. R. and Bianchi, E. (2014), Monitoring of grinding burn by AE and vibration signals, *ICAART 2014 - Proc. 6th Int. Conf. Agents Artif. Intell., vol. 1, pp. 272–279, doi: 10.5220/0004753602720279.*
- [48] Saravanapriyan, S. N. A., Vijayaraghavan, L. and Krishnamurthy, R. (2001), On-line detection of grinding burn by integrated sensing, *SIcon 2001 - Proc. 1st ISA/IEEE Sensors Ind. Conf., pp. 89–94, doi: 10.1109/SFICON.2001.968505.*
- [49] Wang, Z., Willett, P., Deaguiar, P. R. and Webster, J. (2001), Neural network detection of grinding burn from acoustic emission, *Int. J. Mach. Tools Manuf., vol. 41, no. 2, pp. 283–309, doi: 10.1016/S0890-6955(00)00057-2.*
- [50] Reser C. and Reich, C. (2019), Grinding burn prediction with artificial neural networks based on grinding parameters, *Smart SysTech 2019, pp. 56–60.*
- [51] Yang Z. and Yu, Z. (2013), Experimental study of burn classification and prediction using indirect method in surface grinding of AISI 1045 steel, *Int. J. Adv. Manuf. Technol., vol. 68, no. 9–12, pp. 2439–2449, doi: 10.1007/s00170-013-4882-4.*
- [52] Hinch, A. Z. and Tkouat, M. (2018), Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network,” *Procedia Comput. Sci., vol. 127, pp. 123–132, doi: 10.1016/J.PROCS.2018.01.106.*
- [53] Udmale, S. S., Singh, S. K. and Bhirud, S. G. (2019), A bearing data analysis based on kurtogram and deep learning sequence models, *Measurement, vol. 145, pp. 665–677, doi: 10.1016/J.MEASUREMENT.2019.05.039.*
- [54] Lei, J., Liu, C. and Jiang, D. (2019), Fault diagnosis of wind turbine based on Long Short-term memory networks,” *Renew. Energy, vol. 133, pp. 422–432, doi: 10.1016/J.RENENE.2018.10.031.*
- [55] Guo, L., Li, N., Jia, F., Lei, Y. and Lin, J. (2017), A recurrent neural network based health indicator for remaining useful life prediction of bearings,” *Neurocomputing, vol. 240, pp. 98–109, doi: 10.1016/J.NEUCOM.2017.02.045.*
- [56] Yang, R., Huang, M., Lu, Q., and Zhong, M. (2018), Rotating Machinery Fault Diagnosis Using Long-short-term Memory Recurrent Neural Network,” *IFAC-PapersOnLine, vol. 51, no. 24, pp. 228–232, doi: 10.1016/J.IFACOL.2018.09.582.*
- [57] Zhao, S., Zhang, Y., Wang, S., Zhou, B. and Cheng, C. (2019), A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method, *Measurement, doi:*

10.1016/J.MEASUREMENT.2019.06.004.

- [58] Li, F., Xiang, W., Wang, J., Zhou, X. and Tang, B. (2018), Quantum weighted long short-term memory neural network and its application in state degradation trend prediction of rotating machinery, *Neural Networks*, vol. 106, pp. 237–248, doi: 10.1016/J.NEUNET.2018.07.004.
- [59] Kaufmann, T., Sahay, S., Niemietz, P., Trauth, D., Maas, W. and Bergs, T. (2020), AI-based Framework for Deep Learning Applications in Grinding, *SAMI 2020 - IEEE 18th World Symp. Appl. Mach. Intell. Informatics, Proc.*, pp. 195–200, doi: 10.1109/SAMI48414.2020.9108743.
- [60] Wen, L., Li, X. and Gao, L. (2020), A transfer convolutional neural network for fault diagnosis based on ResNet-50, *Neural Comput. Appl.*, vol. 32, no. 10, pp. 6111–6124, doi: 10.1007/s00521-019-04097-w.
- [61] Xu, Y., Li, Z., Wang, S., Li, W., Sarkodie-Gyan, T. and Feng, S. (2021), A hybrid deep-learning model for fault diagnosis of rolling bearings, *Meas. J. Int. Meas. Confed.*, vol. 169, p. 108502, doi: 10.1016/j.measurement.2020.108502.
- [62] Dong, Y., Li, Y., Zheng, H., Wang, R. and Xu, M. (2022), A new dynamic model and transfer learning based intelligent fault diagnosis framework for rolling element bearings race faults: Solving the small sample problem, *ISA Trans.*, vol. 121, pp. 327–348, doi: 10.1016/j.isatra.2021.03.042.
- [63] Grover C. and Turk, N. (2022), A novel fault diagnostic system for rolling element bearings using deep transfer learning on bispectrum contour maps, *Eng. Sci. Technol. an Int. J.*, vol. 31, p. 101049, doi: 10.1016/j.jestch.2021.08.006.
- [64] Ozcan, I. H., Devecioglu, O. C., Ince, T., Eren, L. and Askar, M. (2022), Enhanced bearing fault detection using multichannel, multilevel 1D CNN classifier, *Electr. Eng.*, vol. 104, no. 2, pp. 435–447, doi: 10.1007/S00202-021-01309-2/TABLES/8.
- [65] Wang, X., Mao, D. and Li, X. (2021), Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network, *Measurement*, vol. 173, p. 108518, , doi: 10.1016/J.MEASUREMENT.2020.108518.
- [66] Wang, D., Guo, Q., Song, Y., Gao, S. and Li, Y. (2019), Application of Multiscale Learning Neural Network Based on CNN in Bearing Fault Diagnosis, *J. Signal Process. Syst.*, vol. 91, no. 10, pp. 1205–1217, doi: 10.1007/s11265-019-01461-w.
- [67] Neupane, D., Kim, Y., Seok, J. and Hong, J. (2021), Cnn-based fault detection for smart manufacturing, *Appl. Sci.*, vol. 11, no. 24, doi: 10.3390/app112411732.
- [68] Neupane, D., Kim, Y. and Seok, J. (2021), Bearing Fault Detection Using Scalogram and Switchable Normalization-Based CNN (SN-CNN),” *IEEE Access*, vol. 9, pp. 88151–88166, doi: 10.1109/ACCESS.2021.3089698.

- [69]Eren, L., Ince, T. and Kiranyaz, S. (2019), A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier, *J. Signal Process. Syst.*, vol. 91, no. 2, pp. 179–189, doi: 10.1007/s11265-018-1378-3.
- [70]Wang P. and Gao, R. X. (2020), Transfer learning for enhanced machine fault diagnosis in manufacturing, *CIRP Ann.*, vol. 69, no. 1, pp. 413–416, doi: 10.1016/j.cirp.2020.04.074.
- [71]Kaya, Y., Kuncan, F. and Ertunç, H. M. (2022), A new automatic bearing fault size diagnosis using time-frequency images of CWT and deep transfer learning methods,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 30, no. 5, pp. 1851–1867, doi: 10.55730/1300-0632.3909.
- [72]Shao, H., Jiang, H., Zhang, X. and Niu, M. (2015), Rolling bearing fault diagnosis using an optimization deep belief network, *Meas. Sci. Technol.*, vol. 26, no. 11, doi: 10.1088/0957-0233/26/11/115002.
- [73]Mao, W., Ding, L., Tian, S. and Liang, X. (2020), Online detection for bearing incipient fault based on deep transfer learning, *Meas. J. Int. Meas. Confed.*, vol. 152, p. 107278, doi: 10.1016/j.measurement.2019.107278.
- [74]Lu, T., Yu, F., Han, B. and Wang, J. (2020), A generic intelligent bearing fault diagnosis system using convolutional neural networks with transfer learning, *IEEE Access*, vol. 8, pp. 164807–164814, doi: 10.1109/ACCESS.2020.3022840.
- [75]Wang, X., Shen, C., Xia, M., Wang, D., Zhu, J. and Zhu, Z. (2020), Multi-scale deep intra-class transfer learning for bearing fault diagnosis, *Reliab. Eng. Syst. Saf.*, vol. 202, doi: 10.1016/J.RESS.2020.107050.
- [76]Bearing Steel. <<https://virgamet.com/tubes-100cr6-1-3505-102cr6-1-2067-aisi-52100-lh15-bearing-steel>>, erişim tarihi:05.24.2023.
- [77]T-11L CNC Internal Grinding Machines, (2023), Chuck Type, Machine Tool Business, Business Activities, Toyo Advanced Technologies Co. Ltd.
- [78]Kistler Group. <<https://www.kistler.com/INT/en/cp/acoustic-emission-sensors-8152c/P0000485>>, erişim tarihi: 11.05.2023
- [79]Tasler LTTPro. <<https://www.tasler.de/en/software/lttpro/>>, erişim tarihi: 11.05.2023.
- [80]Huang, N. E. (1998), The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis, *Proc. R. Soc. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903–995, doi: 10.1098/rspa.1998.0193.
- [81]Gaci, S. (2016), A New Ensemble Empirical Mode Decomposition (EEMD) Denoising Method for Seismic Signals, *Energy Procedia*, vol. 97, pp. 84–91, doi: 10.1016/J.EGYPRO.2016.10.026.
- [82]Cios, K. J., Pedrycz, W. and Swiniarski, R. W. (1998), Data Mining and

- Knowledge Discovery, Data Min. Methods Knowl. Discov., pp. 1–26, doi: 10.1007/978-1-4615-5589-6_1.
- [83] Peters, T. M., Williams, J. C. (1998), The Fourier Transform in Biomedical Engineering, Birkhauser.
- [84] Rother, A., Jelali, M. and Söffker, D. (2015), A brief review and a first application of time-frequency-based analysis methods for monitoring of strip rolling mills, J. Process Control, vol. 35, pp. 65–79, doi: 10.1016/J.PROCONT.2015.08.010.
- [85] Grossmann, A. and Morlet, J. (2006), Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape, <https://doi.org/10.1137/0515056>, vol. 15, no. 4, pp. 723–736, doi: 10.1137/0515056.
- [86] Goodfellow, I., Bengio, Y. and Courville, A. (2016), Deep Learning, The MIT Press.
- [87] Müller, A. C. and Guido, S. (2016), Introduction to with Python Learning Machine, O'Reilly.
- [88] Support Vector Machines for Binary Classification - MATLAB & Simulink. <<https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>>, erişim tarihi: 11.26.2022.
- [89] Boashash, B. (1992), Estimating and Interpreting the Instantaneous Frequency of a Signal—Part 2: Algorithms and Applications, Proc. IEEE, vol. 80, no. 4, pp. 540–568, 1992, doi: 10.1109/5.135378.
- [90] Pan, Y. N., Chen, J. and Li, X. L. (2009), Spectral entropy: A complementary index for rolling element bearing performance degradation assessment, Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci., vol. 223, no. 5, pp. 1223–1231, doi: 10.1243/09544062JMES1224.
- [91] Chollet, F. (2018), Deep Learning with Python, Manning Publication Co.
- [92] Cheng, C., Li, J., Liu, Y., Nie, M. and Wang, W. (2019), Deep convolutional neural network-based in-process tool condition monitoring in abrasive belt grinding, Comput. Ind., vol. 106, pp. 1–13, doi: 10.1016/j.compind.2018.12.002.
- [93] ImageNet. <<https://image-net.org/>>, erişim tarihi: 07.02.2022.
- [94] Zhou, B., Lapedriza, A., Torralba, A. and Oliva, A. (2017), Places: An Image Database for Deep Scene Understanding, J. Vis., vol. 17, no. 10, p. 296, doi: 10.1167/17.10.296.
- [95] GoogLeNet convolutional neural network - MATLAB googlenet. <<https://www.mathworks.com/help/deeplearning/ref/googlenet.html>>, erişim tarihi: 07.02.2022.
- [96] Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2017), ImageNet classification

with deep convolutional neural networks, *Commun. ACM*, vol. 60, no. 6, pp. 84–90, doi: 10.1145/3065386.

- [97] Szegedy, C. (2015), *Going Deeper With Convolutions.*, pp. 1–9.
- [98] He, K., Zhang, X., Ren, S. and Sun, J. (2016), Deep Residual Learning for Image Recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770–778.
- [99] SqueezeNet convolutional neural network - MATLAB squeezeNet. <<https://www.mathworks.com/help/deeplearning/ref/squeezenet.html>>, erişim tarihi: 02.07.2022.
- [100] Zhu, X. (2019), Rotor fault diagnosis using a convolutional neural network with symmetrized dot pattern images, *Meas. J. Int. Meas. Confed.*, vol. 138, pp. 526–535, doi: 10.1016/J.MEASUREMENT.2019.02.022.
- [101] Wang, H., Xu, J., Yan, R. and Gao, R. X. (2020), A New Intelligent Bearing Fault Diagnosis Method Using SDP Representation and SE-CNN, *IEEE Trans. Instrum. Meas.*, vol. 69, no. 5, pp. 2377–2389, doi: 10.1109/TIM.2019.2956332.
- [102] Cirrincione, G., Kumar, R. R., Mohammadi, A., Kia, S. H., Barbiero, P. and Ferretti, J. (2020), Shallow Versus Deep Neural Networks in Gear Fault Diagnosis, *IEEE Trans. Energy Convers.*, vol. 35, no. 3, pp. 1338–1347, doi: 10.1109/TEC.2020.2978155.
- [103] Wang, J., Mo, Z., Zhang, H. and Miao, Q. (2019), A deep learning method for bearing fault diagnosis based on time-frequency image, *IEEE Access*, vol. 7, pp. 42373–42383, doi: 10.1109/ACCESS.2019.2907131.
- [104] Keçeli, A. S., Kaya, A. and Can, A. B. (2018), Combining 2D and 3D deep models for action recognition with depth information, *Signal, Image Video Process.*, vol. 12, no. 6, pp. 1197–1205, doi: 10.1007/S11760-018-1271-3/TABLES/4.
- [105] Ceylan, N., Kaçar, S., Güney, E. and Bayılmış, C. (2022), Detection of Grinding Burn Fault in Bearings by Squeeze Net, *Signal Processing and Communications Applications Conference, Karabük*, pp. 1–4.
- [106] Kuncan, M. (2020), An Intelligent Approach for Bearing Fault Diagnosis : Combination of 1D-LBP and GRA, *IEEE Access*, vol. 8, pp. 137517–137529 doi: 10.1109/ACCESS.2020.3011980.
- [107] Shao, S., McAleer, S., Yan, R. and Baldi, P. (2019), Highly Accurate Machine Fault Diagnosis Using Deep Transfer Learning, *IEEE Trans. Ind. Informatics*, vol. 15, no. 4, pp. 2446–2455, doi: 10.1109/TII.2018.2864759.
- [108] Zhu, K., Chen, L. and Hu, X. (2019), A Multi-scale Fuzzy Measure Entropy and Infinite Feature Selection Based Approach for Rolling Bearing Fault Diagnosis, *J. Nondestruct. Eval.*, vol. 38, no. 4, pp. 1–13, doi: 10.1007/s10921-019-0623-4.

