



**T. C.
SİVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**AZDIRMA TEZGÂHLARI İÇİN TEZGÂH İZLEME SİSTEM
TASARIMI**

YÜKSEK LİSANS TEZİ

Resul YERLİKAYA

(20199240026)

Enerji Bilimi ve Teknolojisi Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Yunis TORUN

SİVAS

2022

Resul YERLİKAYA'nın hazırladığı ve “AZDIRMA TEZGÂHLARI İÇİN TEZGÂH İZLEME SİSTEM TASARIMI” adlı bu çalışma aşağıdaki jüri tarafından ENERJİ BİLİMİ VE TEKNOLOJİSİ MÜHENDİSLİĞİ ANA BİLİM DALI’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Tez Danışmanı	Doç. Dr. Yunis TORUN Sivas Cumhuriyet Üniversitesi
Jüri Üyesi	Dr. Öğr. Üyesi. Deniz GÖLBAŞI Sivas Cumhuriyet Üniversitesi
Jüri Üyesi	Dr. Öğr. Üyesi. Yusuf DOĞAN Sivas Bilim ve Teknoloji Üniversitesi

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nevcihan GÜRSOY

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu’nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)’nda belirtilen kurallara uygun olarak hazırlanmıştır.





Bütün hakları saklıdır.

Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

Resul YERLİKAYA, 2022

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

6.12.2022

Resul YERLİKAYA

KATKI BELİRTME VE TEŞEKKÜR

Bilgi ve deneyimlerinden sürekli yararlandığım, tezin her aşamasında yardımlarını esirgemeyen danışman hocam Doç. Dr. Yunis TORUN' a çok teşekkür ederim.

Ayrıca, bu tez çalışması süresince bilgi ve deneyimleri ile bana yol gösteren ESTAŞ ARGE Yöneticisi Fatih ÖZAYDIN' a teşekkürlerimi sunarım.

ÖZET

AZDIRMA TEZGÂHLARI İÇİN TEZGÂH İZLEME SİSTEM TASARIMI

Resul YERLİKAYA

Yüksek Lisans Tezi

Enerji Bilimi ve Teknolojisi Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Yunis TORUN

2022, 68+xvi sayfa

Azdırma tezgâhlarında kullanılan kesici uçlarda yanma, kırılma, körelme, salgı gibi birçok sorun meydana gelmektedir ve bunlar kesiciye hareketini veren motorlarda ciddi zorlanmalara neden olmaktadır. Kesici uca hareketini veren motor zorlanmasının en önemli nedeni kesici uçtaki hatalardır. Kestirimci bakım yöntemiyle gerekli önlemler alınarak hata meydana gelmeden tespit edilmesi, seri üretim yapan tezgâhlar açısından oldukça önemlidir. Kesme esnasında akım, gerilim, ses ve vibrasyon sinyal analizi, takım kırılmalarını, işlenen parçadaki boyutsal ve şekilsel kusurları önleyebilmektedir. Ayrıca işleme anındaki akım farklılıklarından oluşan takım deformasyonunun incelenmesi, parça işleme sonucunda meydana gelecek boyutsal hatayı önceden görmemizi ve gerekli düzeltmeler yapıldığında hatanın önüne geçilmesini mümkün kılar. Bu tezde azdırma tezgâhına kesici uç olarak kırık, körelmiş, yanmış ve sağlam çakılar takılarak parça işlendi. Akım ve gerilim transdüserlerine çakıya hareketini veren asenkron motorun faz kablosu bağlanarak akım ve gerilim ölçüldü. Çakıya yakın titreşimin yoğun olduğu malafa üzerine vibrasyon transdüseri bağlanarak ve çakı mili ucuna enkoder bağlanarak sırası ile titreşim, hız ölçümü yapılmıştır. Buradan okunan analog ham veriler, ARM tabanlı mikrodenetleyiciye bağlı SD kartın içine kaydedilmektedir. Bilgisayar üzerinde oluşturulan EXE uzantılı uygulama aracılığıyla okunan ham veriler, SD karttan bilgisayara aktarılarak ham değerler elde edildi. Her bir örnek için aynı zamanda tezgâhın ve çakının ürettiği ses sinyalleri eş zamanlı olarak

kaydedildi. Kırık, körelmiş, yanmış ve sağlam çakı durumlarında 4 örnek alınmış ve toplanan veriler neticesinde kesici takımın durumu yorumlanmıştır. Ses sinyallerinden, öznitelikler çıkartılmıştır. Çıkartılan öznitelikler Derin Öğrenme modelin eğitilmesinde kullanılmıştır. Ses analizi için model eğitildikten sonra doğrulama veri setinde test edilmiş ve $99,42 \pm 0,132$ oranında başarımlık skor elde edilmiştir.

Anahtar kelimeler: Azdırma Tezgâhı, Öznitelik Çıkartma, Transdüser, Hata Teşhis, Makine Öğrenmesi



ABSTRACT

MACHINE MONITORING SYSTEM DESIGN FOR HOBBING MACHINES

Resul YERLİKAYA

Master of Science Thesis

Department of Energy Science and Technology Engineering

Supervisor: Doç. Dr. Yunis TORUN

2022, 68+xvi pages

There are many problems like burning, breaking, blunting, and runout occur in the cutting tips used in hobbing machines, and these problems result in serious strains on the motors that move the cutter. The most important reason for the motor stress that moves the cutter is the errors in the cutter. It is very important for machines that make mass production to detect faults before they occur by taking the necessary precautions with the predictive maintenance method. During cutting, current, voltage and vibration signal analysis can prevent tool breakages, shape and dimensional errors in the machined part. In addition, examining the tool deformation caused by current differences during machining enables us to predict the dimensional error that will occur under the specified cutting conditions and to compensate for this error when necessary corrections are made. During this study, the piece was machined by attaching broken, blunt, burned and solid sprocket gear cutter to the hobbing machine as cutting edge. The current and voltage were measured by connecting the phase cable of the asynchronous motor that drives solid sprocket gear cutter to the current and voltage transducers. Vibration and speed measurements were made by connecting a vibration transducer on the arbor, where the vibration close to the solid sprocket gear cutter is intense, and by connecting the encoder to the tip of the solid sprocket gear cutter shaft, respectively. The analogue raw data read from here is saved in the SD card connected to the ARM-based microcontroller. Raw data, read through the EXE extension application created

on the computer, were transferred from the SD card to the computer and raw values were obtained. For each sample, the sound signals produced by the bench and the solid sprocket gear cutter were recorded simultaneously. 4 samples were taken in cases of broken, blunt, burned and solid sprocket gear cutter, and the state of the cutting tool was interpreted as a result of the collected data. Features are extracted from the audio signals. The extracted features were used to train the Deep Learning model. After the model was trained for sound analysis, it was tested on the validation data set and a 99.42 ± 0.132 accuracy score was obtained.

Key Words: Hobbing Machine, Feature Extraction, Transducer, Fault diagnosis, Machine Learning

İÇİNDEKİLER

ÖZET	vii
ABSTRACT	ix
ŞEKİLLER DİZİNİ.....	xiii
TABLolar DİZİNİ.....	xv
KISALTMALAR DİZİNİ.....	xvi
1 GİRİŞ.....	1
2 TEZGÂH HATALARI	6
2.1. Kesici Uç Hataları.....	6
2.2. Çakı Hataları	9
3 HATA TEŞHİS YÖNTEMLERİ	11
3.1. İmza Tabanlı Yöntemler	11
3.1.1. Hızlı Fourier Dönüşümü.....	11
3.1.2. Fourier Dönüşümü.....	13
3.1.3. Dalgacık Analizi.....	15
3.1.4. Hilbert Dönüşümü	17
3.1.5. Bispectrum	18
3.2. Modele Dayalı Yöntemler.....	19
3.3. Bilgiye Dayalı Yöntemler	19
3.3.1. Sinir Ağları (NN)	20
4 MATERYAL VE METOT	22
4.1. Veri Toplama	22
4.2. Özellik Çıkarma	31
4.2.1. Spektral Özellik.....	32
4.2.2. Doğrusal Tahmin.....	32
4.2.3. Gamaton Kepstral Katsayıları (GTCC).....	33
4.2.4. Perde Sıklığı	33
4.2.5. Mel-Frekans Kepstral Katsayıları (MFCC).....	33
4.2.6. Yayılı Spektrum	35
4.2.7. Spektral Entropi.....	35
4.2.8. Spektral Merkez	36
4.2.9. Eşit Dikdörtgen Bant Genişliği (ERB).....	36

4.2.10.	Bark Ölçeği	36
4.3.	Sinyal Analizi ve Aşamaları	36
4.3.1.	Derin İnanç Ağları.....	39
5	DENEYSEL ÇALIŞMALAR.....	40
6	SONUÇLAR	62
	KAYNAKLAR.....	63



ŞEKİLLER DİZİNİ

Şekil 2.1	Takım ucunda görülen yüzey aşınması	7
Şekil 2.2	Takım ucunda oluşan krater aşınması	8
Şekil 2.3	Kesme ucunda oluşan çentik aşınması	8
Şekil 2.4	Çakı sıcaklık değişimi	9
Şekil 3.1	Üç seviyeli DWT ayrıştırma ağacı	16
Şekil 3.2	Bispectrum algoritmasının akış şeması	19
Şekil 3.3	Çok katmanlı ileri beslemeli algılayıcının ağ diyagramı	20
Şekil 4.1	İş parçası teknik resmi	23
Şekil 4.2	Hata tespiti akış şeması	24
Şekil 4.3	Gerilim transdüseri giriş-çıkış değerleri grafiği	25
Şekil 4.4	Akım transdüseri giriş-çıkış değerleri grafiği	26
Şekil 4.5	Sinyal verilerinin alınması	26
Şekil 4.6	Vibrasyon transdüseri giriş-çıkış değerleri grafiği	27
Şekil 4.7	Dönüştürücü çıkışının alt gerilim değeri ayarlanması	27
Şekil 4.8	Dönüştürücü çıkışının üst gerilim değeri ayarlanması	28
Şekil 4.9	GTCC blok diyagramı	33
Şekil 4.10	MFCC özellik çıkarımı	34
Şekil 4.11	Derin İnanç Ağ Yapısı	39
Şekil 5.1	Deney düzeneği	40
Şekil 5.2	Sağlam çakı	41
Şekil 5.3	a) Sağlam çakı akım sinyal grafiği b) Sağlam çakı gerilim sinyal grafiği c) Sağlam çakı titreşim sinyal grafiği	42
Şekil 5.4	Körelmiş çakı	43
Şekil 5.5	a) Körelmiş çakı akım sinyal grafiği b) Körelmiş çakı gerilim sinyal grafiği c) Körelmiş çakı titreşim sinyal grafiği	44
Şekil 5.6	Yanık çakı	45
Şekil 5.7	a) Yanık çakı akım sinyal grafiği b) Yanık çakı gerilim sinyal grafiği c) Yanık çakı titreşim sinyal grafiği	46
Şekil 5.8	Kırık çakı	47

Şekil 5.9 a) Kırık çakı akım sinyal grafiği b) Kırık çakı gerilim sinyal grafiği c) Kırık çakı titreşim sinyal grafiği.....	48
Şekil 5.10 a) Boşta çakı akım sinyal grafiği b) Boşta çakı gerilim sinyal grafiği c) Boşta çakı titreşim sinyal grafiği.....	49
Şekil 5.11 Perde Sıklığı Öznitelikler	50
Şekil 5.12 Bark Ölçeği Öznitelikler	51
Şekil 5.13 Spektral Merkez Öznitelikler	52
Şekil 5.14 Eşit Dikdörtgen Bant Genişliği Öznitelikler	53
Şekil 5.15 Yayılı Spektrum Öznitelikler	54
Şekil 5.16 Doğrusal Tahmin Öznitelikler.....	55
Şekil 5.17 Mel Spektrum Öznitelikler.....	56
Şekil 5.18 Mel Frekans Kepstral Katsayıları Öznitelikler	57
Şekil 5.19 Gamaton Kepstral Katsayıları Öznitelikler	58
Şekil 5.20 Spektral Entropi Öznitelikler	59
Şekil 5.21 Sınıflandırma başarımlar grafiği	60
Şekil 5.22 Karşılaştırma grafiği	60

TABLÖLAR DİZİNİ

Tablo 1. Dönüştürücü giriş-çıkış değerleri	28
Tablo 2. Ham veriler ve ölçülen değerler	30



KISALTMALAR DİZİNİ

FFT	: Hızlı Fourier Dönüşümü
DWT	: Ayırık Dalgacık Dönüşümü
DTF	: Ayırık Fourier Dönüşümü
NN	: Sinir Ağları
SOM	: Kendini Düzenleye Haritalar
YSA	: Yapay Sinir Ağları
RMS	: Kare Ortalamalarının Kökü
MPU	: Hafıza Koruma Birimi
NVIC	: İç İç Kesme Yönetim Mekanizması
MAC	: Çoklu Toplama
LP	: Doğrusal Tahmin
ERB	: Eşit Dikdörtgen Bant Genişliği
GTCC	: Gamaton Kepstral Katsayıları
DTC	: Ayırık Kosinüs Dönüşümü
MFCC	: Mel-Frequency Cepstral Coefficient
ASR	: Otomatik Ses Tanıma
FIR	: Sonlu Darbe Yanıtı
RBM	: Sınırlı Boltzmann Makineleri

1 GİRİŞ

Dişli çarklar freze tezgâhlarında açıldıklarında yeterince kaliteli, hassas ve seri olarak üretimi yapılamamaktadır. Bu durumun sebebi freze tezgâhlarının temel amacı dişli çark üretmek olmamasından kaynaklanmaktadır. Fakat düşük devirlerde çalışan, hassas olmayan ve az miktarda imal edilmesi gereken dişli çarkları üretebilecek düzeyde dizayn edilmiştir. Freze tezgâhlarında üretimi yapılamayan dişlilerin daha kısa zamanda, daha kaliteli ve hassas olarak üretilebilmeleri için azdırma dişli tezgâhları kullanılmaktadır. Dişli çarkları yuvarlanma metodu ile açan bu tezgâhlar, imalat sanayiinin gözde dişli imalat tezgâhları olmuşlardır. Azdırma tezgâhları iç dişlileri açamazken, yalnızca dış dişli açmaya uygundurlar. Adını azdırma freze kesicilerinden alan bu tezgâhlar sayesinde, belirlenen hassasiyet toleranslarında ve istenilen kalitede dişli çarklar imal edilebilmektedir.

Endüstriyel tezgâh motorlarının hatasız çalışması amacı ile, çeşitli bilgisayar destekli durum izleme sistemleri uygulanmaktadır [1-10]. Endüstride sağlamlığı, düşük maliyeti, verimli çalışması ve basit yapıda olması sebebi ile asenkron motorlar tercih edilmektedir. Eksene veya kesiciye hareketini veren motor çalışırken ses, sıcaklık, hız, titreşim, gerilim veya akım değerleri gözetlenerek, motorların veri sayfalarında belirtilen tolerans aralığında çalışıp çalışmadıkları hakkında karar verilebilir. Elektrik motorlarında oluşan hatalar genellikle motorun uzun süre bakımsız kullanılmasından kaynaklanmaktadır [1]. Bununla beraber azdırma tezgâhında periyodik bakımı yapılmış motor olsa dahi kesici uçtaki hatalar sistemin istenilen performansta çalışmasını negatif yönde etkileyebilir. Kesici ucun körelmesi iş parçası ile kesici uç arasındaki sürtünme kuvvetini artırdığından dolayı, kesici uca hareketini veren motora ekstra yük bindirmekte ve aşırı yük motor yatak rulmanının bilyelerine hasar vermektedir [2]. Kirli ortamlarda çalışan motorlarda, motor içerisine kaçan toz ve kum parçaları da motor arızalarına etken sayılabilir [1]. Bu gibi çeşitli hataların zamanında tespit edilerek müdahale edilmemesi, motorun arızaya geçmesi, çakının bozulması, işlenen dişlide kalite problemleri gibi önemli maddi kayıplara neden olmaktadır.

Asenkron motor hatalarını elektriksel ve mekanik olarak iki grupta sınıflandırılabilir [2]. Elektriksel hatalar stator kısa devre, kırık rotor çubuğu gibi hatalardır [2]. Mekanik hatalar ise eksantriklik, rulman arızaları, eksen kaçıklığı gibi hatalardır [2]. Bu hataların çoğu kesici

uçtaki yanma, salgı, kırılma ve körelme gibi problemlere bağlı ortaya çıkan zorlanmalardan oluşmaktadır.

Tezgâh motor arızaları tespiti ve sınıflandırılması, sinyallerin frekans bileşenlerine bağlı olarak yapılması üzerine literatürde pek çok çalışma mevcuttur [11-19]. Özellikle kısa devre arızası durumunda frekans modeli, izlenen stator akımından analitik olarak çıkarılır ve bu frekanslardaki yan bant bileşenlerinin genliği, kısa devreli dönüşlerin sayısını belirlemek için uygun bir kriter olarak sunulur [1]. İzolasyon probleminden kaynaklanan stator arızaları; sargılar arası, faz-faz ve faz-toprak arası kısa devre arızası olarak sınıflandırılır [2]. Sargılar arası kısa devre tahmini, arıza uzantısından kurtarmaya neden olduğundan, kesin olarak tespit edilmelidir [2]. Nyamusa ve Demerdash (1987), kısa devre hatası altında sabit mıknatıslı fırçasız dc motorun endüktansları sonlu elemanlar yöntemi ile hesaplamışlardır. Bu endüktanslar, hatalı dc motorun performans analizi için motorun dinamik denklemlerinde kullanılmıştır. Bununla birlikte, denklemin yakınsaması sonlu elemanlar yönteminin seçilen uygun başlangıç girdilerine bağlıdır [3]. Kısa devre arızası durumundaki motorlar manyetik eşdeğer devre kullanılarak simülasyonu yapılabilir [4].

Nelson ve Chow (2002) çalışmalarında kısa devre arızasının stator akımları ve rotor hızı üzerindeki etkisi değişken relüktanslı motorda incelemişlerdir. Motor, kapalı döngü rotor konumu geri beslemeli ve açık döngü voltaj hız kontrollü fırçasız bir sürücü ile çalıştırıldığında, büyük bir kısa devre hatasının rotor hızındaki bir azalma ile ilişkili olduğu gösterilmiştir [5]. Elektrik makinelerinde hata tespiti için motor sinyallerinin genlik analizi güvenilir bir yaklaşım olduğu dikkat çekicidir [6], [7]. Çünkü yük değişimi ve besleme durumu motor sinyali genliklerini değiştirebilir. Bianchi vd. (2003) çalışmalarında motorlar için kontrol stratejilerinin sağlıklı durumdakilerden farklı olduğu ortaya çıkmıştır. Bunun nedeni, hatanın ölçülen tork ve stator akımları üzerindeki gözle görülür etkileridir [8]. Buradaki hatalı motoru kontrol etmek için verimli teknikler kullanılmış olsa da hata tanıma için hiçbir yöntem sunulmamış ve yalnızca hataya dayanıklı durum analizi yapılmıştır [9].

Jigyasu vd. (2018) çalışmalarında Dalgacık Dönüşümü ve Park Vektör analizi gibi yöntemlerden bazılarını içeren olası algılama formlarından bahsetmişlerdir. Sonuçlardan, asenkron motor hatalarının titreşim, ses ve akım ile tespitinde Hızlı Fourier Dönüşümü' nün (FFT) en iyi tekniklerden biri olduğu elde edilmiştir [10].

Luo ve Du (2010) çalışmalarında statordaki kısa devre sargısını tanımlamak için basit bir Dalgacık Dönüşümü kullanmışlardır. Ancak, yalnızca 3. ve 4. düzey ayrıştırma kullanıp, tanımlama konusunda eğitilmiş bir tahminde bulunulmuştur [11]. Sridhar vd. (2015), benzer metotlarla çalışma gerçekleştirmişlerdir [12]. Fakat, her iki modelde otomasyon kullanmamıştır. Ping ve Gaeid (2012), aynı hataları tespit etmek için Ayırık Dalgacık Dönüşümü (DWT) kullanması bakımından benzerdir [13]. Kechida vd. (2015) çalışmalarında daha ilginç bir yaklaşım kullanarak, deneyi aşırı karmaşıklştırabilmesine rağmen hem FFT hem de DWT kullanarak dönüşler arası arızaları izlemek için bir yöntem önermişlerdir [14]. Athulya (2018) aynı hataları tespit etmek amacıyla stator akım sinyali elde etmek için Simulink modelini kullanmıştır. Sinyaller dalgacık analizi kullanılarak ayrıştırılıp, bir sonuca varmak için standart sapmaları elde edilmiştir [15]. Burada daha modern ve popüler bir kombinasyonun araştırması başarıyla analiz edilmiştir. Bir frekans dönüştürücüden güç alan motor ve en çok meydana gelen arıza taşıma koşullarından biri izlenmiştir. Siddiqui vd. (2016) benzer metotlarla deneyler gerçekleştirmişlerdir [16].

Marma vd. (2019) çalışmalarında spektral yoğunluk ve Sürekli Dalgacık Dönüşümü kullanarak kırık rotor çubuklarını tespit etmek için bir yöntem önermişlerdir. Sürekli Dalgacık Dönüşümü algoritmasına dayanan karmaşık bir Morlet dalgacığı hesaplanarak elde edilen skalogramlar daha sonra özellik çıkarma ve değerlendirme için kullanılabilir olmasına rağmen çalışmalar otomasyondan yoksundur. Temel olarak motor durumunun nihai teşhisi bir gözleme dayanır [17]. Bu eksikliği gidermek amacıyla Ünsal ve Kaya (2021) çalışmalarında, asenkron motorda yapay olarak farklı seviyelerde kırık rotor çubuğu, stator kısa devre hatası ile rulman hatalarını oluşturup 25 kHz örnekleme frekansında veriler toplayarak, yapay sinir ağlarıyla sınıflandırma gerçekleştirmişlerdir [18]. Sonuçlardan, yapay sinir ağlarında arıza çeşidi arttıkça başarı oranı azaldığı, işlem yükünün ve hata tespit süresinin arttığı gözlemlenmiştir [18]. Aynı hata durumunda Bayrak ve Küçükler (2016), elde edilen verilerin enerji yoğunluğunu inceleyerek hata boyutu hakkında karar vermişlerdir. Motorun ani gücünde oluşan farklı frekans bandındaki bileşenler, hata oluşup oluşmadığı hakkında bilgi verebilir [19]. Kırık rotor çubuğu, motorun dinamik performansını negatif etkilemekte beraber momentte ve hızda salınımlara sebep olmaktadır [20].

Proses özellikleri dikkate alınarak sinyal verileri değerlendirilip takım aşınması tahmin edilebilir. Kaydedilen sinyaller zaman frekans alanında değerlendirilebilmesi için bir sinyal dönüşümü gereklidir. Sinyallerden oluşturulan karakteristik değerler yardımıyla takım durumu belirlenebilir [21]. Geçmişte takım durumu izleme, özellikle tornalama [21] – [26], frezeleme [27], [28] ve delik delmede [29] bilimsel olarak araştırılmıştır.

Salgado ve Alonso (2007) çalışmalarında, Destek Vektör makinesi ve Tekil Spektrum analizini kullanarak, torna tezgâhı için kesici motoru akım ve ses sinyalinin veri olarak kullanıldığı bir takım durum izleme sistemi sunmuşlardır [30]. Rmili vd. (2016) tornalama işlemi sırasında titreşim sinyallerini toplamak için üç eksenli bir ivmeölçer kullanmış ve ardından özellik parametrelerini çıkarmak için ortalama güç analizini çalıştırmışlardır [31]. Torna tezgâhında gerçekleştirilen diğer bir çalışma, Upase ve Ambhore (2020) sertleştirilmiş çeliği tornalarken titreşim sinyalini toplayarak, titreşim sinyali özellikleri ile takım aşınma durumu değişikliği arasındaki bağlantıyı başarılı bir şekilde modellemişlerdir [32]. Freze tezgâhında takım aşınması tespitine yönelik çalışmada mevcuttur. Mathew vd. (2008) yüzey frezeleme işlemlerinde takım aşınmasını ölçmek için bir ses yayılımı analizi yapmışlardır. Analiz sonucunda sinyal parametreleri ile freze bıçağının yan aşınma değerleri arasında ilişki kurmuşlardır [33]. Titreşim sinyali ile hata teşhisinde, kesici uç ve motor hatalarından, olası algılama ve tanımlama sistemleri üzerine çalışmalar gerçekleştirilmiştir [34] – [38]. Dişli azdırmada takım aşınmasının iş parçası performansı üzerindeki etkisini belirlemek için sadece birkaç çalışma yayınlanmıştır [38] – [41]. Kombogiannis ve Antoniadis (2002) çalışmalarında, önerilen sayısal deneysel yaklaşımın, dişli azdırmada takım aşınma davranışını tahmin etmek ve çakı teğetsel kaydırma koşullarını optimize etmek için başarılı bir şekilde uygulanabileceğini göstermişlerdir. Kaplamalı dişler, yapılan araştırmalarda kaplamasız olanlara kıyasla daha başarılı kesme performansı gösterdiğini elde etmişlerdir. Hata teşhis alanında genellikle akım sinyallerine FFT uygulanması ile gerçekleştirilen analiz yöntemi üzerine çalışmalar yapılmıştır [42] – [50]. Sayısal işleme uygulamalarında sıklıkla tercih edilen FFT, hızlı veri işleme özelliği ile gecikmeyi en aza indirmektedir. FFT, zaman bölgesindeki noktaları frekans bölgesinde ifade etmeyi sağlayan Ayırık Fourier Dönüşümü (DTF) işleminin hızlı algoritmalarla ve yüksek verimle hesaplanma türü olmasından dolayı tercih edilmektedir. Akım sinyallerine Dalgacık Dönüşümü uygulanarak da çalışmalar yapılmıştır [51] – [57].

Literatürde genellikle tek tip sensör veya transdüser ve sabit örnekleme zamanıyla veri alma üzerine yapılmış çalışmalar mevcuttur. Azdırma işleminde dört farklı çakı durumuna bağlı ses kayıt cihazı, enkoder ve çeşitli transdüserleri eş zamanlı kullanarak, çeşitli örnekleme sürelerinde ve parça işlemenin tüm zamanında veri alma sistemine ilişkin bilimsel bir çalışma henüz yapılmamıştır.

Bu çalışmada, azdırma tezgâhlarındaki kesici uca hareketini veren motorun akım, gerilim, hız değerleri ve ses, titreşim sinyalinin çeşitli örnekleme frekanslarında, gerçek zamanlı dijital olarak elde edilmesini sağlayan sistem tasarımı geliştirilmiştir. Akım, gerilim ve titreşim verilerinden frekans genlik grafiği çıkartılmış ve çakı durumları yorumlanmıştır. Ses sinyallerinden, öznitelikler çıkartılmıştır. Çıkartılan öznitelikler Derin Öğrenme modelin eğitilmesinde kullanılmıştır. Ses analizi için model eğitildikten sonra doğrulama veri setinde test edilmiştir.

2 TEZGÂH HATALARI

2.1. Kesici Uç Hataları

Kesici takım aşınması birkaç tipte sınıflandırılabilir ve aşağıdaki gibi özetlenebilir [58]:

- kesme düzlemi deformasyonu ile ilişkili yapışkan aşınma,
- sert parçacıkların kesme etkisinden kaynaklanan aşındırıcı aşınma,
- yüksek sıcaklıklarda meydana gelen difüzyon aşınması,
- yorulma nedeniyle ufalanma gibi kırılma aşınması.

Takım aşınması süreçleri genellikle, kesme koşullarına, iş parçasına, takım malzemesine ve takım uç geometrisine bağlı olarak meydana gelir. Belirli bir kesici takım aşınma biçimi, kesme koşullarına, kesme hızına, deforme olmamış talaş kalınlığına ve yukarıda bahsedilen aşınma mekanizmalarının bir kombinasyonuna bağlı olmaktadır. Her bir aşınma türünün baskın olduğu kesme hızı aralıkları, kesme hızı ve deforme olmamış talaş kalınlığı ile doğru orantılı olarak kabul edilebilir [58]. Kesme derinliği artırılarak kesici takımın kaldırdığı talaş alanı artırılması, takım ömrünün önemli ölçüde azalmasına neden olmaktadır. Düşük kesme hızlarında, kesici takım ağırlıklı olarak kesme noktasının yuvarlanması nedeniyle aşınır ve kesici takım keskinliğini kaybeder [58]. Kesme hızının artması, takım ucunda deformasyona yol açan değişime uyum sağlamak için aşınma alanı deseni değiştirir.


Burun aşınması veya kenar yuvarlatma, ağırlıklı olarak kesici takımın ana kenarlarındaki aşınma ile meydana gelir [58]. Uç aşınması, çoğunlukla kesme koşullarına bağlı oluşan plastik veya elastik deformasyon nedeni ile takım keskinliğinin kaybolmasına bağlı olmaktadır. Yüksek kesme hızlarında, kenar plastik olarak deforme olur ve tüm ucun körelmesi ile sonuçlanmaktadır. Kırılgan takım ve termal yorulma ile yapılan aralıklı kesimlerde, kenar ufalanması ve çatlaması meydana gelmektedir. Ucun önemli ölçüde aşınması, uygun olmayan işleme koşulları veya seramik ve sinterlenmiş karbür gibi kırılgan takımların kullanılmasının sonucu olarak da ciddi arızalar meydana gelebilir.

Kesici uçlar yüksek sertlik değerlerine sahip olmalıdır. Kesme esnasında oluşacak yüksek sıcaklıklara kadar kesici kenar dayanıklılığı da önemlidir. Bu sıcaklık kesici takımın parçaya giren kısmında oluşacağından ısı birikiminin önüne geçmek adına ısı iletiminin iyi olması

takım açısından önemlidir. Kesici takımlar çeşitli nedenlerle sıklıkla özelliklerini yitirdiğinden kolay bulunabilir olmaları ve uygun maliyetle olmaları gerekir.


Talaşlı imalatta kesme hızları takım kapasitesine bağlı olup, takım ömrü ise besleme ve kesme hızına bağlıdır [58]. Kesici takımların parçaya girdiği, sürtünme gerilmesinin yüksek olduğu uç bölgelerde oyulmalar meydana gelmektedir. Bu oyuklarda gerilme yığılmaları meydana geldiğinde, talaş kaldırma işlemine devam edilir ise takım kırılmaya maruz kalabilir. Tabakalaşma aşınması denilen deformasyonda ise kesme esnasında takımda çatlaklar oluşmaktadır. Bu çatlaklarda takımın parçaya girdiği uç noktalarda yaygın olarak görülmektedir.

Yüzey aşınması yüksek kesme kuvveti ve yüksek sıcaklıkta asıl kesme bölgesinde görülmektedir (Şekil 2.1).




Şekil 2.1 Takım ucunda görülen yüzey aşınması

Sürtünmenin fazla olduğu yapışma bölgesinde aşınma oluşarak kesici ucun talaş ile ilk temas ettiği bölgenin biraz gerisinde dairesel şekilde oyuklar oluşur. Kesici uçta oluşan bu deformasyona krater aşınması adı verilmektedir (Şekil 2.2). Yüksek kesme sıcaklıkları ve yüksek kesme gerilmelerinin birleşiminden kaynaklanır. Krater oluşması kesme hızından çok kesme sıcaklığına bağlıdır. Yapışma, ısıl yumuşama ve plastik deformasyon gibi hataların kombinasyonu ile krater aşınması meydana gelebilir. Büyük krater derinlikleri, kesme noktasının ciddi şekilde çökmesini tetikleyebilir.



Şekil 2.2 Takım ucunda oluşan krater aşınması

Talaş kaldırılan yüzeyde deformasyon sertleşmesi meydana geldiğinden dolayı bu bölgede sertlikte artmaktadır. Bu sert yüzeye kesici takımın teması halinde kesme kenarında oluşan yüksek sıcaklıkla birlikte çentik adı verilen aşınmalar meydana gelmektedir (Şekil 2.3).



Şekil 2.3 Kesme ucunda oluşan çentik aşınması


Oluşan bu aşınmalarla kesici takımda gerilme yığılmalarına neden olmakta ve kesme işlemine devam edildiği takdirde kırılma, körelme veya çatlaklar meydana gelmektedir. Sistemlerin optimum performansını sağlamak için makinenin ve kesme işlemi dinamiklerinin, kesici takımların ve iş parçasının izlenmesini önemlidir. Bu nedenle, bir takım durumu izleme sistemi aşağıdaki amaçlara hizmet ettiği söylenebilir:

- tezgâh için hata algılama ve hasar önleme sistemi,
- parça işleme sürecinin kararlılığını kontrol etme ve koruma,
- parça üzerinde işleme toleransının korunduğu kabul edilebilir sınırları sağlama.

2.2. Çakı Hataları

Termal Çatlaklar:

Termal çatlaklar, çakı kesme kenarına dik olarak uzanır ve parça işleme esnasındaki aşırı sıcaklık değişimlerinden kaynaklanır. Çakı talaş kaldırdığı yüzeyde ilerledikçe sıcaklık hızla yükselir. Değişen talaş kalınlığı, kesim boyunca sıcaklığı da değiştirir. Bu sıcaklık değişimleri, kesici uçta termal çatlaklara yol açabilen ısı gerilimleri oluşturur.



Şekil 2.4 Çakı sıcaklık değişimi

Çentik Aşınması:

Çakı dişinin ön yüzünde ve yan tarafında talaş derinliği çizgisine kadar ufalanma veya lokalize aşınma oluştuğunda çakı çentik aşınması meydana gelmektedir. Çentik oluşumu öncelikle iş parçası malzemesinin durumundan kaynaklanır. Önceki bir işleme işleminden

kaynaklanan sertleştirilmiş bir dış katman veya 55 HRC' nin üzerinde ısıtıl işlem görmüş malzeme çakıda çentik oluşumuna neden olabilir.

Krater Aşınması:

Çakı dişinin üst yüzeyinin talaş ile sürtünmesi ile meydana gelen ısı, kesme kenarının arkasındaki bölgeyi yumuşatarak krater adı verilen parçacıkları oluşturur. Krater aşınmasına azdırma işleminde nadiren rastlanır. Ancak belirli çelik ve dökme demir alaşımları işlenirken ortaya çıkabilir. Krater aşınması şiddetli hale gelmesi durumunda çakıda kırılma veya körelme görülebilmektedir.

Yan aşınma:

Çakının, iş parçası ile temas halindeki yüzeyinin yoğun sürtünme etkisinden hem yapışkan hem de aşındırıcı aşınması nedeni ile ortaya çıkar [58]. Yan aşınma, yüzey kalitesinin bozulmasına, temas alanının artmasına ve bunun sonucunda ısı üretiminin artmasına neden olmaktadır. Çakı, iş parçasının yüzeyine sürtünürken kesme çizgisinin derinliğinde aşınma çentikleri oluşmaktadır.

Serbest Yüzey Aşınması:

Serbest yüzey aşınması, kesme kuvvetlerini artırmakta ve yüzey kalitesini önemli ölçüde bozmaktadır. Yanlış belirlenen hız, paso ilerlemesi ve çakı açısı aşınmaya sebep olmaktadır.

3 HATA TEŞHİS YÖNTEMLERİ

Bilgisayarlı veri toplama alanındaki dijital veri işleme ile hata tespiti için genel kullanılan yöntemler aşağıdaki gibidir.

- İmza tabanlı yöntemler [11-16]
- Modele dayalı yöntemler [22-29]
- Bilgiye dayalı yöntemler [1-3,9]

3.1. İmza Tabanlı Yöntemler

Bu yöntemin süreci sıcaklık, basınç, akım ve titreşim gibi parametreler ile spektral analizin kullanımını içermektedir. Burada zaman alanı analizi ve frekans alanı analizi uygulanmaktadır. Makine değişimleri izlenerek zaman tanımlı yöntemler uygulanır. Daha basit hesaplamalar içermesine rağmen düşük hatalara karşı duyarlıdır. İmza tabanlı yöntemlerden bazıları şunlardır:

- Hızlı Fourier Dönüşümü,
- Park Vektör Yaklaşımı,
- Bispektrum,
- Dalgacık Analizi,
- Hilbert Dönüşümü.

3.1.1. Hızlı Fourier Dönüşümü

Asenkron motorlarda hata tespiti yapmak için popüler bir yaklaşım türüdür. FFT, hızlı veri işleme özelliği ile gecikmeyi en aza indirmektedir. FFT, zaman bölgesindeki noktaları frekans bölgesinde ifade etmeyi sağlayan Ayrık Fourier Dönüşümü (DTF) işleminin hızlı algoritmalarla ve yüksek verimle hesaplanma yöntemidir. Örnekleme, ön işleme, hata tespiti ve son işleme olarak 4 aşamadan oluşur. FFT' yi pratik olarak kullanmanın zorlukları aşağıda belirtilmiştir:

- Spektral sızıntıya neden olan kısıtlı zaman penceresi,
- Yüksek frekans çözünürlüğü ihtiyacı,
- Değişken yük koşulları,
- Belirsizliğe neden olan mekanik frekanslar.

Park vektör yaklaşımı ve zarf analiz yöntemleri bu sorunların üstesinden gelmek için kullanılmıştır [10].

FFT frekans alanı analizi, sinyalin zaman alanından frekans alanına dönüştürülmesine dayanmaktadır. FFT, anlık durum izleme yönteminde kullanılan en yaygın tekniktir. Bunun nedeni, motor parametrelerinin bilgisinden, birçok mekanik ve elektriksel arıza sinyalinin frekanslarının belirlenmesidir. Bu arıza sinyalleri, titreşim, akım ve akı vb. dahil olmak üzere farklı sensör sinyallerinde görülebilir. Frekans analizi, arıza sayısı hakkında bilgi sağlamaya yardımcı olmaktadır. Bazı arızalar, benzer hata frekansları üretir ve bu nedenle aralarında ayırım yapmak için fazladan veri gerektirmektedir. FFT' nin ana avantajı, frekanslardaki büyük gürültü sinyallerinde bulunan düşük seviyeli arıza sinyalinin teşhisidir.

Genel olarak FFT yöntemi, sinyal örnekleri arasında çarpma ve toplamada hesaplama gücüne dayalı olarak oldukça hızlıdır. FFT, bir alandan başka bir alana ayrıntılı sinyal spektrum değerleri kümesini ayrıştırır. Her aşama süreci, küçük bir veri seti ile işlenebilen ve veri setinin varyasyonunu belirleyen sinyal spektrumundan oluşur [52]. FFT algoritmasının bu varyasyonu, asenkron motorlardaki hataları tespit etmek için kullanılmaktadır. FFT şu şekilde tanımlanır [47]:

$$X(k) = \sum_{n=0}^{N-1} X(n)e^{-\frac{j2\pi nk}{N}} \quad [3.1]$$

$$X(k) = \sum_{n=0}^{N-1} X(n)W_N^{kn} \quad [3.2]$$

$$W_N = e^{-\frac{j2\pi}{N}} \quad [3.3]$$

W_N , $x(n)$, N ve A sırasıyla twiddle faktörü, $K=0,1,\dots,N-1$, ayrık sinyal zaman alanı, örnek verinin olmadığı durum ve genliği ifade etmektedir.

Her frekans çizgisi, gerçek ve sanal formda karmaşık biçimde FFT işlevi tarafından hesaplanır. Asenkron motorun hem sağlıklı hem de hatalı durumları için sinyalin büyüklüğü, fazı ve güç spektrumu aşağıdaki gibi hesaplanabilir [53]:

$$sinyal\ büyüklüğü = \sqrt{gerçek[FFT(A)]^2 + sanal[FFT(A)]^2} \quad [3.4]$$

$$Faz = \arctan \left\{ \frac{sanal[FFT(A)]}{gerçek[FFT(A)]} \right\} \quad [3.5]$$

$$Güç\ spektrumu = \frac{FFT(A) * FFT^*(A)}{N} \quad [3.6]$$

Teşhis süreci, makinenin hem durağan hem de durağan olmayan süreçleri için bir bütün olmalıdır.

3.1.2. Fourier Dönüşümü

Periyodik olmayan fonksiyonları, basit trigonometrik dalgaların toplamı şeklinde gösterebilme (yapı taşlarına ayırma) ve istenildiğinde tekrar ana fonksiyona sentezleme işlemleri Fourier Dönüşümü ile gerçekleştirilmektedir. Fourier Serisi ise periyodik olan fonksiyonları yapı taşlarına ayırıp tekrar sentezlemeyi gerçekleştirmektedir.

Fourier Serisinin trigonometrik gösterimi denklem [3.7]'deki gibi görülebilmektedir:

$$f(x) = a_0 + \sum_{n=1}^{\infty} \left(a_n \cos \frac{n\pi x}{L} + b_n \sin \frac{n\pi x}{L} \right) \quad [3.7]$$

Fourier Serisinin fonksiyonunun karmaşık sayılı ifade edilmiş hali;

$$f(x) = \sum_{n=-\infty}^{\infty} c_n e^{\frac{i2\pi nx}{L}} \quad [3.8]$$

Burada L periyodu, c_n hangi büyüklükte hangi faz açıları ve hangi frekansta dalgaları kullanılacağını belirtmektedir. Denklem [3.8] sentez formülü olarak tanımlanır ise denklem [3.9]'da analiz formülü olarak tanımlanır.

$$c_n = \frac{1}{L} \int_{-\frac{L}{2}}^{\frac{L}{2}} f(x) \cdot e^{\frac{-i2\pi nx}{L}} dx \quad [3.9]$$

Fourier Serisi periyodik olan fonksiyonları yapı taşlarına ayırıp tekrar sentezlemek ile ilgilenir iken, Fourier Dönüşümü bu işlemleri periyodik olmayan fonksiyonlara da uygulayabileceğimizi göstermektedir.

$\frac{2\pi n}{L}$ açısal frekansı k_n olarak tanımlandığında, 2 ardışık açısal frekansın farkı $\Delta k_n = \frac{2\pi d_n}{L}$, $d_n = 1$ olmakta ve aslında $d_n = \frac{\Delta k_n \cdot L}{2\pi}$ eşitliğini sağlamaktadır. Tanımlanan değişkenler denklem [3.8]'de yerine konur ise;

$$f(x) = \sum_{n=-\infty}^{\infty} c_n \cdot e^{ik_n x} \cdot \frac{L}{2\pi} \Delta k_n \quad [3.10]$$

Olmakta ve $c_n \cdot \frac{L}{2\pi} = c(kn)$ denir ise yeni ifade;

$$f(x) = \sum_{n=-\infty}^{\infty} c(kn) \cdot e^{ik_n x} \cdot \Delta k_n \quad [3.11]$$

$L \rightarrow \infty$ Durumunda Δk_n çok küçülecektir ve k_n sürekli bir değişken olacaktır.

$$f(x) = \int_{-\infty}^{\infty} c(k) \cdot e^{ikx} dk \quad [3.12]$$

Fourier Dönüşümü'nün sentez formülü denklem [3.12]'de elde edilmiştir. Analiz formülü ise $c(k)$ değişkenini denklem [3.9]'da yerine yerleştirerek bulunmuş ve denklem [3.13]'de gösterilmiştir.

$$c(k) = \frac{1}{2\pi} \int_{-\infty}^{\infty} f(x) \cdot e^{-ikx} dx \quad [3.13]$$

Herhangi bir fonksiyon için $c(k)$ katsayısını hesaplaması yapılır ise Fourier Dönüşümü uygulanmış olup, $c(k)$ fonksiyonuna ters Fourier uygulayarak $f(x)$ fonksiyonunu elde edilir.

Fourier serisinde periyodu sonsuza götürerek Fourier Dönüşümü sağlanmakta ve n indeksine bağlı tanımlanan katsayı artık k açısal frekansına bağlı olarak tanımlanmaya başlamaktadır. Artık frekans kesikli değerler almak zorunda kalmayarak her değeri alabilir. Bu matematiksel modeller ile hangi tipte kosinüs dalgaları birleştirildiği, hangi frekansta dalgayı hangi büyüklükte kullanılacağı yorumlanabilir ve faz açısı ile frekans grafiği çizilebilir.

3.1.3. Dalgacık Analizi

Dalgacık Dönüşümü tekniği, ölçülen bir zaman dalga biçimi ile ana dalgacık veya temel dalgacık olarak adlandırılan önceden tanımlanmış bir şekil arasındaki karşılaştırmaya dayanmaktadır. Dönüşüm, ana dalgacıyı yeniden ölçeklendirerek ve zaman aralığında belirli şekil ile arasındaki benzerliğe bakarak yapılmaktadır. Böylece, zaman-frekans alanının 2 boyutlu bir haritası elde edilebilir ve incelenen sinyalin zamanında belirli spektral bileşenlerin yerleşimi yapılabilir.

Fourier Dönüşümü'nün kullanışlılığı, durağan sinyallerle sınırlıdır. Pencereleme tekniği olarak da bilinen teknik, zaman ve frekansın bir fonksiyonuna sinyal vererek, zaman ve frekans hakkında bilgi sağlar. FFT'de pencere sabit boyutu dezavantajından dolayı Dalgacık Dönüşümü yöntemi geliştirilmiştir [14]. Değişken boyutlu pencere kullanarak istenen düşük ve yüksek frekanslı bilgiler için uzun zaman aralıkları kullanılmasına izin verir.


Dalgacık Dönüşümü çok çözünürlüklü yapısı nedeni ile, sinyal işlemede yaygın olarak kabul görmektedir. Dalgacık Dönüşümü, bir sinyali dalgacık adı verilen bir dizi temel işleve ayırıştırır. Dalgacıklar, ana dalgacık adı verilen tek bir prototip dalgacıktan genişleme ve kaydırma yoluyla elde edilir [14].

$$\psi_{s,T}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad [3.14]$$

Burada s , ölçekleme parametresi, $\psi(t)$ ana dalgacık işlevi ve t , kaydırma parametresidir. Dalgacık Dönüşümü, farklı frekanslarda zaman alanı sinyalinin farklı bölümleri için ayrı ayrı hesaplanır. İlk ayırıştırma seviyesindeki dalgacık katsayıları, bir ana dalgacık uygulanarak analiz edilen bir sinyalden elde edilir. Ana dalgacık ölçeklenir ve çevrilirse süreç tekrarlanabilir.

Dalgacık analizi bir zaman-frekans tekniğidir. Bir sinyali hem zaman hem de frekans alanında bir dizi salınım (dalgacık) ayırıştırır [11], [13], [14]. Bu teknik, zamanla değişen veya durağan olmayan sinyal analizi için çok faydalı olan ölçekleme konsepti aracılığıyla spektral ayrışmanın yeni bir tanımını kullanır. Dalgacık analizinin ayrık versiyonu, ölçekleme ve kaydırılmış parametrelerin örneklenmesinden oluşur.

İleri DWT katsayıları, Şekil 3.1’ de gösterildiği gibi örnekleme oranlarındaki değişikliklerle ayrıık zaman alanı sinyalinin $x(n)$ ardışık düşük geçişli $g(n)$ ve yüksek geçişli $h(n)$ filtrelemesiyle hesaplanır.



Şekil 3.1 Üç seviyeli DWT ayrıştırma ağacı

Ayrıık bir sinyal $x[n]$ aşağıdaki gibi ayrıştırılabilir [51]:

$$x[n] = \sum a_{j_0,k} \phi_{j_0,k}[n] + \sum_{j=j_0}^{j-1} \sum d_{j,k} \varphi_{j,k}[n] \quad [3.15]$$

$$\phi_{j_0,k}[n] = 2^{\frac{j_0}{2}} \phi(2^{j_0}n - k) \quad [3.16]$$

$\phi_{j_0,k}[n]$: k ile kaydırılan bir $s = 2^{j_0}$ ölçeğindeki, ölçeklendirme işlevidir,

$$\varphi_{j,k}[n] = 2^{\frac{j}{2}} \varphi(2^j n - k) \quad [3.17]$$

$\varphi_{j,k}[n]$: $s=2^{j_0}$ ölçeğindeki ana dalgacık k ile kaydırılır. $a_{j_0,k}$: $s=2^{j_0}$, da yaklaşık katsayıları, $d_{j,k}$: $s=2^j$ ’de detay katsayıları, $N = 2^j$: N , $x[n]$ örneklerinin sayısıdır.

Detayları kapsayan frekans aralığının, analizin gerçekleştirileceği bantlar ile doğrudan ilişkili olduğu görülebilir.

3.1.4. Hilbert Dönüşümü

Hilbert Dönüşümü tekniği özellikle yüksüz veya düşük yük ile çalışan motorlarda frekansları tespit etmede kullanılan başarılı bir yöntemdir. Doğrusal olmayan ve durağan olmayan sinyalleri analiz etmek için kullanılmaktadır [59]. Hilbert Dönüşümü, gerçek değerli bir sinyali karmaşık bir analitik sinyale dönüştürür. Bu yöntem genlik modülasyonlu bir sinyalin, birçok yönden yararlı olan demodülasyon sinyal zarfını bulmak için kullanılabilir. Giriş sinyali frekans bileşenlerinin fazları, $-\pi/2$ radyan kaydıran bir filtre olarak düşünülebilir. Aşağıdaki formüller Hilbert Dönüşümü'nün temelini verir [59]:

$$HT(x(t)) = I(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad [3.18]$$

Burada $x(t)$, Hilbert Dönüşümü'nün sinyalidir.

Matematiksel olarak, integrali alınamayan bir fonksiyona $(1/\pi t)$ sahip belirli bir sinyalin konvolüsyonu olarak şu şekilde tanımlanabilir [59]:

$$h(t) = H\{x(t)\} = x(t) \frac{1}{\pi t} \quad [3.19]$$

Hilbert dönüşümü, FFT gibi diğer dönüşümlerin aksine etki alanında bir değişiklik içermez. Bir evrişim işleminin sonucu olduğundan hem orijinal sinyali hem de onun Hilbert Dönüşümü zamanın fonksiyonlarıdır. Hilbert Dönüşümü'nün sonucu orijinal sinyale eşdeğer değildir. Bunun yerine frekans bileşeni, orijinal sinyal frekansından 90° geride olan ve orijinal sinyalin genliği ile aynı olan farklı bir sinyaldir. Bu nedenle, orijinal sinyal ve onun Hilbert Dönüşümü ortogonaldir.

Hilbert Dönüşümünden karmaşık bir sinyal üretilir ve gerçek kısmı orijinal sinyal, hayali kısmı ise sinyalin dönüşümüdür. Bu sinyale analitik sinyal denir. Analitik sinyalin modülü, sinyalin anlık genliği, orijinal sinyal ise düşük frekanslı salınımları temsil eder. Hilbert Dönüşümü ile analitik sinyal şu şekilde tanımlanabilir [59]:

$$z(t) = x(t) + j.I(t) \quad [3.20]$$

$$A_z(t) = \sqrt{x(t)^2 + I(t)^2} \quad [3.21]$$

$$\theta_z(t) = \tan^{-1} \left(\frac{x(t)}{I(t)} \right) \quad [3.22]$$

Burada $z(t)$, aktif sinyalden oluşan analitik Hilbert Dönüşümü fonksiyonu, $A_z(t)$, $z(t)$ ' nin genliği, $\theta_z(t)$, $z(t)$ ' nin fazıdır.

Sinyalleri fiziksel olarak anlamlı bir şekilde tanımlayabilmek için anlık frekans cinsinden sunulmaları gerekir. Anlık frekans, Hilbert Dönüşümü kullanılarak elde edilir ve aşağıdaki gibi hesaplanabilen faz değişkenliği olarak temsil edilir [59]:

$$\omega = \frac{d\theta(t)}{dt} \quad [3.23]$$

3.1.5. Bispectrum

Bispectrum' dan sinyalin genliği ve fazı hakkında bilgi sağlayabileceği denklem [3.25]' den görülmektedir. Bu bilgiler hata teşhisinde kullanılır. $x(k)$ ' yı sıfır ortalamalı değişken bir sinyal, k zaman indeksi ve τ_1 ve τ_2 gecikme değişkenleridir. $x(k)$ ' nin zaman alanında üçüncü derece momenti denklem [3.24]' de, Bispectrum' u denklem [3.25]' de verilmiştir [60].


$$c_{3,x}(\tau_1, \tau_2) = E(x(k), x(k + \tau_1), x(k + \tau_2)) \quad [3.24]$$

$$c(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} c_{3,x}(\tau_1, \tau_2) \exp \{-j(\omega_1 \tau_1 + \omega_2 \tau_2)\} \quad [3.25]$$

$|\omega_1| \leq \pi$, $|\omega_2| \leq \pi$, $|\omega_1 + \omega_2| \leq \pi$ varsayılır.

Yukarıdakilerden, Bispectrum' un genlik ve sinyal fazı hakkındaki bilgileri koruduğu sonucu çıkar. Bispectrum hesaplama süreci şematik olarak Şekil 3.2'de gösterilmiştir.

Hata seviyesi arttıkça baskın Bispectrum bileşenleri artar ve bu yöntem durum teşhisi için yeterli spektral bilgi sağlayabilir (örneğin stator voltaj dengesizliği). Bunun nedeni bu tür hataların iyi ayırt edilmiş harmonik frekans bileşenlerine sahip olmamasıdır.



Şekil 3.2 Bispectrum algoritmasının akış şeması

3.2. Modele Dayalı Yöntemler

Bu metot hata varlığında, matematiksel modeller kullanarak motor davranışlarını tahmin etmeyi içermektedir. Bilgisayar simülasyonu, makinelerin elektro-mekanik etkileşimleri ve dinamik davranışları hakkında bilgi sağlayan yararlı bir yöntem olduğu kanıtlanmıştır. Modele dayalı yöntemlerin esasını bilgisayar simülasyonları oluşturmaktadır.

3.3. Bilgiye Dayalı Yöntemler


Bu yöntemin avantajı makine modelleri, yük ve motor karakteristikleri gerekli olmamasıdır. Metot, Sinir Ağları, Destek Vektör Makinelerini, Karar Ağaçlarını ve En Yakın Komşu algoritmalarını içerir. Algoritma, eğitim ve teşhis aşamalarından oluşur. Eğitim aşamasında, motor ölçümleri alınır, işlenir ve ardından özellikleri çıkarılır. Bu özellikler, tanı koymada bilgi sahibi olmaları için akıllı modelleri eğitmek ve donatmak için kullanılır.

Eğitim aşamasını tamamladıktan sonra, motordan yeni ölçümler alınarak eğitilen model için girdi olarak kullanılır. Bu aşamada eğitilmiş model tanıyı verir.

3.3.1. Sinir Ağları (NN)

Sinir Ağları (NN) temel olarak ses tanıma, örüntü tanıma, izleme ve üretim süreçlerinin kontrolü gibi çeşitli karmaşık ve yüksek düzeyde etkileşimli uygulamalarda kullanılmaktadır. Bu tekniğin avantajı, modellemenin gerçek veriler kullanılarak gerçekleştirilebilmesidir. İleri beslemeli, evrişimli, kendini düzenleyen haritalar (SOM) gibi çok sayıda sinir ağı türü vardır.

Endüstriyel uygulamalarda hata tespiti için genellikle çok katmanlı ileri beslemeli algılayıcı tabanlı Yapay Sinir Ağları (YSA) kullanılmaktadır [1], [34], [35], [52]. Çok katmanlı ileri beslemeli algılayıcının ağ diyagramı Şekil 3.3'de gösterilmektedir. Genlik ve frekansın bileşenleri girdi nöronları olarak alınır ve bu nöronlar hatayı belirlemek için karmaşık doğrusal olmayan ilişkileri kolayca eşleyebilen bir geri yayılım yöntemi kullanılarak eğitilir.



Şekil 3.3 Çok katmanlı ileri beslemeli algılayıcının ağ diyagramı

Gizli katman “tansig” olarak adlandırılan transfer fonksiyonuna, çıkış katmanı ise “logsig” olarak adlandırılan transfer fonksiyonlarına sahiptir. Hataları tespit etmek için giriş ve çıkış verileri karşılaştırılarak sonuçlar üretilir ve ardından minimum hata değerine kadar ortalama kare hatası (Mean Squared Error) hesaplanabilir. YSA biyolojik sinir ağlarından esinlenmiştir. Yapı taşları, nöronlar olarak bilinen işlem birimleridir. Nöronlar, ağırlıklı bağlantılar boyunca birbirlerine sinyaller göndererek etkileşime girmektedir. Kopyalama yetenekleri ile doğrusal olmayan sistemlerin işlenmesinde fonksiyon girdi değerine göre bir çıktı kararı vermektedir. YSA ilk olarak bir dizi eğitim verisi kullanılarak eğitilir.

Başta sinir ağıları yanlış çıktı sonuçları verir. Bir hata miktarı ölçülür ve nöronlar arasındaki bağlantıları değiştirmek için kullanılır. Bu işlem tekrarlanır, bağlantıların gücünü değiştirmek için istenen aktivasyon fonksiyonu elde edilerek, eğitimden sonra sistem hataları doğru bir şekilde tanımlayabilen bir bilgi birikimine sahip olur.



4 MATERYAL VE METOT

Kontrol sistemlerinde kontrol performansını negatif olarak etkileyen her türlü etkiye bozucu adı verilmektedir. Motor viskoz sürtünmelerinin değişimi, çakıdaki deformasyon, işlenen malzemenin sertliğindeki değişimler, toplam net torkun değişmesine sebep olan bozucu etkililerdir. Hız kontrolü yapılan kapalı çevrim bir sistemde, bozucu etkilerden kaynaklanan hız hatasını düzeltmek motorun ürettiği mekanik torkun (M) değiştirilmesi ile sağlanmaktadır.

$$M = Km. \Phi. I \quad [4.1]$$

Burada M moment, Km motor sabiti, Φ manyetik akı, I akımdır. Motor sabiti ve manyetik akı sabit değerler olup tork akımla doğru orantılı değişim göstermektedir. Buradan yola çıkarak akıma bağlı çakının zorlandığı noktaları keşfedip hangi zamanda akımın pik olduğunu ve sinyal incelemesi çalışmanın önemli kısmını oluşturur.

Çakı malafası üzerine titreşim transdüseri, motorun herhangi faz kablosuna akım transdüseri, motor faz-nötr arasına gerilim transdüseri ve çakı miline enkoder bağlanarak veriler alınmıştır.


Çalışma akım, gerilim, ses, hız ve titreşim değerlerinin karakteristik noktalarını tespit etmek, sinyalin özelliğini çıkarmak ve daha sonra hatayı teşhis etmek üzerine sistem tasarımından oluşmaktadır. Aynı zamanda takımdaki problemlerin tespiti sayesinde oluşabilecek hatalar hakkında hata meydana gelmeden önce bilgiye sahip olunmasını ve uçta gerekli bakım/onarım yapılarak motorun daha verimli ve daha uzun ömürlü olması, işlenen parçalarda hurda ve hatalı iş sayısının azaltılması amaçlanmıştır. Ayrıca çakıya hareketini veren 3 fazlı, 7.5 kW, 400 volt, 15 Amper, 960 devirli AC motoru üzerinden, çakının zorlanmadan parçaya girdiği ve işlediği sinyalleri belirleyerek o değerleri koruyacak mekanik sistemin sağlanması amaçlanmıştır.

4.1. Veri Toplama

Yüksek üretkenliği nedeni ile dişli azdırma, silindirik dişlilerin yumuşak işlenmesi için en sık kullanılan üretim süreçlerinden biridir. Optimize edilmiş bir üretim sürecinin ana hedeflerinden biri, üretim maliyetlerini en aza indirirken gerekli bileşen kalitesini korumaktır. Her iki durumda da takım aşınması bilgisi büyük önem taşımaktadır.


Takım durumu izleme, işlem sırasında takım aşınmasını izlemek için metodik bir yaklaşım sağlamaktadır. Testler sırasında kaydedilen sinyal verileri frekans alanında işlenerek çeşitli parametrelere göre değerlendirilmiştir. Sonuçlara dayalı olarak, sinyal verileri ile proses koşulları arasındaki ilişkiler hakkında açıklamalar yapılmıştır. Takım durumunun kesin bir değerlendirmesi için birkaç transdüserin kombinasyonu gerekmektedir. Özellikle, akım, gerilim, titreşim transdüserlerinin yanı sıra çakıya yakın bölgeden alınan ses sinyalleri artan aşınma ile birlikte artan genlik değerlerini göstermektedir.

İş parçasının teknik resmine (şekil 4.1) göre belirlenen çakı, uygun bağlama aparatları ile çakı miline bağlanmıştır. Açılacak dişli tipine (düz dişli) göre çakı açısı belirlenmiştir. Dişlinin açılabilmesi için çakı diş derinliği, açılacak diş derinliğine uygun olup olmadığı kontrol edildikten sonra, ilerleme ve paso hız değerleri operatör ekranından girilmiştir. Tezgâh, şanzıman sistem olduğundan eksen hareketi ve ayna tablası dönme hareketi birbirine geçen dişli çarklar sayesinde gerçekleşmektedir. Parça işleme 100 rpm paso hızında, 24 dakikada gerçekleştirilmiş ve bu işlem kırık, körelmiş, yanık ve sağlam çakılar takılarak tekrar edilmiştir. Düz dişli açma sürecinde iş parçasının ekseni ile dişlerinin yönü paralel konumda olup, iş bitinceye kadar kesme soğutma sıvısı kullanarak çakının zorlanmadan parçaya girmesi ve düzgün yüzey elde edilmesi sağlanmıştır.



Şekil 4.1 İş parçası teknik resmi


Akım transdüserinin içinden, çakıya hareketini veren asenkron motorun herhangi faz kablosu geçirilerek motorun akımı ölçülmüştür. Akımı ölçülen motor faz ucu ile motor nötr bağlantısı arasına gerilim transdüseri bağlanarak, motor gerilimi ölçülmüştür. Çakıya yakın titreşimin yoğun olduğu bölgeden vibrasyon transdüseri ile çakı titreşimi ölçülmüştür. Çakı miline enkoder bağlanarak çakı hızı ölçülmüştür. Akım, gerilim, titreşim transdüserlerinden ve enkoderden okunan analog ham veriler (12 bit çözünürlükte), ARM tabanlı (ARM Cortex-M3) mikrodenetleyiciye bağlı SD kartın içine kaydedilmiştir. Bilgisayar üzerinde oluşturulan C++ kodlarıyla yazılmış EXE uzantılı uygulama aracılığı ile okunan ham veriler, SD karttan bilgisayara aktarılmıştır. Ham veriler ölçülen niceliklere dönüştürülmüştür. Daha sonra bu veriler CSV formatına dönüştürülmüştür. Tablo haline getirilen bu veriler çalışmada yorumlanmıştır (bkz. Tablo 2). Kırık, körelmiş, yanmış ve sağlam çakı durumlarında örnekler alınmış ve toplanan veriler neticesinde kesici takımın durumu yorumlanmıştır.



Şekil 4.2 Hata tespiti akış şeması

Deneydeki transdüserler gerçek ölçüm yapmaktadır (True-RMS). RMS, alternatif akım dalga formunun eşdeğer doğru akım değerini hesaplar (RMS: kare ortalamalarının kökü).

Gerilim transdüserinin ölçtüğü nicelik AC 0-500 Volt ve transdüser üzerinden ayarlanan değer AC 0-500 Volttur. Gerilim transdüserinin beslemesi şebekeden 220 volt AC gerilimi olup çıkışı ise 0-5 Volt DC aralığındadır.




Şekil 4.3 Gerilim transdüseri giriş-çıkış değerleri grafiği


Mikrodenetleyici kart giriş gerilimi maksimum 3.3 volt olup, gerilim transdüserinin çıkışı maksimum 5 Volt olması endişe verici bir durum değildir. Çünkü motorun herhangi bir fazı ile nötrü arası gerilimi olan 220 V (şebeke gerilimi) için enterpolasyon işlemi (denklem [4.2]) uygulandığında transdüserin 2.2 Volt çıkış verdiği ve bu değerinde mikrodenetleyici kartın maksimum giriş gerilimi olan 3.3 voltun altında olduğu görülmektedir.

$$Y = Y_1 + \frac{(Y_2 - Y_1)}{(X_2 - X_1)} \cdot (X - X_1) \quad [4.2]$$

Akım transdüseri 0-100 Amper aralığını ölçmektedir. Ancak asenkron motorun çektiği maksimum akım 15 Amper olduğu için ölçüm aralığını transdüserde 0-50 Amper aralığına getirildi. Akım transdüserin beslemesi 24 Volt DC gerilimi olup çıkışı ise 0-5 Volt DC gerilimi aralığındadır. Motor fazının üzerinden geçen akım maksimum 15 Amperdir. Bu durumdaki akım transdüserinin çıkış değeri enterpolasyon işlemi uygulandığında 1.5 Volt olup, mikrodenetleyici kart giriş gerilimi olan 3.3 Voltun altında olduğu saptanmıştır.




Şekil 4.4 Akım transdüseri giriş-çıkış değerleri grafiği



Şekil 4.5 Sinyal verilerinin alınması


VTV 121 transdüserinin beslemesi 9,6-32 Volt DC gerilimi aralığında olup (24 volt), 0-50 mm/s aralığını ölçmekte ve bu değeri 4-20 mA aralığına dönüştürmektedir.



Şekil 4.6 Vibrasyon transdüseri giriş-çıkış değerleri grafiği

Transdüserin 4-20 mA aralığındaki akım çıkışı HW-685 akım-gerilim dönüştürücüsü kullanılarak 0-3,024 Volt DC gerilime dönüştürülmüştür. Bu dönüşüm, devreden 24 volt DC gerilim geçirilerek, bağlanan trimpot ile direnç değeri belirlenmiş olup, alt (4 mA) ve üst akım (20 mA) değerleri için çıkış gerilimi ise dönüştürücü üzerinden sabitlenerek belirlenmiştir. Dönüştürücü çıkışının alt ve üst gerilim değerleri dönüştürücü üzerindeki trimpottan ayarlanabilmektedir.

$24V = 4mA \times R_1$ Akımın alt değeri için $R_1 = 6k\Omega$ bağlanan trimpottan ayarlanmıştır. Bu noktadaki dönüştürücü çıkışının alt gerilim değeri dönüştürücü üzerindeki trimpottan 0 mV olarak sabitlenmiştir.



Şekil 4.7 Dönüştürücü çıkışının alt gerilim değeri ayarlanması

Daha sonra 5, 6, 7, 8,...,20 mA' e kadar akım değerlerindeki çıkış gerilimleri ölçülerek dönüştürücünün lineer çıkış verip vermediği kontrol edilmiştir (Tablo 1).

Tablo 1. Dönüştürücü giriş-çıkış değerleri

mA	mV
4	0
5	189
6	378
7	567
8	756
9	945
10	1134
11	1323
12	1512
13	1701
14	1890
15	2079
16	2268
17	2457
18	2646
19	2835
20	3024

Tablo 1' de akım değerlerine karşılık elde edilen çıkış gerilim değerleri göz önünde bulundurulduğunda dönüştürücünün lineer çıkış verdiği anlaşılmaktadır.

$24V = 20mA \times R_2$ Akımın üst değeri için $R_2 = 1,2k\Omega$ bağlanan trimpottan ayarlanmıştır. Bu noktadaki dönüştürücünün çıkışının üst gerilim değeri 3024 mV olduğu görülmektedir.



Şekil 4.8 Dönüştürücü çıkışının üst gerilim değeri ayarlanması

Mikrodenetleyici kartın A0 pinine vibrasyon transdüseri, A1 pinine akım transdüseri ve A2 pinine gerilim transdüseri bağlanmıştır. Kartın beslemesi 12 volt DC gerilimi olup, bu gerilim kart üzerindeki dahili regülatör sayesinde 5 Volt ve 3.3 Volta dönüştürülmektedir.

Mikrodenetleyici kartın analog girişleri olan A0, A1 ve A2 pinleri 12 bit çözünürlükte çalışmaktadır. n Bit sayısı olmak üzere $2^n = 2^{12} = 4096$ en yüksek olan sayı ve 0-3.3 Volt aralığında $3.3V/4095 = 805,860 \mu V$ hassasiyetinde kart değer okuyabilir.

ARM Cortex M-3:

ARM tabanlı işlemciye sahip olduğu için veri alma kısmında ARM Cortex-M3 mikrodenetleyicili kart tercih edilmiştir. ARM tabanlı denetleyiciler hızlıdır. Genellikle çalışma frekansı 200 MHz'in altında olan ARM Cortex M serisi, daha düşük maliyetlerde daha yüksek enerji verimliliğini gerektiren gömülü sistem uygulamaları için tasarlanmıştır. M serisi MPU (Memory Protection Unit) hafıza koruma birimi ve NVIC (Nested Vectored Interrupt Controller) kesme özelliklerine sahiptir. Kesme işlemi yazılmış bir programın akışı dışında belirtilen fonksiyona giderek, o fonksiyonu yerine getirdikten sonra normal akışına dönmektedir. NVIC özelliğine sahip işlemcilerde birden fazla kesme iç içe çalışabilmektedir. Düşük güç tüketimli, küçük ama performans gerektiren gömülü sistem uygulamaları için komut kümesi geliştirilmiş bir işlemcidir. Donanımsal bölücü ve çarpıcı akümülatör MAC (Multiply Accumulate) komut kümesine sahip olması performansını önemli ölçüde artırmıştır. Ek olarak program geliştirmeyi kolaylaştıran kapsamlı bir hata ayıklama özelliğine sahiptir.

ARM 'ın entegre olduğu mikrodenetleyici kart, birçok donanımı bağlayacak sayıda pine sahiptir. Mikrodenetleyici kart beslemesi 12 volt DC gerilimi olup, bu gerilim dahili regülatör sayesinde 5 volt ve 3.3 volta dönüştürülmektedir.

Tablo 2'de soldaki 3 sütun 12 bitlik ham verileri göstermektedir. Ortadaki 3 sütun ham verilerin mikrodenetleyici karta giren karşılıklarını ve en sağdaki 3 sütun ise sahada ölçülen RMS değerleri göstermektedir.

Tablo 2. Ham veriler ve ölçülen değerler

Gerilim Hz	Akım Hz	Vibrasyon Hızı Hz	Gerilim ADC	Akım ADC	Vibrasyon Hızı ADC	Gerilim RMS	Akım RMS
1215	965	149	0,978882	0,777466	0,120044	97,888184	7,774658
1650	970	124	1,329346	0,781494	0,099902	132,93457	7,814941
1653	956	137	1,331763	0,770215	0,110376	133,17627	7,702148
1650	980	136	1,329346	0,789551	0,10957	132,93457	7,895508
1650	964	280	1,329346	0,77666	0,225586	132,93457	7,766602
1654	969	302	1,332568	0,780688	0,243311	133,256836	7,806885
1651	999	101	1,330151	0,804858	0,081372	133,015137	8,048584
1653	969	290	1,331763	0,780688	0,233643	133,17627	7,806885
1651	932	455	1,330151	0,750879	0,366577	133,015137	7,508789
2127	981	0	1,713647	0,790356	0	171,364746	7,903564
1648	954	179	1,327734	0,768604	0,144214	132,773438	7,686035
1661	945	206	1,338208	0,761353	0,165967	133,820801	7,613525
1655	997	182	1,333374	0,803247	0,146631	133,337402	8,032471
1555	1010	53	1,252808	0,813721	0,0427	125,280762	8,137207
1648	970	162	1,327734	0,781494	0,130518	132,773438	7,814941
1650	993	160	1,329346	0,800024	0,128906	132,93457	8,000244
1652	949	126	1,330957	0,764575	0,101514	133,095703	7,645752
1644	807	0	1,324512	0,650171	0	132,451172	6,501709
1652	998	145	1,330957	0,804053	0,116821	133,095703	8,040527
1651	967	203	1,330151	0,779077	0,16355	133,015137	7,790771

Gerilim için 1.sütun 1.satırdaki ham gerilim değerinin dönüşümü; $\frac{1215}{4096} \times 3,3 = 0,978882$ Volt gerilim cinsinden çıkış elde edilir (3,3 volt mikrodenetleyici kart giriş gerilimidir). Gerilim transdüseri 0-500 Volt AC gerilimine karşılık 0-5 Volt DC çıkış gerilimi ürettiğinden interpolasyon ile 100 Volt AC gerilimine karşılık 1 Volt DC gerilimi denk geldiği saptanmıştır. Dolayısıyla $100 \times 0,978882 = 97,8882$ sahada ölçülen RMS gerilim değerini elde edilir.

Akım için 1.satır 2.sütundaki ham akım değerinin dönüşümü; $\frac{965}{4096} \times 3,3 = 0,777466$ volt gerilim cinsinden çıkış elde edilir. Akım transdüseri 0-50 amper akıma karşılık 0-5 volt DC çıkış gerilimi ürettiğinden interpolasyon ile 1 volt DC çıkış gerilimine karşılık 10 amper akım denk geldiği saptanmıştır. $10 \times 0,777466 = 7,77466$ Amper sahada ölçülen RMS akım değerini elde edilir.

Vibrasyon için 1.satır 3.sütundaki ham vibrasyon değerinin dönüşümü; $\frac{149}{4096} \times 3,3 = 0,120044$ Volt gerilim cinsinden çıkış elde edilir. Vibrasyon transdüserinin 0-50 mm/s titreşime karşılık 4-20 mA çıkışı, dönüştürücü ile 0-3,024 Volt DC çıkışı ürettiğinden interpolasyon ile 1 volt DC çıkış gerilimine karşılık 16,534 mm/s titreşim değeri denk geldiği saptanmıştır. $16,534 \times 0,120044 = 1,984854$ mm/s Sahada ölçülen RMS titreşim değeri elde edilmiştir.

Çalışmada, .mat formatında (veriler MATLAB 'ın yapısal dizi formatında saklanmaktadır) mevcut olan veri tabanından gelen sinyal verileri ele alınmaktadır. C++ programı, sinyalleri almak ve CSV formatlarına dönüştürmek için kullanılmıştır. Ayıklanan veri kümesindeki her bir CSV dosyası, farklı çakılarda işlenen parça durumunda titreşim, akım, gerilim ve ses verilerinin değerlerini içermektedir. Tüm prosedür iki ana bölümden oluşur: özellik çıkarma ve hata sınıflandırması.

4.2. Özellik Çıkarma

Ham verilerden faydalı verileri çıkarmak için uygun bir sinyal işleme tekniği seçilmelidir. Bu durum için genellikle zaman alanı, frekans alanı ve zaman-frekans alanı teknikleri gibi farklı özellik çıkarma teknikleri kullanılmıştır. Bu çalışmada, ses özellikleri ham verilerden çıkarmak için frekans alanı analizi kullanılmıştır.

Özellik çıkarımı, ses içeriğinin değerlendirilmesinde ve karakterize edilmesinde hayati bir role sahiptir. Ses özellikleri, ses sinyali çerçevelerinden çıkarılır. Kolay uyarılana bilirlilik, gürültüye karşı duyarlılık, kolay uygulama ve gerekli yumuşatma ideal özellik (Feature) nitelikleridir. Özellik alanı boyutlarının sayısı, çıkarılan özelliklerin sayısına eşittir. Seçilen özelliklerin sayısı çok fazla ise, boyutluluk sorunu oluşur. Özellikler, temporal, spektral ve prosodic özellikler olarak sınıflandırılmaktadır. Temporal özellikler, analiz için doğrudan ses sinyali dalga biçimini belirlemektedir. Düşük seviyeli özellikler genellikle ses sinyalinin Spektral analizi (frekans alanı) yoluyla çıkarılır. Prozodik özellikler, işitsel algı bağlamında anlamsal bir kavrama sahiptir. Bir özellik çıkarılır çıkarılmaz, herhangi bir sınıflandırıcı, örnekleri uygun gruplar halinde sınıflandırmak için prozodik özellikleri kullanabilir.

Ses sinyallerinin frekans alanı analizi, fiziksel sinyallerin, matematiksel fonksiyonların veya zaman serisi verilerinin frekans bağlamında incelenmesidir. Bir frekans aralığı, sinyalin ne kadarının belirli bir frekans bandı içinde yer aldığını gösterir. Frekans alanı, frekans bileşenlerini yeniden birleştirmek ve orijinal zaman sinyalini elde etmek için her sinüzoid uygulanması gereken faz kaymasını içerebilir. Fourier Dönüşümü gibi teknikler genellikle zaman serisi sinyalini frekans alanına dönüştürmek için kullanılır. FFT, sinyal verilerinin frekans bileşenlerini tahmin eden ham sinyale uygulanır. Daha sonra özellikler, sinyal verilerinden bir saniyelik bir pencereye dayalı olarak tahmin edilir.

Modelde kullanılan öznelikler aşağıdaki gibidir.

4.2.1. Spektral Özellik

Çoğunlukla sesi, konuşmacıyı ve dili tanıma işlemi Spektral Özellikler ile sağlanmaktadır. Spektral hesaplama, üç işlemin bir bileşimidir: Fourier Dönüşümü, logaritma ve ses sinyalinin temel frekansının tanımlanmasına izin veren Ters Fourier Dönüşümü. Ses sinyali genellikle önce vurgulanır ve ardından düzgün bir pencere işlevi ile (Hamming) çarpılır. Ayırık Fourier Dönüşümü' nün (DFT) sınırlı uzunluktaki sonuçları nedeniyle pencere işlevi gereklidir. Hızlı Fourier Dönüşümü (FFT), bir ses sinyalini frekans öğelerine ayırmaktadır.

4.2.2. Doğrusal Tahmin

Doğrusal Tahmin, ses sinyallerindeki fazlalıktan yararlanan güçlü bir spektrum tahmin tekniğidir.

Doğrusal Tahmin denklemi şu şekilde tanımlanır [62]:

$$\overline{s[n]} = \sum_{k=1}^p a_k s[n-k] \quad [4.4]$$

Burada $\overline{s[n]}$ tahmin edilen örneği, a_k doğrusal tahmin katsayısını ve $s[n]$ algılanan sinyali temsil etmektedir. Doğrusal Tahmin' in temel amacı, denklem [4.5] ve denklem [4.6]' da belirtilen hata sinyali çıkarımını en aza indiren Doğrusal Tahmin katsayılarını hesaplamaktır [62].

$$e[n] = s[n] - \overline{s[n]} \quad [4.5]$$

$$e[n] = s[n] - \sum_{k=1}^p a_k s[n-k] \quad [4.6]$$


Minimum tahmin hatası elde etmek için, toplam tahmin hatası şu şekilde temsil edilir [62]:

$$E = \sum_{N=-\infty}^{\infty} e^2(n) \quad [4.7]$$

Tahmin katsayısı a_k kendi başına bir özellik olarak kullanılabilir.

4.2.3. Gamaton Kepstral Katsayıları (GTCC)

Gamaton Kepstral Katsayıları (GTCC) özellik çıkarımı, Mel-Frekans Kepstral Katsayıları özellik çıkarımı şemasına benzemektedir. Ses sinyali önce genellikle 10-50 msn' lik kısa çerçeveler halinde pencereleir. Bu işlemin iki yönlü bir amacı vardır. İlki durağan olmayan ses sinyalinin bu kadar kısa bir aralık için durağan olduğu varsayılabilir. Böylece spektro-zamansal sinyal analizini kolaylaştırır.



Şekil 4.9 GTCC blok diyagramı

Diğeri ise özellik çıkarma işleminin etkinliği artırılır [53]. Daha sonra, GT filtre bankası (birkaç GT filtresinin frekans yanıtlarından oluşur), algısal olarak anlamlı ses sinyali frekanslarını vurgulayarak, sinyalin Hızlı Fourier Dönüşümü' ne uygulanır. Son olarak, ses yüksekliği algısını modellemek ve logaritmik sıkıştırılmış filtre çıkışlarını ilişkilendirmek için log fonksiyonu ve Ayrık Kosinüs Dönüşümü (DCT) uygulanır. Böylece daha iyi enerji sıkıştırması sağlanır.


4.2.4. Perde Sıklığı

Perde Sıklığı, ses veya konuşma sinyallerinin en kritik prozodik özelliğidir. Veriler, Spektral Zarf özellikleri gibi diğer segmental ses korelasyonları üzerinden daha uzun zaman ölçeklerinde iletilir. Bu nedenle, perde miktarının kendisini kullanmak yerine, tüm ses sinyalleri üzerinden perdenin genel statğine (ortalama, maksimum ve standart sapma olarak) yaklaşmasına izin verilir.

4.2.5. Mel-Frekans Kepstral Katsayıları (MFCC)

Mel Frekans Kepstral Katsayıları (MFCC), ses tanımada en çok kullanılan öznetelik çıkarma metodolojilerinden biridir. Mel Frekans Kepstral Katsayılarının kullanımı, özellik çıkarımı için standart yöntemlerden biri olarak kabul edilebilir. Otomatik ses tanımada (ASR) yaklaşık 20 MFCC katsayısının kullanımı yaygın olmasına rağmen 10-12 katsayılarının sesi kodlamak için genellikle yeterli olduğu düşünülür [61], [62].

MFCC kullanmanın en önemli dezavantajı, spektral forma bağlı olması nedeniyle gürültüye duyarlılığıdır. Konuşma sinyallerinin periyodikliğindeki bilgileri kullanan yöntemler bu sorunun üstesinden gelmek için kullanılabilir. Şekil 4.10, MFCC özellik çıkarımı ile ilgili adımları göstermektedir.



Şekil 4.10 MFCC özellik çıkarımı

MFCC özellikleri, LOG filtre bankası enerjilerinin Cepstrum' una karşılık gelir. Bunları hesaplamak için, LOG enerjisi önce filtre bankası çıktılarından şu şekilde hesaplanır [62]:

$$S_t[m] = \ln \left(\sum_{n=0}^{N-1} |X_t[n]|^2 H_m[n] \right) \quad 0 \leq m < M \quad [4.8]$$

Burada $X_t[n]$, t' inci giriş ses çerçevesinin Ayrık Fourier Dönüşümü, $H_m[n]$, filtre bankasındaki m' inci filtrenin frekans yanıtı, N, dönüşümün pencere boyutu ve M, toplam filtre sayısıdır. Daha sonra, LOG enerjilerin ayrık kosinüs dönüşümü (DCT) şu şekilde hesaplanır [62]:

$$c_t[m] = \sum_{n=0} S_t[n] \cos(\pi m(n - v.c)M) \quad 0 \leq m < M \quad [4.9]$$

Katsayıların zaman içindeki değişimini yakalamak için sırasıyla birinci ve ikinci fark katsayıları hesaplanmıştır.

$$\Delta c_t = c_{t+1} - c_{t-1} \quad [4.10]$$

$$\Delta \Delta c_t = \Delta c_{t+1} - \Delta c_{t-1} \quad [4.11]$$

Bu dinamik katsayılar daha sonra statik katsayılarla birleştirilir. Dinamik katsayılar daha sonra t' inci ses çerçevesini temsil eden özellik analizinin nihai çıktısını oluşturmaya göre c_k statik katsayıları ile birleştirilir.

$$X_t = [c_t \ \Delta c_t \ \Delta \Delta c_t]^T \quad [4.12]$$

Frekans bantları MFCC’ de logaritmik olarak konumlandırıldığından, diğer sistemlerden daha avantajlıdır. Ancak MFCC değerleri, ek gürültü varlığında çok güvenilir değildir [62].

MFCC, telefona söylenen sayıları otomatik olarak tanıyabilen sistemler gibi konuşma tanıma sistemlerinde yaygın olarak kullanılır. İnsanları seslerinden tanıma görevi olan konuşmacı tanımada da yaygındır.

Mel Frekans Kepstral Katsayılarının Deltası ve Delta-Deltası, makine öğrenimi ve derin öğrenme uygulamaları için genellikle MFCC ile birlikte kullanılır. MFCC işlevini kullanarak bir ses sinyalinin Mel Frekans Kepstral Katsayıları hesaplanmaktadır. İşlev, katsayılardaki değişiklik olan Delta’ yı ve Delta değerlerindeki değişiklik olan Delta-Delta’yı döndürmektedir. Fonksiyonun hesapladığı “Log Energy” değeri, katsayılar vektörünün başına gelebilir veya katsayılar vektörünün ilk ögesini değiştirebilir. Bu, “Log Energy” bağımsız değişkenini “ekleme” veya “değiştirme” olarak ayarlanmasına bağlı olarak yapılır.

Delta hesaplaması birinci boyut boyunca çalışır. Diğer tüm boyutlar bağımsız kanallar olarak ele alınır. Bir ses özelliği x' in deltası, geçerli örnekten önce M örnek ve geçerli örnekten sonra M örnek içeren $x(k)$ örneğini merkez alan bir bölgenin yerel eğiminin en küçük kareler yaklaşımıdır.

$$\text{delta} = \frac{\sum_{k=-M}^M k x(k)}{\sum_{k=-M}^M k^2} \quad [4.13]$$

Delta pencere uzunluğu, $-M$ ile M arasındaki bölgenin uzunluğunu tanımlamaktadır.

MFCC ve Doğrusal Öngörü Katsayıları gibi kepsral tabanlı özelliklerin, temporal özelliklere kıyasla daha iyi sınıflandırma doğruluğu sağladığını gözlemlenmiştir.

4.2.6. Yayılı Spektrum

Belirli bir bant genişliğinde üretilen enerjinin kasıtlı olarak frekans alanında yayıldığı ve daha geniş bir bant genişliğine sahip bir sinyale dönüştüğü yöntemdir.

4.2.7. Spektral Entropi

Spektral entropi, bir bilgi kaynağının ortalama belirsizliği olarak yorumlanan ve denklem [4.14]’e dayanan bilgi içeriğini ölçmektedir [62].

$$H(x) = - \sum_{i=1}^N p(x_i) \log_2 p(x_i) \quad [4.14]$$

Burada $p(x_i)$ bir olasılık dağılımı ve N çerçeve sayısıdır.

4.2.8. Spektral Merkez

Spektral Merkez, dijital sinyal işlemede frekans spektrumunu karakterize etmek için kullanılan bir metriktir. Frekans spektrumunun "merkezinin" nerede olduğunu gösterir. Sinyal değeri ne kadar küçükse, düşük frekans aralığında o kadar fazla enerji yoğunlaşır. Sinyal dağıtımını sırasında, spektral enerjinin ortalama noktası veya orta noktası Spektral Merkez olarak adlandırılır. Baskın sinyal frekansının zaman içinde nasıl değiştiğini temsil eden parazite dayanıklı tahmin sağlar. Bu nedenle Spektral Merkez, konuşma işleme gibi bazı sinyal işleme uygulamalarında popüler bir araçtır. Spektral Merkez, ses frekansı yayılımının merkezini temsil eder. Yani ses sinyali parlaklık ölçümünü ifade eder ve denklem [4.15]'deki gibi ifade edilir [62].

$$SC = \frac{\int_0^k w\omega |F(\omega)|^2 d\omega}{E} \quad [4.15]$$

Burada frekansın ω_k olarak ayarlandığı ($\omega = \omega_k$), ω_k merkez frekansı, E enerji, $|F(\omega)|^2$ ses sinyalinin güç spektrumudur. Merkez frekansı, analiz penceresinde konuşma ve müzik arasında ayrım yapmayı sağlamaktadır.

4.2.9. Eşit Dikdörtgen Bant Genişliği (ERB)

İnsan işitsel filtrelerinin bant genişliğini yaklaşık olarak tahmin etmek için kullanılan bir ölçüdür.

4.2.10. Bark Ölçeği

İnsan işitmesinin kritik bantlarının her biri bir Bark genişliğine sahip olacak şekilde tanımlanır. Bark Ölçeği üzerinde spektral enerjiyi (dB cinsinden) temsil ederek, kulakta spektral bilgi işleme ile daha yakın bir uyum elde edilir.

4.3. Sinyal Analizi ve Aşamaları

İlk olarak farklı çakı durumlarına ait “kırık”, “yanık”, “sağlam” ve “kör” olmak üzere 4 farklı çakı durumu tipleri için hazırlanan test ortamı yardımıyla 20 dakikalık örnek ses dosyaları

.mp3 formatında kaydedilmiştir. Kaydedilen ses dosyaları MATLAB aracı ve “Audio Toolbox” yardımcı ile 44100 örnekleme frekansında çalışma ortamına aktarılmıştır. Aktarılan ses dosyaları için çıkarılacak öznitelik ve örneklem sayısı, analiz aşamasında kullanılacak bilgisayar için oldukça yüksek performans ve kapasite değerleri gerektirmesinden dolayı, down sample 0.8 azaltılmış ve çıkarılan öznitelikler üzerinden, tüm veri kümesi özelliklerini taşıyan ideal seviyede örneklem alınmıştır.

Sinyal sınıflandırma analizlerinde kullanılan ve sinyal sınıfını tanımlamada ayırıcı korelasyon değerleri sunan “mfcc”, “pitch”, “spectralCentroid”, “linearSpectrum”, “melSpectrum”, “barkSpectrum”, “erbSpectrum”, “gtcc”, “spectralEntropy” ve “spectralSpread” özniteliklerinden oluşan 10 adet öznitelik, bu sinyal sınıflandırma analizinde ana öznitelikler olarak seçilmiştir.

Analiz için kullanılan ses dosyalarının türleri (.mp3) aynı olmasına rağmen kayıt sürelerinin farklı olmasından dolayı seçilen örneklem sayıları farklıdır. Bu durumun geliştirilecek makine modelinde sınıfsal yanlılığa neden olacağı öngörülerek, her farklı sınıftan eşit sayıda (1734) örneklem alınmış ve sınıfsal denge sağlanmıştır.

Analiz sırasındaki işlemler sırasıyla aşağıdaki gibi gerçekleştirilmiştir:

İlk olarak kaydı alınan ses dosyaları MATLAB uygulaması içinde yer alan “Audio Toolbox” yardımcı aracı ile çalışma ortamına yüklenmiştir. Sonrasında her ses kaydı stabil ses örnekleme frekansında (44100), 0.8 oranında azaltılarak örneklem sayısı kısaltılmıştır.

Sisteme yüklenen, veri kısaltma ve düzenleme işlemleri her bir sinyal için daha önce belirtilen 10 öznitelige ek “Window” ve “SampleRate” öznitelikleri de eklenerek, analizi yapılan tüm sinyaller için öznitelik çıkarımı sağlanmıştır. Bu işlem sonunda 4 farklı sınıfa ait 1734*17779 olacak şekilde 4 farklı öznitelik haritaları elde edilmiştir. Öznitelik haritalarından her sınıf için eşit oranda örneklem alınarak sınıf dengesi sağlanmış ve yanlılık (bias) etkisi azaltılmıştır.

Ön işleme yapılan 4 sınıfa ait (kor, kırık, yanık, sağlam) 4 farklı veri seti için “Hedef” kolon başlığı altında etiket sınıfları oluşturulmuş ve ait olduğu veri seti içine yerleştirilmiştir. Bu şekilde ilk olarak ses dosyası halinde alınan veriler MATLAB çalışma ortamında Feature’ lar yardımıyla sayısal değerlere dönüştürülmüş ve etiketlenerek sınıflanma modeli için hazır hale getirilmiştir.

Hazırlanan 4 farklı veri “data” adı altında tek bir veri kümesi olarak birleştirilmiş ve daha sonrasında %85-%15 oranlarında olacak şekilde eğitim-doğrulama veri setlerine ayrıştırılmıştır. Bu ayrıştırma işlemi yapılırken farklı sınıflara ait örnek sayılarının hem eğitim hem de doğrulama veri setinde eşit oranda dağılmasına özen gösterilmiştir. Tüm veri hazırlama işlemleri tamamlandıktan sonra makine modelinin geliştirilmesi aşamasına geçilmiştir. Gözlem sayısının ve öznitelik oranının oldukça fazla olmasından dolayı, sınıflandırma modelinin derin sinir ağları yardımıyla geliştirilmesi planlanmıştır. Bu plan dahilinde geliştirilen derin sinir ağ yapısında kullanılan katman ve bağlantı bilgileri aşağıdaki gibidir:

Geliştirilen derin sinir ağında ilk olarak öznitelik sayısı ile eşit sayıda girdi düğümüne sahip “featureInputlayer” katmanı, “normalizasyon” ve “zscore” parametreleri ile oluşturulmuştur. Bu katmanın çıktılarını girdi olarak alan “fullyConnectedLayer” katmanı 50 düğümünden oluşacak şekilde 2.Katman olarak eklenmiştir. Bu katman sonrasında çıkan verilerin dağılım oranını azaltmak maksadıyla “fullyConnectedLayer” katmanı sonrası “BatchNormalizationLayer” katmanı eklenmiştir. Bu katman sonrasında çıkan değerlerden edinilen bilgi kazanımını maksimize etmek amacıyla, çok daha az bilgi sunan değerlerin geçişi “reluLayer” aktivasyon katmanı ile engellenmiştir. Bu sayede geliştirilen modelin gereksiz işlem yapmasının önüne geçilmiş ve süreden de kazanç sağlanmıştır.

Son olarak sınıflandırma katmanı eklenmeden önce bir adet “fullyConnectedLayer” katmanı daha, tahmin edilmesi istenilen sınıf sayısı (4) kadar düğüm sayısına sahip bağlantı katmanı eklenmiştir. Ayrıca sınıflandırma puanlamasını yapması amacıyla “softMaxLayer” katmanı eklenmiş ve çıkan skorlara göre sınıflandırma işlemini yapan “classificationLayer” katmanı ile derin sinir ağ yapısı oluşturulmuştur.

Hazırlanan model ile eğitim aşamasında kullanılması için belirlenen “parameter” değerleri aşağıdaki gibidir:

Batch_size = 16

Optimize edici (Optimizer) = “Adam”

Yaklaşım sayısı (Epoch) = 30


İterasyon sayısı = 11040

Model yukarıda belirtilen “parameter” değerleri ile eğitildikten sonra doğrulama veri setinde test edilmiştir. Öğrenme metodu olarak Denetimli Öğrenme kullanılmıştır.

4.3.1. Derin İnanç Ağları

Derin İnanç Ağları, Derin Sinir Ağlarına benzeyen ancak aynı olmayan makine öğrenimi algoritmasıdır. Derin İnanç Ağları birçok gizli katmana sahip ileri beslemeli sinir ağıdır. Sınırlı Boltzmann Makineleri (RBM) veya otomatik kodlayıcılar gibi ağlar, her bir alt ağı gizli katmanının bir sonraki katmanını oluşturur. Düğümlerin her katmanı yan yana iletişim kurmaz. Bu RBM seti, bir “softmax” sınıflandırma katmanında sona erebilir.


Sınırlı Boltzmann Makineleri enerji tabanlı modellere ait sinir ağıdır. Girdilerinden bir olasılık dağılımı öğrenebilen bir tür üretken yapay sinir ağıdır. Belirli bir sırayla bağlanan bir dizi kısıtlanmış RBM, bir Derin İnanç Ağı oluşturur. Boltzmann makinesinin "çıktı" katmanının sonucunu, ardışık olarak bir sonraki Boltzmann makinesine girdi olarak eklenir. Sonra onu yakınsayana kadar eğitilir ve tüm ağ tamamlanana kadar aynı işlem uygulanır. Bir Derin İnanç Ağı oluşturmak için her bir RBM katmanı eğitilmelidir. Bu amaçla başlangıçta birimler ve parametreler kullanılmaktadır.



Şekil 4.11 Derin İnanç Ağ Yapısı

5 DENEYSEL ÇALIŞMALAR

Dört çakı tipi uygun bağlama aparatları ile çakı miline bağlanmıştır. Açılacak dişli tipine (düz dişli) göre çakı açısı belirlenmiştir. Parça işleme 100 rpm paso hızında, 24 dakikada gerçekleştirilmiş ve bu işlem kırık, körelmiş, yanık ve sağlam çakılar takılarak tekrar edilmiştir. Akım ve gerilim transdüserlerine çakıya hareketini veren asenkron motorun faz kablosu bağlanarak akım ve gerilim ölçüldü. Çakıya yakın titreşimin yoğun olduğu malafa üzerine vibrasyon transdüseri bağlanarak ve çakı mili ucuna enkoder bağlanarak sırası ile titreşim, hız ölçümü yapılmıştır.






Şekil 5.1 Deney düzeneği

Buradan okunan analog ham veriler, ARM tabanlı mikrodenetleyiciye bağı SD kartın içine kaydedilmektedir. Bilgisayar üzerinde oluşturulan EXE uzantılı uygulama aracılığıyla okunan ham veriler, SD karttan bilgisayara aktarılarak ham değerler elde edildi. Her bir örnek için aynı zamanda tezgâhın ve çakının ürettiği ses sinyalleri eş zamanlı olarak kaydedildi. Kırık, körelmiş, yanmış ve sağlam çakı durumlarında 4 örnek alınmış ve toplanan veriler neticesinde kesici takımın durumu yorumlanmıştır.



Şekil 5.2 Sağlam çakı

Sağlam çakı ile parça işleme deneyinde akım, gerilim ve titreşim frekans genlik sinyallerinin durumları şekil 5.3’ de gözlemlenmiştir. 20.saniyede çakının parçaya girmesine bağı motorun çektiği akımın arttığı grafikten görülmüştür. Gürültüye bağı üç grafikte de parazitler meydana gelmiştir. Gerilim ve akım grafiğinde çakı ile parça ısınmasına ve paso ilerlemesine bağı genlik değerleri giderek yükselmiştir.




Şekil 5.3 a) Sağlam çakı akım sinyal grafiği b) Sağlam çakı gerilim sinyal grafiği c) Sağlam çakı titreşim sinyal grafiği



Şekil 5.4 Körelmiş çakı

Körelmiş çakı ile parça işleme deneyinde akım, gerilim ve titreşim frekans genlik sinyallerinin durumları şekil 5.5’ de gözlemlenmiştir. Akım grafiğinde 3. ve 22. dakikalarda genlik değerleri anlık yükselmiştir. Gerilim ve titreşim genlik değerleri sabit ilerleyen grafik izlenimi vermiştir.




Şekil 5.5 a) Körelmiş çakı akım sinyal grafiği b) Körelmiş çakı gerilim sinyal grafiği c) Körelmiş çakı titreşim sinyal grafiği



Şekil 5.6 Yanık çakı

Yanık çakı ile parça işleme deneyinde akım, gerilim ve titreşim frekans genlik sinyallerinin durumları şekil 5.7’ de gözlemlenmiştir. En net ayırt edici akım grafiği yanık çakı deneyinde elde edilmiştir. Deneyin neredeyse her dakikasında akım ve gerilim grafiklerinde bileşenler meydana gelmiştir.




Şekil 5.7 a) Yanık çakı akım sinyal grafiği b) Yanık çakı gerilim sinyal grafiği c) Yanık çakı titreşim sinyal grafiği




Şekil 5.8 Kırık akı

Kırık akı ile para iřleme deneyinde akım, gerilim ve titreřim frekans genlik sinyalinin durumları řekil 5.9’ da gözlemlenmiřtir. Deneyin yarısına kadar akım ve gerilim grafiğinde bileřenler oluřmuř daha sonrasında ise stabil bir grafik meydana gelmiřtir. Titreřim grafiğı ise ayırt edici bir özellik elde edilememiřtir.




Şekil 5.9 a) Kırık çakı akım sinyal grafiği b) Kırık çakı gerilim sinyal grafiği c) Kırık çakı titreşim sinyal grafiği




Şekil 5.10 a) Boşta çakı akım sinyal grafiği b) Boşta çakı gerilim sinyal grafiği c) Boşta çakı titreşim sinyal grafiği

Çakı boşta deneyinde parça işlemeden alınan örnekler ile akım, gerilim ve titreşim frekans genlik sinyalinin durumları şekil 5.10’ da gözlemlenmiştir. Çakının boşta dönmesi ve iş parçasına temas etmemesinden beklendiği üzere stabil grafikler elde edilmiş olup, boşta çakı deneyi diğer deneylerle kıyaslamak adına baz alınması için önemli rol oynamaktadır. Her deneyin süresi 25 dakika olup, örnekleme süresi 20 ms’ dir.


Elde edilen ses verilerinden, öz nitelikler çıkartılmıştır.




Şekil 5.11 Perde Sıklığı Öz nitelikler




Şekil 5.12 Bark Ölçeği Öznitelikler




Şekil 5.13 Spektral Merkez Öznitelikler




Şekil 5.14 Eşit Dikdörtgen Bant Genişliği Öznitelikler




Şekil 5.15 Yayılı Spektrum Öznitelikler




Şekil 5.16 Doğrusal Tahmin Öznitelikler




Şekil 5.17 Mel Spektrum Öznitelikler



Şekil 5.18 Mel Frekans Kepstral Katsayıları Öznitelikler



Şekil 5.19 Gamaton Kepstral Katsayıları Öznitelikler



Şekil 5.20 Spektral Entropi Öznitelikler

Çıkarılan öznitelikler Derin İnanç Ağ modelinin eğitilmesinde kullanılmıştır.



Şekil 5.21 Sınıflandırma başarımlar grafiği

Şekil 5.21'deki eğitim başarı ve hata grafiklerine bakıldığında, yaklaşık olarak 100 yaklaşım değeri civarında geliştirilen model problem özelliklerini öğrenmiş ve entegre olmuştur. Grafik üzerindeki dalgalanmalar farklı sınıflara ait tahminlerde farklı gürültü seviyelerinin başarı oranına etkisi olarak gözlemlenmiştir. Bunun yanında hata grafiği de beklendiği üzere azalan bir grafik çizmiş ve 100 yaklaşım sonrasında bu stabil görünümü devam ettirmiştir. Eğitim başarı grafiğindeki dalgalanmalara sebep olan gürültü değerlerinin etkisi aynı şekilde hata grafiğinde de görülmektedir. Bu yönüyle bu çalışma gerçek durumu yansıtan ve uyarlanabilir bir profil çizmektedir.

	kor	kırık	saglam	yanık
True Class	kor	kırık	saglam	yanık
	280	243	1	
	1		275	
	3		1	237
	kor	kırık	saglam	yanık
	Predicted Class			

Şekil 5.22 Karşılaştırma grafiği

Şekil 5.22’deki karşılaştırma grafiği incelendiğinde farklı sınıflara ait yüksek başarı oranı açıkça görülmektedir. “kor” sınıfına ait test örneklerinin tamamı doğru tahmin edilirken, “kırık” sınıfına ait bir örneklem “saglam”, “saglam” sınıfına ait 1 örneklem “kor” ve “yanık” sınıfına ait 1 örneklem “saglam”, 3 örneklem “kor” olarak yanlış sınıflandırılmıştır. Bu sınıflandırma yanlışlarının veri setinde yer alan gürültü değerlerinden dolayı meydana gelme olasılığı, elde edilen başarı oranının yüksek olması baz alınarak değerlendirilmiştir.



6 SONUÇLAR

Deneyler, sağlam çakı ile kırık, körelmiş ve yanık çakının etkin güç sinyalleri arasındaki oranın, takım aşınması için güçlü bir gösterge olduğunu kanıtlamıştır. Çalışma, dişli azdırmada takım aşınma oluşumunu tahmin etmeye yönelik yöntemleri kapsamaktadır. Tanıtılan prosedürler, olası her çakı hatası durumunu kapsayan aşınma koşullarını oluşturmak için kusurlu olarak belirlenmiş çakı geometrisine ve bunun deneysel sonuçlarla ilişkisine dayanmaktadır. Akım, gerilim, vibrasyon transdüserleri ve enkoderden alınan sinyaller gömülü sistem ile toplandıktan sonra Flash Disk ile MATLAB ortamına aktarılmıştır. Eş zamanlı ses kaydı yapılmıştır.

Transdüserlerden alınan verilerden elde edilen sinyal ve güç spektrum grafiklerinde net bir fark görülemediği için sınıflandırma sağlanamamış ve RMS ölçüm yapan transdüserlerin frekans spektrumlarının ayırt edici özelliklerini azalttığı gözlemlenmiş, anlık tezgâh hata teşhisi için uygun olmadığı kanısına varılmıştır.

Mikrofondan kaydı alınan ses dosyaları MATLAB uygulaması içinde yer alan “Audio Toolbox” yardımcı aracı ile çalışma ortamına yüklenmiştir. Analizi yapılan tüm sinyaller için 10 adet öznelilik çıkarımı sağlanmıştır. Derin İnanç Ağ yapısını oluşturan katmanlar eklenmiştir. Son aşamada Derin İnanç Ağları sınıflandırma yaparak hatalı çakı-hatasız çakı kararlarına varıp hata tespiti yapmamızı sağlamıştır. Simülasyon ve ölçüm verilerini otomatik olarak birleştiren ve bu bilgilerden takım aşınma tahmin edicilerini hesaplayan bir algoritma geliştirilmiştir. Frekans genlik sinyalinin en yoğun durumu sırası ile yanık çakı, kırık çakı, körelmiş çakı ve sağlam çakı olduğu gözlemlenmiştir.

Ses analizi için model daha önce belirtilen “parameter” değerleri ile eğitildikten sonra doğrulama veri setinde test edilmiş ve $99,42 \pm 0,132$ oranında başarımlık skoru elde edilmiştir.

Azdırma işlemi, karmaşık geometrisi ve mekaniği dikkate alınarak, benzer modelleme metodolojisi, tornalama ve taşlama gibi diğer işleme süreçlerine uygulanabilir. Öte yandan modeller, beş eksenli frezeleme gibi daha karmaşık frezeleme işlemlerine genişletilebilir.

KAYNAKLAR

- [1] **Kolla, S.R., Altman, S.D.** (2007). Artificial neural network based fault identification scheme implementation for a three-phase induction motor, *ISA Trans*, vol. 46, no. 2, pp. 261–266, doi: 10.1016/J.ISATRA.2006.08.002.
- [2] **Ebrahimi, B.M., Faiz, J.** (2010). Feature extraction for short-circuit fault detection in permanent-magnet synchronous motors using stator-current monitoring, *IEEE Trans Power Electron*, vol. 25, no. 10, doi: 10.1109/TPEL.2010.2050496.
- [3] **Nyamusa, T.A., Demerdash, N.A.** (1987). Transient Analysis of Partial Armature Short Circuit in an Electronically Commutated Permanent Magnet Motor System Using an Integrated Nonlinear Magnetic Field-Network Model, *IEEE Power Engineering Review*, vol. PER-7, no. 3, doi: 10.1109/MPER.1987.5527367.
- [4] **Sebastian, T., Slemon, G.** (1987). Transient torque and short circuit capabilities of variable speed permanent magnet motors, *IEEE Trans Magn*, vol. 23, no. 5, doi: 10.1109/TMAG.1987.1065207.
- [5] **Nelson, A.L., Chow, M.Y.** (2002). Characterization of Coil Faults in an Axial Flux Variable Reluctance PM Motor, *IEEE Power Engineering Review*, vol. 22, no. 7, doi: 10.1109/MPER.2002.4312358.
- [6] **Ebrahimi, B.M., Faiz, J.** (2010). Diagnosis and performance analysis of three-phase permanent magnet synchronous motors with static, dynamic and mixed eccentricity, *IET Electr Power Appl*, vol. 4, no. 1, doi: 10.1049/iet-epa.2008.0308.
- [7] **Ebrahimi, B.M., Faiz, J., Roshtkhari, M.J.** (2009). Static-, dynamic-, and mixed-eccentricity fault diagnoses in permanent-magnet synchronous motors, *IEEE Transactions on Industrial Electronics*, vol. 56, no. 11, doi: 10.1109/TIE.2009.2029577.
- [8] **Bianchi, N., Bolognani, S., Zigliotto, M., Zordan, M.** (2003). Innovative remedial strategies for inverter faults in IPM synchronous motor drives, *IEEE Transactions on Energy Conversion*, vol. 18, no. 2, doi: 10.1109/TEC.2002.808334.
- [9] **Pandarakone, S.E., Masuko, M., Mizuno, Y., Nakamura, H.** (2018). Deep Neural Network Based Bearing Fault Diagnosis of Induction Motor Using Fast Fourier Transform Analysis, 2018 IEEE Energy Conversion Congress and Exposition (ECCE), pp. 3214-3221, doi: 10.1109/ECCE.2018.8557651.”.
- [10] **Jigyasu, R., Sharma, A., Mathew, L., Chatterji, S.** (2019). A Review of Condition Monitoring and Fault Diagnosis Methods for Induction Motor, in *Proceedings of the 2nd International Conference on Intelligent Computing and Control Systems, ICICCS* . doi: 10.1109/ICCONS.2018.8662833.

- [11] **Luo, X., Du, P.** (2010). A fault diagnosis method of motor based on wavelet transform, in *2010 Second IITA International Conference on Geoscience and Remote Sensing*, pp. 544–546. doi: 10.1109/IITA-GRS.2010.5602342.
- [12] **Sridhar, S., Rao, K.U., Jade, S.** (2015). Detection of broken rotor bar fault in induction motor at various load conditions using wavelet transforms, in *2015 International Conference on Recent Developments in Control, Automation and Power Engineering, RDCAPE*, doi: 10.1109/RDCAPE.2015.7281373.
- [13] **Ping, H.W., Gaeid, K.S.** (2012). Detection of induction motor faults using direct wavelet transform technique, in *ICEMS 2012 - Proceedings: 15th International Conference on Electrical Machines and Systems*.
- [14] **Kechida, R., Menacer, A., Talhaoui, H., Cherif, H.** (2015). Discrete wavelet transform for stator fault detection in induction motors, in *Proceedings - SDEMPED 2015: IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives*, doi: 10.1109/DEMPED.2015.7303676.
- [15] **Athulya, K.** (2018). Inter Turn Fault Diagnosis in Wound Rotor Induction Machine Using Wavelet Transform, in *2018 International CET Conference on Control, Communication, and Computing, IC4*, doi: 10.1109/CETIC4.2018.8530887.
- [16] **Siddiqui, K.M., Sahay, K., Giri, V.K.** (2016). Early, diagnosis of bearing fault in the inverter driven induction motor by wavelet transform, in *Proceedings of IEEE International Conference on Circuit, Power and Computing Technologies, ICCPCT*, doi: 10.1109/ICCPCT.2016.7530233.
- [17] **Zaman, S.M.K., Marma, H.U.M., Liang, X.** (2019). Broken Rotor Bar Fault Diagnosis for Induction Motors Using Power Spectral Density and Complex Continuous Wavelet Transform Methods, in *2019 IEEE Canadian Conference of Electrical and Computer Engineering, CCECE*, doi: 10.1109/CCECE.2019.8861517.
- [18] **Kaya K., Ünsal, A.** (2021). Yapay Sinir Ağlarıyla Asenkron Motor Çoklu Arızalarının Tespiti ve Sınıflandırılması, *Journal of Polytechnic*, doi: 10.2339/politeknik.933826.
- [19] **Bayrak, M., Küçüker, A.** (2016). Üç Fazlı Asenkron Motorlardaki Kırık Rotor Çubuğu Arızalarının Tespiti İçin Güç Tabanlı Bir Algoritmanın Geliştirilmesi, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, vol. 31, no. 2, doi: 10.17341/gummfd.82945.
- [20] **Kuş, M.** (2019). Asenkron Motorlarda Kırık Rotor Çubuk Arızasının Vibrasyon Sinyali ile Tespiti, *Harran Üniversitesi Mühendislik Dergisi*, 4 (2), 36-43. Retrieved from <https://dergipark.org.tr/en/pub/humder/issue/47643/561528>.
- [21] **Siddhpura, A., Paurobally, R.** (2013). A review of flank wear prediction methods for tool condition monitoring in a turning process, *The International*

Journal of Advanced Manufacturing Technology, vol. 65, no. 1–4, pp. 371–393, doi: 10.1007/s00170-012-4177-1.

- [22] **Hase, A., Wada, M., Koga, T., Mishina, H.** (2014). The relationship between acoustic emission signals and cutting phenomena in turning process, *International Journal of Advanced Manufacturing Technology*, vol. 70, no. 5–8, doi: 10.1007/s00170-013-5335-9.
- [23] **Li, X.** (2002). A brief review: acoustic emission method for tool wear monitoring during turning, *Int J Mach Tools Manuf*, vol. 42, no. 2, pp. 157–165, doi: 10.1016/S0890-6955(01)00108-0.
- [24] **Sharma, V.S., Sharma, S.K., Sharma, A.K.** (2008). Cutting tool wear estimation for turning, *J Intell Manuf*, vol. 19, no. 1, doi: 10.1007/s10845-007-0048-2.
- [25] **Kosaraju, S., Anne, V.G., Popuri, B.B.** (2013). Online tool condition monitoring in turning titanium (grade 5) using acoustic emission Modeling, *International Journal of Advanced Manufacturing Technology*, vol. 67, no. 5–8, doi: 10.1007/s00170-012-4621-2.
- [26] **Bhuiyan, M.S.H., Choudhury, I.A., Dahari, M.** (2014). Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning, *J Manuf Syst*, vol. 33, no. 4, doi: 10.1016/j.jmsy.2014.04.005.
- [27] **Rubio E.M., Teti, R.** (2009). Cutting parameters analysis for the development of a milling process monitoring system based on audible energy sound, *J Intell Manuf*, vol. 20, no. 1, doi: 10.1007/s10845-008-0102-8.
- [28] **Pechenin, V.A., Khaimovich, A.I., Kondratiev, A.I., Bolotov, M.A.** (2017). Method of Controlling Cutting Tool Wear Based on Signal Analysis of Acoustic Emission for Milling,” in *Procedia Engineering*, vol. 176. doi: 10.1016/j.proeng.2017.02.294.
- [29] **Gokulachandran, J., Bharath Krishna Reddy, B.** (2019). A study on the usage of current signature for tool condition monitoring of drill bit, in *Materials Today, Proceedings*, vol. 46. doi: 10.1016/j.matpr.2020.09.696.
- [30] **Salgado D.R., Alonso, F.J.** (2007). An approach based on current and sound signals for in-process tool wear monitoring, *Int J Mach Tools Manuf*, vol. 47, no. 14, doi: 10.1016/j.ijmachtools.2007.04.013.
- [31] **Rmili, W., Ouahabi, A., Serra, R., Leroy, R.** (2016). An automatic system based on vibratory analysis for cutting tool wear monitoring, *Measurement (Lond)*, vol. 77, doi: 10.1016/j.measurement.2015.09.010.
- [32] **Upase R., Ambhore, N.** (2020). Experimental investigation of tool wear using vibration signals, An ANN approach, in *Materials Today: Proceedings*, vol. 24. doi: 10.1016/j.matpr.2020.04.454.
- [33] **Mathew, M.T., Pai, P.S., Rocha, L.A.** (2008). An effective sensor for tool wear monitoring in face milling: acoustic emission, *Sadhana - Academy*

Proceedings in Engineering Sciences, vol. 33, no. 3, doi: 10.1007/s12046-008-0016-3.

- [34] **Dimla, S.D.E.** (1998). Multivariate tool condition monitoring in a metal cutting operation using neural networks. A Thesis submitted in part fulfillment of the requirements for a Doctor of Philosophy Degree in Mechanical Engineering at the University of Wolverhampton.
- [35] **Abu-Mahfouz, I.** (2003). Drilling wear detection and classification using vibration signals and artificial neural network, *Int J Mach Tools Manuf*, vol. 43, no. 7, doi: 10.1016/S0890-6955(03)00023-3.
- [36] **El-Wardany, T.I., Gao, D., Elbestawi, M.A.** (1996). Tool condition monitoring in drilling using vibration signature analysis, *Int J Mach Tools Manuf*, vol. 36, no. 6, doi: 10.1016/0890-6955(95)00058-5.
- [37] **Scheffer, C., Heyns, P.S.** (2001). Wear monitoring in turning operations using vibration and strain measurements, *Mech Syst Signal Process*, vol. 15, no. 6, doi: 10.1006/mssp.2000.1364.
- [38] **Rmili, W., Serra, R., Ouahabi, A., Gontier, C., Kious, M.** (2006). "Tool wear monitoring in turning process using vibration measurement," in *13th International Congress on Sound and Vibration, ICSV*, vol. 5.
- [39] **Klocke, F., Döbbeler, B., Goetz, S., Vieck, T.D.** (2017). Model-Based Online Tool Monitoring for Hobbing Processes, in *Procedia CIRP*, vol. 58. doi: 10.1016/j.procir.2017.03.271.
- [40] **Klocke, F., Döbbeler, B., Goetz, S., Staudt, J.** (2016). Online Tool Wear Measurement for Hobbing of Highly Loaded Gears in Geared Turbo Fans, *Procedia Manuf*, vol. 6, doi: 10.1016/j.promfg.2016.11.002.
- [41] **Bouzakis, K.D., Kombogiannis, S., Antoniadis, A., Vidakis, N.** (2002). Gear hobbing cutting process simulation and tool wear prediction models, *J Manuf Sci Eng*, vol. 124, no. 1, doi: 10.1115/1.1430236.
- [42] **Caballero-Peña J.A., Rosero-García, J.** (2021). Decentralized inter-turn fault diagnosis of induction motors based on wireless sensor networks, *DYNA (Colombia)*, vol. 88, no. 216, doi: 10.15446/dyna.v88n224.88851.
- [43] **Birame, M., Bessedik, S.A., Benkhoris, M.F.** (2021). Detection of partial rotor bar rupture of a cage induction motor using least square support vector machine approach," *Diagnostyka*, vol. 22, no. 1, doi: 10.29354/DIAG/133039.
- [44] **Tran, T., Liang, H., Li, W., Pham, M.** (2021). Comparison of Machine Learning Algorithms for Induction Motor Rotor Single Fault Diagnosis using Stator Current Signal, *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 10, no. 3, doi: 10.30534/ijatcse/2021/031032021.
- [45] **Alviento, E.V., Cabais, J.B., Fajardo, J.M.M., Garcia, R.G., Ballado, A.H.** (2021). Early Detection of Single-Phase Induction Motor Failure through the use of Accelerometer and Temperature Sensor via Arduino, in *Proceeding -*

2021 IEEE 17th International Colloquium on Signal Processing and Its Applications, CSPA, doi: 10.1109/CSPA52141.2021.9377285.

- [46] **Rachmat Ah Ro Ufun, B., Diah Prahmana Karyatanti, I., Yan Dewantara, B.** (2021). Detection of Stator Winding Short Circuit Faults Through Magnetic Fields In Induction Motors, *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 5, no. 1, doi: 10.21070/jeeeu.v5i1.1281.
- [47] **Morozov A.L., Nigmatullin, R.R., Agrusti, G., Lino, P., Maione, G., Kanovic, Z., Martinez-Roman, J.** (2021). Microcontroller realization of an induction motors fault detection method based on FFT and statistics of fractional moments, in *2021 29th Mediterranean Conference on Control and Automation, MED*, doi: 10.1109/MED51440.2021.9480322.
- [48] **Chen, H., Ye, S., Wang, T., Zheng, X., Li, T.** (2021). Extraction of Common-Mode Impedance of an Induction Motor by Using All-Phase FFT with Intermediate-Frequency Filtering, *IEEE Trans Electromagn Compat*, vol. 63, no. 5, doi: 10.1109/TEMPC.2021.3050457.
- [49] **Amanuel, T., Ghirmay, A., Ghebremeskel, H., Ghebrehiwet, R., Bahlibi, W.** (2021). Comparative Analysis of Signal Processing Techniques for Fault Detection in Three Phase Induction Motor, *Journal of Electronics and Informatics*, vol. 3, no. 1, doi: 10.36548/jei.2021.1.006.
- [50] **Isfar, S., Diah Prahmana Karyatanti, I., Yan Dewantara, B.** (2021). The Effects of Damage to the Outer Race Bearing on the Efficiency of the Induction Motor Using Fast Fourier Transform (FFT) Method, *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 5, no. 1, doi: 10.21070/jeeeu.v5i1.1284.
- [51] **Senthil Kumar, R., Gerald Christopher Raj, I.** (2021). Broken rotor bar fault detection using DWT and energy eigenvalue for DTC fed induction motor drive, *International Journal of Electronics*, vol. 108, no. 8, doi: 10.1080/00207217.2020.1870727.
- [52] **Defdaf, M., Berrabah, F., Chebabhi, A., Cherif, B.D.E.** (2021). A new transform discrete wavelet technique based on artificial neural network for induction motor broken rotor bar faults diagnosis, *International Transactions on Electrical Energy Systems*, vol. 31, no. 4, doi: 10.1002/2050-7038.12807.
- [53] **Ibrahim, A., Anayi, F., Packianather, M., Alomari, O.A.** (2022). New Hybrid Invasive Weed Optimization and Machine Learning Approach for Fault Detection, *Energies (Basel)*, vol. 15, no. 4, doi: 10.3390/en15041488.
- [54] **Panigrahy, P.S., Chattopadhyay, P.** (2021). Tri-axial vibration based collective feature analysis for decent fault classification of VFD fed induction motor, *Measurement (Lond)*, vol. 168, doi: 10.1016/j.measurement.2020.108460.
- [55] **Veerendra, A.S., Shah, A.A., Mohamed, M.R., Sekhar, C.P., Leung, P.** (2021). Wavelet transform based fault identification and reconfiguration for a

- reduced switch multilevel inverter fed induction motor drive, *Electronics (Switzerland)*, vol. 10, no. 9, doi: 10.3390/electronics10091023.
- [56] **Zuhaib, M., Shaikh, F.A., Shaikh, U.A., Soomro, A.** (2021). An Approach on MCSA-Based Fault Detection Using Discrete Wavelet Transform and Fault Classification Based on Deep Neural Networks, *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 10, no. 3, doi: 10.30534/ijatcse/2021/1081032021.
 - [57] **Veerendra, A.S., Mohamed, M.R., Punya Sekhar, C.** (2021). A novel fault-detection methodology of proposed reduced switch MLI fed induction motor drive using discrete wavelet transforms, *International Transactions on Electrical Energy Systems*, vol. 31, no. 4, doi: 10.1002/2050-7038.12820.
 - [58] **Arıduru, A.** (1995). Küresel grafitli dökme demirlerde talaş kaldırma kabiliyeti, *Marmara Üniversitesi ProQuest Dissertations Publishing*, 28528631.
 - [59] **Feldman, M.** (2011). Hilbert transform in vibration analysis, *Mechanical Systems and Signal Processing*, vol. 25, no. 3. doi: 10.1016/j.ymssp.2010.07.018.
 - [60] **Grover, C., Turk, N.** (2022). A novel fault diagnostic system for rolling element bearings using deep transfer learning on bispectrum contour maps, *Engineering Science and Technology, an International Journal*, vol. 31, doi: 10.1016/j.jestch.2021.08.006.
 - [61] **Takahashi, N., Gygli, M., Van Gool, L.** (2018). AENet: Learning Deep Audio Features for Video Analysis, *IEEE Trans Multimedia*, vol. 20, no. 3, 2018, doi: 10.1109/TMM.2017.2751969.
 - [62] **Thoidis, I., Giouvanakis, M., Papanikolaou, G.** (2021). Semi-supervised machine condition monitoring by learning deep discriminative audio features, *Electronics (Switzerland)*, vol. 10, no. 20, doi: 10.3390/electronics10202471.
 - [63] **Xu, Y. vd.** (2017). Unsupervised Feature Learning Based on Deep Models for Environmental Audio Tagging, *IEEE/ACM Trans Audio Speech Lang Process*, vol. 25, no. 6, doi: 10.1109/TASLP.2017.2690563.