

BURSA TEKNİK ÜNİVERSİTESİ ❖ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**SES SİNYALLERİ KULLANILARAK TALAŞLI İMALAT PROSESİNDE
TAKIM DURUMUNUN İZLENMESİ**

YÜKSEK LİSANS TEZİ

EMRE KALKANLI

Mekatronik Mühendisliği Anabilim Dalı

Ekim 2021

BURSA TEKNİK ÜNİVERSİTESİ ❖ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**SES SİNYALLERİ KULLANILARAK TALAŞLI İMALAT PROSESİNDE
TAKIM DURUMUNUN İZLENMESİ**

YÜKSEK LİSANS TEZİ

**EMRE KALKANLI
(20241782019)**

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Celalettin YÜCE

Ekim 2021

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 20241782019 numaralı Yüksek Lisans Öğrencisi Emre KALKANLI, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “Ses Sinyalleri Kullanılarak Talaşlı İmalat Prosesinde Takım Durumunun İzlenmesi” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Celalettin YÜCE**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Fatih KARPAT**
Bursa Uludağ Üniversitesi

Doç. Dr. Ahmet MERT
Bursa Teknik Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 27 Ekim 2021



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, Bursa Teknik Üniversitesi Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin numaralı projesi ile desteklenmiştir.

Bu tez, numaralı projesi ile desteklenmiştir.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Emre KALKANLI

İmzası :

X



Eren'e,

ÖNSÖZ

Tez çalışmam süresince bana her türlü desteğini esirgemeyen Dr. Öğr. Üyesi Celalettin Yüce'ye, teorik ve deneysel çalışmalarımda desteklerini aldığım Doç. Dr. Ahmet Mert'e ve Arş. Gör. Safa Şenaysoy'a en içten teşekkürlerimi sunarım. Kesici takım hibesiyle çalışmama destek olan KLP Kesici Takımlar firmasına ve aşınma ölçümlerinde yardımcı olan ZOLLER Türkiye firmasına teşekkürü borç bilirim.

Ekim 2021

Emre KALKANLI



İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xii
ŞEKİL LİSTESİ.....	xiv
ÖZET	xvi
SUMMARY	xvii
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	4
2.1 Talaşlı İmalat.....	4
2.2 Kesici Takımlarda Görülen Aşınma ve Tipleri	6
2.2.1 Serbest yüzey aşınması.....	7
2.2.2 Krater aşınması.....	8
2.2.3 Burun aşınması.....	8
2.3 Takım Durumu İzleme Sistemi	8
2.4 Takım Durumu İzleme Sistemlerinin Yapısı	9
2.4.1 Sensör sistemleri	10
2.4.2 Sinyal işleme	13
2.4.2.1 Sinyal ön işleme	13
2.4.2.2 Öznitelik oluşturma	14
2.4.2.3 Öznitelik seçimi/çıkarımı	17
2.4.3 Yapay zekâ teknikleri.....	18
2.4.3.1 Yapay sinir ağları (YSA).....	18
2.4.3.2 Destek vektör makineleri (DVM).....	22
2.4.3.3 Evrişimli sinir ağları (ESA).....	24
3. MATERYAL ve YÖNTEM.....	30
3.1 Kesici Takım Aşınmasının Belirlenmesi.....	31
3.2 Talaşlı İmalat Parametrelerinin Belirlenmesi.....	33
3.3 Sensör ve Veri Toplama Sistemlerinin Belirlenmesi	35
3.4 Sinyal İşleme ve Öznitelik Oluşturma İşlemlerinin Gerçekleştirilmesi	37
3.5 Makine Öğrenmesi Algoritmalarının Oluşturulması.....	38
3.5.1 YSA algoritmasının oluşturulması	38
3.5.2 DVM algoritmasının oluşturulması.....	39
3.5.3 ESA algoritmasının oluşturulması	39
3.6 Deney Tasarımının Gerçekleştirilmesi.....	41
3.6.1 TDİ sisteminin kurulması (1. deney).....	41
3.6.2 TDİ sisteminin farklı boyutlara sahip iş parçasından toplanan sesler ile test edilmesi (2. deney)	44
4. BULGULAR ve TARTIŞMA.....	46
4.1 TDİ Sisteminin Kurulması (1. Deney) Çalışmalarının Sonuçları	54

4.2 TDİ Sisteminin Farklı Boyutlara Sahip İş Parçasından Toplanan Sesler ile Test Edilmesinin (2. Deney) Sonuçları	57
5. SONUÇ ve ÖNERİLER.....	62
6. Kaynakça	64
ÖZGEÇMİŞ.....	70



KISALTMALAR

ADD	:Ayrık Dalgacık Dönüşümü
BM	:Bulanık Mantık
ÇDR	:Çoklu Doğrusal Regrasyon
ÇDSD	:Çok Değişkenli Senkrosıkıştırma Dönüşümü
Dİ	:Doğrusal İlkelleme
DOİ	:Doğrusal Olmayan İlkelleme
DÖKK	:Doğrusal Öngörü Kepstral Katsayıları
DPA	:Dalgacık Paket Ayırıştırması
DPD	:Dalgacık Paket Dönüşümü
DVM	:Destek Vektör Makineler
EKKDVM	:En Küçük Kareler Destek Vektör Makineleri
FD	:Fourier Dönüşümü
GESBA	:Genişletilmiş Evrişimli Sınırlı Bileşen Analizi
GSR	:Gauss Süreç Regresyonu
HFD	:Hızlı Fourier Dönüşümü
HHD	:Hilbert–Huang Dönüşümü
KA	:Karar Ağaçları
KB	:Krater Genişliğinin Takım Ucuna Olan Maksimum Mesafesi
KEYK	:k-En Yakın Komşu
KF	:Krater Genişliğinin Takım Ucuna Olan Minimum Mesafesi
KM	:Krater Merkezinin Takım Ucuna Olan Mesafesi
KSFD	:Kısa Süreli Fourier Dönüşümü
KT	:Maksimum Krater Derinliği
OKH	:Ortalama kareler hataları
ReLU	:Rectifier Linear Unit
RO	:Rassal Orman
SRAA	:Sınıflama ve Regresyon Ağacı Algoritması
STA	:Ses Tekillik Analizi
SZFD	:Sürekli Zamanlı Fourier dönüşümü
TBA	:Temel Bileşenler Analizi

TDA	:Tekil Değer Ayrıştırması
TDİ	:Takım Durumu İzleme Sistemi
TKA	:Tekil Spektrum Analizi
UATBÇS	:Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
VB	:Ortalama Serbest Yüzey Aşınması
YSA	: Yapay Sinir Ağları



SEMBOLLER

$\ w\ $	: Margin
b	: Bias
e	: Euler sayısı
E	: Tahmin hatası
f	: Filtre boyutu
$f(n)$	: Aktivasyon fonksiyonu
h	: Girdi görüntüsünün yüksekliği
h'	: Çıktı özellik haritasının yüksekliği
i	: Karmaşık sayı
P	: Nöron giriş sayısı
s	: Evrişim işlemi adımı
t	: Sürekli zaman indeksi
w	: Ağırlık vektörü
wd	: Girdi görüntüsünün genişliği
wd'	: Çıktı özellik haritasının genişliği
x	: Öznitelik vektörü
$X(k)$	: Ayrık $x(n)$ sinyalinin frekans bölgesi
$X(n)$	: Ayrık sinyal gösterimi
$X(t)$	: Sürekli sinyal gösterimi
$X(\omega)$	: Sürekli $x(t)$ sinyalinin frekans bölgesi
Π	: Pi sayısı
P	: Öğrenme oranı
ω	: Açısal frekans

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: Ses sinyalleri kullanılarak TDİ sistemlerinin oluşturulmasına yönelik çalışmalar.	27
Çizelge 3.1: Kesici uçların aşınma durumları ve aşınma kalınlıkları.	32
Çizelge 3.2: S355J2+N Kimyasal Kompozisyonu (S355 J2+N Steel Plate, 2021)...	33
Çizelge 3.3: S355J2+N Mekanik Özellikleri.	33
Çizelge 3.4: Freze tezgâhı uygulanabilir ilerleme değerleri.	34
Çizelge 3.5: Freze tezgâhı uygulanabilir devir değerleri.	34
Çizelge 3.6: Kesici uç için uygulanabilir kesme hızı, ilerleme, talaş derinliği aralıkları.	35
Çizelge 3.7: İşleme parametreleri ve düzeyleri.	35
Çizelge 3.8: Ses sinyali toplama donanımları.	36
Çizelge 3.9: Deneyde kullanılan mikrofonların teknik özellikleri (Behringer, 2021) (BOYA, 2021).	36
Çizelge 3.10: Oluşturulan ESAkatmanlarının çıktı şekilleri ve parametre değerleri.	41
Çizelge 3.11: 1. deney için deney planı.	43
Çizelge 3.12: 2. deney için deney planı.	45
Çizelge 4.1: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.	54
Çizelge 4.2: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.	55
Çizelge 4.3: 1. deney sonucunda YSA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	55
Çizelge 4.4: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.	55
Çizelge 4.5: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.	56
Çizelge 4.6: 1. deney sonucunda DVM ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	56
Çizelge 4.7: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.	57
Çizelge 4.8: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.	57
Çizelge 4.9: 1. deney sonucunda ESA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	57
Çizelge 4.10: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.	58
Çizelge 4.11: 2. deney sonucunda 2. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.	58
Çizelge 4.12: 2. deney sonucunda YSA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	58

Çizelge 4.13: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.	59
Çizelge 4.14: 2. deney sonucunda 2. grup ses sinyali toplama donanımı DVM ile kurulan TDİ sisteminin karışıklık matrisi.	59
Çizelge 4.15: 2. deney sonucunda DVM ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	59
Çizelge 4.16: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.	60
Çizelge 4.17: 2. deney sonucunda 2. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.	60
Çizelge 4.18: 2. deney sonucunda ESA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.	60
Çizelge 4.19: Çalışma boyunca elde edilen tüm tahmin doğruluğu değerleri.	61



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Talaşlı imalat işlemleri	5
Şekil 2.2: a) Çevresel frezeleme b) Yüzey frezeleme (Gülmez, 2016)	5
Şekil 2.3: a) Yatay freze tezgâhı b) Dikey freze tezgâhı (Gülmez, 2016).....	6
Şekil 2.4: a) Serbest yüzey aşınması b) Krater aşınması c) Burun aşınması (Özdemir ve Erten, 2003)	6
Şekil 2.5: Kesici takım aşınma ölçüm bölgeleri (Özdemir ve Erten, 2003).....	7
Şekil 2.6: Serbest yüzey aşınmasının zamana bağlı olarak gelişimi (Özdemir ve Erten, 2003)	7
Şekil 2.7: TDİ sistemlerinin yapısı (Abellan-Nebot ve Subirón, 2010)	10
Şekil 2.8: Sinyal işleme işlemindeki adımlar (Abellan-Nebot ve Subirón, 2010)....	13
Şekil 2.9: HFD Blok Diyagramı (Mehrotra ve diğ, 2017).....	16
Şekil 2.10: KSFD adımları (Jeon ve diğ, 2020).....	17
Şekil 2.11: Bir nöronada gerçekleşen işlemler	19
Şekil 2.12: Sigmoid aktivasyon fonksiyonu	19
Şekil 2.13: Hiperbolik tanjant aktivasyon fonksiyonu	20
Şekil 2.14: ReLU aktivasyon fonksiyonu.....	20
Şekil 2.15: İki sınıf ile eğitilen DVM için maksimum margin (Filipe ve diğ, 2012)	23
Şekil 2.16: Klasik ESA Yapısı (O'Shea ve Nash, 2015)	24
Şekil 2.17: 2 x 2 boyutunda filtre	25
Şekil 2.18: Gri seviyeli görüntü.....	25
Şekil 2.19: Evrişim işleminin ilk 5 adımı (Ghosh ve diğ, 2020)	25
Şekil 2.20: Örnek bir havuzlama işlemi (Ghosh ve diğ, 2020)	26
Şekil 2.21: Tam bağlantılı katman (Ghosh ve diğ, 2020).....	27
Şekil 3.1: TDİ sisteminin tasarımı için izlenen adımlar	30
Şekil 3.2: Kesici uç ve tarama başlığı geometrik ölçüleri	32
Şekil 3.3: Serbest yüzey aşınma görüntüleri ve Zoller Geius ölçüm cihazı	32
Şekil 3.4: Deneyde kullanılan Falco marka dik freze tezgâhı	34
Şekil 3.5: Tezgah başlığına sabitlenmiş mikrofonlar	36
Şekil 3.6: Kullanılan mikrofon ve ses katlarının görselleri (a : Behringer ECM8000, b: BOYA By-M1, c: Behringer U-Phoria Um2)	37
Şekil 3.7: YSA diyagramı.....	39
Şekil 3.8: ESA Mimarisi.....	40
Şekil 4.1: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ses sinyalinin zaman bölgesi gösterimi	46
Şekil 4.2: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ses sinyalinin frekans bölgesi gösterimi	47
Şekil 4.3: 675 dev./dk., 170 mm/dk. işleme parametrelerinde iyi durumdaki kesici takımın ses sinyalinin spektogram görüntüsü.....	47
Şekil 4.4: 675 dev./dk., 170 mm/dk. işleme parametrelerinde hafif aşınmış durumdaki kesici takımın ses sinyalinin spektogram görüntüsü	48

Şekil 4.5: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ortalama aşınmış durumdaki kesici takımın ses sinyalinin spektogram görüntüsü	48
Şekil 4.6: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında iyi durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	49
Şekil 4.7: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında iyi durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	49
Şekil 4.8: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında hafif aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	50
Şekil 4.9: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında hafif aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	50
Şekil 4.10: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında ortalama aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	51
Şekil 4.11: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında ortalama aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi	51
Şekil 4.12: 495 dev./dk., 400 mm/dk. işleme parametrelerinde ortalama aşınmış durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi	52
Şekil 4.13: 675 dev./dk., 260 mm/dk. işleme parametrelerinde iyi durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi	52
Şekil 4.14: 850 dev./dk., 170 mm/dk. işleme parametrelerinde hafif aşınmış durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi	53

SES SİNYALLERİ KULLANILARAK TALAŞLI İMALAT PROSESİNDE TAKIM DURUMUNUN İZLENMESİ

ÖZET

Kesici takım aşınması ve kırılması talaşlı imalat operasyonlarının tam otomatik hale getirilebilmesinin önündeki en büyük engellerdendir. Etkili bir takım durumu izleme (TDİ) sistemi, tam otomatik imalat sistemlerinin kurulabilmesi için en iyi çözümdür. Takım durumunun çevrimiçi tespiti için çok çeşitli izleme teknikleri geliştirilmiş olsa da güvenilir, basit ve ucuz bir çözüm ihtiyacı hala devam etmektedir. Bu çalışmanın temel amacı, yüzey frezeleme operasyonu sırasında farklı aşınma durumu ve kesme parametrelerine ait toplanan ses sinyallerini makine öğrenmesi tekniklerini kullanarak sınıflandırmak ve takım durumunu tespit etmek için bir TDİ modeli geliştirmektir. Bu çalışmada yüzey frezeleme operasyonu sırasında toplanan ses sinyalleri ile makine öğrenmesi algoritmaları eğitilerek oluşturulan modellerin, takım aşınma durumlarını başarılı bir şekilde tespit edilebildiği belirlenmiştir. Yapay sinir ağları, destek vektör makinesi ve evrişimli sinir ağları yaklaşımlarını içeren makine öğrenmesi tekniklerine dayalı bir karar verme sistemi geliştirilmiştir. Kurulan sistemlerin başarısı elde edilen tahmin doğruluklarıyla karşılaştırılmıştır. Geliştirilen sistem, önceden işlenmiş verilerle eğitilmiştir. Eğitilen modelin test edilmesiyle önemli bir tahmin doğruluğu elde edilmiştir. Bu durum, ses sinyalleri ve makine öğrenmesi teknikleri kullanarak etkili bir TDİ sisteminin kurulabileceğini kanıtlamaktadır. Ayrıca oluşturulan TDİ sisteminin farklı iş parçası boyutunda aynı performans ile çalışıp çalışmadığı değerlendirilmiştir. Daha düşük boyutlarda iş parçasının yüzey frezeleme işleminden toplanan sesler oluşturulan modellerde test edilmiştir. Elde edilen sonuçlar, iş parçasının boyutunun değişiminin oluşturulan sistemin doğruluğunu düşürdüğü ancak yapay sinir ağı kullanılarak oluşturulan modelin hala yüksek doğruluk değerlerine sahip olduğunu göstermektedir. Ek olarak bu çalışmada, özellikleri farklı iki ses sinyali toplama donanımlarından elde edilen ses sinyalleri ile kurulan modellerin performansları karşılaştırılmıştır. Elde edilen sonuçlar yüksek empedans ve düşük hassasiyete sahip donanımdan elde edilen ses sinyalleri ile oluşturulan TDİ sisteminin iş parçası boyut değişiminde daha kötü sonuçlar verdiği görülmüştür. Sonuç olarak, önerilen TDİ sisteminin başarılı bir şekilde uygulanması, takım değişiklikleri için duruş süresini azaltmayı, talaşlı imalat endüstrisindeki hurda miktarını en aza indirmeyi ve kesici takımların en verimli şekilde kullanılmasını sağlayacaktır.

Anahtar kelimeler: Takım Durumu İzleme Sistemleri, Makine Öğrenmesi, Sinyal İşleme, Talaşlı İmalat, Kesici Takım Aşınmaları

TOOL CONDITION MONITORING USING SOUND SIGNAL IN MACHINING PROCESS

SUMMARY

Cutting tool wear and breakage are among the biggest obstacles to fully automated machining operations. An effective tool condition monitoring (TCM) system is the best solution for setting up fully automated manufacturing systems. Although a wide variety of monitoring techniques have been developed for online detection of tool status, the need for a reliable, simple and inexpensive solution still remains. The main purpose of this study is to classify the collected audio signals belonging to different wear status and cutting parameters during the face milling operation by using machine learning techniques and to develop a TCM model to detect the tool condition. In this study, it has been determined that the models created by training the machine learning algorithms with the audio signals collected during the face milling operation can successfully detect the tool wear conditions. A decision making system based on machine learning techniques including artificial neural networks, support vector machine and convolutional neural network approaches has been developed. The success of the installed systems was compared with the obtained prediction accuracies. The developed system is trained with preprocessed sound data. Significant prediction accuracy was obtained by testing the trained model. This proves that an effective TDI system can be established using audio signals and machine learning techniques. In addition, it has been evaluated whether the generated TDI system works with the same performance in different workpiece sizes. The sound signal collected from the face milling process of the workpiece at lower dimensions were tested in the generated model. The results show that the change in the size of the workpiece reduces the accuracy of the generated system, but it still has high accuracy values in the model generated using the artificial neural network. In addition, in this study, the performances of the models constructed with the audio signals obtained from two different audio signal acquisition equipment were compared. The results obtained show that the TDI system, which is created with audio signals obtained from hardware with high impedance and low sensitivity, gives worse results in workpiece size change. In conclusion, successful implementation of the proposed TDI system will enable to reduce downtime for tool changes, minimize the amount of scrap in the machining industry and make the most efficient use of cutting tools.

Keywords: Tool Condition Monitoring Systems, Machine Learning, Signal Processing, Machining, Cutting Tool Wear

1. GİRİŞ

Talaşlı imalat, imalat tarihinde önemli bir rol oynar. Talaşlı imalat, elde edilmek istenen parçalardan beklenen yüksek boyutsal doğruluk ve yüzey kalitesi nedeniyle tercih edilmektedir. İnsan operatörlerin yerini daha verimli, daha az maliyetli otomatik işleme tezgahlarının almaya başladığı 1950'lerin ortalarına kadar talaşlı imalat işlemleri yüksek vasıflı işgücüne dayanıyordu. Bu sistemlerin üretim maliyetlerini düşürme ve ürün kalitesini yükseltme kabiliyeti nedeniyle çok kısa sürede otomatik işleme endüstride yaygın olarak kullanılmaya başlanmıştır.

Otomatik işleme tezgahlarından maksimum verim elde edilebilmesi için devam eden sürecin kesintiye uğramaması gerekir. Ancak başta kesici takım aşınması olmak üzere pek çok durum süreci kesintiye uğratmaktadır. Ayrıca üretim sistemlerindeki teknolojik gelişmeler nitelikli işgücü ihtiyacını doğurmuştur. Son birkaç on yıldır imalat sanayii, özellikle talaşlı imalat sanayii, vasıflı işgücünde ciddi bir düşüşle karşı karşıyadır. Bu nedenle, talaşlı imalat süreçlerinde duruşlara neden olan parametreleri ve bileşenleri izlemek için etkin bir araç geliştirmek otomatik talaşlı imalat süreçlerinde en önemli konulardan biri haline gelmiştir.

Kesici takım aşınması, talaşlı imalat sürecinde meydana gelen duruşların azaltılması için izlenmesi gereken en kritik konulardan biridir. Etkili bir izleme sistemi takım aşınma seviyesini ve takımın kullanım ömrünün sona erdiğini tespit edebilmelidir. Kullanım ömrünü tamamlamış bir kesici takımın tespit edilememesi düşük yüzey kalitesine, boyutsal hatalara ve hatta talaşlı imalat tezgahında arızalara neden olabilir. Kullanım ömrünü tamamlamamış kesici takımların değiştirilmesi ise üretim verimliliğini azaltmaktadır.

Takım aşınmasının izlenmesi, iş parçasının yüzey kalitesi ve boyutsal bütünlüğünün yanı sıra takımdaki titreşimi kontrol etmek için talaşlı imalat sürecinde yeni ve aktif bir araştırma alanı açmıştır. Ayrıca, takım aşınması izleme sistemlerinin geliştirilmesi, üreticilerin makine duruş sürelerini azaltmalarına yardımcı olabilir ve bu da otomasyon sistemlerinde daha yüksek verimlilik elde edilmesini sağlar.

Bu tez çalışmasının temel amacı, yüzey frezeleme işlemi esnasında oluşan sesleri analiz ederek takım aşınma durumu tahmini yapabilecek bir TDİ sistemi oluşturmaktır. TDİ sistemi, farklı aşınma derecelerine sahip kesici takımlar ile gerçekleştirilen yüzey frezeleme işlemlerinden elde edilen seslerden elde edilen öznitelikler ile üç farklı makine öğrenmesi algoritmasının (Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (DVM), Evrişimli Sinir Ağı (ESA)) eğitilmesi ile oluşturulmuştur. Oluşturulan TDİ sistemleri tahmin doğrulukları yönünden karşılaştırılmıştır. Ayrıca oluşturulan TDİ sistemlerinin farklı iş parçası boyutunda aynı performans ile çalışıp çalışmadığının tespit edilmesi amaçlanmıştır. Daha düşük boyutlarda iş parçasının yüzey frezeleme işleminden toplanan sesler oluşturulan modellerde test edilmiştir. Ek olarak bu çalışmada, özellikleri farklı iki ses sinyali toplama donanımı ses sinyallerinin toplanmasında kullanılmıştır. Böylece ses sinyali toplama donanımlarının kurulan TDİ sistemlerinin performansı üzerindeki etkilerinin tespit edilmesi amaçlanmıştır.

Bu tez çalışmasının konusu yüzey frezeleme sırasında elde edilen ses sinyallerini kullanarak makine öğrenmesi temelli bir TDİ sistemi kurmaktır. Bu konunun alt yapısını tanıtmak için ilk olarak literatür araştırması gerçekleştirilmiştir. Bu kapsamda geleneksel talaşlı imalat yöntemlerinden bahsedilerek frezeleme yöntemi ve kullanılan freze tezgâhları konusunda kısaca bilgi verilmiştir. TDİ sistemlerinin kullanım gerekliliğinden ve amacından bahsedilerek TDİ sistemlerinin yapısından bahsedilmiştir. Literatürde farklı sinyal türleri ile kurulan TDİ sistemleri üzerine yapılmış çalışmalar özetlenmiştir. TDİ sistemlerinin akıllı hale getirilmesi için literatürde kullanılan farklı yapay zekâ teknikleri açıklanmıştır.

Materyal ve Yöntem başlığı altında çalışmada kullanılan materyal ve yöntemlerden bahsedilmiştir. Kullanılan kesici takımın, tarama başlığının ve freze tezgahının özelliklerinden ve bu özellikler dikkate alınarak belirlenen talaşlı imalat parametreleri ve seviyeleri açıklanmıştır. Tez kapsamında kullanılan ses sinyali toplama donanımlarının özellikleri açıklanmış ve sinyallerin toplanması ve kaydedilmesinden izlenen metot açıklanmıştır. Çalışmada kullanılan sinyal işleme ve öznitelik oluşturma yönteminden bahsedilerek kullanılan makine öğrenmesi algoritmaları açıklanmıştır. Tez kapsamında kurulan TDİ sistemi ve bu sistemin farklı iş parçası boyutlarında test edilmesi için izlenen deney tasarımları açıklanmıştır.

Tez çalışmasının Bulgular ve Tartışma bölümünde ise farklı makine öğrenmesi algoritmaları ve ses sinyali toplama donanımları ile oluşturulan TDİ sistemleri tahmin

doğruluđu yönünden karşılaştırılmış ve tartışılmıştır. Ayrıca iş parçası boyutunun deđişiminin oluşturulan TDİ sistemlerinin performansı üzerine etkisi tahmin doğruluđu yönünden karşılaştırılmış ve tartışılmıştır.




2. LİTERATÜR ARAŞTIRMASI


Literatürde takım durum izleme sistemlerinin geliştirilmesi için çeşitli metodolojileri ve teknolojileri içeren çalışmalar önerilmiştir. Bu bölümde, talaşlı imalat, kesici takımlarda görülen aşınma ve tipleri, TDİ sisteminin genel yapısı hakkında kısaca bilgiler verilmiştir.

2.1 Talaşlı İmalat


Şekli, yüzey kalitesi ve boyutları belirlenmiş ürünleri elde etmek için iş parçasından metal işleme tezgahlarında talaş kaldırma işlemine talaşlı imalat denir. Talaş kaldırma işlemi kullanılan kesici takım ve iş parçasının izafi hareketi sonucu iş parçasında gerilim oluşturularak gerçekleşir. Yüksek boyutsal ve yüzeysel hassasiyet elde edilmek istenen durumlarda ve ayrıca karmaşık geometrilere sahip ürünlerin elde edilmesinde talaşlı imalat yöntemi kullanılır. Temel olarak talaşlı imalat yöntemleri, geleneksel, geleneksel olmayan ve aşındırma işlemleri olarak 3 gruba ayrılır (Şekil 2.1). Bu çalışmada geleneksel talaşlı imalat yöntemlerinden biri olan frezeleme yöntemi kullanılmıştır. Frezeleme, kendi eksenini etrafında dönen ve birçok kesici ucu bulunan kesici takımlarla talaş kaldırma işlemidir. Frezeleme işlemi çevresel ve alın (yüzey) frezeleme olarak iki ana gruba ayrılabilir. Çevresel frezelemede kesici dişleri kesici takımın yan yüzeyinde bulunan silindirik kesici takımlar kullanılırken alın frezelemede frezeleme dişleri takımın alın yüzeyinde bulunan alın frezeler kullanılmaktadır (Şekil 2.2). Bu çalışmadaki tüm frezeleme işlemleri yüzey frezeleme olarak uygulanmıştır. Frezeleme işleminin yapıldığı makineler freze tezgâhlarıdır. Frezeleme işleminde, takım ucunun düşey, iş parçasının ise yatay doğrultudaki hareketi ile talaş kaldırılır. Freze tezgâhları genel olarak; kontrol-tahrik ünitesi, ana gövde, takımın tutturulduğu ana mil (malafa), parçasının bağlandığı iş tablası ve ayar kollarından oluşmaktadır. Freze tezgâhları malafanın konumuna göre yatay ve dikey olmak üzere iki gruba ayrılırlar (Şekil 2.3). Bu çalışmada dikey freze tezgâhı kullanılmıştır.



Şekil 2.1: Talaşlı imalat işlemleri.



Şekil 2.2: a) Çevresel frezeleme b) Yüzey frezeleme (Gülmez, 2016).



Şekil 2.3: a) Yatay freze tezgâhı b) Dikey freze tezgâhı (Gülmez, 2016).

2.2 Kesici Takımlarda Görülen Aşınma ve Tipleri


Katı cisimlerin izafi hareketleri sebebiyle sürtünen yüzeylerinde malzeme kayıplarının meydana gelmesi olayına aşınma denir. Kesme işlemi sırasında talaş-kesici takım, iş parçası-kesici takım ara yüzlerinde sürtünmeler meydana gelmektedir. Bu etkileşim sırasında farklı aşınma mekanizmalarının biri veya birkaçının etkisiyle kesici takımda aşınmalar meydana gelmektedir. Aşınma mekanizmaları abrasif aşınması, difüzyon aşınması, oksidasyon aşınması, yorulma aşınması, adhesif aşınma olarak sınıflandırılırlar. Talaşlı imalatla kullanılan kesici takımlarda görülen aşınma iş parçası cinsi ve setliğine, kesme hızına, ilerleme miktarına, kullanılan soğutucu ve yağlayıcılara, kesme bölgesinde oluşan sıcaklık gibi pek çok durumdan etkilenmektedir. İş parçası ve talaşın izafi hareketlerinden dolayı kesici takımın ucunda, talaş yüzeyinde ve serbest yüzeyinde aşınma mekanizmalarının biri veya birkaçı sebebiyle aşınmalar oluşmaktadır (Şekil 2.4) (Özdemir ve Erten, 2003).




Şekil 2.4: a) Serbest yüzey aşınması b) Krater aşınması c) Burun aşınması (Özdemir ve Erten, 2003).

2.2.1 Serbest yüzey aşınması

İş parçasının işlenen yüzeyi ile kesici takımın serbest yüzeyi arasında oluşan sürtünmeden dolayı abrasif aşınma mekanizmaları sonucu oluşan aşınmadır. En sık görülen aşınma türüdür. Kesici takımların ömürlerinin belirlenmesinde genellikle bu aşınma türü referans alınmaktadır. Aşınma miktarı yüzeyde oluşan aşınma şeridinin ortalama genişliği (VB) olarak belirlenir (Şekil 2.5). Belirlenen aşınma değerinin aşılması sonucunda sürtünme, titreşim ve kesme bölgesinde sıcaklık artışı meydana gelir. Serbest yüzey aşınmasının zamana bağlı olarak gelişimi Şekil 2.6'da gösterilmiştir (Özdemir ve Erten, 2003).



Şekil 2.5: Kesici takım aşınma ölçüm bölgeleri (Özdemir ve Erten, 2003).



Şekil 2.6: Serbest yüzey aşınmasının zamana bağlı olarak gelişimi (Özdemir ve Erten, 2003).

2.2.2 Krater aşınması

Krater aşınması, kesici takımın talaş yüzeyinde oluşur. Kesilen talaşların kesici takımın talaş yüzeyinden kayarak uzaklaşması esnasında oluşan abrasif ve difüzyon aşınma mekanizmaları sonucu gerçekleşir. Aşınma miktarı krater genişliğinin takım ucuna olan maksimum mesafesi (KB), krater genişliğinin takım ucuna olan minimum mesafesi (KF), maksimum krater derinliği (KT) ve krater merkezinin takım ucuna olan mesafesi (KM) kullanılarak ölçülmektedir (Şekil 2.5). Genellikle düşük seviyelerdeki krater aşınması takım ömrünü kısaltmaz. Ancak yüksek oranda krater aşınması kesme kenarını zayıflatarak kopmalara yol açabilir. Krater aşınmasının zamana göre gelişimi serbest yüzey aşınması ile benzerdir (Şekil 2.6) (Özdemir ve Erten, 2003).

2.2.3 Burun aşınması

Burun aşınması, esas kesici kenar serbest yüzeyi ile yardımcı kesici kenar serbest yüzeyinin takımın burun bölgesiyle kesiştiği bölgede oluşmaktadır. Serbest yüzey aşınmasında olduğu gibi abrasif aşınma mekanizması ve ayrıca korozyon ya da oksidasyon sebebiyle oluşmaktadır. Yüksek seviyelerde burun aşınması işlenen parçanın yüzey kalitesini olumsuz etkilemektedir (Özdemir ve Erten, 2003).

2.3 Takım Durumu İzleme Sistemi

Teknolojik gelişmeler ile talaşlı imalat endüstrisinde akıllı imalat sistemlerinin kullanımı artmaktadır. Ancak mevcut durumda endüstride kesici takım değiştirme prosedürü geleneksel kesici takım ömrü tahminlerine dayanmaktadır. İzin verilen değerlerin üzerinde aşınmış kesici takımların kullanılması ürünün boyutsal ve yüzey kalitesini düşürmekte, takım tezgahının enerji tüketimi arttırmakta, aşırı kesme kuvveti ve sıcaklık sebebi ile kesici takım kırılmasına sonuç olarak takım tezgâhına bile zarar verebilmektedir. Tüm bu olumsuzlukların önlenmesi için TDİ sistemleri büyük önem arz etmektedir. Kullanım ömrünü tamamlamamış kesici takımların değiştirilmesi ise üretimde verimsizliğe neden olmaktadır. TDİ sistemleri ile kesici takımların anlık aşınma tahminleri yapılarak kesici takımların verimli bir şekilde kullanılması sağlanmaktadır. Sonuç olarak TDİ sistemlerinin amacı:

- Kesici takımların anlık aşınma tahminleri yapmak,
- Kesici takımların kırılmasını ve iş parçasına, takım tezgahına zarar vermesini engellemek,
- Üünün boyutsal ve yüzeysel kusurlarının önlemektir.

2.4 Takım Durumu İzleme Sistemlerinin Yapısı

Şekil 2.7’de TDİ sistemlerinin genel yapısı gösterilmektedir. Literatürde yapılan çalışmalar incelendiğinde talaşlı imalat prosesi için geliştirilen TDİ sistemlerinin oluşturulmasında altı temel husus vardır (Abellan-Nebot ve Subirón, 2010):

1. Sensörler: Talaşlı imalat işlemi pek çok fiziksel veri tipi ile karakterize edilebilmektedir. Mikrofon, dinometre, ivme ölçer, akım sensörü gibi sensörler fiziksel büyüklükleri elektrik sinyallerine dönüştürmektedirler. Kurulmak istenen sistem için en uygun veri ve sensör tipinin seçiminde uygulama koşulları, maliyet, güvenilirlik gibi durumlar değerlendirilmelidir.

2. Sinyal İşleme: Sinyal işleme yöntemleri filtreleme (alçak geçiren, bant geçiren, yüksek geçiren) ve amplifikasyon gibi basit veya kompleks işlemlerdir. Kullanılan sistemin örnekleme frekansı limitleri aliasing oluşumundan kaçınmak için dikkate alınmalıdır. Elde edilen sinyalin istenen frekans bileşenlerini elde edebilmek için uygun dijital filtrelerin kullanılmasına dikkat edilmelidir.


3. Öznitelik Oluşturma: Sensörlerden elde edilen sinyallerden, sinyali en iyi şekilde temsil edebilecek öznitelikler çıkarılmalıdır. Zaman, frekans ve wavelet bölgelerinden pek çok öznitelik oluşturulabilmektedir.

4. Öznitelik Çıkarma: Güvenilir bir model geliştirebilmek için oluşturulan özniteliklerden prosesi en iyi temsil edenler seçilmelidir.

5. Deney Tasarımı: Talaşlı imalat prosesinde gerçekleştirilen deneysel çalışmalar hem zaman alan hem de maliyetli uygulamalardır. Efektif bir deney tasarımının seçilmesi endüstri uygulamaları için gereklidir.

6. Yapay Zekâ Teknikleri: Güvenilir bir TDİ sistemi, talaşlı imalat esnasında elde edilen veriler ve performans değişkenleri arasındaki doğrusal olmayan ilişkiyi öğrenebilen yapay zekâ algoritmasına ihtiyaç duymaktadır. Bu seçim temel olarak veri

büyüklüğüne, beklenen doğruluğa ve geçmiş uygulamalardan elde edilen tecrübeler ile yapılmaktadır.



Şekil 2.7: TDİ sistemlerinin yapısı (Abellan-Nebot ve Subirón, 2010).

2.4.1 Sensör sistemleri

Üretim süreçlerinin izlenmesi ve kontrol edilmesinde sensörlerinin kullanımı ilerleyen yıllarda çok daha fazla artması beklenmektedir. Talaşlı imalat prosesinin izlenmesinde temel olarak iki yöntem mevcuttur: doğrudan ve dolaylı ölçüm yöntemleri. Doğrudan ölçüm yönteminde kullanılan lazer, optic ve ultra-sonik sensörler proses üzerinde doğrudan ölçüm sağlamaktadır. Ancak bu yöntemler ile

yapılan ölçümlerin talaşlı imalat işlemi devam ederken yapılması çok zor ve pahalıdır. Dolaylı ölçüm yöntemi, talaşlı imalat anında sensörler yardımı ile alınan verilerin yorumlanması ile yapıldığından dolayı daha ekonomik ve uygulanabilir olarak değerlendirilebilir. Talaşlı imalat anından toplanan ve imalat süreci ile ilgili bilgiler içeren veri çeşitleri ses, titreşim, kesme kuvveti, akım tüketimi, sıcaklık vb. verilerdir.

Talaşlı imalat esnasında oluşan kesme kuvveti kesme işlemi hakkında bilgiler veren en önemli verilerden biridir. Elde edilen kesme kuvveti verisinin analiz edilmesi ile kesici takımın durumu izlenebilmektedir (Chen ve Jen, 2000; Liu ve Wang, 1999; Altintas, 1988; Özel ve Nadgir, 2002; Kene ve Choudhury, 2019; Oraby ve Hayhurst, 2004; Shankar ve diğ, 2019; Li ve Liu, 2019; Zhu ve Zhang, 2019). Ancak çok eksenli dinamometrenin fiyatlarının yüksek olması, imalat ortamında kullanımının uygun olmaması, sınırlı frekans cevap aralığına sahip olması bu yöntemin endüstride kullanımını zorlaştırmaktadır.

Kesici takımda meydana gelen serbest yüzey aşınmasının artması işleme anında meydana gelen titreşimin genliğinde değişikliklere sebep olur. Bu sebeple kesici takımın durumunun izlenmesinde titreşim verisi yaygın olarak kullanılmaktadır (Scheffer ve diğ, 2003; Dimla ve Lister, 2000; Alonso ve Salgado, 2008; Liu ve diğ, 2017; Hesser ve Markert, 2019; Madhusudana ve diğ, 2016). Bu yöntemin başarılı bir şekilde uygulanabilmesine rağmen titreşim sensörleri proses parametrelerindeki değişimlere ve kesme bölgesinden olan uzaklığına karşı çok duyarlıdır. Bu durum pek çok işlem için kullanımını zorlaştırmaktadır.

Elektrik motorlarının kullandıkları akım miktarı üretilen tork ile orantılıdır. Dolayısıyla talaşlı imalat tezgahlarında kullanılan elektrik motorlarının anlık kullandıkları akım miktarı imalat anında meydana gelen kesme kuvveti ile orantılıdır. Bu sebep ile anlık olarak kullanılan akım miktarı ölçülerek kesici takımların durumları izlenebilmektedir (Lee ve diğ, 1995; Li X. L., 2001; Xu ve diğ, 2019; Renones ve diğ, 2010). Ancak kesme kuvvetinin yüksek frekanslı bileşenlerinin elde edilebilmesi akım sensörleri ile oldukça zordur. Bu durum endüstrideki uygulamasını sınırlandırmaktadır.

Talaşlı imalatla kesici ucun iş parçasını koparması anında metaller plastik olarak şekil değiştirir. Plastik şekil alma esnasında mikro yapıdaki dislokasyon hareketleri sonucunda akustik emisyon enerji salınımı gerçekleşir. Akustik emisyon sensörleri ile

toplanan bu sinyaller takım durumu ile ilişkilendirilerek TDİ sistemleri kurulabilmektedir (Li ve Yuan, 1998; Li ve diğ, 1999).


Genel olarak TDİ sistemleri tek bir veri çeşidi kullanılarak geliştirilmektedir. Ancak kurulan sistemin güvenilirliğini arttırmak için farklı veri çeşitleri bir arada kullanılmaya çalışılmaktadır. Bu duruma sensor füzyon sistemleri adı verilmektedir. Kullanılacak veri çeşitlerinin seçimleri önem arz etmektedir. Örneğin dinamometre ve akım sensörü birbirleri ile aynı bilgileri farklı sinyaller ile toplamaktadır. Aynı şekilde kesme kuvveti ve titreşim ölçümleri birbirleri ile yakın bilgiler vermektedir. Ancak akustik emisyon ile kesme kuvveti daha farklı bilgiler vermekte ve sensör füzyon sistemler için uygun olmaktadır (Ertekin ve diğ, 2003). Bu yöntem kullanılarak takım durum izleme sisteminin kurulmasına yönelik pek çok çalışma mevcuttur (Bahr ve diğ, 1997; Niu ve diğ, 1998; Haber ve diğ, 2004; Chen ve Jen, 2000; Ghosh ve diğ, 2007; Zhang ve diğ, 2015; Stavropoulos ve diğ, 2016).

Talaşlı imalat esnasında ortaya çıkan ses dalgaları prosesin ve takım durumu hakkında bilgiler vermektedir. Ancak literatürde ses verisi kullanarak TDİ sistemi oluşturulması ile ilgili yapılmış çalışmalar diğer yaklaşımlara göre daha azdır. Kothuru ve arkadaşları (2018) yaptığı çalışmada kesici takım aşınmalarını izleyebilmek için ses sinyallerini ve karar verme algoritması olarak DVM kullanmışlardır. Kurulan TDİ sisteminin de yüksek doğruluk oranı elde edilmiştir (Kothuru ve diğ, 2018). Zhixiong ve arkadaşları (2019), ses sinyallerini yenilikçi bir yol ile kullanmışlardır. Elde edilen ses sinyalleri ilk olarak kör kaynak ayrıştırma (KKA) yöntemi ile gürültü ve kaynak sinyalleri ayrılmıştır. Elde edilen kaynak sinyalinin boyutunun azaltılması için genişletilmiş evrişimli sınırlı bileşen analizi (GESBA) ve çok değişkenli senkrosıkıştırma dönüşümü (ÇDSD) kullanılmıştır. DVM algoritması kullanarak oluşturdukları TDİ sistemi ile yüksek tahmin başarıları elde etmişlerdir (Zhixiong ve diğ, 2019). Ravikumar ve Ramachandran (2018) talaşlı imalat anında toplanan ses sinyallerini wavelet dönüşümü kullanılarak öznelilikler elde edilmiş ve karar ağaçları (KA) algoritması kullanılarak TDİ sistemi oluşturulmuştur (Ravikumar ve Ramachandran, 2018). Liu ve arkadaşları (2019), dalgacık paket ayrıştırması (DPA) ile istatistiksel öznelilikler elde etmişlerdir. Doğrusal ilkelleme (Dİ), doğrusal olmayan ilkelleme (DOİ) ve YSA ile elde edilen öznelilikler kullanarak kesici takım aşınmasını tahmin edebilen bir model oluşturmuşlardır (Liu ve diğ, 2019). Kothuru ve arkadaşları (2019), elde edilen ses sinyallerinin kısa süreli Fourier dönüşümünü (KSFD) alarak

spektrogram elde etmiş ve spektrogramı ESA eğitmek için kullanmışlardır (Kothuru ve diğ, 2019). Alzahrani ve arkadaşları (2018), ses sinyallerinin hızlı Fourier dönüşümü (HFD) alarak mutlak spektrum değerlerini DVM algoritmasını eğitmek için kullanmışlardır ve yüksek tahmin değerleri elde etmişlerdir. Ses sinyali kullanılarak TDİ sistemlerinin kurulmasına yönelik çalışmalar Çizelge 2.1’de tablolastırılmıştır.

2.4.2 Sinyal işleme

TDİ sistemlerinin kurulmasındaki en büyük engel talaşlı imalat prosesinin doğrusal olmayan ve zamanla değişen yapısıdır. Ayrıca toplanan sinyallerdeki değişimlerin kesici takımların aşınması ile mi yoksa prosesin farklı bir durumunun değişiminden mi kaynaklandığını tespit edebilmek güçtür. Bu sebeple sinyal işleme yöntemleri etkili bir TDİ sisteminin kurulabilmesi için zorunlu bir işlemdir. Sinyal işleme işlemleri sırasıyla sinyal ön işleme, öznitelik oluşturma ve öznitelik seçimi/çıkarmı adımlarından oluşmaktadır (Şekil 2.8). Ses sinyali kullanılarak TDİ sistemlerinin kurulmasına yönelik çalışmalar Çizelge 2.1’de tablolastırılmıştır.



Şekil 2.8: Sinyal işleme işlemindeki adımlar (Abellan-Nebot ve Subirón, 2010).

2.4.2.1 Sinyal ön işleme

Sinyal ön işleme sensörlerden elde edilen sinyallerin proses ile ilgili sahip olduğu bilgi seviyeleri arttırmak için gerekli bir işlemdir. Bu adımda çevresel etkilerin neden olduğu gürültü sinyallerini ayıklayarak ilgilenilen bilgilere sahip sinyaller elde edilir. Sinyal ön işleme genel olarak analog ve dijital ön işleme olarak ikiye ayrılmaktadır. Analog ön işlemede toplanan analog sinyal sayısallaştırılmaktadır. Sensörler ile toplanan sinyaller, sensörün frekans cevap aralığında kalması için filtrelenmektedir. Dijital ön işlemede sinyallerden istenen frekans aralıklarının elde edilebilmesi için alçak, yüksek, aralık geçiren dijital filtreler ile filtrelenmektedir. Dijital filtreleme pek çok uygulamada yüksek frekanslı gürültüleri sinyalden çıkarmak için kullanılmaktadır. Ghosh ve arkadaşları (2007) talaşlı imalat esnasında toplanan kesme

kuvveti sinyallerini 3.derece alçak geçiren Butterworth ile filtreleyerek oluşturulan TDİ sisteminin performansında iyileşme sağlamışlardır (Ghosh ve diğ, 2007).

2.4.2.2 Öznitelik oluşturma

Talaşlı imalat esnasında elde edilen sinyallerden proses ve kesici takım durumunu en iyi şekilde temsil edebilecek özniteliklerin çıkarılması gerekmektedir. Sinyallerden özniteliklerin çıkarılması ayrıca ilişkisiz verilerin ayıklanması anlamına gelmektedir. Zaman bölgesi analizlerinde sinyaller zamanın bir fonksiyonu olarak ifade edilir. Zaman bölgesi analizleri daha çok akustik emisyon ve kesme kuvveti sinyallerinden öznitelik çıkarmak için kullanılmaktadır. Bu çalışmalarda kuvvet sinyalleri ve takım aşınması arasında iyi bir ilişki çıkarılabilmektedir (Oraby ve diğ, 2005; Al-Habaibeh ve diğ, 2010; Sharma ve diğ, 2008). Zaman bölgesi verileri HFD algoritması ile frekans bölgesine dönüştürülmektedir. Bu durum sinyallerin istenen frekans bileşenleri üzerinde analiz yapılmasına imkân vermektedir. Titreşim ve ses verilerinin öznitelikleri genellikle frekans bölgesi analizleri ile elde edilmektedir (Dornfeld ve Rangwala, 1990; Sharma ve diğ, 2008). Ancak bu yöntemin dezavantajı, takım aşınması ile ilişkilendirilebilecek frekans bileşenlerinin belirlenmesinin oldukça zor olmasıdır. Wavelet dönüşümü sinyalleri zaman ve frekans bölgelerinde gösterilmesini sağlamaktadır. Wavelet dönüşümü sinyallerden zaman-frekans bölgesinde öznitelikler elde edilmesini sağlar (Lee S., 2010; Fang ve diğ, 2014). Sinyallerin zaman-frekans bölgesine dönüştürülmesinde kullanılan bir diğer yöntem KSFD'dür (Seemuang ve diğ, 2016; Kothuru ve diğ, 2019). Hilbert-Huang dönüşüm (HHD) sinyallerden öznitelik çıkarmak için kullanılan diğer yöntemlerden biridir (Wolszczak ve diğ, 2017; Zhang ve diğ, 2015; Kalvoda ve Hwang, 2010; Antonio ve diğ, 2012).

Fourier dönüşümü (FD)

FD sinyal analizinde kullanılan pek çok matematiksel araçlardan biridir. Yöntem sinyalleri sinüzoidal veya karmaşık üstel fonksiyonlara ayrıştırarak frekans bölgesinde gösterilmesini sağlar. Dönüşümün tersinin alınmasıyla sinyalin orijinal zaman bölgesindeki formu tekrar elde edilir. Sürekli Zamanlı Fourier dönüşümü (SZFD) aşağıdaki matematiksel ifade ile temsil edilir:

$$X(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t) e^{-i\omega t} dt \quad (2.1)$$

Denklemden bulunan $x(t)$ orijinal sinyal, $X(\omega)$ sinyalin frekans bölgesi, i karmaşık sayı, ω açısal frekans, t ise zaman indeksidir. SZFD'nin tersi aşağıdaki matematiksel ifade ile temsil edilir:

$$x(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} X(\omega) e^{i\omega t} dt \quad (2.2)$$


Ayrık zamanlı sinyallerde Fourier dönüşümünün diğer bir formu olan Ayrık Zamanlı Fourier dönüşümü (AZFD) kullanılmaktadır. Yukarıdaki formüllerde sürekli zamanlı işlemler ayrık zamanlı işlemlere çevrildiğinde aşağıdaki formül elde edilir:

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-\frac{2\pi i k n}{N}} \quad k = 0, 1, \dots, N-1 \quad (2.3)$$

Denklemden bulunan $x(n)$ orijinal sinyal, $X(k)$ sinyalin frekans bölgesi i karmaşık sayı, n ise zaman indeksidir. AZFD'nin tersi ise aşağıda belirtildiği gibi matematiksel olarak gösterilmektedir:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{\frac{2\pi i k n}{N}} \quad n = 0, 1, \dots, N-1 \quad (2.4)$$


2.3 denkleminde gösterilen AZFD'nin hesaplanması için her bir $X(k)$ için N adet karmaşık çarpma ve $N-1$ adet karmaşık toplama işlemi yapılması gerekmektedir. N adet AZFD almak istediğimizde N^2 adet çarpma ve $N(N-1)$ adet ise toplama işlemi yapılması gerekmektedir. Bu duruma ek olarak her karmaşık çarpma işlemi dört gerçel çarpma ve iki gerçel toplama işlemi, her bir karmaşık toplama ise iki gerçel toplama işlemiyle gerçekleştirilir. Sonuç olarak N 'nin çok büyük bir değer olması durumunda AZFD'nin hesaplanması oldukça zorlaşmaktadır. Bu durumun üstesinden gelebilmek için Cooley ve Tukey HFD algoritmasını geliştirmişlerdir. AZFD ve HFD temel olarak aynı sonuçları vermelerine rağmen HFD gerekli olan denklem sayısını düşürerek işlem için gerekli süreyi kısaltmaktadır. HFD hesaplanırken veri seti daha küçük veri setlerine bölünür ve ayrı ayrı AZFD hesaplanır. Şekil 2.9'da 8 noktalı AZFD işleminin uygulanması gösterilmektedir. Adet 2 noktalı AZFD'nin hesaplanmasından sonra 2 adet 4 noktalı AZFD hesaplanır. Son olarak 1 adet 8 noktalı AZFD hesaplanarak 3 adımda işlemler tamamlanır (Mehrotra ve diğ, 2017).



Şekil 2.9: HFD Blok Diyagramı (Mehrotra ve diğ, 2017).

Kısa süreli Fourier dönüşümü (KSFD)

Bir önceki bölümde bahsedilen Fourier dönüşümü formüllerinde görüleceği üzere yöntem sinyali tüm bir zamanda analiz eder. Bu durum sinyalin frekanslarının zamana bağlı olarak değişimlerinin incelenmesini olanaksız hale getirir. Konuşma sinyalleri gibi pek çok sinyal zamana bağlı olarak frekans bileşenlerinde değişimler olmaktadır. KSFD sinyallerin frekans değişimlerini değerlendirme imkânı sağlar. Bu yöntemde sinyal sonlu uzunluktaki parçalara pencereleme fonksiyonları kullanılarak kesilir ve her bir parça Fourier dönüşümüne tabi tutulur. Sonuçların iyileştirilmesi için kesilen parçalar birbirlerinin üzerine bindirme yapacak şekilde elde edilir (Şekil 2.10).



Şekil 2.10: KSFD adımları (Jeon ve diğ, 2020).

2.4.2.3 Öznitelik seçimi/çıkarımı

Öznitelik oluşturma işleminden sonra farklı sensör sinyallerinden pek çok öznitelik elde edilebilmektedir. Basit tahmin modeli ve daha güvenilir TDİ sistemi için kullanılacak özniteliklerin prosesi en iyi şekilde temsil etmelidir. Bu sebeple öznitelik seçme veya çıkarma işlemi çoğu durumda yapılması gerekmektedir. Öznitelikler takım tezgâhı, iş parçası malzemesi, takım tutucu gibi pek çok parametreden etkilendikleri için TDİ sistemi için en uygun özniteliği seçme çok zor bir işlemdir. Bu sebeple öznitelik sayısının azaltılması için sistematik yaklaşımlar kullanılmaktadır. Genel olarak TDİ sistemlerinde ortalama kareler hatası (OKH), ortalama gibi özniteliklerin seçimi yapılmaktadır (Jemielniak, 2000; Kim ve Chu, 2001; Kuo ve Cohen, 1999).

2.4.3 Yapay zekâ teknikleri

Deneyssel çalışmalar ile elde edilen sinyallerden zaman, frekans ve zaman-frekans bölgesi öznitelikleri elde edilmektedir. Bu öznitelikler kullanılarak karar verme algoritmaları sayesinde takım durumu tahmin edilmektedir. Karar verme algoritmaları TDİ sisteminin kurulmasında hayati bir rol oynamaktadır. Takım durumunun tahmininde literatürde pek çok teknik kullanılmıştır. DVM (Zhou ve diğ, 2020), YSA (Liu ve diğ, 2019), karar ağaçları (KA) (Dahe diğ, 2021), evrişimli sinir ağları, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UATBÇS) (Azmi, 2015), Hidden Markov modeli (Wang ve Wang, 2012), bulanık mantık (BM) (Kuo ve Cohen, 1999) bunlardan birkaçıdır. Ses sinyali kullanılarak TDİ sistemlerinin kurulmasına yönelik çalışmalar Çizelge 2.1’de tablolastırılmıştır.

2.4.3.1 Yapay sinir ağları (YSA)


Son yıllarda en çok ilgi gören karar verme metotlarından biri de yapay sinir ağları modelidir. Çalışma prensibi insan beyninin işleyiş şekline ilham alarak oluşturulmuştur. Her biri belirli sayıda nöron içeren katmanlardan oluşmaktadır. İlk katman girişi son katman çıkışı ifade etmektedir. Bu katmanlardaki nöronlar gizli katmanlardaki her nöron ile bağlantı oluşturmaktadır. Her katmandaki nöron bağlantıları ağırlıklandırılmıştır ve ağırlıklar modelden en iyi sonucu alabilmek için eğitilerek güncellenir. Her bir nöron farklı ağırlıktaki girişlere ve bunun sonucunda çıkışa sahiptir. Farklı ağırlıklara sahip girişlerin toplamı aşağıdaki denklemdeki gibi ifade edilir:

$$n = \sum_{i=1}^P w_i x_i + b \quad (2.5)$$

Denkleminde yer alan P giriş sayısı, w giriş ağırlıkları, x giriş değeri ve b biasdır. Ağırlıklandırılmış girişler bias ile toplanarak aktivasyon fonksiyonuna tabi tutulur (Şekil 2.11). Böylece o nörona ait çıkış elde edilir. Aktivasyon fonksiyonu “f” harfi ile gösterildiğinde aşağıdaki denklem elde edilir:

$$f(n) = f\left(\sum_{i=1}^P w_i x_i + b\right) \quad (2.6)$$


Aktivasyon fonksiyonları eşik fonksiyon, sigmoid fonksiyon, hiperbolik tanjant fonksiyonu veya Relu gibi pek çok formda olabilir (Ertunc ve diğ, 2013).



Şekil 2.11: Bir nöronda gerçekleşen işlemler.

Sigmoid aktivasyon fonksiyonu, girdi olarak gerçek sayıları alır ve çıktıyı $[0,1]$ aralığında oluşturur (Şekil 2.12). Sigmoid fonksiyonunun eğrisi 'S' şeklindedir. Sigmoid'in matematiksel gösterimi aşağıdaki formül ile ifade edilir.


$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.7)$$



Şekil 2.12: Sigmoid aktivasyon fonksiyonu.

Hiperbolik tanjant aktivasyon fonksiyonu, girdi olarak gerçek sayıları alır ve çıktıyı $[-1,1]$ aralığında oluşturur (Şekil 2.13). Hiperbolik tanjant'ın matematiksel gösterimi aşağıdaki formül ile ifade edilir.


$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.8)$$



Şekil 2.13: Hiperbolik tanjant aktivasyon fonksiyonu.

Rectifier Linear Unit (ReLU) sinir ağlarında en yaygın olarak kullanılan aktivasyon fonksiyonudur. Tüm giriş değerlerini pozitif sayılara dönüştürmek için kullanılır (Şekil 2.14). ReLU'nun avantajı, diğerlerine kıyasla çok az hesaplama yükü gerektirmesidir. ReLU'nun matematiksel gösterimi aşağıdaki formül ile ifade edilir.

$$f(x) = \max(0, x) \quad (2.9)$$



Şekil 2.14: ReLU aktivasyon fonksiyonu.

Sınıflandırma işlemi yapan sinir ağlarında bazı yitim fonksiyonlarını kullanarak eğitim örnekleri üzerinde YSA modeli tarafından üretilen tahmin hatası hesaplanır. Bu tahmin hatası, tahminin gerçek çıktıdan ne kadar farklı olduğunu söyler. Ardından bu hata, YSA modelinin öğrenme sürecinde optimize edilir. Yitim fonksiyonu, hatayı hesaplamak için iki parametre kullanır, ilk parametre YSA modelinin tahmin çıktısıdır ve ikincisi gerçek çıktıdır. Kategorik çapraz entropi çoklu sınıflandırmalarda sıklıkla kullanılan yitim fonksiyonudur. Çok sınıflı sınıflandırma problemlerinde karesel hata kaybı fonksiyonunun bir alternatifi olarak yaygın olarak kullanılmaktadır. Çıktıyı bir olasılık dağılımı içinde oluşturmak için çıktı katmanında softmax aktivasyonlarını kullanır. Çapraz entropi fonksiyonunun formülü 2.10'daki denklemde verilmiştir. y_i değeri beklenen değer p_i ise her çıktı grubunun olasılığını belirtmektedir.

$$H(\mathbf{p}, \mathbf{y}) = \sum_i \mathbf{y}^i \log(\mathbf{p}^i) \quad (2.10)$$

Öğrenme süreci iki ana adımı içerir, ilki öğrenme algoritmasının (Optimizer) seçimi ve sonraki adım, sonucu iyileştirmek için bu öğrenme algoritmasında çeşitli iyileştirmeler yapılmasıdır. Herhangi bir denetimli öğrenme algoritmasının temel amacı, hatayı (tahmin edilen çıktı ile gerçek çıktı arasındaki farkı) en aza indirmektir. YSA modeli için gradyan tabanlı öğrenme yöntemleri yaygın olarak kullanılmaktadır. Hatayı azaltmak için, model parametreleri her eğitim döneminde sürekli olarak güncellenir ve model, her eğitim döneminde yerel olarak en uygun çözümü yinelemeli olarak arar. Gradyan iniş algoritması, eğitim hatasını azaltmak için her eğitim döneminde model parametrelerini sürekli olarak günceller. Bu parametreleri doğru bir şekilde güncellemek için öncelikle modelin parametrelerine göre birinci mertebeden türev kullanarak amaç fonksiyonunun eğimini (gradyanını) hesaplar ve ardından hatayı minimize etmek için parametreyi eğimin tersi yönünde günceller. Bu parametre güncelleme işlemi, modelin geri yayılımı sırasında yapılır, burada her bir nörondaki gradyan, önceki katmanından ait tüm nöronlara geri yayılır. Bu işlem matematiksel olarak şu şekilde temsil edilebilir:

$$\mathbf{w}_{ij}^t = \mathbf{w}_{ij}^{t-1} - \Delta \mathbf{w}_{ij}^t \quad (2.11)$$

$$\Delta \mathbf{w}_{ij}^t = \rho * \frac{dE}{d\mathbf{w}_{ij}^t} \quad (2.12)$$


formülde yer alan ρ öğrenme oranı, E tahmin hatasını, $\mathbf{w}_{ij}^t$ t. epoch'daki güncel ağırlığı, $\mathbf{w}_{ij}^{t-1}$ (t-1). epoch'daki ağırlığı belirtmektedir.

YSA kullanılarak takım durumunun izlenmesi ilgi gören ve üzerinde araştırmaların yapıldığı bir yöntemdir. D'Addona ve arkadaşları, YSA algoritmasını kullanarak kesici takım aşınmasını düşük bir tahmin hatası ile tahmin edebilen bir model oluşturabilmişlerdir (D'Addona ve diğ, 2011). Pal ve arkadaşları EN19 çeliğinin tornalanması sırasında kesici takım aşınmasını başarılı bir şekilde tahmin eden TDİ sistemini YSA algoritması kullanarak oluşturmuşlardır (Pal ve diğ, 2011). Shankar ve arkadaşları, kesme kuvveti ve ses sinyalleri ile YSA ve ANFIS algoritmaları ile serbest yüzey aşınmasını tahmin edebilecek TDİ sistemi oluşturmuşlardır. Ortalama kareler hataları (MSE) değerlendirildiğinde YSA ile oluşturulan sistemin daha iyi performans

verdiği bulunmuştur (Shankar ve diğ, 2018). Ancak YSA modellerinin eğitilebilmesi için daha fazla sayıda veri gerekmektedir (Salimiasl ve Özdemir, 2016).

2.4.3.2 Destek vektör makineleri (DVM)

DVM, sınıflandırma ve regresyon görevi için çekirdek tabanlı bir makine öğrenme modeli olarak kullanılmaktadır. DVM'nin olağanüstü genelleme yeteneği, optimal çözümü ve ayırt edici gücü ile birlikte son yıllarda veri madenciliği, örüntü tanıma ve makine öğrenmesi topluluklarının dikkatini çekmiştir. DVM, pratik ikili sınıflandırma problemlerini çözmek için güçlü bir araç olarak kullanılmıştır. Örüntü sınıflandırmasında temel amaç, eğitim verisi için performansı maksimize eden bir model elde etmektir. Geleneksel eğitim yöntemleri, her bir girdi-çıkı çiftinin ait olduğu sınıf içinde doğru bir şekilde sınıflandırılmasını sağlayacak şekilde modelleri oluşturur. Bununla birlikte, sınıflandırıcı eğitim verileri için çok uygunsa, model genelleme yapmayı öğrenmek yerine eğitim verilerini ezberlemeye başlar ve sınıflandırıcının genelleme kabiliyetini düşürür. DVM'nin ana motivasyonu, eğitim setindeki birkaç sınıfı, aralarındaki marjı en üst düzeye çıkaran bir yüzeyle ayırmaktır. Başka bir deyişle, DVM, bir modelin genelleme yeteneğini en üst düzeye çıkarmaya izin verir. Bu, eğitim veri setindeki ortalama karesel hatanın en aza indirilmesi yerine, bir modelin genelleme hatası üzerindeki bir sınırın en aza indirilmesine izin veren yapısal risk minimizasyonu ilkesinin amacıdır (Cervantes ve diğ, 2020).



Şekil 2.15: İki sınıf ile eğitilen DVM için maksimum margin (Filipe ve diğ, 2012).

Verilen öğrenme verilerini ayırmak için bir hiper düzlem çizer ve bu düzlemin her sınıf verileri için de maksimum uzaklıkta olmasını hedefler. Şekil 2.15'te gösterildiği gibi sınıfları ayırmak için bir doğru çizilmiştir. Doğrunun ± 1 'i arasında kalan bölge margin olarak ifade edilir. 2.13'teki formülde yer alan w ifadesi ağırlık vektörünü, x ifadesi öznitelik vektörünü ve b ifadesi ise sapmadır.

$$\hat{y} = \begin{cases} 0 & \text{eğer } w^T \cdot x + b < 0, \\ 1 & \text{eğer } w^T \cdot x + b \geq 0 \end{cases} \quad (2.13)$$

Bu metottaki ana hedef margini maksimize eden hiper düzlemleri bulmaktır. Marginin maksimize edilebilmesi için $\|w\|$ minimize edilmelidir. Minimize etme işlemi lagrange çarpanı metodu ile çözülebilecek 2.14'teki quadratic optimizasyon problemi ile gerçekleştirilmektedir


$$\begin{aligned} & \arg_{w,b} \min \frac{1}{2} \|w\|^2 \\ & \text{s.t: } y^{(i)}(W^T x^{(i)} + b) \geq 1, i = 1, \dots, m \end{aligned} \quad (2.14)$$

Yukarıda bahsedilen işlemler doğrusal olarak ayrılabilen veri setleri için geçerlidir. Ancak çoğu durumda bu söz konusu değildir. Çalışmamızda 3 adet farklı aşınma değerlerine sahip grup bulunmaktadır. Kernel fonksiyonları kullanılarak, doğrusal olarak ayrılamayan veri setleri yüksek boyutlu uzaylarda doğrusal olarak ayrılabilir

duruma getirilebilmektedir. TDİ sistemlerinin kurulmasında karar verme algoritması olarak DVM sıklıkla kullanılmaktadır (Zhou, ve diğ, 2020; Dahe ve diğ, 2021; O'Shea ve Nash, 2015; Sun ve diğ, 2004).

2.4.3.3 Evrişimli sinir ağları (ESA)

ConvNet olarak da isimlendirilen ESA, derin ileri besleme mimarisine sahip bir YSA türüdür. Tam bağlantılı katmanlarına sahip diğer ağlarla karşılaştırıldığında, nesnelerin yüksek düzeyde soyutlanmış özelliklerini öğrenebilirler. ESA modeli, girdi verilerinin çeşitli özelliklerini birden çok soyutlama düzeyiyle öğrenebilen sonlu bir işleme katmanı kümesinden oluşur. Başlangıç katmanlar yüksek seviyeli özellikleri öğrenir ve çıkarırken daha derin katmanlar düşük seviyeli özellikleri öğrenir ve çıkarırlar. Klasik bir ESA modelinin yapısı şekil 2.16'da gösterilmektedir.



Şekil 2.16: Klasik ESA Yapısı (O'Shea ve Nash, 2015).

Günümüzde ESA, görüntü sınıflandırma, nesne algılama, yüz algılama, konuşma tanıma, araç tanıma, yüz ifadesi tanıma, metin tanıma ve çok daha fazlası gibi çeşitli bilgisayarla görü tabanlı uygulamalarda umut verici sonuçlar elde etmektedir.

ESA birden fazla katmandan oluşmaktadır. Evrişim katmanı, ESA mimarisinin en önemli bileşenidir. Bir çıktı özellik haritası oluşturmak için giriş görüntüsüyle evrişim işlemi uygulayacak filtreler içermektedir. Filtreler, her bir değerin filtrenin ağırlığı olarak bilindiği bir matris olarak tanımlanır. ESA modelinin eğitim sürecinin başlangıcında, filtrelerin tüm ağırlıkları rastgele sayılarla oluşturulur. Ardından, modelin eğitim sürecinde ağırlıklar ayarlanır böylece filtreler anlamlı özellikleri çıkarmayı öğrenirler. 2 boyutlu örnek bir filtre şekil 2.17'de gösterilmiştir.


0	1
-1	2

Şekil 2.17: 2 x 2 boyutunda filtre.

Girişin vektör formatında olduğu klasik sinir ağlarının aksine ESA’da giriş çok kanallı bir görüntüdür. Şekil 2.18’de gösterilen 4×4 boyutlu gri seviyeli bir görüntünün şekil 2.17’de gösterilen rasgele başlatılmış ağırlıklara sahip 2×2 boyutlu bir filtre ile evrişim işleminde, 2×2 boyutlu filtre tüm 4×4 boyutundaki görüntü üzerinde yatay ve dikey olarak kaydırılır ve kaydırma boyunca filtre ve görüntü ağırlıkları çarpılır. Çıktı özellik haritasında bir ağırlık değeri oluşturmak için tüm değerler toplanır. Bu işlem, çekirdek artık daha fazla kayamayana kadar devam eder. 5 adımlı evrişim işlemi şekil 2.19’da gösterilmiştir.

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

Şekil 2.18: Gri seviyeli görüntü.



Şekil 2.19: Evrişim işleminin ilk 5 adımı (Ghosh ve diğ, 2020).


Yukarıdaki verilen evrişim işlemi örneğinde, giriş görüntüsüne dolgu olmadan ve çekirdeğe 1'lik adımlarla evrişim işlemi uygulanmıştır. Ancak evrişim işleminde başka adım değeri kullanılabilmektedir. Eğer evrişim işleminin adımını arttırsak, bunun sonucunda daha düşük boyutlu özellik haritası elde edilir.

Doldurma, girdi görüntüsünün kenar boyutu bilgisini daha fazla önemsemek için önemlidir, aksi takdirde herhangi bir dolgu kullanılmadan kenar boyutu bilgisi çok hızlı bir şekilde silinir. Dolgu aynı zamanda girdi görüntü boyutunu artırmak için kullanılır, bunun sonucunda çıktı özellik haritası boyutu da artar. Evrişim işleminden sonra çıktı özellik haritası boyutu aşağıdaki formüller ile hesaplanır. h' çıktı özellik haritasının yüksekliğini, wd' çıktı özellik haritasının genişliğini, h girdi görüntüsünün yüksekliğini, wd girdi görüntüsünün genişliğini, f filtre boyutunu, p dolguyu, s ise evrişim işleminin adımını ifade etmektedir.

$$h' = \left\lfloor \frac{h - f + p}{s} + 1 \right\rfloor \quad (2.15)$$

$$w' = \left\lfloor \frac{wd - f + p}{s} + 1 \right\rfloor \quad (2.16)$$

Havuzlama katmanı, büyük boyutlu özellik haritalarını daha düşük boyutlu özellik haritalarına dönüştürür. Özellik haritalarını küçültürken, her havuzlama adımında her zaman en baskın özellikleri (veya bilgileri) korur. Maksimum havuzlama, minimum havuzlama, ortalama havuzlama, kapılı havuzlama, ağaç havuzlama gibi farklı havuzlama teknikleri vardır. Örnek bir havuzlama işlemi 2.20'de gösterilmektedir.




Şekil 2.20: Örnek bir havuzlama işlemi (Ghosh ve diğ, 2020).

Havuzlama işleminden sonra çıktı özellik haritası boyutu 2.17 ve 2.18'deki formüller ile hesaplanır. h' çıktı özellik haritasının yüksekliğini, wd' çıktı özellik haritasının genişliğini, h girdi görüntüsünün yüksekliğini, wd girdi görüntüsünün genişliğini, f filtre boyutunu, s ise evrişim işleminin adımını ifade etmektedir.

$$h' = \left\lceil \frac{h - f}{s} \right\rceil \quad (2.17)$$

$$w' = \left\lceil \frac{wd - f}{s} \right\rceil \quad (2.18)$$

Genellikle her ESA mimarisinin (sınıflandırma için kullanılan) son katmanı (veya katmanları), bir katmanın içindeki her bir nöronun önceki katmanından her bir nörona bağlı olduğu tam bağlantılı katmanlardan oluşur (Şekil 2.21). Tam bağlantılı katmanların son katmanı, ESA mimarisinin çıktı katmanı (sınıflandırıcı) olarak kullanılır. Tam bağlantılı katmanlar bir YSA türüdür. Tam bağlantılı katmanlar, bir dizi metrik (özellik haritaları) biçimindeki son evrişim veya havuz katmanından girdileri alır ve düzleştirilir. Daha sonra bu vektör ile tam bağlantı katmanına girdi olarak kullanılır.



Şekil 2.21: Tam bağlantılı katman (Ghosh ve diğ., 2020).

Çizelge 2.1: Ses sinyalleri kullanılarak TDİ sistemlerinin oluşturulmasına yönelik çalışmalar.

S.N.	Yazar	Sinyal işleme	Makine öğrenimi
1.	Kothuru ve diğ. (2018)	Dalgacık Paket Dönüşümü (DPD), HFD	DVM
2.	Zhixiong Li ve diğ. (2019)	DPD, KKA, GESBA, ÇDSD	Sınıflama ve Regresyon Ağacı Algoritması (SRAA), Rassal Orman (RO), K-En Yakın Komşu (kEYK) ve DVM,

Çizelge 2.1 (Devam): Ses sinyalleri kullanılarak TDİ sistemlerinin oluşturulmasına yönelik çalışmalar.


3.	Ravikumar ve Ramachandran (2018)	Ayrık Dalgacık Dönüşümü (ADD)	RO, KA
4.	Liu ve diğ. (2019)	DPA	Dİ, DOİ, YSA
5.	Ai ve diğ. (2012)	Doğrusal Öngörü Kepstral Katsayıları (DÖKK)	Kullanılmamıştır.
6.	Salgado ve Alonso (2007)	Tekil Spektrum Analizi (TKA)	En Küçük Kareler Destek Vektör Makineleri (EKKDVM)
7.	Aliustaoglu ve arkadaşları (2009)	Zaman bölgesinde istatistiksel öznitelikler	BM
8.	Seemuang ve diğ. (2015)	KSFD	Kullanılmamıştır.
9.	Alonso ve Salgado (2005)	TKA	YSA
10.	Kothuru ve diğ. (2019)	KSFD	ESA
11.	Raja ve diğ. (2013)	HHD	Kullanılmamıştır.
12.	Raja (2013)	HHD	YSA
13.	Raja ve diğ. (2012)	HHD	Kullanılmamıştır.
14.	Charoenprasit ve diğ. (2018)	KSFD	Kullanılmamıştır.
15.	Huda ve diğ. (2020)	HFD, DPD	Kullanılmamıştır.
16.	Alzahrani ve diğ. (2018)	HFD	DVM
17.	Krishnan ve Samraj (2017)	Temel Bileşenler Analizi (TBA)	Kullanılmamıştır.
18.	Takahashi ve diğ. (2015)	HFD	Kullanılmamıştır.

Çizelge 2.1 (Devam): Ses sinyalleri kullanılarak TDİ sistemlerinin oluşturulmasına yönelik çalışmalar.

19.	Górski ve diğ. (2020)	Zaman bölgesinde istatistiksel öznitelikler elde edilmiştir.	Çoklu Doğrusal Regrasyon (ÇDR)
20.	Downey ve diğ. (2014)	HFD	Kullanılmamıştır.
21.	Rubio ve Teti (2010)	HFD	YSA
22.	Prakash ve Samraj (2019)	TBA	Kullanılmamıştır.
23.	Li ve diğ. (2016)	Zaman bölgesinde istatistiksel öznitelikler elde edilmiştir.	Kullanılmamıştır.
24.	Mannan ve diğ. (2000)	HFD	Kullanılmamıştır.
25.	Ferguson ve diğ. (2018)	HFD	Gauss Süreç Regresyonu (GSR)
26.	Shankar ve diğ. (2018)	Sinyalin zaman bölgesindeki genlik değerleri doğrudan kullanılmıştır.	YSA ve UATBÇS
27.	Raja ve diğ. (2011)	Tekil Değer Ayırıştırması (TDA)	Kullanılmamıştır.
28.	Rafezi ve diğ. (2012)	Zaman bölgesindeki sinyalden elde edilen istatistiksel öznitelikler, HFD, DPD	YSA
29.	Zhou ve diğ. (2021)	Ses Tekillik Analizi (STA)	DVM

3. MATERYAL ve YÖNTEM

TDİ sistemlerinin temel hedefi sinyallerden takım durumu ile ilişkili bilgileri edip makine öğrenmesi algoritmaları ile tahmin etmektir. Bu sebeple TDİ sisteminin başarısı büyük oranda sinyallerin toplandığı deneysel metodolojiye bağlıdır. Bu bölümde TDİ sisteminin tasarımı konularından bahsedilmiştir. TDİ sisteminin tasarımı için izlenen adımlar Şekil 3.1’de verilmiştir.




Şekil 3.1: TDİ sisteminin tasarımı için izlenen adımlar.

3.1 Kesici Takım Aşınmasının Belirlenmesi

Günümüzde imalat alanında yaşanan tüm teknolojik ilerlemelere rağmen kesici takım aşınmaları, tam otomatik talaşlı imalat prosesinin kurulabilmesi önünde bir engeldir. Kesici takım aşınmasının ürünün boyutsal ve yüzeysel kalitesi üzerinde doğrudan etkisi vardır. İmalat anında kesici takımlarda oluşan aşınma bilgilerinin anlık olarak alınabilmesi, kesici takım değiştirme politikasının iyileştirilmesine, optimize edilmiş ve tam otomatik hale getirilmiş imalat operasyonlarının kurulmasına yardımcı olacaktır.

Kesici takımlardaki aşınma, kesme anında meydana gelen şiddetli kesme ve sürtünme kuvvetlerinin bir sonucu olarak kademeleri olarak ilerleyen bir süreçtir. Serbest yüzey aşınmasının artması ile birlikte kesici takım ve iş parçasının temas alanı artacak bunun sonucunda yüksek sürtünme kuvvetlerine neden olacaktır. En fazla karşılaşılan kesici takım aşınmalarından biri serbest yüzey aşınmasıdır. Serbest yüzey aşınması, esas kesme kenarı boyunca kesici takımın serbest yüzeyinden parçacıkların uzaklaşmasıdır.

Tüm yüzey frezeleme işlemleri KLP firmasının üretmiş olduğu TPKN 1603 PPTN kodlu üç adet kesici uç ve 3 ağızlı 50 mm çapında tarama başlığı kullanılarak gerçekleştirilmiştir. Kesici uç ve tarama başlığının geometrik ölçüleri Şekil 3.2’de gösterilmektedir. Kesici takımların aşınma durumları her bir kesici takımın serbest yüzeyinde oluşan serbest yüzey aşınma bölgesinden 8 adet ölçümün ortalaması olarak belirlenmiştir. Tarama başlığında bulunan 3 adet kesici ucun aşınma değerlerinin ortalaması alınarak aşınma durumları sınıflandırılmıştır (Çizelge 3.1). Ölçümler Zoller Genius cihazı ile gerçekleştirilmiştir (Şekil 3.3).



Şekil 3.2: Kesici uç ve tarama başlığı geometrik ölçüleri.

Çizelge 3.1: Kesici uçların aşınma durumları ve aşınma kalınlıkları.

S.N.	Aşınma Durumu	Aşınma Kalınlığı
1	İyi	0-40 μ m
2	Hafif Aşınmış	40-60 μ m
3	Ortalama Aşınmış	60-80 μ m



Şekil 3.3: Serbest yüzey aşınma görüntüleri ve Zoller Geius ölçüm cihazı.

3.2 Talaşlı İmalat Parametrelerinin Belirlenmesi

Tüm talaşlı imalat işlemleri Falco marka dik freze tezgâhı ile gerçekleştirilmiştir (Şekil 3.4). Frezeleme işlemleri yüzey frezeleme ve aynı yönlü frezeleme (Climb cut) yani takımın ilerleme yönü ile dönme yönü aynı yönlü olacak şekilde gerçekleştirilmiştir. Deneylerde 200 x 150 x 100 (mm) ve 150 x 100 x 100 (mm) boyutlarında 2 adet normalize edilmiş genel yapı çeliği S355J2+N iş parçası olarak kullanılmıştır. İşleme parametreleri iş parçası ve kesici takım kalitesine göre belirlenmişti (Çizelge 3.2; 3.3; 3.6). Seçilen parametre değerlerinin takım tezgâhı için uygun olmasına dikkat edilmiştir (Çizelge 3.4; 3.5). Değerlendirme sonucu 3 farklı devir ve 3 farklı ilerleme değeri belirlemiştir (Çizelge 3.7). Tüm deney boyunca talaş derinliği 0,5 mm’de sabit tutulmuştur. Tüm işlemler kesme sıvısı kullanılmaksızın kuru işleme altında gerçekleştirilmiştir.

Çizelge 3.2: S355J2+N Kimyasal Kompozisyonu (S355 J2+N Steel Plate, 2021).

C	Si	Mn	Cr	Mo	Ni	V	W	S	P	CU
max 0.22	max 0.55	max 1.60	0	0	0	0	0	max 0.035	max 0.035	-

Çizelge 3.3: S355J2+N Mekanik Özellikleri.

Akma Dayanımı (N/mm ²)	Çekme Dayanımı (N/mm ²)
315-355	490-630



Şekil 3.4: Deneyde kullanılan Falco marka dık freze tezgâhı.

Çizelge 3.4: Freze tezgâhı uygulanabilir ilerleme değerleri.

mm/dk	A		B	
	C	D	C	D
I	15	25	100	170
II	35	60	260	400

Çizelge 3.5: Freze tezgâhı uygulanabilir devir değerleri.

50 Hz		0	A	B	C
L	I	0	45	80	195
	II	0	115	210	495
M	I	340	x	x	x
	II	850	x	x	x
H	III	0	380	675	1660

Çizelge 3.6: Kesici uç için uygulanabilir kesme hızı, ilerleme, talaş derinliği aralıkları.

Parametre	Aralık
V _c	200-90 (m/dk.)
f _z	0,05-0,5 (mm)
a _p	0,5-3 (mm)

Çizelge 3.7: İşleme parametreleri ve düzeyleri.

	Devir (dev./dk.)	İlerleme (mm/dk.)
1	495	170
2	675	260
3	850	400

3.3 Sensör ve Veri Toplama Sistemlerinin Belirlenmesi

Ses sinyalleri kesme bölgesine 140 mm uzaklıkta takım tezgahının başlığına sabitlenmiş mikrofon ve sinyalleri dijitalleştirecek ses kartı yardımı ile toplanmıştır (Şekil 3.5). Bu çalışmada mikrofon ve ses kartı çeşitlerinin kurulacak TDİ sistemlerinde performans açısından farklılık yaratıp yaratmayacağı değerlendirilebilmek için iki farklı mikrofon-ses kartı kombinasyonu kullanılmıştır. İlk kombinasyon profesyonel mikrofon (Behringer ECM8000) ve ses kartından (Behringer U-Phoria Um2) oluşmaktadır (Çizelge 3.8, Şekil 3.6). Kullanılan iki farklı mikrofonun teknik özellikleri çizelge 3.9’da verilmiştir. Mikrofon XLR kablo ile ses kartına, sert kartı ise diz üstü bilgisayara bağlanmıştır. Ücretsiz ve açık kaynaklı dijital ses editörü ve ses kayıt yazılımı olan Audacity ses sinyallerinin kaydedilmesinde kullanılmıştır. Ses dosyaları wav formatında kaydedilmiştir. İkinci kombinasyon düşük bütçeli genel kullanıcı mikrofonu (BOYA By-M1) ve android akıllı telefonda dahili olarak bulunan ses kartından oluşmaktadır. Ses kayıt yazılımı olarak akıllı telefonunda dahili olarak bulunan ses kayıt yazılımı kullanılmıştır. Ses dosyaları wav formatında kaydedilmiştir. Tüm ses kayıtları her iki kombinasyon kullanılarak eş zamanlı alınmıştır. Ses kaydı kesici takımın iş parçası ile ilk temasında başlatılmış olup, kesici takım iş parçasını tamamen terk ettiği an bitirilmiştir.




Şekil 3.5: Tezgâh başlığına sabitlenmiş mikrofonlar.

Çizelge 3.8: Ses sinyali toplama donanımları.

S.N.	Mikrofon	Ses Kartı
1	Behringer ECM8000	Behringer U-Phoria Um2
2	BOYA By-M1	Akıllı telefon dahili ses kartı

Çizelge 3.9: Deneyde kullanılan mikrofonların teknik özellikleri (Behringer, 2021) (BOYA, 2021).

Özellik	Behringer ECM8000	BOYA By-M1
Tip	Elektret kondenser	Elektret kondenser
Yönel Özellik	Her yöne	Her yöne
Empedans	200 Ohm	1000 Ohm veya daha az
Hassasiyet	70 dB	74 dB veya daha fazla
Frekans Tepkisi	20-20000 Hz	65-18000 Hz



Şekil 3.6: Kullanılan mikrofon ve ses katlarının görselleri (a: Behringer ECM8000, b: BOYA By-M1, c: Behringer U-Phoria Um2).

3.4 Sinyal İşleme ve Öznitelik Oluşturma İşlemlerinin Gerçekleştirilmesi

Bu çalışmada sinyallerden öznitelik oluşturma işlemi kullanılan makine öğrenmesi algoritmalarına bağlı olarak frekans ve zaman-frekans bölgelerinde gerçekleştirilmiştir.

Frekans bölgesinde öznitelik oluşturma işlemlerinde ilk olarak zaman bölgesinde toplanan ses sinyalleri hamming penceresiyle 0.5 saniyelik bölümlere ayrılmıştır. Her bir ses parçası kesici takımın aşınma durumu ile etiketlenmiştir. Ardından tüm 0.5 saniyelik ses parçacıkları HFD kullanılarak frekans bölgesine çevrilmiştir. Ses sinyallerini oluşturan frekans bileşenleri prosesin durumu ile ilgili bilgiler içermektedir. Literatürde kesici takımın aşınma durumu ile ilgili bilgiler elde edebilmek için farklı bant aralıklarda frekans bileşenlerinden öznitelikler elde edilmiştir. Kothuru ve arkadaşları yaptıkları çalışmada 10 kHz üstü yüksek frekans bileşenleri kesici takım durumu ile ilişkili olmadığı sonucuna varmıştır (Kothuru ve diğ., 2019; Rafezi ve diğ., 2012). Bu sebeple 0-10 kHz frekans bandında bulunan frekans bileşenlerinin mutlak değerleri öznitelik olarak makine öğrenimi algoritmasına girdi olarak kullanılmıştır.

Zaman-frekans bölgesinde öznitelik oluşturma işlemlerinde ilk olarak zaman bölgesinde toplanan ses sinyalleri hamming penceresiyle 0.5 saniyelik bölümlere ayrılmıştır. Her bir ses parçası kesici takımın aşınma durumu ile etiketlenmiştir. Tüm

ses parçacıkları KSFD kullanılarak zaman-frekans bölgesine dönüştürülerek spektrogramlar elde edilmiştir. Elde edilen spektrogramlar makine öğrenimi algoritmasına girdi olarak kullanılmıştır.


3.5 Makine Öğrenmesi Algoritmalarının Oluşturulması

Yüzey frezeleme deneyleri sırasında toplanan ses sinyallerinden kullanılan kesici takımların aşınma durumlarını tespit etmek için kurulan TDİ sisteminde YSA, DVM ve ESA makine öğrenmesi algoritmaları kullanılmıştır. Bu bölümde kullanılan algoritmaların oluşturulmasından bahsedilmiştir. YSA, DVM ve ESA algoritmalarının oluşturulması ve model ile ilgili diğer işlemler Python yazılım dili kullanılmıştır. Veri setlerinin %70'i eğitim verisi olarak kullanılmıştır.

3.5.1 YSA algoritmasının oluşturulması

YSA algoritması için tüm ses parçaları zaman bölgesinden frekans bölgesine HFD kullanılarak dönüştürülmüştür. HFD sonucunda elde edilen spektrumdaki 0-10 kHz frekans aralığındaki bileşenlerin mutlak değerleri oluşturulacak 2 farklı YSA'ya girdi olacak öznitelikler olarak kaydedilmiştir. YSA 4 adet gizli katmandan oluşmaktadır. Katmanlardaki nöron sayıları sırasıyla 1024, 512, 256, 128'dir ve aktivasyon fonksiyonu olarak Relu kullanılmıştır. Çıkış katmanı kesici takım aşınma durumu sayısı olan 3 adet nöron içermektedir ve aktivasyon fonksiyonu olarak Softmax kullanılmıştır (Şekil 3.7). Ağ modelinin başarımını belirleyen Kayıp/Yitim fonksiyonu kategorik çapraz entropi olarak belirlenmiştir. Kayıp/yitim fonksiyonunun değerini 0'a yaklaştırabilmek için adam optimizasyon tekniği kullanılmıştır. Batch boyutu 64 olarak belirlenmiş ve 30 epoch süresince eğitim gerçekleştirilmiştir. Tahmin doğruluğu modelin başarısını inceleyebilmek için metrik olarak kullanılmıştır.

Girdi Katmanı
5000 nöron



Çıktı Katmanı
3 nöron +
Softmax

1. Gizli Katman
1024 nöron+ReLU

2. Gizli Katman
512 nöron+ReLU

3. Gizli Katman
256 nöron+ReLU

4. Gizli Katman
128 nöron+ReLU

Şekil 3.7: YSA diyagramı.


3.5.2 DVM algoritmasının oluşturulması

DVM algoritması için tüm ses parçaları YSA algoritmasında olduğu gibi zaman bölgesinden frekans bölgesine HFD kullanılarak dönüştürülmüştür. HFD sonucunda elde edilen spektrumdaki 0-10 kHz frekans aralığındaki bileşenlerin mutlak değerleri oluşturulacak 2 farklı DVM algoritmasına girdi olacak öz nitelikler olarak kaydedilmiştir. Kernel fonksiyonu olarak rbf (radial basis function) fonksiyonu kullanılmıştır.

3.5.3 ESA algoritmasının oluşturulması

ESA algoritması için tüm ses parçaları KSFD kullanılarak zaman-frekans bölgesine dönüştürülerek spectrogramlar elde edilmiştir. Elde edilen spectrogramlar görüntü verisi olarak her iki ESA'nın eğitilmesinde kullanılmıştır. KSFD 1024 noktalı ve %50 kaydırma oranlı HFD ile hesaplanmıştır. ESA'nın yapısı evrişim ve havuzlama katmanlarından oluşan 4 adet blok ve tam bağlantı katmanından oluşmaktadır (Şekil 3.8; Çizelge 3.10). Gizli katmanlarda aktivasyon fonksiyonu ReLU, çıkış katmanında soft-max fonksiyonları kullanılmıştır. Batch boyutu 64 olarak belirlenmiş ve 30 epoch

süresince eğitim gerçekleştirilmiştir. Tahmin doğruluğu modelin başarısını inceleyebilmek için metrik olarak kullanılmıştır. Ağ modelinin başarımını belirleyen Kayıp/Yitim fonksiyonu kategorik çapraz entropi olarak belirlenmiştir. Kayıp/yitim fonksiyonunun değerini 0'a yaklaştırabilmek için rmsprop (root mean squared propagation) optimizasyon tekniği kullanılmıştır.



Şekil 3.8: ESA Mimarisi.

Çizelge 3.10: Oluşturulan ESA katmanlarının çıktı şekilleri ve parametre değerleri.

Katman (tip)	Çıktı Boyutu	Parametre
Evrişim	(Yok, 168, 328, 32)	320
Evrişim _1	(Yok, 166, 326, 32)	9248
Havuzlama	(Yok, 83, 163, 32)	0
Evrişim _2	(Yok, 81, 161, 32)	9248
Evrişim _3	(Yok, 79, 159, 32)	9248
Havuzlama _1	(Yok, 39, 79, 32)	0
Evrişim _4	(Yok, 37, 77, 64)	18496
Evrişim _5	(Yok, 35, 75, 64)	36928
Havuzlama _2	(Yok, 17, 37, 64)	0
Evrişim _6	(Yok, 15, 35, 128)	73856
Havuzlama _3	(Yok, 7, 17, 128)	0
Düzleştirme	(Yok, 15232)	0
Tam Bağlantılı	(Yok, 256)	3899648
Çıktı	(Yok, 3)	771
Toplam Parametre: 4,057,763		
Öğrenilebilir Parametre: 4,057,763		
Öğrenilemez Parametre: 0		

3.6 Deney Tasarımının Gerçekleştirilmesi

Bu çalışmada TDİ sisteminin kurulması (1. Deney) ve kurulan TDİ sisteminin farklı boyutlara sahip iş parçasından toplanan sesler ile test edilmesi (2. Deney) için iki farklı deney gerçekleştirilmiştir.

3.6.1 TDİ sisteminin kurulması (1. deney)

Kurulacak TDİ sisteminin, kesme parametrelerine bağlı olmaksızın kesici takım aşınma durumunu tahmin edebilmesi için parametre düzeyleri kesici takım ve takım tezgahının izin verdiği ölçüde geniş aralıklarla seçilmiştir. 3 farklı aşınma seviyesi için 3 farklı devir ve 3 farklı ilerleme düzeyi seçilmiştir (Şekil 3.11). Her bir aşınma

durumu için toplam 9 adet ve tüm çalışma boyunca toplam 27 adet deney gerçekleştirilmiştir.

Tüm talaşlı imalat işlemleri Falco marka dik freze tezgâhı ile gerçekleştirilmiştir. Frezeleme işlemleri yüzey frezeleme ve aynı yönlü frezeleme (Climb cut) yani takımın ilerleme yönü ile dönme yönü aynı yönlü olacak şekilde gerçekleştirilmiştir. Tüm işlemler kesme sıvısı kullanılmaksızın kuru işleme altına gerçekleştirilmiştir. 200x150x100 mm boyutunda normalize edilmiş genel yapı çeliği S355J2+N iş parçası olarak kullanılmıştır.

Ses sinyalleri kesme bölgesine 140 mm uzaklıkta takım tezgahının başlığına sabitlenmiş iki adet mikrofon (Behringer ECM8000, BOYA By-M) ile toplanmıştır. Behringer ECM8000 mikrofon XLR kablo ile Behringer U-Phoria Um2 ses kartına bağlanarak kullanılmıştır. BOYA By-M ise android akıllı telefona bağlanarak dahili ses kartı ile kullanılmıştır. Ses kayıtları eş zamanlı olarak iki mikrofon ile gerçekleştirilmiştir. Ses kayıtları kesici takımın iş parçasına teması ile başlayıp iş parçasını terk etmesiyle bitirilmiştir. Ses sinyalleri 44.1 kHz ile örneklenerek dijitalleştirilmiştir. Ses sinyalleri kesici takım aşınma durumu, kaydedilen mikrofon, kesme parametrelerine göre etiketlenerek kaydedilmiştir. Toplamda 54 adet ses dosyası kaydedilmiştir.

Her bir ses kayıt dosyasının kayıt süreleri birbirinden farklıdır. Bunun sebebi iş parçasının boyunun sabit ancak ilerleme hızının farklılık göstermesidir. Veri setinin her bir deneyden eşit sayıda veri ile oluşturulması istendiği için her bir ses kaydının tam ortasından 30 saniyelik bölümler kullanılmak üzere çıkartılmıştır. Bu 30 saniyelik bölümler hamming penceresiyle 0.5 saniyelik bölümlere ayrılmıştır. Bu sayede her bir deney için 60 adet 0.5 saniyelik ses kaydı elde edilmiştir. Her bir mikrofon için 1620 adet ses verisi elde edilmiştir. Ses sinyalleri ilk olarak zaman bölgesinde oluşturulmuş ardından HFD kullanılarak frekans bölgesine çevrilmiştir. Spektrumun 0-10 kHz frekans bandında bulunan frekans bileşenlerinin mutlak değerleri öznitelik olarak makine öğrenimi algoritmasına girdi olarak kullanılmıştır.

Çizelge 3.11: 1. deney için deney planı.

SN	Takım Durumu	Devir (dev./dk.)	İlerleme (mm/dk.)
1	İyi	495	170
2			260
3			400
4		675	170
5			260
6			400
7		850	170
8			260
9			400
10	Hafif Aşınmış	495	170
11			260
12			400
13		675	170
14			260
15			400
16		850	170
17			260
18			400
19	Ortalama Aşınmış	495	170
20			260
21			400
22		675	170
23			260
24			400
25		850	170
26			260
27			400

YSA algoritması için tüm ses parçaları zaman bölgesinden frekans bölgesine HFD kullanılarak dönüştürülmüştür. HFD sonucunda elde edilen spektrumdaki 0-10 kHz frekans aralığındaki bileşenlerin mutlak değerleri oluşturulacak 2 farklı YSA'ya girdi olacak öznitelikler olarak kullanılmıştır. Tahmin doğruluğu modelin başarısını inceleyebilmek için metrik olarak kullanılmıştır.

DVM algoritması için tüm ses parçaları YSA algoritmasında olduğu gibi zaman bölgesinden frekans bölgesine HFD kullanılarak dönüştürülmüştür. HFD sonucunda elde edilen spektrumdaki 0-10 kHz frekans aralığındaki bileşenlerin mutlak değerleri oluşturulacak 2 farklı DVM algoritmasına girdi olacak öznitelikler olarak kullanılmıştır. Tahmin doğruluğu modelin başarısını inceleyebilmek için metrik olarak kullanılmıştır.

ESA algoritması için tüm ses parçaları KSFD kullanılarak zaman-frekans bölgesine dönüştürülerek spectrogramlar elde edilmiştir. Elde edilen spectrogramlar görüntü verisi olarak ESA'nin eğitilmesinde kullanılmıştır. Tahmin doğruluğu modelin başarısını inceleyebilmek için metrik olarak kullanılmıştır.

Tüm bu işlemler iki farklı mikrofon ve ses kartından eş zamanlı olarak alınan ses sinyalleri ile ayrı ayrı gerçekleştirilmiş ve performansları karşılaştırılmıştır.

3.6.2 TDİ sisteminin farklı boyutlara sahip iş parçasından toplanan sesler ile test edilmesi (2. deney)

Talaşlı imalat süresinde iş parçasından malzeme uzaklaştırılarak istenen formun elde edilmesi amaçlanmaktadır. Bu işlem boyunca iş parçasının boyunu ve şekli değişmektedir. Literatürde ses sinyalleri kullanılarak frezeleme işlemi için oluşturulan TDİ sistemlerinde iş parçası boyutunun kurulan sistemin performansına etkisinin araştırılmadığı tespit edilmiştir. Literatürde görülen bu boşluğun doldurulması amacıyla 1. deneyde kurulan TDİ sisteminin performansını farklı boyuta sahip iş parçasından elde edilen ses sinyalleri test edilecektir. İş parçasının boyutu 150x100x100 mm olarak seçilmiştir. İş parçası boyutu hariç tüm parametreler 1. deneydekiyle aynı tutulmuştur. Deneyler Taguchi L9 ortogonal dizisine göre gerçekleştirilmiştir.

1. deney bölümünde bahsedildiği gibi her bir ses kayıt dosyasının kayıt süreleri birbirinden farklıdır. Bunun sebebi iş parçasının boyunun sabit ancak ilerleme hızının farklılık göstermesidir. Veri setinin her bir deneyden eşit sayıda veri ile oluşturulması istendiği için her bir ses kaydının tam ortasından 15 saniyelik bölümler kullanılmak üzere çıkartılmıştır. Bu 15 saniyelik bölümler hamming penceresiyle 0.5 saniyelik bölümlere ayrılmıştır. Bu sayede her bir deney için 30 adet 0.5 saniyelik ses kaydı elde

edilmiştir. Her bir mikrofon için 270 adet ses verisi elde edilmiştir. Ses sinyallerinin işlenmesinde 1. deneyde kullanılan yöntemler uygulanmıştır.


Tüm bu işlemler iki farklı mikrofon ve ses kartından eş zamanlı olarak alınan ses sinyalleri ile ayrı ayrı gerçekleştirilmiş ve performansları karşılaştırılmıştır.

Çizelge 3.12: 2. deney için deney planı.


SN	Takım Durumu	Devir (dev./dk.)	İlerleme (mm/dk.)
1	İyi	495	170
2		675	260
3		850	400
4	Hafif Aşınmış	495	260
5		675	400
6		850	170
7	Ortalama Aşınmış	495	400
8		675	170
9		850	260

4. BULGULAR ve TARTIŞMA


Toplanan ses sinyalleri zaman bölgesinde incelendiğinde kesici takımların serbest yüzey aşınmalarının artması ile ses basınçlarında değişimler olduğu görülmektedir (Şekil 4.1). HFD kullanılarak frekans bölgesine dönüştürülerek sinyaller incelendiğinde serbest yüzey aşınmalarının artması 0-10 kHz bandındaki frekans bileşenlerinin genliklerinde değişimler olduğu görülmektedir (Şekil 4.2). Şekil 4.3, 4.4 ve 4.5'te aynı işleme parametrelerinde ve farklı aşınma durumlarına sahip kesici takımlardan alınan 0.5 saniyelik ses sinyalinin spektrogram görüntüleri verilmiştir. Spektogramlar incelendiğinde 0.5 saniyelik ses verisi boyunca frekans karakteristiğinde kayda değer bir değişim olmadığı görülmektedir.




Şekil 4.1: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ses sinyalinin zaman bölgesi gösterimi.




Şekil 4.2: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ses sinyalinin frekans bölgesi gösterimi.



Şekil 4.3: 675 dev./dk., 170 mm/dk. işleme parametrelerinde iyi durumdaki kesici takımın ses sinyalinin spektrogram görüntüsü.




Şekil 4.4: 675 dev./dk., 170 mm/dk. işleme parametrelerinde hafif aşınmış durumdaki kesici takımın ses sinyalinin spektrogram görüntüsü.




Şekil 4.5: 675 dev./dk., 170 mm/dk. işleme parametrelerinde ortalama aşınmış durumdaki kesici takımın ses sinyalinin spektrogram görüntüsü.

İşleme parametrelerindeki değişiklikler oluşan ses sinyallerini doğrudan etkilemektedir. Bu çalışmada devir ve ilerleme hızı işleme parametresi olarak belirlenmiştir. Şekil 4.6-4.11’de parametrelerden biri sabit tutularak diğerinin değiştirilmesi sonucu elde edilen ses verilerinin spektrumları gösterilmektedir. Devir


hızındaki artış ilerleme hızındaki artışa göre ses şiddetini daha fazla etkilediği görülmektedir.




Şekil 4.6: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında iyi durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.




Şekil 4.7: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında iyi durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.




Şekil 4.8: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında hafif aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.



Şekil 4.9: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında hafif aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.




Şekil 4.10: Sabit 400 mm/dk. ilerleme ve farklı devir hızlarında ortalama aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.




Şekil 4.11: Sabit 675 dev./dk. devir ve farklı ilerleme hızlarında ortalama aşınmış durumdaki kesici takım ses sinyallerinin frekans bölgesi gösterimi.


200mm x 150 mm x 100 mm boyutunda iş parçasının kullanıldığı 1. deney ve 150mm x 100 mm x 100 mm boyutunda iş parçasının kullanıldığı 2. deneyden aynı işleme parametrelerine sahip ses verilerinden elde edilen spektrumlar şekil 4.12-4.14'te gösterilmiştir. İş parçasının boyutundaki değişimlerin özellikle 0-6 kHz bandında frekans karakteristiğini etkilediği görülmektedir.



Şekil 4.12: 495 dev./dk., 400 mm/dk. işleme parametrelerinde ortalama aşınmış durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi.



Şekil 4.13: 675 dev./dk., 260 mm/dk. işleme parametrelerinde iyi durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi.



Şekil 4.14: 850 dev./dk., 170 mm/dk. işleme parametrelerinde hafif aşınmış durumdaki kesici takımların 1. ve 2. deneyde toplanan ses sinyallerinin frekans bölgesi gösterimi.

Bu çalışmada TDİ sisteminin kurulması (1. deney) ve kurulan TDİ sisteminin farklı boyutlara sahip iş parçasından toplanan sesler ile test edilmesi (2. deney) için iki farklı deney gerçekleştirilmiştir. Ses sinyallerinin toplanması iki farklı mikrofon-ses kartı grubu ile gerçekleştirilmiştir. İlk grup profesyonel mikrofon (Behringer ECM8000) ve ses kartından (Behringer U-Phoria Um2) oluşmaktadır. İkinci grup düşük bütçeli, genel kullanıcı mikrofonu (BOYA By-M1) ve akıllı telefon dahili ses kartından oluşmaktadır.

1. deneyde elde edilen ses sinyalleri 0.5 saniyelik ses parçacıklarına bölünmüş ve HFD kullanılarak frekans bölgesine, KSFD kullanılarak zaman-frekans bölgesine çevrilmiştir. HFD sonucu elde edilen spektrumdaki 0-10 kHz bandındaki frekans bileşenlerinin genlikleri YSA ve DVM algoritmaları için veri seti olarak kullanılmıştır. KSFD sonucu elde edilen spektrogram görüntüleri ESA algoritmasına girdi olarak kullanılmıştır. Veri setinden test verisi olarak ayrılmış ve modelin daha önce görmediği veriler ile model test edilmiştir. Oluşturulan tüm TDİ sistemleri iki farklı ses sinyali toplama donanımları ile elde edilen ses sinyalleri ile aynı yöntemler kullanılarak ayrı ayrı gerçekleştirilmiştir. 1. deney sonunda kurulan TDİ sistemlerinde kullanılan makine öğrenmesi algoritmaları ve ses sinyali toplama donanımları tahmin doğruluğu yönünden karşılaştırılmıştır.

2. deneyde elde edilen sistemleri 1. deneyde olduğu gibi sinyalleri 0.5 saniyelik ses parçacıklarına bölünmüş ve HFD kullanılarak frekans bölgesine, KSFD kullanılarak

zaman-frekans bölgesine çevrilmiştir. Elde edilen girdiler 1. deneyde oluşturulan TDİ sistemlerinde test verisi olarak kullanılarak iş parçası boyutunun değişiminin oluşturulan TDİ sistemlerinin performansı üzerine etkisi tahmin doğruluğu yönünden karşılaştırılmıştır.

4.1 TDİ Sisteminin Kurulması (1. Deney) Çalışmalarının Sonuçları

TDİ Sisteminin Kurulması için gerçekleştirilen 1. deneyde her iki donanım grubu ile toplanan ses sinyalleri kullanılarak YSA ve DVM algoritmaları veri setinin %70'i ile eğitilmiş ardından %30'u ile test edilmiştir. Sonuçlar tahmin doğruluğu yönünden karşılaştırılmıştır (Çizelge 4.1; 4.2; 4.3; 4.4; 4.5; 4.6). Sonuçlar incelendiğinde talaşlı imalat anında toplanan ses sinyallerinin HFD işlemi ile elde edilen 0-10 kHz bandındaki frekans bileşenlerinin genlikleri YSA ve DVM algoritmasına girdi olarak verilmesiyle oluşturulan TDİ sisteminin başarılı bir şekilde sınıflandırma işlemi yapabildiği görülmektedir. Ayrıca her iki donanım grubu ile de etkili bir TDİ sistemi kurulabileceği belirlenmiştir.

Çizelge 4.1: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.

		Tahmin Edilen Durum			
		İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	İyi	157	2	0	İyi
	Hafif Aşınmış	0	164	0	Hafif Aşınmış
	Ortalama Aşınmış	0	0	163	Ortalama Aşınmış

Çizelge 4.2: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
	Gerçek Durum			
	158	1	0	İyi
	0	164	0	Hafif Aşınmış
	0	0	163	Ortalama Aşınmış

Çizelge 4.3: 1. deney sonucunda YSA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doğruluğu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	99,58
2	BOYA By-M1	Akıllı telefon dahili ses kartı	99,79

Çizelge 4.4: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
	Gerçek Durum			
	157	2	0	İyi
	0	164	0	Hafif Aşınmış
	0	0	163	Ortalama Aşınmış

Çizelge 4.5: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
	Gerçek Durum			
	157	2	0	İyi
	0	164	0	Hafif Aşınmış
	0	0	163	Ortalama Aşınmış

Çizelge 4.6: 1. deney sonucunda DVM ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doğruluğu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	99,58
2	BOYA By-M1	Akıllı telefon dahili ses kartı	99,58

TDİ Sisteminin Kurulması için gerçekleştirilen 1. deneyde her iki donanım grubu ile toplanan ses sinyallerinden KSFD kullanılarak spektrogramlar elde edilerek veri seti oluşturulmuştur. ESA algoritması veri setinin %70'i ile eğitilmiş ardından %30'u ile test edilmiştir (Çizelge 4.7; 4.8; 4.9;). Sonuçlar incelendiğinde talaşlı imalat anında toplanan seslerden elde edilen spektrogramlar ESA algoritmasına girdi olarak verilmesiyle oluşturulan TDİ sistemi YSA ve DVM algoritmaları ile kurulan TDİ sistemlerinden daha düşük tahmin doğruluğuna sahip olduğu görülmektedir.

Çizelge 4.7: 1. deney sonucunda 1. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	158	4	0	İyi
	7	133	22	Hafif Aşınmış
	0	13	149	Ortalama Aşınmış

Çizelge 4.8: 1. deney sonucunda 2. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	154	8	0	İyi
	7	148	7	Hafif Aşınmış
	1	7	154	Ortalama Aşınmış

Çizelge 4.9: 1. deney sonucunda ESA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doğruluğu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	90,53
2	BOYA By-M1	Akıllı telefon dahili ses kartı	93,82

4.2 TDİ Sisteminin Farklı Boyutlara Sahip İş Parçasından Toplanan Sesler ile Test Edilmesinin (2. Deney) Sonuçları

2. deneyde elde edilen ses sinyalleri YSA ve DVM kullanılarak oluşturulan TDİ sistemlerine test verisi olarak verildiğinde tahmin başarısının düştüğü

gözlemlenmektedir (Çizelge 4.10; 4.11; 4.12; 4.13; 4.14; 4.15;). Şekil 4.12-4.14'te görülen iş parçası boyutuna bağlı olarak oluşan frekans karakteristiklerindeki değişimler tahmin doğruluğundaki bu düşüşe neden olmaktadır.

Çizelge 4.10: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	86	4	0	İyi
	2	72	16	Hafif Aşınmış
	0	6	84	Ortalama Aşınmış

Çizelge 4.11: 2. deney sonucunda 2. grup ses sinyali toplama donanımı ve YSA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	66	23	1	İyi
	3	66	21	Hafif Aşınmış
	2	13	75	Ortalama Aşınmış

Çizelge 4.12: 2. deney sonucunda YSA ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doğruluğu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	89,62
2	BOYA By-M1	Akıllı telefon dahili ses kartı	76,66

Çizelge 4.13: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve DVM ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	76	14	0	İyi
	0	52	38	Hafif Aşınmış
	1	6	83	Ortalama Aşınmış

Çizelge 4.14: 2. deney sonucunda 2. grup ses sinyali toplama donanımı DVM ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	70	10	10	İyi
	30	15	45	Hafif Aşınmış
	0	7	83	Ortalama Aşınmış

Çizelge 4.15: 2. deney sonucunda DVM ile TDİ sisteminin donanım gruplarına göre tahmin doğruluğu değerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doğruluğu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	78,14
2	BOYA By-M1	Akıllı telefon dahili ses kartı	62,22

2. deney sonucu elde edilen ses sinyalleri ESA kullanılarak oluşturulan TDİ sistemine test verisi olarak verildiğinde tahmin başarısının düştüğü gözlemlenmektedir (Çizelge 4.16; 4.17; 4.18). Şekil 4.12-4.14'te görülen iş parçası boyutuna bağlı olarak oluşan

frekans karakteristiklerindeki deęişimler tahmin doęruluęundaki bu dūşūşe neden olmaktadır.

Çizelge 4.16: 2. deney sonucunda 1. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	78	9	3	İyi
	46	21	23	Hafif Aşınmış
	19	13	58	Ortalama Aşınmış

Çizelge 4.17: 2. deney sonucunda 2. grup ses sinyali toplama donanımı ve ESA ile kurulan TDİ sisteminin karışıklık matrisi.

	Tahmin Edilen Durum			
	İyi	Hafif Aşınmış	Ortalama Aşınmış	
Gerçek Durum	65	23	2	İyi
	11	43	46	Hafif Aşınmış
	2	34	44	Ortalama Aşınmış

Çizelge 4.18: 2. deney sonucunda ESA ile TDİ sisteminin donanım gruplarına göre tahmin doęruluęu deęerleri.

S.N.	Mikrofon	Ses Kartı	Tahmin Doęruluęu (%)
1	Behringer ECM8000	Behringer U-Phoria Um2	58,14
2	BOYA By-M1	Akıllı telefon dahili ses kartı	56,29

Çalışma boyunca elde edilen tüm tahmin doğruluğu değerleri çizelge 4.19’da gösterilmiştir.

Çizelge 4.19: Çalışma boyunca elde edilen tüm tahmin doğruluğu değerleri.

	1. Deney		2. Deney	
	1. grup ses sinyali toplama donanımı	2. grup ses sinyali toplama donanımı	1. grup ses sinyali toplama donanımı	2. grup ses sinyali toplama donanımı
YSA	%99,58	%99,79	%89,62	%76,66
DVM	%99,58	%99,58	%78,14	%62,22
ESA	%90,53	%93,82	%58,14	%56,29

5. SONUÇ ve ÖNERİLER

Bu tez çalışmasında talaşlı imalat esnasında oluşan ses sinyallerini ve makine öğrenmesi tekniklerini kullanarak kesici takımların aşınma durumlarını tahmin edebilecek bir TDİ sisteminin oluşturulması amaçlanmıştır. Talaşlı imalat boyunca iş parçasından talaşlar uzaklaştırılarak şekli ve boyutunda değişimler olmaktadır. Bu durumun oluşturulan TDİ sisteminin tahmin doğruluğunu etkileyebileceği düşünülerek farklı iş parçası boyutunda toplanan ses sinyalleriyle oluşturulan TDİ sistemleri test edilmiştir. Ayrıca oluşturulan TDİ sistemlerinin tahmin performanslarının kullanılan ses sinyali toplama donanımlarının farklılıklarından etkilenip etkilenmediğinin değerlendirilmesi amaçlanmıştır. Bu doğrultuda iki farklı donanım grubu ile toplanan ses verileri kullanılarak TDİ sistemi oluşturulup tahmin doğrulukları yönünden karşılaştırılmıştır.

TDİ sisteminin oluşturulmasında makine öğrenmesi tekniklerinden YSA, DVM ve ESA kullanılmıştır. Her iki ses sinyali toplama donanımı ile eğitilen modellerin test edilmesiyle yüksek tahmin doğrulukları elde edilmiştir. YSA ve DVM kullanılarak eğitilen modellerin performansları birbirlerine yakın olduğu görülmüştür. ESA kullanılarak eğitilen modelin ise diğer iki tekniğe göre daha düşük performans göstermesine rağmen yine de yüksek bir tahmin doğruluğuna sahip olduğu görülmüştür. Bu durum, ses sinyalleri ve makine öğrenmesi teknikleri kullanarak etkili bir TDİ sisteminin kurulabileceğini kanıtlamaktadır.

Daha düşük boyutlarda iş parçasının yüzey frezeleme işleminden toplanan sesler oluşturulan modellerde test edilmiştir. Elde edilen sonuçlar, iş parçasının boyutunun değişiminin oluşturulan sistemin doğruluğunu düşürdüğü ancak YSA kullanılarak oluşturulan modelin hala yüksek doğruluk değerlerine sahip olduğunu göstermektedir. Ses sinyali toplama donanımları karşılaştırıldığında yüksek empedans ve düşük hassasiyete sahip donanımdan elde edilen ses sinyalleri ile oluşturulan TDİ sisteminin iş parçası boyut değişiminde daha kötü sonuçlar verdiği görülmüştür.

Bu alıřmada nerilen yntemler ile bařarılı bir řekilde TDİ sistemi kurulabileceęi grlmřtr. Ayrıca iř parası boyutunun ve řeklinin deęiřmesi, kullanılan ses sinyali toplama donanımlarındaki farklılıklar oluřturulan TDİ sistemlerinin performansları zerinde etkisi olduęu grlmřtr. Bu sebeple tmyle etkili bir TDİ sistemi oluřturmak iin iř parasının řekli ve boyutu iřlem parametresi olarak ele alınmalı ya da iř parasının řekli ve boyutundan etkilenmeyen zniteliklerin ıkarılabilmesi iin yntemler belirlenmeli, ses sinyali toplama donanımların seimi ile ilgili alıřmalar yapılmalıdır.



6. Kaynakça

- Abellan-Nebot, J. V., & Subirón, F. R.** (2010). A review of machining monitoring systems based. *Int J Adv Manuf Technol*, 47, 237-257.
- Ai, C. S., Sun, Y. J., He, G. W., Ze, X. B., Li, W., & Mao, K.** (2012). The milling tool wear monitoring using the acoustic spectrum. *Int J Adv Manuf Technol*, 61, 457-463.
- Al-Habaibeh, A., Al-Azmi, A., Radwan, N., & Song, Y.** (2010). The application of force and acoustic emission sensors for detecting tool damage in turning processes. *In Key Engineering Materials*, 419, 381-384.
- Aliustaoglu, C., Ertunc, H. M., & Ocak, H.** (2009). Tool wear condition monitoring using a sensor fusion model based on fuzzy inference system. *Mechanical Systems and Signal Processing*, 23, 539-546.
- Alonso, F. J., & Salgado, D. R.** (2005). Application of singular spectrum analysis to tool wear detection using sound signals. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219(9), 703-710.
- Alonso, F., & Salgado, D.** (2008). Analysis of the structure of vibration signals for tool wear detection. *Mech. Syst. Signal Process*, 22, 735-748.
- Altintas, Y.** (1988). In-process detection of tool breakages using time-series monitoring of cutting forces. *Int JMach Tools Manuf*, 28, 157-172.
- Alzahrani, A. M., Liu, R., & Kolodziej, J. R.** (2018). Acoustic Assessment of an End Mill for Analysis of Tool Wear. *Proceedings of the Annual Conference of the PHM*, 10. Philadelphia.
- Antonio, J., Oscar Victor, M., & Hirose, S.** (2012). Ultrasonic imaging of concrete by synthetic aperture focusing technique based on hilbert-huang transform of time domain data. *Mater Trans*, 53(4), 621-626.
- Azmi, A. I.** (2015). Monitoring of tool wear using measured machining forces and neuro-fuzzy modelling approaches during machining of GFRP composites. *Adv Eng Softw*, 82, 53-64.
- Bahr, B., Motavalli, S., & Arfi, T.** (1997). Sensor fusion for monitoring machine tool conditions. *Int J Comput Integr Manuf*, 10, 314-323.
- Behringer.** (2021). *Measurement Condenser Microphone ECM8000 Technical Specifications*. ECM8000: https://mediadl.musictribe.com/media/sys_master/h47/hde/8849927929886.pdf adresinden alındı
- BOYA.** (2021). *BY-M1*. boya-mic: http://www.boya-mic.com/lavaliermicrophones/BY-M1.html?gclid=Cj0KCQjwwY-LBhD6ARIsACvT72Py7kAnpvazt72Mly6LCXjLvsVkcjbVP7w9tOYZg-UGzOYIn-O82e8aAsfTEALw_wcB adresinden alındı
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A.** (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 480, 189-215. doi:<https://doi.org/10.1016/j.neucom.2019.10.118>

- Charoenprasit, S., Seemuang, N., & Slatter, T.** (2018). Monitoring Tool Wear in Drilling Process Using Spindle Noise Features. *International Journal of Mechanical Engineering and Robotics Research*, 7(5), 564-568.
- Chen, S. L., & Jen, Y. W.** (2000). Data fusion neural network for tool condition monitoring in CNC milling machining. *Int J Mach Tools Manuf*, 40, 381-400.
- D'Addona, D. M., Segreto, T., Simeone, A., & Teti, R.** (2011). ANN tool wear modelling in the machining of nickel superalloy industrial products. *CIRP J. Manuf. Sci. Technol.*, 4, 33-37.
- Dahe, S. V., Sai Manikandan, G., Jegadeeshwaran, R., Sakthivel, G., & Lakshmipathi, J.** (2021). Tool condition monitoring using Random forest and FURIA through statistical learning. *Materials Today: Proceedings*, 46, 1161-1166.
- Dimla, D. E., & Lister, P. M.** (2000). On-line metal cutting tool condition monitoring.: I: force and vibration analyses. *Int. J. Mach. Tools Manuf.*, 40, 739-768.
- Dornfeld, D., & Rangwala, S.** (1990). Sensor integration using neural networks for intelligent tool condition monitoring. *ASME Journal of Engineering for Industry*, 112(3), 219-228.
- Downey, J., O'Leary, P., & Raghavendra, R.** (2014). Analysis of audible sound energy emissions during single point machining across full tool life. *International Journal of Machine Tools & Manufacture*.
- Ertekin, Y. M., Kwon, Y., & Tseng, T. L.** (2003). Identification of common sensory features for the control of CNC milling operations under varying cutting conditions. *Int J Mach Tools Manuf*, 43, 897-904.
- Ertunc, H. M., Ocak, H., & Aliustaoglu, C.** (2013). ANN- and ANFIS-based multi-staged decision algorithm for the detection and diagnosis of bearing faults. *Neural Comput & Applic*, 22(1), 435-446.
- Fang, N., Pai, P. S., & Edwards, N.** (2014). A method of using Hoelderexponents to monitor tool-edge wear in high-speed finishmachining. *Int J Adv Manuf Technol*, 72, 1593-1601.
- Ferguson, M., Law, K., Bhinge, R., Park, J., & Lee, Y.** (2013). A Data Processing Pipeline for Prediction of Milling Machine Tool Condition from Raw Sensor Data. *The ASTM Journal of Smart and Sustainable Manufacturing*, [online].
- Filipe, C., Michael, E., Walter, S., & Anderson, R.** (2012). Open Set Source Camera Attribution. *Brazilian Symposium of Computer Graphic and Image Processing*, (s. 71-78).
- Gallo, C.** (2015). Artificial Neural Networks: tutorial. M. Khosrow içinde, *Encyclopedia of Information Science and Technology, Third Edition* (s. 179-189). IGI Global.
- Ghosh, A., Sufian, A., Sultana, F., & Chakrabarti, A.** (2020). Fundamental Concepts of Convolutional Neural Network. V. E. Balas, R. Kumar, & R. Srivastava içinde, *Recent Trends and Advances in Artificial Intelligence and Internet of Things* (s. 519-567). Springer International Publishing.
- Ghosh, N., Ravi, Y. B., Patra, A., Mukhopadhyay, S., Paul, S., Mohanty, A. R., & Chattopadhyay, A. B.** (2007). Estimation of tool wear during CNC milling using neural network-based sensor fusion. *Mech Syst Signal Process*, 21, 466-479.
- Górski, J., Szymanowski, K., Podziewski, P., Śmietańska, K., Czarniak, P., & Cyrankowski, M.** (2019). Use of Cutting Force and Vibro-acoustic Signals in

- Tool Wear Monitoring Based on Multiple Regression Technique for Compreg Milling. *BioResources*, 14(2), 3379-3388.
- Gülmez, T.** (2016). Talaşlı İmalat Operasyonları ve Takım Tezgâhları Ders Notları. <https://web.itu.edu.tr/gulmezt/IMAL%20USULLERI/ch22-Talasli%20Imalat%20Yontemleri.pdf> adresinden alındı
- Haber, R. E., Jimenez, J. E., Peres, C. R., & Alique, J. R.** (2004). An investigation of tool-wear monitoring in a high-speed machining process. *Sens Actuators A-Phys*, 116, 539–545.
- Hesser, D. F., & Markert, B.** (2019). Tool wear monitoring of a retrofittedCNC milling machine using artificial neural networks. *Manuf Lett*, 19, 1-4.
- Huda, F., Karjuni, K., & Rusli, M.** (2020). Cutting tool wear analysis using sound signal and simple microphone. *IOP Conf. Series: Materials Science and Engineering*, 830.
- Jemielniak, K.** (2000). Some aspects of AE application in tool condition monitoring. *Ultrasonics*, 38, 604-608.
- Jeon , H., Jung , Y., Lee, S., & Jung, Y.** (2020). Area-Efficient Short-Time Fourier Transform Processor for Time–Frequency Analysis of Non-Stationary Signals. *Applied Sciences*, 10(20). doi:<https://doi.org/10.3390/app10207208>
- Jiang, C. Y., Zhang, Y. Z., & Xu, H. J.** (1987). In-process monitoring of tool wear stage by the frequency band-energy method. *CIRP Annals-Manufacturing Technology*, 36(1), 45-48.
- Kalvoda, T., & Hwang, Y. R.** (2010). A cutter tool monitoring inmachining process using Hilbert–Huang transform. *Int JMach Tools Manuf*, 50, 495-501.
- Kene, A. P., & Choudhury, S. K.** (2019). Analytical modeling of tool health monitoring system using multiple sensor data fusion approach in hard machining. *Measurement*, 145, 118-129.
- Kim, G. D., & Chu, C. N.** (2001). In-process tool fracture monitoring in face milling using spindle motor current and tool fracture index. *Int J Adv Manuf Technol*, 18, 383-389.
- Kothuru, A., Nooka, S. P., & Liu, R.** (2018). Application of audible sound signals for tool wear monitoring using machine learning techniques in end milling. *Int J Adv Manuf Technol*, 95, 3797-3808.
- Kothuru, A., Nooka, S. P., & Liu, R.** (2019). Application of deep visualization in CNN-based tool condition monitoring for end milling. *Procedia Manufacturing*, 34, 995-1004.
- Krishnan, P., & Samraj, A.** (2017). Tool Wear Condition Monitoring Using Acoustic Analysis Of Emitted Sound Signals By Peak To Peak Analysis. *Proceedings of 93. Hanoi*.
- Kuo, R. J., & Cohen, P. H.** (1999). Multi-sensor integration for online tool wear estimation through radial basis function networks and fuzzy neural network. *Neural Netw*, 12, 355-370.
- Lee, J. M., Choi, D. K., Kim, J., & Chu, C. N.** (1995). Real-time tool breakage monitoring for NC milling process. *CIRP Ann— Manuf Technol*, 44, 59-62.
- Lee, S.** (2010). Tool condition monitoring system in turning operation utilizing wavelet signal processing and multi-learning ANNs algorithm methodology. *Int J Eng Res Innov*, 49-55.
- Li, T., Zhang, M., Fan, Y., Cheng, X., & Lin, S.** (2016). Correlation Analysis of Tool Wear and Cutting Sound Signal. *International Journal of Research in Engineering and Science (IJRES)*, 4(1), 46-50.

- Li, W., & Liu, T.** (2019). Time varying and condition adaptive hidden Markov model for tool wear state estimation and remaining useful life prediction in micro-milling. *Mech Syst Signal Process*, 131, 689-702.
- Li, X. L.** (2001). Detection of tool flute breakage in end milling using feed-motor current signatures. *IEEE-ASME Trans Mechatron*, 6, 491-498.
- Li, X. L., & Yuan, Z. J.** (1998). Tool wear monitoring with wavelet packet transform fuzzy clustering method. *Wear*, 219, 145-154.
- Li, X. L., Dong, S., & Yuan, Z. J.** (1999). Discrete wavelet transform for tool breakage monitoring. *Int J Mach Tools Manuf*, 39, 1935-1944.
- Liu, J., Hu, Y., Wu, B., & Jin, C.** (2017). A hybrid health condition monitoring method in milling operations. *Int J Adv Manuf Technol*, 92, 2069-2080.
- Liu, M. K., Tseng, Y. H., & Tran, M. Q.** (2019). Tool wear monitoring and prediction based on sound signal. *Int J Adv Manuf Technol*, 103, 3361-3373.
- Liu, Y. M., & Wang, C. J.** (1999). Neural network based adaptive control and optimisation in the milling process. *Int J Adv Manuf Technol*, 15, 791-795.
- Madhusudana, C. K., Kumar, H., & Narendranath, S.** (2016). Condition monitoring of face milling tool using K-star algorithm and histogram features of vibration signal. *Eng Sci Technol Int*, 19, 1543-1551.
- Mannan, M. A., Kassim, A. A., & Jing, M.** (2000). Application of image and sound analysis techniques to monitor the condition of cutting tools. *Pattern Recognition Letters*, 21(11), 969-979.
- Mehrotra, M., Pandey, G., & Narula, M. S.** (2017). Implementation of FFT Algorithm. *International Journal Of Engineering Sciences & Research Technology*, 6(5), 206-211.
- Niu, Y. M., Wong, Y. S., & Hong, G. S.** (1998). An intelligent sensor system approach for reliable tool flank wear recognition. *Int J Adv Manuf Technol*, 14, 77-84.
- Oraby, S. E., Al-Modhuf, A. F., & Hayhurst, D. R.** (2005). A diagnostic approach for turning tool based on the dynamic force signals. *Journal of manufacturing science and engineering*, 127(3), 463-475.
- Oraby, S., & Hayhurst, D.** (2004). Tool life determination based on the measurement of wear and tool force ratio variation. *Int. J. Mach. Tools Manuf.*, 44, 1261-1269.
- O'Shea, K., & Nash, R.** (2015). *An Introduction to Convolutional Neural Networks*. arXiv:1511.08458.
- Özdemir, U., & Erten, M.** (2003). Talasli Imalat Sirasinda Kesici Takimda Meydana Gelen Hasar Mekanizmalari ve Takim Hasarini Azaltma Yöntemleri. *Havacılık ve Uzay Teknolojileri Dergisi*, 1(1), 37-50.
- Özel, T., & Nadgir, A.** (2002). Prediction of flank wear by using back propagation neural network modeling when cutting hardened H-13 steel with chamfered and honed CBN tools. *Int. J. Mach. Tools Manuf.*, 42, 287-297.
- Pal, S., Heyns, P. S., Freyer, B. H., Theron, N. J., & Pal, S. K.** (2011). Tool wear monitoring and selection of optimum cutting conditions with progressive tool wear effect and input uncertainties. *J. Intell. Manuf.*, 22, 491-504.
- Prakash, K., & Samraj, A.** (2019). Tool Flank Wear Estimation using Emitted Sound Signal Analysis by PCA – SER Based Peak to Peak Measurements. *International Journal of Engineering and Advanced Technology (IJEAT)*, 8(6), 5212-5216.

- Rafezi, H., Behzad, M., & Akbari, J.** (2012). Time Domain and Frequency Spectrum Analysis of Sound Signal for Drill Wear Detection. *International Journal of Computer and Electrical Engineering*, 4(5), 722-725.
- Raja, E., Sayeed, S., Samraj, A., Kiong, L. C., & Soong, L. W.** (2011). Tool Flank Wear Condition Monitoring during Turning Process by SVD Analysis on Emitted Sound Signal. *European Journal of Scientific Research*, 49(4), 503-509.
- Raja, J. E.** (2013). Tool Condition Monitoring using Competitive Neural Network and Hilbert-. *Asian Journal of Scientific Research*, 6, 703-714.
- Raja, J. E., Kiong, L. C., & Soong, L. W.** (2013). Hilbert–Huang Transform-Based Emitted Sound Signal Analysis. *Arab J Sci Eng*, 38, 2219-2226.
- Raja, J. E., Lim, W. S., & Venkatasethaiah, C.** (2012). Emitted Sound Analysis for Tool Flank Wear Monitoring. *International Journal of Computer and Electrical Engineering*, 4(2), 110-114.
- Ravikumar, S., & Ramachandran, K. I.** (2018). Tool Wear Monitoring of Multipoint Cutting Tool using Sound Signal Features Signals with Machine Learning Techniques. *Materials Today: Proceedings*, 5(11), 25720-25729.
- Renones, A., Rodríguez, J., & de Miguel, L. J.** (2010). Industrial application of a multitooth tool breakage detection system using spindle motor electrical power consumption. *Int J Adv Manuf Technol*, 46, 517-528.
- Rubio, E. M., & Teti, R.** (2010). Process Monitoring Systems for Machining Using Audible Sound Energy Sensors. T. Aized içinde, *Future Manufacturing Systems*. IntechOpen. <https://www.intechopen.com/chapters/12128> adresinden alındı
- S355 J2+N Steel Plate.** (2021, Ekim). Htsteelmill: https://www.htsteelmill.com/s355-j2n-steel-plate.html?gclid=Cj0KCQjw-4SLBhCVARIsACrhWLVmjXUfFj27whrtGRHxDVqmXVqOalCKoQKc8zWp94B1ODZ_tqlK02IaAp5HEALw_wcB adresinden alındı
- Salgado, D. R., & Alonso, F. J.** (2007). An approach based on current and sound signals for in-process tool wear monitoring. *International Journal of Machine Tools & Manufacture*, 47, 2140-2152.
- Salimiasl, A., & Özdemir, A.** (2016). Analyzing the performance of artificial neural network (ANN), fuzzy logic (FL), and leastsquare (LS) based models for online tool condition monitoring. *Int J Adv Manuf Technol*, 87, 1145-1458.
- Scheffer, C., Kratz, H., Heyns, P., & Klocke, F.** (2003). Development of a tool wear-monitoring system for hard turning. *Int. J. Mach. Tools Manuf.*, 43, 973-985.
- Seemuang, N., McLeay, T., & Slatter, T.** (2016). Using spindle noise to monitor tool wear in a turning process. *Int J Adv Manuf Technol*, 86, 2781-2790.
- Shankar, S., Mohanraj, T., & Rajasekar, R.** (2019). Prediction of cutting tool wear during milling process using artificial intelligence techniques. *Int J Comput Integr Manuf*, 32, 174-182.
- Shankar, S., Mohanraj, T., & Rajasekar, R.** (2018). Prediction of cutting tool wear. *International Journal of Computer Integrated Manufacturing*.
- Sharma, V. S., Sharma, S. K., & Sharma, A. K.** (2008). Cutting tool wear estimation for turning. *Journal of Intelligent Manufacturing*, 19(1), 99-108.
- Stavropoulos, P., Papacharalampopoulos, A., Vasiliadis, E., & Chrysosolouris, G.** (2016). Tool wear predictability estimation in milling based on multi-sensorial data. *Int J Adv Manuf Technol*, 82, 509-521.

- Sun, J., Rahman, M., Wong, Y. S., & Hong, G. S.** (2004). Multiclassification of tool wear with support vector machine by manufacturing loss consideration. *International Journal of Machine Tools and Manufacture*, 44(11), 1179-1187.
- Takahashi, H., Sakai, K., & Shizuka, H.** (2015). Development of an in situ tool wear monitoring system. *Advanced Materials Research*, 1117, 277-280.
- Wang, M., & Wang, J.** (2012). CHMM for tool condition monitoring and remaining useful life prediction. *Int J Adv Manuf Technol*, 59, 463-471.
- Wolszczak, P., Łygas, K., & Litak, G.** (2017). Monitoring of Cutting Conditions with The Empirical Mode Decomposition. *Advances in Science and Technology Research Journal*, 11(1), 96-103.
- Xu, G., Chen, J., & Zhou, H.** (2019). A tool breakage monitoring method for end milling based on the indirect electric data of CNC system. *Int J Adv Manuf Technol*, 101, 419-434.
- Zhang, K. F., Yuan, H. Q., & Nie, P.** (2015). A method for tool condition monitoring based on sensor fusion. *J Intell Manuf*, 26(5), 1011-1026.
- Zhixiong, L., Rui, L., & Dazhong, W.** (2019). Data-driven smart manufacturing: Tool wear monitoring with audio signals and machine learning. *Journal of Manufacturing Processes*, 48, 66-76.
- Zhou, C., Guo, K., & Sun, J.** (2021). Sound singularity analysis for milling tool condition monitoring towards sustainable manufacturing. *Mechanical Systems and Signal Processing*, 157.
- Zhou, C., Yang, B., Guo, K., Liu, J., Sun, J., Song, G., . . . Jiang, Z.** (2020). Vibration singularity analysis for milling tool condition monitoring. *International Journal of Mechanical Sciences*, 166, 105254.
- Zhu, K., & Zhang, Y.** (2019). A generic tool wear model and its application to force modeling and wear monitoring in high speed milling. *Mech Syst Signal Process*, 115, 147-161.

ÖZGEÇMİŞ

Ad-Soyad : Emre KALKANLI

ÖĞRENİM DURUMU:

- **Lisans** : 2017, Yıldız Teknik Üniversitesi Makine Mühendisliği
- **Yüksek Lisans** : 2021, Bursa Teknik Üniversitesi, Mekatronik Mühendisliği
Anabilim Dalı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Araştırma Geliştirme Mühendisi – MFK Makina