



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
TORNALAMADA TAKIM SESLERİNDEN TAKIM AŞINMASININ
TAHMİNİ**

Ramazan İLENÇ

**Ağustos-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
TORNALAMADA TAKIM SESLERİNDEN TAKIM AŞINMASININ
TAHMİNİ**

Ramazan İLENÇ

**Danışman
Dr. Öğr. Üyesi Savaş KOÇ**

**Ağustos-2024
BATMAN**

TEZ KABUL VE ONAYI

Ramazan İLENÇ tarafından hazırlanan “Derin Öğrenme Yöntemleri Kullanılarak Tornalamada Takım Seslerinden Takım Aşınmasının Tahmini” adlı tez çalışması 08/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Makine Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Nülifer GÜNDOĞAN

.....

Danışman

Dr. Öğr. Üyesi Savaş KOÇ

.....

Üye

Dr. Öğr. Üyesi Serkan BATI

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü V.

Bu tez çalışması Batman Üniversitesi- Bilimsel Araştırma Projeleri (BAP) Birimi tarafından BATÜBAP-2022-YL-27 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Ramazan İLENÇ

Tarih: 08/08/2024

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK TORNALAMADA TAKIM SESLERİNDEN TAKIM AŞINMASININ TAHMİNİ

Ramazan İLENÇ

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Makine Mühendisliği Ana bilim Dalı

Danışman: Dr. Öğr. Üyesi Savaş KOÇ

2024, 68 Sayfa

Jüri

Dr. Öğr. Üyesi Savaş KOÇ
Dr. Öğr. Üyesi Nülifer GÜNDOĞAN
Dr. Öğr. Üyesi Serkan BATI

İlerleyen akım aşınması ve takım kırılmasının tahmin edilmesi, talaşlı imalat işlemlerinin anlık olarak izlenmesi, kesme parametrelerinin optimizasyonu ve veri tabanlarının oluşturulması açısından büyük bir öneme sahiptir. CNC torna tezgahlarıyla optimize edilen sistemler, yüksek hassasiyet ve doğrulukla sonuçlar elde etmek için tercih edilmektedir. Günümüzde, takım tezgahlarında giderek daha fazla sensör kullanımı söz konusu olup, veri miktarı aşırı derecede artmaktadır. Takım durumu izleme için uygun sistemler, sinyallerin doğasına bağlı olarak seçilmektedir. DL (Derin öğrenme) ve ML (makine öğrenmesi) modelleri, bu sistemlerden bazılarıdır. Bu çalışmada, tornalama sırasında kaydedilen ses verileri, DL ve ML modelleri kullanılarak analiz edilmiştir. İş parçası malzemesi olarak 316L paslanmaz çelik ve 1050 çelik malzemesi kullanılmıştır. Ses verilerinin öznitelikleri, genlik-zaman, mel-spektrogram, MFCCs (Mel Frekanslı Kepstrum Katsayıları), ZCRs (Sıfır Geçiş Oranları) ve RMS (Karekök Ortalama Kare Enerjisi) kullanılarak çıkartılmıştır. DL modelleri olan 1D CNN (Evrişimsel Sinir Ağları) ve 2D CNN ile ML modelleri KNN (K En Yakın Komşular), SVM (Destek Vektör Makineleri), RF (Rastgele Orman) ve topluluk öğrenme modelleri, elde edilen öznitelikler kullanılarak eğitilmiştir. 316L paslanmaz çeliğin işlenmesi sırasında oluşan takım aşınması tahmininde 1D CNN modelinde %98.08, 2D CNN modelinde %96.72, KNN modelinde %94.26, SVM modelinde %90.43 ve topluluk öğrenme modelinde %96.99 gibi yüksek doğruluk oranları elde edilmiştir. 1050 çelik malzemesinin işlenmesi sırasında oluşan takım aşınması tahmininde ise 1D CNN modelinde %89.32, 2D CNN modelinde %91.24, KNN modelinde %89.6, SVM modelinde %84.27, RF modelinde %92.28 ve topluluk öğrenme modelinde %90.35 doğruluk oranları elde edilmiştir. DL yöntemleri ve ML modelleri, olumlu sonuçlar vermekte ve imalat sektöründe uygulanabilir sistemler olduğunu göstermektedir. Bu çalışma, sanayi ve akademik alanlarda uygulanabilirliği ve literatüre katkısı ile dikkat çekmekte olup, gelecekteki çalışmalar için bir temel teşkil etmektedir.

Anahtar kelimeler: Makine öğrenmesi modelleri, Özniteliklerin çıkartılması, Sınıflandırma ve tahmin, Takım aşınması

ABSTRACT

MS THESIS

PREDICTION OF TOOLWEAR FROM TOOL NOISES IN TURNING USING DEEP LEARNING METHODS

Ramazan İLENÇ

Batman University Graduate Education Institute

Department of Mechanical Engineering

Advisor: Asst. Prof. Dr. Savaş KOÇ

2024, 68 Pages

Jury

Asst. Prof. Dr. Savaş KOÇ

Asst. Prof. Dr. Nülfir GÜNDOĞAN

Asst. Prof. Dr. Serkan BATI

The prediction of progressive tool wear and tool breakage, as well as the real-time monitoring of machining processes, is crucial for optimizing cutting parameters and establishing databases. CNC lathe systems optimized for high precision and accuracy are preferred in this context. Nowadays, an increasing number of sensors are being used in machine tools, leading to an exponential growth in input data. Appropriate systems for tool condition monitoring are selected based on the nature of the signals. Some of these systems include DL (deep learning) and ML (machine learning) models. In this study, sounds recorded during turning were analyzed using DL and ML models. The workpiece materials used were 316L stainless steel and 1050 steel. The features of the sound data were extracted using amplitude-time, mel-spectrogram, MFCCs (Mel Frequency Cepstral Coefficients), ZCRs (Zero Crossing Rates), and RMS (Root Mean Square Energy). DL models, including 1D CNN (Convolutional Neural Networks) and 2D CNN, as well as ML models such as KNN (K-Nearest Neighbors), SVM (Support Vector Machines), RF (Random Forest), and ensemble learning models, were trained using the extracted features. During the machining of 316L stainless steel, high prediction accuracies were achieved for tool wear with the 1D CNN model at 98.08%, the 2D CNN model at 96.72%, the KNN model at 94.26%, the SVM model at 90.43%, and the ensemble learning model at 96.99%. For the machining of 1050 steel, prediction accuracies for tool wear were achieved at 89.32% with the 1D CNN model, 91.24% with the 2D CNN model, 89.6% with the KNN model, 84.27% with the SVM model, 92.28% with the RF model, and 90.35% with the ensemble learning model. The DL and ML models demonstrated favorable results, indicating their applicability in the manufacturing industry. This study is noteworthy for its applicability in both industrial and academic fields, contributing to the literature and laying a foundation for future research.

Key words: Classification and prediction, Feature extraction, Machine learning models, Tool wear

ÖNSÖZ

Tezin hazırlanması sürecinde yardımseverlik ve hoşgörüsü ile her zaman yol gösterici olarak bana yardımcı olan değerli danışman hocam Sayın Dr. Öğr. Üyesi Savaş KOÇ'a çok teşekkür ederim.

Ramazan İLENÇ
BATMAN-2024



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ	xii
1. GİRİŞ	1
1.1. İmalatın Önemi.....	3
1.2. Tornalama	4
1.3. Takımların Kullanımı.....	5
1.4. Takım Aşınması	6
1.4.1. Aşınma tipleri	8
1.4.1.1. Abraziv aşınma.....	8
1.4.1.2. Difüzyon aşınması.....	8
1.4.1.3. Yorulma aşınması.....	8
1.4.1.4. Oksidasyon aşınması.....	8
1.4.1.5. Adeziv aşınma	9
1.4.1.6. Serbest yüzey aşınması	9
1.4.1.7. Krater aşınması.....	9
1.4.1.8. Çentik aşınması	9
1.4.2. Takımda meydana gelen hasarlar	10
1.4.2.1. Isıl ve mekanik çatlaklar	10
1.4.2.2. Plastik deformasyon	10
1.5. Yapay Zekanın İmallerdeki Kullanımı.....	11
1.6. Yapay Zekâ	12
1.7. Evrişimli Sinir Ağları (CNN) Mimarisi	13
1.8. Makine Öğrenmesi	13
1.9. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme İlişkisi	14
1.10. Derin Öğrenme Modelleri	15
1.10.1. 1D-CNN modeli.....	15
1.10.2. 2D-CNN modeli.....	16
1.11. Makine Öğrenmesi Modelleri.....	16
1.11.1. Destek Vektör Makinesi modeli	16
1.11.2. K-En Yakın Komşu algoritması	17
1.11.3. Topluluk öğrenme modeli.....	17
1.11.4. Rastgele orman modeli	18
1.12. Ses Analizi ve Öznitelik Çıkartma Yöntemleri	18
2. KAYNAK ARAŞTIRMASI	22

3. MATERYAL VE YÖNTEM.....	28
3.1. Kesici Takım Ucları	28
3.2. Çelik Malzemeler	28
3.3. CNC Torna Tezgâhı	30
3.4. Talaş Derinliği, Devir ve İlerleme	31
3.5. Ses Kayıt ve Görüntü alma	31
3.6. Seslerin Ayıklanması	33
3.7. Seslerin Analizi ve Öznitelik Çıkartma.....	34
3.8. Derin Öğrenme ile Sınıflandırma.....	36
3.8.1 1D CNN modeli	36
3.8.2. 2D CNN modeli	37
3.9. Makine Öğrenmesi ile Sınıflandırma.....	37
3.9.1. SVM modeli.....	37
3.9.2. KNN modeli.....	37
3.9.3. Topluluk öğrenme modeli.....	38
3.9.4. RF modeli	38
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	39
4.1. 316L Paslanmaz Çelik İçin Takım Aşınması Eğitim Sonuçları ve Tahminler	39
4.1.1. 1D CNN modeli sonuçları	39
4.1.2. 2D CNN modeli sonuçları	40
4.1.3. KNN modeli sonuçları	42
4.1.4. SVM modeli sonuçları	43
4.1.5. Topluluk öğrenme modeli sonuçları	44
4.2. 1050 Çelik İçin Takım Aşınması Eğitim Sonuçları ve Tahminler	49
4.2.1. 1D CNN modeli sonuçları	49
4.2.2. 2D CNN modeli sonuçları	50
4.1.3. KNN modeli sonuçları	52
4.1.4. SVM modeli sonuçları	53
4.1.5. RF modeli sonuçları.....	54
4.1.6. Topluluk öğrenme modeli sonuçları	56
5. SONUÇLAR VE ÖNERİLER	61
5.1. Sonuçlar	61
5.2 Öneriler	61
KAYNAKLAR	63
ÖZGEÇMİŞ	68

SİMGELER VE KISALTMALAR

Simgeler

V	:	Kesme hızı
F	:	İlerleme
A	:	Kesme derinliği
F	:	Kuvvet

Kısaltmalar

YSA	:	Yapay Sinir Ağları
BM	:	Bulanık Mantık
TDİ	:	Takım Durumu İzleme
AI	:	Yapay Zekâ
IoT	:	Nesnelerin İnterneti
CNN	:	Evrişimli Sinirsel Ağlar
DL	:	Derin Öğrenme
ML	:	Makine Öğrenmesi
SVM	:	Destek Vektör Makinesi
KNN	:	K-En Yakın Komşu
RF	:	Rastgele Orman
ROC	:	Alıcı İşletim Karakteristiği
VB	:	Serbest Yüzey Aşınması

ŞEKİLLER LİSTESİ

Şekil 1.1. Torna tezgâhının kısımları.....	5
Şekil 1.2. Kesici takımında oluşan aşınma durumu.....	7
Şekil 1.3. Kesici takımında aşınma tipleri	11
Şekil 1.4. CNN mimarisinin genel yapısı	13
Şekil 1.5. Yapay zekâ, ML ve DL ilişkisi	14
Şekil 1.6. 1D-CNN Model diyagramı.....	15
Şekil 1.7. 2D CNN modeli mimarisi	16
Şekil 1.8. Genlik-zaman diyagramı	19
Şekil 1.9. Mel Spectrogram diyagramı	19
Şekil 1.10. MFCC diyagramı.....	20
Şekil 1.11. ZCRs diyagramı	20
Şekil 1.12. RMS enerji diyagramı	21
Şekil 3.1. DNMG150608-OMM P25-M25 sert metal karbür uc	28
Şekil 3.2. 316L Paslanmaz Çelik.....	29
Şekil 3.3. 1050 Çelik Malzemesi.....	30
Şekil 3.4. CNC Torna Tezgâhı	30
Şekil 3.5. Ses Kayıt Cihazı	31
Şekil 3.6. Görüntü Alma Aparatı.....	32
Şekil 3.7. Görüntü alma aparatıyla alınan takım durumu görüntüleri	32
Şekil 3.8. Audacity programı ile seslerin ayıklanması	33
Şekil 3.9. Ses kaydından öznelik çıkartma yöntemi.....	34
Şekil 3.10. Tahminler için karmaşıklık matrisi	35
Şekil 4.1. 1D CNN model her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler.....	39
Şekil 4.2. 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi	40
Şekil 4.3. 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler.....	41
Şekil 4.4. 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi	41
Şekil 4.5. KNN modeli öğrenme eğrisi ve ROC eğrisi	42
Şekil 4.6. KNN modeli karışıklık matrisi	43
Şekil 4.7. SVM modeli öğrenme eğrisi ve ROC eğrisi	43
Şekil 4.8. SVM modeli karışıklık matrisi	44
Şekil 4.9. Topluluk modeli için öğrenme eğrisi ve ROC eğrisi	45
Şekil 4.10. Topluluk modeli karışıklık matrisi	46
Şekil 4.11. Her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler	49
Şekil 4.12. 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi	50
Şekil 4.13. 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler.....	51
Şekil 4.14. 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi	51
Şekil 4.15. KNN modeli öğrenme eğrisi ve ROC eğrisi	52
Şekil 4.16. KNN modeli karışıklık matrisi	53
Şekil 4.17. SVM modeli öğrenme eğrisi ve ROC eğrisi	53
Şekil 4.18. SVM modeli karışıklık matrisi	54
Şekil 4.19. RF modeli öğrenme eğrisi	55

Şekil 4.20. RF modeli karışıklık matrisi.....	55
Şekil 4.21. Topluluk modeli öğrenme eğrisi ve ROC eğrisi	56
Şekil 4.22. Topluluk modeli karışıklık matrisi	57



TABLÖLAR LİSTESİ

Tablo 3. 1. 316L paslanmaz çelik özellikleri	28
Tablo 3. 2. Ses dinlemesi yapılan cihaz bilgileri	31
Tablo 3. 3. Görüntü alma aparatı ölçüleri	32
Tablo 3. 4. Ayıklanmış ses kayıtları.....	33
Tablo 4.1. Takım aşınması sınıflandırma metrik sonuçları.....	47
Tablo 4.2. Takım aşınması sınıflandırmada doğru yanlış tahminler.....	48
Tablo 4.3. Takım aşınması sınıflandırma metrik sonuçları.....	58
Tablo 4.4. Takım aşınması sınıflandırmada doğru yanlış tahminler.....	59



1. GİRİŞ

Günümüzde gelişen teknoloji ve artan üretim taleplerini karşılamak amacıyla talaşlı imalata yönelik çok sayıda araştırma yapılmaktadır. Bunların önemli bir kısmı kesme işlemleri ile yüzey pürüzlülüğü, takım aşınması ve kesme kuvvetlerinin ilişkilerinin incelenmesi şeklinde olmuştur. Talaşlı imalat yıllardır önemini korumakta ve bu alanda yapılan çalışmalar imalatçı firmalar tarafından yakından takip edilmektedir. Her üretimin bir maliyeti ve bu maliyeti belirleyen faktörler vardır. Talaşlı imalat kesici takım ve iş parçasının maliyeti en önemli faktörlerden biri olarak kabul edilebilir. Bu nedenle üretim maliyetini azaltmak ve ürünü daha ucuz hale getirmek için bu faktörlerin dikkate alınması gerekir. Teknolojinin gelişmeye başladığı ilk dönemlerde işlemeyi etkileyen parametreler, takım ömrü, takım aşınması ve yüzey kalitesini etkileyen faktörlere pek önem verilmiyordu. Ancak işleme süreçlerinde seri üretimin önem kazandığı günümüzde bu faktörler daha da önem kazanmaktadır (Kider, 2016).

Kesici takımların ömrünü uzatmak ve iş parçalarının istenen kalitede üretilmesini sağlayarak malzeme israfını önlemek için kesme performansı ve şartlarının en iyi duruma getirilmesi gerekmektedir. Bunu başarmak için, bilim insanları kesici takım ömrünü etkileyen faktörler ve iş parçası kalitesini belirleyen unsurlar üzerinde çalışmalar yapmaktadır. Araştırmalar, tornalama işlemlerinde kesici takım ömrü ve iş parçası kalitesine etki eden pek çok parametrenin bulunduğunu göstermektedir. Kesici takımın geometrik yapısı, uç açısı, yaklaşma açısı, talaş derinliği, ilerleme hızı, kesme hızı, kaplama malzemeleri, soğutma sıvısı, iş parçası ve kesici takımın rijitlik oranı gibi parametreler, hem kesici takımın dayanıklılığını hem de üretilen ürünün kalitesini doğrudan etkilemektedir. Kesici takımda meydana gelen bu aşınma; iş parçasının yüzey kalitesini bozarak kaliteyi düşürmekte, takım tezgâhının mil ve yataklarında titreşimlerin artmasına neden olmakta, talaş kaldırmak için gerekli olan enerji miktarını dolayısıyla enerji sarfiyatını ve üretim maliyeti arttırmaktadır. Yaşanan tüm bu olumsuzluklar kesici takım ömrünün azalmasına ve takım maliyetinin artmasına sebep olmaktadır. Takım ömrüne etki eden nedenlerin bilinmesi ve bu etkilerin en az düzeye indirilerek kontrol altına alınması, en uygun takım ömrünü ve takım değiştirme zamanı belirlemek açısından önem taşımaktadır (Ceviz, 2015).

Yapay zekâ (YZ), özellikle mühendislik başta olmak üzere birçok bilim dalında karmaşık ve belirsizlik içeren verilerin bulunduğu durumlarda problemlerin çözümüne katkı sağlamaktadır. YZ'nin en önemli alt alanlarından bazıları Yapay Sinir Ağları (YSA)

ve Bulanık Mantık'tır (BM). Günümüzde bu iki yöntemin kullanımı oldukça yaygın hale gelmiştir. Bu yöntemlerin uygulama alanlarından biri de imalat sektöründe takım operasyonları sırasında takım kırılması ve aşınmasının tahmin edilmesidir. Takım Durumu İzleme (TDİ) sistemleri, özellikle ekonomik nedenlerle büyük bir gereksinimdir. Kesici takımlar zamanla aşındığından, aşınmış bir takımın değiştirilmesi önemlidir. Eğer aşınmış takımla işleme devam edilirse, takımın kesme yeteneği azalır ve takım tezgahında ya da iş parçasında ciddi hasarlar oluşabilir. Bu durum ürün kalitesinin düşmesine, takım değişimi sırasında zaman kaybına ve ekonomik zarara yol açabilir.

Geçmişte TDİ için farklı yöntemler uygulanmıştır, bunların başında ise matematiksel modeller gelmektedir. Ancak, kesme operasyonlarında kullanılan değişkenler genellikle doğrusal olmayan yapıya sahip olduğu için matematiksel modelleme başarılı olamamıştır. Bu yöntemler, takım kırılması veya aşınmamış takımın gereksiz yere değiştirilmesi gibi sorunlara neden olmuştur. Takım operasyonlarında asıl hedef, takım kırılmadan önce müdahale edebilmektir. Bu nedenle, takım kırılması ve aşınmasının erken belirtilerinin hızlı bir şekilde tahmin edilmesi önemlidir. Günümüzde, YSA ve BM gibi ileri teknolojiler, TDİ sistemlerinde kullanım için büyük önem taşımaktadır. Bu yöntemler doğrusal olmayan problemleri çözebilme yeteneğine sahip olduğundan, takım aşınması ile dolaylı değişkenler arasında güçlü bir ilişki kurabilmektedir.

TDİ sistemleri, belirli değişkenlerin zaman içerisindeki değişimlerini sürekli izleyerek operatörlerin geçmişte yaptığı işin sensörler yardımıyla daha hassas bir şekilde algılanmasını sağlar ve bu sayede işlemde elde edilen sonuçlar daha güvenilir hale gelir. İşleme sırasında bağımsız olarak anlık değişen ve tüm işleme sürecini etkileyen çeşitli değişkenler bulunduğundan, TDİ eş zamanlı olarak gerçekleştirilir. TDİ sistemleri, sensörler aracılığıyla izlenen değişkenlerden veri toplar, bu veriler değerlendirilerek sonuçlara olan etkileri analiz edilir. YSA ve BM gibi yöntemler, yetersiz veri ve gürültülü veri ortamlarında bile başarılı bir şekilde kullanılabilir. Bu yöntemler, matematiksel modellerin aksine, işlemler sırasında çevrimiçi olarak hızlı ve doğru bir şekilde takım aşınmasını tahmin etme imkanı sunar (Kuntoğlu, 2016).

1.1. İmalatın Önemi

İmalat, ham madde durumundaki bir malzemeyi, kullanılabilir bir forma dönüştürme sürecidir. Bu süreç, ilkel yöntemlerle insan ve hayvan gücü kullanılarak ya da makineler aracılığıyla mekanik enerji yardımıyla gerçekleştirilebilir. Tarım, tekstil, gıda gibi üretim alanlarına uygulanabilen sanayi, toplumun kalkınması ve ekonominin büyümesinde önemli bir rol oynamaktadır.

İmalatta elde edilen ürün, üretim araçları yardımıyla meydana getirilir. Geniş bir bakış açısıyla, tüm üretim işlemi yapan araçlara takım tezgâhı denilebilir. Ancak dar anlamda, taş, plastik, metal ve ahşap gibi malzemeleri işleyip belirli bir şekle getiren araçlar takım tezgâhı olarak adlandırılır. En yaygın kullanılan takım tezgâhları ise metal malzemeleri işleyenlerdir. Takım tezgâhına monte edilen ve belirli bir geometrik şekle sahip olan kesici takım yardımıyla, istenen biçim ve boyutta parçalar üretilir ya da iş parçasından fazla olan malzeme talaş şeklinde çıkarılır. İş parçası metal olduğunda bu işleme "Talaş Kaldırma" işlemi denir.

İmalatın ekonomideki rolü, bir ülkenin gelişim sürecinin en temel göstergelerinden biridir. Ülkeler geliştikçe, sektörlerin ekonomideki payları da değişiklik gösterir. Eskiden tarım ve hayvancılık gibi doğal kaynaklara dayalı sektörler daha ön planda ve büyük bir paya sahipken, ülkelerin gelişmesiyle bu pay yerini imalat sektörüne bırakır ve hizmet sektörünün önemi artmaya başlar. Bu değişim, gelişim literatüründe doğal ve yapısal bir dönüşüm olarak tanımlanır. Bunun yanı sıra, sanayinin gelişim sürecindeki rolü de değişir; gelir arttıkça imalat sanayisi hafif sanayiden ağır sanayiye doğru evrilir. Günümüzde ise, imalat sektöründeki değişimleri açıklamak için kullanılan teknolojiler, iş gücünün niteliği ve bilgi düzeylerine göre ayrımlar yapılmaya başlanmıştır (Doğruel ve Doğruel, 2008).


Talaşlı imalat, metal işleme sektöründe temel bir üretim yöntemi olarak öne çıkmaktadır. Bu yöntem, metal malzemelerin özel kesici takımlar halinde şekillendirilmesini sağlayan bir işleme türüdür. Bugün, endüstrinin hızla ilerlemesiyle birlikte, özellikle fason CNC (Bilgisayarlı Sayısal Kontrol) işleme yöntemleri ön plana çıkmaktadır. Talaşlı imalat, metal malzemelerin özel tasarlanmış kesici takımlar aracılığıyla şekillendirilmesini içerir. Bu yöntem, hassas parçalarda ve karmaşık geometrilerin elde edilmesinde etkili bir yol sunar. Delme, frezeleme ve tornalama gibi işlemleri içeren talaşlı imalat, endüstriyel üretimde yaygın olarak kullanılmaktadır. Talaşlı imalatın evrimi, endüstriyel üretimde önemli bir ömrün yaşandığı bir

dönemdir. CNC işleme teknolojisinin bu alandaki etkisi, üretim parçalarının verimliliğini artırarak ve kalite standartlarını yükselterek kendini göstermektedir. Bu gelişmeler, metal işleme sektöründe daha gelişmiş ve gelişmiş çözümlerin ortaya çıkmasına olanak tanımaktadır. Bu kontrollü işleme süreçleri, artık katmanlı imalat olarak bilinen kontrollü malzeme ekleme süreçlerinden farklıdır. Talaşlı imalat ile metal parçaların yanı sıra ahşap, plastik, seramik ve kompozit gibi malzemelerin de imalatı mümkündür. Günümüzde birçok işleme prosesinde, tıpkı katmanlı imalatta olduğu gibi geometrik ve teknolojik bilgilerin kontrolü için bilgisayarlar kullanılmaktadır (Tezel ve ark., 2018).

1.2. Tornalama

Talaşlı imalat, malzemeden talaş kaldırılmasıyla tasarlanmış geometri oluşturma işlemidir. Bu mühendislik geometrisini oluşturmak için uygun malzemeler, uygun aletler ve tezgahlar kullanılmalıdır. Tornalama önemli bir işleme dalıdır. Tornalama, dönen bir malzemeden talaşların çıkarılmasıyla parçaya tasarlanan silindirik şeklin kazandırılması işlemidir (Ahmed ve ark., 2015).

Torna tezgâhı, parçaya dönme hareketi vererek işlenecek parçadan kesici bir takımla sürekli talaş kaldırarak istenilen şekli vermeye yarayan bir tezgâh olarak tanımlanabilir. Büyüklük ve tip olarak revolver torna, masa tornası ve ayaklı torna gibi değişik özelliklerde ve ölçülerde imal edilirler. Torna tezgâhında, iş yapma kabiliyeti yönünden önemli ölçüler puntanın yüksekliği ve iki punta arası maksimum uzaklıktır. Bu ölçüler tornanın işleyebileceği malzemenin çap ve uzunluğunu belirler. Bir torna tezgâhının başlıca ana kısımları Şekil 1.1’ de gösterilmiştir.



Şekil 1.1. Torna tezgâhının kısımları

İş parçası torna tezgâhının aynasına bağlanır. Ayna parçanın durumuna göre üç veya dört ayaklı, düz veya mengeneli ayna olabilir. İstenilen devirlerde döndürülür. Ayna, fener miline bağlanır ve fener mili ise dişli kutusu aracılığıyla tahrik edilir. İş parçasını işlemek için kullanılan kesici takım çok önemli bir eleman olup kater üzerine rijit bir şekilde tespit edilir. İş parçası ekseni boyunca sabit bir ilerleme miktarıyla hareket ederek silindirik veya daha karmaşık profil yüzeyden talaş kaldırır.

1.3. Takımların Kullanımı

Kesici takımlar, iş parçasından talaşların uzaklaştırılarak iş parçasına şekil verilmesinde kullanılan, ağırlıklı olarak ileri teknoloji malzemelerden üretilmiş, özel geometrili, kaliteli, boyutsal doğruluğu yüksek kesicilerdir. İşlenecek parçanın özellikleri, kullanılabilecek kesici takım malzemelerine sınırlamalar getirdiği gibi, takımın kullanım koşulları da takım malzemesi seçimini büyük ölçüde etkiler. Kesici takım malzemelerinden beklenen ortak özellikler yüksek aşınma direnci, sertlik ve dayanıklılıktır.


Yüksek verimle üretim yapabilmek için, üretim sırasında en uygun işleme koşullarının sağlanması oldukça önemlidir. Talaş kaldırma işleminde kullanılan kesme hızı (V), ilerleme miktarı (f) ve kesme derinliği (a) gibi kesme parametreleri, takım ömrü üzerinde büyük bir etkiye sahiptir. Bir iş parçasının yüzeyinden belirli bir malzeme tabakasını kaldırmak için kesici takım adı verilen bir kesicinin malzemeye nüfuz etmesi gerekmektedir. Bu nedenle, kesici takımın işlenecek parçadan daha sert ve dayanıklı olması, işleme esnasında yeterli bir kuvvetin uygulanması ve kesme işleminin gerçekleşmesi için takımın uygun bir geometriye sahip olması şarttır. Ayrıca, kesme işleminin doğru koşullar altında yapılması gerekir. Tornalama işlemi, kesme işleminin sürekliliği ve talaş kaldırma işlemini en iyi şekilde temsil etmesi nedeniyle tek noktalı kesme işlemi olarak ele alınmaktadır (Akkurt, 2000).

Kesme işlemlerinde genel bir kural olarak, ideal kesme şartlarının belirlenmesinde en kritik faktör uygun kesme hızının seçilmesidir. Eğer kesme hızı çok düşük seçilirse, üretilen parça sayısı azalır ve bu düşük hızlarda takım ucunda talaş sıvanması meydana gelebilir, bu da kesici takımın değiştirilmesini zorunlu hale getirebilir. Öte yandan, kesme hızı gereğinden yüksek seçildiğinde takım hızla aşınır ve daha sık takım değişikliği gerekebilir. Bu sebeple, herhangi bir talaş kaldırma işlemi için en uygun kesme hızı, kesici takım ömrü ile kaldırılan talaş miktarını dengeleyecek şekilde belirlenmelidir (Şahin, 2001)

1.4. Takım Aşınması

Talaşlı imalat süreçlerinde, istenilen boyut ve yüzey kalitesindeki parçaları üretirken, hedeflenen üretim maliyetlerine ulaşmak için kesici takım ömrü ve takım aşınması göz önünde bulundurulması gereken kritik unsurlardandır. Aşınma, temas halindeki yüzeylerde mekanik, kimyasal ve benzeri etkiler sonucu ortaya çıkan malzeme kaybı olarak tanımlanır. Kesme işlemi başladığı andan itibaren kesici takım aşınma sürecine girer ve bu aşınma, kesme işlemi boyunca devam eder. Tornalama esnasında takımların aşınması, esas olarak kesme takımının talaş yüzeyinde ve yan yüzünde meydana gelir. Talaş yüzeyindeki aşınma, krater aşınması olarak bilinir ve takım kırılmasına neden olur, ancak iş parçasının boyutsal doğruluğunu ve yüzey kalitesini etkilemez. Takım yan yüzündeki aşınma, takım yan tarafı ile yeni oluşturulan iş parçası yüzeyi arasındaki sürtünmeden dolayı meydana gelir ve takım ömrünün yanı sıra iş parçasının boyutsal doğruluğunu ve yüzey finişini olumsuz yönde etkileyerek malzeme

kaybına neden olur (Siddhpura ve Paurobally, 2013). Şekil 1.2 kesici takımdaki aşınmayı göstermektedir.



Şekil 1.2. Kesici takımda oluşan aşınma durumu

Talaş kaldırma üzerine yapılan çalışmalarda ana hedef, takım hasar mekanizmasına bağlı olarak takım ömrünü belirleyebilecek yöntemler geliştirmektir. Ancak, herhangi bir durumda takım ömrünü kesin bir şekilde belirlemek oldukça zordur. Çünkü takım ömrü; kesme hızı, kesme derinliği, ilerleme hızı, takım ve iş parçası malzemesi ile talaş kaldırma yöntemi gibi birçok faktörden etkilenir. Tahminlere göre, kesici takım aşınmasının %50'si aşındırıcı (abraziv) aşınma, %20'si yapışma (adeziv) aşınma, %10'u kimyasal aşınma ve %20'si diğer aşınmalar (difüzyon, plastik deformasyon) nedeniyle oluşmaktadır (Kopac, 1998).

Aşınma, doğrusal olmayan, karmaşık bir özellik gösterir. Yapılan testler sonucunda, takım aşınmasının zamana bağlı değişiminde üç belirgin aşama gözlemlenmiştir. Bunlar, başlangıçta hızlı bir aşınma periyodu, ardından yavaş bir artış gösteren bir aşınma dönemi ve son olarak tekrar hızlanan bir aşınma periyodudur. Başlangıç aşamasında aşınma hızla artar, ardından daha dengeli bir seviyeye gelir ve takım ömrünün sonlarına yaklaşıldığında tekrar hızlı bir şekilde artış gösterir (Sağlam, 2000).

1.4.1. Aşınma tipleri

1.4.1.1. Abraziv aşınma

Abraziv aşınma, en yaygın aşınma türlerinden biridir ve genellikle iş parçası malzemesindeki sert parçacıklar nedeniyle meydana gelir. Bu durum, iş parçası yüzeyi ile kesici takım arasında giren sert parçacıkların, taşlama işlemine benzer şekilde aşınmaya neden olmasıyla ortaya çıkar. Abraziv aşınma, kesici ucun serbest yüzeyinde aşınmalara yol açar. Bu aşınma türüne karşı kesici kenarın dayanma kapasitesi, büyük ölçüde kesici ucun sertliğine bağlıdır.

1.4.1.2. Difüzyon aşınması

Bu aşınma türü, kesme işlemi sırasında kimyasal etkilerden daha fazla etkilenir. Takım malzemesinin kimyasal özellikleri ile takım ve iş parçası malzemesi arasındaki etkileşim, difüzyon aşınması mekanizmasını ortaya çıkarır. Difüzyon aşınması, özellikle yüksek kesme hızlarında artış gösterir. Ancak, bu tip aşınma tüm takım malzemeleri için geçerli olmayabilir ve bu tür aşınmayı önlemek için çeşitli önlemler alınabilir.

1.4.1.3. Yorulma aşınması

Sıcaklık ve mekanik etkilerin birleşimi sonucu ortaya çıkar. Kesme işlemi sırasında sıcaklık değişimleri ve takıma uygulanan kesme kuvvetlerinin sıfır ile maksimum değerler arasında dalgalanması, kesici kenarın çatlamasına ve kırılmasına yol açabilir. Aralıklı kesme işlemleri, kesici ucun sürekli olarak ısınmasına ve soğumasına neden olur, bu da talaşla temas eden kesici kenarda şok etkilerine yol açar.

1.4.1.4. Oksidasyon aşınması

Yüksek sıcaklıklar ve ortamdaki hava, birçok metal için oksidasyon anlamına gelir. Tungsten ve kobalt gibi malzemeler, gözenekli oksit film tabakaları oluşturabilir, ancak bu tabakalar takım ile yüzeyden uzaklaştırılabilir. Öte yandan, alüminyum oksit gibi bazı oksitler son derece dayanıklı ve serttir. Bu nedenle, bazı takım malzemelerinde kesici kenarın aşınması yaşanabilir. Özellikle kesici kenarın talaşla temas ettiği bölgede,

talaş derinliğinin sona erdiği kısımda hava etkili olabilir ve oksidasyon sonucunda kenarda çentikler oluşabilir.

1.4.1.5. Adeziv aşınma

Bu tür aşınma genellikle takımın talaş yüzeyindeki düşük işleme sıcaklıklarından kaynaklanır. Çelik, alüminyum ve dökme demir gibi uzun ve kısa talaşların olduğu malzemelerde bu aşınma mekanizması görülür. Bu durumda, kesici kenar ile talaş arasındaki yığılma, kenar aşınmasına yol açar.

1.4.1.6. Serbest yüzey aşınması

Takımın serbest yüzeyinde meydana gelen aşınma, serbest yüzey aşınması olarak adlandırılır ve bu durum bir aşınma bölgesinin oluşmasına neden olur. Aşınma bölgesinin işlenmiş yüzeyle sürtünmesi, talaş kaldırılan parça yüzeyinde hasara yol açar. Bunun sonucunda, yüksek serbest yüzey kuvvetleri nedeniyle boyutsal doğrulukta azalma ve sapmalar meydana gelir (Özdemir ve Erten, 2003).

1.4.1.7. Krater aşınması

Kesici takımın talaş yüzeyinde, krater aşınması olarak bilinen bir krater şeklinde aşınma meydana gelir. Takımın talaş yüzeyi, iş parçasından kaldırılan talaşın kaydığı yüzeydir. Genellikle hafif bir krater aşınması, takım ömrünü sınırlamaz ve krater oluşumu, takım talaş açısının etkinliğini artırarak kesme kuvvetlerini azaltır. Ancak, aşırı krater aşınması kesme kenarlarını zayıflatabilir ve bu durum takımın deformasyonuna veya kırılmasına neden olabilir. Krater aşınması, genellikle dökme demir gibi sert ve kırılma malzemelerin işlenmesi sırasında görülür. Krater aşınması, takım malzemelerinin kimyasal kararlılığını artırmak veya takım talaş içindeki çözünürlüğünü azaltmak suretiyle minimize edilebilir (Özdemir, 2008).

1.4.1.8. Çentik aşınması

Kaba yüzeylerin tornalanmasında kullanılan kesici takımlarda, talaş ile işlenmemiş yüzey veya talaş kenarı arasındaki temas noktasında çentik aşınması meydana

gelir. Bu çentiklerin derinliği genellikle, aşınmanın yanı sıra işlenen parçaların sert bir yüzey tabakasına sahip olması veya iş parçasının doğal sertliğinden kaynaklanan abrazyon etkisinden kaynaklanır. Bu durum, talaşın takım üzerinde oluşturduğu çentiklerin derinliğini artırabilir.

1.4.2. Takımda meydana gelen hasarlar

1.4.2.1. Isıl ve mekanik çatlaklar

Bu çatlaklar, kesintili talaş kaldırma işlemleri sırasında değişken yükler veya yüksek talaş sıcaklıkları nedeniyle ortaya çıkar. İki tür çatlak oluşabilir: biri, soğutucu kullanıldığında değişken ısı yükleri altında kesme kenarlarına dik olarak gelişir; diğeri ise değişken mekanik yükler nedeniyle kesme kenarlarına paralel olarak oluşur. Çatlakların oluşumu, talaşın hızla hasar görmesine yol açabilir.

1.4.2.2. Plastik deformasyon

Talaş ile talaş arasındaki temas bölgesinde kesme basınçları talaş tarafından desteklenemediğinde, kesici takımda plastik deformasyon meydana gelir. Bu deformasyon genellikle yüksek ilerleme hızlarında ve yüksek kesme kenar kuvvetlerinde ya da talaş sertliğinin kesme hızı ve sıcaklıkla birlikte azaldığı yüksek kesme hızlarında görülür. Kesme kenarındaki aşırı deformasyon, boyutsal doğrulukta azalma, kötü yüzey kalitesi ve aşırı serbest yüzey aşınması ya da talaş kırılması gibi sorunlara yol açar.

1.4.2.3. Takım kırılması

Takım kırılması, takımın bir bölümünün çatlaması veya kesme kenarlarının parçalanması olarak tanımlanır. Oluşan bu gibi hasarları önlemek için kesme kuvvetlerini azaltmak, daha sağlam ve rijit talaş tertibatları kullanmak ve kırılma tokluğu artırılmış malzemeler tercih etmek önerilir (Özdemir, 2008).

Kesici takım ömrünün durumu ile ilgili bilgi sahibi olmak için, takımda zayıflamaya yol açan nedenleri bilmek önemlidir. Takım hasarı, aşınma, plastik deformasyon ve kırılma gibi etkenlerden kaynaklanabilir. Takım aşınması, etkilenen bölge veya aşınmayı oluşturan fiziksel mekanizmalara göre sınıflandırılır. Ana aşınma

mekanizması büyük ölçüde kullanılan takım malzemesine bağlıdır. Takımlar, talaş oluşumu sırasında karşılamaları gereken yükleri aşamadıklarında plastik deformasyona uğrar veya kırılırlar. Bazı aşınma türleri Şekil 1.3'te gösterilmiştir.



Şekil 1. 3. Kesici takımda aşınma tipleri

Talaş kaldırma işlemi sırasında ortaya çıkan sürtünme, makine elemanlarındaki sürtünmeden farklıdır. Bu fark, talaş kaldırma sürecinde oluşan sürtünmenin sürekli bir şekilde yeni yüzeylerde, yüksek sıcaklık ve basınç altında küçük temas bölgelerinde oluşmasından kaynaklanmaktadır. Bu nedenle, takım aşınması çeşitli aşınma türlerini içeren oldukça karmaşık bir süreçtir (Özdemir, 2008).

1.5. Yapay Zekanın İmallattaki Kullanımı

Artan küreselleşme, ekonomik, sosyal ve politik alanlarda önemli değişikliklere neden olmuştur. Nesnelerin İnterneti (IoT), Bulut Bilişim, Büyük Veri Analitiği ve Yapay Zeka (YZ) gibi birçok teknoloji gelişim aşamasındadır. Bu teknolojiler, Endüstri 4.0'ın temel taşlarını oluşturur ve üretim endüstrisinin akıllı hale gelmesine, bireysel müşteri gereksinimlerine uyum sağlamasına, pazar taleplerine hızla yanıt vermesine ve kaliteyi artırmasına yardımcı olur (Zheng ve ark., 2018).

Endüstri 4.0, yukarıda belirtilen teknolojileri kullanarak üretimi gerçek zamanlı olarak optimize etmek ve dikey, yatay ve uçtan uca entegrasyonu kolaylaştırmak suretiyle küresel üretim ve endüstriyel gelişim üzerinde önemli bir etki yaratmıştır (Obradović ve ark., 2021). Siber-Fiziksel Sistem, üretim endüstrisinde tanınan bir kavram olup, Endüstri 4.0'ın fiziksel ve sanal dünyaların entegrasyonunu sağlar. YZ, günümüzde birçok alanda giderek artan bir şekilde yer bulmakta ve işletmelerin dijital dönüşümünün ayrılmaz bir parçası olmaktadır. Endüstri 4.0 çağında, üretim sektörü bilgiye dayalı akıllı üretimden, veri destekli ve bilgi odaklı akıllı üretime geçiş yapmaktadır (Zhong ve ark., 2017). YZ, akıllı üretim ve Endüstri 4.0'ın temel teknolojilerinden biri olarak kabul edilmektedir (Zheng ve ark., 2018).

1.6. Yapay Zekâ


YZ dendiğinde, birçok kişinin içinde doğal bir merak oluşur. Bu merak, insanlığın tarih boyunca cansız varlıkları hareket ettirme arzusundan kaynaklanmaktadır. Herkes bu konuyu ilgiyle takip etse de, çoğu insanın bu alanda derin bir bilgisi bulunmamaktadır. Günümüzde YZ uygulamalarının öncüsü, insansı robotlar olarak öne çıkmaktadır. Özellikle teknolojinin ilerlemesi ve yeni ihtiyaçların doğmasıyla, YZ ve insana benzeyen robotlara olan ilgi her geçen gün artmaktadır. Şu anda, iş gücünü azaltmak amacıyla insanları yerine geçirebilecek robotların geliştirilmesi gündeme gelmiş ve çeşitli alanlarda kullanılmaya başlanmıştır. YZ, bilgisayar mühendisliği, elektronik, kontrol, mekatronik, programlama ve felsefe gibi birçok disiplinin kesişim alanında yer alan çok yönlü bir alandır (Öztürk ve Şahin, 2018).

Bilim dünyasında, YZ genellikle bir bilgisayarın veya bilgisayar destekli bir makinenin, insana özgü nitelikler taşıyan görevleri yerine getirme yeteneği olarak tanımlanır. Bu görevler, anlam çıkarma, çözüm bulma, genelleme yapma ve geçmiş deneyimlerden öğrenme gibi yüksek düzeyde mantıksal süreçleri içerir (Nabiyev, 2012).

Modern YZ'nın kökenleri, klasik düşünürlerin, insan düşünce sistematiğini simgesel bir sistem olarak tanımlama çabalarına kadar uzanır. Fakat YZ, resmi olarak 1956 yılında oluşturulmuştur. Bu terim, 1956'da Hannover, New Hampshire'daki Dartmouth College'da yapılan bir konferansta ilk kez kullanılmıştır (Lewis ve Writer, 2014).

1.7. Evrişimli Sinir Ağları (CNN) Mimarisi

DL (Derin Öğrenme) alanında temel mimari olarak CNN (Evrişimli Sinir Ağları) kabul edilir. Şekil 1.4'te CNN mimarisinin genel yapısı gösterilmiştir. Bu mimaride ilk aşamalar Konvolüsyon (Convolution) ve Havuzlama (Pooling) katmanlarından oluşur, ardından ise Tam Bağlı (Fully Connected) katman gelir. Son olarak, Sınıflandırma katmanı bulunur. Özetle, CNN'ler ardışık olarak düzenlenmiş birden fazla eğitilebilir katmandan oluşur ve ardından bir sınıflandırıcı ile devam edilir. CNN'de, giriş verileri alındıktan sonra her bir katmanda işlemler gerçekleştirilir ve eğitim süreci tamamlanır. Eğitim sürecinin sonunda, elde edilen sonuç ile hedeflenen sonuç arasındaki fark hesaplanır. Bu fark, ağırlıkların güncellenmesi için geriye yayılım algoritması ile tüm ağırlıklara aktarılır. Her adımda ağırlıklar güncellenerek hata minimize edilir. CNN'ler, giriş verileri olarak görüntü, ses veya video gibi çeşitli sinyallerle çalışabilir (LeCun ve ark., 2015).



Şekil 1. 4. CNN mimarisinin genel yapısı

1.8. Makine Öğrenmesi

ML (Makine Öğrenmesi), veriye dayalı olarak sorunları modelleyen bilgisayar algoritmalarının genel adıdır. Mevcut veri seti ve seçilen algoritma ile oluşturulan model, en yüksek performansı sağlamak üzere tasarlanır. Bu nedenle birçok ML yöntemi geliştirilmiştir; bunlar arasında KNN (K-En Yakın Komşular) algoritması, NB (Naive Bayes) sınıflandırıcısı, DT (Karar Ağaçları), lojistik regresyon analizi, k-ortalamalar algoritması, SVM (Destek Vektör Makineleri) ve YSA (Yapay Sinir Ağları) bulunmaktadır. Bu yöntemler tahmin, kümeleme ve sınıflandırma işlemlerini gerçekleştirebilecek kapasiteye sahiptir. Öğrenme stratejileri ise denetimli, denetimsiz ve

takviyeli olmak üzere üç ana kategoriye ayrılır. Denetimli öğrenmede, model, belirli giriş değerlerine karşılık hedef değerler verilerek bu ilişkileri öğrenir ve yeni veriler için en uygun çıktıları üretmeye çalışır. En iyi model, yeni girişler için de doğru sonuçları verebilir. Denetimsiz öğrenmede ise, hedef değerler olmadan yalnızca giriş değerleri arasındaki ilişkiler analiz edilir ve benzer değerler gruplandırılır. Yeni bir girdi, hangi grup ile ilişkiliyse o grupta yer alır. Takviyeli öğrenme yönteminde ise, hedef çıktıyı sağlamak için bir danışman yerine, elde edilen sonuçların iyi ya da kötü olarak değerlendirilmesini sağlayan bir kriter kullanılır (Atalay ve Çelik, 2017).

1.9. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme İlişkisi

YZ, bilgisayar biliminin bir alt dalıdır ve bilgisayarların akıllı davranmasını sağlayarak akademi ve endüstride kendine yer bulan bir araştırma alanıdır.


(Nilsson, 2014). Bu macera ve YZ'ya yönelik eğilim 2016 yılında, Google DeepMind'a ait bir yazılım şirketinin tarafından, DeepMind üretilen bir yazılım olan AlphaGo ile rakibini avantajsız bir şekilde yenmesiyle başlamıştır (Siau ve Wang, 2018). YZ, ML ve DL benzer kavramlar birbiriyle çok karıştırılan kavramlardır. YZ ile ML ilişkisi Şekil 1.5'te verilmiştir. YZ, programların insanlar gibi öğrenebilmesi ve davranabilmesi iken ML ise aynı amaç için yazılan algoritmalarıdır.



Şekil 1. 5. Yapay zekâ, ML ve DL ilişkisi

1.10.2. 2D-CNN modeli

2D CNN modeli, bir evrişim katmanı, bir havuzlama katmanı ve bir tam bağlantı katmanından oluşan çok katmanlı bir sinir ağı yapısını temsil eder. Bu model Şekil 1.7’de detaylandırılmıştır. Evrişim katmanları, giriş görüntüsünü N adet küçük ağırlıklı matrisle işleyip doğrusal olmayan ReLU aktivasyon fonksiyonu kullanarak N özellik haritası üretir. Özellik haritalarındaki gereksiz bilgiler, ortalama havuzlama veya maksimum havuzlama katmanında ortalama veya maksimum değerlerin hesaplanmasıyla daha küçük matrislere dönüştürülür. Ezberci öğrenmenin önüne geçmek için veri düşürme değeri uygulaması yapılır, böylece verilerin bir kısmı ele alınır. Nihai veriyi düzenlemek için tam bağlantı katmanı kullanılır ve sinir ağlarından geçirilerek sınıflandırma işlemi gerçekleştirilir (Yang ve ark., 2018).



Şekil 1. 7. 2D CNN modeli mimarisi

1.11. Makine Öğrenmesi Modelleri

1.11.1. Destek Vektör Makinesi modeli

SVM, sınıflandırma veya doğrusal ilişkilerin belirlenmesi gibi problemleri çözmek için kullanılan bir denetimli makine öğrenmesi algoritmasıdır. Özellikle ikili sınıflandırma problemleri söz konusu olduğunda, SVM etkili bir şekilde kullanılabilir (Cortes, 1995). Doğrusal olarak ayrılabilen sınıfları belirlemek için sıklıkla kullanılan yöntem, çekirdek fonksiyonları sayesinde, doğrusal olarak ayrıştırılamayan bir giriş uzayını, bu doğrusal olarak ayrılabilen daha yüksek boyutlu uzaya taşıyarak, doğrusal

olmayan verileri sınıflandırmada başarılı bir şekilde kullanılmaktadır. (Güran ve ark., 2014).

En eski sınıflandırıcılardan biri olan SVM eğitildikten sonra sağladığı tahminlerin doğruluğu açısından belirgin bir performans gösterir. SVM genellikle sınıflandırma sorunlarında kullanılan gözetimli öğrenme yöntemlerindendir. Bu sınıflandırma, iki sınıf arasındaki noktaların maksimum uzaklıkta olmasını sağlamak için, bir düzlem üzerinde yerleştirilmiş noktaları ayıran bir doğru çizer. Küçük ve orta ölçekteki karmaşık veri setleri için uygundur.

1.11.2. K-En yakın komşu algoritması

KNN, sınıflandırılmamış bir örneğin en yakın komşularını belirleyerek benzer sınıflara göre tahminler yapan bir yöntemdir. Bu algoritma, en yakın komşuları bulmak amacıyla veri setini tek tek tarar; bu nedenle tembel öğrenme ya da vaka tabanlı öğrenme yöntemi olarak bilinir (Cunningham ve Delany, 2021). Ancak, bu yaklaşım büyük veri kümelerinde yavaş çalışmasına yol açar (Guo ve ark., 2003). KNN algoritması, sınıflandırılmamış bir örneği, önceden sınıflandırılmış veri noktaları arasındaki uzaklığa göre uygun sınıfa atar (Cover ve Hart, 1967).

1.11.3. Topluluk öğrenme modeli

Topluluk (Ensemble) öğrenme modeli birden fazla modeli eğiterek tahminleri birleştiren ve tek bir model gibi çalışan sınıflandırma ve tahmin modellerini oluşturmaktadır. Denetimli öğrenme uygulamalarında topluluk öğrenme modelleri, uyarıcıları karar verici olarak birleştirilerek tek bir çatı altında toplamaktadır. Temel öğrenme unsuru olarak da tanımlanan uyarıcılar, bir grup etiketli sınıf örneğini girdi verisi olarak alan ve örnekleri genelleştiren bir modeldir. Bir topluluk öğrenme modeli, herhangi bir türdeki ML modellerini birleştirebilmektedir. Temel prensibi, birden fazla modeli birleştirmesi ve hataları azaltarak genel tahmin performansını tek bir modele göre iyileştirmesi olduğu bildirilmiştir (Sagi ve Rokach, 2018).


1.11.4. Rastgele orman modeli

RF (Rastgele Orman) algoritması, Leo Breiman tarafından geliştirilen topluluk sınıflandırma yöntemlerinden biridir (Breiman, 2001; Mursalin ve ark., 2017). Bu tür topluluk sınıflandırma teknikleri, tek bir sınıflandırıcı yerine birden fazla sınıflandırıcı oluşturarak, bu sınıflandırıcıların tahminleriyle yeni verileri sınıflandıran algoritmalardır (Akar ve Güngör, 2012).

1.12. Ses Analizi ve Öznitelik Çıkartma Yöntemleri


Ses analizi, ses dosyaları üzerinden ses karakteristik özellikleri çıkarılarak yapılan analiz türüdür. Ses analizi ile çıkarılan bu özellikler eğitime veri olarak verilebilmekte veya sesin görüntüye (spectrogram, chromogram, ...) dönüştürüldüğü özellikler olarak görüntü işleme yoluyla sistemde eğitilebilmektedir. Her iki özellik türü düşünüldüğünde, ses analizinin çalışma alanı oldukça geniştir. Ses analizi aracılığıyla ses dosyaları sayısal verilere dönüştürülmektedir. Bu sayısal veriler ile özellik çıkarımı işlemi uygulanmaktadır. Elde edilen bu özellikler, sesin karakteristik özelliklerini oluşturmaktadır. Ses karakteristik özelliklerinin eğitim aşamasında kullanılması ile oluşturulan sistemin başarısı test verileri ile ölçülmektedir (Güven, 2024).

Öznitelikleri anlayabilmek için öncelikli olarak sinyal gösterimlerini anlamak gerekir. Bir sinyalin genlik-zaman ve frekans-zaman olmak üzere iki temel gösterimi vardır. Genlik-zaman gösteriminde sinyalin dalga formu gözlemlenir. Dalga formu bize zaman içerisinde sinyalde meydana gelen seviye değişikliklerini gösterir. Sayısal sistemlerde genlik 1 ile -1 arasında tanımlıdır ve bu aralıkta normalize edilir. Bir sinyalin frekans-zaman gösterimini elde edebilmek için Fourier çevirimi kullanılır. Şekil 1.8'de genlik-zaman diyagramı gösterilmektedir. Ayrık sistemlerde Fourier çeviriminin verimli gerçekleştirilebilmesi için STFT (Kısa Zaman Fourier Çevirimi) yöntemi tercih edilir. STFT doğrusal olarak yerleştirilmiş merkez frekansları ile zaman-frekans sunumu elde edilir. STFT analizi yapılan sinyalin frekans içeriğini gözlemlemek amacıyla tercih edilen yöntemlerden biri genlik-zaman ölçerdir (Yücel, 2023).



Şekil 1. 8. Genlik-zaman diyagramı


Spektrogramlar, belirli bir dalga biçiminde bulunan farklı frekanslarda bir sinyalin sinyal ses yüksekliğini veya gücünü zaman içinde temsil etmenin görsel bir yoludur. Sadece 2 Hz'e karşı 10 Hz'de daha fazla veya daha az enerji olup olmadığını görmekle kalmaz, aynı zamanda enerji seviyelerinin zaman içinde nasıl değiştiği de görülebilmektedir. Diğer bilimlerde spektrogramlar genellikle mikrofonların yanı sıra insanlar, makineler, hayvanlar, balinalar, jetler vb. tarafından da kaydedilir. Üretilen ses dalgalarının frekanslarını görüntülemek için kullanılır. FFT (Hızlı Fourier dönüşümü) kullanılarak bir zaman sinyalinden bir ses spektrogramı oluşturulabildiği ifade edilmiştir. "Mel" melodinin kısaltması olduğu, bunun, perdelerin karşılaştırılmasına dayanan algısal bir ölçek ölçümü olduğunu ima edilmiştir (Tran ve Lundgren, 2020). Şekil 1.9'da mel-spectrogram diyagramı gösterilmiştir.



Şekil 1. 9. Mel Spectrogram diyagramı


MFCCs (Mel Frekansı Kepstrum Katsayıları) yöntemi ilk olarak 1980'lerde Davis ve Mermelstein tarafından kullanılmıştır (Davis ve Mermelstein, 1980). MFCCs algoritması, Hamming penceresini kullanarak bir ses akışını daha küçük pencerelelere

yeniden şekillendirerek çerçevelere bölmektedir. FFT kullanılarak her kare için bir spektrum oluşturulur ve her spektrum bir filtre bankası kullanılarak ağırlıklandırılır. Son olarak, Logaritma ve DCT (Ayrık Kosinüs Dönüşümü) kullanılarak MFCC vektörü hesaplanır (Yıldırım, 2022). Şekil 1.10’da MFCCs diyagramı gösterilmiştir.



Şekil 1. 10. MFCC diyagramı


Zaman temsil öznelikleri kısa zaman penceresinde ve doğrudan sinyal genlik verisi ile hesaplanırlar. ZCRs (Sıfır Geçiş Oranları) ve RMS (Karekök Ortalama Kare Enerjisi) enerji zaman temsil öznelikleri arasındadır. ZCRs birim zamanda sinyalin pozitif ve negatif olma sıklığıdır. Şekil 1.11’de ZCRs diyagramı gösterilmiştir. Bu değer sinyalin yüksek frekans içeriği ve sahip olduğu gürültü arttıkça artmaktadır.



Şekil 1. 11. ZCRs diyagramı

RMS enerji kısa zaman penceresi içerisinde her bir örneğin genlik değerinin karesinin toplamı ve bu toplamın kare kökünün alınması ile hesaplanır. Logaritmik olarak

da ifade edilebilir. Şekil 1.12’de gösterilmiştir. Enerji, bize sinyalin zarf yapısı hakkında değerli bilgiler sunmaktadır (Yücel, 2023).



Şekil 1. 12. RMS enerji diyagramı

2. KAYNAK ARAŞTIRMASI

İmalat süreçleri genellikle iki ana kategoriye ayrılır: talaşlı ve talaşsız üretim, her birinin ürün üretiminde önemli rolleri vardır. Talaşlı üretim uzun yıllardır kullanılmakta olup, etkisi günümüzde de artarak devam etmektedir. İşleme sırasında, takım ve iş parçası sürekli olarak temas halinde olduğundan, takım aşınır ve bu aşınma iş parçasının boyutlarında sürekli değişiklikler meydana getirir. Takımın aşınma miktarı düşük görünebilir, ancak hassas talaş kaldırma işlemlerinde, bu durum atık parça sayısının artmasına neden olabilir (Cook, 1973).

CNC makinelerinin kullanıldığı otomasyon sistemlerinde, esnek ve grup üretim hatlarında yaşanan sorunları çözmek için bilgi eksikliği olan operatörler sürekli olarak talaş kaldırma sürecini izlemek zorunda kalmaktadır. Bu durum, otomasyonun verimliliğine zarar verir ve operatör etkileşiminin sistemden çıkarılmasını gerektirir. Sonuç olarak, pahalı CNC makinelerinde maliyetli hasarlar meydana gelebilir (Salimiasl ve Rafighi, 2017).

Talaşlı imalat işlemlerinde, kesici takım üzerine gelen kuvvet, kesme işlemini en iyi şekilde açıklayan bir değişken olarak kabul edilmiştir (Dong ve ark., 2006, Ertekin ve ark., 2003). Kesme kuvvetindeki değişime ilişkin bilgiler, iş parçası yüzeyinin kalitesini, takım aşınmasını izlemek ve geometrik görünümünü değerlendirmek için kullanılır. Bu nedenle kesme kuvveti, takım durumunun izlenmesinde ve iş parçası boyutu doğruluğunun araştırılmasında güçlü bir teşhis veya tahmin aracı olarak tercih edilir (Benardos ve Vosniakos, 2002). Tüm kesme işlemlerinde talaşın malzemeden uzaklaştırılması sırasında kesme kuvvetinin oluşması esastır. Analitik modelleri kanıtlamak için araştırmacılar, işleme sırasında kesme kuvvetlerinin izlenmesi ve takım kırılmasının belirlenmesi için kapsamlı modeller sağlamıştır (Byrne ve ark., 2003). Tork transdüserleri mekanik bir yapının kuvvet gibi bir deformasyona verdiği tepkiden oluşur ancak tork transdüserlerinde uygulanan yük burulma şeklinde gerçekleşir. Her iki sensör için de kuvvet ölçüm teknolojisi aynıdır ancak tork sensörlerinin kullanımı ve döner takım tutuculardan sinyal aktarım yöntemleri farklı olabilir. Takım aşınması ile tork ve kesme kuvveti arasında önemli bir ilişki olduğu için araştırmacılar, takım aşınmasını izlerken kesme kuvveti ve torkun ölçülmesini önermişler.

1050 çelik malzemesi ile kaplamasız tungsten karbür (DNMG 150608) takım ucu kullanılmıştır. Çalışma kapsamında, 90-2500 dev/dk aralığında kesme hızları, 0,03-0,25 mm/dev aralığında ilerleme ve 0,5-2 mm aralığında talaş derinlikleri dikkate alınmıştır.

Kuru kesme koşullarında, kesme kuvvetlerinin sinyalleri bir dinamometre ile ölçülmüş ve 65 mm uzunluğunda bir kesme işlemi sırasında takım yanak aşınması değerlendirilmiştir. Takım aşınmasındaki değişikliklere karşılık kesme kuvvetindeki değişim incelenmiş ve kesme kuvveti-aşınma, zaman-aşınma grafiklerinin çıkarılması sağlanmıştır. Çalışma sonuçları, kesme kuvvetlerinin takım aşınmasını izlemek için daha uygun bir yöntem olduğunu göstermiş ve takım kırılmasının izlenmesinde kesme kuvvetlerinin dikkate alınmasının etkili olduğunu ortaya koymuştur. Elde edilen sonuçlar, kullanılan malzeme ve kesici uç için geçerli bulunmuş ve diğer malzemeler ve kesici uçlar için de kesme kuvvetlerinin ölçülmesi önerilmiştir (Cakir ve Işık, 2005).

Titreşim sinyalleri, takımın durumunu (takım aşınması, takım kırılması vb.) izlemek ve yüzey pürüzlülüğünü tahmin etmek için kullanılabilir (Bhuiyan ve ark, 2014). Takım aşınmasını izlemek için kesici takımın titreşim sinyalleri ölçülmüştür. Araştırmacılara göre kesici takım aşındıkça titreşim sinyallerinin genliği artar. Bu nedenle takım aşınması ile titreşim sinyali genlikleri arasında bir ilişki kurmak mümkündür (Scheffer ve ark., 2003).

İşleme operasyonlarının güvenilirliğini artırmak amacıyla takım yan aşınması izlenmiştir. Bu çalışmada, talaş kaldırma işlemleri için CNMG120408-HM kesici uçlar ve seramik-metal kesici uçlar kullanılmıştır. Sabit kesme hızı (200 m/min), sabit ilerleme (0,15 mm/rev) ve sabit talaş derinliği (2 mm) değerlerinde yapılan deneyde, titreşim algılayıcısı takım aşınmasının izlenmesinde kullanılmıştır. İşleme sırasında takım aşınmasıyla değişen kesici takım titreşimi genliğinin karekök ortalaması, takım durumunu değerlendirmek için ölçülmüştür. Bu yöntemin doğruluğunu test etmek amacıyla CNC torna tezgahında deneyler gerçekleştirilmiş ve oransal risk modeliyle elde edilen sonuçlar karşılaştırılmıştır. Sonuçlar, titreşim genliğinin takım aşınmasıyla arttığını göstermiştir. Çalışma, titreşim genliği kullanılarak takım aşınmasını izlemenin başarılı ve etkili bir yöntem olabileceğini öne sürmüştür (Ding ve He, 2011).

YSA; insan beyninin işleyişinin yapay bir benzetimi olarak geliştirilmiştir. YSA, belirli değerler temelinde, girdi alanındaki noktaları çıktı alanındaki eş noktalarla bir fonksiyon aracılığıyla ilişkilendirir (Teti ve ark., 2010). YSA, hem sürekli hem de ayırık verileri işleyebilirken, yüksek bir genelleştirme yeteneği gösterir. YSA, bir haritalama cihazı veya model ayırıcısı ve model bütünleştirici olarak işlev görebilir (Salimiasl ve Rafighi, 2017).

Tornalama işlemlerinde takım yanak aşınmasını izlemek amacıyla regresyon analizi ve YSA modelleri kullanılmıştır. Bu çalışmada, sabit bir kesici tipi (TPG322

COMPAX 1500), üç farklı kesme hızı (300, 500, 700 m/min), üç farklı ilerleme hızı (0,1; 0,2; 0,4 mm/rev) ve sabit bir talaş derinliği (0,5 mm) dikkate alınmıştır. Aşınmanın izlenmesi için kesme kuvvetleri ölçülmüş ve YSA sistemine aktarılmıştır. İlerleme ve kesme kuvvetleri, tahmin modeline giriş olarak verilmiş ve takım aşınmasını tahmin etmede ilerleme kuvvetlerinin esas kesme kuvvetlerinden daha etkili olduğu bulunmuştur. Çalışma sonucunda, kesme parametrelerinin ve kesme kuvvetlerinin takım aşınması üzerindeki etkileri grafiklerle gösterilmiştir. Talaş kaldırma sırasında, takım aşınması arttıkça kesme kuvvetlerinin de yükseldiği gözlemlenmiştir. Ayrıca, kesme hızının artması takım aşınmasını artırırken, ilerlemenin artması takım aşınmasını azalttığı bulunmuştur. Önerilen izleme prosedürü, kesme kuvvetleri kullanılarak aşınmanın izlenmesinin başarılı bir şekilde gerçekleştirildiğini göstermiştir (Lin ve ark., 2003).

Sertleşme eğiliminden dolayı paslanmaz çeliğin işlenmesi zordur. Kullanılan bu paslanmaz çeliklerin delinmesi işlemlerinde, takım aşınması ve yüzey pürüzlülüğü delme çubuğunun titreşiminden etkilenir. AISI 316 çeliğinin sementite karbür takım uçlarıyla delinmesinde takım aşınması, yüzey pürüzlülüğü ve iş parçasının titreşimi incelenmiştir. İş parçası titreşiminin çevrimiçi veri toplaması için bir Lazer Doppler Vibrometresi ve işlemek için yüksek hızlı bir FFT emisyon sinyallerini işlemek için yüksek hızlı bir FFT analizörü kullanılmıştır. Deneysel veriler bir araya getirilmiş ve YSA tekniklerine aktarılmıştır. Uç yarıçapı, kesme hızı, ilerleme ve kaldırılan malzeme hacmi girdi parametreleri kullanılarak geri yayılım algoritmasına sahip çok katmanlı bir sensör modeli kullanılmıştır. Yüzey pürüzlülüğünü, takım aşınmasını ve iş parçası titreşim genliğini tahmin etmek için bir YSA kullanılmıştır. Tahmin edilen değerler toplanan deneysel verilerle karşılaştırılmış ve hata hesaplanmıştır. Bu çalışmada önerilen deney tasarımına göre sekiz adet iki aşamalı deney gerçekleştirilmiştir. Her deneysel testte bağımlı ve bağımsız değişkenler arasında güçlü bir korelasyon bulunmuştur. Toplanan deneysel veriler bir YSA ile eğitilmiştir. Bu deneyler 15 örnekle doğrulanmış ve 8 örnekle test edilmiştir. Deneysel veriler ile yüzey pürüzlülüğü (%4,5185 hata), iş parçası titreşimi (%4,2568 hata) ve takım aşınması (%2,9237 hata) için öngörülen değerler arasında uyum olduğu bulunmuştur. Bu parametreler için sinir ağları uygun kesimin seçiminde yardımcı olabilir. Ayrıca takım titreşimini, takım aşınmasını ve yüzey pürüzlülüğünü öngörebilir. (Rao ve ark., 2014)

YSA'lar biyolojik sinir ağlarından ilham alan bir model ailesidir. Bir YSA üç tür parametreyle tanımlanır: (1) farklı nöron katmanları arasındaki bağlantı modeli, (2) bağlantı ağırlıklarının güncellenmesinin öğrenme süreci ve (3) nöronun ağırlıklı girdisini

çıktı aktivasyonuna dönüştüren aktivasyon fonksiyonu. Birçok YSA türü arasında ileri beslemeli sinir ağı ilk ve en popüler YSA'dır. Geri yayılım, YSA eğitimi için gradyan iniş gibi bir optimizasyon yöntemiyle birleştirilmiş bir öğrenme algoritmasıdır. Takım aşınma oranı genellikle işlem parametrelerinden (örneğin, kesme ve ilerleme hızı), kesici takım geometrisinden, işleme parçası ve takım malzemelerinin özelliklerinden etkilenir. Taylor denklemi takım ömrü beklentisi için takım aşınmasının bir yaklaşımını sağlar (Taylor, 1906). Bununla birlikte, algılama teknolojisindeki hızlı ilerlemeler ve modern CNC makinelerinde bulunan sensörlerin sayısının artmasıyla birlikte, çeşitli ölçülen veriler kullanılarak takım aşınmasının daha doğru bir şekilde tahmin edilmesi mümkün olmaktadır.

Yapılan bir deney, takım yan aşınmasının ilerlemesini izlemek için bir kuvvet sensörü ve takım aşınmasını tahmin etmek için bir yöntem olarak makine öğrenimi, daha spesifik olarak bir CNN kullanan bir işlem için takım aşınması tahmin sistemini sunmaktadır. Önerilen yöntem, bir test işlemi olarak frezeleme kullanılarak deneysel olarak gösterilmiştir. Kaplamasız bilyalı uc freze ve paslanmaz çelik iş parçalarıyla kuru işleme kullanılarak deneyler yapılmıştır. Yanak aşınması dijital bir mikroskop kullanılarak yerinde ölçülmüştür. ML modelinin tahminleri, önceki deneylerden elde edilen tüm verileri içeren bir deneyim veritabanına dayanmaktadır. Önerilen proses için takım aşınma tahmin sistemi, yan aşınma optimizasyonuna ve takım ömrünün uzatılmasına olanak tanıyan en iyi ilerleme hızını ve iş mili hızı ayarını bulmak için ML modeliyle sürekli iletişim kurarak uyarlanabilir bir kontrol sistemi tarafından yönlendirilmektedir. ML modelinin sağladığı tahminlere ve flanş aşınmasının ilerlemesinin bir fonksiyonu olarak kesme kuvvetlerindeki değişimi yakalayan kuvvet sensöründen sağlanan bilgilendirici geri bildirim dayandır. Bu çalışmada, yalnızca CNN'lere dayalı takım aşınmasının tahmini için ML model bileşeni gösterilmiştir. Burada açıklanan işleme kurulumuyla bu veri seti altı adet 6 mm küresel uçlu tungsten karbür kesiciden gelen kesme kuvveti x , y ve z boyutlarında titreşim ve akustik emisyon verilerini inceleyen yedi sinyal kanalından oluşmuştur. Bu değişkenler CNN'yi eğitmek için PHM veri setinden seçilmiştir. Bu aşamadaki amaç, üç boyutta ölçülen mevcut kuvvetler göz önüne alındığında, kesici takımın durumunun belirlenebileceği öğrenme modülünün kavram kanıtını yapmaktır. Ölçümler, PHM veri setindeki kesicilerden yalnızca birine göre yapılmış ve çıkarılan her katmanın mm cinsinden ölçülen aşınması kullanılarak veriler hızlı ilk aşınma, düzgün aşınma ve arıza olmak üzere

üç sınıfa ayrılmıştır. Bu kavram kanıtının genelliğini desteklemek için aşınma bölgeleri keyfi olarak tanımlanmıştır (Wang ve Oates, 2015).

Bu yöntem iki ana adımı gerçekleştirir. İlk olarak zaman serileri normalleştirilir ve kutupsal koordinat sistemine dönüştürülür. Daha sonra, farklı zaman aralıklarındaki zamansal korelasyonu belirlemek için her nokta arasındaki trigonometrik fark dikkate alınarak açısal perspektif kullanılır. Büyük zaman serileri için, zaman serilerinin boyutunu azaltmak ve trendleri korurken bunları düzeltmek için PAA (Parçalı Toplama Yaklaşımı) azaltma kullanılabilir. CNN, softmax regresyon yöntemi, 0,1 ve 0,01 öğrenme oranları ve 0,1 bozulma faktörü kullanılarak 1000 adım için eğitilmiştir. Önerilen bu metodolojinin doğruluk tahmini %90 olduğunu göstermiştir. Deneysel sonuçlar, CNN'nin kesme işlemi sırasında üretilen kuvvetler ile takım yan aşınması arasındaki mevcut ilişkiyi tanımlayabildiğini göstermektedir. Bu yöntem, eğitim süreci sırasında uygun verilerin mevcut olması koşuluyla herhangi bir iş parçası malzemesine veya kesici takıma uygulanabilir. Öğrenme bileşeninin iş parçası kombinasyonunun davranışı ve seçilen takım konusunda eğitilmesi gerekir. (Gouarir ve ark., 2018)

Bir tornalama deneyinde, parçacık kopması ve takım kırılması tespiti amacıyla S55C malzemesi ve HSS takım kullanılmıştır. Deneylerde AE (Akustik Emisyon) sensörü ile sinyal işleme FFT analizi kullanılarak gerçekleştirilmiş ve serbest yüzey aşınması ölçülmüştür. Parçacık kopması anında AE sinyali zirve yapar ve geliştirilen algoritma, sinyal belirlenen eşik değerini geçtiğinde kopmanın az veya çok oluşup oluşmadığını tespit edebilir. İki farklı kesme şartında yapılan testlerde, sistemin parçacık kopmasını %90 doğruluk oranıyla tespit edebildiği gözlemlenmiştir (Inasaki ve ark., 1987).

Aşınma tespiti üzerine yapılan başka bir çalışmada, deney sayısını ve hata payını azaltmak için farklı iş parçası malzemeleri kullanılmıştır. Çelik ve Al alaşımı iş parçası malzemeleri ile TiN (Titanyum Nitrür) kaplamalı beş farklı takım kullanılmıştır. Motor mil akımını ve titreşimi ölçerek serbest yüzey aşınması ile bu sensör sinyalleri arasında ilişki kuran bir YSA kurulmuştur. Deneyler torna tezgâhında yapılmış, titreşim sinyalleri SSA (Singular Spectrum Analysis) ile işlenmiş, akım sinyalleri ise YSA ile analiz edilmiştir. Başlangıçta 30 olan deney sayısı, 70 deneye çıkarılmış ve az bir değişim olduğu gözlemlenmiştir, bu da sistemin güvenilirliğini kanıtlamıştır (Salgado ve ark., 2013).

Ses analizi üzerine yapılan bir diğer çalışmada, çağrı merkezi çalışanları ile müşteriler arasındaki telefon konuşmalarının otomatik olarak olumlu veya olumsuz

olarak sınıflandırılması ele alınmıştır. Çalışmada, firma tarafından yapılan telefon görüşmelerinden oluşan bir veri seti kullanılmıştır. Veri seti, üçer saniyelik 10.411 ses kaydından oluşur; bu kayıtların 5.408'i olumlu, 5.003'ü ise hakaret, münakaşa ve öfke içeren olumsuz kayıtlardır. Çağrı merkezi konuşmalarından anlamlı öznitelikler elde etmek için MFCCs öznitelikleri çıkarılmıştır. Olumlu ve olumsuz kayıtları sınıflandırmak için önerilen CNN mimarisi MFCCs öznitelikleriyle eğitilmiştir. CNN modeli, %86,1 eğitim başarısı, %77,3 doğrulama başarısı göstermiş ve test verilerinde %69,4 sınıflandırma başarısı elde edilmiştir. Bu çalışma, çağrı merkezlerinde konuşmaların otomatik analizini yaparak olumsuz durumları kalite yöneticilerine bildirip, müşteri memnuniyetini artırmayı amaçlamaktadır (Karataş ve ark., 2023).



3. MATERYAL VE YÖNTEM

3.1. Kesici Takım Ucları

Bu deneyde DNMG150608-OMM P25-M25 sert metal karbür uc kullanılmıştır. Şekil 3.1’ de gösterilmiştir. Karbür uçlar, yüksek sıcaklıklara karşı dayanımlı, yüksek sertlikleri ve aşınmaya karşı dirençli oldukları için diğer uçlara göre daha dayanıklıdır. Bu nedenle metal, alaşım ve sert malzemelerin işlenmesinde kullanılır.



Şekil 3. 1. DNMG150608-OMM P25-M25 sert metal karbür uc

3.2. Çelik Malzemeler

Deneylerde Kullanılan 316L paslanmaz çeliğin özellikleri Tablo 3.1’de verilmiştir.

Tablo 3. 1. 316L paslanmaz çelik özellikleri

Terimi	Özellikleri
Malzeme adı:	316L paslanmaz çelik EN standartlarında 1.4404 kalite paslanmaz çelik olarak kodlanır
Kimyasal birleşim:	C: %0.030, Mn: %2.0, Si: %1.0, Cr: %16.0-%18.0 arası, P: %0.045, S: %0.03, Ni: %10-%14.0 arası, Mo: %2.0-%3.0 arası
Sertlik değeri:	Rockwell (HRB): 95
Kullanılan ölçüler:	Boy: 100 mm, En: 50 mm

Özellikleri verilen 316L paslanmaz çelik Şekil 3.2’de gösterilmiştir.



Şekil 3. 2. 316L Paslanmaz Çelik

1050 Çelik Malzeme;

- Orta Karbon İçeriği: 1050 imalat çeliği, %0.50 karbon içeriğine sahiptir. Bu orta karbon içeriği, çeliği sertleştirme ve yüksek mukavemet sağlama yetenekleri açısından avantajlı kılar.
- Yüksek Mukavemet: 1050 imalat çeliği, orta karbon içeriği nedeniyle diğer düşük karbonlu çeliklere göre daha yüksek mukavemete sahiptir. Bu özelliği, ağır yükler altında dayanıklılık sağlar ve parçaların deformasyon veya çatlamaya karşı dirençli olmasını sağlar.
- Sertlik: 1050 imalat çeliği, sert bir çelik türüdür. Bu özelliği, çeşitli işleme ve şekillendirme işlemlerine tabi tutulabilir ve son derece sert parçaların üretilmesine olanak tanır.
- İyi İşlenebilirlik: 1050 imalat çeliği, işlenmesi ve şekillendirilmesi kolay olan bir malzemedir. Bu özellik, çeşitli imalat işlemlerinde yüksek verimlilik ve kolaylık sağlar.
- Orta Düzeyde Mekanik Özellikler: 1050 imalat çeliği, orta düzeyde dayanıklılık, tokluk ve aşınma direncine sahiptir. Bu özellikler, genellikle orta yükseklikte uygulamalar için uygundur.

Özellikleri açıklanan 1050 Çelik Şekil 3.3'te gösterilmiştir.



Şekil 3. 3. 1050 Çelik Malzemesi

3.3. CNC Torna Tezgâhı

Yapılan deneylerde daha yüksek hassasiyet ve daha doğru sonuçlar elde etmek için CNC torna kullanılmıştır. Ayrıca kaydedilen ses kayıtlarının fazla olmasından dolayı deneyler zaman kaybı yaşanmaması için CNC torna ile yapılmıştır. Kullanılan CNC torna modeli ECOCA SL-8P Şekil 3.4’de gösterilmiştir.



Şekil 3. 4. CNC Torna Tezgâhı

3.4. Talaş Derinliği, Devir ve İlerleme

Talaş kaldırma işlemleri için bu çalışmada DNMG150608-OMM P25-M25 kesici uçlar kullanılmıştır. Deney 1-154 için, sabit kesme hızı (1200 m/dk), sabit ilerleme (0,15 mm/dev) ve sabit talaş derinliği (2 mm) ile talaş kaldırma işlemi yapılmış, deney 155-205 için ise sabit kesme hızı (1600 m/dk), sabit ilerleme (0,25 mm/dev) ve sabit talaş derinliği (1.2 mm) ile talaş kaldırma işlemi yapılmıştır.

3.5. Ses Kayıt ve Görüntü alma

Deneyde yapılan işleme sırasında sesleri kaydetmek için kullanılan ses kayıt cihazı Şekil 3.5’de ve ses kayıt cihazının özellikleri Tablo 3.2’de gösterilmiştir.



Şekil 3. 5. Ses Kayıt Cihazı

Tablo 3. 2. Ses dinlemesi yapılan cihaz bilgileri

Parça adı	Özellği
Marka	Ses kayıt cihazı
Formatı	Li kayıt (HQ) WAV 1536 kbps, (SP) mp3 kbps
Frekans tepkisi	20Hz-20KHz
Cihaz depolama alanı	16 GB
Cihaz boyutu	98*33*12 mm


Görüntü almak için Şekil 3.6’da gösterilen aparat kullanılmıştır. Görüntü alma aparatının özellikleri Tablo 3.3’te gösterilmiştir. Bu aparatla alınan görüntüler Şekil 3.7’de takım durumu için aşınmamış, az aşınmış, aşınmış ve çok aşınmış olarak kesici takımlar gösterilmiştir.



Şekil 3. 6. Görüntü Alma Aparatı

Tablo 3. 3. Görüntü alma aparatı ölçüleri

Ebat	Ölçüleri
Toplam yükseklik	118 mm
Alt taban ölçüleri	220*200 mm
Üst taban ölçüleri	120*100 mm
Görüntü alınan yükseklik	100 mm
Malzeme	Beyaz MDF Lam



Şekil 3. 7. Görüntü alma aparatıyla alınan takım durumu görüntüleri


3.6. Seslerin Ayıklanması

Bu çalışmada toplam 205 adet deney yapılmış ve bu deneylerin 66 tanesi 316L paslanmaz çelik ile 139 tanesi 1050 çelik ile yapılmıştır. 316L paslanmaz çelik için alınan 66 adet deney ses kayıtları 1828 ayrı ses verisi olarak ayrılmış ve bu sesler 176 adet aşınmamış, 598 adet az aşınmış, 428 adet aşınmış ve 626 adet çok aşınmış olarak ayıklanmıştır. 1050 çelik için toplam 139 ses kaydı 3366 ses kaydı olarak ayrılmış ve bu sesler 884 adet aşınmamış, 728 adet az aşınmış, 893 adet aşınmış ve 861 adet çok aşınmış olarak ayıklanmıştır. Yapılan bu deneyler 26 Haziran 2023 – 25 Kasım 2023 tarihleri arasında yapılmıştır. Bu seslerin %80'i eğitim verisi ve %20'si test verisi olarak seçilmiştir. Tablo 3.4'te ayıklanan sesler gösterilmiştir.

Tablo 3. 4. Ayıklanmış ses kayıtları

Takım durumu	316L paslanmaz Çelik için	1050 çelik için
0- aşınmamış	176 adet ses	884 adet ses
1- az aşınmış	598 adet ses	728 adet ses
2- aşınmış	428 adet ses	893 adet ses
3- çok aşınmış	626 adet ses	861 adet ses


Bu çalışmada ses kayıtlarını ayıklamak için Şekil 3.8'de gösterilen Audacity programı kullanılmıştır.



Şekil 3. 8. Audacity programı ile seslerin ayıklanması

3.7. Seslerin Analizi ve Öznitelik Çıkartma

Bu çalışmada kesici takım seslerinin özelliklerini çıkarmak için Phyton veri tabanlı Librosa kütüphanesinden faydalanılmıştır. Kesici takım seslerinin özniteliklerini elde etmek için genlik-zaman, mel-spectrogram, MFCC'ler ZRC'ler ve RMS enerji gibi özellik çıkartma yöntemleri kullanılmıştır. Ses kaydından öznitelik çıkartma yöntemi Şekil 3.9' da gösterilmiştir. Her bir ses için özniteliklerin çıkartılması işlemlerinde 18 adet özelliklerden oluşan veri seti oluşturulmuştur.




Şekil 3. 9. Ses kaydından öznitelik çıkartma yöntemi

Sınıflandırma sonucunun ve algoritma performansını belirlemede çeşitli varsayımlar kullanılmaktadır (Masetic ve Subasi, 2016). Sınıflandırıcı algoritmasının kalitesinin belirlenmesi için; doğruluk, kesinlik, duyarlılık, özgüllük, ve F-ölçüsü kriterleri ele alınmıştır. Bu kriterler; TP (doğru pozitif), FP (yanlış pozitif), TN (doğru negatif) ve FN (yanlış negatif) tahmin değerleri kullanılarak değerlendirilme

yapılmaktadır (Ozcift ve Gulten, 2011). AUC (Eğri altındaki alan) ise ROC (Alıcı işletim karakteristiği) eğrisi altında kalan bölgenin alanı olarak hesaplanmaktadır.

- TP, aşınmış olarak etiketlenen kesici takımın gerçekte aşınmış olması,
- FP, aşınmamış olarak etiketlenen kesici takımın aşınmış olarak belirlenmesi,
- TN, aşınmamış olan kesici takımın gerçekte aşınmamış olması,
- FN, aşınmış olan takımın aşınmamış olarak etiketlenmesi anlamlarına gelir.

Sınıflandırma işlemlerinde tahmin edilmesi gereken değerleri göstermek için Şekil 3.10'da yer alan Karmaşıklık Matrisi (Confusion Matrix) tablosu kullanılmaktadır. Bu matris, bir sınıflandırma sistemi tarafından gerçekleştirilen gerçek ve tahmin edilen sınıflamaları içerir. Sınıflandırma performansı, matristeki veriler aracılığıyla değerlendirilir (Mursalin ve ark., 2017).



		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3. 10. Tahminler için karmaşıklık matrisi

Duyarlılık kriteri, gerçekten aşınmış olan örneklerin kaç tanesinin pozitif olarak tahmin edildiğini göstermektedir.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (3.1)$$

Sınıflandırıcının aşınmamış örnekleri tahmin etmedeki etkinliği özgüllük kriteri ile saptanmaktadır.

$$\text{Özgüllük} = TN / (TN + FP) \quad (3.2)$$

Kesinlik kriteri ile aşınmış olarak tahmin edilen örneklerden gerçekten kaç tanesinin pozitif olduğu saptanmaktadır.

$$\text{Kesinlik} = TP / (TP + FP) \quad (3.3)$$

Doğruluk bir modelin başarısını vermektedir. Doğru tahminlerin tüm verilere oranlanması ile bulunmaktadır.

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (3.4)$$

F1 skoru (F1_score), kesinlik ve duyarlılık değerlendirme ölçülerinin harmonik ortalamasını vermektedir.

$$F1 = 2 * (\text{kesinlik} * \text{duyarlılık}) / (\text{kesinlik} + \text{duyarlılık}) \quad (3.5)$$

$$AUC = (\text{kesinlik} * \text{duyarlılık}) / 2 \quad (3.6)$$

3.8. Derin Öğrenme ile Sınıflandırma

Bu çalışmada CNC Torna ile işlenen 316L paslanmaz çelik ve 1050 çelik malzemesinin işlenmesinde kullanılan kesici takım aşınma seslerinin DL yöntemi ile sınıflandırılması için 1D CNN ve 2D CNN kullanılmıştır.

3.8.1 1D CNN modeli

Ses gibi tek boyutlu veri modelleme ve eğitiminde daha az parametre ile kullanılan 1D CNN modeli, evrişim katmanları, havuzlama ve veri küçültme adımlarından oluşmaktadır. Bu çalışmada, her bir ses sinyaline ait 15 özellikten oluşan bir ses veri dizisi kullanılmıştır. Evrişim katmanında 3x1 boyutunda üç filtre kullanılmıştır. Evrişim katmanlarında sırasıyla 16, 32, 64 ve 128 filtre kullanılmıştır.

3.8.2. 2D CNN modeli

Bu çalışmada, librosa kütüphanesi kullanılarak dört sınıf ses dosyası yüklenmiş ve işlenmiştir. Kütüphanedeki ses sinyallerinden oluşturulan MFCCs görüntülerinden 15 özellik haritası üretilmiştir. MFCCs görüntüleri 2D CNN mimarisi için giriş verisi olarak kullanılmıştır. Daha sonra verilerin %20'si test seti olarak belirlenirken kalan %80'lik kısım eğitim setini oluşturmuştur. Ses dosyaları Conv. 2D ve Maxpooling 2D katmanlarından oluşan bir CNN modelinde işlenerek sınıflandırılmıştır. Ayrıca aktivasyon fonksiyonu olarak Relu ve dolgu için 'same' seçilmiştir. Bu 2D CNN modelinde, evrimsel süreç için tek bir adımda 16x3x3 filtreler ve 2x2 maksimum havuzlama işlemleri kullanılmıştır. Diğer adımlarda ise sırasıyla 32, 64 ve 128 filtre ve havuzlama yapıldıktan sonra veriler tam katmanlı bağlantı işlemine tabi tutularak 128 sinir ağından oluşan bir sinir ağından geçirilmiştir. Sınıflandırma Softmax fonksiyonu kullanılarak gerçekleştirilmiştir.

3.9. Makine Öğrenmesi ile Sınıflandırma

Bu çalışmada CNC Torna ile işlenen 316L paslanmaz çelik ve 1050 çelik malzemesinin işlenmesinde kullanılan kesici takım aşınma seslerinin ML yöntemi ile sınıflandırılması için SVM, KNN, RF ve topluluk öğrenme modelleri kullanılmıştır.

3.9.1. SVM modeli

Denetimli öğrenme kategorisinde kabul edilen SVM modeli, kümeleme algoritmalarından farklıdır. Aykırı değer sınıflandırma, tahmin ve tespit gibi teknikler arasında en etkili yöntemlerden biridir. SVM, veri setlerinin sınıflandırılmasında iki eğitim ve bir test sürecinden geçer. Bu çalışmada kernel olarak “linear” seçilmiştir.

3.9.2. KNN modeli

Bu model hem sınıflandırma hem de regresyon tahmin analizlerinde kullanılabilen basit ama etkili bir parametrik olmayan denetimli makine öğrenme algoritmasıdır. Sınıflandırılacak veri için k en yakın komşu alınarak bu verinin bir komşuluğu oluşturulur. Bu çalışmada k komşu sayısı 3 olarak seçilmiştir.

3.9.3. Topluluk öğrenme modeli

Topluluk öğrenme yöntemleri, birçok makine öğrenmesi probleminde en gelişmiş çözümleri temsil etmektedir. Birden fazla modeli eğiterek tahminleri birleştiren ve tek bir model gibi çalışan sınıflandırma ve tahmin modellerini oluşturmaktadır. Bu çalışmada sınıflandırma için RF, KNN ve SVM birlikte kullanılmıştır. Bir araya getirilen yeni örnekler ile farklı bir yol oluşturulmuştur. Bu tekrarlama ile örnekler arttırılmış ve buna göre tahminler yapılmıştır.

3.9.4. RF modeli


RF Sınıflandırıcısı, birçok karar ağacının birleşmesiyle oluşur ve bu ağaçlar arasında doğruluk performansı en yüksek olanlar seçilir. Her bir ağaç, veri setindeki özelliklere göre dallanır (Veranyurt ve ark., 2020). Bu yöntem, birden fazla sınıflandırıcı üreten ve bu sınıflandırıcılardan elde edilen oylar ile yeni verileri sınıflandıran bir öğrenme algoritmasıdır (Bilgin, 2017). Dallanma karar noktalarına bağlı olarak belirlenir (Breiman, 2001). Karar ağaçlarının küçük veri setlerinde aşırı uyum sorunu yaşadığı bilinir. RF, analiz edilen örneklem boyutu ile alt örnek boyutunun eşit olduğu, doğruluk performansını artırmak ve aşırı uyumu önlemek için ortalama kullanarak çalışan bir meta tahmin sınıflandırıcısıdır.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA


4.1. 316L Paslanmaz Çelik İçin Takım Aşınması Eğitim Sonuçları ve Tahminler

4.1.1. 1D CNN modeli sonuçları

Derin öğrenme yöntemlerinden olan 1D CNN modeli ile 316L paslanmaz çelik takım aşınması ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir. 1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.1’de verilmiştir.



Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. döngüden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. 316L çelik takım aşınması ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCCs görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. 316L çelik için takım aşınması ses kayıtları çalışmasındaki aşınmamış, yarı aşınmış, aşınmış ve çok aşınmış ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.2’de verilmiştir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 0 (aşınmamış), 1 (az aşınmış), 2 (aşınmış) ve 3 (çok aşınmış) olarak sınıflandırılmıştır.




Şekil 4. 2. 1D CNN modeli ROC eğrisi ve karmaşıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 27 test verisinin 27'si doğru tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 121 ses verisinden 117 sesi (1) olarak doğru tahmin ederken, 1 sesi (0), 2 sesi (2) ve 1 sesi (3) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 76 veriden 73 sesi (2) olarak doğru tahmin ederken, 0 sesi (0), 1 sesi (1) ve 2 sesi (3) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 142 ses verisinden 142 tanesi (3) olarak doğru tahmin edilmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %100, (1) için %96,69, (2) için %96,05 ve (3) için %100 olarak hesaplanmıştır.


4.1.2. 2D CNN modeli sonuçları

2D CNN modeli ile 316L paslanmaz çelik için takım aşınması ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.3'te gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 10. döngüden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4. 3. 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler


316L paslanmaz çelik için takım aşınması ses kaydı çalışmalarındaki 0,1, 2 ve 3 ses etiketlerine ait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.4'te gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 27 test verisinin 27'si doğru tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 121 ses verisinden 115 sesi (1) olarak doğru tahmin ederken, 3 sesi (0), 2 sesi (2) ve 1 sesi (3) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 76 veriden 73 sesi (2) olarak doğru tahmin ederken, 3 sesi (3) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 142 ses verisinden 139 tanesini (3) olarak doğru tahmin ederken 3 sesi (2) olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %100, (1) için %95, (2) için %96,05 ve (3) için %97,88 olarak hesaplanmıştır.



Şekil 4. 4. 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi


4.1.3. KNN modeli sonuçları

Makine öğrenmesi modellerinden biri olan KNN modeli ile 316L çelik için takım aşınması ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.5'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı arttıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4. 5. KNN modeli öğrenme eğrisi ve ROC eğrisi


316L paslanmaz çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.6'da gösterilmiştir. KNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 27 test verisinin 27'si doğru tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 121 ses verisinden 108 sesi (1) olarak doğru tahmin ederken, 10 sesi (0) ve 3 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 76 veriden 76 sesi (2) olarak doğru tahmin etmiştir. (3) olarak tanımlanan modelin 142 ses verisinden 134 tanesini (3) olarak doğru tahmin ederken 4 sesi (0) ve 4 sesi (1) olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %100, (1) için %89,25, (2) için %100 ve (3) için %94,36 olarak hesaplanmıştır.



Şekil 4. 6. KNN modeli karışıklık matrisi

4.1.4. SVM modeli sonuçları

Makine öğrenmesi modellerinden biri olan SVM modeli ile 316L çelik için takım aşınması ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.7'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı arttıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4. 7. SVM modeli öğrenme eğrisi ve ROC eğrisi

316L paslanmaz çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.8'da gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 27 test verisinin 25'i (0) olarak doğru tahmin edildiğini 2 sesi (1) olarak yanlış tahmin edildiğini

göstermektedir. (1) olarak tanımlanan modelin 121 ses verisinden 102 sesi (1) olarak doğru tahmin ederken, 6 sesi (0), 5 sesi (2) ve 8 sesi (3) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 76 veriden 76 sesi (2) olarak doğru tahmin etmiştir. (3) olarak tanımlanan modelin 142 ses verisinden 128 tanesini (3) olarak doğru tahmin ederken 2 sesi (0) ve 12 sesi (1) olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %92,6, (1) için %84,3, (2) için %100 ve (3) için %90,14 olarak hesaplanmıştır.


SVM-Karmaşıklık matrisi

Gerçek sınıflar	0	1	2	3
0	25	2	0	0
1	6	102	5	8
2	0	0	76	0
3	2	12	0	128
Tahmin edilen sınıflar	0	1	2	3

Şekil 4. 8. SVM modeli karmaşıklık matrisi


4.1.5. Topluluk öğrenme modeli sonuçları

Makine öğrenmesi modellerinden topluluk öğrenme modelinde RF, SVM ve KNN öodelleri birlikte kullanılarak sonuçlar elde edilmiştir. Topluluk modeli ile 316L paslanmaz çelik için takım aşınması ses analizi öz niteliklerinin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.9'da verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça RF modeli için başarı ve skor oranlarının çok değişmediği, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4. 9. Topluluk modeli için öğrenme eğrisi ve ROC eğrisi

316L paslanmaz çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.8’da gösterilmiştir. Topluluk modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 27 test verisinin 27’si (0) olarak doğru tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 121 ses verisinden 114 sesi (1) olarak doğru tahmin ederken, 3 sesi (0) ve 4 sesi (3) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 76 veriden 76 sesi (2) olarak doğru tahmin etmiştir. (3) olarak tanımlanan modelin 142 ses verisinden 138 tanesini (3) olarak doğru tahmin ederken 1 sesi (0) ve 3 sesi (1) olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %100, (1) için %94,21, (2) için %100 ve (3) için %97,18 olarak hesaplanmıştır.



Şekil 4. 10. Topluluk modeli karışıklık matrisi

Takım aşınması sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Takım aşınması için yapılan 5 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi 1D CNN modeli ile elde edilmiştir. Tablo 4.1’de verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarı 1D CNN modelinde %98,08 ve en düşük başarı ise SVM modelinde %90,43 olarak elde edilmiştir.

Tablo 4. 1. Takım aşınması sınıflandırma metrik sonuçları

Model	Sınıflandırma	Doğruluk (%)	Hassasiyet (%)	Geri çağırma (%)	F1 skoru (%)	Numune sayısı
1D CNN	Aşınmamış		96	100	98	27
	Az aşınmış	98,08	99	97	98	121
	Aşınmış		97	96	97	76
	Çok aşınmış		98	100	99	142
2D CNN	Aşınmamış		90	100	95	27
	Az aşınmış	96,72	100	95	97	121
	Aşınmış		94	96	95	76
	Çok aşınmış		97	98	98	142
KNN	Aşınmamış		66	100	79	27
	Az aşınmış	94,26	96	89	93	121
	Aşınmış		96	100	98	76
	Çok aşınmış		100	94	97	142
SVM	Aşınmamış		76	93	83	27
	Az aşınmış	90,43	88	84	86	121
	Aşınmış		94	100	97	76
	Çok aşınmış		94	90	92	142
Topluluk öğrenme	Aşınmamış		87	100	93	27
	Az aşınmış	96,99	97	94	96	121
	Aşınmış		100	100	100	76
	Çok aşınmış		97	97	97	142

Sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Tablo 4.2’de gösterilmiştir. Bu tabloda yapılan tahminlere göre en iyi sonucu 1D CNN modeli vermektedir. En düşük sonuçların ise SVM modelinde olduğu görülmektedir.

Tablo 4. 2. Takım aşınması sınıflandırmada doğru yanlış tahminler


Model	Sınıflandırma	Doğru tahmin	Yanlış tahmin
1D CNN	Aşınmamış	27	0
	Az aşınmış	117	4
	Aşınmış	73	3
	Çok aşınmış	142	0
2D CNN	Aşınmamış	27	0
	Az aşınmış	115	6
	Aşınmış	73	3
	Çok aşınmış	139	3
KNN	Aşınmamış	27	0
	Az aşınmış	108	13
	Aşınmış	76	0
	Çok aşınmış	134	8
SVM	Aşınmamış	25	2
	Az aşınmış	102	19
	Aşınmış	76	0
	Çok aşınmış	128	14
Topluluk öğrenme	Aşınmamış	27	0
	Az aşınmış	114	7
	Aşınmış	76	0
	Çok aşınmış	138	4

Takım aşınmasının eğitim test verileri doğruluk oranı sonuçları 1D CNN modelinde %98,08, 2D CNN modelinde %96,7 KNN modelinde %94,26, SVM modelinde %90,43 ve ensemble öğrenme modelinde %97 olarak hesaplanmıştır. Eğitim test sonucunda en iyi değeri 1D CNN modelinin verdiğini görüyoruz. En düşük değeri ise SVM modeli vermiştir.

4.2. 1050 Çelik İçin Takım Aşınması Eğitim Sonuçları ve Tahminler


4.2.1. 1D CNN modeli sonuçları

Derin öğrenme yöntemlerinden olan 1D CNN modeli ile 1050 çelik takım aşınması ses kaydı 50 döngü (epoch) kullanılarak eğitilmiştir. 1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.11'de verilmiştir.



Şekil 4. 11. Her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

Bu grafiklerde gösterilen sonuçlar incelendiğinde, 10. döngüden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. 1050 çelik takım aşınması ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. 316L çelik için takım aşınması ses kayıtları çalışmasındaki aşınmamış, az aşınmış, aşınmış ve çok aşınmış ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.12'de verilmiştir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 0 (aşınmamış), 1 (az aşınmış), 2 (aşınmış) ve 3 (çok aşınmış) olarak sınıflandırılmıştır.




Şekil 4. 12. 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 172'si doğru tahmin edilirken 18 sesi (1), 7 sesi (2) ve 2 sesi (3) olarak yanlış tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses verisinden 109 sesi (1) olarak doğru tahmin ederken, 15 sesi (0) ve 13 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 150 sesi (2) olarak doğru tahmin ederken, 16 sesi (0) ve 1 sesi (2) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 171 tanesi (3) olarak doğru tahmin edilmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %86,43, (1) için %80, (2) için %90 ve (3) için %100 olarak hesaplanmıştır.

4.2.2. 2D CNN modeli sonuçları


2D CNN modeli ile 1050 çelik için takım aşınması ses kaydı 50 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.13'te gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 10. döngüden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. 1050 çelik için takım aşınması ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4. 13. 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

1050 çelik için takım aşınması ses kaydı çalışmalarındaki 0,1, 2 ve 3 ses etiketlerine ait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.14'te gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 179'u doğru tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses verisinden 115 sesi (1) olarak doğru tahmin ederken, 13 sesi (0) ve 9 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 150 sesi (2) olarak doğru tahmin ederken, 16 sesi (0) ve 1 sesi (1) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 171 tanesini (3) olarak doğru tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %90,


(1) için %84, (2) için %90 ve (3) için %100 olarak hesaplanmıştır.



Şekil 4. 14. 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi


4.1.3. KNN modeli sonuçları

Makine öğrenmesi modellerinden biri olan KNN modeli ile 1050 için takım aşınması ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.15'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4.15. KNN modeli öğrenme eğrisi ve ROC eğrisi


1050 çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.16'da gösterilmiştir. KNN modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 161'i doğru tahmin edildiğini 20 sesi (1), 16 sesi (2) ve 2 sesi (3) olarak yanlış tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses verisinden 118 sesi (1) olarak doğru tahmin ederken, 8 sesi (0) ve 11 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 154 sesi (2) olarak doğru tahmin ederken 8 sesi (0), ve 3 sesi (1) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 171 tanesini (3) olarak doğru tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %81, (1) için %86, (2) için %92,2 ve (3) için %100 olarak hesaplanmıştır.



Şekil 4. 16. KNN modeli karışıklık matrisi

4.1.4. SVM modeli sonuçları

Makine öğrenmesi modellerinden biri olan SVM modeli ile 1050 çelik için takım aşınması ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.17’de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı başarı ve skor oranlarının çok değışmediğı görölmektedir.



Şekil 4. 17. SVM modeli öğrenme eğrisi ve ROC eğrisi

1050 çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.18’de gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 172’si (0) olarak doğru tahmin edildiğini 22 sesi (1), 1 sesi (2) ve 4 sesi (3) olarak yanlış

tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses verisinden 113 sesi (1) olarak doğru tahmin ederken, 24 sesi (2), olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 119 sesi (2) olarak doğru tahmin ederken 32 sesi(0), 5 sesi (1) ve 11 sesi (3) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 164 tanesini (3) olarak doğru tahmin ederken 4 sesi (1) ve 3 sesi (2) olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %86,4, (1) için %82,4, (2) için %71,2 ve (3) için %96 olarak hesaplanmıştır.


SVM-Karmaşıklık matrisi

Gerçek sınıflar	0	1	2	3
0	172	22	1	4
1	0	113	24	0
2	32	5	119	11
3	0	4	3	164
	0	1	2	3
	Tahmin edilen sınıflar			

Şekil 4. 18. SVM modeli karışıklık matrisi


4.1.5. RF modeli sonuçları

Makine öğrenmesi modellerinden biri olan RF modeli ile 1050 çelik için takım aşınması ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. RF modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi Şekil 4.19'da verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4. 19. RF modeli öğrenme eğrisi


1050 çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.20’de gösterilmiştir. RF modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 176’sı (0) olarak doğru tahmin edildiğini 16 sesi (1), 4 sesi (2) ve 3 sesi (3) olarak yanlış tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses verisinden 120 sesi (1) olarak doğru tahmin ederken, 10 sesi (0) ve 7 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 155 sesi (2) olarak doğru tahmin ederken 12 sesi (0) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 171 tanesini (3) olarak doğru tahmin ederken etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %88,4, (1) için %87,6, (2) için %92,8 ve (3) için %100 olarak hesaplanmıştır.



Şekil 4. 20. RF modeli karışıklık matrisi

4.1.6. Topluluk öğrenme modeli sonuçları


Makine öğrenmesi modellerinden topluluk öğrenme modelinde RF, SVM ve KNN öodelleri birlikte kullanılarak sonuçlar elde edilmiştir. Topluluk modeli ile 1050 çelik için takım aşınması ses analizi özneteliklerinin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim, doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.21’de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznetelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça RF modeli için başarı ve skor oranlarının çok değışmediği, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4. 21. Topluluk modeli öğrenme eğrisi ve ROC eğrisi

1050 çelik için takım aşınması ses kaydı çalışmalarındaki 0, 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.22’de gösterilmiştir. Topluluk modelinin tahmin matrisi incelendiğinde, (0) olarak tanımlanan 199 test verisinin 172’si (0) olarak doğru tahmin edildiğini 19 sesi (1), 5 sesi (2) ve 3 sesi (3) olarak yanlış tahmin edildiğini göstermektedir. (1) olarak tanımlanan modelin 137 ses

verisinden 113 sesi (1) olarak doğru tahmin ederken, 10 sesi (0) ve 14 sesi (2) olarak yanlış tahmin etmiştir. (2) olarak tanımlanan 167 veriden 153 sesi (2) olarak doğru tahmin edildiğini 13 sesi (0) ve 1 sesi (1) olarak yanlış tahmin etmiştir. (3) olarak tanımlanan modelin 171 ses verisinden 171 tanesini (3) olarak doğru tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi (0) için %86,4, (1) için %82,5, (2) için %91,6 ve (3) için %100 olarak hesaplanmıştır.



Şekil 4. 22. Topluluk modeli karışıklık matrisi

Takım aşınması sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Takım aşınması için yapılan 6 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi RF modeli ile elde edilmiştir. Tablo 4.3’de verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarı RF modelinde %92,28 ve en düşük başarı ise SVM modelinde %84,27 olarak elde edilmiştir.

Tablo 4. 3. Takım aşınması sınıflandırma metrik sonuçları

Model	Sınıflandırma	Doğruluk (%)	Hassasiyet (%)	Geri çağırma (%)	F1 skoru (%)	Numune sayısı
1D CNN	Aşınmamış	89,32	85	86	86	199
	Az aşınmış		85	80	82	137
	Aşınmış		88	90	89	167
	Çok aşınmış		99	100	99	171
2D CNN	Aşınmamış	91,24	86	90	88	199
	Az aşınmış		88	84	86	137
	Aşınmış		91	90	91	167
	Çok aşınmış		99	100	100	171
KNN	Aşınmamış	89,6	90	81	85	199
	Az aşınmış		84	86	85	137
	Aşınmış		85	92	89	167
	Çok aşınmış		99	100	99	171
SVM	Aşınmamış	84,27	84	86	85	199
	Az aşınmış		78	82	80	137
	Aşınmış		81	71	76	167
	Çok aşınmış		92	96	94	171
RF	Aşınmamış	92,28	89	88	89	199
	Az aşınmış		88	88	88	137
	Aşınmış		93	93	93	167
	Çok aşınmış		98	100	99	171
Topluluk öğrenme	Aşınmamış	90.35	88	86	87	199
	Az aşınmış		85	82	84	137
	Aşınmış		89	92	90	167
	Çok aşınmış		98	100	99	171

Sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Tablo 4.4’de gösterilmiştir. Bu tabloda yapılan tahminlere göre en iyi sonucu RF modeli vermektedir. En düşük sonuçların ise SVM modelinde olduğunu görüyoruz.

Tablo 4. 4. Takım aşınması sınıflandırmada doğru yanlış tahminler

Model	Sınıflandırma	Doğru tahmin	Yanlış tahmin
1D CNN	Aşınmamış	172	27
	Az aşınmış	109	28
	Aşınmış	150	17
	Çok aşınmış	171	0
2D CNN	Aşınmamış	179	20
	Az aşınmış	115	22
	Aşınmış	150	17
	Çok aşınmış	171	0
KNN	Aşınmamış	161	38
	Az aşınmış	118	19
	Aşınmış	154	13
	Çok aşınmış	171	0
SVM	Aşınmamış	172	27
	Az aşınmış	113	24
	Aşınmış	119	48
	Çok aşınmış	164	7
RF	Aşınmamış	176	23
	Az aşınmış	120	17
	Aşınmış	155	12
	Çok aşınmış	171	0
Topluluk öğrenme	Aşınmamış	172	27
	Az aşınmış	113	24
	Aşınmış	153	14
	Çok aşınmış	171	0

Takım aşınmasının eğitim test verileri doğruluk oranı sonuçları 1D CNN modelinde %89,3, 2D CNN modelinde %91,2, KNN modelinde %89,6, SVM modelinde %84,2, RF modelinde %92,3 ve ensemble öğrenme modelinde %90,3 olarak hesaplanmıştır. Eğitim test sonucunda en iyi değeri RF modelinin verdiğini görüyoruz. En düşük değeri ise SVM modeli vermiştir.

YZ tekniklerinin kullanımı, hızlı, kaliteli ve verimli üretim sağlamak isteyen işletmeler için zorunlu hale gelmiştir. Bu alanda yapılmış birçok çalışma bulunmaktadır.

Bu bölümde bazı çalışmalar değerlendirilmiş ve genel olarak olumlu sonuçlar elde edildiği gözlemlenmiştir. Lin ve arkadaşları, tornalama işlemlerinde takım yanak aşınmasını izlemek amacıyla regresyon analizi ve YSA modelleri önermişlerdir. Aşınma durumunun izlenmesi için kesme kuvvetleri ölçülmüş ve bu veriler YSA sistemine aktarılmıştır. İlerleme ve kesme kuvvetleri, tahmin modeline giriş olarak verilmiş ve takım aşınmasının tahmininde ilerleme kuvvetlerinin kesme kuvvetlerinden daha etkili olduğu belirlenmiştir (Lin ve ark., 2003). Attanasio ve ekibi, tornalama işlemlerinde takım yanak aşınmasını tahmin etmek için bir YSA modeli geliştirmiştir. SAE 1050 malzemesi ve tungsten karbür uç (SPUN120308) kullanılarak, üç farklı kesme hızı ve üç farklı ilerleme seviyesinde ve sabit talaş derinliğiyle deneyler yapılmıştır. YSA modelinde ilerleme, kesme hızı ve zaman giriş olarak kullanılmış, aşınma ise çıktı olarak alınmıştır. Çalışmanın sonucunda, YSA yönteminin takım aşınması tahmininde yüksek doğruluk sağlama potansiyeline sahip olduğu belirtilmiştir (Attanasio ve ark., 2013).

DL yöntemleri ve ML modelleri kullanılarak tornalamada takım aşınması ile ilgili yapılan çalışmada 316L paslanmaz çeliğin işlenmesi sırasında oluşan takım aşınması tahmini 1D CNN modelinde %98,08 gibi yüksek bir sonuç elde edildi. 1050 çelik malzemesinin işlenmesinde oluşan takım aşınması tahmini RF modelinde %92,28 sonuç elde edildi. Tornalamada takım aşınması tahmini için ML modellerinin olumlu sonuçlar verdiğini ve imalat sektöründe uygulanabilir sistemler olduğunu göstermektedir. Bu sistemler gelecekte geliştirilebilir ve başka sistemlerde kullanılabilir.

TDİ’de en önemli konulardan bir tanesi doğru karar verebilmek için ses sinyallerinin doğru şartlarda kaydedilmesi ve en uygun veri işleme yöntemleri ile analiz edilmesidir. TDİ ve anlık uyarı sistemlerine ilişkin geliştirilecek modellerde tek algılayıcı modeli kullanılması durumunda talaş kaldırma işleminin karmaşık yapısı nedeniyle elde edilecek verilerin analizinde algılayıcıdan kaynaklanan algılama ve ölçme eksiklikleri olabilmektedir. Bu nedenden dolayı çoklu algılayıcıların kullanılması sistemde güvenilirliği artıracaktır.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Bu çalışmada tornalama sırasında kaydedilen ses verilerinin makine öğrenmesi modelleri kullanılarak seslerin analizi yapılmıştır. İş parçası malzemesi olarak 316L paslanmaz çelik ve 1050 çelik malzemesi kullanılmıştır. Makine öğrenme modelleri 1D CNN, 2D CNN, KNN, SVM, RF ve topluluk öğrenme modeli ile eğitilen ses verileri python kütüphanesi librosa kullanılarak Genlik- Zaman, Mel-Spectrogram, MFCCs (Mel Frekans Kepstral Katsayıları), ZCRs (Sıfır Geçiş Oranları) ve RMS (Karekök Ortalama Kare) enerji ile ses verilerinin öznitelikleri çıkartılmıştır.

316L paslanmaz çelik takım aşınması analizi için sınıflandırmada (0) aşınmamış, (1) az aşınmış, (2) aşınmış ve (3) çok aşınmış olarak etiketlenmiştir. (0) için 176 ses, (1) için 598 ses, (2) için 428 ses ve (3) için 626 ses eğitimleri için çıkan eğitim sonuçları 1D CNN modeli test doğruluğu %98,8, 2D CNN modeli testin doğruluğu %96,72, KNN modeli test doğruluğu %94,26, SVM modeli testin doğruluğu %90,43, Topluluk öğrenme modeli testin doğruluğu %99,699. 316L paslanmaz çelik ile takım aşınması için yapılan tahminlerde en iyi eğitim sonucunu test doğruluk değeri %98,08 ile 1D CNN modeli vermiştir. En zayıf sonucu ise %90,43 değerle SVM modeli vermiştir.

1050 çelik ile takım aşınması analizi için sınıflandırmada (0) aşınmamış, (1) yarı aşınmış, (2) aşınmış ve (3) çok aşınmış olarak etiketlenmiştir. (0) için 884 ses, (1) için 728 ses, (2) için 893 ses ve (3) için 861 ses eğitimleri için çıkan sonuçları ise 1D CNN modeli test doğruluğu %89,32, 2D CNN modeli testin doğruluğu %91,24, KNN modeli test doğruluğu %89,6, SVM modeli test doğruluğu %84,27, RF modeli test doğruluğu %92,28, Topluluk öğrenme modeli testin doğruluğu %90,35. 1050 çelik ile takım aşınması için yapılan tahminlerde en iyi eğitim sonucunu test doğruluk değeri %92,28 ile RF modeli vermiştir. En zayıf sonucu ise %84,27 değerle SVM modeli vermiştir.

5.2 Öneriler

Talaşlı imalat işlemlerinde en önemli konu, yapılacak işlemin mümkün olan en düşük maliyetle ve istenilen en uygun kalitede gerçekleşmesidir. Tornalama işlemi, endüstri sektöründe en önemli üretim süreçlerinin başında gelir. Tornalama sonucu elde edilen herbir parçanın kalitesi, toplam ürün kalitesini etkileyen bir faktördür. Dolayısıyla

bu tür parçalarda kalite seviyesini yükseltmek zorunlu hale gelmiştir. İmalat endüstrisindeki takım operasyonlarında takım ve iş parçasında istenmeyen durumların oluşmasının engellenmesi ve gerekli önlemlerin alınması için takım durumunun online olarak izlenmesi gereklidir. Aksi takdirde üretimin kesintiye uğraması, takım değiştirme sırasında geçen ölü zaman, takım ve iş parçasında meydana gelen zararların maliyeti, kesme işlemindeki kalite düzeyinin düşmesi gibi dezavantajlar ortaya çıkmaktadır.

CNC makinelerin yer aldığı otomasyonda, esnek ve grup üretim hatlarında yaşanan olumsuzluklar için sebep sonuç ilişkisini kurabilme bilgi düzeyine sahip olmayan operatör, daima talaş kaldırma sürecini takip etmek zorunda kalmaktadır. Bu durum otomasyonun amacını boşa çıkarmakta ve otomasyon sistemi ile işleme hattındaki operatör etkileşiminin sistemden çıkarılmasını gerektirmektedir. Tüm bu nedenler pahalı CNC makinelerinde yüksek maliyetli hasarlara yol açmasına neden olabilir.

Talaşlı imalat işlemlerinde takım durumunu izlemek amacıyla birçok yöntem geliştirilmiş olup bunlardan çok azı başarılı olarak kullanılmaktadır. Kullanılan algılayıcıların ve kullanılan yöntemler uluslararası standartlarda olmasına rağmen henüz endüstrinin isteklerine tam olarak cevap verebilecek bir TDİ modeli oluşturulamamıştır. Kurulacak TDİ modelinin endüstride etkin olarak kullanılabilmesi için atölye ortamında uygulanabilecek yöntemler tercih edilmeli ve kullanılan TDİ yöntemi ekonomik olmalıdır.

Günümüzde DL ve ML yöntemleri birçok alanda kullanılmaktadır. Bu yöntemler birçok alanda başarı elde etmiştir. Gelecekte tornalama işlemlerinde dezavantajların önlenmesi ve daha kaliteli üretim yapabilmek için bu sistem kullanılabilir. CNC torna makinesine uyumlu hale getirilen sistem işlem sırasında makine çalışmasına bir engel oluşturmamakta ve makineye donanım olarak eklenebilir. Ayrıca ses kayıt cihazı gövde kısmında tarete yakın bir yerde konumlandırıldığında daha net ses verileri elde edilebilir. İşleme yapılırken ses kayıtlarından alınan verilerle takım durumu izlenebilir ve anında müdahale edilebilir.

Bu çalışma gelecekte sanayi ve akademik alanda yeni çalışmalara katkı sağlayabilir. Literatüre katkısı ile YZ alanlarında gelecekteki yeni çalışmalar için bir temel teşkil edebilir.

KAYNAKLAR

- Ahmed, G. S., Quadri, S. S.H, and Mohiuddin, M. S. 2015. Optimization of feed and radial force in turning process by using Taguchi design approach. *Materials Today: Proceedings*, 2(4-5), 3277-3285.
- Akar, Ö., ve Güngör, O. 2012. Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 139-146.
- Akkurt, M. 2000. *Talaş kaldırma yöntemleri ve takım tezgahları*. Birsen Yayınevi.
- Atalay, M., ve Çelik, E. 2017. Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Attanasio, A., Ceretti, E., Giardini, C., and Cappellini, C. 2013. Tool wear in cutting operations: experimental analysis and analytical models. *Journal of Manufacturing Science and Engineering*, 135(5), 051012.
- Benardos, P. G., and Vosniakos, G. C. 2002. Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments. *Robotics and Computer-Integrated Manufacturing*, 18(5-6), 343-354.
- Bhuiyan, M. S. H., Choudhury, I. A., and Dahari, M. 2014. Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning. *Journal of Manufacturing Systems*, 33(4), 476-487.
- Bilgin, M. 2017. Gerçek veri setlerinde klasik makine öğrenmesi yöntemlerinin performans analizi. *Breast*, 2(9), 683.
- Breiman, L. 2001. Random Forest. *Mach. Learn*, 45, 5–32.
- Byrne, G., Dornfeld, D., and Denkena, B. J. C. A. 2003. Advancing cutting technology. *Cirp Annals*, 52(2), 483-507.
- Cakir, M. C., and Isik, Y. 2005. Detecting tool breakage in turning aisi 1050 steel using coated and uncoated cutting tools. *Journal of Materials Processing Technology*, 159(2), 191-198.
- Ceviz, M. 2015. Kesici takım, kesme hızı ve malzeme cinsinin yüzey pürüzlülüğüne etkilerinin araştırılması.
- Cortes, C. 1995. Support-Vector Networks. *Machine Learning*. 20, 273-289.
- Cook, N. H. 1973. Tool wear and tool life. 931-938
- Cover, T., and Hart, P. 1967. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.

- Cunningham, P., and Delany, S. J. 2021. K-nearest neighbour classifiers-a tutorial. *ACM computing surveys (CSUR)*, 54(6), 1-25.
- Davis, S., and Mermelstein, P. 1980. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE transactions on acoustics, speech, and signal processing*, 28(4), 357-366.
- Ding, F., and He, Z. 2011. Cutting tool wear monitoring for reliability analysis using proportional hazards model. *The International Journal of Advanced Manufacturing Technology*, 57, 565-574.
- Doğruel, S., ve Doğruel, F. 2008. Türkiye sanayiine sektörel bakış. *İstanbul: TÜSİAD Yayını*.
- Dong, J., Subrahmanyam, K. V. R., Wong, Y. S., Hong, G. S., and Mohanty, A. R. 2006. Bayesian-inference-based neural networks for tool wear estimation. *The International Journal of Advanced Manufacturing Technology*, 30, 797-807.
- Ertekin, Y. M., Kwon, Y., and Tseng, T. L. B. 2003. Identification of common sensory features for the control of CNC milling operations under varying cutting conditions. *International Journal of Machine Tools and Manufacture*, 43(9), 897-904.
- Gouarir, A., Martínez-Arellano, G., Terrazas, G., Benardos, P., and Ratchev, S. J. P. C. (2018). In-process tool wear prediction system based on machine learning techniques and force analysis. *Procedia CIRP*, 77, 501-504.
- Guo, G., Wang, H., Bell, D., Bi, Y., and Greer, K. 2003. KNN model-based approach in classification. In *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, CoopIS, DOA, and ODBASE 2003, Catania, Sicily, Italy, November 3-7, 2003. Proceedings* 986-996. Springer Berlin Heidelberg.
- Güran, A., Uysal, M., ve Doğrusöz, Ö. 2014. Destek vektör makineleri parametre optimizasyonunun duygu analizi üzerindeki etkisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 86-93.
- Güven, Z. A. 2024. Ses analizi ile müzik türlerinin sınıflandırılmasına yönelik kapsamlı bir çalışma. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(1), 325-333.
- Inasaki, I., Aida, S., and FUKUOKA, S. 1987. Monitoring system for cutting tool failure using an acoustic emission sensor: vibration, control engineering, engineering for industry. *JSME international journal*, 30(261), 523-528.
- Karataş, A. F., Mercan, Ö. B., Özdil, U., ve Ozan, Ş. 2023. Çağrı Merkezlerinde Olumsuzluk İçeren Çağrıların Evrişimsel Sinir Ağları ile Tespiti. *Bilişim Teknolojileri Dergisi*, 16(1), 13-19.

- Kider, M. S. 2016. Tornalama işleminde kesme parametrelerinin karşılaştırmalı optimizasyonu.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., and Inman, D. J. 2021. 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 107398.
- Kopač, J. 1998. Influence of cutting material and coating on tool quality and tool life. *Journal of Materials Processing Technology*, 78(1-3), 95-103.
- Kuntoğlu, M. 2016. Tornalamada akustik emisyon ve kesme kuvveti sinyalleri kullanarak takım kırılması ve ilerleyen takım aşınmasının tahmin edilmesi.
- LeCun, Y., Bengio, Y., and Hinton, G. 2015. Deep learning. *nature*, 521(7553), 436-444.
- Lewis, T., and Writer, S. 2014. A brief history of artificial intelligence. *Live Science*.
- Lin, J. T., Bhattacharyya, D., and Kecman, V. 2003. Multiple regression and neural networks analyses in composites machining. *Composites Science and Technology*, 63(3-4), 539-548.
- Masetic, Z., and Subasi, A. 2016. Congestive heart failure detection using random forest classifier. *Computer methods and programs in biomedicine*, 130, 54-64.
- Mursalın, M., Zhang, Y., Chen, Y., and Chawla, N. V. 2017. Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier. *Neurocomputing*, 241, 204-214.
- Nabiyev, V. V. 2012. Yapay Zekâ: İnsan-Bilgisayar Etkileşimi. Baskı Yeri: Seçkin Yayıncılık.
- Nilsson, N. J. 2014. *Principles of artificial intelligence*. Morgan Kaufmann.
- Obradović, T., Vlačić, B., and Dabić, M. 2021. Open innovation in the manufacturing industry: A review and research agenda. *Technovation*, 102, 102221.
- Ozcift, A., and Gulten, A. 2011. Classifier ensemble construction with rotation forest to improve medical diagnosis performance of machine learning algorithms. *Computer methods and programs in biomedicine*, 104(3), 443-451.
- Özdemir, K. 2008. *İlk aşınma bölgesinde takım aşınmasını etkileyen parametrelerin deneysel analizi* (Master's thesis, Bursa Uludağ University (Turkey)).
- Özdemir, U., ve Erten, M. 2003. Talaslı İmalat Sirasında Kesici Takımda Meydana Gelen Hasar Mekanizmaları Ve Takım Hasarını Azaltma Yöntemleri. *Journal of Aeronautics and Space Technologies*, 1(1), 37-50.
- Öztürk, K., ve Şahin, M. E. 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36

- Rao, K. V., Murthy, B. S. N., and Rao, N. M. 2014. Prediction of cutting tool wear, surface roughness and vibration of work piece in boring of AISI 316 steel with artificial neural network. *Measurement*, 51, 63-70.
- Sagi, O., and Rokach, L. 2018. Ensemble learning: A survey. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 8(4), e1249.
- Sağlam, H. 2000. Frezelemede yapay sinir ağları kullanarak, çok elemanlı kuvvet ölçümlerine dayalı takım durumu izleme.
- Salgado, D. R., Cambero, I., Olivenza, J. H., Sanz-Calcedo, J. G., López, P. N., and Plaza, E. G. 2013. Tool wear estimation for different workpiece materials using the same monitoring system. *Procedia Engineering*, 63, 608-615.
- Salimiasl, A., and Rafighi, M. 2017. Talaş Kaldırma İşlemlerinde Takım Durumunun İzlemesi İçin Son Gelişmelerin İncelenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 5(1), 314-337.
- Scheffer, C., Kratz, H., Heyns, P. S., and Klocke, F. 2003. Development of a tool wear-monitoring system for hard turning. *International Journal of Machine Tools and Manufacture*, 43(10), 973-985.
- Siau, K., and Wang, W. 2018. Building trust in artificial intelligence, machine learning, and robotics. *Cutter business technology journal*, 31(2), 47-53.
- Siddhpura, A., and Paurobally, R. 2013. A review of flank wear prediction methods for tool condition monitoring in a turning process. *The International Journal of Advanced Manufacturing Technology*, 65, 371-393.
- Şahin, Y. 2001. *Talaş kaldırma prensipleri*. Nobel Yayın Dağıtım.
- Tang, W., Long, G., Liu, L., Zhou, T., Blumenstein, M., and Jiang, J. 2020. Omni-scale cnns: a simple and effective kernel size configuration for time series classification. *arXiv preprint arXiv:2002.10061*.
- Taylor, F. W. 1906. *On the art of cutting metals* (Vol. 23). American society of mechanical engineers.
- Teti, R., Jemielniak, K., O'Donnell, G., and Dornfeld, D. 2010. Advanced monitoring of machining operations. *CIRP annals*, 59(2), 717-739.
- Tezel, T., Topal, E. S., ve Kovan, V. 2018. Hibrit İmalat: Eklemeli imalat ile talaşlı imalat yöntemlerinin birlikte kullanılabilirliğinin incelenmesi. *International Journal of 3D Printing Technologies and Digital Industry*, 2(3), 60-65.
- Tran, T., and Lundgren, J. 2020. Drill fault diagnosis based on the scalogram and mel spectrogram of sound signals using artificial intelligence. *Ieee Access*, 8, 203655-203666.

- Veranyurt, Ü., Deveci, A., Esen, M. F., ve Veranyurt, O. 2020. Makine öğrenmesi teknikleriyle hastalık sınıflandırması: Ranfom forest, K-nearest neighbour ve adaboost algoritmaları uygulaması. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 6(2), 275-286.
- Wang, Z., and Oates, T. 2015. Imaging time-series to improve classification and imputation. *arXiv preprint arXiv:1506.00327*.
- Yang, X., Ye, Y., Li, X., Lau, R. Y., Zhang, X., and Huang, X. 2018. Hyperspectral image classification with deep learning models. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5408-5423.
- Yıldırım, M. 2022. MFCC Yöntemi ve önerilen derin model ile çevresel Seslerin Otomatik olarak sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 449-457.
- YÜCEL, İ. E. 2023. Müzik araştırmalarında ses içerik analizi. *The Journal of Academic Social Science*, 136(136), 282-297.
- Zheng, Z., Xie, S., Dai, H. N., Chen, X., and Wang, H. 2018. Blockchain challenges and opportunities: A survey. *International journal of web and grid services*, 14(4), 352-375.
- Zhong, R. Y., Xu, X., Klotz, E., and Newman, S. T. 2017. Intelligent manufacturing in the context of industry 4.0: a review. *Engineering*, 3(5), 616-630.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ramazan ilenç
Uyruğu : TC

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Batman Gazi Lisesi	2010
Üniversite	: Batman üniversitesi	2017
Yüksek Lisans	:	
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
-----	-------	--------

UZMANLIK ALANI

YABANCI DİLLER

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR