

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**TEL ELEKTRO EROZYON İŞLEME İLE KESİLEN
ALÜMİNYUM ALAŞIMLARININ YÜZEY PÜRÜZLÜLÜK
DEĞERLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
TAHMİN EDİLMESİ**

Osman AYDUR

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

ŞUBAT 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**TEL ELEKTRO EROZYON İŞLEME İLE KESİLEN ALÜMİNYUM
ALAŞIMLARININ YÜZEY PÜRÜZLÜLÜK DEĞERLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

Tez Yazarı
Osman AYDUR

Danışman
Doç. Dr. Mustafa ULAŞ

ŞUBAT 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Tel Elektro Erozyon İşleme İle Kesilen Alüminyum Alaşımlarının Yüzey Pürüzlülük Değerlerinin Makine Öğrenmesi Yöntemleri İle Tahmin Edilmesi
Yazarı:	Osman AYDUR
İlk Teslim Tarihi:	29.12.2021
Savunma Tarihi:	05.02.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Mustafa ULAŞ Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Erkan TANYILDIZI Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Aytuğ BOYACI Milli Savunma Üniversitesi, Hava Harp Okulu	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Tel Elektro Erozyon İşleme İle Kesilen Alüminyum Alaşımlarının Yüzey Pürüzlülük Değerlerinin Makine Öğrenmesi Yöntemleri İle Tahmin Edilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

05.02.2022

Osman AYDUR



ÖNSÖZ

Yüksek lisans tez çalışma konumun belirlenmesi, tez çalışmamın araştırma, hazırlama dahil olmak üzere tüm süreçlerinde bilgi birikimlerini, deneyimlerini, fikirlerini, görüşlerini ve kıymetli vakitlerini benden esirgemeyen, her an desteğini hem fiili hem de manevi olarak hissettiren kıymetli hocam Sayın Doç. Dr. Mustafa ULAŞ'a teşekkürlerimi sunarım. Aynı zamanda teknik bilgileri ile desteklerini esirgemeyen Doç. Dr. Turan GÜRGENÇ'e teşekkürlerimi sunarım. Yüksek lisans tez çalışmam süresince destekleri ve kıymetli düşünceleri ile daima yanımda olan arkadaşlarım, sevdiklerim ve her zaman, her konuda destekçim olan değerli aileme sonsuz teşekkür ederim.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından **MF.19.52** protokol numaralı proje ile desteklenmiştir.

Osman AYDUR

ELAZIĞ, 2022

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLOLAR LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
2. LİTERATÜR İNCELEMESİ	2
3. GENEL BİLGİLER	5
3.1. Elektro Erozyon İşleme	5
3.1.1. Tel Erozyon (Wire Electrical Discharge Machining - WEDM)	5
3.1.2. Freeze Erozyon (Electrical Discharge Milling)	6
3.1.3. Taşlama Erozyon (Electrical Discharge Grindig- EDG)	6
3.1.4. Ultrasonik Destekli Erozyon (UEDM)	6
3.1.5. Oyma Erozyon	6
3.1.6. Mikro Elektro Erozyon (MEDM)	6
3.1.7. Mikro Tel Erozyon	6
3.2. Tel Erozyon Yöntemi	7
3.2.1. Tel Erozyon (WEDM) Yöntemi	7
3.2.2. WEDM Yönteminin Uygulama Alanları	10
3.2.3. Tel Erozyon Tezgâhı Hakkında Genel Bilgiler	10
3.2.4. Tel Erozyon Tezgâhının İşleme Parametreleri	10
3.2.5. WEDM Uygulamalarında Kesme Performansını Etkileyen Faktörler	13
3.2.6. WEDM Avantaj ve Dezavantajları	15
3.3. WEDM Yönteminde Kullanılan Tel Karakteristikleri	16
3.3.1. Tellerin Fiziki Karakteristikleri	16
3.3.2. Tel Seçimi	18
4. VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ	21
4.1. Veri Madenciliği	22
4.1.1. Veri Madenciliği Süreçleri	22
4.1.2. Sınıflandırma	24
4.1.3. Kümeleme	24
4.1.4. Birliktelik Kuralları	25
4.2. Makine Öğrenmesi	25
4.2.1. Naïve Bayes Sınıflandırıcı Algoritması	25
4.2.2. K-Ortalamlar Algoritması	26
4.2.3. Destek Vektör Makinesi	27
4.2.4. Doğrusal Regresyon	28
4.2.5. Lojistik Regresyon	28
4.2.6. Yapay Sinir Ağları	29
4.2.7. Uç Öğrenme	31

4.2.8. Karar Ağaçları	31
4.2.9. Rastgele Ormanlar	32
4.2.10. En Yakın Komşular	32
5. MATERYAL VE METOT	33
5.1. VERİ TOPLAMA	33
5.2. ÖNERİLEN MODELLER	40
5.2.1. Destek Vektör Regresyon Makinesi	40
5.2.2. Uç Öğrenme Makinesi	41
5.2.3. Ağırlıklı Uç Öğrenme Makinesi	42
5.2.4. Değerlendirme Parametreleri	42
6. BULGULAR VE TARTIŞMA	44
7. SONUÇLAR	49
ÖNERİLER	50
KAYNAKLAR	51
ÖZGEÇMİŞ	

ÖZET

Tel Elektro Erozyon İşleme İle Kesilen Alüminyum Alaşımlarının Yüzey Pürüzlülük Değerlerinin Makine Öğrenmesi Yöntemleri İle Tahmin Edilmesi

Osman AYDUR

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Şubat 2022, Sayfa: xii + 55

Teknolojinin yoğun kullanımı ile birlikte her gün hızla artmakta olan büyük bir veri yığını oluşmaktadır. Büyük dijital verilerin toplanması, depolanması ve işlenmesinin sonucunda birçok alanda iş gücü ve zaman konusunda kâr sağlanmaktadır. İşlenmediği sürece anlamsız ve karmaşık halde bulunduklarından ötürü sadece gereksiz depolama alanı tüketen veriler, veri madenciliği veya makine öğrenmesi yöntemleri ile işlendiklerinde anlamlı veriler haline dönüştürülebilmektedir. Veri yığınları anlamlı hale geldiğinde kurum, kuruluş veya bireyler için zamandan tasarruf etmeyi mümkün kılacaktır. Veri madenciliği, makine öğrenmesi veya derin öğrenme gibi günümüzün önem arz eden öğrenme yöntemleri ile geliştirilecek akıllı sistemler sayesinde hata, zaman faktörleri en aza indirgenmektedir. Bu çalışmada, veri madenciliği ve makine öğrenmesi ile gerçekleştirilen akıllı sistemlerin önemi göz önünde bulundurularak kavramlar incelenmiştir. Havacılık, uzay ve otomotiv sektörleri başta olmak üzere sanayi alanında önemli yeri olan alüminyum alaşımlarından biri olan Al7075 alaşımı, tel elektro erozyon işleme (WEDM) yöntemi ile farklı parametrelerde işlenmiş ve oluşan yüzey pürüzlülükleri veri madenciliği yöntemleri ile tahmin edilmiştir. Yapılan bu çalışmada giriş parametresi olarak voltaj, darbe süresi, basınç ve tel besleme esas alınmıştır. WEDM sonucunda girdi ve çıktı parametreleriyle birlikte veri seti elde edilmiş, ELM, W-ELM, SVR ve Q-SVR yöntemleri ile yüzey pürüzlülük değerleri tahmin edilmiş ve sonuçlar değerlendirilmiştir. Sonuç olarak, kullanılan yöntemler arasında en yüksek performansa sahip olan W-ELM, 0.9720 R^2 değeri ile yüzey pürüzlülüğünü tahmin etmiştir. Gerçekleştirilen çalışma ile birlikte imalat endüstrisinde büyük bir potansiyele sahip olan alüminyum alaşımının iş gücü, zaman ve maliyet konusunda yüksek kazanımlar elde edileceği öngörülmektedir.

Anahtar Kelimeler: Makine Öğrenmesi, Veri Madenciliği, Tel Elektro Erozyon İşleme, Yüzey Pürüzlülüğü

ABSTRACT

Prediction Of Surface Roughness Values Of Aluminum Alloys Cut By Wire Electro Erosion Machining By Machine Learning Methods

Osman AYDUR

Master's Thesis

FIRAT UNIVERSITY

Graduate School of Natural and Applied Sciences

Department of Software Engineering

February 2022, Pages: xii + 55

Intensively using the technology, a large data pile was formed, which was increasing rapidly every day. This profits labor and time in many areas as the collection, storage, and processing of large digital data. Since data is meaningless and complex unless processed, they only consume unnecessary storage space and can be turned into meaningful data when processed by data mining or machine learning methods. These stacks are made meaningful and save time for institutions, organizations or individuals. Errors and time factors are minimized by using intelligent systems that will be developed with today's important learning methods such as data mining, machine learning or deep learning. In this study, the concepts are examined considering the importance of smart systems realized with data mining and machine learning. Al7075 alloy, which is one of the aluminum alloys that have an important place in the industry, especially in the aerospace and automotive sectors, has been processed in different parameters by wire electro-erosion processing (WEDM) method and the resulting surface roughness has been predicted by data mining methods. In this research, voltage, pulse duration, pressure, and wire feeding are taken as input parameters. After the WEDM process, obtained a data set with input and output parameters, and surface roughness values were predicted with ELM, W-ELM, SVR, and Q-SVR methods and the results were evaluated. As a result, W-ELM, which has the highest performance among the methods used, predicted the surface roughness with an R^2 value of 0.9720. As a consequence of the work carried out, predicted that the aluminum alloy has great potential in the manufacturing industry, will achieve high gains in labor, time, and cost.

Keywords: Machine Learning, Data Mining, Wire Electro Discharge Machining, Surface Roughness

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. EDM'nin Şematik Görünümü	7
Şekil 3.2. Tel Erozyon Tezgahının Çalışma Şeması.....	9
Şekil 3.3. Puls süresi - Voltaj ilişkisi.....	11
Şekil 3.4. WEDM işlemini etkileyen faktörler [30]	16
Şekil 3.5. İş Parçası ve Tel çapı arasındaki ilişki	19
Şekil 3.6. Köşe Radyüsüne Göre Tel Seçimi.....	19
Şekil 4.1. Veri Madenciliği Süreçleri	24
Şekil 4.2. Kümeleri belirlenmemiş veri kümesi	26
Şekil 4.3. Küme merkezlerinin belirlenmesi	26
Şekil 4.4. Verilerin merkeze yakın kümelere aktarılması.....	27
Şekil 4.5. Küme sınırlarının belirlenmesi	27
Şekil 4.6. DVM algoritması çalışma prensibi.....	27
Şekil 4.7. CNN algoritması çalışma sıralaması örneği	29
Şekil 4.8. LSTM algoritması çalışma örneği.....	30
Şekil 5.1. DeneySEL Kurulum [66].....	34
Şekil 5.2. İş Parçasının işlenmesi [66].....	34
Şekil 5.3. WEDM ile İşlenmiş Al7075 Alüminyum Alaşımları [66]	37
Şekil 5.4. Numune 1-9 yüzey pürüzlülükleri [66].....	37
Şekil 5.5. Numune 10-18 yüzey pürüzlülükleri [66]	37
Şekil 5.6. Numune 19-27 yüzey pürüzlülükleri [66]	38
Şekil 5.7. Numune 28-36 yüzey pürüzlülükleri [66]	38
Şekil 5.8. Numune 37-45 yüzey pürüzlülükleri [66]	38
Şekil 5.9. Numune 46-54 yüzey pürüzlülükleri [66]	38
Şekil 5.10. Numune 55-63 yüzey pürüzlülükleri [66]	39
Şekil 5.11. Numune 64-72 yüzey pürüzlülükleri [66]	39
Şekil 5.12. Numune 72-81 yüzey pürüzlülükleri [66]	39
Şekil 5.13. Numune 1-81 yüzey pürüzlülük değerleri [66]	40
Şekil 6.1. DeneySEL sonuçların ELM Modeli sonuçları ve hataları ile karşılaştırılması [66]	45
Şekil 6.2. DeneySEL sonuçların W-ELM Modeli sonuçları ve hataları ile karşılaştırılması [66]	46
Şekil 6.3. DeneySEL sonuçların SVR Modeli sonuçları ve hataları ile karşılaştırılması [66]	46
Şekil 6.4. DeneySEL sonuçların Q-SVR Modeli sonuçları ve hataları ile karşılaştırılması [66]	47

Şekil 6.5. Modellerin regresyon sonuçları a) ELM Modeli regresyonu b) W-ELM Modeli regresyonu c) SVR Modeli regresyonu d) Q-SVR Modeli regresyonu [66]	47
Şekil 6.6. Tüm modellerin sonuçlarının deneysel sonuçlarla karşılaştırılması [66]	48



TABLÖLER LİSTESİ

	Sayfa
Tablo 2.1. Literatür Taraması	2
Tablo 3.1. Farklı Malzemelere Ait İletkenlik Oranları	17
Tablo 3.2. Farklı Malzemelere Ait Kopma Mukavemetleri	17
Tablo 3.3. İçbükey köşe radyüs limitleri.....	20
Tablo 5.1. Al7075 alüminyum alaşımasının kimyasal bileşimi [66].....	33
Tablo 5.2. Alüminyum Alaşımasının İşleme Parametreleri [66].....	34
Tablo 5.3. Değerlendirme Metriklerinin Formülasyonları [66]	43
Tablo 6.1. Eğitilmiş Modellerin Değerlendirme Metrikleri Sonuçları [66]	45

SİMGELER VE KISALTMALAR

Kısaltmalar

ANN	: Artificial Neural Network (Yapay Sinir Ağı)
C	: Kapasite
CNC	: Bilgisayarlı Kesim Makineleri
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağları)
DA	: Boyutsal Doğruluk
EDG	: Electrical Discharge Grindig (Taşlama Erozyon)
EDM	: Electrical Discharge Machining (Elektrik Erozyon İşleme)
ELM	: Extreme Learning Machine (Uç Öğrenme Makinesi)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MEDM	: Micro Electrical Discharge Machining (Mikro Elektro Erozyon)
MRR	: Material Removal Rate (Talaş Kaldırma Oranı)
Q-SVR	: Qiskit Support Vector Regression
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağları)
SAS	: Statistical Analysis System
SF	: Tabla İlerleme Hızı
SLFN	: Hidden Layer Feed Forward Networks (Gizli Katmanlı İleri Beslemeli Ağlar)
SPSS	: Statistical Package for the Social Sciences
SR	: Yüzey Pürüzlülüğü
SRM	: Structural Risk Minimization (Yapısal Risk Minimizasyonu)
SV	: Aralık Voltajı
SVM	: Support Vector Machine (Destek Vektör Makinesine)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
UEDM	: Ultrasonic Assisted Electrical Discharge Machining (Ultrasonik Destekli Erozyon)
V	: Ana Güç Kaynağı Voltajı
VW	: Tel İlerleme Hızı
W-ELM	: West Extreme Learning Machine
WEDM	: Wire Electrical Discharge Machining (Tel Elektrik Erozyon İşleme)
WT	: Tel Gerilmesi

1. GİRİŞ

Havacılık ve otomotiv gibi sektörlerde, yakıt maliyetlerini, egzoz emisyonlarını azaltmak ve araçların performansını iyileştirmek için ağırlığı ve maliyetleri azaltmak çok önemlidir [1]. Tel elektrik erozyon işleme (WEDM), imalat endüstrilerinde kullanılan hassas geometrilerin işlenmesi için yaygın olarak kullanılan ve geleneksel olmayan işleme yöntemlerinden biridir. WEDM ile talaşlı imalat ana prensip, iş parçası ile hareketli tel arasında oluşturulan kontrollü kıvılcım ile malzeme yüzeyinde erozyon oluşturarak yüzeyi aşındırmaktır. Bu yöntemde yüksek hassasiyet ve kaliteli parçalar üretmek mümkün olduğundan bu yöntemle olan ilgi her geçen gün artmaktadır. Ayrıca imalat sanayinde de bu yöntem, karmaşık, hassas ve yüzeylerin düzensiz şekilleri olabileceğinden her türlü iletken malzemenin işlenmesinde sıklıkla kullanılmaktadır [2,3]. Yüksek yüzey kalitesi ve boyutsal doğruluk derecesi gerektiren parçaların üretimi için çok önemli bir imalat yöntemidir. İşlenebilirliği tanımlayan en önemli süreç faktörleri WEDM işleme yönteminde, maliyetin yanı sıra sürecin en önemli unsurları, talaş kaldırma oranı (MRR), boyutsal doğruluk (DA) ve yüzey pürüzlülüğüdür (SR). Bu faktörler arasında yüzey pürüzlülüğü, işlenen parçaların kalitesini belirlemek ve değerlendirmek için en önemli kalite özelliklerinden biridir. Ayrıca üretilen parçaların yüzey pürüzlülüğü, korozyon direnci, sürtünme, yorulma mukavemeti, aşınma direnci gibi özellikleri etkiler. Bu nedenle iş parçaları işlendikten sonra ortaya çıkan ürünlerin yüzey pürüzlülüğünün düşük olması istenir [4,5]. Yüzey pürüzlülüğü, yüzeyin dokusu ve yüzeyin bütünlüğü ile doğrudan ilişkilidir. İş parçasının yüzey geometrisini tanımlar. İşleme sürecine bağlı olarak yüzey pürüzlülüğü mekanizmasının oluşumunun karmaşıklığı nedeniyle, yüzey pürüzlülüğünü analitik denklemlerle belirlemek çok zordur.

Makine öğrenmesi algoritmaları ile analitik olarak belirlenmesi zor olan zaman alıcı ve maliyetli deneylerin sonuçlarının tahmin edilmesi birçok alanda uygulama bulmuştur. Bu alanlar arasında enerji, malzeme bilimi, sağlık, makine ve imalat mühendisliği, elektrik mühendisliği, inşaat mühendisliği, biyoloji, fizik vb. gösterilebilir. Ayrıca uç öğrenme makinesi (ELM) ve destek vektör regresyonu (SVR) yüzey pürüzsüzlüğü tahmini alanlarında da başarıyla kullanılmıştır [6].

Yapılan araştırmalar da göz bulundurulursa veri madenciliği ve makine öğrenmesi yöntemleri uygulama ve araştırma bağlamında önem arz etmektedir. Gerçekleştirilen bu çalışmada, öncelikle olarak veri madenciliği ve makine öğrenmesi kavramları, sonra ise bu kavramların altında yer alan yöntemler incelenmiştir. İnceleme sonucunda veri madenciliği ve makine öğrenmesi yöntemleri hakkında fikir ve bilgi sahibi olacağı düşünülen okurun bilgilerinin bir veri seti üzerinde uygulanmasıyla pekişmesi hedeflenmiştir.

2. LİTERATÜR İNCELEMESİ

WEDM yöntemi doğruluğunun yanı sıra uzun süreli ve maliyetli bir imalat yöntemidir. Ayrıca WEDM yönteminde değişen üretim parametreleri ve parça boyutu ile yüzey pürüzlülüğü, imalat süreleri ve maliyet değişimi önem arz etmektedir. Farklı talaşlı imalat parametrelerine göre malzemelerin yüzeylerinde oluşacak yüzey pürüzlülüğünün makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ile en uygun talaşlı imalat parametreleri önceden belirlenebilir ve bu sayede iş gücü, maliyet ve zaman kaybının önüne geçilebilir. Özellikle yeni ve karmaşık parçalar tasarlarırken, tasarım mühendislerine maliyet ve iş gücü açısından önemli avantajlar sağlanabilir. Bu konu ile ilgili daha önce yapılan bazı araştırmalar Tablo 2.1’te gösterilmektedir.

Tablo 2.1. Literatür Taraması

Araştırmacılar	İşlenmiş Malzeme	Giriş Parametreleri	Çıkış Parametreleri	Deney Sayısı	Tahmin Yöntemi
Rao ve ark. [7]	BIS-24345 alüminyum alaşımı	Darbe Kapalı süresi Tepe Akımı Dielektrik basıncı Tel Besleme hızı Tel gerilimi Kıvılcım aralığı Gerilim Servo Besleme	Malzeme kaldırma oranı	18	Yapay sinir ağı
Surya ve ark. [8]	Al7075-TiB ₂ MMC	Darbe Açma süresi Darbe Kapanma süresi Tepe Akım Yatak hızı	Yüzey pürüzlülüğü Talaş kaldırma oranı Boyutsal doğruluk	27	Yapay sinir ağı
Thankachan ve ark. [4]	Al-Sn-SiC MMC	Darbe Açma süresi Darbe Kapanma süresi Tel Besleme oranı Sn wt% SiC wt%	Yüzey pürüzlülüğü Talaş kaldırma oranı	32	Yapay sinir ağı

Gurupavan ve ark. [9]	Al-5 wt%Si ₃ N ₄ MMC	Darbe Açma süresi Darbe Kapanma süresi Tepe Geçerli Yatak Hızı	Yüzey pürüzlülüğü Talaş kaldırma oranı Boyutsal doğruluk Elektrot aşınması	27	Yapay sinir ağı
Shandilya ve ark. [10]	AlSiCp MMC	Darbe Açma süresi Darbe Kapanma süresi Servo Gerilim Tel Besleme hızı	Malzeme kaldırma oranı	29	Yapay sinir ağı
Phate ve Toney [11]	AlSiCp MMC	Darbe Açma süresi Darbe Kapanma süresi Tel Besleme hızı Tepe Akımı	Yüzey pürüzlülüğü Talaş kaldırma oranı	27	Yapay sinir ağı
Yusoff ve ark. [12]	Inconel 718	Darbe Açma süresi Darbe Kapanma süresi Tepe Akımı Servo Voltajı Dielektrik basıncı	Yüzey pürüzlülüğü Talaş kaldırma hızı Kesme hızı Kıvılcım boşluğu	22	Yapay sinir ağı
Singh ve ark. [13]	AA 6063	Darbe Açma süresi Darbe Kapanma süresi Tepe Akımı Servo Voltajı	Yüzey pürüzlülüğü	81	Destek Vektör Makinesi

Devarasiddappa ve diğerleri tarafından yapılan çalışmada, Yapay sinir ağı (ANN) modeli geliştirilerek yüzey pürüzlülüğü tahmin edilmiştir [14]. Guangwei ve diğerleri tarafından yapılan çalışmada, Destek Vektör Makinesine (SVM) dayanan bir tahmin yöntemi önerilmektedir [15]. Tan ve diğerleri, SVM ve ANN algoritmalarını kullanarak aşınma kaybı ve sürtünme katsayılarını tahmin etmiştir [16]. Phate ve diğerleri tarafından yapılan çalışmada, performans tahmini için Yapay Sinir Ağları (ANN) modellerinin doğruluğu test edilmiştir [11]. Başka bir çalışmada, aşınmaya dirençli sert krom tabakanın kalınlığı tahmin etmek için destek vektör regresyon algoritması kullanılmıştır [17]. Singh ve diğerleri tarafından yapılan çalışmada, Destek vektör

makina algoritmalarından bazıları (Lineer Regression, Non Lineer Regression, PUK kernel) kullanılarak yüzey pürüzlülük değerleri tahmin edilmiştir [18]. Shandilya ve diğerleri tarafından yapılan çalışmada, Yapay Sinir Ağları (ANN) ile geliştirilen modellerin diğer modellere kıyasla daha doğru tahminler sağladığı tespit edilmiştir[10].

Bobbili ve diğerleri, çalışmalarında alüminyum alaşım 7017 ve haddelenmiş homojen zırh (RHA) Tel Elektro Erozyon İşleme sonucunda Material Removal Rate (Talaş Kaldırma Oranı) ve yüzey pürüzlülüğü modellemesi ve analizi yapmışlardır [19]. Sharma ve diğerleri, çalışmalarında Al 6063/ ZrSiO₄(p) maddesinin Tel Elektro Erozyon İşleme sonuçları MMC metodu kullanarak incelemiş ve en uygun koşulları tahmin etmişlerdir [20]. Kumar ve diğerleri, çalışmalarında Al 2024 - SiC (0.0-12.0 Wt. %) - Grafen (0.5 Wt. %) nanokompozitler ultrasonik sıvı işleme (ULP) yöntemi ardından planetary ball milling (planet bilyeli freze) uygulayarak yüzey pürüzlülüğünü araştırmışlardır[21]. Srinivasa ve diğerleri, çalışmalarında alüminyum z2014 T6 alaşımı üzerindeki kesme değerleri sonuçları göz önüne alarak yüzey bütünlüğünü araştırmışlardır [22]. Gautier ve diğerleri, çalışmalarında külçe halinde bir Ti-48Al2Cr-2Nb gama titanyum alüminid (P-TiAl) alaşımına Tel Elektro Erozyon İşleme işlemi sonucu Deneysel Tasarım (DOE) ve Varyans Analizi (ANOVA) yöntemlerini kullanarak analiz yapmış ve yüzey pürüzlülüğünü incelemişlerdir [23]. Koyano ve diğerleri, çalışmalarında Tel Elektro Erozyon İşleme sırasında optik fiber iki renkli bir pirometre kullanarak tel sıcaklığına bağlı yüzey bütünlüğü araştırmışlardır [24].

Bu çalışmada, mevcut literatür çalışmalardan farklı olarak bu çalışmalara göre farklı işlem parametrelerinde kesilecek olan alüminyum alaşımının işlendikten sonraki yüzey pürüzlülük değerleri belirlenecek ve makine öğrenme yöntemleri kullanılarak modellenecek ve tahminleri gerçekleştirilecektir. Bu çalışmanın akademik seviyede bilgi üreteceği, ülkemizin bu konudaki bilgi seviyesini artıracığı ve bu tür çalışmaların sanayimizin kullanımına sunularak sanayimizin rekabet gücünü artıracığına inanılmaktadır.

3. GENEL BİLGİLER

Bu bölümde çeşitli elektro erozyon işleme (EDM) yöntemleri ile ilgili bilgiler verilerek, araştırmamızda kullanılan tel elektro erozyon işleme (WEDM) yöntemi ve kullanım alanları detaylı olarak incelenmiştir. Ayrıca bu yöntemde kullanılan tezgâhlar, tel karakteristikleri, kesme parametreleri, kesme işlemini etkileyen faktörler ve malzeme çeşitleri hakkında bilgiler verilmiştir.

3.1. Elektro Erozyon İşleme

Metalik malzemeler, EDM, WEDM, freeze erozyon, taşlama erozyon, ultrasonik destekli erozyon, oyma erozyon, mikro-elektro erozyon ve mikro tel erozyon gibi yöntemler kullanılarak işlenebilir [7]. EDM klasik talaşlı imalat yöntemlerinden farklı olarak yüksek tamlıklarda iş parçaları elde edebilmek için termal enerjiyi kullanır ve meydana gelen elektriksel boşalmalarla parçaları işler. Bu yöntemle bir insan saçının çapından bile daha küçük çaplardaki metaller bile işlenebilir ancak kullanılacak iş parçaları elektrik iletkenliğine sahip olmalıdır.

EDM sistemleri temel olarak Dalma Erozyon ve Tel Erozyonu olarak ikiye ayrılır. Her bir erozyon yönteminin uygulama alanları ve yöntemleri birbirinden farklıdır. Dalma Erozyon yöntemi iş parçasının bir dielektrik sıvı ortamına daldırılmasını gerektirir ve takım elektrotu iş parçasının yüzeyine bastırılarak gerçekleştirilir. Tel erozyonda ise bir tel elektrotu, iş parçası boyunca doğrusal olarak hareket ettirilerek, meydana gelen elektriksel boşalmalarla kesme işlemini gerçekleştirir [25].

3.1.1. Tel Erozyon (Wire Electrical Discharge Machining - WEDM)

Bu yöntemde, Şekil 3.1’de de görülebileceği gibi iş parçası önceden hazırlanan bir CNC olarak adlandırılan bilgisayarlı sayısal kontrol programı ile imal edilir. Genellikle kalıp ve kalıp parçaları gibi sanayi uygulamalarında kullanılır. Bir tel elektrot iş parçası üzerinde doğrusal olarak hareket ettirilerek, meydana gelen elektriksel boşalmalarla kesme işlemini gerçekleştirilir. Kullanılan tel elektrotlar iş parçasının üzerinden yalnızca bir defa geçtikten sonra atılır. Dielektrik sıvı eriyen metale püskürtülerek kesme alanının içini süpürürken, aynı zamanda iş parçası ve tel elektrotları soğutmak için kullanılır [3].

3.1.2. Freeze Erozyon (Electrical Discharge Milling)

Diğerlerine göre daha yeni bir yöntemdir. Tek parça ve sert metalden yapılan talaşlı imalat takımı olan freze çakısı gibi kendi etrafında dönen silindirik bir elektrot kullanarak ortaya çıkan elektro boşalımlarla iş parçalarına şekil verme işlemidir [25].

3.1.3. Taşlama Erozyon (Electrical Discharge Grindig- EDG)

Elektrot olarak abrasiv taşlama taşı elektrik iletkenliği olan bir tekerlek kullanılır. Diğer yöntemlerle benzer şekilde elektro boşalımlarla iş parçalarına şekil verilir. Genellikle karpitler ve elmas formları gibi kesici takımların bilenmesinde kullanılan bir yöntemdir [25].

3.1.4. Ultrasonik Destekli Erozyon (UEDM)

Takım elektrotu olarak ultrasonik frekanslarla titreten bir elektrot kullanarak, meydana gelen elektriksel boşalımlarla, küçük ya da mikro düzeydeki deliklerin delinmesini sağlar [1].

3.1.5. Oyma Erozyon


Bu sistem, işlenmek istenen malzemenin içine doğru ilerleyen bir delik veya eğri olarak belirlenmiş bir yolda, tünel kazarcasına ilerleyerek işlem yapabilme yeteneğine sahip olmasından dolayı oldukça orijinaldir. Kullanılan elektrot eğilebilen bir çubuk şeklindedir [1].

3.1.6. Mikro Elektro Erozyon (MEDM)

Genel olarak kullanılan elektrotların aksine zıt kutuplu olarak tasarlanan, 5 mikrondan daha küçük elektrotlar yardımıyla mikro deliklerin işleminde kullanılırlar. Dalma erozyon yönteminin küçük bir şekli olarak da tanımlanabilir [25].

3.1.7. Mikro Tel Erozyon

Mikro tel erozyon yönteminde çapı 10 μm olan tungsten tel elektrotları kullanılır ve ölçüleri 0,1mm ve 1mm arasında değişen ince plakalar işlenir[25].



Şekil 3.1. EDM'nin Şematik Görünümü

3.2. Tel Erozyon Yöntemi

İngiliz fizikçi Priestly elektrik anahtarları ile ilgili yaptığı çalışmasında, anahtarlarda oluşan kontak aşınma probleminin akım şiddeti ve metale bağlı olarak meydana geldiğini tespit etmiştir. Bu sayede erozyon teknolojisinin temelleri atılmıştır. İlerleyen zamanlarda Sovyet bilim insanı ve kâşif Boris Lazarenko, meydana gelen elektriksel aşınmaları kontrol altına alınabileceği ve bunların yapıcı olarak kullanılabilmesi düşüncesini öne sürmüştür. 1943 yılında ise Electrical Discharge Machine (EDM) kavramı doğmuştur. Bu sayede elektriksel boşalmalarla metallerin işlenmesi mümkün hale gelmiştir. Daha sonraları İsviçreli dört bilim insanı bu teknolojinin endüstriyel açıdan potansiyelini göz önüne alarak kendilerine ait küçük bir çalışma alanında birkaç yıl boyunca çalışmalar gerçekleştirdiler ve 1954 yılında Agie Corporation isimli şirketlerini kurmuşlardır. Ancak WEDM teknolojisini dünyaya tanıtmaları 1969 yılında gerçekleşmiştir[2]. 1980'li yıllarda bilgisayarlı kesim makinelerinin (CNC) geliştirilmesi ve kullanılmaya başlanmasıyla daha karmaşık şekiller üretilebilir ve işlenebilir hale gelmiştir. Sonraki yıllarda bu sistemlere eklenen bir akım kesme devresi ve kontrolör yardımı ile malzemelerin işlenmesi sırasında meydana gelen ark oluşumu gibi sorunların önüne geçilmiştir.

3.2.1. Tel Erozyon (WEDM) Yöntemi

Tel erozyon, metal parçaları işlemek için geliştirilen elektrik erozyonla işlemenin bir çeşididir. Elektrot olarak iletken bir tel kullanılır. Kesme işlemine başlamadan önce kullanılacak telin ve iş parçasının yalıtkan bir sıvı içerisine yerleştirilmesi gerekmektedir. Kesme işlemi süresinde iş parçası ve tel arasında meydana gelmesi gereken elektriksel boşalım belirli ölçütler göz önünde bulundurularak uygulanan voltaj ile sağlanır [26]. Bu ölçütler;

- İş parçası ile kullanılan tel arasındaki mesafe

- Dielektrik sıvının yalıtım kapasitesi
- Boşluk kirliliği

İşlem sırasında meydana gelen gerilimin oluşturduğu zıt kutuplar sayesinde negatif ve pozitif yüklü iyonlar çok kısa bir süre içinde yüksek hızla hareket etmeye başlar. Bu durumun gerçekleşmesi sonucunda, metaller arasındaki en yakın mesafenin bulunduğu noktada bir ara kanal oluşur. Oluşan bu kanaldan elektrik akımı geçmektedir. Bir elektriksel boşalım, yani deşarj olayı en yüksek elektriksel seviye noktasında yer alır. Meydana gelen kıvılcım sayıları 300.000'e kadar ulaşabilmektedir. Aynı zamanda, deşarj olayı sırasında akımın geçtiği noktalarda 8.000°C - 12.000°C aralığında yüksek ısı ortaya çıkar. Ortaya çıkan bu ısı, her iki metalin yüzeyinde belirli bir bölgeyi sürekli olarak eritir. Erime sırasında kopan parçalar akım kesildikten sonra hızla soğurlar. Kullanılan dielektrik sıvı soğutma etkisini destekler ve metal parçacıkların kesim ortamından uzaklaştırılmasını sağlar. Uzaklaştırılamayan ve dielektrik sıvıya karışan çökelmeyen partiküller filtreler aracılığı ile artık madde olarak atılmaktadır.

Tel erozyon yöntemi ile gerçekleştirilen kesim sırasında, tel elektrotun ve iş parçasının aşınma oranları birbirlerine eşit ve simetrik değildir. Bu yöntem kullanılarak gerçekleştirilen kesme işleminin başarılı olabilmesi için bazı özelliklere ihtiyaç duyulmaktadır.

- Elektrot (kullanılan tel) yüksek iletkenliğe sahip olmalıdır.
- İşlenecek olan malzeme elektriği iletme özelliğine sahip olmalıdır.
- Dielektrik sıvının (saf su) ideal yalıtkanlık özelliğine sahip olması ve ideal ısıda (18°C) muhafaza edilmesi gerekir.
- İdeal ortam sıcaklığı 20°C ve ideal nem oranı %50 olarak korunmalıdır.
- Akım jeneratörünün gücü, kararlılığı ve iyonlaşma etkisine adaptasyonu da önemli etkenlerdendir.


Günümüzde WEDM uygulamalarında çeşitli programlama dilleri ve sürümleri kullanılmaktadır. Bu sayede daha az iş gücü gerekmekte ve minimum hata toleransları ile şekil geometrileri elde edilmektedir. Bu programlar sayesinde matematiksel hesaplamalar oldukça kısa sürede gerçekleştirilir ve diyaloglu veri girişi yöntemi ile operatör iş parçalarını tanımlayabilmektedir.

Şekil 3.2'de çalışma şeması gösterilen WEDM tezgâhında işlemlerin gerçekleşme sırası şu şekildedir:

- X ve Y eksenlerinde hareket eden ve içi dielektrik sıvı ile doldurulmuş olan iş tankı için bir çalışma alanı belirlenir.
- Belirlenen bu alan programlanacak iş parçası bir dosya adı altında, tanımlı geometrilere bölünür.
- Her geometri için ayrı ayrı numaralar verilerek profiller belirlenir.
- Telin izleyeceği yol olan kesme yolu çizilir.

- İşlemin koşullarına göre tel çapı, dielektrik sıvı türü, malzeme cinsi gibi kesme parametreleri teker teker belirlenir.
- Veya daha önceden bilgisayar destekli modelleri oluşturulmuş parçalar için CNC paket programları kullanılmaktadır.

WEDM ile gerçekleştirilen işlemlerde yüksek ısı kullanılmasından dolayı, iş parçalarının yüzeylerinde mikron mertebesinde gözenekler ve bu gözenekler arasında çatlaklar meydana gelebilir. Meydana gelen bu deformasyon iş parçasının ömrünü kısaltarak imalatçı için maliyet artışına sebep olur.



Şekil 3.2. Tel Erozyon Tezgahının Çalışma Şeması

3.2.2. WEDM Yönteminin Uygulama Alanları

WEDM yöntemi kalıp ve zımba parçaları, saç metal pres kalıpları, ekstrüzyon kalıpları, hızlı prototip, torna takımları, özel şekil malzemeleri, broş ve şablon imalatlarında kullanılmaktadır. Küçük konikler ve tam boyutlu malzemelere ihtiyaç duyulduğu durumlarda kalıp imalatı için, tel erozyon için mükemmel bir uygulama sağlayan pahalı kesme elektrotları kullanılır. Kalıp işlemleri yüksek düzeyde elektrot yüzey kalitesi ister ve bu kalite WEDM ile elde edilebilir. Bu sebeple dişi kalıp ve zımba yapımında sağladığı kolaylıklardan dolayı WEDM tercih edilmektedir. Ayrıca kalıp imalatında bu yöntemi tercih edilmesi büyük ölçüde tasarruf sağlamaktadır[27,28]. Ekstrüzyon kalıplar, aynı kesite sahip uzun parçaların üretiminde kullanılan kalıplardır. Klasik yöntemde bu kalıpların üretimi için testereleme ve eğeleme gibi pahalı bir yöntem kullanılırken WEDM ile bu maliyet tasarrufu sağlanmaktadır [29]. Prototip ve şablon üretiminde NC programlama ile küçük düzenlemeler yapılarak süreç hızlanmaktadır [27]. Elmas, karbür ve standart olmayan farklı malzemeler kullanılarak üretilen yeni teknoloji için kullanılacak özel şekil malzemeleri geleneksel yöntemlerle kesmek maliyet açısından olumsuz etki yaratmaktadır. Bu yüzden WEDM ile bu sorunun önüne geçilmektedir.

3.2.3. Tel Erozyon Tezgâhı Hakkında Genel Bilgiler


Günümüzde, havuzlu soğutmalı ve püskürtme soğutmalı olarak kullanılan tel erozyon tezgâhları bulunmaktadır. Bu tezgâhlarda 3 ana eksen ve 2 yardımcı eksen vardır. Ana eksenler X, Y ve Z eksenleridir. Yardımcı eksenler ise genellikle U ve V eksenini olarak isimlendirilmektedir. X eksenini, iş parçasının sağ ve sol yönlerdeki hareketini gerçekleştirirken, Y eksenini, ileri ve geri hareketlerini sağlar. Z eksenini ise telin dik olan eksenini temsil etmektedir ve kesilecek olan parçanın kalınlığına göre değişir. Yardımcı eksenlerden olan U eksenini, tel elektrotun X eksenini boyunca kaydırılması sonucu oluşan eksenidir. V eksenini ise tel elektrotun Y eksenini üzerindeki hareketi sonucu oluşan eksenini temsil etmektedir. U açısı ve V açısı ise U ve V eksenlerinin oluşumu sırasındaki kaydırma açılarıdır. Bu eksenler tezgâh bilgisayarı tarafına verdiğimiz açılara bağlı otomatik olarak program tarafından hesaplanır ve eksenlerin yapması gereken hareketler bu şekilde uygulanır. Klasik bir tel erozyon tezgâhının kontrol üniteleri; servo-mekanizma kısmı olarak adlandırılan ve kesme şartlarını ayarlamak için kullanılan kısım, iş parçasının işlenmesi için gereken veri ve tezgâh ayarlarının yapıldığı kısım ve son olarak el ile veri girişinin yapıldığı kısımlardan oluşmaktadır.

3.2.4. Tel Erozyon Tezgâhının İşleme Parametreleri

WEDM işlemi, ısıtma, soğutma gibi fiziksel süreçlerden meydana gelmektedir. Kıvılcım plazmasının kıvamı ve elektriksel erozyon enerjisi krater boyutunu belirler ve bu durum, işleme ve

yüzey kalitesine etki eder. Bu yüzden işleme parametreleri uygun olarak seçilmelidir. Tel erozyon tezgâhının işleme parametreleri, puls süresi (on time), puls ara süresi (off time), puls ara süresi ayarı, yardımcı güç kaynağı devresi, ana güç kaynağı maksimum akımı, ana güç kaynağı voltajı (V), aralık Voltajı (SV), tabla ilerleme hızı (SF), kapasite (C), tel gerilmesi (WT) ve tel ilerleme hızıdır (VW).

1. **Puls Süresi (T_{on}):** Şekil 3.3’de görüleceği gibi puls süresi, her kıvılcımda tel elektrotta uygulana elektrik zamanını kontrol eder. Puls süresi yüksek ayarlandığında enerji üretimi büyük oranda artmaktadır. Kendilerine ait özel ve kullanılabilir seri numaraları sayesinde ayarlanabilmektedir ve en düşük numara en kısa puls süresini temsil etmektedir. Bu parametre fazla arttırıldığında kesme işlemi daha hızlı gerçekleşir. Ancak bu durumda, doğruluk azalacak, yüzey pürüzlülüğü artacak ve kullanılan tel kırılmaya karşı dayanıksız olacaktır.



Şekil 3.3. Puls süresi - Voltaj ilişkisi

2. **Puls Ara Süresi (T_{off}):** Bu parametre ile oluşan kıvılcımların aralarındaki zaman uzunluğunun kontrolü sağlanır ve değer aralığı 1-25 μ s arasındadır. Yüksek ayarlandığında daha büyük kıvılcımların arasındaki süreyi temsil eder. Bu durumda üretilen enerji daha düşüktür. Puls ara süresi aşamasında parçacıklar aralığın dışına püskürtülür. Eğer bu parametre süreçte yer almazsa veya doğru ayarlanmazsa, tel elektrot kısa devre yapabilir veya kırılabilir. Puls ara süresi ve puls süresi birlikte göz önünde bulundurulur ve puls ara süresinin, puls süresinden daha düşük olmaması gerekir.
3. **Puls Ara Süresi Ayarı (MA):** Adaptif olarak adlandırılan uyarlanabilir kontrolün duyarlılık oranını ve miktarını kontrol eder ve değer aralığı M:0-9 ve A:0-9 arasında değişkenlik gösterebilir. Makinenin uyarlanabilir kontrol ünitesi sürdürülen kesme

işleminin iyi olmadığını kavradığında bu değerlere bakılır. M değeri duyarlılığı kontrol eder ve fonksiyonu IP(Ana güç kaynağı maksimum akımı) ayarına göre değişkenlik gösterir.

IP 16'dan büyük olarak ayarlandığında;

M: İşlem koşullarının kararlılığı ve kararsızlığının hangi seviyede inceleneceğini ayarlar.

A: Kararsız işleme esnasında puls ara süresinin ölçeğini ayarlar. Yüksek seviyede ayarlanması, tel kırılma ihtimalini azaltır. Aynı zamanda işleme kararlılığını da artırmış olur.

IP değeri 15 ten küçük olacak şekilde ayarlandığında ise;

M: İşlem koşullarının kararlılığı ve kararsızlığının hangi seviyede inceleneceğini ayarlar.

A: Kararsız işleme esnasında puls ara süresinin ölçeğini ayarlar. Yüksek seviyede ayarlanması, puls ara ölçek faktörünü büyütür. Bu durum daha yüksek işleme kararlılığı ve daha az işlem miktarı sağlar.

4. **Yardımcı Güç Kaynağı Devresi (HP):** Burada H artış gösteren açık aralık voltajını kullanan devredir ve parametre aralığı H:00-99'dur. Meydana gelen elektrik arkı P' dir ve puls süresini temsil eder, parametre aralığı P:0-4'tür. Eğer MA parametresi yürütülen kesme işleminin kararsız olduğuna karar verirse bu parametre kullanılır. IP değeri 16'dan küçük olursa H yüksek voltaj devresini seçer, P parametresi ise kıvılcımın devam edeceği süreyi seçer. IP değeri 15 veya daha küçük bir değere ayarlandığında ise P değerinin kullanılmasına gerek yoktur.
5. **Ana Güç Kaynağı Maksimum Akımı (IP):** Akımın en üst noktasıdır ve tele uygulanan akım miktarını kontrol eder. Parametre değerleri 00-17 arasında değişkenlik gösterir. EDM kıvılcım enerjisi; T_{on} , V ve IP tarafından belirlenmektedir.
6. **Ana Güç Kaynağı Voltajı (V):** Tele güç ekler ve IP ile deşarj puls enerji miktarını ayarlar. Değer aralığı 60-270 arasında değişkenlik göstermektedir. Voltaj süresi iş parçalarının kalınlığına göre değişkenlik gösterir, daha ince parçalar için daha düşük voltajlar kullanılırken, daha kalın parçalar için daha büyük voltaj değerleri kullanılması gerekir.
7. **Aralık Voltajı (SV- Servo voltaj):** Kesme performansı ve aşırı yanma denilen durumu kontrol etmektedir ancak tele güç eklemeyiz. Yüksek değere ayarlandığı takdirde kesme hızının yavaşlamasına, aşırı düşük değerlerde ise parçacıkların aralıkların içinde kalarak kesme işleminin kararsız olmasına sebep olur.
8. **Tabla İlerleme Hızı (SF):** Servo ilerleme de denir ve bir tablanın en yüksek ilerleme hızını ayarlar. Normal servo; tablanın tablanın SV değerinin referans seviyeye yaklaşacak şekilde çalışmasını sağlar. Sabit hızda ilerleme; herhangi bir servo kontrol olmadan,

tablanın ayarlanan ilerleme hızında çalışmasına neden olur. Doğrusal ayar (SFD); tabla gerekli verileri direk olarak bilgisayardan alır.

9. **Kapasite(C):** Tele daha yüksek oranlarda güç eklemenin yoludur. Parametre değerleri 0-0.2 μF dir. Her cihazda bulunmayabilir.
10. **Tel Gerilmesi (WT):** Otomatik bir tel çekici içeren makinelerdeki tellerin gerilim değerini belirler. WT parametre değerleri 380-22000 arasında değişkenlik gösterebilir.
11. **Tel İlerleme Hızı (VW):** VW değeri malzeme kalınlığına göre ayarlanır 3-15m/dakika arasında değişen değerler kullanılabilir. Kalın malzemelerde hızın artırılarak tel kırılmalarının önüne geçilebilir ve tel düzgünlüğü sağlanabilir. VW değeri erozyon hızını, boşluğu ve işlenmiş olan yüzeyi etkilemez ancak düşük miktarda hız iş parçalarında nüksetme sorununa yol açabilir ve tel parçalarının kırılma olasılığını artırır.

3.2.5. WEDM Uygulamalarında Kesme Performansını Etkileyen Faktörler

WEDM uygulamalarında iş parçasını kesme işlemi sırasında performansı etkileyen 3 temel faktör vardır. Bunlar kesme doğruluğu, kesme hızı ve İşlenecek olan parçanın geometrisinin programlanmasıdır. Son yıllarda imalat endüstrisinde meydana gelen gelişmeler doğrultusunda, kullanılan malzemelerin yüzey pürüzlülükleri de WEDM için önemli bir ölçüttür [30].

Kesme Doğruluğu: Kesme işleminde doğruluğu korumak adına dikkat edilmesi gereken birkaç husus bulunmaktadır. Bu hususlar aşağıda sıralanmaktadır [31].

- Kesme süreci boyunca, tel elektrotun çapı ile işlenecek olan parça arasındaki kesme genişliği sabit olmalıdır.
- Kullanılan tel elektrotun gerginliği ve tel kılavuzlarının aksel dengesi uygun şekilde ayarlanmalıdır.
- Tellerde meydana gelecek titreşimler minimize edilmelidir.
- Telin eğilme ve kırılma durumları önem arz etmektedir.

Tel Eğilmeleri: Kesme doğruluğunu etkileyen önemli etkenlerden birisi de tel eğilmeleri konusudur. Elektrot olarak kullanılan tel, kıvılcım oluşumunu meydana getiren elektro dinamik, elektro statik kuvvetler ve hidrolik kuvvetlerin etkisiyle iki eksen üzerinde çekilmeye başlar. Bu çekilme neticesinde tele uygulanan gerginlik oranı azalır. Bu sebeple farklı profillerdeki parçaların kesimi sırasında telin geride kalma durumundan kaynaklı kesilen parçada 100 mikron kadar hata oluşabilmektedir.

Bu konudaki hataların önüne geçebilmek amacıyla, tel germe direncini arttırmak veya köşelerin kesimi sırasında kesme hızını düşürmek gibi yöntemler denenmiştir. Ancak kesme hızını

düşürmek maliyet açısından olumsuz bir etkiye yol açtığı gözlemlenmiştir. Son yıllarda telleri titreşim ve analizleri konusunda sistemler geliştirilmektedir ve bu sistemlerin temel işlevleri şunlardır:

- Kesme işlemi sırasında ve kesme işlemi dışında telin boşta gezdirilmesi durumlarında telin pozisyon ve yer değiştirme oranının ölçülmesi.
- Titreşimlerin ölçülmesi esnasında edinilen verilerden yararlanılarak analizlerin gerçekleştirilmesi [32].

Tel Kırılmaları: WEDM sürecinde, kıvılcım frekansının yüksek olması, malzemelerin işleme hızını arttırırken uygulanan gücü yoğunluğuna bağlı olarak tel elektrotların kırılmasına da sebep olabilmektedir. Telin kırılması veya kopması, kesme işleminin performansını, doğruluğunu ve kalitesini olumsuz yönde etkilemektedir. Bu durumun önüne geçmek amacıyla Time Off olarak adlandırılan kıvılcım ara süresi uzun tutulmaktadır. Ancak yine de tel kopmaları tam olarak engellenememektedir. Ayrıca bu durum işlem süresinin de artmasına sebep olmaktadır.

Kullanılacak telin boyu işlenecek maddenin yüksekliğine göre belirlenmekte ve tel uzadıkça uygulanan güç yoğunluğu ve tel elektrottaki ısı genleşme oranı artış göstermektedir. Bu durum kopma olasılığını arttırmaktadır. Yapılan birçok araştırmada, kullanılan telin fiziksel özellikleri, geometrik şekli ve uygulanan güç miktarının telin kopmasında önemli etkileri olduğu görülmektedir. Çoğunlukla silindir formunda teller tercih edilmektedir. Ayrıca tele uygulanan gerginlik, telin gerilme direncinin %50-%60'ına eşit olması gerekmektedir [26].

Kesme Hızı: Tel erozyon işleminde kesme hızı, birim zamanda kesilen iş parçasının kalınlığı olarak tanımlanmaktadır. Kesme hızı kıvılcım boşalımın kontrolü ile ölçülür. Deşarj alanındaki enerjiyi arttırmak kesme hızını arttırabilir ancak bu durum tel kopmalarına sebep olacaktır. Bu durum iş parçasının kalitesini ve işleme zamanını etkilemektedir. Kesme voltajı, darbe genişliği, amper, kapasite, güç, kullanılan parçaların malzemeleri, tellerin fiziksel özellikleri ve dielektrik sıvının özellikleri gibi faktörler de kesme hızını etkilemektedir [26].

Yüzey Pürüzlülüğü: Yüzeyler düzensiz ve karışık işlemler kullanılarak imal edilirler. Yüksek mukavemet gerektiren ve ağır basınçlara dayanabilen parçaları imal etmek, detaylı ve özel yüzey kalitesine ihtiyaç duyar. Bu parçaların yüzey pürüzlülüğü ölçülerek kontrol edilmesi gerekmektedir. Tam anlamıyla düzgün bir yüzey elde etmek neredeyse imkânsızdır ve her zaman yüzey dokuları üzerinde pürüzler veya dalgalanmalar kalmaktadır. Yüzey dokusu; pürüzlülük, dalgalanma, yataylık ve çatlaklıklar olmak üzere dört temel elemandan oluşur.

Pürüzlülük, üretim sürecini tabiatında var olan takım izleri ve ölçü dışı düzensizliklerdir. Dalgalanma, pürüzlülüğün uzunluğundan daha büyüktür ve bütün düzensizlikleri temsil eder.


Yüzeylerdeki dalgalanma, makineden, kesici takımın kırılması veya hasarından, titreşimden, parçanın dönmesinden veya ısıl işlemlerden kaynaklanabilir. Dalgalı yüzeylerin üst üste gelmesiyle pürüzlülük oluşur. Yataylık, çoğunlukla üretim yönteminden kaynaklanan bir hatadır. Çatlaklar ise bir yüzeydeki aralıkların değişmesi sonucu oluşur ve istenmeyen, kasıtsız düzensizliklerdir. Oluşan çatlaklar içerisinde hava boşlukları ve kazıntılar barındırır [32].

3.2.6. WEDM Avantaj ve Dezavantajları

WEDM sürecinde, klasik yöntemin aksine işlenecek olan parça ile kullanılan tel elektrot arasında fiziksel bir temas yoktur. Bu durumda, kesme fonksiyonu için itme kuvvetine ihtiyaç olmayacaktır. Yalnızca tel elektrotu taşıyan başlığın düşey hareketini sağlamak için kuvvet gerekmektedir. Bu yöntem 3 temel yeteneğe sahiptir [30]. Bunlar;

- İşlenmesi zor olan metal ve alaşımları işleyebilmektedir. Bu sayede havacılık sanayisinde kullanıla döküm alaşımları, sertleştirilmiş çelikten yapılan takım ve kalıpların işlenmesinde kullanılabilir.
- Karmaşık şekilleri otomatik olarak yeniden üretebilmektedir.
- İşleme esnasında büyük kuvvetlere ihtiyaç duymaz. Bu sayede bağlama zorluğuna sahip küçük ve nazik parçalar kolaylıkla işlenebilir. Erimiş parçacıklar dielektrik sıvı vasıtasıyla Şekil 3.2’de gösterilen kıvılcım aralığından uzaklaştırılır.

İşlemler sırasında minimum düzeyde insan dikkati ve becerisi gerektirmesi bu yöntemin en büyük avantajlarından. WEDM, yeteneklerinin sağladığı avantajların yanı sıra bazı dezavantajlara da sahiptir. WEDM’in, işleme hızını, yüzey tamlığını, doğruluk ve diğer performans ölçümlerini etkileyen faktörler Şekil 3.4’te gösterilmektedir [30]. Bu faktörlerden tek bir tanesinde hata olması bile işleme sonucunu olumsuz etkilemektedir. Enerji kıvılcım yoğunluğu ve zaman tarafından belirlenir. Bu parametreler, bir metal kesme işlemini çok önemli iki kabulü olan, yüzey pürüzlülüğü ve işleme hızını etkiler. Yapılan bazı çalışmalarda yüzey pürüzlülüğü sorununu gidermek için deşarj(boşalım) enerjisi azaltılmıştır [25,26,28,32].



Şekil 3.4. WEDM işlemini etkileyen faktörler [30]

3.3. WEDM Yönteminde Kullanılan Tel Karakteristikleri

Teorik olarak her iletken malzeme, tel elektrot olarak kullanılabilir. Fakat pratikte sıklıkla kullanılan birkaç tür bulunmaktadır. En yaygın kullanılan malzeme pirinç ve bakırdır. Tel elektrotların, kırılmaya karşı dayanıklı, yüksek elektriksel iletkenlik ve aşındırılan parçacıkların taşınması için düşük buharlaşma enerjisine sahip olması gerekmektedir. Teller genellikle; tek bileşenli teller (bakır, pirinç, pirinç alaşımları, molibden alaşımları), ince tabaka kompozitler (çinko kaplı pirinç, çinko kaplı bakır ve molibden grafitleri) ve kalın tabaka kompozitler (bakır üstüne pirinç kaplı teller ve pirinç üstüne pirinç kaplı teller) olarak üç grupta incelenmektedir [3].

3.3.1. Tellerin Fiziki Karakteristikleri

Bu bölümde teller elektriksel, mekaniksel ve termal fiziki özellikleri başlıkları altında incelenmektedir.

Elektriksel Özellikler: Tellerin elektrot olarak kullanılabilmesi için iletken özelliğe sahip olması gerekmektedir. Tablo 3.1’de farklı malzemelerin iletkenlik özellikleri gösterilmektedir. En yüksek elektriksel iletkenliğe sahip olan malzeme bakırdır. Uluslararası Yumuşak Bakır Standardı

(IACS)'e göre %100 iletkenlik oranlı olarak kabul edilmiştir. Ayrıca, diğer malzemeleri ölçmek amacıyla yükseklik işareti olarak kullanılmaktadır.

Tablo 3.1. Farklı Malzemelere Ait İletkenlik Oranları

Madde	% IACS
Bakır	100
Alüminyum	63
Molibden	32
Çinko	28
Pirinç (67/37)	20
Kurşun	8

Mekaniksel Özellikler:

1. **Kopma Mukavemeti:** Mukavemet kelime anlamı olarak karşı koyma, dayanıklılık, direnç anlamına gelmektedir. Kopma mukavemeti ise devamlı ve lineer bir şekilde fazlalaşan gerilimin sonucu olarak, malzemenin koptuğu andaki gerilim büyüklüğü olarak tanımlanır. Psi veya N/mm^2 birimleri ile ifade edilir[32].

Tablo 3.2. Farklı Malzemelere Ait Kopma Mukavemetleri

Madde	PSI
Bakır	35.000
Pirinç (Yumuşak)	70.000
Pirinç (Sert)	130.000
Pirinç (%2 Alüminyum)	173.000
Molibden	280.000

Tablo 3.2’te farklı malzemelere ait kopma mukavemetleri gösterilmektedir. Burada bakır en düşük kopma mukavemetine sahip iken molibden en yüksek kopma mukavemetine sahiptir. Bu durumda, sadece kopma mukavemeti özelliğine bakıldığı zaman elektrot olarak kullanmak için molibden iyi bir seçim olabilir. Ancak sadece kopma mukavemeti özelliğine bakarak karar vermek doğru bir yöntem olmayacaktır. Bu yüzden bir tel elektrotta olması istenen diğer özelliklerin de göz önünde bulundurulması gerekmektedir.


2. **Hafıza:** Hafıza özelliği, telin “yumuşak veya sert” olma niteliğine bağlıdır. Tel “yumuşak” olduğunda, makaradan geçerken düzgün kalmaz. Bu durum kesme işlemi sırasında uygulanan gerilmeden dolayı önemsizdir. Ancak gevşeme durumunda otomatik bir şekilde tel takmaya çalıştığı durumlarda önemlidir, bu durumda sert bir tel kullanmak daha avantajlıdır. “Sert” teller yüksek kopma mukavemetine sahiptir[33].
3. **Uzama:** WEDM işlemi süresince, gerilme kuvvetleri ve termal kuvvetler sebebiyle birim uzunlukta meydana gelen yüzde değişimi uzama olarak tanımlanır. Yumuşak bir telde %20’ den daha fazla uzama görülebilirken, sert bir telde %2’ den daha az uzama görülebilmektedir. Yumuşak tel kesme işlemi sırasında, kılavuzların giriş çıkış noktaları üzerinde hareket ettirildiğinde daha az titreşim ortaya koymaktadır [33].

Termal Fiziksel Özellikler: Tellerin erime sıcaklığı ve buhar basıncı termal fiziksel özellikleridir. Elektro boşalım işlemi sırasında istenmeyen artıkları uzaklaştırmak ve bu sayede meydana gelecek kısa devreleri azaltmak için yarık ve boşluklar oluşturulur. Erime noktası bu noktada önemli bir özelliktir.

Kesim işlemi sırasında ortaya çıkan ısıнын birçoğu tel tarafından emilebilir veya kaybolabilir. Tel çekirdeği fazla ısı kaybettiğinde, telin gerilmesine bağlı olarak telde kopma meydana gelebilir. Bu durum kesme performansını olumsuz bir şekilde etkiler. İhtiyaç duyulan enerjinin iş parçasına bırakılabilmesi için telin hızlı buharlaşma özelliğine sahip olması beklenmektedir. Kısacası WEDM sürecinde düşük bir erime sıcaklığına ve yüksek buhar basıncına ihtiyaç duyulur. Tel erime noktasını geçip buharlaşmaya başladığında, kesim bölgesindeki eriyen parçacıkların yerine gazlar oluşur. Erime sıcaklığı düşük olduğu zaman, malzemeyi buharlaştırmak daha kolay hale gelecektir [33].


3.3.2. Tel Seçimi

Kullanılacak tel elektrotta olması gereken fiziksel özelliklerin yanı sıra işlenecek iş parçasının özelliklerine de dikkat edilmesi gerekmektedir. İş parçasının kalınlığı göz önünde bulundurularak tel seçimi yapılması gerekir. Şekil 3.5’te iş parçası ve kullanılacak tel çapları arasındaki ilişki gösterilmektedir. Şekilde gösterilenin aksine iş parçasının kalınlığına uygun olmayan tel kullanılırsa zaman ve maliyet konusunda problemler ortaya çıkacaktır.



Şekil 3.5. İş Parçası ve Tel çapı arasındaki ilişki

İş parçasının kalınlığının yanı sıra köşe çevrelerin yarıçapı yaklaşık sıfır dışbükey köşeleri yuvarlatır. İşlenmiş olukların genişliği tel çapından daha büyüktür. Bunun sebebi deşarj aralıklarıdır. Şekil 3.6’de de görülebileceği gibi, işlenmiş köşe çevrelerinin (radyüs) yarıçapı, işlenmiş olan oluğun genişliğinden daha büyük olan içbükey köşeleri yuvarlatılır.



Şekil 3.6. Köşe Radyüsüne Göre Tel Seçimi

Kesim işleminde ince tel elektrotlar kullanıldığında içbükey köşe radyüs limiti daha küçük olur. Aynı zamanda tele iletilen maksimum elektrik akımının azalmasına bağlı olarak, kesme hızı

ve kesilen plakaların maksimum kalınlıklarında azalma olur. Tablo 3.3'te tellerin çaplarına göre içbükey köşe radyüs limitleri gösterilmektedir.

Tablo 3.3. İçbükey köşe radyüs limitleri

Tel Çapı	İlk Kesim	Son Kesim
Ø 0.10	R0.1+	R0.07-R0.1
Ø 0.20	R0.2+	R0.11-R0.2
Ø 0.25	R0.25+	R0.14-R0.25
Ø 0.30	R0.3+	R0.17-R0.3

4. VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ

Günümüz teknolojisi hızlı bir şekilde ilerlemekte ve ilerleyişiyle birlikte her geçen gün gücü artmaktadır. Bu hızlı ilerleyiş ile insanların bilgisayar teknolojilerini kullanmaları sonucu yeryüzünde devamlı büyük veri yığınları oluşmaktadır. Bilgisayarların bilgi saklama kapasitelerinin artmasının yanı sıra bilgi kaydı yapılabilen alanların sayısı da artış göstermektedir. Fakat bilgisayar sistemlerinin ürettiği ve alanlarında sakladığı bu bilgiler üzerlerinde işlem yapılmadığı sürece anlamsız veriler olarak kalacaktır. Bu anlamsız veriler belirli amaçlar doğrultusunda işlendiğinde anlam kazanacaktır. Ham ve işlenmeden önce değeri olmayan veriyi bilgiye ve anlamlı hale dönüştürme işlemine veri madenciliği denilmektedir [34]. Verilerin çeşitliliği ve hacimlerinin artışıyla beraber “Büyük Veri” gibi kavramlar ortaya çıkmış, bu kavramlara çözüm bulabilmek adına Yapay zekâ sistemleri, makine öğrenmesi yöntemleri, veri madenciliği yöntemleri kullanılmaya başlanmış ve büyük verileri de inceleyerek çıkarımlar yapmaya çalışılmıştır[35]. Oluşan bu büyük veri yığınları içerisinde yapılan incelenmesi sonucu stratejik olarak alınması gereken pazarlama kararlarının doğru ve zamanında alınabilmesi, bu sayede birçok alanda kar elde edilmesi mümkün hale gelmektedir. Bu nedenle, bu gibi konularda araştırmacılara yardım sağlayacak veri madenciliği, makine öğrenmesi, yapay zekâ gibi sistemler önem kazanmış ve üzerinde çalışmaya değer hale gelmiştir [36]. Eğitimsel veri madenciliği topluluğu tarafından tanımlanan “Eğitimsel veri madenciliği, eğitim ortamından gelen benzersiz veri türlerini keşfetmek için yöntemler geliştirmek ve öğrencileri ve öğrendikleri ortamı daha iyi anlamak için bu yöntemleri kullanmak” ile ortaya çıkan bir disiplin sorunudur olarak tanımlanmaktadır. Eğitim, ülkenin ilerlemesi için vazgeçilmez bir unsurdur. Eğitim ortamında madencilik, eğitimsel veri madenciliği olarak adlandırılmaktadır. Eğitim veri tabanından bilgiyi keşfetmek için yeni yöntemler geliştirmekle ilgilenmektedir. Eğitimsel veri madenciliği, eğitim sisteminin bu sorunların üstesinden gelmesine yardımcı olabilecek bir dizi teknik sunmaktadır ve dolayısıyla ülkenin geleceği konusunda da etki sahibi olacak bir alan haline gelmektedir [37]. Bu kavramların yanı sıra zamanla “Veri hazırlama” diye bir konudan da bahsetmek gerekmektedir. Veri hazırlama, veri analizinin en temel aşamasıdır. Bundan dolayı ham verileri temizleme işlemiyle ilgili de sıklıkla araştırmalar ve geliştirmeler yapılmaktadır [38].

Bu konuda yapılan çalışmalar incelendiğinde, metin ve web madenciliği, fikir madenciliği, duygu analizi gibi konular için sınıflandırma, kümeleme ve yapay sinir ağları kullanıldığı görülmüştür[35]. Bir perakendeci işletme için işletmecinin müşterilere göre kişiselleştirilmiş satış hareketlerini içeren veri tabanından yararlanarak ayrıntılı ve göreceli ölçüm sonuçlarını içeren bir satış gerçekleştiren sistem karar ağaçları ile tasarlanmış ve işletmenin pazarlama stratejilerinde büyük çapta etki göstereceği tahmin edilmiştir[36]. Konuşma tanıma, sinyal tanıma, nesne algılama, metin işleme, görsel nesne tanıma ve ilaç keşfi gibi diğer birçok alandaki son teknolojiyi

önemli ölçüde geliştirmiştir. Geliştirilen bu sistemlerde günümüzün son teknolojileri arasında yer alan derin öğrenme kavramına ait yöntemlerden yararlanılmıştır [39]. Görüş madenciliği konusunda yapılan diğer bir çalışmada, görüş sahibinin tutumu, davranışları, duyguları gibi öznel bilgilerin çıkarılması için makine öğrenme yöntemleri üç temel başlıkta incelenmiştir. Öğreticili, yarı-öğreticili, öğreticisiz olarak ayrılan bu üç ana başlık için makine öğrenmesi yöntemleri uygulanarak güçlü ve zayıf yönleri tartışılmıştır [40].

4.1. Veri Madenciliği

Teknoloji hızlı bir şekilde gelişmekte ve bu hızlı ilerleyişe paralel olarak dünyada oluşan veri de artmaktadır. Bilgisayarların veri saklama kapasiteleri artmakta ve bununla beraber bu verilerin kaydedildikleri alanların sayısı ve büyüklükleri de azımsanamayacak hızda genişlemektedir. Bu genişleme ile işe yarar ve incelenebilir veriler olduğu gibi aynı zamanda anlamsız veriler de ortaya çıkmaktadır. Bilgisayar sistemleri ile üretilen veriler diğer verilerden bağımsız olarak tek başlarıyken bir anlam ifade etmemektedirler. Bu veriler çıplak gözle gözlemlendiğinde anlamsızdır fakat bu veriler belirli bir amaca yönelik işlendiğinde anlamlı hale gelmektedir [34].

Ham verilerin işlenmesi sonucu değerli verilerin elde edilmesi işlemine Veri Madenciliği denilmektedir. Ham verilerden değerli sonuçların elde edilmesiyle birlikte geleceğe yönelik doğru tahminlerde bulunabilmekte ve bu tahminler ile kurum, kuruluş veya bireysel olarak kazanımlar sağlanabilmektedir. Veri madenciliği uygulanacak verinin büyüklüğü veri madenciliği uygulamamıza engel değildir. Veri büyüyüp küçüldükçe başarımlar veya işlem süresi artıp azalabilmektedir fakat veri madenciliği işlemleri tamamlanabilir. Dolayısıyla bireylerin tek başlarına veya ekip olarak başaramayacakları işlemleri gelişen teknolojinin donatıları ile gerçekleştirilebilmekte ve veri madenciliği sonucunda her konuda büyük verimlilikler kazanılabilmektedir.

4.1.1. Veri Madenciliği Süreçleri

Ham verinin ve elde edilmek istenilen verinin büyüklüğüne bağlı olarak gerçekleşen süreçler zaman zaman değişiklik gösterse de genel olarak, Şekil 4.1’de de gösterilen veri madenciliği süreçleri şu şekildedir;

Veri Seçimi: Çözüm sağlamak istenen probleme ilişkin veriler seçilmelidir ve seçilen veriler iyi analiz edilmelidir. Seçim tamamlandıktan sonra gerçekleştirilen tüm aşamalar bu seçim üzerinden yürüyeceğinden dolayı kritik bir adımdır.

Ön İşleme ve Veri Temizleme: Bu aşama daima uygulanan bir aşama olmamakla birlikte tutarsız ve gürültülü verilerin işlenmesi adımıdır. Tutarsız veya gürültülü veri, veri seti içerisinde amaca uygun fakat bilgiyi elde etmeyi zorlaştıran unsurlar taşıyan verilere denilmektedir. Bu verilerin temizlenmesi aşamasında isteğe bağlı olarak bu veri kümesi tamamen atılabilmektedir. Ayrıca verinin veri kümesinden tamamen atılmasının istenmediği durumlarda yerine genel bir sabit veya ortalama değerler konulabileceği gibi ilgili değer tahmini de yine farklı veri madenciliği yöntemleriyle yapılabilmektedir.


Veri İndirgeme: Günümüzde teknoloji oldukça gelişmektedir fakat teknolojinin gelişimi zaman zaman verinin büyüklüğünden dolayı ilgili veri setine veri madenciliği uygulamaya yeterli olmayabilmektedir. Bu gibi büyük veri setlerine veri madenciliği uygularken sonuca etkisinin önemsenmeyecek derecede az olduğu düşünülen veri veya niteliklerin sayıları azaltılabilmektedir.

Veri Bütünleştirme: Veri madenciliği uygulanan veri setleri her zaman tek kaynaktan toplanmayabilmektedir. Farklı kaynaklardan toplanarak işlenmek üzere oluşturulan veri ambarına verilerin aktarılması safhasında aynı verinin farklı şekillerde ifade edilmesiyle karşılaşılabilir. Örnek olarak aynı veri ambarına kaydedilmek üzere farklı kaynaklardan alınan cinsiyet değerleri "K", "Kadın", "Female" olarak farklı şekillerde kayıt edilmiş olabilmektedir. Bu duruma çözüm olarak uygulanan Veri Bütünleştirme işleminde verilerin tamamı aynı şekilde kaydedilmelidir. Bu sayede bu şekilde eklenen veriler birbirinden farklı değil birbiriyle aynı değerleri ifade edecektir.

Veri Dönüştürme: Zaman zaman bazı verilere veri madenciliğini direkt uygulamak uygun olmayabilmektedir. Değişkenlerin ortalama ve varyant değerlerinin birbirlerinden önemli derecede farklı olması durumunda, ortalama ve varyant değerleri büyük olan verilerin tüm veri seti üzerindeki etkisi önemli derecede dengesizlik sağlamaktadır. Ayrıca benzer bir şekilde veri seti içerisindeki büyük veya küçük uç değerler sonuçların sağlıklı olmamasına yol açabilmektedir. Bu nedenlerden dolayı verinin tipine göre istenilen normalleştirme veya standartlaştırma algoritması kullanılarak dönüşümünün sağlanması ve bu şekilde veri madenciliğine devam edilmesi gerekmektedir.

Veri Madenciliği Aşaması: Sürecin önceki adımları sonucu ortaya çıkan veri seti kullanılarak, veri setinin tipi ve çalışmada ulaşılmak istenen amaca yönelik veri madenciliği yöntemi uygulanarak sonuca ulaşılmaktadır. Yöntemler çeşitli algoritmalar yardımı sonucu sonuç vermektedir, her algoritma kendine has karakteristik özelliklere ve veri giriş çıkış tipine sahiptir.

Yorumlama ve Doğrulama: Yöntemler sonucu elde edilen sonuçlar karşılaştırılır ve yorumlanır. Verinin amacına ve tipine göre en doğru algoritma tespit edilir [41].



Şekil 4.1. Veri Madenciliği Süreçleri

4.1.2. Sınıflandırma

Veriler istenilen sonuçlara göre farklı veri madenciliği yöntemlerinin uygulanmasını gerektirmektedir. Sınıflandırma işlemi bir veri kümesi üzerindeki sınıflar arasında veriyi dağıtma işlemidir. Sınıflandırma algoritmaları verilen eğitim veri seti üzerinden verinin sınıf içerisinde dağılım şeklini öğrenmektedir. Bu öğrenme işlemi sonrasında sınıfları belirli olmayan test verileri üzerinde doğru sınıflandırma işlemini gerçekleştirmeyi hedeflemektedir. Veri kümesi içerisinde verilen sınıfları temsil eden etiketler, eğitim test esnasında verilerin sınıflarının belirlenmesi amacıyla kullanılmaktadır.

Sınıflandırma algoritmalarının amaçları verilen veri kümesindeki eksik değeri doğru olarak tahmin etmektir. Belirlenen sınıflandırma algoritması ile birlikte tüm değerleri doğru olarak bilinen veri seti üzerinde eğitim gerçekleştirilir ve sonucunda yeni gelen verinin hangi sınıfa dâhil olduğunu tahmin etme işlemi yapılır. Üzerinde çalıştığımız veri setinin değişkenliğine göre geliştirilmiş sınıflandırma algoritmalarına, Destek Vektör Makinesi, Doğrusal Olmayan Destek Vektör Makinesi, Veri Akış Madenciliği, Naive Bayes Sınıflandırıcısı, Karar Ağacı Öğrenmesi, K-En Yakın Komşu örnek olarak verilebilmektedir [42].

4.1.3. Kümeleme

Veri kümesi içerisindeki verileri benzerliklerine göre belirli gruplar halinde düzenlemeyi hedeflemektedir. Kümeleme algoritmalarının en önemli bileşeni verilerin birbirlerine uzaklıklarıdır. Bu algoritmaların uygulanmasında kullanılan uzaklık ölçütlerinden en popülerleri Oklit, Minkowski ve Manhattan'dır. Bazı uzaklığı ölçülemeyecek verileri, veri dönüştürme işleminden geçirerek algoritmayı uygulamak gerekmektedir.

Kümeleme algoritmalarına, En Yakın Komşu Algoritması, En Uzak Komşu Algoritması, k-Ortalamalar Yöntemi örnek olarak verilebilmektedir [43].

4.1.4. Birliktelik Kuralları

Birliktelik kuralı, olayların beraber gerçekleşme durumlarını çözümleyen veri madenciliği yöntemlerine denir. Bu yöntem, diğer yöntemlerden farklı olarak durumun olma şartını belirli olasılıklarla ortaya koymaktadır. Eğitim verileri analiz edilerek bu veriler içerisindeki birliktelik davranışlarının tespiti sonucu test verilerinin sonuçları tahmin edilmektedir [44].

Birliktelik kuralı algoritmalarına; Apriori, Carma, Sequence, GRI, Eclat örnek olarak verilebilmektedir.

4.2. Makine Öğrenmesi

Bilgi teknolojilerinin yüksek hızda gelişmesi ve internetin yaygın olarak kullanılması ile birçok platformda verilerin türleri, çeşitliliği ve büyüklüğü hatırı sayılır şekilde artış göstermiştir. Verilerin artışı dolayısıyla Büyük veri kavramı ortaya çıkmış ve bu alanda çalışmalar ciddi manada artmıştır. Bu artış dolayısıyla bazı veri madenciliği yöntemlerinin yetersizliği ortaya çıkmış ve yerini makine öğrenmesi yöntemleri almaya başlamaktadır. Veri madenciliği ve makine öğrenmesi yöntemlerinin temel amacı verileri analiz ederek anlamlı bilgiler elde etmektir[35]. Elde edilen anlamlı bilgiler sonucunda hem birçok alandaki iş yüklerinde iyileştirmeler gerçekleştirilmiş, hem de bu yöntemler ile geliştirilen sistemler sayesinde birçok iş kolunda karar mekanizmasının insanların yerine gelişen bilgisayar sistemlerinde gerçekleştirilebilmesi sağlanmıştır.

Makine öğrenmesi yöntemlerinin ciddi anlamda kullanımı ile birlikte görüş madenciliği, metin madenciliği, fikir madenciliği, duygu analizi ve bunlarla birlikte birçok alanda çözümler üretilmeye devam edilmiştir [40]. Gerçekleştirilen bu çözümler sayesinde e-ticaret sitelerinde kişilerin satın almak isteyecekleri ürünler tahmin edilmekte ve karşılırları çıkarılmaktadır. Kişilerin sosyal medya paylaşım ve yorumları sonucu kişilerin psikolojileri, eylemleri de tahmin edilmektedir. Aynı zamanda sağlık sektöründe, otomotiv sektöründe, bilgisayar bilimlerinde, eğlence, pazarlama gibi çok çeşitli alanlarda da kullanımı görülmektedir.

4.2.1. Naive Bayes Sınıflandırıcı Algoritması

Naive Bayes Sınıflandırıcısı, birçok makine öğrenmesi algoritmasına göre büyük ölçüde basittir. Basit olmamasının temel sebeplerinden biri özelliklerin bağımsız verilen sınıflar olduğunu varsayarak öğrenmeyi gerçekleştirmesidir. Bağımsızlık genel olarak yöntemi zayıflattığı düşünülse de pratikte Naive Bayes Sınıflandırıcısı daha karmaşık sınıflandırıcılarla rekabet edebilmektedir [45].

Naive Bayes Sınıflandırma Algoritmasının formülizasyonu (4.1) numaralı denklemde gösterilmiştir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (4.1)$$

$P(A|B)$ = B olayı gerçekleştiğinde A olayının gerçekleşme olasılığı

$P(A)$ = A olayının gerçekleşme olasılığı

$P(B|A)$ = A olayı gerçekleştiğinde B olayının gerçekleşme olasılığı


$P(B)$ = B olayının gerçekleşme olasılığı

4.2.2. K-Ortalamalar Algoritması


K-ortalamalar yöntemi, aynı küme içerisindeki noktalar arasında ortalama kare mesafesini bularak çalışır. Ortalama kare mesafesini en aza indirmeyi amaçlayan bu kümeleme yöntemi genellikle yaygın kullanılan bir yöntemdir. Kümeleme yöntemlerinin genelinde olduğu gibi doğruluk konusunda garanti sunmayan K-ortalamalar Algoritması, basit ve hızlı olduğundan dolayı pratikte kullanıcılara çok cazip gelmektedir [46]. Kullanılan matematiksel yöntemle göre bir merkez belirlenmektedir. Belirlenen bu merkez her sınıfa uzaklığı ölçülerek, uzaklık değerine göre yeni kümeye yerleştirme işlemi gerçekleştirilmektedir. Şekil 4.2’de gösterilen kümesi belirlenmemiş bir veri kümesidir. Şekil 4.3’te ilgili veri kümesinin merkez noktaları belirlenir ve Şekil 4.4’te bu merkez noktalarına yakınlıklarına göre veriler bir kümeye dâhil olurlar. Şekil 4.5’te ise kümelerin dış çerçeveleri de çizilmiş olacaktır.

Algoritma temel olarak 4 aşamadan oluşur:


1. Küme merkezlerinin belirlenmesi
2. Merkez dışındaki örneklerin mesafelerinin ölçülmesi ve sınıflandırılması
3. Yapılan sınıflandırmaya göre yeni merkezlerin belirlenmesi
4. Merkezin artık değişmeyeceği duruma gelinene kadar 2. ve 3. adımların tekrarlanması




Şekil 4.2. Kümeleri belirlenmemiş veri kümesi



Şekil 4.3. Küme merkezlerinin belirlenmesi




Şekil 4.4. Verilerin merkeze yakın kümelerle aktarılması



Şekil 4.5. Küme sınırlarının belirlenmesi

4.2.3. Destek Vektör Makinesi

Genellikle yaygın olarak tıp, biyoinformatik alanlarında kullanılan Destek Vektör Makineleri (Support Vector Machine - SVM) bir sınıflandırma algoritmasıdır [47]. Hiper düzlem olarak adlandırılan karar sınırları belirleyerek sınıflandırma işlemini gerçekleştirmektedir. Destek vektör makinelerinin diğer sınıflama yöntemlerinden daha etkili ve güçlü olduğu ispatlanmıştır [48]. Şekil 4.6'da SVM algoritmasının uygulanması sonucunda sınıflandırılmış iki ayrı sınıf görülmektedir.



Şekil 4.6. SVM algoritması çalışma prensibi

$\{X_i, Y_i\}_{i=1}^n$ eğitim için örnek veri kümesi olduğunu varsayarsak; X_i girdi vektörü, $Y_i \in \{-1, +1\}$ ise sınıf etiketlerini temsil etmektedir [49]. Destek vektör makineleri, iki sınıf doğrusal olarak ayrılabilir olduğunda verilen verileri ayıracak en uygun $f(x) = 0$ sonucunu bulmaya çalışmaktadır [50].

$$f(x) = \langle \omega \cdot x \rangle + b = 0 \quad (4.2)$$

(4.2) numaralı denklemde, ω ağırlık vektörünü, b sapmayı belirtmektedir. ω ve b hiper düzlemi ayırma pozisyonunun tanımlanması için kullanılmaktadır. En iyi hiper düzlem (4.3) numaralı denklemdeki kısıtlı optimizasyon problemini çözerek bulunabilir:

$$\arg \min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (4.3)$$

$$s.t. y_i \langle \omega \cdot x_i + b \rangle \geq 1, i = 1, 2, 3, \dots, n.$$

Bir giriş vektörü ω olarak sınıflandırılan doğrusal karar fonksiyonu (4.4) numaralı denklemde görüldüğü gibi yazılabilir:

$$f(x) = \text{sign}(\sum_{i=1}^N \alpha_i y_i (x_i \cdot x) + b) \quad (4.4)$$

Destek vektör makineleri, $K(x_i, x_j)$ çekirdek fonksiyonu kullanılarak doğrusal olmayan sınıflandırmada da kullanılabilir. $K(x_i, x_j)$ değeri $\varphi(x_i) \cdot \varphi(x_j)$ 'ye eşittir. Burada $\varphi(x_i)$, giriş verilerini yüksek boyutlu özellik alanına dönüştüren dönüştürme işlevidir. Daha sonra, doğrusal olmayan karar fonksiyonu (4.5) numaralı denklemdeki gibi tanımlanabilir:

$$f(x) = \text{sign}(\sum_{i=1}^N \alpha_i y_i K(x_i, x) + b) \quad (4.5)$$

DVM başlangıçta ikili sınıflandırma için tasarlandığından, doğrudan çok sınıflı sınıflandırma ile ilgilenemez. Çok-sınıflı sınıflandırma problemleri çözülürken çoğunlukla problem iki-sınıflı problemlere ayrıştırılmaktadır. Sınıflandırma yöntemi olarak ikili ağaç mimarisi yaklaşımı sıklıkla kullanılmaktadır [51].

4.2.4. Doğrusal Regresyon

Regresyon analizi, sebep-sonuç ilişkisiyle birbirine bağlı olarak bulunan değişkenler arasındaki ilişkiyi, o konuda tahmin veya kestirimler yapmak amacıyla tasarlanan istatistiksel analiz tekniğidir. Regresyon analizinin en önemli bölümü, model oluşturulduktan sonra modelin yeterli olup olmadığının kontrol aşamasıdır. Regresyon analizinin tüm varsayımları sağlaması doğru modele yeterli derecede yaklaştığını garanti etmektedir[52].


4.2.5. Lojistik Regresyon

Lojistik regresyon analizi, bireylerin farklı gruplara ayrılarak sınıflandırılmasını amaçlamaktadır. Bireylerin hangi gruba üye olduğunu kestirmeyi hedeflemek için bir regresyon denklemi oluşturan bu yöntem, bağımsız değişkenlerin sürekli veya süreksiz olmalarına yönelik bir kısıtlama getirmemektedir. Aynı zamanda lojistik modele uygun oluşturulmuş denklemlerin analizini gerçekleştirecek SPSS (Statistical Package for the Social Sciences), SAS (Statistical Analysis System) gibi birçok paket program bulunmaktadır. Bu paket programlar sayesinde özellikle bankacılık ve sigortacılık alanlarında modeller kolaylıkla incelenebilmekte ve yorumlanabilmektedir [53].

4.2.6. Yapay Sinir Ağları

Geleneksel metotlar kadar başarımlı sağlayan hatta daha iyi neticeler verebilen Yapay Sinir Ağları, özellikle doğrusal olmayan zaman serisi problemlerinde başarımlı gösterdiği gözlemlenmiştir [54]. Yapay Sinir Ağları, aynı zamanda gelişen teknoloji ile birlikte artan veri miktarının zorlukları olarak görülen veri işleme ve hesaplama gücü konusunda karmaşık simülasyonların yapılması, yapay zekâ teknolojilerinde kullanılarak geleceğe dönük öngörülerini de mümkün hale getirmesi günümüzde daha sık kullanılmasının sebepleri arasında yer almaktadır [55].

Büyük ölçekli görüntülerde Evrişimli Sinir Ağları (CNN) hesaplama açısından genel olarak maliyetli olmaktadır. Maliyetli olmasının sebebi hesaplama miktarının görüntünün piksel değeriyle doğru orantılı olarak artıyor olmasıdır [56]. Dolayısıyla işlem yapmak istediğimiz resim büyüdükçe piksel değerlerinin sayısal olarak artmasıyla birlikte ağırlık derinliği de artmakta ve işlem yükü ile ağırlık çalışma süresi de doğru orantılı olarak uzamaktadır. Büyük ölçekli görsel tanıma problemleri için derin öğrenme algoritmalarının arasında en gelişmiş çözümlerden biri olarak görülmektedir [57].




Şekil 4.7. CNN algoritması çalışma sıralaması örneği

Sinir biliminden kısmen esinlenen CNN algoritması, algoritmanın genel yapısında beynin görsel sistemi gibi çalışmayı hedeflemektedir. Göze çarpan en temel fark ise beynin görsel sisteminde tekrarlayan bağlantılar fazla iken, CNN'nin kendini tekrar eden bir ileri besleme mimarisi sayesinde sonuca ulaşmaya çalışmasıdır [58]. Şekil 4.7'de verilen bir CNN ağı örneği ile de görülebileceği gibi sürekli kendini beslemesi üzerine çalışan algoritma sonuca bu şekilde ulaşmaktadır. Bu tür problemlerin derin öğrenme algoritmaları ile çözülmesi konusunda önemli bir yeri tutan CNN algoritması iyi sistemler ile çalıştırıldığında mükemmel sonuçlar verebilmektedir [59]. Pratikte uygulaması her geçen gün iyileşen algoritmalar sonucu kolaylaşan algoritma ileri beslemeli mimarisi ile özellikle video ve resim tanıma konusu olmak üzere birçok alanda başarı ile kullanılan güncel bir algoritma haline gelmiştir.

Tekrarlayan Sinir Ağları (RNN) genel hatları ve kullanımı açısından CNN algoritması ile benzerlik göstermektedir. Genelde resim video işleme konularında kullanılan bu algoritma, CNN gibi kendini besleyen yapısı ile birlikte öğrenme işlemini gerçekleştirmektedir ancak CNN'nin aksine hesaplama miktarı girişin boyutundan bağımsız olarak artmaktadır [56].

Uzun Kısa Süreli Bellek (LSTM) algoritması bellek tabanlı bir sinir ağı algoritması olduğundan dolayı karmaşık ve daha uzun soluklu problemlerde başarımı yüksek görülmektedir. Konuşma tanıma, el yazısı tanıma veya müzik modelleme gibi birçok alanda yüksek başarımlar sağlamaktadır [60]. Genelde derin sinir ağları zor öğrenme problemlerinde mükemmel performanslar elde ettiği bilinmektedir ve LSTM bu algoritmaların başını çekmektedir. Birçok algoritmayla karşılaştırıldığında, LSTM çok daha başarılı sonuçlara yol açar ve çok daha hızlı öğrenir [61].



Şekil 4.8. LSTM algoritması çalışma örneği

Şekil 4.8'de örnek olarak verilen yapıda da görüldüğü gibi benzeri sinir ağı algoritmaları gibi devamlı olarak kendini tekrarlayan yapısı sayesinde öğrenme konusundaki problemlerde başarılı olmaktadır. Problemin kendisiyle bağlantılı olarak uzun veya kısa süreli öğrenme gerçekleştirerek benzer kuldarda yarıştığı algoritmalara göre bazı problemleri çok daha hızlı ve stabil çözebilme yeteneğine sahiptir.

4.2.7. Uç Öğrenme

Uç öğrenme makineleri, gizli düğümlerin parametrelerine ihtiyaç duyan ileri beslemeli bir sinir ağıdır. Tek bir katmanda veya birden fazla gizli düğüm katmanı ile regresyon, sınıflandırma, kümeleme, sıkıştırma ve özellik öğrenme için kullanılır. Öğretim süreci sırasında, uç öğrenme makineleri, katmanlar arasındaki ilişkileri yani gizli düğümlerin parametrelerini öğrenir. Düğümlerin parametreleri, Gizli düğümlerin genel tanınmış özelliklerini kullanarak, gizli düğümlere bağlayan ağırlıklarında en iyi sonuçlar elde etmeye çalışırlar. Uç öğrenme makineleri, gizli düğümlerin içindeki gizli düğümlerin tanınmış özelliklerine bağlı olarak artan ağırlıklar verirler. Diğer bir deyişle gizli düğümlerin tanınmış özellikleri, düğümlerin parametrelerinin değiştirilmesi ile değişir. Genellikle bir uç öğrenme makinesi, düğümleri, iki katmana göre tanımlar. Birinci katman, gizli düğümleri, iki katmana göre tanımlar. İkinci katman gizli düğümleri birbirlerine göre tanımlar. Hedef düğüm her iki katmanın gizli düğümleri için değişken bir ağırlık olarak tanımlanır. İki katmanın her birinin gizli düğümleri, hedef düğüm için verilen ağırlıkların yükseltilmesine yardım eder. Ardından gizli düğümlerin tanımlanmasının hedef düğüm için verilen ağırlıkların yükseltilmesine yardım etmesini ve hedef düğümün tanımlanmasını sağlamak için, hedef düğümün tanımlanmasına yardım etmesi gereken, gizli düğümlerin tanımlanmasıdır. Bu gibi çeşitli katmanlı sistemlerin gelişimi, öğretim sürecinde, gizli düğümlerin tanımlanmasına yardım etmek için, gizli düğümlere göre, öğrenme yoluyla gerçekleşmektedir. Gizli düğümleri tanımlayan, parametrelerinde değişiklikler yapar. Bu değişiklikler, gizli düğümlerin tanımlanmasını katılaştırır. Bu yöntemi, öğrenen bir uç öğrenme makinesi olarak kullanmak için, gizli düğümlerin tanımlanmasını tanımlayan, parametrelerinde değişiklik yapmak gerekmektedir. Bu değişiklikler, gizli düğümlerin tanımlanmasını kararlaştırılır [6,62].

4.2.8. Karar Ağaçları

Gelişen bilgisayar teknolojisi dolayısıyla işletmelerde veri yığınları oluşmaktadır. Hemen hemen her alanda kararların doğru ve zamanında alınabilmesi birçok konuda fayda sağlamaktadır. Bu faydadan en kolay şekilde yararlanabilmek için verilerin en iyi şekilde analiz edilmesi ve anlamlı hale getirilmesi gerekmektedir ve bunu sağlayacak güçlü veri madenciliği yöntemlerine ihtiyaç duyulmaktadır. Veri madenciliği yöntemlerinin tahmin modeli oluşturma safhasında en yaygın kullanılan ve etkili olarak değerlendirilen yöntemlerinden biri karar ağaçlarıdır. Karar ağaçları, hedef fonksiyonları yaklaşık olarak hesaplamaktadır. Öğrenme fonksiyonunun sonucunda sonuçlar karar ağacı üzerinde gösterilmektedir [36].

4.2.9. Rastgele Ormanlar

2001 yılında Leo Breiman tarafından geliştirilen Random Forests (Rassal/Rastgele Orman) algoritması sınıflandırma değerini yükseltmek için, sınıflandırma işlemi sırasında birden fazla karar ağacı üreten bir topluluk öğrenme yöntemidir [63]. Oluşturulan her bir karar ağacı bir arada karar ormanı adını verdiğimiz yapıyı oluşturur. Karar ormanı denilen yapıya yeni ağaçlar yani veri kümeleri eklendikçe, test verilerine ait hata tahminleri daha düşük sonuçlar vermeye başlar. Astronomi, yazılım geliştirme, sağlık, finans analizi, fizik gibi oldukça geniş bir uygulama alanına sahiptir [64].

4.2.10. En Yakın Komşular

Birçok bilgisayar görme problemi için, en çok zaman alan bileşen, yüksek boyutlu alanlarda eşleşen en yakın komşudan oluşur. Bu yüksek boyutlu problemler doğrusal aramadan daha hızlıdır. Fakat bu problemleri çözecek algoritmalar yoktur. Basit ve gürültülü veri setleri üzerinde etkili olması sebebiyle günümüzde en popüler makine öğrenmesi algoritmaları arasında yer almaktadır. Ancak, uzaklık hesabı yaparken bütün olasılıkları hafızasına kaydetme gereksiniminden dolayı büyük sistem gereksinimleri gerektirmektedir. En yakın komşu arama problemi, makine öğrenimi, belge geri çağırma, veri sıkıştırma, biyoinformatik ve veri analizi gibi diğer birçok uygulamada da büyük önem taşımaktadır [65].

5. MATERYAL VE METOT


Araştırmamızda Al7075 alüminyum alaşımı WEDM ile farklı parametrelerde işlenmiş ve yüzey pürüzlülük değerleri deneysel olarak belirlenmiştir. Toplam 81 farklı yüzey pürüzlülüğü verisi elde edilmiştir. Elde edilen yüzey pürüzlülük değerleri, ELM, W-ELM, SVR ve Q-SVR gibi farklı makine öğrenme yöntemleri kullanılarak tahmin edilmiştir. Modellerin performans analizi için 10 k-kat yöntemi kullanılmıştır [66].

5.1. VERİ TOPLAMA

Bu çalışmada iş parçası malzemesi olarak 10 mm çapında Al7075 T6 alüminyum alaşımı kullanılmıştır. Al7075'in kimyasal bileşimi Tablo 5.1'de gösterilmektedir. Talaşlı imalat sürecince Sodick SL400Q marka WEDM makinesi kullanılmıştır. İş parçası Şekil 5.1'deki gibi WEDM üzerine sabitlenmiştir. Tablo 5.2'de verilen parametreler kullanılarak Şekil 5.2'de gösterildiği gibi işlem gerçekleştirilmiştir. Her parametrede 5 mm'lik bir parça kesilmiş ve tüm işlenmiş numuneler Şekil 5.3'de görülmektedir. Numunelerin yüzey pürüzlülük değerleri, Mitutoyo SJ-201 profilometre ile işlenmiş yüzeylerin dikey ve yatay yönünde ölçülmüştür. Yüzey pürüzlülük ölçümleri 0,8 mm uzunluğundan düşey ve yatay yönde 6 farklı mesafede alınmıştır. Bu ölçümlerin ortalaması hesaplanarak yüzey pürüzlülük değerleri belirlenmiştir. Deneylerde kullanılan numunelerin yüzey pürüzlülük değerleri Şekil 5.4, Şekil 5.5, Şekil 5.6, Şekil 5.7, Şekil 5.8, Şekil 5.9, Şekil 5.10, Şekil 5.11 ve Şekil 5.12'de gösterilmektedir. Şekil 5.13'de ise tüm sonuçların genel grafiği gösterilmektedir. En düşük yüzey pürüzlülük değeri, 8 V gerilimde, 8 µs darbe zamanında, 25 bar dielektrik basınçta ve 2 mm/dk. tel besleme ile işlenmiş numunede 2.490 olarak ölçülmüştür. En yüksek yüzey pürüzlülük değeri ise 4 V gerilim, 8 µs darbe zamanı, 50 bar dielektrik basınç ve 6 mm/dk. tel besleme ile işlenen numunede 3.177 olarak ölçülmüştür. Düşük tel besleme ve dielektrik basınçta yüzey pürüzlülük değerleri daha düşük olduğu gözlemlenmiştir [66].

Tablo 5.1. Al7075 alüminyum alaşımının kimyasal bileşimi [66]

Element	Al	Si	Fe	Cu	Mn	Mg	Çinko	Cr	Diğer
İçerik (%)	Bal	0.4	0.5	1.2-2.0	0.3	2.1-2.9	5.1-6.1	0.18-0.28	0.25



Şekil 5.1. Deneysel Kurulum [66]



Şekil 5.2. İş Parçasının işlenmesi [66]


Tablo 5.2. Alüminyum Alaşımının İşleme Parametreleri [66]

Örnek Numarası	Gerilim (V)	Darbe Süresi (µs)	Dielektrik Basınç (Bar)	Tel Besleme (m/dk)	Sabit Parametreler
1	4	4	25	2	
2	8	4	25	2	
3	12	4	25	2	
4	4	8	25	2	
5	8	8	25	2	
6	12	8	25	2	
7	4	12	25	2	
8	8	12	25	2	
9	12	12	25	2	
10	4	4	50	2	
11	8	4	50	2	
12	12	4	50	2	
13	4	8	50	2	
14	8	8	50	2	
15	12	8	50	2	
16	4	12	50	2	
17	8	12	50	2	
18	12	12	50	2	


19	4	4	75	2	
20	8	4	75	2	
21	12	4	75	2	
22	4	8	75	2	
23	8	8	75	2	
24	12	8	75	2	
25	4	12	75	2	
26	8	12	75	2	
27	12	12	75	2	
28	4	4	25	4	
29	8	4	25	4	
30	12	4	25	4	
31	4	8	25	4	
32	8	8	25	4	
33	12	8	25	4	
34	4	12	25	4	Tepe
35	8	12	25	4	Akımı:2215A
36	12	12	25	4	Darbe
37	4	4	50	4	Kapanma
38	8	4	50	4	Süresi:0,15 µs
39	12	4	50	4	Tel
40	4	8	50	4	Gerilimi:1600g
41	8	8	50	4	MAO:254
42	12	8	50	4	
43	4	12	50	4	Tel Elektrot
44	8	12	50	4	Malzemesi:
45	12	12	50	4	Pirinç
46	4	4	75	4	Tel Elektrot
47	8	4	75	4	Çapı:0.25mm
48	12	4	75	4	

49	4	8	75	4
50	8	8	75	4
51	12	8	75	4
52	4	12	75	4
53	8	12	75	4
54	12	12	75	4
55	4	4	25	6
56	8	4	25	6
57	12	4	25	6
58	4	8	25	6
59	8	8	25	6
60	12	8	25	6
61	4	12	25	6
62	8	12	25	6
63	12	12	25	6
64	4	4	50	6
65	8	4	50	6
66	12	4	50	6
67	4	8	50	6
68	8	8	50	6
69	12	8	50	6
70	4	12	50	6
71	8	12	50	6
72	12	12	50	6
73	4	4	75	6
74	8	4	75	6
75	12	4	75	6
76	4	8	75	6
77	8	8	75	6
78	12	8	75	6


79	4	12	75	6
80	8	12	75	6
81	12	12	75	6




Şekil 5.3. WEDM ile İşlenmiş Al7075 Alüminyum Alaşımları [66]




Şekil 5.4. Numune 1-9 yüzey pürüzlülükleri [66]




Şekil 5.5. Numune 10-18 yüzey pürüzlülükleri [66]




Şekil 5.6. Numune 19-27 yüzey pürüzlülükleri [66]




Şekil 5.8. Numune 37-45 yüzey pürüzlülükleri [66]




Şekil 5.7. Numune 28-36 yüzey pürüzlülükleri [66]




Şekil 5.9. Numune 46-54 yüzey pürüzlülükleri [66]




Şekil 5.10. Numune 55-63 yüzey pürüzlülükleri [66]



Şekil 5.11. Numune 64-72 yüzey pürüzlülükleri [66]



Şekil 5.12. Numune 72-81 yüzey pürüzlülükleri[66]



Şekil 5.13. Numune 1-81 yüzey pürüzlülük değerleri [66]

5.2. ÖNERİLEN MODELLER

5.2.1. Destek Vektör Regresyon Makinesi

Destek Vektör Makinesi (SVM), regresyon ve sınıflandırmaya yönelik farklı bir denetimli öğrenme yaklaşımıdır [67,68]. Drucker ve ark. 1997'de regresyon problemlerinin çözümü için Destek Vektör Regresyon Makinelerini (SVR) tanımlamıştır [69]. SVR, yapısal risk minimizasyonu (SRM) ilkesini [70] kullanır ve birçok araştırma alanında başarıyla uygulanabilir. SVR, Linear, RBF, Gaussian, Polynomial [71] gibi farklı çekirdekler kullanılmaktadır. Problem alanı ve veri seti, çekirdek tiplerini ve fonksiyon parametrelerini tanımlamaktadır [72]. Bir problemin girdileri ve bu problemin hesaplanan/gözlenen çıktıları veri setinin yapısını oluşturmaktadır [73]. Tasarlanan SVR modelinde kullanıma en uygun çekirdek tipinin seçimi veri setinin yapısına bağlıdır [74].

Giriş vektörü, n-boyutlu deneysel veri kümesine göre ayarlanır ve giriş vektörü olarak kullanılır. Çıktı vektörünün tek boyutlu bir hedef vektörü vardır. $X = \{x_1, x_2, \dots, x_n\}$ giriş vektörünü temsil eder ve $T = \{t_1, t_2, \dots, t_n\}$ çıktı vektörünü temsil eder [75].

$$f(x) = w^T \varphi(x) + b \quad (5.1)$$

NS $\varphi(x)$ doğrusal olmayan bir fonksiyondur, b önyargı değeridir ve w^T ağırlık vektörüdür. SVR'nin amacı, x değerlerini en düşük regresyon riskini gösteren değerlere indirgeyen w ve b değerlerini bulmaktır ve (5.1) numaralı denklemi ile temsil edilir. Hatayı azaltmak için ise (5.2) numaralı denklem kullanılabilir.

$$\text{Minimize}_{w,b} \frac{1}{2} w^T + C \sum_{i=1}^l \xi_i + \xi_i^* \quad (5.2)$$

C değeri, öğrenme makinesinin karmaşıklığını belirler. Büyük C değeri, makineyi daha karmaşık hale getirirken doğruluğu artırır [72]. Eğitilmiş SVR modeli, (5.3) numaralı denklemi kullanarak tahminler oluşturur.

$$f(x) = \sum_{i=1}^l \theta_i \varphi(x, x_i) + b \quad (5.3)$$

Bu çalışmada kullanılan veri seti, ikinci dereceden çekirdek fonksiyon s ile daha iyi sonuçlar vermektedir. İkinci dereceden çekirdek işlevi (5.4) numaralı denklem ile verilmiştir.

$$L_{quad}(f(x) - y) = (f(x) - y)^2 \quad (5.4)$$

5.2.2. Uç Öğrenme Makinesi

Yapay sinir ağları (ANN), yüksek uyumluluğu nedeniyle birçok farklı araştırma alanında kullanılmaktadır. ANN'nin birçok araştırma alanında kullanılmasının nedeni, herhangi bir problem uzayında kabul edilebilir sonuçlar üreten modelleri eğitebilme yeteneğidir [76]. Ancak ANN'nin eğitim yöntemiyle bir dezavantajı vardır. Eğitim ve hata azaltma işlemi iterasyonlarla gerçekleştirilir. Yinelemeler gecikmelere neden olur. Uç Öğrenme Makineleri (ELM), öğrenme süreci gecikmelerini ortadan kaldırmak için tek gizli katmanlı ileri beslemeli ağlar (SLFN'ler) olarak geliştirilmiştir [62]. Kısa öğrenme süresi nedeniyle, ELM yaygın SLFN türüdür. ELM, girdi ağırlıklarını ve gizli önyargıları belirlemek için daha fazla gizli nörona ihtiyaç duyar [62]. Tek çıkışlı bir ELM modeli (5.5) numaralı denklemdeki gibi ifade edilebilir.

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = h(x) \beta \quad (5.5)$$

Burada $\beta = [\beta_1 \dots \beta_L]$ çıktı ağırlıkları vektörüdür. $h(x)$, ise çıktı vektörüdür. L , 1-boyutlu gizli katmanı temsil eder. ELM' in amacı eğitim hatasını ve katmanlar arasındaki gizli nöron sayısını azaltmaktır. (5.6) numaralı denklem minimizasyonu temsil etmektedir.

$$\text{Minimize: } H^t T^2 \quad (5.6)$$

$x_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}]^T$, girdi matrisi parametrelerini temsil ederken, $y_i = [y_{i1}, y_{i2}, y_{i3}, \dots, y_{im}]^T \in R^m$ çıktı matrisi parametrelerini temsil eder. ELM çıktı matrisini yinelemeler olmadan hesaplamak için kullanılan Moore-Penrose genelleştirilmiş ters matrisidir [77]. (5.7) ve (5.8) numaralı denklemlerde görülebileceği gibi, Y matrisi çıkış vektörünü temsil eder. Gizli katman çıktı matrisi ise (5.9) numaralı denklemde gösterilmiştir.

$$\beta = \begin{bmatrix} \beta_1^T \\ \dots \\ \beta_M^T \end{bmatrix}_{M \times 1} \quad (5.7)$$

ve

$$Y = \begin{bmatrix} y_1^T \\ \dots \\ y_N^T \end{bmatrix}_{N \times 1} \quad (5.8)$$

$$\beta = H^+ Y \quad (5.9)$$

Burada H^+ , H matrisinin Moore-Pensore genelleştirilmiş tersini temsil etmektedir. Ağırlık matrisi β yukarıdaki eşitliği kullanarak hesaplanabilir.

5.2.3. Ağırlıklı Uç Öğrenme Makinesi

ELM ve Ağırlıklı ELM (WELM) karşılaştırıldığında, WELM'nin doğruluk oranını arttırdığı gözlemlenmiştir. Ayrıca bu artış sırasında ELM'nin avantajı olan "kısa süreli eğitimde" herhangi bir kayıp yaşanmamaktadır [78]. WELM yöntemi genellikle ELM'den daha iyi sonuç vermektedir.

- ELM, minimum norm ile en küçük kareler çözümlerini hesaplar. Bu yüzden kontrol etmek zordur.
- ELM, ampirik risk azaltma kuralına dayanmaktadır. Bu yöntem, aşırı takılan modellere neden olabilmektedir.

5.2.4. Değerlendirme Parametreleri

Regresyon problemlerinin çözümünde kullanılan makine öğrenmesi tekniklerinin sonuçlarının performansını analiz etmek için değerlendirme metrik yöntemleri vardır. Bu metriklerden üçü, tasarlanan modellerin performansını değerlendirmek için kullanılmıştır. Bunlar; çalışmada belirleme katsayısı (R^2), ortalama mutlak hata (MAE) ve ortalama karekök hata ($RMSE$) olarak kullanılmıştır. Bu istatistiksel performans ölçütlerinin her

biri, önerilen modelin performansı hakkında farklı bir bakış açısıyla bilgi sağlamaktadır [72]. Tablo 5.3’de kullanılan performans metriklerine ait istatistiksel denklemler gösterilmektedir. E_i deneysel veriyi temsil ederken, P_i ise modellere ait tahmin değerlerini temsil etmektedir.(5.10) numaralı denklemdeki gibi, bütün deneysel verilerin ortalaması $\bar{E}$ ile ifade edilir.

$$\bar{E} = \frac{1}{n} \sum_{i=1}^n E_i \quad (5.10)$$

Tablo 5.3. Değerlendirme Metriklerinin Formülasyonları [66]

Performans Metrikleri	Denklemler
Belirleme Katsayısı (R^2)	$R^2 = 1 - \frac{\sum_{i=1}^n (E_i - P_i)^2}{\sum_{i=1}^n (E_i - \bar{E})^2}$
Ortalama Mutlak Hata (MAE)	$MAE = \frac{\sum_{i=1}^n E_i - P_i }{n}$
Kök Ortalama Kare Hatası (RMSE)	$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - P_i)^2}{n}}$

6. BULGULAR VE TARTIŞMA

Bu çalışmada, WEDM yöntemi ile farklı parametreler göz önünde bulundurularak Al7075 alüminyum alaşımının işlenmesi sonucu yüzey pürüzlülük değerinin ELM, W-ELM, SVR ve Q-SVR gibi farklı makine öğrenme yöntemleri kullanılarak tahmin edilmesi gerçekleştirilmiştir. Gerçekleştirilen bu tahminleme sonucu elde edilen sonuç şekil ve tablolarına yer verilmiştir.

Alüminyum alaşımlarının yüzey pürüzlülük değerleri deneylerden elde edilen WEDM ile makine öğrenmesi yöntemleri ile kabul edilebilir performansa ulaşılmaya çalışılmıştır. Makine öğrenmesi yöntemleri ile karmaşık deneyler ve matematiksel işlemler yapılmadan yüksek doğrulukla modellenmiştir [66]. Önerilen model ile yeni veri setlerinin tahmini çok kolay, hızlı ve düşük hata ile hesaplanacaktır. Bu çalışmada birden fazla model önerilmiş ve bu modeller arasında karşılaştırmalı performans analizi yapılmıştır. Temel olarak iki farklı yöntem kullanılmıştır. Bunlardan biri ELM, diğeri SVR idi. İki yöntem arasındaki temel fark, eğitim süreleridir. ANN algoritmasından farklı olan ELM'nin iteratif olmayan eğitim yöntemi, eğitim sürelerini önemli ölçüde azaltmıştır. SVR, bir risk minimizasyon yöntemiyle yinelemeli eğitim sağlar.


Modellerin performansını analiz etmek için iki farklı yöntem vardır. Bunlardan biri k-kat, diğeri ise verileri yüzde olarak ayırmaktır. Bu çalışmada, veri setinin test kısmı, 10-k-katlama yöntemi ile 10 ayrı parçaya ayrılan her parça tek tek denenmiştir. Bu yöntem, eğitim ve test kısmı için verilerin ayrılmasından daha doğru sonuçlar verir.


Yöntemlerin eğitim başarısı genellikle veri setine bağlıdır. Bir yöntemin her veri kümesinde her zaman yüksek doğrulukla çalışacağı iddia edilemez. Bu nedenle bu çalışmada birden fazla farklı algoritma ve birden fazla model denenmiştir. Yüzey pürüzlülüğünü tahmin etmek için ELM, W-ELM, SVR ve Q-SVR kullanılmıştır. Deney setinden ölçülen 81 veri bu 4 farklı modele uygulanmıştır. Bu modellerde voltaj (V), darbe süresi (μ s), dielektrik giriş parametreleri olarak basınç (bar) ve tel besleme (m/dak.), çıkış parametreleri olarak ise yüzey pürüzlülüğü (μ m) kullanılmıştır. Modellerin her biri performans parametreleri ile analiz edildiğinde, W-ELM modelinin diğer tüm modellerden daha iyi sonuçlar elde ettiği rahatlıkla görülebilmektedir. W-ELM, en yakın R^2 değerine sahip Q-SVR'den %1,07 daha iyi sonuçlarla 0.9720'de R-kare değerini tahmin etmiştir. Ayrıca hataların karelerinin toplamının toplam örnek sayısına oranı ile bulunan W-ELM'nin, RMSE değerleri üzerinden bir karşılaştırma yapıldığında ELM, SVR ve Q-SVR modellerinden daha iyi sonuçlar verdiği görülmüştür. Sırasıyla %21,38, %44,34 ve %2,93 başarımlar elde edildiği Tablo 6.1'de gösterilmiştir.

Tablo 6.1. Eğitilmiş Modellerin Değerlendirme Metrikleri Sonuçları [66]


Model Adı	Kernel	R^2	RMSE	MAE
ELM	Sigmoidal	0.9411	0.0463	0.0357
W-ELM	Sigmoidal	0.9720	0.0364	0.0320
SVR	Lineer	0.8824	0.0654	0.0531
Q-SVR	Quadratic (2.dereceden)	0.9613	0.0375	0.0330

Şekil 6.1, Şekil 6.2, Şekil 6.3 ve Şekil 6.4’de tasarlanan modeller tarafından yapılan tahmini ve deneysel sonuçlardan ölçülen değerleri göstermektedir. Şekil 6.1, ELM model sonuçları ve deneysel sonuçların karşılaştırmasını verir. Şekil 6.2’de W-ELM modelinin hemen hemen tüm deneysel sonuçlara uyduğu görülmektedir. Şekil 6.3 incelendiğinde, SVR modelinin performans değerlerinin deneysel sonuçlarla uyumsuz bir grafik gösterdiği görülmektedir. Bu grafik, SVR hataları hakkında bilgi sağlar. Q-SVR model sonuçları, Şekil 6.4’deki deneysel sonuçlarla karşılaştırılmıştır. Şekil 6.5’de tüm modellerin tahmini ile uyumlu bir regresyon grafiği sunulmaktadır. Şekil 6.6’da ise tüm model sonuçlarının deneysel sonuçlarla karşılaştırması gerçekleştirilmiştir.


**Şekil 6.1.** Deneysel sonuçların ELM Modeli sonuçları ve hataları ile karşılaştırılması [66]




Şekil 6.2. Deneyisel sonuçların W-ELM Modeli sonuçları ve hataları ile karşılaştırılması [66]




Şekil 6.3. Deneyisel sonuçların SVR Modeli sonuçları ve hataları ile karşılaştırılması [66]



Şekil 6.4. Deneyisel sonuçların Q-SVR Modeli sonuçları ve hataları ile karşılaştırılması [66]



Şekil 6.5. Modellerin regresyon sonuçları a) ELM Modeli regresyonu b) W-ELM Modeli regresyonu c) SVR Modeli regresyonu d) Q-SVR Modeli regresyonu [66]



Şekil 6.6. Tüm modellerin sonuçlarının deneysel sonuçlarla karşılaştırılması [66]

8. SONUÇLAR

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) MF.19.52 protokol numaralı proje ile desteklenmiştir. Bu bağlamda, FÜBAP destekleri ile birlikte “Surface roughness prediction of machined aluminum alloy with wire electrical discharge machining by different machine learning algorithms” çalışması yayımlanmıştır.

En düşük yüzey pürüzlülüğü değeri 2.490, en yüksek yüzey pürüzlülüğü değeri 3.177 olarak ölçülmüştür. Numunelerin yüzey pürüzlülüğü değişen parametrelerden etkilenmiş ve düşük tel besleme ve dielektrik basınçta yüzey pürüzlülük değerleri daha düşük olmuştur. Havacılık, uzay ve otomotiv sektörlerinde tercih edilen alüminyum alaşımları hafif olmalarına göre yüksek mukavemet ve dayanıklılığa sahiptir. Tel elektrik deşarj işleme gibi geleneksel olmayan yöntemlerle alüminyumun hassas işlenmesi (WEDM) popüler bir yaklaşımdır. WEDM ile işlenmiş yüzeylerin yüzey pürüzlülüğünün deneysel olarak belirlenmesi zaman alıcı ve maliyetlidir. Bu çalışmada çok önemli olan bu maliyetlerin minimize edilmesi makine öğrenmesi algoritmaları ile aşağıdaki performans oranı ile sağlanmıştır. WEDM ile işlenmiş alüminyum alaşımlarının yüzey pürüzlülük değerleri, ELM, W-ELM, SVR ve Q-SVR makine öğrenmesi yöntemleri kullanılarak tasarlanan modeller ile başarılı bir şekilde tahmin edilmiştir. R^2 değeri 0,9411, 0,9720, 0,8824 ve 0,9613 olan, ELM, W-ELM, SVR ve Q-SVR makinesi sırasıyla uygulanan öğrenme yöntemleridir. W-ELM en yüksek performansa sahiptir ve 0.9720 R^2 değeri ile yüzey pürüzlülüğünü tahmin etmiştir. W-ELM modelinin RMSE değeri 0.0364 olarak hesaplanmıştır. Bu çalışma sonucunda, işlenmiş alüminyum alaşımlarının yüzey pürüzlülüğünün WEDM ile tahmin edilmesi için makine öğrenmesi yöntemlerinin kullanımının %2,8 gibi düşük bir hata oranı ile mümkün olduğu görülmüştür. Geliştirilen makine öğrenme algoritması modeli, karmaşık matematiksel işlemlere veya yüksek doğrulukla uzun ve maliyetli deneylere gerek kalmadan sahada çalışan herkes tarafından kullanılacaktır. İmalat endüstrisinde yüzey pürüzlülüğünü tahmin etmek için W-ELM yöntemini kullanarak, iyi yüzey özelliklerine ve yüksek boyutsal hassasiyete sahip parçaların imalatında deneysel süreyi ve maliyeti azaltabilir. Yeni bir parça tasarlarlarken önerilen modelleri kullanarak tasarım mühendisleri tasarım avantajları sağlayabilecek ve yeni bir tasarım yaparken zaman kısılacaktır.

ÖNERİLER

Özellikle havacılık, uzay ve otomotiv sektörlerinde tercih edilen alüminyum alaşımları hafif olmalarına rağmen yüksek mukavemet ve dayanıklılığa sahip olmaları dolayısıyla üzerinde çalışması önem arz eden malzemelerdir. Alüminyum alaşımlarının sanayi alanındaki bu önemli yeri göz önünde bulundurularak gerçekleştirilen bu çalışmada ELM, W-ELM, SVR ve Q-SVR makine öğrenmesi yöntemleri kullanılarak yüzey pürüzlülük değerinin tahmini gerçekleştirilmiştir. Elde edilen sonuçlar göz önünde bulundurulduğunda elde edilen sonuçların kabul edilebilir düzeyde başarılı olduğu görülmektedir.

Makine öğrenmesi ve derin öğrenme yöntemlerinin her gün hızla geliştiği günümüzde sanayi alanında bu yöntemler kullanılarak yapılan tahminlerin, zaman, hız, iş gücü ve iş kalitesini doğrudan etkilediği görülmektedir. Bu alanlarda yapılan çalışmalarda zaman, hız ve iş gücü büyük önem arz etse de üretilmek istenen ürünün kalitesi bu parametrelerin tamamını doğrudan etkilemektedir. Makine öğrenmesi ve derin öğrenme yöntemleriyle yapılan tahminler sayesinde insan hatasının minimize edilmesi sağlanacak ve bu sayede bahsi geçen tüm parametrelerde başarılı bir şekilde performans gözlemlenecektir. Makine öğrenmesi yöntemlerinin başarımları ve doğrulukları elde edilen veri setinin büyüklüğü ve temizliği ile doğru orantılı olarak değişkenlik göstermektedir. Bu çalışmada elde edilen veri seti, verilerin temizliği göz önünde bulundurularak genişletilebileceği düşünülmektedir. Aynı zamanda büyüyen bu veri seti üzerinde farklı makine öğrenmesi ve derin öğrenme algoritmalarının uygulanması sonucunda daha yüksek başarımlar ve doğrulukta sonuçlar elde edilebileceği öngörülmektedir.

KAYNAKLAR

- [1] M.C. Santos, A.R. Machado, W.F. Sales, M.A.S. Barrozo, E.O. Ezugwu, Machining of aluminum alloys: a review, *Int. J. Adv. Manuf. Technol.* 86 (2016) 3067–3080. <https://doi.org/10.1007/s00170-016-8431-9>.
- [2] P. Srinivasa Rao, K. Ramji, B. Satyanarayana, Effect of wire EDM conditions on generation of residual stresses in machining of aluminum 2014 T6 alloy, *Alexandria Eng. J.* 55 (2016). <https://doi.org/10.1016/j.aej.2016.03.014>.
- [3] R. Chaudhari, J.J. Vora, S.S.M. Prabu, I.A. Palani, V.K. Patel, D.M. Parikh, Pareto optimization of WEDM process parameters for machining a NiTi shape memory alloy using a combined approach of RSM and heat transfer search algorithm, *Adv. Manuf.* 9 (2021). <https://doi.org/10.1007/s40436-019-00267-0>.
- [4] T. Thankachan, K. Soorya Prakash, R. Malini, S. Ramu, P. Sundararaj, S. Rajandran, D. Rammasamy, S. Jothi, Prediction of surface roughness and material removal rate in wire electrical discharge machining on aluminum based alloys/composites using Taguchi coupled Grey Relational Analysis and Artificial Neural Networks, *Appl. Surf. Sci.* 472 (2019). <https://doi.org/10.1016/j.apsusc.2018.06.117>.
- [5] C. Natarajan, S. Muthu, P. Karuppuswamy, Prediction and analysis of surface roughness characteristics of a non-ferrous material using ANN in CNC turning, *Int. J. Adv. Manuf. Technol.* 57 (2011). <https://doi.org/10.1007/s00170-011-3343-1>.
- [6] T. Gurgenc, O. Altay, M. Ulas, C. Ozel, Extreme learning machine and support vector regression wear loss predictions for magnesium alloys coated using various spray coating methods, *J. Appl. Phys.* 127 (2020). <https://doi.org/10.1063/5.0004562>.
- [7] P. Srinivasa Rao, K. Ramji, B. Satyanarayana, Prediction of Material removal rate for Aluminum BIS-24345 Alloy in wire-cut EDM, *Int. J. Eng. Sci. Technol.* 2 (2010).
- [8] V.R. Surya, K.M.V. Kumar, R. Keshavamurthy, G. Ugrasen, H. V. Ravindra, Prediction of Machining Characteristics using Artificial Neural Network in Wire EDM of Al7075 based In-situ Composite, *Mater. Today Proc.* 4 (2017) 203–212. <https://doi.org/10.1016/j.matpr.2017.01.014>.
- [9] H.R. Gurupavan, T.M. Devegowda, H. V. Ravindra, G. Ugrasen, Estimation of Machining Performances in WEDM of Aluminium based Metal Matrix Composite Material using ANN, in: *Mater. Today Proc.*, 2017. <https://doi.org/10.1016/j.matpr.2017.06.316>.
- [10] P. Shandilya, P.K. Jain, N.K. Jain, RSM and ANN modeling approaches for predicting average cutting speed during WEDM of SiCp/6061 Al MMC, in: *Procedia Eng.*, Elsevier Ltd, 2013: pp. 767–774. <https://doi.org/10.1016/j.proeng.2013.09.152>.
- [11] M.R. Phate, S.B. Toney, Engineering Science and Technology , an International Journal Modeling and prediction of WEDM performance parameters for Al / SiCp MMC using dimensional analysis and artificial neural network, *Eng. Sci. Technol. an Int. J.* 22 (2019) 468–476. <https://doi.org/10.1016/j.jestch.2018.12.002>.
- [12] Y. Yusoff, A. Mohd Zain, S. Sharif, R. Sallehuddin, M.S. Ngadiman, Potential ANN prediction model for multiperformances WEDM on Inconel 718, *Neural Comput. Appl.* 30 (2018). <https://doi.org/10.1007/s00521-016-2796-4>.
- [13] T. Singh, P. Kumar, J.P. Misra, Surface roughness prediction modelling for wedm of aa6063 using support vector machine technique, in: *Mater. Sci. Forum*, 2019. <https://doi.org/10.4028/www.scientific.net/MSF.969.607>.
- [14] D. Devarasiddappa, J. George, M. Chandrasekaran, N. Teyi, Application of Artificial Intelligence Approach in Modeling Surface Quality of Aerospace Alloys in WEDM Process, *Procedia Technol.* 25 (2016) 1199–1208. <https://doi.org/10.1016/j.protcy.2016.08.239>.
- [15] H. Guangwei, X.I.A. Weiwen, Q.I.N. Ling, Z. Wansheng, Online workpiece height estimation for reciprocated traveling wire EDM based on support vector machine, *Procedia CIRP.* 68 (2018) 126–131. <https://doi.org/10.1016/j.procir.2017.12.034>.

- [16] Y.F. Tan, L. He, X.L. Wang, X. Hong, W.G. Wang, Tribological properties and wear prediction model of TiC particles reinforced Ni-base alloy composite coatings, *Oral Oncol.* (2014). [https://doi.org/10.1016/S1003-6326\(14\)63384-7](https://doi.org/10.1016/S1003-6326(14)63384-7).
- [17] F. Sánchez Lasheras, P.J. García Nieto, F.J. De Cos Juez, J.A. Vilán Vilán, Evolutionary support vector regression algorithm applied to the prediction of the thickness of the chromium layer in a hard chromium plating process, *Appl. Math. Comput.* (2014). <https://doi.org/10.1016/j.amc.2013.11.031>.
- [18] S. Singh, D. Garg, S. Kumar, *Engineering Science and Technology , an International Journal* Modeling and optimization of process variables of wire-cut electric discharge machining of super alloy Udimet-L605, *Eng. Sci. Technol. an Int. J.* 20 (2017) 247–264. <https://doi.org/10.1016/j.jestch.2016.09.023>.
- [19] R. Bobbili, V. Madhu, A.K. Gogia, *Engineering Science and Technology , an International Journal* Modelling and analysis of material removal rate and surface roughness in wire-cut EDM of armour materials, *Eng. Sci. Technol. an Int. J.* 18 (2015) 664–668. <https://doi.org/10.1016/j.jestch.2015.03.014>.
- [20] A. Sharma, M.P. Garg, K.K. Goyal, Prediction of optimal conditions for WEDM of Al 6063 / ZrSiO₄ (p) MMC, *MSPRO.* 6 (2014) 1024–1033. <https://doi.org/10.1016/j.mspro.2014.07.173>.
- [21] H.G.P. Kumar, M.A. Xavier, Assessment of Mechanical and Tribological Properties of Al 2024- SiC - Graphene Hybrid Composites, in: *Procedia Eng., Elsevier B.V., 2017: pp. 992–999*. <https://doi.org/10.1016/j.proeng.2017.01.251>.
- [22] P. Srinivasa, K. Ramji, B. Satyanarayana, Surface integrity of wire EDMed aluminum alloy : A comprehensive experimental investigation, *J. King Saud Univ. - Eng. Sci.* 30 (2018) 368–376. <https://doi.org/10.1016/j.jksues.2016.12.001>.
- [23] G. Gautier, P.C. Priarone, S. Rizzuti, L. Settineri, V. Tebaldo, 15th CIRP Conference on Modelling of Machining Operations A contribution on the modelling of wire electrical discharge machining of a Ü -TiAl alloy, *Procedia CIRP.* 31 (2015) 203–208. <https://doi.org/10.1016/j.procir.2015.03.019>.
- [24] T. Koyano, T. Takahashi, S. Tsurutani, A. Hosokawa, Temperature Measurement of Wire Electrode in Wire EDM by Two-color Pyrometer, *Procedia CIRP.* 68 (2018) 96–99. <https://doi.org/10.1016/j.procir.2017.12.029>.
- [25] O. İmamoğlu, Tel erozyon tezgahında 2379 çeliğinin işlenmesinde kesme parametrelerinin şekil ve boyut toleranslarına etkisi, *Marmara Üniversitesi, 2007*.
- [26] N.U. Tosun, Yüksek manganlı çeliklerin tel erozyon tezgahında işlenmesinde tel aşınmasının ve yüzey pürüzlülüğünün incelenmesi, *Fırat University), 2001*.
- [27] T.J. Drozda, C. Wick, *Tool and manufacturing engineers handbook: machining (Vol. 1), 1983*.
- [28] M.I. Gökler, A.M. Ozanözü, Experimental investigation of effects of cutting parameters on surface roughness in the WEDM process, *Int. J. Mach. Tools Manuf.* 40 (2000). [https://doi.org/10.1016/S0890-6955\(00\)00035-3](https://doi.org/10.1016/S0890-6955(00)00035-3).
- [29] J. Owen, *Intelligent EDM, Manuf. Eng.* (1992) 50–52.
- [30] D. Scott, S. Boyina, K.P. Rajurkar, Analysis and optimization of parameter combinations in wire electrical discharge machining, *Int. J. Prod. Res.* 29 (1991). <https://doi.org/10.1080/00207549108948078>.
- [31] K.H. Ho, S.T. Newman, S. Rahimifard, R.D. Allen, State of the art in wire electrical discharge machining (WEDM), *Int. J. Mach. Tools Manuf.* 44 (2004). <https://doi.org/10.1016/j.ijmachtools.2004.04.017>.
- [32] D. Aydogdu, Tel erezyonda kesme parametrelerinin parçanın boyut ve şekil toleranslarına etk ilerinin deneysel incelenmesi, (2009).
- [33] M. Bayraktutar, Tel erozyon tezgahında yüzey kalitesine etki eden parametrelerin incelenmesi / The Investigation of parameters affecting the surface quality in wire-cut EDM, *Marmara Üniversitesi, 2000*. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=aBaZRgQIEVoRmek8tk2Psg&no=NqHstBUBewC1YlpVyyduuqA>.

- [34] Veri Madenciliği ve Türkiye’deki Uygulama Örnekleri, İstanbul Ticaret Üniversitesi Fen Bilim. Derg. (2012).
- [35] M. Atalay, E. Çeelik, Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları, Mehmet Akif Ersoy Üniversitesi Sos. Bilim. Enstitüsü Derg. 9 (2017).
- [36] G.G. Emel, Ç. Taşkın, Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması, Eskişehir Osmangazi Üniversitesi Sos. Bilim. Derg. 6 (2005). <https://doi.org/10.17494/ogusbd.06798>.
- [37] B. R.B, “Importance of Data Mining in Higher Education System,” IOSR J. Humanit. Soc. Sci. (2013). <https://doi.org/10.9790/0837-0661821>.
- [38] S. Zhang, C. Zhang, Q. Yang, Data preparation for data mining, Appl. Artif. Intell. (2003). <https://doi.org/10.1080/713827180>.
- [39] Y. Lecun, Y. Bengio, G. Hinton, Deep learning, Nature. (2015). <https://doi.org/10.1038/nature14539>.
- [40] A. Onan, S. Korukoğlu, Makine öğrenmesi yöntemlerinin görüş madenciliğinde kullanılması üzerine bir literatür araştırması, Pamukkale Univ Muh Bilim Derg. (2016). <https://doi.org/10.5505/pajes.2015.90018>.
- [41] A. Tekerek, Veri Madenciliği Süreçleri ve Açık Kaynak Kodlu Veri Madenciliği Araçları, Akad. Bilişim’11 - XIII. Akad. Bilişim Konf. Bildir. (2011).
- [42] S. Ruggieri, Efficient C4.5, IEEE Trans. Knowl. Data Eng. (2002). <https://doi.org/10.1109/69.991727>.
- [43] A. Likas, N. Vlassis, J. J. Verbeek, The global k-means clustering algorithm, Pattern Recognit. (2003). [https://doi.org/10.1016/S0031-3203\(02\)00060-2](https://doi.org/10.1016/S0031-3203(02)00060-2).
- [44] J.S. Park, M.S. Chen, P.S. Yu, An Effective Hash-Based Algorithm for Mining Association Rules, ACM SIGMOD Rec. (1995). <https://doi.org/10.1145/568271.223813>.
- [45] I. Rish, An empirical study of the naive Bayes classifier, IJCAI 2001 Work. Empir. Methods Artif. Intell. (2001). <https://doi.org/10.1039/b104835j>.
- [46] D. Arthur, S. Vassilvitskii, K-means++: The advantages of careful seeding, in: Proc. Annu. ACM-SIAM Symp. Discret. Algorithms, 2007.
- [47] A. Ben-Hur, J. Weston, A user’s guide to support vector machines., Methods Mol. Biol. (2010). https://doi.org/10.1007/978-1-60327-241-4_13.
- [48] T. Kavzoglu, J. Jaafar, P.M. Mather, Extraction of Field Boundary Information: Using Satellite Images Classified by Artificial Neural Networks, Spat. Inf. Environ. (2001).
- [49] T.S. Furey, N. Cristianini, N. Duffy, D.W. Bednarski, M. Schummer, D. Haussler, Support vector machine classification and validation of cancer tissue samples using microarray expression data, Bioinformatics. (2000). <https://doi.org/10.1093/bioinformatics/16.10.906>.
- [50] N.M. Khan, R. Ksantini, I.S. Ahmad, B. Boufama, A novel SVM+NDA model for classification with an application to face recognition, Pattern Recognit. (2012). <https://doi.org/10.1016/j.patcog.2011.05.004>.
- [51] J. Jiang, T. Jiang, S. Zhai, A novel recognition system for human activity based on wavelet packet and support vector machine optimized by improved adaptive genetic algorithm, Phys. Commun. (2014). <https://doi.org/10.1016/j.phycom.2014.04.006>.
- [52] S. Sahiner, The Basic Principles of Fitting Linear Regression Model By Least Squares Method En Küçük Kareler Yöntemi ile Doğrusal Regresyon Modeli Oluşturmanın Temel Prensipleri Giriş, (2000).
- [53] Ö. Çokluk, Lojistik Regresyon Analizi: Kavram ve Uygulama. (Turkish), Logist. Regres. Concept Appl. (2010).
- [54] C. Hamzaçebi, F. Kutay, Yapay sinir ağları ile Türkiye elektrik enerjisi Tüketiminin 2010 yılına kadar tahmini, J. Fac. Eng. Archit. Gazi Univ. (2004).
- [55] B. Ataseven, Yapay Sinir Ağları ile Öngörü Modellemesi, Öneri Derg. 10 (2013) 101-115–115.

<https://doi.org/10.14783/od.v10i39.1012000311>.

- [56] V. Mnih, N. Heess, A. Graves, K. Kavukcuoglu, Recurrent models of visual attention, in: *Adv. Neural Inf. Process. Syst.*, 2014.
- [57] L. Xie, A. Yuille, Genetic CNN, in: *Proc. IEEE Int. Conf. Comput. Vis.*, 2017. <https://doi.org/10.1109/ICCV.2017.154>.
- [58] M. Liang, X. Hu, Recurrent convolutional neural network for object recognition, in: *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2015. <https://doi.org/10.1109/CVPR.2015.7298958>.
- [59] K.H. Jin, M.T. McCann, E. Froustey, M. Unser, Deep Convolutional Neural Network for Inverse Problems in Imaging, *IEEE Trans. Image Process.* (2017). <https://doi.org/10.1109/TIP.2017.2713099>.
- [60] K. Greff, R.K. Srivastava, J. Koutnik, B.R. Steunebrink, J. Schmidhuber, LSTM: A Search Space Odyssey, *IEEE Trans. Neural Networks Learn. Syst.* (2017). <https://doi.org/10.1109/TNNLS.2016.2582924>.
- [61] S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Comput.* (1997). <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [62] G. Bin Huang, Q.Y. Zhu, C.K. Siew, Extreme learning machine: A new learning scheme of feedforward neural networks, in: *IEEE Int. Conf. Neural Networks - Conf. Proc.*, 2004. <https://doi.org/10.1109/IJCNN.2004.1380068>.
- [63] L. Breiman, Documentation for R package randomForest, *Mach. Learn.* (2001). <https://doi.org/10.1023/A:1010933404324>.
- [64] A. Liaw, M. Wiener, Classification and Regression by randomForest, *R News.* (2002).
- [65] M. Muja, D.G. Lowe, Fast approximate nearest neighbors with automatic algorithm configuration, in: *VISAPP 2009 - Proc. 4th Int. Conf. Comput. Vis. Theory Appl.*, 2009. <https://doi.org/10.5220/0001787803310340>.
- [66] M. Ulas, O. Aydur, T. Gurgenc, C. Ozel, Surface roughness prediction of machined aluminum alloy with wire electrical discharge machining by different machine learning algorithms, *J. Mater. Res. Technol.* 9 (2020) 12512–12524. <https://doi.org/10.1016/j.jmrt.2020.08.098>.
- [67] C. Cortes, V. Vapnik, Support-Vector Networks, *Mach. Learn.* 20 (1995). <https://doi.org/10.1023/A:1022627411411>.
- [68] P.S. Yu, S.T. Chen, I.F. Chang, Support vector regression for real-time flood stage forecasting, *J. Hydrol.* 328 (2006). <https://doi.org/10.1016/j.jhydrol.2006.01.021>.
- [69] H. Drucker, L. Kaufman, C.J.. Burges, A. Smola, V. Vapnik, Support Vector Regression Machines, (1997) 155–161.
- [70] H. Sharafi, I. Ebtehaj, H. Bonakdari, A.H. Zaji, Design of a support vector machine with different kernel functions to predict scour depth around bridge piers, *Nat. Hazards.* 84 (2016). <https://doi.org/10.1007/s11069-016-2540-5>.
- [71] R.G. Brereton, G.R. Lloyd, Support Vector Machines for classification and regression, *Analyst.* 135 (2010). <https://doi.org/10.1039/b918972f>.
- [72] O. Bilhan, M.E. Emiroglu, C.J. Miller, M. Ulas, The evaluation of the effect of nappe breakers on the discharge capacity of trapezoidal labyrinth weirs by ELM and SVR approaches, *Flow Meas. Instrum.* 64 (2018). <https://doi.org/10.1016/j.flowmeasinst.2018.10.009>.
- [73] A.H. Zaji, H. Bonakdari, S.R. Khodashenas, S. Shamshirband, Firefly optimization algorithm effect on support vector regression prediction improvement of a modified labyrinth side weir's discharge coefficient, *Appl. Math. Comput.* 274 (2016). <https://doi.org/10.1016/j.amc.2015.10.070>.
- [74] O. Altay, T. Gurgenc, M. Ulas, C. Özel, Prediction of wear loss quantities of ferro-alloy coating using different machine learning algorithms, *Friction.* 8 (2020). <https://doi.org/10.1007/s40544-018-0249-z>.
- [75] Ö. Baydaroğlu, K. Koçak, SVR-based prediction of evaporation combined with chaotic approach, *J.*

- Hydrol. 508 (2014). <https://doi.org/10.1016/j.jhydrol.2013.11.008>.
- [76] M. Açıkgenç, M. Ulaş, K.E. Alyamaç, Using an Artificial Neural Network to Predict Mix Compositions of Steel Fiber-Reinforced Concrete, Arab. J. Sci. Eng. 40 (2015). <https://doi.org/10.1007/s13369-014-1549-x>.
- [77] X. Shi, J. Wang, G. Liu, L. Yang, X. Ge, S. Jiang, Application of extreme learning machine and neural networks in total organic carbon content prediction in organic shale with wire line logs, J. Nat. Gas Sci. Eng. 33 (2016) 687–702. <https://doi.org/10.1016/j.jngse.2016.05.060>.
- [78] W. Zong, G. Bin Huang, Y. Chen, Weighted extreme learning machine for imbalance learning, Neurocomputing. 101 (2013). <https://doi.org/10.1016/j.neucom.2012.08.010>.



ÖZGEÇMİŞ

Osman AYDUR

[illegible]

Service	Percentage of Respondents
Mobile phone	100%
Laptop	95%
Tablet	85%
Smart TV	75%
Smart speaker	65%
Smartwatch	55%
Smart home device	45%

[REDACTED]

[REDACTED] [REDACTED]
[REDACTED]
[REDACTED]

AKADEMİK FAALİYETLER

Makaleler:

1. M. Ulas, O. Aydur, T. Gurgenc, C. Ozel, Surface roughness prediction of machined aluminum alloy with wire electrical discharge machining by different machine learning algorithms, J. Mater. Res. Technol. 9 (2020) 12512–12524. <https://doi.org/10.1016/j.jmrt.2020.08.098>.

Projeler:

1. Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) - MF.19.52