



T.C.  
KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI



# MAKİNE ÖĞRENME TEKNİKLERİNİN MÜHENDİSLİK UYGULAMALARINDA KULLANILMASI

AQEEL JALİL RADHI RADHI

YÜKSEK LİSANS TEZİ

KIRŞEHİR  
2024



T.C.  
KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI



# MAKİNE ÖĞRENME TEKNİKLERİNİN MÜHENDİSLİK UYGULAMALARINDA KULLANILMASI

AQEEL JALIL RADHI RADHI

YÜKSEK LİSANS TEZİ

DANIŞMAN

PROF. DR. ALİ OSMAN KURBAN

KIRŞEHİR  
2024

**KIRŐEHİR AHİ EVRAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**  
**YÜKSEK LİSANS TEZ ÇALIŐMASI**  
**ETİK BEYANI**

Kırőehir Ahi Evran Üniversitesi Bilimsel Araőtırma ve Yayın Etiđi Yönergesini okuduđumu ve anladıđımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladıđım bu tez çalışmasında;

- Tez içinde sunduđum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiđimi,
- Tüm bilgi, belge, deđerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduđumu,
- Tez çalışmasında yararlandıđım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiđimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deđeriklik yapmadıđımı,
- Tez olarak sunduđum bu çalışmanın özgün olduđunu bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime dođabilecek tüm hak kayıplarını kabullendiđimi beyan ederim. ..../...../20....

Öđrenci  
Aqeel Jalil Radhi RADHI

# İÇİNDEKİLER DİZİNİ

Sayfa No

|  |      |
|--|------|
| İÇİNDEKİLER DİZİNİ .....   | I    |
| TEŞEKKÜR.....  | III  |
| ÖZET .....   | IV   |
| ABSTRACT .....   | V    |
| TABLolar DİZİNİ .....  | VI   |
| ŞEKİLLER DİZİNİ .....  | VII  |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                   | VIII |
| 1.GİRİŞ.....   | 1    |
| 1.1 Makine Öğrenimi Nedir: .....                                       | 1    |
| 1.1.1 Makine öğrenimi neden önemlidir: .....                           | 2    |
| 1.1.2 Makine öğrenimi nerede kullanılır: .....                         | 2    |
| 1.1.2.1 Üretimde kullanılan yüzey pürüzlülüğü.....                     | 2    |
| 1.1.2.2 Sağlık hizmetleri ve yaşam bilimleri .....                     | 2    |
| 1.1.2.3 Finansal hizmetler .....                                       | 2    |
| 1.1.2.4 Perakende ve e-ticaret .....                                   | 3    |
| 1.1.2.5 Medya ve eğitim .....  | 3    |
| 1.1.3 Makine öğrenimi nasıl çalışır: .....                             | 3    |
| 1.1.4 Makine öğreniminin avantajları ve dezavantajları nelerdir: ..... | 3    |
| 1.1.4.1 Makine öğrenimi modellerinin avantajları.....                  | 3    |
| 1.1.4.2 Makine öğrenimi modellerinin dezavantajları .....              | 4    |
| 1.2. Makine Öğrenme Teknikleri Kullanılarak Yüzey Pürüzlülüğü .....    | 4    |
| 1.2.1 Makine öğrenme teknikleri.....                                   | 8    |
| 1.2.1.1 Makine öğreniminin değerlendirilmesi.....                      | 9    |
| 1.2.1.2 Makine öğrenme grupları.....                                   | 11   |
| 1.2.1.2.1 Gözetimli öğrenme (Supervised learning) .....                | 12   |
| 1.2.1.2.2 Gözetimsiz öğrenme (Unsupervised learning).....              | 13   |
| 1.2.1.3 Karar ağaçları.....  | 15   |
| 1.2.1.4 Yapay sinir ağları (YSA) .....                                 | 16   |
| 1.2.1.4.1 Geri yayılım.....  | 18   |
| 1.2.1.5 Destek vektör makineleri .....                                 | 19   |
| 1.2.1.7 Bayes sınıflandırması.....                                     | 20   |
| 1.2.1.8 Q - öğrenme .....  | 22   |
| 1.2.1.9 Lineer diskriminant analizi .....                              | 22   |

|   |           |
|---|-----------|
| 1.2.1.10 Lineer lojistik regresyon .....                            | 23        |
| 1.2.1.11 Ölçekli eşlenik gradyan.....                               | 24        |
| 1.2.1.12 Doğrusal olmayan lojistik regresyon ile sinir ağları ..... | 25        |
| 1.2.1.13 K-En yakın komşu .....                                     | 26        |
| <b>2.ÖNCEKİ ÇALIŞMALAR .....</b>                                    | <b>29</b> |
| <b>3.MATERYAL VE METOT .....</b>                                    | <b>35</b> |
| 3.1 Materyal .....  | 35        |
| 3.2 Metod .....   | 35        |
| 3.2.1 Parametrelerin tanımlanması .....                             | 36        |
| 3.2.2 Veri toplama ve hazırlama.....                                | 36        |
| 3.2.3 Model oluşturma ve eğitim.....                                | 36        |
| 3.2.4 Doğrulama ve değerlendirme .....                              | 36        |
| 3.2.5 Optimizasyon ve uygulama .....                                | 36        |
| 3.2.6 Sürekli iyileştirme ve geri bildirim döngüsü .....            | 36        |
| <b>4.BULGULAR VE TARTIŞMA .....</b>                                 | <b>41</b> |
| <b>5. SONUÇ VE ÖNERİLER.....</b>                                    | <b>49</b> |
| <b>KAYNAKÇA .....</b>   | <b>53</b> |
| <b>ÖZGEÇMİŞ.....</b>  | <b>57</b> |

## TEŐEKKÜR

Yüksek Lisansa başlamamda ve yüksek lisans ders sürecinde kendisini tanıdığım günden bu yana gösterdiği sakin ve sabırlı hali ile her zaman bana örnek olmasının yanı sıra bir bilim insanının nasıl çalışması gerektiğini kendisinden öğrendiğim değerli danışmanım Prof. Dr. Ali Osman KURBAN'a içtenlikle teşekkür ederim. Tezimin nihai hale gelmesinde katkıları olan değerli jüri üyelerim Prof. Dr. Levent URTEKİN ve Prof. Dr. Fehmi NAİR'e teşekkürlerimi sunarım.

Hayatımın her alanında her zaman yanımda olan, bugünlere ulaşmamda en büyük paya sahip olan ve beni her zaman destekleyen kıymetli aileme, varlığıyla bana güç veren babam Jalil Radhi RADHI, annem Hasna RADHI, kardeşlerim Halit RADHI ve Dr. Macit RADHI'ye teşekkür ediyorum. Hep birlikte olduğumuz değerli arkadaşım Tahseen ALLAWI'ye teşekkürlerimi sunuyorum.

Mart, 2024

Aqeel Jalil Radhi RADHI

## ÖZET

### YÜKSEK LİSANS TEZİ

#### MAKİNE ÖĞRENME TEKNİKLERİNİN MÜHENDİSLİK UYGULAMALARINDA KULLANILMASI

Aqeel Jalil Radhi RADHI

#### KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Prof. Dr. Ali Osman KURBAN  
Yıl:2024, Sayfa:57  
Jüri: Prof. Dr. Ali Osman KURBAN  
Prof. Dr. Levent URTEKİN  
Prof. Dr. Fehmi NAİR

Tezde makine öğrenimi nedir, neden önemlidir nerelerde kullanılır, nasıl çalışır ve avantajları dezavantajları gibi konulara değinildi. Makine öğreniminin teknikleriyle beraber konuya giriş yapıldı.

Tezde makine öğrenim tekniklerinin neler olduğu, öğrenme gruplarının nasıl işlediği incelendi. Yüzey pürüzlülüğünün makine öğreniminde nasıl çalıştığı tekniklerin pürüzlülükle bağlantılı kısımları hangi parametrelerle karşımıza çıktığı analiz edildi. Yüzey pürüzlülük değerlerinin makine öğrenimindeki etkilerini ortaya çıkan verilerin makine öğreniminde ve kullanılmasında neden olacak sonuçlar bakımından etkileri araştırıldı. Yüzey pürüzlülüğü hesaplamaları; Elde bulunulan malzemenin yüzeyinin düzgün olup olmamasını inceleyen ölçümlerdir. Makine öğrenim algoritmalarının pürüzlülükte kullanım amaçları endüstriyel bakımdan önemli bir konudur. İmalat ve birçok yerde önem arz eden bir yapı olan yüzey pürüzlülüğü ürünün önemli bir sorunudur. Bu yüzden yüzey pürüzlülüğünün hesaplanmasında değindiğimiz modeller ile pürüzlülükten doğan olumsuz sonuçların en aza indirilmesi hedeflenmiştir. Yüzey pürüzlülüğü genel olarak yüzeyde oluşan yükseklik ve yüzeyde oluşan dalgalanmaların istatistiksel olarak karakterize edilmesidir. Bu analizler ise bazı parametreler aracılığı ile yapılırlar. Bu parametrelere örnek verecek olursak  $R_a$  (ortalama yüzey pürüzlülüğü),  $R_z$  (maksimum yüzey pürüzlülüğü),  $R_q$  (kök ortalama Kare yüksekliği) gibi konulara değinildi.

Sonuçta yapılan tezde, iki farklı yüzey pürüzlülük ölçüm makinesi ile incelemiş olan üç farklı malzemenin pürüzlülük değerleri ile kullanılan materyaller incelendi. Yapılan deney ölçüm cihazları ve veriler kullanılarak sonuçlar elde edildi.

**Anahtar Kelimeler:** Makine öğrenim teknikleri, Makine öğrenimi yüzey pürüzlülüğünde modeller, Yüzey Pürüzlülük parametreleri

## **ABSTRACT**

# **MASTER'S THESIS USING MACHINE LEARNING TECHNIQUES IN ENGINEERING APPLICATIONS**

**Aqeel Jalil Radhi RADHI**

**KIRŞEHİR AHİ EVRAN UNIVERSITY  
INSTITUTE OF NATURAL AND APPLIED SCIENCES  
DEPARTMENT MECHANICAL ENGINEERING**

**Supervisor: Prof. Dr. Ali Osman KURBAN  
Year:2024, Pages:57  
Juries: Prof. Dr. Ali Osman KURBAN  
Prof. Dr. Levent URTEKİN  
Prof. Dr. Fehmi NAİR**

In the thesis, topics such as what machine learning is, why it is important, where it is used, how it works and its advantages and disadvantages were touched upon. The subject was introduced with the techniques of machine learning.

In the thesis, what machine learning techniques are and how learning groups work were examined. It was analyzed how surface roughness works in machine learning and with what parameters the roughness-related parts of the techniques appear. The effects of surface roughness values on machine learning were investigated in terms of the consequences that would result in machine learning and use of the resulting data. Surface roughness calculations are measurements that examine whether the surface of the material is smooth or not. The intended use of machine learning algorithms in roughness is an industrially important issue. Surface roughness, which is an important structure in manufacturing and many other places, is an essential problem of the machine. Therefore, it is aimed to minimize the negative consequences caused by roughness with the models we mentioned in calculating surface roughness. Surface roughness is generally a statistical characterization of the height and fluctuations occurring on the surface. These analyzes are made through some parameters. To give examples of these parameters, topics such as Ra (average surface roughness), Rz (maximum surface roughness), Rq (root mean square height) were mentioned.

As a result, in the thesis, the roughness values of three different materials examined with two surface roughness measuring machines and the materials used were examined. Results were obtained using experimental measuring devices and data.

**Keywords:** Machine learning techniques, Machine Learning models in surface roughness, Surface Roughness parameters



## TABLolar DİZİNİ

### Sayfa No

|  |    |
|--|----|
| <b>Tablo 1. 1:</b> Yüzey İşleme İşaretleri .....   | 7  |
| <b>Tablo 3. 1:</b> Kullanılan Ölçme Cihazlarına ait özellikler. ....                           | 40 |
| <b>Tablo 4. 1:</b> Alüminyum Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ ).....     | 41 |
| <b>Tablo 4. 2:</b> Çelik Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ ).....         | 41 |
| <b>Tablo 4. 3:</b> Plastik Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ ) .....      | 41 |
| <b>Tablo 5. 1:</b> Çalışmada kullanılan numunelerin Ra(Ortalama yüzey pürüzlülük) değerleri    | 50 |
| <b>Tablo 5. 2:</b> Çalışmada kullanılan numunelerin Rz(Maksimum yüzey pürüzlülük) değerleri    | 50 |
| <b>Tablo 5. 3:</b> Çalışmada kullanılan numunelerin Rq(Kök ortalama kare yüksekliği) değerleri | 51 |

## ŞEKİLLER DİZİNİ

### Sayfa No

|  |    |
|--|----|
| Şekil 1. 1: Makine öğrenimi şeması.....  | 1  |
| Şekil 1. 2: Makine Öğreniminin Çalışma Prensipleri .....   | 2  |
| Şekil 1. 3: Medya açısından öğrenim.....   | 3  |
| Şekil 1. 4: Ra (Ortalama Yüzey Pürüzlülüğü) .....  | 5  |
| Şekil 1. 5: Rz (Maksimum Yüzey Pürüzlülüğü).....   | 5  |
| Şekil 1. 6: Rq (Kök Ortalama Kare Yüksekliği).....   | 6  |
| Şekil 1. 7: Makine öğrenmesi yöntemi .....   | 12 |
| Şekil 1. 8: E-posta sınıflandırma problemi .....   | 12 |
| Şekil 1. 9: Regresyon problemi.....  | 13 |
| Şekil 1. 10: Etiket içermeyen bir eğitim seti.....   | 13 |
| Şekil 1. 11: Öbekleme.....   | 14 |
| Şekil 1. 12: Yüksek boyutlu bir veri setinin boyutunu azaltarak görselleştirme .....   | 14 |
| Şekil 1. 13: Pekiştirmeli öğrenme.....   | 15 |
| Şekil 1. 14: Karar ağaçları gösterimi .....  | 15 |
| Şekil 1. 15: Yapay Sinir Ağı Modeli (YSA).....   | 17 |
| Şekil 1. 16: Veri setini iki ayrı doğrusal ayırma kullanarak iki gruba ayıran vektör makinesi  | 19 |
| Şekil 1. 17: Eşlenik Gradyan (yeşil çizgi) ve Gradyan İniş (kırmızı çizgi) Algoritmalarının karşılaştırılması .....                  | 25 |
| Şekil 1. 18: K-en Yakın Komşu Örneği.....  | 27 |
| Şekil 3.1:Endüstriyel kalitede düz levha alüminyum malzemesi.....  | 38 |
| Şekil 3. 2: Karbon çelikten imal edilmiş düz evhalar.....  | 38 |
| Şekil 3. 3: Polimerik bir malzemeden üretilmiş standart numune.....  | 39 |
| Şekil 3. 4: a) Mitutoyo Marka SurfTest SJ-210 model ve b) İnsize ISR – C300 marka pürüzlülük Ölçme cihazı.....                       | 39 |
| Şekil 3. 5: İnsize ISR – C300 cihazından elde edilen Plastik numunenin yüzey pürüzlülük grafiği.....                                 | 40 |
| Şekil 4. 1: Z0m, Dört Makine Öğrenimi Algoritmasının Performansları. Eğitim (a, c, e, g) ve Test (b, d, f, h) Aşamaları.....         | 44 |
| Şekil 4. 2: Tahmini $kB^{-1}$ Makine öğrenmesi Algoritmalarının Eğitim(a,c,e,g) ve Test (b,d,f,h) aşamalarındaki Performansları..... | 45 |
| Şekil 4. 3: Fiziksel Tabanlı z0m Modellerinin Performansları.....  | 46 |
| Şekil 4. 4: Fiziksel Tabanlı $kB^{-1}$ Modellerinin Performansları. [30'dan büyük $kB^{-1}$ Değerleri hariç Tutulmuştur].....        | 47 |

## SİMGELER VE KISALTMALAR LİSTESİ

| Simgeler        | Açıklama  |
|-----------------|---|
| $Y$             | : Çıktı uzayı   |
| $Y_t$           | : $t$ zamanına ait zaman serisi                       |
| $\alpha$        | : düzgünleştirme sabiti                               |
| $\beta$         | : çarpma sabiti                                       |
| $F_t$           | : $t$ döneminin tahmin verisi,                        |
| $X_t$           | : $t$ zamanındaki gerçekleşmiş talep                  |
| $n$             | : hareketli ortalamaya kabul edilen dönemlerin sayısı |
| $\mu_t$         | : $t$ zamanın ortalaması                              |
| $\varepsilon_t$ | : $t$ dönemine ait hata                               |
| $\delta$        | : fonksiyon sabiti                                    |
| $w_{1j}$        | : 1 numaralı girdinin $j$ . ağırlık değeri            |
| $f$             | : etkinlik fonksiyonu                                 |
| $0_j$           | : Sigmoid fonksiyonu                                  |
| $V_i$           | : $i$ Değere ait toplama işlevi                       |
| $n$             | : dönü sayısı   |
| $S_F$           | : F'in denetim şeması                                 |
| $\lambda$       | : YSA' da kullanılan Yumuşatma sabitidir.             |

| Kısaltmalar     | Açıklama   |
|-----------------|--|
| <b>ANN(YSA)</b> | : Artificial Neural Network - Yapay Sinir Ağları                                   |
| <b>ML</b>       | : Machine Learning - Makine Öğrenimi   |
| <b>MQL</b>      | : Minimum Quantity Lubrication- Minimum Miktar Yağlama                             |
| <b>DBN</b>      | : Deep Belief Network - Derin Düşünce Ağı  |
| <b>BDA</b>      | : Bilgisayar Destekli Yorulma Testi ve Analizi                                     |
| <b>AISI</b>     | : Amerikan Demir ve Çelik Enstitüsü  |
| <b>ANOVA</b>    | : ANalysis Of VAriance - Varyans Analizi   |
| <b>KNN</b>      | : K-Nearest Neighbours - K-En Yakın Komşular                                       |
| <b>LDA</b>      | : Lineer Diskriminant Analizi  |
| <b>LLR</b>      | : Lineer Lojistik Regresyon  |
| <b>SCG</b>      | : Kademeli Eşlenik Gradyan   |
| <b>MLP</b>      | : Multi-layer Perceptron- Çok Katmanlı Algılayıcılar                               |
| <b>RMSE</b>     | : Root Mean Square Error- Kök Ortalama Kare Hatası                                 |
| <b>MAPE</b>     | : Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hatası                      |
| <b>R2</b>       | : The Coefficient of Determination-Belirleme Katsayısı                             |
| <b>MDP</b>      | : Markov Decision Process- Markov Karar Süreci                                     |
| <b>MMC</b>      | : Multimedia Cart - Sayısal Depolama Aygıtı  |
| <b>SVM</b>      | : Support Vector Machine- Destek Vektör Makinesi                                   |
| <b>ANFIS</b>    | : Adaptive Neuro-Fuzzy Inference System-Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi |

| <b>Kısaltmalar</b>     | <b>Açıklama</b>  |
|------------------------|--|
| <b>QPSO</b>            | : The Quantum Particle <u>Swarm</u> Optimization-Kuantum Parçacık Toplam Optimizasyonu                         |
| <b>Z<sub>0h</sub></b>  | : Isı transferi için Termodinamik pürüzlülük uzunluğu  |
| <b>Z<sub>0m</sub></b>  | : Momentum transferinde kullanılan Hava pürüzlülük uzunluğu  |
| <b>FFT-LSTM</b>        | : Fast Fourier Transform Long Short Term Memory Network - Hızlı Fourier Uzun Kısa Vadeli Bellek Ağı Dönüştürme |
| <b>FFT-DNN</b>         | : Fast Fourier Transform-Deep Neural Networks - Hızlı Fourier Dönüşümü Derin Sinir Ağları                      |
| <b>1-D CNN</b>         | : One-Dimensional Convolutional Neural Network -Tek Boyutlu Evrişimsel Sinir Ağı)                              |
| <b>kB<sup>-1</sup></b> | : Makine öğrenim tekniğinde kullanılan direnç büyüklüğü  |



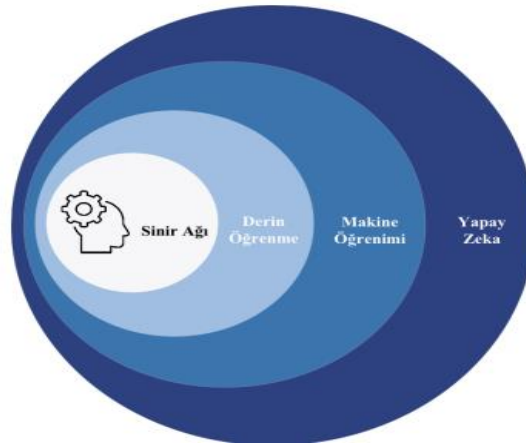
## 1.GİRİŞ

Tezde ele alınan makine öğrenme tekniklerinin mühendislik uygulamalarında kullanılması konusunu arařtırmalarım dođrultusunda inceleyeceđiz. Tezde makine öğreniminin yüzey pürüzlülüđünde ne gibi arařtırmalara konu olduđu ve bunlardan elde edilen bilgiler tezin ana konusunu oluřturmaktadır. Tezde, insan hayatının birçođ bölümünde karřılařtıđımız bir konu olarak makine öğreniminin avantajlarını ve dezavantajlarını, makine öğrenimi ne olduđunu, neden önemli olduđunu, nerelerde kullanıldıđı ele alınmaktadır.


Makine öğreniminde de önemli bir yere sahip olan farklı malzemelerin yüzey pürüzlülük deđerleri tespitlerinin yapılması. Yüzey pürüzlülüđü ile ilgili çalışmalar, materyal – metot ve bulgular-tartıřmalar olarak tezde ele alınmaktadır.

### 1.1 Makine Öğrenimi Nedir:

Makine öğrenimi, yapay zekanın alt dalıdır ve bilgisayar sistemlerinin veri üzerinde otomatik bir řekilde öğrenme ve gelişme yeteneđini ifade eder. Geleneksel programlamada olduđu gibi kendilerine verilen bir görevi gerçekleřtirmek için dođrudan talimatlar vermek yerine, makine öğrenimi algoritmaları veri analizi ve desen tanıma yoluyla bu görevleri gerçekleřtirmek için kendilerini sürekli geliştirirler. Bilgisayar sistemlerindeki açık talimatlar yerine oluřan düzenlemeden yola çıkarak görevleri gerçekleřtirmek için kullandıđı algoritmalar ve istatistiksel modeller oluřturma bilimidir. Bilgisayar sistemlerinin bir parçası olan makine öğrenimi belirli miktarda eski veriyi iřlemek, analiz etmek gibi algoritmaları anlayabilmesidir. Veri kümesinde belirli bir girdiyi dođru řekilde ifade ederler. Buna bir örnek ile açıklayacak olursak, veri bilimcileri tıbbi bir alanda röntgen sonuçlarından kanserli bir alanı ayırt ederek bunu anlayabilirler.



Şekil 1. 1: Makine öğrenimi şeması



**Şekil 1. 2:** Makine Öğreniminin Çalışma Prensipleri

### **1.1.1 Makine öğrenimi neden önemlidir:**

Makine öğrenimi; birçok alanda fayda sağlayan bir algoritmadır. Makine öğrenimi büyümeyi destekleyerek birçok işletme açısından önemlidir. Günümüzde gittikçe gelişen teknolojiler ile çoğalan verileri işleyebilmek ve anlayabilmek açısından makine öğrenimi önem arz eder. Bir veriyi tanıyabilmek anlayabilmek açısından birçok yönden yardımcı olurlar. Bu yüzden gelecekte ve günümüzde birçok teknolojik ortamda büyük bir kullanım alanı bulmuştur.

### **1.1.2 Makine öğrenimi nerede kullanılır**

Makine öğrenimi bizlere yüzey pürüzlülükleri hakkında da bilgi verir. Makine öğreniminde elde edilen veriler ile de bunlara rastlamaktayız. Yüzey pürüzlülüğünde makine öğreniminin etkileri nerelerde kullanıldığını ifade edilecektir.

Makine öğreniminin kullanıldığı bazı alanlar:

#### **1.1.2.1 Üretimde kullanılan yüzey pürüzlülüğü**

Üretim alanında makine öğrenimi önemli bir yere sahiptir. Kalite kontrolü, tedarik, süreç optimizasyonu olarak endüstriyel açıdan kullanılır.

#### **1.1.2.2 Sağlık hizmetleri ve yaşam bilimleri**

Makine öğrenimi; sağlık hizmetleri ve yaşam bilimi olarak tıbbi alanda karşımıza çıkmaktadır. Hastalık teşhisi, programlama, çözüm üretme, tahlil gibi birçok konuda sağlık hizmetlerinde yardımcı olmaktadır.

#### **1.1.2.3 Finansal hizmetler**


Makine öğrenimi finansal konularda karşımıza kredi işlemlerinde, dolandırıcılık işlemlerinde, bankacılık sektörlerinde, müşteri hizmetleri ve kişiselleştirilmiş birçok alanda finansal konularda kullanılır.

#### 1.1.2.4 Perakende ve e-ticaret

Makine öğrenimi perakende açısından ele alındığında karşımıza müşteri açısından satın alma ve satış konularında davranış analizleri, stok yönetimi gibi birçok alanda önem arz etmektedir.

#### 1.1.2.5 Medya ve eğitim

Makine öğrenimi medyada karşımıza ürün tasarlama, görüntü ve ses, içerik önerisi gibi alanlarda da karşımıza çıkmaktadır.



Şekil 1. 3: Medya açısından öğrenim

#### 1.1.3 Makine öğrenimi nasıl çalışır:

Makine öğrenimi, veri tabanlı bir yaklaşımla karşımıza çıkmaktadır. Veri toplama, model seçimi, eğitim, değerlendirme ve ayarlama gibi adımları izleyerek belirli bir süreci temsil eder. Farklı uygulamalarda birçok değişiklik göstermektedir. İzlenen adımlar belirli bir problem ile özelleştirilir. Burada önemli olan doğru verileri kullanılarak doğru adımlarla doğru sonuca ulaşabilmektir.

#### 1.1.4 Makine öğreniminin avantajları ve dezavantajları nelerdir:

##### 1.1.4.1 Makine öğrenimi modellerinin avantajları

- Veri odaklı ulaşılabilen çözümler
- Geniş kapsam sonucu ile esneklik anlayışı
- Doğruluk ve performans
- İyileştirme ve doğruluk
- Ölçeklenebilirlik



### 1.1.4.2 Makine öğrenimi modellerinin dezavantajları

- Veriye bağlılık
- Aşırı derece öğrenme
- Yorumlanabilirlik ve karmaşıklık
- Veri yanlılığı ve önyargı
- Büyük veri ihtiyacı
- Kaynak ihtiyacı ve hesaplama gücü

## 1.2. Makine Öğrenme Teknikleri Kullanılarak Yüzey Pürüzlülüğü

XVIII. yy'da buharlı makinelerin icadıyla beraber sanayi, her tür alanda çok hızlı bir şekilde gelişme göstermiştir. İmalat sektörünün merkezinde yer alan tornalama ve talaş kaldırma işlemi teknolojinin gelişmesiyle ilerleme kaydetmiştir.

Tornalama işlemi sonrasında işlenen ürünün yüzeyinin düz olmaması durumu pürüzlülük olarak tanımlanır. Oluşan bu yüzey pürüzlülüğü, tornalama işleminden sonra istenmeyen bir durum olarak ortaya çıkmaktadır. Yüzey pürüzlülüğünü ölçmek için günümüze kadar pek çok ölçme tekniği geliştirilmiştir. Bu ölçme işlemi en ilkel olan dokunma yöntemi ile başlar, çeşitli cihazların ve teknolojinin yardımıyla çok hassas ölçümlere kadar varır.

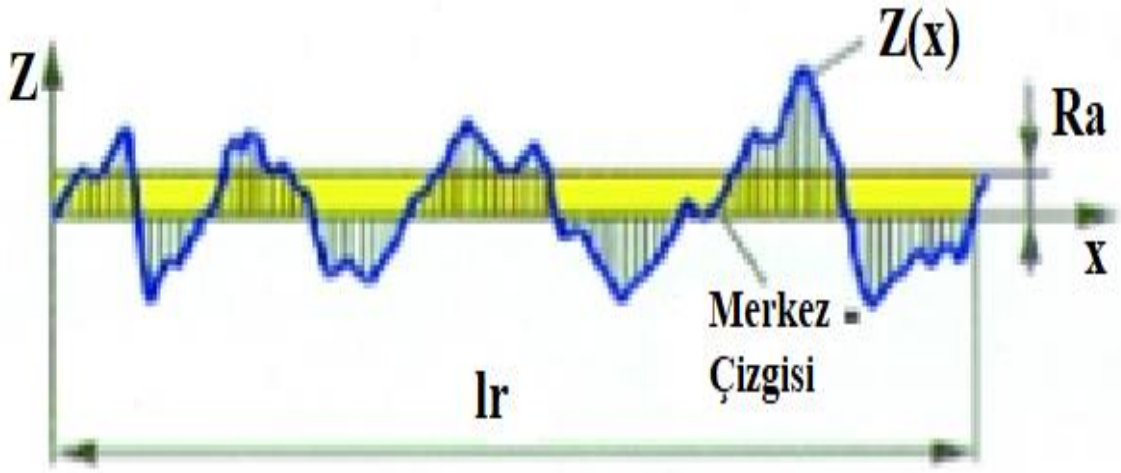
Yüzey pürüzlülüğü ölçme yöntemlerini iki temel başlık altında değerlendirebiliriz. Bunlar; uygulama şekline göre (Tahribatlı, Tahribatsız, Temaslı, Temassız); ölçme hassasiyetine göre (Kaba, Orta, Hassas). Bu ölçme yöntemlerinde istenilen özellikler; pürüzlülüğü ölçülen yüzeye herhangi bir tahribatta ve temasta bulunulmaması ve hassas ölçüm yapılabilmesidir.

Yüzey pürüzlülüğü, bir yüzeyin düzenli olup olmadığını ifade eder. Matematiksel olarak, yüzey pürüzlülüğü genellikle bir yüzeyin yükseklik profili veya yüzeydeki dalgalanmaların istatistiksel analizi ile karakterize edilir. Bu analiz, çeşitli parametreler aracılığıyla yapılır. En yaygın kullanılan parametrelerden bazıları şunlardır:

### **Ra (Ortalama Yüzey Pürüzlülüğü)**

Ra, bir yüzeyin yükseklik profili üzerindeki ortalama pürüzlülüğünü belirtir. Yüzey profilinin en yüksek ve en düşük noktaları arasındaki ortalama mesafe bağıntı (1.1) de verilmiştir.

$$Ra = \frac{1}{ln} \int_0^{lr} |Z(x)| dx \quad (1.1)$$




Şekil 1. 4: Ra (Ortalama Yüzey Pürüzlülüğü)

**Rz (Maksimum Yüzey Pürüzlülüğü)**

Rz, yüzeyin en yüksek ve en düşük noktaları arasındaki maksimum mesafeyi ifade eder. Bu parametre, yüzeydeki en yüksek dalgalanmaları ölçer.

$$Rz = \frac{(R_1+R_2+R_4+R_6+R_9) - (R_3+R_5+R_7+R_8+R_{10})}{L} \quad (1.2)$$

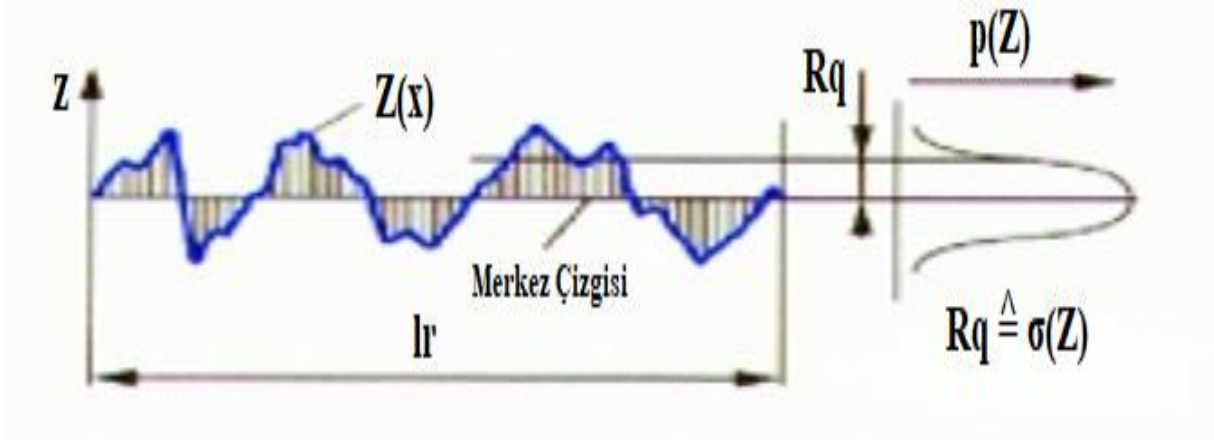


Şekil 1. 5: Rz (Maksimum Yüzey Pürüzlülüğü)

**Rq (Kök Ortalama Kare Yüksekliği)**

Rq, yüzeyin ortalama karekök yüksekliğini belirtir. Yani, yüzey profilinin karekök altında toplam uzunluğunun ortalamasıdır.

$$Rq = \sqrt{\frac{1}{ln} \int_0^{lr} Z^2(x) dx} \quad (1.3)$$



Şekil 1. 6: Rq (Kök Ortalama Kare Yüksekliği)

### Ry (Maksimum Pürüzlülük Derinliği)

Ry, yüzeyin en yüksek ve en düşük noktaları arasındaki maksimum pürüzlülük derinliğini(yiv) ifade eder.

### Rmax (Maksimum Yüzey Yüksekliği)

Rmax, yüzeydeki en yüksek noktadan en düşük noktaya kadar olan maksimum mesafeyi gösterir.

Bu parametreler yüzey pürüzlülüğünü tanımlamak için kullanılır ve yüzeyin farklı özelliklerini ölçmek için kullanılacak istatistiksel bir çerçeve sunmaktadır. Bu parametrelerin kullanımı; Mühendislik, endüstriyel üretim ve malzeme bilimi gibi birçok alanda yaygın olarak görülmektedir. Bu parametrelerin kullanımı insan hayatını kolaylaştıran bir yazılımdır. Bu ise Makine öğrenimi sisteminin bir alt kümesidir (Bilgisayar sistemi).

Yüzey pürüzlülük değerleri; Makine elemanlarında sistemin güç kaybı yönüyle de önemli olup mükemmel bir ölçüm yapmak oldukça zordur.

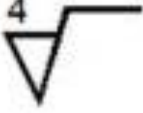
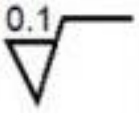
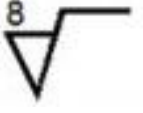

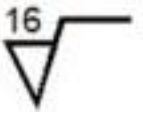
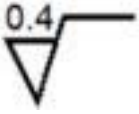
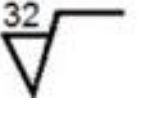
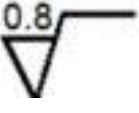
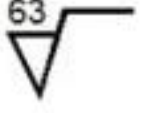
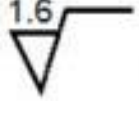
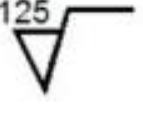



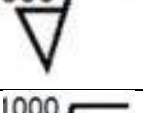
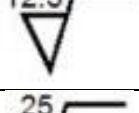
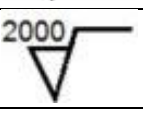
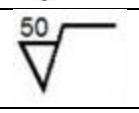
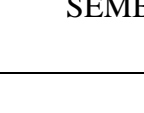
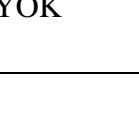
$$R_T \leq 10 \mu\text{m} \text{ parlatılmış yüzey (Ayna)}$$

$$R_{\text{tmin}} = 0.025 \mu\text{m} \text{ ölçülebilen minimum yüzey pürüzlülüğü (mutlak değildir)}$$

$$R_{\text{tmin}} = 0,025 \cdot 10^{-3} \text{ mm} (0,025 \cdot 10^{-6}) \text{ m}$$

Yüzey işleme işaretlerine ait bilgiler Tablo1.1' de verilmiştir:

**Tablo 1. 1:**Yüzey İşleme İşaretleri

| TEZGÂH İŞLEME | DIN 3141 (ESKİ GÖSTERİMİ) | ASA 46-1 (AMERİKAN STANDARDI)  | DIN 3142 (YENİ GÖSTERİMİ)   | AÇIKLAMA   |
|---------------|---------------------------|--|---|--|
| LAPLAMA       | ▽▽▽▽                      | 4       | 0.1     | Honlama, perdahlama gibi yüksek kalite işleme sonrası elde edilirler. Silindir içindeki yüzeyler, rodlar ve benzeri sızdırmazlık gereken yerlerde kullanılır. Ayna görüntüsü verir.                    |
|               |                           | 8       | 0.2     |  |
| TAŞLAMA       | ▽▽▽                       | 16      | 0.4     | Yüksek kalite taşlama işlemi ile elde edilirler. Sübap yatakları, kam yüzeyleri, sürtünmesiz yataklar, hassas yüzeyler için kullanılırlar. Parlak görüntü verirler.                                    |
|               |                           | 32     | 0.8    |  |
| İNCE İŞLEME   | ▽▽                        | 63    | 1.6   | Taşlama, raybalama, kaba honlama ile elde edilir. Yüksek devirli yataklamalar, sızdırmazlık gereken yüzeyler, pistonlar, kaymalı yatak, fren kasnakları vs. için kullanılır.                           |
|               |                           | 125   | 3.2   |  |
| ORTA İŞLEME   | ▽▽                        | 250   | 6.3   | Orta kalite taşlama veya çok ince zımpara ile elde edilir. Preste geçme yüzeyleri, kam yüzeyi, kaymalı yataklamalar, ağır yük taşıyan yatak yüzeyleri, raybalanmış delikler için kullanılır.           |
|               |                           | 500   | 12.5  |  |
| KABA İŞLEME   | ▽                         | 1000  | 25    | Yüksek kalite torna ve frezeleme işlemi ile elde edilirler. Hareket etmeyen fakat ağır yük taşıyan yataklar, dişli dış yüzeyleri, şaft yüzeyleri, mil delikleri, soğuk çekme yüzeyler için kullanılır. |
|               |                           | 2000  | 50    |  |
| İŞLEM YOK     | ~                         | SEMBOL YOK   |   | İşleme gerektirmeyen yüzeylerdir.  |

### 1.2.1 Makine öğrenme teknikleri

Makine öğrenimi, karmaşık veri kalıplarını tespit etme ve ardından bu kalıplara dayalı faydalı ve pratik yöntemler oluşturma kapasitesine odaklanır. Öğrenme uygulamaları, sınıflandırma, regresyon, denetimsiz öğrenme ve takviyeli öğrenme, makine öğrenimi uygulamalarının birkaç örneğidir. Sınıflandırma ve regresyon gibi denetimli öğrenme konularında girdiler ve çıktılar vardır ve amaç girdiden sonuca giden haritayı öğrenebilmektir. Gözetimsiz öğrenme sorunlarında amaç, girdi verileri elimizde olduğu için girdilerdeki düzenliliği belirlemektir. Bazen bir sistemin çıktısı bir dizi eylemdir ve en önemlisi amaç olan politikayı gerçekleştirmek için doğruları doğru sırayla yapabilmektir.

İşleri etkili bir şekilde yönetmek için veri madenciliği aşaması bağlamında uygun strateji seçilmelidir. Bunun için genellikle makine öğrenimi teknikleri kullanılmaktadır. İnsanlar ve bilgisayarlar arasındaki temel ayrım zamanla insanların problem çözme yöntemlerini doğal olarak geliştirme eğiliminde olmasıdır. İnsanlar geçmişteki hataları düzeltmeye çalışırlar veya onlardan ders çıkarmak için sorunlara yeni çözümler üretirler. Geleneksel bilgisayar programları, yaptıkları işin sonuçlarını dikkate almadıkları için davranışlarda değişiklik yapamazlar. Bu sorun, özellikle yeni beceriler edinme ve böylece zaman içinde performanslarını artırma becerisine sahip bilgisayar sistemleri oluşturmayı gerektiren makine öğrenimi disiplini tarafından ele alınmaktadır.

Makine öğrenimi, tahmin doğruluğunu artırmak için tahmine dayalı modellerin sistem verilerine bağlı olarak parametrelerini değiştirdiği süreçlerdir. Karmaşık ve dinamik sistemleri etkili bir şekilde simüle etmek için makine öğreniminin hayati bir araç olduğu görülmektedir. Elektrik enerjisi tüketiminin modellenmesi, dinamik kimyasal süreçlerin uyarlanabilir karakterizasyonu, öğütme işlemlerinin kararlılık analizi ve makine öğreniminin diğer kullanımına örnektirler. İşleme sırasında kesme kuvvetlerinin, takım aşınmasının ve yüzey pürüzlülüğünün oluşturulmasında yer alan çok sayıda karmaşık mekanizma nedeniyle, mikro/nano MMC (Multimedia Cart-Sayısal depolama aygıtı) sistemleri de son derece etilidir. Endüstriyel süreçleri etkin bir şekilde düzenlemek için MMC işleme sistemleri, makine öğrenimi kullanılarak doğru bir şekilde tahmin edilebilirler.

Ek olarak, makine öğrenimi sistemleri tipik olarak, bilgisayar programının yapabileceği çıkarım derecesine göre kurulan, kullandıkları temel öğrenme tekniklerine dayalı olarak farklı gruplara ayrılırlar. Ezberci öğrenme, tüm geleneksel bilgisayar sistemlerinin kullandığı yöntemi tanımlamak için kullanılan bir terimdir. Herhangi bir

çıkarmam yapamazlar ve uygulamada verilen verilerden herhangi bir sonuç çıkarmadığı için herhangi bir dönüşüme uğrayamazlar. Bu bilgilerinin programcı tarafından açıkça uygulanması gerekmektedir. Verileri belirli bir giriş dilinden dâhili bir dile çevirebilen tüm bilgisayar programları, talimatlardan öğrenme olarak kabul edilirler. Programcı yine de bu dönüşümün nasıl başarılı bir şekilde gerçekleştirileceği konusunda rehberlik sağlar, fakat bilgisayar programının yalnızca az miktarda çıkarmam yapması gerekmektedir. Sonuç olarak daha yüksek derecede bir öğrenme sistemini ezberci öğrenmeden ayırır.

Daha önce öğrenilen bilgilerde değişiklikler yaparak, analogi yoluyla öğrenme, genellikle hali hazırda var olanlarla karşılaştırılabilir ve bu nedenle benimsenmesi daha basit olan yeni beceriler oluşturmayı amaçlar. Dinamik bir bilgi koleksiyonu bu sistemde birleştirilip değiştirilebilmelidir. Orijinal bilgisayar programının farkında olmadığı, birkaç yeni bir yöntemin kullanılmasını gerektirmektedir. Günümüzde daha çok öğrenme yöntemlerinden biri örneklerden öğrenmedir çünkü en fazla esnekliği sunar ve bilgisayar sistemlerinin verilerdeki önceden tanımlanmamış yapıları ve kalıpları keşfetmesini sağlamaktadır. Sınıflandırma ve veri madenciliği çalışmalarında kullanılan yaygın bir strateji, mevcut örneklerin dinamik bir kümesine dayalı olarak gelen veri girdilerinin sınıflandırılmasını tahmin etmek için örneklerden bilgi edinmektir.

Herhangi bir ürünün yüzey kalitesi, öncelikle takım geometrisi, kesme hızı, iş parçasının malzemesi, kesme derinliği, ilerleme hızı ve makine dinamiği, kesme sıcaklığı ve takım aşınması gibi diğer faktörlerden etkilenir. Yukarıda belirtilen faktörlerdeki küçük sapma, işlenmiş yüzey üzerinde önemli bir etkiye neden olabilir. Bu nedenle, belirtilen değerlerin kullanımı gerekli hale gelmektedir.

İstenilen yüzey kalitesini sağlamak için en uygun ayarlar seçilmelidir. Talaşlı imalat endüstrisinde, operatörler genellikle işleme ayarlarının oluşturulması için deneysel yöntemi kullanmaktadır.

Deneysel yaklaşımlar o kadar verimli değildir. Amaçlanan sonucun elde edilmesinde malzeme israfına yol açmanın yanı sıra zaman alıcıdır. Makine öğrenimi modellerinin ortaya çıkışı, asıl işlem gerçekleştirilmeden önce işleme ayarlarını değiştirerek bu sorunu çözmek için bir çözüm olanağı sunmasıdır. Kesme sıvısının kullanılması, kesme sıcaklığının en aza indirilmesini sağlar ve düzgün yağlamaya yardımcı olarak daha iyi yüzey kalitesi sağlar.

### **1.2.1.1 Makine öğreniminin değerlendirilmesi**

Makine öğreniminin bir diğer çok önemli kısmı, bilgisayar yazılımının ürünün uygun ve analitik sonuçlarını nasıl algıladığı ve hangilerinin hata içerdiği sorunudur.

Bunun algoritma için herhangi bir sorun teşkil etmediği bir örnek, bir e-ticaret mağazasındaki müşterinin satın alma yapıp yapmayacağını tahmin etmeye çalışan bir bilgisayar programı olabilir.

Veri girişi daha sonra müşterinin ürün satın alıp almadığına dair verilen bilgilerle günlüğe kaydedilir ve daha sonra algoritmanın performansını değerlendirmek için kullanılabilir. Belge çevirilerinin analizi de dâhil olmak üzere gerçek dünya verilerine erişimi olmayan araştırma alanları daha zor durumlar sağlar. Sunulan çeviriler, bir bilgisayar algoritmasının çıktısını karşılaştırmak için önce insanlar tarafından kategorilere ayrılmalıdır. Bundan sonra, makine öğrenimi algoritması ilk algoritma kullanılarak eğitilir ve algoritmanın etkinliğini değerlendirmek için test veri seti kullanılarak performans göstergeleri hesaplanır. Küçük test ve eğitim verilerine erişim, makine öğrenimi sistemleri için yaygın bir sorundur. Bu nedenle, bu programları değerlendirirken aşırı yükleme ciddi bir sorun olabilir. X-Fold doğrulama, bu sorunun çözümüne yönelik tipik bir yaklaşımdır. Tüm veri setini X parçaya ayırma ve her birini ayrı ayrı bir test veri seti olarak kullanırken geri kalanını eğitim verileriyle birleştirme uygulaması, çapraz doğrulama olarak bilinir.

Daha sonra, performans göstergelerinin tüm doğrulama süreçleri üzerinden ortalaması alınır. Herkesin kusurları ve avantajları olduğu için, makine öğrenim algoritmalarının değerlendirilmesi ile ilgili her konu için mükemmel bir gösterge yoktur. Bir makine öğrenimi programının performansını değerlendirmek için en önemli faktörler şunlardır:

Yanlış sınıflandırma oranı, bir veri kümesindeki yanlış sınıflandırılan verilerin göreceli miktarını tanımlar.  $y_i$ ,  $i$  veri noktasının tahminiye ve  $y_i$  gerçek etiketse, yanlış sınıflandırma şu şekilde tanımlanır:

$$\text{misc}_n = \frac{1}{n} \sum (y - \hat{y}_i) \quad (1.4)$$

Yanlış sınıflandırma için temel sorun, sonuçlarının büyük ölçüde etiket miktarına veya sınıf etiketleri arasındaki veri dağılımına bağlı olmasıdır. Verilen örnekte %3'lük bir yanlış sınıflandırma oranı elde edilmektedir. Ancak veri setinin %97'sinin a sınıfı ve %3'ünün b sınıfı ile etkilendiği bir örnek verilebilir.

Karşılaştırma, göstergenin ifadesini iyileştirmek için gösterge değerine göre kıyaslama değerini değerlendirme sürecidir. Verilen örnekte denetimli öğrenme senaryosundaki ikili sınıflandırma görevi için kıyaslama algoritması her zaman en yaygın sınıfı tahmin eden bir sınıflandırıcı olabilir. Yanlış sınıflandırma oranı daha sonra

kıyaslama referansına göre tanımlanabilir. Bu durumda %20' lik bir yanlış sınıflandırma oranı, yüzde 30 puanlık kıyaslama ile karşılaştırıldığında görece bir gelişmede eşit sınıf dağılımı ile sonuçlanmaktadır.

Tüm doğru sınıflandırılmış örnekler arasında doğru sınıflandırılan örneklerin oranı, pozitif tahmin değeri olarak da bilinen doğruluk değeri olarak bilinir. Daha önce belirtilen e-ticaret örneği kullanılarak gösterilebilir. 1 kesinlik değeri etiketi satın alarak sınıflandırılan her müşterinin gerçekten bir satın alma gerçekleştirdiğini gösterir. Bunun, satın aldıkları ürünlerde ürün etiketi taşıyan müşterilerin sayısı üzerinde herhangi bir etkisi yoktur.

Weissel ve ark.(2002), Tüm gerçek örnekler arasında doğru şekilde kategorize edilmiş örneklerin oranı, duyarlılık olarak da bilinen geri çağırma değeri olarak bilinir. Sağlanan örnekte bu, 1'lik bir geri arama değerinin, bir tüketici tarafından yapılan her satın alımın işaretlendiğini gösterdiği anlamına gelir. Veri setinin her bir örneğini satın alma ile sınıflandırarak 1 hatırlama değerinin kolayca elde edilebileceğini belirtilmesi gerekir.

F-ölçme: ikisi arasındaki harmonik ortalamayı kullanarak geri çağırma ve kesinlik ifadelerini birleştirmeyi amaçlar:

$$F_1 = x \frac{\text{kesinlik} \times \text{hatırlama}}{\text{kesinlik} + \text{hatırlama}} \quad (1.5)$$

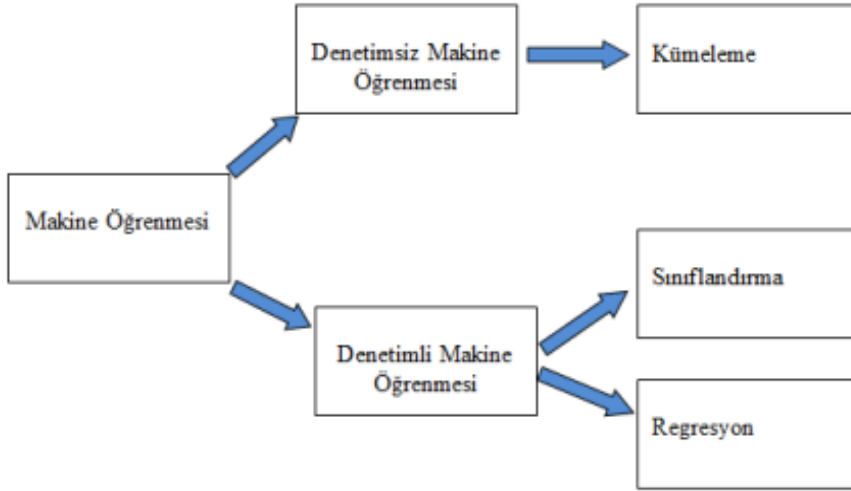
Weissel ve ark.(2002), Makine öğrenimi programlarının performansını göstermek için en iyi yaklaşımlardan biri, gerçek pozitif, yanlış pozitif, gerçek negatif ve yanlış negatif tahminleri birbirinden ayıran, beklenmedik durum tablosu olarak da adlandırılan karışıklık matrisidir.

### **1.2.1.2 Makine öğrenme grupları**

Zilyas ve Yılmaz (2023) Makine öğrenimi, 1959'da başlangıcı itibariyle yapay zekâda sayısal öğrenme ve model tanımlama çalışmasından oluşan, bilgisayar biliminin bir parçasıdır. Makine öğrenimi, bir yapı işlevi olarak verilere dayalı tahminler yapabilen algoritmalarıdır. Bu algoritmalar statik programı sıkı sıkıya takip etmek yerine, veriye dayalı tahminler ve kararlar almak için örnek girdilerden modeller oluşturarak çalışırlar. Makine öğreniminin temel oluşum nedeni temel sorunlardır. Bilgisayarların kullanım amaçlarının çalışmalarının önüne geçmesi sebebiyle işlemleri kendi başlarına gerçekleştirmeyi öğrenmeleri mümkün müdür? Sorusunu sordurur. Geliştiricileri verilerin öğrenen kuralları manuel olarak oluşturması yerine bilgisayar verilerine



bakmaktadır. Makine öğrenmesi yaklaşımları; Denetimli öğrenme, Denetimsiz öğrenme, Pekişmeli öğrenme, Yarı gözetimli öğrenme olarak ayrılmıştır.

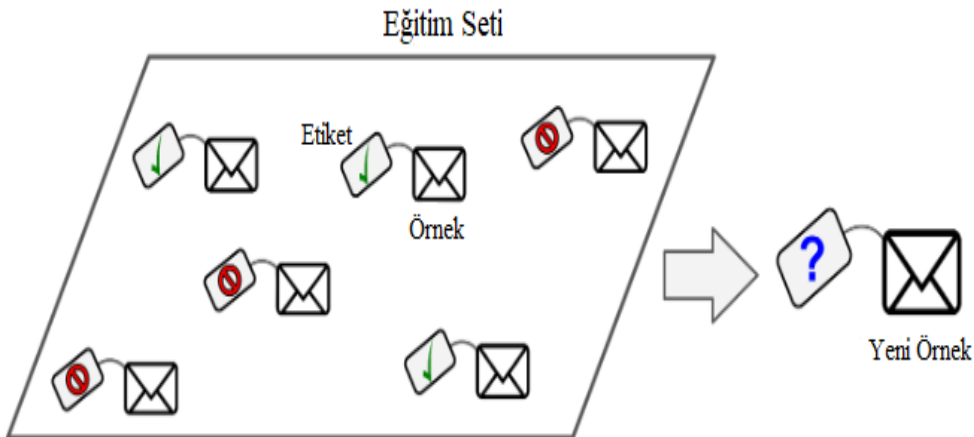


Şekil 1. 7: Makine öğrenmesi yöntemi (Calayır ve Kabak, 2021)

Calayır ve Kabak (2021) Makine öğrenmesinin meydana geldiği tarih, ilk öğrenen makinelerin oluşturulması, teori temelleri ve sinir ağları gibi öne çıkan üç olayla nitelendirilebilecek farklı dönemler altında gruplandırılmıştır. Veri madenciliğinin gelişmesinde büyük katkı sağlayan ve sıklıkla kullanılan, makine öğrenmesi yöntemleri; denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve yarı-denetimli öğrenme (semisupervised learning) algoritmalarıdır.

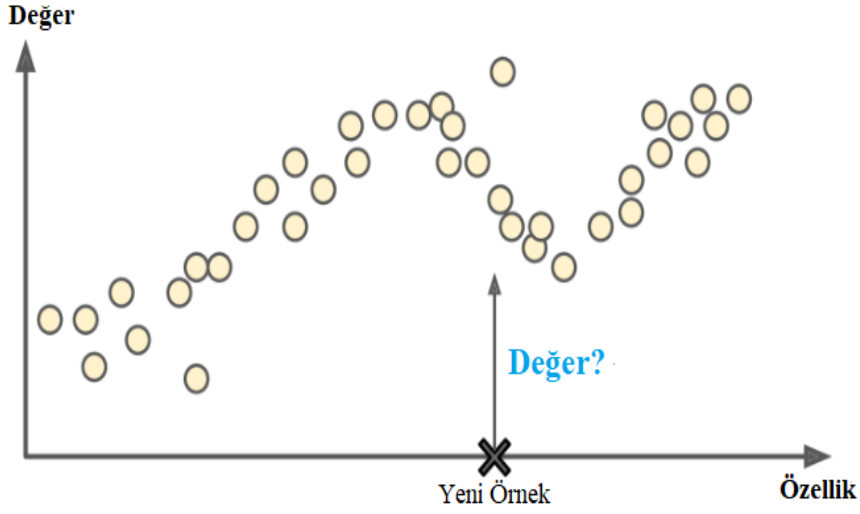
#### 1.2.1.2.1 Gözetimli öğrenme (Supervised learning)

Gözetimli öğrenme, gönderdiğimiz algoritmada eğitim verileri, etiket (label) olarak isimlendirilir, istediğimiz çözümleri verir. En yaygın gözetimli öğrenme, sınıflandırmadır (classification). İstenmeyen eposta filtresi (spam filter), gözetimli öğrenmeye güzel bir örnektir. Eğitim verisi, epostaların yanında onların istenmeyen bir şey olup olmadığını belirten etiketler içerirler.



Şekil 1. 8: E-posta sınıflandırma problemi

Başka bir yaygın olan gözetimli öğrenme örneği ise regresyondur. Regresyon probleminde, elimizdeki mevcut verilerden sayısal bir değeri tahmin etmeye çalışırız.



**Şekil 1. 9:** Regresyon problemi


Bazı regresyon algoritmaları, sınıflandırma problemleri için de kullanılabilir. Lojistik regresyon, sınıflandırma içerisinde kullanılan tekniklerden biridir.

Aşağıdaki listede en çok kullanılan gözetimli öğrenme algoritmaları şunlardır:

- k- En yakın komşu kestirimi (k-Nearest Neighbors)
- Lojistik Regresyon (Logistic Reg.)
- Karar ağaçları (Decision Trees) ve Rastgele Ormanlar (Random Forests)
- Yapay Sinir Ağları

#### 1.2.1.2.2 Gözetimsiz öğrenme (Unsupervised learning)

Gözetimsiz öğrenmede, algoritmaya gönderdiğimiz verilerin etiketleri olmaz. Algoritma bir eğitmeni olmadan kendisi öğrenmeye çalışır.




**Şekil 1. 10:** Etiket içermeyen bir eğitim seti

Aşağıdaki listede en çok kullanılan gözetimsiz öğrenme algoritmaları şunlardır:

- Öbekleme (Clustering)

k- Merkezli öbekleme (k-Means), Beklenti büyütme (Expectation Maximization)

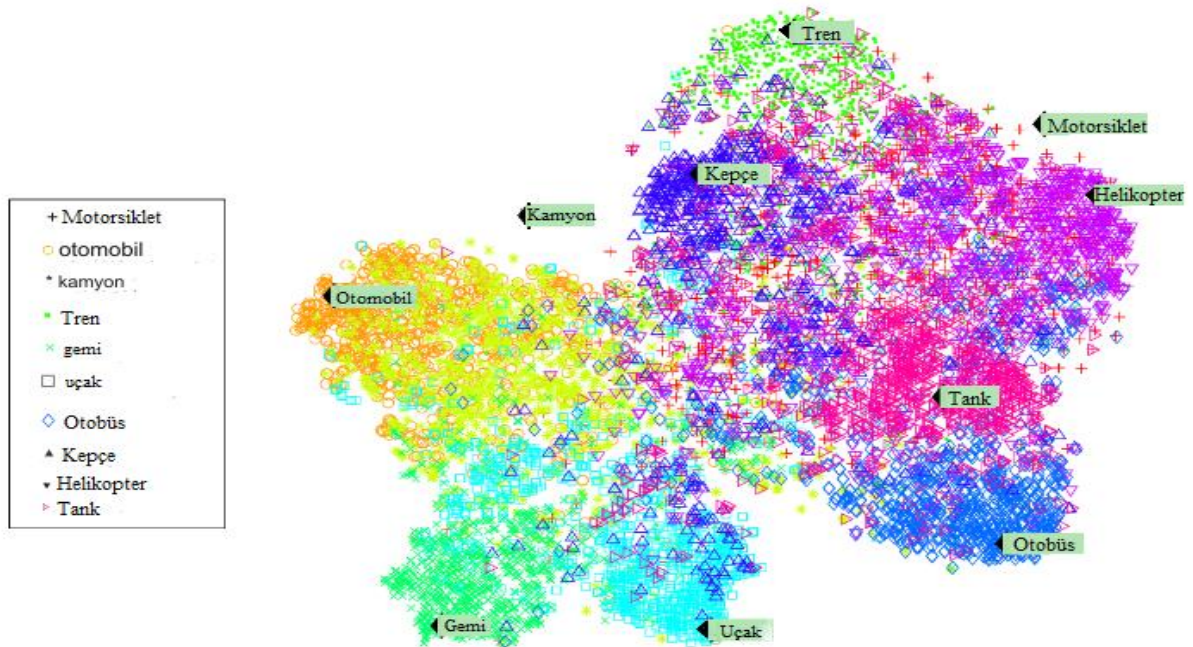
Özellik 2



Şekil 1. 11: Öbekleme

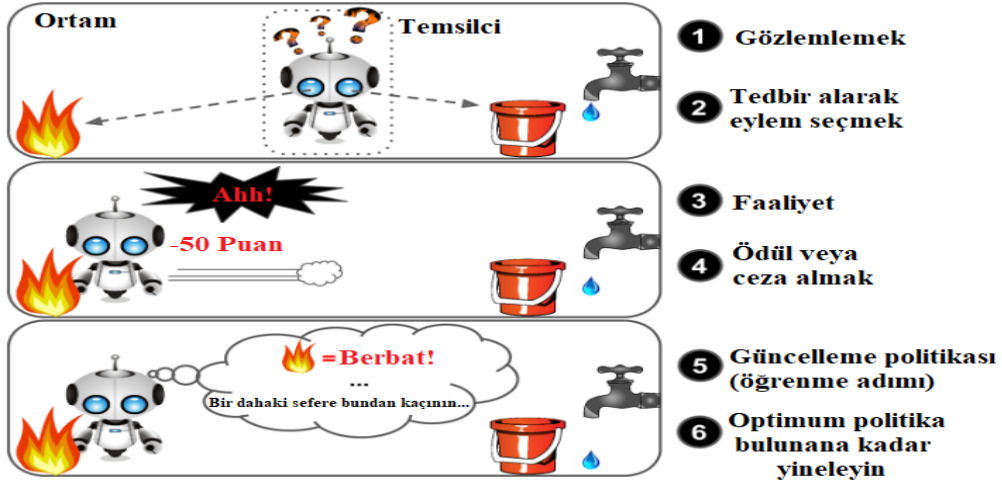
- Boyut azaltma (Dimensionality Reduction)

Temel Bileşen Çözümlemesi (Principal Component Analysis)



Şekil 1. 12: Yüksek boyutlu bir veri setinin boyutunu azaltarak görselleştirme


- İlişkilendirme kuralları (Association rule learning)
- Pekiştirmeli öğrenme (reinforcement learning)



Şekil 1. 13: Pekiştirmeli öğrenme

### 1.2.1.3 Karar ağaçları

Kaya ve Yıldız (2014) Karar ağaçları, eğitimde kullanılan metodlarda hızlı olması, sonuçlarının daha kolay bir şekilde yorumlanabilmesi ve etkin olması sebebiyle sıklıkla kullanılan yöntemlerden biri olmuştur. Karar ağaçları ile sınıflandırma iki adımda gerçekleştirilmiştir. İlk adımda ağaç oluşturuluyor. İkinci adımda bu ağaç yapısından sınıflandırma kuralları elde ediliyor. Genel olarak sınıflandırma işlemi şöyle ifade edilmiştir:  $D=\{t_1,t_2,\dots, t_n\}$  bir veri tabanı olsun ve her bir kayıt  $t_i$  ile temsil edilsin.  $C=\{C_1,C_2,\dots,C_m\}$  ise  $m$  adet sınıftan oluşan sınıflar kümesini temsil etsin diyelim. Her bir  $C_j$  ayrı bir sınıftır ve her bir sınıf kendisine ait kayıtları içerir. Yani,  $C_j=\{t_i | t_i \in C_j, 1 \leq i \leq n \text{ ve } t_i \in D\}$ , dir. Veri tabanındaki her bir kayıt için alanlar ise  $\{A_1,A_2,\dots,A_n\}$  'den oluştuğunu düşünelim. Bu tanıma ilaveten her bir kayıt  $C=\{C_1,C_2,\dots,C_m\}$  sınıflarından birine ait ise karar ağacı şöyle tanımlanabilir: Her bir düğüm  $A_i$  alanı ile isimlendirilir. Kök düğüm ile yaprak arasındaki düğümler birer sınıflandırma kuralı olur. Karar ağaçları oluşturulurken kullanılan algoritmanın ne olduğu önemlidir. Kullanılan algoritmaya göre ağacın yapısı değişebilir. Değişik ağaç yapıları farklı sınıflandırma sonuçları verilecektir. Karar ağaçlarına dayalı olarak geliştirilen bir sürü algoritma vardır.



Şekil 1. 14: Karar ağaçları gösterimi (Ziyas ve Yılmaz, 2023)

Karar ağaçları, regresyon problemleri ve sınıflandırmada kullanılan popüler makine öğrenimi algoritmalarıdır. Yüzey pürüzlülüğü analizi genellikle regresyon problemleri ile analiz edilir, çünkü belirli bir yüzeyin pürüzlülüğünü ölçmek için sürekli bir çıktı değeri gereklidir. Karar ağaçları, veri setindeki özellikleri kullanarak ağaç yapısında bir dizi karar kuralı oluşturur ve böylece girdi özelliklerine dayanarak çıktı değerlerini tahmin ederler. Karar ağaçları yüzey pürüzlülüğü analizi için önemli bir araçtır. Bu yöntem, veri setindeki özellikleri kullanarak yüzey pürüzlülüğü değerlerini tahmin etmek için etkili bir şekilde kullanılır. Ancak, doğru sonuçlar elde etmek için doğru özelliklerin seçilmesi ve modelin uygun şekilde eğitilmesi gerekmektedir.

Yapay Zekâ; İnsan zihni ile ilişkilendirilen öğrenme ve Problem çözme gibi bilimsel eylemleri taklit eden makineler. Yani bir bilgisayarın veya robotun (bilgisayar kontrollü) akıllı varlıklarla ilişkili görevleri yerine getirme yeteneğidir.

Örneğin: Su verme / yemek saatleri / hasta ilaç verme süresi-miktarı, görüntü işleme/ dil tercümesi / ses tanıma / akıllı ev sistemleri /oyun vb.

Temel amaç insan zekâsını gerektiren görevleri yapabilen makina yapımıdır. Burada yapay zekâdaki amaç: insan varlığında gözlemediğimiz akıllı davranış olarak adlandırılan davranışları gösterebilen makina/bilgisayar yapımı.

Makine öğrenme tekniğinde elde edilen; Şekil 1.11, Şekil 1.12, Şekil 1.13, Şekil 1.14' de verilen şekillerle ilgili geliştirilen yazılım programları kullanılmaktadır.

#### **1.2.1.4 Yapay sinir ağları (YSA)**

Singh ve ark.(2009), Yapay sinir ağları "biyolojik sinir ağlarına dayanan matematiksel bir model ve dolayısıyla biyolojik sinir sisteminin bir simülasyonu" olarak edilir.

Geleneksel algoritmalarla karşılaştırıldığında, sinir ağlarının uygulanması daha basittir. Oldukça karmaşık problemlerin üstesinden gelebilir. Yapay sinir ağları kendi kendini organize eden ve basit yapıları nedeniyle kullanılmaktadır. Bu, insanların programcılarının yardımı olmadan çeşitli sorunları çözmelerini sağlar. Gösterildiği gibi, bir sinir ağı, bir müşterinin satın alma yapıp yapmayacağını tahmin etmek için çevrimiçi bir işletmedeki müşteri davranışı hakkındaki bilgileri kullanarak eğitilebilir.

Nöron olarak da bilinen düğümler, bu nöronlar arasında ağın öğrenme sürecinde değiştirilebilen ağırlıklı bağlantılardır. Her düğümün giriş değerlerine bağlı olarak çıkış değerini hesaplayan bir aktivasyon fonksiyonu yapay sinir ağını oluşturur. Bir sinir ağındaki her katman farklıdır. Çıktı katmanı ağ çıktısı üretir, gizli katmanlar girdi ve çıktı katmanlarını birbirine bağlar ve girdi katmanı, ilgili girdi verilerinin öznitelik değerleri gibi dış kaynaklardan bilgi alır. Düğümlerin ara bağlantılarının eşleşen ağırlığı ile

çarpılan toplam gelen düğüm sayısı, her katmandaki her bir düğümün giriş değerini verir. Ek olarak, sinir ağları iki kategoriden biriyle ifade edilmektedir:

- Ağın kendisinden girdi almayan herhangi bir ağ, ileri beslemeli ağ olarak adlandırılır. Bu, giriş verilerinin gizli düğümlerden 0'dan n'ye tek bir yönde giriş düğümlerinden çıkış düğümlerine doğru aktığını gösterir. Sistem yeniden kalibrasyonu için geriye dönük veri sunulmamıştır.

- Geri bildirim seçeneğine sahip olan tüm ağlar, tekrarlayan ağlar olarak kabul edilir. Çünkü bunlar, öğrenme sürecinin önceki aşamalarındaki verileri sonraki aşamalarda kullanabilir. Ağdaki her düğüm için aynı olan önceden ayarlanmış bir işlevdeki her giriş değeri.

Her düğüm için çıkış değerini hesaplamak için kullanılır. Sigmoid fonksiyonu ( $o_j$ ) daha çok fonksiyondur ve aşağıdaki gibi tanımlanır:

$$o_j = \frac{1}{1 + e^{-i_j}} \quad (1.6)$$

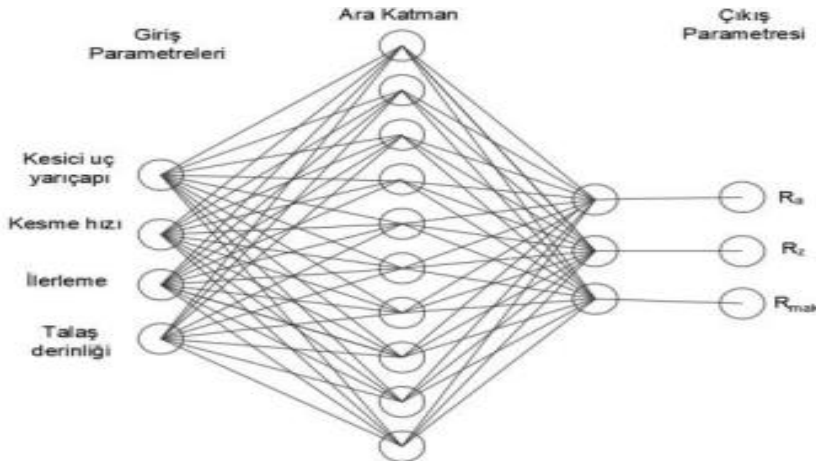
Burada  $i_j$ , j'nin tüm girdi düğümlerinden oluşur.

$$e = 1 + 1! + \frac{1}{2!} + \frac{1}{3!} + \dots + \frac{1}{n!} \quad (1.7)$$

$e_{\max} = 2.72$  (Euler Sayısı )

Erb (1993), bu fonksiyonun iki önemli avantajının, 0 ile 1 arasındaki değerlerin normalleştirilmesi ve doğrusal olmayan yapısı olduğunu iddia ediyor ve hızlı ve basit ağ öğrenimi sağlar ve aşırı yük ve baskınlık etkilerini önler.

Bir veya daha fazla özelliğin amaçlanan hedef özellik üzerinde önemli bir etkisi olduğunda, diğer özellikler ilgisiz hale gelir ve böylece baskın hale gelir. Bu fenomen baskınlık etkisi olarak bilinir. Giriş katmanında üç giriş düğümü, bir gizli katman ve iki çıkış düğümü bulunan Yapay sinir ağı örneği Şekil 1.15'de gösterilmektedir.



Şekil 1.15: Yapay Sinir Ağı Modeli (YSA) (Erb., 1993)

#### 1.2.1.4.1 Geri yayılım

Geri yayılım, sinir ağlarında, ağdaki yerel bir hatayı kullanarak ağdaki ara bağlantıların ağırlıklarını geri dönüşümlü olarak sıfırlamak için kullanılan prosedürdür. Bu açıkça, bir dizi girdi değeri için bir tahmin oluşturulduktan ve hata hesaplandıktan sonra gerçek çıktı değerinin tahmin değeriyle karşılaştırılacağı anlamına gelir.

Bağlantılar daha sonra bu hata kullanılarak yeniden düzenler ağdan ayrılan düğümlere doğrudan bağlı olan kenarlardan başlayarak ve yoluna devam eder. Sinir ağını eğitmeden önce öğrenmeyi hızlandırmak için kullanılabilecek temel değişkenler önem kazanır.

Dubey ve ark. (2021), Öğrenme oranı, öğrenme sürecinin uygulamaya konulduğu orandır. Her bir çıkış değerinin yerel yanlılığı, 0 ila 1 aralığına sahip olan parametre değeri ile birleştirilir. 0 öğrenme oranı, bu nedenle uyarılma yapılmamasına neden olur. Öğrenme temposunun doğru ayarlanması sürecin başarılı olabilmesi için şarttır. Ağırlıklar değişebileceğinden, değer çok yüksek ayarlandığında en iyi değerleri bulmak zorlaşır. Bununla birlikte, değer çok düşük ayarlanırsa, hataların ağı yeni bir optimizasyona itmek için yeterli ağırlığı olmayacağından ağırlıklar yerel maksimumda kalabilir.

Doğru ayarları bulmak için bir bozulma parametresi eklenebilir. Bu parametre, yüksek bir öğrenme oranı değeri sağlar.

Yerel maksimumda takılıp kalmamak için eğitim sürecinin önceki döngüleri ve salınımı önlemek için öğrenme süreci sırasında azaltılmasını zorlar.

Sinir ağları için bir diğer önemli parametre ise momentumdur. Son ağırlık değişiminin bir kısmını kullanarak iyileştirme sürecini yumuşatmak ve yeni ağırlık değişikliğine eklemek için kullanılır.

Minimum hata; 2.1.3 alt bölümünde açıklanan Karar Ağaçları için durdurma kriterine benzer şekilde öğrenme süreci için bir durdurma kriteridir. Ağın birleşik hatası bu eşiğin altına düştüğünde öğrenme süreci durdurulur.

Bu parametreleri toplayarak, bağlantı için yeni ağırlık hesaplama formülü aşağıdaki gibidir:

$$W = 1 * \epsilon + m * W_p \quad (1.8)$$

Burada, W: yeni ağırlık değişimidir.

(1) öğrenme oranıdır.

$\epsilon$  : minimum hatadır.

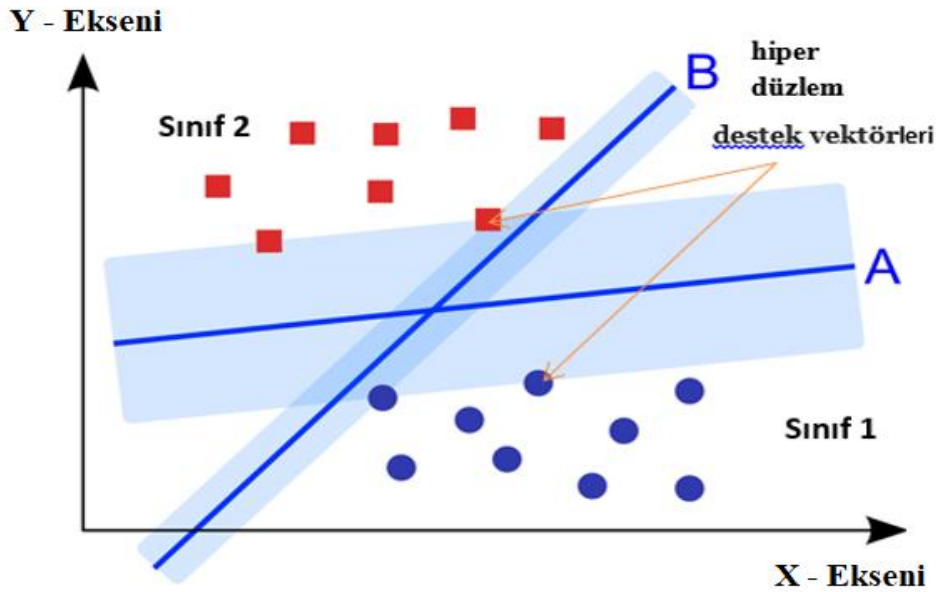
m : momentumdur.

$W_p$  : önceki döngünün ağırlık değişimidir.

### 1.2.1.5 Destek vektör makineleri

Destek vektör makineleri denetimli öğrenme teknikleridir, bu nedenle yeni keşfedilen verileri kategorilere ayırmak için önceden bilinen ve etiketlenmiş verileri kullanırlar. Veri sınıflandırmasına temel yaklaşım, veri noktalarını (A) mümkün olan en az hata miktarıyla veya (B) mümkün olan en büyük marjla ilgili etiketlere bölen bir fonksiyon oluşturmaya çalışmakla başlar. Bunun nedeni, atama işlevinin yanındaki daha geniş boşluklarda etiketlerin birbirinden daha kolay ayırt edilmesidir ve bu da daha az hatayla sonuçlanır.

Şekil 1.16'da veri setinin herhangi bir sorunla karşılaşmadan çeşitli fonksiyonlara bölünebileceğini göstermektedir. Bu nedenle, ayırma işlevini çevreleyen marj, ayırmanın kalitesini değerlendirmek için ek bir parametre olarak kullanılır. A ayrımı bu durumda iki sınıfı doğru bir şekilde ayırdığı için tercih edilir. İlk yaklaşımda SVM (Support Vector Machine- Destek Vektör Makinesi ) yaptığı şey, iki sınıfın verileri arasında bir ayırma çizgisi ( veya hiper düzlem ) bulmaktır. SVM, verileri girdi olarak alan ve mümkünse bu sınıfları ayıran bir çizgi çıkaran bir algoritmadır. Bir sorunla başlayalım. Aşağıda gösterildiği gibi bir veri kümeniz olduğunu ve mavi elipslerden ( kırmızı dikdörtgenleri sınıflandırmanız gerektiğini varsayalım. Yani göreviniz bu veri kümesini iki sınıfta ayıran ideal bir çizgi bulmaktır ( kırmızı ve mavi ).



**Şekil 1. 16:** Veri setini iki ayrı doğrusal ayırma kullanarak iki gruba ayıran vektör makinesi

Steinwart ve Christman (2008) Çevrimiçi bir mağazada satın alma yapma olasılığını belirlemeye yönelik bir örnek, n veri noktasından oluşan bir veri kümesi kullanır; burada her veri noktası, o belirli oturuma ilişkin veri değerlerini tutan bir nitelik vektöründen (x)



ve bir etiketten oluşur. (y) müşterinin satın alma işlemi yapıp yapmadığının belirtilmesi. Ortaya çıkan fonksiyon, eğer veriler tamamen doğrusal ise yaklaşan olayları sınıflandırmak için kullanılabilir. Bu stratejideki iki önemli konuya değinilmiştir. İlk olarak, SVM artık tüm veri noktalarını (x, y) y = yanlış olan modeldeki (x, y) tüm veri noktalarından ayıran bir işlem bulmaya çalışıyor.

- Veriler, doğrusal olarak ayrılabilir olabilir veya olmayabilir; bu, gerçek dünya verilerinde sıklıkla görülen bir durumdur. Yukarıda verilen örnekte, örneğin bir çevrimiçi mağazada iki müşterinin tamamen benzer şekilde hareket etmesi ve bunlardan yalnızca birinin satın alma yapması söz konusu olabilir. Bu, aynı özellik vektörünün farklı etiketlere sahip olması nedeniyle ayrılamaz verilerle sonuçlanacaktır.

- SVM'nin potansiyel aşırı yükleme ikinci sorundur. Bunu önlemek için ön işleme sırasında verilerdeki gürültünün tanımlanması ve bazı hatalı sınıflandırmaların kabul edilmesi önemlidir. Aksi takdirde SVM yanlış doğruluk değerleri üretecek ve bu da gelecekteki oluşumların yanlış sınıflandırılmasına yol açacaktır.

#### 1.2.1.6 Markov karar süreçleri

MDP'ler (Markov Decision Process -Markov karar süreçleri), MDP adı Rus matematikçi Andrey Markov'dan geliyor çünkü Markov'un zincirlerinin bir uzantısı olarak bilinen ayırık rastgele kontrol süreçleri, sonuçların kısmen kontrollü ve kısmen rastgele olduğu sistemler için karar verme modelleri olarak sıklıkla kullanılır. Kontrol teorisine, yapay zekâya ve karar vermeye sıklıkla uygulanırlar. MDP'deki her adım bir adımdır, sürecin içinde olması için s olası durum vardır ve karar verici s'den uygun eylemi seçmekte özgürdür. MDP'ler dörtlü bir gruptan ( $S, A, Pa, Ra$ ) oluşur;

Burada S, sonlu bir durum sayısındır, A her bir durumdan elde edilebilen sonlu bir eylemler dizisidir,

$$P_a(s, s') = Pr(s_{t+1} = s' | s_t = s, a_t = a) \quad (1.9)$$

(t) zamanında (s) durumundaki (a) eylemin gerçekleşme olasılığıdır. (t + 1) zamanında (s') durumuna yol açar ve  $R_a(s, s')$ , s durumundan s' durumuna geçişin sonra alınan veya beklenen anında ödül eylem nedeniyle (a).

#### 1.2.1.7 Bayes sınıflandırması

Bazı öğrenimi sonucun olasılığını hesaplamak için önceki sonuçların olasılıkları ile gözlem ve kanıtların kullanımını içeren bir denetimli öğrenme şeklidir. Daha spesifik olarak, belirli bir hipotezin doğru olma olasılığı, gözlenen bazı kanıtlar (hipotezin arka olasılığı) göz önüne alındığında, hipotezin önceki olasılığı ile gözlemlenen kanıtın hipotezle uyumluluğunun (hipotez olasılığı) bir kombinasyonundan gelir.

Bu tezdeki ilk taktik, Young ve ark. (2019) tarafından geliştirilen sınıflandırma yöntemine dayanmaktadır. Bayes denklemi bir öğrenme türü kullanır. Bu sınıflandırma

yöntemi, bir dizi girdi özelliğinin,  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ , bir dizi çıktı ölçümüne eşlenmesini içerir.

$\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$ . Sınıflandırma için öğrenme, TS büyüklüğünde bir  $\gamma$  eğitim grubu oluşturarak yapılır. Bu eğitim setini kullanarak girdi özelliklerinden bir çıktı ölçüsüne tutarlı bir eşleme bulmak, sınıflandırıcının bir dizi girdi özelliğinin sınıfını doğru bir şekilde tahmin etmesini sağlar.

Sınıflandırma görevi, kanıtları, kategorinin olasılığını ve önceki olasılığı kullanarak her kategorinin son olasılıklarını belirlemek ve ardından en yüksek nihai olasılığa sahip kategoriye seçmektir. İki giriş özelliği için son olasılıkları hesaplamak için aşağıdaki denklem kullanılır:

$$\text{Sonsal Olasılık} = (\text{Olasılık} \times \text{Öncül Olasılık}) / \text{Kanıt} \quad (1.10)$$

Sonsal (posterior) olasılık :  $p(y/x) \rightarrow (x, \text{özellikleri})$  tahminine göre  $(y, \text{hedef})$  'in sonsal olasılığıdır.

Olasılık(probability) :  $p(x/y) \rightarrow$  verilen katmanı tahmin etme olasılığıdır.

Öncül( prior probability) Olasılık:  $p(y) \rightarrow$  sınıfın önceki olasılığıdır.

Kanıt:  $p(x) \rightarrow$  belirlenen önceki olasılığıdır

$$\text{Prob}[y = c / (x_1, x_2)] = \frac{\text{Prob}[(x_1, x_2) | y = c] \times \text{Prob}(y = c)}{\text{Prob}(x_1, x_2)} \quad (1.11)$$

Payda araştırması  $(x_1, x_2)$  olarak da bilinen kanıt, bir  $\mathbf{X}$  gözleminin tüm potansiyel hipotezler altında hesaba katılmasının marjinal olasılığıdır. Tüm sınıf görevlerinde sabit olduğu için karar vermekle ilgisi yoktur.

$\text{Prob}(y = c)$ ,  $y$  uygulama sınıfının  $(c)$  olduğu hipotezinin önsel olasılığıdır. Bu eğitim setinden kolayca hesaplanır.

$\text{Prob}(x_1, x_2 | y = c)$ ,  $y$  uygulama sınıfının  $c$  olması koşuluyla,  $\mathbf{X}$  girdi öznitelik vektörünü görmenin girdi-özellik başına koşullu olasılığıdır.

$$\text{Prob}[(x_1, x_2) | y = c] = \text{Prob}(x_1 | y = c) \times \text{Prob}(x_2 | y = c) \quad (1.12)$$

Böylece, bir sınıfın sonsal olasılığı aşağıdaki gibi hesaplanabilir:

$$\text{Prob}(y = c) = \text{Prob}(x_1, x_2 | y = c) \times \text{Prob}(y = c) \quad (1.13)$$

Eğitim setindeki yetersiz veri noktası sayısı nedeniyle, girdi özelliklerinin çıktı ölçeğiyle eşleşmediği belirli durumlar olabilir ve bu da koşullu bir sıfır olasılığına yol açar. Bu yüzden onları yumuşatarak onlardan kurtuluyoruz:

$$\text{Prob}(x | y = c) = \text{frekans}(x_i, y = c) + \lambda \text{ i frekans}(y = c) + \lambda n x \quad (1.14)$$

Burada  $\lambda$  bir yumuşatma sabitidir ( $\lambda > 0$ ) ve  $nx$ ,  $x_i$ 'nin gözlemlenen farklı niteliklerinin sayısıdır.

### 1.2.1.8 Q - öğrenme

Q- Öğrenme olarak bilinen pekiştirmeli öğrenme yöntemi kullanılırken ortamın bir modeli gerekli değildir. Q- Öğrenme algoritması, bir model oluşturmak için ortamı araştırır. Tüm potansiyel eylemlerden bir olasılıkla rastgele bir eylem seçtiğimiz ve 1 s olasılıkla en uygun eylemi seçtiğimiz keşif aşaması için bir seçenektir. Durum ve iş kombinasyon kalitesini belirlediğinden iş değerinin fonksiyonu Q olarak da bilinir. Mevcut durum,  $st$ , bir eylem,  $at$  verildiğinde,  $st$ ,  $rt+1$ , sonraki durum,  $st+1$  ve sonraki eylem,  $at+1$  durumunda eyleme geçmek için yeni Q fonksiyon değerleri hesaplanır. Aşağıdaki denklemi kullanarak her olası durum-eylem çifti hesaplanabilir:

$$Q^{new}(s_t, a_t) \rightarrow 1 - \alpha \cdot Q(s_t, a_t) + \alpha \cdot (r_t + \gamma \times \max_a Q(s_{t+1}, a)) \quad (1.15)$$

Burada  $0 < \alpha \leq 1$  öğrenme oranıdır ve  $0 \leq \gamma < 1$  indirim faktörüdür. Önceki Q değerlerinin aşılma derecesi, öğrenme hızına bağlı olarak değişmektedir.

### 1.2.1.9 Lineer diskriminant analizi

Bayesian sınıflandırma yaklaşımı, parametrelerin bir önceki dağılımın rastgele değişkenleri olarak kabul edildiği doğrusal LDA (Lineer Diskriminant Analizi) kullanılır. Örnekleri bir sınıfa atayan veya bölen bir fonksiyonun öğrenildiği veriye dayalı doğrusal ve doğrusal olmayan diskriminant analiziyle karşılaştırıldığında bu fikir tamamen farklıdır. Öğrenilen her sınıftan örneklerin bir modelini kullandığından, Bayes tahmininin LDA ile kullanımına bazen üretken modelleme denir. Ön bilgi parametrelerin ön dağılımın rastgele değişkenleri olarak dikkate alınmasıyla kullanılabilir.

Dubey ve ark.(2021), Örneğin, bir ortalama  $\mu$ 'nin a ve b arasında olma olasılığının çok yüksek olduğunu bilerek, olasılık, yoğunluğun büyük kısmı a ve b arasında olacak şekilde belirlenebilir.

Choi (2006), Önceden bir olasılık dağılımı ve bir sınıf olabilirliği verildiğinde, Bayes teoremi (denklem 1.16), bir maksimum a posteriori (MAP; denklem 1.17) kullanarak yeni bir gözlemlenen örnek  $x_n$  için bir sınıf tahmini ( $C_k$ ) türetmek üzere bir sonsal olasılık elde etmek için çağrılabilir.

$$p(C_k | x_n) = p(C_k)p(x_n|C_k)/ p(x) \quad (1.16)$$

$$\arg_k \max p(C_k|x_n) p(C_k) \quad (1.17)$$

LDA, hem tek deęişkenli hem de çok deęişkenli girdi uzaylarının ve ikili veya çok sınıflı sınıflandırmanın çok çeşitli sınıflandırma problemlerine uygulanabilir. Aşağıdaki Denklem 1.18'de gösterildiği gibi (çalışmamızda kullandığımız) Gauss veya normal dağılım, en sık kullanılan istatistiksel dağılım işlevidir.

$$N(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2} \quad (1.18)$$

Gauss dağılımının, doğa ve sosyal bilimler de dahil olmak üzere çeşitli çalışma alanlarında kullanılan önde gelen bir model olmasının birkaç nedeni vardır, ancak basit bir görüş, Gauss dağılımının şeklinin, iyi bilinen çan şeklinin genellikle kabul edilebilir bir model olduğudur. Bu fikir, Gauss şeklinin kovaryans  $\sigma$  ve ortalama  $\mu$  tarafından kontrol edilmesi gerçeğiyle ortaya çıkar.

Varyans (veya eğrinin genişliği) verilerin varyansını gösterirken, ortalamanın konumu (veya eğrinin tepesi) rastgele deęişkenlerin nerede kümelenme eğiliminde olduğu tahmin edilir.

#### 1.2.1.10 Lineer lojistik regresyon

Lineer diskriminant analizine (LDA) benzer bir şekilde, lineer lojistik regresyon (LLR), doğrudan  $p(C_k|x_n)$ 'yi tahmin eden bir lineer model oluşturmaya yönelik bir yöntemdir. Ancak bunu, verilerin olasılığını artıran lineer kısıtlamalar uygulayarak yapar. Mevcut verilere dayalı olasılıksal modeller oluşturmak için Denklem 1.19, tüm doğrusal fonksiyon deęerlerinin 0 ile 1 arasında olmasını ve  $x_n$ 'nin herhangi bir deęeri için hepsinin toplamının 1 olmasını gerektirerek LLR'nin  $p(C_k|x_n)$ 'yi nasıl doğrudan ifade ettiğini gösterir.

$$p(C_k|x_n) = \sum_{m=1}^K f(x_n, \beta_k) f(x_n, B_m) \quad m=1 \quad (1.19)$$

LDA ile Bayes teoremi, sınıf öncelikleri ve sınıf olasılık modelleri, daha sonra belirli bir örnek  $x_n$  için farklı sınıflar arasında ayırım yapmak için kullanılan sınıf sonsal olasılıklarını çıkarmak için kullanıldı. Buna karşılık, LLR, veri olasılığını en üst düzeye çıkarmak için doğrudan gradyanları kullanarak doğrusal ağırlık parametreleri  $\beta_k$  için çözülebilir.

Bu, olabilirlik fonksiyonu numaralandırılarak yapılır,  $L(\beta)$ , her  $t_n, k \in \{0, 1\}$  deęerinin ve her satırın yalnızca tek 1. sınıf deęişken dönüşümleri gösterge deęişkenleri olarak bilinir ve her bir örnek  $x_n$  için doğru terimlerin seçimindeki fonksiyonun üslerinde kullanılmaktadır.

$$C = \{k_1, k_2, k_3, \dots, k_n\}$$

↓

$$\begin{array}{cccc} t_{1,1} & t_{1,2} & \dots & t_{1,k} \\ t_{2,1} & t_{2,2} & \dots & t_{2,k} \\ \vdots & \vdots & & \vdots \\ t_{n,1} & t_{n,2} & \dots & t_{n,k} \end{array} \quad (1.20)$$

N          K

$$L(\beta) = \prod_{n=1}^N \prod_{k=1}^K p(C_k | x_n)^{t_{n,k}} \quad (1.21)$$

Veri olasılığını maksimize eden  $\beta$ 'yı bulmak için, ürünlerin çarpımı,  $\beta$ 'ya göre gradyan hesaplamasını basitleştirmek için doğal logaritma kullanılarak toplamların toplamına dönüştürülür. Denklem (1.22) doğrusal olmadığından, ölçekli eşlenik gradyan veya gradyan inişi gibi yinelemeli yöntemler, log olabilirlik  $A\beta LL(\beta)$  gradyanını çözmek ve ilgili  $\beta$  ağırlıklarını elde etmek için kullanılabilir.


$$LL(\beta) = \sum_{n=1}^N \cdot \sum_{k=1}^K t_{n,k} \log p\left(\frac{C_k}{x_n}\right) \quad (1.22)$$

#### 1.2.1.11 Ölçekli eşlenik gradyan

Basit eğik çizgi iniş algoritmaları, eğimi takip ederken sabit bir adım boyutu  $\delta$  kullanır. Yavaş yakınsama süreleri, sabitlendiğinde ideal değerin seçilmesindeki zorluktan kaynaklanabilir. Bunun yerine, her yinelemede emin olmak için tek boyutlu yinelemeli aramalar olan bir dizi gradyan eğilim çizgisi araması yapmak tercih edilir. Hat aramalarını gerçekleştirmeyi belirtmenin önceden belirlenmiş bir adım boyutuna sahip olmaktan daha tercih edilir olmasına rağmen, ortaya çıkan gradyan iniş sürecinde farklı problemleri kapsar.

Örneğin eğim iniş yönleri çakıştığı için eğim boyunca bir yöndeki bir minimum diğer yönlere geçmiş minimum değerleri bozabilir. Eşlenik olmayan yönleri hesaplayan eşlenik gradyan algoritmaları bu sorunu çözmek için kullanılmaktadır.

Gradyan iniş (kırmızı çizgi) ve eşlenik gradyan iniş (yeşil çizgi),  $x_0$  noktasında başlayan ve  $x$  noktasında minimumu bulmak için eğimden aşağı inen algoritma örnekleridir.



**Şekil 1. 17:** Eşlenik Gradyan (yeşil çizgi) ve Gradyan İniş (kırmızı çizgi) Algoritmalarının Karşılaştırılması (Qian , 2010)

Qian (2010), Eşlenik yönlerde çizgi aramaları, adım boyutunu hesaplamak için geleneksel eşlenik gradyan algoritmalarında hala kullanılmaktadır. Satır aramalarının belirli dezavantajları da vardır, yani algoritmanın performansına zarar verebilecek yinelemeli hata hesaplamalarına duyulan ihtiyaç. Hata azaltmadaki başarıya ve olasılığa ikinci dereceden yaklaşımın esasına dayalı olarak, SCG (Kademeli Eşlenik Gradyan) algoritmaları satır aramanın yerini almaktadır.

#### 1.2.1.12 Doğrusal olmayan lojistik regresyon ile sinir ağları

Yaygın olarak sinir ağı modelleri olarak adlandırılan yapay sinir ağları, insan beyninin çalıştığına inanılan şekilde modellenmiştir. Beyin, öğrenme, algılama ve duyuşal işlemeyle ilgili olanlar da dâhil olmak üzere pek çok günlük bilgi işleme ihtiyacını mevcut herhangi bir bilgisayar sisteminden daha iyi karşılamaktadır.

Weissel ve ark.(2002), İnsan beyni modern bilgisayarlardan çok farklı olmasına rağmen, hesaplama birimi olarak görev yapan sinapsların ve nöronların varlığı nedeniyle temel fikirlerin hala doğru olduğuna inanılıyor. Temel fark, insan beyninin, devasa çok katmanlı bir ağda birbirine bağlanan sinapslar ve nöronlarla birlikte milyarlarca temel paralel işlem biriminden oluşmasıdır.

Makine öğrenimi söz konusu olduğunda bu fikirler, diğer algılayıcılar tarafından ağırlıklı bağlantılar yoluyla bağlanan temel işlem elemanı olan algılayıcı olarak

modellenir. Denklem 1.23, sensörün çıktısının, ağırlıklı yanlılığı içeren girdilerinin ağırlıklı toplamı olduğunu göstermektedir.

$$y = \sum_{i=1}^n w_i x_i + w_0 \quad (1.23)$$

Sinir ağının çıktısını ve  $y_i$  ile hedef arasındaki ortalama kare hatasını en aza indiren ağırlık parametrelerini ( $w_i$ ) belirlemek için bir eğitim veri kümesi kullanarak,  $y$ 'nin çıktısını hesaplamak için bir  $x_i$ ,  $i=1,2,\dots,n$ , örneği vererek geri yayılım kullanılır.  $w_0 = 1$  Varsayılan olarak sinir ağının bir parçası olan bir üst seviye (birden çok sensör için), sınıfları gruplara ayırmak için doğrusal bir ayırıcı olarak kullanılabilir. Tahmin doğruluğunu artırmak için Denklem 1.24'te belirtildiği gibi gizli birim katmanı detektörlerini doğrusal olmayan detektörlere dönüştürüyoruz. Bu, sinir ağının çıktısının doğrusal ağırlıklara ancak doğrusal olmayan girdilere sahip olduğu doğrusal olmayan ve doğrusal olmayan sınırların kullanımına izin verir.

$$y'_i = \text{sigmoid}(y_i) = \frac{1}{1 + \exp(-w^T x)} \quad (1.24)$$

Burada  $y_i$ , gizli katmanın Çıkış vektörüdür.

Bir sinir ağı ile sınıflandırma için (doğrusal olmayan lojistik regresyon), paralel çıktı algılayıcılarının sayısı, sınıfların sayısına eşittir. Her algılayıcıdan gelen çıktı,  $y_i$ , daha sonra, son işlenmiş çıktılarının maksimumunu alınarak ilgili sınıfı belirlemek için denklem 1.25'deki işleme gönderilir:

$$\text{softmax}_i(y) = \frac{\exp(y^i)}{\sum_{j=1}^n \exp(y^j)} \quad (1.25)$$

Qian (2010), Sinir ağlarının kullanımına yönelik en büyük eleştirilerden biri eğitim için gereken süredir. Basit bir dereceli iniş yaklaşımı kullanmak bunu ciddi bir sorun haline getirebilirken, kademeli eşlenik gradyan (SCG) dâhil olmak üzere daha yeni eğitim yöntemleri, eğitim için gereken süreyi büyük ölçüde azaltabilir.


### 1.2.1.13 K-En yakın komşu

Qian (2010), KNN (K-Nearest Neighbours - K-En Yakın Komşular) tekniği, veri sınıflandırma problemine denetimsiz ve parametrik olmayan bir yaklaşımdır. Parametrik olmayan tahminin temel dayanağı, karşılaştırılabilir girdilerin eşdeğer sonuçlara yol açacağıdır.

Özellik uzayındaki en yakın  $k$  örnek arasında en yaygın olan sınıf belirlenerek yeni örnekler KNN kullanılarak sınıflandırılır. Öklid mesafesi yaygın olarak kullanılsa da, bu yaklaşım başka tür bir mesafe ölçümü gerektirir. Her biri 'i' öznitelikleri içeren iki  $a$  ve  $b$  noktası arasındaki Öklid uzaklığı, denklem 1.26'da tanımlanmıştır.


$$d(a, b) = \sqrt{\sum_{i=1}^n (b_i - a_i)^2} \quad (1.26)$$

Bir uygulamayı inceleyelim. Şekil 1.18 'de mavi kareler ve kırmızı üçgenler içeren bir veri seti gösterilmektedir. Mavi kare veya kırmızı üçgen kategorisine ait güncel bir örnek, yeşil dairedir. Yeni örnek,  $k = 3$  ise (yarıçapı 3 olan daha küçük iç daire ile temsil edilir) incelenen alanda daha fazla kırmızı üçgen olduğundan, kırmızı üçgen olarak kategorize edilmiştir. Yeni örnek,  $k = 5$  ise mavi bir kare olarak kategorize edilir.



$k = 3$

Class = ▲



$k = 5$

Class = ■

Şekil 1. 18: K-en Yakın Komşu Örneği





## 2.ÖNCEKİ ÇALIŞMALAR

Liu ve ark.(2009), Çok sayıda girdinin olduğu ve girdiler ile çıktılar arasındaki ilişkinin karmaşık fiziksel süreçler nedeniyle belirsiz olduğu verimli metal işlemeyle ilgili görevlerin tahmin edilmesinde, makine öğrenim (ML) yöntemlerinin özellikle başarılı olduğu kanıtlanmıştır. Takım ömrü tahmini, metal işleme endüstrisinden bir örnektir. Bu özellikle sert frezeleme gibi işlemler için kritik öneme sahiptir.

Basit ve zor kırılma mekaniği problemlerini çözmeye yardımcı olmak için Makine öğrenimi ve sinir ağı modelleri üzerine araştırmalar yaptı.

Bu çalışmada; üreticiler için daha kullanışlı ve pratik bir yöntem geliştirmek amacıyla uyumlu/sürekli veya kırılmalı/kırılmızsız işleme sonuçları ve yüzey ölçüm parametreleri için ayrı tahminler yapmak amacıyla makine öğrenimini kullanan imalat mühendisleri için daha kullanışlı bir araç oluşturdu. Yüzey kırılması, işleme parametrelerinin bir fonksiyonu olarak ayrı ayrı meydana gelmez, ancak genellikle yüzey görünümünde ani bir değişiklik olarak ortaya çıkar. İşleme girdi parametreleri (talaş açısı, ilerleme, takım yarıçapı ve kesme derinliği gibi) ile yüzey ölçüm parametreleri (aritmetik ortalama yüzey pürüzlülüğü, tepeden vadiye ve çarpıklık gibi) arasındaki karmaşık ilişkiler nedeniyle elmas kalem uçlu tornalama sırasındaki fiziksel davranışlar makine öğrenimi için ideal bir uygulamadır.

Böylece, çıktıyı ikili bir karara basitleştirmek, çeşitli makine öğrenimi sınıflandırma yöntemlerinin kullanılmasına izin verir. Burada geliştirilen takımlar: (1) klasik geometrik işleme parametrelerini (örn. takım yarıçapı, kesme derinliği) malzeme deformasyonunu ve deformasyon oranlarını (örn. maksimum kesilmemiş talaş kalınlığı); (2) model oluşturma sırasında işleme parametrelerini ve doğrudan ölçülen yüzey metrolojisi parametrelerini kullanarak yüzey kırılmasını tanımlayarak nihai ürün kalite güvencesinin tahminini iyileştirmek ve (3) kırılma sonucunu öngören sınıflandırma modellerine makineyle işleme parametreleriyle birlikte girdi olarak yüzey metrolojisi parametrelerini tahmin etmek için yeni bir Auto ML regresyon modelinin dâhil edilmesi. Auto ML modelleme uygulamasını sınıflandırma görevine genişleterek, (3)'ün faydası, üreticinin veri biliminde uzmanlığa sahip olmasını gerektirmemesidir. Ayrıca, (2) ve (3)'ün her ikisi de işleme sonuçlarının proses içi veya üretim sonrası ölçümünü gerektirmez çünkü tahmin modelleri üretim çalışmalarından önce oluşturulur.

Gösterilen sonuç, "kırılma" veya "kırılma yok" şeklinde ikili bir tahmin yapan ve bir üretim mühendisinin üretken üretim parametrelerini seçmek için kullanabileceği uygun/olmayan yanıtları sağlayan bir makine öğrenimi modelidir. Giriş parametreleri ile

yüzey bütünlüğü arasındaki, daha önce önemli olduğu düşünülmemeyen korelasyonların bilimsel olarak araştırılması farklı bir sonuçtur. Örneğin daha yüksek kesme hızları daha iyi yüzey kalitesiyle sonuçlanabiliyorsa yüzey kalitesinden ödün vermeden talaş kaldırma oranları artırılabilir.

Yılmaz ve ark.(2014), frezeleme işlemlerinde kesme parametrelerinin titreşim ivme seviyesi ve yüzey kalitesi üzerindeki etkileri araştırılmış ve optimum işleme parametreleri tespit edilmiştir. Deneylerde Taguchi tasarım tekniği kullanılmış ve 132, 220, 308 mm/min kesme hızı, 0,05, 0,1, 0,2 mm/tooth ilerleme, 1, 1,5 mm kesme derinliği ve 1, 2, 4 adet uç sayısı kontrol faktörleri olarak belirlenmiştir. İşleme parametrelerine uygun olarak deneylerde Taguchi L 18 ( $2^1 \times 3^3$ ) orthogonal dizi seçilmiştir. Deney sonuçları değerlendirilirken Minitab 15 yazılımı yardımıyla sinyal/gürültü (S/N) oranı esas alınmış ve optimum titreşim ivmesi seviyesi ve yüzey pürüzlülüğü değerlerini veren kontrol faktörleri belirlenmiştir. Kontrol faktörlerinin sonuçlara etkisi ANOVA (ANalysis Of VARIance - Varyans Analizi ) yardımıyla bulunmuştur. Sonuç olarak titreşim ivme seviyesi ve yüzey pürüzlülüğünün en fazla ilerleme değerinden etkilendiği tespit edilmiştir.

Elangovan ve ark.(2015) girişimi, yüzey pürüzlülüğünü tahmin etmek için dönme sırasında titreşim verilerinin toplanmasını içeriyordu. Araştırmaları, makine öğrenimi teknolojisindeki temel bileşen analizi özelliğinin azaltılmasının, daha az hesaplama işi ve artan öngörülebilirlik ile sonuçlandığını ortaya çıkardı.

Sharma ve ark.(2016), daha az yağlama gerektiren çeşitli geleneksel kesme sıvıları ve nanoakışkanlar üzerindeki çalışması bunların uygulamalarını kapsıyordu. Kesme sıvısına nanoakışkan ilavesinin kesme kuvvetini, yüzey kalitesini ve takım aşınmasını nasıl etkilediği araştırıldı.

Mia ve ark.(2018), Sertleştirilmiş çeliğin dönüşümü için bir sürdürülebilirlik modeli geliştirmek amacıyla bir çevre koruma stratejisi olan Spor Matrisini kullandı. MQL ile katı yağlayıcılarla desteklenen basınçlı hava arasında yapılan bir karşılaştırma, MQL'in daha temiz üretimi desteklediğini ve çevre dostu olduğunu gösterdi.

Sampaio ve ark.(2018), 1045 çeliğinin zor tornalanması durumunda PCBN( polycrystalline cubic boron nitride- polikristalin kübik bor nitrür) takımının aşınmasını, talaş oluşumunu ve yüzey pürüzlülüğünü araştırdı. MQL'in soğutma etkisi nedeniyle kesme kuvvetleri ve delik aşınması azalır.

Abbas ve ark.(2019), AISI 1045 paslanmaz çelik yüzey kaplamasının sürdürülebilirliğini ve enerji kullanımını araştırdılar. Tornalama, kuru, taşkın ve

minimum miktarda yağlama ortamlarında gerçekleştirildi; MQL(Minimum quantity lubrication-Minimum miktarda yağlama) tornalama, daha düşük güç tüketimi ve yüzey kalitesi sağlayan 0,7 ağırlıklı sürdürülebilirlik indeksi ile daha iyi özellikler gösterdi.

Abbas ve ark.(2019), üç farklı yağlama modu kullanarak 1045 çeliği dönüştürdü: kuru, aşırı ve MQL. Kesme ayarlarını iyileştirmek için üç adet çok amaçlı optimizasyon modeli kullanılmıştır.

Bonfa ve ark.(2019), deneyler sırasında AISI D6 çeliğine biyolojik olarak parçalanabilen kesme sıvısını üç yönde uygulayarak yüzey pürüzlülüğünü ölçebildiler. Sonuçlar, takım yüzeyine MQL uygulandığında en düşük yüzey pürüzlülüğünün 0,05 mm/dev ilerleme hızında üretildiğini gösterdi.

Lin ve ark.(2019), yüzey pürüzlülüğünü ölçmek için titreşim sinyallerini analiz etmek üzere derin öğrenmeyi kullandı. FFT-DNN (Fast Fourier Transform-Deep Neural Networks )1-D CNN (one-dimensional convolutional neural network -Hızlı Fourier Dönüşümü Derin Sinir Ağları) tek boyutlu evrimsel sinir ağı ve FFT-LSTM (Fast Fourier Transform Long Short Term Memory Network - Hızlı Fourier Uzun Kısa Vadeli Bellek Ağı Dönüştürme), eğitim ve performansı tahmin etmek için kullanılan üç modeldi. Titreşim sinyalleriyle birlikte 1D CNN ve FFT-LSTM modelinin kullanılması tavsiye edilmektedir.

Alajmi ve ark.(2020), AISI 304 paslanmaz çeliğin yüzey pürüzlülüğünü mape-QPSO( Adaptive Neuro-Fuzzy Inference System-The Quantum Particle Swarm Optimization) yöntemini kullanarak tahmin etmiştir. Kuru tornalama ile kriyojenik tornalama arasındaki farklar tartışılmıştır. Tahmin doğruluğunu değerlendirmek için R2 ( the coefficient of determination-belirleme katsayısı), RMSE ( Root Mean Square Error-kök ortalama kare hatası) ve MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hatası) metrikleri kullanıldı. Beklenen değer ile kuru eğirme denemeleri arasındaki MAPE %4,95 olarak kaydedilirken, soğutulmuş eğirme için bu oran %5,15 olarak kaydedildi.

Dubey ve ark.(2020), işleme için çeşitli soğutma metodolojilerini gözden geçirdi. Kesme kuvvetini, yüzey pürüzlülüğünü ve takım aşınmasını azaltmak için MQL uygulamasının diğer tekniklere göre daha iyi olduğu belirlendi.

Sizemore ve ark.(2020), tarafından makine öğrenimi yöntemleri kullanıldı. Elmas tornalamada yüzey pürüzlülüğünü tahmin etmek için. Hem bakır hem de germanyum için elmas dönüşümü sırasında, yapay sinir ağı (ANN), karar ağaçları, destek vektör makineleri (SVM) dâhil olmak üzere dört farklı makine öğrenimi ML(Machine learning-

Makine Öğrenim) modelinin tahmin gücü değerlendirildi. Makine öğrenimi modelleriyle karşılaştırıldığı YSA modeli, minimum hatayla tahminler üretti.

Eser ve ark.(2021), Alüminyum alaşımları araştırmalarına konu olmuştur. RSM ve ANN kullanılarak oluşturulan modeller arasında R2, MDP ve RMSE (Root Mean Square Error- Kök Ortalama Kare Hatası) karşılaştırmaları yapıldı. RSM kullanılarak elde edilen R2'nin YSA'dan daha yüksek bir değere sahip olması, RSM modelinin YSA'ya göre üstün kararlılığını gösterdi.

Manjunath ve ark.(2021), Ultra hassas işleme bağlamında yüzey pürüzlülüğünün öngörülmesini ve izlenmesini değerlendirdiler. İvmeölçer, gerinim ölçer sensörü, piezoelektrik dönüştürücü ve akustik emisyon dahil olmak üzere çeşitli veri toplama cihazlarının bir tartışmasını içerir.

Raza ve ark.(2021), tarafından yüzey için 30NiCrMoV14 alaşımı incelendi. 0,19 mm/dev ilerleme hızında 0,137 mm yüzey kalitesi elde edildi; bu da ilerleme hızının kritik bir faktör olduğunu kanıtladı.

Dubey ve ark.(2021), nanoakışkanla zenginleştirilmiş kesme sıvısı kullanarak çelik üzerinde tornalama gerçekleştirdi. Bunun yüzey pürüzlülüğü ve kesme sıcaklığı üzerindeki etkisini inceledi. Hibrit nanoakışkan kullanıldığında yüzey pürüzlülüğü tek nanoakışkanla karşılaştırıldığında %31 oranında azalıtı.

Khanna ve diğerleri (2021), En iyi ayarlar 147 m/dak kesme hızı, 0,28 mm kesme derinliği ve 0,06 mm/dev besleme hızıydı. Üçü arasında MQL en iyi sonuçları verdi. Ti-6Al-4V ELI dönüşümünün işleme kapasitelerinin ve hizmet ömrü değerlendirmesinin karşılaştırmalı analizi. Soğutmalı işleme, kesme kuvveti açısından MQL'yi ve taşma işlemeyi geçti, ancak MQL takım ömrü açısından daha iyi sonuç verdi. MQL işleme, fazladan yağ olmaması nedeniyle daha küçük bir çevresel etkiye sahip olmuştur.

Korkmaz ve ark.(2021), Nimonic 80A (Nikel alaşım malzemesi), kuru, taşma ve MQL ayarlarında nozül yönünü değiştirerek. Kuru tornalamaya göre takım aşınmasındaki azalma %60 mertebesinde aşınma ve yapışma takım işlemenin başlıca nedenleriydi. Kriyojenik ve minimum yağlamayı birleştirilip ortalama kesme hızı değiştirilerek, yüzey topolojisi iyileştirilmiş ve yüzey kalitesi düşürülmüştür. İyileştirilen bölgenin yağlanması için MQL ve kriyojenik teknolojiler kullanılmıştır. MQL örneğinde üretilen yüzey pürüzlülüğü, MQL büyüklüğü işlenmiş iş parçası üzerinde koruyucu bir tabaka oluşturduğundan daha düşüktü.

Dubey ve ark.(2021), işleme alanındaki sıcaklığı ve çeşitli kesme koşullarını ölçmek için çeşitli yöntemler. Sıcaklığın doğrudan ve dolaylı olarak nasıl izleneceği

irdelendi. Çeşitli yöntemler arasındaki sıcaklıkları karşılaştırmak için termokupullar kullanılarak başarılı sonuçlar elde edildi.

Gupta ve ark.(2022), 2205 dubleks çeliği araştırdı ve kuru ve MQL ortamlarında tornalama gerçekleştirdi ve meme açısını değiştirerek işleme tribolojik özellikleri üzerindeki etkisini inceledi. Çift jetli MQL uygulaması, takım aşınmasıyla birlikte daha düşük güç tüketimi ile sonuçlandı.

Khanna ve ark.(2022), Çökeltmiş paslanmaz çeliği dönüştürürken enerji kullanımını incelemek için sekiz farklı akışkan kesme tekniği kullanmışlardır. Çalışmada dokuz benzersiz girdi parametresi kombinasyonu kullanıldı. Yağ buharının kesme bölgesine verimli bir şekilde nüfuz etmesi nedeniyle, küçük miktarlarda elektrostatik yağlamaya batırılan hibrit nanopartiküller, karşılaştırma analizinde en düşük enerji kullanımını gösterdi.

Ross ve ark.(2022), yüzey pürüzlülüğünü analiz etmek için Nimonic 80A alaşımının öğütülmesinde MQL ve kriyojenik soğutma kullanmış ve sonucu hibrit kriyo-MQL soğutma ile karşılaştırmıştır. İş parçasına hibrit yağlama yaklaşımının uygulanması kesme bölgesindeki sürtünmenin azalması nedeniyle tane boyutunun küçülmesine ve dolayısıyla soğutma etkisine neden olmuştur.

Sap ve ark.(2022), bakır bazlı bir kompozit üzerinde kuru, MQL ve kriyojenik soğutma ortamlarında öğütme üzerine deneyler gerçekleştirdi. Çalışma, kriyojenik işlemenin kesme sıcaklığını düşürerek tribolojik özelliklerin iyileştirilmesine neden olduğunu ve MQL'nin gelişmiş yüzey özellikleriyle sonuçlandığını ortaya koydu.

Çamlı ve ark.(2022), İçten soğutmalı uygulama ile dıştan soğutmalı uygulama karşılaştırıldığında, kesme sıcaklığı %40 daha düşüktü. Tren tekerleği uygulamalarında kullanılan ER7 (European Railway) çeliği üzerinde MQL kuru ortam, MQL ve nano akışkanlarla deneyleri. Çalışmalar, sırasıyla 300 m/dak ve 0,15 mm/köprülleme önerilen kesme hızı ve ilerleme hızında en iyi sonucu verdi. MQL ve nano-MQL söndürme kullanımı ile yüzey pürüzlülüğü sırasıyla %24 ve %34 oranında azaltılmıştır.

Gupta ve ark.(2022), AA2024-T351 alaşımı sıvı nitrojen ve karbondioksit yağlama ile kuru ortamda dönüştürüldüğünde kesme dayanımı ve kesme sıcaklığı sonlu eleman modellemesi kullanılarak hesaplanır. Bulgular daha sonra deneysel verilerle karşılaştırılır. Beklenen sonuçlar, deneyin sonuçlarıyla yakından eşleşir. Sarkan kenarlar kriyojenik söndürme ile en aza indirildiğinden kesme kuvvetlerinin azaldığı gözlemlendi.

Literatürden birçok araştırmacının çeşitli makine öğrenme teknikleri kullanarak kuru veya soğuk haddelenmiş çeliğin tornalanması sırasında çeşitli malzemeler üzerinde

kesme kuvveti, yüzey pürüzlülüğü ve takım aşınmasını tahmin etmeye çalıştıkları belirlendi.

Nano partiküller açısından zengin bir kesme sıvısı ortamında yüzey pürüzlülüğünü tahmin etmek özellikle zordur. Birçok çalışma, MQL metodolojisini yürütmek için nano akışkanları kullanmıştır, ancak bir kesme sıvısındaki parçacık boyutundaki değişikliğin makine öğrenimi kullanılarak tahmin edilmesi daha yeni bir yöntemdir. Bu çalışmada, ortalama tane boyutları 30 - 40 nm olan alümina nano partiküller ve işleme için farklı tane boyutlarına sahip iki farklı kesme sıvısı kullanıldı.

### 3.MATERYAL VE METOT

#### 3.1 Materyal

Tezde makine öğreniminin yüzey pürüzlülüğü parametrelerinde analizler olarak farklı üç malzemenin yüzey pürüzlülüğünü değerlendirmek üzere deney yapıldı. Bu deneyin yapılış nedeni üç farklı malzemenin yüzey pürüzlülüklerinin farklılıklar gösteriyor olup olmamasıdır. Deneyde materyal ve metot şu şekildedir:

1. **Alüminyum Numuneleri:** Endüstriyel kalitede düz levha alüminyum malzemesi (Şekil 3.1’de gösterilmiştir)
2. **Çelik Numuneleri:** Karbon çelikten imal edilmiş düz levhalar (Şekil 3.2’de gösterilmiştir)
3. **Plastik Numuneleri:** Polimerik bir malzemedan üretilmiş standart numuneler (Şekil 3.3’te gösterilmiştir)

#### Deney Malzemeleri

- **Profilometre Cihazı:** Yüzey pürüzlülüğünü ölçmek için Mitutoyo marka SurfTest SJ-210 model ve İnsize ISR – C300 marka pürüzlülük ölçer cihazları kullanıldı. (Tablo 3.1’de Cihazlara ait özellikler, Şekil 3.4’te sırasıyla A ve B olarak gösterilmiştir)
- **Numune Hazırlama Ekipmanları:** Numunelerin düzgün bir şekilde hazırlanması için kesme makinesi, zımpara kâğıtları ve temizleme solüsyonları kullanıldı.
- **Bilgisayar ve Yazılım:** Veri analizi için bilgisayar kullanılarak elde edilen plastik numunenin pürüzlülük grafiği (Şekil 3.5’te gösterilmiştir)

#### 3.2 Metod

Yüzey pürüzlülüğü; Malzemenin yüzeyindeki mikro yapısal özellikleri tanımlayan önemli bir parametredir. Bu parametreler malzemenin işlevselliği, dayanıklılığı, performansı ve estetik görünümü üzerinde doğrudan etkilidir. Bu nedenle, yüzey pürüzlülüğünün doğru bir şekilde analiz edilmesi ve optimize edilmesi, birçok endüstriyel uygulama için kritik öneme sahiptir. Makine öğrenimi teknikleri, bu karmaşık yapıları anlamak, parametreleri belirlemek ve işleme koşullarını optimize etmek için güçlü bir araç olarak hizmet eder.

Makine öğreniminin yüzey pürüzlülüğü üzerindeki ana amacı, yüzey pürüzlülüğü parametrelerini doğru bir şekilde analiz etmek ve tahmin etmek için güçlü ve verimli bir model oluşturmaktır. Bu amaç doğrultusunda bir dizi alt hedef belirlenebilir:



**3.2.1 Parametrelerin tanımlanması:** İlk olarak yüzey pürüzlülüğünü tanımlayan ve etkileyen temel parametrelerin belirlenmesi önemlidir. Bu parametreler genellikle ortalama pürüzlülük (Ra), en yüksek pürüzlülük (Rz), toplam pürüzlülük (Rt) gibi ölçümlerden elde edilmektedir.

**3.2.2 Veri toplama ve hazırlama:** Makine öğrenimi modelleri, uygun bir veri seti üzerinde eğitilir. Bu nedenle, yüzey pürüzlülüğünü etkileyen faktörleri temsil eden doğru ve kapsamlı bir veri seti toplanmalı ve hazırlanmalıdır. Bu süreç, özellikle büyük miktarda ve çeşitlilik gösteren verilerin toplandığı endüstriyel ortamlarda dikkatlice yapılmalıdır.

**3.2.3 Model oluşturma ve eğitim:** Veri seti üzerinde uygun bir makine öğrenimi modelinin seçilmesi ve eğitilmesi gereklidir. Bu model, yüzey pürüzlülüğünü tahmin etmek için öğrenilerek genellemesi doğru bir şekilde yapılmalıdır.

**3.2.4 Doğrulama ve değerlendirme:** Oluşturulan modelin performansı, çeşitli doğrulama teknikleri kullanılarak değerlendirilmelidir. Bu, modelin genelleme yeteneğini değerlendirmek ve gerçek dünya verilerine nasıl tepki verdiğini anlamak için gereklidir.

**3.2.5 Optimizasyon ve uygulama:** Oluşturulan modelin doğruluğu ve güvenilirliği doğrulandıktan sonra, bu model gerçek dünya uygulamalarında kullanılabilir. Örneğin, bir üretim sürecinin belirli bir pürüzlülük seviyesine ulaşması için gerekli işleme parametrelerini belirlemekte kullanılabilir.

**3.2.6 Sürekli iyileştirme ve geri bildirim döngüsü:** Makine öğrenimi modelleri, sürekli olarak geri bildirim alarak ve yeni verilerle eğitilerek sürekli olarak iyileştirilebilir. Modelin güncel kalmasını ve değişen koşullara uyumunu sağlar.

Bu hedefler, yüzey pürüzlülüğü analizi ve optimize edilmesi için makine öğrenimi tekniklerinin kullanılmasında temel bir çerçeve sağlar. Bu süreç endüstriyel uygulamalarda ürün kalitesi ve işlem verimliliğini artırılması ile maliyetlerin azaltılmasına yardımcı olacaktır.


## **Deney Metodolojisi**

- **Numune Hazırlığı:** Her malzeme için standart boyutlarda numuneler kesildi. Numuneler, pürüzsüz ve düzgün bir yüzeye sahip olacak şekilde zımparalandı ve temizlendi.
- **Profilometre Ölçümleri:** Her bir numune için profilometre cihazı kullanılarak yüzey pürüzlülüğü ölçümleri gerçekleştirildi. Ölçümler, numunenin farklı bölgelerinde ve farklı yönlerde tekrarlanarak ortalamalar alındı.


- **Veri Analizi:** Profilometre tarafından elde edilen veriler, Ra, Rz, Rq gibi temel pürüzlülük parametrelerini hesaplamak için uygun yazılım araçları kullanılarak analiz edildi.
- **Kalibrasyon:** Profilometre cihazı her ölçüm öncesinde kalibre edildi. Kalibrasyon işlemi, cihazın doğru ölçümler yapmasını sağlamak için düzenli aralıklarla gerçekleştirildi.
- **Numune Seçimi:** Malzeme örnekleri, homojen ve temsil edici numuneler seçilerek deneye dâhil edildi. Numunelerin pürüzsüz yüzeylere sahip olduğundan emin olmak için görsel incelemeler yapıldı.
- **Ölçüm Standartları:** Tüm ölçümler uluslararası standartlara uygun olarak gerçekleştirildi. ISO 4287 ve ISO 25178 gibi pürüzlülük ölçümü için standartlar göz önünde bulunduruldu.
- **Deney Ortamı:** Ölçümler, kontrol edilmiş bir laboratuvar ortamında sabit sıcaklık ve nem koşullarında gerçekleştirilerek dış etkenlerin ölçümlerinin etkilememesi için gerekli önlemler alındı.
- **Tekrarlanabilirlik Kontrolü:** Ölçümler, her bir numune için en az üç kez tekrarlanarak tekrarlanabilirlik kontrolü sağlandı. Elde edilen verilerin tutarlılığı ve güvenilirliği sağlandı.
- **Veri Analizi Yazılımı:** Profilometre tarafından elde edilen veriler özel olarak tasarlanmış veri analizi yazılımı kullanılarak işlendi ve analiz edildi.  
Bu yazılım pürüzlülük parametrelerinin hesaplanması ve istatistiksel analizlerin yapılması için uygun araçlar sağladı.
- **Hata Analizi:** Ölçüm hatalarını minimize etmek için sürekli hata analizleri yapıldı. Ölçüm prosedürleri ve numune hazırlığı adımları sürekli olarak gözden geçirilerek geliştirildi.

**İstatistiksel Analiz:** Elde edilen verilerin istatistiksel analizi, Anova (Varyans Analizi) ve Tukey testi gibi uygun istatistiksel yöntemler kullanılarak elde edilmektedir. Bu analizler, farklı malzemeler arasındaki pürüzlülük farklarını değerlendirmek ve sonuçların güvenilirliğini sağlamak için yapılmaktadır.


Bu şekilde deneyde kullanılan malzemelerin ve metodolojinin detaylı bir şekilde açıklaması, deneyin tekrarlanabilirliğini ve sonuçların güvenilirliğini artırmaktadır.




**Şekil 3.1:**Endüstriyel kalitede düz levha alüminyum malzemesi.



**Şekil 3. 2:** Karbon çelikten imal edilmiş düz levhalar.



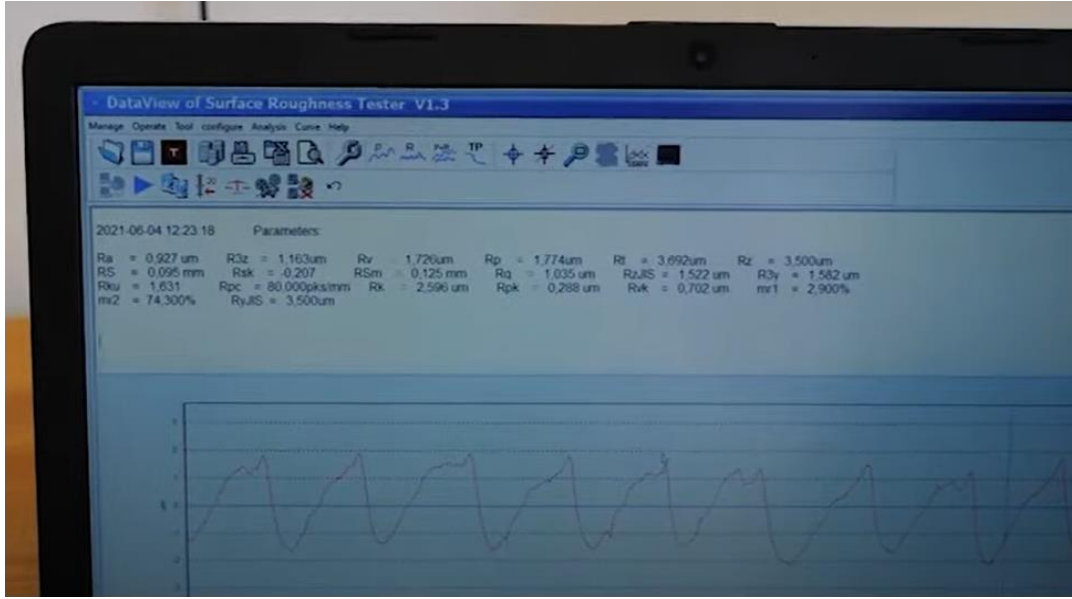
Şekil 3. 3: Polimerik bir malzemeden üretilmiş standart numune.



Şekil 3. 4: a) Mitutoyo Marka SurfTest SJ-210 model ve b) İnsize ISR – C300 marka Pürüzlülük Ölçme cihazı

**Tablo 3. 1:** Kullanılan Ölçme Cihazlarına ait özellikler.

| Model                                 | Mitutoyo marka SurfTest SJ-210 model Pürüzlülük Ölçme cihazı | İnsize ISR – C300 marka Pürüzlülük Ölçme cihazı |
|---------------------------------------|--|---|
| Ölçme Hızı, mm/s                      | 0.25- 0.5 - 0.75   | 0.135 - 0.5 - 1                                 |
| Ölçme Kuvveti, Mn                     | 0.75   | 4   |
| Uç Malzemesi                          | Elmas  | Elmas   |
| Kesme Uzunluğu( $\lambda_c$ ), mm     | 0.08 - 0.25 - 0.8 - 2.5                                      | 0.25 - 0.8 - 2.5                                |
| Değerlendirme Uzunluğu, $\mu\text{m}$ | 300, (- 160 ~ 160) aralığında                                | 320 ,(-160 ~ 160) aralığında                    |



**Şekil 3. 5:** İnsize ISR – C300 marka cihazdan elde edilen Plastik numunenin yüzey pürüzlülük grafiği

#### 4.BULGULAR VE TARTIŞMA

Tezde yapılan deney sonucunda alüminyum, çelik ve plastik numunelerden elde edilen sonuçların iki makine ile ölçümünden edinilen sonuçlar Tablo 4.1, Tablo 4.2 ve Tablo 4.3'te sırasıyla verilmiştir:

**Tablo 4. 1:** Alüminyum Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ )

| Pürüzlülük Değerleri | Mitutoyo marka SurfTest                | İnsize ISR – C300 marka<br>Pürüzlülük Ölçer cihaz |
|----------------------|--|---|
|                      | SJ-210 model Pürüzlülük<br>Ölçer cihaz |   |
| Ra ( $\mu\text{m}$ ) | 0.294                                  | 0.262   |
| Rz ( $\mu\text{m}$ ) | 2.509                                  | 2.224   |
| Rq ( $\mu\text{m}$ ) | 0.376                                  | 0.334   |

**Tablo 4. 2:** Çelik Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ )

| Pürüzlülük Değerleri | Mitutoyo marka SurfTest | İnsize ISR – C300 marka<br>Pürüzlülük Ölçer cihaz |
|----------------------|-------------------------|---|
|                      | SJ-210 model cihaz      |   |
| Ra ( $\mu\text{m}$ ) | 0.323                   | 0.313   |
| Rz ( $\mu\text{m}$ ) | 2.794                   | 2.578   |
| Rq ( $\mu\text{m}$ ) | 0.403                   | 0.378   |

**Tablo 4. 3:** Plastik Numunelerin Yüzey Pürüzlülük Değerleri ( $\mu\text{m}$ )

| Pürüzlülük Değerleri | Mitutoyo marka SurfTest | İnsize ISR – C300 marka<br>Pürüzlülük Ölçer cihaz |
|----------------------|-------------------------|---|
|                      | SJ-210 model cihaz      |   |
| Ra ( $\mu\text{m}$ ) | 1.167                   | 0.927   |
| Rz ( $\mu\text{m}$ ) | 3.716                   | 3.5   |
| Rq ( $\mu\text{m}$ ) | 1.068                   | 1.035   |

Her üç malzeme grubunda da elde edilen sonuçlar neticesinde iki makine arasında bir farklılık olduğunu gösterdi ( $< 0.05$ ). Belirli malzemelerdeki farklılıkları doğrulanmış oldu. Bulgularımız her iki makinenin de genel olarak benzer sonuçlar sağladığını ancak bazı malzemelerde küçük farklılıklar olduğunu bizlere göstermiştir. Özellikle, alüminyum numunelerinde İnsize ISR – C300 marka Pürüzlülük Ölçer cihazda daha düşük Ra ve Rz değerleri sağladığı görülmektedir. Profilometre cihazlarının arasındaki küçük farklılıklar her iki makinenin de ölçüm hassasiyetinin ve doğruluğunun yüksek olduğunu göstermektedir. Ancak belirli malzemelerdeki farklılıklar makine seçimi ve ölçüm şartlarının önemini belirler. Bulgularımız endüstriyel uygulamalarda malzeme seçimi ve işleme süreçlerinin optimize edilmesi açısından profilometre cihazlarının sonuçlar açısından önemlidir. Daha hassas ve doğru sonuçlar, ürün kalitesi ve performansını artırmaktadır. Bulgularımızı analiz ederken, Ra, Rz ve Rq gibi pürüzlülük parametreleri arasında belirli bir irtibat vardır. Örneğin Ra değeri arttıkça genellikle Rz ve Rq değerlerinin de arttığı görülmektedir. Farklı pürüzlülük parametrelerinin malzeme yüzeyinin özelliklerinin belirlenmesine imkân sağlamıştır. Çalışmada belirli malzemeler üzerinde pürüzlülük ölçümleri yaparken, farklı işleme parametrelerinin (örneğin, kesme hızı, besleme hızı, kesici takım malzemesi vb.) bu parametreler üzerindeki etkisini doğrudan incelendi. Bulgularımız yüzey pürüzlülüğünün endüstriyel uygulamalarda önemli bir faktör olduğunu ve malzeme seçimi, üretim süreçleri ve kalite kontrolü gibi alanlarda önemli bir değere sahiptir. Daha düşük pürüzlülük değerlerine sahip malzemelerin belirli uygulamalarda tercih edilebileceği ve bu parametrelerin ürün performansı üzerinde belirleyici olabileceği düşünüldü. Çalışma sırasında, ölçüm prosedürlerinin standartlaştırılması belirlendi. Standartlaştırılmış ölçümlerin tekrarlanabilirliği ve sonuçların karşılaştırılmasını yapılmıştır. Herhangi bir ölçüm cihazının doğruluğu ve hassasiyeti sınırlıdır. Elde edilen sonuçlarda belirsizlik oluşturmaktadır. Bu nedenle ölçüm hatalarını tanımlamak ve bunların sonuçları üzerindeki potansiyel etkisini değerlendirmek önemlidir. Farklı profilometre cihazlarının ve ölçüm tekniklerinin daha ayrıntılı bir şekilde karşılaştırılması, belirli malzemeler üzerindeki pürüzlülük etkisinin endüstriyel uygulamalarda optimize edilmesi gibi konular önem arz etmektedir.

Yüzey pürüzlülük uzunluklarını hesaplamak için dört makine öğrenme tekniğinin etkinliği Şekil 4.1 ve 4.2'de gösterilmektedir. Makine öğrenimi tekniklerinden elde edilen sonuçlar istenilen değerdedir. Tüm modellerde gözlemlenen ve tahmin edilen günlük z0m

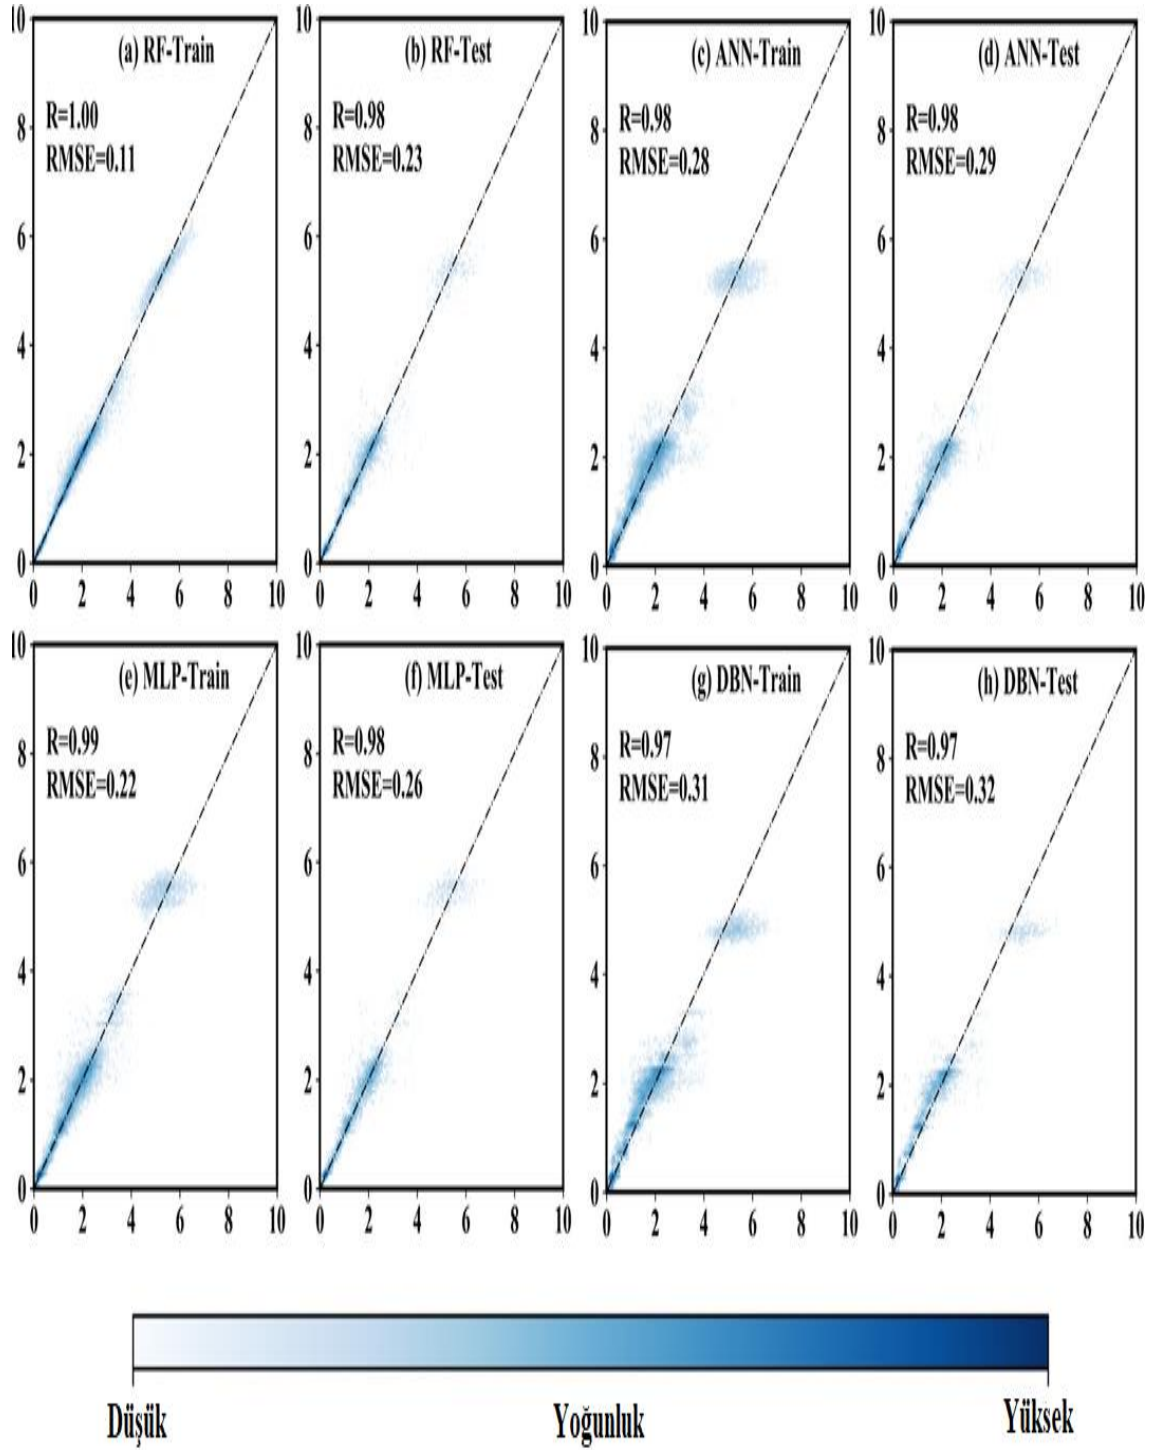
değerinin korelasyon katsayısı (R), aerodinamik pürüzlülüğün uzunluğu açısından 1'e yaklaşmaktadır.

RF yöntemi için kök ortalama kare hatası (RMSE), sırasıyla eğitimde 0,11 m ve testte 0,23 m'dir. Buna karşılık, YSA yaklaşımı, sırasıyla 0,28m ve 0,29m'lik eğitim ve test RMSE'leri verir. Derin sinir ağı teknikleri birbirinden çok farklı çalışmaktadır. DBN (Deep Belief Network - Derin Düşünce Ağı) yöntemi, hem eğitim hem de testte 0,31 m'yi aşan bir RMSE ile en düşük z0m tahminini sağlarken, MLP (Multi-layer Perceptron- Çok Katmanlı Algılayıcılar ) 'nin doğruluğu YSA'lardan daha iyi ancak RF'lerden daha düşüktür. KB<sup>-1</sup> (makine öğrenim tekniğinde kullanılan aşırı direnç büyüklüğü) sonucu için z0m'den biraz daha düşük bir R olmasına rağmen, makine öğrenimi modelleri yarım saatlik aşırı direncin kopyalanmasında da iyi performans göstermektedir. Eğitim ve test sırasında sırasıyla 0,97 ve 0,87 R değerleri ve 0,98 ve 1,97 RMSE değerleri ile RF algoritması en iyi sonuçları elde etmeye devam ediyor. YSA ve MLP algoritmalarının performansı, R'nin 0,8'de ve RMSE'nin 2,4'e yakın olmasıyla karşılaştırılabilir.

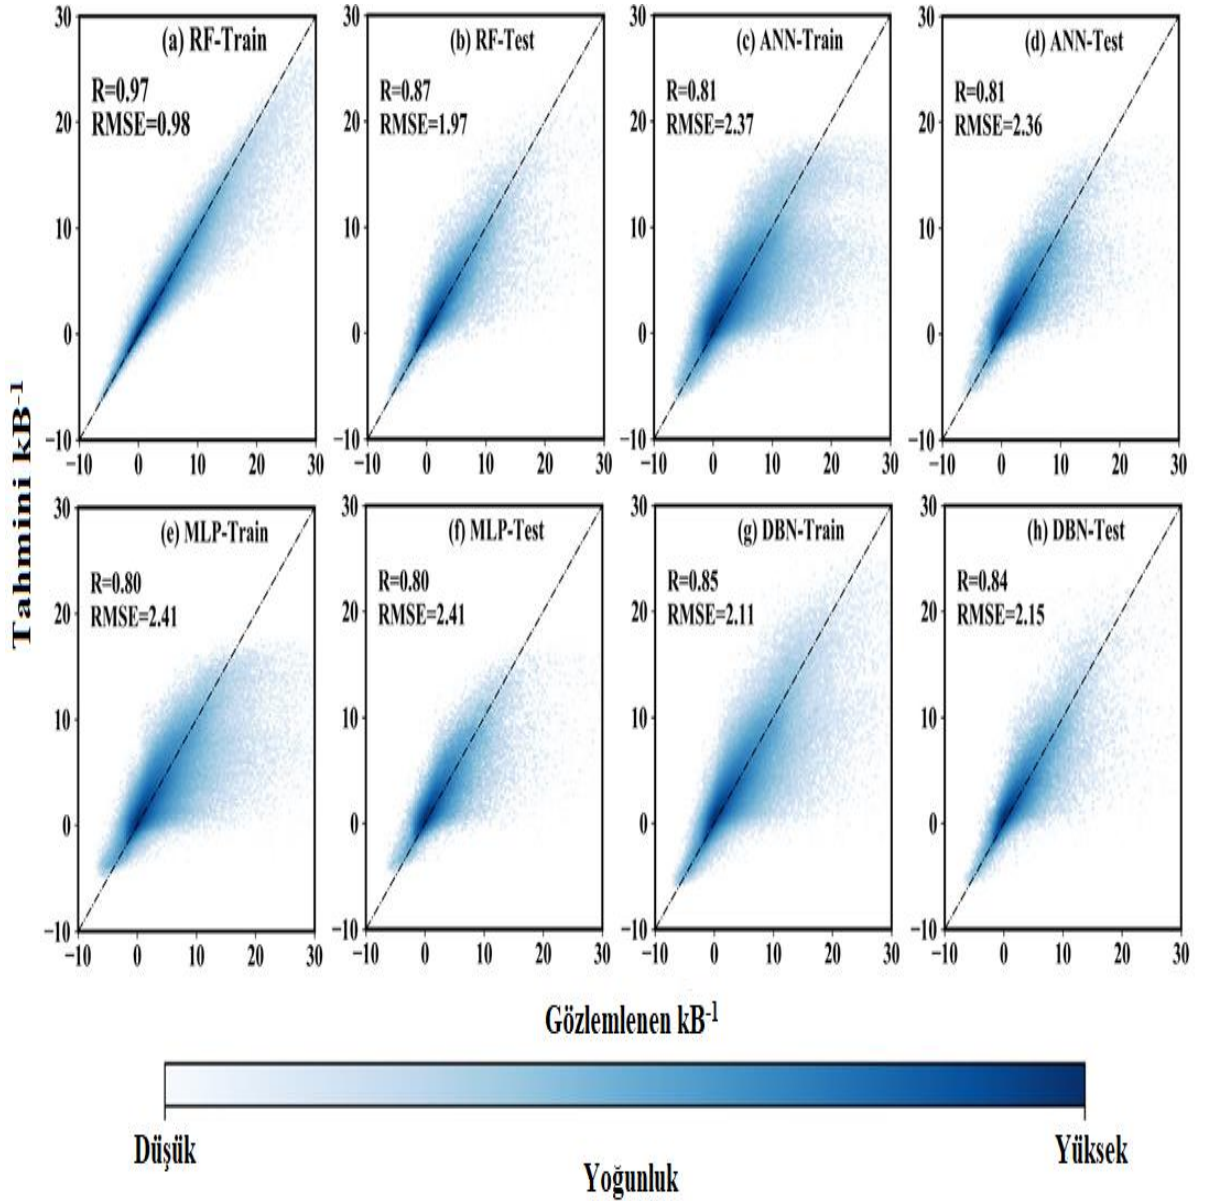
Hem eğitim hem de testte kabaca 0,85'lik bir R ve kabaca 2,11'lik bir RMSE ile DBN modeli, RF modelinden daha iyi performans göstermeye devam ederken diğer iki sinir ağı modelinden daha iyi performans gösterir.

Sonuç olarak, RF yöntemi aerodinamik ve termodinamik pürüzlülük uzunluklarının belirlenmesinde sinir ağı tekniklerinden daha iyi performans göstermektedir. Birçok sinir ağı algoritmasının performansı esasen aynıdır.





**Şekil 4. 1:** ZOm, Dört Makine Öğrenimi Algoritmasının Performansları. Eğitim (a, c, e, g) ve Test (b, d, f, h) Aşamaları.




**Şekil 4. 2:** Tahmini  $kB^{-1}$  Makine öğrenmesi Algoritmalarının Eğitim(a,c,e,g) Ve Test (b,d,f,h) Aşamalarındaki Performansları.

Derin sinir ağı tekniğinin performansı, gizli katmanlara sahip sinir ağından biraz daha iyi performans göstermesine rağmen kararsızdır. Ne MLP ne de DBN algoritmaları, yüzey pürüzlülük uzunluklarını tahmin etmede sürekli olarak birbirinden daha iyi performans göstermez.

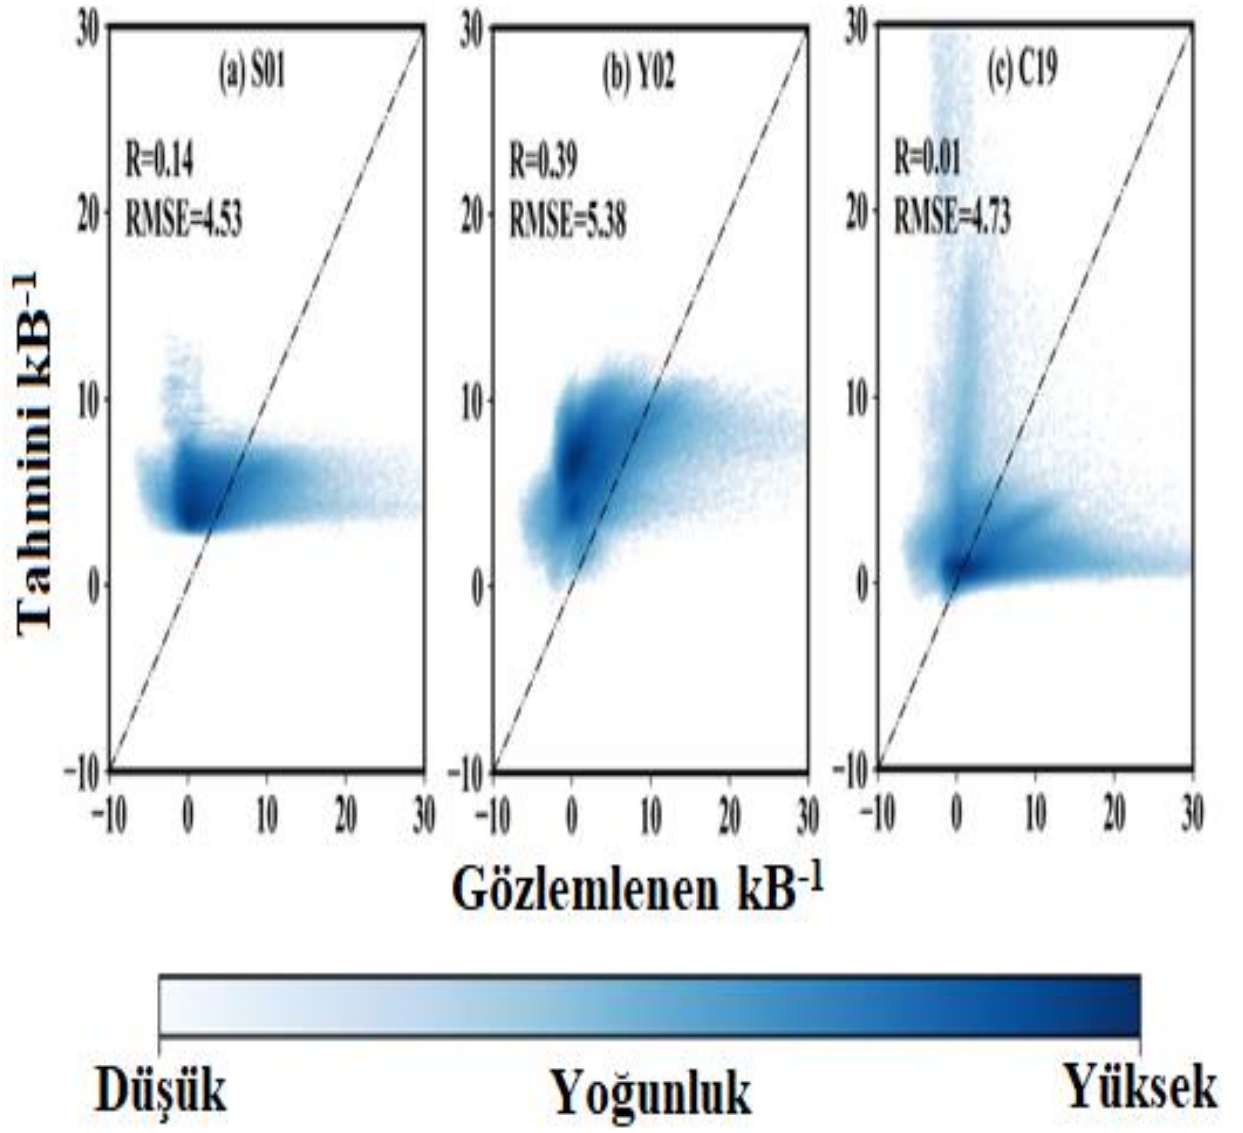
Şekil 4.2’de aerodinamik pürüzlülük uzunluklarına dayalı olarak üç fiziksel modelin performansını göstermektedir. Bu modeller nispeten yüksek hata oranlarına sahiptir. M17, 0,82 R ve 0,81 m RMSE ile en iyi aerodinamik pürüzlülük tahminini elde eder. 0,77 R ve 0,92 m RMSE ile R94, M17’yi küçük bir farkla takip ediyor. M97, yalnızca 0,47 R ve 1,43 metre RMSE ile en az istenen sonuçları verdi.

Şekil 4.3'de görülebileceği gibi, hiçbir model maksimum direnci teşvik eden bulgular vermez. Aşırı direnç ölçümü için en iyi performans Y02 tarafından sağlanır, ancak R değeri yalnızca 0,39'dur ve RMSE'si 5,38'e ulaşabilir. En kötü modeller, R değerleri neredeyse 0 ve RMSE 4.5 olan S01 ve C19'dur.

Şekil 4.3(a) ve (b)'deki veri noktalarının çoğu kimlik çizgisinin üzerindedir, ancak Şekil 4.4(c) kimlik çizgisine yakın en yüksek veri noktası yoğunluğuna sahiptir, bu da S01 ve Y02'nin  $kB^{-1}$ 'yi önemli ölçüde etkiler. Şekil 4.4(c) ayrıca  $kB^{-1}$  fazla tahmininin bazı aykırı değerlerini göstermektedir.



Şekil 4. 3: Fiziksel Tabanlı z0m Modellerinin Performansları.



Şekil 4. 4: Fiziksel Tabanlı  $\text{kB}^{-1}$  Modellerinin Performansları. [30'dan büyük  $\text{kB}^{-1}$  Değerleri Hariç Tutulmuştur].



## 5. SONUÇ VE ÖNERİLER

Tezde makine öğrenim teknikleri ile yüzey pürüzlülük analizleri incelendi. Yüzey pürüzlülük değerleri ile makine öğrenim modelleri arasındaki ilişkiler ele alındı. Burada modellerin yüzey pürüzlülük esasına göre önemli kısımları incelenmiş olup, yüzey kalitesinin işlenebilirlik özelliğini doğrudan etkilediği görülmektedir.

Makine öğreniminde uygulanan yöntemler pürüzlülük analizleri bakımından önemli bir etkiye sahiptir. Makine öğrenimi; Yüzey pürüzlülük analizini incelemek, analiz etmek, verileri işlemek ve malzemenin en uygun pürüzlülük seviyelerinin belirlenmesinde etkili olmaktadır.

Makine öğrenim modelleri karar ağaçları, yapay sinir ağları (YSA) ve yüzey pürüzlülüğü gibi ele alınan konularda ve analizlerde önemli bir paya sahiptir. Yüzey pürüzlülüğü analizleri regresyon problemleri ile de açıklanabilir, çünkü belirli bir yüzeyin pürüzlülüğünü ölçmek için sürekli bir çıkıntıya(set) ihtiyaç vardır. Karar ağaçları, veri setindeki özellikleri kullanarak yapıda bir dizi karar kuralı oluşturur ve böylece girdi özelliklerine dayanarak çıktı değerleri tahmin edilmektedir. Burada YSA'lar insan beyninin çalışma sistemini taklit eden ve karmaşık ilişkilerini öğrenmeyi başaran bir modeldir. Yüzey pürüzlülüğü açısından da önemli bir yere sahiptir. YSA'lar yüzey pürüzlülük analizlerinde ve veri tahminlerinde bulunmanın yanı sıra sınıflandırmalar da yapabilirler.

Tezin devamında yapılan deneysel çalışmada; İki farklı deney cihazı ile üç farklı malzemenin pürüzlülük değerlerinin analizi yapılmıştır. Burada; Alüminyumun çeliğe göre, çeliğin ise plastiğe göre elde edilen deney sonuçları pürüzlülük analizinde oluşan hassasiyeti de belirlemektedir.

Deneyde Mitutoyo marka SurfTest SJ-210 model ve İnsize ISR – C300 marka Pürüzlülük ölçüm cihazı kullanılmış olup, alüminyum numune, çelik numune ve plastik numunelerden elde edilen **Ra** (Ortalama yüzey pürüzlülük) değerleri Tablo 5.1'de verilmiştir.

**Tablo 5. 1:** Çalışmada kullanılan numunelerin Ra (Ortalama yüzey pürüzlülük) değerleri

| Pürüzlülük Değerleri                  | Mitutoyo marka Surfrest SJ-210 model Pürüzlülük Ölçüm cihaz | İnsize ISR – C300 marka Pürüzlülük Ölçüm cihaz |
|---------------------------------------|---|--|
| Alüminyum numune Ra ( $\mu\text{m}$ ) | 0.294   | 0.262  |
| Çelik numune Ra ( $\mu\text{m}$ )     | 0.323   | 0.313  |
| Plastik numune Ra ( $\mu\text{m}$ )   | 1.167   | 0.927  |

Alüminyum numunenin Ra (Ortalama yüzey pürüzlülük) değerleri, çelik numuneye göre, çelik numunenin yüzey pürüzlülük değerlerinin de plastik numuneye göre daha düşük değerde olduğu görülmektedir.

Numunelerin ortalama yüzey pürüzlülük büyüklükleri sırasıyla şu şekildedir;

$$Ra_{(\text{Alüminyum})} < Ra_{(\text{Çelik})} < Ra_{(\text{Plastik})} \text{ sonucu elde edilmiştir.}$$

Ayrıca Denklem 1.1 deki verilen bağıntı da kullanılıp nümerik olarak Ra değerleri elde edilebilir.

Deneyde Mitutoyo marka Surfrest SJ-210 model ve İnsize ISR – C300 marka Pürüzlülük ölçüm cihaz kullanılıp Alüminyum numune, çelik numune ve plastik numunelerden elde edilen **Rz** (Maksimum yüzey pürüzlülük) değerleri Tablo 5.2 de verilmiştir.

**Tablo 5. 2:** Çalışmada kullanılan numunelerin Rz ( Maksimum yüzey pürüzlülük) değerleri

| Pürüzlülük Değerleri                  | Mitutoyo marka Surfrest SJ-210 model Pürüzlülük Ölçüm cihaz | İnsize ISR – C300 marka Pürüzlülük Ölçüm cihaz |
|---------------------------------------|---|--|
| Alüminyum numune Rz ( $\mu\text{m}$ ) | 2.509   | 2.224  |
| Çelik numune Rz ( $\mu\text{m}$ )     | 2.794   | 2.578  |
| Plastik numune Rz ( $\mu\text{m}$ )   | 3.716   | 3.500  |

Alüminyum numunenin Rz (Maksimum yüzey pürüzlülük) değerleri, çelik numuneye göre, çelik numunenin yüzey pürüzlülük değerlerinin de plastik numuneye göre daha düşük mertebede olduğu görülmektedir.

Numunelerin maksimum yüzey pürüzlülük değerleri sırasıyla şu şekildedir;

$$RZ_{(Alüminyum)} < RZ_{(Çelik)} < RZ_{(Plastik)} \text{ sonucuna ulaşılmıştır.}$$

Ayrıca Denklem 1.2 deki verilen bağıntı da kullanılıp nümerik olarak Rz değerleri elde edilebilir.

Deneyde Mitutoyo marka Surfrest SJ-210 model ve İnsize ISR – C300 marka Pürüzlülük ölçüm cihaz kullanılıp Alüminyum numune, çelik numune ve plastik numunelerden elde edilen **Rq** (Kök ortalama kare yüksekliği) değerleri Tablo 5.3 de verilmiştir.

**Tablo 5.3:** Çalışmada kullanılan numunelerin Rq (Kök ortalama kare yüksekliği) değerleri

| <b>Pürüzlülük Değerleri</b>     | <b>Mitutoyo marka Surfrest SJ-210 model Pürüzlülük Ölçüm cihaz</b> | <b>İnsize ISR – C300 marka Pürüzlülük Ölçüm cihaz</b> |
|---------------------------------|--|---|
| <b>Alüminyum numune Rq (µm)</b> | 0.376  | 0.334   |
| <b>Çelik numune Rq (µm)</b>     | 0.403  | 0.378   |
| <b>Plastik numune Rq (µm)</b>   | 1.068  | 1.035   |

Alüminyum numunenin Rq (Kök ortalama kare yüksekliği) pürüzlülük değerleri, çelik numuneye göre, çelik numunenin yüzey pürüzlülük değerlerinin de plastik numuneye göre daha düşük mertebede olduğu görülmektedir.

Çalışmada kullanılan numunelerin Kök Ortalama Kare Yüksekliği yüzey pürüzlülük büyüklükleri sırasıyla şu şekildedir;

$$Rq_{(Alüminyum)} < Rq_{(Çelik)} < Rq_{(Plastik)} \text{ sonucuna ulaşılmıştır.}$$

Ayrıca Denklem 1.3' de verilen bağıntıda kullanılıp nümerik olarak Rq değerleri elde edilebilir.

Makine öğrenimi tekniğinin mühendislik uygulamalarında; Derin sinir ağlarının verilerinden daha uygun bilgi elde edilmektedir. İnsan beyninin çalışma şekline göre genel hatlarıyla modellenen (Derin öğrenme) algoritmaları olan sinir ağları, katmanları tarafından desteklenmektedir.

YSA insan beyni gibi çalışacak şekilde modellenen bir algoritma, makine öğreniminin alt kümesini oluşturmaktadır. İnsan beyninden esinlenerek işlemi öğreten bir yapay zekâ yöntemi olan derin öğrenme (DL) sistemi; Zekanın eğitilmesine imkan



sağlamakta olup, aynı zamanda makinelerin dünyayı algılamasında kullanılan bir yöntemdir.

Yağlama yöntemlerinin yüzey işleme şartlarında daha iyi bir yüzey kalitesi elde etmede önemli bir etkiye sahip olduğu belirlenmiştir.

Burada kuru işleme şartlarında en yüksek Ra değeri 1,05  $\mu\text{m}$  olarak elde edilmiştir. Aynı şartlarda kıyaslandığında MQL ile elde edilen veri yaklaşık %24, nano-MQL ile elde edilen sonuç ise yaklaşık %34 daha az değerdedir.

En fazla güç tüketimi kuru işleme alanında meydana gelmiştir. Her bir uzunluk için elde edilen güçlerin toplamına bakılarak MQL ve nano-MQL ile yapılan deneylerde sırasıyla yaklaşık %5,3 ve %10,2 daha az güç tüketimi olduğu hesaplanmıştır.

Bu nedenle, uzay-zamansal özelliklerin değerlendirilmesi için evrişimli veya tekrarlayan sinir ağı teknikleri kullanılarak yüzey pürüzlülük uzunluklarının doğru ölçümü elde edilebilir.

Teknolojinin hızla ilerlemesiyle mühendislik projelerinin her zamankinden daha karmaşık olduğu görülmektedir. Bu araştırmalarda ürünlerde dayanıklılık ve ürün performansının tespiti önemlidir. BDA (Bilgisayar Destekli Yorulma Testi ve Analizi) mühendislerin yeniliği için ileri adımları belirlemede etkili bir faktördür.

Mühendislik malzemelerinin yüzey pürüzlülük değerleri; Ürünün işleme özelliklerini, yorulma ömrünü ve güvenilirliğini etkilemektedir. Bilgisayar destekli belirli bir yüzey pürüzlülüğüne sahip ürünlere uygulanan yorulma test analizleri yapılabilecek diğer bir çalışma konusudur.

Burada çok sayıda daha farklı malzemelerin değişik çalışma şartlarındaki yüzey pürüzlülük değerlerinin belirlenmesi sürtünme katsayılarını etkilemektedir.

EHD (Elastohidrodinamik) yağlama sistemli kaymalı yataklarda kullanılan malzemelerin düşük sürtünme katsayıları sistemde oluşan güç kayıplarını da azaltacaktır.

## KAYNAKÇA

- Abbas, A.T., Benyahia, F., El Rayes, M.M., Pruncu, C., Taha, M.A., Hegab, H. (2019). Towards optimization of machining performance and sustainability aspects when turning AISI 1045 steel under different cooling and lubrication strategies. *Materials* 2019, 12, 3023.
- Abbas, A.T., Gupta, M.K., Soliman, M.S., Mia, M., Hegab, H., Luqman, M., Pimenov, D.Y. (2019). Sustainability assessment associated with surface roughness and power consumption characteristics in nanofluid MQL-assisted turning of AISI 1045 steel. *Int. J. Adv. Manuf. Technol.* 2019, 105, 1311–1327.
- Alajmi, M.S., Almeshal, A.M. (2002). Prediction and optimization of surface roughness in a turning process using the ANFIS-QPSO method. *Materials* 2020, 13, 2986.
- A. Weissel, F. Bellosa, (2002). —Process Cruise Control: Event-Driven Clock Scaling for Dynamic Power Management, in *CASES \_02*, 2002.
- Bonfá, M.M., Costa, É.S., Sales, W.F., Amorim, F.L., Maia, L.H.A., Machado, Á.R. (2019). Evaluation of tool life and workpiece surface roughness in turning of AISI D6 hardened steel using PCBN tools and Minimum Quantity of Lubricant (MQL) applied at different directions. *Int. J. Adv. Manuf. Technol.* 2019, 103, 971–984.
- Calayır, Kabak.(2021). ” Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama”, 664-665, Ankara. 2021
- Çamlı, K.Y., Demirsöz, R., Boy, M., Korkmaz, M.E., Yaşar, N., Giasin, K., Pimenov, D.Y. (2022). Performance of MQL and Nano-MQL lubrication in machining ER7 steel for train wheel applications. *Lubricants* 2022, 10, 48.
- Dubey, V., Kumar Sharma, A., Kumar Singh, R. (2020). Study of various cooling methodology used in machining processes. *Mater. Today Proc.* 2020, 21, 1572–1576.
- Dubey, V., Sharma, A.K., Singh, R.K. (2021). A technological review on temperature measurement techniques in various machining processes. In *Lecture Notes in Mechanical Engineering*; Springer: Singapore, 2021.
- Dubey, V., Sharma, A.K., Vats, P., Pimenov, D.Y., Giasin, K., Chuchala, D. (2021). Study of a multicriterion decision-making approach to the Mql turning of Aisi 304 steel using hybrid nanocutting fluid. *Materials* 2021, 14, 7207.
- D. Y. Singh and A. S. Chauhan,(2009). “Neural networks in data mining,” *Journal of Theoretical and Applied Information Technology*, vol. 5, no. 1, pp. 37–42, 2009.

- Elangovan, M., Sakthivel, N.R., Saravanamurugan, S., Nair, B.B., Sugumaran, V. (2015). Machine learning approach to the prediction of surface roughness using statistical features of vibration signal acquired in turning. *Procedia Comput. Sci.* 2015, 50, 282–288.
- Eser, A., Ayskar Ayyildiz, E., Ayyildiz, M., Kara, F.(2021). Artificial intelligence-based surface roughness estimation modelling for milling of AA6061 alloy. *Adv. Mater. Sci. Eng.* 2021, 2021.
- F. Qian, et al.,(2010). —TOP: Tail Optimization Protocol for Cellular Radio Resource Allocation, in *ICNP*, 2010.
- Gokmen, M., Vekerdy, Z., Verhoef, A., Verhoef, W., Batelaan, O., van der Tol, C., (2012). Integration of soil moisture in SEBS for improving evapotranspiration estimation under water stress conditions. *Remote Sens. Environ.* 121, 261–274.
- Gupta, M.K., Boy, M., Erdi Korkmaz, M., Yaşar, N.; Günay, M., Krolczyk, G.M. (2022). Measurement and analysis of machining induced tribological characteristics in dual jet minimum quantity lubrication assisted turning of duplex stainless steel. *Meas. J. Int. Meas. Confed.* 2022, 187, 110353.
- I. Steinwart and A. Christmann (2008). *Support Vector Machines*. Springer Publishing Company, Incorporated, 1st ed., 2008.
- Kaya ve Yıldız.(2014). ” Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz”, *Marmara Üniversitesi, Fen Bilimleri Dergisi* 3 2014 93 .2014
- Khanna, N., Shah, P., de Lacalle, L.N.L., Rodríguez, A.; Pereira, O. (2021). In pursuit of sustainable cutting fluid strategy for machining Ti-6Al-4V using life cycle analysis. *Sustain. Mater. Technol.* 2021, 29, e00301.
- Khanna, N., Shah, P., Sarikaya, M., Pusavec, F. (2022). Energy consumption and ecological analysis of sustainable and conventional cutting fluid strategies in machining 15–5 PHSS. *Sustain. Mater. Technol.* 2022, 32, e00416.
- Korkmaz, M.E., Gupta, M.K., Boy, M.; Yaşar, N., Krolczyk, G.M.; Günay, M. (2021). Influence of duplex jets MQL and Nano-MQL cooling system on machining performance of Nimonic 80A. *J. Manuf. Process.* 2021, 69, 112–124.
- Lin, W.J., Lo, S.H., Young, H.T., Hung, C.L. (2019).Evaluation of deep learning neural networks for surface roughness prediction using vibration signal analysis. *Appl. Sci.* 2019, 9, 1462.
- L. Liu and M. T. Özsu,(2009). *Encyclopedia of Database Systems*. Springer US, 2009.

- Manjunath, K., Tewary, S., Khatri, N., Cheng, K. (2021). Monitoring and predicting the surface generation and surface roughness in ultraprecision machining: A critical review. *Machines* 2021, 9, 369.
- Mia, M., Gupta, M.K., Singh, G., Królczyk, G.; Pimenov, D.Y. (2018). An approach to cleaner production for machining hardened steel using different cooling-lubrication conditions. *J. Clean. Prod.* 2018, 187, 1069–1081.
- Nakai, T., Sumida, A., Daikoku, K., et al., (2008). Parameterization of aerodynamic roughness over boreal, cool- and warm-temperature forests. *Agric. For. Meteorol.* 148 (12), 1916–1925.
- Raza, S.M., Khan, A.M., Farooq, M.U., Iqbal, A., Pimenov, D.Y., Giasin, K., Leksycki, K.(2021). Modelling and analysis of surface evolution on turning of hard-to-cut CLARM 30NiCrMoV14 steel alloy. *Metals* 2021, 11, 1751.
- Ross, N.S., Gopinath, C., Nagarajan, S., Gupta, M.K., Shanmugam, R., Kumar, M.S., Boy, M., Korkmaz, M.E. (2022). Impact of hybrid cooling approach on milling and surface morphological characteristics of Nimonic 80A alloy. *J. Manuf. Process.* 2022, 73, 428–439.
- R. J. Erb,(1993). “Introduction to backpropagation neural network computation,” *Pharmaceutical Research*, vol. 10, no. 2, pp. 165–170, 1993.
- Sampaio, M.A., Machado, Á.R., Laurindo, C.A.H., Torres, R.D., Amorim, F.L.(2018). Influence of Minimum Quantity of Lubrication (MQL) when turning hardened SAE 1045 steel: A comparison with dry machining. *Int. J. Adv. Manuf. Technol.* 2018, 98, 959–968.
- Sap, S., Usca, Ü.A., Uzun, M., Kunto şglu, M., Salur, E., Pimenov, D.Y. (2022). Investigation of the effects of cooling and lubricating strategies on tribological characteristics in machining of hybrid composites. *Lubricants* 2022, 10, 63.
- Sharma, A.K., Tiwari, A.K., Dixit, A.R. (2016). Effects of Minimum Quantity Lubrication (MQL) in machining processes using conventional and nanofluid based cutting fluids: A comprehensive review. *J. Clean. Prod.* 2016, 127, 1–18.
- Sizemore, N.E., Nogueira, M.L., Greis, N.P., Davies, M.A. (2020). Application of machine learning to the prediction of surface roughness in diamond machining. *Procedia Manuf.* 2020, 48, 1029–1040.
- S. Choi, et al., (2006).—A selective DVS technique based on battery residual mi2roprocessors and microsystems,|| Elsevier Sc., 30(1):33 –42, 2006.

- Yılmaz V., Dilipak H., Sarıkaya M., Yılmaz C.Y., Meral G.(2014). “Frezeleme İşlemlerinde Titreşimi ve Yüzey Pürüzlülüğünü Etkileyen Parametrelerin Optimizasyonu”, Süleyman Demirel Üniversitesi Teknik Bilimler Meslek Yüksek Okulu SDU Teknik Bilimler Dergisi 4-1 2014 37.
- Zilyas, Yılmaz. (2023). “Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli”, Dicle Üniversitesi, Mühendislik dergisi 14:3 2023 440
- Xu, T., Guo, Z., Liu, S., et al. (2018). Evaluating different machine learning methods for upscaling evapotranspiration from flux towers to the regional scale. *J. Geophys. Res.* 123, 8674–8690.
- Wang, H., Magagi, R., Goita, K., Trudel, M., McNairn, H., Powers, J. (2019). Crop phenology retrieval via polarimetric SAR decomposition and random forest algorithm. *Remote Sens. Environ.* 231, 111234.

## ÖZGEÇMİŞ

| <b>Kişisel Bilgiler</b> |                         |
|-------------------------|-------------------------|
| <b>Adı Soyadı:</b>      | Aqeel Jalil Radhi Radhi |
| <b>Uyruğu:</b>          | Irak                    |
| <b>Orcid Numarası:</b>  | 0009-0009-8573-0718     |

| <b>Eğitim Bilgileri</b> |                                 |
|-------------------------|---------------------------------|
| <b>Lisans</b>           |                                 |
| <b>Üniversite</b>       | Teknoloji Üniversitesi / Bağdat |
| <b>Fakülte</b>          | Makine Fakültesi                |
| <b>Bölümü</b>           | Makine Mühendisliği             |
| <b>Mezuniyet Yılı</b>   | 2006                            |
| <b>Yüksek Lisans</b>    |                                 |
| <b>Üniversite</b>       | Kırşehir Ahi Evran Üniversitesi |
| <b>Enstitü Adı</b>      | Fen Bilimleri Enstitüsü         |
| <b>Anabilim Dalı</b>    | Makine Mühendisliği             |
| <b>Mezuniyet Tarihi</b> | 2024                            |

| <b>Tezden Üretilen Makaleler ve Bildiriler</b>  |
|---|
| Aqeel Jalil Radhi ve Prof. Dr. Ali Osman Kurban (21-24 Eylül 2023)<br>Makine Öğrenimi Teknikleri Kullanılarak Yüzey Pürüzlülük<br>Parametreleri Araştırılması, Dergi(American Journal Engineering Research) |