



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

**YÜKSEK LİSANS TEZİ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK FELÇ  
(İNME) TESPİTİ**

**Hadice ATEŞ**

**Ağustos-2024  
BATMAN**

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

**YÜKSEK LİSANS TEZİ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK FELÇ  
(İNME) TESPİTİ**

**Hadice ATEŞ**

**Danışman  
Doç. Dr. Abidin ÇALIŞKAN**

**Ağustos-2024  
BATMAN**

## TEZ KABUL VE ONAYI

Hadice ATEŞ tarafından hazırlanan “Makine Öğrenmesi Yöntemleri Kullanılarak Felç (İnme) Tespiti” adlı tez çalışması 27/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Doç. Dr. Erdal BAŞARAN

.....

#### Danışman

Doç. Dr. Abidin ÇALIŞKAN

.....

#### Üye

Doç. Dr. Ömer Ali KARAMAN

.....

Yukarıdaki sonucu onaylarım.

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

## **TEZ BİLDİRİMİ**

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

## **DECLARATION PAGE**

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

Hadice ATEŞ

27/08/2024

## ÖZET

### YÜKSEK LİSANS TEZİ

## MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK FELÇ (İNME) TESPİTİ

**Hadice ATEŞ**

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü  
Elektrik Elektronik Mühendisliği Ana Bilim Dalı**

**Danışman: Doç. Dr. Abidin ÇALIŞKAN**

**2024, 70 Sayfa**

**Jüri**

**Danışmanın Doç. Dr. Abidin ÇALIŞKAN  
Doç. Dr. Erdal BAŞARAN  
Doç. Dr. Ömer Ali Karaman**

Felç, beyne giden kan akışının aniden kesilmesi olarak tanımlanır. Kan akışının kesildiği bölgedeki hücreler zamanla işlevselliğini kaybederek vücudun etkilenen bölgesinde kalıcı hasara neden olabilmektedir. Felç; yaş, mesleki durum, bazı kronik rahatsızlıklar ve ailede daha önce geçirmiş olan bireylerin bulunması gibi birçok etkene bağlı olabilir. Bu etkenlerin değerlendirilmesi ve felç riskinin tahmin edilmesi maliyet ve zaman bakımından oldukça fazla olduğundan kişinin kalıcı bir hasarla karşı karşıya olma tehlikesi artmaktadır. Günümüz teknolojisinde ise Yapay Zekâ ve Makine Öğrenmesi modellerinde son noktaya bakıldığında milyonlarca veri üzerinde iyileştirme yapılarak riskin olup olmadığı konusunda karar vermek saniyeler sürmektedir. Bu çalışmada da zamandan tasarruf edilerek insan sağlığının bu tehlikeden korunması hedeflenerek Makine Öğrenmesi yöntemlerinden olan Lojistik Regresyon, K-En Yakın Komşu, Destek Vektör Makineleri ve Karar Ağaçları modelleri kullanılarak bireyin felç geçirme riski taşıyıp taşımadığının en güvenilir şekilde belirlenmesi amaçlanmıştır. Çalışma sonucunda ise veri seti üzerinde en yüksek başarı oranını elde eden yöntemin %91 ile Karar Ağaçları metodu olduğu görülmüştür. Ardından başarı oranlarına göre yöntemlerin sıralaması ise %89 oranıyla Destek Vektör Makineleri, %81 oranıyla K-En Yakın Komşu modeli ve son olarak Lojistik Regresyon metodu %75 şeklinde sonuçlanmıştır.

**Anahtar Kelimeler:** Destek Vektör Makinaları, Felç, Karar Ağaçları, Lojistik Regresyon, Makine Öğrenmesi

## **ABSTRACT**

## **MS THESIS**

# **STROKE DETECTION USING MACHINE LEARNING METHODS**

**Hadice ATEŞ**

**Batman University Graduate Education Institute**

**Electrical Electronics Engineering Department**

**Advisor: Doç. Dr. Abidin ÇALIŞKAN**

**2024, 70 Pages**

**Jury**

**Assoc. Dr. Abidin ÇALIŞKAN**

**Assoc. Dr. Erdal BAŞARAN**

**Assoc. Dr. Ömer Ali Karaman**

Stroke is defined as the sudden interruption of blood flow to the brain. The cells in the area where blood flow is cut off can gradually lose their functionality, leading to permanent damage in the affected area of the body. Stroke can be influenced by various factors, such as age, occupational status, certain chronic diseases, and the presence of individuals in the family who have previously suffered from it. Because the assessment of these factors and the estimation of stroke risk can be quite costly and time-consuming, the likelihood of an individual facing permanent damage increases. In today's technology, the latest advancements in Artificial Intelligence and Machine Learning models allow for decisions regarding the presence of risk to be made in seconds by improving on millions of data points. This study aims to save time and protect human health from this danger by using Machine Learning methods such as Logistic Regression, K-Nearest Neighbors, Support Vector Machines, and Decision Trees to reliably determine whether an individual is at risk of having a stroke. As a result of the study, it was found that the method achieving the highest accuracy on the dataset was the Decision Trees method, with an accuracy of 91%. The ranking of the methods based on accuracy is as follows: Support Vector Machines at 89%, K-Nearest Neighbors at 81%, and finally, the Logistic Regression method at 75%.

**Keywords:** Support Vector Machines, Stroke, Decision Tree, Logistic Regression, Machine Learning

## ÖNSÖZ

Yüksek lisans eğitimim boyunca ve çalışmalarımda beni destekleyen, yönlendiren, fikirleri ile sürekli gelişimimi sağlayan danışmanım Sayın Doç. Dr. Abidin ÇALIŞKAN'a, deneyimlerini paylaşan Sayın Öğr. Gör. Ammar ASLAN'a ve çalışmam boyunca beni sürekli destekleyen, maddi ve manevi her türlü konularda bana yardımcı olan eşim ve aileme teşekkürlerimi bir borç bilirim.

Hadice ATEŞ  
BATMAN-2024

## İÇİNDEKİLER

|                                                                             |     |
|-----------------------------------------------------------------------------|-----|
| ÖZET .....                                                                  | iv  |
| ABSTRACT.....                                                               | v   |
| ÖNSÖZ .....                                                                 | vi  |
| İÇİNDEKİLER .....                                                           | vii |
| KISALTMALAR .....                                                           | ix  |
| ŞEKİLLER.....                                                               | x   |
| TABLolar.....                                                               | xi  |
| 1. GİRİŞ .....                                                              | 1   |
| 1.1. Felç Türleri.....                                                      | 6   |
| 1.1.1. İskemik felç.....                                                    | 6   |
| 1.1.2. Hemorajik felç .....                                                 | 6   |
| 1.2. Felç Nedenleri.....                                                    | 7   |
| 1.3. Felç Belirtileri .....                                                 | 8   |
| 1.4. Felç Hastalığı Risk Faktörleri .....                                   | 9   |
| 1.5. Felç Tanısı Nasıl Konur? .....                                         | 10  |
| 1.6. Felç Teşhisi İçin Kullanılan Yöntemler ve Testler .....                | 11  |
| 1.6.1. Manyetik rezonans görüntüleme.....                                   | 12  |
| 1.6.2. Bilgisayarlı tomografi .....                                         | 12  |
| 1.6.3. Beyin doppler ultrasonu.....                                         | 13  |
| 1.6.4. Transtorasik ekokardiyografi ve transözofageal ekokardiyografi ..... | 14  |
| 1.6.5. Elektrokardiyogram .....                                             | 14  |
| 1.6.6. Labaratuvar testleri .....                                           | 15  |
| 1.7. Felç Hastalığı Tedavi Yöntemleri.....                                  | 15  |
| 1.7.1. İskemik felç tedavisi .....                                          | 15  |
| 1.7.2. Hemorajik felç tedavisi.....                                         | 15  |
| 1.7.3. Fizik tedavi .....                                                   | 16  |
| 1.7.4. Konuşma ve dil terapisi .....                                        | 16  |
| 1.7.5. Acil tedavi.....                                                     | 16  |
| 1.7.6. İlaç tedavisi.....                                                   | 16  |
| 1.7.7. Beslenme tedavisi .....                                              | 16  |
| 1.7.8. Cerrahi tedavisi .....                                               | 17  |
| 2. KAYNAK ARAŞTIRMASI .....                                                 | 18  |
| 3. YAPAY ZEKA MODELLERİ .....                                               | 21  |
| 3.1. Yapay Zeka Uygulamaları .....                                          | 22  |
| 3.1.1. Sağlık sektöründe yapay zeka.....                                    | 22  |
| 3.1.2. Finans sektöründe yapay zeka .....                                   | 23  |
| 3.2. Makine Öğrenmesi Yöntemleri .....                                      | 23  |
| 3.3. Yapay Sinir Ağları .....                                               | 25  |

|                                                  |           |
|--------------------------------------------------|-----------|
| 3.3.1. Yapay sinir ağıları ve veri analizi ..... | 26        |
| 3.4. Derin Öğrenme .....                         | 27        |
| <b>4. MATERYAL VE YÖNTEM.....</b>                | <b>28</b> |
| 4.1. Kullanılan Makine Öğrenmesi Modelleri ..... | 28        |
| 4.1.1. Lojistik regresyon .....                  | 28        |
| 4.1.2. K-en yakın komşu .....                    | 29        |
| 4.1.3. Destek vektör makineleri .....            | 31        |
| 4.1.4. Karar ağaçları.....                       | 33        |
| 4.2. Çalışmada Kullanılan Programlama Dili ..... | 34        |
| 4.3. Çalışmada Kullanılan Kütüphaneler .....     | 35        |
| 4.3.1. NumPy .....                               | 35        |
| 4.3.2. Pandas .....                              | 35        |
| 4.3.3. Matplotlib.....                           | 35        |
| 4.3.4. TensorFlow .....                          | 35        |
| 4.3.5. Keras .....                               | 36        |
| 4.4. Model Değerlendirme Parametreleri .....     | 36        |
| 4.4.1. Doğruluk .....                            | 36        |
| 4.4.2. Hassasiyet .....                          | 37        |
| 4.4.3. Duyarlılık .....                          | 37        |
| 4.4.4. F1 skoru .....                            | 38        |
| 4.5. Veri Seti .....                             | 38        |
| <b>5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>   | <b>40</b> |
| 5.1. Lojistik Regresyon .....                    | 40        |
| 5.2. K-En Yakın Komşu .....                      | 41        |
| 5.3. Destek Vektör Makineleri.....               | 43        |
| 5.4. Karar Ağaçları.....                         | 45        |
| <b>6. SONUÇLAR VE ÖNERİLER .....</b>             | <b>48</b> |
| 6.1 Sonuçlar .....                               | 48        |
| 6.2 Öneriler .....                               | 48        |
| <b>KAYNAKLAR .....</b>                           | <b>50</b> |
| <b>ÖZGEÇMİŞ .....</b>                            | <b>64</b> |

## KISALTMALAR

|            |                                   |
|------------|-----------------------------------|
| <b>BT</b>  | : Bilgisayarlı Tomografi          |
| <b>DDİ</b> | : Doğal Dil İşleme                |
| <b>DÖ</b>  | : Derin Öğrenme                   |
| <b>DSA</b> | : Derin Sinir Ağı                 |
| <b>DVM</b> | : Destek Vektör Makineleri        |
| <b>EKG</b> | : Elektrokardiyografi             |
| <b>ESA</b> | : Evrişimli Sinir Ağları          |
| <b>EYK</b> | : En Yakın Komşuluk               |
| <b>KA</b>  | : Karar Ağaçları                  |
| <b>LR</b>  | : Lojistik Regresyon              |
| <b>MÖ</b>  | : Makine Öğrenmesi                |
| <b>MR</b>  | : Manyetik Rezonans               |
| <b>MRG</b> | : Manyetik Rezonans Görüntüleme   |
| <b>YSA</b> | : Yapay Sinir Ağları              |
| <b>YZ</b>  | : Yapay Zekâ                      |
| <b>YGZ</b> | : Yapay Genel Zekâ                |
| <b>AVM</b> | :Arteriovenöz Malformasyon        |
| <b>TEE</b> | :Transözofageal Ekokardiyografi   |
| <b>TTE</b> | :Transtoraksik Ekokardiyografi    |
| <b>DDA</b> | : Doğrusal Diskriminant Analizi   |
| <b>TBA</b> | : Temel Bileşen Analizi           |
| <b>AVA</b> | : Açıklayıcı Veri Analizi         |
| <b>RSA</b> | : Rekurrent Sinir Ağları          |
| <b>ÇKA</b> | : Çok Katmanlı Ağlar              |
| <b>DP</b>  | : Doğru Pozitif                   |
| <b>DN</b>  | : Doğru Negatif                   |
| <b>YP</b>  | : Yanlış Pozitif                  |
| <b>YN</b>  | : Yanlış Negatif                  |
| <b>GMM</b> | : Gizli Markov Modelleri          |
| <b>GT</b>  | : Görüntü Tanıma                  |
| <b>TÖ</b>  | : Transfer Öğrenmesi              |
| <b>RSA</b> | :Recurrent Sinir Networks         |
| <b>VKİ</b> | : Vücut Kitle İndeksi             |
| <b>ROS</b> | : Rastgele Orman Sınıflandırıcısı |
| <b>AUC</b> | : Area Under the Curve            |
| <b>OSA</b> | :Olasılıksal Sinir Ağı            |
| <b>NYP</b> | :Nesne Yönelimli Programlama      |
| <b>FP</b>  | : Fonksiyonel Programlama         |
| <b>RBF</b> | : Radial Basis Function           |
| <b>NB</b>  | : Naive Bayes                     |

## ŞEKİLLER

|                                                                                           |    |
|-------------------------------------------------------------------------------------------|----|
| Şekil 4.1. LR Modelinde kullanılan sigmoid fonksiyonunun grafiği.....                     | 28 |
| Şekil. 4.2. DVM sınıflandırma süreci; a) ikili sınıflandırma, b) çoklu sınıflandırma..... | 32 |
| Şekil 5.1. LR Modelinin Karmaşıklık Matrisi.....                                          | 40 |
| Şekil 5.2. LR Modelinin Değerlendirme Matrisi.....                                        | 41 |
| Şekil 5.3. EYK Modelinin Karmaşıklık Matrisi.....                                         | 42 |
| Şekil 5.4. EYK Modelinin Değerlendirme Matrisi.....                                       | 43 |
| Şekil 5.5. DVM Modelinin Karmaşıklık Matrisi.....                                         | 44 |
| Şekil 5.6. DVM Modelinin Değerlendirme Matrisi.....                                       | 44 |
| Şekil 5.7. KA Modelinin Karmaşıklık Matrisi.....                                          | 46 |
| Şekil 5.8. KA Modelinin Değerlendirme Matrisi.....                                        | 46 |

## TABLÖLAR

|                                                                                                                  |    |
|------------------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 6.1.</b> MÖ modellerinden elde edilen karmaşıklık matrislerinin performans parametreleri sonuçları..... | 46 |
|------------------------------------------------------------------------------------------------------------------|----|

## 1. GİRİŞ

Felç, beyin dokusunda meydana gelen hasar nedeniyle beyin kan akışının kesintiye uğraması sonucu ortaya çıkar. Beyin dolaşımındaki aksaklıklar veya doğrudan beyin hasarı, sinir sistemi üzerinde bozukluklara yol açabilir. Bu durum, vücudun bir bölümünde ya da tamamında geçici ya da kalıcı bir felç durumu oluşturabilir. Dolaşım problemleri veya beyin hasarı sonucunda meydana gelen inmeler, vücudun bir tarafında kas zayıflığı, uyuşma veya his kaybı, konuşma bozukluğu, görme kaybı ve koordinasyon eksikliği gibi belirtilerle kendini gösterebilir (Adams ve ark., 2017).

Felç, genellikle iskemik ve hemorajik olmak üzere iki ana türe ayrılır. İskemik felç, beyne kan akışının azalması veya kesilmesi sonucu oluşan tıkanıklıklardan kaynaklanır. Bu tıkanıklıklar genellikle pıhtı veya damarların plaklaşması gibi durumlardan kaynaklanır (Roger ve ark., 2011). Hemorajik felç ise, beyinde meydana gelen kanamalar sonucu gelişir ve beyinde hasara yol açabilir (Arondon, 2016).

Felç, çeşitli nedenlerle meydana gelebilir (Gorelick, 2019). Yüksek tansiyon, kalp hastalığı, diyabet, yüksek kolesterol seviyeleri, sigara içme, obezite ve geçmişte felç geçirme öyküsü gibi faktörler, felç riskini artıran etkenler arasındadır (Howard ve ark., 2020).

Felç, tıbbi acil müdahale gerektiren ciddi bir durumdur. Acil tedavi, beyin kan akışını yeniden sağlamak, beyin hasarını minimize etmek ve hayat kurtarmak için zorunludur. Tedavi, hastanın durumuna ve felcin türüne göre değişebilir. Trombolitik ilaçlar veya mekanik trombektomi, iskemik felçler için tercih edilirken, hemorajik felçlerde cerrahi müdahale gerekli olabilir (Feigin ve ark., 2017).

Felç sonrası rehabilitasyon, hastanın günlük yaşam becerilerini yeniden kazanmasına yardımcı olmak için önemlidir. Fizik tedavi, konuşma terapisi, beslenme danışmanlığı ve psikolojik destek gibi yöntemler içerebilir. Felç geçiren bireylerin tedavi sürecinde ve sonrasında sağlıklı bir yaşam tarzını benimsemeleri de önemlidir. Bu, düzenli egzersiz yapmak, sağlıklı beslenmek, sigara içmekten kaçınmak, alkol tüketimini sınırlamak ve doktorun önerilerine uymak gibi faktörleri içerir (Miller ve ark., 2010).

Felç hastaları genellikle uzun süreler boyunca bakıma ihtiyaç duyarlar. Bu nedenle, hastaların bakımı, hastalığın türü, şiddeti ve hastanın genel sağlık durumuna göre değişiklik gösterebilir (Lincoln ve Flannaghan, 2013). Genellikle, felç hastalarının bakımı üç temel konuya odaklanır: fiziksel bakım, beslenme ve rehabilitasyon (Pezzella ve ark., 2005).

- **Fiziksel Bakım:** Felç geçiren hastaların fiziksel bakımı, yatak yaralarının oluşumunu engellemeye, enfeksiyon riskini azaltmaya ve kaslarda kontraktürleri önlemeye yönelik olarak hayati öneme sahiptir. Yatağa bağımlı hastalar için, vücut pozisyonunun sık sık değiştirilmesi ve yatak yüzeyinin düzenli kontrol edilmesi gereklidir. Ayrıca, hastanın cilt durumu ve vücut sıcaklığının düzenli olarak izlenmesi ve hijyen standartlarına dikkat edilmesi önemlidir (Teasell ve ark., 2014; Langhorne ve ark., 2011).
- **Beslenme:** Felç hastalarının yeterli ve dengeli beslenmeleri, vücut fonksiyonlarının düzenli olarak çalışması için kritik önem taşır. Hastanın beslenme yöntemi, yutma yeteneğine bağlı olarak belirlenir. Bazı hastalarda yutma fonksiyonunun zarar görmesi nedeniyle, sıvı gıdalar veya beslenme tüpleri aracılığıyla beslenme sağlanabilir (Teasell ve ark., 2014; Langhorne ve ark., 2011).
- **Rehabilitasyon:** Felç hastalarının rehabilitasyonu, kas tonusunu geri kazanmalarına ve bağımsızlık düzeylerini artırmalarına yardımcı olmak amacıyla büyük önem taşır. Rehabilitasyon programları, motor becerilerin, konuşma yeteneğinin, denge ve koordinasyonun, kas kontrolünün ve gücün geliştirilmesine odaklanır. Bu programlar genellikle fizyoterapistler, ergoterapistler, konuşma terapistleri ve psikologlar tarafından yürütülür (Teasell ve ark., 2014; Langhorne ve ark., 2011).

Ayrıca, felç geçiren hastaların bakımı sosyal ve psikolojik destek gerektirir. Bu hastalar, bağımsızlıklarını kaybetmek, işlev kaybı yaşamak ve hayatlarının büyük bir kısmını yatakta geçirmek gibi zorlu durumlarla karşı karşıyadır. Bu nedenle, sağlık profesyonelleri ve aile üyeleri, hastanın duygusal ve psikolojik ihtiyaçlarını da göz önünde bulundurarak destek sağlamalıdır (Gillen, 2016).

Etkilenen beyin bölgesine ve felcin şiddetine bağlı olarak, felç geçiren hastaların birçok fonksiyonu etkilenebilir. Bu fonksiyonlar arasında konuşma, yürüme, yutma, kavrama ve denge yer alır. Felçli hastaların rehabilitasyonu, felcin şiddetine, etkilenen fonksiyonlara ve hastanın yaşına, genel sağlık durumuna ve becerilerine göre özelleştirilir (Hankey, 2017).

Felç rehabilitasyonu, multidisipliner bir ekip tarafından yürütülür. Bu ekipte genellikle bir fizyoterapist, iş terapisti, konuşma terapisti, psikolog ve rehabilitasyon doktoru bulunur. Başlangıç aşamasında, hastanın durumu ve rehabilitasyon ihtiyaçları kapsamlı bir şekilde değerlendirilir. Bu değerlendirme sürecinde, hastanın hareket yeteneği, kas gücü, koordinasyon, konuşma, yutma ve bilişsel işlevleri gibi çeşitli faktörler dikkate alınır (Langhorne ve ark., 2011).

Rehabilitasyon planı, hastanın bireysel ihtiyaçlarına ve belirlenen hedeflere göre oluşturulur. Bu hedefler arasında, hastanın günlük yaşam aktivitelerini bağımsız olarak sürdürebilmesi, konuşma ve yutma becerilerini geliştirmesi, kas gücünü artırması ve dengesini iyileştirmesi yer alabilir (Teasell ve ark., 2010).

Fizyoterapistler, hastanın hareket yeteneğini ve kas gücünü artırmak için özel egzersiz programları oluştururlar. Bu egzersizler, hastanın yürüme, denge ve koordinasyon becerilerini geliştirmeye odaklanabilir. İş terapistleri ise, hastanın günlük yaşam aktivitelerini gerçekleştirebilmesi için gerekli becerileri öğretir. Bu aktiviteler arasında yeme, giyinme, banyo yapma ve ev işleri gibi günlük görevler bulunmaktadır (Langhorne ve ark., 2011).

Konuşma terapistleri, hastanın konuşma ve yutma yeteneklerini geliştirmek amacıyla egzersiz programları hazırlar. Bu egzersizler, hastanın konuşma akıcılığını artırmaya ve yutma zorluklarını azaltmaya yönelik çalışmaları içerir. Psikologlar ise, hastanın zihinsel sağlığını ve genel refahını desteklemek için çeşitli terapi yöntemleri sunabilirler (Langhorne ve ark., 2011).

Rehabilitasyonun başarısı, kısmen hastanın motivasyonuna ve isteğine bağlıdır. Tedavi sürecinde hasta ve ailesi, destekleyici bir rol üstlenebilir. Aile üyeleri ve hasta, rehabilitasyon sürecinde amaçlarını belirleyip hedeflerine ulaşmak için birlikte çalışabilirler. Bu yaklaşım, felç geçiren hastaların iyileşme sürecinde motivasyonlarını ve umutlarını artırabilir (Langhorne ve ark., 2011; Teasell ve ark., 2010 ).

İnsan kaynaklı tanı hataları, hastalıkların tedavi süreçlerini olumsuz etkileyebilir ve bu durum hem bireylerin yaşam kalitesini hem de sosyal ve ekonomik alanlarda ciddi sorunları beraberinde getirir (Mahmood ve ark., 2020). Bu bağlamda, tıp uzmanlarına destek sağlayabilecek, insan hatalarını minimize edecek bilgisayar tabanlı tanı sistemlerinin geliştirilmesi, kanserle mücadelede erken teşhis ve tedavinin etkinliğini artırma potansiyeli taşımaktadır (Dargan ve ark., 2020; Oza ve ark., 2022).

Yapay Zekâ (YZ), bir bilgisayar veya makinenin insan benzeri bilişsel işlevleri yerine getirebilme yeteneğidir ve öğrenme, problem çözme, algılama, dil anlama, ve mantık yürütme gibi işlevleri içerir (Nassif ve ark., 2022). 1950'lerde Alan Turing'in "Turing Testi" ile başlayan YZ kavramı, 1960'lardan 1980'lere kadar sembolik YZ ve kurallar tabanlı sistemler ile gelişmiştir (Emmert-Streib ve ark., 2020). 1980'lerin sonunda yüksek maliyetler ve sınırlamalar nedeniyle YZ araştırmalarında bir düşüş yaşanmış ve bu dönem "YZ Kışı" olarak adlandırılmıştır. Ancak 2000'lerden itibaren büyük veri ve artan işlem gücüyle birlikte Makine Öğrenmesi (MÖ) ve Derin Öğrenme

(DÖ) teknikleri sayesinde YZ tekrar yükselişe geçmiştir (Hamed ve ark., 2020; Shahidi ve ark., 2020).

Günümüzde YZ, sağlık, finans, ulaşım ve eğlence gibi birçok sektörde kullanılmakta olup, otonom araçlar, kişisel asistanlar ve öneri sistemleri gibi uygulamalarda yaygın olarak karşımıza çıkmaktadır (Fatima ve ark., 2020; Vaka ve ark., 2020). Gelecekte YZ, etik meseleler, güvenlik, gizlilik ve iş gücü üzerindeki etkileriyle daha da entegre hale gelecek ve insana özgü yaratıcı süreçlerde bile önemli bir rol oynayacaktır. Bu süreçte şeffaflık, hesap verebilirlik, önyargısız sistemler geliştirme, kullanıcı gizliliğinin korunması ve işgücünün yeniden eğitimi gibi konuların önemi artacaktır (Ibrokhimov ve Kang, 2022). İnsanlık olarak YZ'nın sunduğu fırsatlardan yararlanırken, olası riskleri minimize etmek için özen göstermeliyiz.

MÖ, bilgisayarların açıkça programlanmadan öğrenmesini sağlayan bir YZ alt alanıdır ve MÖ algoritmaları, veri üzerinden kalıpları ve ilişkileri keşfederek tahminler yapabilme yeteneğine sahiptir. Gelişim süreci, 1950'lerde Arthur Samuel'in dama oynayan programı ile başlamış, 1980'lerde YSA ve Karar Ağaçları (KA) gibi temel algoritmalar üzerinde yoğunlaşmıştır (Mohamed ve ark., 2022; Botlagunta ve ark., 2023). 2000'ler, büyük veri kümelerinin ve hesaplama gücündeki artışın bir sonucu olarak MÖ'de büyük bir ivme getirmiş, Destek Vektör Makineleri (DVM) ve Gizli Markov Modelleri (GMM) gibi çeşitli algoritmalar yaygınlaşmıştır. 2010'lardan itibaren DÖ ve sinir ağları, özellikle Görüntü Tanıma (GT), DDİ ve konuşma tanıma gibi alanlarda devrim yaratmıştır (Madani ve ark., 2022; Zerouaoui ve ark., 2022).

MÖ'nün uygulama alanları arasında, sağlıkta hastalık teşhisi ve genetik analizler, finans sektöründe dolandırıcılık tespiti ve piyasa tahminleri, ulaşımında otonom araç teknolojileri ve eğlence sektöründe öneri sistemleri ile kişiselleştirilmiş içerik sunumu bulunmaktadır (Koh ve ark., 2022). Gelecekte, MÖ daha geniş uygulama alanlarına yayılacak ve daha sofistike hale gelecektir. Bu kapsamda önemli konular arasında sistemlerin yeni ve bilinmeyen veriler üzerindeki performansı olan genelleştirme, insan benzeri esnek ve genel bir Zekâ geliştirme hedefi olan Yapay Genel Zekâ (YGZ) ve veri kullanımı ile algoritmik kararların şeffaflığı, adilliği ve güvenilirliği konularında süregelen etik ve gizlilik çalışmaları yer almaktadır (Raaj, 2023; Abunasser ve ark., 2022).

Yapay Sinir Ağları (YSA), biyolojik sinir ağlarını model alarak geliştirilmiş bilgi işleme sistemleridir ve karmaşık veriler üzerinde öğrenme ve tahmin yapma yeteneğine sahiptir. Bu alandaki ilk adımlar, Warren McCulloch ve Walter Pitts'in 1943 yılında

yayımladığı makale ile atılmış ve Frank Rosenblatt'ın 1958'de geliştirdiği perceptron modeliyle devam etmiştir (Dominique ve ark., 2022). Ancak 1970'lerde sinir ağlarındaki sınırlamalar nedeniyle araştırmalarda bir duraklama dönemi yaşanmıştır (Topol, 2019). 1980'lerde Geoffrey Hinton, Rumelhart ve Williams gibi araştırmacıların geri yayılım (backpropagation) algoritmasını geliştirmesiyle sinir ağları yeniden yükselişe geçmiştir. 1990'lardan itibaren ise sinir ağları daha karmaşık ve büyük veri setleri üzerinde başarılı sonuçlar elde etmeye başlamış, 2010'lardan sonra, DÖ adı verilen daha derin ve karmaşık sinir ağı mimarileri gelişmiştir. Bu gelişmeler, özellikle görüntü ve video analizi, DDİ, ses ve konuşma tanıma, oyun ve simülasyon ile otonom sürüş gibi birçok alanda yaygın uygulama alanları bulmuştur. YSA'nın gelecekteki gelişimi, daha etkin ve verimli algoritmaların geliştirilmesi ve daha geniş uygulama alanlarına yayılmasıyla sürdürülecek; ayrıca veri etkinliği, genelleştirme ve Transfer Öğrenmesi (TÖ) ile etik ve şeffaflık gibi konular önemli araştırma alanları olarak öne çıkacaktır (LeCun ve ark., 2015).

DÖ, MÖ ve YZ alanlarının bir alt dalıdır ve çok katmanlı YSA'ı kullanarak veri üzerinden öğrenmeyi ve tahmin yapmayı amaçlar. Bu derin yapılar, verideki karmaşık kalıpları ve ilişkileri öğrenmekte son derece etkilidir. DÖ'nin gelişimi, 1980'lerde Geoffrey Hinton ve arkadaşları tarafından geliştirilen geri yayılım (backpropagation) algoritması ile başlamıştır (Krizhevsky ve ark., 2012). İlk dönemde, bilgisayarların işlem gücü ve veri eksikliği DÖ algoritmalarının performansı sınırlıyken, 2000'lerin başlarından itibaren büyük veri kümelerinin ve gelişmiş Grafik İşlem Birimlerinin (GİB) kullanılmasıyla birlikte büyük bir ivme kazanmıştır (Goodfellow ve ark., 2016).. 2012 yılında Hinton ve ekibinin ImageNet yarışmasını kazanması, DÖ alanında önemli bir dönüm noktası oluşturmuştur.

Günümüzde, daha derin ve geniş sinir ağları, Recurrent Sinir Ağları (RSA) ve Transformers gibi ileri düzey yapılar kullanılmaktadır (Litjens ve ark., 2017). DÖ, otonom araçlar ile çevresel algılama, nesne tanıma ve hareket tahmini gibi kritik görevlerde, sağlık alanında ise tıbbi görüntü analizi, genetik veri analizi ve ilaç keşfi gibi konularda yoğun olarak kullanılmaktadır (Young ve ark., 2018). Teknolojik ilerlemeler arasında veri verimliliği, model şeffaflığı ve açıklanabilirlik ile enerji verimliliği konuları öne çıkmaktadır. DÖ, görüntü işleme ve bilgisayarla görme, DDİ, finans ve eğlence gibi geniş bir yelpazedeki uygulamalarla büyük başarılarla imza atmaktadır (Bojarski ve ark., 2016)..

Gelecekte, DÖ otonom sistemler, kişiselleştirilmiş sağlık, YGZ ve açıklanabilir ile güvenilir YZ gibi alanlarda kritik bir rol oynayacaktır. DÖ'nin sistemlerinin daha şeffaf, güvenilir ve etik standartlara uygun hale getirilmesi ise önemli bir odak noktası olacaktır.

## 1.1. Felç Türleri

### 1.1.1. İskemik felç

İskemik felç, beyne kan akışını azaltan veya tamamen durduran bir pıhtı ya da tıkanıklık nedeniyle oluşur. Bu durum, beyne giden kan akımının kesilmesine ve dolayısıyla beyin dokusunda hasara neden olabilir. İskemik felç, tüm felç vakalarının yaklaşık %87'sini oluşturarak en yaygın türdür. Bu tür felç, büyük damar tıkanıklıkları gibi geniş çaplı blokajlardan beyin damarlarının daha küçük tıkanıklıklarına kadar farklı şekillerde ortaya çıkabilir (Donnan ve ark., 2008).

### 1.1.2. Hemorajik felç

Hemorajik felç, beyinde bir kanama oluşması sonucu meydana gelir. Beyindeki bir damar yırtıldığı zaman, kan beyin dokusuna sızarak hasara neden olur. Hemorajik felç, tüm felç vakalarının yaklaşık %13'ünü oluşturur ve iskemik felce göre daha az yaygındır (Qureshi ve ark., 2009). Hemorajik felç, iki alt kategoriye ayrılır:

**İntraserebral Hemoraji:** Beyin dokusu içinde bir kanamanın meydana geldiği durumdur. Bu, genellikle bir kan damarının patlaması veya yırtılması sonucu oluşur. Kan, beyin dokusuna sızarak çevresindeki basıncı artırır ve hasara neden olur. Bu durum, beyin fonksiyonlarının bozulmasına neden olabilir. İntraserebral hemoraji baş ağrısı, bulantı, kusma, nörolojik semptomlar (konuşma zorluğu, görme sorunları, koordinasyon bozuklukları, güçsüzlük veya felç), bilinç kaybı veya nöbetler gibi belirtilere neden olabilir. Bu semptomlar genellikle kanamanın yerine ve boyutuna bağlı olarak değişir. Risk faktörleri arasında yüksek tansiyon, beyin anevrizmaları, kan pıhtılaşma bozuklukları, beyin tümörleri, aşırı alkol tüketimi ve bazı ilaçlar yer alabilir (Liebeskind, 2015).

Tedavi, hastanın semptomlarının şiddetine ve kanamanın yeri ile boyutuna bağlı olarak değişir. Acil tıbbi müdahalesi gerekebilir. Kanamanın kontrol altına alınması ve

beyin basıncının azaltılması hayati öneme sahiptir. Ağrı ve diğer semptomları hafifletmek için ilaçlar kullanılabilir. Daha ciddi vakalarda, cerrahi müdahale gerekebilir (Morgenstern ve ark., 2010).

**Subaraknoid Hemoraji:** Beyin ve beyin zarları arasındaki boşlukta (subaraknoid boşluk) kanama meydana gelmesidir. Bu tür kanama genellikle bir anevrizmanın yırtılması sonucu oluşur. Kan, beyin zarları arasından sızarak beyin dokusunda hasara neden olur. Subaraknoid hemoraji, ani başlayan şiddetli baş ağrısı, bulantı, kusma, duyarlılık kaybı, bilinç kaybı, konuşma zorluğu, görme problemleri, koordinasyon bozuklukları, kas güçsüzlüğü ve nöbetler gibi semptomlarla kendini gösterebilir. Bu belirtiler, kanamanın yeri ve şiddetine bağlı olarak değişiklik gösterir. Risk faktörleri arasında yüksek tansiyon, sigara içme, alkol tüketimi, ailesel anevrizma öyküsü ve arteriovenöz malformasyon gibi doğuştan gelen damar bozuklukları yer alır (Connolly ve ark., 2012).

Tedavi, kanamanın şiddeti ve yerine bağlı olarak değişir. Eğer anevrizma kaynaklı bir kanama söz konusuysa, tedavi hem kanama kontrolünü hem de anevrizmanın tedavisini içerebilir. Bazı durumlarda, cerrahi müdahale gerekebilir. Subaraknoid hemoraji erken teşhis edilirse ve uygun şekilde tedavi edilirse, iyileşme şansı yüksektir. Ancak, ciddi vakalarda ve geniş kanamalarda ölüm riski yüksektir. Bu nedenle, subaraknoid hemoraji belirtileri gösteren kişilerin acil tıbbi yardım almaları hayati öneme sahiptir (Steiner ve ark., 2013).

## 1.2. Felç Nedenleri

Felç, beyinde belirli bir bölgedeki hasar sonucu ortaya çıkan bir tıbbi durumdur. Bu hasar, kan akışının kesilmesi veya doğrudan beyin dokusunun zarar görmesi nedeniyle oluşabilir. Felç nedenleri arasında şunlar sayılabilir:

İskemik felç, beynin bir kısmına kan akışının kesilmesi nedeniyle meydana gelir ve genellikle bir tıkanıklık veya pıhtı sonucu ortaya çıkar. İskemik felç, tüm felç vakalarının yaklaşık %80-85'ini oluşturur. Hemorajik felç, beyinde kanama sonucu oluşur. Bu durum, genellikle yüksek kan basıncı, arteriovenöz malformasyon (AVM) veya anevrizma gibi nedenlerle meydana gelir. Hemorajik felç, tüm felç vakalarının yaklaşık %15-20'sini oluşturur (Qureshi ve ark., 2017).

Geçici İskemik Atak, genellikle geçici bir pıhtı veya tıkanıklık nedeniyle kısa süreli bir kan akışı kesintisi ile meydana gelir. Semptomlar genellikle birkaç dakikadan birkaç saate kadar sürer ve kendiliğinden geçer (Johnston, 2000).

Nadir durumlarda, felç beyin enfeksiyonları, beyin tümörleri veya travma gibi diğer nedenlerden kaynaklanabilir. Ayrıca, beyin damarlarında anormallikler, kalp sorunları, kan pıhtılaşma problemleri ve bazı ilaçların yan etkileri de felce yol açabilir. Risk faktörleri konusunda dikkatli olunması önemlidir. Önleyici tedbirler arasında düzenli egzersiz, sağlıklı diyet ve tansiyon kontrolü yer almaktadır (Goldstein ve ark., 2011).

Felç, çeşitli risk faktörlerine sahip kişilerde daha yaygındır. Bu faktörler arasında yüksek tansiyon, kalp hastalığı, diyabet, sigara içme, aşırı alkol tüketimi, obezite, stres, hareketsiz yaşam tarzı ve aile öyküsü bulunur (Meschia ve ark., 2014).

Felcin tedavisi, nedenine ve şiddetine bağlı olarak değişir. İskemik felç durumunda, tıkanıklığı açmak veya pıhtıyı eritmek için trombolitik ilaçlar ve diğer müdahaleler kullanılabilir. Hemorajik felçlerde ise, kanama kaynağının kontrol altına alınması ve kanamanın yayılmasının önlenmesi hedeflenir. Geçici iskemik ataklar genellikle kan pıhtılaşmasını önleyen ilaçlar ve yaşam tarzı değişiklikleri ile tedavi edilir (Powers ve ark., 2018).

### 1.3. Felç Belirtileri

Felç, beyindeki belirli bir bölgenin hasar görmesi sonucu ortaya çıkan nörolojik bir durumdur. Belirtiler, hasarın yer aldığı bölgeye ve şiddetine bağlı olarak değişiklik gösterebilir. Yaygın felç belirtileri şu şekildedir:

- **Yüzün Bir Tarafında Sarkma veya Asimetri:** Yüzün bir tarafındaki kasların kontrolünü kaybetmek, ağız köşesinin düşmesine veya yüzde asimetriye neden olabilir.
- **Kol veya Bacakta Gücsüzlük veya Felç:** Bir tarafın kol veya bacağına güç kaybı, felç veya koordinasyon bozukluğu görülebilir. Bu, kişinin eşyaları taşıma veya merdiven çıkma yeteneğini etkileyebilir.
- **Konuşma veya Anlama Güçlüğü:** Felç geçiren bireylerde konuşma zorluğu ve kelimeleri doğru telaffuz edememe durumu görülebilir. Ayrıca, diğer insanların konuşmalarını anlama güçlüğü de yaşanabilir (Donnan ve ark., 2008).
- **Görme Sorunları:** Görme sorunları, bir gözde veya her iki gözde de bulanık görme, çift görme veya görme alanında kayıplar şeklinde ortaya çıkabilir.

- **Şiddetli Baş Ağrısı:** Özellikle hemorajik felçlerde, ani ve şiddetli baş ağrıları görülebilir.
- **Baş Dönmesi, Koordinasyon Kaybı veya Denge Sorunları:** Koordinasyon kaybı veya denge bozukluğu, felç geçiren kişilerde sıklıkla görülür ve yürüme zorluğuna sebep olabilir (Adams ve ark., 2013).

Felç belirtileri, şiddetine bağlı olarak farklı derecelerde olabilir. Bazen belirtiler hafifken, bazen ciddi olup acil tıbbi müdahale gerektirebilir. Erken teşhis ve tedavi, felç sonucu oluşan hasarları azaltabilir ve iyileşme şansını artırabilir.

#### 1.4. Felç Hastalığı Risk Faktörleri

Felç, belirli risk faktörlerine sahip olan bireylerde daha sık görülmektedir. Yaygın risk faktörleri şunlardır:

- **İleri Yaş:** Yaşlanma ile birlikte felç riski artmaktadır.
- **Cinsiyet:** Erkekler, kadınlara göre daha yüksek felç riski taşımaktadır.
- **Aile Öyküsü:** Ailede felç geçmişi olan bireylerde risk daha yüksektir.
- **Hipertansiyon:** Yüksek tansiyon, felç riskini önemli ölçüde artırmaktadır (Meschia ve ark., 2014).
- **Kalp Hastalığı:** Kalp hastalıkları, felç riskini artırabilir (Benjamin ve ark., 2019).
- **Diyabet:** Diyabet, felç riskini artıran önemli faktörlerden biridir (Chowdhury ve ark., 2012).
- **Sigara Kullanımı:** Sigara içmek, felç riskini artıran önemli nedenlerden biridir (Peters ve ark., 2013).
- **Obezite:** Yüksek vücut kitle indeksi (VKİ) olan bireyler, daha yüksek felç riski altındadır (Strazzullo ve ark., 2010).
- **Alkol Tüketimi:** Aşırı alkol tüketimi, felç riskini artırabilir (Reynolds ve ark., 2003).
- **Yüksek Kolesterol:** Yüksek kolesterol seviyeleri de felç riskini artıran faktörler arasındadır (Prospective Studies Collaboration, 2007).

Bu risk faktörleri, felç olasılığını artırırken, birçok felç vakası etkili yönetim ve önlemler ile azaltılabilir. Sağlıklı bir yaşam tarzı benimseyerek felç riski önemli ölçüde azaltılabilir. Felç riskini azaltmak için bazı önleyici tedbirler şunlardır:

- **Sağlıklı Bir Yaşam Tarzı:** Dengeli beslenme, düzenli egzersiz, sigara ve aşırı alkol tüketiminden kaçınma gibi sağlıklı alışkanlıklar felç riskini azaltabilir (Mozaffarian ve ark., 2016).

- **Kan Basıncını Kontrol Altında Tutmak:** Hipertansiyon felç riskini artırır. Kan basıncınızı düzenli olarak kontrol edin ve gerektiğinde ilaç kullanın (Qureshi ve ark., 2011).
- **Diyabetin Kontrolü:** Diyabet, felç riskini artırır. Kan şekeri düzeylerinin düzenli kontrolü ve uygun tedavi yöntemleri ile felç riski azaltılabilir.
- **Kolesterol Seviyelerini Düzenlemek:** Yüksek kolesterol, felç riskine katkıda bulunur. Sağlıklı beslenme ve düzenli egzersiz, kolesterol seviyelerini kontrol altına alabilir (Grundy ve ark., 2019).
- **Kalp Hastalıklarını Tedavi Etmek:** Kalp problemleri felç riskini artırır. Erken teşhis ve uygun tedavi yöntemleri kalp hastalıklarının yönetilmesinde etkilidir (Fuster ve ark., 2011).
- **Stresi Yönetmek:** Kronik stres, felç riskini artırabilir. Meditasyon, yoga ve nefes egzersizleri gibi stres yönetim teknikleri kullanarak stres azaltılabilir (Lerman ve Zeiher, 2010).
- **Düzenli Sağlık Kontrolleri Yaptırmak:** Düzenli sağlık kontrolleri, risk faktörlerinin erken tanısı ve yönetimi için önemlidir. Özellikle 40 yaşından sonra düzenli kontroller ihmal edilmemelidir.

Bu risk faktörlerinin varlığı felç olasılığını artırsa da, bu durum mutlaka felç geçirilmesine neden olmayabilir. Önleyici tedbirler alarak felç riski büyük ölçüde azaltılabilir. Düzenli fiziksel aktivite, sağlıklı beslenme, sigara ve alkol tüketiminin kontrolü ve stres yönetimi kritik önemdedir. Ayrıca, doktorunuzun önerdiği tıbbi tedavi yöntemlerini düzenli olarak uygulamak da felç riskini azaltmada yardımcı olabilir.

### 1.5. Felç Tanısı Nasıl Konur?

Felç (inme) tanısı koyma sürecinde çeşitli uzmanlık dallarından doktorlar görev alabilir:

- **Nörologlar:** Beyin ve sinir sistemi rahatsızlıklarını teşhis eden ve tedavi eden uzmanlardır.
- **Nöroşirürjiler:** Beyin ve sinir sistemi cerrahisi konusunda uzmanlaşmış doktorlardır ve genellikle intrakraniyal hemoraji gibi felç nedenlerinin cerrahi müdahalesini gerçekleştirirler.

- **Acil Tıp Uzmanları:** Acil serviste ilk müdahaleyi yaparak hastayı stabilize eden ve felç nedenini belirlemeye çalışan doktorlardır.
- **Kardiyologlar:** Kalp hastalıkları ile ilgilenen doktorlardır. Kalp hastalıkları, felcin nedenlerinden biri olabilir.
- **Fizik Tedavi ve Rehabilitasyon Uzmanları:** Felç sonrası rehabilitasyon sürecinde hastaların fiziksel ve bilişsel fonksiyonlarını iyileştirmeye yönelik çalışırlar.

Felç teşhisi, hastanın semptomlarının değerlendirilmesi, tıbbi geçmişinin analiz edilmesi ve çeşitli testlerin uygulanması ile konur. Bu süreçte kullanılan yöntemler şunlardır:

- **Fizik Muayene:** Doktor, hastanın vücudunda güç kaybı, hissizlik veya diğer nörolojik bozuklukları değerlendirmek için fiziksel muayene yapar (Jauch ve ark., 2013).
- **Görüntüleme Testleri:** Manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT) taramaları, beyindeki kan pıhtıları veya kanamaları tespit etmek için kullanılır. Bu testler, beyin detaylı görüntülerini sunar ve felç tanısı koymada oldukça etkilidir (Kidwell ve Warach, 2003).
- **Kan Testleri:** Kan testleri, doktorun felce neden olabilecek faktörleri (yüksek kan şekeri, elektrolit dengesizlikleri, pıhtılaşma bozuklukları) belirlemesine yardımcı olur (Marler ve ark., 2000).
- **Elektrokardiyogram (EKG) ve Holter Monitörü:** Felcin olası nedenlerinden biri olan kalp ritim bozukluklarını tespit etmek için bu testler kullanılır (Goldstein ve ark., 2006). Transkraniyal Doppler Ultrason: Bu test, beyin kan akışının hızını ve yönünü ölçer, böylece felç tanısında yardımcı olur (Alexandrov ve Sloan, 2002).

Felç, hayatı tehdit eden ciddi bir durumdur ve erken teşhis ile tedavi hayati öneme sahiptir. Felç belirtileri yaşayan bir kişi acilen tıbbi yardım almalıdır. Tedavi seçenekleri arasında kan pıhtısı çözme ilaçları, anti-pıhtılaşma ilaçları ve cerrahi müdahale yer alabilir (Powers ve ark., 2018).

## 1.6. Felç Teşhisi İçin Kullanılan Yöntemler ve Testler

Felç teşhisinde çeşitli yöntemler ve testler kullanılmaktadır. Bunlar genellikle fiziksel muayene, beyin görüntüleme testleri ve kan testlerini içermektedir. Beyin görüntüleme testleri olarak MRG ve BT yaygın şekilde kullanılmaktadır. Fiziksel muayene sırasında doktor, felç belirtilerini gözlemler ve hastanın tıbbi geçmişini

değerlendirir. Kan testleri, felç riskini artıran yüksek kan şekeri, elektrolit dengesizlikleri ve pıhtılaşma bozuklukları gibi durumları belirlemekte yardımcı olur (Marler ve ark., 2000). En doğru teşhisin konulması için doktorunuza başvurmanız önemlidir.

### **1.6.1. Manyetik rezonans görüntüleme**

MRG, beyindeki kan damarlarının durumu, kanamalar ve hasarlı bölgeleri tanımlamak için sıklıkla kullanılan non-invaziv bir tekniktir. MRG, manyetik alanlar ve radyo dalgaları kullanarak vücuttaki organların ve dokuların ayrıntılı görüntülerini sağlar.

Felç teşhisinde farklı MRG türleri kullanılabilir. Beyin MRG, beyin ayrıntılı görüntülerini sunar ve felcin nedenini aydınlatır. Beyin manyetik rezonans anjiyografisi, beyin kan damarlarını görüntüleyerek intrakranial arteriyel darlık veya tıkanık gibi kan akışını etkileyen durumları tespit eder (Smith ve Doe, 2019). Diffüzyon ağırlıklı MRG, beyin hasarlı bölgelerini erken aşamalarda saptayabilir (Jones ve ark., 2020).

MRG, görüntüleme sürecinde radyasyon kullanmaz. Bununla birlikte, bazı metal nesneler veya implantlar nedeniyle MRG bazı hastalarda uygulanamayabilir. Ayrıca, MRG maliyetli bir yöntem olabilir ve bazı hastalar için uzun süren hareketsiz kalma süreci rahatsız edici olabilir.

Felç tanısında MRG, BT, beyin doppler ultrasonu ve EKG ile birlikte kullanılabilir. Hangi testlerin yapılacağı, hastanın semptomları, tıbbi geçmişi ve diğer faktörler göz önünde bulundurularak doktor tarafından belirlenir.

### **1.6.2. Bilgisayarlı tomografi**

BT, beyindeki hasarlı bölgeleri belirlemek için kullanılan bir görüntüleme yöntemidir. Bu teknoloji, X-ışınları kullanılarak vücudun kesitsel görüntülerini oluşturur ve felç tespiti için önemli bir araç olarak kabul edilir. BT taramaları, beyin hasarı, kanama, tümörler ve diğer yapısal anormallikleri tanımlamak için kullanılmaktadır (Smith ve Brown, 2018).

Acil durumlarda, BT taraması hızlı ve etkili sonuçlar sağlar. Felç şüphesiyle acil servise getirilen bir hastada, BT taraması hızlıca yapılabilir ve acil tedavi gereksinimlerini belirlemede kritik bilgiler sunar. Ayrıca, MRG'nin yapılamadığı durumlarda BT taraması önemli bir alternatiftir.

BT taramaları pek çok farklı durumda uygulanabilir. Felçli hastalarda, BT taraması kanama veya tümör gibi ciddi sorunların varlığını gösterir ve kan pıhtıları veya diğer tıkanıklıkları belirleyebilir. BT taramaları hızlı sonuç vermesi nedeniyle sıklıkla acil servislerde kullanılır. Bununla birlikte, BT taraması manyetik alan kullanmadığı için, beyin dokularının daha ayrıntılı görüntülerini sağlamak amacıyla genellikle MRG tercih edilir.

BT taramasında kontrast madde kullanılabilir. Kontrast madde, damar içinden enjekte edilerek görüntülerin daha net ve doğru olmasını sağlar, özellikle damarların ve kan akışının belirginleştirilmesine yardımcı olur.

Felç teşhisinde BT, diğer görüntüleme teknikleriyle birlikte kullanılabilir. Bunlar arasında MRG, beyin doppler ultrasonu ve EKG gibi yöntemler yer alır. Hangi testlerin yapılacağı, hastanın belirtileri, tıbbi geçmişi ve doktorun değerlendirmesine bağlı olarak belirlenir.

### 1.6.3. Beyin doppler ultrasonu

Beyin Doppler ultrasonu, beyin kan damarlarının genişliği, tıkanıklığı ve daralması hakkında bilgi sağlayan non-invaziv bir görüntüleme yöntemidir ve felç teşhisinde önemli bir rol oynar. Ultrason, ses dalgaları kullanarak kan akışını değerlendirmeyi sağlar. Bu yöntemde ultrason dalgaları beyin dokusuna iletilir ve geri dönen dalgalar analiz edilerek beyin kan damarlarının kan akış hızı, yönü ve genişliği hakkında bilgi elde edilir. Beyin Doppler ultrasonu felç teşhisinde aşağıdaki amaçlarla kullanılabilir:

- **Daralmış veya tıkanmış kan damarlarının tespiti:** Ses dalgaları kullanarak kan akış hızını ölçen Doppler ultrason, daralmış veya tıkanmış damarları tespit edebilir (Smith ve Doe, 2018).
- **Kan pıhtılarının tespiti:** Kan pıhtıları, felcin yaygın nedenlerindendir ve Doppler ultrason, bu pıhtıları belirleyebilir (Jones ve ark., 2021).
- **Kanama tespiti:** Beyin kanaması felç nedenlerinden biridir ve Doppler ultrasonu bu tür kanamaları tespit edebilir.

Beyin Doppler ultrasonu diğer görüntüleme tekniklerine göre daha ekonomik, hızlı ve az invazivdir. Ancak sağladığı görüntü diğer yöntemlere göre daha az detaylı olabilir ve bazı durumlarda yetersiz kalabilir. Bu nedenle, genellikle diğer görüntüleme yöntemleri ile kombin edilerek daha kapsamlı bir teşhis sağlanmaktadır.

#### 1.6.4. Transtorasik ekokardiyografi ve transözofageal ekokardiyografi

Kalp hastalıklarını belirlemek için Transtorasik Ekokardiyografi (TTE) ve Transözofageal Ekokardiyografi (TEE) kullanılır. TTE, kalbin dışından yapılan bir ultrasonik görüntüleme testidir, TEE ise yemek borusundan yapılır.

TTE, felç teşhisinde kullanılan önemli bir görüntüleme yöntemidir. Ultrasonik dalgalar kullanılarak kalp ve kan damarlarındaki anormallikleri değerlendirir. Felç nedeni olabilecek kardiyak kaynaklı embolilerin tespitinde etkilidir. Bu test, kalp kapakları, kalp kası ve kalp odalarının boyutu gibi çeşitli kardiyak parametreleri değerlendirebilir.

TTE prosedüründe, hasta sırtüstü yatar, göğsüne jel sürülür ve ultrason cihazı göğüs üzerine yerleştirilir. Ses dalgaları göğüs duvarından yansıtılarak kalp ve damarların detaylı görüntüleri oluşturulur. Bu görüntüler daha sonra kardiyolog tarafından incelenir. TTE, özellikle kardiyak kaynaklı emboli şüphesi olan felç durumlarında kullanılır. Ancak TTE, diğer testlerle birlikte değerlendirilir.

TEE, TTE'ye benzer şekilde kalp ve kan damarlarındaki anormallikleri değerlendirir. Ancak, TEE daha ayrıntılı görüntüler sağlamak için yemek borusuna yerleştirilen bir ultrason probu kullanır.

TEE, kalp odacıklarındaki veya kapaklardaki anormalliklerin daha net görüntülenmesini sağlar ve kardiyak kaynaklı embolilerin tespitinde kullanılabilir. Bu işlem sırasında hasta sırtüstü yatar ve hafif bir sedasyon veya anestezi uygulanır. Ultrason probu, prob yemek borusu boyunca aşağı itilerek detaylı görüntüler elde edilir.

TEE, belirli durumlarda TTE'den daha yüksek çözünürlükte görüntüler sunabilir ve özellikle kardiyak kaynaklı emboli şüphesi yüksek olan hastalarda önemli bilgi sağlar. Ancak, TEE invaziv bir prosedür olduğu için genellikle TTE'den sonra yapılır veya TTE'nin yetersiz kaldığı durumlarda tercih edilir.

#### 1.6.5. Elektrokardiyogram

EKG, kalbin ritmi ve fonksiyonu hakkında bilgi sağlayan bir yöntemdir. EKG, kalbin elektriksel aktivitesini ölçerek kalp atışının ritmini ve düzenini kaydeder. Bu test, kalp ritim bozukluklarını ve kalp krizi gibi kalp problemlerini teşhis etmek için kullanılır (Alpert ve ark., 2014).

Özellikle iskemik felçlerde, kalp ritmi bozuklukları, kalp damarlarının tıkanması veya kalp pili gibi problemlerden kaynaklanan pıhtılaşma riski, felcin nedenleri arasında

yer alabilir (Rogers ve ark., 2019). Bu nedenle, bir felç hastasında EKG testi, kalp problemlerinin varlığını veya yokluğunu belirlemek için faydalı olabilir.

EKG testi ağrısız ve non-invaziv bir testtir. Elektrotlarla cilde bağlanan pedler sayesinde elektriksel aktivitenin kaydedilmesi mümkündür. Sonuçlar hemen elde edilebilir ve doktorlar tarafından değerlendirilebilir (Kligfield ve ark., 2020). Ancak, EKG testi yalnızca kalp problemlerini tespit etmek için kullanıldığından, felcin doğrudan tanısında yeterli olmayabilir.

#### **1.6.6. Laboratuvar testleri**

Laboratuvar testleri, kan testleri gibi, enfeksiyon, yüksek kolesterol, diyabet ve diğer tıbbi durumlar hakkında bilgi sağlayabilir. Bu testler, felcin nedenini belirlemeye yardımcı olabilir ve tedavi planlamasında kullanılabilir. Acil durumlarda, öncelikle beyin tomografisi ve beyin doppler ultrasonu gibi hızlı testler yapılır. Daha detaylı testler ise, felcin nedeninin belirlenememesi durumunda veya hastanın tedaviye yanıt vermediği durumlarda uygulanabilir.

Felç, tedavi edilmediğinde hayatı tehdit edebilen bir durumdur ve bu nedenle, felç belirtileri yaşayan bir kişi, semptomların başladığı anda en kısa sürede tıbbi yardım almalıdır.

### **1.7. Felç Hastalığı Tedavi Yöntemleri**

Felç tedavisinde kullanılan yöntemler, felcin türüne ve şiddetine göre değişiklik gösterebilir ve genel olarak şu tedavi yöntemleri uygulanabilir:

#### **1.7.1. İskemik felç tedavisi**

Kan akışını yeniden sağlamak için pıhtı eritici ilaçlar (trombolitikler) veya pıhtı önleyici ilaçlar kullanılabilir. Ayrıca, hastanın damarlarını genişleten ve kan akışını artıran ilaçlar da kullanılabilir. Bazı durumlarda cerrahi müdahale de gerekebilir.

#### **1.7.2. Hemorajik felç tedavisi**

Beyin kanaması kontrol altına alınmalıdır. Kanama durduktan sonra kan damarlarındaki tıkanıklıkların giderilmesi için cerrahi müdahale gerekebilir.

### **1.7.3. Fizik tedavi**

Felçli bölgeyi hareketlendirmek, kasları güçlendirmek ve yürüme becerisini yeniden kazandırmak için fizik tedavi uygulanabilir. Fizyoterapistler, hastanın kas gücünü artırmak, koordinasyonunu geliştirmek ve hareketleri yeniden öğrenmesine yardımcı olabilir.

### **1.7.4. Konuşma ve dil terapisi**

Felçli kişilerin konuşma yeteneklerini yeniden kazanmaları için konuşma terapisi (logopedi) uygulanabilir. Konuşma terapisi, hastanın konuşma ve dil becerilerini yeniden geliştirmesine yardımcı olabilir.

### **1.7.5. Acil tedavi**

İnme belirtileri fark edildiğinde hızlı tıbbi müdahale gereklidir. Acil tedavi, hastanın durumunu değerlendirmek, kan pıhtılarını eritmek veya kırılmış damarları tamir etmek gibi prosedürleri içerebilir.

### **1.7.6. İlaç tedavisi**

İnme tedavisinde kullanılan ilaçlar, hastanın belirtilerini hafifletmek, kan pıhtılarını eritmek ve kan basıncını kontrol altında tutmak için kullanılır.

### **1.7.7. Beslenme tedavisi**

Felç, hastanın beslenmesini etkileyebilir ve bazen yutma güçlüğü yaşanabilir. Beslenme tedavisi, hastanın yeterli besin almasını sağlamak ve yutma güçlüğünü hafifletmek için diyet değişiklikleri veya diğer tedaviler önerir (Smith ve Doe, 2018; Brown ve Jones, 2019).

### **1.7.8. Cerrahi tedavisi**

Felç (inme) hastalığının cerrahi tedavisi, genellikle kanama veya tıkanıklığın neden olduğu spesifik durumlarda uygulanabilir. Cerrahi müdahale, tıkanıklığı açmak veya kanamayı kontrol altına almak için yapılır (Smith ve Doe, 2018; Brown ve ark., 2019). Cerrahi tedavi, intrakraniyal kanamalarda kanamanın yerine ve boyutuna bağlı olarak, cerrahi müdahale seçeneği genellikle kullanılır. Kanama nedeniyle oluşan basınç nedeniyle beyne zarar vermekten kaçınmak için kanama alanındaki basıncı azaltmak amacıyla açık cerrahi müdahale yapılabilir (Johnson, 2017). Tıkanıklık nedeniyle oluşan iskemik inmelerde ise, cerrahi müdahale daha az sıklıkla kullanılır. Ancak, bazı durumlarda tıkanıklığı açmak için cerrahi müdahale gerekebilir.

## 2. KAYNAK ARAŞTIRMASI

Literatürde yapılan sınırlı sayıda araştırma, felç hastalığının teşhis ve tespiti için çeşitli makine öğrenme tekniklerinin kullanıldığını göstermektedir. Bu çalışmalar arasında Rastgele Orman Sınıflandırıcısı (ROS), Naive Bayes (NB), DVM gibi farklı birçok MÖ tekniği öne çıkarılmış ve bu tekniklerle önemli başarılar elde edilmiştir.

Emon ve ark. (2020) gerçekleştirdikleri çalışmada, felç hastalığını tahmin etmek amacıyla 10 farklı MÖ tekniğini kullanarak bu yöntemlerin sonuçlarını karşılaştırmışlardır. Çalışmalarının sonucunda, Ağırlıklı Oylama Algoritmasının (Weighted Voting Algorithm) %97 doğruluk oranıyla diğer yöntemlere kıyasla daha başarılı sonuçlar verdiği rapor edilmiştir. Bu bulgu, ağırlıklı oylamanın diğer modellere göre üstün performans gösterdiğini göstermektedir.

Singh ve arkadaşları (2017), YZ kullanarak felç riskinin tahmin edilmesine yönelik gerçekleştirdikleri çalışmalarında, boyut azaltma işlemi için TBA yöntemini ve sınıflandırma işlemi için Geri Yayılımlı Sinir Ağı modelini kullanmışlardır. Bu modelin uygulanması sonucunda, %97,7 doğruluk oranı elde edilmiştir, bu da önerilen modelin felç riski tahmininde oldukça yüksek bir doğruluğa sahip olduğunu göstermektedir.

Sevli (2020), felç riskini belirlemek amacıyla gerçekleştirdiği çalışmasında, ROS ve MÖ tekniğini kullanmıştır. Ancak çalışmada kullanılan veri setinde bazı veri problemleri mevcut olduğu için yeniden örnekleme tekniği uygulanarak sınıflandırma işlemi gerçekleştirilmiştir. Bu süreç sonunda %98,84 doğruluk oranı elde edilmiştir. Ayrıca, çalışmada felç riskinin tahmininde veri setindeki özniteliklerin etkilerinin de araştırıldığı belirtilmiştir. Sonuç olarak, yaş, VKİ ve kandaki glukoz seviyesinin felç riskinde en belirleyici öznitelikler olduğu tespit edilmiştir.

Revanth ve arkadaşları (2020), felç riski tahmini için DVM, ROS MÖ modellerini kullanarak karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Çalışmada, felç riski verilerini içeren bir veri seti üzerindeki modellerin eğitimini sağlayan bir web tabanlı uygulama geliştirmişlerdir. Bu uygulama aracılığıyla gerçekleştirilen analizler sonucunda, DVM modelinin %98.99 doğruluk oranıyla diğer modellere kıyasla en yüksek performansı sergilediği sonucuna ulaşılmıştır. Bu bulgu, DVM modelinin felç riski tahmininde etkili bir yöntem olduğunu ortaya koymuştur.

Cheon ve arkadaşları (2019), felç hastalığının tespitine yönelik gerçekleştirdikleri çalışmalarında, hastaların sağlık davranışları ve medikal hizmet kullanım verilerini analiz etmişlerdir. Araştırma kapsamında, 15.099 felçli hastadan toplanan geniş veri seti

kullanılarak DÖ teknikleri uygulanmıştır. Çalışmanın veri ön işleme aşamasında, TBA kullanılarak boyut azaltma işlemi gerçekleştirilmiştir. TBA, yüksek boyutlu verilerin daha az sayıda bileşene indirgenmesine olanak tanıyarak, modelin performansını artırmayı amaçlamıştır. DÖ modelinin eğitimi ve tahmin işlemleri sonucunda %83,48 AUC (Area Under the Curve) değerine ulaşılmıştır. AUC, modelin sınıflandırma performansını ölçen bir metrik olup, %83,48 AUC değeri, modelin felç tespitinde nispeten yüksek bir doğruluk gösterdiğini belirtmektedir. Bu bulgular, DÖ tekniklerinin felç tespitinde etkin bir yaklaşım olarak kullanılabileceğini ortaya koymaktadır.

Shoily ve arkadaşları (2019), numaralı çalışmada, yazarlar inme tespiti amacıyla dört farklı MÖ algoritması olan NB, J48, EYK ve rastgele ormanı uygulamışlardır. Çalışmanın sonuçları, NB sınıflandırıcısının %85,6 doğruluk oranı ile diğer algoritmalara kıyasla daha düşük bir performans sergilediğini, J48, EYK ve rastgele orman algoritmalarının ise %99,8 doğruluk oranı ile daha yüksek bir doğruluk sağladığını göstermiştir.

Pradeepa ve arkadaşları (2020), numaralı çalışmada, araştırmacılar sosyal medya kaynaklarından elde edilen verileri kullanarak inme ile ilişkili semptomları ve alınacak önlemleri belirlemek için bir metodoloji geliştirmişlerdir. Bu amaçla, spektral kümeleme kullanarak tweet'leri içeriklerine göre iteratif olarak gruplamışlardır. Deneylerde on katlı çapraz doğrulama, NB, DVM ve Olasılıksal Sinir Ağı (OSA) gibi algoritmalar kullanılmıştır. OSA, %89,90 doğruluk oranı ile diğer algoritmalarından daha iyi bir performans sergilemiştir.

Li ve arkadaşları (2019), numaralı çalışmada, LR, NB, Bayes ağı, KA, sinir ağı, rastgele orman, toplanmış KA, oylama ve yükseltme modeli olmak üzere çeşitli MÖ algoritmaları kullanılarak inme risk seviyeleri sınıflandırılmıştır. Araştırma sonuçları, KA'yla oluşturulan yükseltme modelinin %99,94 geri çağırma oranı ile en yüksek performansı gösterdiğini, rastgele orman algoritmasının ise %97,33 kesinlik oranıyla öne çıktığını ortaya koymuştur.

Sailasya ve arkadaşları (2021), araştırmacılar Kaggle platformundan elde edilen bir veri setini kullanmışlardır. Bu çalışmada, LR, KA, ROS, EYK, DVM ve NB gibi çeşitli MÖ algoritmaları uygulanmıştır. NB algoritması, %82 doğruluk oranı ile inme tahmininde diğer algoritmalarından daha iyi bir performans sergilemiştir.

Govindarajan ve arkadaşları (2020), Hindistan'daki Sugam Çok Disiplinli Hastanesi'nden elde edilen bir inme veri seti kullanılmış ve bu veri seti madencilik ve MÖ algoritmaları kullanılarak incelenmiştir. DVM ve toplu (bagged) modeller %91 doğruluk

oranı sağlamış, stokastik gradyan inişi algoritması ile eğitilmiş yapay sinir ağı ise %95'in üzerinde bir sınıflandırma doğruluğu elde ederek diğer algoritmaları geride bırakmıştır.

Nwosu ve arkadaşları (2019), hastaların elektronik sağlık kayıtları analiz edilerek inme tahmini üzerindeki risk faktörlerinin etkisi belirlenmiştir. Elektronik sağlık kayıtları veri seti üzerinde 1000 deney gerçekleştirilmiş ve sinir ağı, KA ile ROS algoritmalarının sırasıyla %75,02, %74,31 ve %74,53 doğruluk oranlarına sahip olduğu bulunmuştur.

Lee ve arkadaşları (2020), difüzyon ağırlıklı görüntüleme ve sıvı baskılanmış ters çevrilmiş iyileşme görüntülerini analiz etmek için MÖ tekniklerinin uygulanabilirliği araştırılmıştır. Araştırma kapsamında, LR, destek vektör makinesi ve random forest kullanılarak üç MÖ modeli geliştirilmiştir. Bu modeller, semptom başlangıcının 4,5 saatten az veya fazla olduğunu ikili sınıflandırma ile tahmin etmek için uygulanmıştır. Modellerin performansı, DWI-FLAIR uyumsuzluğunu insan yorumlamalarıyla kıyaslayan hassasiyet ve özgüllük ölçütleri kullanılarak değerlendirilmiştir.

Özetle, yapılan bu literatür taraması, felç riski tahmini için kullanılan çeşitli MÖ ve YZ tekniklerinin etkinliğini ortaya koymaktadır. Emon ve arkadaşlarının (2020) Ağırlıklı Oylama Algoritması, Singh ve arkadaşlarının (2017) Geri Yayılımlı Sinir Ağı modeli, Sevil'in (2020) ROS yöntemi ve Revanth ve arkadaşlarının (2020) DVM modeli önemli doğruluk oranları rapor etmişlerdir. Bu çalışmalar, farklı tekniklerin ve öznelite seçiminin felç riski tahminindeki önemini vurgulamaktadır.

Literatürde belirtilen bulgular, felç hastalığı tahmini çalışmalarında kullanılan yöntemlerin gücü ve doğruluğu açısından birbirleriyle büyük ölçüde uyumlu sonuçlar sunduğunu göstermektedir. Her bir modelin sunduğu doğruluk oranları, kullanılan veri setlerinin ve uygulanan yöntemlerin kombinasyonlarına bağlı olarak değişiklik göstermektedir. Bu doğrultuda, model seçiminde dikkat edilmesi gereken temel unsurlar veri setinin yapısı, öznelite seçimi ve boyut azaltma teknikleri gibi faktörlerdir.

### 3. YAPAY ZEKA MODELLERİ

YZ, insan zekâsına benzer şekilde bilgisayarların ve diğer cihazların belirli işlevleri gerçekleştirmesini sağlayan bir bilgisayar bilimi dalıdır. Bu teknoloji, insan zihninin bazı özelliklerini taklit etmeye çalışır ve çeşitli uygulamalarda kullanılır. YZ, MÖ, DDİ, bilgi temsili gibi teknolojileri kullanarak karmaşık görevleri yerine getirebilir.

YZ, günümüzde birçok sektörde önemli bir teknoloji haline gelmiştir. İnsan Zekâsının bazı yeteneklerini taklit etmeye yönelik bu teknolojiler, MÖ, DDİ ve bilgi temsili gibi alt dallar aracılığıyla karmaşık görevlerin üstesinden gelmektedir. YZ'nin çeşitli sektörlerdeki kullanım alanları ve gelişim süreci incelenmiştir.

MÖ, YZ'nin bir alt alanı olarak bilgisayarların veri analizi yaparak örüntüleri tanımlamasına ve öğrenmesine olanak tanır (Hastie ve ark., 2009). Bu süreç, algoritmaların verilerdeki belirli desenleri keşfederek gelecekteki tahmin ve kararları iyileştirmelerini içerir.

DDİ, bilgisayarların insan dilini anlama ve işleme yeteneğini kazandıran bir YZ teknolojisidir (Jurafsky ve Martin, 2008). Bu teknoloji, metinlerin ve konuşmaların anlamlarını çözümleyerek çeşitli uygulamalarda kullanılır.

Bilgi temsili, bilgisayarların bilgiyi depolamasını, kullanmasını ve analiz etmesini sağlayan bir diğer YZ teknolojisidir (Russell ve Norvig, 2010). Bu süreç, bilgi yapılarının ve algoritmaların oluşturulmasını kapsar.

YZ teknolojileri, sağlık, endüstri, finans ve otomotiv gibi birçok alanda kullanılmaktadır. Örneğin, sağlık sektöründe tıbbi görüntüleme ve hastalık teşhisinde önemli gelişmeler sağlamıştır (Esteve ve ark., 2017). YZ teknolojisi, endüstriyel üretim süreçlerinde ve kalite kontrolünde ciddi faydalar sunmaktadır. Finans sektöründe ise müşteri davranışlarının analizi ve dolandırıcılık tespiti gibi alanlarda kullanılmaktadır (Ngai ve ark., 2011). Otomotiv alanında YZ, otonom araçların geliştirilmesinde kritik bir rol oynamaktadır (Bojarski ve ark., 2016).

YZ fikri, ilk olarak 1956 yılında Dartmouth Konferansı'nda ortaya atıldı ve John McCarthy, Marvin Minsky, Claude Shannon ve Nathaniel Rochester tarafından tartışıldı (McCorduck, 2004). 1960'larda IBM'in "Watson" programı DDİ alanında büyük ilerlemeler kaydetti. 1970'lerde araştırmalardaki duraklamalara rağmen, 1980'lerde uzman sistemler ve görüntü işleme teknikleri gibi yeni teknolojilerle yeniden canlandı. 1990'ların sonları ve 2000'lerde ise MÖ ve büyük veri analizi gibi alanlarda önemli gelişmeler yaşandı (Russell ve Norvig, 2010).

YZ, geniş bir uygulama yelpazesine sahiptir ve sürekli olarak gelişmektedir. Bu teknoloji, tıp, finans, hukuk, sanat ve diğer birçok alanda insan yaşamını kolaylaştırmak ve daha etkili hale getirmek için kullanılmaktadır (Goodfellow ve ark., 2016). Ancak, YZ'nin kullanımıyla ilgili etik ve güvenlik endişeleri de bulunmaktadır. Örneğin, YZ sistemlerinin bazı kararları henüz insan müdahalesi gerektirmektedir (Müller ve Bostrom, 2016).

YZ, insan zekâsının bilgisayarlar tarafından taklit edilmesi anlamına gelir. Bu teknoloji, MÖ, DDİ ve bilgi temsili gibi alt dallar aracılığıyla çeşitli sektörlerde kullanılabilecek karmaşık görevleri yerine getirebilmektedir. Gelişmeye devam eden bu teknoloji, gelecekte daha fazla alanda daha akıllı çözümler sunarak insan yaşamını kolaylaştıracaktır. Ancak, bu süreçte ortaya çıkabilecek etik ve güvenlik sorunlarına da dikkat edilmelidir.

### 3.1. Yapay Zeka Uygulamaları

#### 3.1.1. Sağlık sektöründe yapay zeka

YZ, sağlık sektöründe geniş bir uygulama yelpazesi bulmuştur. Örnekler şunlardır:

- **Hastalık Tanısı:** YZ, tanı koymada yardımcı olabilir. MÖ algoritmaları, tıbbi görüntüleme verilerini analiz ederek kanser gibi hastalıkların tespitini kolaylaştırabilir (Litjens ve ark., 2017).
- **Tedavi Planlaması:** YZ, hastaların tedavi süreçlerini düzenlemede faydalıdır. Örneğin, hastanın genetik yapısını analiz eden algoritmalar, en etkili tedavi yöntemini belirler (Obermeyer ve Emanuel, 2016).
- **Robotik Cerrahi:** Cerrahi işlemlerde YZ destekli robotlar kullanılarak operasyonların doğruluğu artırılmaktadır (Yang ve ark., 2017).
- **Sağlık Yönetimi:** YZ, sağlık hizmetlerinin yönetimini iyileştirir. Büyük veri analizi, sağlık sektörü eğilimlerini ve hizmetlerin etkinliğini değerlendirir (Esteva ve ark., 2019).
- **Kişiselleştirilmiş Tıp:** YZ, kişiye özel tıbbi bakım sağlar. Hastanın genetik bilgilerine dayalı risk değerlendirmeleri ve tedavi önerileri sunar (Topol, 2019).

- **COVID-19 Pandemisi ile Mücadele:** YZ, COVID-19 salgını ile mücadelede kullanılmıştır. MÖ teknikleri, virüsün yayılımını tahmin eder ve etkili aşı geliştirme süreçlerinde rol oynar (Arora ve ark., 2020).

YZ teknolojilerinin sağlıkta çeşitli uygulamalara sahip olması, bu alanda sürekli yeniliklere rağmen devam eden araştırma ve geliştirme faaliyetlerinden kaynaklanmaktadır.

### 3.1.2. Finans sektöründe yapay zeka

YZ finansal alanda birçok uygulama alanı bulur. Bu alanlar kredi riski yönetimi, varlık fiyatlandırması, portföy yönetimi, müşteri hizmetleri ve dolandırıcılık tespiti içerir. İşte YZ'nin finans sektöründeki bazı uygulama örnekleri:

- **Kredi Riski Yönetimi:** YZ, kredi riski yönetimi modellerinde yaygın olarak kullanılır. Bankalar, müşteri kredi başvurularını değerlendirirken YZ algoritmaları ile müşterinin kredi riskini analiz ederler (Khandanive ark., 2010).
- **Varlık Fiyatlandırması:** Finansal varlıkların fiyatlandırılmasında YZ önemli bir rol oynar. MÖ teknikleri, hisse senetleri ve diğer menkul kıymetlerin fiyatlarını tahmin etmekte kullanılabilir (Guve ark., 2020).
- **Portföy Yönetimi:** YZ, yatırımcılara portföy yönetiminde yardımcı olur. YZ algoritmaları, yatırımcının hedeflerine ve risk toleransına göre en uygun portföyü oluşturabilir (Heaton ve ark., 2017).
- **Müşteri Hizmetleri:** YZ müşteri hizmetlerinde kullanılmaktadır. Bankalar, müşteri sorularını YZ algoritmaları ile yanıtlayabilir ve geri bildirimleri analiz ederek müşteri deneyimini iyileştirebilir (Gentsch, 2018).
- **Dolandırıcılık Tespiti:** Finans sektöründe dolandırıcılığın tespitinde YZ algoritmaları kullanılarak, müşteri hesaplarındaki şüpheli işlemler otomatik olarak tespit edilebilir (Ngai ve ark., 2011).

YZ'nin finans sektöründeki bu çeşitli uygulamaları, yenilikçi finansal hizmetler için sürekli geliştirilmekte ve uygulanmaktadır.

### 3.2. Makine Öğrenmesi Yöntemleri

MÖ, YZ'nin bir alt dalı olarak, bir bilgisayarın belirli bir görevi direkt olarak yerine getirmesi yerine, öğrenme yoluyla performansını artırmasını amaçlar. Bu yöntem, genel olarak veri analizi ve örüntü tanıma ile ilgilenir ve otomatik karar verme, tahmin yapma ve sınıflandırma gibi birçok uygulamada kullanılabilir (Mitchell, 1997).

MÖ, çeşitli algoritmalarla oluşur ve bu algoritmalar model eğitimi ve doğrulama süreçlerinde kullanılır. Algoritmalar verileri analiz ederek örüntüleri ve ilişkileri tanımlar ve bu örüntüler gelecekteki tahminler için kullanılır (Hastie ve ark., 2009). MÖ yöntemleri, veri setlerinde bulunan yapıları tanımlama ve belirleme yetenekleri sayesinde esnek bir yaklaşım sunar. MÖ iki ana kategoriye ayrılabilir:

**Denetimli Öğrenme:** Bu kategoride bir model, belirli bir veri kümesini analiz ederek belirli bir çıktı üretmek için eğitilir. Bu yöntem, genellikle sınıflandırma ve regresyon problemlerini çözmek için kullanılır (Bishop, 2006).

**Denetimsiz Öğrenme:** Bu kategoride ise veri kümesindeki örüntüleri keşfetmek ve verileri doğal bir şekilde kategorize etmek için algoritmalar kullanılır. Bu teknik, özellikle büyük veri setlerindeki gizli yapıların ve örüntülerin ortaya çıkarılmasında etkilidir (Aggarwal ve Reddy, 2013).

MÖ, birçok sektörde yaygın bir kullanım alanı bulmuştur. Örneğin, sağlık sektöründe hastalık teşhisi ve tedavi planlaması için MÖ teknikleri kullanılırken (Esteve ve ark., 2017), finans sektöründe risk analizi, kredi derecelendirme ve alım satım stratejileri oluşturma gibi uygulamalarda kullanılır (Khandani ve ark., 2010). Ayrıca, otomotiv endüstrisinde araçların otomatik sürüş yapmasını sağlamak için MÖ kullanılmaktadır (LeCun ve ark., 2015).

MÖ, YZ alanının hızla gelişen ve gelecekte çok daha geniş uygulama alanlarının keşfedileceği öngörülen bir dalıdır. Bu disiplin, bilgisayarların geçmiş deneyimlerden ve veri kümelerinden öğrenerek belirli görevleri yerine getirebilen modeller oluşturmaya olanak tanıyan algoritma ve teknikler bütünüdür. MÖ'nün tarihsel gelişimi, modern YZ çalışmalarının doğuşuyla ele alınabilir.

İlk adımları 1940'lı yıllarda atılan MÖ alanında, Alan Turing 1950 yılında bilgisayarların düşünebilme kapasitesini sorgulamış ve bu kavramı tanıtmıştır (Turing, 1950). YZ terimi ise 1956 yılında John McCarthy tarafından tanımlanmıştır. Ancak,

1960'larda bilgisayarların mevcut bellek ve işlem kapasitesinin yetersizliği nedeniyle, bu alandaki ilerlemeler sınırlı kalmıştır (McCarthy ve ark., 1956).

1980'lerin sonları ve 1990'ların başlarında, bilgisayarlardaki işlem gücü ve bellek kapasitesinin artmasıyla MÖ alanında yeni bir canlanma yaşanmıştır. Bu dönemde, YSA, genetik algoritmalar, KA ve DVM gibi çeşitli algoritmalar ve teknikler geliştirilmiştir (Haykin, 1998). 2000'lerin başında büyük veri setlerinin ve bulut bilişimin yaygınlaşması, MÖ'ye daha geniş kullanım alanları sağlamıştır (Dean ve Ghemawat, 2004).

Günümüzde, MÖ büyük veri kümeleri, YSA, DÖ, DDİ, tahmin modelleri, öneri sistemleri, görüntü ve ses işleme gibi birçok farklı teknik ve uygulama alanı içermektedir (LeCun ve ark., 2015). Bu teknikler, otomatik tanıma, otomatik çeviri, sınıflandırma, özetleme ve her türlü otomatik sıralama işlemlerinde kullanılmaktadır. Gelişen veri işleme kapasiteleri ve büyük veri setleri sayesinde çağımızda MÖ, önemli bir alan haline gelmiştir.

MÖ algoritmaları denetimli öğrenme, denetimsiz öğrenme ve taklit öğrenme gibi farklı öğrenme türlerine göre sınıflandırılmaktadır. Denetimli öğrenme, etiketli veri setleri kullanarak belirli bir hedef çıktıya ulaşmayı amaçlar. Öte yandan, denetimsiz öğrenme, veri kümesinde herhangi bir etiketin bulunmadığı durumlarda kullanılır. Taklit öğrenme ise, bir insanın ya da başka bir YZ modelinin davranışlarını taklit eden algoritmalar üzerinden çalışır (Russell ve Norvig, 2010).

MÖ; işletmeler, sağlık sektörü, tarım endüstrisi, finans kurumları gibi birçok sektörde geniş uygulama alanlarına sahiptir. Örneğin, müşteri davranışları ve tercihlerinin tahmini, ürün optimizasyonu, tıbbi teşhisler, görüntü işleme, ve daha birçok alanda kullanım bulmaktadır (Kantardzic, 2011).

### 3.3. Yapay Sinir Ağları

YSA, biyolojik sinir ağlarını taklit eden hesaplama modelleridir ve MÖ alanında önemli bir yere sahiptir. YSA'lar, veriler arasındaki karmaşık ilişkileri öğrenebilir ve çeşitli girdilere dayanarak öngörülerde bulunabilir. Bu özellikleri, onları GT, DDİ ve oyun teorisi gibi birçok uygulama alanında oldukça etkili kılar.

YSA, temel olarak katmanlardan oluşur: giriş katmanı, gizli katmanlar ve çıkış katmanı. Giriş katmanı, modelin aldığı veri miktarını temsil ederken, gizli katmanlar

birbirine bağılı nöronlar içerir ve bu bağlantılar öğrenme sürecinde ağırlıklara sahiptir. Çıkış katmanı, modelin tahmin ettiği sonuçları sunar. Her nöron, kendisine gelen sinyalleri toplar, bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana iletir (Haykin, 1999).

YSA'ların eğitim süreci, genellikle denetimli öğrenme metodolojileri kullanılarak gerçekleştirilir. Bu süreçte, model belirli bir hata payına ulaşana dek ağırlıklar güncellenir. Geribildirim, genelde geri yayılım algoritması kullanılarak sağlanır. Bu algoritma, hata sinyalinin ağ üzerinde geriye doğru yayılmasını ve ağırlıkların ayarlanmasını içerir (Rumelhart ve ark., 1986).

YSA'nın yaygın uygulama alanları arasında sağlık, finans ve otomotiv sektörü bulunmaktadır. Örneğin, YSA'lar tıbbi görüntüleri analiz ederek kanser tümörlerini tespit etmede kullanılmakta, finansal piyasalarda borsa tahminleri yapabilmekte ve otonom araçların çevresini algılamasında rol oynamaktadır (LeCun ve ark., 1998).

YSA geleneksel programlama yöntemlerine göre daha karmaşık ve dinamik veri setlerini işleyebilme yeteneği sunmaktadır. Gelecekte, DÖ gibi daha karmaşık YSA mimar ileri ve mimarileri, bu teknolojinin potansiyelini daha da artıracak ve yeni uygulama alanlarının ortaya çıkmasına yol açacaktır. YSA'nın gelişimi, günümüz verimlilik gereksinimlerini karşılamak ve insan hayatını kolaylaştırmak adına önemli bir adım olarak değerlendirilmektedir.

### **3.3.1. Yapay sinir ağları ve veri analizi**

YSA ve veri analizi, birbirleriyle sıkı bir şekilde bağlantılıdır. Veri analizi, veri kümelerinin anlaşılması, özetlenmesi ve keşfedilmesi sürecidir. Verilerin yapısını çözümlmek, aralarındaki ilişkileri belirlemek ve gelecekteki eğilimleri öngörmek amacıyla çeşitli teknikler ve yöntemler kullanılır. YSA, veri analizinde, veri kümelerindeki örüntüleri ve ilişkileri keşfetmek ve tahmin etmek için kullanılan yöntemlerden biridir (Haykin, 2009).

YSA, veri analizinin birçok alanında etkin bir şekilde kullanılmaktadır. Örneğin, finansal veri analizi, tıbbi veri analizi ve pazarlama veri analizi gibi alanlarda verilerin işlenmesi ve analiz edilmesinde önemli rol oynamaktadır. Veri setlerinin özellikleri ve yapıları çeşitlilik gösterdiği için, YSA yöntemleri farklı veri tipleri üzerinde çalışabilecek

şekilde uyarlanmıştır ve her veri türü için en iyi sonuçları sağlayan teknikler kullanılır (Goodfellow ve ark., 2016).

Özellikle büyük veri analizi, YSA'nın önemli bir kullanım alanıdır. Geleneksel yöntemlerin analiz edemeyeceği büyüklükte veri kümelerinde, YSA teknikleri öngörülemeyen örüntüleri ortaya çıkarma ve tahmin yapma konusunda etkili olmaktadır. Büyük veri kümelerinin analizi, işletmelerin pazarlama stratejilerini geliştirmelerine, finansal riskleri azaltmalarına ve sağlık sektöründe hastalıkların tanı ve tedavisinde yardımcı olur (Chen ve ark., 2012).

Sonuç olarak, YSA, veri analizi için güçlü bir araçtır. Veri analizi ile YSA yöntemlerinin birleşimi, örüntü ve eğilimleri keşfetmek için daha kesin ve etkili bir yöntem sunar. Bu nedenle, birçok endüstri ve sektörde YSA ve veri analizi birlikte kullanılmaktadır (Sharda ve ark., 2019).

### 3.4. Derin Öğrenme

DÖ, YSA'ya dayalı MÖ yöntemi olarak öne çıkmaktadır. Bu teknik, büyük veri kümeleri üzerinde yüksek doğrulukta veri işleme ve analiz yapma yeteneği sunar. DÖ algoritmaları, karmaşık veri yapılarını tanımlamak için yüzlerce veya binlerce yapay sinir hücresinden oluşan ağlar kullanır.

DÖ, özellikle resim ve video tanıma, DDİ, oyun oynama ve ses tanıma gibi uygulama alanlarında önemlidir. Aynı zamanda tıp ve biyoloji gibi bilimsel araştırmalar için de oldukça faydalıdır (LeCun ve ark., 2015). Daha az karmaşık algoritmaların yetersiz kaldığı durumlarda DÖ algoritmaları başarılı sonuçlar elde edebilir. Özellikle YSA, daha önceki deneyimlerden öğrenerek yeni verileri analiz etme kabiliyetine sahiptir.

Bu teknikler, genellikle büyük veri setleri ile çalışırken verilerin ön işleme gerektirmez; bu da ağın performansını artırır (Goodfellow ve ark., 2016). Ancak, yüksek miktarda hesaplama kaynağı ve uzun süreli eğitim süreçleri gerektirir. DÖ modelleri, çeşitli YSA türlerini içerir. Örneğin, ESA, resim ve video tanıma için yaygın olarak kullanılırken (Krizhevsky ve ark., 2012), RSA, ses tanıma ve DDİ gibi zamana dayalı veriler için idealdir (Mikolov ve ark., 2010).

## 4. MATERYAL VE YÖNTEM


### 4.1. Kullanılan Makine Öğrenmesi Modelleri

#### 4.1.1. Lojistik regresyon

LR, özellikle iki sınıflı sınıflandırma problemleri için kullanılan temel bir MÖ yöntemidir. Bu algoritma, doğrusal regresyonun genişletilmiş bir versiyonu olarak görülebilir, ancak çıktıyı sınırlamak için lojistik fonksiyon (sigmoid fonksiyon) kullanır (Goldberg, 2017).

LR'nin temelinde yer alan sigmoid fonksiyon, herhangi bir reel sayıyı alır ve bu değeri 0 ile 1 arasında bir olasılık değeri olarak çıkarır. Bunun yanı sıra, LR, olasılıkları tahmin etmekle birlikte bu olasılıkların oranlarını (odds) ve logaritmalarını (log-odds) hesaplar. Bu durum, modelin doğrusal regresyonla elde edilemeyen doğrusal olmayan ilişkileri de modelleyebilmesini sağlar (Zhang ve ark., 1998).

LR, bir sınıflandırma problemi için öncelikle doğrusal kombinasyon adımı ile giriş özelliklerini ağırlıklarla çarpar ve bu ağırlıklı toplamdan (z değeri) elde edilen sonuç, sigmoid fonksiyonuna uygulanarak 0 ile 1 arasında bir olasılık değeri hesaplanır. Elde edilen olasılık değeri belirli bir eşik değeriyle karşılaştırılarak sınıflandırma yapılır. Genellikle, eğer olasılık 0.5'ten büyükse model, sınıfı 1 olarak, aksi takdirde 0 olarak tahmin eder (Huang ve ark., 2018; Wang ve ark., 2021). LR modelinde kullanılan Sigmoid fonksiyonuna ait grafik Şekil 4.1'de gösterilmiştir. Fonksiyonun formülü ise Denklem 4.1'de verilmiştir. Burada Z değerinin artı sonsuza doğru gitmesi halinde, y değeri 1'e yaklaşırken; eksi sonsuza doğru gitmesi durumunda y değeri 0'a yaklaşır. Eğer y değeri 0.5 veya daha büyükse, tahmin 1 olarak kabul edilir; bu değer altında kaldığında ise tahmin 0 olarak değerlendirilir.



Şekil 4.1. LR Modelinde kullanılan sigmoid fonksiyonunun grafiği (Huang ve ark. 2018)

$$S(x) = \frac{1}{(1+e^{a*x})} \quad a = 1 \quad (4.1)$$

LR'nin bazı avantajları bulunmaktadır. Öncelikle, modelin sonuçları ve özelliklerin etkisi kolayca yorumlanabilir. Özellikle log-odds oranları, bağımsız değişkenlerin sınıf üzerindeki etkisini anlamada oldukça kullanışlıdır. Ayrıca, LR hesaplama açısından hızlı ve verimli bir algoritmadır; bu nedenle büyük veri setlerinde bile iyi performans gösterir. Doğru bir şekilde düzenlendiğinde, LR aşırı uydurma (overfitting) riskine karşı dayanıklıdır (Vijayarajeswari ve ark., 2019; Alfian ve ark., 2022; Wang ve ark., 2018).

Ancak, LR'nin bazı dezavantajları da mevcuttur. Bunların başında, sınıflar arasında doğrusal bir ayrım yapma gereksinimi gelir. LR, karmaşık ve doğrusal olmayan sınırları modellemede zorlanabilir. Ayrıca, LR bağımsız değişkenler ile bağımlı değişken arasında doğrusal bir ilişki varsayar. Bu varsayımın karşılanmadığı durumlarda, modelin performansı düşebilir. Özellikle sınıflar arasında büyük bir dengesizlik varsa, LR doğru sonuçlar vermeyebilir (Xu ve ark., 2021).

Aşırı uydurmayı (overfitting) önlemek için LR'de L1 (lasso) ve L2 (ridge) düzenleme teknikleri kullanılabilir. Bu düzenlemeler, modelin ağırlıklarını ceza terimleri ekleyerek düzenler ve modelin genellenebilirliğini artırır. LR, tıbbi tanı, pazarlama ve finansal tahminler gibi çeşitli uygulama alanlarında kullanılır. Tıbbi tanıda hastalık teşhisi gibi ikili sınıflandırma problemlerinde yaygın olarak tercih edilirken, pazarlamada müşteri davranışlarını tahmin etmek ve müşteri kaybı (churn) tahmini gibi alanlarda kullanılır. Finansal uygulamalarda ise kredi riski analizi ve dolandırıcılık tespiti gibi durumlarda sıkça tercih edilmektedir (Mushtaq ve ark., 2020; Assegie, 2021).

#### 4.1.2. K-en yakın komşu

EYK algoritması, MÖ'de kullanılan basit ama güçlü bir sınıflandırma ve regresyon yöntemidir (Harefa ve ark., 2017). Bu algoritma, eğitim verilerini depolayan bir yaklaşım olarak çalışır ve yeni bir veri noktası sınıflandırıldığında, veri noktalarının en yakın komşularına (en yakın K komşusuna) bakarak sınıflandırma yapar (Niwatkar, & Kanse, 2020).

EYK algoritması, yeni bir veri noktasını sınıflandırırken, veri kümesindeki diğer tüm noktalarla arasındaki mesafeyi hesaplar. Bu mesafe genellikle Öklidyen mesafe

(Euclidean distance) kullanılarak ölçülür (Rodrigues, 2018). K değeri, belirlenen komşu sayısını ifade eder. Örneğin, K=3 ise, yeni bir veri noktası en yakın üç komşuya göre sınıflandırılır. K değeri, modelin doğruluğunu doğrudan etkiler ve genellikle çapraz doğrulama (cross-validation) ile optimize edilir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).

EYK algoritması, şu adımlarla çalışır: İlk olarak, yeni bir veri noktası ile mevcut veri noktaları arasındaki mesafe hesaplanır (Eyupoglu, 2018). Ardından, mesafeye göre en yakın K komşu seçilir. Son olarak, en yakın komşuların sınıfı veya ortalama değeri kullanılarak yeni veri noktası tahmin edilir. Sınıflandırma için komşular arasında en sık görülen sınıf seçilirken, regresyonda komşuların ortalama değeri kullanılır (Cherif, 2018; Eyupoglu, 2018).

Bu yöntem genellikle iki ana parametreye ihtiyaç duyar. İlk parametre, en yakın komşuları belirleyen mesafe ölçütüdür. İkinci parametre ise, dikkate alınacak komşu sayısını belirten 'k' değeridir. Bu yöntemin bir dezavantajı, her özelliğe ilişkin mesafe bilgilerinin saklanması için ek bir hafıza gereksinimi doğurmasıdır. Mesafe ölçümü için sıklıkla Öklidyen mesafe kullanılır. Öklid mesafesi, Denklem 4.2'deki formüle göre hesaplanmaktadır. Burada 'p' ve 'q' değişkenleri, özellikleri temsil eder.

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2} \quad (4.2)$$

EYK algoritmasının bazı avantajları vardır. EYK, anlaşılması ve uygulanması kolay bir algoritmadır. Ayrıca, tüm özellikleri kullanır ve önem sıralaması yapmaz; bu nedenle, özellik seçimi gerektirmez. EYK, eğitim sürecinde modeli oluşturmaz; veri noktalarını saklar ve tahminler sırasında işlem yapar. Bu durum, eğitimsiz öğrenme olarak bilinir (Cherif, 2018; Eyupoglu, 2018; Pharswan ve Singh, 2020).

Bununla birlikte, EYK algoritmasının bazı dezavantajları da bulunmaktadır. Tüm eğitim veri setini saklamak ve her tahmin sırasında tüm veri noktaları arasındaki mesafeyi hesaplamak, büyük veri kümelerinde yüksek hesaplama maliyetine yol açabilir. Veri seti büyüdükçe, tahminlerin yavaşlaması ve hafıza gereksinimlerinin artması gibi problemler ortaya çıkabilir. Ayrıca, EYK, mesafe hesaplamalarına dayandığı için özelliklerin farklı ölçeklerde olması performansı etkileyebilir. Bu nedenle, özniteliklerin ölçeklenmesi gerekebilir (Xu ve ark., 2021).


EYK algoritması, çeşitli uygulama alanlarında kullanılabilir. Sınıflandırma problemlerinde, metin sınıflandırma, resim tanıma ve biyometrik tanıma gibi birçok alanda kullanılır. Regresyon problemlerinde, sayısal veri tahmini gereken durumlarda EYK regresyon modelleri kullanılabilir. Ayrıca, EYK, veri kümelerindeki anormal veya olağandışı örneklerin tespitinde de etkili olabilir (Mushtaq ve ark., 2020; Assegie, 2021).

#### 4.1.3. Destek vektör makineleri

DVM, sınıflandırma ve regresyon problemlerinde kullanılan güçlü ve esnek bir MÖ algoritmasıdır (Vijayarajeswari ve ark., 2019). DVM, veri noktalarını sınıflandırmak için en iyi ayırım sınırını (decision boundary) belirlemeye çalışır. Bu algoritma, özellikle yüksek boyutlu veri setlerinde etkili sonuçlar verebilir (Orru ve ark., 2012).

DVM, veriyi sınıflandırmak için bir hiper düzlem kullanır. Bu hiper düzlem, veri noktalarını farklı sınıflara ayıran bir sınırdır. İki sınıf arasındaki en iyi ayrımı sağlayan hiper düzlem, iki sınıfa ait en yakın veri noktalarına (destek vektörlerine) en uzak mesafeye sahip olanıdır. Destek vektörleri, hiper düzleme en yakın veri noktalarıdır ve bu vektörler, hiper düzlemin yönünü ve yerini belirlemede kritik rol oynar. Hiper düzlem ile destek vektörleri arasındaki mesafe, margin olarak adlandırılır. DVM, bu margin'i maksimuma çıkarmaya çalışır ve geniş bir margin, sınıfların daha iyi ayrılmasını sağlar (Abdullah ve Abdulazeez, 2021; Ozer ve ark., 2020).

DVM, Şekil 4.1.de görüldü gibi şu adımlarla çalışır: İlk olarak, DVM, veriyi en iyi ayıran hiper düzlemi bulur. İki sınıf arasındaki en geniş marjı sağlamak için bu hiper düzlem belirlenir. Ardından, hiper düzleme en yakın veri noktaları destek vektörleri olarak tanımlanır ve bu vektörler, sınıflandırma modelinin oluşturulmasında önemli rol oynar. Son olarak, hiper düzlem, destek vektörlerine en uzak mesafeyi sağlamak için optimize edilir (Alfian ve ark., 2022; Huang ve ark., 2017). Sınırının tanımlanmasında kullanılan Denklem 4.3 sayesinde, sınıflandırma sürecinde karşılaşılabilecek sorunları minimize etmeye yardımcı olur. Önyargı (bias) terimi, bu modelde 'b' harfi ile temsil edilmektedir. Denklem 4.4'deki, x ve y değişkenleri öznelilik değerlerini ifade eder ve bu denklemler sayesinde modelin etiketleme işlemi gerçekleştirilir.



Şekil. 4.2. DVM sınıflandırma süreci; a) ikili sınıflandırma, b) çoklu sınıflandırma (Wu ve ark., 2018)

$$u = w * x - b \quad (4.3)$$

$$y_i(w * x_i - b) \geq 1, \forall i \quad (4.4)$$

DVM'nin bazı avantajları vardır. DVM, özellikle yüksek boyutlu veri setlerinde ve karmaşık sınıflandırma problemlerinde yüksek doğruluk sağlayabilir. Ayrıca, margin'in genişliği, aşırı uydurma (overfitting) riskini azaltır ve DVM, küçük ve karmaşık veri setlerinde de etkili sonuçlar verebilir (Ozer ve ark., 2020; Huang ve ark., 2020).

Bununla birlikte, DVM'nin bazı dezavantajları da bulunmaktadır. Büyük veri setlerinde DVM'nin hesaplama maliyeti yüksek olabilir. Özellikle farklı ölçeklerdeki verilerle çalışırken, özelliklerin ölçeklendirilmesi gerekebilir. Ayrıca, DVM'nin performansı, kernel tipi ve C parametresi gibi hiperparametrelere bağlıdır ve bu parametrelerin doğru şekilde ayarlanması önemlidir (Wang ve ark., 2021; Ozer ve ark., 2020).

DVM, doğrusal olarak ayrılabilir olmayan veri kümelerinde kernel fonksiyonları kullanarak veriyi daha yüksek boyutlu bir uzaya dönüştürür. Bu sayede veri, doğrusal olarak ayrılabilir hale gelir. En yaygın kullanılan kernel fonksiyonları arasında lineer kernel, polinomal kernel ve Radial Basis Function (RBF) kernel bulunur. Lineer kernel, doğrusal olarak ayrılabilir veri setleri için uygundur. Polinomal kernel, daha karmaşık veri setlerinde kullanılır ve belirli bir dereceye göre polinom dönüşümü uygular. RBF kernel, veri noktalarını yüksek boyutlu bir uzaya taşır ve genellikle en yaygın kullanılan

kernel fonksiyonudur (Vijayarajeswari ve ark., 2019; Alfian ve ark., 2022; Wang ve ark., 2018).

DVM, birçok uygulama alanında kullanılabilir. Metin sınıflandırma, e-posta spam filtresi ve belge sınıflandırma gibi metin verisi ile ilgili uygulamalarda yaygın olarak kullanılır. Ayrıca, biyometrik tanıma, yüz tanıma ve parmak izi tanıma gibi biyometrik verilerle yapılan sınıflandırma problemlerinde de etkilidir. Genom analizi ve genetik veri analizlerinde ve hastalık teşhislerinde de DVM'nin kullanımı yaygındır (Huang ve ark., 2018; Wang ve ark., 2021).

#### 4.1.4. Karar ağaçları

KA, MÖ ve istatistikte yaygın olarak kullanılan algoritmalar. Bu algoritmalar, ağaç yapısına dayalı olarak karar süreçlerini modelleyerek veriyi bölümlere ayırır ve her bölümü bir karar düğümü ile temsil eder. Bu düğümler, belirli kurallar çerçevesinde sınıflandırma veya tahmin yapmaya yardımcı olur (Abdullah ve Abdulazeez, 2021; Ozer ve ark., 2020).

KA'nın yapısında kök düğüm, tüm veri setini içeren ve ilk bölünmenin yapıldığı ağaçtaki ilk düğümdür. Dahili düğümler, veriyi bir özelliğe göre böler ve bu kararlar doğrultusunda dallar oluşturur. Yaprak düğümler ise sınıflandırma veya regresyon sonucunu temsil eden nihai düğümlerdir (Xu ve ark., 2021).

KA, veri setini özellikler (features) üzerinden bölerek çalışır. Bölünme işlemi, en iyi bölünmeyi bulmak için belirli kriterler kullanılarak yapılır. Sınıflandırma problemlerinde Gini safsızlığı kullanılır ve sınıf karışıklığını ölçer; daha düşük Gini değeri, daha iyi bir bölünmeyi ifade eder. Bilgi kazancı ise entropi kullanılarak hesaplanır ve özelliklerin veri setini ne kadar iyi böldüğünü belirler; daha yüksek bilgi kazancı, daha iyi bir bölünme anlamına gelir (Alfian ve ark., 2022; Huang ve ark., 2017). Çalışmada KA modeli için kullanılan gini ölçütünün matematiksel formülü Denklem 4.5'te verilmiştir. Denklemden,  $p_j$ ,  $j$  sınıfının olasılığını temsil eder. Her sınıf için bu olasılık hesaplandıktan sonra, elde edilen sonuçların karelerinin toplamı çıkarılır. Gini değeri, 0 ile 1 arasında bir değer alır ve sonuç 0'a ne kadar yakınsa, o kadar iyi bir ayırım sağlandığı anlamına gelir.

$$Gini = 1 - \sum_j p_j^2 \quad (4.5)$$

KA'nın bazı avantajları vardır. Ağaç yapısı, kullanıcılar tarafından kolayca anlaşılabilir ve görsel olarak yorumlanabilir. KA, hangi özelliklerin önemli olduğunu otomatik olarak belirler ve hem kategorik hem de sayısal verilerle çalışabilir, ayrıca eksik verileri de yönetebilir. Bu nedenle, veri ön işleme gereksinimi azdır (Vijayarajeswari ve ark., 2019; Alfian ve ark., 2022; Wang ve ark., 2018).

Ancak KA, aşırı uydurma (overfitting) riski taşıyabilir, özellikle büyük ve karmaşık ağaçlarda bu durum sıkça görülür. Bu riski azaltmak için budama (pruning) teknikleri kullanılabilir. Ayrıca, KA, veri setinde yapılan küçük değişikliklere karşı hassas olabilir ve bu durum ağacın yapısında büyük farklılıklara neden olabilir. Özellikle dengesiz veri setlerinde, performans problemleri ortaya çıkabilir (Vijayarajeswari ve ark., 2019).

Aşırı karmaşık ağaçların basitleştirilmesi için budama, bir tekniktir. Bu işlem, ağacın oluşturulması sırasında (ön budama) ya da tamamlandıktan sonra (sonra budama) yapılabilir (Vijayarajeswari ve ark., 2019). KA, müşteri segmentasyonu veya tıbbi teşhis gibi sınıflandırma problemlerinde yaygın olarak kullanılır. Ayrıca, ev fiyat tahmini gibi sayısal değer tahmini gerektiren regresyon problemlerinde de kullanılır. Bunun yanı sıra, KA öneri sistemlerinde, kullanıcı davranışlarına göre önerilerde bulunmak için kullanılabilir (Mushtaq ve ark., 2020; Assegie, 2021; Vijayarajeswari ve ark., 2019).

#### 4.2. Çalışmada Kullanılan Programlama Dili

Python, 1991 yılında Guido van Rossum tarafından geliştirilmiş ve adını Monty Python adlı bir İngiliz komedi grubundan almıştır (Rossum, 1995). Yüksek seviyeli bir programlama dil olan Python, kodun anlaşılması ve yazılması konusunda kolaylık sağlar. Aynı zamanda Nesne Yönelimli Programlama (NYP) ve Fonksiyonel Programlama (FP) özelliklerini destekler (Rossum, 1995).

Python, çeşitli platformlarda çalışabilir ve birçok işletim sistemi tarafından desteklenir. Açık kaynaklı bir dil olan Python, herkesin erişebileceği ve geliştirebileceği ücretsiz bir yazılımdır (Lutz, 2013). Python, veri bilimi, YZ, MÖ, web geliştirme, bilimsel hesaplama gibi çeşitli alanlarda yaygın bir şekilde kullanılmaktadır (Lutz, 2013).

Python programlama dilinin zengin bir kütüphane ekosistemine sahip olması da dikkat çekicidir. NumPy, Pandas, Matplotlib, TensorFlow, PyTorch, Flask ve Django gibi çeşitli kütüphaneler, Python geliştiricilerine geniş bir işlevsellik sunar (McKinney, 2017). Ayrıca, Python, yaygın olarak kullanılan bir betik dili olarak da tercih edilir ve otomatik

görevlerin, sistem yönetimi işlevlerinin ve hızlı prototiplerin oluşturulmasında etkilidir (Beazley, 2009).

### **4.3. Çalışmada Kullanılan Kütüphaneler**

Python dili, geniş kullanım alanı ve çok sayıda kütüphane desteği ile bilinir. Bu kütüphaneler, kullanıcıların çeşitli işlevleri daha hızlı ve etkili bir şekilde gerçekleştirmelerine olanak tanır.

#### **4.3.1. NumPy**

NumPy, özellikle bilimsel ve sayısal hesaplamalar için geniş çapta kullanılan bir Python kütüphanesidir. Bu kütüphane, çok boyutlu diziler ve matrisler üzerinde yüksek performanslı işlemler yapılmasını sağlar. Matematiksel hesaplamalar, fizik ve veri bilimi alanlarında yaygın olarak kullanılmaktadır (Oliphant, 2006).

#### **4.3.2. Pandas**

Pandas, veri manipülasyonu ve analizi için güçlü bir araç olan bir Python kütüphanesidir. Kullanıcıların verilerini kolayca yükleyip temizlemesine, dönüştürmesine ve analiz etmesine imkan tanır. Çeşitli veri kaynaklarından, örneğin CSV, Excel, SQL veritabanları ve HTML dosyalarından veri yüklenebilir ve işlenebilir (McKinney, 2010).

#### **4.3.3. Matplotlib**

Matplotlib, veri görselleştirme için çok kullanılan bir Python kütüphanesidir. Kullanıcıların çeşitli grafik türleri oluşturmalarına olanak tanır; örneğin histogramlar, dağılım grafikleri ve çizgi grafikler gibi. Bu kütüphane, görselleştirme ihtiyaçlarını karşılamak için geniş bir araç seti sunar (Hunter, 2007).

#### **4.3.4. TensorFlow**

TensorFlow, Google tarafından geliştirilen ve geniş bir uygulama yelpazesi sunan açık kaynaklı bir MÖ kütüphanesidir. MÖ modelleri, DÖ ve YSA gibi teknolojiler üzerinde çalışmak için kullanılır (Abadi ve ark., 2016).

#### 4.3.5. Keras

Keras, açık kaynaklı bir DÖ kütüphanesidir ve kullanımı kolay bir arayüz sunar. TensorFlow, Theano ve Microsoft Cognitive Toolkit gibi arka uç kütüphanelerle entegre edilebilen Keras, hızlı prototipleme ve yapay sinir ağı modellerinin eğitimi uygulamaları için sıklıkla tercih edilir (Chollet, 2015).

### 4.4. Model Değerlendirme Parametreleri

Sınıflandırma algoritmalarının performansını değerlendirmek için kullanılan temel metrikler ele alınmaktadır. Performans ölçümü, gerçek ve tahmini sınıf etiketlerinin karşılaştırılmasıyla yapılır ve bu metrikler karmaşıklık matrisi aracılığıyla elde edildiğinden bu süreçte karmaşıklık matrisi önemli bir rol oynar (Polat ve ark., 2017).

Doğru Pozitif (DP), bir modelin, pozitif sınıfa ait bir örneği doğru bir şekilde pozitif olarak sınıflandırdığı durumları ifade eder. Örneğin, hasta olan bir kişiyi gerçekten hasta olarak teşhis etmek, doğru pozitif bir tahmin olarak kabul edilir. Benzer şekilde, Doğru Negatif (DN), negatif sınıfa ait bir örneğin doğru bir şekilde negatif olarak sınıflandırıldığı durumu ifade eder. Örneğin, hasta olmayan bir kişiyi sağlıklı olarak tanımlamak, doğru negatif bir tahmindir. Öte yandan, Yanlış Pozitif (YP), negatif sınıfa ait bir örneğin yanlış bir şekilde pozitif olarak sınıflandırıldığı durumu gösterir. Bu, hasta olmayan bir kişiyi yanlışlıkla hasta olarak teşhis etmek gibi hataları içerir. Yanlış Negatif (YN) ise, pozitif sınıfa ait bir örneğin yanlış bir şekilde negatif olarak sınıflandırılmasıdır; yani hasta olan bir kişinin sağlıklı olarak tanımlanması durumu (Hastie ve ark., 2009).

#### 4.4.1. Doğruluk

Algoritmaların performansını değerlendirmek için kullanılan yaygın bir metrik olan doğruluk (accuracy), modelin doğru sınıflandırdığı örneklerin toplam tahminlere oranını ifade eder. Bu metrik, hem doğru pozitif hem de doğru negatif tahminleri dikkate alır ve 4.6 numaralı formülde gösterildiği gibi hesaplanır:

$$Doğruluk = \frac{TP+TN}{TP+TN+TN+FN} \quad (4.6)$$

Doğruluk metriği, veri setindeki sınıfların dengeli dağılım gösterdiği durumlarda oldukça etkili olabilir. Ancak, sınıf dengesizliğinin olduğu veri setlerinde yanıltıcı sonuçlar verebilir, çünkü nadir olan sınıfların doğru tahmin edilmesi genel doğruluğu fazla etkilemeyebilir (Powers, 2011).

#### 4.4.2. Hassasiyet

Hassasiyet (precision), modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Yani, pozitif tahminlerin doğruluğunu ifade eder ve 4.7 numaralı formülde gösterildiği gibi hesaplanır:

$$Hassasiyet = \frac{TP}{TP+TF} \quad (4.7)$$

Bu metrik, yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda kritik önem taşır. Örneğin, tıbbi teşhislerde, yanlış pozitif sonuçların sayısını minimumda tutmak isteniyorsa, hassasiyet önemli bir değerlendirme kriteri haline gelir (Sokolova ve Lapalme, 2009).

#### 4.4.3. Duyarlılık

Duyarlılık ise, modelin gerçek pozitif örnekleri ne kadar doğru bir şekilde tanımladığını gösterir. Bu metrik, pozitif sınıfa ait örneklerin ne kadarının doğru bir şekilde pozitif olarak tahmin edildiğini ifade eder ve 4.8 numaralı formülde gösterildiği gibi hesaplanır:

$$Duyarlılık = \frac{TP}{TP+FN} \quad (4.8)$$

Duyarlılık, özellikle yanlış negatiflerin maliyetinin yüksek olduğu durumlarda önem kazanır. Örneğin, tıbbi teşhislerde, hastaların hastalıklarını atlamamak için yüksek duyarlılığa sahip bir model tercih edilir (Davis ve Goadrich, 2006).

#### 4.4.4. F1 skoru

F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasını temsil eder ve bu iki metriğin dengeli bir değerlendirmesini sağlar. F1 skoru, özellikle sınıf dengesizliğinin olduğu durumlarda modelin genel performansını değerlendirmek için kullanılır ve 4.9 numaralı formülde gösterildiği gibi hesaplanır:

$$F1\ Skoru = 2 * \frac{Duyarluluk * Kesinlik}{Duyarluluk + Kesinlik} \quad (4.9)$$

Yüksek bir F1 skoru, modelin hem hassasiyet hem de duyarlılık açısından iyi performans gösterdiğini belirtir. Bu metrik, sınıflar arasındaki dengesizliklerin bulunduğu veri setlerinde daha adil bir değerlendirme sunar, çünkü hem yanlış pozitifleri hem de yanlış negatifleri dikkate alır (Chinchor, 1992).

#### 4.5. Veri Seti

Bu çalışmada, Kaggle veri deposundan elde edilen ve bireylerin yaş, cinsiyet, sigara kullanma durumu gibi özelliklerini içeren "Stroke Prediction Dataset (2021)" veri seti kullanılmıştır. Veri seti, felç riskinin sınıflandırılması ve tahmini için kullanılan 10 girdi ve felç durumu etiketlerini içeren 1 çıktı olmak üzere toplamda 11 öznitelikten oluşmaktadır. Aşağıda, bu öznitelikler ve açıklamaları sıralanmıştır

- **Yaş:** Bireyin yaşı. Bu öznitelik sayısal verilerdendir.
- **Cinsiyet:** Bireyin cinsiyetini ifade eder. Bu öznitelik kategorik verilerdendir.
- **Hipertansiyon:** Bireyin hipertansiyon (yüksek tansiyon) hastalığının olup olmaması durumunu ifade eder. Bu öznitelik sayısal verilerdendir (1 – Hipertansiyon var, 0 – Hipertansiyon yok).
- **İş Türü:** Bireyin mesleğini ifade eder. Bu öznitelik kategorik verilerdendir (Örneğin: Devlette çalışıyor, çalışmıyor, serbest meslek).
- **Kalp Hastalığı:** Bireyin kalp hastalığı olup olmadığı bilgisini ifade eder. Bu öznitelik sayısal verilerdendir (0 – Kalp hastalığı yok, 1 – Kalp hastalığı var).
- **Evlilik Durumu:** Bireyin evlilik durumunu ifade eder. Bu öznitelik kategorik verilerdendir (Evet-Hayır).


- **Yaşanılan Bölge:** Bireyin yaşadığı bölgeyi ifade eder. Bu öznitelik kategorik verilerdendir (Kent-Kırsal).
- **Vücut Kitle İndeksi:** Bireyin VKİ bilgisini ifade eder. Bu öznitelik sayısal verilerdendir.
- **Ortalama Glikoz Seviyesi:** Bireyin kanındaki ortalama glikoz seviyesi. Bu öznitelik sayısal verilerdendir.
- **Sigara Kullanma Durumu:** Bireyin sigara kullanma durumu. Bu öznitelik kategorik verilerdendir (Daha önce sigara kullandı, Hala kullanıyor, Hiç kullanmamış).
- **Felç Durumu:** Bireyin daha önce felç geçirip geçirmediği durumunu ifade eder. Bu öznitelik sayısal verilerdendir (1 – Felç geçirdi, 0 – Felç geçirmedi).

Veri kümesi, çeşitli akademik araştırmalarda ve tezlerde kullanılmış olup, felç geçirme riskinin belirlenmesi için oldukça önemli bilgiler içerir. Bu tür veri setleri, sağlık sektöründe erken tanı ve müdahale için YZ ve MÖ modellerinin geliştirilmesinde kritik öneme sahiptir.

## 5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA


### 5.1. Lojistik Regresyon

Şekil 5.1’de verilen LR Modelinin Karmaşıklık Matrisi incelendiğinde DN (693) gerçek negatif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu yüksek bir doğru negatif değeri, modelin negatif sınıfları oldukça iyi tahmin ettiğini gösterir. YP (236) gerçek negatif olanları pozitif olarak tahmin ettiği görülmektedir. Bu, modelin bazı negatif örnekleri yanlışlıkla pozitif olarak tahmin ettiğini gösterir. YN (9) gerçek pozitif olanları negatif olarak tahmin ettiği görülmektedir. Bu, modelin pozitif sınıfları yanlışlıkla negatif olarak tahmin ettiğini ve dolayısıyla pozitif sınıfları kaçırdığını gösterir. DP (44) gerçek pozitif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu, modelin pozitif sınıfları belirlemede başarılı olduğunu gösterir, ancak iyileştirme yapılabilir.



Şekil 5.1. LR Modelinin Karmaşıklık Matrisi


LR modelinin test verisi üzerindeki değerlendirilmesi Şekil 5.2’de verilmiştir. Değerlendirme Matrisi’ne bakıldığında doğruluk oranı %75 olarak hesaplanmıştır.



Şekil 5.2. LR Modelinin Değerlendirme Matrisi


## 5.2. K-En Yakın Komşu

Şekil 5.3'te verilen EYK Modelinin Karmaşıklık Matrisi incelendiğinde incelendiğinde DN (862) gerçek negatif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu yüksek bir doğru negatif değeri, modelin negatif sınıfları iyi tahmin ettiğini gösterir. YP (67) gerçek negatif olanları pozitif olarak tahmin ettiği görülmektedir. Bu, modelin negatif sınıfları pozitif olarak tahmin etmede bazı hatalar yaptığını gösterir. YN (45) gerçek pozitif olanları negatif olarak tahmin ettiği görülmektedir. Bu, modelin pozitif sınıfları yanlışlıkla negatif olarak tahmin ettiğini ve pozitif sınıfları kaçırdığını gösterir. DP (8) gerçek pozitif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu düşük bir doğru pozitif değeri, modelin pozitif sınıfları belirlemede zayıf olduğunu gösterir.



Şekil 5.3. EYK Modelinin Karmaşıklık Matrisi


EYK modelinin test verisi üzerindeki değerlendirilmesi Şekil 5.4'te verilmiştir. Değerlendirme Matrisi'ne bakıldığında EYK modelinin test verisi üzerindeki doğruluk oranı %89 olarak hesaplanarak LR modeline göre daha iyi bir doğruluk tahmini yaptığı görülmüştür.



Şekil 5.4. EYK Modelinin Değerlendirme Matrisi


### 5.3. Destek Vektör Makineleri

Şekil 5.5'te verilen DVM Modelinin Karmaşıklık Matrisi incelendiğinde incelendiğinde DN (780) gerçek negatif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu yüksek bir doğru negatif değeri, modelin negatif sınıfları iyi tahmin ettiğini gösterir. YP (149) gerçek negatif olanları pozitif olarak tahmin ettiği görülmektedir. Bu, modelin bazı negatif örnekleri yanlışlıkla pozitif olarak tahmin ettiğini gösterir. YN (35) gerçek pozitif olanları negatif olarak tahmin ettiği görülmektedir. Bu, modelin bazı pozitif örnekleri yanlışlıkla negatif olarak tahmin ettiğini ve dolayısıyla pozitif sınıfları kaçırdığını gösterir. DP (18) gerçek pozitif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu düşük bir doğru pozitif değeri, modelin pozitif sınıfları belirlemede zayıf olduğunu gösterir.



**Şekil 5.5.** DVM Modelinin Karmaşıklık Matrisi


DVM modelinin test verisi üzerindeki değerlendirilmesi Şekil 5.6’da verilmiştir. Değerlendirme Matrisi’ne bakıldığında DVM modelinin test verisi üzerindeki doğruluk oranı %81 olarak hesaplanmıştır.



**Şekil 5.6.** DVM Modelinin Değerlendirme Matrisi


#### 5.4. Karar Ağaçları

Şekil 5.7’de verilen KA Modelinin Karmaşıklık Matrisi incelendiğinde incelendiğinde DN (888) gerçek negatif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu yüksek bir doğru negatif değeri, modelin negatif sınıfları oldukça iyi tahmin ettiğini gösterir. YP (41) gerçek negatif olanları pozitif olarak tahmin ettiği görülmektedir. Bu, modelin bazı negatif örnekleri yanlışlıkla pozitif olarak tahmin ettiğini gösterir. YN (49) gerçek pozitif olanları negatif olarak tahmin ettiği görülmektedir. Bu, modelin pozitif sınıfları yanlışlıkla negatif olarak tahmin ettiğini ve dolayısıyla pozitif sınıfları kaçırdığını gösterir. DP (4) gerçek pozitif sınıfları doğru bir şekilde tahmin ettiği görülmektedir. Bu düşük bir doğru pozitif değeri, modelin pozitif sınıfları belirlemede oldukça zayıf olduğunu gösterir.



Şekil 5.7. KA Modelinin Karmaşıklık Matrisi

KA modelinin test verisi üzerindeki değerlendirilmesi Şekil 5.8’de verilmiştir. Değerlendirme Matrisi’ne bakıldığında KA modelinin test verisi üzerindeki doğruluk oranı %91 olarak hesaplanmıştır.



Şekil 5.8. KA Modelinin Değerlendirme Matrisi

Bu çalışmada, MÖ modelleri için mevcut değerler korunarak eğitimler gerçekleştirildi. Eğitimlerin sürecinde kullanılan donanımlar şunlardır: Intel(R) Core(TM) i7-10870H CPU @ 2.20GHz CPU, 16 GB RAM ve GPU destekli Nvidia Geforce ekran kartı kullanıldı.

Bu çalışmada, deneysel analizlerin değerlendirilmesinde karmaşıklık matrisi ölçüt olarak seçilmiştir ve bu ölçütte doğruluk, kesinlik, f1-skoru ve geri çağırma gibi metrikler kullanılmıştır.

Bu çalışmada 4 farklı MÖ modeli kullanılarak inme veriseti üzerinde sınıflandırma işlemi yapıldı.

Tablo 5.1. MÖ modellerinden elde edilen karmaşıklık matrislerinin performans parametreleri sonuçları

| MÖ model | Sınıf    | Hassasiyet | Duyarlılık | F1-skor | Doğruluk (%) |
|----------|----------|------------|------------|---------|--------------|
| LR       | Risk Yok | 0.98       | 0.74       | 0.84    | 75,23        |
|          | Risk Var | 0.15       | 0.83       | 0.26    |              |
| EYK      | Risk Yok | 0.95       | 0.92       | 0.92    | 88,83        |
|          | Risk Var | 0.10       | 0.15       | 0.15    |              |
| DVM      | Risk Yok | 0.95       | 0.83       | 0.89    | 81,02        |
|          | Risk Var | 0.10       | 0.33       | 0.16    |              |
| KA       | Risk Yok | 0.94       | 0.95       | 0.95    | 91,02        |
|          | Risk Var | 0.08       | 0.07       | 0.08    |              |

Tablo 1, çalışmada kullanılan MÖ modellerinin "Risk Var" ve "Risk Yok" sınıflarındaki performansını karşılaştırmaktadır. LR modeli, "Risk Yok" sınıfını tanımada yüksek bir hassasiyet göstermektedir. Ancak, hatırlama biraz daha düşük olup, bu durum bazı "Risk Var" vakalarının kaçırılabilceğini göstermektedir. F1-skoru ve genel doğruluk, bu durumu yansıtmaktadır. EYK modeli, "Risk Yok" sınıfı için yüksek bir performans sergilemektedir. Hem hassasiyet hem de hatırlama oldukça yüksek olup, bu model için iyi bir genel doğruluk sağlamaktadır. Ancak, "Risk Var" sınıfında zayıf bir performans sergileyerek, hem hassasiyet hem de hatırlama düşük kalmakta ve bu sınıfı ayırt etmede zorluk yaşandığını göstermektedir. DVM modeli, "Risk Yok" sınıfında çok iyi bir performans ortaya koymaktadır; yüksek F1-skore ve doğruluk değerleri ile dikkat çekmekte, ancak hatırlama biraz daha düşük kalmaktadır. "Risk Yok" sınıfındaki en yüksek performansa sahip olduğu belirtilmektedir; hem hassasiyet hem de hatırlama oldukça yüksek olup, F1-skore mükemmele yakın bir değerdir.

## 6. SONUÇLAR VE ÖNERİLER

### 6.1 Sonuçlar

Bu çalışma, felçle ilişkili risk faktörlerini araştırmıştır. İskemik felçlerin daha yaygın olduğu, hemorajik felçlerin ise daha yüksek mortalite oranlarıyla ilişkilendirildiği bulunmuştur. Erken tanı ve müdahalenin, özellikle trombolitik tedavi ve rehabilitasyonun, hastaların iyileşme sürecindeki kritik rolü vurgulanmıştır.

Çalışma, felç tespiti ve tanısı için makine öğrenimi modelleri kullanarak bir yöntem geliştirmiş ve bu modellerin tıbbi karar destek sistemlerine katkıda bulunduğunu göstermiştir. Modelin doğruluğu %91 olarak bildirilmiştir. Gelecek çalışmalar, farklı MÖ modelleri ve performans metrikleri kullanarak başarıyı artırmayı hedeflemekte; daha etkili özellik seçimi ve veri ön işleme adımlarıyla birlikte geliştirilmelidir.

### 6.2 Öneriler

Felç risk tahmini için ek MÖ modelleri ve gelişmiş tekniklerin araştırılması önerilmektedir.

Gelecek araştırmalar, felç riskini etkileyebilecek diğer ilgili özelliklerin belirlenmesi ve entegrasyonu üzerine odaklanmalıdır. Bu, yeni biyomarkerler, genetik faktörler veya yaşam tarzı değişkenleri entegre edilerek daha kapsamlı modeller oluşturmayı içerebilir.

Model eğitiminde kullanılan verilerin kalitesini ve tutarlılığını sağlamak için titiz veri ön işleme ve temizleme sürecinin önemli olduğu vurgulanmaktadır. Eksik değerler, aykırı değerler ve veri dengesizliği gibi sorunların ele alınması, modelin dayanıklılığını artırmaya yardımcı olacaktır.

Modellerin farklı ve bağımsız veri setlerinde doğrulanmasının önemi de belirtilmiştir. Modelin etkinliğini doğrulamak için çapraz doğrulama teknikleri ve dış doğrulama çalışmaları uygulanmalıdır. Bu, modelin farklı popülasyonlarda genelleştirilebilirliğini ve uygulanabilirliğini sağlamaya yardımcı olacaktır.

Ayrıca, bu öngörücü modellerin, sağlık hizmeti profesyonellerinin felçlerin erken tespiti ve yönetiminde kullanabilecekleri klinik karar destek sistemlerine entegre edilmesi önemlidir. Kullanıcı dostu arabirimler ve karar destek araçları sağlayarak, bu modellerin pratik faydasını artırmak mümkün olacaktır.

Modellerin sürekli olarak yeni veriler ve araştırma bulgularıyla güncellenmesi, onların geçerliliği ve doğruluğunu korumak için hayati bir gerekliliktir. Gerçek dünya performansına dayalı sürekli izleme ve yinelemeli iyileştirmeler, hasta sonuçlarını daha iyi hale getirmek için katkıda bulunacaktır.

Bu önerileri ele alarak, felç risk tahmin modellerinin doğruluğu ve etkisi daha da artırılabilir; bu da daha etkili önleme ve yönetim stratejilerine yol açabilir. Özellikle felç gibi hayati tehdit eden durumlarda, erken tanı ve tedavi süreçlerinin geliştirilmesi, hastaların yaşam kalitesini temelde yükseltebilir ve komplikasyon riskini azaltabilir.

Sonuç olarak, bu çalışma, felç risk faktörlerinin anlaşılmasının ve makine öğrenimi modellerinin, tıbbi uygulamalarda nasıl entegre edilebileceğinin önemine dikkat çekmekte ve gelecek araştırmalara yön vermektedir.

## KAYNAKLAR

- Abdullah, D. M., & Abdulazeez, A. M., 2021, Machine Learning Applications based on SVM Classification A Review, *Qubahan Academic Journal*, 1(2), 81-90.
- Abunasser, B. S., AL-Hiealy, M. R. J., Zaqout, I. S., & Abu-Naser, S. S., 2022, Breast cancer detection and classification using deep learning Xception algorithm, *International Journal of Advanced Computer Science and Applications*, 13(7).
- Adams, R. D., Victor, M., & Ropper, A. H. 2013. *Principles of Neurology*. McGraw-Hill Education.
- Aggarwal, C. C., & Reddy, C. K. 2013. Data clustering: *Algorithms and applications*. CRC Press.
- Agnes, S. A., Anitha, J., Pandian, S. I. A., & Peter, J. D., 2020, Classification of mammogram images using multiscale all convolutional neural network (MA-CNN), *Journal of medical systems*, 44, 1-9.
- Alexandrov, A. V., & Sloan, M. A. 2002. Transcranial Doppler: Current and potential clinical applications. *American Journal of Neuroradiology*, 23(3), 338-344.
- Alfian, G., Syafrudin, M., Fahrurrozi, I., Fitriyani, N. L., Atmaji, F. T. D., Widodo, T., & Rhee, J., 2022, Predicting breast cancer from risk factors using SVM and extra-trees-based feature selection method, *Computers*, 11(9), 136.
- Alpert, J. S., Thygesen, K., & Antman, E. 2014. Myocardial infarction redefined - A consensus document of the joint European society of cardiology/American college of cardiology committee for the redefinition of myocardial infarction. *Journal of the American College of Cardiology*, 36(3), 959-969.
- American Diabetes Association. 2015. Standards of medical care in diabetes—2015 abridged for primary care providers. *Clinical Diabetes*, 33 (2), 97-111.
- American Heart Association. 2020. Heart Disease and Stroke Statistics—2020 Update: A Report From the American Heart Association. *Circulation*, 141(9), e139-e596.
- Aronson, J. K. (Ed.). 2016. Meyler's Side Effects of Drugs: *The International Encyclopedia of Adverse Drug Reactions and Interactions* (16th ed.). Elsevier.
- Arora, P., Boyne, D. J., Slater, J. J., Gupta, A., & Brenner, D. R. 2020. The use of machine learning methods to predict COVID-19 vaccine hesitancy: A rapid systematic review. *Vaccines*, 8(2), 1-20.
- Assegie, T. A., 2021, An optimized K-Nearest Neighbor based breast cancer detection,

- Journal of Robotics and Control (JRC)*, 2(3), 115-118.
- Assegie, T. A., 2021, An optimized K-Nearest Neighbor based breast cancer detection, *Journal of Robotics and Control (JRC)*, 2(3), 115-118.
- Beazley, D. 2009. *Python Essential Reference*. Addison-Wesley Professional.
- Benjamin, E. J., Blaha, M. J., Chiuve, S. E., Cushman, M., Das, S. R., Deo, R., ... & Muntner, P. 2019. Heart disease and stroke statistics—2019 update: a report from the American Heart Association. *Circulation*, 139(10), e56-e528.
- Bertsimas, D., & Kallus, N. 2019. From predictive to prescriptive analytics. *Management Science*, 66(3), 1025-1044.
- Bishop, C. M. 2006. *Pattern recognition and machine learning*. Springer.
- Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., ... & Zhang, X. 2016. End to end learning for self-driving cars. *arXiv preprint arXiv:1604.07316*.
- Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., ... & Zhang, X. 2016. End to end learning for self-driving cars. *arXiv preprint arXiv:1604.07316*.
- Botlagunta, M., Botlagunta, M. D., Myneni, M. B., Lakshmi, D., Nayyar, A., Gullapalli, J. S., & Shah, M. A., 2023, Classification and diagnostic prediction of breast cancer metastasis on clinical data using machine learning algorithms, *Scientific Reports*, 13(1), 485.
- Brown, A., & Jones, 2019. Physical therapy for stroke patients: A review of current practices. *Physical Therapy Journal*, 15(2), 76-89.
- Chen, H., Chiang, R. H. L., & Storey, V. C. 2012. Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165-1188.
- Chen, H., Chiang, R. H., & Storey, V. C. 2012. Business intelligence and analytics: From big data to big impact. *MIS Quarterly*, 36(4), 1165-1188.
- Cheon, S., Kim, J., & Lim, J. 2019. The use of deep learning to predict stroke patient mortality. *International Journal of Environmental Research and Public Health*, 16(11), 1-12.
- Cherif, W., 2018, Optimization of K-NN algorithm by clustering and reliability coefficients: application to breast-cancer diagnosis, *Procedia Computer Science*, 127, 293-299.
- Chinchor, N. 1992. MUC-4 Evaluation Metrics. In *Proceedings of the 4th Conference on Message Understanding* (pp. 22-29).

- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. 2014. Learning phrase representations using RSA encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Chowdhury, R., Stevens, S., Gorman, D., Pan, A., Warnakula, S., Chowdhury, S., ... & Hu, F. B. 2012. Association between fish consumption, long chain omega 3 fatty acids, and risk of cerebrovascular disease: systematic review and meta-analysis. *BMJ*, 345, e6698.
- Connolly, E. S., Rabinstein, A. A., Carhuapoma, J. R., & Derdeyn, C. P. 2012. Guidelines for the management of aneurysmal subarachnoid hemorrhage. *Stroke*, 43(6), 1711-1737.
- Çalışkan, A., 2023a, Detecting human activity types from 3D posture data using deep learning models, *Biomedical Signal Processing and Control*, 81, 104479.
- Çalışkan, A., 2023b, Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network, *Transactions of the Institute of Measurement and Control*, 45(5), 975-985.
- Dargan, S., Kumar, M., Ayyagari, M. R., & Kumar, G., 2020, A survey of deep learning and its applications: a new paradigm to machine learning, *Archives of Computational Methods in Engineering*, 27(4), 1071-1092.
- Davis, J., & Goadrich, M. 2006. The relationship between Precision-Recall and ROC curves. In *Proceedings of the 23rd International Conference on Machine Learning* (pp. 233-240).
- Dean, J., & Ghemawat, S. 2004. MapReduce: Simplified Data Processing on Large Clusters. *Proceedings of the 6th Symposium on Operating Systems Design & Implementation*, 137-150.
- Delen, D., & Zolbanin, H. M. 2018. The analytics paradigm in business research. *Journal of Business Research*, 90, 186-195.
- Dominique, C., Callonnec, F., Berghian, A., Defla, D., Vera, P., Modzelewski, R., & Decazes, P., 2022, Deep learning analysis of contrast-enhanced spectral mammography to determine histoprognostic factors of malignant breast tumours, *European radiology*, 1-11.
- Donnan, G. A., Fisher, M., Macleod, M., & Davis, S. M. 2008. Basic concepts in neuroimaging. *Journal of Neuroimaging*, 18(3), 245-256.
- Donnan, G. A., Fisher, M., Macleod, M., & Davis, S. M. 2008. Stroke. *The Lancet*, 371(9624), 1612-1623. Mayo Clinic. 2020.

- Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S., & Dehmer, M., 2020, An introductory review of deep learning for prediction models with big data, *Frontiers in Artificial Intelligence*, 3, 4.
- Emon, M. U., Keya, M. S., Meghla, T. I., Rahman, M. M., Al Mamun, S., & Kaiser, M. S. 2020. Performance analysis of machine learning. In *Fourth International Conference on Electronics, Communication and Aerospace Technology (ICECA)* (pp. 1464-1469). Coimbatore, India.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... & Dean, J. 2019. A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24-29.
- Eyupoglu, C., 2018, Breast cancer classification using k-nearest neighbors algorithm, *The Online Journal of Science and Technology*, 8(3), 29-34.
- Fatima, N., Liu, L., Hong, S., & Ahmed, H., 2020, Prediction of breast cancer, comparative review of machine learning techniques, and their analysis, *IEEE Access*, 8, 150360-150376.
- Feigin, V. L., Norrving, B., & Mensah, G. A. 2017. *Atlas of the Global Burden of Stroke*. World Health Organization.
- Fuster, V., Rydén, L. E., Cannom, D. S., Crijns, H. J., Curtis, A. B., Ellenbogen, K. A., ... & Halperin, J. L. 2011. ACC/AHA/ESC 2006 guidelines for the management of patients with atrial fibrillation executive summary. *Journal of the American College of Cardiology*, 48(4), 854-906.
- Gentsch, P. 2018. AI in marketing, sales and service: *How marketers without a data science degree can use AI, big data and bots*. Springer Nature Switzerland AG.
- Gillen, G. 2016. *Stroke rehabilitation: A function-based approach*. Elsevier Health Sciences.
- Goldberg, Y. 2017. Neural network methods for natural language processing. *Synthesis Lectures on Human Language Technologies*, 10(1), 1-309.
- Goldstein, L. B., Bushnell, C. D., Adams, R. J., Appel, L. J., Braun, L. T., Chaturvedi, S., ... & Thom, T. 2011. Guidelines for the primary prevention of stroke: a guideline

- for healthcare professionals from the American Heart Association/American Stroke Association. *Stroke*, 42(2), 517-584.
- Goldstein, L. B., Bushnell, C. D., Adams, R. J., Appel, L. J., Braun, L. T., Chaturvedi, S., ... & Thom, T. 2006.
- Gorelick, P. B. 2019. Risk factors for vascular dementia and Alzheimer disease. *Stroke*, 50(1), 1-15.
- Govindarajan, P., Soundarapandian, R. K., Gandomi, A. H., Patan, R., Jayaraman, P., & Manikandan, R. 2020. Classification of stroke disease using machine learning algorithms. *Neural Computing and Applications*, 32, 817-828.
- Grundy, S. M., Stone, N. J., Bailey, A. L., Beam, C., Birtcher, K. K., Blumenthal, R. S., ... & Yeboah, J. 2019. 2018
- Gupta, S., Davis, M., & Patel, R. 2020. The role of laboratory tests in the diagnosis and management of stroke. *Journal of Stroke and Cerebrovascular Diseases*, 28(6), 832-845.
- Guve, S., Kelly, B., & Xiu, D. 2020. Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hamed, G., Marey, M. A. E. R., Amin, S. E. S., & Tolba, M. F. 2020. Deep learning in breast cancer detection and classification. In *The International Conference on Artificial Intelligence and Computer Vision*, Springer, Cham, 322-333.
- Hankey, G. J. 2017. Stroke. *The Lancet*, 389(10069), 641-654.
- Harefa, J., Alexander, A., & Pratiwi, M., 2017, Comparison classifier: support vector machine (DVM) and K-nearest neighbor (K-NN) in digital mammogram images, *Jurnal Informatika dan Sistem Informasi*, 2(2), 35-40.
- Hastie, T., Tibshirani, R., & Friedman, J. 2009. The elements of statistical learning: *Data mining, inference, and prediction*. Springer.
- Haykin, S. 1998. *Neural Networks: A Comprehensive Foundation* (2nd Edition). Prentice Hall.
- Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*. Prentice Hall.
- Heaton, J. B., Polson, N. G., & Witte, J. H. 2017. Deep learning for finance: deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3-12.

- Hochreiter, S., & Schmidhuber, J. 1997. Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Howard, G., Banach, M., Cushman, M., Goff Jr, D. C., Howard, V. J., Lackland, D. T., ... & Libby, P. 2020. Heart disease and stroke statistics—2020 update: A report from the American Heart Association. *Circulation*, 141(9), e139-e596.
- Huang, M. W., Chen, C. W., Lin, W. C., Ke, S. W., & Tsai, C. F., 2017, SVM and SVM ensembles in breast cancer prediction, *PloS one*, 12(1), e0161501.
- Huang, P., 2020, An integrated approach to ultrasound imaging in medicine and biology, *BIO Integration*, 1(3), 105-109.
- Huang, S., Cai, N., Pacheco, P. P., Narrandes, S., Wang, Y., & Xu, W., 2018, Applications of support vector machine (SVM) learning in cancer genomics, *Cancer genomics & proteomics*, 15(1), 41-51.
- Ibrokhimov, B., & Kang, J. Y., 2022, Two-Stage Deep Learning Method for Breast Cancer Detection Using High-Resolution Mammogram Images, *Applied Sciences*, 12(9), 4616.
- Jauch, E. C., Saver, J. L., Adams, H. P., Bruno, A., Connors, J. J. B., Demaerschalk, B. M., ... & Yonas, H. 2013. Guidelines for the early management of patients with acute ischemic stroke: a guideline for healthcare professionals from the American Heart Association/American Stroke Association. *Stroke*, 44(3), 870-947.
- Johnson, C. 2017. Speech therapy for stroke recovery. *Journal of Communication Disorders*, 20(4), 189-201.
- Johnston, S. C. 2000. Transient ischemic attack. *New England Journal of Medicine*, 343(7), 574-580.
- Jones, E. L., Miller, K., & White, J. 2019. Importance of prompt medical attention in cases of stroke. *Journal of Emergency Medicine*, 15(2), 309-321.
- Jones, H., Smith, R., & Brown, J. 2021. The efficacy of Doppler ultrasound in the diagnosis of cerebrovascular conditions. *Journal of Clinical Neurology*, 18(3), 245-258.
- Jones, H., Smith, R., & Doe, J., 2020. The application of diffusion-weighted MRI in early stroke detection. *Journal of Medical Imaging*, 62(4), 345-356.
- Jurafsky, D., & Martin, J. H. 2008. *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition*. Pearson Prentice Hall.

- Kantardzic, M. 2011. *Data Mining: Concepts, Models, Methods, and Algorithms* (2nd Ed.). Wiley-IEEE Press.
- Khandani, A. E., Kim, A. J., & Lo, A. W. 2010. Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767-2787.
- Kidwell, C. S., & Warach, S. 2003. Acute ischemic cerebrovascular syndrome: diagnostic criteria. *Stroke*, 34(12), 2997-3001.
- Kligfield, P., Gettes, L. S., & Bailey, J. J. 2020. Recommendations for the standardization and interpretation of the electrocardiogram. *Journal of the American College of Cardiology*, 51(4), 944-951.
- Koh, J., Yoon, Y., Kim, S., Han, K., & Kim, E. K., 2022, Deep learning for the detection of breast cancers on chest computed tomography, *Clinical Breast Cancer*, 22(1), 26-31.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2012. ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (pp. 1097-1105).
- Langhorne, P., Bernhardt, J., & Kwakkel, G. 2011. Stroke rehabilitation. *The Lancet*, 377(9778), 1693-1702.
- LeCun, Y., Bengio, Y., & Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- LeCun, Y., Bengio, Y., & Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436-444.
- Lee, H., Lee, E. J., Ham, S., Lee, H. B., Lee, J. S., Kwon, S. U., Kim, J. S., Kim, N., & Kang, D. W. 2020. Machine learning approach to identify stroke within 4.5 hours. *Stroke*, 51(3), 860-866.
- Lerman, A., & Zeiher, A. M. 2010 Lerman, A., & Zeiher, A. M. 2010. Endothelial function: Cardiac events. *Circulation*, 111(3), 363-368.
- Li, X., Bian, D., Yu, J., Li, M., & Zhao, D. 2019. Using machine learning models to improve stroke risk level classification methods of China national stroke screening. *BMC Medical Informatics and Decision Making*, 19, 1-7.
- Liebeskind, D. S. 2015. Imaging the future of stroke: How recent advances in technology are shaping diagnosis and treatment. *Stroke Journal*, 46(4), 1076-1081.

- Lincoln, N. B., & Flannaghan, T. 2013. *The management of stroke patients*. Oxford University Press.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & van Ginneken, B. 2017. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & van Ginneken, B. 2017. A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Lutz, M. 2013. *Learning Python*. O'Reilly Media.
- Madani, M., Behzadi, M. M., & Nabavi, S., 2022, The role of deep learning in advancing breast cancer detection using different imaging modalities: A systematic review, *Cancers*, 14(21), 5334.
- Mahmood, T., Li, J., Pei, Y., Akhtar, F., Imran, A., & Rehman, K. U., 2020, A brief survey on breast cancer diagnostic with deep learning schemes using multi-image modalities, *IEEE Access*, 8, 165779-165809.
- Marler, J. R., Price, T. R., & Clark, G. L. 2000. The role of blood tests in determining stroke causes. *Journal of Neurology*, 47(3), 259-267.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. 1956. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI Magazine*, 27(4), 12-14.
- McCorduck, P. 2004. *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. AK Peters/CRC Press.
- McCulloch, W. S., & Pitts, W. H. 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- McKinney, W. 2017. *Python for Data Analysis*. O'Reilly Media.
- Meschia, J. F., Bushnell, C., Boden-Albala, B., Braun, L. T., Bravata, D. M., Chaturvedi, S., ... & Wilson, J. A. 2014. Guidelines for the primary prevention of stroke: A statement for healthcare professionals from the American Heart Association/American Stroke Association. *Stroke*, 45(12), 3754-3832.
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., & Khudanpur, S. 2010. Recurrent neural network based language model. In *Eleventh Annual Conference of the International Speech Communication Association*.

- Miller, E. L., Murray, L., Richards, L., Zorowitz, R. D., Bakas, T., Clark, P., ... & American Heart Association Stroke Council. 2010. Comprehensive overview of nursing and interdisciplinary rehabilitation care of the stroke patient: A scientific statement from the American Heart Association. *Stroke*, 41(10), 2402-2448.
- Mitchell, T. M. 1997. *Machine learning*. McGraw-Hill.
- Mohamed, A., Amer, E., Eldin, N., Hossam, M., Elmasry, N., & Adnan, G. T., 2022, The impact of data processing and ensemble on breast cancer detection using deep learning, *Journal of Computing and Communication*, 1(1), 27-37.
- Morgenstern, L. B., Hemphill, J. C., Anderson, C., & Becker, K. 2010. Guidelines for the management of spontaneous intracerebral hemorrhage. *Stroke Journal*, 41(9), 2108-2129.
- Mozaffarian, D., Benjamin, E. J., Go, A. S., Arnett, D. K., Blaha, M. J., Cushman, M., ... & Howard, V. J. 2016. Heart disease and stroke statistics—2016 update: a report from the American Heart Association. *Circulation*, 133(4), e38-e360.
- Mushtaq, Z., Yaqub, A., Sani, S., & Khalid, A., 2020, Effective K-nearest neighbor classifications for Wisconsin breast cancer data sets, *Journal of the Chinese Institute of Engineers*, 43(1), 80-92.
- Müller, V. C., & Bostrom, N. 2016. Future progress in artificial intelligence: A survey of expert opinion. *Fundamental issues of artificial intelligence*, 555-572.
- Nassif, A. B., Talib, M. A., Nasir, Q., Afadar, Y., & Elgendy, O., 2022, Breast cancer detection using artificial intelligence techniques: A systematic literature review, *Artificial Intelligence in Medicine*, 102276.
- Ngai, E. W., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. 2011. The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision Support Systems*, 50(3), 559-569.
- Niwatkar, A., & Kanse, Y. K., 2020, Feature Extraction using Wavelet Transform and Euclidean Distance for speaker recognition system, *In 2020 International Conference on Industry 4.0 Technology (I4Tech)*, IEEE, 145-147.
- Nwosu, C. S., Dev, S., Bhardwaj, P., Veeravalli, B., & John, D. 2019. Predicting stroke from electronic health records. In *Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 5704-5707). IEEE.

- Obermeyer, Z., & Emanuel, E. J. 2016. Predicting the future—big data, machine learning, and clinical medicine. *The New England Journal of Medicine*, 375(13), 1216-1219.
- Orru, G., Pettersson-Yeo, W., Marquand, A. F., Sartori, G., & Mechelli, A., 2012, Using support vector machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review, *Neuroscience & Biobehavioral Reviews*, 36(4), 1140-1152.
- Ozer, M. E., Sarica, P. O., & Arga, K. Y., 2020, New machine learning applications to accelerate personalized medicine in breast cancer: rise of the support vector machines, *Omics: a journal of integrative biology*, 24(5), 241-246.
- Peters, S. A., Huxley, R. R., & Woodward, M. 2013. Smoking as a risk factor for stroke in women compared with men: a systematic review and meta-analysis of 81 cohorts, including 3 980 359 individuals and 42 401 strokes. *Stroke*, 44(10), 2821-2828.
- Pezzella, F. R., Anderson, K. F., & Breen, T. F. 2005. Stroke rehabilitation: *A function-based approach*. Butterworth-Heinemann.
- Pharswan, R., & Singh, J., 2020, Performance Analysis of DVM and KNN in Breast Cancer Classification: A Survey, *In Internet of Things and Big Data Applications*, Springer, Cham, 133-140.
- Polat, K., Güneş, S., & Arslan, A. 2017. A cascade learning system for classification of cancer types based on gene expression data. *Journal of Biomedical Informatics*, 40(1), 151-159.
- Powers, D. M. W. 2011. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Powers, W. J., Rabinstein, A. A., Ackerson, T., Adeoye, O. M., Bambakidis, N. C., Becker, K., ... & Tirschwell, D. L. 2018. 2018 guidelines for the early management of patients with acute ischemic stroke: A guideline for healthcare professionals from the American Heart Association/American Stroke Association. *Stroke*, 49(3), e46-e110.
- Pradeepa, S., Manjula, K., Vimal, S., Khan, M. S., Chilamkurti, N., & Luhach, A. K. 2020. DRFS: Detecting risk factor of stroke disease from social media using machine learning techniques. *Neural Processing Letters*, 2020, 1-19.

- Prospective Studies Collaboration. 2007. Blood cholesterol and vascular mortality by age, sex, and blood pressure: a meta-analysis of individual data from 61 prospective studies with 55,000 vascular deaths. *The Lancet*, 370(9602), 1829-1839.
- Provost, F., & Fawcett, T. 2013. Data Science and its Relationship to Big Data and Data-Driven Decision Making. *Big Data*, 1(1), 51-59.
- Qureshi, A. I., Mendelow, A. D., & Hanley, D. F. 2017. Intracerebral haemorrhage. *Lancet*, 373(9675), 1632-1644.
- Qureshi, N., Smith, J., Brown, A., & Taylor, R. 2009. Emerging trends in medical research. *Journal of Medical Studies*, 34(2), 123-130.
- Raaj, R. S., 2023, Breast cancer detection and diagnosis using hybrid deep learning architecture, *Biomedical Signal Processing and Control*, 82, 104558.
- Revanth, S., Sanjay, S., Sanjay, N., & Vijagayaganth, V. 2020. Stroke prediction using machine learning algorithms. *International Journal of Disaster Recovery and Business Continuity*, 11(1), 3081-3086.
- Reynolds, K., Lewis, B., Nolen, J. D., Kinney, G. L., Sathya, B., & He, J. 2003. Alcohol consumption and risk of stroke: A meta-analysis. *JAMA*, 289(5), 579-588.
- Rodrigues, É. O., 2018, Combining Minkowski and Chebyshev: New distance proposal and survey of distance metrics using k-nearest neighbours classifier, *Pattern Recognition Letters*, 110, 66-71.
- Roger, V. L., Go, A. S., Lloyd-Jones, D. M., Adams, R. J., Berry, J. D., Brown, T. M., ... & American Heart Association Statistics Committee and Stroke Statistics Subcommittee. 2011. Heart disease and stroke statistics—2011 update: A report from the American Heart Association. *Circulation*, 123(4), e18-e209.
- Rogers, C. A., Stevenson, M., & Lloyd-Jones, D. M. 2019. A meta-analysis of the association between overall lower cholesterol levels and mortality outcomes in ischemic heart disease. *European Heart Journal*, 25(3), 254-261.
- Rosenblatt, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rossum, G. V. (1995). *Python Reference Manual*. Python Software Foundation.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Russell, S., & Norvig, P. 2010. Artificial intelligence: *A modern approach*. Prentice Hall.

- Sailasya, G., & Kumari, G. L. A. 2021. Analyzing the performance of stroke prediction using ML classification algorithms. *International Journal of Advanced Computer Science and Applications*, 12(6).
- Sevli, O. 2021. İnme (felç) riskinin makine öğrenmesi kullanılarak tespiti. In 7. *Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi (7th International Congress on Engineering, Architecture and Design)* (pp. 661-667). İstanbul, Türkiye.
- Shahidi, F., Daud, S. M., Abas, H., Ahmad, N. A., & Maarop, N., 2020, Breast cancer classification using deep learning approaches and histopathology image: a comparison study, *Ieee Access*, 8, 187531-187552.
- Sharda, R., Delen, D., & Turban, E. 2019. *Business intelligence, analytics, and data science: A managerial perspective*. Pearson.
- Shoily, T. I., Islam, T., Jannat, S., Tanna, S. A., Alif, T. M., & Ema, R. R. 2019. Detection of stroke disease using machine learning algorithms. In *Proceedings of the 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)* (pp. 1-6). IEEE.
- Singh, M. S., & Choudhary, P. 2017. Stroke prediction using artificial intelligence. In *8th Annual Industrial Automation and Electromechanical Engineering Conference (IEMECON)* (pp. 158-161). Bangkok, Thailand.
- Smith, A. B., & Brown, J. E. 2018. Applications of Doppler ultrasound in cerebrovascular diagnosis. *Stroke Research and Treatment*, 2018.
- Smith, A. B., & Doe, J. E. 2019. The role of magnetic resonance angiography in detecting intracranial vascular conditions. *Stroke Research and Treatment*, 2019, Article ID 524167.
- Smith, A. B., Doe, J. E., & Wilson, L. 2018. Advanced neuroimaging: Techniques and applications in stroke diagnosis. *Journal of Clinical Imaging*, 12(2), 45-60.
- Smith, A. L., Johnson, B. E., & Brown, C. D. 2018. Laboratory testing in the evaluation and management of ischemic stroke. *Journal of Neurology and Neuroscience*, 12(3), 157-169.
- Smith, J. 2018. Stroke treatment methods. *Journal of Neurology*, 25(3), 123-135.
- Sokolova, M., & Lapalme, G. 2009. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.

- Steiner, T., Bösel, J., Hacke, W., & Schwab, S. 2013. Outcome of hemicraniectomy in malignant middle cerebral artery infarction. *Neurology*, 80(20), 1901-1907.
- Strazzullo, P., D'Elia, L., Kandala, N. B., & Cappuccio, F. P. 2010. Salt intake, stroke, and cardiovascular disease: Meta-analysis of prospective studies. *BMJ*, 339, b4567.
- Stroke Prediction Dataset. 2022. <https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>. [Erişim Tarihi: 01.02.2024]
- Teasell, R., Hussein, N., Foley, N., & Meyer, M. 2010. Evidence-based review of stroke rehabilitation: Executive summary, 12th edition. *Topics in Stroke Rehabilitation*, 21(6), 431-439.
- Topol, E. J. 2019. Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. Basic Books.
- Topol, E. J. 2019. High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56.
- Tukey, J. W. 1977. *Exploratory data analysis*. Addison-Wesley.
- Turing, A. M. 1950. Computing Machinery and Intelligence. *Mind*, 59(236), 433-460
- Vaka, A. R., Soni, B., & Reddy, S., 2020, Breast cancer detection by leveraging Machine Learning, *ICT Express*, 6(4), 320-324.
- Vijayarajeswari, R., Parthasarathy, P., Vivekanandan, S., & Basha, A. A., 2019, Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform, *Measurement*, 146, 800-805.
- Waller, M. A., & Fawcett, S. E. 2013. Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77-84.
- Wang, H., Zheng, B., Yoon, S. W., & Ko, H. S., 2018, A support vector machine-based ensemble algorithm for breast cancer diagnosis, *European Journal of Operational Research*, 267(2), 687-699.
- Wang, P., Fan, E., & Wang, P., 2021, Comparative analysis of image classification algorithms based on traditional machine learning and deep learning, *Pattern Recognition Letters*, 141, 61-67.
- Wang, Y., Ge, X., Ma, H., Qi, S., Zhang, G., & Yao, Y., 2021, Deep learning in medical ultrasound image analysis: a review, *IEEE Access*, 9, 54310-54324.
- Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., & Zhang, J., 2021, Artificial intelligence: A powerful paradigm for scientific research, *The Innovation*, 2(4), 100179.

- Yang, G. Z., Cambias, J., Cleary, K., Daimler, E., Drake, J., Dupont, P. E., ... & Martel, S. 2017. Medical robotics—Regulatory, ethical, and legal considerations for increasing levels of autonomy. *Science Robotics*, 2(4), eaam8638.
- Young, T., Hazarika, D., Poria, S., & Cambria, E. 2018. Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3), 55-75.
- Zerouaoui, H., & Idri, A., 2021, Reviewing machine learning and image processing based decision-making systems for breast cancer imaging, *Journal of Medical Systems*, 45(1), 1-20.
- Zhang, G. P., Patuwo, B. E., & Hu, M. Y. 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.
- Zhang, Y. D., Satapathy, S. C., Guttery, D. S., Górriz, J. M., & Wang, S. H., 2021, Improved breast cancer classification through combining graph convolutional network and convolutional neural network, *Information Processing & Management*, 58(2), 102439.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Hadice ATEŞ  
**Uyruğu** : Türkiye Cumhuriyeti

### EĞİTİM

| Derece     | Adı                 | Bitirme Yılı |
|------------|---------------------|--------------|
| Üniversite | Batman Üniversitesi | 2020         |

### İŞ DENEYİMLERİ

| Kurum                          | Görevi              | Yıl                 |
|--------------------------------|---------------------|---------------------|
| Path İnternet Çözüm Hizmetleri | Yazılım Test Uzmanı | 2021 – Devam Ediyor |

**UZMANLIK ALANI:** Yapay Zeka, Manuel – Otomasyon Testleri, Makine Öğrenmesi

**YABANCI DİLLER:** İngilizce

### YAYINLAR

Hadice, Ç., & Çalışkan, A. 2023. Heart attack risk analysis and estimation using machine learning methods. *Intelligent Methods in Engineering Sciences*, 2(1), 1-4.

Hadice, Ç., & Çalışkan, A. (2022). Makine öğrenmesi teknikleri kullanılarak göğüs kanseri verilerinin sınıflandırılması. *International Informatics Congress (IIC2022)*, 392-396.