



**KARACİĞER TRANSPLANTASYONU SONRASI  
MAKİNE VE DERİN ÖĞRENME YÖNTEMLERİ  
İLE KARACİĞER HASTALIKLARININ TEŞHİSİ**

**Zeynep BİLEN**

**Danışman: Dr. Öğr. Üyesi Ferhat BOZKURT**

**Yüksek Lisans Tezi**

**Bilgisayar Mühendisliği Ana Bilim Dalı**

**2022**

**(Her hakkı saklıdır.)**

T.C.  
ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

**KARACİĞER TRANSPLANTASYONU SONRASI MAKİNE VE DERİN ÖĞRENME  
YÖNTEMLERİ İLE KARACİĞER HASTALIKLARININ TEŞHİSİ**

(Diagnosis of Liver Diseases with Machine and Deep Learning Methods After Liver  
Transplantation)

YÜKSEK LİSANS TEZİ

Zeynep BİLEN

Danışman: Dr. Öğr. Üyesi Ferhat BOZKURT

Erzurum  
Eylül, 2022

## KABUL VE ONAY TUTANAĞI

Zeynep BİLEN tarafından hazırlanan “KARACİĞER TRANSPLANTASYONU SONRASI MAKİNE VE DERİN ÖĞRENME YÖNTEMLERİ İLE KARACİĞER HASTALIKLARININ TEŞHİSİ” başlıklı çalışması 05 /08 / 2022 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bilim Dalında, yüksek lisans tezi olarak kabul edilmiştir.

|               |                                                                   |                      |
|---------------|-------------------------------------------------------------------|----------------------|
| Jüri Başkanı: | Prof. Dr. Rıdvan SARAÇOĞLU<br><i>Van Yüzüncü Yıl Üniversitesi</i> | Aslı Islak İmzalıdır |
| Danışman:     | Dr. Öğr. Üyesi Ferhat BOZKURT<br><i>Atatürk Üniversitesi</i>      | Aslı Islak İmzalıdır |
| Jüri Üyesi:   | Dr. Öğr. Üyesi Mete YAĞANOĞLU<br><i>Atatürk Üniversitesi</i>      | Aslı Islak İmzalıdır |

Enstitü Yönetim  
Kurulunun .../.../....  
tarih ve ..... sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

**Prof. Dr. Saltuk Buğrahan CEYHUN**

**Enstitü Müdürü**

Aslı Islak İmzalıdır

**Not:** Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Dr. Öğr. Üyesi Ferhat BOZKURT danışmanlığında sunulan “KARACİĞER TRANSPLANTASYONU SONRASI MAKİNE VE DERİN ÖĞRENME YÖNTEMLERİ İLE KARACİĞER HASTALIKLARININ TEŞHİSİ” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

| Tez Bölümleri                   | Tezin Benzerlik Oranı (%) | Maksimum Oran (%) |
|---------------------------------|---------------------------|-------------------|
| Giriş                           | 3                         | 30                |
| Kuramsal Temeller               | 10                        | 30                |
| Materyal ve Yöntem              | 22                        | 35                |
| Araştırma Bulguları ve Tartışma | 3                         | 20                |
| Sonuçlar ve Öneriler            | 0                         | 20                |
| Tezin Geneli                    | 15                        | 25                |

**Not:** Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

| Tez Yazarı (Öğrenci)       | Tez Danışmanı                 |
|----------------------------|-------------------------------|
| Zeynep BİLEN               | Dr. Öğr. Üyesi Ferhat BOZKURT |
| 5.8.2022                   | 5.8.2022                      |
| İmza: Aslı Islak İmzalıdır | İmza: Aslı Islak İmzalıdır    |

\* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun ....../....../.... tarih ve ..... sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun ....../....../.... tarih ve ..... sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

## TEŞEKKÜR

Eğitim sürecim boyunca her zaman bilgi ve tecrübeleriyle destekçim olan danışman Sayın Dr. Öğr. Üyesi Ferhat BOZKURT’a,

Bilgisayar Mühendisliğine dair edindiğim bilgilerin temellerini oluşturan, bunun için emek veren, eğiten Atatürk Üniversitesi Bilgisayar Mühendisliği Bölümü Öğretim Üyelerine,

Tez çalışmam da kullandığım veriler için Atatürk Üniversitesi Araştırma Hastanesi Organ Nakli Eğitim Araştırma ve Uygulama Merkez Müdürlüğü başkanı Sayın Prof. Dr. Gürkan ÖZTÜRK ve çalışma arkadaşlarına,

Hayatımın her anında beni maddi ve manevi olarak destekleyen, dualarını hep yanımda hissettiğim canım aileme

Teşekkür ederim.

Zeynep BİLEN

## ÖZET

### YÜKSEK LİSANS TEZİ

#### KARACİĞER TRANSPLANTASYONU SONRASI MAKİNE VE DERİN ÖĞRENME YÖNTEMLERİ İLE KARACİĞER HASTALIKLARININ TEŞHİSİ

Zeynep BİLEN

Danışman: Dr. Öğr. Üyesi Ferhat BOZKURT

**Amaç:** Bu çalışmada, karaciğer nakli olan hastaların nakil sonrasında oluşabilecek hastalıkların teşhisi amaçlanmıştır. Atatürk Üniversitesi Araştırma Hastanesinde, karaciğer nakli olan hastaların bilgilerinden oluşan veri setinin, makine ve derin öğrenme algoritmaları ile oluşturulan modeller aracılığıyla sınıflandırılması amaçlanmıştır. Oluşturulan modellerin performans değerlendirmeleri yapıp karşılaştırma yapılmıştır.

**Yöntem:** Veri girişi için arayüz tasarlanmıştır. Arayüz aracılığı ile veriler veri tabanında toplanmıştır. Bunun yanı sıra hastaların dosyasında bulunmayan bilgiler hastanenin bilgi işleminden talep edilip hepsi tek bir veri havuzunda toplanmıştır. Toplanan verilerin sınıflandırması için makine ve derin öğrenme algoritmalarından modeller kullanılmıştır. Veri seti %80'i eğitim, %20'si test olarak ayrılmış olup modellerin eğitiminde ve test edilmesinde kullanılmıştır. Aynı zamanda veri setinde ayırım yapılmadan k çapraz doğrulama yapılmıştır. Eğitilen modellerin performans metrikleri bize en iyi sonucun hangi modelde olduğunu göstermiştir. Veri ön işleme, modellerin oluşturulması, eğitilmesi ve test edilmesi Google Colaboratory bulut ortamında, Python programlama diliyle gerçekleştirilmiştir.

**Bulgular:** Modeller oluşturulmadan önce k çapraz doğrulama ve özellik çıkarıma yöntemlerinden LDA ve PCA yöntemleri kullanılmıştır. Kullanılan yöntemlere bağlı olarak modellerin performans metrikleri farklılık göstermiştir. Veri setinde dört bağımlı değişken alınmıştır. Ex bağımlı değişkeni için modeller arasında en yüksek doğruluk oranı PCA yöntemi ile %90 olmuştur. K çapraz doğrulama sonrası en yüksek doğruluk oranı LDA yöntemi ile %98 olmuştur. Nüks yeri bağımlı değişkeni için modeller arasında en yüksek doğruluk oranı her iki yöntem ile de %82 olmuştur. K çapraz doğrulama sonrası en yüksek doğruluk oranı LDA yöntemi ile %98 olmuştur. Tümör nüks bağımlı değişkeni için modeller arasında en yüksek doğruluk oranı her iki yöntem ile %79 olmuştur. K çapraz doğrulama sonrası en yüksek doğruluk oranı LDA yöntemi ile %99 olmuştur. Ölüm nedeni bağımlı değişkeni için modeller arasında en yüksek doğruluk oranı LDA yöntemi ile %86 olmuştur. K çapraz doğrulama sonrası en yüksek doğruluk oranı LDA yöntemi ile %99 olmuştur. Bağımlı değişkenlere k çapraz doğrulama uygulandıktan sonra ki doğruluk oranlarının ortalaması sonucunda en iyi yöntem LDA seçilmiştir.

**Sonuç:** Bu çalışma dahilinde karaciğer nakli olan hastaların bilgileri bir veri havuzunda toplanmıştır. Toplanan verilerin, hastalıkların erken teşhisi ve taraması için makine ve derin öğrenmesi yöntemleri ile sınıflandırılması yapılmıştır. Hekimlere, hastalar hakkında gerekli bilgi ve uyarılarda bulunabilen bir sistem oluşturulmuştur. Bu sistemin ilerleyen süreçlerde sadece karaciğer değil diğer organ nakilleri için kullanılabilir hale getirilmesi buna bağlı olarak veri sayısının artması ile birlikte, daha iyi başarımlar elde edilmesi hastalıkların teşhisi bakımından büyük önem arz etmektedir.

**Anahtar Kelimeler:** derin öğrenme, makine öğrenmesi, karaciğer, transplantasyon

Eylül 2022, 75 sayfa

## ABSTRACT

### MASTER'S THESIS

#### DIAGNOSIS OF LIVER DISEASES WITH MACHINE AND DEEP LEARNING METHODS AFTER LIVER TRANSPLANTATION

**Zeynep BİLEN**

**Supervisor: Assist. Prof. Dr. Ferhat BOZKURT**

**Purpose:** In this study, it was aimed to diagnose the diseases that may occur after transplantation in patients with liver transplantation. It is aimed to classify the data set consisting of the information of patients with liver transplantation in Atatürk University Research Hospital, through models created with machine and deep learning algorithms. Performance evaluations of the created models were made and comparisons were made.

**Method:** Interface is designed for data entry. Data were collected in the database through the interface. In addition, the information that is not in the patients' files was requested from the hospital's information process and all of them were collected in a single data pool. Models from machine and deep learning algorithms were used to classify the collected data. The data set was divided into 80% training and 20% test, and was used in training and testing the models. At the same time, k cross validation was performed without discrimination in the data set. The performance metrics of the trained models showed us which model had the best results. Data pre-processing, creation, training and testing of models were carried out in the Google Collaboratory cloud environment, using the Python programming language.

**Findings:** Before the models were created, LDA and PCA methods were used from k cross-validation and feature extraction methods. Depending on the methods used, the performance metrics of the models differed. Four dependent variables were taken in the data set. The highest accuracy rate among the models for the dependent variable Ex was 90% with the PCA method. The highest accuracy rate after K cross validation was 98% with LDA method. The highest accuracy rate among the models for the recurrence location dependent variable was 82% with both methods. The highest accuracy rate after K cross validation was 98% with LDA method. The highest accuracy rate among the models for the tumor recurrence site dependent variable was 79% with both methods. The highest accuracy rate after K cross validation was 99% with LDA method. The highest accuracy rate among the models for the cause of death dependent variable was 86% with the LDA method. The highest accuracy rate after K cross validation was 99% with LDA method. As a result of the average of the accuracy rates after applying k cross validation to the dependent variables, the best method LDA was chosen.

**Results:** In this study, the information of patients who had liver transplantation was collected in a data pool. The collected data were classified by machine and deep learning methods for early diagnosis and screening of diseases. A system has been established to provide physicians with necessary information and warnings about patients. Making this system available not only for liver but also for other organ transplants in the future, along with the increase in the number of data, is of great importance in terms of diagnosing diseases.

**Keywords:** deep learning, machine learning, liver, transplantation

**Semptember 2022, 75 pages**

## İÇİNDEKİLER

|                                                |      |
|------------------------------------------------|------|
| KABUL VE ONAY TUTANAĞI.....                    | i    |
| ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU .....     | ii   |
| TEŞEKKÜR .....                                 | iii  |
| ÖZET .....                                     | iv   |
| ABSTRACT .....                                 | v    |
| İÇİNDEKİLER.....                               | vi   |
| TABLolar DİZİNİ.....                           | viii |
| ŞEKİLLER DİZİNİ .....                          | ix   |
| KISALTMALAR VE SİMGELER DİZİNİ.....            | xii  |
| GİRİŞ.....                                     | 1    |
| KURAMSAL TEMELLER.....                         | 6    |
| MATERYAL VE METOT .....                        | 15   |
| Materyal .....                                 | 15   |
| Veri seti .....                                | 15   |
| Metot .....                                    | 16   |
| Veri ön işleme .....                           | 17   |
| Özellik çıkarma (Feature extration) .....      | 18   |
| Makine öğrenmesi (ML) .....                    | 20   |
| Naive bayes (NB).....                          | 21   |
| Destek vektör makinesi (SVM).....              | 22   |
| Lojistik regresyon (LR).....                   | 22   |
| Karar ağacı (DT) .....                         | 23   |
| Rastgele orman (RF) .....                      | 25   |
| K – En yakın komşu (KNN) .....                 | 25   |
| Derin Öğrenme (DL).....                        | 26   |
| Tekrarlayan sinir ağları (RNN) .....           | 28   |
| Uzun kısa süreli bellek (LSTM).....            | 29   |
| ARAŞTIRMA BULGULARI ve TARTIŞMA .....          | 33   |
| Hastane Veri Seti İle Yapılan Çalışmalar ..... | 34   |
| ILPD İle Yapılan Çalışmalar.....               | 52   |
| SONUÇLAR VE ÖNERİLER .....                     | 56   |

|                |    |
|----------------|----|
| KAYNAKLAR..... | 58 |
| ÖZGEÇMİŞ.....  | 61 |



## TABLÖLAR DİZİNİ

|                                                                                                                  |    |
|------------------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 1.</b> Karaciğer Nakli Bekleyen Hasta Sayısı.....                                                       | 3  |
| <b>Tablo 2.</b> Organ Nakli Olan Hasta Sayısı.....                                                               | 4  |
| <b>Tablo 3.</b> Hastane Veri Seti Ortalama, Minimum ve Maksimum Değerleri .....                                  | 15 |
| <b>Tablo 4.</b> ILPD Veri Seti Ortalama, Minimum Ve Maksimum Değerleri .....                                     | 16 |
| <b>Tablo 5.</b> Ex Bağımlı Değişkeni İçin Performans Metrikleri.....                                             | 34 |
| <b>Tablo 6.</b> Nüks Yeri Bağımlı Değişkeni İçin Performans Metrikleri.....                                      | 35 |
| <b>Tablo 7.</b> Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri.....                                     | 35 |
| <b>Tablo 8.</b> Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri.....                                    | 36 |
| <b>Tablo 9.</b> PCA'lı Ex Bağımlı Değişkeni İçin Performans Metrikleri .....                                     | 36 |
| <b>Tablo 10.</b> PCA'lı Nüks Yeri Bağımlı Değişkeni İçin Performans Metrikleri .....                             | 37 |
| <b>Tablo 11.</b> PCA'lı Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri.....                             | 37 |
| <b>Tablo 12.</b> PCA'lı Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri .....                           | 38 |
| <b>Tablo 13.</b> LDA'lı Ex Bağımlı Değişkeni İçin Performans Metrikleri .....                                    | 38 |
| <b>Tablo 14.</b> LDA'lı Nüks Yeri Bağımlı Değişken İçin Performans Metrikleri .....                              | 39 |
| <b>Tablo 15.</b> LDA'lı Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri .....                            | 39 |
| <b>Tablo 16.</b> LDA'lı Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri.....                            | 40 |
| <b>Tablo 17.</b> Çapraz Doğrulama Sonrası Ex Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri.....           | 42 |
| <b>Tablo 18.</b> Çapraz Doğrulama Sonrası Nüks Yeri Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri .....   | 42 |
| <b>Tablo 19.</b> Çapraz Doğrulama Sonrası Tümör Nüks Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri .....  | 43 |
| <b>Tablo 20.</b> Çapraz Doğrulama Sonrası Ölüm Nedeni Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri ..... | 43 |
| <b>Tablo 21.</b> ILPD Veri Seti İle Oluşturulan Modellerin Performans Metrikleri .....                           | 52 |
| <b>Tablo 22.</b> ILPD Veri Seti İle Literatürde Yapılan Çalışmaların Doğruluk Oranları .....                     | 55 |

## ŞEKİLLER DİZİNİ

|                                                                                                    |    |
|----------------------------------------------------------------------------------------------------|----|
| Şekil 1. Çeşitli makine ve derin öğrenme algoritmalarının performans analizinin iş akışı .....     | 17 |
| Şekil 2. Orijinal veri setindeki donör kilo histogram grafiği .....                                | 18 |
| Şekil 3. Veri ön işlemeden sonra donör kilo veri dağılım grafiği (histogram). ....                 | 18 |
| Şekil 4. PCA uygulandığında veri setindeki boyutun varyans değerleri.....                          | 19 |
| Şekil 5. SVM destek vektörleri ve hiper düzlemi .....                                              | 22 |
| Şekil 6. DT yapısı.....                                                                            | 24 |
| Şekil 7. DT’de derinlik değerlerine karşılık auc değeri .....                                      | 24 |
| Şekil 8. Bu çalışmada önerilen ex bağımlı değişken için DT yapısı.....                             | 25 |
| Şekil 9. K değerleri dizisi .....                                                                  | 26 |
| Şekil 10. Nöron hücresi yapısı .....                                                               | 27 |
| Şekil 11. YSA modeli.....                                                                          | 27 |
| Şekil 12. RNN yapısı.....                                                                          | 28 |
| Şekil 13. Bu çalışmada önerilen RNN model .....                                                    | 29 |
| Şekil 14. LSTM yapısı .....                                                                        | 29 |
| Şekil 15. LSTM unutma katmanının yapısı.....                                                       | 29 |
| Şekil 16. LSTM giriş kapısı yapısı ve formülü .....                                                | 30 |
| Şekil 17. Eski değer yeni değer ile güncellenmesi.....                                             | 30 |
| Şekil 18. LSTM çıkış kapısı yapısı .....                                                           | 31 |
| Şekil 19. Bu çalışmada önerilen ex bağımlı değişken için LSTM model .....                          | 32 |
| Şekil 20. 2x2 Karmaşıklık matrisi (a), modelin karmaşıklık matrisi (b).....                        | 33 |
| Şekil 21. N katmanlı çapraz doğrulama .....                                                        | 40 |
| Şekil 22. N katmanlı çapraz doğrulama .....                                                        | 41 |
| Şekil 23. N katmanlı çapraz doğrulama .....                                                        | 41 |
| Şekil 24. LDA’lı ex bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi .....             | 44 |
| Şekil 25. LDA’lı ex bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon<br>grafikleri..... | 44 |
| Şekil 26. LDA’lı ex bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon<br>grafikleri.....  | 45 |
| Şekil 27. LDA’lı ML ve DL modellerinin ex bağımlı değişkeni için doğruluk değer<br>grafigi .....   | 45 |

|                                                                                                                                |    |
|--------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 28.</b> LDA'lı ex bağımlı değişken için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b) .....        | 45 |
| <b>Şekil 29.</b> LDA'lı nüks yeri bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi.....                            | 46 |
| <b>Şekil 30.</b> LDA'lı nüks yeri bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri.....                  | 47 |
| <b>Şekil 31.</b> LDA'lı nüks yeri bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri.....                   | 47 |
| <b>Şekil 32.</b> LDA'lı ML ve DL modellerinin nüks yeri bağımlı değişken doğruluk değer grafiği.....                           | 47 |
| <b>Şekil 33.</b> LDA'lı nüks yeri bağımlı değişken için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b) ..... | 48 |
| <b>Şekil 34.</b> LDA'lı tümör nüks bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi.....                           | 48 |
| <b>Şekil 35.</b> LDA'lı tümör nüks bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri.....                 | 49 |
| <b>Şekil 36.</b> LDA'lı tümör nüks bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri.....                  | 49 |
| <b>Şekil 37.</b> LDA'lı ML ve DL modellerinin tümör nüks bağımlı değişken doğruluk değer grafiği.....                          | 49 |
| <b>Şekil 38.</b> LDA'lı tümör nüks bağımlı değişkenin ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b) .....   | 50 |
| <b>Şekil 39.</b> LDA'lı ölüm nedeni bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi.....                          | 50 |
| <b>Şekil 40.</b> LDA'lı ölüm nedeni bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri .....               | 51 |
| <b>Şekil 41.</b> LDA'lı ölüm nedeni bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri.....                 | 51 |
| <b>Şekil 42.</b> LDA'lı ML ve DL modellerinin ölüm nedeni bağımlı değişken doğruluk değer grafiği.....                         | 51 |
| <b>Şekil 43.</b> LDA'lı ölüm nedeni bağımlı değişkenin ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b) .....  | 52 |
| <b>Şekil 44.</b> ILPD verisi için ML ve DL modellerinin doğruluk değer grafiği .....                                           | 53 |
| <b>Şekil 45.</b> ILPD verisi için ML ve DL modellerinin karmaşıklık matrisi .....                                              | 53 |

|                                                                                                          |    |
|----------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 46.</b> ILPD verisi için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b) ..... | 54 |
| <b>Şekil 47.</b> ILPD verisi için RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri .....               | 54 |
| <b>Şekil 48.</b> ILPD verisi için LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri .....              | 54 |



## KISALTMALAR VE SİMGELER DİZİNİ

|             |                                                                                        |
|-------------|----------------------------------------------------------------------------------------|
| <b>ANN</b>  | : Artificial Neural Network (Yapay Sinir Ağları (YSA))                                 |
| <b>AODE</b> | : Aggregating One Dependence Estimators (Tek Bağımlı Tahmin Edicileri Toplama (TBTET)) |
| <b>AUC</b>  | : Area under the ROC Curve (ROC Eğrisi Altındaki Alan (AUC))                           |
| <b>CART</b> | : Classification And Regression Trees (Sınıflandırma ve Regresyon Ağaçları)            |
| <b>DL</b>   | : Deep Learning (Derin Öğrenme (DÖ))                                                   |
| <b>DNN</b>  | : Deep Neural Networks (Derin Sinir Ağları (DSA))                                      |
| <b>DS</b>   | : Decision Stump (Karar Kütüğü (KK))                                                   |
| <b>DT</b>   | : Decision Tree (Karar Ağacı (KA))                                                     |
| <b>FFNN</b> | : Feedforward Neural Network (İleri Beslemeli Sinir Ağı (İBSA))                        |
| <b>GRU</b>  | : Gated Recurrent Unit (Geçitli Tekrarlayan Birim (GTB))                               |
| <b>HNB</b>  | : Hidden Naive Bayes                                                                   |
| <b>ILPD</b> | : Indian Liver Patient Dataset (Hint Karaciğer Hasta Veri Seti (HKHVS))                |
| <b>KNN</b>  | : K-Nearest Neighbors (K – En Yakın Komşu)                                             |
| <b>LDA</b>  | : Linear Discriminant Analysis (Doğrusal Diskriminant Analizi (DDA))                   |
| <b>LR</b>   | : Logistic Regression (Lojistik Regresyon (LR))                                        |
| <b>LSTM</b> | : Long Short-Term Memory (Uzun Kısa Süreli Bellek (UKSB))                              |
| <b>LMT</b>  | : Logistics Model Tree (Lojistik Model Ağacı (LMT))                                    |
| <b>ML</b>   | : Machine Learning (Makine Öğrenmesi (MÖ))                                             |
| <b>MCC</b>  | : Matthews Correlation Coeffic (Matthews Korelasyon Katsayısı (MKK))                   |
| <b>NB</b>   | : Naive Bayes                                                                          |
| <b>OKSA</b> | : Oto Kodlayıcı Sinir Ağları                                                           |
| <b>PCA</b>  | : Principal component analysis (Temel Bileşen Analizi (TBA))                           |
| <b>RBF</b>  | : Radial Basis Function (Radyal Temel İşlem (RTİ))                                     |
| <b>RF</b>   | : Random Forest (Rastgele Orman)                                                       |
| <b>RNN</b>  | : Recurrent Neural Networks (Tekrarlayan Sinir Ağları (TSA))                           |
| <b>ROC</b>  | : Receiver Operating Characteristics (Alıcı İşletim Karakteristiği (AİK))              |
| <b>SHGM</b> | : Sağlık Hizmetleri Genel Müdürlüğü                                                    |
| <b>SVM</b>  | : Support Vector Machine (Destek Vektör Makinesi (DVM))                                |
| <b>MLP</b>  | : Multi-Layer Perceptron (Çok Katmanlı Algılayıcı (ÇKA))                               |

## GİRİŞ

Karaciğer insan vücudunda karnın üst sağ tarafında, kaburga kafesinin altında yer almaktadır. Karaciğer ağırlığı kadınlarda ortalama 1,2-1,4 kg, erkeklerde ortalama 1,4-1,8 kg arasında değişmektedir. Vücudumuzdaki en büyük organdır (Taşdoğan, 2019).

Karaciğer insan metabolizmasında önemli bir rol oynamaktadır. Gıdalardan alınan şekeri glikojene çevirip depolamak görevlerinden sadece bir tanesidir. Protein sentezi, yağların sentezi ve depolanması, karbonhidrat depolanması ve salınması gibi görevlerde yer almaktadır. Bunların yanı sıra A, D, E ve K vitaminlerinin ve yağların emilimi için safra üretir. Üre yapımında da yer alır. Vücudumuza alınan zararlı madde ve ilaçları zararsız hale getirerek vücuttan atılmasında rol oynar (Taşdoğan,2019). Kanın pıhtılaşması için gereken faktörlerin sentezini yapmaktadır. Karaciğerin en önemli özelliklerinden birisi de kendini yenileyebilmesidir. Karaciğer bu görevleri yerine getiremediği zaman karaciğer hastalıkları ortaya çıkmaktadır (Acarlı, 2020).

Karaciğer hastalıkları çocuklarda doğuştan ortaya çıkmaktadır. Annenin hamileliği esnasında yaşadığı sıkıntılardan ötürü veya kalıtsal olarak çocuklarda karaciğer hastalığı, yetmezliği ortaya çıkmaktadır. Karaciğer hastalığı, yetmezliği yetişkinlerde sonradan ortaya çıkmaktadır. Bu sebepten ötürü yetişkinlerin karaciğer hastalığına yakalanmaması için dikkat edilmesi gereken hususlar vardır. Hepatit aşılarının eksiksiz yapılması önemlidir. Çünkü hepatit virüsü kan yolu ile buluşabilmektedir. Alkolden uzak durulmalı, fazla kilolu olmaktan kaçınılmalı, yenilen mantarların zehirli olmamasına dikkat edilmelidir. Gereksiz ilaç kullanılmamalı, zayıflamak için veya herhangi bir sebepten ötürü kullanılan bitkisel karışımlara dikkat edilmelidir. Safra kesesinde bulunan taş safra yollarını tıkayıp karaciğere zarar verebileceğinden dolayı tedavisi ihmal edilmemelidir. Düzenli olarak kan testleri yapılmalı ve sağlıklı beslenmeye dikkat edilmelidir (Acarlı, 2020).

Karaciğer hastalığının türüne ve şiddetine göre birçok belirti baş gösterebilmektedir. Sarılık, karında ağrı ve şişlik, kusma, ateş, mide bulantısı, kaşıntı, idrar renginde koyuluk, iştah kaybı, uyku bozuklukları karaciğer hastalığının belirtilerinden bazılarıdır. Karaciğer hastalıkları genellikle erken dönemde belirti vermez. Hepatit A, B, C, D ve E, Alkole bağlı karaciğer yağlanması, Alkole bağlı olmayan karaciğer yağlanması, Siroz, Karaciğer kanseri, Wilson, Lenfoma, Karaciğer kistleri karaciğer hastalıklardan bazılarıdır. Bu hastalıkların

etkileri ile ya da çevresel faktörlerden dolayı karaciğer görevlerini yerine getiremediğinde karaciğer yetmezliği ortaya çıkmaktadır (Anonim, 2021).

Karaciğer yetmezliği karaciğerin büyük bir kısmının geri dönüşümsüz bir şekilde hasara uğraması ile ortaya çıkar. Kişide hayati risk oluşturarak yaşam kalitesini bozmaktadır. Karaciğer yetmezliği akut ve kronik olmak üzere ikiye ayrılır. Akut karaciğer yetmezliği kişide herhangi bir sorun yok iken aniden gelişen karaciğer fonksiyon kaybıdır. Akut karaciğer yetmezliği aşırı doz ilaç alımı ya da zehirlenmeden dolayı oluşabilir. Kronik karaciğer yetmezliği kişide zamanla yavaş yavaş ilerleme gösterir ve karaciğer çalışmayacak duruma gelir. Karaciğer yetmezliği belirli aşamalardan karaciğerin iltihaplanması erken bir aşamadır. Genellikle bu aşamada hasta bu durumu anlamayabilir. Erken teşhis ve tedavi edilmesi bu aşama için önem arz etmektedir. Fibrozis evresi ise karaciğer iltihaplandıktan sonra tedavi edilmezse karaciğerde yaralar oluşmaya başlar. Yaralar büyüyüp yayıldıkça sağlıklı dokunun yerini alır. Yara ile kaplanmış olan karaciğer dokusu görevlerini yerine getiremez. Erken teşhis ve tedavi edilmesi durumunda karaciğer kendini iyileştirebilir. Bu aşama fibroz ya da fibrozis olarak isimlendirilir. Siroz evresinde olan karaciğerin fibroz evresinde iken tedavisi yapılmamış olup yara neredeyse tüm karaciğere yayılmış bir durumdadır. Hastada sağlık sorunları belirti göstermeye başlar. Siroz tedavisinde sağlıklı kalan karaciğer dokusu korunur ve yaranın ilerlemesi durdurulur. Sirozun tedavi edilemediği durumlarda karaciğer işlevini tamamen yitirir ve kanser de içerisinde olmak üzere birçok komplikasyon oluşur. Hastalığın son evresinde olan karaciğer kötüleşmiş ve geri dönüşü olmayan bir duruma girmiştir. Tedavisi karaciğer nakli olmaktadır. Bu evrede olan hastalar nakil listelerinde önceliğe sahiptirler (Anonim, 2021).

Karaciğer nakli yani transplantasyonu iki şekilde gerçekleşmektedir. Beyin ölümü gerçekleşmiş veya sağlıklı insanlardan fonksiyonları normal devam eden karaciğer dokusundan bir kısmı alınır ve karaciğer yetmezliği olan hastaların karaciğer dokusu ile değiştirilir. İlk defa 1963 yılında kadavradan organ nakli gerçekleştirilmiştir. Organ nakli Colorado Üniversitesinde Starzl tarafından yapılmıştır. Bu nakilde uzun süreli başarı sağlanamamış ve çalışmalar devam etmiştir. Devam eden çalışmalar sonucunda aynı ekip uzun süreli başarı ile sonuçlanan ilk transplantasyonu 1967 yılında yapmışlardır (Starzl, 1968). Karaciğer nakli yapılacak kadavra sayısının azlığından dolayı yeni yöntemlerin bulunması zorunlu bir hal almıştır. Bundan ötürü canlı donörden nakil, Smith tarafından ilk kez gerçekleştirilmiştir. Canlı vericiden yapılan karaciğer nakilleri ilk olarak çocuklarda denenmiştir (Hashikura, 1994). Transplantasyon öncesinde ve sonrasında dikkat edilmesi gereken birçok önemli husus vardır. Hasta seçimi, nakil sırasında uygulanacak olan cerrahi teknik, organın saklanması, nakil yapılacak greftin boyutu, nakil sonrasında hastanın kullanacağı immünsupresif tedavi (bağışık baskılayıcı

ilaçlar), donör ve alıcının seçimi önemli noktalardır (De Villa, 2003). Önemli noktaların belirlenmesi sonucunda nakil sonrasında hastaların yaşam süreleri ilk senelerde %30 iken günümüzde ise bu oran %80'lere kadar çıkmıştır. Organ bağışının yetersiz kalması fakat nakillerin yaygınlaşması ile organ bekleyen hasta sayısı artmakta ama kadavra sayısı yetersiz kalmaktadır. Bu yetersizliğin önüne geçebilmek için yeni yöntemlere başvurulmuştur. Bu yöntemlerden birisi kadavradan alınan karaciğerin sağ lobunu yetişkinler için kullanırken, sol lobunu ya da sol letaral segmentini çocuklar için kullanılmaktadır. Böylelikle tek bir kadavra ile iki hasta tedavi olabilmektedir (Kasapoğlu, 2010).

Sağlık Hizmetleri Genel Müdürlüğü (SHGM) Doku, Organ Nakli ve Diyaliz Hizmetleri Dairesi Başkanlığının Organ Karar Destek Sistemlerinin verilerine göre ülkemizde son 5 yılda karaciğer nakli bekleyen hastaların sayısı yıllara göre Tablo 1'de gösterilmiştir (Doku, 2021).

**Tablo 1.** Karaciğer Nakli Bekleyen Hasta Sayısı

|               | HASTA SAYISI  |
|---------------|---------------|
| 2015          | 2252          |
| 2016          | 2206          |
| 2017          | 2097          |
| 2018          | 2143          |
| 2019          | 2261          |
| 2020          | 1715          |
| <b>TOPLAM</b> | <b>12.674</b> |

SGHM, Organ Nakli ve Diyaliz Hizmetleri Dairesi Başkanlığının Organ Karar Destek Sistemlerinin verilerine göre ülkemizde son 5 yılda organ nakli olan hastaların sayısı yıllara göre Tablo 2'de gösterilmiştir (Doku, 2021).

Hasta, nakil sonrasında oluşabilecek komplikasyonlardan dolayı rutin olarak izlenmelidir. 1980 yılı öncesinde nakil sonrasında sağ kalım oranı %50'nin altında seyretmekteydi. Günümüzde ise bu oran %80'nin üzerinde çıkabilmiştir. Nakil sonrasında vücudun organı kabul etmemesi (rejeksiyon) akut ve kronik rejeksiyon olarak adlandırılmıştır. Akut rejeksiyon genelde nakilden sonraki 90 gün içinde belirti gösterir. Ateş, karın ağrısı, karında sıvı miktarında artış, koyu renkli idrar, açık renkli gayta, yorgunluk vd. belirtiler baş göstermektedir.

**Tablo 2.** Organ Nakli Olan Hasta Sayısı

|                           | 2021         | 2020         | 2019         | 2018         | 2017         | 2016         |
|---------------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| <b>AKCİĞER</b>            | 19           | 11           | 33           | 43           | 42           | 22           |
| <b>BÖBREK</b>             | 3.286        | 2.499        | 3.874        | 3.874        | 3.344        | 3421         |
| <b>EKSTREMİTE SAĞ KOL</b> | 1            |              | 1            |              |              |              |
| <b>EKSTREMİTE SAĞ KOL</b> | 1            |              | 1            |              |              |              |
| <b>İNCE BARGİRSAK</b>     | 2            | 2            | 4            |              | 2            | 5            |
| <b>KALP</b>               | 23           | 21           | 84           | 91           | 76           | 70           |
| <b>KARACİĞER</b>          | 1.490        | 1.320        | 1.776        | 1.587        | 1.446        | 1.396        |
| <b>PANKREAS</b>           |              | 1            | 3            | 4            |              | 6            |
| <b>GENEL TOPLAM</b>       | <b>4.822</b> | <b>3.854</b> | <b>5.765</b> | <b>5.599</b> | <b>4.910</b> | <b>4.920</b> |

Karaciğer nakli, karaciğerde ortaya çıkan siroz, kanser gibi birçok hastalığın tedavisinde tüm dünyada ve ülkemizde aktif ve yaygın bir şekilde kullanılmaktadır. Ülkemizde karaciğer nakli canlı verici oranı daha fazla olmak üzere tüm yaş gruplarında çokça ve başarıyla yapılmaktadır. Sağlık Bakanlığının verilerine göre yılda yaklaşık olarak 1500 karaciğer hastasına nakil yapılmaktadır. Nakil yapılan hastaların önemli bir bölümü uzun bir dönemde normal bir hayat yaşamaktadırlar. Karaciğer hastalıkları ilk aşamalarda kolay teşhis edilebilir değildir fakat erken teşhisi ölüm oranını düşürdüğü için çok önemlidir. Hasta nakil öncesi, nakil sırasında ve nakil sonrasında uzun bir dönem takip edilmektedir. Bu takip süreçlerinde yapılan sağlık muayeneleri ile oldukça büyük veriler toplanmakta ve bu veriler karaciğer hastalıklarının teşhisinde kullanılmalıdır. Karaciğer nakli yapıldıktan sonra hastalarda nakil yapılan organın fonksiyon göstermemesi, organ reddi, damarsal problemler, enfeksiyon gibi çeşitli komplikasyonlar görülmektedir. Bu komplikasyonları en aza indirmek, nakil sonrası hastanın yaşam süresini ve kalitesini artırmak amaçlanmaktadır.

Transplantasyon sonrasında hastaların tansiyon, nabız, ateş, şuur vb. gibi genel muayene bulgularının yanı sıra karaciğer ile ilgili testler, enfeksiyonun varlığını gösterebilecek testler, ultrason, tomografi, MR gibi radyolojik değerlendirmeler ve biyopsi, doku incelemeleri gibi patolojik değerlendirmelerin ne zaman yapılacağı uzman hekimler tarafından belirlenir ve sonuçları değerlendirirler. Değerlendirme hekimin daha önceki deneyimlerine göre şekillenebileceği gibi ulusal ve uluslararası çalışmalarla elde edilen verilerin analiz edilmesiyle elde edilir. Veriler ne kadar çoksa elde edilen sonuçların güvenilirliği de o kadar yüksek olur. Hekim bu verilere dayanarak bir tedavi programı belirler. Tedavi sürecinde de tetkikler devam eder ve süreç takip edilir. Duruma göre takip ve tedaviye devam edilir veya tedavi değişilir.

Yapılacak olan Makine öğrenmesi (Machine Learning (ML)) veya derin öğrenme (Deep Learning (DL)) modeli yukarıda tanımlanan şekilde modellenecektir.

Bu çalışmanın kalan kısımları ise şu şekilde oluşturulmuştur: ikinci bölümde, karaciğer hastalıklarının ML ve DL yöntemleri ile tahmin edilmesiyle ilgili yapılan çalışmalar anlatılmıştır. Üçüncü bölümde çalışmada kullanılan veri seti, hangi ön işlemler den geçirildiği, oluşturulan modeller ve modelde kullanılan algoritmalar hakkında kısaca bilgi verilmiştir. Dördüncü bölümde, modelin eğitim ve test sonucunda elde edilen performans metrikleri, karmaşıklık matrisleri ve grafikler yorumlanmıştır. Son bölümde çalışma sonucunda elde edilen sonuçlar tartışılmış ve gelecek çalışmalardan bahsedilmiştir.



## KURAMSAL TEMELLER

Dandil (2013) yaptığı çalışmada karaciğerde oluşan hastalıkların teşhisi için Yapay Sinir Ağları (Artificial Neural Network (ANN)) tabanlı bir sistem geliştirmiştir. Çalışma da karaciğer hastası olan ve olmayan insanlardan alınan kategorik ve sayısal verilerden oluşan Hint Karaciğer Hasta Veri Seti (Indian Liver Patient Dataset (ILPD)) kullanılmıştır. ILPD veri seti içeriğinde, hastanın yaşı, hastanın cinsiyeti, toplam bilirubin, doğrudan bilirubin, doğrudan olmayan fosfat, alemin aminotransferaz, aspartat aminotransferaz, toplam protein, albumin, albumin ve globulin oranı. Çalışmada teşhis için ANN ve Bayes sınıflandırma yöntemlerini kullanmıştır. Veri setinin %70'i ANN'nin eğitiminde kullanılırken, %30' u ise test verisi olarak kullanılmıştır. İki sınıflandırma yöntemlerinde dönem sayısı (Epoch) değeri 1000 alınmıştır. Sistem eğitilip test edildikten sonra performans analizi için Doğruluk Yüzdesi ve Yanlışlık Yüzdesi kriterlerine bakılmıştır. ANN Doğruluk yüzdesi %82, Yanlışlık yüzdesi %18 olmuştur. Bayes teoreminde ise Doğruluk yüzdesi %68, Yanlışlık yüzdesi %32'dir. Çalışmada bayes sınıflandırmanın ANN'den başarısız olduğu gözlenmiştir. Farklı makine öğrenmesi algoritmalarının kullanılmaması ANN'yi başarılı yapmıştır. Bu ANN'ye başarılı demek için yeterli değildir ve bir dezavantajdır.

Hashem and Mabrouk (2014) yaptıkları çalışmada yaygın olarak görülen diyabet ve kronik karaciğer hastalıklarını ele almışlardır. ILPD veri seti ve Matlab çalışma ortamı kullanılmıştır. ML algoritmalarından Destek Vektör Makinesi (Support Vector Machine (SVM)) yöntemi ile modelleme yapmışlardır. Çalışmada veri setinden 8 öznitelik kullanılmıştır. Bu öznitelikler şu şekildedir; Hastanın yaşı, hastanın cinsiyeti, toplam bilirubin, doğrudan bilirubin, alkalın fosfat, alemin aminotransferaz, aspartat aminotransferaz ve toplam proteinlerdir. ILPD veri setinde %73,2 teşhis başarıları elde edilmiştir. Çalışmada belirtilen özniteliklerin kullanılarak modellerin oluşturulması literatüre yeni ve başarılı veri seti kazandırılmasından bahsedilebilir. İki farklı çalışma konusu olabilen diyabet ve karaciğer hastalıklarının teşhisinin tek bir çalışma altında toplanıp incelenmesi literatür için kolaylık sağlamıştır.

Gulia *et al.* (2014) karaciğer hastalığının teşhisi için ILPD veri setini kullanmışlardır. ML algoritmalarından J48, Çok katmanlı algılayıcı (Multi-Layer Perceptron (MLP)), SVM, Rastgele Orman (Random Forest (RF)) ve Bayes Net kullanmışlardır. Veri setinde öznitelik ayrımı yapmadan yaptıkları başarı ölçümleri şu şekildedir: %71,35 ile en yüksek başarı SVM, %70,32 RF, %68,78 J48, %68,26 MLP ve %67,23 Bayes Net. Veri setinde ön işleme yapılarak

başarıyı etkileyen önemli öznitelikler seçilmiştir. Veri ön işlemede Özellik Seçim algoritması (Greedy Stepwise) kullanılmıştır. Veri ön işleme sonucunda %71,86 ile en yüksek başarı RF %71,35 SVM, %70,84 MLP, %70,66 J48 ve %69,12 Bayes Net teşhis başarısı göstermiştir. Bu çalışmada ILPD veri seti kullanan diğer çalışmalardan farklı olarak özellik seçim algoritması kullanılmıştır. Bu araştırma çalışmasının çözüm getirebileceği sorular şu şekilde verilebilir: Hibrit model yapımı nasıl yapılır? Karaciğer veri setlerinde özellik seçimi nasıl uygulanır? Özellik Seçimi olan veya olmayan karaciğer hastalarının tahmin doğruluğunu iyileştirmek için sınıflandırma algoritmalarının karşılaştırmalı analizi nasıl yapılır? Bu çalışma, karaciğer hastalarının sınıflandırılmasıyla ilgili çeşitli yönlerin bilinmesine yardımcı olabilecek bu soruların yanıtlarını bulmaktadır. Bu çalışmayı gerçekleştirerek, model yapımında kullanılmak üzere ilgili özelliklerin bir alt kümesini seçme süreci olarak özellik seçiminin büyük bir önemi olduğu gösterilmiştir. Bir sınıflandırma algoritması uygulanmadan önce ILPD üzerinde öznitelik seçimi kullanılarak sınıflandırma algoritmasının performansı artar.

Jin *et al.* (2014) yaptıkları çalışmada ML algoritmaları ile karaciğer hastalığını tahmin etmişlerdir. Veri seti olarak ILPD kullanılmıştır. Kullanılan ML algoritmaları şu şekildedir; Karar Ağacı (Decision Tree (DT)), K- En Yakın Komşu (K-Nearest Neighbors (KNN)), MLP, Saf Bayes (Naive Bayes (NB)), Lojistik Regresyon (Logistic Regression (LR)) ve RF. Algoritmaların performans ölçütü olarak doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Sensitivity), özgüllük (Specificity) kullanılmıştır. Bu ölçütlerin ortalama başarı oranları şu şekildedir; özgüllük %98,6, doğruluk %96,55, kesinlik %93,69 ve duyarlılık %92,1'dir. Bu çalışmada, karaciğer hasta verilerine algoritmik özellikleri dikkate alan sınıflandırma algoritmalarının performansını değerlendirilmiştir. Bunu değerlendirme için, önerilen algoritmaların sonuçlarını orijinal olarak kullanılanlarla karşılaştırma için tahmin testi gerçekleştirilmiştir. Deneyim ve analizleri sayesinde, veri madenciliğinin etkinliği, kullanılan algoritmaya veya verilerin özelliklerine göre büyük ölçüde değişmiştir. Ek olarak, daha etkili performans kriterlerine daha uygun algoritmaların seçimi eşlik etmelidir. Son olarak, sırasıyla algoritmik özellikleri ve tahmin testinin performansını göz önünde bulundurarak, etkili algoritmalar seçmenin ve veri değerlendirme faktörlerinin önemli olduğu sonucuna varılmıştır.

Montazeri (2014) yaptığı çalışmada karaciğer hastalığının tanısını tahmin etmek için makine öğrenimi modelleri kullanmıştır. Saf Bayes, RF, KNN, AdaBoost ve SVM kullanılan makine öğrenmesi algoritmalarıdır. California Üniversitesinde kayıtlı olan 583 hastanın verisi kullanılmıştır. Veri seti içerisinde yaş, bilirubin, direkt bilirubin, toplam proteinler, albümin, a/g oranı, sgpt, sgot, alk fos değerleri yer almıştır. Modellerin performansı özgüllük, duyarlılık, doğruluk ve Alıcı İşletim Karakteristiği (Receiver Operating Characteristics (ROC)) eğrisi

altındaki alan (AUC) ile karşılaştırılmıştır. Modellerin doğruluğu şu şekildedir: Saf Bayes %55, RF %72, KNN %64, AdaBoost %70 ve SVM %71'dir. AUC değerleri ise sırası ile 0,72, 0,72, 0,59, 0,67 ve 0,5'tir. RF doğruluk düzeyi en yüksek olan modeldir.

Ayeldeen *et al.* (2015) çalışmasında Hepatit C virüsü olan hastada karaciğer fibrozunun var olup olmadığının ve fibroz derecesinin tahmin edilmesi üzerine çalışılmıştır. Hepatit C virüsü olan 100 Mısırlı hastanın verileri ile çalışılmıştır. Veri seti içerisinde dokuz biyokimyasal belirteç aspartateaminotransferaz (AST) enzimi, alaninaminotransferaz (ALT) enzimi, serum albümin (ALB), toplam bilirubin (T.BIL), direkt bilirubin (D.BIL), Gamma, Glutamil Transpeptidaz (GGT), Hyaluronik Asit (HA), 2-makroglobulin (2-MC) ve apoliporotin A2 (ApoA2) DT sınıflandırıcısına dayalı ML tekniği kullanılmıştır. Sınıflandırma %93,7 doğruluğunda bulunmuştur. Bu çalışmada, tıbbi alan için istatistiksel makine öğrenimi modelinin araştırma sonuçları üzerinde olumlu bir etkisi olmuştur ve doktorlara, tıbbi prosedürlere minimum ihtiyaç duyarak teşhis süreçlerini iyileştirmeleri için analitik bir araçla yardımcı olabilir. Model, karar vericiler için zamanında karar verme sorununun üstesinden gelmek için verilerin tahmin edilmesi ve görselleştirilmesi için daha etkili ve verimli bir şekilde kullanılabilir. Ayrıca, öznelite seçim stratejilerini kullanarak, en önemli değişkenleri seçerek, kullanılacak değişkenlerin sayısı azaltılabilir.

Abdar *et al.* (2017) çalışmada ILPD veri setini kullanmıştır. Bu veri setinde 416 karaciğer hastalığı ve 167 sağlıklı karaciğer kaydı bulunmaktadır. Bu veri seti Boosted C5.0 ve CHAID algoritmaları olarak adlandırılan iki algoritma ile analiz edilmektedir. Bu algoritmaların performansları karşılaştırıldığında, Boosting tekniği ile C5.0 algoritmasının %93,75 doğruluğa sahip olduğu ortaya çıkmakta ve bu sonuç %65,00 olan CHAID algoritmasından daha iyi bir performansa sahip olduğunu ortaya koymaktadır. Bu çalışmanın önemli bir başarısı her iki algoritmanın da karaciğer hastalığı için tek bir sınıfta kurallar üretme yeteneğidir. Boosted C5.0 algoritmasında oluşturulan kuralları kullanarak, erkeklerin karaciğer hastalığına kadınlara göre daha yatkın olduğu sonucuna varılmıştır. Deneysel sonuçlara ve karaciğer hastalığına ilişkin diğer mevcut çalışmalara göre, artırılmış C5.0 kabul edilebilir performansa sahiptir. Yeni bir yöntem olarak önerilen yöntem oldukça basit kurallar üretmiştir. Birkaç metrik kullanarak, bu çalışmada artırılmış C5.0'in doğruluğunun literatürdeki yüksek doğruluklardan biri olduğunu da gözlemlenmiştir. Ayrıca en önemli beş faktördeki özelliklerin ve kesme noktalarının önemi ortaya konmuştur. Hekimlerin karaciğer hastalığı gibi çeşitli hastalıklarda özelliklerin önemi hakkında farklı görüşleri olduğundan, bu çalışma, özellikle bu hastalığın arkasındaki önemli faktörleri belirlemek için madencilik tabanlı sınıflandırıcılar tarafından kuralların üretilmesine ve uygulanmasına odaklanmıştır.

Hamid *et al.* (2017) karaciğerdeki anormalliklerinin ultrason görüntülerini kullanarak görüntünün normal ve anormal etiketlenen dışında tahminin yanlış olabileceğini de algılayabilen bir ML modeli geliştirmişlerdir. Kullanılan modeller KNN, SVM ve Çekimser öğrenmedir (LWA). Çekimser öğrenme, model yanlış sınıflandırma yapmak yerine yapacağı sınıflandırmadan emin olmadığında etiket üretmekten çekinir. Modellerin performans ölçütü olarak AUC-ROC kullanılmıştır. KNN %78, SVM %87 AUC-ROC performans ölçütü göstermiştir. Bu çalışmada, karaciğer ultrason görüntülerinin normal ve anormal vakalar olarak sınıflandırılması için yeni bir yaklaşım geliştirilmiştir. Yaklaşımın yeniliği, sınıflandırma için kaçınılmaz öğrenme modelinin kullanılmasında yatmaktadır. Önerilen yöntem, doğru tahminler üretme ve aykırı değerleri belirleme konusunda yeterince yüksek güvene sahip olmadığı durumları otomatik olarak belirleyebilmektedir. Böylece model, bilmediğini bilen bir yapay zekâ sistemi olarak düşünülebilir. Sonuçlar, önerilen sistemin pratik bir ortamda çok faydalı olduğunu ve zamandan, paradan ve ağırlı veya pahalı testlerden geçme zahmetinden tasarruf ederek hem hastalara hem de tıp doktorlarına yardımcı olabilir. Ayrıca LWA çerçevesi için yeni bir stokastik gradyan tabanlı çözücü önerilmiştir. Önerilen şema diğer alanlarda da uygulanabilir.

Borulday (2017) yaptığı çalışmada işlemsel zekâ yöntem ve uygulamalarını kullanarak 14 farklı karaciğer hastalığının teşhisi üzerinde çalışmıştır. Çalışmada işlemsel zekâ yöntemi olarak karar ağacı kullanılmıştır. 3 farklı vaka girilerek teşhis başarımlarına bakılmıştır. 1. Vaka da girilen bilgilere göre %100 oranında Siroz tanısı konulmuştur. 2. Vaka da ise girilen bilgiler sonucunda birbirine yakın oranlar da çok çeşitli hastalık tanısı konmuştur. Tanı sonucunu daraltmak için laboratuvar testlerine başvurulmuş ve %100 oranında Akut Hepatit A tanısı konulmuştur. 3. Vakada da 2. Vakada olduğu gibi laboratuvar testlerine başvurulmuş ve %29,1 oranlarında Siroz ve Otoimmün Hepatit, %22,7 Birincil Sklerozan Kolanjit, %19,2 Birincil Biliyer Siroz tanısı konulmuştur. Bu çalışma, makine öğrenimini tıbbi teşhis amacıyla analitik bir araç olarak kullanmış ve etkili olumlu sonuçlar vermiştir. Doktorlara teşhiste önemli ölçüde yardım sağlarken aynı zamanda ek tıbbi prosedürlere olan ihtiyacı azaltır. Amaç, uygulama ve ara yüzün gerçek hasta vakalarında kullanılabilmesi için gerekli iyileştirme ve eklemelerin yapılmasıdır. Karar ağacı 71 testi kullanır ve 14 olası hastalığı daraltır. Çıktı olarak en olası hastalığı verir. Gerçek hasta vakalarında kullanılması amaçlanan bu uygulama, teşhis başarı oranını artırmaya yönelik ilk adımdır. Aynı zamanda, geniş bir hastalık yelpazesini ve bir bütün olarak test verilerini yorumlama olasılığına yönelik ilk adımdır.

Alaybeyoğlu ve Mülâyim (2018) yaptıkları çalışmada karaciğer kanserinin teşhisinde SVM tabanlı bir sistem tasarımı geliştirmişlerdir. Veri seti olarak ILPD kullanmışlardır.

Yapılan çalışmanın performans değerlendirme ölçütü olarak doğruluk, pozitif kestirim değeri, negatif kestirim değeri, duyarlılık, özgüllük ve F- Ölçütü kullanılmıştır. Performans değerlendirme sonuçları şu şekildedir: %87,16 ile en yüksek başarı pozitif kestirim, %79,9 duyarlılık, %78,33 doğruluk, %75 özgüllük, %63,71 negatif kestirim teşhis başarısı göstermiştir. Kullanıcının geliştirilen sistemi kullanabilmeleri için ara yüzler tasarlanmıştır. Kullanıcılar laboratuvar test sonuçlarını bu ara yüzler aracılığı ile sisteme girmekte ve sistem, girilen verileri destek vektör makinesi tekniğini kullanarak hasta ile ilgili sonuç çıkarsamasında bulunmaktadır.

Auxilia (2018) yaptığı çalışmada karaciğer hastalıklarını öngörebilmek için ML algoritmaları kullanmıştır. Veri kümesi olarak ILPD kullanılmıştır. ML algoritmalarından DT %81, RF %77, SVM %77, ANN %71 ve NB %37 başarı görülmüştür. En iyi sonuç DT de elde edilmiştir. Hindistan'daki hastaların nüksetme ve ciddiyet durumuyla mücadele etmek için hazırlık aşamasında karaciğer kontaminasyonunun ayırt edici kanıtı zorunludur. Hastalar, özelleştirilmiş tedavinin iyileştirilmesi için başlangıç endikasyonları açısından taranmalıdır. Bu araştırmada, ML algoritmalarını kullanarak karaciğer hastalığının tahmini için çalışılmıştır. Karar ağacının diğer sıralama sınıflandırma algoritmalarından farklı olarak daha iyi sonuçlar verdiği görülmüştür.

Ma *et al.* (2018) çalışmasında Çin'de Alkolsüz Yağlı Karaciğer hastalığı teşhisi için ML teknikleri ile modelleme yapılmıştır. Zhejiang Üniversitesi, Birinci Bağlı Hastanesi'nde sağlık muayenesine katılan hastalar ile çalışma yapılmıştır. Çalışma da anketler, laboratuvar testleri, fiziksel muayeneler ve karaciğer ultrasonografisi kullanılmıştır. 11 tane ML sınıflandırma algoritması kullanılmıştır. KNN, SVM, LR, NB, Bayes Ağı, RF, C4.5, AdaBoost, Gizli Saf Bayes (Hidden Naive Bayes (HNB)), Tek Bağımlı Tahmin Edicileri Toplama (Aggregating One Dependence Estimators (AODE)). Sınıflandırma modellerinin performans ölçütü olarak kesinlik, özgüllük, hassaslık, geri çağırma ve F-ölçütü (F- Measure) kullanılmıştır. LR %83,41 ile en iyi doğruluk değerine, SVM 0,725 ile en iyi kesinlik değerine, AODE 0,680 ile en iyi geri çağırma değerine, Bayes ağı 0,655 ile en iyi F-ölçütü değerine sahiptir. Bayes ağ tekniği ile en iyi genel performans gösteren ML tekniğidir. Bayes ağ tekniği %83 doğruluk, 0,878 özgüllük, 0,675 duyarlılık ve 0,655 f-skoru puanları elde edilmiştir. Tarama modelinden elde edilen sonuçlar, bilgi kazanım puanlarına dayalı olarak en ayırt edici ilk 5 özelliğin ağırlık, TG, ALT, GGT ve serum ürik asit seviyeleri olduğunu ortaya çıkardı. Böylece pratikte kullanıcılar bu 5 özelliğe odaklanabiliyordu. Tahmin modelinden elde edilen sonuçlar, Bayes ağ modelinin en iyi performansa sahip olduğunu göstermiştir.

Singh *et al.* (2018) yaptıkları çalışmada sınıflandırma algoritmalarını kullanarak karaciğer hastalığını tahmin etmişlerdir. Kullanılan algoritmalar: LR, KNN ve SVM'dir. Algoritmaların performans ölçütü doğruluk ve karmaşıklık matrisi ile yapılmıştır. ILPD veri seti kullanılmıştır. KNN doğruluk değeri %73,97, duyarlılık değeri 0,904 ve özgüllük değeri 0,317 çıkmıştır. LR doğruluk değeri %73,97 duyarlılık değeri 0,952 ve özgüllük değeri 0,195 çıkmıştır. SVM doğruluk değeri %71,97, duyarlılık değeri 0,952 ve özgüllük değeri 0,195 çıkmıştır. Tıbbi terimde test duyarlılığı, testin hastalığı olanları doğru bir şekilde tanımlama yeteneği olduğundan, karaciğer hastalığını tahmin etmek için en iyi model LR'dir.

Deperlioğlu (2019), bu çalışmada Hepatit Hastalığının teşhisi için Derin Sinir Ağları kullanılmıştır. Oto Kodlayıcı Sinir Ağları (OKSA) ile sınıflandırma yapılmıştır. Hepatit veri seti kullanılmıştır. Veri setinin %70'i eğitim %30'u test verisi olarak kullanılmıştır. OKSA ile oluşturulan modelde dönem sayısı 1000 alınmıştır. OKSA ile yapılan sınıflandırmada 20 kez çalışma yapılmış olup doğruluk, duyarlılık ve özgüllük değerlerinin ortalaması alınmıştır. Bu ortalamaya göre en düşük doğruluk oranı %89, en yüksek doğruluk oranı ise %100 çıkmıştır. Ortalama doğruluk oranı ise: %97,82 olmuştur. Çalışmada karma yöntem olmadan, özellik seçimi yapılmadan OKSA kullanarak yapılan sınıflandırmanın doğruluk oranını artırılabilceği anlaşılmıştır. OKSA ile hepatit olan hastaların teşhisi kolay, hızlı ve verimli bir yöntem olmuştur.

Ramana *and* Boddu (2019) yaptıkları çalışmada birçok tıbbi veri kümeleri kullanarak sınıflandırma algoritmaları üzerinde çalışmıştır. Karaciğer hastalığının tıbbi teşhisi için ILPD veri seti kullanılmıştır. Torbalama (Bagging), Saf Bayes, J48, MLP, JRip ve KNN makine öğrenmesi algoritmaları kullanılarak sınıflandırma yapılmıştır. Algoritmaların performansı doğruluk, duyarlılık, kesinlik, özgüllük ve ROC ile değerlendirilmiştir. %69,30 ile Torbalama yönteminde en yüksek başarı elde edilmiştir. %68,95 başarı oranı ile MLP, %68,78 başarı oranı ile J48, %66,38 başarı oranı ile Jrip, %64,49 başarı oranı ile KNN ve %55,75 ile NB başarı oranları ölçülmüştür. Çalışmada ILPD veri seti dışında diyabet hastalığı, kronik böbrek yetmezliği gibi birçok hastalığın tıbbi teşhisi yapılmıştır. Kullanılan veri setlerinde en çok doğruluğu kronik böbrek yetmezliğinde elde etmiştir. Veri setinin tüm tıbbi veri setleri arasında en fazla öznitelige sahip olması ve çok katmanlı algı sınıflandırıcısının en yüksek sınıflandırıcı performansı veren sinir ağı sınıflandırıcılarından biri olması olabilir.

Wu *et al.* (2019) çalışmasında ML algoritmalarını kullanarak yağlı karaciğer hastalığının tahminini yapmışlardır. New Taipei şehir hastanesinde 2009 yılının aralık ayında yağlı karaciğer taraması yapılan 577 hasta veri setinde yer almıştır. 377Hasta yağlı karaciğere sahiptir. Veri seti içerisinde yaş, cinsiyet, sistolik kan basıncı (mmHg), diyastolik kan basıncı

(mmHg), karın kuşağı, trigliserit, HDL-K, Glikoz AC, GOT-AST, GPT-ALT değerleri bulunmaktadır. RF, NB, ANN, LR kullanılan sınıflandırma modelleridir. Modellerin performans değerlendirmesi ROC eğrisinin altında kalan alan ve doğruluk ile ölçülmüştür. Modellerin ROC değerleri şu şekildedir; RF %92,5, NB %88,8, ANN %89,5, LR %85,4'tür. Modellerin doğruluk değerleri ise RF %87,48, NB%82,65, ANN %81,85 ve LR %76,96'dır. Yalnızca bir tıp merkezinden veri toplanmıştır. Ancak, çok merkezli veri kümesi ve harici doğrulama daha iyi performansa ve güvenilirliğe sahip olabilir. ML değişkenleri entegrasyonu için bir sınıflandırma yaklaşımı kullanılmıştır, ancak daha iyi tahmin geliştirmek için DL yaklaşımı kullanılabilir.

Rahman *et al.* (2019) yaptıkları çalışmada kronik karaciğer hastalığı teşhisinin maliyetini tahmin ile azaltmak için ML algoritmaların performanslarını değerlendirmişlerdir. Çalışmada LR, KNN, DT, SVM, NB ML algoritmaları kullanılmıştır. Farklı sınıflandırma tekniklerinin performansı Doğruluk, kesinlik, geri çağırma ve f-1 ölçütü ölçüm teknikleri üzerinde değerlendirilmiştir. Veri seri olarak ILPD kullanılmıştır. LR %75, RF %74, DT %69, SVM %64, KNN %62, NB %53 doğruluk bulunmuştur. En yüksek doğruluk LR'de elde edilmiştir. Uygulama, karaciğer enfeksiyonunu önceden tahmin etme ve sağlık durumunu tavsiye etme seçeneğine sahip olacaktır. Bu uygulama, tıbbi temellerin ve belirli uzmanların bulunmadığı ülkelerde iyi bir yardımcı olabilir.

Keleş *et al.* (2020) yaptığı çalışmada karaciğer hastalığının teşhisi için ML algoritmaları kullanılmıştır. ILPD veri seti kullanılmıştır. Çalışma da kullanılan ML algoritmaları şu şekildedir: J48, Lojistik Model Ağacı (Logistics Model Tree (LMT)), Karar Kütüğü (Decision Stump – DS), Hoeffding Ağacı, REPTree, RF ve KNN'dir. Her bir algoritma için değerlendirme ölçütü olarak doğruluk, duyarlılık, özgüllük, ROC, Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient (MCC)), geri çağırma, kesinlik ve F-Ölçütü kullanılmıştır. J48 algoritmasında en yüksek performans ölçütü %80,8, LMT algoritmasında en yüksek performans ölçütü %80,1, Karar Kütüğü algoritmasında en yüksek performans ölçütü %92,6, Hoeffding Ağacı algoritmasında en yüksek performans ölçütü %95,7, RF algoritmasında en yüksek performans ölçütü %75,3, KNN algoritmasında en yüksek performans ölçütü %94,5 ile özgüllük olmuştur. REPTree algoritmasında en yüksek performans ölçütü %76,1, RF algoritmasında en yüksek performans ölçütü %90,2 ile ROC olmuştur. Çalışma da birçok ML yöntemleri kullanılmıştır. Performans metriklerinde MCC kullanılması ile diğer çalışmalardan farklı olmuştur. Çalışma içeriğinde yapılan diğer çalışmalar ile doğruluk karşılaştırması yapılmıştır.

Singh *et al.* (2020) yaptıkları çalışmada sınıflandırma ve öznitelik seçme tekniği kullanılarak karaciğer hastalığı tahmin edilmiştir. ILPD veri seti üzerinde çalışma yapılmıştır. Sınıflandırma için LR, SMO, RF, NB, J48 ve KNN algoritmaları kullanılmıştır. İki aşamalı olarak algoritmaların başarı oranı ölçülmüştür. Birinci aşama da veri setinde herhangi bir veri ön işleme yapmadan performans başarımları ölçülmüştür. Bu aşamada en yüksek başarı %72,53 ile RF’de elde edilmiştir. LR %72,5, SMO %71,36, J48 %68,78, KNN %64,15 ve NB %55,74 oranında başarı elde edilmiştir. İkinci aşamada ise veri setinde Özellik Seçim algoritması (Greedy Stepwise) kullanarak önemli öznitelikler belirlenip başarı ölçümü yapılmıştır. İkinci aşamada en yüksek başarı %73,36 ile LR’de elde edilmiştir. RF %71,87, SMO %71,36, j48 %70,67, KNN %67,41 ve Saf Bayes %55,90 oranında başarı elde edilmiştir. Araştırma sırasında kappa istatistiği, doğru sınıflandırılmış örnekler ve ortalama mutlak hata gibi diğer parametrelerin sonuçları da karaciğer hastalıkları veri setinde karşılaştırılmıştır. En iyi sonuç, öznitelik seçme teknikleri ile LR sınıflandırıcı kullanılarak elde edilmiş ve öznitelik seçme tekniğinin uygulanmasından sonra farklı sınıflandırıcıların yürütme süreleri azalmıştır.

Hashem *et al.* (2020) bu çalışmada karaciğerde en sık görülen Hepatit C hastalığının makine öğrenimi algoritmaları ile teşhisi yapılmıştır. Veriler Mısır’daki Kahire Üniversitesi ve Kasr Al-Aini Hastanesinden uzmanlar tarafından toplanılmıştır. Doğrusal Regresyon, Alternatif Karar Ağacı, Sınıflandırma ve Regresyon ağaçları (CART) ve REPTree sınıflandırıcı algoritmaları kullanılmıştır. Hassaslık, özgüllük, pozitif öngörme değeri, negatif tahmin değeri, doğruluk ve AUC-ROC ile Sınıflandırıcıların performansları ölçülmüştür. Alternatif karar ağacı %95,6 ile en iyi doğruluğu ve %99 ile AUC değerini göstermektedir. Makine öğrenimi teknikleri, HCC geliştirme riskini yüksek doğrulukla tahmin edebilir. Bu yöntemler, hekimlerin HCC’li hastaları teşhis etmesi ve izlemesi için verimli ve zarar verici olmayan yollar sunar. Yaş, AFP, ALP, albümin ve toplam bilirubin, HCC varlığı ile güçlü bir şekilde ilişkili bulunmuştur.

Özer (2021) çalışmasında tekrarlayan sinir ağları ile hepatit hastalığının teşhisi yapılmıştır. Veri seti kan donörü, hepatit, fibroz ve siroz olarak 4 sınıflandırmaya ayrılmıştır. İleri beslemeli Sinir Ağı (Feedforward Neural Network (FFNN)), Basit RNN, Uzun Kısa Süreli Bellek (Long Short-Term Memory (LSTM)) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit (GRU)) kullanılmıştır. Performans başarımları ölçütü olarak doğruluk, hassaslık, geri çağırma ve F1-ölçütü kullanılmıştır. Basit RNN %97,72 doğruluk değeri ile diğer modellere göre daha iyi performans göstermiştir. Tüm hastalıkların sınıflandırması F1-ölçütünde en iyi performans Basit RNN modelinde gözlenmiştir. Kullanılan veri setinin özellikleri arasında zamansal bir bağımlılık yoktur. Ancak sabit vektörlerin sıralı olarak işlenmesinin FFNN modeline göre daha iyi performans sağladığı düşünülmektedir. LSTM ve GRU modelleri de verileri sırayla işler.

Öte yandan, LSTM ve GRU daha karmaşık bir modül yapısına sahiptir ve genellikle daha yüksek miktarda veri gerektirir. Bu nedenle performanslarının Basit RNN'ye göre daha düşük olduğu düşünülmektedir.

Literatürde yapılan çalışmalar, aynı hedefe farklı yöntemler ile ulaşmıştır. Modellerde en iyi başarıyı elde edebilmek için farklı ML ve DL algoritmaları kullanılmıştır. Dandıl (2013) yaptığı çalışmada sadece Bayes teoremini kullanmıştır. Oluşturulan modellerin başarıyı için farklı ML algoritmalarının kullanılmaması bir dezavantaj oluşturmuştur. Hashem *and* Mabrouk (2014) yaptıkları çalışmada diyabet ve karaciğer hastalıklarının teşhisinin tek çalışma altında bulunması bir avantaj sağlamıştır. Gulia *et al.* (2014) yaptıkları çalışma da özellik seçiminin model başarıyı üzerindeki etkisi gözlenmiştir. Seçilen öznelilikler ile algoritmanın performansının artması bir avantajdır. Jin *et al.* (2014) yaptıkları çalışmada etkili algoritma seçmenin modelin tahmin performansını direkt olarak etkilediği sonucuna varılmıştır. Diğer yapılacak çalışmalarda göz önüne alınması gereken bir çıkarım olmuştur. Ayeldeen *et al.* (2015) çalışmasının diğer çalışmalardan farklı olarak sadece hepatit C hastalığı üzerinde çalışmıştır. Bunun yerine farklı karaciğer hastalıklarının incelenmesi çalışmanın kapsamı açısından daha iyi olacaktır. Modellerin başarıyı veri sayısının 100 olması etkilemiştir. Veri sayısının artırılması başarıyı için etkili olacaktır. Abdar *et al.* (2017) çalışmada Boosted C5.0 algoritmasında oluşturulan kurallar ile erkeklerin kadınlara göre hastalığa daha yatkın olduğu sonucuna varılmıştır. Bu kurallar ile elde edilen çıkarımlar çalışma için avantaj sağlamıştır. Hamid *et al.* (2017) yaptıkları çalışma diğer çalışmalardan farklı olarak ultrason görüntülerini kullanarak karaciğerdeki normal ve anormal durumların tespitini yapmıştır. Yapılan tahminin yanlış olabileceğini algılayabilen ML modeli geliştirilmesi çalışmanın artısı olmuştur. Auxilia (2018) yaptığı çalışmada modelin başarıyı sadece doğruluğa bakarak değerlendirilmesi çalışmanın eksik yönlerinden birisidir.

## MATERYAL VE METOT

### Materyal

#### Veri seti

Bu çalışmada kullanılan veri seti Erzurum Atatürk Üniversitesi Araştırma ve Eğitim Hastanesinin Organ Nakli Araştırma ve Uygulama Merkez Müdürlüğünde karaciğer nakli yapılan 110 hastanın bilgisini içermektedir. Veri seti 188 bağımsız değişken (Cinsiyet, boy, yaş, kilo vs.) ve dört bağımlı değişkenden (Ex, Nüks yeri, Tümör nüks, Ölüm nedeni) oluşmaktadır. Ex bağımlı değişkeni ex olma ve olmama durumunu içerir. Nüks yeri bağımlı değişkeni hastada tümör yok, tümör var ama nüks yok ve hastada tümör ve nüks var üç durum içerir. Tümör nüks bağımlı değişkeni nüks yeri bağımlı değişkeni gibi üç durum içerir. Ölüm nedeni bağımlı değişkeni kardiyak arrest, multi organ yetmezliği ve ölüm nedeni yok gibi üç durum içermektedir.

Veri setinin %80'i eğitim ve %20'si test aşamasında kullanılmak üzere ayrılmıştır. Tablo 3'te veri setinden örnek olarak ilk 10 öz niteliğin ortalama, maksimum ve minimum değerleri verilmiştir.

**Tablo 3.** Hastane Veri Seti Ortalama, Minimum ve Maksimum Değerleri

|                                 | Ortalama | Max. Değer | Min. Değer |
|---------------------------------|----------|------------|------------|
| <b>Cinsiyet</b>                 | 1,44     | 2,00       | 1,00       |
| <b>Yaş</b>                      | 40,33    | 73,00      | 1,00       |
| <b>Boy</b>                      | 160,67   | 185,0      | 1,00       |
| <b>Kilo</b>                     | 65,75    | 109,0      | 12,00      |
| <b>BMI</b>                      | 30,25    | 36,94      | 9,91       |
| <b>Kan Grubu</b>                | 3,64     | 8,00       | 1,00       |
| <b>Donör Yaşı</b>               | 34,53    | 71,00      | 0,00       |
| <b>Donör Cinsiyet</b>           | 1,34     | 2,00       | 1,00       |
| <b>Donör Akrabalık Derecesi</b> | 0,87     | 5,00       | 0,00       |
| <b>Donör Boy</b>                | 168,86   | 190,0      | 125,00     |


Bu çalışmada kullanılan diğer veri seti ILPD'dir. 416 hastalıklı karaciğer ve 167 sağlıklı karaciğer verisi bulunmaktadır. Tek bir bağımlı değişken alınmıştır. Modeller karaciğeri sağlıklı veya hastalıklı diye sınıflandırmaktadır. Tablo 4'te veri setindeki bağımsız değişkenlerin ortalama, maksimum ve minimum değerleri verilmiştir.

**Tablo 4.** ILPD Veri Seti Ortalama, Minimum ve Maksimum Değerleri

|                                  | <b>Ortalama</b> | <b>Max. Değer</b> | <b>Min. Değer</b> |
|----------------------------------|-----------------|-------------------|-------------------|
| <b>Cinsiyet</b>                  | 44,74           | 90,00             | 4,00              |
| <b>Yaş</b>                       | 0,75            | 1,00              | 0,00              |
| <b>Toplam Bilirubin</b>          | 3,29            | 75,00             | 0,40              |
| <b>Doğrudan Bilirubin</b>        | 1,48            | 19,70             | 0,10              |
| <b>Alkalın Fosfotaz</b>          | 290,57          | 2110,0            | 63,00             |
| <b>Alamin Aminotransferaz</b>    | 80,71           | 2000,0            | 10,00             |
| <b>Aspartat Aminotransferaz</b>  | 109,91          | 4929,0            | 10,00             |
| <b>Toplam Protien</b>            | 6,48            | 9,60              | 2,70              |
| <b>Albumin</b>                   | 3,14            | 5,50              | 0,90              |
| <b>Albümin ve Globulin Oranı</b> | 0,94            | 2,00              | 1,00              |

## Metot

Çalışmanın bu aşamasında veri seti üzerinde yapılan ön işleme ve özellik çıkarmaya yer verilmiştir. Kullanılan algoritmalar hakkında bilgi verilmiştir. Bu çalışmada KNN, SVM, NB, LR, DT, RF, RNN ve LSTM kullanılmıştır. Şekil 1'de çeşitli makine ve derin öğrenme yöntemleriyle karaciğer transplantasyonu sonrası karaciğer hastalıklarının tespiti için gerçekleştirilen çalışmanın tasarım akış şeması verilmiştir. Bu şemadaki her adım aşağıda alt bölümlerde detaylandırılmıştır.




**Şekil 1.** Çeşitli makine ve derin öğrenme algoritmalarının performans analizinin iş akışı

### Veri ön işleme


Makine öğreniminin başarısını birçok faktör etkiler. Verilerin kalitesi her şeyden önce gelir. Veri setinde çok fazla alakasız ve gereksiz bilgi varsa veya veriler gürültülü ve güvenilmezse, eğitim aşamasında öğrenme daha zordur. Veri ön işleme mümkün olduğunca çok alakasız ve fazla bilgiyi tanımlama ve kaldırma işlemidir. Veri ön işleme, verileri gelecekteki işlem adımlarında kullanırken daha kolay ve etkili bir biçime dönüştürmeyi amaçlar. Eksik verileri tamamlama, kategorik verileri sayısal verilere dönüştürme, boyut indirgeme, tekrarlayan verileri temizleme gibi birçok veri ön işleme yapılmıştır.

Veri setinde sayısal olmayan verilerin sayısal verilere dönüştürülmesi gerekir. Kategorik olan veriler onları temsil eden sayısal değerlere dönüştürülmüştür. Veri seti içerisindeki öznitelikler kontrol edilerek boş olan hücreler bulundukları kolonun ortalama değeri ile doldurulmuştur. Veri setinde özniteliklerde aykırı değer olup olmadığı tespit edilmiş ve aykırı veriler o özniteliğin ortalaması ile değiştirilmiştir. Şekil 2’de çalışmada kullanılan veri setinden örnek olarak ‘donör kilo’ özniteliği alınarak veri dağılım grafiği (histogram) çizilmiştir. Bu grafikte verilerin dağılımı gösterilmiştir.



**Şekil 2.** Orijinal veri setindeki donör kilo histogram grafiği

Aykırı değer şu şekilde bulur: bulunduğu öznitelikteki her değerın 0.25 ve 0,75 katı alınır aralarındaki fark alınarak çeyrekler arası açıklık bulunur. Çeyrekler arası açıklığın 1,5 katı alınır ve o değerin dışında kalan değerler aykırı olarak kabul edilir. Aykırı değerler tespit edilip veri önışleme yapıldıktan sonra donör kilodaki verilerin dağılımı şekil 3'teki gibi değışmiştir.



**Şekil 3.** Veri ön işlemeden sonra donör kilo veri dağılım grafiği (histogram).


Bu çalışmada kullanılan algoritmaların başarısına tüm değerlerin eşit olarak katkıda bulunmasını sağlamak için bu değerlerin aynı standarda ölçeklendirilmesi gerekir (Erdem, 2020). Standardizasyonu sağlamak için veri setindeki veriler, özellik standardizasyonu ile 0 ile 1 aralığında ölçeklendirildi. StandardScaler, verilerin dağılımının ortalama değeri 0 ve standart sapması 1 olacak şekilde dönüştürmesidir. Çok değışkenli veriler söz konusu olduğunda, bu özellik yapılır. Verilerin dağılımı göz önüne alındığında, veri kümesindeki her değerin ortalama değeri çıkarılır ve tüm veri kümesinin standart sapmasına bölünür. Bu amaçla Python'da sklearn.preprocessing kitaplığının StandardScaler yöntemi kullanıldı.

### Özellik çıkarma (Feature extration)

Büyük boyutlu bir veri setine sahip olmak, daha yüksek hesaplama maliyetlerine ve fazla öğrenmeye yol açan bir problemdir. Bu nedenle, veri işlemeyi kolaylaştırmak ve gerekli hesaplama kaynaklarını azaltmak, sistemin performansını iyileştirmek ve orijinal verilerden mümkün olduğunca fazla bilgi tutmak için veri seti boyutunu azaltmak istenebilir (Nobre,

2019). Bu çalışmada sınıflandırma ve boyutsallık indirgeme için yaygın olan Temel Bileşen Analizi (Principal component analysis (PCA)) ve Doğrusal Diskriminant Analizi (Linear Discriminant Analysis (LDA)) kullanıldı.

PCA, en basit ve en çok kullanılan boyut azaltma yöntemlerinden biridir ve çok sayıda boyutu olan bir veri kümesini, orijinal veri kümesinin bilgilerinin çoğunu hala içeren küçük bir veri kümesine indirmek için kullanılabilir. PCA'nın amacı, yüksek boyutlu bir veri setinin ana bileşenlerinden, veri yapısını değiştirmeden daha düşük boyutlu bir uzaya projeksiyon yapmak ve mevcut özelliklerin doğrusal bir kombinasyonu olan bir dizi temel bileşen elde etmektir (Nobre, 2019). Bu çalışmada python scikit-learn kütüphanesinden sklearn.decomposition kitaplığından PCA metodu kullanılmıştır. İlk olarak verilerin standardizasyonu uygulanmıştır. Boyut azaltma yapılırken veri içerisindeki bilgilerin yüksek oranda korunması amaçlanmıştır. Varyans değeri boyut azaltılırken veri setindeki bilgilerin ne kadar korunduğunun bilgisini verir. Veri setinde gerçek boyutu azaltmadan önce varyans değeri %100'dür. Veri setindeki gerçek boyuta kadar olan varyans değerleri şekil 4'teki grafikte verilmiştir. Grafiğe göre hangi boyutta varyans değerinin kaç olduğu verilmiştir. Buna yönelik bu aradaki değerlerin varyans değerlerine bakılmıştır. Farklı boyut değerlerine bakılıp en yüksek varyansa sahip boyut seçilmiştir. Boyut değeri 80 iken varyans değeri %99,99 çıkmıştır. Buna bakılarak PCA yöntemi uygulandığı zaman boyut 80 olarak güncellenmiştir. 109x192 boyutlu veri seti 109x80 boyuta indirgenmiştir.



**Şekil 4.** PCA uygulandığında veri setindeki boyutun varyans değerleri

LDA, sınıf içi frekansların eşit olmadığı ve performanslarının rastgele oluşturulmuş test verileri üzerinde incelendiği durumu kolayca ele alır. Veri sınıflandırması için LDA iki biçimde uygulanabilir: Sınıfa bağlı ve Sınıftan bağımsız dönüşümler. Sınıfa bağlı yaklaşım, her sınıf için ayrı ayrı sınıflar arası kovaryansın sınıf içi kovaryansa oranını maksimize etmeyi içerir. Bu, her biri bir sınıfa karşılık gelen L dönüşümleriyle sonuçlanır. Sınıftan bağımsız yaklaşım, aynı anda tüm sınıflar arasında sınıflar arası dağılımın sınıf içi dağılıma oranını maksimize etmeyi içerir (Xanthopoulos, 2013). LDA hiper parametre olarak çözücü almaktadır. Bu

çözümler şu şekildedir: 'svd': Tekil değer ayrıştırması (varsayılan). Kovaryans matrisini hesaplamaz, bu nedenle bu çözümler, çok sayıda özelliği olan veriler için önerilir. 'lsqr': En küçük kareler çözümü. Bütölme veya özel kovaryans tahmincisi ile birleştirilebilir. 'eigen': Özdeğer ayrıştırması. Bütölme veya özel kovaryans tahmincisi ile birleştirilebilir. Bütölme, modelin karmaşıklığını azaltarak, bir tür düzenleştirci görevi gören modele bir çözümler ekler. Bütölmede kullanılan çözümler 'eigen' veya 'lsqr'. Bu çalışma da sınıfa bağıli yaklaşım izlenmiştir. Daha başarılı performansı 'svd' vermiştir. Veri setinde çok sayıda özellik olduđu için parametre olarak 'svd' kullanılmıştır bu parametre verinin boyutunu otomatik olarak ayarlar. Python scikit-learn kütphanesinden sklearn.discriminant\_analysis kitaplığından LDA yöntemi kullanılmıştır. 109x192 boyutlu veri seti 109x2 boyuta indirgenmiştir.

### **Makine öğrenmesi (ML)**

ML, makinenin insan gibi düşünmesini sağlayan ve insan müdahalesi olmadan kendi başına karar verebilen yapay zekânın dalıdır. Doğrudan programlanmadan makinelerin otomatik olarak öğrenmesini sağlama sürecidir. ML'nin temel amacı, verilere erişebilen ve bunları öğrenme süreçleri için kullanabilen bir bilgisayar programı oluşturmaktır (İbrahim and Abdulazeez, 2021).

Başka bir ifadeyle ML, kabul edilebilir bir aralıkta tahminler yapmak için giriş verilerini analiz ederek, işlemleri öğrenen ve optimize eden programlanmış algoritmalarıdır. Yeni verilerin beslenmesi ile bu algoritmalar daha doğru tahminler yapma eğilimindedir (Uddin, 2019).

ML, geniş kapsamlı uygulamalarla bilgisayar biliminin en hızlı büyüyen alanlarından biridir. Verilerdeki anlamlı kalıpları otomatik olarak algılar. ML, programlara öğrenme ve uyum sağlama yeteneği kazandırır. Bir ML yapısına ne kadar fazla veri sağlanırsa, o kadar çok eğitilebilir ve üstün tahmin değerleri üretebilir (Osisanwo,2017).

Bir algoritmanın nasıl eğitildiğine ve eğitim sırasında çıktının kullanılabilirliğine bağıli olarak, ML sınıflandırılabilir. ML algoritmalarının nasıl gruplanacağına dair bazı varyasyonlar olsa da amaçlarına ve temel alınan makinenin öğretilme şekline göre üç sınıfa ayrılabilirler. Bu üç kategori: denetimli, denetimsiz ve pekiştirmeye dayalıdır (Uddin, 2019).

Denetimli öğrenme, algoritmanın girdi verilerinden verileri tahmin etmeyi öğrendiği ve bu türün girdi ve çıktı verilerine sahip olduđu anlamına gelir. Altta yatan algoritmayı eğitmek için önce etiketli bir eğitim veri kümesi kullanılır. Bu eğitilmiş algoritma daha sonra onları benzer gruplara ayırmak için etiketlenmemiş test veri kümesinden beslenir (Uddin, 2019). Denetimli öğrenme altında, bir dizi örnek veya eğitim modülü doğru çıktılarla sağlanır ve bu

eğitim setleri temelinde, algoritma çıktısını girdi olarak verilenlerle karşılaştırarak daha doğru yanıt vermeyi öğrenir. Denetimli öğrenme, örnekler yoluyla öğrenme veya örneklerden öğrenme olarak da bilinir (Alzubi,2018). Denetimli öğrenme, girdileri istenen çıktılara eşleyen bir işlev üretir.

Denetimsiz öğrenmede ise, algoritma sadece girdi verisine sahiptir ve girdi verisinden içsel yapıyı öğrenir. Denetimsiz öğrenme yaklaşımı, onlardan kurallar türetmek için verilerden tanımlanamayan mevcut kalıpları tanımakla ilgilidir. Bu teknik, veri kategorilerinin bilinmediği bir durumda uygundur. Burada, eğitim verileri etiketlenmez. Denetimsiz öğrenme, öğrenme için istatistik tabanlı bir yaklaşım olarak kabul edilir ve bu nedenle etiketlenmemiş verilerde gizli yapı bulma problemini ifade eder (Alzubi,2018).

Algoritma yalnızca çıktının doğru olup olmadığını söyleyen bir yanıtla sağlandığından, pekiştirmeli öğrenme bir ara öğrenme türü olarak kabul edilir. Algoritma, doğru çıktıyı elde etmek için çeşitli olasılıkları araştırmalı ve ekarte etmelidir. Algoritma, soruna herhangi bir öneri veya çözüm türetmez (Alzubi,2018). Pekiştirmeli öğrenmede sistem, çevre ile etkileşim yoluyla öğrenmeye çalışır ve istenen eylemi ödüllendirir ve istenmeyenleri cezalandırır. Bu yöntemlerin uygulanması, hastalıkların teşhisi gibi bir dizi tıbbi işlev için kullanılmaktadır (İbrahim, 2021).

### **Naive bayes (NB)**

Denetimli öğrenme algoritmasıdır. Bayes teoremine dayanan sınıflandırma tekniğidir. Bu teorem, o olayla ilgili koşulların ön bilgisine dayalı olarak bir olayın olasılığını tanımlayabilir. Temsil edilen B olayının belirli bir önceki olasılığı aşağıdaki gibi  $P(A|B)$  ile:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \quad (1)$$

- A ve B olaylardır.
- $P(A)$  ve  $P(B)$ , A ve B'yi birbirinden bağımsız olarak gerçekleşme olasılıklarıdır.
- $P(A/B)$  koşullu olasılıktır, yani B'nin doğru olduğu durumda A'nın gerçekleşme olasılığıdır.
- $P(B/A)$ , A'nın doğru olduğu durumda B'nin gerçekleşme olasılığıdır.

NB sınıflandırıcıları, özellikler arasında güçlü bağımsızlık varsayımlarına sahip Bayes Teoremi kavramına dayanan basit olasılıklı sınıflandırıcılar kategorisine girer. Özellikle girdilerin boyutlarının yüksek olduğu durumlarda uygundur (Alzubi, 2018).

Bu sınıflandırıcı, bir sınıftaki belirli bir özelliğin, o sınıfa ait özelliklerin kendi aralarında karşılıklı bağımlılığa sahip olabilmesine rağmen, başka herhangi bir özellikle




veya girişinin, regresyon modelini kullanarak belirli bir sınıfa ait olduğunu tahmin eden bir regresyon modelidir. Lojistik regresyon, uygulama basitliği, hesaplama etkinliği, eğitime dayalı etkinlik, düzenleme kolaylığı gibi birçok önemli noktaya sahiptir. Giriş özellikleri için ölçeklendirmeye gerek yoktur (İbrahim, 2021). Doğrusal olmayan bir problemi çözmek zordur. Aşırı uyum gösterebilir. Sınıflandırma için sigmoid fonksiyonu kullanır. Sigmoid veri setindeki verileri 0 ile 1 arasına sıkıştırmak için kullanılır. Matematiksel formülü denklem 2’de bulunmaktadır. X girdi verilerini,  $\Theta$  katsayıyı temsil eder. ANN de sigmoid aktivasyon fonksiyonu olarak kullanılır.

$$\sigma(x) = \frac{1}{e^{-(\Theta x)}} \quad (2)$$

Bu çalışmada lojistik regresyon parametre olarak random\_state=0 alındı. Kodda random state belirlenmezse eğitim verileri değişeceğinden doğruluk da her çalıştırma için değişir. Bu nedenle sabit bir sayı tanımladığımızda her çalıştırmada eğitim verileri sabit olacaktır. Farklı çalıştırmalarda aynı eğitim ve test verilerini elde ederiz.


### **Karar ağacı (DT)**

Denetimli öğrenme algoritmasıdır. DT, en eski ve önde gelen ML algoritmalarından biridir. DT, belirli bir değişkene bağlı olarak verileri art arda bölerek regresyon ve sınıflandırma sorunlarını çözmek için makine öğreniminde kullanılan bir algoritmadır. Veriler düğümlere bölünür ve ağacın yaprağı nihai kararları temsil eder. DT’nin amacı, eğitim verilerinden türetilen basit karar kurallarını öğrenerek hedef değişkeni tahmin etmek için kullanılabilecek bir model oluşturmaktır. Ağaç, bir eğitim süreci sırasında eğitim verileri kullanılarak oluşturulur. Yaprak düğümler sınıfın adını tutarken, karar düğümü yaprak olmayan bir düğümdür. DT, kategorik ve sayısal verileri yönetir. Bir DT, karar mantıklarını modeller, yani veri öğelerini ağaç benzeri bir yapı içinde sınıflandırmak için sonuçları test eder ve bunlara karşılık gelir (İbrahim, 2021). Hem regresyon hem de sınıflandırma için kullanılır. Sayısal ve kategorik verilerin işlenmesi kolaydır. Birçok parametre almaktadır. Bunlardan birisi ‘criterion’ ve farklı iki değer alır. ‘gini’ ve ‘entropy’ bu iki değerdir. Bu parametre hem regresyon hem de sınıflandırma karar ağaçları için geçerlidir. Bu iki değer genellikle çok benzer sonuçlar verse de performans farkı vardır. Entropi logaritmik algoritma kullandığından gini daha hızlıdır. Entropi, keşifsel üstünlük sağlayabilirken, gini yanlış sınıflandırmalar için avantajlı olabilir. Bu çalışmada hem performans açısından hem de amacın sınıflandırma olması nedeniyle ‘gini’ parametresi seçilmiştir. Daha büyük ağaçların yorumlanması zordur. Şekil 6’da DT yapısının görselleştirilmiş hali verilmiştir.




**Şekil 6.** DT yapısı

Bu çalışmada DT criterion = 'gini', max\_depth=5 parametrelerini almıştır. Criterion, düğüm saflığını gösteren değerdir. Düğüm daha saf olduğunda, gini indeksi değeri daha küçüktür ve sıfıra yakındır. DT algoritması, bu değer sıfıra ulaşana kadar veya onu durduracak başka bir parametre olmadığı sürece düğümleri böler. Max\_depth kök düğüm ile yaprak düğüm arasındaki yolu temsil eder. Ağacın maksimum derinliğini gösterir. Ağaç ne kadar derin olursa, o kadar çok bölünmeye sahip olur ve veriler hakkında daha fazla bilgi yakalar. 1 ile 32 arasında değişen derinliklere sahip bir karar ağacı yerleştirilip eğitim ve test auc değerleri çizildi. Çizilen değerler doğrultusunda derinlik 5'ten büyük olduğunda auc değerleri maksimum noktada olduğu için derinlik 5 olarak alınmıştır. Şekil 7'de derinlik değerlerine karşılık auc değerleri verilmiştir.



**Şekil 7.** DT'de derinlik değerlerine karşılık auc değeri

Şekil 8'de bu çalışmada seçilen parametreler doğrultusunda oluşan örnek olarak bağımlı değişken ex için DT yapısı gösterilmiştir.



**Şekil 8.** Bu çalışmada önerilen ex bağımlı değişken için DT yapısı

### Rastgele orman (RF)

Denetimli öğrenme algoritmasıdır. Bu algoritmada, en üstte bir girdi girilir ve veriler, ağaçtan geçerken daha küçük kümeler halinde toplanır. RF, ağaçları bir topluluk kavramıyla birleştirerek bu kavramı bir sonraki düzeye taşır. RF sınıflandırıcısının yararı, çalışma sürelerinin kısa olması, dengesiz olması ve eksik verilerin ele alınabilmesidir. RF’de, yeni veri kümesi veya test verileri, oluşturulan tüm alt ağaçlara dağıtılır. Ormandaki her karar alt ağacının, veri kümesinin sınıfına karar vermesine izin verilir. Daha sonra model, çoğunluk oylamasından en uygun sınıfı seçecektir. Regresyon ve sınıflandırma problemi için kullanılabilir (İbrahim, 2021).

Bu çalışmada RF algoritması parametre olarak  $n\_estimators=10$  almıştır. Bu parametre tahmin ortalamalarını almadan önce inşa edilen ağaç sayısıdır. Daha fazla sayıda ağaç daha iyi performans sağlar ancak kod yavaşlayacağından işlemcinin kaldırabileceği kadar yüksek bir değer seçilmiştir çünkü bu, tahminleri daha güçlü ve daha kararlı hale getirmektedir.

### K – En yakın komşu (KNN)


Denetimli öğrenme algoritmasıdır. KNN algoritması, en basit ve en eski sınıflandırma algoritmalarından biridir. Bir NB sınıflandırıcısının daha basit bir versiyonu olarak düşünülebilir. NB tekniğinden farklı olarak, KNN algoritması olasılık değerlerini dikkate almayı gerektirmez (Uddin, 2019). Diğer yöntemlerden farklıdır, çünkü bu algoritma önce bir model oluşturmadan verileri doğrudan sınıflandırma için kullanır. Bu nedenle, model yapımının hiçbir detayının dikkate alınmasına gerek yoktur ve modeldeki tek ayarlanabilir parametre, sınıf üyeliği tahminine dâhil edilecek en yakın komşuların sayısı olan  $k$ 'dir (Dreiseitl, 2002).

Bu çalışma da KNN algoritması parametre olarak  $n\_neighbors=7$  almıştır.  $n\_neighbors$  bir öğeyi sınıflandırırken kaç komşunun kontrol edilmesi gerektiğini düzenler. Maksimum komşu sayısı verinin eğitim ve test olarak ayrıldıktan sonra eğitimde olan verilerin sayısı kadardır. Maksimum komşu sayısına kadar tüm  $k$  değerleri denenmiş olup bir dizide tutulmuştur. Dizinin maksimum elemanı ve indeksi bulunarak en iyi başarıyı veren  $k$  değeri belirlenmiştir. Dizi Şekil 9’da verilmiştir.

**Şekil 9. K değerleri dizisi**

$$(\sum_{i=1}^n |p_i - q_i|^p)^{1/p} \quad (3)$$


DL, bir makine öğrenimi şeklidir. Makine öğreniminden farklı olarak, derin öğrenme ağlarında özellik çıkarma ve sınıflandırma açıkça yapılmaz. DL ağının gizli katmanları, tüm bunları, harici araştırmacıyı dahil etmeden, dolaylı olarak kendi içinde yapar (Swapna, 2018). DL, tüm katmanların bir önceki katmandan aldığı bilgi ve sonucu kendinden sonraki katmana ilettiği birden çok katmandan oluşur. YSA, insan beyninin bilgiyi nasıl analiz ettiğini ve işlediğini taklit eder (Irmak, 2021). YSA biyolojik olarak sinir ağlarını örnek almaktadır. Bir sinir ağı, elektrik uyarılarının beyinde yayılmasına yardımcı olan nöron hücrelerinin birbirine bağlanmasıdır. Bir sinir ağındaki temel öğrenme birimi, sinir hücresi olan nörondur. Bir nöron, dendritler (reseptör), soma (elektrik sinyali işlemcisi), çekirdek (nöronun çekirdeği) ve akson (nöronun verici ucu) olmak üzere dört bölümden oluşur. Şekil 10'da nöron hücre yapısı verilmiştir.



**Şekil 10.** Nöron hücresi yapısı

Biyolojik sinir ağına benzer şekilde, bir YSA üç katman üzerinde çalışır: girdi katmanı, gizli katman ve çıktı katmanı. Bu ağ türü, ağırlıklı ara bağlantılara sahiptir ve paralel dağıtılmış işlemi gerçekleştirmek için ara bağlantıların ağırlıklarını ayarlayarak öğrenir (Dreiseitl, 2002).

YSA modelleri dörde ayrılır. Bunlar tek katmanlı algılayıcı, çok katmanlı algılayıcı, ileri beslemeli ve geri beslemeli YSA'dır. Tek katmanlı algılayıcı sadece girdi ve çıktıdan oluşur. YSA çalışmaları ilk olarak tek katmanlı algılayıcılar ile başlamıştır. Doğrusal olan olaylar çözüme ulaşabilirken olmayan olayları öğrenemediğinden yeni modeller oluşturulmuştur. MLP doğrusal olmayan olayları öğrenebilmesi için geliştirilen bir modeldir. En yaygın kullanılan modeldir. Üç katmandan oluşur girdi katmanı, gizli katman ve çıktı katmanı. Girdi katmanı dış dünyadan gelen verileri alır. Bu katmanda herhangi bir veri işleme alınmaz. Ara katman girdi katmanından gelen verileri işler, çözüme kavuşturur ve sonucu çıktı katmanına aktarır. Çıktı katmanı kendisine gelen veriyi işler ve dış dünyaya aktarır. İleri beslemeli sinir ağına tek yönlü bilgi akışı mevcuttur. Çok katmanlı algılayıcı gibi girdi verileri gizli katmana aktarılır. Gizli ve çıktı katmanı bilgiyi işler ve bir çıkış üretir.




**Şekil 11.** YSA modeli

Şekil 11'de çok katmanlı ve ileri beslemeli YSA mevcuttur. Geri beslemeli sinir ağı modelinin ileri beslemeli sinir ağından farkı, bilgi tek yönlü akmaz. Bilgi gizli ve çıktı katmanında hem ileri yönlü hem de geri yönlü aktarılır. Dinamik bir hafıza söz konusudur. Bir çıkış bir sonraki giriş olabileceğinden bu bilgi hafızada tutulur (Öztemel, 2003).

## Tekrarlayan sinir ağıları (RNN)


RNN, her biri diğer her düğüme yönlendirilmiş (tek yönlü) bağlantıya sahip nöronları taklit eden bir düğüm ağıdır. Her düğümün zamanla değişen gerçek değerli bir aktivasyonu vardır. Her bağlantı (sinaps), her yinelemede değiştirilebilen gerçek değerli bir ağırlığa sahiptir. Düğümler, ya ağına dışından veri almak için giriş düğümleri ya da sonuç veren çıkış düğümleridir ya da girdiden çıktıya giden yolları aracılığıyla içlerinden geçen verileri değiştiren gizli düğümlerdir. İleri beslemeli sinir ağından türetilmiştir. Geleneksel ileri beslemeli sinir ağlarından farkı, RNN'nin girdi dizilerini işlemek için diğer adıyla bellek olarak bilinen dâhili durumunu kullanabilmesidir (Swapna, 2018).

Şekil 12’de bir RNN yapısı verilmiştir. Şekil 12’de ki A bir yapay sinir ağında hücreyi temsil ederken,  $x$  girdi verilerini,  $h$  çıktı verilerini temsil etmektedirler. Hücreden çıkan değer tekrar kendisine gelerek bir döngü oluşturur. Döngü sayesinde YSA geçmiş bilgileri de kullanarak sınıflandırma yapar. Eşitliğin sol tarafında RNN’nin  $t$  sayıda girdi ve çıktılarından oluşan genel yapısı verilmiştir. Eşitliğin sağ tarafı ise RNN’nin açılmış şeklidir.



**Şekil 12.** RNN yapısı (Olah, 2015)


Bu çalışmada YSA bir giriş katmanı bir çıkış katmanı ve üç tane gizli katmandan oluşur. Aktivasyon fonksiyonu olarak ‘Relu’ kullanılmıştır. Oluşturulan modelde en iyi sonuca varmak için uygun hiper-parametreler seçilmiştir. Eğitim tur sayısı (epoch) 1000 alınmıştır. Eğitim tur sayısı eğitim kaç turda tanımlanacağını verir. Model eğitim ve test aşamasında tüm verileri aynı anda işleme almaz verileri alt kümlere böler. Alt küme boyutu (batch size) 10 alınmıştır. Şekil 13’te örnek olarak ex bağımlı değişken için modelin görselleştirilmiş hali verilmiştir.



**Şekil 13.** Bu çalışmada önerilen RNN model


### Uzun kısa süreli bellek (LSTM)

LSTM, RNN'nin geliştirilmiş bir şeklidir. Bu ağlar, tekrarlayan ağların uzun vadeli bağımlılık sorunundan kurtulmak için tasarlanmıştır. RNN'ler uzun geçmişi hatırlamazlar bu nedenle farklı bir mimariye ihtiyaç duyulmuştur. LSTM mimarisinin gelişmesiyle birlikte bu sorun ortadan kalkmıştır. LSTM'ler bilgileri uzun süre hatırlamakta iyidir. Daha önceki bilgiler modelin doğruluğunu etkileyebileceğinden, LSTM'ler doğal bir kullanım seçimi haline gelir (Kumar, 2018). Şekil 14'te LSTM genel yapısı gösterilmiştir.



**Şekil 14.** LSTM yapısı (Olah, 2015)

LSTM, RNN'den farklı olarak tek bir nöral ağ katmanını yerine dört tane nöral ağ katmanını vardır. Standart RNN'den farklı olarak LSTM ünitesinin giriş sayısı çıkış sayısından fazladır. Giriş portu, çıkış portu ve unutma portu, LSTM biriminin girişleridir ve ağ tarafından diğer birimler için yalnızca tek bir çıkış kullanılır. Unutma portu hücre durumundaki bilginin hafızada saklanıp saklanmayacağını tutar. Şekil 15'te LSTM birim içeriğinin görselleştirilmiş hali verilmiştir.




**Şekil 15.** LSTM unutma katmanının yapısı (Olah, 2015)

Formül 4’te unutma katmanının formülü verilmiştir. Unutma katman yapısı “geçit katmanını unut” olarak adlandırılan sigmoid bir katman tarafından tutulur.  $h_{t-1}$  Ve  $x_t$ ’ye bakar ve  $C_{t-1}$  hücre durumundaki her sayı için 0 ile 1 arasında bir sayı verir. 1, “bunu tamamen sakla”yı temsil ederken, 0, “bundan tamamen kurtul” temsil eder.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

Bir sonraki aşama giriş kapısı. Bu aşamada hücrede bilginin saklanıp saklanmayacağını bilgisi belirlenir. Sigmoid sinir ağı ve tanjant katmanı olarak giriş kapısı ikiye ayrılır. Sigmoid kısmında güncellenecek değerin hangisi olacağına karar verilir. Tanjant katmanında saklanması gereken değerden vektör oluşturulur. Giriş kapısında bu iki değerin birleştirilmesi ile yeni bir değer elde edilir. Şekil 16’da giriş kapısı yapısının görselleştirilmiş hali verilmiştir.




**Şekil 16.** LSTM giriş kapısı yapısı ve formülü (Olah, 2015)

Formül 5’te unutma katmanının formülü verilmiştir. İlk olarak, “giriş kapısı katmanı” adı verilen bir sigmoid katman, hangi değerleri güncelleyeceğimize karar verir. Daha sonra, bir tanh katmanı yeni aday değerlerin bir vektörünü yaratır,  $\hat{C}_t$  bu duruma eklenebilir.

$$I_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_i)$$

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

Bu aşamada giriş kapısından geçen birleştirilip oluşan değerin yeni değer ile güncellemesi yapılır. Durum için bir güncelleme oluşturmak için bu ikisini birleştireceğiz. Şekil 17’de eski değerin yeni değer ile güncellenme kısmı gösterilmiştir.




**Şekil 17.** Eski değerin yeni değer ile güncellenmesi (Olah, 2015)

Eski değerin yeni değere güncellenme durumu formül 6’da verilmiştir. Eski hücre durumunu,  $C_{t-1}$ ’i yeni hücre durumu  $C_t$ ’ye güncelleme zamanı. Daha önce unutmaya karar verdiğimiz şeyleri unutarak eski durumu  $f_t$  ile çarpıyoruz. Sonra  $*C_t$  eklenir. Bu, her bir durum değerini güncellemeye ne kadar karar verdiğimizize göre ölçeklenen yeni aday değerlerdir.

$$C_t = f_t * C_t - 1 + i_t * \hat{C}_t \quad (6)$$

Değerin güncellenmesi gerçekleştikten sonra çıkış kapısına yönlendirilir. Çıkış kapısı tanjant ve sigmoid katmanlarından oluşur. Bu katmanlardan gelen değerler çarpılarak çıkan değer çıktı olarak belirlenir. Şekil 18’de LSTM biriminin çıkış yapısı gösterilmiştir.




**Şekil 18.** LSTM çıkış kapısı yapısı (Olah, 2015)

Formül 7’de LSTM çıkış kapısı hesaplaması verilmiştir. Son olarak, ne çıktı alınacağına karar verilmeli. Bu çıktı, hücre durumumuza dayalı olacaktır, ancak filtrelenmiş bir versiyon olacaktır. İlk olarak, hücre durumunun hangi bölümlerinin çıktısını alacağımıza karar veren bir sigmoid katman çalıştırılır. Daha sonra, hücre durumunu tanh (değerleri -1 ile 1 arasında olacak) ile koyulur ve sigmoid geçidinin çıktısı ile çarpılır, böylece sadece karar verilen kısımlar çıkartılır.

$$h_t = o_t * \tanh(C_t)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

Bu çalışmada model bir giriş, bir çıkış ve iki tane gizli katmandan oluşur. Aşırı öğrenmenin önüne geçebilmek için 0,2’lik seyreltme yapılmıştır. Oluşturulan modelde en iyi sonuca varmak için uygun hiper-parametreler seçilmiştir. Optimizasyon metotlarından Stochastic Gradient Descent, RMSProp ve Adam metotları denenmiştir. En uygun metot ‘Adam’ seçilmiştir. Eğitim tur sayısı (epoch) 500, alt küme boyutu (batch size) 72 alınmıştır. Şekil 19’da örnek olarak ex bağımlı değişken için modelin görselleştirilmiş hali verilmiştir.



**Şekil 19.** Bu çalışmada önerilen ex bağımlı değişken için LSTM model

## ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu tez çalışmasında ML ve DL ile oluşturulan modeller eğitildi ve test edildi. Modeller belirli performans metrikleri ile karşılaştırıldı. Modellerin performans değerlendirilmesi birkaç performans metriğine göre yapılmıştır. Dengeli dağılmayan veri setlerinde modellerin performansını sadece bir metriğe göre değerlendirmek yeterli olmayabilir. Bu çalışma da performans metriği olarak: Hassasiyet (Precision-PR), duyarlılık (Recall-RE), F1-skoru (F1-SC), doğruluk (Accuracy-ACC) ve işlem karakteristik eğrisi (Receiver Operating Characteristic- ROC) kullanılmıştır. İkili sınıflandırma probleminde, 2x2 karmaşıklık matrisi, dört olası sonucun her biri tarafından tahmin edilen örneklerin sayısını gösterir: gerçek pozitiflerin sayısı (True Positive-TP), gerçek negatiflerin sayısı (True Negative-TN), yanlış pozitiflerin sayısı (False Positive-FP) ve yanlış negatif sayısı (False Negative-FN). Birçok sınıflandırıcı performans metriği, bu dört değerden türetilir. Şekil 20’de örnek olarak ex bağımlı değişkeni alınarak karmaşıklık matrisi gösterilmiştir.



Şekil 20. 2x2 Karmaşıklık matrisi (a), modelin karmaşıklık matrisi (b)

Bu karmaşıklık matrisinde;

EE : Ex iken model tarafından ex olarak bulunanları,

EH : Hayatta iken model tarafından ex olarak bulunanları,

HE : Ex iken model tarafından hayatta bulunanları,

HH : Hayatta iken model tarafından hayatta olarak bulunanları, temsil etmektedir.

Doğruluk oluşturduğumuz modelin başarısını vermektedir. Doğru sınıflandırılmış verilerin toplam veri sayısına bölünmesi ile elde edilir. Veri setinde dengesiz dağılım söz konusu ise bu gibi durumlarda etkili olduğunu söylemek mümkün değildir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

Kesinlik, modelin pozitif dediği örneklerin gerçekten pozitif olma olasılığıdır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (9)$$

Duyarlılık modelin pozitif dediği örneklerin ne kadarını pozitif tahmin ettiğini gösterir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (10)$$

F1-skoru modelin sağlamlığının ölçüsüdür. 0-1 arasında değere sahiptir. Kesinlik ve duyarlılık metriklerinin harmonik ortalaması ile hesaplanmaktadır.

$$F1 - skor = \frac{2xDuyarlılıkxKesinlik}{Duyarlılık + Kesinlik} \quad (11)$$

ROC eğrisi duyarlılık değerlerinin, yanlış pozitif oranına karşılığıdır. ROC eğrisi grafiksel yaklaşımı duyarlılık ve yanlış pozitif oran arasındaki ilişkiyi kavramayı kolaylaştırır. Grafiğin x ekseninde yanlış pozitif oran yer alırken, y ekseninde duyarlılık yani doğru pozitif oran yer alır. İdeal performans gösteren ROC eğrisi sol süt köşeye yaklaştıkça artar (Ertosun, 2010).

### Hastane Veri Seti İle Yapılan Çalışmalar

Herhangi bir özellik çıkarma tekniği kullanılmadan önce ex bağımlı değişkenine bağlı olarak oluşturulan ML ve DL modellerinden elde edilen sonuçlar tablo 5'te verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %88 hassasiyet, %86 duyarlılık ve %83 f1-skor ile SVM ve RF, %86 doğruluk ile LR, KNN, SVM ve RF diğer modellere göre yüksek performans göstermiştir.

**Tablo 5.** Ex Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 82             | 82             | 82            | 86           |
| KNN      | 67             | 82             | 74            | 86           |
| SVM      | 88             | 86             | 83            | 86           |
| NB       | 72             | 55             | 60            | 54           |
| DT       | 75             | 77             | 76            | 77           |
| RF       | 88             | 86             | 83            | 86           |
| RNN      | 67             | 82             | 74            | 81           |
| LSTM     | 67             | 82             | 74            | 81           |

Herhangi bir özellik çıkarma tekniği kullanılmadan önce nüks yeri bağımlı değişkenine bağlı olarak oluşturulan ML ve DL modellerinden elde edilen sonuçlar tablo 6’da verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %81 hassasiyet ile DT, %82 duyarlılık ile RNN ve LSTM, %74 f1-skor ile RNN ve LSTM, %82 doğruluk ile RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 6.** Nüks Yeri Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 53             | 73             | 61            | 72           |
| KNN      | 53             | 73             | 61            | 72           |
| SVM      | 53             | 73             | 61            | 72           |
| NB       | 53             | 73             | 61            | 72           |
| DT       | 81             | 77             | 72            | 72           |
| RF       | 53             | 73             | 61            | 73           |
| RNN      | 67             | 82             | 74            | 82           |
| LSTM     | 67             | 82             | 74            | 82           |

Herhangi bir özellik çıkarma tekniği kullanılmadan önce tümör nüks bağımlı değişkenine bağlı olarak oluşturulan ML ve DL modellerinden elde edilen sonuçlar tablo 7’de verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %62 hassasiyet, %79 duyarlılık, %69 f1-skor ve %79 doğruluk ile RNN ve LSTM ile diğer modellere göre yüksek performans göstermiştir.

**Tablo 7.** Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 46             | 68             | 55            | 31           |
| KNN      | 46             | 68             | 55            | 68           |
| SVM      | 46             | 68             | 55            | 68           |
| NB       | 46             | 68             | 55            | 68           |
| DT       | 51             | 68             | 58            | 68           |
| RF       | 46             | 68             | 55            | 68           |
| RNN      | 62             | 79             | 69            | 79           |
| LSTM     | 62             | 79             | 69            | 79           |

Herhangi bir özellik çıkarma tekniği kullanılmadan önce ölüm nedeni yeri bağımlı değişkenine bağlı olarak oluşturulan ML ve DL modellerinden elde edilen sonuçlar tablo 8’de verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %85 hassasiyet ile RF,

%86 duyarlılık ile LR, DT ve RF, %85 f1-skor ile RF ve %86 doğruluk ile DT ve RF diğer modellere göre yüksek performans göstermiştir.

**Tablo 8.** Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 82             | 86             | 84            | 81           |
| KNN      | 73             | 77             | 75            | 77           |
| SVM      | 67             | 82             | 74            | 82           |
| NB       | 75             | 68             | 70            | 68           |
| DT       | 84             | 86             | 82            | 86           |
| RF       | 85             | 86             | 85            | 86           |
| RNN      | 67             | 82             | 74            | 81           |
| LSTM     | 67             | 82             | 74            | 82           |

PCA yöntemi kullanılarak ex bağımlı değişkenine bağlı olarak oluşturduğumuz ML ve DL modellerinden elde edilen sonuçlar tablo 9’da verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %92 hassasiyet, %91 duyarlılık, %90 f1-skor, %90 doğruluk ile DT diğer modellere göre yüksek performans göstermiştir.

**Tablo 9.** PCA’lı Ex Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 85             | 86             | 86            | 86           |
| KNN      | 75             | 77             | 76            | 77           |
| SVM      | 79             | 82             | 79            | 81           |
| NB       | 75             | 77             | 76            | 77           |
| DT       | 92             | 91             | 90            | 90           |
| RF       | 82             | 82             | 82            | 82           |
| RNN      | 67             | 82             | 75            | 81           |
| LSTM     | 67             | 82             | 74            | 81           |

PCA yöntemi kullanılarak nüks yeri bağımlı değişkenine bağlı olarak oluşturduğumuz ML ve DL modellerinden elde edilen sonuçlar tablo 10’da verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %67 hassasiyet ile RNN ve LSTM, %82 duyarlılık ile RNN ve LSTM, %74 f1-skor ile RNN ve LSTM, %82 doğruluk ile RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 10.** PCA’lı Nüks Yeri Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 46             | 68             | 55            | 68           |
| KNN      | 46             | 68             | 55            | 68           |
| SVM      | 46             | 68             | 55            | 68           |
| NB       | 46             | 68             | 55            | 68           |
| DT       | 46             | 68             | 55            | 68           |
| RF       | 46             | 68             | 55            | 68           |
| RNN      | 67             | 82             | 74            | 82           |
| LSTM     | 67             | 82             | 74            | 82           |

PCA yöntemi kullanılarak tümör nüks bağımlı değişkenine bağlı olarak oluşturduğumuz ML ve DL modellerinden elde edilen sonuçlar tablo 11’de verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %62 hassasiyet, %79 duyarlılık, %69 f1-skor, %79 doğruluk ile RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 11.** PCA’lı Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 46             | 68             | 55            | 68           |
| KNN      | 46             | 68             | 55            | 68           |
| SVM      | 46             | 68             | 55            | 68           |
| NB       | 46             | 68             | 55            | 68           |
| DTC      | 46             | 68             | 55            | 68           |
| RF       | 45             | 64             | 53            | 64           |
| RNN      | 62             | 79             | 69            | 79           |
| LSTM     | 62             | 79             | 69            | 79           |

PCA yöntemi kullanılarak ölüm nedeni bağımlı değişkenine bağlı olarak oluşturduğumuz ML ve DL modellerinden elde edilen sonuçlar tablo 12’de verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri: %80 hassasiyet ile LR, %82 duyarlılık ile LR, DT, RF, RNN ve LSTM, %81 f1-skor ile LR, %82 doğruluk ile SVM, DT, RF, RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 12.** PCA’lı Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 80             | 82             | 81            | 81           |
| KNN      | 73             | 77             | 75            | 77           |
| SVM      | 67             | 82             | 74            | 82           |
| NB       | 66             | 77             | 71            | 77           |
| DT       | 76             | 82             | 79            | 82           |
| RF       | 67             | 82             | 74            | 82           |
| RNN      | 67             | 82             | 74            | 82           |
| LSTM     | 67             | 82             | 74            | 82           |

LDA yöntemi kullanılarak ex bağımlı değişken ile oluşturduğumuz modellerden elde edilen sonuçlar tablo 13’te verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri %86 hassasiyet ile LR, KNN, SVM ve NB, %82 duyarlılık ile LR, KNN, SVM, NB, RNN ve LSTM, %83 f1-skor ile LR, KNN, SVM ve NB, %82 doğruluk ile LR, KNN ve SVM diğer modellere göre yüksek performans göstermiştir.

**Tablo 13.** LDA’lı Ex Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 86             | 82             | 83            | 82           |
| KNN      | 86             | 82             | 83            | 82           |
| SVM      | 86             | 82             | 83            | 82           |
| NB       | 86             | 82             | 83            | 77           |
| DT       | 84             | 77             | 79            | 77           |
| RF       | 84             | 77             | 79            | 77           |
| RNN      | 67             | 82             | 74            | 81           |
| LSTM     | 67             | 82             | 74            | 81           |

LDA yöntemi kullanılarak nüks yeri bağımlı değişken ile oluşturduğumuz modellerden elde edilen sonuçlar tablo 14’te verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri %67 hassasiyet, %82 duyarlılık, %74 f1-skor, %82 doğruluk ile RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 14.** LDA’lı Nüks Yeri Bağımlı Değişken İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 52             | 68             | 59            | 68           |
| KNN      | 53             | 73             | 61            | 73           |
| SVM      | 53             | 73             | 61            | 73           |
| NB       | 52             | 68             | 59            | 68           |
| DT       | 55             | 73             | 63            | 72           |
| RF       | 55             | 73             | 63            | 72           |
| RNN      | 67             | 82             | 74            | 82           |
| LSTM     | 67             | 82             | 74            | 82           |

LDA yöntemi kullanılarak tümör nüks bağımlı değişken ile oluşturduğumuz modellerden elde edilen sonuçlar tablo 15’te verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri %76 hassasiyet ile LR, %79 duyarlılık, %69 f1-skor ve %79 doğruluk ile RNN ve LSTM diğer modellere göre yüksek performans göstermiştir.

**Tablo 15.** LDA’lı Tümör Nüks Bağımlı Değişkeni İçin Performans Metrikleri


| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 76             | 73             | 65            | 73           |
| KNN      | 46             | 68             | 55            | 68           |
| SVM      | 46             | 68             | 55            | 68           |
| NB       | 76             | 73             | 65            | 73           |
| DT       | 49             | 68             | 57            | 68           |
| RF       | 49             | 68             | 57            | 68           |
| RNN      | 62             | 79             | 69            | 79           |
| LSTM     | 62             | 79             | 69            | 79           |

LDA yöntemi kullanılarak ölüm nedeni bağımlı değişken ile oluşturduğumuz modellerden elde edilen sonuçlar tablo 16’da verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri %86 hassasiyet ile DT, %86 duyarlılık ile LR, SVM ve NB, %85 f1-skor ile LR, SVM ve NB, %86 doğruluk ile LR ve SVM diğer modellere göre yüksek performans göstermiştir.

**Tablo 16.** LDA’lı Ölüm Nedeni Bağımlı Değişkeni İçin Performans Metrikleri

| Modeller | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|----------|----------------|----------------|---------------|--------------|
| LR       | 85             | 86             | 85            | 86           |
| KNN      | 80             | 82             | 81            | 82           |
| SVM      | 85             | 86             | 85            | 86           |
| NB       | 85             | 86             | 85            | 68           |
| DT       | 86             | 73             | 75            | 73           |
| RF       | 84             | 82             | 81            | 73           |
| RNN      | 62             | 79             | 69            | 79           |
| LSTM     | 62             | 79             | 69            | 79           |

Veri seti eğitim ve test olarak ayrılırken özniteliğin dağılımına bağlı olarak sapmalar olabilir. Eğitim ve testte meydana gelen sapmalar hatalara neden olur bu hataların önüne geçebilmek için modelde k sayısı kadar çapraz doğrulama (k fold cross-validation) yöntemi uygulanmıştır. Bu yöntem veriyi rastgele karıştırarak belirlenen k değerine göre çaprazlama bir şekilde parçalar. Her parça eğitim ve test için kullanılır. Böylelikle oluşan hata asgariye indirgenir. Veri eğitim ve test olarak ayrılmadan önce farklı k değerlerine göre doğruluk değerlerine bakılmıştır. Birçok kez çalıştırma sonucunda veri setimiz için ideal doğruluk değeri 0,771 çıkmıştır. Şekil 21’de ki grafikte ise k değerlerine karşılık gelen doğruluk gösterilmiştir.

**Şekil 21.** N katmanlı çapraz doğrulama

Şekil 22’de k değerlerine karşılık ortalama doğruluk, minimum ve maksimum değerler verilmiştir.


```

Ideal: 0.771
> k=2, ortalama doğruluk=0.688 min ve max değerler (0.648,0.727)
> k=3, ortalama doğruluk=0.706 min ve max değerler (0.694,0.722)
> k=4, ortalama doğruluk=0.717 min ve max değerler (0.607,0.778)
> k=5, ortalama doğruluk=0.698 min ve max değerler (0.545,0.864)
> k=6, ortalama doğruluk=0.727 min ve max değerler (0.526,0.889)
> k=7, ortalama doğruluk=0.733 min ve max değerler (0.600,0.812)
> k=8, ortalama doğruluk=0.734 min ve max değerler (0.538,1.000)
> k=9, ortalama doğruluk=0.754 min ve max değerler (0.583,1.000)
> k=10, ortalama doğruluk=0.745 min ve max değerler (0.545,0.909)
> k=11, ortalama doğruluk=0.790 min ve max değerler (0.700,0.900)
> k=12, ortalama doğruluk=0.753 min ve max değerler (0.556,1.000)
> k=13, ortalama doğruluk=0.771 min ve max değerler (0.625,1.000)
> k=14, ortalama doğruluk=0.783 min ve max değerler (0.500,1.000)
> k=15, ortalama doğruluk=0.782 min ve max değerler (0.500,1.000)
> k=16, ortalama doğruluk=0.774 min ve max değerler (0.571,1.000)
> k=17, ortalama doğruluk=0.800 min ve max değerler (0.500,1.000)
> k=18, ortalama doğruluk=0.800 min ve max değerler (0.500,1.000)
> k=19, ortalama doğruluk=0.760 min ve max değerler (0.333,1.000)
> k=20, ortalama doğruluk=0.783 min ve max değerler (0.333,1.000)
> k=21, ortalama doğruluk=0.797 min ve max değerler (0.333,1.000)
> k=22, ortalama doğruluk=0.798 min ve max değerler (0.400,1.000)
> k=23, ortalama doğruluk=0.772 min ve max değerler (0.250,1.000)
> k=24, ortalama doğruluk=0.769 min ve max değerler (0.250,1.000)
> k=25, ortalama doğruluk=0.768 min ve max değerler (0.250,1.000)

```

**Şekil 22.** N katmanlı çapraz doğrulama

Bu çalışma da ML modellerin performanslarının daha etkin bir şekilde çalışması için k değeri 13 seçilmiştir. Bu işlem için Python scikit-learn kütüphanesi ile gerçekleştirilmiştir. Şekil 23'te n tane k değeri için eğitim ve test verilerine göre çapraz doğrulama yapılmıştır.



**Şekil 23.** N katmanlı çapraz doğrulama

$$Doğruluk = \frac{1}{N} \sum_{i=1}^N A_i \quad (12)$$

Formül 12'de N tane k değeri için çapraz doğrulamanın doğruluk değeri verilmiştir. Alınan k değerine göre veri seti eşit parçalara ayrılmış ve her birinin çıkış değeri toplanmıştır.

Modellere herhangi yöntem uygulamadan, PCA, LDA uygulandıktan sonraki üç durum için k sayısı kadar çapraz doğrulama yapılmıştır. Ex bağımlı değişken ile oluşturulan modellerin çapraz doğrulama sonrası doğruluk değerleri tablo 17'de verilmiştir.

**Tablo 17.** Çapraz Doğrulama Sonrası Ex Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri

| Modeller | NON-METHOD (%) | PCA (%) | LDA (%) |
|----------|----------------|---------|---------|
| LR       | 85             | 82      | 98      |
| KNN      | 87             | 88      | 98      |
| SVM      | 82             | 82      | 98      |
| NB       | 82             | 82      | 98      |
| DT       | 82             | 85      | 97      |
| RF       | 82             | 84      | 97      |
| RNN      | 67             | 82      | 74      |
| LSTM     | 67             | 82      | 74      |

Nüks yeri bağımlı değişken ile oluşturulan modellerin çapraz doğrulama sonrası doğruluk değerleri Tablo 18’de verilmiştir.

**Tablo 18.** Çapraz Doğrulama Sonrası Nüks Yeri Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri

| Modeller | NON- METHOD (%) | PCA (%) | LDA (%) |
|----------|-----------------|---------|---------|
| LR       | 96              | 96      | 98      |
| KNN      | 96              | 96      | 96      |
| SVM      | 96              | 96      | 96      |
| NB       | 96              | 96      | 96      |
| DT       | 94              | 89      | 98      |
| RF       | 96              | 95      | 98      |
| RNN      | 77              | 94      | 96      |
| LSTM     | 77              | 94      | 98      |

Tümör nüks bağımlı değişken ile oluşturulan modellerin çapraz doğrulama sonrası doğruluk değerleri Tablo 19’da verilmiştir.

**Tablo 19.** Çapraz Doğrulama Sonrası Tümör Nüks Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri


| Modeller | NON- METHOD (%) | PCA (%) | LDA (%) |
|----------|-----------------|---------|---------|
| LR       | 96              | 96      | 99      |
| KNN      | 96              | 96      | 96      |
| SVM      | 96              | 96      | 96      |
| NB       | 96              | 96      | 96      |
| DT       | 94              | 88      | 99      |
| RF       | 96              | 96      | 97      |
| RNN      | 97              | 94      | 95      |
| LSTM     | 97              | 93      | 98      |

Ölüm nedeni bağımlı değişken ile oluşturulan modellerin çapraz doğrulama sonrası doğruluk değerleri Tablo 20’de verilmiştir.

**Tablo 20.** Çapraz Doğrulama Sonrası Ölüm Nedeni Bağımlı Değişkeni İçin Modellerin Doğruluk Değerleri


| Modeller | NON- METHOD (%) | PCA (%) | LDA (%) |
|----------|-----------------|---------|---------|
| LR       | 92              | 87      | 99      |
| KNN      | 89              | 86      | 99      |
| SVM      | 86              | 83      | 98      |
| NB       | 69              | 85      | 95      |
| DT       | 83              | 75      | 97      |
| RF       | 89              | 82      | 98      |
| RNN      | 86              | 82      | 94      |
| LSTM     | 86              | 82      | 94      |

Bu çalışmada ex bağımlı değişkenin k çapraz doğrulama yapıldıktan sonra ML ve DL ile oluşturulan modellerde ortalama en yüksek sonuçlar PCA ve LDA yöntemi kullanılarak elde edilmiştir. Şekil 24’te LDA yöntemi ile modellerin en yüksek sonuç verdiği karmaşıklık matrisleri verilmiştir.




**Şekil 24.** LDA'lı ex bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi


LDA yöntemi ile ex bağımlı değişkeninin DL modellerinden RNN ve LSTM kayıp ve doğruluk fonksiyon grafikleri şekil 25 ve şekil 26'da verilmiştir. Kayıp fonksiyonu azalma seyretmiştir. Grafiklerdeki bu azalma modelin hatasının azalmasını göstermektedir. Modellerin doğruluğu eğitim ve test aşamasında senkron olması modelin öğrendiği şekilde tahmin ettiğini göstermektedir.



**Şekil 25.** LDA'lı ex bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri




(a)



(b)


**Şekil 26.** LDA'lı ex bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri

Şekil 27'de LDA yöntemi ile ex bağımlı değişkenine bağlı oluşturulan tüm modellerin doğruluk oranları grafikte gösterilmiştir. Birçok modelin doğruluk oranı benzerlik gösterirken en yüksek doğruluk değeri L, SVM ve KNN'de gözlenmiştir.




**Şekil 27.** LDA'lı ML ve DL modellerinin ex bağımlı değişkeni için doğruluk değer grafiği

Şekil 28'te ex bağımlı değişken için farklı ML ve DL algoritmaların ROC eğrisi verilmiştir.




(a)



(b)


**Şekil 28.** LDA'lı ex bağımlı değişken için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b)

Bu çalışmada nüks yeri bağımlı değişkenin ML ve DL ile oluşturulan modellerde ortalama en yüksek sonuçlar k çapraz doğrulama yapılarak elde edilmiştir. Şekil 29’da LDA yöntemi ile oluşturulan modellerin en yüksek sonuç verdiği karmaşıklık matrisleri verilmiştir.




**Şekil 29.** LDA'nı nüks yeri bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi

LDA yöntemi ile nüks bağımlı değişkenin DL modellerinden RNN ve LSTM kayıp ve doğruluk fonksiyon grafikleri Şekil 30 ve Şekil 31’de verilmiştir. Kayıp fonksiyonu epoch değeri arttıkça azalma göstermiştir. Grafiklerdeki bu azalma modelin hatasının azalmasını göstermektedir. Modellerin doğruluğu eğitim ve test aşamasında senkron olması modelin öğrendiği şekilde tahmin ettiğini göstermektedir.




(a)




(b)

**Şekil 30.** LDA'lı nüks yeri bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri




(a)



(b)


**Şekil 31.** LDA'lı nüks yeri bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri

Şekil 32'de nüks yeri bağımlı değişkenine bağlı oluşturulan tüm modellerin doğruluk oranları grafikte gösterilmiştir. Birçok model aynı doğruluk oranı gösterirken en yüksek doğruluk değeri RNN ve LSTM'de gözlenmiştir.




**Şekil 32.** LDA'lı ML ve DL modellerinin nüks yeri bağımlı değişken doğruluk değer grafiği

Şekil 33'te nüks yeri bağımlı değişken için farklı ML ve DL algoritmaların ROC eğrisi verilmiştir.




**Şekil 33.** LDA'lı nüks yeri bağımlı değişken için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b)

Bu çalışmada tümör nüks bağımlı değişkenin ML ve DL ile oluşturulan modellerde en yüksek sonuçlar k çapraz doğrulama kullanılarak elde edilmiştir. Şekil 34'te LDA yöntemi ile oluşturulan modellerin karmaşıklık matrisleri verilmiştir.




**Şekil 34.** LDA'lı tümör nüks bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi

Tümör nüks bağımlı değişkeninin DL modellerinden RNN ve LSTM kayıp ve doğruluk fonksiyon grafikleri Şekil 35 ve Şekil 36’da verilmiştir. Kayıp fonksiyonu epoch değeri arttıkça azalma göstermiştir. Grafikteki bu azalma modelin hatasının her öğrenmede azaldığını göstermektedir.




**Şekil 35.** LDA'lı tümör nüks bağımlı değişkeninin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri




**Şekil 36.** LDA'lı tümör nüks bağımlı değişkeninin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri

Şekil 37’de Tümör nüks bağımlı değişkenine bağlı oluşturulan tüm modellerin doğruluk oranları grafikte gösterilmiştir. RNN ve LSTM %79 doğruluk oranı ile en yüksek performansı göstermişlerdir.




**Şekil 37.** LDA'lı ML ve DL modellerinin tümör nüks bağımlı değişken doğruluk değer grafiği

Şekil 38’de tümör nüks bağımlı değişken için farklı ML ve DL algoritmalarının ROC eğrisi verilmiştir.




**Şekil 38.** LDA'lı tümör nüks bağımlı değişkenin ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b)

Bu çalışmada ML ve DL ile oluşturulan modellerde en yüksek sonuçlar k çapraz doğrulama kullanılarak elde edilmiştir. Şekil 39'da LDA ile oluşturulan modellerin karmaşıklık matrisleri verilmiştir.




**Şekil 39.** LDA'lı ölüm nedeni bağımlı değişkenin ML ve DL modellerinin karmaşıklık matrisi

Ölüm nedeni bağımlı değişkeninin DL modellerinden RNN ve LSTM kayıp ve doğruluk fonksiyon grafikleri Şekil 40 ve Şekil 41’de verilmiştir. Kayıp fonksiyonu epoch değeri arttıkça azalma seyretmiştir. Grafiklerdeki bu azalma modelin hatasının azalmasını göstermektedir.




(a)




(b)

**Şekil 40.** LDA’lı ölüm nedeni bağımlı değişkenin LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri




(a)



(b)


**Şekil 41.** LDA’lı ölüm nedeni bağımlı değişkenin RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri

Şekil 42’de ölüm nedeni bağımlı değişkenine bağlı oluşturulan tüm modellerin doğruluk oranları grafikte gösterilmiştir. LR ve SVM %86 doğruluk ile en yüksek performans göstermişlerdir.




**Şekil 42.** LDA’lı ML ve DL modellerinin ölüm nedeni bağımlı değişken doğruluk değer grafiği

Şekil 43’te ölüm nedeni bağımlı değişken için farklı ML ve DL algoritmalarının ROC eğrisi verilmiştir.



(a)



(b)

**Şekil 43.** LDA'lı ölüm nedeni bağımlı değişkenin ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b)

### ILPD İle Yapılan Çalışmalar


Bu bölümde ILPD veri seti ile yapılan çalışmalara yer verilmiştir. Veri seti gerekli ön işlemeden geçirilmiştir. %67'si eğitim ve %33'ü test verisi olarak ayrılmıştır.

Tablo 21'de oluşturulan modellerin performans metrikleri verilmiştir. Elde edilen sonuçlar doğrultusunda performans metrikleri %82 hassasiyet ile NB, %71 duyarlılık ile RNN ve LSTM, %66 f1-skor ile DT ve RF ve %82 doğruluk ile RNN ve LSTM, diğer modellere göre yüksek performans göstermiştir.

**Tablo 21.** ILPD Veri Seti İle Oluşturulan Modellerin Performans Metrikleri


| Modeller    | Hassasiyet (%) | Duyarlılık (%) | F1 – Skor (%) | Doğruluk (%) |
|-------------|----------------|----------------|---------------|--------------|
| <b>LR</b>   | 64             | 69             | 63            | 69           |
| <b>KNN</b>  | 61             | 63             | 62            | 63           |
| <b>SVM</b>  | 59             | 69             | 58            | 69           |
| <b>NB</b>   | 82             | 57             | 57            | 57           |
| <b>DT</b>   | 66             | 66             | 66            | 66           |
| <b>RF</b>   | 65             | 69             | 66            | 69           |
| <b>RNN</b>  | 50             | 71             | 59            | 82           |
| <b>LSTM</b> | 50             | 71             | 59            | 82           |

Şekil 44'te ILPD veri seti ile oluşturulan tüm modellerin doğruluk oranları grafikte gösterilmiştir. Birçok model aynı doğruluk oranı gösterirken en yüksek doğruluk değeri RNN ve LSTM'de gözlenmiştir.




**Şekil 44.** ILPD verisi için ML ve DL modellerinin doğruluk değer grafiği

ML ve DL modellerin en yüksek doğrulukları RNN ve LSTM de gözlenmiştir. Veri seti içerisinde test için ayrılan verilerden kaç tanesinin doğru tahmin edildiği karmaşıklık matrislerinde verilmiştir. Şekil 45'te modellerin karmaşıklık matrisleri verilmiştir.




**Şekil 45.** ILPD verisi için ML ve DL modellerinin karmaşıklık matrisi

Şekil 46’da ILPD veri seti için farklı ML ve DL algoritmaların ROC eğrisi verilmiştir.




Şekil 46. ILPD verisi için ML modellerinin ROC eğrisi (a) ve DL modellerinin ROC eğrisi (b)

DL modellerinden RNN ve LSTM kayıp ve doğruluk fonksiyon grafikleri Şekil 47 ve Şekil 48’de verilmiştir. Kayıp fonksiyonu epoch değeri arttıkça azalma seyretmiştir



Şekil 47. ILPD verisi için RNN kayıp (a) ve doğruluk (b) fonksiyon grafikleri



Şekil 48. ILPD verisi için LSTM kayıp (a) ve doğruluk (b) fonksiyon grafikleri

Bu tez çalışmasında ILPD veri seti ile en yüksek doğruluk %82 başarımları sağlamıştır. Yapılan diğer çalışmaların başarımları ise şu şekildedir: Hashem *and* Mabrouk (2014) yaptıkları çalışmada ILPD veri seti ile en yüksek doğruluk %73,2 başarımları sağlamıştır. Gulia *et al.* (2014) yaptıkları çalışmada ILPD veri setinde en yüksek doğruluk %71,35 başarımları sağlamıştır. Jin *et al.* (2014) yaptıkları çalışmada ILPD veri seti ile en yüksek doğruluk %96,55 başarımları sağlamıştır. Abdar *et al.* (2017) yaptıkları çalışmada ILPD veri seti ile en yüksek doğruluk %93,75 başarımları sağlamıştır. Alaybeyoğlu ve Mülâyim (2018) yaptıkları çalışmada en yüksek doğruluk %75 başarımları sağlamıştır. Auxilia (2018) yaptığı çalışmada %81 ile en yüksek başarımları sağlamıştır. ILPD veri seti ile yapılan çalışmaların yılı, metodu ve doğruluk oranları Tablo 22’de verilmiştir.

**Tablo 22.** ILPD Veri Seti İle Literatürde Yapılan Çalışmaların Doğruluk Oranları

| Çalışma                   | Yıl  | Metod        | Doğruluk (%) |
|---------------------------|------|--------------|--------------|
| Hashem <i>and</i> Mabrouk | 2014 | SVM          | 73           |
| Gulia <i>et al.</i>       | 2014 | Bayes Net    | 71           |
| Jin <i>et al.</i>         | 2014 | RF           | 96           |
| Abdar <i>et al.</i>       | 2017 | Boosted C5.0 | 93           |
| Alaybeyoğlu ve Mülâyim    | 2018 | SVM          | 75           |
| Auxilia                   | 2018 | DT           | 81           |
| Bu çalışma                | 2022 | RNN, LSTM    | 82           |

## SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında karaciğer nakli sonrası hastaların ML ve DL yöntemleri ile karaciğer hastalıklarının teşhisi, yaşam kalitesi ve ölüm durumları değerlendirilmiştir. Veri seti olarak Erzurum Atatürk Üniversitesi Eğitim ve Araştırma Hastanesinin organ nakli bölümünde karaciğer nakli olan 110 hastanın bilgisi yer almaktadır. Bu bilgiler içerisinde canlı ve kadavra vericinin yaşı, cinsiyeti, kadavranın ölüm nedeni, alıcının kan sonuçları, nakil sırasında gerçekleşen işlemler, kullanılan kan miktarı, nakil sonrası enfeksiyon oluşması gibi birçok durumu belirten 188 öznitelik bulunmaktadır.

Toplanan verilere ön işleme yapılmıştır. Veri ön işleme aşamasında veriler içerisinde aykırı değer olup olmadığı, boş veri kontrolü, tekrar eden veri temizleme gibi işlemlerden geçirilmiştir. Veri ön işlemeden sonra veri seti eğitim (%80) ve test (%20) olarak ikiye ayrılmıştır. Oluşturulan modelin performansını artırmak için özellik çıkarma yöntemlerinden PCA ve LDA kullanılmıştır. ML algoritmalarından NB, SVM, LR, RF, DT ve KNN kullanılmıştır. DL algoritmalarından ise RNN ve LSTM kullanılmıştır.

Bu çalışmada oluşturulan modellerin performansını ölçmek için farklı performans metrikleri kullanılmıştır. Kullanılan performans metrikleri şu şekildedir: hassasiyet, duyarlılık, f1-skor ve doğruluk. K çapraz doğrulama ile en yüksek doğruluk değerleri elde edilmiştir.

Ex bağımlı değişkeni için k çapraz doğrulama ile PCA yöntemi uygulandığında %96 ile en yüksek doğruluk LR, KNN, SVM ve NB vermiştir. K çapraz doğrulama ile LDA uygulandığında %98 ile en yüksek doğruluğu LR, KNN, SVM ve NB vermiştir.

Nüks yeri bağımlı değişkeni için k çapraz doğrulama ile PCA yöntemi uygulandığında %96 ile en yüksek doğruluk LR, KNN, SVM ve NB vermiştir. K çapraz doğrulama ile LDA uygulandığında %98 ile en yüksek doğruluğu LR, DT, RF ve LSTM vermiştir.

Tümör nüks bağımlı değişkeni için k çapraz doğrulama ile PCA yöntemi uygulandığında %96 ile en yüksek doğruluk LR, KNN, SVM, RF ve NB vermiştir. K çapraz doğrulama ile LDA uygulandığında %99 ile en yüksek doğruluğu LR ve DT vermiştir.

Ölüm nedeni bağımlı değişkeni için k çapraz doğrulama ile PCA yöntemi uygulandığında %87 ile en yüksek doğruluk LR vermiştir. K çapraz doğrulama ile LDA uygulandığında %99 ile en yüksek doğruluğu LR ve KNN vermiştir.

Sonuç olarak, önerilen modeller ile oluşturulan yeni veri seti kullanılarak karaciğer nakli sonrasında hastaların yaşam kalitesini etkileyen durumların tahmini gerçekleştirilmiştir. Bu tez

alışmasında literatürden farklı olarak kendi oluşturduğumuz veri seti kullanılmıştır. Literatüre yeni bir veri seti ile katkı sağlanmıştır.

Gelecek alışmalarda daha fazla veri ile daha yüksek sonuçlar almayı hedeflemekteyiz. Sadece karaciğer nakli değil, diğer organ nakilleri içinde bu alışmayı uygulanabilir hale getirmeyi amaçlamaktayız. Bu sayede çeşitli veri setleri oluşturma imkânı elde etmiş ve başka organ nakli bölümlerinde uygulanabilir hale getirmeyi amaçlamaktayız.



## KAYNAKLAR

- Abdar, M., Zomorodi-Moghadam, M., Das, R., & Ting, I. H. (2017). Performance analysis of classification algorithms on early detection of liver disease. *Expert Systems with Applications*, 67, 239-251.
- Acarlı, K. (2020). Karaciğer Sağlığını Koruyan 10 Hayati Öneri. Erişim adresi <https://www.memorial.com.tr/saglik-rehberi/karaciger-sagligini-koruyan-10-hayati-oneri> (28.12.2021)
- Alzubi, J., Nayyar, A., & Kumar, A. (2018, November). Machine learning from theory to algorithms: an overview. In *Journal of physics: conference series* (Vol. 1142, No. 1, p. 012012). IOP Publishing.
- Alaybeyoglu, A., & Mulayim, N. (2018) Karaciğer Kanseri Teşhisinde Destek Vektör Makinesi Tabanlı Uzman Sistem Tasarımı Support Vector Machine based Expert System Design for Liver Disorder Diagnosis. *Tıp Tekno'18*. 208-210
- Anonim, Karaciğer Yetmezliği Nedir, Neden Olur? Belirtileri, Teşhisi Ve Tedavisi. Erişim adresi <https://www.medikalakademi.com.tr/karaciger-yetmezligi-nedir-neden-olur-belirtileri-teshisi-ve-tedavisi/> (30.12.2021)
- Auxilia, L. A. (2018, May). Accuracy prediction using machine learning techniques for indian patient liver disease. In *2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI)* (pp. 45-50). IEEE
- Ayeldeen, H., Shaker, O., Ayeldeen, G., & Anwar, K. M. (2015, November). Prediction of liver fibrosis stages by machine learning model: A decision tree approach. In *2015 Third World Conference on Complex Systems (WCCS)* (pp. 1-6). IEEE.
- Borulday, M. G., Yegin, E. G., Mahouti, P., & Gunes, F. Diagnosing Liver Diseases with Decision Tree Algorithm. *International Journal on Technical and Physical Problems of Engineering (IJTPE)*, (33), 67-70.
- De Villa, V. H., Lo, C. M., & Chen, C. L. (2003). Ethics and rationale of living-donor liver transplantation in Asia. *Transplantation*, 75(3), S2-S5.
- Doku, Organ Nakli ve Diyaliz Hizmetleri Daire Başkanlığı. Organ Karar Destek Sistemi. Erişim adresi [https://organkds.saglik.gov.tr/dss/PUBLIC/Transplant\\_Solid\\_Organ.aspx](https://organkds.saglik.gov.tr/dss/PUBLIC/Transplant_Solid_Organ.aspx) (28.12.2021)
- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of biomedical informatics*, 35(5-6), 352-359.
- Dandıl, E. (2013). Karaciğerde Oluşan Hastalıkların Tespitinde Makine Öğrenmesi Yöntemlerinin Kullanılması, *Akademik Bilişim Konferans Bildirileri*, 614-617.
- Deperlioglu, Ö. (2019). Derin Sinir Ağları ile Hepatit Hastalığı Teşhisi, *Ecsac'19 19th European Conference On Science, Artculture*, 467-473.
- Ertosun, A. D., Bağ, B., Uzar, G., & Turanoğlu, M. A. (2010). ROC (Receiver Operating Characteristic) Eğrisi Yöntemi İle Tanı Testlerinin Performanslarının Değerlendirilmesi. XII. Öğrenci Sempozyumu Çalışma Grubu Raporları. XII. Öğrenci Sempozyumu Çalışma Grubu Raporları, 1-7.
- Gulia, A., Vohra, R., & Rani, P. (2014). Liver patient classification using intelligent techniques. *International Journal of Computer Science and Information Technologies*, 5(4), 5110-5115.

- Hamid, K., Asif, A., Abbasi, W., & Sabih, D. (2017, December). Machine learning with abstention for automated liver disease diagnosis. In *2017 International Conference on Frontiers of Information Technology (FIT)* (pp. 356-361). IEEE.
- Hashem, E. M., & Mabrouk, M. S. (2014). A study of support vector machine algorithm for liver disease diagnosis. *American Journal of Intelligent Systems*, 4(1), 9-14.
- Hashem, S., ElHefnawi, M., Habashy, S., El-Adawy, M., Esmat, G., Elakel, W., ... & Shousha, H. I. (2020). Machine learning prediction models for diagnosing hepatocellular carcinoma with HCV-related chronic liver disease. *Computer methods and programs in biomedicine*, 196, 105551.
- Hashikura, Y., Makuuchi, M., Kawasaki, S., Matsunami, H., Ikegami, T., Nakazawa, Y., ... & Ichida, T. (1994). Successful living-related partial liver transplantation to an adult patient. *The Lancet*, 343(8907), 1233-1234.
- Ibrahim, I., & Abdulazeez, A. (2021). The role of machine learning algorithms for diagnosing diseases. *Journal of Applied Science and Technology Trends*, 2(01), 10-19.
- Irmak, Coşkun. (2021). *Bulut Tabanlı Derin Öğrenme Modelleri Kullanılarak İnsansı Robotlarda Duygu Analizi*. Yüksek Lisans Tezi, Atatürk Üniversitesi.
- İlhan, N., & SAĞALTICI, D. (2020). Twitter'da duygu analizi. *Harran Üniversitesi Mühendislik Dergisi*, 5(2), 146-156.
- Jin, H., Kim, S., & Kim, J. (2014). Decision factors on effective liver patient data prediction. *International journal of Bio-science and Bio-Technology*, 6(4), 167-178.
- Kasapoğlu, B., Yalçın, K. S., & Türkay, C. (2010). Canlı donörden karaciğer transplantasyonu. *Güncel Gastroenteroloji*, 14(2), 96-102.
- Keleş, A., Karslı, Ö. B., & Keleş, A. (2020). Makine Öğrenme Algoritmaları ile Karaciğer Hastalığının Teşhisi. *Turkish Studies-Information Technologies and Applied Sciences*, 15(1), 75-83.
- Kumar, J., Goomer, R., & Singh, A. K. (2018). Long short term memory recurrent neural network (LSTM-RNN) based workload forecasting model for cloud datacenters. *Procedia Computer Science*, 125, 676-682.
- Montazeri, M. (2014). Machine learning models for predicting the diagnosis of liver disease. *Koomesh*, 16(1), 53-59.
- Ma, H., Xu, C. F., Shen, Z., Yu, C. H., & Li, Y. M. (2018). Application of machine learning techniques for clinical predictive modeling: a cross-sectional study on nonalcoholic fatty liver disease in China. *BioMed research international*, 2018.
- Nobre, J., & Neves, R. F. (2019). Combining principal component analysis, discrete wavelet transform and XGBoost to trade in the financial markets. *Expert Systems with Applications*, 125, 181-194.
- Olah, C. (2015, Ağustos 27). Understanding LSTM Networks. Erişim adresi <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (20.06.2022)
- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Özer, İ. (2021, February). Recurrent Neural Network Based Methods For Hepatitis Diagnosis. In *International Symposium of Scientific Research and Innovative Studies* (Vol. 22, p. 25).

- Öztemel, E. (2003). Yapay sinir ağıları. PapatyaYayincılık, İstanbul.
- Rahman, A. S., Shamrat, F. J. M., Tasnim, Z., Roy, J., & Hossain, S. A. (2019). A comparative study on liver disease prediction using supervised machine learning algorithms. *International Journal of Scientific & Technology Research*, 8(11), 419-422.
- Ramana, B. V., & Boddu, R. S. K. (2019, January). Performance comparison of classification algorithms on medical datasets. In *2019 IEEE 9th annual computing and communication workshop and conference (CCWC)* (pp. 0140-0145). IEEE.
- Singh, J., Bagga, S., & Kaur, R. (2020). Software-based prediction of liver disease with feature selection and classification techniques. *Procedia Computer Science*, 167, 1970-1980.
- Singh, A. S., Irfan, M., & Chowdhury, A. (2018, December). Prediction of liver disease using classification algorithms. In *2018 4th international conference on computing communication and automation (ICCCA)* (pp. 1-3). IEEE.
- Starzl, T. E., Groth, C. G., Brettschneider, L., Penn, I., Fulginiti, V. A., Moon, J. B., ... & Porter, K. A. (1968). Orthotopic homotransplantation of the human liver. *Annals of surgery*, 168(3), 392
- Swapna, G., Vinayakumar, R., & Soman, K. P. (2018). Diabetes detection using deep learning algorithms. *ICT express*, 4(4), 243-246.
- Taşdoğan, B. E. (2019). Karaciğer Nasıl Bir Organdır? Vücutta Ne Yapar?
- Uddin, S., Khan, A., Hossain, M. E., & Moni, M. A. (2019). Comparing different supervised machine learning algorithms for disease prediction. *BMC medical informatics and decision making*, 19(1), 1-16.
- Xanthopoulos, P., Pardalos, P. M., & Trafalis, T. B. (2013). Linear discriminant analysis. In *Robust data mining* (pp. 27-33). Springer, New York, NY.
- Wu, C. C., Yeh, W. C., Hsu, W. D., Islam, M. M., Nguyen, P. A. A., Poly, T. N., ... & Li, Y. C. J. (2019). Prediction of fatty liver disease using machine learning algorithms. *Computer methods and programs in biomedicine*, 170, 23-29.

## ÖZGEÇMİŞ

|                             |                                                                                                    |
|-----------------------------|----------------------------------------------------------------------------------------------------|
| <b>Kişisel Bilgiler</b>     |                                                                                                    |
| <b>Adı Soyadı:</b>          | Zeynep BİLEN                                                                                       |
| <b>Doğum tarihi:</b>        |                                                                                                    |
| <b>Doğum Yeri:</b>          |                                                                                                    |
| <b>Uyruğu:</b>              |                                                                                                    |
| <b>Adres:</b>               |                                                                                                    |
| <b>Tel:</b>                 |                                                                                                    |
| <b>E-mail:</b>              |                                                                                                    |
| <b>Eğitim</b>               |                                                                                                    |
| <b>Lise:</b>                | Anadolu İmam Hatip Lisesi                                                                          |
| <b>Lisans:</b>              | Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği (2013 – 2018)                 |
| <b>Yüksek lisans:</b>       | Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (2018 – 2022) |
| <b>Yabancı Dil Bilgisi</b>  |                                                                                                    |
| <b>İngilizce:</b>           | Orta                                                                                               |
| <b>Projeler ve Yayınlar</b> |                                                                                                    |
|                             |                                                                                                    |