

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE IN VITRO
FERTİLİZASYON TEDAVİ BAŞARISININ
TAHMİNLENMESİ**

**Hazırlayan
Rabia PEMİK**

**Danışman
Prof. Dr. Lale ÖZBAKIR**

Yüksek Lisans Tezi

**Eylül 2024
KAYSERİ**

T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE IN VITRO
FERTİLİZASYON TEDAVİ BAŞARISININ
TAHMİNLENMESİ
(Yüksek Lisans Tezi)

Hazırlayan
Rabia PEMİK

Danışman
Prof. Dr. Lale ÖZBAKIR

Eylül 2024
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Rabia PEMİK

İmza

“Makine Öğrenmesi Yöntemleriyle In Vitro Fertilizasyon Tedavi Başarısının Tahminlenmesi” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Rabia PEMİK

İmza

Danışman

Prof. Dr. Lale ÖZBAKIR

İmza

Endüstri Mühendisliği ABD Başkanı

Prof. Dr. Lale ÖZBAKIR

İmza

Prof. Dr. Lale ÖZBAKIR danışmanlığında **Rabia PEMİK** tarafından hazırlanan “**Makine Öğrenmesi Yöntemleriyle In Vitro Fertilizasyon Tedavi Başarısının Tahminlenmesi**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Endüstri Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

22/08/2024

JÜRİ:

Danışman : Prof. Dr. Lale ÖZBAKIR

Üye : Prof. Dr. Hülya TORUN

Üye : Dr. Öğr. Üyesi M. Merhad AY

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 26.09.2024 tarih ve 721594 sayılı kararı ile onaylanmıştır.

...../...../.....

Prof. Dr. Emel KIZILKAYA AYDOĞAN

Enstitü Müdürü

TEŐEKKÜR

Öncelikle, alıőmalarım boyunca bana rehberlik eden, her türlü yardımı ve fedakârlığı sağlayan, her adımda beni destekleyen, bilgi ve tecrübesi ile bana yol gösteren saygıdeğer tez danışmanım Prof. Dr. Lale ÖZBAKIR'a en içten teşekkürlerimi sunarım.

Ayrıca hem lisans hem yüksek lisans eğitimim süresince bilgi ve deneyimlerinden faydalandığım Endüstri Mühendisliği Bölümü Akademisyenler 'ine bana sağladıkları eğitim ve verdikleri değerli tavsiyeler için minnettarım.

Araştırmamı yaparken verilerin toplanması ve kullanılması sürecinde bana yardımcı olan Erciyes Üniversitesi Kadın Hastalıkları ve Doğum Ana Bilim Dalı Tüp Bebek Ünitesi yetkililerine, çalışanlarına ve Doç. Dr. Fulya ÇAĞLI'ya teşekkür ederim.

Bu süreçte moral ve motivasyon kaynağım olan sevgili eşim Fevzi PEMİK'e her koşulda yanımda olan ve desteğini esirgemeyen anneme sonsuz teşekkürlerimi sunarım.

Rabia PEMİK

Eylül 2024, KAYSERİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE IN VITRO FERTİLİZASYON TEDAVİ BAŞARISININ TAHMİNLENMESİ

Rabia PEMİK

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Eylül 2024
Danışman: Prof. Dr. Lale ÖZBAKIR**

ÖZET

İnfertilite, dünya çapında yetişkin nüfusun yaklaşık %17,5'inde görülen önemli bir sağlık sorunudur. In Vitro Fertilizasyon (IVF), infertil çiftler için yaygın ve etkili bir tedavi yöntemidir. Bu çalışma, IVF tedavisi alan çiftlerde parametrelerin klinik gebelik sonucuna etkisinin analiz edilerek tedavi başarısını makine öğrenmesi algoritmaları ile tahminlemeyi amaçlamaktadır. Bu kapsamda IVF tedavisi alan 3627 çiftin 40 farklı öznelikten oluşan sağlık verileri incelenmiştir. Tedavi başarısının tahmini için çeşitli makine öğrenmesi algoritmalarından; SVM, C4.5, CART, Rastgele Orman, k-NN, Naive Bayes, Lojistik Regresyon, ANN, Gradyan ve Uyarlamalı Arttırma kullanılmıştır. Tedavi başarısı iki farklı yaklaşımla tahmin edilmiştir. İlk yaklaşımda, çiftlerin tedavi süreci dahil tüm verileri analiz edilerek tedavi başarısı (başarılı=1 veya başarısız=0) tahmin edilmiştir. İkinci yaklaşımda ise, çiftlerin tedaviye başlama/başlamama kararını seçebilmelerini desteklemek amacıyla sadece tedavi öncesi verileri analiz edilerek tedavinin başarılı olma olasılığı tahmin edilmiştir. Tedavi tahmin başarılarını arttırmak için normalizasyon, veri dengeleme ve öznelik seçimi yöntemleri uygulanarak performans metriklerine göre algoritmalar karşılaştırılmıştır. Elde edilen sonuçlara göre, 10-kat çapraz doğrulama ve Pearson korelasyonu ile öznelik seçimi kullanılarak **tedavi başarısının tahmini; %96,59** doğruluk değeriyle Rastgele Orman algoritmasıyla gerçekleştirilmiştir. Tedavi öncesi verileriyle çiftlerin **tedavisinin başarılı olma olasılığı** ise **%91,40** doğruluk oranıyla yine Rastgele Orman algoritmasıyla tahmin edilmiştir. Bu çalışma IVF tedavi başarısını yüksek doğruluk oranlarıyla tahmin etmek için makine öğrenmesi algoritmalarının etkin bir şekilde kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Makine Öğrenmesi, Veri Dengeleme, Öznelik Seçimi, In Vitro Fertilizasyon, Tedavi Başarısı Tahmini

PREDICTION OF SUCCESS OF IN VITRO FERTILIZATION TREATMENT WITH MACHINE LEARNING METHODS

Rabia PEMİK

**Erciyes University, Institute of Natural and Applied Sciences
Master Thesis, September 2024
Supervisor: Prof. Dr. Lale ÖZBAKIR**

ABSTRACT

Infertility is a major health problem that occurs in approximately 17.5% of the adult population worldwide. In Vitro Fertilization (IVF) is a common and effective treatment for infertile couples. This study aims to analyze the effect of parameters on clinical pregnancy outcomes in couples diagnosed with infertility and receiving IVF treatment and to predict treatment success with machine learning algorithms. The health data of 3627 couples who received IVF treatment, consisting of 40 attributes, were examined. From various machine learning algorithms for prediction of treatment success; SVM, C4.5, CART, Random Forest, k-NN, Naive Bayes, Logistic Regression, ANN, Gradient Boosting, and Adaptive Boosting were used. Treatment success using by two different approaches. In the first approach, all data of the couples, including the treatment process, were analyzed and the success of the treatment (successful=1 or unsuccessful=0) was predicted. In the second approach, the probability of success of the treatment was estimated by analyzing only the pre-treatment data to support the couples' choice of whether to start treatment or not. To improve treatment prediction accuracy, methods such as normalization, data balancing, and feature selection were applied, and the algorithms were evaluated based on performance metrics. Using 10-fold cross-validation and Pearson correlation-based feature selection, the Random Forest algorithm achieved **96.59%** accuracy in predicting treatment success. For pre-treatment data, the Random Forest algorithm estimated the probability of success with 91.40% accuracy. This study demonstrates that machine learning algorithms can effectively predict IVF treatment success with high accuracy.

Keywords: Machine Learning, Data Balancing, Feature Selection, In Vitro Fertilization, Treatment Success Prediction

İÇİNDEKİLER

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE İN VİTRO FERTİLİZASYON TEDAVİ BAŞARISININ TAHMİNLENMESİ

KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR.....	xi
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
GİRİŞ.....	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Problem Durumu	3
1.1.1. İnfertilite.....	3
1.1.2.İnfertilite Nedenleri	4
1.1.3. Tanı Yöntemleri	4
1.1.4. In Vitro Fertilizasyon	5
1.2. Araştırmanın Amacı	8
1.3. Araştırmanın Önemi.....	8

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Yöntem	9
2.1.1. Makine Öğrenmesi.....	9

2.1.2. Makine Öğrenmesi Algoritmaları	10
2.1.2.1. Destek Vektör Makinesi (SVM).....	11
2.1.2.2. C4.5 Karar Ağacı	12
2.1.2.3 CART Karar Ağacı.....	12
2.1.2.4. Rastgele Orman.....	13
2.1.2.5. k-En Yakın Komşu (k-NN).....	14
2.1.2.6. Naive Bayes	16
2.1.2.7. Lojistik Regresyon	16
2.1.2.8. Uyarlamalı Artırma (AdaBoost).....	17
2.1.2.9. Gradyan Arttırma (Gradient Boosting).....	18
2.1.2.10. Yapay Sinir Ağları (ANN).....	20
2.1.3. Veri Ön İşleme	20
2.1.3.1 Aykırı Veri Tespiti ve Çıkarılması	21
2.1.3.2. Eksik Veri Tespiti ve İkamesi	21
2.1.3.3. Normalizasyon	22
2.1.4. k-Katmanlı Çapraz Doğrulama	22
2.1.5. Sentetik Azınlık Örneklem Arttırma (SMOTE) Yöntemi	22
2.1.6. Öznitelik Seçimi	23
2.1.6.1. Bootstrap Yöntemi	23
2.1.6.2. Yinemeli Özellik Eleme (RFE).....	23
2.1.6.3. Pearson Korelasyonu	24
2.1.7. Performans Metrikleri	24
2.1.7.1. Karmaşıklık Matrisi.....	24
2.1.7.2. Doğruluk	25
2.1.7.3. Kesinlik	25
2.1.7.4. Duyarlılık	25
2.1.7.5. Hassasiyet.....	26

2.1.7.6. F-1 Skor	26
2.1.7.7. AUC Deęeri.....	26
2.2. Materyal.....	27
2.2.1. Veri Seti	27

3. BÖLÜM

BULGULAR

3.1 Arařtırma Modeli.....	33
3.2 Evren ve Örneklem	33
3.2.1 IVF Tedavi Başarısının Tahminlenmesi.....	33
3.2.1.1. Eğitim ve Test Kümesinin Belirlenmesi	34
3.2.1.2. Öznitelik Seçimi.....	37
3.2.2. IVF Tedavi Başarı Olasılığının Tedavi Öncesi Verilerle Tahminlenmesi	41
3.2.2.1. Eğitim ve Test Kümesinin Belirlenmesi	42
3.2.2.2. Öznitelik Seçimi.....	45

4. BÖLÜM

TARTIřMA-SONUÇ ve ÖNERİLER

4.1.Tartıřma.....	50
4.2.Sonuç ve Öneriler.....	53
KAYNAKÇA	55
ÖZGEÇMİř.....	61

KISALTMALAR

DSÖ: Dünya Sağlık Örgütü

IVF: In Vitro Fertilizasyon

SVM: Destek Vektör Makinesi

k-NN: k-En Yakın Komşu

ANN: Yapay Sinir Ağları

SMOTE: Sentetik Azınlık Aşırı Örnekleme

RFE: Yinemeli Özellik Eleme

ROC: İşlem Karakteristik Eğrisi

AUC: İşlem Karakteristik Eğrisi Altında Kalan Alan

ASRM: Amerikan Üreme Tıbbı Derneği

FSH: Folikül Uyarıcı Hormon

LH: Luteinize Edici Hormon

PRL: Prolaktin Hormonu

E2: Estradiol Hormonu

hCG: İnsan Koryonik Gonadotropin

ICSI: İntrasitoplazmik Sperm Enjeksiyonu

MLP: Çok Katmanlı Algılayıcılar

RIMARC: ROC Eğrisi Altındaki Alanı En Üst Düzeye Çıkararak Örnekleri Sıralama

SVMLight: Destek Vektör Makine Sıralaması

RIkNN: k-En Yakın Komşu Kullanarak Sıralama

RPART: Özyinemeli Bölümleme

TABLOLAR LİSTESİ

Tablo 1. Veri Setini Oluşturan Öznitelikler ve Özellikleri	27
Tablo 2. Sayısal Özniteliklere Ait İstatistiksel Bilgiler	28
Tablo 3. Kullanılan Makine Öğrenmesi Algoritmalarının Parametreleri	32
Tablo 4. 1.Yaklaşım: %80 eğitim seti- %20 test seti Performans Metrikleri	35
Tablo 5. 1.Yaklaşım: %66 eğitim seti- %34 test seti Performans Metrikleri	35
Tablo 6. 1.Yaklaşım: 5-katlı Çapraz Doğrulama Performans Metrikleri.....	36
Tablo 7. 1.Yaklaşım: 10-katlı Çapraz Doğrulama Performans Metrikleri.....	36
Tablo 8. 1.Yaklaşım: Öznitelik Seçimi Yöntemlerine Göre Öznitelik Alt Kümeleri.....	38
Tablo 9. 1.Yaklaşım: Bootstrap Yöntemi Performans Metrikleri.....	39
Tablo 10. 1.Yaklaşım: RFE Yöntemi Performans Metrikleri	39
Tablo 11. 1.Yaklaşım: Pearson Korelasyonu Performans Metrikleri	40
Tablo 12. 2.Yaklaşım: %80 eğitim seti- %20 test seti Performans Metrikleri	42
Tablo 13. 2.Yaklaşım: %66 eğitim seti- %34 test seti Performans Metrikleri	43
Tablo 14. 2.Yaklaşım: 5-katlı Çapraz Doğrulama Performans Metrikleri.....	44
Tablo 15. 2.Yaklaşım: 10-katlı Çapraz Doğrulama Performans Metrikleri.....	44
Tablo 16. 2.Yaklaşım: Öznitelik Seçimi Yöntemlerine Göre Öznitelik Alt Kümeleri...	46
Tablo 17. 2.Yaklaşım: Bootstrap Yöntemi Performans Metrikleri.....	46
Tablo 18. 2.Yaklaşım: RFE Yöntemi Performans Metrikleri	47
Tablo 19. 2.Yaklaşım: Pearson Korelasyonu Performans Metrikleri	48
Tablo 20. Tedavinin Başarılı Olma Olasılık Dağılımı	49

ŞEKİLLER LİSTESİ

Şekil 1. SVM Çalışma Prensibi	11
Şekil 2. SVM Kaba-Kodu.....	12
Şekil 3. Karar Ağacı Çalışma Prensibi	12
Şekil 4. Karar Ağacı Kaba-Kodu.....	13
Şekil 5. Rastgele Orman Çalışma Prensibi.....	13
Şekil 6. k-NN Çalışma Prensibi.....	15
Şekil 7. k-NN Kaba-Kodu	15
Şekil 8. Lojistik Regresyon Çalışma Prensibi	17
Şekil 9. Uyarlamalı Arttırma Çalışma Prensibi	18
Şekil 10. Uyarlamalı Arttırma Kaba-Kodu.....	18
Şekil 11. Gradyan Arttırma Çalışma Prensibi	19
Şekil 12. Gradyan Arttırma Kaba-Kodu.....	19
Şekil 13. ANN Çalışma Prensibi	20
Şekil 14. Karmaşıklık Matrisi.....	24
Şekil 15. ROC Eğrisi	26
Şekil 16. Öznitelikler ve Histogram Grafikleri	29
Şekil 17. Hedef Değişken ile Değişkenler Arası Isı Haritası	30
Şekil 18. Hedef Değişken ile Değişkenler Arası Isı Haritası	31
Şekil 19. 1.Yaklaşım: İş Akış Şeması	34
Şekil 20. 2.Yaklaşım: İş Akış Şeması	41
Şekil 21.1.Yaklaşım Algoritmaların Performans Karşılaştırması	50
Şekil 22. 2.Yaklaşım Algoritmaların Performans Karşılaştırması	52

GİRİŞ

İnfertilite, dünya genelinde birçok çiftin karşılaştığı önemli bir sağlık sorunudur. Dünya Sağlık Örgütü (DSÖ)'nün 2023'te yayınladığı rapora göre dünya çapında, yetişkin nüfusunun yaklaşık %17,5'inde (altı kişiden birinde) infertilite görülmektedir. (WHO, 2023) In Vitro Fertilizasyon (IVF), infertil çiftler için en yaygın ve etkili tedavi yöntemlerinden biridir. IVF, laboratuvar ortamında yumurta ve spermin birleştirilerek embriyo oluşturulmasını ve bu embriyonun rahim içine transfer edilmesini içerir (Steptoe et al., 1978). Ancak, IVF tedavisinin başarı oranları çeşitli faktörlere bağlı olarak değişiklik göstermektedir ve tedavi sürecinin belirsizlikleri çiftler üzerinde ek bir psikolojik yük oluşturabilmektedir (Domar et al., 2012).

Son yıllarda, sağlık verilerinin analizi ve tedavi başarılarının öngörülmesi amacıyla veri bilimi ve makine öğrenmesi tekniklerinin kullanımı giderek yaygınlaşmaktadır. Makine öğrenmesi, büyük veri kümeleri üzerinde çalışarak sağlık durumlarını tahmin etme ve tedavi stratejilerini geliştirme konusunda büyük bir potansiyel sunmaktadır (Rajkomar et al., 2019). Makine öğrenmesi algoritmaları, sağlık verilerinden öğrenerek hasta sonuçlarını tahmin edebilir ve bu tahminler, tedavi sürecini iyileştirme ve kişiselleştirilmiş sağlık çözümleri sunma imkanı tanır (Topol, 2019). Bu bağlamda, makine öğrenmesi algoritmaları IVF tedavisinin başarısını önceden tahmin etmek, çiftlerin tedaviye başlama kararlarını desteklemek ve tedavi süreçlerini optimize etmek açısından büyük bir potansiyele sahiptir.

Tez çalışması kapsamında, Erciyes Üniversitesi Kadın Hastalıkları ve Doğum Ana Bilim Dalı Tüp Bebek Ünitesi'nde 2004 ile 2023 yılları arasında IVF tedavisi gören 3627 çiftin sağlık verileri Python programlama dili kullanılarak makine öğrenmesi algoritmaları ile tedavi başarısının tahmin edilmesi amaçlanmıştır. Algoritmalar arasında Destek Vektör Makinesi (SVM) C4.5 Karar Ağacı, CART Karar Ağacı, Rastgele Orman, k-En Yakın Komşu (k-NN), Naive Bayes, Lojistik Regresyon, Yapay Sinir Ağları (ANN), Gradyan

Arttırma (Gradient Boosting Machines), ve Uyarlamalı Arttırma (AdaBoost) bulunmaktadır.

Çalışmanın ilk yaklaşımında, çiftlerin tedavi süreci dahil tüm verileri analiz edilerek tedavi başarısı (başarılı = 1 ve başarısız = 0) tahmin edilmiştir. İkinci yaklaşımında ise, sadece tedavi öncesi veriler analiz edilerek tedavinin başarılı olma olasılığı tahmin edilmiştir. Tedavi tahmin başarılarını artırmak için normalizasyon, veri dengeleme ve öznitelik seçimi yöntemleri uygulanmıştır. Normalizasyon için; Min-Max normalizasyon yöntemi, veri dengeleme için; Sentetik Azınlık Aşırı Örnekleme (SMOTE) yöntemi, öznitelik seçimi için; Bootstrap yöntemi, Yinemeli Özellik Eleme (RFE) yöntemi, Pearson Korelasyonu yöntemi ve eğitim-test kümesinin bölünmesi için farklı yöntemler uygulanmıştır. Algoritmaların performansı doğruluk, kesinlik, duyarlılık, F1-skor ve İşlem Karakteristik Eğrisi (ROC) altında kalan alan (AUC) gibi performans göstergeleri ile değerlendirilmiştir.

Tez çalışmasının organizasyonu şu şekilde belirlenmiştir:

- Birinci bölümde, infertilite ve infertilitenin nedenleri, IVF süreci, literatür araştırmaları ele alınmıştır. Ayrıca, araştırmanın amacı ve önemi açıklanmıştır.
- İkinci bölümde, makine öğrenmesi ile ilgili genel bilgiler ve algoritmalar ele alınmıştır. Makine öğrenmesi algoritmalarının devamında veri ön işleme adımları, normalizasyon, veri dengeleme, öznitelik seçimi yöntemleri ayrıntılı olarak açıklanmıştır. Ayrıca çalışmada kullanılan veri seti de bu bölümde tanıtılmıştır.
- Üçüncü bölümde, IVF tedavi başarısının tahmini ile ilgili iki farklı yaklaşım incelenmiştir. İlk yaklaşımda, IVF tedavi başarısının tedavi öncesi ve tedavi sürecindeki verilerle tahmin edilmesi; ikinci yaklaşımda ise sadece tedavi öncesi verilerle IVF tedavi başarı olasılığının tahmin edilmesi ele alınmıştır. Her iki yaklaşımda da çalıştırılan makine öğrenmesi algoritmalarının performans metriklerine göre elde edilen sonuçlar sunulmuştur.
- Dördüncü bölümde, elde edilen performans metrikleri ve sonuçları karşılaştırılmış ve öneriler sunulmuştur.

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Problem Durumu

1.1.1. İnfertilite

İnfertilite, üreme çağındaki çiftlerin herhangi bir doğum kontrol yöntemi kullanmaksızın en az bir yıl düzenli cinsel ilişkiye rağmen gebelik elde edememesi durumu olarak tanımlanır. (Bankowski et al., 2005) Bu durum Dünya Sağlık Örgütü tarafından bireylerin fiziksel, psikolojik ve sosyal yaşamlarını olumsuz etkileyen önemli bir halk sağlığı sorunu olarak kabul edilir.

İnfertilite primer ve sekonder olmak üzere iki ana kategoriye ayrılır. Bir çiftin daha önce hiç gebelik elde edememesi durumunu primer infertilite, canlı doğum sonuçlansın ya da sonuçlanmasın en az bir gebelik oluşması sonrasında tekrar gebelik sağlanamaması durumunu sekonder infertilite tanımlar. (Crosignani, 2013)

İnfertilite prevalansı, beslenme, yaşam tarzı, çevresel faktörler ve sağlık hizmetlerine erişim gibi nedenlerle bölgesel farklılıklar gösterebilir. İnfertilite prevalansı yüksek gelirli ülkelerde %17,8 iken düşük ve orta gelirli ülkelerde %16,5'tir. (Njagi et al., 2023) Bu oranlar, infertilitenin yaygın bir sorun olduğunu ve toplum sağlığı açısından önemli bir yer tuttuğunu göstermektedir.

Amerikan Üreme Tıbbı Derneği (ASRM), infertilitenin bir hastalık olduğunu belirterek kriterlerin değerlendirilmesini önermektedir:

- Hastanın tıbbi, cinsel ve üreme geçmişi, yaşı, fiziksel muayene bulguları, tanısal testler veya bu unsurların herhangi bir kombinasyonuna dayanarak başarılı bir gebelik elde edilememesi.
- İnfertilite sebebinin bulunamadığı durumlarda, düzenli ve korunmasız cinsel ilişkiye rağmen, 35 yaş altındaki kadınlarda 12 ay, 35 yaş ve üzeri kadınlarda ise 6 ay sonra infertilite değerlendirmesine başlanması. (American Society for Reproductive Medicine, 2020).

1.1.2. İnfertilite Nedenleri

İnfertilitenin etiyolojik sınıflaması yüzdelik oranlarla şu şekilde ifade edilmektedir: %23 erkek faktörleri, %18 ovulatuvar disfonksiyon, %14 tubal faktör, %9 endometriozis, %5 koital sorunlar, %3 servikal faktörler ve %28 açıklanamayan nedenlerdir. (Avcı, 2018).

İnfertilite etiyolojisi incelendiğinde genetik faktörler, hormonal dengesizlikler, enfeksiyonlar, yaşam tarzı faktörleri (sigara, alkol, obezite) ve çevresel etkenlerin önemli rol oynadığı görülmektedir (Sharma et al., 2013). Kadınlarda ve erkeklerde infertilite nedenleri farklılık göstermektedir. Erkeklerde infertiliteye neden olan başlıca faktörler şunlardır: Varikosel, kriptorşidizm, hipospadias, düşük testosteron seviyesi, orşit gibi yapısal ve hormonal bozukluklar, spermin yapısındaki anormallikler, sperm sayısındaki azalmalar, libido düşüklüğü ve ereksiyon bozuklukları. Kadınlarda infertiliteye neden olan faktörler ise doğuştan gelişimsel bozukluklar, anovulasyon, polikistik over sendromu, luteal faz yetmezliği gibi over sorunları, uterus ve servikse ilişkin problemler, tubal ve peritoneal faktörler ile vulva ve vajina ile ilgili sorunlardır (Karacakaya Ercan vd., 2024).

1.1.3. Tanı Yöntemleri

Çiftlerin tanı değerlendirmesinde birçok prosedür çiftlere eş zamanlı uygulanmaktadır. İlk adım çiftlerin fiziksel muayenesi ve detaylı tıbbi geçmişinin alınmasıdır. Bu süreçte infertilite süresi, adet düzeni, gebelik-düşük geçmişi, cerrahi geçmiş ve ilaç kullanımı gibi bilgiler toplanır. Kadınlarda folikül uyarıcı hormon (FSH), luteinize edici hormon (LH), prolaktin hormonu (PRL), estradiol (E2) gibi hormon testleriyle; erkeklerde sperm sayısı, hareketliliği ve morfolojisi semen analiziyle değerlendirilir. Görüntüleme yöntemlerinden transvajinal ultrason; over rezervi ve rahim anomalilerinin

değerlendirilmesinde histerosalpingografi; fallop tüplerinin açıklığını ve uterin boşluğun yapısının değerlendirilmesinde kullanılır. Bu prosedürlere ek olarak laparoskopi; endometriozis veya pelvik yapışıklıklar gibi durumları değerlendiren cerrahi prosedürleri bulunmaktadır (İnceli, 2019).

1.1.4. In Vitro Fertilizasyon

IVF, fallop tüplerinde doğal olarak gerçekleşen yumurtaların ve sperm döllenen sürecinin dışarıda, kontrollü bir laboratuvar ortamında gerçekleştirilmesiyle oluşan embriyoların rahime transfer edilmesi sürecidir. Bu süreç ovaryan stimülasyonu, oosit toplama, in vitro fertilizasyon, embriyo kültürü ve embriyo transferi aşamalarından oluşur. Ovaryan stimülasyonu aşamasında, kadının yumurtalıkları birden fazla oosit üretmesi için hormonlarla (genellikle FSH ve LH) uyarılır ve bu süreç boyunca yumurtalıkların yanıtı ultrason ve kan testleri ile izlenir. Oositler yeterince olgunlaştığında, insan Koryonik Gonadotropin (hCG) enjeksiyonu ile ovulasyon tetiklenir ve yaklaşık 36 saat sonra oositler toplanır. Toplanan oositler, laboratuvar ortamında sperm ile bir araya getirilerek döllenen takip edilir. Döllenen embriyolar, kültür ortamında birkaç gün boyunca gelişimlerine devam eder ve bu süreçte embriyoların kalitesi değerlendirilir. En iyi kaliteye sahip embriyolar seçilerek, kadının rahmine transfer edilir. IVF yöntemi, ilk kez 1978 yılında Louise Brown'un doğumu ile başarıya ulaşmış ve üreme tıbbında önemli bir gelişme olarak literatüre geçmiştir (Yılmaz, 2016).

IVF tedavisinin başarısı çiftler arasında çeşitli parametrelere bağlı olarak önemli ölçüde değişiklik gösterdiği anlaşılmıştır. Bu parametrelerin belirlenmesi, tedavi başarısını tahmin etmek ve tedavi süreçlerini optimize etmek açısından kritik öneme sahiptir. IVF tedavi başarısını etkileyen başlıca parametreler ve bu konular üzerine yapılmış çalışmalar ana başlıklar altında incelendiğinde; sıklıkla istatistiksel yöntemler kullanılıyor iken son yıllarda makine öğrenmesi algoritmaları üzerinde çalışıldığı görülmektedir.

(Atar, 2009) İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi'ne ait 1964 veriyi kullanarak IVF başarısızlığını etkileyen faktörleri Ki-Kare Testi ve Lojistik Regresyon yöntemleriyle incelemiştir. Açıklanamayan infertilite, polikistik over görünümü, uzun protokol kullanımı, basamaklı olarak üçüncü günde doz azaltılması, İntrasitoplazmik

sperm enjeksiyonu (ICSI) uygulaması, transfer sırasında kanama görülmemesi ve luteal destek uygulamasının daha yüksek gebelik oranları ile ilişkili olduğunu tespit etmiştir.

(Seyhan, 2012) Erciyes Üniversitesi Tüp Bebek Ünitesi'ne ait 1177 veriyi istatistiksel olarak Ki-Kare Testi yöntemiyle ikili ilişkileri bulmak için incelemiştir. Belirlediği 8 parametreden 5 tanesinin (vücut kitle indeksi, yaş, endometrium kalınlığı, embriyo transferinde verilen embriyoların sayısı, embriyo transferinde verilen embriyoların gradeleri) tüp bebek tedavisini etkileyen faktörler olduğunu tespit etmiştir.

Tedavi başarısını etkileyen faktörlerin tespit edilmesinde regresyon analizi meta-analiz, lojistik regresyon ve çok değişkenli regresyon analizi gibi yöntemlerin sıklıkla kullanıldığı görülmüştür. Çoklu değişkenlerin ve doğrusal olmayan korelasyonların incelenmesinde daha gelişmiş veri analizi ve tahmini gerekmektedir.

Makine öğrenmesi tekniklerinin odak noktası, bilgiyi yüksek doğrulukla keşfetmek için verilerdeki gizli ve bilinmeyen örüntüleri keşfederek bilgisayarlı ve verimli tahmine dayalı modelleme geliştirmektir. Makine öğreniminin amacı, bilgisayarın belirli bir problemi çözmek için verilerden veya deneyimlerden öğrenmesine izin vererek tahmin modelleri tasarlamak ve geliştirmektir (Raef et al., 2019).

(Kaufmann et al., 1997) 14 özniteliğe t-testi ile öznitelik seçimi uygulayarak yaş, toplanan yumurta sayısı, transfer edilen embriyo sayısı ve embriyo dondurma uygulanıp/uygulanmadığı özniteliklerinin sonuç üzerinde etkili olduğunu tespit etmiştir. Bu öznitelikler kullanarak ANN yöntemiyle gebelik sonucunun başarısını %59'luk doğruluk değeriyle tahminlendiğini belirtilmiştir.

Bazı çalışmalar tedaviyi etkileyen faktörlerin tespit edilmesi dışında tüp bebek tedavisinin başarı oranını artırmak için embriyo seçim sürecine de odaklanmıştır.

(Moreles et al., 2008) morfolojik ve klinik veriler kullanılarak embriyoların seçiminde başarılı seçimi yapabilmek için Naive Bayes yöntemini kullanarak %71,43 doğrulukla sınıflandırma yapabirmiştir.

Bu çalışmaya benzer (Chen et al., 2009) ise veri madenciliği tabanlı bir tahmin modeli kullanarak en yüksek implantasyon potansiyeline sahip embriyoyu seçmek için Karar

Ağacı, J48 ve Naive Bayes gibi veri madenciliği yöntemlerini kullanarak %71 doğruluk oranına ulaşabilmiştir.

(Uyar, 2010) hastaya ve embriyoya ilişkin 18 öznitelik üzerinde çeşitli makine öğrenmesi algoritmalarını (SVM, Karar Ağaçları, Naive Bayes, k-NN, Çok Katmanlı Algılayıcılar (MLP) ve Rastgele Orman) kullanmıştır. 11 özneliğin sonuç üzerinde etkili olduğunu tespit ederek Naive Bayes yöntemiyle embriyo implantasyon sonucunu %80,4 doğruluk değeriyle tahminlendiğini belirtmiştir.

(Mısırlı, 2013) tüp bebek yönteminde tedavi başarı şansını tahmin etme ve tedavi yöntemi önerme konu başlıklı çalışmasında 2020 veriyle çalışmıştır. Çalışmasında sıralama algoritmalarını kullanarak tedavi başarısını tahmin etmek için ROC Eğrisi Altındaki Alanı En Üst Düzeye Çıkararak Örnekleri Sıralama (RIMARC) Destek Vektör Makine Sıralaması (SVMlight) ve k-En Yakın Komşu Kullanarak Sıralama (RkNN) yöntemlerini kullanmıştır. Sonrasında tedavi yöntemi önerme sistemi için makine öğrenimi yöntemlerinden en yakın komşu tabanlı ve karar ağacı tabanlı algoritmalarını kullanmıştır.

(Hafız el at., 2017) tüp bebek tedavisi ve ICSI için 486 veriyi ele alarak tedavi başarısını tahminlemek için Rastgele Orman, Özyinemeli Bölümleme (RPART), SVM, Uyarlamalı Arttırma ve k-NN yöntemlerini kullanmıştır. Tedavi başarısını 5-kat çapraz doğrulama uygulanarak Rastgele Orman yöntemiyle %84,23 doğrulukla gerçekleştirdiğini belirtmiştir.

(Ramasamy et al., 2017) IVF tedavi başarı oranını tahmin etmek için Hibrit Özellik Azaltma Algoritması geliştirmiştir. Bu algoritmayı kullanarak 41 öznelikten en etkili olan 18 özneliği seçerek MLP makine öğrenmesi algoritmasıyla %90,35 doğruluk değeriyle tahminlendiğini belirtmiştir.

(Hassan et al., 2018) 1749 veriyi kullanarak tüp bebek tedavisinde tedavi başarısını tahminlemek için makine öğrenimi yöntemlerinden MLP, SVM, C4.5, CART ve Rastgele Orman yöntemlerini kullanmıştır. Tedavi başarısını SVM sınıflandırıcı tarafından %98,38 doğrulukla gerçekleştirmiştir.

Yukarıda sunulan çalışmalardan, IVF alanında yapılan farklı bilimsel arařtırmalarda makine öğrenmesi yöntemlerini teknolojinin gelişmesiyle son yıllarda sıklıkla kullanıldığı sonucuna varılmıştır. Özellikle tedavi başarısını etkileyen parametrelerin belirlenmesi ve tedavi başarısının tahminlenmesi çalışmalarına ağırlık verilmiştir.

1.2. Arařtırmanın Amacı

Bu tez çalışmasının amacı, infertilite tanısı konulan ve IVF tedavisi alan çiftlerde klinik gebelik sonucunu en fazla etkileyen parametreleri tespit ederek, tedavi öncesi ve tedavi sürecindeki verilerine göre tedavi başarısını makine öğrenmesi algoritmaları ile tahmin etmektir.

Çalışmanın birinci yaklaşımında, çiftlerin tedavi süreci dahil tüm verileri analiz edilerek tedavi başarısı (başarılı = 1 veya başarısız = 0) tahmin edilmiştir. İkinci yaklaşımında ise, çiftlerin tedaviye başlama/başlamama kararını desteklemek amacıyla, olasılık sonucu verebilen makine öğrenmesi algoritmalarıyla tedavi öncesi verileri analiz edilerek tedavinin başarılı olma olasılığı tahmin edilmiştir.

1.3. Arařtırmanın Önemi

Bu çalışma, IVF tedavi başarısını yüksek doğruluk oranlarıyla tahmin etmek için makine öğrenmesi algoritmalarının etkin bir şekilde kullanılabileceğini göstermektedir. Makine öğrenmesi tekniklerinin kullanılması, IVF tedavi süreçlerini optimize etmek ve çift sonuçlarını iyileştirme potansiyeline sahiptir. Bu sayede, IVF tedavisi gören çiftler için belirsizliğin azaldığı bir tedavi süreci sunulabilir.

Ayrıca, yapılan literatür incelemelerinde bu çalışmanın, IVF tedavi başarısını tahmin etmede benzer çalışmalardan daha yüksek doğruluk oranlarına ulaştığı görülmüştür. Bu, makine öğrenmesi algoritmalarının doğru bir şekilde uygulandığında klinik karar destek sistemlerinde etkili bir araç olabileceğini göstermektedir.

2. BÖLÜM

YÖNTEM VE MATERYAL

Bu bölümde, çalışmada kullanılan makine öğrenmesi yöntemleri ve algoritmaların temel çalışma prensipleri ile uygulama adımları detaylı bir şekilde tanımlanmıştır. Ayrıca analizlerde kullanılan veri ön işleme adımları; normalizasyon, veri dengeleme ve öznitelik seçimi yöntemleri açıklanmıştır. Devamında çalışmada kullanılan veri seti tanımlanmış, öznitelikler, özniteliklerin dağılımları ve istatistiksel özellikleri detaylandırılarak bahsedilmiştir.

2.1. Yöntem

2.1.1. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların insanlara benzer şekilde öğrenmesini sağlamak için insanın öğrenme yeteneğinden esinlenilerek geliştirilmiş, çıkarımlarını matematiksel ve istatistiğe dayalı yöntemler kullanarak gerçekleştiren ayrıca yaptığı bu çıkarımlar ile tahminde bulunan yapay zekanın bir alt dalıdır (Mitchell, 1997).

Makine öğrenmesi ilk kez 1959 yılında bir dama oyununu analiz etmek için Arthur Samuel tarafından kullanılmıştır. Arthur Samuel tarafından makine öğrenmesi “bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren araştırma alanı” olarak ifade edilmiştir (Samuel, 1959). Makine öğrenmesi algoritmalar ve istatistiksel modeller aracılığıyla verilerden öğrenme ve gelecekteki olayları tahmin etme üzerine odaklanır (Bishop, 2006).

Makine öğrenmesi, günümüzde çeşitli sektörlerde geniş bir uygulama alanına sahip olup, birçok problemin çözümünde etkin bir şekilde kullanılmaktadır. Üretim sektöründe makine öğrenmesi, tahmine dayalı bakım, kalite kontrol ve tedarik zinciri lojistik

çözümlerinde yaygın olarak uygulanmaktadır. Sağlık hizmetlerinde, teşhis ve tedavi süreçlerinin iyileştirilmesi için makine öğrenmesi yöntemleri kullanılmakta, hastalıkların erken teşhisinde önemli rol oynamaktadır. Finansal sektörde ise, risk analizi, dolandırıcılık tespiti ve yeni yatırım fırsatlarının tahminlenmesi gibi alanlarda makine öğrenmesi tekniklerinden yararlanılmaktadır. Perakende sektöründe, müşteri hizmetleri, stok yönetimi ve pazarlama stratejilerinin belirlenmesinde makine öğrenmesi algoritmaları önemli katkılar sağlamaktadır.

Makine öğrenmesi türleri dört ana kategoriye ayrılmaktadır (Takcı, 2020).

Denetimli Öğrenme (Supervised Learning): Modelin eğitimi için etiketlenmiş ve tanımlı verilerin kullanıldığı ve test aşamasında tahminleme yapılan öğrenme türüdür. Denetimli öğrenme yöntemleri sınıflandırma ve regresyon olarak ikiye ayrılmaktadır.

Denetimsiz Öğrenme (Unsupervised Learning): Bu yöntem etiketlenmemiş veri kümeleri arasındaki anlamlı bağlantıları ortaya çıkarmaya çalışan öğrenme türüdür. Denetimli öğrenmenin aksine modelin eğitim aşaması bulunmamaktadır. Denetimsiz öğrenme yöntemleri kümeleme ve birliktelik kuralı analizi olarak ikiye ayrılmaktadır.

Yarı Denetimli Öğrenme (Semi-Supervised Learning): Denetimli ve denetimsiz öğrenme yöntemlerini birleştirir. İlk olarak, etiketlenmiş veriler kullanılarak model kısmen eğitilir ve ardından eğitilen model etiketsiz verileri etiketler. Daha sonra, modelin eğitiminde hem etiketli hem de sonradan etiketlenmiş veriler birlikte kullanılır.

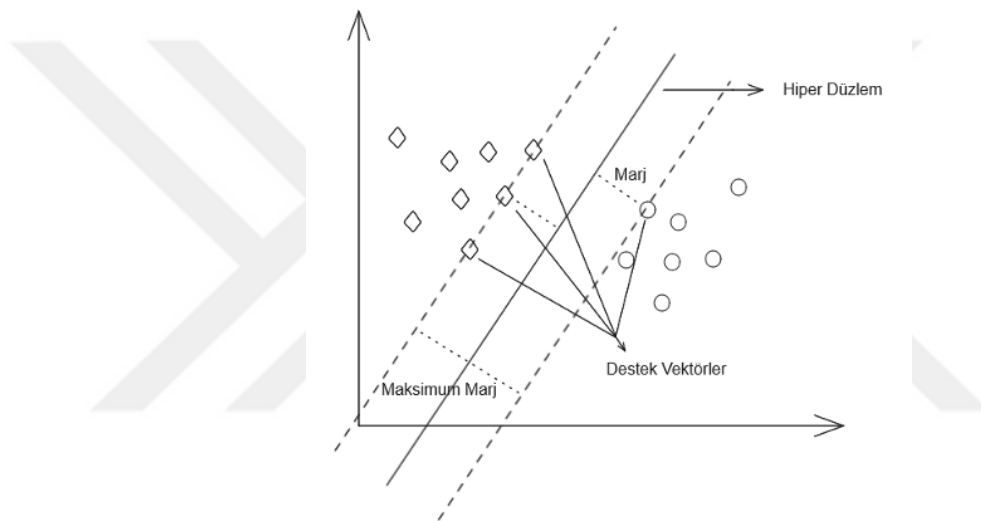
Takviyeli öğrenme (Reinforcement Learning): Bu yöntem bir ajan adı verilen öğrenme süreci sisteminde ödül-ceza mekanizması bulunan bir öğrenme türüdür.

2.1.2. Makine Öğrenmesi Algoritmaları

Yapılan literatür çalışmasında, tedavi başarısının tahminine yönelik birçok makine öğrenmesi algoritmaların kullanıldığı görülmüştür. Yaygın olarak kullanılan SVM, C4.5 Karar Ağacı, CART Karar Ağacı, Rastgele Orman, k-NN, Naive Bayes, Lojistik Regresyon, ANN, Gradyan Arttırma ve Uyarlamalı Arttırma algoritmaları seçilerek tez çalışmasında kullanılmıştır.

2.1.2.1. Destek Vektör Makinesi (SVM)

İlk defa 1960'ların sonlarında Vladimir Vapnik ve Alexander Cheryonenkis tarafından temel prensipleri geliştirilmiştir. Modern formülasyonu ve popüler hale gelmesi Vapnik ve Cortes'in 1995'te yayınladıkları makaleyle gerçekleşmiştir. SVM algoritması istatistiksel öğrenme ve optimizasyon teorisine dayanmaktadır. Yüksek boyutlu veri kümelerinde verileri farklı sınıflara ayıran en iyi hiper düzlemi bulmak için çalışır ve bu hiper düzlem sınıflar arasındaki en büyük marjini maksimize edecek şekilde seçilir. Bu sayede, sınıflandırma hataları minimize edilmiş olur (Cortes et al., 1995).



Şekil 1. SVM Çalışma Prensibi

Kaynak: Mammone, Turchi, Cristianini, 2009

SVM algoritması öğrenme modeli oluşturulmasının kaba-kodu (pseudo-code) Şekil 2'de verilmiştir (Shalev-Shwartz et al., 2011).

Girdiler:

$\{x_1, x_2, x_3, \dots, x_n\}$: X özellik vektörü

$\{y_1, y_2, y_3, \dots, y_n\}$: Y sınıf çıktıları

λ : düzenleme parametresi

T: adımların sayısı

1. $w = (0, \dots, 0)$ ile **başlat**
2. **döngü** $t=1$ 'den T'ye kadar
3. **seç** eğitim örneği x_i ve onunla ilişkili olan çıktı etiketi y_i
4. $\eta = \frac{1}{\lambda \cdot t}$
5. $skor = w \cdot x_i$
6. **eğer** $y \cdot skor < 1$ ise

7. $w = (1 - \eta \cdot \lambda) \cdot w + (\eta \cdot y_i) \cdot x_i$
8. **değilse**
9. $w = (1 - \eta \cdot \lambda) \cdot w$
10. **çıktı** w

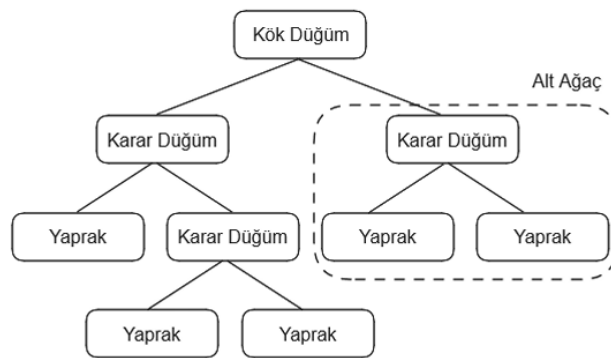
Şekil 2. SVM Kaba-Kodu

2.1.2.2. C4.5 Karar Ağacı

İlk defa 1993'te J. Ross Quinlan tarafından geliştirilmiş ve "C4.5: Programs for Machine Learning" adlı kitabında tanıtılmıştır. C4.5 Karar Ağacı algoritması veri kümesindeki nitelikleri bilgi kazancı oranı, Gini indeksi veya entropi kullanarak sınıflandırma yapmak için veri kümesini bölerek karar ağaçları oluşturur ve bu sayede aşırı uyumu engeller (Quinlan, 1993).

2.1.2.3 CART Karar Ağacı

İlk defa 1984'te Leo Breiman, Jerome Friedman, Richard Olshen ve Charles Stone tarafından geliştirilmiş ve "Classification and Regression Trees" adlı kitapta tanıtılmıştır. Sınıflandırma ve Regresyon (CART) Karar Ağacı algoritması veri kümesindeki nitelikleri Gini Saflığı ve Varyans Azaltma Kriterlerini kullanarak sınıflandırma yapmak için veri kümesini bölerek karar ağaçları oluşturur (Breiman et al., 1984). Karar ağaçları kök, düğüm, dallar ve yaprak olmak üzere dört bölümden oluşmaktadır. Her bir yaprak düğüm sonucunu, düğümler özellikleri, dallar ise karar kurallarını temsil etmektedir. Kök düğümler ise veri kümesinden yola çıkarak nihai sınıflandırma sonucunu içermektedir. Karar ağaçları yukarıdan aşağıya böl ve yönet tarzında oluşturulan tümevarım yöntemiyle oluşturulmaktadır.



Şekil 3. Karar Ağacı Çalışma Prensipleri

Karar ağacına dayalı olarak geliştirilen algoritmaların öğrenme modeli oluşturulmasının kaba-kodu (pseudo-code) Şekil 4'te verilmiştir (Tuncer vd., 2020).

Girdiler:

$\{x_1, x_2, x_3, \dots, x_n\}$: X özellik vektörü

$\{y_1, y_2, y_3, \dots, y_n\}$: Y sınıf çıktıları

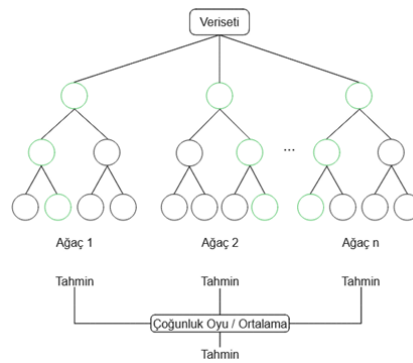
T: Ağaç

1. T=0 başlangıç durumunda ağaç boş küme **başlat**
 2. Dallanma kriterlerini belirle (bilgi kazancı, gini saflığı, entropi)
 3. Dallanma kriterine göre T kök düğüm belirle
 4. Dallanma kriterine göre Kök düğümü Dallara ayır
 5. Her bir dal **için yap**
 6. Düğüm oluşturmak için değişken belirle
 7. **eğer** durdurma kriterine ulaşıldı ise
 8. Yaprak ekle, **dur**
 9. **değilse**
 10. **tekrarla**
-

Şekil 4. Karar Ağacı Kaba-Kodu

2.1.2.4. Rastgele Orman

İlk defa 2001'de Leo Breiman tarafından geliştirilmiş ve "Random Forest" adlı makalesinde tanıtılmıştır. Rastgele Orman algoritması veri örnekleri üzerinde farklı karar ağaçlarının bağımsız olarak eğitildiği ve nihai sınıflandırma sonucunu bu ağaçların çoğunluğundan veya ortalamasından alarak tahmin yapmaktadır (Breiman, 2001). Sınıflandırma ve regresyon problemlerinde sıklıkla kullanılan algoritmanın farklı karar ağaçlarını eğiterek daha dengeli ve güvenilir sonuçlar elde ettiği vurgulanmaktadır (Cutler et al., 2007).



Şekil 5. Rastgele Orman Çalışma Prensibi

Kaynak: Kibria, Matin, 2022

2.1.2.5. *k-En Yakın Komşu (k-NN)*

İlk defa 1967'de Thomas M. Cover ve Peter E. Hart tarafından geliştirilmiş ve "Nearest Neighbor Pattern Classification" adlı makalede tanıtılmıştır. k-NN algoritması benzer verilerin birbirine yakın olduğunu varsayarak yeni eklenecek bir verinin sınıfını belirlemek için eğitim veri kümesindeki verilere olan uzaklığını hesaplamakta ve en yakın k komşunun etiketine bakmaktadır. Komşuların çoğunluk sınıfı veya ortalama değeri yeni eklenen verinin sınıfı olarak atanmaktadır (Cover et al., 1967). Yeni verinin sınıfını belirlemek amacıyla eğitim veri kümesindeki verilere olan uzaklıkları hesaplamak için Öklid, Manhattan ve Minkowski uzaklık fonksiyonları gibi yöntemler kullanılmaktadır. Fakat sayısal, ordinal ve nominal niteliklerin bir arada bulunduğu veri setlerinde bu uzaklıkların kullanımı anlamlı bir mesafe ölçümü sağlayamamaktadır. Gower mesafesi, heterojen veri kümelerinde benzerlik ölçümü için kullanılan bir metrik olup hem sayısal hem de kategorik verilerin aynı anda işlenmesine olanak tanır (Gower, 1971). Bu tez kapsamında, sınıflandırma işlemleri için Gower Mesafesi tercih edilmiştir. ve sayısal öznitelikler için Gower Mesafesi Denklem 1 ile hesaplanmaktadır.

$$d_{ij} = \frac{|x_{ik} - x_{jk}|}{R_k} \quad (1)$$

Nominal öznitelikler için Gower Mesafesi Denklem 2 ile hesaplanmaktadır.

$$d_{ij} = \begin{cases} 0 & \text{eğer } x_{ik} = x_{jk} \\ 1 & \text{eğer } x_{ik} \neq x_{jk} \end{cases} \quad (2)$$

Burada d_{ij} iki veri noktası arasındaki mesafeyi, x_{ik} ve x_{jk} iki veri noktasının k. öznitelik değerlerini ve R_k ise k. özneliğin aralığını (maksimum değer- minimum değer) temsil etmektedir.

Ordinal öznitelikler için Gower Mesafesi Denklem 2 ile hesaplanmaktadır.

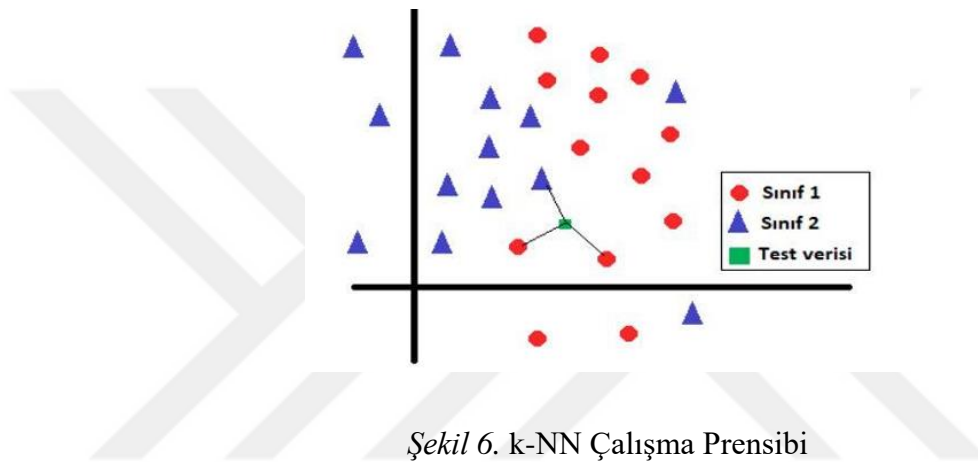
$$d_{ij} = \frac{|r(x_{ik}) - r(x_{jk})|}{R_k} \quad (3)$$

Ordinal öznitelikler sayısal özniteliklere benzer şekilde, fakat sıralı kategorilerin farkı üzerinden normalize edilmektedir. Burada, $r(x)$ sıralı değeri, R_k ise sıralı aralığı (maksimum değer- minimum değer) temsil eder.

Gower mesafesi her bir veri seti için Denklem 4 ile hesaplanmaktadır.

$$D_{ij} = \frac{\sum_{k=1}^p w_k d_{ij}^{(k)}}{\sum_{k=1}^p w_k} \quad (4)$$

Burada, D_{ij} iki veri noktası arasındaki toplam Gower mesafesini, w_k k. öznitelik için ağırlığı (genellikle 1), $d_{ij}^{(k)}$ k. öznitelik için mesafeyi ve p toplam öznitelik sayısını temsil etmektedir.



Şekil 6. k-NN Çalışma Prensibi

Kaynak: Çavuşoğlu, Kaçar, 2019

k-NN algoritması öğrenme modeli oluşturulmasının kaba-kodu (pseudo-code) Şekil 7’de verilmiştir (Kliemann et al., 2016).

Girdiler:

$\{x_1, x_2, x_3, \dots, x_n\}$: X özellik vektörü

$\{y_1, y_2, y_3, \dots, y_n\}$: Y sınıf çıktıları

$\{x, y\} \in p$

maks_iter: maksimum iterasyon sayısı

1. başlangıç merkezleri rastgele atayarak $\mu_1, \mu_2, \mu_3, \dots, \mu_k$ **başlat**

2. **tekrarla**

3. $y_1, y_2, y_3, \dots, y_n = \emptyset$ boş küme

4. **her** x_i ve onunla ilişkili olan çıktı etiketi y_i için **yap**

5. $i = \text{argmin}_{i=1\dots k} \|p - \mu_i\|^2$

5. $Y_i = Y_i \cup \{p\}$

6. $i = 1 \dots k$ için **yap**

7. eğer $Y_i \neq \emptyset$ ise $\mu_i = \frac{1}{|Y_i|} \sum_{p \in Y_i} p$

8. küme merkezi $\mu_1, \mu_2, \mu_3, \dots, \mu_k$ değişmiyorsa veya maks_iter ulaşıldıysa **dur**

Şekil 7. k-NN Kaba-Kodu

2.1.2.6. Naive Bayes

İlk defa 1763'te Thomas Bayes tarafından yayımlanan "An Essay towards solving a Problem in the Doctrine of Chances" çalışmasında tanıtılmıştır. Naive Bayes algoritması Bayes Teoremine dayanan verinin sınıflandırma işlemi sırasında özniteliklerin birbirinden bağımsız olduğunu varsayan olasılık tabanlı yöntemdir. Naive Bayes sınıflandırıcısı, Bayes Teoremi'ni temel alarak, belirli bir veri örneğinin her bir sınıfa ait olma olasılığını hesaplar ve bu olasılıkları karşılaştırarak örneğin en yüksek olasılığa sahip olduğu sınıfa atanmasını sağlar. Bayes Teoremi, aşağıdaki Denklem 5 ile hesaplanmaktadır (Bayes,1763).

$$P(C_k|X) = \frac{P(X|C_k) \cdot P(C_k)}{P(X)} \quad (5)$$

Burada:

$P(C_k|X)$: X verisinin C_k sınıfına ait olma olasılığı,

$P(X|C_k)$: C_k sınıfı altında X verisinin gözlemlenme olasılığı,

$P(C_k)$: C_k sınıfının genel olasılığı,

$P(X)$: X verisinin genel gözlemlenme olasılığıdır.

Naive Bayes algoritmasında, özniteliklerin birbirinden bağımsız olduğu varsayımı yapılır, bu da Denklem 6 ile ifade edilmektedir.

$$P(X|C_k) = \prod_{i=1}^n P(x_i|C_k) \quad (6)$$

Burada $X = \{x_1, x_2, x_3, \dots, x_n\}$ özniteik vektörünü temsil eder ve x_i özneliğin i . Değerini belirtir. Bu varsayımın, özellikle büyük veri setlerinde hızlı ve etkili bir şekilde sınıflandırma performansı sağladığı belirtilmektedir (Domingos, 1999).

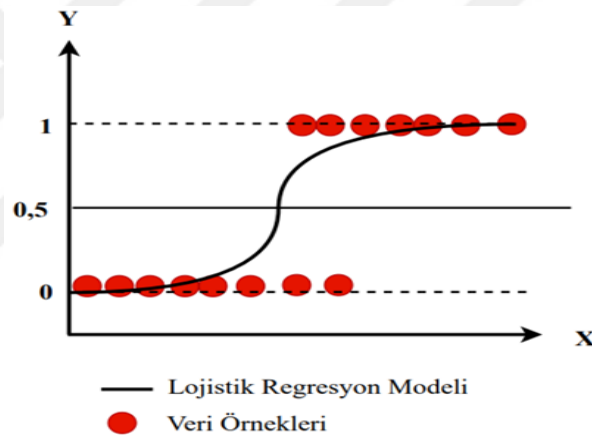
2.1.2.7. Lojistik Regresyon

İlk defa 1904'te Charles Spearman lojistik fonksiyonu tanıtarak ikili verilerin analizi için adım atmıştır. 1958 yılında ise David Cox lojistik regresyonun teorik temelini

geliştirmiştir. Lojistik Regresyon algoritması, bağımsız değişkenlerin doğrusal kombinasyonlarını kullanan bağımlı değişkenin olasılığını Sigmoid Fonksiyonu ile hesaplayarak verinin sınıfını tahmin eden olasılık tabanlı yöntemdir (Hosmer et al., 2013). Sigmoid fonksiyon Denklem 7 ile hesaplanmaktadır:

$$f(x) = \frac{1}{1 + e^{-x}} = \frac{1}{1 + e^{-(\theta^T x)}} \quad (7)$$

Sigmoid fonksiyon, $-\infty$ ve $+\infty$ aralığında değer almaktadır. Sonuç olarak 0 ve 1 değerlerini oluşturmaktadır. Fonksiyonun sonucunun 0,5 değerinden büyük olması durumunda sonuç 1 ve 0,5 değerinden küçük olması durumunda sonuç 0 olarak tahmin edilmektedir.




Şekil 8. Lojistik Regresyon Çalışma Prensibi

Kaynak: Azizoğlu, 2023

2.1.2.8. Uyarlamalı Artırma (AdaBoost)

İlk defa 1995'te Yoav Freund ve Robert E. Schapire tarafından "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting" makalesinde tanıtılmıştır. Uyarlamalı Artırma algoritması, tüm eğitim verilerine eşit ağırlık vererek başlar ve karar ağacı eğitilerek hata oranlarını hesaplar. Ardından yanlış sınıflandırılan örneklerin ağırlıkları artırılırken doğru sınıflandırılan örneklerin ağırlıkları azaltılarak nihai güçlü modelin oluşturulmasını amaçlayan topluluk öğrenimi yöntemidir (Freund et al., 1995).



Şekil 9. Uyarlamalı Arttırma Çalışma Prensibi

Kaynak: Püsküllü, 2024

Uyarlamalı Arttırma algoritması öğrenme modeli oluşturulmasının kaba-kodu (pseudo-code) Şekil 10'da verilmiştir (Bilban vd. 2022).

Girdiler:

$\{x_1, x_2, x_3, \dots, x_n\}$: X özellik vektörü

$\{y_1, y_2, y_3, \dots, y_n\}$: Y sınıf çıktıları

$\{(x_i, y_i)\}_{i=1}^n \in p$

$w_i^1 = \frac{1}{N}, i = 1, 2, \dots, N$: başlangıç ağırlık değeri

ca_i : i. verinin gerçek değerine karşılık gelen kategori

K: aynı kategorideki toplam örnek sayısı

$\Pi(\cdot)$: işaretçi fonksiyonu

Z_t : normalizasyon faktörü

1. **başla**

2. **tekrarla** $t=1$ 'den T 'e kadar

3. SAMME.R algoritması ile w^t iyi **hesapla**

4. **her** $x_i, h^t(x)$ fonksiyonunda **çalıştır**

5. $h^t(x)$ fonksiyonunun regresyon işlemi hata değeri **hesapla**

6. $error^t = \sum_{i=1}^N w_i^t \Pi(ca_i \neq h^t(x_i))$

7. $a^t = \ln \frac{1 - error^t}{error^t} + \ln(K - 1)$

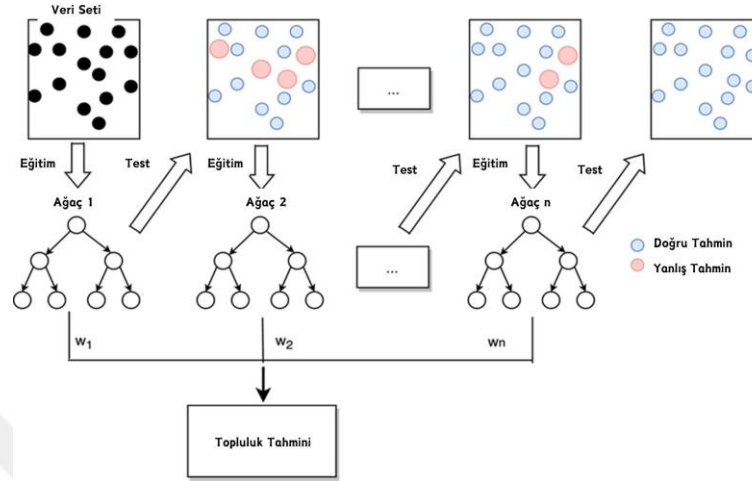
8. $w_i^{t+1} = \frac{w_i^t}{Z_t} \cdot \exp(a^t \Pi(ca_i \neq h^t(x_i)))$

Şekil 10. Uyarlamalı Arttırma Kaba-Kodu

2.1.2.9. Gradyan Arttırma (Gradient Boosting)

İlk defa 1999'ta Jerome H. Friedman tarafından "Greedy Function Approximation: A Gradient Boosting Machine" adlı makalesinde tanıtılmıştır. Gradyan Arttırma algoritması, basit bir model ile başlar ve modelin tahmin hatalarını hesaplar. Ardından gradyan iniş yöntemini kullanarak her yeni karar ağacında bir önceki ağaçta hesaplanan

model hatalarının en aza indirilmesi prensibine dayanan zayıf öğrencilerin güçlü öğrenciye dönüştürülmesini amaçlayan topluluk öğrenimi yöntemidir (Friedman, 2001).



Şekil 11. Gradyan Arttırma Çalışma Prensibi

Kaynak: Zhang, Lin, Vogelmann, Zhang, Xie, Qin, Golaz, 2021

Gradyan Arttırma algoritması öğrenme modeli oluşturulmasının kaba-kodu (pseudo-code) Şekil 12’de verilmiştir (Bilban vd. 2022).

Girdiler:

$\{x_1, x_2, x_3, \dots, x_n\}$: X özellik vektörü

$\{y_1, y_2, y_3, \dots, y_n\}$: Y sınıf çıktıları

$\{(x_i, y_i)\}_{i=1}^n \in p$

$L(y, F(x))$: eksik fonksiyon

maks_iter: maksimum iterasyon sayısı

1. $F_0(x)$ sabit değerle **başlat**

2. $F_0(x) = \text{argmin} \sum_{y_i=1}^N L(y_i, y_i)$

3. **tekrarla** m=1’den maks_iter’e kadar

4. $r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]$

5. $F(x) = F_{m-1}(x) \quad i=1,2,3,\dots,n$

5. $p_m(x)$ model tahmin değeri

6. $y = \text{argmin} \sum_{y_i=1}^N L(y_i, F_{m-1}(x_i) + y p_m(x_i))$

7. $F_m(x) = F_{m-1}(x) + y_m p_m(x)$


8. maks_iter ulaşıldıysa **dur**

9. **çıktı** $F_m(x)$

Şekil 12. Gradyan Arttırma Kaba-Kodu

2.1.2.10. Yapay Sinir Ağları (ANN)

İlk defa 1943'te Warren McCulloch ve Walter Pitts biyolojik nöronların işleyişini taklit eden bir model önermiştir. Bu model, basit mantık kapıları kullanarak sinir hücrelerinin işleyişini açıklamayı amaçlamıştır (McCulloch et al., 1958). 1958 yılında ise Frank Rosenblatt, Perceptron adlı öğrenme algoritmasını tanıtarak yapay sinir ağlarının gelişimine önemli bir katkıda bulunmuştur. Perceptron, basit bir yapay sinir ağı modelidir ve modern yapay sinir ağlarının temel yapı taşlarından biri olarak bilinmektedir (Rosenblatt, 1958). Yapay Sinir Ağları, insan beyninin çalışma şeklini taklit eden ve giriş katmanından çıktıya kadar olan verileri işlemek için düğümlerden (nöronlar) ve bu nöronlar arasındaki bağlantılardan (ağırlıklar) oluşan aktivasyon fonksiyonu kullanarak çıktıyı tahmin eden algoritmalarıdır (Hinton et al., 2006). Yapay sinir ağları, özellikle büyük veri kümeleri ve karmaşık problemler için güçlü bir araçtır ve günümüzde derin öğrenme gibi daha ileri tekniklerin temelini oluşturur.



Şekil 13. ANN Çalışma Prensibi

Kaynak: Öztürk, Ergin Şahin, 2018

2.1.3. Veri Ön İşleme

Veri ön işleme, makine öğrenmesi ve veri analizi süreçlerinde önemli bir adımdır. Bu süreç, ham verilerin analize hazır hale getirilmesi amacıyla uygulanmaktadır.

Toplanan ham veriler üzerinde yapılan veri temizleme işlemleri; aykırı veri tespiti ve gürültü giderme, eksik veri tespiti ve ikamesi gibi adımları içerir. Veri dönüştürme işlemleri; veri birleştirme ve normalizasyon gibi yöntemlerle verilerin

karşılaştırılabilirliğini artırmayı hedefler. Veri azaltma işlemleri ise, özellik seçimi ve boyut indirgeme yöntemleriyle veri setini daha yönetilebilir ve analiz edilebilir hale getirir. Bu adımlar, makine öğrenmesi algoritmalarının performansını artırmak ve daha güvenilir sonuçlar elde etmek için veri seti üzerinde uygulanan kritik işlemlerdir.

2.1.3.1 Aykırı Veri Tespiti ve Çıkarılması

Aykırı veri tespiti için standart sapma, Z-skoru, kutu grafiği, Tukey's Fences ve Isolation Forest yöntemleri yaygın olarak kullanılmaktadır. Bu tez çalışması kapsamında Tukey's Fences yöntemi kullanılmıştır. Bu yöntem, çeyrekler arası aralık (IQR) değerini birinci çeyrek (Q1) ve üçüncü çeyrek (Q3) arasındaki farktan hesaplar. Alt sınır ve üst sınır aralıklarının dışında kalan değerler aykırı değerler olarak tespit edilmektedir (Tukey, 1977). Tukey's Fences yöntemi Denklem 8'te ifade edildiği gibi hesaplanmaktadır.

$$IQR = Q3 - Q1 \quad (8)$$

$$Alt\ Sınır = Q1 - 1,5 \times IQR \quad (9)$$

$$Üst\ Sınır = Q3 + 1,5 \times IQR \quad (10)$$

2.1.3.2. Eksik Veri Tespiti ve İkamesi

Eksik veri tespiti yapıldıktan sonra, eksik verilerinin analize etkisini yönetebilmek için liste silme, çiftler arası silme, veri ikamesi ve modelleme yöntemleri uygulanmaktadır. Veri ikame yöntemleri; basit ikame yöntemleri (ortalama, medyan, mod ikame), ileri düzey ikame yöntemleri (regresyon, stokastik regresyon ikame), çoklu ikame ve makine öğrenme tabanlı yöntemler (k-NN, rastgele orman ikame) olarak kategorilere ayrılmaktadır (Little et. al., 2002).

Bu tez çalışması kapsamında, eksik veri ikamesi için makine öğrenme tabanlı k-NN ikame yöntemi, yalnızca sayısal öznitelikler üzerinde Öklid uzaklık fonksiyonuna göre hesaplanmıştır. Bu yöntem, eksik değerleri tahmin etmek için eksik veriye en yakın olan k sayıda komşunun değerlerini kullanarak verilerdeki benzerliklerden yararlanır ve eksik verileri tahmin eder (Troyanskaya et al., 2001). Öklid uzaklık fonksiyonu Denklem 11'de ifade edildiği gibi hesaplanmaktadır.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (21)$$

2.1.3.3. Normalizasyon

Normalizasyon, farklı ölçeklerdeki verilerin karşılaştırılabilir olmasını ve algoritmaların daha iyi performans göstermesini sağlamak için verilerin belirli bir aralıkta yeniden ölçeklendirilmesini içerir. Yaygın olarak kullanılan normalizasyon yöntemleri arasında Z-skoru normalizasyonu, Min-Max normalizasyonu, logaritmik dönüşüm ve robust skalalama bulunmaktadır.

Bu tez çalışması kapsamında yalnızca sayısal öznitelikler üzerinde Min-Max normalizasyon yöntemi kullanılmıştır. Bu yöntem, verileri veri setindeki minimum ve maksimum değerleri kullanarak $[0,1]$ aralığında yeniden ölçeklendirir.

X mevcut değer, X_{\min} aralık içerisindeki en küçük değer ve X_{\max} aralık içerisindeki en büyük değeri ifade etmektedir (Jain et. al., 2000). Min-Max normalizasyonu Denklem 12'de ifade edildiği gibi hesaplanmaktadır.

$$X_{yeni} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

2.1.4. k-Katmanlı Çapraz Doğrulama

k-katmanlı çapraz doğrulama, veri setindeki her bir örneğin doğrulamada kullanılmasını sağlayarak modelin aşırı öğrenmesinin önüne geçmektir. Bu yöntem, veri setini k eşit katmana böler ve bir katmanı test kümesi, k-1 tanesini ise eğitim kümesi olarak kullanır. Bu işlem k kez tekrarlanır ve modelin performans metriği bu k tekrardan elde edilen ortalama ile modelin genel performansı değerlendirilir (James et. al., 2013).

2.1.5. Sentetik Azınlık Örneklem Arttırma (SMOTE) Yöntemi

Veri setinde bulunan hedef sınıfındaki verilerin sayısı, her kategori için yaklaşık olarak eşit dağılıma sahip değil ise bu tür veri setlerine dengesiz veri seti denmektedir. İlk defa 2002 yılında Nitesh V. Chawla ve çalışma arkadaşları tarafından geliştirilen SMOTE yöntemi, dengesiz veri setlerinde azınlık sınıfın örneklerini arttırmak ve sınıf dengesizliğini gidermek için kullanılan bir veri arttırma yöntemidir. Bu yöntem, her

azınlık sınıfı verisi için k en yakın komşu bulur ve rastgele seçilen bir komşu ile orijinal azınlık sınıfı verisi arasındaki doğrusal interpolasyon kullanarak sentetik veriler oluşturur. Oluşturulan sentetik veriler, orijinal azınlık sınıfı verilerine eklenerek dengeli bir veri kümesi oluşturur (Chawla et. al., 2002). Sentetik örneklerin oluşturulması Denklem 13'te ifade edildiği gibi hesaplanmaktadır.

$$x_{yeni} = x_i + \delta x (x_{nn} - x_i) \quad (13)$$

Burada x_i orijinal azınlık sınıfı örneği, x_{nn} rastgele seçilen k en yakın komşudan biridir ve δ , 0 ile 1 arasında rastgele bir sayıdır.

2.1.6. Öznitelik Seçimi

Modelin anlaşılabilirliğini arttırmak, hesaplama maliyetini azaltmak ve modelin performansını arttırmak amacıyla hedef sınıfın tahmin edilmesinde en fazla katkısı bulunan özniteliklerin belirlenmesinde kullanılan seçim yöntemleridir. Bu yöntemler genellikle iki ana kategoriye ayrılır: filtre tabanlı yöntemler ve sarmal tabanlı yöntemler.

Bu tez çalışması kapsamında Pearson Korelasyonu, RFE ve Bootstrap yöntemleri kullanılarak modelin performansı değerlendirilmiştir.

2.1.6.1. Bootstrap Yöntemi

Bootstrap, veri setinden rastgele örnekler alarak çok sayıda yeni veri seti oluşturur ve bu veri setleri üzerinde modelin performansını değerlendirerek özniteliklerin önemini belirleyen bir yöntemdir. Bu yöntem, özniteliklerin model üzerindeki etkilerini anlamak için öznitelik seçiminde yeniden örnekleme ve istatistiksel analizler kullanır (Davison et. al., 1997).

2.1.6.2. Yinemeli Özellik Eleme (RFE)

RFE, veri setinde içerisindeki özniteliklerin önem derecesine göre sıralanmasını ve en az öneme sahip özniteliklerin sistematik olarak elenmesini içeren bir yöntemdir. Bu yöntem, modelin performansını değerlendiren bir metrik kullanarak özniteliklerin önem derecelerini belirler ve en düşük öneme sahip öznitelikleri eleyerek en iyi performans gösteren öznitelik kümesini bulana kadar devam eder (Guyon et. al., 2002).

2.1.6.3. Pearson Korelasyonu

Pearson korelasyonu, veri seti içerisindeki özniteliklerin birbirleri arasında bulunan lineer ilişkinin varlığını, yönünü ve şiddetini ölçmek için kullanılan bir yöntemdir. Bu yöntem, öznitelikler arasındaki ilişkiyi ölçer ve bu ilişkiyi -1 ile +1 arasında bir değerle ifade eder. – ve + sembolleri ilişkinin yönünü göstermektedir. 0 ilişkinin zayıf, -1 kuvvetli olumsuz ve +1 kuvvetli olumlu olmak üzere ilişkinin varlığını ve şiddetini ifade etmektedir. Pearson korelasyonu, yüksek korelasyon gösteren özniteliklerin veri setinden seçilmesini sağlar (Pearson, 1895). Pearson Korelasyonu Denklem 14’te ifade edildiği gibi hesaplanmaktadır.

$$\rho_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \quad (14)$$

Burada, $Cov(X,Y)$ X ve Y arasındaki kovaryansı, σ_X ve σ_Y ise X ve Y'nin standart sapmalarını temsil eder.

2.1.7. Performans Metrikleri

2.1.7.1. Karmaşıklık Matrisi

Karmaşıklık matrisi, makine öğrenmesi sınıflandırma problemlerinde modelin başarısını ölçmek için gerçek değerler ve tahmin edilen değerler arasındaki ilişkileri gösteren bir matristir. Dört temel bileşenden oluşur: doğru pozitifler (TP), yanlış pozitifler (FP), doğru negatifler (TN) ve yanlış negatifler (FN). Karmaşıklık matris gösterimi Şekil 14.’de verilmiştir.

		Gerçek Değerler	
		Pozitif (1)	Negatif (0)
Tahmin Değerleri	Pozitif (1)	Doğru Pozitif	Yanlış Pozitif
	Negatif (0)	Yanlış Negatif	Doğru Negatif

Şekil 14. Karmaşıklık Matrisi

Şekil 14’te görüldüğü gibi karmaşıklık matrisinde yer alan ifadeler:

- **Doğru Pozitif (True Positive-TP):** Gerçek sınıf ve tahmin edilen sınıfın doğru şekilde sınıflandırıldığı durumdur
- **Yanlış Pozitif (False Positive-FP):** Gerçek sınıfın yanlış ve tahmin edilen sınıfın doğru sınıflandırıldığı durumdur.
- **Doğru Negatif (True Negative-TN):** Gerçek sınıf ve tahmin edilen sınıfın yanlış şekilde sınıflandırıldığı durumdur.
- **Yanlış Negatif (False Negative-FN):** Gerçek sınıfın doğru ve tahmin edilen sınıfın yanlış sınıflandırıldığı durumdur.

Karmaşıklık matrisi kullanılarak çeşitli performans metrikleri hesaplanabilmektedir. Bu metrikler, sınıflandırma modelinin başarısını değerlendirmede önemli rol oynamaktadır. (Powers, 2011)

2.1.7.2. Doğruluk

Model üzerinde doğru tahmin edilen durumların toplamının, tüm durumlar toplamına oranını ifade etmektedir. Doğruluk değeri, Denklem 15'te ifade edildiği gibi hesaplanmaktadır.

$$\text{Doğruluk (accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

2.1.7.3. Kesinlik

Model üzerinde gerçek negatif durumların tüm negatif durumlara oranı olarak ifade edilmektedir. Kesinlik değeri, Denklem 16'da ifade edildiği gibi hesaplanmaktadır.

$$\text{Kesinlik (specificity)} = \frac{TN}{TN + FP} \quad (16)$$

2.1.7.4. Duyarlılık

Model üzerinde pozitif olarak tahmin edilmesi gereken durumların kaçının doğru tahmin edildiği oranını ifade edilmektedir. Duyarlılık değeri, Denklem 17'de ifade edildiği gibi hesaplanmaktadır.

$$\text{Duyarlılık (recall)} = \frac{TP}{TP + FN} \quad (17)$$

2.1.7.5. Hassasiyet

Model üzerinde gerçek pozitif durumların tüm pozitif durumlara oranı olarak ifade edilmektedir. Hassasiyet değeri, Denklem 18’te ifade edildiği gibi hesaplanmaktadır.

$$\text{Hassasiyet (precision)} = \frac{TP}{TP + FP} \quad (18)$$


2.1.7.6. F-1 Skor

Kesinlik ve duyarlılık değerlerinin harmonik ortalamasının alınması ile Denklem 19’da ifade edildiği gibi hesaplanmaktadır.

$$\text{F1 Skor} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (19)$$

2.1.7.7. AUC Değeri

ROC eğrisinin altındaki alanı ifade eder ve bir sınıflandırma modelinin genel performansını ölçmek için kullanılır. ROC eğrisi, bir modelin çeşitli eşit değerlerdeki Doğru Pozitif Oranı (Duyarlılık) ve Yanlış Pozitif Oranı arasındaki ilişkiyi gösterir. AUC değerinin 0,5’ten küçük olması modelin rastgele tahmin yaptığını işaret ederken 1’e yaklaştıkça modelin tahmin performansının iyi ve mükemmel olduğunu ifade etmektedir.



Şekil 15. ROC Eğrisi

Kaynak: Tomak, Bek, 2010

2.2. Materyal

2.2.1. Veri Seti

Bu tez çalışmasında, Erciyes Üniversitesi Kadın Hastalıkları ve Doğum Ana Bilim Dalı Tüp Bebek Ünitesi'nde 2004 ile 2023 yılları arasında IVF tedavisi gören 3627 çiftin sağlık verileri Python programlama dili kullanılarak incelenmiştir. Veri setini oluşturan öznitelikler ve özellikleri Tablo 1'de özetlenmiştir.


Tablo 1. Veri Setini Oluşturan Öznitelikler ve Özellikleri

Öznitelik Numarası	Öznitelik Adı	Tanım	Öznitelik Türü	Öznitelik Değeri
1	k_yasi	Kadın yaşı	Sayısal	18-48
2	e_yasi	Erkek yaşı	Sayısal	19-64
3	inf_nedeni	İnfertilite nedeni	Kategorik	14 çeşit neden
4	inf_suresi	İnfertilite süresi	Sayısal	0 - 25
5	nu_us	Daha önce yapılan aşılama işlem sayısı	Kategorik	0 - 10
6	icsi_us	Daha önce yapılan tüp bebek tedavi sayısı	Kategorik	0 - 8
7	tese_us	Daha önce yapılan TESE işlem sayısı	Kategorik	0 - 5
8	epid_a_us	TESE işlemlerinde enjektör kullanımı	Kategorik	0: Enjektör kullanılmadı 1: Enjektör kullanıldı
9	once_gebelik	Tedavi öncesi gebelik sayısı	Kategorik	0 - 5
10	once_dusuk	Tedavi öncesi düşük sayısı	Kategorik	0 - 5
11	once_dogum	Tedavi öncesi canlı doğum sayısı	Kategorik	0 - 2
12	vki	Vücut kitle indeksi	Sayısal	2 - 44,5
13	protokol	Tedavi protokolü	Kategorik	9 çeşit protokol
14	toplam_do	Yumurtlama uyarıcılarının miktarı	Sayısal	46,56 - 20550
15	bE2	Bazal estradiol hormon	Sayısal	0,01 - 3639
16	PRL	Prolaktin hormon	Sayısal	0,24 - 349,7
17	bFSH	Bazal folikül uyarıcı hormon	Sayısal	0,09 - 60,6
18	LH	Lüteinizan hormon	Sayısal	0,01 - 94
19	hCG	İnsan koryonik gonadotropin hormon	Kategorik	5 çeşit ilaç veya ilaçların kombinasyonu
20	hCG_gunu_E2	hCG enjeksiyonu sonrası E2 değeri	Sayısal	18 - 10729
21	end_kalinlik	Endometriyum kalınlığı	Sayısal	0,8 - 23
22	triple	Triple ölçümünde ultrason kullanımı	Kategorik	0: Ultrason kullanılmadı 1: Ultrason kullanıldı
23	AFC	Antral follikül sayısı	Sayısal	1 - 44
24	toplanan_OS	Toplanan yumurta sayısı	Sayısal	0 - 72
25	MII_sayisi	Toplanan olgun yumurta sayısı	Sayısal	0 - 38
26	sperm_k	Sperm kaynağı	Kategorik	5 yöntem
27	sperm_sayisi	Sperm sayısı	Sayısal	0 - 310
28	A	İleri hareketli sperm sayısı	Sayısal	0 - 90
29	B	Hareketli sperm sayısı	Sayısal	0 - 192
30	C	Yerinde hareketli sperm sayısı	Sayısal	0 - 110
31	D	Hareketsiz sperm sayısı	Sayısal	0 - 154
32	sperm_m	Spermin dölleme yeteneği	Kategorik	0: Dölleme yeteneği az 1: Dölleme yeteneği iyi 2: Dölleme yeteneği kötü
33	2PN	Döllenen yumurta sayısı	Sayısal	0 - 33
34	t_gunu	Transfer günü	Kategorik	0 - 6
35	t_emb_s	Tranfer edilen yumurta sayısı	Sayısal	0 - 6
36	hatching	Embriyo zonasına yapılan işlem	Kategorik	0: İşlem yapılmadı 1: İşlem yapıldı
37	kan_ic	Katater içinde kan durumu	Kategorik	0: Yok / 1: Var
38	mukus_ic	Katater içinde mukus durumu	Kategorik	0: Yok / 1: Var
39	kan_dis	Katater dışında kan durumu	Kategorik	0: Yok / 1: Var
40	mukus_dis	Katater dışında mukus durumu	Kategorik	0: Yok / 1: Var
41	kl_gebelik	Klinik Gebelik	Kategorik	0: Başarısız / 1: Başarılı

Veri setinde yer alan sayısal özniteliklere ait istatistiksel bilgiler sırasıyla; "count" (toplam kayıt sayısı), "mean" (ortalama değeri), "std" (standart sapma değeri), "min" (minimum değeri), "25%" (ilk çeyrek değeri), "50%" (medyan değeri), "75%" (üçüncü çeyrek değeri) ve "max" (maksimum değeri) olarak tanımlanmıştır. Sayısal özniteliklere ait istatistiksel bilgiler Tablo 2’de ve özniteliklere ait histogram grafikleri Şekil 16’da sunulmuştur.

Tablo 2. Sayısal Özniteliklere Ait İstatistiksel Bilgiler


Öznitelik Numarası	Öznitelik Adı	count	mean	std	min	25%	50%	75%	max
1	k_yasi	3627	30.64489	5.325029	18	27	30	35	48
2	e_yasi	3627	34.04218	5.686529	19	30	33	37	64
4	inf_suresi	3615	6.921134	4.583201	0	3.5	6	9	25
12	vki	3298	25.43249	4.466847	2	22	25	28	44.5
14	toplam_doz	3312	2462.872	1157.581	46.56	1687.5	2212.5	3000	20550
15	bE2	3311	56.47046	101.093	0.01	31.75	45.53	63.19	3639
16	PRL	3349	17.67077	13.92452	0.24	10.2	14.59	21.2	349.7
17	bFSH	3392	7.086008	3.601548	0.09	5.28	6.5	7.9525	60.6
18	LH	3359	6.161135	4.518323	0.01	3.86	5.33	7.21	94
20	hCG_gunu_E2	3437	2139.871	1353.181	18	1152	1856	2877	10729
21	end_kalinlik	3387	10.16118	2.360455	0.8	8.5	10	12	23
23	AFC	3364	9.775268	6.110541	1	6	9	12	44
24	toplanan_OS	3627	8.766749	7.092072	0	3	8	13	72
25	MII_sayisi	3627	6.458506	5.704299	0	2	5	10	38
27	sperm_sayisi	3494	36.43078	46.9828	0	0.5	20	52	310
28	A	3452	4.241744	8.523674	0	0	0	5	90
29	B	3451	10.95358	18.74528	0	0	3	15	192
30	C	3452	9.360078	13.34699	0	0.1	4	13	110
31	D	3462	11.87913	15.81951	0	0.2	6	18	154
33	2PN	3623	4.349158	4.319812	0	1	3	7	33
35	t_emb s	3627	1.610973	1.265182	0	0	2	2	6



Şekil 16. Öznitelikler ve Histogram Grafikleri

Bu tez çalışmanın amacı, klinik gebelik sonucunu en fazla etkileyen değişkenleri tespit ederek tedavi öncesi ve tedavi sürecindeki verilerden hareketle tedavi başarısını tahmin etmektir. Bu amaca ulaşabilmek için iki ayrı veri seti kullanılarak **iki farklı yaklaşımla** analizler gerçekleştirilmiştir.

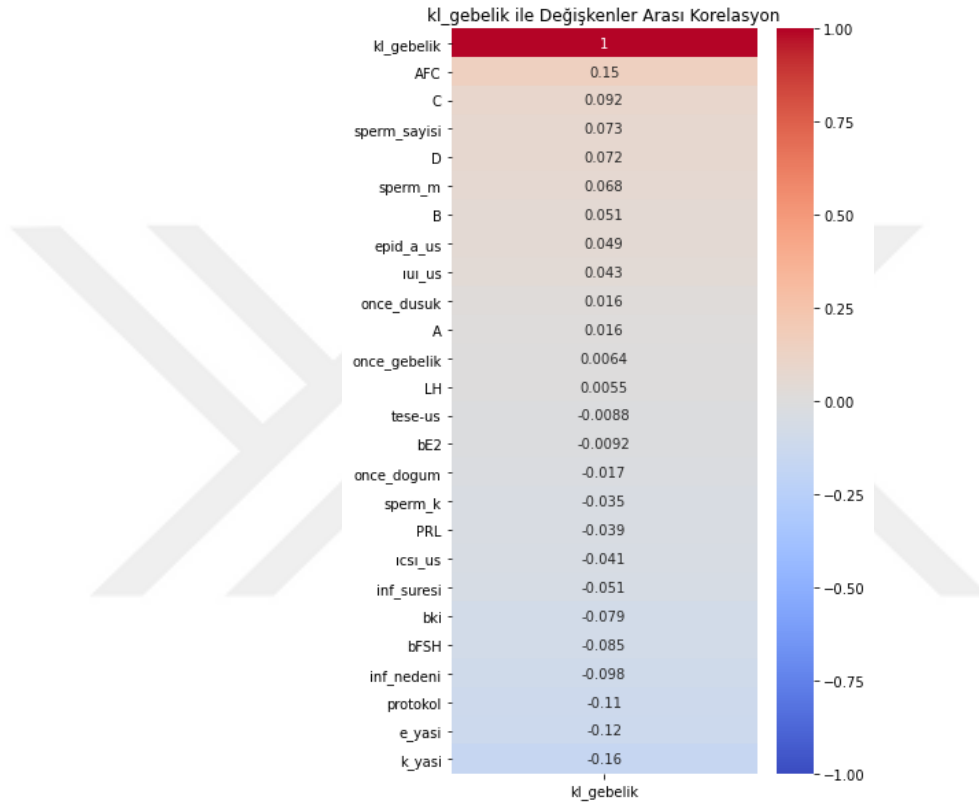
Çalışmada kullanılan **birinci yaklaşım**, tedavi öncesi ve tedavi süreci toplam 41 öznitelik kullanılarak çiftlerin klinik gebelik hedef değişken bilgisi dahilinde veriler analiz edilerek tedavi başarısı (başarılı = 1 veya başarısız = 0) tahmin edilmiştir. Veri setindeki 41 öznitelik ile hedef değişken arası korelasyonu gösteren ısı haritası Şekil 17’de verilmiştir.



Şekil 17. Hedef Değişken ile Değişkenler Arası Isı Haritası

Veri setinin ön işlemden geçmemiş halinde 3.627 veri bulunmaktadır. 2.1.3. Veri Ön İşleme bölümünde detaylı bir şekilde açıklanan aykırı verilerin tespiti ve çıkarılması, eksik verilerin tespiti ve ikamesi, normalizasyon yöntemlerinin uygulanması sonucunda 3.477 veri elde edilmiştir. Bu verilerin 2.641 adeti kl_gebelik = 0 iken 836 adet kl_gebelik =1 sınıf dağılımına sahiptir. Verinin dengesiz durumunu düzeltmek amacıyla SMOTE yöntemi uygulanmış ve sonuç olarak 2.641 adet kl_gebelik = 0 ve 2.641 adet kl_gebelik =1 olmak üzere toplam 5.282 verinin bulunduğu dengeli bir veri seti elde edilmiştir.

Çalışmada kullanılan **ikinci yaklaşımda** ise, sadece tedavi öncesi bilgilerin yer aldığı 26 öznitelik kullanılarak çiftlerin tedaviye başlama/başlamama kararını desteklemek amacıyla analiz gerçekleştirilerek tedavinin başarılı olma olasılığı tahmin edilmiştir. Veri setindeki 26 öznitelik ile hedef değişken arası korelasyonu gösteren ısı haritası Şekil 18’de verilmiştir.



Şekil 18. Hedef Değişken ile Değişkenler Arası Isı Haritası

Veri setinin ön işlemden geçmemiş halinde 3.627 veri bulunmaktadır. 2.1.3. Veri Ön İşleme bölümünde detaylı bir şekilde açıklanan aykırı verilerin tespiti ve çıkarılması, eksik verilerin tespiti ve ikamesi, normalizasyon yöntemlerinin uygulanması sonucunda 3.541 veri elde edilmiştir. Bu verilerin 2.676 adeti kl_gebelik = 0 iken 865 adet kl_gebelik =1 sınıf dağılımına sahiptir. Verinin dengesiz durumunu düzeltmek amacıyla SMOTE yöntemi uygulanmış ve sonuç olarak 2.676 adet kl_gebelik = 0 ve 2.676 adet kl_gebelik =1 olmak üzere toplam 5.352 verinin bulunduğu dengeli bir veri seti elde edilmiştir.

Bu çalışmanın her iki yaklaşımında kullanılan algoritmaların parametreleri Tablo 3.'te verilmiştir.

Tablo 3. Kullanılan Makine Öğrenmesi Algoritmalarının Parametreleri

Algoritma	Parametre	Açıklama
Random Forest	n_estimators=100	Ağaç sayısı.
	criterion='gini'	Saflık ölçütü.
	max_depth=None	Maksimum derinlik.
	min_samples_split=2	Bir düğümü bölmek için gereken minimum örnek sayısı.
	min_samples_leaf=1	Bir yaprak düğümünde bulunması gereken minimum örnek sayısı.
Naive Bayes	priors=None	Sınıf önceliklerini belirleyen dizi.
	var_smoothing=1e-9	Verinin varyansına eklenen küçük bir değer.
Logistic Regression	penalty='l2'	Düzenleme türü.
	C=1.0	Düzenleme kuvveti.
	solver='lbfgs'	Optimizasyon algoritması.
	max_iter=1000	En fazla iterasyon sayısı.
ANN	hidden_layer_sizes=(100,)	Gizli katmanlardaki nöron sayısı.
	activation='relu'	Aktivasyon fonksiyonu.
	solver='adam'	Ağırlık optimizasyon algoritması.
	alpha=0.0001	L2 düzenleme terimi.
	max_iter=1000	En fazla iterasyon sayısı.
	random_state=42	Rastgelelik için kullanılan sabit değer.
C4.5	criterion='entropy'	Karar ağacı oluşturulurken kullanılan kriter ('entropy' bilgiyi ölçer).
	splitter='best'	Bölme stratejisi.
	max_depth=None	Maksimum derinlik.
	min_samples_split=2	Bir düğümü bölmek için gereken minimum örnek sayısı.
	min_samples_leaf=1	Bir yaprak düğümünde bulunması gereken minimum örnek sayısı.
CART	criterion='gini'	Karar ağacı oluşturulurken kullanılan kriter ('gini' saflaştırma ölçer).
	splitter='best'	Bölme stratejisi.
	max_depth=None	Maksimum derinlik.
	min_samples_split=2	Bir düğümü bölmek için gereken minimum örnek sayısı.
	min_samples_leaf=1	Bir yaprak düğümünde bulunması gereken minimum örnek sayısı.
kNN	n_neighbors=5	Komşu sayısı.
	metric='precomputed'	Önceden hesaplanmış mesafe metriği kullanılır. (Gower Mesafesi)
SVM	C=1.0	Düzenleme parametresi.
	kernel='rbf'	Kernel türü.
	degree=3	Polynomial kernel derecesi.
	gamma='scale'	Kernel katsayısı.
	probability=True	Olasılık tahminlerinin etkinleştirilmesi.
Gradyan Arttırma	n_estimators=100	Ağaç sayısı.
	learning_rate=0.1	Öğrenme hızı.
	max_depth=3	Maksimum derinlik.
	subsample=1.0	Alt örnekleme oranı.
	random_state=42	Rastgelelik için kullanılan sabit değer.
Uyarlamalı Arttırma	n_estimators=50	Ağaç sayısı.
	learning_rate=1.0	Öğrenme hızı.
	random_state=42	Rastgelelik için kullanılan sabit değer.

3. BÖLÜM

BULGULAR


3.1 Araştırma Modeli

Bu bölümde 2. Bölümde detaylı bir şekilde açıklanmış olan makine öğrenmesi algoritmaları, geliştirme ortamı, performans ölçütleri ve veri seti kullanılarak yöntemlere ait sonuçlar verilmiş ve yorumlanmıştır. IVF tedavi başarısının tahminlenmesi ve IVF tedavi başarı olasılığının tedavi öncesi verilerle tahminlenmesi yaklaşımları için sonuçlar ayrı alt başlıklar halinde açıklanmıştır. Elde edilen sonuçlar, doğruluk, kesinlik, duyarlık, hassasiyet, f1-skor ve AUC değeri performans metriklerine göre değerlendirilmiş ve yorumlanmıştır.

3.2 Evren ve Örneklem

3.2.1 IVF Tedavi Başarısının Tahminlenmesi

Bu çalışmada, çalışmanın birinci yaklaşımında yer alan tedavi öncesi ve tedavi sürecindeki bilgileri içeren 40 öznitelik ve 1 hedef değişken ile 5.282 veriden oluşan SMOTE uygulanmış dengeli veri seti kullanılmıştır. Analizlerin ilk aşamasında, veri setinin eğitim ve test kümelerine ayrılması için farklı yöntemler değerlendirilmiştir. Ardından, öznitelik seçimi yöntemleri kullanılarak, seçilen öznitelikler ile makine öğrenmesi algoritmalarının performansı çeşitli metriklerle değerlendirilmiştir. Birinci yaklaşımda kullanılan iş akış şeması Şekil 19'da verilmiştir.



Şekil 19. 1.Yaklaşım: İş Akış Şeması

3.2.1.1. Eğitim ve Test Kümesinin Belirlenmesi

Veri setinin eğitim ve test kümelerine ayrılması adımı makine öğrenimi algoritmalarının performansını değerlendirmek için kritik öneme sahiptir. Bu çalışmada, eğitim ve test kümesinin belirlenmesinde dört farklı seçenek kullanılmıştır: %80 eğitim seti ve %20 test seti, %66 eğitim seti ve %34 test seti, 5-katlı çapraz doğrulama ve 10-katlı çapraz doğrulama. Bu seçenekler SVM, C4.5, CART, Rastgele Orman, k-NN, Naive Bayes, Lojistik Regresyon ve ANN algoritmalarıyla analiz edilmiştir.

%80 eğitim seti ve %20 test seti olarak belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 4.'te sunulmuştur.

Tablo 4. 1.Yaklaşım: %80 eğitim seti- %20 test seti Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
SVM	69.82	45.12	63.63	94.01	75.89	79.68
C45	78.62	77.63	78.41	79.59	79.00	78.61
CART	77.29	75.14	76.53	79.40	77.94	77.27
Rastgele Orman	84.96	80.69	82.50	89.14	85.69	94.35
k-NN	79.75	65.77	73.60	93.45	82.34	88.39
Naive Bayes	72.28	66.92	70.53	77.53	73.86	79.56
Lojistik Regresyon	71.05	61.19	67.98	80.71	73.80	75.70
ANN	81.46	74.38	77.89	88.39	82.81	88.56

Tablo 4.'te yer alan sonuçlara göre, **Rastgele Orman** algoritması %84.96 doğruluk ve %94.35 AUC değeri ile en yüksek performansı göstermiştir. **ANN** %81.46 doğruluk ve %88.56 AUC değeri ile ikinci sırada yer alırken, **k-NN**, **C4.5** ve **CART** algoritmaları sırasıyla %79.75, %78.62 ve %77.29 doğruluk oranları ile dengeli bir performans sergilemiştir. **SVM** ve **Naive Bayes** algoritmaları ise daha düşük doğruluk oranları ile performans göstermiştir. SVM duyarlılık metriğinde %94.01 ile oldukça yüksek bir değer elde etmiştir. Bu, SVM'nin bazı sınıflarda çok başarılı olduğunu, ancak genel doğruluk açısından diğer algoritmalar kadar etkili olmadığını göstermektedir. %66 eğitim seti ve %34 test seti olarak belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 5.'te sunulmuştur.

Tablo 5. 1.Yaklaşım: %66 eğitim seti- %34 test seti Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
SVM	69.66	44.19	63.78	94.01	76.00	77.60
C45	75.50	73.92	75.53	77.02	76.27	75.47
CART	74.83	73.92	75.72	74.73	75.22	74.84
Rastgele Orman	81.79	76.54	79.46	86.82	82.98	92.46
k-NN	77.39	62.76	71.96	91.39	80.52	85.99
Naive Bayes	71.16	66.29	70.16	75.82	72.88	77.70
Lojistik Regresyon	70.77	61.39	68.35	79.74	73.61	75.46
ANN	79.96	69.70	75.60	89.76	82.07	86.17

Tablo 5.'te yer alan sonuçlara göre, **Rastgele Orman** algoritması %81.79 doğruluk ve %92.46 AUC değeri ile en iyi performansı göstermiştir. **ANN** algoritması %79.96 doğruluk ve %86.17 AUC değeri ile ikinci sırada yer alırken, diğer algoritmalar daha düşük doğruluk ve AUC değerleri sergilemiştir.

5-katlı çapraz doğrulama yöntemiyle belirlenen veri setinde makine öğrenmesi algoritmalarının performans metrikleriyle birlikte Tablo 6'da sunulmuştur.

Tablo 6. 1.Yaklaşım: 5-katlı Çapraz Doğrulama Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	AUC Değeri
					Skor	
SVM	78.50	63.26	71.84	93.75	81.35	82.78
C45	84.00	80.87	82.00	87.12	84.48	84.00
CART	84.00	80.87	82.00	87.12	84.48	84.00
Rastgele Orman	90.53	81.44	84.30	99.62	91.32	98.89
k-NN	83.05	69.32	75.93	96.78	85.10	90.52
Naive Bayes	81.82	80.30	80.88	83.33	82.09	89.58
Lojistik Regresyon	76.89	74.05	75.45	79.74	77.53	83.33
ANN	84.75	71.21	77.35	98.30	86.57	89.84

5-katlı çapraz doğrulama sonuçlarında, **Rastgele Orman** algoritması %90.53 doğruluk ve %98.89 AUC değeri ile en yüksek performansı göstermiştir. **C4.5** ve **CART** algoritmaları %84 doğruluk ve %84 AUC değerleri ile dengeli performans sergilemiştir. Bu yöntemle yapılan doğrulama, Rastgele Orman algoritmasının verilerin dağılımından bağımsız olarak genel olarak yüksek performans gösterdiğini ortaya koymuştur.

10-katlı çapraz doğrulama yöntemiyle belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 7.'de sunulmuştur.

Tablo 7. 1.Yaklaşım: 10-katlı Çapraz Doğrulama Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	AUC Değeri
					Skor	
SVM	89.02	84.47	85.76	93.56	89.49	94.27
C45	93.37	92.05	92.25	94.70	93.46	93.37
CART	91.10	92.42	92.22	89.77	90.98	91.10
Rastgele Orman	95.08	91.29	91.90	98.86	95.26	99.70
k-NN	91.86	87.50	88.50	96.21	92.20	96.78

Naive Bayes	86.93	90.15	89.47	83.71	86.50	93.21
Lojistik Regresyon	86.93	91.29	90.46	82.58	86.34	93.94
ANN	93.18	88.64	89.58	97.73	93.48	97.57

10-katlı çapraz doğrulama sonuçlarında, **Rastgele Orman** algoritması %95.08 doğruluk ve %99.70 AUC değeri ile en yüksek performansı sergilemiştir. **C4.5** ve **ANN** algoritmaları da yüksek doğruluk ve AUC değerleri ile iyi performans göstermiştir. Bu sonuçlar, Rastgele Orman algoritmasının IVF tedavi başarısını tahmin etmede en etkili algoritma olduğunu bir kez daha ortaya koymuştur.

Veri setinin eğitim ve test kümelerine ayrılmasında dört seçeneği değerlendirdiğimizde en düşük performansı %66 eğitim seti- %34 test seti, ardından %80 eğitim seti- %20 test seti ve 5-katlı çapraz doğrulama gösterirken, en yüksek performansı 10-katlı çapraz doğrulama yöntemi ile elde edilmiştir. 10 katlı çapraz doğrulama yöntemi ile her model için 10 farklı eğitim ve test seti oluşturularak, en iyi performans gösteren veri seti belirlenmiş ve modeller bu veri seti üzerinde eğitilmiştir. Modellerin sonuçlarına göre, Rastgele Orman algoritması en yüksek doğruluk %95.08 ve AUC %99.70 değerleri ile en iyi performansa sahip olmuştur. Bu nedenle, bir sonraki analizler için veri seti olarak **10-katlı çapraz doğrulama veri seti** kullanılmıştır. Bu yöntem modelin genelleme yeteneğini daha iyi değerlendirmiş ve veri setindeki çeşitliliği en iyi şekilde temsil etmiştir. Bu bağlamda, bir sonraki analiz aşaması olarak öznitelik seçimi sürecine geçilmiştir.

3.2.1.2. Öznitelik Seçimi

Öznitelik seçimi verilerdeki önemli özelliklerin belirlenmesi ve gereksiz özelliklerin ayıklanması süreçlerini içerir. Doğru özniteliklerin seçilmesi, makine öğrenmesi modellerinin karmaşıklığını azaltmayı, eğitim süresini kısaltmayı ve performansını arttırmayı sağlar. Öznitelik seçimini belirlemek için üç yöntem ele alınmıştır: Bootstrap Yöntemi, Yinemeli Özellik Eleme ve Pearson Korelasyonu. Bu üç öznitelik seçim yöntemi kullanılarak oluşturulan öznitelik alt kümeleri ile aynı sekiz makine öğrenmesi algoritmaları tekrar eğitilmiştir. Eğitim sonuçları incelendiğinde, bazı öznitelik seçim yöntemlerinin bazı sınıflandırma modellerinin performansını iyileştirdiği, bazılarında ise

performansın değişmediği veya düştüğü gözlemlenmiştir. Bu doğrultuda, modellerin IVF tedavi başarısını tahmin etmedeki etkinliği değerlendirilmiştir.

Veri setindeki 41 öznitelikten Bootstrap yöntemi ile 26 öznitelik, Yinemeli Özellik Eleme yöntemi ile 20 öznitelik ve Pearson Korelasyonu yöntemi ile 15 öznitelik önemli olarak seçilmiştir. Seçilen özniteliklerden oluşturulan öznitelik alt kümeleri Tablo 8.'de sunulmuştur.

Tablo 8. 1.Yaklaşım: Öznitelik Seçimi Yöntemlerine Göre Öznitelik Alt Kümeleri

Bootstrap Yöntemi	Yinemeli Özellik Eleme	Pearson Korelasyonu
k_yasi	k_yasi	k_yasi
e_yasi	e_yasi	e_yasi
inf_nedeni	inf_suresi	inf_nedeni
inf_suresi	vki	protokol
ıuı_us	toplam_doz	toplam_doz
ıcsı_us	bE2	bFSH
vki	PRL	hCG_gunu_E2
protokol	LH	end_kalinlik
toplam_doz	hCG_gunu_E2	AFC
bE2	end_kalinlik	toplanan_OS
PRL	AFC	MII_sayisi
bFSH	toplanan_OS	2PN
LH	MII_sayisi	t_gunu
hCG_gunu_E2	sperm_sayisi	t_emb_s
end_kalinlik	B	hatching
AFC	C	
toplanan_OS	D	
MII_sayisi	2PN	
sperm_sayisi	t_gunu	
A	t_emb_s	
B		
C		
D		
2PN		
t_gunu		
t_emb_s		

Bootstrap yöntemi ile veri setindeki özniteliklerden seçilen 26 öznitelik önem sırasına göre şunlardır: k_yasi, e_yasi, inf_nedeni, inf_suresi, ıuı_us, ıcsı_us, vki, protokol, toplam_doz, bE2, PRL, bFSH, LH, hCG_gunu_E2, end_kalinlik, AFC, toplanan_OS, MII_sayisi, sperm_sayisi, A, B, C, D, 2PN, t_gunu, t_emb_s. Bu seçilen öznitelikler ile makine öğrenmesi algoritmaları çalıştırıldığında alınan sonuçlar performans metrikleriyle birlikte Tablo 9.'da sunulmuştur.

Tablo 9. 1.Yaklaşım: Bootstrap Yöntemi Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
SVM	88.83	84.47	85.71	93.18	89.29	93.85
C45	92.99	91.67	91.88	94.32	93.08	92.99
CART	91.10	91.67	91.57	90.53	91.05	91.10
Rastgele Orman	94.70	90.53	91.26	98.86	94.91	99.62
k-NN	88.99	81.76	84.07	96.23	89.74	95.73
Naive Bayes	88.07	90.91	90.36	85.23	87.72	95.36
Lojistik Regresyon	87.50	92.05	91.25	82.96	86.91	94.28
ANN	91.86	87.88	88.77	95.83	92.17	96.14

Bootstrap Yöntemi ile seçilen 26 öznelik ile elde edilen performans sonuçlarını incelendiğinde **Rastgele Orman** algoritması en yüksek doğruluk oranı %94.70 ve en yüksek AUC değeri %99.62 ile en iyi performansı sergilemiştir. **C4.5** ve **ANN** algoritmaları da oldukça iyi sonuçlar elde etmiştir.

RFE yöntemi ile veri setindeki özneliklerden seçilen 20 öznelik önem sırasına göre şunlardır: k_yasi, e_yasi, inf_suresi, vki, toplam_do, be2, PRL, LH, hCG_gunu_E2, end_kalinlik, AFC, toplanan_OS, MII_sayisi, sperm_sayisi, B, C, D, 2PN, t_gunu, t_emb_s. Bu seçilen öznelikler ile makine öğrenmesi algoritmaları çalıştırıldığında alınan sonuçlar performans metrikleriyle birlikte Tablo 10.'da sunulmuştur.

Tablo 10. 1.Yaklaşım: RFE Yöntemi Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
SVM	88.07	83.71	85.02	92.42	88.57	95.33
C45	93.56	92.42	92.59	94.70	93.63	93.56
CART	89.02	89.39	89.31	88.64	88.97	89.02
Rastgele Orman	95.83	92.42	92.91	99.24	95.97	99.62
k-NN	91.67	88.64	89.29	94.70	91.91	96.57
Naive Bayes	87.50	91.67	90.91	83.33	86.96	95.36
Lojistik Regresyon	86.74	92.42	91.45	81.06	85.94	94.45
ANN	90.34	89.77	89.89	90.91	90.40	96.19

RFE yöntemi ile seçilen 20 öznelik kullanılarak elde edilen performans sonuçları incelendiğinde **Rastgele Orman** algoritması en yüksek doğruluk oranı %95.83 ve AUC

değerini %99.62 elde ederek en iyi performansı sergilemiştir. **C45** ve **k-NN** algoritmaları da yüksek performans göstermiştir.

Pearson Korelasyonu yöntemi ile veri setindeki özniteliklerden seçilen 15 öznitelik önem sırasına göre şunlardır: *k_yasi*, *e_yasi*, *inf_nedeni*, *protokol*, *toplam_doiz*, *bFSH*, *hCG_gunu_E2*, *end_kalinlik*, *AFC*, *toplanan_OS*, *MII_sayisi*, *2PN*, *t_gunu*, *t_emb_s*, *hatching*. Bu seçilen öznitelikler ile makine öğrenmesi algoritmaları çalıştırıldığında alınan sonuçlar performans metrikleriyle birlikte Tablo 11.'de sunulmuştur.

Tablo 11. 1.Yaklaşım: Pearson Korelasyonu Performans Metrikleri


Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
SVM	88.83	81.44	83.83	96.21	89.59	93.81
C45	95.27	94.32	94.42	96.21	95.31	95.27
CART	92.80	92.05	92.16	93.56	92.86	92.80
Rastgele Orman	96.59	93.94	94.25	99.24	96.68	99.83
k-NN	91.67	87.12	88.19	96.21	92.03	97.07
Naive Bayes	88.26	90.53	90.08	85.99	87.98	95.79
Lojistik Regresyon	86.36	90.15	89.34	82.58	85.83	93.32
ANN	90.15	86.74	87.59	93.56	90.48	95.25

Pearson Korelasyonu Yöntemi ile seçilen 15 öznitelik ile elde edilen sonuçlar incelendiğinde de **Rastgele Orman** algoritması, %96.59 doğruluk ve %99.83 AUC değeri ile en yüksek performansı gösteren algoritma olmuştur. **C45** ve **CART** algoritmaları da yüksek performans değerleri sunmuştur. Pearson Korelasyonu diğer öznitelik seçimi yöntemlerine göre daha az öznitelik ile modeli daha iyi genellediği ve daha yüksek başarı sonuçları verdiği görülmüştür.

Bu sonuçlar, öznitelik seçimi yöntemlerinin makine öğrenmesi algoritmalarının performansını önemli ölçüde etkileyebileceğini göstermektedir. RFE ve Pearson Korelasyonu yöntemleri, genellikle daha düşük öznitelik sayısı ile benzer veya daha yüksek performans elde edilmesini sağlamıştır. Özellikle Pearson Korelasyonu yöntemi, en yüksek doğruluk ve AUC değerlerini sunarak, özniteliklerin seçiminde etkili bir yaklaşım olduğunu ortaya koymuştur. Rastgele Orman algoritması ise her üç yöntemde de en yüksek performansı sağlayarak tedavi başarısını en yüksek doğrulukla eden algoritma olmuştur.

3.2.2. IVF Tedavi Başarı Olasılığının Tedavi Öncesi Verilerle Tahminlenmesi

Bu çalışmada ele alınan ikinci yaklaşımda tedavi öncesi bilgileri içeren 26 öznitelik, 1 hedef değişken ve 5.352 veriden oluşan SMOTE uygulanmış dengeli veri seti kullanılmıştır. Analizlerin ilk aşamasında, veri setinin eğitim ve test kümelerine ayrılması için farklı yöntemler uygulanmıştır. Ardından, öznitelik seçimi yöntemleri kullanılarak, seçilen öznitelikler ile makine öğrenmesi algoritmalarının performansı çeşitli metriklerle değerlendirilmiştir. İkinci yaklaşımda kullanılan iş akış şeması Şekil 20.'de verilmiştir.



Şekil 20. 2.Yaklaşım: İş Akış Şeması

İkinci yaklaşımda, tedavi başarısı olasılığını tahmin etmek amacıyla, olasılık üretebilen makine öğrenmesi algoritmaları kullanılmıştır. Bu bağlamda, çeşitli algoritmaların olasılık tahmini yapma yöntemleri şu şekilde açıklanabilir:

Lojistik Regresyon algoritması, bağımlı değişkenin logaritmik oranını kullanarak bir olayın olma olasılığı ile olmama olasılığı arasındaki oranına dayalı bir olasılık tahmini yapmaktadır. Naive Bayes algoritması ise Bayes teoremini temel alarak, her bir özneliğin bağımsızlığı varsayımıyla olasılık hesaplaması gerçekleştirmektedir. k-NN algoritması, en yakın komşuların sınıflarının ağırlıklı ortalamasına dayanarak olasılık üretmektedir. SVM, karar sınırına olan uzaklıkları kullanarak olasılık tahmini yapmaktadır. Rastgele Orman ve Gradyan Arttırma algoritmaları, birden fazla karar ağacının oylama mekanizmasıyla olasılık hesaplaması gerçekleştirirken, Uyarlamalı Arttırma algoritması zayıf sınıflandırıcıların birleşimiyle daha güçlü bir sınıflandırıcı oluşturarak olasılık tahmini yapmaktadır. ANN ise, çok katmanlı algılayıcı yapısıyla, ağırlıkların güncellenmesi sonucu olasılık tahmini gerçekleştirmektedir.

3.2.2.1. Eğitim ve Test Kümesinin Belirlenmesi

Veri setinin eğitim ve test kümelerine ayrılması adımı makine öğrenimi algoritmalarının performansını değerlendirmek için kritik öneme sahiptir. Bu çalışmada, eğitim ve test kümesinin belirlenmesinde dört farklı seçenek kullanılmıştır: %80 eğitim seti ve %20 test seti, %66 eğitim seti ve %34 test seti, 5-katlı çapraz doğrulama ve 10-katlı çapraz doğrulama. Bu seçenekler Lojistik Regresyon, Naive Bayes, k-NN, SVM, Rastgele Orman, Gradyan Arttırma, Uyarlamalı Arttırma, ANN algoritmalarıyla analiz edilmiştir.

%80 eğitim seti ve %20 test seti olarak belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 12.'de sunulmuştur.

Tablo 12. 2.Yaklaşım: %80 eğitim seti- %20 test seti Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
Lojistik Regresyon	61.72	56.49	59.66	67.18	63.20	66.28
Naive Bayes	63.96	54.30	60.82	74.05	66.78	69.44
k-NN	72.83	54.66	65.98	91.79	76.78	83.52
SVM	62.65	43.69	58.38	82.44	68.35	66.60
Rastgele Orman	84.03	78.24	79.86	90.08	84.66	93.00

Gradyan Arttırma	78.24	69.84	73.43	87.02	79.65	89.81
Uyarlamalı Arttırma	73.11	59.78	67.46	87.02	76.00	83.39
ANN	73.20	59.96	67.56	87.02	76.06	80.58

Tablo 12’de yer alan sonuçlara göre, **Rastgele Orman** algoritması %84.03 doğruluk ve %93.00 AUC değeri ile en yüksek performansı göstermiştir. **Gradyan Arttırma** %78.24 doğruluk ve %89.81 AUC değeri ile ikinci sırada yer alırken, **ANN** ve **Uyarlamalı Arttırma** algoritmaları sırasıyla %73.20 ve %73.11 doğruluk oranları ile dengeli bir performans sergilemiştir. Lojistik Regresyon ve SVM algoritmaları ise daha düşük doğruluk oranları ile performans göstermiştir.

%66 eğitim seti ve %34 test seti olarak belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 13.’te sunulmuştur.

Tablo 13. 2.Yaklaşım: %66 eğitim seti- %34 test seti Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
Lojistik Regresyon	60.66	56.96	59.77	64.39	62.00	64.45
Naive Bayes	63.52	52.79	61.00	74.31	67.00	68.32
k-NN	71.32	54.33	65.79	88.42	75.45	79.35
SVM	62.09	45.67	58.97	78.61	67.39	65.18
Rastgele Orman	80.33	75.03	77.31	85.67	81.28	90.15
Gradyan Arttırma	76.92	69.11	73.17	84.79	78.55	88.52
Uyarlamalı Arttırma	72.58	61.34	68.31	83.90	75.31	81.75
ANN	72.42	66.92	70.07	77.95	73.80	79.64

Tablo 13.’te yer alan sonuçlara göre, **Rastgele Orman** algoritması %80.33 doğruluk ve %90.15 AUC değeri ile en iyi performansı göstermiştir. **Gradyan Arttırma** algoritması %79.92 doğruluk ve %88.52 AUC değeri ile ikinci sırada yer alırken, diğer algoritmalar daha düşük doğruluk ve AUC değerleri sergilemiştir.

5-katlı çapraz doğrulama yöntemiyle belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 14.’te sunulmuştur.

Tablo 14. 2.Yaklaşım: 5-katlı Çapraz Doğrulama Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
Lojistik Regresyon	61.96	58.88	61.27	65.05	63.10	66.32
Naive Bayes	68.32	60.37	65.81	76.26	70.65	72.15
k-NN	70.65	48.79	64.37	92.52	75.92	80.27
SVM	61.31	45.98	58.66	76.64	66.45	63.17
Rastgele Orman	83.93	70.09	76.57	97.76	85.88	96.44
Gradyan Arttırma	80.37	63.74	72.79	97.01	83.17	94.85
Uyarlamalı Arttırma	74.86	57.01	68.32	92.71	78.67	83.93
ANN	74.49	60.37	69.10	88.60	77.64	82.37

5-katlı çapraz doğrulama sonuçlarına göre, **Rastgele Orman** algoritması %83.93 doğruluk ve %96.44 AUC değeri ile en yüksek performansı göstermiştir. **Gradyan Arttırma** algoritmaları %80.37 doğruluk ve %94.85 AUC değerleri ile dengeli performans sergilemiştir. Bu yöntemle yapılan doğrulama, Rastgele Orman algoritmasının verilerin dağılımından bağımsız olarak yüksek performans gösterdiğini ortaya koymuştur.

10-katlı çapraz doğrulama yöntemiyle belirlenen veri setinde makine öğrenmesi algoritmalarının performans metriklerine göre sonuçları Tablo 15'te sunulmuştur.

Tablo 15. 2.Yaklaşım: 10-katlı Çapraz Doğrulama Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1	
					Skor	AUC Değeri
Lojistik Regresyon	68.60	67.54	68.13	69.66	68.89	75.19
Naive Bayes	71.96	59.70	67.57	84.27	75.00	78.30
k-NN	77.76	59.70	70.33	95.88	81.14	86.69
SVM	68.04	48.13	62.83	88.02	73.32	71.86
Rastgele Orman	87.47	75.75	80.30	99.25	88.78	98.42
Gradyan Arttırma	84.67	71.16	77.35	98.13	86.51	96.45
Uyarlamalı Arttırma	77.76	64.05	71.85	91.42	80.46	86.94
ANN	71.59	59.33	67.27	83.90	74.67	79.66

10-katlı çapraz doğrulama sonuçlarında, **Rastgele Orman** algoritması %87.47 doğruluk ve %98.42 AUC değeri ile en yüksek performansı sergilemiştir. **Gradyan Arttırma** algoritması da yüksek doğruluk ve AUC değeri ile iyi performans göstermiştir. Bu

sonular, Rastgele Orman algoritmasının IVF tedavi bařarısını tahmin etmede en etkili algoritma olduėunu bir kez daha ortaya koymuřtur.

Veri setinin eėitim ve test kmelerine ayrılmasında drt seeneėi deėerlendirdiėimizde en dřk performans %66 eėitim seti- %34 test seti, ardından %80 eėitim seti- %20 test seti ve 5-katlı apraz doėrulama gsterirken, en yksek performans 10-katlı apraz doėrulama yntemi ile elde edilmiřtir. 10 katlı apraz doėrulama yntemi ile her model iin 10 farklı eėitim ve test seti oluřturularak, en iyi performans gsteren veri seti belirlenmiř ve modeller bu veri seti zerinde eėitilmiřtir. Modellerin sonularına gre, Rastgele Orman algoritması en yksek doėruluk %87.47 ve AUC %98.42 deėerleri ile en iyi performansa sahip olmuřtur. Bu nedenle, bir sonraki analizler iin veri seti olarak **10-katlı apraz doėrulama veri seti** kullanılmıřtır. Bu yntem modelin genelleme yeteneėini daha iyi deėerlendirmiř ve veri setindeki eřitliliėi en iyi řekilde temsil etmiřtir. Bu baėlamda, bir sonraki analiz ařaması olarak znitelik seimi srecine geilmiřtir.

3.2.2.2. znitelik Seimi

znitelik seimini belirlemek iin aynı  yntem ele alınmıřtır: Bootstrap Yntemi, Yinemeli zellik Eleme ve Pearson Korelasyonu. Bu  znitelik seim yntemi kullanılarak oluřturulan znitelik alt kmeleri ile aynı sekiz olasılık sonucu verebilen makine ėrenmesi algoritmaları tekrar eėitilmiřtir. Eėitim sonuları incelendiėinde, bazı znitelik seim yntemlerinin bazı sınıflandırma modellerinin performansını iyileřtirdiėi, bazılarında ise performansın deėiřmediėi ve dřtėi gzlemlenmiřtir. Bu doėrultuda, modellerin IVF tedavi bařarısını tahmin etmedeki etkinliėi deėerlendirilmiřtir.

Veri setindeki 26 znitelikten Bootstrap yntemi ile 19 znitelik, Yinemeli zellik Eleme yntemi ile 25 znitelik ve Pearson Korelasyonu yntemi ile 7 znitelik nemli olarak seilmiřtir. Seilen zniteliklerden oluřturulan znitelik alt kmeleri Tablo 16.'da verilmiřtir.

Tablo 16. 2.Yaklaşım: Öznitelik Seçimi Yöntemlerine Göre Öznitelik Alt Kümeleri

Bootstrap Yöntemi	Yinemeli Özellik Eleme	Pearson Korelasyonu
k_yasi	k_yasi	k_yasi
e_yasi	e_yasi	e_yasi
inf_nedeni	inf_nedeni	inf_nedeni
inf_suresi	inf_suresi	vki
ıuı_us	ıuı_us	protokol
ıcsı_us	ıcsı_us	bFSH
vki	tese_us	AFC
protokol	epid_a_us	
bE2	once_gebelik	
PRL	once_dusuk	
bFSH	once_dogum	
LH	vki	
AFC	protokol	
sperm_sayisi	bE2	
A	PRL	
B	bFSH	
C	LH	
D	AFC	
sperm_m	sperm_k	
	sperm_sayisi	
	A	
	B	
	C	
	D	
	sperm_m	

Bootstrap yöntemi ile veri setindeki özniteliklerden seçilen 19 öznitelik şunlardır: k_yasi, e_yasi, inf_nedeni, inf_suresi, ıuı_us, ıcsı_us, vki, protokol, bE2, PRL, bFSH, LH, AFC, sperm_sayisi, A, B, C, D, sperm_m. Bootstrap yöntemiyle oluşturulan bu alt küme, bir önceki yaklaşımda seçilen öznitelik alt kümesinden tedavi sürecinin öznitelikleri çıkartıldığında da oluşmaktadır. Bu durum, Bootstrap yönteminin iki farklı yaklaşımda da önemli özniteliklerin aynı şekilde belirlediğini göstermektedir. Bu seçilen öznitelikler ile makine öğrenmesi algoritmaları çalıştırıldığında elde edilen sonuçlar, performans metrikleriyle birlikte Tablo 17’de sunulmuştur.

Tablo 17. 2.Yaklaşım: Bootstrap Yöntemi Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
Lojistik Regresyon	68.41	68.28	68.28	68.54	68.41	73.77
Naive Bayes	71.03	54.10	65.64	88.02	75.20	78.97
k-NN	77.38	60.45	70.39	94.38	80.64	85.87
SVM	64.49	61.94	63.70	67.04	65.33	63.23
Rastgele Orman	85.98	72.76	78.40	99.25	87.60	98.44
Gradyan Arttırma	85.05	71.16	77.49	98.88	86.89	97.13
Uyarlamalı Arttırma	78.13	63.06	71.55	93.26	80.98	88.03

ANN	76.08	68.28	72.49	83.90	77.78	82.77
-----	-------	-------	-------	-------	-------	-------

Bootstrap Yöntemi ile seçilen 19 öznitelik ile elde edilen performans sonuçları incelendiğinde, **Rastgele Orman** algoritması en yüksek doğruluk oranı %85.98 ve en yüksek AUC değeri %98.44 ile en iyi performansı sergilemiştir. **Gradyan Arttırma** algoritması %85.05 doğruluk ve %97.13 AUC değerleri ile yüksek performans elde etmiştir.

RFE yöntemi ile veri setindeki özniteliklerden seçilen 25 öznitelik şunlardır: k_yasi, e_yasi, inf_nedeni, inf_suresi, iu1_us, ics1_us, tese_us, epid_a_us, once_gebelik, once_dusuk, once_dogum vki, protokol, bE2, PRL, bFSH, LH, AFC, sperm_k, sperm_sayisi, A, B, C, D, sperm_m. RFE yöntemiyle oluşturulan bu alt küme, bir önceki yaklaşımda seçilen özniteliklerden farklı öznitelikleri de içermektedir. Ayrıca, RFE yöntemi veri setindeki 26 öznitelikten 25'ini seçerek neredeyse tüm özniteliklerin önemli olduğunu belirtmiş, ancak modelin karmaşıklığını azaltma ve model eğitim süresini kısaltma hedefine ulaşamamıştır. Bu durum RFE yönteminin ikinci yaklaşımda özniteliklerin seçiminde etkili bir yaklaşım olmadığını ortaya koymuştur. Bu seçilen öznitelikler ile makine öğrenmesi algoritmaları eğitildiğinde alınan sonuçlar, performans metrikleriyle birlikte Tablo 18'te sunulmuştur.

Tablo 18. 2.Yaklaşım: RFE Yöntemi Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
Lojistik Regresyon	68.60	67.54	68.13	69.66	68.89	75.19
Naive Bayes	71.96	59.70	67.57	84.27	75.00	78.30
k-NN	77.76	59.70	70.33	95.88	81.14	86.69
SVM	68.04	48.13	62.83	88.02	73.32	71.86
Rastgele Orman	88.60	78.36	81.99	98.88	89.64	98.12
Gradyan Arttırma	84.67	71.16	77.35	98.13	86.51	96.44
Uyarlamalı Arttırma	77.76	64.05	71.85	91.42	80.46	86.94
ANN	74.77	58.96	68.75	90.64	78.19	83.33

RFE yöntemi ile seçilen 25 öznitelik kullanılarak elde edilen performans sonuçları incelendiğinde **Rastgele Orman** algoritması en yüksek doğruluk oranı %88.60 ve AUC değerini %98.12 elde ederek en iyi performansı sergilemiştir. **Gradyan Arttırma**

algoritması %84.67 doğruluk ve %96.44 AUC değerleri ile yüksek performans elde etmiştir.

Pearson Korelasyonu yöntemi ile veri setindeki özniteliklerden seçilen 7 öznitelik şunlardır: k_yasi, e_yasi, inf_nedeni, vki, protokol, bFSH, AFC. Pearson korelasyon yöntemiyle oluşturulan bu alt küme, az sayıda öznitelik ile modeli temsil edebilmiştir. Seçilen bu öznitelikler ile makine öğrenmesi algoritmaları çalıştırıldığında alınan sonuçlar, performans metrikleriyle birlikte Tablo 19'da sunulmuştur.

Tablo 19. 2.Yaklaşım: Pearson Korelasyonu Performans Metrikleri

Algoritmalar	Doğruluk	Kesinlik	Hassasiyet	Duyarlılık	F-1 Skor	AUC Değeri
Lojistik Regresyon	65.11	52.24	62.02	77.99	69.09	71.24
Naive Bayes	68.79	64.18	67.12	73.41	70.13	76.23
k-NN	73.08	62.31	68.92	83.90	75.68	80.27
SVM	64.67	58.21	62.91	71.16	66.78	62.86
Rastgele Orman	91.40	87.69	87.21	97.00	91.84	97.90
Gradyan Arttırma	89.35	83.21	85.00	95.51	89.95	97.46
Uyarlamalı Arttırma	74.21	59.33	68.59	89.14	77.52	85.26
ANN	68.97	61.19	66.34	76.78	71.18	74.96

Pearson Korelasyonu Yöntemi ile seçilen 7 öznitelik ile elde edilen performans sonuçları incelendiğinde de **Rastgele Orman** algoritması, %91,40 doğruluk ve %97,90 AUC değeri ile en yüksek performansı gösteren algoritma olmuştur. **Gradyan Arttırma** algoritması ise %89.35 doğruluk ve %97.46 AUC değerleri ile yüksek performans elde etmiştir. Pearson Korelasyonu yöntemi, diğer öznitelik seçimi yöntemlerine göre daha az öznitelik ile modeli daha iyi genellediği ve daha yüksek başarı sonuçları verdiği görülmüştür.

Sonuç olarak, Bootstrap, RFE ve Pearson Korelasyonu yöntemleri kullanılarak seçilen özniteliklerle yapılan analizlerde, Rastgele Orman algoritmasının her üç yöntemde de en iyi performansı sergilediği görülmüştür. Gradyan Arttırma algoritması da her üç yöntemde yüksek performans göstermiştir, bu da onu güçlü bir alternatif olarak öne çıkarmaktadır. Pearson Korelasyonu yöntemi, daha az sayıda öznitelik ile yüksek performans elde edilmesini sağlamış olup, modeli genelleme açısından daha etkili bir yöntem olduğu görülmüştür.

Sonuç olarak ikinci yaklaşımda tedavi öncesi verilerde Pearson Korelasyonu yöntemi kullanılarak seçilen özneliliklerle yapılan Rastgele Orman algoritmasının analiz sonuçları doğrultusunda çiftlerin tedaviye başlama ya da başlamama kararını desteklemek amacıyla tedavi başarısını tahmin etmek üzere kullanılmıştır. Bu analiz sonucunda tedavinin başarılı olma olasılığı, %91,40 doğruluk ve %97,90 AUC değeri ile tahmin edilmiştir.

Analiz test kümesinde yer alan 535 çifte ait veriler üzerinde uygulanmış ve her bir çift için tedavi başarısı olasılıkları hesaplanmıştır. Tahmin edilen olasılık değerlerinin dağılımı, belirli aralıklar halinde Tablo 20’de sunulmuştur.

Tablo 20. Tedavinin Başarılı Olma Olasılık Dağılımı

Olasılık Aralıkları	Olasılık Sayısı (Çiftlerin Sayısı)
0%-10%	27
10%-20%	54
20%-30%	58
30%-40%	46
40%-50%	60
50%-60%	40
60%-70%	55
70%-80%	71
80%-90%	87
90%-100%	37

Olasılık dağılımları incelendiğinde, test verisindeki 535 çiftin tahmin edilen tedavi başarısı olasılıklarının %80-90 aralığında yoğunlaştığı ve bu aralıkta 87 olasılık değerinin bulunduğu gözlemlenmiştir. Buna karşılık %0-10 aralığında 27 olasılık değeri hesaplanmıştır. Tedavinin başarılı olma olasılığı düşük olan (%50 altında olan) 245 çift varken, bulunurken tedavinin başarılı olma olasılığı yüksek olan (50 ve üzeri olan) 290 çift bulunmaktadır. Olasılık dağılımının geniş bir spektruma yayılması, modelin tahminlerinin yüksek doğrulukla çeşitlilik gösterdiğini ve modelin tedavi başarısını etkin bir şekilde öngördüğünü ortaya koymaktadır.


4. BÖLÜM

TARTIŞMA-SONUÇ VE ÖNERİLER

4.1.Tartışma

Bu tez çalışması çeşitli makine öğrenmesi algoritmalarıyla IVF tedavisi alan çiftlerde klinik gebelik sonucunu en fazla etkileyen parametreleri tespit ederek, tedavi öncesi ve tedavi süreci verilerine göre tedavi başarısını tahmin etmiştir.

Çalışmanın birinci yaklaşımında, çiftlerin tedavi süreci dahil tüm verileri analiz edilerek tedavi başarısı (başarılı = 1 veya başarısız = 0) tahmin edilmiştir. Bu analizde, SMOTE uygulanmış ve dengelenmiş bir veri seti kullanılmış olup, veri seti 40 öznitelik ve 1 hedef değişken ile 5.282 veriden oluşmaktadır. Makine öğrenmesi algoritmalarının performansı farklı veri bölme yöntemleri ve öznitelik seçimi yöntemleri kullanılarak değerlendirilmiştir. Algoritmaların doğruluk bazlı performans sonuçları Şekil 21.'de sunulmuştur.



Şekil 21.1.Yaklaşım Algoritmalarının Performans Karşılaştırması


Doğruluğa dayalı performans sonuçları incelendiğinde, Rastgele Orman algoritması, tüm yöntemlerde en yüksek başarı oranlarını göstermiş ve %96.59 doğruluk oranı ile en iyi performansı sergilemiştir. Bu yüksek başarı oranı, Rastgele Orman algoritmasının veri setindeki karmaşıklığı modelleme konusundaki başarılı olduğunu yansıtmaktadır.

C45 ve CART algoritmaları da yüksek performans göstermiş olup, özellikle öznitelik seçimi yöntemlerinin etkisiyle başarı oranları artarak sırasıyla %95.27 ve %92.80 doğruluk oranlarına ulaşmıştır. Bu algoritmaların öznitelik seçimi yöntemleriyle performanslarının artırılabilceği gözlemlenmiştir.

k-NN ve ANN algoritmalarının, diğer yöntemlere kıyasla daha düşük doğruluk oranları sağladığı görülmüştür. k-NN algoritması %91,86, ANN ise %90.15 doğruluk oranlarına ulaşmıştır. Naive Bayes ve Lojistik Regresyon algoritmalarının performansı, diğer algoritmalara göre daha düşük doğruluk oranlarıyla sınırlı kalmıştır. Naive Bayes %88.26, Lojistik Regresyon ise %87.50 doğruluk oranlarına ulaşmıştır.

İkinci yaklaşımda ise, tedavi başarısı olasılığını tahmin etmek amacıyla, olasılık üretebilen ve çiftlere tedavi öncesi olasılık tahmini sağlayabilen makine öğrenmesi algoritmaları kullanılarak veriler analiz edilmiştir. Bu analizde, SMOTE uygulanmış ve dengelenmiş bir veri seti kullanılmış olup, veri seti 26 öznitelik, 1 hedef değişken ve toplam 5.352 veriden oluşmaktadır. Makine öğrenmesi algoritmalarının performansı, çeşitli veri bölme ve öznitelik seçimi yöntemleriyle değerlendirilmiştir. Algoritmaların doğruluk bazı performans sonuçları Şekil 22'de sunulmuştur.

Doğruluğa dayalı performans sonuçları incelendiğinde, Rastgele Orman algoritması, tüm yöntemlerde en yüksek başarı oranlarını göstermiştir. Özellikle, Pearson Korelasyonu öznitelik seçimi yöntemi ile %91,40 doğruluk oranı elde ederek en iyi performansı sergilemiştir. Gradyan Arttırma algoritması da yüksek bir performans göstermiş ve Pearson Korelasyonu öznitelik seçimi yöntemi ile %89,35 doğruluk oranına ulaşmıştır.



Şekil 22. 2.Yaklaşım Algoritmalarının Performans Karşılaştırması

Uyarlamalı Arttırma ve ANN algoritmaları sırasıyla Bootstrap öznelik seçimi yönteminde %78.13 ve %76.08 ve k-NN algoritması 10-katlı çapraz doğrulama yönteminde %77.76 doğruluk oranıyla algoritmalar dengeli performans seviyeleri sergilemiştir. Bu algoritmaların hiper parametre optimizasyonu ile daha yüksek başarı oranlarına ulaşılabileceği değerlendirilmektedir.

Naive Bayes, Lojistik Regresyon ve SVM algoritmalarının doğruluk oranları ise daha düşük seviyelerde kalmıştır. 10-katlı çapraz doğrulama yönteminde Naive Bayes algoritması %71.96, Lojistik Regresyon %68.60 ve SVM algoritması ise %68.04 doğruluk oranlarına ulaşabilmiştir. Bu algoritmalar öznelik seçimi yöntemlerinde performanslarını arttıramamıştır.

Sonuç olarak, Rastgele Orman ve Gradyan Arttırma algoritmalarının daha yüksek performans sergilediği görülmüştür. Bu iki algoritma, topluluk öğrenmesi (ensemble learning) yöntemlerine dayanmaktadır. Topluluk öğrenmesi yöntemlerinin temel amacı, farklı modellerin güçlü yönlerini bir araya getirerek daha yüksek doğruluk, genelleme kapasitesi ve kararlılık sağlamaktır. Bu nedenle, sağlık verileri gibi karmaşık veri setlerinde topluluk öğrenmesi algoritmalarının kullanımı, yüksek doğruluk performansı sunacağı öngörülmektedir.

4.2.Sonuç ve Öneriler

Bu tez çalışması IVF tedavisi alan çiftlerin tedavi öncesi ve tedavi süreci verilerini kullanarak çeşitli makine öğrenmesi algoritmalarıyla tedavi başarısını değerlendirmiştir. Çalışmanın birinci yaklaşımında, çiftlerin tedavi süreci dahil tüm verileri analiz edilerek tedavi başarısı (başarılı = 1 veya başarısız = 0) SMOTE uygulanmış dengeli bir veri seti kullanılarak ve 10-kat çapraz doğrulama ile Pearson korelasyonu tabanlı öznelik seçimi uygulanarak tahmin edilmiştir. Bu yaklaşımla Rastgele Orman algoritması %96.59 doğruluk oranı ile en yüksek performansı göstermiştir. İkinci yaklaşımda ise, sadece tedavi öncesi verileri kullanılarak, çeşitli olasılık sonucu verebilen makine öğrenmesi algoritmalarıyla tedavinin başarılı olma olasılığı tahmin edilmiştir. Bu bağlamda, yine SMOTE uygulanmış dengeli veri seti kullanılarak ve 10-katlı çapraz doğrulama ile Pearson korelasyonu tabanlı öznelik seçimi yöntemi uygulanarak **Rastgele Orman** algoritmasıyla %91,40 doğruluk oranı ile başarılı sonuçlar elde edilmiştir.

Literatürde, IVF tedavi başarısını tedavi öncesi ve tedavi süreci verileri kullanarak tahmin eden çeşitli çalışmalar bulunmaktadır. Örneğin, (Ramasamy et al., 2017) çalışmasında MLP makine öğrenmesi algoritması kullanarak %90,35 doğruluk oranı elde etmişken, (Hassan et al.,2018) tarafından gerçekleştirilen bir diğer çalışma SVM sınıflandırıcı ile %98,38 doğruluk oranına ulaşmıştır. Bu tez çalışması, literatürdeki benzer çalışmalarla kıyaslandığında, **Rastgele Orman** algoritması ile tedavi öncesi ve tedavi sürecindeki verilerle yapılan analizlerde %96,59 doğruluk oranı ve sadece tedavi öncesi verilerle yapılan analizlerde ise %91,40 doğruluk oranı ile yüksek performans gösteren önemli bir çalışma olarak öne çıkmaktadır.

Çalışmanın sonuçları, IVF tedavi başarısının yüksek doğruluk oranlarıyla tahmin edilebilmesi için makine öğrenmesi algoritmalarının etkin bir şekilde kullanılabileceğini ortaya koymuştur. Makine öğrenmesi tekniklerinin kullanımı, IVF tedavi süreçlerini optimize etme ve çiftlerin tedavi sonuçlarını iyileştirme potansiyeline sahip olup, bu bağlamda tedavi sürecinde belirsizliğin azaltılması yönünde katkılar sunabilmektedir. Ayrıca, bu çalışma IVF tedavisinin başarısını etkileyen önemli faktörlerin belirlenmesine yönelik katkılar sağlamakta ve IVF tedavisi görecekt çiftler için tedaviye başlama kararlarının önemini vurgulayan literatüre değerli bir katkıda bulunmaktadır.

Gelecek alıřmalarda, daha geniř veri setleri ve farklı makine ğrenmesi algoritmaları kombinasyonlarının deęerlendirilmesi ile IVF tedavisinin başarı tahmininde daha kapsamlı ve genellenebilir sonuçların elde edilmesi hedeflenmelidir. Ayrıca, algoritmaların performansını daha da artırmak amacıyla hiper parametre optimizasyonu, z nitelik mhendislięi ve model doęrulama stratejileri zerine daha derinlemesine arařtırmalar yapılması nerilmektedir.



KAYNAKÇA

1. World Health Organization, Sexual and Reproductive Health and Research, 2023. Infertility Prevalence Estimates, 1990-2021. (Web sayfası: [Kısırlık Prevalans Tahminleri, 1990–2021 \(who.int\)](https://www.who.int/news-room/fact-sheets/detail/infertility)), (Erişim tarihi: Temmuz 2024).
2. Steptoe, P.C., Edwards, R. G., 1978. Birth after the reimplantation of a human embryo. **The Lancet**, **312** (8085): 366.
3. Domar, A.D., Zuttermeister, P.C., Friedman, R., 2012. The psychological impact of infertility: a comparison with patients with chronic pain, diabetes, and hypertension. **Fertility and Sterility**, **97** (3): 503-508.
4. Rajkomar, A., Dean, J., Kohane, I., 2019. Machine learning in medicine. **New England Journal of Medicine**, **380** (14): 1347-1358.
5. Topol, E.J., 2019. Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. Basic Books, New York. 368 pp.
6. Bankowski, J.B., Vlahos, N., 2005. Johns Hopkins Jinekoloji ve Obstetrik El Kitabı. Atlas Kitapçılık, Ankara. 484 pp.
7. Crosignani, P.G., 2013. Primary and secondary infertility. **The Journal of Reproductive Medicine**, **48** (6): 435-440.
8. Njagi, P., Groot, W., Arsenijevic, J., Dyer, S., Mburu, G., Kiarie, J., 2023. Financial costs of assisted reproductive technology for patients in low- and middle-income countries: a systematic review. **Human Reproduction Open**, **2023** (2).
9. Practice Committee of the American Society for Reproductive Medicine, 2020. Testing and interpreting measures of ovarian reserve: a committee opinion. **Fertility And Sterility**, **114** (6): 1151–1157.
10. Avcı, A., 2018. Açıklanamayan İnfertilite Olgularında IVF ve ICSI Sonuçlarının Karşılaştırılması. Maltepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek lisans Tezi, İstanbul, 58 s.
11. Sharma, R., Biedenharn, K.R., Fedor, J.M., Agarwal, A., 2013. Lifestyle Factors and Reproductive Health: Taking Control of Your Fertility. **Reproductive Biology and Endocrinology**, **11** (1): 66.
12. Karacakaya, Ercan, Z., Mutlu, H., 2024. Beslenme ve infertilite: güncel yaklaşım. **Ondokuz Mayıs Üniversitesi Kadın ve Aile Araştırmaları Dergisi**, **4** (1): 1-16.

13. Yılmaz, H., 2016. İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Tüp Bebek Birimi Verilerine Göre In Vitro Fertilizasyonda Başarıyı Etkileyen Faktörler. İstanbul Üniversitesi, Uzmanlık Tezi, İstanbul, 91 s.
14. Atar, G., 2009. Tüp Bebek Başarısızlıklarında Klinik Etmenler. İstanbul Üniversitesi, Cerrahpaşa Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim Dalı, Uzmanlık Tezi, İstanbul, 87 s.
15. Seyhan, M., 2012. Erciyes Üniversitesi Tıp Fakültesi Tüp Bebek Ünitesinde Ocak 2005-Ocak 2011 Tarihleri Arasında Tedavi Gören Hastaların Klinik Gebeliği Üzerine Endometrium, Embriyo Sayısı ve Kalitesi, Embriyo Transfer Şekli Gibi Parametrelerin Etkileri. Erciyes Üniversitesi, Sağlık Bilimleri Enstitüsü, Histoloji-Embriyoloji Anabilim Dalı, Yüksek Lisans Tezi, Kayseri, 59 s.
16. Raef, B., Ferdousi, R., 2019. A review of machine learning approaches in assisted reproductive technologies. **Acta Informatica Medica**, **27** (3): 205-211.
17. Kaufmann, S.J., Eastaugh, J.L., Snowden, S., Smye, S.W., Sharma, V., 1997. The application of neural networks in predicting the outcome of in-vitro fertilization. **Human Reproduction**, **12** (7): 1454-1457.
18. Morales, D.A., Bengoetxea, E., Larranaga, P., Garcia, M., Franco, Y., Fresnada, M., Merino, M., 2008. Bayesian classification for the selection of in vitro human embryos using morphological and clinical data. **Computer Methods and Programs in Biomedicine**, **90** (2): 104-116.
19. Chen, F., Neuborg, D., Debrock, S., Peeraer, K., D'Hooghe, T., Spiessens, C., 2016. Selecting the embryo with the highest implantation potential using a data mining based prediction model. **Reproductive Biology and Endocrinology**, **14** (10).
20. Uyar, A., Ayse, B., Ciray, H.N., 2015. Predictive modeling of implantation outcome in an in vitro fertilization setting: an application of machine learning methods. **Medical Decision Making**, **35** (6):714–725.
21. Mısırlı, G., 2013. Estimating The Chance Of Success And Suggestion For Treatment In IVF. Bilkent Üniversitesi, Bilgisayar Mühendisliği, Yüksek Lisans Tezi, İstanbul, 116 s.
22. Hafız P., Nematollahi M., Boostani R., Bahia, N.J., 2017. Predicting implantation outcome of in vitro fertilization and intracytoplasmic sperm injection using data mining techniques. **Fertil Steril**, **11** (3):184–190.

23. Ramasamy, N., Durairaj, M., 2017. Feature reduction by improvised hybrid algorithm for predicting the IVF success rate. **J Adv Res Comput Sci**, **8** (1):37–40.
24. Hassan, M.R., Al-Insaf, S., Hossain M.I., Kamruzzaman, J., 2020. A machine learning approach for prediction of pregnancy outcome following IVF treatment. **Neural Computing and Applications**, **32**: 2283-2297.
25. Mitchell, T.M., 1997. Machine Learning. McGraw-Hill, New York, 414 pp.
26. Samuel, A.L., 1959. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, **3** (3): 210-229.
27. Bishop, C.M., 2006. Pattern Recognition and Machine Learning. Springer, New York, 738 pp.
28. Takcı, H., 2020. Teori ve Uygulamada Veri Madenciliği. Nobel Akademik Yayıncılık, Ankara, 250 s.
29. Cortes, C., Vapnik, V., 1995. Support-vector networks. **Machine Learning**, **20** (3): 273-297.
30. Mammone, A., Turchi, M., Cristianini, N., 2009. Support vector machines. **Wiley Interdisciplinary Reviews: Computational Statistics**, **1** (3): 283-289.
31. Shalev-Shwartz S., Singer Y., Srebro N., Cotter A., 2011. Pegasos: Primal Estimated Sub Gradient Solver For SVM. **Mathematical Programming**, **127** (1): 3–30.
32. Quinlan, J.R., 1993. C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, San Francisco, 302 pp.
33. Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J., 1984. Classification and Regression Trees. Wadsworth International Group, Belmont, 358 pp.
34. Sneha, N., Gangil, T., 2019. Analysis of diabetes mellitus for early prediction using optimal features selection. **Journal of Big Data**, **6** (1): 13.
35. Tuncer, T., Tatar, Y., 2020. Karar ağacı kullanarak saldırı tespit sistemlerinin performans değerlendirmesi. **Journal of Engineering Science and Technology**, **15** (6): 2668-2685.
36. Breiman, L., 2001. Random forests. **Machine Learning**, **45** (1): 5-32.
37. Cutler, D.R., Edwards, T.C., Beard, K.H., Cutler, A., Hess, K.T., Gibson, J., Lawler, J. J., 2007. Random forests for classification in ecology. **Ecology**, **88** (11): 2783-2792.
38. Kibria, H.B., Matin, A., 2023. The severity prediction of the binary and multi-class cardiovascular disease -- a machine learning-based fusion approach. **arXiv**.

39. Cover, T.M., Hart, P.E., 1967. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, **13** (1): 21-27.
40. Gower, J.C., 1971. A general coefficient of similarity and some of its properties. **Biometrics**, **27** (4): 857-871.
41. Çavuşoğlu, Ü., Kaçar, S., 2019. Anormal trafik tespiti için veri madenciliği algoritmalarının performans analizi. **Academic Platform Journal of Engineering and Science**, **7** (2): 205-216.
42. Kliemann, L., Sanders, P., 2016. Algorithm Engineering: Selected Results And Surveys. Springer International Publishing, Cham, Switzerland, 291 pp.
43. Bayes, T., 1763. An essay towards solving a problem in the doctrine of chances. **Philosophical Transactions of the Royal Society**, **53**: 370-418.
44. Domingos, P., 1999. A unified bias-variance decomposition for zero-one loss. **Machine Learning**, **36** (1): 55-77.
45. Hosmer, D.W., Lemeshow, S., Sturdivant, R.X., 2013. Applied Logistic Regression. Wiley, Hoboken, New Jersey, 528 pp.
46. Azizoglu, F., 2023. Makine Öğrenmesi Yöntemleriyle Kalp Hastalarının Sağlık Tahmini. Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sivas, 72 s.
47. Freund, Y., Schapire, R.E., 1995. A decision-theoretic generalization of on-line learning and an application to boosting. **Journal of Computer and System Sciences**, **55** (1): 119-139.
48. Püsküllü, İ., 2024. Boosting algoritmalarının temelleri: gradient boosting ve adaptive boosting nedir. (Web sayfası: [Boosting Algoritmalarının Temelleri: Gradient Boosting ve Adaptive Boosting Nedir? | by İbrahim Püsküllü | Medium](#)). (Erişim Tarihi: Temmuz 2024).
49. Bilban, S., Aydoğan, H., 2022. Using machine learning methods to predict the effect of alternative fuel mixtures on exhaust emissions. **Avrupa Bilim ve Teknoloji Dergisi**, **34**: 273-279.
50. Friedman, J.H., 2001. Greedy function approximation: a gradient boosting machine. **The Annals of Statistics**, **29** (5): 1189-1232.
51. Zhang, T., Lin, W., Vogelmann, A.M., Zhang, M., Xie, S., Qin, Y., Golaz, J.C., 2021. Improving convection trigger functions in deep convective parameterization

- schemes using machine learning. **Journal of Advances in Modeling Earth Systems**, **13**.
52. McCulloch, W.S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, **5**: 115-133.
53. Rosenblatt, F., 1958. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, **65** (6): 386-408.
54. Hinton, G.E., Osindero, S., Teh, Y.W., 2006. A fast learning algorithm for deep belief nets. **Neural Computation**, **18** (7): 1527-1554.
55. Öztürk, K., Şahin, Ergin, M., 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. **Takvim-i Vekayi**, **6** (2): 25-36.
56. Tukey, J.W., 1977. Exploratory Data Analysis. Addison-Wesley, 668 pp.
57. Little, R.J.A., Rubin, D.B., 2002. Statistical Analysis with Missing Data, Wiley. 408 pp.
58. Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., Altman, R.B., 2001. Missing value estimation methods for dna microarrays. **Bioinformatics**, **17** (6): 520-525.
59. Jain, A.K., Duin, R.P.W., Mao, J., 2000. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **22** (1): 4-37.
60. James, G., Witten, D., Hastie, T., Tibshirani, R., 2013. An Introduction to Statistical Learning: with Applications in R. Springer, New York, 439 pp.
61. Chawla, N.V., Bowyer, K.W., Hall, L.O., Kegelmeyer, W.P., 2002. SMOTE: synthetic minority over-sampling technique. **Journal of Artificial Intelligence Research**, **16**: 321-357.
62. Davison, A.C., Hinkley, D.V., 1997. Bootstrap Methods and Their Applications. Cambridge University Press, Cambridge, UK, 322 pp.
63. Guyon, I., Weston, J., Barnhill, S., Schölkopf, B., 2002. Gene selection for cancer classification using support vector machines. **Machine Learning**, **46** (1-3): 389-422.
64. Pearson, K., 1895. Notes on regression and inheritance in the case of two parents. **Proceedings of the Royal Society of London**, **58**: 240-242.

65. Powers, D.M.W., 2011. Evaluation: from precision, recall and f-measure to roc, informedness, markedness & correlation. **Journal of Machine Learning Technologies**, 2 (1): 37-63.
66. Tomak, L., Bek, Y., 2010. İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. **Journal of Experimental and Clinical Medicine**, 27: 58-65.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Rabia Pemik

Uyruğu:

Doğum Tarihi ve Yeri:

Medeni Durum:

e-mail:

Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Erciyes Üniversitesi, Endüstri Mühendisliği	2019
Lise	Balçova Anadolu Lisesi, İzmir	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2021-Halen	Kayseri Sanayi Odası	Endüstri Mühendisi
2019-2021	Kemerli Metal San. Ve Tic. A.Ş.	Üretim Planlama Sorumlusu

YABANCI DİL

İngilizce

YAYINLAR

-