



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**YAPAY ZEKÂ YAKLAŞIMI İLE
KÜMÜLATİF KONSEPSİYON TAHMİN
MODELİ GELİŞTİRİLMESİ**

Tuğba KURT

DOKTORA TEZİ

Doç. Dr. Burçin KURT

TRABZON-2024

BEYAN

Bu tez çalışmasının Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü tez yazım kılavuzu standartlarına uygun olarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterildiğini ve kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

01/07/2024

Tuğba KURT

İthaf

*Rasyonel dünyaya beni şefkatle iten anneme ve sezgisel zihnini analitik ile birleştirmeyi
başarabilenlere...*



TEŞEKKÜR

Doktora eğitimim süresince ve tez çalışmamın yürütülmesinde teknik anlamda çok şey öğrendiğim, her daim manevi destek gördüğüm ve tüm samimiyetiyle yanımda bulunan değerli danışman hocam Doç. Dr. Burçin KURT'a, lisansüstü eğitim hayatına girmeme vesile olan değerli hocam Prof. Dr. Kemal TURHAN'a ve verdiği kıymetli destek ve katkılarından dolayı Dr. Öğr. Üyesi Uğur ŞEVİK'e minnetle teşekkürlerimi sunarım.

Çalışma süresince bana yol gösteren mentörüm Doç. Dr. Beril GÜRLEK'e, hem fikir hem de bilgi paylaşımı anlamında yardımlarını sağlayan Öğr. Gör. Dr. İlknur Buçan KIRKBİR'e, biyoistatistik alanındaki yeteneğini takdir ettiğim ve ihtiyacım olduğu her an bilgi ve deneyimini benimle paylaşan Prof. Dr. Ali GÜNER'e çok teşekkür ederim.

İnişli çıkışlı olan bu yolculukta desteğini hep hissettiren ofis arkadaşım Zeliha BAYRAKTAR'a, anabilim dalındaki arkadaşlarım Arş. Gör. Dr. Zeliha Aydın KASAP'a ve Neslihan BAKİ'ye ve son olarak doktora eğitimim dahil, diğer disiplinlerdeki öğrenme çabalarım için bana özgür alan açan ve motivasyon sağlayan sevgili eşim O.Ömür KURT'a içtenlikle teşekkür ederim.

Tuğba KURT

İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

ONAY

BEYAN

İthaf

TEŞEKKÜR

İÇİNDEKİLER

vi

TABLolar DİZİNİ

ix

ŞEKİLLER DİZİNİ

x

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

xi

ÖZET

xii

ABSTRACT

xiii

1. GİRİŞ ve AMAÇ

1

2. GENEL BİLGİLER

3

2.1. Doğal Konsepsiyon

3

2.1.1. Toplam Doğurganlık (Total Fertility) Hızı

3

2.2. Fertilite, Fekundite ve Fekundabilite Kavramları

5

2.3. Subfertilite ve İnfertilite Kavramları

5

2.4. Fertilite/İnfertiliteyi Etkileyen Faktörler

6

2.5. Gebelik ve Makine Öğrenmesine İlişkin Literatür Çalışmaları

7

3. GEREÇ ve YÖNTEM

10

3.1. Veri Seti

11

3.2. Değişkenler

11

3.3. Veri Ön işleme

11

3.3.1. Çoklu Bağıntılılık (Multicollinearity)

11

3.3.2. Değişken Eleme

12

3.4. İstatistiksel Analiz

15

3.5. Öznitelik Seçimi (Feature Selection)

15

3.6. Modellerin Geliştirilmesine İlişkin Yaklaşımlar

17

3.6.1. Senaryo 1 (Tüm Değişkenler)

17

3.6.2. Senaryo 2 (15 Değişken)

18

3.6.3. Senaryo 3 (9 Değişken)

19

3.7. Modellerin Geliştirilmesi	20
3.7.1. Yapay Zekâ ve Makine Öğrenmesi	20
3.7.2. Makine Öğrenmesi Yaklaşımları	20
3.7.3. Makine Öğrenmesinin Uygulanma Aşamaları	23
3.7.4. Sınıflama Algoritmaları	24
3.7.4.1. Naive Bayes	24
3.7.4.2. Destek Vektör Makineleri - DVM (Support Vector Machines - SVM)	25
3.7.4.3. Rastgele Orman (Random Forest)	26
3.7.4.4. XGBoost (eXtreme Gradient Boosting)	27
3.7.4.5. CatBoost (Category Boosting)	28
3.7.5. Model Eniyileme: Hiper Parametre Optimizasyonu	29
3.7.6. Makine Öğrenmesi Performans Değerlendirme Metrikleri	29
4. BULGULAR	32
4.1. İstatistiksel Analiz Bulguları	32
4.2. Öznitelik Seçimi Bulguları	37
4.2.1. Boruta Algoritması ile Belirlenen Önemli Değişkenler	37
4.2.2. Rastgele Orman Algoritması ile Belirlenen Önemli Değişkenler	39
4.2.3. LASSO Regresyon Algoritması ile Belirlenen Önemli Değişkenler	40
4.2.4. Tekrarlayan Öznitelik Elemesi (RFE) ile Belirlenen Önemli Değişkenler	42
4.2.5. Lojistik Regresyon Algoritması ile Belirlenen Önemli Değişkenler	43
4.3. Makine Öğrenmesi Modellerine Ait Bulgular	45
4.4. Hiper Parametre Optimizasyon Bulguları	47
4.5. Geliştirilen Modellerin Tahmin Performanslarının Karşılaştırılması	54
4.6. Geliştirilen En Başarılı Tahmin Modeline İlişkin Olasılıksal Yaklaşım	56
5. TARTIŞMA ve SONUÇ	62
6. KAYNAKLAR	70
EKLER	79
Ek 1. Etik Kurum İzni	80
Ek 2. Konsepsiyon Tahmini Değişken Formu	81
Ek 3. Google Formları Üzerinden Hazırlanan Soru Formu Linki	83
Ek 4. Bilgilendirilmiş Onam Formu	84
Ek 5. Hiper Parametre Optimizasyonu Sonrası Senaryo 1 Kapsamında Geliştirilen Tahmin Modellerine Ait Performans Metriklerinin Karşılaştırılması	85

Ek 6. Hiper Parametre Optimizasyonu Sonrası Senaryo 1 Kapsamında Geliştirilen Tahmin Modellerine Ait ROC Eğrilerinin Karşılaştırılması	86
Ek 7. Hiper Parametre Optimizasyonu Sonrası Senaryo 3 Kapsamında Geliştirilen Tahmin Modellerine Ait Performans Metriklerinin Karşılaştırılması	87
Ek 8. Hiper Parametre Optimizasyonu Sonrası Senaryo 3 Kapsamında Geliştirilen Tahmin Modellerine Ait ROC Eğrilerinin Karşılaştırılması	88
ÖZGEÇMİŞ	89



TABLÖLAR DİZİNİ

Tablo No	Sayfa
Tablo 1. Veri setinden çıkarılan 19 değişken	13
Tablo 2. Veri setinde kalan 32 değişken	14
Tablo 3. Senaryo 1’de kullanılan değişkenler	18
Tablo 4. Senaryo 2’de kullanılan değişkenler	19
Tablo 5. Senaryo 3’te kullanılan değişkenler	20
Tablo 6. Karışıklık matrisi (Confusion matrix)	29
Tablo 7. Sayısal değişkenlere ait tanımlayıcı istatistikler	32
Tablo 8. Kategorik değişkenlere ait tanımlayıcı istatistikler	34
Tablo 9. Gini değerine göre belirlenen önemli değişkenler	40
Tablo 10. Lojistik regresyon analizi ile belirlenen önemli faktörler	43
Tablo 11. Öznitelik seçim yöntemlerine göre anlamlı bulunan değişkenler	44
Tablo 12. Senaryo 1’e göre geliştirilen tahmin modellerinin performans sonuçları	45
Tablo 13. Senaryo 2’ye göre geliştirilen tahmin modellerinin performans sonuçları	46
Tablo 14. Senaryo 3’e göre geliştirilen tahmin modellerinin performans sonuçları	46
Tablo 15. XGBoost algoritmasının senaryolara göre performans karşılaştırması	47
Tablo 16. RF algoritması için optimizasyon için arama uzayında kullanılan hiper parametre değer kümeleri	48
Tablo 17. XGBoost algoritması için optimizasyon için arama uzayında kullanılan hiper parametre değer kümeleri	48
Tablo 18. CatBoost algoritması için optimizasyon için arama uzayında kullanılan hiper parametre değer kümeleri	48
Tablo 19. DVM algoritması için optimizasyon için arama uzayında kullanılan hiper parametre değer kümeleri	48
Tablo 20. RF algoritması için elde edilen optimum hiper parametre değerleri	49
Tablo 21. XGBoost algoritması için elde edilen optimum hiper parametre değerleri	49
Tablo 22. CatBoost algoritması için elde edilen optimum hiper parametre değerleri	49
Tablo 23. DVM algoritması için elde edilen optimum hiper parametre değerleri	49
Tablo 24. Senaryo 1, 2 ve 3’e göre oluşturulan tahmin modellerinin hiper parametre optimizasyonu sonrasındaki performanslarının karşılaştırılması	51

ŞEKİLLER DİZİNİ

Şekil No	Sayfa
Şekil 1. Dünya genelinde toplam doğurganlık hızı	4
Şekil 2. Türkiye’de doğum sayısı ve toplam doğurganlık hızı	4
Şekil 3. Yapılan tez çalışmasına ilişkin akış şeması	10
Şekil 4. Denetimli makine öğrenmesi süreci	21
Şekil 5. Topluluk öğrenmesine yönelik genel yapı	23
Şekil 6. Destek vektör makinesinin yapısı	26
Şekil 7. Rastgele orman algoritması	27
Şekil 8. XGBoost algoritması	28
Şekil 9. ROC Eğrisi	31
Şekil 10. İstatistiksel açıdan anlamlı olan sayısal değişkenlere ait boxplot grafikleri	33
Şekil 11. İstatistiksel açıdan anlamlı olan kategorik değişkenlere ait grafikler	37
Şekil 12. Boruta algoritması ile belirlenen önemli değişkenler	39
Şekil 13. Rastgele orman algoritması ile belirlenen önemli değişkenler	40
Şekil 14. LASSO regresyon algoritması ile belirlenen önemli değişkenler	41
Şekil 15. RFE algoritması ile belirlenen önemli değişkenler	43
Şekil 16. Hiper parametre optimizasyonu sonrası Senaryo 2 kapsamında geliştirilen tahmin modellerine ait ROC eğrilerinin karşılaştırılması	54
Şekil 17. Hiper parametre optimizasyonu sonrası Senaryo 2 kapsamında geliştirilen tahmin modellerine ait performans metriklerinin karşılaştırılması	55
Şekil 18. Geliştirilen en başarılı modelin “gebe kalamadı” sınıfına ait katılımcılara ilişkin tahmin sonuçları ve olasılık değerleri	57
Şekil 19. Geliştirilen en başarılı modelin “gebe kaldı” sınıfına ait katılımcılara ilişkin tahmin sonuçları ve olasılık değerleri	58
Şekil 20. Gebe kalma olasılık değerlerinin “düşük”, “orta” ve “yüksek” sınıflarına dönüştürülmesine ilişkin algoritma akış diyagramı	59
Şekil 21. Geliştirilen en başarılı modelin “gebe kalamadı” sınıfına ait katılımcılara ilişkin gebe kalma olasılığı tahmin sonuçları	60
Şekil 22. Geliştirilen en başarılı modelin “gebe kaldı” sınıfına ait katılımcılara ilişkin gebe kalma olasılığı tahmin sonuçları	60
Şekil 23. Düşük, orta ve yüksek grup sınıflandırmalarına dair gebelik durumunun değerlendirilmesi	61

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

Kısaltmalar

AUC	Eğri altındaki alan
ANNs	Yapay sinir ağları
CART	Sınıflama ve regresyon ağaçları
CV	Çapraz doğrulama
DN	Doğru negatif
DP	Doğru pozitif
DT	Karar ağacı
DVM	Destek vektör makineleri
GA	Güven aralığı
GBDT	Gradyan artırma karar ağacı
IVF	In vitro fertilizasyon
KNN	K-en yakın komşular
KTÜ	Karadeniz Teknik Üniversitesi
LASSO	En küçük mutlak küçülme ve seçim operatörü
LR	Lojistik regresyon
ML	Makine öğrenmesi
OR	Odds oranı
PCOS	Polikistik over sendromu
RF	Rastgele orman
RFE	Tekrarlayan öz nitelik elemesi
TDO	Toplam doğurganlık oranı
VKİ	Vücut kitle indeksi
YN	Yanlış negatif
YP	Yanlış pozitif

Simgeler

χ^2	Ki-kare
β	Beta

ÖZET

Yapay Zekâ Yaklaşımı ile Kümülatif Konsepsiyon Tahmin Modeli Geliştirilmesi

Kümülatif konsepsiyon, bir kadının belirli bir zaman dilimi içinde gebe kalma olasılığını ifade eder. Bu olasılık, sosyal, kültürel, ekonomik, çevresel, davranışsal, biyolojik, psikolojik ve genetik etmenler başta olmak üzere birçok faktöre bağlı olarak değişir. Kümülatif konsepsiyon, kadınların doğurganlık planlaması yaparken veya infertilite tedavisi görmeye karar verirken dikkate alabilecekleri önemli bir göstergedir. Hangi çiftin infertilite (kısırlık) veya subfertilite için riskli grupta olduğunu bilmek, gebelik öncesi (prekonsepsiyonel) değerlendirmeye ihtiyacı olup olmadığına karar vermek açısından oldukça önemlidir. Bu nedenle gebelik elde etme ihtimalini araştıran ve bu yöntemle spontan gebelik şansı az olan ve infertilite için risk faktörü taşıyan kadınların erken tanınmasını sağlayacak non-invaziv (girişimsel olmayan), ucuz ve etkili tahmin modellerinin geliştirilmesi önem arz etmektedir. Bu amaçla yapılan prospektif tez çalışmasında, uzman doktor tarafından belirlenen sorularla oluşturulan bir kayıt formu 300 katılımcı tarafından doldurulmuş ve maksimum 12 ay olmak üzere 2 ayda bir gebelik takibi yapılmıştır. Elde edilen veriler ile beş farklı öznelite seçimi yöntemi kullanılarak risk/şans faktörü olan değişkenler belirlenmiş ve bu değişkenler üzerinden makine öğrenmesi yöntemleri kullanılarak beş farklı tahmin modeli geliştirilmiştir. Bu tahmin modelleri arasında en başarılı model CatBoost algoritması ile elde edilmiştir (Doğruluk:0.83, Duyarlılık:0.90, Özgüllük:0.76 ve ROC-AUC:0.83). CatBoost algoritmasına göre elde edilen tahmin sonuçları olasılık değerlerine dönüştürülerek model çıktısında her bir sınıf (gebe kaldı/kalamadı) için olasılık değerleri elde edilmiştir. Elde edilen olasılık değerleri, uzman hekim tarafından belirlenen kesim noktaları üzerinden “düşük”, “orta” ve “yüksek” olmak üzere üç sınıfa ayrılmıştır. Böylece, henüz gebelik öncesi aşamadayken, sadece kayıt formu bilgileri kullanılarak gebe kalma olasılığı “düşük”, “orta” ve “yüksek” şeklinde verebilen, hekime yardımcı olabilecek başarılı bir karar destek modeli geliştirilmiştir. Geliştirilen bu karar destek sistemi ile uzman hekim, gebe adayına ilişkin bilgileri sisteme girdiğinde, gebelik olasılığına ilişkin önsel bir tahmin sonucu elde edebilecek ve bununla birlikte muayene bilgilerini de kullanarak gebelik tedavi sürecini planlayabilecektir.

Anahtar Kelimeler: Fertilite, İnfertilite, Klinik Karar Destek Sistemi, Makine öğrenmesi, Prospektif çalışmalar

ABSTRACT

Developing a Model for Prediction of Cumulative Conception with Artificial Intelligence Approach

Cumulative conception refers to a woman's probability of becoming pregnant within a specific timeframe, influenced by various factors including social, cultural, economic, environmental, behavioral, biological, psychological, and genetic factors. It serves as an important indicator for women to consider when planning fertility or deciding on infertility treatment. Knowing which couples are at risk for infertility or subfertility is crucial in determining the need for preconceptional evaluation. Therefore, the development of non-invasive, affordable, and effective prediction models to explore the likelihood of achieving pregnancy is imperative. In a prospective thesis study conducted for this purpose, a registration form consisting of questions determined by a specialist physician was completed by 300 participants, and pregnancy follow-up was conducted every two months for up to a maximum of 12 months. Data obtained were used to identify variables with risk/chance factors through five different feature selection methods, and five different prediction models were developed using machine learning methods based on these variables. Among these models, the most successful one was achieved with the CatBoost algorithm (Accuracy:0.83, Sensitivity:0.90, Specificity:0.76 and ROC-AUC:0.83). Prediction results obtained according to the CatBoost algorithm were transformed into probability values, providing probability values for each class (pregnant/not pregnant) in the model output. These probability values were then divided into three classes “low,” “medium,” and “high” based on cutoff points determined by the specialist physician. A successful decision support model has been developed to assist physicians in providing an initial estimation of pregnancy likelihood as “low,” “medium,” or “high” solely based on registration form data during the preconception stage. With this developed decision support system, when a specialist physician enters candidate information into the system, they can obtain a preliminary prediction regarding the probability of pregnancy, along with using examination information to plan the pregnancy treatment process.

Keywords: Clinical Decision Support System, Fertility, Infertility, Machine Learning, Prospective studies

1. GİRİŞ ve AMAÇ

Son birkaç dekatta batı toplumlarındaki çiftler, gebe kalmayı kademeli olarak ileri yaşlara kadar ertelemektedir. Gebelik isteğindeki bu gecikmenin altında etkili doğum kontrol yöntemine erişimin artması, kadının eğitimsel başarısının artması, işgücüne kadın katılımının artması, ideal çocuk sayısı ile ilişkili kültürel değişim, cinsiyet eşitliğinde iyileşme, ekonomik belirsizlik ve aile dostu işyeri politikalarının yokluğu gibi faktörler bulunmaktadır (1). İleri yaşlarda gebe kalmaya çalışan çiftlerin sayısındaki artış göz önüne alındığında, genel popülasyonda doğurganlığın gebelik öncesi (prekonsepsiyonel) dönemde ayrıntılı karakterizasyonun büyük klinik faydaya sahip olacağı aşikârdır. Hangi çiftin infertilite/subfertilite için riskli grupta olduğunu bilmek, gebelik öncesi değerlendirmeye ihtiyacı olup olmadığına karar vermek açısından oldukça önemlidir (2).

Bununla birlikte kadınların birçoğu infertilite (kısırlık) risk faktörlerini farkında olmadıklarından gebelik öncesi (prekonsepsiyonel) dönemde hekime başvurmazlar. Bu da özellikle fertilitayı (doğurganlık) etkileyen risk faktörlerine sahip olan çiftlerin tanı ve tedavisinde gecikmeye neden olur. Her çiftin tedavisiz gebe kalma şansı olduğundan, gebelik planlayan çiftlerin doğal yollardan gebe kalma ihtimalini önceden bilmesi, klinik değerlendirmeye tedavi ihtiyacı oluşturabilecek bir patoloji olup olmadığının öğrenilmesini ve tedaviye erkenden başlanmasını sağlar (3, 4).

Son yıllarda tıp alanında makine öğrenmesi yöntemlerinin kullanımı, otomatik klinik karar sistemleri oluşturma ve hastalıkları erken teşhis etme açısından oldukça önem arz etmektedir. Literatürde mevcut risk faktörlerinin tek başına, fertilitate (doğurganlık) ve infertilite (kısırlık) üzerine olan etkilerini araştıran birçok çalışma mevcut iken (5-7), henüz gebelik öncesi aşamadayken biyokimyasal belirteçler kullanmaksızın birden fazla risk faktörünün kümülatif konsepsiyon ihtimali (her adet döngüsünde gebe kalma ihtimali) üzerindeki etkisini makine öğrenmesi yaklaşımı ile araştıran çalışma sayısı oldukça kısıtlıdır.

Bu tez çalışmasında, kümülatif konsepsiyon olasılığının tahmininde kullanılabilecek basit, hızlı, düşük maliyetli ve kolay ulaşılabilir bir tahmin modeli geliştirilmesi planlanmıştır. Bu yolla, fertilitate (doğurganlık) açısından risk ve şans faktörleri olan çiftlerin erken tanınmasını sağlamak adına, gebelik planlayan bir kadının henüz gebelik öncesi (prekonsepsiyonel) aşamadayken makine öğrenmesi yöntemleri aracılığıyla gebe kalma olasılığını, “düşük”, “orta” ve “yüksek” olmak üzere başarılı bir

şekilde sınıflandırabilecek non-invaziv (girişimsel olmayan), ucuz ve etkili bir tahmin modeli geliştirmek amaçlanmıştır. Ayrıca bu çalışma, spontan gebelik olasılığı düşük olan ve infertilite (kısırlık) için risk faktörü taşıyan çiftlerin erken tanınması ile gebelik sürecinin buna göre planlamasında hekimlere yardımcı olabilir. Bununla birlikte, orta düzeyde gebelik olasılığı olan kadınların, psikolojik açıdan kısırlık şüphesiyle keskin bir sınıra sokulmaması, gebelik olasılığı yüksek olan kadınlara ise gereksiz tedavi maliyetinden kaçınması, gebelik elde etme konusunda kaygı hissetmemesi ve uzman hekim kararı ile gebelik elde etme sürecine ilişkin biraz daha bekleme tavsiyesi verilmesi önerilebilir. Ayrıca uzman hekim tarafından, düşük gebelik ihtimali olan ve infertil olması muhtemel olan olguların erken dönemde tespit edilmesi ve erken tedaviye başlanabilmesi adına gebe kalma süreci planlanabilir.

2. GENEL BİLGİLER

2.1. Doğal Konsepsiyon

Doğal konsepsiyon, bir çiftin hamilelik elde etme sürecini ilaç veya yardımcı üreme teknolojileri kullanmadan doğal yollarla gerçekleştirmesi anlamına gelmektedir. Gebelik, genellikle denenen ilk ay içinde yaklaşık %30 ihtimalle oluşur. Gebe kalma olasılığı zamanla azalır ve bir yılın sonunda %5'e düşer. Kümülatif gebelik oranları, altı ay sonra %75, bir yıl sonra %90 ve iki yıl sonra %95'tir. Genellikle gebelik elde edilememenin nedenleri bir yıl kadar sonra araştırılır fakat, bazı çiftler için araştırmaya daha erken başlamak uygun olabilir.

Kendiliğinden gebe kalma olasılığı; yaş, önceki gebelik, deneme süresi, doğal döngü sırasındaki cinsel ilişki zamanlaması, vücut kitle indeksi ve organik veya hormonal patolojilerden etkilenir. Bu faktörlerin başında, azalan over (yumurtalık) rezervi ile ilişkisi nedeni ve ileri yaş gelir. 35-39 yaş arası kadınlar için kendiliğinden gebe kalma şansı, 19-26 yaşları arasındaki kadınların yarısı kadardır (9, 10).


2.1.1. Toplam Doğurganlık (Total Fertility) Hızı

Toplam doğurganlık oranı, bir kadının doğurganlık çağı boyunca (genellikle 15-49 yaş arası) ortalama olarak doğurduğu çocuk sayısını ifade eder. Bu oranla, çiftlerin düzenli cinsel ilişkiye girmesi neticesinde gebelik elde etme olasılığı üzerinden doğurganlık potansiyelleri değerlendirilir (11).


Doğurganlık oranı terimi, sıklıkla toplam doğurganlık hızı (TDH) ile birbirinin yerine kullanılmaktadır. Bir yıldaki doğum sayısının, 15-44 yaş arası kadın sayısına bölünmesi ve bin ile çarpılmasıyla elde edilen rakam, toplam doğurganlık oranını verir. Toplam doğurganlık hızı ise ölüm olmadığı varsayılarak, belirli bir yılda gözlemlenen yaşa özel doğurganlık hızlarına tabi olması durumunda, bir kadının 50 yaşına gelene kadar sahip olacağı ortalama canlı doğum sayısını ifade eder (12). Temel olarak, ikisi de aynı doğurganlık ölçüsünü belirtirler.

Şekil 1'de, Worldbank'tan elde edilerek düzenlenen verilere göre 1999-2021 yılları arasında dünya genelindeki toplam doğurganlık hızı görülmektedir. Burada, dünyadaki toplam doğurganlık hızının genel seyri sunulmuştur. 2000 yılında dünya genelinde toplam doğurganlık hızı 2.7 seviyesindeyken, 2020 yılına gelindiğinde bu hızın 2.3'ler seviyesine kadar düştüğü görülmektedir. Şekil 2'de ise, TÜİK'ten elde edilen verilere göre 2001-2022

yılları arasında Türkiye’deki toplam doğurganlık hızı görülmektedir. Buna göre ülkemizde 2001’de 2.38 olan toplam doğurganlık hızı, 2022’de 1.62’ye düşmüştür. Yani, bir kadının doğurganlık çağı boyunca ortalama olarak doğurabileceği çocuk sayısı 2022’de 1.62 olarak gerçekleşmiştir. Bu da doğurganlığın, nüfusun yenilenme düzeyi olarak kabul edilen 2.10’un altında kaldığını göstermektedir.



Şekil 1. Dünya genelinde toplam doğurganlık hızı (Worldbank’tan, 13)



Şekil 2. Türkiye’de doğum sayısı ve toplam doğurganlık hızı (TÜİK’ten, 14)

2.2. Fertilite, Fekundite ve Fekundabilite Kavramları

Fertilite (doğurganlık), bir çiftin doğal yollardan çocuk sahibi olma kapasitesini ifade eder. Çiftler, genellikle bir yıl içinde düzenli cinsel ilişkiye rağmen gebelik elde edilememesi durumunda, klinik olarak değerlendirilirler (15). Fekundite, canlı bir doğum yapma kapasitesini ifade ederken, fekundabilite ise bir adet döngüsü (menstrüel siklus) boyunca cinsel ilişki sırasında gebe kalma olasılığını ifade etmek için kullanılır (16).

Normal adet döngüsü, hipotalamus, hipofiz ve gonadal organlar arasında otokrin ve parakrin mekanizmaları tarafından kontrol edilir. Menstrüel döngünün ilk günü, adet kanamasının başladığı gün olarak kabul edilir ve sonrasında ilk 14-21 gün foliküler faz, ikinci 14 gün ise luteal faz olarak adlandırılır. Bu döngü genellikle 28-35 gün arasında sürer. Bu fazlar arasındaki hormonal değişimler ve foliküler büyüme, ovulasyon ve endometrial döngü boyunca yaşanan değişiklikler döngünün normal seyrini belirlerler (17).

2.3. Subfertilite ve İnfertilite Kavramları

Subfertilite, çocuk sahibi olma yeteneğinin normale oranla az olması olarak tanımlanır. Her altı çiftten biri gebe kalma sürecinde istenmeyen bir gecikme yaşar. Bu çiftlerin kabaca yarısı ya kendiliğinden ya da nispeten basit bir tavsiye veya tedavi ile gebelik elde ederler. Diğer yarısı subfertil (hafif derecede kısırlık bulgularının olması) kaldığı için, in vitro fertilizasyon (tüp bebek) ve diğer yardımcı üreme teknikleri gibi daha karmaşık tedavi yöntemlerine ihtiyaç duyarlar. Fertilite (doğurganlık) sorunu olduğunu düşünen çiftlerin çoğunda, aslında gebe kalamamaya neden olacak ciddi bir sebep bulunmamaktadır. Subfertiliteye sahip çiftlerin çoğu ya spontan ya da tedavi sonrası gebe kalır ancak, %4'ü istemsiz olarak çocuk sahibi olamaz (9).

İnfertilite ise, tamamen başarısız bir doğurganlık durumunu ifade eder. Bir çiftin belirli bir süre boyunca (genellikle bir yıl) düzenli cinsel ilişkiye rağmen gebe kalamaması durumunu tanımlar. İnfertil (kısır) çiftlerde, gebe kalma (konsepsiyon) ihtimalini azaltan ve çiftlerin birini ya da ikisini etkileyen bir veya daha fazla faktör bulunmaktadır (11).

Güncel yayınlar, erkek fertilitésinin de yaşla birlikte azaldığını göstermektedir. Yaş ile artan sperm ve ositteki (döllenenmemiş yumurta hücresi) genetik kusurların, gamet fonksiyonunun bozulmasına ve sağlıklı embriyonik gelişime neden olabileceği düşünülmektedir (10, 18).

Bir diğ er  nemli fakt r ise subfertilite s residir. Bu s re    yıldan azsa, bir  iftin gebe kalma olasılıđı, daha uzun s redir  ocuk sahibi olmaya  alıřan  iftlere g re 1.7 kat daha fazladır.    yıldan daha uzun s ren, a ıklanamayan subfertilitesi olan  iftlerde, gebe kalma řansı her d ng de yaklaşık %1-3't r. Daha  nce gebeliđi olan  iftlerde de bu řans, gebeliđi olmayanlara g re 1.8 kat y ksektir (9). Ayrıca ovulasyonu (yumurtanın atılması)  n g r lebilen d zenli menstrual (adet g rme) paterne sahip  iftlerde, cinsel iliřkinin zamanlamasına dikkat edilirse gebelik elde etme řansı artmaktadır. Bununla birlikte menstrual siklusu (adet g rme d nemleri) d zensiz olan kadınlarda folik ler faz s resi  n g r lemediđinden ovulasyon (yumurtanın atılması) zamanı belirsizdir ve bu  iftlerde de gebelik elde etmede gecikme yařanabilir (19).

2.4. Fertilite/ nfertiliteyi Etkileyen Fakt rler

Sosyal, k lt rel, ekonomik,  evresel, davranıřsal, biyolojik, psikolojik ve genetik etmenler bařta olmak  zere fertiliteyi ve infertiliteyi direkt veya indirekt olarak etkileyen bir ok fakt r bulunmaktadır (20). Bařlıcaları, ařađıda maddeler halinde  zetlenmiřtir.

Demografik, Sosyoekonomik ve K lt rel Fakt rler

- Yař, eđitim d zeyi, gelir d zeyi, yařam yeri, evlilik yařı (21-23)  evresel Fakt rler
-  evresel kirleticiler ve kimyasallar (24, 25) Psikolojik Fakt rler
- Stres (26)
- Psikotik Bozukluklar (27)

Davranıřsal ve Yařam tarzı ile İlgili Fakt rler

- Sigara, alkol ve uyuřturucu kullanımı (19)
- Obezite (28)
- Uyku kalitesi (29)
- Fiziksel aktivite (30)
- Oturma s resi (30)
- Ayakta kalma s resi (31)
- Beslenme (32)
- Cinsel iliřki sıklıđı (33)
- Korunma y ntemi (34, 35)
- Dođum y ntemi (36, 37)

- Yumurtlama günü (38, 39) Genetik Faktörler
- Epigenetik (40)
- Genetik bozukluklar (41)

Ek Hastalıklar

- Sistemik hastalıklar: Diyabet, çölyak, açıklanamayan kısırlık, tekrarlayan düşük, D vitamini eksikliği, tiroid, erkekte sperm sayısı ve hareketliliği, sperm morfolojisi, hipertansiyon, kronik böbrek yetmezliği
- Cinsel yolla bulaşan enfeksiyonlar, hipertansiyon, miyom, genital enfeksiyon, polikistik over sendromu (PCOS), çikolata kisti (endometriozis kisti) (42)

Tıbbi Müdahaleler ve İlaçlar

- Radyoterapi ve kemoterapi (43, 44)
- Kullanılan bazı ilaçlar (45)

Diğer Biyolojik ve Fizyolojik Faktörler

- Ovülasyon düzeni (16, 46)
- Rahim ve rahim ağzı sağlığı (47, 48)
- Hormonal dengesizlikler (49)
- Anatomik sorunlar (50)
- Regl siklus (Adet döngüsü) (51)

2.5. Gebelik ve Makine Öğrenmesine İlişkin Literatür Çalışmaları

Literatürde infertilite (kısırlık) risk faktörlerinin tek başına gebelik elde etme üzerine etkilerini araştıran birçok çalışma mevcut olmasına rağmen, birden fazla risk faktörünün doğal sikluslarda kümülatif konsepsiyon üzerine etkisini, yapay zekâ yaklaşımı kullanılarak araştıran çalışma sayısı oldukça kısıtlıdır.

Literatürdeki çalışmalar incelendiğinde, Jeremiah A. Balogun ve arkadaşları tarafından 2016 yılında yapılan bir çalışmada, naive Bayes, yapay sinir ağları ve karar ağaçları yöntemleriyle, 39 kadın hasta verisi kullanılarak infertilite (kısırlık) riski için bir tahmin modeli geliştirilmiş ve en yüksek doğruluk oranı %74.36 olarak elde edilmiştir (52).

Fayemiwo ve arkadaşları tarafından 2019 yılında yapılan bir çalışmada, doğurganlık hızındaki artış/azalış ve ölü doğumdan sorumlu olan faktörlerin belirlenmesi amacıyla, en yakın komşu sınıflaması, rastgele orman sınıflaması ve karar ağaçları yöntemleri kullanılmıştır. Kadının yaşının, eğitim düzeyinin ve yaşadığı yerin doğum sırasında çocuğun hayatta kalması için en önemli faktörler olduğu ve rastgele orman sınıflamasının diğer iki modele göre daha başarılı olduğu sonucuna ulaşılmıştır (53).

ShuJie Liao ve arkadaşlarının, in vitro fertilizasyon (tüp bebek) ve embriyo transferi yapılan 60.648 infertil (kısır) çift üzerinde, 2020 yılında yaptıkları bir çalışmada makine öğrenmesi yöntemlerinden rastgele orman algoritması kullanılarak klinisyenlere kısırlık düzeyini tahmin etmede yardımcı olacak dinamik bir puanlama sistemi oluşturulmuştur. Çapraz doğrulama sonuçlarına göre sistemin kararlılığının %95.94 (% 95 CI, % 95.14-% 96.74) olduğu görülmüştür (7).

2019 yılında, Bo Zhang ve arkadaşları tarafından, kısırlıktan müzdarip olan ve IVF (tüp bebek) tedavisi gören 11.190 çift üzerinde, temel tıbbi muayene bilgilerinin yanı sıra, folikül sayımı ve hormon değerleri gibi ölçüm değerlerinin de kullanılarak kümülatif gebelik oranlarının tahmin edildiği bir çalışma yapılmıştır. Tüp bebek tedavisi yaklaşımını belirlemeyi ve tedavi masraflarını düşürmeyi hedefleyen bu çalışmada, destek vektör makineleri kullanılmış ve en iyi AUC değeri 0.692 olarak elde edilmiştir (54).

Jennifer J. Yland ve arkadaşlarının 2021 yılında yapmış oldukları bir çalışmada, 2013 ve 2019 yıllarında 21-45 yaşları arasında, ABD veya Kanada'da ikamet eden, doğurganlık tedavisi almayan ve kayıt sırasında aktif olarak hamile kalmaya çalışan 4133 katılımcıya temel bir anket doldurtulmuştur. Elde edilen veriler üzerinden katılımcılar 12 ay dolana dek, gebe kalana kadar her iki ayda bir takip edilmiştir. Çalışmada sosyodemografik faktörler, yaşam tarzı ve davranışsal alışkanlıklar, beslenme kalitesi, tıbbi geçmiş ve erkek partner hakkında olmak üzere başlangıçta toplamda 163 özellik dikkate alınmıştır. Nihai sadeleştirilmiş modeller sırasıyla; model I için 14, model II ve model III için 15 değişken içermektedir. Lojistik regresyon, destek vektör makineleri, sinir ağları, gradyan güçlendirme yöntemlerini kullanarak 6 aylık ve 12 aylık peryotlarda hamilelik olasılığını tahmin eden ve ayrıca Cox yöntemi aracılığıyla 12 siklus boyunca, her adet döngüsündeki gebelik olasılığını tahmin eden, toplamda üç farklı model geliştirilmiştir. Model I ve II için AUC değerleri sırasıyla %70 ve %66 olarak belirlenmiştir. Model III için uyum indeksi %63 olarak elde edilmiştir (8).


Bertini ve arkadaşları 2022 yılında yaptıkları bir çalışmada, gebelik komplikasyonlarını belirlemek için makine öğrenimi yöntemlerinin uygulanabilirliğini ve performansını değerlendirmeyi amaçlamışlardır. PubMed, Scopus ve Web of Science veri tabanlarından sistematik derleme ile 98 makale incelenmiş ve PRISMA yöntemiyle aralarından 31 makale seçilmiştir. Elde ettikleri sonuçlara göre, destek vektör makinesi ile prematürite doğum tahmininde %95.7 doğruluk ve de XGBoost ile neonatal mortalite oranını (yenidoğan ölüm oranı) %99.7 doğruluk ile tahmin etmişlerdir. Makine öğrenimi, perinatal komplikasyonların tahmininde önemli bir potansiyele sahip olabileceği sonucuna varılmıştır (55).

Lijue Liu ve arkadaşları tarafından 2020 yılında, in vitro fertilizasyon-embriyo transferi sonrası erken gebelik kaybı oranının yüksek olabilme ihtimali üzerine makine öğrenme algoritmalarını kullanarak embriyonik gelişimi tahmin eden bir model ile doktorlara klinik karar desteği sağlama amaçlı bir çalışma yapılmıştır. İn vitro fertilizasyon-embriyo transferi sonrası devam eden gebelik ve erken gebelik kaybı örnekleri arasındaki özellikler analiz edilmiş ve fetal kalp atış hızı ve embriyo transferi sonrası geçen günler arasındaki ilişki incelenerek bir tahmin modeli geliştirilmiştir. Lojistik regresyon, destek vektör makinesi, karar ağaçları, geri yayılım sinir ağı, XGBoost ve rastgele orman algoritmalarını kullanarak tahmin modelleri oluşturulmuş ve her algoritmanın fetal kalp atış dahil edilerek ve edilmeyerek tahmin doğruluğu karşılaştırılmıştır. Rastgele orman modelinin, fetal kalp atış hızı dahil olduğunda %97 recall ve F1 skoru, 0.97 AUC değerleriyle en yüksek doğruluğu sağladığı ve modelin 10 hafta sonra doğruluk oranının %99'a ulaşıldığı görülmüştür (56).

3. GEREÇ ve YÖNTEM

Yapılan doktora tez çalışması, KTÜ Biyoistatistik ve Tıp Bilişimi Ana Bilim Dalında yürütülmüştür. Prospektif olan çalışma için öncelikle KTÜ Tıp Fakültesi Bilimsel Araştırmalar Etik Kurul Başkanlığından 15.09.2021 tarihinde, 2021/257 protokol numaralı yazı ile etik kurul onayı alınmıştır (Ek 1). Literatür taraması yapılarak uzman hekim tarafından belirlenen değişkenlere ilişkin veriler, Opr. Dr. Beril GÜRLEK kadın hastalıkları ve doğum kliniğine başvuran katılımcılardan prospektif olarak elde edilerek, Excell ortamına aktarılmıştır. Veri ön işleme süreci ve tanımlayıcı istatistikler için IBM SPSS 23; makine öğrenmesi yöntemleri ve veri görselleştirme için açık kaynaklı R programlama dili (R Foundation for Statistical Computing, Vienna, Austria, version 4.3.1) kullanılmıştır.

Yapılan tez çalışmasına ilişkin akış şeması Şekil 3'te verilmiştir.



Şekil 3. Yapılan tez çalışmasına ilişkin akış şeması

3.1. Veri Seti

Veri seti, prospektif olarak 2021-2022 yılları arasında 15 aylık bir takip süresi boyunca elde edilmiştir. Herhangi bir korunma metodu kullanan veya gebelik istemi konusunda kararsız olan, 1 yılın üstünde infertilite (kısırlık) öyküsü olan ya da hali hazırda infertilite tedavisi gören, çalışma sürecinde tedavi görmeye karar veren veya gebe kalmaktan vazgeçen kadınlar çalışma dışı bırakıldı. Opr. Dr. Beril GÜRLEK kadın hastalıkları ve doğum kliniğine başvuran ve gebelik isteyen, 18-45 yaş arasında olmak üzere 300 katılımcıya ait bilgiler, onamları da alınarak, ilk üç ay içinde hem yüz yüze hem telefon hem de online formlar (Google formlar) aracılığıyla elde edildi. Sonrasındaki 12 aylık takip süresinde bilgileri alınan 300 katılımcı, yaklaşık 2-3 ayda bir telefonla aranıp, gebe kalıp kalmadıkları kontrol edildi. Bu bir yıllık sürecin sonunda 300 katılımcıdan, 160'ının 12 ay bitmeden gebelik elde ettiği ve 12. ayın bitimini takiben yapılan son aramalarda hala gebe kalamayan 140 kişi olduğu bilgisine ulaşıldı. Veriler excell ortamında kaydedilerek veri toplama süreci tamamlandı ve gebe kalan ve kalamayan olmak üzere toplamda 300 katılımcıya ait demografik, yaşam tarzı, davranışsal faktörler, tıbbi ve üreme geçmişlerine ilişkin veriler elde edildi.

3.2. Değişkenler

Konsepsiyon tahmini değişken soru formu (Ek 2) hazırlanarak yüz yüze görüşmeler ile ve aynı soru formu üzerinden çevrimiçi bir Google formu olarak derlenmesi (Ek 3) ile, katılımcılardan onamları da (Ek 4) alınarak toplanan bilgilerle veri seti oluşturuldu. 300 katılımcıya ait veri setindeki 51 değişken arasından, çoklu bağıntılılık analizi sonucu yüksek korelasyon gösteren, gebelerden bazı değişkenlere ilişkin sağlıklı bilgi alınamaması ve eksik verilerin fazla olması gibi sebeplerle 19 değişken çalışmadan çıkarıldı ve çıkarılan değişkenler Tablo 1'de sunuldu. Nihai veri setinde kalan 32 değişken ise Tablo 2'deki gibidir.

3.3. Veri Ön işleme

3.3.1. Çoklu Bağıntılılık (Multicollinearity)

Çoklu bağıntılılık, bağımsız değişkenler arasındaki yüksek ilişki veya bağımlılığı ifade eder. Bu durum, modelin doğruluğunu ve istatistiksel güvenilirliğini etkileyebilir. Bağımsız değişkenler arasındaki Pearson veya Spearman korelasyon katsayıları hesaplanarak yüksek pozitif veya negatif korelasyonlar tespit edilebilir. Eğer iki veya daha

fazla bağımsız değişken arasında güçlü bir ilişki varsa, bu çoklu bağıntılılık işareti olabilir. Bu bağlamda bağımsız değişkenler arasındaki ilişkiler Spearman rank korelasyon testi ile analiz edildi ve yüksek korelasyon gösteren değişkenler analizden çıkarıldı.

3.3.2. Değişken Eleme

Çalışmanın başında katılımcılara uygulanan soru formlarında mevcut olan 51 değişken arasından, uzman hekim görüşü de alınarak, çoklu bağıntılılık sonucu yüksek korelasyon gösteren ve ayrıca gebelerden bazı değişkenlere ilişkin doğru bilgi alınamaması ve eksik verilerin fazla olması gibi sebeplerle 19 değişken elendi.

Elenen 19 değişken arasından; oturularak geçirilen süre ve hareket süresi ($r=0.916$) değişkenleri negatif yönde yüksek korelasyon gösterdiğinden, çoklu bağıntılılık problemi oluştu ve uzman görüşü ile “oturma süresi” elenerek, veri seti için “hareket süresi” değişkeni tercih edildi.

“Evlilik süresi” ve “evlilik yaşı” değişkenlerinin toplamının, katılımcının yaş değişkenine karşılık gelmesinden ötürü yanlılığa sebep olabileceğinden, bu değişkenler elenerek sadece “yaş” değişkeni kullanıldı.

“Son gebelik üstünden geçen süre” ve “toplam gebelik sayısı”, “toplam çocuk sayısı”, “toplam çocuk sayısı”, “yaşayan çocuk sayısı” olmak üzere 5 değişken daha eksik verinin fazla olması nedeniyle elendi.

Ayrıca gebelerden konuyla ilgili doğru bilgi elde edememesi sebebiyle “subfertilite süresi” ve “psikiyatrik ilaç kullanımı” olmak üzere 2 değişken elendi.

“Çalışma durumu” (çalışıyor/çalışmıyor) değişkeni, “meslek” değişkeni (kamu/özel/ev hanımı) içerisinden oluşturulduğu için yanlılığa sebep olabileceğinden, “çalışma durumu” değişkeni elendi ($r=0.505$).

“17 yaş sonrası ani kilo artış miktarı (kg)” ve “korunmayı bıraktıktan sonra ani kilo artış miktarı (kg)”, “kilo artışı var mı?” sorularına “yok” diyen ve “sigara, alkol, kahve kullanıyor musunuz?” sorularına hem kadınların hem de eşlerinin, “hayır” cevaplarına ilişkin, örneklem büyüklüğü yetersizliği sebebiyle uzman görüşü de alınarak, 9 değişken daha elenmiştir.

Toplamda çıkarılan 19 değişken Tablo 1’de sunuldu.

Tablo 1. Veri setinden çıkarılan 19 değişken

Değişkenler
Evlilik süresi (yıl)
Evlilik yaşı
Son gebelik üstünden geçen süre
Subfertilite süresi
Oturularak geçirilen süre
Toplam gebelik sayısı
Toplam çocuk sayısı
Yaşayan çocuk sayısı
Kürtaj veya Düşük Sayısı
Çalışma Durumu
Psikiyatrik İlaç Kullanımı
17 yaş sonrası ani kilo artış miktarı (kg)
Korunmayı bıraktıktan sonra ani kilo artış miktarı (kg)
Sigara adeti
Eş sigara adeti
Alkol adedi
Eş alkol adedi
Kahve adedi
Eş kahve adedi

Toplamda 51 değişken içerisinde çıkarılan 19 değişkenin ardından, kalan 32 değişken ile çalışmaya devam edildi. Bu değişkenlere ilişkin detaylar Tablo 2’de sunuldu.

Tablo 2. Veri setinde kalan 32 değişken

Değişkenler	Veri Tipi	Değişken Aralık Değeri
Yaş	Nümerik	[19-44]
Yaşam yeri	Nominal	“Kırsal”, “Şehir merkezi”
Eğitim	Ordinal	“İlköğretim”, “Lise”, “Önlisans/Lisans”, “Yüksek Lisans/Doktora”
Meslek	Nominal	“Kamu”, “Özel”, “Ev hanımı”
Hane Geliri	Nominal	“Açlık sınırı”, “Açlık ve yoksulluk sınırı”, “Yoksulluk sınırı üstü”
VKİ (Vücut Kitle Endeksi)	Nümerik	[17.53 - 51.42]
17 yaş sonrası ani kilo artışı	Nominal	“evet” veya “hayır”
Korunmayı bıraktıktan sonra ani kilo artışı	Nominal	“evet” veya “hayır”
Gece toplam uyku süresi (saat)	Nümerik	[5-12]
Uyku saati	Nominal	“21.00-23.00”, “23.00-24.00”, “24+”
Uykuya dalma süresi (dk)	Nominal	“15'den az”, “16-30”, “31-60+”
Doğum yöntemi	Nominal	“Normal”, “Sezaryen”, “Doğum yok”
Cinsel ilişki sıklığı (hafta)	Nümerik	[0-4]
Ayakta kalma süresi (gün/saat)	Nümerik	[1-14]
Sigara	Nominal	“evet” veya “hayır”
Kahve	Nominal	“evet” veya “hayır”
Alkol	Nominal	“evet” veya “hayır”
Regl siklus	Nominal	“21 günden kısa”, “21-35 gün”, “35 gün+”
Yumurtlama testi kullanımı	Nominal	“evet” veya “hayır”
Yumurtlama günü hesabı için telefon uygulaması	Nominal	“evet” veya “hayır”
Korunma yöntemi	Nominal	“Geri çekme”, “Modern yöntem”, “Hiç korunmadı”
Ailede kısırlık öyküsü	Nominal	“evet” veya “hayır”
Folik asit kullanımı	Nominal	“evet” veya “hayır”
Ek ilaç kullanımı	Nominal	“evet” veya “hayır”
Ek hastalık	Nominal	“evet” veya “hayır”
D vitamini eksikliği	Nominal	“evet” veya “hayır”
Psikiyatrik tanı	Nominal	“evet” veya “hayır”
Eş (VKİ)	Nümerik	[17.53 - 43.60]
Eş (Eğitim)	Ordinal	“İlköğretim”, “Lise”, “Önlisans/Lisans”, “Yüksek Lisans/Doktora”
Eş (Sigara)	Nominal	“evet” veya “hayır”
Eş (Kahve)	Nominal	“evet” veya “hayır”
Eş (Alkol)	Nominal	“evet” veya “hayır”
Gebelik Durumu	Nominal	1=gebe kaldı, 0=gebe kalamadı

3.4. İstatistiksel Analiz

Verilerin istatistiksel analizi için SPSS 23 ve R 4.3.1 açık erişimli programlama dili kullanılmıştır. Nicel veriler için normal dağılıma uygunluk Kolmogrov-Smirnov testi ile değerlendirilmiştir. Tanımlayıcı istatistikler, hiçbirisi normal dağılıma uymayan nicel değişkenler için medyan (1.çeyreklik- 3.çeyreklik; Q1-Q3) olarak; nitel değişkenler ise frekans (n) ve yüzde (%) olarak verilmiştir. Normal dağılım göstermeyen nicel değişkenlerde gruplar arası farkı saptamada Mann Whitney U testi, kategorik değişkenlerde oranlar bakımından fark bulunup bulunmadığını belirlemede ise ki-kare testi kullanılmıştır. Veriler istatistiksel olarak %95 güven aralığında test edilmiş ve $p < 0.05$ değerleri anlamlı olarak kabul edilmiştir.

3.5. Öznitelik Seçimi (Feature Selection)

Öznitelik seçimi, bir veri seti içerisindeki en önemli öznitelikleri seçme ve belirleme sürecidir. Kümeleme ve sınıflama yöntemlerinde veri boyutunun yüksek olması model oluşturma sürecini ve analizini zorlaştırabilir. Bu yöntem, yüksek boyutlu veri kümelerinden alt kümeler belirlenerek ve gereksiz özellikler çıkararak modeli daha doğru hale getirmek için kullanılan bir ön işleme sürecidir. Seçilen özniteliklerin sayısını azaltmak veya kaldırmak makine öğrenmesi modellerinin performansı önemli ölçüde etkileyebilmektedir (57). Aynı zamanda bu süreç modelin aşırı uyum (overfitting) riskini azaltmaktadır (58). Öznitelik seçim yöntemleri, filtreleme (filter), sarmal (wrapper) ve gömülü (embedded) olmak üzere aşağıdaki gibi üç kategoride genellenebilirler:

1. Filtreleme Yöntemleri: Bu yöntemler ile, veri setinde filtreleme yapılır ve sınıflama algoritmalarına dayanmayan, uzaklık, bilgi, bağımlılık ve tutarlılık gibi istatistiksel ölçütleri kullanarak öznitelik seçimi yapılır. En sık kullanılan yöntemler arasında, Fisher skor, ki-kare, bilgi kazancı (information gain), kazanç oranı (gain ratio), gini, f-skor (f- score), Boruta, korelasyon özellik seçimi (correlation feature selection) bulunmaktadır (58- 60).

Filtreleme yöntemlerinden Boruta algoritması, özelliklerin önemini belirlemek için rastgele ormanları temel alır. Temel prensip olarak rastgele orman modelini birçok kez eğitmek ve her bir özelliğin gerçekten önemli olup olmadığını belirlemek için permütasyon önemi (permutation importance) ölçütünü kullanmaktadır. Böylece belirli bir özelliğin model performansındaki değişikliği ölçülmektedir (61).

2. Sarmal Yöntemler (Wrapper-Based): Sarmal yöntemlerde genellikle seçim ölçütü olarak sınıflama doğruluğu kullanılır. Bu yöntemler, sıralı seçim algoritmaları ve sezgisel arama algoritmaları olarak ayrılırlar. Öznitelik alt küme uzayı fazla olduğunda sezgisel yöntemler tercih edilir. Kullanılan yöntemler arasında ardışık ileri yönde seçim (sequential forward selection), ardışık geri yönde seçim (sequential backward selection), ardışık ileri yönde kayan seçim (sequential forward floating selection), ardışık geri yönde kayan seçim (sequential backward floating selection), özyinelemeli özellik eleme (recursive feature elimination - RFE), genetik algoritma (genetic algorithm), parçacık sürü optimizasyonu (particle swarm optimization) en sık kullanılan sarmal yöntemlere örnekler (58, 59) .

3. Gömülü (Embedded) Yöntemler: Gömülü yöntemlerin yapısında, sınıflama algoritması ve öznitelik seçim algoritması bir arada olduğundan, bu yöntemler öznitelik seçimini ve sınıflamayı aynı anda yaparlar. En uygun öznitelik alt kümesinin aranması, sınıflandırıcı yapısının içine entegre edilir ve öznitelik alt kümesi ile hipotezlerin birleşik bir alanda aranmasına olanak tanır. Bu yöntemler, birbirine bağlı bir dizi karar ağacının sonuçlarını birleştirerek daha güçlü ve stabil tahminler yapmayı amaçlar. Gömülü yöntemler, tek başına bir karar ağacından daha güçlü ve dengeli tahminler sağlarlar. Bunun nedeni, birden fazla ağacın tahminlerinin birleştirilmesiyle oluşturulmuş daha genelleşici bir model olmalarıdır. Gömülü yöntemlere en küçük mutlak küçülme ve seçim operatörü (LASSO), rastgele orman ve lojistik regresyon gibi yöntemler örnek verilebilirler (58, 62, 63).

Çalışmamızda, tahminsel modellemede kullanılacak olan değişkenleri belirlemek adına 300 örneklem ve 32 değişkenden oluşan veri setinde gebe kalıp, kalamama ile ilişkili olarak öznitelik seçimi ile belirlenen önemli faktörler; sarmal yöntemlerden olan özyinelemeli özellik eleme (RFE), filtreleme yöntemlerden olan Boruta algoritması, gömülü yöntemlerden olan rastgele orman (RF) ve lojistik regresyon geriye doğrusal regresyon eleme (logistic regression model backward LR elimination) ve de en küçük mutlak küçülme ve seçim operatörü (LASSO) olmak üzere beş farklı yöntem ile belirlenmiştir. Bunun sonucunda, tüm değişkenler (senaryo 1) ve öznitelik seçimi ile edilen değişkenlere ilişkin (senaryo 2 ve senaryo 3) olmak üzere, üç farklı senaryo yaklaşımı için makine öğrenmesi yöntemleri kullanılarak tahmin modelleri geliştirilmiştir.

3.6. Modellerin Geliştirilmesine İlişkin Yaklaşımlar

Tüm değişkenler (32 değişken), öznitelik seçimi yöntemlerinin hepsinde en az bir kez önemli bulunan 15 değişken ve tüm öznitelik seçimi yöntemlerinin çoğunda ortak olarak yüksek öneme sahip 9 değişken olmak üzere üç farklı senaryo yaklaşımı önerilmiştir. Kullanılan tüm makine öğrenmesi yöntemlerinin model performansları bu üç senaryo üzerinde değerlendirilmiştir. Oluşturulan veri seti %70'i modelin eğitilmesinde, kalan %30'u ise modelin performansının değerlendirilmesi için test seti olarak rastgele ayrılmıştır.

3.6.1. Senaryo 1 (Tüm Değişkenler)

Çalışmadaki kullanılan tüm değişkenler olan ve 32 değişkeni kapsayan, 160'ı gebe kalan ve 140'ı gebe kalamayan olmak üzere toplam 300 katılımcıya ait verinin, %70'i alınarak, 210'u eğitim seti ve aynı verinin %30'u alınarak, kalan 90'ı da test seti olacak biçimde rastgele olarak bölünmüştür. Böylece Senaryo 1 için 32 değişkenli bir eğitim/test setleri elde edilmiştir. Senaryo 1'de kullanılan ve Tablo 2'de veri yapıları gösterilen 32 değişken, Tablo 3'teki gibidir.

Tablo 3. Senaryo 1’de kullanılan değişkenler

Değişkenler
Yaş
Yaşam yeri
Eğitim
Meslek
Hane Geliri
VKİ (Vücut Kitle Endeksi)
17 yaş sonrası ani kilo artışı
Korunmayı bıraktıktan sonra ani kilo artışı
Gece toplam uyku süresi (saat)
Uyku saati
Uykuya dalma süresi (dk)
Doğum Yöntemi
Cinsel ilişki sıklığı (hafta)
Ayakta kalma süresi (gün/saat)
Sigara
Kahve
Alkol
Regl siklus
Yumurtlama testi kullanımı
Yumurtlama günü hesabı için telefon uygulaması
Korunma yöntemi
Ailede kısırlık öyküsü
Folik Asit Kullanımı
Ek İlaç Kullanımı
Ek Hastalık
D vitamini eksikliği
Psikiyatrik tanı
Eş (VKİ)
Eş (Eğitim)
Eş (Sigara)
Eş (Kahve)
Eş (Alkol)

3.6.2. Senaryo 2 (15 Değişken)

Senaryo1’deki 32 değişkenden öznitelik seçimi yöntemlerinde en az bir kez önemli bulunan 15 değişken seçilmiştir. Böylece Senaryo 2’de, öznitelik seçimi yöntemleri

sonucunda belirlenen 15 deęiřkene ait eęitim/test setleri oluřturulmuřtur. Senaryo 2’de kullanılan 15 deęiřken Tablo 4’teki gibidir.

Tablo 4. Senaryo 2’de kullanılan deęiřkenler

Deęiřkenler
VKİ
Eęitim durumu
Gece toplam uyku sũresi (gũnde/saat)
Yař
Ayakta kalma sũresi (gũnde/saat)
Eř (VKİ)
Regl siklus
D vitamini eksiklięi
Korunma yũntemi
(Eř) Eęitim durumu
Yumurtlama testi
Folik asit kullanımı
Ek ilaç kullanımı
Korunmayı bıraktıktan sonra kilo artımı
Hane geliri

3.6.3. Senaryo 3 (9 Deęiřken)

Senaryo 1’deki 32 deęiřken arasından, œznitelik seęimi yũntemlerinin hemen hepsinde ortak olarak yũksek œneme sahip olan 9 deęiřken seęilmiřtir. Seęilen bu deęiřkenler aracılıęı ile, 3. Senaryo ięin 9 deęiřkenli bir test/train seti oluřturulmuřtur. Senaryo 3’te kullanılan 9 deęiřken Tablo 5’te verilmiřtir.

Bũylece, œznitelik seęimi œncesi ve sonrası elde edilen sonuēlara gũre toplamda 3 senaryo belirlenmiř ve bu senaryolara iliřkin eęitim/test setleri oluřturulmuřtur.

Tablo 5. Senaryo 3’te kullanılan değişkenler

Değişkenler
VKİ
Eğitim Durumu
Gece toplam uyku süresi (günde/saat)
Yaş
Ayakta kalma süresi (günde/saat)
Regl siklus
D vitamini eksikliği
Korunma yöntemi
Korunmayı bıraktıktan sonra kilo artımı

3.7. Modellerin Geliştirilmesi

3.7.1. Yapay Zekâ ve Makine Öğrenmesi

Günümüzde sağlık alanında büyük ve çeşitli miktarlarda veri birikmektedir. Sağlık kuruluşlarındaki mevcut operasyonel ve klinik kararları iyileştirmek için yapılandırılmış ve yapılandırılmamış verilerde bulunan örüntüleri ve ilişkileri analiz etmek için makine öğrenmesi, istatistiksel analiz, modelleme teknikleri gibi araçlar kullanılmaktadır (64).

Uzman sistemler, yapay zekâ ve makine öğrenmesi yöntemlerinin tıp alanında kullanılmasının temel amaçlarından biri de, hastalıkları erken teşhis etmede doktorlara yardımcı olabilmektir (65). Son dönemde yapılan bazı çalışmalarda, büyük veri ve makine öğrenmesi algoritmalarıyla elde edilen sonuçların, hekimlerle eşit performans gösterdiği görülmüştür (66).


3.7.2. Makine Öğrenmesi Yaklaşımları

Makine öğrenmesi yöntemlerinde çeşitli öğrenme türleri bulunmaktadır. Sistem tarafından kullanılan öğrenme algoritması öğrenme türlerine göre değişiklik gösterir ve öğrenmenin nasıl gerçekleştirileceğini belirler. Başlıca öğrenme türleri ve ayrıntıları aşağıdaki gibidir. (67, 68).

- Denetimli Makine Öğrenmesi (Supervised Machine Learning)
- Denetimsiz Makine Öğrenme (Unsupervised Machine Learning)
- Yarı-Denetimli öğrenme (Semi-supervised Learning)
- Pekiştirerek öğrenme (Reinforcement Learning)

- Topluluk Öğrenmesi (Ensemble Learnig)

Denetimli Makine Öğrenmesi (Supervised Machine Learning): Denetimli (gözetimli) öğrenme, girdi-çıkı çiftlerine dayalı olarak girdi verilerini karşılık gelen çıktı verileriyle eşleştirebilen bir işlevin elde edilmesine odaklanan bir makine öğrenmesi sürecidir. Bu süreç, etiketli eğitim verilerinden bir fonksiyonun çıkarılmasını içerir. Denetimli makine öğrenmesi algoritmalarında girdi veri seti, eğitim ve test kümelerine bölünür. Eğitim seti, tahmin edilecek veya sınıflandırılacak çıktı değişkenini içerir. Tüm algoritmalar, eğitim verileri aracılığıyla örüntüleri ayırt eder ve daha sonra bu örüntüleri tahmin veya sınıflama için test veri setine uygular (68). Denetimli makine öğrenmesi algoritmalarının iş akışı aşağıdaki Şekil 4'te gösterilmiştir.



Şekil 4. Denetimli makine öğrenmesi süreci (Afrin'den, 69)

Denetimsiz Makine Öğrenme (Unsupervised Machine Learning): Denetimsiz (gözetimsiz) öğrenme, insan müdahalesine ihtiyaç duymadan etiketlenmemiş veri kümelerini analiz eder. Bu yöntem çıktı verilerini kullanmaz. Veri tabanlı bir süreç olan denetimsiz öğrenme genellikle üretken özelliklerin çıkarılması, anlamlı desenlerin


belirlenmesi, sonuçlardaki gruplamalar ve keşif amaçları için kullanılır. En yaygın görevleri arasında kümeleme, olasılık yoğunluk tahmini, özellik öğrenme, boyut azaltma, birliktelik kurallarını bulma, anormallik tespiti bulunmaktadır (70).

Yarı-Denetimli Öğrenme (Semi-Supervised Learning): Yarı denetimli öğrenme, denetimli ve denetimsiz yöntemlerin hibrit hali olarak tanımlanır. Hem etiketli hem de etiketsiz veriler üzerinde çalışır. Bu nedenle, “gözetimsiz” öğrenme ile “gözetimli” öğrenme arasında bir konumda bulunur. Gerçek dünyada, etiketlenmiş veriler çeşitli nedenlerden dolayı nadir olabilir ve bu yüzden etiketlenmemiş verilerin yararlı olduğu birçok durum söz konusudur. Bunun için class yöntemi kullanılarak datalar sınıflandırılır. Yarı denetimli öğrenmenin uygulama alanları arasında makine çevirisi, sahtekarlık tespiti, veri etiketleme ve metin sınıflama yer almaktadır (70).

Pekiştirerek Öğrenme (Reinforcement Learning): Takviyeli öğrenme, yazılım araçlarının belirli bir ortamda nasıl hareket etmeleri gerektiğini öğrenmeye odaklanan bir makine öğrenmesi alanıdır. Bu öğrenme türü geri beslenme ve kümülatif ödül temelinde çalışarak, denetimli öğrenme ve denetimsiz öğrenme paradigmalarının yanı sıra temel makine öğrenmesi kavramlarını da içerir (68).

Topluluk Öğrenmesi (Ensemble Learning): Topluluk öğrenmesi (ensemble learning) stratejik olarak oluşturulmuş birden çok öğrenme algoritmasının bir araya getirilerek birlikte kullanılmasıdır. Bu yöntemin amacı, tekil modellerin zayıf yönlerini birleştirerek daha güçlü ve genelleyici bir model elde etmektir. Bu açıdan topluluk öğrenmesi, çeşitli öğrenme algoritmaları veya aynı algoritmanın farklı öğrenme parametreleri ile eğitilmiş modelleri bir araya getirebilir. En yaygın kullanılan topluluk öğrenmesi yöntemleri, gradyan artırma (gradient boosting) veya rastgele orman gibi teknikleri de içeren güçlendirme (boosting) ve torbalama (bagging)’dır (68).

Topluluk öğrenmesinin temel avantajları, modelin genel performansını artırması, overfitting'e karşı pozitif direnç göstermesi ve güvenilir sonuçlar verebilmesi sayılabilir. Bu yöntem, sınıflama veya regresyon gibi çeşitli makine öğrenmesi yöntemlerinde başarıyla kullanılabilir (71). Topluluk öğrenme mimarisine dair genel yapı Şekil 5'teki gibidir.



Şekil 5. Topluluk öğrenmesine yönelik genel yapı (Küçükakçalı'dan, 72)

3.7.3. Makine Öğrenmesinin Uygulanma Aşamaları

Makine öğrenmesinin uygulanma aşamaları sırasıyla;

1. Veri setinin oluşturulması
2. Oluşturulan veri setinin, algoritmalar açısından uygun hale getirilmesi için temizlenmesi ve uygun formata dönüştürülmesi ile eğitim ve test verisine ayrılması gibi işlemlerden oluşan veri ön işleme aşamasının gerçekleştirilmesi
3. Yukarıda belirtilen aşamalar sonucunda oluşturulan eğitim veri setinin ve algoritmaların kullanılarak modelin geliştirilmesi
4. Model oluşturulduktan sonra, test veri seti üzerinden modelin değerlendirilmesinin yapılması

5. Sonuçların istenilen düzeyde olması durumunda uygulamanın canlı ortama taşınması aksi halde sonuçların geliştirilmesi, olarak özetlenebilecektir (73).

1 ve 2. maddelerdeki aşamalar, bölüm 3.3'teki veri ön işleme başlığı altında gerçekleştirilmiştir. 3, 4 ve 5. aşamalar için, denetimli makine öğrenmesi ve topluluk öğrenmesi algoritmaları arasından tez çalışmasında kullanılacak olan sınıflama algoritmaları, bölüm 3.7.4'te özetlenmiştir. Ayrıca 5. aşamada belirtilen sonuçların geliştirmesi için yapılan çalışmalar, bölüm 3.7.5'te "model eniyileme" başlığı altında özetlenmiştir.

3.7.4. Sınıflama Algoritmaları

Sınıflama algoritmalarıyla elde edilen modellerde, modelin performansını değerlendirmek ve bilinmeyen örnekleri sınıflamak için eğitim veri setinde bulunan ve etiketi bilinen örnekler kullanılır. Model, eğitim veri setindeki bu örneklerden öğrendiği kalıpları kullanarak yeni gelen veri örneklerini uygun sınıflara atamaya çalışır. Sınıflama algoritmaları genellikle olasılık tabanlı ve olasılık tabanlı olmayan (ayrık) olarak iki kategoriye ayrılırlar. Olasılık tabanlı sınıflandırıcılarda, bir örneğin belirli bir sınıfa ait olma olasılığı hesaplanırken, olasılık tabanlı olmayan sınıflandırıcılar ise örneğin hangi sınıfa ait olduğunu ya da olmadığını doğrudan belirtilir. Bu sınıflandırıcılar ikili (binary) olabildiği gibi, 2'den fazla çoklu sınıflandırıcı da söz konusu olabilir (74).

Bu bağlamda tez çalışmasında kullanılan olasılık tabanlı sınıflama algoritmaları aşağıdaki gibi kısaca özetlenmiştir.

3.7.4.1. Naive Bayes

Naive Bayes, Bayes teoremine dayalı bir sınıflama yöntemidir ve diğer bazı sınıflama yöntemlerine kıyasla genellikle daha etkili olduğu bilinmektedir. Bu durum, naive Bayes'in her koşulu veya olayı birbirinden bağımsız varsaymasından kaynaklanan güçlü özelliğine dayanır. Bu yöntem genellikle büyük veri kümeleri üzerinde başarılı bir şekilde uygulanabilir. Bayes teoreminin formülü aşağıdaki gibidir:

$$P(X|C) = \frac{P(C)P(X|C)}{p(X)} \quad (\text{Eşitlik 1})$$

Burada:

$P(C|X)$: X verildiğinde C'nin olasılığı

$P(X|C)$: C verildiğinde X'in olasılığı

$P(C)$: C olayının olasılığı

$P(X)$: X olayının olasılığıdır.


$$X = (x_1, x_2, x_3, \dots, x_n) \quad (\text{Eşitlik 2})$$

3.7.4.2. Destek Vektör Makineleri - DVM (Support Vector Machines - SVM)

DVM (Destek Vektör Makinesi), sınıflandırılacak veya tahmin edilecek değişkenle ilgili sınıfları, ayırıcı bir hiper düzlem aracılığıyla en iyi şekilde birbirinden ayırabilen düzlemleri belirlemeyi amaçlar. Bu da, etiketli eğitim verileri verildiğinde algoritmanın yeni örnekleri kategorize etmek için optimal bir hiper düzlem üreteceği anlamına gelmektedir (76). Destek vektör makineleri, dağılımdan bağımsız öğrenme yeteneğine sahip olan ve yapısal riski minimize etmeye odaklanmış optimizasyon temelli denetimli öğrenme sınıflayıcılarıdır. Destek vektör makinesinin yapısı Şekil 6'da gösterilmiştir.

Destek vektör makineleri, farklı çekirdek fonksiyonlarını kullanarak sınıflama ve tahmin işlemlerini gerçekleştirir. Veri setinin yapısına göre, sınıflama ve tahmin performansını doğrudan etkileyen en uygun çekirdek fonksiyonunun belirlenmesi oldukça önemlidir. Radyal tabanlı çekirdek fonksiyonu, doğrusal çekirdek fonksiyonu, Laplace çekirdek fonksiyonu, polinomial çekirdek fonksiyonu, Bessel çekirdek fonksiyonu ve hiperbolik tanjant çekirdek fonksiyonu destek vektör makineleri'nde kullanılan çekirdek fonksiyonlarıdır (77).


Çalışmamızda, en optimum sonucu vermiş olan radyal tabanlı çekirdek fonksiyonu kullanılmıştır.



Şekil 6. Destek vektör makinesinin yapısı (Doğaner'den, 77)

3.7.4.3. Rastgele Orman (Random Forest)

Rastgele orman (RF) sınıflandırıcısı, makine öğrenmesi ve veri bilimi alanlarında yaygın olarak kullanılan bir topluluk sınıflama tekniğidir. Bu yöntem, birden fazla karar ağacını bir araya getirerek “paralel birleştirme” yaklaşımını benimser. Farklı sınıflandırıcılara paralel olarak veri setinin alt örneklerini kullanır ve sonuçları çoğunluk oyu ile veya ortalama değerle birleştirir. Böylece aşırı öğrenme sorunu en aza indirilir ve tahmin doğruluğu artırılır. Rastgele orman öğrenme modeli genellikle tek bir karar ağacına dayalı modellerden daha doğru olan, kontrollü varyasyona sahip bir dizi karar ağacı oluşturmak için torbalama (bagging) ve rastgele öznitelik seçimini birleştirir. Adaptif olan bu sınıflandırıcı hem sınıflama hem de regresyon problemleri için uygun olmaktadır. Ayrıca hem kategorik hem de sürekli değerler içeren veri setleri için kullanışlıdır (70). Veri kümesindeki veriler ve öznitelikler, rassal olarak çok sayıda küçük gruba bölünerek Şekil 7’deki gibi farklı karar ağaçları oluşturur.




Şekil 7. Rastgele orman algoritması (Aydın'dan, 78)

3.7.4.4. XGBoost (eXtreme Gradient Boosting)

Topluluk öğrenmesi (ensemble learning) yöntemlerinden biri olan gradyan güçlendirme (gradient boosting) tekniklerini içeren XGBoost algoritması, rastgele orman (RF) gibi başlı başına bir dizi modele dayanan, genellikle karar ağaçları kullanarak bir bütün oluşturan bir öğrenme algoritmasıdır. Gradyan iniş (gradient descent) tekniği ile kayıp fonksiyon en aza indirilerek ağırlıklar optimize edilir. En iyi modeli belirlemek için detayları dikkate alan bir güçlendirme (boosting) yöntemidir. İkinci dereceden gradyanları hesaplar ve böylece kayıp fonksiyonu en aza indirmek ve de aşırı uyumu azaltmak için gelişmiş düzenleme (regülerizasyon) tekniklerini (L1 ve L2) kullanarak modelin performansını artırır. XGBoost'un yorumlanması hızlıdır ve büyük boyutlu veri kümelerini etkili bir şekilde işleyebilme yeteneğine sahiptir (70).

Rastgele orman algoritmasından farklı olarak, modeli oluşturan karar ağaçları tamamen rassal şekilde oluşturulmaz. Her yeni karar ağacı, kendisinden önceki karar ağacının hatalarını iyileştirmeye odaklanır, bu da veri kümesindeki özelliklerin ve ilişkilerin daha iyi yakalanmasını sağlar. Bu durum, bir önceki ağacın yanlış sınıflandırdığı örnekler üzerine odaklanarak yeni ağacın bu hataları düzeltmeye çalıştığı anlamına gelir.

Şekil 8’de görüldüğü üzere her bir karar ağacı, modelin tahmin gücünü artırırken, topluluk olarak bir araya getirildiğinde daha güçlü bir tahmin modeli oluşturur (78).



Şekil 8. XGBoost algoritması (Aydın’dan, 78)

3.7.4.5. CatBoost (Category Boosting)

CatBoost, kategorik değişken destekli bir gradyan artırıcı karar ağacı (GBDT) algoritmasıdır. CatBoost, kategorik özellikleri daha etkili bir şekilde ele alır. Geleneksel GBDT algoritmaları, kategorik değişkenleri doğrudan kullanamazlar veya özel ön işlemler gerektirirler. CatBoost algoritması ise kategorik değişkenleri doğrudan işleyebilir ve modellemede kullanabilir. CatBoost, birçok kategorik değişkenle etkili bir şekilde başa çıkabilen az sayıda hiper parametreye sahiptir. Böylece kullanıcıların modelin karmaşıklığını yönetirken daha az ayar yapması sağlanılarak, modelin eğitimi daha kolay bir hale getirilir. Kısaca CatBoost algoritması, kategorik değişkenlerle etkili bir şekilde çalışabilen, az parametreyle yüksek performans sağlayabilen ve GBDT'nin güçlendirilmiş bir versiyonudur (79).

3.7.5. Model Eniyileme: Hiper Parametre Optimizasyonu

Makine öğrenmesi algoritmalarının başarısı, hiper parametrelerin doğru bir şekilde yapılandırılmasına bağlıdır. Hiper parametrelerin uygun şekilde ayarlanması, modelin performansı üzerinde doğrudan bir etkiye sahiptir. Hiper parametre optimizasyonu en kör yaklaşımla, deneme ve yanılma (trial and error) yöntemiyle gerçekleştirilir. Bu süreçte farklı hiper parametre değerlerine dair kombinasyonlar denenerek, model üzerindeki performans etkisine bakılır (80).

Izgara arama (grid search), makine öğrenmesi modelinin hiper parametrelerini belirlemek adına yaygın olarak kullanılan bir hiper parametre optimizasyon tekniğidir. Hiper parametreler için arama alanını belirleyerek mümkün olan tüm parametre kombinasyonlarını oluşturan sistematik bir arama yöntemidir. Bu algorithmada optimizasyon süreci, parametreler arasındaki etkileşimlerden bağımsız olarak sağlanır ve tüm parametreler eşit olasılığa sahiptir (81).

Çalışmamızdaki sınıflayıcıların hiper parametre optimizasyonları için, ızgara arama yöntemi kullanılmıştır. Sınıflayıcılar için kullanılan parametreler ve optimum parametre değerleri sırasıyla Tablo 15-18’de verilmiştir.

3.7.6. Makine Öğrenmesi Performans Değerlendirme Metrikleri

Karışıklık Matrisi (Confusion Matrix): Karışıklık matrisi, dört ana bileşenden oluşur (DP, DN, YP ve YN). Bu dört bileşen, sınıflama modelinin performansını ölçmek için çeşitli metriklerin hesaplanmasında kullanılır. Karışıklık matris aracılığı ile sınıflandırıcının performansı daha ayrıntılı bir şekilde değerlendirilebilir (Tablo 6).

Tablo 6. Karışıklık matrisi (Confusion matrix)

	Tahmin (+)	Tahmin (-)
Gerçek (+)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Gerçek (-)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Makine öğrenmesi sınıflandırıcılarının performansını değerlendirmek için birkaç yaygın ölçüm bulunmaktadır. Aşağıda kullanılan bazı temel performans metrikleri özet olarak verilmiştir. Denklemlerdeki;

- DP (Doğru Pozitif) : Gerçek pozitif sınıfı doğru tahmin etme sayısını,
- DN (Doğru Negatif) : Gerçek negatif sınıfı doğru bir şekilde tahmin etme sayısını,
- YP (Yanlış Pozitif) : Gerçek negatif sınıfı yanlış bir şekilde tahmin etme sayısını,
- YN (Yanlış Negatif) : Gerçek pozitif sınıfı yanlış bir şekilde tahmin etme sayısını ifade etmektedir (80-82).

Doğruluk (Accuracy): Doğruluk, doğru tahminlerin toplam örnek sayısına oranını ifade eder. Dengesiz sınıf dağılımı söz konusu olduğunda doğruluk değeri tek başına yeterli olmayabilir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (\text{Eşitlik 3})$$

Kesinlik (Precision): Pozitif olarak tahmin edilen örneklerin, gerçekten pozitif olanlara oranını belirtir. Modelin yanlış pozitifleri elemesi içindir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (\text{Eşitlik 4})$$

Duyarlılık (Recall): Gerçekten pozitif olan örneklerin ne kadarının pozitif tahmin edildiğini gösterir. Modelin yanlış negatifleri düşük tutmasına odaklanır.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (\text{Eşitlik 5})$$

Özgüllük (Recall): Gerçekten negatif olan örneklerin ne kadarının negatif tahmin edildiğini gösterir. Modelin yanlış pozitifleri düşük tutmasına odaklanır.

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (\text{Eşitlik 6})$$


F1 Skoru: F1 skoru, kesinlik ve duyarlılık arasında denge kurmaya çalışan bir metriktir. Özellikle dengesiz sınıf dağılımı söz konusu ise tercih edilebilir.

$$\text{F1 Skor} = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (\text{Eşitlik 7})$$

AUC-ROC (Eğri Altındaki Alan (Area Under the Curve)-(ROC eğrisi (Receiver Operating Characteristic)): ROC eğrisi pozitif ve negatif sınıflar arasındaki performansı, duyarlılık ve özgüllük değerleri üzerinden geniş bir şekilde değerlendiren bir ölçüdür. Farklı eşik değerleri için dikey eksen üzerinde doğru pozitiflik (duyarlılık) ve yatay eksen üzerinde yanlış pozitiflik (1-özgüllük) oranlarının yer aldığı bir eğridir. ROC eğrisi

üzerindeki her nokta farklı eşik değerlerine karşılık gelen duyarlılık ve 1-özgüllük değerlerini gösterir. Genellikle düşük yanlış pozitiflik oranlarına sahip eşik değerleri, düşük doğru pozitiflik oranına da sahiptir. Doğru pozitiflik oranı arttıkça, yanlış pozitiflik oranı da artar. ROC eğrisi; testin ayırt etme gücünün belirlenmesine, çeşitli testlerin etkinliklerinin karşılaştırılmasına, uygun pozitiflik eşiğinin belirlenmesine, laboratuvar sonuçlarının kalitesinin izlenmesine, uygulayıcının gelişiminin izlenmesine ve farklı uygulayıcıların tanı etkinliklerinin karşılaştırılmasına olanak sağlar (Şekil 9).

En yaygın kullanılan ölçüm, ROC eğrisinin altında kalan alanı (Area Under Curve - AUC) hesaplamakla elde edilir. AUC, 0 ile 1 arasında değer alır ve 1'e ne kadar yakın ise testin başarısı o kadar yüksek demektir (85).



Şekil 9. ROC Eğrisi (Tomak'tan, 85)

4. BULGULAR

4.1. İstatistiksel Analiz Bulguları

Veri setinde, ilk yılın tamamlanmasının ardındaki son takipte gebe kalan 160, gebe kalamayan 140 olmak üzere toplamda 300 hastaya ait 32 değişken bulunmaktadır. Katılımcıların gebe elde etme (pozitif) ve gebelik elde edememe (negatif) durumları hipotez testleri ile karşılaştırılarak, demografik bulgular sayısal değişkenler için Tablo 7'deki, kategorik değişkenler için Tablo 8'deki gibi sunulmuştur.


Buna göre sayısal değişkenlere ait tanımlayıcı istatistikleri incelediğimizde; “yaş”, “vki”, “gece toplam uyku süresi”, “ayakta kalma süresi” değişkenleri açısından gebelik elde eden ve edemeyen katılımcılar arasında istatistiksel olarak anlamlı bir fark olduğu görülmüştür ($p<0.05$) (Tablo 7) ve bu değişkenlere ilişkin grafikler Şekil 10'da sunulmuştur. Kategorik değişkenlerine ait tanımlayıcı istatistiklerini incelediğimizde; “eğitim durumu” ve “hane geliri”, “D vitamini eksikliği”, “eş eğitim durumu”, “ek ilaç kullanımı”, “ek hastalık”, “regl siklus”, “yumurtlama testi”, “korunma yöntemi”, “folik asit kullanımı” ve “korunmayı bıraktıktan sonra ani kilo artışı” değişkenlerinin gebelik elde eden ve edemeyen katılımcılar arasında istatistiksel olarak anlamlı bir fark olduğu görülmüştür ($p<0.05$) (Tablo 8) ve bu değişkenlere ilişkin grafikler Şekil 11'deki gibi sunulmuştur.

Böylece toplamda 15 değişkenin gebelik elde etme açısından anlamlı bir fark oluşturduğu görülmüştür. Hipotez testlerine göre belirlenen bu 15 değişken, gebelik elde etme açısından risk ve şans faktörü olarak önemli değişkenler olarak dikkate alınabilirler.

Tablo 7. Sayısal değişkenlere ait tanımlayıcı istatistikler

	Gebelik Durumu (Pozitif=160)	Gebelik Durumu (Negatif=140)	
Sayısal Değişkenler	Medyan (Q1-Q3)	Medyan (Q1-Q3)	p
Yaş	29 (27-33)	32 (29-35)	<0.001*
VKİ	24.27 (22.18-26.80)	25.39 (22.64-28.87)	0.013*
Gece toplam uyku süresi (günde/saat)	8 (8-9)	8 (7-8)	<0.001*
Cinsel ilişki sıklığı (hafta)	2 (2-3)	2 (2-3)	0.879
Ayakta kalma süresi (günde/saat)	8 (6-9)	6 (4-8)	<0.001*
Eş (VKİ)	26.88 (24.83-29.37)	27.71 (25.50-29.99)	0.131

* $p<0.05$



Şekil 10. İstatistiksel açıdan anlamlı olan sayısal değişkenlere ait boxplot grafikleri


Tablo 8. Kategorik değişkenlere ait tanımlayıcı istatistikler

		Gebelik Durumu (Pozitif=160)	Gebelik Durumu (Negatif=140)	
Kategorik Değişkenler		n (%)	n (%)	p
Yaşam yeri	Yaşam yeri	49 (30.6)	48 (34.3)	0.457
	Kırsal	111 (69.4)	92 (65.7)	
Eğitim durumu	İlköğretim	3 (1.8)	19 (13.6)	<0.001*
	Lise	19 (11.9)	35 (25.0)	
	Önlisans/Lisans	111 (69.4)	78 (55.7)	
	Yüksek Lisans/Doktora	27 (16.9)	8 (5.7)	
Meslek	Kamu	49 (35.0)	63 (39.4)	0.073
	Özel	24 (17.1)	40 (25.0)	
	Ev Hanımı	67 (47.9)	57 (35.6)	
Hane geliri	Açlık sınırı	5 (3.1)	11 (7.9)	0.001*
	Açlık ve yoksulluk sınırı	72 (45.0)	87 (61.1)	
	Yoksulluk sınırı üstü	83 (51.9)	42 (30.0)	
17 yaş sonrası ani kilo artışı	Evet	80 (50)	81 (57.9)	0.173
	Hayır	80 (50)	59 (42.1)	
Korunmayı bıraktıktan sonra ani kilo artışı	Evet	20 (12.5)	38 (27.1)	0.001*
	Hayır	140 (87.5)	102 (72.9)	
Uyku saati	[21.00-23.00)	17 (10.6)	20 (14.3)	0.518
	(23.00-24.00]	53 (33.1)	49 (35.0)	
	(24+)	90 (56.3)	71 (50.7)	
Uykuya dalma süresi (dk)	15'den az	63 (39.4)	53 (37.9)	0.800
	16-30	73 (45.6)	62 (44.3)	
	31-60+	24 (15.0)	25 (17.9)	
Doğum yöntemi	Normal	41 (25.6)	31 (22.1)	0.631
	Sezaryen	14 (8.8)	16 (11.4)	
	Henüz doğum yok	105 (65.6)	93 (66.4)	
Sigara kullanımı	Evet	19 (12)	20 (14)	0.327
	Hayır	141 (88)	120 (86)	
Kahve tüketimi	Evet	104 (65.0)	93 (66.4)	0.795
	Hayır	56 (35.0)	47 (33.6)	
Alkol kullanımı	Evet	9 (5.6)	4 (2.9)	0.240
	Hayır	151 (94.4)	136 (97.1)	
Regl siklus	21 günden kısa	11 (8.1)	13 (7.9)	<0.001*
	21-35 gün	99 (86.9)	139 (70.7)	
	35 gün+	30 (5.0)	8 (21.4)	
Yumurtlama testi kullanımı	Evet	28 (17.5)	40 (28.6)	0.022*
	Hayır	132 (82.5)	100 (71.4)	
Yumurtlama günü hesabı için telefon uygulaması kullanımı	Evet	102 (63.7)	88 (62.9)	0.873
	Hayır	58 (36.3)	52 (37.1)	


Tablo 8. (Devam)

Korunma yöntemi	Geri çekme	78 (48.8)	47 (33.6)	0.001*
	Modern yöntem	56 (35.0)	45 (32.1)	
	Hiç korunmadı	26 (16.2)	48 (34.3)	
Kısırlık öyküsü	Var	9 (5.6)	10 (7.1)	0.590
	Yok	151 (94.4)	130 (92.9)	
Folik asit kullanımı	Evet	106 (66.3)	111 (79.3)	0.012*
	Hayır	54 (33.7)	29 (20.7)	
Ek ilaç kullanımı	Var	40 (25.0)	60 (42.9)	0.001*
	Yok	120 (75.0)	80 (57.1)	
Ek hastalık	Var	76 (47.5)	91 (65.0)	0.002*
	Yok	84 (52.5)	49 (35.0)	
D vitamini eksikliği	Evet	27 (16.9)	64 (45.7)	<0.001*
	Hayır	133 (83.1)	76 (54.3)	
Psikiyatrik tanı	Var	25 (15.6)	17 (12.1)	0.386
	Yok	135 (84.4)	123 (87.9)	
Eş (eğitim durumu)	İlköğretim	9 (5.6)	19 (13.6)	0.001*
	Lise	30 (18.8)	43 (30.7)	
	Önlisans/Lisans	95 (59.4)	67 (47.9)	
	Yüksek Lisans/Doktora	26 (16.2)	11 (7.8)	
Eş (sigara kullanımı)	Evet	68 (42.5)	61 (43.6)	0.852
	Hayır	92 (57.5)	79 (56.4)	
Eş (kahve tüketimi)	Evet	68 (42.5)	53 (37.9)	0.413
	Hayır	92 (57.5)	87 (62.1)	
Eş (alkol kullanımı)	Evet	16 (10.0)	10 (7.1)	0.380
	Hayır	144 (90.0)	130 (92.9)	

*p<0.05



Şekil 11. (Devam)



Şekil 11. İstatistiksel açıdan anlamlı olan kategorik değişkenlere ait grafikler

4.2. Öznitelik Seçimi Bulguları

Bölüm 4.1’de tanımlayıcı istatistikleri verilen, 300 katılımcı ve 32 değişkenden oluşan veri seti, öznitelik seçimi yöntemlerinden Boruta algoritması, rastgele orman (RF), tekrarlayan öznitelik elemesi (RFE), lojistik regresyon ve LASSO regresyon olmak üzere toplamda beş farklı algoritma ile analiz edildi. Bu algoritmaların her birinden elde edilen sonuçlar, ayrı ayrı aşağıdaki gibi özetlenmiştir.

4.2.1. Boruta Algoritması ile Belirlenen Önemli Değişkenler

Boruta algoritması sonuçlarının görüldüğü Şekil 12’ye göre, değişkenler önem sırasına göre dizilirse, sağ baştan yeşil plotlar onaylanan 9 değişkeni ve sarı plotlar 3 aday


(tentative) deęiřkeni ifade etmektedir. Buna gre Boruta algoritmasında, onaylanan 9 ve aday 3 olmak zere toplamda 12 deęiřken nemli bulunmuřtur ve deęiřkenler nem sırasına gre ařaęıdaki gibi sıralanmıřtır.

Onaylanan deęiřkenler:

- Gece toplam uyunan sre (gn/saat)
- VKİ
- D vitamini eksiklięi
- Yař
- Ayakta kalma sresi (gn/saat)
- Eęitim
- Regl siklus
- Hane geliri
- Korunma yntemi

Aday (Tentatives) Deęiřkenler:

- Meslek
- Korunmayı bıraktıktan sonra kilo artıřı
- Ek ila kullanımı




Şekil 12. Boruta algoritması ile belirlenen önemli değişkenler

4.2.2. Rastgele Orman Algoritması ile Belirlenen Önemli Değişkenler

Rastgele orman algoritması ile elde edilen ve gebelik durumu tahmini için önemli bulunan 10 değişken, Tablo 9’da gösterilmiştir. Burada hesaplanan ve veri kümesindeki sınıfları ayırt etme yeteneğinin ne kadar yüksek olduğunu gösteren mean decrease gini değerleri büyükten küçüğe sıralanmıştır. Mean decrease gini (gini azalmasının ortalama değeri) değeri için cutoff, Şekil 13’te de görüldüğü üzere yatay ekseninde kırılmanın başladığı 5 değeri üzerinden belirlenmiş ve dikey bir bordo çizgi ile önem sınırı gösterilmiştir. Buna göre önemli bulunan 10 değişken, 5 olan mean decrease gini değeri üzerindeki kırmızı dikey çizginin sağındaki alan içinde yer almaktadır.

Tablo 9. Gini değerine göre belirlenen önemli değişkenler

Değişkenler	Mean Decrease Gini
VKİ (BMI)	15.98
Gece toplam uyunan süre (gün/saat)	13.67
Yaş	13.18
Ayakta kalma süresi (günde/saat)	12.74
VKİ (Eş)	11.29
Eğitim durumu	7.39
Regl siklus	6.90
D vitamini eksikliği	6.15
Korunma yöntemi	5.28
Eğitim Durumu (Eş)	5.21




Şekil 13. Rastgele orman algoritması ile belirlenen önemli değişkenler

4.2.3. LASSO Regresyon Algoritması ile Belirlenen Önemli Değişkenler

LASSO regresyon analizinin sonuçları Şekil 14'teki gibidir. Burada görüldüğü üzere $\log \lambda$ değeri arttıkça katsayılar sıfıra yaklaşırken, düşük katkı sağlayan değişkenler model dışında bırakılarak modelin karmaşıklığı azaltılmaktadır. Düşük binom sapması (binomial deviance) değerleri ve artan lambda değerleri arasından optimum değerleri bulmak hedeflenir. İdeal değerler genellikle, lambda değerini artırdıkça katsayıların sıfıra

yaklaşmasını temsil eden çizgiler arasındaki denge noktasında bulunur. Bu aralıkta bulunan ve bağımlı değişkeni en iyi açıklayan 13 değişken sırasıyla aşağıdaki gibidir.

1. Yaş
2. VKİ (BMI)
3. Korunmayı bıraktıktan sonra kilo artışı
4. Gece toplam uyunan süre (gün/saat)
5. Ayakta kalma süresi (günde/saat)
6. Yumurtlama testi
7. Folik asit
8. Ek ilaç kullanımı
9. D vitamini eksikliği
10. Eğitim (ilköğretim/lise/lisansüstü)
11. Hane geliri (yoksulluk üstü)
12. Regl siklus (35 günden fazla)
13. Korunma yöntemi (geri çekme/ hiç korunmadı)




Şekil 14. LASSO regresyon algoritması ile belirlenen önemli değişkenler

4.2.4. Tekrarlayan Öznitelik Elemesi (RFE) ile Belirlenen Önemli Değişkenler

Şekil 15’te görüldüğü üzere öznitelik sayısının artmasıyla birlikte modelin performansının değişmektedir. Buna göre modelin optimum performansını sağlayan öznitelik sayısının belirlenirken, doğruluk (accuracy) oranının 11 değişken için pik yaptığı görülmektedir. Pik noktası da dahil olmak üzere, buraya kadarki 11 değişken bağımlı değişkeni (gebelik durumu: pozitif/negatif) en başarılı şekilde tahmin etmek için belirlenen değişkenler olup, diğer değişkenler çıkarılabilirler. Tekrarlayan öznitelik elemesi algoritmasına göre belirlenen değişkenler önem sırasına göre aşağıdaki gibidir.

Önemli bulunan 11 değişken;

1. Gece toplam uyunan Süre (gün/saat)
2. VKİ
3. Ayakta kalma süresi (günde/saat)
4. Yaş
5. D vitamini eksikliği
6. Eğitim durumu
7. Hane geliri
8. Regl siklus
9. Korunma yöntemi
10. Korunmasız kilo artımı
11. Ek ilaç kullanımı



Şekil 15. RFE algoritması ile belirlenen önemli değişkenler

4.2.5. Lojistik Regresyon Algoritması ile Belirlenen Önemli Değişkenler

Lojistik regresyon geriye doğrusal regresyon eleme yöntemi ile belirlenen değişkenler ve katsayıları Tablo 10’da özetlenmiştir.

Tablo 10. Lojistik regresyon analizi ile belirlenen önemli değişkenler

Değişkenler	Coefficient (β)	OR (95% CI)	p	H*
Yaş	-0.172	0.84 (0.76 - 0.93)	<0.001	0.564
Korunmayı bıraktıktan sonra kilo artımı	-1.07	0.34 (0.14 - 0.82)	0.016	
Eğitim durumu (lisans/önlisans)	3.09	21.94 (2.86 - 168.15)	0.002	
Eğitim durumu (lisansüstü)	4.72	112.52 (10.11-1252.77)	<0.001	
Gece toplam uyunan süre (saat)	0.538	2.45 (1.2 - 2.45)	0.003	
Regl siklus (28 günde bir)	-1.47	0.23 (0.06 - 0.95)	0.041	
Regl siklus (35 gün+)	-2.99	0.05 (0.01 - 0.28)	<0.001	
Yumurtlama testi	-1.17	0.31 (0.14 - 0.7)	0.004	
Ayakta kalma süresi (günde/saat)	0.187	1.21 (1.05 - 1.38)	0.007	
D vitamini eksikliği	-1.25	0.29 (0.11 - 0.73)	0.008	

$R^2 = 0.548$; $n = 300$; *Hosmer-Lemeshow uyum iyiliği (H) istatistiği;
 $p < 0.05$; Doğruluk: %81.7, Duyarlılık: %81.9, Özgünlük: %81.4.

Tablo 10'daki sonuçlara göre “yaş”, “korunmayı bıraktıktan sonraki kilo artımı”, “eğitim durumu”, “gece toplam uyuyan uyku süresi”, “regl siklus”, “yumurtlama testi kullanımı”, “ayakta kalma süresi” ve “D vitamini eksikliği” önemli değişkenler olarak belirlenmiştir.

Hosmer-Lemeshow test sonuçlarına göre son adım için uyum iyiliği istatistiği (H) 0.564 olarak elde edilmiş olup, modele dahil edilen değişkenlerin model için uyumlu olduğu görülmüştür. Son adım için Nagelkerke R² istatistiği 0.548 olarak elde edilmiştir. Modelin doğru sınıflama oranı %81.7 olarak elde edilmiştir. Denklemin duyarlılığı %81.9; özgüllüğü ise %81.4 olarak bulunmuştur. Son adımda kalan değişkenleri incelediğimizde, kurulan son lojistik regresyon modelindeki değişkenler arasında, en belirgin bir fark gösteren “eğitim durumu” olmuştur. “Eğitim durumu” önlisans/lisans ve lisansüstü olan katılımcıların (OR=21.94, [GA] (2.86-168.15); p=0.002 ve OR=112.52, [GA] (10.11-1252.77); p<0.001) gebe kalma odds'larının oldukça yüksek olduğu görülmüştür. Bu değişkeni, “uyku süresi” izlemektedir (OR=2.45, [GA] (1.2 -2.45); p=0.003) (Tablo 10).

Boruta algoritması, rastgele orman, tekrarlayan öznitelik elemesi (RFE), lojistik regresyon ve LASSO regresyon olmak üzere tüm öznitelik seçimi yöntemlerinin sonuçları Tablo 11'deki gibi birbirleriyle karşılaştırmalı olarak özetlenmiştir.

Tablo 11. Öznitelik seçim yöntemlerine göre anlamlı bulunan değişkenler

Değişkenler	Öznitelik Seçimi Yöntemleri				
	Boruta	Rastgele Orman (RF)	Tekrarlayan öznitelik elemesi (RFE)	LASSO Regresyon	Lojistik Regresyon (LR)
1. VKİ	*	*	*	*	-
2. Gece toplam uyku süresi	*	*	*	*	*
3. Yaş	*	*	*	*	*
4. Ayakta kalma süresi	*	*	*	*	*
5. Eş (VKİ)	-	*	-	-	-
6. Eğitim durumu	*	*	*	*	*
7. Regl siklus	*	*	*	*	*
8. D vitamini eksikliği	*	*	*	*	*
9. Korunma Yöntemi	*	*	*	*	*
10. Eş (Eğitim Durumu)	-	*	-	-	-
11. Yumurtlama testi	-	-	-	*	*
12. Folik asit kullanımı	-	-	-	*	-
13. Ek İlaç Kullanımı	*	-	*	*	-
14. Korunmayı Bıraktıktan Sonra Kilo Artımı	*	-	*	*	*
15. Hane Geliri	*	-	*	*	-

* Öznitelik seçim yöntemlerinde önemli bulunan değişkenler

Tablo 11’de görüldüğü üzere, öznitelik seçimi yöntemlerinin hepsinde en az bir kez önemli bulunan 15 değişken mevcuttur. Kullanılan beş algoritmanın hepsinde ortak öneme sahip 7 değişken; “uyku süresi”, “hareket süresi”, “eğitim durumu”, “regl siklus”, “korunma yöntemi”, “D vitamini eksikliği” ve “yaş” önemli değişkenler olarak belirlendi. Lojistik Regresyon haricinde diğer yöntemlerin dördünde de “VKİ” değişkeni önemli olarak bulundu. Rastgele orman (RF) algoritması haricinde diğer yöntemlerin hepsinde “korunmayı bıraktıktan sonra kilo artımı” değişkeni önemli olarak elde edildi. Bu sonuçlara göre Senaryo 1’e ek olarak, Senaryo 2 ve 3 olmak üzere iki ayrı değişken senaryosu daha oluşturuldu.

Senaryo 1’de öznitelik seçimi yapılmadan önceki tüm değişkenler kullanılmış olup, bu değişkenler Tablo 3’te sunuldu.

Senaryo 2’de öznitelik seçimi yöntemlerinin hepsinde en az bir kez önemli bulunan 15 değişken kullanıldı ve bu değişkenler Tablo 4’te sunuldu.

Senaryo 3’te ise, özellik seçimi yöntemlerinin hepsinde ortak öneme sahip 7 değişken ve RF, LR yöntemleri haricinde, Boruta, RFE ve LASSO yöntemlerinin hepsinde önemli bulunan 2 değişken (“VKİ” ve “korunmayı bıraktıktan sonra kilo artımı”) olmak üzere, toplamda 9 değişken kullanıldı ve bu değişkenler Tablo 5’te sunuldu.

4.3. Makine Öğrenmesi Modellerine Ait Bulgular

Öznitelik seçimi sonrasında tüm değişkenler (32 değişken), öznitelik seçimi yöntemlerinin hepsinde en az bir kez önemli bulunan 15 değişken ve hemen hepsinde ortak olarak yüksek öneme sahip 9 değişken olmak üzere oluşturulan üç farklı senaryo için, makine öğrenmesi algoritmalarından; CatBoost, XGBoost, rastgele orman (RF), naive Bayes ve DVM yöntemleri kullanılmıştır. Böylece üç farklı senaryo için, beş farklı karar destek modeli geliştirilmiştir. Senaryo 1, 2 ve 3’e ait sonuçlar sırasıyla Tablo 12-14’de verilmiştir.

Tablo 12. Senaryo 1’e göre geliştirilen tahmin modellerinin performans sonuçları

Algoritmalar	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Ölçütü	%95 (GA)
Naive Bayes	0.73	0.81	0.64	0.72	0.76	(0.63 - 0.82)
XGBoost	0.75	0.74	0.78	0.83	0.78	(0.65 - 0.84)
CatBoost	0.75	0.92	0.57	0.71	0.80	(0.65 - 0.84)
Rastgele Orman	0.72	0.79	0.64	0.72	0.75	(0.62 - 0.81)
DVM	0.73	0.83	0.62	0.71	0.77	(0.63 - 0.82)

Tablo 13. Senaryo 2’ye göre geliştirilen tahmin modellerinin performans sonuçları

Algoritmalar	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Ölçütü	%95 (GA)
Naive Bayes	0.77	0.81	0.71	0.76	0.78	(0.66 - 0.85)
XGBoost	0.81	0.77	0.88	0.91	0.84	(0.71 - 0.88)
CatBoost	0.75	0.81	0.69	0.75	0.78	(0.65 - 0.84)
Rastgele Orman	0.76	0.79	0.71	0.76	0.77	(0.65 - 0.84)
DVM	0.71	0.81	0.59	0.70	0.75	(0.60 - 0.80)

Tablo 14. Senaryo 3’e göre geliştirilen tahmin modellerinin performans sonuçları

Algoritmalar	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Ölçütü	%95 (GA)
Naive Bayes	0.80	0.90	0.68	0.76	0.82	(0.67 - 0.89)
XGBoost	0.77	0.74	0.82	0.87	0.80	(0.64 - 0.87)
CatBoost	0.80	0.90	0.68	0.76	0.83	(0.68 - 0.89)
Rastgele Orman	0.77	0.84	0.68	0.75	0.79	(0.64 - 0.87)
DVM	0.80	0.94	0.64	0.75	0.83	(0.68 - 0.89)

Üç senaryo tüm algoritmaların performansı açısından incelendiğinde, naive Bayes yöntemi için Senaryo 1’e ilişkin doğruluk ve duyarlılık performansı, Senaryo 2 ve Senaryo 3’e göre daha düşüktür, ancak özgüllük ve kesinlik sonuçları benzerdir (Tablo 12). Senaryo 2 ve Senaryo 3’te öz nitelik seçimi sonrası doğruluk ve duyarlılık artmakla birlikte, özellikle Senaryo 3’te duyarlılık önemli ölçüde yükselmiştir. Tablo 13-14’de görüldüğü üzere özgüllük ve kesinlik değerleri ise genellikle benzer seyretmiştir.

XGBoost, CatBoost ve rastgele orman (RF) algoritmaları sonuçlarına bakıldığında, Senaryo 1, Senaryo 2 ve Senaryo 3’e göre genel olarak daha düşük performans göstermiştir. Öz nitelik seçimi sonrası: Senaryo 2 ve Senaryo 3’te doğruluk ve özgüllük değerleri artmıştır. Duyarlılık ve kesinlik değerlerinin ise bazı durumlarda arttığı, bazılarında ise azaldığı görülmektedir.

DVM algoritmasında ise Senaryo 1, diğer algoritmalarda da olduğu gibi Senaryo 2 ve Senaryo 3’e göre genel olarak daha düşük performans göstermiştir. Senaryo 2 ve Senaryo 3’te doğruluk ve duyarlılık değerleri artarken, kesinlik değerinin bazı durumlarda arttığı, bazılarında azaldığı görülmüştür. Özgüllük değerleri ise genellikle benzer seyretmiştir.

Tüm algoritma sonuçları karşılaştırıldığında, üç senaryoda da en iyi performansı XGBoost algoritmasının gösterdiği görülmüştür. Buna göre, XGBoost algoritmasına ilişkin tüm senaryo sonuçları Tablo 15’te gösterilmiştir.

Tablo 15. XGBoost algoritmasının senaryolara göre performans karşılaştırması

Algoritmalar	Metrikler	Öznitelik seçimi Öncesi	Öznitelik seçimi Sonrası (15 değişken)	Öznitelik seçimi Sonrası (9 değişken)
		Senaryo 1	Senaryo 2	Senaryo 3
XGBoost	Doğruluk	0.75	0.81	0.77
	Duyarlılık	0.74	0.77	0.74
	Özgüllük	0.78	0.88	0.82
	Kesinlik	0.83	0.91	0.87
	F1 Ölçütü	0.78	0.84	0.80

Tablo 15’e göre XGBoost algoritmasının, üç senaryo arasından en iyi performansı Senaryo 2’de (Doğruluk = 0.81 Duyarlılık = 0.77 Özgüllük = 0.88 Kesinlik = 0.91 F1-Ölçütü = 0.84) gösterdiği görülmektedir. Buna göre optimizasyon öncesinde XGBoost algoritması aracılığıyla, üç senaryoya göre geliştirilen modeller arasında, 15 değişkenden oluşan Senaryo 2’nin, gebelik durumu tahmini için en başarılı performansı gösterdiği görülmektedir.

4.4. Hiper Parametre Optimizasyon Bulguları

Naive Bayes’te hiper parametre optimizasyonu tipik olarak, algoritma tarafından kullanılan temel olasılık dağılımları veya düzeltme teknikleriyle ilgili parametrelerin ayarlanmasını içerir. Bununla birlikte, naive Bayes nispeten basittir ve sınır ağları veya destek vektör makineleri gibi daha karmaşık algoritmalarla karşılaştırıldığında çoğu zaman ayarlanacak çok fazla hiper parametreye sahip değildir. Bu nedenle, naive Bayes yöntemi dışında kullanılan tüm makine öğrenmesi algoritmalarının tahmin performansının en iyi olduğu değerleri belirlemek için ızgara arama tekniği ile hiper parametre optimizasyonu yapıldı.

Rastgele orman (RF), XGBoost, CatBoost ve DVM algoritmalarının optimizasyonu için öncelikle modellerde kullanılan hiper parametrelere ilişkin değer kümeleri oluşturuldu. Bu modellere göre değer kümeleri sırasıyla Tablo 16-19’daki gibidir.

Ardından tanımlanan hiper parametre değer kümelerine göre modellerin tahmin performansları test seti üzerinde her üç senaryo için yeniden değerlendirildi ve en başarılı performansı veren hiper parametre optimum değerleri elde edildi (Tablo 20-23).

Tablo 16. RF algoritmasında optimizasyon için arama uzayında kullanılan hiper parametreler ve değer kümeleri

Hiperparametreler	Optimizasyon için kullanılan değer kümeleri
ntree	50, 100, 200, 500
mtry	5, 15, by = 2
nodesize	3, 9, by = 2
samplesize	.55, .632, .70, .80

Tablo 17. XGBoost algoritmasında optimizasyon için arama uzayında kullanılan hiper parametreler ve değer kümeleri

Hiperparametreler	Optimizasyon için kullanılan değer kümeleri
max depth	15, 29, by = 2
max leaves	63, 127, 255, 511, 1023, 2047, 4095
eta	0.1, 0.2, 0.3, 0.4, 0.5
iter	35, 55, by = 1

Tablo 18. CatBoost algoritmasında optimizasyon için arama uzayında kullanılan hiper parametreler ve değer kümeleri

Hiperparametreler	Optimizasyon için kullanılan değer kümeleri
depth	4, 6, 8, 10
learning rate	0.1, 0.01, 0.001
L2 leaf reg	0.1, 0.01 ve 0.001
Border count	32, 64, 128, 256
iter	10, 20, 30, 50

Tablo 19. DVM algoritmasında optimizasyon için arama uzayında kullanılan hiper parametreler ve değer kümeleri

Hiperparametreler	Optimizasyon için kullanılan değer kümeleri
cost	0.001, 0.01, 0.1, 1, 5, 10, 100
gamma	0.001, 0.01, 0.1, 1, 5, 10, 100

RF, XGBoost, CatBoost ve DVM algoritmalarında, her üç senaryo için kullanılan hiper parametrelere ilişkin optimizasyon sonucu elde edilen optimum değerler sırasıyla Tablo 20-23'teki gibi sunulmuştur.

Tablo 20. RF algoritması için elde edilen optimum hiper parametre değerleri

Hiper parametreler	Optimizasyon için kullanılan değerler		
	Senaryo 1	Senaryo 2	Senaryo 3
ntree	10	100	100
mtry	24	9	24
nodesize	5	9	9
sample size	0.55	0.55	0.55

Tablo 21. XGBoost algoritması için elde edilen optimum hiper parametre değerleri

Hiper parametreler	Optimizasyon için kullanılan değerler		
	Senaryo 1	Senaryo 2	Senaryo 3
max depth	17	10	25
max leaves	25	2047	1023
eta	0.5	0.3	0.3
iter	47	50	38

Tablo 22. CatBoost algoritması için elde edilen optimum hiper parametre değerleri

Hiper parametreler	Optimizasyon için kullanılan değerler		
	Senaryo 1	Senaryo 2	Senaryo 3
depth	10	10	10
learning rate	0.01	0.1	0.001
L2 leaf reg	0.1	0.01	0.001
border count	128	64	128
iter	30	50	50

Tablo 23. DVM algoritması için elde edilen optimum hiper parametre değerleri

Hiper parametreler	Optimizasyon için kullanılan değerler		
	Senaryo 1	Senaryo 2	Senaryo 3
cost	1	100	100
gamma	0.01	0.01	0.01

Hiper parametre optimizasyon yöntemi sonucunda elde edile optimum değerlere göre, her üç senaryo için modeller yeniden geliştirildi. Optimizasyon öncesinde elde edilen performans sonuçları (doğruluk, duyarlılık ve özgüllük) ile optimizasyon sonrasında elde edilen performans sonuçları Tablo 24'deki gibi kıyaslandı.



Tablo 24. Senaryo 1, 2 ve 3'e göre oluşturulan tahmin modellerinin hiper parametre optimizasyonu sonrasındaki performanslarının karşılaştırılması

Algoritmalar	Metrikler	Senaryo 1		Senaryo 2		Senaryo 3	
		Optimizasyon Öncesi	Optimizasyon Sonrası	Optimizasyon Öncesi	Optimizasyon Sonrası	Optimizasyon Öncesi	Optimizasyon Sonrası
Naive Bayes	Doğruluk	0.73	0.73	0.77	0.77	0.80	0.80
	Duyarlılık	0.81	0.81	0.81	0.81	0.90	0.90
	Özgüllük	0.64	0.64	0.71	0.71	0.68	0.68
XGBoost	Doğruluk	0.75	0.76	0.81	0.78	0.77	0.80
	Duyarlılık	0.74	0.78	0.77	0.80	0.74	0.81
	Özgüllük	0.78	0.73	0.88	0.75	0.82	0.78
CatBoost	Doğruluk	0.75	0.78	0.75	0.83	0.80	0.77
	Duyarlılık	0.92	0.90	0.81	0.90	0.90	0.94
	Özgüllük	0.57	0.64	0.69	0.76	0.68	0.57
Random Forest	Doğruluk	0.72	0.80	0.76	0.76	0.77	0.78
	Duyarlılık	0.79	0.85	0.79	0.77	0.84	0.84
	Özgüllük	0.64	0.74	0.71	0.74	0.68	0.71
DVM	Doğruluk	0.73	0.73	0.71	0.76	0.80	0.80
	Duyarlılık	0.83	0.85	0.81	0.81	0.94	0.91
	Özgüllük	0.62	0.60	0.59	0.71	0.64	0.68

Her üç senaryo için, optimizasyon öncesi ve sonrası performans sonuçları kıyaslanarak incelendiğinde; naive Bayes algoritmasına ilişkin bir optimizasyon yapılmadığından, herhangi bir fark bulunmamaktadır. Bununla birlikte diğer makine öğrenmesi algoritmalarının optimizasyon sonrası performans sonuçlarının genel olarak biraz daha arttığı görülmektedir. Özellikle CatBoost algoritmasının, Senaryo 2 kapsamında optimizasyon sonrası performans sonuçlarının önemli ölçüde artmıştır (Tablo 24).

Üç senaryonun geneline bakıldığında, Senaryo 2'deki tüm algoritmaların duyarlılık ve özgüllük değerlerinin diğer senaryolara nazaran daha dengeli bir yapıda olduğu görülmektedir. Senaryo 2'deki sonuçlar ile Senaryo 1 ve 3'teki sonuçları kıyaslayacak olursak; örneğin CatBoost algoritmasının duyarlılığı Senaryo 1'de %90 ve senaryo 3'te %94 olmak üzere yüksek seyrederken, özgüllüğü Senaryo 1'de %64 ve Senaryo 3'te %57 olmak üzere oldukça düşük seyretmiştir. Aynı durum DVM algoritması için de söz konusudur.

Yüksek duyarlılık, düşük özgüllük değerleri senaryo 1 ve 2 için ortalama olarak doğruluk oranlarında düşüklüğe sebep olmuştur. XGBoost algoritmasında, optimizasyon sonrasında doğruluk ve duyarlılık değerlerinde öznitelik seçimi sonrası (Senaryo 2 ve 3) iyileşme gösterdiğini ancak, özgüllük değerlerinde bir miktar azalma olduğu görülmektedir. Özellikle, doğruluk ve duyarlılık metriklerindeki artışlar, öznitelik seçimi yapıldıktan sonra modelin daha iyi tahminler yapabildiğini ve daha dengeli sonuçlar elde ettiğini göstermektedir. Ancak, özgüllük metriğindeki azalma ile XGBoost modelinin negatif sınıfı doğru bir şekilde sınıflama becerisinde bir düşüş olduğu söylenebilir.

Optimizasyon sonrası elde edilen sonuçlara göre, doğruluk, duyarlılık, özgüllük metriklerine dayalı olarak en iyi performansı gösteren makine öğrenmesi modelinin, Senaryo 2'de CatBoost algoritması olduğu görülmüştür (Doğruluk=0.83, Duyarlılık=0.90, Özgüllük=0.76). Buna en yakın performansların sırasıyla; Senaryo 1'de RF (Doğruluk=0.80, Duyarlılık=0.85, Özgüllük=0.74) ve Senaryo 3'te XGBoost (Doğruluk=0.80, Duyarlılık=0.81, Özgüllük=0.78) ile elde edildiği görülmektedir. CatBoost algoritmasında optimizasyon sonrasında, doğruluk ve özgüllük metriklerinde öznitelik seçimi sonrası (Senaryo 2 ve 3) iyileşme göstermektedir ancak, öznitelik seçimi öncesi (Senaryo 1) için duyarlılık değerinde az da olsa bir azalma olurken, özellikle özgüllük değerinde belirgin bir artış olduğu görülmektedir. Bu durum, CatBoost'un

öznitelik seçimi yapıldıktan sonraki yani Senaryo 2 ve 3'teki model performansını artırdığını ve daha spesifik tahminler yapabildiğini göstermektedir.

Rastgele orman algoritmasının, optimizasyon sonrasındaki doğruluk ve özgüllük metriklerinde, öznitelik seçimi sonrası (Senaryo 2 ve 3) genel bir iyileşme gösterdiği ancak, Senaryo 2'de duyarlılık metriğinde bir azalma olduğunu görülmektedir. Özellikle özgüllük metriğindeki artış, modelin negatif sınıfı doğru bir şekilde sınıflama becerisinde bir artış olduğunu ancak, duyarlılık metriğindeki azalma, modelin pozitif sınıfı doğru bir şekilde sınıflama becerisinde bir düşüş olduğunu göstermektedir.

Son olarak optimizasyon sonrasında DVM (Destek vektör makineleri) algoritmasındaki doğruluk ve özgüllük metrikleri incelendiğinde, öznitelik seçimi sonrasında genel bir iyileşme olurken, duyarlılık değerinde bir azalma olduğu görülmektedir. Özellikle özgüllük değerinde artış söz konusu olsa da duyarlılık değerindeki azalma sebebiyle, modelin pozitif sınıfı doğru bir şekilde sınıflama becerisinde bir düşüş olduğu çıkarılabilir (Tablo 24).


Makine öğrenmesi modelleri bulguları sonuçlarına dair son değerlendirmeye göre; öznitelik seçimi ve hiper parametre optimizasyonu sonrası üç farklı senaryoda geliştirilen beş farklı model geliştirilmiştir. Çalışmamızda gebe kalan katılımcıları tahmin etmek istediğiniz bir sınıflama problemini çözümlediğimizden, duyarlılık ve özgüllük arasındaki öncelikli tercih, problemi çözümleme amacınıza ve problem bağlamınıza bağlı olarak doğruluk değerini düşürmeyecek şekilde, dolayısıyla %70'in altına düşmeyen özgüllük değeri olmak üzere, duyarlılıktan yana olacaktır. Duyarlılık, gerçek pozitiflerin (gebe olanların doğru bir şekilde tahmin edilmesi) tüm pozitifler içindeki oranını ifade ettiğinden ve yanlış negatiflerin (gebe olanları kaçırılmasının) minimize edilmesi gerektiği durumlar için önemlidir.

Buna göre Tablo 20'deki optimizasyon sonrası elde edilen sonuçlara bakıldığında, doğruluk, duyarlılık, özgüllük metriklerine dayalı olarak optimum performansı gösteren makine öğrenmesi modelinin, Senaryo 2'deki CatBoost algoritması olduğu (Doğruluk=0.83, Duyarlılık=0.90, Özgüllük=0.76) tespit edilmiştir. Bu sonuçlar, optimizasyon öncesinde en iyi sonuç veren XGBoost algoritmasına göre (Doğruluk = 0.81 Duyarlılık = 0.77 Özgüllük = 0.88), optimizasyon sonrasında özellikle duyarlılık açısından çok daha iyi performans veren CatBoost algoritmasının, gebelik elde edip edememe açısından en iyi ayırt edici algoritma olduğu görülmüştür.

Bu aşamadan sonra, Senaryo 2’de optimum sonucu elde ettiğimiz CatBoost algoritmasının (Doğruluk=0.83, Duyarlılık=0.90, Özgüllük=0.76) tahmin sonuçları, “type = prob” argümanı ile olasılık tabanlı olarak dönüştürüldü. Böylece model çıktısında her bir sınıf için tahmin edilen ve her bir sınıfa ait olma olasılığını ifade eden olasılık değerleri elde edildi. Bu sonuca göre gebe kalma olasılığı “düşük”, “orta” ve “yüksek” şeklinde sınıflandırılarak çalışmamızdaki nihai tahmin modeli geliştirildi ve sonuçlar bölüm 4.6’da tüm ayrıntıları ile verildi.

4.5. Geliştirilen Modellerin Tahmin Performanslarının Karşılaştırılması


Üç farklı senaryo yaklaşımına ilişkin hiper parametre optimizasyonu sonrası geliştirilen makine öğrenmesi modellerine ait en başarılı sonuçlar Senaryo 2’de elde edilmiştir. Senaryo 2 kapsamında geliştirilen tahmin modellerine ilişkin ROC eğrileri karşılaştırması Şekil 16’da, performans metriklerinin grafiksel karşılaştırılması ise Şekil 17’de verilmiştir. Benzer şekilde, Senaryo 1 ve 3’e ilişkin grafikler de sırasıyla Ek 5-8’de sunulmuştur.



Şekil 16. Hiper parametre optimizasyonu sonrası Senaryo 2 kapsamında geliştirilen tahmin modellerine ait ROC eğrilerinin karşılaştırılması

ROC eğrisi altında kalan alan olarak ifade edilen AUC değeri, sınıflandırıcının performansına ilişkin bilgi verir; bu değer 0-1 arasında değişir ve 1'e ne kadar yakınsa sınıflandırıcının performansının o kadar iyi olduğunu göstermektedir. AUC değerinin 1 olması %100 doğru sınıflandırma anlamına gelmektedir. Buna göre, Şekil 16'da sunulan tahmin modellerinin AUC değerlerine bakıldığında, XGBoost algoritması ile geliştirilen modelin AUC değerinin 0.86 ile diğer dört modele göre daha yüksek olduğu görülmektedir. Buna en yakın AUC değeri 0.83 olarak CatBoost algoritması ile elde edilmiştir.

Naive Bayes, DVM ve RF algoritmaları kullanılarak geliştirilen tahmin modellerinin AUC değerleri sırasıyla; 0.76, 0.76 ve 0.75 olarak elde edilmiştir. Bu sonuçlar boost tabanlı algoritmalara göre daha düşüktür.



Şekil 17. Hiper parametre optimizasyonu sonrası Senaryo 2 kapsamında geliştirilen tahmin modellerine ait performans metriklerinin karşılaştırılması

Şekil 17 incelendiğinde; XGBoost ve CatBoost modellerinin diğer modellere göre daha iyi performans sergilediği görülmektedir. XGBoost'un doğruluğu %78, duyarlılığı %80, özgüllüğü %75 ve ROC-AUC değeri %86 ve CatBoost'un doğruluğu %83, duyarlılığı %90, özgüllüğü %76 ve ROC-AUC değeri %83 olarak elde edilmiştir. Bu iki model kıyaslandığında, XGBoost algoritmasının biraz daha yüksek ROC-AUC değerine sahip olmasına rağmen, özellikle duyarlılık açısından CatBoost algoritması %90 ile çok daha iyi sonuç vermiştir. İki algoritmanın da özgüllük değerlerinin birbirine oldukça yakın olduğu görülmektedir.

CatBoost algoritması, özellikle kategorik değişkenlerle doğrudan çalışabilen olasılık tabanlı bir sınıflayıcı olma özelliğiyle öne çıkan bir algoritmadır. Diğer birçok makine öğrenmesi algoritmasında kategorik değişkenleri öncelikle sayısal bir formata dönüştürmek gerekirken, CatBoost algoritması için bu tür bir ön işlem gerekmemektedir. Bu açıdan büyük oranda kategorik değişkenlerden oluşan veri setimiz için CatBoost algoritması ideal bir tercihtir denilebilir.

Sonuç olarak, elde edilen gebelik durumu tahmin modelleri arasından en başarılısı CatBoost algoritması ile geliştirilen tahmin modeli olarak seçilmiş ve sonrasında olasılıksal tahmin için bu model üzerinden işlemlere devam edilmiştir.

4.6. Geliştirilen En Başarılı Tahmin Modeline İlişkin Olasılıksal Yaklaşım

Makine öğrenmesi algoritmalarında tahmin sonuçları genellikle, “type = prob” argümanı ile sayısal olasılık değerleri olarak dönüştürülebilmektedir. Bu argüman, model çıktısına ilişkin her bir sınıfa ait tahmin değerlerini olasılıksal olarak vermektedir. Bu değerler her bir sınıfa ait olma olasılığını ifade etmektedir. Böylece modelin tahmin sonuçları olasılıksal olarak elde edilmektedir. Bu olasılık değeri 0 ile 1 arasında olup, her sınıf için ait olma olasılığını vermektedir. Bir örneğin belirli bir sınıfa ait olma olasılığı ne kadar yüksekse (1'e ne kadar yakın ise), o sınıfa ait olma ihtimali o kadar yüksek demektir. Burada amaç, gebe kalma/kalmama sınıfları için elde edilen olasılık değerleri kullanılarak katılımcıların gebe kalma durumunun “düşük”, “orta” ve “yüksek” olarak sınıflandırılmasıdır.

Bu amaçla en başarılı model olan CatBoost algoritmasına göre elde edilen tahmin sonuçları, “type = proba” argümanı ile olasılık değerlerine dönüştürüldü. Böylece model çıktısında her bir sınıf için tahmin edilen ve her bir sınıfa ait olma olasılığını ifade eden olasılık değerleri elde edildi. Örneğin, “gebe kaldı” sınıfı için bir örneğin olasılık değeri

0.7 ise bu durum, örneğin “gebe kaldı” sınıfına ait olma ihtimalinin %70 olduğunu gösterir. Tahmin edilen olasılıkların eşik değeri ile karşılaştırılması, sınıflama kararlarının alınmasına olanak tanır. Bu nedenle genellikle bir eşik değeri belirlenir (örneğin 0.5) ve eğer bir sınıfın olasılığı eşik değerinden büyükse, o sınıfa ait olma ihtimali olarak kabul edilir. Mesela bir katılımcının “gebe kaldı” sınıfına ait olma olasılığı eşik değerinden büyükse, o kişi “gebe kaldı” sınıfında tahmin edilir. Bu şekilde, her bir örneğin sınıflandırılması için olasılık değerleri kullanılarak karar verilir.

Bu aşamadan sonra elde edilen gebe kalma/kalmama sınıflarına ait olasılık değerlerinin, gebe kalma durumuna ilişkin “düşük”, “orta” ve “yüksek” sınıflarına dönüştürülebilmesi için uzman hekim değerlendirmesiyle, olasılık değeri eşit bir şekilde 3’e bölünerek ($1/3=0.33$) her bir sınıf için eşik değeri belirlendi. Böylece gebe kalma olasılığı 0.33 ve altındaki değerler “düşük” sınıf etiketi alırken, ~0.67 ve üzerindeki değerler “yüksek” ve 0.67 ile 0.33 arasında kalan değerler ise “orta” şeklinde sınıflandı.

CatBoost algoritması ile geliştirilen en başarılı tahmin modeline ilişkin test seti (n=90) üzerinde, “gebe kalamayan” ve “gebe kalan” katılımcılara ait gerçek durum ve tahmin sonuçları sırasıyla; Şekil 18-19’da verilmiştir.

	Gerçek Durum	Tahmin	Tahmine Göre Gebe Kalma Olasılığı
17	gebe kalamadı	gebe kalamadı	0.18
18	gebe kalamadı	gebe kalamadı	0.37
19	gebe kalamadı	gebe kalamadı	0.43
20	gebe kalamadı	gebe kalamadı	0.43
21	gebe kalamadı	gebe kalamadı	0.44
22	gebe kalamadı	gebe kalamadı	0.41
23	gebe kalamadı	gebe kalamadı	0.18
24	gebe kalamadı	gebe kalamadı	0.49
25	gebe kalamadı	gebe kalamadı	0.17
26	gebe kalamadı	gebe kalamadı	0.11
27	gebe kalamadı	gebe kalamadı	0.15
28	gebe kalamadı	gebe kalamadı	0.31
29	gebe kalamadı	gebe kalamadı	0.06
30	gebe kalamadı	gebe kaldı	0.83


Şekil 18. Geliştirilen en başarılı modelin “gebe kalamadı” sınıfına ait katılımcılara ilişkin tahmin sonuçları ve olasılık değerleri

	Gerçek Durum	Tahmin	Tahmine Göre Gebe Kalma Olasılığı
68	gebe kaldı	gebe kaldı	0.83
69	gebe kaldı	gebe kaldı	0.94
70	gebe kaldı	gebe kaldı	0.92
71	gebe kaldı	gebe kaldı	0.83
72	gebe kaldı	gebe kaldı	0.75
73	gebe kaldı	gebe kaldı	0.85
74	gebe kaldı	gebe kaldı	0.92
75	gebe kaldı	gebe kaldı	0.69
76	gebe kaldı	gebe kaldı	0.88
77	gebe kaldı	gebe kaldı	0.69
78	gebe kaldı	gebe kaldı	0.75
79	gebe kaldı	gebe kaldı	0.86
80	gebe kaldı	gebe kaldı	0.97

Şekil 19. Geliştirilen en başarılı modelin “gebe kaldı” sınıfına ait katılımcılara ilişkin tahmin sonuçları ve olasılık değerleri

Şekil 18 incelendiğinde, “gebe kalamadı” sınıfına ait gerçek durum ve tahmin sonuçlarının çoğunlukla tutarlı seyrettiği ve olasılık değerlerinin düşük olduğu görülmektedir. Şekil 19’da ise, “gebe kaldı” sınıfına ait gerçek ve tahmin sonuçlarının aynı olduğu ve yüksek seyrettiği görülmektedir.

Gebe kaldı sınıfı için olasılık değerleri üzerinden elde edilen sonuçlar, Şekil 20’de sunulan algoritma ile “düşük”, “orta” ve “yüksek” şeklinde sınıflara ayrılmıştır. Böylece, geliştirilen karar destek sistemi yardımıyla katılımcının gebe kalma durumu “düşük”, “orta” veya “yüksek” şeklinde tahmin edilebilecektir.



Şekil 20. Gebe kalma olasılık değerlerinin “düşük”, “orta” ve “yüksek” sınıflarına dönüştürülmesine ilişkin algoritma akış diyagramı

CatBoost algoritması ile geliştirilen en başarılı tahmin modeline ilişkin test seti (n=90) üzerinde, gerçekte “gebe kalamayan” ve “gebe kalan” katılımcılara ait tahmin olasılıkları Şekil 20’deki algoritma ile “düşük”, “orta” ve “yüksek” sınıflarına dönüştürüldü ve elde edilen sonuçlar sırasıyla Şekil 21-22’de verildi.

	Gerçek Durum	Tahmin	Tahmine Göre Gebe Kalma Olasılığı	Tahmine Göre Gebe Kalma Olasılık Sınıfı
17	gebe kalamadı	gebe kalamadı	0.18	Düşük
18	gebe kalamadı	gebe kalamadı	0.37	Orta
19	gebe kalamadı	gebe kalamadı	0.43	Orta
20	gebe kalamadı	gebe kalamadı	0.43	Orta
21	gebe kalamadı	gebe kalamadı	0.44	Orta
22	gebe kalamadı	gebe kalamadı	0.41	Orta
23	gebe kalamadı	gebe kalamadı	0.18	Düşük
24	gebe kalamadı	gebe kalamadı	0.49	Orta
25	gebe kalamadı	gebe kalamadı	0.17	Düşük
26	gebe kalamadı	gebe kalamadı	0.11	Düşük
27	gebe kalamadı	gebe kalamadı	0.15	Düşük
28	gebe kalamadı	gebe kalamadı	0.31	Düşük
29	gebe kalamadı	gebe kalamadı	0.06	Düşük
30	gebe kalamadı	gebe kaldı	0.83	Yüksek

Şekil 21. Geliştirilen en başarılı modelin “gebe kalamadı” sınıfına ait katılımcılara ilişkin gebe kalma olasılığı tahmin sonuçları

	Gerçek Durum	Tahmin	Tahmine Göre Gebe Kalma Olasılığı	Tahmine Göre Gebe Kalma Olasılık Sınıfı
68	gebe kaldı	gebe kaldı	0.83	Yüksek
69	gebe kaldı	gebe kaldı	0.94	Yüksek
70	gebe kaldı	gebe kaldı	0.92	Yüksek
71	gebe kaldı	gebe kaldı	0.83	Yüksek
72	gebe kaldı	gebe kaldı	0.75	Yüksek
73	gebe kaldı	gebe kaldı	0.85	Yüksek
74	gebe kaldı	gebe kaldı	0.92	Yüksek
75	gebe kaldı	gebe kaldı	0.69	Yüksek
76	gebe kaldı	gebe kaldı	0.88	Yüksek
77	gebe kaldı	gebe kaldı	0.69	Yüksek
78	gebe kaldı	gebe kaldı	0.75	Yüksek
79	gebe kaldı	gebe kaldı	0.86	Yüksek
80	gebe kaldı	gebe kaldı	0.97	Yüksek

Şekil 22. Geliştirilen en başarılı modelin “gebe kaldı” sınıfına ait katılımcılara ilişkin gebe kalma olasılığı tahmin sonuçları


Şekil 21’deki “gebe kalamadı” sınıfına ait katılımcılara ilişkin olarak, gebe kalma durumuna dair kesitsel olarak verilen gerçek durum ve tahmin sonuçlarında görüldüğü üzere; 19, 20, 21, 22 ve 24. satırlarda yer alan katılımcılara ilişkin “gebe kalamadı” sınıfı için gerçek durum ve tahmin sonuçları aynıdır ve bu katılımcıların gebe kalma olasılıkları

0.33'ün üzerinde seyretmiş ve orta sınıfa dahil olmuşlardır. Buna göre bu katılımcılar için, ileride gebelik elde etme ihtimalleri vardır denilebilir. Şekil 21'deki "gebe kalamadı" sınıfına ait doğru tahmin sonuçları incelendiğinde ise; 17, 25, 26, 27, 28 ve 29. satırlarda yer alan katılımcıların gebe kalma olasılıkları 0.33'ün altında seyrettiği ve "düşük" sınıfa dahil oldukları görülmektedir. Buna göre, düşük gebelik ihtimali olan ve infertil olması muhtemel olan bu olguların tespit edilmesi ve erken tedaviye başlanabilmesi için uzman hekim tarafından gebe kalma süreci planlanabilir.

Şekil 22'deki "gebe kaldı" sınıfına ait katılımcılara ilişkin gebe kalma durumu kesitsel tahmin sonuçlarına bakıldığında ise, gerçek durum ve tahmin sonuçlarının hepsinin aynı olduğu ve tahmine göre tüm gebelik durumlarının "yüksek" (%67'nin üstünde) sınıfa dahil olduğu görülmektedir.

Nihayetinde, elde edilen tüm bu sonuçlara göre tahmine ait olasılık değerleri üzerinden üç sınıf oluşturuldu ve gebe kalma olasılığı; "düşük", "orta" ve "yüksek" şeklinde sınıflandırılarak, gebe kalma olasılığına ilişkin başarılı bir tahmin modeli geliştirildi.

Test veri setindeki 90 katılımcının, olasılık tabanlı elde edilen tahmine göre 24'ü düşük, 20'si orta ve 46'sı yüksek olarak sınıflandırılmıştır. Bu sınıflara ait gebe kalma durumu değerlendirmesi Şekil 23'te özetlenmiştir.



Şekil 23. Düşük, orta ve yüksek grup sınıflandırmalarına dair gebelik durumunun değerlendirilmesi

5. TARTIŞMA ve SONUÇ

Bu tez çalışmasında, kümülatif konsepsiyon olasılık tahmininde kullanılabilecek basit, hızlı, düşük maliyetli ve kolay ulaşılabilir bir tahmin modeli geliştirilmesi planlanmıştır. Bu doğrultuda, fertilité (doğurganlık) açısından risk ve şans faktörleri olan çiftlerin erken tanınmasını sağlamak adına gebelik planlayan bir kadının henüz gebelik öncesi aşamadayken, makine öğrenmesi yöntemleri aracılığıyla gebe kalma olasılığını “düşük”, “orta” ve “yüksek” şeklinde iyi bir duyarlılık seviyesinde sınıflandırabilecek non-invaziv (girişimsel olmayan), ucuz ve etkili bir tahmin modeli geliştirmek amaçlanmıştır. Ayrıca bu çalışma aracılığı ile spontan gebelik şansı düşük olan ve infertilite (kısırlık) açısından risk faktörü taşıyan çiftlerin erken tanınmasını sağlanarak, hekimlere süreci planlamada yardımcı olabilecek bir karar destek sistemi geliştirilmiştir.

Bu amaçla yapılan prospektif tez çalışmasında onamları alınan 300 katılımcıya, kayıt sırasında bir soru formu doldurtuldu ve katılımcılar gebe kalana kadar 2 ayda bir olmak üzere 12 ay süresince gebelik açısından takip edildiler. Elde edilen veriler aracılığıyla, henüz gebelik öncesi aşamadayken, istatistiksel öznitelik seçimi yöntemleri kullanılarak, gebelik ile ilişkili olan etkin risk ve şans faktörleri belirlendi. Sonrasında üç farklı senaryo yaklaşımı geliştirilerek daha kapsamlı bir analiz yapıldı ve sonuçlar karşılaştırıldı. Ardından, bu senaryolar üzerinde makine öğrenmesi yöntemleri kullanılarak tahmin modelleri geliştirildi ve en yüksek performansı gösteren model belirlendi.

Son 30 yılda kadınlar, eğitim, sosyal ve ekonomik nedenlerle çocuk sahibi olmayı geciktirmektedirler. İleri yaşta anne olma (35 yaş ve üstü), prematüre doğum, düşük doğum ağırlığı, ölü doğum, kromozomal anomaliler ve doğum komplikasyonları gibi riskleri beraberinde getirmektedir (86). Aynı zamanda dünya çapında milyonlarca bireyi ve çifti etkileyen üreme sistemi sorunlarından kaynaklanan infertilite, düşük ve orta gelirli ülkelerde genellikle yüksek maliyetler ve finansman eksikliği nedeniyle ulaşılamaz hale gelmektedir (87). Çocuk sahibi olamamak, çiftlerden birinin tıbbi tedaviye ihtiyacı olsa bile her iki tarafı da etkileyen tıbbi bir durumdur. Bu durum, psikolojik ve mali kaynakları tüketen ve önemli miktarda zaman, para, fiziksel ve duygusal enerji harcamayı gerektiren bir süreçtir. Evlendikten sonra, hemen hemen tüm çiftler belirli bir zamanda kendi çocuklarına sahip olmayı isteseler de, kadınların ne zaman hamile kalacağını öngörmek çok mümkün değildir. İnsanlar, modern tıbbın kısırlık tedavisi de dahil olmak üzere, bazı alanlarda yetersiz kaldığına yönelik bir inanca sahip olabilmektedirler (88). Bu bağlamda

infertilite tedavilerinin kadınlar üzerindeki psikopatolojik etkileri de dikkate değerdir. İnfertilite tedavisi için alınan hormonal ilaçlar, kadınların ruh haline etki ederek psikotik bozukluklarına neden olabilmektedir (89). Doğurganlık tedavileri, tıbbi izlemeden hormonal ilaçlara ve in vitro fertilizasyona (IVF) kadar çeşitli yöntemleri içermektedir ve bu durum, kadınlar ve partnerleri için hem fiziksel hem de duygusal açıdan zorlayıcı olabilmektedir. Depresyon, durum kaygısı ve stres gibi psikolojik faktörlerin başarılı gebelik elde etme olasılığını azaltabileceği düşünülmektedir. Çocuk sahibi olmak isteyen çiftler, eğer hamile kalma durumu beklenenden daha uzun sürerse hayal kırıklığı yaşayabilmektedirler. Ayrıca kısırlık tanı ve tedavisi, bireylerde psikolojik sıkıntılara neden olabilmektedir. Psikolojik faktörler, kısırlık risk faktörü sayılabilmektedir. Psikolojik durumlar ve kısırlık arasında karşılıklı etkileşim için üç tür ilişki tanımlanmıştır. Bu ilişkiler gözden geçirilerek kısırlık tedavisine alternatif bir yaklaşım önerilmektedir (90). Ayrıca tıbbi literatürde idiyopatik kısırlık denilen ve çiftlerin doğurganlık sorunlarına neden olan herhangi bir tıbbi veya anatomik sorunu tespit edilemezken hamilelik elde edememesine yol açan bir tür kısırlık durumu söz konusudur. İdiyopatik kısırlıkta çiftler, tıbbi muayenelerde ve testlerde normal sonuçlar gösterirken, yine de hamilelik elde etmede başarısız olabilmektedirler. İdiyopatik kısırlıkta çiftler belli bir süre sonra çeşitli tıbbi veya yardımcı üreme teknikleriyle tedaviye yönlendirilebilmektedirler (91).

Bunların yanı sıra gebelik planlayan kadınların birçoğu infertilite risk faktörlerini farkında olmadıklarından, gebelik öncesi dönemde hekime başvurmamaktadırlar. Bu da özellikle fertilitiyi etkileyen risk faktörlerine sahip olan çiftlerin tanı ve tedavisinde gecikmeye neden olmaktadır. Her çiftin tedavisiz gebe kalma olasılığı olduğundan, gebelik planlayan çiftlerin doğal yollardan gebe kalma ihtimalini önceden bilmeleri, klinik değerlendirmeye tedavi ihtiyacı oluşturabilecek bir patoloji olup olmadığının öğrenilmesini ve tedaviye erkenden başlanılmasını sağlayabilmektedir. Erken başvuru bazen, gereksiz tedavi ve tetkiklere ve de strese maruz kalmak gibi nedenlerle sorun olabilirken, bazen de uzun yıllar hekime gidilmemesi zaman kaybedilmesine ve neticede durumun ciddi bir sağlık problemi haline gelmesine sebep olabilmektedir. Bu açıdan gebe kalmayı planlayan bir çiftin hekime başvurma zamanlamasını önceden belirlemesi oldukça önemlidir. Tüm bunlar göz önüne alındığında, gebelik elde etme ihtimalini araştıran ve bu yöntemle spontan gebelik olasılığı düşük olan ve infertilite için risk faktörleri taşıyan çiftlerin erken tanınmasını sağlayacak non-invaziv, ucuz ve etkili tahmin modellerinin geliştirilmesi önem arz etmektedir.

Literatürde, makine öğrenmesi yöntemleri ve klasik istatistiksel yaklaşımlar kullanılarak fertilite ve kümülatif konsepsiyon ile ilgili yapılan çalışmalarda, genellikle infertilite riskinin temel alındığı veya demografik verilerle birlikte biyokimyasal belirteçlerin de kullanıldığı görülmektedir. Bununla birlikte, yine aynı yöntemlerle gebelik planlaması için mobil uygulamalarının geliştirildiği görülmüştür. Risk faktörlerinin tek başına fertilite ve infertilite üzerine olan etkilerini araştıran birçok çalışma mevcut iken, literatürde henüz gebelik öncesi aşamadayken birden fazla risk faktörünün kümülatif konsepsiyon ihtimali üzerindeki etkisini araştıran, yapay zekâ yaklaşımı ile yapılan sadece bir çalışmaya rastlanmıştır. Literatürdeki bu boşluğa istinaden yapılan prospektif tez çalışmasında, katılımcılara ait demografik, yaşam tarzı, davranışsal faktörler, tıbbi ve üreme geçmişleri ile ilgili özelliklere dayalı olarak elde edilen veriler kullanılarak, herhangi bir biyokimyasal belirteç olmaksızın gebe kalma olasılığına ilişkin non-invaziv, ucuz ve etkili bir tahmin modeli geliştirilmiştir.

Gebelik (konsepsiyon) tahmini için, fertilite/infertilite'yi etkileyen şans ve risk faktörleri ile ilgili yapılan çalışmalar incelendiğinde; Jennings ve arkadaşları tarafından 2019 yılında yapılan bir çalışmada, çalışmamızda olduğu gibi doğurganlık tahmini ve gebelik planlaması üzerine odaklanılmış ve istatistiksel analizler kullanılarak doğurganlık üzerine etki eden faktörler incelenmiştir. Kullanıcıları “düşük” ve “yüksek” doğurganlık günleri hakkında bilgilendiren “dinamik optimal zamanlama (dot)” adını verdikleri akıllı bir telefon uygulaması geliştirilmiştir. Uygulamanın kullanım etkinliği ile ilgili güven aralıkları Kaplan Meir sağkalım analizi ile belirlenmiş ve kusursuz kullanım başarısızlık oranı %1.0 (%95 CI: %0.9-%2.9); tipik kullanım başarısızlık oranı 18-39 yaş arası kadınlar için %5.8 (%95 CI: %3.57-%8.09) olarak hesaplanmıştır (92).

Dennis ve arkadaşları 2023 yılında, Kanadalı 928 kadın arasında gebelik öncesi sağlık bilgisinin belirleyiciliğine ilişkin yaptıkları kesitsel bir çalışmada, regresyon analizi kullanarak gebelik planlayan ailelerde gelir, göç durumu, düşük/doğmamış çocuk öyküsü ve gebelik öncesi sağlık bakımının önemli olduğu tespit etmişlerdir (93). Çalışmamızda olduğu gibi, bu çalışmada da gebelik planlayan kadınların sağlık ve demografik faktörleri incelenmiştir.

Boedt ve arkadaşlarının 2021 yılında Cochrane kütüphanesi tarafından önerilen standart metodolojik prosedürleri kullanarak yaptıkları bir derlemede, çalışmamızda olduğu gibi gebelik ve doğurganlık üzerine yaşam tarzı ve sağlık faktörlerinin etkisini

incelemiş ve infertiliteye sahip bireylerin prekonsepsiyon dönemde yaşam tarzı tavsiyelerine göre fertilité sonuçlarını ve yaşam tarzı davranış deęişiklikleri üzerindeki güvenilirliğini ve etkinliğini deęerlendirmişlerdir. Buna göre prekonsepsiyonel saęlık bakımının önemi için mevcut kanıtlar ele alınmış, belirli yaşam tarzı ve beslenme müdahaleleri tanımlanmış, kısırlık tedavisinden önce tıbben karmaşık hastanın bakımı tartışılmıştır (94).

Stanford ve arkadaşlarının 2020 yılında yaptıkları bir çalışmada, kadınların mobil hesaplama uygulamaları kullanmalarının, çocuk sahibi olmaya çalışan kadınlar arasındaki doğurganlık üzerinde olumlu bir etkiye sahip olup olmadığını araştırılmıştır. Araştırmacılar, gebelik olasılığı oranını (fecundability ratio) tahmin etmek için oransal olasılık regresyon modelleri (proportional probability regression models) ile kadınlara ait, “yaş, ırk/etnik köken, önceki gebelik, VKİ, gelir, mevcut sigara içme durumu, eğitim, partner eğitimi, kafein alımı, hormonal doğum kontrol yöntemi kullanımı, gece başına uyku saatleri, adet döngüsü düzenlilięi, gebelik öncesi dönemde takviyelerin kullanımı, medeni durum, cinsel ilişki sıklığı ve subfertilite öyküsü gibi bir dizi deęişkeni ele almışlardır. Sonuç olarak gebe kalmaya çalışan çiftlerde, buna ilişkin mobil uygulama kullanımının döngü başına gebelik olasılığını yaklaşık %12-20 oranında artırabildięi görülmüştür (95). Benzer olarak bizim çalışmamızda da mobil uygulama kullanımının doğurganlık üzerine etkisi incelenmiştir.

Yland ve arkadaşları tarafından prospektif olarak yapılan kohort bir çalışmada, ABD veya Kanada'da yaşayan, 21-45 yaş arası, doğurganlık tedavisi kullanmayan ve henüz doğum yapmayan 4133 kadın katılımcının verileri kullanılarak, hamilelik olasılıęının 6 ve 12 adet döngü boyunca kümülatif gebelik olasılıęını (her adet döngüsünde gebe kalma olasılıęı) tahmin etmek için denetimli makine öğrenmesi yöntemlerinden lojistic regresyon, destek vektör makineleri (DVM), hafif gradyan artırma makinesi (LightGBM) ve yapay sinir aęları (ANNs) kullanarak üç tahmin modeli geliştirilmiştir. Model I: Hamilelik denemesi süresi içinde 12 adet süresinden az, model II: Hamilelik denemesi süresi içinde 6 adet süresinden az ve model III: Cox modelleri kullanılarak her adet döngüsü için hamilelik olasılıęını tahmini etmek üzere, toplamda üç model geliştirilmiştir. Model III, doğurganlık üzerine odaklanmıştır ve sonuçlar, tam model ve basitleştirilmiş model olmak üzere iki farklı yaklaşımla sunulmuştur. Tam modelde, istatistiksel özellik seçimi yapılmıştır ve en etkili deęişkenler belirlenmiştir.

Basitleştirilmiş modelde ise, her bir değişkenin tek başına Cox modeline uygulanarak en iyi uyum indeksine sahip olan değişkenlerin seçilmesiyle hamilelik olasılığını etkileyen önemli değişkenler belirlenmiştir (8).

Yland ve arkadaşları bu çalışmada, yinelemeli öznitelik elemesi yapıldıktan sonra elde ettikleri nihai modellerde sırasıyla; Model I ve Model II için 14 ve 15 değişken kullandılar. Model I ve Model II için 0.70 ve 0.66 AUC değerleri elde edilmiştir. 15 değişken içeren Model III için ise, %63 uyum indeksi elde etmişlerdir. Katılımcılardan, temel çizelgede sosyodemografik faktörler, yaşam tarzı ve davranışsal faktörler, diyet kalitesi, tıbbi geçmiş ve seçilmiş erkek eş özellikleri hakkında verileri toplanılmıştır. Tüm modellerde hamilelikle pozitif ilişkilendirilen tahmin ediciler, “daha önce bir bebeği emzirmek” ve “multivitamin veya folik asit takviyeleri kullanmak” idi. Tüm modellerde hamilelikle ters ilişkilendirilen tahmin ediciler; “kadın yaş”, “kadın vücut kitle indeksi” ve “infertilite geçmişi” idi. İnfertilite geçmişi olmayan kadınlar arasındaki en önemli tahmin ediciler ise “kadın yaş”, “kadın vücut kitle indeksi”, “erkek vücut kitle indeksi”, “doğurganlık uygulaması kullanımı”, “hamile kalmayı deneme süresi” ve “algılanan stres” olarak tespit edilmiştir (8).

Yland ve arkadaşları tarafından yapılan bu prospektif çalışmada, tez çalışmamız ile benzer olarak sosyodemografik faktörler, yaşam tarzı ve davranışsal faktörler, tıbbi geçmiş ve erkek eş özelliklerine dair değişkenleri, farklı olarak Yland ve arkadaşları diyet kalitesi değişkenini kullanmış ve logistic regresyon, destek vektör makineleri (DVM), hafif gradyan artırma makinesi (LightGBM) ve yapay sinir ağları (ANNs) makine öğrenmesi algoritmaları kullanılarak, kümülatif gebelik olasılığı tahmini için en iyi sonuç olarak %70 AUC değeri elde edilmiştir. Yapılan tez çalışmamızda ise farklı olarak CatBoost, XGBoost, rastgele orman ve naive Bayes algoritmaları kullanılmış ve gebe kalma durumu tahmini için %83 ile daha yüksek bir AUC değeri elde edilmiştir. Bununla birlikte gebelik olasılığı “düşük”, “orta” ve “yüksek” olarak gruplanmıştır.

Yapılan doktora tez çalışmasının ilk aşamasında 300 katılımcıya uygulanan soru formunda mevcut olan 51 değişken arasından, uzman hekim görüşü de alınarak çoklu bağıntılılık sonucu yüksek korelasyon gösteren, bazı değişkenlere ilişkin doğru bilgi alınamaması, eksik verilerin fazla olması ve yanlışlık sebebiyle 19 değişken veri ön işleme aşamasında çalışmadan çıkarılan 19 değişken arasından; “oturularak geçirilen süre” ve “hareket süresi” değişkenleri negatif yönde yüksek korelasyon gösterdiğinden ($r=0.916$),

çoklu bağıntılılık problemi oluştu ve uzman görüşü ile “oturma süresi” elenerek, “hareket süresi” değişkeni tercih edildi. 51 değişken arasından eleme sonrası kalan 32 değişkenden oluşan veri seti için, hipotez testleri sonucuna göre gebe kalan ve kalamayan katılımcılar arasında istatistiksel olarak anlamlı farklar tespit edildi. Buna göre katılımcılara ait sayısal değişkenlerden, “yaş, vki, gece toplam uyku süresi, ayakta kalma süresi” ve kategorik değişkenlerden, “eğitim durumu, hane geliri, korunmayı bıraktıktan sonra ani kilo artışı, regl siklus, yumurtlama testi kullanımı, korunma yöntemi, folik asit kullanımı, ek ilaç kullanımı, ek hastalık, D vitamini eksikliği, eş eğitim durumu” olmak üzere toplamda 15 değişkenin gebelik elde eden ve edemeyen katılımcılar arasında istatistiksel olarak anlamlı bir fark oluşturduğu saptandı ($p<0.05$).

Hipotez testleri sonucunda anlamlı olarak elde edilen 15 değişken ile öznitelik seçimi metotlarının hepsinde en az bir kez önemli bulunan 15 değişken arasından, 14’ünün ortak değişkenler olduğu görüldü. Buradaki tek fark; hipotez testlerinde önemli bulunan “ek hastalık” değişkeni iken, öznitelik seçimi sonuçlarında önemli olarak tespit edilen “eş vki” değişkeni idi. Bu iki değişken haricindeki tüm değişkenlerin hem hipotez testlerinde hem de öznitelik seçimi yöntemlerinde ortak olarak önemli bulunması, başlangıçtaki değişken seçimi açısından validasyonu kuvvetlendirmektedir.

Yapılan çalışmada, gebelik olasılığı tahmini için geliştirilen en başarılı model, %90 doğruluk, %76 özgüllük ve 0.83 AUC değerleri ile CatBoost algoritması olarak elde edilmiş ve gebe kalma olasılığını, henüz gebelik öncesi aşamadayken, “düşük”, “orta” ve “yüksek” şeklinde iyi bir duyarlılık seviyesinde sınıflandırılmıştır.

Elde edilen bu nihai tahmin modeline göre, orta ve düşük gebelik ihtimali olan katılımcıların direkt hekime yönlendirilmesinin yanı sıra, gebelik olasılığı “orta” olanları psikolojik olarak kısırlık şüphesiyle keskin bir sınıra sokmamak adına, gebelik olasılığı “orta” şeklinde bir grubun daha olması sağlandı. Böylece gebelik olasılığı yüksek olan kadınlara uzman hekim kararı ile, gereksiz tedavi maliyetinden kaçınması, gebelik elde etme konusunda kaygı hissetmemesi ve gebelik elde etme sürecine ilişkin biraz daha bekleme tavsiyesi verilebileceği düşünüldü. Düşük gebelik ihtimali olan ve infertil olması muhtemel olan olguların ise, erken dönemde tespit edilmesi ve erken tedaviye başlanabilmesi için uzman hekim tarafından gebe kalma sürecinin planlanabileceği öngörüldü.

Bu tez çalışması gebelik isteyen bir kadının, henüz gebelik öncesi aşamadayken makine öğrenmesi yöntemlerini kullanılarak gebe kalma olasılığının başarılı bir şekilde tahmin edilmesi adına önemli bir adımdır. Geliştirilen bu karar destek sistemi, yapay zekâ aracılığıyla hekimlerin doğurganlık planlaması ve infertilite tedavisi gibi alanlarda erken müdahalede bulunmasını sağlayabilecektir. Ayrıca bu çalışma, gebelik olasılığını tahmin etmek için geleneksel yöntemlerden daha etkili ve hassas bir yaklaşım sunabilecektir.

Genetik yapı ve coğrafi özelliklerin de gebelik ile ilişkili faktörleri etkileyebileceği göz önüne alındığında, ülkemizde yaşayan kadınların gebelik elde etme ihtimalini araştıran çalışmaların literatüre önemli oranda katkı sağlayacağı düşünülmektedir. Bu çalışma, Karadeniz bölgesindeki hastaları içeren bölgesel bir çalışma olmasına rağmen, ülkemizde yapay zekâ araçları kullanılarak gebelik tahmini adına yapılan ilk çalışma olması açısından özgünlük taşımaktadır.

Yapılan bu tez çalışması, prospektif bir çalışma olması açısından oldukça değerlidir çünkü, ileriye yönelik veri toplanma; güncellik, doğruluk, esneklik, boylamsal eğilimleri yakalama yeteneği, nedenselliği ele alma, önyargıların azaltılması, araştırma geçerliliği ve gerçek dünyaya uygulanabilirlik gibi çok sayıda avantaj sunmaktadır. Çalışmanın kısıtlılığı olarak, katılımcı sayısının 300 olması düşünülebilir. Katılımcı sayısı prospektif bir çalışma için yeterli olabilir ancak, daha geniş bir örneklem büyüklüğü, sonuçların genellenebilirliği açısından daha güçlü olabilir. Çalışmamız, prospektif veri toplama sürecinin zorluğu açısından değerlendirildiğinde, bu alanda umut vaat eden başarılı bir pilot çalışma olarak kabul edilebilir. Çalışmanın tek bir bölgeyle sınırlı kalması, sonuçların diğer bölgeler veya farklı kültürel ve sosyoekonomik yapılar için geçerliliğini sınırlayabilir. Gelecek dönemlerde farklı bölgeler de dahil edilerek, daha geniş katılımcı örneklemiyle çalışma genişletilebilir. Böylece gebelik olasılığı tahmini için kullanılacak bu karar destek sistemi, daha geniş bir hasta kitlesi üzerinde test edilerek dışsal doğrulamanın yapılması sağlanılabilir. Bu da klinik uygulamalarda kullanılabilecek etkili bir araç olma potansiyelini artırabilir. Ayrıca, katılımcıların doldurduğu formlar aracılığıyla elde edilen veriler, önyargı ve yanlış bilgi içerme riski taşıyabilirler. Özellikle yaşam tarzı ve davranışsal faktörler gibi subjektif bilgilerde bu risk daha yüksek olması kısıtlılıklar arasında sayılabilir.

Çalışmamızın bir sonucu olarak, geliştirilen karar destek sisteminin uygulamaya dönüştürülmesi ve bir mobil uygulama şeklinde sunulması planlanmaktadır. Bu mobil

uygulama, uzman hekimlere doğurganlık planlaması yapan bireylere ve çiftler kadınlar için gebe kalma olasılıklarının tahmin edilmesinde ve doğurganlık süreçlerinin optimize edilmesinde yardımcı olabilecektir. Uygulama, uzman hekim kontrolünde kullanıcılara kişisel verilerini girdikleri bir platform sunacak ve bu verilere dayanarak gebe kalma olasılıklarını “düşük”, “orta” veya “yüksek” şeklinde sınıflandırabilecektir. Böylece bireylerin, sağlık uzmanları ile iş birliği yaparak daha bilinçli kararlar almalarına ve doğurganlık süreçlerini iyileştirmelerine olanak tanınabilecektir.



6. KAYNAKLAR

1. Wesselink AK, Rothman KJ, Hatch EE, Mikkelsen EM, Sørensen HT, Wise LA (2017). Age and fecundability in a North American preconception cohort study. *American Journal of Obstetrics and Gynecology* 217: 667.e1-667.e8.
2. Phillips AM, Magann EF, Whittington JR, Whitcombe DD, Sandlin AT (2019). Cme review article 25 74: 539-545.
3. Van der Zee B, de Beaufort ID, Steegers EAP, Denktaş S (2013). Perceptions of preconception counselling among women planning a pregnancy: A qualitative study. *Family Practice* 30: 341-346.
4. Dennis CL, Prioreschi A, Brown HK, Brennenstuhl S, Bell RC, Atkinson S, Misita D, Marini F, Carsley S, Jiwani-Ebrahim N, et al. (2022). Medical, behavioural and social preconception and interconception risk factors among pregnancy planning and recently pregnant Canadian women. *Family Medicine and Community Health* 10: 1- 11.
5. Idowu P, Balogun J, Babawale O (2016). A predictive model for the risk of infertility in women using supervised learning algorithms - A comparative analysis. *Ife Journal of Information Communication Technology* 1: 24-33.
6. Amiri F, Najafi R (2020). Investigating of factors affecting the fertility pattern of Arak city in 2018 with the structural equation modeling. *Journal of Arak University of Medical Sciences* 23(3): 360-373.
7. Liao SJ, Pan W, Dai WQ, Jin L, Huang G, Wang R, Hu C, Pan W, Tu H (2020). Development of a dynamic diagnosis grading system for infertility using machine learning. *JAMA network open* 3: e2023654.
8. Yland JJ, Wang T, Zad Z, Willis SK, Wang TR, Wesselink AK, Jiang T, Hatch EE, Wise LA, Paschalidis IC (2022). Predictive models of pregnancy based on data from a preconception cohort study. *Human Reproduction* 37: 565-576.
9. Taylor A (2003). ABC of subfertility: Extent of the problem. *British Medical Journal* 327: 434-436.
10. Schwartz D, Mayaux MJ (1982). Female fecundity as a function of age. *New England Journal of Medicine* 306: 404-406.

11. Glazener CMA, Chris W, Ford L (2002). Predicting conception. *Human Fertility* 5: 3-8.
12. Skakkebaek NE, Lindahl-Jacobsen R, Levine H, Andersson AM, Jørgensen N, Main KM, Lidegaard Ø, Priskorn L, Holmboe SA, Bräuner E V., et al. (2022). Environmental factors in declining human fertility. *Nature Reviews Endocrinology* 18: 139-157.
13. The World Bank (2024). Fertility rate, total (births per woman). <https://data.worldbank.org/indicator/SP.DYN.TFRT.IN?end=2021&start=1999>. [Erişim Tarihi 23 Nisan 2024].
14. TÜİK (2024). Doğum istatistikleri, 2022. <https://data.tuik.gov.tr/Bulten/Index?p=Birth-Statistics-2022-49673>. [Erişim Tarihi 30 Nisan 2024].
15. Marian B (2019). Demographic analysis of changes in fertility rates in the united states. MSc thesis, Faculty of California State Polytechnic University, Department of Mathematics and Statistics, Pomona.
16. Özşahin Z (2020). Fertilité farkındalığını artırmaya yönelik sağlığı geliştirme modeli doğrultusunda verilen eğitimin kadınlarda fertilité farkındalığına etkisi. İnönü Üniversitesi, Sağlık Bilimleri Enstitüsü, Ebelik Anabilim Dalı, Malatya.
17. Akkök T (2023). Yapay olarak hazırlanmış donmuş embriyo transfer (fet) sikluslarında luteal faz desteğinde farklı progesteron uygulamalarının etkinliğinin karşılaştırılması. Uludağ Üniversitesi Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim Dalı, Bursa.
18. Lan L, Harrison CL, Misso M, Hill B, Teede HJ, Mol BW, Moran LJ (2017). Systematic review and meta-analysis of the impact of preconception lifestyle interventions on fertility, obstetric, fetal, anthropometric and metabolic outcomes in men and women. *Human Reproduction* 32: 1925-1940.
19. McKinnon CJ, Hatch EE, Rothman KJ, Mikkelsen EM, Wesselink AK, Hahn KA, Wise LA (2016). Body mass index, physical activity and fecundability in a North American preconception cohort study. *Fertility and Sterility* 106: 451-459.
20. O'Gam, C., & Robey B (2014). Fertility trends and factors affecting fertility. *Women in the Third World: An Encyclopedia of Contemporary* 176: 176-184.

21. Lerch M (2019). Fertility decline in urban and rural areas of developing countries. *Population and Development Review* 45: 301-320.
22. Adhikari R (2010). Demographic, socio-economic, and cultural factors affecting fertility differentials in Nepal. *BMC Pregnancy and Childbirth* 10: 1-11.
23. He D, Zhang X, Zhuang Y, Wang Z, Jiang Y (2019). China fertility report, 2006-2016. *China Population and Development Studies* 2: 430-439.
24. Younglai E V., Holloway AC, Foster WG (2005). Environmental and occupational factors affecting fertility and IVF success. *Human Reproduction Update* 11: 43-57.
25. Lassi ZS, Imam AM, Dean S V., Bhutta ZA (2014). Preconception care: Caffeine, smoking, alcohol, drugs and other environmental chemical/radiation exposure. *Reproductive Health* 11: 1-12.
26. Sezgin H, Hocaoglu C (2014). İnfertilitenin psikiyatrik yönü. *Psikiyatride Güncel Yaklaşımlar* 6(2):165-184.
27. Howard LM, Kumar C, Leese M, Thornicroft G (2002). The general fertility rate in women with psychotic disorders. *American Journal of Psychiatry* 159: 991-997.
28. Stokes VJ, Anderson RA, George JT (2015). How does obesity affect fertility in men - And what are the treatment options? *Clinical Endocrinology* 82: 633-638.
29. Kırca N, Öngen M (2021). İnfertilite ve uyku kalitesi arasındaki ilişki. *Jinekoloji-Obstetrik ve Neonatoloji Tıp Dergisi* 18: 757-761.
30. Mena GP, Mielke GI, Brown WJ (2020). Do physical activity, sitting time and body mass index affect fertility over a 15-year period in women? Data from a large population-based cohort study. *Human Reproduction* 35: 676-683.
31. Brinson AK, da Silva SG, Hesketh KR, Evenson KR (2023). Physical activity and fertility. *J Phys Act Health* 20: 600-615.
32. Silvestris E, Lovero D, Palmirotta R (2019). Nutrition and female fertility: An interdependent correlation. *Frontiers in Endocrinology* 10: 346.
33. Gaskins AJ, Sundaram R, Buck Louis GM, Chavarro JE (2018). Predictors of sexual intercourse frequency among couples trying to conceive. *The Journal of Sexual Medicine* 15: 519-528.

34. Simmons RG, Jennings V (2020). Fertility awareness-based methods of family planning. *Best Practice and Research: Clinical Obstetrics and Gynaecology* 66: 68-82.
35. Bongaarts J (2017). The effect of contraception on fertility: Is sub-Saharan Africa different? *Demographic Research* 37: 129-146.
36. Gurol-Urganci I, Bou-Antoun S, Lim CP, Cromwell DA, Mahmood TA, Templeton A, van der Meulen JH (2013). Impact of caesarean section on subsequent fertility: A systematic review and meta-analysis. *Human reproduction* 28: 1943-1952.
37. Ahmadi A, Ramazanzadeh R, Derakhshan S, Khodabandehloo M, Farhadifar F, Roshani D, Mousavi A, Hedayati MA, Taheri M (2022). Prevalence of *Listeria monocytogenes* infection in women with spontaneous abortion, normal delivery, fertile and infertile. *BMC Pregnancy and Childbirth* 22: 1-6.
38. Johnson S, Stanford JB, Warren G, Bond S, Bench-Capon S, Zinaman MJ (2020). Increased likelihood of pregnancy using an app-connected ovulation test system: A randomized controlled trial. *Journal of Women's Health* 29: 84-90.
39. Zwingerman R, Chaikof M, Jones C (2020). A critical appraisal of fertility and menstrual tracking apps for the iPhone. *Journal of Obstetrics and Gynaecology Canada* 42: 583-590.
40. Tokat MA, Başlı M, Yanık F, Bilgiç D, Başoğlu M (2022). Fertilitiyi geliştirmede prekonsepsiyonel bakım: İnfertil çiftler için örnek bir holistik bakım şeması. *İzmir Katip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi*, 7(3), 623-628.
41. Kohler HP, Rodgers JL, Miller WB, Skytthe A, Christensen K (2006). Bio-social determinants of fertility. *International Journal of Andrology* 29: 46-53.
42. Vander Borgh M, Wyns C (2018). Fertility and infertility: Definition and epidemiology. *Clinical Biochemistry* 62: 2-10.
43. Grady MC (2006). Preconception and the young cancer survivor. *Maternal and Child Health Journal* 10: 165-168.
44. Signorello LB, Mulvihill JJ, Green DM, Munro HM, Stovall M, Weathers RE, Mertens AC, Whitton JA, Robison LL, Boice JD (2010). Stillbirth and neonatal death in relation to radiation exposure before conception: A retrospective cohort study. *The Lancet* 376: 624-630.

45. Örsal Ö, Tözün M, Ünsal A (2011). Kadınların ev kazalarında ilk yardım bilgi düzeylerinin değerlendirilmesi. *Sürekli Tıp Eğitimi Dergisi* 5: 202-222.
46. Dinçer Y, Şanlı Y, Beji NK (2015). İnfertilite hemşireliğinde kanıta dayalı yaklaşımlar. *Androloji Bülteni* 17: 289-295.
47. Ćwiertnia A, Borzyszkowska D, Golar A, Tuczyńska N, Kozłowski M, Kwiatkowski S, Cymbaluk-Płoska A (2022). The impact of uterus didelphys on fertility and pregnancy. *International Journal of Environmental Research and Public Health* 19 (17): 10571.
48. Taylor E, Gomel V (2008). The uterus and fertility. *Fertility and Sterility* 89: 1-16.
49. Küçükkaya B, Süt HK, Koyunoğlu Y, Kaya M, Yongaç C (2018). Hemşirelik öğrencilerinin fertilitateyi etkileyen faktörlere ilişkin bilgi ve tutumları. *Sakarya Üniversitesi Holistik Sağlık Dergisi* 1: 52-64.
50. Abrao MS, Muzii L, Marana R (2013). Anatomical causes of female infertility and their management. *International Journal of Gynecology and Obstetrics* 123: 18-24.
51. Maylawati DSA, Ramdhani MA, Zulfikar WB, Taufik I, Darmalaksana W (2017). Expert system for predicting the early pregnancy with disorders using artificial neural network. 2017 5th International Conference on Cyber and IT Service Management (CITSM), Denpasar, Indonesia, 08-10 August 2017, 1-6.
52. Balogun, J. A., Egejuru, N. C., & Idowu PA (2018). Comparative analysis of predictive models for the likelihood of infertility in women using supervised machine learning techniques. *Computer Reviews Journal* 2(1): 313-330.
53. Fayemiwo MA, Adegbite O, Ofoegbu EO (2019). Comparative analysis of predictive models on fertility rate using machine learning algorithms. *Adeleke University Journal of Engineering and Technology* 2: 85-97.
54. Zhang B, Cui Y, Wang M, Li J, Jin L, Wu D (2019). In Vitro Fertilization (IVF) cumulative pregnancy rate prediction from basic patient characteristics. *IEEE Access* 7: 130460-130467.
55. Bertini A, Salas R, Chabert S, Sobrevia L & Pardo F (2022). Using machine learning to predict complications in pregnancy: A systematic review. *Frontiers in Bioengineering and Biotechnology* 9: 780389.

56. Liu L, Jiao Y, Li X, Ouyang Y & Shi D (2020). Machine learning algorithms to predict early pregnancy loss after in vitro fertilization-embryo transfer with fetal heart rate as a strong predictor. *Computer Methods and Programs in Biomedicine* 196: 105624.
57. Bilen A, Özer AB (2022). Siber saldırılar için rastgele orman algoritması kullanılarak öznelik seçimi. *Fırat Üniversitesi Fen Bilimleri Dergisi* 34(1): 31-37.
58. Pulat M, Kocakoç İD (2021). Türkiye’de makine öğrenmesi ve karar ağaçları alanında yayınlanmış tezlerin bibliyometrik analizi. *Journal of Management and Economics* 28(2): 287-308.
59. Chandrashekar G, Sahin F (2014). A survey on feature selection methods. *Computers and Electrical Engineering* 40: 16-28.
60. Kamalov F, Sulieman H, Moussa S, Reyes JA, Safaraliev M (2023). Nested ensemble selection: An effective hybrid feature selection method. *Heliyon* 9: e19686.
61. Tang R, Zhang X (2020). CART Decision Tree Combined with Boruta Feature Selection for Medical Data Classification. 2020 5th IEEE International Conference on Big Data Analytics (ICBDA), Xiamen, China, 08-11 May 2020, 80-84.
62. Emanet S, Baydoğmuş GK, Demir Ö (2021). Öznelik seçme yöntemlerinin makine öğrenmesi tabanlı saldırı tespit sistemi performansına etkileri. *DÜMF Mühendislik Dergisi* 12(5): 743-755.
63. Zakharov R, Dupont P (2011). Ensemble logistic regression for feature selection. In *Pattern Recognition in Bioinformatics: 6th IAPR International Conference (PRIB)*, Delft, The Netherlands, 2-4 November 2011, 133-144.
64. Akgül G, Çelik AA, Aydın ZE, Öztürk ZK (2020). Hipotiroidi hastalığı teşhisinde sınıflandırma algoritmalarının kullanımı. *Bilişim Teknolojileri Dergisi* 13: 255-268.
65. Eyüpoğlu C, Yavuz E (2020). Kanseri teşhisi için makine öğrenmesi tekniklerine dayalı yeni bir sınıflandırma metodu. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi* 7: 1106-1123.
66. Beam AL, Kohane IS (2018). Big data and machine learning in health care. *JAMA* 319(13): 1317-1318.

67. Karşı ÖB (2019). Makine Öğrenme Yöntemleri ile Karaciğer Hastalığının Teşhisi. Yüksek Lisans Tezi, Ağrı İbrahim Çeçen Üniversitesi, Fen Bilimleri Enstitüsü, Matematik Anabilim Dalı, Ağrı.
68. Mahesh Batta (2020). Machine learning algorithms-A review. International Journal of Science and Research (IJSR) 9(1): 381-386.
69. Afrin F, Nahar I (2015). Incremental learning based intelligent job search system. PhD Thesis, BRAC University, Department of Computer Science & Engineering, Bangladesh.
70. Sarker IH (2021). Machine learning: Algorithms, real-world applications and research directions. SN Computer Science 2: 1-21.
71. Sagi O, Rokach L (2018). Ensemble learning: A survey. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery 8: 1-18.
72. Küçükakçalı Z (2023). Topluluk öğrenme yöntemlerine dayalı bilgisayar destekli tanı sisteminin geliştirilmesi: Genomik teknolojileri üzerine uygulaması. Doktora Tezi, İnönü Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, Malatya.
73. Kartal E (2015). Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Enformatik Anabilim Dalı, İstanbul.
74. Görmez B (2021). Adli bilişimde makine öğrenmesi: makine öğrenmesi algoritmaları ile terör olaylarının tahmin edilmesi çalışması. Yüksek lisans tezi, Ankara Üniversitesi, Sağlık Bilimleri Enstitüsü, Disiplinlerarası Adli Bilimler Anabilim Dalı, Ankara.
75. Salmi N, Rustam Z (2019). Naïve Bayes classifier models for predicting the colon cancer. IOP Conference Series: Materials Science and Engineering 546 (5): 052068.
76. Asarkaya S, Kaynar O, Yelmen İ, Yıldırım F, Zontul M (2021). Ddos saldırılarının makine öğrenimi algoritmalarıyla tespiti. Journal of Design Architecture and Engineering 1: 221-232.
77. Doğaner A (2020). Topluluk Öğrenme Yöntemleri ile Renal Hücreli Karsinom'un Tahmin Edilmesi. Doktora Tezi, İnönü Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, Malatya.

78. Aydın A (2023). Topluluk öğrenmesi kullanılarak zararlı alan adlarının sınıflandırılması. Yüksek lisans tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
79. Zhou F, Pan H, Gao Z, Huang X, Qian G, Zhu Y, Xiao F (2021). Fire prediction based on catboost algorithm. *Mathematical Problems in Engineering* 2021: 1-9.
80. Yang L, Shami A (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing* 415: 295-316.
81. Alibrahim H, Ludwig SA (2021). Hyperparameter optimization: Comparing Genetic algorithm against grid search and bayesian optimization. 2021 IEEE Congress on Evolutionary Computation (CEC), Kraków, Poland, 28 June 2021 - 01 July 2021, 1551-1559.
82. Erickson BJ, Kitamura F (2021). Magician's corner: 9. performance metrics for machine learning models. *Radiology: Artificial Intelligence* 3: 1-7.
83. Sevlı O, Kemalöglu N (2021). Olağandışı olaylar hakkındaki tweet'lerin gerçek ve gerçek dışı olarak Google BERT modeli ile sınıflandırılması. *Veri Bilimi* 4: 31-37.
84. Rácz A, Bajusz D, Héberger K (2019). Multi-level comparison of machine learning classifiers and their performance metrics. *Molecules* 24: 1-18.
85. Tomak L, Bek Y (2010). İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *Journal of Experimental and Clinical Medicine* 27: 58-65.
86. Bayrampour H, Heaman M, Duncan KA, Tough S (2012). Advanced maternal age and risk perception: A qualitative study. *BMC Pregnancy and Childbirth* 12: 1-13.
87. Njagi P, Groot W, Arsenijevic J, Dyer S, Mburu G, Kiarie J (2020). Economic costs of infertility care for patients in low-income and middle-income countries: A systematic review protocol. *BMJ Open* 10: 1-6.
88. Sharma S, Khinchi M, Sharma N AD and GM (2011). Female infertility - An overview. *International Journal of Pharmaceutical Sciences and Research* 2: 1-12.
89. Lez-Rodríguez AG, Cobo JS, Soria V, Usall J, Garcia-Rizo C, Bioque M, Monreal JA, Labad J (2020). Women undergoing hormonal treatments for infertility: A systematic review on psychopathology and newly diagnosed mood and psychotic disorders. *Frontiers in Psychiatry* 11: 1-12.

90. Cwikel J, Gidron Y, Sheiner E (2004). Psychological interactions with infertility among women. *European Journal of Obstetrics and Gynecology and Reproductive Biology* 117: 126-131.
91. Szkodziak F, Krzyżanowski J, Szkodziak P (2020). Psychological aspects of infertility. A systematic review. *Journal of International Medical Research*: doi: 10.1177/0300060520932403.
92. Jennings V, Haile LT, Simmons RG, Spieler J, Shattuck D (2019). Perfect- and typical-use effectiveness of the Dot fertility app over 13 cycles: Results from a prospective contraceptive effectiveness trial. *European Journal of Contraception and Reproductive Health Care* 24: 148-153.
93. Dennis CL, Prioreshi A, Birken CS, Brennenstuhl S, Brown HK, Bell RC, Marini F, Wrottesley S V. (2023). Predictors of preconception health knowledge among Canadian women: A nationwide cross-sectional study. *Journal of Clinical Nursing* 32: 4843-4851.
94. Boedt T, Vanhove AC, Vercoe MA, Matthys C, Dancet E, Lie Fong S (2021). Preconception lifestyle advice for people with infertility. *Cochrane Database of Systematic Reviews*: doi: 10.1002/14651858.CD008189.pub3
95. Stanford JB, Willis SK, Hatch EE, Rothman KJ, Wise LA (2020). Fecundability in relation to use of mobile computing apps to track the menstrual cycle. *Human Reproduction* 35: 2245-2252.



EKLER

Ek 2. Konsepsiyon Tahmini Değişken Formu

Hastaya Ait Bilgiler

Tarih:

Konsepsiyon Tahmini Değişken Formu

Adı Soyadı :

Doğum Tarihi:

Telefon:

Meslek:

Boy:

Kilo:

17 yaş sonrası kilo değişimi (alınan kilo miktarı (kg)):

Gebelik istemi sonrası kilo değişimi (kg):

Uyku Bozuklukları:

Geceleri ortalama kaç saat uyursunuz?

Geceleri saat kaçta uyumaya gidersiniz?

Uykuya dalmanız ortalama kaç dakika sürer?.....

Hastaya Ait Bilgiler

Evlilik süresi:

Evlilik yaşı:

Subfertilite süresi (Ne zamandır gebe kalmak istiyorsunuz?)
(ay/yıl):

Son gebelik sonrası geçen süre (yıl/ay):

Cinsel ilişki sıklığı (sayı/haftada):

Oturarak geçirilen süre (saat/günlük):

Ayakta kalma süresi (saat/haftalık):

Sigara.....tane/günde

Kahve.....fincan/günde

Alkol.....bardak/günde

G (Gebelik Sayısı):

P (Doğum Sayısı):

Y (Yaşayan Çocuk Sayısı):

D (Kürtaj Sayısı):

Önceden doğum varsa doğum yöntemi:

(Normal/Sezaryen):

Ek 2. (Devam)

Hastaya Ait Bilgiler

Yaşam Yeri

- ☐ Kırsal
☐ Şehir

Hane Geliri

- ☐ Açlık sınırı (2.736 TL)
☐ Açlık ve Yoksulluk sınırı
☐ Yoksulluk sınırı (8.912 TL)
☐ Yoksulluk sınırı üstü

Önceki Koruma Yöntemi

- ☐ OKS (Doğum Kontrol Hapı)
☐ Geri Çekme
☐ Kondom (Prezervatif)
☐ Aylık iğne
☐ 3 aylık iğne
☐ Hiç korunmadım

Menstrüel Döngü (Adet Döngüsü)

- ☐ 28 günde bir
☐ 35 günden uzun
☐ 21 günden kısa
☐ OLİGOMENORE (seyrek adet görme)
☐ POLİMENORE (sık adet görme)

Gebelik şansını artırmak için ovulasyon (yumurtlama) gününü takip ediyor musunuz?

- ☐ Evet
☐ Hayır

Evet ise, takip için ovulasyon kiti mi yoksa mobil uygulaması mı kullanıyor musunuz?

Eğitim Durumu

- ☐ İlköğretim
☐ Lise
☐ Lisans
☐ Yüksek Lisans/Doktora

Ailede Kısırlık Öyküsü

- ☐ Var
☐ Yok

Folik asit kullanıyor musunuz?

- ☐ Evet
☐ Hayır

Varsa kullandığınız diğer ilaçların adı:

Tıbbi Geçirilmiş Cerrahi Öykü

- ☐ Diabet
☐ Hipertansiyon
☐ Fibroid (Miyom)
☐ Genital enfeksiyon
☐ Cinsel yolla bulaşan hastalık
☐ Trioid
☐ PKOS (Yumurtalık Kisti)
☐ D vitamini eksikliği
☐ Endometriozis (Çikolata Kisti)
☐ Habituel abortus (Tekrarlayan Düşük)

Santral Sinir Sistemi

- ☐ Anksiyete (Kaygı bozukluğu) / Panik atak/
Depresyon tanısı aldınız mı?

Evetse bununla ilgili olarak ilaç kullandınız mı/kullanıyor musunuz?

- ☐ Evet
☐ Hayır

Erkek Partner

Boy: Kilo: Sigara.....tane/günde

Yaş: Alkol.....bardak/günde

Eğitim Durumu

- ☐ İlköğretim
☐ Lise
☐ Lisans
☐ Yüksek Lisans/Doktora

Kahve.....fincan/günde

Ek 3. Google Formları Üzerinden Hazırlanan Soru Formu Linki

<https://docs.google.com/forms/d/14R8SEQSx79Ny3wTkNt9ixPGbU6YhyGP5BT7BPizQMvc/edit>



Ek 4. Bilgilendirilmiş Onam Formu

BİLGİLENDİRİLMİŞ GÖNÜLLÜ ONAM FORMU

Sizi, Doç. Dr. Beril GÜRLEK'in özel kliniği ve KTÜ Biyoistatistik ve Tıp Bilişimi Anabilim Dalı tarafından ortak yürütülen “Yapay Zekâ Yaklaşımı ile Kümülatif Konsepsiyon Tahmin Modeli Geliştirilmesi” başlıklı araştırmaya davet ediyoruz. Bu çalışmada gebelik elde etme olasılığı düşük olan kadınların önceden tespitini sağlayacak girişimsel olmayan, ucuz ve etkili bir tahmin modeli geliştirilmesi planlanmaktadır. Araştırmada, tahminen 10 dakika kadar bir süreyi alacak olan, gebelik ile ilişkili olduğu düşünülen demografik verilerin, yaşam tarzının ve davranışsal faktörlerin yanı sıra, tıbbi ve üreme geçmişleri hakkında temel soruları içeren soruları yanıtlamanız istenecektir. Bu çalışmada, gebelik planlayan çiftlere ait bilgilerden elde edilen veriler kullanılarak, kadınların gebe kalabilme ihtimali 12 aylık süreç sonunda, “düşük”, “orta” ve “yüksek” şeklinde sınıflandırılacak olan bir tahmin modeli geliştirilmesi amaçlanmıştır. Araştırmaya sizin dışınızda tahminen 299 katılımcı katılacaktır. Bu çalışmaya katılmak tamamen gönüllülük esasına dayanmaktadır. Çalışmanın amacına ulaşması için sizden beklenen, bütün soruları eksiksiz, kimsenin baskısı veya telkini altında olmadan, size en uygun gelen cevapları içtenlikle verecek şekilde cevaplamanızdır. Tıbbi verileriniz, orjinal kayıtlar ve katılımcı bilgileriniz etik kurul, kurum ve diğer sağlık otoriteleriyle paylaşılabilir. Kimliğinizi ortaya çıkaracak kayıtlar gizli tutulacaktır, araştırma sonuçları açıklansa bile kamuoyuna kimliğiniz açıklanmayacaktır. Araştırmayla ilgili katılmaya devam etme isteğinizi etkileyecek yeni bilgiler bulunduğu takdirde zamanında bilgilendirileceksiniz. Bu formu okuyup onaylamanız, araştırmaya katılmayı kabul ettiğiniz anlamına gelecektir. Ancak, çalışmaya katılmama veya katıldıktan sonra herhangi bir anda çalışmayı bırakma hakkına da sahipsiniz. Bu çalışmadan elde edilecek bilgiler tamamen araştırma amacı ile kullanılacak olup katılımcı bilgileriniz gizli tutulacaktır; ancak verileriniz yayın amacı ile kullanılabilir. İletişim bilgileriniz ise sadece izninize bağlı olarak ve farklı araştırmacıların sizinle iletişime geçebilmesi için kullanılabilir. Eğer araştırmanın amacı ile ilgili verilen bu bilgiler dışında şimdi veya sonra daha fazla bilgiye ihtiyaç duyarsanız araştırmacıya şimdi sorabilir veya berilsem@yahoo.com e-posta adresi ve 0 532 795 5311 numaralı telefondan ulaşabilirsiniz. Araştırma tamamlandığında genel/size özel sonuçların sizinle paylaşılmasını istiyorsanız lütfen araştırmacıya iletiniz.

Yukarıda yer alan ve araştırmadan önce katılımcıya verilmesi gereken bilgileri okudum ve katılmam istenen çalışmanın kapsamını ve amacını, gönüllü olarak üzerime düşen sorumlulukları anladım. Çalışma hakkında yazılı ve sözlü açıklama aşağıda adı belirtilen araştırmacı tarafından yapıldı. Bana, çalışmanın muhtemel riskleri ve faydaları sözlü olarak da anlatıldı. Katılımcıların bilgilerinin özenle korunacağı konusunda yeterli güven verildi.

Bu koşullarda söz konusu araştırmaya kendi isteğimle, gönüllü olarak hiçbir baskı ve telkin olmaksızın istediğim zaman gerekçeli veya gerekçesiz araştırmadan ayrılabileceğimi bilerek katılmayı

- kabul ediyorum
- kabul etmiyorum

İletişim bilgilerimin diğer araştırmacıların benimle iletişime geçebilmesi için saklanması;

- kabul ediyorum
- kabul etmiyorum

Katılımcının:


Adı-Soyadı:

Tarih:


İletişim Bilgileri: e-posta:

Telefon:


Ek 5. Hiper Parametre Optimizasyonu Sonrası Senaryo 1 Kapsamında Geliştirilen Tahmin Modellerine Ait Performans Metriklerinin Karşılaştırılması




Ek 6. Hiper Parametre Optimizasyonu Sonrası Senaryo 1 Kapsamında Geliştirilen Tahmin Modellerine Ait ROC Eğrilerinin Karşılaştırılması



Ek 7. Hiper Parametre Optimizasyonu Sonrası Senaryo 3 Kapsamında Geliştirilen Tahmin Modellerine Ait Performans Metriklerinin Karşılaştırılması



Ek 8. Hiper Parametre Optimizasyonu Sonrası Senaryo 3 Kapsamında Geliştirilen Tahmin Modellerine Ait ROC Eğrilerinin Karşılaştırılması



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Soyadı, Adı : Tuğba KURT
Uyruğu :
Doğum Tarihi ve Yeri :
Telefon (İş) :
E-Posta :
Yazışma Adresi (İş) :

EĞİTİM BİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
Doktora/Uzmanlık	Karadeniz Teknik Üniversitesi / Biyoistatistik ve Tıp Bilişimi	2018-
Yüksek Lisans	Karadeniz Teknik Üniversitesi / Biyoistatistik ve Tıp Bilişimi	2017
Lisans	Ondokuz Mayıs Üniversitesi / İstatistik	2007
Lise	Pazar 75. Yıl İ.M.K.B Anadolu Lisesi	2002

AKADEMİK/MESLEKİ DENEYİMİ

Görevi	Kurum	Süre (Yıl -Yıl)
1. İstatistikçi	Karadeniz Teknik Üniversitesi, Farabi Hastanesi	2010-
2. Bankacı	Türkiye Vakıflar Bankası	2008-2010

YABANCI DİL

İngilizce, B1 (Orta)

UZMANLIK ALANI

İstatistik, Biyoistatistik, Tıp Bilişimi, Makine Öğrenmesi, Yapay Zekâ

YAYINLAR

1. Kamaşak T, Dilber B, Yaman SÖ, Durgut BD, Kurt T, Çoban E, ... & Cansu A (2020). HMGB-1, TLR4, IL-1R1, TNF- α , and IL-1 β : Novel epilepsy markers?. *Epileptic Disorders* 22: 183-193.
2. Kamasak T, Durgut BD, Arslan EA, Sahin S, Dilber B, Kurt T, Cansu A (2018). The Role of electroencephalography in differentiating epileptic and non-epileptic events in adolescents: 3-year experience in one pediatric neurology center. *Güncel Pediatri-Journal Of Current Pediatrics* 16: 19-30.
3. Kamaşak T, Cansu A, Arslan EA, Şahin S, Durgut BD, Dilber B, Kurt T, Terzi M & Boz C (2017). Pediatrik yaş başlangıçlı multipl skleroz ile erişkin yaş başlangıçlı multipl sklerozun karşılaştırılması. *Türkiye Klinikleri Nöroloji Dergisi* 12: 57-63.
4. Kamasak T, Direk M, Kurt T, & Karaman S. Otizmli çocuklarda doğum öyküsü, anne sütü alma süresi, televizyon ile tanışma yaşı, televizyon, akıllı telefon ve tablet kullanım alışkanlıklarının incelenmesi. *Kırıkkale Üniversitesi Tıp Fakültesi Dergisi* 22: 411-417.
5. Kırkbir İB & Kurt T (2020). Hemşirelik bilişimi ve karar verme sürecinde klinik karar destek sistemlerinin önemi. *Hemşirelik Bilimi Dergisi* 3: 28-31.
6. Akturan S, Güner Y, Tuncel B, Üçüncüoğlu M, & Kurt T (2022). Evaluation of alarm fatigue of nurses working in the COVID-19 Intensive Care Service: A mixed methods study. *Journal of Clinical Nursing* 31: 2654-2662.
7. Kurt B, Gürlek B, Keskin S, Özdemir S, Karadeniz Ö, Kırkbir İB, ... & Turhan K (2023). Prediction of gestational diabetes using deep learning and Bayesian optimization and traditional machine learning techniques. *Medical & Biological Engineering & Computing* 61: 1649-1660.
8. Kurt B, Gürlek B, Keskin S, Kurt T, Kasap ZA., Kırkbir İB & Turhan K (2023). A prospective study for gestational diabetes mellitus: Analysis of risk factors in Turkish women for early prediction. *International Journal of Gynecology & Obstetrics* 161(2): 525-535.
9. Renda G, Gökkaya İ, Kandemir G, Özyiğit T, & Kurt T (2024). Pharmacy students' knowledge and attitudes about homeopathy: A descriptive survey conducted in Turkey. *Homeopathy* 113(01): 041-048.

10. Kurt B, Kırkbir İB, Kurt T, Guner A, Uluşahin M (2023). A novel computer based risk prediction model for vocal cord palsy before thyroidectomy. Computer Methods and Programs in Biomedicine: 107563.

BİLDİRİLER

1. Turhan K, Kurt T, Kurt B, Kırkbir İB. Akut apandisit nedeniyle opere edilen hastaların kümeleme yöntemi ile profillerinin belirlenmesi. Tıp Bilişiminde Yenilikler Sempozyumu, Ankara, Türkiye, 25 Mart 2017, ss.1
2. Kurt T, Gürlek B, Turhan K, Batıoğlu AS. Analysis of effective factors for intrauterine insemination outcome in male infertility by using logistic regression”, 7th International Conference on Medical Informatics & Telemedicine, Rome, Italy, 12-13 August 2019, pp 1.
3. Kırkbir İB, Kurt T, Güner A, Kurt B. Predicting Risk of death after myocardial infarction using machine learning methods. 14. Tıp Bilişimi Kongresi Bildiriler Kitabı, İzmir, Türkiye, 16 Mart 2023, ss.188