



In-depth analysis of machine learning models and explainable artificial intelligence methods in diabetes diagnosis

Hakan Güler^{1*}, Derya Avcı², Mustafa Ulaş³, Tülay Omma⁴

¹Department of Software Engineering, Faculty of Technology, Fırat University, 23100, Elazığ, Türkiye

²Computer Technologies, Vocational School of Technical Sciences, Fırat University, Elazığ, Türkiye

³Artificial Intelligence and Data Engineering, Faculty of Engineering, Fırat University, Elazığ, Türkiye

⁴Department of Endocrinology and Metabolic Diseases, Faculty of Medicine, Lokman Hekim University, Ankara, Türkiye

Highlights:

- Model comparison in diabetes diagnosis
- Explainable AI approach
- Analysis for clinical applications

Keywords:

- Diabetes
- Explainable Artificial Intelligence
- SHAP
- LIME
- XGBoost

Article Info:

Research Article

Received: 19.09.2024

Accepted: 08.03.2025

DOI:

10.17341/gazimmfd.1552790

Acknowledgement:

This study is supported by Fırat University Scientific Research Projects Coordination Unit (FÜBAP) with project number ADEP.23.21.

Correspondence:

Author: Hakan Güler

e-mail:

hakanguler@firat.edu.tr

phone: +90 537 733 8252

Graphical/Tabular Abstract

This study aims to develop an effective predictive model for early diabetes diagnosis. Diabetes poses a significant risk as a chronic disease worldwide. The study comprehensively addresses data settings, preprocessing steps, and machine learning models employed. It outlines the stages of diabetes prediction and techniques utilized at each stage, including dataset selection, preprocessing, and various machine learning models such as K-Nearest Neighbors (KNN), Support Vector Machine (SVM), Neural Networks, Random Forest, Decision Tree, Naïve Bayes, and XGBoost. The "Classification" section summarizes the techniques used for diabetes classification and their outcomes. The "Results" section presents the performance and accuracy rates of each machine learning model. Additionally, the "Artificial Intelligence" and "Expert Doctor" sections discuss the results of predictions made by expert doctors using AI methods. Finally, the "Comparison of Artificial Intelligence and Expert Doctor" section evaluates and compares the predictions made by AI and expert doctors, assessing their performance (Figure A).




Figure A. Diabetes prediction process overview: data preprocessing, machine learning models and benchmarking

Purpose: This study delves into assessing the efficacy of diverse machine learning models alongside Explainable Artificial Intelligence (XAI) techniques for the early diagnosis and prediction of diabetes using healthcare datasets. With the burgeoning volume of healthcare data, data mining and machine learning have become indispensable tools for unraveling, detecting, diagnosing, and scrutinizing diabetes datasets.

Theory and Methods: The research meticulously evaluates K-Nearest Neighbors (K-NN), Support Vector Machine (SVM), Naive Bayes, Artificial Neural Networks (ANN), Decision Tree, Random Forest, and XGBoost models across a comprehensive diabetes dataset spanning various healthcare systems. Model performances are rigorously evaluated using key metrics such as accuracy, F1 score, sensitivity, and specificity. Subsequent to rigorous data cleaning and preprocessing, each model undergoes training and testing stages.

Results: The study unveils diverse performances among the models, with XGBoost exhibiting the highest accuracy rate of 98.91%, closely followed by Random Forest at 91.68%. Moreover, the integration of XAI techniques like SHAP and LIME enriches model interpretability by elucidating influential features.

Conclusion: Expert insights corroborate the practical viability of these models in real-world scenarios, underscoring their pivotal role in enhancing early diabetes diagnosis and facilitating effective disease management strategies. This research paves the way for advancements in early diabetes diagnosis, promising improved healthcare outcomes and patient well-being.



Mühendislik Mimarlık Fakültesi Dergisi

Journal of The Faculty of Engineering
and Architecture of Gazi University

Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Diyabet hastalığı teşhisinde makine öğrenimi modelleri ile açıklanabilir yapay zeka yöntemlerinin analizi

Hakan Güler^{1*}, Derya Avcı², Mustafa Ulaş³, Tülay Omma⁴

¹Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 23000, Merkez, Elazığ, Türkiye

²Bilgisayar Teknolojileri, Teknik Bilimler Meslek Yüksekokulu, Fırat Üniversitesi, Elazığ, Türkiye

³Yapay Zeka ve Veri Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

⁴Lokman Hekim Üniversitesi Tıp Fakültesi Endokrinoloji ve Metabolizma Hastalıkları Anabilim Dalı, Ankara, Türkiye

Ö N E Ç İ K A N L A R

- Diyabet teşhisinde model karşılaştırması
- Açıklanabilir yapay zeka yaklaşımı
- Klinik uygulamalara yönelik analiz

Makale Bilgileri

Araştırma Makalesi

Geliş: 19.09.2024

Kabul: 08.03.2025

DOI:

10.17341/gazimmfd.1552790

Anahtar Kelimeler:

Açıklanabilir Yapay Zeka,
Diyabet,
SHAP,
XGBoost

ÖZ

Sağlık sektöründe büyük veri kümelerinin artışı, makine öğrenimi yöntemlerini diyabet veri setlerinin analizi, tahmini ve keşfi süreçlerinde kritik bir konuma taşımıştır. Bu çalışma, diyabetin erken teşhisine odaklanarak yedi makine öğrenimi modelinin performanslarını karşılaştırmış ve Açıklanabilir Yapay Zeka (XAI) tekniklerinin etkisini incelemiştir. K-En Yakın Komşular (KNN), Destek Vektör Makineleri (SVM), Naive Bayes, Yapay Sinir Ağları (YSA), Karar Ağaçları, Rastgele Orman ve XGBoost modelleri, veri temizleme, ön işleme, eğitim ve test aşamalarını içeren sistematik bir değerlendirme sürecine tabi tutulmuştur. Değerlendirmeler doğruluk, F1 skoru, hassasiyet ve özgünlük gibi performans kriterleri temel alınarak yapılmıştır. Bu çalışmada, önceki çalışmalardan farklı olarak, en iyi performans gösteren modelin yorumlanabilirliğini artırmak için SHAP (Shapley Additive Explanations) ve LIME (Local Interpretable Model-Agnostic Explanations) gibi açıklanabilir yapay zeka yöntemleri entegre edilmiştir. Bu yöntemler, modelin karar sürecinde önemli rol oynayan özellikleri belirleyerek, daha şeffaf ve anlaşılır sonuçlar elde edilmesini sağlamıştır. Ayrıca, elde edilen bulgular, modellerin gerçek dünya uygulamalarındaki potansiyelini değerlendirmek amacıyla uzman görüşleriyle desteklenmiştir. Sonuçlar, XGBoost algoritmasının %98.91 doğruluk oranı ile KNN (%81.18), SVM (%75.38), Naive Bayes (%75.49), YSA (%74.83), Karar Ağaçları (%76.91) ve Rastgele Orman (%91.68) algoritmalarına kıyasla üstün bir performans sergilediğini göstermiştir. Bu çalışma, makine öğreniminin XAI teknikleriyle entegre edilmesinin, diyabet teşhisi için şeffaf ve etkili çözümler sunduğunu ortaya koymaktadır.

In-depth analysis of machine learning models and explainable artificial intelligence methods in diabetes diagnosis

H I G H L I G H T S

- Model comparison in diabetes diagnosis
- Explainable AI approach
- Analysis for clinical applications

Article Info

Research Article

Received: 19.09.2024

Accepted: 08.03.2025

DOI:

10.17341/gazimmfd.1552790

Keywords:

Diabetes,
Explainable Artificial
Intelligence,
SHAP,
XGBoost

ABSTRACT

With the rise of large datasets in the healthcare sector, machine learning methods have gained significant importance in analyzing, predicting, and discovering patterns within diabetes datasets. This study focuses on the early diagnosis of diabetes by comparing the performance of seven machine learning models and exploring the impact of Explainable Artificial Intelligence (XAI) techniques. The models—K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Naive Bayes, Artificial Neural Networks (ANN), Decision Trees, Random Forest, and XGBoost—were evaluated using a well-structured pipeline that included data cleaning, preprocessing, training, and testing stages. Performance metrics such as accuracy, F1 score, sensitivity, and specificity were applied for robust evaluation. Unlike many previous studies, this research integrates XAI methods like SHAP (Shapley Additive Explanations) and LIME (Local Interpretable Model-Agnostic Explanations) to enhance the interpretability of the best-performing model. These techniques identified critical features contributing to the model's decisions, enabling better insights into the decision-making process. Additionally, the findings were validated through expert opinions to ensure real-world applicability. The results demonstrated significant improvements, with XGBoost achieving an accuracy rate of 98.91%, outperforming the KNN (81.18%), SVM (75.38%), Naive Bayes (75.49%), ANN (74.83%), Decision Trees (76.91%), and Random Forest (91.68%) models. This study highlights the potential of integrating machine learning with XAI techniques for transparent and effective diabetes diagnosis.

1. Giriş (Introduction)

Günümüzde veri bilimi ve yapay zeka teknolojileri [1] sağlık sektöründe hastalıkların teşhis, tedavi ve yönetimini iyileştirmek için önemli dönüşümlere öncülük etmektedir. Bu dönüşüm, klinik veri analizi alanında çeşitli makine öğrenimi modellerinin geliştirilmesini ve uygulanmasını içermektedir [2]. Bu bağlamda diyabet gibi kronik hastalıkların erken teşhisi ve etkin tedavisi için veriyeye dayalı yaklaşımlar önem kazanmıştır. Diabetes Mellitus (DM), insülin eksikliği veya insülin direncine bağlı olarak gelişen kronik bir metabolik bozukluktur. Tip 1 DM, insülin eksikliği (insülinopeni) ile karakterize edilirken, Tip 2 DM genellikle insülin direnci ve yetersizliği nedeniyle ortaya çıkar. Ayrıca, bazı diyabet türleri, insülin sekresyonundaki genetik bozukluklar, pankreas hastalıkları, endokrinopatiler, enfeksiyonlar, ilaçlar veya kimyasal ajanlar gibi diğer faktörlerden de kaynaklanabilmektedir. Özellikle Tip 2 DM için risk faktörleri arasında yaş, cinsiyet, ailede diyabet öyküsü, gebelik diyabeti, hipertansiyon, hareketsiz yaşam tarzı ve vücut kitle indeksi (BMI) yer almaktadır. DM'nin erken tanısı ve tedavisi, ileride gelişebilecek makro ve mikrovasküler komplikasyonların önlenmesi açısından hayati önem taşımaktadır. Prediyabetin kardiyovasküler riskte önemli bir artışa neden olduğu bilinmektedir. DM'nin erken tanı ve tedavisi ileride gelişebilecek makro ve mikrovasküler komplikasyonlar açısından hayati önem taşımaktadır. Prediyabetin kardiyovasküler riskte önemli bir artışa neden olduğu bilinmektedir [3]. Diyabetin gelişimi üzerinde yaşam tarzı seçimlerinin kritik bir etkisi olduğu saptanmıştır. Bu seçimlerin, kimi durumlarda hastalığın ilerlemesini geciktirebildiği, hatta bazı vakalarda tamamen önleyebildiği görülmektedir. Ayrıca, yaşam tarzı tercihleri, kardiyovasküler hastalık riskinin azalmasında da kilit bir rol oynamaktadır. Türkiye'de gerçekleştirilen geniş çaplı tarama çalışmaları sonucunda, diyabet ve prediyabet vakalarının yaklaşık yarısının henüz tanı almadığı tespit edilmiştir. Bu durum, risk altındaki bireylerin zamanında tespit edilmesi ve düzenli aralıklarla tarama testlerinin yapılmasının önemini vurgulamaktadır. FINDRISK (Finnish Diabetes Risk Score) anketi gibi risk puanlama testleri, risk altındaki bireyleri belirlemek için yaygın olarak kullanılmaktadır [4].

Bu bölümde, çalışmamızın amacı, diyabet teşhisinde makine öğrenimi ve açıklanabilir yapay zeka (XAI) tekniklerinin rolü ve bu alandaki mevcut sorunlar ele alınmaktadır. Literatürdeki eksiklikler belirlenmiş ve çalışmamızın bu boşlukları nasıl doldurmayı hedeflediği açıklanmıştır. Diyabet hastalığı günümüzde büyük bir sorun olarak karşımıza çıkmakta ve dünya çapında bir sorun haline gelmektedir. Hastalığın etkilerinin yönetilmesi ve bireylere kişiselleştirilmiş tedavi planlarının sunulması, doğru ve güvenilir bir veri analizi altyapısı gerektirir. Bu çalışmamızın amacı, diyabet verilerini kullanarak farklı makine öğrenme yöntemlerinin etkinliğini kapsamlı bir şekilde analiz etmektir. Araştırmada SVM, Naive Bayes, Yapay Sinir Ağları, KNN, XGBoost, Karar Ağaçları ve Rastgele Orman algoritmaları kullanılarak bu yöntemlerin diyabet teşhisindeki başarıları karşılaştırılmalı olarak değerlendirilmiştir. Bu yöntemlerin her birinin yetenekleri ayrı ayrı analiz edilerek sonuçlar paylaşılmıştır. Açıklanabilir Yapay Zeka (XAI) [5] teknikleri, model kararlarının anlaşılmasına ve model çıktıları üzerinde en fazla etkiye sahip olan özelliklerin belirlenmesine yardımcı olmaktadır. Bu değerlendirmeler alanında uzman doktordan alınan geri bildirimlerle karşılaştırılmıştır. Yapılan literatür taramasında diyabet ile ilgili yapılan çalışmalara ve yöntemlerine odaklanılmıştır.

Nishat vd. DM olarak bilinen diyabetin öngörülmesinin, sağlık teknolojisinin gelişmesine ve e-sağlık sistemlerinin oluşturulmasına ne kadar hızlı ve doğru bir şekilde katkı sağlayabileceğini araştırmak amacıyla bir çalışma gerçekleştirmişler [6]. Kaleem vd. daha doğru diyabet tahmini için makine öğreniminden yararlanan akıllı bir sağlık

öneri sistemi önerdi. Çok özellikli ve büyük sağlık veri kümelerini işlemenin zorluğunu vurgulamışlardır ve K-kat Çapraz Doğrulama yoluyla değerlendirilen yaklaşımlarının sağlamlığını vurgulamışlardır [7]. Shabtari vd. diyabetin etkisini tahmin etmek için veri madenciliği tekniklerinin ayrıntılı bir incelemesini sunmuş ve diyabet şiddetini tahmin etmek için RapidMiner'ın kullanımını göstermiştir [8]. Azbeg vd. güvenli diyabet tahmini için istatistiksel yöntemleri, Blockchain'i ve IPFS'yi içeren IoT tabanlı bir sistem mimarisi geliştirdi ve farklı veri kümelerinde başarıya ulaştı [9]. Lukmanto vd. diyabeti sınıflandırmak için özellik seçimi ve bulanık destek vektör makinesi yöntemlerini kullanarak %89,02 doğruluk oranıyla umut verici sonuçlar elde etti [10]. Zhu vd. k-ortalama kümeleme ve lojistik regresyon gibi veri madenciliği tekniklerini kullanarak erken diyabet tanısına odaklandılar ve önerilen modelleriyle daha iyi sonuçlar bildirdiler [11]. Huma vd. gizli kalıpları ortaya çıkarmak için büyük sağlık veri kümeleri üzerinde Naive Bayes ve Yapay Sinir Ağı gibi gelişmiş makine öğrenme algoritmalarının benimsenmesiyle erken teşhisin önemini vurguladı [12]. Aamir vd. derin öğrenme ve makine öğrenme algoritmalarını kullanarak diyabet öncesi tespiti ele aldı, LSTM ve derin öğrenme yöntemleriyle üstün performans elde etti [13]. Febrian vd. diyabet tahmini için KNN ve Naive Bayes algoritmalarını karşılaştırmış ve çeşitli sağlık özelliklerine dayalı başarılı sonuçlar bildirmiştir [14]. Gollapalli vd. Suudi Arabistan'daki bir hastane veri kümesinde çeşitli makine öğrenimi yöntemlerini kullandı ve Sentetik Azınlık Aşırı Örnekleme Tekniği gibi dengeleme teknikleriyle başarıya ulaştı [15]. Dutta vd. Bangladeş'ten diyabetle ilgili bir veri setine erişerek makine öğrenme yöntemlerini ve hiperparametre optimizasyonunu kullanarak yüksek doğruluk oranlarına ulaştı [16]. Doğru vd. erken diyabet tanısı için birden fazla makine öğrenimi algoritmasını birleştirerek ve sonuçları farklı veri kümelerinde analiz ederek kolektif bir öğrenme modeli önerdi [17]. Panda vd. KNN algoritmasını ve SVM kullanarak yüksek hassasiyetli tahmine odaklanmıştır [18]. Theerthagiri vd. diyabet tahmini için geleneksel sınıflandırma algoritmaları arasında çok katmanlı algılayıcı yöntemlerinin etkinliğini vurgulamıştır [19]. Mahesh vd. diyabet tanısı için çeşitli makine öğrenimi yaklaşımlarını araştırdı, sonuçları klinik sonuçlarla karşılaştırdı ve çeşitli iç görüler elde etmeyi hedefledi. Bu tekniklerin sonuçlarını ve karşılaştırmalarını paylaştılar [20]. Sng vd. ChatGPT'nin diyabet kişisel bakımı ve eğitimindeki rolünü incelemiş ve ChatGPT'nin temel diyabet bakımı ve eğitiminde anlaşılır ve doğru bilgi sağlama potansiyeline ışık tutmuştur [21]. Mohanty vd. çalışmalarında, Açıklanabilir Yapay Zeka (XAI) teknikleri olan LIME, SHAP ve PDP gibi yöntemlerle bu modellerin şeffaflığını artırmayı amaçlamışlardır. Sağlık alanında açıklanabilir yapay zeka kullanımının faydalarını iki vaka analizi üzerinden değerlendirmişlerdir [22]. Payrovnazari vd.'nin yaptığı çalışmada, gerçek dünyadaki elektronik sağlık kaydı verilerini kullanan açıklanabilir yapay zeka (XAI) modelleri sistematik bir şekilde incelenmiştir. Araştırmada, bu tekniklerin farklı biyomedikal uygulamalara göre nasıl kategorize edilebileceği, mevcut çalışmaların hangi eksiklikleri barındırdığı ve gelecekteki araştırma yönlerinin neler olabileceği ele alınmıştır [23]. Albahri vd. sağlık alanında güvenilir ve XAI uygulamalarının değerlendirilmesine yönelik sistematik bir inceleme sunmuşlardır. Yapay zekanın sağlıkta güvenilirliği ve açıklanabilirliği üzerine mevcut araştırma boşluklarını ele almışlardır [24]. Lauritsen ve çalışma arkadaşları, akut kritik hastalıkların erken tespiti amacıyla açıklanabilir bir yapay zeka erken uyarı sistemi (xAI-EWS) geliştirmişlerdir. Bu sistem, elektronik sağlık kaydı verilerinden elde edilen verileri açıklayıcı bilgilerle birlikte sunarak klinik uygulamalara katkı sağlamayı hedeflemiştir. Geleneksel erken uyarı skorlarına (EWS) kıyasla, xAI-EWS, elektronik sağlık kayıtlarını (EHR) kullanarak yüksek doğrulukta tahminler sağlamışlar ve bu tahminleri açıklayarak klinik uygulamalara entegrasyonu kolaylaştırmışlardır [25]. Zhang vd. çalışmasında, diyabet teşhisi için geleneksel yöntemlerin

sınırlamalarını ele alan, geri yayılım sinir ağı (BPNN) temelli bir derin öğrenme yaklaşımını önermişlerdir. Çalışmada, sınıf dengesizliğini gidermek amacıyla veri yeniden örnekleme ve normalizasyon teknikleri kullanılmıştır. Bu yaklaşım, geleneksel makine öğrenimi yöntemlerine kıyasla, hem doğruluk hem de duyarlılık açısından üstün sonuçlar elde etmiştir. Pima diyabet veri setinde %89.81, CDC BRFSS2015 veri setinde %75.49 ve Mesra diyabet veri setinde %95.28 doğruluk oranları elde etmişlerdir [26]. Imrie, Cebere, McKinney ve van der Schaar'ın çalışmasında, teşhis ve prognostik modelleme için geliştirilen AutoPrognosis 2.0 adlı otomatik makine öğrenimi çerçevesi tanıtmışlardır. Çalışmalarında, optimize edilmiş makine öğrenimi süreçlerini, model açıklanabilirliği ve klinik uygulama araçları sunmuşlardır. UK Biobank verileri kullanılarak oluşturulan diyabet risk skoru, geleneksel klinik risk skorlarından daha başarılı bulunmuş ve bir web tabanlı karar destek aracı olarak uygulanmıştır. Çalışma, bu açık kaynaklı çerçevenin klinisyenler için teşhis ve prognostik modeller geliştirmeyi kolaylaştırmayı hedeflediğini vurgulamaktadır [27]. Garcia-Ordás vd. çalışmalarında, diyabetin erken teşhisine yönelik derin öğrenme tabanlı bir yöntem sunmuşlardır. Çalışmada, veri artırımı için varyasyonel bir otoenkoder (VAE), özellik artırımı için seyrek bir otoenkoder (SAE) ve sınıflandırma için bir evrişimli sinir ağı (CNN) kullanılan bir yöntem geliştirmişlerdir. Pima Indians Diabetes Database üzerinde yapılan değerlendirmelerde, dengeli bir veri kümesi kullanılarak SAE ve CNN'in birlikte eğitilmesiyle %92.31 doğruluk oranı elde etmişlerdir [28]. Başer ve ekibi çalışmalarında, diyabetin teşhisinde makine öğrenmesi tekniklerinin kullanımı incelemiştir. Çalışmalarında, 1999-2008 yılları arasında ABD'deki 130 hastaneden elde edilen 70.000 sağlık kaydını içeren bir veri seti düzenlenmiş ve bireylerin diyabet durumlarına göre sınıflandırılmasını yapmışlardır. Bu doğrultuda, veri setine uygun çeşitli makine öğrenmesi algoritmaları uygulanmış ve bu algoritmaların performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, en iyi performansı gösteren beş algoritma (Karar ağaçları, k-en yakın komşuluk, Lojistik regresyon, Naive Bayes ve Rastgele orman) değerlendirilmiş ve doğru sınıflandırmada en iyi sonuç Rastgele orman algoritması ile elde edilmiştir. Çalışma, makine öğrenmesi yöntemlerinin diyabet teşhisindeki etkinliğini vurgulamaktadır [29]. Özkan ve ekibinin yaptıkları çalışmada, diyabet tanısının sınıflandırılmasında denetimli makine öğrenme algoritmalarının performansları karşılaştırılmıştır. Araştırmada, Haziran-Eylül 2013 tarihleri arasında bir devlet hastanesinin endokrinoloji polikliniğine başvuran 18 yaş ve üzerindeki 232 hastadan elde edilen veriler kullanılmıştır. İki farklı yaklaşımla sınıflandırma modelleri oluşturulmuştur: İlkinde istatistiksel olarak anlamlı bulunan 18 değişken, ikincisinde ise endokrinoloji uzmanlarının klinik olarak önemli gördüğü 21 değişken kullanılmıştır. Naive Bayes, rastgele orman, karar ağaçları, destek vektör makineleri, k-en yakın komşuluk, yapay sinir ağları ve çokterimli lojistik regresyon algoritmaları ile sınıflandırmalar gerçekleştirilmiştir. Modeller, doğruluk, duyarlılık, seçicilik, F-ölçütü, ROC eğrisi gibi çeşitli performans ölçütleriyle değerlendirildikten sonra 10-katlı çapraz geçerlilik yöntemiyle test edilmiştir. Analizler WEKA ve R Studio kullanılarak yapılmış ve çalışma süreleri kaydedilmiştir. En iyi performansı, %84.48 ve %81.90 doğruluk oranları ile rastgele orman algoritması göstermiştir [30]. Bilgin yapmış olduğu çalışmasında, diyabetin erken dönemde tanısına yönelik risk tahmin modellerinin geliştirilmesinde makine öğrenmesi algoritmalarının kullanımı incelemiştir. Araştırmada, diyabetin insan sağlığı üzerindeki olumsuz etkilerine dikkat çekilmiş ve erken teşhis ile hastalığın oluşturma potansiyelini azaltılmasının önemi vurgulanmıştır. Çalışmada, 520 denekten alınan verilerle oluşturulan bir veri tabanı kullanılarak diyabete yakalanma olasılığını tahmin etmek için Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Destek Vektör Makineleri, Karar Ağaçları, Doğrusal Ayrımıcı Analizi ve k-NN yöntemleri uygulanmıştır. Bu algoritmalar arasından k-NN metodu %99.81 doğruluk oranıyla en yüksek performansı göstermiştir. Çalışma kapsamında, en yüksek doğruluğu sağlayan algoritma bir

bilgisayar kullanıcı arayüzüne entegre edilerek bir diyabet erken tanı kiti geliştirilmiştir [31]. Ramaha ve Imad'ın çalışmasında, diyabetik retinopati teşhisinde kullanılan bilgisayar destekli karar destek sistemleri incelenmiştir. Çalışma, makine öğrenimi ve derin öğrenme yaklaşımlarının bu alandaki kullanımını derlemiş, bu yaklaşımların önerilen metodolojiler, kullanılan veri setleri ve elde edilen sonuçlar açısından karşılaştırmasını yapmıştır. Diyabetik retinopati, diyabetin bir komplikasyonu olarak dünya çapında milyonlarca insanı etkileyen ve görme kaybına neden olabilen bir hastalık olarak ele alınmıştır. Çalışmada, derin öğrenme tabanlı yöntemlerin, özellikle evrelerin kategorik sınıflandırılmasında, ikili sınıflandırmaya göre daha iyi performans gösterdiği vurgulanmıştır. Ayrıca, mevcut diyabetik retinopati veri setleri değerlendirilmiş ve bu değerlendirmelerin, araştırmacıların gelecekteki çalışmalarında en uygun metodolojileri ve veri setlerini seçmelerine yardımcı olabileceği ifade edilmiştir [32]. Daigavhane ve Gundewar'ın çalışmalarında, diyabetin erken teşhisinde farklı makine öğrenimi sınıflandırıcılarının performanslarını incelemişlerdir. Çalışmada, klinik ve demografik özellikleri içeren kapsamlı bir veri seti kullanılarak Destek Vektör Makineleri, Rastgele Orman, Karar Ağaçları, Naive Bayes ve k-NN algoritmaları değerlendirilmiştir. Sınıflandırıcılar, doğruluk, kesinlik, geri çağırma ve F1-skora dayalı değerlendirme ölçütleriyle karşılaştırılmıştır. Sonuçlar, algoritmalar arasında tahmin doğruluğunda farklılıklar olduğunu ve diyabet tahmini için algoritma seçiminin özenle yapılmasının önemini ortaya koymuştur [33]. Shaukat ve ekibinin çalışmasında, diyabet tahmini için PIMA diyabet veri seti kullanılarak Karar Ağaçları, k-NN, Rastgele Orman, Lojistik Regresyon ve SVM algoritmaları değerlendirilmiştir. WEKA ve Python araçlarıyla yapılan analizlerde, algoritmalar çeşitli performans metrikleriyle karşılaştırılmıştır. Lojistik Regresyon, Python'da %81 ve WEKA'da %80.43 kesinlik oranıyla en iyi sonuçları vermiştir [34]. Albadi ve ekibinin çalışmasında, diyabet teşhisi için hibrit bir makine öğrenimi modeli geliştirilmiştir. Modellerinde, Destek Vektör Makinesi, Karar Ağaçları ve Rastgele Orman sınıflandırıcılarını birleştirerek doğruluğu artırmayı hedeflemişlerdir. Pima Indian Diabetes veri seti üzerinde, glikoz seviyesi, BMI, yaş ve insülin düzeyleri gibi yeni parametreler kullanılarak holdout ve k-fold çapraz doğrulama yöntemleriyle eğitim ve doğrulama yapılmıştır. Hibrit model, holdout yöntemiyle %88.5, k-fold çapraz doğrulama ile %90.1 doğruluk sağlamıştır. Tek başına Karar Ağaçları ve Rastgele Orman algoritmaları ise sırasıyla %76.8 ve %75.3 doğruluk oranı elde etmiştir [35]. Zhuhadar ve Lytras'ın çalışmalarında, diyabet teşhisinde Otomatik Makine Öğrenimi (AutoML) tekniklerinin kullanımı incelemişlerdir. Çalışma, AutoML'nin diyabet risk faktörlerini belirleme, tedavi stratejilerini optimize etme ve hasta sonuçlarını iyileştirme süreçlerinde nasıl sürdürülebilir bir yaklaşım sunduğunu vurgulamıştır. Araştırmada kullanılan veri seti üzerinde, Glikoz, BMI, DiabetesPedigreeFunction ve Kan Basıncı gibi değişkenlerin diyabet durumunu belirlemede en önemli faktörler olduğu belirlenmiştir. AutoML, en uygun modelin seçilmesini sağlayarak tahmin sürecini hızlandırmış, gereksiz test ve prosedürleri azaltarak sağlık hizmetlerinin çevresel etkisini düşürmüştür [36].

Çalışmanın başlıca katkıları aşağıda sunulmuştur.

- Tahmin Modellerinin Bütünsel Değerlendirilmesi: Çalışma, diyabet tahmini için geleneksel ve modern makine öğrenimi modellerini kapsamlı bir şekilde değerlendirmeyi ve her modelin güçlü ve zayıf yönlerini ayırt etmeyi amaçladı. Bu, gelecekteki araştırma ve uygulamalarda önemli tavsiyelerin yolunu açacaktır.
- Sağlam Özellik Önemi Değerlendirmesi: Model performansını anlamak için, çalışma aynı zamanda diyabet tahmininde bireysel özelliklerin önemi üzerinde de durmaktadır. Rastgele Orman ve XGBoost modellerine uygulanan özellik önemi analizi, modelin kararlarını daha anlaşılır kılan kritik faktörleri vurgulamaktadır.

- **Pratik Uygulamalar için Sağlık Perspektifi:** Bu çalışma, teknik yöntemlerin ötesine geçerek, modellerin gerçek dünyadaki sağlık senaryolarında nasıl kullanılabileceğine odaklanarak, teorik gelişmeler ile sağlık uygulamalarındaki somut faydalar arasında köprü kurmaktadır. Sağlık profesyonellerine ve karar vericilere pratik bilgiler sunmayı amaçlamaktadır.
- **Gelecek Yönergelerin İncelenmesi:** Bu çalışma sadece mevcut bulgulara odaklanmakla kalmayıp aynı zamanda diyabet tahmini alanında gelecekteki potansiyel yönelimleri keşfetmeyi de amaçlamaktadır. Modelin uyarlanabilirliğini ve ölçeklenebilirliğini tartışır ve gelecekteki araştırma ve geliştirme için öneriler sunar.
- **Diyabet Tahmin Modellerinin Kapsamlı Değerlendirilmesi:** Sağlık Perspektifleri ile Uzman Değerlendirmesinin Bütünleştirilmesi: Doktor değerlendirmesiyle karşılaştırma yapılan çalışmada, açıklanabilir yapay zeka modellerinin tıp uzmanlarının öncelikleriyle uyumlu olduğu vurgulanmaktadır.

Bu çalışma, diyabet teşhisi için makine öğrenimi modellerinin kullanımı ve açıklanabilir yapay zeka tekniklerinin uygulanmasını ele alan dört ana bölümden oluşmaktadır. Birinci bölümde (Giriş), diyabet teşhisinin önemi ve makine öğrenimi ile açıklanabilir yapay zeka tekniklerinin sağlık alanındaki uygulamaları üzerine genel bir çerçeve çizilmektedir. Bu bölümde, çalışmanın amacı ve literatürdeki mevcut yaklaşımlarla ilişkisi ortaya konulmuştur. İkinci bölümde (Deneyisel Metot), çalışmanın deneyel çerçevesi sunulmakta olup, kullanılan veri seti ve veri işleme adımları detaylandırılmaktadır. İlk olarak, veri setinin özellikleri ve elde ediliş süreçleri açıklanmakta, ardından keşifsel veri analizi kapsamında veri dağılımları ve özniteliklerin genel yapısı incelenmektedir. Bu aşamadan sonra, çeşitli makine öğrenimi algoritmalarının performansları karşılaştırmalı olarak değerlendirilmekte ve bu modellerin sınıflandırma sonuçları ele alınmaktadır. Üçüncü bölümde (Sonuçlar ve Tartışmalar), makine öğrenimi modellerinin uygulamaları neticesinde elde edilen sonuçlar tartışılmakta, her modelin doğruluk ve performans açısından değerlendirilmesi yapılmaktadır. Bu bölüm ayrıca, modellerin şeffaflığını artıran açıklanabilir yapay zeka tekniklerinin etkilerini de irdelemektedir. Dördüncü bölümde (Sonuçlar), çalışmanın genel bulguları ve diyabet teşhisi için makine öğrenimi modellerinin klinik uygulamalardaki potansiyeli üzerinde durulmakta ve bu modellerin sunduğu katkılar üzerine çıkarımlar yapılmaktadır.

2. Deneyisel Metot (Experimental Method)


Bu bölümde, çalışmada kullanılan veri seti, veri işleme adımları ve makine öğrenimi modellerinin uygulanma süreçleri açıklanmıştır. Her bir adım, modeli eğitime ve test etme süreçlerine yönelik olarak detaylandırılmıştır. Dünya çapında birçok kronik hastalık bulunmakla birlikte, diyabet hastalığı en önemli risk faktörlerinden biri olarak kabul edilmektedir. Bu çalışmada, diyabet tahmin sürecinin ilk

aşaması olan Veri Seti aşamasında, diyabet tahmini için uygun bir veri seti belirlenmiş ve bu veri üzerinde çalışmalar gerçekleştirilmiştir. Bir sonraki aşama olan Veri Ön İşleme adımı, veri temizleme, eksik değerlerin doldurulması, özellik seçimi ve özellik ölçeklendirme gibi işlemler gerçekleştirilmiştir. Bu adımlar, veri setinin analiz edilebilir ve makine öğrenimi modelleri için uygun hale getirilmesini sağlamıştır. Ardından çalışmada kullanılan KNN, SVM, Yapay Sinir Ağı, Rastgele Orman, Karar Ağaçları, Naive Bayes ve XGBoost gibi makine öğrenimi algoritmalarının uygulanma süreci detaylandırılmıştır. Bu modeller, diyabet sınıflandırılması için farklı teknikler kullanılarak test edilmiş ve sonuçlar karşılaştırılmıştır. Sınıflandırma adımı, diyabetin doğru bir şekilde sınıflandırılması amacıyla kullanılan teknikler ve bu tekniklerin sağladığı sonuçlar analiz edilmiştir.

Her bir modelin performansı, doğruluk, hassasiyet, duyarlılık ve F1 skoru gibi önemli performans metrikleri kullanılarak detaylı bir şekilde değerlendirilmiştir. Bu metrikler, modelin sınıflandırma yeteneğini farklı açılardan inceleyerek, hangi modelin daha iyi sonuçlar verdiğini belirlemede kritik rol oynamaktadır. Her makine öğrenimi modelinin performansına dair detaylı bir açıklama yapılmış ve hangi modelin daha iyi sonuçlar verdiği ortaya konulmuştur. Son olarak, uzman doktorun ve yapay zeka yöntemlerinin yaptığı tahminler incelenmiş ve elde edilen sonuçlar değerlendirilmiştir. Şekil 1 üzerinde diyabet teşhis sürecinin ve çalışmanın genel süreci gösterilmiştir. Diyabet teşhisi için kullanılan veri seti, ilk olarak veri işleme adımlarından geçirilmiştir. Bu aşamada, eksik verilerin doldurulması, veri temizleme ve ön işleme işlemleri gerçekleştirilmiştir. İşlenen veriler, farklı makine öğrenimi modelleri KNN, SVM, Yapay Sinir Ağları, Rastgele Orman, Karar Ağaçları, XGBoost, Naive Bayes kullanılarak analiz edilmiştir. Her bir model, sınıflandırma yaparak sonuçları sunmuştur. Son aşamada, yapay zeka ve uzman tarafından elde edilen sonuçlar karşılaştırılmış ve genel performans değerlendirilmiştir.

2.1. Veri Seti (Data Set)

Çalışmada kullanılan veri seti, veri bilimcileri ve tıp uzmanları için önemli bir kaynak olan Kaggle platformundan seçilmiştir [37]. Bu veri kümesi, sağlıkla ilgili çeşitli özellikleri barındırmaktadır ve toplamda 2768 kayıt içermektedir. Her bir kayıt noktası, hastalara ait farklı tıbbi parametreler içermektedir. Veri setinde yer alan bu özellikler, diyabetin temel etkilerinin daha iyi anlaşılmasını sağlamaktadır. Hastaların yaşı, soy ağacını, tansiyon ve kan değerleri gibi çeşitli parametreleri analiz edilmiştir. Bu parametrelerin her biri diyabet ile ilişkili önemli faktörler olup, anlamlı özelliklere dönüştürülmüş ve sınıflandırma işlemi gerçekleştirilmiştir. Veri kümesi, Tablo 1'de de gösterildiği üzere, Id, gebelik durumu glikoz seviyesi, kan basıncı, deri kalınlığı, insülin, vücut kitle indeksi, soy



Şekil 1. Diyabet teşhisi sürecinin genel grafiksel özeti (General graphical summary of the diabetes diagnosis process)

ağacı ve yaş olmak üzere çeşitli tıbbi özellikleri içermektedir. Örneğin, Id alanı her kayıt için benzersiz bir kimlik numarasını temsil ederken, glikoz seviyesi diyabetin teşhisinde kritik rol oynamaktadır. Benzer şekilde, kan basıncı ve insülin seviyeleri de diyabet riskini belirlemede önemli parametreler arasında yer almaktadır. Veri setinde 2768 örnek bulunmaktadır. Veri ön işleme sürecinde aşağıdaki adımlar izlenmiştir:

- **Id Sütununun Çıkarılması:** Id sütunu model eğitimi açısından anlam taşımadığından, veri setinden çıkarılmıştır.
- **Eğitim ve Test Verilerinin Ayrılması:** Veri setinin eğitim ve test verileri olarak ayrılması işleminde, veri seti %67 eğitim ve %33 test olmak üzere ikiye bölünmüştür. Bu süreç sonunda eğitim seti 1854 kayıt içerirken, test seti 914 kayıttan oluşmaktadır. Bu bölme, modellerin performanslarını objektif bir şekilde değerlendirmek için gereklidir ve modelin genelleme yeteneğini test seti üzerinden ölçmeye olanak tanımaktadır.

Tablo 1'de yer alan bu özellikler, diyabet erken teşhisi için önemli ipuçları sunmaktadır. Ayrıca, test setinde yer alan 914 kayıt ile eğitim sürecinde modelin performansı test edilmiştir. Özetle, bu veri seti üzerinde yapılan analizler sonucunda, diyabetin erken teşhisine yönelik tahmin modelleri geliştirilmiştir.

Çalışmada kullanılan veri setleri üzerinde eksik değerlerin doldurulması ve ölçekleme adımları uygulanmıştır. Eksik değerler, ilgili değişkenlerin ortalaması alınarak tamamlanmıştır. Ayrıca, veri setleri üzerinde Min-Max normalizasyon yöntemi uygulanarak tüm özellikler [0, 1] aralığına dönüştürülmüştür. Bu işlem, algoritmaların daha hızlı ve kararlı bir şekilde çalışmasını sağlamıştır.

2.2. Veri Analizi Keşfi (Explore Data Analysis)

Bu bölümde, çalışmada kullanılan veri seti detaylı bir şekilde incelenmiştir. Öncelikli hedef, veri setini derinlemesine anlamak ve değişkenler arasındaki ilişkileri ortaya koymaktır. Bu süreçte, veri

kümesinde yer alan sayısal değerler üzerinde çeşitli analizler gerçekleştirilmiş ve değişkenler arasındaki ilişkili yapılar tanımlanmıştır. Veri setindeki değişkenlerin özellikleri incelenmiş ve bu değişkenlerin hangi alanlarla daha güçlü ilişkiler kurabileceği tespit edilmiştir. Tablo 2, veri setinin ayrıntılı analizini sunmakta olup, diyabet verilerindeki değişkenler incelenmiş ve her bir değişkene ait minimum, maksimum, yüzde 25, yüzde 50 ve yüzde 75 dilim değerleri rapor edilmiştir. Bu kapsamlı analiz, her bir değişkenin dağılımını daha iyi kavramamıza ve diyabet tahmininde hangi değişkenlerin daha etkili olduğunu belirlememize olanak sağlamaktadır. Örneğin, glikoz seviyesi, BMI ve insülin gibi değişkenlerin, diyabet teşhisi üzerindeki belirleyici etkisi bu tablo aracılığıyla açıkça gözlemlenebilmektedir.

Veri setindeki değişkenlerin yapıları incelenmiş ve bu değişkenlerin hangi alanlarla daha güçlü ilişkiler kurabileceği gösterilmiştir. Şekil 2'de, diyabet durumu ve özellikleri arasındaki ilişkilerin görsel analizi gösterilmiştir. İlgili görselde, diyabet teşhisi için önemli olan değişkenlerin nasıl etkileşimde olduğu ve verilerin genel dağılımı gösterilmektedir.


Veri setinin bazı bölümlerinin sayısal verilere dönüştürülmesi gerekmektedir. Eksik değerlerin sayısını belirlemek için bu değerlerin sıfır olduğu varsayılmıştır. Benzer şekilde mükerrer kayıt sayısı da 0 olarak görülüyor. Veri setindeki diyabet durumunun "Sonuç" sütununa göre görselleştirilmesi için Seaborn kütüphanesinin ikili grafik fonksiyonu kullanıldı. Bu grafik, her bir özellik çifti için bir nokta bulutu grafiği çizerek diyabet durumunun olası ilişkilerini görsel olarak ortaya koymaktadır. Bu görsel çalışmanın analiz sonuçlarına görsel destek sağlamaktadır. "Kimlik", "Gebelik", "Glikoz", "Kan Basıncı" ve "Cilt Kalınlığı" özelliklerinin dağılımları görselleştirilmiştir. Özellikle "Glikoz" özelliği diyabet riskinin önemli bir belirleyicisi olabilir çünkü kan şekeri düzeyleri diyabet teşhisinde kritik bir ölçümdür. Yüksek tansiyon diyabet riskini artırabileceğinden "Kan Basıncı" özelliği diyabet riskiyle de ilişkilendirilebilir. Bu görseller, veri kümesindeki özelliklerin diyabet durumu üzerindeki etkilerinin daha iyi anlaşılmasına yardımcı olur.

Tablo 1. Veri seti dağılımı (Data set distribution)


Özellik	Açıklama
Id	Veri kümesindeki her kayıt için benzersiz olan kimlik alanı
Gebelikler	Veri setindeki hastanın hamilelik durumu
Glikoz	Glikoz seviyesi
Kan Basıncı	mm Hg cinsinden kan basıncı alanı
Deri Kalınlığı	Deri kalınlığının bulunduğu alan mm cinsinden alınır.
İnsülin	Mu U/ml cinsinden insülin adı verilen insülin alanı
BMI	Vücut kitle indeksi alanı kg olarak
Soyağacı Fonksiyonu	Diyabetin genetik problemini bulmak için şecere alanı
Yaş	Veri kümesindeki hastanın yaşı
Sonuç	Diyabet veya diyabet değil alanı (0 ve 1 çıktı)

Tablo 2. Diyabet verilerinin ayrıntılı analizi (Detailed analysis of diabetes data)


Özellik	Sayı	Anlam	Minimum	(25)%	(50) %	(75) %	Maximum
Id	2768	384.50	1.00	692.75	1384.50	2076.25	2768.00
Hamilelikler	2768	3.74	0.00	1.00	3.00	6.00	17.00
Glikoz	2768	121.10	0.00	99.00	117.00	141.00	199.00
Kan Basıncı	2768	69.13	0.00	62.00	72.00	80.00	122.00
Deri Kalınlığı	2768	20.82	0.00	0.00	23.00	32.00	110.00
İnsülin	2768	80.12	0.00	0.00	37.00	130.00	846.00
BMI	2768	32.13	0.00	27.30	32.20	36.62	80.60
Soyağacı Fonksiyonu	2768	0.47	0.07	0.24	0.37	0.62	2.42
Yaş	2768	33.13	21.00	24.00	29.00	40.00	81.00
Sonuç	2768	0.34	0.00	0.00	0.00	1.00	1.00




Şekil 2. Renklendirilmiş ikili özellik: diyabet durumu ve özellikleri arasındaki ilişkilerin görsel analizi
(Colorized dual feature: visual analysis of relationships between diabetes status and features)



Şekil 3. Sonuç ve özellikler arasındaki korelasyon analizi (Correlation analysis between the outcome and features)



Şekil 4. Sonuç ve özellikler arasındaki korelasyon matrisi (Correlation matrix between the outcome and features)



Şekil 5. Sayısal özelliklerin kutu grafiği analizi (Box plot analysis of the numerical features)

Korelasyon analizi, bir veri çerçevesindeki değişkenler arasındaki ilişkileri anlamak için önemli bir yöntemdir ve genellikle veri bilimi projelerinde sıkça kullanılmaktadır. Bu çalışmada, "Sonuç" değişkeni ile diğer özellikler arasındaki ilişkilerin belirlenmesi, diyabet teşhisi ve tahmini açısından kritik bir öneme sahiptir. Korelasyon analizi sayesinde, hangi özelliklerin "Sonuç" değişkeni üzerinde daha büyük bir etkiye sahip olduğu belirlenmiş ve bu özelliklerin modelin tahmin performansını nasıl etkilediği değerlendirilmiştir. Bu ilişkileri analiz etmek için iki farklı görselleştirme yöntemi kullanılmış olup, Şekil 3'te gösterilmektedir. İlk olarak, veri çerçevesindeki tüm sayısal özellikler arasındaki korelasyon matrisi, bir ısı haritası olarak görselleştirilir. Bu ısı haritası, bir renk şemasındaki her bir özellik çifti arasındaki korelasyonu gösterir. Daha yüksek korelasyonlar daha belirgin bir renkle vurgulanır. İkinci olarak "Sonuç" değişkeninin diğer özelliklerle ilişkisini gösteren bir çubuk grafik oluşturuldu. Bu grafik, her özelliğin "Sonuç" ile ilişkisini gösterir. Çubukların yüksekliği ilişkinin gücünü temsil eder. Grafikte x ekseninde özellik adları gösterilmiştir. Korelasyon katsayıları ise y ekseninde gösterilmiştir. İlgili hücredeki her sayı bir şeyi belirtir. Değişkenler veya özellikler arasında bir katsayı olarak görünür. Olumlu ve olumsuz ilişkilerin bir örneği de verilmektedir. Değerler ne kadar yakınsa ilişki o kadar güçlü olur. Sıfıra yakın değerler korelasyonun düşük olduğunu veya korelasyon olmadığını gösterir. Dolayısıyla tablodaki her hücre değişkenler arasındaki ilişkiyi açıklamak için önemli noktalara işaret etmektedir.

Veri setindeki her bir özelliğin dağılımını göstermek için kutu grafikleri oluşturulmuştur. Kutu grafiği, bir veri kümesindeki değişkenlerin dağılımını ve merkezi eğilimini görselleştirmek için kullanılan bir grafik türüdür. Çalışmada kullanılan değişkenler kutu grafikleri ile açıklanmıştır. Şekil 4'te gösterilen kutu grafikleri, veri setindeki her bir özelliğin dağılımını ve medyan değerlerini ortaya koymaktadır.

- Gebelik Özelliği:** Bu özellik, bireylerin geçirdiği gebelik sayısını ifade etmektedir. Kutu grafiğine göre, gebelik sayısının medyan değeri yaklaşık olarak 3'tür.
- Glikoz Özelliği:** Bireylerin glikoz seviyelerini göstermektedir. Glikoz seviyelerinin medyan değeri yaklaşık olarak 115 mg/dL olarak saptanmıştır.
- Kan Basıncı Özelliği:** Bireylerin kan basıncı düzeylerini temsil etmektedir. Bu özelliğin ortanca değeri, yaklaşık 72,5 mm Hg olarak belirlenmiştir.
- Deri Kalınlığı Özelliği:** Bireylerin cilt kalınlığını ifade etmektedir. Kutu grafiğine göre deri kalınlığının medyan değeri yaklaşık 23 mm olarak tespit edilmiştir.
- İnsülin Özelliği:** İnsülin düzeylerini ifade eden bu özelliğin ortanca değeri, yaklaşık 30 μ U/ml'dir.
- BMI (Vücut Kitle İndeksi):** Vücut kitle indeksini gösteren bu özelliğin medyan değeri, yaklaşık olarak 32 kg/m^2 'dir.

- Soy Ağacı Özelliği:** Diyabetin kalıtsal etkilerini ifade eden bu özelliğin medyan değeri yaklaşık 0,4 olarak hesaplanmıştır.
- Yaş Özelliği:** Bireylerin yaşlarını temsil eden bu özelliğin medyan değeri, yaklaşık olarak 29'dur.
- Sonuç Özelliği:** Bireylerin diyabet tanısı alıp almadığını göstermektedir. Diyabet tanısı alan bireylerin oranı, kutu grafiğine göre yaklaşık %35 civarındadır.

2.3. Makine Öğrenimi Modelleri (Machine Learning Models)

Çalışmanın bu bölümünde, kullanılan makine öğrenmesi yöntemleri detaylı olarak ele alınmış ve her bir modelin uygulama süreçleri, avantajları ve performansları derinlemesine incelenmiştir. Veri seti analiz süreci tamamlandıktan sonra ilgili veri seti farklı yöntemler kullanılarak uygulanmıştır. Bu yöntemler arasında KNN, SVM, Yapay Sinir Ağı, Rastgele Orman, Karar Ağaçları, Naive Bayes ve XGBoost gibi yöntemler bulunmaktadır. Her algoritma, veri setini anlama ve potansiyel diyabet vakalarını belirleme yeteneği açısından dikkatle değerlendirildi.

Tablo 3'de, çalışmamızda kullanılan makine öğrenimi modelleri ve bu modellerin parametre ayarları detaylı bir şekilde sunulmuştur. Bu parametreler, model performansını optimize etmek amacıyla literatürdeki en iyi uygulamalar dikkate alınarak belirlenmiştir. Optimizasyon işlemleri sırasında Grid Search yöntemi kullanılarak, her bir model için en uygun parametreler seçilmiştir. Özellikle, XGBoost modelinde kullanılan öğrenme oranı ve maksimum derinlik parametreleri, veri setine uyum sağlamak için optimize edilmiştir. Destek Vektör Makineleri (SVM) için RBF kernel türü tercih edilerek doğruluk artırılmıştır. Yapay Sinir Ağları için ReLU aktivasyon fonksiyonu ve iki gizli katmanlı yapı, diyabet teşhisi probleminde başarı sağlamıştır. Çalışmada kullanılan makine öğrenimi modellerinin parametre ayarları, Grid Search yöntemiyle optimize edilmiştir. XGBoost için öğrenme oranı (learning rate), maksimum derinlik (max depth) ve n_estimators parametreleri optimize edilerek doğruluk değeri artırılmıştır. SVM için kernel türü ve ceza parametresi (C) optimize edilmiş, RBF kernel kullanılarak doğruluk oranı artırılmıştır. Rastgele Orman algoritmasında, ağaç sayısı (n_estimators) ve maksimum derinlik parametreleri optimize edilmiştir. KNN algoritması için en uygun komşu sayısı belirlenmiştir. Naive Bayes algoritması için varsayılan parametreler kullanılmıştır, çünkü model, parametre ayarlamalarından ziyade veri dağılımına dayalıdır. Yapay Sinir Ağları için öğrenme oranı, gizli katman sayısı ve aktivasyon fonksiyonları optimize edilmiştir. Karar Ağaçları için maksimum derinlik ve dallanma kriterleri ayarlanmıştır. KNN sınıflandırıcısı, sınıflandırma alanında hem temel model hem de referans noktası olarak uzun süredir kullanılan sağlam bir algoritmadır. Basitliğine ve uygulanabilirliğine rağmen KNN sınıflandırıcısı, daha karmaşık makine öğrenimi yöntemleriyle

Tablo 3. Makine Öğrenimi Modelleri ve Parametre Ayarlarının Karşılaştırması
(Comparison of Machine Learning Models and Parameter Settings)

Model İsmi	Parametre	Değer
KNN	Komşu sayısı	5
SVM	Kernel Türü	RBF
Naive Bayes	C (Ceza Parametresi)	1.0
	Dağılım Türü	Gaussian
Yapay Sinir Ağı	Gizli Katman Sayısı	2
	Aktivasyon Fonksiyonu	ReLU
	Öğrenme Oranı	0.01
Karar Ağaçları	Maksimum Derinlik	5
Rastgele Orman	Estimators (Ağaç Sayısı)	100
	Öğrenme Oranı	0.1
XGBoost	Maksimum Derinlik	5
	Estimators (Ağaç Sayısı)	100

karşılaştırıldığında genellikle rekabetçi sonuçlar elde eder. Geleneksel olarak, ön bilgiye dayanmadan, KNN sınıflandırıcıları örnekler arasındaki yakınlığı ölçmek için Öklid mesafelerini kullanır [38].

İstatistik temelli olmasına rağmen yaygın olarak kullanılan ve karşımıza çıkan sınıflandırma yöntemlerinden birisi de Destek Vektör Makinesi algoritmasıdır. İlk kez 1995 yılında Cortes ve Vapnik tarafından yayımlandı. Kaldırılmasının asıl amacının sınıflar arasındaki ayrımı artırmak ve tahmin hatasını en aza indirmek olduğunu belirtmişlerdi. Destek vektör makinesi algoritmalarının çeşitli yetenekleri vardır. En önemli özelliği hem doğrusal hem de doğrusal olmayan verilerle çalışabilmesidir. Bu tür algoritma boyutlandırma bölümündeki sorunlara odaklanır. Bu, yüksek boyutlu uzaylarda etkilidir. Ayrıca küçük veri setlerinin sınıflandırılmasında da rol oynar [39]. Yaygın olarak kullanılan yöntemlerden biri Naive Bayes sınıflandırmasıdır. Dolayısıyla bu yöntem pratiktir. Temel çalışma prensibi olasılık tahminidir. Deneyimlere dayanarak tahminlerde bulunarak olasılıkları bulur. Yöntem, bir durumun varlığı veya yokluğu ile ilgili bir durum olarak karşımıza çıkar. Tercih edilen denetimli öğrenme yöntemidir. Bunun nedeni olasılık tahmini ve esnek yapısıdır [40].

Karar ağacı algoritmaları birçok durum veya örneklerle başlar. Daha sonrasında durumları sınıflandırmak için kullanılacak bir ağaç veri yapısı oluşturur. Her durum, sayısal veya sembolik değere sahip olabilen çeşitli özelliklerle tanımlanır. Karar ağacının çalışma yönteminde her eğitim koşuluna karşılık gelen bir etiket bulunur. Bu etiket ilgili sınıfın adını temsil ederek ilişkilendirilir. En önemli özelliklerinden biri karar verme mekanizmasının bulunmasıdır [41]. Denetimli bir öğrenme türü olan Rastgele Orman modeli, hem sınıflandırma hem de regresyon problemleri için yaygın olarak kullanılan güçlü bir makine öğrenme algoritmasıdır. Model, birden fazla karar ağacının bir araya gelerek oluşturduğu bir yapıya dayanır ve bu sayede daha doğru ve kararlı tahminler elde edilmesine olanak tanır. İstatistiksel öğrenme teorisini temel alan algoritma, ilk eğitim veri kümelerinden birden fazla kopya oluşturmak için rastgele örneklemeye önyüklemeyi kullanır. Algoritma, ormandaki ağaç sayısını temsil eden bir değer seçer, torbalama yöntemini kullanarak önyükleme örnekleri oluşturur ve Gini kriterini kullanarak en uygun bölünmeyi belirler [42]. Rastgele Orman, sağlam bir tahmin modeli oluşturmak için birden fazla karar ağacını ve bunların her biri aracılığıyla yapılan tahminleri etkili bir şekilde birleştirir; bu da onu karmaşık veri kümeleri ve sınıflandırma sorunları için uygun hale getirir.

Sinir Ağı algoritması güçlü bir sınıflandırma yöntemidir. Başarılı bir algoritma farklı sınıfları içerir ve yüksek doğrulukta sınıflandırma sonuçları elde eder. Ayrıca Sinir Ağı, algoritmada kullanılan hiperparametreleri en aza indirir ve aşırı eğitim süresi gerektirmez. Sinir Ağı'nın eğitim ve test doğruluk oranları yüksektir, bu da onu diğer derin öğrenme algoritmalarına kıyasla küçük veri kümeleriyle çalışmayı daha kullanıcı dostu hale getirir [43]. Bu özellikleriyle Sinir Ağları özellikle hızlı, verimli ve doğruluğu yüksek sınıflandırma görevlerinde tercih edilen bir algoritma haline gelmiştir. XGBoost modeli problem çözme, performans ve minimum karmaşıklıkla nedeniyle sektörde yaygın olarak kullanılmaktadır. Derin öğrenme çözümleriyle karşılaştırıldığında XGBoost'un CPU'lardaki küçük verilerle çalışmasının daha kolay olduğu düşünülüyor. XGBoost'un avantajı grafiksel gösterim için güvenilir amaç fonksiyonunda yatmaktadır [44]. Bu modeller veri kümesi karmaşıklığını ele almak için farklı yaklaşımlar sunar. Seçilen çeşitli modeller detaylı olarak değerlendirilir. Model sayısının çok olması sonuçların karşılaştırılmasında önemli bir adımdır. Veri seti, kalıpların ve davranışların daha sağlam bir şekilde araştırılmasına olanak tanır. Modelin genel anlaşılabilirliğini artırmak için çeşitli açıklama ve yorumlar eklenmiş, modellerin güvenilirliği vurgulanmış ve geleceğe yönelik tahminlerde bulunulmuştur.


Bu çalışmada, makine öğrenimi algoritmalarının seçimi, veri setinin özellikleri ve hedeflenen performans kriterleri doğrultusunda yapılmıştır. XGBoost, veri setindeki sınıflar arası ayrımları yüksek doğrulukla gerçekleştirebilmesi ve büyük veri setlerinde hızlı çalışması nedeniyle tercih edilmiştir. Ayrıca, algoritmanın aşırı öğrenmeye dayanıklılığı, karmaşık ilişkileri modelleme kapasitesini artırmıştır. SVM, yüksek boyutlu ve karmaşık veri yapılarında gösterdiği üstün performans ve RBF çekirdek fonksiyonu kullanılarak sağlanan doğruluk artışı ile öne çıkmıştır. Rastgele Orman algoritması, özelliklerin önem sırasını belirleme yeteneği ve dengersiz veri kümelerinde kararlı sonuçlar sunması nedeniyle tercih edilmiştir. KNN algoritması, basit yapısı ve küçük veri setlerinde etkili sonuçlar vermesi sebebiyle kullanılmıştır. Naive Bayes algoritması, özellikle Gaussian dağılım varsayımı altında hızlı ve etkili tahminler sağlamasıyla dikkat çekmiştir. Yapay Sinir Ağları, doğrusal olmayan karmaşık ilişkileri modelleyebilme kapasitesi ve ReLU aktivasyon fonksiyonu ile iki gizli katmanlı yapı kullanılarak optimize edilmiştir. Karar Ağaçları ise veri setinin özelliklerini hiyerarşik olarak ayırabilme kabiliyeti ve yorumlanabilir yapısı nedeniyle tercih edilmiştir. Bu yöntemlerle elde edilen sonuçlar, bir sonraki bölümde tartışılmaktadır.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışma, literatürde yer alan benzer çalışmalarla karşılaştırıldığında çeşitli açılardan önemli farklılıklar göstermektedir. Öncelikle, veri seti işleme süreçlerinde eksik değerlerin doldurulması ve sınıf dengesizliğinin giderilmesi için uygulanan gelişmiş teknikler, model performansını önemli ölçüde artırmıştır. Bunun yanı sıra, SHAP ve LIME gibi açıklanabilir yapay zeka yöntemlerinin entegre edilmesi, modellerin karar süreçlerinin daha şeffaf ve anlaşılır hale gelmesini sağlamıştır. Literatürde genellikle ihmal edilen bu adım, modellerin klinik uygulamalarda daha güvenilir bir şekilde kullanılmasına olanak tanımaktadır.

Diabetes hastalığının erken teşhisi, hastalığın yönetimi ve komplikasyonlarının önlenmesi açısından kritik bir öneme sahiptir. Bu çalışmada, diabetes teşhisini optimize etmek amacıyla KNN, SVM, Yapay Sinir Ağı, Rastgele Orman, Karar Ağaçları, Naive Bayes ve XGBoost gibi çeşitli makine öğrenimi modelleri kullanılarak kapsamlı bir değerlendirme yapılmıştır. Her bir modelin performansı, doğruluk, hassasiyet ve F1 skoru gibi önemli metrikler üzerinden karşılaştırılarak analiz edilmiştir. Değerlendirme sürecinde her bir modelin hedefleri ayrı ayrı irdelenmiştir. Elde edilen bulgular, her uygulamanın avantajlarının ve sınırlamalarının anlaşılmasına yardımcı olacak ve bu modellerin klinik ortamlarda kullanılması konusunda hayati bilgiler sağlayacaktır. Çalışmada elde edilen bulgular, XGBoost modelinin diğer makine öğrenimi modellerine kıyasla en yüksek doğruluk oranına ulaştığını göstermektedir. Bu sonuç, XGBoost'un diabetes teşhisinde özellikle etkili bir yöntem olduğunu ortaya koymaktadır. Ayrıca modele açıklanabilir yapay zeka yöntemlerinden SHAP ve LIME uygulanmıştır. Her iki teknik de programların kararları için güvendiği özellikleri ve tahminlerine en çok hangi özelliklerin katkıda bulunduğunu belirleyerek modele belirgin katkılarda bulunmuştur. Alanında uzman tıbbi görüşlerin dahil edilmesi ve bu sonuçların değerlendirilmesi, bu modellerin klinik uygulamada nasıl kullanılabileceğine dair daha fazla fikir vermektedir. Sonuç olarak bu çalışma, açıklanabilir yapay zeka teknikleri ve uzman tavsiyelerinin yanı sıra diabetes tahmininde kullanılan makine seçeneklerinin değerlendirilmelerini de içeren kapsamlı bir analiz sunmaktadır.

Karışıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir araçtır. Şekil 6'da, çalışmada kullanılan farklı makine öğrenimi modellerinin (KNN, SVM, Naive



Şekil 6. Karışıklık Matrisleri a) KNN, b) SVM, c) Naive Bayes, d) Yapay Sinir Ağı, e) Karar Ağaçları f) Rastgele Orman ve g) XGBoost (Confusion Matrices a) KNN, b) SVM, c) Naive Bayes, d) Neural Network, e) Decision Tree, f) Random Forest and g) XGBoost)


Bayes, Yapay Sinir Ağı, Karar Ağaçları, Rastgele Orman ve XGBoost) test veri seti üzerindeki performansları karışıklık matrisleri ile gösterilmektedir. Her bir karışıklık matrisi, ilgili modelin doğru ve yanlış sınıflandırmalarını görselleştirir ve modellerin performanslarını karşılaştırmamıza olanak tanır. Bu matris, modelin gerçek ve tahmin edilen sınıflarını karşılaştırır ve farklı sınıflandırma sonuçlarını görsel olarak sunar. Genellikle karışıklık matrisi, bir sınıflandırma modelinin doğruluğunu, duyarlılığını, özgüllüğünü ve diğer performans ölçütlerini değerlendirmek için kullanılır. Gerçek sınıf ve tahmin edilen sınıf arasındaki örnek sayısını hücreler içerisinde görmektedir. Matrisin köşegenindeki değerler doğru sınıflandırılmış örnekleri temsil ederken, diğer hücreler yanlış sınıflandırılmış örnekleri göstermektedir. Test veri seti üzerinde performansların gösterilmesinde karışıklık matrisinin önem derecesi yüksektir. Bu matrisler, modelin farklı sınıflar arasındaki performansını görsel olarak sunmakta ve modelin hangi sınıfları ne kadar doğru veya yanlış sınıflandırdığını anlamamıza yardımcı

olmaktadır. Tablo 3, farklı makine öğrenimi modellerinin diyabet veri seti üzerindeki performanslarının doğruluk, F1 skoru, geri çağırma ve hassasiyet gibi metriklerle karşılaştırılmasını sunmaktadır. Sonuçlar, özellikle XGBoost modelinin diğer modellere kıyasla en yüksek doğruluk ve performans değerlerine ulaştığını göstermektedir. Bu tablo, diyabet teşhisinde kullanılan modellerin etkinliğini değerlendirme açısından önemli bir referans sağlamaktadır.


Bu çalışma, çeşitli makine öğrenimi modellerini kullanarak diyabet teşhisinin sonuçlarına odaklanmıştır. Bu modeller arasında XGBoost modeli yüksek doğruluk oranları ve performans metrikleriyle öne çıktı. Ancak modelin karmaşıklığı nedeniyle XGBoost'un belirli bir tahmin yaparken hangi niteliklere odaklandığını anlamak önemlidir. Çalışma sonucunda XGBoost modelinin spesifik bir tahminini açıklamak için LIME ve SHAP metodolojileri tercih edilmiştir. Bu aşamada modelin karmaşık versiyonunun basite indirildiği görülmüştür. Basit model üzerinde detaylı incelemeler yapılmıştır.

Tablo 4. Makine Öğrenimi Modellerinin Diyabet Veri Seti Üzerindeki Performans Karşılaştırması
(Performance Comparison of Machine Learning Models on Diabetes Dataset)


Model İsmi	Performans Metrikleri			
	Doğruluk (%)	F1 Score (%)	Recall (%)	Hassasiyet (%)
KNN	81.18	81.04	81.18	80.95
SVM	75.38	73.53	75.38	74.50
Naive Bayes	75.49	75.16	75.49	74.97
Yapay Sinir Ağı	74.83	71.47	74.83	75.03
Karar Ağaçları	76.91	76.20	76.91	76.16
Rastgele Orman	91.68	91.54	91.68	91.70
XGBoost	98.91	98.91	98.91	98.91



a) SHAP



b) LIME



c) SHAP Özellik Ağırlığı

Şekil 7. XGBoost Modelinin Model Performansı ve SHAP/LIME Açıklanabilirlik Analizi
(Model Performance and SHAP/LIME Explainability Analysis of the XGBoost Model)

LIME açıklanabilir modeller arasında yapay zeka yöntemleri arasındadır. Çalışma mantığı sorguların girişlerini değiştirerek çalışmaktadır. Bu şekilde çalıştığında modelin tamamını açıklamak yerine modelin belirli kısımları üzerinde çalışmaktadır [45]. Lundberg ve Lee tarafından 2017 yılında sunulan SHAP yöntemi de açıklanabilir bir yapay zeka yöntemidir. SHAP yöntemi, belirli bir parça yerine her özelliğe önem değerleri atayarak çalışmaktadır [46].

Çalışmada modelin içsel karar süreci açıklanabilirlik uygulanarak değerlendirilmiştir. LIME ve SHAP gibi yöntemler XGBoost uygulamalarıyla ayrılmış bir desen modeli üzerinde öğretilmektedir. Elde edilen sonuçların, modele özel bir tahmin oluşturulurken her iki açıklanabilirlik tekniğinin hangi özelliklere odaklandığını ve bu özelliklerin tahmin üzerindeki etkilerini göstermesi amaçlanmıştır. LIME tarafından üretilen açıklamalar, belirli bir tahminin olasılığını etkileyen özelliklerin yerel etkilerini gösterir. Bu işlemlerin yapılma nedeni tahmin olasılığının anlaşılmasını sağlamaktır. Olasılığı artıran ve azaltan faktörler ilk sırada gelmektedir. SHAP, etkili açıklanabilir yapay zeka yöntemleri arasında ilk sırada yer almaktadır. SHAP çalışması incelendiğinde özelliklerin tahmine katkısı açıkça görülmektedir. Vücut kitle indeksi ve hamilelik gibi değişkenlerin model tahminine etkisi gösterilmiştir. Diğer bir değişken olan kan şekeri ise olumsuz etki yaptığı gösterilmiştir. Bu sonuçlar ve SHAP özelliğinin sonuçları sayesinde karar süreçleri kolaylaşmıştır. Daha geniş bir bakış açısı sunulmakta ve performans analizleri sağlanmaktadır. Şekil 7.a'da, SHAP değerleri yardımıyla her bir özelliğin model çıktısına olan etkisi detaylı bir şekilde analiz edilmiştir. Bu grafikte, pozitif SHAP değerleri tahmini pozitif yönde etkilerken, negatif SHAP değerleri tahminin olumsuz yönde etkilediğini göstermektedir. Özellikle Glikoz seviyesi, model tahminini en güçlü şekilde etkileyen negatif bir özelliktir. Şekil 7.b, LIME kullanılarak yapılan analiz sonucunda, her bir özelliğin model çıktısına olan önem düzeyini görselleştirmektedir. Özelliklerin model tahminlerine katkıları bu grafik ile net bir şekilde ortaya konulmuştur. LIME, her bir tahmin için yerel açıklamalar sağlarken, SHAP daha genel bir bakış açısı sunar. Burada ID, Hamilelik ve Kan Basıncı gibi özelliklerin model üzerindeki ağırlığı gösterilmiştir. Şekil 7.c ise SHAP değerlerinin özellik ağırlıkları ile görselleştirildiği grafiklerdir. Yüksek ve düşük değerlerin özellikler üzerindeki etkisi renk skalası ile gösterilmiştir. Özellikle BMI, Glikoz ve İnsülin gibi özelliklerin tahmin üzerindeki etkileri detaylı bir şekilde sunulmuştur. Bu görselleştirme, modelin hangi özelliklere dayandığını daha anlaşılır hale getirmektedir.

Çalışmada, öznelitliklerin diyabet teşhisi üzerindeki etkileri karşılaştırmalı olarak ele alınmıştır. Yapay Zeka ve uzman doktor tarafından yapılan sıralamalar, öne çıkan önemli faktörleri değerlendirmektedir. Hem yapay zeka hem de uzman doktor analizlerinde, Glikoz, BMI ve Yaş en kritik öznelitlikler olarak öne çıkmaktadır. Ancak her iki sıralamada da Hamilelik ve Kan Basıncı gibi özellikler önemli rol oynamaktadır. Cilt Kalınlığı ve İnsülin gibi özelliklerin etkisi, yapay zeka ve uzman arasında hafif farklılıklar göstermektedir. Bu karşılaştırma, hem modelin hem de uzmanların benzer değerlendirmelere sahip olduğunu, ancak bazı öznelitliklerde farklı öncelikler tanıdıklarını ortaya koymaktadır. Bu sonuçlar Şekil 8'de görsel olarak sunulmuştur.


Açıklanabilir yapay zeka yöntemleri, kullanılan modellerdeki karar yapılarını anlamak ve belirli tahminlerin neden yapıldığını açıklamak açısından kritik öneme sahiptir. Bu yöntemler, modelin daha şeffaf ve anlaşılır olmasını sağlar. Aynı zamanda, modelin performansının iyileştirilmesine de katkıda bulunarak, yanlış sınıflandırmalar ve doğruluk oranındaki eksikliklerin tespit edilmesine yardımcı olur. Böylelikle, modelde var olan potansiyel sorunlar veya iyileştirme alanları net bir şekilde belirlenebilir ve gerekli düzeltmeler yapılabilir.

Tablo 5'te yer alan çalışmalarda diyabet teşhisinde kullanılan çeşitli makine öğrenimi modellerinin doğruluk oranları karşılaştırılmaktadır. Rastogi vd. Logistic Regression algoritması ile %82.46 doğruluk oranına ulaşmış ve yöntemin doğrusal sınıflandırma varsayımı, karmaşık veri ilişkilerini modellemede sınırlı kalmıştır. Reddy vd. KNN algoritması ile %80.80 doğruluk oranı elde etmiş, ancak veri setinin boyutuna olan hassasiyet, performans üzerinde olumsuz etkiler yaratmıştır. Bansal vd. tarafından yapılan çalışmada Logistic Regression algoritması %75.32 doğruluk oranı sağlamış, ancak eksik veri yönetimi ve sınırlı veri ön işleme süreçleri performansı etkilemiştir. Nass vd. ise SVM algoritmasını kullanarak %78.00 doğruluk oranına ulaşmış, kernel seçimi ve sınıf dengesizliği gibi metodolojik farklılıklar performansı sınırlamıştır. Khanam vd. K-NN algoritmasını %79.42 doğruluk oranıyla değerlendirmiş ve yöntemin yüksek işlem süreleriyle performans kısıtlamaları yaşadığı belirtilmiştir. Nahzat vd. Random Forest algoritmasını %88.31 doğruluk oranıyla uygulamış, ancak sınırlı hiperparametre optimizasyonu nedeniyle daha iyi performans elde edilememiştir. Cihan vd. Logistic Regression algoritmasını %80.80 doğruluk oranı ile kullanmış, veri ön işleme eksiklikleri doğruluk oranlarını etkilemiştir. Daha ileri tekniklerin kullanıldığı çalışmalarda, Modak vd. XGBoost algoritmasını %94.30 doğruluk oranıyla uygulamış ve sınıf dengesizliği ile karmaşık veri ilişkilerinde önemli başarılar elde etmişlerdir. Ancak, hiperparametre optimizasyon süreçlerinin eksik detaylandırılması, sonuçların genel karşılaştırmasını zorlaştırmıştır. Rahaman vd. Random Forest algoritması ile %81.00 doğruluk oranına ulaşmış, ancak sınıf dengesizliği problemleri nedeniyle sonuçlar sınırlı kalmıştır.

Rastogi vd. Reddy vd. Modak vd. Rahaman vd. çalışmaları, yapılan çalışma ile aynı veri setini kullanarak diyabet teşhisi üzerine yapılan analizler arasında dikkat çekmektedir. Bu çalışmaların her biri farklı makine öğrenimi algoritmaları ve yöntemler kullanarak veri seti üzerinde performans değerlendirmesi yapmıştır. Ancak, veri ön işleme teknikleri, sınıf dengesizliği sorunlarının ele alınması ve hiperparametre optimizasyon süreçlerindeki farklılıklar, çalışmamızda elde edilen sonuçları literatürdeki diğer çalışmalardan ayıran temel unsurlardır. Çalışmamız, aynı veri seti üzerinde %98.91 doğruluk oranıyla literatürdeki en yüksek performansı sağlayarak, XGBoost algoritması ve açıklanabilir yapay zeka yöntemlerinin etkinliğini ortaya koymaktadır.

Çalışmamızda kullanılan XGBoost algoritması ise, literatürdeki çalışmalara kıyasla %98.91 doğruluk oranı ile en iyi performansı sergilemiştir. Özellikle, veri ön işleme adımları, hiperparametre optimizasyonu ve açıklanabilir yapay zeka yöntemlerinin entegrasyonu (SHAP ve LIME), modelin performansını artıran temel faktörlerdir. Bu durum, XGBoost'un sınıf dengesizliğini giderme ve karmaşık veri ilişkilerini modellemede sağladığı üstünlüğü açıkça göstermektedir.

XGBoost'un üstün performansı, algoritmanın ağaç tabanlı yapısıyla verideki ilişkileri daha iyi modelleyebilmesine dayanmaktadır. Algoritmanın, sınıflar arasındaki sınırları daha net bir şekilde belirlemesi ve aşırı öğrenmeye karşı dayanıklılığı, doğruluk oranlarının artmasına katkıda bulunmuştur. Ayrıca, çalışmamızda SHAP ve LIME yöntemleri kullanılarak, XGBoost modelinin karar verme süreçleri detaylı bir şekilde incelenmiştir. Bu yöntemler, modelin hangi özelliklere daha fazla önem verdiğini açıklamış ve modelin güçlü yönlerini belirgin hale getirmiştir. Önerilen çalışmada kullanılan XGBoost algoritması, %98.91 gibi oldukça yüksek bir doğruluk oranı ile diğer çalışmalara karşılaştırıldığında üstün bir performans sergilemiştir. Bu sonuç, XGBoost'un genel modelleme kapasitesinin diğer yöntemlere kıyasla daha güçlü olduğunu göstermektedir. Bununla birlikte, XGBoost'un özellikle büyük veri setlerinde ve karmaşık yapısal verilere sahip durumlarda başarılı



Şekil 8. Diyabet Tanısında Öncelikli Faktörlerin Açıklanabilir Yapay Zeka (SHAP) ve Uzman Yorumlarıyla Karşılaştırılması
(Comparison of Priority Factors in Diabetes Diagnosis with Explainable Artificial Intelligence (SHAP) and Expert Comments)

Tablo 5. Aynı ve Benzer Veri Setlerini Kullanan Çalışmalardaki Modellerin Karşılaştırılması
(Comparison of Models in Studies Using Same and Similar Data Sets)

Çalışma İsmi	Metot	Doğruluk (%)	Farklılıklar
Rastogi vd. [47]	Logistic Regression	82.46	Doğrusal sınıflandırma varsayımı, karmaşık veri ilişkilerinde sınırlamalar.
Reddy vd. [48]	K-NN	80.80	Yüksek boyutlu veri setlerinde performans düşüklüğü.
Bansal vd. [49]	Logistic Regression	75.32	Eksik veri yönetimi eksiklikleri performansı düşürmüştür.
Nass vd. [50]	Support Vector Machine	78.00	Kernel seçimi ve sınıf dengesizliğine duyarlılık etkileri gözlenmiştir.
Khanam vd. [51]	K-NN	79.42	Veri seti büyüklüğüne karşı hassasiyet ve yüksek işlem süreleri.
Nahzat vd. [52]	Random Forest	88.31	Daha iyi performans için sınırlı hiperparametre optimizasyonu yapılmıştır.
Cıhan vd. [53]	Logistic Regression	80.80	Veri ön işleme eksiklikleri nedeniyle doğruluk sınırlı kalmıştır.
Modak vd. [54]	XGBoost	94.30	Hiperparametre optimizasyonunun eksik detayları.
Rahaman vd. [55]	Random Forest	81.00	Sınıf dengesizliğine duyarlılık gözlenmiştir.
Önerilen Yöntem	XGBoost	98.91	Parametre optimizasyonu, veri ön işleme ve açıklanabilir yapay zeka entegrasyonu.

olduğu literatürde de desteklenmektedir. Sonuç olarak, makine öğrenimi modellerinin diyabet teşhisi alanındaki başarısı, modelin yapısına, kullanılan veri setinin özelliklerine ve veri ön işleme adımlarına bağlıdır. Literatürdeki çalışmalarla yapılan bu karşılaştırmalar, önerilen XGBoost modelinin diyabet teşhisi için etkili bir araç olabileceğini ve klinik uygulamalarda güvenilir sonuçlar verebileceğini göstermektedir. Bu bulgular, çalışmamızın özgün yönlerini daha iyi anlamamıza yardımcı olmaktadır ve sonuç bölümünde özetlenmiştir.

Gelecek çalışmalarda, önerilen yöntemin farklı tıbbi veri setleri üzerinde uygulanması, modelin genelleme performansını daha geniş bir kapsamda değerlendirmek için önemli bir fırsat sunacaktır. Ayrıca, SHAP ve LIME gibi açıklanabilir yapay zeka yöntemlerinin diğer tıbbi teşhis süreçlerinde uygulanması, yapay zeka temelli sistemlerin güvenilirliğini artırabilir. Bunun yanı sıra, gerçek zamanlı teşhis sistemlerinin geliştirilmesi, bu modellerin klinik uygulamalarda daha yaygın kullanılmasını mümkün kılabilir. Çalışmamız, bu tür

uygulamalar için temel bir çerçeve sunmakta ve gelecekteki çalışmalara yön vermektedir.

3.1. Önerilen Yöntemin Avantajları ve Motivasyonları (Advantages and Motivations of the Proposed Method)

Önerilen yöntem, literatürde yaygın olarak karşılaşılan sınıf dengesizliği, eksik veri yönetimi ve model genelleştirme problemleri gibi temel zorlukları çözmeye yönelik bir motivasyonla geliştirilmiştir. Veri ön işleme aşamasında kullanılan Min-Max normalizasyonu ve eksik değer doldurma teknikleri, veri setindeki dengesizlikleri gidererek modellerin daha kararlı bir şekilde çalışmasını sağlamıştır. Makine öğrenimi modellerinin şeffaflığını artırmak için SHAP ve LIME gibi açıklanabilir yapay zeka yöntemleri entegre edilmiştir. Bu yöntemler, model kararlarının anlaşılabilirliğini artırarak klinik uygulamalarda kullanılabilirliği desteklemektedir. Örneğin, SHAP analizleri sayesinde XGBoost algoritmasının hangi özellikleri öncelikli olarak değerlendirdiği açık bir şekilde ortaya

konmuştur. Mevcut yöntemlerin aksine, XGBoost algoritması %98.91 doğruluk oranıyla literatürde bildirilen Logistic Regression (%82.46) ve KNN (%80.80) gibi yöntemleri önemli ölçüde geride bırakmıştır. Ayrıca, XGBoost'un aşırı öğrenmeye karşı dayanıklı yapısı, diğer yöntemlerde sıkça karşılaşılan genelleştirme problemlerini ortadan kaldırmıştır. Bu avantajları sayesinde önerilen yöntem, yalnızca yüksek doğruluk oranları sunmakla kalmayıp, aynı zamanda şeffaf ve güvenilir bir yapay zeka çözümü sunmaktadır.

4. Sonuçlar (Conclusions)

Bu bölümde, farklı makine öğrenimi modellerinin performans karşılaştırmaları sunulmuş ve en iyi sonucu veren modelin özellikleri tartışılmıştır. Sonuçlar, modellerin klinik uygulamalardaki potansiyel kullanımına ışık tutmaktadır. Sonuçlar, çeşitli makine öğrenimi modellerinin diyabet teşhisinde etkinliğini ve bu modellerin bu karmaşık sorunu çözmedeki çeşitli yeteneklerini ortaya koymaktadır. Önemli olanın belirli bir sorun bağlamında en uygun modelin seçilmesi olduğunu vurgulanmaktadır. Yalnızca doğruluğun değil, aynı zamanda bu karmaşık ölçümlerin de incelenmesi, modellerin güçlü ve zayıf yönlerine ilişkin iç görüler sağlamaktadır. Bu incelikli model değerlendirme yaklaşımı, performanslarının daha sağlam bir şekilde anlaşılmasına katkıda bulunur ve diyabet teşhis sorununun benzersiz özelliklerine uyan en uygun çözümün seçilmesinde rehberlik eder. DM kılavuzlarında risk faktörlerini içeren anketler kullanılarak kişilerin gelecekte DM geliştirme risklerinin hesaplanması ve komplikasyonlar başlamadan yaşam tarzı değişikliği tedavisinin planlanması önerilmektedir. Bu amaçla en sık kullanılan FINDRISK (Finnish Diabetes Risk Score) anketinde yaş, vücut kitle indeksi, bel çevresi, egzersiz düzeyi, meyve ve sebze tüketimi, tansiyon düzeyi gibi sorulara puan verilerek toplam risk puanı hesaplanabilmektedir.

Çevresel faktörlerin diyabet üzerinde etkisi bulunmaktadır. Bu etkiler tip 2'de görülmektedir. Toplamların birçok kritik noktayı benimsemesi bunlara yol açmıştır. Modern yaşam tarzından, insanların aktif hareketlerinin azalmasına kadar pek çok faktör vardır. Yüzyılın üçüncü çeyreğine bakıldığında besinlerde farklılıklar görülmektedir. Hızlı hazırlanıp tüketilen, lif oranı düşük, yağ ve kalorisi yüksek gıdaların önemi arttı. Bu artış diyabetin görülmeye sıklığı ve sıklığının artması için kaçınılmaz hale gelmiştir. Bu nedenlerin ortaya çıkması tip 2 diyabeti de etkilemiştir. Bu nedenlerin bir sonucu olarak bazı önlemlerin alınması için kapsamlı çalışmalar yapılmıştır. 'Da Qing Diyabet ve IGT' başlıklı çalışma önleme çalışmaları alanına giriyor. Bu 1997 araştırması Çin'de IGT'li kişiler üzerinde gerçekleştirildi. Araştırmada %40'ı diyet ve egzersiz diyabet üzerinde etkili olduğunu söyledi [56]. Başka bir çalışma olan Finlandiya Diyabet Önleme Çalışması (FDPS) 2001 yılında yürütüldü ve yayınlandı. Bu program, IGT'li obez veya fazla kilolu hastalara dayanmaktadır. Tip 2 diyabet türünde yapılan çalışmalarda risk oranının %58 oranında azaltılabileceği ifade edilmiştir [57]. Sonuçları 2003 yılında Amerika Birleşik Devletleri ve Kanada'da yayınlanan ve aşırı kilolu veya obez IAD veya IGT'li bireyleri kapsayan Diyabet Önleme Programı (DPP) çalışmasında yoğun yaşam değişiklikleri ile diyabet riski %58 iken, bu oran %31 olarak bulunmuştur. metformin ile %. Oranın azaldığı bildirilmektedir [58]. Daha sonra yayınlanan bu çalışmaların uzun dönemli takip raporları, koruyucu etkinin yıllar sonra bile devam ettiğini gösterdi. Da Qing çalışmasının 30. yılında korumanın yaşam tarzı değişikliği grubunda %30, FDPS'nin 7. yılında %43, DPP'nin (DPPOS) 10. yılında %34, DPP'nin (DPPOS) 10. yılında ise %27 olarak devam ettiği görüldü. 15. yılda % [59]. Bu çalışmalarda yaşam tarzı değişikliğinin hedeflediği iki ana unsur, ilk 6 ayda %7 kilo kaybı ve haftada en az 150 dakika orta tempolu egzersiz (tempolu yürüyüş gibi). Yine kalori hedefleri bireyin günlük beslenme alışkanlıkları ve vücut kitle indeksi dikkate alınarak toplam kalori alımının 500-1000 kalori altında olacak şekilde planlanmaktadır. Egzersiz olarak haftada

ortalama 700 kcal kaybetmek amacıyla haftada en az 3 gün ve toplam 150 dakika (10 dakikanın altına düşmemek kaydıyla) uygulandı. Metabolik hedeflere ulaşmak için Akdeniz diyeti, düşük karbonhidrat diyeti, bitki bazlı diyet ve Hipertansiyonu Durdurmaya Yönelik Diyet Yaklaşımları gibi çok sayıda beslenme modeli üzerinde çalışmalar yapılmış ve çoğunda benzer olumlu sonuçlar elde edilmiştir. Yine hasta tercihiyle dayalı çalışmalarla faydaları kanıtlanmış teknoloji destekli yaşam tarzı değişikliği programlarının özellikle içinde bulunduğumuz pandemi döneminde etkili olabileceğini gösteren çalışmalar mevcut.

Bu araştırma, diyabet teşhisi için farklı makine öğrenimi modellerini ve sonuçlarını değerlendirmiştir. Çalışma sonucunda her modelin farklı doğruluk oranlarına sahip olduğu ortaya çıkmıştır. Kullanılan modeller arasında; KNN, SVM, Naive Bayes, Yapay Sinir Ağları, Karar Ağaçları, Rastgele Orman ve XGBoost performans açısından karşılaştırılmış ve her birinin güçlü ve zayıf yönleri belirlenmiştir. Sonuç olarak, XGBoost modeli en yüksek doğruluk oranı ile diğer modellerden üstün performans sergilemiştir. Rastgele Orman ise belirli ölçütlerde başarılı sonuçlar vermiştir, ancak XGBoost diğer ölçümlerde beklenenden daha yüksek performans göstermiştir. Sonuçlar, makine öğrenimi modellerinin diyabet teşhisinde etkili bir şekilde kullanılabileceğini ve XGBoost'un bu alanda en başarılı model olduğunu göstermektedir. Gelecekteki çalışmalar, bu modellerin daha büyük ve daha çeşitli veri setleri üzerinde uygulanarak genel güvenilirliğinin ve uygulanabilirliğinin artırılmasını hedefleyebilir.

Teşekkür (Acknowledgement)

Bu çalışma Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından ADEP.23.21 proje numarası ile desteklenmektedir.

Kaynaklar (References)

1. Fetzer, J. H., Fetzer, J. H., What is Artificial Intelligence?, Springer Netherlands, 3-27, 1990.
2. Song, C., Ristenpart, T., Shmatikov, V., Machine learning models that remember too much. In Proceedings of the 2017 ACM SIGSAC Conference on computer and communications security, 587-601, 2017.
3. Egan, A. M., Dinneen, S. F., What is diabetes?. Medicine, 47 (1), 1-4, 2019.
4. Tuomilehto, J., Lindström, J., Eriksson, J. G., Valle, T. T., Hämäläinen, H., Ilanne-Parikka, P., ... Uusitupa, M., Prevention of type 2 diabetes mellitus by changes in lifestyle among subjects with impaired glucose tolerance. New England journal of medicine, 344 (18), 1343-1350, 2001.
5. Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., Yang, G. Z., XAI-Explainable artificial intelligence. Science robotics, 4 (37), eaay7120, 2019.
6. Nishat, M. M., Faisal, F., Mahbub, M. A., Mahbub, M. H., Islam, S., Hoque, M. A., Performance assessment of different machine learning algorithms in predicting diabetes mellitus. Biosc. Biotech. Res. Comm, 14 (1), 74-82, 2021.
7. Kaleem, H., Liaqat, S., Hassan, M. T., Mehmood, A., Ahmad, U., Ditta, A., An Intelligent Healthcare system for detecting diabetes using machine learning algorithms. Lahore Garrison University Research Journal of Computer Science and Information Technology, 6 (03), 1-11, 2022.
8. Shabtari, M. M., Shukla, V. K., Singh, H., Nanda, I., Analyzing PIMA Indian Diabetes Dataset through Data Mining Tool 'RapidMiner'. In 2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), 560-574, IEEE, 2021.
9. Azbeg, K., Boudhane, M., Ouchetto, O., Jai Andaloussi, S., Diabetes emergency cases identification based on a statistical predictive model. Journal of Big Data, 9 (1), 1-25, 2022.
10. Lukmanto, R. B., Nugroho, A., Akbar, H., Early detection of diabetes mellitus using feature selection and fuzzy support vector machine. Procedia Computer Science, 157, 46-54, 2019.

11. Zhu, C., Idemudia, C. U., Feng, W., Improved logistic regression model for diabetes prediction by integrating PCA and K-means techniques. *Informatics in Medicine Unlocked*, 17, 100179, 2019.
12. Naz, H., & Ahuja, S., Deep learning approach for diabetes prediction using PIMA Indian dataset. *Journal of Diabetes & Metabolic Disorders*, 19, 391-403, 2020.
13. Aamir, Z., Murtza, I., Pre-Diabetic Diagnosis from Habitual and Medical Features using Ensemble Classification. *Journal of Computing & Biomedical Informatics*, 5 (01), 283-294, 2023.
14. Febrian, M. E., Ferdinan, F. X., Sendani, G. P., Suryanigrum, K. M., Yunanda, R., Diabetes prediction using supervised machine learning. *Procedia Computer Science*, 216, 21-30, 2023.
15. Gollapalli, M., Alansari, A., Alkhorasani, H., Alsubaii, M., Sakloua, R., Alzahrani, R., ... Albaker, W., A novel stacking ensemble for detecting three types of diabetes mellitus using a Saudi Arabian dataset: Pre-diabetes, T1DM, and T2DM. *Computers in Biology and Medicine*, 147, 105757, 2022.
16. Dutta, A., Hasan, M. K., Ahmad, M., Awal, M. A., Islam, M. A., Masud, M., Meshref, H., Early prediction of diabetes using an ensemble of machine learning models. *International Journal of Environmental Research and Public Health*, 19 (19), 12378, 2022.
17. Doğru, A., Buyrukoğlu, S., Ari, M., A hybrid super ensemble learning model for the early-stage prediction of diabetes risk. *Medical & Biological Engineering & Computing*, 61 (3), 785-797, 2023.
18. Panda, M., Mishra, D. P., Patro, S. M., Salkuti, S. R., Prediction of diabetes disease using machine learning algorithms. *IAES International Journal of Artificial Intelligence*, 11 (1), 284, 2022.
19. Theerthagiri, P., Ruby, A. U., Vidya, J., Diagnosis and classification of the diabetes using machine learning algorithms. *SN Computer Science*, 4 (1), 72, 2022.
20. Mahesh, T. R., Vivek, V., Kumar, V. V., Natarajan, R., Sathya, S., Kanimozhi, S., A comparative performance analysis of machine learning approaches for the early prediction of diabetes disease. In 2022 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI), 1-6, IEEE, 2022.
21. Sng, G. G. R., Tung, J. Y. M., Lim, D. Y. Z., Bee, Y. M., Potential and pitfalls of ChatGPT and natural-language artificial intelligence models for diabetes education. *Diabetes Care*, 46 (5), e103-e105, 2023.
22. Mohanty, A., Mishra, S., A comprehensive study of explainable artificial intelligence in healthcare. In *Augmented Intelligence in Healthcare: A Pragmatic and Integrated Analysis*, Singapore: Springer Nature Singapore, 475-502, 2022.
23. Payrovnaziri, S. N., Chen, Z., Rengifo-Moreno, P., Miller, T., Bian, J., Chen, J. H., ... He, Z., Explainable artificial intelligence models using real-world electronic health record data: a systematic scoping review. *Journal of the American Medical Informatics Association*, 27 (7), 1173-1185, 2020.
24. Albahri, A. S., Duham, A. M., Fadhel, M. A., Alnoor, A., Baqer, N. S., Alzubaidi, L., ... Deveci, M., A systematic review of trustworthy and explainable artificial intelligence in healthcare: Assessment of quality, bias risk, and data fusion. *Information Fusion*, 2023.
25. Lauritsen, S. M., Kristensen, M., Olsen, M. V., Larsen, M. S., Lauritsen, K. M., Jørgensen, M. J., ... Thiesson, B., Explainable artificial intelligence model to predict acute critical illness from electronic health records. *Nature communications*, 11 (1), 3852, 2020.
26. Zhang, Z., Ahmed, K. A., Hasan, M. R., Gedeon, T., Hossain, M. Z., A deep learning approach to diabetes diagnosis. In *Asian Conference on Intelligent Information and Database Systems*, Singapore: Springer Nature Singapore, 87-99, 2024.
27. Imrie, F., Cebere, B., McKinney, E. F., van der Schaar, M., AutoPrognosis 2.0: Democratizing diagnostic and prognostic modeling in healthcare with automated machine learning. *PLOS Digital Health*, 2 (6), e0000276, 2023.
28. García-Ordás, M. T., Benavides, C., Benítez-Andrades, J. A., Alaiz-Moretón, H., García-Rodríguez, I., Diabetes detection using deep learning techniques with oversampling and feature augmentation. *Computer Methods and Programs in Biomedicine*, 202, 105968, 2021.
29. Başer, B. Ö., Yangın, M., Sarıdaş, E. S., Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25 (1), 112-120, 2021.
30. Özkan, Y., Yürekli, B. S., Suner, A., Diyabet tanısının tahminlenmesinde denetimli makine öğrenme algoritmalarının performans karşılaştırması. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 12 (1), 211-226., 2022.
31. Bilgin, G., Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması. *Journal of Intelligent Systems: Theory and Applications*, 4 (1), 55-64, 2021.
32. Ramaha, N., Imad, S., Derin Öğrenmeye Karşı Makine Kullanarak Diyabetik Retinopati Teşhisi. *Avrupa Bilim ve Teknoloji Dergisi*, 51, 301-313, 2021.
33. Daigavhane, M. K., Gundewar, S., Diabetes Prediction using Different Machine Learning Classifiers. In 2024 Parul International Conference on Engineering and Technology (PICET), 1-6, IEEE, 2024.
34. Shaukat, Z., Zafar, W., Ahmad, W., Haq, I. U., Husnain, G., Al-Adhaileh, M. H., ... Algarni, A., Revolutionizing Diabetes Diagnosis: Machine Learning Techniques Unleashed. In *Healthcare*, 11 (21), 2864 MDPI, 2023.
35. Albadri, R. F., Awad, S. M., Hameed, A. S., Mandeel, T. H., Jabbar, R. A., A Diabetes Prediction Model Using Hybrid Machine Learning Algorithm. *Mathematical Modelling of Engineering Problems*, 11 (8), 2024.
36. Zhuhadar, L. P., Lytras, M. D., The application of AutoML techniques in diabetes diagnosis: current approaches, performance, and future directions. *Sustainability*, 15 (18), 13484, 2023.
37. <https://www.kaggle.com/datasets/nanditapore/healthcare-diabetes> (Access Date: 10.01.2024)
38. Song, Y., Huang, J., Zhou, D., Zha, H., Giles, C. L., Iknn: Informative k-nearest neighbor pattern classification. In *European conference on principles of data mining and knowledge discovery*, Berlin, Heidelberg: Springer Berlin Heidelberg, 248-264, 2007.
39. Gollapalli, M., Alansari, A., Alkhorasani, H., Alsubaii, M., Sakloua, R., Alzahrani, R., ... Albaker, W., A novel stacking ensemble for detecting three types of diabetes mellitus using a Saudi Arabian dataset: Pre-diabetes, T1DM, and T2DM. *Computers in Biology and Medicine*, 147, 105757, 2022.
40. Kadar, J. A., Agustono, D., Napitupulu, D., Optimization of candidate selection using naïve Bayes: case study in company X. In *Journal of Physics: Conference Series*, 954 (1), 012028, IOP Publishing, 2018.
41. Quinlan, J. R., C4. 5: programs for machine learning. Elsevier, 2014.
42. Hassan, M. M., Mollick, S., Yasmin, F., An unsupervised cluster-based feature grouping model for early diabetes detection. *Healthcare Analytics*, 2, 100112, 2022.
43. Risdin, F., Mondal, P. K., Hassan, K. M., Convolutional neural networks for detecting fruit information using machine learning techniques. *IOSR Journal of Computer Engineering (IOSR-JCE)*, 22 (2), 01-13, 2020.
44. Dong, W., Huang, Y., Lehane, B., Ma, G., XGBoost algorithm-based prediction of concrete electrical resistivity for structural health monitoring. *Automation in Construction*, 114, 103155, 2020.
45. Ribeiro, M. T., Singh, S., Guestrin, C., "Why should i trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, 1135-1144, 2016.
46. Antwarg, L., Miller, R. M., Shapira, B., Rokach, L., Explaining anomalies detected by autoencoders using Shapley Additive Explanations. *Expert systems with applications*, 186, 115736, 2021.
47. Rastogi, R., Bansal, M., Diabetes prediction model using data mining techniques. *Measurement: Sensors*, 25, 100605, 2023.
48. Reddy, S. K., Krishnaveni, T., Nikitha, G., Vijaykanth, E., Diabetes prediction using different machine learning algorithms. In 2021 Third International Conference on Inventive Research in Computing Applications (ICIRCA), 1261-1265, IEEE, 2021.
49. Bansal, A., Singhrova, A., Performance analysis of supervised machine learning algorithms for diabetes and breast cancer dataset. In 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), 137-143, IEEE, 2021.
50. Nass, L., Swift, S., Al Dallal, A., In-depth analysis of medical dataset mining: a comparative analysis on a diabetes dataset before and after preprocessing. *KnE Social Sciences*, 45-63, 2019.
51. Khanam, J.J., Foo, S.Y., A comparison of machine learning algorithms for diabetes prediction. *Ict Express*, 7 (4), 432-439, 2021.
52. Nahzat, S., Yağanoğlu, M., Diabetes prediction using machine learning classification algorithms. *Avrupa Bilim ve Teknoloji Dergisi*, 24, 53-59, 2021.

53. Cihan, P., Coşkun, H., Performance comparison of machine learning models for diabetes prediction. In 2021 29th Signal Processing and Communications Applications Conference (SIU), 1-4, IEEE, 2021.
54. Modak, S. K. S., Jha, V. K., Diabetes prediction model using machine learning techniques. Multimedia Tools and Applications, 83 (13), 38523-38549, 2024
55. Rahaman, M. J., Evaluate the Predictive Performance of Supervised Machine Learning Algorithms in Diabetes Dataset, 2022.
56. Pan, X. R., Li, G. W., Hu, Y. H., Wang, J. X., Yang, W. Y., An, Z. X., ... Howard, B. V., Effects of diet and exercise in preventing NIDDM in people with impaired glucose tolerance: the Da Qing IGT and Diabetes Study. Diabetes care, 20 (4), 537-544, 1997.
57. Tuomilehto, J., Lindstrom, J., Eriksson, J., Valle, T., Hamalainen, H., Ilanne-Parikka, P., ... Uusitupa, M., Finnish Diabetes Prevention Study. Group, 344, 1343-1350, 2001.
58. Knowler, W. C., Barrett-Connor, E., Fowler, S. E., Hamman, R. F., Lachin, J. M., Walker, E. A., Nathan, D. M., Diabetes Prevention Program Research Group., Reduction in the incidence of type 2 diabetes with lifestyle intervention or metformin. The New England journal of medicine, 346 (6), 393-403, 2002.
59. Herman W. H., The cost-effectiveness of diabetes prevention: results from the Diabetes Prevention Program and the Diabetes Prevention Program Outcomes Study. Clinical diabetes and endocrinology, 1, 9, 2015.

