



Makine Öğrenimi Yöntemleri ile Bireylerin Kronik Hastalık Durumlarının Sınıflandırılması: Türkiye İstatistik Kurumu'nun 2023 Gelir ve Yaşam Koşulları Araştırması Üzerine Bir Uygulama

Yunus Emre Gür^{1*}, Kâmil Abdullah Eşidir²

¹ Yönetim Bilişim Sistemleri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

² Fırat Kalkınma Ajansı, Elazığ, Türkiye

yegur@firat.edu.tr, abduhahesidir@yahoo.com

Öz

Kronik hastalıkların artan prevalansı (görülme sıklığı) ve bunların bireylerin yaşam kalitesi üzerindeki olumsuz etkileri, kamu sağlığı alanında öncelikli meseleler arasında yer almaktadır. Bu hastalıkların erken teşhis ve yönetimi, sağlık hizmetlerine erişimdeki eşitsizlikler ve sosyoekonomik faktörlerle karmaşıklaşan bir süreçtir. Bu bağlamda, makine öğrenimi yöntemleri, büyük ve karmaşık veri kümelerinden bilgi çıkararak tahminlerde bulunma konusunda önemli bir potansiyel sunmaktadır. Özellikle TabNet yöntemi, güçlü tahmin yetenekleri ve karmaşık ilişkileri modelleme kapasitesi ile dikkat çekmektedir. Bu çalışma, Türkiye İstatistik Kurumu'nun 2023 Gelir ve Yaşam Koşulları Araştırması verilerini kullanarak, Yapay Sinir Ağları (YSA), Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Destek Vektör Makinesi (DVM), Rastgele Orman, Gradient Boosting ve TabNet gibi yöntemler ile bireylerin kronik hastalık durumlarının sınıflandırılmasını amaçlamaktadır. Bulgular, sağlık hizmetlerine genel erişimin iyi olduğunu, ancak bazı kesimlerin hala erişimde zorluklar yaşadığını; kronik hastalıkların genel sağlık durumu ve istihdam gibi faktörlerle güçlü bir ilişkisi olduğunu ve TabNet yönteminin yüksek doğruluk, kesinlik ve duyarlılık gibi performans metrikleri ile etkili bir sınıflandırma yapabildiğini ortaya koymuştur. Sonuç olarak model, %97 genel doğruluk oranı ile kronik hastalık durumunu başarıyla sınıflandırmıştır. Bu çalışma, sağlık politikalarının geliştirilmesi ve sektörel analizler için stratejik kararlar alınmasında kullanılacak değerli bilgiler sunmakta ve makine öğrenimi yöntemlerinin, özellikle TabNet tekniğinin, sağlık verileri analizinde etkin bir şekilde kullanılmasının önemini vurgulamaktadır.

Anahtar kelimeler: Makine Öğrenimi, Veri Sınıflandırma, Kronik Hastalık Yönetimi, TabNet, Sağlık Politikaları Geliştirme.

Classification of Chronic Disease Status of Individuals Using Machine Learning Methods: An Application on The 2023 Income and Living Conditions Survey of the Turkish Statistical Institute

Abstract

The increasing prevalence of chronic diseases and their negative impact on the quality of life of individuals is one of the priority issues in the field of public health. Early diagnosis and management of these diseases is a process complicated by inequalities in access to healthcare services and socio-economic factors. In this context, machine learning methods offer significant potential for making predictions by extracting information from large and complex data sets. In particular, the TabNet method stands out for its strong predictive capabilities and ability to model complex relationships. This study aims to classify the chronic disease status of individuals using methods such as Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), Support Vector Machines (SVM), Random Forest, Gradient Boosting and TabNet using data from the 2023 Income and Living Conditions Survey of the Turkish Statistical Institute. The results showed that overall access to health services is good, but some segments still have difficulty accessing it; chronic diseases have a strong relationship with factors such as general health status and

* Sorumlu yazar.
E-posta adresi: yegur@firat.edu.tr

employment; and the TabNet method can perform effective classification with performance metrics such as high accuracy, precision and sensitivity. As a result, the model successfully classified chronic disease status with an overall accuracy rate of 97%. This study provides valuable information that can be used to make strategic decisions for health policy development and sectoral analysis, and highlights the importance of using machine learning methods, particularly the TabNet technique, effectively in health data analysis.

Keywords: Machine Learning, Data Classification, Chronic Disease Management, TabNet, Health Policy Development.

1. Giriş (Introduction)

Günümüzde, kronik hastalıkların yaygınlığı ve bunların bireylerin yaşam kalitesi üzerindeki etkileri, kamu sağlığı alanında öncelikli konular arasında yer almaktadır. Kronik hastalıklar, uzun süreli sağlık sorunları olarak tanımlanır ve tedavi edilse bile genellikle tam iyileşme sağlanamamaktadır (Kumsar ve Yılmaz, 2014; Altuntaş vd., 2015). Bu hastalıkların erken teşhisi ve yönetimi, bireylerin yaşam kalitesini önemli ölçüde artırabilirken, sağlık hizmetlerine erişimdeki eşitsizlikler ve sosyoekonomik faktörler bu süreci karmaşıklaştırmaktadır (Küçükberber vd., 2011). Bu bağlamda, makine öğrenimi yöntemleri, büyük ve karmaşık veri kümelerinden bilgi çıkarma ve tahmin yapma konusunda önemli bir potansiyele sahiptir (Sönmez ve Zengin, 2023). Yapay Sinir Ağları (YSA), Uzun Kısa Süreli Bellek ağları (LSTM), Evrişimli Sinir Ağları (CNN), Rastgele Orman, Gradyan Artırma (Gradient Boosting), TabNet ve Destek Vektör Makineleri (DVM) gibi makine öğrenimi modellerinin sağlık hizmetleri sınıflandırma problemlerinde artan kullanımı, tıbbi veri analizi alanında önemli bir eğilimi yansıtmaktadır. Rastgele Orman ve Gradient Boosting, sağlık hizmetleri sınıflandırma görevlerinde kayda değer başarı gösteren topluluk öğrenme yöntemleridir. Rastgele Ormanlar, tahmin doğruluğunu ve aşırı uyuma karşı sağlamlığı artırmak için birden fazla karar ağacını birleştirmektedir. Bu yöntem, yorumlanabilirliği ve çok sayıda özelliğe sahip büyük veri kümelerini işleme yeteneği nedeniyle risk değerlendirmesi ve hasta sınıflandırması dahil olmak üzere çeşitli sağlık senaryolarında yaygın olarak kullanılmaktadır (Luo vd., 2018). Gradient Boosting, önceki modeller tarafından yapılan hataları düzeltmeye odaklanarak modelleri sırayla oluşturur ve bu da karmaşık sağlık hizmeti veri kümelerinde tahmin gücünü artırır. Bu yöntem, güçlü tahmin yetenekleri ve karmaşık ilişkileri modelleme kapasitesi ile sağlık alanındaki sınıflandırma sorunları için giderek daha fazla kullanılan bir yöntem haline gelmiştir (Yaygın, 2019; Özdemir, 2023). YSA'lar, büyük veri kümelerinden öğrenme ve verilerdeki karmaşık örüntüleri belirleme yeteneğine sahip oldukları için sağlık uygulamalarında özellikle etkili olmaktadır. Bu yetenek, YSA'ların hastalık teşhisi ve prognozu gibi görevler için kullanıldığı ve tıbbi verilerin doğasında bulunan doğrusal olmayan ilişkileri işlemedeki etkinliklerini gösteren çeşitli çalışmalarda gösterilmiştir (Ahsan vd., 2023). Öte yandan, uzun vadeli bağımlılıkları hatırlama yetenekleri, LSTM'lerin çeşitli sağlık uygulamalarında geleneksel modellerden daha iyi performans göstermesini sağlamaktadır (Ahsan

vd., 2023). Çalışmalar, CNN'lerin de çeşitli sağlık alanı sınıflandırma görevlerinde yüksek doğruluk oranlarına ulaşabildiğini ve böylece erken teşhis ve müdahaleyi kolaylaştırdığını göstermektedir (Almutairi vd., 2022). DVM'ler, sağlık hizmetlerinde makine öğreniminin bir diğer temel taşıdır. DVM'ler özellikle yüksek boyutlu verileri işleme konusunda uzmandır ve kanser teşhisi ve genetik veri analizi de dahil olmak üzere çeşitli alanlarda hastalık sınıflandırması için yaygın olarak kullanılmaktadır (Guido vd., 2024). Nispeten daha yeni bir model olan TabNet, özellikleri dinamik olarak seçmek için sıralı bir dikkat mekanizması kullanır ve bu da onu sağlık hizmetleri ortamlarında yaygın olarak bulunan tablo verileri için özellikle etkili kılmaktadır (Arık ve Pfister, 2019). Yüksek performansı korurken yorumlanabilir sonuçlar sağlama yeteneği, TabNet'i modelin karar verme sürecine ilişkin içgörülere ihtiyaç duyan sağlık uygulayıcıları için değerli bir araç haline getirmektedir (Arık ve Pfister, 2019).

Bununla birlikte, gelir dağılımı ve yoksulluk, ekonomik kalkınmanın yanı sıra sosyal adalet ve eşitlik açısından da büyük önem taşıyan konulardır. Gelir dağılımındaki adaletsizlikler ve yoksulluk, bir ülkenin ekonomik başarısının yanı sıra toplumsal dengenin ve istikrarın da önemli göstergeleridir. Bu nedenle, ekonomik açıdan sağlıklı bir değerlendirme yapabilmek için gelir dağılımı ve yoksullukla ilgili verilere dayalı olarak politika ve sosyal programlar geliştirilmelidir. Bu programlar, gelir eşitsizliğini azaltmaya, yoksulluğu önlemeye ve sosyal adaleti sağlamaya yönelik olmalıdır (Yar, 2015). Ayrıca, gelir dağılımı ve yoksullukla ilgili verilerin düzenli olarak izlenmesi ve analiz edilmesi, politika yapıcıların karar alma süreçlerinde daha bilinçli kararlar almasına yardımcı olacaktır (Ersöz, 2003).

Türkiye İstatistik Kurumu'nun (TÜİK) 2023 yılında gerçekleştirdiği Gelir ve Yaşam Koşulları Araştırması (GYKA), Türkiye'deki hanelerin sosyoekonomik durumları ve bireylerin yaşam koşulları hakkında kapsamlı veriler sunmaktadır. Bu araştırma, bireylerin genel sağlık durumları, sağlık hizmetlerine erişimde karşılaştıkları zorluklar, istihdam durumları, eğitim durumları ve sosyoekonomik koşulları gibi önemli göstergeleri içermektedir. Bu çalışma, GYKA veri setini kullanarak, bireylerin kronik bir hastalığının olup olmadığını tahmin etmek için YSA, LSTM, CNN, Rastgele Orman, Gradient Boosting, TabNet ve DVM gibi makine öğrenimi modellerini uygulamaktadır. Araştırma, genel sağlık durumu, sağlık probleminden ötürü faaliyetlerde sınırlılık, doktora başvuramama durumu, istihdam durumu, eğitim seviyesi, sosyal yaşam durumu ve ücretli sosyal faaliyetlere katılım durumu gibi bağımsız değişkenlerin, bireylerin kronik

hastalık durumlarının sınıflandırılmasındaki etkilerini incelemektedir.

Bu çalışmanın amacı, sağlık alanında karar verme süreçlerini desteklemek ve makine öğrenimi tabanlı modellerin potansiyelini göstermek adına bu yöntemleri kullanarak, Türkiye'deki bireylerin kronik hastalık durumlarını sınıflandırmak ve sağlık durumları üzerine derinlemesine bir analiz sunmaktır. Makalenin bundan sonraki bölümlerinde, makine öğrenimi yöntemlerinin sağlık verileri analizindeki rolü hakkında bir literatür incelemesi sunulmuştur. Ardından, çalışmanın metodolojisi anlatılmış ve kullanılan yöntemlerin teorik temelleri ve uygulama süreci detaylandırılmıştır. Daha sonra, çalışmanın bulguları açıklanmış ve makine öğrenimi sınıflandırma algoritmalarının performansı değerlendirilmiştir. Son olarak, makalenin sonuç ve öneri kısmında, elde edilen bulguların sağlık politikaları ve sektör analizleri üzerindeki etkileri ele alınmış ve bu sonuçların gelecekteki araştırmalara yön vermesi için öneriler geliştirilmiştir. Bu değerlendirmeler, sağlık alanında daha bilinçli kararlar alınmasına ve sektörün ihtiyaçlarına yönelik stratejilerin oluşturulmasına katkıda bulunmayı amaçlamaktadır.

2. Literatür İncelemesi (Literature Review)

Makalenin bu bölümünde, makine öğrenimi yöntemlerinin sağlık verileri analizindeki rolü hakkında bir literatür incelemesi gerçekleştirilmiştir. Elde edilen çalışmaların bir kısmı bu bölümde sunulmuştur.

Özkan (2019)'ın çalışmasında, sağlık verileri üzerinden hastalık tanısı koyma sürecinde karşılaşılan problemler ele alınarak, KEEL veri tabanından alınan çeşitli hastalık veri setleri üzerinde torbalama ve artırma algoritmaları karşılaştırmıştır. Veri ön işleme sonrasında, artırma algoritmaları genel olarak torbalama yöntemlerine üstün performans sergilemiştir. Özellikle, Gradient Boosting algoritması, hepatit hastalığının teşhisinde %98.36 doğruluk, %98.68 kesinlik, %98.95 duyarlılık, ve %98.91 F-Skor değerleri ile dikkate değer sonuçlar elde etmiştir. Bu bulgular, veri ön işlemenin ve seçilen algoritmaların doğru hastalık tanısında önemli rol oynadığını göstermektedir.

Hematolojik hastalıklar alanında, Ahmed vd. (2019), mikroskopik görüntülerden lösemi alt türlerini belirlemek için CNN'leri kullanmıştır. Geliştirdikleri model %88,25'lik bir doğruluk oranına ulaşarak derin öğrenme tekniklerinin karmaşık hastalıklar için teşhis doğruluğunu artırma potansiyeline işaret etmiştir. Bu durum, lösemi teşhisi için CNN'lerle derin transfer öğrenmesi kullanan ve modelin kan hücreleri görüntülerinden ilgili özellikleri etkili bir şekilde çıkarma yeteneğini vurgulayan Loey vd. (2020) tarafından da desteklenmektedir.

Gaddam ve Pattnaik (2020) tarafından yapılan bir çalışma, YSA kullanarak aritmi tespiti için EKG sinyal sınıflandırmasına odaklanmıştır. Model, kardiyak anormallikleri belirlemedeki etkinliğini göstererek %91'lik bir doğruluk elde etmiştir. Bu yetenek, yaygın

kronik durumlar olan kardiyovasküler hastalıkların zamanında teşhis ve tedavisi için çok önemlidir.

Pacci vd. (2021), yaptıkları bir çalışmada, tüp bebek tedavisinde pozitif gebelik sonucunu tahmin etmek amacıyla yapay zekâ tabanlı bir klinik karar destek sistemi geliştirilmişlerdir. Çalışmada, Yeditepe Üniversitesi Hastanesi'nden alınan 1154 tedavi siklusuna ait veriler kullanılarak, beş farklı sınıflandırma yöntemi (DVM, Çok Katmanlı Algılayıcı, Rastgele Orman, XGBoost ve LightGBM) karşılaştırmalı olarak test edilmiştir. En yüksek sınıflandırma performansı, Destek Vektör Makineleri yöntemi ile elde edilmiştir, AUC değeri 0.70 olarak bulunmuş ve karar eşik değerinin optimizasyonu ile gebelik sonucunun %71.7 Doğru Pozitif ve %59.4 Doğru Negatif oranıyla tahmin edilmesi sağlanmıştır.

Tang ve Liu (2021), yapmış oldukları bir çalışmada, Alzheimer hastalığının (AD) ilerleyişini, beyin manyetik rezonans görüntüleme (MRI) verileri kullanılarak çeşitli makine öğrenimi algoritmaları ile sınıflandırmış ve tahmin etmişlerdir. ADNI veri tabanından alınan 560 katılımcı, kognitif normal (CN), erken hafif bilişsel bozukluk (EMCI), geç hafif bilişsel bozukluk (LMCI) ve Alzheimer (AD) olmak üzere dört gruba ayrılmıştır. Rastgele Orman, DVM ve Karar Ağacı algoritmaları kullanılarak bu grupların hastalık ilerleyişi sınıflandırılmıştır. Rastgele Orman algoritması en yüksek doğruluğa (CN-AD için %96.14) ve en yüksek AUC değerine (0.92) ulaşarak diğer modellerden daha başarılı olmuştur. Sınıflandırmada kullanılan MRI özellikleri ile Rastgele Orman modeli, hastalığın erken teşhisinde yardımcı bir araç olarak önerilmiştir.

Gündoğdu (2021)'nin çalışmasında, Kaggle veri tabanından alınan kalp hastalığı veri seti kullanılarak Python aracılığıyla 7 sınıflandırma algoritması (Destek Vektör Makineleri, Gaussian Naive Bayes, Gradient Boosting ve Rastgele Orman) performanslarının karşılaştırılması yapılmıştır. En iyi performans gösteren algoritma, %89.7 F1 skoru ve %90.2 doğruluk ile Rastgele Orman olmuştur. Açlık kan şekeri özelliğinin önem sıralamasında en alta yer alması, sınıflandırma performansı üzerinde minimal etkisi olduğunu göstermiştir. Bu bulgular, kalp hastalığı tahmininde daha etkili ve doğru sistemlerin geliştirilmesine katkı sağlayabilir.

Kim vd. (2021) tarafından gerçekleştirilen "Makine Öğrenimi Tabanlı Kardiyovasküler Hastalık Tahmini Modeli: Kore Ulusal Sağlık Sigortası Hizmeti Verileri Üzerine Bir Kohort Çalışması" isimli araştırmada, Kore Ulusal Sağlık Sigortası Hizmeti'nin sağlık taraması veri setinden en uygun tahmin modelini belirlemek amacıyla bir dizi makine öğrenimi yöntemi uygulanmıştır. Bu yöntemler; Lojistik Regresyon, K-En Yakın Komşu, Karar Ağaçları, Rastgele Orman, Ekstra Ağaçlar, XGBoosting, Gradyan Arttırma, AdaBoost, DVM ve Çok Katmanlı Algılayıcılar içermektedir. Araştırma sonuçlarına göre, XGBoosting, Gradient Boosting ve Rastgele Orman yöntemleri, performans ölçütleri

bazında diğerlerine üstün gelerek en iyi tahmin modellerini oluşturmuştur.

Toğaçar vd. (2021), yapmış oldukları bir çalışmada, deri kanseri tespiti için CNN tabanlı yeni bir model geliştirmişlerdir. Model, Autoencoder, MobileNetV2 ve Spiking Neural Networks (SNN) bileşenlerini kullanarak, iyi huylu ve kötü huylu tümörleri sınıflandırmışlardır. ISIC veri seti kullanılarak yapılan deneylerde, MobileNetV2 modeli ve spiking ağları ile %95.27'lik bir doğruluk oranı elde edilmiştir. Bu sonuçlar, Autoencoder ve SNN'nin MobileNetV2 modelinin performansını artırmada etkili olduğunu göstermiştir. Çalışma, deri kanseri tespiti için yüksek hassasiyetli ve tamamen otomatik bir karar destek aracı sunmaktadır.

Bununla birlikte, Akcan ve Sertbaş (2021)'in çalışmasında, göğüs kanseri teşhisi için topluluk öğrenme yöntemleri kullanılarak bir dizi makine öğrenimi algoritmasının performansı karşılaştırılmıştır. DVM, K-En Yakın Komşu (KNN), Naive Bayes, Karar Ağaçları ve Rastgele Orman gibi algoritmalar yanında, bagging, boosting ve voting gibi topluluk öğrenme yöntemleri uygulanmıştır. Veri ön işleme ve özellik ölçeklendirme adımları yapıldıktan sonra, bu yöntemlerin doğruluk, kesinlik, duyarlılık, F-Skor ve AUC skorları karşılaştırılmıştır. En yüksek doğruluk oranları Soft Voting, Bagging (SVC) ve XGBoost yöntemleriyle elde edilmiştir, bu da topluluk öğrenme yöntemlerinin bireysel sınıflandırma yöntemlerine göre daha üstün performans sergilediğini göstermiştir.

Purwaningsih (2022), kronik böbrek hastalığının (KBH) tahmini için DVM modeli kullanmış ve ileri özellik seçimi (Forward Selection) kullanarak modeli geliştirmiştir. Çalışmada, DVM modeli farklı çekirdekler (dot, polynomial ve RBF) ile test edilmiştir ve en yüksek doğruluk oranı %98,50 (AUC = 1,000) ile dot çekirdekli DVM'de elde edilmiştir. Ancak, ileri özellik seçimi uygulanarak SVM+FS modeli ile RBF çekirdeği kullanıldığında doğruluk %99,75'e (AUC = 1,000) yükselmiştir. Bu sonuçlar, ileri özellik seçiminin DVM performansını önemli ölçüde artırdığını göstermektedir. Çalışmada ayrıca, hastalık durumunu tahmin etmek için YSA modeli de kullanılmış ve %90,5'lik bir doğruluk elde edilmiştir. YSA'nın klinik ve laboratuvar verilerine dayalı olarak risk altındaki hastaların belirlenmesinde sağlık hizmeti sağlayıcılarına yardımcı olabileceği KBH'de erken tanı ve müdahalenin önemini vurgulamaktadır.

Sevli (2023)'nin çalışmasında, diyabet hastalığının erken teşhisi için Pima Indian Diabetes veri seti üzerinde altı farklı makine öğrenimi yöntemi (Destek Vektör Makinesi, Lojistik Regresyon, K-En Yakın Komşu, Rastgele Orman, AdaBoost, Gradient Boosting) kullanılarak sınıflandırma çalışmaları yapılmıştır. Yeniden örnekleme teknikleri uygulanarak, sınıflandırıcıların başarıları artırılmaya çalışılmıştır. En yüksek performans, Rastgele Orman sınıflandırıcısı ile InstanceHardnessThreshold az örnekleme tekniği kullanılarak elde edilmiş; %96.29 doğruluk, %98.07

kesinlik, %100 geri çağırma, %96.22 F1 Skoru ve %96.29 AUC değerleri raporlanmıştır. Gradient Boosting ve AdaBoost yöntemleri de benzer yeniden örnekleme tekniği ile yüksek performans göstermiştir.

Coşkun ve Yüksek (2023), ölümcül hepatit hastalığının tanısı için öznelik seçimi yöntemini kullanarak bulanık mantık ve çeşitli makine öğrenmesi yöntemlerinin başarısını karşılaştırmıştır. UCI makine öğrenimi deposundan alınan hepatit veri seti üzerinde öncelikle veri ön işleme ve öznelik seçimi işlemleri yapılmış, ardından bulanık model ve makine öğrenmesi modelleri test edilmiştir. Bulanık Mantık yöntemiyle %94 doğruluk elde edilirken, Gradient Boosting algoritmasıyla %98.36 doğruluk, %98.68 kesinlik, %98.95 duyarlılık ve %98.91 f-skor değerleri elde edilmiştir. Sonuçlar, Gradient Boosting yönteminin diğer makine öğrenme yöntemleri ve bulanık mantık yaklaşımına göre hepatit hastalığının teşhisinde daha başarılı olduğunu göstermektedir.

Kim vd. (2023), konvolüsyonel sinir ağlarını (CNN), LSTM ile birleştiren çok görevli bir öğrenme çerçevesi kullanarak kronik hastalık tahminini araştırmıştır. Yaklaşımları, birden fazla kronik hastalığı aynı anda tahmin etmede %94,3'lük bir doğruluk elde etmiştir. Bu çalışma, LSTM'nin kronik hastalık tahmini için gerekli olan zaman serisi verilerindeki zamansal ilişkileri modelleme yeteneğini vurgulamaktadır.

Zhang vd. (2023) tarafından yapılan bir başka çalışma, solunum ses dosyalarını kullanarak akciğer hastalığı tespitine odaklanmıştır. LSTM modeli %98,82'lik etkileyici bir doğruluk ve 0,97'lik bir F1 skoru elde ederek ses verilerindeki sıralı örüntüleri yakalamadaki üstün performansını göstermiştir. Bu yüksek doğruluk seviyesi, LSTM'nin öksürük seslerine dayalı kronik solunum yolu hastalıklarını teşhis etmedeki etkinliğinin altını çizmektedir.

Özdemir (2023)'in yapmış olduğu bir çalışmada, aritmilerin sınıflandırılması için makine öğrenmesi algoritmaları kullanılmıştır. Yöntem olarak Bagging Decision Tree, Rastgele Orman, Extra Tree, Gradient Boosting ve DVM algoritmaları kullanılmıştır. Çalışma, MIT PhysioNet veri seti üzerinde gerçekleştirilmiş ve belirli hasta numaraları (203, 208, 210 ve 213) üzerinde odaklanılmıştır. Bulgular, bu algoritmaların aritmilerin sınıflandırılmasında etkili olduğunu ve çeşitli algoritmaların performanslarının karşılaştırılmasıyla elde edildiğini göstermektedir. Özellikle, Random Forest ve Gradient Boosting gibi yöntemlerin yüksek doğruluk oranları sunabileceği belirtilmektedir. Makale, makine öğrenmesi algoritmalarının aritmi sınıflandırmasındaki potansiyelini ve sağlık alanındaki uygulamalarını vurgulamaktadır.

Duyar vd. (2023) bağırsak mikrobiyota verilerini kullanarak kardiyovasküler hastalıkların tespitini araştırmış ve TabNet'i diğer makine öğrenimi modelleriyle karşılaştırmıştır. Çalışma, TabNet'in boosting yöntemlerine kıyasla daha zayıf sonuçlar verdiğini gösterse de, modelin kronik hastalık sınıflandırmasında uygulanabilirliğine ilişkin değerli

bilgiler sağlamıştır. Konuyla ilgili bir başka çalışmada, McLaughlin vd. (2023), TabNet kullanarak pan-kanser varyant arama üzerine odaklanılmıştır. Çalışma, mutasyonları somatik veya germline olarak sınıflandırmayı amaçlamış ve TabNet'in bu sınıflandırma görevinde yüksek performans elde ettiğini bildirmiştir. Çalışma, TabNet'in yorumlanabilirliğini ve kanser genomisinde kritik öneme sahip olan tablo verilerini işlemdeki etkinliğini vurgulamıştır. Hegde ve Mundada (2020) tarafından yapılan bir çalışmada, diğer makine öğrenimi tekniklerinin yanı sıra TabNet de kullanılmıştır. Çalışma, TabNet'in kronik hastalıkları tahmin etmede %90'lık bir doğruluk elde ettiğini ve sağlık analitiğinde güçlü bir araç olarak rolünü güçlendirdiğini bildirmiştir. Ek olarak, Elkholy vd. (2023) TabNet kullanarak kronik böbrek hastalığı için geliştirilmiş bir optimize sınıflandırma modeli geliştirmiştir. Model %92,5'lik bir doğruluk oranına ulaşarak kronik böbrek hastalığını erken bir aşamada tespit etmedeki etkinliğini ortaya koymuştur. Bu yüksek doğruluk oranı, kronik böbrek hastalığının küresel olarak artan prevalansı göz önüne alındığında özellikle önemlidir.

Choubey vd. (2024), büyük veri madenciliğini kullanarak kronik hastalıkların tahmini için yeni bir yaklaşım sunulmuştur. Bu yaklaşımda, Özellik Seçimi için Principal Component Analysis (PCA) ve sınıflandırma için eXtreme Gradient Boosting (XGB) algoritmaları kullanılmıştır. PCA, veri boyutunu azaltarak en önemli varyasyonları yakalarken, XGB bu özellikleri kullanarak yüksek doğrulukta hastalık tahmini yapmaktadır. Çalışmanın sonuçları, %98.8 doğruluk, %98 recall ve %98.7 F1-skoru ile yüksek bir performans göstermiştir. Modelin işlem süresi 8 saniye olup, bu hızlı işlem kapasitesi, modeli pratik uygulamalar için uygun hale getirmektedir. Guhan vd. (2024), kronik böbrek hastalığının doğru teşhisinin önemini vurgulamaktadır. Araştırma, proaktif sağlık stratejilerinin iyileştirilmesine yardımcı olmakta ve kronik hastalıkların önlenmesi ve yönetimi konusunda değerli bilgiler sağlamaktadır. Çalışmada, kronik bir hastalık olan böbrek yetmezliği olasılığını tahmin eden Büyük Veri analize dayalı bir çerçeve geliştirilmiştir. Çerçevede, kronik hastalıklarla ilişkili risk faktörlerini ve korelasyonları tespit etmek için MEG (Mean Decrease Gini), MSE (Mean Square Error), Grid Search, K-fold cross validation gibi gelişmiş Makine Öğrenimi tekniklerini kullanılmıştır. El-Shafeiy vd. (2024), tarafından yapılan bir başka çalışmada, doğurganlık kalitesini tahmin etmek için YSA uygulanmış ve %85'lik bir doğruluk oranı rapor edilmiştir. Bu araştırma, doğru tahminlerin klinik kararlara rehberlik edebileceği ve hasta sonuçlarını iyileştirebileceği üreme sağlığı alanında YSA'nın çok yönlülüğünü göstermektedir. Modelin performansı, karmaşık veri kümelerine dayalı olarak sağlıkla ilgili sonuçların tahmin edilmesinde daha geniş uygulamalar için potansiyeline işaret etmektedir.

Sonuç olarak, YSA, LSTM, CNN, Rastgele Orman, Gradient Boosting, TabNet ve DVM gibi makine öğrenimi modellerinin sağlık hizmetleri sınıflandırma problemlerine entegrasyonu, bu alanda dönüştürücü bir değişimi temsil etmektedir. Literatürdeki çalışmalardan da hareketle, bu modeller yalnızca tahmin doğruluğunu artırmakla kalmamakta, aynı zamanda klinik karar verme sürecini bilgilendirebilecek değerli içgörüler de sağlamaktadır. Araştırmalar ilerlemeye devam ettikçe, bu teknolojilerin hasta sonuçlarını iyileştirme ve sağlık hizmeti süreçlerini kolaylaştırma potansiyeli artacak ve modern tıpta vazgeçilmez araçlar haline gelecektir. Ayrıca, bu çalışmanın özgün değeri, Türkiye İstatistik Kurumu'nun (TÜİK) 2023 yılı Gelir ve Yaşam Koşulları Araştırması (GYKA) veri seti kullanılarak, bireylerin kronik hastalık durumlarının makine öğrenimi yöntemleriyle sınıflandırılmasıdır. Mevcut literatürde bu spesifik veri seti ve yöntemle kronik hastalık durumlarının sınıflandırılmasına dair herhangi bir çalışma bulunmamaktadır. Çalışma, bu kapsamlı ve güncel veri setini kullanarak, sağlık hizmetlerine erişimdeki eşitsizlikler ve sosyoekonomik faktörlerin sağlık durumları üzerindeki etkilerini incelemiş, yüksek doğruluk oranlarıyla sınıflandırma yaparak literatüre önemli bir katkı sağlamıştır. Bu özgün yaklaşım, sağlık politikalarının geliştirilmesinde ve sektörel analizlerde stratejik kararlar alınmasında kullanılabilir değerli bilgiler sunmaktadır.

3. Çalışmanın Metodolojisi (Methodology of the Study)

Bu çalışmada, Türkiye İstatistik Kurumu'nun (TÜİK) 2023 yılı Gelir ve Yaşam Koşulları Araştırması (GYKA) verileri temel alınarak, Türkiye'deki bireylerin kronik hastalık durumlarını sınıflandırmak amacıyla çeşitli makine öğrenimi yöntemleri kullanılmıştır. GYKA verileri, Türkiye'deki hanelerin sosyoekonomik durumları ve bireylerin yaşam koşulları hakkında kapsamlı veriler sunmaktadır. Bununla birlikte, bireylerin genel sağlık durumları, sağlık hizmetlerine erişimde karşılaştıkları zorluklar ve istihdam durumları gibi önemli göstergeleri de içermektedir. Çalışmada, GYKA araştırmasında kullanılan anket formundan elde edilen yedi bağımsız değişken, kronik hastalık durumu tahminlerinin yapılmasında kullanılmıştır. Yapılan ön analizler sonucunda eksik veriler, veri tabanından çıkarılmıştır. Veri setinde toplamda 64.607 adet hücre verisi kullanılmıştır.

Bu çalışmada, kullanılan bağımsız değişkenler, genel sağlık durumu, faaliyetlerde sınırlama durumu dağılımı, doktora başvuramama durumu, istihdam durumu, eğitim seviyesi, sosyal yaşam durumu ve ücretli sosyal faaliyetlere katılma durumu şeklindedir. Bu değişkenler, araştırmada bireylerin kronik hastalık durumunu (bağımlı değişken) etkileyen faktörler olarak incelenmiştir. Bu bağımsız değişkenler, kronik hastalık durumunu anlamak ve değerlendirmek için kullanılmıştır. Orijinal mikro veri setinde "Genel Sağlık

Durumu” 5 farklı biçimde ifade edilmiştir (1-Çok İyi, 2-İyi, 3-Orta, 4-Kötü, 5-Çok Kötü). Analiz adımlarını sadeleştirmek adına Çok İyi ve İyi sınıfları “0- Sağlığı

İyi” şeklinde sadeleştirilmiştir. 3, 4 ve 5 sınıfları ise “1- Sağlığı Kötü” olarak sınıflandırılmıştır.

Tablo 1. Değişkenlere ilişkin tanımlamalar ve açıklamalar (Definitions and explanations of variables)

Değişken Adı	Değişken Tanımı	Açıklama
FS010	Ferdin genel sağlık durumu	1- Çok iyi 2-İyi 3 Orta 4-Kötü 5-Çok kötü
FS030	Sağlık probleminden ötürü faaliyetlerde sınırlama olup olmadığı	1-Evet, çok sınırlandı 2-Evet, sınırlandı 3-Hayır, sınırlanmadı
FS050	Ferdin son 12 ay içerisinde ihtiyaç duyulduğu halde doktora başvuramama durumu	1-Evet, en az 1 kere 2-Hayır, hiç olmadı 3-Hayır, ihtiyaç olmadı
FI010	Ferdin istihdam durumu	1-Tam zamanlı ücretli çalışan 2-Yarı zamanlı ücretli çalışan 3-Tam zamanlı işveren 4-Yarı zamanlı işveren 5-İş arıyor 6-Eğitime devam ediyor 7-Emekli 8-Engelli 9-Ev işleri ile meşgul 10-Diğer
FE030	Ferdin Eğitim Seviyesi	0-Okur-yazar olmayan 1-Bir okul bitirmede 2-İlkokul 3-İlköğretim 4-Ortaokul ve dengi 5-Genel lise 6-Mesleki veya Teknik lise 7-Yüksekokul 8-Fakülte 9-Yüksek Lisans 10-Doktora
FY050	Ayda en az bir kere arkadaş, aile/akraba ile yemek yemek veya bir şeyler içmek için dışarıda (lokanta, pastane, kafe vb. yerlerde) bir araya gelme durumu	1-Evet 2-Hayır-maddi yetersizlik 3-Hayır-diğer nedenler
FY060	Spor, sinema, konser gibi boş zaman faaliyetlerine (ücret ödeyerek) düzenli olarak katılma durumu	1-Evet 2-Hayır-maddi yetersizlik 3-Hayır-diğer nedenler
FS020 (Bağımlı Değişken)	Ferdin kronik bir hastalığının olup olmadığı	0-Evet 1-Hayır

Tablo 1’de analizlerde kullanılan bağımsız değişkenler ve değişkenlerin açıklama ve tanımlamaları gösterilmiştir. İlgili tabloda yer alan veri seti, içerdiği bilgilerin türünü ve bu bilgilerin nasıl kodlandığını açıklamaktadır. Tablo 1’de analizlerde kullanılan değişkenler ve bunlara ait tanımlamalar ve açıklamalar gösterilmektedir. İlgili tabloda, veri setinin ne tür bilgiler içerdiği ve bu bilgilerin nasıl kodlandığı açıklanmaktadır.

Kronik hastalıkların tahmini için çeşitli makine öğrenmesi sınıflandırma algoritmaları kullanılmıştır ve analiz Python yazılımı aracılığıyla yürütülmüştür. Bu süreçte, veri işleme ve manipülasyonu için Pandas ve NumPy kütüphaneleri; veri görselleştirme amacıyla

Matplotlib ve Seaborn; veri bölümlendirme için Scikit-learn’in train_test_split fonksiyonu kullanılmıştır. Veri seti %80’i eğitim ve %20’si test seti olmak üzere ikiye ayrılmıştır. Gradient Boosting, YSA, LSTM, CNN, TabNet, DVM ve Rastgele Orman modellerini kullanarak sınıflandırma işlemi yapmak için çeşitli kütüphaneler gereklidir. Klasik makine öğrenmesi modelleri olan DVM, Rastgele Orman ve Gradient Boosting için scikit-learn kullanılmıştır. Derin öğrenme modelleri (ANN, LSTM, CNN) için ise tensorflow ve keras kütüphaneleri, alternatif olarak PyTorch tabanlı modeller için torch tercih edilmiştir. TabNet modeli için pytorch-tabnet kullanılmış, veri görselleştirme ve model değerlendirme amacıyla matplotlib, seaborn ve scikit-

plot gibi kütüphaneler tercih edilmiştir. Bu araçlar, kapsamlı sınıflandırma işlemlerinin uygulanabilmesini ve performans değerlendirmelerinin yapılabilmesini sağlamaktadır. Bu kütüphaneler, Python'un veri bilimi ve makine öğrenimi projelerinde standart araçları arasında yer almaktadır ve geniş bir kullanım alanına sahiptir (Wade ve Glynn, 2020).

Bununla birlikte, bu çalışmada, makine öğrenmesi sınıflandırma algoritmalarının başarısını değerlendirmek için Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1 Puanı (F1-Score) gibi metrikler kullanılmıştır. Doğruluk, toplam tahminlerin ne kadarının doğru yapıldığını göstermektedir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

(Toplam Örnek Sayısı)

Kesinlik, pozitif olarak tahmin edilen durumların gerçekte ne kadarının pozitif olduğunu göstermektedir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık veya hassasiyet, gerçek pozitif durumların ne kadarının doğru tahmin edildiğini göstermektedir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

F1 Puanı, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve dengeli bir ölçümdür.

$$F1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Bu ifadeler, sınıflandırma modelinin tahmin sonuçlarını temsil etmektedir. DP (Doğru Pozitif) modelin pozitif olarak doğru tahmin ettiği durum sayısını, DN (Doğru Negatif) modelin negatif olarak doğru tahmin ettiği durum sayısını, YP (Yanlış Pozitif) modelin pozitif olarak yanlış tahmin ettiği durum sayısını ve YN (Yanlış Negatif) modelin negatif olarak yanlış tahmin ettiği durum sayısını belirtmektedir. Bununla birlikte, yukarıda açıklanan metriklere ek olarak kullanılan "support" metriği, sınıflandırma raporlarında her sınıf için veri noktalarının toplam sayısını ifade etmektedir. Bu metrik, modele girdi olarak verilen her sınıfın örnek sayısını gösterir ve modelin performans değerlendirmesini yaparken, veri setindeki sınıf dağılımını anlamak için önemlidir. Özellikle dengesiz veri setlerinde, bazı sınıfların diğerlerine göre daha az veya daha fazla örneğe sahip olması durumunda, "support" değeri bu sınıfların analizdeki ağırlığını ve önemini göstermektedir.

3.1. Gradient boosting yöntemi (Gradient boosting method)

Makine öğreniminde karşılaşılan yaygın bir zorluk, veri setlerinden parametrik olmayan regresyon veya sınıflandırma modelleri geliştirmektir. Gerçek dünya senaryolarında, teorik modeller çoğunlukla eksik olur ve araştırmacılar, girdi değişkenleri arasındaki ilişkiler hakkında önceden bilgi sahibi olmadan modeller oluşturmak zorunda kalabilirler. Bu eksiklik, sinir ağları ve destek vektör makineleri gibi parametrik olmayan teknikler kullanılarak, doğrudan verilerden modeller oluşturularak giderilebilir. Modeller genellikle denetimli olarak oluşturulur, bu da hedef değişkenlerin önceden tanımlanması gerektiği anlamına gelir. Pratikte, genellikle güçlü tek bir model yerine, daha güçlü tahminler elde etmek için birçok zayıf modelin birleştirildiği topluluk yaklaşımları tercih edilir. Rastgele ormanlar (Breiman, 2001) ve sinir ağı toplulukları (Hansen ve Salamon, 1990), bu yaklaşımın başarılı örnekleridir (Liu vd., 2004; Shu ve Burn, 2004; Fanelli vd., 2012; Qi, 2012).

Rastgele ormanlar gibi yaygın topluluk teknikleri, topluluktaki modellerin basit ortalamasına dayanmaktadır. Güçlendirme yöntemleri ailesi, farklı yapıcı bir topluluk oluşturma stratejisini temel almaktadır. Boosting'in ana fikri, topluluğa sırayla yeni modeller eklemektir. Her bir iterasyonda, yeni bir zayıf, temel öğrenici model, o ana kadar öğrenilen tüm topluluğun hatasına göre eğitilmektedir. İlk öne çıkan boosting teknikleri tamamen algoritma güdümlü olmuş, bu da özelliklerinin ve performanslarının ayrıntılı analizini oldukça zorlaştırmıştır (Schapire, 2002). Bu durum, bu algoritmaların neden diğer tüm yöntemlerden daha iyi performans gösterdiğine ya da tam tersine ciddi aşırı uyum nedeniyle uygulanamaz olduğuna dair bir dizi spekülasyona yol açmıştır (Sewell, 2011).

Bu doğrultuda, istatistiksel çerçeve ile bağlantı kurmak için, artırma yöntemlerinin gradyan iniş tabanlı bir formülasyonu türetilmiştir (Freund ve Schapire, 1997; Friedman vd., 2000; Friedman, 2001). Boosting yöntemlerinin bu formülasyonu ve ilgili modeller, gradient boosting makineleri olarak adlandırılmıştır. Bu çerçeve aynı zamanda model hiperparametrelerinin temel gerekçelerini sağlamış ve daha fazla gradient boosting (gradyan artırma) modeli geliştirme için metodolojik temel oluşturmuştur. Gradyan artırma makineleri (GBM) ile öğrenme süreci, ardışık yeni modeller ekleyerek yanıt değişkeninin daha kesin tahminlerini elde etmeyi hedeflemektedir. Bu yöntemin temeli, her yeni temel öğrenicinin, topluluğun genel kayıp fonksiyonunun negatif gradyanına en uygun şekilde eşleşecek biçimde oluşturulmasıdır. Kayıp fonksiyonları çeşitli olabilir; örneğin, klasik karesel hata kaybı kullanıldığında, süreç ardışık hata düzeltmeye yönelik olur. GBM'lerin yüksek derecede özelleştirilebilir yapısı, model tasarımında önemli bir özgürlük sağlamakla birlikte çeşitli uygulama ve araştırma alanlarında etkili çözümler sunmaktadır

(Bissacco vd., 2007; Hutchinson vd., 2011; Pittman ve Brown, 2011; Johnson ve Zhang, 2012).

Gradient Boosting sınıflandırma algoritmasının temel adımları, genel olarak aşağıdaki matematiksel formüllerle açıklanabilir:

Başlangıç Tahmini: İlk adımda, tüm gözlemler için sabit bir başlangıç tahmini yapılmaktadır. Bu, genellikle hedef değişkenin ortalaması olabilir:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma) \quad (5)$$

Negatif Gradyan Hesaplama: Her iterasyon m için, gerçek değerler ile mevcut tahminler arasındaki kaybın negatif gradyanı hesaplanmaktadır. Bu, modelin hatalarını belirlemektedir:

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad (6)$$

Zayıf Öğrenici Fit Etme: Her iterasyonda, hesaplanan negatif gradyanlara (hatalara) en iyi uyan bir zayıf öğrenici (genellikle bir karar ağacı) fit edilir:

$$h_m(x) = \text{Fit model to } r_{im} \quad (7)$$

Adım Boyutu (Öğrenme Oranı) Belirleme: Zayıf öğrenicinin katkısını ayarlamak için bir adım boyutu (α) kullanılır. Bu, modelin her adımda ne kadar “öğreneceğini” kontrol etmektedir.

Model Güncelleme: Model, her iterasyonda zayıf öğrenicinin katkısıyla güncellenmektedir. Böylece, modelin hatalarından öğrenmesi sağlanmaktadır:

$$F_m(x) = F_{m-1}(x) + \alpha \cdot h_m(x) \quad (8)$$

Durma Kriteri: Belirlenen iterasyon sayısına ulaşılan veya başka bir durma kriteri karşılanana kadar adımlar tekrarlanmaktadır. Bu süreç, hedef değişkenin tahmininde kullanılan kümülatif bir model oluşturur. Gradient Boosting, karmaşık tahmin problemlerinde yüksek performans gösteren güçlü ve esnek bir algoritmadır.

3.2. Uzun kısa süreli bellek yöntemi (Long Short term memory method)

LSTM, zaman serisi verileri veya sıralı verilerle (dizi verileri) çalışmak üzere geliştirilmiş bir tür yapay sinir ağıdır. LSTM, özellikle uzun vadeli bağımlılıkları ve karmaşık kalıpları öğrenme yeteneğiyle tanınmaktadır. RNN'lerin (Recurrent Neural Networks - Tekrarlayan Sinir Ağları) geliştirilmiş bir versiyonudur ve zaman içindeki bilgi akışını korumak ve unutmak için “kapılar” kullanarak bilgi kaybını ve gradyan sorunlarını önlemektedir (Vidya ve Hari, 2023).

LSTM, geleneksel RNN'lerden farklı olarak, uzun vadeli bağımlılıkları daha iyi öğrenebilmek için hücre durumu (cell state) ve çeşitli kapılar (gates) kullanmaktadır. Bu kapılar, hücre durumunun ne

kadarının güncellenip ne kadarının tutulacağını belirlemektedir. Giriş kapısı, yeni gelen bilginin hücre durumuna ne kadar ekleneceğini kontrol etmektedir. Unutma kapısı, hücre durumundaki bilginin ne kadarının unutulacağını belirlemektedir. Çıkış kapısı ise hücre durumunun hangi kısmının çıkışa aktarılacağını kontrol etmektedir (Dai vd., 2020). Bu kapılar, LSTM'nin sıralı verilere dayanarak kararlar almasını sağlar ve sınıflandırma görevlerinde verinin zamansal özelliklerini dikkate alarak tahminler yaparlar. LSTM'nin sınıflandırma işlemlerinde çalışma şekline bakıldığında, öncelikle LSTM katmanına, sıralı veri girilir. Her veri noktası, belirli bir zamanda (time step) olan veriyi temsil etmektedir. Ardından, LSTM katmanları, zaman içindeki bağımlılıkları ve kalıpları öğrenir. LSTM'den elde edilen özellikler, sınıflandırma katmanına (genellikle dense veya fully connected layer) aktarılır ve son olarak softmax veya sigmoid aktivasyon fonksiyonu ile sınıf olasılıkları hesaplanır (Jongjaraunsuk vd., 2024). LSTM'deki her bir kapının işleyişi Denklem 9-14 'te gösterildiği gibi formüle edilmektedir.

Unutma Kapısı:

$$f_t = \sigma(W_f \cdot [h_{t-1}, \chi_t] + b_f) \quad (9)$$

Burada, f_t , unutma kapısı çıkışıdır. σ , sigmoid aktivasyon fonksiyonudur. W_f ve b_f , ağırlık matrisi ve bias terimidir. h_{t-1} , önceki gizli durumdur. χ_t ise şu anki giriştir.

Giriş Kapısı ve Giriş Adayı:

$$i_t = \sigma(W_i \cdot [h_{t-1}, \chi_t] + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, \chi_t] + b_C) \quad (11)$$

Burada, i_t , giriş kapısının çıkışıdır. \tilde{C}_t , yeni bilgi adayıdır. W_i , W_C ve b_i , b_C , ilgili ağırlıklar ve bias terimleridir.

Hücre Durumu Güncellemesi:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (12)$$

Burada, C_t , güncellenmiş hücre durumudur. C_{t-1} , önceki hücre durumudur.

Çıkış Kapısı ve Gizli Durum:

$$o_t = \sigma(W_o \cdot [h_{t-1}, \chi_t] + b_o) \quad (13)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (14)$$

Burada, o_t , çıkış kapısının çıkışıdır. h_t , güncellenmiş gizli durumudur ve bu, sonraki katmanlara aktarılır. Son olarak, h_t , sınıflandırma katmanına girer ve sınıf tahminleri yapılır.

3.3. Konvolüsyonel sinir ağları yöntemi (Convolutional neural networks method)

CNN, özellikle görüntü işleme ve sınıflandırma gibi alanlarda yaygın olarak kullanılan bir derin öğrenme modelidir. CNN'ler, verilerin mekânsal ve zamansal ilişkilerini anlamak ve yakalamak için katmanlar aracılığıyla özellik çıkarımı yapmaktadırlar. Görüntü sınıflandırma, nesne tanıma ve ses analizi gibi birçok sıralı ve yapısal veriyle çalışabilirler (Maggiori vd., 2017). CNN, genellikle üç ana katman tipinden oluşmaktadır. Bunlardan ilki, evrişim katmanıdır (convolutional layer). Bu katman, girdi verisine küçük filtreler (kernels) uygular. Bu filtreler, veri üzerinde kaydırılarak (stride) özellikler çıkarılır. Çıkan özellik haritaları, girişin mekânsal özelliklerini koruyarak daha derin bir seviyede temsil edilmesini sağlar. İkincisi, havuzlama katmanıdır (pooling layer). Bu katman, evrişim katmanından gelen özellik haritalarının boyutunu azaltmak ve işlem maliyetini düşürmek için kullanılır. Genellikle “Max Pooling” veya “Average Pooling” gibi yöntemler kullanılır. Max Pooling, belirli bir alan içindeki en yüksek değeri alarak boyutu küçültür. Sonucu ana katman ise tam bağlantılı katmandır (fully connected layer). Bu katman, özellik haritalarını düzleştirerek (flatten) klasik yapay sinir ağına benzer şekilde tüm nöronları birbirine bağlar. Son olarak, çıkış katmanında softmax veya sigmoid aktivasyon fonksiyonu kullanılarak sınıflandırma yapılır (Chan ve Fan, 2022).

Bir CNN, sınıflandırma işlemlerinde belirli adımları takip ederek çalışır. İlk olarak, model bir girdi alır; bu genellikle bir görüntü veya sıralı veri şeklindedir. Ardından, evrişim ve havuzlama katmanları devreye girerek girdi verisinden özellikler çıkarır. Bu katmanlar, verinin mekânsal ve yapısal ilişkilerini kullanarak özellikleri giderek daha soyut bir şekilde temsil eder. Daha sonra, bu özellikler tam bağlantılı katmanlara iletilir ve burada işlenerek sınıf olasılıkları hesaplanır. Son adımda ise, çıktı katmanında her bir sınıf için olasılıklar verilir ve en yüksek olasılığa sahip sınıf, modelin tahmini olarak belirlenir. Bu süreç, CNN'nin veriyi işleyip doğru sınıflandırmayı yapmasını sağlar (Dubey vd., 2023). Bu sürecin matematiksel formülasyonu Denklem 15-19'da gösterilmektedir.

Evrişim Katmanı:

$$Z_{i,j}^{(k)} = (W^{(k)} * X)_{i,j} + b^{(k)} \quad (15)$$

Burada, $Z_{i,j}^{(k)}$, k filtresi için evrişim sonucundaki çıktı değeridir. $W^{(k)}$, k filtresinin ağırlık matrisi (kernel) ve $b^{(k)}$ ise bias terimidir. X , giriş verisidir ve $*$, evrişim işlemi ifade etmektedir.

Aktivasyon Fonksiyonu:

$$A_{i,j}^{(k)} = RELU(Z_{i,j}^{(k)}) = \max(0, Z_{i,j}^{(k)}) \quad (16)$$

Burada, RELU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmaktadır.

Havuzlama Katmanı (Max Pooling):

$$P_{i,j}^{(k)} = \max(A_{i,j}^{(k)}) \quad (17)$$

Burada, havuzlama işlemi belirli bir alan içinde en yüksek değeri alır ve böylece çıktı boyutunu küçültür.

Tam Bağlantılı Katman ve Çıkış:

$$Z = W \cdot A + b \quad (18)$$

Burada, Z , tam bağlantılı katmandaki çıktı vektördür. W , ağırlık matrisi ve b bias terimidir. A , düzleştirilmiş özelliklerdir.

Sınıflandırma Çıkışı:

$$P(y = j|x) = \frac{e^{Z_j}}{\sum_{k=1}^K e^{Z_k}} \quad (19)$$

3.4. Tabular öğrenme ağı (Tabular learning network-TabNet)

TabNet, tabular veri üzerinde çalışan ve özellikle sınıflandırma ve regresyon görevlerinde başarılı olan bir derin öğrenme modelidir. TabNet, dikkat (attention) mekanizmasını kullanarak önemli özellikleri otomatik olarak seçer ve öğrenme sürecini yönlendirir. Model, her adımda, dikkat mekanizmasını kullanarak hangi özelliklerin daha önemli olduğunu belirlemede ve bu özelliklere odaklanarak öğrenme sürecini optimize etmektedir. Diğer derin öğrenme modellerinden farklı olarak, TabNet tabular verilerle çalışırken açıklanabilirlik (explainability) ve verimli öğrenme özelliklerini bir araya getirmektedir (Albin Ahmed vd., 2023).

Modelde, veriler, giriş olarak alınır ve doğrusal katmanlar (fully connected layers) ile işlenir. Her giriş özelliği, doğrusal bir dönüşüme tabi tutulur. Model, hangi özelliklerin o adımda önemli olduğunu belirlemek için bir dikkat ağı (attention network) kullanır. Bu katmanlar, her adımda farklı özelliklere odaklanarak bilgiyi verimli bir şekilde öğrenir ve diğer adımlara aktarır. Dikkat mekanizması, verinin bir kısmını maskeler ve geri kalan kısmı seçerek bilgi kaybını minimize eder. Bu sayede, her adımda yeni ve önemli özellikler modele dahil edilir. Dikkat katmanlarından gelen bilgiler, karar katmanlarında işlenir ve bu katmanlar, sınıflandırma veya regresyon görevleri için nihai tahminleri oluşturur (Gao vd., 2022). Bu sürecin matematiksel formülasyonu Denklem 20-23'te gösterilmektedir.

Girdi Dönüşümü:

$$x'_t = W_t \cdot x + b_t \quad (20)$$

Burada, x'_t , girişin doğrusal dönüşümünden elde edilen çıktıdır. W_t ve b_t , ağırlık ve bias terimleridir.

Dikkat Mekanizması:

$$M_t = \text{Softmax}(W_m \cdot x'_t + b_m) \quad (21)$$

Burada, M_t , o adımda kullanılan maskedir. W_m ve b_m , ağırlık ve bias terimleridir.

Özellik Seçimi ve Maskeleye:

$$x_{t+1} = M_t \odot x'_t \quad (22)$$

Burada, x_{t+1} , maskelenmiş ve seçilmiş özelliklerdir. \odot , eleman bazlı çarpma işlemi ifade etmektedir.

Karar Adımları:

$$y_t = f(x_{t+1}) \quad (23)$$

Burada, y_t , her adımda yapılan tahmindir. f , karar adımıdaki doğrusal dönüşümler ve aktivasyon fonksiyonları ile ifade edilen bir fonksiyondur. Son aşamada, her karar adımıda elde edilen bilgiler birleştirilerek nihai sınıf olasılıkları hesaplanır.

3.5. Yapay sinir ağı-YSA (Artificial neural network-ANN)

YSA, insan beynindeki nöronların çalışma prensiplerinden ilham alınarak geliştirilmiş bir makine öğrenmesi modelidir. YSA'lar, katmanlar halinde düzenlenmiş nöronlardan (node) oluşur ve bu nöronlar, veriler arasındaki karmaşık ilişkileri öğrenerek çeşitli görevleri (sınıflandırma, regresyon, vb.) gerçekleştirebilirler. Görüntü tanıma, metin analizi ve zaman serisi tahmini gibi birçok farklı alanda kullanılabilirler (Huang vd., 2020).

YSA, genellikle üç ana katman tipinden oluşmaktadır: Girdi, gizli ve çıkış katmanı. Girdi katmanı, modelin aldığı ham veriyi temsil etmektedir. Her bir girdi, bu katmandaki bir nöron tarafından işlenir. Girdi katmanından gelen veriler, gizli katmanlarda işlenir. Gizli katmanlar, veriler arasındaki karmaşık ilişkileri öğrenir. Bu katmanlar, doğrusal olmayan (non-linear) aktivasyon fonksiyonları ile donatılmıştır ve bu sayede veriler arasındaki karmaşık kalıpları yakalayabilir (Al-Shamisi vd., 2013). Gizli katmanlardan gelen işlenmiş bilgiler, çıkış katmanında toplanır ve sınıflandırma (veya başka bir görev) için son tahminler yapılır. Çıkış katmanındaki nöron sayısı, sınıflandırılacak sınıf sayısına eşittir. YSA ile sınıflandırma işlemi sürecinde, girdi verileri, giriş katmanına aktarılır ve bu katmandaki nöronlar, veriyi modelin içine alır. Gizli katmanlarda, her nöron bir önceki katmandan gelen veriyi ağırlıklarla çarpır ve bir bias değeri ekleyerek bir toplam elde eder. Bu toplam, aktivasyon fonksiyonu ile işlenir ve doğrusal olmayan bir çıkış üretilir. Bu işlem, katmanlar arasında devam eder. Çıkış katmanına ulaşıldığında, model her sınıf için olasılıklar üretir ve en yüksek olasılığa sahip sınıf modelin tahmini olarak belirlenir (Arkin vd., 2020). Bu sürecin matematiksel formülasyonları Denklem 24-26'da gösterilmiştir.

Ağırlıklı Toplama:

$$z = \sum_{i=1}^n w_i x_i + b \quad (24)$$

Burada, z , nöronun toplam ağırlıklı girdisidir. w_i , i girdisinin ağırlığıdır. x_i , i girdisinin kendisidir. b , nöronun bias (sapma) terimidir.

Aktivasyon Fonksiyonu:

$$\alpha = \text{Activation}(z) \quad (25)$$

z , değeri bir aktivasyon fonksiyonuna (sigmoid, ReLU vd.) uygulanarak doğrusal olmayan bir dönüşüm yapılır. Burada, α , nöronun aktivasyon çıkışıdır.

Çıkış Katmanı:

$$P(y = j|x) = \frac{e^{Z_j}}{\sum_{k=1}^K e^{Z_k}} \quad (26)$$

Burada, $P(y = j|x)$, girişin j sınıfına ait olma olasılığıdır. Z_j , j sınıfı için çıkış katmanından gelen toplamdır. Bu süreç, YSA'nın her nöronunun çıktısını hesaplamak için tekrar edilir ve en sonunda, modelin verdiği en yüksek olasılıklı sınıf, tahmin edilen sınıf olarak belirlenir.

3.6. Rastgele orman yöntemi (Random forest method)

Rastgele Orman, sınıflandırma ve regresyon görevlerinde kullanılan, birden fazla karar ağacının (decision tree) bir araya getirilmesiyle oluşturulan bir makine öğrenmesi modelidir. Temel mantığı, birçok karar ağacını eğiterek bu ağaçların tahminlerini birleştirip (çoğunlukla oylama veya ortalama alma yöntemi ile) daha doğru ve genelleştirilebilir sonuçlar elde etmektir. Bu yöntem, karar ağaçlarının zayıf yönlerini azaltarak daha sağlam ve etkili bir model oluşturur (Liu vd., 2023). Sınıflandırma sürecinde, model, eğitim veri setinden rastgele örnekler seçerek (bootstrap yöntemi) her bir ağaç için farklı alt kümeler oluşturur. Bu yöntem, ormanın her ağacının farklı veri örnekleriyle eğitilmesini sağlar ve çeşitliliği artırır. Her bir ağaç, her düğümde tüm özellikler yerine rastgele bir alt küme özellik kullanır. Bu sayede, her ağaç farklı bir özellik kombinasyonu kullanarak eğitilir ve bu, ağaçlar arasında çeşitliliği artırarak aşırı uyumu (overfitting) önler. Rastgele seçilen veri örnekleri ve özellikler kullanılarak her ağaç eğitilir. Her ağaç, kendi veri kümesi üzerinde en iyi bölünmeyi bulmak için çalışır ve bir karar ağacı oluşturur. Model, yeni bir veri örneği geldiğinde, ormandaki her ağaç bu veri örneği için bir sınıf tahmini yapar. Sınıflandırma için, en çok oyu alan sınıf nihai tahmin olarak kabul edilir (Anjum vd., 2023). Bu sürecin, matematiksel formülasyonu Denklem 27-30'da gösterilmektedir.

Bootstrap Yöntemi:

$$D_i \subset D \quad (27)$$

Burada, D_i , i . karar ağacı için seçilen veri alt kümesidir. *Özellik Alt Kümesi Seçimi:*

$$F \subseteq \{X_1, X_2, \dots, X_M\} \quad (28)$$

Burada, her düğümde, toplam M özellik arasından rastgele m sayıda özellik seçilir. F , seçilen özellik alt kümesidir ve $m \ll M$.

Karar Ağaçlarının Eğitimi:

$$t^* = \arg \max (Gain(t)) \quad (29)$$

Burada, her bir karar ağacı, kendi veri kümesi ve seçilen özellikler kullanılarak eğitilir. $Gain(t)$, düğümdeki bilgi kazancını ifade etmektedir (bilgi kazancı veya Gini indeksi).

Tahmin ve Oylama:

$$\hat{y} = \text{mode}(\hat{y}_1, \hat{y}_2, \dots, \hat{y}_B) \quad (30)$$

Burada, \hat{y} , rastgele ormanın nihai tahminidir. \hat{y}_i , her bir ağacın yaptığı tahmindir ve B , ormandaki ağaç sayısıdır. Sınıflandırmada, tüm ağaçların tahminleri alınır ve en sık tekrar eden sınıf seçilir (mode).

3.7. Destek vektör makinesi – DVM (Support vector machine- SVM)

DVM, sınıflandırma ve regresyon gibi makine öğrenmesi görevlerinde kullanılan, veri noktalarını sınıflandırmak için hiper düzlemler oluşturan bir algoritmadır. DVM, doğrusal ve doğrusal olmayan veri kümeleri için çalışabilen, özellikle yüksek boyutlu veri setlerinde etkili sonuçlar veren bir modeldir. Temel amacı, veri noktalarını en iyi şekilde ayıracak ve sınıflar arasındaki mesafeyi maksimize edecek bir hiper düzlem bulmaktır (An ve Liang, 2012).

DVM, veri noktalarını iki farklı sınıf arasında ayıran bir hiper düzlem oluşturur. Bu hiper düzlem, sınıflar arasındaki maksimum marjini (margin) sağlayacak şekilde yerleştirilir. Model, ayırıcı hiper düzleme en yakın olan veri noktalarına (destek vektörleri) dayanarak bu hiper düzlemi optimize etmektedir (Lee vd., 2016). DVM, veri noktalarını özellik uzayında temsil eder. Her bir veri noktası, bu uzayda bir vektör olarak ifade edilir. Algoritma, veri noktalarını ayıracak bir hiper düzlem bulmaya çalışır. Bu hiper düzlem, veri noktalarını doğru şekilde sınıflandıracak ve marjini maksimum yapacak şekilde optimize edilir. Hiper düzleme en yakın olan ve bu düzlemin oluşturulmasında en etkili olan veri noktaları, destek vektörleri olarak adlandırılır. Bu noktalar, hiper düzlemin konumunu ve yönünü belirler. Model, hiper düzleme dayalı olarak her yeni veri noktası için bir karar fonksiyonu kullanarak tahmin yapar. Veri noktası bu fonksiyona göre sınıflandırılır (Xi vd., 2017). Tüm bu süreç, matematiksel formülasyonları ile birlikte Denklem 31-35'te gösterilmektedir.

Hiper Düzlem Denklemi:

$$w \cdot x + b = 0 \quad (31)$$

Burada, w , hiper düzlemin normal vektörüdür. x , veri noktası ve b , bias terimidir.

Marjin Maksimizasyonu:

$$\text{minimize } \frac{1}{2} \|w\|^2 \quad (32)$$

İki sınıf arasındaki mesafeyi maksimize etmek için hiper düzlem Denklem 32'de gösterildiği gibi optimize edilmektedir. Bu optimizasyon, w vektörünün normunu minimize etmeyi amaçlar ve böylece maksimum marjini elde edilir.

Kısıt Koşulları:

$$y_i(w \cdot x_i + b) \geq 1 \quad \forall_i \quad (33)$$

Hiper düzlem, her sınıf için veri noktalarının doğru tarafta olmasını sağlayacak şekilde Denklem 33'teki gibi düzenlenir. Burada, y_i , veri noktasının sınıf etiketidir (+1 veya -1). x_i , veri noktasıdır. DVM, marjini maksimize ederken, genellikle dual problem kullanılarak çözülür. Bu aşama Denklem 34'te gösterilmektedir.

Lagrange Çarpanları ve Dual Problem:

$$L(w, b, \alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (34)$$

Burada, α_i , Lagrange çarpanlarıdır ve her veri noktası için optimize edilir. Eğitim tamamlandıktan sonra, yeni bir veri noktası x için karar fonksiyonu Denklem 35'teki gibidir.

Karar Fonksiyonu:

$$f(x) = \text{sign}(w \cdot x + b) \quad (35)$$

Burada, sign fonksiyonu, x noktasının hangi sınıfa ait olduğunu belirlemektedir.

4. Bulgular (Findings)

Bu çalışmada, sınıflandırma işlemi için kullanılan tüm makine öğrenimi yöntemlerinin optimal hiperparametrelerinin belirlenmesinde Optuna kütüphanesi kullanılmıştır. Optuna, hiperparametre optimizasyonu için bir otomatikleştirme kütüphanesidir ve makine öğrenimi modellerinin performansını artırmak için en iyi hiperparametreleri bulmayı amaçlamaktadır. Sınıflandırma işlemi için YSA, LSTM, CNN, TabNet, Gradient Boosting, Rastgele Orman (RF) ve DVM modellerinin optimal hiperparametrelerinin belirlenmesinde Python programlama dili kullanılarak Optuna kütüphanesi kapsamlı bir şekilde uygulanmıştır. Optuna, her modelin özel gereksinimlerine uygun olacak şekilde arama alanları (search spaces) tanımlayarak hiperparametre optimizasyonu sağlamıştır. YSA, LSTM ve CNN modellerinde TensorFlow ve PyTorch kütüphaneleri kullanılarak ağ derinliği (katman sayısı), nöron sayısı, öğrenme oranı (learning rate), aktivasyon fonksiyonları ve batch size

gibi parametreler optimize edilmiştir. TabNet için ise, Optuna kullanılarak TabNet'in dikkat (attention) katmanlarının sayısı, öğrenme oranı ve maskeleyme oranı gibi spesifik hiperparametreler ayarlanmıştır. Gradient Boosting (GB) modelinde, learning rate, max_depth ve n_estimators gibi ağaç tabanlı yapıların performansını artıran parametreler optimize edilmiştir. Rastgele Orman modelinde, ağaç sayısı (n_estimators), maksimum derinlik (max_depth) vd. gibi

hiperparametreler belirlenmiştir. DVM modeli için ise, kernel tipi (linear, rbf vb.), düzenleme parametresi (C), ve kernel parametreleri (gamma) gibi ayarlar Optuna aracılığıyla titizlikle optimize edilmiştir. Bu sayede, her modelin performansı en üst düzeye çıkarılarak sınıflandırma görevinde yüksek doğruluk oranları elde edilmiştir. Sonuç olarak, bu optimizasyon süreci sonunda elde edilen tüm hiperparametreler Tablo 2'de gösterilmiştir.

Tablo 2. Modellerin optuna ile belirlenen optimal hiperparametreleri (Optimal hyperparameters of the models determined by optuna)

Model	Hiperparametreler	Değer
YSA	n_layers	3
	Units_L0	127
	Activation_L0	ReLU
	Units_L1	55
	Activation_L1	tanh
	Units_L2	61
	Activation_L2	ReLU
	Learning Rate	0.0037
LSTM	Batch Size	108
	lstm_units	76
	n_layers	1
	Units_L0	75
CNN	Learning Rate	2.162e-05
	Batch Size	128
	n_filters	24
	Kernel size	2
	n_layers	2
	Units_L0	119
TabNet	Units_L1	57
	Learning Rate	0.0006
	Batch Size	74
	n_d	16
	n_a	16
	n_steps	5
	gamma	1.5
GBM	Lambda_sparse	0.0001
	Optimizer_fn	Torch.Optim.Adam
	Optimizer_params	"lr": 1e-2
	Mask_type	sparsemax
	n_independent	2
	n_shared	2
	virtual_batch_size	128
	Momentum	0.02
	Clip_value	2.0
	Scheduler_fn	torch.optim.lr_scheduler.StepLR
	Scheduler_params	"step_size": 10, "gamma": 0.1
	Epsilon	1e-15
	n_estimators	120
Learning Rate	0.1373	
max_depth	9	
Rastgele Orman	n_estimators	272
	min_samples_split	5
	max_depth	9
	min_samples_leaf	8
DVM	Bootstrap	True
	Kernel	Linear
	C	0.0959
	Gamma	0.0012

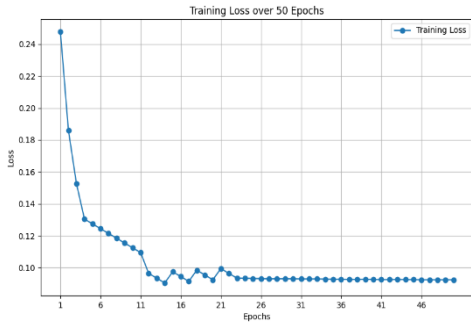
Tablo 3'te yer alan sınıflandırma raporuna göre, kronik hastalığı olan bireyleri (0 Sınıfı) ve olmayan bireyleri (1 Sınıfı) sınıflandırmak üzere kullanılan modellerin test performansları karşılaştırılmıştır. YSA modelinde, 0 sınıfı için F1 puanı 0,92 olarak hesaplanmış olup, duyarlılık değeri 0,93 ve kesinlik değeri 0,92'dir. 1 sınıfı için ise F1 puanı 0,96, duyarlılık 0,96 ve kesinlik 0,95 olarak gözlenmiştir. LSTM modeli benzer sonuçlar vermekle birlikte, 0 sınıfı için F1 puanı 0,92 ve 1 sınıfı için 0,95 olarak hesaplanmıştır. CNN modeli, her iki sınıfta da yüksek performans sergileyerek 0 sınıfında F1 puanı 0,94 ve 1 sınıfında 0,96'ya ulaşmıştır. TabNet modeli ise en yüksek doğruluğa ulaşarak, 0 sınıfında F1 puanını 0,96, 1 sınıfında ise 0,97 olarak vermiştir. GBM ve RF modelleri nispeten daha düşük performans göstermiş, her iki model de 0 sınıfı için 0,90 civarında bir F1 puanı elde etmiş, 1 sınıfı için ise 0,95 seviyesine çıkmıştır. DVM ise genel olarak daha düşük performans sergilemiş olup, 0 sınıfında F1 puanı 0,87, 1 sınıfında ise 0,93 olarak gözlenmiştir. Genel olarak, TabNet ve CNN modelleri tüm sınıflarda daha yüksek doğruluk ve sınıflandırma performansı sergilerken, GB ve RF

modelleri daha ortalama bir performans göstermiştir. DVM ise kronik hastalığı olan bireylerin sınıflandırılmasında daha düşük bir performans sergilemiştir.

Şekil 1, en başarılı sınıflandırma performansını gösteren TabNet modelinin eğitim sürecindeki hatanın iterasyon sayısına bağlı olarak nasıl değiştiğini gösteren bir eğriyi göstermektedir. Grafikte gözlemlendiği üzere, eğitim süreci başlangıçta yüksek bir kayıp değeriyle (yaklaşık 0,24) başlamış ve ilk birkaç epoch boyunca kayıpta hızlı bir düşüş gerçekleşmiştir. İlk 10 epoch sonrasında, kayıp değeri önemli ölçüde azalarak 0,10 seviyelerine ulaşmıştır. Bu noktadan itibaren, kayıpta önemli bir değişim görülmemekte ve modelin performansı stabil hale gelmiştir. Özellikle 20. epoch'tan sonra kaybın sabitlenmesi, modelin daha fazla öğrenme sağlayamadığını ve büyük ölçüde yakınsadığını (converge) göstermektedir. Grafik, modelin eğitim süreci boyunca etkin bir şekilde optimize olduğunu ve aşırı öğrenme (overfitting) belirtisi göstermeden kayıp fonksiyonunu minimize ettiğini göstermektedir.

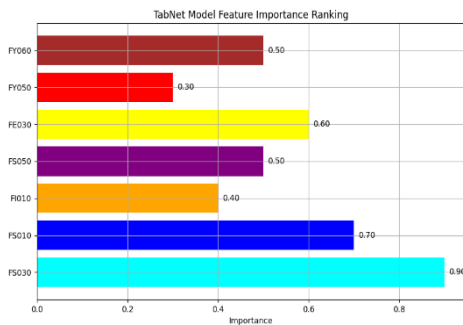
Tablo 3. Modellerin test sonuçlarına ilişkin sınıflandırma raporu (Classification report on the test results of the models)

Model		Kesinlik	Duyarlılık	F1 Puanı	Destek
YSA	0	0,93	0,92	0,92	4.492
	1	0,95	0,96	0,96	8.430
	Doğ.			0,95	12.922
	Genel Ort.	0,94	0,94	0,94	12.922
	Ağır. Ort.	0,95	0,95	0,95	12.922
LSTM	0	0,93	0,91	0,92	4.492
	1	0,95	0,96	0,95	8.430
	Doğ.			0,94	12.922
	Genel Ort.	0,94	0,94	0,94	12.922
	Ağır. Ort.	0,94	0,94	0,94	12.922
CNN	0	0,95	0,93	0,94	4.492
	1	0,96	0,97	0,96	8.430
	Doğ.			0,96	12.922
	Genel Ort.	0,95	0,95	0,95	12.922
	Ağır. Ort.	0,96	0,96	0,96	12.922
TabNet	0	0,96	0,95	0,96	4.492
	1	0,97	0,97	0,97	8.430
	Doğ.			0,97	12.922
	Genel Ort.	0,97	0,97	0,97	12.922
	Ağır. Ort.	0,97	0,97	0,97	12.922
GBM	0	0,90	0,90	0,90	4.492
	1	0,94	0,95	0,95	8.430
	Doğ.			0,93	12.922
	Genel Ort.	0,92	0,92	0,92	12.922
	Ağır. Ort.	0,93	0,93	0,93	12.922
RF	0	0,90	0,89	0,90	4.492
	1	0,94	0,95	0,95	8.430
	Doğ.			0,93	12.922
	Genel Ort.	0,92	0,92	0,92	12.922
	Ağır. Ort.	0,93	0,93	0,93	12.922
DVM	0	0,89	0,85	0,87	4.492
	1	0,91	0,94	0,93	8.430
	Doğ.			0,91	12.922
	Genel Ort.	0,90	0,90	0,90	12.922
	Ağır. Ort.	0,91	0,91	0,91	12.922



Şekil 1. TabNet modelinin eğitim hatası (Training error of the Tabnet model)


Şekil 2, TabNet modelindeki bağımsız değişkenlerin önem derecelerini gösteren bir sıralama çubuk grafiğidir. Burada, FS030, FS010, FI010, FS050, FE030, FY050 ve FY060 olarak gösterilen değişkenler (Tablo 1’de açıklanmıştır), modelin tahmin performansı üzerindeki etkilerine göre sıralanmıştır. FS030 olarak ifade edilen ve ferdin sağlık probleminden ötürü faaliyetlerde sınırlama olup olmadığını gösteren özellik model için açık ara en önemli değişken olarak belirtilmiş ve en yüksek öneme sahip olduğu gözlemlenmiştir. Bunu 0.70 önem derecesi ile FS010, ardından 0.60 önem derecesine sahip FE030 takip etmektedir. Diğer özellikler arasında FY060 ve FS050’nin her ikisi de 0.50 önem derecesi ile benzer öneme sahipken, FI010’ın önemi 0.40 olarak belirlenmiştir. FY050, 0.30 ile en düşük önem derecesine sahip özellik olarak sıralamada yer almaktadır. Bu sonuçlar, TabNet modelinin dikkat mekanizması aracılığıyla bazı özelliklere daha fazla ağırlık verdiğini ve bu özelliklerin modelin sınıflandırma performansı üzerindeki etkisinin farklı olduğunu göstermektedir. Özellikle FS030 ve FS010 özellikleri, modelin öğrenme sürecinde kritik bir rol oynamaktadır.



Şekil 2. TabNet modeline göre bağımsız değişkenlerin önem sıralaması (Importance ranking of independent variables)

Şekil 3’te, TabNet modelinin test performansını gösteren karmaşıklık matrisi yer almaktadır. “0” etiketi kronik bir hastalığı olan bireyleri, “1” etiketi ise hastalığı olmayan bireyleri temsil etmektedir. Kronik hastalığı olan bireyler için (0), model 4.322 doğru sınıflandırma (Gerçek Pozitif) yaparken, 170 bireyi

yanlış bir şekilde kronik hastalığı yok olarak tahmin etmiştir (Yanlış Negatif). Kronik hastalığı olmayan bireyler için (1), model 8.248 bireyi doğru sınıflandırmıştır (Gerçek Negatif), ancak 182 bireyi yanlış bir şekilde kronik hastalığı var olarak sınıflandırmıştır (Yanlış Pozitif). Modelin genel performansına bakıldığında, hem kronik hastalığı olan bireyler hem de olmayan bireyler için yüksek doğruluk oranları elde ettiği görülmektedir.



Şekil 3. TabNet modelinin test sonuçlarına ilişkin karmaşıklık matrisi (Confusion matrix for the test results of the TabNet model)

Bu aşamadan sonra, modelin genel performansını değerlendirmek ve genelleme yeteneğini ölçmek için kullanılan yaygın bir doğrulama tekniği olan çapraz doğrulama yöntemi uygulanarak, modelin sadece tek bir eğitim ve test veri setiyle değil, farklı veri parçalarıyla eğitilip test edilmesi sağlanmıştır. Bu sayede, modelin aşırı uyum (overfitting) veya eksik uyum (underfitting) yapma olasılığı değerlendirilmiş ve modelin daha genelleştirilebilir sonuçlar üretebilme yeteneği daha doğru bir şekilde ölçülmüştür. Bu süreçte, veri seti 5 eşit parçaya bölünmüştür. Her bir iterasyonda, bu 5 parçadan biri test seti olarak ayrılırken geri kalan 4 parça modelin eğitimi için kullanılmıştır. Bu işlem 5 kez tekrarlanmış ve her seferinde farklı bir parça test seti olarak kullanılmıştır. Sonuç olarak, modelin performansı her bir iterasyonda hesaplanmış ve tüm iterasyonların ortalaması alınarak daha dengeli bir performans ölçümü elde edilmiştir. Bu sürece ilişkin sonuçlar, Tablo 4’te gösterilmiştir.

Tablo 4. TabNet modelinin 5 katlı çapraz doğrulama sonuçları (5-fold cross-validation results of the TabNet model)

Model	Ort.Doğruluk	Kat1	Kat2	Kat3	Kat4	Kat 5
TabNet	0,972	0,973	0,969	0,975	0,973	0,971

Tablo 4’teki sonuçlar incelendiğinde, her bir katmandaki doğruluk değerleri sırasıyla Kat 1: 0,973, Kat 2: 0,969, Kat 3: 0,975, Kat 4: 0,973 ve Kat 5: 0,971 olarak hesaplanmıştır. Bu değerlerin ortalaması ise 0,972 olarak belirlenmiştir. Sonuçlar, TabNet modelinin sınıflandırma performansının her bir doğrulama setinde oldukça istikrarlı olduğunu ve genelleme yeteneğinin

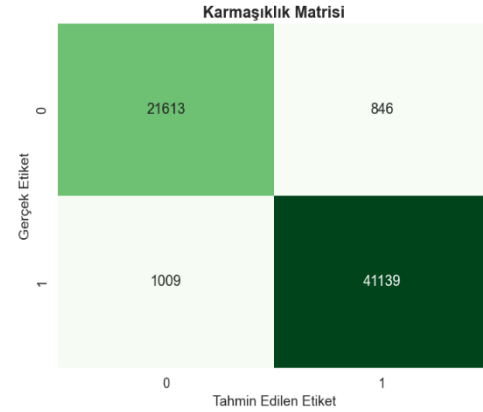
yüksek olduğunu göstermektedir. Farklı veri bölümlerinde modelin performansındaki küçük farklılıklar (0,969 ile 0,975 arasında değişen doğruluk oranları) modelin tutarlı olduğunu ve aşırı uyuma (overfitting) karşı dirençli olduğunu işaret etmektedir. Ortalama doğruluk oranı olan 0,972, modelin genel olarak veri setinde yüksek bir doğruluk sağladığını ve güvenilir bir performans sergilediğini ortaya koymaktadır. Bu sonuçlar, TabNet modelinin test edilmemiş veriler üzerinde de benzer şekilde başarılı olabileceğini öngörmektedir. TabNet modelinin tüm veri seti üzerinde tahmin performansının değerlendirilmesi, modelin genelleme yeteneğini daha kapsamlı bir şekilde incelemek açısından kritik bir adım olacaktır. 5 katlı çapraz doğrulama sonuçları modelin farklı veri bölümlerinde istikrarlı performans sergilediğini gösterse de, tüm veri seti üzerindeki tahmin performansının değerlendirilmesi, modelin gerçek dünyadaki veri kümeleri üzerindeki etkinliğini daha net ortaya koyacaktır. Bu değerlendirme, modelin yalnızca eğitim ve test verilerindeki başarısını değil, tüm veri seti ile ne kadar iyi genelleme yapabileceğini gösterecektir. Böylece, elde edilen performans ölçütleri (doğruluk, kesinlik, duyarlılık, F1 puanı vb.), modelin çeşitli veri yapıları karşısında sağlam ve güvenilir sonuçlar üretebilme kapasitesini doğrulayacaktır. Bu aşama, modelin pratik uygulamalarda kullanılabilirliğini belirleyecek ve potansiyel zayıf yönlerini ortaya çıkararak olası iyileştirmeler için yol gösterecektir. Modelin tüm veri seti üzerindeki tahmin performansına ilişkin sınıflandırma raporu Tablo 5'te sunulmaktadır.

Tablo 5. TabNet modelinin tüm veri seti tahmin performansını gösteren sınıflandırma raporu (Classification report showing the prediction performance of the TabNet model across the entire dataset)

Model	Kesinlik	Duyarlılık	F1 Puanı	Destek	
TabNet	0	0,96	0,95	0,95	22.459
	1	0,97	0,97	0,97	42.148
	Doğ.			0,97	64.607
	Genel Ort.	0,96	0,96	0,96	64.607
	Ağır. Ort.	0,97	0,97	0,97	64.607

İlgili tablodaki sınıflandırma raporuna göre, kronik hastalığı olan bireyler (0) için modelin kesinlik değeri 0,96, duyarlılık değeri 0,95 ve F1 puanı 0,95 olarak hesaplanmıştır. Kronik hastalığı olmayan bireyler (1) için ise, modelin kesinlik ve duyarlılık değerleri 0,97 olup, F1 puanı da yine 0,97 olarak kaydedilmiştir. Modelin genel doğruluk oranı 0,97 olarak belirlenmiş ve modelin sınıflandırma performansı her iki sınıfta da oldukça yüksektir. Genel ortalamalar incelendiğinde, kesinlik, duyarlılık ve F1 puanlarının tüm veri seti için sırasıyla 0,96, 0,96 ve 0,96 olduğu görülmektedir. Ağırlıklı ortalama değerler de aynı doğrultuda, tüm metriklerde 0,97 seviyesinde olup, TabNet modelinin geniş bir veri seti üzerinde tutarlı ve güçlü bir

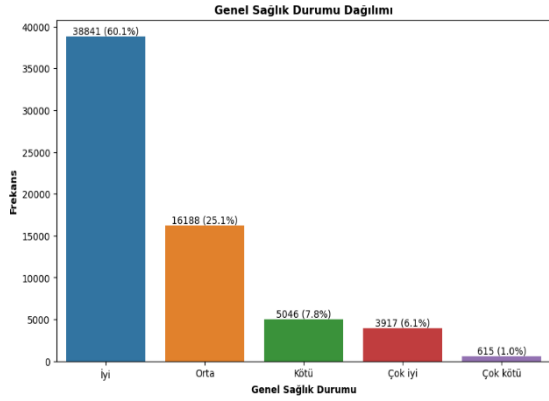
performans sergilediğini göstermektedir. Bu sonuçlar, modelin sınıflar arasında dengeli bir performans sunduğunu ve hem kronik hastalığı olan hem de olmayan bireyleri yüksek doğrulukla sınıflandırabildiğini ortaya koymaktadır. Bununla birlikte, modelin bu sınıflandırma sürecine ilişkin karmaşıklık matrisi Şekil 4'te sunulmuştur.



Şekil 4. TabNet modelinin tüm veri seti tahmin performansını gösteren karmaşıklık matrisi (Confusion matrix showing the prediction performance of the TabNet model across the entire dataset)


Gerçek etiketlerle karşılaştırıldığında, model kronik hastalığı olan bireyleri (0) 21.613 kez doğru sınıflandırmış (Gerçek Pozitif) ve 846 bireyi yanlış bir şekilde kronik hastalığı yok olarak tahmin etmiştir (Yanlış Negatif). Kronik hastalığı olmayan bireyler (1) için model 41.139 doğru sınıflandırma yapmış (Gerçek Negatif) ve 1.009 bireyi yanlış bir şekilde kronik hastalığı var olarak sınıflandırmıştır (Yanlış Pozitif). Modelin genel doğruluk oranı oldukça yüksek olup, her iki sınıfta da dengeli bir performans sergilediği gözlenmektedir. Ancak, yanlış negatif ve yanlış pozitif sayılarının varlığı, modelin sınıflandırma performansında bazı iyileştirme fırsatlarının olduğunu göstermektedir. Genel olarak, bu matriste TabNet modelinin kronik hastalığa sahip olan ve olmayan bireyleri yüksek doğrulukla sınıflandırdığı ve genelleme yeteneğinin güçlü olduğu anlaşılmaktadır.

Ek olarak, Şekil 5, TÜİK'in 2023 Gelir ve Yaşam Koşulları Araştırması (GYKA) verilerine dayanarak, Türkiye'deki bireylerin genel sağlık durumunun dağılımını göstermektedir. GYKA, Türkiye'de 64607 birey üzerinde uygulanmıştır. Araştırmaya katılan bireylerin büyük bir kısmı (%60.1) kendilerini "iyi" sağlık durumunda olarak tanımlarken, "orta" sağlık durumunda olanların oranı %25.1'dir. "Kötü" sağlık durumuna sahip bireyler %7.8, "çok iyi" durumda olanlar %6.1 ve "çok kötü" sağlık durumunda olanlar ise %1.0 olarak belirlenmiştir. Gradient Boosting sınıflandırma yöntemi kullanılarak yapılan bu analiz, nüfusun sağlık durumları üzerine değerli içgörüler sağlamakta ve sağlık politikalarının şekillendirilmesi için kullanılabilir önemli bilgiler sunmaktadır.



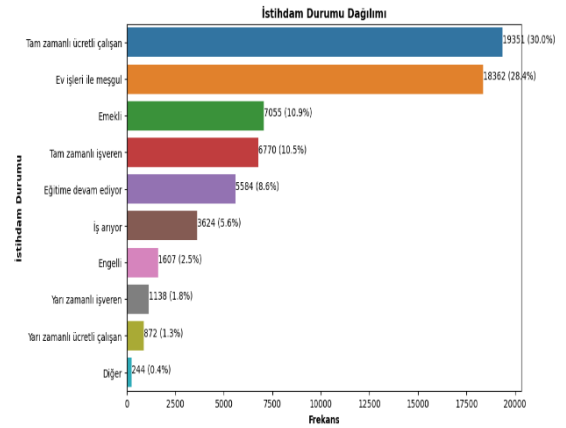
Şekil 5. Genel sağlık durumu dağılımı (Distribution of general health status)

Şekil 6, bireylerin günlük faaliyetlerindeki sınırlamaların dağılımını göstermektedir. Bireylerin büyük bir çoğunluğu (%74.3) günlük faaliyetlerinde herhangi bir sınırlamaya sahip olmadıklarını belirtirken, %19.0'lık bir kesim bazı sınırlamalar yaşadığını, %6.6'lık bir grup ise faaliyetlerinde ciddi sınırlamalar olduğunu ifade etmiştir. Bu veriler, nüfusun sağlıklı ilgili kısıtlamalarının kapsamlı bir resmini çizmekte ve bu konularda müdahale gerektirebilecek alanları belirlemede kullanılabilir.



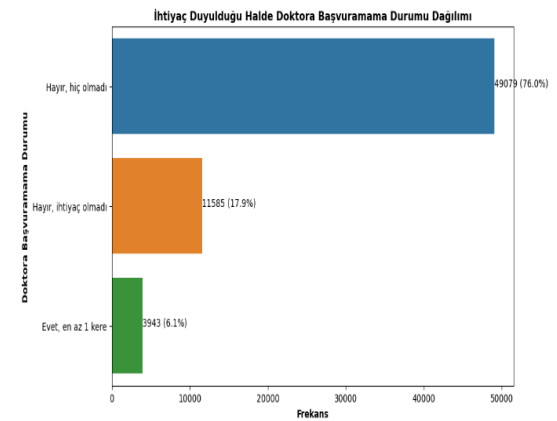
Şekil 6. Faaliyetlerde sınırlama durumu dağılımı (Distribution of restrictions on activities)

Buna ek olarak, Şekil 7'de, bireylerin istihdam durumu dağılımını gösteren bir histogram gösterilmektedir. En yüksek frekanslı kategori, tam zamanlı ücretli çalışanları temsil etmekte (%30.0), ardından ev işleri ile meşgul olanlar (%28.4) gelmektedir. Emekliler %10.9 ile üçüncü en büyük grubu oluştururken, tam zamanlı işverenler ve eğitime devam edenler sırasıyla %10.5 ve %8.6 ile takip etmektedir. İş arayanlar ve engelliler de sırasıyla %5.6 ve %2.5'lik bir orana sahiptir. Yarı zamanlı çalışanlar ve diğer kategoride yer alanlar ise toplamın daha küçük bir yüzdesini oluşturmaktadır. Bu veriler, istihdam piyasasının yapısı ve iş gücüne katılımın çeşitli yönleri hakkında önemli bilgiler sunmaktadır.




Şekil 7. İstihdam durumu dağılımı (Employment status distribution)

Şekil 8, bireylerin ihtiyaç duydukları halde doktora başvurup başvurmadıklarını gösteren bir dağılımı temsil etmektedir. %76.0'lık büyük bir çoğunluk, ihtiyaç duyduğunda doktora başvurmadığını söylemiş yani herhangi bir engelle karşılaşmadıklarını belirtmiştir. %17.9'luk bir kesim belirli durumlarda doktora başvuramama durumu yaşadığını ifade ederken, sadece %6.1'lik bir grup ihtiyaç duyduklarında en az bir kez doktora başvuramama durumu yaşadığını belirtmiştir. Bu veriler, sağlık hizmetlerine erişim konusunda genel olarak olumlu bir tablo çizerken, azınlıkta olan bir grubun karşılaştığı zorluklara dikkat çekmektedir.



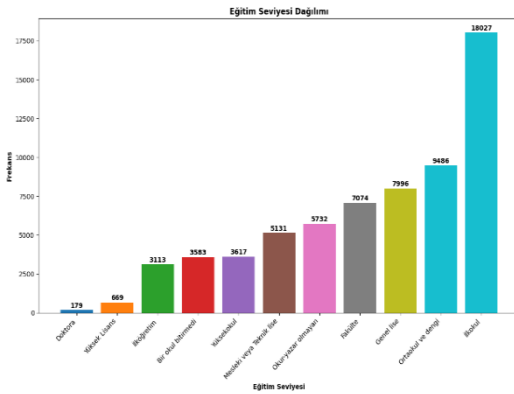
Şekil 8. İhtiyaç duyulduğu halde doktora başvuramama durumu dağılımı (Distribution of inability to consult a doctor when needed)

Şekil 9'da, bireylerin kronik hastalık durum dağılımı gösterilmektedir. Görselde görüldüğü üzere, katılımcıların %65.2'si herhangi bir kronik hastalığa sahip olmadıklarını belirtmiş, buna karşın %34.8'i kronik bir hastalığa sahip olduklarını ifade etmiştir. Bu oranlar, ülkedeki kronik sağlık sorunlarının yaygınlığını ve toplum sağlığına yönelik politika ve kaynak dağılımı için önemli bir veri noktasını temsil etmektedir.



Şekil 9. Kronik hastalık durumu dağılımı (Chronic disease status distribution)

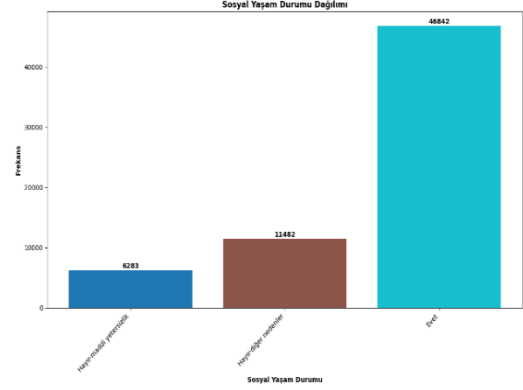
Şekil 10, bireylerin eğitim seviyesi dağılımını göstermektedir. En yüksek frekansa sahip eğitim seviyesi 18.027 birey ile "İlkokul" kategorisi olurken, bu grubu 9.486 birey ile "Ortaokul ve dengi" ve 7.996 birey ile "Genel lise" kategorileri takip etmektedir. "Fakülte" mezunlarının sayısı 7.074 iken, "Okur-yazar olmayan" bireyler 5.732, "Mesleki veya Teknik lise" mezunları ise 5.131 frekansa sahiptir. Daha düşük frekanslar ise "Yükseköğretim" (3.617), "Bir okul bitirmede" (3.583), ve "İlköğretim" (3.113) kategorilerinde gözlemlenmiştir. En az sayıda birey "Yüksek Lisans" (669) ve "Doktora" (179) seviyelerinde bulunmaktadır. Bu dağılım, veri setinde eğitim seviyesi bakımından bir yoğunlaşmanın ilköğretim ve ortaokul seviyelerinde olduğunu, yükseköğretim düzeylerinde ise nispeten düşük bir temsil olduğunu göstermektedir.



Şekil 10. Eğitim seviyesi durumu dağılımı (Distribution of educational status)

Şekil 11, bireylerin sosyal yaşam durumlarına göre dağılımını göstermektedir. Verilere göre, bireylerin büyük çoğunluğu (46.842) "Evet" kategorisinde yer alarak sosyal yaşam etkinliklerine katılım sağlamaktadır. Buna karşın, "Hayır-diğer nedenler" kategorisinde yer alan bireylerin sayısı 11.482 olup, sosyal etkinliklere katılmayanların önemli bir kısmını oluşturmaktadır. "Hayır-maddi yetersizlik" sebebiyle sosyal etkinliklere katılmayan bireylerin sayısı ise

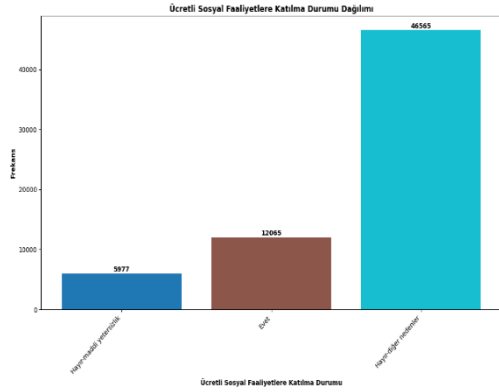
6.283 olarak tespit edilmiştir. Bu dağılım, sosyal etkinliklere katılımın genellikle yüksek olduğunu, ancak maddi yetersizliklerin katılımı kısıtlayan bir faktör olduğunu göstermektedir. Diğer nedenler ise maddi yetersizlikten daha büyük bir engel olarak gözlemlenmektedir. Bu durum, sosyoekonomik faktörlerin bireylerin sosyal yaşamlarına olan etkisini daha derinlemesine incelemek için önemli bir bulgu olarak değerlendirilebilir.




Şekil 11. Sosyal yaşam durumu dağılımı (Distribution of social life status)

Şekil 12, bireylerin ücretli sosyal faaliyetlere katılım durumuna göre dağılımını göstermektedir. Verilere göre, ücretli sosyal faaliyetlere katılmayan bireylerin çoğunluğu "Hayır-diğer nedenler" kategorisinde yer almakta olup, bu grupta 46.565 birey bulunmaktadır. Buna karşın, maddi yetersizlik nedeniyle bu tür faaliyetlere katılmayan birey sayısı 5.977 ile sınırlıdır. Ücretli sosyal faaliyetlere katılan bireylerin sayısı ise 12.065 olarak belirlenmiştir. Bu dağılım, bireylerin ücretli sosyal faaliyetlere katılımında "diğer nedenlerin" maddi yetersizlikten daha büyük bir engel oluşturduğunu göstermektedir. Ücretli faaliyetlere katılımın düşük olmasının, bireylerin zaman yönetimi, ilgi alanları veya sosyal faktörler gibi çeşitli nedenlerden kaynaklanabileceği değerlendirilebilir. Türkiye gibi ülkelerde sosyal aktivitelerin ücretli olması, sosyoekonomik durumun sosyal katılım üzerindeki etkisini de vurgulamakta olup, bu tür analizlerin sosyoekonomik politikalar ve sosyal programların geliştirilmesi açısından önemli bilgiler sunmaktadır.

Bununla birlikte Şekil 13, bireylerin genel sağlık durumları ile kronik hastalık varlığı arasındaki ilişkiyi gösteren bir sütun grafiği içermektedir. "İyi", "Çok iyi", "Orta", "Kötü" ve "Çok kötü" kategorileri, bireylerin kendilerini sağlık açısından nasıl değerlendirdiklerini temsil ederken, renkler kronik hastalık durumunu ("Evet" ve "Hayır") göstermektedir. "İyi" kategorisindeki sütunun yüksekliği, bu sağlık durumunu rapor eden bireylerin önemli bir kısmının kronik hastalık rapor etmediğini göstermektedir. Benzer şekilde, "Orta" kategorisinde de kronik hastalık olmadığını belirten bireylerin sayısı dikkate değerdir. Bu görsel, genel sağlık algısı ile kronik hastalıkların varlığı arasında önemli bir ilişki olduğunu göstermektedir.



Şekil 12. Ücretli sosyal faaliyetlere katılım durumu dağılımı (Distribution of participation in paid social activities)




Şekil 13. Genel sağlık durumu ve kronik hastalık durumu arasındaki ilişki (The relationship between general health status and chronic disease status)


Şekil 14, sağlık problemleri nedeniyle günlük faaliyetlerde sınırlama yaşayan bireylerin kronik hastalık durumları ile ilişkisini göstermektedir. Grafikte görüldüğü gibi, sağlık problemlerinden ötürü faaliyetlerinde herhangi bir sınırlama olmayan bireylerin çoğunluğu kronik hastalık bildirmemiştir. Buna karşın, faaliyetlerinde sınırlama yaşayanların büyük bir kısmının aynı zamanda kronik hastalıklara sahip olduğu görülmektedir. Bu durum, kronik hastalıkların bireylerin günlük yaşam aktiviteleri üzerindeki etkisini açıkça ortaya koymaktadır.

Şekil 15, bireylerin istihdam durumları ile kronik hastalık durumları arasındaki ilişkiyi göstermektedir. İstihdam durumu kategorileri arasında, tam zamanlı ücretli çalışanlar arasında kronik hastalık bildirenlerin sayısı, bildirmeyenlere göre daha azken, emekliler arasında kronik hastalık bildirenlerin sayısı daha fazla görülmektedir. Yarı zamanlı çalışanlar ve iş arayanlar arasında da kronik hastalıklar yaygınken, ev işleri ile meşgul olanlar ve eğitime devam edenler arasında daha az yaygındır. Bu dağılım, istihdam türü ve kronik sağlık durumları arasındaki potansiyel korelasyonları gözler önüne sermektedir. Görseldeki veriler, istihdam durumu ve kronik hastalıkların varlığı arasındaki ilişkiyi

incelerken, emeklilik ve tam zamanlı çalışma gibi hayatın farklı evrelerinin sağlık üzerinde belirgin bir etkisi olabileceğini işaret etmektedir. Emeklilik durumu, muhtemelen yaşla bağlantılı olarak kronik hastalık prevalansının (belirli bir süre içinde bir hastalığın toplumda görülme sıklığını gösteren ölçüt) yüksekliğini gösterirken, tam zamanlı çalışanlar arasında bu oranın daha düşük olması, çalışan nüfusun genel sağlık durumunun daha iyi olabileceğine işaret edebilir. Yarı zamanlı çalışanlar ve iş arayanlar arasındaki kronik hastalık oranları, bu grupların stres ve yaşam tarzı faktörlerinin sağlık üzerinde etkili olabileceğini düşündürmektedir. Eğitim görenler arasında kronik hastalık oranının düşük olması, genç nüfusun genel sağlık durumunun daha iyi olabileceğini veya eğitimin sağlık üzerinde olumlu bir etkisinin olabileceğini yansıtır olabilir. Bu tür veriler, halk sağlığı planlaması ve istihdam politikalarının oluşturulması açısından değerli bilgiler sağlamaktadır.

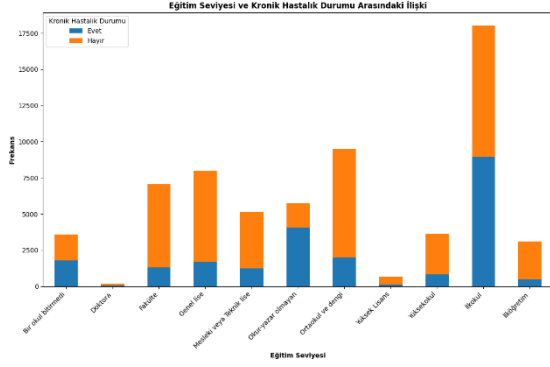


Şekil 14. Faaliyetlerde sınırlama ve kronik hastalık durumu arasındaki ilişki (The relationship between limitation of activities and chronic disease status)



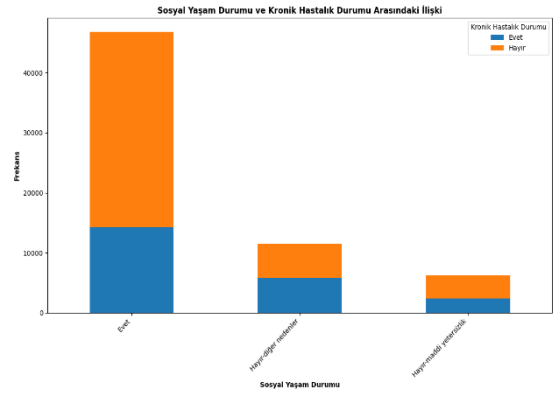
Şekil 15. İstihdam durumu ve kronik hastalık durumu arasındaki ilişki (The relationship between employment status and chronic disease status)

Şekil 16, bireylerin eğitim seviyesi durumları ile kronik hastalık durumları arasındaki ilişkiyi göstermektedir. Grafikte her bir eğitim seviyesi, kronik hastalığı olan bireyler (mavi) ve olmayan bireyler (turuncu) olarak ikiye ayrılmıştır. En yüksek frekansa sahip grup ilkökul mezunları olup, bu grupta kronik hastalığı olan bireylerin oranı diğer eğitim seviyelerine göre oldukça yüksektir. Ortaokul ve dengi okullardan mezun olan bireylerde de kronik hastalığı olan bireylerin oranı dikkat çekicidir. Genel lise ve mesleki/teknik lise mezunlarında ise kronik hastalığı olan bireylerin oranı nispeten daha düşüktür. Doktora ve yüksek lisans mezunları ise, hem toplamda daha düşük sayıda temsil edilmekte hem de kronik hastalık oranı çok düşük seviyelerde kalmaktadır. Genel olarak, eğitim seviyesi arttıkça kronik hastalık oranının azaldığı gözlemlenmektedir. Bu bulgu, düşük eğitim seviyesine sahip bireylerde kronik hastalıkların daha yaygın olduğunu ve eğitimin bireylerin sağlık durumu üzerinde önemli bir etkiye sahip olabileceğini göstermektedir.



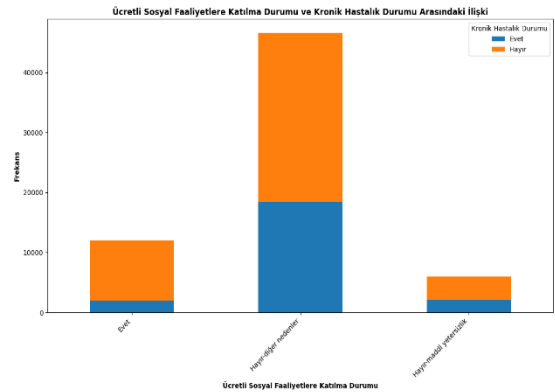
Şekil 16. Eğitim seviyesi ve kronik hastalık durumu arasındaki ilişki (The relationship between education level and chronic disease status)

Şekil 17, bireylerin sosyal yaşam durumları ile kronik hastalık durumları arasındaki ilişkiyi göstermektedir. Grafikte sosyal yaşam durumları "Evet" (sosyal etkinliklere katılanlar), "Hayır-diğer nedenler" (katılmayanlar) ve "Hayır-maddi yetersizlik" (katılmayanlar) olarak üç ana gruba ayrılmıştır. Sosyal etkinliklere katılan bireylerin (Evet) arasında kronik hastalığı olanların sayısı önemli bir orana sahip olup, bu grup içerisindeki bireylerin büyük çoğunluğunu kronik hastalığı olmayanlar oluşturmaktadır. "Hayır-diğer nedenler" kategorisinde, kronik hastalığı olan bireylerin oranı dikkate değer şekilde yüksektir, ancak bu grupta da kronik hastalığı olmayan bireyler çoğunluğu oluşturmaktadır. "Hayır-maddi yetersizlik" kategorisinde ise kronik hastalığı olan bireyler ve olmayan bireyler arasında daha dengeli bir dağılım olduğu gözlemlenmektedir. Genel olarak, sosyal etkinliklere katılma oranı düşük olan bireyler arasında kronik hastalığın daha yaygın olduğu ve sosyal yaşamın sağlık durumu üzerinde belirgin bir etkisinin olabileceği anlaşılmaktadır. Bu bulgu, sosyal etkileşimlerin sağlıkla ilişkili sonuçlar üzerindeki rolünü vurgulamaktadır.



Şekil 17. Sosyal yaşam durumu ve kronik hastalık durumu arasındaki ilişki (The relationship between social life status and chronic disease status)

Şekil 18, ücretli sosyal faaliyetlere katılma durumu ve kronik hastalık durumları arasındaki ilişkiyi göstermektedir. Ücretli sosyal faaliyetlere katılan bireyler ("Evet") arasında kronik hastalığı olan bireylerin (mavi) oranı oldukça düşük olup, büyük çoğunluk kronik hastalığı olmayan bireylerden (turuncu) oluşmaktadır. "Hayır-diğer nedenler" kategorisinde, sosyal faaliyetlere katılmayan bireyler arasında kronik hastalığı olanların oranı daha yüksektir, ancak yine de kronik hastalığı olmayan bireyler bu grupta çoğunluğu oluşturmaktadır. Maddi yetersizlik nedeniyle ücretli sosyal faaliyetlere katılmayan bireyler arasında ise kronik hastalığı olan ve olmayan bireylerin sayısı daha dengeli olup, kronik hastalığı olmayanlar az bir farkla çoğunluktadır. Genel olarak, ücretli sosyal faaliyetlere katılmayan bireyler arasında kronik hastalığın daha yaygın olduğu ve özellikle maddi yetersizlik durumunda bu oranın daha belirgin hale geldiği görülmektedir. Bu bulgular, sosyoekonomik faktörlerin ve sağlık durumunun sosyal etkinliklere katılım üzerindeki etkilerini ortaya koymaktadır.



Şekil 18. Ücretli sosyal faaliyetlere katılma durumu ve kronik hastalık durumu arasındaki ilişki (The relationship between participation in paid social activities and chronic disease status)

5. Sonuçlar (Conclusions)

Bu çalışmada, Türkiye İstatistik Kurumu'nun (TÜİK) 2023 Gelir ve Yaşam Koşulları Araştırması (GYKA) verileri kullanılarak, bireylerin kronik hastalık durumlarının çeşitli makine öğrenimi yöntemleri ile sınıflandırılması amaçlanmıştır. Literatürdeki mevcut boşluk, geniş ve karmaşık veri kümelerinden edinilen bilgiyi etkili bir şekilde kullanarak sağlık alanında karar verme süreçlerini destekleyecek modellerin geliştirilmesine yöneliktir. Bu çalışma, makine öğrenimi yöntemlerinin, özellikle de güçlü tahmin yetenekleri ve karmaşık ilişkileri modelleme kapasitesi ile dikkat çeken TabNet derin öğrenme tekniğinin, sağlık verileri analizinde etkin bir şekilde kullanılmasının önemini vurgulamaktadır. Araştırmanın odak noktası, sağlık hizmetlerine erişimdeki eşitsizlikler ve sosyoekonomik faktörlerin sağlık durumları üzerindeki etkisini anlamak ve değerlendirmektir. Bu çalışmanın bulguları, sağlık politikalarının geliştirilmesi ve sektörel analizler için stratejik kararlar alınmasında kullanılabilecek değerli bilgiler sağlamaktadır.

Bu çalışmanın öne çıkan bulguları arasında, TabNet modelinin %97 doğruluk oranı ile en yüksek performansı gösterdiği tespit edilmiştir. YSA, LSTM, CNN, GBM ve RF gibi modeller de yüksek doğruluk oranları sunmakla birlikte, TabNet modeli özellikle genelleme yeteneği ve sınıflar arasındaki dengeli performansı ile öne çıkmıştır. Optuna kütüphanesi kullanılarak tüm modellerin hiperparametre optimizasyonu yapılmış ve bu sayede modellerin tahmin gücü artırılmıştır. Ayrıca, eğitim seviyesi, sosyal yaşam katılımı, genel sağlık durumu ve ekonomik faktörlerin kronik hastalık riskleri üzerinde önemli bir etkisi olduğu bulunmuştur. Sosyal yaşam katılımının ve ekonomik yetersizliklerin kronik hastalık durumu ile güçlü bir ilişkiye sahip olduğu gözlemlenmiştir, bu da sosyal ve ekonomik faktörlerin sağlık üzerindeki rolünün altını çizmektedir.

Bu bulgular doğrultusunda, sağlık politikalarının kronik hastalıkların önlenmesi ve yönetilmesine yönelik olarak sosyal ve ekonomik faktörleri dikkate alacak şekilde yeniden yapılandırılması gerekmektedir. Özellikle, sosyal yaşam katılımının sağlık üzerindeki olumlu etkisi göz önünde bulundurularak, bireylerin sosyal faaliyetlere katılımını teşvik eden programlar geliştirilebilir. Maddi yetersizliklerin kronik hastalıklar üzerindeki olumsuz etkisini azaltmak için, düşük gelirli bireyler ve gruplar için sağlık hizmetlerine erişimi kolaylaştırıcı politikalar hayata geçirilmelidir. Ayrıca, eğitim seviyesinin kronik hastalık riskini azaltıcı etkisi göz önünde bulundurularak, sağlık eğitimi programları yaygınlaştırılmalı ve özellikle risk altındaki gruplara yönelik farkındalık çalışmaları artırılmalıdır. Bu tür bütüncül politikalar, bireylerin hem fiziksel hem de sosyal sağlığını iyileştirmeyi hedeflemeli ve sağlığın sosyal belirleyicilerini göz ardı etmeden daha kapsayıcı bir yaklaşım benimsemelidir. Sektörel bazda alınabilecek stratejik kararlar, sağlık, eğitim ve sosyal

hizmetler sektörleri arasında iş birliğini artırmaya yönelik olmalıdır. Sağlık sektöründe, kronik hastalıkların önlenmesi ve yönetimi için daha entegre ve kişiselleştirilmiş tedavi yaklaşımları geliştirilmelidir. Bu doğrultuda, sağlık teknolojilerine ve yapay zekâ destekli erken teşhis sistemlerine yapılan yatırımlar artırılabilir. Eğitim sektöründe, halk sağlığına yönelik bilinçlendirme kampanyaları ve sağlık eğitimi programları geliştirilerek, bireylerin hastalıklar hakkında daha fazla bilgi sahibi olmaları sağlanabilir. Sosyal hizmetler sektöründe ise, sosyal yaşam katılımını destekleyen projeler ve özellikle düşük gelirli gruplara yönelik sosyal destek programları uygulanabilir. Ayrıca, iş dünyasında çalışanların sağlık durumlarının iyileştirilmesi amacıyla, iş yerlerinde sağlık taramaları, fiziksel aktivite programları ve psikososyal destek hizmetleri teşvik edilmelidir. Bu stratejik adımlar, sektörler arası iş birliği ile toplum sağlığının genel olarak iyileştirilmesine katkı sağlayacaktır.

Bu çalışmanın bulgularını literatürde yer alan diğer çalışmalara kıyasladığımızda, TabNet modelinin kronik hastalık sınıflandırmasındaki %97 doğruluk oranıyla öne çıktığını ve özellikle Türkiye İstatistik Kurumu (TÜİK) verileri üzerinde elde edilen sonuçların literatüre önemli bir katkı sağladığını görmekteyiz. Özkan (2019)'un Gradient Boosting algoritmasıyla hepatit hastalığını %98.36 doğruluk, %98.68 kesinlik ve %98.95 duyarlılıkla sınıflandırması, veri ön işleme ve model seçiminin önemini vurgulamakla birlikte, bu çalışmada kullanılan TabNet modeliyle elde edilen sonuçlar, farklı bir sağlık alanında benzer bir performans sergilemiştir. Ahmed vd. (2019)'un CNN ile lösemi alt türlerini sınıflandırma çalışmasında %88.25 doğruluk elde edilmiştir, bu da CNN'in özellikle görüntü tabanlı verilerdeki başarısını göstermektedir. Ancak, TabNet modeli, özellikle tabular veri üzerinde daha yüksek doğruluk sağlamasıyla fark yaratmaktadır. Gaddam ve Pattnaik (2020)'in YSA ile aritmi tespitinde %91 doğruluk elde etmesi de kardiyovasküler hastalıklar için etkili bir sınıflandırma sunarken, TabNet'in kronik hastalıkların sınıflandırılmasındaki başarısı daha geniş bir veri seti üzerinde daha yüksek performans sağlamaktadır. Pacci vd. (2021)'in tüp bebek tedavisinde gebelik tahmini için Destek Vektör Makineleri ile elde ettiği %71.7 doğru pozitif ve %59.4 doğru negatif oranları, TabNet modelinin kronik hastalık sınıflandırmasındaki %97 doğruluk oranına kıyasla daha düşük bir performans sergilemiştir. Tang ve Liu (2021)'in Alzheimer hastalığının ilerleyişini sınıflandırmada Rastgele Orman algoritması ile elde ettikleri %96.14 doğruluk oranı, TabNet modeline yakın bir başarı göstermektedir, ancak TabNet'in daha genel bir veri seti üzerinde bu başarıyı sağlaması dikkat çekicidir. Akcan ve Sertbaş (2021) ile Purwaningsih (2022) tarafından yapılan çalışmalarda sonuçlarla karşılaştırıldığında, özellikle topluluk öğrenme yöntemleri ve DVM gibi algoritmaların başarılı bir şekilde uygulandığı görülmektedir. Akcan ve Sertbaş'ın göğüs kanseri teşhisinde topluluk öğrenme yöntemlerini

kullanarak Soft Voting, Bagging ve XGBoost ile en yüksek doğruluk oranlarına ulaşması, bu yöntemlerin bireysel sınıflandırma algoritmalarına göre üstün performans sergilediğini göstermektedir. Aynı şekilde, bu çalışmada kullanılan TabNet modeli de kronik hastalıkların sınıflandırılmasında benzer bir şekilde yüksek doğruluk oranı (%97) elde etmiştir. Topluluk öğrenme yöntemleri gibi, TabNet de karmaşık sağlık verileri üzerinde genelleme yeteneği açısından etkili sonuçlar sunmaktadır. Purwaningsih'in çalışmasında ise, DVM modeli ve ileri özellik seçimi (forward selection) kullanılarak kronik böbrek hastalığının %99.75 doğrulukla sınıflandırılması, DVM algoritmasının optimize edilmiş haliyle yüksek performans sağladığını göstermektedir. Bu doğruluk oranı, TabNet'in kronik hastalıklar üzerinde elde ettiği %97 doğruluk oranına kıyasla biraz daha yüksek olsa da, her iki çalışmada da özellik seçimi ve doğru model optimizasyonunun sınıflandırma başarılarını artırdığı vurgulanmaktadır. Ayrıca, Purwaningsih'in çalışmasındaki YSA modelinin %90,5 doğruluk oranı ile TabNet'in elde ettiği %97 doğruluk karşılaştırıldığında, TabNet'in daha yüksek bir performans sergilediği görülmektedir. Sevlı (2023)'nin diyabet hastalığını %96.29 doğruluk ile sınıflandırması, Gradient Boosting ve AdaBoost gibi yöntemlerle yüksek başarı elde edilmiştir. Coşkun ve Yüksek (2023) ise Gradient Boosting ile hepatit hastalığının sınıflandırılmasında %98.36 doğruluk oranına ulaşarak başarılı bir sonuç elde etmişlerdir, ancak TabNet'in kronik hastalıklar üzerindeki uygulamaları bu başarıya oldukça yakındır. Son olarak, Kim vd. (2023)'ün LSTM ve CNN tabanlı modellerle %94.3 doğruluk elde etmesi, kronik hastalıkların zaman serisi verileri üzerinde incelenmesi açısından önemlidir. Bu çalışmadaki TabNet modeli, tablo verisi üzerinde yüksek doğrulukla çalışarak, kronik hastalık tahmini gibi kritik sağlık problemlerinde başarılı bir performans sergilemektedir. Coşkun ve Yüksek (2023)'in çalışmasında Gradient Boosting algoritması %98.36 doğruluk ile öne çıkmışken, bu çalışmada TabNet %97 doğruluk oranıyla oldukça yakın bir performans sergilemiştir. Bununla birlikte, Gradient Boosting hepatit hastalığında yüksek başarı sağlamış olsa da, TabNet'in geniş bir kronik hastalık yelpazesinde benzer bir başarı elde etmesi, modelin genel uygulanabilirliği açısından önemli bir avantajdır. Kim vd. (2023)'in CNN ve LSTM kombinasyonunu kullanarak kronik hastalık tahmininde %94.3 doğruluk elde etmesi, derin öğrenme modellerinin zaman serisi verilerde etkili olduğunu göstermektedir. Ancak, TabNet modeli %97 doğruluk ile daha yüksek bir performans sergilemiş ve özellikle tabular veri üzerinde güçlü bir alternatif olarak öne çıkmıştır. Zhang vd. (2023)'in LSTM modeliyle %98.82 doğruluk oranı elde etmesi de LSTM'nin ses verileri üzerinde yüksek performans sağladığını gösterirken, TabNet'in sağlık verisi gibi tabular yapılar üzerinde etkili sonuçlar vermesi onu farklı bir bağlamda rekabetçi hale getirmektedir. Özdemir (2023)'in aritmi

sınıflandırmasında Gradient Boosting ve Rastgele Orman gibi yöntemlerle yüksek doğruluk elde etmesi, bu çalışmanın bulgularını desteklemekte olup, TabNet'in kronik hastalık tahmininde bu yöntemlerle rekabet edebilecek düzeyde performans sunduğunu göstermektedir. Aynı şekilde, Duyar vd. (2023)'ün TabNet'in boosting yöntemlerine kıyasla daha düşük performans gösterdiğini belirttiği çalışmada, bu modelin farklı veri türlerine ve sağlık koşullarına uygulanabilirliğinin incelenmesi gerektiği ortaya çıkmaktadır. Choubey vd. (2024)'ün PCA ve XGBoost kullanarak kronik hastalık tahmininde %98.8 doğruluk elde etmesi, TabNet ile karşılaştırıldığında biraz daha yüksek bir sonuç sunmaktadır. Ancak, TabNet'in işlem süresi ve model yapısındaki avantajları göz önüne alındığında, bu çalışmanın geniş çaplı sağlık verisi üzerinde sağladığı %97 doğruluk oranı önemli bir başarıdır. Ayrıca, Elkholy vd. (2023)'ün TabNet kullanarak kronik böbrek hastalığını %92.5 doğrulukla tahmin etmesi de, TabNet'in kronik hastalıklar üzerinde etkili olabileceğini vurgulayan diğer bir bulgudur. Sonuç olarak, TabNet modeli, yukarıda bahsi geçen diğer çalışmalarla karşılaştırıldığında, özellikle geniş tabular veri kümeleri üzerinde yüksek doğruluk ve genelleme yeteneği sunarak rekabetçi bir performans sergilemiştir. Gradient Boosting, LSTM ve CNN gibi modellerin spesifik veri setlerinde başarılı sonuçlar elde etmesine rağmen, TabNet'in kronik hastalık sınıflandırmasındaki başarısı, geniş veri setleri ve uygulama alanları için güçlü bir alternatif olduğunu göstermektedir.

Bu çalışma, Türkiye İstatistik Kurumu'nun 2023 Gelir ve Yaşam Koşulları Araştırması verileri kullanılarak makine öğrenimi yöntemleri ile bireylerin kronik hastalık durumlarının sınıflandırılmasına yöneliktir. Veri setinde kullanılan bağımsız değişkenler, kronik hastalıkların sınıflandırılmasında önemli bir rol oynamış ve elde edilen yüksek doğruluk oranlarına katkı sağlamıştır. Özellikle bireylerin eğitim seviyesi, sosyal yaşam katılımı, ekonomik durumu ve genel sağlık durumu gibi demografik ve sosyoekonomik değişkenler, kronik hastalıkların tahmin edilmesinde belirleyici olmuştur. Eğitim seviyesi düşük bireylerde kronik hastalık riskinin daha yüksek olduğu gözlemlenirken, sosyal yaşamdan uzak olan ve maddi yetersizlik çeken bireylerde de hastalık riskinin arttığı bulgulanmıştır. Bu, sosyal ve ekonomik faktörlerin bireylerin sağlık durumu üzerindeki etkisini doğrulamakta ve sağlığın sosyal belirleyicileri kavramının önemini vurgulamaktadır. Ayrıca, veri setinde yer alan diğer değişkenler, bireylerin genel sağlık durumu ve yaşam koşullarıyla ilişkili olup, kronik hastalık riskini etkileyen çok yönlü faktörler olarak karşımıza çıkmaktadır. Bu değişkenlerin modelde doğru şekilde kullanılması, TabNet ve diğer makine öğrenimi algoritmalarının yüksek performans göstermesini sağlamış ve hastalıkların sınıflandırılmasında önemli bir başarı elde edilmiştir.

Bu çalışmanın bazı kısıtlılıkları bulunmaktadır. İlk olarak, kullanılan veri seti Türkiye İstatistik Kurumu'nun (TÜİK) belirli bir zaman dilimine ait verilerine dayandığı için, veriler coğrafi ve zamansal olarak sınırlıdır; bu da modelin farklı popülasyonlar ve zaman dilimlerinde genelleme yeteneğini sınırlayabilir. İkinci olarak, veri setindeki bağımsız değişkenler ağırlıklı olarak sosyoekonomik ve demografik faktörlerden oluşmakta olup, biyomedikal ve klinik verilerin eksikliği, kronik hastalıkların daha derinlemesine ve biyolojik temelli bir analizine olanak sağlamamaktadır. Ayrıca, modelin performansı yüksek olmasına rağmen, kullanılan değişkenlerin doğruluğu ve eksiksizliği modele doğrudan etki etmektedir; eksik veya hatalı veriler modelin tahmin gücünü zayıflatabilir.

Gelecekte yapılacak çalışmalar için birkaç önemli öneri ve tavsiye sunulabilir. İlk olarak, veri setinin coğrafi ve zamansal sınırlarının ötesine geçerek, farklı ülkelerden ve bölgelerden elde edilen daha geniş kapsamlı ve çok merkezli veri setlerinin kullanılması, modelin genelleme yeteneğini artırabilir. Ayrıca, mevcut çalışmada kullanılan sosyoekonomik ve demografik değişkenlerin yanı sıra, biyomedikal verilerin (genetik, klinik test sonuçları ve hastalık geçmişi vs.) entegrasyonu, kronik hastalıkların daha derinlemesine analiz edilmesini sağlayarak modelin tahmin doğruluğunu artırabilir. Ayrıca, gelecekte hibrit model yaklaşımlarının denenmesi, tahmin performansını daha da iyileştirebilir. Ayrıca, modelin açıklanabilirliği ve yorumlanabilirliğini artırmak için SHAP ve LIME gibi model açıklama tekniklerinin kullanılması, sağlık profesyonellerinin ve politika yapımcıların sonuçları daha iyi anlamalarına ve karar süreçlerine dahil etmelerine yardımcı olabilir. Son olarak, zaman serisi analizine dayalı çalışmaların genişletilmesi, kronik hastalıkların ilerleyişi ve uzun vadeli sağlık sonuçları üzerine öngörüler sunarak proaktif ve önleyici sağlık politikalarının geliştirilmesine katkı sağlayabilir.

Kaynaklar (References)

Ahmed, N. A., Yiğit, A., Işık, Z., Alpkoçak, A., 2019. Identification of leukemia subtypes from microscopic images using convolutional neural network. *Diagnostics*, 9(3), 104. <https://doi.org/10.3390/diagnostics9030104>

Ahsan, M., Khan, A., Khan, K. R., Sinha, B. B., Sharma, A., 2023. Advancements in medical diagnosis and treatment through machine learning: a review. *Expert Systems*, 41(3). <https://doi.org/10.1111/exsy.13499>

Akcan, F., Sertbaş, A., 2021. Topluluk Öğrenmesi Yöntemleri ile Göğüs Kanseri Teşhisi. *Electronic Turkish Studies*, 16(2).

Albin Ahmed, A., Shaahid, A., Alnasser, F., Alfaddagh, S., Binagag, S., Alqahtani, D., 2023. Android ransomware detection using supervised machine learning techniques based on traffic analysis. *Sensors*, 24(1), 189. <https://doi.org/10.3390/s24010189>

Almutairi, M., Chiroma, H., Abubakar, S., 2022. Detecting elderly behaviors based on deep learning for healthcare:

recent advances, methods, real-world applications and challenges. *IEEE Access*, 10, 69802-69821. <https://doi.org/10.1109/access.2022.3186701>

Al-Shamisi, M. H., Assi, A., Hejase, H., 2013. Artificial neural networks for predicting global solar radiation in al ain city - uae. *International Journal of Green Energy*, 10(5), 443-456. <https://doi.org/10.1080/15435075.2011.641187>

Altuntaş, O., Esra, A. K. I., Huri, M., 2015. Kronik hastalıklarda ilaç kullanımının yaşam kalitesi ve sosyal katılıma etkisi üzerine nitel bir çalışma. *Ergoterapi ve Rehabilitasyon Dergisi*, 3(2), 79-86.

An, W., Liang, M., 2012. A new intrusion detection method based on svm with minimum within-class scatter. *Security and Communication Networks*, 6(9), 1064-1074. <https://doi.org/10.1002/sec.666>

Anjum, M. J., Tariq, F., Anjum, K. M., Shaheen, M., Ahmad, F., 2023. Identification of diseases caused by non-synonymous single nucleotide polymorphism using random forest and linear regression algorithms. <https://doi.org/10.21203/rs.3.rs-3001745/v1>

Arik, S. Ö., Pfister, T., 2021. Tabnet: Attentive interpretable tabular learning. In *Proceedings of the AAAI conference on artificial intelligence*, 35(8), 6679-6687. <https://doi.org/10.48550/arXiv.1908.07442>

Arkin, F. S., Aras, G., Doğu, E., 2020. Comparison of artificial neural networks and logistic regression for 30-days survival prediction of cancer patients. *Acta Informatica Medica*, 28(2), 108. <https://doi.org/10.5455/aim.2020.28.108-113>

Bissacco, A., Yang, M.-H., Soatto, S., 2007. Fast human pose estimation using appearance and motion via multi-dimensional boosting regression, in *IEEE Conference on Computer Vision and Pattern Recognition, CVPR'07*. (Minneapolis, MN). <https://doi.org/10.1109/CVPR.2007.383129>

Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5-32. <https://doi.org/10.1023/A:1010933404324>

Chen, C., Fan, L., 2022. Cnn-lstm-attention deep learning model for mapping landslide susceptibility in kerala, india. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-3/W1-2022, 25-30. <https://doi.org/10.5194/isprs-annals-x-3-w1-2022-25-2022>

Choubey, S. B., Chitra, T., Hephzipah, J. J., 2024. Big Data Mining for Chronic Disease Prediction using Principal Component Analysis and eXtreme Gradient Boosting. *GK International Journal of Advanced Research in Engineering and Technology*, 1(1), 1-11.

Coşkun, C., Yüksek, E., 2023. Hepatit hastalığının tespitinde bulanık mantık ve makine öğrenmesi yöntemlerinin karşılaştırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 14(4), 539-546.

Dai, X., Yin, H., Jha, N. K., 2020. Grow and prune compact, fast, and accurate lstms. *IEEE Transactions on Computers*, 69(3), 441-452. <https://doi.org/10.1109/tc.2019.2954495>

Dubey, G., Khera, R., Grover, A., Kaur, A., Goyal, A., Rajkumar, R., Srivastava, S., 2023. A hybrid convolutional network and long short-term memory (hbcnls) model for sentiment analysis on movie reviews. *International Journal on Recent and Innovation Trends in Computing and Communication*, 11(4), 341-348. <https://doi.org/10.17762/ijrctc.v11i4.6458>

- Duyar, C., Senica, S. O., Kalkan, H., 2023. Detection of cardiovascular disease using gut microbiota data. <https://doi.org/10.21203/rs.3.rs-2794999/v1>
- Elkholy, S., Rezk, A., Saleh, A. A., 2023. Enhanced optimized classification model of chronic kidney disease. *International Journal of Advanced Computer Science and Applications*, 14(2). <https://doi.org/10.14569/ijacsa.2023.0140239>
- El-Shafeiy, E., El-Desouky, A. I., Elghamrawy, S. M., 2024. An optimized artificial neural network approach based on sperm whale optimization algorithm for predicting fertility quality. *Studies in Informatics and Control*, 27(3), 349-358. <https://doi.org/10.24846/v27i3y201810>
- Ersöz, A. G., 2003. Dünya konferansları belgelerinde aile ve yoksulluk: Saptamalar ve öneriler. *Sosyal Politika Çalışmaları Dergisi*, 6(6).
- Fanelli, G., Dantone, M., Gall, J., Fossati, A., Gool, L., 2012. Random forests for real time 3D face analysis. *Int. J. Comput. Vis.* 1, 1–22. <https://doi.org/10.1007/s11263-012-0549-0>
- Freund, Y., Schapire, R., 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *J. Comput. Syst. Sci.* 55, 119–139.
- Friedman, J., 2001. Greedy boosting approximation: a gradient boosting machine. *Ann. Stat.* 29, 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Friedman, J., Hastie, T., Tibshirani, R., 2000. Additive logistic regression: a statistical view of boosting. *Ann. Stat.* 28, 337–407. <https://doi.org/10.1214/aos/1016218222>
- Gaddam, C. M. Pattnaik, S. S., 2020. An ensemble based ecg signal classification approach for accurate arrhythmia detection. *International Journal of Emerging Technology and Advanced Engineering*, 10(8), 57-61. https://doi.org/10.46338/ijetae0820_08
- Gao, X., Chen, D., Pan, Q., 2022. An interpretable classification model of breast tumors with tubular mammography data. 2nd International Conference on Signal Image Processing and Communication (ICSIPC 2022). <https://doi.org/10.1117/12.2643654>
- Guhan, T., Bhavishya, S. Kalaiarasan, S., Lalith, K., Dhitchith, O. P., 2024. Chronic Illness Detection using Gradient Boosting Algorithm. *Grenze International Journal of Engineering & Technology (GIJET)*, 10.
- Guido, R., Ferrisi, S., Lofaro, D., Conforti, D., 2024. An overview on the advancements of support vector machine models in healthcare applications: a review. *Information*, 15(4), 235. <https://doi.org/10.3390/info15040235>
- Gündoğdu, S., 2021. Kalp hastalık risk tahmini için Python aracılığıyla sınıflandırıcı algoritmalarının performans değerlendirmesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(69), 1005-1013.
- Hansen, L., Salamon, P., 1990. Neural network ensembles. *IEEE Trans. Pattern Anal. Mach. Intell.* 12, 993–1001. <https://doi.org/10.1109/34.58871>
- Hegde, S. Mundada, M. R., 2020. Early prediction of chronic disease using an efficient machine learning algorithm through adaptive probabilistic divergence based feature selection approach. *International Journal of Pervasive Computing and Communications*, 17(1), 20-36. <https://doi.org/10.1108/ijpcc-04-2020-0018>
- Huang, Y., Gao, Z., Zhang, H., 2020. Comparison of common machine learning algorithms trained with multi-zone models for identifying the location and strength of indoor pollutant sources. *Indoor and Built Environment*, 30(8), 1142-1158. <https://doi.org/10.1177/1420326x20931576>
- Hutchinson, R. A., Liu, L.P., Dietterich, T. G., 2011. “Incorporating boosted regression trees into ecological latent variable models,” in *AAAI’11*, (San Francisco, CA), 1343–1348. Available online at: <http://www.aaai.org/ocs/index.php/AAAI/AAAI11/paper/view/3711>
- Johnson, R., Zhang, T., 2012. Learning Nonlinear Functions Using Regularized Greedy Forest. Technical Report. arXiv:1109.0887. doi: 10.2172/1052139
- Jongjaraunsuk, R., Taparhudee, W., Suwannasing, P., 2024. Comparison of water quality prediction for red tilapia aquaculture in an outdoor recirculation system using deep learning and a hybrid model. *Water*, 16(6), 907. <https://doi.org/10.3390/w16060907>
- Kim, G., Lim, H., Kim, Y., Kwon, O., Choi, J., 2023. Intra-person multi-task learning method for chronic-disease prediction. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-28383-9>
- Kim, J. O., Jeong, Y. S., Kim, J. H., Lee, J. W., Park, D., Kim, H. S., 2021. Machine learning based cardiovascular disease prediction model: A cohort study on the Korean national health insurance service health screening database. *Diagnostics*, 11(6), 943.
- Kumsar, A. K., Yılmaz, F. T., 2014. Kronik Hastalıklarda Yaşam Kalitesine Genel Bakış. *ERÜ Sağlık Bilimleri Fakültesi Dergisi*, 2(2), 62-70.
- Küçükberber, N., Özdemir, K., Yorulmaz, H., 2011. Kalp hastalarında sağlıklı yaşam biçimi davranışları ve yaşam kalitesine etki eden faktörlerin değerlendirilmesi. *Anadolu Kardiyol Derg*, 11, 619-626.
- Lee, E. Y., Fulan, B. M., Wong, G. C. L., Ferguson, A. L., 2016. Mapping membrane activity in undiscovered peptide sequence space using machine learning. *Proceedings of the National Academy of Sciences*, 113(48), 13588-13593. <https://doi.org/10.1073/pnas.1609893113>
- Liu, Q., Li, S., Li, Y., Yu, L., Zhao, Y., Wu, Z., Zhang, Y., 2023. Identification of urinary volatile organic compounds as a potential non-invasive biomarker for esophageal cancer. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-45989-1>
- Liu, Y., Wang, Y., Li, Y., Zhang, B., Wu, G., 2004. Earthquake prediction by RBF neural network ensemble, in *Advances in Neural Networks - ISNN 2004*, eds F.-L. Yin, J. Wang, and C. Guo (Berlin; Heidelberg: Springer), 962–969. https://doi.org/10.1007/978-3-540-28648-6_153
- Loey, M., Naman, M. R., Zayed, H. H., 2020. Deep transfer learning in diagnosing leukemia in blood cells. *Computers*, 9(2), 29. <https://doi.org/10.3390/computers9020029>
- Luo, L., Zhang, F., Yao, Y., Gong, R., Fu, M., Xiao, J., 2018. Machine learning for identification of surgeries with high risks of cancellation. *Health Informatics Journal*, 26(1), 141-155. <https://doi.org/10.1177/1460458218813602>
- Maggiore, E., Tarabalka, Y., Charpiat, G., Alliez, P., 2017. Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657. <https://doi.org/10.1109/tgrs.2016.2612821>

- McLaughlin, R. T., Asthana, M., Meo, M. D., Ceccarelli, M., Jacob, H. J., Masica, D. L., 2023. Fast, accurate, and racially unbiased pan-cancer tumor-only variant calling with tabular machine learning. *NPJ Precision Oncology*, 7(1). <https://doi.org/10.1038/s41698-022-00340-1>
- Özdemir, A., 2023. Makine Öğrenmesi Algoritmaları ile Aritmilerin Sınıflandırılması. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 39(3), 394-402.
- Özkan, Y., 2019. Hastalık tanısı verilerinde veri ön işlemenin topluluk öğrenme sınıflandırma algoritmaları üzerindeki etkisinin incelenmesi, *Ege Üniversitesi, Sağlık Bilimleri Enstitüsü, Yayınlanmamış Yüksek Lisans Tezi*, İzmir.
- Pacci, Z., Şengül, Y. A., Attar, R., Alagöz, O., 2021. Yapay Zeka Tabanlı Klinik Karar Destek Sistemi ile Tüp Bebek Tedavisi Gebelik Sonucu Tahmini. *EMO Bilimsel Dergi*, 11(22), 27-35.
- Pittman, S. J., Brown, K. A., 2011. Multi-scale approach for predicting fish species distributions across coral reef seascapes. *PLoS ONE* 6:e20583. <https://doi.org/10.1371/journal.pone.0020583>
- Qi, Y., 2012. Random forest for bioinformatics, in *Ensemble Machine Learning*, eds C. Zhang and Y. Ma (New York, NY: Springer), 307. https://doi.org/10.1007/978-1-4419-9326-7_11
- Schapire, R., 2002. The boosting approach to machine learning: an overview. *Nonlin. Estim. Classif. Lect. Notes Stat.* 171, 149–171. https://doi.org/10.1007/978-0-387-21579-2_9
- Sevli, O., 2023. Diagnosis of diabetes mellitus using various classifiers. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(2), 989-1001.
- Sewell, M., 2011. Ensemble Learning. Technical Report, Department of Computer Science, University College London. Available online at: http://www.cs.ucl.ac.uk/fileadmin/UCL-CS/research/Research_Notes/RN_11_02.pdf Erişim tarihi: 20.02.2024
- Shu, C., Burn, D. H., 2004. Artificial neural network ensembles and their application in pooled flood frequency analysis. *Water Resour. Res.* 40, 1–10. <https://doi.org/10.1029/2003WR002816>
- Sönmez, O., Zengin, K., 2023. Süt Sığırlarının Buzağılama Zamanının Tahmininde Makine Öğrenme Yöntemlerinin Kullanımı Çalışmaları Üzerine Bir Değerlendirme. *Journal of New Results in Engineering and Natural Sciences*, 2023(18), 27-39.
- Tang, X. Liu, J., 2021. Comparing different algorithms for the course of alzheimer's disease using machine learning. *Annals of Palliative Medicine*, 10(9), 9715-9724. <https://doi.org/10.21037/apm-21-2013>
- Toğaçar, M., Cömert, Z., Ergen, B., 2021. Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks. *Chaos, Solitons & Fractals*, 144, 110714.
- Vidya, G., Hari, V. S., 2023. Lstm network integrated with particle filter for predicting the bus passenger traffic. *Journal of Signal Processing Systems*, 95(2-3), 161-176. <https://doi.org/10.1007/s11265-022-01831-x>
- Wade, C., Glynn, K., 2020. Hands-On Gradient Boosting with XGBoost and scikit-learn: Perform accessible machine learning and extreme gradient boosting with Python. Packt Publishing Ltd.
- Xi, J., Liang, R., Fei, X., 2017. An algorithm of improving speech emotional perception for hearing aid. *Modern Physics Letters B*, 31(19-21), 1740094. <https://doi.org/10.1142/s0217984917400942>
- Yangın, G., 2019. XGboost ve Karar Ağacı tabanlı algoritmaların diyabet veri setleri üzerine uygulaması, *Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmamış Yüksek Lisans Tezi*, İstanbul.
- Yar, F., 2015. Türkiye’de gelir dağılımı & yoksulluk. *Global Analiz*, 2, 1-30.
- Zhang, P., Swaminathan, A., Uddin, A. A., 2023. Pulmonary disease detection and classification in patient respiratory audio files using long short-term memory neural networks. *Frontiers in Medicine*, 10. <https://doi.org/10.3389/fmed.2023.1269784>