



Kardiyovasküler Hastalıkların Derin Öğrenme Algoritmaları İle Tanısı

Ali VIRIT^{1*} Ali ÖTER²

¹Kahramanmaraş Sütçü İmam University, Institute of Science, Department of Information Systems, Kahramanmaraş, Türkiye

²Kahramanmaraş Sütçü İmam University, Vocational School of Technical Sciences, Department of Electronics and Automation, Kahramanmaraş, Türkiye

Article Info

Research article
Received: 30/06/2024
Revision: 15/08/2024
Accepted: 10/10/2024

Keywords

Cardiovascular
Diseases
Deep Learning
Explainable AI

Makale Bilgisi

Araştırma makalesi
Başvuru: 30/06/2024
Düzeltilme: 15/08/2024
Kabul: 10/10/2024


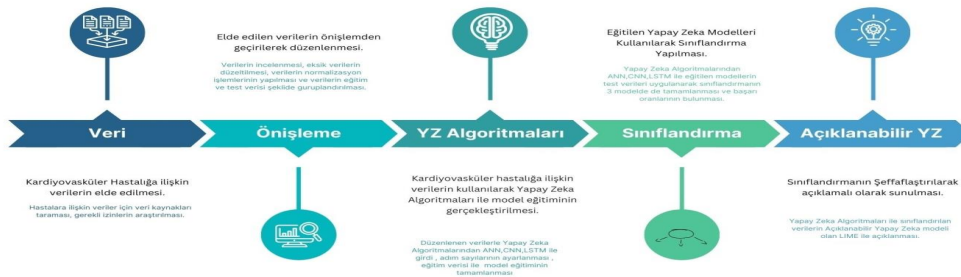
Anahtar Kelimeler

Kardiyovasküler
Hastalıklar
Derin Öğrenme
Açıklanabilir yapay
zeka

Grafik Özet (Graphical/Tabular Abstract)

Bu çalışmada, Yapay Zekâ algoritmaları kullanılarak Kardiyovasküler hastalıkların tanısı yapılarak Açıklanabilir Yapay Zeka ile yorumlanmıştır. / In this study, the diagnosis of cardiovascular diseases was made using Artificial Intelligence algorithms and interpreted with Explainable Artificial Intelligence.

Çalışma Adımları



Şekil A: Kardiyovasküler hastalıkların tanısı ve yorumlanması / Figure A: Diagnosis and interpretation of cardiovascular diseases

Önemli noktalar (Highlights)

- Kardiyovasküler hastalıkların otomatik tanısı / Automatic diagnosis of cardiovascular diseases
- YZ modelleri ile Kardiyovasküler hastalıklara tanı konulması / Diagnosing cardiovascular diseases with AI models
- Açıklanabilir YZ modelleri ile hastalık tanılarının yorumlanması / Interpreting disease diagnoses with explainable AI models

Amaç (Aim): Kardiyovasküler hastalıkların YZ yöntemleri ile tanısı ve Açıklanabilir YZ ile sonuçların şeffaflaştırılması. / Diagnosis of cardiovascular diseases with AI methods and making the results transparent with Explainable AI.

Özgünlük (Originality): Kardiyovasküler hastalıklarının tanı sonuçlarının görsel olarak yorumlanması / Visual interpretation of diagnostic results of cardiovascular diseases

Bulgular (Results): Kullanılan üç YZ modelinde benzer sonuçlar elde edilmiştir. CNN modeli %73,5 en yüksek doğruluk oranı bulunmuştur. / Similar results were obtained in the three AI models used. The CNN model was found to have the highest accuracy rate of 73.5%.

Sonuç (Conclusion): Açıklanabilir YZ ile de daha şeffaf sonuçlar oluşturarak erken tanı ile tedavi süreçlerine katkı sağlayabileceği öngörülmüştür. / It is envisaged that explainable AI can create more transparent results and contribute to early diagnosis and treatment processes.



Kardiyovasküler Hastalıkların Derin Öğrenme Algoritmaları İle Tanısı

Ali VIRT^{1*} Ali ÖTER²

¹Kahramanmaraş Sütçü İmam University, Institute of Science, Department of Information Systems, Kahramanmaraş, Türkiye

²Kahramanmaraş Sütçü İmam University, Vocational School of Technical Sciences, Department of Electronics and Automation, Kahramanmaraş, Türkiye

Makale Bilgisi

Araştırma makalesi
Başvuru: 30/06/2024
Düzeltilme: 15/08/2024
Kabul: 10/10/2024

Anahtar Kelimeler

Kardiyovasküler
Hastalıklar
Derin Öğrenme
Açıklanabilir yapay zeka

Öz

Kardiyovasküler hastalıklar dünyada en ölümcül hastalıkların başında gelmektedir. Riski azaltmada erken teşhis oldukça önemlidir. Bu çalışmada Yapay Zekâ (YZ) algoritmaları kullanılarak Kardiyovasküler hastalıkların erken teşhisindeki etkisi araştırılmaktadır. Çalışmada derin öğrenme algoritmalarından ANN, CNN ve LSTM algoritmaları kullanılarak, Kardiyovasküler Hastalıkların teşhis edilmesi ve açıklanabilir YZ ile sınıflandırmanın daha şeffaf olarak sunulması amaçlanmıştır. Yapılan çalışmada bu üç yöntemin de benzer sonuçlar verdiği ve açıklanabilir YZ ile de neden hasta veya hasta olmadığına ilişkin bilgiler ortaya konulmuştur. Kullanılan üç YZ modelinde benzer sonuçlar elde edilmiştir. CNN modeli %73,5 en yüksek doğruluk oranı bulunmuştur. Bu bulgular, YZ modellerinin Hastalık teşhislerinde etkin bir araç olarak kullanılabileceğini ve Açıklanabilir YZ ile de daha şeffaf sonuçlar oluşturarak erken tanı ile tedavi süreçlerine katkı sağlayabileceğini ortaya koymaktadır.

Diagnosis of Cardiovascular Diseases with Deep Learning Algorithms

Article Info

Research article
Received: 30/06/2024
Revision: 15/08/2024
Accepted: 10/10/2024

Keywords

Cardiovascular Diseases
Deep Learning
Explainable AI

Abstract

Cardiovascular diseases are one of the deadliest diseases in the world, and early diagnosis is essential. This study investigates the effect of Artificial Intelligence algorithms on the early diagnosis of Cardiovascular Diseases. The aim of the study is to diagnose cardiovascular diseases by using artificial intelligence algorithms (ANN, CNN, and LSTM) and to present the classification more transparently with explainable artificial intelligence. Similar results were obtained in the three AI models used. The CNN model was found to have the highest accuracy rate of 73.5%. This study revealed that these three methods gave similar results, and with Explainable Artificial Intelligence, information was revealed about why the patient was or was not sick. These findings reveal that Artificial Intelligence models can be used as effective tools in disease diagnosis and that artificial intelligence can create more transparent results and contribute to early diagnosis and treatment processes.

1. GİRİŞ (INTRODUCTION)

Kardiyovasküler hastalıklar (KVH) ülkemizde ve tüm dünyada çok yaygın görülen ve dünyada ölümcül hastalıkların başında gelen bir hastalıktır[1]. Dünya Sağlık Örgütü'nün(WHO) 2019 verilerine göre ortalama 17.9 milyon insanın bu hastalıktan hayatını kaybetmesine neden olan ve tüm ülkelerde vefat eden insanların sayısının %38'ine karşılık geldiği hesaplanmaktadır[2]. KHV'da ölümcül olma nedeni genellikle damarlardaki tıkanıklıklardan meydana gelen kanın beyne ve kalbe ulaşımında yaşanan sorunlardır. Bu tıkanıklıkların en önemli nedeni damarların iç duvarlarında yağ birikerek damarı tıkamasıdır.

Ayrıca KHV' da yoksulluk, stres ve genetik etkenler de önem arz etmektedir[3]. Tıkanan damarların hemen açılması ve dolaşım sisteminin sağlıklı yürümesi gerekmektedir aksi hallerde ise kalp krizi, beyin kanaması gibi durumlar ortaya çıkabilmekte, felç kalma ve hayatını kaybetme durumları oluşmaktadır. Bu yüzden erken tanı ve teşhis oldukça önemlidir [4].

Son yıllarda bu hastalıkların teşhis ve tedavi süreçlerinde Yapay zekâ (YZ) teknikleri olan makine öğrenimi (ML) algoritmalarının uygulanması savunulmaktadır, ML denklemlerinin doğrudan yöntemle iyi uyum sağladığı bulunmuştur [5-7]. Şengur ve arkadaşları tarafından ML ile temel

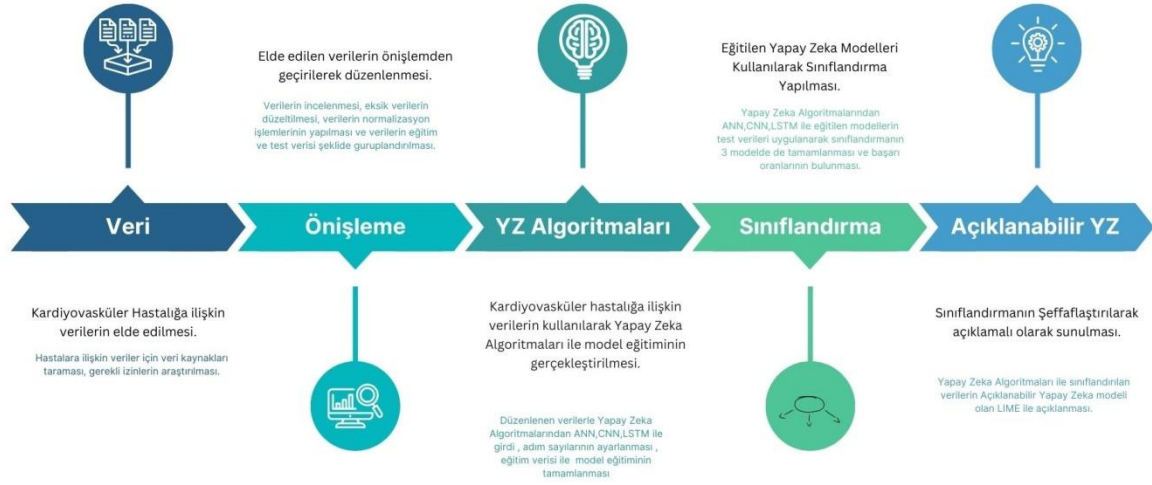
bileşen analizi (PCA), K-en yakın komşu (KNN) algoritmaları kullanılarak kalp seslerini analiz ederek kalp kapakçıklarının sağlığını belirleyen sınıflandırma çalışmasında a % 95.9 duyarlılık ve % 96 özgüllük oranı elde edilmiştir [8]. Çilhoroz tarafından yürütülen Kardiyovasküler hastalıktan ölümü etkileyen faktörlerin tanımlanması için OECD ülkeleri üzerine bir çalışma başlıklı araştırmada en küçük kareler yöntemi kullanılmıştır. Çalışmalarında sigara içme ve içki içme gibi zararlı alışkanlıklarının KVH'ye bağlı ölümler üzerinde olumlu bir etkisi olduğunu belirlemiştir [9]. Veri madenciliği yöntemleriyle kalp ve damar hastalıkları tahmini konulu yapılan başka bir çalışmada yöntemlerin performans karşılaştırması yapılmıştır. Bu çalışmada sınıflandırıcı performansı Hidden Naive Bayes (HNB) algoritmasının %84,8 başarı oranı ile en iyi performansı gösterdiği sonucuna ulaşılmıştır[10]. Kaba ve diğerleri tarafından yazılan kardiyovasküler hastalık tahmininde makine öğrenmesi sınıflandırma algoritmalarının karşılaştırıldığı çalışmada Lojistik regresyon(LR) analizi performansı %86,76 doğrulukla rastgele orman algoritmasından sonra başarılı sonuçlar elde edilmiştir[11]. Ancak belirtilen bu çalışmalarda derin öğrenme (DL) tekniklerine çok az sayıda rastlanmıştır. DL teknikleri günümüzde pek çok farklı alanda kullanılmaktadır [12-14]. Özellikle işaret ve görüntü işleme, doğal dil işleme, robotik ve ses tanıma gibi alanlarda derin öğrenme algoritmalarının etkinliği kanıtlanmıştır. İşaret işleme, doğadaki ve insan yapımı sistemlerden gelen işaretleri analiz etmekle ilgilenir. Bu işaretler, ses, görüntü, video veya diğer veri türleri olabilir. Bu işaretlerden bilgi çıkarmak için matematiksel ve istatistiksel hesaplama yöntemleri kullanılarak işaret işleme gerçekleştirilir. Bir işaretin veya verinin hangi kategoriye ait olduğunun tahmin edilerek sınıflandırılması, bozulmuş bir işaretin düzeltilmesi, bir işaretin boyutunun artırılması veya azaltılması yaygın işaret işleme teknikleridir. Son gelişmeler özellikle DL tarafından tahminde elde edilen hızlı gelişmeler bu teknolojilerin bilimsel keşifleri hızlandıracağına dair bir iyimserlik dalgası oluşturmuştur[15, 16]. DL modellerinin son yıllarda açıklanabilir YZ modelleri kullanılarak yorumlanması birçok bilim alanında yaygınlaşmaya başlamıştır [17-19]. Açıklanabilir YZ, herhangi bir sektördeki veri setini kullanılarak YZ modellerini uygulanması kullanıcıların güven ve özgüven oluşturması açısından belirleyici olmaktadır.

İnsanlar; çarpıntı, göğüste ağrı, nefes darlığı, çarpıntı, kolda uyuşma gibi şikâyetlerle doktora başvurup bu belirtilerin neden olduğu hastalığın teşhisine ulaşmaya çalışmaktadırlar. Doktorların hastanedeki yoğunluk nedeniyle kısa zamanda hastalara teşhis koymaları gerekmekte bu durum hastaların yanlış teşhisine neden olabilmektedir. Bundan dolayı KHV'nin YZ tabanlı yöntemler kullanılarak karar destek sistemleri oluşturulması doktorlara teşhis aşamasında fayda sağlayacaktır. Bu amaçla üç farklı DL yöntemi kullanılarak başarı oranları karşılaştırılmış, en yüksek başarı oranı veren yöntem tespit edilerek, daha şeffaf sonuçlar elde edilmesi için Açıklanabilir YZ ile görsel olarak sonuçların yorumlandığı bir çalışma gerçekleştirilmiştir. Yapılan çalışmada, üç farklı CNN, RNN ve LSTM modeli gibi DL tekniği kullanılarak KVH için tahmin modeli geliştirilmiştir. Modellere ait tahmin performansları LIME tekniği ile görsel olarak yorumlanmıştır. Literatürden ve yukarıdaki açıklamalardan YZ yöntemleri kullanılarak Kardiyovasküler hastalıkların hızlı teşhis ve tanısını sağlamak için günümüzde oldukça hızlı gelişen teknoloji yardımıyla hekimlere destek sağlamaktır. Aynı zamanda olası hatalarını önlemek adına Açıklanabilir YZ kullanılarak sonuçların şeffaflaştırılması ile kullanılan YZ modellerinin güvenilirliği artırılarak karar süreçlerinde hekim değerlendirmelerine önemli bir avantaj oluşturacaktır.

2. MATERYAL VE METOD (MATERIALS AND METHODS)

Bu çalışmada açık erişimli kaggle sitesinden KVH veri seti kullanılarak YZ yöntemleri ve sınıflandırma ve sonuçların yorumlanması yapılmıştır. Yapılan çalışmaya ilişkin işlem basamakları Şekil 1'de ayrıntılı olarak gösterilmiştir. İlk işlem basamağı olarak kaggle sitesinden veri seti elde edilmiştir. Daha sonra YZ modellerinde kullanılması için ön işlemden geçirilerek veriler hazır hale getirilmiştir. Çalışmanın üçüncü basamağında YZ yöntemlerinden ANN, CNN, LSTM ile modelleri için eğitimler gerçekleştirilmiştir. Dördüncü basamakta ise test verileri ile sınıflandırmalar yapılmış ve değerlendirme kriterlerine göre başarı oranları elde edilmiştir. Son olarak modellerin sınıflandırma başarıları açıklanabilir YZ yöntemlerinden LIME ile yorumlanmıştır.

Çalışma Adımları



Şekil 1. Akış şeması (Flow chart)

2.1. Veri Seti (Data Set)

Çalışmada kullanılan veri seti, (<https://www.kaggle.com/code/sefakocakalay/cardiovascular-disease-prediction-tr/input>) web sitesinden alınmıştır. Veri setinde gerçek bilgiler,

tıbbi muayenenin sonuçları ve hasta tarafından verilen bilgiler olmak üzere 12 özneliğin bulunduğu 70.000 örnek hasta verisi bulunmaktadır. Tablo 1'de veri setindeki özneliklerin adı tipi ve içerikleri ile ilgili bilgiler detaylı olarak verilmiştir.

Tablo 1. Kardiyoloji veri setinin temel bilgileri (Basic information of cardio dataset)

Sıra No	Öznelik	Tipi	İçeriği
1	Yaş	Sayısal	10798-23713 (Gün)
2	Boy	Sayısal	55-250 (cm)
3	Kilo	Sayısal	10-200 (Kg)
4	Cinsiyet	Kategorik	Kadın(1)/Erkek(2)
5	Sistolik Kan Basıncı	Sayısal	-150-16020
6	Diastolik Kan Basıncı	Sayısal	-70-11000
7	Kolesterol	Kategorik	Normal(1) Normalin Üstünde(2) Normalin Çok Üstü(3)
8	Glikoz	Kategorik	Normal(1) Normalin Üstünde(2) Normalin Çok Üstü(3)
9	Sigara	Kategorik	Evet(0)/Hayır(1)
10	Alkol	Kategorik	Evet(0)/Hayır(1)
11	Fiziksel Aktivite	Kategorik	Evet(0)/Hayır(1)
12	KHV var mı yok mu?)	Kategorik	Evet(0)/Hayır(1)

2.2. Yöntemler (Methods)

YZ alanında bir alt dal olan DL insan beyninden esinlenen Yapay sinir ağı (YSA) yapısını örnek alır. Bu ağlar giriş, gizli ve çıkış katmanları olmak üzere

temel üç katmandan oluşmaktadır. Kullanılan DL tekniğine göre gizli katmandaki katman sayılarında farklılıklar olmaktadır [20, 21].

Yapay Sinir Ağı (YSA): dünyadaki en gelişmiş sistemlerin başında insan beyni gelmektedir. Bilim insanları beyinin yapısını örnek olarak bir algoritma geliştirmeye çalışmışlardır. İnsan beyninin yapısına benzeyen bir model olarak YSA oluşturmuşlardır [22]. YSA, birbirlerine bağlanmış birçok sinir hücresinden oluşan matematiksel sistemlerdir. Bir sinir hücresi, genellikle transfer fonksiyonu olarak anılan bir denklemdir. Sinir hücresi, diğer işlem birimlerinden işaretleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkarır. Sinir hücrelerinin ağ içinde birbirlerine bağlanması ile YSA yapısı oluşturulur. Birçok YSA uygulamasında benzer karakteristiğe sahip sinir hücreleri tabakalar halinde yapılandırılarak transfer fonksiyonları eş zamanlı olarak çalıştırılır. En basit bir YSA modelinde yukarıda da bahsedildiği gibi giriş, gizli ve çıkış katmanları üç katman bulunur [23].

Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN): CNN çok katmanlı, ileri beslemeli bir YSA ağıdır. CNN’de giriş bilgisi konvolüsyon çekirdekleri adı verilen küçük filtreler kullanarak işlenir, işlenen bu bilginin boyutunu küçültmek ve önemli bilgileri korumak için havuzlama adı verilen bir işlem uygulanır. Son olarak giriş bilgilerine göre sınıflandırma veya tahminlerde bulunmak için bağlantı ya da çıkış katmanları kullanılarak istenen işlemler gerçekleştirilir [24, 25].

Uzun Kısa Vadeli Hafıza Ağları (LSTM) Bu metod sıralı verileri işleyen Tekrarlayan Sinir Ağı (RNN)’nin sınırlılığı olan kısa bellek problemini çözmek için geliştirilmiştir. RNN’ler önceki hesaplamaları hafızalarında tutarlar ve bunları çıktı ile eşleştirirler bu yüzden girdiler arasındaki ilişkiler önemlidir ve kısa süreli olarak hatırlar ve bir sonraki adımı yürütür [26]. LSTM ise daha uzun süreli hatırlama olanağı sağlar. LSTM yapısı giriş, unutma ve çıkış olmak üzere 3 kapı, blok girişi, Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme (peephole) bağlantılarından oluşmaktadır. Nöronun çıktısı tekrar tekrar nöronun girişine ve tüm kapılarına bağlanır. LSTM’in kendi durumunu sıfırlamak için unutma kapısı, kesin zamanlamaları öğrenmeyi kolaylaştırmak için ise gözetleme bağlantıları eklenmiştir [27].

Açıklanabilir YZ (XAI): ML ve DL modellerinin karar süreçlerini kolay okunabilir ve kavranabilir hale getirmeyi amaçlayan bir yapay zekâ alt alanıdır [28]. Geleneksel olarak, YZ modelleri, çıktılarının nasıl ve neden üretildiğini detaylı bir şekilde açıklamaz ve bu durum sistemin sır olarak kalmasına neden olur. Açıklanabilir YZ, bu karmaşık modellerin mantıksal işleyişini daha anlaşılır hale getirerek, YZ modellerinin karar

verme süreçlerini şeffaf ve anlaşılabilir hale getirmeyi amaçlamaktadır. Açıklanabilir YZ algoritmaları kullanılarak YZ modellerinin çıkış değerlerinin girişi değerlerine göre sayısal veya görsel olarak açıklaması yapılmaktadır. Açıklanabilir YZ modelleri içerisinde en yaygın kullanılan LIME (Local Interpretable Model-Agnostic Explanations) yöntemidir. Bu yöntem, karmaşık YZ modellerinin nasıl karar verdiğini anlamamızı ve güvenilirliğini değerlendirmemizi sağlar [29, 30].

LIME modeli AYZ’nin verdiği kararların şeffaflığına odaklanan ve yorumlanabilirliğini arttıran bir yöntemdir. Bu modelde YZ’ya girdi olarak girilen verilerin çıkış verisini nasıl değiştirdiğini izleyerek bir yorumlama sağlamaya çalışmaktadır. LIME modelden bağımsız olarak çalışarak örnek veri noktalarını bozar ve yeni örnekler oluşturur ve ilk modelin kararlarına benzer tahmin yaparak değişkenlerin tahmin üzerindeki etkisini gösterir [30, 31].

2.3. Değerlendirme Kriterleri (Evaluation Criteria)

YZ modellerinin eğitim performanslarını değerlendirirken birçok metrik kullanılmaktadır [1]. Bu çalışmada eğitim performansları Ortalama karesel hata (MSE) kullanılarak değerlendirilmiştir. MSE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama kare farkını ölçen bir istatistiksel ölçüdür. YZ modellerinin performansını değerlendirmek için yorumlamayı kolaylaştıran ve sıklıkla kullanılan bir hata metriğidir.

$$MSE = \frac{1}{N} \sum_i^N (Y_i - Y_{\text{tahmin}(i)})^2 \quad (1)$$

Burada N toplam veri sayısıdır, Y_i hedef değerlerdir, Y_{tahmin} ise tahmin edilen değerlerdir.

Çalışmada modellerin sınıflandırma performanslarını Doğruluk, Kesinlik, Duyarlılık, F1-Skor ölçütleri kullanılarak değerlendirilmiştir. Verilerin doğru şekilde sınıflandırılma oranı doğruluk, verilerdeki olumlu tahminlerin ne kadar doğru olduğu duyarlılık, doğru sınıflandırmasının kesinlik oranını kesinlik, Kesinlik ve duyarlılığın harmonik ortalamasıdır F1 skoru göstermektedir [33, 34].

Metotların Confusion Matrisi çıkartılarak Doğruluk, Kesinlik, Duyarlılık, F1 Skor değerleri aşağıdaki formüllere göre hesaplanmıştır.

$$\text{Doğruluk} = \frac{TP+TF}{TP+TF+FP+FN} \quad (2)$$

$$\text{Kesinlik} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FP} \quad (4)$$

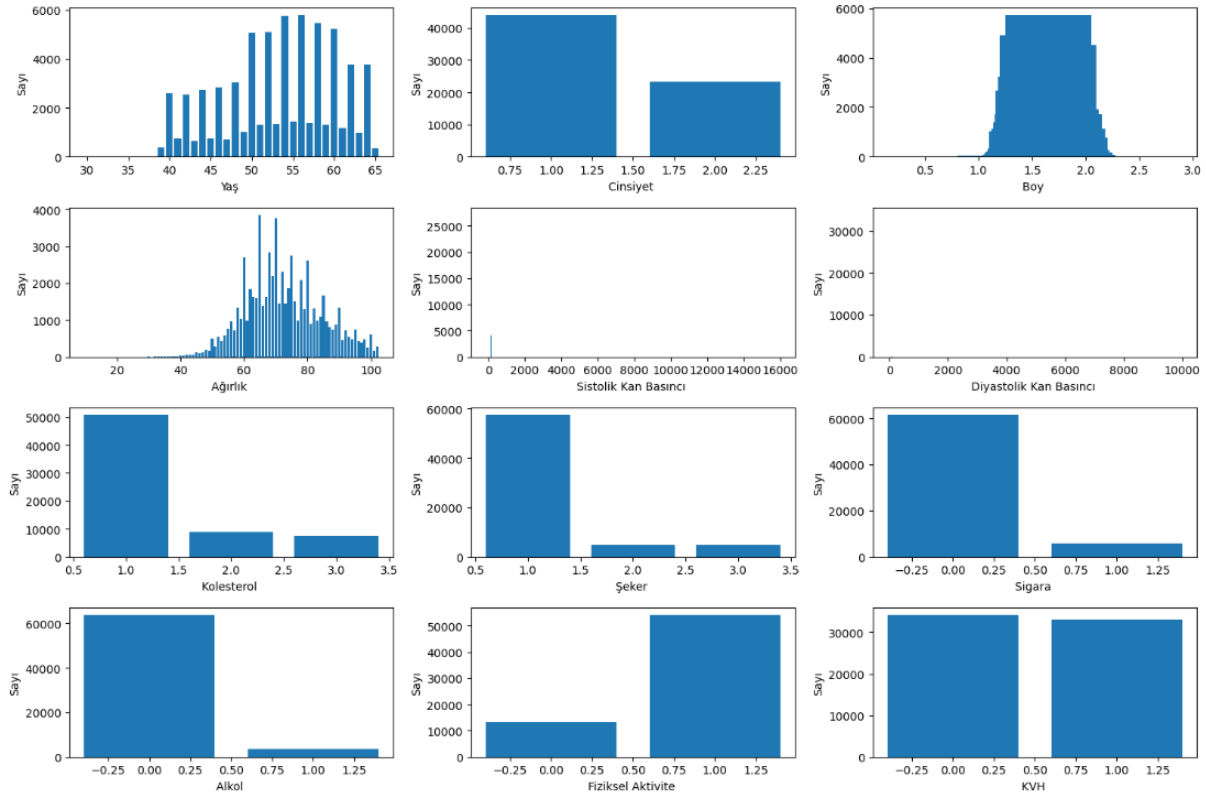
$$F1\text{Skor} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

Denklemlerde TP(doğru pozitif), FP(yanlış pozitif), TN(doğru negatif), FN(yanlış negatif) şeklinde aşağıdaki gibi kullanılmıştır.

3. BULGULAR (RESULTS)

Veri setinde eksik veri ya da boş veri bulunmamaktadır. Verilerin dağılımları incelendiğinde bazı verilerin uç değerlerde olduğu görülmekte ve bu değerlerin performansı

etkileyeceğinden bu aykırı değerler çıkartılmıştır. 70000 hastaya ilişkin verilerin bulunduğu veri setindeki giriş değişkenlerinin istatistiksel dağılımları incelenerek aykırı veriler çıkarılmıştır. İstatistiksel işlemlerde değişkenlerin ortalama değer, standart sapma (std), çarpıklık ve basıklık durumları incelenmiştir. Kilo, Sistolik kan basıncı, Diyastolik kan basıncı değişkenlerindeki değerler için $\text{ortalama} \pm 3 * \text{Std}$ hesaplanarak güven aralığı belirlenen 67189 hastaya ait veri çalışmada kullanılmıştır. Kullanılan veri setinin değişkenlerin dağılımları kabaca Şekil 2’de verilmiştir.



Şekil 2. Değişkenlerin istatistiksel dağılımı (Statistical distribution of variables)

Yaş değişkeninin dağılımını gösteren grafikte, 45-65 yaş aralığındaki bireyler yoğun olarak yer almaktadır. 40 yaş altı ve 60 yaş üstünde oldukça az sayıda hasta bulunmaktadır. Kullanılan veri setinin orta yaş ve ileri yaş grubunun daha fazla temsil edildiği görülmektedir. Kadın (1) ve Erkek (2) temsil edildiği ikinci grafikte kadın hastaların daha fazla sayıda olduğu görülebilir. Üçüncü grafikte boy ve dördüncü grafikte ağırlık değişkeninin dağılımını gösterildiği grafik, normal dağılıma benzer bir eğilim sergilemektedir. Beşinci ve altıncı grafikler, sistolik ve diyastolik kan basıncının dağılımını göstermektedir. Yedinci grafikte kolesterol

sevizinci grafikte şeker seviyelerinin dağılımını gösterilmektedir. Normal(1), Normalin üstünde(2) ve Normalin çok üstü(3) olmak üzere sınıflandırılan hastalara ait verilerin genellikle normal veya hafif yüksek kolesterol seviyelerine sahip olduğunu gösterir. Son dört grafikte ise Sigara, Alkol, Fiziksel aktivite ve KVH verileri Evet (0) ve Hayır (1) şeklinde kategorik olarak sınıflandırılmıştır.


Veri setimiz %80 eğitim ve %20 test verisi rastgele olacak şekilde YZ algoritmalarında kullanılmak üzere ikiye bölünmüştür. Model, kalp hastalıkları ile parametreler arasındaki ilişkiyi öğrenmek için

eğitilmiştir. Kullanılan modelin hiperparametreleri parametreleri tablo 2’de detaylı şekilde en iyi sonuca göre ayarlanmıştır. Model gösterilmiştir.

Tablo 2. YZ yöntemlerinde kullanılan parametreler (Parameters used in AI methods)

ANN	CNN	LSTM
Filters =32, Kernel size = 3 Activation = relu Activation=sigmoid optimizer =adam loss = mse Epochs=50	Filters = 32, Kernel size = 3 Activation = relu Activation=sigmoid optimizer =adam loss = mse Epochs=50	Filters = 32, Kernel size = 3 Activation=relu Activation=sigmoid optimizer =adam loss = mse Epochs=50


Yapılan çalışma da ANN, CNN, LSTM modelleri için Tablo 2’deki parametreler kullanılarak model eğitimleri yapılmıştır. MSE’nin kayıp fonksiyonu olarak kullanılarak her üç modelde en iyi sonuç 0,18 ile LSTM de elde edilmiştir. ANN ve CNN modellerinde de LSTM modeline yakın sonuç elde edilmiştir. Her üç modelin eğitim süreçlerindeki kayıp değerlerini ait kayıp eğrileri şekil 3’de gösterilmiştir. Her üç modelin de ilk iterasyonlarda yüksek kayıp değerlerine sahip olduğu ve ilk 10 iterasyonda kayıplarda belirgin bir düşüş gözlenmektedir. ANN ve CNN modellerinin benzer performans gösterdiği kayıp değerleri yavaşlayarak 0.18 civarında sabitlenmektedir. LSTM modeli başlangıçta daha hızlı bir düşüş göstermiş, sonrasında diğer modellerle benzer bir performans sergilemiştir.



Şekil 3. ANN, CNN, LSTM modelleri kayıp eğrisi (ANN, CNN, LSTM models loss curve)

Seçilen veri setine uygulanan ANN, CNN, LSTM modelleri ile yapılan çalışmada elde edilen kayıp

veri değerleri Şekil 3’de, doğruluk değerleri Şekil 4’de verilmiştir. ANN ve CNN modelleri yaklaşık olarak %74 doğruluk seviyesine hızlıca ulaşırken, LSTM modeli başlangıçta daha düşük bir doğrulukla başlamakta, ancak daha sonra diğer modellerle benzer bir performans sergilemektedir. 20. iterasyondan sonra, tüm modellerin doğruluk değerleri benzer bir şekilde yaklaşık %74 seviyesinde seyretmiştir. DL modellerinin eğitim sürecinde performanslarının iyileştiği ve belirli bir iterasyon sonrasında kararlı bir doğruluk seviyesinde olduğu görülmektedir.



Şekil 4. ANN, CNN, LSTM modelleri doğruluk eğrisi (ANN, CNN, LSTM models accuracy curve)

Doğruluk duyarlık Kesinlik ve F1 skoru için denklem 2, 3, 4, 5 kullanılarak YZ modellerinin test başarıları ölçülmüştür. ANN, CNN, LSTM ile yapılan modellerin Doğruluk, Duyarlılık, Kesinlik ve F1 Skor değerleri Tablo 3 de verilmiştir.

Tablo 3. Model performansları (Model performances)

Modeller	Doğruluk	Duyarlılık	Kesinlik	F1 Skor
ANN	0.734	0.735	0.734	0.734
CNN	0.735	0.735	0.735	0.734
LSTM	0.732	0.732	0.732	0.732

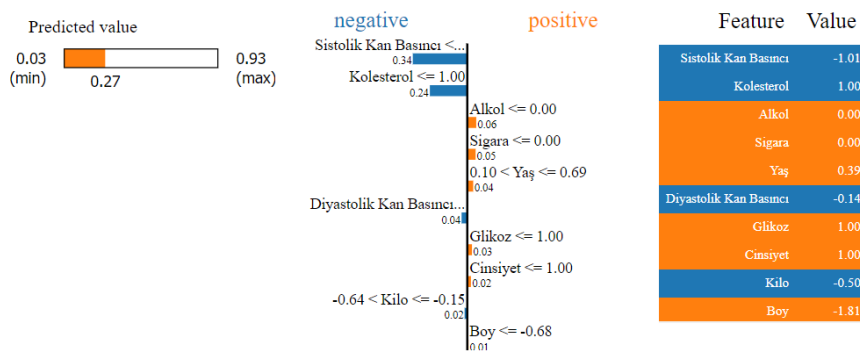
ANN ile yapılan çalışmada AYZ metotlarından LIME uygulanmış ve örnek seçilen 2 hastaya ilişkin veriler Şekil 5 ve Şekil 6 da verilmiştir.

ANN ile yapılan çalışmada açıklanabilir YZ metotlarından LIME uygulanmış ve örnek seçilen 2 hastaya ilişkin veriler Şekil 5 ve Şekil 6 da verilmiştir.


Şekil 5’da sol tarafta, modelin tahmin ettiği değer 0.03 ile 0.93 aralığında değiştiğini ve 0.27 olarak tahmin edildiğini gösterilmektedir. Şeklin orta kısmında ANN ile yapılan tahminde Sistolik Kan Basıncı 0.34 ile negatif yönde, Kolesterol değeri

0.24 ile negatif yönde, yani tahmini azaltan bir etkiye sahipken Alkol değeri 0.06, Sigara değeri 0.05 ve Glikoz değeri 0.03 ile pozitif olarak tahmini artıran bir etkiye sahiptir.

Şekil 6’da sol tarafta, modelin tahmin ettiği değer 0.04 ile 0.93 aralığında değiştiğini ve 0.44 olarak tahmin edildiğini göstermektedir. Şeklin orta kısmında ANN ile yapılan tahminde Sistolik Kan Basıncı değeri 0.35, Kolesterol değeri 0.23, Diyastolik Kan Basıncı 0.04 ile negatif yönde, yani tahmini azaltan bir etkiye sahipken Yaş değeri 0.12, Sigara değeri 0,05 ve Alkol değeri 0.04 ile pozitif olarak tahmini artıran bir etkiye sahiptir.



Şekil 5. 10. Hastanın ANN ile yapılan hastalık tahminin LIME ile açıklaması (Explanation of the disease prediction of the 10th indexed patient made with ANN using LIME)



Şekil 6. 20. Hastanın ANN ile yapılan hastalık tahminin LIME ile açıklaması (Explanation of the disease prediction of the 20th indexed patient made with ANN using LIME)


CNN ile yapılan çalışmada açıklanabilir YZ metotlarından LIME uygulanmış ve örnek seçilen 2 hastaya ilişkin veriler Şekil 7 ve Şekil 8 da verilmiştir.

Şekil 7’da sol tarafta, modelin tahmin ettiği değer 0.06 ile 0.95 aralığında değiştiğini ve 0.23 olarak tahmin edildiğini göstermektedir. Şeklin orta kısmında CNN ile yapılan tahminde Sistolik Kan Basıncı değeri 0.32 ile negatif yönde, Kolesterol değeri 0.26, Diyastolik Kan Basıncı 0.14 ile negatif


yönde, yani tahmini azaltan bir etkiye sahipken Sigara değeri 0.08 ve Alkol değeri 0.06 ile pozitif olarak tahmini artıran bir etkiye sahiptir.

Şekil 8’da sol tarafta, modelin tahmin ettiği değer 0.06 ile 0.95 aralığında değiştiğini ve 0.32 olarak tahmin edildiğini göstermektedir. Şeklin orta kısmında de Sistolik Kan Basıncı değeri 0.31 ile negatif yönde, Kolesterol değeri 0.26, Diyastolik Kan Basıncı 0.14 değeri ile negatif yönde, yani tahmini azaltan bir etkiye sahipken Sigara değeri

0.06 ve Alkol değeri 0.08 ile pozitif olarak tahmini artıran bir etkiye sahiptir.



Şekil 7. 10. Hastanın CNN ile yapılan hastalık tahmininin LIME ile açıklaması (Explanation of the disease prediction of the 10th indexed patient made with ANN using LIME)



Şekil 8. 20 Hastanın CNN ile yapılan hastalık tahmininin LIME ile açıklaması (Explanation of the disease prediction of the 20th indexed patient made with ANN using LIME)

Açıklanabilir YZ ile yorumlanan bu tür bir görsel, DL modelinin kararlarını anlamak ve yorumlamak için önemli bir araçtır. Bu sayede, değerlendiricilerin modelin hangi özelliklere dayanarak karar verdiği daha iyi anlamasına ve gerektiğinde modelin doğruluğu veya güvenilirliği konusunda daha başarılı değerlendirmeler yapmalarına imkân sağlamaktadır.

4. SONUÇLAR ve TARTIŞMA (CONCLUSIONS and DISCUSSION)

Kardiyovasküler hastalıklar dünyada ve ülkemizde oldukça tehlikeli bir hastalıktır. Hasta verileri hastalıkların erken teşhisinde oldukça önemli bir yere sahiptir. Kardiyovasküler hastalıkların tespitinde kan değerlerinin değerlendirilmesi teşhiste önemli bir yol olmaktadır. Bu çalışmada 70 bin hastanın verileri kullanılmıştır. Amaçlanan araştırmayı yapmak için Python dili kullanılarak derin öğrenme ile veri işleme araçlarından Keras, Numpy ve Pandas kütüphaneleri kullanılarak düzenlenmiş olduğumuz verileri DL yöntemlerinden olan ANN, CNN, LSTM teknikleri kullanılmıştır.

Veriler normalize edildikten sonra %80 eğitim %20 test verisi olarak ayrılmıştır. Çalışılan modellerin tahminlerdeki başarı performansları Python dilinde yazılmış kodlar ve kütüphaneler kullanılarak doğrulukları hesaplanmıştır.

ANN, CNN, LSTM ile yapılan bu öğrenmeler sonucunda Açıklanabilir YZ ile çıkarılan sonuçların hangi veriler ile elde edildiği şeffaf bir şekilde açıklanmıştır. Bu bulgular ile hekime karar verme sürecinde daha şeffaf daha başarılı sonuçlar alması sağlanacaktır. Yapılan çalışmada elde edilen doğruluk, hassasiyet, kesinlik, F1 skor değerlerine bakılarak kardiyovasküler hastalıkların tespitinde ANN, CNN, LSTM gibi yöntemlerin kullanılabileceği Açıklanabilir YZ ile de bu sonuçların neden elde edildiği açıklanarak hekimlerin yapacağı tespit daha doğru ve daha hızlı sonuçlar oluşturabileceği sonucuna varılmıştır. DL modelleri ile yapmış olduğumuz çalışmada oldukça iyimser sonuçlar ortaya çıkmış ve elde ettiğimiz bu verilere göre her üç DL yöntemin doğruluk oranlarının hemen hemen aynı oranda başarı elde edildiği gözlemlenmiştir.

Tablo 4. Akademik alanlarda yer alan çalışmalar (Studies in academic fields)

Çalışmayı Yapanlar	Çalışma Konusu	Kullanılan Yöntemler	Sonuçlar
[35] Yan ve Diğ. (2006)	Kalp hastalığı teşhisi için çok katmanlı algılayıcı tabanlı tıbbi karar destek sistemi	Çoklu Algılama Karar Destek Sistemi	%90 Doğruluk
[8] Şengur (2007)	Temel bileşen analizi, yapay bağışıklık sistemi ve bulanık mantık tabanlı bir uzman sistemik-KNN kalp kapak hastalıklarının tanısı	Temel Bileşen Analizi(PCA) K-En Yakın Komşu(KNN)	%95,9 Duyarlılık %96 Özgünlük
[36] Palaniappan ve Diğ. (2008)	Veri madenciliği tekniklerini kullanan akıllı kalp hastalığı tahmin sistemi	Karar Ağacı Naive Bayes	%86 Doğruluk NaviBayes % 80,4 Karar Ağacı
[37] Shao ve Diğ. (2014)	Kalp hastalığı sınıflandırması için hibrit akıllı modelleme şemaları	Hibrit Modelleme	%83,93 Doğruluk
[38] Priyanka ve Diğ. (2017)	Kalp hastalıklarını tahmin etmede veri madenciliği tekniklerinin kullanımı	Naive Bayes Karar Ağacı	%98 Doğruluk Karar Ağacı %83 Doğruluk Naive Bayes

Genel olarak KVH hastaları ile ilgili veri setindeki, istatistiksel dağılımlar demografik ve sağlık verilerinin geniş bir yelpazede dağıldığını ve belirli özelliklerde yoğunlaştığını göstermektedir. Bu veriler, sağlık politikalarının ve müdahalelerinin hedeflenmesinde önemli ipuçları sunmaktadır.

Kardiyovasküler hastalıkların teşhisinde Tablo 4’de ayrıntılı şekilde verilen literatürdeki birçok çalışmada kullanılan yöntemler ve başarı oranları verilmiştir. Çalışmada kullandığımız YZ yöntemlerinden olan CNN, ANN, LSTM algoritmaları veri setinde bulunan 70000 bin veriyi işleyerek sonuçları ortaya koymuştur. Sonuçların literatürdeki diğer çalışmaların aksine bulguların açıklanabilir YZ ile şeffaflaştırılması önemli bir etken oluşturmaktadır.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Çalışma araştırma kurumu veya fonu tarafından desteklenmemiştir. / The study was not supported by any research institution or fund.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Ali VIRIT: Verileri inceleyerek YZ modellerini kurmuş, sonuçlarını analiz ederek, makalenin yazım işlemini gerçekleştirmiştir.

Ali VIRIT: He established the AI models by examining the data, analyzed the results and completed the writing process of the article.

Ali ÖTER: YZ modellerini incelenmesi, sonuçların analiz edilmesi, maklenin yazım işlemi ve denetimini gerçekleştirmiştir.

Ali ÖTER: Examined the AI models, analyzed the results, and completed the writing and supervision of the article.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Ö. P. Özkan, S. K. Büyükuinal, Z. Yiğit, Y. İnci, F. Ş. Şakar, and D. Ö. Ersü, "Kardiyovasküler hastalık tanısı almış hastaların sağlıklı yaşam biçimi davranışlarının değerlendirilmesi," *Mersin Üniversitesi Sağlık Bilimleri Dergisi*, vol. 12, no. 1, pp. 22-31, 2019.
- [2] G. S. WHO, "Global status report on noncommunicable diseases 2010," 2014.
- [3] H. Arıcı, and S. T. Kavradım, "Kardiyovasküler Hastalıklarda Konfor," *Akdeniz Hemşirelik Dergisi*, vol. 2, no. 1, pp. 32-39, 2023.
- [4] B. Kolukisa, V. C. Gungor, and B. B. Gungor, "An ensemble feature selection methodology that incorporates domain knowledge for cardiovascular disease diagnosis." pp. 1-4.
- [5] M. M. Ahsan, and Z. Siddique, "Machine learning-based heart disease diagnosis: A systematic literature review," *Artificial Intelligence in Medicine*, vol. 128, pp. 102289, 2022.
- [6] F. I. Alarsan, and M. Younes, "Analysis and classification of heart diseases using heartbeat features and machine learning algorithms," *Journal of big data*, vol. 6, no. 1, pp. 1-15, 2019.
- [7] P. Rubini, C. Subasini, A. V. Katharine, V. Kumaresan, S. G. Kumar, and T. Nithya, "A cardiovascular disease prediction using machine learning algorithms," *Annals of the Romanian Society for Cell Biology*, pp. 904-912, 2021.
- [8] A. Sengur, "An expert system based on principal component analysis, artificial immune system and fuzzy k-NN for diagnosis of valvular heart diseases," *Computers in biology and medicine*, vol. 38, no. 3, pp. 329-338, 2008.
- [9] İ. A. Çilhoroz, and Y. Çilhoroz, "Kardiyovasküler Hastalıklara Bağlı Ölümleri Etkileyen Faktörlerin Belirlenmesi: OECD Ülkeleri Üzerinde Bir Araştırma," *Acibadem Sağlık Bilimleri Dergisi*, vol. 12, no. 2, 2021.
- [10] S. Erkuş, "Veri madenciliği yöntemleri ile kardiyovasküler hastalık tahminin yapılması," Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü. İstanbul., 2015.
- [11] G. Kaba, and S. B. Kalkan, "Kardiyovasküler Hastalık Tahmininde Makine Öğrenmesi Sınıflandırma Algoritmalarının Karşılaştırılması," *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, vol. 21, no. 42, pp. 183-193, 2022.
- [12] M. Swathy, and K. Saruladha, "A comparative study of classification and prediction of Cardio-Vascular Diseases (CVD) using Machine Learning and Deep Learning techniques," *ICT Express*, vol. 8, no. 1, pp. 109-116, 2022.
- [13] S. Ahmad, M. Z. Asghar, F. M. Alotaibi, and Y. D. Alotaibi, "Diagnosis of cardiovascular disease using deep learning technique," *Soft Computing*, vol. 27, no. 13, pp. 8971-8990, 2023.
- [14] T. Sharean, and G. Johncy, "Deep learning models on Heart Disease Estimation-A review," *Journal of Artificial Intelligence*, vol. 4, no. 2, pp. 122-130, 2022.
- [15] C. Y. Cheung, D. Xu, C.-Y. Cheng, C. Sabanayagam, Y.-C. Tham, M. Yu, T. H. Rim, C. Y. Chai, B. Gopinath, and P. Mitchell, "A deep-learning system for the assessment of cardiovascular disease risk via the measurement of retinal-vessel calibre," *Nature biomedical engineering*, vol. 5, no. 6, pp. 498-508, 2021.
- [16] Z. Alkayyali, S. A. B. Idris, and S. S. Abu-Naser, "A Systematic Literature Review of Deep and Machine Learning Algorithms in Cardiovascular Diseases Diagnosis," *Journal of Theoretical and Applied Information Technology*, vol. 101, no. 4, pp. 1353-1365, 2023.
- [17] M. Pawlicki, A. Pawlicka, R. Kozik, and M. Choraś, "Advanced insights through systematic analysis: Mapping future research directions and opportunities for xAI in deep learning and artificial intelligence used in cybersecurity," *Neurocomputing*, pp. 127759, 2024.
- [18] W. Saeed, and C. Omlin, "Explainable AI (XAI): A systematic meta-survey of current challenges and future opportunities," *Knowledge-Based Systems*, vol. 263, pp. 110273, 2023.
- [19] A. M. Groen, R. Kraan, S. F. Amirkhan, J. G. Daams, and M. Maas, "A systematic review on the use of explainability in deep learning systems for computer aided diagnosis in radiology: Limited use of explainable AI?," *European Journal of Radiology*, vol. 157, pp. 110592, 2022.
- [20] F. DOĞAN, and İ. TÜRKÖĞLU, "Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme," *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 10, no. 2, pp. 409-445, 2019.

- [21] A. Şeker, B. Diri, and H. H. Balık, "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme," *Gazi Mühendislik Bilimleri Dergisi*, vol. 3, no. 3, pp. 47-64, 2017.
- [22] B. Ataseven, "Yapay sinir ağları ile öngörü modellemesi," *Öneri Dergisi*, vol. 10, no. 39, pp. 101-115, 2013.
- [23] A. Öter, O. Aydoğan, and D. Tuncel, "Automatic sleep stage classification using Artificial Neural Networks with Wavelet Transform," *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 8, no. 1, pp. 59-68, 2019.
- [24] M. Karakurt, and İ. İşeri, "Patoloji görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması," *Avrupa Bilim ve Teknoloji Dergisi*, no. 33, pp. 192-206, 2022.
- [25] J. Egger, C. Gsaxner, A. Pepe, K. L. Pomykala, F. Jonske, M. Kurz, J. Li, and J. Kleesiek, "Medical deep learning—A systematic meta-review," *Computer methods and programs in biomedicine*, vol. 221, pp. 106874, 2022.
- [26] P. Dhruv, and S. Naskar, "Image classification using convolutional neural network (CNN) and recurrent neural network (RNN): A review," *Machine learning and information processing: proceedings of ICMLIP 2019*, pp. 367-381, 2020.
- [27] A. Sherstinsky, "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network," *Physica D: Nonlinear Phenomena*, vol. 404, pp. 132306, 2020.
- [28] B. Ersöz, Ş. Sağiroğlu, and H. İ. Bülbül, "A Short Review on Explainable Artificial Intelligence in Renewable Energy and Resources." pp. 247-252.
- [29] R. Dwivedi, D. Dave, H. Naik, S. Singhal, R. Omer, P. Patel, B. Qian, Z. Wen, T. Shah, and G. Morgan, "Explainable AI (XAI): Core ideas, techniques, and solutions," *ACM Computing Surveys*, vol. 55, no. 9, pp. 1-33, 2023.
- [30] J. M. Darias, B. Díaz-Agudo, and J. A. Recio-Garcia, "A Systematic Review on Model-agnostic XAI Libraries." pp. 28-39.
- [31] S. Sezer, A. Oter, B. Ersoz, C. Topcuoglu, H. İ. Bulbul, S. Sagiroglu, M. Akin, and G. Yilmaz, "Explainable artificial intelligence for LDL cholesterol prediction and classification," *Clinical Biochemistry*, pp. 110791, 2024.
- [32] A. Öter, B. Ersöz, Z. Berktaş, H. İ. Bülbül, E. Orhan, and Ş. Sağiroğlu, "An artificial intelligence model estimation for functionalized graphene quantum dot-based diode characteristics," *Physica Scripta*, vol. 99, no. 5, pp. 056001, 2024/03/29, 2024.
- [33] N. E. Campione, and D. C. Evans, "The accuracy and precision of body mass estimation in non-avian dinosaurs," *Biological Reviews*, vol. 95, no. 6, pp. 1759-1797, 2020.
- [34] A. Öter, "Automatic Detection of Epileptic Seizures from EEG Signals Using Artificial Intelligence Methods," *Gazi University Journal of Science Part C: Design and Technology*, pp. 1-1, 2024.
- [35] H. Yan, Y. Jiang, J. Zheng, C. Peng, and Q. Li, "A multilayer perceptron-based medical decision support system for heart disease diagnosis," *Expert Systems with Applications*, vol. 30, no. 2, pp. 272-281, 2006.
- [36] S. Palaniappan, and R. Awang, "Intelligent heart disease prediction system using data mining techniques." pp. 108-115.
- [37] Y. E. Shao, C.-D. Hou, and C.-C. Chiu, "Hybrid intelligent modeling schemes for heart disease classification," *Applied Soft Computing*, vol. 14, pp. 47-52, 2014.
- [38] N. Priyanka, and P. R. Kumar, "Usage of data mining techniques in predicting the heart diseases—Naïve Bayes & decision tree." pp. 1-7.