

## Comprehensive Evaluation of Ensemble Learning (EL) Models in Cardiovascular Diseases Management: A Meta-Synthesis Approach

**Mahmoud Zahedian**

Nezhad 

Ph.D student, Department of Information  
Technology Management, Ferdowsi University  
of Mashhad, Mashhad, Iran

**Mohammad Mehraeen** \*

Professor, Department of Information  
Technology Management, Ferdowsi University  
of Mashhad, Mashhad, Iran

**Rouhollah Bagheri** 

Associate Professor, Department of Information  
Technology Management, Ferdowsi University  
of Mashhad, Mashhad, Iran

**Seyyed Mohammad**

Tabatabae 

Assistant Professor, Department of Medical  
Informatics, Faculty of Medicine, Mashhad  
University of Medical Sciences, Mashhad, Iran

### Abstract

Cardiovascular diseases (CVDs) are among the leading causes of mortality worldwide. The increasing volume of complex data generated by diagnostic tools, such as electrocardiograms (ECG), poses significant challenges for clinicians, impacting both diagnostic accuracy and treatment speed. Ensemble Learning (EL), by integrating multiple models, offers enhanced performance in CVD management; however, few studies have systematically compared its techniques or provided a comprehensive classification of EL applications in this domain. Therefore, this study aims to categorize EL models in CVD management, evaluate their performance and efficiency within each category, identify the

\* Corresponding Author: mehraeen@um.ac.ir

**How to Cite:** Zahedian Nezhad, M., Mehraeen, M., Bagheri, R., Tabatabae, S.M. (2026). Comprehensive Evaluation of Ensemble Learning (EL) Models in Cardiovascular Diseases Management: A Meta-Synthesis Approach, *Journal of Business Intelligence Management Studies*, 15(55), 39-126. DOI: 10.22054/ims.2025.86650.2638

advantages and limitations of each model, and analyze the role of feature engineering in their application. To achieve these objectives, a meta-synthesis approach was employed, examining the use of EL models in combination with Machine Learning (ML) and Deep Learning (DL) techniques for CVD management. The seven-step method proposed by Sandelowski and Barroso (2007) was applied for the meta-synthesis. Initially, relevant articles were retrieved from the Web of Science using predefined keywords. Subsequently, articles were screened based on title, abstract, accessibility, full content, and research methodology, and the final selection was made for detailed analysis. Findings from the meta-synthesis indicate that EL applications in CVD management can be classified into four main domains: prediction (75 articles), diagnosis (30 articles), identification (18 articles), and classification (9 articles). The results confirm that EL models are dominant across all four domains, with their effectiveness significantly enhanced when integrated with ML and DL techniques. Among various approaches, Random Forest (RF) and gradient boosting algorithms such as XGBoost were the most frequently used and identified as the most efficient and accurate models. This study provides a structured overview, offering valuable insights for researchers in designing intelligent CVD prediction and diagnostic systems, as well as for clinicians in utilizing these systems, and establishes a framework for applying hybrid models to achieve more precise and effective CVD management.

## **1. Introduction**

Effective management of cardiovascular diseases (CVDs) is increasingly challenged by the complexity and increasing volume of data generated by modern diagnostic technologies. This data-rich environment complicates clinical interpretation and timely diagnosis. Therefore, artificial intelligence (AI) and machine learning (ML) have become essential tools, and ensemble learning (EL) techniques—such as boosting, bagging, and stacking—have emerged as particularly powerful for building robust predictive models by integrating diverse data sources. Despite significant advances in this field, there is still a gap in the systematic and comprehensive review of the literature on

the effectiveness, strengths, and limitations of EL techniques across all areas of CVDs management. This study aims to address this gap by providing a comprehensive review and providing insights that will enable researchers and practitioners to apply these models with greater accuracy and interpretability.

**Research Questions:**

1. How can EL models used in CVD management be categorized?
2. Which EL models achieve the highest accuracy within each CVD management category?
3. What limitations and challenges exist in applying EL models to CVD management?
4. How are EL models typically validated and evaluated?
5. What preprocessing and feature engineering methods are used in datasets designed for EL-based CVD management?

**2. Literature Review**

AI covers a wide range of methods that try to mimic how people think and solve problems. At the heart of it all, you've got ML and deep learning (DL). ML uses stats and algorithms to learn from organized data, while DL leans on artificial neural networks to pull out deeper patterns from tricky stuff like medical images or signals. Now, when we want to boost how well these models predict things and make them more reliable, you turn to EL. EL pulls together predictions from a bunch of different models and blends them into one answer that's usually more accurate. The real point of EL is to cut down on errors by mixing up different models—so if one misses something, another can catch it. It will often see approaches like bagging, boosting, stacking, and voting used here. Ensemble methods are valuable in healthcare, where model reliability and accuracy across diverse patient datasets are crucial.

**3. Methodology**

A meta-synthesis method was employed in this research to comprehensively analyze and interpret literature results on EL and ML/DL models in CVD management. It conforms to a seven-step guideline process by Sandelowski and Barroso in 2007, which is most

appropriate for meta-synthesis, especially for incorporating qualitative studies with their quantitative counterparts. Intensive literature searches were undertaken on Web of Science with its publication years ranging from 2010-2024, and with flexible searching keywords such as “Cardiovascular Diseases,” “Machine Learning,” “Deep Learning.”

Starting with 1,323 articles, a rigorous staged process of screening was undertaken, with consideration for title, abstract, availability, and final relevance. Finally, 134 articles met all criteria to be included in final meta-synthesis for consideration in their synthesis. Data from these articles was employed for analysis in meta-synthesis to finally group models for EL into four groups regarding management for CVDs.

#### **4. Results**

The synthesis of 134 studies shows that EL models in CVD management fall into four primary categories: prediction, diagnosis, classification, and identification. Prediction is the most extensively studied domain, represented by 75 articles focusing on forecasting disease onset, stratifying patient risk, optimizing healthcare resources, and predicting survival outcomes. Diagnosis (30 studies) and classification (18 studies) are also significant areas where EL and ML/DL models are used to detect CVDs from biomedical signals such as ECG and PCG, as well as to differentiate between different types of heart diseases. Identification (9 studies), though less common, focuses on recognizing key risk factors to support preventive interventions.

In terms of model adoption, EL methods have exceptionally high popularity in the literature. Random Forest is noticed to be adopted most in its individual capacity as an algorithm, representing 111 occurrences. Amongst popular boosting algorithms, XGBoost leads, with Gradient Boosting not too far behind in second place, while AdaBoost follows. Amongst traditional ML algorithms, Support Vector Machines and Logistic Regression algorithm remain ever popular in their respective applications in classification problems. On the other hand, the DL landscape is diverse, with ANNs and their variants like MLPs being the most common, while Convolutional Neural Networks are pivotal for image and signal analysis, and

Recurrent Neural Networks like LSTMs are typically applied to sequential data.

### **5. Discussion and Conclusion**

EL models, especially RF and XGBoost, play a crucial role in managing CVDs in the primary areas of prediction, diagnosis, classification, and identification. One major upcoming trend involves the synergy between EL and DL models such as CNNs, which perform exceptionally on complex biomedical patterns inherent in classification and identification problems. Notably, these models require critical preprocessing steps in data, with techniques for noise reduction, dimensionality reduction, or correction for class imbalance, such as SMOTE, being necessary for improving model accuracy, consistency, and generalizability. Nevertheless, there are numerous challenges in clinical practice, especially due to their dependency on small-scale studies, computational complexity, or BI proprieties, signifying critical importance for model validation via rigorous testing for accuracy, sensitivity, specificity, and AUC-ROC, while SHAP analysis or XAI analysis is being increasingly called for in overcoming proprieties in model interpretability.

**Keywords:** Cardiovascular Diseases Management, Meta-synthesis Approach, Ensemble Learning (EL), Machine Learning (ML), Deep Learning (DL).



## ارزیابی جامع مدل‌های یادگیری گروهی (EL) در مدیریت بیماری‌های قلبی عروقی: رویکردی فراترکیب

دانشجوی دکتری رشته مدیریت فناوری اطلاعات، گروه مدیریت، دانشگاه فردوسی مشهد، مشهد، ایران

id محمود زاهدیان نژاد

استاد مدیریت فناوری اطلاعات، گروه مدیریت، دانشگاه فردوسی مشهد، مشهد، ایران

\* id محمد مهرآیین

دانشیار مدیریت فناوری اطلاعات، گروه مدیریت، دانشگاه فردوسی مشهد، مشهد، ایران

id روح‌الله باقری

استادیار انفورماتیک پزشکی، گروه انفورماتیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی مشهد، مشهد، ایران

id سید محمد طباطبایی

### چکیده

بیماری‌های قلبی-عروقی (CVDs) یکی از علل اصلی مرگ‌ومیر در سراسر جهان محسوب می‌شوند. افزایش داده‌های پیچیده حاصل از ابزارهای تشخیصی مانند الکتروکاردیوگرام (ECG)، چالش‌های قابل توجهی را برای پزشکان ایجاد کرده که بر دقت تشخیص و سرعت درمان تأثیر می‌گذارد. یادگیری گروهی (EL) با ترکیب مدل‌های مختلف، عملکرد بهتری را در مدیریت CVD ها ارائه می‌دهد، اما تحقیقات محدودی به صورت سیستماتیک تکنیک‌های مختلف آن را مقایسه کرده‌اند و به بررسی یک طبقه‌بندی جامع از به کارگیری مدل‌های گروهی در CVD ها پرداخته‌اند؛ بنابراین، هدف این مطالعه، دسته‌بندی مدل‌های EL در مدیریت CVD ها، ارزیابی عملکرد و کارایی آن‌ها در هر دسته، شناسایی مزایا و محدودیت‌های هر مدل و تحلیل نقش مهندسی ویژگی در به کارگیری آن‌ها در مدیریت CVD ها است. این پژوهش برای دستیابی به اهداف تحقیق از رویکرد فراترکیب استفاده کرده که به بررسی کاربرد مدل‌های EL در ترکیب با مدل‌های یادگیری ماشین (ML) و یادگیری عمیق (DL) در مدیریت CVD ها می‌پردازد. برای به کارگیری روش فراترکیب (Meta-Synthesis) در این تحقیق از رویکرد هفت‌گانه

سندلوسکی و باروسو (۲۰۰۷) استفاده شده است. در ابتدا با استفاده از کلیدواژه‌های مشخص شده و جست‌وجوی آن‌ها در پایگاه علمی وب آو ساینس، منجر به استخراج مقاله شده و سپس با بررسی مقالات از نظر عنوان، چکیده، دسترسی‌پذیری، تمام محتوا و روش‌شناسی تحقیق، مقاله جهت بررسی نهایی انتخاب شدند. یافته‌های این فراترکیب نشان می‌دهد که کاربرد مدل‌های یادگیری در مدیریت CVD ها به چهار حوزه‌ی اصلی تقسیم می‌شود: پیش‌بینی (۷۵ مقاله)، تشخیص (۳۰ مقاله)، شناسایی (۱۸ مقاله) و طبقه‌بندی (۹ مقاله). نتایج تأیید می‌کند که مدل‌های EL در تمام این چهار حوزه غالب هستند و کارایی آن‌ها با ادغام با تکنیک‌های ML و DL به‌طور قابل توجهی افزایش می‌یابد. در میان رویکردهای مختلف، مدل‌های جنگل تصادفی (RF) و الگوریتم‌های تقویت گرادیان مانند XGBoost، بیشترین فراوانی استفاده را داشته و به‌عنوان کارآمدترین و دقیق‌ترین مدل‌ها شناخته می‌شوند. این پژوهش با ارائه یک نمای کلی ساختاریافته، بینش‌های ارزشمندی را برای محققان در طراحی سیستم‌های هوشمند تشخیص و پیش‌بینی CVD ها و متخصصان بالینی جهت استفاده از این سیستم‌ها فراهم می‌کند و چارچوبی برای به‌کارگیری مدل‌های ترکیبی جهت دستیابی به مدیریت دقیق‌تر و مؤثرتر بیماری‌های قلبی-عروقی ارائه می‌دهد.

کلیدواژه‌ها: مدیریت بیماری‌های قلبی عروقی (CVDs)، رویکرد فراترکیب، یادگیری گروهی (EL)، یادگیری ماشین (ML)، یادگیری عمیق (DL).

## مقدمه

بیماری‌های قلب و عروقی<sup>۱</sup> (CVDs) شامل طیف گسترده‌ای از اختلالات است که قلب و عروق خونی را تحت تأثیر قرار می‌دهد که باعث ایجاد یک بحران جهانی همراه با بالاترین میزان مرگ و میر می‌شود. CVD ها شامل چندین زیرگروه با خواص منحصر به فرد، عوامل خطر و چالش‌های تشخیصی هستند. این گروه شامل طیف گسترده‌ای از آسیب‌شناسی‌ها مانند بیماری عروق کرونر<sup>۲</sup> (CAD)، حمله قلبی، نارسایی قلبی، فشار خون بالا، آریتمی، بیماری شریانی محیطی و بیماری دریچه قلب است (Nabel 2003; Virani et al. 2020). بیماری‌های قلبی عروقی بیماری‌های چندعاملی هستند که تحت تأثیر عوامل خطر مختلفی از طیف وسیعی از عوامل فیزیولوژیکی، ژنتیکی و رفتاری قرار می‌گیرند (Roth et al. 2020; Virani et al. 2020).

در حالی که مدیریت و کنترل عوامل خطر مختلف می‌تواند بروز و شروع سریع بیماری‌های قلبی عروقی را کاهش دهد، شناسایی عوامل مهم، تشخیص زودهنگام و پیش‌بینی دقیق شروع بیماری برای مداخله مؤثر و بهبود پیامدهای بیمار بسیار مهم است. با پیشرفت‌های تکنولوژیکی در دهه‌های اخیر در ابزارهای تشخیصی، از جمله الکتروکاردیوگرام<sup>۳</sup> (ECG)، اسکن توموگرافی کامپیوتری (CT)، اکو کاردیوگرافی، تکنیک‌های تصویربرداری پیشرفته و سنسورهای پوشیدنی، همگی باعث تشخیص زودهنگام بیماری شده و به نظارت مداوم و بلادرنگ بیماران کمک کرده‌اند (Celermajer et al. 2012) (Moradi et al. 2023; Sun et al. 2021) با این حال، ساختار پیچیده سیستم قلبی عروقی، ابزارهای تشخیصی مختلف و داده‌های مرتبط با آن‌ها و همچنین حجم عظیمی از داده‌های تولید شده از این سیستم پیچیده، چالش بزرگی را برای پزشکان جهت تفسیر این داده‌ها و در نهایت تشخیص بیماری و حتی نوع آن ایجاد کرده است (Chen et al. 2021).

---

1. Cardiovascular diseases (CVDs)

2. Coronary Artery Disease (CAD)

3. Electrocardiogram (ECG)

در چنین شرایطی، نیاز به روش‌های محاسباتی هوشمند که بتوانند این داده‌های پیچیده را تحلیل کرده و الگوهای پنهان در آن‌ها را شناسایی کنند بیش از پیش احساس می‌شود. در این راستا، فناوری‌هایی مانند هوش مصنوعی<sup>۱</sup> (AI)، یادگیری ماشین<sup>۲</sup> (ML) و یادگیری عمیق<sup>۳</sup> (DL) نقش برجسته‌ای در پردازش و تفسیر داده‌ها و در نهایت شناسایی، تشخیص و پیش‌بینی CVD ها ایفا کرده‌اند (Sidey-Gibbons and Sidey-Gibbons 2019). نوآوری‌های اخیر در یادگیری گروهی (EL) مانند طبقه‌بندی کننده‌ها و مدل‌های تقویت<sup>۴</sup>، بگینگ<sup>۵</sup>، پشته‌ای یا انباشتگی<sup>۶</sup> و رأی‌گیری<sup>۷</sup>، راه را برای مدل‌های مدیریت CVD های قوی‌تر با ادغام داده‌های چندگانه هموار کرده است (Mahajan et al. 2023; Miao, 2016; Miao, and Miao 2016). ادغام این تکنیک‌ها با سایر مدل‌های ML و DL که در آن مدل‌های آموزش دیده بر روی یک گروه برای استفاده در گروه دیگر سازگار می‌شوند، پتانسیل غلبه بر مدیریت این بیماری‌ها را نشان داده است (Tiwari, Chugh, and Sharma 2022).

علیرغم مزایای آن، مطالعات نقش محدودی در بررسی اثربخشی تکنیک‌های مختلف EL و مقایسه آن‌ها در تشخیص و پیش‌بینی جامع CVD ها ایفا کرده‌اند. به‌عنوان مثال در تحقیقی به‌تازگی، گوئر و همکاران (۲۰۲۵)، مروری بر پیش‌بینی بیماری نارسائی قلبی (HF) با استفاده از مدل‌های یادگیری گروهی، با در نظر گرفتن متغیرهای محیطی و سلامت، انجام داده‌اند. این مطالعه، تحقیقات مربوط به روش‌های گروهی شناخته‌شده مانند AdaBoost، XGBoost، CatBoost، جنگل تصادفی، طبقه‌بندی کننده‌های انباشت و رأی‌گیری را خلاصه و ترکیب کرده است. نتایج آن‌ها نشان می‌دهد که از بین این روش‌ها، روش‌های انباشت و رأی‌گیری همیشه از نظر پیش‌بینی خطر

- 
1. Artificial Intelligence (AI)
  2. Machine Learning (ML)
  3. Deep Learning (DL)
  4. Boosting
  5. Bagging
  6. Stacking
  7. Voting

HF نسبت به سایرین برتر بوده‌اند و هر دو به دقت نسبتاً خوب و عملکرد پایدار در مجموعه داده‌های مختلف دست یافته‌اند. همچنین رویکردهای اخیر مانند تقویت حداقل خطا، BOO-ST و CBCEC را که با مسائل متعددی مانند عدم تعادل داده‌ها و انتخاب ویژگی سروکار دارند، مورد بحث قرار داده‌اند (Gour et al. 2025).

تاکور و همکاران (۲۰۲۳)، نقش روش‌های گروهی را در تشخیص قلب و عروق برجسته کرده‌اند. همچنین، یزدی و اسدی (۲۰۲۵)، در مطالعه‌ای روشی پیشرفته به نام بهینه‌سازی یادگیری گروهی پویا مبتنی بر GMM را با استفاده از یک الگوریتم تکاملی چند هدفه مبتنی بر تجزیه (MOEA/D) برای تشخیص CVD معرفی می‌کند. این رویکرد از نمونه‌گیری مجدد تکاملی الهام گرفته از مدل مخلوط گاوسی (GMM) برای افزایش تنوع، عملکرد و کمیت طبقه‌بندی‌کننده‌ها استفاده می‌کند و مجموعه داده‌های بهینه را تولید می‌کند. روش پیشنهادی آن‌ها بر روی هفت مجموعه داده بیماری قلبی آزمایش شده است که نتایج آن‌ها نشان‌دهنده عملکرد عالی الگوریتم‌های گروهی است (Yazdi and Asadi 2025). در تحقیقی دیگر، کریتاناوونگ و همکاران (۲۰۲۰)، نقش الگوریتم‌های ML در پیش‌بینی CVD را مورد بررسی و ارزیابی قرار داده‌اند؛ بنابراین، فقدان تجزیه و تحلیل سیستماتیک و جامع از اثربخشی، نقاط قوت، محدودیت‌ها و کاربرد بالینی و همچنین همگرایی مدل‌های گروهی، مانع از درک کامل آن در مدیریت CVD ها شده است. برای رفع این شکاف، پژوهش حاضر نوآوری خود را در قالب یک تحلیل نظام‌مند از مطالعات موجود درباره‌ی مدل‌های EL در مدیریت این بیماری‌ها ارائه می‌کند.

این پژوهش به صورت عملیاتی از طریق (۱) طبقه‌بندی جدید و ساختارمند مدل‌ها و تکنیک‌های EL بر اساس حوزه‌های کاربردی مختلف در مدیریت CVD ها (مانند تشخیص، پیش‌بینی و طبقه‌بندی خطر)، (۲) مقایسه‌ی کمی معیارهای عملکردی مدل‌ها از نظر معیارهایی مانند دقت، حساسیت، خاصیت و AUC، (۳) تحلیل روش‌های اعتبارسنجی به کاررفته در مطالعات منتخب، (۴) شناسایی و طبقه‌بندی چالش‌ها و محدودیت‌های موجود در پیاده‌سازی مدل‌های EL و در نهایت (۵) بررسی جامع روش‌ها و فنون مدیریت داده‌ها و

مهندسی ویژگی‌ها برای به کارگیری مؤثر مدل‌های EL در داده‌های چندمنبعی CVD، به شکاف پژوهشی موجود پاسخ می‌دهد.

بنابراین، پرداختن به این شکاف، بینش‌های ارزشمندی را برای محققان و متخصصان CVD فراهم می‌کند که به دنبال استفاده از این مدل‌ها به شیوه‌ای دقیق‌تر، قابل‌اعتمادتر و قابل‌تفسیرتر در مدیریت این بیماری‌ها هستند. از این رو، این پژوهش به دنبال رفع این شکاف پژوهشی با طرح و پاسخ به سؤالات زیر است.

۱. به کارگیری مدل‌ها و تکنیک‌های EL در مدیریت CVD ها در چند دسته تقسیم‌بندی می‌شوند؟

۲. کدام مدل‌های EL بیشترین دقت و عملکرد را در هر دسته از مدیریت CVD ها داشته‌اند؟

۳. چگونه مدل‌ها و تکنیک‌های EL در مدیریت CVD ها اعتبارسنجی می‌شوند؟

۴. محدودیت‌ها و چالش‌های مربوط به به کارگیری مدل‌های EL در مدیریت CVD ها چیست؟

۵. جهت به کارگیری مدل‌های EL در مدیریت داده‌ها CVD چه تکنیک‌ها و روش‌های پیش‌پردازش داده‌ها و مهندسی ویژگی‌های استفاده می‌شود؟

برای پاسخ به سؤالات مطرح شده، این مطالعه از یک روش فراترکیب استفاده می‌کند که به‌طور سیستماتیک یافته‌های ادبیات موجود را ادغام و تجزیه و تحلیل می‌کند. در ادامه، مفاهیم اساسی EL و ML/DL در بخش دوم بررسی و به دنبال آن مروری بر ادبیات مربوط به کاربرد این روش‌ها در مدیریت CVD ها در بخش سوم انجام می‌شود. بخش چهارم روش تحقیق را با تمرکز بر رویکرد فراترکیب و پایگاه داده وب آو ساینس توصیف می‌کند. بخش پنجم یافته‌های فراترکیب را در استفاده از مدل‌های یادگیری، به‌ویژه EL، در مدیریت CVD ها ارائه می‌دهد. بخش ششم شامل یک بررسی جامع از مدیریت CVD ها از نظر چهار دسته اصلی یعنی تشخیص، پیش‌بینی، طبقه‌بندی و شناسایی بر اساس مدل‌های یادگیری است. بخش‌های هفتم، هشتم و نهم به ترتیب معیارهای ارزیابی عملکرد

مدل‌ها، محدودیت‌ها و چالش‌های استفاده از مدل‌های یادگیری گروهی و ترکیبی و اهمیت مهندسی ویژگی و پیش‌پردازش داده‌ها را مورد بحث قرار می‌دهند. در نهایت، مقاله با بخش دهم به پایان می‌رسد که نتیجه‌گیری کلی را ارائه می‌دهد.

### پیشینه پژوهش

#### مبانی نظری پژوهش

هوش مصنوعی حوزه گسترده‌ای است که هدف آن ایجاد ماشین‌ها یا سیستم‌هایی است که قادر به شبیه‌سازی عملکردهای شناختی شبیه انسان مانند ادراک، استدلال و تصمیم‌گیری هستند. در زمینه CVD ها، AI این امکان را فراهم کرده است تا از حجم عظیم داده‌های بالینی، تصویری و سیگنال‌های فیزیولوژیکی الگوهای پنهان استخراج شود و تشخیص‌های سریع‌تر و دقیق‌تری صورت گیرد. به عنوان یک اصطلاح چتر گسترده، هوش مصنوعی شامل ML و DL است که روش‌های تخصصی‌تری برای به دست آوردن قابلیت‌های هوش مصنوعی هستند.

یادگیری ماشین بر الگوریتم‌های آماری و داده‌محور متکی است که می‌توانند از داده‌های گذشته یاد بگیرند و در مواجهه با داده‌های جدید تصمیم‌گیری کنند (Navaei, Safarzadeh, and Sobhani 2025). بر اساس داده‌ها، ML و DL سیستم‌ها را قادر می‌سازد تا تشخیص، پیش‌بینی، طبقه‌بندی و تصمیمات آگاهانه بگیرند (Azmi et al. 2022). ML در طول زمان با در دسترس قرار گرفتن داده‌های جدید با استفاده از روش‌های مبتنی بر داده برای یافتن الگوها، پیش‌بینی‌ها و تکمیل وظایف طبقه‌بندی، سازگار می‌شود. نقطه قوت ML سازگاری و ظرفیت آن برای کار با داده‌های ساختاریافته است (Chen et al. 2022).

شاخه‌های اصلی ML یادگیری تحت نظارت، بدون نظارت و تقویتی هستند و با استفاده از مدل‌ها و الگوریتم‌های آماری نتایج را پردازش، پیش‌بینی و طبقه‌بندی می‌کند (Azmi et al. 2022). به عنوان مثال، علی و همکاران (۲۰۲۱)، به بررسی الگوریتم‌های یادگیری ماشین نظارت شده در پیش‌بینی بیماری قلبی پرداخته‌اند و از نظر عملکرد و دقت

مورد مقایسه قرار داده‌اند. نتایج آن‌ها نشان می‌دهد که الگوریتم‌های k-نزدیک‌ترین همسایه (KNN)، درخت تصمیم (DT) و جنگل‌های تصادفی (RF)، بهترین عملکرد را در میان سایر الگوریتم‌های ML نظارت‌شده کسب کرده‌اند (Ali et al. 2021). در تحقیق دیگر، کریتاناوونگ و همکاران (۲۰۲۰)، بر اساس یک فراتحلیل بر روی ده‌ها مطالعه در حوزه‌ی به‌کارگیری الگوریتم‌های نظارت‌شده در پیش‌بینی CVD نشان داده‌اند که الگوریتم‌های مبتنی بر تقویت گرادایانت (مانند XGBoost)، درخت تصمیم و SVM توانمندی بالایی در پیش‌بینی و تشخیص بیماری‌های قلبی از جمله CAD و تحلیل ریسک قلبی دارند (Krittawong et al. 2020). همچنین انصاری و همکاران (۲۰۲۳)، در زمینه‌ی تشخیص سیگنال ECG و ریزکلاس‌بندی آریتمی‌ها مروری بر مطالعات مبتنی بر یادگیری نظارت‌شده و شبکه‌های عصبی عمیق (به‌ویژه مدل‌های کانولوشنی و MLP) بین سال‌های ۲۰۱۷ تا ۲۰۲۳ داشته‌اند. نتایج آن‌ها گزارش‌کننده‌ی عملکرد برتر الگوریتم‌های نظارت‌شده در کنار شبکه‌های عصبی در تشخیص و طبقه‌بندی آریتمی و سایر نشانگرهای قلبی بوده‌اند (Ansari et al. 2023).

از سوی دیگر، روش‌های بدون نظارت برای فشرده‌سازی، خوشه‌بندی و فنوتایپینگ بیماران کاربرد یافته‌اند (Nucifora et al. 2025)؛ برای مثال، سی. جنتزر و همکاران (۲۰۲۴)، با استفاده از الگوریتم‌های خوشه‌بندی و مدل‌های یادگیری نهفته مانند autoencoders زیرگروه‌های بالینی متمایزی در نارسایی قلبی و تصویربرداری قلبی شناسایی کرده‌اند که قابلیت ریسک‌سنجی و طبقه‌بندی مجدد بیماران را نشان می‌دهد (Jentzer et al. 2024). همچنین چائو و همکاران (۲۰۲۵)، گزارش داده‌اند که ترکیب تکنیک‌های یادگیری ماشین نظارت‌شده (مثل XGBoost / LightGBM) با فرایندهای انتخاب ویژگی و تنظیم فرآیندها بر اساس الگوریتم‌های نظارت‌نشده می‌تواند دقت پیش‌بینی حوادث قلبی را به‌طور معناداری بهبود دهد (Cao et al. 2025). در تحقیقی دیگر پریادارشی و همکاران (۲۰۲۴)، به بررسی نقش روش‌های یادگیری بدون نظارت در پیشبرد تحلیل تصویربرداری پرداخته‌اند. آن‌ها الگوریتم‌های بدون نظارت، از جمله

تکنیک‌های خوشه‌بندی، کاهش ابعاد و مدل‌های تولیدی را بررسی و مورد تجزیه و تحلیل قرار داده‌اند. نتایج آن‌ها نشان می‌دهد که الگوریتم‌های خوشه‌بندی مانند K-means، خوشه‌بندی سلسله مراتبی، DBSCAN، خوشه‌بندی طیفی، C-means فازی و خوشه‌بندی تغییر میانگین و همچنین روش‌های کاهش ابعاد مانند PCA و t-SNE و مدل‌های تولیدی مانند VAE ها و GAN ها، بیشترین استفاده را در کشف الگوهای پنهان و افزایش دقت تشخیصی تصویربرداری قلبی داشته‌اند (Priyadarshi et al. 2024). این شواهد نشان می‌دهد که هر دو رده‌ی روش‌ها — نظارت‌شده و بدون نظارت — نقش عملی و مکمل در پژوهش‌های CVD ایفا می‌کنند.

میشرا و همکاران (۲۰۲۵)، در تحقیق دیگر، یک مرور عمیق بر اساس روش بررسی مرور نظام‌مند (SLR) در زمینه به‌کارگیری تکنیک‌های یادگیری تقویتی (RL) برای تشخیص و کنترل بیماری‌های بحرانی ارائه داده‌اند. نتایج آن‌ها نشان می‌دهد که تکنیک‌های تقویت پیشرفته شامل تقویت عمیق، تقویت چندعاملی، یادگیری تقویتی سلسله مراتبی، یادگیری تقویتی معکوس و یادگیری فدرال، بیشترین کاربردها را در بهبود تشخیص و کنترل بیماری‌ها از جمله بیماری‌های قلبی عروقی و قلبی داشته‌اند (Mishra, Shrivastava, and Bhushan 2025). در حوزه CVD ها، ML در تحلیل داده‌های ساختاریافته مانند سوابق بیماران، نتایج آزمایشگاهی و ویژگی‌های بالینی بسیار کاربرد دارد. برای مثال، مدل‌های ML در شناسایی بیماران در معرض خطر سکته قلبی یا پیش‌بینی پیامدهای درمانی بر اساس پارامترهای جمعیت‌شناختی و سبک زندگی عملکرد قابل توجهی داشته‌اند.

شکل دیگری از ML به نام «یادگیری عمیق» از شبکه‌های عصبی مصنوعی<sup>۱</sup> (ANNs) استفاده می‌کند که می‌تواند نمایش‌های سلسله مراتبی را یاد بگیرد و روابط داده پیچیده را بیان کند. در مدیریت CVD ها، DL به‌ویژه در تحلیل سیگنال‌های ECG، تصاویر اکوکاردیوگرافی، MRI و CT نقش کلیدی دارد؛ زیرا می‌تواند الگوهای پیچیده‌ای را که

---

1. Artificial Neural Networks (ANNs)

برای پزشک به صورت چشمی قابل تشخیص نیستند، استخراج کند. برای نمونه، شبکه‌های CNN در تشخیص آریتمی‌ها از سیگنال ECG یا در تفکیک بافت‌های آسیب‌دیده از تصاویر قلبی دقت بالایی نشان داده‌اند (Ansari et al. 2023).


با وجود این، مدل‌های منفرد ML یا DL ممکن است در مواجهه با نویز داده، ناهمگنی بیماران، یا کمبود داده‌های آموزشی دچار افت عملکرد شوند. در چنین شرایطی، یادگیری گروهی به عنوان رویکردی ترکیبی و قدرتمند مطرح می‌شود. مدل‌های EL یکی از متناسب‌ترین راه‌حل‌هاست که پیش‌بینی‌کننده‌های مختلفی را از چندین مدل جمع‌آوری می‌کند. در مقایسه با یک طبقه‌بندی واحد، رویکردهای گروهی از چندین الگوریتم (ML یا DL) برای تولید پیش‌بینی‌های دقیق‌تر استفاده می‌کنند. هدف اصلی مدل‌های گروهی کاهش خطاهای تعمیم است. هنگامی که مدل‌های پایه مستقل و متنوع هستند، این روش به طور مؤثری خطاهای پیش‌بینی را کاهش می‌دهد (Mahajan et al. 2023).

نکته‌ی مهم آن است که EL با مدل‌های ترکیبی (Hybrid ML-DL) تفاوت دارد. در EL، چندین مدل جداگانه و مستقل اجرا می‌شوند و نتایج آن‌ها در مرحله‌ی نهایی ادغام می‌شود؛ در حالی که در مدل‌های ترکیبی، معماری‌های ML و DL به صورت درونی یا زنجیروار باهم ترکیب می‌شوند تا یک مدل واحد با ساختار چندلایه ایجاد گردد. به عنوان مثال، در یک مدل ترکیبی ممکن است ویژگی‌ها ابتدا با شبکه‌ی CNN استخراج و سپس با الگوریتم جنگل تصادفی طبقه‌بندی شوند؛ اما در EL، CNN و جنگل تصادفی هر کدام خروجی مستقل دارند و سپس نتایج آن‌ها با رأی‌گیری یا استکینگ ادغام می‌شود. تحت یک قانون تجمیع خاص، رویکردهای گروهی چندین الگوریتم تک طبقه‌بندی‌کننده را ترکیب می‌کنند. هر یک از اعضای گروه به طور مستقل آموزش دیده‌اند تا همان کار را حل کنند و راه‌حلی برای مشکل کلی ارائه دهند. سپس خروجی نهایی گروه با استفاده از یک قانون تجمیع تولید می‌شود که خروجی‌های مدل‌های جداگانه را ترکیب می‌کند. همان‌طور که در شکل یک نشان داده شده است، این رویکرد برای پیش‌بینی به خروجی جمعی مدل‌های فردی متکی است. اگرچه یک مجموعه از چندین مدل پایه

تشکیل شده است، اما به عنوان یک مدل واحد عمل و رفتار می کند ( Hosni et al. 2021; Mahajan et al. 2023). این تکنیک به ویژه در مراقبت های بهداشتی ارزشمند است، جایی که مجموعه داده های متنوع و معیارهای تشخیصی نیاز به عملکرد مدل قابل اعتماد دارند. به عنوان مثال، این ساختار نشان می دهد که داده های آموزشی وارد مجموعه ای از مدل های پایه (مانند درخت تصمیم، شبکه عصبی یا SVM) می شوند، خروجی آن ها ترکیب شده و نتیجه نهایی تولید می شود. در کاربردهای قلبی عروقی، همین ساختار با داده های خاص مانند سیگنال های ECG، تصاویر CT یا داده های بالینی به کار می رود تا مدل نهایی با دقت و پایداری بالاتری عمل کند.

روش های گروهی، مانند بگینگ، بوستینگ یا تقویتی، انباشته و رأی گیری، چندین مدل را برای افزایش دقت و استحکام پیش بینی ترکیب می کنند ( Alotaibi 2025; Hosni et al. 2021; Rane, Choudhary, and Rane 2024). در کاربردهای قلبی عروقی، EL می تواند داده های چندمنبعی (مانند ECG، داده های آزمایشگاهی و سوابق پزشکی) را ادغام کرده و از ترکیب نقاط قوت مدل های مختلف برای کاهش خطاهای تشخیص و افزایش قابلیت تعمیم استفاده کند. به عنوان مثال، ترکیب شبکه های عصبی با درخت های تصمیم در چارچوب EL منجر به بهبود عملکرد در پیش بینی حملات قلبی شده است.

شکل ۱. رویکرد ساختاری یادگیری گروهی



### مرور مطالعات گذشته

این بخش یک نمای کلی از مطالعات قبلی را ارائه می دهد. چندین محقق پیمایش ها و بررسی هایی را در مورد کاربردهای EL و ML در بیماری های قلبی عروقی انجام داده اند و

هدف آن‌ها ارائه راهنمایی عملی در مورد استفاده از این تکنیک‌ها و مدل‌ها در زمینه قلب و عروق و نقشه راه برای تحقیقات آینده است. جدول I خلاصه‌ای از آن‌ها را ارائه می‌دهد. حسنی و همکاران (۲۰۲۱)، یک رویکرد مطالعه نقشه‌برداری سیستماتیک ارائه می‌دهند که کاربرد تکنیک‌های طبقه‌بندی گروهی را در بیماری‌های قلبی عروقی بررسی می‌کند. ابتدا نویسندگان جستجوی کلیدواژه‌ها را در چهار کتابخانه IEEE Xplore، ACM Digital Library، PubMed و Scopus انجام دادند و ۳۵۱ مقاله را بازیابی کردند که بر اساس ۹ سؤال تحقیق مورد تجزیه و تحلیل قرار گرفتند. این مطالعه نشان داد که در اکثر مطالعات CVD، گروه‌های همگن رایج‌ترین روش‌های گروهی هستند که مدل‌هایی مانند درختان تصمیم<sup>۱</sup> (DTs)، ANN ها و طبقه‌بندی کننده‌های بیزی رایج‌ترین تکنیک‌های منفرد هستند. بیشترین نقش مدل‌ها در حیطه تشخیصی بود و روش اعتبارسنجی متقابل<sup>۲</sup> -k fold غالب‌ترین تکنیک برای ارزیابی مدل‌ها بود. همچنین نتایج نشان می‌دهد که مطالعات قبلی به طور جامع از ابزارهای متن‌باز مانند Weka، Python و R Software برای پردازش مدل‌ها استفاده کرده‌اند و برخی مطالعات نیز بهینه‌سازی پارامترهای طبقه‌بندی کننده را بررسی کرده‌اند. این مطالعه بر عملکرد برتر روش‌های گروهی نسبت به طبقه‌بندی کننده‌های تکی تأکید می‌کند (Hosni et al. 2021).

کریتاناونگ و همکاران (۲۰۲۰)، با توجه به استفاده روزافزون از الگوریتم‌های ML در پیش‌بینی CVD، یک فرا تحلیل را بر اساس داده‌های ۱۰۳ مطالعه و ۳،۳۷۷،۳۱۸ نفر ارزیابی کردند. الگوریتم‌های تقویتی و مدل‌های سفارشی عملکرد قوی در پیش‌بینی بیماری CAD داشته‌اند. برای پیش‌بینی سکته مغزی، مدل ماشین‌های بردار پشتیبان<sup>۳</sup> (SVMs)، الگوریتم‌های تقویتی و شبکه‌های عصبی پیچشی<sup>۴</sup> (CNNs) به AUC های تجمعی بالای ۰/۹۰ درصد دست یافته‌اند. این مطالعه نشان داد که مدل‌های تقویتی و SVM عملکرد پیش‌بینی امیدوارکننده‌ای را نشان می‌دهند (Krittanawong et al. 2020).

1. Decision Trees (DTs)

2. Cross-validation

3. Support vector machines (SVMs)

4. Convolutional Neural Network (CNNs)

عزمی و همکاران (۲۰۲۲)، با ارزیابی ۴۱ مقاله، تجزیه و تحلیل مقایسه‌ای جامعی از تکنیک‌های ML برای پیش‌بینی CVD انجام داده‌اند. چالش‌های کلیدی در ادبیات موجود شامل محدودیت در اندازه مجموعه داده، توزیع ناسازگار داده‌ها، عدم همبستگی بالینی، روش‌های ناکافی انتخاب ویژگی، تنظیم ناکافی هایپرپارامتر، استفاده محدود از تکنیک‌های فراابتکاری و گروهی و شکاف در ادغام بالینی است. چندین مدل ML - از جمله DT، RF، بیز ساده<sup>۱</sup> (NB)، رگرسیون لجستیک<sup>۲</sup> (LR)، ANN، K نزدیک‌ترین همسایه<sup>۳</sup> (KNN) و SVM - از نظر دقت پیش‌بینی مورد بررسی قرار گرفته‌اند. در این میان، RF که یک الگوریتم گروهی است بالاترین دقت را نشان داده و پس از آن SVM قرار دارد (Azmi et al. 2022).

تاکور و همکاران (۲۰۲۳)، نقش روش‌های گروهی را در تشخیص قلب و عروق برجسته می‌کنند و بر توانایی آن‌ها در افزایش قابلیت اطمینان و کاهش تشخیص‌های نادرست تأکید می‌کنند. این مطالعه مدل‌های ML و DL را بر اساس کاربردهای تشخیصی آن‌ها طبقه‌بندی می‌کند و نشان می‌دهد که چگونه ادغام چندین مدل دقت پیش‌بینی را بهبود می‌بخشد و نرخ خطا را کاهش می‌دهد. این بر مزیت نسبی رویکردهای گروهی برای دستیابی به نتایج قابل اعتماد در دستیابی به دقت تشخیصی بالا و کاهش خطاها در وظایف پیش‌بینی تأکید می‌کند (Thakur et al. 2023).

در سال‌های اخیر، دو رویکرد محاسباتی نوظهور یعنی یادگیری انتقالی<sup>۴</sup> (TL) و یادگیری فدرال<sup>۵</sup> (FL)، به صورت فزاینده‌ای در پژوهش‌های مرتبط با بیماری‌های قلبی عروقی مورد توجه قرار گرفته‌اند. یادگیری انتقالی اجازه می‌دهد مدل‌های پیش‌آموزش دیده (مثلاً روی مجموعه داده‌های بزرگ تصویری یا سیگنال) برای تسریع همگرایی و بهبود عملکرد در مجموعه داده‌های کوچک‌تر یا خاص حوزه‌ی قلبی مورد

- 
1. Naive Bayes (NB)
  2. Logistic regression (LR)
  3. K-Nearest Neighbors (KNN)
  4. Transfer Learning (TL)
  5. Federated Learning (FL)

«فاین-تیون» قرار گیرند؛ این رویکرد به ویژه در تحلیل تصاویر پزشکی و سیگنال‌های ECG که داده‌های برچسب‌خورده محدود دارند مفید است و مطالعات اخیر نشان می‌دهند که استفاده از چارچوب‌های انتقالی چندمنظوره می‌تواند دقت تشخیصی را در پیش‌بینی CVD به صورت قابل توجهی افزایش دهد (Karthikeyan and others 2024).

از سوی دیگر، یادگیری فدرال به عنوان راه حلی برای چالش‌های حریم خصوصی و محدودیت اشتراک‌گذاری داده‌های بیمارستانی پدیدار شده است؛ در FL مدل‌ها به صورت توزیع‌شده بر روی داده‌های محلی در مراکز مختلف آموزش داده می‌شوند و تنها پارامترها یا وزن‌ها به صورت مرکزی ادغام می‌شوند، بدون آنکه داده‌های خام بیمار تبادل شوند. این رویکرد برای مطالعات قلب و عروق بسیار مناسب است زیرا امکان استفاده از داده‌های چندمرکزی و متنوع را بدون نقض محرمانگی فراهم می‌آورد و مطالعات کاربردی اخیر نشان داده‌اند که FL می‌تواند برای پیش‌بینی آریتمی (مثلاً AF) از سیگنال ECG با حفظ حریم خصوصی داده‌ها عملکرد رقابتی ارائه دهد (Rahman, Karmarkar, and Islam 2024).

در تحقیقی دیگر، چورنی و هوی لینگ (۲۰۲۵) یک مجموعه داده توزیع‌شده غیرمستقل و یکسان برای تشخیص فیبریلاسیون دهلیزی ایجاد کرده‌اند. در تحقیق آن‌ها دو خط پایه (یک طبقه‌بندی‌کننده متمرکز و یک طبقه‌بندی‌کننده فدرال) آموزش داده شده‌اند و عملکرد طبقه‌بندی‌کننده‌هایی که قبل از آموزش فدرال روی داده‌های مشترک از قبل آموزش دیده‌اند، مقایسه شده‌اند. نتایج آن‌ها نشان‌دهنده این است که طبقه‌بندی‌کننده متمرکز از همه مدل‌های دیگر بهتر عمل کرده و مدل فدرال عملکرد مناسبی را کسب نکرده است. یافته‌های کلی این تحقیق نشان می‌دهد که اشتراک‌گذاری جزئی داده‌ها در ایجاد مدل‌های یادگیری ماشین فدرال ممکن است عملکرد را به طور قابل توجهی بهبود بخشد (Chorney and Ling 2025).


در عمل، ترکیب TL و FL (مثلاً فاین-تیون کردن مدل‌های پیش‌آموزش دیده به صورت محلی در هر مرکز و ادغام پارامترها به صورت فدرال) یک جهت پژوهشی بسیار

امیدوارکننده برای افزایش تعمیم‌پذیری مدل‌ها و هم‌زمان حفظ حریم خصوصی و قابلیت همکاری میان بیمارستان‌ها فراهم کرده است (Alreshidi et al. 2024).

### روش‌شناسی تحقیق

تکنیک‌ها، الگوریتم‌ها و مدل‌های متعددی برای تشخیص، پیش‌بینی و طبقه‌بندی بیماری‌های قلبی عروقی به کار گرفته شده است. این مدل‌ها در درجه اول بر اساس اصول EL و ML/DL هستند. از آنجا که روش فراترکیب یک رویکرد کیفی است که به‌طور هم‌زمان یافته‌های کمی و کیفی را بررسی و تلفیق می‌کند، می‌تواند به‌عنوان ابزاری مؤثر برای شناسایی و تحلیل این مدل‌ها و تکنیک‌ها عمل کند. در این مطالعه از روش فراترکیب برای استخراج و تحلیل مدل‌ها و تکنیک‌های EL در حوزه بیماری‌های قلبی عروقی استفاده شده است. این پژوهش از نظر ماهیت کاربردی بوده و از نظر گردآوری داده‌ها در هر دو دسته مطالعات کیفی و کمی قرار می‌گیرد. برای شناسایی و استخراج تکنیک‌ها و مدل‌های مختلف EL مورد استفاده در مدیریت CVD ها، رویکرد فراترکیب هفت مرحله‌ای پیشنهادشده توسط سندلوسکی و باروسو<sup>۱</sup> (2007) (Sandelowski, Barroso, and Voils 2007) به‌عنوان چارچوب تحقیق پذیرفته شده است. مراحل این روش در شکل دوم نشان داده شده است.

شکل ۲. الگوی ۷ مرحله‌ای رویکرد فراترکیب سندلوسکی و باروسو (۲۰۰۷)



اولین گام در رویکرد فراترکیب شامل تعریف سوالات پژوهشی است که هدف مطالعه پرداختن به آنها است. سوالات پژوهش که در بخش مقدمه مطرح شده و مبنای این

1. Sandelowski and Barroso (2007)

رویکرد است، به شرح زیر است:

۱. مدل‌ها و تکنیک‌های EL بکار گرفته شده در مدیریت بیماری‌های قلبی عروقی در چند دسته تقسیم‌بندی می‌شوند؟

۲. کدام مدل‌های EL بیشترین دقت و عملکرد را در هر دسته از مدیریت CVD ها داشته‌اند؟

۳. محدودیت‌ها و چالش‌های مربوط به مدل‌های EL در مدیریت CVD ها چیست؟

۴. چگونه مدل‌ها و تکنیک‌های EL در مدیریت CVD ها اعتبارسنجی می‌شوند؟

۵. برای استفاده از مدل‌های در مدیریت‌ها داده‌ها و ویژگی‌های یک مجموعه داده با چه تکنیک‌ها و روش‌هایی پیش پردازش و مهندسی می‌شوند؟

در گام دوم رویکرد فراترکیب، پایگاه وب آو ساینس به‌عنوان منبع اصلی برای مرور نظام‌مند ادبیات علمی انتخاب شد. سه کلمه کلیدی اصلی که برای انجام جستجوها استفاده شدند شامل «Cardiovascular Diseases»، «Machine Learning» و «Deep Learning» از سال ۲۰۱۰ تا پایان سال ۲۰۲۴ بودند. دلیل استفاده از اصطلاحات «یادگیری ماشین» و «یادگیری عمیق» به جای «یادگیری گروهی» بر اساس اهداف انجام این مطالعه بود. اصطلاحات جستجو به صورت زیر فرموله شدند:

- TS= (“Cardiovascular Diseases” AND “Machine Learning”)
- TS= (“Cardiovascular Diseases” AND “Deep Learning”)

در مرحله سوم، فرآیند غربالگری و انتخاب مقالات مرتبط انجام شد. انتخاب مقالات بر اساس معیارهای دقیق و از پیش تعریف شده انجام شده است که جزئیات آن در جدول یک ارائه شده است. سپس مقالات استخراج شده در پنج مرحله ارزیابی عنوان، بررسی چکیده، بررسی دسترسی، ارتباط محتوا و درنهایت ارزیابی کیفیت روش شناختی مورد ارزیابی قرار گرفتند. این فرآیند تضمین می‌کند که درنهایت فقط مطالعات معتبر و مرتبط در تحقیق گنجانده می‌شوند.

جدول ۱. معیارهای ورود مقالات

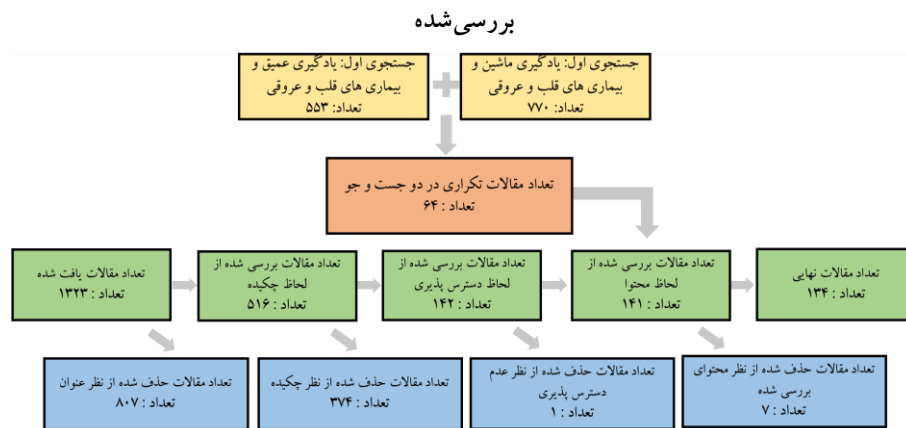
معیارهای خروج	شرایط ورود	معیارهای
مقالاتی که به زبان انگلیسی نوشته نشده‌اند	مقالات نوشته شده به زبان انگلیسی	زبان مقالات
مقالات منتشر شده قبل از سال ۲۰۱۰	مقالات منتشر شده بین سال‌های ۲۰۱۰ تا ۲۰۲۴	بازه زمانی انتشار
مطالعات غیر مرتبط با موضوع مشخص شده	پیش‌بینی و تشخیص بیماری‌های قلبی عروقی بر اساس EL	موضوع تحقیق
مطالعات خارج از محدوده مشخص شده	شناسایی مدل‌ها، تکنیک‌ها و الگوریتم‌های EL به کاررفته در تشخیص، پیش‌بینی، طبقه‌بندی و شناسایی بیماری‌های قلبی عروقی.	دامنه تحقیق

در طول فرآیند غربالگری مقاله، ۷۷۰ مقاله از پرس و جو اول و ۵۵۳ مقاله از پرس و جو دوم بازیابی شد که ۶۴ مقاله بین این دو همپوشانی داشتند. برای شناسایی مقالات تکراری، عناوین هر دو جستجو در ابتدا به‌طور جداگانه بررسی شدند. قبل از رفتن به مرحله دوم (بررسی چکیده)، مقالات تکراری و همپوشانی شناسایی و حذف شدند. در این مرحله ۵۱۶ مقاله بر اساس عناوین آن‌ها مرتبط تلقی شدند. مرحله دوم که شامل بررسی چکیده مقالات بود، منجر به انتخاب ۱۴۲ مقاله شد. در مرحله سوم، در مورد دسترسی به مقالات، ۱۴۱ مقاله در دسترس و به‌طور کامل استخراج شد. سپس این مقالات از نظر ارتباط محتوایی مورد بررسی قرار گرفتند و در نهایت ۱۳۴ مقاله بر اساس اهداف و سؤالات پژوهش در مرحله چهارم انتخاب شدند. برای بررسی مرحله نهایی - ارزیابی کیفیت روش شناختی - جهت افزایش دقت و اطمینان از کیفیت روش شناختی مقالات نهایی، ارزیابی کیفیت بر اساس دستورالعمل و چک‌لیست رسمی JBI انجام شد. این چک‌لیست شامل معیارهایی چون وضوح سؤال پژوهش، کفایت روش نمونه‌گیری، شفافیت طراحی مطالعه، تحلیل داده‌ها و کنترل سوگیری است. تنها مقالاتی که امتیاز کافی بر اساس معیارهای JBI کسب کردند در تحلیل نهایی باقی ماندند. استفاده از این ابزار که یکی از پرکاربردترین و معتبرترین ابزارهای ارزیابی کیفیت در مطالعات مروری نظام‌مند است،

ارزیابی جامع مدل‌های یادگیری گروهی (EL) در مدیریت بیماری‌های ...؛ زاهدیان نژاد و همکاران | ۶۱

موجب افزایش اطمینان به اعتبار و تکرارپذیری یافته‌ها گردید فرآیند غربالگری پنج مرحله‌ای در شکل سوم نشان داده شده است.

شکل ۳. فرآیند غربالگری مقالات استخراج شده از پایگاه داده وب آو ساینس از نظر پنج مرحله



جدول دوم مراحل هفت گانه روش فراترکیب را همراه با تعریف مختصر هر مرحله و نحوه اجرای آن در این پژوهش نشان می‌دهد.

جدول ۲. مراحل هفت گانه فراترکیب سندلوسکی و باروسو (۲۰۰۷) و نحوه به‌کارگیری در این

#### پژوهش

مرحله فرا ترکیب	توضیح مفهومی	نحوه اجرا در پژوهش حاضر (کاربرد در EL و CVD)
۱. شناسایی هدف و سؤال پژوهش	تعیین دقیق هدف و سؤالات پژوهش برای تمرکز در فرایند فراترکیب	سؤالات اصلی درباره شناسایی، طبقه‌بندی، ارزیابی و چالش‌های مدل‌های EL در مدیریت CVD ها در ابتدای پژوهش تعریف شد.
۲. جستجوی نظام‌مند مطالعات	انتخاب پایگاه‌ها و کلیدواژه‌ها برای گردآوری شواهد مرتبط	پایگاه Web of Science با کلیدواژه‌های "Cardiovascular Diseases" AND "Machine Learning" و "Deep Learning" برای بازه ۲۰۱۰-۲۰۲۴ استفاده شد.
۳. غربالگری و انتخاب مطالعات	تعیین معیارهای ورود و خروج و حذف موارد تکراری یا غیرمرتبط	معیارهای ورود و خروج در جدول ۱ آورده شد. ۱۳۴ مقاله مرتبط پس از غربالگری پنج مرحله‌ای انتخاب شدند.

نحوه اجرا در پژوهش حاضر (کاربرد در EL و CVD)	توضیح مفهومی	مراحل فرا ترکیب
از هر مقاله نوع مدل EL، الگوریتم‌ها، داده‌های ورودی (ECG، CT، داده‌های بالینی)، هدف و نتایج عملکرد استخراج شد.	شناسایی و استخراج مفاهیم کلیدی از مطالعات منتخب	۴. استخراج داده‌ها و یافته‌ها
مدل‌ها و تکنیک‌های EL در چهار گروه اصلی (تشخیص، پیش‌بینی، طبقه‌بندی و شناسایی) طبقه‌بندی شدند.	مقایسه مفاهیم مشترک و ایجاد طبقات معنایی	۵. مقایسه و طبقه‌بندی یافته‌ها
یافته‌ها از مطالعات کمی و کیفی ترکیب شدند تا الگوی مفهومی ارتباط میان EL، ML/DL و کاربردهای CVD استخراج شود.	تلفیق یافته‌ها و تولید مفاهیم یا چارچوب‌های جدید	۶. ترکیب و یکپارچه‌سازی مفاهیم
چارچوب مفهومی حاصل، نشان‌دهنده نقش مدل‌های EL در بهبود دقت و نتایج در مدیریت CVD است.	تبیین چارچوب نهایی و ارائه پیامدهای علمی و عملی	۷. ارائه و تفسیر نتایج نهایی

در نتیجه، ۱۳۴ مقاله که معیارهای ارتباط محتوایی را داشتند، به‌عنوان انتخاب نهایی در نظر گرفته شدند. یافته‌های فراترکیب نشان داد که انواع مدل‌ها و تکنیک‌های EL در کنار رویکردهای ML و DL در مدیریت بیماری‌های قلبی عروقی به کار گرفته شده است. این مدل‌ها و تکنیک‌ها در ۱۳۴ مقاله منتخب شناسایی شدند. در مرحله‌ی تحلیل داده‌ها، کلیه‌ی اطلاعات استخراج شده از ۱۳۴ مقاله‌ی منتخب شامل نوع بیماری قلبی عروقی، منبع و نوع داده‌ها، نام و نوع مدل‌های EL، روش‌های پیش‌پردازش داده و مهندسی ویژگی، معیارهای ارزیابی عملکرد و محدودیت‌های مطالعات در یک فایل اکسل ذخیره و کدگذاری شدند.

سپس با استفاده از روش تحلیل محتوا، داده‌های کیفی، کمی و مفهومی موردبررسی قرار گرفتند. در طی این فرآیند، الگوهای مفهومی تکرارشونده میان مقالات شناسایی و بر اساس هدف و ماهیت هر مطالعه در قالب چهار حوزه‌ی اصلی مدیریت CVD شامل پیش‌بینی<sup>۱</sup>، تشخیص<sup>۲</sup>، طبقه‌بندی<sup>۱</sup> و شناسایی<sup>۲</sup> سازمان‌دهی و دسته‌بندی شدند. این

1. Prediction
2. Diagnosis

دسته‌بندی در مرحله‌ی نهایی فراترکیب و بر اساس کدگذاری محوری (روش تحلیل محتوا با استفاده از شمارش فراوانی) انجام گرفت تا الگوهای غالب در کاربرد مدل‌های EL در حوزه‌ی CVD شناسایی شود. نتایج این فراترکیب و دسته‌بندی آن‌ها در جدول سوم ارائه شده است.

### یافته‌های فراترکیب

با تمرکز بر هدف اصلی مطالعه، یعنی بررسی نقش الگوریتم‌های یادگیری گروهی در مدیریت CVD ها، یافته‌ها نشان دادند که مدل‌های EL مانند جنگل تصادفی، AdaBoost، Gradient Boosting، XGBoost و Stacking Ensemble در بسیاری از مطالعات به صورت مستقل یا در ترکیب با مدل‌های ML و DL به کار رفته‌اند. این مدل‌ها به دلیل قابلیت ادغام تصمیم‌گیری چند الگوریتم، کاهش واریانس و مقابله با داده‌های نویزی و نامتوازن، در مقایسه با مدل‌های منفرد عملکرد دقیق‌تر و پایدارتری ارائه داده‌اند. به طور خاص، در حوزه‌های پیش‌بینی و تشخیص بیماری‌های قلبی، مدل‌های XGBoost و جنگل تصادفی بیشترین فراوانی و بالاترین دقت را ثبت کرده‌اند. این یافته‌ها تأیید می‌کنند که رویکرد EL نه تنها به عنوان یک روش مکمل، بلکه به عنوان یکی از چارچوب‌های اصلی در طراحی سیستم‌های هوشمند تشخیص و پیش‌بینی CVD مطرح است.

- 
1. Classification
  2. Identification

جدول ۳. دسته‌بندی مدیریت بیماری‌های قلبی عروقی مبتنی بر مدل‌های یادگیری بر اساس یافته‌های روش فراترکیب.

مراجع	زیرمجموعه‌ها	دسته‌بندی مدیریت CVD ها
(Ahamed, Koli, et al. 2022; Ahamed, Mir, and Chishti 2022; Al-Yarimi 2022; Alfaidi et al. 2022; Anbumani and Kaniyaiah 2024; Bertsimas et al. 2022; Bhatt et al. 2023; Datta et al. 2022; Dinh et al. 2019; Dritsas and Trigka 2023; Dubey, Sinhal, and Sharma 2022; Ghosh et al. 2021; Guo et al. 2020; Hassan et al. 2024; Henni et al. 2023; Husain et al. 2023; Islam et al. 2022; Kim et al. 2021; Lacson et al. 2019; Lambay and Mohideen 2024; Lee et al. n.d.; Li et al. 2021; Lo, Fujita, and Pai 2016; Lv et al. 2021; Muhammad et al. 2023; Najim and Nasri 2024; Nissa et al. 2024; Noor et al. 2023; Ohashi et al. 2023; Ospina et al. 2023; Ott et al. 2024; Pan et al. 2022; Rahim et al. 2021; Sajid et al. 2021, 2022; Samaras et al. 2023; Saputra et al. 2023; Sheeba et al. 2022; Sherazi, Zheng, and Lee 2023; Sinha et al. 2023; Stepanyan et al. 2022; Subramani et al. 2023; Tachie et al. 2023; Tiwari et al. 2022; Tolentino et al. 2020; Torres et al. 2023; Tsai et al. 2022; Varale and Thakre 2020)	پیش‌بینی بیماری‌های قلبی عروقی با استفاده از مدل‌های EL	پیش‌بینی (۷۵ مقاله)
An et al. 2021; Barriada et al. 2022; Bertsimas et al. ) 2022; Chun et al. 2021; Du et al. 2023; Hossain, Uddin, and Khan 2021; Islam et al. 2022, 2023; Lee et al. 2024; Mondal et al. 2024; Oanh and Tung 2022; et al. B. A. S. Oliveira et al. 2023; Paul Navarrete 2022; Reddy et al. 2021; Sozen et al. 2023; Teresa (Garcia-Ordas et al. 2023; You et al. 2023	افزایش پیش‌بینی خطر CVD	
Ahn et al. 2021; Daghistani et al. 2019; Hu et al. ) 2020; Karboub and Tabaa 2022; M. Oliveira et al. (2023	بهینه‌سازی منابع بیمارستان و مدیریت بیمار	
Chicco and Jurman 2020; Hassan et al. 2024; ) Moreno-Sanchez 2023; Tadege, Tegegne, and Dessie (2024	پیش‌بینی پیامدهای بقا برای بیماران CVD	
Baghdadi et al. 2023; Chalapathi et al. 2024; ) Dhanka, Bhardwaj, and Maini 2023; Elvas et al. 2023; Husain et al. 2023; Ibarra et al. 2022; Jiang et	تشخیص و تشخیص زودهنگام	تشخیص (۳۰ مقاله)

مراجع	زیرمجموعه‌ها	دسته‌بندی مدیریت CVD ها
al. 2023; Kokol et al. 2021; Moskaleva et al. 2022; Najafi et al. 2023; Ogunpola et al. 2024; Oyewola, (Dada, and Misra 2024; Sapra et al. 2023	بیماری‌های قلبی عروقی با استفاده از مدل‌های EL	
Aarthy and Iqbal 2024; Al-Absi et al. 2022; Ardeti et al. 2022; Balaha et al. 2022; Divya, Shadrach, and Padmaja 2023; Latha et al. 2022; Lilda, Jayaparvathy, and Balaji 2022; Pandey et al. 2023; Ribeiro et al. 2024; Sharma et al. 2020; Shchetinin and Glushkova 2022; Simegn, Gebeyehu, and Degu 2022; Yang et al. (2018; Zafar et al. 2023	تشخیص و تشخیص بیماری‌های قلبی عروقی با استفاده از PPG, ECG و PCG تصویربرداری	
Boulkaboul et al. 2024; Hassaballah et al. 2023; He ) et al. 2021; Kumar and Kumar 2023; Pavic et al. 2023; Xiang et al. 2023; Yongcharoenchaiyasit et al. (2023	طبقه‌بندی CVD ها و تشخیص زود هنگام با استفاده از مدل‌های EL	طبقه‌بندی (۱۸ مقاله)
Eleyan and Alboghbaish 2024; Enad and ) Mohammed 2024; Essa and Xie 2021; Lee et al. 2021; Maheshwari et al. 2023; Wu et al. 2021; Yadav (et al. 2020; Zhanquan et al. 2022; Zou et al. 2022	طبقه‌بندی ECG و سیگنال‌های قلبی با استفاده از مدل‌های EL و DL	
Guarneros-Nolasco et al. 2021; Gutierrez-Esparza et al. 2023; Hsu 2018; Kirboga and Kucuksille 2023; Kumar et al. 2021; Louridi, Douzi, and El Ouahidi (2021; Tadesse et al. 2021; Wu et al. 2022	شناسایی عوامل خطر بیماری‌های قلبی عروقی	شناسایی (۹ مقاله)
(Desai et al. 2022; Li et al. 2020; Maqsood et al. 2021)		دسته‌بندی دیگر (۳ مقاله)

زیر بخش‌های زیر تجزیه و تحلیل جامعی از نحوه استفاده از مدل‌های EL و ML/DL برای مدیریت CVD ها ارائه می‌دهند. همان‌طور که نتایج در جدول سوم در بالا نشان می‌دهد، نقش این مدل‌ها در مدیریت بیماری‌های قلبی عروقی به چهار حوزه اصلی دسته‌بندی می‌شوند: پیش‌بینی، تشخیص، طبقه‌بندی و شناسایی. هر دسته از زیرمجموعه‌های خاصی

تشکیل شده است که کاربردهای متنوع و تعداد مطالعات متمرکز بر هر جنبه را برجسته می‌کند.

### الف) مدیریت بیماری‌های قلبی عروقی

پیش‌بینی بیماری‌های قلبی عروقی: نقش محوری در مدیریت پیشگیرانه بیماری‌های قلبی عروقی ایفا می‌کند و ۷۵ مقاله به این دسته اختصاص داده شده است. در این میان، تمرکز قابل توجهی بر پیش‌بینی CVD با استفاده از مدل‌های EL است، جایی که روش‌های گروهی مانند تقویت گرادیان شدید<sup>۱</sup> (XGBoost)، RF و تقویت‌کنندگی وفقی<sup>۲</sup> (AdaBoost) دقت پیش‌بینی را افزایش می‌دهند. افزایش پیش‌بینی خطر بیماری‌های قلبی عروقی یکی دیگر از زیرمجموعه‌های حیاتی است که هدف آن شناسایی افراد در معرض خطر بالا قبل از شروع شرایط شدید است. علاوه بر این، بهینه‌سازی منابع بیمارستانی و مدیریت بیمار از طریق مدل‌های پیش‌بینی برای بهبود ارائه مراقبت‌های بهداشتی، کاهش هزینه‌ها و تخصیص کارآمد منابع پزشکی مورد توجه قرار می‌گیرد. یکی دیگر از حوزه‌های کلیدی، پیش‌بینی نتایج بقا برای بیماران CVD است، جایی که مدل‌ها پیش‌آگهی بیمار را پیش‌بینی می‌کنند و به برنامه‌ریزی درمان شخصی کمک می‌کنند و در نتیجه مراقبت طولانی‌مدت از بیمار را بهبود می‌بخشند.

تشخیص بیماری‌های قلبی عروقی: تشخیص به‌موقع و دقیق برای مدیریت مؤثر بیماری‌های قلبی عروقی ضروری است و ۳۰ مقاله بر این دسته متمرکز شده است. تشخیص و تشخیص زودهنگام CVD با استفاده از مدل‌های EL برای شناسایی علائم اولیه و اطمینان از مداخلات سریع تمرکز اصلی مقالات این حوزه بوده‌اند. روش‌های مبتنی بر سیگنال‌های ECG، فوتوپلتیسموگرافی<sup>۳</sup> (PPG)، صوتی قلب<sup>۴</sup> (PCG) و تصویربرداری به استاندارد

---

1. eXtreme Gradient Boosting (XGBoost)

2. Adaptive Boosting (AdaBoost)

3. Photoplethysmogram (PPG)

4. Phonocardiogram (PCG)

برای تشخیص ناهنجاری‌های ساختاری و عملکردی قلب تبدیل شده‌اند. استفاده از مدل‌های EL همراه با پردازش سیگنال زیست پزشکی، دقت بالاتر در تشخیص را بدون احتمال تشخیص اشتباه تضمین کرده است.

طبقه‌بندی بیماری‌های قلبی و عروقی: طبقه‌بندی دقیق CVD ها برای تعیین مسیرهای درمانی مناسب بسیار مهم است، همان‌طور که در ۱۸ مقاله منعکس شده است. زیر طبقه‌بندی شامل طبقه‌بندی بیماری‌های قلبی عروقی و تشخیص زودهنگام با استفاده از مدل‌های EL است که شرایط مختلف قلبی عروقی را با دقت بالا طبقه‌بندی می‌کند. علاوه بر این، کاربرد مدل‌های DL و EL در طبقه‌بندی ECG و سیگنال‌های قلبی در حال افزایش است و بهترین استراتژی را برای شناسایی و تجزیه و تحلیل الگوهای پیچیده سیگنال‌های زیست پزشکی به دست آورده است. روش‌های طبقه‌بندی برای تمایز بین بیماری‌های قلبی مانند آریتمی و بیماری‌های ایسکمیک قلبی ضروری هستند تا امکان درمان‌های انتخابی تر فراهم شود.

شناسایی بیماری‌های قلبی عروقی: شناسایی عوامل خطر مرتبط با بیماری‌های قلبی عروقی برای پیشگیری و استراتژی‌های درمان ضروری است. این دسته که در ۹ مقاله پوشش داده شده است، بر شناسایی عوامل خطر CVD با استفاده از مدل‌های پیشرفته ML و EL تأکید دارد. با شناسایی عوامل اصلی تعیین کننده (عوامل خطر) - مانند فشار خون بالا، دیابت و غیره - این مدل‌ها به پزشکان CVD در شروع استراتژی‌های پیشگیرانه و تجویز تغییرات سبک زندگی برای افراد در معرض خطر کمک می‌کنند.

#### ب) مدل‌های EL، ML و DL در مدیریت CVD ها

این زیربخش یک نمای کلی از مدل‌ها، روش‌ها و الگوریتم‌هایی را که معمولاً در مطالعات مختلف برای مدیریت CVD ها استفاده شده‌اند، با تأکید ویژه بر روش‌های EL، تکنیک‌های کلاسیک ML و معماری‌های DL ارائه می‌دهد. جدول سوم تمام این مدل‌ها و

تکنیک‌های مورد استفاده در مقالات را به همراه فراوانی آن‌ها نشان می‌دهد.

مدل‌های یادگیری گروهی (EL): تجزیه و تحلیل یافته‌ها نشان می‌دهد که مدل‌های EL یکی از پرکاربردترین رویکردها هستند. در بین روش‌های تقویتی، XGBoost بیشترین (۵۰ بار) و پس از آن تقویت گرادیان<sup>۱</sup> (GB) (۳۵ بار) و AdaBoost (۲۷ بار) قرار دارند. ماشین تقویت کننده گرادیان سبک<sup>۲</sup> (LightGBM) (۱۲ بار) و تقویت گرادیان دسته‌بندی شده<sup>۳</sup> (CatBoost) (۹ بار) مدل‌های جدیدی هستند که محبوبیت فزاینده‌ای دارند که نشان‌دهنده علاقه بیشتر به روش‌های تقویتی کارآمد و مقیاس پذیر است. انواع مدل‌های تقویتی کمتر رایج، از جمله درخت افزایش گرادیان<sup>۴</sup> (۵ بار) و Adaptive Boosting KNN (۱ بار)، کاربرد گسترده آن‌ها را نشان می‌دهد. روش‌های بگینگ، اگرچه کمتر از بوستینگ رایج هستند، اما هنوز هم نقش مهمی دارند. مدل Bagging Classifier (۱۴ بار) و مدل‌های دیگری مانند Bagged Tree و Bagging with Logistic Regression بیشترین تکرار را داشته‌اند. قابل ذکر است که مدل RF (۱۱۱ بار) به‌طور کلی پرکاربردترین مدل گروهی است که استحکام و تطبیق پذیری آن را در مطالعات نشان می‌دهد. سایر تکنیک‌های گروهی، مانند درختان اضافی<sup>۵</sup> (ETs) (۱۱ بار)، پشته‌ای (۷ بار) و طبقه‌بندی کننده‌های رأی‌گیری<sup>۶</sup> (۹ بار) نیز اهمیت ترکیب چندین مدل را برای افزایش عملکرد پیش‌بینی نشان می‌دهند.

مدل‌های یادگیری ماشین (ML) سنتی و کلاسیک: در میان مدل‌های سنتی، SVM‌ها بسیار محبوب هستند و در ۹۴ مقاله ظاهر شده‌اند و اثربخشی آن‌ها را در طبقه‌بندی داده‌های با ابعاد بالا منعکس می‌کند. در عین حال، رگرسیون لجستیک (۶۹ بار) یک مدل پیش فرض

- 
1. Gradient Boosting (GB)
  2. Light Gradient Boosting Machine (LightGBM)
  3. Categorical Gradient Boosting (CatBoost)
  4. Gradient Boosting Tree
  5. Extra Trees (ETs)
  6. Voting Classifiers

برای طبقه‌بندی باینری است. مدل‌های مبتنی بر درخت مانند DT (54 بار) و RF (111 بار) به دلیل قابلیت تفسیر و تطبیق‌پذیری موردعلاقه بسیاری از مقالات بوده‌اند. مدل‌های KNN (56 بار) و بیز ساده (46 بار) نیز به دلیل سادگی بودنشان به خوبی مورد استناد قرار گرفته‌اند. مدل‌های بهینه‌سازی مانند طبقه‌بندی کننده‌های نزولی گرادیان تصادفی<sup>۱</sup> (SGDC) (۱۳ بار) و الگوریتم‌های ژنتیک (۱ بار) نیاز به به کارگیری مدل‌هایی را نشان می‌دهند که بتوانند مجموعه داده‌های بزرگ را با همگرایی سریع تر مدیریت کنند. مدل‌های تجزیه و تحلیل بقا که کمتر مورد استفاده مطالعات قرار گرفته‌اند، مانند جنگل‌های بقا تصادفی و رگرسیون کاکس، اهمیت داده‌های زمانی را در حوزه‌های خاص قلب و عروق نشان می‌دهند. با پیشرفت مدل‌های جدید ML مانند مدل‌های یادگیری ماشین کوانتومی<sup>۲</sup> (QML) همچون SVC کوانتومی (QSVC ۲ بار) و شبکه‌های عصبی کوانتومی<sup>۳</sup> (QNNs ۱ بار) تلاش‌های اولیه برای استفاده از محاسبات کوانتومی برای ML را نشان می‌دهند. در نهایت، مدل‌های خوشه‌بندی، مانند K-means (2 بار) و خوشه‌بندی سلسله مراتبی (۱ بار)، در رویکردهای یادگیری بدون نظارت و همچنین روش‌های طبقه‌بندی مبتنی بر فازی (۱ بار) نقش مدل‌های کلاسیک خوشه‌بندی و طبقه‌بندی را در رسیدگی به CVD ها را در بعضی از مقالات نشان می‌دهند.

مدل‌های یادگیری عمیق (DL): مدل‌های DL تنوع قابل توجهی را در مطالعات نشان می‌دهند. شبکه‌های عصبی مصنوعی (ANNs) به طور کلی با ۷۵ بار تکرار پرکاربردترین مدل‌ها و شبکه‌های مورد استفاده هستند و انواع آن‌ها مانند پرسپترون چندلایه<sup>۴</sup> (MLP) (۲۲ بار) و شبکه‌های عصبی پس انتشار<sup>۵</sup> (BPNN) (۴ بار) کاربرد گسترده‌ای در مقالات داشته‌اند. CNN ها و معماری‌های آن‌ها، مانند ResNet (9 بار)، MobileNet (4 بار) و

---

1. Stochastic gradient descent classifiers (SGDC)  
2. Quantum machine learning (QML)  
3. Quantum neural networks (QNNs)  
4. Multi-Layer Perceptron (MLP)  
5. Backpropagation

InceptionV3 (1 بار)، کاربرد قابل توجهی در وظایف پردازش تصویر و سیگنال را ایفا کرده‌اند. از بین شبکه‌های عصبی بازگشتی<sup>۱</sup> (RNNs)، شبکه‌های حافظه طولانی کوتاه‌مدت<sup>۲</sup> (LSTM) (11 بار) استفاده شده است، در حالی که انواع آن مانند BiLSTM (6 بار) و واحد بازگشتی دروازه‌ای<sup>۳</sup> (GRU) (۲ بار) برای داده‌های متوالی استفاده شده‌اند. قابل ذکر است که یادگیری انتقالی<sup>۴</sup> (TL) و معماری‌های پیشرفته، اگرچه کمتر تکرار شده‌اند اما در برخی مطالعات به خاطر اثرپذیری آن‌ها در محیط‌های دارای منابع محدود مورد استفاده قرار گرفته‌اند.

جدول ۴: مدل‌ها و تکنیک‌های یادگیری مورد استفاده در مدیریت بیماری‌های قلبی عروقی بر اساس سه دسته اصلی همراه با فراوانی آن‌ها.

نام الگوریتم یا مدل و تعداد فراوانی آن‌ها در مقالات	دسته‌بندی کلیه مدل‌ها، تکنیک‌ها و الگوریتم‌های مورد استفاده
<b>مدل‌های یادگیری گروهی (EL)</b>	
XGB (50), Gradient Boosting (35), ADABOOST (27), LGBM (13), Catboost (9), Gradient Boosting Tree (GBT) (5), Boosting (5), Adaptive Boosting (2), Gradient Boost Decision Tree (GBDT) (3), Adaptive Boosting KNN (1), Adaptive Boosting-Tree (1), Boosted generalized linear model (BoGLM) (1), AdaBoostM1 with LR (1), AdaBoostM1 with decision stump (DS) (1), Boosted tree (1), LogitBoost (1), Catboost-tuned (1), Stochastic Gradient Boosting (SGB) <sup>(۱)</sup>	مدل‌های تقویتی (GBMs) (۱۳۸ بار)
RF (111), Bagging Classifier (BaggC) (14), Bagged tree (BT) (3), Bagging_QSVM (1), Bagging with LR (1), Bagging with REPTree (1),	مدل‌های بگینگ (۱۳۱ بار)
Ensemble Classifier (18), Extra Trees (11), Stacking Algorithm (7), Soft and hard voting (5), Voting (4), Regression Ensemble (1), Ensemble Deep Learning (EDL) (1), Weighted Ensemble Model (WEM) (1),	سایر مدل‌های گروهی (۴۹ بار)

1. Recurrent Neural Networks (RNNs)
2. Long short-term memory (LSTM)
3. Gated Recurrent Unit (GRU)
4. Transfer Learning (TL)

نام الگوریتم یا مدل و تعداد فراوانی آن‌ها در مقالات	دسته‌بندی کلیه مدل‌ها، تکنیک‌ها و الگوریتم‌های مورد استفاده
<b>مدل‌های یادگیری ماشینی سنتی و کلاسیک (ML).</b>	
LR (69), Linear regression (9), Ridge Classifier (2), Elastic / Elated-Net (2), Multiple / Multivariate Linear Regression (MLR) (2), LogisticRegressionCV (LogRegCV) (1), least squares (LS) boost (1), Flexible discriminant analysis (FDA) (1), Cox proportional hazard (CPH) (1), Generalized additive model (GAM) (1), Lasso (1), Generalized linear model (GLM) (1), Binomial logistic regression (BLR) (1), Multivariate logistic regression (MLR) (1), Multivariate adaptive regression spline (MARS) (1),	مدل‌های رگرسیون (۹۴ بار)
DT (54), Classification & regression trees (CART) (3), Rotation Forest (RotF) (2), logistic model tree (J48) (2), K-best algorithm (1), Optimal classification trees (OCT) (1), XGBRF (1), Conditional inference tree (CIT) (1), Fine tree (1), Random tree (RT) (1),	طبقه بندی درخت (۶۸ بار)
SVM/SVC (81), Linear SVM (LSVM) (4), Sequential minimal optimization (SMO) (2), GaussianProcessClassifier (GauPro) (1), OneVsRestClassifier (OvsR) (1), Nu svc (1), Gaussian radial kernel SVM (1), SVM RBF / Support Vector Classifier with Radial Basis Function kernel (SVCR) (1), Adaptive binary tree-based SVM (1), Passive Aggressive (1),	طبقه بندی بردار پشتیبان (SVC) (۹۴ بار)
Naïve Bayes (NB) (32), GaussianNB (GauNB) (8), Bayesian Network (3), Bayesian generalized linear model (BGLM) (1), Multinomial naive bayes (1), Bernoulli naive bayes (1),	شبکه‌های بیزین (۴۶ بار)
KNN (56), JRip (1), One Rule (1), Instance-based classifier (IBk) (1),	نزدیک‌ترین همسایه‌ها (۵۹ بار)
Stochastic Gradient Descent Classifier (SGDC) (13), Linear Discriminant Analysis (LDA) (7), Passive Aggressive Classifier (PAC) (1), Quadratic discriminant analysis (QDA) (1), SGDCClassifierMod (SGDCMod) (1) Modified Artificial Plant Optimization (MAPO) (1), Genetic Algorithm (1),	مدل‌های بهینه سازی (۲۵ بار)
Random Survival Forest (RSF) (3), Extra Survival Trees (1), Survival SVM (SSVMs) (1), Survival Tree (1), Semi parametric (cox) survival (1), Discrimination and Calibration of Cox regression (1), Cox regression (1),	مدل‌های تجزیه و تحلیل بقا (۹ بار)

نام الگوریتم یا مدل و تعداد فراوانی آن‌ها در مقالات	دسته‌بندی کلیه مدل‌ها، تکنیک‌ها و الگوریتم‌های مورد استفاده
K-means (2), Hierarchical Self-Calibrating (HSC) (1), Markov statistics nonparametric techniques (1), Case-based reasoning (CBR) (1), DBSCAN (1), Mean Shift Clustering (1), Hierarchical Clustering (1), K-modes (1), Kstar (1) Fuzzy-based classification methods (1),	خوشه بندی و مدل‌های فازی (۱۱ بار)
Quantum SVC (QSVC) (2), Quantum NNs (QNNs) (1), Hybrid quantum multi-layer perceptron (HWMLP) algorithm (1),	یادگیری ماشین کوانتومی (QML) (۴ بار)
<b>مدل‌های یادگیری عمیق (DL)</b>	
CNN (21), ResNet/50 (9), Mobilenet (4), Transfer learning algorithms (2), AlexNet (2), TabNet (1), Xception (1), NASNet (1), Capsulenet (1), InceptionV3 (1), DenseNet-121 (1), U-Net (1), Region Convolutional Neural Network (RCNN) (1)	شبکه‌های عصبی پیچشی (CNNs) (۴۶ بار)
ANN (23), MLP (22), Neural Network (14), BPNN (4), Backpropagation (2), Deep Neural Network (DNN) (2), Extreme Learning Machine (ELM) (2), Radial basis function (RBF) (1), Quadratic Classifier (1), Cascade Forward Neural Network (CFNN) (1), Model average neural network (mANN) (1), Deep Belief Network (DBN) (1), Feed Forward Neural Network (FFNN) (1), HQMLP (1)	شکل‌های عصبی مصنوعی (ANNs) (۷۵ بار)
LSTM (11), BiLSTM (6), RNN (3), GRU (2), Stacked LSTM (2), Elman Neural Network (ELMAN) (1), Vanilla LSTM (1), Extreme boosting LSTM (1), A-LSTM (1),	شبکه‌های عصبی بازگشتی (RNNs) (۲۸ بار)
Transfer learning (TL) (2), Boltzmann machine (1), Deep Auto-Encoder (DAE) (1),	سایر مدل‌های یادگیری عمیق (۴ بار)

### تجزیه و تحلیل یافته‌ها و نتایج فراترکیب

این بخش نگاهی عمیق به هر چهار دسته مدیریت CVD با استفاده از مدل‌ها و تکنیک‌های EL ارائه می‌دهد.

## تشخیص زود هنگام بیماری‌های قلبی عروقی با استفاده از مدل‌های یادگیری گروهی

اهداف تشخیصی در حوزه بیماری‌های قلبی عروقی بر بهره‌گیری از منابع داده چند دامنه مانند سیگنال‌های ECG، تصویربرداری، متابولومیک و داده‌های بالینی تأکید دارند تا دقت تشخیصی بیماری‌های مختلف از جمله آریتمی‌ها، انفارکتوس میوکارد، CAD و سکته مغزی را فراهم کنند. بررسی مطالعات در این زمینه نشان‌دهنده پیشرفت چشمگیر در استفاده از مدل‌های EL و ML/DL برای تشخیص CVD ها است. مدل‌ها و تکنیک‌های گروهی نظیر RF، XGBoost، GB، AdaBoost، CatBoost و Bagging به دلیل توانایی یکپارچه‌سازی خود، همواره عملکرد بهتری نسبت به مدل‌های منفرد داشته‌اند؛ این روش‌ها برای مدیریت مجموعه داده‌های نامتعادل، بهینه‌سازی ویژگی‌ها و تعمیم مدل بسیار مناسب بوده‌اند. RF به دلیل عملکرد بالا در داده‌های بالینی ساختاریافته و سیگنال‌های ECG با ابعاد بالا برجسته است، در حالی که XGBoost در شناسایی روابط غیرخطی و مقابله با داده‌های نویزدار و نامتعادل برتری دارد. علاوه بر این، مدل‌های ترکیبی که ML و DL را با مدل‌های EL ترکیب می‌کنند، تعادل بهینه‌ای بین قابلیت تفسیر و دقت تشخیصی ارائه داده‌اند.

مدل‌های یادگیری عمیق، به ویژه CNN ها، LSTM ها، GRU ها، ANN ها و شبکه‌های عصبی عمیق<sup>۱</sup> (DNNs)، به سرعت به روشی مطلوب برای مدیریت داده‌های بزرگ و پیچیده تبدیل شده‌اند و در وظایفی مانند طبقه‌بندی سیگنال ECG، تحلیل صدای قلب و تشخیص مبتنی بر تصویر، به دقت‌های قابل توجهی دست یافته‌اند. تکنیک‌های پیش‌پردازش و بهینه‌سازی داده‌ها و ویژگی‌ها، از جمله روش‌های انتخاب ویژگی مانند MAPO و GradCAM و همچنین روش‌های رسیدگی به عدم تعادل کلاس‌ها با استفاده از تکنیک‌های نمونه‌گیری مانند تکنیک بیش‌نمونه‌گیری اقلیت مصنوعی<sup>۲</sup> (SMOTE)، نقش

1. Deep Neural Networks (DNNs)

2. Synthetic Minority Oversampling Technique (SMOTE)

حیاتی در افزایش عملکرد مدل‌ها ایفا کرده‌اند. بهینه‌سازی فرآیندها<sup>۱</sup> و تکنیک‌های فیلترینگ مانند کاهش نویز در سیگنال‌های ECG و PPG نیز به بهبود دقت کمک کرده‌اند. یافته‌ها نشان می‌دهند که ادغام مدل‌های سنتی ML و تکنیک‌های پیشرفته DL با روش‌های EL و استخراج ویژگی‌های مهم، تشخیص CVD ها را به‌طور چشمگیری بهبود بخشیده است و در کاربردهای خاص به دقت‌های بیش از ۹۰ درصد دست یافته‌اند؛ حتی برخی از مدل‌های CNN که با تبدیل موجک<sup>۲</sup> (WT) ترکیب شده‌اند، دقت تا ۹۹٫۵۱ درصد را گزارش کرده‌اند.

#### – الگوریتم‌ها و تکنیک‌های کلیدی مورد استفاده برای تشخیص CVD:

برای تشخیص، مطالعات بررسی شده در این دسته، الگوریتم‌ها و تکنیک‌های کلیدی را به کار برده‌اند. در میان آن‌ها، RF، انواع تقویت گرادیان (مانند XGBoost) و SVM به‌عنوان پرکاربردترین‌ها برجسته شده‌اند. همچنین سایر مدل‌های سنتی ML شامل رگرسیون لجستیک، K-نزدیک‌ترین همسایه، درخت تصمیم و بی‌یز ساده به دلیل سادگی و کارایی خود در تشخیص CVD ها رایج بوده‌اند. با این حال، عملکرد آن‌ها اغلب در مواجهه با داده‌های پیچیده و با ابعاد بالا ضعیف گزارش شده است. به‌عنوان مثال، SVM، اگرچه در مطالعات تشخیص آریتمی‌ها استفاده شده، اما به‌طور کلی ضعیف‌تر از الگوریتم‌های پیچیده‌تر عمل کرده است. RF، به دلیل توانایی‌اش در تجمیع چندین درخت تصمیم و افزایش دقت، به‌طور گسترده در مقالات استفاده شده (Zafar et al. 2023) (Elvas et al. 2023; Moskaleva et al. 2022; Simegn et al. 2022; Yang et al. 2018) و در برخی مطالعات، مانند (Antoniades et al. 2022) و (Antoniades et al. 2022) (Simegn et al. 2022)، (Aarthy and Iqbal 2024; Husain et al. 2023) (Zafar et al. 2023). به‌عنوان بهترین الگوریتم شناخته شده است.

تکنیک‌های یادگیری گروهی، از جمله RF، Bagging، AdaBoost و XGBoost،

- 
1. Hyperparameters
  2. Wavelet transforms (WTs)

به‌طور مداوم با رویکردهای ML و DL ترکیب شده‌اند تا عملکرد را بهبود بخشند. این روش‌ها در مدیریت داده‌های نامتعادل و نویزدار مؤثر بوده و تشخیص‌ها و پیش‌بینی‌های پایدارتری نسبت به مدل‌های منفرد ارائه داده‌اند. برای مثال، XGBoost و RF اغلب در ترکیب با تکنیک‌هایی مانند SMOTE یا روش‌های انتخاب ویژگی استفاده می‌شوند و مطالعاتی نظیر (Dhanka et al. 2023) و (Ardehi et al. 2022) به کاربرد XGBoost در ترکیب با سایر طبقه‌بندی‌کننده‌ها اشاره کرده‌اند. همچنین، الگوریتم‌هایی مانند CatBoost، AdaBoost و LightGBM نیز به‌طور مکرر در مقالات ظاهر شده‌اند که کارایی آن‌ها را در بهبود دقت تشخیصی نشان می‌دهد؛ به‌عنوان مثال، ترکیب XGBoost و AdaBoost برای افزایش دقت در مدل‌های غیرخطی در (Balaha et al. 2022). (Kokol et al. 2021) مشاهده شده است. در حالی که روش‌های DL مانند ANN، LSTM، CNN و DNN کمتر از تکنیک‌های کلاسیک ML رایج بوده‌اند، اما برای پردازش داده‌های پیچیده مانند سیگنال‌های ECG و PPG بسیار ضروری بوده‌اند (Sapra et al. 2023)، (Eleyan and Alboghbaish 2024) و (Elvas et al. 2023). CNN‌ها به‌طور گسترده در تحلیل ECG استفاده شده و مدل‌های ترکیبی مانند AlexNet-50 و ResNet-50 نتایج امیدوارکننده‌ای در تحلیل سیگنال‌های ECG و صدای قلب نشان داده‌اند. جدول چهارم خلاصه‌ای از این یافته‌ها و مسائل موردبحث در بالا در مورد تشخیص CVD‌ها با استفاده از مدل‌های مختلف یادگیری را نشان می‌دهد.

#### - بهترین الگوریتم با بالاترین عملکرد

یافته‌های مطالعات این دسته نشان می‌دهند که یادگیری عمیق در ترکیب با یادگیری گروهی (EDL) بهترین نتایج را ارائه می‌دهد و به دقت ۱۰۰٪ دست یافته است، در حالی که RF و XGBoost از پرکاربردترین و قابل‌اعتمادترین الگوریتم‌ها در مطالعات متعدد بوده‌اند. در این مطالعات، عملکرد معیار دقت بین ۷۳ تا ۱۰۰ درصد بسته به عواملی مانند پیچیدگی داده‌ها، کیفیت پیش‌پردازش و روش‌های بهینه‌سازی متغیر بوده است. الگوریتم RF چهار بار در مطالعات برای عملکرد بالای خودش با دقت بین ۸۲٪ تا ۱۰۰٪ ذکر شده

است. به طور مشابه، XGBoost کاربرد بالایی را نشان داده و به دقت بین ۹۱٫۸۵٪ تا ۱۰۰٪ دست یافته است. به عنوان مثال، XGBoost و RF با هم به دقت ۱۰۰٪ در مطالعه (Simegn et al. 2022) برای تشخیص بیماری‌های قلبی کسب کرده است. XGBoost در مقالات متعددی دارای دقت متفاوت است به عنوان مثال در مطالعه‌ی (Dhanka et al. 2023) به دقت ۹۱٫۸۵ و در مطالعه‌ی (Ogunpola et al. 2024) پس از بهینه‌سازی به دقت ۹۸٫۵۰ درصد رسیده است. سایر مدل‌های گروهی نیز عملکرد خوبی از خود نشان داده‌اند، CRDHHO-EL (یک مدل ترکیبی EL) در مطالعه‌ی (Divya et al. 2023) دقت ۹۹٫۴۳٪ را به دست آورده است. همچنین، طبقه‌بندی کننده درختان اضافی<sup>۱</sup> (ETC) دارای دقت ۱۰۰٪ در مطالعه‌ی (Balaha et al. 2022) بوده است.

از سوی دیگر، مدل‌های DL، به ویژه EDL، نمرات کاملی را به دست آورده‌اند، در حالی که روش‌های سنتی ML مانند LR و SVM به طور کلی دقت کمتری (حدود ۷۰-۸۰٪) داشته‌اند. برخی از مدل‌های DL که در مقالات عملکرد بالایی کسب کرده‌اند عبارت‌اند از: مدل CNN در [۵۵] با دقت ۹۹٫۴۰٪ در تشخیص آریتمی؛ مدل AlexNet50 در [۸۰] با دقت ۹۸٫۹۶٪؛ مدل ترکیبی LASSO-CNN با دقت ۹۹٫۵۱٪ در [۱۰۲] جهت تشخیص بیماری‌های قلبی؛ مدل DNN با دقت ۹۸٫۳٪ جهت مدیریت سیگنال‌های ECG؛ مدل CatBoost با دقت ۹۰٫۹۴٪؛ شبکه‌های عصبی ساده در دو مطالعه با دقت ۹۶ درصد؛ و مدل CapsulNet با دقت ۹۶٫۷ درصد در (Latha et al. 2022).

## پیش‌بینی و پیش‌آگهی بیماری‌های قلبی عروقی با استفاده از مدل‌های یادگیری گروهی

مطالعات بررسی‌شده در زمینه پیش‌بینی بیماری‌های قلبی عروقی بر افزایش قدرت تشخیصی جهت پیش‌بینی، پیش‌آگهی و پیامدهای درمان تمرکز دارند. این تحقیقات به طور عمده بر توسعه مدل‌های پیش‌بینی خطر بسیار دقیق برای بیماری‌های قلبی و فشار

1. Extra Trees Classifier (ETC)

خون بالا، شناسایی عوامل خطر حیاتی و بهبود قابلیت تفسیر مدل‌های EL برای متخصصان مراقبت‌های بهداشتی تأکید می‌کنند. بیماری‌های شایعی مانند CVD، بیماری عروق کرونر، نارسایی قلبی و فشار خون بالا به‌عنوان پیش‌بینی‌کننده‌های کلیدی مورد مطالعه قرار گرفته‌اند. ویژگی‌های تحلیل‌شده عمدتاً شامل سن، کلسترول و فشار خون هستند. اکثر مطالعات به چالش‌هایی نظیر مجموعه داده‌های نامتعادل، مقادیر ازدست‌رفته، برآزش بیش‌ازحد و فرآیندهای محاسباتی فشرده پرداخته‌اند تا استحکام و کارایی مدل‌ها را افزایش دهند. برخی تحقیقات بر پیش‌بینی بقای بیمار (مانند بقای نارسایی قلبی)، مدیریت منابع بیمارستانی و پیش‌بینی مرگ‌ومیر در بیمارستان تمرکز کرده‌اند. همچنین، کاربردپذیری مدل‌های EL و تکنیک‌های ترکیبی برای افزایش دقت و کاهش هشدارهای کاذب بررسی شده است و تمرکز فزاینده‌ای بر استفاده از هوش مصنوعی قابل توضیح برای افزایش شفافیت در پیش‌بینی خطر CVD مشاهده می‌شود. هدف کلی این مطالعات، افزایش پیش‌بینی بیماری، پیش‌بینی خطر و قدرت تشخیصی برای پیش‌بینی و تحلیل بقا با استفاده از تکنیک‌های پیشرفته EL و ML/DL است.

بهینه‌سازی مدل‌های یادگیری از طریق انتخاب ویژگی و تنظیم فرآیندها در اکثر جنبه‌ها و اهداف مطالعات پیش‌بینی مشاهده می‌شود. رویکردهای رایج در این دسته شامل مدل‌های گروهی (مانند GBMs، RF، Stacking و چارچوب‌های ترکیبی)، روش‌های یادگیری عمیق (مانند CNN، LSTM، GRU، DNN) و سایر الگوریتم‌های کلاسیک ML (مانند SVM، DT، LR، KNN و NB) هستند. مدل‌های LightBoost، XGBoost، GB، RF و سایر طبقه‌بندی‌کننده‌های EL به‌طور گسترده برای بهینه‌سازی نتایج پیش‌بینی در CVD ها استفاده شده‌اند. توسعه استراتژی‌های ترکیبی، مانند ترکیب ML و DL با تکنیک‌های EL، نشان‌دهنده نیاز به مدل‌های قوی‌تر برای مقابله با پیچیدگی داده‌های پزشکی است. یافته‌های کلی نشان می‌دهد که الگوریتم‌هایی مانند XGBoost، RF و LightGBM اغلب از نظر دقت از دیگر مدل‌ها بهتر عمل کرده‌اند و انتخاب ویژگی و روش‌های EL در بهبود عملکرد مدل نقش اساسی داشته‌اند. مطالعات همچنین بر رفع

محدودیت‌ها در روش‌های سنتی مانند چالش‌های پیش‌پردازش داده‌ها، عدم تعادل طبقه‌ای، بهینه‌سازی پارامترهای مدل و دستیابی به دقت پیش‌بینی و تشخیصی بالاتر متمرکز بوده‌اند.

#### - الگوریتم‌های تکراری در پیش‌بینی CVD ها:

XGBoost و RF الگوریتم‌هایی هستند که اغلب در مطالعات ذکر شده‌اند و چندین بار در وظایف پیش‌بینی CVD ظاهر شده‌اند. این الگوریتم‌ها به دلیل استحکام، توانایی مدیریت متغیرهای طبقه‌بندی شده و پیوسته و دقت پیش‌بینی بالا به خوبی شناخته شده‌اند. RF تقریباً در هر مطالعه‌ای به دلیل مدیریت مجموعه داده‌های پیچیده دیده شده است. XGBoost، نیز پرکاربردترین الگوریتم در چندین مقاله بوده که به‌طور برجسته در مطالعاتی مانند (Bhatt et al. 2023; Datta et al. 2022; Hu et al. 2020; Lee et al. 2022, 2024; You et al. 2023) نتایج خوبی را کسب کرده است. XGBoost به‌طور مداوم عملکرد قوی را در وظایف مختلف، از جمله توان بخشی CVD (Torres et al. 2023)، پیش‌بینی ترخیص از بیمارستان (Ahn et al. 2021) و پیش‌بینی فشار خون بالا (Islam et al. 2022, 2023) نشان داده است. مدل GB اغلب با RF جفت شده تا دقت را افزایش دهد، در حالی که AdaBoost اغلب در تنظیمات گروهی برای بهبود عملکرد پیش‌بینی استفاده شده است. CatBoost، در مطالعاتی مانند (Baseer et al. 2024; Pan et al. 2022; Samaras et al. 2023) و (Ohashi et al. 2023) در مطالعاتی مانند (Tachie et al. 2023)، نیز به کار گرفته شده‌اند. علاوه بر این، مدل‌های سفارشی و ترکیبی، مانند RFRF-ILM (Guo et al. 2020) و ConvSGLV (Rustam et al. 2022)، به‌طور مکرر برای افزایش بیشتر دقت و استحکام پیشنهاد شده است. سایر الگوریتم‌های رایج شامل LR، SVM، DT، NB و KNN هستند. در این میان، الگوریتم LR یک معیار سنتی و درعین حال پرکاربرد برای مقایسه است، در حالی که الگوریتم SVM به‌ویژه برای مجموعه داده‌های کوچک‌تر مؤثر بوده است.

### – مدل‌ها و الگوریتم‌ها با بالاترین عملکرد در پیش‌بینی CVD ها:

مدل‌های EL، به‌ویژه آن‌هایی که مبتنی بر تقویت گرادیان و RF هستند، بالاترین سطح از عملکرد را در پیش‌بینی بیماری‌های قلبی-عروقی نشان داده‌اند. در میان الگوریتم‌های تقویتی، XGBoost در مطالعات متعدد به بالاترین دقت دست یافته است که شامل معیارهایی چون (Torres et al. 2023)  $R^2=92\%$ ،  $AUROC=0.865$  (Ahn et al. 2021)  $AUC=0.99$  (Lv et al. 2021) و دقت  $96\%$  (Mondal et al. 2024) و  $88.81\%$  (Islam et al. 2023) می‌شود. سایر مدل‌های مبتنی بر GBM مانند AdaBoost نیز دقت  $95\%$  را ثبت کرده‌اند (Nissa et al. 2024). RF نیز در ترکیب با روش‌های دیگر به نتایج چشمگیری رسیده است؛ از جمله ترکیب آن با EG-HFS (دقت  $96.23\%$ ) (Lambay and Ghosh et al. 2024)، روش Relief در مدل RFBM (دقت  $99.05\%$ ) (Mohideen 2024) و مدل‌های خطی بهبودیافته در RFRF-ILM (دقت  $96.6\%$ ) (Guo et al. 2020) و همراه با درخت تصمیم (دقت  $96.75\%$ ) (Husain et al. 2023). علاوه بر این، روش‌های پشته‌ای نیز کارایی بالایی از خود نشان داده‌اند، مانند مدل ParSEL با دقت  $97\%$  (Noor et al. 2023) و سایر مدل‌های Stacked Ensemble با دقت‌هایی نظیر  $92.34\%$  (Tiwari et al. 2022) و  $87.8\%$  (Dritsas and Trigka 2023). روش‌های گروهی دیگر مانند دسته‌بندهای با رأی‌گیری نرم<sup>۲</sup> (SVEC) با  $AUC=99.97\%$  (Lertampaiporn et al. 2022) و ماشین یادگیری افراطی (ELM) با دقت تا  $99.06\%$  (Najim and Nasri 2024) نیز عملکرد بی‌نقصی را به ثبت رسانده‌اند.

رویکردهای ترکیبی سفارشی، مدل‌های DL و برخی الگوریتم‌های سنتی نیز نتایج برجسته‌ای را به دست آورده‌اند. مدل‌های ترکیبی پیشنهادی مانند GRU-ODE-Bayes با  $AUROC=0.812$  (Lee et al. 2024) و BMDA-MKELM با دقت  $99.5\%$  (Sheeba et al. 2022) و IACPSO-LR با دقت  $98\%$  (Dubey et al. 2022) و MaLcADD با دقت

---

1. RF bagging machine (RFBM)  
2. Soft-voting ensemble classifiers (SVEC)

Ahmadian et al. )/۹۶,۸۹ با دقت و (Rahim et al. 2021) /۹۹,۱ (2022) عملکردی فراتر از مدل‌های پایه از خود نشان دادند. در حوزه یادگیری عمیق، LSTM به AUROC برابر ۰,۹۸ (Datta et al. 2022) ، DNN به دقت ۰,۹۰,۲ (Stepanyan et al. 2022) و ترکیب CNN با مدل‌های گروهی (ConvSGLV) به دقت ۰,۹۳ (Rustam et al. 2022) دست یافتند. همچنین ادغام TabNet و CatBoost دقت ۰,۹۸ را به همراه داشت (Baseer et al. 2024). جالب توجه است که برخی مدل‌های سنتی‌تر نیز در شرایط خاصی درخشیده‌اند؛ برای مثال، KNN به دقت ۰,۹۲,۱ (Sozen et al. 2023) و رگرسیون خطی تعمیم‌یافته به دقت ۰,۹۸ (Karboub and Tabaa 2022) دست یافته‌اند که نشان‌دهنده اهمیت انتخاب الگوریتم متناسب با داده و مسئله است.

### طبقه‌بندی CVD ها بر اساس مدل‌های یادگیری گروهی

طبقه‌بندی بیماری‌های قلبی-عروقی نقشی محوری در مدیریت آن‌ها ایفا می‌کند، زیرا به طور مستقیم بر تشخیص، پیش‌بینی و برنامه‌ریزی درمانی تأثیر می‌گذارد. طبقه‌بندی صحیح، امکان شناسایی بیماری‌های مشخصی مانند آریتمی و بیماری عروق کرونر، درجه‌بندی شدت خطر برای تنظیم درمان و ارائه برنامه‌های پیشگیرانه سفارشی را فراهم می‌آورد، در حالی که طبقه‌بندی نادرست می‌تواند به تصمیمات پزشکی نامناسب یا تأخیر در درمان منجر شود. مطالعات در این حوزه بر چهار دسته اصلی متمرکز هستند: طبقه‌بندی نوع بیماری، تفکیک ریتم طبیعی قلب از غیرطبیعی، پیش‌بینی خطراتی مانند مرگ ناگهانی قلبی و تشخیص چندکلاسه بیماری‌هایی نظیر نارسایی قلبی، تنگی آئورت و زوال عقل.

هدف مشترک در مطالعات تحلیل‌شده‌ی این دسته، طبقه‌بندی هر چه بهتر بیماری‌ها/بیماران و دستیابی به تشخیص زودهنگام و دقیق CVD ها از طریق تلفیق مدل‌های نوآورانه EL با ML/DL است. این مقالات با بهره‌گیری از ویژگی‌های پیشرفته استخراج‌شده از سیگنال‌های ECG و اصوات قلب، از روش‌های متنوعی مانند CNN ها، LSTM ها، مدل‌های تقویت‌گرادبان (مانند XGBoost) و حتی چارچوب‌های یادگیری ماشین کوانتومی (QML) برای بهبود دقت تشخیصی در کاربردهای مختلفی همچون

طبقه‌بندی آریتمی‌ها، تحلیل نقایص دریچه قلب و پیش‌بینی خطر مرگ ناگهانی قلبی در بیماران خاص استفاده می‌کنند. این رویکرد یکپارچه، حرکت به سمت استفاده از محاسبات پیشرفته برای مدیریت شخصی‌سازی‌شده‌ی بیماری‌های قلبی را نشان می‌دهد.

### – الگوریتم‌ها و تکنیک‌های پرکاربرد و تکراری با عملکرد بالا در طبقه‌بندی CVD ها

در حوزه طبقه‌بندی CVD ها، مدل‌های EL رویکردی غالب محسوب می‌شوند که در میان آن‌ها، الگوریتم RF به دلیل قابلیت تعمیم بالا، بیشترین کاربرد را داشته و غالباً با مدل‌های دیگر نظیر CNN یا SVM ترکیب شده‌اند. در کنار الگوریتم‌های سنتی ML مانند SVM و KNN، مدل‌های DL از جمله CNN، LSTM و ResNet، به ویژه در استخراج ویژگی و طبقه‌بندی سیگنال‌های ECG، نقش کلیدی دارند. در میان آن‌ها SVM یکی از الگوریتم‌های پرکاربرد است که اغلب با استفاده از تکنیک‌های فراابتکاری برای به حداکثر رساندن دقت طبقه‌بندی تنظیم و ترکیب شده است. موفقیت بالای مدل‌های ترکیبی مانند CNN-LSTM و EXGB-LSTM در طبقه‌بندی‌های پیچیده و چندکلاسه در مطالعاتی مانند (Eleyan and Alboghbaish 2024; Essa and Xie 2021) و (Abdullah et al. 2023) به اثبات رسیده است. علاوه بر این، رویکردهای نوینی مانند یادگیری ماشین کوانتومی (QML) (Enad and Mohammed 2024; Maheshwari et al. 2023)، از جمله SVM کوانتومی (QSVM)، شبکه‌های عصبی کوانتومی (QNNs) و Bagging- QSVM و یادگیری انتقال (Xiang et al. 2023) نیز برای افزایش دقت و پایداری مدل‌ها مورد استفاده قرار گرفته‌اند.

عملکرد این مدل‌ها در طیف وسیعی از دقت، بین ۶۷/۳۴٪ تا ۹۹/۹۲٪، قرار می‌گیرد که اکثر چارچوب‌های یادگیری عمیق و ترکیبی به دقتی بالاتر از ۹۰٪ دست یافته‌اند. مدل D-ResNet با دقت ۹۸/۹۲٪ (Boukhaboul et al. 2024) و مدل ترکیبی FFT+CNN-LSTM با دقت ۹۷/۶٪ (Eleyan and Alboghbaish 2024) نتایج برجسته‌ای کسب کرده‌اند. الگوریتم RF به تنهایی در یک مطالعه به دقت استثنایی ۹۹/۹۲٪ (Hassaballah et al.)

(al. 2023) و در ترکیب با XGB به حساسیت و ویژگی ۹۹٪ (Pavic et al. 2023) رسیده است. سایر مدل‌ها نیز نتایج قابل توجهی داشته‌اند؛ برای مثال، مدل K-PCA با EXGB- Lee et ) ۹۴/۳٪ (Abdullah et al. 2023)، مدل XGB به دقت ۹۰/۴۶٪ ( Lee et ) (al. 2021) و الگوریتم کوانتومی QSVM به دقت ۹۰/۱۶٪ ( Enad and Mohammed ) (2024) کسب کرده‌اند.

### شناسایی CVD ها با استفاده از مدل‌های یادگیری گروهی

مطالعات تحلیل‌شده در این دسته بر استفاده از مدل‌های EL همراه با رویکردهای ML و DL برای شناسایی بیماری‌های قلبی عروقی و شرایط مرتبط با آن تمرکز دارند. هدف اصلی این تحقیقات، شناسایی عوامل خطر کلیدی و پیش‌بینی‌کننده‌های CVD برای افزایش دقت تشخیص، درمان و پیشگیری از این بیماری‌هاست. شناسایی دقیق و سریع عواملی نظیر فشار خون بالا، دیابت، کلسترول بالا، سابقه بیماری قلبی، سبک زندگی و سابقه خانوادگی که تشخیص CVD ها را دشوار می‌کنند، از اهمیت بالایی برخوردار است. این مطالعات همچنین بر مدیریت شخصی CVD ها، توضیح‌پذیری مدل‌ها و ادغام فناوری‌هایی مانند اینترنت اشیا تأکید دارند. نتایج کلی بر سه هدف اصلی متمرکز است: شناسایی عوامل و ویژگی‌های خطر حیاتی، بهبود عملکرد تشخیصی با استفاده از مدل‌های EL و ML/DL و بهینه‌سازی کارایی و هزینه‌های مراقبت‌های بهداشتی. در این میان، EL به‌عنوان متداول‌ترین روش، با ترکیب نقاط قوت الگوریتم‌های متعدد، عملکرد برتر را به نمایش می‌گذارد. رویکردهای ترکیبی مانند Stacking نیز قدرت پیش‌بینی را بیشتر کرده‌اند.

مطالعات از طیف گسترده‌ای از روش‌های گروهی مانند RF، Gradient Boosting، XGBoost، AdaBoost و الگوریتم‌های Bagging در کنار مدل‌های ML/DL و روش‌های یادگیری انتقال استفاده کرده‌اند. مدل‌های RF و XGBoost نیز به‌طور مکرر باهم ظاهر و ترکیب شده‌اند که نشان‌دهنده اثربخشی آن‌ها در مقابله با مجموعه داده‌های پیچیده CVD است. برای مقابله با چالش‌هایی مانند عدم تعادل داده‌ها و مقادیر

از دست رفته، تکنیک‌های پیش‌پردازش مانند SMOTE، انتساب چندگانه توسط معادلات زنجیره‌ای<sup>۱</sup> (MICE) و الگوریتم‌های انتخاب ویژگی از جمله الگوریتم حداکثر ارتباط حداقل افزونگی<sup>۲</sup> (mRMR) به طور گسترده‌ای به کار گرفته شده‌اند. قابلیت تفسیر مدل از طریق تجزیه و تحلیل توضیحات افزودنی شاپلی<sup>۳</sup> (SHAP) و شناسایی عوامل حیاتی نیز در اکثر مطالعات این دسته کاربرد دارد. ویژگی‌هایی مانند شاخص توده بدنی، سن، سطح کلسترول، فشار خون سیستولیک، سیگار کشیدن و سطح گلوکز در بسیاری از مقالات به عنوان عوامل تأثیرگذار در پیش‌بینی بیماری‌های قلبی عروقی مطرح شده‌اند. اعتبارسنجی داده‌ها بر روش‌های قوی مانند اعتبارسنجی متقابل k-fold، روش‌های بوت استرپ و بهینه‌سازی جستجوی شبکه‌ای متکی هستند که مدل‌های قابل اعتماد و قابل تعمیم را تضمین می‌کنند. علی‌رغم پیشرفت‌ها، مطالعات با محدودیت‌هایی مانند حجم نمونه کوچک، عدم تعادل داده‌ها و تعمیم‌پذیری محدود به دلیل استفاده از مجموعه داده‌های تک بیمارستانی یا منطقه خاص مواجه‌اند.

#### - پرکاربردترین و بهترین الگوریتم‌ها در شناسایی CVD ها:

در این دسته نیز مانند سه دسته دیگر، روش‌های EL به عنوان یک دسته غالب، به طور گسترده در مطالعات مختلف مورد استفاده قرار گرفته‌اند. الگوریتم‌هایی نظیر GB، RF، XGBoost، AdaBoost، Bagging، Extra Trees و LightGBM اغلب در تحقیقات متعدد به کار رفته‌اند. این الگوریتم‌ها غالباً به منظور بهره‌گیری از نقاط قوت هر یک، به صورت ترکیبی مورد استفاده قرار می‌گیرند؛ نمونه‌هایی از این ترکیبات شامل RF + GB + XGB و AdaBoost + LGBM می‌باشند. در این میان، RF تقریباً در تمامی مقالات، مورد بررسی قرار گرفته و به عنوان یکی از مورد بحث‌ترین و تطبیق‌پذیرترین الگوریتم‌ها شناخته می‌شود که کارایی خود را در وظایفی نظیر پیش‌بینی بقا، تشخیص

1. Multiple Imputation by Chained Equation (MICE)

2. Minimum Redundancy Maximum Relevance (mRMR)

3. SHapley Additive exPlanations (SHAP)

جنسیت و طبقه‌بندی گروه سنی اثبات کرده است. به‌طور مشابه، XGBoost و GB نیز از اهمیت بالایی برخوردار بوده و به کرات مورد بحث قرار گرفته‌اند. تحلیل مطالعات این دسته نشان می‌دهد که مدل‌های AdaBoost، RF و XGBoost معمولاً با تکنیک SMOTE ترکیب شده تا با چالش عدم تعادل داده‌ها مقابله کنند. همچنین، برای تفسیر نتایج مدل‌های پیچیده، به‌ویژه در ترکیب با الگوریتم‌هایی نظیر XGBoost و RF، از روش SHAP به‌وفور استفاده شده است.

علاوه بر الگوریتم‌های EL، مدل‌های ML شامل درخت تصمیم، ماشین بردار پشتیبان، K نزدیک‌ترین همسایگان، رگرسیون لجستیک، بی‌بیز گوسی (GNB) و رگرسیون کاکس<sup>۱</sup>، اغلب به‌صورت جداگانه یا گروهی در تحلیل‌های مقایسه‌ای ظاهر شده‌اند. رویکردهای DL، هرچند کمتر از ML سنتی مورد بحث قرار گرفته‌اند، اما در برخی مطالعات گنجانده شده‌اند. تکنیک‌هایی نظیر شبکه‌های عصبی پیچشی، شبکه‌های عصبی بازگشتی و یادگیری انتقالی غالباً با روش‌های گروهی ترکیب شده‌اند و رویکردهای ترکیبی را برای وظایف پیچیده استخراج و ویژگی و پیش‌بینی برجسته کرده‌اند. در زمینه شناسایی CVD، روش‌های EL به‌ویژه پشته‌ای به‌طور مداوم عملکرد بهتری نسبت به الگوریتم‌های مستقل از خود نشان داده‌اند که این امر بر اثربخشی ترکیب مدل‌ها تأکید می‌کند. به‌طور خاص، روش‌های EL (مانند Stacking، RF، XGBoost) به‌طور پیوسته به‌دقت و مقدار AUC بالاتری دست یافته‌اند به‌عنوان مثال، در مطالعه‌ای توسط (Louridi et al. 2021)، الگوریتم پشته‌ای بالاترین دقت (۹۵٫۸۳٪) را کسب کرد که آن را در میان الگوریتم‌های مورد اشاره به مؤثرترین روش تبدیل نمود. نتایج حاصل از RF نیز (۹۴٪ - ۹۶٪ برای پیش‌بینی بقا، تشخیص جنسیت و طبقه‌بندی گروه سنی) کارایی بسیار مؤثر این الگوریتم را در زمینه‌های خاص برجسته می‌کند (Kumar et al. 2021). در پژوهشی دیگر (Tadesse et al. 2021)، مدل DeepMI با بهره‌گیری از استراتژی‌های تلفیق داده به AUROC 96.7% دست یافته است. ارزیابی معیار دقت در مطالعات تحلیل شده نیز از

۴۹,۵٪ (با الگوریتم mRMR) (Hsu 2018) تا ۹۵,۸۳٪ (با الگوریتم انباشته) (Louridi et al. 2021) متغیر است.

## مقالات دیگر

از بین مطالعات بررسی شده، سه مقاله در چهار دسته فوق قرار نمی‌گیرند و بر استفاده از مدل‌های EL و ML/DL در پایش بیماری‌های قلبی عروقی و فشار خون تمرکز دارند. در مقاله (Desai et al. 2022) یک سیستم رایانش ابری مبتنی بر ML به نام (HealthCloud) برای پایش سلامت بیماران قلبی معرفی شده است که از داده‌های مجموعه‌ی UCI استفاده می‌کند و مدل‌هایی مانند LR، شبکه‌های عصبی، SVM، درختان تقویت گرادیان و KNN ها را بررسی می‌کند. مقاله (Li et al. 2020) به برآورد غیرتهاجمی فشار خون ناشی از سیگنال‌های ECG، PPG و فشار خون شریانی<sup>۱</sup> (ABP) در مجموعه داده MIMIC II با استفاده از مدل BiLSTM پرداخته است. این مطالعه دقت بالای آن را در مقایسه با مدل‌هایی مانند رگرسیون خطی چندگانه<sup>۲</sup> (MLR) و روش‌های گروهی رگرسیون (مانند بگینگ، تقویت و پشته‌ای) نشان داده است. در نهایت، مقاله (Maqsood et al. 2021) روش‌های استخراج ویژگی از سیگنال‌های PPG برای پیش‌بینی فشار خون را با استفاده از مجموعه داده‌های MIMIC-II و PPG-BP تجزیه و تحلیل کرده است و نشان می‌دهد که ویژگی‌های حوزه زمان در ترکیب با مدل‌های DL مانند BiLSTM و GRU بهترین عملکرد را دارند. هر سه مقاله بر استفاده از مدل‌های مختلف یادگیری برای بهبود نظارت و پیش‌بینی بیماری‌های قلبی عروقی و نظارت بر فشار خون و بررسی چالش‌هایی مانند دقت پیش‌بینی، همگام‌سازی حسگر و پیچیدگی پردازش داده‌ها متمرکز بودند.

## معیارهای ارزیابی عملکرد مدل‌های یادگیری در مدیریت CVD ها

تجزیه و تحلیل مطالعات نشان می‌دهند که معیارهای ارزیابی مدل برای ارزیابی مدل‌های

---

1. Arterial blood pressure (ABP)  
2. Multiple linear regression (MLR)

ML/DL و EL برای مدیریت CVD ها چقدر مهم هستند. این معیارها که از تکنیک‌های مختلف آماری و ریاضی حاصل می‌شوند، دقت، قابلیت اطمینان و تعمیم‌پذیری مدل‌ها را تضمین می‌کنند. طیف وسیعی از معیارهای آماری به دست آمده از ماتریس درهم ریختگی<sup>۱</sup> و سایر روش‌های کمی عمدتاً در ارزیابی مدل‌های یادگیری استفاده شده‌اند. در مدیریت بیماری‌های قلبی عروقی، ماتریس در ارزیابی میزان تمایز مدل بین بیمارانی که این بیماری را دارند و بیمارانی که این بیماری را ندارند بسیار مهم است (Husain et al. 2023; Lambay and Mohideen 2024; Lilda et al. 2022; Nissa et al. 2024). شکل ۴ ساختار ماتریس درهم ریختگی را بر حسب چهار پیامد اصلی و به دنبال آن معیارهای ارزیابی مهم ارائه می‌دهد.

شکل ۴. چارچوب ماتریس درهم ریختگی و معیارهای ارزیابی حاصل از آن.

**کلاس پیش بینی شده**

		مثبت	منفی	
کلاس واقعی	مثبت	مثبت واقعی (TP)	منفی کاذب (FN) خطای نوع دوم	معیار حساسیت (TPR) $\frac{TP}{TP + FN}$
	منفی	مثبت کاذب (FP) خطای نوع اول	منفی واقعی (TN)	معیار خاصیت (FPR) $\frac{TN}{TN + FP}$
		مقدار پیش‌بینی شده مثبت (دقت) (PPV) $\frac{TP}{TP + FP}$	مقدار پیش‌بینی شده منفی (NPV) $\frac{TN}{TN + FN}$	معیار صحت $\frac{TP + TN}{TP + FP + TN + FN}$

این معیارها توانایی پیش‌بینی، عملکرد و سازگاری مدل‌ها را در وظایفی مانند طبقه‌بندی باینری و چند کلاسه تخمین می‌زنند. عملکرد طبقه‌بندی معمولاً با معیارهای قابل توجهی مانند صحت<sup>۲</sup>، حساسیت (یادآوری)<sup>۳</sup>، خاصیت<sup>۱</sup>، دقت<sup>۲</sup>، نمره<sup>۳</sup> F1 و مساحت زیر منحنی

1. Confusion Matrix
2. Accuracy
3. Sensitivity (Recall)

مشخصه عملکرد سیستم<sup>۴</sup> (AUC-ROC) اندازه‌گیری می‌شود. برای پرداختن به مسائلی مانند طبقه‌بندی چندطبقه‌ای و عدم تعادل طبقاتی، مطالعات معیارهای پیچیده دیگری مانند از دست دادن همینگ، دقت متوازن و ضریب همبستگی متیوز<sup>۵</sup> (MCC) را بررسی کرده‌اند. همچنین برای پیش‌بینی پیامدهای پیوسته در برخی از مدل‌های خاص، از معیارهای رگرسیون یا خطای خاص و همبستگی مانند  $R^2$  (R-squared)، میانگین خطای مطلق<sup>۶</sup> (MAE)، جذر میانگین مربعات خطا<sup>۷</sup> (RMSE)، میانگین مربعات خطا<sup>۸</sup> (MSE) و غیره استفاده شده است. با ارائه بینش جامع در مورد عملکرد مدل در بسیاری از مجموعه داده‌ها، تکنیک‌های اعتبارسنجی متقابل مانند اعتبارسنجی متقابل k-fold اعتبار این ارزیابی‌ها را بهبود بخشیده‌اند. تعدادی از این معیارها از ماتریس درهم‌ریختگی مشتق شده‌اند که پیش‌بینی‌ها را به مثبت کاذب<sup>۹</sup> (FP)، مثبت واقعی<sup>۱۰</sup> (TP)، منفی کاذب<sup>۱۱</sup> (FN) و منفی واقعی<sup>۱۲</sup> (TN) دسته‌بندی می‌کند. بعضی از مطالعات از معیارهای خاص مدل، معیارهای اعتبارسنجی و آماری استفاده کرده‌اند که برای مشخصات مجموعه داده مناسب هستند، مانند پرداختن به عدم تعادل مجموعه داده یا ارائه بینش عمیق‌تر و دقیق‌تر از طریق معیارهایی مانند نمرات بریر، کاپای کوهن، مقدار احتمال<sup>۱۳</sup>، شاخص یودن<sup>۱۴</sup> (YI)، قابلیت تفسیر و غیره. هدف اصلی مدیریت CVD ها بهینه‌سازی مدل‌ها و تضمین طبقه‌بندی، حساسیت و صحت دقیق است. جدول پنجم طبقه‌بندی جامعی از معیارهای ارزیابی عملکرد

- 
1. Specificity
  2. Precision
  3. F1 - Score
  4. The area under the ROC curve (AUC-ROC)
  5. Matthews correlation coefficient (MCC)
  6. Mean absolute error (MAE)
  7. Root mean square error (RMSE)
  8. Mean square error (MSE)
  9. False Positive (FP)
  10. True Positive (TP)
  11. False Negative (FN)
  12. True Negative (TN)
  13. P-Value
  14. Youden Index (YI)

مورد استفاده در مدل‌های EL و ML/DL برای مدیریت CVD ها را ارائه می‌دهد. این معیارها را در دسته‌های مهمی گروه‌بندی می‌کند، مانند معیارهایی برای ارزیابی عمومی بر اساس ماتریس‌های درهم‌ریختگی، معیارهای مبتنی بر خطای رگرسیون، معیارهای همبستگی، معیارهای خاص یک مدل، روش‌های اعتبارسنجی، معیارهای آماری و شاخص‌های عملکرد محاسباتی. هر دسته شامل طیف وسیعی از معیارها است که برای ارزیابی دقت، قابلیت تفسیر و کارایی محاسباتی مدل ضروری است.

جدول ۵. طبقه‌بندی جامعی از معیارهای ارزیابی عملکرد مورد استفاده برای مدل‌های EL و ML/DL در مدیریت CVD ها، همراه با فراوانی آن‌ها در مطالعات بررسی شده.

معیارهای ارزیابی و فراوانی آن‌ها	دسته‌بندی معیارهای ارزیابی
<ul style="list-style-type: none"> <li>• Confusion Matrix (44),</li> <li>• Accuracy (114), Balanced Accuracy (1), Mean Accuracy (MA) (1), Average accuracy of each state (MPA) (1), Accuracy of each state (CPA) (1), Average Accuracy (1), Overall accuracy (PA) (1), Multi-value accuracy (MACC) (1), Prediction accuracy of TAE (1),</li> <li>• Specificity (51), Average specificity (ASp) (1),</li> <li>• Precision (82), Macro-precision (MP) (1),</li> <li>• Sensitivity (55), Recall (65), Positive Predictive Value (PPV) (9), Macro-recall (MR) (1), Average sensitivity (ASe) (1),</li> <li>• F-measure / F1-Score (86), Macro-F1 score (MF1) (2), Macro-Averaged F1-Score (1), Weighted F1-Score (1),</li> <li>• AUC-ROC (66), AUC-PR (8), PRC Area (1),</li> <li>• Matthews Correlation Coefficient (MCC) (10), Fallout (1), Gmean (1), Critical Success Index (CSI) (1), The Dice similarity coefficient (DSC) (۲), Jaccard score (1), Detection Rate (DR) (1), Detection Prevalence (DP) (1),</li> <li>• False Positive Rate (FPR) (18), True Positive Rate (TPR) (14), Negative predictive values (NPVs) (NPR) (6), True Negative Rate (TNR) (4), False Negative Rate (FNR) (1), False discovery rate (FDR) (1), False omission rate (FOR) (1), Average True Positive Predictive (ATPP) (1),</li> </ul>	<p>معیارهای ارزیابی عمومی (معیارهای ماتریس درهم ریختگی)</p>

معیارهای رگرسیون (معیارهای مبتنی بر خطا)	جذر میانگین مربعات خطا (RMSE) (۱۰)، میانگین خطای مطلق (MAE) (۴)، میانگین مربعات خطا (MSE) (۱)، میانگین مربعات خطای نرمال شده (NMSE) (۱)، میانگین درصد مطلق خطای (MAPE) (۱)، SEE (۱)، خطای مطلق نسبی (RAE) (۱)، Average squared error (ASE) (۱)، نرخ خطا (۷)، تلفات ورود به سیستم (۲)، ضرر همینگ (۱)، نرخ ضرر (۱)،
معیارهای همبستگی	ضریب تعیین (R <sup>2</sup> ) (۵)، مربع R <sup>2</sup> اسپیرمن (۱)، ضریب همبستگی Hosmer-Lemeshow-2 (۱)،
معیارهای خاص مدل	قابلیت تفسیر (I) (۱)، شاخص تفسیرپذیری-دقت (IAI) (۱)، شاخص تفسیرپذیری-سازگاری (ICI) (۱)، شاخص سازگاری (C-index) (۱)، شاخص C-IPCW Prescription Robustness (PR) (۱)، Effectiveness (PE) (1)، احتمال آستانه (۲)، حداکثر اختلاف میانگین (MMD) (۱)، Expected Reciprocal Rank (ERR) (۱)،
معیارها و تکنیک‌های اعتبارسنجی	فواصل اطمینان بوت استرپ برای اعتبارسنجی خارجی (۱)، اعتبارسنجی متقابل برای اعتبارسنجی داخلی (به عنوان مثال، hold-out, k-fold) (۵۴)، میانگین اعتبارسنجی متقابل (۱)، میانگین دقت K-fold (۱)، شاخص Youden (YI) (۳)، فاصله اطمینان (CI) (۷)،
معیارهای آماری	نمره بریر (BS) (۳)، میانگین نمره بریر (۱)، نمودارهای کالیبراسیون (۱)، آماره کاپا کوهن یا نمره کاپا (KS) (۹)، P-Value (۶)، انحراف معیار (SD) (۴)، آزمون U Whitney Mann (۱)، نمودار وابستگی جزئی (PDP) (۲)، نسبت پایداری (۱)، نمودار کاپلان مایر (۱)،
معیارهای محاسباتی	زمان کل (۵)، QoS (۱)، تأخیر (۱)، استفاده از حافظه (۱)، گزارش طبقه بندی (۱)، نرخ طبقه بندی نادرست (۱)،

### محدودیت‌ها و چالش‌های مدیریت بیماری‌های قلبی عروقی با استفاده از

#### مدل‌های EL و ترکیبی

مطالعاتی که بر استفاده از تکنیک‌های EL، ML و DL در مدیریت بیماری‌های قلبی عروقی تمرکز دارند، با چالش‌ها و محدودیت‌های مکرری مواجه هستند. این محدودیت‌ها عمدتاً شامل مسائل مربوط به کیفیت و حجم داده‌ها، تعمیم‌پذیری، عدم تعادل کلاس‌ها و نیازهای محاسباتی است. یکی از مشکلات برجسته، اتکا به مجموعه داده‌های کوچک یا

تک مرکزی است که به دقت متوسط، قابلیت تعمیم پذیری پایین و تنوع عملکردی محدود منجر می شود. همچنین، عدم تعادل کلاس در مجموعه داده ها می تواند عملکرد مدل را در کلاس های اقلیت کاهش دهد، در حالی که داده های از دست رفته (مانند سیگنال های ECG ناقص) بر دقت و طبقه بندی تأثیر منفی می گذارند. علاوه بر این، استفاده از مدل های خطی برای شناسایی الگوهای پیچیده و غیرخطی در داده های قلبی عروقی ناکافی است و فقدان اعتبارسنجی مدل ها در مجموعه داده های دنیای واقعی، قابلیت تعمیم پذیری آن ها را به زمینه های بالینی مختلف زیر سؤال می برد.

محدودیت های دیگر شامل پیچیدگی محاسباتی و نیازهای منابع برای مدل های پیچیده، به ویژه مدل های DL مانند CNN، است که استقرار آن ها را در کاربردهای بلادرنگ محدود می کند. همچنین، پیچیدگی روش های گروهی می تواند قابلیت تفسیر مدل ها را کاهش دهد و از سودمندی آن ها برای تصمیم گیری بالینی بکاهد. مشکلات در مهندسی و انتخاب ویژگی نیز از جمله چالش های مهم است؛ وجود نویز در داده های با ابعاد بالا کارایی مدل را کاهش می دهد و عدم وجود روش های قوی برای انتخاب ویژگی های مرتبط، دقت پیش بینی ها را محدود می کند. در نهایت، مطالعات با محدودیت های عملکردی مانند حساسیت پایین در شناسایی بی نظمی های کمتر رایج یا تمرکز صرف بر طبقه بندی عمومی صداها، قلب مواجه هستند که دامنه کاربرد آن ها را محدود می سازد. موانع اجرایی و عدم پوشش کافی پایش بلادرنگ و تجزیه و تحلیل مستمر در تحقیقات نیز مانع استقرار عملی این مدل ها می شوند. شکاف در آزمایش و اعتبارسنجی مکرر، از جمله فقدان اعتبارسنجی خارجی، قابلیت اطمینان نتایج بسیاری از مطالعات را کاهش می دهد. برای غلبه بر این چالش ها، نیاز به مجموعه داده های بزرگ تر و متنوع تر، روش های بهبود یافته انتخاب ویژگی، اعتبارسنجی خارجی و چارچوب های محاسباتی کارآمدتر وجود دارد. جدول ششم محدودیت ها و چالش هایی را که اغلب در استفاده از مدل های ML، EL و DL برای مدیریت CVD ها مواجه می شوند، ارائه می دهد.

جدول ۶. محدودیت‌ها و چالش‌های مکرر در به‌کارگیری مدل‌های EL، ML و DL برای مدیریت CVD ها.

دسته‌بندی	زیرشاخه	نمونه	توضیحات
محدودیت‌های مجموعه داده	مجموعه داده‌های کوچک و داده‌های محدود	مجموعه داده‌های قطر، Statlog، MIT-BIH، HD، بیمارستان جیانگشی	مجموعه داده‌های کوچک استحکام آماری و تعمیم‌پذیری را کاهش می‌دهند.
	عدم تعادل داده‌ها	نسبت بیماری به غیر بیماری،	توزیع نابرابر کلاس آموزش مدل را سوگیری می‌کند و دقت کلاس اقلیت را کاهش می‌دهد. برای رفع آن تکنیک‌های نمونه‌برداری مجدد استفاده می‌شود.
	داده‌های گمشده	شکاف‌های سیگنال ECG و جزئیات از دست‌رفته بیماران	اطلاعات دموگرافیک/بالیستی ناقص یا گم‌شده بر دقت تأثیر می‌گذارد.
	کیفیت داده‌ها و داده‌های نویز دار	تصاویر ECG نویز دار، مانند مجموعه داده ACD، تصاویر شبکه‌ای با وضوح پایین	داده‌های با کیفیت پایین یا مصنوعی استحکام مدل را کاهش می‌دهد.
	وابستگی خاص داده	مجموعه داده‌های منطقه‌ای (دانشگاه سچنوف و بیمارستان سانتا ماریا)	مدل‌های آموزش دیده بر روی جمعیت‌های خاص ممکن است به‌خوبی تعمیم نگیرند.
	نوع داده‌ها	مجموعه داده‌های کلیولند، مجارستان و سوئیس	چالش‌های یکپارچه‌سازی داده‌های ساختاریافته و بدون ساختار.
	مجموعه داده‌های عمومی در مقابل خصوصی	مانند مجموعه داده MIT-BIH و کلیولند قلب	استفاده بیش‌ازحد از مجموعه داده‌های عمومی خطر برآزش بیش‌ازحد را به همراه دارد. مجموعه داده‌های اختصاصی تکرارپذیری را محدود می‌کند.
	مهندسی و انتخاب ویژگی	استخراج ویژگی محدود در برخی مطالعات	داده‌های با ابعاد بالا ممکن است نویز ایجاد کنند. انتخاب ویژگی محدود بر دقت تأثیر می‌گذارد.
محدودیت‌های مدل محاسباتی	پیچیدگی محاسباتی	مدل‌های DL و EL به منابع بالایی نیاز دارند و کاربردهای بلادرنگ را محدود می‌کنند.	
		XGB، CNN-LSTM، RESNet50، CapsuleNet	

دسته بندی	زیر شاخه	نمونه	توضیحات
	حساسیت مدل	عملکرد تأثیر سیگنال های ECG نویزدار	برخی از مدل ها به نویز بسیار حساس هستند و قابلیت اطمینان را کاهش می دهند.
	مسائل مقیاس پذیری	قابلیت های پردازش ECG بلادرنگ محدود	مشکل در مدیریت داده های در مقیاس بزرگ یا بلادرنگ.
	قابلیت تفسیر مدل	XGB و گروه های عمیق	مدل های DL و گروهی فاقد قابلیت تفسیر هستند و بر پذیرش بالینی تأثیر می گذارند.
محدودیت های عملکرد	محدودیت های عملکرد	به عنوان مثال، مشکلات در معیار حساسیت در مدل AdaBoost	حساسیت کمتر برای نمونه های نادر؛ طبقه بندی باینری پیش بینی های ظریف را محدود می کند.
	نظارت بلادرنگ	مسائل پردازشی سیگنال های قلبی همچون ECG به صورت بلادرنگ	مطالعات کمی چالش های استقرار بلادرنگ را بررسی می کنند.
	مراحل اولیه توسعه	مانند تکنیک های برجسب دار	برخی از روش ها هنوز در مراحل آزمایشی با مجموعه داده های محدود هستند.
	عدم اعتبار سنجی خارجی	عدم وجود ارزیابی اعتبارسنجی متقابل در مجموعه داده های خارجی	بسیاری از مطالعات فاقد اعتبارسنجی خارجی هستند که قابلیت اطمینان را کاهش می دهند.
کاربرد در دنیای واقعی	چالش های یکپارچه سازی در مراقبت بهداشتی	ادغام محدود با سیستم های EHR	مشکل در همسویی خروجی های مدل با گردش کار بالینی.
	عملکرد در محیط های نویزدار	مانند مسائل مربوط به ثبات در تشخیص ضربان قلب مبتنی بر ویدئو	مدل های آزمایش شده در تنظیمات ایده آل ممکن است در سناریوهای دنیای واقعی شکست بخورند.
	هزینه محاسباتی	مدل های DL که به خوشه های GPU نیاز دارند	نیازهای پردازش بالا برخی از مدل ها را در محیط های دارای منابع محدود غیر عملی می کند.
تعمیم پذیری و	محدودیت های مجموعه داده	مجموعه داده های MIT-Statlog و BIH	مطالعات تک مرکزی فاقد قابلیت تعمیم به جمعیت های مختلف هستند.

دسته‌بندی	زیرشاخه	نمونه	توضیحات
اعتبارسنجی	نمایندگی کم گروه‌های اقلیت	برخی از مجموعه داده‌ها بر گروه‌های قومی خاص تمرکز می‌کنند	تنوع جمعیتی محدود بر کاربرد گسترده‌تر تأثیر می‌گذارد.
	شکاف‌های اعتبارسنجی	عدم اعتبارسنجی متقابل مجموعه داده	بسیاری از روش‌ها فاقد آزمایش بر روی مجموعه داده‌های دنیای واقعی هستند که کاربرد آن را محدود می‌کند.
	چالش‌های تجزیه و تحلیل زیر گروه	ناتوانی در تجزیه و تحلیل گروه‌های خطر خاص	حجم نمونه کوچک تجزیه و تحلیل زیر گروه را محدود می‌کند.

در میان این محدودیت‌ها، شایع‌ترین محدودیت، اندازه مجموعه داده کوچک بود که اغلب با مسائل مربوط به تعمیم‌پذیری محدود همراه بوده است. این دو اغلب باهم اتفاق می‌افتند، زیرا مجموعه داده‌های کوچک ذاتاً توانایی یک مدل را برای تعمیم محدود می‌کنند. یکی دیگر از ترکیب‌های رایج از محدودیت‌ها، پیچیدگی محاسباتی همراه با محدودیت‌های داده بود که در مجموع مانع مقیاس‌پذیری و کارایی مدل‌ها می‌شد. داده‌های پرسروصدا یا همان نویزی یکی از تکرارشونده‌ترین مسائل است و پس از آن حجم نمونه کوچک قرار دارد. یک چالش کلیدی این است که ترکیب منابع داده ناهمگن به دلیل مسائل استانداردسازی و یکپارچه‌سازی دشوار است. پیشنهادهای عملی می‌تواند شامل افزایش تنوع مجموعه داده، بهبود تکنیک‌های پیش‌پردازش داده‌ها و استفاده از یادگیری فدرال برای مجموعه داده‌های اختصاصی باشد که می‌تواند محدودیت‌های زیادی را برطرف کند.

### مهندسی داده و ویژگی و پیش‌پردازش در مدیریت CVD

مطالعات بررسی شده بر اهمیت یک رویکرد سیستماتیک برای پیش‌پردازش داده‌ها در مدیریت بیماری‌های قلبی عروقی تأکید دارند، با تمرکز ویژه بر مهندسی ویژگی، آماده‌سازی داده‌ها، تعادل داده‌ها و تنظیم فرآیند. این تکنیک‌ها باهدف بهبود عملکرد،

قابلیت اطمینان، قابلیت تفسیر و تعمیم‌پذیری مدل‌های EL و ML/DL به کار رفته‌اند. این شامل مقابله با مسائلی نظیر داده‌های پرسروصدا، عدم تعادل کلاس، ابعاد بالا و برآزش بیش‌ازحد<sup>۱</sup> است. ترکیب استراتژی‌های پیشرفته‌ای مانند کاهش ابعاد و بهینه‌سازی ابرپارامترها با روش‌های اساسی نظیر اعتبارسنجی متقابل و تجزیه و تحلیل داده‌های اکتشافی<sup>۲</sup> (EDA)، به نتایج قوی و عملکرد پیش‌بینی‌کننده مطلوب منجر می‌شود. علاوه بر این، ادغام منابع داده‌های مختلف و روش‌های پیش‌پردازش وابسته به دامنه، مانند کروماتوگرافی مایع برای پروفایل متابولیت، تنوع استراتژی‌های ابداع‌شده بر اساس پیچیدگی داده‌های قلبی عروقی را نشان می‌دهد.

روش‌های کلیدی در پیش‌پردازش داده‌ها به چهار دسته اصلی تقسیم می‌شوند: آماده‌سازی داده‌ها، انتخاب ویژگی، استخراج ویژگی و روش‌های ترکیبی. انتخاب ویژگی، مانند روش‌های Filter، Wrapper، Embedded، Boruta، با کاهش ابعاد مجموعه داده از طریق انتخاب متغیرهای مرتبط، کارایی مدل را افزایش می‌دهد. تکنیک‌های نمونه‌گیری مانند SMOTE، MICE و انواع آن، عدم تعادل کلاس را برای انصاف بهتر مدل مدیریت می‌کنند و SMOTE اغلب با روش‌های SHAP یا VIM برای تجزیه و تحلیل اهمیت ویژگی ترکیب می‌شود. تنظیم ابرپارامترها با استفاده از روش‌هایی نظیر RandomizedSearchCV و Optuna، پارامترهای مدل را برای عملکرد بهینه تنظیم می‌کند و اعتبارسنجی متقابل k-fold همراه با آن برای اطمینان از استحکام و قابلیت اطمینان مدل استفاده می‌شود. روش‌های کاهش ابعاد مانند تجزیه و تحلیل مؤلفه‌های اصلی<sup>۳</sup> (PCA) و تجزیه و تحلیل مؤلفه‌های مستقل<sup>۴</sup> (ICA)، ابعاد را ضمن حفظ اطلاعات مهم کاهش می‌دهند. تکنیک‌های نرمال‌سازی و مقیاس‌بندی، داده‌ها را برای بهترین عملکرد مدل استاندارد می‌کنند و فیلترها و تبدیل‌های فوری کیفیت داده‌ها را از طریق حذف نویز بهبود می‌بخشند. در نهایت، تکنیک‌های تفسیر مدل مانند SHAP و هوش مصنوعی قابل

- 
1. Overfitting
  2. Exploratory data analysis (EDA)
  3. Principal component analysis (PCA)
  4. Independent component analysis (ICA)

توضیح<sup>۱</sup> (XAI)، شفافیت در تصمیم‌گیری مدل را افزایش می‌دهند و پیش‌بینی‌های مبتنی هوش مصنوعی را قابل توضیح‌تر و قابل‌اعتمادتر می‌کنند. جدول هفتم چندین روش مورد استفاده در این زمینه یعنی تکنیک‌های مرتبط با مهندسی و پیش‌پردازش ویژگی‌ها و داده‌ها را طبقه‌بندی می‌کند که در اکثر مقالات مورد استفاده قرار گرفته‌اند.

جدول ۷. طبقه‌بندی وظایف و تکنیک‌های مهندسی داده و ویژگی به همراه فراوانی آن‌ها در مطالعات بررسی شده.

تکنیک‌ها	دسته‌بندی‌های مهندسی داده و ویژگی
Shearing (1), Shifting (1), Rotating (1), Zooming (1)	تکنیک‌های تقویت ویژگی و داده
Flipping and Cropping (۱)، الگوریتم پان تامپکینز (۲)، روش غربالگری بوروتا (۲)، روش تعیین‌شده (۳)، روش Wrapper (۴)، روش فیلتر (۵)، Relief (۱)، InfoGain (۲)، حذف ویژگی بازگشتی (RFE) (۱)، آنتروپی (۲)، از دست دادن اطلاعات (۱)، تکنیک ارزیابی ویژگی ReliefF (۱)، تکنیک انتخاب ویژگی مبتنی بر همبستگی (۱)،	تکنیک‌های انتخاب و استخراج ویژگی
PCA (۷)، حداقل مربعات جزئی (PLS) (۱)، تجزیه و تحلیل مؤلفه‌های مستقل (ICA) (۱)،	کاهش داده‌ها و ویژگی‌ها
فیلتر پایین‌گذر (۱)، فیلتر میانه (۲)، فیلتر Butterworth برای نویز زدایی (۳)، تبدیل سریع فوری (FFT) (۱)، تبدیل فوری گسسته (DFT) (۱)، تبدیل موجک گسسته (DWT) (۲)، آمار مرتبه بالاتر (HOS) (۱)، D-local binary pattern (LBP) (۱)، فواصل R-R (۱)، گشتاور مرکزی (CM) (۱)، تابع پایه هرمیت (HBF) (۱)،	حذف داده‌ها؛ پردازش تصویر و سیگنال؛ و تکنیک‌های تشخیص الگو
SMOTE (۱۰)، روش بوت استرپ برای نامتعادل (۱)، نمونه‌برداری بیش‌ازحد پیاده‌روی تصادفی (RWOS) (۱)، تکنیک نمونه‌گیری بیش‌ازحد اقلیت وزن‌دار اکثریت (MWMOTE) (۱)، SMOTE — مرزی (B-SMOTE) (۱)، مصنوعی تطبیقی (ADASYN) (۱)، نمونه‌گیری بیش‌ازحد تصادفی (ROS) (۱)، نمونه‌برداری سایه افین تصادفی موضعی (LoRAS) (۱)، نمونه‌گیری سایه	تکنیک‌های تعادل داده و کلاس

## 1. Explainable artificial intelligence (XAI)

تکنیک‌ها	دسته‌بندی‌های مهندسی داده و ویژگی
افین تصادفی وزنی مجاورت (ProWRAS) (۱)،	
نرمال‌سازی / استانداردسازی Z-score (۲)، نرمال‌سازی (۱)، Abs-Max Scaler (۱)، مقیاس بندی استاندارد (SS) (۳)، مقیاس بندی مقاوم (۱)، مقیاس بندی و نرمال‌سازی Min-Max (۵)،	پیش‌پردازش داده‌ها
هوش مصنوعی قابل توضیح (XAI) (۲)، SHAP (۱۴)،	قابلیت تفسیر مدل

### - استخراج ویژگی

استخراج ویژگی یک گام حیاتی در بهبود عملکرد مدل‌های یادگیری است که داده‌های خام را به اطلاعات معنادار تبدیل می‌کند تا مدل بتواند الگوهای مهم را بیاموزد. در این فرآیند، تکنیک‌های مختلفی به کار گرفته می‌شوند. تجزیه و تحلیل حوزه زمان و زمان-فرکانس، به ویژه برای سیگنال‌های صوتی قلب، ویژگی‌های مهمی را استخراج می‌کند. ویژگی‌های مورفولوژیکی، مانند ماتریس‌های هم‌رخدادی سطح خاکستری (GLCM) (Lee et al. 2021)، ساختارهای داده‌ای را از ECG و صدای قلب آشکار می‌سازند. تبدیلات موجک، از جمله حذف نویز موجک و تبدیل موجک گسسته<sup>۱</sup> (DWT)، برای پاک‌سازی داده‌ها و برجسته کردن الگوهای مهم استفاده می‌شوند. تبدیل فوریه سریع<sup>۲</sup> (FFT) نیز با ترکیب با CNN ها و LSTM ها برای استخراج ویژگی و مدل‌سازی توالی به کار رفته‌اند (Eleyan and Alboghbaish 2024). مدل‌های یادگیری عمیق مانند CNN در استخراج ویژگی و طبقه‌بندی چند کلاسه برتری دارند و از روش‌هایی مانند مهندسی ویژگی فضایی کانولوشن<sup>۳</sup> (CSFE) برای استخراج الگوهای معنی دار از مجموعه داده‌های پیچیده استفاده شده‌اند (Zafar et al. 2023). تکنیک‌هایی مانند تجزیه حالت تجربی<sup>۴</sup> (EMD) (Lilda et al. 2022) برای استخراج ویژگی‌های غیرخطی از سیگنال‌های ECG

1. Discrete wavelet transforms (DWT)
2. Fast Fourier Transform (FFT)
3. Convolutional spatial feature engineering (CSFE)
4. Empirical Mode Decomposition (EMD)

استفاده شده و به تشخیص دقیق‌تر CVD ها کمک می‌کند. همچنین، در ( Yang et al. 2018) PCANet اعمال شده است که به افزایش استخراج ویژگی از سیگنال‌های ECG نوین‌دار کمک کرده است. در مطالعه (Rustam et al. 2022)، مدل ConvSGLV با ترکیب CNN با مجموعه‌ای از مدل‌های مختلف مانند SGDC، LR و SVM برای استخراج و طبقه‌بندی ویژگی‌ها توسعه داده شده است. در مطالعه دیگری، ( Baseer et al. 2024) از TabNet برای استخراج ویژگی‌های پیچیده استفاده کرد که منجر به بهبود دقت پیش‌بینی شد. علاوه بر این، ویژگی‌های مهندسی دستی اغلب با فرآیندهای خودکار ترکیب می‌شوند تا دقت مدل‌ها افزایش یابد. در نهایت، ویژگی‌های استخراج شده به‌عنوان ورودی برای مدل‌های یادگیری برای مدیریت بیماری‌های قلبی-عروقی به کار می‌روند که این امر نقش کلیدی در افزایش دقت و کارایی مدل‌ها در تشخیص و مدیریت این بیماری‌ها دارد.

#### - انتخاب ویژگی و کاهش ابعاد

انتخاب ویژگی و کاهش ابعاد، دو رویکرد کلیدی در حوزه پیش‌پردازش داده‌ها هستند که نقشی حیاتی در بهینه‌سازی عملکرد و کارایی مدل‌های یادگیری ایفا می‌کنند. هدف اصلی این تکنیک‌ها، شناسایی و گزینش مهم‌ترین و مرتبط‌ترین ویژگی‌ها از میان انبوه داده‌ها و هم‌زمان حذف ویژگی‌های غیرضروری یا نویز دار است. این فرآیند، علاوه بر کاهش ابعاد مجموعه داده و پیچیدگی محاسباتی، به بهبود چشمگیر دقت و سرعت آموزش مدل‌ها کمک می‌کند و در نهایت، منجر به افزایش قابلیت تفسیر نتایج و درک بهتر روابط بین ویژگی‌ها و خروجی مدل می‌شود. برای دستیابی به این اهداف، روش‌های متنوعی توسعه یافته‌اند که هر یک نقاط قوت خاص خود را دارند. روش‌های مبتنی بر فیلتر<sup>۱</sup>، مانند استفاده از اطلاعات متقابل<sup>۲</sup> (Dritsas and Trigka 2023) یا الگوریتم mRMR، ویژگی‌ها را بر اساس معیارهای آماری و مستقل از مدل ارزیابی می‌کنند ( Hsu

- 
1. Filter Methods
  2. Mutual Information

(2018). در مقابل، روش‌های مبتنی بر Wrapper، نظیر حذف ویژگی بازگشتی<sup>۱</sup> (RFE)، از عملکرد یک مدل یادگیری برای ارزیابی زیرمجموعه‌های مختلف ویژگی‌ها بهره می‌برند (Noor et al. 2023). روش‌های تعبیه‌شده<sup>۲</sup> نیز، مانند تکنیک عمل‌گر گزینش و انقباض کمترین قدر مطلق<sup>۳</sup> (LASSO)، فرآیند انتخاب ویژگی را مستقیماً در روند آموزش مدل ادغام می‌کنند. علاوه بر این، تکنیک‌هایی مانند PCA برای کاهش ابعاد با تبدیل داده‌ها به فضایی با ابعاد کمتر کاربرد داشته، در حالی که ابزارهایی مانند SHAP به ارزیابی اهمیت هر ویژگی در تصمیم‌گیری مدل کمک کرده‌اند (Alfaidi et al. 2022; Islam et al. 2023). بهینه‌سازی ژنتیکی نیز به حذف ویژگی‌های اضافی برای افزایش کارایی مدل کمک می‌کند. فرایند انتخاب ویژگی در مدیریت بیماری‌های قلبی عروقی حائز اهمیت است، جایی که مدل‌های EL (مانند RF، SGD، GB، XGBoost) با استفاده از انتخاب ویژگی‌های بهینه‌شده، عملکرد بالاتری از خود نشان می‌دهند.

#### - پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها یک مرحله حیاتی و تکرارشونده در مدل‌های یادگیری به‌ویژه مدل‌های EL است که برای افزایش کیفیت داده‌ها و تضمین سازگاری آن‌ها با الگوریتم‌ها ضروری است، به‌ویژه در مدیریت بیماری‌های قلبی عروقی. این فرآیند شامل چندین وظیفه کلیدی است: ابتدا، مدیریت داده‌های از دست رفته با استفاده از تکنیک‌هایی مانند MICE، میانگین‌گیری و غیره برای حفظ یکپارچگی داده‌ها انجام می‌شود. در مرحله بعد، تشخیص داده‌های پرت و حذف نویز از طریق فیلترهای مختلف (مانند FIR، IIQR، Butterworth) برای بهبود کیفیت سیگنال (به‌ویژه در ECG و سیگنال‌های صوتی قلب) صورت می‌گیرد (Kokol et al. 2021) (Aarthy and Iqbal (Ardeti et al. 2022) (2024). سپس، نرمال‌سازی و مقیاس‌بندی داده‌ها با روش‌هایی مانند نرمال‌سازی حداقل-

1. Recursive Feature Elimination (RFE)

2. Embedded Methods

3. Least Absolute Shrinkage and Selection Operator (LASSO)

حداکثر و امتیاز Z برای جلوگیری از تسلط ویژگی‌های با محدوده عددی بزرگ‌تر و بهبود عملکرد مدل اعمال می‌شود (Baghdadi et al. 2023). علاوه بر این، تکنیک‌های تعادل کلاس/داده مانند SMOTE (Jiang et al. 2023; Ogunpola et al. 2024) و نمونه‌گیری بیش‌ازحد (از جمله SMOTE-Tomek و SMOTE-ENN) (Moreno-Sanchez 2023; Shchetinin and Glushkova 2022; Sinha et al. 2023) برای رسیدگی به مسائل عدم تعادل کلاس که در مجموعه داده‌های پزشکی رایج است، به کار گرفته شده‌اند. همچنین، تقسیم‌بندی داده‌ها (مانند استفاده از روش U-Net) برای جداسازی بخش‌های مرتبط سیگنال استفاده می‌شوند. این فرآیندهای جامع پیش‌پردازش، داده‌ها را برای ورودی به مدل‌های یادگیری آماده می‌کنند و در نهایت به توسعه مدل‌های مدیریت CVD دقیق‌تر و قابل‌اطمینان‌تر کمک می‌کنند.

#### - بهینه‌سازی هایپر پارامتر

بهینه‌سازی هایپر پارامتر یک گام اساسی در بهبود دقت و پایداری مدل‌های یادگیری است که باهدف شناسایی بهترین پارامترها انجام می‌شود. مطالعات مختلف از تکنیک‌های متنوعی برای این منظور بهره برده‌اند، از جمله روش‌های تنظیم فرای پارامتر عمومی مانند RandomizedSearchCV و Optuna که به‌طور گسترده برای تنظیم دقیق مدل‌ها و افزایش عملکرد آن‌ها به کار رفته‌اند (Dhanka et al. 2023) و (Simegn et al. 2022). علاوه بر این، رویکردهای پیشرفته‌تری نظیر بهینه‌سازی‌های اصلاح‌شده (مانند بهینه‌سازی اصلاح‌شده پروانه-شعله<sup>۱</sup> (MMFO) برای افزایش همگرایی شبکه‌های عصبی MLP (Ahmadian et al. 2022) و بهینه‌سازی خودکار طبقه‌بندی شده ازدحام ذرات بهبودیافته<sup>۲</sup> (IACPSO) (Dubey et al. 2022) برای بهینه‌سازی انتخاب ویژگی) و الگوریتم‌های خاص مانند TPE (Cocianu et al. 2023) (برای بهینه‌سازی شبکه‌های LSTM)،

---

1. Modified Moth-Flame Optimization (MMFO)

2. Improved Auto Categorical Particle Swarm Optimization (IACPSO)

بهینه‌سازی مبتنی بر جغرافیای زیستی<sup>۱</sup> (BBO)، الگوریتم بهینه‌سازی سنجاقک<sup>۲</sup> (DFO) و خوشه‌بندی فضایی مبتنی بر چگالی<sup>۳</sup> (DBSCAN) (Sheeba et al. 2022) نیز با مدل‌های EL/ML ادغام شده‌اند. این تکنیک‌ها، شامل تنظیم معیارهایی مانند اندازه دسته، نرخ یادگیری و توابع فعال‌سازی هستند. همچنین تعدادی از الگوریتم‌های بهینه‌سازی پیشرفته‌ای همچون بهینه‌سازی شکارچیان دریایی<sup>۴</sup> (MPA)، بهینه‌سازی فراابتکاری<sup>۵</sup> (MHO) و بهینه‌سازی کرم شب‌تاب<sup>۶</sup> (FFO) در مطالعات دیگر استفاده شده‌اند. در نهایت، بهینه‌سازهایی مانند Grid Search CV، Adam Optimizer، RMSprop و Adagrad، همراه با روش‌های سیستماتیک‌تر مانند برآورد پارزن با ساختار درختی<sup>۷</sup> (TPE) و RandomizedSearchCV، نقش مهمی در بهبود دقت و استحکام مدل‌های مورد استفاده در مدیریت بیماری‌های قلبی عروقی (CVD) ایفا می‌کنند.

جدول هشتم یک نمای کلی از دسته‌بندی‌های ابرپارامترها و تکنیک‌های مربوط به آن‌ها که در مدل‌های EL و ML/DL برای مدیریت CVD استفاده شده‌اند، ارائه می‌دهد. دسته اول، معیارهای تنظیم فراپارامتر، اهمیت تنظیم دقیق پارامترها را برای دستیابی به عملکرد بهینه مدل برجسته می‌کند. در مجموع ۳۴ مقاله از تکنیک‌های تنظیم فراپارامتر عمومی در کار خود استفاده کرده‌اند که برخی از قابل توجه‌ترین آن‌ها شامل اصلاح اندازه دسته، نرخ یادگیری و کاربرد تابع فعال‌سازی SoftMax است. دسته مدل‌های بهینه‌سازی، استفاده از الگوریتم‌های پیشرفته برای یافتن پیکربندی پارامترهای بهینه با استفاده از روش‌های بهینه‌سازی را به نمایش می‌گذارد. در نهایت، دسته بهینه‌سازها طیف متنوعی از استراتژی‌ها را نشان می‌دهد که Grid Search CV و Adam Optimizer متداول‌ترین روش‌هایی هستند که برای انتخاب هایپرپارامتر استفاده می‌شوند.

- 
1. Biogeographic-based optimization (BBO)
  2. Dragonfly Optimization (DFO)
  3. Density-Based Spatial Clustering of Applications with Noise (DBSCAN)
  4. Marine Predators Algorithm (MPA)
  5. Metaheuristic Optimization (MHO)
  6. Firefly Optimization (FFO)
  7. Tree-structured Parzen Estimation (TPE)

جدول ۸. طبقه‌بندی ابرپارامترها، بهینه‌سازها و تکنیک‌های مرتبط بکار گرفته شده در مدل‌های EL و ML/DL برای مدیریت CVD ها در مطالعات، همراه با فراوانی آن‌ها.

تکنیک	دسته‌بندی های پارامترها
تنظیم هایپرپارامتر (۳۴)، Batch Size (۳)، نرخ یادگیری (۳)، Max Soft (۳)، Maxpooling (۲)، اندازه تست (۱)، نرمال‌سازی دسته‌ای (۱)، تکرار (۱)	معیارهای تنظیم هایپرپارامتر
الگوریتم‌های IACPSO، BBO (۱)، DFO (۱)، FFO (۱)، MHO (۱)، MPA (۱)، PSO (۱)	مدل‌های بهینه‌سازی
Grid search CV (۵)، بهینه‌ساز آدام (۴)، بهینه‌ساز RMSprop (ریشه میانگین مربع) (۳)، بهینه‌ساز آداگراد (۲)، برآورد پارزن ساختار درختی (TPE) (۱)، بهینه‌ساز AdaDelta (۱)، بهینه‌ساز AMSGrad Adam (۱)، بهینه‌ساز RMSProp (۱)، بهینه‌ساز Centered (۱)، بهینه‌ساز Nesterov SGD (۱)، بهینه‌ساز Ftrl (۱)، بهینه‌ساز AdaMax (۱)، جستجوی شبکه تصادفی (۱)، RandomizedSearchCV (۱)، بهینه‌سازی جستجوی تصادفی (۱)	بهینه‌سازها

#### - تقسیم و اعتبارسنجی داده‌ها

تقسیم و اعتبارسنجی داده‌ها برای ارزیابی معتبر مدل‌ها ضروری است. تکنیک‌های اعتبارسنجی، تخمین قوی از عملکرد مدل را بدون برازش بیش‌ازحد و برآوردهای دقیق ارائه می‌دهد. روش‌هایی مانند اعتبارسنجی متقابل k-fold (به‌عنوان مثال، ۳-۵-۱۰ برابر و ۲۰-تکرار)، تقسیمات آزمون-تست (به‌عنوان مثال، ۷۰-۳۰٪ یا ۸۰-۲۰٪) و رویکرد بوت استرپ برای جلوگیری از برازش بیش‌ازحد و ارائه برآوردهای عملکرد سازگار در اکثر مطالعات استفاده شده‌اند. این تکنیک‌های اعتبارسنجی معمولاً با تکنیک‌های بهینه‌سازی مانند جستجوی شبکه و تنظیم فراپارامترها برای بهینه‌سازی پارامترهای مدل و به حداکثر رساندن دقت ترکیب شده‌اند. جدول نهم توزیع چین‌های اعتبارسنجی متقابل مورد استفاده در مطالعات مختلف را برجسته می‌کند. اعتبارسنجی متقابل ۱۰ برابری متداول‌ترین تکنیک است که در ۳۸ مقاله استفاده شده است که تعادل را بین کارایی محاسباتی و ارزیابی مدل قابل اعتماد منعکس می‌کند. اعتبارسنجی متقابل ۳-۵ برابری که ۷ بار بکار قرار گرفته شده، زمانی استفاده می‌شود که اندازه مجموعه داده محدود باشد، یا مدل‌ها باید فوراً آزمایش

شوند. علاوه بر این، روش‌های پیشرفته مانند اعتبارسنجی متقابل ۱۱ برابر، ۱۹ برابر و حتی (Al-Yarimi 2022) k-fold Leave-Pair-Out (LPOCV) یک‌بار اعمال شده‌اند که در حوزه‌های خاصی که ارزیابی عملکرد بالا ضروری است، صورت گرفته‌اند.

جدول ۹. توزیع فولدهای اعتبارسنجی متقابل مورد استفاده در مطالعات مختلف.

فراوانی	فولدهای اعتبارسنجی متقابل
۳۸	۱۰ فولد
۷	۳-۵ فولد
هر مورد یک‌بار	اعتبارسنجی متقابل ۱۱ فولد، ۱۹ فولد، k-fold Leave-Pair-Out (LPOCV)

#### - ابزارهای توضیح‌پذیری

تکنیک مقادیر SHAP در مطالعات مختلف به‌طور گسترده برای قابلیت تفسیر مدل‌ها استفاده شده‌اند که چگونگی نقش و اهمیت ویژگی‌های مختلف در مدل‌های تشخیصی و پیش‌بینی را توضیح می‌دهد. به‌عنوان مثال، در مطالعات (Islam et al. 2023; Torres et al. 2023) SHAP برای تجزیه و تحلیل اهمیت ویژگی استفاده شده، در حالی که در مطالعه (Moreno-Sanchez 2023)، از تکنیک XAI هوش برای همین منظور استفاده شده است. در مطالعه (Baghdadi et al. 2023) از مقادیر SHAP برای شناسایی و تبیین ویژگی‌های تأثیرگذار در پیش‌بینی و تحلیل اهمیت ویژگی بهره‌برده است. بعضی از مطالعات نیز تکنیک‌های دیگری را استفاده کرده‌اند. به‌عنوان مثال، در مطالعه (Al-Absi et al. 2022)، از تکنیک GradCAM به‌عنوان ابزاری برای تفسیر مدل‌های DL و شناسایی ویژگی‌های مهم استفاده شده است.

#### - تکنیک‌های همجوشی و تحلیل چند سطحی

تجزیه و تحلیل چند سطحی با ادغام اطلاعات از منابع متعدد، دقت طبقه‌بندی را افزایش می‌دهد. استراتژی‌های ادغام در سطوح مختلف - مانند ادغام در داده‌ها، ویژگی‌ها و تصمیم‌گیری - برای استفاده از اطلاعات مکمل استفاده شده‌اند. ترکیب داده‌ها و ویژگی‌ها

از منابع متعدد (به‌عنوان مثال، سیگنال‌های ECG) به‌طور قابل توجهی دقت پیش‌بینی را بهبود می‌بخشند. به‌عنوان مثال، برای یکپارچه‌سازی ویژگی‌ها، مطالعه (Guo et al. 2020) از مدل‌های خطی و تکنیک RF جهت افزایش عملکرد پیش‌بینی استفاده کرده است. به‌طور مشابه، مطالعه (Shi et al. 2021) تحلیل همبستگی متعارف تشخیصی (DCCA) را همراه با استخراج ویژگی‌ها از طریق شبکه‌های ResNet و GRU بکار گرفته است. علاوه بر این، مدل‌های مبتنی بر CNN که با تکنیک‌های مهندسی ویژگی‌ها ادغام شده‌اند، به‌دقت بالایی دست یافته‌اند، مانند مطالعه (Zhanquan et al. 2022) که دقت طبقه‌بندی ۹۸٫۴۱ درصدی را با استفاده از ترکیبی از ویژگی‌های استخراج‌شده به‌صورت دستی و مبتنی بر DL را گزارش داده است (Zhanquan et al. 2022). یادگیری چندوجهی یکی دیگر از راهبردهای مؤثر برای بهبود عملکرد پیش‌بینی کننده با ترکیب روش‌های مختلف داده است. به‌عنوان مثال، مطالعه (AI-Absi et al. 2022) از یک رویکرد یادگیری چندوجهی جهت ادغام تصاویر شبکه‌ای و DXA استفاده کرده که منجر به افزایش دقت و قابلیت تفسیر مدل شده است. با تکنیک‌های یادگیری چندوجهی، می‌توان منابع داده ناهمگن را برای پیش‌بینی بهتر ترکیب کرد. به‌عنوان مثال، تکنیک تجزیه حالت تجربی که عمدتاً یک تکنیک پردازش سیگنال برای تجزیه و تحلیل سیگنال‌های غیر ثابت، مانند داده‌های ECG است، می‌تواند برای استخراج و طبقه‌بندی ویژگی‌های پیچیده استفاده شود. اگرچه EMD به‌طور مستقیم به‌عنوان یک پارادایم یادگیری چندوجهی استفاده نمی‌شود، اما می‌تواند مدل‌های چندوجهی را با افزایش کیفیت ویژگی استخراج‌شده توسط ECG قبل از ادغام با روش‌های اضافی، مانند تاریخچه بالینی یا داده‌های تصویری، تسهیل کند. با بهبود سیگنال ECG و عملکرد طبقه‌بندی بالاتر، EMD می‌تواند به‌عنوان یک ابزار پیش‌پردازش در پارادایم‌های یادگیری چندوجهی استفاده شود که در آن اطلاعات از منابع مختلف ترکیب می‌شوند تا تشخیص قوی CVD را امکان‌پذیر کند (Lilda et al. 2022). علاوه بر این تکنیک‌ها، تکنیک‌های افزایش داده‌ها به رفع مشکلات داده‌های ازدست‌رفته کمک می‌کند. مطالعه (Kokol et al. 2021) استفاده از تولید داده‌های مصنوعی را به‌عنوان روشی

برای جبران سوابق از دست رفته، اطمینان از کامل بودن داده‌ها و استحکام مدل، اهمیت این تکنیک را برجسته کرده است.

### بحث و نتیجه‌گیری

نتایج این مطالعه نشان می‌دهد که مدل‌های یادگیری گروهی (EL) نقش کلیدی در مدیریت بیماری‌های قلبی عروقی دارند و در چهار طبقه اصلی شامل پیش‌بینی، تشخیص، شناسایی و طبقه‌بندی بیماری‌ها مورد استفاده قرار می‌گیرند. یافته‌ها نشان می‌دهد که ترکیب مدل‌های EL با یادگیری ماشین (ML) و یادگیری عمیق (DL) می‌تواند دقت و کارایی تشخیصی را بهبود بخشد. به‌طور خاص، مدل‌های جنگل تصادفی (RF) و روش‌های تقویت‌کننده مانند XGBoost به دلیل قابلیت بالای آن‌ها در مدیریت داده‌های نامتوازن، مقاومت در برابر نویز، جلوگیری از بیش‌برازش و توانایی ترکیب تصمیم‌گیری چند درخت در قالب یادگیری گروهی، دقت بالاتری نسبت به مدل‌های منفرد به دست آورده‌اند و از موفق‌ترین روش‌های مورد استفاده در مطالعات مرتبط بوده‌اند. با استفاده از مجموعه داده‌های بزرگ و متنوع، این رویکردها امکان شناسایی الگوهای پیچیده و ارائه پیش‌بینی‌های دقیق‌تر را فراهم می‌کنند که می‌تواند منجر به بهبود فرآیندهای تصمیم‌گیری بالینی و کاهش خطاهای تشخیصی شود. همچنین نقش DL در دو دسته شناسایی و طبقه‌بندی بیماری‌های قلبی عروقی نسبت به دودسته دیگر مشهودتر بود. دلیل این امر پیچیدگی داده‌ها و سیگنال‌ها از جمله ECG، تصاویر و صداهای قلب است که در شناسایی و طبقه‌بندی CVD استفاده می‌شود. معماری‌های مختلف DL در این دو دسته بسیار قدرتمندتر از الگوریتم‌های ML و مدل‌های گروهی ظاهر شده‌اند و به دقت و عملکرد بسیار بهتری دست یافته‌اند. یافته‌ها نشان می‌دهد که در این دو مقوله بیشترین الگوریتم‌هایی که با مدل‌های DL ترکیب شده‌اند شامل CNN و LSTM است. نتایج خوبی داشته‌اند، مدل‌های RF و XGB هستند که نشان‌دهنده درهم تنیدگی مدل‌های DL با EL است که روند نوظهوری را نشان می‌دهد.

یکی دیگر از ترکیب‌های مهم در مطالعات بررسی شده، نقش پیش‌پردازش داده‌ها و

مهندسی ویژگی است که تکنیک‌های آن نقش اساسی در بهبود عملکرد، دقت، قابلیت اطمینان و تعمیم‌پذیری مدل‌های مورد استفاده در مدیریت CVD ها دارد. تکنیک‌های حذف نویز و داده‌های پرت، متعادل کردن مجموعه داده‌ها و کلاس‌ها و قابلیت تفسیر مدل به این پیشرفت‌ها کمک کرده است. در این میان، نقش تکنیک‌هایی مانند SMOTE و SHAP بسیار مشهود است.

علاوه بر این، این مطالعه به محدودیت‌های مدل‌های EL نیز پرداخته است. بسیاری از مطالعات بررسی شده از مجموعه داده‌های کوچک و غیرمتوازن استفاده کرده‌اند که می‌تواند بر استحکام آماری و تعمیم‌پذیری مدل‌ها تأثیر منفی بگذارد. کیفیت داده‌ها، از جمله وجود نویز در سیگنال‌های ECG یا تصاویر پزشکی با وضوح پایین، نیز یکی از چالش‌های رایج بوده است. علاوه بر این، فقدان داده‌های دموگرافیک و بالینی کامل و نبود اعتبارسنجی خارجی در برخی مطالعات، ارزیابی عملکرد مدل‌ها را محدود می‌کند. از منظر فنی، مدل‌های یادگیری عمیق و گروهی اگرچه دقت بالایی دارند، اما به منابع محاسباتی زیاد نیاز دارند و اغلب فاقد قابلیت تفسیر کافی هستند که این امر بر پذیرش بالینی آن‌ها تأثیر می‌گذارد. همچنین، در بسیاری از موارد، مدل‌ها بر روی جمعیت‌های خاص آموزش داده شده‌اند و در نتیجه ممکن است در محیط‌های دنیای واقعی یا داده‌های چندمرکزی عملکرد مشابهی نداشته باشند. در نهایت، هزینه محاسباتی بالا، محدودیت در پردازش بلادرنگ و شکاف در ارزیابی کاربردهای واقعی از دیگر چالش‌هایی است که باید در پژوهش‌های آینده مورد توجه قرار گیرد.

به طور کلی، یافته‌های این مطالعه می‌تواند بینش‌های ارزشمندی را برای پژوهشگران و متخصصان حوزه هوش مصنوعی و سلامت فراهم کند و مسیر پژوهش‌های آینده را در استفاده از مدل‌های ترکیبی یادگیری روشن نماید. با توجه به روندهای نوظهور در مطالعات اخیر، پیشنهاد می‌شود پژوهش‌های آتی بر توسعه چارچوب‌های ترکیبی هوشمند مبتنی بر تلفیق مدل‌های ML، DL و EL متمرکز شوند که بتوانند به صورت تطبیقی و خودکار، نوع داده‌های ورودی (مانند سیگنال‌های ECG، تصاویر پزشکی و داده‌های بالینی

چندوجهی) را شناسایی و مناسب‌ترین الگوریتم را برای تحلیل آن انتخاب کنند. به‌طور خاص، پژوهش‌های آینده می‌توانند به طراحی مدل‌های هیبریدی مبتنی بر CNN-RF، LSTM-XGBoost یا AutoML-EL پردازند که علاوه بر بهبود دقت، قابلیت تفسیر بالینی، کارایی محاسباتی و پردازش بلادرنگ را افزایش دهند. همچنین، توسعه‌ی این چارچوب‌ها بر روی مجموعه داده‌های چندمرکزی و ناهمگون می‌تواند گامی مهم در جهت افزایش تعمیم‌پذیری و قابلیت کاربرد در محیط‌های واقعی سلامت دیجیتال باشد. در مسیر تحقیقاتی آینده، بهره‌گیری از هوش مصنوعی مولد (Generative AI) و هوش مصنوعی عاملی (Agentic AI) می‌تواند مسیر نوینی در ترکیب با مدل‌های یادگیری گروهی برای مدیریت CVD ها فراهم کند. GenAI با توانایی تولید داده‌های واقع‌گرایانه و رفع عدم توازن مجموعه داده‌ها، می‌تواند عملکرد مدل‌های ترکیبی را ارتقا دهد. در مقابل، Agentic AI با قابلیت تصمیم‌گیری تطبیقی و تعامل پویا با داده‌های بالینی، می‌تواند نقش مؤثری در توسعه‌ی سامانه‌های تشخیص و نظارت بلادرنگ ایفا کند. ادغام این رویکردها با چارچوب‌های EL، زمینه‌ساز نسل جدیدی از سیستم‌های هوشمند سلامت مبتنی بر یادگیری خودکار و داده‌محور خواهد بود.

### تعارض منافع

نویسندگان اعلام می‌دارند هیچ تعارض منافی در رابطه با نویسندگی و یا انتشار این مقاله وجود ندارد.

### ORCID

Mahmoud Zahedian Nezhad		<a href="https://orcid.org/0000-0001-6466-9828">https://orcid.org/0000-0001-6466-9828</a>
Mohammad Mehraeen		<a href="http://orcid.org/0000-0002-4154-8975">http://orcid.org/0000-0002-4154-8975</a>
Rouhollah Bagheri		<a href="https://orcid.org/0000-0003-3154-7466">https://orcid.org/0000-0003-3154-7466</a>
Seyyed Mohammad Tabatabaei		<a href="https://orcid.org/0000-0002-3153-8968">https://orcid.org/0000-0002-3153-8968</a>

## References

1. Aarthy, S. T., and J. L. Mazher Iqbal. 2024. "A Novel Deep Learning Approach for Early Detection of Cardiovascular Diseases from ECG Signals." *MEDICAL ENGINEERING & PHYSICS* 125. doi: 10.1016/j.medengphy.2024.104111.
2. Abdullah, Azween, S. Nithya, M. Mary Shanthi Rani, S. Vijayalakshmi, and Balamurugan Balusamy. 2023. "Stacked LSTM and Kernel-PCA-Based Ensemble Learning for Cardiac Arrhythmia Classification." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 14(9):39–48.
3. Ahamed, Jameel, Abdul Manan Koli, Khaleel Ahmad, Mohd Alam Jamal, and B. B. Gupta. 2022. "CDPS-IoT: Cardiovascular Disease Prediction System Based on IoT Using Machine Learning." *INTERNATIONAL JOURNAL OF INTERACTIVE MULTIMEDIA AND ARTIFICIAL INTELLIGENCE* 7(4):78–86. doi: 10.9781/ijimai.2021.09.002.
4. Ahamed, Jameel, Roohie Naaz Mir, and Mohammad Ahsan Chishti. 2022. "Industry 4.0 Oriented Predictive Analytics of Cardiovascular Diseases Using Machine Learning, Hyperparameter Tuning and Ensemble Techniques." *INDUSTRIAL ROBOT-THE INTERNATIONAL JOURNAL OF ROBOTICS RESEARCH AND APPLICATION* 49(3, SI):544–54. doi: 10.1108/IR-10-2021-0240.
5. Ahmadian, Sajad, Seyed Mohammad Jafar Jalali, Saeid Raziani, and Abdolah Chalechale. 2022. "An Efficient Cardiovascular Disease Detection Model Based on Multilayer Perceptron and Moth-Flame Optimization." *EXPERT SYSTEMS* 39(4, SI). doi: 10.1111/exsy.12914.
6. Ahn, Imjin, Hansle Gwon, Heejun Kang, Yunha Kim, Hyeram Seo, Heejung Choi, Ha Na Cho, Minkyung Kim, Tae Joon Jun, and Young-Hak Kim. 2021. "Machine Learning-Based Hospital Discharge Prediction for Patients With Cardiovascular Diseases: Development and Usability Study." *JMIR MEDICAL INFORMATICS* 9(11). doi: 10.2196/32662.
7. Al-Absi, Hamada R. H., Mohammad Tariqul Islam, Mahmoud Ahmed Refaee, Muhammad E. H. Chowdhury, and Tanvir Alam. 2022. "Cardiovascular Disease Diagnosis from DXA Scan and Retinal Images Using Deep Learning." *SENSORS* 22(12). doi: 10.3390/s22124310.
8. Al-Yarimi, Fuad Ali Mohammed. 2022. "Handling High Dimensionality in Ensemble Learning for Arrhythmia Prediction." *INTELLIGENT AUTOMATION AND SOFT COMPUTING* 32(3):1729–42. doi: 10.32604/iasc.2022.022418.

9. Alfaidi, Aseel, Reem Aljuhani, Bushra Alshehri, Hajer Alwadei, and Sahar Sabbeh. 2022. "Machine Learning: Assisted Cardiovascular Diseases Diagnosis." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 13(2):135–41.
10. Ali, Md Mamun, Bikash Kumar Paul, Kawsar Ahmed, Francis M. Bui, Julian M. W. Quinn, and Mohammad Ali Moni. 2021. "Heart Disease Prediction Using Supervised Machine Learning Algorithms: Performance Analysis and Comparison." *COMPUTERS IN BIOLOGY AND MEDICINE* 136. doi: 10.1016/j.combiomed.2021.104672.
11. Alotaibi, Aziz. 2025. "Ensemble Deep Learning Approaches in Health Care: A Review." *Computers, Materials & Continua* 82(3).
12. Alreshidi, Fayez Saud, Mohammad Alsaffar, Rajeswari Chengoden, and Naif Khalaf Alshammari. 2024. "Fed-CL-an Atrial Fibrillation Prediction System Using ECG Signals Employing Federated Learning Mechanism." *Scientific Reports* 14(1):21038.
13. An, Ying, Nengjun Huang, Xianlai Chen, FangXiang Wu, and Jianxin Wang. 2021. "High-Risk Prediction of Cardiovascular Diseases via Attention-Based Deep Neural Networks." *IEEE-ACM TRANSACTIONS ON COMPUTATIONAL BIOLOGY AND BIOINFORMATICS* 18(3):1093–1105. doi: 10.1109/TCBB.2019.2935059.
14. Anbumani, Menaga, and Kannan Kaniyaiah. 2024. "Soft Set-Based Parameter Reduction Algorithm Through a Discernibility Matrix and the Hybrid Approach for the Risk-Factor Prediction of Cardiovascular Diseases by Various Machine Learning Techniques." *PERTANIKA JOURNAL OF SCIENCE AND TECHNOLOGY* 32(1):265–84. doi: 10.47836/pjst.32.1.16.
15. Ansari, Yaqoob, Omar Mourad, Khalid Qaraqe, and Erchin Serpedin. 2023. "Deep Learning for ECG Arrhythmia Detection and Classification: An Overview of Progress for Period 2017-2023." *FRONTIERS IN PHYSIOLOGY* 14. doi: 10.3389/fphys.2023.1246746.
16. Ardeti, Venkata Anuhya, Venkata Ratnam Kolluru, George Tom Varghese, and Rajesh Kumar Patjoshi. 2022. "An Outlier Detection and Feature Ranking Based Ensemble Learning for ECG Analysis." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 13(6):727–37.
17. Azmi, Javed, Muhammad Arif, Md Tabrez Nafis, M. Afshar Alam, Safdar Tanweer, and Guojun Wang. 2022. "A Systematic Review on Machine Learning Approaches for Cardiovascular Disease Prediction Using Medical Big Data." *MEDICAL ENGINEERING & PHYSICS* 105. doi: 10.1016/j.medengphy.2022.103825.
18. Baghdadi, Nadiah A., Sally Mohammed Farghaly Abdelaliem, Amer

- Malki, Ibrahim Gad, Ashraf Ewis, and Elsayed Atlam. 2023. "Advanced Machine Learning Techniques for Cardiovascular Disease Early Detection and Diagnosis." *JOURNAL OF BIG DATA* 10(1). doi: 10.1186/s40537-023-00817-1.
19. Balaha, Hossam Magdy, Ahmed Osama Shaban, Eman M. El-Gendy, and Mahmoud M. Saafan. 2022. "A Multi-Variate Heart Disease Optimization and Recognition Framework." *NEURAL COMPUTING & APPLICATIONS* 34(18, SI):15907–44. doi: 10.1007/s00521-022-07241-1.
  20. Barriada, Ruben G., Olga Simo-Servat, Alejandra Planas, Cristina Hernandez, Rafael Simo, and David Masip. 2022. "Deep Learning of Retinal Imaging: A Useful Tool for Coronary Artery Calcium Score Prediction in Diabetic Patients." *APPLIED SCIENCES-BASEL* 12(3). doi: 10.3390/app12031401.
  21. Baseer, K. K., K. Sivakumar, Duggineni Veeraiah, Gunjan Chhabra, Prasanna Kumar Lakineni, M. Jahir Pasha, Ramu Gandikota, and Gopakumar Harikrishnan. 2024. "Healthcare Diagnostics with an Adaptive Deep Learning Model Integrated with the Internet of Medical Things (IoMT) for Predicting Heart Disease." *BIOMEDICAL SIGNAL PROCESSING AND CONTROL* 92. doi: 10.1016/j.bspc.2024.105988.
  22. Bertsimas, Dimitris, Alison Rose Ann Borenstein, Antonin Dauvin, and Agni Orfanoudaki. 2022. "Ensemble Machine Learning for Personalized Antihypertensive Treatment." *NAVAL RESEARCH LOGISTICS* 69(5):669–88. doi: 10.1002/nav.22040.
  23. Bhatt, Chintan M., Parth Patel, Tarang Ghetia, and Pier Luigi Mazzeo. 2023. "Effective Heart Disease Prediction Using Machine Learning Techniques." *ALGORITHMS* 16(2). doi: 10.3390/a16020088.
  24. Boulkaboul, Sahar, Samira Bouchama, Syphax Kasser, and Belkacem Ait Si Ali. 2024. "D-Resnet: Deep Resnet Based Approach for ECG Classification." *CONTROL ENGINEERING AND APPLIED INFORMATICS* 26(1):64–71.
  25. Cao, Kerang, Chang Liu, Siqi Yang, Yuxin Zhang, Lili Li, Hoekyung Jung, and Shuo Zhang. 2025. "Prediction of Cardiovascular Disease Based on Multiple Feature Selection and Improved PSO-XGBoost Model." *Scientific Reports* 15(1):12406.
  26. Celermajer, David S., Clara K. Chow, Eloï Marijon, Nicholas M. Anstey, and Kam S. Woo. 2012. "Cardiovascular Disease in the Developing World: Prevalences, Patterns, and the Potential of Early Disease Detection." *Journal of the American College of Cardiology* 60(14):1207–16.
  27. Chalapathi, Mukkoti Maruthi Venkata, Dudekula Khasim Vali,

- Yellapragada Venkata Pavan Kumar, Challa Pradeep Reddy, and Purna Prakash Kasaraneni. 2024. "AN INSIGHT INTO VIABLE MACHINE LEARNING MODELS FOR EARLY DIAGNOSIS OF CARDIOVASCULAR DISEASE." *SCALABLE COMPUTING-PRACTICE AND EXPERIENCE* 25(1, SI). doi: 10.12694/scpe.v25i1.2326.
28. Chen, Liang, Zhijun Han, Junhong Wang, and Chengjian Yang. 2022. "The Emerging Roles of Machine Learning in Cardiovascular Diseases: A Narrative Review." *ANNALS OF TRANSLATIONAL MEDICINE* 10(10). doi: 10.21037/atm-22-1853.
29. Chen, Shuwen, Jiaming Qi, Shicheng Fan, Zheng Qiao, Joo Chuan Yeo, and Chwee Teck Lim. 2021. "Flexible Wearable Sensors for Cardiovascular Health Monitoring." *Advanced Healthcare Materials* 10(17):2100116.
30. Chicco, Davide, and Giuseppe Jurman. 2020. "Machine Learning Can Predict Survival of Patients with Heart Failure from Serum Creatinine and Ejection Fraction Alone." *BMC MEDICAL INFORMATICS AND DECISION MAKING* 20(1). doi: 10.1186/s12911-020-1023-5.
31. Chorney, Wesley, and Sing Hui Ling. 2025. "Federated Learning Strategies for Atrial Fibrillation Detection." *Journal of Experimental and Theoretical Analyses* 3(3):23.
32. Chun, Matthew, Robert Clarke, Benjamin J. Cairns, David Clifton, Derrick Bennett, Yiping Chen, Yu Guo, Pei Pei, Jun Lv, Canqing Yu, Ling Yang, Liming Li, Zhengming Chen, Tingting Zhu, and China Kadoorie Biobank Collaborati. 2021. "Stroke Risk Prediction Using Machine Learning: A Prospective Cohort Study of 0.5 Million Chinese Adults." *JOURNAL OF THE AMERICAN MEDICAL INFORMATICS ASSOCIATION* 28(8):1719–27. doi: 10.1093/jamia/ocab068.
33. Cocianu, Catalina-Lucia, Cristian Razvan Uscatu, Konstantinos Kofidis, Sorin Muraru, and Alin Gabriel Vaduva. 2023. "Classical, Evolutionary, and Deep Learning Approaches of Automated Heart Disease Prediction: A Case Study." *ELECTRONICS* 12(7). doi: 10.3390/electronics12071663.
34. Daghistani, Tahani A., Radwa Elshawi, Sherif Sakr, Amjad M. Ahmed, Abdullah Al-Thwayee, and Mouaz H. Al-Mallah. 2019. "Predictors of In-Hospital Length of Stay among Cardiac Patients: A Machine Learning Approach." *INTERNATIONAL JOURNAL OF CARDIOLOGY* 288:140–47. doi: 10.1016/j.ijcard.2019.01.046.
35. Datta, Suparno, Ariane Morassi Sasso, Nina Kiwit, Subhronil Bose, Girish Nadkarni, Riccardo Miotto, and Erwin P. Boettinger. 2022. "Predicting Hypertension Onset from Longitudinal Electronic Health

- Records with Deep Learning.” *JAMIA OPEN* 5(4). doi: 10.1093/jamiaopen/ooac097.
36. Desai, Forum, Deepraj Chowdhury, Rupinder Kaur, Marloes Peeters, Rajesh Chand Arya, Gurpreet Singh Wander, Sukhpal Singh Gill, and Rajkumar Buyya. 2022. “HealthCloud: A System for Monitoring Health Status of Heart Patients Using Machine Learning and Cloud Computing.” *INTERNET OF THINGS* 17. doi: 10.1016/j.iot.2021.100485.
  37. Dhanka, Sanjay, Vibhor Kumar Bhardwaj, and Surita Maini. 2023. “Comprehensive Analysis of Supervised Algorithms for Coronary Artery Heart Disease Detection.” *EXPERT SYSTEMS* 40(7). doi: 10.1111/exsy.13300.
  38. Dinh, An, Stacey Miertschin, Amber Young, and Somya D. Mohanty. 2019. “A Data-Driven Approach to Predicting Diabetes and Cardiovascular Disease with Machine Learning.” *BMC MEDICAL INFORMATICS AND DECISION MAKING* 19(1). doi: 10.1186/s12911-019-0918-5.
  39. Divya, R., Finney Daniel Shadrach, and S. Padmaja. 2023. “Cardiovascular Risk Detection Using Harris Hawks Optimization with Ensemble Learning Model on PPG Signals.” *SIGNAL IMAGE AND VIDEO PROCESSING* 17(8):4503–12. doi: 10.1007/s11760-023-02684-y.
  40. Dritisas, Elias, and Maria Trigka. 2023. “Efficient Data-Driven Machine Learning Models for Cardiovascular Diseases Risk Prediction.” *SENSORS* 23(3). doi: 10.3390/s23031161.
  41. Du, Jinsong, Xiao Chang, Chunhong Ye, Yijun Zeng, Sijia Yang, Shan Wu, and Li Li. 2023. “Developing a Hypertension Visualization Risk Prediction System Utilizing Machine Learning and Health Check-up Data.” *SCIENTIFIC REPORTS* 13(1). doi: 10.1038/s41598-023-46281-y.
  42. Dubey, Animesh Kumar, Amit Kumar Sinhal, and Richa Sharma. 2022. “An Improved Auto Categorical PSO with ML for Heart Disease Prediction.” *ENGINEERING TECHNOLOGY & APPLIED SCIENCE RESEARCH* 12(3):8567–73.
  43. Eleyan, Alaa, and Ebrahim Alboghbaish. 2024. “Electrocardiogram Signals Classification Using Deep-Learning-Based Incorporated Convolutional Neural Network and Long Short-Term Memory Framework.” *COMPUTERS* 13(2). doi: 10.3390/computers13020055.
  44. Elvas, Luis B., Miguel Nunes, Joao C. Ferreira, Miguel Sales Dias, and Luis Bras Rosario. 2023. “AI-Driven Decision Support for Early Detection of Cardiac Events: Unveiling Patterns and Predicting Myocardial Ischemia.” *JOURNAL OF PERSONALIZED MEDICINE*

- 13(9). doi: 10.3390/jpm13091421.
45. Enad, Huda Ghazi, and Mazin Abed Mohammed. 2024. "Cloud Computing-Based Framework for Heart Disease Classification Using Quantum Machine Learning Approach." *JOURNAL OF INTELLIGENT SYSTEMS* 33(1). doi: 10.1515/jisys-2023-0261.
  46. Essa, Ehab, and Xianghua Xie. 2021. "An Ensemble of Deep Learning-Based Multi-Model for ECG Heartbeats Arrhythmia Classification." *IEEE ACCESS* 9:103452–64. doi: 10.1109/ACCESS.2021.3098986.
  47. Ghosh, Pronab, Sami Azam, Mirjam Jonkman, Asif Karim, F. M. Javed Mehedi Shamrat, Eva Ignatious, Shahana Shultana, Abhijith Reddy Beeravolu, and Friso De Boer. 2021. "Efficient Prediction of Cardiovascular Disease Using Machine Learning Algorithms With Relief and LASSO Feature Selection Techniques." *IEEE ACCESS* 9:19304–26. doi: 10.1109/ACCESS.2021.3053759.
  48. Gour, Sanjeev, Rajendra Randa, Karuna Nidhi Pandagre, Arpit Neema, Sangeeta Jat, and Deepak Malakar. 2025. "A Comprehensive Review on Predicting Heart Failure with Ensemble Learning: Integrating Environmental Variables and Health Perspectives." *International Journal of Environmental Sciences* 11(4s):959–73.
  49. Guarneros-Nolasco, Luis Rolando, Nancy Aracely Cruz-Ramos, Giner Alor-Hernandez, Lisbeth Rodriguez-Mazahua, and Jose Luis Sanchez-Cervantes. 2021. "Identifying the Main Risk Factors for Cardiovascular Diseases Prediction Using Machine Learning Algorithms." *MATHEMATICS* 9(20). doi: 10.3390/math9202537.
  50. Guo, Chunyan, Jiabing Zhang, Yang Liu, Yaying Xie, Zhiqiang Han, and Jianshe Yu. 2020. "Recursion Enhanced Random Forest With an Improved Linear Model (RERF-ILM) for Heart Disease Detection on the Internet of Medical Things Platform." *IEEE ACCESS* 8:59247–56. doi: 10.1109/ACCESS.2020.2981159.
  51. Gutierrez-Esparza, Guadalupe, Tomas Pulido, Mireya Martinez-Garcia, Tania Ramirez-delReal, Lucero E. Groves-Miralrio, Manlio F. Marquez-Murillo, Luis M. Amezcua-Guerra, Gilberto Vargas-Alarcon, and Enrique Hernandez-Lemus. 2023. "A Machine Learning Approach to Personalized Predictors of Dyslipidemia: A Cohort Study." *FRONTIERS IN PUBLIC HEALTH* 11. doi: 10.3389/fpubh.2023.1213926.
  52. Hassaballah, Mahmoud, Yaser M. M. Wazery, Ibrahim E. E. Ibrahim, and Aly Farag. 2023. "ECG Heartbeat Classification Using Machine Learning and Metaheuristic Optimization for Smart Healthcare Systems." *BIOENGINEERING-BASEL* 10(4). doi: 10.3390/bioengineering10040429.
  53. Hassan, Md. Mehedi, Sadika Zaman, Md. Mushfiqur Rahman, Anupam

- Kumar Bairagi, Walid El-Shafai, Rajkumar Singh Rathore, and Deepak Gupta. 2024. "Efficient Prediction of Coronary Artery Disease Using Machine Learning Algorithms with Feature Selection Techniques." *COMPUTERS & ELECTRICAL ENGINEERING* 115. doi: 10.1016/j.compeleceng.2024.109130.
54. He, Yi, Wuyou Li, Wangqi Zhang, Sheng Zhang, Xitian Pi, and Hongying Liu. 2021. "Research on Segmentation and Classification of Heart Sound Signals Based on Deep Learning." *APPLIED SCIENCES-BASEL* 11(2). doi: 10.3390/app11020651.
55. Henni, Fouad, Baghdad Atmani, Fatiha Atmani, and Fatima Saadi. 2023. "Improving Coronary Artery Disease Prediction: Use of Random Forest, Feature Importance and Case-Based Reasoning." *INTERNATIONAL JOURNAL OF DECISION SUPPORT SYSTEM TECHNOLOGY* 15(1). doi: 10.4018/ijdsst.319307.
56. Hosni, Mohamed, Juan M. de Gea, Ali Idri, Manal El Bajta, Jose Luis Fernandez Aleman, Gines Garcia-Mateos, and Ibtissam Abnane. 2021. "A Systematic Mapping Study for Ensemble Classification Methods in Cardiovascular Disease." *ARTIFICIAL INTELLIGENCE REVIEW* 54(4):2827–61. doi: 10.1007/s10462-020-09914-6.
57. Hossain, Ekramul, Shahadat Uddin, and Arif Khan. 2021. "Network Analytics and Machine Learning for Predictive Risk Modelling of Cardiovascular Disease in Patients with Type 2 Diabetes." *EXPERT SYSTEMS WITH APPLICATIONS* 164. doi: 10.1016/j.eswa.2020.113918.
58. Hsu, Wei-Yen. 2018. "A Decision-Making Mechanism for Assessing Risk Factor Significance in Cardiovascular Diseases." *DECISION SUPPORT SYSTEMS* 115:64–77. doi: 10.1016/j.dss.2018.09.004.
59. Hu, Zhixu, Hang Qiu, Ziqi Su, Minghui Shen, and Ziyu Chen. 2020. "A Stacking Ensemble Model to Predict Daily Number of Hospital Admissions for Cardiovascular Diseases." *IEEE ACCESS* 8:138719–29. doi: 10.1109/ACCESS.2020.3012143.
60. Husain, Mohammad, Pankaj Kumar, Mohammad Nadeem Ahmed, Arshad Ali, Mohammad Ashiquee Rasool, Mohammad Rashid Hussain, and Muhammad Shahid Dildar. 2023. "Harnessing Ensemble in Machine Learning for Accurate Early Prediction and Prevention of Heart Disease." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 14(10):182–95.
61. Ibarra, Rodrigo, Jaime Leon, Ivan Avila, and Hiram Ponce. 2022. "Cardiovascular Disease Detection Using Machine Learning." *COMPUTACION Y SISTEMAS* 26(4):1661–68. doi: 10.13053/CyS-26-4-4422.
62. Islam, Md. Merajul, Md. Jahangir Alam, Md Maniruzzaman, N. A. M.

- Faisal Ahmed, Md Sujan Ali, Md. Jahanur Rahman, and Dulal Chandra Roy. 2023. "Predicting the Risk of Hypertension Using Machine Learning Algorithms: A Cross Sectional Study in Ethiopia." *PLOS ONE* 18(8). doi: 10.1371/journal.pone.0289613.
63. Islam, Sheikh Mohammed Shariful, Ashis Talukder, Md. Abdul Awal, Md. Muhammad Umer Siddiqui, Md. Martuza Ahamad, Benojir Ahammed, Lal B. Rawal, Roohallah Alizadehsani, Jemal Abawajy, Liliana Laranjo, Clara K. Chow, and Ralph Maddison. 2022. "Machine Learning Approaches for Predicting Hypertension and Its Associated Factors Using Population-Level Data From Three South Asian Countries." *FRONTIERS IN CARDIOVASCULAR MEDICINE* 9. doi: 10.3389/fcvm.2022.839379.
64. Jentzer, Jacob C., Yogesh N. V Reddy, Sabri Soussi, Ruben Crespo-Diaz, Parag C. Patel, Patrick R. Lawler, Alexandre Mebazaa, and Shannon M. Dunlay. 2024. "Unsupervised Machine Learning to Identify Subphenotypes among Cardiac Intensive Care Unit Patients with Heart Failure." *ESC Heart Failure* 11(6):4242–56.
65. Jiang, Lili, Sirong Chen, Yuanhui Wu, Da Zhou, and Lihua Duan. 2023. "Prediction of Coronary Heart Disease in Gout Patients Using Machine Learning Models." *MATHEMATICAL BIOSCIENCES AND ENGINEERING* 20(3):4574–91. doi: 10.3934/mbe.2023212.
66. Karboub, Kaouter, and Mohamed Tabaa. 2022. "A Machine Learning Based Discharge Prediction of Cardiovascular Diseases Patients in Intensive Care Units." *HEALTHCARE* 10(6). doi: 10.3390/healthcare10060966.
67. Karthikeyan, N. K., and others. 2024. "A Novel Attention-Based Cross-Modal Transfer Learning Framework for Predicting Cardiovascular Disease." *Computers in Biology and Medicine* 170:107977.
68. Kim, Joung Ouk (Ryan), Yong-Suk Jeong, Jin Ho Kim, Jong-Weon Lee, Dougho Park, and Hyoung-Seop Kim. 2021. "Machine Learning-Based Cardiovascular Disease Prediction Model: A Cohort Study on the Korean National Health Insurance Service Health Screening Database." *DIAGNOSTICS* 11(6). doi: 10.3390/diagnostics11060943.
69. Kirboga, Kevser Kubra, and Ecir Ugur Kucuksille. 2023. "Identifying Cardiovascular Disease Risk Factors in Adults with Explainable Artificial Intelligence." *ANATOLIAN JOURNAL OF CARDIOLOGY* 27(11):657–63. doi: 10.14744/AnatolJCardiol.2023.3214.
70. Kokol, Peter, Jan Jurman, Tajda Bogovic, Tadej Završnik, Jernej Završnik, and Helena Blazun Vosner. 2021. "Supporting Real World Decision Making in Coronary Diseases Using Machine Learning." *INQUIRY-THE JOURNAL OF HEALTH CARE ORGANIZATION PROVISION AND FINANCING* 58. doi: 10.1177/0046958021997338.

71. Krittanawong, Chayakrit, Hafeez Ul Hassan Virk, Sripal Bangalore, Zhen Wang, Kipp W. Johnson, Rachel Pinotti, HongJu Zhang, Scott Kaplin, Bharat Narasimhan, Takeshi Kitai, Usman Baber, Jonathan L. Halperin, and W. H. Wilson Tang. 2020. "Machine Learning Prediction in Cardiovascular Diseases: A Meta-Analysis." *SCIENTIFIC REPORTS* 10(1). doi: 10.1038/s41598-020-72685-1.
72. Kumar, Deepak, Chaman Verma, Sanjay Dahiya, Pradeep Kumar Singh, Maria Simona Raboaca, Zoltan Illes, and Brijesh Bakariya. 2021. "Cardiac Diagnostic Feature and Demographic Identification (CDF-DI): An IoT Enabled Healthcare Framework Using Machine Learning." *SENSORS* 21(19). doi: 10.3390/s21196584.
73. Kumar, Pardeep, and Ankit Kumar. 2023. "Heart Disease Classification and Recommendation by Optimized Features and Adaptive Boost Learning." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 14(3):909–14.
74. Lacson, Ronilda C., Bowen Baker, Harini Suresh, Katherine Andriole, Peter Szolovits, and Eduardo Lacson Jr. 2019. "Use of Machine-Learning Algorithms to Determine Features of Systolic Blood Pressure Variability That Predict Poor Outcomes in Hypertensive Patients." *CLINICAL KIDNEY JOURNAL* 12(2):206–12. doi: 10.1093/ckj/sfy049.
75. Lambay, Muhib Anwar, and S. Pakkir Mohideen. 2024. "Applying Data Science Approach to Predicting Diseases and Recommending Drugs in Healthcare Using Machine Learning Models - A Cardio Disease Case Study." *MULTIMEDIA TOOLS AND APPLICATIONS*. doi: 10.1007/s11042-023-18035-5.
76. Latha, S., P. Muthu, Khin Wee Lai, Azira Khalil, and Samiappan Dhanalakshmi. 2022. "Performance Analysis of Machine Learning and Deep Learning Architectures on Early Stroke Detection Using Carotid Artery Ultrasound Images." *FRONTIERS IN AGING NEUROSCIENCE* 13. doi: 10.3389/fnagi.2021.828214.
77. Lee, Heechang, Taeyoung Yoon, Chaeyun Yeo, HyeonYoung Oh, Yebin Ji, Seongwoo Sim, and Daesung Kang. 2021. "Cardiac Arrhythmia Classification Based on One-Dimensional Morphological Features." *APPLIED SCIENCES-BASEL* 11(20). doi: 10.3390/app11209460.
78. Lee, Joonyub, Yera Choi, Taehoon Ko, Kanghyuck Lee, Juyoung Shin, and Hun-Sung Kim. 2024. "Prediction of Cardiovascular Complication in Patients with Newly Diagnosed Type 2 Diabetes Using an XGBoost/ GRU-ODE-Bayes-Based Machine-Learning Algorithm." *ENDOCRINOLOGY AND METABOLISM* 39(1):176–85. doi: 10.3803/EnM.2023.1739.
79. Lee, Woojoo, Youn-Hee Lim, Eunhee Ha, Yeonjin Kim, and Won

- Kyung Lee. 2022. "Forecasting of Non-Accidental, Cardiovascular, and Respiratory Mortality with Environmental Exposures Adopting Machine Learning Approaches (Vol 14, Pg 1, 2022)." *ENVIRONMENTAL SCIENCE AND POLLUTION RESEARCH* 29(58):88330. doi: 10.1007/s11356-022-22224-4.
80. Lertampaiporn, Supatcha, Apiradee Hongsthong, Warin Wattanapornprom, and Chinae Thammarongtham. 2022. "Ensemble-AHTPpred: A Robust Ensemble Machine Learning Model Integrated With a New Composite Feature for Identifying Antihypertensive Peptides." *FRONTIERS IN GENETICS* 13. doi: 10.3389/fgene.2022.883766.
81. Li, Qingqing, Wenhui Xie, Liping Li, Lijing Wang, Qinyi You, Lu Chen, Jing Li, Yilang Ke, Jun Fang, Libin Liu, and Huashan Hong. 2021. "Development and Validation of a Prediction Model for Elevated Arterial Stiffness in Chinese Patients With Diabetes Using Machine Learning." *FRONTIERS IN PHYSIOLOGY* 12. doi: 10.3389/fphys.2021.714195.
82. Li, Yung-Hui, Latifa Nabila Harfiya, Kartika Purwandari, and Yue-Der Lin. 2020. "Real-Time Cuffless Continuous Blood Pressure Estimation Using Deep Learning Model." *SENSORS* 20(19). doi: 10.3390/s20195606.
83. Lilda, S. Daphin, R. Jayaparvathy, and Akshaya Balaji. 2022. "An Efficient Machine Learning Based Ventricular Late Potential Detection and Classification Technique for Cardiac Healthcare." *CONCURRENCY AND COMPUTATION-PRACTICE & EXPERIENCE* 34(26). doi: 10.1002/cpe.7279.
84. Lo, Ying-Tsang, Hamido Fujita, and Tun-Wen Pai. 2016. "PREDICTION OF CORONARY ARTERY DISEASE BASED ON ENSEMBLE LEARNING APPROACHES AND CO-EXPRESSED OBSERVATIONS." *JOURNAL OF MECHANICS IN MEDICINE AND BIOLOGY* 16(1, SI). doi: 10.1142/S0219519416400108.
85. Louridi, Nabaouia, Samira Douzi, and Bouabid El Ouahidi. 2021. "Machine Learning-Based Identification of Patients with a Cardiovascular Defect." *JOURNAL OF BIG DATA* 8(1). doi: 10.1186/s40537-021-00524-9.
86. Lv, Haichen, Xiaolei Yang, Bingyi Wang, Shaobo Wang, Xiaoyan Du, Qian Tan, Zhujing Hao, Ying Liu, Jun Yan, and Yunlong Xia. 2021. "Machine Learning-Driven Models to Predict Prognostic Outcomes in Patients Hospitalized With Heart Failure Using Electronic Health Records: Retrospective Study." *JOURNAL OF MEDICAL INTERNET RESEARCH* 23(4). doi: 10.2196/24996.
87. Mahajan, Palak, Shahadat Uddin, Farshid Hajati, and Mohammad Ali

- Moni. 2023. "Ensemble Learning for Disease Prediction: A Review." P. 1808 in *Healthcare*. Vol. 11.
88. Maheshwari, Danyal, Ubaid Ullah, Pablo A. Osorio Marulanda, Alain Garcia-Olea Jurado, Ignacio Diez Gonzalez, Jose M. Ormaetxe Merodio, and Begonya Garcia-Zapirain. 2023. "Quantum Machine Learning Applied to Electronic Healthcare Records for Ischemic Heart Disease Classification." *HUMAN-CENTRIC COMPUTING AND INFORMATION SCIENCES* 13. doi: 10.22967/HCIS.2023.13.006.
89. Maqsood, Sumbal, Shuxiang Xu, Matthew Springer, and Rami Mohawesh. 2021. "A Benchmark Study of Machine Learning for Analysis of Signal Feature Extraction Techniques for Blood Pressure Estimation Using Photoplethysmography (PPG)." *IEEE ACCESS* 9:138817–33. doi: 10.1109/ACCESS.2021.3117969.
90. Miao, Kathleen H., Julia H. Miao, and George J. Miao. 2016. "Diagnosing Coronary Heart Disease Using Ensemble Machine Learning." *International Journal of Advanced Computer Science and Applications* 7(10).
91. Mishra, Aditya Dev, Ajay Kumar Shrivastava, and Megha Bhushan. 2025. "Disease Diagnosis and Control by Reinforcement Learning Techniques: A Systematic Literature Review." *Discover Computing* 28(1):129.
92. Mondal, Subhash, Ranjan Maity, Yachang Omo, Soumadip Ghosh, and Amitava Nag. 2024. "An Efficient Computational Risk Prediction Model of Heart Diseases Based on Dual-Stage Stacked Machine Learning Approaches." *IEEE ACCESS* 12:7255–70. doi: 10.1109/ACCESS.2024.3350996.
93. Moradi, Hamed, Akram Al-Hourani, Gianmarco Concilia, Farnaz Khoshmanesh, Farhad R. Nezami, Scott Needham, Sara Baratchi, and Khashayar Khoshmanesh. 2023. "Recent Developments in Modeling, Imaging, and Monitoring of Cardiovascular Diseases Using Machine Learning." *BIOPHYSICAL REVIEWS* 15(1, SI):19–33. doi: 10.1007/s12551-022-01040-7.
94. Moreno-Sanchez, Pedro A. 2023. "Improvement of a Prediction Model for Heart Failure Survival through Explainable Artificial Intelligence." *FRONTIERS IN CARDIOVASCULAR MEDICINE* 10. doi: 10.3389/fcvm.2023.1219586.
95. Moskaleva, Natalia E., Ksenia M. Shestakova, Alexey V Kukharenko, Pavel A. Markin, Maria V Kozhevnikova, Ekaterina O. Korobkova, Alex Brito, Sabina N. Baskhanova, Natalia V Mesonzhnik, Yuri N. Belenkov, Natalia V Pyatigorskaya, Elena Tobolkina, Serge Rudaz, and Svetlana A. Appolonova. 2022. "Target Metabolome Profiling-Based Machine Learning as a Diagnostic Approach for Cardiovascular

- Diseases in Adults.” *METABOLITES* 12(12). doi: 10.3390/metabo12121185.
96. Muhammad, Ghulam, Saad Naveed, Lubna Nadeem, Tariq Mahmood, Amjad R. Khan, Yasar Amin, and Saeed Ali Omer Bahaj. 2023. “Enhancing Prognosis Accuracy for Ischemic Cardiovascular Disease Using K Nearest Neighbor Algorithm: A Robust Approach.” *IEEE ACCESS* 11:97879–95. doi: 10.1109/ACCESS.2023.3312046.
  97. Nabel, Elizabeth G. 2003. “Cardiovascular Disease.” *New England Journal of Medicine* 349(1):60–72.
  98. Najafi, Amirhossein, Alireza Nemati, Mahdi Ashrafzadeh, and Sarfaraz Hashemkhani Zolfani. 2023. “Multiple-Criteria Decision Making, Feature Selection, and Deep Learning: A Golden Triangle for Heart Disease Identification.” *ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE* 125. doi: 10.1016/j.engappai.2023.106662.
  99. Najim, Ahmed Haitham, and Nejah Nasri. 2024. “Artificial Intelligence for Heart Disease Prediction and Imputation of Missing Data in Cardiovascular Datasets.” *COGENT ENGINEERING* 11(1). doi: 10.1080/23311916.2024.2325635.
  100. Navaei, Reza Lotfi, Mohammad Safarzadeh, and Seyed Mohammad Jafar Sobhani. 2025. “Optimizing Flamelet Generated Manifold Models: A Machine Learning Performance Study.” *ArXiv Preprint ArXiv:2507.01030*.
  101. Nissa, Najmu, Sanjay Jamwal, Mehdi Neshat, Yudong Zhang, and Francesco Cauteruccio. 2024. “A Technical Comparative Heart Disease Prediction Framework Using Boosting Ensemble Techniques.” *COMPUTATION* 12(1). doi: 10.3390/computation12010015.
  102. Noor, Ayesha, Nadeem Javaid, Nabil Alrajeh, Babar Mansoor, Ali Khaqan, and Safdar Hussain Bouk. 2023. “Heart Disease Prediction Using Stacking Model With Balancing Techniques and Dimensionality Reduction.” *IEEE ACCESS* 11:116026–45. doi: 10.1109/ACCESS.2023.3325681.
  103. Nucifora, Gaetano, Daniele Muser, Joshua Bradley, Zoi Tsoumani, Giulia De Angelis, Thomas Caiffa, Matthias Schmitt, Gianfranco Sinagra, and Chris Miller. 2025. “Unsupervised Phenotypic Clustering of Cardiac MRI Data Reveals Distinct Subgroups Associated with Outcomes in Ischemic Cardiomyopathy.” *The International Journal of Cardiovascular Imaging* 1–11.
  104. Oanh, Tran Thi, and Nguyen Thanh Tung. 2022. “Predicting Hypertension Based on Machine Learning Methods: A Case Study in Northwest Vietnam.” *MOBILE NETWORKS & APPLICATIONS* 27(5,

- SI):2013–23. doi: 10.1007/s11036-022-01984-w.
105. Ogunpola, Adedayo, Faisal Saeed, Shadi Basurra, Abdullah M. Albarrak, and Sultan Noman Qasem. 2024. “Machine Learning-Based Predictive Models for Detection of Cardiovascular Diseases.” *DIAGNOSTICS* 14(2). doi: 10.3390/diagnostics14020144.
  106. Ohashi, Yukitaka, Tomohiko Ihara, Kazutaka Oka, Yuya Takane, and Yukihiro Kikegawa. 2023. “Machine Learning Analysis and Risk Prediction of Weather-Sensitive Mortality Related to Cardiovascular Disease during Summer in Tokyo, Japan.” *SCIENTIFIC REPORTS* 13(1). doi: 10.1038/s41598-023-44181-9.
  107. Oliveira, Bruno Alberto Soares, Giulia Zanon Castro, Giovanna Luiza Medina Ferreira, and Frederico Gadelha Guimaraes. 2023. “CML-Cardio: A Cascade Machine Learning Model to Predict Cardiovascular Disease Risk as a Primary Prevention Strategy.” *MEDICAL & BIOLOGICAL ENGINEERING & COMPUTING* 61(6):1409–25. doi: 10.1007/s11517-022-02757-z.
  108. Oliveira, Mariana, Joana Seringa, Fausto Jose Pinto, Roberto Henriques, and Teresa Magalhaes. 2023. “Machine Learning Prediction of Mortality in Acute Myocardial Infarction.” *BMC MEDICAL INFORMATICS AND DECISION MAKING* 23(1). doi: 10.1186/s12911-023-02168-6.
  109. Ospina, Raydonal, Adenice G. O. Ferreira, Helio M. de Oliveira, Victor Leiva, and Cecilia Castro. 2023. “On the Use of Machine Learning Techniques and Non-Invasive Indicators for Classifying and Predicting Cardiac Disorders.” *BIOMEDICINES* 11(10). doi: 10.3390/biomedicines11102604.
  110. Ott, Gabriel, Yannik Schaubelt, Juan Miguel Lopez Alcaraz, Wilhelm Haverkamp, and Nils Strodthoff. 2024. “Using Explainable AI to Investigate Electrocardiogram Changes during Healthy Aging-From Expert Features to Raw Signals.” *PLOS ONE* 19(4). doi: 10.1371/journal.pone.0302024.
  111. Oyewola, David Opeoluwa, Emmanuel Gbenga Dada, and Sanjay Misra. 2024. “Diagnosis of Cardiovascular Diseases by Ensemble Optimization Deep Learning Techniques.” *INTERNATIONAL JOURNAL OF HEALTHCARE INFORMATION SYSTEMS AND INFORMATICS* 19(1). doi: 10.4018/IJHISI.334021.
  112. Pan, Chandan, Arnab Poddar, Rohan Mukherjee, and Ajoy Kumar Ray. 2022. “Impact of Categorical and Numerical Features in Ensemble Machine Learning Frameworks for Heart Disease Prediction.” *BIOMEDICAL SIGNAL PROCESSING AND CONTROL* 76. doi: 10.1016/j.bspc.2022.103666.
  113. Pandey, Saroj Kumar, Anupam Shukla, Surbhi Bhatia, Thippa Reddy

- Gadekallu, Ankit Kumar, Arwa Mashat, Mohd Asif Shah, and Rekh Ram Janghel. 2023. "Detection of Arrhythmia Heartbeats from ECG Signal Using Wavelet Transform-Based CNN Model." *INTERNATIONAL JOURNAL OF COMPUTATIONAL INTELLIGENCE SYSTEMS* 16(1). doi: 10.1007/s44196-023-00256-z.
114. Paul Navarrete, Jean, Jose Pinto, Rosa Liliana Figueroa, Maria Elena Lagos, Qing Zeng, and Carla Taramasco. 2022. "Supervised Learning Algorithm for Predicting Mortality Risk in Older Adults Using Cardiovascular Health Study Dataset." *APPLIED SCIENCES-BASEL* 12(22). doi: 10.3390/app122211536.
115. Pavic, Ognjen, Lazar Dasic, Tijana Geroski, Mina Vaskovic Jovanovic, and Nenad Filipovic. 2023. "RISK CLASSIFICATION FOR SUDDEN CARDIAC DEATH IN PATIENTS WITH HYPERTROPHIC CARDIOMYOPATHY BASED ON MACHINE LEARNING ALGORITHMS." *JOURNAL OF THE SERBIAN SOCIETY FOR COMPUTATIONAL MECHANICS* 17(2):153–65. doi: 10.24874/jsscm.2023.17.02.11.
116. Priyadarshi, Rahul, Rakesh Ranjan, Anish Kumar Vishwakarma, Tiansheng Yang, and Rajkumar Singh Rathore. 2024. "Exploring the Frontiers of Unsupervised Learning Techniques for Diagnosis of Cardiovascular Disorder: A Systematic Review." *IEEE Access*.
117. Rahim, Aqsa, Yawar Rasheed, Farooque Azam, Muhammad Waseem Anwar, Muhammad Abdul Rahim, and Abdul Wahab Muzaffar. 2021. "An Integrated Machine Learning Framework for Effective Prediction of Cardiovascular Diseases." *IEEE ACCESS* 9:106575–88. doi: 10.1109/ACCESS.2021.3098688.
118. Rahman, Md Saifur, Chandan Karmarkar, and Sheikh Mohammed Shariful Islam. 2024. "Application of Federated Learning in Cardiology: Key Challenges and Potential Solutions." *Mayo Clinic Proceedings: Digital Health* 2(4):590–95.
119. Rane, Nitin, Saurabh P. Choudhary, and Jayesh Rane. 2024. "Ensemble Deep Learning and Machine Learning: Applications, Opportunities, Challenges, and Future Directions." *Studies in Medical and Health Sciences* 1(2):18–41.
120. Reddy, Karna Vishnu Vardhana, Irraivan Elamvazuthi, Azrina Abd Aziz, Sivajothi Paramasivam, Hui Na Chua, and S. Pranavanand. 2021. "Heart Disease Risk Prediction Using Machine Learning Classifiers with Attribute Evaluators." *APPLIED SCIENCES-BASEL* 11(18). doi: 10.3390/app11188352.
121. Ribeiro, Pedro, Joana Sa, Daniela Paiva, and Pedro Miguel Rodrigues. 2024. "Cardiovascular Diseases Diagnosis Using an ECG Multi-Band Non-Linear Machine Learning Framework Analysis."

- BIOENGINEERING-BASEL* 11(1). doi: 10.3390/bioengineering11010058.
122. Roth, Gregory A., George A. Mensah, Catherine O. Johnson, Giovanni Addolorato, Enrico Ammirati, Larry M. Baddour, Noël C. Barengo, Andrea Z. Beaton, Emelia J. Benjamin, Catherine P. Benziger, and others. 2020. "Global Burden of Cardiovascular Diseases and Risk Factors, 1990--2019: Update from the GBD 2019 Study." *Journal of the American College of Cardiology* 76(25):2982–3021.
  123. Rustam, Furqan, Abid Ishaq, Kashif Munir, Mubarak Almutairi, Naila Aslam, and Imran Ashraf. 2022. "Incorporating CNN Features for Optimizing Performance of Ensemble Classifier for Cardiovascular Disease Prediction." *DIAGNOSTICS* 12(6). doi: 10.3390/diagnostics12061474.
  124. Sajid, Mirza Rizwan, Arshad Ali Khan, Haitham M. Albar, Noryanti Muhammad, Waqas Sami, Syed Ahmad Chan Bukhari, and Iram Wajahat. 2022. "Exploration of Black Boxes of Supervised Machine Learning Models: A Demonstration on Development of Predictive Heart Risk Score." *COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE* 2022. doi: 10.1155/2022/5475313.
  125. Sajid, Mirza Rizwan, Noryanti Muhammad, Roslinazairimah Zakaria, Ahmad Shahbaz, Syed Ahmad Chan Bukhari, Seifedine Kadry, and A. Suresh. 2021. "Nonclinical Features in Predictive Modeling of Cardiovascular Diseases: A Machine Learning Approach." *INTERDISCIPLINARY SCIENCES-COMPUTATIONAL LIFE SCIENCES* 13(2, SI):201–11. doi: 10.1007/s12539-021-00423-w.
  126. Samaras, Agorastos-Dimitrios, Serafeim Moustakidis, Ioannis D. Apostolopoulos, Elpiniki Papageorgiou, and Nikolaos Papandrianos. 2023. "Uncovering the Black Box of Coronary Artery Disease Diagnosis: The Significance of Explainability in Predictive Models." *APPLIED SCIENCES-BASEL* 13(14). doi: 10.3390/app13148120.
  127. Sandelowski, Margarete, Julie Barroso, and Corrine I. Voils. 2007. "Using Qualitative Metasummary to Synthesize Qualitative and Quantitative Descriptive Findings." *Research in Nursing & Health* 30(1):99–111.
  128. Sapra, Varun, Luxmi Sapra, Akashdeep Bhardwaj, Salil Bharany, Akash Saxena, Faten Khalid Karim, Sara Ghorashi, and Ali Wagdy Mohamed. 2023. "Integrated Approach Using Deep Neural Network and CBR for Detecting Severity of Coronary Artery Disease." *ALEXANDRIA ENGINEERING JOURNAL* 68:709–20. doi: 10.1016/j.aej.2023.01.029.
  129. Saputra, Jayson, Cindy Lawrencya, Jecky Mitra Saini, and Suharjito Suharjito. 2023. "Hyperparameter Optimization for Cardiovascular

- Disease Data-Driven Prognostic System.” *VISUAL COMPUTING FOR INDUSTRY BIOMEDICINE AND ART* 6(1). doi: 10.1186/s42492-023-00143-6.
130. Sharma, Prerna, Krishna Choudhary, Kshitij Gupta, Rahul Chawla, Deepak Gupta, and Arun Sharma. 2020. “Artificial Plant Optimization Algorithm to Detect Heart Rate & Presence of Heart Disease Using Machine Learning.” *ARTIFICIAL INTELLIGENCE IN MEDICINE* 102. doi: 10.1016/j.artmed.2019.101752.
  131. Shchetinin, E. Y., and A. G. Glushkova. 2022. “Arrhythmia Detection Using Resampling and Deep Learning Methods on Unbalanced Data.” *COMPUTER OPTICS* 46(6):980–87. doi: 10.18287/2412-6179-CO-1112.
  132. Sheeba, Adlin, S. Padmakala, C. A. Subasini, and S. P. Karuppiah. 2022. “MKELM: Mixed Kernel Extreme Learning Machine Using BMDA Optimization for Web Services Based Heart Disease Prediction in Smart Healthcare.” *COMPUTER METHODS IN BIOMECHANICS AND BIOMEDICAL ENGINEERING* 25(10):1180–94. doi: 10.1080/10255842.2022.2034795.
  133. Sherazi, Syed Waseem Abbas, Huilin Zheng, and Jong Yun Lee. 2023. “A Machine Learning-Based Applied Prediction Model for Identification of Acute Coronary Syndrome (ACS) Outcomes and Mortality in Patients during the Hospital Stay.” *SENSORS* 23(3). doi: 10.3390/s23031351.
  134. Shi, Jingjing, Chao Chen, Hui Liu, Yinglong Wang, Minglei Shu, and Qing Zhu. 2021. “Automated Atrial Fibrillation Detection Based on Feature Fusion Using Discriminant Canonical Correlation Analysis.” *COMPUTATIONAL AND MATHEMATICAL METHODS IN MEDICINE* 2021. doi: 10.1155/2021/6691177.
  135. Sidey-Gibbons, Jenni A. M., and Chris J. Sidey-Gibbons. 2019. “Machine Learning in Medicine: A Practical Introduction.” *BMC Medical Research Methodology* 19:1–18.
  136. Simegn, Gizeaddis Lamesgin, Worku Birhanie Gebeyehu, and Mizanu Zelalem Degu. 2022. “Computer-Aided Decision Support System for Diagnosis of Heart Diseases.” *RESEARCH REPORTS IN CLINICAL CARDIOLOGY* 13:39–54. doi: 10.2147/RRCC.S366380.
  137. Sinha, Nidhi, M. A. Ganesh Kumar, Amit M. Joshi, and Linga Reddy Cenkeramaddi. 2023. “DASMcC: Data Augmented SMOTE Multi-Class Classifier for Prediction of Cardiovascular Diseases Using Time Series Features.” *IEEE ACCESS* 11:117643–55. doi: 10.1109/ACCESS.2023.3325705.
  138. Sozen, Mert Erkan, Gorkem Sariyer, Mustafa Yigit Sozen, Gaurav Kumar Badhotiya, and Lokesh Vijavargy. 2023. “Machine Learning

- Implementations for Multi-Class Cardiovascular Risk Prediction in Family Health Units.” *INTERNATIONAL JOURNAL OF MATHEMATICAL ENGINEERING AND MANAGEMENT SCIENCES* 8(6):1171–87. doi: 10.33889/IJMEMS.2023.8.6.066.
139. Stepanyan, I. V, Ch. A. Alimbayev, M. O. Savkin, D. Lyu, and M. Zidun. 2022. “Comparative Analysis of Machine Learning Methods for Prediction of Heart Diseases.” *JOURNAL OF MACHINERY MANUFACTURE AND RELIABILITY* 51(8):789–99. doi: 10.3103/S1052618822080210.
140. Subramani, Sivakannan, Neeraj Varshney, M. Vijay Anand, Manzoore Elahi M. Soudagar, Lamyia Ahmed Al-keridis, Tarun Kumar Upadhyay, Nawaf Alshammari, Mohd Saeed, Kumaran Subramanian, Krishnan Anbarasu, and Karunakaran Rohini. 2023. “Cardiovascular Diseases Prediction by Machine Learning Incorporation with Deep Learning.” *FRONTIERS IN MEDICINE* 10. doi: 10.3389/fmed.2023.1150933.
141. Sun, Jin-Yu, Hui Shen, Qiang Qu, Wei Sun, and Xiang-Qing Kong. 2021. “The Application of Deep Learning in Electrocardiogram: Where We Came from and Where We Should Go?” *International Journal of Cardiology* 337:71–78.
142. Tachie, Christabel Y. E., Daniel Obiri-Ananey, Nii Adjetey Tawiah, Nii Attoh-Okine, and Alberta N. A. Aryee. 2023. “Machine Learning Approaches for Predicting Fatty Acid Classes in Popular US Snacks Using NHANES Data.” *NUTRIENTS* 15(15). doi: 10.3390/nu15153310.
143. Tadege, Melaku, Awoke Seyoum Tegegne, and Zelalem G. Dessie. 2024. “Post-Surgery Survival and Associated Factors for Cardiac Patients in Ethiopia: Applications of Machine Learning, Semi-Parametric and Parametric Modelling.” *BMC MEDICAL INFORMATICS AND DECISION MAKING* 24(1). doi: 10.1186/s12911-024-02480-9.
144. Tadesse, Girmaw Abebe, Hamza Javed, Komminist Weldemariam, Yong Liu, Jin Liu, Jiyan Chen, and Tingting Zhu. 2021. “DeepMI: Deep Multi-Lead ECG Fusion for Identifying Myocardial Infarction and Its Occurrence-Time.” *ARTIFICIAL INTELLIGENCE IN MEDICINE* 121. doi: 10.1016/j.artmed.2021.102192.
145. Teresa Garcia-Ordas, Maria, Martin Bayon-Gutierrez, Carmen Benavides, Jose Aveleira-Mata, and Jose Alberto Benitez-Andrades. 2023. “Heart Disease Risk Prediction Using Deep Learning Techniques with Feature Augmentation.” *MULTIMEDIA TOOLS AND APPLICATIONS* 82(20):31759–73. doi: 10.1007/s11042-023-14817-z.

146. Thakur, Gajendra Singh, Sunil Kumar Sahu, N. Kumar Swamy, Manish Gupta, Tony Jan, Mukesh Prasad, and Andrea Prati. 2023. "Review of Soft Computing Techniques in Monitoring Cardiovascular Disease in the Context of South Asian Countries." *APPLIED SCIENCES-BASEL* 13(17). doi: 10.3390/app13179555.
147. Tiwari, Achyut, Aryan Chugh, and Aman Sharma. 2022. "Ensemble Framework for Cardiovascular Disease Prediction." *COMPUTERS IN BIOLOGY AND MEDICINE* 146. doi: 10.1016/j.compbiomed.2022.105624.
148. Tolentino, Lean Karlo S., John Erick L. Isoy, Kayne Adriane A. Bulawan, Mary Claire T. Co, Caryl Faye C. Monreal, Ian Joshua W. Vitto, Maria Victoria C. Padilla, Jay Fel C. Quijano, Romeo Jr L. Jorda, and Jessica S. Velasco. 2020. "CAREdio: Health Screening and Heart Disease Prediction System for Rural Communities in the Philippines." *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 11(8):464–72.
149. Torres, Romina, Christopher Zurita, Diego Mellado, Orietta Nicolis, Carolina Saavedra, Marcelo Tuesta, Matias Salinas, Ayleen Bertini, Oneglio Pedemonte, Marvin Querales, and Rodrigo Salas. 2023. "Predicting Cardiovascular Rehabilitation of Patients with Coronary Artery Disease Using Transfer Feature Learning." *DIAGNOSTICS* 13(3). doi: 10.3390/diagnostics13030508.
150. Tsai, Dung-Jang, Shih-Hung Tsai, Hui-Hsun Chiang, Chia-Cheng Lee, and Sy-Jou Chen. 2022. "Development and Validation of an Artificial Intelligence Electrocardiogram Recommendation System in the Emergency Department." *JOURNAL OF PERSONALIZED MEDICINE* 12(5). doi: 10.3390/jpm12050700.
151. Varale, Viraj S., and Kalpana S. Thakre. 2020. "Prediction of Heart Disease Using Machine Learning Algorithm." *BIOSCIENCE BIOTECHNOLOGY RESEARCH COMMUNICATIONS* 13(14, SI):287–90. doi: 10.21786/bbrc/13.14/67.
152. Virani, Salim S., Alvaro Alonso, Emelia J. Benjamin, Marcio S. Bittencourt, Clifton W. Callaway, April P. Carson, Alanna M. Chamberlain, Alexander R. Chang, Susan Cheng, Francesca N. Delling, and others. 2020. "Heart Disease and Stroke Statistics—2020 Update: A Report from the American Heart Association." *Circulation* 141(9):e139--e596.
153. Wu, Mengze, Yongdi Lu, Wenli Yang, and Shen Yuong Wong. 2021. "A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network." *FRONTIERS IN COMPUTATIONAL NEUROSCIENCE* 14. doi: 10.3389/fncom.2020.564015.
153. Wu, Xingwei, Chang Huan, Mengting Li, Qin Lv, Jiaying Zhang, Enwu

- Long, Jiuqun Zhu, and Rongsheng Tong. 2022. "A Machine Learning-Based Risk Warning Platform for Potentially Inappropriate Prescriptions for Elderly Patients with Cardiovascular Disease." *FRONTIERS IN PHARMACOLOGY* 13. doi: 10.3389/fphar.2022.804566.
154. Xiang, Menghui, Junbin Zang, Juliang Wang, Haoxin Wang, Chenzheng Zhou, Ruiyu Bi, Zhidong Zhang, and Chenyang Xue. 2023. "Research of Heart Sound Classification Using Two-Dimensional Features." *BIOMEDICAL SIGNAL PROCESSING AND CONTROL* 79(2). doi: 10.1016/j.bspc.2022.104190.
155. Yadav, Anjali, Anushikha Singh, Malay Kishore Dutta, and Carlos M. Travieso. 2020. "Machine Learning-Based Classification of Cardiac Diseases from PCG Recorded Heart Sounds." *NEURAL COMPUTING & APPLICATIONS* 32(24, SI):17843–56. doi: 10.1007/s00521-019-04547-5.
156. Yang, Weiyi, Yujuan Si, Di Wang, and Buhao Guo. 2018. "Automatic Recognition of Arrhythmia Based on Principal Component Analysis Network and Linear Support Vector Machine." *COMPUTERS IN BIOLOGY AND MEDICINE* 101:22–32. doi: 10.1016/j.combiomed.2018.08.003.
157. Yazdi, Fatemeh, and Shahrokh Asadi. 2025. "Enhancing Cardiovascular Disease Diagnosis: The Power of Optimized Ensemble Learning." *IEEE Access* 13:46747–62.
158. Yongcharoenchaiyakit, Khomkrit, Sujitra Arwatchananukul, Punnarumol Temdee, and Ramjee Prasad. 2023. "Gradient Boosting Based Model for Elderly Heart Failure, Aortic Stenosis, and Dementia Classification." *IEEE ACCESS* 11:48677–96. doi: 10.1109/ACCESS.2023.3276468.
159. You, Jia, Yu Guo, Ju-Jiao Kang, Hui-Fu Wang, Ming Yang, Jian-Feng Feng, Jin-Tai Yu, and Wei Cheng. 2023. "Development of Machine Learning-Based Models to Predict 10-Year Risk of Cardiovascular Disease: A Prospective Cohort Study." *STROKE AND VASCULAR NEUROLOGY* 8(6):475–85. doi: 10.1136/svn-2023-002332.
160. Zafar, Kainat, Hafeez Ur Rehman Siddiqui, Abdul Majid, Adil Ali Saleem, Ali Raza, Furqan Rustam, and Sandra Dudley. 2023. "Deep Learning-Based Feature Engineering to Detect Anterior and Inferior Myocardial Infarction Using UWB Radar Data." *IEEE ACCESS* 11:97745–57. doi: 10.1109/ACCESS.2023.3312948.
161. Zhanquan, Sun, Wang Chaoli, Tian Engang, and Yin Zhong. 2022. "ECG Signal Classification via Combining Hand-Engineered Features with Deep Neural Network Features." *MULTIMEDIA TOOLS AND APPLICATIONS* 81(10):13467–88. doi: 10.1007/s11042-021-11523-

- 6.
162. Zou, Congyu, Alexander Mueller, Utschick Wolfgang, Daniel Rueckert, Phillip Mueller, Matthias Becker, Alexander Steger, and Eimo Martens. 2022. "Heartbeat Classification by Random Forest With a Novel Context Feature: A Segment Label." *IEEE JOURNAL OF TRANSLATIONAL ENGINEERING IN HEALTH AND MEDICINE* 10. doi: 10.1109/JTEHM.2022.3202749.

**استناد به این مقاله:** زاهدیان نژاد، محمود، مهرآیین، محمد، باقری، روح‌الله، طباطبایی، سید محمد. (۱۴۰۵). ارزیابی جامع مدل‌های یادگیری گروهی (EL) در مدیریت بیماری‌های قلبی عروقی: رویکردی فراترکیب، مطالعات مدیریت کسب و کار هوشمند، ۱۵(۵۵)، ۳۹-۱۲۶. DOI: 10.22054/ims.2025.86650.2638



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..