

Predicting Cardiovascular Diseases from EEG Signals Using YOLO Network Composition and XGBoost Algorithm

Alireza Asghari Kiadeh¹, Sara Motamed^{2*}

1. M.Sc. Student, Department of Computer Engineering, FSh.C., Islamic Azad University, Fouman, Iran

2. Associate Professor, Department of Computer Engineering, FSh.C., Islamic Azad University, Fouman, Iran

ARTICLE INFO:

Article History:

Received: 1 Jun 2025

Accepted: 27 Oct 2025

Published: 21 Dec 2025

*Corresponding Author:

Sara Motamed

Email:

sara.motamed@iau.ac.ir

Citation: Asghari Kiadeh A, Motamed S. Predicting Cardiovascular Diseases from EEG Signals Using YOLO Network Composition and XGBoost Algorithm. Journal of Health and Biomedical Informatics 2025; 12(3): 236-49. [In Persian]

Introduction: Cardiovascular diseases continue to be one of the leading causes of mortality worldwide, making early detection crucial for reducing complications and fatalities. Traditional diagnostic methods often depend on the manual interpretation of cardiac signals, which can be time-consuming and reliant on the expertise of clinicians. However, advances in deep learning and data mining have facilitated the automated analysis of medical signals and the detection of hidden patterns. This study presents a novel approach to identifying cardiac diseases based on ECG signals.

Method: In this study, we developed a hybrid deep learning model that utilizes the fast version of the YOLO network to extract mid-level features from ECG signals, combined with the XGBoost algorithm to improve classification performance. ECG signals from the MIT-BIH Arrhythmia Database were first extracted and preprocessed. These signals were then input into the YOLO network to generate feature vectors. The outputs of the network were subsequently fed into the XGBoost algorithm for final classification using an ensemble of multiple weak decision trees. Finally, we compared the proposed model with established conventional methods.

Results: The results demonstrated that the YOLO network effectively extracts key features from ECG signals, and its integration with XGBoost significantly enhances overall model accuracy. The proposed model outperformed baseline methods, including simple neural networks and support vector machines (SVMs). Evaluation on the MIT-BIH Arrhythmia Database revealed substantial improvements in classification accuracy, as well as enhanced sensitivity and specificity. These findings indicate that combining deep learning with boosting algorithms provides an efficient approach for medical signal analysis.

Conclusion: The YOLO-XGBoost hybrid model offers an accurate and innovative approach for detecting cardiac diseases from ECG signals. In addition to enhancing classification accuracy, this method is well-suited for implementation in clinical decision support systems and can serve as an efficient tool for patient screening. Future work could involve validating the model with larger and more diverse datasets and integrating it into intelligent medical systems.

Keywords: Heart disease, Arrhythmia, Deep learning, Cardiac signals, YOLO, XGBoost



CrossMark

مقاله پژوهشی

پیش‌بینی بیماری‌های قلبی-عروقی از روی سیگنال‌های EEG با استفاده از ترکیب شبکه YOLO و الگوریتم XGBoost

علیرضا اصغری کیاده^۱، سارا معتمد^{۲*}

۱. دانشجوی ارشد، گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران

۲. استادیار، گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران

چکیده

مقدمه: بیماری‌های قلبی-عروقی همچنان از اصلی‌ترین علل مرگ‌ومیر در سراسر جهان به شمار می‌روند و تشخیص زودهنگام آن‌ها اهمیت حیاتی در کاهش عوارض و مرگ دارد. روش‌های سنتی تشخیص این بیماری‌ها غالباً متکی بر تفسیر دستی سیگنال‌های قلبی بوده که زمان‌بر و وابسته به تجربه پزشک است. پیشرفت روش‌های یادگیری عمیق و داده‌کاوی امکان تحلیل خودکار سیگنال‌های پزشکی و شناسایی الگوهای پنهان را فراهم کرده است. در این پژوهش رویکردی نوین برای شناسایی بیماری‌های قلبی بر پایه سیگنال‌های ECG ارائه می‌شود.

روش کار: در این مطالعه یک مدل ترکیبی مبتنی بر یادگیری عمیق طراحی شد که از شبکه YOLO (نسخه سریع) برای استخراج ویژگی‌های میان‌سطحی سیگنال‌های ECG و از الگوریتم XGBoost به‌منظور بهبود فرآیند طبقه‌بندی استفاده می‌کند. ابتدا داده‌های مربوط به پایگاه MIT-BIH Arrhythmia استخراج و پیش‌پردازش شدند. سپس، سیگنال‌ها به شبکه YOLO داده شدند تا بردارهای ویژگی استخراج گردد. خروجی شبکه به الگوریتم XGBoost داده شد تا طبقه‌بندی نهایی با ترکیب چندین درخت تصمیم ضعیف انجام گیرد. در نهایت، مدل پیشنهادی با روش‌های متداول موجود مقایسه شد.

یافته‌ها: نتایج آزمایش‌ها نشان داد شبکه YOLO توانایی استخراج ویژگی‌های کلیدی از سیگنال‌های ECG را دارد و در ترکیب با XGBoost موجب افزایش دقت کلی مدل می‌شود. مدل پیشنهادی توانست نسبت به روش‌های پایه از جمله شبکه‌های عصبی ساده و SVM عملکرد بهتری ارائه دهد. در ارزیابی بر روی پایگاه داده MIT-BIH، دقت طبقه‌بندی مدل پیشنهادی به‌طور قابل توجهی افزایش یافت و شاخص‌هایی همچون حساسیت و ویژگی نیز بهبود پیدا کردند. این نتایج نشان می‌دهد استفاده همزمان از یادگیری عمیق و الگوریتم‌های تقویتی می‌تواند یک رویکرد کارآمد در تحلیل سیگنال‌های پزشکی باشد.

نتیجه‌گیری: این پژوهش نشان داد که مدل ترکیبی YOLO-XGBoost روشی دقیق و نوآورانه برای شناسایی بیماری‌های قلبی بر اساس سیگنال‌های ECG است. این روش علاوه بر افزایش دقت طبقه‌بندی، قابلیت پیاده‌سازی در سیستم‌های پشتیبان تصمیم‌گیری بالینی را دارد و می‌تواند به عنوان ابزاری کارآمد در غربالگری بیماران مورد استفاده قرار گیرد. در آینده می‌توان این مدل را با داده‌های بیشتر و متنوع‌تر اعتبارسنجی کرده و در سامانه‌های هوشمند پزشکی یکپارچه‌سازی نمود.

کلیدواژه‌ها: بیماری قلبی، آریتمی، یادگیری عمیق، سیگنال‌های قلبی، YOLO، XGBoost

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۴/۳/۱۱

پذیرش: ۱۴۰۴/۸/۵

انتشار برخط: ۱۴۰۴/۹/۳۰

نویسنده مسئول:

سارا معتمد

ایمیل:

sara.motamed@iau.ac.ir

ارجاع: اصغری کیاده، علیرضا، معتمد

سارا. پیش‌بینی بیماری‌های قلبی-عروقی از روی سیگنال‌های EEG با استفاده از ترکیب شبکه YOLO و الگوریتم XGBoost. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۴؛ ۱۲(۳): ۲۳۶-۲۴۹.

مقدمه

امروزه در حوزه پزشکی، گردآوری داده‌های مربوط به بیماری‌های مختلف اهمیت چشمگیری دارد. منابع داده‌ای حوزه سلامت حجم گسترده‌ای از اطلاعات بالینی را در بر می‌گیرند و با ظهور نظام‌های اطلاعات یکپارچه و پیشرفت فناوری اطلاعات، اهمیت این داده‌ها بیش از پیش آشکار شده است. قابل توجه است که حجم داده‌های جمع‌آوری شده بسیار بالا است و برای اینکه بتوان از بین این حجم انبوه داده‌ها الگوها و نتایج مورد نظر را به‌دست آورد، باید از تکنیک‌های هوش مصنوعی استفاده کرد. هوش مصنوعی و در ادامه آن داده کاوی از جمله پیشرفت‌های فن آوری در راستای مدیریت داده‌ها است و استفاده گسترده از سیستم‌های اطلاعات و پایگاه‌های داده، ادغام آن با شیوه‌های سنتی به یک الزام تبدیل کرده است [۱]. در سال‌های اخیر میزان بالای ابتلا به بیماری قلبی و عروقی و تعداد بالای مرگ و میر ناشی از بیماری قلبی در سراسر جهان این مسئله را به یکی از نگرانی‌های صنعت بهداشت و درمان تبدیل کرده است و هر ساله در جهان تعداد زیادی از انسان‌ها را از بین می‌برد یا بر عملکرد آن‌ها تأثیر می‌گذارد. در واقع قلب و سیستم انتقال خون، از مهم‌ترین ارگان‌های بدن انسان می‌باشند. هر اختلالی در این ارگان‌ها بر روی عملکرد کل بدن تأثیر بسیار محسوسی داشته، زیرا سیستم انتقال خون مسئولیت تأمین انرژی مورد نیاز تمام ارگان‌های بدن (از جمله خود قلب) را برعهده دارد [۲]. شرایطی که عملکرد قلب شما را تحت تأثیر قرار می‌دهد، از آن به عنوان بیماری‌های قلبی-عروقی نام برده می‌شود. بیماری‌های قلبی-عروقی علت اصلی مرگ در بسیاری از جمعیت جهان است. بر اساس گزارش سازمان جهانی بهداشت، بیماری‌های قلبی-عروقی اولین بیماری غیرواگیر است که باعث مرگ‌ومیرهای متعدد در جهان می‌شود. در سال ۲۰۲۰، یک مطالعه توسط سازمان بهداشت جهانی تخمین زده شد که بیش از ۱۷ میلیون نفر بر اثر بیماری‌های قلبی-عروقی جان خود را از دست داده‌اند که نشان دهنده بیش از ۴۰ درصد از مرگ و میرها در سراسر جهان است [۲]. همچنین مطالعه Ahsan و Siddique نشان داد که بیش از ۷۰ درصد مرگ و میرها در کشورهای کم درآمد و متوسط رخ می‌دهد. مرگ و میر بر اثر بیماری قلبی در ایران به عنوان مهم‌ترین چالش نظام سلامت کشور، موجب بیش از یک سوم کل مرگ‌ها است. سوانح و حوادث و سرطان در رتبه‌های دوم و سوم علل مرگ در ایران هستند [۱]. پیش‌بینی شده است بیماری‌های قلبی و عروقی تنها علت اصلی مرگ در جهان باقی بماند [۳].

از طرف دیگر، از پایان سال ۱۳۹۸ شاهد فراگیر شدن بیماری کرونا هستیم و با توجه به بررسی‌های صورت گرفته، بیشتر مبتلایان به این بیماری دارای بیماری‌های زمینه‌ای از جمله فشارخون بالا، اختلالات قلبی-عروقی و دیابت هستند و میزان مرگ و میر در این افراد نسبت به دیگر مبتلایان بیشتر است [۴]. در واقع، افرادی که دچار بیماری قلبی-عروقی هستند در مقابل سایر بیماری‌ها نیز به شدت آسیب پذیر خواهند بود؛ لذا لازم است افراد جامعه به خصوص گروه‌های پرخطر مورد غربالگری قرار گیرند تا میزان ابتلا به بیماری قلبی را بتوان کنترل کرد و یا از وخیم شدن بیماری جلوگیری کرد تا میزان مرگ و میر کاهش یابد و این زمانی امکان‌پذیر است که بتوان شرایط جسمی افراد را مورد پایش قرار داد و تمهیدات لازم جهت پیش‌بینی ابتلای افراد به بیماری با توجه به شرایط بالینی و پزشکی افراد را به‌کار برد تا بتوان بیماری را در مرحله اولیه و حتی قبل از بروز شواهد و علائم تشخیص داد که این امر می‌تواند سبب کاهش بروز و شیوع این‌گونه بیماری‌ها باشد [۵]. این جاست که می‌توان از فناوری‌های هوش مصنوعی در سیستم‌های مراقبت‌های بهداشتی برای پیش‌بینی بیماری قلبی-عروقی استفاده کرد [۶].

بیماری‌های قلبی و عروقی یکی از اصلی‌ترین علل مرگ‌ومیر در سراسر جهان هستند و تشخیص به‌موقع آن‌ها می‌تواند تأثیر زیادی بر کاهش خطرات و بهبود کیفیت زندگی بیماران داشته باشد [۳-۱]. پیشرفت‌های اخیر در حوزه هوش مصنوعی و داده‌کاوی، امکان تحلیل حجم عظیم داده‌های پزشکی مانند سیگنال‌های ECG (Electrocardiogram) را برای شناسایی الگوهای بیماری فراهم کرده است [۷-۴]. مطالعات متعددی در زمینه پیش‌بینی و تشخیص بیماری‌های قلبی انجام شده است. امیری و همکاران [۸] با استفاده از الگوریتم k-means و نرم‌افزار کلمنتاین، به تشخیص بیماری قلبی پرداخته و خطای ۱۳٪ را روی داده‌های به‌کار رفته گزارش کردند. فریدونی و همکاران [۹] یک سیستم بیوالکتریک مبتنی بر شبکه عصبی MLP (Multi-Layer Perceptron) طراحی کردند که دقت ۹۳٪ را به دست آورد. رجب‌لو و همکاران [۱۰]، از سیستم خبره فازی برای تشخیص استفاده کرده و دقت ۹۶/۳٪ را گزارش دادند. مختاری و همکاران



[۱۱]، روش درون یابی اسپالین را برای مدل سازی سیگنال ECG پیشنهاد کردند که دقت و سرعت بالاتری نسبت به روش های متداول داشت.


در حوزه یادگیری ماشین، ناروئی و همکاران [۱۲] با ترکیب PCA (Principal Component Analysis) و شبکه MLP به دقت ۹۳/۴٪ در طبقه بندی دودویی و ۷۸٪ در چندکلاسه دست یافتند. دشتی نژاد و همکاران [۱۳]، رویکردی مبتنی بر غنیه شناسی و شبکه پس انتشار خطا ارائه دادند. نظری [۱۴]، با مقایسه الگوریتم هایی مانند نزدیک ترین همسایه، رگرسیون لجستیک و جنگل تصادفی، بالاترین دقت را برای جنگل تصادفی (۹۷/۶۱٪ در تست) گزارش کرد. حدادینا و همکاران [۱۵]، به بررسی مزایا و معایب روش های فعلی تشخیص الگو در داده های ECG پرداختند. روش های مبتنی بر ویژگی های آشوب گون نیز مورد توجه قرار گرفته اند. دولت آبادی و همکاران [۱۶]، با استفاده از ویژگی های حوزه آشوب و شبکه ELMAN (Elman Neural Network) عملکرد مناسبی به دست آوردند. در سطح بین المللی، پژوهش هایی مانند Palaniappan و Awang [۱۷]، Taneja [۱۸]، Lakshmi و همکاران [۱۹] و Masethe و همکارش [۲۰]، با استفاده از ترکیب الگوریتم هایی مانند درخت تصمیم، شبکه بیز و شبکه عصبی، سیستم های پیش بینی بیماری قلبی را توسعه داده و به دقت هایی بین ۸۴٪ تا ۹۹٪ دست یافته اند. با وجود نتایج امیدوار کننده این مطالعات، چالش هایی همچون نویز داده های ECG، عدم تعادل در تعداد نمونه های کلاسی، و محدودیت مدل ها در شناسایی الگوهای پیچیده باقی مانده است. این موارد، نیاز به توسعه مدل های ترکیبی و پیشرفته تر را برای بهبود دقت و پایداری پیش بینی ها برجسته می کند.

در مدل های YOLO، لایه های پایانی معمولاً از یک لایه Fully Connected یا Softmax برای انجام طبقه بندی استفاده می کنند. این ساختار در مواجهه با داده های پیچیده و دارای نویز، مانند سیگنال های ECG، ممکن است باعث کاهش دقت شود؛ زیرا قدرت این لایه ها در ترکیب ویژگی های استخراج شده محدود است. در مدل پیشنهادی، خروجی لایه ویژگی یاب YOLO (feature map) به جای ورود مستقیم به یک لایه Fully Connected، به الگوریتم XGBoost داده می شود. XGBoost به عنوان یک روش تقویت گرادیانی با قابلیت ترکیب تعداد زیادی طبقه بندی کننده ضعیف، توانایی بالایی در شناسایی الگوهای غیرخطی و مقابله با داده های نامتوازن دارد. این ترکیب، علاوه بر حفظ مزیت های YOLO در استخراج ویژگی های مکانی-زمانی سیگنال، دقت و پایداری طبقه بندی را در مقایسه با ساختار اصلی YOLO به طور معناداری بهبود می بخشد. در این راستا، در این مطالعه از ترکیب شبکه YOLO سریع و افزایش گردایان فوق العاده (XGBoost) برای پیش بینی بیماری قلبی از روی سیگنال های ECG استفاده شده است. شبکه YOLO با توجه با فیلترهایی که روی ماتریس ورودی اعمال می شوند، توانایی استخراج ویژگی های سطح میانی را دارند. با این حال این شبکه ها با محدودیت هایی نیز مواجه می باشند. برای افزایش دقت این شبکه ها در مدل پیشنهادی از XGBoost روی لایه آخر شبکه YOLO استفاده شده است. در این راستا هدف این مطالعه استفاده از روش های هوش مصنوعی و پیرو آن یادگیری عمیق برای پیش بینی بیماری های مربوط به قلب است که از آریتمی قلب حاصل می شوند تا پزشکان و مراکز بهداشتی و درمانی بتوانند با استفاده از آن ها به راهکارهایی برای تشخیص زودهنگام بیماری دست یابند. درواقع، برخلاف دستگاه های پزشکی مانند مانیتور قلب که علائم حیاتی فرد را مورد بررسی قرار می دهد، هوش مصنوعی می تواند اطلاعات این دستگاه را جمع آوری کرده و پس از تجزیه و تحلیل متوجه شرایط پیچیده تری مانند خطراتی که بیمار را در آینده تهدید می کند، شود. هدف این مطالعه استفاده از XGBoost است که این یک الگوریتم یادگیری گروهی بسیار مؤثر است که می تواند چندین طبقه بندی ضعیف را به یک طبقه بندی قوی برای عملکرد طبقه بندی بهتر تبدیل کند. مدل پیشنهادی روی مجموعه داده های آریتمی MIT-BIH مورد آزمایش قرار گرفت و براساس نتایج به دست آمده مدل پیشنهادی از دقت بالاتری نسبت به روش های پایه برای تشخیص بیماری قلبی برخوردار بود.

روش کار

از آنجایی که هدف این مطالعه تشخیص بیماری قلبی از روی سیگنال های ECG قلب با استفاده از ترکیب شبکه های یادگیری عمیق است، از ترکیب YOLO و مدل XGBoost که یک مدل تقویت شده گردایان است، استفاده شده است. در مدل پیشنهادی از YOLO به عنوان یک استخراج کننده ویژگی قابل آموزش برای به دست آوردن ویژگی ها از ورودی و از XGBoost [۲۱] به عنوان یک شناسایی کننده در سطح بالای شبکه برای تولید نتایج استفاده شده است که می تواند استخراج و طبقه بندی ویژگی با قابلیت اطمینان بالا را تضمین

کند. شماتیک کلی مراحل مدل پیشنهادی در شکل ۱ نشان داده شده است. مدل پیشنهادی سیگنال‌های ECG را به عنوان ورودی دریافت کرده و دسته‌بندی می‌کند.



شکل ۱: مراحل مدل پیشنهادی

با توجه به شکل ۱، مدل پیشنهادی شامل ترکیب شبکه YOLO و مدل XGBoost می‌باشد. از مزایای مدل پیشنهادی می‌توان به موارد زیر اشاره کرد:

دقت بالا: شبکه YOLO یک روش بسیار سریع است که به صورت همزمان تمام شیء‌های موجود در یک تصویر را تشخیص می‌دهد. با ترکیب آن با XGBoost، می‌توان از قوانین ویژه برای تشخیص اشیاء به علاوه قابلیت‌های بیشتری مانند عملکرد بهتر در مواردی که یک شیء در تصویر به صورت جزئی یا پوشیده است، استفاده کرد. این ترکیب می‌تواند دقت تشخیص را بهبود بخشد.

سرعت بالا: شبکه YOLO به دلیل استفاده از شبکه عصبی کانولوشنی (CNN) با ساختار ساده، به طور کلی بسیار سریع عمل می‌کند. با استفاده از XGBoost که یک الگوریتم گروه‌بندی و رگرسیون قوی است، می‌توان در پردازش داده‌های خروجی YOLO از سرعت و کارایی بالاتری برخوردار بود.


توانایی یادگیری: مدل XGBoost یک روش ماشین بردار پشتیبان تقویت شده است که بهبودهای جدیدی را نسبت به روش‌های قدیمی‌تر برای گروه‌بندی و رگرسیون ارائه می‌دهد. با اضافه کردن XGBoost به YOLO، می‌توان توانایی یادگیری الگوریتم را افزایش داد و دقت و قابلیت تعمیم‌پذیری آن را بهبود بخشید.

در ادامه سلسله مراحل مدل پیشنهادی به تفکیک مورد بررسی قرار خواهد گرفت:

مرحله اول: پیش‌پردازش ورودی

مجموعه داده‌ای که در این مطالعه مورد استفاده قرار گرفت، پایگاه داده آریتمی MIT/BIH است. این مجموعه داده شامل ۴۸ رکورد است که توسط آزمایشگاه آریتمی BIH جمع‌آوری شده است. هر رکورد حاوی سیگنال ECG دو کاناله با مدت زمان ۳۰ دقیقه است که از ضبط ۲۴ ساعته هر بیمار انتخاب شده است. فرکانس سیگنال ECG 360 هرتز است. پایگاه داده نه تنها سیگنال ECG را ارائه می‌دهد، بلکه اطلاعات مربوط به زمان و اطلاعات کلاس ضربان قلب را که توسط متخصص قلب تأیید شده است، ارائه می‌دهد. از پایگاه داده آریتمی MIT/BIH، ۴۴ رکورد برای استفاده انتخاب شد. این رکوردها شامل دسته‌های مختلفی از ضربان قلب، مانند ضربان طبیعی، آریتمی‌های بطنی، دهلیزی است. در مرحله پیش‌پردازش، چهار رکورد حاوی ضربان قلب سریع برای استفاده در این مطالعه حذف شد. در ادامه، فقط از سیگنال ECG سرب-۱ به عنوان داده خام استفاده می‌شود. با توجه به وجود نویزهای خارجی در بین سیگنال‌های ECG، از روش نویز زدایی برای به دست آوردن داده‌های تمیز استفاده شد. تبدیل موجک یک روش نویز زدایی است که از تابع موجک برای در هم آمیختن با سیگنال استفاده می‌کند. در مدل پیشنهادی نیز از این روش استفاده شد، زیرا می‌تواند اجزای فرکانس زمانی دقیق سیگنال ECG را حفظ کند. همچنین تبدیل موجک می‌تواند ضرایب موجک را استخراج کرده و سیگنال را بازسازی کند.

همان‌طور که در شکل ۲ نشان داده شده است، سیگنال قرمز داده خام و سیگنال سبز سیگنال بدون نویز است. در مقایسه با سیگنال قبل از نویز کردن، سیگنال پردازش شده صاف‌تر است و حول منحنی سطح نوسان می‌کند، که نشان می‌دهد تبدیل موجک مؤثر است. بنابراین، سیگنال بدون نویز از تداخل نویزها جلوگیری می‌کند.




شکل ۲: سیگنال ECG خام و سیگنال بدون نویز با استفاده از تبدیل موجک

مرحله دوم: شبکه YOLO

YOLO معماری سیستم‌های تشخیص اشیاء را دست‌خوش تغییراتی کرده است و به مسئله تشخیص اشیاء به‌صورت یک مسئله رگرسیون می‌نگرد که مستقیم از پیکسل‌های تصویر به مختصات باکس و احتمال کلاس‌ها می‌رسد. با استفاده از سیستم YOLO، برای تشخیص اشیای موجود در تصویر، به هر تصویر شما فقط یک بار می‌نگرید [۲۲]. روش YOLO شامل یک شبکه عصبی کانولوشنی با ۲۴ لایه کانولوشنی، برای استخراج ویژگی و همچنین ۲ لایه کاملاً همبند برای پیش‌بینی احتمال و مختصات اشیاء است.

همچنین، یک نسخه سریع از YOLO برای جابه جایی مرزهای تشخیص اشیای سریع طراحی شده است. YOLO سریع، یک شبکه عصبی با تعداد لایه‌های کانولوشنی کمتر است که در آن از ۹ لایه کانولوشنی به جای ۲۴ لایه کانولوشنی استفاده شده و البته تعداد فیلترهای هر لایه در YOLO سریع نسبت به YOLO اصلی کمتر است. در مدل پیشنهادی از YOLO سریع استفاده شد. علت استفاده از این شبکه این است که آموزش آن بسیار سریع بوده و برای پیش‌بینی تشخیص، به صورت کلی به تصویر نگاه می‌کند. از طرف دیگر، YOLO تیمیم‌پذیری بالایی دارد و در مقابل حوزه‌های جدید و یا داده‌های ورودی غیرمنتظره با احتمال کمتری نسبت به بقیه سیستم‌ها با شکست مواجه می‌شود. معماری شبکه YOLO در شکل ۳ قابل مشاهده است [۲۳، ۲۴]. یکی از مزایای اصلی شبکه YOLO سرعت بالا است. به دلیل استفاده از یک بخش واحد برای تشخیص تمام اشیاء، عملکرد آن در زمان واقعی بسیار بهتر است تا روش‌های دیگر. همچنین، با توجه به این که YOLO اطلاعات پیشین تصویر را در نظر نمی‌گیرد، از لحاظ حافظه، ظرفیت بسیار کمتری نسبت به روش‌های قبلی نیاز دارد.



شکل ۳: ساختار شبکه YOLO

مرحله سوم: افزایش گرادیان فوق العاده (XGBoost)

XGBoost الگوریتمی است که اخیراً در حوزه یادگیری ماشین به کار گرفته می‌شود. الگوریتم XGBoost یک پیاده‌سازی از تقویت گرادینان درخت تصمیم‌گیری است که برای سرعت و کارایی بالا طراحی شده است. این الگوریتم یک الگوریتم یادگیری گروهی بسیار مؤثر است که می‌تواند چندین طبقه‌بندی ضعیف را به یک طبقه‌بندی قوی برای عملکرد طبقه‌بندی بهتر تبدیل کند. در مدل پیشنهادی، XGBoost به سطح بالای CNN اضافه می‌شود تا نتایج دسته‌بندی تصویر را افزایش دهد [۲۵]. به طور کلی، در مدل پیشنهادی ابتدا

داده‌های تصویر ورودی نرمال شده و به لایه ورودی YOLO منتقل می‌شوند. پس از آموزش YOLO توسط الگوریتم پس انتشار برای چندین دوره برای به دست آوردن ساختار مناسب برای طبقه بندی تصاویر، XGBoost جایگزین لایه خروجی دسته بند سافت مکس در YOLO می‌شود و از ویژگی‌های قابل آموزش YOLO برای آموزش استفاده می‌کند. مدل ترکیبی پیشنهادی می‌تواند به‌طور خودکار ویژگی‌ها را از ورودی دریافت کند و نتایج طبقه‌بندی دقیق‌تری را با ترکیب دو طبقه‌بندی‌کننده برجسته ارائه می‌دهد. ساختار کلی مدل پیشنهادی در شکل ۴ نشان داده شده است.

به طور خلاصه، مدل پیشنهادی این مطالعه حاصل شبکه YOLO سریع و XGBoost است. شبکه YOLO با توجه با فیلترهایی که روی ماتریس ورودی اعمال می‌شوند، توانایی استخراج ویژگی‌های سطح میانی را دارند. با این حال این شبکه‌ها با محدودیت‌هایی نیز مواجه می‌باشند. در این راستا و برای افزایش دقت این شبکه‌ها در مدل پیشنهادی از XGBoost روی لایه آخر شبکه YOLO استفاده شده است. هدف از استفاده از XGBoost این است که این یک الگوریتم یادگیری گروهی بسیار مؤثر است که می‌تواند چندین طبقه‌بندی ضعیف را به یک طبقه‌بندی قوی برای عملکرد طبقه‌بندی بهتر تبدیل کند.

روش و ابزار گردآوری داده‌ها

مجموعه داده‌های آریمی MIT-BIH شامل ۴۸ رکورد است که هر یک مدت زمان تقریبی ۳۰ دقیقه از یک سیستم سرپایی دو کاناله، بین سال‌های ۱۹۷۵ و ۱۹۷۹ جمع‌آوری شده است. بیست و سه نمونه ضبط شده به طور تصادفی از ۴۰۰۰ نمونه بلند مدت هولتر متشکل از یک گروه متنوع از ساکنان بیمارستان داخل ساختمان (۷۰٪) و همچنین بیماران در فضای باز (۳۰٪) انتخاب شدند. بیست و پنج نمونه از یک مجموعه مشابه با تمرکز بر آریمی‌های پیچیده بطنی، اتصالی و فوق بطنی انتخاب شدند. این نمونه‌ها با سرعت ۳۶۰ نمونه در ثانیه برای هر کانال با وضوح ۱۱ بیت در محدوده ۱۰ میلی ولت دیجیتالی شدند. حداقل دو متخصص قلب در حاشیه نویسی هر رکورد شرکت داشتند و مسائل و راه‌حل‌های مربوطه را که برای رسیدن به نتیجه قابل خواندن توسط کامپیوتر لازم بود، ثبت کردند. از این رو، برای سوابق، تقریباً ۱۱۰۰۰۰ توضیح در این پایگاه ثبت شد. داده‌های این مجموعه داده به صورت عمومی برای دانلود در دسترس هستند. این مجموعه داده نه تنها سیگنال ECG را ارائه می‌دهد، بلکه اطلاعات مربوط به زمان و اطلاعات کلاس ضربان قلب را که توسط متخصص قلب تأیید شده است، ارائه می‌دهد. از پایگاه داده آریمی MIT/BIH، ۴۴ رکورد برای استفاده انتخاب شد. این رکوردها شامل دسته‌های مختلفی از ضربان قلب، مانند ضربان طبیعی، آریمی‌های بطنی، دهلیزی است. چهار رکورد حاوی ضربان قلب سریع برای استفاده در این مطالعه حذف شدند.

در این مطالعه فقط از سیگنال ECG سرب-۱ به عنوان داده خام استفاده شد. با توجه به وجود نویزهای خارجی در بین سیگنال‌های ECG، از روش نویز زدایی برای به دست آوردن داده‌های تمیز استفاده شد. تبدیل موجک یک روش نویز زدایی است که از تابع موجک برای در هم آمیختن با سیگنال استفاده می‌کند. از این روش در این مطالعه استفاده شد، زیرا می‌تواند اجزای فرکانس زمانی دقیق سیگنال ECG را حفظ کند. همچنین، تبدیل موجک می‌تواند ضرایب موجک را استخراج کرده و سیگنال را بازسازی کند تا رانش خط پایه را حذف کند.

برای به دست آوردن مجموعه داده‌های آموزشی، سیگنال ECG پیوسته به ضربان قلب فردی تبدیل شد. عرض تک ضرب به ۳۰۰ داده نمونه تقریب زده شد و ضربان حول پیک R متمرکز شده است. بنابراین، از حاشیه نویسی R-peak ارائه شده توسط پایگاه داده برای انجام تبدیل استفاده شد. از آنجایی که این نقاط اوج R به عنوان نقطه مرکزی هر ضربان قلب در نظر گرفته می‌شوند، برای هر ضربان، سیگنال پیوسته قطع شد تا ۱۵۰ نقطه نمونه قبل از پیک R و ۱۴۹ نقطه بعد از آن به‌دست آورده شود، به این معنی که یک ضربان دارای ۳۰۰ ویژگی است. در مجموع ۱۰۲۵۴۸ ضربان قلب به‌دست می‌آید. جدول ۱ تعداد نمونه‌ها را در ۱۰ دسته بیماری قلبی که توسط AAMI (Association for the Advancement of Medical Instrumentation) توصیه شده است، نشان می‌دهد.



جدول ۱: تعداد نمونه‌ها در هر کلاس

ریتیم طبیعی (Normal Rhythm)	۸۰۹۲۱
ریتیم دهلیزی (Arterial Rhythm)	۲۷۴۵
ریتیم بطنی (Ventricular Rhythm)	۸۵۳۸
آریتیمی (Arrhythmia)	۳۵۵
غیر قابل تحلیل (Cannot analysis)	۷۱۸۷
نویز (Noise)	۵۸۶
بلوک (Block)	۱۹۳
غیر طبیعی الف (Abnormal A)	۱۲۴۱
غیر طبیعی ب (Abnormal B)	۹۸۲
جمع کل (Sum)	۱۰۲۵۴۸

همان‌طور که در جدول ۱ مشاهده می‌شود، توزیع نمونه‌ها در بین کلاس‌های ده‌گانه پیشنهادی استاندارد AAMI یکسان نیست و برخی کلاس‌ها دارای تعداد بسیار اندکی نمونه هستند. این عدم توازن می‌تواند منجر به سوگیری مدل به سمت کلاس‌های پرتعداد شود و عملکرد آن را در شناسایی کلاس‌های کم‌نمونه کاهش دهد. همچنین، وجود کلاس‌هایی مانند "نویز" و "غیر قابل تحلیل" نشان‌دهنده سیگنال‌های با کیفیت پایین یا غیرقابل استفاده است که می‌تواند فرآیند آموزش را مختل کند؛ به همین دلیل این کلاس‌ها در مدل پیشنهادی استفاده نشده‌اند.

در هر دسته، دسته‌های مختلفی از بیماری‌های قلبی وجود دارد. تعداد نمونه‌های هر کلاس متفاوت است. در این مطالعه پنج کلاس از تمام کلاس‌هایی که دارای بیشترین تعداد نمونه هستند، به منظور آموزش کارآمدتر انتخاب شدند. ضربان‌های مربوطه از تمام ضربان‌های قلب استخراج می‌شود و پس از ضربان زدن، به دو قسمت تقسیم می‌شوند. یکی به عنوان مجموعه آموزشی با ۷۰ درصد داده استفاده می‌شود و دیگری به عنوان مجموعه آزمایشی نگهداری می‌شود. تعداد نمونه‌های مجموعه‌های انتخاب شده در جدول ۲ آمده است. همان‌طور که مشخص است پنج کلاس نماینده انتخاب شد: ضربان طبیعی، ضربان بلوک شاخه سمت چپ (beat Left Bundle Branch Block)، ضربان بلوک شاخه سمت راست (RBBB(Right Bundle Branch Block Beat)، انقباض زودرس بطن (Premature PVC (Ventricular Contraction و ضربان زودرس دهلیزی (APB (Atrial Premature Contraction. دلیل اصلی انتخاب آن‌ها این است که این پنج کلاس بیشترین نمونه‌ها را از بین ۱۰۲۵۴۸ ضربان قلب تشکیل می‌دهند. این انتخاب دو مزیت دارد: اولاً، آموزش مدل پیشنهادی با مجموعه داده‌های بزرگ به جای مجموعه‌های کوچک راحت‌تر و مؤثرتر است. از این رو کلاس‌هایی با اکثر نمونه‌ها انتخاب شدند تا اطمینان حاصل شود که مدل پیشنهادی می‌تواند بهتر آموزش داده شود. ثانیاً، می‌توان تأثیر طبقات نامتعادل را کاهش داد. از آنجایی که اگر تعداد نمونه‌های هر کلاس با هم تفاوت فاحشی داشته باشد، باعث می‌شود مدل طبقه‌بندی کاملاً بی‌فایده باشد، برای رفع این مشکل، در این مطالعه از کلاس‌های کوچک غفلت کرده و کلاس‌های بزرگ انتخاب شد.

جدول ۲: تعداد نمونه‌ها در هر کلاس انتخابی

کلاس	داده‌های آموزش	داده‌های آزمایشی
ریتیم طبیعی	۴۸۷۵۵	۲۰۸۹۵
ضربان بلوک شاخه سمت چپ	۲۵۷۶	۱۱۰۴
ضربان بلوک شاخه سمت راست	۵۰۹۲	۲۱۸۲
انقباض زودرس بطن	۴۸۶۷	۲۰۸۶
ضربان زودرس دهلیزی	۱۷۸۲	۷۶۴
مجموع داده‌ها	۶۳۰۷۲	۲۷۰۳۱

جدول ۲ تعداد نمونه‌ها در پنج کلاس منتخب را نشان می‌دهد. این پنج کلاس ریتم طبیعی، ضربان بلوک شاخه سمت چپ، ضربان بلوک شاخه سمت راست، انقباض زودرس بطن و ضربان زودرس دهلیزی بر اساس دو معیار انتخاب شده‌اند: (۱) بیشترین تعداد نمونه در کل مجموعه داده، که امکان آموزش پایدار و کاهش نیاز به تکنیک‌های پیچیده افزایش داده‌های مصنوعی را فراهم می‌کند، و (۲) کاهش عدم توازن کلاس‌ها برای جلوگیری از سوگیری مدل. داده‌های هر کلاس به صورت تصادفی به دو بخش آموزشی (۷۰٪) و آزمایشی (۳۰٪) تقسیم شده‌اند تا از نشت داده بین دو مجموعه جلوگیری شود و ارزیابی دقیق‌تری از عملکرد مدل به دست آید. این انتخاب‌ها تضمین می‌کند که مدل پیشنهادی بتواند الگوهای غالب سیگنال ECG را به خوبی یاد بگیرد و در عین حال تعمیم‌پذیری خود را حفظ کند.

روش تجزیه و تحلیل داده‌ها

به منظور ارزیابی مدل پیشنهادی از معیار ارزیابی دقت، صحت و فراخوانی و امتیاز F استفاده می‌شود و به ترتیب مطابق رابطه (۱)، (۲)، (۳) و (۴) محاسبه می‌شوند:

$$accuracy = (TP + TN) / N \quad (1)$$

$$precision = TP / (TP + FP) \quad (2)$$

$$recall = TP / (TP + FN) \quad (3)$$

$$F - measure = \frac{2 \times precision \times recall}{precision + recall} \quad (4)$$

در روابط فوق نمونه مثبت درست طبقه‌بندی شده (TP (True Positive) و نمونه منفی درست طبقه‌بندی شده (TN (True Negative) به ترتیب نمونه‌های مثبت و منفی هستند که درست طبقه‌بندی شده‌اند. نمونه منفی که به اشتباه مثبت طبقه‌بندی شده (False Positive) و FP و نمونه مثبت که به اشتباه منفی طبقه‌بندی شده (False Negative) و FN به ترتیب نمونه‌های مثبت و منفی هستند که نادرست طبقه‌بندی شده‌اند و N نیز برابر تعداد کل نمونه‌ها است.

نتایج

از آنجایی که اجرای برنامه بر پایه یادگیری عمیق به جهت محاسبات و پردازش اطلاعات از میان میلیون‌ها داده مختلف صورت می‌گیرد، از یک پردازنده معمولی نمی‌توان انتظار داشت این عملیات را انجام دهد. لذا ضرورت تهیه سخت‌افزارهایی با سرعت بالاتر و قوی‌تر از نیازهای مهم فرایند فوق می‌باشد. برای پیاده‌سازی روش پیشنهادی از زبان برنامه‌نویسی پایتون استفاده شد که باعث تسهیل طراحی و پیاده‌سازی الگوریتم‌های یادگیری ماشین و یادگیری عمیق شده است. برای استفاده از محیط برنامه‌نویسی پایتون، از آناکوندا استفاده شده است. لازم به ذکر است که بر اساس مدل پیشنهادی، از ترکیب شبکه YOLO و XGBoost برای دسته‌بندی استفاده شد. هاپیرپارامترهای مورد استفاده برای تنظیم مدل پیشنهادی در جدول ۳ نشان داده شده است.

جدول ۳: هاپیرپارامترهای مورد استفاده برای تنظیم مدل پیشنهادی

نرخ یادگیری	۰/۰۰۱
تکرار	۵۰۰
بهینه‌ساز	Adam
تعداد نمونه‌ها در هر دسته آموزشی	۲
فعال‌ساز	ReLU
تعداد زیر بچ‌ها (batch)	۱۲
ضریب جریمه روی وزن‌ها برای جلوگیری از بیش‌برازش	۰/۰۰۰۵



همان‌طور که در جدول ۳ نشان داده شده است، هایپرپارامترهای مدل پیشنهادی با هدف بهینه‌سازی عملکرد و جلوگیری از بیش‌برازش تنظیم شده‌اند. نرخ یادگیری برابر 0.001 انتخاب شد تا فرآیند آموزش به‌صورت پایدار و تدریجی انجام شود. تعداد تکرار آموزش برابر 500 تعیین گردید تا مدل فرصت کافی برای یادگیری الگوهای موجود در داده‌ها داشته باشد. بهینه‌ساز Adam به دلیل توانایی سازگاری با نرخ یادگیری و عملکرد مناسب در داده‌های نویزی به کار گرفته شد. اندازه دسته برابر 2 و تعداد زیربخش‌ها برابر 12 در نظر گرفته شد تا مصرف حافظه در پردازش داده‌های با ابعاد بالا کاهش یابد. برای ایجاد غیرخطی‌سازی در شبکه از تابع فعال‌ساز ReLU استفاده شد. همچنین، ضریب کاهش وزن برابر 0.0005 برای محدود کردن مقادیر وزن‌ها و جلوگیری از بیش‌برازش مدل انتخاب گردید. نتایج حاصل از اعمال مدل پیشنهادی روی نمونه داده‌های آموزشی هر پنج کلاس معرفی شده در جدول ۴ نشان داده است.

جدول ۴: نتایج حاصل از پیاده‌سازی مدل پیشنهادی

امتیاز F	حساسیت	صحت	دقت	دسته‌ها
۹۸/۲	۹۸/۷	۹۸/۶	۹۸/۶	ریتم طبیعی
۹۸/۴	۹۹/۱	۹۷/۸	۹۷/۸	ضربان بلوک شاخه سمت چپ
۹۷/۳	۹۸/۳	۹۸/۴	۹۸/۲	ضربان بلوک شاخه سمت راست
۹۸/۳	۹۸/۶	۹۷/۳	۹۸/۴	انقباض زودرس بطن
۹۸/۶	۹۸/۲	۹۸/۲	۹۸/۲	ضربان زودرس دهلیزی
۹۸/۱۶	۹۸/۵۸	۹۸/۰۶	۹۸/۲۴	مجموع داده‌ها

همان‌طور که در جدول ۴ مشاهده می‌شود، مدل پیشنهادی در تمام کلاس‌های انتخاب‌شده دقتی بالاتر از 97% داشته و میانگین دقت کلی آن به 98.24% رسیده است. این عملکرد بالا در تمامی معیارهای صحت، حساسیت و امتیاز-F نشان‌دهنده توان مدل در شناسایی دقیق و پایدار انواع ضربان‌های قلبی است. برای مثال، در کلاس ضربان بلوک شاخه سمت چپ دقت 97.8% و حساسیت برابر 99.1% به‌دست آمده که بیانگر توانایی مدل در شناسایی تقریباً کامل نمونه‌های این کلاس است. در ادامه نیز به منظور نشان دادن برتری روش پیشنهادی، این مدل با سایر مدل‌های پایه مقایسه شده است. نتایج مقایسه‌ها در جدول ۵ نشان داده شده است.

جدول ۵: مقایسه مدل پیشنهادی با سایر مدل‌های پایه

روش	دقت
1D-CNN	۸۸/۲۵
2D-CNN	۹۰/۲۳
AlexNet	۹۵/۳۱
VGGNet	۹۶/۲۴
ResNet	۹۷/۳۰
YOLO V4	۹۷/۸۰
YOLO+XGBoost	۹۸/۲۴

مقایسه نتایج جدول ۵ نشان می‌دهد که مدل پیشنهادی YOLO+XGBoost نسبت به شبکه‌های پایه مانند 1D-CNN (با دقت 88.25%) و حتی مدل‌های عمیق‌تر مانند ResNet 97.30% و YOLO V4 97.80% عملکرد بهتری داشته است. علت اصلی این برتری، ترکیب دو بخش مکمل در مدل پیشنهادی است: قابلیت YOLO در استخراج ویژگی‌های مکانی-زمانی غنی از سیگنال ECG و توانایی XGBoost در ترکیب مجموعه‌ای از طبقه‌بندی‌کننده‌های ضعیف به یک طبقه‌بندی‌کننده قوی که الگوهای غیرخطی پیچیده را بهتر شناسایی می‌کند.

این ترکیب باعث شده حتی نسبت به YOLO v4 به‌تنهایی، دقت طبقه‌بندی ۰/۴۴٪ افزایش یابد که در کار با داده‌های پزشکی و حساسیت بالای کاربرد، تفاوت معناداری محسوب می‌شود. از سوی دیگر، استفاده از XGBoost باعث کاهش تأثیر عدم‌توازن کلاس‌ها شده و توانایی مدل در شناسایی کلاس‌های کم‌نمونه مانند APB را بهبود داده است.

جدول ۶: ماتریس آشفتگی مدل پیشنهادی

پیش‌بینی: ضربان زودرس دهلیزی	پیش‌بینی: انقباض زودرس بطن	پیش‌بینی: ضربان بلوک شاخه سمت راست	پیش‌بینی: ضربان بلوک شاخه سمت چپ	پیش‌بینی: ریتم طبیعی	
۵۸	۶۸	۸۷	۸۳	۲۰۹۹	ریتم طبیعی
۷	۸	۷	۱۰۹۳	۱۹	ضربان بلوک شاخه سمت چپ
۲	۴	۲۱۴۵	۱۰	۲۱	ضربان بلوک شاخه سمت راست
۱	۲۰۵۵	۶	۹	۱۵	انقباض زودرس بطن
۷۳۸	۲	۵	۷	۱۲	ضربان زودرس دهلیزی


با بررسی جدول ۶ می‌توان به موارد زیر اشاره کرد:

- **خطاهای نمونه منفی** که به اشتباه مثبت طبقه‌بندی شده
 - در کلاس ریتم طبیعی، تعداد کمی از سیگنال‌ها (حدود ۱/۴٪) به‌اشتباه در کلاس‌های ضربان بلوک شاخه سمت چپ، ضربان بلوک شاخه سمت راست یا انقباض زودرس بطن قرار گرفته‌اند. علت اصلی این اشتباه‌ها شباهت بخش‌های خاصی از موج QRS در نمونه‌های نویزی است.
 - در کلاس انقباض زودرس بطن نیز نمونه‌هایی وجود دارد که به‌اشتباه به عنوان ضربان بلوک شاخه سمت راست یا ضربان بلوک شاخه سمت چپ پیش‌بینی شده‌اند، که این امر ناشی از نزدیکی شکل موج در برخی بیماران و نیز تداخلات الکتریکی در سیگنال است.

- **خطاهای نمونه مثبت** که به اشتباه منفی طبقه‌بندی شده
 - بالاترین نرخ مثبت که به اشتباه منفی طبقه‌بندی شده مربوط به کلاس ضربان زودرس دهلیزی است (حدود ۳/۴٪)، که می‌تواند ناشی از کمبود نمونه آموزشی در این کلاس و شباهت نسبی الگوی موجی آن با ضربان‌های نرمال یا PVC باشد.
 - کلاس‌های ضربان بلوک شاخه سمت چپ و ضربان بلوک شاخه سمت راست خطاهای کمی دارند، ولی اشتباهات بیشتر در مرز بین این دو کلاس رخ داده که نشان‌دهنده شباهت بالای ساختار موجی آن‌ها است.

- الگوهای کلی خطا

- کلاس‌های با تعداد نمونه کمتر مثل ضربان زودرس دهلیزی بیشترین آسیب را از عدم‌توازن داده می‌بینند، هرچند استفاده از XGBoost نسبت به YOLO خالص این اثر را کاهش داده است.
- بیشتر اشتباهات در تفکیک کلاس‌هایی رخ داده که ویژگی‌های ECG آن‌ها شباهت ساختاری دارد. مانند انقباض زودرس بطن و ضربان بلوک شاخه سمت راست است.



شکل ۴: نمودار ROC مدل پیشنهادی

همان‌طور که در شکل ۴ مشاهده می‌شود، مساحت زیر منحنی (AUC (Area Under the Curve) برای همه کلاس‌ها بالاتر از ۰/۹۷ است که نشان‌دهنده توانایی بسیار بالای مدل در تفکیک صحیح کلاس‌ها است. این موضوع به‌ویژه در کلاس‌های با تعداد نمونه کمتر مانند ضربان زودرس دهلیزی اهمیت دارد، زیرا مدل توانسته با وجود عدم توازن داده، الگوهای متمایز این کلاس‌ها را به‌خوبی شناسایی کند. شیب تند منحنی‌ها در ابتدای محور نشان‌دهنده حساسیت بالای مدل در شناسایی نمونه‌های مثبت واقعی و نرخ پایین مثبت کاذب است.

نتایج نشان می‌دهد که ترکیب YOLO و XGBoost توانسته است دقت مدل را نسبت به روش‌های پایه بهبود دهد. دلیل اصلی این بهبود، استفاده از ویژگی‌های مکانی-زمانی استخراج‌شده توسط YOLO و توانایی XGBoost در ترکیب مجموعه‌ای از طبقه‌بندی‌کننده‌های ضعیف برای شناسایی الگوهای غیرخطی پیچیده در داده‌های ECG است. این رویکرد باعث شده مدل به‌ویژه در کلاس‌های با تعداد نمونه کمتر عملکرد بهتری داشته باشد. با این حال، مدل پیشنهادی در شرایطی که حجم داده آموزشی محدود یا تنوع آن کم باشد، ممکن است دچار بیش‌برازش شود. همچنین، ماهیت دو مرحله‌ای پردازش باعث افزایش زمان آموزش و نیاز به منابع محاسباتی بیشتر می‌شود که می‌تواند در کاربردهای بلادرنگ محدودیت ایجاد کند. بررسی تأثیر تغییر هایپرپارامترها نشان داد که نرخ یادگیری ۰/۰۰۱ بهترین تعادل بین سرعت همگرایی و دقت نهایی را فراهم کرده است؛ نرخ‌های بالاتر باعث کاهش دقت و نرخ‌های پایین‌تر موجب کندی همگرایی شدند. افزایش اندازه بچ (Batch size) موجب کاهش نوسانات در فرآیند آموزش شد، ولی مصرف حافظه را افزایش داد. تغییر تعداد لایه‌ها و نسخه YOLO نیز بر زمان آموزش و دقت نهایی تأثیرگذار بود؛ به‌طور کلی، نسخه‌های سبک‌تر YOLO زمان آموزش کمتری داشتند، ولی در شناسایی جزئیات الگوها دقت پایین‌تری نشان دادند.

بحث و نتیجه‌گیری

یافته‌های این پژوهش نشان داد که ترکیب شبکه YOLO و الگوریتم XGBoost می‌تواند عملکرد بهتری در تشخیص آریتمی‌های قلبی بر اساس سیگنال‌های ECG نسبت به روش‌های متداول ارائه دهد. استفاده از YOLO این امکان را فراهم کرد که ویژگی‌های میان‌سطحی سیگنال‌ها به‌طور خودکار استخراج شوند، در حالی که XGBoost با تجمیع طبقه‌بندی‌کننده‌های ضعیف، توانست دقت نهایی مدل را به شکل قابل توجهی افزایش دهد. این نتایج با گزارش‌های پیشین در حوزه ترکیب یادگیری عمیق و الگوریتم‌های تقویتی همسو است، اما نوآوری اصلی پژوهش حاضر در بهره‌گیری از YOLO به‌عنوان یک استخراج‌کننده ویژگی در داده‌های ECG محسوب می‌شود. با وجود این دستاوردها، محدودیت‌هایی نیز وجود دارد. استفاده از پایگاه داده MIT-BIH به‌عنوان تنها منبع داده، سبب می‌شود قابلیت تعمیم‌پذیری مدل در شرایط واقعی بالینی محدود شود. همچنین حجم نسبتاً کوچک داده‌ها مانع از آموزش مدل‌های عمیق می‌شود و ممکن است در کارایی آن در مواجهه با داده‌های جدید تأثیرگذار باشد. علاوه بر این، تمرکز بر یک نوع آریتمی خاص می‌تواند محدودیت دیگری برای کاربرد گسترده مدل به حساب آید.

با توجه به نتایج به‌دست‌آمده، می‌توان نتیجه گرفت که مدل پیشنهادی توانایی بالایی برای استفاده به‌عنوان ابزار کمک‌تشخیصی در سیستم‌های پشتیبان تصمیم‌گیری بالینی دارد. این مدل می‌تواند در غربالگری اولیه بیماران و شناسایی افراد در معرض خطر بالا مفید واقع شود و در نهایت به بهبود کیفیت خدمات سلامت و کاهش بار بیماری‌های قلبی منجر گردد.

پیشنهاد می‌شود در مطالعات آینده، داده‌های متنوع‌تر و بزرگ‌تری از مراکز مختلف بالینی مورد استفاده قرار گیرد تا قابلیت تعمیم‌پذیری مدل افزایش یابد. همچنین بهره‌گیری از رویکردهای انتقال یادگیری و انطباق دامنه می‌تواند به کاهش چالش کمبود داده کمک کند. تحلیل جامع خطاها و شناسایی موقعیت‌هایی که بیشترین احتمال بروز خطا را دارند نیز از دیگر مسیرهای مهم پژوهشی خواهد بود. در نهایت، توسعه نسخه‌های کارآمد و بهینه‌شده این مدل در قالب نرم‌افزارهای بالینی می‌تواند گامی مؤثر در کاربرد واقعی آن در محیط‌های درمانی باشد.

تعارض منافع

هیچ گونه تضاد منافی بین نویسندگان وجود ندارد.

کد اخلاق

این مطالعه دارای مجوز از کمیته اخلاق دانشگاه علوم پزشکی کرمان با کد IR.KMU.REC.1404.350 می‌باشد.

سهم مشارکت نویسندگان

مفهوم و طراحی روش، تجزیه و تحلیل و تفسیر داده‌ها: علیرضا اصغری کیاده، پیش نویس مقاله، تجزیه و تحلیل آماری و بازبینی مقاله توسط سارا معتمد انجام شده است.

References

- [1]. Ahsan MM, Siddique Z. Machine learning-based heart disease diagnosis: A systematic literature review. *Artif Intell Med* 2022;102289. doi: [10.1016/j.artmed.2022.102289](https://doi.org/10.1016/j.artmed.2022.102289)
- [2]. Brites IS, da Silva LM, Barbosa JL, Rigo SJ, Correia SD, Leithardt VR. Machine learning and iot applied to cardiovascular diseases identification through heart sounds: A literature review. *InFormatics* 2021; 8(4): 73.
- [3]. Diwakar M, Tripathi A, Joshi K, Memoria M, Singh P. Latest trends on heart disease prediction using machine learning and image fusion. *Materials Today: Proceedings* 2021;37:3213-8. doi:[10.1016/j.matpr.2020.09.078](https://doi.org/10.1016/j.matpr.2020.09.078)
- [4]. Elhoseny M, Mohammed MA, Mostafa SA, Abdulkareem KH, Maashi MS, Garcia-Zapirain B, et al. A New Multi-Agent Feature Wrapper Machine Learning Approach for Heart Disease Diagnosis. *Computers, Materials & Continua*. 2021;67(1): 51-71. <https://doi.org/10.32604/cmc.2021.012632>
- [5]. Elias P, Poterucha TJ, Rajaram V, Moller LM, Rodriguez V, Bhav S, et al. Deep learning electrocardiographic analysis for detection of left-sided valvular heart disease. *J Am Coll Cardiol* 2022;80(6):613-26. doi: [10.1016/j.jacc.2022.05.029](https://doi.org/10.1016/j.jacc.2022.05.029)
- [6]. Kavitha M, Gnaneswar G, Dinesh R, Sai YR, Suraj RS. Heart disease prediction using hybrid machine learning model. In 2021 6th international conference on inventive computation technologies (ICICT); 2021 Jan 20-22; Coimbatore, India: IEEE; 2021. p. 1329-33. doi: [10.1109/ICICT50816.2021.9358597](https://doi.org/10.1109/ICICT50816.2021.9358597)
- [7]. Ramesh KN, Ramesh P, Manisha G, Anupama G, Nithin GR, Prasad MM. Heart Disease Prediction using Hybrid Machine Learning Techniques. *Journal of Algebraic Statistics* 2022;13(2): 3669.
- [8]. Amiri A, Jafarzadeh H, Parvortabar Z. Heart disease diagnosis using artificial intelligence and data mining techniques. *The First Regional Conference on Power Refining Information Technology*; 2014 May 31; Gachsaran: Gachsaran Applied Science Center; 2014. [In Persian]
- [9]. Faridouni M, Estakhrian A. Design and simulation of a trainable bioelectric system for arrhythmia diagnosis using neural networks. *The first national conference on electrical engineering of the Young and Elite Researchers Club*; 2016 Apr 26; Shiraz: Islamic Azad University of Shiraz; 2016. [In Persian]
- [10]. Rajabloo S, Molaiean T, Yaghmaei F. Heart disease diagnosis using fuzzy logic. *The Second National Conference on Mathematics and its Applications in Engineering*; 2015 May 14; Juybar: Islamic Azad University of Juybar; 2015. [In Persian]
- [11]. Mokhtari M, Pishgar SH. ECG signal modeling using spline interpolation for heart disease diagnosis. *3rd National Conference on New Technologies in Electrical and Computer Engineering*; 2016. [In Persian]



- [12]. Naroui A, Zamani B. Arrhythmia heart disease diagnosis using PCA and MLP neural network. National Conference on Modern Research in Science and Technology; 2015; Iran. [In Persian].
- [13]. Dashti nejad N, Askar Farashah M. Diagnosis of liver and heart disease through iridology based on error backpropagation network. 2015 Sep 5; International Conference on New Research Findings in Electrical Engineering and Computer Science, Tehran: Nikan; 2016. [In Persian]
- [14]. Nazari A. Evaluation of performance and accuracy of data mining techniques for timely heart disease diagnosis. 4th International Conference New Research in Engineering and Technology; 2015. [In Persian]
- [15]. Hadadnia J, Mahdavi A. Pattern recognition technology in diagnosis and analysis of heart diseases. In: 3rd National and 1st Int Conference Applied Research in Electrical, Mechanical and Mechatronics Engineering; 2015; Iran. [In Persian].
- [16]. Dowlatabadi A, Hajipour A. Heart disease diagnosis using chaotic features and neural networks. 7th National Conference Electrical and Electronics Engineering of Iran; 2015. [In Persian]
- [17]. Palaniappan S, Awang R. Intelligent heart disease prediction system using data mining techniques. In: 2008 IEEE/ACS International Conference on Computer Systems and Applications; 2008 Mar 31; IEEE; 2008.p. 108-15.
- [18]. Taneja A. Heart disease prediction system using data mining techniques. Orient J Comp Sci Technol 2013;6(4):457–66.
- [19]. Lakshmi MS, Haritha D, Srkit V. Heart disease diagnosis using predictive data mining. International Journal of Computer Science and Information Security 2016;14(7):1–5.
- [20]. Masethe HD, Masethe MA. Prediction of heart disease using classification algorithms. Proceedings of the World Congress on Engineering and Computer Science 2014 Oct 22-24; San Francisco, USA: WCECS; 2014.
- [21]. Chen T, He T, Benesty M, Khotilovich V, Tang Y, Cho H, et al. Xgboost: Extreme Gradient Boosting; R Package Version 0.4-2; 2015.
- [22]. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature 2015;521(7553):436–44.
- [23]. Yadav SS, Jadhav SM. Deep convolutional neural network based medical image classification for disease diagnosis. Journal of Big Data 2019;6(1):1–18.
- [24]. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems; 2012. p. 1–9.
- [25]. Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2016 Aug 13; p. 785-94.