



2025 (Autumn), 3(3):19-25

DOI:

Research article

Journal of Physiology of Training and Sports Injuries

(PTSIJournal@gmail.com)

(zanjan.ptsijournal@iau.ac.ir)

<https://sanad.iau.ir/journal/eps>

Received: 2025/9/11

Accepted: 2025/11/1

(ISSN: 3060 - 6306)

ECG-based Smart Assessment for the Prevention of Exercise-Related Cardiac Events: A Lightweight Prediction Framework

Mahdi Bazargani¹, Nafiseh Fareghzadeh², Hassan Ziafat³

1. Department of Computer Engineering, Za.C., Islamic Azad University, Zanjan, Iran. Email: mbzirm@iau.ac.ir.

2. Department of Computer Engineering, Khod.C., Islamic Azad University, Khodabandeh, Zanjan, Iran.

(Corresponding Author). Email: fareghzadeh@iau.ac.ir.

3. Department of Computer Engineering, Nat.C., Islamic Azad university, Natanz, Iran. Email: dr.ziafat@iau.ac.ir

Abstract:

The prevalence of cardiovascular diseases continues to increase annually, with heart attacks constituting the most common of these diseases. Diagnosis of heart disease (HD) is associated with significant challenges due to the high variability of symptoms. Advances in wearable smart devices have facilitated the development of Internet of Things (IoT)-based healthcare solutions; however, designing a lightweight and efficient model for diagnosing heart diseases remains challenging.

In this paper, a novel two-stage approach for classifying heart disease is presented. In the first step, an optimized nonlinear support vector machine (SVM) is used to effectively separate classes. The second step uses a modified fuzzy logic system to refine and improve the classification process. Electrocardiogram (ECG) signals are first preprocessed to remove noise and smooth the data, then features including PQRS waveform characteristics, linear features, and mutual information are extracted. The classification framework involves a two-stage learning process focusing on cardiac arrhythmias. In the first step, each class is individually subjected to a binary classifier using the Wild Horse Optimization algorithm with sigmoid thresholding (WHO-sigmoid-TH-NL-demarcation). The resulting outputs are then processed by a Takagi-Sugeno (TS) fuzzy logic system optimized by the Giza Pyramid Construction (GPC) method for final decision making.

Evaluation on the MIT-BIH arrhythmia database shows the effectiveness of the proposed method; with average accuracy, sensitivity and specificity of 98.58%, 98.13% and 96.47%, respectively. The implementation of this approach in the MATLAB environment demonstrates its practical applicability and effectiveness.

Keywords: Heart Disease Diagnosis, Internet of Things (IoT), WHO-sigmoid-TH-NL-demarcation, GPC-TS fuzzy logic, MIT-BIH arrhythmia database, MATLAB.

How to Cite: Bazargani, M., Fareghzadeh, N., Ziafat, H. (2025). ECG-based Smart Assessment for the Prevention of Exercise-Related Cardiac Events: A Lightweight Prediction Framework. Journal of Physiology of Training and Sports Injuries, 3(3):19-25. [Persian].

فصلنامه فیزیولوژی تمرین و آسیب‌های ورزشی؛ پاییز ۱۴۰۴، ۳(۳).



دوره ۳ - شماره ۳
پاییز ۱۴۰۴ - صص: ۱۹-۲۵

تاریخ دریافت: ۱۴۰۴/۶/۲۰
تاریخ پذیرش: ۱۴۰۴/۸/۱۰
مقاله پژوهشی

ارزیابی هوشمند مبتنی بر الکتروکاردیوگرام برای پیشگیری از رویدادهای قلبی مرتبط با ورزش: یک چارچوب پیش‌بینی سبک‌وزن

مهدی بازرگانی^۱، نفیسه فارغ‌زاده^۲، حسن ضیافت^۳

۱. گروه مهندسی کامپیوتر، واحد زنجان، دانشگاه آزاد اسلامی، زنجان، ایران.

۲. گروه مهندسی کامپیوتر، واحد خدابنده، دانشگاه آزاد اسلامی، خدابنده، ایران. (نویسنده مسئول).

پست الکترونیک: fareghzadeh@iau.ac.ir

۳. گروه مهندسی کامپیوتر، واحد نطنز، دانشگاه آزاد اسلامی، نطنز، ایران.

چکیده:

شیوع بیماری‌های قلبی عروقی هم‌چنان به‌صورت سالانه در حال افزایش است و حملات قلبی، شایع‌ترین این بیماری‌ها است. تشخیص بیماری‌های قلبی به‌دلیل تنوع بالای علائم، با چالش‌های قابل توجهی همراه است. پیشرفت در دستگاه‌های هوشمند پوشیدنی، توسعه راهکارهای مراقبت سلامت مبتنی بر اینترنت اشیا (IoT) را تسهیل کرده است؛ با این حال، طراحی مدلی سبک‌وزن و کارآمد برای تشخیص بیماری‌های قلبی هم‌چنان دشوار است.

در این مقاله، یک رویکرد نوین دو مرحله‌ای برای طبقه‌بندی بیماری‌های قلبی ارائه می‌شود. در مرحله نخست، از یک ماشین بردار پشتیبان غیرخطی بهینه‌سازی شده (SVM) به‌منظور جداسازی مؤثر کلاس‌ها استفاده می‌شود. مرحله دوم، از یک سیستم منطق فازی اصلاح‌شده برای پالایش و بهبود فرآیند طبقه‌بندی بهره می‌گیرد. سیگنال‌های الکتروکاردیوگرام (ECG) در ابتدا، پیش‌پردازش می‌شوند تا نویزها حذف و داده‌ها هموارسازی شوند. سپس، ویژگی‌هایی شامل مشخصه‌های موج‌های PQRST، ویژگی‌های خطی و اطلاعات متقابل، استخراج می‌گردد. چارچوب طبقه‌بندی شامل یک فرآیند یادگیری دو مرحله‌ای با تمرکز بر آریتمی‌های قلبی است. در گام نخست، هر کلاس به‌صورت جداگانه تحت یک طبقه‌بندی دودویی قرار می‌گیرد که از الگوریتم بهینه‌سازی اسب وحشی همراه با آستانه‌گذاری سیگموئیدی (WHO-sigmoid-TH-NL-demarcation) استفاده می‌کند. پس از آن، خروجی‌های حاصل، توسط یک سیستم منطق فازی تاکاگی-سوگنو (TS) که با روش ساخت اهرام جیزه (GPC) بهینه‌سازی شده است، برای تصمیم‌گیری نهایی پردازش می‌شوند. ارزیابی‌های انجام شده روی پایگاه داده آریتمی MIT-BIH نشان‌دهنده اثربخشی روش پیشنهادی است؛ به‌طوری‌که میانگین دقت، حساسیت و ویژگی به‌ترتیب برابر با ۹۸٫۵۸٪، ۹۸٫۱۳٪ و ۹۶٫۴۷٪ به‌دست آمد. پیاده‌سازی این رویکرد در محیط MATLAB انجام شد که کاربردپذیری عملی آن را نشان داد.

واژگان کلیدی: تشخیص بیماری قلبی، اینترنت اشیا (IoT)، WHO-sigmoid-TH-NL-demarcation، منطق فازی GPC-TS، پایگاه داده آریتمی MIT-BIH، MATLAB.

شیوه استناددهی: بازرگانی، مهدی؛ فارغ‌زاده، نفیسه؛ ضیافت، حسن. ارزیابی هوشمند مبتنی بر الکتروکاردیوگرام برای پیشگیری از رویدادهای قلبی مرتبط با ورزش: یک چارچوب پیش‌بینی سبک‌وزن. فصلنامه فیزیولوژی تمرین و آسیب‌های ورزشی، پاییز ۱۴۰۴، ۳(۳): ۱۹-۲۵.

فصلنامه فیزیولوژی تمرین و آسیب‌های ورزشی؛ پاییز ۱۴۰۴، ۳(۳).



۱. مقدمه

بیماری‌های قلبی عروقی به‌عنوان یکی از مهم‌ترین علل مرگ‌ومیر در سراسر جهان، هر ساله، مسئول میلیون‌ها مورد فوت هستند. تشخیص زودهنگام، به‌ویژه در مناطق کم‌برخوردار که دسترسی به تخصص پزشکی محدود است، از اهمیت بالایی برخوردار است [۱۲].

آریتمی‌ها به‌عنوان یکی از شایع‌ترین اختلالات ریتم قلب، عمدتاً از طریق الکتروکاردیوگرام (ECG) تشخیص داده می‌شوند؛ با این حال، شباهت شکل موج‌ها و تنوع ناهنجاری‌ها، تفسیر سیگنال‌ها را برای پزشکان دشوار و زمان‌بر می‌سازد. الکتروکاردیوگرام ابزاری کم‌هزینه و پرکاربرد است که فعالیت الکتریکی قلب را بازتاب می‌دهد و می‌تواند تحت تأثیر عواملی نظیر پرفشاری خون، هایپرتروفی میوکارد یا کم‌خونی ناشی از بیماری‌های کلیوی قرار گیرد [۱].

اینترنت اشیا، امکان پایش پیوسته بیماری‌های قلبی را فراهم کرده است. رویکردهای یادگیری ماشین قابلیت بالایی در پیش‌بینی و تشخیص بیماری‌های قلبی عروقی از خود نشان داده‌اند، با این حال، اغلب آن‌ها فاقد چارچوب‌های هوشمند برای مدیریت کارآمد داده‌های با ابعاد بالا هستند. با توجه به پیچیدگی الگوریتم‌ها، نیاز به راهکارهای سبک‌وزن، کارآمد و کاربردی مبتنی بر اینترنت اشیا به‌طور فزاینده‌ای در حال افزایش است [۷].

روش‌های مبتنی بر یادگیری عمیق در تحلیل سیگنال الکتروکاردیوگرام، معمولاً شامل مراحل زیر است. دریافت سیگنال از بیماران از طریق اینترنت اشیا، پیش‌پردازش با استفاده از پاسخ ضربه‌ای محدود، استخراج ویژگی‌هایی نظیر موج P، قطعه ST، قله R، تغییرپذیری ضربان قلب (HRV)، قطعه PQ، طول موج‌های T و QRS، تبدیل‌های موجک و اطلاعات متقابل، انتخاب ویژگی با استفاده از مدل‌های بهینه‌سازی ترکیبی (برای مثال، بهینه‌ساز Alpha Spider Dwarf که ترکیبی از TSA و SMA است) و در نهایت، طبقه‌بندی با استفاده از شبکه‌های عصبی کانولوشنی شبکه‌های Bi-LSTM یا RNN. همچنین، مدل‌های ترکیبی که از SVM، آدابوست و جنگل تصادفی (RF) بهره می‌گیرند، نظیر ASM-RF، موجب افزایش دقت پیش‌بینی، کاهش نرخ خطا و بهبود زمان پاسخ می‌شوند. در این رویکردها، توابع برازندگی برای بهینه‌سازی لایه‌های طبقه‌بندی به کار می‌روند که به تصمیم‌گیری به‌موقع درمانی کمک می‌کند [۵]. سیستم‌های یادگیری عمیق مبتنی بر اینترنت اشیا، نظیر DLMNN، با ترکیب احراز هویت، رمزنگاری و طبقه‌بندی، انتقال امن داده‌ها را فراهم کرده و تشخیص بیماری قلبی را با حساسیت، ویژگی و دقت بالا انجام می‌دهند [۵]. مدل‌های یادگیری ماشین دو مرحله‌ای که از متامدل‌های وزن‌دهی شده ویژگی و رویکردهای رأی‌گیری ترکیبی استفاده می‌کنند، در پیش‌بینی

بیماری عروق کرونری عملکرد مؤثری داشته و به دقتی معادل ۹۵٫۸۷٪ دست یافتند. همچنین، شبکه‌های CNN سبک‌وزن برای استخراج ویژگی‌های ECG که با پروتکل‌های مسیریابی کم‌صرف ادغام شدند، دقت‌هایی تا ۹۸٫۳۹٪ را گزارش کردند [۱۱]. مدل‌های فازی LSTM که از الگوریتم PF-HHO برای انتخاب ویژگی استفاده می‌کنند، پیش‌بینی بلادرنگ رویدادهای قلبی را بهبود دادند [۹]. سیستم‌های مبتنی بر شبکه‌های بدن بی‌سیم (WBAN) از الگوریتم IDOX برای انتخاب کانال و از ID-CNN همراه با خودمرزگذارها برای استخراج ویژگی بهره می‌برند [۱۳]. در حوزه طبقه‌بندی استرس مبتنی بر EEG، استفاده از LSTM و بهینه‌سازی مورچه-شیر (Ant-lion) موجب بهبود تشخیص بیماری‌های قلبی عروقی شد [۱۰]. سامانه‌هایی نظیر CAHRD با ترکیب پیش‌پردازش الگوریتم Pan-Tompkins، استخراج ویژگی، بهینه‌سازی مبتنی بر موجک (BWO) و SVM هسته‌ای، طبقه‌بندی ضربان قلب را انجام دادند [۲]. رویکردهای چندمرحله‌ای مبتنی بر DCNN و ERBF به امتیاز F معادل ۹۶٫۰۳٪ دست یافتند [۳]. همچنین، سیگنال‌های ECG اصلاح‌شده که با شبکه‌های D-CNN پردازش شدند، دقت‌های ۹۷٫۷۰٪ برای پایگاه داده MIT-BIH، ۹۹٫۷۱٪ برای St. Petersburg و ۹۸٫۲۴٪ برای PTB را نشان دادند [۶].

در مجموع، اگرچه این پژوهش‌ها، پیشرفت‌های قابل‌توجهی در طبقه‌بندی آریتمی‌های قلبی ارائه داده‌اند، اما اغلب به پیچیدگی پیاده‌سازی در محیط‌های مبتنی بر اینترنت اشیا توجه کافی نداشته‌اند. توسعه مدل‌های طبقه‌بندی سبک‌وزن، نظام‌مند و مناسب برای اینترنت اشیا، همچنان به‌عنوان یک خلأ پژوهشی باقی مانده است. در این مطالعه، یک مدل یادگیری ماشین ترکیبی سبک‌وزن و سازگار با اینترنت اشیا برای طبقه‌بندی سیگنال‌های ECG پیشنهاد می‌شود. در این چارچوب، از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) برای انتخاب ویژگی‌های مرتبط استفاده شده و سپس، یک طبقه‌بندی دو مرحله‌ای به کار گرفته می‌شود. در مرحله نخست، روش WHO برای وزن‌دهی ویژگی‌ها و طبقه‌بندی دودویی مورد استفاده است. در مرحله دوم، یک سیستم فازی بهینه‌سازی شده با روش ساخت اهرام جیزه (GPC) به کار می‌رود. این رویکرد، امکان تشخیص دقیق، زودهنگام و از راه دور آریتمی‌های قلبی را فراهم کرده و آن را برای محیط‌های با منابع محدود، مناسب می‌سازد. در این راستا، پژوهش حاضر یک رویکرد یادگیری ماشین مبتنی بر الگوریتم‌های فراابتکاری را برای دستیابی به مدلی سبک‌وزن و کارآمد با دقت بالا پیشنهاد می‌کند. اهداف این پژوهش شامل موارد زیر است.


- معرفی یک سیستم سبک‌وزن و کارآمد مبتنی بر اینترنت اشیا برای دستگاه‌های پوشیدنی به‌منظور پایش علائم حیاتی در بیماری‌های قلبی عروقی.

$$F(X) = W_1 \cdot X^3 + W_2 \cdot X^2 + W_3 \cdot X \quad (1)$$

$$Z = \sum F_i(X) \quad (2)$$

$$\text{Sigmoid}(X) = \frac{1}{1 + e^{-w_1(Z-w_2)}} \quad (3)$$

- تولید ویژگی های دودویی برای هر قطعه سیگنال ECG
- تابع برازندگی مطابق با الگوریتم ۱ تعریف شد.
- عملکرد مدل در شکل ۲ نمایش داده شد.



شکل ۱. نمایش فلوچارت معماری مدل پیشنهادی

الگوریتم ۱. تابع برازندگی برای روش

WHO-sigmoid-TH-NL-demarcation (مرحله اول)

```
function [output] = fitnessfunction3D (w, X, Y)
W = w(1:(end-2));
out = (X.^3) * W(1:13) + (X.^2) * W(14:26) + X * W(27:39);
out = 1. / (1 + exp(-1 * w(end-1) * (out - w(end))));
output = sum(abs(Y - out));
end
```

- به کارگیری الگوریتم های فرا ابتکاری WHO و GPC برای طبقه بندی دودویی سیگنال های الکتروکاردیوگرام.
- استفاده از یادگیری ماشین و الگوریتم GWO به منظور بهبود استخراج ویژگی و انتخاب بهینه ویژگی ها.
- توسعه یک چارچوب دولایه شامل ترکیب GPC-TS-Fuzzy و WHO-sigmoid-TH-Weighting.

۲. روش پژوهش

۱.۲. پایگاه داده ECG، پیش پردازش و انتخاب ویژگی

در این پژوهش، پایگاه داده آریتمی MIT-BIH برای آموزش و آزمون مدل مورد استفاده قرار گرفت [۴]. این پایگاه داده شامل ۴۸ رکورد ECG به مدت نیم ساعت از دو لید V1 و MLII با نرخ نمونه برداری ۳۶۰ هرتز است که حاوی برچسب گذاری نوع ضربان، نوع ریتم، قله ها و محل شروع و پایان موج ها بوده و توسط متخصصان قلب انجام شده است. قطعه های ECG با طول ۵۰۰ نمونه (حدود ۳٫۹ ثانیه در نرخ ۱۲۸ هرتز) به صورت هم پوشان استخراج شدند. برای کاهش مشکل عدم توازن کلاس ها، قطعه های مربوط به تمامی افراد با یکدیگر ادغام گردیدند. همچنین، معیارهای ارزیابی به صورت وزن دار محاسبه شدند. در مرحله پیش پردازش، نویزهای فرکانس پایین و بالا با استفاده از فیلترهای میانه با پنجره های ۲۰۰ و ۶۰۰ میلی ثانیه حذف و سپس، سیگنال ها در بازه $-1, -1, +1, -1, +1, -1, +1$ نرمال سازی گردیدند [۸]. برای همسان سازی با پایگاه داده LTAF، سیگنال ها با نرخ ۱۲۸ هرتز کاهش نمونه برداری داده شده و به پنجره های ۵۰۰ نمونه ای تقسیم شدند. انتخاب ویژگی با استفاده از الگوریتم بهینه سازی گرگ خاکستری (GWO) انجام شد تا با کاهش ابعاد داده و بهبود عملکرد طبقه بندی همراه باشد. در این فرآیند، ویژگی هایی با حداقل واریانس درون کلاسی و حداکثر جدایی بین کلاسی انتخاب شدند که شامل ویژگی های مرتبط با کمپلکس QRS، ویژگی های آماری و ویژگی های حوزه فرکانس بودند.

۲.۲. معماری مدل پیشنهادی

معماری یادگیری دو مرحله ای پیشنهادی (شکل ۱) شامل اجزای زیر بود.

۱. پیش پردازش: پاک سازی و آماده سازی سیگنال های ECG.
۲. استخراج ویژگی: استخراج ۲۲ ویژگی اولیه، نرمال سازی و کاهش به تعداد ۱۳ ویژگی منتخب با استفاده از الگوریتم GWO.
۳. یادگیری ماشین در مرحله اول: (WHO-sigmoid-TH-NL-demarcation)
 - الگوریتم بهینه سازی اسب وحشی (WHO) برای بهینه سازی منحنی های سیگموئیدی غیر خطی مرتبه سوم (معادلات ۱ تا ۳) به منظور جداسازی مؤثر کلاس ها به کار گرفته شد.

۱. Gray Wolf Optimization (GWO)


فصلنامه فیزیولوژی تمرین و آسیب های ورزشی؛ بهار ۱۴۰۴، ۳(۳).

الگوریتم ۲. تابع برازندگی سیستم منطق فازی برای طبقه‌بندی بهینه با استفاده از روش GPA (مرحله دوم)

```
function [val] = fuzzyfit (x, fis, X, Y)
fis.Inputs(1, 1).MembershipFunctions(1, 1).Parameters = [x(1),0];
fis.Inputs(1, 1).MembershipFunctions(1, 2).Parameters = [x(2),1];
fis.Inputs(1, 2).MembershipFunctions(1, 1).Parameters = [x(3),0];
fis.Inputs(1, 2).MembershipFunctions(1, 2).Parameters = [x(4),1];
fis.Inputs(1, 3).MembershipFunctions(1, 1).Parameters = [x(5),0];
fis.Inputs(1, 3).MembershipFunctions(1, 2).Parameters = [x(6),1];
fis.Inputs(1, 4).MembershipFunctions(1, 1).Parameters = [x(7),0];
fis.Inputs(1, 4).MembershipFunctions(1, 2).Parameters = [x(8),1];
fis.Inputs(1, 5).MembershipFunctions(1, 1).Parameters = [x(9),0];
fis.Inputs(1, 5).MembershipFunctions(1, 2).Parameters = [x(10),1];
fis.Inputs(1, 6).MembershipFunctions(1, 1).Parameters = [x(11),0];
fis.Inputs(1, 6).MembershipFunctions(1, 2).Parameters = [x(12),1];
fis.Inputs(1, 7).MembershipFunctions(1, 1).Parameters = [x(13),0];
fis.Inputs(1, 7).MembershipFunctions(1, 2).Parameters = [x(14),1];
fis.Inputs(1, 8).MembershipFunctions(1, 1).Parameters = [x(15),0];
fis.Inputs(1, 8).MembershipFunctions(1, 2).Parameters = [x(16),1];
fis.Inputs(1, 9).MembershipFunctions(1, 1).Parameters = [x(17),0];
fis.Inputs(1, 9).MembershipFunctions(1, 2).Parameters = [x(18),1];
fis.Inputs(1, 10).MembershipFunctions(1, 1).Parameters = [x(19),0];
fis.Inputs(1, 10).MembershipFunctions(1, 2).Parameters = [x(20),1];
output = evalfis (fis, X);
Ynew = round(output*10);
accuracy = mean (Y == Ynew); % calculated accuracy
val = (1-accuracy) *100;
end
```

۳. یافته‌ها

هدف این مطالعه، طبقه‌بندی هفت نوع آریتمی همراه با ریتم طبیعی قلب است. پس از پیش‌پردازش، مجموعه داده به صورت تصادفی به ۸۵٪ برای آموزش و ۱۵٪ برای آزمون و اعتبارسنجی تقسیم شد، زیرا مجموعه‌های آموزشی بزرگ‌تر نتایج بهتری ارائه دادند. مدل برای ۱۰۰ اپوک با استفاده از تابع زیان cross-entropy آموزش داده شد.



شکل ۲. نمایش عملکرد الگوریتم WHO برای طبقه‌بندی ۷ کلاس آریتمی قلبی بر اساس ویژگی‌های منتخب سیگنال ECG

۴. یادگیری ماشین در مرحله دوم: (GPC-TS-Fuzzy)


- سیستم منطق فازی تاکاگی-سوگنو (TS) برای طبقه‌بندی خروجی‌های دودویی به کار گرفته شد.
- توابع عضویت گاو سی ورودی‌ها با استفاده از روش ساخت اهرام جیزه (GPC) بهینه‌سازی گردید.
- تابع هدف (معادله ۴) با هدف بیشینه‌سازی دقت طبقه‌بندی تعریف شد.
- (4) $F = 100 - \text{Accuracy}\%$
- الگوریتم ۲ شامل تابع بهینه‌سازی مورد استفاده در این مرحله است.

۳.۲. ارزیابی عملکرد

معیارهای ارزیابی عملکرد شامل دقت (Acc)، حساسیت (Se) و ویژگی (Sp) هستند.

- (5) $\text{Acc} (\%) \triangleq \frac{(TP+TN)}{(TP+TN+FP+FN)} \times 100\%$
- (6) $\text{Se} (\%) \triangleq \frac{TP}{(TP+FN)} \times 100\%$
- (7) $\text{Sp} (\%) \triangleq \frac{TN}{(TN+FP)} \times 100\%$

که در آن TP، TN، FP و FN به ترتیب نشان‌دهنده مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب هستند.



شکل ۵. منحنی های ویژگی عملکرد دریافت کننده (ROC) برای پیش بینی های مدل پیشنهادی در ۷ کلاس آریتمی

برای نشان دادن کارایی محاسباتی، زمان استنتاج اندازه گیری شد. مدل، تنها ۰/۳۲ میلی ثانیه به ازای هر ضربان روی Raspberry Pi داشت و به اندازه کافی سبک است که حتی روی میکروکنترلر ATmega8 نیز پیاده سازی شود. برای بررسی overfitting، ۱۰٪ از داده ها به عنوان ورودی های دیده نشده کنار گذاشته شدند. ارزیابی های جدید نشان داد که تغییرات دقت حداقلی است (۰/۰۳۲٪ برای مدل غیرخطی و ۰/۴۳۶٪ برای مدل خطی) که استحکام مدل در برابر overfitting را تأیید می کند.

۴. بحث و نتیجه گیری


یکی از اهداف کلیدی این پژوهش، طراحی روشی مناسب برای محیط های IoT با منابع محدود بود. ساختار سبک و پیش پردازش مؤثر مدل، آن را برای پایش ECG در محیط واقعی، کاربردی می سازد. با این حال، برخی کلاس های آریتمی هنوز دقت کمتری دارند و عدم قطعیت در برچسب گذاری داده های آموزش/آزمون، محدودیت هایی هستند که در پژوهش های آینده باید مورد توجه قرار گیرند.

تشخیص دقیق آریتمی های قلبی برای درمان زودهنگام حیاتی است و سیستم های تشخیص رایانه ای نقش مهمی در این زمینه دارند. در این مطالعه، سیگنال های ECG از پایگاه داده MIT-BIH برای طبقه بندی هفت نوع آریتمی و ریتم طبیعی با استفاده از یک مدل دو مرحله ای گرفته شدند. مرحله اول شامل جداسازی غیرخطی کلاس ها و وزن دهی با روش WHO است و مرحله دوم از یک طبقه بند فازی بهینه سازی شده با GPC استفاده می کند. این روش به میانگین دقت ۹۸/۵۸٪ و زمان استنتاج ۰/۳۲ میلی ثانیه دست یافت و برای کاربردهای بلادرنگ مناسب است. با وجود عملکرد بالا، برخی کلاس های آریتمی هنوز نیاز به بهبود دارند. پژوهش های آینده بر گسترش تعداد کلاس ها و ادغام تحلیل زمانی

بهینه سازی های فراابتکاری WHO و GPC به دلیل همگرایی سریع و نیاز به کمترین تنظیم پارامترها به کار گرفته شدند و به طور مستمر وزن ها و بایاس ها از طریق تابع هدف به روزرسانی شدند. ماتریس اغتشاش که عملکرد طبقه بندی را نشان می دهد، در شکل ۳ ارائه شده است. معیارهای اصلی این ماتریس نشان دهنده مثبت های واقعی است. معیارهای حساسیت و ویژگی که مستقل از تعداد قطعات هستند، برای ارزیابی استفاده شدند (شکل ۴). ویژگی در تمامی کلاس ها بیش از ۹۰٪ بود. بیشترین خطای طبقه بندی در کلاس SVTA رخ داد، در حالی که کلاس AFIB کمترین خطا را نشان داد. در مجموع، ۲۲ ویژگی استخراج شد و ۱۳ ویژگی مؤثر با استفاده از الگوریتم WGO انتخاب گردید. ویژگی های مبتنی بر PQRS بیشترین نقش را در دقت طبقه بندی ایفا کردند. مدل پیشنهادی به میانگین دقت ۹۸/۵۸٪ دست یافت. سیستم غیرخطی WHO-sigmoid-TH-NL-demarcation + GPC-TS-Fuzzy نسبت به نسخه خطی، ۷/۹۳٪ بهبود نشان داد. با وجود سادگی ساختار (تنها دو لایه پردازشی)، عملکرد آن از سیستم های پیچیده تر مانند شبکه های عصبی عمیق و روش های مبتنی بر CNN بهتر یا برابر بود. منحنی های ROC (شکل ۵) نشان می دهند که مقادیر AUC برای تمامی کلاس های آریتمی تقریباً ایده آل بوده و عملکرد تفکیک پذیری بالای مدل را منعکس می کند.

Classes	NSR	PREX	AFL	AFIB	B	T	SVTA
NSR	56	4	0	0	0	0	0
PREX	5	33	2	0	0	0	0
AFL	0	0	17	3	0	0	0
AFIB	0	0	0	40	0	0	0
B	0	0	1	0	29	0	0
T	0	0	0	0	1	13	0
SVTA	0	0	0	2	0	0	8

شکل ۳. ماتریس اشتباه پیش بینی های روش پیشنهادی روی داده های آزمون



شکل ۴. نتایج ارزیابی تکنیک پیشنهادی روی داده های آزمون و آموزش

1. Inference Time

فصلنامه فیزیولوژی تمرین و آسیب های ورزشی؛ بهار ۱۴۰۴، ۳(۳).



lightweight CNN with attention module and IoT. Sensors, 7697, (18):23.

[12] Shi, H., Wang, H., Zhang, F., Huang, Y., Zhao, L., Liu, C. (2019). Inter-patient heartbeat classification based on region feature extraction and ensemble classifier. Biomedical Signal Processing and Control, 51, 105-97.

[13] Veerabaku, M.G., Nithiyantham, J., Urooj, S., Abdul Quadir, S., Arun, K., Tee, K.F. (2023). Intelligent Bi-LSTM with architecture optimization for heart disease prediction in WBAN through optimal channel selection and feature selection. Biomedicines, 11(4), 1167.

مبتنی بر LSTM برای شناسایی بهتر ویژگی‌های وابسته به زمان ECG متمرکز خواهند بود.

تشکر و قدردانی

نویسندگان از تمام افرادی که با ارائه راهنمایی‌های فنی، بازخوردهای سازنده و حمایت در طول پژوهش به این مطالعه کمک کردند، صمیمانه قدردانی می‌کنند. تلاش‌های ایشان نقش بسزایی در بهبود کیفیت و کامل بودن این تحقیق داشت.

تضاد منافع

نویسندگان اعلام می‌دارند که هیچ‌گونه تضاد منافع وجود ندارد.

منابع

[1] Chen, L., Yu, H., Huang, Y., Jin, H. (2021). ECG Signal-Enabled Automatic Diagnosis Technology of Heart Failure. Journal of Healthcare Engineering, 2021(1), 5802722.

[2] Deepa, S.R., Subramoniam, M., Swarnalatha, R., Poornapushpakala, S., & Barani, S. (2023). Meta-Heuristic Optimized Hybrid Wavelet Features for Arrhythmia Classification. Intelligent Automation & Soft Computing, 37(1).

[3] Dhara, S.K., Bhanja, N., Khampariya, P. (2024). An adaptive heart disease diagnosis via ECG signal analysis with deep feature extraction and enhanced radial basis function. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization, 11(7), 2245927.

[4] Goldberger, A.L., Amaral, L., Glass, L., Hausdorff, J.M., Ivanov, P., Mark, R.G., Stanley, H.E. (2000). Components of a new research resource for complex physiologic signals. PhysioBank, PhysioToolkit, and Physionet.

[5] Hannan, A., Cheema, S.M., Pires, I.M. (2024). Machine learning-based smart wearable system for cardiac arrest monitoring using hybrid computing. Biomedical Signal Processing and Control, 87, 105519.

[6] Hasan, N.I., Bhattacharjee, A. (2019). Deep learning approach to cardiovascular disease classification employing modified ECG signal from empirical mode decomposition. Biomedical signal processing and control, 52, 128-140.

[7] Mishra, J., Tiwari, M. (2024). IoT-enabled ECG-based heart disease prediction using three-layer deep learning and meta-heuristic approach. Signal, Image and Video Processing, 18(1), 361-367.

[8] Mondéjar-Guerra, V., Novo, J., Rouco, J., Penedo, M.G., Ortega, M. (2019). Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers. Biomedical Signal Processing and Control, 47, 41-48.

[9] Munagala, N., Krishna, L., Lakshmi R., Rani, A.D., Reddy, D.V. Rama, K. (2022). A smart IoT-enabled heart disease monitoring system using meta-heuristic-based Fuzzy-LSTM model. biocybernetics and biomedical engineering, 42(4), 1183-1204.

[10] Phutela, N., Relan, D., Gabrani, G., Kumaraguru, P., Samuel, M. (2022). Stress classification using brain signals based on LSTM network. Computational Intelligence and Neuroscience, 2022(1), 7607592.

[11] Sadat, T., Safran, M., Khan, I., Alfarhood, S., Khan, R., Ashraf, I. (2023). Efficient classification of ECG images using a