

Automatic PAC and PVC Arrhythmia Detection in Single-Lead ECG Signals Using Specialized ResNet-Based Models

Mehrshad Goljarian^{1†}, Vania Shayestehfar^{2†}, Mohammad Mahdi Moeini-Manesh³, Ali Fotowat-Ahmady^{4*}

¹ Department of Electrical Engineering, Sharif University of Technology, Tehran, Iran

² Department of Electrical Engineering, Sharif University of Technology, Tehran, Iran

³ Department of Electrical Engineering, Sharif University of Technology, Tehran, Iran

⁴ Department of Electrical Engineering, Sharif University of Technology, Tehran, Iran

Received: 11 May 2026, Revised: 20 July 2026, Accepted: 31 July 2026

Paper type: Research

Abstract

This study presents a deep learning system for the simultaneous detection of two cardiac arrhythmias: Premature Ventricular Contractions (PVCs) and Premature Atrial Contractions (PACs). Our approach employs specialized ResNet-inspired 1D-CNN architectures, in which separate expert models are trained for the detection of each specific arrhythmia type. This ensemble-based strategy allows each network to learn distinctive features associated with its target class. The proposed system was trained on the iCentia11k dataset and evaluated on data collected from multiple databases. The data preprocessing pipeline includes heartbeat segmentation, resampling to a uniform frequency of 250 Hz, and Z-score normalization. To address class imbalance, a class-weighted loss function is employed. Our proposed model for PVC detection achieves a recall of 95.53% and an F1-score of 90.37% on the test set. The corresponding expert model for PAC detection achieves a recall of 98.00% and an F1-score of 90.13%. The overall accuracy of the proposed framework is reported as 96.11%.

Keywords: Electrocardiogram, Deep Learning, Cardiac arrhythmia, Convolutional Neural Networks, ResNet, iCentia11k database, Holter.

[†] These authors contributed equally to this work.

^{*} Corresponding Author's email: afotowat@sharif.edu

تشخیص خودکار آریتمی‌های قلبی PAC و PVC در سیگنال ECG تک‌کاناله با استفاده از مدل‌های تخصصی مبتنی بر ResNet

مهرشاد گلجاریان^۱، وانیا شایسته‌فر^۲، محمدمهدی معینی منش^۳، علی فتوت احمدی^۴*

^۱ دانشکده مهندسی برق، دانشگاه صنعتی شریف، تهران، ایران

^۲ دانشکده مهندسی برق، دانشگاه صنعتی شریف، تهران، ایران

^۳ دانشکده مهندسی برق، دانشگاه صنعتی شریف، تهران، ایران

^۴ دانشکده مهندسی برق، دانشگاه صنعتی شریف، تهران، ایران

تاریخ دریافت: ۱۴۰۵/۰۲/۲۱ تاریخ بازبینی: ۱۴۰۵/۰۴/۲۹ تاریخ پذیرش: ۱۴۰۵/۰۵/۰۹

نوع مقاله: پژوهشی

چکیده

این پژوهش یک سیستم یادگیری عمیق برای تشخیص هم‌زمان دو آریتمی قلبی انقباض زودرس بطنی (PVC) و انقباض زودرس دهلیزی (PAC) ارائه می‌دهد. رویکرد ما از معماری‌های تخصصی 1D-CNN الهام گرفته از ResNet بهره می‌برد، به طوری که مدل‌های متخصص جداگانه‌ای برای تشخیص هر نوع آریتمی خاص آموزش می‌بینند. این روش Ensemble به هر شبکه اجازه می‌دهد تا ویژگی‌های متمایز مربوط به کلاس هدف خود را یاد بگیرد. سیستم پیشنهادی بر روی پایگاه داده iCentia11k آموزش داده شده و بر روی داده‌های جمع‌آوری شده در چندین پایگاه داده ارزیابی شده است. سیر پیش‌پردازش داده شامل تقسیم‌بندی ضربان قلب، نمونه‌برداری مجدد در فرکانس ۲۵۰ هرتز و نرمال‌سازی Z-Score می‌باشد. برای مقابله با عدم تعادل کلاس، یک تابع loss با وزن کلاسی اعمال می‌شود. مدل پیشنهادی ما برای تشخیص PVC به بازیابی (Recall) برابر با 95.53% و امتیاز F1 برابر با 90.37% در مجموعه آزمایشی دست می‌یابد. مدل متخصص متناظر برای PAC نیز به بازیابی برابر با 98.00% و امتیاز F1 برابر با 90.13% دست می‌یابد. صحت (Accuracy) این مدل برابر 96.11% گزارش می‌شود.

کلیدواژگان: الکتروکاردیوگرام، یادگیری عمیق، آریتمی قلبی، شبکه عصبی کانولوشنی، ResNet، پایگاه داده iCentia11k، هولتر.

* این دو نویسنده دارای مشارکت یکسان بوده و نویسنده اول مشترک محسوب می‌شوند.


* رایانامه نویسنده مسؤول: afotowat@sharif.edu

۱- مقدمه


الکتروکاردیوگرام (ECG) به‌عنوان یکی از مهم‌ترین ابزارهای تشخیصی در پزشکی، امکان بررسی فعالیت الکتریکی قلب و شناسایی ناهنجاری‌های قلب را فراهم می‌آورد. تشخیص به‌موقع آریتمی‌های قلبی مانند انقباض زودرس دهلیزی (PAC) و انقباض زودرس بطنی (PVC) از اهمیت بالینی ویژه‌ای برخوردار است، چرا که می‌تواند از بروز عوارض جدی‌تر جلوگیری کند [۱، ۲].

همان‌طور که در شکل‌های ۱ و ۲ نشان داده شده است، PAC و PVC دارای الگوهای متمایزی در سیگنال ECG هستند. به‌طور ساده، آریتمی PAC با موج P زودرس و تغییر شکل یافته مشخص می‌شود، در حالی که PVC با مجموعه QRS پهن و تغییر شکل یافته شناسایی می‌گردد [۲].

در سال‌های اخیر، روش‌های مبتنی بر یادگیری عمیق به دلیل توانایی بالا در استخراج خودکار ویژگی‌های پیچیده از داده‌های خام، تحول چشمگیری در حوزه تشخیص خودکار آریتمی‌ها ایجاد کرده‌اند. مطالعات متعددی از معماری‌های مختلف شبکه‌های عصبی شامل شبکه‌های عصبی کانولوشنی (CNN) [۳]، شبکه‌های بازگشتی (LSTM) [۴]، و ترکیب این دو [۵] برای این منظور استفاده کرده‌اند. همچنین معماری‌های پیشرفته‌تری مانند شبکه‌های باقیمانده (ResNet) [۶] و مدل‌های مبتنی بر ترانسفورمر مورد توجه قرار گرفته‌اند [۷].



شکل ۱. نمونه‌ای از آریتمی PAC در سیگنال ECG



شکل ۲. نمونه‌ای از آریتمی PVC در سیگنال ECG

باوجود پیشرفت‌های قابل‌توجه در این حوزه، تشخیص هم‌زمان چندین نوع آریتمی با دقت و قابلیت اطمینان بالا همچنان یک چالش محسوب می‌شود که مهم‌ترین عامل آن تنوع بسیار زیاد سیگنال‌های قلبی بین بیماران مختلف یا حتی یک بیمار با خودش است [۸].

رویکردهای موجود اغلب یا بر تشخیص یک آریتمی خاص متمرکزند یا از معماری‌های پیچیده‌ای استفاده می‌کنند که نیازمند منابع محاسباتی زیاد هستند. در پژوهش‌های قبلی [۱۰] PAC و PVC به صورت مجزا کشف و شمارش می‌شدند. مقاله حاضر با هدف غلبه بر این چالش‌ها، یک چارچوب ترکیبی کارآمد و دقیق برای تشخیص هم‌زمان دو آریتمی شایع PAC و PVC ارائه می‌دهد. نوآوری اصلی این کار در طراحی سیستم Ensemble مبتنی بر دو مدل تخصصی ResNet است که هر کدام به‌طور عمیق بر ویژگی‌های آریتمی‌های PAC و PVC تمرکز می‌کنند. این رویکرد امکان یادگیری ویژگی‌های متمایز هر آریتمی را فراهم آورده و از طریق یک قاعده تصمیم‌گیری هوشمند، نتایج دو مدل را ترکیب می‌کند. عملکرد روش جدید به وضوح بهتر از نتایج تحقیقات قبلی است [۱۰].

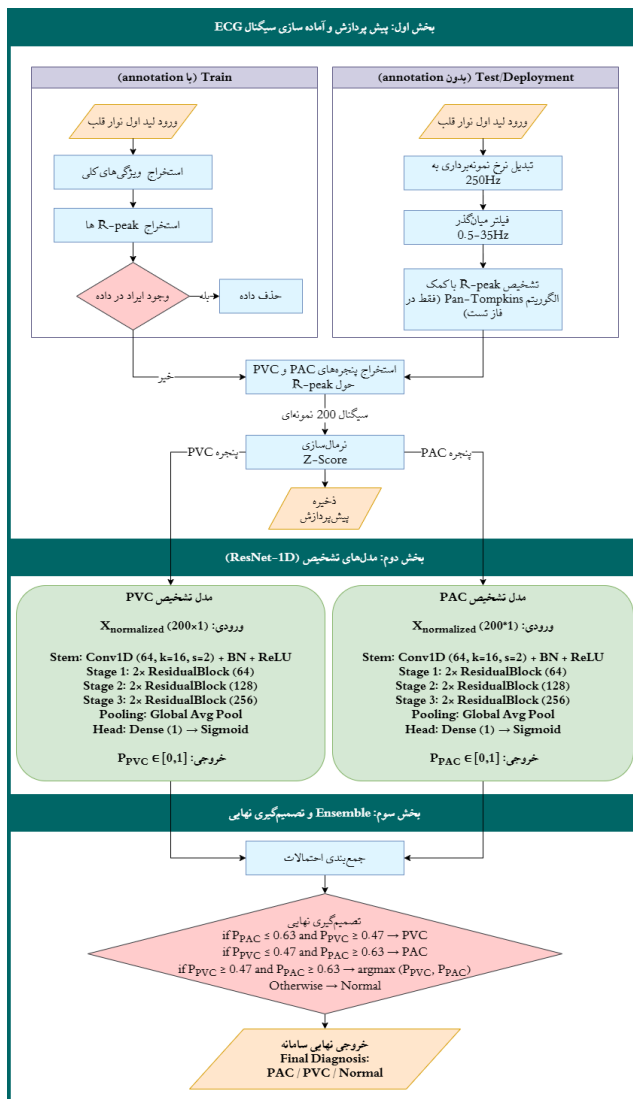
در بخش ۲، روش کار شامل پیش‌پردازش داده‌ها، طراحی معماری مدل‌ها و استراتژی آموزش به تفصیل شرح داده می‌شود. بخش ۳ به ارائه نتایج و تحلیل عملکرد سیستم بر روی پایگاه‌های داده مختلف اختصاص داشته و همچنین محدودیت‌ها و چالش‌های سیستم مورد بررسی قرار می‌گیرد. در نهایت در بخش ۴، نتیجه‌گیری و پیشنهاداتی برای کارهای آینده ارائه می‌شود.

۲- روش کار


در این پژوهش، یک چارچوب یادگیری عمیق ترکیبی برای تشخیص هم‌زمان PAC و PVC از ECG ارائه شده است. روش پیشنهادی مبتنی بر دو مدل تخصصی مجزا و یک معماری Ensemble است.

پایگاه‌داده اصلی مورد استفاده در این مطالعه، iCentia11k است که شامل ۵۰ سگمنت ۷۰ دقیقه‌ای ECG برای ۱۱ هزار نفر از بیماران مختلف با فرکانس نمونه‌برداری ۲۵۰ هرتز می‌باشد [۹]. این پایگاه داده حاوی حاشیه‌نویسی‌های دقیق برای ضربان‌های دارای آریتمی‌های قلبی PAC و PVC در برابر ضربان‌های نرمال است. برای مدیریت حجم بالای داده و تسریع فرایند توسعه مدل، از نمونه‌برداری تصادفی به اندازه ۴ درصد از کل دیتاست برای مجموعه‌های آموزشی (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمایشی (۱۵ درصد) استفاده شد.

توجه مهم آنکه تقسیم داده‌ها در سطح بیمار (Patient-level split)



شکل ۳. بلوک دیاگرام کامل سامانه پیشنهادی برای تشخیص آریتمی‌های PAC و PVC



شکل ۴. نمونه‌ای از فرایند استخراج ضربان‌ها از سیگنال ECG. پنجره‌های زمانی متفاوتی برای استخراج آریتمی‌های PAC و PVC در نظر گرفته می‌شود.

انجام شده است، به‌طوری که هیچ نمونه‌ای از یک بیمار به طور هم‌زمان در مجموعه‌های آموزش و آزمایش قرار نمی‌گیرد؛ بنابراین هیچ‌گونه نشت داده (Data-leakage) رخ نمی‌دهد.

اگرچه ۴ درصد از کل پایگاه داده iCentia11k تنها بخشی از داده اصلی را شامل می‌شود، اما همین مقدار نیز معادل ده‌ها هزار ضربان قلبی بوده و به دلیل تنوع بیماران و حضور نمونه‌های مربوط به کلاس‌های نرمال، PAC و PVC، برای آموزش و ارزیابی اولیه مدل پیشنهادی کفایت دارد. همچنین این انتخاب، امکان یادگیری مدل با سخت‌افزارهای ساده‌تر را نیز فراهم می‌سازد که می‌تواند نشان‌دهنده کارایی روش پیشنهادی در شرایط داده و منابع محاسباتی محدود باشد.

چارچوب پیشنهادی برای تشخیص هم‌زمان آریتمی‌های PAC و PVC شامل سه مرحله اصلی است: (۱) پیش‌پردازش داده‌ها و استخراج ضربان‌ها، (۲) طراحی و آموزش مدل‌های تخصصی یادگیری عمیق، و (۳) استنتاج با یک استراتژی ترکیبی برای تصمیم‌گیری نهایی. در ادامه هر یک از این مراحل به تفصیل شرح داده می‌شوند. در شکل ۳ نمای کلی از روش کار انجام شده قابل ملاحظه است.

۲-۱- پیش‌پردازش

مرحله پیش‌پردازش با هدف آماده‌سازی داده‌ها برای ورود به مدل‌های یادگیری عمیق انجام می‌شود. این مرحله شامل چندین گام اساسی است. ابتدا با استفاده از نقاط R ارائه شده در حاشیه‌نویسی‌های پایگاه داده، هر ضربان قلب به‌صورت یک قطعه سیگنال جداگانه استخراج می‌شود. شکل ۴ نمونه‌ای از این فرایند را نشان می‌دهد.

نکته کلیدی در این مرحله استفاده از پنجره‌های متفاوت برای هر یک از آریتمی‌های هدف است. برای تشخیص PVC، از پنجره‌ای متشکل از ۵۰ نمونه قبل و ۱۵۰ نمونه بعد از نقطه R (مجموعاً ۲۰۰ نمونه) استفاده می‌شود. این پنجره امکان بررسی کامل تغییرات مجموعه QRS و وقفه جبرانی پس از PVC را فراهم می‌آورد. در مقابل، برای تشخیص PAC، از پنجره‌ای با تمرکز بیشتر بر بخش قبل از مجموعه QRS استفاده می‌شود که شامل ۱۶۰ نمونه قبل و ۴۰ نمونه بعد از نقطه R (مجموعاً ۲۰۰ نمونه) می‌باشد. این پنجره امکان بررسی دقیق‌تر موج P زودرس و فاصله RR کوتاه‌شده مقدم را مهیا می‌سازد.

آریتمی به کلاس مثبت را تولید می‌کند.

۲-۳- آموزش و بهینه‌سازی مدل‌ها

هر یک از مدل‌های متخصص PVC و PAC به صورت مستقل آموزش داده می‌شوند. برای آموزش مدل‌ها از الگوریتم بهینه‌ساز Adam استفاده شده است [۱۳]. تابع هزینه انتخاب‌شده، آنتروپی متقاطع دودویی می‌باشد که برای مقابله با مشکل عدم تعادل کلاس‌ها، از وزن‌دهی کلاس استفاده شده است [۱۴].

برای مقابله با عدم تعادل کلاس‌ها، از تابع هزینه آنتروپی متقاطع دودویی با وزن‌دهی کلاس استفاده شد. ضریب وزن کلاس اقلیت به عنوان یک ابرپارامتر (hyperparameter) روی مجموعه اعتبارسنجی تنظیم گردید. به این منظور، مقادیر مختلف در بازه ۱ تا ۵ برای وزن‌دهی کلاس اقلیت بررسی شد و عملکرد مدل بر اساس تعادل میان Precision، Recall و F1-score برای کلاس آریتمی ارزیابی گردید. در نهایت، مقدار ۱٫۵ برای وزن کلاس اقلیت انتخاب شد.

برای جلوگیری از بیش‌برازش و بهبود عملکرد مدل، از چندین راهبرد استفاده شده است. لایه‌های Dropout با نرخ‌های مختلف در بخش‌های مختلف شبکه قرار داده شده‌اند. همچنین از توقف زودهنگام (Early Stopping) با نظارت بر loss مجموعه اعتبارسنجی و 8 patient استفاده شده است. علاوه بر این، از کاهش پلکانی نرخ یادگیری (ReduceLROnPlateau) نیز استفاده شده که در صورت عدم بهبود loss اعتبارسنجی برای ۵ دوره متوالی، نرخ یادگیری را به نصف کاهش می‌دهد. سایر پارامترهای آموزش شامل اندازه دسته ۶۴ و حداکثر ۵۰ دوره آموزش می‌باشند.

۲-۴- استنتاج و چارچوب ترکیبی

فرایند استنتاج شامل دو مرحله اصلی است: تشخیص خودکار نقاط R و ترکیب خروجی مدل‌های تخصصی.

برای تشخیص خودکار نقاط R، از یک الگوریتم ساده‌شده مبتنی بر Pan-Tompkins [۱۵] استفاده شده است. این الگوریتم شامل مراحل مشتق‌گیری، مربع کردن سیگنال، هموارسازی با پنجره متحرک و اعمال آستانه تطبیقی است. برای هر نقطه R تشخیص‌داده‌شده، دو قطعه سیگنال مطابق با پنجره‌های تعریف شده برای PAC و PVC استخراج می‌شوند. هر قطعه پس از نرمال‌سازی به مدل متخصص مربوطه ارسال شده و احتمال تعلق آن آریتمی به کلاس هدف محاسبه می‌شود.

برای اتخاذ تصمیم نهایی درباره نوع هر آریتمی، از یک قاعده ترکیبی مبتنی بر آستانه‌های بهینه استفاده شده است. آستانه‌های

پس از استخراج ضربان‌ها، مرحله نرمال‌سازی انجام می‌شود. هر ضربان با استفاده از نرمال‌سازی Z-Score استاندارد می‌شود که در آن میانگین سیگنال صفر و واریانس آن یک می‌گردد [۱۰]. این فرایند طبق رابطه (۱) انجام می‌پذیرد.

$$X_{\text{norm}} = \frac{x - \mu}{\sigma}, \quad (1)$$

که در آن x نمونه سیگنال، X_{norm} نمونه سیگنال نرمال‌شده، μ میانگین و σ انحراف معیار نمونه‌های موجود در ضربان هستند. در مرحله برچسب‌گذاری، دودسته طبقه‌بندی دودویی مجزا تعریف می‌شود. برای مدل متخصص PVC، تنها نماد حاشیه‌نویسی 'V' به عنوان کلاس مثبت (برچسب ۱) در نظر گرفته می‌شود و نمادهای 'N' (نرمال)، 'S' (PAC) و 'Q' (سایر) به عنوان کلاس منفی (برچسب صفر) برچسب‌گذاری می‌شوند. برای مدل متخصص PAC نیز تنها نماد 'S' به عنوان کلاس مثبت در نظر گرفته شده و سایر نمادها به عنوان کلاس منفی برچسب می‌خورند. این استراتژی به هر مدل اجازه می‌دهد تا به طور تخصصی بر تشخیص یک آریتمی خاص متمرکز شود.

۲-۲- معماری مدل‌های تخصصی

معماری انتخاب شده برای هر دو مدل متخصص، مبتنی بر شبکه عصبی باقی‌مانده یک‌بعدی (1D CNN) است. انتخاب این معماری به دلیل توانایی آن در آموزش شبکه‌های عمیق بدون مواجهه با مشکل گرادیان‌های محوشونده است. هسته اصلی این معماری، بلوک‌های باقی‌مانده هستند که از طریق اتصالات کوتاه، امکان عبور مستقیم اطلاعات و گرادیان را فراهم می‌آورند [۱۱].

ساختار هر مدل متخصص به صورت زیر است: لایه ورودی به ابعاد 1×200 که نمایانگر یک مجموعه QRS نرمال‌سازی شده است. سپس یک لایه اولیه با ۶۴ فیلتر و اندازه کرنل ۱۵ قرار دارد که برای استخراج ویژگی‌های درشت مقیاس طراحی شده است. پس از این لایه، سه مرحله از بلوک‌های باقی‌مانده قرار دارند. در مرحله اول، دو بلوک باقی‌مانده با ۶۴ فیلتر و کرنل ۵ قرار گرفته‌اند. در مرحله دوم، تعداد فیلترها به ۱۲۸ افزایش یافته و دو بلوک باقی‌مانده دیگر اضافه می‌شوند. در مرحله سوم نیز تعداد فیلترها به ۲۵۶ رسیده و دو بلوک باقی‌مانده نهایی قرار می‌گیرند. پس از آخرین مرحله باقی‌مانده، یک لایه Flatten برای تبدیل خروجی سه‌بعدی به بردار یک‌بعدی استفاده می‌شود. سپس یک لایه کاملاً متصل با ۱۰۰ نورون و تابع فعال‌سازی ReLU قرار دارد که به دنبال آن یک لایه Dropout [۱۲] با نرخ ۰٫۴ برای جلوگیری از بیش‌برازش اضافه شده است. در نهایت، لایه خروجی با یک نورون و تابع فعال‌سازی سیگموئید، احتمال تعلق

کاناله استخراج شده است. پایگاه داده MIT-BIH Arrhythmia با فرکانس ۳۶۰ هرتز یکی از استانداردترین پایگاه‌های داده در تحقیقات آریتمی محسوب می‌شود. پایگاه داده MIT-BIH Long Term نیز شامل سیگنال‌های بلندمدت با فرکانس ۱۲۸ هرتز می‌باشد که شرایط واقعی‌تری را شبیه‌سازی می‌کند. به‌منظور یکسان‌سازی، تمامی سیگنال‌ها به فرکانس مشترک ۲۵۰ هرتز نمونه‌برداری مجدد شده‌اند. علاوه بر این برای تمامی پایگاه‌های داده، فرایند نرمال‌سازی Z-Score مشابه با داده‌های آموزشی اعمال شده است. هیچگونه فیلتراسیون اضافی یا پردازش سیگنال دیگری بر روی داده‌های پایگاه‌های مختلف انجام نشده است. ارزیابی اصلی مدل پیشنهادی روی مجموعه آزمون مستقل پایگاه داده iCentia11k انجام شد؛ به‌گونه‌ای که داده‌های آزمون از نظر بیمار/سگمنت از مجموعه‌های آموزش و اعتبارسنجی جدا بودند. برای بررسی قابلیت تعمیم مدل، پایگاه‌های داده خارجی شامل St. MIT-BIH Arr.، Pt. MIT-BIH L.T. نیز مورد استفاده قرار گرفتند. در این بخش، شاخص‌های کمی عملکرد شامل Accuracy، Recall و F1-score بر اساس مجموعه‌های ارزیابی تعیین‌شده برای هر پایگاه داده محاسبه شدند (بخش ۳،۳).

۳-۲- تحلیل عملکرد سیستم

برای بررسی جزئی‌تر عملکرد سیستم پیشنهادی، دو نمونه از سگمنت‌های پایگاه‌های داده مختلف تحلیل شده‌اند. تحلیل‌های ارائه‌شده شامل ماتریس درهم‌ریختگی، منحنی ROC و نمایش گرافیکی آریتمی‌های تشخیص‌داده‌شده است.

۳-۲-۱- تحلیل سگمنت p08050 از پایگاه‌داده iCentia11k

این سگمنت، نمونه‌ای دارای PAC است. شکل‌های ۵ و ۶ به ترتیب منحنی ROC و ماتریس درهم‌ریختگی این سگمنت را نمایش می‌دهند.

همان‌طور که در شکل ۵ مشاهده می‌شود، منحنی ROC برای کلاس PAC به AUC کامل (۱،۰۰) دست یافته که نشان‌دهنده تشخیص بی‌نقص این آریتمی در این سگمنت است. عملکرد کل سیستم نیز با AUC برابر ۰،۹۶ در سطح مطلوبی قرار دارد. ماتریس درهم‌ریختگی (شکل ۶) عملکرد دقیق سیستم را تایید می‌کند. سیستم توانسته است ۴۴۹۱ ضربان نرمال را به درستی طبقه‌بندی کند و تنها ۷۶ مورد را به اشتباه به عنوان آریتمی تشخیص داده است. برای کلاس PAC، از ۳۹۳ آریتمی موجود، سیستم ۳۸۹ مورد را به درستی شناسایی کرده و تنها ۴ مورد را از دست داده است. در شکل ۷ نمونه‌ای از یک تشخیص PAC نمایش داده شده است.

تصمیم‌گیری به‌عنوان ابرپارامترهای مرحله استنتاج روی مجموعه اعتبارسنجی تنظیم شدند. برای این منظور، خروجی احتمالاتی مدل‌های متخصص PAC و PVC روی مجموعه اعتبارسنجی محاسبه شد و مقادیر مختلف آستانه در بازه ۰،۳ تا ۰،۷ بررسی گردید. معیار انتخاب آستانه، دستیابی به تعادل مناسب میان Precision، Recall و F1-score برای هر کلاس آریتمی و درعین حال کنترل موارد مثبت کاذب بود. براین اساس، آستانه ۰،۴۷ برای مدل متخصص PVC و آستانه ۰،۶۳ برای مدل متخصص PAC انتخاب شد. این آستانه‌ها سپس بدون تغییر برای ارزیابی نهایی روی مجموعه آزمون و سایر پایگاه‌های داده استفاده شدند.

قاعده تصمیم‌گیری به این صورت عمل می‌کند که اگر تنها یکی از مدل‌ها احتمال بالاتر از آستانه را گزارش کند، آریتمی به آن کلاس اختصاص می‌یابد. در موارد نادری که هر دو مدل احتمال بالاتر از آستانه خودشان را گزارش کنند، آریتمی به کلاسی اختصاص می‌یابد که مدل مربوطه اطمینان بیشتری (احتمال بالاتر) دارد. اگر هیچ یک از مدل‌ها احتمال بالاتر از آستانه را گزارش نکنند، آریتمی به‌عنوان نرمال طبقه‌بندی می‌شود.

۲-۵- پیاده‌سازی

تمامی مراحل پیش‌پردازش، آموزش مدل‌ها و استنتاج در زبان برنامه‌نویسی پایتون نسخه 3.8 پیاده‌سازی شده‌اند. برای بخش یادگیری عمیق از کتابخانه TensorFlow نسخه 2.8 و Keras استفاده شده است. عملیات خواندن و پردازش سیگنال‌های ECG با استفاده از کتابخانه‌های تخصصی WFDB و SciPy انجام گرفته است. فرایندهای آموزشی و ارزیابی بر روی یک کارت گرافیک NVIDIA با پشتیبانی از CUDA اجرا شده‌اند.

۳- نتایج و بحث

۳-۱- پایگاه‌های داده

برای ارزیابی جامع سیستم پیشنهادی، عملکرد آن بر روی چهار پایگاه‌داده معتبر ECG مورد آزمایش قرار گرفته است. این پایگاه‌های داده عبارت‌اند از:


- iCentia11k (برای آموزش مدل‌ها استفاده شده) [۹]
- St Petersburg Incart 12-lead Arrhythmia [۱۶]
- MIT-BIH Arrhythmia [۱۷]
- MIT-BIH Long Term ECG [۱۸]

پایگاه‌داده St Petersburg شامل سیگنال‌های ۱۲ کاناله با فرکانس ۲۵۷ هرتز است که تنها کانال اول آن برای سازگاری با مدل تک


۳-۲-۲- تحلیل سگمنت 144 از پایگاه داده St Petersburg

این سگمنت، نمونه‌ای با عملکرد عالی سیستم در تشخیص PVC را نشان می‌دهد. شکل‌های ۸ و ۹ به ترتیب منحنی ROC و ماتریس درهم‌ریختگی این سگمنت را نمایش می‌دهند.


همان‌طور که در شکل ۸ مشاهده می‌شود، منحنی ROC برای کلاس PVC به AUC برابر ۰٫۹۸ دست یافته که نشان‌دهنده قدرت تشخیص بسیار بالای مدل برای این آریتمی است. عملکرد کلی سیستم نیز به AUC برابر ۰٫۹۸ در سطح عالی قرار دارد. ماتریس درهم‌ریختگی (شکل ۹) عملکرد دقیق سیستم را تایید می‌کند. سیستم توانسته است ۲۰۱۸ ضربان نرمال را به درستی طبقه‌بندی کند و تنها ۴۴ مورد را به اشتباه به عنوان آریتمی تشخیص داده است. برای کلاس PVC، از ۷۱۵ آریتمی موجود، سیستم ۶۴۳ مورد را به درستی شناسایی کرده و ۷۲ مورد را از دست داده است. در شکل ۱۰ نمونه‌ای از یک تشخیص PVC نمایش داده شده است.




شکل ۸. منحنی ROC از پایگاه داده St Petersburg. عملکرد عالی در تشخیص PVC (با $AUC = 0.98$) مشاهده می‌شود.




شکل ۹. ماتریس درهم‌ریختگی با امتیاز F1 برابر 0.9586



شکل ۵. منحنی ROC از پایگاه داده iCentia11k. عملکرد عالی در تشخیص PAC (با $AUC = 1.00$) مشاهده می‌شود.



شکل ۶. ماتریس درهم‌ریختگی با امتیاز F1 برابر 0.9847



شکل ۷. نمونه‌ای آریتمی PAC تشخیص داده شده در زمان ۷٫۳۱ ثانیه. سیستم با احتمال ۰٫۹۷ این آریتمی را به عنوان PAC شناسایی کرده، در حالی که احتمال PVC تنها ۰٫۱۲ بوده است. تطابق کامل بین پیش‌بینی سیستم (PRED: S) و برچسب واقعی (TRUE: S) عملکرد دقیق مدل را نشان می‌دهد.

جدول ۱. عملکرد سیستم در پایگاه‌های داده مختلف

Metric	iCentia11k [9]	St. Pt. [16]	MIT-BIH Arr. [17]	MIT-BIH L. T. [18]
Accuracy	98.09%	96.77%	97.43%	92.18%
Avg Recall	98.95%	95.12%	96.09%	94.83%
Recall (PAC)	98.98%	-	93.37%	97.02%
Recall (PVC)	99.79%	92.38%	97.51%	92.42%
F1 (PAC)	90.56%	-	90.24%	89.71%
F1 (PVC)	89.53%	92.13%	94.95%	84.90%

جدول ۲. مقایسه عملکرد سیستم پیشنهادی با کارهای مرتبط

Method	Dataset	Accuracy	F1 (PVC)	F1 (PAC)
Proposed Method	iCentia11k	98.09%	89.53%	90.56%
Encoder [19]	iCentia11k	99.78%	95.65%	89.35%
uPVC-Net [20]	iCentia11k	97.83%	65.73%	66.98%
Variational Autoencoder [21]	iCentia11k	83%	96.72%	82.31%
Hybrid CNN-LSTM [22]	MIT-BIH	83.44%	-	-
Hierarchical Clustering [10]	Raw Data	95.33%	96.68%	93.66%


سوم آنکه، آستانه‌های تصمیم‌گیری به‌صورت تجربی و ثابت تنظیم شده‌اند. توسعه مکانیزمی برای تنظیم تطبیقی این آستانه‌ها بر اساس ویژگی‌های سیگنال ورودی می‌تواند استحکام سیستم را افزایش دهد.

مورد چهارم این است که تعیین آستانه‌های تصمیم‌گیری در مرحله نهایی، به‌صورت دستی تعیین شده است که می‌تواند عملکرد سیستم را تحت شرایط مختلف در پایگاه‌های داده مختلف تحت تأثیر قرار دهد.

در نهایت، یکی دیگر از محدودیت‌های این مطالعه، عدم انجام Ablation Study کامل برای بررسی سهم جداگانه اجزای مختلف چارچوب پیشنهادی است. اگرچه طراحی پنجره‌های اختصاصی و مدل‌های تخصصی بر اساس تفاوت‌های فیزیولوژیک PAC و PVC انجام شده، اما مقایسه کمی میان حالت‌هایی مانند یک ResNet مشترک، دو ResNet تخصصی بدون پنجره اختصاصی و چارچوب کامل Ensemble می‌تواند نقش هر جزء را دقیق‌تر مشخص کند.

۴- نتیجه‌گیری

در این مقاله، یک چارچوب ترکیبی مبتنی بر یادگیری عمیق برای تشخیص هم‌زمان دو آریتمی شایع قلبی PAC و PVC ارائه شد. رویکرد اصلی مبتنی بر آموزش دو مدل تخصصی با معماری ResNet یک‌بعدی بود که هر یک برای استخراج ویژگی‌های بهینه یک آریتمی خاص طراحی شده‌اند. خروجی این مدل‌ها در مرحله استنتاج توسط یک قاعده تصمیم‌گیری مبتنی بر آستانه‌های بهینه،



شکل ۱۰. نمونه‌ای آریتمی PVC تشخیص داده‌شده در زمان ۶،۳۸ ثانیه. سیستم با احتمال کامل (۱۰۰) این آریتمی را به عنوان PVC شناسایی کرده، در حالی که احتمال PAC تنها ۰،۲۸ بوده است. تطابق کامل بین پیش‌بینی سیستم (PRED: V) و برچسب واقعی (TRUE: V) عملکرد دقیق مدل را نشان می‌دهد.

۳-۳- نتایج کمی و تحلیل

نتایج ارزیابی سیستم پیشنهادی که در جدول ۱ ارائه شده است، نشان‌دهنده عملکرد پایدار و قابل اطمینان آن در پایگاه‌های داده متنوع است. این سیستم با دستیابی به صحت‌هایی در محدوده ۰،۹۲۱۸ تا ۰،۹۸۰۹، قابلیت تعمیم‌پذیری مطلوبی را نشان می‌دهد. مقایسه با کارهای مرتبط در جدول ۲ نیز حاکی از عملکرد رقابتی است؛ به عنوان مثال، سیستم پیشنهادی در مقایسه با uPVC-Net [۲۰] برتری قابل توجهی در امتیاز F1 هر دو نوع آریتمی PAC و PVC دارد و در مقایسه با Variational Autoencoder [۲۱] نیز از صحت بسیار بالاتری (۰،۹۸۰۸ در مقابل ۰،۸۳) برخوردار است. اگرچه عملکرد سیستم در مواجهه با سیگنال‌های بلندمدت و پرنویز MIT-BIH کاهش یافته (صحت ۰،۹۲۱۸)، این نتیجه اهمیت کیفیت سیگنال ورودی را در کاربردهای واقعی تأکید می‌کند.

۴-۳- محدودیت‌ها و چالش‌ها

علی‌رغم عملکرد مطلوب سیستم، چندین محدودیت و چالش قابل ذکر است. در وهله اول، سیستم فعلی تنها بر تشخیص دو آریتمی شایع PAC و PVC متمرکز است که از روی تک کانال استخراج می‌شود. برای تبدیل شدن به یک سیستم تشخیص جامع آریتمی، نیاز به گسترش و اضافه کردن مدل‌های متخصص برای سایر آریتمی‌ها (مانند فیبریلاسیون دهلیزی) با استفاده از سیگنال‌های ۱۲ کاناله وجود دارد. دوم آنکه، عملکرد سیستم به‌دقت مرحله تشخیص خودکار نقاط R وابسته است. خطا در این مرحله، به‌ویژه در سیگنال‌های با نویز شدید، می‌تواند به‌صورت زنجیره‌ای بر دقت طبقه‌بندی تأثیر بگذارد. به عبارت دیگر، اگر نقطه R به‌درستی شناسایی نشود، استخراج مجموعه QRS با خطا مواجه شده و در نتیجه طبقه‌بندی نادرست خواهد بود [۲۳].

- [8] S. Osowski and T. H. Linh, "Ecg beat recognition using fuzzy hybrid neural network," *IEEE Transactions on Biomedical Engineering*, vol. 48, no. 11, pp. 1265–1271, 2001.
- [9] S. Tan, S. Ortiz-Gagné, N. Beaudoin-Gagnon, P. Fecteau, A. Courville, Y. Bengio, and J. P. Cohen, "Icentia11k Single Lead Continuous Raw Electrocardiogram Dataset," *PhysioNet*, Apr. 2022, version 1.0. [Online]. Available: <https://doi.org/10.13026/kk0v-r952>
- [10] F. Khodami, "Investigating the effect of motion artifacts on the impedance between chest electrodes and skin," M.S. thesis, Sharif University of Technology, Tehran, Iran, 2021.
- [11] A. Zhang, X. Yang, T. Li, M. Dou, and H. Yang, "Classification method of ecg signals based on ranet," *Cardiovascular Engineering and Technology*, vol. 15, no. 5, pp. 561–571, Oct 2024. [Online]. Available: <https://doi.org/10.1007/s13239-024-00730-5>
- [12] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929–1958, 2014. [Online]. Available: <http://jmlr.org/papers/v15/srivastava14a.html>
- [13] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," 2017. [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [14] J. Johnson and T. Khoshgoftaar, "Survey on deep learning with class imbalance," *Journal of Big Data*, vol. 6, p. 27, 03 2019.
- [15] J. Pan and W. J. Tompkins, "A real-time qrs detection algorithm," *IEEE Transactions on Biomedical Engineering*, vol. BME-32, no. 3, pp. 230–236, 1985.
- [16] V. Tihonenko, A. Khaustov, S. Ivanov, and A. Rivin, "St.-petersburg institute of cardiological technics 12-lead arrhythmia database," 2007. [Online]. Available: <https://physionet.org/content/incartdb/>
- [17] G. Moody and R. Mark, "The impact of the mit-bih arrhythmia database," *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, pp. 45–50, 2001.
- [18] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, "The mit-bih long term database," 1992. [Online]. Available: <https://physionet.org/content/ltadb/>
- [19] M. Kapsecker, M. C. Möller, and S. M. Jonas, "Disentangled representational learning for anomaly detection in single-lead electrocardiogram signals using variational autoencoder," *Computers in Biology and Medicine*, vol. 184, p. 109422, Jan. 2025. [Online]. Available: <http://dx.doi.org/10.1016/j.combiomed.2024.109422>
- [20] H. Hamami, Y. Solewicz, D. Zur, Y. Kleerekoper, and J. A. Behar, "upvc-net: A universal premature ventricular contraction detection deep learning algorithm," *IEEE Transactions on Biomedical Engineering*, p. 1–10, 2026. [Online]. Available: <http://dx.doi.org/10.1109/TBME.2026.3655531>
- [21] M. Kapsecker and S. M. Jonas, "Cross-device federated unsupervised learning for the detection of anomalies in single-lead electrocardiogram signals," *PLOS Digital Health*, vol. 4, no. 4, p. e0000793, Apr. 2025. [Online]. Available: <http://dx.doi.org/10.1371/journal.pdig.0000793>
- [22] K. A. Purtova, V. A. Moskalenko, L. A. Smirnov, G. V. Osipov, and N. Y. Zolotykh, "Problem analysis of the experiment formulation correctness in the task of ecg diagnostics using machine learning methods," *SSRN preprint*, no. 4947212, 2024.
- [23] K. Tateno and L. Glass, "A method for detection of atrial fibrillation using rr intervals," in *Computers in Cardiology 2000*. Vol.27 (Cat. 00CH37163), 2000, pp. 391–394

ترکیب و نتیجه نهایی تولید می‌شود. سیستم قابلیت کار کاملاً خودکار، از تشخیص نقاط R گرفته تا طبقه‌بندی نهایی را داراست. ارزیابی جامع بر روی چهار پایگاه داده معتبر نشان داد که سیستم پیشنهادی به عملکردی پایدار و قابل اطمینان دست یافته است. صحت در پایگاه داده iCentia11k برابر ۰٫۹۸۰۹، بازیابی برای PVC برابر ۰٫۹۹۷۹ و برای PAC برابر ۰٫۹۸۹۸ به دست آمد. نوآوری‌های اصلی این کار عبارت‌اند از طراحی مدل‌های متخصص ResNet برای هر آریتمی و ارائه قاعده تصمیم‌گیری Ensemble با آستانه‌های بهینه که نتیجه آن روی چهار پایگاه داده متنوع ارزیابی شد. سیستم پیشنهادی پتانسیل کاربردی در حوزه‌های مختلف از جمله سیستم‌های نظارتی قلبی در منزل، دستگاه‌های پوشیدنی سلامت و سیستم‌های غربالگری اولیه را دارد. برای تکمیل و گسترش این پژوهش، کارهای آینده زیر پیشنهاد می‌شود: گسترش دامنه تشخیص به سایر آریتمی‌های مهم مانند فیبریلاسیون دهلیزی، بهبود تشخیص PAC از طریق بررسی معماری‌های جایگزین یا افزودن مکانیزم‌های توجه، توسعه روشی پویا برای تنظیم خودکار آستانه‌های تصمیم‌گیری و در نهایت، ارزیابی سیستم در محیط‌های بالینی واقعی با داده‌های جمع‌آوری شده از بیماران.

مراجع

- [1] M. A. Scrugli, D. Loi, L. Raffo, and P. Meloni, "A runtime-adaptive cognitive iot node for healthcare monitoring," in *Proceedings of the 16th ACM International Conference on Computing Frontiers*, ser. CF '19. New York, NY, USA: Association for Computing Machinery, 2019, p. 350–357. [Online]. Available: <https://doi.org/10.1145/3310273.3323160>
- [2] M. S. Thaler, *The only EKG book you'll ever need*. Wolters Kluwer Health/Lippincott Williams et Wilkins, 2012.
- [3] U. B. Baloglu, M. Talo, O. Yildirim, R. S. Tan, and U. R. Acharya, "Classification of myocardial infarction with multi-lead ecg signals and deep cnn," *Pattern Recognition Letters*, vol. 122, pp. 23–30, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S016786551930056X>
- [4] Özal Yildirim, "A novel wavelet sequence based on deep bidirectional lstm network model for ecg signal classification," *Computers in Biology and Medicine*, vol. 96, pp. 189–202, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0010482518300738>
- [5] S. Mehta and A. Aneja, "Enhanced ecg signal analysis using hybrid cnn-lstm and augmentation techniques," in *2025 International Conference on Automation and Computation (AUTOCOM)*, 2025, pp. 1657–1661.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [7] A. Natarajan, Y. Chang, S. Mariani, A. Rahman, G. Boverman, S. Vij, and J. Rubin, "A wide and deep transformer neural network for 12-lead ecg classification," in *2020 Computing in Cardiology*, 2020, pp. 1–4.