

Improving the Diagnosis of Arrhythmia using a Combination of Neural Networks in a Hierarchical Way

Abidi Atena¹, Heydaran Daroogheh Amnyieh Zahra², Jamahmoodi Hanieh³, Salarniya Setare⁴, Zabbah Iman^{5*}

• Received: 19 May 2023

• Accepted: 10 Dec 2023

Introduction: Heart diseases are one of the most common types of diseases, which cause the death of many people. Arrhythmias are an irregular heartbeat that causes the heart to beat abnormally fast (tachycardia) or slow (bradycardia). Therefore, the identification and classification of cardiac arrhythmias using ECG signals is of great importance. This research aimed to provide a data mining-based model to improve the diagnosis of previous arrhythmia.

Method: In this descriptive-analytical study, the UCI reference dataset, which consists of 452 samples with 279 features, was used. The samples were categorized into five classes for the detection and identification of different types of cardiac arrhythmias. The algorithm employed in this research is a combination of hierarchical neural networks (expert system combination).

Results: In all networks, 70% of the samples were used for training, while the remaining 30% were used for testing. After modeling and comparing the generated models and recording the results, the prediction accuracy for cardiac arrhythmia in the absence of combination learning reached 89.5%, and it increased to 93.5% after employing the hierarchical expert combination approach.

Conclusion: The results of this research show that the proposed method based on the combination of neural networks in a hierarchical form, which leads to the specialization of the task of each class, can have better performance compared to similar models in diagnosing cardiac arrhythmia.

Keywords: Data Mining, Neural Networks, Cardiac Arrhythmia Diagnosis, Mixture of Experts

• **Citation:** Abidi A, Heydariyan Daroogheh Amnyieh Z, Jamahmoodi H, Salarniya S, Zabbah I Improving the Diagnosis of Arrhythmia using a Combination of Neural Networks in a Hierarchical Way. *Journal of Health and Biomedical Informatics* 2023; 10(3): 223-37. [In Persian] doi: 10.34172/jhbmi.2023.28

1. Department of Computer Engineering, Bushehr Branch, Islamic Azad University, Bushehr, Iran
2. Department of Electrical Engineering, Dolatabad Branch, Islamic Azad University, Isfahan, Iran
3. Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran
4. Department of Computer Engineering, Torbat Heydariyeh University, Torbat Heydariyeh, Iran
5. Department of Computer, Torbat Heydariyeh Branch, Islamic Azad University, Torbat Heydariyeh, Iran

*Corresponding Author: Iman Zabbah

Address: Islamic Azad University, Torbat Heydariyeh

• Tel: 09159311050 • Email: im.zabbah@iau.ac.ir

ترکیب سلسله مراتبی شبکه‌های عصبی مصنوعی به منظور بهبود تشخیص بیماری آریتمی قلبی

آتنا عبیدی^۱، زهرا حیدران داروقه امنیه^۲، هانیه جامحمودی^۳، ستاره سالارنیا^۴، ایمان ذباح^{۵*}

• پذیرش مقاله: ۱۴۰۲/۹/۱۹

• دریافت مقاله: ۱۴۰۲/۲/۲۹

مقدمه: بیماری‌های قلبی یکی از شایع‌ترین انواع بیماری‌ها هستند، که باعث مرگ و میر بسیاری از افراد می‌شوند. آریتمی‌ها، نوع نامنظمی در ضربان قلب هستند که موجب می‌شوند قلب به طور غیرطبیعی سریع (تاکی‌کاردی) یا آهسته (برادی‌کاردی) کار کند؛ لذا شناسایی و کلاس‌بندی آریتمی‌های قلبی با استفاده از سیگنال ECG از اهمیت بالایی برخوردار است. هدف از این پژوهش ارائه یک مدل مبتنی بر داده‌کاوی با هدف بهبود تشخیص آریتمی قلبی است.

روش: این مطالعه به شیوه توصیفی-تحلیلی و از پایگاه داده UCI استفاده شده است. این پایگاه داده شامل ۴۵۲ نمونه و ۲۷۹ ویژگی است. نمونه‌ها برای تشخیص و شناسایی نوع آریتمی قلبی در ۵ دسته کلی طبقه‌بندی شده‌اند. الگوریتم استفاده شده در این پژوهش ترکیبی از شبکه‌های عصبی به صورت سلسله‌مراتبی (ترکیب سیستم‌های خبره) است.

نتایج: در تمامی شبکه‌ها، ۷۰٪ از نمونه‌ها برای آموزش و ۳۰٪ آن‌ها به منظور آزمون استفاده شده است. پس از مدل‌سازی و مقایسه مدل‌های تولید شده و ثبت نتایج، دقت پیش‌بینی بیماری آریتمی قلبی در زمان عدم ترکیب یادگیری ۸۹/۵٪ و پس از ترکیب خبره‌ها به روش سلسله‌مراتبی ۹۳/۵٪ به دست آمد.

نتیجه‌گیری: نتایج حاصل از این پژوهش نشان می‌دهد که روش پیشنهادی مبتنی بر ترکیب شبکه‌های عصبی به شکل سلسله‌مراتبی، که منجر به تخصصی شدن هر طبقه بند می‌شود، می‌تواند عملکرد بهتری نسبت به مدل‌های مشابه در تشخیص آریتمی قلبی داشته باشد.

کلیدواژه‌ها: داده‌کاوی، شبکه‌های عصبی، تشخیص آریتمی قلبی، ترکیب خبره‌ها

• **ارجاع:** عبیدی آتنا، حیدریان داروقه امنیه زهرا، جامحمودی هانیه، سالارنیا ستاره، ذباح ایمان. ترکیب سلسله‌مراتبی شبکه‌های عصبی مصنوعی به منظور بهبود تشخیص بیماری آریتمی قلبی. *مجله انفورماتیک سلامت و زیست پزشکی* ۱۴۰۲؛ ۱۰(۳): ۲۳۳-۲۳۷. doi: 10.34172/jhbmi.2023.28

۱. گروه کامپیوتر، واحد بوشهر، دانشگاه آزاد اسلامی، بوشهر، ایران

۲. گروه برق، واحد دولت آباد، دانشگاه آزاد اسلامی، اصفهان، ایران

۳. گروه کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

۴. دانش آموخته کارشناسی کامپیوتر، گروه برق و کامپیوتر، دانشگاه تربت حیدریه، تربت حیدریه، خراسان رضوی، ایران

۵. گروه کامپیوتر، واحد تربت حیدریه، دانشگاه آزاد اسلامی، تربت حیدریه، ایران

* نویسنده مسئول: ایمان ذباح

آدرس: تربت حیدریه، دانشگاه آزاد اسلامی

• Email: im.zabbah@iau.ac.ir

• شماره تماس: ۰۹۱۵۹۳۱۱۰۵۰

مقدمه

قلب، یکی از مهم‌ترین اعضای بدن است که وظیفه پمپاژ کردن خون را بر عهده دارد. چنانچه عملکرد قلب از نظم طبیعی (ریتم) خود خارج شود، گردش خون به خوبی انجام نمی‌شود و این امر می‌تواند خطرات جدی برای فرد به دنبال داشته باشد. به ضربان غیرعادی قلب آریتمی گفته می‌شود. به طور کلی دو نوع آریتمی قلبی وجود دارد، برادی کاردی (ضربان آهسته: کمتر از ۶۰ ضربان در دقیقه) و تاکی کاردی (ضربان تند: بیش از ۱۰۰ ضربان در دقیقه). وقتی که آریتمی شدید باشد، توانایی قلب در پمپاژ خون کاهش می‌یابد و منجر به تنگی نفس، درد قفسه سینه، احساس خستگی و از دست دادن هوشیاری می‌شود. آریتمی‌ها، بسیار شایع بوده و سالانه میلیون‌ها نفر در جهان را درگیر می‌کنند. در ایران علت ۷۰ درصد از مرگ‌های ناگهانی، مربوط به نارسایی‌های قلبی و عروقی است که در صدر آمار مرگ‌های سالیانه است [۱]. تقریباً ۳۵۰،۰۰۰ نفر در سال به دلیل آریتمی قلبی در حالت اضطراری و بدون اضطرار می‌میرند. این شامل مواردی از قبیل فیبریلاسیون دهلیزی، تاکی کاردی، و سایر نوع‌های آریتمی‌های قلبی است. درصد مرگ و میر بر اثر آریتمی قلبی بسیار وابسته به نوع آریتمی و وضعیت فرد مبتلا است. افرادی که به طور مداوم تحت نظارت پزشکان هستند و درمان مناسبی دریافت می‌کنند، ممکن است مرگ و میر آن‌ها کاهش یابد؛ اما در مواردی که آریتمی‌های قلبی تشخیص داده نمی‌شوند یا درمان به موقع انجام نمی‌شود، ممکن است مرگ و میر ناشی از آریتمی‌های قلبی افزایش یابد. یکی از راه‌های شناخته شده برای تشخیص به موقع آریتمی‌های قلبی بررسی فعالیت‌های الکتریکی قلب با استفاده از سیگنال‌های الکتروکاردیوگرام (ECG/Electro Cardio Gram) است. نوار قلب در عین سادگی، کاربردهای وسیعی در تشخیص بیماری‌های قلبی دارد که مهم‌ترین آن‌ها تشخیص ریتم ضربان قلب، علائم حمله قلبی، ضخیم شدگی عضلات دیواره قلب، پریکاردیت و همچنین آمبولی، اثرات داروها و... است [۲]. در زمینه تشخیص بیماری‌های قلبی به کمک روش‌های داده‌کاوی، مطالعات متعددی انجام شده است به عنوان نمونه می‌توان به پژوهش سعدی و همکاران اشاره کرد که با تکیه بر داده‌های بیمارستان شهید رجایی تهران و با استفاده از روش‌های داده‌کاوی به شناسایی فاکتورهای مؤثر در ابتلاء به بیماری کرونر قلب پرداختند [۳]. در مطالعه‌ای به بررسی استفاده از شبکه‌های عصبی کانولوشنال عمیق برای تشخیص فیبریلاسیون آریتمی قلبی پرداخته شده است. محققان در این مطالعه از سیگنال‌های

الکتروکاردیوگرام (ECG) استفاده کرده و با استفاده از شبکه‌های عصبی کانولوشنال عمیق، سعی می‌کنند فیبریلاسیون آریتمی را به طور خودکار تشخیص دهند [۴]. در مطالعه‌ای دیگر یک شبکه عصبی مدولار با تعداد لایه‌های پنهان مختلف از یک تا سه و با درصد آموزش مختلف ارائه گردید [۵]. استفاده از یادگیری‌های عمیق نیز در سال‌های اخیر مورد توجه محققین بوده است. در پژوهش Jun و همکاران [۶] که در سال ۲۰۱۸ انجام شد، محققان سیگنال‌های الکتروکاردیوگرام (ECG) را به صورت دقیق به برش‌های کوچک‌تری (ضربان به ضربان) تقسیم و سپس از شبکه‌های عصبی کانولوشنال برای تشخیص آریتمی‌ها استفاده می‌کنند. این شبکه‌ها به صورت خودکار و با استفاده از الگوریتم‌های یادگیری عمیق، نمونه‌های ECG را در دسته‌های مختلف آریتمی قلبی مانند تاکی کاردی، فیبریلاسیون آریتمی و غیره، طبقه‌بندی می‌کنند. استفاده از روش‌های حذف نویز با استفاده از فیلتر وقفی بر روی سیگنال‌های ECG نیز در مطالعه‌ای انجام شده است [۷]. در مطالعه‌ای از مدل‌سازی توجه و لایه‌های کانولوشنال عمیق استفاده شده است، تا توانایی تشخیص آریتمی‌های قلبی در سیگنال‌های ECG را بهبود بخشد. همچنین، ساختار سبک این سیستم، میزان پیچیدگی محاسباتی را کاهش می‌دهد و از منابع سخت‌افزاری کمتری استفاده می‌کند [۸]. با وجود مطالعات متعدد در خصوص تشخیص بیماری آریتمی قلبی، خلأهایی در مطالعات مشاهده می‌شود که برخی ناشی از ذات مسئله، و برخی ناشی از عدم تحلیل دقیق پایگاه داده می‌باشد. محدودیت‌های ذاتی مسئله از آنجا ناشی می‌شود که برخی از کلاس‌های آریتمی قلبی ذاتاً دارای تعداد نمونه کم هستند و راه‌کارهای مواجهه با تعداد نمونه‌های کم در یک کلاس رویکردی است که در مطالعات مبتنی بر داده‌های نامتوازن به آن پرداخته شده است. طراحی یک مدل یادگیر که توانایی طبقه‌بندی تمامی کلاس‌های آریتمی قلبی را داشته باشد بنا به دلیل ذکر شده و بدون توجه به روش‌های داده‌افزایی در کلاس‌های اقلیت عملاً غیر ممکن است، اما طراحی ترکیبی از یادگیرها که هر کدام وظیفه خاصی را بر عهده دارند راهکاری است که در این پژوهش مورد توجه قرار گرفته است و روشی برای افزایش تمرکز مدل‌های یادگیر بر روی کلاس‌های خاص است. از آنجایی که در پایگاه داده UCI تعداد ویژگی‌های نمونه‌های آریتمی‌های قلبی زیاد است (۲۷۹ ویژگی) محققین این حوزه دو راهکار را مورد بررسی قرار داده‌اند. در راهکار اول بسیاری از محققین با استفاده از روش‌های استخراج ویژگی اقدام به کاهش

باشد. تشخیص صحیح و سریع این بیماری می‌تواند در پیشگیری از عوارض جانبی و حتی جلوگیری از مرگ ناشی از آریتمی تأثیر چشم‌گیری داشته باشد. استفاده از الگوریتم‌های تشخیص آریتمی مبتنی بر یادگیری عمیق و شبکه‌های عصبی، می‌تواند به تشخیص زودرس و دقیق‌تر آریتمی‌های قلبی کمک کند. این امر می‌تواند در تشخیص زودرس و درمان مناسب آریتمی‌های خطرناک مانند فیبریلاسیون دهلیزی (AFib) و پیش‌فیبریلاسیون دهلیزی (pre-AFib) مؤثر باشد. همچنین تشخیص دقیق آریتمی‌های قلبی می‌تواند به پیش‌بینی خطر وقوع حمله قلبی کمک کند و از اشتباهات کاذب در تشخیص جلوگیری کند.

اگرچه در مطالعات متعدد پژوهشگران حوزه یادگیری ماشین در خصوص تشخیص بیماری آریتمی قلبی دستاوردهای چشمگیری به دست آمده است، لیکن مشاهده می‌شود که در اکثر مدل‌های یادگیر طراحی شده، صرفاً نوع خاصی از شبکه عصبی مصنوعی و یا شبکه عمیق مورد استفاده قرار گرفته است. این مسئله موجب می‌شود طبقه‌بند به سمت کلاس‌هایی با نمونه‌های بیشتر همگرا شود. ایده اصلی مطالعه حاضر که به عنوان ارزش افزوده‌ای به پژوهش‌های قبلی است، استفاده از ترکیبی از مدل‌های یادگیر است. همان‌طور که در تشخیص یک بیماری جمع نظرات چند پزشک می‌تواند راهکاری برای تصمیم‌گیری باشد، تخصصی کردن مدل یادگیر بر روی آریتمی‌های خاص و سپس تجمیع نظرات مدل‌های یادگیر، می‌تواند راهکاری برای طبقه‌بندی دقیق‌تر و به تبع آن بهبود تصمیم‌گیری باشد. مدل‌های یادگیر استفاده شده در این تحقیق شبکه عصبی پرسپترون چند لایه است. اگرچه استفاده از یادگیرهای عمیق در سال‌های اخیر مورد توجه محققان بوده است؛ اما این نوع از یادگیرها وابسته به تعداد زیاد نمونه هستند که شبکه‌های عصبی پرسپترون این محدودیت را کمتر دارند. به این ترتیب به جای افزودن لایه‌های مخفی در شبکه‌های پرسپترون اقدام به طراحی شبکه‌های عصبی مصنوعی مختلف شده است که هر کدام به منظور تشخیص یک نوع آریتمی خاص تعلیم می‌بینند. پایگاه داده مورد استفاده از مرجع UCI جمع‌آوری داده است. برای رسیدن به هدف مذکور، از روش ترکیب سلسله مراتبی شبکه‌های عصبی مصنوعی یا همان ترکیب خبره‌ها استفاده شده است. افزایش خبره‌ها منجر به تخصصی شدن وظیفه آن‌ها شده و ضمن تمرکز شبکه به توزیع خطا حول هدف کمک خواهد کرد و در نهایت موجب افزایش صحت عملکرد سیستم تصمیم‌گیر می‌شود.

ابعاد مسئله نمودند. به عنوان نمونه می‌توان به پژوهش Mitra و Samanta کرد که ابتدا با استفاده از انتخاب ویژگی مبتنی بر همبستگی (Correlation-based Feature Selection) ابعاد ویژگی نمونه‌ها را کاهش داده و سپس به منظور طبقه‌بندی از شبکه عصبی پس انتشار خطا و الگوریتم لوبنبرگ مارکوارت استفاده کرد [۹]. در مطالعه‌ای دیگر کاهش ویژگی‌ها با روش آنالیز مؤلفه اصلی (Principal Component Analysis) PCA انجام گردید و سپس از شبکه عصبی پرسپترون چند لایه برای طبقه‌بندی آریتمی قلبی استفاده شد [۱۰]. در مطالعه‌ای دیگر که بر روی تشخیص آریتمی‌های قلبی انجام گردید از PCA برای استخراج ویژگی و از (Support Vector Machine) SVM به عنوان طبقه‌بند برای ۶ کلاس استفاده گردید [۱۱]. در راهکار دوم به جای کاهش ابعاد، تعداد کلاس‌های مسئله کاهش یافته است. مثلاً به جای تشخیص ۱۶ نوع آریتمی، فقط به تشخیص دسته محدودی از آریتمی‌ها پرداخته شده است. به عنوان نمونه در مطالعه‌ای از تبدیل موجک استفاده شده است تا امکان تشخیص فقط ۳ نوع از آریتمی‌های رایج میسر گردد [۱۲]. عدم وجود پایگاه داده‌های استاندارد بزرگ که به اندازه کافی نمونه‌های آریتمی را در خود داشته باشد جزء مشکلات محققین تشخیص آریتمی بوده است؛ لذا در مطالعاتی سعی بر ایجاد پایگاه داده‌های عظیمی در این حوزه شده است که می‌توان به مطالعه‌ای اشاره کرد که با یک مجموعه داده شامل ۲۹۱۶۳ بیمار منحصر به فرد و ۱۴ کلاس، یک شبکه عصبی کانولوشن ۳۴ لایه را آموزش دادند و به پیش‌بینی و دقت قابل ملاحظه‌ای رسیدند [۱۳]. برخی از پژوهش‌ها به بررسی روش‌های یادگیری ماشین برای تشخیص بیماری‌های قلبی از روی سیگنال‌های ECG، از جمله شبکه‌های عصبی، ماشین بردار پشتیبان و درخت تصمیم می‌پردازند و در پایان نشان می‌دهند که استفاده از روش‌های یادگیری ماشین برای تشخیص بیماری‌های قلبی از روی سیگنال‌های ECG، به دقت بالا و شناسایی زودرس بیماری‌های قلبی کمک می‌کند. وجود پایگاه داده‌های بزرگ می‌تواند امکان استفاده از روش‌های یادگیری عمیق، جهت تشخیص آریتمی را فراهم کند. مثلاً در پژوهشی استفاده از شبکه‌های عصبی عمیق در طبقه‌بندی سیگنال‌های ECG با استفاده از معماری یادگیری عمیق، از نرون‌های کانولوشن در لایه‌های اول به عنوان استخراج ویژگی استفاده کردند و سپس در پایان سیگنال‌های ECG را طبقه‌بندی کردند [۱۴]. بیماری آریتمی قلبی یک اختلال در نوع و یا ضربان قلب است که می‌تواند عوارض جدی برای سلامتی فرد داشته

جریان الکتریکی از دهلیزها، اولین موج را ایجاد می‌کند که در حالت طبیعی گرد، صاف و قرینه بوده و نشان دهنده دپولاریزاسیون دهلیزها است. فاصله PR: از ابتدای موج P تا شروع کمپلکس QRS به این نام خوانده می‌شود. این فاصله نشان‌دهنده زمان سپری شده برای رسیدن موج دپولاریزاسیون از دهلیزها به بطن‌ها است. قسمت عمده این فاصله به علت وقفه این پالس در گره دهلیزی بطنی شکل می‌گیرد. کمپلکس QRS: از مجموع سه موج تشکیل شده است و در مجموع نشان‌دهنده دپولاریزاسیون بطن‌ها است. اولین موج منفی بعد از P، موج Q نام دارد. اولین موج مثبت بعد از P را موج R، و اولین موج منفی بعد از R را S می‌نامند. چون هر سه موج ممکن است با هم دیده نشوند، مجموع این سه موج را با هم یک کمپلکس QRS می‌نامند. قطعه: ST از انتهای QRS تا ابتدای موج T را قطعه ST نامگذاری کرده‌اند. این قطعه، نشان‌دهنده مراحل ابتدایی ریولاریزاسیون بطن‌ها است. موج T: موج گرد و مثبت می‌باشد که بعد از ترکیب QRS ظاهر می‌شود. این موج، نشان‌دهنده مراحل انتهایی ریولاریزاسیون بطن‌ها است و در ارتفاع بین ۰/۵ تا حداکثر ۱۰ میلی‌متر می‌باشد. فاصله QT: از ابتدای کمپلکس QRS تا انتهای موج P می‌باشد و نشان‌دهنده زمان لازم برای مجموع فعالیت بطن‌ها در طی یک چرخه قلبی است. فاصله QT زمانی طبیعی است که اندازه آن کمتر از نصف فاصله R-R در سرعت‌های قلب باشد. موج U: موجی گرد و کوچک می‌باشد که بعد از T ظاهر می‌شود و این موج همیشه دیده نمی‌شود.

پایگاه داده مورد استفاده


مجموعه داده مورد استفاده در این تحقیق، از آرشیو دادگان یادگیری ماشین (UCI machine learning repository, <https://archive.ics.uci.edu/dataset/5/arrhythmia>) (a) UCI جمع آوری شده است [۱۶]. این مجموعه شامل ۴۵۲ نمونه سیگنال قلبی از افراد مختلف با جنسیت و سن متفاوت می‌باشد. تعداد ویژگی‌های استخراج شده از این سیگنال‌ها ۲۷۹ ویژگی که ۲۰۶ ویژگی آن پیوسته بوده و باقی گسسته است و در تعیین وجود یا عدم وجود بیماری آریتمی قلبی و طبقه‌بندی آن در یکی از ۱۶ گروه پیش فرض است. در این مجموعه داده کلاس "۱" اشاره به ECG نرمال، کلاس‌های "۲-۱۵" اشاره به کلاس‌های مختلف آریتمی و کلاس "۱۶" به بقیه داده‌های طبقه‌بندی نشده اشاره دارد. داده‌ها توسط نرم‌افزار Excel نسخه ۲۰۱۳ جمع‌بندی و با نرم‌افزار SPSS تحلیل و توسط MATLAB نسخه ۲۰۱۶ مورد برنامه‌نویسی قرار گرفته‌اند.

تحقیق حاضر به منظور بهبود دقت تشخیص بیماری آریتمی قلبی انجام شده است و از طریق استفاده از ترکیب شبکه‌های عصبی و روش سلسله مراتبی، توانایی تشخیص بیماری را بهبود بخشیده است. از دیدگاه علمی، این تحقیق می‌تواند از یک طرف به افزایش دقت و قابلیت پیش‌بینی آریتمی‌های قلبی و از طرف دیگر به توسعه دانش در زمینه هوش مصنوعی و پردازش سیگنال‌های پزشکی کمک کند و در نهایت می‌تواند منجر به بهبود در تشخیص آریتمی‌های قلبی و کاهش هزینه‌های درمانی و بهبود کیفیت خدمات بهداشتی و درمانی گردد.

روش

سیگنال‌های ECG

یکی از مهم‌ترین ابزارها در زمینه بررسی وضعیت قلب، دستگاه ECG می‌باشد. این دستگاه جریان‌های الکتریکی قلب را از طریق الکترودهایی که روی مناطق مختلف پوست قرار داده می‌شوند، دریافت و آن‌ها را به شکل یک نمودار تفسیر می‌نماید. این نمودار، الکتروکاردیوگرام (ECG) نامیده می‌شود [۱۵]. از ECG اغلب به منظور بررسی صحت عملکرد سیستم هدایت الکتریکی قلب استفاده می‌گردد. گره سینوسی (SA) قسمت کوچکی از بافت ماهیچه‌ای مربوط به دیواره دهلیز راست است که با تولید یک سیگنال ادغام شونده در فواصل معین، همانند یک دستگاه تنظیم کننده ضربان قلب رفتار می‌نماید. دیواره دهلیز نیز آن قسمت از دهلیز قلب است که خون سیاهرگی به آن می‌رود [۱۸]. شکل ۱ سیگنال نرمال ECG و اجزای تشکیل دهنده آن را نشان می‌دهد.



شکل ۱: سیگنال ECG و اجزای تشکیل‌دهنده آن [۱۶]

هر کدام از اجزای مشاهده شده بر روی شکل ۱، نشان دهنده بخشی از فعالیت الکتریکی سلول‌های قلب می‌باشد. موج P: عبور

شرایطی و همچنین به لحاظ یکسان کردن ارزش داده‌ها برای شبکه عصبی، نرمالیزه کردن داده‌ها قبل از اعمال به سیستم انجام شده است. عمل نرمال‌سازی داده‌ها مطابق رابطه ۱ انجام گرفته است:


$$xn = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

در رابطه ۱ مقدار x بیانگر نمونه مورد نظر و x_{min} کمترین مقدار داده و x_{max} بیانگر حداکثر مقدار داده می‌باشد. در تشخیص نوع آریتمی، تعداد ویژگی‌های زیادی وجود که حاوی حجم اطلاعاتی بالایی نیستند و امکان حذف بسیاری از آن‌ها وجود دارد.

مورد معیارهای ورود نمونه‌ها این نکته قابل ذکر است که مطالعه بر اساس وضعیت بالینی، سن، جنسیت و سایر ویژگی‌های مرتبط صورت گرفته است و معیارهای جمع‌آوری داده‌های پزشکی از بیماران تست‌های الکتروکاردیوگرافی (ECG)، بوده است. همچنین با توجه به این که داده‌های مسئله از نوع غیر قابل انتساب هستند، حفظ محرمانگی اطلاعات به طور کامل انجام شده است. توزیع نمونه‌ها در هر کلاس در شکل ۲ نشان داده شده است.

نرمال‌سازی داده

با توجه به آن که ورود داده‌ها به شکل خام باعث کاهش سرعت و دقت سیستم‌های یادگیر می‌شود، برای پیشگیری از چنین




شکل ۲: توزیع نمونه‌های هر آریتمی در پایگاه داده UCI

اول به گونه‌ای قرار گیرد که واریانس داده‌ها بیشترین مقدار شود. به همین ترتیب محورهای بعدی، عمود بر تمامی محورهای قبلی به گونه‌ای قرار می‌گیرند که داده‌ها در آن جهت دارای بیشترین پراکندگی باشند. با توجه به این که تعداد ویژگی‌های نمونه‌های پایگاه داده مورد استفاده ۲۷۹ ویژگی است و برخی از این ویژگی‌ها عملاً تأثیر زیادی در عملکرد و تعیین نوع آریتمی ندارد، لذا انتخاب ویژگی‌های مناسب به روش PCA می‌تواند ضمن کاهش هزینه سربار محاسبات منجر به بهبود عملکرد مدل یادگیر گردد. پس از اعمال روش PCA تعداد ۱۸ ویژگی از مجموع ۲۷۹ ویژگی انتخاب گردید که عبارت‌اند از:

انتخاب ویژگی توسط آنالیز مؤلفه اصلی (PCA)

روش PCA یکی از بهترین روش‌ها برای کاهش ابعاد داده به صورت خطی می‌باشد، چرا که با حذف ضرایب کم اهمیت به دست آمده از این تبدیل، اطلاعات از دست رفته نسبت به روش‌های دیگر کمتر است. در این روش محورهای مختصات جدیدی برای داده‌ها تعریف شده و داده‌ها براساس این محورهای مختصات جدید بیان می‌شوند. اولین محور باید در جهتی قرار گیرد که (واریانس داده‌ها حداکثر شود، یعنی در جهتی که پراکندگی داده‌ها بیشتر است). دومین محور باید عمود بر محور

Sex, QRS duration, DII 49, DII 76, DII91, DII103, DII112, DII163, DII167, DII169, DII173, DII 199, DII207, DII211, DII261, DII267, DII271, and DII277.



شکل ۳: معماری شبکه عصبی پرسپترون، مورد استفاده در این مطالعه ($m=5$ و $n=18$)

نتایج

نتایج پژوهش در دو بخش مجزا، شامل معرفی معیارهای ارزیابی و مقایسه نتایج مدل به کار رفته ارائه شده است. اگر چه یک شبکه عصبی به دلیل قابلیت پردازش موازی بسیار مقاوم است و با تنظیم درست تعداد لایه‌های مخفی و تعداد نرون‌های مناسب توانایی تقریب‌زنی هر نوع تابع غیر خطی را دارد؛ اما اگر قرار باشد دقت یک طبقه‌بند افزایش یابد، یک روش این است که تعداد کلاس‌های آن طبقه‌بند را کاهش و در مقابل تعداد یادگیرها را افزایش داد. مدل پیشنهادی از ترکیبی از دسته‌بندهای قوی برای دسته‌بندی استفاده می‌کند. این مکانیزم که اصطلاحاً ترکیب خبره‌ها نامیده می‌شود، فضای ورودی را به زیر فضاهایی تقسیم کرده و سپس هر زیر فضا را به یک دسته‌بند محول می‌کند. این زیر فضاها بر اساس بردار خروجی (Target) تقسیم‌بندی می‌شوند. به این معنی که آریتمی‌هایی که در کلاس سالم (Normal) هستند در یک زیر فضا قرار می‌گیرند و به‌عنوان نمونه‌هایی با طبقه ۱ و بقیه نمونه‌ها با طبقه ۲ مشخص می‌شوند. این امر باعث سهولت آموزش می‌شود، زیرا به‌جای آموزش الگوریتم یادگیر بر روی یک فضا با رفتار پیچیده، الگوریتم بر روی یک فضا با رفتاری ساده‌تر آموزش می‌بیند. مسلم است که این امر موجب افزایش کارایی (که همان افزایش دقت تشخیص است) خواهد شد. به منظور بهبود عملکرد مدل یادگیر در تشخیص آریتمی قلبی، تلاش شده است که تمرکز مدل افزایش پیدا کند. به عبارت دقیق‌تر چندین مدل یادگیر را

در واقع ویژگی sex مربوط به جنسیت است که در درجه بالایی از اهمیت قرار دارد. دومین ویژگی مهم QRS duration است و همان‌طور که قبلاً ذکر شد مدت زمانی است که از زمان شروع امواج Q تا انتهای امواج S در نمودار ECG طی می‌شود. این اندازه‌گیری نمایانگر زمانی است که امواج الکتریکی به طول بخش‌های Q، R، و S از امواج QRS از دستگاه اندازه‌گیری می‌شوند و حاوی اطلاعات مهمی در تشخیص آریتمی می‌باشند. سومین ویژگی مهم، DII49 مربوط به کانال DII یکی از کانال‌های الکتروکاردیوگرام است؛ که در آن اندازه‌گیری‌ها از دو سنسور الکتروود بر روی بدن انجام می‌شود. سایر ویژگی‌های مهم به دست آمده، مانند DII 76 (کانال ۷۶) (کانال دیگری از ECG)، DII91 و سایر کانال‌های مستخرج در درجه بعدی مهم‌ترین ویژگی‌ها در تشخیص نوع آریتمی قرار دارند.

طراحی مدل یادگیر با استفاده از شبکه عصبی

به طور کلی باید یک تعادل بین دقت (Accuracy) و قابلیت تعمیم (Generalizability) در سیستم یادگیر وجود داشته باشد. شبکه عصبی مصنوعی با وجود داده اعتبار سنجی (Validation) و انتخاب مناسب ویژگی‌ها و طراحی معماری، مدلی مناسب برای تشخیص نوع آریتمی قلبی می‌باشد. در این پژوهش یکی از معروف‌ترین شبکه‌های عصبی به نام شبکه عصبی پرسپترون چند لایه (Multy Layer Perceptron) MLP استفاده شده است [۱۷]. این شبکه شامل سه لایه ورودی، مخفی و خروجی است. سیگنال‌های ورودی به وسیله ضریب‌های بهنجارکننده به مقدار یک، نرمالیزه شده و بعد از محاسبات، خروجی به مقدار واقعی برگردانده می‌شود. همچنین مقادیر اولیه وزن‌ها به صورت اتفاقی در نظر گرفته شده‌اند. شکل ۳ معماری شبکه عصبی مورد استفاده در این پژوهش که شامل ۲ لایه مخفی است را نشان می‌دهد.

در این شبکه n : تعداد ویژگی‌های انتخاب شده توسط روش PCA (۱۸ ویژگی) و m : تعداد کلاس‌های اصلی آریتمی قلبی می‌باشد.

$$\text{(Specificity)} = \frac{TN}{TN + FP} = \frac{121}{121 + 62} = 66.1\%$$

به طوری که:

TP: کل افراد فاقد آریتمی که به درستی تشخیص داده شده‌اند. FP: کل افراد داری آریتمی که اشتباهاً فاقد آریتمی تشخیص داده شده‌اند. TN: کل افراد فاقد آریتمی که درست تشخیص داده شده‌اند. FN: کل افراد داری آریتمی که اشتباهاً داری آریتمی تشخیص شده‌اند. جدول ۱ وضعیت یادگیری شبکه N1 را نشان می‌دهد.

همان‌طور که در شکل ۱ مشاهده می‌شود ۵ نوع آریتمی: Ischemic Changes, Old Anterior, Old Inferior, Sinus bradycardia, right bundle branch bloc به ترتیب با تعداد ۵۰، ۲۵، ۱۵، ۱۵، ۴۴ بیشترین فراوانی‌ها، بعد از نمونه نرمال را دارند. در مرحله دوم این پژوهش یک سیستم یادگیر طراحی شده است که بتواند وضعیت تعلق نمونه‌هایی که در مرحله قبل به عنوان آریتمی تشخیص داده شده‌اند را به مجموعه ۵ نوع آریتمی، بررسی کند. نام این شبکه N2 است و به روش شبکه قبلی طراحی و مورد آموزش قرار گرفت. این شبکه هم به صورت دو کلاسه آموزش داده شده است و یک نمونه جدید اگر به یکی از این پنج کلاسه تعلق داشته باشد در کلاس ۱ و در غیر این صورت در کلاس ۲ قرار خواهد گرفت. شبکه عصبی N2 در مجموع از ۱۸۳ نمونه توانسته است ۱۵۱ مورد را به درستی و تعداد ۳۲ مورد را به صورت نادرست کلاس‌بندی کند. به روش مشابه پارامترهای ارزیابی برای شبکه دوم نیز محاسبه گردید، که در جدول ۲ نمایش داده شده است. شبکه عصبی سوم N3، نمونه‌ها را با توجه به پنج کلاس اصلی طبقه‌بندی می‌کند و هر نمونه را در کلاس خود جای می‌دهد. این شبکه نیز به طور مشابه طراحی و آموزش داده شده است. پارامترهای ارزیابی برای هر یک از آریتمی‌ها محاسبه و در جدول ۳ درج گردید. جهت ارزیابی نهایی مدل ارائه شده و مقایسه آن با زمانی که فقط از یک شبکه عصبی استفاده می‌شود، شبکه N_final طراحی شد. وظیفه شبکه عصبی N_final، کلاس‌بندی نمونه‌ها در ۷ کلاس می‌باشد. بدین ترتیب که نمونه‌های سالم در کلاس ۱، نمونه‌های ۵ کلاس اصلی آریتمی در کلاس‌های ۲، ۳، ۴، ۵ و ۶ و همچنین نمونه‌های سایر آریتمی در کلاس ۷ قرار گیرند. الگوریتم مورد استفاده در این پژوهش در شکل ۴ نشان داده شده است.

به گونه‌ای آموزش دهیم که بر روی تشخیص نوع خاصی از آریتمی خبره شوند. بدین منظور ۳ شبکه عصبی N1 و N2 و N3 طراحی شدند. وظیفه شبکه عصبی اول، (N1) تشخیص آریتمی‌های سالم از سایر آریتمی‌ها است. شبکه N1 با ۸۰٪ از آریتمی‌های سالم و بیمار آموزش داده شد و با ۲۰٪ درصد از داده‌ها مورد آزمون قرار گرفت. از مجموع ۲۳۷ نمونه که در کلاس ۱ یعنی کلاس نرمال قرار داشته‌اند و به هیچ یک از آریتمی‌ها تعلق نداشتند، شبکه عصبی N1 توانسته است ۲۰۷ مورد را به درستی کلاس‌بندی کند و فقط ۳۰ مورد اشتباهاً در کلاس دوم قرار گرفته‌اند. همچنین از مجموع ۱۸۳ مورد که بیمار بوده‌اند (انواع مختلف آریتمی) شبکه توانسته ۱۲۱ مورد را به درستی کلاس‌بندی کند و ۶۲ مورد اشتباهاً در کلاس نرمال قرار گرفته‌اند. به‌طور کلی در سیستم‌های دسته‌بندی، برای بررسی میزان موفقیت و کارایی پارامترهای متعددی وجود دارد که به ترتیب عبارت‌اند از: دقت (Accuracy) که از رابطه ۲ محاسبه می‌شود و برای شبکه عصبی اول محاسبه شده است:

(۲)

Accuracy

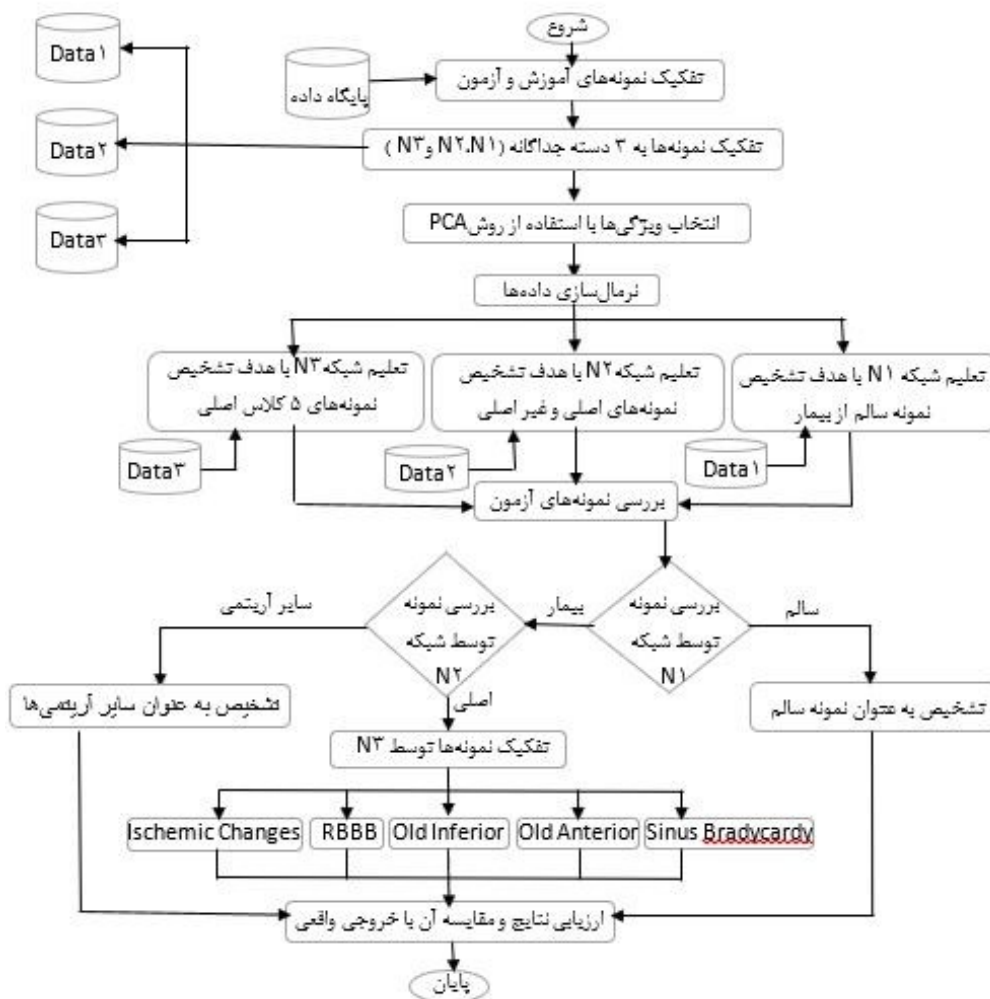
$$= \frac{\sum \text{True positive} + \text{True negative}}{\sum \text{Total population}} = \frac{207 + 121}{420} = 0.78$$

در رابطه ۲ صورت کسر شامل دو پارامتر True Positive (TP) و True Negative (TN) می‌باشد که به ترتیب عبارت‌اند از «کل افراد سالمی که سالم تشخیص داده شده‌اند» و «کل افراد مبتلا به آریتمی که بیمار تشخیص داده شده‌اند». و مخرج نیز کل افراد اعم از سالم و بیمار را تشکیل می‌دهد. علاوه بر محاسبه دقت شبکه دو شاخص حساسیت Sensitivity به معنی نسبت تعداد افراد بیمار به کل افراد و شاخص صحت Specificity به معنی نسبت تعداد افراد سالم به کل افراد نیز محاسبه شده است که از طریق روابط ۳ و ۴ به دست می‌آید و برای شبکه اول محاسبه شده است:

(۳)

$$\text{(Sensitivity)} = \frac{TP}{TP + FN} = \frac{207}{207 + 30} = 87.3$$

(۴)



شکل ۴: الگوریتم مورد استفاده در این پژوهش

جدول ۱: وضعیت یادگیری شبکه عصبی اول در تشخیص نمونه‌های سالم از سایر آریتمی‌ها

تعداد کل نمونه‌ها	تعداد نمونه‌ها پس از حذف نمونه‌های ناقص	تعداد نمونه‌های نرمال (فاقد آریتمی)	سایر آریتمی‌ها	دقت شبکه Accuracy N1	حساسیت Sensitivity N1	ویژگی Specificity N1
۴۵۰	۴۲۰	۲۲۷	۱۹۳	٪۷۸/۱	٪۸۷/۳	٪۶۶/۱

جدول ۲: وضعیت یادگیری شبکه عصبی دوم در تشخیص ۵ کلاس از سایر آریتمی‌ها

تعداد کل نمونه‌ها	تعداد نمونه‌ها پس از حذف نمونه‌های ناقص	تعداد نمونه‌های کلاس ۱ (یکی از ۵ آریتمی اصلی)	تعداد نمونه‌های سایر آریتمی‌ها کلاس ۲	دقت شبکه Accuracy N2	حساسیت Sensitivity N2	ویژگی Specificity N2
۱۸۳	-----	۱۳۵	۴۸	٪۸۲/۱	٪۹۲/۶	٪۵۴/۲

جدول ۳: وضعیت یادگیری شبکه عصبی سوم در تشخیص هر یک از ۵ آریتمی به تفکیک

تعداد نمونه‌ها (آزمایش)	نوع آریتمی	تعداد تشخیص داده شده توسط N3	حساسیت Sensitivity N3	ویژگی Specificity N3	دقت کل طبقه بندی Accuracy N3
۳۶	Ischemic Changes	۳۳	٪۹۱/۷	٪۸۶/۸	٪۹۳/۵
۱۳	Old Anterior	۱۳	٪۱۰۰	٪۱۰۰	
۱۴	Old Inferior	۱۳	٪۹۲/۹	٪۸۶/۷	
۲۴	Sinus bradycardy	۲۳	٪۷۵/۰	٪۸۵/۷	
۴۸	branch bloc right bundle	۴۶	٪۹۵/۵	٪۹۵/۸	

جدول ۴: وضعیت یادگیری شبکه عصبی چهارم بدون استفاده از ترکیب یادگیرها

تعداد نمونه‌ها (آزمایش)	نوع آریتمی	تعداد تشخیص داده شده توسط Nfinal	حساسیت Sensitivity Nfinal	ویژگی Specificity Nfinal	دقت کل طبقه بندی Accuracy Nfinal
۲۳۹	Normal	۲۲۷	٪۹۲/۷	٪۹۵/۸	٪۸۹/۵
۳۱	Ischemic Changes	۲۸	٪۹۰/۳	٪۷۷/۸	
۱۴	Old Anterior	۱۲	٪۸۵/۷	٪۹۲/۳	
۱۲	Old Inferior	۱۰	٪۸۳/۳	٪۷۱/۴	
۴۲	Right bundle branch bloc	۳۸	٪۹۰/۵	٪۷۹/۲	
۱۶	Sinus bradycardy	۰	٪۱۰۰	٪۶۶/۸	
۶۰	Other	۴۵	٪۷۵/۰	٪۹۳/۸	


دسته‌بند یکسان و ناپایدار (مانند درخت تصمیم یک سطحی و یا شبکه عصبی) با یکدیگر ترکیب می‌شوند. خروجی الگوریتم، رأی‌گیری اکثریت است. در این الگوریتم پایگاه داده به چند قسمت مجزا تبدیل می‌شود و هر قسمت به یکی از طبقه‌بندها واگذار می‌شود. روش دیگر الگوریتم **boosting** [۱۶] است، که مانند الگوریتم قبلی است با این تفاوت که دسته‌بندها به صورت سری قرار می‌گیرند. یعنی ورودی هر دسته‌بند تحت تأثیر خروجی دیگر دسته‌بندهای قبل از خودش است. به هر دو روش فوق، اصطلاحاً «خردجمعی» گفته می‌شود. در این پژوهش از الگوریتم **boosting** به منظور تشخیص نوع آریتمی قلب استفاده شده است. همان‌طور که الگوریتم شکل ۴ نشان می‌دهد، ابتدا پایگاه داده مفروض به ۳ قسمت تقسیم شده و هر قسمت با هدف تعلیم یکی از شبکه‌های N1 و N2 و N3 تفکیک شده است. سپس به روش **PCA** برای هریک از داده‌های تفکیک شده، انتخاب ویژگی و سپس نرمال‌سازی انجام شده است. وظیفه شبکه عصبی اول N1 تشخیص نمونه‌های نرمال از سایر آریتمی‌ها است. اگر نمونه وارد شده نرمال باشد که گزارش آن اعلام می‌گردد و الگوریتم خاتمه می‌یابد، اما اگر نمونه مبتلا به آریتمی باشد جهت تشخیص این که آیا نمونه در کلاس آریتمی‌های رایج ۵ گانه است یا خیر به شبکه عصبی دوم N2 ارسال می‌شود. اگر شبکه عصبی دوم

این پژوهش با هدف تشخیص آریتمی‌های قلبی با استفاده از روش‌های مبتنی بر یادگیری ماشین انجام شده است. داده‌های مورد استفاده در این مطالعه، از مرجع داده **UCI**، شامل ۴۵۲ نمونه با ویژگی جمع‌آوری شده است. از این تعداد ۵۴/۲٪ وضعیت نرمال و ۴۵/۸٪ مبتلا به یکی از انواع ۱۵ آریتمی می‌باشند. پرواضح است که وجود تعداد نمونه‌های بیشتر می‌تواند منجر به بهبود فرآیند یادگیری در مدل‌های یادگیر شود، لیکن چالش کمبود نمونه در بسیاری از پایگاه داده‌های پزشکی وجود دارد [۱۸] و پایگاه داده مفروض به عنوان یک مرجع تشخیص بیماری آریتمی قلبی، نیز از این مسئله مستثنی نیست. به منظور آموزش مدل‌های یادگیر از ۷۰٪ نمونه‌ها به عنوان داده‌های آموزش و از ۳۰٪ به عنوان داده‌های آزمون استفاده شده است. فرآیند انتخاب نمونه‌های آموزش و آزمون به صورت تصادفی بوده و به منظور اطمینان از حضور تمامی نمونه‌ها در فرآیند آموزش از روش اعتبارسنجی متقابل (**K-fold**) استفاده شده است. آنچه که در این پژوهش نسبت به سایر مطالعات مشابه، متمایز است، استفاده از چندین سیستم یادگیر به جای یک سیستم است. به گونه‌ای که یادگیرها بتوانند با مشارکت یکدیگر نتایج دقیق‌تری را به دست آورند. روش‌های مختلفی برای ترکیب کردن دسته‌بندها وجود دارد. یکی از معروف‌ترین آن‌ها الگوریتم **Bagging** است که در آن تعدادی از


تشخیص دهد که نمونه در بین ۵ کلاس رایج نیست که آن را به عنوان سایر آریتمی‌ها گزارش می‌دهد و در غیر این صورت به شبکه عصبی سوم N3 ارسال می‌کند. در نهایت شبکه عصبی سوم تشخیص می‌دهد که نمونه مورد نظر جزو کدام یک از انواع ۵ گانه آریتمی‌ها است. جهت بررسی عملکرد روش پیشنهادی از رابطه ۵، شاخص میانگین مربعات خطا (RMSE) استفاده شده است.

(۵)


$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{T}}$$



شکل ۵: الف) خطای RMSE شبکه N1



شکل ۵: ب) خطای RMSE شبکه N2



شکل ۵: ج) خطای RMSE شبکه N3

الف نشان می‌دهد که شبکه عصبی اول (N1) پس از ۱۵ تکرار به خطای ۰/۰۷ در داده‌های آزمون رسیده است و همان طور


شکل ۵ - الف، ب و ج به ترتیب بهترین خطای یادگیری شبکه عصبی N1 و N2 و N3 می‌باشند. به عبارت دقیق‌تر شکل ۵-

پایه‌سازی شده است. به عنوان مثال، می‌توان به تشخیص آریتمی قلبی با روش‌های مبتنی بر رگرسیون به منظور تشخیص دو کلاس نرمال و غیر نرمال [۱۷]، مدل مخفی مارکو برای ۳ نوع آریتمی [۱۸]، کلونی زنبور برای تشخیص ۶ نوع آریتمی [۱۹]، درخت تصمیم برای دو کلاس نرمال و غیر نرمال [۲۰]، اشاره کرد. مجموعه‌ای از مطالعات و روش‌های مختلف در جدول ۵ نشان داده شده است.

هدف نهایی یک سیستم شناسایی الگو رسیدن به بالاترین نرخ طبقه‌بندی ممکن برای مسئله موردنظر است. از آنجایی که هیچ الگوریتم طبقه‌بندی وجود ندارد که به تنهایی به طور کامل برای تمام مسائل مناسب باشد، ترکیب خبرها به عنوان یک راه‌حل برای افزایش کارایی آن‌ها پیشنهاد شده است. آنچه که در این مطالعه نسبت به سایر پژوهش‌های مشابه مشهود است، جایگزینی ترکیب طبقه‌بندی مختلف به صورت سری، است. علت بهبود نتیجه را می‌توان این‌گونه توصیف کرد که: اگرچه هر یک از شبکه‌های عصبی می‌توانند به تنهایی به پیش‌بینی بیماری آریتمی قلبی بپردازند؛ اما وقتی وظیفه هر طبقه‌بند تخصصی شود، منجر به افزایش دقت آن می‌شود. به این ترتیب برای هر طبقه‌بندی پایه، توزیع نمونه‌های ورودی برای آموزش در جهتی تغییر داده می‌شود که طبقه‌بندی‌ها بر روی نمونه‌ها سخت‌تر متمرکز شوند و در نهایت هر یک از شبکه‌ها بهتر تعلیم داده شوند.

همان‌طور که جدول ۵ نشان می‌دهد محققین مختلف با روش‌های متعددی سعی در بهبود تشخیص بیماری آریتمی قلبی داشته‌اند، که روش‌های مختلف طبقه‌بندی از شبکه‌های عصبی مصنوعی گرفته تا شبکه‌های یادگیر عمیق مورد توجه بوده است. اغلب پایگاه داده‌های مورد مطالعه مربوط به پایگاه داده MIT-Arrhythmias BIH بوده که در پژوهش حاضر نیز از همین پایگاه داده استفاده شده است. سه پارامتر دقت (Accuracy) و (Sensitivity) و (Specificity) به منظور صحت‌سنجی مدل‌های پیشنهادی مورد ارزیابی قرار گرفته‌اند. جدول ۶ مقایسه عملکرد روش ترکیب شبکه‌ها و روش بدون ترکیب را نشان می‌دهد.

که الگوریتم پیشنهادی در شکل ۴ نشان می‌دهد وظیفه این شبکه تشخیص نمونه‌های سالم از بیمار بوده است. شکل ۵-ب فرآیند یادگیری شبکه دوم را نشان می‌دهد و بیانگر این است که این شبکه در تشخیص وظیفه خود یعنی نمونه اصلی و غیر اصلی توانسته است به خطای ۰/۱۲ در داده‌های آزمون دست پیدا کند. شکل ۵-ج که با هدف تشخیص ۵ کلاس اصلی طراحی و آموزش داده شده است، پس از ۱۱ تکرار به خطای ۰/۲۹ رسیده است. برای این که بتوان عملکرد ترکیب شبکه‌ها را با عملکرد شبکه در حالتی که ترکیب انجام نشده است مقایسه شود شبکه‌ای بنام Nfinal طراحی شد که فرآیند آموزش آن در شکل ۶ نشان داده شده است.



شکل ۶: خطای شبکه Nfinal

نتایج حاکی از آن است که شبکه عصبی Nfinal که قرار است به تنهایی ۶ نوع آریتمی را تشخیص دهد بعد از گذشت ۴۷۸ تکرار توانسته است به خطای ۰/۱۲ دست پیدا کند در حالی که جمع تکرارهای ۳ شبکه فوق برابر ۴۵ تکرار می‌باشد. به عبارت دقیق‌تر استفاده از چندین شبکه عصبی مصنوعی و ترکیب آن‌ها به روش سلسله مراتبی نسبت به زمانی که فقط از یک شبکه عصبی استفاده می‌شود در پیش‌بینی دقیق‌تر بیماری مؤثر است.

بحث و نتیجه‌گیری

تاکنون، تحقیقات و مطالعات زیادی در زمینه کاربرد داده کاوی در تشخیص بیماری آریتمی قلبی انجام شده است. همچنین روش‌های مختلف داده کاوی بر روی داده‌های آریتمی قلبی که عمدتاً در دو مجموعه MIT و UCI گردآوری شده‌اند،

جدول ۵: انواع روش‌های مورد مطالعه در تشخیص آریتمی قلب

روش مورد مطالعه	تشخیص نوع آریتمی	پایگاه داده	صحت عملکرد	سال
شبکه عصبی مصنوعی [۲۱]	Normal, Sinus bradycardly	MIT-BIH	Accuracy=%۹۰/۱۶	۲۰۱۱
ژنتیک و شبکه عصبی [۲۲]	6 different arrhythmias	MIT-BIH arrhythmias	Specificity=%۸۴/۱۰	۲۰۱۱
شبکه عصبی فازی [۲۵]	Normal, Ischemic Changes Old Anterior, Other	UCI	Accuracy=%۹۳/۷۵	۲۰۱۲
شبکه عصبی پایه شعاعی [۲۶]	LBBB, RBBB, PVC	MIT-BIH arrhythmias	Accuracy=%۹۹/۶۰ Sensitivity=%۹۹/۶۰ Specificity=%۹۹/۹۰	۲۰۱۲
بردار ماشین پشتیبان SVM [۲۳]	Normal, PVC, Other	MIT-BIH	MSE test= ۰/۱۵۳	۲۰۱۳
ویولت و شبکه عصبی مصنوعی [۲۴]	Normal, Fusion beat, Ventricular ectopic beat, Supra ventricular, Unknown beat	MIT-BIH arrhythmias	Sensitivity=%۶۹/۳۸ Accuracy=%۹۷/۵۰	۲۰۱۴
بیزین [۲۷]	3-6 arrhythmias	MIT-BIH arrhythmias	Accuracy=%۶۹/۳۸ Sensitivity=%۹۴/۶۷	۲۰۱۴
یادگیری عمیق [۲۸]	ترکیب CNN و عصبی بازگشتی (RNN)	MIT-BIH arrhythmias	Accuracy=%۹۸/۱۶ Sensitivity=%۹۸/۰۵ Specificity=%۹۲/۰۶	۲۰۱۹
ترکیب یادگیر عمیق [۲۹]	PVC, LBBB, RBBB, Tachycardia	MIT-BIH arrhythmias	Accuracy=%۸۸/۱۸ Sensitivity=%۸۵/۶۷ Specificity=%۸۱/۲۵	۲۰۲۲
یادگیری عمیق [۳۰]	4 arrhythmias	PhysioNet/Computing in Cardiology 2021	Accuracy=%۹۸/۱۷	۲۰۲۱
یادگیری عمیق [۳۱]	5 arrhythmias	MIT-BIH arrhythmias	Accuracy=%۹۶/۶۰ Sensitivity=%۶۴/۰۴ Specificity=%۸۹/۱	۲۰۱۷
یادگیری عمیق CNN [۳۲]	Coronary artery disease	MIT-BIH arrhythmias	Accuracy=%۹۹/۸۵ Sensitivity=%۹۹/۱ Specificity=%۹۹/۸۴	۲۰۱۸

جدول ۶: مقایسه عملکرد ترکیب سلسله مراتبی شبکه عصبی با شبکه عصبی مستقل

تعداد آریتمی‌های قابل تشخیص	استفاده از روش ترکیب شبکه‌های عصبی	استفاده از یک شبکه عصبی	دقت شبکه
Normal, Ischemic Changes, Old Anterior, Old Inferior Right bundle branch bloc, Sinus bradycardia, Other	Accuracy	%۹۳/۵	%۸۹/۵
	AUC	۰/۹۶	۰/۹۱

پژوهش حاضر نشان می‌دهد که در تشخیص بیماری آریتمی قلبی ترکیب شبکه‌های عصبی مصنوعی به صورت سلسله مراتبی نه تنها نسبت به حالت عدم ترکیب شبکه‌ها نتایج بهتری دارد بلکه نسبت به تحقیقات مشابه این حوزه توانسته است به دقت مطلوب‌تری با توجه به تعداد کلاس آریتمی‌ها (۶ نوع آریتمی) دست یابد.

برخی از محدودیت‌های این پژوهش عبارت‌اند از: محدودیت در انتخاب ویژگی‌ها: در این پژوهش، به دلیل استفاده از روش PCA ممکن است برخی از ویژگی‌های مرتبط با تشخیص آریتمی‌های قلبی نادیده گرفته شده باشند و این ممکن است منجر به از دست دادن اطلاعات یا رابطه‌های پنهان در داده‌ها شده باشد که می‌توانست تأثیر مثبتی بر تشخیص نوع آریتمی داشته باشد.

محدودیت در دسترسی به داده‌ها: با توجه به این که پایگاه داده مورد مطالعه از یک پایگاه داده مشخص حاوی داده‌های ECG برای نمونه‌های خاصی از بیماران بوده، ممکن است منجر به عدم قابلیت تعمیم نتایج به جمعیت‌های دیگر یا نوع‌های آریتمی‌های مختلف شود.

برخی از محدودیت‌های این پژوهش عبارت‌اند از: محدودیت در انتخاب ویژگی‌ها: در این پژوهش، به دلیل استفاده از روش PCA ممکن است برخی از ویژگی‌های مرتبط

افزودن تنوع به آنها می‌تواند به بهبود کارایی مدل‌های شبکه‌های عصبی کمک کند. این شامل استفاده از داده‌های ECG از منابع مختلف و تعداد بیشتری از بیماران و شرایط مختلف می‌شود.

به دلیل نامتوازن بودن داده‌ها برخی از کلاس‌های آریتمی قلبی که با کمبود نمونه مواجه بودند با سایر کلاس‌ها ترکیب شده‌اند. این مسئله می‌تواند منجر به عدم تشخیص آریتمی‌های نادر شود. استفاده از روش‌های داده‌افزایی به منظور متوازن‌سازی داده‌ها می‌تواند در تحقیقات آتی مورد توجه قرار گیرد. استفاده از ترکیب با دیگر روش‌ها: ممکن است ترکیب شبکه‌های عصبی با روش‌های دیگری مانند روش‌های کلاسیک پردازش سیگنال یا الگوریتم‌های یادگیری ماشینی، ممکن است نتایج بهتری در تشخیص آریتمی‌های قلبی داشته باشد.

تعارض منافع

نویسندگان مقاله اعلام می‌دارند که در این پژوهش هیچگونه تعارض منافی وجود ندارد.

References

1. Dowlatshahi M. Application of fuzzy logic in detecting irregular heartbeat using ECG. *Fuzzy Systems and its Applications* 2020;3(1):33-61. doi:20.1001.1.27174409.1399.3.1.3.8/DOR
2. Zhou X, Zhu X, Nakamura K, Noro M. Atrial fibrillation detection using convolutional neural networks. 9th International Conference on Awareness Science and Technology (iCAST); 2018 Sep 19-21; Fukuoka, Japan: IEEE; 2018. p. 84-9. doi: 10.1109/ICAWS.2018.8517221
3. Saadi P, Zeinalnezhad M, Movahedi SF. Modeling and Predicting the Risk of Coronary Artery Disease Using Data Mining Algorithms. *Journal of Health and Biomedical Informatics* 2021; 8(2):193-207. [In Persian]
4. Swapna G, Soman KP, Vinayakumar R. Automated detection of cardiac arrhythmia using deep learning techniques. *Procedia Computer Science* 2018;132:1192-201. <https://doi.org/10.1016/j.procs.2018.05.034>
5. Badr M, Al-Otaibi S, Alturki N, Abir T. Detection of heart arrhythmia on electrocardiogram using artificial neural networks. *Computational Intelligence and Neuroscience*. 2022;2022. <https://doi.org/10.1155/2022/1094830>
6. Jun TJ, Nguyen HM, Kang D, Kim D, Kim YH. ECG arrhythmia classification using a 2-D

محدودیت‌های تعداد نمونه‌ها: تعداد نمونه‌های موجود در پایگاه داده به خصوص در برخی از کلاس‌ها محدود است و این ممکن است تأثیر مثبت یا منفی بر عملکرد مدل‌های سلسله‌مراتبی داشته باشد، به ویژه در شناسایی آریتمی‌های نادر یا خارج از دامنه پوشش داده شده.

محدودیت‌های زمانی: به دلیل محدودیت‌های زمانی، تنها یک ترکیب مشخص از معماری‌ها و پارامترهای شبکه‌های عصبی مصنوعی مورد بررسی قرار گرفته است؛ لذا ممکن است تأثیری بر بهبود یا تناسب بهتر سیستم‌های دیگر داشته باشد.

پیشنهاداتی که در پژوهش‌های آتی می‌تولند مورد بررسی محققین این حوزه قرار گیرد، عبارت‌اند از:

توسعه مدل‌های پیچیده‌تر: استفاده از مدل‌های شبکه‌های عصبی بیشتری با ساختارها و لایه‌های پیچیده‌تر برای ترکیب سلسله‌مراتبی می‌تواند مد نظر قرار گرفته و به بهبود دقت تشخیص و تفکیک آریتمی‌ها کمک کند.

استفاده از شبکه‌های عصبی عمیق‌تر: استفاده از ترکیب شبکه‌های عصبی عمیق‌تر، مانند شبکه‌های عصبی ترتیبی (RNNs)، می‌تواند در پژوهش‌های آتی مورد بررسی قرار گیرد. استفاده از داده‌های بزرگ‌تر و متنوع‌تر: افزایش حجم داده‌ها و

convolutional neural network. arXiv preprint arXiv:1804.06812. 2018 Apr 18.

<https://doi.org/10.48550/arXiv.1804.06812>

7. Fooladi S, Farsi H, Farsi F. Adaptive Filtering Strategy to Remove Noise from ECG Signals Using Wavelet Transform and Deep Learning *Journal of Health and Biomedical Informatics* 2020; 7(3): 318-25. [In Persian]

8. Le KH, Pham HH, Nguyen TB, Nguyen TA, Thanh TN, Do CD. Lightx3ecg: A lightweight and explainable deep learning system for 3-lead electrocardiogram classification. *Biomedical Signal Processing and Control* 2023;85:104963. <https://doi.org/10.1016/j.bspc.2023.104963>

9. Mitra M, Samanta RK. Cardiac arrhythmia classification using neural networks with selected features. *Procedia Technology* 2013;10:76-84. <https://doi.org/10.1016/j.protcy.2013.12.339>

10. Yang F, Du J, Lang J, Lu W, Liu L, Jin C, Kang Q. Missing value estimation methods research for arrhythmia classification using the modified kernel difference-weighted KNN algorithms. *BioMed Research International* 2020;2020. <https://doi.org/10.1155/2020/7141725>

11. Yang W, Si Y, Wang D, Guo B. Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine.

- Computers in Biology and Medicine 2018;101:22-32. <https://doi.org/10.1016/j.compbiomed.2018.08.003>
12. Mohonta SC, Motin MA, Kumar DK. Electrocardiogram based arrhythmia classification using wavelet transform with deep learning model. *Sensing and Bio-Sensing Research* 2022;37:100502. <https://doi.org/10.1016/j.sbsr.2022.100502>
13. Rajpurkar P, Hannun AY, Haghpanahi M, Bourn C, Ng AY. Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv preprint arXiv:1707.01836*. 2017 Jul 6. <https://doi.org/10.48550/arXiv.1707.01836>
14. Pyakillya B, Kazachenko N, Mikhailovsky N. Deep Learning for ECG Classification. *Journal of Physics Conference Series* 2017;913(1):012004. doi:10.1088/1742-6596/913/1/012004
15. Hassanzadeh M, Zabbah I, Layeghi K. Diagnosis of Coronary Heart Disease using mixture of experts method. *Journal of Health and Biomedical Informatics* 2018;5(2):274-85. [In Persian]
16. Lichman M. *UCI Machine Learning Repository*. California: University of California; 2013. 2013.
17. Pinkus A. Approximation theory of the MLP model in neural networks. *Acta Numerica* 1999;8:143-95. Doi: <https://doi.org/10.1017/S0962492900002919>
18. Zhao Y, Cheng J, Zhang P, Peng X. ECG classification using deep CNN improved by wavelet transform. *Computers, Materials and Continua* 2020;64(3): 1615-28. <https://doi.org/10.32604/cmc.2020.09938>
19. Yang H, Wei Z. Arrhythmia recognition and classification using combined parametric and visual pattern features of ECG morphology. *IEEE Access* 2020;8:47103-17.
20. Wang G, Chen M, Ding Z, Li J, Yang H, Zhang P. Inter-patient ECG arrhythmia heartbeat classification based on unsupervised domain adaptation. *Neurocomputing* 2021;454:339-49. <https://doi.org/10.1016/j.neucom.2021.04.104>
21. Zeraatkar E, Kermani S, Mehridehnavi A, Aminzadeh A, Zeraatkar E, Sanei H. Arrhythmia detection based on Morphological and time-frequency Features of t-wave in Electrocardiogram. *J Med Signals Sens* 2011; 1(2): 99-106.
22. Waseem K, Javed A, Ramzan R, Farooq M. Using evolutionary algorithms for ECG Arrhythmia detection and classification. *Seventh International Conference on Natural Computation*; 2011 Jul 26-28; Shanghai, China: IEEE; 2011. p. 2386-90. doi: 10.1109/ICNC.2011.6022596
23. Khazae A. Heart beat classification using particle swarm optimization. *International Journal of Intelligent Systems and Applications* 2013;5(6):25. doi: 10.5815/ijisa.2013.06.03
24. Das MK, Ari S. ECG beats classification using mixture of features. *International Scholarly Research Notices* 2014;2014. <https://doi.org/10.1155/2014/178436>
25. Jadhav SM, Nalbalwar SL, Ghatol AA. Artificial neural network models based cardiac arrhythmia disease diagnosis from ECG signal data. *International Journal of Computer Applications* 2012;44(15):8-13.
26. Rai HM, Trivedi A, Shukla S, Dubey V. ECG arrhythmia classification using aubechies wavelet and radial basis function neural network. *Nirma University International Conference on Engineering*; 2012 Dec 6-8; Ahmedabad, India: IEEE; 2012. p. 1-6. doi: 10.1109/NUICONE.2012.6493281
27. Ahmed AF, Owis MI, Yassine IA. Novel Bayesian classifier discriminant function optimization strategies for arrhythmia classification. *International Conference on Biomedical and Health Informatics*; 2014 Jun 1; Valencia, Spain: IEEE; 2014. p. 693-6. doi: 10.1109/BHI.2014.6864458
28. Andersen RS, Peimankar A, Puthusserypady S. A deep learning approach for real-time detection of atrial fibrillation. *Expert Systems with Applications* 2019;115:465-73. <https://doi.org/10.1016/j.eswa.2018.08.011>
29. Jahan MS, Mansourvar M, Puthusserypady S, Wiil UK, Peimankar A. Short-term atrial fibrillation detection using electrocardiograms: A comparison of machine learning approaches. *International Journal of Medical Informatics* 2022;163:104790. <https://doi.org/10.1016/j.ijmedinf.2022.104790>
30. Bortolan G. 3D ECG display with deep learning approach for identification of cardiac abnormalities from a variable number of leads. *Physiological Measurement*. 2023 Feb 16;44(2):024002. doi:10.1088/1361-6579/acb4dc
31. Acharya UR, Fujita H, Oh SL, Hagiwara Y, Tan JH, Adam M, Tan RS. Deep convolutional neural network for the automated diagnosis of congestive heart failure using ECG signals. *Applied Intelligence* 2019;49:16-27.
32. Tan JH, Hagiwara Y, Pang W, Lim I, Oh SL, Adam M, et al. Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals. *Computers in Biology and Medicine* 2018;94:19-26. <https://doi.org/10.1016/j.compbiomed.2017.12.023>