

تجزیه و تحلیل چندوجهی سیگنال‌های الکتروکاردیوگرام برای تشخیص آریتمی قلبی با بهره‌گیری از روش‌های یادگیری ماشین و یادگیری عمیق

مطهره اکبری پودینه^۱، فاطمه زارع مهرجردی^{۲*}، محسن سرداری زارچی^۳

^۱کارشناسی ارشد هوش مصنوعی، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه میبد، میبد، ایران

^۲استادیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه میبد، میبد، ایران

^۳دانشیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه میبد، میبد، ایران

چکیده

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۳/۱۲/۲۷

تاریخ پذیرش:

۱۴۰۴/۵/۲۵

کلیدواژه‌ها:

آریتمی قلبی، سیگنال ECG

یادگیری ماشین، یادگیری عمیق

نویسنده مسئول:

fzare@meybod.ac.ir

بیماری‌های قلبی مانند آریتمی قلبی شایع‌ترین علت مرگ در جهان محسوب می‌شوند. تشخیص سریع این نوع بیماری باعث افزایش کیفیت زندگی، طول عمر و کاهش هزینه‌های درمان می‌شود. در این پژوهش هدف شناسایی بیماری آریتمی قلبی از روی الکتروکاردیوگرام و ابزار هوش مصنوعی است. روش پیشنهادی از سه مرحله پیش‌پردازش، تقسیم‌بندی پایگاه داده و طبقه‌بندی داده‌ها تشکیل شده است. ابتدا در مرحله پیش‌پردازش، عملیات نرمال‌سازی، پاک‌سازی و متوازن‌سازی کلاس‌ها انجام شده است. سپس پایگاه داده پردازش شده برای عملیات آموزش و آزمایش تقسیم‌بندی شده است. در نهایت داده‌ها با استفاده از طبقه‌بندهای مختلف یادگیری ماشین، معماری‌های یادگیری عمیق و یک مدل ترکیبی از معماری‌های CNN، RNN و Transformer، گروه‌بندی شده‌اند. روش پیشنهادی با پایگاه داده MIT-BIH مورد ارزیابی قرار گرفته است. نتایج ارزیابی‌ها نشان داد که از بین مدل‌های یادگیری ماشین و معماری‌های مختلف یادگیری عمیق، مدل ترکیبی با ادغام ویژگی‌های محلی حاصل از معماری CNN و شناسایی وابستگی‌های زمانی طولانی و پیچیده توسط معماری RNN و Transformer جز برترین طبقه‌بندها هست. در نهایت، یافته‌ها بر اهمیت ادغام ویژگی‌های چندگانه در تحلیل سیگنال‌های حاصل از الکتروکاردیوگرام برای تشخیص دقیق‌تر آریتمی قلبی تأکید می‌کند و می‌تواند در توسعه سیستم‌های تشخیصی خودکار کارآمدتر استفاده شود.

doi : 10.22034/ABMIR.2025.22930.1118

۱- مقدمه

سایر بیماری‌های قلبی: این مورد شامل عفونت‌ها، بزرگ‌شدن عضله قلب و اختلالات ارثی می‌باشند. شناسایی زودهنگام هر یک از بیماری‌های قلبی باعث کاهش هزینه‌های درمان و افزایش طول عمر بیمار می‌شود [۱].

اگرچه روش‌های مختلفی مانند معاینه بالینی، اکوکاردیوگرافی، مانیتورینگ تله‌متری، مطالعات الکتروفیزیولوژی و ام آر آی قلبی نیز برای تشخیص و بررسی آریتمی قلبی وجود دارند، اما تمرکز اصلی این پژوهش بر تحلیل سیگنال‌های ECG بوده است. دلیل این تمرکز، پتانسیل بالای روش‌های یادگیری ماشین^۱ و یادگیری عمیق^۲ در استخراج الگوهای پیچیده از داده‌های ECG و ارائه یک روش تشخیصی خودکار، دقیق و کارآمدتر بر مبنای این سیگنال در دسترس است.

الکتروکاردیوگرام یا سیگنال^۳ ECG، نوعی آزمایش برای بررسی سلامت قلب و تشخیص بیماری‌های قلبی از روی ریت‌های نامنظم موجود در این آزمایش است. درواقع یک ابزار تشخیصی حیاتی در حوزه قلب است که با اندازه‌گیری فعالیت الکتریکی قلب، اطلاعات ارزشمندی درباره سلامت قلب ارائه می‌دهد. ریت‌های نامنظم قلب که ممکن است نشانه‌ای از بیماری‌های قلبی جدی باشند، به راحتی با استفاده از ECG قابل تشخیص هستند. پیشرفت هوش مصنوعی و تحلیل سیگنال ECG با کمک این روش‌ها به پزشکان کمک می‌کند تا بیماری‌های قلبی را در مراحل اولیه تشخیص داده و اقدامات درمانی مناسب را در اسرع وقت انجام دهند [۲].

۲- مروری بر کارهای گذشته

با توجه به مطالعه‌های انجام شده، روش‌های موجود جهت تشخیص و دسته‌بندی آریتمی قلبی با استفاده از هوش مصنوعی به دو دسته عمده تقسیم می‌شوند: روش‌های یادگیری ماشین و روش‌های یادگیری عمیق. یادگیری ماشین یک علم میان رشته‌ای است که هدف آن تقلید رفتار انسان در یادگیری است. یادگیری بدون ماشین به سه دسته اصلی یادگیری تحت نظارت، یادگیری بدون

بیماری‌های قلبی عروقی یکی از دلایل اصلی مرگ‌ومیر جهان هستند. تشخیص زودهنگام این بیماری‌ها، کلید اصلی درمان موفق و نجات‌بخش جان بسیاری از بیماران است. به‌طور کلی بیماری‌های قلبی و عروقی را می‌توان در ۵ دسته گروه‌بندی کرد.

بیماری‌های کرونری و عروقی: این دسته از بیماری‌ها ناشی از سخت شدن و تنگ شدن شریان‌های قلب (آترواسکلروز) هستند. بیماری عروق کرونری زمانی رخ می‌دهد که شریان‌های قلب تنگ یا مسدود شوند. این شایع‌ترین نوع بیماری قلبی است و اغلب باعث حمله قلبی و آنژین (درد قفسه سینه) می‌شود. بیماری عروقی مربوط به مشکلات در سایر رگ‌های خونی است که جریان خون را کاهش داده و عملکرد قلب را تحت تأثیر قرار می‌دهد.

اختلالات ریتم قلب (آریتمی): این دسته از بیماری‌ها باعث می‌شوند که قلب با سرعت بیش‌ازحد، کند یا به‌صورت نامنظم بتپد. میلیون‌ها نفر با اختلالات ریتم قلب مواجه هستند که جریان خون آن‌ها دچار اختلال شده است.

بیماری‌های مربوط به ساختار قلب: این دسته به ناهنجاری‌های ساختاری قلب از جمله دریچه‌ها، دیواره‌ها، عضلات یا رگ‌های خونی نزدیک به قلب اشاره دارد. این ناهنجاری‌ها می‌توانند مادرزادی باشند یا پس از تولد در اثر عفونت، فرسودگی یا سایر عوامل به وجود آیند. افرادی که با نقص‌های قلبی زندگی می‌کنند و خانواده‌های آن‌ها، در تمام سنین و مراحل زندگی خود نیاز به حمایت دارند و اغلب به مراقبت‌های پزشکی و جراحی مداوم نیاز دارند.

نارسایی قلبی: نارسایی قلبی یک بیماری جدی است که پس از آسیب دیدن یا ضعیف شدن قلب ایجاد می‌شود. شایع‌ترین علل نارسایی قلبی حمله قلبی و فشارخون بالا هستند. هرچند درمان قطعی برای آن وجود ندارد، اما تشخیص زودهنگام، تغییر سبک زندگی و دارودرمانی می‌تواند به افراد کمک کند تا زندگی فعال داشته باشند، از بستری شدن در بیمارستان جلوگیری کند و عمر طولانی‌تری داشته باشند.

³ Electrocardiogram

¹ Machine Learning

² Deep Learning

دقت‌های متوسط ۹۳/۵۳٪ و ۹۵/۲۲٪ را برای سیگنال‌های ECG با نویز و بدون نویز به دست آورد. بدون اینکه نیاز به استخراج یا انتخاب ویژگی داشته باشد. نقاط قوت این مدل شامل توانایی تشخیص دقیق سیگنال‌های ECG ناشناخته حتی در حضور نویز و پتانسیل استفاده در محیط‌های بالینی برای کمک به پزشکان است. این تحقیق به اهمیت تشخیص زودهنگام MI و بهره‌وری سیستم‌های تشخیص به کمک کامپیوتر تأکید دارد [۶].

مورالیدار به بررسی شناسایی و پیش‌بینی آریتمی قلبی از طریق سیگنال‌های ECG با استفاده از الگوریتم‌های یادگیری ماشین پرداخته است. محققان از مجموعه داده‌های UCI که شامل ۱۷ نوع ضربان مختلف است، برای آموزش مدل‌های مختلف، از جمله شبکه عصبی عمیق^۴، ماشین بردار پشتیبان^۵ و الگوریتم نزدیک‌ترین همسایگی^۶ استفاده کردند. روش‌های پیش‌پردازش، مانند حذف ستون‌های خالی و جانمایی مقادیر گمشده، دقت پیش‌بینی را بهبود بخشید. این مقاله بر اهمیت حذف خطای انسانی در تشخیص آریتمی تأکید کرده و ابزارهای یادگیری ماشین را به عنوان راهکاری مؤثر برای تشخیص خودکار و بی‌درنگ این اختلال‌ها معرفی می‌کند. از نکات قوت آن می‌توان به دقت بالا و استفاده از تکنیک‌های نوآورانه اشاره کرد، درحالی‌که پیچیدگی الگوریتم‌ها و نیاز به داده‌های تمیز به عنوان نکات ضعف مطرح می‌شود [۷].

ستایش و همکاران از یک شبکه رمزگذار خودکار برای شناسایی افراد دارای بیماری قلبی و افراد سالم استفاده کردند. آنها از پایگاه داده ECG5000 استفاده کردند و شبکه را فقط بر اساس نمونه‌های سالم آموزش دادند. پس از آموزش شبکه نمونه‌های سالم و بیماری قلبی از روی خطای به دست آمده از مرحله بازسازی شناسایی شدند. روش مورد نظر توانسته با کسب دقت ۹۴/۵٪ نمونه‌های افراد سالم و بیماران قلبی را به خوبی از هم شناسایی کند [۲].

مورات و همکارانش از مدل شبکه عصبی عمیق برای استخراج ویژگی از روی سیگنال ECG و تشخیص آریتمی قلبی استفاده کردند. آنها با بررسی بیش از ۱۰۰۰ پرونده ECG و با ترکیب ویژگی‌های عمیق و ریتمیک به دقت قابل توجهی رسیدند [۸].

نظارت و یادگیری نیمه نظارتی تقسیم می‌شود. در یادگیری تحت نظارت، همه نمونه‌ها و برجسب‌های آنها موجود هستند و با استفاده از آنها مدل ایجاد می‌شود. بدیهی است که برجسب نمونه‌های جدید با استفاده از مدل ایجاد شده پیش‌بینی می‌شوند. از عیب‌های روش یادگیری ماشین این است که عملکرد روش‌های یادگیری ماشین به شدت وابسته به مرحله استخراج ویژگی از داده است، بطوریکه استخراج ویژگی‌های نامناسب، عملکرد ضعیف روش‌های یادگیری ماشین را به دنبال دارد.

روش یادگیری عمیق زیرمجموعه‌ای از روش یادگیری ماشین است و امروزه در مسائل زیادی کاربرد دارد. روش یادگیری عمیق می‌تواند به صورت خودکار ویژگی‌های سطح بالا را به صورت مستقیم از روی داده‌ها استخراج کند. این روش بازنمایی‌های بامعنا و قدرتمندی را از روی داده‌ها آموزش می‌بندد و از استخراج ویژگی به صورت دستی جلوگیری می‌کند. معماری‌های یادگیری عمیق به داده و زمان زیادی برای آموزش و جلوگیری از مساله بیش‌برازش نیاز دارند و این بزرگ‌ترین چالش در روش یادگیری عمیق است [۴ و ۳]. در ادامه مروری بر تعدادی از مطالعه‌های انجام شده در زمینه تشخیص بیماری آریتمی قلبی آورده شده است.

پیش‌بینی بیماری قلبی با استفاده از شبکه‌های عصبی گرافی با ارائه یک رویکرد سیستماتیک توسط بی و همکاران انجام شده است. این مطالعه تلاش کرده است تا داده‌ها را به دو دسته بیماری قلبی و غیر قلبی دسته‌بندی کند و از مراحل مختلفی هم‌چون تعریف مدل، آموزش، و بهینه‌سازی بهره گرفته است. در این پژوهش، علاوه بر شبکه‌های عصبی گرافی، از شبکه‌های عصبی پیش‌خور^۱ نیز برای پیش‌بینی‌های اصلی استفاده شده است، که به عنوان پایه‌ای برای بهبود و توسعه مدل‌های جدید مورد توجه قرار گرفته‌اند [۵].

تان و همکارانش رویکردی جدید برای تشخیص خودکار انفارکتوس میوکارد^۲ با استفاده از سیگنال‌های الکتروکاردیوگرام ارائه کردند که به منظور حل چالش‌های تفسیر بصری سیگنال‌ها توسعه یافته است. با استفاده از یک الگوریتم شبکه عصبی کانولوشن^۳ عمیق یازده لایه، این تحقیق توانسته است

⁴ Deep Neural Network (DNN)

⁵ Support vector machine (SVM)

⁶ K-Nearest Neighbors (KNN)

¹ Feed Forward Neural Network (FNN)

² Myocardial Infraction (MI)

³ Convolutional Neural Network (CNN)

وابستگی به تخصص انسانی در تحلیل و پتانسیل تشخیص زودهنگام الگوهای غیرطبیعی اشاره کرد.

معماری یادگیری عمیق ترکیبی پیشنهادی با بهره‌گیری هم‌زمان از ویژگی‌های محلی و وابستگی‌های زمانی طولانی سیگنال‌های ECG، گامی در جهت استفاده از این مزایا برای تشخیص دقیق‌تر آریتمی قلبی برداشته است.

۳- مفاهیم اصلی

در این بخش مروری کلی بر پایگاه داده و روش‌های پیشنهادی آورده شده است.

۳-۱ پایگاه داده MIT-BIH

یکی از مهم‌ترین بخش‌های هر زمینه پژوهشی وجود پایگاه داده مناسب و بزرگ در آن زمینه است. در صورت وجود پایگاه داده مناسب، مقایسه الگوریتم‌های مختلف در زمینه پژوهشی به راحتی انجام می‌شود. عملکرد هر دو روش یادگیری ماشین و یادگیری عمیق نیز وابسته به وجود پایگاه داده مناسب است.

در زمینه بیماری آریتمی قلبی یکی از مهم‌ترین و پر تنوع‌ترین پایگاه داده‌های موجود، پایگاه داده MIT-BIH است که در سال ۱۹۸۰ توسط بیمارستان بیت اسرائیل و MIT جمع‌آوری شده است و اغلب محققان از آن استفاده می‌کنند.

پایگاه داده‌های دیگری نیز برای ECG نیز وجود دارند ولی یا تعداد نمونه‌های آن کم هست و یا برای یک نوع بیماری قلبی خاص با روش خاصی تهیه شده‌اند. پایگاه داده MIT-BIH شامل ۴۷ ضبط نیم ساعته ECG دو کاناله است و دارای ۱۰۹۴۴۶ نمونه از ۵ کلاس نرمال و ۴ نوع عارضه قلبی (N، S، V، F و Q) است که با فرکانس ۱۲۵ هرتز نمونه‌برداری شده‌اند. یکی از معایب پایگاه داده مذکور وجود تعداد نمونه‌های نامتوازن در کلاس‌های مختلف است [۱۴].

جدول (۱) تعداد نمونه‌های موجود در هر کلاس را نشان می‌دهد که به‌خوبی نشان‌دهنده مشکل نامتوازن بودن پایگاه داده است. شکل (۱) نمونه‌های از کلاس‌های مختلف پایگاه داده را نمایش می‌دهد.

دنیسیوک و همکارانش تعداد ۱۰۳ مقاله علمی در زمینه الگوریتم‌های تشخیص خودکار بیماری‌های قلبی از سال ۲۰۱۷ تا ۲۰۲۲ را بررسی کردند. سپس مدل‌هایی مانند شبکه عصبی کانولوشن و ماشین بردار پشتیبان را به عنوان مؤثرترین مدل‌ها گزارش کردند [۹].

ساهو و همکارانش به تحلیل پیشرفته آریتمی‌های قلبی با استفاده از سیگنال‌های ECG پرداختند. آن‌ها از فیلترهای تطبیقی و مورفولوژی ریاضی برای حذف نویز استفاده کردند. مزیت این روش‌ها دقت بالا است، اما بهینه‌سازی بیشتر مورد نیاز است [۱۰]. لی و همکارانش از مدل‌های شبکه عصبی کانولوشنی عمیق و مفهوم یادگیری انتقالی^۱ برای تشخیص هفت نوع آریتمی قلبی از ۵۱/۵۷۹ پرونده ECG استفاده کردند. نیاز به داده‌های آموزش زیاد و پیچیدگی مدل از محدودیت‌های این روش است [۱۱].

ستار و همکارانش بر روی طبقه‌بندی آریتمی‌های قلبی با استفاده از معماری CNN و LSTM^۲ تمرکز کردند و به دقت ۹۲٪ رسیدند. مزایای روش مذکور شامل بهبود دقت و کاهش زمان تحلیل دستی است، اما نیاز به داده‌های متنوع یکی از مسائل چالش‌برانگیز است [۱۲].

راضا و همکارانش، با استفاده از مدلی با ۹ لایه CNN برای طبقه‌بندی سیگنال‌های ECG در مجموعه داده MIT-BIH به دقت ۹۴/۰۳٪ دست یافتند. این مدل در مقایسه با مدل‌های قبلی دقت و حساسیت بهتری داشت، اما نیاز به منابع سخت‌افزاری بیشتر از چالش‌های آن بود [۱۳].

در این پژوهش هدف ارائه یک روش نوین برای تشخیص دقیق و خودکار آریتمی قلبی از طریق تحلیل چندوجهی سیگنال‌های ECG با بهره‌گیری از قدرت روش‌های یادگیری ماشین و یادگیری عمیق است. این روش‌ها مزایای قابل توجهی نسبت به روش‌های سنتی تحلیل سیگنال ECG دارند. ازجمله این مزایا می‌توان به قابلیت استخراج ویژگی‌های پیچیده و غیرخطی که در تشخیص آریتمی‌های ظریف بسیار حائز اهمیت است، توانایی کار با حجم وسیع داده برای ایجاد مدل‌های قوی‌تر و قابل تعمیم، کاهش

² Long Short-Term Memory (LSTM)


¹ Transfer Learning

۴- روش پیشنهادی

نمای کلی از روش پیشنهادی در شکل (۲) نشان داده شده است. این روش پیشنهادی در ۴ مرحله جمع‌آوری داده‌ها، پیش‌پردازش بر روی داده‌ها، تقسیم‌بندی داده‌ها و دسته‌بندی داده‌ها انجام شده است. در ادامه جزئیات هر یک از مراحل روش پیشنهادی شرح داده شده است.

جدول (۱): تعداد نمونه‌های هر کلاس پایگاه داده MIT-BIH

تعداد نمونه	کلاس
۷۲۴۷۱	Normal beats(N)
۲۲۲۳	Supra ventricular ectopic beats(S)
۵۷۸۸	Ventricular ectopic beats(V)
۶۴۱	Fusion beats(F)
۶۴۳۱	Unknown beats(Q)




شکل (۱): نمونه داده از کلاس‌های مختلف موجود در دیتاست MIT-BIH: a: ضربان سالم، b: ضربان نابجای فوق بطنی، c: ضربان نابجای عضله بطنی، d: ضربان ترکیبی و e: ضربان ناشناخته

در این رابطه هر ویژگی از میانگین کم و سپس بر انحراف معیار آن ویژگی تقسیم شده است تا مقادیر ویژگی در بازه ۰ تا ۱ قرار گیرد.

روش‌های حل مشکل داده‌های گم‌شده: در این مرحله ابتدا ویژگی‌هایی که درصد بالایی مقدار خالی دارند حذف شده و سپس مقادیر خالی هر ویژگی بر اساس مقدار مد هر ویژگی و با توجه به برچسب‌های نمونه‌هایی با کلاس یکسان پر شده‌اند.

اولین مرحله روش پیشنهادی مرحله پیش‌پردازش است، همان‌طور که در شکل (۲) آورده شده است خود شامل ۳ مرحله است: نرمال کردن داده‌ها: در این مرحله برای اینکه همه ویژگی‌ها در دامنه یکسانی قرار بگیرند و تأثیر یکسانی در تشخیص باشند از روش‌های نرمال‌سازی از قبیل StandardScaler استفاده شده است. رابطه (۱) این روش نرمال‌سازی را نمایش می‌دهد.

$$X_{scaled} = \frac{X - X_{mean}}{\sigma} \quad (1)$$



شکل (۲): نمای کلی روش پیشنهادی

پایگاه داده با نسبت ۹۰ به ۱۰ برای طبقه‌بندی‌های یادگیری ماشین انجام شده است. به گونه‌ای که ۹۰٪ داده‌ها برای آموزش و ۱۰٪ داده‌ها برای آزمایش در نظر گرفته شده است. این تقسیم‌بندی در روش‌های یادگیری عمیق با نسبت ۸۰، ۱۰ و ۱۰ برای آموزش^۴، اعتبارسنجی^۵ و آزمایش^۶ صورت گرفته است. در پایان دسته‌بندی داده‌ها در ۵ کلاس با استفاده از انواع الگوریتم‌های یادگیری ماشین و معماری‌های یادگیری عمیق طراحی شده به صورت تکی و ترکیبی انجام شده است. در ادامه توضیح مختصری از مدل‌سازی روش‌های یادگیری ماشین و یادگیری عمیق استفاده شده آورده شده است.

۴-۱ مدل‌سازی روش‌های یادگیری ماشین

ماشین بردار پشتیبان: یکی از محبوب‌ترین روش‌های یادگیری ماشین برای دسته‌بندی است. این روش بر اساس یافتن یک

روش‌های رفع مشکل نامتوازن بودن^۱ کلاس‌های مختلف: با توجه به جدول (۱) نامتوازن بودن پایگاه داده MIT-BIH به وضوح قابل تشخیص است. بزرگ‌ترین مشکل پایگاه داده نامتوازن، سوق داشتن طبقه‌بند به کلاس با داده اکثریت است.

برای حل مشکل نامتوازن بودن در این پژوهش از روش Smote استفاده شده است. در روش Smote با تولید نمونه‌های جدیدی در همسایگی نمونه‌های موجود در کلاس با تعداد حداقل، متوازن‌سازی داده انجام می‌شود. این روش با استفاده از مفهوم الگوریتم K نزدیک‌ترین همسایگی و با اندازه‌گیری فاصله‌ها چند نمونه مشابه را انتخاب کرده و با استفاده از آن‌ها و در همسایگی آن‌ها نمونه جدید را ایجاد می‌کند [۱۵].

پس از آن که سه گام مرحله پیش‌پردازش بر روی پایگاه داده اعمال شد، پایگاه داده به اصطلاح تمیز^۲ شده است. سپس تقسیم‌بندی

⁴ Validation

⁵ Test

¹ Imbalanced

² Clean

³ Train

مختلفی از جمله دسته‌بندی تصاویر ماهواره‌ای مورد استفاده قرار می‌گیرد [۱۸].

آدابوست^۴: این روش با ترکیب چند مدل ضعیف و تقویت آن‌ها به حل مسائل پیچیده می‌پردازد. در این روش، مدل‌ها به صورت سلسله‌مراتبی آموزش می‌بینند و هر مدل تلاش می‌کند ایرادات مدل‌های قبلی را برطرف کند. تمرکز مدل‌ها بر روی نمونه‌هایی است که در مراحل قبلی به درستی طبقه‌بندی نشده‌اند. برای این منظور، وزن نمونه‌هایی که درست طبقه‌بندی شده‌اند کاهش می‌یابد و وزن نمونه‌های اشتباه افزایش پیدا می‌کند. با این کار، مدل بعدی می‌فهمد که کجا باید تمرکز کند و سعی می‌کند نمونه‌هایی که به درستی طبقه‌بندی نشده‌اند را بهتر تشخیص دهد [۱۹].

۴-۲ مدل‌سازی روش‌های یادگیری عمیق

یادگیری عمیق زیرمجموعه‌ای از روش‌های یادگیری ماشین است که بر اساس شبکه‌های عصبی مصنوعی ساخته شده است. در سال‌های اخیر معماری‌های یادگیری عمیق مانند شبکه‌های عصبی عمیق، شبکه‌های عصبی بازگشتی و شبکه‌های عصبی کانولوشن و دیگر معماری‌های جدید در زمینه‌هایی از جمله بینایی کامپیوتر، تشخیص گفتار، پردازش زبان طبیعی، پردازش سیگنال، بیوانفورماتیک، طراحی دارو و پزشکی استفاده شده است. در ادامه توضیح مختصری از هر کدام آورده شده است.

شبکه عصبی عمیق: این شبکه در واقع یک نسخه پیشرفته از شبکه عصبی مصنوعی است که به منظور تقلید از عملکرد نرون‌های مغز انسان برای یادگیری طراحی شده است. شبکه عصبی مصنوعی پایه از سه لایه اصلی تشکیل شده است: لایه ورودی، لایه پنهان، و لایه خروجی. این شبکه ورودی‌ها را با استفاده از وزن‌هایی که لایه‌ها را به هم متصل می‌کنند به خروجی مناسب نگاشت می‌دهد، و خروجی به عنوان تابعی از ورودی‌ها محاسبه می‌شود. رابطه (۲) نحوه عملکرد یک شبکه عصبی مصنوعی ساده را نمایش می‌دهد.

$$output = f\left(\sum_i^n (w_i * x_i)\right) \quad (2)$$

ابرفصله جداکننده عمل می‌کند که بیش‌ترین فاصله بین نمونه‌های هر کلاس را فراهم می‌کند. ابتدا برای پیدا کردن مرزهای خطی بین کلاس‌ها معرفی شد، اما با استفاده از توابع کرنل، قابلیت یافتن مرزهای غیرخطی را نیز دارد و در مسائل پیچیده با فضای ویژگی‌های بالا به خوبی عمل می‌کند [۱۶ و ۱۵].

درخت تصمیم^۱: این روش داده‌های آموزشی را به صورت سلسله‌مراتبی تقسیم می‌کند. بر اساس مقدار ویژگی‌های مختلف، داده‌ها به گونه‌ای تقسیم می‌شوند که جداسازی بین کلاس‌ها به حداکثر برسد و داده‌ها در گره‌های برگ قرار گیرند. یکی از مشکلات درخت‌های تصمیم، احتمال بیش‌برازش است که باعث کاهش عمومیت مدل می‌شود [۱۷ و ۱۶].

رگرسیون لجستیک^۲: علی‌رغم نام آن، این روش برای طبقه‌بندی به کار می‌رود. در اینجا احتمال عضویت هر داده در کلاس‌های مختلف محاسبه شده و نمونه به کلاسی که بیش‌ترین احتمال را دارد نسبت داده می‌شود [۱۵].

جنگل تصادفی^۳: این الگوریتم از یادگیری دسته‌ای بهره می‌برد و از مجموعه‌ای از درخت‌های کم‌عمق برای ایجاد مدل نهایی استفاده می‌کند. هر درخت به طور مستقل روی یک نمونه برداری تصادفی از داده‌ها آموزش می‌بیند و نتیجه نهایی از طریق رأی‌گیری اکثریت درخت‌ها تعیین می‌شود. این روش به دلیل مقاومت در برابر داده‌های نویزی و نامتوازن، عملکرد خوبی دارد [۱۷].

روش Bagging: یک روش یادگیری دسته‌ای است که چندین مدل پیش‌بینی کننده را به طور مستقل آموزش داده و نتایج آن‌ها را ترکیب می‌کند تا واریانس مدل کاهش یابد. Random Forest یکی از کاربردهای معروف این روش است [۱۸].

روش XGBoost: یک روش تقویت کننده گرادین درختی است که برای مسائل دسته‌بندی و رگرسیون به کار می‌رود. این الگوریتم از تنظیم گر برای جلوگیری از بیش‌برازش، هرس درخت‌ها برای بهینه‌سازی عملکرد، و پردازش موازی برای افزایش سرعت استفاده می‌کند. XGBoost به دلیل سرعت بالا و دقت قابل توجه در مسائل

⁴ Ensemble Learning

⁵ AdaBoost

¹ Decision Tree

² Logistic Regression

³ Random Forest

الگوهای موجود در داده‌های تصویر را یاد بگیرند و شناسایی کنند. خروجی لایه‌های کانولوشن برای کاهش ابعاد و پیچیدگی به لایه پولینگ و سپس به یک سری لایه‌های کاملاً متصل منتقل می‌شود که وظایف طبقه‌بندی یا رگرسیون را بر اساس ویژگی‌های استخراج‌شده انجام می‌دهند. لایه‌های کانولوشنی در انواع یک‌بعدی برای پردازش بردار، دوبعدی برای پردازش تصویر و سه‌بعدی برای پردازش ویدئو طراحی شده‌اند. شبکه‌های عصبی کانولوشنی یک‌بعدی (1D CNNs) نوعی از شبکه‌های عصبی هستند که برای پردازش داده‌های یک‌بعدی مانند سری‌های زمانی یا سیگنال‌های صوتی و پزشکی استفاده می‌شوند. این شبکه‌ها با استفاده از فیلترهای کانولوشنی، الگوهای محلی را در داده‌ها شناسایی می‌کنند و سپس با ترکیب این الگوها، ویژگی‌های سطح بالاتر را استخراج می‌کنند. به زبان ساده مانند یک ذره‌بین عمل می‌کنند که الگوهای کوچک و مهم را در داده‌های ترتیبی پیدا می‌کنند [۲۰ و ۳]. جدول (۳) لایه‌های معماری شبکه عصبی کانولوشنی طراحی شده را نشان می‌دهد.

جدول (۳): نمایی از لایه‌های معماری شبکه عصبی کانولوشنی طراحی شده

نوع لایه	شکل خروجی	تعداد پارامترها
conv1d (Conv1D)	(None, 182, 32)	۲۲۴
max_pooling1d (MaxPooling1D)	(None, 91, 32)	۰
conv1d_1 (Conv1D)	(None, 89, 64)	۶۲۰۸
max_pooling1d_1 (MaxPooling1D)	(None, 45, 64)	۰
conv1d_2 (Conv1D)	(None, 44, 32)	۴۱۲۸
max_pooling1d_2 (MaxPooling1D)	(None, 22, 32)	۰
flatten (Flatten)	(None, 704)	۰
dense_0 (Dense)	(None, 100)	۷۰۵۰۰
dense_1 (Dense)	(None, 50)	۵۰۵۰
dense_2 (Dense)	(None, 5)	۲۵۵

LSTM آورده شده است. این شبکه‌ها با استفاده از مکانیسم‌های پیچیده‌ای، قادر به حفظ و مدیریت اطلاعات در طول زمان هستند. یکی از اجزای کلیدی در LSTM، سلول حافظه است که به عنوان مخزنی برای اطلاعات طولانی‌مدت عمل می‌کند. این سلول،

با افزایش تعداد لایه‌های پنهان، شبکه عصبی عمیق ایجاد می‌شود. تمام لایه‌های مورد استفاده در این شبکه، لایه کاملاً متصل هستند که دارای تعداد بسیار زیاد پارامتر برای تنظیم شدن هستند [۴ و ۳]. لایه‌های معماری شبکه عصبی عمیق طراحی شده طی فرآیند اعتبارسنجی متقابل^۱ در این پژوهش در جدول (۲) آورده شده است

شده

نوع لایه	شکل خروجی	تعداد پارامترها
dense_0 (Dense)	(None, 128)	۲۴۰۶۴
dense_1 (Dense)	(None, 64)	۸۲۵۶
dense_2 (Dense)	(None, 5)	۳۲۵

شبکه عصبی کانولوشنی: نوعی معماری شبکه عصبی است که معمولاً در یادگیری عمیق برای تشخیص تصویر و ویدئو استفاده می‌شود. این شبکه از ترکیب سه لایه کانولوشن، لایه پولینگ و لایه کاملاً متصل تشکیل شده است، برای شناسایی و استخراج خودکار ویژگی‌ها از تصاویر با اعمال یک سری فیلترهای کانولوشنی بر روی تصویر ورودی طراحی شده‌اند که به آن‌ها امکان می‌دهد

شبکه عصبی بازگشتی^۲: شبکه‌های عصبی بازگشتی، به عنوان یکی از پیشرفته‌ترین معماری‌های شبکه‌های عصبی، به طور خاص برای پردازش داده‌های ترتیبی طراحی شده‌اند. LSTM یکی از پرکاربردترین شبکه‌های بازگشتی است. در شکل (۳) نمایی از لایه

² Recurrent Neural Network (RNN)

¹ Cross validation

جدول (۴): نمایی از لایه‌های معماری شبکه عصبی بازگشتی طراحی


شده

نوع لایه	شکل خروجی	تعداد پارامترها
Lstm (LSTM)	(None, 187, 50)	۱۰۴۰۰
dropout (Dropout)	(None, 187, 50)	۰
lstm_1 (LSTM)	(None, 187, 50)	۲۰۲۰۰
dropout_1 (Dropout)	(None, 187, 50)	۰
flatten (Flatten)	(None, 9350)	۰
dense_0 (Dense)	(None, 32)	۲۹۹۲۳۲
dense_1 (Dense)	(None, 5)	۱۶۵

ترنسفورمر^۱: ترنسفورمرها، انقلابی در حوزه یادگیری عمیق ایجاد کردند. ترنسفورمرها، که در ابتدا برای پردازش زبان طبیعی توسعه یافتند، اکنون در سایر کاربردها از جمله پردازش سیگنال مورد استفاده قرار می‌گیرند. ترنسفورمرها از دو بخش اصلی به نام‌های رمزگذار^۲ و رمزگشا^۳ تشکیل شده‌اند. بلوک رمزگذار مسئول پردازش ورودی‌ها و تولید بازنمایی‌های داخلی است. این بلوک شامل لایه‌های توجه چندسره^۴ و شبکه‌های پیش‌خور موضعی است که به ترتیب پردازش می‌شوند. این ترکیب به مدل کمک می‌کند تا ویژگی‌های پیچیده‌ای از ورودی‌ها استخراج شود. بلوک رمزگشا مسئول تولید خروجی‌ها بر اساس بازنمایی‌های داخلی تولید شده توسط رمزگذار است. این بلوک نیز شامل لایه‌های توجه چندسره و شبکه‌های پیش‌خور موضعی است. علاوه بر این، بلوک رمزگشا به بازنمایی‌های تولید شده توسط رمزگذار نیز توجه می‌کند تا اطلاعات ورودی را به خروجی مرتبط تبدیل کند.

مفهوم توجه چندسره، خود از تعدادی لایه توجه به خود^۵ تشکیل شده است. هر یک از این لایه‌ها میزان توجه و ارزش‌گذاری بر روی قسمت‌های مختلف ورودی را با استفاده از سه ماتریس پرسش^۶، کلید^۷ و ارزش^۸ متفاوت انجام داده و یک بازنمایی منحصر به فردی از ورودی را ایجاد می‌کنند. بازنمایی‌های مختلف به دست آمده از لایه‌های خود توجه با هم ترکیب شده تا بازنمایی قوی‌تر از ویژگی‌ها به دست آید. در ادامه با اضافه کردن لایه‌های

اطلاعات را در طول گام‌های زمانی منتقل می‌کند و به شبکه اجازه می‌دهد تا وابستگی‌های بلندمدت را یاد بگیرد.



شکل (۳): نمایی از لایه LSTM [۳]

برای کنترل جریان اطلاعات در سلول حافظه، LSTM از سه گیت ورودی، فراموشی و خروجی استفاده می‌کند. یکی از مهم‌ترین این گیت‌ها، گیت فراموشی است. این گیت تصمیم می‌گیرد که کدام اطلاعات از سلول حافظه باید حذف شوند. به عبارت دیگر، گیت فراموشی تعیین می‌کند که شبکه چه اطلاعاتی را دیگر نیاز ندارد و می‌تواند آن‌ها را فراموش کند. این مکانیسم به شبکه کمک می‌کند تا فقط اطلاعات مرتبط و مهم را حفظ کند و از بار اضافی اطلاعات غیرضروری جلوگیری کند. با ترکیب سلول حافظه و گیت‌های کنترلی، LSTM قادر به یادگیری الگوهای پیچیده در داده‌های ترتیبی است و در کاربردهای متنوعی مانند پردازش سیگنال به کار می‌رود [۲۰ و ۳]. رابطه (۳) نحوه عملکرد لایه LSTM موجود در شکل (۳) را بیان می‌کند. در این رابطه h نشان‌دهنده اطلاعات مرحله قبلی، b بایاس و C سلول حافظه است. در ادامه جدول (۴) لایه‌های معماری شبکه عصبی بازگشتی طراحی شده در این پژوهش را نشان می‌دهد.

$$\begin{aligned}
 i_t &= \sigma(W_{xi}X_t + W_{hi}h_{t-1} + b_i) \\
 f_t &= \sigma(W_{xf}X_t + W_{hf}h_{t-1} + b_f) \\
 o_t &= \sigma(W_{xo}X_t + W_{ho}h_{t-1} + b_o) \\
 C'_t &= \tanh(W_{xc}X_t + W_{hc}h_{t-1} + b_c) \\
 C_t &= f_t \cdot C_{t-1} + i_t \cdot C'_t \\
 h_t &= o_t \cdot \tanh(C_t)
 \end{aligned} \quad (3)$$

⁵ Self-Attention

⁶ Query(Q)

⁷ Key(K)

⁸ Value(V)

¹ Transformer

² Encoder

³ Decoder

⁴ Multi-Head Attention

مدل‌های ترنسفورمر با استفاده از مکانیسم توجه، قادر به مدل‌سازی وابستگی‌های پیچیده و طولانی‌مدت بین عناصر داده هستند. برخلاف شبکه‌های عصبی بازگشتی که به صورت متوالی داده‌ها را پردازش می‌کنند، ترنسفورمرها می‌توانند به صورت موازی عمل کنند، که این امر منجر به افزایش سرعت و کارایی در پردازش داده‌ها می‌شود. توانایی ترنسفورمرها در درک روابط معنایی و ساختاری در داده‌ها، آن‌ها را به ابزاری قدرتمند تبدیل کرده است [۲۱]. جدول (۵) معماری ترنسفورمر مورد استفاده در این پژوهش را نشان می‌دهد.

جدول (۵): نمایی از لایه‌های معماری ترنسفورمر مورد استفاده شده

نوع لایه	شکل خروجی	تعداد پارامترها
input_layer (InputLayer)	(None, 187, 1)	۰
add (Add)	(None, 187, 64)	۰
transformer_encoder_0 (TransformerEncoder)	(None, 187, 64)	۸۳۲۰۰
transformer_encoder_1 (TransformerEncoder)	(None, 187, 64)	۸۳۲۰۰
transformer_encoder_2 (TransformerEncoder)	(None, 187, 64)	۸۳۲۰۰
global_average_pooling1d (GlobalAveragePooling1D)	(None, 64)	۰
dense_0 (Dense)	(None, 5)	۳۲۵

این صورت که لایه اول خروجی‌های خود را به لایه دوم ارسال می‌کند، لایه دوم به لایه سوم و این فرآیند تا لایه آخر و لایه امتیازدهی ادامه دارد. برخلاف شبکه‌های معمولی، در شبکه‌های عصبی گرافی، انتشار اطلاعات به طور هم‌زمان در تمام گره‌های گراف صورت می‌گیرد. یعنی هیچ گره یا لایه ابتدایی برای آغاز فرآیند انتشار وجود ندارد. این کار با به‌روزرسانی اطلاعات هر گره به تعداد دفعات از پیش تعیین‌شده‌ای انجام می‌شود. ارزش جدید هر گره تحت تأثیر اطلاعات خود گره و هم‌چنین گره‌هایی که با آن یال مشترک دارند، یعنی همسایگانش، قرار می‌گیرد. به‌این‌ترتیب، هر گره برای به‌روزرسانی اطلاعات خودش از اطلاعات همسایگان خود نیز بهره می‌برد تا نمایشی غنی‌تر و دقیق‌تر از گراف ایجاد کند. در ادامه اطلاعات به دست آمده به

پیش‌خور، بازنمایی‌های تولید شده به خروجی مناسب نگاشت می‌شوند. رابطه (۴) نحوه عملکرد توجه چندسر در معماری ترنسفورمر را نمایش می‌دهد.

$$head_i = Attention(QW^Q, KW^K, VW^V) \\ = Softmax \left[\frac{QW_i^Q (KW_i^K)^T}{\sqrt{(d_k)}} \right] VW_i^V \quad (4) \\ MultiHead(Q, K, V) = \\ concat(head_1, head_2, \dots, head_h)W_o$$

شبکه عصبی گرافی^۱: این شبکه‌ها به عنوان ابزاری قدرتمند برای تحلیل داده‌های ساختاریافته در قالب گراف، ظهور کرده‌اند. گراف‌ها ساختارهای داده‌ای متشکل از گره‌ها (نقاط) و یال‌ها (اتصالات) هستند که در زمینه‌هایی مانند تحلیل شبکه‌های اجتماعی، کشف دارو، پیش‌بینی رفتار مولکولی و پردازش سیگنال کاربردهای گسترده‌ای دارند. در پردازش سیگنال، جایی که روابط و وابستگی‌های بین بخش‌های مختلف داده اهمیت بالایی دارد، GNN ها با مدل‌سازی این ارتباطات قادر به شناسایی الگوهای پیچیده و پنهان و استخراج ویژگی‌های دقیق‌تر هستند [۲۲].

انواع مختلفی از مسائلی از جمله تجزیه و تحلیل سیگنال ECG که قابل تبدیل به گره و یال باشند را می‌توان با گراف‌ها و شبکه‌های عصبی گرافی حل کرد. در شبکه‌های عصبی معمولی یک ترتیبی برای انتشار اطلاعات داده ورودی در طول شبکه وجود دارد. به

¹ Graph Neural Network (GNN)

از هر سیگنال ECG هستند. اعداد روی یال‌ها بیانگر میزان شباهت یا نزدیکی بین دو نمونه سیگنال ECG هستند که با استفاده از فاصله اقلیدسی محاسبه شده‌اند. یال‌ها بین گره‌هایی رسم می‌شوند که فاصله اقلیدسی بین بردارهای ویژگی آن‌ها کمتر از یک مقدار آستانه مشخص باشد. در این پژوهش مقدار آستانه ۰/۵ در نظر گرفته شده است. نحوه محاسبه فاصله اقلیدسی و تشکیل یال بین دو گره i و j با تعداد k ویژگی در رابطه (۵) آورده شده است.

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^{187} (x_{ik} - x_{jk})^2} \quad (5)$$

در این پژوهش، تحلیل و پیمایش بر روی گراف شکل (۴) با استفاده از معماری GCN انجام می‌شود. همان‌طور که قبلاً گفته شد، برخلاف شبکه‌های عصبی معمولی که اطلاعات را به صورت ترتیبی از لایه‌ای به لایه دیگر منتقل می‌کنند، GCN از یک فرآیند پیام‌رسانی استفاده می‌کند. در این فرآیند، هر گره به طور هم‌زمان اطلاعات خود و همسایگانش را در طول یال‌های گراف جمع‌آوری و ترکیب می‌کند تا نمایش غنی‌تر و آگاه از ساختار محلی گراف از خود به دست آورد. به صورت مفهومی، در هر لایه از GCN، دو عملیات اصلی تجمیع^۴ و ترکیب^۵ صورت می‌گیرد. در مرحله تجمیع، هر گره اطلاعات (ویژگی‌های) همسایگان متصل به خود را جمع‌آوری می‌کند. در مرحله ترکیب، اطلاعات تجمیع شده از همسایگان، با ویژگی‌های فعلی خود گره ترکیب شده و سپس از طریق یک تبدیل خطی (با وزن‌های قابل یادگیری) و یک تابع فعال‌سازی غیرخطی عبور می‌کند تا ویژگی‌های به‌روز شده گره برای لایه بعدی به دست آید. این مراحل در فرآیند آموزش و طی تعداد دفعات از پیش تعیین‌شده تکرار می‌شود تا اطلاعات گره‌ها جامع‌تر شود. رابطه (۶) نمایش ساده‌ای از این دو مرحله را خلاصه کرده است.

$$Update(i) = Combine\left(i, \sum_{j \in N_i} m_{ij}\right) \quad (6)$$

⁴ Aggregation

⁵ Combination

شبکه پیش‌خور داده می‌شود تا در لایه امتیازدهی دسته‌بندی انجام شود.

انواع مختلفی از GNN‌ها توسعه یافته‌اند که هر کدام رویکردهای متفاوتی برای تجمیع و به‌روزرسانی اطلاعات گره‌ها دارند. از جمله شناخته‌شده‌ترین آن‌ها می‌توان به شبکه‌های گرافی کانولوشنی^۱ (GCN)، شبکه‌های گرافی مبتنی بر توجه^۲ (GAT)، که وزن‌های مختلفی به همسایگان می‌دهند، و شبکه گرافی نمونه‌برداری و تجمیع^۳ (GraphSAGE)، که بر روی نمونه‌برداری از همسایگان تمرکز دارد، اشاره کرد. در میان این انواع، GCN به دلیل سادگی معماری، کارایی محاسباتی و توانایی اثبات‌شده در یادگیری نمایش‌های مفید از داده‌های گرافی، به طور گسترده مورد استفاده قرار می‌گیرد. GCN تعادلی مطلوب بین قدرت بیانی و پیچیدگی مدل فراهم می‌کند و برای مدل‌سازی روابط محلی بر اساس ویژگی‌های گره‌ها و ساختار ثابت گراف بسیار مناسب است [۲۳]. در این پژوهش، GCN به عنوان هسته اصلی تحلیل بر روی داده‌های ECG مدل‌سازی شده به صورت گراف انتخاب شده است.

در پژوهش جاری، هدف اصلی از تبدیل سیگنال‌های ECG به یک ساختار گرافی، بهره‌برداری از روابط و شباهت‌های پنهان بین نمونه‌های مختلف سیگنال ECG است که با روش‌های سنتی طبقه‌بندی (که هر نمونه را مستقل از دیگری در نظر می‌گیرند) قابل‌شناسایی نیستند. این مدل‌سازی گرافی به ما امکان می‌دهد تا اطلاعات تشخیصی غنی‌تری را با لحاظ کردن زمینه و همسایگی هر سیگنال در فضای ویژگی‌ها استخراج کنیم. به عنوان مثال، یک سیگنال ECG مبهم ممکن است با بررسی سیگنال‌های مشابه خود در گراف، بهتر تشخیص داده شود، که این امر به افزایش دقت و پایداری سیستم تشخیص کمک می‌کند.

شکل (۴) گرافی است که به منظور مدل‌سازی روابط بین نمونه‌های سیگنال ECG ساخته شده است. هر گره در این گراف نمایش‌دهنده یک نمونه سیگنال ECG است که دارای ۱۸۷ ویژگی است. این ۱۸۷ ویژگی در واقع ۱۸۷ مقدار ولتاژ نمونه‌برداری شده

¹ Graph Convolutional Network (GCN)

² Graph Attention Network (GAT)


³ Graph Sample and Aggregate (GraphSAGE)

نرمال شده است، $W(l)$ ماتریس وزن‌های قابل یادگیری برای لایه 1 است که در طول فرآیند آموزش بهینه می‌شوند، و σ تابع فعال‌سازی غیرخطی است. این عملیات کانولوشن گرافنی، ویژگی‌های هر گره را بر اساس همسایگانش به‌روزرسانی می‌کند. پس از چندین لایه از این به‌روزرسانی، خروجی نهایی GCN (نمایش‌های یادگرفته‌شده گره‌ها) به عنوان ورودی به یک لایه امتیازدهی داده می‌شود تا برچسب کلاس مربوط به هر سیگنال ECG پیش‌بینی گردد.

ورودی اصلی به هسته مدل GCN شامل دو جزء است، ماتریس ویژگی گره‌ها (X) که هر سطر آن یک بردار ویژگی ۱۸۷ بعدی برای هر نمونه ECG است، و ماتریس مجاورت (A) که ساختار اتصالات بین گره‌ها را بر اساس فواصل اقلیدسی و آستانه نشان می‌دهد. این دو ماتریس مستقیماً به GCN وارد می‌شوند. رابطه (۷) به‌روزرسانی ویژگی‌های گره‌ها در یک لایه از GCN را نشان می‌دهد.

$$H(l+1) = \sigma \left(D^{\frac{-1}{2}} A D^{\frac{-1}{2}} H(l) W(l) \right) \quad (\forall)$$

در این رابطه $H(l)$ ماتریس ویژگی های گره ها در لایه l ، $D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$ مسئول تجمع اطلاعات از همسایگان یک گره به صورت



شکل (۴): نمایی از ساختار گرافی سیگنال ECG (هر گره به صورت شماره نمونه و برچسب نمونه آورده شده است. منظور از عنوان گره (۱) ۳ نمونه چهارم و کلاس آن با برچسب ۱ است).

کلاس سالم و از ۱ تا ۴ برای بیماری‌های قلبی) است. اعداد روی یال‌ها نیز بیانگر فاصله اقلیدسی (میزان شباهت) بین نمونه‌های ECG متصل است، که نشان‌دهنده نزدیکی آن‌ها در فضای ویژگی است.

شکل (۴) نمایی از گراف ساخته شده با ۱۰ نمونه سیگنال ECG را نمایش می‌دهد. در این شکل هر گره به صورت $N(c)$ نمایش داده شده است. نماد N بیانگر شماره نمونه سیگنال ECG است که در این شکل از اعداد ۰ تا ۹ متغیر است. نماد c کلاس مربوط به آن نمونه سیگنال ECG است و مقادیرش از ۰ تا ۴ (عدد ۰ برای

۵- شبیه‌سازی و ارائه نتایج

برای بررسی نتایج روش پیشنهادی، ابتدا طبق شکل (۲) مراحل روش کار بر روی پایگاه داده MIT-BIH انجام شده است. برای این منظور ابتدا ویژگی‌های پایگاه داده نرمال شده است تا همه ویژگی‌ها در یک دامنه قرار بگیرند، مشکل مقادیر ویژگی‌های خالی و گم شده ویژگی‌ها با روش مدگیری رفع شده است و مساله نامتوازن بودن کلاس‌ها با روش Smote حل شده است. سپس داده‌ها برای استفاده در روش‌های یادگیری ماشین به دو بخش داده آموزش و آزمایش و در مدل‌های یادگیری عمیق به سه بخش داده آموزش، اعتبارسنجی و آزمایش تقسیم شده است. در نهایت دسته‌بندی داده‌ها با استفاده از روش‌های یادگیری ماشین و مدل‌های یادگیری عمیق ذکر شده، انجام شده است. مدل‌های یادگیری عمیق طی ۲۰ بار تکرار آموزش داده شده‌اند. مقادیر هایپرپارامترهای معماری‌های یادگیری عمیق در جدول (۶) آورده شده است. نتایج آزمایش‌ها با استفاده از اعتبارسنجی متقابل ۵ تایی و بر اساس معیارهای ارزیابی مختلف بررسی شده است.

جدول (۶): هایپرپارامترهای معماری‌های یادگیری عمیق

مقدار	هایپرپارامتر
۲۰	تعداد تکرار
Adam	بهینه‌ساز
۳۲	سایز دسته
۰,۰۰۱	نرخ یادگیری
Categorical cross entropy	تابع هزینه
۱۳۵ دقیقه	زمان آموزش (مدل ترکیبی)
۱۲ میلی‌ثانیه	زمان آزمایش


۴-۱ معیارهای ارزیابی

برای ارزیابی روش پیشنهادی از معیارهای دقت، صحت، فراخوان و معیار F1 موجود در جدول (۷) استفاده شده است [۳].

جدول (۷): معیارهای ارزیابی مختلف

معیار ارزیابی	رابطه
دقت (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$
صحت (Precision)	$P = \frac{TP}{TP + FP}$

مدل ترکیبی^۱ در این پژوهش طبقه‌بندی بیماری آریتمی قلبی با استفاده از معماری‌های یادگیری عمیق طراحی شده هم به صورت تکی و هم به صورت ترکیب سه معماری برتر انجام شده است. شکل (۵) ساختار مدل یادگیری عمیق ترکیبی پیشنهادی را نشان می‌دهد. در این مدل ترکیبی، داده‌های سیگنال ECG به صورت هم‌زمان و در سه انشعاب موازی با هم به لایه‌های سه معماری برتر CNN، RNN و Transformer طراحی شده، داده شده است. در ادامه خروجی لایه‌های نهایی از هر سه مدل یادگیری عمیق تکی با استفاده از لایه concatenate به یکدیگر ادغام شده‌اند. در نهایت کلاس هر نمونه سیگنال با استفاده از ویژگی‌های ادغام شده و پس از گذر از لایه امتیازدهی مشخص شده است. لایه امتیازدهی از نوع SoftMax است و با تعداد ۵ نرون برای طبقه‌بندی سیگنال‌های ECG در ۵ گروه، یک گروه افراد سالم و ۴ گروه از انواع بیماری‌های قلبی طراحی شده است. در این مدل ترکیبی، مدل CNN با شناسایی و استخراج الگوهای محلی و روابط مکانی میان ویژگی‌های سیگنال ECG، معماری (LSTM)RNN با شناسایی وابستگی‌های زمانی میان سیگنال ECG و معماری ترنسفورمر با شناسایی ارتباطات طولانی، پیچیده و غیرخطی بین نقاط مختلف سیگنال‌های ECG به طور مکمل و چندوجهی عمل کردند.



شکل (۵): ساختار مدل یادگیری عمیق ترکیبی پیشنهادی

¹ Hybrid model

مختلف یادگیری ماشین، و از کتابخانه TensorFlow برای طراحی معماری‌های یادگیری عمیق پیشنهادی استفاده شده است. اجرای تمام کدها با استفاده از T4 GPU و در بستر Colab انجام شده است. نتایج تجربی حاصل از طبقه‌بندهای مختلف یادگیری ماشین و یادگیری عمیق پژوهش جاری به ترتیب در جدول (۸) و (۹) آورده شده است.

جدول (۸): نتایج به دست آمده از طبقه‌بندهای مختلف یادگیری ماشین

مدل	Logistic Regression	Decision Tree	SVM	Random Forest	Adaboost	Bagging	XGBoost
دقت	۶۵/۵۲	۹۳/۸۳	۹۶/۸	۸۵/۹۲	۸۶/۵	۹۶/۵۶	۹۶/۹۵
صحت	۸۸/۰۵	۹۴/۸۵	۹۶/۷۶	۷۸/۰۸	۸۴/۷۵	۹۶/۶۴	۹۷/۲
فراخوان	۶۵/۵۸	۹۳/۸	۹۶/۸۳	۸۵/۸۶	۸۶/۴۵	۹۶/۵۲	۹۶/۸۹
امتیاز F1	۷۲/۲۵	۹۴/۳۲	۹۶/۵۸	۸۰/۵۶	۸۴/۹۹	۹۶/۵۹	۹۷/۱۴

جدول (۹): نتایج به دست آمده از معماری‌های مختلف یادگیری عمیق

معماری یادگیری عمیق	1-DNN (model1)	1D CNNs (model2)	RNN (model3)	Transformer (model4)	GCN (model5)	Hybrid model (model(2,3,4))
دقت	۹۵/۷۶	۹۵/۷۸	۹۵/۸۵	۹۶/۵۱	۹۵/۶۱	۹۷/۷۷
صحت	۹۵/۷	۹۵/۹۴	۹۵/۹۸	۹۷/۱۳	۹۵/۵۹	۹۷/۸۸
فراخوان	۹۵/۷۳	۹۵/۸۱	۹۵/۸۳	۹۶/۵۵	۹۵/۷۱	۹۷/۷۵
امتیاز F1	۹۵/۷۱	۹۵/۸۴	۹۵/۹۱	۹۶/۷۵	۹۵/۳۴	۹۷/۸۱

عملکرد مناسب‌تری دارد. سیگنال‌های ECG ذاتاً ماهیت زمانی دارند و تشخیص بیماری‌های آریتمی قلبی اغلب به الگوها و تغییراتی بستگی دارد که ممکن است در فواصل زمانی نسبتاً دور از هم در سیگنال رخ دهند. معماری ترنسفورمر با توجه به مکانیسم خود-توجهی می‌تواند این وابستگی‌های طولانی را در سرتاسر نقاط سیگنال به صورت موازی و بدون رویارویی با مشکل محوشدگی یا انفجار گرادیان مدل کند. معماری ترنسفورمر هم‌چنین دارای یادگیری سلسله مراتبی ویژگی‌ها (ویژگی‌های محلی در لایه‌های پایین‌تر و الگوهای کلی و انتزاعی در لایه‌های بالاتر) و انعطاف‌پذیری در توجه به بخش‌های مهم سیگنال است. این موارد باعث شده تا معماری مذکور بتواند الگوهای ظریف و پیچیده مرتبط با انواع بیماری‌های آریتمی قلبی را بهتر شناسایی کرده و در نتیجه عملکرد تشخیص را بهبود بخشد. در این پژوهش علاوه بر معماری‌های یادگیری عمیق به صورت تکی، یک مدل ترکیبی حاصل از ادغام سه مدل یادگیری عمیق برتر

با توجه به نتایج به دست آمده از جدول (۸) می‌توان دریافت که از میان طبقه‌بندهای یادگیری ماشین، روش XGBoost عملکرد بهتری نسبت به دیگر طبقه‌بندها داشته است. این الگوریتم قدرتمند بر پایه درخت‌های تصمیم بنا شده و از تکنیک تقویت گرادیان برای دستیابی به دقت و کارایی بالا بهره می‌برد. عملکرد برتر XGBoost را می‌توان به ویژگی‌هایی نظیر استفاده از گرادیان بوستینگ، تکنیک‌های منظم‌سازی برای جلوگیری از بیش‌برازش، قابلیت مدیریت داده‌های گمشده و پردازش موازی کارآمد نسبت داد.

از روی جدول (۹) هم‌چنین می‌توان دریافت که روش‌های یادگیری عمیق با استخراج خودکار ویژگی‌های سطح بالا از روی داده‌ها عملکرد برتری نسبت به طبقه‌بندهای یادگیری ماشین دارند. هم‌چنین از میان معماری‌های یادگیری عمیق مذکور در این پژوهش، معماری ترنسفورمر با توجه به پیوستگی اطلاعات موجود در سیگنال ECG نسبت به دیگر معماری‌های یادگیری عمیق

تنظیمات هایپرپارامترهای مدل قرار گیرد. بنابراین هیچ تضمینی برای حفظ این سطح از عملکرد در تمامی شرایط وجود ندارد. در کل ارزیابی دقیق روش‌ها همراه با نظر گرفتن اطلاعات زمینه بالینی، در تفسیر نهایی نتایج همواره حائز اهمیت است.

در ادامه مقایسه روش پیشنهادی با سایر مقالات انجام شده بر روی پایگاه داده MIT-BIH در جدول (۱۰) آورده شده است. نتایج جدول مذکور نیز نشان می‌دهد که روش یادگیری عمیق ترکیبی پیشنهادی توانسته با ادغام ویژگی‌های چندگانه و مدل‌سازی وابستگی‌های محلی و زمانی پیچیده در تحلیل سیگنال‌های ECG عملکرد بهتر و دقیق‌تری در تشخیص آریتمی قلبی نسبت به سایر روش‌های انجام شده داشته باشد.

جدول (۱۰): مقایسه روش پیشنهادی با دیگران

F1-score	Recall	Precision	Accuracy	مقاله
۹۵	۹۱/۴	۹۹/۱	۹۴/۵	شبکه Autoencoder [۲]
۸۷/۶	۹۳	۸۳/۴	۹۷/۶	شبکه CNN [۲۴]
۹۳/۴۹	۹۴	۹۳	۹۷	شبکه CNN [۲۵]
۸۷/۱	۸۵	۸۹/۱۵	۸۹/۳	جنگل تصادفی [۲۶]
۹۵/۶	۹۵/۵	۹۵/۸	۹۶/۲	شبکه عصبی گرافی [۲۷]
۹۱/۸	۹۱/۵	۹۲/۱	۹۴/۷	شبکه Autoencoder [۲۸]
۹۲/۳	۸۷/۱	۹۸/۲	۸۹/۵	شبکه ترنسفورمر [۲۹]
۹۷/۸۱	۹۷/۵۵	۹۷/۸۸	۹۷/۷۷	روش پیشنهادی (مدل ترکیبی)

گرفته و عملیات نرمال‌سازی، حذف مقادیر خالی و رفع مشکل نامتعادل بودن پایگاه داده با روش Smote انجام شده است. در ادامه داده تقسیم‌بندی شده و در نهایت فرآیند آموزش و آزمایش بر روی داده‌های مربوطه انجام شده است. نتایج ارزیابی روش‌های مختلف نشان می‌دهد که روش یادگیری عمیق ترکیبی به دلیل ادغام ویژگی‌های محلی و مکانی با ویژگی‌های زمانی پیچیده که به دلیل ماهیت پیوستگی سیگنال ECG است، توانسته با مقدار میانگین دقت ۹۷/۷۷٪ و انحراف معیار ۰/۲، مقدار میانگین صحت ۹۷/۸۸٪ و انحراف معیار ۰/۱۴، مقدار میانگین فراخوان ۹۷/۷۵٪ و انحراف معیار ۰/۲ و میانگین معیار F1-score با مقدار ۹۷/۸۱٪ و انحراف معیار ۰/۱۶ بهترین عملکرد را داشته باشد.

(RNN، 1D CNNs و Transformer) به‌منظور بهره‌گیری از مزایای رویکردهای مختلف در استخراج ویژگی‌های سیگنال ECG طراحی شده است. این ترکیب به ما امکان می‌دهد تا به طور هم‌زمان ویژگی‌های محلی، متوالی و وابستگی‌های زمانی پیچیده را از سیگنال ECG استخراج کنیم، که هیچ یک از معماری‌های تکی به تنهایی قادر به انجام آن نبودند. نتایج تجربی ارزیابی‌ها در جدول (۹) نشان داد که این مدل ترکیبی با ادغام این قابلیت‌های متنوع، عملکرد بهتری در طبقه‌بندی سیگنال‌های ECG و تشخیص آریتمی‌های قلبی نسبت به معماری‌های تکی از خود نشان داده است. با این حال، شایان ذکر است که عملکرد این روش‌ها می‌تواند تحت تأثیر تغییراتی در توزیع و کیفیت داده‌های ورودی و هم‌چنین

۶- نتیجه‌گیری

شناسایی ناهنجاری و بیماری‌های مختلف قلبی با استفاده از الکتروکاردیوگرام امری رایج و ضروری توسط پزشکان متخصص قلب است. تجزیه و تحلیل درست و به‌موقع بیماری از روی سیگنال ECG باعث درمان زودهنگام، کاهش هزینه‌ها و افزایش طول عمر بیمار می‌شود. ورود هوش مصنوعی در این حوزه باعث افزایش دقت و سرعت تشخیص بیماری شده و پزشکان را در این مساله مهم یاری کرده است. از این رو، در این پژوهش هدف شناسایی بیماری‌های قلبی از روی سیگنال ECG با استفاده از هوش مصنوعی است. برای این منظور از انواع طبقه‌بندهای مختلف یادگیری ماشین و معماری‌های یادگیری عمیق استفاده شده است. ابتدا پایگاه داده معروف MIT-BIH طی مراحل پیش‌پردازش قرار

نیازمند زمان و تخصص بالاست و دسترسی به پایگاه‌های داده بزرگ و متنوع محدود است. در نهایت، درک و تفسیر نتایج مدل‌های هوش مصنوعی و ارتباط آن‌ها با وضعیت بالینی بیمار هم‌چنان نیازمند دخالت متخصصان پزشکی است و ابزار هوش مصنوعی به عنوان دستیار مورد استفاده قرار می‌گیرند. انجام اعتبارسنجی‌های بالینی دقیق و گسترده بر روی داده‌های متنوع قبل از کاربرد بالینی ضروری است. ادغام داده‌های ECG جمع‌آوری‌شده در شرایط جغرافیایی و سنی مختلف، از مراکز گوناگون و با روش‌های ضبط متفاوت، همراه با استفاده از روش‌های ترکیبی قوی‌تر برای افزایش تعمیم‌پذیری در برابر داده‌های جدید، می‌تواند گامی مهم جهت رفع محدودیت‌های ذکر شده و تشخیص بهتر بیماری‌های آریتمی قلبی باشد.

با توجه به نتایج امیدوارکننده پژوهش جاری، تشخیص آریتمی قلبی با استفاده از یادگیری ماشین و عمیق هنوز با چالش‌های متعددی در حوزه داده‌های ECG مواجه است. ضبط سیگنال‌های ECG به شدت مستعد نویز و مصنوعات ناشی از عوامل محیطی مانند حرکت بیمار، تداخلات الکتریکی و مشکلات تماس الکترودها هستند، که می‌توانند الگوهای بیماری را مخدوش کنند. علاوه بر این، تنوع قابل توجه در ویژگی‌های ECG بین افراد مختلف با موقعیت جغرافیایی و محدوده سنی متفاوت و حتی در طول زمان برای یک فرد به دلیل تغییرات فیزیولوژیکی، وضعیت بیماری و تنوع روش‌های ضبط سیگنال ECG، تعمیم‌پذیری مدل‌های آموزش‌دیده بر روی یک مجموعه داده خاص به جمعیت‌های دیگر یا داده‌های جدید را محدود می‌کند. هم‌چنین، جمع‌آوری داده‌های ECG با کیفیت و برچسب‌گذاری دقیق آن‌ها

References

- [1] D. G. Manuel, M. Leung, K. Nguyen, P. Tanuseputro and H. Johansen, "Burden of cardiovascular disease in Canada," Canadian Journal of Cardiology, Vol. 19, No. 9, pp. 997-1004, 2003.
- [2] S. Setayesh and M. A. Tabrazed, "Predicting Heart Attack by Detecting Abnormalities in ECG Data Using Deep Self-Encoding Network", National Conference on Artificial Intelligence and Software Engineering, 1402, pp. 1-6.
- [3] F. Z. Mehrjardi, A. M. Latif, M. S. Zarchi, and R. Sheikhpour, "A survey on deep learning-based image forgery detection," Pattern Recognition, vol. 144, 2024, doi: 10.1016/j.patcog.2023.109778.
- [4] F. Z. Mehrjardi, A. M. Latif, and M. S. Zarchi, "Copy-move forgery detection and localization using deep learning," International Journal of Pattern Recognition and Artificial Intelligence, Vol. 37, No. 9, 2023, doi: 10.1142/S0218001423520122.
- [5] B. Wang, X. Lyu, J. Qu, H. Sun, Z. Pan and Z. Tang, "GNDD: A graph neural network-based method for drug-disease association prediction," In IEEE International Conference on Bioinformatics and Biomedicine (BIBM), pp. 1253-1255, IEEE, 2019, doi: 10.1109/BIBM47256.2019.8983257.
- [6] U. R. Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan and M. Adam, "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals," Information sciences, Vol. 415, pp. 190-198, 2017, doi: 10.1016/j.ins.2017.06.027.
- [7] M. Vijayagopal, S. Muralidhara, N. Kashyap and P. Mendiratta, "Arrhythmia prediction and diagnosis using data analysis," NC State University, Raleigh, 2020.
- [8] F. Murat, O. Yildirim, M. Talo, Y. Demir, R. S. Tan, E. J. Ciaccio, and U. R. Acharya, "Exploring deep features and ECG attributes to detect cardiac rhythm classes," Knowledge-Based Systems, Vol. 232, 2021, doi: 10.1016/j.knosys.2021.107473.
- [9] H. V. Denysyuk, R. J. Pinto, P. M. Silva, R. P. Duarte, F. A. Marinho, L. Pimenta and I.M. Pires, "Algorithms for automated diagnosis of cardiovascular diseases based on ECG data: A comprehensive systematic review," Vol. 9, No. 2, 2023, 10.1016/j.heliyon.2023.e13601.
- [10] S. Sahoo, M. Dash, S. Behera and S. Sabut, "Machine learning approach to detect cardiac arrhythmias in ECG signals: A survey," Vol. 41, No. 4, pp.185-194, 2020, doi: 10.1016/j.irbm.2019.12.001.
- [11] C. Li, H. Zhao, W. Lu, X. Leng, L. Wang, X. Lin, and J. Xiang, "DeepECG: Image-based electrocardiogram interpretation with deep convolutional neural networks," Biomedical Signal Processing and Control, Vol. 69, 2021, doi: 10.1016/j.bspc.2021.102824.

- [12] S. Sattar, R. Mumtaz, M. Qadir, S. Mumtaz, M. A. Khan, T. De Waele and A. Shahid, "Cardiac Arrhythmia Classification Using Advanced Deep Learning Techniques on Digitized ECG Datasets," *Sensors*, Vol. 24, No. 8, 2024, doi: 10.3390/s24082484
- [13] M. A. Raza, M. Anwar, K. Nisar, A. A. A. Ibrahim, U. A. Raza, S. A. Khan, F. Ahmad "Classification of electrocardiogram signals for arrhythmia detection using convolutional neural network," *Computers, Materials and Continua*, Vol. 77, No. 3, pp. 3817-3834, 2023.
- [14] Z. F. M. Apandi, R. Ikeura and S. Hayakawa, "Arrhythmia detection using MIT-BIH dataset: A review," In *International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, pp. 1-5, 2018, doi: 10.1109/ICASSDA.2018.8477620.
- [15] J. Z. Ahmadabadi, F. Z. Mehrjardi, M. Ghanbary and M. Mirzaei, "Identification of Effective Factors and Prediction of Ischemic Heart Disease Using Machine Learning Methods and Data from the Yazd Health Study (YaHS)," *Journal of Shahid Sadoughi University of Medical Sciences*, Vol. 32, No. 7, pp. 67-79, 2024, doi: 10.18502/ssu.v32i7.16571.
- [16] F. Rustam, M. Khalid, W. Aslam, V. Rupapara, A. Mehmood and G.S. Choi, "A performance comparison of supervised machine learning models for Covid-19 tweets sentiment analysis," *Plos one*, Vol. 16, No. 2, 2021, doi: 10.1371/journal.pone.0245909.
- [17] S. Ray, "A quick review of machine learning algorithms," In *International conference on machine learning, big data, cloud and parallel computing (COMITCon)*, pp. 35-39, 2019, doi: 10.1109/COMITCon.2019.8862451.
- [18] H. Jafarzadeh, M. Mahdianpari, E. Gill, F. Mohammadimanesh and S. Homayouni, "Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and PolSAR data: a comparative evaluation," *Remote Sensing*, Vol. 13, No. 21, 2021, doi: 10.3390/rs13214405.
- [19] B. Mahesh, "Machine learning algorithms-a review," *International Journal of Science and Research (IJSR)*, Vol. 9, No. 1, pp. 381-386, 2020, doi: 10.21275/ART20203995.
- [20] S. M. Matinkhah, A. khakbaz, F. Adibnia, "Application of 'long-term-short-term memory' and 'convolutional neural networks' to detect distributed denial of service attacks," *Applied and Basic Machine Intelligence Research*, Vol. 2, No. 1, 2024, doi: 10.22034/ABMIR.2023.19764.1025.
- [21] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez and I. Polosukhin, "Attention is all you need," *Advances in neural information processing systems*, Vol. 30, 2017.
- [22] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," *arXiv preprint arXiv:1609.02907*, 2016, doi: 10.48550/arXiv.1609.02907.
- [23] D. Oniani, C. Wang, Y. Zhao, A. Wen, H. Liu and F. Shen, "Comparisons of graph neural networks on cancer classification leveraging a joint of phenotypic and genetic features," *arXiv preprint arXiv:2101.05866*, 2021.
- [24] M. Chourasia, A. Thakur, S. Gupta and A. Singh, "ECG heartbeat classification using CNN," In *IEEE 7th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, pp. 1-6, IEEE, 2020, doi: 10.1109/UPCON50219.2020.9376451
- [25] A. A. Ahmed, W. Ali, T. A. Abdullah and S. J. Malebary, "Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model," *Mathematics*, Vol. 11, No. 3, pp. 1-16, 2023, doi: 10.3390/math11030562.
- [26] C. G. Igiri, V. I. E. Anireh, N. D. Nwiabu, and D. Matthias, "Comparative analysis of supervised machine learning algorithms for ECG arrhythmia detection using small dataset," *International Journal of Computer Science and Mathematical Theory (IJCSMT)*, vol. 9, no. 4, pp. 23-44, 2023.
- [27] N. Pant, P. Singh, and R. Bera, "ECG-GraphNet: A graph neural network approach for electrocardiogram-based arrhythmia classification," *Biomedical Signal Processing and Control*, vol. 87, 105442, 2024.
- [28] M. S. Al Rahhal, Y. Bazi and H. AlHichri, "Deep learning approach for active classification of electrocardiogram signals," *Journal of Medical Systems*, vol. 44, no. 4, pp. 1-11, 2020.
- [29] H. Shi, H. Xu and M. Zhou, "Transformer-based anomaly detection for ECG signals," *Algorithms*, vol. 16, no. 4, 185, MDPI, 2023.

Multimodal analysis of ECG signals for cardiac arrhythmia detection using machine learning and deep learning methods

Motahareh Akbari Podineh¹, Fatemeh Zare Mehrjardi^{2*}, Mohsen Sardari Zarchi³

¹MSc. in Artificial Intelligence, Computer Engineering Department, Faculty of Technology and Engineering, Meybod University, Meybod, Yazd, Iran

²Assistant Professor, Computer Engineering Department, Faculty of Technology and Engineering, Meybod University, Meybod, Yazd, Iran

³Associate Professor, Computer Engineering Department, Faculty of Technology and Engineering, Meybod University, Meybod, Yazd, Iran

Article Information

Original Research Paper

Received:

2025 March 17

Accepted:

2025 August 16

Keywords:

Cardiac arrhythmia, ECG signal, machine learning, deep learning

Corresponding Author*:

fzare@meybod.ac.ir

Abstract

Cardiovascular diseases, such as cardiac arrhythmia, are considered the most common cause of death worldwide. Early detection of this type of heart disease increases patient quality of life, prolongs life, and reduces treatment costs. In this research, the goal is to identify cardiac arrhythmia from electrocardiogram using artificial intelligence tools. The proposed method consists of three stages: preprocessing, database partitioning, and data classification. First, in the preprocessing stage, operations such as data normalization, cleaning, and balancing of classes have been performed. Then, the processed database has been partitioned for training and testing operations. Finally, the data has been classified using various machine learning classifiers, deep learning architectures, and a hybrid model combining CNN, RNN, and Transformer architectures. The proposed method has been evaluated using the MIT-BIH database. Evaluation results showed that among machine learning models and various deep learning architectures, the hybrid model, by integrating local features obtained from the CNN architecture and identifying long and complex temporal dependencies by the RNN and Transformer architectures, is among the top classifiers. Ultimately, the findings emphasize the importance of integrating multiple features in ECG signal analysis for more accurate cardiac arrhythmia diagnosis and can be used in the development of more efficient automated diagnostic systems.

 : 10.22034/ABMIR.2025.22930.1118

E-ISSN: [2821-2037](#) /© 2025. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

