این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

Published by: Iranian Society for Biomedical Engineering / www.isbme.ir

Iranian Journal of Biomedical Engineering

www.ijbme.org / P-ISSN: 2008-5869 / E-ISSN: 8006-9685

Volume 18, Issue 4, Winter 2025, 399 - 408

Robust Feature Extraction from ECG Signals Using Normalized Cepstral Coefficients for Cardiac Arrhythmia Detection

Aslani, Shadi [1] / Marvi, Hossein [2*] / Kafaei, Mehdi [3]

[1] - MSC, Electronics, Shahrood University of technology, Shahrood, Iran
[2] - Associate Professor, Shahrood University of technology, Shahrood, Iran
[3] - Assistant Professor, Shahrood University of technology, Shahrood, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2025.2054411.1968
Received: 25/2/2025 Revised: 2/5/2025 Accepted: 15/5/2025

KEYWORDS

Cardiac Arrhythmia
Signal Processing
ECG Signal
CNN Network
Classification

ABSTRACT

Classification of electrocardiogram (ECG) signals is a crucial process in the diagnosis and treatment of cardiac abnormalities. ECG signals provide valuable information about the heart's condition, and classifying these signals as normal or abnormal plays a vital role in identifying and managing various cardiac disorders. In recent years, various feature extraction methods have been developed to enhance the accuracy and efficiency of automated ECG classification. This paper proposes a robust feature extraction method for ECG signals using normalized cepstral coefficients for the detection of cardiac arrhythmias. The extracted features in the proposed method are fed into a convolutional neural network (CNN) for classification. Additionally, various parameters of the CNN were examined to select the optimal network configuration. Statistical analysis demonstrates that the proposed feature extraction method and network achieve high accuracy in distinguishing unhealthy supraventricular arrhythmia and malignant ventricular ectopy signals from healthy signals. The experimental results indicate a 98% classification accuracy of the network in the testing phase.

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

ناشر: انجمن مهندسی پزشکی ایران / www.isbme.ir

مجله‌ی مهندسی پزشکی زیستی

شاپای چاپی: ۵۸۶۹-۲۰۰۸ / شاپای الکترونیکی: ۹۶۸۵-۸۰۰۶ / www.ijbme.org

دوره: ۱۸، شماره: ۴، زمستان ۱۴۰۳، ۳۹۹ - ۴۰۸

استخراج ویژگی مقاوم از سیگنال ECG با استفاده از ضرایب کپسترال نرمالیزه شده برای تشخیص آریتمی های قلبی

اصلانی، شادی [۱] / مروی، حسین [۲*] / کفائی، مهدی [۳]

[۱] – کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه صنعتی شاهرود، شاهرود، ایران
[۲] – دانشیار، گروه الکترونیک و مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه صنعتی شاهرود، شاهرود، ایران
[۳] – استادیار، گروه دفتر یا آزمایشگاه، دانشکده مهندسی برق، دانشگاه صنعتی شاهرود، شاهرود، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2054411.1968

ثبت در سامانه: ۱۴۰۳/۱۲/۷ بازنگری: ۱۴۰۴/۲/۱۲ پذیرش: ۱۴۰۴/۲/۲۵

واژه‌های کلیدی

آریتمی قلبی
پردازش سیگنال
سیگنال **ECG**
شبکه **CNN**
طبقه‌بندی

چکیده

طبقه‌بندی سیگنال الکتروکاردیوگرام یک فرآیند مهم در تشخیص و درمان ناهنجاری‌های قلبی است. سیگنال‌های ECG اطلاعات ارزشمندی در مورد وضعیت قلب ارائه می‌دهند و طبقه‌بندی این سیگنال‌ها به عنوان طبیعی یا غیرطبیعی نقش مهمی در تشخیص و درمان ناهنجاری‌های مختلف قلبی ایفا می‌کند. در سال‌های اخیر، روش‌های مختلف استخراج ویژگی برای طبقه بندی خودکار ECG به منظور افزایش صحت و کارایی طبقه‌بندی ECG توسعه یافته است. در این مقاله یک روش استخراج ویژگی مقاوم از سیگنال ECG با استفاده از ضرایب کپسترال نرمال شده برای تشخیص آریتمی‌های قلبی پیشنهاد شده است. ویژگی‌های استخراج شده در روش پیشنهادی به یک شبکه عصبی کانوولوشن جهت طبقه بندی داده شده است. همچنین پارامتر های مختلف شبکه CNN به منظور انتخاب شبکه بهینه مورد بررسی قرار گرفته است. با کمک مطالعه آماری نشان داده شده که روش استخراج ویژگی پیشنهادی و شبکه ارائه شده دارای صحت مناسب و بالایی در تشخیص سیگنال ناسالم بیماری آریتمی فوق بطنی و اکتوپی بطنی بدخیم از سیگنال سالم است. نتایج آزمایش های انجام شده نشان دهنده ۹۸ درصد صحت شبکه در مرحله آزمایش است.

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

۱- مقدمه

ECG[1] یک روش تشخیصی غیرتهاجمی است که فعالیت الکتریکی قلب را اندازه‌گیری می‌کند. ECG به‌طور گسترده در عمل بالینی برای تشخیص طیفی از شرایط و ناهنجاری‌های قلبی استفاده می‌شود. تفسیر ECG یکی از اجزای اساسی فرآیند تشخیصی است و تشخیص دقیق می‌تواند منجر به درمان سریع و مناسب شود [۱].

آریتمی‌ها، ریتم‌های غیرطبیعی قلب هستند که می‌توانند ناشی از شرایط مختلف قلبی و غیر قلبی باشند. ECG می‌تواند برای تشخیص انواع مختلف آریتمی از جمله فیبریلاسیون دهلیزی[2]، تاکی کاردی بطنی[3] و فلوتر دهلیزی[4] استفاده شود. AF شایع ترین آریتمی پایدار است و با افزایش خطر سکته مغزی و سایر عوارض قلبی عروقی همراه است. ECG می‌تواند فعالیت الکتریکی نامنظم و آشفته مرتبط با AF را که با عدم وجود امواج P و ریتم نامنظم بطنی مشخص می‌شود، تشخیص دهد.

VTیک آریتمی بالقوه تهدید کننده زندگی است که می‌تواند منجر به ایست قلبی ناگهانی شود. ECG می‌تواند ریتم بطنی سریع و منظم مرتبط با VT را که با شکل موج‌های ترکیبی QRS گسترده مشخص می‌شود، تشخیص دهد. فلوتر دهلیزی یک آریتمی کمتر شایع است که با ریتم دهلیزی سریع و منظم مشخص می‌شود. آریتمی هدایتی، ناهنجاری‌های رسانایی (هدایتی) زمانی رخ می‌دهند که سیگنال‌های الکتریکی در قلب به تأخیر افتاده یا مسدود می‌شوند و منجر به ریتم غیرطبیعی قلب می‌شوند. ECG می‌تواند برای تشخیص انواع مختلف ناهنجاری‌های هدایت، از جمله بلوک‌های شاخه‌ای و بلوک دهلیزی مورد استفاده قرار گیرد. بلوک‌های شاخه بسته زمانی اتفاق می‌افتد که یک یا هر دو شاخه که سیگنال‌های الکتریکی را در قلب هدایت می‌کنند مسدود شده یا با تأخیر مواجه شوند [۱].

سیگنال‌های ECG معمولا با استفاده از تکنیک‌های مختلف پردازش سیگنال برای استخراج اطلاعات مفید در مورد فعالیت الکتریکی قلب تجزیه و تحلیل می‌شوند .تجزیه و تحلیل سیگنال‌های ECG شامل مراحلی از جمله پیش پردازش، استخراج ویژگی و طبقه بندی است. اولین مرحله در تجزیه و تحلیل سیگنال ECG ، پیش پردازش است که شامل تمیز کردن و فیلتر کردن سیگنال برای حذف نویز و مصنوعات است. سیگنال‌های ECG اغلب با انواع مختلفی از نویزها مانند ناترازی، نویز عضلانی و تداخل خط برق آلوده می‌شوند. تکنیک‌های پیش پردازش برای کاهش اثر این منابع نویز و بهبود کیفیت سیگنال ECG استفاده می‌شود.

مرحله دوم در تجزیه و تحلیل سیگنال ECG استخراج ویژگی است که شامل استخراج اطلاعات مربوطه از سیگنال ECG است که می‌تواند برای طبقه بندی ناهنجاری‌های قلبی استفاده شود. سیگنال‌های ECG حاوی ویژگی‌های مختلفی هستند که نشان دهنده فعالیت الکتریکی قلب هستند، مانند دامنه، مدت زمان و مورفولوژی امواجP، QRS وT [۲].

مرحله نهایی در تجزیه و تحلیل سیگنال ECG طبقه بندی است که شامل استفاده از ویژگی‌های استخراج شده برای طبقه‌بندی سیگنال ECG به عنوان بهنجار یا غیرطبیعی است. الگوریتم‌های طبقه‌بندی را می‌توان به دو دسته تقسیم کرد: نظارت شده و بدون نظارت.

در ادامه این مقاله؛ در بخش دوم، کارهای صورت گرفته در زمینه پژوهش مورد بررسی قرار خواهد گرفت. در بخش سوم، روش پیشنهادی تشریح خواهد شد، در بخش چهارم نتایج روش پیشنهادی آورده می‌شود و در نهایت در بخش پنجم روش پیشنهادی مورد بررسی و تجزیه تحلیل قرار خواهد گرفت.

۲- پیشینه

طبقه‌بندی ECG فرآیند طبقه‌بندی سیگنال‌های ECG به‌عنوان طبیعی یا غیرطبیعی است. سیگنال‌های ECG طبیعی دارای یک الگوی منظم هستند و از امواج و فواصل متمایز شامل موج P، شکل موج ترکیبی QRS[5] و موج T تشکیل شده اند. از سوی دیگر، سیگنال‌های غیرطبیعی ECG دارای بی‌نظمی در الگوهای خود هستند و ممکن است ناهنجاری‌های قلبی زمینه‌ای را نشان دهند [۲].

طبقه‌بندی ECG می‌تواند به‌صورت دستی توسط متخصصان پزشکی آموزش دیده انجام شود، اما این فرآیند زمان‌بر و مستعد خطا است. بنابراین، روش‌های طبقه‌بندی خودکار ECG برای بهبود صحت و کارایی طبقه بندی ECG ایجاد شده است. این روش‌های خودکار از تکنیک‌های مختلف پردازش سیگنال و یادگیری ماشین برای طبقه‌بندی سیگنال‌های ECG به‌عنوان طبیعی یا غیرطبیعی استفاده می‌کنند [۳].

در مرجع [۴] یک مدل مبتنی بر پردازش سیگنال ECG توسط تجزیه موجک با استفاده از تبدیل موجک گسسته پیشنهاد شده است. این تجزیه ابتدا این امکان را فراهم می‌کند

[1] Electrocardiogram
[2] Atrial Fibrillation (AF)
[3] Ventricular Tachycardia (VT)
[4] Atrial flutter

[5] QRS: ترکیبی از سه انحراف (موجQ ، موج R و موج S) در نوار قلب (الکتروکاردیوگرام) که بیانگر دپولاریزاسیون سریع بطن راست و چپ است.

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

که نویز سیگنال حذف شود و سپس ویژگی‌های آماری از ضرایب تقریبی سیگنال حذف شده استخراج می‌شود و در نهایت داده‌های به‌دست آمده در طبقه‌بندی کننده ماشین بردار پشتیبان با اعتبار متقاطع برای اعتبار بیشتر طبقه‌بندی می‌شود. پس از آزمایش این مدل با موجک‌های مادر مختلف در مقیاس‌های مختلف، صحت در مقیاس چهارم بالا بوده و بهترین صحت به‌دست آمده ۸۷,۵۰ درصد است.

در پژوهش دیگر یک روش طبقه‌بندی جدید بر اساس ویژگی‌های چندگانه با ترکیب مورفولوژی شکل موج و تحلیل آماری حوزه فرکانس ارائه می‌شود [۵] این روش صحت طبقه‌بندی بهبود یافته را ارائه می‌دهد و زمان صرف شده برای طبقه‌بندی سیگنال‌ها را به حداقل می‌رساند. یک بسته موجک برای تجزیه سیگنال ECG حذف شده استفاده می‌شود، و حداکثر مقدار و انحراف استاندارد ضرایب بسته موجک تجزیه شده برای به دست آوردن فضای ویژگی حوزه فرکانس محاسبه می‌شود. روش آستانه شیب برای تشخیص اوج R و محاسبه فواصل RR اعمال می‌شود و دو بازه RR اول به‌عنوان ویژگی‌های حوزه زمانی استخراج می‌شوند. صحت تشخیص روش مذکور ۹۶,۶۷ درصد گزارش شده است. داده‌های این مطالعه از سه پایگاه داده تولید می‌شوند، یعنی پایگاه داده آریتمی MIT-BIH، پایگاه داده بلند مدت AF(LTAFDB) و شبیه‌ساز پارامتر فیزیولوژیکی Fluke(ProSim2). وقتی سیگنال‌های ECG جمع‌آوری می‌شوند، داده‌های ۱۰۰۰ نقطه‌ای به‌عنوان بخش داده انتخاب می‌شوند و فرکانس نمونه‌برداری ۳۶۰ هرتز است. برای هر نوع ECG، ۶۰ مجموعه سیگنال ECG استخراج می‌شود و ۵۴۰ مجموعه داده جمع آوری می‌شود. طبقات مختلفی از آریتمی‌ها با یک الگوی خاص در طول ضبط ECG مشخص می‌شوند. این یافته هم‌چنین نشان می‌دهد که تجزیه و تحلیل دقیق نمونه‌های ECG می‌تواند به تشخیص نوع آریتمی کمک کند. مرجع [۱۲] بر روی مطالعه نه نوع آریتمی به نام‌های N، SB، VT، V، A، AF، AT، SA و ST تمرکز دارد. از نظر بالینی، انواع مختلف آریتمی شکل موج‌های متفاوتی دارند. ST[۶] و SB[۷] دارای گروه‌های موج QRS بهنجار با تفاوت‌های جزئی در فاصله PR[۸] و تفاوت‌های قابل توجه در فاصله RR هستند.

به‌عنوان مثال، SB به‌طور متوسط کم‌تر از 60 R spike در دقیقه است، در حالی که ST به طور متوسط ۱۰۰ R spike- ۱۵۰در دقیقه است. فاصله RRوSB زیاد است و فاصله RR[۹] وST کوچک است. این ویژگی می‌تواند دو آریتمی متفاوت را تشخیص دهد. مراحل این روش، شامل برداشت ویژگی، بهنجار کردن داده، تقسیم بندی داده‌ها به داده‌های اموزش و تست و دیگر مراحل می‌شود. این مطالعه رسیدن به صحت تشخیص ۷۸,۶ درصد را گزارش کرده است.

در مطالعه‌ای دیگر انجی[۱۰] و همکاران بر روی دو ساختار شبکه عصبی و شبکه فازی مطالعه کرده و این دو ساختار را با یکدیگر مقایسه کرده‌اند [۶]. در این مطالعه طبقه‌بندی بیماری‌های خاص با استفاده از شبکه عصبی مصنوعی[۱۱] و روابط هم ارزی فازی صورت گرفته است. در این مطالعه سیگنال‌ها به چهار دسته ایسکمیک کاردیومیوپاتی متسع، بلوک کامل قلب، فیبریلاسیون دهلیزی نابجا و عادی تقسیم بندی شده‌اند. این ساختار شامل سه لایه نرونی شامل لایه ورودی، لایه میانی یا لایه پنهان و لایه خروجی می‌باشد. تغییرپذیری ضربان قلب به عنوان سیگنال پایه استفاده می‌شود که از آن پارامترهای خاصی استخراج شده و برای طبقه بندی به ANN ارائه می‌شود. از همین داده‌ها برای طبقه بندی کننده هم ارزی فازی نیز استفاده می‌شود. الگوریتم این روش شامل چهار دسته کلی بررسی اولیه، پیش پردازش، محاسبه روابط فازی و دسته بندی می‌شود. طبقه‌بندی‌کننده ANN معماری پیش‌خور در حدود ۸۵ درصد موارد آزمایشی صحیح است، طبقه‌بندی‌کننده فازی در بیش از ۹۰ مورد، طبقه‌بندی صحیح را ارائه می‌دهد.

شبکه‌های عصبی عمیق[۱۲] به‌طور گسترده در کارهای طبقه‌بندی ECG استفاده شده‌اند که شامل تجزیه و تحلیل فعالیت الکتریکی قلب ثبت‌شده در سیگنال ECG و طبقه‌بندی آن به انواع مختلف ریتم‌ها یا شرایط قلبی است. مدل‌های DNN برای کارهای مختلف طبقه‌بندی ECG، از جمله تشخیص آریتمی، تجزیه و تحلیل قطعه ST و تشخیص فیبریلاسیون دهلیزی، توسعه یافته‌اند. این مدل‌ها معمولاً از شبکه‌های عصبی کانولوشن[۱۳] یا شبکه‌های عصبی بازگشتی به عنوان بلوک‌های سازنده خود استفاده می‌کنند.

---

[۶] بخشی از نوار قلب است که بین انتهای موج S و شروع موج T قرار دارد

[۷] Sinus Bradycardia (SB)، یعنی ضربان قلب آهسته‌تر از حد طبیعی، اما ریتم آن سینوسی و طبیعی است (ریتم قلب از گره سینوسی می‌آید، فقط سرعتش پایین است).

[۸] PR: مدت زمانی است که سیگنال الکتریکی از دهلیزها به بطن‌ها می‌رسد.

[۹] فاصله زمانی بین دو موج R پیاپی در نوار قلب است

[۱۰] aNgee

[۱۱] Artificial Neural Network (ANN)

[۱۲] Deep Neural Networks (DNN)

[۱۳] Convolutional Neural Networks (CNN)

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

مونته نگرو[۱۴] و همکاران از شبکه‌های CNN برای شناسایی سیگنال‌ها استفاده کرده‌اند. آن‌ها از پایگاه داده TNMG که سری‌های زمانی ECG خام و فیلتر نشده را در قالب یک داده سه بعدی در یک فایل ارائه می‌دهند کمک گرفته‌اند [۷]. هر سیگنال برای حذف ناترازی (مثلاً مصنوعات حرکتی) فیلتر می‌شود و از فرکانس نمونه‌برداری اصلی ۴۰۰ هرتز تا ۳۰۰ هرتز نمونه‌برداری می‌شود تا از بایاس و اثرات مرتبط با فرکانس نمونه‌برداری جلوگیری شود. صحت تشخیص این مقاله برابر با ۸۶,۱۵ درصد بوده است.

وانگ[۱۵] و همکاران در سال ۲۰۲۴، روشی هوشمند برای تشخیص فیبریلاسیون دهلیزی با استفاده از CEPNCC-BiLSTM مبتنی بر داده‌های بلندمدت فتوپلتیسموگرافی[۱۶] ارائه دادند. فیبریلاسیون دهلیزی (AF) شایع‌ترین آریتمی قلبی است که با اپیزودهای متناوب و بدون علامت مشخص می‌شود. روش‌های سنتی اغلب در شناسایی ماهیت پراکنده و پیچیده AF ناکارآمد هستند و منجر به افزایش تشخیص‌های نادرست می‌شوند. این مطالعه یک روش هوشمند برای تشخیص AF با ترکیب تجزیه تجربی مد مکمل، ضرایب کپسترال با نرمال‌سازی توان، شبکه BiLSTM[۱۷] و فناوری موج نبض فوتوالکتریک ارائه می‌دهد. این رویکرد دقت ۹۹,۲٪ و سرعت پردازش بالا را در داده‌های PPG بلندمدت نشان داده و در ارزیابی ET-score نسبت به روش‌های دیگر عملکرد بهتری دارد [۸].

اسلام و همکاران در سال ۲۰۲۳، روشی نوآورانه برای طبقه‌بندی ضربان قلب بر مبنای ECG با عنوان HARDC ارائه کردند. این روش ترکیبی از شبکه‌های عصبی بازگشتی دوطرفه با ساختار دوگانه(BiGRU-BiLSTM) ، CNNهای گسترش یافته و مکانیسم توجه سلسله‌مراتبی است که به طور مؤثر ویژگی‌های محلی و جهانی سیگنال را استخراج می‌کند. استفاده از CGAN برای تولید داده‌های مصنوعی و بهبود طبقه‌بندی، دقت بالای ۹۹,۶۰٪ را در مجموعه داده PhysioNet 2017و MIT-BIH نشان داده است. این مدل کارایی و تفسیرپذیری بالایی در تشخیص آریتمی ارائه کرده است [۹].

چوی[۱۸] و همکاران در سال ۲۰۲۴، مدل ECGBERT را معرفی کردند که بر پایه یادگیری بازنمایی خودنظارتی توسعه یافته است و هدف آن رمزگشایی زبان پنهان سیگنال‌های ECGمی‌باشد. این مدل با پیش‌آموزش بدون نظارت، نیاز به داده‌های برچسب‌خورده پزشکی را کاهش داده و می‌تواند با حداقل تغییر برای وظایف مختلف مانند تشخیص فیبریلاسیون دهلیزی، طبقه‌بندی ضربان قلب، تشخیص آپنه خواب و احراز هویت کاربران، تنظیم شود. نتایج نشان می‌دهد ECGBERTدر این حوزه‌ها به نتایج پیشرفته‌ای دست یافته است [۱۰].

دارماواهیونی[۱۹] و همکاران در سال ۲۰۲۴، بهبود عملکرد طبقه‌بندی آریتمی بر مبنای سیگنال ECG را از طریق بهینه‌سازی ویژگی‌ها بررسی کردند. آن‌ها با به‌کارگیری استخراج ویژگی‌های کم‌عمق مبتنی بر تحلیل دامنه زمان و استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری برای انتخاب ویژگی، موفق شدند به دقت، حساسیت، ویژگی و صحت ۱۰۰٪ در طبقه‌بندی آریتمی‌های قلبی دست یابند. این رویکرد ساده و با پیچیدگی پایین، امکان استفاده مؤثر در کاربردهای عملی را فراهم می‌کند [۱۱].

۳- روش پیشنهادی

۳-۱ معرفی روش استخراج ویژگیPNCC

ضرایب PNCC نوعی تکنیک استخراج ویژگی است که در پردازش سیگنال صوتی و گفتار استفاده می‌شود این ویژگی ها براساس ضرایب فرکانس Mel Cepstral (MFCCs) هستند که به‌طور گسترده در سیستم‌های تشخیص گفتار استفاده می‌شود. روش PNCC شامل یک مرحله اضافی است که طیف توان سیگنال را نرمال می‌کند، که می‌تواند به کاهش تأثیر تغییرات در قدرت سیگنال بر بردارهای ویژگی حاصل کمک کند[۱۲]. این مرحله نرمال‌سازی با گرفتن لگاریتم طیف توان و سپس اعمال یک فیلتر خطی به طیف حاصل انجام می‌شود. پس از مرحله نرمال‌سازی، روش PNCC ضرایب را به روشی مشابه روش MFCC محاسبه می‌کند. سیگنال ابتدا به فریم‌های کوتاه تقسیم می‌شود و طیف توان هر فریم با استفاده از تبدیل فوریه محاسبه می‌شود. سپس طیف حاصل از یک بانک فیلتر عبور می‌کند که پاسخ فرکانسی سیستم شنوایی انسان را تقریبی می‌کند. سپس لگاریتم انرژی‌های بانک فیلتر محاسبه می‌شود و ضرایب حاصل تحت پردازش‌های بیشتری مانند نرمال‌سازی میانگین و تفریق میانگین قرار می‌گیرند. به‌طورکلی، PNCCها می‌توانند یک روش قوی و کارآمد برای استخراج ویژگی‌ها از سیگنال‌های گفتاری و صوتی ارائه دهند

[۱۴] Montenegro
[15] Wang
[16] Photoplethysmography
[17] Cepstral Coefficients, Bi-directional Long Short-term Memory (CEPNCC-BiLSTM)
[18] Choi
[19] Darmawahyuni

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

که برای کارهایی مانند تشخیص گفتار و طبقه بندی موسیقی مناسب هستند. مرحله نرمال‌سازی توان در روش PNCC[۲۰] می‌تواند به بهبود استحکام فرآیند استخراج ویژگی نسبت به تغییرات در قدرت سیگنال و نویز محیطی کمک کند[۱۲]. بلوک دیاگرام روش PNCC در شکل ۱ رسم شده است.

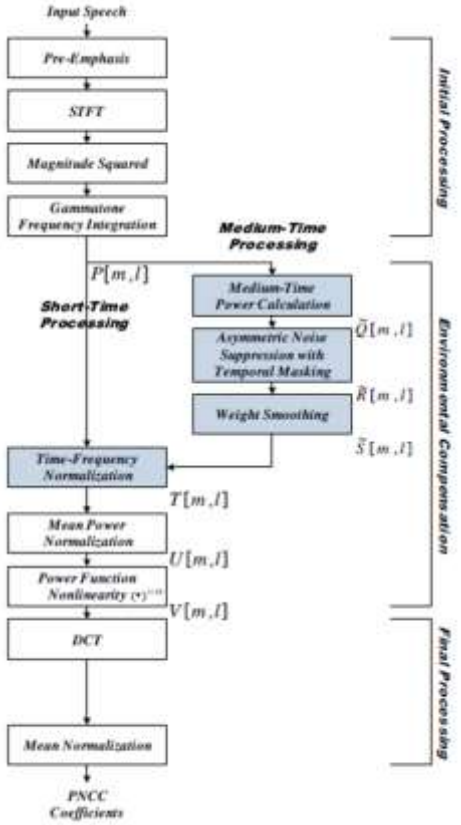

شکل ۱ : بلوک دیاگرام روش استخراج ویژگیPNCC

۳-۲روش پیشنهادی برمبنای PNCC

بلوک دیاگرام روش پیشنهادی طبقه بندی ECG در شکل ۲، نشان داده شده است. این سیستم از چهار مرحله اصلی تشکیل شده است:

- ✓ استخراج ویژگیPNCC : سیگنال های ECG ابتدا برای حذف نویز پیش پردازش می شوند. برای حذف نویز از فیلتر میانگین استفاده شده است، در واقع پیچیدگی چندانی در این حالت وجود نداشت چرا که روند پژوهش به کمک یادگیری عمیق توانایی کنترل نویز را دارد. سپس سیگنال‌های از پیش پردازش شده به اجزای اصلی خود تجزیه می شوند. سپس ضرایب مؤلفه عادی اصلی (PNCC) از مؤلفه‌های اصلی استخراج می شود. فاصله اقلیدسی PNCC مذکور از مجموعه PNCC های سیگنال‌های سالم محاسبه می‌شود، تا یک بردار مناسب حاصل گردد. این بردار کمک می‌کند تا مدل یک پشتیبان برای تصمیم‌گیری داشته باشد (فاصله کمتر برابر است با احتمال سلامت بیشتر سیگنال). این PNCC ها به همراه فاصله‌های اقلیدسی به‌عنوان ورودی شبکه در نظر گرفته می‌شود.
- ✓ استخراج ویژگی با CNN: سپس PNCC ها به CNNوارد می شوند .CNN برای استخراج ویژگی‌های سطح بالا از PNCC ها استفاده می شود.
- ✓ طبقه بندی: ویژگی‌های استخراج شده سپس به یک طبقه‌بندی کننده وارد می شوند. طبقه‌بندی کننده برای طبقه‌بندی سیگنال های ECG به یکی از کلاس‌های مورد نظر استفاده می‌شود.
- ✓ آزمون آماری: آزمون آماری برای بهینه‌سازی آزمایش‌ها جهت تعیین بهترین مجموعه شرایط آزمایشی است.

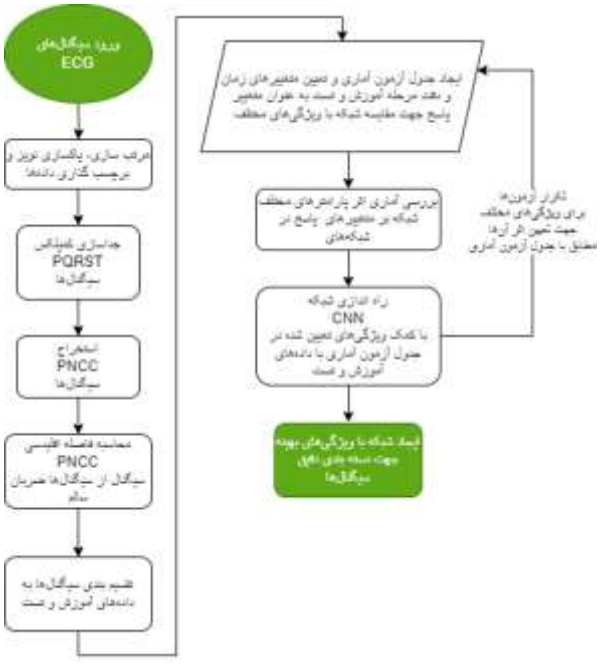

شکل ۲: بلوک دیاگرام روش پیشنهادی برای دسته بندی سیگنال‌های سالم و ناسالم

در این پژوهش، نوآوری اصلی در توسعه یک چارچوب ترکیبی برای طبقه‌بندی سیگنال‌های ECG است که در آن ابتدا ویژگی‌های مقاوم از طریق استخراج ضرایب مؤلفه عادی اصلی به دست آمده و در کنار محاسبه فاصله اقلیدسی نسبت به نمونه‌های سالم به کار گرفته می‌شود. این فاصله به عنوان یک شاخص کمکی، میزان نزدیکی سیگنال جدید به الگوهای طبیعی را کمی‌سازی می‌کند. سپس این اطلاعات به شبکه عصبی کانولوشنی وارد می‌شود تا ویژگی‌های سطح بالای

[۲۰] Power-Normalized Cepstral Coefficients (PNCC)

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

غیرخطی و پیچیده از داده‌های اولیه استخراج گردد. استفاده همزمان از PNCC به منظور افزایش مقاومت در برابر نویز و CNN برای استخراج الگوهای پیچیده، یک رویکرد دوسویه و هدفمند را در جهت بهبود دقت طبقه‌بندی و ارتقاء قابلیت اطمینان مدل ارائه می‌دهد. این چارچوب پیشنهادی، با بهره‌گیری از ترکیب تکنیک‌های استخراج ویژگی سنتی و یادگیری عمیق، توانایی بالایی در تحلیل سیگنال‌های ECG در شرایط واقعی و نویزی نشان می‌دهد.

۴- نتایج

۴-۱ مجموعه داده

در این پژوهش از پایگاه داده MIT-BIH[۲۱] به عنوان یک مجموعه داده در دسترس عموم استفاده شده است. این مجموعه شامل مجموعه وسیعی از نوارهای ضبط شده ECG است که از بیماران مبتلا به آریتمی‌های مختلف و همچنین ریتم سینوسی طبیعی به دست آمده است. موارد ضبط شده تحت شرایط مختلف به دست آمده و شامل موارد بستری و سرپایی می‌شود.

برای آموزش و بررسی‌های آماری ۲۵۰ نمونه سیگنال‌های آریتمی فوق بطنی، بطن بدخیم و سیگنال قلبی سالم در نظر گرفته شده است. این سیگنال‌ها پس از فیلتر شدن و جدا شدن بخش شکل موج ترکیبی PQRS با یک‌دیگر هم‌سایز و هم فرکانس شدند تا قابلیت مقایسه با یک‌دیگر را داشته باشند.

در شکل ۳، نمونه‌هایی از دو سیگنال سالم (اولین و آخرین) و یک سیگنال ناسالم (تصویر وسط) آورده شده است.

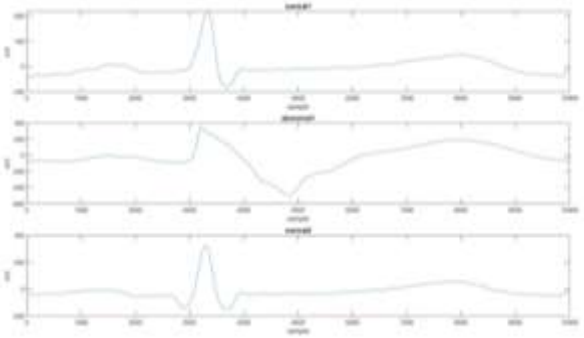

شکل (۳): نمونه‌ای از تصاویر سیگنال در مجموعه‌داده

۴-۲ مشخصات شبکه CNN

همان‌طور که در بخش‌های قبل بیان شد، برای طبقه‌بندی از شبکه CNN استفاده شده که به‌عنوان ورودی یک ماتریس چهار بعدی را دریافت می‌کند. یک بعد این ماتریس زمان یا به عبارت دیگر نمونه‌های پشت سرهم است. در سه بعد دیگر دو ماتریس دو بعدی قرار دارد. یکی از این ماتریس‌های شامل ویژگی PNCC برداشتی از کمپلس‌های PQRS سیگنال قلبی است و دیگری شامل فاصله اقلیدسی‌های ویژگی PNCC سیگنال مورد بررسی از PNCC، سیگنال‌های سالم دیگر است که شکل شماتیک از لایه‌های داده‌های ورودی در شکل ۴، آمده است.

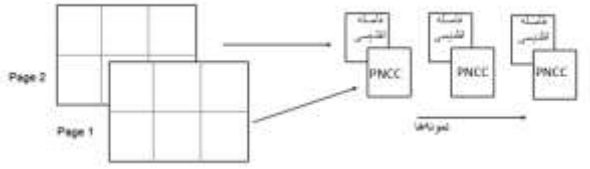

شکل ۴: شکل شماتیک از لایه‌های داده‌های ورودی شامل ماتریس فاصله اقلیدسی سیگنال‌ها از سیگنال‌ها ناسالم و ماتریس PNCC

شبکه ایجاد شده مانند شبکه‌های عمیق دیگر دارای لایه ورودی هم سایز با سایز ماتریس ورودی می‌باشد. لایه خروجی آن نیز شامل یک لایه کاملا متصل با خروجی یک نرون برای مشخص کردن پاسخ شبکه می‌باشد. لایه‌های میانی آن نیز از لایه‌های بیشینه کننده، بهینه ساز و غیره تشکیل شده است. در ورودی شبکه تمامی داده ها به ابعاد ۴۰*۶۷ تبدیل شدند. همچنین به منظور ارزیابی مدل پیشنهادی ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد به عنوان داده‌های آزمون مورد استفاده قرار گرفت. معماری دقیق و همچنین سایر مشخصات این شبکه در شکل ۵ قابل مشاهده می باشد.

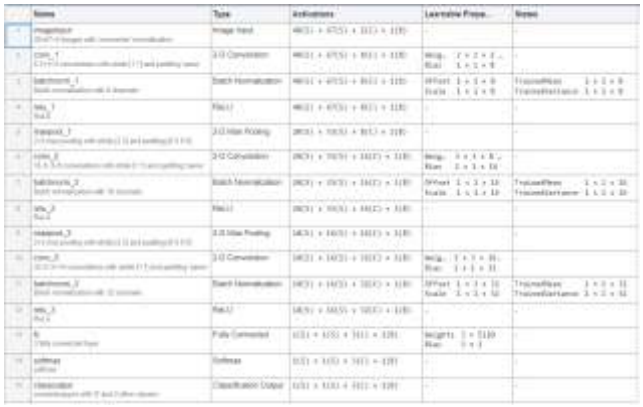

شکل ۵: خلاصه لایه‌های مختلف سازنده شبکه CNN مورد مطالعه در این مقاله

کارایی روش پیشنهادی یا همان PNCC در حالتی که داده‌ها نویز زیادی دارند مورد بررسی قرار گیرد، کارایی این مدل در دو حالت داده‌های نویزی و بدون نویز مورد بررسی قرار می‌گیرد.

۴-۳ نتایج برای حالت بدون نویز

با توجه به بررسی و مدل‌سازی‌های انجام شده مشخص شده که در بهترین حالت شبکه باید بر روی epoch های بالا تنظیم شود. تغییر الگوریتم هم اثرگذاری معناداری بر روی آموزش شبکه نداشته اما با الگوریتم SGDM در بیشینه صحت مرحله تست قرار خواهیم گرفت. بر اساس این بررسی Initial learning rate در بهترین حالت بر روی ۰،۰۱ قرار داده شده

[۲۱] https://www.physionet.org/content/mitdb/1.0.0/

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

است. پارامتر decay rate of gradient نیز در الگوریتم مذکور بی‌تاثیر می‌باشد. شکل۶ ماتریس سردرگمی داده های تست را به تفکیک ۳ کلاس مورد بررسی قرار داده است. در این ماتریس کلاس ۱ متعلق به افراد سالم و کلاس ۲ و ۳ نیز به ترتیب متعلق به بیماران آریتمیsupraventricular و malignant ventricular می‌باشد. همچنین نمودار صحت و مقدار خطای شبکه در طی تکرارهای آموزش در شبکه ایجاد شده با پارامترهای ذکر شده در شکل ۷ ترسیم شده است. هم‌چنین در جدول ۱، صحت شبکه برای دو سیگنال در مرحله آموزش و مرحله تست به همراه مجموع تعداد شکل موج‌های ترکیبی اورده شده است. این مقادیر قدرت این شبکه را خصوصا در مرحله کاربرد عملی نشان می‌دهد. سایر پارامترهای خروجی تست در جدول ۲ قابل مشاهده می باشد.

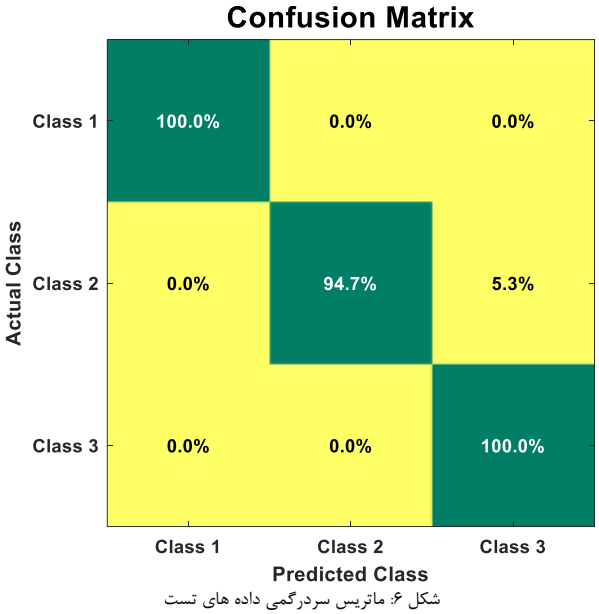

شکل ۶: ماتریس سردرگمی داده های تست

جدول ۱: صحت شبکه برای سیگنال های نرمالیزه در مرحله آموزش و مرحله تست

پارامتر	طبقه بندی	واقعی	تشخیص	دقت	صحت
مرحله آموزش	normal	78	78	0.99	0.98
	supraventricular arrhythmia	166	162		
	malignant ventricular ectopy	156	160		
مجموع تعداد شکل موج‌های ترکیبی		400	400		
مرحله تست	normal	12	12	0.98	0.98
	supraventricular arrhythmia	19	18		
	malignant ventricular ectopy	19	20		
مجموع تعداد شکل		50	50		

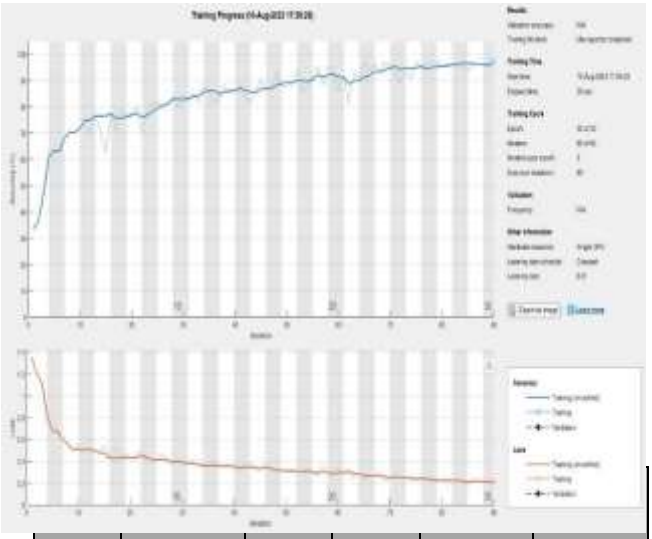

0.9896	0.9892	0.9824	0.9825	0.9833	0.9800

۴-۴ نتایج حاصل از اضافه نمودن نویز

همان‌طورکه بیان شد، یکی از مزایای روش PNCC استحکام در برابر نویز و مصنوعات بود به این معنی که روش PNCC می‌تواند به کاهش تاثیر نویز و مصنوعات در سیگنال ECG کمک کند برای آشکار شدن این موضوع ما نویز گوسی سفید با SNRهای 0db , 5db و 10db را به سیگنال‌های ECG اعمال کرده‌ایم و عملکرد شبکه را در این حالت‌ها بررسی کرده‌ایم. شکل ۸ الی ۱۰ به‌ترتیب عملکرد شبکه را برای SNRهای 0db , 5db و 10db نشان می‌دهند.

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

همان‌طورکه در جدول ۳، می‌بینیم متوجه می‌شویم که در بدترین حالت یعنی SNR=0db نویز تاثیر چندانی بر عملکرد شبکه نداشته و در این حالت صحت شبکه در مرحله آموزش و مرحله تست به‌ترتیب برابر با ۹۲ و ۹۴ درصد است در حالی که عملکرد شبکه در حالت بدون نویز به‌ترتیب برابر با ۹۷ و ۹۸ درصد بوده است بنابراین مزیت استحکام در برابر نویز و مصنوعات روش PNCC آشکار می‌شود.

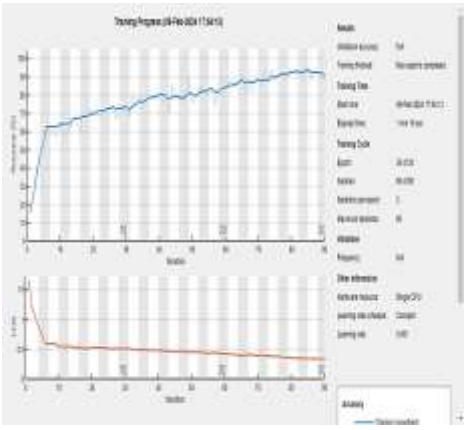

شکل ۸: عملکرد شبکه بر روی سیگنال‌های ECG با نویز گوسی سفید. SNR=0db

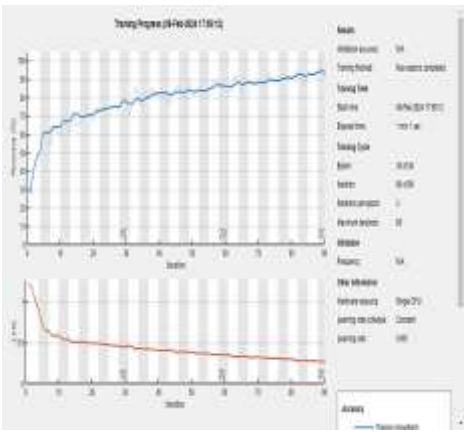

شکل ۹: عملکرد شبکه بر روی سیگنال‌های ECG با نویز گوسی سفید. SNR=5db

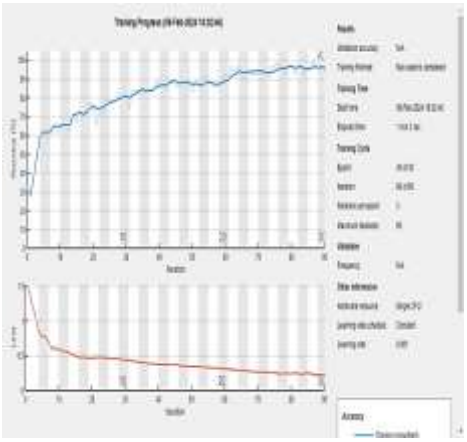

شکل ۱۰: عملکرد شبکه بر روی سیگنال‌های ECG با نویز گوسی سفید. SNR=10db

جدول ۳: مقایسه عملکرد شبکه بر روی سیگنال‌های ECG نویزی در سه SNR متفاوت و سیگنال بدون نویز

SNR نویز گوسی سفید	صحت آموزش(درصد)	صحت تست(درصد)
بدون نویز	۹۷	۹۸
۰ دسی بل	۹۲	۹۴
۵ دسی بل	۹۳,۵	۹۶
۱۰ دسی بل	۹۵	۹۷

۵-۴ مقایسه با سایر روش ها

جهت ارزیابی روش پیشنهادی با سایر روش ها، نتایج حاصل از روش پیشنهادی با نتایج بدست آمده از مراجع [۱۲]، [۱۳] و [۱۴] مقایسه شده است. این نتایج در جدول ۴ آمده است. لازم به ذکر است که ردیف دوم از نظر تعداد آریتمی‌ها با این روش یکسان است اما سایرروش ها تعداد آریتمی‌های بیشتری در نظر گرفته‌اند. همانطور که در جدول ۴ مشاهده می شود. روش پیشنهادی در مقایسه با روش های دیگر دارای صحت بالاتر است.

جدول ۳: مقایسه روش پیشنهادی با سایر روش‌ها

پژوهشگر	طبقه‌بند	روش پیشنهادی	دسته‌ها	صحت (درصد)	پایگاه داده
روش پیشنهادی	CNN	PNCC	Supraventricular Arrhythmia Malignant Ventricular Ectopy Healthy Signal	98	MIT-BIH
M.Ramkumar [15]	SVM	Wavelet Transform	N, VT	96.13	MIT
D.Abdelhamid [13]	SVM	Wavelet Transform	N, A, V, RB, LB	93.06	MIT
A.Zadeh [14]	SVM	Wavelet Transform	N, A,V, RB, LB	96	MIT

۵- ارزیابی نهایی

در این مطالعه از روش استخراج ویژگی بر مبنای PNCC به کمک شبکه CNN برای تشخیص بیماری‌های قلبی از روی سیگنال‌های ECG استفاده شده است. هدف این مطالعه استخراج ویژگی مقاوم از روی سیگنال‌های ECG و توسعه یک مدل طبقه‌بندی قوی و کارآمد است که می‌تواند به تشخیص زودهنگام بیماری‌های قلبی کمک کند. پیچیدگی‌های سیگنال‌های ECG حاصله از بیماری‌های قلبی عروقی، چالش‌های منحصر به فردی را در پردازش و طبقه بندی این سیگنال ها ایجاد می‌کند. روش‌های استخراج ویژگی از سیگنال

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت قرار داده خواهد شد

اغلب برای به تصویر کشیدن الگوها و ویژگی‌های ظریفی که بین سیگنال‌های قلبی سالم و بیمار تمایز می‌دهد، تلاش می‌کنند.

روش PNCC یک روش کارآمد بوده که توانایی استخراج ویژگی های مرتبط و منحصر به فرد از سیگنال‌های غیر ایستا و پیچیده را خصوصا در محیط‌های نویزی دارا می باشد. علاوه بر این، در بخش بررسی انتخاب و آماده سازی مجموعه داده، از جمله مجموعه سیگنال‌های قلبی از افراد سالم و بیماران مبتلا به دو بیماری‌های قلبی پرداخته ایم. در این مطالعه ارزیابی از عملکرد مدل CNN ارائه شده و پارامترهای مهم اثر گذار بر این شبکه‌ها مورد بررسی قرارگرفته اند. نتایج و بحث‌های ارائه شده در این مقاله به پیشرفت روش‌های تجزیه و تحلیل تشخیص پزشکی کمک می‌کند و پیامدهای امیدوارکننده ای برای بهبود تشخیص و مدیریت بیماری‌های قلبی عروقی دارد. دقت ۹۸درصدی این مدل با مقدار صحت و نره بازگشت حدود ۹۸درصدی در خروجی مدل تست این شبکه می تواند کارامدی این مدل را تایید نماید.

روش پیشنهادی به واسطه استفاده از ویژگی PNCC نسبت به نویز تاثیرپذیری کمتری دارد. همچنین استفاده از شبکه عصبی کانولوشنی (CNN) برای طبقه‌بندی داده ها، انعطاف در یادگیری الگوهای پیچیده و تمایزدهنده را بیشتر کرده که در کنار قابلیت های تشخیص و طبقه بندی بیماران از افراد سالم، می تواند در مطالعات پیشگیری و تشخیص زودهنگام بیماران نیز موثر واقع شود. از جمله چالش های این روش نیز می توان به پیچیدگی پیاده‌سازی و تحلیل و پردازش داده های عملیاتی اشاره داشت.

۶- منابع

[1] J. G. Webster and A. J. Nimunkar, “Medical Instrumentation: Application and Design, 5th Edition,” p. 928, 2020, [Online]. Available: https://www.wiley.com/en-us/Medical+Instrumentation%3A+Application+and+Design%2C+5th+Edition-p-9781119457336.

[2] S. H. Jambukia, V. K. Dabhi, and H. B. Prajapati, “Classification of ECG signals using machine learning techniques: A survey,” Conf. Proceeding - *2015* Int. Conf. Adv. Comput. Eng. Appl. ICACEA *2015*, pp. 714–721, 2015, doi: 10.1109/ICACEA.2015.7164783.

[3] F. Murat, O. Yildirim, M. Talo, U. B. Baloglu, Y. Demir, and U. R. Acharya, “Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review,” Comput. Biol. Med., vol. 120, no. April, p. 103726, 2020, doi: 10.1016/j.compbiomed.2020.103726.

[4] Y. Toulni, T. B. Drissi, and B. Nsiri, “Electrocardiogram signals classification using discrete wavelet transform and support vector machine classifier,” IAES Int. J. Artif. Intell., vol. 10, no. 4, pp. 960–970, 2021, doi: 10.11591/IJAI.V10.I4.PP960-970.

[5] H. Li et al., “Classification of electrocardiogram signals with waveform morphological analysis and support vector machines,” Med. Biol. Eng. Comput., vol. 60, no. 1, pp. 109–119, 2022, doi: 10.1007/s11517-021-02461-4.

[6] U. Rajendra Acharya, P. Subbanna Bhat, S. S. Iyengar, A. Rao, and S. Dua, “Classification of heart rate data using artificial neural network and fuzzy equivalence relation,” Pattern Recognit., vol. 36, no. 1, pp. 61–68, 2003, doi: 10.1016/S0031-3203(02)00063-8.

[7] L. Montenegro, M. Abreu, A. Fred, and J. M. Machado, “Human-Assisted vs. Deep Learning Feature Extraction: An Evaluation of ECG Features Extraction Methods for Arrhythmia Classification Using Machine Learning,” Appl. Sci., vol. 12, no. 15, pp. 1–15, 2022, doi: 10.3390/app12157404.

[8] Wang Z, Fan J, Dai Y, Zheng H, Wang P, Chen H, Wu Z. Intelligent Detection Method of Atrial Fibrillation by CEPNCC-BiLSTM Based on Long-Term Photoplethysmography Data. Sensors. 2024 Aug 14;24(16):5243.

[9] Islam MS, Hasan KF, Sultana S, Uddin S, Quinn JM, Moni MA. HARDC: A novel ECG-based heartbeat classification method to detect arrhythmia using hierarchical attention based dual structured RNN with dilated CNN. Neural Networks. 2023 May 1;162:271-87.

[10] Choi S, Mousavi S, Si P, Yhdego HG, Khadem F, Afghah F. Ecgbert: Understanding hidden language of ecgs with self-supervised representation learning. arXiv preprint arXiv:2306.06340. 2023 Jun 10.

[11] Darmawahyuni A, Nurmaini S, Tutuko B, Rachmatullah MN, Firdaus F, Sapitri AI, Islami A, Marcelino J, Isdwanta R, Perwira MI. An improved electrocardiogram arrhythmia classification performance with feature optimization. BMC Medical Informatics and Decision Making. 2024 Dec 30;24(1):412.

[12] C. Kim and R. M. Stern, “Power-Normalized Cepstral Coefficients (PNCC) for Robust Speech Recognition,” IEEE/ACM Trans. Audio Speech Lang. Process., vol. 24, no. 7, pp. 1315–1329, 2016, doi: 10.1109/TASLP.2016.2545928.

[13] A. Daamouche, L. Hamami, N. Alajlan, and F. Melgani, “A wavelet optimization approach for ECG signal classification,” Biomed. Signal Process. Control, vol. 7, no. 4, pp. 342–349, 2012, doi: 10.1016/j.bspc.2011.07.001.

[14] A. E. Zadeh and A. Khazaee, “High efficient system for automatic classification of the electrocardiogram beats,” Ann. Biomed. Eng., vol. 39, no. 3, pp. 996–1011, 2011, doi: 10.1007/s10439-010-0229-6.

[15] M. Ramkumar, C. Ganesh Babu, G. S. Priyanka, and R. Sarath Kumar, “Ecg Arrhythmia Signals Classification Using Particle Swarm Optimization-Support Vector Machines Optimized With Independent Component Analysis,” IOP Conf. Ser. Mater. Sci. Eng., vol. 1084, no. 1, pp. 012009, 2021, doi: 10.1088/1757-899x/1084/1/012009.

البته نسخه فعلی نیز کاملا معتبر بوده و تمام اطلاعات و داده‌های آن قابل استناد می‌باشد