

تشخیص آریتمی فیبریلاسیون دهلیزی با استفاده از CNN و LSTM

تندیس بهرام راد، فارغ التحصیل کارشناسی ارشد^۱، حسین حسینی نژاد محبتی، استادیار^۲

۱- گروه الکترونیک - دانشکده مهندسی برق - دانشگاه صنعتی خواجه نصیرالدین طوسی - تهران - ایران tbahramrad@gmail.com
۲- گروه الکترونیک - دانشکده مهندسی برق - دانشگاه صنعتی خواجه نصیرالدین طوسی - تهران - ایران Hosseini_nezhad@kntu.ac.ir

چکیده: آریتمی فیبریلاسیون دهلیزی یکی از خطرناک‌ترین بیماری‌های قلبی است که با تشخیص درست و به موقع آن می‌توان از بروز سکت‌های مغزی و قلبی جلوگیری کرد. برای بالا بردن سرعت تشخیص و همچنین کم کردن احتمال خطای پزشکی مسئله‌ی تشخیص خودکار این نوع آریتمی مطرح می‌شود. در برخی از پژوهش‌ها برای تشخیص آن از روش‌های کلاسیک یادگیری ماشین استفاده شده است ولی به علت دشوار بودن تشخیص این آریتمی و وابستگی آن به بررسی چندین ضریان متوالی، استفاده از یادگیری عمیق دقت بالاتری در تشخیص نهایی دارد. بنابراین در این مقاله یک رویکرد مبتنی بر استفاده از شبکه یادگیری عمیق با ترکیب شبکه‌های LSTM و CNN پیشنهاد شده است. در این پژوهش با فیلتر میان‌های و یک مرحله میانگین‌گیری از سیگنال، نویز سرگردان خط مینا و نویز ناشی از حرکت عضلات حذف شده و باعث بهبود سیگنال به نویز به اندازه ۸/۲۹ دسیبل شده است. بهم ریختگی فاصله RR در سیگنال ECG یکی از بارزترین ویژگی‌های آریتمی فیبریلاسیون دهلیزی است، لذا با هدف کاهش پیچیدگی محاسباتی رویکرد پیشنهادی، فاصله RR به جای کل نمونه‌های سیگنال الکتروکاردیوگرام به عنوان داده ورودی شبکه در نظر گرفته شده است. برای تشخیص R از یک روش مبتنی بر الگوریتم Pan-Tompkins با اعمال تغییراتی برای بهبود انطباق‌پذیری استفاده شده است. ارزیابی رویکرد پیشنهادی روی دو پایگاه Challenge 2017 و MIT-BIH AFDB انجام شده و صحت به صورت بین بیمار به ترتیب ۹۷٪ و ۹۰٪ بدست آمده است.

واژه‌های کلیدی: آریتمی فیبریلاسیون دهلیزی، حذف نویز، یادگیری عمیق، تشخیص خودکار، شبکه عصبی پیچشی، شبکه حافظه کوتاه مدت طولانی

Atrial Arrhythmia Detection Using LSTM and CNN

Tandis Bahramrad, MSc Graduated¹, Hossein Hosseini-Nejad, Assistant Professor²,

1- Faculty of Electrical Engineering, K.N. Toosi University of Technology, Tehran, Iran, Email: tbahramrad@gmail.com
2- Faculty of Electrical Engineering, K.N. Toosi University of Technology, Tehran, Iran, Email: Hosseini_nezhad@kntu.ac.ir

Abstract: Atrial Fibrillation (AFib) arrhythmia is one of the most hazardous cardiac diseases. Accurate diagnosis of this arrhythmia can prevent many strokes. In order to more accurate and early detection of this arrhythmia, automatic diagnosis is considered. In this paper, median filter and mean calculation of ECG signal were used for base line wander and muscle noise cancellation. The result of applying this method to ECG signal no.119 from MIT-BIH dataset, was 8.29 dB improvement in the SNR. Since variation in RR-interval of the ECG signal is one of the most common features of atrial fibrillation arrhythmia, RR-interval was considered as the input of algorithm instead of whole ECG signal samples. For R detection from ECG signal, Pan-Tompkins algorithm with adaptive threshold was used. Although in some other researches classic machine learning methods were utilized to detect AFib arrhythmia, deep learning method results in better accuracy, which is because of AFib detection dependency to sequential beats. Hence, in this article a deep learning network was designed using CNN and LSTM, also 10 RR-intervals were considered as the input data. The accuracy of inter-patient tests of this research on Challenge 2017 and MIT-BIH AFDB datasets were about 97% and 90%, respectively.

Keywords: Atrial Fibrillation Arrhythmia, Noise Cancellation, Deep Learning, Automatic Detection, Convolutional neural network, Long short-term memory.

تاریخ ارسال مقاله: ۱۴۰۱/۱۲/۲۰

تاریخ اصلاح مقاله: ۱۴۰۲/۰۸/۱۵

تاریخ پذیرش مقاله: ۱۴۰۲/۰۹/۱۲

نام نویسنده مسئول: حسین حسینی نژاد محبتی

نشانی نویسنده مسئول: ایران-تهران- دانشگاه صنعتی خواجه نصیرالدین طوسی- دانشکده برق - گروه الکترونیک.

۱- مقدمه

فیبریلاسیون دهلیزی یکی از مهم‌ترین اختلالات قلب محسوب می‌شود که تشخیص آن نیازمند بررسی سیگنال الکتروکاردیوگرام به مدت طولانی است [۱]. تشخیص خودکار آریتمی قلبی شامل چند مرحله است: پیش‌پردازش، قسمت بندی، استخراج ویژگی و دسته‌بندی. که در ادامه توضیح مختصری در مورد هر یک از این مراحل ارائه می‌شود.

- پیش‌پردازش: این مرحله به منظور کاهش نویز سیگنال و بهبود کیفیت آن انجام می‌شود. نویز سیگنال علاوه بر ایجاد مشکل در تشخیص انسانی، در تشخیص خودکار نیز تاثیر منفی دارد و باعث افزایش خطا در تشخیص آریتمی و کاهش دقت سیستم می‌شود. نویزهای متنوعی در سیگنال الکتروکاردیوگرام وجود دارد که نویز خط مبنا و نویز عضلات دو نویز متداول و چالش‌برانگیز است. نویز سرگردان خط مبنا که یک نویز فرکانس پایین است، در اثر تنفس بیمار بوجود می‌آید و خط مبنا سیگنال الکتروکاردیوگرام را تغییر می‌دهد. با انقباض عضلات بدن به خصوص عضلات نزدیک به الکترودهای نصب شده به بدن، نویزی بر روی سیگنال الکتروکاردیوگرام ایجاد می‌کند. این نویز متناسب با فعالیت بدنی شخص تغییر می‌کند لذا حذف آن یکی از چالش برانگیزترین مراحل در پیش‌پردازش است.

- قسمت‌بندی: در این قسمت کمپلکس QRS در سیگنال الکتروکاردیوگرام تشخیص داده می‌شود. در بعضی از مقاله‌ها، این مرحله به عنوان بخشی از مرحله‌ی استخراج ویژگی در نظر گرفته می‌شود و مرحله‌ای مستقل محسوب نمی‌شود.

- استخراج ویژگی: این مرحله در موفقیت مرحله‌ی دسته‌بندی آریتمی قلبی بسیار تاثیرگذار است و ویژگی‌های بدست آمده دقت عملکرد دسته‌بندی‌کننده را تعیین می‌کند. هر اطلاعات بدست آمده از سیگنال الکتروکاردیوگرام که مشخص‌کننده‌ی نوع ضربان قلب باشد یک ویژگی محسوب می‌شود. استخراج ویژگی روش‌های گوناگونی دارد. برای مثال با بررسی شکل سیگنال در حوزه‌ی زمان و یا فرکانس می‌توان مستقیماً از سیگنال الکتروکاردیوگرام استخراج ویژگی داشت. تکنیک‌های تبدیل حوزه سیگنال، یکی از بهترین روش‌ها در این مرحله محسوب می‌شود که ویژگی‌های ارزشمندی در اختیار می‌گذارد و باعث افزایش دقت تفکیک دسته‌ها در مرحله‌ی دسته‌بندی می‌شود [۲]. ویژگی‌های آماری مثل میانگین، کمینه و واریانس و ویژگی‌های شکل‌شناسایی مانند فاصله PR، RR، از جمله ویژگی‌های پر کاربرد در سیگنال الکتروکاردیوگرام است. اکثر اوقات ویژگی‌های استخراج شده ابعاد بزرگی دارند و همچنین بعضی از آنها کارایی لازم را برای مرحله‌ی دسته‌بندی ندارند، لذا با روش‌های مختلفی باید ابعاد ویژگی‌ها را کاهش داد.

- دسته‌بندی: در این مرحله با توجه به ویژگی‌های بدست آمده در مرحله‌ی قبل، کار دسته‌بندی داده‌ها انجام می‌شود. دسته‌بندی

به مدلی پیش‌بینی‌کننده اطلاق می‌شود که داده‌های ورودی را در دسته‌های مشخصی قرار می‌دهد. برای انجام دسته‌بندی باید مجموعه‌ای از داده‌ها را برای آموزش الگوریتم و مجموعه‌ای از داده نیز برای آزمودن آن در نظر گرفت. برای آموزش باید داده‌ی ورودی با دسته بندی مشخص وجود داشته باشد. در ادامه مروری بر پژوهش‌های انجام شده در مورد هر یک از این مراحل ارائه می‌گردد. در پژوهش Bhoi et al. [۳] عملکرد فیلترهای میانه‌ای، پایین‌گذر باترورث، پاسخ ضربه محدود، میانگین متحرک وزن‌دار و تبدیل موجک ایست (SWT) در حذف نویز از سیگنال الکتروکاردیوگرام مقایسه شده است. یکی از معیارهای سنجش عملکرد فیلتر میزان حذف فرکانس ناخواسته است فیلتر SWT بهترین عملکرد را در حذف فرکانس‌های ناخواسته را در میان دیگر فیلترها داشته است. با معیار برجستگی نیز SWT عملکرد بهتری داشت [۳]. در مقاله P. Mukherjee and A. Bakshi [۴] چند روش مختلف حذف نویز بررسی و مقایسه شده است. در این پژوهش برای حذف نویز فرکانس پایین از فیلتر فرکانس بالا با فرکانس قطع بزرگتر از ۵/۰ هرتز استفاده شده است و در ادامه فیلتر پاسخ ضربه محدود باترورث پیشنهاد می‌شود. مزیت این روش برای حذف نویز فرکانس پایین عدم وجود موج‌های کوچک در فرکانس باند توقف است [۴]. به علت حساسیت حذف نویز فرکانس بالا در این مقاله عملکرد فیلترهای مختلفی از جمله فیلتر Savitzky-Golay، هموار سازی و میانگین متحرک به ترتیب با اندازه پنجره‌های ۱۷، ۳۰ و ۱۵ بررسی شده است. همچنین فیلتر پنجره وزن‌دار متحرک، گوسی با اندازه پنجره برابر با ۷، میانه‌ای، پاسخ ضربه محدود با پنجره مستطیلی و باترورث نیز مقایسه شده‌اند. مرتبه فیلتر میانه‌ای و پاسخ ضربه محدود ۱۵ در نظر گرفته شده است و فیلتر باترورث با فرکانس قطع ۵۰ هرتز و مرتبه ۱۰ بررسی شده است. در بررسی فیلترها تابع وزن پنجره متحرک وزن‌دار گوسی استفاده شد که این فیلتر سری با فیلتر Savitzky-Golay با معیار ارزیابی سیگنال به نویز ۱۰/۳۴ دسی بل بهترین عملکرد را برای حذف نویز فرکانس بالا در مقایسه با دیگر فیلترها دارد [۴].

در تحقیق Wu et al. [۵] با ترکیب دو شبکه پیچشی و بازگشتی، شبکه‌ای عمیق طراحی شده است که آریتمی فیبریلاسیون دهلیزی را با صحت ۹۷/۰۸٪ تشخیص می‌دهد. ساختار این شبکه شامل سه لایه شبکه‌ی پیچشی و یک لایه شبکه حافظه‌ی کوتاه‌مدت طولانی است و پایگاه داده‌ی مورد استفاده در این تحقیق Physionet/Challenge 2017 است [۵].

در تحقیقی دیگر H.Dang et al. [۶] از دو شبکه‌ی پیچشی و بازگشتی به شکل ترکیب لایه‌های پیچشی در ابتدای ساختار، شبکه‌ی حافظه‌ی کوتاه‌مدت ماندگار دو طرفه در لایه‌های میانی و دو لایه‌ی تماماً متصل در انتها استفاده شده است. ورودی این شبکه‌ی عمیق ویژگی‌های

در سال ۲۰۲۱، Tutuko et al. [۱۲] برای تشخیص خودکار فیبریلاسیون دهلیزی شبکه عصبی عمیق بر پایه سیستم ابری پیشنهاد داده است. این ساختار از ۱۳ لایه شبکه پیچشی تک بعدی تشکیل شده است و تابع فعال‌سازی برای لایه‌های مخفی تابع واحد یک‌سوسه خطی و برای لایه خروجی Tanh و Sigmoid استفاده شده است. با هدف دسترس‌پذیری پزشک به تشخیص این سیستم و بررسی وضعیت بیمار، در این تحقیق ساختار پیشنهادی روی سیستم ابری پیاده‌سازی شده است. در ابتدا با استفاده از روش تبدیل موجک گسسته نوین سیگنال الکتروکاردیوگرام حذف می‌شود، سپس ۲۷۰۰ نمونه از سیگنال به عنوان ورودی به شبکه داده می‌شود. در تشخیص دو دسته ضربان سالم و دارای آریتمی فیبریلاسیون دهلیزی، صحت عملکرد این ساختار ۹۹/۸٪ اعلام شده است [۱۲].

Cao et al. [۱۳] در تحقیق خود دو شبکه MSResNet و FDResNet را پیشنهاد داده است. ورودی این شبکه‌ها سیگنال الکتروکاردیوگرام از پایگاه داده Physionet/Challenge 2017 است. خروجی این شبکه‌ها با سه ورودی متفاوت اعلام شده است. دقت عملکرد شبکه در تشخیص آریتمی فیبریلاسیون دهلیزی با سیگنال خام الکتروکاردیوگرام ۹۸/۱۶٪ است، در صورتی که سیگنال قلب با روش DWF پیش‌پردازش شود دقت شبکه به ۹۷٪ می‌رسد [۱۳].

در تحقیق Mashrur et al. [۱۴] شبکه عمیق به نام AlexNet پیشنهاد شده که با ترکیب شبکه‌های عصبی پیچشی طراحی شده است. در این تحقیق ۳۰ ثانیه سیگنال الکتروکاردیوگرام، که از پایگاه داده Physionet/Challenge 2017 گرفته شده است، با روش CWT به تصویر RGB تبدیل شده و به عنوان ورودی به شبکه پیشنهادی اعمال می‌شود. صحت تشخیص این شبکه ۹۷/۹٪ اعلام شده است [۱۴].

در پژوهش Hyo-Chang Seo et al. [۱۵] ساختار پیشنهاد شده متشکل از ResNet است و همچنین از سه پایگاه داده متفاوت با دسترسی آزاد از منبع Physionet استفاده شده است. ۱۰ ثانیه از سیگنال الکتروکاردیوگرام به عنوان داده ورودی به این شبکه داده می‌شود. بیشترین صحتی که در این پژوهش گزارش شده حدود ۹۹-۹۸٪ است و همچنین در بخش ارزیابی کمترین صحت در محدوده ۹۲-۵۳٪ اعلام شده است [۱۵].

در پژوهش Y-Y. Jo et al. [۱۶] برای تشخیص فیبریلاسیون دهلیزی ساختار پیشنهادی دو قسمت مجزا دارد که هر قسمت شامل ۴ بلوک Residual است و هر بلوک هم از ۲ لایه شبکه پیچشی ساخته شده است. ورودی کل شبکه ۱۰ ثانیه سیگنال الکتروکاردیوگرام است. یک بخش ویژگی P سیگنال و بخش دیگر بهم‌ریختگی R-R سیگنال را بررسی می‌کند. خروجی این دو بخش توسط دو لایه تماماً متصل بهم ترکیب می‌شود. معیار ارزیابی عملکرد شبکه پیشنهادی در این پژوهش AUC است که در محدوده ۰/۹۹-۰/۹۶ برای پایگاه داده‌های متفاوت اعلام شده است [۱۶].

استخراج‌شده از سیگنال الکتروکاردیوگرام پایگاه داده MIT-BIH است که به صورت دو دسته مجزا به شبکه وارد می‌شوند. دسته اول اندازه قله‌ی R در سیگنال الکتروکاردیوگرام و دسته دوم ویژگی‌های P، QRS و T است. صحت خروجی این شبکه پیشنهادی هنگام آموزش ۹۹/۹۴٪ و برای آزمودن ۹۶/۵۹٪ گزارش شده است [۶].

پژوهش G. Petmezas et al. [۷] نیز از ترکیب دو شبکه عصبی پیچشی و بازگشتی برای طراحی شبکه عمیق استفاده کرده است. ساختار این شبکه دارای ۱۳ لایه مخفی، شامل ۳ لایه شبکه عصبی پیچشی و سپس شبکه حافظه کوتاه‌مدت طولانی است با این تفاوت که شبکه عصبی پیچشی برای استخراج ویژگی در ابتدای ساختار قرار گرفته است. در این تحقیق برای حل مشکل عدم تعادل داده‌ها، روش یادگیری فدراسیون نیز به کار رفته است. برای داده‌های ورودی ابتدا قسمت R سیگنال الکتروکاردیوگرام، از پایگاه داده MIT-BIH، تشخیص داده می‌شود. سپس ۲۵۰ میلی‌ثانیه قبل از R و ۵۰۰ میلی‌ثانیه بعد از آن به عنوان کل ضربان در نظر گرفته می‌شود [۷].


در تحقیق Zhang et al. [۸] نیز از ترکیب دو شبکه عصبی پیچشی و حافظه کوتاه‌مدت طولانی استفاده شده است. با این تفاوت که در این ساختار پیشنهادی شبکه حافظه کوتاه‌مدت طولانی در ابتدا شبکه قرار دارد و خروجی این قسمت به عنوان ورودی به شبکه عصبی پیچشی، که شامل ۳ بلوک شبکه عصبی پیچشی است، داده می‌شود. بعد از اعمال روش‌های حذف نویز بر روی سیگنال الکتروکاردیوگرام، ۱۰ ثانیه از آن به عنوان ورودی به شبکه داده می‌شود. صحت عملکرد این ساختار به طور متوسط بر سه پایگاه داده مجزا حدوداً ۹۵/۶۵٪ است [۸]. در تحقیق Ziqian Wu et al. [۹] ۱۰ ثانیه سیگنال الکتروکاردیوگرام از پایگاه داده MIT-BIH با روش تبدیل موجک پیوسته به تصویر تبدیل شده است. سپس ساختاری تشکیل شده از ۴ بلوک پیشنهاد شده که هر بلوک شامل دو لایه شبکه عصبی پیچشی است. این شبکه عمیق پیشنهادی با صحت ۹۷/۵۶٪ قابلیت تشخیص آریتمی فیبریلاسیون دهلیزی را دارد [۹]. تحقیق Hsieh et al. [۱۰] شبکه‌ای با ۱۰ بلوک شبکه عصبی پیچشی ارائه داد و همچنین از پایگاه داده Physionet/Challenge 2017 استفاده کرده است. ورودی شبکه مدت زمان ثابتی از سیگنال الکتروکاردیوگرام ثابت است. شبکه تحت آموزش با استفاده از تابع زیان، بازخورد خواهد داشت که توسط آن عملکرد خود را اصلاح می‌کند. در این مقاله نحوه عملکرد با معیار ارزیابی امتیاز F1، ۷۸/۲٪ اعلام شده است [۱۰].

در پژوهشی دیگر، Chen et al. [۱۱] از روش استخراج ویژگی چندگانه و شبکه عصبی پیچشی استفاده کرده است. پایگاه‌های داده به کار رفته در این پژوهش شامل MIT-BIH، QT، AHA، CSE است. در این تحقیق ابتدا ویژگی‌های سیگنال الکتروکاردیوگرام استخراج شده و سپس به عنوان ورودی به شبکه عصبی پیچشی داده می‌شود. صحت تشخیص این روش ۹۸/۹۳٪ اعلام شده است [۱۱].

منجر به کاهش تعداد مقایسه و افزایش سرعت اجرای الگوریتم می‌شود.

در روش پیشنهادی پردازش دیگری برای حذف نویز بر روی سیگنال خروجی اعمال کردیم، به این صورت که از هر نمونه و ۷ نمونه قبلی آن (مجموعاً ۸ نمونه) میانگین گرفته می‌شود. همچنین پیاده‌سازی سخت افزاری میانگین ۸ نمونه به دلیل این که توانی از ۲ است پیچیدگی محاسباتی کمی دارد.

برای آزمودن فیلتر پیشنهادی از دو سیگنال بدون نویز پایگاه داده MIT-BIH با شماره‌های ۱۱۸ و ۱۱۹ استفاده شد. ابتدا دو نویز سرگردان خط مبنا و نویز عضلات از همین پایگاه داده به آن‌ها اضافه شد. سپس فیلتر پیشنهادی بر آن‌ها اعمال شد. سیگنال به نویز به ترتیب برای سیگنال ۱۱۸ مقدار ۵/۹۸ دسیبل و برای سیگنال ۱۱۹ مقدار ۸/۲۹ دسیبل بهبود یافت. در شکل نتیجه حذف نویز فیلتر پیشنهادی بر سیگنال ۱۱۹ نشان داده شده است.



شکل ۱: سیگنال شماره ۱۱۹ پایگاه داده MIT-BIH و نتیجه اعمال فیلتر پیشنهادی بر آن

۳-۲- الگوریتم تشخیص قله R

یکی از مهم‌ترین ویژگی‌های آریتمی فیبریلاسیون دهلیزی بهم‌ریختگی فاصله R-R در سیگنال است. از این رو قله R را به عنوان یک ویژگی مهم از سیگنال الکتروکاردیوگرام استخراج می‌کنیم. یکی از پرکاربردترین روش‌هایی که برای تشخیص R ارائه شده الگوریتم Pan-Tompkins است. در این مقاله از روشی بر پایه این الگوریتم استفاده شده اما جهت بهبود پاسخ، تغییراتی در آن ایجاد کرده که در ادامه تشریح می‌شود. در سیگنال ECG مشخص است که قسمت QRS از باقی قسمت‌های سیگنال بزرگ‌تر و شیب بیشتری دارد. با توجه به این موضوع ابتدا با محاسبه مشتق سیگنال، این قسمت از بقیه برجسته‌تر می‌شود. در شکل سیگنال اصلی شماره ۱۰۰ پایگاه داده MIT-BIH آمده که الگوریتم پیشنهادی روی آن اعمال شده است.

در پژوهش‌های پیشین از تمام نمونه‌های سیگنال الکتروکاردیوگرام و یا چند ویژگی مهم به عنوان ورودی به شبکه استفاده شده که منجر به پیچیده شدن شبکه‌های عمیق مورد استفاده می‌شود. در این پژوهش فقط با استفاده از فاصله RR به عنوان ورودی شبکه عمیق طراحی شده با ترکیب LSTM و CNN آریتمی فیبریلاسیون دهلیزی تشخیص داده می‌شود.

۲- رویکرد پیشنهادی

در این بخش رویکردی برای تشخیص آریتمی فیبریلاسیون دهلیزی پیشنهاد می‌شود. ابتدا پایگاه داده استفاده شده، سپس پیش پردازش و بعد معماری شبکه عمیق پیشنهادی معرفی می‌شوند.

۲-۱- پایگاه داده

در این پژوهش از دو پایگاه داده MIT-BIH AFDB و Challenge 2017 استفاده شده است [۱۷]. پایگاه داده MIT-BIH AFDB به صورت اختصاصی شامل سیگنال‌ها با آریتمی دهلیزی است که با فرکانس ۲۵۰ هرتز تبدیل به دیجیتال شده است. پایگاه داده Challenge 2017 شامل سیگنال‌های افرادی است که با دستگاه AliveCor با فرکانس نمونه‌برداری ۳۰۰ هرتز ثبت شده است و شامل ۴ دسته سیگنال عادی، دارای آریتمی فیبریلاسیون دهلیزی، نویزدار و غیره است [۱۸]. در این پایگاه داده هر سیگنال مربوط به شخص مجزایی است.

۲-۲- پیش‌پردازش

در این قسمت روش استفاده شده برای حذف نویزها به ویژه نویز سرگردان خط مبنا و همچنین الگوریتم محاسبه فاصله RR معرفی می‌شود. کدهای الگوریتم‌های این قسمت با استفاده از نرم‌افزار MATLAB نوشته شده است.

فیلتر میانه‌ای یک فیلتر غیرخطی است که براساس میانه گرفتن از نمونه‌ها داخل پنجره کار می‌کند. این پنجره سرتاسر سیگنال حرکت می‌کند و خروجی فیلتر هم‌اندازه سیگنال اصلی است.

در روش پیشنهادی دو فیلتر میانه‌ای سری برای حذف نویز سرگردان خط مبنا استفاده شده است. فیلتر اول با مرتبه ۲۰۰ و فیلتر دوم با مرتبه ۲۰۱ طراحی شده است. به این معنا که در فیلتر اول از هر ۲۰۰ نمونه میانه گرفته می‌شود و خروجی به فیلتر میانه‌ای دوم داده می‌شود که از هر ۲۰۱ نمونه میانه می‌گیرد. مکانیزم پیاده سازی فیلتر میانه به این شکل است که با در نظر گرفتن ۲۰۱ داده اول، به صورت معمول به ترتیب کوچک به بزرگ مرتب می‌شود از آن به بعد هر داده ورودی ابتدا با میانه قبلی مقایسه می‌شود، اگر بزرگ‌تر بود با چارک سوم و اگر کوچک‌تر بود با چارک اول مقایسه می‌شود و این روند تا آنجا ادامه دارد که جای داده جدید مشخص شود. در حالت بیشینه با ۸ مقایسه مرتب‌سازی انجام می‌شود و این مساله

شکل ۵: نتیجه انتگرال گرفتن از مشتق دوم سیگنال

الکتروکاردیوگرام

عرض این پنجره وابسته به فرکانس نمونه برداری سیگنال الکتروکاردیوگرام است. لذا روش پیشنهادی برای هر سیگنال الکتروکاردیوگرامی با هر فرکانس نمونه برداری مناسب است. مقدار مناسب عرض پنجره استفاده شده به صورت تجربی و پس از آزمون پنجره های مختلف، از رابطه (۱) به دست آمد که fs فرکانس نمونه برداری و W عرض پنجره است. همچنین در محاسبه عرض پنجره با تقسیم کردن فرکانس نمونه برداری بر عدد ۱۶، محاسبات سخت افزاری ساده تر و با سرعت بالاتری انجام می شود.


$$W = fs/16 \quad (1)$$

پس از اعمال انتگرال با استفاده از رابطه (۲) روی پنجره با عرض مشخص شده، شکل ۶ به دست می آید. در انتها با استفاده از آستانه قابل انطباق قله R تشخیص داده می شود. مقدار ابتدایی این آستانه از ۴ ثانیه اولیه انتگرال ECG طبق رابطه (۳) بدست می آید. در این معادله min تابع کمینه و $mean$ تابع میانگین است، همچنین ECG integral از رابطه (۲) بدست می آید. پس از محاسبه مقدار اولیه آستانه، با تشخیص هر قله R در سیگنال این آستانه با استفاده از رابطه (۴) به روزرسانی می شود (شکل ۶).


$$ECG_INTEGRAL(i) = \sum_{t=i-window}^i ECG_diff^2(t) \quad (2)$$

$$Adaptive\ R_{Threshold} = \min(0.1, \frac{\sum_{i=0}^{4*fs} ECG(i)}{4 * fs}) \quad (3)$$

$$Adaptive\ R_{Threshold} = \max(\frac{13 * last\ Adaptive\ R_{Threshold}}{16}, \frac{\max(ECG_{integral})}{2}) \quad (4)$$




شکل ۶ شکل مشکی رنگ سیگنال اصلی الکتروکاردیوگرام، شکل آبی رنگ حاصل انتگرال از مشتق دوم سیگنال و شکل قرمز رنگ آستانه قابل انطباق است که با توجه به هر R تغییر می کند. اگر اندازه پنجره درست انتخاب شده باشد بازه ای که انتگرال بیشتر از آستانه قرار می گیرد بازه QRS ها است. در نهایت مقدار بیشینه در این





شکل ۲: سیگنال اصلی الکتروکاردیوگرام از پایگاه داده MIT-BIH

نمونه شماره ۱۰۰

پس از مشتق گرفتن از سیگنال الکتروکاردیوگرام قسمتی از R شیب مثبت و بخش دیگر شیب منفی پیدا می کند (شکل ۶)، لذا برای مثبت کردن شیب منفی و همچنین کم کردن تاثیر نویز، توان ۲ سیگنال محاسبه می شود (شکل ۷).




شکل ۳: مشتق اول سیگنال الکتروکاردیوگرام




شکل ۴: مقایسه مشتق اول سیگنال الکتروکاردیوگرام (الف) و مربع آن (ب)


پس از به توان ۲ رساندن سیگنال در ناحیه نقطه ای R دو قله رخ داده است. حال یک پنجره با عرض مشخصی روی این مربع مشتق لغزاند و انتگرال داده های داخل پنجره محاسبه می شود. (شکل ۸).



مورد نیاز برای آموزش شبکه برای هر دوره حدوداً ۱ دقیقه بود و صحت آموزش حدوداً ۹۷٪ بدست آمد (شکل). نتیجه با ورودی ۳۰ ثانیه از ۱۰ ثانیه بهتر بود ولی به همان میزان زمان آموزش نیز افزایش یافت. به دلیل سرعت پایین و پیچیدگی بالای این ساختار پیشنهاد شد که به جای تمام سیگنال از ویژگی مهم سیگنال که وجه تمایز سیگنال دارای آریتمی با سیگنال نرمال است، استفاده شود.



شکل ۸: طراحی شبکه CNN با ورودی سیگنال کامل ECG




شکل ۹: طراحی شبکه ترکیبی LSTM و CNN با ورودی سیگنال کامل ECG

بهم‌ریختگی فاصله RR چندین ضربه متوالی یکی از نشانه‌های آریتمی فیبریلاسیون دهلیزی است. بنابراین ۱۰ فاصله RR از یک سیگنال الکتروکاردیوگرام به عنوان ورودی در نظر گرفته شد. ساختار دیگری فقط با استفاده از CNN و بدون استفاده از LSTM طراحی شد. در این ساختار صحت بالای ۹۰٪ با استفاده از حدود ۱۰ الی ۳۰ لایه CNN حاصل می‌شد که همچنان پیچیدگی شبکه بالا بود.

در نهایت به دلیل اهمیت توالی RR ها برای تشخیص آریتمی فیبریلاسیون دهلیزی، در لایه اول از شبکه LSTM با تعداد واحد ۲۰۰ و تابع فعال‌سازی tanh استفاده شد. در این حالت به دلیل ساده بودن ورودی شبکه نیازی به استفاده از لایه MaxPooling نیست. علت استفاده از تابع فعال‌ساز tanh متقارن بودن آن اطراف صفر است در صورتی که این موضوع در مورد تابع فعال‌ساز ReLU صدق نمی‌کند. به همین دلیل هنگام استفاده از تابع فعال‌ساز ReLU مشکل "Dead ReLU" به وجود می‌آید. در مواجهه با این مشکل نورون تحت آموزش دیگر آموزش نمی‌بیند و فقط خروجی صفر را تولید می‌کند. حتی این مشکل در طراحی‌های RNN به مراتب بدتر هم می‌شود. همچنین tanh عموماً در شبکه‌هایی برای تشخیص دو کلاس استفاده می‌شود، لذا تابع فعال‌ساز tanh یک انتخاب مناسب برای این طراحی است. در لایه‌های بعد، از ۳ لایه شبکه پیچشی یک بعدی استفاده شده است.

بازه محاسبه می‌شود که نماینده R می‌باشد. شکل ۷ تشخیص R را نشان می‌دهد. نکته قابل توجه در این روش استفاده از تقسیم‌های توان‌های ۱۲ ست که پیاده‌سازی سخت‌افزاری آن را به مراتب ساده‌تر می‌کند.



شکل ۷: نتیجه تشخیص R (نقاط قرمز)، با استفاده از روش پیشنهادی

۲-۴- شبکه یادگیری عمیق

در این پژوهش از ترکیب دو شبکه بازگشتی و پیچشی برای تشخیص AFib بودن یا نبودن استفاده شده است. یکی از راه‌های تشخیص آریتمی فیبریلاسیون دهلیزی براساس بهم‌ریختگی فاصله RR چندین ضربه متوالی است. بنابراین ورودی شبکه پیشنهادی نهایی به میزان ۱۰ فاصله RR از یک سیگنال الکتروکاردیوگرام در نظر گرفته شده است. این بخش پژوهش با استفاده از Keras از کتابخانه TensorFlow در پایتون پیاده‌سازی شده است.

ابتدا ورودی شبکه تک ضربه در نظر گرفته شد. شبکه‌ای با ۹ لایه CNN طراحی شد که صحت آموزش ۸۹٪ الی ۹۰٪ بدست آمد. در ادامه شبکه‌ای با ترکیب CNN و LSTM طراحی شد که با ورودی تک ضربه، صحت آموزش آن بالاتر از ۹۰٪ نشد. همچنین نتیجه صحت آزمون بر این شبکه‌ها در حدود ۸۰٪ بدست آمد که نتیجه مطلوبی نبود. بنابراین لزوم استفاده از چند ضربه متوالی از سیگنال برای تشخیص آریتمی فیبریلاسیون دهلیزی مشخص شد.

در ادامه از کل سیگنال ECG به عنوان ورودی استفاده شد و شبکه‌ای متشکل از ۱۰ لایه CNN با MaxPooling آزموده شد که با ورودی ۱۰ و ۳۰ ثانیه سیگنال ECG صحت آموزش حدوداً ۹۵٪ بدست آمد (شکل ۸). قابل ذکر است که نتیجه با ورودی ۳۰ ثانیه مطلوب‌تر بود ولی نسبت به ورودی ۱۰ ثانیه زمان آموزش بیشتری داشت. سپس شبکه‌ای با ترکیب LSTM با تعداد واحد ۵۰۰ و ۳ لایه CNN با تعداد فیلتر ۲۵۶ طراحی شد. لایه LSTM به دلیل اهمیت توالی نمونه‌های ورودی نقش به‌سزایی در تشخیص آریتمی فیبریلاسیون دهلیزی دارد. در این ساختار به دلیل استفاده از کل سیگنال به عنوان ورودی، به لایه MaxPooling برای کاهش ابعاد و پیچیدگی نیاز شد. با این وجود زمان

	ویک ضربان				
G. Petmezas et al. [۷]	یک ضربان	MIT-BIH AF	Normal, AFIB, AFlutter, J	CNN-LSTM	صحت=۹۷/۸۷٪
Zhang et al. [۸]	۱۰ ثانیه ECG	Challenge 2017, MIT-BIH, Wearable Device	AF, non-AF	LSTM-CNN	صحت=۹۶/۲۳٪
Ziqian Wu et al. [۹]	۱۰ ثانیه ECG دوبعدی	MIT-BIH	Normal, AF, Noise, Others	CNN	صحت=۹۷/۵۶٪
Hsieh et al. [۱۰]	۱۰ ثانیه ECG دوبعدی	Challenge 2017	Normal, AF, Noise, Others	CNN	F1=۷۸/۲
Chen et al. [۱۱]	سیگنال ECG	Challenge 2017	Normal, AF	CNN	صحت=۹۸/۹۲٪
Tutuko et al. [۱۲]	۲۰۰۰ نمونه ECG	MIT-BIH	Normal, AF, non-AF	CNN	صحت=۹۸/۹۴٪
Cao et al. [۱۳]	سیگنال ECG	Challenge 2017, MIT-BIH AF	Normal, AF, Noise, Others	FDResNet, MSResNet	صحت=۸۷/۱۲٪ صحت=۹۷/۹٪
Mashrur et al. [۱۴]	۳۰ ثانیه ECG دوبعدی	Challenge 2017	Normal, AF	AlexNet	صحت=۹۷/۹٪
Hyo-Chang Seo et al. [۱۵]	۱۰ ثانیه ECG	Challenge 2017	AF, non-AF	ResNet	صحت=۹۹-۹۸٪
Y-Y. Jo et al. [۱۶]	RR interval و یک ضربان	Challenge 2017	AF, non-AF	ResNet	صحت=۹۷/۲٪


۳- نتیجه گیری

در این پژوهش برای تشخیص آریتمی فیبریلاسیون دهلیزی دو مرحله پیش پردازش و دسته بندی با شبکه یادگیری عمیق بر روی سیگنال الکتروکاردیوگرام انجام شد. مرحله پیش پردازش شامل حذف نویز و تشخیص قسمت R می شود. فیلتر میانه و همچنین روش میانگین گیری برای حذف نویز عضلات و سرگردان خط مبنا پیشنهاد داده شد که عملکرد مطلوبی بر روی سیگنال پایگاه داده داشت. برای تشخیص R از سیگنال الکتروکاردیوگرام، روش مرسوم Pan-Tompkins اصلاح و استفاده شد. در آخر برای تشخیص دو دسته سیگنال با آریتمی فیبریلاسیون دهلیزی و بدون آن، شبکه های ترکیبی از LSTM و CNN با ورودی ۱۰ فاصله RR متوالی پیشنهاد شد. صحت تشخیص در هنگام آموزش ۹۹/۸٪ و آزمون در محدوده ۹۶-۹۰٪ نتیجه شد. استفاده از ورودی ساده تر و با ابعاد کمتر باعث پیچیدگی کمتر در شبکه طراحی شده می شود و در عین حال روش پیشنهادی از صحت تشخیص مطلوبی برخوردار است. پیشنهاد می شود در کارهای آینده تعداد آریتمی های قابل تشخیص افزایش پیدا کند و همچنین تلاش شود تا صحت الگوریتم ارتقاء پیدا کند.

مراجع

[1] A. Goldberger, *Goldberger's clinical electrocardiography*, 2017.

تعداد فیلتر و اندازه کرنل هر سه لایه به ترتیب ۱۲۸ و ۷ در نظر گرفته شده است. گام دو لایه اول ۲ و لایه آخر ۱ گذاشته شد. تابع فعال سازی این سه لایه نیز tanh است و برای نرمال سازی ورودی هر لایه از Batch Normalization استفاده شد. ابعاد خروجی لایه CNN با ابعاد ورودی لایه تماماً متصل مطابقت ندارد و نیاز به تغییر ابعاد است. بنابراین لایه Flatten ابعاد خروجی لایه های قبل را تغییر داده و برای لایه تماماً متصل آماده می کند. در لایه آخر که قرار است بین دو کلاس AFib بودن یا نبودن تصمیم گیری شود، از Softmax استفاده شد (شکل ۱۰).



شکل ۱۰: ساختار کلی شبکه عمیق پیشنهادی، ترکیبی از LSTM و

CNN با ورودی ۱۰ فاصله RR

روش بهینه سازی به کار رفته در این ساختار، Adam با نرخ یادگیری ۰/۰۰۱ است و شبکه طراحی شده با ۹۵٪ داده های Challenge 2017 در اندازه دسته ۲۰ و دوره ۳۰۰ آموزش دید. زمان آموزش هر دوره نیز حدود ۱ الی ۲ ثانیه بود.

در این پژوهش با استفاده از ورودی با ابعاد بسیار کم تر از سایر پژوهش ها و شبکه ای به نسبت ساده تر، آریتمی فیبریلاسیون دهلیزی بالای ۹۰ درصد به صورت بین بیمار در مرحله آزمایش به درستی تشخیص داده می شود. این روش به نرخ نمونه برداری یا دستگاه ثبت سیگنال وابسته نیست.

۲-۵- مقایسه با سایر پژوهش ها

در جدول ۱ نتیجه رویکرد پیشنهاد شده با پژوهش های مشابه مقایسه شده است. همان گونه که مشاهده می شود، ورودی شبکه پیشنهاد شده در این پژوهش، بسیار ساده تر از دیگر پژوهش هاست. لذا شبکه طراحی شده گرچه دقت آن مختصری کمتر از بعضی از پژوهش ها است اما با داده کمتری قابلیت تشخیص دارد و همچنین شبکه ساده تر و سرعت بالاتری دارد.

جدول ۱ جدول مقایسه ساختاری پیشنهادی با پژوهش های مشابه

خروجی	ساختاری پیشنهادی	کلاس های تشخیص داده شده	پایگاه داده	ورودی	پژوهش
صحت=۹۷٪	CNN-LSTM	AF, non-AF	Challenge 2017, MIT-BIH AF, Wearable Device	۱۰ فاصله RR	پژوهش پیشنهادی
صحت=۹۷/۰۸٪	CNN-LSTM	AF, non-AF	Challenge 2017	سیگنال ECG	Wu et al. [۵]
صحت=۹۹/۹۴٪	CNN-BLSTM	AF, non-AF	MIT-BIH AF	RR interval	H. Dang et al. [۶]

- [10] Chaur-Heh Hsieh, *Detection of Atrial Fibrillation Using 1D Convolutional Neural Network*, Sensors, 2020.
- [11] Xianjie Chen, *Atrial fibrillation detection based on multi-feature extraction and convolutional neural network for processing ECG signals*, Computer Methods and Programs in Biomedicine, 2021.
- [12] Bambang Tutuko, *AFibNet: an implementation of atrial fibrillation detection with convolutional neural network*, BMC Medical Informatics Decision Making, 2021.
- [13] B. Cao, *Atrial Fibrillation Detection Using an Improved Multi-Scale Decomposition Enhanced Residual Convolutional Neural Network*, pp. 89152-89161, 2019.
- [14] D. Mashrur, *Automatic Identification of Arrhythmia from ECG Using AlexNet Convolutional Neural Network*, 4th International Conference on Electrical Information and Communication Technology (EICT), 2019.
- [15] Hyo Chang Seo, *ECG data dependency for atrial fibrillation detection based on residual networks*, Scientific Report, 2021.
- [16] Yong-Yeon Jo a, *Explainable artificial intelligence to detect atrial fibrillation using electrocardiogram*, International Journal of Cardiology, 2020.
- [17] G. Goldberger, *{PhysioBank, PhysioToolkit, and PhysioNet}: Components of a New Research Resource for Complex Physiologic Signals*, Circulation, 2000.
- [18] Gari D Clifford, *AF Classification from a Short Single Lead ECG Recording: the PhysioNet/Computing in Cardiology Challenge 2017*, Computing in Cardiology (CinC), 2017.
- [2] S. Berkaya, *A survey on ECG analysis*, Biomedical Signal Processing and Control, 2018.
- [3] A. K. Bhoi, *Multidimensional Approaches for Noise Cancellation of ECG signal* International Conference on Nonlinear Dynamics and Applications, 2022.
- [4] A. B. Pranoy Mukherjee, *System for ECG Signal Denoising*, International Conference on Communication and Signal Processing, 2020.
- [5] G. Wu, *Automatic atrial fibrillation detection from short ECG signals: A hybrid deep learning approach*, IISE Transactions on Healthcare Systems Engineering, pp. 1-19, 2021.
- [6] S. M. Dang H, *A Novel Deep Arrhythmia-Diagnosis Network for Atrial Fibrillation Classification Using Electrocardiogram Signals*, IEEE Access, pp. 75577-75590, 2019.
- [7] Georgios Petmezas a, *Automated Atrial Fibrillation Detection using a Hybrid CNN-LSTM Network*, Biomedical Signal Processing and Control, 2021.
- [8] Xiangyu Zhang, *Over-fitting suppression training strategies for deep learning-based atrial fibrillation detection*, Medical & Biological Engineering & Computing, 2021.
- [9] Ziqian Wu, *A Deep Learning Method to Detect Atrial Fibrillation Based on Continuous Wavelet Transform*, 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2019.