



الگوریتم PiCA-ESN و تبدیل Stockwell

سارا میهن‌دوست

استادیار گروه مهندسی برق، دانشکده فناوری‌های صنعتی، دانشگاه صنعتی ارومیه، ارومیه، ایران

چکیده

فیبریلاسیون دهلیزی (AF) شایع‌ترین نوع آریتمی قلبی است که با ایجاد بی‌نظمی در ضربان قلب همراه است. مطالعات بالینی نشان می‌دهند که بیماران مبتلا به AF اغلب علائم قابل مشاهده‌ای در طول فیبریلاسیون دهلیزی ندارند؛ از این رو، تشخیص این بیماری برای پزشک متخصص دشوار است. تشخیص خودکار AF با استفاده از سیگنال الکتروکاردیوگرام (سیگنال ECG) به پزشک معالج در تشخیص کمک بسزایی می‌کند و خطر ابتلا به بیماری‌های حاد قلبی و سکته مغزی را کاهش می‌دهد. در این مقاله، رویکردی جدید به منظور استخراج سیگنال فیبریلاتور دهلیزی (موج f) از سیگنال ECG با استفاده از الگوریتم PiCA-ESN و آنالیز زمان-فرکانس آن توسط تبدیل Stockwell برای طبقه‌بندی AF پایان‌یافته و پایان‌نیافته پیشنهاد شده است. ابتدا سیگنال فیبریلاتور دهلیزی (موج f) از سیگنال ECG استخراج شده و پس از آن تصویر زمان-فرکانس موج f با استفاده از تبدیل Stockwell به دست می‌آید؛ در ادامه، دامنه تصویر زمان-فرکانس Stockwell توسط ویژگی‌های مختلف بازتوصیف و به ترکیب ۳ طبقه‌بند اعمال می‌شود. به علاوه در این مطالعه آزمایش جدیدی برای بررسی پایداری ویژگی‌ها در طول سیگنال پیشنهاد شده است. این مطالعه بر روی پایگاه داده فیزیوت پیاده‌سازی شده و نتایج به دست آمده نشان می‌دهند که روش پیشنهادی عملکرد بهتری در مقایسه با روش‌های برگزیده چالش فیزیوت با دستیابی به دقت ۱۰۰ درصد دارد.

واژگان کلیدی: سیگنال الکتروکاردیوگرام (ECG)، فیبریلاسیون دهلیزی (AF)، موج f، الگوریتم PiCA-ESN، تبدیل Stockwell (تبدیل S).

Atrial Fibrillation Classification Using PiCA-ESN Algorithm and Stockwell Transform

Sara Mihandoost

Assistant Professor of Department of Electrical Engineering, Urmia University of Technology, Urmia, Iran.

Abstract

Atrial fibrillation (AF) is a prevalent cardiac arrhythmia characterized by irregular heartbeats, often without noticeable symptoms in patients. Diagnosing AF is challenging for cardiologists, requiring advanced methods for accurate identification using electrocardiogram (ECG) signals. Automated AF diagnosis can significantly aid cardiologists in prompt identification, potentially reducing the risks associated with acute heart disease and stroke. Various non-invasive techniques based on ECG signal processing have been suggested to better understand the mechanisms by analyzing the atrial fibrillatory waves (f-waves). Different signal processing methods for f-wave extraction have been explored, which may be classified as follows: average beat subtraction and its advanced variants, QT-interval interpolation, principal and independent component analysis, nonlinear adaptive filtering using an echo state network, diffusion geometry, and extended Kalman filtering. This study aims to extract the f-wave from the ECG signal using the PiCA-ESN algorithm, which yields better results compared to other

* Corresponding author

* نویسنده عهده‌دار مکاتبات

methods. Additionally, the f-wave's time-frequency behavior was analyzed using the Stockwell transform to differentiate between terminated and non-terminated AF states for the first time in this study. First, the PiCA-ESN algorithm facilitated the extraction of the f-wave from the ECG signal. Subsequently, the Stockwell transform was used to compute the time-frequency maps of the extracted f-wave. Various features were derived from the amplitude of the Stockwell transform and utilized in conjunction with three classifiers: MLP, SVM, and AdaBoost. The findings reveal that the proposed method outperforms selected methodologies from the Physionet Challenge 2004, achieving an impressive 100% accuracy in both tasks. Additionally, an experiment was conducted to assess the robustness of the proposed features across consecutive signal segments, validating their stability during signal analysis.

Keywords: Electroencephalogram (ECG), Atrial fibrillation (AF), f-wave, PiCA-ESN algorithm, Stockwell transform (S transform).

۱- مقدمه

فیبریلاسیون دهلیزی (AF^۱) با شیوع ۱۰ درصد در جمعیت بالای هفتاد سال، شایع‌ترین آریتمی قلبی است [۱] که تنها در ایالات متحده بیش از دویلمیون نفر از ابتلا به آن رنج می‌برند [۲]. AF موجب ایجاد بی‌نظمی در دپلاریزاسیون دهلیزها و متعاقب آن سبب کاهش توانایی دهلیزها در تخلیه خون به بطن‌ها و در نتیجه اختلال در عملکرد قلب می‌شود. AF با افزایش خطر نارسایی قلبی و تولید لخته‌های خون خطر سکتة مغزی را نیز افزایش می‌دهد [۳].

AF را می‌توان به سه دسته مختلف تقسیم‌بندی کرد؛ ۱- AF حمله‌ای^۲ که ظرف مدت هفت‌روز خودبه‌خود خاتمه می‌یابد. ۲- AF مداوم^۳ که به کمک مداخلات پزشکی پایان می‌یابد. ۳- AF دائمی^۴ که در آن ریتم سینوسی قابل بازبایی نیست [۴]. مطالعه AF حمله‌ای و شناسایی مکانیسم‌های شروع و خاتمة آن به‌درک بهتر پاتوفیزیولوژیک آریتمی AF و در نتیجه درمان مؤثرتر آن کمک بسزایی می‌کند.

از آنجاکه سازوکار پاتوفیزیولوژیک AF هنوز کامل شناخته‌شده نیست، تجزیه و تحلیل دستی ریتم پیوستة سیگنال‌های ECG^۵ زمان‌بر و پیچیده است. در سال‌های گذشته میزان پژوهش‌های متمرکز برای تشخیص خودکار AF افزایش یافته است [۵]. روش‌های غیرتهاجمی مختلفی برای تشخیص AF با استفاده از سیگنال‌های ECG پیشنهاد شده است که اغلب از تجزیه و تحلیل موج f (f-wave^۶) بهره برده‌اند. سیگنال فیبریلاتور دهلیزی (موج f) سیگنالی نامنظم با دامنة بسیار اندک (در مقایسه با دامنة سیگل PQRST قلبی) است که در اثر بی‌نظمی انقباض‌های دهلیزی در سیگنال ECG فرد مبتلا به AF مشاهده می‌شود؛ به‌طوری‌که، دیگر پیک‌های P قابل‌شناسایی نیستند و در موج

f پنهان می‌شوند. همان‌طور که پیش‌تر اشاره شد؛ به‌دلیل این‌که امواج f دامنة بسیار کوچک‌تری نسبت به دامنة کمپلکس‌های QRST در سیگنال ECG دارند، بهتر است که ابتدا موج f از سیگنال ECG استخراج شود تا رفتار آن مؤثرتر مورد بررسی قرار گیرد. روش‌های مختلفی برای استخراج موج f پیشنهاد شده است که در کل به‌صورت زیر طبقه‌بندی می‌شوند: درون‌یابی فاصله QT [۶-۷]، تفریق ضربان متوسط^۷ [۸] و انواع توسعه‌یافته آن [۹-۱۰]، پالایة تطبیقی غیرخطی با استفاده از شبکه عصبی [۱۱-۱۲]، تجزیه و تحلیل مؤلفه‌های اصلی و مستقل [۱۳-۱۵]، هندسة ترکیبی [۱۶] و پالایة کالمن توسعه‌یافته [۱۷]؛ در این میان، روش‌های مبتنی بر تفریق ضربان متوسط مورد استقبال بیشتری قرار گرفته‌اند. پس از استخراج موج f ویژگی‌های مختلفی برای توصیف آن و طبقه‌بندی AF پیشنهاد شده است که از مهم‌ترین آن‌ها می‌توان به موارد زیر اشاره کرد: [۱۸-۱۹] ویژگی‌های فرکانسی را برای تشخیص AF پیشنهاد کرده‌اند، [۲۰] ویژگی‌های دامنة موج f را با استفاده از بزرگی هارمونیک‌ها مشخص می‌کند، [۲۱] روش مدل پیش‌بینی چندمتغیره مبتنی بر رگرسیون ترابری را برای مدل‌کردن امواج f به‌کار گرفته است، در [۲۲] موج f با استفاده از روش تجزیه مد ذاتی آنالیز شده است، [۲۳] از ویژگی‌های دامنة موج f و چگالی طیف توان آن بهره برده است. در مطالعه دیگر [۲۴] از ویژگی‌های آماری، هندسی، دامنة فرکانس و پوانکاره^۸ استفاده شده است. [۲۵] ویژگی‌های مبتنی بر مدل آنتروپی شرطی تصحیح‌شده و رگرسیون خودکار را به‌کار گرفته و در [۲۶] از تبدیل چرپلت^۹ و شبکه عصبی عمیق کانولوشنی استفاده شده است.

همان‌طور که مشاهده می‌شود در سال‌های گذشته، تلاش‌های ارزنده‌ای در زمینه آنالیز سیگنال‌های ECG به‌منظور تشخیص خودکار AF انجام شده که تمرکز اغلب آن‌ها بر روی استخراج موج f و آنالیز محتویات زمانی و

¹ Atrial Fibrillation

² Paroxysmal AF

³ Persistent AF

⁴ Permanent AF

⁵ Electroencephalogram

⁶ Atrial fibrillatory signal

⁷ Average beat subtraction

⁸ Poincaré

⁹ Chirplet

به چالش انتخاب مناسب‌ترین موجک مادر و از دست دادن فاز مطلق اشاره کرد [۲۷].

تبدیل Stockwell (تبدیل S)، توسعه‌یافته تبدیل موجک پیوسته برپایه پنجره‌های گاوسی متحرک و مقیاس‌پذیر است که توسط Stockwell [۲۷] معرفی شده‌است. تبدیل Stockwell یک روش آنالیز زمان-فرکانس مؤثر و کارآمد است که هم‌زمان وضوح فرکانسی بالایی را در فرکانس‌های پایین و وضوح زمانی بالایی را در فرکانس‌های بالا ارائه می‌دهد؛ بنابراین، در این مطالعه، تبدیل S برای نمایش زمان-فرکانس سیگنال‌های فیبریلاتور دهلیزی (موج f) استفاده شده‌است. تبدیل S یک سیگنال پیوسته $z(t)$ به صورت زیر نمایش داده می‌شود:

$$S_z(\tau, f) = e^{j2\pi\tau} W_z(\tau, d) \quad (1)$$

که در آن d عکس فرکانس ($d = 1/f$) است. همچنین $W_z(\tau, d)$ تبدیل موجک پیوسته سیگنال $z(t)$ با موجک مادر گوسین است:

$$W_z(\tau, d) = \int_{-\infty}^{+\infty} z(t) w(t - \tau, d) dt \quad (2)$$

$$w(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}} e^{-j2\pi f t} \quad (3)$$

بنابراین رابطه (۱) به صورت زیر تغییر می‌یابد:

$$S_z(\tau, f) = \int_{-\infty}^{+\infty} z(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2 f^2}{2}} e^{-j2\pi f t} dt \quad (4)$$

همان‌طور که مشاهده می‌شود در رابطه (۴) عرض پنجره در تبدیل S به فرکانس وابسته‌است؛ به‌طوری‌که با کاهش فرکانس، گسترده‌تر و با افزایش فرکانس، باریک‌تر می‌شود [۲۷].

حال آنکه برای سیگنال‌های گسسته در زمان تبدیل S گسسته براساس تبدیل فوریه گسسته (DFT^*) سیگنال ورودی محاسبه می‌شود. تبدیل DFT برای سیگنال گسسته در زمان $z[nT]$ که حاصل نمونه‌برداری N نقطه‌ای با دوره تناوب T از سیگنال پیوسته $z(t)$ است، برابر است با [۲۷]:

$$Z\left[\frac{k}{NT}\right] = \frac{1}{N} \sum_{n=0}^{N-1} z[nT] e^{-\frac{j2\pi kn}{N}}, \quad k = 0, 1, \dots, N-1 \quad (5)$$

تبدیل S گسسته در واقع به صورت تصویر بردار (که با سری زمانی $z[nT]$ تعریف شده) بر روی مجموعه‌ای از بردارها تعریف شده‌است. هر بردار پایه توسط N گوسین شیف‌یافته به N بردار محلی تقسیم می‌شود، به‌طوری‌که مجموع این N بردار محلی همان بردار پایه اصلی است؛

طیفی بوده‌است؛ علی‌رغم کارهای صورت‌گرفته، تعداد پژوهش‌های انجام‌شده برای آشکارکردن ساختار ذاتی موج f و استخراج ویژگی‌هایی که برخاسته از ماهیت ذاتی سیگنال باشند بسیار اندک بوده‌است. نکته‌ای که باید در هنگام استخراج ویژگی به آن توجه شود، ماهیت موج f است که سیگنالی غیرایستاد و دارای تغییرات زمانی و فرکانسی شدیدی است.

در این مقاله برای استخراج موج f از سیگنال ECG، از یک روش ترکیبی به نام PiCA-ESN^۱ که برپایه دو روش آنالیز مؤلفه‌های اصلی و پالایه تطبیقی غیرخطی است، استفاده شده‌است [۳]. این روش در سال ۲۰۲۲ مطرح شده و از مزایای جداسازی سیگنال‌ها از منبع^۲ و پالایه تطبیقی غیرخطی^۳ بهره برده‌است و موج f دقیق‌تری نسبت به سایر روش‌ها استخراج می‌کند. پس از استخراج موج f ، در ادامه با توجه به ماهیت غیرایستاد موج f ویژگی‌های حوزه زمان-فرکانس موج f با استفاده از اندازه تبدیل stockwell (تبدیل S) محاسبه و به طبقه‌بند اعمال می‌شود.

در ادامه این مقاله، در بخش دوم تبدیل S و در بخش سوم پایگاه داده مورد استفاده معرفی می‌شود. الگوریتم پیشنهادی برای پیش‌بینی AF در بخش چهارم ارائه می‌شود. بخش پنجم و ششم نیز به ترتیب به بحث و بررسی نتایج و نتیجه‌گیری می‌پردازند.

۲- آنالیز زمان-فرکانس سیگنال‌های غیرایستاد با استفاده از تبدیل Stockwell

از آنجاکه سیگنال‌های ECG و فیبریلاتور دهلیزی (موج f) دارای ویژگی‌های غیرخطی و غیرایستایی‌اند، روش‌های مختلف آنالیز زمان-فرکانس، مانند تبدیل فوریه زمان کوتاه و تبدیل موجک به‌طور معمول برای تجزیه و تحلیل آن‌ها استفاده شده‌است. تبدیل فوریه زمان کوتاه با توجه به ثابت بودن عرض پنجره، نمی‌تواند هم‌زمان وضوح زمان-فرکانس مناسبی را فراهم آورد. تبدیل موجک برخلاف تبدیل فوریه زمان کوتاه با تجزیه هر سیگنال به چندین مقیاس مختلف به‌طوری‌که هر مقیاس نشان‌دهنده وضوح خاصی از سیگنال است می‌تواند وضوح زمان-فرکانس مناسبی از سیگنال ارائه دهد؛ از طرفی از معایب آن می‌توان

^۱ PiCA-ESN (periodic component analysis & echo state neural network)


^۲ Source separation

^۳ Non-linear adaptive filter


^۴ Discrete Fourier transform

در این بخش به جزئیات الگوریتم پیشنهادی پرداخته می‌شود. ابتدا به منظور حذف نوفه‌های حرکتی از سیگنال‌های ECG، یک پالایه باترورث بالاگذر با فرکانس قطع ۰/۵ هرتز به سیگنال‌ها اعمال می‌شود.

نوفه تداخل برق شهری نیز به کمک تبدیل S از سیگنال‌های ECG حذف می‌شود که در ادامه توضیح داده خواهد شد؛ پس از آن، موج f از سیگنال‌های ECG استخراج می‌شود و در ادامه ویژگی‌های مختلفی از اندازه تبدیل S استخراج و پس از نرمال‌شدن با استفاده از روش اعتبارسنجی ۱۰-دسته‌ای^۱ به طبقه‌بندی اعمال می‌شوند؛ همان‌طور که در شکل (۱) نشان داده شده است.



(شکل-۱): نمودار جعبه‌ای روش پیشنهادی
(Figure-1): The proposed method flowchart



¹ 10-fold cross validation

بنابراین تبدیل گسسته S برای سیگنال گسسته در زمان $z[nT]$ به صورت زیر تعریف می‌شود:

$$S_z \left[mT, \frac{n}{NT} \right] = \sum_{k=0}^{N-1} z \left[\frac{k+n}{NT} \right] e^{\frac{-2\pi^2 k^2}{n^2}} e^{\frac{-j2\pi kn}{N}}, \quad n, m = 0, 1, 2, \dots, N-1 \quad (6)$$

که در آن تابع $e^{\frac{-2\pi^2 k^2}{n^2}}$ نشان‌دهنده تابع گوسین است. اندازه تابع تبدیل S به کمک رابطه زیر محاسبه می‌شود که در این مطالعه به منظور استخراج ویژگی از آن استفاده شده است. برای مطالعه جزئیات بیشتر در مورد تبدیل S به [۲۷] مراجعه نمایید.

$$|S_z| = \sqrt{(\text{Re}\{S_z\})^2 + (\text{Im}\{S_z\})^2} \quad (7)$$

۳- پایگاه داده

پایگاه داده توسط تارنمای Physionet برای استفاده در چالش سال ۲۰۰۴ ارائه شده است [۲۸-۲۹] که شامل هشتاد سیگنال ECG دوکاناله است. سیگنال‌های ECG درواقع بخش‌های یک دقیقه‌ای از سیگنال ضبط‌شده توسط هولتر ۲۰ تا ۲۴ ساعته از بیماران مبتلا به AF حمله‌ای می‌باشند که با فرکانس ۱۲۸ نمونه در ثانیه نمونه‌برداری شده‌اند.

پایگاه داده به یک مجموعه آموزش و دو مجموعه آزمایش (A و B) تقسیم شده است. سیگنال ECG ضبط‌شده در مجموعه آموزش قرار دارد که به سه کلاس با نام‌های AF خاتمه‌نیافته (N)، بلافاصله خاتمه‌یافته (T)، یا به زودی خاتمه‌یافته (S) تقسیم می‌شوند. ده سیگنال از مجموعه آموزش برچسب N دارند، بدین معنی که AF حداقل یک ساعت پس از پایان ضبط ادامه می‌یابد. بیست سیگنال دیگر متعلق به ده بیمار مختلف است که برچسب S یا T به این معنی که AF در یک دقیقه پس از پایان ضبط (S) و یا یک ثانیه پس از پایان ضبط (T) پایان می‌یابد. جمع‌بندی اطلاعات در مورد مجموعه‌های آموزش و آزمایش این پایگاه داده در جدول (۱) ارائه شده است. لازم به ذکر است که هدف چالش طبقه‌بندی دو حالت مختلف دو کلاس T در مقابل S و همچنین T در مقابل N است.

(جدول-۱): جزئیات پایگاه داده

(Table-1): Details of the Database

پایگاه داده	S	N	T	کل
داده‌های آموزش	۱۰	۱۰	۱۰	۳۰
داده‌های آزمون A	-	۱۵	۱۵	۳۰
داده‌های آزمون B	۱۰	-	۱۰	۲۰

۴- روش پیشنهادی

(شکل-۲): مقایسه موج f استخراج شده توسط الگوریتم PiCA-

ESN و الگوریتم سرکوب کننده پیک‌های-QRST

(Figure-2): Comparison of the extracted f-wave by PiCA-ESN algorithm and QRST-cancellation algorithm

قسمت نخست و دوم شکل (۱) به ترتیب، سیگنال‌های ECG متعلق به یک بیمار در دو کانال مختلف و موج‌های f استخراج شده از ECGها را برای مثال نمایش می‌دهد (لازم به ذکر است که سیگنال‌ها شصت ثانیه‌ای‌اند و برای وضوح بهتر در قسمت نخست و دوم از شکل (۱) به صورت بیست ثانیه‌ای نمایش داده شده‌اند).

در ادامه اندازه تبدیل S برای موج f (شصت ثانیه‌ای) محاسبه شده که تصویر یک کانال آن برای مثال در قسمت سوم شکل (۱) نمایش داده شده است. در این مطالعه از نرم افزار MATLAB برای آنالیز داده‌ها استفاده شده است.

۴-۱- استخراج موج f

در این مقاله از الگوریتم PiCA-ESN برای استخراج موج f استفاده شده که در [۳] معرفی شده است. این الگوریتم با استفاده از اطلاعات محل پیک‌های R و روش آنالیز مولفه متناوب اصلی (PiCA) [۳۰] سیگنال مربوط به بطن‌ها را از سیگنال ECG استخراج و به عنوان سیگنال مرجع به پالایهٔ وفقی غیرخطی مبتنی بر شبکهٔ عصبی حالت اکو (ESN) تحویل می‌دهد. ESN برای استخراج موج f (سیگنال مربوط به دهلیزها) سیگنال مرجع (سیگنال مربوط به بطن‌ها) را از سیگنال ECG کسر می‌کند.

همان‌طور که پیش‌تر عنوان شد، الگوریتم PiCA-ESN به اطلاعات مربوط به محل پیک‌های R نیاز دارد. در این مقاله از الگوریتم شناخته شده Pan-Tompkins [۳۱] برای استخراج محل پیک‌های R استفاده شده است؛ پس از استخراج محل قرارگرفتن پیک‌های R، از الگوریتم PiCA-ESN جهت استخراج امواج فیبریلاتور دهلیزی (موج f) استفاده می‌شود.

شکل (۲) موج f استخراج شده توسط الگوریتم PiCA-ESN در مقایسه با الگوریتم سرکوب کننده پیک‌های-QRST^۱ که مبتنی بر روش تفریق ضربان متوسط است و اغلب مقاله‌های منتخب چالش ۲۰۰۴ فیزیونوت از آن بهره گرفته‌اند را نمایش می‌دهد. به نظر می‌رسد که موج f استخراج شده توسط الگوریتم سرکوب کننده پیک‌های-QRST حاوی باقیماندهٔ متناظر با پیک‌های QRST (سیگنال مرتبط به بطن‌ها) بیشتری است؛ همچنین برای اثبات این ادعا آزمایشی روی مجموعه آزمایش A طراحی

^۱ QRST-cancellation algorithm

شده است؛ به طوری که ویژگی‌های یکسانی از امواج f استخراج شده توسط هر دو الگوریتم محاسبه شده و به طبقه‌بند SVM اعمال می‌شود. نتایج این آزمایش در جدول (۲) نشان دهندهٔ درستی ادعای مطرح شده است؛ به طوری که، الگوریتم PiCA-ESN در استخراج موج f موفق‌تر بود و منجر به طبقه‌بندی با دقت بالاتری شده است.

(جدول-۲): مقایسه کیفیت موج f استخراج شده توسط

الگوریتم‌های PiCA-ESN و سرکوب کننده پیک‌های-QRST

از منظر دقت طبقه‌بندی و امتیاز F1

(Table-2): Comparison of the quality of the extracted f-wave using PiCA-ESN and QRST-cancellation in terms of accuracy and F1 score

الگوریتم	امتیاز F1	دقت
PiCA-ESN	۹۴٪	۹۳٪
سرکوب کننده پیک‌های-QRST	۸۱٪	۸۰٪

۴-۲- استخراج ویژگی

استخراج ویژگی مهم‌ترین مرحله در پردازش موج f به منظور طبقه‌بندی AF است؛ در این مرحله با توجه مشخصات ذاتی سیگنال‌ها، ویژگی‌هایی از موج f استخراج می‌شوند که تمایز بیشتر نسبت به کلاس‌های موردنظر ایجاد کنند.

در این مطالعه با توجه به ماهیت غیرایستان موج f ویژگی‌های حوزهٔ زمان-فرکانس از آن استخراج می‌شود؛ برای این منظور، ابتدا موج f با N نمونه با استفاده از تبدیل S به تصویر زمان-فرکانس S_z با ابعاد $N \times M$ تبدیل می‌شود؛ سپس ویژگی‌هایی که در ادامه معرفی می‌شوند، از تصویر زمان-فرکانس S_z استخراج می‌شوند. برای هر بیمار ویژگی‌ها از هر دو کانال ECG محاسبه می‌شوند. لازم به ذکر است که از آنجاکه امواج f اغلب با فرکانس‌هایی کمتر از ۲۵ هرتز مشخص می‌شوند به استناد مرجع [۳۲] و همچنین به منظور حذف نوفهٔ پنجاه هرتز برق شهری از سیگنال، محدودهٔ ۱-۴۰ هرتز برای محاسبهٔ تبدیل S در نظر گرفته شده است؛ البته محدودهٔ فرکانسی ۱-۴۰ هرتز پس از بررسی عملکرد روش پیشنهادی در محدوده‌های فرکانسی مختلفی مابین یک هرتز و بیشتر از ۲۵ هرتز تا کمتر از پنجاه هرتز انتخاب شده است.

۴-۲-۱- فرکانس لحظه‌ای

به دلیل اینکه مؤلفه‌های فرکانسی موج f حاوی اطلاعات مهمی از AF است از فرکانس لحظه‌ای تصویر زمان-

فرکانس S_z به عنوان ویژگی استفاده می شود که به کمک رابطه (۸) محاسبه می شود [۱۹]. برای بازتوصیف بهتر فرکانس لحظه ای از آمارگان های مختلفی نظیر میانگین، میانه، کشیدگی، چولگی، انحراف معیار، بیشینه و کمینه استفاده می شود.

$$f_{i,z}[n] = \frac{f_s \sum_{n=0}^{N-1} n S_z}{2N \sum_{n=0}^{N-1} S_z} \quad (8)$$

۴-۲-۲- تمرکز انرژی^۱:

برای محاسبه کمی تمرکز انرژی موج f درحوزه زمان-فرکانس از رابطه زیر استفاده می شود.

$$EC_z = (\sum_{n=0}^{N-1} \sum_{m=0}^{M-1} S_z^{\frac{1}{2}})^2 \quad (9)$$

۴-۲-۳- همواری طیفی موج f :

همواری طیفی، توزیع توان سیگنال را درحوزه زمان-فرکانس نشان می دهد [۳۳]. می توان افزایش همواری طیفی را به معنی وجود پیک های بزرگ تر در موج f در نظر گرفت که ویژگی کارآمدی برای تشخیص AF است [۲۰]. برای بازتوصیف بهتر همواری طیفی از آمارگان های مختلفی نظیر میانگین، میانه، کشیدگی، چولگی، انحراف معیار، چارک نخست و چارک سوم استفاده می شود.

$$TFF_z = \frac{(\prod_{n=0}^{N-1} \prod_{m=0}^{M-1} S_z)^{\frac{1}{N^2}}}{\sum_{n=0}^{N-1} \sum_{m=0}^{M-1} S_z} \quad (10)$$

۴-۲-۴- آنتروپی Renyi

این معیار میزان پیچیدگی توزیع زمان-فرکانس را مشخص می کند. هرچه مقدار این معیار کمتر باشد، به معنی پیچیدگی (آشفستگی) کمتر توزیع زمان-فرکانس و می توان معادل تفکیک پذیری بالاتر و تمرکز انرژی بیشتر دانست. آنتروپی Renyi با استفاده از رابطه (۱۱) محاسبه می شود که در آن α مرتبه آنتروپی را مشخص می کند که یک عدد صحیح و به طور معمول بزرگ تر از یک است [۳۳].

$$RE_z(\alpha) = \frac{1}{1-\alpha} \log_2 \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} S_z^\alpha \quad (11)$$

۴-۲-۵- آنتروپی Sample^۲

آنتروپی نمونه (SampEn) درواقع نسخه اصلاح شده آنتروپی تقریبی^۳ است که برای ارزیابی پیچیدگی سیگنال های فیزیولوژیکی استفاده می شود. در این مقاله، به منظور ارزیابی پیچیدگی مؤلفه های فرکانسی مختلف درطول زمان استفاده شده است؛ به این صورت که آنتروپی

نمونه سطرهای مختلف تصویر زمان-فرکانس S_z محاسبه شده و میانگین آن ها به عنوان ویژگی در بردار ویژگی ذخیره می شود.

۴-۳- طبقه بندی

در این مقاله برای افزایش قابلیت اطمینان صحت طبقه بندی از ترکیب سه طبقه بند و روش رأی گیری حداکثر استفاده شده است؛ زیرا در کاربردهای پزشکی افزایش درصد تشخیص درست و کاهش درصد تشخیص نادرست مطلوب است. طبقه بندهای شبکه عصبی پرسپترون چندلایه (MLP^۴)، ماشین بردار پشتیبان (SVM^۵) و AdaBoost انتخاب شده اند. الگوریتم پیشنهادی با داده های آموزش و آزمایش مطابق جدول (۱) مورد آموزش و آزمایش قرار می گیرد.

۴-۳-۱- شبکه های عصبی MLP:

یکی از پرکاربردترین و شناخته شده ترین طبقه بندها است که دارای سه نوع لایه ورودی، مخفی (میانی) خروجی است؛ در این مقاله، از طبقه بند MLP با سه لایه مخفی با هفتاد، سی و پانزده نورون با توابع فعال سازی سیگموئید تانژانت هیپربولیک و لگاریتمی استفاده شده است. برای آموزش شبکه عصبی در این مطالعه، از روش پس انتشار لونیگ-مارکوورت^۶ و هزار بار تکرار استفاده شده است.

۴-۳-۲- ماشین بردار پشتیبان (SVM):

SVM یکی از طبقه بندها است که در این مطالعه استفاده شده است. SVM سعی می کند داده ها را با یک ابرصفحه بهینه جدا کند [۳۴]؛ در این مقاله، SVM با هسته های مختلف گاوسی، خطی و چندجمله ای آزمایش شده است و بهترین نتیجه با توابع هسته^۷ RBF غیرخطی حاصل شده است [۳۴].

۴-۳-۳- AdaBoost

درکل می توان گفت که طبقه بند Adaboost از تعداد زیادی درختان تصمیم گیری کوچک که هریک برخی از ویژگی ها را انتخاب می کنند، تشکیل شده است. خروجی این طبقه بند از طریق ترکیب خروجی پیش بینی شده توسط طبقه بندهای ساخته شده به دست می آید [۳۳]؛ به دلیل قدرتش در جلوگیری از آموزش بیش از حد^۸ و قابلیت سازگاری با مدل های مختلف و استفاده آسان

^۴ Multilayer perceptron

^۵ Support vector machine

^۶ Levenberg-Marquardt backpropagation method

^۷ Radial base functions

^۸ Overfitting

^۱ Energy concentration measure

^۲ Sample entropy

^۳ Approximate Entropy

می‌دهد چقدر مدل در شناسایی موارد مثبت واقعی و شناسایی نکردن موارد منفی واقعی موفق بوده‌است.

در این روابط، TP^6 به معنای تعداد موارد درستی که مدل به درستی به عنوان مثبت تشخیص داده‌است، TN^7 به معنای تعداد موارد درستی که مدل به درستی به عنوان منفی تشخیص داده‌است، FN^8 به معنای تعداد مواردی است که مدل به اشتباه به عنوان منفی تشخیص داده‌است، FP^9 به معنای تعداد مواردی است که مدل به اشتباه به عنوان مثبت تشخیص داده‌است.

۵-۱- بخش نخست

در این بخش عملکرد طبقه‌بندهای مختلف به تنهایی و همچنین به صورت ترکیبی با روش رأی حداکثر^{۱۰} بررسی می‌شود؛ برای این منظور ویژگی‌های استخراج شده به طبقه‌بندها اعمال و عملکرد طبقه‌بندی‌ها مقایسه می‌شود. جدول (۳) نتایج به دست آمده را نشان می‌دهد. همان‌طور که انتظار می‌رود ترکیب طبقه‌بندها عملکرد بهتری نسبت به عملکرد هر کدام از طبقه‌بندها با معیار دقت، حساسیت، اختصاصیت و امتیاز F1 دارد.

(جدول-۳): مقایسه عملکرد طبقه‌بندهای مختلف روی

طبقه‌بند	حساسیت	اختصاصیت	امتیاز F1	دقت
SVM	۱۰۰٪	۸۷٪	۹۴٪	۹۳٪
MLP	۹۳٪	۸۰٪	۸۸٪	۸۷٪
Adaboost	۹۳٪	۱۰۰٪	۹۷٪	۹۷٪
رأی بیشینه (SVM& MLP& Adaboost)	۱۰۰٪	۱۰۰٪	۱۰۰٪	۱۰۰٪

مجموعه داده‌های آزمون A

(Table-3): Performance comparison of different classifiers on test set A

۵-۲- بخش دوم

در بخش دوم عملکرد روش پیشنهادی با طبقه‌بندی به روش رأی بیشینه با نتایج به دست آمده توسط روش‌های برگزیده چالش فیزیونت ۲۰۰۴ و همچنین مقاله‌هایی که به تازگی روی این پایگاه داده منتشر شده، مقایسه و در جدول (۴) گزارش شده‌است. جدول (۴) نشان می‌دهد که

مورد توجه قرار می‌گیرد. رویکرد مرحله آموزش بدین صورت است که سیگنال‌هایی که در مراحل قبل به اشتباه طبقه‌بندی شده‌اند با احتمال بیشتری برای آموزش طبقه‌بند در مرحله بعد مورد استفاده قرار می‌گیرند و آموزش طبقه‌بندهای متوالی، به سمت سیگنال‌هایی که پیش‌بینی آن‌ها دشوار است، سوق پیدا می‌کند [۳۳]؛ در این مقاله از صد طبقه‌بند درخت تصمیم به عنوان طبقه‌بندهای ضعیف با الگوریتم هماهنگ‌سازی SAMME^۱ شده‌است.

۵- نتایج شبیه‌سازی

در این قسمت نتایج شبیه‌سازی روش پیشنهادی در قالب سه بخش زیر گزارش می‌شود: در بخش نخست عملکرد طبقه‌بندها بررسی می‌شود. در بخش دوم نتایج به دست آمده به کمک طبقه‌بند منتخب با نتایج برگزیده چالش فیزیونت و مطالعاتی که به تازگی روی این پایگاه داده انجام شده مقایسه و در بخش آخر پایداری ویژگی‌های پیشنهادی با به کارگیری قطعات چهارثانیه‌ای سیگنال ارزیابی می‌شود.

گفتنی است که از معیارهای دقت^۲، حساسیت^۳، اختصاصیت^۴ و امتیاز F1^۵ (بر حسب درصد) برای ارزیابی نتایج استفاده شده‌است.

$$(12) \quad \text{دقت} = \frac{TP+TN}{TP+TN+FP+FN}$$

از این معیار برای ارزیابی این که مدل چقدر از مواردی را که تشخیص داده واقعاً درست بوده‌است استفاده می‌شود.

$$(13) \quad \text{حساسیت} = \frac{TP}{TP+FN}$$

حساسیت نشان می‌دهد که مدل چقدر توانسته موارد مثبت واقعی را درست شناسایی کند.

$$(14) \quad \text{اختصاصیت} = \frac{TN}{TN+FP}$$

اختصاصیت نشان می‌دهد که مدل چقدر توانسته‌است موارد منفی واقعی را درست شناسایی کند.

$$(15) \quad \text{امتیاز F1} = \frac{2 \times TP}{2 \times TP + FP + FN}$$

امتیاز F1 یک معیار جامع است که توازن بین دقت و حساسیت را بیان می‌کند و به طور معمول برای زمان‌هایی که تعادل بین دقت و حساسیت مهم است مانند کاربردهای پزشکی استفاده می‌شود و نشان

¹ Stagewise additive modeling using a multiclass exponential loss function

² Accuracy

³ Recall

⁴ Specificity

⁵ F1 Score

⁶ True Positives

⁷ True Negatives

⁸ False Negatives

⁹ False Positives

¹⁰ Major voting

روش پیشنهادی توانسته داده‌ها را با دقت بالاتری طبقه‌بندی کند.

۵-۳ - بخش سوم

بخش سوم به بررسی پایداری ویژگی‌ها در طول سیگنال اختصاص داده شده است. انتظار می‌رود یک ویژگی کارآمد در تمام طول یک سیگنال طولانی با برچسب یکسان عملکرد مشابهی داشته باشد؛ برای این منظور ابتدا هریک از سیگنال‌های ECG به پانزده بخش چهار ثانیه‌ای (مطابق با [۲۶]) تقسیم و تصویر زمان-فرکانس تبدیل S برای هربخش محاسبه شده، پس از آن ویژگی‌های موردنظر از اندازه تبدیل S استخراج شده و به طبقه‌بند اعمال می‌شوند. جدول (۵)، دو سیگنال مختلف متعلق به دو بیمار متفاوت از کلاس‌های مختلف T و N مجموعه آموزش را به عنوان مثال نشان می‌دهد. در این جدول به دلیل کمبود فضا خروجی واقعی و پیش‌بینی شده برای چهار بخش از پانزده بخش هرکدام از سیگنال‌ها برای مثال نمایش داده شده است (خطا با رنگ قرمز مشخص شده است). نتایج جدول (۵) نشان می‌دهند تمامی بخش‌های نشان داده شده جز یک بخش به درستی پیش‌بینی شده‌اند؛ همچنین تمام معیارهای ارزیابی برای تمام سیگنال‌های شرکت داده شده در این آزمایش محاسبه شده و در جدول (۶) با نتایج مطالعه [۲۶] (که به تازگی مطرح شده و از همین پایگاه داده استفاده کرده است) مقایسه شده است. نتایج این آزمایش نشان می‌دهند که اگرچه عملکرد روش پیشنهادی در به کارگیری سیگنال ECG با طول کوتاه‌تر (چهار ثانیه‌ای) بی‌تغییر نمانده و کاهش داشته است، اما از مقایسه جدول‌های (۶) و (۳) می‌توان گفت ویژگی‌های پیشنهادی برای سیگنال ECG چهار ثانیه‌ای در مقایسه با سیگنال ECG پانزده ثانیه‌ای پایداری قابل قبولی را نشان می‌دهند. همچنین نتایج نشان می‌دهد که ویژگی‌های پیشنهادی عملکرد بهتری نسبت به مطالعه [۲۶] دارد.

گفتنی است در این آزمایش قسمت‌های مختلف یک سیگنال یا در مرحله آموزش شرکت داشته‌اند و یا در مرحله آزمایش، یعنی هیچ دو قسمتی از یک سیگنال هم‌زمان هم در آزمایش و هم در آموزش شرکت داده نشده‌اند؛ به علاوه در این قسمت برای داشتن مقایسه عادلانه با [۲۶] تنها از داده‌های آموزش و بخش چهار ثانیه‌ای (مطابق با [۲۶]) استفاده شده است که در دو کلاس AF پایان یافته (T&S) و پایان نیافته (N) طبقه‌بندی شده‌اند.

(جدول ۴-): مقایسه دقت عملکرد روش پیشنهادی با سایر روش‌ها

(Table-4) : Correct classification rate of the proposed method comparing with other methods

روش‌ها	طول سیگنال (ثانیه)	داده‌های آزمون A	داده‌های آزمون B
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کننده پیک‌های-QRST و آنالیز حوزه فرکانس [۳۵]	۶۰	۹۷٪	۱۰۰٪
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کننده پیک‌های-QRST و آنالیز حوزه زمان و فرکانس [۳۶]	۶۰	۹۳٪	۸۰٪
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کننده پیک‌های-QRST و آنالیز فرکانس [۳۷]	۶۰	۹۰٪	۱۰۰٪
روش مبتنی بر استخراج موج f با استفاده از فاصله QT و ویژگی‌های کلینیکی [۳۸]	۶۰	۹۰٪	*
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کننده پیک‌های-QRST توسعه یافته و آنالیز حوزه زمان-فرکانس [۴]	۶۰	۹۰٪	*
روش مبتنی بر آنالیز حوزه فرکانس فواصل R-R [۳۹]	۶۰	*	۸۰٪
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کننده پیک‌های-QRST و آنالیز حوزه فرکانس [۴۰]	۶۰	*	۸۰٪
روش شبکه SVM دو مسیره [۴۱]	۶۰	۹۶٪.۷	*
روش تخصیص دینامیکی سمبل‌ها و طبقه‌بند یادگیری گروهی [۴۲]	۶۰	۹۹٪.۸	*
روش پیشنهادی	۶۰	۱۰۰٪	۱۰۰٪

* گزارش نشده است.

(جدول ۵-): یک نمونه مثال از نتایج به دست آمده در مقایسه با

مقدار خروجی واقعی برای دو سیگنال متفاوت از

مجموعه داده‌های آموزش

(Table-5): An example of the obtained results compared to the target value for two different signals in the ttraining set.



- Bovill, "Relationship between prothrombin activation fragment F1. 2 and international normalized ratio in patients with atrial fibrillation", *Stroke*, vol. 28, no. 6, pp. 1101-1106, 1997.
- [3] S. Mihanost, L. Sörnmo, M. Doyen, and J. Oster, "A comparative study of the performance of methods for f-wave extraction", *Physiological Measurement*, vol. 43, no. 10, pp. 105006, 2022.
- [4] F. Nilsson, M. Stridh, A. Bollmann, and L. Sörnmo, "Predicting spontaneous termination of atrial fibrillation with time-frequency information", *Computers in Cardiology*, pp. 657-660, 2004.
- [5] S. S. Chugh, J. L. Blackshear, W. K. Shen, S. C. Hammill, S. C. and B. J. Gersh, "Epidemiology and natural history of atrial fibrillation: clinical implications", *Journal of the American College of Cardiology*, vol. 37, no. 2, pp. 371-378, 2001.
- [6] W. M. Feinberg, E. S. Cornell, S. D. Nightingale, L. A. Pearce, R. P. Tracy, R. G. Hart, and E. G. Bovill, "Relationship between prothrombin activation fragment F1. 2 and international normalized ratio in patients with atrial fibrillation", *Stroke*, vol. 28, no. 6, pp. 1101-1106, 1997.
- [7] P. Bonizzi, M. Stridh, L. Sörnmo L, and O. Meste, "Ventricular activity residual reduction in remainder ECGs based on short-term autoregressive model interpolation", *Annual Computers in Cardiology Conference (CinC)*, vol. 36, pp. 813-816, 2009.
- [8] J. Slocum, A. Sahakian, and S. Swiryn, "Diagnosis of atrial fibrillation from surface electrocardiograms based on computer-detected atrial activity", *Journal of electrocardiology*, vol. 25, no. 1, pp. 1-8, 1992.
- [9] M. Stridh, and L. Sörnmo, "Spatiotemporal QRST cancellation techniques for analysis of atrial fibrillation", *IEEE Transactions on Biomedical Engineering*, vol. 48, no. 1, pp. 105-111, 2001.
- [10] J. Behar, J. Oster, and G. D. Clifford, "Combining and benchmarking methods of foetal ECG extraction without maternal or scalp electrode data", *Physiological measurement*, vol. 35, no. 8, pp. 1569-1589, 2014.
- [11] H. Jaeger, "The "echo state" approach to analysing and training recurrent neural networks-with an erratum note", Bonn, Germany: German National Research Center for Information Technology, *GMD Technical Report*, vol. 148, no. 34, pp. 13, 2001.
- [12] A. Petrénas, V. Marozas, L. Sörnmo, and A. Lukosevicius, "An echo state neural network for QRST cancellation during atrial fibrillation", *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 10, pp. 2950-2957, 2012.
- [13] F. Castells, C. Mora, J. J. Rieta, D. Moratal-Pérez, and J. Millet, "Estimation of atrial fibrillatory wave from single-lead atrial fibrillation electrocardiograms using principal component analysis concepts", *Medical and biological Engineering and Computing*, vol. 43, no. 5, pp. 557-560, 2005.
- [14] R. Alcaraz, and J. J. Rieta, "Adaptive singular value cancellation of ventricular activity in

پایگاه داده	N	N	N	N	T	T	T	T
خروجی واقعی	.	.	.	.	۱	۱	۱	۱
خروجی پیش‌بینی شده	۰.۸	۰.۲	۰.۰	۰.۰	۰.۱	۰.۷	۰.۹	۰.۹

(جدول-۶): میانگین نتایج طبقه‌بندی روش پیشنهادی با استفاده از روش رأی حداکثر برای ده fold در مقایسه با نتایج

[۲۶] برای سیگنال ECG چهار ثانیه‌ای

(Table-6): Average classification rate for the proposed method using major voting and ten-folds in comparison with the obtained results of reference [26] for 4 seconds ECG signal

روش‌ها	حساسیت	اختصاصیت	امتیاز F1	دقت
روش پیشنهادی	94% ± 3.2	91% ± 2.1	94% ± 4.2	93% ± 3.7
روش [۲۶]	76% ± 4.1	75% ± 3.5	66% ± 4.2	75% ± 3.4

۶- بحث و نتیجه‌گیری

در این مقاله یک روش جدید برای طبقه‌بندی فیبریلاسیون دهلیزی مبتنی بر آنالیز زمان-فرکانس ارائه شد. ابتدا سیگنال فیبریلاتور دهلیزی (موج f) با استفاده از الگوریتم PiCA-ESN از سیگنال ECG استخراج و پس از آن طیف زمان-فرکانس آن به کمک تبدیل S محاسبه شد. در ادامه ویژگی‌ها از دامنه تبدیل S استخراج و به ترکیب سه طبقه‌بند MLP، SVM و AdaBoost اعمال شدند. نتایج نشان‌داد که روش پیشنهادی عملکرد بهتری در مقایسه با مقاله‌هایی که به‌تازگی روی این پایگاه داده منتشر شده‌است؛ همچنین آزمایش جدیدی برای بررسی پایداری ویژگی‌های پیشنهادی در طول یک سیگنال با تقسیم متوالی یک سیگنال به بخش‌های چهار ثانیه‌ای طراحی و آزمایش شد. نتایج به‌دست‌آمده حاکی از پایداری قابل قبول ویژگی‌های پیشنهادی است.

7-References

۷- مراجع

- [1] S. S. Chugh, J. L. Blackshear, W. K. Shen, S. C. Hammill, S. C. and B. J. Gersh, "Epidemiology and natural history of atrial fibrillation: clinical implications", *Journal of the American College of Cardiology*, vol. 37, no. 2, pp. 371-378, February 2001.
- [2] W. M. Feinberg, E. S. Cornell, S. D. Nightingale, L. A. Pearce, R. P. Tracy, R. G. Hart, and E. G.

- with ECG signals”, *Computers in Biology and Medicine*, vol. 137, pp.104783, 2021.
- [27] R. G. Stockwell, L. Mansinha, and R. Lowe, “Localization of the complex spectrum: The S-transform”, *IEEE Transaction on Signal Processing*, vol. 44, pp. 998–1000, 1996.
- [28] GB. Moody, “Spontaneous Termination of Atrial Fibrillation” *PhysioNet and Computers in Cardiology 2004*, Apr. 11, 2004. [Online]. Available: <https://physionet.org/content/aftdb/1.0.0/>. [Accessed: Sept. 10, 2024].
- [29] G. Moody, “Spontaneous termination of atrial fibrillation: a challenge from physionet and computers in cardiology 2004”, *Computers in Cardiology*, pp. 101–104, 2004.
- [30] R. Sameni, C. Jutten, and M. B. Shamsollahi, “Multichannel electrocardiogram decomposition using periodic component analysis”, *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 8, pp. 1935-1940, 2008.
- [31] J. Pan, and W. J. Tompkins, “A real-time QRS detection algorithm”, *IEEE Transactions on Biomedical Engineering*, vol. 32, pp. 230-236, 1985.
- [32] A. Petrėnas, and M. Vaidotas, *Atrial fibrillation from an engineering perspective*, Edited by Leif Sörnmo, Berlin: Springer, 2018.
- [33] H. Hazeri, P. Zarjam, and G. Azemi, “Classification of normal/abnormal PCG recordings using a time-frequency approach”, *Analog Integrated Circuits and Signal Processing*, vol. 109, no. 2, pp. 459-465, 2021.
- [34] M. Azimi Far, S. Nejatian, H. Parvin, K. Bagheri Fard, and V. Rezaei, “Predicting cardiac arrhythmia on ECG signal using an ensemble of optimal multicore support vector machines”, *Signal and Data Processing*, vol. 19, no. 3, pp. 65-86, 2022.
- [۳۴] عظیمی‌فر، مریم، نجاتیان، پروین، باقری فرد، کرم الله، رضایی وحیده، «پیش‌بینی آریتمی قلبی در سیگنال ECG با به‌کارگیری مجمعی از ماشین‌های بردار پشتیبان چند هسته‌ای بهینه»، پردازش علائم و داده‌ها، دوره ۱۹، شماره ۳، صفحات ۶۵-۸۶، ۱۴۰۱.
- [35] S. Petrutiu, A. V. Sahakian, and J. Ng, S. Swiryn, “Analysis of the surface electrocardiogram to predict termination of atrial fibrillation: the 2004 computers in cardiology/physionet challenge”, In *Computers in Cardiology 2004*, pp. 105-108.
- [36] D. Hayn, K. Edegger, D. Scherr, P. Lercher, B. Rotman, W. Klein, and G. Schreier, “Automated prediction of spontaneous termination of atrial fibrillation from electrocardiograms”, In *Computers in Cardiology 2004*, 2004, pp. 117-120.
- [37] F. Cantini, F. Conforti, M. Varanini, F. Chiarugi, and G. Vrouchos, “Predicting the end of an atrial fibrillation episode: the physionet challenge”, In *Computers in Cardiology 2004*, 2004, pp. 121-124.
- [38] M. Lemay, Z. Ihara, J. M. Vesin, and L. Kappenberger. “Computers in cardiology/physionet challenge 2004: AF classification based on clinical features”, In *Computers in Cardiology 2004*, pp. 669-672, 2004.
- single-lead atrial fibrillation electrocardiograms”, *Physiological measurement*, vol. 29, no. 12, pp. 1351-1369, 2008.
- [15] R. Llinares, and J. Igual, “Application of constrained independent component analysis algorithms in electrocardiogram arrhythmias”, *Artif Intell Med*, vol. 47, no. 2, pp. 121-133, 2009.
- [16] J. Malik, N. Reed, C. L. Wang, and H. T. Wu, “Single-lead f-wave extraction using diffusion geometry”, *Physiological measurement*, vol. 38, no. 7, pp. 1310-1334, 2017.
- [17] E. K. Roonizi, and R. Sassi, “An extended Bayesian framework for atrial and ventricular activity separation in atrial fibrillation”, *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 6, pp. 1573-1580, 2016.
- [18] P. Langley, J. P. Bourke, and A. Murray, “Frequency analysis of atrial fibrillation”, In *Computers in Cardiology IEEE*, pp. 65–68, 2000.
- [19] M. Stridh, and L. Sörnmo, “Time-frequency characterization of atrial arrhythmias using principal decomposition”, In *23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol.2, pp. 1808–1811, 2001.
- [20] M. Stridh, L. Sörnmo, C. J. Meurling, and S. B. Olsson, “Sequential characterization of atrial tachyarrhythmias based on ECG time-frequency analysis”, *IEEE Transactions on Biomedical Engineering*, vol. 5, pp.100–114, 2004.
- [21] V. Zarzoso, D G. Latcu, A R Hidalgo-Muñoz, M. Meo, O. Meste, I. Popescu, and N. Saoudi, “Non-invasive prediction of catheter ablation outcome in persistent atrial fibrillation by fibrillatory wave amplitude computation in multiple electrocardiogram leads”, *Archives of cardiovascular diseases*, vol. 109, no. 12, pp. 679-688, 2016.
- [22] R.K. Tripathy, M.R. Paternina, J.G. Arrieta, and P. Pattanaik, “Automated detection of atrial fibrillation ecg signals using two stage vmd and atrial fibrillation diagnosis index”, *Journal of Mechanics in Medicine and Biology*, vol. 17, no. 7, pp. 1740044, 2017
- [23] R. J. Martis, U. R. Acharya, H. Prasad, C. K. Chua, and C. M. Lim, “Automated detection of atrial fibrillation using bayesian paradigm”, *Knowledge-Based Systems*, vol. 54, pp. 269–275, 2017.
- [24] A. Nguyen, S. Ansari, M. Hooshmand, K. Lin, H. Ghanbari, J. Gryak, and K. Najarian, “Comparative study on heart rate variability analysis for atrial fibrillation detection in short single-lead ecg recordings”, In *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 526–529, 2018.
- [25] S. Cerutti, L. Mainardi, A. Porta, and A. Bianchi, “Analysis of the dynamics of RR interval series for the detection of atrial fibrillation episodes”, *Computers in Cardiology IEEE*, pp. 77–80, 1997.
- [26] T. Radhakrishnan, J. Karhade, S. K. Ghosh, P. R. Muduli, R. K. Tripathy, and U. R. Acharya, “AFCNNet: Automated detection of AF using chirplet transform and deep convolutional bidirectional long short term memory network

- [39] B. Logan, and J. Healey, "Detection of spontaneous termination of atrial fibrillation", *In Computers in Cardiology 2004*, pp. 653-656, 2004.
- [40] Q. Xi, and S. Shkurovich, "Prediction of spontaneous termination of atrial fibrillation in surface ECG by frequency analysis", *In Computers in Cardiology 2004*, pp. 113-116, 2004.
- [41] L. Liu, F. Liu, X. Ren, Y. Li, B. Han, L. Zhang, S. Wei, "Predicting spontaneous termination of atrial fibrillation based on dual path network and feature selection", *Biomedical Signal Processing and Control*, 88, pp. 105606, 2024.
- [42] N. Ganapathy, D. Baumgärtel, and T. M. Deserno, "Automatic detection of atrial fibrillation in ECG using co-occurrence patterns of dynamic symbol assignment and machine learning". *Sensors*, vol. 21, no. 10, pp. 3542, 2021.



سارا میهن دوست مدرک دکترای

خود را در رشته مهندسی برق گرایش سیستم در سال ۱۳۹۵ از دانشگاه ارومیه دریافت کرده است؛ همچنین از سال ۲۰۱۹ تا ۲۰۲۱، پژوهشگر

پسادکتر در آزمایشگاه تشخیصی و تصویربرداری دانشگاه لورن فرانسه فعالیت بود. او از سال ۱۳۹۹ به گروه مهندسی برق دانشگاه صنعتی ارومیه پیوست و در حال حاضر استادیار این دانشگاه است. علایق پژوهشی او تجزیه و تحلیل بافت، پردازش سیگنال های زیست پزشکی، مدل سازی سیگنال، تشخیص الگو و پردازش سیگنال های تصادفی است.

نشانی رایانامه ایشان عبارت است از:

Sara.mihandoost@uut.ac.ir

