طبقه‌بندی فیبریلاسیون دهلیزی با استفاده از الگوریتم PiCA-ESN و تبدیل Stockwell

سارا میهن‌دوست

استادیار گروه مهندسی برق، دانشکدهٔ 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 درطول فیبریلاسیون دهلیزی ندارند؛ ازاین‌رو، تشخیص این بیماری برای پزشک مختصص دشوار است. تشخیص خودکار AF با استفاده از سیگنال الکتروکاردیوگرام (سیگنال ECG) به پزشک معالج در تشخیص کمک بسزایی می‌کند و خطر ابتلا به بیمارهای حاد قلبی و سکتهٔ مغزی را کاهش می‌دهد. در این مقاله، رویکردی جدید به‌منظور 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 شده‌است. 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 به‌دست می‌آید؛ در ادامه، دامنهٔ تصویر زمان-فرکانس Stockwell توسط ویژگی‌های مختلف بازتوصیف و به‌ترکیب ۳ طبقه‌بند اعمال می‌شود. به‌علاوه در این مطالعه آزمایش جدیدی برای بررسی پایداری ویژگی‌ها درطول سیگنال پیشنهاد شده‌است. این مطالعه بر روی پایگاه داده فیزیونت پیاده‌سازی شده و نتایج به‌دست‌آمده نشان می‌دهند که روش پیشنهادی عملکرد بهتری در مقایسه با روش‌های برگزیدهٔ چالش فیزیونت با دستیابی به‌دقت ۱۰۰درصد 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

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

• تاریخ ارسال مقاله: ۱۴۰۲/۱/۱۸ • تاریخ پذیرش: ۱۴۰۳/۶/۰۱ • تاریخ انتشار: ۱۴۰۳/۸/۸ • نوع مطالعه: کاربردی

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]

[DOI: 10.61186/jsdp.21.2.43]

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 fibrilation (AF), f-wave, PiCA-ESN algorithm, Stockwell transform (S transform).

۱-مقدمه

فیبریلاسیون دهلیزی (AF[1]) با شیوع ۱۰درصد در جمعیت بالای هفتاد سال، شایع‌ترین آریتمی قلبی است[۱] که تنها در ایالات متحده بیش از دومیلیون نفر از ابتلا به آن رنج می‌برند[۲]. AF موجب ایجاد بی‌نظمی در دپلاریزاسیون دهلیزها و متعاقب آن سبب کاهش توانایی دهلیزها در تخلیهٔ خون به بطن‌ها و درنتیجه اختلال در عملکرد قلب می‌شود. AF با افزایش خطر نارسایی قلبی و تولید لخته‌های خون خطر سکتهٔ مغزی را نیز افزایش می‌دهد[۳].

AF را می‌توان به سه‌دستهٔ مختلف تقسیم‌بندی کرد؛ ۱- AF حمله‌ای[2] که ظرف مدت هفت‌روز خودبه‌خود خاتمه می‌یابد. ۲- AF مداوم[3] که به‌کمک مداخلات پزشکی پایان می‌یابد. ۳- AF دائمی[4] که در آن ریتم سینوسی قابل بازیابی نیست[۴]. مطالعهٔ AF حمله‌ای و شناسایی مکانیسم‌های شروع و خاتمهٔ آن به‌درک بهتر پاتوفیزیولوژیک آریتمی AF و درنتیجه درمان مؤثرتر آن کمک بسزایی می‌کند.

ازآنجاکه سازوکار پاتوفیزیولوژیک AF هنوز کامل شناخته‌شده نیست، تجزیه‌وتحلیل دستی ریتم پیوستهٔ سیگنال‌های ECG[5] زمان‌بر و پیچیده است. در سال‌های گذشته میزان پژوهش‌های متمرکز برای تشخیص خودکار AF افزایش یافته‌است[۵]. روش‌های غیرتهاجمی مختلفی برای تشخیص AF با استفاده از سیگنال‌های ECG پیشنهادشده‌است که اغلب از تجزیه‌وتحلیل موج f (f-wave[6]) بهره برده‌اند. سیگنال فیبریلاتور دهلیزی (موج f) سیگنالی نامنظم با دامنهٔ بسیار اندک (در مقایسه با دامنهٔ سیگنال PQRST قلبی) است که دراثر بی‌نظمی انقباض‌های دهلیزی در سیگنال ECG فرد مبتلا به AF مشاهده می‌شود؛ به‌طوری‌که، دیگر پیک‌های P قابل‌شناسایی نیستند و در موج f پنهان می‌شوند. همان‌طورکه پیش‌تر اشاره‌شد؛ به‌دلیل این‌که امواج f دامنهٔ بسیار کوچک‌تری نسبت به دامنهٔ کمپلکس‌های QRST در سیگنال ECG دارند، بهتر است که ابتدا موج f از سیگنال ECG استخراج شود تا رفتار آن مؤثرتر موردبررسی قرارگیرد. روش‌های مختلفی برای استخراج موجf پیشنهادشده‌است که درکل به‌صورت زیر طبقه‌بندی می‌شوند: درون‌یابی فاصله QT [۶-۷]، تفریق ضربان متوسط[7] [۸] و انواع توسعه‌یافتهٔ آن [۹-۱۰]، پالایهٔ تطبیقی غیرخطی با استفاده از شبکهٔ عصبی [۱۱-۱۲]، تجزیه‌وتحلیل مؤلفه‌های اصلی و مستقل [۱۳-۱۵]، هندسهٔ ترکیبی [۱۶] و پالایهٔ کالمن توسعه‌یافته[۱۷]؛ دراین‌میان، روش‌های مبتنی بر تفریق ضربان متوسط مورداستقبال بیشتری قرارگرفته‌اند. پس از استخراج موج f ویژگی‌های مختلفی برای توصیف آن و طبقه‌بندی AF پیشنهادشده‌است که از مهم‌ترین آن‌ها می‌توان به‌موارد زیر اشاره کرد: [۱۸-۱۹] ویژگی‌های فرکانسی را برای تشخیص AF پیشنهاد کرده‌اند، [۲۰] ویژگی‌های دامنهٔ موج f را با استفاده از بزرگی هارمونیک‌ها مشخص می‌کند، [۲۱] روش مدل پیش‌بینی چندمتغیرهٔ مبتنی بر رگرسیون ترابری را برای مدل‌کردن امواج f به‌کار گرفته‌است، در [۲۲] موج f با استفاده از روش تجزیهٔ مد ذاتی آنالیز شده‌است، [۲۳] از ویژگی‌های دامنهٔ موج f و چگالی طیف توان آن بهره برده‌است. درمطالعهٔ دیگر [۲۴] از ویژگی‌های آماری، هندسی، دامنهٔ فرکانس و پوانکاره[8] استفاده شده‌است. [۲۵] ویژگی‌های مبتنی بر مدل آنتروپی شرطی تصحیح‌شده و رگرسیون خودکار را به‌کارگرفته و در [۲۶] از تبدیل چرپلت[9] و شبکهٔ عصبی عمیق کانولوشنی استفاده شده‌است.

همان‌طورکه مشاهده می‌شود درسال‌های گذشته، تلاش‌های ارزنده‌ای در زمینهٔ 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 Fibrilation
[2] Paroxysmal AF
[3] Persistent AF
[4] Permanent AF
[5] Electroencephalogram
[6] Atrial fibrillatory signal
[7] Average beat subtraction
[8] Poincar
[9] Chirplet

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

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 غیرایستان و دارای تغییرات زمانی و فرکانسی شدیدی است.

دراین‌مقاله برای استخراج موج f از سیگنال ECG، از یک روش ترکیبی به‌نام PiCA-ESN[1] که برپایهٔ دو روش آنالیز مؤلفه‌های اصلی و پالایهٔ تطبیقی غیرخطی است، استفاده شده‌است[۳]. این روش درسال ۲۰۲۲ مطرح‌شده و از مزایای جداسازی سیگنال‌ها از منبع[2] و پالایهٔ تطبیقی غیرخطی[3] بهره برده‌است و موج f دقیق‌تری نسبت به سایر روش‌ها استخراج می‌کند. پس از استخراج موج f، در ادامه باتوجه به ماهیت غیرایستان موج f ویژگی‌های حوزهٔ زمان-فرکانس موج fبا استفاده از اندازهٔ تبدیل stockwell (تبدیل S) محاسبه و به طبقه‌بند اعمال می‌شود.

درادامهٔ این مقاله، در بخش دوم تبدیل S و در بخش سوم پایگاه دادهٔ مورد استفاده معرفی می‌شود. الگوریتم پیشنهادی برای پیش‌بینی AF دربخش چهارم ارائه می‌شود. بخش پنجم و ششم نیز به‌ترتیب به بحث‌وبررسی نتایج و نتیجه‌گیری می‌پردازند.

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

از آنجاکه سیگنال‌های ECG و فیبریلاتور دهلیزی (موجf) دارای ویژگی‌های غیرخطی و غیرایستایی‌اند، روش‌های مختلف آنالیز زمان-فرکانس، مانند تبدیل فوریهٔ زمان‌کوتاه و تبدیل موجک به‌طورمعمول برای تجزیه‌وتحلیل آن‌ها استفاده شده‌است. تبدیل فوریهٔ زمان‌کوتاه باتوجه به ثابت‌بودن عرض پنجره، نمی‌تواند هم‌زمان وضوح زمان-فرکانس مناسبی را فراهم آورد. تبدیل موجک برخلاف تبدیل فوریهٔ زمان‌کوتاه با تجزیهٔ هر سیگنال به چندین مقیاس مختلف به‌طوری‌که هر مقیاس نشان‌دهندهٔ وضوح خاصی از سیگنال است می‌تواند وضوح زمان-فرکانس مناسبی از سیگنال ارائه‌دهد؛ ازطرفی از معایب آن می‌توان به چالش انتخاب مناسب‌ترین موجک مادر و ازدست‌دادن فاز مطلق اشاره‌کرد[۲۷].

تبدیل Stockwell (تبدیل S)، توسعه‌یافتهٔ تبدیل موجک پیوسته برپایهٔ 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 $z(t)$ به‌صورت زیر نمایش داده می‌شود:

$$S_z(\tau,f) = e^{j2\pi\tau} W_z(\tau,d) \qquad (۱)$$

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

$$W_z(\tau,d) = \int_{-\infty}^{+\infty} z(t) w(t-\tau,d)dt \qquad (۲)$$

$$w(t,f) = \frac{|f|}{\sqrt{2\pi}} e^{\frac{-t^2 f^2}{2}} e^{-j2\pi ft} \qquad (۳)$$

بنابراین رابطهٔ (۱) به‌صورت زیر تغییر می‌یابد:

$$S_z(\tau,f) = \int_{-\infty}^{+\infty} z(t) \frac{|f|}{\sqrt{2\pi}} e^{\frac{-(\tau-t)^2 f^2}{2}} e^{-j2\pi ft} dt \qquad (۴)$$

همان‌طور که مشاهده می‌شود در رابطهٔ (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 فوریهٔ گسسته (DFT[4]) سیگنال ورودی محاسبه می‌شود. تبدیل DFT برای سیگنال گسسته در زمان $z[nT]$ که حاصل نمونه‌برداری N نقطه‌ای با دورهٔ تناوب T از سیگنال پیوستهٔ $z(t)$ است، برابراست با [۲۷]:

$$Z\left[\frac{k}{NT}\right] = \frac{1}{N}\sum_{n=0}^{N-1} z[nT] e^{\frac{-j2\pi kn}{N}},$$
$$k = 0,1 \dots, N-1 \qquad (۵)$$

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

[1] PiCA-ESN (periodic component analysis & echo state neural network)
[2] Source seperation
[3] Non-linear adabtive filter
[4] Discrete Fourier transform

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

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

$$S_z\left[mT, \frac{n}{NT}\right] = \sum_{k=0}^{N-1} z\left[\frac{k+n}{NT}\right] e^{\frac{-2\pi^2 k^2}{n^2}} e^{\frac{-j2\pi kn}{N}},$$
$$n, m = 0,1,2,\dots,N-1 \qquad (۶)$$

که در آن تابع $e^{\frac{-2\pi^2 k^2}{n^2}}$ نشان‌دهندهٔ تابع گوسین است. اندازهٔ تابع تبدیل S به‌کمک رابطهٔ زیر محاسبه می‌شود که دراین مطالعه به‌منظور استخراج ویژگی از آن استفاده شده‌است. برای مطالعهٔ جزئیات بیشتر درمورد تبدیل S به [۲۷] مراجعه نمایید.

$$|S_z| = \sqrt{(Rel\{S_z\})^2 + (Im\{S_z\})^2} \qquad (۷)$$

۳- پایگاه داده

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

پایگاه داده به یک مجموعه‌آموزش و دو مجموعه‌آزمایش (A و B) تقسیم شده‌است. سی سیگنال ECG ضبط‌شده در مجموعه‌آموزش قراردارد که به سه کلاس با نام‌های AF خاتمه‌نیافتهٔ (N)، بلافاصله خاتمه‌یافتهٔ (T)، یا به‌زودی خاتمه‌یافتهٔ (S) تقسیم می‌شوند. ده سیگنال از مجموعه آموزش برچسب N دارند، بدین معنی که AF حداقل یک‌ساعت پس از پایان ضبط ادامه می‌یابد. بیست سیگنال دیگر متعلق به ده بیمار مختلف است که برچسب S یا T به این‌معنی‌که AF در یک دقیقه پس از پایان ضبط (S) و یا یک ثانیه پس از پایان ضبط (T) پایان می‌یابد. جمع‌بندی اطلاعات درمورد مجموعه‌های آموزش و آزمایش این پایگاه داده در جدول (۱) ارائه شده‌است. لازم به‌ذکر است که هدف چالش طبقه‌بندی دوحالت مختلف دو کلاسهٔ T در مقابل S و همچنین T درمقابل N است.

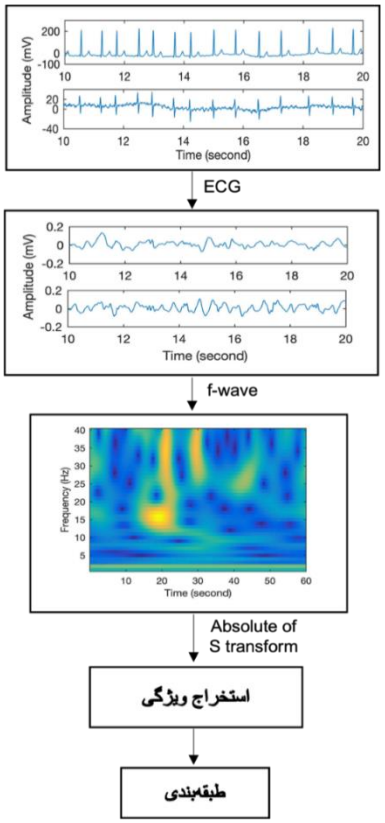
(جدول-۱): جزئیات پایگاه داده
(Table-1): Details of the Database

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

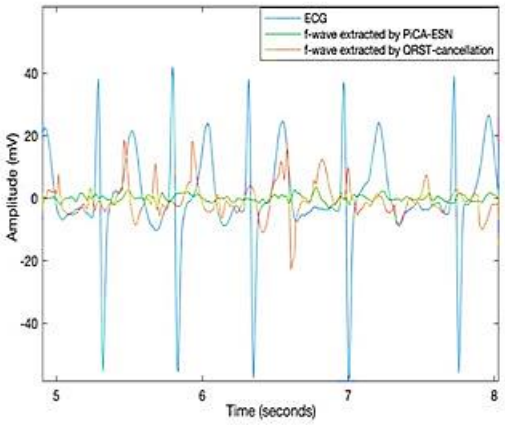
۴- روش پیشنهادی

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

نوفهٔ تداخل برق شهری نیز به کمک تبدیل S از سیگنال‌های ECG حذف می‌شود که در ادامه توضیح داده خواهد شد؛ پس‌ازآن، موج f از سیگنال‌های ECG استخراج می‌شود و درادامه ویژگی‌های مختلفی از اندازهٔ تبدیل S استخراج و پس از نرمال‌شدن با استفاده از روش اعتبارسنجی ۱۰-دسته‌ای[1] به طبقه‌بندها اعمال می‌شوند؛ همان‌طورکه درشکل (۱) نشان داده‌شده‌است.



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



[1] 10-fold cross validation

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

(شکل-۲): مقایسهٔ موج f استخراج‌شده توسط الگوریتم PiCA-ESN و الگوریتم سرکوب‌کنندهٔ پیک‌های QRST-

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

قسمت نخست و دوم شکل (۱) به‌ترتیب، سیگنال‌های ECG متعلق به یک بیمار در دو کانال مختلف و موج‌های f استخراج شده از ECGها را برای مثال نمایش می‌دهد (لازم به‌ذکر است که سیگنال‌ها شصت‌ثانیه‌ای‌اند و برای وضوح بهتر در قسمت نخست و دوم از شکل (۱) به‌صورت بیست‌ثانیه‌ای نمایش داده شده‌اند).

درادامه اندازهٔ تبدیل S برای موج f (شصت‌ثانیه‌ای) محاسبه‌شده که تصویر یک کانال آن برای مثال درقسمت سوم شکل (۱) نمایش داده‌شده‌است. دراین مطالعه از نرم‌افزار MATLAB برای آنالیز داده‌ها استفاده شده‌است.

۴-۱- استخراج موج f

دراین مقاله از الگوریتم PiCA-ESN برای استخراج موج f استفاده‌شده که در [۳] معرفی شده‌است. این الگوریتم با استفاده از اطلاعات محل پیک‌های R و روش آنالیز مولفهٔ متناوب اصلی (PiCA) [۳۰] سیگنال مربوط به بطن‌ها را از سیگنال ECG استخراج و به‌عنوان 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 به‌محل پیک‌های R نیاز دارد. دراین مقاله از الگوریتم شناخته‌شده Pan-Tompkins [۳۱] برای استخراج محل پیک‌های R استفاده شده‌است؛ پس از استخراج محل قرارگرفتن پیک‌های R، از الگوریتم PiCA-ESN جهت استخراج امواج فیبریلاتور دهلیزی (موج f) استفاده می‌شود.

شکل (۲) موج f استخراج‌شده توسط الگوریتم PiCA-ESN در مقایسه با الگوریتم سرکوب‌کنندهٔ پیک‌های QRST-[1] که مبتنی بر روش تفریق ضربان متوسط است و اغلب مقاله‌های منتخب چالش ۲۰۰۴ فیزیونت از آن بهره‌گرفته‌اند را نمایش می‌دهد. به‌نظر می‌رسد که موج f استخراج‌شده توسط الگوریتم سرکوب‌کنندهٔ پیک‌های QRST- حاوی باقیماندهٔ متناظر با پیک‌های QRST (سیگنال مرتبط به بطن‌ها) بیشتری است؛ همچنین برای اثبات این ادعا آزمایشی روی مجموعه‌آزمایش A طراحی شده‌است؛ به‌طوری‌که ویژگی‌های یک‌سانی از امواج f استخراج‌شده توسط هر دو الگوریتم محاسبه‌شده و به طبقه‌بند SVM اعمال می‌شود. نتایج این آزمایش در جدول (۲) نشان‌دهندهٔ درستی ادعای مطرح‌شده است؛ به‌طوری‌که، الگوریتم PiCA-ESN در استخراج موج f موفق‌تر بود و منجر به طبقه‌بندی با دقت بالاتری شده‌است .

(جدول-۲) : مقایسهٔ کیفیت موج f استخراج‌شده توسط الگوریتم‌های PiCA-ESN و سرکوب‌کنندهٔ 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٪
سرکوب‌کنندهٔ پیک‌های QRST-	۸۱٪	۸۰٪

۴-۲- استخراج ویژگی

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

در این مطالعه باتوجه 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 به‌ذکر است که از آنجاکه امواج f اغلب با فرکانس‌هایی کمتر از ۲۵هرتز مشخص می‌شوند به استناد مرجع [۳۲] و همچنین به‌منظور حذف نوفهٔ پنجاه‌هرتز برق شهری از سیگنال، محدودهٔ ۴۰-۱ هرتز برای محاسبهٔ تبدیل S درنظر گرفته شده‌است؛ البته محدودهٔ فرکانسی ۴۰-۱ هرتز پس از بررسی عملکرد روش پیشنهادی در محدوده‌های فرکانسی مختلفی مابین یک هرتز و بیشتر از ۲۵هرتز تا کمتر از پنجاه هرتز انتخاب شده‌است.

۴-۲-۱- فرکانس لحظه‌ای

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

[1] QRST-cancellation algorithm

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]

[DOI: 10.61186/jsdp.21.2.43]

فرکانس S_z به‌عنوان ویژگی استفاده می‌شود که به‌کمک رابطهٔ (۸) محاسبه می‌شود[۱۹]. برای بازتوصیف بهتر فرکانس لحظه‌ای از آمارگان‌های مختلفی نظیر میانگین، میانه، کشیدگی، چولگی، انحراف معیار، بیشینه و کمینه استفاده می‌شود.

$$f_{i,z}[n] = \frac{f_s}{2N} \frac{\sum_{n=0}^{N-1} nS_z}{\sum_{n=0}^{N-1} S_z} \quad (۸)$$

۴-۲-۲- تمرکز انرژی[1]:

برای محاسبهٔ کمّی تمرکز انرژی موج f درحوزهٔ زمان-فرکانس از رابطهٔ زیر استفاده می‌شود.

$$EC_z = (\sum_{n=0}^{N-1} \sum_{m=0}^{M-1} S_z^{\frac{1}{2}})^2 \quad (۹)$$

۴-۲-۳- همواری طیفی موج f:

همواری طیفی، توزیع توان سیگنال را درحوزهٔ زمان-فرکانس نشان می‌دهد[۳۳]. می‌توان افزایش همواری طیفی را به‌معنی وجود پیک‌های بزرگ‌تر در موج f درنظرگرفت که ویژگی کارآمدی برای تشخیص AF است[۲۰]. برای بازتوصیف بهتر همواری طیفی از آمارگان‌های مختلفی نظیر میانگین، میانه، کشیدگی، چولگی، انحراف معیار، چارک نخست و چارک سوم استفاده می‌شود.

$$TFF_z = \frac{(\prod_{n=0}^{N-1} \prod_{m=0}^{N-1} S_z)^{\frac{1}{N^2}}}{\sum_{n=0}^{N-1} \sum_{m=0}^{N-1} S_z} \quad (۱۰)$$

۴-۲-۴- آنتروپی Renyi

این معیار میزان پیچیدگی توزیع زمان- فرکانس را مشخص می‌کند. هرچه مقدار این معیار کمتر باشد، به‌معنی پیچیدگی (آشفتگی) کمتر توزیع زمان-فرکانس و می‌توان معادل تفکیک‌پذیری بالاتر و تمرکز انرژی بیشتر دانست. آنتروپی Renyi با استفاده از رابطهٔ (۱۱) محاسبه می‌شود که در آن α مرتبهٔ آنتروپی را مشخص می‌کند که یک عدد صحیح و به‌طورمعمول بزرگ‌تر از یک است[۳۳].

$$RE_z(\alpha) = \frac{1}{1-\alpha} \log_2 \sum_{n=0}^{N-1} \sum_{m=0}^{N-1} S_z^{\alpha} \quad (۱۱)$$

۴-۲-۵- آنتروپی Sample[2]

آنتروپی نمونه (SampEn) درواقع نسخهٔ اصلاح‌شدهٔ آنتروپی تقریبی[3] است که برای ارزیابی پیچیدگی سیگنال‌های فیزیولوژیکی استفاده می‌شود. در این مقاله، به‌منظور ارزیابی پیچیدگی مؤلفه‌های فرکانسی مختلف درطول زمان استفاده شده‌است؛ به‌این‌صورت که آنتروپی نمونهٔ سطرهای مختلف تصویر زمان- فرکانس S_z محاسبه‌شده و میانگین آن‌ها به‌عنوان ویژگی در بردار ویژگی ذخیره می‌شود.

۴-۳- طبقه‌بندی

در این مقاله برای افزایش قابلیت اطمینان صحت طبقه‌بندی از ترکیب سه طبقه‌بند و روش رأی‌گیری حداکثر استفاده شده‌است؛ زیرا در کاربردهای پزشکی افزایش درصد تشخیص درست و کاهش درصد تشخیص نادرست مطلوب است. طبقه‌بندهای شبکهٔ عصبی پرسپترون چندلایه (MLP[4])، ماشین بردار پشتیبان (SVM[5]) و AdaBoost انتخاب شده‌اند. الگوریتم پیشنهادی با داده‌های آموزش و آزمایش مطابق جدول (۱) مورد آموزش و آزمایش قرار می‌گیرد.

۴-۳-۱- شبکه‌های عصبی MLP:

یکی از پرکاربردترین و شناخته‌شده‌ترین طبقه‌بندهاست که دارای سه‌نوع لایهٔ ورودی، مخفی (میانی) خروجی است؛ دراین‌مقاله، از طبقه‌بند MLP با سه لایهٔ مخفی با هفتاد، سی و پانزده نورون با توابع فعال‌سازی سیگموئید تانژانت هیپربولیک و لگاریتمی استفاده شده‌است. برای آموزش شبکهٔ عصبی در این مطالعه، از روش پس انتشار لونبرگ-مارکوارت[6] و هزار بار تکرار استفاده شده‌است.

۴-۳-۲- ماشین بردار پشتیبان (SVM):

SVM یکی از طبقه‌بندهاست که دراین مطالعه استفاده شده‌است. SVM سعی می‌کند داده‌ها را با یک ابرصفحهٔ بهینه جدا کند[۳۴]؛ دراین‌مقاله، SVM با هسته‌های مختلف گاوسی، خطی و چندجمله‌ای آزمایش شده‌است و بهترین نتیجه با توابع هستهٔ RBF[7] غیرخطی حاصل شده‌است[۳۴].

۴-۳-۳- AdaBoost

درکل می‌توان گفت که طبقه‌بند Adaboost از تعداد زیادی درختان تصمیم‌گیری کوچک که هریک برخی از ویژگی‌ها را انتخاب می‌کنند، تشکیل شده‌است. خروجی این طبقه‌بند از طریق ترکیب خروجی پیش‌بینی‌شده توسط طبقه‌بندهای ساخته‌شده به‌دست می‌آید[۳۳]؛ به‌دلیل قدرتش در جلوگیری از آموزش بیش‌ازحد[8] و قابلیت سازگاری با مدل‌های مختلف و استفادهٔ آسان

[1] Energy concentration measure
[2] Sample entropy
[3] Approximate Entropy
[4] Multilayer perceptron
[5] Support vector machine
[6] Levenberg-Marquardt backpropagation method
[7] Radial base functions
[8] Overfitting

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

موردتوجه قرار می‌گیرد. رویکرد مرحلهٔ آموزش بدین‌صورت است که سیگنال‌هایی که در مراحل قبل به اشتباه طبقه‌بندی شده‌اند با احتمال بیشتری برای آموزش طبقه‌بند درمرحلهٔ بعد مورد استفاده قرار می‌گیرند و آموزش طبقه‌بندهای متوالی، به‌سمت سیگنال‌هایی که پیش‌بینی آن‌ها دشوار است، سوق پیدا می‌کند[۳۳]؛ دراین‌مقاله از صد طبقه‌بند درخت تصمیم به‌عنوان طبقه‌بندهای ضعیف با الگوریتم هماهنگ‌سازی SAMME[1] شده‌است.

۵- نتایج شبیه‌سازی

در این قسمت نتایج شبیه‌سازی روش پیشنهادی درقالب سه‌بخش زیر گزارش می‌شود: در بخش نخست عملکرد طبقه‌بندها بررسی می‌شود. در بخش دوم نتایج به‌دست‌آمده به‌کمک طبقه‌بند منتخب با نتایج برگزیدهٔ چالش فیزیونت و مطالعاتی که به‌تازگی روی این پایگاه داده انجام‌شده مقایسه و دربخش آخر پایداری ویژگی‌های پیشنهادی با به‌کارگیری قطعات چهارثانیه‌ای سیگنال ارزیابی می‌شود.

گفتنی است که از معیارهای دقت[2]، حساسیت[3]، اختصاصیت[4] و امتیاز F1[5] (برحسب درصد) برای ارزیابی نتایج استفاده شده‌است.

$$\text{دقت} = \frac{TP+TN}{TP+TN+FP+FN} \qquad (۱۲)$$

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

$$\text{حساسیت} = \frac{TP}{TP+FN} \qquad (۱۳)$$

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

$$\text{اختصاصیت} = \frac{TN}{TN+FP} \qquad (۱۴)$$

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

$$\text{امتیاز} F1 = \frac{2\times TP}{2\times TP+FP+FN} \qquad (۱۵)$$

امتیاز F1 یک معیار جامع است که توازن بین دقت و حساسیت را بیان می‌کند و به‌طورمعمول برای زمان‌هایی که تعادل بین دقت و حساسیت مهم است مانند کاربردهای پزشکی استفاده می‌شود و نشان می‌دهد چقدر مدل در شناسایی موارد مثبت واقعی و شناسایی‌نکردن موارد منفی واقعی موفق بوده‌است.

در این روابط،[6] TP به‌معنای تعداد موارد درستی که مدل به‌درستی به‌عنوان مثبت تشخیص داده‌است،[7] TN به‌معنای تعداد موارد درستی که مدل به‌درستی به‌عنوان منفی تشخیص داده‌است،[8] FN به‌معنای تعداد مواردی است که مدل به اشتباه به‌عنوان منفی تشخیص داده‌است،[9] FP به‌معنای تعداد مواردی است که مدل به اشتباه به‌عنوان مثبت تشخیص داده‌است.

۵-۱- بخش نخست

در این بخش عملکرد طبقه‌بندهای مختلف به‌تنهایی و همچنین به‌صورت ترکیبی با روش رأی حداکثر[10] بررسی می‌شود؛ برای این منظور ویژگی‌های استخراج‌شده به طبقه‌بندها اعمال و عملکرد طبقه‌بندی‌ها مقایسه می‌شود. جدول (۳) نتایج به‌دست‌آمده را نشان می‌دهد. همان‌طور که انتظار می‌رود ترکیب طبقه‌بندها عملکرد بهتری نسبت به عملکرد هرکدام از طبقه‌بندها با معیار دقت، حساسیت، اختصاصیت و امتیاز F1 دارد.

(جدول-۳) : مقایسهٔ عملکرد طبقه‌بندهای مختلف روی مجموعه داده‌های آزمون A

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٪

(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 به‌دست‌آمده توسط روش‌های برگزیدهٔ چالش فیزیونت ۲۰۰۴ و همچنین مقاله‌هایی که به‌تازگی روی این پایگاه داده منتشرشده، مقایسه و در جدول (۴) گزارش شده‌است. جدول (۴) نشان می‌دهد که

[1] Stagewise additive modeling using a multiclass exponential loss function
[2] Acuuracy
[3] Recall
[4] Specificity
[5] F1 Score

[6] True Positives
[7] True Negetives
[8] False Negetives
[9] False Positives
[10] Major voting

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

روش پیشنهادی توانسته داده‌ها را با دقت بالاتری طبقه‌بندی کند.

۵-۳ - بخش سوم

بخش سوم به بررسی پایداری ویژگی‌ها درطول سیگنال اختصاص داده‌شده است. انتظار می‌رود یک ویژگی کارآمد در تمام طول یک سیگنال طولانی با برچسب یکسان عملکرد مشابهی داشته‌باشد؛ 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 محاسبه‌شده، پس‌ازآن ویژگی‌های موردنظر از اندازهٔ تبدیل S استخراج‌شده و به طبقه‌بند اعمال می‌شوند.

جدول (۵)، دو سیگنال مختلف متعلق به دو بیمار متفاوت از کلاس‌های مختلف N و T مجموعه آموزش را به‌عنوان مثال نشان می‌دهد. در این جدول به‌دلیل کمبود فضا خروجی واقعی و پیش‌بینی‌شده برای چهار بخش از پانزده بخش هرکدام از سیگنال‌ها برای مثال نمایش داده‌شده‌است (خطا با رنگ قرمز مشخص شده‌است). نتایج جدول (۵) نشان می‌دهند تمامی بخش‌های نشان‌داده‌شده جز یک بخش به‌درستی پیش‌بینی شده‌اند؛ همچنین تمام معیارهای ارزیابی برای تمام سیگنال‌های شرکت‌داده‌شده در این آزمایش محاسبه‌شده و درجدول (۶) با نتایج مطالعهٔ [۲۶] (که به‌تازگی مطرح‌شده و از همین پایگاه داده استفاده کرده‌است) مقایسه شده‌است. نتایج این آزمایش نشان می‌دهند که اگرچه عملکرد روش پیشنهادی در به‌کارگیری سیگنال ECG با طول کوتاه‌تر (چهارثانیه‌ای) بی‌تغییر نمانده و کاهش داشته‌است، اما از مقایسهٔ جدول‌های (۶) و (۳) می‌توان گفت ویژگی‌های پیشنهادی برای سیگنال ECG چهارثانیه‌ای درمقایسه با سیگنال ECG پانزده ثانیه‌ای پایداری قابل قبولی را نشان می‌دهند. همچنین نتایج نشان می‌دهد که ویژگی‌های پیشنهادی عملکرد بهتری نسبت به مطالعهٔ [۲۶] دارد.

گفتنی است در این آزمایش قسمت‌های مختلف یک سیگنال یا در مرحلهٔ آموزش شرکت داشته‌اند و یا در مرحلهٔ آزمایش، یعنی هیچ دو قسمتی از یک سیگنال هم‌زمان هم در آزمایش و هم در آموزش شرکت‌داده نشده‌اند؛ به‌علاوه در این قسمت برای داشتن مقایسهٔ عادلانه با [۲۶] تنها از داده‌های آموزش و بخش چهار ثانیه‌ای (مطابق با [۲۶]) استفاده شده‌است که در دو کلاس AF پایان‌یافته (T&S) و پایان‌نیافته (N) طبقه‌بندی شده‌اند.

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

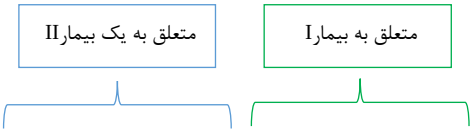
(Table-4) : Correct classification rate of the proposed method comparing with other methods

روش‌ها	طول سیگنال (ثانیه)	داده‌های آزمونA	داده‌های آزمونB
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کنندهٔ پیک‌های-QRST و آنالیز حوزهٔ فرکانس[۳۵]	۶۰	٪۹۷	٪۱۰۰
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کنندهٔ پیک‌های-QRST و آنالیز حوزهٔ زمان و فرکانس [۳۶]	۶۰	٪۹۳	٪۸۰
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کنندهٔ پیک‌های-QRST و آنالیز فرکانس [۳۷]	۶۰	٪۹۰	٪۱۰۰
روش مبتنی بر استخراج موج f با استفاده از فاصلهٔ QT و ویژگی‌های کلینیکی [۳۸]	۶۰	٪۹۰	*
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کنندهٔ پیک‌های-QRST توسعه‌یافته و آنالیز حوزهٔ زمان-فرکانس [۴]	۶۰	٪۹۰	*
روش مبتنی بر آنالیز حوزهٔ فرکانس فواصل R-R [۳۹]	۶۰	*	٪۸۰
روش مبتنی بر استخراج موج f با استفاده از الگوریتم سرکوب‌کنندهٔ پیک‌های-QRST و آنالیز حوزهٔ فرکانس[۴۰]	۶۰	*	٪۸۰
روش شبکهٔ 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 نشده‌است.

(جدول-۵): یک نمونه مثال از نتایج به‌دست‌آمده در مقایسه با مقدار خروجی واقعی برای دو سیگنال متفاوت از مجموعه‌داده‌های آموزش

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



[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]

[DOI: 10.61186/jsdp.21.2.43]

پایگاه داده	N	N	N	N	T	T	T	T
خروجی واقعی	۰	۰	۰	۰	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 چهارثانیه‌ای

(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 به‌کمک تبدیل S محاسبه شد. در ادامه ویژگی‌ها از دامنهٔ 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 درطول یک سیگنال با تقسیم متوالی یک سیگنال به بخش‌های چهار ثانیه‌ای طراحی و آزمایش شد. نتایج به‌دست‌آمده حاکی از پایداری قابل‌قبول ویژگی‌های پیشنهادی است.

۷- مراجع 7-Refrences

[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. 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. Mihandoost, 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. Sornmo, "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. Petrėnas, 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]

[DOI: 10.61186/jsdp.21.2.43]

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. 998–100, 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 چندهسته‌ای بهینه»، پردازش علائم و داده‌ها، دورهٔ ۱۹، شمارهٔ 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. Sornmo, "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. Sornmo, 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 detectionof 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]
[DOI: 10.61186/jsdp.21.2.43]

[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 رشتهٔ مهندسی برق گرایش سیستم در سال ۱۳۹۵ از دانشگاه ارومیه دریافت کرده‌است؛ همچنین از سال ۲۰۱۹ تا ۲۰۲۱، پژوهش‌گر پسادکترا در آزمایشگاه تشخیصی و تصویربرداری دانشگاه لورن فرانسه فعالیت بود. او از سال ۱۳۹۹ به گروه مهندسی برق دانشگاه صنعتی ارومیه پیوست و درحال‌حاضر استادیار این دانشگاه است. علایق پژوهشی او تجزیه‌وتحلیل بافت، پردازش سیگنال‌های زیست‌پزشکی، مدل‌سازی سیگنال، تشخیص الگو و پردازش سیگنال‌های تصادفی است.

نشانی رایانامهٔ ایشان عبارت است از:

Sara.mihandoost@uut.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]

[DOI: 10.61186/jsdp.21.2.43]

[DOI: 10.61186/jsdp.21.2.43] [Downloaded from jsdp.rcisp.ac.ir on 2026-11-04]