

Heart arrhythmia diagnosis by neural networks using chaotic features of HRV signal and generalized discriminant analysis

R. Soleymani¹, M.Rouhani^{2*}

¹Lecturer, Islamic Azad University of Sabzevar, Iran,
soleymani.r@gmail.com

²Assistant Professor, Islamic Azad University of Gonabad, Iran,
modjtaba_rouhani@yahoo.com

Abstract

in this paper, a novel and effective algorithm for classification of important heart arrhythmia is presented. The proposed algorithm uses heart rate variation (HRV) signal which has better chaotic characteristics. In addition to commonly used linear time domain and frequency domain features, nonlinear (chaotic) features are examined, too. To increase classification accuracy and facilitate learning, two techniques are used: a) extracted features are reduced by generalized discriminant analysis (GDA) and b) by a self organizing map (SOM), the most informant data are selected. Chaotic features help to improve diagnosis accuracy from 92% up to 97%. The results indicate the importance of GDA and SOM in efficiency of proposed algorithm. MLP, SVM and PNN classifiers are examined and compared. The proposed algorithm was able to diagnose 7 arrhythmias PVC, AFL, AF, CHB, LBBB, VF, VT and normal sinus rhythm (NSR) with 97.4% accuracy.

Keywords: Heart arrhythmia, Electrocardiography (ECG), Heart rate variability (HRV), neural networks, Support vector machines (SVM), self organizing maps (SOM), generalized discriminant analysis (GDA).

* Corresponding author
Address: Modjtaba Rouhani, Islamic Azad University of Gonabad, Mashhad, Iran.
Tel: +98 5337255000
Fax: +98 5337255005
E-mail: modjtaba_rouhani@yahoo.com

تشخیص آریتمی‌های قلبی بکمک شبکه‌های عصبی با بکارگیری ویژگی‌های آشوبی سیگنال نرخ تغییرات قلبی و تکنیک تحلیل تمایزی تعمیم یافته

رضا سلیمانی^۱، سید مجتبی روحانی^{۲*}

^۱ مربی دانشگاه آزاد اسلامی، واحد سبزوار

soleymani.r@gmail.com

^۲ استادیار دانشگاه آزاد اسلامی، واحد گناباد

modjtaba_rouhani@yahoo.com

چکیده

در این مقاله یک الگوریتم جدید و مؤثر جهت طبقه‌بندی آریتمی‌های مهم قلبی با استفاده از سیگنال تغییرات ضربان قلب HRV که دارای مشخصه‌های آشوبگونه بهتری نسبت به ECG ست پیشنهاد شده است. در مرحله استخراج ویژگی، علاوه بر ویژگی‌های متداول خطی زمانی و فرکانسی، ویژگی‌های غیرخطی (آشوبگون) نیز بررسی شده‌اند. برای تسهیل در تعلیم و افزایش دقت طبقه‌بندی‌کننده، از دو تکنیک استفاده شده است: الف) تعداد ویژگی‌های استخراج شده توسط تکنیک آنالیز تمایزی تعمیم یافته GDA کاهش یافته است بدون آنکه این کاهش محتوای اطلاعات موجود را تقلیل دهد. ب) به کمک یک نگاشت خودسازمانده SOM برای هر گروه از داده‌ها، داده‌هایی برای تعلیم انتخاب شده‌اند که بیشترین محتوای اطلاعات را در مورد آن گروه داشته باشند. بررسی نتایج نشان می‌دهد که ویژگی‌های آشوبگونه نقش موثری در افزایش دقت سیستم تشخیص آریتمی قلبی دارد بنحوی که دقت کلی روش از حدود ۹۲٪ به ۹۷٪ افزایش یافته است. همچنین این نتایج موید اهمیت بکارگیری تکنیک‌های GDA و SOM به نحو پیش گفته است. در مرحله طبقه‌بندی طبقه‌بندهای MLP و SVM و PNN مورد استفاده قرار گرفته و نتایج مقایسه شده است. در این مقاله ۷ نوع آریتمی مختلف VT, VF, LBBB, CHB, AF, AFL, PVC و نیز گروه ضربانهای طبیعی (NSR) با دقت کلی ۹۷.۴ درصد شناسایی و طبقه‌بندی شده‌اند.

کلیدواژگان: آریتمی قلبی، سیگنال ECG، سیگنال HRV، شبکه عصبی مصنوعی، ماشینهای بردار پشتیبان SVM، تحلیل تمایزی تعمیم یافته GDA، نگاشت خودسازمانده SOM

عهده‌دار مکاتبات

نشانی: ایران، مشهد، گناباد، خیابان دانشگاه، دانشگاه آزاد اسلامی

تلفن: ۰۵۳۳۷۲۵۵۰۰۰، دورنگار: ۰۵۳۳۷۲۵۵۰۰۵، پیام نگار: modjtaba_rouhani@yahoo.com

۱- مقدمه

بیماری های قلب و عروق از شایع ترین بیماری های قرن حاضر محسوب شده و نارسایی قلبی امروزه بزرگترین عامل مرگ و میر در جوامع صنعتی و نیمه صنعتی به حساب می آیند. به دلیل اهمیت موضوع، ابزارها و روش های مختلفی برای بررسی نحوه عملکرد قلب در پزشکی نوین ابداع گردیده است. هدف در تمام روش ها به دست آوردن انواع مختلف و مکمل اطلاعات ساختاری و عملکردهای قلب است، به نحوی که به کمک آنها پزشک متخصص نه تنها توانایی تشخیص نوع بیماری قلبی را داشته باشد، بلکه بتواند بروز نارسایی قلبی احتمالی در آینده را نیز پیش بینی و از آن جلوگیری نماید. هدف از این تحقیق ارائه روشی برای تشخیص خودکار آریتمی های قلبی برای کمک به پزشک است.

متداول ترین روش برای تشخیص آریتمی های قلبی، آنالیز سیگنال فعالیت الکتریکی قلب الکتروکاردیوگرام است که به اختصار آن را ECG می نامند. ECG اطلاعات مهمی در مورد نحوه عملکرد قلب و نارسایی های آن در اختیار ما قرار می دهد. از آنجایی که بیماری های قلبی گسترده اند و همچنین پارامترهای زیادی می توان از سیگنال ECG استخراج نمود، لذا در کارهای گذشته در این زمینه تنوع فراوانی در انتخاب بیماری ها، پارامترهای استخراجی از ECG و روش انتخابی جهت طبقه بندی آریتمی های قلبی مشاهده می گردد. اکثر سیستم های تشخیص آریتمی قلبی شامل بخشهای دریافت سیگنال قلبی، پیش پردازش سیگنال، استخراج ویژگی هایی که بر اساس آن بتوان تشخیص را انجام داد و در نهایت یک طبقه بندی کننده برای تعیین نوع آریتمی قلبی می باشند. هر یک از این بخشها می تواند به روشهای مختلفی پیاده سازی شود که این نحوه پیاده سازی بر دقت و کارایی سیستم کلی موثر است. در این تحقیق تمرکز بر روی قسمتهای مربوط به انتخاب ویژگی و تعلیم طبقه بندی کننده است.

در مقالاتی که از سیگنال ECG جهت استخراج ویژگی

استفاده کرده اند، عموماً از ترکیبی هایی از ویژگی های زمانی و فرکانسی به همراه طبقه بندی کننده های عصبی یا فازی عصبی بهره برده شده است. نکته ممیزه دیگر این مقالات از یک دیگر در تعداد و نوع آریتمی های قلبی است که هر یک در نظر گرفته اند. بعنوان مثال از شبکه عصبی - فازی^۱ جهت کلاسه بندی سه آریتمی VT, VF, AF استفاده شده و دقت شبکه به ۹۷٪ رسیده است [۱]. از تبدیلات ویولت^۲ و شبکه عصبی^۳ RBF نیز جهت تشخیص ۳ آریتمی AF, VT, VF و گروه ضربانهای طبیعی NSR استفاده شده که برای هر کدام درصد کلاس بندی ۱۰۰، ۱۰۰، ۹۵/۲ و ۹۲/۵ حاصل شده است [۲]. همچنین از تبدیلات ویولت به همراه ترکیبی از طبقه بندی کننده های SVM^۴ و MLP^۵ فازی و روش های کاهش بعد^۶ PCA و LDA جهت طبقه بندی ۵ بیماری VT, SVT, PVC, APC, VF، و گروه ضربانهای طبیعی NSR استفاده شده و نتایج خوبی نیز حاصل شده است [۳]. در [۴] از مشخصه های زمانی، فرکانسی و ویولت به همراه شبکه MLP و روش کاهش بعد PCA جهت طبقه بندی ۹ نوع آریتمی مختلف استفاده شده است. این آریتمی ها شامل AAP, PFUS, FLWAV, PACED, APC, FUSION, PVC, RBBB, LBBB، و گروه ضربانهای طبیعی NSR بوده و درصد کلاس بندی برای هر کدام به ترتیب ۸۸، ۹۰، ۹۳، ۸۹، ۸۷، ۹۸، ۹۳، ۹۴ و ۹۵ درصد حاصل شده است. برخی مقالات نیز تنها یک آریتمی خاص را مورد بررسی قرار داده اند. [۵-۷] به جز روش های مبتنی بر استفاده از شبکه های عصبی و یا ترکیبی از آنها با شبکه های فازی؛ روش های دیگری هم جهت دسته بندی آریتمی ها مانند طبقه بندی قاعده-محور^۸ [۸] و یا طبقه بندی کننده های بیزین^۹ [۱۰] و [۹] نیز ارائه شده اند.

در تمام روش های ذکر شده از خود سیگنال ECG به عنوان سیگنال مورد استفاده جهت استخراج پارامترها و پردازش آنها استفاده شده است. در اکثر این روش ها همانطور که بیان شد از پارامترهای خطی حوزه ی زمان، فرکانس و یا ویولت استفاده شده است. نکته ای که در مورد

^۱ Neuro-Fuzzy

^۲ Wavelet transform

^۳ Radial basis function networks

^۴ Support vector machine

^۵ Multi layer Perceptron

^۶ Principal Components Analysis

^۷ Linear discriminant analysis

^۸ rule-based

^۹ Bayesian

است [۱۶] از تکنیک PCA برای کاهش بعد فضای ویژگی استفاده شده و طبقه‌بندی‌کننده شبکه عصبی با تعلیم بکمک بهینه‌سازی انبوه ذرات PSO بکار گرفته شده است. رنج دقت کلی الگوریتم برای تشخیص VEB و SVEB به ترتیب ۹۸.۳٪-۸۴.۶٪ و ۹۷.۴٪-۶۳.۵٪ گزارش شده است. در مطالعه‌ای دیگر [۱۷] از روشی دقیق برای تشخیص تطبیقی ضربان قلب برای هر بیمار بر اساس تکنیک ویولت استفاده شده است تا ضربان نرمال بیمار در شرایط مختلف به دقت آشکار شود و به کمک آن شرایط غیرنرمال تشخیص داده شود. دقت طبقه‌بندی آریتمی‌های قلبی در بانک داده MIT-BIH برابر ۹۷.۴۲٪ بوده است. همچنین در سال ۲۰۱۱ از انتخاب ویژگی برای تشخیص آریتمی به کمک طبقه‌بندی‌کننده‌ای ساده استفاده شده است. [۱۸] در این مقاله، بهترین مدل با استفاده از هشت ویژگی بدست آمده است و بر روی همان بانک داده به دقت کلی ۹۳٪ رسیده است.

نویسندگان حاضر با استفاده از طبقه‌بندی‌کننده شبکه عصبی و بکارگیری ویژگی‌های آشوبگون سیگنال ECG توانسته بودند بر روی همین بانک داده به دقتی در حدود ۹۵٪ برای طبقه‌بندی ۶ آریتمی (AF, PVC, VT, CHB, LBBB و VF) و یک گروه نرمال برسند. [۱۹] در این مقاله با توسعه کار گزارش شده در [۱۹] الگوریتمی جهت طبقه‌بندی آریتمی‌های قلبی پیشنهاد شده که قادر است ۷ نوع آریتمی مختلف (VT, VF, LBBB, CHB, AF, AFL, PVC) و حالت ریتم طبیعی NSR را با دقت کلی ۹۷.۴ درصد شناسایی و طبقه‌بندی کند. همچنین در این مقاله به مقایسه طبقه‌بندی‌کننده‌های دیگری (ماشین‌های بردار پشتیبان SVM و شبکه عصبی احتمالی PNN) با شبکه چندلایه پرسپترون MLP پرداخته شده است.

در روش پیشنهادی این مقاله از الگوریتم کاهش ویژگی آنالیز تمایزی تعمیم یافته (GDA)، شبکه‌های عصبی خودسازمانده (SOM^{۱۱}) و طبقه‌بندی‌کننده پرسپترون چندلایه (MLP) و یا ماشین‌های بردار پشتیبان استفاده شده است. در ابتدا سیگنال HRV از سیگنال‌های ECG بدست

سیگنال‌های ECG قابل ذکر است، آن است که این سیگنال‌ها به نویز حساس بوده و از طرفی پردازش آنها پروسه‌ای زمان بر خواهد بود. همچنین مراحل کار پیچیده و دشوار بوده و دقت این روش‌ها برای برخی بیماریها پایین است.

دسته‌ای دیگر از مقالات و کارهای انجام شده، فعالیت خود را بر روی سیگنال HRV^{۱۱} متمرکز کرده‌اند. در این مقاله از سیگنال فواصل زمانی R-R سیگنال ECG بعنوان معرف سیگنال HRV استفاده شده است. مزیت این روش‌ها در این است که سیگنال HRV به نویز حساسیت کمتری دارد و نیز از آنجایی که خصلت آشوبگونه^{۱۱} و غیرخطی بیشتری نسبت به سیگنال ECG از خود به نمایش می‌گذارد، لذا می‌توان از پارامترهای غیرخطی و آشوبی علاوه بر پارامترهای زمانی و فرکانسی استفاده نمود که باعث افزایش دقت طبقه‌بندی در اکثر بیماری‌ها می‌شود [۱۵-۱۱].

بعنوان مثال در [۱۱] از ۳ پارامتر غیرخطی و آشوبگونه‌ی بزرگترین نمای لیاپانوف^{۱۲}، آنتروپی مشخصه^{۱۳} و نگاشت پوانکاره^{۱۴} جهت طبقه‌بندی ۸ نوع بیماری مختلف استفاده شده است. از شبکه‌ی عصبی MLP نیز بعنوان طبقه‌بندی کننده استفاده شده و درصد کلاسه بندی به ۸۵٪ رسیده است.

همچنین در [۱۲] از ۴ پارامتر غیرخطی و آشوبگونه‌ی بزرگترین نمای لیاپانوف، آنتروپی مشخصه، نگاشت پوانکاره و تحلیل نوسانات بازگشتی^{۱۵} جهت طبقه‌بندی ۸ بیماری (CHB, VF, AF, PVC, LBBB, ISCH SSS) و گروه ضربانهای طبیعی NSR استفاده شده است. دقت شبکه‌های عصبی مورد استفاده برای هر کدام به ترتیب ۹۲/۸۵، ۹۶/۷۷، ۹۸/۲۳، ۹۰، ۸۹/۳۶، ۹۰، ۸۸/۹، ۸۸/۹ می‌باشد.

در روشی دیگر ترکیبی از پارامترهای خطی و غیرخطی جهت تحلیل فعالیت‌های قلبی مورد استفاده قرار گرفته است [۱۳]. البته در برخی موارد فقط از سیگنال‌های زمانی یا فرکانسی جهت تحلیل سیگنال HRV استفاده شده است [۱۴، ۱۵].

در مقاله‌ای که در سال ۲۰۰۹ در این زمینه ارائه شده

¹⁰ Heart Rate Variability¹⁴ Poincare plot¹¹ Chaotic¹⁵ Detrained fluctuation analysis¹² Largest Lyapunov exponent¹⁶ Self Organizing Map¹³ Spectral entropy

فعالیت قلب است. برای هر کلاس حدوداً ۵۰ نمونه ی دو دقیقه‌ای از سیگنال های MIT-BIH استخراج شده است. جهت اعتبار کار سعی شده تا نمونه‌های هر کلاس از چند شخص متفاوت گرفته شود. در مواردی که تعداد افراد کمی در بانک اطلاعات موجود بوده است، برای بدست آوردن تعداد نمونه‌های کافی از بخشهای مختلف یک سیگنال ECG استفاده شده است. در جدول یک مشخصات داده‌های بانک MIT-BIH استفاده شده در این تحقیق آمده است.

در این مقاله هفت نوع آریتمی مهم^{۱۸}، AF^{۱۹}، VF^{۲۰}، PVC^{۲۱}، LBBB^{۲۲}، CHB^{۲۳}، AFL^{۲۴} و VT^{۲۴} و حالت ریتم نرمال قلبی^{۲۵} NSR مورد بررسی قرار خواهند گرفت که در مجموع تشکیل هشت کلاس مختلف برای تشخیص توسط سیستم پیشنهادی را خواهد داد.

بلوک دیاگرام کلی روند طرح پیشنهادی در نمودار شکل ۱ نشان داده شده است. همانطور که مشاهده می‌کنید این الگوریتم از ۴ بخش پیش پردازش بر روی سیگنال، استخراج مشخصه‌ها (شامل مشخصه‌های زمانی، فرکانسی و آشوبناک) از سیگنال، کاهش تعداد مشخصه‌ها (با استفاده از تکنیک GDA) و داده‌ها (با استفاده از خودسازمانده SOM) و طبقه‌بندی بیماری‌ها با استفاده از شبکه‌های عصبی (MLP و PNN و SVM) تشکیل شده است. هر کدام از این بلوک‌ها شامل چندین بخش خواهند بود که به توضیح این بخش‌ها خواهیم پرداخت.

در این مقاله سعی شده بیشتر بر خواص غیرخطی سیگنالهای قلبی تمرکز شود. که از مهمترین این خواص، می توان خواص آشوبگونه و فراکتالی سیگنال های قلبی را نام برد. می دانیم که سیگنال های قلبی تماماً رفتارهای آشوبگونه از خود نشان می‌دهند. اما جالب آن است که بدانیم سیگنال HRV خواص آشوبی و غیرخطی بیشتری از خود به نمایش می‌گذارد. لذا جهت حصول طبقه‌بندی بهتر آریتمی ها، پردازش خود را معطوف به سیگنال HRV خواهیم کرد که خود از سیگنال ECG حاصل می‌شود. لذا مرحله‌ی اول کار بدست آوردن سیگنال HRV از سیگنال ECG خواهد بود.

می‌آید. از هر سیگنال HRV، 14 مشخصه ی زمانی، فرکانسی، غیرخطی و آشوبگونه استخراج می شوند. این مشخصه‌ها قبل از ورود به شبکه‌ی عصبی توسط الگوریتم GDA کاهش بعد یافته و سپس به طبقه‌بندی‌کننده اعمال می‌شوند. برای رسیدن به بهترین دقت و کارایی در طبقه‌بندی‌کننده، انتخاب صحیح الگوهای تعلیم اهمیت زیادی دارد. بدین منظور از یک نگاشت خودسازمانده SOM برای تعیین الگوهای تعلیمی که بیشترین اطلاعات را در مورد هر بیماری دارند استفاده شده است. در مرحله طبقه‌بندی نیز از چندین طبقه‌بندی‌کننده مختلف استفاده و نتایج مقایسه شده است.

ادامه مقاله به شرح ذیل است. در بخش دوم داده‌های مورد استفاده و پیش‌پردازش اولیه آن به همراه روش کلی ارائه شده آمده است. بخش سوم به انتخاب ویژگی و کاهش بعد فضای ویژگی اختصاص یافته است. سپس در بخش چهارم شیوه بکارگیری نگاشت خود سازمانده برای انتخاب بهترین الگوهای تعلیم آورده شده است. در بخش پنجم، انواع طبقه‌بندی‌کننده‌های مورد استفاده معرفی شده‌اند و در بخش ششم نتایج اعمال روش ارائه شده و بررسی و مقایسه نتایج آورده شده است. بخش پایانی مقاله نیز به جمع‌بندی اختصاص داده شده است.

۲- داده‌ها و روش

داده های ECG جهت آنالیز در این مقاله از پایگاه داده^{۱۷} MIT-BIH استخراج شده است [۳۸-۳۹]. این پایگاه داده بعنوان یک مرجع استاندارد و معتبر زمینه‌ای مناسب را جهت بررسی نحوه عملکرد قلب، تعیین آریتمی‌های قلبی و طبقه‌بندی آنها فراهم ساخته است.

MIT-BIH شامل ۴۸ سیگنال ECG از افراد مختلف در سنین متفاوت است. هر کدام از این سیگنال ها در ۳۰ دقیقه از شخص مورد نظر گرفته شده و بافرکانس 360Hz نمونه‌گیری شده‌اند.

همانطور که بیان شد هدف طبقه بندی ۷ نوع مختلف

¹⁷ Massachusetts Institute of Technology- Beth Israel Hospital: Arrhythmia laboratory

²⁰Pre- Ventricular Contraction

²⁴Ventricular Tachycardia

²¹Left Bundle Branch Block

²⁵ Normal sinus Rhythm

¹⁸ Atrial Fibrillation

²²Complete Heart Block

¹⁹Ventricular Fibrillation


²³Atrial flutter

جهت حذف نویز سیگنال ECG از فیلتر میان گذر با باند عبوری (۴-۲۰ Hz) استفاده شده است.

جهت شناسایی کمپلکس QRS و متعاقب آن موج R لازم است که نویزهای همراه با سیگنال اصلی حذف شوند.

جدول ۱: مشخصات داده‌های بانک MIT-BIH استفاده شده در این مقاله

Duration	Rate	Beats	ECG lead configuration	Record No	class
30:06	70-89	2239	MLII, V5	100	NSR
30:06	55-79	1860	MLII, V1	101	
30:06	62-92	2082	MLII, V2	103	
30:06	78-102	2526	MLII, V1	105	
30:06	74-91	2537	MLII, V1	112	
30:06	48-87	1789	MLII, V1	113	
30:06	55-83	1861	MLII, V1	121	
30:06	67-96	2476	MLII, V5	122	
30:06	41-65	1515	MLII, V5	123	
30:06	77-101	2492	MLII, V1	109	
30:06	64-82	2123	MLII, V1	111	LBBB
28:53	49-92	2003	MLII, V1	214	
2:24	143-358	472	MLII, V1	207	VF
1:02	174-177	164	MLII, V1	215	VT
1:04	110-117	220	MLII, V1	213	
1:05	126-150	256	MLII, V1	214	
26:13	70-78	1380	V5, V2	104	CHB
2:28	57:90	105	MLII, V1	207	
10:06	56-149	198	MLII, V1	201	AF
21:32	54-180	2529	MLII, V1	203	
21:30	63-158	2420	MLII, V1	210	
23:47	51-103	2082	MLII, V2	219	
29:17	47-110	2031	MLII, V1	221	
3:45	69-163	208	MLII, V1	222	
0:48	121-143	19	MLII, V1	202	AFL
7:03	133-148	412	MLII, V1	222	
5:48	50-88	362	MLII, V1	228	PVC
5:04	69-92	396	MLII, V1	221	



شکل ۱ بلوک دیاگرام روش پیشنهادی

موج R ابتدا یک نقطه در کمپلکس QRS تخمین زده می‌شود. سپس بوسیله‌ی بدست آوردن ماکزیمم قدر مطلق

مرحله‌ی بعدی، آشکارسازی کمپلکس QRS با استفاده از الگوریتم پن-تامپکینز^{۳۶} [۲۲،۲۱] است. جهت بدست آوردن

RMS : پارامتر زمانی دیگر مورد استفاده ریشه مربعات
تفاضل فواصل R-R متوالی است
PNN50 : به هم ریختن فاصله‌ی زمانی مابین ضربانات
قلب باعث بروز اکثر بیماری‌های قلبی می‌شود. PNN50
معیری از فواصل زمانی سیگنال HRV است. جهت بدست
آوردن آن می‌بایست ابتدا تفاضل تمام RR های متوالی را
محاسبه و سپس تعداد تفاضلاتی را که مقدار آنها کمتر از
50ms است (NN50) بر (N-1) تقسیم شود.

$$NN50 = \frac{MN50}{N-1} \times 100\% \quad (1)$$

FF: بی ثباتی (Mx) و پیچیدگی (FF) سری زمانی
پارامترهای آماری هستند که جهت تحلیل سیگنال HRV از
آنها استفاده می‌شود. در این تعاریف بیش‌های کوتاه مدت
HRV مورد تحلیل قرار می‌گیرند. بی‌ثباتی بصورت نسبت
مشتق اول واریانس سری زمانی به واریانس سری زمانی
محاسبه می‌شود.

$$M_x = \left[\frac{\delta x'^2}{\delta x} \right]^{1/2} = \frac{\delta x'}{\delta x} \quad (2)$$

پیچیدگی نیز بصورت (۳) تعریف می‌شود.

$$FF = \frac{M_x'}{M_x} = \frac{\delta x'' / \delta x'}{\delta x' / \delta x} \quad (3)$$

۳-۲- ویژگی‌های حوزه‌ی فرکانس سیگنال HRV:

اگر چه پارامترهای حوزه‌ی زمان، پارامترهای موثری در
تحلیل سیگنال‌های قلبی هستند اما توانایی جداسازی مابین
محتویات سمپاتیک و پاراسمپاتیک را به خوبی ندارند [۲۳].
همچنین پذیرفته شده است که چگالی طیف توان در فرکانس
های بالا (0.15-0.4Hz) آریتمی‌های مرتبط با دستگاه‌های
تنفسی را آشکار می‌کند. از طرف دیگر چگالی طیف توان در
فرکانس‌های پایین (0.04-0.15Hz) آریتمی‌های مرتبط با
دستگاه‌های سمپاتیک را آشکار می‌کند [۲۴، ۲۵]. در این

سیگنال در طی پنجره زمانی
(QRS - 280ms, QRS + 120) مقدار R از کمپلکس
QRS استخراج می‌شود. سیگنال HRV با استفاده از فواصل
زمانی مابین امواج R متوالی (فواصل R-R) بدست می‌آید.
شکل (۲) سیگنال شماره ۱۱۹ از پایگاه داده MIT-BIH
به همراه HRV استخراج شده از آن را نشان می‌دهد.

۳- استخراج و کاهش ویژگی سیگنال آشوبناک

HRV:

سیگنال HRV هم رفتارهای خطی را از خود به نمایش
می‌گذارد و هم رفتارهای غیرخطی را (مخصوصاً رفتارهای
آشوبناک را). در این مقاله از ۷ ویژگی خطی حوزه زمان
سیگنال HRV، 2 ویژگی خطی حوزه‌ی فرکانس و ۵ ویژگی
غیرخطی و آشوبی سیگنال HRV استفاده شده است. انتخاب
این ۱۴ ویژگی بر اساس سعی و خطا از میان تعداد بسیار
زیادی ویژگی‌های خطی زمانی و فرکانسی و ویولت بکار
رفته در سایر مقالات بوده است. طول سیگنال در مقالات
و تحقیقات گذشته جهت تحلیل آن بین ۱۶ ضربان تا ۳۲
ضربان متفاوت بوده است [۱۵، ۱۴، ۱۳، ۱۲]. در این کار از
طول سیگنال (N=۳۲) جهت تحلیل کلیه‌ی پارامترها استفاده
شده است [۴].

۳-۱- ویژگی‌های خطی زمانی HRV

هفت پارامتر حوزه‌ی زمان سیگنال HRV که در این کار
استفاده شده اند عبارتند از: [۱۴] و [۱۵]

Mean : عبارتست از میانگین فواصل R-R سیگنال
HRV. همانطور که بیان شد تعداد فواصل R-R (N=32)
خواهد بود.

SD: پارامتر دیگر مورد استفاده از حوزه‌ی زمان انحراف
معیار فواصل R-R خواهد بود.

Mean HR, SD HR: از میانگین و انحراف معیار
ضربانات قلب نیز می‌توان بعنوان پارامترهایی مناسب در
تحلیل سیگنال HRV استفاده نمود.

باشد، شیوه های قابل اعتمادی برای محاسبه نماها وجود دارد. اما اگر فقط سری زمانی در دسترس باشد، مسأله مورد نظر بسیار پیچیده تر می شود. برای فراهم کردن الگوریتم هایی در جهت محاسبه نماهای لیپانوف فقط با استفاده از آزمایشات، تلاش های بسیاری انجام و روش های گوناگونی نیز پیشنهاد شده است. البته اغلب این روش ها فقط برای محاسبه بزرگترین نمای لیپانوف، معتبر هستند [۳۰، ۲۹، ۲۸، ۲۵].

در این مقاله از الگوریتم محاسبه بزرگترین نمای لیپانوف که توسط روزنتین^{۳۰} ارائه شده استفاده می گردد [۳۱]. ابتدا ماتریس مربوط به بردارهای M -حافظه جهت تجدید ساختار فرآیند، تشکیل می شود [۲۷]. بردارهای M -حافظه در صفحه فاز مسیرهایی را دنبال می کنند که همگرایی یا واگرایی مسیرهایی نزدیک به هم جهت محاسبه بزرگترین نمای لیپانوف، تخمین زده می شود. اگر نمای لیپانوف از صفر بزرگتر باشد نشانگر دور شدن نقاط نزدیک به هم با گذشت زمان است که بیانگر آشوبی بودن سیستم است. برای یک فرایند تصادفی نمای لیپانوف به سمت بی نهایت میل می کند [۳۲]. همانند بعد همبستگی مقادیر $M=3$ و $r=0.04$ جهت محاسبه بزرگترین نمای لیپانوف استفاده شد. همچنین لازم به ذکر است که بزرگترین نمای لیپانوف برای تمام HRV های استخراج شده، مقداری مثبت به دست می آید که بیانگر خصلت آشوبی سیگنال های HRV است.

آنتروپی تقریب (APEn)^{۳۱}: آنتروپی تقریب معیاری از فشردگی یا بی نظمی سیگنال را در اختیار ما قرار می دهد. مقادیر بزرگ APEn بی نظمی بالای سیگنال و مقادیر کوچک تر آن بیان کننده نظم سیگنال است. آنتروپی تقریب به صورت احتمال لگاریتمی تعریف می شود که در آن الگوهای داده ای که نزدیک به هم قرار دارند، برای مقایسه ی بعدی با یک الگوی بزرگتر، باز هم نزدیک باقی می مانند. بنابراین APEn همانگونه که گفته شد یک اندازه گیری کمی از نظم را بیان می کند که نظم و قابلیت پیشگویی بیشتر،

مقاله نیز از LF (چگالی طیف توان در فرکانس های پایین) و HF (چگالی طیف توان در فرکانس های بالا) بعنوان مشخصه های حوزه ی فرکانس سیگنال HRV استفاده شده است.

۳-۳- ویژگی های آشوبگونه سیگنال HRV

همانطور که بیان شد بعلا فشرده گی و خواص آشوبگونه و غیرخطی سیگنال های HRV، استفاده ی تنها از معیارهای حوزه ی زمان و فرکانس در تحلیل این سیگنال ها کارایی چندانی نخواهند داشت. همچنین امکان جداسازی تعدادی از آریتمی ها فقط توسط پارامترهای غیرخطی و آشوبگونه امکان پذیر است. در این کار از ۵ معیار غیرخطی و آشوبی جهت تحلیل سیگنال HRV استفاده شده است که به توضیح آنها خواهیم پرداخت.

بعد همبستگی: تخمین بعد همبستگی در سیگنال های آشوبی، تخمینی از بعد فراکتالی ارائه می دهد و از این جهت معیاری برای میزان پیچیدگی مدل تخمینی احتمالی است. آنچه برای تخمین بعد همبستگی سیگنال های آشوبی در پی می آید، براساس روشی است که گراسبرگ^{۲۷} و پروکاسیا^{۲۸} ارائه داده اند. این روش به الگوریتم G-P مشهور است (این روش تاکنون موثق ترین روش پیشنهادی است) [۲۶].

در این روش ابتدا می بایست ماتریس M حافظه را ایجاد کرد. این ماتریس از کنار هم قرار دادن بردارهای M -حافظه به دست می آید [۲۷]. در روش تخمین بعد همبستگی، ارتباط و همبستگی بین نقاط M -حافظه اندازه گیری می شود. برای انجام دادن این کار بایستی انتگرال همبستگی را در فضای M -حافظه محاسبه کرد. انتگرال همبستگی $C_M(r)$ تخمینی از یک احتمال است که دوبردار از سری زمانی به طول M ، فاصله ای کمتر از r با همدیگر داشته باشند. در این مقاله با $M=3$ و $r=0.04$ تخمین های مناسبی از D_2 بدست آمده است.

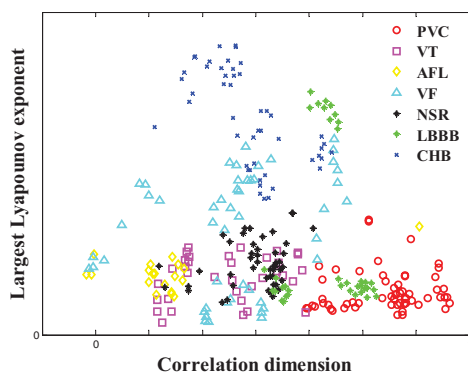
بزرگترین نمای لیپانوف^{۲۹}: اگر قوانین سیستم معلوم

²⁷ Grassberger
³⁰ Rosenstein

²⁸ Procaccia
³¹ Approximate entropy

²⁹ Largest Lyapunov exponent

این تأثیرات در رفتار الکتریکی قلب و سیگنال ECG و به تبع آن HRV به وضوح نمایان است. لذا همیشه در این سیگنال ها دچار تغییرات شدید هستیم. این تغییرات باعث می شود تا تشخیص بیماری ها و یا افراد سالم کمی دچار مشکل شود. همچنین باعث می شود تا تعدادی کلاس های مختلف در فضای مشخصه های ورودی با یکدیگر همپوشانی داشته باشند. بعنوان نمونه کلاس های VF و VT یا NSR و LBBB همپوشانی زیادی را در فضای مشخصه ایجاد کرده که باعث مشکل شدن تشخیص آنها از یکدیگر می شود. لذا در جست و جوی مکانیزی هستیم که بتواند تفاوت دسته های هر کلاس را تا حد امکان کوچک و تفاوت دسته های مابین کلاس ها را تا حد امکان از یکدیگر دور کند. الگوریتم آنالیز تمایزی تعمیم یافته (GDA) تا حد زیادی ما را به این مقصود می رساند [۲۰]. GDA در حقیقت یک الگوریتم کاهش بعد است که تعمیمی از آنالیز جداسازی خطی (LDA) به شمار می آید [۲۰]. در این روش داده های آموزشی توسط یک تابع کرنال به یک فضای مشخصه با ابعاد بالاتر تبدیل می شوند. در این فضای مشخصه با بعد بالاتر، کلاس های مختلف می توانند بصورت خطی از یکدیگر جدا شوند. یکی از وجوه برتری تکنیک GDA نسبت به سایر روشهای کاهش ویژگی در آن است که تعداد ویژگی های بهینه انتخابی همواره برابر یکی کمتر از تعداد کلاسهای خروجی است [۳۷].



شکل ۳: بزرگترین نمای لیاپانوف برحسب بعد همبستگی برای ۷ کلاس قبل از اعمال GDA

کم شدن APEn را به دنبال خواهد داشت و بالعکس [۳۳،۳۴]. برای آنتروپی تقریب مقدار پارامترهای M و r به ترتیب ۲ و $0.2SD$ قرار داده می شوند.

آنتروپی طیف^{۳۲}: آنتروپی طیف فشردگی فواصل R-R را در حوزه فرکانس مشخص می کند. آنتروپی طیف می تواند بعنوان معیاری برای میزان نامعینی در باره های رویدادها در فرکانس f تفسیر شود. الگوریتم بدست آوردن آنتروپی طیف مشابه آنتروپی تقریب است اما با کمی تفاوت [۳۴،۳۵]. مقادیر m و r جهت محاسبه ی آنتروپی طیف مشابه آنتروپی تقریب در نظر گرفته شده است.

نمودار پوانکاره SD1/SD2: نمودار پوانکاره یک تکنیک برگرفته از دینامیک غیرخطی است که به خوبی طبیعت نوسانات سری زمانی را توصیف می کند. در این نمودار هر درایه سری زمانی برحسب مقادیر قبلی خود رسم می شود. در مورد سری زمانی حاصل از سیگنال های قلبی نمودار پوانکاره نشان دهنده ی میزان نارسایی قلب در یک فرد است. این نمودار اطلاعات خلاصه شده ای را علاوه بر اطلاعات جزئی ضربان به ضربان درباره رفتار قلب فراهم می آورد.

نمودار پوانکاره به صورت کمی با محاسبه ی انحراف معیار فواصل نقاط با خطوط $y = x$ و $y = -x + 2 \times \bar{x}$ که \bar{x} میانگین سری زمانی است، آنالیز می شود. این انحراف معیارها به ترتیب SD_1, SD_2 نامگذاری شده اند. SD_1 به تغییرات سریع در داده ها مربوط می شود و SD_2 تغییرات طولانی مدت فواصل سری زمانی را توصیف می کنند. این تحلیل نیاز به هیچ پیش پردازش یا دادگان ایستا ندارد و از این رو برای تحلیل سیگنال های قلبی بسیار مطلوب است [۳۶].

۴-۳- کاهش ویژگی ها

انسان همواره با کنش های مختلفی از محیط بیرون مواجه است لذا دستگاه های داخلی بدن انسان نیز در قبال این تغییرات واکنش های مختلفی از خود به نمایش می گذارند.

³² Spectral entropy

شده است که در مجموع حدود ۴۰۰ الگو برای مرحله تست و ارزیابی سیستم کلی استفاده شده‌اند. از آنجا که برخی از بیماری‌های قلبی دارای علائم کاملاً مشابه هستند، ممکن است که در یک بیماری علائم دیگر نیز ظاهر شده باشد. این باعث می‌شود که داده‌های تعلیم گاهی متناقض باشند و عمل تعلیم طبقه‌بندی‌کننده را با دشواری همراه سازند. در این پژوهش سعی شده است تا با خوشه‌بندی^{۳۴} داده‌های تعلیم، برای هر کلاس از داده‌ها (یکی از هفت نوع بیماری یا ریتم سالم) الگوهایی انتخاب شوند که دارای بیشترین نمایندگی برای آن بیماری خاص بوده و در نتیجه همپوشانی کمتری با سایر بیماریها داشته باشند. بدین وسیله کارآیی طبقه‌بندی (برای کل داده‌ها) به نحوی موثر افزایش یافته است.

بدین منظور داده‌های تعلیم به یک شبکه عصبی نگاشت خود سازمانده SOM (یا شبکه کوهون^{۳۵}) ارائه شده‌اند. نگاشت خود سازمانده یک شبکه عصبی با تعلیم بدون سرپرستی است که داده‌های مشابه را در نرونهای نزدیک به هم دسته‌بندی می‌کند و بدین ترتیب از آن برای خوشه‌بندی داده‌ها استفاده می‌شود [۴۰]. از یک نگاشت خودسازمانده دو بعدی با ۱۰۰ نرون استفاده شده است و داده‌های مربوط به هشت کلاس مختلف به این نگاشت تعلیم داده شده‌اند. در نهایت نرونهایی که دارای بیشترین برد برای هر کلاس بوده‌اند به عنوان نمایندگان آن گروه انتخاب شده و داده‌هایی متناظر با این نرونها بعنوان داده‌های تعلیم برای مرحله بعدی لحاظ گردیده‌اند، چرا که این داده‌ها بیشترین تمایز را با سایر کلاس‌ها دارا هستند و به عبارتی بطور مشخص همان کلاس را معرفی می‌نمایند.

۵- طبقه‌بندی داده‌ها

برای طبقه‌بندی داده‌ها از شبکه‌های عصبی چند لایه MLP و شبکه‌های عصبی احتمالی PNN و ماشین‌های بردار پشتیبان SVM استفاده شده و نتایج در حالت‌های مختلف با یکدیگر مقایسه شده است.

شکل های ۳ و ۴ رسم مشخصه‌ی بزرگترین نمای لیاپانوف را برحسب بعد همبستگی برای ۷ کلاس مختلف قبل از اعمال GDA و بعد از آن به ترتیب نشان می‌دهد. هدف از این دو شکل نمایش بصری کارکرد الگوریتم GDA در افزایش تفکیک‌پذیری داده‌ها است و طبعاً از آنجا که تعداد ویژگی‌ها اصلی ۱۴ و تعداد ویژگی‌های انتخابی ۷ است امکان نمایش بصری روش بصورت کامل وجود ندارد. همچنین شکل ۵ تغییرات چهار ویژگی از بین ۷ ویژگی استخراج شده توسط GDA را بصورت BOXPLOT نمایش می‌دهد. تحلیل واریانس^{۳۳} این چهار ویژگی نشان‌دهنده افزایش قابل توجه نسبت بین واریانس دیده شده در هر کلاس نسبت به واریانس مورد انتظار است که با نسب F نشان داده می‌شود و برای این چهار ویژگی بترتیب برابر ۶۵۱ و ۲۱۱ و ۸۰۵۰ و ۷۲۰ محاسبه شده است. به جهت مقایسه، این نسبت برای چهار ویژگی غیرخطی D₂ و LLE و APEn و Spectral entropy بترتیب برابر ۱۲۹ و ۳۹ و ۷۷۹ و ۱۱۹ بوده است.

همانطور که مشاهده می‌شود در فضای ویژگی‌های اولیه بزرگترین نمای لیاپانوف و بعد همبستگی داده‌ها قابل تفکیک نیستند اما با اعمال الگوریتم GDA و رفتن به فضای ویژگی‌های جدید، الگوهای مرتبط با کلاس‌های متفاوت به طور مناسبی از یکدیگر جدا شده‌اند. همچنین فضای ویژگی‌ها به کمک روش GDA به طور قابل قبولی کاهش یافته (از ۱۴ ویژگی به ۷ ویژگی) و باعث افزایش درصد موفقیت در طبقه‌بندی آریمی‌ها خواهد شد.

همانطور که بیان شد در این مقاله تعداد مشخصه‌های ورودی (تعداد ویژگی‌های استخراج شده) برابر با ۱۴ و تعداد کلاس‌ها برابر با تعداد بیماری‌ها (۸) است. در پردازش شبکه‌ی عصبی MLP این ۱۴ مشخصه توسط GDA به ۷ مشخصه کاهش می‌یابد.

۴- انتخاب الگوهای تعلیم

از هر کلاس حدود ۵۰ نمونه سیگنال ECG استخراج

²⁷Grassberger

³¹ Approximate entropy

²⁸Procaccia

³³ANOVA: ANalysis Of VAriance

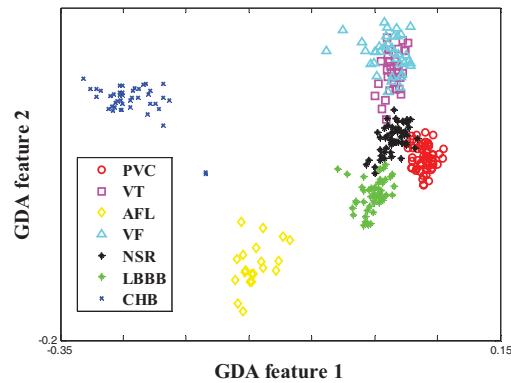
²⁹Largest Lyapunov exponent

³⁴ Clustering


³⁵Kohonen

³⁰Rosenstein


³⁶Spread



شکل ۴: دو ویژگی نگاشت یافته برای ۷ کلاس بعد از اعمال GDA



شکل ۵: نمودارهای boxplot برای چهار ویژگی اول از ۷ ویژگی بدست آمده توسط GDA



شکل ۶: استفاده از دو شبکه MLP جهت دسته بندی

برای طبقه‌بندی بکمک شبکه عصبی چندلایه از دو شبکه عصبی MLP بصورت سری استفاده می‌شود. به این صورت که ابتدا کلاس‌های VT, VF, LBBB, CHF, NSR را که مشخصه‌های شبیه‌تری به یکدیگر دارند، بعنوان یک کلاس در نظر گرفته شده و هر کدام از کلاس‌های AFL, PVC, AF نیز جداگانه بعنوان یک کلاس بررسی می‌شود. بنابراین شبکه MLP اولیه ۴ کلاس خواهد داشت. شمایی مربوط به کلاس‌ها در شکل ۶ دیده می‌شود.

همانطور که مشخص است شبکه MLP دوم شامل ۵ کلاس باقیمانده یعنی CHF, NSR, LBBB, VF, VT خواهد بود. هر دو شبکه دولایه و تعداد نرون‌های لایه‌های مخفی با سعی و خطا بدست می‌آید (نرون‌های لایه پنهان

جدول ۲ نتایج مربوط به استفاده از اعمال روش پیشنهادی در این مقاله را برای دسته‌بندی آریتمی‌های قلبی با استفاده از شبکه عصبی پرسپترون چندلایه بعنوان طبقه‌بندی‌کننده را نمایش می‌دهد. این جدول شامل سه ستون نتایج دقت طبقه‌بندی آریتمی‌های مختلف است. در اولین ستون سمت چپ، نتایج برای حالتی آورده شده است که داده‌های مربوط به ۱۴ ویژگی استخراجی از سیگنال HRV مستقیماً به شبکه عصبی MLP تعلیم داده شده‌اند. در این حالت حداکثر دقت بدست آمده برابر ۹۹٪ و حداقل آن برابر ۹۱٪ بوده است. ستون دوم این جدول تاثیر بکارگیری الگوریتم کاهش بعد فضای ویژگی GDA را در بهبود نتایج نشان می‌دهد. دیده می‌شود که در هر یک از کلاسهای هشتگانه بین یک تا دو درصد دقت بهبود یافته و به بین ۹۳٪ تا ۱۰۰٪ رسیده است. ستون سمت راست جدول نتیجه نهایی روش پیشنهادی یعنی استفاده از GDA برای کاهش بعد و SOM برای انتخاب الگوی تعلیم را نشان می‌دهد و می‌تواند دید که استفاده از این روش حداقل یک درصد دیگر هم به دقت افزوده و آن را به بین ۹۴.۸ تا ۱۰۰ درصد افزایش داده است. بدین ترتیب کارایی روش پیشنهادی بخوبی قابل مشاهده است.

جدول (۳) نتایج مربوط به طبقه‌بندی آریتمی‌ها بر اساس شبکه‌های MLP، SVM و PNN را نشان می‌دهد. همچنین تأثیر الگوریتم GDA و SOM مانند حالت قبل بررسی شده است.

جدول (۳) نتایج طبقه‌بندی آریتمی‌ها با استفاده از شبکه‌های MLP، SVM و PNN به همراه بررسی تأثیر الگوریتم GDA و

SOM بردقت طبقه‌بندی

Method	Test data accuracy (%)	Overall accuracy (%)
MLP	83.33	95
MLP+GDA	88.9	96.67
MLP+GDA+SOM	91.3	97.39
SVM	75.93	92.78
SVM+GDA	81.0	94.3
SVM+GDA+SOM	83.2	94.96
PNN	71.8	91.54
PNN+GDA	76.73	93.02
PNN+GDA+SOM	79.5	93.85

MLP اول به ترتیب ۵، ۷ و نرون‌های لایه پنهان MLP دوم ۸ (۷)، علاوه بر شبکه MLP از SVM و PNN نیز برای طبقه‌بندی داده‌ها استفاده شده است. برای SVM از هشت SVM مختلف (برای هر کلاس داده، یک SVM) استفاده شده است. مشخصات ماشین‌های بردار پشتیبان مانند نوع کرنل بکار رفته با سعی و خطا بهینه شده‌اند. توابع کرنل استفاده شده از بین توابع مختلف گوسی و چندجمله‌ای و RBF امتحان شده و بهترین پاسخها با تابع کرنل RBF بدست آمده است. تابع کرنل برای GDA نیز بصورت RBF در نظر گرفته شده است. همچنین برای شبکه عصبی احتمالی نیز مقدار شعاع^{۳۶} بهینه شده است. جهت آموزش شبکه‌ها از ۷۰٪ داده‌ها و برای مرحله‌ی تست از تمام داده‌ها استفاده شده است. آموزش شبکه‌های مختلف و طراحی آنان بر اساس رسیدن به سطح خطای طبقه‌بندی کمتر از یک درصد بوده است و در بیشتر موارد دقت تعلیم به ۱۰۰٪ رسیده است.

۶- نتایج

جدول (۲) نتایج طبقه‌بندی آریتمی‌ها با استفاده از MLP به همراه مشخصه‌های زمانی، فرکانسی و آشوبی

		Accuracy (%)					
		ORG+MLP		GDA+MLP		GDA+SOM+MLP	
		Test	Overall	Test	Overall	Test	Overall
Class	AF	86.2	95.86	92.77	97.83	94.57	98.37
	CHF	97.07	99.12	100	100	100	100
	LBBB	80.03	94.01	85.6	95.68	88.63	96.59
	NSR	82.6	94.78	90.7	97.02	92.07	97.62
	VF	73.13	91.94	79.67	93.9	82.7	94.81
	VT	73.13	91.94	79.67	93.9	82.7	94.81
	PVC	86.2	95.86	92.77	97.83	94.57	98.37
	AFL	88.27	96.48	90.87	97.26	95.2	98.56

²⁷ Grassberger

³¹ Approximate entropy

²⁸ Procaccia

³³ ANOVA: ANalysis Of VAriance

²⁹ Largest Lyapunov exponent

³⁴ Clustering

³⁵ Kohonen

³⁰ Rosenstein

³⁶ Spread

صرفاً تست بدست آورد. بعنوان مثال در مورد دقت کلی الگوریتم در جدول ۳ برای بهترین پیکربندی (MLP+GDA+SOM) که برابر ۹۷.۳۹٪ ذکر شده است مقدار دقت برای داده‌های تست به تنهایی ۹۱.۳۳٪ بوده است.

نکته دیگری که باید در انتهای این بخش به آن اشاره کرد در مورد بار محاسباتی سیستم پیشنهادی است. کارهای انجام شده در این مقاله را باید به دو بخش تفکیک کرد: اول کارهایی که بصورت *offline* و تنها یکبار برای تعیین الگوریتم بهینه، کاهش ویژگی‌ها، کاهش داده‌های تعلیم و آموزش شبکه انجام شده است. این موارد طبعاً تنها یک بار انجام می‌پذیرند و تاثیری در زمان اجرای واقعی الگوریتم و افزایش بار محاسباتی آن ندارد. دوم کارهایی که باید بصورت *online* یا *offline* (بسته به نوع استفاده از سیستم تشخیص بیماری) جهت تشخیص بیماری یک فرد انجام شود و شامل پیش‌پردازش سیگنال، استخراج ۱۴ ویژگی، ارائه ۱۴ ویژگی به تبدیل غیرخطی GDA و بدست آوردند.

۷ ویژگی و در نهایت ارائه این ۷ ویژگی به شبکه عصبی MLP است. در این مرحله عمده محاسبات مربوط به استخراج ویژگی است و در واقع روشهای ارائه شده و مقایسه شده در این مقاله تاثیری اندک بر زمان اجرای آن دارد. بعنوان مثال کاهش الگوهای غیر مفید در آموزش شبکه عصبی بکمک شبکه خودسازمانده SOM تنها در مرحله طراحی الگوریتم استفاده می‌شود و بار محاسباتی آن در پردازش سیستم تشخیص بیماری طراحی شده نقشی ندارد. با توجه به افزایش روزافزون قدرت پردازنده‌ها و سرعت زیاد پردازش در شبکه‌های عصبی، این امکان هست که بتوان روش ارائه شده در این مقاله را بصورت برخط نیز پیاده‌سازی کرد اما نویسندگان مقاله در این مورد بررسی ویژه‌ای انجام نداده‌اند.

همانطور که مشاهده می‌شود با توجه به آریتمی‌ها و پارامترهای انتخاب شده در این مقاله و روش‌های بکاربرده شده جهت کاهش پارامترها و انتخاب داده‌های مناسب، شبکه MLP از دقت بالاتری نسبت به دو روش دیگر طبقه‌بندی برخوردار بوده است.

یکی دیگر از ادعاهای این مقاله آن بوده است که با توجه به خصلت آشوبی سیگنال‌های قلبی، پارامترهای آشوبی و غیرخطی از اهمیت به‌سزایی در افزایش کارایی سیستم تشخیص آریتمی‌های قلبی برخوردار می‌شوند. در این قسمت جهت مشاهده این موضوع همان روش مرحله قبلی اما بدون استفاده از پارامترهای آشوبی و غیرخطی و فقط با استفاده از پارامترهای زمانی و فرکانسی انجام شده است. جدول (۴) این نتایج را نشان می‌دهد. همچنانکه دیده می‌شود حداکثر دقت بدست آمده توسط ویژگی‌های زمانی و فرکانسی (با همان الگوریتم) به حدود ۹۵٪ می‌رسد که نسبت به ۱۰۰٪ حاصل از تلفیق ویژگی‌های آشوبگون بسیار پایین‌تر است.

البته این نتایج به این معنی نیست که پارامترهای غیرخطی به تنهایی قادر خواهند بود طبقه‌بندی را به طور کامل و به خوبی انجام دهند و یا اینکه طبقه‌بندی بیماری‌ها بدون پارامترهای غیرخطی امکان‌پذیر نخواهد بود. بلکه بدین معنی است که با توجه به بیماری‌های انتخاب شده در این پژوهش حضور پارامترهای آشوبی و غیرخطی تأثیر چشمگیری بر عملکرد طبقه‌بندی داشته است. همینطور باید اذعان داشت که حضور پارامترهای خطی جهت طبقه‌بندی بعضی از بیماری‌ها از یکدیگر بسیار ضروری و لازم است.

در تفسیر مقادیر جداول ۲ تا ۴ باید دقت داشت که مقادیر برای دقت کلی داده‌های آموزش ذکر شده است. با توجه به آنکه دقت تعلیم برای داده‌های تست حدود ۱۰۰٪ بوده است به راحتی می‌توان مقادیر مربوط به دقت الگوریتم برای داده‌های تست را بر اساس نسبت ۳۰ درصدی داده‌های

شبکه عصبی MLP و PNN و ماشین بردار پشتیبان جهت طبقه‌بندی این آریتمی‌های استفاده شده است. مقایسه نتایج کارایی بالاتر MLP را نسبت به دو روش دیگر نشان می‌دهد. در این روش ۸ کلاس مختلف با دقت کلی ۹۷.۳ درصد شناسایی شده‌اند که در مقایسه با سایر روشها دقت بسیار خوبی را در تشخیص این تعداد آریتمی نشان می‌دهد. بررسی انجام شده بر روی نتایج حاکی از آن است که ویژگی‌های آشوبگونه تاثیر غیرقابل انکاری بر افزایش دقت کلی سیستم تشخیص برای این آریتمی‌ها دارد. همچنین نشان داده شد که الگوریتم کاهش بعد فضای ویژگی GDA و همچنین استفاده از نگاشت خودسازمانده SOM برای تعیین داده‌های تعلیم با بیشترین اطلاعات راجع به هر کلاس نیز می‌تواند کمک موثر در افزایش کارایی سیستم تشخیص داشته باشد.

با توجه به تعداد کلاس‌های زیاد و دقت قابل قبول نسبت به کارهای قبلی انجام شده در این زمینه، به نظر می‌رسد روش پیشنهادی می‌تواند روش مناسب و مؤثرتری جهت طبقه‌بندی این نوع آریتمی‌ها باشد.

یکی از مزیت‌های روش پیشنهادی استفاده از سیگنال HRV به جای استفاده از خود سیگنال ECG است. از آنجایی که سیگنال‌های ECG در شرایط مختلف از افراد ضبط می‌شوند، لذا نویز می‌تواند تاثیر زیادی بر پارامترهای استخراج شده از آنها داشته باشد که این مطلب در مورد سیگنال‌های HRV تأثیر چندانی ندارد.

همچنین زمان پردازش، در سیگنال‌های HRV نسبت به سیگنال‌های ECG کاهش می‌یابد. همینطور خواص آشوبگونه و غیرخطی بیشتر سیگنال HRV نسبت به ECG این امکان را به ما می‌دهد که از این پارامترهای مناسب جهت جداسازی آریتمی‌ها از یکدیگر به نحو مطلوب‌تری استفاده کنیم. البته لازم به ذکر است که با توجه به برتری‌های اشاره شده این سیگنال معایبی نیز دارد که از آن جمله می‌توان به ناتوانی این سیگنال‌ها در جداسازی بعضی آریتمی‌ها اشاره کرد که شناسایی این

جدول ۴) نتایج طبقه بندی آریتمی‌ها با استفاده از الگوریتم GDA و شبکه MLP صرفا با مشخصه های زمانی و فرکانسی

		ACCURACY (%)					
		ORG+MLP		GDA+MLP		GDA+SOM+MLP	
		Test	Overall	Test	Overall	Test	Overall
CLASS	AF	68.87	90.66	72.77	91.83	73.87	92.16
	CHF	73.73	92.12	80.0	94	82.93	94.88
	LBBB	63.67	89.1	72.27	91.68	74.1	92.23
	NSR	70.27	91.08	73.4	92.02	78.23	93.47
	VF	56.93	87.08	93.0	97.9	64.27	89.28
	VT	56.93	87.08	93.0	97.9	64.27	89.28
	PVC	68.87	90.66	72.77	91.83	73.87	92.16
	AFL	72.67	91.8	73.73	92.12	78.4	93.52

۷- جمع بندی

در این مقاله یک روش مؤثر طبقه بندی آریتمی‌های قلبی براساس سیگنال‌های HRV ارائه شده است. مرحله اول استخراج فواصل R-R سیگنال ECG جهت تشکیل سیگنال HRV است. بدین منظور پس از فیلتر کردن سیگنال ECG خام، کمپلکس QRS تخمین زده شده، موج R حاصل می‌شود. سری حاصل از ۳۲ فاصله ی R-R متوالی برای هر بیمار ذخیره می‌شود. از هر سیگنال HRV، ۷ مشخصه ی زمانی، ۲ مشخصه فرکانسی و ۵ مشخصه آشوبی و غیرخطی استخراج می‌گردد. این مشخصه‌ها جهت شناسایی ۷ کلاس آریتمی مختلف AF, CHB, LBBB, ALF, VF, VT, PVC و یک کلاس ریتم قلبی نرمال NSR بکار برده می‌شوند.

به منظور کاهش زمان آموزش و بهبود عملکرد طبقه‌بندی، ۱۴ ویژگی اولیه به ۷ ویژگی توسط الگوریتم GDA کاهش می‌یابند. همچنین از شبکه های عصبی خودسازمانده SOM جهت تعیین داده‌های مناسب تعلیم برای این ۸ دسته داده استفاده می‌شود.

- cardiac abnormalities using heart rate signals," *Med. Biol. Eng. Comp.*, Vol. 42, No. 3, pp 288-293, 2004.
- [12] Anuradha B. and Veera Reddy V.C., "ANN for classification of cardiac arrhythmias," *ARPN Journal of Engineering and Applied Sciences*, Vol. 3, No. 3, pp 1-6, 2008.
- [13] Acharyaa U.R., Bhat P.S., Iyengar S.S., Rao A., Dua S., "Classification of heart rate data using artificial neural network and fuzzy equivalence relation", *Elsevier Pattern Recognition Society*, Vol. 36, No. 1, pp 61-68, 2003.
- [14] Tsiouras M.G., Fotiadis D.I., "Automatic arrhythmia detection based on time and time-frequency analysis of heart rate variability," *Elsevier Computer Methods and Programs in Biomedicine*, Vol. 74, No. 2, pp 95-108, 2004.
- [15] Ghodrati A., Murray B., Marinello S., "RR Interval analysis for detection of atrial fibrillation in ECG monitors," 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS 2008., pp 601-604, Aug. 2008.
- [16] Ince, T.; Kiranyaz, S.; Gabbouj, M.; "A Generic and Robust System for Automated Patient-Specific Classification of ECG Signals," *IEEE Transactions on Biomedical Engineering*, Vol.56, No.5, pp.1415-1426, May 2009.
- [17] Faezipour, M.; Saeed, A.; Bulusu, S.C.; Nourani, M.; Minn, H.; Tamil, L.; "A Patient-Adaptive Profiling Scheme for ECG Beat Classification," *Information Technology in Biomedicine*, *IEEE Transactions on*, Vol.14, No.5, pp.1153-1165, Sept. 2010.
- [18] Llamedo, M.; Martínez, J.P.; "Heartbeat Classification Using Feature Selection Driven by Database Generalization Criteria," *IEEE Transactions on Biomedical Engineering*, Vol.58, No.3, pp 616-625, March 2011.
- [19] Rouhani, M.; Soleymani, R.; "Neural Networks Based Diagnosis of Heart Arrhythmias Using Chaotic and Nonlinear Features of HRV Signals," *Computer Science and Information Technology - Spring Conference, IACSITSC '09*, pp 545-549, 17-20 April, Singapore, 2009.
- [20] Baudat G., Anouar F., "Generalized discriminant analysis using a kernel approach," *Neural Comput.*, Vol. 12, No. 10, pp 2385-2404, 2002.
- [21] Hamilton P., Tompkins W., "Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database," *IEEE Transactions on Biomedical Engineering*, Vol. 33, No. 12, pp 1157-1165, 1986.
- [22] Pan J., Tompkins W.J., "A real time QRS detection algorithm," *IEEE Transactions on Biomedical Engineering*, Vol. 32, No. 3, pp 230-236, 1985.
- [23] Acharya R., Kannathal N., Krishnan S., "Comprehensive analysis of cardiac health using heart rate signals," *Physiol. Meas.*, Vol. 25, No. 5, pp 1139-1151, 2004.
- [24] Acharya R., Kumar A., Bhat P.S., Lim C.M., Iyengar S., Kannathal N., "Classification of cardiac abnormalities

آرتمی‌ها فقط از روی خود سیگنال‌های ECG امکان پذیر است.

مراجع

- [1] Wang Y., Zhu Y.S., Thakor N.V. and Xu Y.H., "A short-time multifractal approach for arrhythmia detection based on fuzzy neural network," *IEEE Transactions on Biomedical Engineering*, Vol. 48, No. 9, pp 989-995, Sep. 2001.
- [2] Al-Fahoum A.S., Howitt I., "Combined wavelet transformation and radial basis neural networks for classifying life-threatening cardiac arrhythmias," *Med. Biol. Eng. Computer*, Vol. 37, No. 5, pp 566-573, 1999.
- [3] Song M.H., Lee J., Cho S.P., Lee K.J. and Yoo S.K., "Support vector machine based arrhythmia classification using reduced features," *International Journal of Control, Automation and Systems*, Vol. 3, No. 4, pp 571-579, Dec. 2005.
- [4] Kadbi M.H., Hashemi J., Mohseni H.R. and Maghsoudi A., "Classification of ECG arrhythmias based on statistical and time-frequency features," *IEE Advances in Medical, Signal and Information Processing*, pp 1-4, July 2006.
- [5] Gharaviri A., Dehghan F., Teshnelab M., Moghaddam H.A., "Comparison of neural network, ANFIS, and SVM classifiers for PVC arrhythmia detection," *IEEE, Proceedings of the Seventh International Conference on Machine Learning and Cybernetics*, Vol. 2, pp 750-755, 2008.
- [6] Kara S., Okandan M., "Atrial fibrillation classification with artificial neural networks," *Elsevier Pattern Recognition Society*, Vol. 40, No. 11, pp 2967-2973, 2007.
- [7] Minami K.I., Nakajima H. and Toyoshima T., "Real-time discrimination of ventricular tachyarrhythmia with Fourier-transform neural network," *IEEE Transactions on Biomedical Engineering*, Vol. 46, No. 2, pp 179-185, 1999.
- [8] Khadra L., Al-Fahoum A.S., Al-Nashash H., "Detection of life-threatening cardiac arrhythmias using the wavelet transformation," *Med. Biol. Eng. Comp.*, Vol. 35, No. 6, pp 626-632, 1997.
- [9] Owis M.I., Abou-Zied A.H., Youssef A.M. and Kadah Y.M., "Study of features based on nonlinear dynamical modeling in ECG arrhythmia detection and classification," *IEEE Transactions on Biomedical Engineering*, Vol. 49, No. 7, pp 733-736, 2002.
- [10] Jovic A., Bogunovic N., "Analysis of ECG records using ECG chaos extractor platform and weka system," *IEEE Proceedings of conf. on information technology interfaces*, pp 347-352, June 2008.
- [11] Acharya R., Kumar A., Bhat P.S., Lim C.M., Iyengar S.S., Kannathal N., Krishnan S.M., "Classification of

- [40] Haykin S., *Neural Networks and learning machines*, Third ed., Pearson Prentice Hall, 2009.
- using heart rate signals,” *Medicine and Biology Engineering Comput.*, Vol. 42, No. 3, pp 288-293, 2004.
- [25] Kantz H., Schreiber T., *Nonlinear time series analysis*, Cambridge, UK: Cambridge University Press; 1997.
- [26] Grassberger P. and Procaccia I., “Characterization of strange attractors,” *Phys. Rev. Lett.*, Vol. 50, No. 5, pp 346-349, 1983.
- [27] Takens F., “Detecting Strange Attractors in Tubulence,” *Lecture Notes in Mathematics* 898, Springer-Verlag, Berlin, 1980.
- [28] Kurths J., Herzel H., “An Attractor in a solar time Series,” *Physical Department*, Vol. 25, No. 1-3, pp 165-172, 1987.
- [29] Osaka M., Saito H., Someya T., Hayakawa H., Cohen R.J., “Detection of nonlinearity in temporal patterns of ventricular premature beats,” *Computer in Cardiology*, pp 349-352, Sep. 1995.
- [30] Wolf A., Swift J.B., Swinney H.L., Vastano J.A., “Determining Lyapunov exponents from a time series,” *Physica*, Vol. 16, pp 285-317, 1985.
- [31] Rosenstein M., Collins J. and De Luca C., “A practical method for calculating largest Lyapunov exponents from small data sets,” *NeuroMuscular Research Center and Department of Biomedical Engineering*, Boston University, November 20, 1992.
- [32] Parker T.S. and Chua L.O., *Practical numerical algorithms for chaotic systems*, New York, NY, Springer-verlag, 1997.
- [33] Fusheng Y., Bo H. and Qingyu T., “Approximate entropy and its application in biosignal analysis,” *IEEE Nonlinear Biomedical Signal Processing: Dynamic Analysis and Modeling*, Vol. II, Chap. 3, pp 72-91, 2001.
- [34] Richman J.A. and Moorman J.R., “Physiological time-series analysis using approximate entropy and sample entropy,” *Amer. J Physiol.*, Vol. 278, pp 2039-2049, 2000.
- [35] Lake D.E., Richman J.S., Griffin M.P. and Moorman J.R., “Sample entropy analysis of neonatal heart rate variability,” *Amer. J Physiol.*, Vol. 283, pp 789-797, Sep. 2002.
- [36] Brennan M., Palaniswami M. and Kamen P., “Do existing measures of Poincaré plot geometry reflect nonlinear features of heart rate variability?,” *IEEE Transactions Biomedical Engineering*, Vol. 48, No. 11, pp 1342-1347, Nov. 2001.
- [37] Liu Y.H., Huang H.P., Weng C.H., “Recognition of electromyographic signals using cascaded kernel learning machine,” *IEEE/ASME Trans. Mechatron*, Vol. 12, No. 3, pp 253-264, 2007.
- [38] MIT-BIH Arrhythmia Database, <http://www.physionet.org/physiobank/database/mitdb/>
- [39] Goldberger A. L., Amaral L. A. N., Glass L., Hausdorff J. M., Ivanov P. C., Mark R. G., Mietus J. E., Moody G. B., Peng C.-K., and Stanley H. E., “PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals,” *Circulation* Vol. 101, No. 23, pp 215-220, 2000.