

طبقه‌بندی امواج قلبی به منظور تشخیص سگته‌ی قلبی مبتنی بر استخراج ویژگی‌های ریخت‌شناسی از الگوهای فضایی - زمانی امواج وکتور کاردیوگرام

نسترن جعفری هفشجانی^۱، علیرضا مهری دهنوی^۲، رضا حاجیان^۳، شب‌نم بوداغ^۴، محدثه بهجتی^۵

مقاله پژوهشی

چکیده

مقدمه: یکی از شایع‌ترین بیماری‌های قلبی- عروقی (CVDs یا Cardiovascular diseases) در سراسر جهان سگته‌ی قلبی (Myocardial infarction یا MI) است. با پردازش و واکاوی امواج الکتروکاردیوگرام (ECG یا Electrocardiography) و وکتور کاردیوگرام (VCG یا Vectorcardiography)، می‌توان به تشخیص و توصیف بیماری‌های قلبی نظیر MI دست‌یافت. یکی از روش‌های نوین در تشخیص، استفاده از متغیرهای فضایی- زمانی امواج وکتور کاردیوگرام است. هدف از انجام این مطالعه، تفکیک صحیح امواج سالم از بیمار به استفاده از طبقه‌بند شبکه‌ی عصبی مصنوعی و رسیدن به حساسیت و صحت قابل قبول و همچنین، نشان دادن مزایای وکتور کاردیوگرافی و به کارگیری آن به عنوان روشی جهت پوشش معایب الکتروکاردیوگرافی بود.

روش‌ها: در این تحقیق، علاوه بر به کارگیری امواج الکتروکاردیوگرام در حوزه‌ی زمان، از الگوهای فضایی- زمانی امواج وکتور کاردیوگرام به منظور شناسایی ۸۰ بیمار مبتلا به MI و تمایز آن‌ها از ۸۰ فرد سالم بهره بردیم.

یافته‌ها: زمانی که ترکیب ویژگی‌های ۱۲ لید ECG و ۳ لید VCG به ورودی طبقه‌بند شبکه‌ی عصبی پیش‌خور (Feedforward neural network) اعمال شد، صحت ۹۱/۲ درصد، حساسیت ۹۲/۶ درصد و ویژگی ۹۰/۰ درصد حاصل شد که نتایج، مقادیر بالاتری را نسبت به زمانی که ویژگی‌ها به صورت جداگانه اعمال شوند، نشان می‌دهد.

نتیجه‌گیری: مشاهدات بیانگر این است که روش‌های مبتنی بر ترکیب ECG و VCG، می‌توانند در تفکیک موارد MI از موارد سالم مؤثر باشند. امید است که این روش در ارزیابی بالینی و تشخیص نارسایی قلبی مفید واقع شود.

واژگان کلیدی: سگته‌ی قلبی، الکتروکاردیوگرافی، وکتور کاردیوگرافی، تبدیل ویولت، مدل‌های شبکه‌ی عصبی

ارجاع: جعفری هفشجانی نسترن، مهری دهنوی علیرضا، حاجیان رضا، بوداغ شب‌نم، بهجتی محدثه. طبقه‌بندی امواج قلبی به منظور تشخیص سگته‌ی قلبی مبتنی بر استخراج ویژگی‌های ریخت‌شناسی از الگوهای فضایی- زمانی امواج وکتور کاردیوگرام. مجله دانشکده پزشکی اصفهان ۱۳۹۸؛ ۳۷ (۵۴۸): ۱۱۹۲-۱۱۹۳

مقدمه

طبق گزارش سازمان جهانی بهداشت (World Health Organization یا WHO)، بیماری عروق کرونر قلبی (Coronary heart disease یا CHD)، عامل اصلی مرگ و میر افراد بالای ۳۵ سال است (۱). از این رو، به دلیل اهمیت موضوع، شیوع بیماری سگته‌ی قلبی (Myocardial infarction یا MI) و افزایش مرگ و میر، ابزارها و روش‌های مختلفی برای بررسی نحوه‌ی عملکرد قلب و بیماری‌های

مرتبط با آن در پزشکی نوین ابداع شده است که از جمله مهم‌ترین آن می‌توان به ثبت و واکاوی فعالیت‌های الکتریکی قلب با استفاده از تکنیک الکتروکاردیوگرافی (ECG یا Electrocardiography) اشاره کرد (۲). علاوه بر ابزار الکتروکاردیوگرافی، می‌توان از وکتور کاردیوگرافی (vectorcardiography یا VCG) به عنوان روشی تکمیلی در تشخیص بیماری‌های قلبی نظیر MI استفاده نمود (۳). تاکنون مطالعات متعددی مبتنی بر شناسایی نارسایی‌های قلبی از

۱- دانشجوی کارشناسی ارشد، گروه بیوالکتریک، دانشکده‌ی فن‌آوری‌های نوین علوم پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۲- استاد، گروه بیوالکتریک، دانشکده‌ی فن‌آوری‌های نوین علوم پزشکی و مرکز تحقیقات پردازش تصویر و سیگنال پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۳- گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

۴- استادیار، مرکز آموزشی- تحقیقاتی و درمانی قلب و عروق شهید رجایی، دانشگاه علوم پزشکی ایران، تهران، ایران

۵- متخصص قلب و عروق، فلوشیپ اکوکاردیوگرافی، مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی، دانشگاه علوم پزشکی ایران، تهران، ایران

Email: mehri@med.mui.ac.ir

نویسنده‌ی مسؤول: علیرضا مهری دهنوی

جعبه برای محاسبه‌ی آشفتگی مسیرهای RPS استفاده گردید که برای اندازه‌ی جعبه‌ی 10×10 و ترکیب چهار متغیر شمارش جعبه‌های Vx و Vz و روش خود شباهتی Vx و Vy نتایج بهتری با حساسیت ۹۲ درصد، ویژگی ۹۶ درصد و صحت ۹۴ درصد به دست آمد. همچنین، Liu و همکاران (۱۱)، ویژگی‌های نوینی از موج ECG ارائه دادند که در آن، یک سیگنال ECG را بر روی تابع چند جمله‌ای مرتبه‌ی ۱۲۰، به نام PolyECG-S، سازگار کردند. ویژگی PolyECG-S به طور تقریبی با منحنی ECG هماهنگ شد و سکته‌ی قلبی را با حساسیت ۹۴/۴ درصد تشخیص دادند.

در این مطالعه، بر روی ویژگی‌های ریخت‌شناسی و سعی بر تقلید تشخیصی و به کارگیری نظر پزشک تمرکز شده است. بنابراین، ویژگی‌های مرتبه‌ی بالا و غیر خطی استفاده نشده است. ثبت امواج ECG و VCG و به کارگیری ویژگی‌های بردارهای VCG برای بررسی فعالیت‌های فضایی-زمانی الکتریکی قلب علاوه بر ویژگی‌های زمانی (فواصل و دامنه‌ها) امواج ۱۲ لید ECG از جمله نوآوری‌های این مطالعه به شمار می‌آید.

روش‌ها

جمع‌آوری داده: در این مطالعه، امواج الکتروکاردیوگرام و کتورکاردیوگرام طی چهار ماه در بخش اورژانس و سایر بخش‌های مراقبت‌های قلبی مرکز آموزشی-تحقیقاتی و درمانی قلب و عروق شهید رجایی تهران از ۸۰ بیمار زن و مرد با میانگین سنی ۵۰ سال و تشخیص اولیه‌ی MI در ناحیه‌ی قدامی (Anterior) و تحتانی (Inferior) پس از تأیید از سوی متخصص قلب و عروق، توسط دستگاه الکتروکاردیوگرافی کاردیاکس ثبت شد. تشخیص اولیه در مورد وجود یا عدم وجود سکته، با استفاده از علائم بالینی بیمار، نشانگرهای قلبی و معاینه‌های قلبی-عروقی مانند الکتروکاردیوگرافی و اکوکاردیوگرافی انجام شد. به علاوه، ۸۰ داده از افراد سالم ثبت شد. هر ثبت شامل ۱۵ موج، ۱۲ لید مرسوم (I, II, III, aVR, aVL, aVF و $V1-V6$) به همراه سیستم ۳ لید (X, Y, Z) فرانک که سیگنال‌های VCG از آن‌ها استخراج می‌شود. هر ۱۵ لید امواج (سالم و بیمار) با نرخ نمونه‌برداری ۱۰۰۰ نمونه در ثانیه دیجیتال می‌شوند.

پیش پردازش: در این تحقیق، از ناچ فیلتر مرتبه‌ی دوم با پاسخ ضربه‌ی نامحدود (IIR notch filter) برای کاهش نویز برق شهر استفاده شد. همچنین، برای از بین بردن تغییرات زمینه (Baseline wander) از تابع پایه‌ی موجک دابشیز ۶ (۶ db) کمک گرفته شد (۱۲-۱۳). در مرحله‌ی بعدی، برای تقویت پیک‌های R از تبدیل موجک گسسته بیشترین هم‌پوشانی (Maximal overlap discrete wavelet transform) یا MODWT) بر روی امواج ECG اعمال شد. به این صورت که

جمله MI، بر اساس واکاوی امواج الکتروکاردیوگرام و کتورکاردیوگرام گزارش شده است. بر اساس مطالعات انجام گرفته بر روی الگوریتم‌های تشخیص MI، بیشتر آن‌ها بر روی چارچوب یادگیری ماشین متمرکز شده‌اند که شامل پیش پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی می‌باشند. واکاوی امواج قلبی، می‌تواند بر پایه‌ی ویژگی‌های مبتنی بر زمان باشد که به طور عمده، به صورت فاصله‌های زمانی بر حسب میلی‌ثانیه سنجیده می‌شوند (۴). روش‌های مبتنی بر فرکانس بیشتر توسط تبدیل فوریه محاسبه می‌شوند. با این که استفاده از این روش، باعث افزایش حساسیت می‌شود، اما وضوح زمانی در طی فرایند تبدیل از بین می‌رود و بنابراین، نمی‌توان تعیین کرد که در چه بخشی از زمان تغییرات اتفاق افتاده است (۵). روش‌های مبتنی بر زمان-فرکانس که محاسبات آن با استفاده از تبدیل ویولت صورت می‌گیرد، امکان نمایش امواج در مقیاس‌های مختلف و محلی‌سازی هماهنگ زمان و فرکانس را فراهم می‌کند (۶).

از جمله مطالعات در این زمینه، می‌توان به کار Correa و همکاران (۷) اشاره کرد که در آن استخراج چهار متغیر بردار قلبی ST-T از امواج VCG را پیشنهاد دادند. برای مقایسه، تغییرات اندازه‌ی بردار قرارداد ST (ST_{VM}) و گرادیان فضایی بطن (SVG) نیز محاسبه شدند. نتایج آزمون‌های آماری نشان داد زمانی که aST_{VM} و $ST-T_{VD}$ در طبقه‌بندی استفاده شوند، ایسکمی با حساسیت ۹۰/۵ درصد و ویژگی ۹۲/۶ درصد قابل تشخیص است. در مطالعه‌ی دیگری، Remya و همکاران (۸) با استفاده از یک روش آستانه‌گذاری تطبیقی ساده به منظور طبقه‌بندی سکته‌ی قلبی قدامی و تحتانی از تغییرات رخ داده در امواج ECG کمک گرفتند. عمق پیک Q و افزایش ارتفاع در قطعه‌ی ST از جمله متغیرهایی بودند که برای جداسازی موارد سالم از بیمار به طبقه‌بند شبکه‌ی عصبی مصنوعی (Artificial neural network یا ANN) اعمال کردند. با این روش، به حساسیت ۹۳/۶۱ درصد در موارد سکته‌ی قلبی تحتانی و حساسیت ۸۶/۱۵ درصد در موارد سکته‌ی قلبی فوقانی دست یافتند.

Diker و همکاران (۹)، با ترکیب ویژگی‌های ریخت‌شناسی و ویژگی‌های تبدیل ویولت گسسته، روشی برای شناسایی سکته‌ی قلبی با استفاده از طبقه‌بند ماشین بردار پشتیبان (Support vector machine یا SVM) و الگوریتم ژنتیک (Genetic algorithm یا GA) ارائه دادند که توانستند به نتایج با حساسیت ۸۷/۸۰ درصد و ویژگی ۸۵/۹۷ درصد دست یابند. در مقاله‌ی Costa و همکاران (۱۰)، ارتباط فضای قسمت بازسازی شده (Reconstructed phase space) و شبکه‌های عصبی مصنوعی برای تشخیص سکته‌ی قلبی از روی امواج کتورکاردیوگرافی ارائه شده است. در این مطالعه، از روش شمارش

VCG در موارد HC به یکدیگر نزدیک‌تر هستند؛ در حالی که در موارد MI از یکدیگر دور هستند.

انتخاب ویژگی: برای هر موج، ۴۸ ویژگی استخراج شد؛ چرا که با بالا رفتن فضای ویژگی، امکان افزایش خطای محاسباتی برای طبقه‌بندی وجود دارد. بنابراین، برای شناسایی ویژگی‌های کارآمد، یک آزمایش آماری مناسب نیاز است. شناسایی ویژگی‌هایی که دارای اطلاعات قابل توجه برای تشخیص MI هستند، دشوار است. بنابراین، برای حل این مسأله، از آزمون t برای رتبه‌بندی ویژگی‌ها استفاده شد (۱۶). با توجه به اهمیت ویژگی‌ها، ۲۷ ویژگی نظیر RRavg, RRstd, Rpos, Rang, Tang, Qamp, STelev, QTstd, QTavg, RRstd, Rpos, Tpos, Qpos, Oct0Ratio, Oct1Var, Oct2Avg, Oct3Avg, Oct3Max, Oct3Ratio, Oct4Avg, Oct4Max, Oct4Ratio, Oct4Var, Oct5Ratio, Oct5Var, Oct6Max, Oct7Avg و Oct7Max که دارای $P < 0.05$ بودند، انتخاب و به ورودی شبکه‌ی عصبی با اعتبارسنجی fold-۱۰ اعمال شد.

طبقه‌بندی: در این مطالعه، از شبکه‌ی عصبی پیش‌خور (Feed forward neural network) به منظور جداسازی داده‌های افراد سالم از افراد بیمار به کار گرفته شد. شبکه‌ی عصبی پیش‌خور، اولین و ساده‌ترین نوع شبکه‌ی عصبی مصنوعی است که اطلاعات تنها از یک مسیر با جهت رو به جلو حرکت می‌کند. در واقع، اطلاعات با شروع از گره (نورون)‌های ورودی و گذر از لایه‌های پنهان به سمت گره‌های خروجی می‌روند.

از نظر بهینه‌سازی، یادگیری شبکه‌ی عصبی معادل به حداقل رساندن تابع خطا است که یک تابع چند متغیره وابسته به وزن‌های شبکه است. بسیاری از الگوریتم‌های آموزش مبتنی بر الگوریتم نزول شیب (Gradient descent) هستند. از جمله‌ی آن‌ها، می‌توان به الگوریتم گرادیان مزدوج مدرج (Scaled conjugate gradient) یا (SCG) اشاره کرد که تقریب درجه‌ی دوم خطای E را در همسایگی نقطه w نشان می‌دهد:

ابتدا با استفاده از موجک پیش‌فرض 'Sym4'، شکل موج ECG به پنج سطح تجزیه شد. سپس با استفاده از ضرایب ۴ و ۵ موجک با محدوده‌ی فرکانسی (۵/۲۵، ۱۱/۲۵) و (۱۱/۲۵، ۵/۶۲۵) شکل موج ECG بازسازی شد (۱۴).

در این مطالعه، پیک R به کمک جعبه ابزار پردازش موج Matlab با الگوریتم Find peaks و روش «Min peak height» و «Min peak distance» تشخیص داده شد. همچنین، دیگر پیک‌های سیگنال الکتروکاردیوگرام شامل P، Q، S و T نیز با الگوریتم Find peaks و ایجاد محدوده‌ی زمانی قابل جداسازی هستند؛ به این صورت که پس از تشخیص موج R ۰/۵ تا ۰/۰۵ ثانیه قبل از موج R، موج P ۰/۰۵-۰/۲ ثانیه قبل از موج R، موج Q ۰/۰۵-۰/۲ ثانیه بعد از موج R، موج S ۰/۰۵-۰/۶۰ ثانیه بعد از موج R، موج T قرار می‌گیرد.

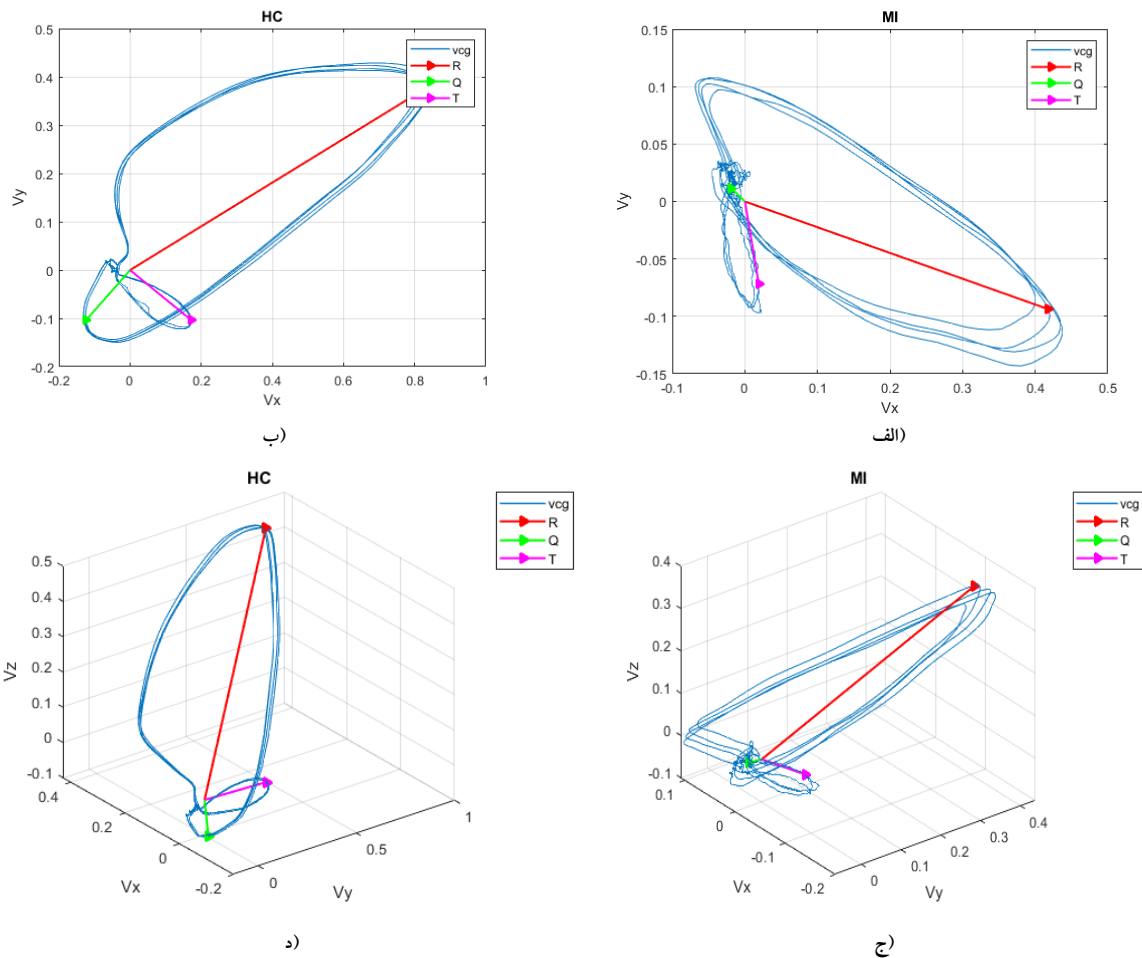
استخراج ویژگی: در این تحقیق، سه گروه ویژگی شامل ویژگی‌های ریخت‌شناسی الکتروکاردیوگرام، بردارهای وکتورکاردیوگرام و اکتانت‌های وکتورکاردیوگرام استخراج شد. در سیستم مختصات دکارتی، فضای سه بعدی به هشت اکتانت تقسیم می‌شود که می‌توان علاوه بر بررسی لیدهای ECG در بعد زمان از بردارهای سه بعدی VCG که در نواحی مختلف اکتانت‌ها قرار می‌گیرند، برای تجزیه و تحلیل فضایی- زمانی فعالیت الکتریکی قلب بهره برد (۱۵). در جدول ۱، ویژگی‌های استخراجی این سه گروه آمده است.

در شکل ۱، بردارهای Q، R و T از نقطه‌ی مرجع ایزوالکتریک در VCG تا انتهای لوپ‌های Q، R و T به صورت دو بعدی در راستای Vx ، Vy و به صورت سه بعدی در راستای Vx ، Vy و Vz کشیده شده‌اند. با استفاده از ویژگی‌های استخراجی این بردارها اطلاعات بیشتری در مورد MI می‌توان به دست آورد. همان‌طور که مشاهده می‌شود، توزیع فضایی امواج VCG برای موارد سالم تفاوت‌هایی با موارد MI نشان می‌دهد؛ به این صورت که حلقه‌های

جدول ۱. سه گروه ویژگی مورد مطالعه

گروه	ویژگی‌ها
ویژگی‌های ECG	میانگین فاصله‌ی RR (RR avg)، انحراف معیار فاصله‌ی RR (RR std)، میانگین فاصله‌ی QT (QT avg)، واریانس فاصله‌ی QT (QT std)، میزان صعود قطعه‌ی ST (ST elev)، مساحت سطح زیر قطعه‌ی ST (ST Itg)، ارتفاع موج Q (Q amp)
ویژگی‌های بردار VCG	اندازه‌ی بردارهای موج Q (Q mag)، موج R (R mag)، موج T (T mag)، زاویه‌ی بین بردار R و T (RTang)، زاویه‌ی بردار R (Rang) و زاویه‌ی بردار T (Tang)
ویژگی‌های اکتانت‌های VCG	موقعیت اکتانت بردار Q (Qpos)، بردار R (Rpos) و بردار T (Tpos)، درصد قرارگیری بردارها در هر اکتانت (OctNRatio) و بیشینه‌ی اندازه‌ی بردارها در هر اکتانت (OctNMax)، میانگین اندازه‌ی بردارها در هر اکتانت (OctNAvg) و واریانس اندازه‌ی بردارها در هر اکتانت (OctNVar)

ECG: Electrocardiography; VCG: Vectorcardiography



شکل ۱. نمایش لوپ‌ها و بردارهای پیشینه‌ی R, Q, T وکتور کاردیوگرام در صفحات ۲ بعدی V_x و V_y و صفحات ۳ بعدی V_x , V_y و V_z برای موارد (HC) و (MI) Myocardial infarction

عنوان ورودی به شبکه اعمال شد. سپس، در مرحله‌ی بعد، ترکیب تمام ویژگی‌ها بعد از انتخاب ویژگی به شبکه اعمال و نتایج بررسی شد. این شبکه، متشکل از یک لایه‌ی ورودی، یک لایه‌ی پنهان و یک لایه‌ی خروجی می‌باشد. تعداد نورون‌های موجود در لایه‌ی ورودی به اندازه‌ی بردار ویژگی ورودی بستگی دارد و تعداد نورون‌های لایه‌ی خروجی برابر با تعداد کلاس‌هایی است که بردار ویژگی‌ها طبقه‌بندی می‌شوند. از این رو، تعداد ۲ نورون برای لایه‌ی خروجی و با در نظر گرفتن ویژگی‌های سه گروه، تعداد ۷ نورون برای لایه‌ی پنهان انتخاب شد. عملکرد شبکه‌ی عصبی با روش K-fold cross-validation ارزیابی شد (۱۸). روش اعتبارسنجی متقاطع ۱۰ فولد شامل تقسیم‌بندی تصادفی داده‌ها به ۱۰ قسمت با اندازه‌های به طور تقریبی یکسان و استفاده از ۹ قسمت برای آموزش و بقیه برای آزمایش می‌باشد و زمانی که کل داده‌ها آموزش دیدند، داده‌های آزمون آزمایش می‌شوند. داده‌های آموزش خود به سه قسمت: ۷۰ درصد

$$E_{qw}(y) = E(w) + E'(w)^T y + \frac{1}{2} y^T E''(w) y \quad (1)$$

برای تعیین حداقل $E_{qw}(y)$ باید نقاط بحرانی برای $E_{qw}(y)$ یافت شود. نقاط بحرانی در سیستم خطی Muller (۱۷) به صورت زیر تعریف می‌شود:

$$E'_{qw}(y) = E''(w) y + E'(w) = 0 \quad (2)$$

در یادگیری SCG به دلیل استفاده از یک مکانیسم مقیاس‌گذاری مرحله‌ای، از جستجوی خطی وقت‌گیر در هر تکرار جلوگیری می‌شود. بنابراین، سرعت الگوریتم از سایر الگوریتم‌های مرتبه‌ی دوم بیشتر می‌شود و همچنین، نتایج بهتری نسبت به سایر روش‌های آموزش و شبکه‌های عصبی آزمایش شده، مانند شبکه‌ی عصبی پس انتشار و شبکه‌ی عصبی آبشاری دریافت می‌شود. در این مدل، ویژگی‌های سه گروه در سه مرحله‌ی جداگانه به

گردید، نتایج بالاتری با صحت ۹۱/۲ درصد، حساسیت ۹۲/۶ درصد و ویژگی ۹۰/۰ درصد به دست آمد که عملکرد بهتر سیستم در زمان استفاده از متغیرهای ECG و VCG به طور هم‌زمان را نشان می‌دهد. در شکل ۲- الف، ماتریس کانفیوژن شبکه‌ی عصبی برای ترکیب سه گروه ویژگی را نشان می‌دهد و شکل ۲- ب، مربوط به مساحت سطح زیر منحنی Receiver operating characteristic (ROC) برای ترکیب ویژگی‌های سه گروه است که میزان سطح زیر منحنی در این حالت بیشتر از زمانی است که ویژگی‌ها جداگانه به مدل اعمال شوند.

بحث

با توجه به این که در این تحقیق، با هدف دست‌یابی به روشی قابل اعتماد و توجیه‌پذیر از نظر بالینی انجام شد، رویکرد ارایه شده، به بررسی مجموعه‌ی جدیدی از ویژگی‌های ریخت‌شناسی در جهت بهبود نظارت بر ECG، پردازش و تفسیر توسط کاردیولوژیست پرداخته است. نتایج به دست آمده از این تحقیق، نشان می‌دهد که ویژگی‌های اکتانت VCG، عملکرد بهتری نسبت به ویژگی‌های ECG دارد و همچنین، اطلاعات پاتولوژیکی دیگری از دینامیک‌های فضایی VCG علاوه بر اطلاعات ECG می‌توان به دست آورد. به علاوه، استخراج ویژگی‌های اکتانت VCG با روش‌های خودکار رایانه‌ای، راحت‌تر از بررسی قوانین فاصله‌ای مو ۱۲ لید ECG و تشخیص MI از روی آن خواهد بود. همچنین، ترکیب ویژگی‌های ECG، VCG و اکتانت‌های VCG، می‌تواند روش مناسبی برای تفکیک انواع HC و MI باشد.

همان‌طور که نتایج نشان می‌دهد، با ترکیب ویژگی‌های ECG و VCG، نتایج بالاتری با صحت ۹۱/۲ درصد، حساسیت ۹۲/۶ درصد و ویژگی ۹۰/۰ درصد حاصل شد که در مقایسه با مطالعات Correa و همکاران (۴) و نیز Diker و همکاران (۹)، حساسیت بالاتری در تشخیص سکتته حاصل شد و با اختلاف بسیار کمی، مطالعات Costa و همکاران (۱۰) و Liu و همکاران توانستند موارد بیمار و سالم را با نتایج بهتری از هم تفکیک کنند.

برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد برای ارزیابی تقسیم می‌شود که در انتهای هر دوره (Epoch)، این ۱۵ درصد داده آزمایش می‌شوند. عملکرد کل اعتبارسنجی، برابر میانگین ۱۰ بار ارزیابی می‌باشد.

یافته‌ها

کارایی طبقه‌بند با استفاده از معیارهای آماری همچون صحت (Accuracy)، حساسیت (Sensitivity) و ویژگی (Specificity) برای سه گروه ویژگی ECG، VCG octant و مجموع سه گروه طبق فرمول‌های زیر به دست می‌آید و مقادیر آن در جدول ۲ آمده است. صحت، توانایی یک آزمون در افتراق صحیح موارد بیمار و سالم از سایر موارد معرفی می‌شود و برابر نسبت مجموع موارد مثبت حقیقی و منفی حقیقی به کل موارد آزمون شده است. حساسیت، توانایی یک آزمون برای پیدا کردن موارد بیماری معرفی می‌شود و برابر نسبت موارد مثبت حقیقی به مجموع موارد مثبت حقیقی و منفی کاذب است. ویژگی، توانایی یک آزمون برای پیدا کردن موارد سالم معرفی می‌شود و برابر نسبت موارد منفی حقیقی به مجموع موارد منفی حقیقی و مثبت کاذب است.

$$\text{Accuracy (Acc)} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (۳)$$

$$\text{Sensitivity (Sen)} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (۴)$$


$$\text{Specificity (Spe)} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (۵)$$

همان‌طور که در جدول ۲ آمده است، به کمک ویژگی‌های ECG، صحت ۷۹/۴ درصد، حساسیت ۷۶/۵ درصد و ویژگی ۸۱/۳ درصد، با ویژگی‌های VCG به صحت ۷۷/۹ درصد، حساسیت ۷۵/۰ درصد و ویژگی ۷۹/۷ درصد و با گروه ویژگی اکتانت‌های VCG صحت ۸۶/۸ درصد، حساسیت ۸۵/۳ درصد و ویژگی ۸۷/۹ درصد حاصل شد. همچنین، زمانی که از ترکیب ویژگی‌های ۱۲ لید ECG و ۳ لید VCG در ورودی طبقه‌بند ANN استفاده

جدول ۲. عملکرد طبقه‌بند Artificial neural network (ANN) با اعتبارسنجی 10-fold

گروه	صحت	حساسیت	ویژگی	سطح زیر نمودار ROC
ویژگی‌های ECG	۷۹/۴	۷۶/۵	۸۱/۳	۰/۸۱۸
ویژگی‌های بردار VCG	۷۷/۹	۷۵/۰	۷۹/۷	۰/۸۸۵
ویژگی‌های اکتانت‌های VCG	۸۶/۸	۸۵/۳	۸۷/۹	۰/۹۴۷
ترکیب ویژگی‌های ۳ گروه	۹۱/۲	۹۲/۶	۹۰/۰	۰/۹۶۹

ROC: Receiver operating characteristic; ECG: Electrocardiography; VCG: Vectorcardiography



Output Class \ Target Class	0	1	
0	63 46.3%	7 5.1%	90.0% 10.0%
1	5 3.7%	61 44.9%	92.4% 7.6%
	92.6% 7.4%	89.7% 10.3%	91.2% 8.8%

شکل ۲. الف) ماتریس کانفیوژن شبکه‌ی عصبی با اعتبارسنجی 10-fold در حالت ترکیب ویژگی‌ها، ب) منحنی Receiver operating characteristic (ROC) شبکه‌ی عصبی در حالت ترکیب ویژگی‌ها

تشکر و قدردانی

این مقاله، برگرفته از پایان‌نامه به شماره‌ی ۳۹۷۲۰۵ می‌باشد. نویسندگان این مقاله، بر خود لازم می‌دانند از معاونت پژوهشی دانشگاه علوم پزشکی اصفهان و مرکز آموزشی-تحقیقاتی و درمانی قلب و عروق شهید رجایی به جهت حمایت از اجرای این پایان‌نامه تشکر و قدردانی نمایند.

تنظیم بیشتر متغیرهای ورودی و ساخت طبقه‌بندی بهتر، استخراج ویژگی‌های جدید از لوب‌ها و اکتانت‌های VCG و ترکیب با ویژگی‌های زمان-فرکانس، تشخیص ناحیه‌ی آسیب دیده‌ی قلب، پردازش و مقایسه‌ی پایگاه‌های اطلاعاتی فیزیوننت با نتایج امواج ثبتی از مواردی است که می‌توان در مطالعات آینده به آن پرداخت.

References

- Benjamin EJ, Muntner P, Alonso A, Bittencourt MS, Callaway CW, Carson AP, et al. Heart disease and stroke statistics-2019 update: A report from the American Heart Association. *Circulation* 2019; 139(10): e56-e528.
- Zhang X, Cowan BR, Bluemke DA, Finn JP, Fonseca CG, Kadish AH, et al. Atlas-based quantification of cardiac remodeling due to myocardial infarction. *PLoS One* 2014; 9(10): e110243.
- Chee J, Acharya R, Er K, Tan W, Chua CK. Visualization of cardiac health using vector cardiogram. *IRBM* 2008; 29(4): 245-54.
- Correa R, Arini PD, Correa LS, Valentinuzzi M, Laciari E. Identification of patients with myocardial infarction. vectorcardiographic and electrocardiographic analysis. *Methods Inf Med* 2016; 55(3): 242-9.
- Tripathy RK, Zamora-Mendez A, de la O Serna JA, Paternina MRA, Arrieta JG, Naik GR. Detection of life threatening ventricular arrhythmia using digital taylor fourier transform. *Front Physiol* 2018; 9: 722.
- Thomas M, Kr Das M, Ari S. Automatic ECG arrhythmia classification using dual tree complex wavelet based features. *AEU-Int J Electron Commun* 2015; 69(4): 715-21.
- Correa R, Arini PD, Correa LS, Valentinuzzi M, Laciari E. Novel technique for ST-T interval characterization in patients with acute myocardial ischemia. *Comput Biol Med* 2014; 50: 49-55.
- Remya RS, Indiradevi KP, Babu KKA. Classification of myocardial infarction using multi resolution wavelet analysis of ECG. *Procedia Technology* 2016; 24: 949-56.
- Diker A, Comert Z, Avci E, Velappan S. Intelligent system based on Genetic Algorithm and support vector machine for detection of myocardial infarction from ECG signals. *Proceedings of the 26th Signal Processing and Communications Applications Conference (SIU)*; 2018 May 2-5; Izmir, Turkey.
- Costa CM, Silva IS, de Sousa RD, Hortegal RA, Regis CDM. The association between reconstructed phase space and Artificial Neural Networks for vectorcardiographic recognition of myocardial infarction. *J Electrocardiol* 2018; 51(3): 443-9.
- Liu B, Liu J, Wang G, Huang K, Li F, Zheng Y, et al. A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection. *Comput Biol Med* 2015; 61: 178-84.
- Wang D, Si Y, Yang W, Zhang G, Li J. A novel electrocardiogram biometric identification method based on temporal-frequency autoencoding. *Electronics* 2019; 8(6): 667.

13. Jeedella J, Ahamad HA, Al-Mualla M, Noras JM. Design and analysis of second order IIR notch filters with double frequency initialization. Proceedings of 2006 IEEE GCC Conference (GCC); 2006 Mar 20-22; Manama, Bahrain.
14. Sundarasekar R, Thanjaivadivel M, Manogaran G, Kumar PM, Varatharajan R, Chilamkurti N, et al. Internet of things with maximal overlap discrete wavelet transform for remote health monitoring of abnormal ECG signals. *J Med Syst* 2018; 42(11): 228.
15. Yang H, Bukkapatnam ST, Le T, Komanduri R. Identification of myocardial infarction (MI) using spatio-temporal heart dynamics. *Med Eng Phys* 2012; 34(4): 485-97.
16. Kim TK. T test as a parametric statistic. *Korean J Anesthesiol* 2015; 68(6): 540-6.
17. Moller MF. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Netw* 1993; 6(4): 525-33.
18. Acharya UR, Fujita H, Oh SL, Hagiwara Y, Tan JH, Adam M. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Inf Sci* 2017; 415-416: 190-8.

Classification of Cardiac Signals in Order to Diagnose Myocardial Infarction based on Extraction of Morphological Features from Spatio-Temporal Patterns of Vectorcardiogram Signals

Nastaran Jafari-Hafshejani¹, Alireza Mehri-Dehnavi², Reza Hajian³,
Shabnam Boudagh⁴, Mohaddeseh Behjati⁵

Original Article

Abstract

Background: One of the most common cardiovascular diseases (CVDs) in the world is myocardial infarction (MI). By analyzing electrocardiogram and vectorcardiography (VCG) signals, it is possible to identify and characterize heart diseases such as MI. One of the new methods of detection is the use of spatio-temporal parameters of VCG signals. This study aimed to correctly distinguish healthy signals from patients, achieve acceptable accuracy, and show the benefits of VCG and its application as a method to cover the shortcoming of electrocardiography.

Methods: In this study, in addition to applying electrocardiogram signals in the time domain, spatio-temporal patterns of VCG signals were used to identify 80 patients with MI, and differentiate them from 80 healthy individuals.

Findings: When combining the 12-lead electrocardiography (ECG) and the 3-lead VCG features applied to the Feedforward Neural Network classifier input, an accuracy of 91.2%, specificity of 92.6%, and specificity of 90% were obtained. The results were in higher values than when applied separately.

Conclusion: The observations indicate that combined ECG and VCG methods can be effective in distinguishing MI cases from healthy cases. It is hoped that this method may be useful in the clinical evaluation and heart failure diagnosis.

Keywords: Myocardial infarction, Electrocardiography, Vectorcardiography, Wavelet transform, Neural network models

Citation: Jafari-Hafshejani N, Mehri-Dehnavi A, Hajian R, Boudagh S, Behjati M. **Classification of Cardiac Signals in Order to Diagnose Myocardial Infarction based on Extraction of Morphological Features from Spatio-Temporal Patterns of Vectorcardiogram Signals.** J Isfahan Med Sch 2019; 37(548): 1192-9.

1- MSc Student, Department of Biomedical Engineering, School of Advanced Medical Technology, Isfahan University of Medical Sciences, Isfahan, Iran

2- Professor, Department of Biomedical Engineering, School of Advanced Medical Technology AND Medical Image and Signal Processing Research Center, Isfahan University of Medical Sciences, Isfahan, Iran

3- Department of Biomedical Engineering, Amirkabir University of Technology, Tehran, Iran

4- Assistant Professor, Rajaie Cardiovascular Medical and Research Center, Iran University of Medical Sciences, Tehran, Iran

5- Cardiologist, Echocardiography Fellowship, Rajaie Cardiovascular Medical and Research Center, Iran University of Medical Sciences, Tehran, Iran

Corresponding Author: Alireza Mehri-Dehnavi, Email: mehri@med.mui.ac.ir