

طراحی یک سیستم هوشمند مبتنی بر شبکه‌های عصبی و ویولت برای تشخیص آریتمی‌های قلبی

فرشته پورآهنگریان^۱ آزاده کیانی^۲ علی کرمی^۳ بهمن زنج^۴

۱- دانشجوی دکتری الکترونیک - آموزشکده فنی و حرفه‌ای سما- دانشگاه آزاد اسلامی واحد تنکابن - تنکابن- ایران
f.ahangaryan@gmail.com

۲- دانشجوی دکتری الکترونیک - دانشگاه آزاد اسلامی واحد رشت - رشت- ایران
azadeh.kiyani@gmail.com

۳- استادیار - دانشکده فنی و مهندسی- دانشگاه گیلان - رشت- ایران
karami_al@yahoo.com

۴- مریم - دانشکده فنی و مهندسی- دانشگاه گیلان - رشت- ایران
bahmanzanj@yahoo.com

چکیده: در این مقاله، یک روش جدید برای طبقه‌بندی آریتمی‌های قلبی بر مبنای تبدیل ویولت و شبکه‌های عصبی ارائه شده است. از تبدیل ویولت گسسته (DWT) جهت پردازش رکوردهای ECG و استخراج ویژگی‌های زمان - فرکانس استفاده می‌شود. نتیجه‌ی بدست آمده به عنوان بردار ورودی برای آموزش و تست یک شبکه‌ی عصبی مورد استفاده قرار می‌گیرد. هر چند که در سال‌های اخیر، الگوریتم‌های متنوعی برای تشخیص آریتمی‌های قلبی پیشنهاد شده‌اند، اما اکثر محققین از تعداد محدودی داده در کار خود استفاده نموده‌اند در حالیکه در این تحقیق از ۲۰ رکورد موجود در پایگاه داده استاندارد MIT-BIH در قالب ۴۲۰ نمونه سیگنال استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد که سیستم طراحی شده با استفاده از یک شبکه‌ی عصبی پرسپترون چند لایه (MLP) به عنوان طبقه‌بندی کننده از دقت بالایی برخوردار می‌باشد و می‌تواند ۴ کلاس آریتمی را با دقت بیش از ۹۷٪ طبقه‌بندی کند.

کلمات کلیدی: ECG، آریتمی‌های قلبی، شبکه‌های عصبی، ویولت.

تاریخ ارسال مقاله : ۱۳۸۸/۱۱/۴

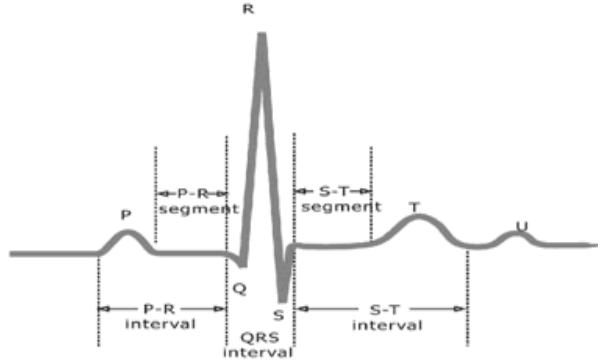
تاریخ پذیرش مقاله : ۱۳۹۰/۷/۱۸

نام نویسنده‌ی مسئول : فرشته پورآهنگریان

نشانی نویسنده‌ی مسئول : ایران - تنکابن- دانشگاه آزاد اسلامی - آموزشکده فنی و حرفه‌ای سما

۱- مقدمه

سیگنال ECG نشان دهنده فعالیت الکتریکی قلب می‌باشد. اجزای مهم این سیگنال عبارتند از: موج P، کمپلکس QRS، موج T و موج U. شکل ۱ بخش‌های مختلف این سیگنال را نشان می‌دهد. هرگونه تغییر در سیگنال ECG می‌تواند نشان دهنده یک بیماری قلبی باشد که به این تغییرات آریتمی گفته می‌شود. تشخیص آریتمی‌های قلبی به دلیل تشخیص به هنگام شرایط قلب از اهمیت زیادی برخوردار می‌باشد. تشخیص آریتمی‌های قلبی توسط فرد ماهر زمان قبل توجهی می‌طلبد و همواره مستعد خطا می‌باشد. لذا ایده اتوماتیک کردن تشخیص آریتمی‌های قلبی شکل گرفت.



شکل (۱): یک پریود از سیگنال ECG نرمال

روش‌های مختلفی جهت تشخیص و طبقه‌بندی آریتمی‌های قلبی پیشنهاد شده‌اند که تفاوت این روش‌ها در چگونگی استخراج ویژگی و نوع سیستم طبقه‌بندی کننده می‌باشد. ویژگی‌هایی که در تحقیقات مورد استفاده قرار گرفته اند عبارتند از: ویژگی‌های مورفولوژیکی سیگنال ECG [۱-۳]، ویژگی‌های مربوط به فواصل زمانی [۱-۴]، چند جمله‌ای‌های هرمیتی [۵]، تعدادی از طبقه‌بندی کننده‌های بکار رفته در تحقیقات قبلی عبارتند از: تفکیک کننده‌های خطی [۳]، شبکه‌های عصبی [۱-۶، ۳-۸].

تبديل‌های مختلفی برای استخراج ویژگی از سیگنال ECG مورد استفاده قرار می‌گیرد. گروهی از محققین از تبدیل فوریه برای این کار استفاده نموده‌اند [۶]. نتایج گذشته نشان می‌دهد که ویژگی‌های زمان - فرکانس، کارایی بالاتری در طبقه‌بندی ضربان‌های قلب دارند. اما تبدیل فوریه تبدیل مناسبی برای آنالیز سیگنال‌های غیر ایستا مانند ECG نیست.

امروزه تبدیل ویولت به عنوان ابزار قدرتمندی در استخراج ویژگی از سیگنال ECG مورد استفاده قرار می‌گیرد [۷، ۸، ۱۰-۱۲]. مشکل مقایلات فوق، عدم استخراج ویژگی‌های مناسب از ECG (تعداد و نوع آن‌ها) می‌باشد که منجر به کاهش کارایی سیستم پیشنهادی این تحقیقات می‌شود.

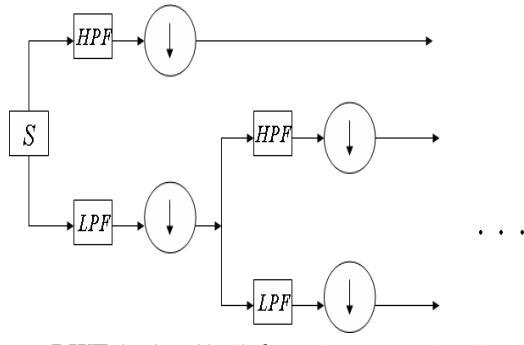
۲- تبدیل ویولت

تبدیل ویولت یک تبدیل زمان - مقیاس است که اطلاعات هر دو حوزه‌ی زمان و فرکانس را حفظ می‌کند و این موضوع در مورد سیگنال‌های غیر ایستا از اهمیت زیادی برخوردار می‌باشد. آنالیز ویولت به ما این امکان را می‌دهد که در جاهایی که اطلاعات دقیق‌تری از فرکانس‌های پایین مورد نیاز است، از باره‌های زمانی طولانی تر استفاده کنیم و در جایی که اطلاعات فرکانس‌های بالا را می‌خواهیم، از باره‌های کوچک‌تر استفاده کنیم. تبدیل ویولت سیگنال $x(t)$ به صورت زیر تعریف می‌شود:

$$a > 0 \quad w_a x(b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

در فرمول فوق، a فاکتور تغییر مقیاس، b میزان جابجایی و $\Psi(t)$ ویولت مادر است. تبدیل ویولت به دو نوع پیوسته (CWT) و گسسته (DWT) تقسیم می‌شود. در این تحقیق از تبدیل ویولت گسسته جهت حذف نویز و استخراج ویژگی استفاده شده است.

اساس کار تبدیل ویولت گسسته با توجه به الگوریتم ملاط [۱۳]، عبور سیگنال از فیلترهای بالا گذر و پایین گذر می‌باشد. هر طبقه شامل دو فیلتر دیجیتال و یک downsampler بعد از هر فیلتر می‌باشد. خروجی‌های فیلتر بالا گذر ضرایب جزیی و خروجی‌های فیلتر پایین گذر ضرایب تقریب نامیده می‌شوند. از آنجا که در بسیاری از سیگنال‌ها محتویات فرکانس پایین مهم‌ترین بخش است، تجزیه‌ی سیگنال با تجزیه‌ی ضرایب تقریب ادامه می‌یابد. تعداد سطوح تجزیه در آنالیز ویولت از اهمیت زیادی برخوردار می‌باشد که معمولاً با توجه به ماهیت سیگنال انتخاب نوع ویولت مادر نیز به نوع کاربرد بستگی دارد [۱۴]. شکل ۲ تجزیه‌ی یک سیگنال با استفاده از DWT نشان می‌دهد.



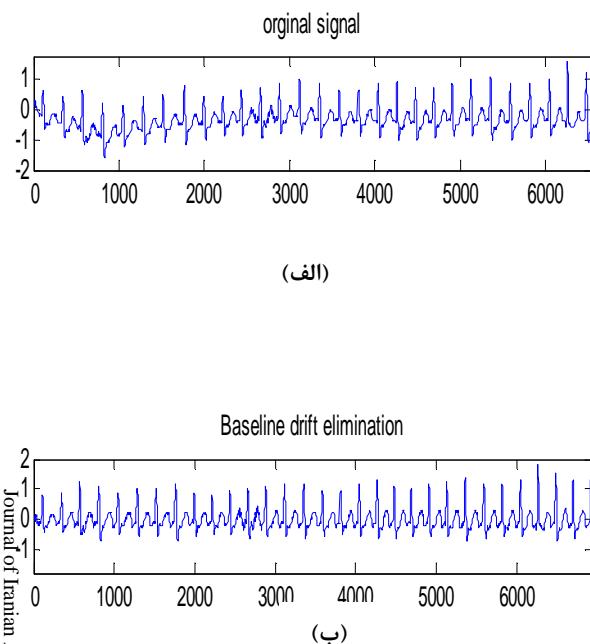
شکل (۲): تجزیه‌ی یک سیگنال با استفاده از DWT

۳- سیستم پیشنهادی

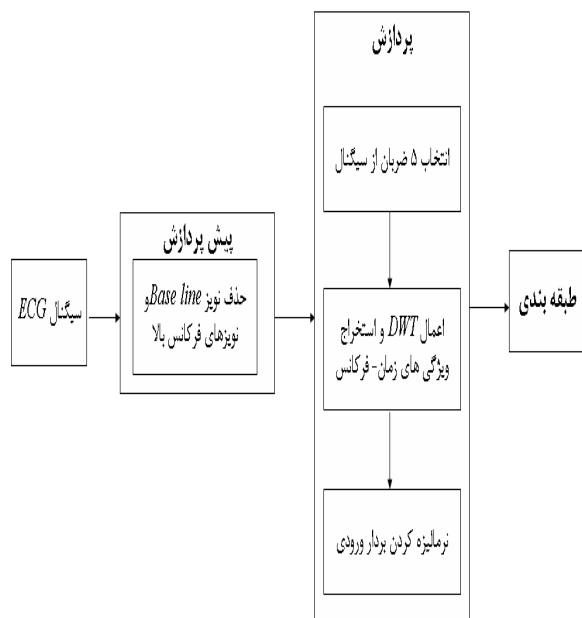
شکل ۳، دیاگرام بلوکی روش پیشنهاد شده را نشان می‌دهد. همانطور که در شکل نشان داده شده است، این روش شامل سه مرحله می‌باشد که عبارتند از: پیش‌پردازش، استخراج ویژگی و طبقه‌بندی.



پیش پردازش و حذف نویز سیگنال ECG موجب افزایش کارایی سیستم خواهد شد. زیرا این عمل موجب استخراج ویژگی های دقیق-تری از سیگنال می شود. یکی از مهمترین نویزها، نویز Base Line است که یک مقدار dc به سیگنال اضافه می کند. برای حذف این نویز از یک فیلتر دیجیتال ساده موسوم به Average Moving استفاده شده است. این فیلتر، داده ها را با استفاده از جایگزینی هر نمونه با میانگین نمونه ها در یک همسایگی، هموار می سازد. این فرآیند معادل یک فیلتر پایین گذر می باشد. شکل ۴، یک نمونه از سیگنال ECG اخذ شده از پایگاه داده را در حضور این نویز و پس از حذف آن نشان می دهد.



شکل (۴): (الف) سیگنال ECG اخذ شده از پایگاه داده
(ب) حذف نویز Base line از سیگنال شکل الف



شکل (۳): دیاگرام بلوکی روش پیشنهاد شده

در این سیستم، یک سیگنال ECG دیجیتال به عنوان ورودی طبقه‌ی پیش پردازشگر اعمال می شود. هدف از این مرحله، حذف نویز از ECG می باشد. در مرحله‌ی بعدی، تبدیل ویولت به سیگنال حاصل از مرحله‌ی قبل اعمال گردیده و ویژگی‌های مطلوب استخراج می شود. در آخرين مرحله، طبقه‌بندی کننده‌ی مورد نظر به طبقه‌بندی آریتمی‌های قلبی می پردازد. جزئیات مربوط به هر مرحله در بخش‌های بعدی توضیح داده شده است.

۱-۳- حذف نویز از سیگنال ECG

در این تحقیق، ۲۰ رکورد از رکوردهای موجود در پایگاه داده MIT-BIH Arrhythmias Data Base [۱۵] مورد استفاده قرار گرفت. جدول زیر رکوردهای به کار رفته و کلاس طبقه‌بندی مربوط به آن‌ها را نشان می دهد.

جدول (۱): رکوردهای به کار رفته و کلاس طبقه‌بندی مربوط به

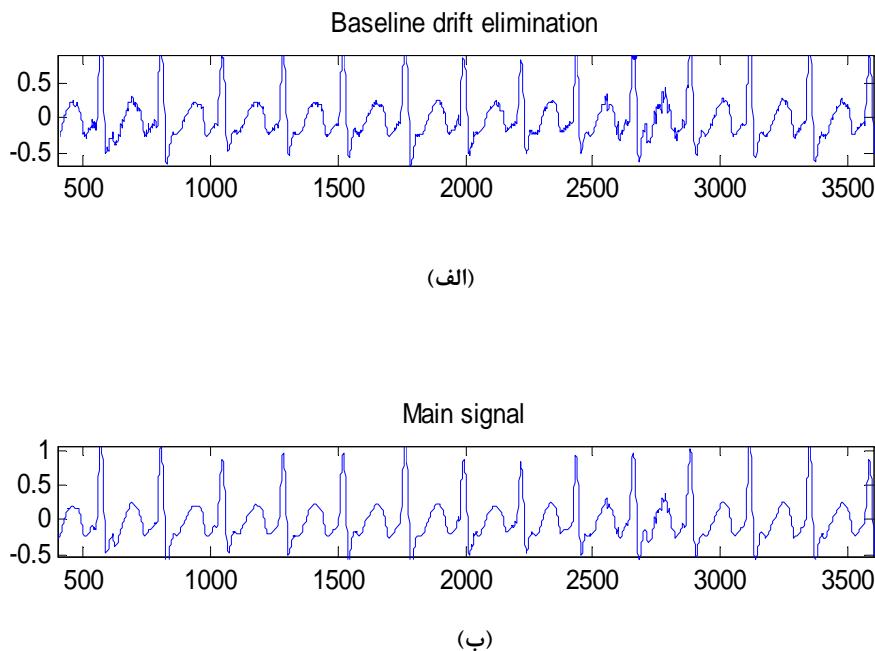
کلاس طبقه‌بندی	شماره رکورد در پایگاه داده
NORMAL	-۱۱۲ ۱۱۷-۱۲۱-۱۲۲-۱۲۳-۲۰۲-۲۲۰-۲۲۲-۲۳۴ ۱۰۰-۱۰۱-۱۰۳-۱۱۵
RBBB	۱۱۸-۲۱۲-۲۲۱
LBBB	۱۰۹-۱۱۱
PB	۱۰۷-۲۱۷

آن‌ها

حذف نویزهای فرکانس بالا به کمک تبدیل ویولت امکان پذیر است. پروسه کلی حذف نویز با ویولت به شرح زیر است:

- انتخاب ویولت و تعداد سطوح تجزیه
- به دست آوردن ضرایب ویولت (جزئیات و تقریب)
- قرار دادن آستانه روی ضرایب جزئی
- بازسازی سیگنال با استفاده از عکس تبدیل ویولت

دو نوع تابع آستانه‌گذاری استاندارد در کاربردهای حذف نویز موسوم به آستانه‌گذاری سخت و نرم به صورت زیر می باشند:



شکل (۵): (الف) سیگنال ECG پس از حذف نویز Base line و قبل از
حذف نویز فرکانس بالا (ب) سیگنال ECG پس از حذف این دو نویز

تری در آشکارسازی تغییرات سیگنال دارد. به همین دلیل جهت پردازش سیگنال در این تحقیق، $db6$ مورد استفاده قرار گرفت. در شکل ۵ یک نمونه سیگنال ECG پس از حذف نویزهای آن نشان داده شده است.

(۲)

$$THR_H(Y, T) = \begin{cases} Y & , |Y| \geq T \\ 0 & , |Y| < T \end{cases}$$

$$THR_S(Y, T) = \begin{cases} sign(Y)(|Y| - T) & , |Y| \geq T \\ 0 & , |Y| < T \end{cases}$$

همچنین مقدار مناسب برای حد آستانه را می‌توان از روش‌های مختلفی محاسبه کرد. مقدار آستانه در تبدیل ویولت گسسته توسط Donoho معرفی شده و از رابطه زیر به دست می‌آید [۱۶]:

$$T = \hat{\sigma} \sqrt{2 \ln(N)} \quad (3)$$

که در آن N طول سیگنال نویزی و $\hat{\sigma}$ نیز انحراف معیار نویز است. در این تحقیق، تعداد سطوح تجزیه ۸ و نوع ویولت مادر دابیشیز انتخاب شده است. این نوع ویولت، شباهت بسیاری به کمپلکس QRS دارد.

لازم به ذکر است که اکثر محققینی که از دابیشیز در آنالیز ECG استفاده نموده اند، دابیشیز مرتبه 4 ($db4$) را در پردازش این سیگنال مفید دانسته‌اند، در حالیکه گروهی از محققین در سال ۲۰۰۵ [۱۷]، پس از مقایسه‌ی کارایی $db4$ و $db6$ در پردازش ECG، به این نتیجه دست یافته‌اند که $db6$ از کارایی بیشتری برخوردار است و توانایی بیش-

استخراج ویژگی یکی از مهم‌ترین مراحل در مسائل تشخیص الگو است و دقت هر طبقه‌بندی کننده به استخراج ویژگی بستگی دارد. در مرحله استخراج ویژگی، ۵ ضربان از سیگنال انتخاب می‌شود. انتخاب این تعداد نمونه این اطمینان را ایجاد می‌کند که آریتمی در این بازه‌ی زمانی اتفاق افتاده است. با اعمال DWT به سیگنال مورد نظر ضرایب ویولت به دست می‌آیند. استفاده از ضرایب ویولت به عنوان بردار ویژگی، موجب افزایش اندازه بردار و رویدی طبقه‌بندی کننده می‌شود و این امر تأثیر نامطلوبی در عملکرد طبقه‌بندی کننده خواهد داشت. بنابراین به منظور کاهش اندازه بردار ویژگی، ویژگی‌های زیر به عنوان ویژگی نهایی انتخاب شده‌اند.

ماکریم ضرایب ویولت در هر سطح مینیمم ضرایب ویولت در هر سطح واریانس ضرایب ویولت در هر سطح

انحراف معیار ضرایب ویولت در هر سطح

پس از استخراج ویژگی، بردار بدست آمده جهت حصول به نتایج بهینه نرمالیزه شده است.

۴- نتایج شبیه‌سازی

در این مقاله، از معیار زیر برای تعیین درصد کارایی سیستم طراحی شده (یعنی میزان تشخیص درست آریتمی) استفاده شده است:

$$A = 100 \left(1 - \frac{Ne}{Nt} \right) \quad (4)$$

در فرمول فوق، پارامتر A درصد کارایی شبکه‌ی عصبی، Nt تعداد کل نمونه‌ها و Ne تعداد نمونه‌هایی است که به درستی طبقه‌بندی نشده‌اند.

در این مقاله، از دو الگوریتم (trainlm و trainlm) برای آموزش شبکه عصبی MLP استفاده شده است. در هر شبکه، ۸۰ نمونه به عنوان الگوهای آموزش و ۳۴۰ نمونه برای تست شبکه عصبی آموزش دیده در نظر گرفته شده است. الگوهای آموزشی بصورت تصادفی به شبکه اعمال می‌شوند. بنابراین، شبکه سعی می‌کند خود را با تغییرات دائم ورودی طبیق دهد و از این لحاظ قدرت یادگیری شبکه بالا می‌رود [۲۰]. جدول ۲ مقایسه کارایی دو شبکه مذکور را نشان می‌دهد. نتایج این جدول بیان می‌کند که شبکه آموزش دیده با الگوریتم traingdx، تنها به ۱۰ نمونه از ۳۴۰ نمونه تست پاسخ درست نداده است و درصد کارایی شبکه ۹۷/۰۶٪ می‌باشد در حالی که شبکه آموزش دیده با الگوریتم trainlm، به ۲۱ نمونه از ۳۴۰ نمونه تست پاسخ درست نداده است و درصد کارایی شبکه ۹۳/۸۲٪ است. نتایج بدست آمده نشان می-

جدول (۲): مقایسه کارایی دو شبکه آموزش داده شده

شبکه عصبی	کلاس‌های طبقه‌بندی	تعداد نمونه آموزش	تعداد نمونه تست	تعداد نمونه تست اشتباہ	درصد کارایی شبکه
الگوریتم آموزش	NORMAL	۲۰	۱۰۰	۲	۹۹/۹۸
	RBBB	۲۰	۸۰	۳	۹۶/۲۵
	LBBB	۲۰	۸۰	۲	۹۹/۹۸
	PB	۲۰	۸۰	۳	۹۶/۲۵
	Total	۸۰	۳۴۰	۱۰	۹۷/۰۶
الگوریتم آموزش trainlm	NORMAL	۲۰	۱۰۰	۴	۹۶
	RBBB	۲۰	۸۰	۶	۹۲/۵
	LBBB	۲۰	۸۰	۴	۹۶
	PB	۲۰	۸۰	۷	۹۱/۲۵
	Total	۸۰	۳۴۰	۲۱	۹۳/۸۲

۳-۳- استفاده از شبکه عصبی به عنوان طبقه‌بندی

کننده

دلایل متعددی برای استفاده از یک شبکه عصبی به عنوان طبقه‌بندی کننده وجود دارد:

شبکه‌های عصبی مصنوعی ساختار ساده‌ای برای کاربردهای فیزیکی (طبیعی) دارند.

شبکه‌های عصبی مصنوعی می‌توانند به آسانی کلاس‌های پیچیده را طبقه‌بندی کنند.

ویژگی اصلی شبکه‌های عصبی مصنوعی، اختصاص نتایج به بردار-های ورودی است که در آموزش شبکه وجود ندارند [۱۸].

در این تحقیق، پس از شبیه‌سازی‌های فراوان و مقایسه عملکرد شبکه‌ها، شبکه عصبی پرسپترون چندلایه (MLP) به عنوان طبقه‌بندی کننده انتخاب گردید.

این طبقه‌بندی کننده شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشد. تعداد لایه‌های پنهان و همچنین تعداد نرون‌های این لایه، نقش مهمی در عملکرد شبکه عصبی ایفا می‌کنند. هیچ معياری که بتوان تعداد دقیق نرون‌های لایه پنهان را تخمین زد وجود ندارد اما روش‌های زیادی برای تخمین اولیه تعداد نرون‌های لایه پنهان وجود دارد:

بهتر است که تعداد نرون‌های لایه پنهان بین تعداد نرون‌های

ورودی شبکه و نرون‌های لایه خروجی شبکه باشند.

تعداد نرون‌های لایه پنهان برابر مجموع $3/2$ برابر تعداد ورودی و

تعداد نرون‌های لایه خروجی شبکه در نظر گرفته شود.

تعداد نرون‌های لایه پنهان کمتر از دو برابر تعداد ورودی شبکه در نظر گرفته شود.

روش‌های ذکر شده تنها می‌تواند نقطه آغاز در تعیین تعداد معقول نرون‌های لایه پنهان باشد. با در نظر گرفتن این قوانین برای شروع کار، تعداد مناسب نرون‌های لایه پنهان با استفاده از روش سعی و خطای بدست می‌آید [۱۹].

بنابراین در این تحقیق، به روش سعی و خطای برای بهترین حالت عملکرد شبکه، تعداد ۱۰ نرون برای لایه‌ی پنهان در نظر گرفته شده است.

همچنین پس از بررسی مشخص گردید ویژگی‌های بیان شده در سطوح ۵ و ۶ تفاوتی در عملکرد شبکه ایجاد نمی‌نمایند. بنابراین، این ویژگی‌ها از بردار ویژگی حذف شده است. از آنجا که تعداد نرون‌های لایه ورودی برابر با سایز بردار ویژگی است و تعداد نرون‌های لایه خروجی به تعداد کلاس‌های طبقه‌بندی بستگی دارد، ساختار شبکه عصبی بصورت (۲۴-۱۰-۲) خواهد شد. نرون‌های لایه مخفی، دارای تابع عملکرد سیگموئید دوقطبی و نرون‌های لایه خروجی دارای تابع عملکرد خطی می‌باشند.

جدول(۳): مقایسه کارایی سیستم طراحی شده با سایر تحقیقات انجام شده در این زمینه

کارایی سیستم پیشنهادی به درصد	کلاس‌های طبقه‌بندی	پایگاه داده	روش	محققین
۸۸/۳۳	Normal – PVC – PB – RBBB- atrial premature beat – fusion of paced and normal beat	۱۰ فایل (MIT-BIH arrhythmias data base)	شبکه‌ی عصبی چند مرحله‌ای	Hosseini et al.[۶]
۹۵/۱۶	PVC – Normal – Other beat	۲۲ فایل (MIT-BIH arrhythmias data base)	ترکیب ویولت و ویژگی‌های زمانی/ شبکه‌ی عصبی	Inan et al.[۸]
۹۷/۰۴	PVC and Non PVC	۷ فایل (MIT-BIH arrhythmias data base)	ویولت/ شبکه‌ی عصبی	Shyu et al.[۷]
۹۷	PVC – Normal – Other beat	۴۰ فایل (MIT-BIH arrhythmias data base)	PCA و ویولت/ شبکه‌ی عصبی	Turker Ince et al. [۲۲]
۹۷	Normal –PB – RBBB - LBBB	۲۰ فایل (MIT-BIH arrhythmias data base)	استخراج ویژگی از ضرایب شبکه‌ی عصبی ویولت /	تحقیق انجام شده

و (traingdx) مورد آموزش و تست قرار گرفت. پس از بررسی این نتیجه حاصل شد که شبکه عصبی MLP با الگوریتم آموزش traingdx بهترین انتخاب برای طبقه‌بندی کننده می‌باشد. زمان مورد نیاز جهت آموزش و تست شبکه عصبی به دلیل استخراج ویژگی‌های مناسب از سیگنال ECG، کاهش محسوس یافته است. بطوری که در یک سیستم با مشخصات IV Pentium ، ۱/۷GHz و ۵۱۲ Mگابایت RAM، زمان مورد نیاز جهت تشخیص آریتمی یک نمونه تست ۰/۰۳ ثانیه می‌باشد. نکته قابل توجه در این تحقیق، استفاده از ۲۰ نمونه در قالب ۴۲۰ فایل از پایگاه داده است و این در حالی است که بسیاری از محققین از تعداد کمتری فایل جهت آموزش و تست استفاده کرده‌اند با وجود این، دقت سیستم طراحی شده و تعداد کلاس‌های طبقه‌بندی در این تحقیق در مقایسه با تحقیقات انجام شده از برتری نسبتاً مناسبی برخوردار می‌باشد. این سیستم می‌تواند ۴ کلاس نرمال، وقفه در بافت سمت چپ(LBBB)، وقفه در بافت سمت راست (RBBB) و ضربان زودرس بطنی(PVC) را با دقت بیش از ۹۷٪ طبقه‌بندی نماید.

مراجع

- [1] T.H.Yeap,F. Johnson, and M. Rachniowski, "ECG beat classification by a neural network," in Proc. Annu. Int. Conf. IEEE Engineering Medicine and Biology Society, pp. 1457–1458, 1990
- [2] P. deChazal , R.B.Reilly, "Automatic classification of ECG beats using a waveform shape and hear beat interval

دهد که شبکه MLP با الگوریتم آموزش traingdx در مقایسه با شبکه MLP با الگوریتم آموزش trainlm از عملکرد بهتری برخوردار می‌باشد. تمامی شبیه‌سازی‌ها در نرم‌افزار matlab انجام شده است [۲۱]. در جدول ۳ مقایسه‌ای بین تحقیقات انجام شده در این زمینه و تحقیق ارائه شده، نشان داده شده است. برای هر تحقیق، روش انجام کار، تعداد فایل‌های استفاده شده از پایگاه داده ذکر شده در مرجع [۱۵]، تعداد کلاس‌های طبقه‌بندی و درصد کارایی سیستم ارائه شده ذکر شده است. بهترین نتیجه بدست آمده در مرجع [۷] با وجود ۲ کلاس طبقه‌بندی و استفاده از ۷ فایل پایگاه داده، ۹۷/۰۴٪ است، در حالی که کارایی روش انجام شده در این تحقیق، به ازای ۴ کلاس طبقه‌بندی و استفاده از ۲۰ فایل پایگاه داده، ۹۷/۰۶٪ می‌باشد. بنابراین، با مشاهده جدول می‌توان به این نتیجه رسید که با در نظر گرفتن تعداد فایل‌های استفاده شده از پایگاه داده و تعداد کلاس‌های طبقه‌بندی، سیستم طراحی شده در این تحقیق از کارایی بهتری نسبت به سایر تحقیقات برخوردار می‌باشد.

۵- نتیجه‌گیری

در این مقاله، روشی جدید برای طبقه‌بندی آریتمی‌های قلبی ارائه شده است. ابتدا با استفاده از تکنیک‌های پردازش سیگنال و DWT، نویزهای موجود در ECG حذف شد. پس از این مرحله، ویژگی‌های زمان – فرکانس جهت ورودی شبکه عصبی به عنوان سیستم طبقه‌بندی کننده استخراج گردید. شبکه عصبی MLP با دو نوع الگوریتم آموزش trainlm)

- features," in Proc. Int. Conf. Acoustics. . Speech, and Signal Processing, pp. 269-272, 2003.
- [3] P. deChazal, "classifier using Morphology and Heartbeat Interval Features," IEEE Trans Biomed. Eng, pp.2535-2543, 2006.
- [4] Y. H. Hu, S. Palreddy, and W. J. Tompkins, "A patient-adaptable ECG beat classifier using a mixture of experts approach," IEEE Trans Biomed. Eng, pp. 891-900, 1997.
- [5] M. Lagerholm, C.Peterson, G. Braccini, L. Edenbrandt, and and L. Sormmo, "Clustering ECG complexes using hermite functions and self-organizingmaps," IEEE Trans. Biomed. Eng, pp. 834-848, 2000.
- [6] H.G.Hosseini, K.J.Reynolds, and D.Powers, "A multi-stage neural network classifier for ECG events," in Proc.23rdInt.Conf.IEEE EMBS, vol. 2, pp. 1672-1675, 2001.
- [7] L.Y.Shyu, Y.H.Wu, andW.C.Hu, "Using wavelet transform and fuzzy neural network for VPC detection from the holter ECG," IEEE Trans. Biomed. Eng, pp. 1269-1273, 2004.
- [8] Omer T.Inan and Gregory T. A. Kovacs, "Robust neural network-based classification of premature ventricular contractions using wavelet transform and timing interval features," IEEE Trans Biomed. Eng, pp.2507- 2515, 2006.
- [9] K. Minami, H. Nakajima, and T. Toyoshima, "Real-time discrimination of ventricular tachy arrhythmia with Fourier- transform neural network," IEEE Trans. Biomed. Eng., vol. 46, pp. 179-185,Feb.1999.
- [10] C. Li, C. X. Zheng, and C. F. Tai, "Detection of ECG characteristic points using wavelet transforms," IEEE Trans. Biomed. Eng., pp.21-28, 1995.
- [11] M. R. Risk, J. F. Sobh, and J. P. Saul, "Beat detection and classification of ECG using self organizing maps," in Proc. 19th Int. Conf. IEEE. EMBS, pp. 89-91, 1997.
- [12] D. Cvetkovic, E. D. Ubeyli and I. Cosic, "Wavelet transform feature extraction from human PPG, ECG, and EEG signal responses to ELFPEMF exposures: A pilot study", ELSEVIER, Digital Signal Process, 2008.
- [13] S. Mallat, "A theory for multi resolution signal decomposition: The wavelet representation, " IEEE Trans. Pattern Anal. Machine Intell, vol. 11, pp.674-693, 1989.
- [14] Wavelet Toolbox User's Guide for Use with Matlab 7. The Mathworks Inc, 2006.
- [15] MIT-BIH arrhythmia database directory at "<http://physionet.fri.uni-lj.si/physiobank/database/mitdb/>
- [16] D. L. Donoho, "De - noising by soft - thresholding," IEEE Trans. Inform. Theory, vol. 41, pp. 613-627, 1995.
- [17] S. Z. Mahmoodabadi, A. Ahmadian, M. D. Abolhasani , "ECG feature extraction using daubechies wavelets," Proceeding of the Fifth IASTED International Conference Visualization, Imaging, and Image Processing, Spain, 2005.
- [18] T. Olmez, Z. Dokur, " Application of InP Neural Network to ECG Beat Classification ,," Neural omput & Applic11:pp.144-155, 2003.
- [19] Heaton, Jeff, *Introduction to Neural Networks with Java*, 1st Edition, 2005.
- [20] ع. عرفانیان امیدوار، ع. عرفانی، "تشخیص الگوهای EEG در هنگام تصور حرکت دست با استفاده از یک طبقه‌بندی کننده مبتنی بر تجزیه و تحلیل مولفه‌های مستقل" ، مجله انجمان مهندسین برق و الکترونیک ایران، سال اول، شماره سوم، ۱۳۸۳، ۴۳-۳۳.
- [21] Neural Networks Toolbox User's Guide for Use with Matlab 7. The Mathworks Inc, 2006.
- [22] T. Ince, S. Kiranyaz, and M. Gabbuji, "Automatic atient-specific classification of premature contraction," in Proc. 30th Int. Conf. IEEE. EMBS, , pp. 5475-5477, 2008.