

# SID



سرویس های ویژه



سرویس ترجمه تخصصی



کارگاه های آموزشی



بلاگ مرکز اطلاعات علمی



سامانه ویراستاری STES



فیلم های آموزشی

## کارگاه های آموزشی مرکز اطلاعات علمی



مقاله نویسی علوم انسانی



اصول تنظیم قراردادها



آموزش مهارت های کاربردی در تدوین و چاپ مقاله

## استفاده از دسته بندی کننده های غیر خطی در تشخیص ضربان به ضربان ایسکمی

مریم محبی آشتیانی<sup>۱\*</sup>، حمید ابریشمی مقدم<sup>۲</sup> و بابک محمدزاده اصل<sup>۱</sup>

۱- دانشگاه تربیت مدرس، دانشکده فنی، گروه مهندسی پزشکی

۲- دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده برق، گروه مهندسی پزشکی

E-mail: mohebbi\_maryam@yahoo.com

### چکیده

دسته بندی ضربانهای قلبی در سیگنال الکتروکاردیوگرام (ECG) نقش بسیار مهمی در آشکارسازی اپیزودهای ایسکمی دارد. در این مقاله الگوریتمی را برای تشخیص ضربانهای ایسکمی با استفاده از دسته بندی کننده های غیر خطی شبکه عصبی و ماشین بردار پشتیبان ارائه کرده ایم. این الگوریتم شامل سه مرحله است. در مرحله اول سیگنال ECG به منظور استخراج یک الگوی نمونه، حذف نویز و آرتیفکت، استخراج قطعه ST و... مورد پیش پردازش قرار می گیرد. در مرحله بعد داده های مورد نیاز برای طبقه بندی کننده آماده سازی شده و در مرحله آخر هر ضربان دسته بندی می شود. روش ارائه شده با استفاده از مجموعه داده ای مشتمل بر ۱۸۰۴۷ ضربان از پایگاه داده ESC ST-T database مورد ارزیابی قرار گرفته و نتایج بدست آمده برای دو معیار حساسیت و پیش بینی مثبت به ترتیب برابر ۹۷/۲۲٪ و ۹۷/۴۴٪ برای دسته بندی کننده شبکه عصبی با نرخ یادگیری متغیر و ۹۲/۱۳٪ و ۹۰/۳۴٪ برای دسته بندی کننده ماشین بردار پشتیبان می باشد.

واژه‌های کلیدی: قطعه ST، دسته بندی ضربان، شبکه عصبی، ماشین بردار پشتیبان.

### ۱- مقدمه

آشکارسازی ایسکمی به حساب می آید و از طرفی به پزشکان متخصص در آشکارسازی صحیح اپیزودهای ایسکمی نیز کمک می کند.

در طول سالهای اخیر الگوریتم های مختلفی برای تشخیص ضربانهای ایسکمی ارائه شده اند که می توان به تبدیل موجک [۲]، الگوریتمهای قاعده-مبنا [۳-۴]، الگوریتم بر مبنای قوانین انجمنی (Rule-mining) [۵]، الگوریتم ژنتیک [۶] و شبکه های عصبی [۷] اشاره کرد. در این مقاله از دو دسته بندی کننده شبکه عصبی و ماشین بردار پشتیبان (SVM) برای تشخیص ضربان های ایسکمی استفاده شده است. الگوریتم ارائه شده شامل ۳ مرحله می باشد که فلوچارت کلی آن در شکل ۱ نشان داده شده است.

بیماریهای قلب و عروق از شایع ترین بیماریهای قرن حاضر محسوب می شود و نارسایی عروق کرونر امروزه بزرگترین عامل مرگ و میر در جوامع صنعتی و نیمه صنعتی به حساب می آید. ایسکمی میوکارد (Myocardial Ischemia) در اثر گرفتن عروق خون رسان قلبی و کاهش اکسیژن دریافتی سلولهای قلبی پدید می آید. در نتیجه سلولهای میوکارد کمتر و یا بیشتر تحریک می شوند که این تغییر خود را در فاز ریپولاریزاسیون سیکل قلبی نشان می دهد و از آن جا که قطعه ST ریپولاریزاسیون بطنی را منعکس می کند، بنابراین بالارفتن و پایین آمدن قطعه ST می تواند نشانه ایسکمی و یا آسیب دیدگی باشد [۱].

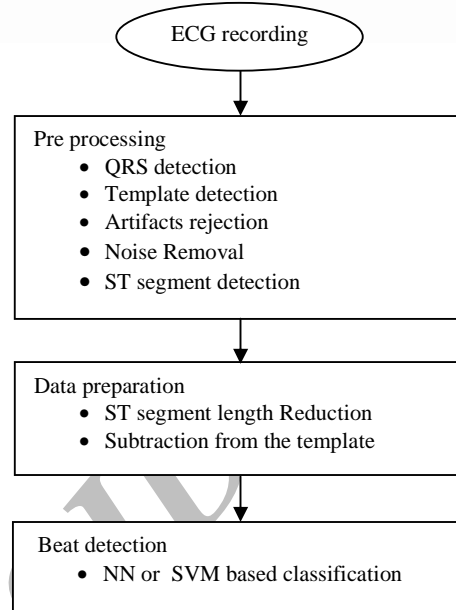
مونیتورینگ سیگنال ECG برای استخراج قطعه ST و تشخیص ضربان های ایسکمی کاربردی ترین تکنیک برای

نادرست دسته بندی می شوند و الگوریتم برای ضربان بعدی ادامه می یابد.

انواع نویزهای که استخراج قطعه ST را مشکل می سازند، شامل نویز برق شهر، نویز سیگنالهای الکتریکی ماهیچه (EMG) و نویز انحراف از خط زمینه (BW) می باشد. برای حذف نویز برق شهر و تداخل الکتریکی ماهیچه ها در تشخیص نقطه J از یک پنجره متوسط گیر متحرک با طول ۲۰ ms در بازه [R+۲۰ ms, R+۱۲۰ ms] استفاده می کنیم به این ترتیب که پنجره موردنظر در این بازه نقطه به نقطه پیش می رود و مقدار هر نمونه برابر میانگین نمونه های موجود در پنجره خواهد بود. همین الگوریتم را در بازه [R-۸۰ ms, R-۶۰ ms] برای حذف نویز در آشکارسازی سطح ایزو الکتریک تکرار می کنیم [۹]. برای حذف نویز انحراف خط زمینه نیز از تکنیک اسپلاین درجه ۳ (cubic spline) [۱۰] استفاده می کنیم.

برای آشکارسازی نقطه J از الگوریتم آشکارسازی لبه [۱۱] استفاده می کنیم. در این الگوریتم از یک پنجره متحرک با طول ۲۰ ms استفاده می شود که از ۲۰ ms بعد از موج S شروع شده و نقطه به نقطه پیش می رود تا به ۱۲۰ ms بعد از این موج برسد و در هر قسمت شیب سیگنال محاسبه می شود. در طول حرکت پنجره هر جا شیب سیگنال برای اولین بار به کمتر از  $2/5 \mu Vms^{-1}$  برسد، الگوریتم متوقف می شود و نقطه میانی این پنجره به عنوان نقطه J در نظر گرفته می شود. چنانچه بعد از پایان الگوریتم، در هیچ پنجره ای شیب سیگنال به کمتر از این حد نرسید، در اینصورت در همین بازه به دنبال نقطه ای می گردیم که مشتق اول آن صفر باشد. الگوریتم با پیدا کردن اولین نقطه با شیب صفر متوقف شده و این نقطه به عنوان نقطه J در نظر گرفته می شود.

در این الگوریتم طول پیش فرض برای قطعه ST را ۱۶۰ ms در نظر گرفته و بنابراین فاصله بین نقطه J تا J+160 ms را به عنوان قطعه ST استخراج می کنیم که با توجه به نرخ نمونه برداری سیگنال مورد استفاده (۲۵۰ Hz) این قطعه شامل ۴۰ نمونه خواهد بود [۷].



شکل ۱: فلوچارت کلی دسته بندی ضربان های ایسکی

## ۲- روشها و ابزارها

### ۲-۱- پیش پردازش سیگنال ECG و استخراج قطعه ST

هدف اصلی انجام این مرحله استخراج قطعه ST به گونه ای است که بتوان از آن به عنوان ورودی دسته بندی کننده استفاده کرد. این مرحله شامل آشکارسازی موج R، استخراج الگوی نمونه، حذف انواع نویزها و از جمله حذف انحراف خط زمینه و در نهایت آشکارسازی نقطه J (شروع قطعه ST) می باشد. به این منظور ابتدا با استفاده از الگوریتم Pan-Tompkins [۸] کمپلکس QRS و در نهایت موج R را در هر ضربان مشخص می کنیم. گام بعدی استخراج یک الگوی نمونه است که از آن هم برای حذف ضربان های نادرست و هم برای اندازه گیری انحراف قطعه ST استفاده می کنیم. این الگوی نمونه از متوسط گیری ضربان های ۳۰ ثانیه ابتدای هر ثبت از سیگنال بدست می آید. این الگو به صورت ثابت نمی باشد، بلکه در طول آنالیز سیگنال و با هر ضربان درست این الگو به روز می شود. از فاصله اقلیدسی بین الگوی بدست آمده و هر ضربان به عنوان معیاری برای تشخیص نرمال یا غیر نرمال بودن آن استفاده می کنیم. به این ترتیب که ضربانهایی که فاصله اقلیدسی آنها از الگوی نمونه بیشتر یک آستانه مشخص باشد، به عنوان ضربان

۲-۳-۱- دسته بندی کننده شبکه عصبی  
کلاس های خروجی: ضربان نرمال و ضربان ایسکمی.  
بردار الگوی ورودی: ۲۰ نمونه از قطعه ST.

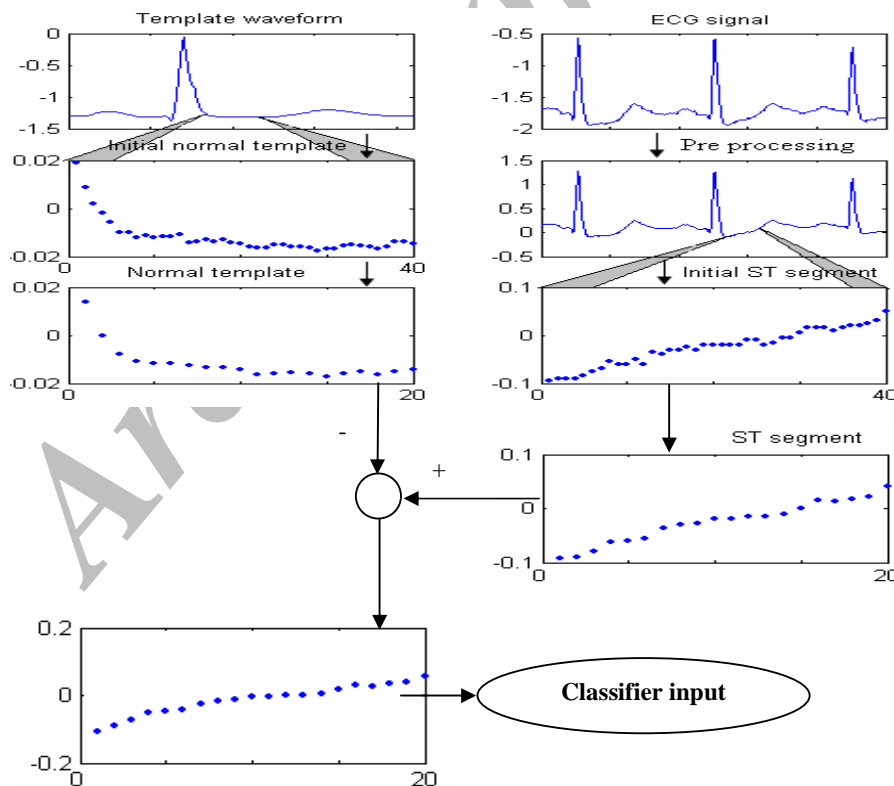
ساختار شبکه عصبی: از یک شبکه پرسپترون سه لایه پیشخور بعنوان طبقه بندی کننده غیر خطی که با استفاده از الگوریتم پس انتشار خطا با نرخ یادگیری متغیر آموزش داده می شود، استفاده می کنیم. تعداد نورون های لایه اول برابر با تعداد نمونه های الگوی ورودی (۲۰ نورون) در نظر گرفته شده و لایه خروجی شامل ۲ نورون می باشد که مقداری بین ۱ و ۰ اختیار می کنند. همچنین تابع فعالیت نورون ها از نوع تانژانت سیگموئید انتخاب و با تغییر تعداد نورون های لایه میانی سعی در بهینه سازی معماری شبکه عصبی می گردد. تعدادی از انواع ساختارهای معمول شبکه های عصبی مصنوعی بررسی و

## ۲-۲- آماده سازی داده

در این بخش به آماده سازی داده های مورد نیاز برای دسته بندی کننده می پردازیم. به منظور کاهش حجم داده ورودی دسته بندی کننده، طول قطعه ST را با متوسط گیری هر دو نمونه متوالی به ۲۰ نمونه کاهش می دهیم. همین الگوریتم را بر روی الگوی نمونه نیز اعمال کرده و یک الگوی نرمال را برای قطعه ST استخراج می کنیم. تفاضل قطعه ST و الگوی نرمال به عنوان ورودی به دسته بندی کننده اعمال می شود. شکل ۲ مراحل آماده سازی داده را نشان می دهد.

## ۲-۳- دسته بندی ضربان

در این مرحله با استفاده از دو طبقه بندی کننده غیرخطی به دسته بندی هر ضربان می پردازیم.



شکل ۲: مراحل آماده سازی داده های ورودی به دسته بندی کننده را نشان می دهد. ستون سمت راست استخراج قطعه ST از ضربان مورد نظر و ستون چپ قطعه ST الگوی نرمال را نشان می دهد. تفاضل این دو به عنوان ورودی به دسته بندی کننده اعمال می شود.

سازی مناسب برای این کار، معیار ماکزیمم حاشیه است، که سبب یافتن یک ابرصفحه با ماکزیمم حاشیه جداسازی  $\gamma$  می‌گردد (شکل ۳). برای توصیف این ابرصفحه بهینه تنها به بردارهایی نیاز است که بر روی حاشیه قرار دارند. این بردارها به بردارهای حمایتی مشهور می‌باشند. برای نمایش کانونی این ابرصفحه، شرط  $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$  باید برآورده شود تا اینکه مقدار حاشیه برابر با  $\gamma = 2/\|\mathbf{w}\|^2$  گردد. بنابراین، ماکزیمم کردن حاشیه  $\gamma$  معادل با مینیمم کردن  $(1/2)\|\mathbf{w}\|^2$  تحت همان شروط است. اگر بخواهیم متغیری را نیز برای تخطی کردن از شروط مطروح در نظر بگیریم یک متغیر  $\xi_i$  نیز به مسئله اضافه می‌شود و منتج به مسئله‌ای می‌گردد به نام بهینه-سازي حاشیه نرم SVM که به صورت زیر است:

$$\min \frac{1}{2}\|\mathbf{w}\|^2 + C \sum_i \xi_i \quad (3)$$

$$\text{s.t. } y_i(\mathbf{w}\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i > 0 \forall i.$$

مقادیر بزرگتر برای پارامتر ساماندهی  $C$  متناظر است با مقدار جریمه بیشتر برای تخطی از شروط مذکور. برای حل کردن این مسئله، می‌توان آن را به صورت ضرایب مثبت لاگرانژ  $\alpha_i$  بازنویسی نمود. بنابراین، نمایش دوگانه (۳) مستلزم ماکزیمم کردن عبارت زیر می‌باشد:

$$L_D = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (4)$$

این کار با شروط  $\sum_i \alpha_i y_i = 0$  و  $0 \leq \alpha_i \leq C$  منجر به حاصل شدن بردار وزن به صورت زیر می‌گردد:

$$\mathbf{w} = \sum_i^{N_s} y_i \alpha_i \mathbf{x}_i. \quad (5)$$

که در آن  $N_s$  تعداد بردارهای حمایتی حاصل می‌باشد. جایگزین نمودن  $\mathbf{w}$  در (۲) با کمک (۵) به عبارت زیر منتج می‌شود:

$$f(\mathbf{x}) = \sum_i^{N_s} y_i \alpha_i (\mathbf{x} \cdot \mathbf{x}_i) + b. \quad (6)$$

می‌توان نشان داد که با جایگزین کردن ضرب داخلی  $\mathbf{x} \cdot \mathbf{x}_i$  با یک تابع Kernel متقارن مثبت معین  $K(\mathbf{x}, \mathbf{x}_i)$  می‌توان

بهترین شبکه عصبی منتجه، یک شبکه عصبی سه لایه پیشخور با ۲۰ نورون پردازش کننده، با تابع فعالیت سیگموئید استاندارد، در لایه پنهان می‌باشد. در نهایت با ماکزیمم گیری از دو خروجی شبکه عصبی، کلاس مربوط به مجموعه ویژگی‌های ورودی مشخص می‌شود. آموزش شبکه تا زمانیکه مربع خطا کمتر از ۰/۰۱ شود یا تعداد تکرارهای آموزش به ۲۰۰۰ برسد ادامه می‌یابد.

### ۲-۳-۲- دسته بندی کننده SVM

یک راه آسان برای طبقه بندی دو کلاسه، همانطور که در شکل ۳ ملاحظه می‌شود، ساختن یک ابرصفحه با مشخصات یک بردار وزن  $\mathbf{w}$  و یک ترم بایاس  $b$  است. بر پایه مجموعه داده آموزشی شامل تعداد  $l$  نمونه از بردارهای داده  $\mathbf{x}_i$  و برچسبهای کلاس  $y_i$  متناظر با آنها یک الگوریتم یادگیری ماشین با تکیه بر یک سری روشهای بهینه سازی مناسب برای پیدا کردن این چنین ابرصفحه ای لازم می‌باشد [۱۳-۱۴].


اگر داده های آموزشی را به صورت زیر در نظر بگیریم:

$$(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l) \in R^N \times \{-1, 1\} \quad (1)$$

در فاز آزمایش، برچسب کلاس بردار جدید داده  $\mathbf{x}$  را می‌توان با استفاده از تصویر  $\mathbf{x}$  بر روی بردار وزن  $\mathbf{w}$  پیش بینی نمود:

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b. \quad (2)$$

علامت این تصویر بیانگر برچسب کلاس مورد نظر است.



شکل ۳: یک نمونه از ماشین بردار حمایتی خطی

با اینکه می‌توان ابرصفحه های متفاوتی را برای جدا کردن فضای داده به دو زیرمجموعه یافت، ولی یک روش بهینه-

$$se(\%) = \frac{TP}{TP + FN} \times 100 \quad (9)$$

$$pp(\%) = \frac{TP}{TP + FP} \times 100. \quad (10)$$

که TP، FP و FN به ترتیب به مثبت صحیح، مثبت اشتباه و منفی اشتباه اشاره می کند. پیاده سازی روی چندین مجموعه داده، آزمایش شده و نتایج ارائه شده در این جدول میانگین نتایج را نشان می دهند. نتایج بدست آمده نشان دهنده کارایی بالای این روش در دسته بندی ضربانهای قلب به دو دسته نرمال و ایسکمی می باشد. توجه به این نکته ضروری است که تعداد ضربان های نرمال در مقایسه با ضربانهای ایسکمی زیادتر است و این موضوع دسته بندی را به واقعیت نزدیکتر می کند چون در ثبت های ECG تعداد ضربان های نرمال نسبت به دیگر ضربان ها بیشتر است.

جدول ۱: نتایج دسته بندی ضربان با استفاده از شبکه عصبی

Beat Classes	# of Train & Test beats	Sensitivity	Positive Predictivity
Normal	10000,5000	98.86%	98.65%
Ischemic	2000,1047	95.54%	96.23%
Average	12000,6047	97.22%	97.44%

جدول ۲: نتایج دسته بندی ضربان با استفاده از SVM

Beat Classes	# of Train & Test beats	Sensitivity	Positive Predictivity
Normal	10000,5000	86.50%	98.37%
Ischemic	2000,1047	97.76%	82.30%
Average	12000,6047	92.13%	90.34%

در جدول ۳ نیز خلاصه ای از نتایج بدست آمده از دیگر روشهای تشخیص اتوماتیک ضربان های ایسکمی آمده است. مقایسه بین نتایج این دسته بندی و سایر روشها کارایی قابل قبول این الگوریتم را نشان می دهد.

با یک تبدیل ضمنی، فضای داده مورد نظر را به فضای ویژگی (معمولا با ابعاد بالاتر) تبدیل نمود. این باعث تشکیل یک تابع جداسازی غیرخطی به شکل زیر می شود

$$S(\mathbf{x}) = \sum_i^{N_s} y_i \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (7)$$

این تکنیک منجر به ایجاد مرزهای تصمیم قابل انعطافتری در فضای داده می شود، که می تواند دقت طبقه بندی را افزایش دهد. در این مقاله، برای تمام نمونه های SVM، از تابع کرنل (kernel) گوسی به صورت زیر استفاده شده است.

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2}\right) \quad (8)$$

رفتار یک طبقه بندی کننده SVM توسط دو پارامتر ضریب ساماندهی C و پهنای باند  $\sigma$  کرنل گوسی کنترل می گردد. هر دوی این پارامترها باید به دقت انتخاب شوند تا نتایج خوبی حاصل گردد. برای انتخاب مقادیر بهینه، داده آموزشی را به دو بخش آموزشی و ارزیابی تقسیم می کنیم. سپس هر ترکیبی از این دو پارامتر که کمترین خطا را روی داده های ارزیابی ایجاد کنند بعنوان مقادیر بهینه انتخاب شده و برای آموزش SVM استفاده می شوند. بهترین  $\sigma$  و C بدست آمده با این روش به ترتیب ۰/۵ و ۱۰ می باشند.

### ۳- نتایج

برای ارزیابی الگوریتم ارائه شده در دسته بندی ضربان های ایسکمی از مجموعه داده ای مشتمل بر ۱۸۰۴۷ ضربان (شامل ۱۵۰۰۰ ضربان نرمال و ۳۰۴۷ ضربان ایسکمی) از پایگاه داده ESC ST-T database استفاده کرده ایم.

نتایج دسته بندی و همچنین تعداد داده های مورد استفاده برای آموزش و تست دسته بندی کننده شبکه عصبی و SVM برای دو معیار حساسیت (sensitivity) و پیش بینی مثبت (positive predictivity) به ترتیب در جدول ۱ و ۲ ارائه شده اند. دو معیار فوق برای ارزیابی به صورت زیر تعریف می شوند:

- [7] T. Stamkopoulos, K. Diamanaras, N. Maglaveras and M. Srintzizis, "ECG Analysis Using Nonlinear PCA Neural Networks For Ischemia Detection," *IEEE Transaction On Signal Processing*, vol.46, no.11, 1998.
- [8] J. Pan, and W.J. Tompkins, "A real time QRS detection algorithm," *IEEE Transaction on Biomedical Engineering*, vol. 32, pp. 230-36, 1985.
- [9] C. Papaloukas, D. I. Fotiadis, A. P. Liavas, A. Link and L. K. Michalis, "A Robust Knowledge-Based Technique for Ischemia Detection in Noisy ECGs," 4<sup>th</sup> conference on knowledge based intelligent engineering systems, pp.768-771, 2000.
- [10] F. Badilini, A. J. Moss and E. L. Titlebaum, "Cubic Spline Baseline Estimation in Ambulatory ECG Recordings for the Measurement of Segment Displacements," *IEEE Eng. Medical and Biology*, Vol. 13, Vo.2, pp.584-585, 1991.
- [11] I. K. Daskalov, I. A. Dotsinsky, I. I. Christov, "Developments in ECG Acquisition, Preprocessing, Parameter Measurement, and Recording," *IEEE Eng. Med.Bio*, vol. 17, no.2, pp.50-58, 1998.
- [12] C. Papaloukas, D. I. Fotiadis, A. Likas, and L. K. Michalis, "An Expert System for Ischemia Detection Based on Parametric modeling and Artificial Neural Networks," *Proc. Eur. Med. Biol. Eng. Conf*, pp. 742-743, 2002.
- [13] G. Mercier and M. Lennon, "Support Vector Machines for Hyper spectral Image Classification with Spectral-Based Kernels," *Proc. IGARSS, Toulouse, France*, vol.1, pp. 288-290, 2003.
- [14] L. Wang, B. Liu, and C. Wan, "Support Vector Machines with Graded Resolution for Classification Problems," *IEEE International Conference on Granular Computing*, vol. 2, pp. 666-670, 2005.

جدول ۳: مقایسه بین نتایج بدست آمده با سایر الگوریتم های

دسته بندی ضربان های ایسکمی

Method	Sensitivity	Positive Predictivity
Genetic algorithm & multicriteria [6]	91%	91%
Parametric model[12]	81%	84%
PCA & NN [7]	90%	90%
Set of rules [4]	70%	63%
Rule-mining based [5]	87%	93%
This work (SVM)	92.13%	90.34%
(NN)	97.22%	97.44%

#### ۴- نتیجه گیری

در این مقاله با استفاده از دسته بندی کننده های غیر خطی شبکه عصبی و ماشین بردار پشتیبان به دسته بندی ضربان های نرمال و ایسکمی پرداختیم که نتایج بدست آمده کارایی خوب این دسته بندی کننده ها را برای تشخیص ضربان ها نشان می دهد. در ادامه این تحقیق با استفاده از ضربانهای ایسکمی تشخیص داده شده به تشخیص اپیزودهای ایسکمی خواهیم پرداخت و به نظر می رسد با تکمیل این مرحله ابزاری مفید و قابل اعتماد برای کمک به متخصصین قلب و عروق و بیماران با سابقه ایسکمی ارائه خواهد شد.

#### مراجع

- [1] M. J. Goldman, principles of clinical electrocardiography, 11th ed. Los Altos, CA: Lange Medical, 1982.
- [2] L. Senhadji, G. Carrault, J. J. Bellanger, and G. Passariello, "Comparing Wavelet Transforms for Recognizing Cardiac Patterns," *IEEE Eng. Med. Biol. Mag*, vol. 14, no. 2, pp. 167-173, 1995.
- [3] C. Papaloukas, D. I. Fotiadis, A. P. Liavas, A. Likas, and L. K. Michalis, "A Knowledge-Based Technique for Automated Detection of Ischemic Episodes in Long Duration Electrocardiograms," *Medical & Biological Engineering & computing*, vol. 39, no. 1, pp. 105-112, 2001.
- [4] C. Papaloukas, D. I. Fotiadis, A. Likas, C. S. Stroumbis, and L. K. Michalis, "Use of a Novel Rule-Based Expert System in the Detection of Changes in the ST Segment and the T Wave in Long Duration ECGs," *Journal of electrocardiology*, vol. 35, no. 1, 2002.
- [5] T.P.Exarchos, C.Papaloukas, D.I.Fotiaidis and L.K.Michalis," An Association Rule mining -based methodology for automated detection of ischemic ECG beats", *IEEE Trans. Biomed. Eng.*, vol. 53, no.8, pp. 1531-1540, 2006.
- [6] Y. Goletsis, C. Papaloukas, D. I. Fotiadis, A. Likas, and L. K. Michalis, "Automatic ischemic beat classification using genetic algorithms and multicriteria decision analysis," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 10, pp. 1717-1725, Oct. 2004.

# SID



سرویس های ویژه



سرویس ترجمه تخصصی



کارگاه های آموزشی



بلاگ مرکز اطلاعات علمی



سامانه ویراستاری STES



فیلم های آموزشی

## کارگاه های آموزشی مرکز اطلاعات علمی



مقاله نویسی علوم انسانی



اصول تنظیم قراردادها



آموزش مهارت های کاربردی در تدوین و چاپ مقاله