

کاربرد منطق فازی در تشخیص تپش قلب نامنظم با استفاده از نوار قلب

آرمین شوقی، محمدباقر دولتشاهی*

گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه لرستان

چکیده

الکتروکاردیوگرام از مهمترین سیگنال‌های حیاتی است که توسط پزشکان برای اهداف تشخیصی مورد استفاده قرار می‌گیرد. این سیگنال‌ها اطلاعات کلیدی درباره‌ی فعالیت الکتریکی قلب فراهم می‌آورند که ثبت و نمایش آن‌ها در طول زمان، منجر به مشاهده تغییرات فعالیت قلب می‌گردد. امروزه طبقه‌بندی این سیگنال‌ها کاربرد وسیعی در علوم پزشکی و تشخیص بیماری‌ها دارد و استفاده از روش‌های خودکار آنالیز آن‌ها با بهره‌گیری از تکنیک‌های مبتنی بر رایانه، تجزیه و تحلیل خودکار شکل و الگوی شکل موج سیگنال‌های قلب می‌تواند به پزشکان در تشخیص نوع بیماری کمک بسیاری نماید. تکنیک‌های مختلفی برای طبقه‌بندی بیماری‌های قلبی که به صورت بی‌نظمی ضربان‌های قلب شناخته می‌شوند، تا به حال ارائه شده است. این مقاله با هدف بررسی توسعه تکنیک‌های مختلف طبقه‌بندی بی‌نظمی ضربان‌های قلبی بر اساس منطق فازی به همراه بحث در مورد تکنیک‌های پذیرفته‌شده، انجام شده است.

۱ مقدمه

طبق گزارشات سازمان بهداشت جهانی، بیماری‌های قلبی عروقی یکی از مهمترین دلایل مرگ و میر در سراسر جهان هستند که در میان این بیماری‌ها، بی‌نظمی ضربان‌های قلبی رایج‌ترین نوع بیماری محسوب می‌شود. از میان ۵۰ میلیون فوت که سالیانه اتفاق می‌افتد، ۲۰ میلیون آن‌ها به دلیل بیماری‌های قلبی و عروقی است [۶۹]. به این ترتیب، طبقه‌بندی دقیق این سیگنال‌ها

Mathematics Subject Classification (2010): 68T10, Email: Dowlatshahi.mb@lu.ac.ir.

عبارات و کلمات کلیدی: تپش قلب، نوار قلب، منطق فازی

۱۳۹۹ (انجمن سیستم‌های فازی ایران)

مورد توجه بسیاری از مطالعات زیست پزشکی قرار گرفته است. یکی از موثرترین ابزارها برای شناسایی این بیماری‌ها تجزیه و تحلیل سیگنال‌های نوار قلب است. تجزیه و تحلیل نوار قلب فردی می‌تواند اشکال مشخصه، ویژگی‌های مورفولوژیکی و اطلاعات بالینی با همبستگی معنی‌داری برای تشخیص خودکار یک الگوی نوار قلب فراهم کند. عملیات تجزیه و تحلیل سیگنال‌های قلب بسته به کاربرد شامل چندین مرحله مانند پیش‌پردازش [۶۴، ۴۶، ۶۵] استخراج ویژگی‌ها [۴۸، ۴۰]، انتخاب ویژگی‌ها [۲۳، ۶، ۵۳، ۲۴، ۱۶] تغییر ویژگی‌ها و طبقه‌بندی [۱۴، ۵۶] است. با این حال، طبقه‌بندی خودکار ضربان‌های نوار قلب یک مسئله دشوار است، زیرا سیگنال‌های نوار قلب دارای ویژگی‌های مورفولوژیکی و زمانی متفاوتی برای بیماران مختلف در شرایط جسمی مختلف هستند.

در این مقاله قصد داریم در مورد طبقه‌بندی سیگنال‌های قلبی با استفاده از روش‌های مبتنی بر منطق فازی و بررسی راهکارهای پذیرفته شده در این حوزه بپردازیم. ساختار مقاله به صورت زیر سازماندهی شده است. در بخش ۲ به بررسی مفاهیم پایه پرداخته می‌شود. در بخش ۳ به تشریح مجموعه داده‌های مشهور حوزه تشخیص تپش قلب می‌پردازیم. در بخش ۴ به تشریح روش‌های موجود دسته‌بندی تپش قلب بر اساس منطق فازی پرداخته می‌شود. در نهایت در بخش ۵ نتیجه‌گیری آورده خواهد شد.

۲ مفاهیم پایه

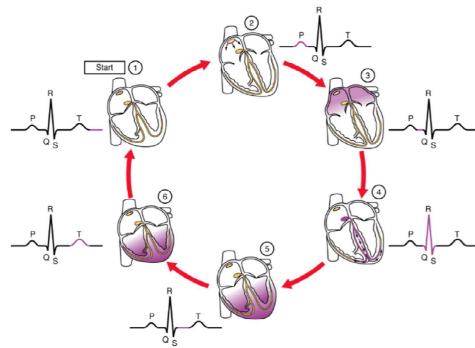
۱.۲ سیگنال‌های نوار قلب

نمونه سیگنال‌های نوار قلب مرتبط با یک چرخه قلبی مشترک در شکل ۲ نشان داده شده است. بخش ۱ شکل ۲ نشان دهنده شروع فرایند چرخه قلب با انقباض گره سینوس دهلیزی که به عنوان یک ضربان‌ساز طبیعی عمل می‌کند، می‌باشد. بخش ۲ شکل ۲ نشان دهنده موج P است. این موج وضعیت فعال شدن دهلیز را نشان می‌دهد که از تجزیه و تحلیل این بخش در تشخیص فلوتردهلیزی^۱ استفاده می‌شود. بخش ۳ از شکل ۲ نشان دهنده قطعه PQ می‌باشد

^۱ Atrial Flutter

که زمان فعال شدن دهلیز تا زمان فعال شدن بطن‌ها را اندازه‌گیری می‌کند. بخش ۴ شکل ۲ نشان دهنده‌ی مجموعه‌ی QRS می‌باشد که از سه موج Q و R و S تشکیل شده است. اولین موج آن کوتاه و به سمت پایین و منفی بوده و مربوط به دپلاریزاسیون^۲

سپتوم^۳ است، موج دوم طولانی و باریک بوده و نشان دهنده‌ی دپلاریزاسیون بطن چپ است، موج سوم کوچک، رو به پایین و منفی بوده و مربوط به دپلاریزاسیون مناطق پایه و عقب بطن چپ می‌باشد. تغییرات این مجموعه حاکی از وجود بیماری‌های قلبی مانند آریتمی، برافروختگی و حمله قلبی است. بخش ۵ از شکل ۲ قطعه‌ی ST را نشان می‌دهد که پس از موج S شروع شده و با موج T پایان می‌یابد. این قطعه مربوط به فاصله‌ی زمانی است که بطن‌ها منقبض شده و به استراحت باز می‌گردند و تجزیه و تحلیل آن می‌تواند مشکلات ایسکمیک^۴ را نشان دهد. بخش ۶ شکل ۲ نشان دهنده‌ی موج T است که بیانگر تغییر مجدد بطن‌ها یا به بیان دیگر نشان دهنده‌ی مدت زمانی است که بطن‌ها مرحله‌ی فعال‌سازی خود را به اتمام رسانده و آماده‌ی انجام انقباض جدید می‌باشند. این موج اطلاعاتی در مورد هیپرتروفی قلب^۵، نارسایی قلبی و بیماری ایسکمیک قلب نشان می‌دهد [۸، ۲۶، ۴۵]



شکل ۱: چرخه‌ی قلبی [۲۶]

نتیجه‌ی این فعالیت‌ها، جریان‌های الکتریکی روی سطح بدن ایجاد می‌شوند و تغییرات

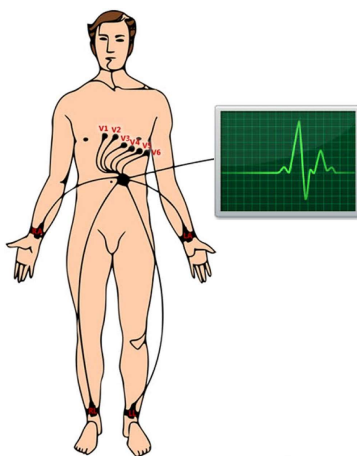
^۲Depolarization

^۳Septum

^۴Ischemic Problems

^۵Hypertrophy

پتانسیل الکتریکی، سطح پوست را تحریک می‌کنند. انتشار سیگنال‌های الکتریکی از الگوهای پیروی می‌کند که با استفاده از الکتروکاردیوگرافی قابل اندازه‌گیری است [۶۲]. الکتروکاردیوگرافی^۶ شامل قرار دادن الکتروود بر روی پوست بیماران است تا هرگونه فعالیت الکتریکی را که قلب آن‌ها در طی مدت زمانی مشخص ایجاد می‌کند، ثبت کند. پیکربندی الکتروودها در الکتروکاردیوگرافی معمولاً حاصل ترکیب ۵ الکتروود به این صورت است که یکی از الکتروودها روی بازوی چپ (LA)^۷، یکی روی بازوی راست (RA)^۸، دیگری در پای چپ (LL)^۹، دیگری روی پای راست (RL)^{۱۰} و دیگری روی سینه، به سمت راست بیرونی (V یا V_۱)^{۱۱} قرار می‌گیرد [۲۹]. روش دیگر اندازه‌گیری روشی است که از ۱۰ الکتروود استفاده می‌کند، که در آن ۵ الکتروود اضافی (علاوه بر V یا V_۱ روی قفسه سینه و LA، RL، LL و RA روی پاها و بازوها) روی قفسه‌ی سینه (V_۲ تا V_۶) قرار می‌گیرد. پیکربندی ۱۰ الکتروود (۱۲ هد) را می‌توان در شکل ۲ مشاهده کرد [۵].



شکل ۲: پیکربندی ۱۰ الکتروود (۱۲ هد) [۵]

^۶Electrocardiography

^۷Left Arm Lead


^۸Right Arm Lead

^۹Left Leg Lead

^{۱۰}Right Leg Lead

^{۱۱}Ventricle

شکل ۳، چهار قسمت از سیگنال نوار قلب معمولی را نشان می‌دهد. این سیگنال شامل یک موج P، یک مجموعه QRS، یک موج T و یک موج U است که همه‌ی آن‌ها دارای الگوهای ظاهری جداگانه‌ای هستند و قابل تشخیص می‌باشند [۴]. عملکرد عالی یک الگوریتم طبقه‌بندی نوار قلب تا حد زیادی به تشخیص دقیق و قابل اعتماد مجموعه QRS، همراه با امواج P و T بستگی دارد [۴۵].



شکل ۳: مشخصات یک پیک از نوار قلب [۴]

۲.۲ بی‌نظمی قلبی

به ریتم غیرطبیعی قلب بی‌نظمی قلبی یا آریتمی گفته می‌شود که به دلیل تغییر در ترتیب طبیعی ضربان‌های الکتریکی قلب اتفاق می‌افتد. بی‌نظمی ممکن است در اتاق‌های فوقانی و تحتانی قلب اتفاق بیفتد و از طرفی بی‌نظمی در بطن‌ها یک تهدید جدی برای زندگی محسوب می‌شود [۵۶]. انواع مختلف بی‌نظمی قلبی عبارتند از:

- (۱) ریتم سینوسی عادی (NSR)^{۱۲} : نمایش ریتم قلب معمولی از گره سینوس منشا می‌گیرد. معمولاً ضربان منظم قلب بسته به ورودی‌ها به گره سینوس ممکن است متفاوت باشد.

¹²Normal Sinus Rhythm

(۲) ضربان های زودرس (Extra) : شایع ترین نوع بی نظمی است که هیچ علائمی ندارد و بی ضرر است. افراد احساس لرز در سینه یا ضربان قلب از دست رفته می کنند. این ضربان ها انقباضات زودرس دهلیزی (PAC) ^{۱۳} و انقباضات زودرس بطن (PVC) ^{۱۴} را تشکیل می دهند.

(۳) بی نظمی فوق بطنی ^{۱۵} : وضعیتی است که در دهلیز با ضربان قلب سریع شروع می شود. انواع مختلفی از بی نظمی فوق بطنی عبارتند از فیبریلاسیون دهلیزی (AF) ^{۱۶} ، فلوتر دهلیزی، تاکی کاردی فوق عروقی پاروکسیسمال (PSVT) ^{۱۷} و سندرم ولف پارکینسون وایت ^{۱۸}.

(۴) بی نظمی بطنی ^{۱۹} : انواع بی نظمی بطنی عبارت است از فلوتر بطنی، تاکی کاردی بطنی (VT) ^{۲۰} ، فیبریلاسیون بطنی (VF) ^{۲۱} . این شرایط تهدیدکننده باید با شوک دفیبریلاتور برای نجات زندگی درمان شود.

(۵) اختلال عملکرد گره سینوس ^{۲۲} : مشکلات مربوط به گره سینوس قلب منجر به ضربان آهسته قلب می شود. افراد مبتلا به این نوع بی نظمی ممکن است به ضربان ساز احتیاج داشته باشند.

(۶) بلوک قلب : این وضعیت ممکن است در گره AV ^{۲۳} یا سیستم HPS ^{۲۴} به دلیل انسداد کامل در مسیر هدایت رخ دهد. ضربان قلب آهسته و نامنظم می شود و ممکن است نیاز به یک ضربان ساز برای درمان باشد.

¹³Premature Atrial Complex

¹⁴Premature Ventricular Contraction

¹⁵Supraventricular Tachycardia

¹⁶Atrial Fibrillation

¹⁷Paroxysmal Supraventricular Tachycardia

¹⁸Wolff Parkinson White

¹⁹Ventricular Arrhythmias

²⁰Ventricular Tachycardia

²¹Ventricular Fibrillation

²²Sinus node Dysfunction

²³Atrioventricular

²⁴His-Purkinje System

(۷) ناهنجاری هدایت عمدتا در سمت چپ یا راست بطن‌ها به نام انسداد شاخه‌ای رشته‌ی راست^{۲۵} (RBBB) یا انسداد شاخه‌ای رشته‌ی چپ^{۲۶} (LBBB) رخ می‌دهد.

۳.۲ منطق فازی

مفهوم و مطالعه در مورد منطق فازی از سال ۱۹۲۰ آغاز شد ولی عبارت منطق فازی اولین بار توسط پروفسور لطفی عسگرزاده (۱۹۲۱-۲۰۱۷) در سال ۱۹۶۵ در دانشگاه برکلی به کار رفت [۶۸]. ایشان با توجه به منطق به کار رفته در دستگاه‌های دیجیتال، متوجه شد که این دستگاه‌ها توانایی شبیه‌سازی تفکرات و ایده‌های ذهن انسان را دارا نیستند و نمی‌توانند مانند انسان فکر کنند، زیرا منطق دیجیتال برای هر تصمیم فقط دو وضعیت درست (True) و غلط (False) را در نظر می‌گیرد، در حالی که تفکر انسانی درجاتی از درستی یا نادرستی را برای تصمیم محسوب می‌کند. می‌توان رویکرد منطق فازی را به شکلی تصور کرد که به جای در نظر گرفتن دو وضعیت مثلا سیاه یا سفید، طیفی از رنگ خاکستری را جایگزین کرد که از یک طرف به رنگ سفید و از طرف دیگر به رنگ سیاه محدود می‌شود. در حوزه‌های مختلفی مانند هوش مصنوعی و نظریه کنترل [۳۴] از منطق فازی استفاده می‌شود. بنابراین با استفاده از منطق فازی در این زمینه‌ها، رایانه‌ها قادر هستند براساس داده‌های غیرقطعی و غیرصریح، محاسبات و تصمیم‌سازی کنند [۱۵]. یک سیستم استنتاج فازی دارای چهار بخش اصلی است که در شکل ۴ نحوه ارتباط این بخش‌ها به خوبی دیده می‌شود.

قوانین پایه: این بخش، شامل همه قاعده‌ها و شرایطی است که به صورت «اگر...آنگاه» توسط یک متخصص مشخص شده‌اند تا قادر به کنترل تصمیمات یک سیستم تصمیم‌گیری^{۲۷} باشند. با توجه به روش‌های جدید در نظریه فازی، امکان تنظیم و کاهش قواعد و قوانین بوجود آمده است به طوری که با کمترین قوانین می‌توان بهترین نتیجه را گرفت.

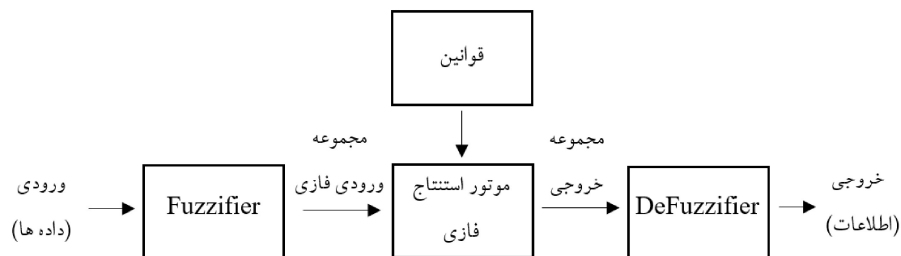
فازی سازی^{۲۸} : در گام فازی سازی، ورودی‌ها به اطلاعات فازی تبدیل می‌شوند. به این

^{۲۵}Right Bundle Branch Block

^{۲۶}Left Bundle Branch Block

^{۲۷}Decision-making system

^{۲۸}Fuzzifier



شکل ۴: چهار بخش اصلی یک سیستم استنتاج فازی [۴۱]

معنی که اعداد و ارقام و اطلاعاتی که باید پردازش شوند، به مجموعه‌ها و اعداد فازی تبدیل خواهند شد. داده‌های ورودی که مثلا توسط حسگرها در یک سیستم کنترل، اندازه‌گیری شده‌اند، به این ترتیب تغییر یافته و برای پردازش بر مبنای منطق فازی آماده می‌شوند.

موتور استنتاج یا هوش: در این بخش، میزان انطباق ورودی‌های حاصل از فازی سازی با قوانین پایه مشخص می‌شود. به این ترتیب بر اساس درصد انطباق، تصمیمات مختلفی به عنوان نتایج حاصل از موتور استنتاج فازی تولید می‌شود.

برگرداندن از فازی^{۲۹}: در آخرین مرحله نیز نتایج حاصل از استنتاج فازی که به صورت مجموعه‌ها فازی هستند به داده‌ها و اطلاعات کمی و رقمی تبدیل می‌شوند. در این مرحله با توجه خروجی‌ها که شامل تصمیمات مختلف به همراه درصدهای انطباق‌های متفاوتی هستند، بهترین تصمیم‌ها انتخاب می‌شود. معمولا این انتخاب بر مبنای بیشترین میزان انطباق خواهد بود [۴۱].

۳ مجموعه داده‌های سیگنال‌های نوار قلب

۱.۳ بانک اطلاعاتی بی‌نظمی MIT-BIH [۴۶]

این بانک اطلاعاتی شامل ۴۸ پرونده از سیگنال‌های نوار قلب دو کاناله به مدت ۳۰ دقیقه به دست آمده از ۴۷ فرد بین سال‌های ۱۹۷۵ و ۱۹۷۹ در آزمایشگاه بی‌نظمی قلبی BIH است. بیست و پنج مرد از ۳۲ تا ۸۹ سال و بیست و دو زن در سن ۲۳ تا ۸۹ سال انتخاب شدند. این

²⁹DeFuzzifier

بانک اطلاعاتی شامل ۱۱۶۱۳۷ تعداد مجموعه‌ی QRS است. سیگنال‌های نوار قلب با فرکانس ۳۶۰ نمونه در ثانیه با وضوح ۱۱ بی‌تی با دامنه ۱۰ میلی‌ولت و باند عبور شده در ۱۰۰ - ۰/۱ هرتز فیلتر شدند. این مجموعه داده شامل ضربان‌های مختلفی از جمله ضربان معمولی، RBBB، LBBB، ضربان‌های زودرس دهلیزی (APB) ۳۰ و مجتمع بطن زودرس (PVC) سیگنال‌های ضبط شده‌است که در جدول ۱ خلاصه می‌شوند.

۲.۳ بانک اطلاعاتی بی‌نظمی (Creighton University) CU [۵۰]

بانک اطلاعاتی CU شامل ۳۵ پرونده ۸ دقیقه‌ای از بیماران مبتلا به تاکی‌کاردی بطنی، فلوتر بطنی و فیبریلاسیون بطنی است. سیگنال‌ها با فرکانس ۲۵۰ هرتز با وضوح ۱۲ بی‌تی با دامنه ۱۰ میلی‌ولت دیجیتالی شده و با Low-Pass Bessel Aecond-order Active فیلتر می‌شوند.

۳.۳ بانک اطلاعاتی بی‌نظمی (American Heart Association) AHA [۲۲]

بانک اطلاعاتی AHA شامل ۸۰ رکورد دو کانال است. سیگنال‌ها با فرکانس ۲۵۰ هرتز با وضوح ۱۲ بی‌تی با دامنه ۱۰ میلی‌ولت دیجیتالی می‌شوند.

۴.۳ بانک اطلاعاتی بی‌نظمی European ST-T [۶۳]

بانک اطلاعاتی ST-T اروپا شامل ۹۰ پرونده‌ی دو ساعته ۷۹ بیمار است. سیگنال‌ها با فرکانس ۲۵۰ هرتز با وضوح ۱۲ بی‌تی با برد ۲۰ میلی‌ولت نمونه برداری می‌شوند.

۵.۳ بانک اطلاعاتی بی‌نظمی QT [۳۶]

بانک اطلاعاتی QT شامل ۱۰۵ رکورد پانزده دقیقه‌ای دو کانال است. سیگنال‌ها با فرکانس ۲۵۰ هرتز نمونه برداری می‌شوند و طبق استاندارد انجمن پیشرفت پزشکی (AAMI)، ضربان‌های بی‌نظمی قلبی در ۵ کلاس N، S، V، F و Q تقسیم می‌شوند.

³⁰Atrial Premature Beats

³¹Premature Ventricular Contraction

جدول ۱: توزیع انواع مختلف بی‌نظمی‌های قلبی در رکوردهای مجموعه داده‌های MIT-BIH [۵۶]

نوع	رکورد
ضربان نرمال	۲۳۴، ۲۳۰، ۲۱۹، ۲۰۵، ۲۰۲، ۱۲۳، ۱۲۲، ۱۲۱، ۱۱۷، ۱۱۵، ۱۱۴، ۱۱۳، ۱۱۲، ۱۰۸، ۱۰۵، ۱۰۳، ۱۰۱، ۱۰۰
ضربان LBBB	۲۱۴، ۲۰۷، ۱۱۱، ۱۰۹
ضربان RBBB	۲۳۱، ۲۱۲، ۱۲۴، ۱۱۸
ضربان PVC	۲۳۳، ۲۲۸، ۲۲۱، ۲۱۳، ۲۰۸، ۲۰۳، ۲۰۱، ۲۰۰، ۱۱۹، ۱۱۶، ۱۰۶
ضربان APB	۲۳۲، ۲۲۳، ۲۲۲، ۲۲۰، ۲۰۹

۴ طبقه‌بندی سیگنال‌های نوار قلب با منطق فازی

همانطور که در شکل ۵ نشان داده شده است، یک طبقه‌بندی عملی نوار قلب فازی معمولاً از دو بلوک عملکرد اصلی تشکیل شده است: استخراج پارامتر از سیگنال‌های قلب^{۳۲} و طبقه‌بندی کننده فازی. اولین بلوک عملکرد برای تشخیص ویژگی‌ها و پارامترهای مهم از نوار قلب استفاده می‌شود. پارامترهای به دست آمده از جمله دامنه و مدت زمان برای طبقه‌بندی نوار قلب به بلوک عملکرد دوم منتقل می‌شوند. روش فازی برای آنالیز بالینی بسیار مؤثر و کاربردی است. در واقع روش‌های بسیاری بر اساس منطق فازی و ترکیب منطق فازی با سایر منطق‌ها برای طبقه‌بندی بی‌نظمی‌های نوار قلب وجود دارد. برای طبقه‌بندی بی‌نظمی‌های نوار قلب با استفاده از طبقه‌بندی فازی، برخی از الگوهای نوار قلب و متغیرهای زبانی مورد نیاز است که در جدول ۲ نشان داده شده است.


اولین مرحله در الگوریتم‌های طبقه‌بندی آماده‌سازی داده‌ها است. ورودی‌های لازم برای طبقه‌بندی، مجموعه‌های PQRST هستند که بر اساس روش‌های مختلفی که برای تشخیص این نقاط در دنباله‌ای از سیگنال‌های قلب وجود دارد [۲۳، ۳۱، ۳۷، ۶۶] تشخیص داده شده و به عنوان داده‌ی ورودی به طبقه‌بند ارسال می‌شوند که تعداد آن‌ها به ظرفیت مجموعه داده‌های مورد استفاده و تعداد ویژگی‌ها به الگوریتم تشخیص مورد استفاده بستگی دارد. در مرحله‌ی آماده‌سازی، مجموعه‌های PQRST از ورودی خوانده شده و ویژگی‌های آن‌ها با توجه به جدول ۲ استخراج می‌شود و متغیرهای زبانی^{۳۳} تولید می‌شوند. در ادامه توابع عضویت^{۳۴} در مرحله‌ی فازی‌سازی

³²Parameterize ECG

³³Linguistic Variable

³⁴Membership Function

تولید می‌شوند. خروجی به صورت متغیرهای فازی خواهد بود که به این ترتیب به یک مرحله‌ی برگردان فازی نیاز است تا متغیرهای فازی را به عنوان ورودی دریافت کند و متغیرهای واضح را تولید کند. پس از مرحله‌ی فازی‌سازی، ویژگی‌ها به صورت درجه عضویت بین 0 تا 1 بیان می‌شوند. روش استنباط از قاعده‌ی If-Then استفاده می‌کند. به عنوان مثال برای بیماری LBBB، موج T و مجموعه‌ی QRS خلاف جهت یکدیگر هستند و ضربان قلبی یا PR کوتاه بوده و موج p مشاهده نمی‌شود. به این ترتیب طبقه‌بندی نوع LBBB به صورت زیر تعریف می‌شود: اگر جهت موج T به سمت بالا ^{۳۵} باشد و جهت مجموعه‌ی QRS نیز به سمت بالا باشد و موج P مشاهده نشده باشد و ضربان قلب قبلی یا RR کوتاه باشد آنگاه نوع بیماری تشخیص داده شده LBBB خواهد بود.



شکل ۵: ساختار طبقه‌بند فازی سیگنال‌های قلبی

در این قانون متغیرهای زبانی شامل به سمت بالا ^{۳۶}، به سمت پایین ^{۳۷}، مشاهده نشده ^{۳۸} و کوتاه ^{۳۹} است. نتیجه‌ی تابع عضویت که یک عدد بین 0 و 1 است، به عنوان فرضیه در نظر گرفته می‌شود و در ادامه اگر مقدار آن از یک محدوده‌ی مشخصی بیشتر باشد، ضربان نوع LBBB تشخیص داده می‌شود [۳۸].

محققان و دانشمندان روش‌های بسیاری را برای طبقه‌بندی بی‌نظمی‌های نوار قلب ارائه داده اند. به عنوان مثال، طبقه‌بندی فازی [۱۱]، شبکه‌ی عصبی موجک [۱]، بهبود عملکرد طبقه‌بندی

^{۳۵}Upward

^{۳۶}Upward

^{۳۷}Downward

^{۳۸}Disappeared

^{۳۹}Small

جدول ۲: ویژگی های ضربان قلب و متغیرهای زبانی مربوطه [۳۸]

متغیرهای زبانی	ویژگی های نوار قلب
Short; Normal; Long	ضربان قلب قبلی (RR^0)
Short; Normal; Long	ضربان قلب بعدی (RR^1)
Early; Normal; Disappear	موج p
Upward; Downward	مجموعه QRS
High; Normal; Low	موج R
Upward; Downward; Disappear	موج T

استخراج ویژگی های خطی [۵۲]، بعد همبستگی و بزرگترین نماینده لیاپونوف [۲۷]، تبدیل موجک و روش فواصل زمانی [۴۸]، الگوریتم های طبقه بندی چند سیگنال [۲۸] و شکل کارآمد ترکیب ویژگی های تبدیل موجک مورفولوژیکی به همراه ویژگی های دنباله ای زمانی سیگنال نوار قلب [۴۴]. تحقیقات انجام شده روش های بی شماری را برای طبقه بندی سیگنال های نوار قلب مانند ماشین های بردار پشتیبان برای تشخیص ضربان قلب ایجاد کرده اند [۳۰، ۳۳، ۶۱]، شبکه عصبی مصنوعی (ANN) ^{۴۰} [۲، ۳]، تکنیک افتراق دهنده ی خطی فیشر (FLDA) ^{۴۱} [۱۸]، توابع هرمیت و نقشه خود سازمان یافته [۳۵]، مدت ضربان های قلب همراه با شکل و خصوصیات مورفولوژیکی پارامترهای آن [۱۲]، الگوریتم استفاده از چندین لید، مبتنی بر مشاهده ی تضادفی ویژگی ها [۹]، تجزیه و تحلیل توسط تبدیل هیلبرت [۷، ۵۱] ماشین یادگیری افراطی [۳۲]، درخت مدل لجستیک [۴۲]، مدل مخلوط گاوسی [۴۳] و نیز برخی از مدل ها وجود دارند که بر اساس ترکیب و همبستگی روش های ذکر شده در بالا ایجاد شده اند و در بسیاری از موارد روش های ترکیبی نتیجه بهتری نسبت به سایر روش ها نشان داده اند.

۱.۴ طبقه بندی کننده ی فازی سازگار

با استناد بر نتایج حاصل از تحقیقات انجام شده، استفاده از طبقه بند فازی سازگار برای طبقه بندی سیگنال های قلب بسیار کاربردی بوده و نتایج دقیقی بدست آورده است. به منظور بهینه سازی

⁴⁰ Artificial Neural Networks

⁴¹ Fisher's Linear Discriminant Analysis

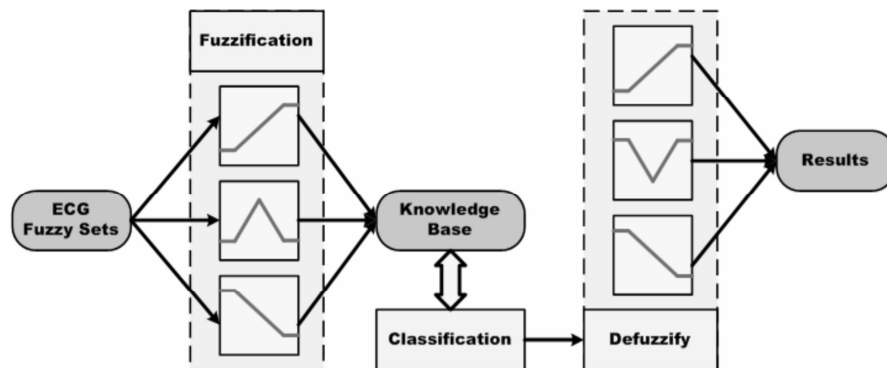
پارامترهای سیستم نظیر مقادیر آستانه و مرزهای عضویت، این سیستم به یک مرحله یادگیری نیاز دارد. مقادیر حاشیه در تابع عضویت تقریباً در مرحله‌ی یادگیری ثابت هستند و از یک مجموعه قانون از پیش تعریف شده برای طبقه‌بندی مناسب ضربان‌های قلب استفاده می‌شود. این مقادیر در تابع عضویت با استفاده از مقادیر حاشیه‌ی ضربان‌های از پیش طبقه‌بندی شده سفارشی می‌شوند. در طبقه‌بندی سیگنال‌های قلبی فازی، تابع عضویت در اصل از دانش پزشکی و مجموعه داده‌های پزشکی حاصل می‌شود. از این رو قابل پیش‌بینی است که کارایی تابع عضویت ثابت هنگامی که به بخش‌های خاص سیگنال‌های قلب گسترش یابد کاهش می‌یابد. بنابراین برای موفقیت برنامه‌های کاربردی در زندگی واقعی، سازگاری باید یک مرحله‌ی ضروری از هر طبقه‌بند سیگنال‌های قلبی فازی باشد [۲۰]. در حقیقت به خوبی قابل مشاهده است که تعمیم و سازگاری به عنوان دو گام ضروری برای هر سیستم هوشمند عمل می‌کند. یک سیستم هوشمند درست اغلب با تعمیم^{۴۲} و خودسازگاری^{۴۳} با برنامه خاص ایجاد می‌شود. در استفاده از طبقه‌بندی‌کننده‌های فازی برای تجزیه و تحلیل سیگنال‌های قلب، پارادایم مبتنی بر محاسبات عصبی برای خودسازگاری توصیه می‌شود. با این وجود برای یادگیری و بروزرسانی به مجموعه‌ای از مجموعه داده‌های مستقل نیاز است که متأسفانه برای طبقه‌بندی‌کننده‌های فازی استفاده شده در زیست‌پزشکی غیرممکن است. در نتیجه روش خودسازگاری آنلاین براساس تئوری یادگیری آماری پیشنهاد شده است. ساختار چنین طبقه‌بند کننده‌ی سیگنال‌های قلبی فازی سازگار (AFC-ECG)^{۴۴} در شکل ۶ نشان داده شده است.

قبل از خودسازگاری، تمام پارامترها مطابق با دانش پزشکی به عنوان مقادیر پیش‌فرض تنظیم می‌شوند. چنین سیستم پیش‌فرضی برای مدتی اجرا می‌شود. سپس AFC-ECG سعی می‌کند خود را با داده‌های مشاهده شده تطبیق دهد. پس از سازگاری دوباره برای مدتی اجرا خواهد شد. AFC-ECG طبقه‌بندی فازی را در مبدل‌های زیست‌پزشکی انجام می‌دهد در حالی که خودسازگاری در سرورهای مرکزی انجام می‌شود [۳۸]. ترکیبی از قابلیت‌های انطباقی شبکه‌ی عصبی و سیستم استنتاج فازی دقت بیش از ۹۷٪ [۶۳] و ۹۶٪ [۵۸] را نشان داده است.

⁴²Generalization

⁴³Self Adaptation

⁴⁴Adaptive Fuzzy Classifier



شکل ۶: نمودار طبقه بندی سیگنال های قلبی با استفاده از طبقه بندی های فازی سازگار Adaptive Fuzzy Classifier [۳۸]

۲.۴ خوشه بندی C-Means فازی

خوشه بندی داده ها برای یافتن شباهت در داده ها استفاده می شود و داده های مشابه را در گروه های مشابه قرار می دهد [۱۷]. FCM^{۴۵} روشی فازی است که با الگوریتم خوشه بندی داده ها سروکار دارد و به طور گسترده مورد استفاده قرار گرفته شده است. این الگوریتم در ابتدا توسط دوون^{۴۶} [۴۳] معرفی شد و بعداً در سال ۱۹۸۱ توسط بزdek^{۴۷} گسترش یافت [۸].

در این فرایند، هر نقطه از داده ها بر حسب مقدار درجه ی عضویت به یک خوشه خاص تعلق می گیرد. الگوریتم FCM چهار مرحله دارد. در ابتدا ماتریس عضویت با مقادیر دلخواه بین ۰ تا ۱ مقداردهی می شود و سپس مراکز خوشه ای فازی مشخص می شوند و در ادامه تابع هزینه محاسبه می شود. در نهایت محاسبات در صورت کاهش مقدار آن از یک آستانه ی مشخص شده متوقف می شود. همچنین اگر پیشرفت آن در تکرار قبلی کمتر از یک آستانه مشخص باشد، باید محاسبه به پایان برسد. به این ترتیب یک ماتریس عضویت جدید محاسبه می شود و در نهایت مراکز خوشه ای فازی یک بار دیگر محاسبه می شوند. همایی نژاد و دوستان [۲۵] توانسته اند با استفاده

⁴⁵Fuzzy C-Means

⁴⁶Donn

⁴⁷Bezdek

جدول ۳: نتایج طبقه‌بندی فازی مبتنی بر خوشه‌بندی FCM [۵۵]

Sensitivity	Prediction Positive	Accuracy	Type
۹۹/۶۶%	۹۶/۷۶%	۹۷/۴۱%	Normal
۹۶/۳۳%	۹۸/۲۹%	۹۷/۴۱%	LBBB
۹۸/۶۶%	۹۵/۷۹%	۹۷/۴۱%	RBBB
۹۵/۰۰%	۹۸/۹۵%	۹۷/۴۱%	PB

از طبقه‌بندی‌کننده‌ی فازی FCM و تکنیک خوشه‌بندی کاهشی^{۴۸} به دقت ۹۷/۴۷ درصد در طبقه‌بندی سیگنال‌های قلبی با استفاده از مجموعه داده MIT-BIH برسند، که می‌تواند به عنوان یک عملکرد عالی برای طبقه‌بندی بی‌نظمی‌های نوار قلب در نظر گرفته شود.

روپا^{۴۹} و دوستان [۵۵] ساختار RSKFCM^{۵۰} را ارائه دادند که با استفاده از روش انتخاب ویژگی RLP^{۵۱} [۱۰] توانستند به دقت ۹۰/۳۵ درصدی در طبقه‌بندی سیگنال‌های قلب برسند. در ادامه روپا و دوستان [۵۴] یک الگوریتم خوشه‌بندی بدون نظارت اصلاح شده جدید را برای تشخیص دقیق بیماری‌های قلبی ارائه دادند. برای انتخاب بهترین ویژگی برای یادگیری بهتر از روش‌های انتخاب ویژگی مانند تحلیل مولفه‌های اصلی^{۵۲}، تحلیل خطی تبعیض‌آمیز^{۵۳} و نمایه‌سازی حفظ محلیت تنظیم شده^{۵۴} استفاده کرده‌اند. مجموعه‌ای از ویژگی‌های کاهش یافته با استفاده از روش خوشه‌بندی C-Means فازی بصری اصلاح شده (MIFCM)^{۵۵} خوشه‌بندی می‌شوند. آن‌ها توانستند با استفاده از روش انتخاب ویژگی RLPI به دقت ۹۵/۳۶ درصد در طبقه‌بندی سیگنال‌های قلب برسند.

قاریب^{۵۶} و دوستان [۲۱] روشی برای تشخیص انقباض بطن زودرس (PVC) در سیگنال

⁴⁸Subtractive Clustering

⁴⁹Ropa

⁵⁰Robust Spatial Kernel Fuzzy C-Means

⁵¹Regularized Locality Preserving Indexing

⁵²Principal Component Analysis

⁵³Linear Discriminative Analysis

⁵⁴Regularized Locality Preserving Indexing

⁵⁵Modified Intuitionistic Fuzzy C-Means Clustering

⁵⁶Gharieb

الکتروکاردیوگرام ارائه داده‌اند. در این مقاله روش حداقل فاصله (MD) ^{۵۷} و تحلیل خطی تبعیض آمیز در یک فضای ویژگی پیشنهادی برای طبقه‌بندی به کار گرفته شده است. این ویژگی‌ها توسط تبدیل موجک پیوسته سیگنال ضربان نوار قلب و به دنبال آن توسط اپراتور TKE ^{۵۸} استخراج می‌شوند. نمونه‌های اولیه کلاس‌های مختلف در فضای ویژگی با استفاده از الگوریتم خوشه‌بندی C-Means فازی (FCM) تولید می‌شوند. برای آزمایش روش پیشنهادی، از بانک اطلاعاتی بی‌نظمی MIT-BIH استفاده شده است. این روش موفق به بدست آوردن دقت % ۱۰۰ در طبقه‌بندی ضربان‌های نرمال و PVC با طبقه‌بندی کننده MD شده است.

۳.۴ ماشین بردار پشتیبان فازی

اصل اساسی ماشین‌های بردار پشتیبان که توسط وپنیک ^{۵۹} [۱۳] پیشنهاد شده است، شناسایی یک جداساز خطی است که میزان خطای طبقه‌بندی را به حداقل می‌رساند در حالی که حداکثر حاشیه را بین کلاس‌ها بعد از قراردادن نمونه‌های آموزشی در یک فضای ویژگی چندبعدی برقرار می‌کند. تشخیص یک جداساز خطی بهینه در فضای ورودی دشوار است، بنابراین با نگاشت بردار ورودی به یک فضای ویژگی چندبعدی امکان شناسایی جداساز خطی مطلوب را فراهم می‌کنیم. تعداد برنامه‌هایی که از SVM ^{۶۰} استفاده می‌کنند همچنان در حال افزایش است. اما ممکن است برخی از داده‌های ورودی دقیقاً به یکی از دو کلاس مورد نظر اختصاص داده نشوند. برای برخی از داده‌ها بسیار مهم است که به یک کلاس واحد اختصاص داده شوند تا SVM بتواند به طور صحیح این نقاط را از هم جدا کند، در حالی که سایر نقاط داده از بین رفته توسط نویز ارزش کمتری دارند و بهتر است از آن‌ها صرف نظر کرد. SVM فاقد این نوع توانایی تبعیض آمیز است. از این رو یک طرح عضویت فازی برای آموزش داده‌های SVM اعمال می‌شود و SVM را به FSVM ^{۶۱} تبدیل می‌کند به گونه‌ای که نقاط ورودی مختلف می‌توانند در یادگیری سطح تصمیمات سهم متفاوتی داشته باشند. روش FSVM طیف وسیعی از مقادیر عضویت فازی را که برای تولید توابع

⁵⁷Minimum Distance

⁵⁸Teager Kiaser Energy

⁵⁹Vapnik

⁶⁰Support Vector Machine

⁶¹Fuzzy Support Vector Machine

عضویت ضروری هستند، اختصاص می‌دهد. برای محاسبه درجه‌ی عضویت، توابع عضویت سنتی استفاده می‌شود. همچنین توابع عضویت خاص داده نیز می‌توانند مورد استفاده قرار بگیرند. به منظور تخصیص درجه‌ی عضویت، از چهار تابع استفاده می‌شود که شامل یک کلاس Weighing (OCW) ^{۶۲}، میانگین فاصله از کلاس تا کلاس (DTCM) ^{۶۳}، فاصله تا یک کلاس میانگین (DTCM) ^{۶۴}، کاردینالیته (CAR) ^{۶۵} و طبقه بند C-Means فازی (FCM) ^{۶۶} است. برای تسهیل در کاهش ابعاد، چهار تکنیک مورد استفاده قرار می‌گیرد که شامل تجزیه و تحلیل مؤلفه‌های اصلی (PCA) ^{۶۷}، تجزیه و تحلیل عاملی (FA) ^{۶۸}، حذف ویژگی بازگشتی با ماشین بردار پشتیبان (RFE-SVM) ^{۶۹} و انتخاب ویژگی همبستگی (CFS) ^{۷۰} است [۶۷، ۷۰].

نمونه‌ی استفاده از ماشین بردار پشتیبان فازی برای طبقه‌بندی سیگنال‌های قلب مقاله لیبی ^{۷۱} و دوستان [۶۱] است که به دقت ۹۹/۴۲ درصد با درجه تابع عضویت فازی ۲۸ برای طبقه‌بندی سیگنال‌های نرمال و دقت ۹۸/۷۸ درصد با درجه تابع عضویت ۵۰ برای طبقه‌بندی سیگنال‌های VT یا تاکی‌کاردی بطنی و دقت ۹۹/۷۹ درصد با درجه تابع عضویت ۵ برای طبقه‌بندی سیگنال‌های فیبریلاسیون بطنی یا VF رسیده است.

۴.۴ ترکیب تبدیل موجک و شبکه‌ی عصبی فازی برای تشخیص انقباض زودرس بطن

شیو ^{۷۲} و همکاران [۶۰] یک روش برای تشخیص انقباض زودرس بطنی مبتنی بر ترکیب تبدیل موجک و شبکه‌ی عصبی فازی پیاده‌سازی کردند، مزیت اصلی آن استفاده‌ی مجدد از اطلاعاتی بود

⁶²One Class Weighing

⁶³Distance to Class Mean

⁶⁴Distance to One Class Mean

⁶⁵Cardinality

⁶⁶Fuzzy C-Means

⁶⁷Principal Component Analysis

⁶⁸Factor Analysis

⁶⁹Recursive Feature Elimination with Support Vector Machine

⁷⁰Correlation-based Feature Selection

⁷¹Lee

⁷²Shyu

جدول ۴: نتایج بدست آمده از روش های پیشنهادی [۴۷]

روش	دقت
PCA	۸۶٫۷٪
GPCA	۹۰٪
ICA	۹۱٪
GICA	۹۳٫۳٪
FGPCA	۹۴٫۴٪
FGICA	۹۴٫۷٪

که هنگام تشخیص مجموعه ی QRS بدست می آمد که یک گام ضروری برای الگوریتم های طبقه بندی سیگنال قلب برای تشخیص انقباض زودرس بطنی به حساب می آید. از جمله سایر ویژگی های این روش استفاده از موجک مشابه برای تشخیص مجموعه ی QRS و طبقه بندی انقباض زودرس بطن برای کاهش محاسبات و پیچیدگی و زمان اجرا می باشد. در نهایت توانستند با استفاده از این روش به دقت ۹۹٫۷۹٪ در تشخیص انقباض زودرس بطنی دست پیدا کنند.

۵.۴ تجزیه و تحلیل مولفه های اصلی و مولفه های مستقل مبتنی بر سیستم فازی ژنتیکی

مورگان و همکاران [۴۷] یک نسخه ی بهبود یافته از آنالیز مولفه های اصلی (PCA) و آنالیز مولفه های مستقل (ICA) به منظور استخراج ویژگی برای طبقه بندی سیگنال های ایسکمیک از سیگنال های قلبی ارائه دادند. در این روش الگوریتم فازی K-Means و ژنتیک با PCA و ICA به منظور استخراج ویژگی های مرتبط ترکیب شده و روش های پیشنهادی FGPCA^{۷۳} و FGICA^{۷۴} نامگذاری شده اند. در ادامه برای طبقه بندی سیگنال ها به دو دسته ایسکمیک و غیر ایسکمیک با استفاده از ویژگی های بدست آمده از FGPCA و FGICA از LSSVM^{۷۵} استفاده شده است. مقایسه ی دقت حاصل از روش های ارائه شده بر روی مجموعه داده های ST-T اروپا [۴۰] شامل ۲۰۴۰ ضربان استخراج شده از ۱۷ بیمار مختلف در جدول ۴ نشان داده شده است.

⁷³Fuzzy-Genetic based PCA

⁷⁴Fuzzy-Genetic based ICA

⁷⁵Least Square Support Vector Machine

۶.۴ سیستم استنتاج عصبی فازی تطبیقی

نزمی^{۷۶} و دوستان [۴۹] یک روش مبتنی بر سیستم استنتاج عصبی فازی تطبیقی ANFIS^{۷۷} برای طبقه‌بندی سیگنال‌های قلبی ارائه دادند. در این روش استخراج ویژگی‌ها با استفاده تجزیه و تحلیل مولفه‌های مستقل^{۷۸} و طیف توان^{۷۹} و فاصله‌ی RR^{۸۰} انجام شده و سپس به عنوان بردار ورودی به طبقه‌بند ANFIS فرستاده می‌شود. نتایج بدست آمده حاکی از آن است که این سیستم قادر به تشخیص ریتم سینوسی طبیعی، انقباض زودرس بطنی، انقباض زودرس دهلیزی، تاکی‌کاردی بطنی، فیبریلاسیون بطنی و تاکی‌کاردی با دقت بالای ۹۷٪ می‌باشد.

پاراتانا^{۸۱} و دوستان [۵۹] یک رویکرد مبتنی بر سیستم استنتاج عصبی فازی تطبیقی برای طبقه‌بندی سیگنال‌های قلبی به سه طبقه‌ی ضربان عادی، ضربان بلوک شاخه بسته‌ی چپ، انقباض بطن زودرس ارائه دادند. در این رویکرد ویژگی‌های مهم با استفاده از ترکیب ویژگی‌های مورفولوژیکی و آماری تشخیص داده می‌شوند و در نهایت به طبقه‌بند ANFIS برای طبقه‌بندی ارسال می‌شوند. نتایج بدست آمده نشان دهنده‌ی دقت ۹۶٪ این سیستم در طبقه‌بندی سیگنال‌های قلب می‌باشد.

۵ نتیجه‌گیری

این مقاله با هدف تمرکز بر توسعه موفق و بررسی روال پیشرفت در انواع روش‌های مبتنی بر منطق فازی در طبقه‌بندی بی‌نظمی‌های قلبی انجام شده و ارزیابی کارایی و دقت و همچنین مبانی نظری این تکنیک‌ها ارائه شده است. نتایج بدست آمده نشان می‌دهد که ترکیب منطق فازی با سایر روش‌ها بطور قابل توجهی کارایی بهتری نسبت به تکنیک‌های غیرترکیبی برای طبقه‌بندی بی‌نظمی‌های سیگنال‌های قلب دارد. بسیاری از روش‌های دیگری نیز وجود دارند که با

⁷⁶Nazmy

⁷⁷Adaptive Neuro-Fuzzy Inference System

⁷⁸Independent Component Analysis

⁷⁹Power Spectrum

⁸⁰RR Interval

⁸¹Prarthana

منطق فازی ترکیب نشده اند، در حالی که ترکیب آن ها با منطق فازی نیز توسط محققان پیشنهاد شده است.

مراجع

- [1] Acharya, R., Suri, J. S., Spaan, J.A.E., Krishnan, S. M. (2007). Advances in Cardiac Signal Processing. *Springer Berlin Heidelberg New York*, 13, 327-338.
- [2] Anuradha, B., Reddy, V. C. V., (2008). ANN for classification of cardiac arrhythmias, *ARPJ Journal of Engineering and Applied Sciences*.
- [3] Asl, B. M. Z., Setarehdan S. K., (2006). Neural Network Based Arrhythmia Classification Using Heart Rate Variability Signal. *Proceedings of the 2nd International Symposium on Biomedical Engineering, Bangkok, Thailand*, 149-162.
- [4] Balaskas, K., Siozios, K. (2019). ECG Analysis and Heartbeat Classification Based on Shallow Neural Networks, *8th International Conference on Modern Circuits and Systems Technologies (MOCASST)*, 1-4.
- [5] Barill, T. (2003). The Six Second ECG: A Practical Guidebook to Basic ECG Interpretation. *nursecom*.
- [6] Bayati, H., Dowlatshahi, M. B., Paniri, M. (2020). MLPSO: A Filter Multi-label Feature Selection Based on Particle Swarm Optimization. *25th International Computer Conference, Computer Society of Iran (CSICC)*, 1-6.
- [7] Benitez, D., Gaydecki, P. A., Zaidib, A., Fitzpatrick, A.P. (2001). The use of the Hilbert transform in ECG signal analysis. *Computers in Biology and Medicine*, 31, 399-406.

- [8] Bezdek, J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*. 2013.
- [9] Bogdanova, I., Rinc', F., Atienza, D. (2012). A Multi-lead ECG Classification Based On Random Projection Features. *IEEE Xplore*, 2012, 625-628.
- [10] Cai, D., He, X., Zhang, W.V., Han, J. (2007). Regularized locality preserving indexing via spectral regression, *sixteenth ACM conference on Conference on information and knowledge management*, ACM, 741–750.
- [11] Channappa B., Satish T., Hamde, Laxman M., Waghmare (2011). ECG Acquisition and Analysis System for Diagnosis of Heart Diseases. *Sensors & Transducers Journal*, 133, 18-29.
- [12] Chazal, P.De., O'Dwyer, M., Reilly, R.B. (2004) Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features. *IEEE Transaction on Biomedical Engineering*, 51, 1196- 1206.
- [13] Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–2970.
- [14] Dowlatshahi, M.B., Derhami, V., Nezamabadi-pour, H. (2018). A Novel Three-Stage Filter-Wrapper Framework for miRNA Subset Selection in Cancer Classification. *Informatics*, 5, 13.
- [15] Dowlatshahi, M.B., Derhami, V., Nezamabadi-pour, H. (2019). Fuzzy particle swarm optimization with nearest-better neighborhood for multimodal optimization. *Iranian Journal of Fuzzy Systems*.

- [16] Dowlatshahi, M.B., Derhami, V., Nezamabadi-pour, V. (2017). Ensemble of Filter-Based Rankers to Guide an Epsilon-Greedy Swarm Optimizer for High-Dimensional Feature Subset Selection. *Information*, 8, 152.
- [17] Dowlatshahi, M.B., Nezamabadi-pour, H. (2014). GGSA: A Grouping Gravitational Search Algorithm for data clustering. *ScienceDirect*, 36, 114-121.
- [18] Duin, R.P.W., Loog, M. (2004). Linear dimensionality reduction via a heteroscedastic extension of lda: the chernoff criterion. *IEEE Trans*, 26, 732-739.
- [19] Dunn, J. C. (1974) A Fuzzy Relative of the ISODATA Process and its Use in Detecting Compact Well Separated Clusters. *Journal of Cybernetics*, 3, 32-57.
- [20] Farhan, A., Wei, CL., Ahmed, MT. (2018). A Qualitative Overview of Fuzzy Logic in ECG Arrhythmia Classification, *Semantic Scholar*, 5, 232-239 .
- [21] Gharieb, R.R., Massoud, M., Nady, S., Moness, M. (2016) Fuzzy c-means in features space of Teager-Kaiser Energy of continuous wavelet coefficients for detection of PVC beats in ECG. *2016 8th Cairo International Biomedical Engineering Conference (CIBEC)*. Cairo, 72-75.
- [22] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE (2003). PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*, 101, 215-220.
- [23] Hashemi, A., Dowlatshahi M. B., (2020). MLCR: A Fast Multi-label Feature Selection Method Based on K-means and L2-norm. *25th International Computer Conference, Computer Society of Iran (CSICC)*, 1-7.

- [24] Hashemi, A., Dowlatshahi, M.B., Nezamabadi-pour, H., (2019). MGFS: A multi-label graph-based feature selection algorithm via PageRank centrality. *ScienceDirect*, 142.
- [25] Homaeinezhad, M.R., Tavakkoli, E., Ghaffari, A. (2011). Discrete Wavelet-based Fuzzy Network Architecture for ECG RhythmType Recognition: Feature Extraction and Clustering-Oriented Tuning of Fuzzy Inference System. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 4, 107-130.
- [26] Illustration from Anatomy & Physiology, Connexions Web Site, 2013, <http://cnx.org/content/col11496/1.6/>.
- [27] Inan, O.T., Giovangrandi, L., Kovacs. G. T. A. (2006). Robust neural network-based classification of premature ventricular contractions using wavelet transform and timing interval features. *IEEE Transaction on Biomedical Engineering*, 53, 2507-2515.
- [28] Ince, T., Kiranyaz, S., Gabbouj, M. (2009). A Generic and Robust System for Automated Patient-specific Classification of Electrocardiogram Signals. *IEEE Transactions on Biomedical Engineering*, 56, 1415-1426.
- [29] *Introductory Guide to Identifying ECG Irregularities*, DailyCareBioMedical Inc. 2016
- [30] Jalal A., Nasiri, Naghibzadeh, M., Yazdi, H.S., Naghibzadeh, B. (2009). ECG Arrhythmia Classification with Support Vector Machines and Genetic Algorithm. *Third UKSim European Symposium on Computer Modeling and Simulation*, 187-192.

- [31] Jeppesen, J., Beniczky, S., Johansen, P., Sidenius, P., Frederiksen, A.F. (2017). Fully automated R-peak detection algorithm for patients with epilepsy: First step towards portable seizure detector. *Elsevier*, 128, 9, e282.
- [32] Karpagachelvi, S., Arthanari, M., Sivakumar, M. (2011). Classification of ECG Signals Using Extreme Learning Machine. *Computer and Information Science*, 4, 42-52.
- [33] Kohli, N., Verma, N.K., Roy, A. (2010) SVM Based Methods for Arrhythmia Classification in ECG. *International Conference on Computer & Communication Technology*, 486490.
- [34] LEE, C.C. (1990). Fuzzy Logic Controller, Fuzzy Logic in Control Systems. *IEEE*, 20, 404 – 418.
- [35] Lagerholm, M., Peterson, C., Braccini, G., Edenbrandt, L., Sörnmo, L. (2000). Clustering ECG Complexes Using Hermite Functions and Selforganizing Maps. *IEEE Transaction on Biomedical Engineering*, 47, 838-848.
- [36] Laguna P., Mark R.G., Goldberger A.L., Moody G.B. (1997). A Database for Evaluation of Algorithms for Measurement of QT and Other Waveform Intervals in the ECG. *Computers in Cardiology*, 24, 673-676.
- [37] Laitala, J., Jiang, M., Syrjälä, E., Naeini, E.K., Airola A., Rahmani, A.M., Dutt, N.D.D., Liljeberg, P. (2020). Robust ECG R-peak detection using LSTM. *35th Annual ACM Symposium on Applied Computing Association for Computing Machinery, New York, NY, USA*, 1104–1111.
- [38] Lei, W.K., Li, B.N., Dong, M.C., Vai, M.I. (2007). AFC-ECG: An adaptive fuzzy ECG classifier. *Springer*, 39, 189-199.

- [39] Li, H., Liang, H., Miao, C. et al (2016). Novel ECG Signal Classification Based on KICA Nonlinear Feature Extraction. *Circuits Syst Signal Process* 35, 1187–1197.
- [40] Liu, T., Si, Y., Wen, D., Zang, M., Lang, L. (2016). Dictionary learning for VQ feature extraction in ECG beats classification. *Expert Systems with Applications*, 53, 129-137.
- [41] MENDEL, J. M. (1995) Fuzzy Logic Systems for Engineering: A tutorial. *IEEE*, 83, 345-377.
- [42] Mahesh, V., Kandaswamy, A., Vimal, C., Sathish, B. (2009). ECG arrhythmia classification based on logistic model tree. *J. Biomedical Science and Engineering*, 2, 405-411.
- [43] Martis, R.J., Chakraborty, C., Ray, A.K. (2009). A two-stage mechanism for registration and classification of ECG using Gaussian mixture model. *Pattern Recognition*, 42, 2979 – 2988.
- [44] Mehta, S.S., Lingayat, N.S. (2007). Support Vector Machine for Cardiac Beat Detection in Single Lead Electrocardiogram. *IAENG, International Journal of Applied Mathematics*, 1630-1635.
- [45] Merone, M., Soda, P., Sansone, M., Sansone, C. (2017). ECG databases for biometric systems: a systematic review. *Expert Systems*, 67, 189–202.
- [46] Moody, G.B., Mark, R.G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEE*, 20, 45-50.

- [47] Murugan, S., Radhakrishnan, S. (2010). Improving Ischemic Beat Classification Using Fuzzy-Genetic Based PCA And ICA. *(IJCSE) International Journal on Computer Science and Engineering*. 02, 05, 1532-1538.
- [48] Naghsh-Nilchi, A. R. Mohammadi A. R. K. (2009). Cardiac Arrhythmias Classification Method Based on MUSIC, Morphological Descriptors, and Neural Network. *EURASIP Journal on Advances in Signal Processing*, 2008.
- [49] Nazmy, T.M., El-Messiry, H., Al-Bokhity, B. (2010). Adaptive Neuro-Fuzzy Inference System for classification of ECG signals. *The 7th International Conference on Informatics and Systems (INFOS)*, 1-6.
- [50] Nolle, F.M., Badura, F.K., Catlett, J.M., Bowser, R.W., Sketch, M.H. (1986). CREI-GARD, a new concept in computerized arrhythmia monitoring systems. *Computers in Cardiology*, 13, 515-518.
- [51] Nunes, J.C., Nait-Ali, A. (2005) Hilbert transform-based ECG modeling. *Biomedical Engineering*, 39, 133-137.
- [52] Owis, M., Abou-Zied, A., Youssef, A.B., Kadah, Y. (2001). Robust feature extraction from ECG signals based on nonlinear dynamical modeling. *23rd Annual International Conference IEEE Engineering in Medicine and Biology Society*, 2, 1585-1588.
- [53] Paniri, M., Dowlatshahi, M.B., Nezamabadi-pour, H. (2019). MLACO: A multi-label feature selection algorithm based on ant colony optimization. *ScienceDirect*, 192.
- [54] Roopa, C.K., Harish, B.S, (2018). Interpretation of ECG using modified Intuitionistic fuzzy C-MEANS clustering for arrhythmia data. *ICTACT*, 09.

- [55] Roopa, C.K., Harish, B.S., Aruna Kumar S.V., (2018). A Novel Method of Clustering ECG Arrhythmia data using Robust Spatial Kernel Fuzzy C-Means. *Science Direct*, 143, 133-140.
- [56] Sahoo, S., Dash, M., Behera, S., Sabut, S. (2020). Machine Learning Approach to Detect Cardiac Arrhythmias in ECG Signals: A Survey – *IRBM*.
- [57] Sahoo, S., Kanungo, B., Behera, S., Sabut, S. (2017). Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities. *Measurement*, 108, 55-66.
- [58] Sakhare, P.B., Ghongade, R. (2015). An Approach for ECG Beats Classification using Adaptive Neuro Fuzzy Inference System. *Annual IEEE India Conference (INDICON)*, 1-6.
- [59] Sakhare, P.B., Ghongade, R. (2015). An approach for ECG beats classification using Adaptive Neuro Fuzzy Inference System. *Annual IEEE India Conference (INDICON)*. New Delhi, 1-6.
- [60] Shyu, L.Y., Wu, W.H., Hu, H.U. (2004). Using wavelet transform and fuzzy neural network for VPC detection from the holter ECG. *IEEE Transactions on Biomedical Engineering*. 51, 7, 1269-1273.
- [61] Song, M.H., Lee, J., Cho, S.P., Lee, K.J., Yoo, S.K. (2005). Support Vector Machine Based Arrhythmia Classification Using Reduced Features. *International Journal of Control, Automation and Systems*, 3, 571-579.
- [62] Spach, M.S., Kootsey, J.M. (1983) The nature of electrical propagation in cardiac muscle Am. J. Physiol. Heart Circ. *Physiol*, 244 (H) ,3-22.

- [63] Taddei, A., Distanto, G., Emdin, M., Pisani, P., Moody, G.B., Zeelenberg, C., Marchesi, C. (1992). The European ST-T Database: standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography. *European Heart Journal*, 13, 1164-1172.
- [64] Venkatesan, C., Karthigaikumar, P., Paul, A., Satheeskumaran, S., Kumar, R (2018). ECG Signal Preprocessing and SVM Classifier-Based Abnormality Detection in Remote Healthcare Applications. *IEEE*. 6, 9767-9773.
- [65] Venkatesan, C., Karthigaikumar, P., Varatharajan, R (2018). A novel LMS algorithm for ECG signal preprocessing and KNN classifier based abnormality detection. *Multimed Tools Appl* , 77, 10365–10374.
- [66] Warmerdam, G. J. J., Vullings, R., Schmitt, L., Van Laar, J. O. E. H., Bergmans, J. W. M. (2018). Hierarchical Probabilistic Framework for Fetal R-Peak Detection, Using ECG Waveform and Heart Rate Information. *IEEE Transactions on Signal Processing*, 66, 16, 4388-4397.
- [67] Yong, L.S., Yong, A.D., Hae, S.M., Joung, L.K. (2011). The Classification of Electrocardiograph Arrhythmia Patterns using Fuzzy Support Vector Machines , *International Journal of Fuzzy Logic and Intelligent Systems* ,11 , 204-210.
- [68] Zadeh, L.A. (1998). Fuzzy Logic University of California. *IEEE*, 4, 83-93.
- [69] Zhang, Y., Zhang, Y., Lo, B., Xu, W. (2019). Wearable ECG signal processing for automated cardiac arrhythmia classification using CFASE-based feature selection. *Expert Systems*, e12432.

- [70] Özcan, N.O., Gurgun, F. (2010). Fuzzy Support Vector Machines for ECG Arrhythmia Detection. *20th International Conference on Pattern Recognition*, 2973-2976.