



Arrhythmia Classification Improvement by Individually Mapping the Feature Space of each patient

Shafaatfar, Hamid¹ / Taghizadeh, Mehdi^{2*} / Valizadeh, Morteza³ / Fatehi, Mohammad Hossein²

¹ - Ph.D. Student, Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran

² - Assistant Professor, Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran

³ - Assistant Professor, Department of Electrical Engineering, Urmia University, Urmia, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2022.554427.1776

Received: 6 June 2022

Revised: 26/8/2022 – 28/11/2022

Accepted: 21 December 2022

KEYWORDS

*Cardiac Arrhythmia
Classification
Feature Extraction
Feature Space Mapping*

ABSTRACT

Automatic detection of cardiac arrhythmias is very important for the successful treatment of heart disease and machine learning is used for this purpose. To correctly classify arrhythmic classes, it is important to extract the appropriate features to distinguish between different classes. In this paper, a deep convolutional neural network is used to extract the feature. Due to the fact that the heart rates of different patients are very different, arrhythmia classes will have many intra-class changes. To reduce intra-class changes, each patient's heart rate is mapped with a dedicated function to increase its resemblance to the heart rate of one of the training patient data's. The proposed specific mapping reduces intra-class changes and significantly increases the classification accuracy of cardiac arrhythmias. To prove the effectiveness of the proposed method, its results were compared with several new studies based on three criteria for accuracy, sensitivity and specificity and on the same data set. The accuracy obtained is about 96.24%, which shows the better performance of the proposed method compared to other works.

***Corresponding Author**

Address	Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran		
Postal Code	73198-66451	Tel	+98-71-42243940
E-Mail	mehdi.taghizadeh@iau.ac.ir	Fax	+98-71-42230508





بهبود کارایی طبقه‌بندی خودکار آریتمی‌های قلبی با نگاشت اختصاصی فضای ویژگی هر بیمار

شفاعت‌فر، حمید^۱ / تقی‌زاده، مهدی^{۲*} / ولی‌زاده، مرتضی^۳ / فاتحی، محمدحسین^۲

- ^۱ - دانشجوی دکتری، دانشکده‌ی برق و کامپیوتر، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران
^۲ - استادیار، دانشکده‌ی برق و کامپیوتر، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران
^۳ - استادیار، دانشکده‌ی برق و کامپیوتر، دانشگاه ارومیه، ارومیه، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2022.554427.1776

پذیرش: ۳۰ آذر ۱۴۰۱

بازنگری: ۱۴۰۱/۹/۷ - ۱۴۰۱/۶/۴

ثبت در سامانه: ۱۶ خرداد ۱۴۰۱

چکیده

واژه‌های کلیدی

تشخیص خودکار آریتمی‌های قلبی برای درمان موفق بیماری‌های قلبی از اهمیت زیادی برخوردار است و یادگیری ماشین برای این منظور مورد استفاده قرار می‌گیرد. برای طبقه‌بندی صحیح کلاس‌های آریتمی، استخراج ویژگی‌های مناسب جهت ایجاد تمایز بین کلاس‌های مختلف، اهمیت زیادی دارد. در این مقاله از یک شبکه‌ی عصبی پیچشی عمیق برای استخراج ویژگی استفاده شده است. با توجه به این که ضربان‌های قلبی بیماران مختلف دارای تفاوت زیادی هستند، کلاس‌های آریتمی دارای تغییرات درون کلاسی زیادی خواهند بود. برای کاهش تغییرات درون کلاسی، ضربان‌های قلبی هر بیمار با یک تابع اختصاصی به نحوی نگاشت داده شده است که شباهت آن به ضربان‌های قلبی یکی از بیماران آموزشی افزایش یابد. نگاشت اختصاصی پیشنهادی سبب کاهش تغییرات درون کلاسی شده و دقت طبقه‌بندی آریتمی‌های قلبی را به میزان قابل ملاحظه‌ای افزایش داده است. برای اثبات کارایی روش پیشنهادی، نتایج آن با چندین تحقیق جدید بر اساس سه معیار ارزیابی دقت، حساسیت و اختصاصیت و روی مجموعه‌ی داده‌ی یکسان مقایسه شده است. دقت به دست آمده حدود ۹۶/۲۴ درصد بوده که نشان دهنده‌ی کارایی بهتر روش پیشنهادی در مقایسه با سایر کارها است.

آریتمی قلبی

طبقه‌بندی

استخراج ویژگی

نگاشت فضای ویژگی

*نویسنده‌ی مسئول

نشانی: دانشکده‌ی برق و کامپیوتر، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران
کد پستی: ۷۳۱۹۸-۶۶۴۵۱
تلفن: +۹۸-۷۱-۴۲۲۴۳۹۴۰
دورنگار: +۹۸-۷۱-۴۲۲۳۰۵۰۸
پست الکترونیک: mehdi.taghizadeh@iau.ac.ir



۱- مقدمه

معمولا سیگنال‌های قلبی در بازه‌ی زمانی ۲۴ ساعته ثبت شده و مورد تحلیل قرار می‌گیرد تا آریتمی‌های نادر تشخیص داده شود. تحلیل دستی این سیگنال طولانی بوده و بازبینی بصری توسط پزشک هم به زمان زیادی نیاز دارد و هم مستعد خطای انسانی است. از این رو طبقه‌بندی خودکار آریتمی‌های قلبی از اهمیت زیادی برخوردار بوده [۲] و تحقیقات زیادی در این زمینه انجام شده است.

به هر گونه ناهنجاری در ریتم ضربان قلب، آریتمی گفته شده [۳] و آریتمی‌های قلبی به صورت کلی در دو دسته‌ی مورفولوژیکی و ریتمیک تقسیم‌بندی می‌شوند. استاندارد اصلی و جهانی که کلاس‌های آریتمی را مشخص کرده استاندارد AAMI^۱ است که سیگنال ECG را به ۵ کلاس طبقه‌بندی می‌کند [۴]. این کلاس‌ها در جدول (۱) نشان داده شده است که در آن ضربان غیرنرمال فوق بطنی^۲ (کلاس S)، ضربان غیرنرمال بطنی^۳ (کلاس V) و ضربان فیوژن^۴ (کلاس F) به صورت زیر تعریف می‌شوند.

سیستم گردش خون از طریق انقباض‌های منظم قلب ایجاد می‌شود که برای سلامتی انسان بسیار مهم است. قلب خون را از طریق عروق به بدن پمپاژ می‌کند و هر گونه انسدادی در عروق می‌تواند منجر به سکته‌ی قلبی و مرگ شود. بر اساس اعلام سازمان جهانی بهداشت، بیماری‌های قلبی و عروقی عامل حدود ۳۱ درصد از مرگ و میر در جهان بوده که ۸۲ درصد از این تعداد مرگ و میر در کشورهای با سرانه‌ی درآمد کم یا متوسط رخ می‌دهد که دلیل آن هزینه‌ی بالای انجام آزمایش‌های دوره‌ای و کمبود پزشک متخصص برای خواندن و تفسیر سیگنال‌های قلبی است [۱]. فعالیت‌های الکتریکی قلب توسط دستگاه الکتروکاردیوگرافی (ECG) ثبت می‌شود که حاوی اطلاعات ارزشمندی درباره‌ی عمل‌کرد قلب است. با بررسی سیگنال ECG توسط پزشک متخصص بسیاری از بیماری‌های قلبی تشخیص داده می‌شود. با توجه به این که تشخیص زودهنگام بیماری قلبی سبب تسهیل درمان می‌شود،

جدول (۱) - کلاس‌های آریتمی بر اساس استاندارد AAMI

Q	F	V	S	N	کلاس‌های ضربان قلبی بر اساس AAMI
ضربان ناشناخته	ضربان فیوژن	ضربان غیرنرمال بطنی	ضربان غیرنرمال فوق بطنی	ضربان‌هایی که در کلاس‌های S, V, F یا Q نیستند	توضیحات

ضربان فیوژن هنگامی اتفاق می‌افتد که یک ضربان فوق بطنی و یک ضربان بطنی به طور هم‌زمان برای تولید یک کمپلکس ترکیبی فعال شوند. این ضربان هنگامی که ایمپالس‌های الکتریکی از منابع مختلف به طور هم‌زمان در یک ناحیه از قلب عمل کنند رخ می‌دهد. این ضربان اگر روی قسمت‌های بطنی عمل کند به آن ضربان فیوژن بطنی و اگر در بخش‌های دهلیزی صورت گیرد به آن ضربان فیوژن دهلیزی گفته می‌شود [۴].

پزشکان برای تشخیص اختلالات، دامنه‌ی موج‌ها و فواصل بین آن‌ها را با اندازه‌های طبیعی و نرمال مقایسه کرده و در صورت وجود اختلافات معنی‌دار به وجود بیماری‌های قلبی پی می‌برند [۶]. یادگیری ماشین می‌تواند برای حل این مساله کمک شایانی کند. در روش‌های سنتی یادگیری ماشین، پدیده‌های مورد مطالعه در یک فضای ویژگی نمایش داده شده و تکنیک‌های یادگیری ماشین در آن فضای ویژگی، توابع متمایز کننده‌ای را برای اخذ تصمیم یاد می‌گیرند و عمدتاً توصیف پدیده‌ها در فضای ویژگی بر اساس دانش بشر از ماهیت مساله

ضربان غیرنرمال فوق بطنی، ضربانی نابهنگام، با عرض باریک اما شاید کمی متفاوت از ضربان طبیعی بیمار است. این ضربان ممکن است منشا سینوسی، دهلیزی یا گره‌ای داشته باشد. روند افزایشی در ضربان‌های غیرنرمال فوق بطنی ممکن است شاخص یا نشانه‌ای برای فیبریلاسیون دهلیزی باشد. فیبریلاسیون دهلیزی موضوع بسیار مهمی است زیرا می‌تواند منجر به حمله‌ی قلبی یا سکته شود [۵].

ضربان غیرنرمال بطنی یک بی‌نظمی است که در آن قبل از این که گره سینوسی فرصت صدور ایمپالس بعدی را پیدا کند، یک کانون نابه‌جا در بطن‌ها یک ایمپالس صادر می‌کند که سبب دپولاریزه شدن کل ماهیچه‌ی قلب می‌شود. این آریتمی سبب تغییراتی در سیگنال می‌شود که از آن جمله می‌توان به عدم وجود امواج P (یا وجود آن بعد از کمپلکس QRS و به صورت وارونه)، غیرمنظم بودن فاصله‌ی PR (در بعضی مواقع پهن و غیرطبیعی بودن کمپلکس QRS) و جهت وارونه داشتن موج T با QRS اشاره کرد [۴].

^۱ Ventricular Ectopic Beat^۲ Fusion Beat^۱ The Association for the Advancement of Medical Instrumentation^۲ Supraventricular Ectopic Beat



مفید هستند. این ویژگی‌ها اطلاعاتی که در ECG وجود دارد را به خوبی توصیف می‌کنند. به همین دلیل گشتاورهای آماری مرتبه‌ی بالا برای طبقه‌بندی انواع آریتمی‌ها مورد استفاده قرار گرفته و از شبکه‌ی فازی عصبی برای طبقه‌بندی آن‌ها استفاده شده که طبقه‌بندی ۷ نوع آریتمی در یک مجموعه‌ی داده به دقت ۹۶/۶٪ رسیده است [۱۵]. هم‌چنین در مقاله‌ی [۱۶] از گشتاورهای آماری مرتبه‌ی بالا به عنوان ویژگی و از PCA برای کاهش تعداد ویژگی استفاده شده که دقت طبقه‌بندی ۹۳/۵٪ برای آن گزارش شده است.

در سال‌های اخیر از روش‌های یادگیری عمیق برای طبقه‌بندی آریتمی‌های قلبی استفاده شده است که از آن جمله می‌توان به پژوهش‌هایی مانند شبکه‌های عصبی پیچشی باقی‌مانده‌ی بهبود یافته‌ی عمیق [۱۷]، شبکه‌ی عصبی عمیق چندمقیاسی [۱۸]، شبکه‌ی عصبی پیچشی عمیق [۱۹] و شبکه‌ی عصبی پیچشی عمیق با تابع هزینه‌ی وزن‌دهی شده‌ی دسته‌ای^۱ [۲۰] اشاره کرد. در مقاله‌ی [۲۱] سیگنال ECG با تحلیل زمان-فرکانس به تصویر تبدیل شده و با طبقه‌بندی آن تصاویر با بهره‌گیری از تکنیک یادگیری انتقالی و شبکه‌ی عصبی عمیق ResNet-101 کلاس سیگنال مورد تحلیل مشخص شده است. اخیراً یک تکنیک طبقه‌بندی آریتمی تفسیرپذیر ارائه شده است که علاوه بر طبقه‌بندی آریتمی‌ها، قابلیت تفسیر تصمیمات اتخاذ شده را نیز فراهم می‌کند [۲۲].

در این مقاله روشی ارائه شده است که در آن توصیف‌گرها و مرزهای تصمیم به طور خودکار آموزش داده می‌شود. این سیستم با دریافت سیگنال‌های قلبی، کلاس آریتمی‌ها را تشخیص داده و برای ارزیابی inter-patient که در حالت عملی با آن مواجه هستیم، به دقت طبقه‌بندی قابل قبولی دست پیدا کرده است. ایده‌ی اصلی این روش، نگاشت ویژگی‌های بیماران مختلف با تبدیل‌های متفاوت برای کاهش تغییرات درون‌کلاسی است و سعی می‌کند سیگنال‌های هر بیمار را به نحوی نگاشت دهد تا به سیگنال‌های یکی از بیماران آموزشی بیش‌ترین شباهت را داشته باشد که این موضوع باعث کاهش تغییرات درون‌کلاسی و تسهیل طبقه‌بندی آریتمی‌ها می‌شود.

۲- روش پیشنهادی برای طبقه‌بندی آریتمی

قلبی

در این مقاله روشی برای طبقه‌بندی آریتمی‌های قلبی با رویکرد ارزیابی inter-patient ارائه شده است. این رویکرد به استفاده‌ی کاربردی از سیستم تشخیص خودکار کمک خواهد کرد زیرا در

تعریف می‌شود. برای مسائل خیلی پیچیده تعریف فضای ویژگی مناسب کار آسانی نیست.

بنابراین نسل جدیدی از یادگیری ماشین با عنوان یادگیری عمیق ارائه شده است که داده‌های اصلی مانند تصویر و سیگنال به صورت خام وارد سیستم یادگیری ماشین شده و در طی فرایند یادگیری، توصیف‌گرهای مناسب هم‌زمان با آموزش مرز تصمیم، یاد گرفته می‌شود.

در این ساختارها نیازی به دانش اولیه‌ی طراح در مورد خواص پدیده‌ی مورد مطالعه وجود ندارد و سیستم یادگیری صرفاً با مشاهده‌ی داده‌های آموزشی و مقادیر مطلوب آن‌ها، توصیف‌گرهای مناسب و توابع متمایزکننده را آموزش می‌بیند. شبکه‌های عصبی پیچشی (CNN) یکی از معروف‌ترین روش‌های یادگیری عمیق بوده که برای پردازش تصویر و سیگنال خیلی مناسب هستند [۷].

تا کنون روش‌های بسیاری در زمینه‌ی شناخت آریتمی‌های قلبی و طبقه‌بندی آن‌ها ارائه شده است که از آن جمله می‌توان به روش‌های مبتنی بر شبکه‌ی عصبی با تابع پایه‌ی شعاعی [۸]، ماشین بردار پشتیبان (SVM) [۱۰، ۱۱] و ماشین یادگیری حداکثر (ELM) [۱۲] اشاره کرد. در مقاله‌ی [۱۳] از تبدیل موجک برای استخراج ویژگی استفاده شده که موجک مادر بهینه از بین یک مجموعه‌ی بانک موجک متعامد انتخاب شده که این کار با در نظر گرفتن همبستگی آن‌ها با سیگنال ECG انجام شده و ویژگی‌ها از سه قسمت سیگنال که متناظر با موج P، کمپلکس QRS و موج T هستند استخراج شده که برای استخراج ویژگی، مجموع مقادیر این قسمت‌ها در حوزه‌ی تبدیل موجک محاسبه شده است.

در مقاله‌ی [۳] از ضرایب تبدیل موجک گسسته به همراه تکنیک کاهش ویژگی تحلیل مولفه‌های اصلی (PCA) برای یافتن ویژگی‌های متمایز کننده‌ی کلاس نرمال از سایر کلاس‌های آریتمی استفاده شده است. دقت طبقه‌بندی برابر با ۹۸/۸۷٪ با این ویژگی‌ها و طبقه‌بندی شبکه‌ی عصبی به دست آمده که این آزمایش روی مجموعه‌ی داده‌ی MIT-BIH انجام شده است. آزمایشات انجام شده با استفاده از ویژگی‌های خطی اکثراً روی داده‌های بدون نویز انجام شده است به طوری که این میزان دقت در حضور نویز قابل حصول نیست [۱۴].

ویژگی‌های زیادی بر مبنای گشتاورهای مرتبه‌ی بالای نرخ ضربان برای تشخیص غیرطبیعی بودن عمل کرد قلب ارائه شده است. ماهیت غیرطبیعی و دینامیک ویژگی‌های کامولنت‌های مرتبه‌ی بالاتر برای استخراج تغییرات کوچک در سیگنال ECG

^۱ Batch-Weighted

حدود ۷۵۰۰۰ نمونه و کم‌تعدادترین دسته ضربان زودهننگام فوق بطنی (SP) با تنها ۲ نمونه است. در این مجموعه‌ی داده محل‌های موج R و نوع کلاس هر ضربان قلبی مشخص شده است. در این تحقیق مانند بسیاری از تحقیق‌های رایج، از استاندارد AAMI^۲ استفاده شده که در آن ضربان‌های قلبی به ۵ گروه اصلی آریتمی شامل N، S، V، F و Q تقسیم شده است. برای مقایسه‌ی کارایی روش‌های مختلف، مجموعه‌ی داده‌ی MIT-BIH مطابق جدول (۲) به دو گروه مجموعه‌ی داده‌ی ۱ (DS1) و مجموعه‌ی داده‌ی ۲ (DS2) تقسیم شده که برای آموزش و DS2 برای ارزیابی سیستم‌های تشخیص آریتمی مورد استفاده قرار گرفته است.

جدول (۲) - تقسیم‌بندی سیگنال‌های مجموعه‌ی داده‌ی MIT-BIH

مجموعه‌ی داده	شماره‌ی سیگنال‌های ضبط شده‌ی MIT-BIH در مجموعه‌ی داده
DS1	۱۱۰، ۱۰۶، ۱۰۸، ۱۰۹، ۱۱۲، ۱۱۴، ۱۱۵، ۱۱۶، ۱۱۸، ۱۱۹، ۱۲۲، ۱۲۴، ۲۰۱، ۲۰۳، ۲۰۵، ۲۰۷، ۲۰۸، ۲۰۹، ۲۱۵، ۲۲۰، ۲۲۳، ۲۳۰
DS2	۱۰۰، ۱۰۳، ۱۰۵، ۱۱۱، ۱۱۳، ۱۱۷، ۱۲۱، ۱۲۳، ۲۰۰، ۲۰۲، ۲۱۰، ۲۱۲، ۲۱۳، ۲۱۴، ۲۱۹، ۲۲۱، ۲۲۲، ۲۲۸، ۲۳۱، ۲۳۲، ۲۳۳، ۲۳۴

۲-۲- پیش‌پردازش سیگنال‌های قلبی

پیش‌پردازش یکی از مهم‌ترین مراحل پردازش سیگنال بوده که شامل عملیاتی مانند حذف نویز، نرمال‌سازی و بخش‌بندی است. در کاربردهای یادگیری عمیق این عمل منجر به بهبود عمل کرد یادگیری شبکه‌ی عصبی می‌شود. از این رو پیش‌پردازش‌های مورد نظر روی سیگنال‌های قلبی انجام شده است.

یک روش متداول برای کاهش تغییرات درون‌کلاسی، افزایش کارایی و سرعت هم‌گرایی شبکه و تولید سیگنال نرمال از سیگنال ورودی است. با در نظر گرفتن $S(n)$ به عنوان سیگنال قلبی یک بیمار که شامل یک ضبط به مدت ۳۰ دقیقه می‌باشد، ابتدا نرمال‌سازی دامنه مطابق رابطه‌ی زیر انجام شده است.

$$S_N(n) = \frac{S(n)}{\max(S(n))} \quad (1)$$

هم‌چنین برای توجه به ماهیت سیگنال قلبی که در آن ضربان‌های مختلف دارای طول‌های زمانی متفاوتی هستند و از سوی دیگر این سیگنال‌ها توسط شبکه‌های پیچشی پردازش

عمل بیمارانی که برای انجام معاینات مراجعه می‌کنند در روند آموزش سیستم تشخیص دخیل نبوده و این همان رویکرد ارزیابی inter-patient است. مشکل اصلی این رویکرد، تغییرات درون‌کلاسی زیاد آریتمی‌ها و نمونه‌های نرمال است زیرا این نمونه‌ها از بیماران مختلفی استخراج شده و شکل سیگنال قلبی آن‌ها تا اندازه‌ای متفاوت می‌باشد. با توجه به این که نمونه‌های آموزشی از تمام بیماران در مجموعه‌ی داده‌های آموزشی وجود ندارد، این امر سبب ایجاد خطای طبقه‌بندی در سیگنال‌های قلبی بیمارانی خواهد شد که در روند آموزش سیستم هوشمند مشارکت نداشته‌اند. لذا ایده‌ی اصلی این مقاله بر این اصل بنا شده است که قبل از طبقه‌بندی نمونه‌های جدید با استفاده از تکنیک‌های خوشه‌بندی و بهینه‌سازی، ویژگی‌های آن‌ها به نحوی نگاشت داده شوند که تغییرات درون‌کلاسی را در فضای ویژگی کاهش دهند. برای کاهش تغییرات درون‌کلاسی سعی شده است تا از بین نمونه‌های آموزشی، بیماری که ضربان‌های قلبی او بیش‌ترین شباهت را به ضربان‌های قلبی ورودی سیستم دارد پیدا شده و ویژگی‌های ضربان‌های قلبی به نحوی نگاشت داده شود که شباهت آن‌ها با نمونه‌ی آموزشی انتخاب شده حداکثر گردد. این اقدام باعث کاهش تغییرات درون‌کلاسی می‌شود. هم‌چنین برای استخراج ویژگی‌های سیگنال‌های قلبی یک شبکه‌ی عصبی پیچشی ارائه شده است تا روند آموزش و طبقه‌بندی بدون نیاز به دانش طراح و تنها بر مبنای داده‌های برچسب خورده انجام شود. برای یادگیری الگوریتم‌های یادگیری ماشین به داده‌های آموزشی نیاز بوده که خوش‌بختانه برای تحلیل سیگنال‌های قلبی مجموعه‌ی داده‌های متنوعی جمع‌آوری شده و در اختیار محققان قرار داده شده است. مجموعه‌ی داده‌های بسیاری در این زمینه وجود دارد که مجموعه‌ی داده‌ی MIT-BIH معتبرترین آن‌ها است [۲۳].

۲-۱- مجموعه‌ی داده

در این مقاله از مجموعه‌ی داده‌ی MIT-BIH که در سایت فیزیونت^۱ قابل دست‌یابی بوده استفاده شده است. این مجموعه شامل ۴۸ ضبط از ۴۸ بیمار به مدت ۳۰ دقیقه است. فرکانس نمونه‌برداری آن ۳۶۰ نمونه بر ثانیه و لیدهای مورد استفاده‌ی آن MLII، V1، V2، V4 و V5 بوده که در این تحقیق فقط از لید MLII استفاده شده است. در این مجموعه‌ی داده بالغ بر ۱۰۹۰۰۰ ضربان قلبی برچسب‌دار از ۱۵ نوع ضربان قلب مختلف وجود دارد که تعداد نمونه‌های ضربان‌های مختلف متفاوت است. پرتعدادترین دسته مربوط به ضربان طبیعی با

^۲ American Association of Medical Instrumentation (AAMI)

^۱ PhysioNet



بالاتری را استخراج کنند. در واقع آموزش لایه‌های پیچشی را می‌توان با یافتن فیلترهایی برای استخراج ویژگی‌های موثر از تصویر ورودی معادل دانست. بنابراین نقش لایه‌های پیچشی در شبکه‌های عمیق را می‌توان استخراج ویژگی در نظر گرفت. با تعمیم فیلترهای مورد نظر به سیگنال‌های یک‌بعدی می‌توان فیلترهایی را به صورت خودکار آموزش داد تا از سیگنال‌های ورودی ویژگی‌های موثرتری را استخراج کنند. این فیلترها در لایه‌های پیچشی یک‌بعدی آموزش می‌بینند که در نهایت یک نقشه‌ی ویژگی را می‌توان از لایه‌های پیچشی دریافت کرد.

لایه‌های پیچشی یک‌بعدی در کاربردهای پردازش سیگنال، تحلیل سری‌های زمانی و تحلیل زبان طبیعی کاربرد دارند. شبکه‌های پیچشی یک‌بعدی به صورت رابطه‌ی (۳) ویژگی‌های جدید را با پردازش ویژگی‌های لایه‌های قبلی استخراج می‌کنند.

$$y_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} w_{ik}^l * x_i^{l-1} \quad (3)$$

در این رابطه y_k^l نقشه‌ی ویژگی k -ام در لایه‌ی l -ام، b_k^l مقدار بایاس متناظر با y_k^l ، x_i^{l-1} نقشه‌ی ویژگی i -ام در لایه‌ی $(l-1)$ ، w_{ik}^l وزن‌هایی که نقشه‌های ویژگی در لایه‌ی $l-1$ به نقشه‌ی ویژگی k -ام در لایه‌ی l منتقل می‌کنند، N_{l-1} تعداد نقشه‌های ویژگی در لایه‌ی $(l-1)$ -ام و $*$ عملگر کانولوشن است [۲۴]. در ادامه توضیحاتی در مورد بخش‌های اصلی شبکه‌ی عصبی پیچشی ارائه شده است.

۲-۳-۱- توابع فعال‌سازی

در شبکه‌های عصبی چندلایه خروجی نورون‌ها از یک تابع غیرخطی عبور می‌کند که به آن‌ها توابع فعال‌سازی گفته می‌شود. توابع فعال‌سازی به لایه‌های پیچشی کمک می‌کنند تا ویژگی‌های غیرخطی و پیچیده‌تری را آموزش ببینند. در لایه‌های پیچشی معمولاً از تابعی به نام RELU^۲ به عنوان تابع فعال‌سازی استفاده شده که با رابطه‌ی زیر پیاده‌سازی می‌شود.

$$\text{ReLU}(x) = \max(0, x) \quad (4)$$

این تابع فعال‌سازی در شبکه‌های عمیق بسیار محبوب است زیرا تا حدی از به وجود آمدن مشکل محوشدگی گرادیان در شبکه‌های عمیق جلوگیری می‌کند که این امر در الگوریتم‌های آموزش بر مبنای گرادیان دارای اهمیت است. در این مقاله در تمام لایه‌های پیچشی از این تابع فعال‌سازی استفاده شده است.

خواهند شد که طول‌هایی یکسان از سیگنال را برای استخراج ویژگی تحلیل می‌کنند، نمی‌توان یک قطعه از سیگنال با طول ثابت را به عنوان یک ضربان قلبی در نظر گرفت زیرا با این اقدام ممکن است بخشی از اطلاعات مهم سیگنال از بین برود. لذا برای کاهش تغییرات درون‌کلاسی سعی شده است تا محور زمانی سیگنال‌ها به نحوی نرمالیزه شود که بتوان هر ضربان قلبی را به صورت یک بازه‌ی ثابت حول محل پیک R مربوطه توصیف کرد. برای نرمال‌سازی محور زمانی از رابطه‌ی (۲) استفاده شده است. اگر $a = T_1/T_2$ باشد که در آن T_2 متوسط فاصله‌ی زمانی بین دو پیک R متوالی کلاس نرمال در کل مجموعه‌ی سیگنال‌های موجود در پایگاه داده و T_1 متوسط فاصله‌ی زمانی بین دو پیک R متوالی در سیگنال‌های مورد نظر است، آن‌گاه مقیاس محور زمانی با رابطه‌ی زیر انجام می‌شود.

$$S_T(n') = S_N([an']) \quad 0 < n' \leq \left\lfloor \frac{N_1}{a} \right\rfloor \quad (2)$$

در این رابطه N_1 طول سیگنال اصلی و $[]$ عملگر جزء صحیح است. برای $a > 1$ مقیاس محور زمانی باعث فشرده‌سازی سیگنال و برای $a < 1$ باعث گسترده شدن سیگنال می‌شود. پس از این مقیاس محور زمانی $[T_2]$ نمونه‌ی در اطراف موج R به عنوان یک ضربان قلبی در نظر گرفته شده به نحوی که موج R در وسط نمونه‌ها قرار گیرد و با توجه به برچسب موج R مربوطه، داده‌های برچسب خورده تعیین شده است.

۲-۳-۲- استخراج ویژگی از سیگنال‌های قلبی با

شبکه‌های پیچشی

شبکه‌های پیچشی یکی از موفق‌ترین ساختارها در میان ساختارهای یادگیری عمیق بوده و مزیت اصلی این شبکه‌ها این است که استخراج ویژگی به صورت خودکار صورت گرفته و دیگر نیازی به تعریف عمل‌گرهای استخراج ویژگی توسط کاربر و بر مبنای دانش انسان از مساله‌ی مورد مطالعه نیست. استفاده از لایه‌های پیچشی^۱ و لایه‌های کاهش اندازه^۲ در این شبکه‌ها رایج است. لایه‌های پیچشی می‌توانند ویژگی‌های سطح پایین و سطح بالا را به طور سلسله‌مراتبی استخراج کنند [۲۴].

شبکه‌ی عصبی پیچشی ابتدا برای طبقه‌بندی تصاویر ایجاد شده است که در آن شبکه با دریافت تصویر، در لایه‌های مختلف فیلترهایی را آموزش می‌بیند تا با بهره‌گیری از آن‌ها ویژگی‌های موثری را استخراج کند و ویژگی‌های استخراج شده به نوبه‌ی خود توسط فیلترهای دیگری پردازش شده تا ویژگی‌های سطح

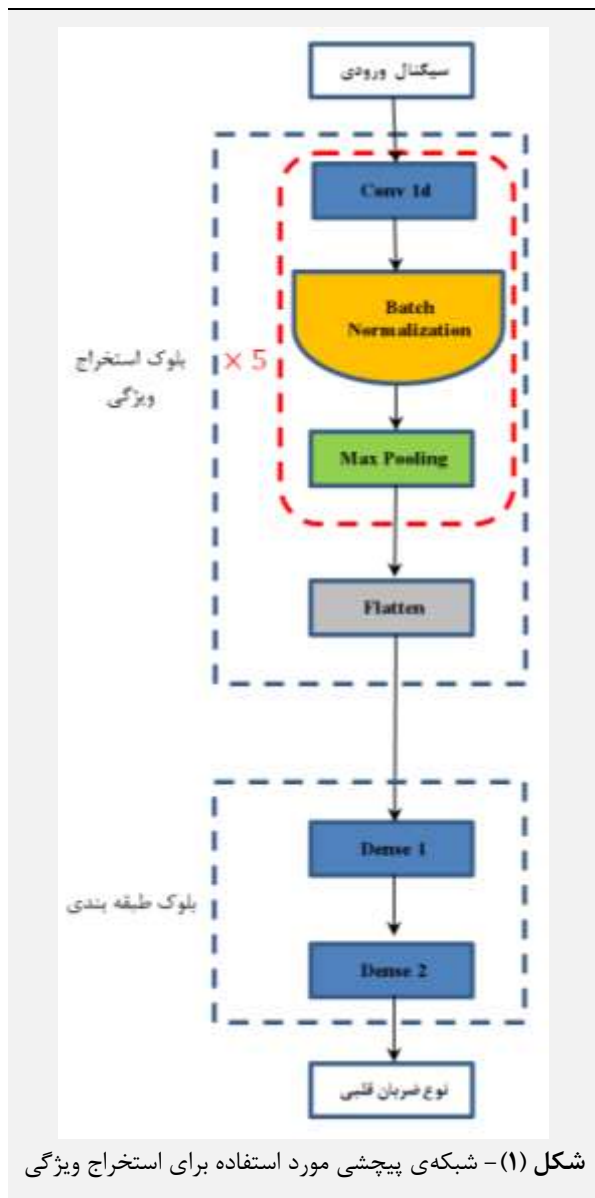
^۱ Rectified Linear Unit

^۱ Convolutional Layer

^۲ Pooling Layer

۲-۳-۵- لایه‌ی هموارساز

لایه‌ی هموارساز تمام نقشه‌های ویژگی را در قالب یک بردار مرتب می‌کند. ساختار شبکه‌ی پیچشی مورد استفاده در این مقاله برای استخراج ویژگی و طبقه‌بندی آریتمی‌ها در شکل (۱) نشان داده شده است.



شکل (۱) - شبکه‌ی پیچشی مورد استفاده برای استخراج ویژگی

در این ساختار از ۵ لایه‌ی پیچشی استفاده شده است که به دنبال هر یک از آن‌ها یک لایه‌ی نرمالیزه کننده‌ی دسته و یک لایه‌ی کاهش اندازه‌ی بیشینه وجود دارد. لایه‌های پیچشی از نظر اندازه و تعداد فیلترها در هر لایه متفاوت هستند که مشخصات شبکه در جدول (۳) ارائه شده است. خروجی لایه‌ی پیچشی پنجم پس از عبور از لایه‌ی کاهش اندازه شامل ۱۵۰ مقدار است که از آن به عنوان بردار ویژگی استفاده می‌شود.

همچنین در این تحقیق از تابع فعال‌سازی softmax استفاده شده است. خروجی‌های هر نورون پس از عبور از این تابع، بین صفر و یک نگاشت پیدا می‌کند. به عبارت دیگر خروجی تمام نورون‌های آن لایه به نحوی نرمالیزه می‌شود به طوری که مجموع کل خروجی‌های آن برابر با ۱ شود. بنابراین خروجی این تابع فعال‌سازی معادل توزیع احتمال طبقه‌بندی است و می‌توان از آن‌ها به عنوان احتمال تعلق یک شی به کلاس مشخصی بهره گرفت [۲۵].

۲-۳-۲- لایه‌های تمام متصل

در این لایه‌ها هر نورون به تمام نورون‌های لایه‌ی قبلی یا به تمام مولفه‌های بردار ویژگی وصل می‌شود. از این لایه‌ها برای استخراج ویژگی‌های کلی از شی مورد مطالعه یا طبقه‌بندی آن شی استفاده می‌شود. در این مقاله از دو لایه‌ی متصل استفاده شده که تعداد نورون‌های لایه‌ی دوم برابر با تعداد کلاس‌های مورد نظر بوده که در این مقاله برابر با ۵ است.

۲-۳-۳- لایه‌های کاهش اندازه

در این شبکه‌ها در هر لایه از چندین فیلتر استفاده شده و لذا ویژگی‌های متفاوتی استخراج می‌شود. از طرفی بار محاسباتی و تعداد پارامترها به شدت افزایش پیدا می‌کند که ممکن است آموزش شبکه‌ی عصبی را با مشکل مواجه کند. به همین دلیل پس از لایه‌های پیچشی از لایه‌های کاهش اندازه استفاده می‌شود که هدف از استفاده‌ی آن‌ها کاهش اندازه‌ی داده‌ها، پارامترهای یادگیری و کاهش حجم محاسبات است. این لایه با کاهش از طریق حذف اطلاعات زائد و حفظ چکیده‌ی مقادیر آن‌ها در یک همسایگی مشخص، به کنترل حجم محاسبات و تعداد پارامترهای شبکه کمک می‌کند. از سوی دیگر این لایه‌ها باعث می‌شود نقشه‌ی ویژگی نسبت به جابه‌جایی مقاوم گردد [۲۵]. در این تحقیق از لایه‌ی کاهش بعد بیشینه^۱ استفاده شده است که حداکثر مقدار نقشه‌ی ویژگی در یک همسایگی مشخص را نگه داشته و سایر مقادیر را دور می‌ریزد.

۲-۳-۴- لایه‌ی نرمال‌سازی دسته‌ای

لایه‌ی نرمال‌سازی دسته‌ای^۲ بعد از لایه‌ی پیچشی به منظور نرمالیزه کردن خروجی‌های آن و افزایش سرعت یادگیری به کار برده می‌شود. این لایه شامل چندین پارامتر است که در حین آموزش شبکه تنظیم شده تا خروجی‌های آن لایه در محدوده‌ی مطلوبی قرار گیرد [۲۵].

^۱ Flatten

^۱ Max Pooling

^۲ Batch Normalization



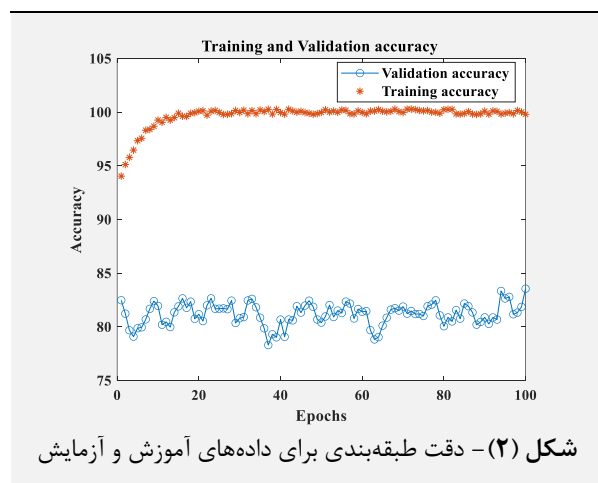
جدول (۳) - مشخصات شبکه‌ی پیچشی مورد استفاده (تعداد کل پارامترها: ۳۳۴۰۰)

نوع لایه‌ها	اندازه‌ی خروجی لایه‌ها	تعداد پارامترها	سایر توضیحات
Conv1d (Conv1D)	(۲۷۱, ۵)	۱۵۵	۵ فیلتر با طول ۳۰ با تابع فعال‌ساز ReLU
Batch Normalization	(۲۷۱, ۵)	۲۰	
Max_Pooling1d	(۱۳۵, ۵)	۰	
Conv1d_1	(۱۲۱, ۱۵)	۱۱۴۰	۱۵ فیلتر با طول ۱۵ با تابع فعال‌ساز ReLU
Batch Normalization 1	(۱۲۱, ۱۵)	۶۰	
Max_Pooling1d_1	(۶۰, ۱۵)	۰	
Conv1d_2	(۵۱, ۳۰)	۴۵۳۰	۳۰ فیلتر با طول ۱۰ با تابع فعال‌ساز ReLU
Batch Normalization 2	(۵۱, ۳۰)	۱۲۰	
Max_Pooling1d_2	(۲۵, ۳۰)	۰	
Conv1d_3 (Conv1D)	(۲۱, ۴۰)	۶۰۴۰	۴۰ فیلتر با طول ۵ با تابع فعال‌ساز ReLU
Batch Normalization 3	(۲۱, ۴۰)	۱۶۰	
Max_Pooling1d_3	(۱۰, ۴۰)	۰	
Conv1d_4	(۶, ۵۰)	۱۰۰۵۰	۵۰ فیلتر با طول ۵ با تابع فعال‌ساز ReLU
Batch Normalization 3	(۶, ۵۰)	۲۰۰	
Max_Pooling1d_3	(۳, ۵۰)	۰	
Flatten	(۱۵۰)	۰	
Dense1	(۷۰)	۱۰۵۷۰	لایه‌ی تمام متصل با ۷۰ نورون با تابع فعال‌ساز ReLU
Dense 2	(۵)	۳۳۵	لایه‌ی تمام متصل با ۵ نورون با تابع فعال‌ساز Softmax

۲-۳-۶- آموزش شبکه‌ی عصبی

این شبکه در محیط پایتون نسخه ۲/۷ با استفاده از کتابخانه‌ی Keras در بستر نسخه 2/1 Tensor Flow پیاده‌سازی شده که کتابخانه‌ی متن بازی^۱ است که برای یادگیری ماشین و در نتیجه یادگیری عمیق به کار برده می‌شود. برای آموزش شبکه از بهینه‌ساز RMSprop و تابع هزینه‌ی Categorical Cross Entropy استفاده شده است. دقت طبقه‌بندی برای داده‌های آموزش و آزمایش در شکل (۲) نشان داده شده است. این شبکه برای داده‌های آموزشی دقت طبقه‌بندی ۹۹/۶٪ را نشان داده در حالی که برای داده‌های تست دقت خیلی پایین یعنی ۸۱/۴٪ به دست آمده است. در آزمایشی دیگر ارزیابی intra-patient انجام شده است. در این ساختار برای ارزیابی، ابتدا تمام سیگنال‌ها قطع‌بندی شده و به صورت تصادفی بخشی از نمونه‌ها به عنوان داده‌ی آموزشی و بقیه‌ی آن‌ها به عنوان داده‌های آزمایش در نظر گرفته شده است. در این ارزیابی برای داده‌های آموزشی دقت ۹۹/۳٪ و برای داده‌های آزمایش دقت ۹۸/۹٪ گزارش شده است. تفاوت بین این دو نوع ارزیابی نشان می‌دهد که نمونه‌های بیماران متفاوت در فضای ویژگی در مکان‌های متفاوتی قرار می‌گیرد با وجود این که نوع آریتمی‌های آن‌ها یکسان است. در فرایند ارزیابی intra-patient با توجه به این که نمونه‌هایی از هر بیمار به عنوان

داده‌های آموزشی مورد استفاده قرار می‌گیرد اثر این تغییرات درون کلاسی خیلی مشکل‌ساز نیست زیرا در مکان‌های مختلف فضای ویژگی نمونه‌هایی برای هدایت سیستم یادگیری وجود دارد اما در ارزیابی inter-patient نمونه‌هایی از هر بیمار در اختیار نیست و با توجه به تغییرات درون کلاسی، قواعد به خوبی آموزش داده نمی‌شود لذا فقط از بخش استخراج ویژگی شبکه‌ی آموزش دیده استفاده می‌شود. با توجه به این که ویژگی‌های استخراج شده برای بیماران متفاوت در فضای ویژگی متفاوتی قرار می‌گیرد، ایده‌ی اصلی تصحیح فضای ویژگی هر بیمار برای افزایش کارایی سیستم تشخیص خودکار است.



^۱ Open Sources

$$f(\alpha, \beta, S_p) = \sum_{i=1}^3 (z_i - y_{S_p(i)})^2 \quad (۶)$$

$$= \sum_{i=1}^3 ((\alpha x_i + \beta) - y_{S_p(i)})^2$$

در این رابطه $S_p(i)$ درایه‌ی i -ام مجموعه‌ی S_p است. با ثابت فرض کردن S_p ، α و β به نحوی تعیین شده‌اند که رابطه‌ی (۶) کمینه گردد. برای این منظور گرادیان تابع f برابر با صفر قرار داده شده و با حل معادلات زیر مقادیر مجهول تعیین شده است.

$$\begin{cases} \frac{\partial f}{\partial \alpha} = 0 \\ \frac{\partial f}{\partial \beta} = 0 \end{cases} \quad (۷)$$

$$\Rightarrow \begin{cases} \alpha \left(\sum_{i=1}^3 x_i^2 \right) + \beta \left(\sum_{i=1}^3 x_i \right) = \sum_{i=1}^3 y_{S_p(i)} x_i \\ \alpha \left(\sum_{i=1}^3 x_i \right) + \beta = \sum_{i=1}^3 y_{S_p(i)} \end{cases}$$

مقادیر بهینه‌ی حاصل از حل این معادلات که برای مجموعه‌ی تناظر S_p معتبر بوده با $\alpha_{S_p}^*$ و $\beta_{S_p}^*$ نمایش داده شده است. برای یافتن بهترین پارامترهای نگاشت برای مجموعه‌ی تناظر مناسب، مقادیر تابع هدف به ازای $\alpha_{S_p}^*$ و $\beta_{S_p}^*$ مختلف بررسی شده و آن مجموعه‌ی تناظری که به کم‌ترین تابع هزینه منجر شده به عنوان مجموعه‌ی تناظر بهینه انتخاب شده و با S_{p^*} نمایش داده شده است.

$$f(\alpha_{S_{p^*}}^*, \beta_{S_{p^*}}^*, S_{p^*}) = \min(f(\alpha_{S_p}^*, \beta_{S_p}^*, S_p)) \quad (۸)$$

با داشتن $\alpha_{S_{p^*}}^*$ و $\beta_{S_{p^*}}^*$ مطابق رابطه‌ی زیر نمونه‌های بیمار i -ام نگاشت شده است تا شباهت توزیع نمونه‌های آن به توزیع نمونه‌های بیمار i -ام حداکثر گردد.

$$z = \alpha_{S_{p^*}}^* x + \beta_{S_{p^*}}^* \quad (۹)$$

۲-۴-۲- نگاشت نمونه‌های آموزشی در فضای ویژگی و آموزش شبکه‌ی عصبی دولایه

با فرض این که ۲۲ بیمار برای آموزش سیستم در اختیار قرار دارد سعی شده است تا نمونه‌های آموزشی به نحوی نگاشت داده شود که فاصله‌ی درون‌کلاسی حداقل گردد. برای این منظور ابتدا فاصله‌ی اقلیدسی نمونه‌های هر بیمار با سایر بیماران محاسبه شده و سپس متوسط آن فواصل سنجیده شده است. بیماری که متوسط فاصله‌ی آن با سایر بیماران حداقل

۲-۴-۲- نرمال کردن ویژگی‌ها برای کاهش تغییرات درون‌کلاسی

در مجموعه‌ی ضربان‌های بیماران مختلف ممکن است کلاس‌های مختلفی از آریتمی به همراه کلاس نرمال و یا فقط نمونه‌هایی از کلاس نرمال وجود داشته باشد، لذا سعی شده است تا در مرحله‌ی اول به ازای هر بیمار، در بین نمونه‌های آموزشی، بیماری پیدا شود که ضربان‌های قلبی آن‌ها بیش‌ترین شباهت را داشته باشد. سپس فضای ویژگی متناظر با آن بیمار به نحوی نگاشت شده است که شباهت آن‌ها بیش‌تر شود. برای یافتن شباهت بیشینه و هم‌چنین پارامترهای نگاشت، ابتدا ضربان‌های قلبی هر بیمار خوشه‌بندی شده و سپس پارامترهای نگاشت به نحوی تنظیم شده است تا خوشه‌های حاصل از ضربان‌های دو بیمار بیش‌ترین شباهت را داشته باشد.

۲-۴-۱- خوشه‌بندی ضربان‌های قلبی بیماران و نگاشت فضای ویژگی برای کاهش تغییرات درون‌کلاسی

از آن‌جا که معمولاً بیش‌تر از سه نوع آریتمی در ضربان‌های یک بیمار وجود ندارد، ضربان‌های قلبی هر بیمار به سه خوشه تقسیم شده که برای این منظور از خوشه‌یابی k -means استفاده شده است. معمولاً یک یا دو خوشه متعلق به کلاس نرمال بوده و خوشه‌های باقی‌مانده با سایر کلاس‌ها متناظر می‌شود. فرض کنید خوشه‌های x_1 ، x_2 و x_3 متعلق به بیمار i -ام و خوشه‌های y_1 ، y_2 و y_3 متعلق به بیمار j -ام بوده و هدف نگاشت ویژگی‌های ضربان‌های بیمار i -ام به نحوی که شباهت آن به ویژگی‌های ضربان‌های بیمار j -ام حداکثر گردد باشد. برای این منظور مراکز خوشه‌ها با تابع زیر نگاشت می‌شود.

$$z = \alpha x + \beta \quad (۵)$$

در این رابطه α و β پارامترهای تابع نگاشت بوده و به نحوی تعیین شده‌اند که تابع رابطه‌ی (۶) کمینه گردد. با توجه به این که تناظر بین خوشه‌ها مشخص نیست، به هر یک از خوشه‌های بیمار i -ام آزادی داده شده است تا به هر یک از خوشه‌های بیمار j -ام نگاشت داده شود. بنابراین ۹ حالت ممکن برای تناظر بین خوشه‌ها وجود دارد. بر این اساس ۹ مجموعه برای پوشش ۹ حالت تعریف شده و با S_p نمایش داده شده که p عددی بین ۱ تا ۹ است. برای مثال اگر مجموعه‌ی S_2 به صورت $S_2 = \{1, 1, 2\}$ باشد به این معنی است که خوشه‌ی اول و دوم بیمار i -ام با خوشه‌ی اول از بیمار j -ام و خوشه‌ی سوم بیمار i -ام با خوشه‌ی دوم بیمار j -ام متناظر است.

بوده به عنوان بیمار مرجع در نظر گرفته شده و سپس مراحل زیر برای کاهش فاصله‌ی درون‌کلاسی اجرا شده است.

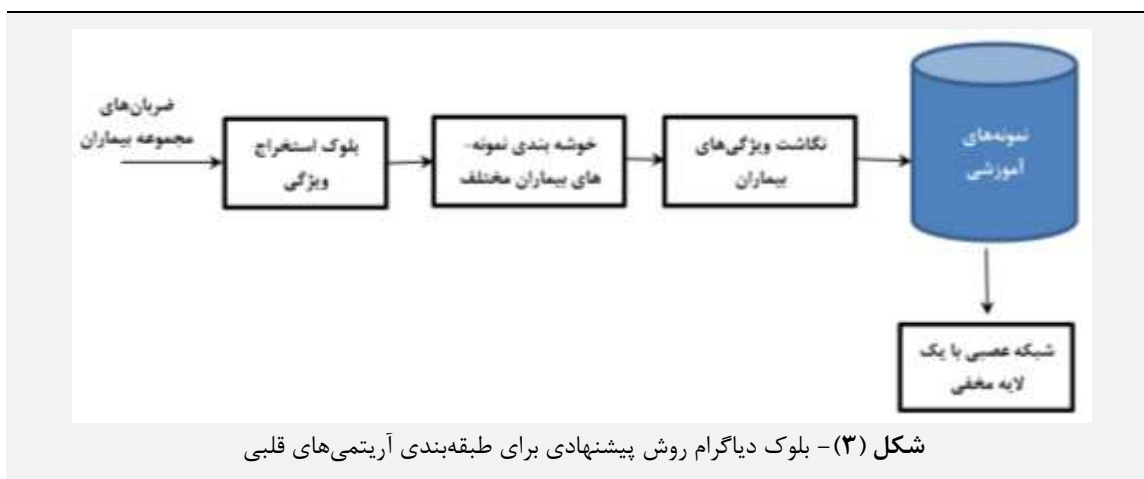
۱- یک مجموعه تحت عنوان ST تعریف شده و خوشه‌های بیمار مرجع در آن قرار داده شده است.

۲- بیماری که خوشه‌های حاصل از ضربان‌های قلبی آن بیش‌ترین شباهت را به خوشه‌های بیمار مرجع دارد به عنوان نمونه‌ی آموزشی بعدی انتخاب شده و سپس پارامترهای α_{Sp}^* و β_{Sp}^* به نحوی انتخاب شده است که پس از نگاشت، شباهت توزیع نمونه‌های آن به توزیع نمونه‌های بیمار مرجع حداکثر گردد. نمونه‌های بیمار انتخاب شده پس از نگاشت با رابطه‌ی (۹) که پارامترهای آن با رابطه‌ی (۷) تعیین شده، در مجموعه‌ی ST ذخیره شده است.

۳- بیمار بعدی که فاصله‌ی آن به یکی از اعضای مجموعه‌ی ST حداقل باشد به عنوان نمونه‌ی بعدی انتخاب شده، پارامترهای

۲-۵- آموزش طبقه‌بند

در این تحقیق برای طبقه‌بندی ضربان‌های بیماران مختلف از یک شبکه‌ی عصبی با یک لایه‌ی مخفی استفاده شده است. تعداد نورون‌های لایه‌ی مخفی برابر با ۷۰ و تعداد نورون‌های لایه‌ی خروجی برابر با ۵ (تعداد کلاس‌ها) تنظیم شده است. پس از استخراج ویژگی از ضربان‌های بیماران مختلف و نگاشت آن‌ها در فضای ویژگی، بردار ویژگی نهایی شکل گرفته و از آن برای آموزش شبکه‌ی عصبی دولایه استفاده شده است. بلوک دیاگرام روش پیشنهادی در شکل (۳) نشان داده شده است.



آموزش‌دیده، داده شده و طبقه‌بندی ضربان‌های قلبی صورت گرفته است.

۳- نتایج و بحث

برای بررسی کارایی مدل از سه معیار ارزیابی آماری شناخته شده با عناوین صحت، حساسیت و اختصاصیت که به ترتیب با روابط زیر تعریف می‌شوند استفاده شده است.

$$\text{Acc}(\%) = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (10)$$

$$\text{Sen}(\%) = \frac{TP}{TP + FN} \times 100 \quad (11)$$

$$\text{Spe}(\%) = \frac{TN}{TN + FP} \times 100 \quad (12)$$

در این روابط TP تعداد طبقه‌بندی صحیح یک کلاس خاص، FN تعداد طبقه‌بندی اشتباه در نمونه‌های یک کلاس خاص، TN تعداد ضربان‌هایی که به کلاس خاصی تعلق ندارند و توسط

۲-۶- طبقه‌بندی ضربان‌های قلبی بیماران جدید

برای طبقه‌بندی ضربان‌های قلبی بیمار جدید که در مجموعه‌ی داده‌ی آموزشی وجود ندارد، مراحل زیر انجام شده است.

۱- تمام ضربان‌های قلبی آن بیمار از سیگنال ECG استخراج شده و هر یک از آن‌ها به بلوک استخراج ویژگی داده شده است تا بردار ویژگی متناظر با تمام ضربان‌های قلبی استخراج شود.

۲- بردارهای ویژگی، خوشه‌بندی شده و خوشه‌های حاصل با نمونه‌های مجموعه‌ی ST مقایسه شده است. از بین اعضای آن مجموعه، بیماری که ضربان‌های قلبی آن بیش‌ترین شباهت را به ضربان‌های بیمار جدید دارد انتخاب شده است.

۳- پارامترهای نگاشت α_{Sp}^* و β_{Sp}^* به نحوی تعیین شده است که شباهت ضربان‌های بیمار جدید و بیمار انتخابی حداکثر شود.

۴- پس از نگاشت ضربان‌های قلبی بیمار جدید با استفاده از روابط (۶)، (۷) و (۸) بردارهای ویژگی به شبکه‌ی عصبی

با مقایسه‌ی ماتریس‌های سردرگمی مشخص شده که نگاشت ویژگی‌های بیماران باعث شده تا ویژگی‌های نمونه‌ی جدید به سمت نمونه‌های بیماری که بیش‌ترین شباهت را با آن دارد هدایت شده و این موضوع باعث کاهش تغییرات درون‌کلاسی شده است. لذا بردارهای ویژگی با دقت بیش‌تری طبقه‌بندی شده است. برای مقایسه‌ی کارایی روش پیشنهادی، مدل ۲ با کارهای تحقیقاتی ارائه شده در سایر مراجع مقایسه شده و دقت آن با چندین مدل شناخته شده بر اساس سه معیار ارزیابی دقت، حساسیت و اختصاصیت و روی مجموعه‌ی داده‌ی یکسان مقایسه شده که نتایج در جدول (۶) ارائه شده است. در این جدول معیار Acc برای هر کلاس به صورت جداگانه محاسبه شده و متوسط آن‌ها گزارش شده است.

مدل به سایر کلاس‌ها طبقه‌بندی می‌شوند و FP تعداد ضربان‌های متعلق به سایر کلاس‌ها که به اشتباه به کلاس مشخصی اختصاص داده می‌شود را نشان می‌دهد. برای بررسی اثر نگاشت ویژگی‌ها، دو مدل مختلف ارزیابی شده است. مدل ۱ نشان دهنده‌ی شبکه‌ی شامل لایه‌های پیچشی و لایه‌های تمام متصل شکل (۱) بوده و مدل ۲ نشان دهنده‌ی ساختار شامل بلوک نگاشت ویژگی پیشنهادی نشان داده شده در شکل (۳) است. ماتریس سردرگمی برای مدل‌های فوق روی داده‌های آزمایش به دست آمده و در جدول‌های (۴) و (۵) ارائه شده است. داده‌های آزمایش شامل ۴۴۲۵۹ نمونه‌ی کلاس N، ۱۸۳۷ نمونه‌ی کلاس S، ۳۲۲۱ نمونه‌ی کلاس V، ۳۸۸ نمونه‌ی کلاس F و ۷ نمونه‌ی کلاس Q است.

جدول (۵) - ماتریس سردرگمی برای مدل ۲

کلاس تخمینی					کلاس واقعی
Q	F	V	S	N	
۰	۰	۳۴۱	۱۷۵۷	۴۲۱۶۱	N
۰	۰	۳۵	۱۶۲۸	۱۷۴	S
۰	۰	۲۸۷۶	۵۲	۲۹۳	V
۰	۱۹۹	۹۷	۱۱	۸۱	F
۱	۰	۲	۰	۴	Q

جدول (۴) - ماتریس سردرگمی برای مدل ۱

کلاس تخمینی					کلاس واقعی
Q	F	V	S	N	
۰	۲	۲۲۴۳	۳۴۶۸	۳۸۵۴۶	N
۰	۰	۸۲	۱۴۷۲	۲۸۳	S
۰	۰	۲۴۳۷	۲۴۵	۵۳۹	V
۰	۸۴	۴۹	۳۷	۲۱۸	F
۰	۰	۰	۲	۵	Q

جدول (۶) - مقایسه کارایی روش پیشنهادی با سایر تحقیقات

Class (V)		Class (S)		Class (N)		Acc	روش‌های مختلف
Sen (%)	Spe (%)	Sen (%)	Spe (%)	Sen (%)	Spe (%)		
۸۹/۳	۹۸/۶۲	۸۸/۶۲	۹۶/۲۶	۹۵/۲۶	۸۹/۲۶	۹۶/۲۴	روش پیشنهادی
۸۷/۳۴	۹۵/۹	۶۱/۹۲	۹۷/۸۹	۹۴	۸۲/۵	۹۲/۴	مقاله‌ی [۱۰]
۸۸/۳۵	۹۴/۹۲	۳۵/۲۲	۹۸/۸۳	۹۴/۵۴	۸۰/۸	۸۸/۹۹	مقاله‌ی [۱۷]
۸۹/۲۳	۹۴/۰۲	۶۲/۴۹	۹۸/۱۱	۹۱/۸۹	۷۶/۹۳	۸۹/۹۱	مقاله‌ی [۱۹]
۹۲/۰۵	۹۷/۵۴	۸۲/۰۴	۹۷/۸۹	۸۸/۵۲	۹۱/۳	۸۸/۳۴	مقاله‌ی [۲۰]

تفاوت قابل ملاحظه‌ای دارد، نمونه‌های کلاس‌های یکسان در فضای ویژگی در مکان‌های متفاوتی قرار گرفته و تغییرات درون‌کلاسی آریتمی‌های قلبی زیاد خواهد بود که این عامل باعث کاهش کارایی سیستم طبقه‌بندی خودکار آریتمی قلبی می‌شود. بر این اساس در این مقاله یک تابع اختصاصی برای نگاشت ویژگی‌های ضربان‌های هر بیمار ارائه شده که شباهت ضربان‌های هر بیمار را به ضربان‌های قلبی یکی از بیماران آموزشی افزایش داده و این موضوع باعث کاهش تغییرات درون‌کلاسی و افزایش دقت طبقه‌بندی آریتمی‌های قلبی شده است. روش پیشنهادی در مقایسه با سایر روش‌های شناخته شده کارایی بهتری را نشان می‌دهد.

مقایسه‌ی نتایج نشان می‌دهد که با خوشه‌بندی ضربان‌های بیماران مختلف و نگاشت خوشه‌ها به نحوی که توزیع ضربان‌های هر بیمار به یکی از بیماران آموزشی بیش‌ترین شباهت را داشته باشد، باعث کاهش تغییرات درون‌کلاسی شده و دقت طبقه‌بندی آریتمی‌ها در روش ارزیابی inter-patient را به طور قابل ملاحظه‌ای افزایش داده است.

۴- نتیجه‌گیری

در این تحقیق از یک شبکه‌ی عصبی پیچشی عمیق برای استخراج ویژگی‌های ضربان‌های قلبی استفاده شده است. با توجه به این که شکل ضربان‌های قلبی در بیماران مختلف

- wavelet”, 21st IEEE Convention of the Electrical and Electronic Engineers in Israel. Proceedings (Cat. No.00EX377), pp. 346-350, 2000.
- [14] H. Danandeh Hesar, A. Danandeh Hesar, “An Improved Model-Based Bayesian Framework for ECG Processing in Non-Stationary Environments”, Iranian Journal of Biomedical Engineering, vol. 15, no. 3, pp. 231-240, Jan 2022.
- [15] R. J. Martis, U. R. Acharya, and H. Adeli, “Current Methods in Electrocardiogram Characterization”, Computers in biology and medicine, vol. 48, pp. 133-149, May 2014.
- [16] R. J. Martis, U. R. Acharya, K. Mandana, A. Ray, and C. Chakraborty, “Cardiac Decision Making Using Higher Order Spectra”, Biomedical Signal Processing and Control, Vol. 8, Issue 2, pp. 193-203, Mar 2013.
- [17] Y. Li, R. Qian, K. Li, “Inter-patient arrhythmia classification with improved deep residual convolutional neural network”, Computer Methods and Programs in Biomedicine, vol. 214, p.106582, Feb 2022.
- [18] C. Chen, Y. Lin, S. Lee, W. Tsai, T. Huang, Y. Liu, M. Cheng, C. Dai, “Automated ECG classification based on 1D deep learning network Methods”, Methods, vol. 202, pp. 127-135, Jun 2022.
- [19] J. Takalo-Mattila, J. Kiljander and J. Soinen, “Inter-Patient ECG Classification Using Deep Convolutional Neural Networks”, 21st Euromicro Conference on Digital System Design (DSD), pp. 421-425, 2018.
- [20] J. Wang, R. Li, B. Fu, C. Xiao, and D. Z. Chen, “Towards interpretable arrhythmia classification with human-machine collaborative knowledge representation”. IEEE Transactions on Biomedical Engineering, 68(7), pp.2098-2109, 2020.
- [21] Y. Zhang, J. Li, S. Wei, F. Zhou, and D. Li, “Heartbeats Classification Using Hybrid Time-Frequency Analysis and Transfer Learning Based on ResNet”. IEEE Journal of Biomedical and Health Informatics, 25(11), pp.4175-4184, 2021.
- [22] A. Sellami, H. Hwang, “A robust deep convolutional neural network with batch-weighted loss for heartbeat classification”, Expert Systems with Applications, Vol. 122, pp. 75-84, May 2019.
- [23] <https://physionet.org/content/mitdb/1.0.0/>
- [24] S. Kiranyaz, T. Ince and M. Gabbouj, “Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks”, IEEE Transactions on Biomedical Engineering, vol. 63, no. 3, pp. 664-675, Mar 2016.
- [25] F. Chollet, “Deep Learning with Python”, Manning Publications, 2018. S. Ioffe, C. Szegedy, “Batch normalization: accelerating deep network training by reducing internal covariate shift”, International Conference on Machine Learning, pp. 448-456, Feb 2015.
- ## ۵- مراجع
- [1] S. Sahoo, M. Dash, S. Behera, S. Sabut, “Machine Learning Approach to Detect Cardiac Arrhythmias in ECG Signals: A Survey”, IRBM, Vol 41, Issue 4, pp. 185-194, Jan 2020.
- [2] S. H. Choi, H. Yoon, H. B. Kim, H. S. Kim, H. B. Kwon, S. M., Oh, Y. J., Lee and K. S. Park, “Real-time apnea-hypopnea event detection during sleep by convolutional neural networks” Computers in biology and medicine, No. 100, pp. 123-131, 2018.
- [3] Moini J. “Cardiopulmonary Pharmacology for Respiratory Care”, Jones & Bartlett Learning, Nov 2010.
- [4] R. J. Martis, U. R. Acharya, L. C. Min, “Ecg Beat Classification Using Pca, Lda, Ica and Discrete Wavelet Transform”. Biomedical Signal Processing and Control, Vol. 8, Issue 5, pp. 437-448, 2013.
- [5] Conover, M.B, “Understanding electrocardiography”, Elsevier Health Sciences, 2002.
- [6] T. Mikolov, S. Kombrink, L. Burget, J. Černocký and S. Khudanpur, “Extensions of recurrent neural network language model”, 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 5528-5531, 2011.
- [7] A. Graves, A. Mohamed and G. Hinton, “Speech recognition with deep recurrent neural networks”, 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 6645-6649, 2013.
- [8] H. M. Rai, A. Trivedi, and S. Shukla, “ECG signal processing for abnormalities detection using multi-resolution wavelet transform and Artificial Neural Network classifier”, Measurement, vol. 46, no. 9, pp. 3238 – 3246, May 2013.
- [9] M. Koruürek and B. Doğan, “ECG beat classification using particle swarm optimization and radial basis function neural network”, Expert Systems with Applications, vol. 37, no. 12, pp. 7563-7569, May 2010.
- [10] G. Garcia, G. Moreira, D. Menotti, E. Luz, “Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO”, Scientific Reports, vol. 7, no. 1, pp. 1-11, Sep 2017.
- [11] R. Soleimani, S. Rouhani, “Heart arrhythmia diagnosis by neural networks using chaotic features of HRV signal and generalized discriminant analysis”, Iranian Journal of Biomedical Engineering, vol. 5, no. 2, pp. 89-103. Jun 2011.
- [12] S. Karpagachelvi, M. Arthanari, and M. Sivakumar, “Classification of Electrocardiogram Signal With Extreme Learning Machine and Vector Machine”, Neural Computing and Applications, vol. 8, no. 1, Sep 2011.
- [13] B. Castro, D. Kogan and A. B. Geva, “ECG feature extraction using optimal mother