

داده افزایی گوسی نمونه‌های مرزی و انتخاب توزیع محور جهت بهبود دسته بندی آریتمی‌های قلبی با شبکه‌های عصبی عمیق

محمد یوسف خسروی خلیران^۱، دانشجوی کارشناسی ارشد، ایمان ذباح^۲، استادیار، رضا ابراهیم پور^۳، استاد

۱- گروه هوش مصنوعی - دانشکده مهندسی کامپیوتر، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران usef.khosravi@gmail.com

۲- گروه برق و کامپیوتر - واحد تربت حیدریه، دانشگاه آزاد اسلامی، تربت حیدریه، ایران - Imanzabbah@gmail.com

۳- گروه هوش مصنوعی - دانشکده مهندسی کامپیوتر، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران، rebrahimpour@sru.ac.ir

چکیده: بیماری‌های قلبی یکی از شایع‌ترین انواع بیماری‌ها و عامل ۳۱٪ از مرگ و میرهای بشر است. آریتمی‌ها، ضربان‌های غیرطبیعی قلب و ناشی از عوامل، مشکلات و بیماری‌های مختلف هستند. پژوهشگران جهت شناسایی خودکار و طبقه بندی انواع آریتمی‌های قلبی روش‌ها و دسته بندهای مختلفی ارائه داده اند. شبکه‌های عصبی عمیق پیچشی یا CNN، از بهترین مدل‌هایی هستند که در صورت وجود تعداد نمونه ی آموزش کافی، عملکرد قابل قبولی ارائه می‌دهند. در داده کاوی پزشکی تعداد نمونه‌های کم آموزشی در برخی از کلاسها بسیار محتمل است و این چالش موجب می شود که مدل طبقه بند به سمت کلاسه‌های اکثریت همگرا شده و طبقه بندی را دچار مشکل کند. داده افزایی یکی از رویکردهای رایج مورد استفاده محققین در برخورد با این چالش است. در این مطالعه به منظور حل چالش مذکور درتعداد نمونه‌های محدود آموزشی در برخی از کلاس‌های آریتمی‌های قلبی روشی مبتنی بر کنترل کننده پراکندگی ارائه شده است تا با انتخاب دقیق تر نمونه‌های حاصل از داده افزایی، فضای پراکندگی بالقوه و ممکن نمونه‌ها در دنیای طبیعی به خوبی پوشش داده شود. برای انتخاب روش موثر دسته بندی انواع آریتمی‌ها، ۳ معماری مختلف CNN و ۷ روش متفاوت داده افزایی مقایسه شده اند. بدین منظور با مرتب کردن نمونه‌های مصنوعی، روش داده‌افزایی برتر بر اساس شاخصهای وزن و میزان مرزی بودن و انتخاب تعداد لازم نمونه‌های مصنوعی با گزینه ی برتر از میان ۵ توزیع مختلف انجام می‌شود. در طول روش داده افزایی معرفی شده، از میان ۳ معماری CNN، معماری موسوم به ۱۶ لایه و از میان ۷ جفت روش داده افزایی-شدت مختلف، داده افزایی ترکیبی انحراف دامنه-تغییر مقیاس با شدت ۵٪ و از میان ۵ توزیع انتخاب، توزیع ترتیبی و از میان حجم‌های داده‌افزایی ۱، ۲، ۳ و ۴ برابر کلاس اکثریت، حجم ۲ منجر به کسب نتایج برتر شده است. نتایج بدست آمده نشان می‌دهد مدل ارائه شده ضمن بهبود نتایج دسته بندی در ۱۷ کلاس از داده‌های نامتوازن MIT-BIH و بخصوص آریتمی‌های با نمونه کم، توانسته است به صحت ۹۶٫۹۲٪ دست یابد. روش ارائه شده می‌تواند در داده افزایی سایر داده‌های سری‌های زمانی دوره ای به کار رود.

واژه‌های کلیدی: یادگیری عمیق، داده افزایی، الکتروکاردیوگرام، سری‌های زمانی، دسته بندی

تاریخ ارسال مقاله: ۱۴۰۱/۰۶/۲۸

تاریخ اصلاح مقاله: ۱۴۰۴/۰۴/۲۵

تاریخ پذیرش مقاله: ۱۴۰۴/۰۵/۲۵

نام نویسنده مسئول: ایمان ذباح

نشانی نویسنده مسئول: گروه برق و کامپیوتر، دانشگاه تربت حیدریه، تربت حیدریه، خراسان رضوی، ایران.

Data Augmentation on Marginal samples and distribution-based selection to improve ECG signal classification with deep learning

Mohammad Usef Khosravi Khaliran, student¹, Iman Zabbah, Assitant Professor², Reza Ebrahimpour, Professor³

1- faculty of Computer Engineering Shahid Rajaee Teacher Training University, Iran

2- Department of Computer, Torbat-e-Heydariyeh branch, Islamic Azad University, Torbat-e-Heydariyeh, Iran

3- faculty of Computer Engineering Shahid Rajaee Teacher Training University, Iran

Abstract: One of the most prevalent forms of illnesses, heart problems account for 31% of fatalities among people. Arrhythmias are irregular heartbeats brought on by a variety of conditions, issues, and diseases. Deep convolutional neural network, or CNN, is now one of the best techniques and categories for the automated detection and categorization of cardiac arrhythmias. CNN performs best when given a large number of training instances. However, due to the rarity of illnesses, certain classes in the database have relatively few samples, which may be made up for by employing efficient data augmentation techniques. In order to select a reliable strategy for identifying arrhythmias, 3 distinct CNN architectures, and 7 various data augmentation techniques have been examined in this work. A dispersion controller is introduced as a specific innovation to cover the potential dispersion space of samples happening in the natural world in order to select a better dispersion of samples created by data augmentation techniques and prevent label transfer. This work involves choosing the necessary number of artificial samples with the superior choice among 5 distinct distributions after sorting the artificial samples of the superior data augmentation technique based on the weight and borderline index. The combined amplitude deviation-scale change data augmentation with 5% intensity, among the 17 pairs of different intensity-data augmentation methods, among the 3 CNN architectures, the so-called 16-layer architecture, among the 5 selection distributions, Sequential distribution, and among the data augmentation volumes of 1, 2, 3 and 4 times the majority class, volume 2 has produced the best results during the data augmentation method. The findings demonstrate that the proposed model has improved classification outcomes in 17 classes of MIT-BIH imbalanced data, particularly arrhythmias with limited samples while achieving 96.92% accuracy. Other periodic time series data can be added using the manner that is being demonstrated.


Keywords: Deep Learning, Data Augmentation, Electrocardiogram, Times Series, Classification



۱- مقدمه

بر اساس گزارشات پزشکی منتشر شده، بیماری‌های قلبی-عروقی از عمده علت‌های مرگ و میر بشر هستند [1]. به طوری که علت ۳۱٪ از مرگ‌ها را به خود اختصاص داده است [2]. یکی از علت‌های بیماری‌های قلبی-عروقی، بی‌نظمی‌های ضربان قلب است بطوری که ضربان قلب انحرافات نسبت به الگوی عادی پیدا می‌کند [3]. هرچند انواع زیادی از ضربان قلب غیر طبیعی وجود دارد اما دسته بندی دقیق بیماری‌های قلبی می‌تواند به تشخیص و درمان آن کمک کند [4].

سیگنال الکتروکاردیوگرام یا ECG، ابزاری مطمئن و بدون عارضه است که به طور گسترده در تشخیص بیماری‌های قلبی-عروقی به کار می‌رود. و از ۱۲ جریان تشکیل شده است [5]. نمونه‌ای از دو سیگنال قلبی سالم و با آریتمی فوق بطنی در شکل ۱ قابل مشاهده است.



شکل ۱ الف- سیگنال ECG قلب سالم ب- سیگنال ECG قلب با آریتمی فوق بطنی [۶]

متخصصان قلب به طور سنتی، تفسیر سیگنال‌های ECG را به صورت دستی و غیر ماشینی و بر اساس ضوابط تشخیصی و تجربه انجام می‌دهند. علاوه بر این که تشخیص دستی زمان بر است و نیاز به تخصص دارد تشخیص غلط، تصمیمات بالینی اشتباهی را در پی خواهد داشت و سلامتی و زندگی انسان را تهدید می‌کند. لذا تشخیص نوع آریتمی‌های قلب و عیب شناسی دقیق و خودکار سیگنال‌های ECG موضوع مورد توجه بسیاری از محققین در سال‌های اخیر بوده است [۷].

الگوریتم‌های هوش مصنوعی و در دسترس بودن مجموعه‌های عمومی و متن باز داده‌های ECG در این راه بسیار کارآمد بوده‌اند. در یک دسته بندی کلی پژوهش‌های مربوطه در سه دسته قابل تقسیم‌اند. اول روش‌هایی که بدون استخراج ویژگی اقدام به دسته بندی می‌کنند. دوم روش‌هایی که یک فاز اولیه و مجزای استخراج ویژگی دارند و سوم روش‌های بدون نیاز به استخراج ویژگی مستقل، که در واقع قابلیت استخراج ویژگی به طور ضمنی در فرایند آموزش آن‌ها در هم تنیده است و در حال حاضر شبکه‌های عصبی عمیق پیچشی از آن دسته‌اند.

دسته ی اول را می‌توان روش‌های طبقه بندی سری‌های زمانی، بدون استخراج ویژگی خاص و با در نظر گرفتن فاصله ی نمونه‌ها از یکدیگر در نظر گرفت. بعنوان مثال یک روش موثر و استاندارد طلایی^۲، ترکیب

k نزدیک ترین همسایه با فاصله ی پویای مشرف بر انحراف زمان^۲ یا به اختصار DTW است. در این روش در الگوریتم k نزدیک ترین همسایه، نسخه ای از فاصله ی اقلیدسی با قابلیت شناسایی نقطه ی متناظر جابجا شده در زمان به نام DTW به کار رفته است؛ که در کارهایی مانند روش کخ و همکاران [۸] نمود دارد. پس از این دسته، روش‌ها و نتایج بهتری ارائه شده است که کاربرد آن را به حاشیه برده است.

در دسته ی دوم طبقه بندی سیگنال‌های ECG، ابتدا استخراج ویژگی و سپس طبقه بندی انجام شده است. بعنوان مثال جازول و همکاران [۹] ویژگی‌های فاصله‌های ریخت شناسی و فاصله‌های داخلی تیش قلب یا QRS و فاصله‌های یک دوره ی قله به قله ی ضربان قلب یا RR را استخراج کرده‌اند و با دسته بندی بیزین و تحلیل تشخیصی خطی وزن دار^۴ اقدام به شناسایی و دسته بندی آریتمی‌های قلبی کرده‌اند. در کارهای لامدو و همکاران [۱۰] و همچنین مار و همکاران [۱۱] الگوریتم انتخاب پیشاپیش متغیر ترتیبی استفاده شده است تا مشخصه‌های مرتبط از ویژگی‌های متنوع تر و گسترده تر استخراج شود. در پژوهش‌هایی مانند پژوهش توماس و همکاران [۱۲] نیز از ویژگی‌هایی شامل مولفه‌های فرکانسی و تبدیل موجک گسسته استفاده شده است. از آن جایی که مشکل عدم توازن باعث بیش برآش دسته بند به سمت کلاس اکثریت می‌شود الگوریتم‌های حساس به هزینه معرفی شدند و از طرفی به مرور زمان دسته بندهای جدیدتر و موثرتر مانند ماشین بردار پشتیبان [۱۳] به کار گرفته شده‌اند. روش‌های ترکیبی نیز در این دسته معرفی شده است به طوری که دسته بندهای مختلف بر روی ویژگی‌های استخراج شده ی مختلف در کنارهم، به کار گرفته شده‌اند. بعنوان مثال همایی نژاد و همکاران [۱۴] ویژگی‌های مکانی ضربان قلب را استخراج می‌کنند و ترکیب وزن داری از 6 دسته بند را بر روی آن‌ها به کار گرفته‌اند. در مورد روش‌های ذکر شده پیش پردازش و مهندسی داده‌ها بایستی مورد توجه قرار گیرد اما در مدل‌هایی مانند شبکه‌های عصبی عمیق پیچشی که در این مطالعه مورد استفاده قرار گرفته است با توجه به استخراج ویژگی خودکار، نیازی به این کار نیست.

دسته ی سوم که جدیدتر و موفق تر است، به کارگیری شبکه ی عصبی عمیق پیچشی یا CNN است که در آن استخراج ویژگی به صورت خودکار انجام می‌شود. CNN زیر شاخه ای از یادگیری عمیق است. یادگیری عمیق در سال‌های اخیر نوآوری و کاربردهای بسیار زیادی را به همراه داشته است. از جمله این موارد پردازش تصویر، پردازش زبان طبیعی، بازی‌های رایانه ای و کاربردهای پزشکی است [۱۵]. همچنین به منظور تشخیص بسیاری از بیماری‌های نوظهور نیز مورد توجه محققین قرار دارد [۱۶]. CNN در طبقه بندی انواع داده‌ها از جمله سیگنال‌های ECG توانسته نتایج بسیار خوبی را کسب کند. بطور مثال در پژوهش وانگ و همکاران [۱۷] جهت دسته بندی سیگنال‌های ECG، ۱۱ روش طبقه بندی سیگنال از جمله دسته بندی با DTW، شبکه‌های عصبی پرسپترون چند لایه و شبکه ی عمیق پیچشی تماما

پژوهش‌ها و همکاران [۱۹] باز هم طی طبقه‌بندی عمیق انتها به انتها، یک معماری موثرتر بسیار عمیق Resnet یک بعدی، با ۳۳ لایه ی پیچشی ارائه شده است. اما در این مطالعات به عدم توازن در نمونه‌های آریمتی مورد نظر و حجم اندک نمونه‌ها توجه نشده است و به طور کلی سعی شده است که طبقه‌بندی کلی مورد توجه قرار گیرد، در این شرایط زمانی که تعداد نمونه‌ها از یک کلاس خاص کم باشد مدل یادگیر را به سمت کلاس اکثریت پیش می‌برد و منجر به بروز چالش می‌شود. و از طرفی نیاز یادگیری عمیق به حجم انبوه داده‌ها [۲۰] مرتفع نمی‌شود. برای حل این مشکل می‌توان با داده‌افزایی به آموزش و کسب نتایج بهتر شبکه‌های عمیق کمک کرد.

متصل و شبکه‌ی عمیق پیچشی ResNet یک بعدی مورد مقایسه قرار گرفته‌اند که شبکه‌ی عمیق پیچشی تماماً متصل موفق‌تر بوده است. در پژوهش دیگری توسط حسینی و همکاران [۱۸] با تبدیل سیگنال ECG به تصویر با استفاده از شبکه‌ی کانولوشن دوبعدی طبقه‌بندی صورت گرفته است که اشکال وارد بر آن پیچیدگی زمانی بالا در پردازش تصویر است که به جای آن می‌توان از شبکه‌های CNN یک بعدی برای پردازش مستقیم سیگنال استفاده نمود. نمونه‌ی آن پژوهش ییلدیرین و همکاران [۶] است که با کاربرد انتها به انتهای شبکه‌ی عمیق که در آن از قطعه‌بندی یا پیش‌پردازش‌های خاص استفاده نشده است سعی شده است معماری شبکه‌ی پیچشی یک بعدی موثری برای دسته‌بندی سیگنال خام ECG ارائه شود. در

جدول ۱ مروری بر انواع طبقه‌بندی‌های اخیر برای دسته‌بندی سیگنال‌های ECG

پژوهش	سال	کلاس	پایگاه داده	مجموعه ویژگی	نوع طبقه‌بند	صحت	ضعف
چازل [۹]	۲۰۰۴	۵	MIT-BIH	ریخت شناسی، فواصل ضربان قلب (QRS)، فواصل RR	آنالیز تشخیص خطی (LDA)	۷۷٫۷٪	نتیجه
کنخ [۸]	۲۰۰۵	۲	Fetal ECG	داده‌ی خام	KNN	۶۷٪	نتیجه
لامدو [۱۰]	۲۰۱۱	۵	MIT-BIH	ریخت شناسی، فواصل QRS، فواصل RR با روش انتخاب ویژگی جستجوی رو به جلو	آنالیز تشخیص خطی	۹۳٪	تعداد کلاس
مار [۱۱]	۲۰۱۱	۴	MIT-BIH	زمانی، آماری، ریخت شناسی، فواصل QRS، فواصل RR با روش انتخاب ویژگی جستجوی رو به جلو	آنالیز تشخیص خطی، SVM، MLP	۹۴٪	تعداد کلاس
همایی نژاد [۱۳]	۲۰۱۱	۸	MIT-BIH	ویژگی‌های مکانی QRS	SVM	۹۵٫۱٪	تعداد کلاس
همایی نژاد [۱۴]	۲۰۱۲	۷	MIT-BIH	ویژگی‌های مکانی QRS	KNN, SVM, MLP	۹۸٫۱٪	تعداد کلاس
توماس [۱۲]	۲۰۱۵	۵	MIT-BIH	مولفه‌های فرکانسی و تبدیل موجک گسسته	MLP	۹۴٫۶٪	تعداد کلاس
وانگ [۱۷]	۲۰۱۷	۲	UCR	داده‌ی خام	1D-CNN	۹۸٫۵٪	تعداد کلاس
ییلدیرین [۶]	۲۰۱۸	۱۷	MIT-BIH	داده‌ی خام	1D-CNN	۹۱٫۳٪	نتیجه
حسینی [۲۰]	۲۰۲۰	۱۷	MIT-BIH	تصویر داده خام	2D-CNN	۹۶٫۷٪	پیچیدگی
هانون [۱۹]	۲۰۲۰	۱۲	personal data	داده‌ی خام	1D-CNN (Resnet)	۹۷٫۸٪	تعداد کلاس

عدد میان خط مستقیم دو ویژگی متناظر دو نمونه‌ی موجود مقدار گذاری می‌شود. هی و همکاران [۲۵] روش ADASYN را ارائه داده‌اند که همانند روش SMOTE است اما با این تفاوت که شانس بیشتری برای داده‌افزایی پیرامون نمونه‌های مرزی تر یا سخت-تشخیص قائل شده‌اند. در این روش نمونه‌ها براساس بیشتر بودن تعداد نمونه‌های کلاس‌های مخالف در K نزدیک‌ترین همسایه، مرزی تر و پرچالش‌تر در نظر گرفته می‌شوند. اکسی و همکاران [۲۶] داده‌افزایی گوسی نمونه‌های مرزی با عنوان GDO را ارائه داده‌اند. آن‌ها با شاخصی مبتنی بر تعداد و مجموع فاصله‌ها با نمونه‌های کلاس مخالف در k نزدیکترین همسایه نمونه‌های مرزی را ارزش گذاری می‌کنند و با مکانیزم چرخ رولت شانس بیشتری برای انتخاب نمونه‌های مرزی تر قائل می‌شوند و داده‌افزایی را حول آن‌ها با پراکندگی گوسی انجام می‌دهند. شیوه‌ی انتخاب نمونه‌های مرزی برای داده‌افزایی در دو روش ADASYN و GDO موثر است که در این مطالعه طی یک نوآوری خاص، با اعمال یک رگولاسیون انتخاب توزیع محور، مورد استفاده قرار گرفته است که باعث انعطاف و تنظیم شدت انتخاب نمونه‌های مرزی

با توجه به این که تعداد نمونه‌های برخی از کلاس‌های بیماری قلبی و عروقی در پایگاه داده‌های موجود بسیار کم است، بعنوان یک راهکار اقدام به تولید داده‌های مصنوعی می‌شود. در زمینه‌ی داده‌افزایی سیگنال‌های ECG روش‌هایی مانند جایگشت در پژوهش پن و همکاران [۲۱] بررسی شده است. همچنین داده‌افزایی عمیق با شبکه‌های مولد تخصصی در پژوهش چن و همکاران [۲۲] صورت گرفته است. حاتمیان و همکاران [۲۳] تاثیر داده‌افزایی با شبکه‌ی مولد تخصصی یک بعدی پیچشی و روش ترکیبی گوسی را بررسی کرده‌اند. در مورد داده‌افزایی‌های فوق‌الاولا انواع روش‌های داده‌افزایی به کار گرفته و مقایسه نشده است و عموماً به بررسی تعداد کمی از روش‌ها پرداخته‌اند. از طرفی در میان نمونه‌های مصنوعی تولید شده ارزیابی و انتخاب نمونه‌های بهتر انجام نشده است که در این مطالعه مورد بررسی قرار گرفته است.

روش‌های مختلفی برای داده‌افزایی ارائه شده است. یکی از اولین و شناخته‌شده‌ترین روش‌های داده‌افزایی روش SMOTE است که چاولا و همکاران [۲۴] ارائه داده‌اند و طی آن هر ویژگی نمونه‌ی جدید با

افزایی در حجم‌های ۲ تا ۳۰ برابری در تصاویر بافت‌های سرطانی، در حجم ۷ برابری شاهد بهبود نتایج به میزان ۱۲٪ بوده‌اند. بنابر این در این مطالعه داده افزایشی تا سقف ۱ و ۲ و ۳ و ۴ برابری حجم کلاس اکثریت نیز مورد بررسی قرار می‌گیرد.

در این مطالعه به منظور دسته‌بندی سیگنال‌های ECG از یادگیر عمیق CNN (به عنوان که یکی از بهترین طبقه‌بندهای حاضر) استفاده شده است. بدین منظور ابتداء، داده افزایشی در کلاس‌هایی که تعداد نمونه اندکی دارند، انجام شده است. این نکته در بسیاری از مطالعات ذکر شده مورد توجه محققین نبوده است. چالش دیگر تولید نمونه مصنوعی این است که آیا راهی برای کنترل پراکندگی نمونه‌های تولید شده وجود دارد تا انتقال برچسب صورت نگیرد؟ برای این مورد نیز، یک نوآوری با انتخاب توزیع محور نمونه‌های مصنوعی مرزی در این مطالعه ارائه شده است تا بتوان در نواحی تداخل کلاس‌ها از مناطق مرزی با کاربرد توزیع‌های مختلف با شدت مناسب دوری کرد. نوآوری دیگری که در این مطالعه مورد نظر بوده است پاسخ به این سوال است که با توجه به طول دوره‌های متفاوت در ضربان قلب در افراد مختلف، و عدم انطباق نمونه‌های ECG، چه روشی برای مقایسه‌ی صحیح نمونه‌ها به کار گرفته شود تا نمونه‌های مرزی تعیین شوند؟ برای حل این چالش هر نمونه سیگنال ECG که رکوردی طولانی مدت از تپش‌های قلب است به قطعاتی به طول یک دوره ی RR تپش قلب تفکیک می‌شود و سپس با نرخ نمونه برداری یکسان، تپش‌های قلب یکسان با طول مساوی و قابل انطباق به دست می‌آیند.

می‌شود. شیوه‌ی تولید نمونه در دو روش ADASYN و GDO برای نمونه‌های با ویژگی‌های مستقل و با همبستگی کم مناسب است و به دلیل تغییر مجزای هر نقطه از سیگنال، فارغ از توجه به نقاط اطراف، برای داده‌های نوع سیگنال انحراف نرمی در سیگنال ایجاد نمی‌کند و بیشتر شبیه افزودن نویز عمل می‌کند. بنابراین در مرحله‌ی تولید نمونه، باید شیوه‌ای متناسب سیگنال انتخاب شود. در پژوهش یام و همکاران [۲۷] انواع روش‌های جایگشت، چرخش، تغییر مقیاس، انحراف دامنه و انحراف زمان مورد بررسی قرار گرفته است که روش انحراف زمان ۱۱٫۶۸٪ و روش ترکیبی جایگشت+چرخش+انحراف زمان توانسته نتایج را ۱۶٫۱۶٪ نسبت به حالت بدون داده افزایشی بهبود بخشد. روش Robustad [۲۸] داده افزایشی با تغییر مولفه‌های فرکانسی را ارائه داده است. طبق پژوهش ایوانا و همکاران [۲۹] تولید نمونه برای سری‌های زمانی و سیگنال‌ها، در حداقل ۵ فضای مختلف شامل دامنه، زمان، فرکانس، ویژگی‌های آماری و فضای پنهان قابل درک با روش‌هایی مانند شبکه‌های عصبی و تجزیه می‌تواند اتفاق افتد. در پژوهش فونز و همکاران [۳۰] کاربرد ۱۰ روش داده افزایشی در کنار هم استفاده شده که نتیجه بخش بوده است. بنابراین در این مطالعه علاوه بر این که شانس بیشتری به داده افزایشی حول نمونه‌های مرزی داده می‌شود؛ ۷ روش داده افزایشی مختلف بررسی و بهترین آن‌ها مورد استفاده قرار می‌گیرد. بعد دیگری که در داده افزایشی باید مورد توجه قرار گیرد حجم داده افزایشی است، ساکایی و همکاران [۳۱] حجم‌های ۳ و ۵ و ۷ برابری داده افزایشی را در سیگنال بررسی کرده‌اند و دریافته‌اند که در حجم ۳ برابر نتایج ۶٪ بهبود یافته است. لیو و همکاران [۳۲] با داده

جدول ۲ مروری بر انواع روش‌های داده افزایشی اخیر برای سیگنال

پژوهش	سال	نوع	روش داده افزایشی	ضعف
SMOTE [۲۴]	۲۰۰۵	هندسی	تولید نمونه بین فاصله‌ی اقلیدسی ویژگی‌های متناظر نمونه‌های موجود	تغییر مجزای هر نقطه و کارایی اندک برای سیگنال (برای سیگنال شبیه اعمال نویز عمل می‌کند).
ADASYN [۲۵]	۲۰۰۴	هندسی- آماری	داده افزایشی با نمونه‌های مرزی ضمن تولید نمونه پراکندگی محور بین فاصله‌ی اقلیدسی ویژگی‌های متناظر نمونه‌های موجود (پراکندگی حسب تعداد نمونه‌های کلاس مخالف)	تغییر مجزای هر نقطه و کارایی اندک برای سیگنال (برای سیگنال شبیه اعمال نویز عمل می‌کند).
GDO [۲۶]	۲۰۱۱	هندسی- آماری	داده افزایشی با نمونه‌های مرزی ضمن تولید نمونه پراکندگی محور بین فاصله‌ی اقلیدسی ویژگی‌های متناظر نمونه‌های موجود (پراکندگی حسب تعداد و فاصله‌ی نمونه‌های کلاس مخالف)	تغییر مجزای هر نقطه و کارایی اندک برای سیگنال (برای سیگنال شبیه اعمال نویز عمل می‌کند).
پن [۲۱]	۲۰۱۱	جایگشت	جایجایی بخش‌های تصادفی از سیگنال در زمان	در سیگنال‌های دوره‌ای منظم سیگنال‌های غیر معمول تولید می‌کند.
حاتمیان [۲۳]	۲۰۲۰	GAN	داده افزایشی با شبکه‌های عمیق GAN	نیاز به نمونه‌های زیاد برای تولید نمونه‌ی باکیفیت، که در ابتدا در دسترس نیست.
چن [۲۲]	۲۰۱۹	GAN	داده افزایشی با شبکه‌های عمیق GAN	نیاز به نمونه‌های زیاد برای تولید نمونه‌ی باکیفیت، که در ابتدا در دسترس نیست.
یام [۲۷]	۲۰۱۷	هندسی	کاربرد انواع نگاشت مکانی: تغییر مقیاس، انحراف دامنه، انحراف زمان، چرخش، جایگشت و ترکیب آن‌ها	به پراکندگی نمونه‌ها توجه خاصی نشده است.
Robustad [۲۸]	۲۰۲۰	فرکانسی	تغییر مولفه‌های فرکانسی سیگنال	به پراکندگی نمونه‌ها توجه خاصی نشده است.
فونز [۳۰]	۲۰۲۱	ترکیبی	کاربرد ۱۰ روش مختلف داده افزایشی با روش α -trim و حذف تعداد α داده افزایشی که کمترین و بیشترین خطا را دارند.	به بررسی حجم‌های مختلف داده افزایشی توجهی نشده است.

مطالعه حاضر	۲۰۲۳	ترکیبی	استفاده از روش‌های فوق به همراه معرفی رگولاسیون توزیع انتخاب نمونه‌های مرزی و در نظر گرفتن حجم داده افزایشی	نسبت به روش‌های فوق اندکی زمان بر است.
-------------	------	--------	---	--



شکل ۲. دیاگرام روش MDADS. در مرحله ی تولید نمونه‌های مصنوعی، تولید و ذخیره ی نمونه تا ۱۰ برابر حجم کلاس اکثریت انجام می‌شود. در مرحله ی تعیین روش داده افزایشی با شدت مناسب، ۱۷ جفت روش داده افزایشی-شدت بررسی می‌شود. در مراحل انتخاب روش داده افزایشی برتر و توزیع برتر، حجم داده افزایشی هر کلاس تا ۲ برابر کلاس اکثریت است.

آخرین نوآوری این پژوهش بررسی حجم داده افزایشی مورد نیاز است. بدین منظور و جهت پاسخ به آن، در مرحله ی بعد حجم‌های مختلف داده افزایشی بررسی می‌شود تا یک حجم مناسب انتخاب گردد. در نهایت، با انجام مراحل فوق، در کیفیت بخشی به داده افزایشی سیگنال‌های ECG گام‌های موثری برداشته شده است. انواع روش‌های داده افزایشی ذکر شده بطور خلاصه در جدول ۲ آمده است.

در مطالعه ی حاضر، ابتدا سیگنال‌های ECG به روش فاصله‌های قله به قله (RR)، قطعه بندی و با نمونه برداری مجدد با نرخ مشخص، قطعات و نمونه‌های با طول یکسان به دست می‌آیند. این قطعات به عنوان نمونه‌های جدید و به نمایندگی از کلاس خود مورد پردازش قرار خواهند گرفت. بعد از آن، به منظور برقراری توازن در تعداد نمونه‌های کلاس‌ها و تقویت آموزش شبکه ی عصبی عمیق، داده افزایشی با در نظر گرفتن اولویت در داده‌های مرزی انجام می‌شود. سپس با یک توزیع برتر و مناسب تر، از بین نمونه‌های مصنوعی تولید شده، مجموعه ی نهایی انتخاب می‌شود و با حجم مناسب به همراه نمونه‌های واقعی، جهت آموزش شبکه ی عصبی عمیق کانولوشنی مورد استفاده قرار می‌گیرند. این عملیات برای ۷ روش داده افزایشی انجام می‌شود تا روش منتخب تعیین و مورد استفاده قرار گیرد. مقایسه ی نتایج روش ارائه شده با سایر روش‌های اخیر کارایی آن را تایید می‌کند.

۲- روش پیشنهادی و پایگاه داده:

روش داده افزایشی نمونه‌های مرزی با انتخاب توزیع محوره یا به اختصار MDADS مطابق شکل ۲، از ۶ بخش اصلی تشکیل می‌شود: ۱- قطعه بندی سیگنال به دوره‌های متناوب آن و نمونه برداری مجدد و نرمال سازی نمونه‌ها ۲- انتخاب دسته بند برتر ۳- تولید و ذخیره ی نمونه‌های مصنوعی ۴- انتخاب روش داده افزایشی برتر. ۵- اعمال استراتژی وزن دهی اینبار برای نمونه‌های مصنوعی روش داده افزایشی برتر و تعیین توزیع انتخاب برتر برای آن ۶- تعیین حجم داده افزایشی برتر. در ادامه توضیح دقیق تر هر مرحله بیان می‌شود. در این مطالعه جهت کار با داده‌های ECG، از مجموعه داده ی MIT-BIH نسخه ی ۱۷ کلاس‌ه استفاده شده است که رایج ترین داده ی مورد استفاده ی پژوهش‌های اخیر در دسته بندی سیگنال‌های ECG است. در این پایگاه داده، تعداد ۱۰۰۰ نمونه ی سیگنال ECG به طول ۳۶۰۰ نقطه وجود دارد و طبق شکل ۳ شامل حداکثر تعداد ۲۸۳ نمونه در دسته ی افراد سالم و حداقل ۱۰ نمونه در برخی دسته‌های بیماری‌های خاص است و لذا نرخ عدم توازن در آن ۲۸،۳ می‌باشد. هر سیگنال نشان دهنده ی ۱۰ ثانیه ضبط ECG با فرکانس نمونه برداری ۳۶۰ هرتز است که از ۴۵ فرد مبتلا به مشکلات قلبی مختلف و همچنین سالم جمع آوری شده است.

۲-۲- انتخاب معماری برتر CNN

طبقه‌بندی پنجره‌ها با گزینه‌ی برتر از میان سه معماری شبکه‌های پیچشی ۱۶ لایه [۶] یا VGG [۲۹] و یا نسخه‌ی یک بعدی ResNet [۳۴]، انجام می‌شود. پارامترهای این سه شبکه طبق پژوهش‌های مرجع هر کدام انتخاب شده است. برچسب نهایی سیگنال ECG کاملی که قطعه‌بندی شده بود؛ برچسب قطعات یا همان پنجره‌ها، با بیشترین فراوانی، خواهد بود.

۲-۳- وزن دهی:

هر یک از نمونه‌های اولیه‌ی آموزش بر اساس دو شاخص تراکم و فاصله با نمونه‌های کلاس مخالف اطراف، یک وزن دریافت می‌کنند [۲۶]. این وزن برای مشخص شدن نمونه‌های مرزی تر به کار می‌رود به طوری که در مراحل بعد، یک بار جهت تولید و ذخیره‌ی نمونه‌ی مصنوعی مرزی تر تا ۱۰ برابر کلاس اکثریت برای هر کلاس و برای هر روش داده افزایی، و با شدت‌های مختلف داده افزایی و یک بار دیگر جهت تعیین توزیع انتخاب برتر برای نمونه‌های مصنوعی روش داده افزایی برتر به کار می‌رود. شاخص نسبت تراکم از رابطه‌ی (۱) به دست می‌آید:

$$C(X_i) = \frac{|N_i^{maj}|}{K} \quad (1)$$


توسط شاخص ارزیابی فوق، نمونه‌هایی از کلاس اقلیت که در میان K همسایه‌ی خود، بیشترین تعداد همسایه از سایر کلاس‌ها را دارند شاخص نسبت تراکم و به عبارتی شانس بیشتری برای انتخاب شدن خواهند داشت. علاوه بر بررسی تعداد نمونه‌ها طبق رابطه‌ی (۶) با شاخص نسبت فاصله، فاصله‌ها نیز بررسی می‌شود:

تابع dist طبق رابطه (۵) محاسبه می‌شود:

با جمع دو مقدار به دست آمده شاخص اهمیت نهایی طبق رابطه (۴) به دست می‌آید:

شاخص اهمیت نرمال شده‌ی نمونه‌ی X_i نیز بر اساس رابطه (۳) محاسبه می‌شود:


بطوری که مجموع این شاخص‌ها مطابق رابطه (۲) یک خواهد بود:



شکل ۳. فراوانی کلاس‌های مختلف در پایگاه داده‌ی MIT-BIH

۲-۱- پیش پردازش:

در ابتدای این مرحله، سیگنال به دوره‌هایش قطعه‌بندی و با در نظر گرفتن نرخ نمونه برداری مناسب، قطعات به طول یکسان به دست می‌آیند. در این مطالعه از روش قطعه‌بندی به روش قله به قله یا RR مطابق پژوهش [۳۳] که یکی از ساده‌ترین و رایج‌ترین روش‌هاست استفاده شده است. سپس قطعات به بازه‌ی $[1, -1]$ نرمال سازی می‌شوند. با این روش دوره‌های موجود در هر سیگنال استخراج و بعنوان نمونه‌های اصلی در ادامه مورد پردازش قرار خواهند گرفت. نمونه‌ی این قطعه‌بندی در شکل ۴ قابل مشاهده است. هر سیگنال بلند مدت اولیه‌ی تست، به چندین قطعه تقسیم می‌شود و احتمالاً توسط دسته بند برای هر قطعه برچسب متفاوتی تخمین زده می‌شود. سوال این جاست که برچسب نهایی هر سیگنال بلند مدت تست چیست؟ پاسخ این است که برچسب قطعات با فراوانی بیشتر، برچسب نهایی آن سیگنال اصلی طولانی مدت و قطعه‌بندی نشده است.



شکل ۴ قطعه‌بندی سیگنال به روش RR به همراه نمونه برداری مجدد با نرخ ۴۸۰ نقطه

در بازه ی ۰ تا ۱ قرار گرفته و با عدد تصادفی λ طبق رابطه ی (۷) که با احتمال یکنواخت در این بازه تولید می‌شود نمونه مربوطه انتخاب می‌گردد [۲۶].

$$\sum_{i=1}^{k-1} \hat{I}_i < \lambda < \sum_{i=1}^k \hat{I}_i, \quad 1 \leq k \leq n \quad (7)$$

بعد از انتخاب شدن هر نمونه، یک نمونه جدید در محدوده اش با یکی از ۵ روش داده افزایی تولید می‌شود (و به تعداد G طبق رابطه ی (۸) تا رسیدن کلاس اقلیت تا α برابر کلاس اکثریت که در این مطالعه مقدار آن $\alpha=10$ در نظر گرفته شده است، انتخاب نمونه پایه و تولید نمونه جدید بر اساس آن ادامه می‌یابد [۲۶].

$$G = \alpha |T^{maj}| - |T^{min}| \quad (8)$$

همان طور که قبلا اشاره شد، در این مطالعه ۷ روش داده افزایی مقایسه و برترین آن‌ها مورد استفاده قرار می‌گیرد. این روش‌ها به دلیل فضای اعمال تغییرات متفاوتشان انتخاب شده‌اند. انواع روش‌های داده افزایی سری‌های زمانی طبق پژوهش [۲۶] در شکل ۵ ذکر شده است. همچنین مثالی از نمونه‌های تولید شده با هر روش در شکل ۶ قابل مشاهده است. در روش‌های اول تا چهارم شامل تغییر مقیاس، انحراف دامنه، انحراف زمان [۲۷] و گوسی [۲۶] به شکل‌های گوناگون، یک تغییر یا انحراف در سیگنال اولیه با واریانس در محدوده ی مشخص اعمال می‌شود تا یک سیگنال مصنوعی جدید تولید شود. در روش داده افزایی پنجم که تغییر مولفه‌های فرکانسی [۲۸] است با اعمال این تغییرات در فضای فرکانس، سیگنال جدید تولید می‌شود. به این نکته نیز توجه می‌شود که مطابق یافته‌های پژوهش [۲۷] مبنی بر کارایی روش‌های ترکیبی، بر روی نمونه‌های حاصل از دو روش انحراف دامنه و انحراف زمان، مجدداً تغییر مقیاس اعمال می‌شود تا تنوع نمونه‌ها بیشتر شود و توانمندی و پایداری شبکه عصبی با آموزش بر روی نمونه‌های متنوع تر بیشتر شود.

داده افزایی ششم، با استفاده از شبکه ی GAN و بر اساس نسخه ی یک بعدی شبکه ی عصبی عمیق پژوهش [۳۵] انجام شده است. روش داده افزایی هفتم با نوعی از شبکه ی عصبی LSTM انجام شده است که در پژوهش [۳۶] معرفی شده است. برای حل مشکل کمبود داده ی آموزش این دو شبکه ی عصبی عمیق، نه با تکرار نمونه‌های موجود، بلکه همانطور که در پژوهش یام و همکاران [۲۷] داده افزایی ترکیبی ثمر بخش بوده است، از داده‌های تولید شده با سایر روش‌ها استفاده می‌کنند. دو روش عمیق، با حجم کامل نمونه‌های موجود برای هر کلاس بعلاوه ی نمونه‌های مصنوعی دو روش انحراف دامنه و زمان که تغییر مقیاس نیز داشته‌اند در همان کلاس، در دو فاز الف-آموزش و ب-تولید نمونه به تعداد دلخواه، انجام می‌شود.


$$D(X_i) = \frac{\sum_{X_j \in N_i^{maj}} dist(X_i, X_j)}{\sum_{X_j \in N_i^{maj}} dist(X_i, X_j) + \sum_{X_j \in N_i^{min}} dist(X_i, X_j)} \quad (6)$$

$$I(X_i) = \frac{I(X_i)}{\sum_{k=1}^l I(X_{ik})} \quad (5)$$

$$\hat{I}(X_i) = \frac{I(X_i)}{\sum_{i=1}^{|T^{min}|} I(X_i)} \quad (3)$$

$$\sum_{i=1}^{|T^{min}|} \hat{I}(X_i) = 1 \quad (2)$$

برتری روش وزن دهی نمونه‌های مرزی با پژوهش GDO [۲۶] که در این جا طبق روابط بالا مورد استفاده قرار گرفته است، این است که نسبت به پژوهش ADASYN [۲۵] علاوه بر تعداد نمونه‌های کلاس مخالف، مجموع فاصله‌ها با آن‌ها نیز در K همسایه ی اطراف در نظر گرفته شده است که باعث می‌شود نمونه‌های نویزی تر که داخل کلاس‌های مخالف قرار دارند برای داده افزایی کمتر مورد استفاده قرار بگیرند. در مراحل بعدی بار دیگر این روش وزن دهی برای حجم انبوه نمونه‌های مصنوعی تولید شده با روش داده افزایی- شدت منتخب نیز به کار خواهد رفت.



شکل ۵ انواع روش‌های داده افزایی سری‌های زمانی

۲-۴- تولید سیگنال‌های مصنوعی:

بعد از انتساب وزن به هر نمونه که با شاخص اهمیت مرزی بودن در بخش قبل انجام شد با روش انتخاب چرخ رولت بر اساس وزن‌های اختصاص داده شده، هر بار یک نمونه با قابلیت تکرار، انتخاب می‌شود تا تولید نمونه مصنوعی بر اساس آن، هر بار با یک روش داده افزایی- شدت انجام شود. با این شیوه، تولید نمونه از تواهی مرزی بیشتر اتفاق می‌افتد و تا رساندن حجم هر کلاس به ۱۰ برابر کلاس اکثریت برای هر روش داده افزایی- شدت، این کار تکرار می‌شود. در پایان این مرحله، نمونه‌ها برای هر روش داده افزایی- شدت مختلف، برای هر کدام از کلاس‌ها ذخیره می‌شوند. (به جز ۲ روش داده افزایی آخر که از نوع عمیق هستند و بدون شدت‌های مختلف ذخیره می‌شوند). همان طور که گفته شد، در این مرحله، شیوه ی انتخاب با استفاده از روش چرخ رولت انجام می‌شود [۲۶]. طبق این روش که در الگوریتم‌های ژنتیک پر کاربرد است، نمونه‌ها به طول اهمیت یا همافزن نرمال شده ی خود


۲-۵- انتخاب روش داده افزایی-شدت برتر

در این مرحله، از نمونه‌های مصنوعی ذخیره شده در مرحله ی قبل، برای محک زدن کارایی هر روش داده افزایی-شدت استفاده می‌شود. از میان حجم انبوه نمونه‌های مصنوعی هر روش داده افزایی-شدت، تا رساندن تعداد نمونه‌های هکلاس آن روش به ۲ برابر حجم کلاس اکثریت با توزیع انتخاب یکنواخت (تصادفی)، تعداد نمونه ی لازم انتخاب می‌شود. توجه به این نکته ضروری است که درست است که از توزیع یکنواخت (تصادفی) استفاده شده است، اما پراکندگی نمونه‌های مصنوعی انتخاب شده، به دلیل این که نمونه‌های مصنوعی در مراحل قبل با اولویت نمونه‌های مرزی تولید شده بودند، حالت مرزی دارد و نه حالت تصادفی. دسته بندی با نمونه‌های مصنوعی هر روش داده افزایی-شدت که ۱۷ حالت دارد (چون روش‌های عمیق به جای ۳ شدت، یک حالت دارند) بررسی می‌شود و در نهایت روش داده افزایی-شدت برتر مشخص می‌شود. این روش انتخاب، طبق پژوهش GDO [۲۶]، از توزیع قابل قبولی در پوشش نواحی مرزی برخوردار است و از کاربرد روش انتخاب توزیع محور که حجم پردازش را با ۵ توزیع مختلف تا ۵ برابر افزایش می‌دهد خودداری می‌شود. بعد از این که در مرحله حاضر

روش داده افزایی-شدت برتر مشخص شد، در مرحله ی بعد، روش انتخاب توزیع محور با ۵ توزیع مختلف، بر روی روش داده افزایی-شدت برتر انجام خواهد شد.

۲-۶- انتخاب توزیع محور:


در این بخش نوآوری مطالعه ی حاضر اتفاق می‌افتد. فرایند وزن دهی بخش‌های قبل، این بار نه برای نمونه‌های اصلی اولیه، بلکه برای حجم انبوه نمونه‌های ذخیره شده ی روش داده افزایی-شدت منتخب (که در بخش قبل مشخص شده بود) انجام می‌شود و به هر نمونه یک وزن داده می‌شود. این نمونه‌ها طبق وزن خود مرتب می‌شوند تا عملیات انتخاب توزیع محور بر روی آن‌ها انجام شود. در این مطالعه توزیع‌های ترتیبی، نمایی، خطی، تصادفی و نرمال با پارامترهای پیش فرض رایج خود برای انجام این عملیات در نظر گرفته شده اند. با دقت در عملکرد هر یک از این توزیع‌ها مشخص می‌شود که با کاربرد هر کدام به ترتیب نام برده شده، از فراوانی نمونه‌های مرزی با شیب ملایمی کاسته می‌شود. این شیوه نقش کنترل کننده ی پراکندگی را بازی می‌کند که انتخاب طبق شاخص وزن نمونه‌ها از شدت زیاد به کم را ممکن می‌کند.



شکل ۶ نمونه‌های مصنوعی تولید شده با داده افزایی‌های مختلف: الف-نمونه اولیه. ب-تغییر مقیاس. ج-انحراف دامنه +تغییر مقیاس. د-انحراف زمان + تغییر مقیاس. ه-گوسی. و-تغییر مولفه‌های فرکانس. ز-GAN. ح-LSTM

ی رساندن تعداد نمونه‌های هر کلاس تا ۲ برابر حجم کلاس اکثریت است که جهت آموزش به دسته بند CNN داده می‌شوند و کیفیت دسته بندی بررسی می‌شود. در پایان این مرحله یکی از ۵ توزیع برتر برای روش داده افزایی با شدت مشخص برگزیده می‌شود.

در شکل ۷ اثر کاربرد هر کدام از انواع توزیع‌های گفته شده بر روی پراکندگی افقی داده ی فرضی قابل مشاهده است. برای روش داده افزایی-شدت منتخب، ابتدا حلقه‌بوه داده‌های مصنوعی تولید و ذخیره شده ی آن روش در مراحل قبل، طبق وزنشان مرتب و هر بار با یک توزیع، تعداد لازم از آن‌ها انتخاب می‌شود. این تعداد لازم به اندازه



شکل 7 شبیه سازی توزیع نهایی داده‌ها در روش داده افزایی نمونه‌های مرزی با انتخاب توزیع محور

استفاده می‌شود. بنابراین در این مطالعه از روش‌های حذف نویز در پیش پردازش استفاده نشده است. با قطعه بندی به روش RR دوره‌های سیگنال بعنوان نمونه‌های جدید استخراج می‌شوند تا در ادامه به جای سیگنال‌های طولانی مدت، پردازش شوند. در قطعه بندی سیگنال، نرخ نمونه برداری منتخب با توجه به میانگین طول تپش‌های قلب پایگاه داده و طول دوره ی بهینه ی ورودی دسته بند CNN مورد استفاده (که بهتر است مضربی از برخی پارامترهای این شبکه نیز باشد) معادل ۴۸۰ نقطه در نظر گرفته شده است. با توجه به این که در ادامه از الگوریتم شبکه عصبی عمیق پیچشی استفاده خواهد شد که به طور خودکار ویژگی‌های سطح بالا و پنهان را استخراج می‌نماید روش استخراج ویژگی دیگری استفاده نمی‌شود. در هر کدام از ۱۷ کلاس، ۱۰ درصد نمونه‌ها بعنوان آزمایش و ۹۰ درصد باقی بعنوان نمونه‌های آموزش جدا سازی شد. اصولاً در مطالعات و آزمایشات مختلف اگر در دسته بند مورد استفاده از تابع فعالساز سیگموید استفاده شده باشد، نرمال سازی داده‌ها و قطعات به روش کمترین-بیشترین به بازه ی $[0,1]$ انجام می‌شود و اگر از توابع فعالساز ReLU یا tanh استفاده شده باشد، نرمال سازی به بازه ی $[-1,1]$ انجام می‌شود. در این مطالعه با توجه به استفاده از تابع فعالساز ReLU در دسته بندهای CNN به کار رفته، حالت دوم، یعنی نرمال سازی به بازه ی $[-1,1]$ انجام شده است.

۲-۷- حجم داده افزایی:

بعد از این که جفت‌تر داده افزایی-توزیع در مرحله ی قبل تعیین شد، داده افزایی برای رساندن تعداد نمونه‌های هر کلاس به میزان ۱، ۲، ۳ و ۴ برابر کلاس اکثریت مورد بررسی قرار می‌گیرد تا آخرین متغیر یعنی حجم داده افزایی مناسب تعیین شود. در نهایت برترین نتیجه و روش منتخب که یک جفت‌تر داده افزایی-توزیع با حجم داده افزایی مطلوب است در مطالعه ی حاضر مشخص می‌شود.

۳- نتایج شبیه سازی

در این بخش، به ترتیب نتایج پیش پردازش داده‌ها، انتخاب ویژگی، مقادیر پارامترها، دسته بندی و نتایج حاصل آن و در نهایت مقایسه ی نتایج با سایر روش‌ها مطرح می‌شود.

۳-۱- پیش پردازش داده‌ها و انتخاب ویژگی

عموما دسته بندهای مختلف پیش پردازش‌های متناسب خود را می‌طلبند. به دلیل استفاده از شبکه ی عصبی عمیق پیچشی در دسته بندی داده‌ها، که روابط عمیق، پنهان و سطح بالا را شناسایی می‌نماید اولاً در مطالعات مختلف نه تنها مواردی مانند حذف نویز داده‌ها اتفاق نمی‌افتد بلکه جهت تولید نمونه‌های مصنوعی جدید از افزودن نویز نیز

۳-۲- معماری منتخب CNN

برای سیگنال با طول دوره، ماهیت و پراکندگی متفاوت، معماری‌های CNN متفاوتی مناسب تر هستند. در این مطالعه از میان ۳ معماری گفته شده، شبکه عصبی ۱۶ لایه [۶] طبق نتایج بهتر، برگزیده شد. معماری و پارامترهای این شبکه در جدول ۳ قابل مشاهده است.

جدول ۳ جزئیات معماری شبکه عصبی کانولوشنی ۱۶ لایه

فعالساز	گام	اندازه	تعداد فیلتر	نوع لایه
ReLU	۱	۱۲	۱۲۸	Convolution 1
-	-	-	-	Batch Norm
-	۳	-	۲	Max Pool
ReLU	۱	۷	۳۲	Convolution
-	-	-	-	Batch Norm
-	۲	-	۲	Max Pool
ReLU	۱	۱۰	۳۲	Convolution
ReLU	۲	۵	۱۲۸	Convolution
-	۲	-	۲	Max Pool
ReLU	۱	۱۵	۲۵۶	Convolution
-	۲	-	۲	Max Pool
ReLU	۱	۵	۵۱۲	Convolution
-	-	-	-	Flatten
ReLU	-	-	۵۱۲	Dense
SoftMax	-	-	۱۷	Dense (output)

۳-۳- پارامترهای روش پیشنهادی

۷ روش داده افزایی به دلیل فضای عملکردی متفاوت هر یک در این مطالعه به کار گرفته شده اند. برای هر کدام از روش‌ها داده افزایی تغییر مقیاس، انحراف دامنه، انحراف زمان [۲۷]، گوسی [۲۶] و فرکانسی [۲۸]، واریانس مطابق پژوهش‌های مربوطه و پژوهش [۲۹] با شدت‌های مختلف ۰.۵٪ و ۱.۰٪ و ۲.۰٪ مورد ارزیابی قرار گرفته است. براساس نتایج حاصله، این میزان، برای تغییر مقیاس ۲.۰٪، انحراف دامنه ۰.۵٪ و برای انحراف زمان، گوسی و فرکانسی ۱.۰٪، برترین بوده اند و در داده افزایی مربوطه استفاده شده اند. همانطور که قبلاً نیز اشاره شده است برای داده افزایی با دو شبکه ی عمیق GAN و LSTM از داده‌های مصنوعی تولید شده با روش‌های انحراف دامنه و انحراف زمان نیز که تغییر مقیاس نیز بر روی آن‌ها انجام شده است استفاده شده است. در مورد ۵ توزیع به کار رفته هر توزیع با ضرایب μ و σ پیش فرضش به کار رفته است.

۳-۴- نتایج

در دور اول ۳ معماری مختلف CNN بدون داده افزایی بررسی شدند که معماری ۱۶ لایه [۶] به دلیل کسب نتایج بهتر طبق بعنوان دسته بند نهایی تعیین شد.

جدول ۴ نتایج کاربرد معماری‌های مختلف CNN

روش داده افزایی	صحت		
	۱۶ لایه	VGG	ResNet
بدون قطعه بندی/بدون داده افزایی	۴۷.۳	۴۶.۸	۴۵.۷
قطعه بندی/بدون داده افزایی	۶۸.۷	۶۷.۴	۶۵.۹

در دور دوم با هر کدام از ۷ روش داده افزایی و هر یک از ۳ شدت مختلف مربوطه برای ۵ روش داده افزایی اول، که ۱۷ جفت روش داده افزایی- شدت را به دنبال دارد، نمونه ی مصنوعی به صورت جداگانه تولید می شود. برای ۱۷ حالت گفته شده، به تفکیک هر کلاس تا حجم ۱۰ برابر کلاس اکثریت، نمونه ی مصنوعی با اولویت تولید در محدوده ی مرزی، تولید و ذخیره می‌شود. اولویت دهی برای تولید نمونه ی مرزی با شیوه ی وزن دهی و انتخاب نمونه ی پایه با چرخ رولت، که در بخش‌های قبل به تفصیل بیان شد انجام شده است. بر اساس پژوهش‌های گذشته و آزمایشات انجام شده، در معیار وزن دهی نمونه‌های مرزی تعداد نمونه های همسایه یا KNN با مقدار $K=5$ بهترین نتیجه را داشته است. برای بررسی کارایی هر روش داده افزایی، از نمونه‌ها ذخیره شده آن روش داده افزایی در مرحله ی قبل استفاده می‌شود تا حجم نمونه‌های هر کلاس به ۲ برابر کلاس اکثریت برسد. این نمونه‌ها در آموزش دسته بند CNN استفاده می‌شود و در نهایت با مقایسه ی نتایج حاصل از روش‌های داده افزایی مختلف در این بخش روش داده افزایی منتخب با شدت مناسب تر انتخاب می‌شود. نتایج حاصل در این مرحله، حسب معیارهای f1-score و صحت در جدول ۵ قابل مشاهده است. بر اساس نتایج، بهترین روش داده افزایی، ترکیب انحراف دامنه و تغییر مقیاس با شدت اعمال تغییرات ۵٪ بوده است که طی آن صحت دسته بندی ۸۵٪ به دست آمده است. نتایج این مرحله در جدول ۵ ثبت شده است.

جدول ۵ نتایج انواع روش‌های داده افزایی با انتخاب تصادفی نمونه‌های مرزی

روش داده افزایی	شدت	صحت	f1-score
تغییر مقیاس	۵٪	۷۸.۲	۷۸.۱
تغییر مقیاس	۱۰٪	۷۹.۶	۷۹.۵
تغییر مقیاس	۲۰٪	۸۰	۸۱
انحراف دامنه + تغییر مقیاس	۰.۵٪	۸۵	۸۴
انحراف دامنه + تغییر مقیاس	۱۰٪	۸۴.۳	۸۳.۶
انحراف دامنه + تغییر مقیاس	۲۰٪	۸۳.۹	۸۳.۲
انحراف زمان+ تغییر مقیاس	۰.۵٪	۸۲.۵	۸۲.۱
انحراف زمان+ تغییر مقیاس	۱۰٪	۸۳	۸۲
انحراف زمان+ تغییر مقیاس	۲۰٪	۸۲.۱	۸۱.۵
گوسی	۰.۵٪	۷۲.۷	۷۲.۶
گوسی	۱۰٪	۷۳	۷۳
گوسی	۲۰٪	۷۲.۱	۷۰.۸
فرکانسی	۰.۵٪	۷۶.۷	۶۵.۱
فرکانسی	۱۰٪	۷۷.۵	۶۶
فرکانسی	۲۰٪	۷۴.۴	۶۳.۶
GAN	-	۷۲	۶۳.۵
LSTM	-	۷۳	۶۶

و نمونه‌های حاصل از هر کدام در آموزش دسته بند CNN به کار گرفته شود و با مقایسه ی نتایج دسته بندی، توزیع برتر تعیین شود. حجم داده افزایی هر کلاس در این بخش نیز تا رسیدن به ۲ برابر کلاس اکثریت برای هر کلاس بوده است.

در دور سوم، نوآوری این مطالعه به کار گرفته می‌شود که کنترل کننده ی پراکندگی نمونه‌های مصنوعی است. این بار، حجم انبوه نمونه‌های ذخیره شده ی روش داده افزایی-شدت منتخب در مرحله ی قبل، وزن دهی می‌شوند تا ۵ روش انتخاب توزیع محور بر روی آن‌ها بررسی شود

جدول ۶ نتایج حاصل از کاربرد کنترل کننده ی توزیع انتخاب بر روی روش داده افزایی ترکیب انحراف دامنه و تغییر مقیاس

روش داده افزایی	شدت	نرمال		یکنواخت		خطی		نمایی		ترتیبی	
		صحت	F1	صحت	F1	صحت	F1	صحت	F1	صحت	F1
تغییر مقیاس + انحراف دامنه	۰.۵٪	۹۲.۷	۹۱.۹	۹۲.۴	۹۱.۷	۹۴.۲	۹۳.۶	۹۵.۷	۹۵.۱	۹۶.۹	۹۶.۴

در دور چهارم حجم‌های داده افزایی تا ۱، ۲، ۳ و ۴ برابر کلاس اکثریت براچفت روش داده افزایی-توزیع منتخب حاصل از مراحل قبل بررسی شده است که حجم ۲ برابر برترین نتیجه را داشته است.

جدول ۷ نتایج حاصل از بررسی حجم‌های مختلف برای دسته بندی با جفت روش داده افزایی-توزیع منتخب

روش داده افزایی	شدت	حجم ۱ برابر		حجم ۲ برابر		حجم ۳ برابر		حجم ۴ برابر	
		صحت	F1	صحت	F1	صحت	F1	صحت	F1
تغییر مقیاس + انحراف دامنه با توزیع انتخاب ترتیبی	۰.۵٪	۹۳.۱	۹۲.۴	۹۶.۹	۹۶.۴	۹۵.۷	۹۵.۳	۹۴.۱	۹۳.۶

نتایج انتخاب نمونه با توزیع ترتیبی به تفکیک کلاس طبق جدول ۸ معادل ۹۶.۴٪ به دست آمده است. که نشان می‌دهد عملکرد روش پیشنهادی برای کلاس‌های اقلیت کارآمد بوده است.

جدول ۸ نتایج دسته بندی با انتخاب با توزیع Sequential به تفکیک کلاس

شماره کلاس	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	مجموع
کل نمونه‌ها	۲۸۳	۶۶	۲۰	۱۳۵	۱۳	۲۱	۱۳۳	۵۵	۱۳	۱۰	۱۰	۱۰	۱۱	۱۰۳	۶۲	۱۰	۴۵	۱۰۰۰
نمونه آزمایش	۲۸	۶	۲	۱۳	۱	۲	۱۳	۵	۱	۱	۱	۱	۱	۱۰	۶	۱	۴	۹۶
F1-score	۰.۹۶	۰.۸۶	۱.۰۰	۰.۹۶	۱.۰۰	۱.۰۰	۰.۹۶	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۰.۹۷
صحت	۰.۹۳	۱.۰۰	۱.۰۰	۰.۹۲	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۰.۹۷

ارائه داده است. به عبارت دقیق تر چهار عامل که باعث قطعه بندی سیگنال به روش RR می‌شود عبارتست از: ۱- ماهیت دوره ای سیگنال ECG ۲- امکان استفاده از روش‌های داده افزایی سیگنال با بازدهی بالاتر به دلیل قابلیت ارزش گذاری قطعه‌ها، ۳- چندین برابر شدن سیگنال‌های اولیه با تقسیم آن‌ها به چندین قطعه و ۴- قابلیت تعیین نمونه‌های مرزی با محاسبات آماری. به این ترتیب تولید نمونه ی جدید و کاهش واریانس کلی نمونه‌ها و در نتیجه امکان همگرایی و آموزش بهتر شبکه ی عصبی عمیق در شرایط وجود نمونه‌های بیشتر با واریانس کمتر منجر بهبود نتایج شده است. در جدول ۹ مقایسه ی انواع مطالعات

۴- بحث و مقایسه ی نتایج

طبقه بندی سیگنال با CNN روشی رایج و قابل قبول است، اما نیاز CNN به حجم انبوه داده‌ها در بسیاری از پژوهش‌ها مرتفع نشده و کمتر به آن پرداخته شده است. بدین منظور مطالعه ی حاضر به ارائه ی یک روش داده افزایی موثرتر در جهت دسته بندی دقیق تر سیگنال ECG به خصوص در کلاس‌هایی که با نمونه‌های محدود ماحه هستیم بپردازد. همانطور که گفته شد، سه جنبه ی مهم الف-روش داده افزایی، ب-حجم و ج-پراکندگی، محورهای اصلی در داده افزایی در مطالعات محققین هستند که مطالعه ی حاضر روشی جامع با در نظر گرفتن هر سه پارمتر

اخیر در طبقه بندی آریتمی‌های قلبی در مقایسه با روش حاضر آمده است.

جدول ۹. مقایسه روش پیشنهادی با آخرین پژوهش‌ها

پژوهش	سال	طول سیگنال	تعداد کلاس	مجموعه ویژگی	نوع طبقه بند	صحت کلی	زمان اجرای نمونه‌های تست (ثانیه)
Lind and yang [45]	۲۰۱۴	۱۲۰	۵	فاصله‌های RR استاندارد شده	LD وزن دار	۹۳٪	۰.۰۰۱
Huang et al [46]	۲۰۱۴	۲۰۰	۵	فاصله‌های RR و نگاشت تصادفی	ترکیب چند SVM	۹۴٪	-
Acharya et al [47]	۲۰۱۷	۳۶۰	۵	داده خام	پیش‌بینی	۹۴.۰۳٪	۰.۰۰۴
Yang et al [48]	۲۰۱۸	۳۰۰	۵	PCA	SVM خطی	۹۷.۹۴٪	۰.۰۱۲
Oh et al [49]	۲۰۱۸	متغیر	۵	داده خام	پیش‌بینی-بازگشتی	۹۸.۱۰٪	-
Yildirim [50]	۲۰۱۸	۳۶۰	۵	داده خام	بازگشتی جهت دار	۹۹.۳۹٪	-
Plawiak [51]	۲۰۱۸	۳۶۰۰	۱۵	مولفه‌های فرکانسی سیگنال	ترکیب ژنتیکی SVM	۹۳.۰۴٪	۰.۰۱۶
Plawiak [52]	۲۰۱۸	۳۶۰۰	۱۷	مولفه‌های فرکانسی سیگنال	ترکیب ژنتیکی SVM	۹۱.۴۰٪	۰.۰۱۷
Yildirim [6]	۲۰۱۸	۳۶۰۰	۱۷	داده خام با تغییر مقیاس	پیش‌بینی یک بعدی	۹۱.۳۳٪	۰.۰۰۶
Al-Huseiny [20]	۲۰۲۰	۳۶۰۰	۱۷	تصویر داده خام	پیش‌بینی دو بعدی	۹۶.۶۷٪	۰.۱۲۸
J. Remy [41]	۲۰۲۱	۳۶۰۰	۵	تپش قلب و انواع مولفه‌های فرکانسی	بازگشتی جهت دار	۹۳.۹٪	۰.۰۲۷
Wah, T. Y [43]	۲۰۲۲	۳۶۰۰	۵	میانگین متحرک حادثه گرای دوگانه به همراه تبدیل فوریه ی فراکتال	ترکیب k نزدیک ترین همسایه و ماشین بردار پشتیبان	۹۹.۹٪	۰.۰۲۲
Kumari, L.V [42]	۲۰۲۲	۳۶۰۰	۶	داده خام	ترکیب دو درخت تصمیم	۹۸.۷٪	۰.۰۰۲
Fons [30]	۲۰۲۱	ترکیبی	۱۷	فاصله‌های RR استاندارد شده و تغییر مقیاس یافته به همراه داده افزایی α -trim	پیش‌بینی یک بعدی	۹۵.۴۲٪	۰.۰۱۵
روش ارائه شده	۲۰۲۳	۴۸۰	۱۷	فاصله‌های RR استاندارد شده و تغییر مقیاس یافته به همراه داده افزایی با انتخاب توزیع محور	پیش‌بینی یک بعدی	۹۶.۹۲٪	۰.۰۱۵

trim نسبت به روش پیشنهادی به میزان ۱.۵٪ عملکرد ضعیف تری دارد.

۵- نتیجه گیری

در این مطالعه جهت داده افزایی موثر سیگنال‌های یک بعدی دوره ای و بالاحص سیگنال‌های ECG، یک کنترل کننده ی انتخاب توزیع محور ارائه شد تا از میان حجم عظیمی از نمونه‌های مصنوعی حاصل از داده افزایی، نمونه‌های مناسب تر انتخاب شوند که با انعطاف حاصل از کاربرد توزیع‌های مختلف قابل کنترل هستند. در نتیجه ی استفاده از روش ارائه شده، فضای رخداد بالقوه ی نمونه‌ها در دنیای واقعی در فضای گسترده تر و با دقت بیشتری با نمونه‌های حاصل از داده افزایی قابل پوشش است و از انتقال برچسب و تولید نمونه‌هایی که به کلاس‌های مخالف تعلق دارند اجتناب می‌شود. روش حاضر بر روی سیگنال‌های ECG پایگاه داده ی MIT-BIH ارزیابی و با انواع روش‌های دسته بندی اخیر مقایسه شد که نتایج قابل قبولی داشته است. همچنین به منظور مقایسه با یکی از آخرین روش‌های داده افزایی، روش داده افزایی α -trim [۳۰] در مدل حاضر، پیاده سازی و مورد مقایسه قرار گرفت که نتایج نشان از برتری روش پیشنهادی به میزان

همانطور که ستون آخر جدول ۹ نشان می‌دهد، پیچیدگی زمانی روش ارائه شده و سایر روش‌ها در دسته بندی داده‌های آزمون، محاسبه شده است. اگرچه پیچیدگی زمانی مطالعه حاضر نسبت به برخی از روش‌ها بیشتر است، لیکن باید این نکته در نظر گرفته شود که روش ارائه شده توانایی طبقه بندی ۱۷ نمونه آریتمی را دارد در حالی که در پژوهش‌های همتیان و همکاران [۳۷]، قاسمی و همکاران [۳۸]، جعفری هفشجانی و همکاران [۳۹]، ماندگار و همکاران [۴۰]، رکسی و همکاران [۴۱]، کوماری و همکاران [۴۲]، واه و همکاران [۴۳] و هانون و همکاران [۴۴] تعداد کلاس‌ها به ۵ کلاس تقلیل یافته است. این درحالی است که یکی از چالش‌های مهم تشخیص بیماری آریتمی قلبی، تشخیص کلاس‌های آریتمی نادری است که تعداد نمونه اندکی دارند. در نهایت زمان اجرای الگوریتم پیشنهادی نشان می‌دهد که CNN آموزش دیده به روش پیشنهادی، زمان اجرای معقول در دسته بندی، دارد. در مقایسه با پژوهش‌های ییلدیرین و همکاران [۶] و حسینی و همکاران [۲۰] که اقدام به طبقه بندی ۱۷ کلاس نموده اند؛ روش ارائه شده منجر به کسب نتایج بهتری شده است. مقایسه ی روش پیشنهادی با یکی از آخرین پژوهش‌های انجام شده، [۳۰] نشان می‌دهد که داده افزایی موسوم به α -

ای که مبتنی بر فاصله ی اقلیدسی نیستند ارائه دهند. در مورد توزیع‌های به کار رفته نیز کارایی سایر توزیع‌ها از جمله بتا که با پارامترهای متنوع قابلیت انتخاب دقیق تری ارائه می‌دهد می‌تواند مورد توجه قرار گیرد.

۱.۵٪ داشته است. پژوهش‌های آینده می‌توانند بر روی کاربرد روش داده افزایی ارائه شده، برای سایر داده‌ها بپردازند. همچنین استفاده از شاخص‌های ارزیابی موثرتری نسبت به شاخص تراکم و فاصله‌های مرزی می‌تواند در مطالعات آتی مورد بررسی قرار گیرد. شاخص‌های که قادر باشند عملکرد قابل قبولی را در مواجهه با سیگنال‌های غیر دوره

مراجع

- Features and Analyzing Original Component. *Advanced Signal Processing*.
- [17] Wang Z, Yan W, Oates T. Time series classification from scratch with deep neural networks: A strong baseline. In: *IJCNN*; 2017
 - [18] Al-Huseiny, M. S., Abbas, N. K., & Sajit, A. S. (2020). Diagnosis of arrhythmia based on ECG analysis using CNN. *Bulletin of Electrical Engineering and Informatics*, 9(3), 988-995.
 - [19] Hannun, A. Y., Rajpurkar, P., Haghighpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, 25(1), 65-69.
 - [20] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
 - [21] Pan Q, Li X, Fang L. Data augmentation for deep learning-based ECG analysis. In: *Feature Eng. And Comput. Intell. in ECG Monitor*. Springer; 2020. p. 91-111
 - [22] Chen G, Zhu Y, Hong Z, Yang Z. EmotionalGAN: Generating ECG to enhance emotion state classification. In: *AICS*; 2019
 - [23] Hatamian FN, Ravikumar N, Vesal S, Kemeth FP, Struck M, Maier A. The effect of data augmentation on classification of atrial fibrillation in short single-lead ECG signals using deep neural networks. In: *IEEE ICASSP*; 2020
 - [24] Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
 - [25] He, H., Bai, Y., Garcia, E. A., & Li, S. (2008, June). ADASYN: Adaptive synthetic sampling approach for imbalanced learning. In 2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence) (pp. 1322-1328). Ieee.
 - [26] Xie, Y., Qiu, M., Zhang, H., Peng, L., & Chen, Z. (2020). Gaussian distribution methods for oversampling for imbalanced data classification. *IEEE Transactions on Knowledge and Data Engineering*.
 - [27] Um, T. T., Pfister, F. M., Pichler, D., Endo, S., Lang, M., Hirche, S., ... & Kulić, D. (2017, November). Data augmentation of wearable sensor data for Parkinson's disease monitoring using convolutional neural networks. In *Proceedings of the 19th ACM international conference on multimodal interaction* (pp. 216-220).
 - [28] Gao, J., Song, X., Wen, Q., Wang, P., Sun, L., & Xu, H. (2020). Robuststat: Robust time series anomaly detection via decomposition and convolutional neural networks. *arXiv preprint arXiv:2002.09545*.
 - [29] Iwana, B. K., & Uchida, S. (2021). An empirical survey of data augmentation for time series classification with neural networks. *Plos one*, 16(7), e0254841.
 - [30] Fons, E., Dawson, P., Zeng, X. J., Keane, J., & Iosifidis, A. (2021). Adaptive weighting scheme for automatic time-series data augmentation. *arXiv preprint arXiv:2102.08310*.
 - [31] Sakai, A., Minoda, Y., & Morikawa, K. (2017, August). Data augmentation methods for machine-learning-based classification of bio-signals. In 2017 10th Biomedical Engineering International Conference (BMEiCON) (pp. 1-4). IEEE.
 - [32] Liu, Y., Zhou, Y., Liu, X., Dong, F., Wang, C., & Wang, Z. (2019). Wasserstein GAN-based small-sample augmentation for new-generation artificial intelligence: a case study of cancer-staging data in biology. *Engineering*, 5(1), 156-163.
 - [33] Javadi, M., Arani, S. A. A. A., Sajedin, A., & Ebrahimpour, R. (2013). Classification of ECG arrhythmia by a modular neural
 - [1] Benjamin, E. J., Virani, S. S., Callaway, C. W., Chamberlain, A. M., Chang, A. R., Cheng, S., ... & Muntner, P. (2018). Heart disease and stroke statistics—2018 update: a report from the American Heart Association. *Circulation*, 137(12), e67-e492.
 - [2] Sahoo, S., Dash, M., Behera, S., & Sabut, S. (2020). Machine learning approach to detect cardiac arrhythmias in ECG signals: a survey. *Irbm*, 41(4), 185-194.
 - [3] jalali shahri, M. S. , Khatib, F. , Seyed Mahdavi, S. J. , Heidari Bakavoli, A. and Kahrom, M. (2023). Design optimized neural network for diagnosis of atrial fibrillation. *Advanced Signal Processing*. doi: 10.22034/jasp.2023.51706.1189.
 - [4] World Health Organization. *Global Status Report on Noncommunicable Diseases*; WHO: Geneva, Switzerland, 2014.
 - [5] Bogun, F.; Anh, D.; Kalahasty, G.; Wissner, E.; Serhal, C.B.; Bazzi, R.; Weaver, W.D.; Schuger, C. Misdiagnosis of atrial fibrillation and its clinical consequences. *Am. J. Med.* 2004, 117, 636-642
 - [6] Yildirim, Ö., Plawiak, P., Tan, R. S., & Acharya, U. R. (2018). Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Computers in biology and medicine*, 102, 411-420.
 - [7] Sajedin, A., Zakernejad, S., Faridi, S., Javadi, M., & Ebrahimpour, R. (2010). A trainable neural network ensemble for ECG beat classification. *International Journal of Biomedical and Biological Engineering*, 4(9), 479-485.
 - [8] Keogh, E., & Ratanamahatana, C. A. (2005). Exact indexing of dynamic time warping. *Knowledge and information systems*, 7(3), 358-386.
 - [9] de Chazal P, O'Dwyer M, Reilly RB: Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Trans Biomed Eng* 2004, 51:1196-1206
 - [10] Llamado-Soria M, Martinez JP: Heartbeat classification using feature selection driven by database generalization criteria. *IEEE Trans Biomed Eng* 2011, 58:616-625
 - [11] Mar T, Zaunseder S, Martinez JP: Optimization of ECG classification by means of feature selection. *IEEE Trans Biomed Eng* 2011, 58:2168-2177.
 - [12] Thomas, M., Das, M. K., & Ari, S. (2015). Automatic ECG arrhythmia classification using dual tree complex wavelet based features. *AEU-International Journal of Electronics and Communications*, 69(4), 715-721.
 - [13] Homaeinezhad, M. R., Tavakkoli, E., Atyabi, S. A., Ghaffari, A., & Ebrahimpour, R. (2011). Synthesis of multiple-type classification algorithms for robust heart rhythm type recognition: Neuro-svm-pnn learning machine with virtual QRS image-based geometrical features. *Scientia Iranica*, 18(3), 423-431.
 - [14] Homaeinezhad, M. R., Atyabi, S. A., Tavakkoli, E., Toosi, H. N., Ghaffari, A., & Ebrahimpour, R. (2012). ECG arrhythmia recognition via a neuro-SVM-KNN hybrid classifier with virtual QRS image-based geometrical features. *Expert Systems with Applications*, 39(2), 2047-2058.
 - [15] Wang, J.; Qiao, X.; Liu, C.; Wang, X.; Liu, Y.; Yao, L.; Zhang, H. Automated ECG classification using a non-local convolutional block attention module. *Comput. Methods Programs Biomed.* 2021, 203, 106006
 - [16] Zabbah, I., Maroosi, A., & Ebrahimpour, R. (2022). Intelligent diagnosing COVID-19 Disease Using a Combination of Deep

- decision tree. *Signal, Image and Video Processing*, 16(3), 695-703.
- [43] Wah, T. Y., Mohammed, M. A., Iqbal, U., Kadry, S., Majumdar, A., & Thinnukool, O. (2022). Novel DERMA Fusion Technique for ECG Heartbeat Classification. *Life*, 12(6), 842.
- [44] Hannun, A. Y., Rajpurkar, P., Haghighpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, 25(1), 65-69.
- [45] C. C. Lin and C. M. Yang, "Heartbeat Classification Using Normalized RR Intervals and Wavelet Features," 2014 International Symposium on Computer, Consumer and Control, Taichung, 2014, pp. 650-653.
- [46] Huang, H., Liu, J., Zhu, Q., Wang, R., & Hu, G. (2014). A new hierarchical method for inter-patient heartbeat classification using random projections and RR intervals. *Biomedical engineering online*, 13, 1-26.
- [47] U. R. Acharya, et al., "A deep convolutional neural network model to classify heartbeats," *Comput. Biol. Med.*, vol. 89, pp. 389-396, 2017.
- [48] Yang, W., Si, Y., Wang, D., & Guo, B. (2018). Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine. *Computers in Biology and Medicine*
- [49] S. L. Oh, E. Y. Ng, R. S. Tan, & U. R. Acharya, "Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats", *Computers in Biology and Medicine*, 2018
- [50] Ozal Yildirim; A novel wavelet sequences based on deep bidirectional LSTM network model for ECG signal classification; *Computers in Biology and Medicine*; 2018; 96; 189 – 202
- [51] Pawel Plawiak; Novel methodology of cardiac health recognition based on ECG signals and evolutionary-neural system; *Expert Systems with Applications*; 2018; 92; 334 – 349
- [52] Pawel Plawiak; Novel genetic ensembles of classifiers applied to myocardium dysfunction recognition based on ECG signals; *Swarm and Evolutionary Computation*; 2018; 39; 192 – 208
- network based on mixture of experts and negatively correlated learning. *Biomedical Signal Processing and Control*, 8(3), 289-296.
- [34] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated residual transformations for deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1492-1500).
- [35] Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. C. (2017). Improved training of wasserstein gans. *Advances in neural information processing systems*, 30.
- [36] Eapen, J., Bein, D., & Verma, A. (2019, January). Novel deep learning model with CNN and bi-directional LSTM for improved stock market index prediction. In *2019 IEEE 9th annual computing and communication workshop and conference (CCWC)* (pp. 0264-0270). IEEE.
- [۳۷] همتیان، & مالکی. (۲۰۱۵). شاخص هورست چندگانه اصلاح شده برای ارزیابی میزان آشوبناک بودن در کاربرد طبقه‌بندی آریتمی‌های قلبی. فصل نامه علمی پژوهشی مهندسی پزشکی زیستی، ۹(۲)، ۱۶۳-۱۷۸.
- [۳۸] قاسمی، کرد، & غلامی. (۲۰۱۷). طبقه‌بندی آریتمی‌های قلبی مبتنی بر ترکیب نتایج شبکه‌های عصبی با نظریه شواهد دمپستر-شفر. پردازش علائم و داده‌ها، ۱۴(۲)، ۲۵-۴۲.
- [۳۹] جعفری هفشجانی، نسترن، مهری دهنوی، حاجیان، بوداغ، & بهجتی. (۲۰۱۹). طبقه‌بندی امواج قلبی به منظور تشخیص سکته‌ی قلبی مبتنی بر استخراج ویژگی‌های ریخت‌شناسی از الگوهای فضایی-زمانی امواج وکتور کاردیوگرام. مجله دانشکده پزشکی اصفهان، ۳۷(۵۴۸)، ۱۱۹۲-۱۱۹۹.
- [40] Mondéjar-Guerra, V., Novo, J., Rouco, J., Penedo, M. G., & Ortega, M. (2019). Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers. *Biomedical Signal Processing and Control*, 47, 41-48.
- [41] Remy, J., Velmani, P., & Rajakumar, T. C. (2021) Heart Beat classification in MIT-BIH arrhythmia ecg dataset using double layer BI-LSTM model. *International Journal of Mechanical Engineering*. Vol6. 11980
- [42] Kumari, L. V., & Sai, Y. P. (2022). Classification of ECG beats using optimized decision tree and adaptive boosted optimized

زیر نویس ها

* weighted linear discriminant analysis (wLDA)
 ° Marginal data augmentation with distribution based selection (MDADS)

¹ Electrocardiogram
 ² Golden Standard
 ³ Dynamic time warping distance