

## تشخیص انواع ناهنجاری‌های قلبی با استفاده از یادگیری عمیق مبتنی بر هزینه

الهام عنایتی

دانشکده ریاضی و علوم کامپیوتر - دانشگاه دامغان - دامغان - ایران  
پست الکترونیکی: e.enayati@std.du.ac.ir

رضا مرتضوی\*

دانشکده فنی و مهندسی - دانشگاه دامغان - دامغان - ایران  
پست الکترونیکی: r\_mortazavi@du.ac.ir

عبدالعلی بصیری

دانشکده ریاضی و علوم کامپیوتر - دانشگاه دامغان - دامغان - ایران  
پست الکترونیکی: basiri@du.ac.ir

### چکیده

هم‌آمیختگی<sup>۱</sup> برای تشخیص نوع ناهنجاری قلبی ارائه شده است که علاوه بر اعمال هزینه در سطح داده با استفاده از تابع ضرر مبتنی بر هزینه در مرحله یادگیری، هزینه دسته‌بندی اشتباه را برای رده‌های دارای تعداد نمونه کمتر افزایش می‌دهد. مدل پیشنهادی همچنین از یک روش بخش‌بندی ضربان قلب در مرحله پیش‌پردازش استفاده می‌کند که حاوی اطلاعات بیشتری برای دسته‌بندی هستند. نتایج تجربی مدل پیشنهادی بر روی مجموعه داده MIT-BIH در مقایسه با روش کاپویی و ۳ روش رقیب دیگر، بجز در معیار یادآوری، سایر شاخص‌های صحت، دقت و معیار F برتری روش پیشنهادی را نشان می‌دهند و بر اساس معیار یادآوری دومین بهترین نتیجه حاصل شده است. به طور خاص در شاخص صحت کل در مقایسه با بهترین روش رقیب ۲۰٪ بهبود و برای معیار F در دسته‌های غیرنرمال ۲۶٪ بهبود حاصل شده است.

یکی از راه‌های تشخیص بیماری‌های ناشی از ناهنجاری‌های قلبی، بررسی سیگنال‌های الکتروکاردیوگرام است. این سیگنال‌ها به صورت سیگنال‌های پیوسته زمانی هستند که قبل از پردازش باید به ضربان‌های قلب شکسته شوند. از آنجایی سیگنال‌های قلبی در حجم زیاد ذخیره می‌شوند پردازش آنها توسط روش‌های معمول یادگیری ماشین دشوار است. همچنین مسئله تشخیص نوع ناهنجاری در سیگنال‌های الکتروکاردیوگرام تنها یک مسئله دسته‌بندی چند رده‌ای نیست؛ بلکه با توجه به ماهیت مجموعه داده‌های واقعی موجود، یک مسئله دسته‌بندی داده‌های نامتعادل است. در این زمینه یک راه‌حل بالقوه، استفاده از راهکارهای مبتنی بر هزینه است که ممکن است در سطح الگوریتم یا سطح داده پیاده‌سازی شوند. در این مقاله، یک مدل مبتنی بر یادگیری عمیق با استفاده از شبکه

قلب (بخش‌بندی سیگنال) و تشخیص نوع ضربان قلب (دسته‌بندی سیگنال) تقسیم نمود. بخش‌بندی سیگنال به معنای تقسیم یک سیگنال پیوسته ECG به زیر دنباله‌هایی است که به عنوان یک ضربان در نظر گرفته می‌شوند و در بسیاری از مطالعات معادل مفهوم پزشکی آن یعنی شامل یک موج کامل قلبی به نام موج P-QRS-T می‌باشند.<sup>۲</sup> هرچه بخش‌ها حاوی اطلاعات مفید بیشتری باشند، مدل در مرحله دسته‌بندی قادر به تخصیص بهتر بخش‌ها به رده‌های مربوطه خواهد بود.

مطالعه کاپویی و همکاران یک نمونه معروف از کارهای این حوزه است [۵]. در این مطالعه در مرحله پیش‌پردازش سیگنال ECG، مدل پیشنهادی اقدام به بخش‌بندی سیگنال قلبی با نمونه‌برداری ۱۲۵ هرتز به بخش‌هایی با طول مساوی می‌نماید. هر ضربان قلب در این روش شامل یک موج کامل P-QRS-T است. مدل پیشنهادی از یک شبکه عمیق با پنج ماژول هم‌آمیختگی که هر ماژول از دو لایه هم‌آمیختگی تشکیل شده است که برای دسته‌بندی ضربان‌های قلب به پنج دسته (N, S, V, F و Q) استفاده می‌نماید. مدل بر روی مجموعه MIT-BIH به صحت ۹۳/۴٪ دست یافته است. این مدل نسبت به مدل‌های پیش از خود به نتایج قابل توجهی دست یافته است. این در حالی است که در طراحی آن به ماهیت نامتعادل بودن مجموعه داده توجهی نشده است. تاکنون در تعداد کمی از کارهای انجام شده در این حوزه از سازوکارهای مبتنی بر هزینه برای بهبود نتایج مدل استفاده شده است. یک نمونه اخیر در مطالعه رومدهانی و همکاران است که از یک شبکه عمیق با شش لایه هم‌آمیختگی و تابع ضرر فوکال<sup>۳</sup> برای محاسبه هزینه دسته‌بندی توسط شبکه استفاده شده است [۶]. شاخص صحت گزارش شده در این مطالعه برای مجموعه MIT-BIH ۹۸/۴۱٪ بوده است. سایر نتایج به دست آمده برای دسته‌بندی مجموعه داده مذکور، نتایج بسیار خوبی را نشان می‌دهند. اما در مطالعه [۷]، نتایج آزمایش‌های تجربی انجام شده بر اساس مطالعه

واژه‌های کلیدی: سیگنال الکتروکاردیوگرام، نامنظمی قلبی، یادگیری عمیق، یادگیری مبتنی بر هزینه، شبکه هم‌آمیختگی.

#### ۱. مقدمه

بیماری‌های قلبی، یکی از شایع‌ترین علت‌های مرگ‌ومیر در جهان هستند [۱]. اغلب، تشخیص بیماری‌های قلبی بر اساس گزارش‌های بالینی بیمار و سوابق پزشکی آنها است که توسط افراد متخصص انجام می‌شود. یکی از ابزارهای مهم در بررسی وضعیت سلامت افراد و تشخیص نامنظمی‌های قلبی، سیگنال‌های الکتروکاردیوگرام (ECG) هستند. این سیگنال‌ها در بیماران سرپایی در زمان محدود و در بیماران بستری یا تحت‌نظر به‌صورت شبانه‌روزی ذخیره و بررسی می‌شوند.

امروزه با افزایش حجم اطلاعات مربوط به سوابق پزشکی بیماران و نیز استفاده از ابزارها و حسگرهایی که به‌صورت شبانه‌روزی اطلاعات مربوط به وضعیت بیماران نظیر نوار قلب را ذخیره می‌کنند، تنها وجود افراد خبره در حوزه پزشکی پاسخگوی رفع نیازهای تحلیلی مربوط به داده‌های بیماران نیست. استفاده از ابزارهای یادگیری ماشین و به‌خصوص یادگیری عمیق فرصت خوبی برای تحلیل داده‌های حوزه سلامت به وجود آورده است. در حوزه تشخیص بیماری‌های قلبی، استفاده از الگوریتم‌های یادگیری عمیق بر روی سیگنال‌های الکتروکاردیوگرام به‌منظور دسته‌بندی ضربان‌های قلب و تشخیص انواع نامنظمی‌های قلبی کاربرد دارد [۲].

در برخی از مطالعات به دسته‌بندی سیگنال‌های قلبی به دو دسته نرمال و غیرنرمال پرداخته شده است [۳، ۴] در برخی دیگر دسته‌بندی به مسئله تشخیص نوع نامنظمی [۵، ۶] بدل شده است. از آنجایی که مجموعه داده‌های مربوط به نوار قلب به‌صورت سیگنال‌های الکتریکی پیوسته می‌باشند لذا مسئله تشخیص نامنظمی را می‌توان شامل زیر مسئله‌های کلی تشخیص یک ضربان

۲- توضیحات بیشتر در بخش ۲ آمده است.

یک داده متعلق به مجموعه‌های کم تعداد بیشتر از یک داده متعلق مجموعه پر تعداد باشد، مسئله نامتعادل بودن دسته‌ها را تعدیل می‌نمایند. در روش‌های سطح الگوریتم، مدل در هنگام آموزش با وزن‌دهی هزینه دسته‌بندی سعی در حل مسئله می‌نمایند. در این روش‌ها هزینه دسته‌بندی یک نمونه عضو دسته حداقل از هزینه دسته‌بندی مربوط به یک نمونه عضو دسته حداکثر بیشتر است [۹].

در این مطالعه برای زیرمسئله بخش‌بندی در مرحله پیش‌پردازش داده‌ها از یک روش جدید استفاده شده است که با استفاده از آن یک ضربان قلب شامل اطلاعات (ویژگی‌های) بیشتری خواهد بود. این ویژگی‌های اضافی در مرحله دسته‌بندی سیگنال به تشخیص بهتر نوع سیگنال کمک می‌کنند. در مدل پیشنهادی از یک شبکه هم‌آمیختگی برای دسته‌بندی سیگنال‌های الکتروکاردیوگرام استفاده شده است. این شبکه علاوه بر اعمال هزینه در سطح داده، از یک سازوکار تابع ضرر مبتنی بر هزینه<sup>۴</sup> در سطح الگوریتم استفاده می‌کند که در آن هزینه بیشتری برای دسته‌بندی ضربان‌های غیرنرمال که در رده‌های با تعداد نمونه‌های کم و یا بسیار کم قرار دارند، محاسبه می‌کند. این شبکه قادر است ۵ دسته ضربان شامل یک دسته سالم و چهار دسته نامنظمی را تشخیص دهد. بدین ترتیب با افزایش مقدار تابع ضرر سعی در جبران کم تعداد بودن برخی رده‌ها در مقابل سایر رده‌ها می‌کند و این سبب افزایش کارایی مدل هم در دسته‌بندی نمونه‌های مربوط به رده پرتعداد و هم در دسته‌بندی نمونه‌های مربوط به رده‌های کم تعداد می‌شود چنانکه در شاخص‌های ارزیابی این نتایج مشهود است. مجموعه داده مورد استفاده در این مطالعه مجموعه داده MIT-BIH<sup>۵</sup> است که به عنوان محک در این حوزه شناخته می‌شود. مقدار شاخص صحت<sup>۶</sup> کل در مجموعه داده مذکور با استفاده از مدل پیشنهادی به مقدار ۲۰٪ بهتر از بهترین نتیجه برای سایر مدل‌های رقیب به دست آمده است. همچنین معیار F برای رده‌های غیرنرمال،

رومدهانی و همکاران را تأیید نمی‌کند. لذا در اینجا یک مدل پیشنهادی جدید مبتنی بر هزینه برای بهبود نتایج ارائه می‌شود.

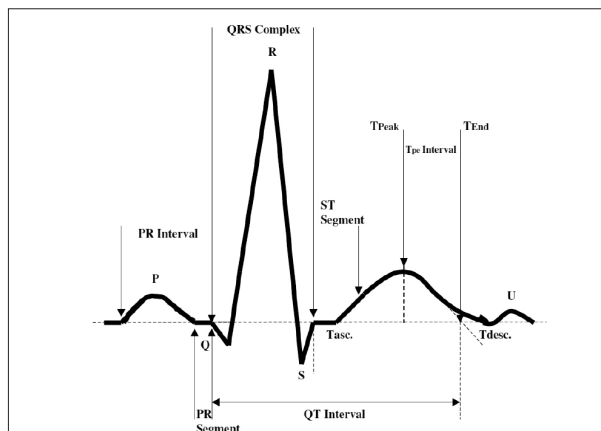
از آنجایی که در مدل‌های مربوط به دسته‌بندی سیگنال‌های قلبی با توجه به ماهیت مجموعه‌های داده ECG موجود با مسئله دسته‌بندی مجموعه‌های داده نامتعادل مواجه هستیم [۸]، بدیهی است که در این نوع دسته‌بندی‌ها غالباً گرایش مدل به سمت مجموعه‌های حداکثری است. تاکنون راه‌حل‌های متنوعی برای غلبه بر مشکل گرایش به سمت مجموعه‌های حداکثر ارائه شده است. یکی از روش‌های مرسوم، استفاده از مدل‌های مبتنی بر هزینه است که در آنها به نحوی با متفاوت در نظر گرفتن هزینه دسته‌بندی مربوط به نمونه‌های متعلق به مجموعه‌های حداقل نسبت به نمونه‌های مجموعه‌های حداکثر سعی در جبران این گرایش دارند [۹]. به طور مثال، در مورد مجموعه داده نسبتاً حجیم MIT-BIH با ۱۰۹۴۴۶ ضربان که هر ضربان نیز یک سری زمانی است، حدود ۸۳٪ از مجموعه داده (یعنی ۹۰۶۳۱ ضربان) عضو رده نرمال هست نشان‌دهنده به شدت نامتعادل بودن مجموعه داده است. این ویژگی علاوه بر این که علت استفاده از رویکرد مبتنی بر هزینه در این مطالعه را نشان می‌دهد، سبب می‌شود که در گزارش نتایج توجه به شاخص‌های مربوط به هر رده به جای شاخص‌های کل، از اهمیت ویژه‌ای برخوردار باشند، چرا که تشخیص درست یک نمونه از دسته غیرنرمال گرچه تغییر چشمگیری در شاخص‌های کل ایجاد نمی‌کند اما به دلیل اهمیت تشخیص حتی یک ناهنجاری در دنباله‌ای از ضربان‌های قلب که منجر به تشخیص درست یک فرد بیمار می‌شود، امری بسیار حیاتی است که با توجه به شاخص‌های کلی گزارش شده در اغلب مطالعات انجام شده، این واقعیت کم اهمیت بوده است.

روش‌های مبتنی بر هزینه در دو سطح داده و الگوریتم ارائه می‌شوند. روش‌های سطح داده در مرحله پیش‌پردازش با اعمال وزن‌دهی به مجموعه داده اولیه، به نحوی که اثر

4- Cost-sensitive loss function

5- <https://physionet.org/content/mitdb/1.0.0/>

6- Accuracy



شکل (۱): یک نمونه ضربان قلب P-QRS-T [۱۱].

پیک R است. یک ضربان قلب شامل قسمت‌های معنادار متعددی از جمله دیپلاریزاسیون دهلیزی (P-wave)،<sup>۷</sup> دیپلاریزاسیون شکمی (QRS-complex)<sup>۸</sup> و ریپلاریزاسیون (T-wave)<sup>۹</sup> است. هرگونه تغییر در بازه‌های نشان داده شده در شکل (۱) (بازه‌های PR، QT، ST و...) به معنای یک رخداد غیرمعمول در نظر گرفته می‌شود که ممکن است منجر به نامنظمی قلبی شود. در زیر برخی از ضربان‌های مورد بررسی در مطالعه حاضر آمده است [۱]:

ضربان‌های نرمال قلب (N): ضربان‌های معمولی (NOR)، ضربان فرار دهلیزی (AE)، ضربان نودال (جانکشنال) (NE)، ضربان باندل چپ (LBBB)، ضربان باندل راست (RBBB) در دسته ضربان‌های نرمال قلب قرار دارند.

ضربان‌های زودرس فوق بطنی<sup>۱۱</sup> (S): این ضربان‌ها نشان دهنده فعال شدن زودرس دهلیزها از محلی به غیر از گره سینوسی است و می‌تواند از دهلیزها منشأ بگیرد. همچنین به عنوان ضربان زودرس دهلیزی<sup>۱۲</sup> یا ضربان‌های فوق بطنی زودرس<sup>۱۳</sup> یا ضربان‌های زودرس پیوندی<sup>۱۴</sup> نیز شناخته می‌شوند و اکثریت قریب به اتفاق منشأ دهلیزی دارند.

- 7- Atrial depolarization
- 8- Ventral depolarization
- 9- Repolarization
- 10- Normal beats
- 11- Supraventricular premature or ectopic beat (atrial or nodal)
- 12- Atrial premature beat
- 13- Super ventricular beat
- 14- Nodal (junctional) premature beat

مقدار ۰/۲۱۵ توسط مدل پیشنهادی در برابر مقدار ۰/۱۷۰ برای بهترین نتیجه مدل‌های رقیب بوده است که به معنای بهبود نسبی بیش از ۲۶٪ می‌باشد. در سایر شاخص‌ها نیز این برتری به چشم می‌خورد که جزئیات بیشتر آن در بخش آزمایش‌ها آمده است.

به صورت کلی نوآوری‌های این مقاله به شرح زیر است: (۱) استفاده از یک روش بخش‌بندی جدید برای مجموعه داده که سبب نگهداری اطلاعات (ویژگی‌های) بیشتری می‌شود. (۲) استفاده از سازوکارهای مبتنی بر هزینه در سطح داده و سطح الگوریتم (تابع ضرر مبتنی بر هزینه) که قادر به تعدیل تاثیر نامتعادل بودن مجموعه داده می‌شود. در ادامه ساختار مقاله به این صورت است. در بخش دوم مفاهیم مربوط به ضربان قلب و نامنظمی‌های قلبی آمده است که در این مطالعه به تشخیص آنها می‌پردازیم. در بخش سوم به بررسی تاریخچه مختصری از کارهای مرتبط با این حوزه پرداخته شده است. در بخش چهارم، معماری مدل پیشنهادی و جزئیات مربوط به آن ارائه شده است. جزئیات مربوط به مجموعه داده مورد استفاده در بخش پنجم آمده است. در بخش ششم معیارهای ارزیابی مورد استفاده در آزمایش‌های تجربی معرفی شده‌اند. آزمایش‌ها، نتایج و تحلیل آنها در بخش هفتم آمده است. در نهایت بخش هشتم به نتیجه‌گیری و پیشنهادهایی برای کارهای آینده اختصاص یافته است.

## ۲. مفاهیم پایه

با توجه به اهمیت شناخت ساختار سیگنال ECG، ضروری است پیش از بررسی کارهای انجام شده در تشخیص ناهنجاری با استفاده از سیگنال الکتروکاردیوگرام، برخی مفاهیم پزشکی مربوطه معرفی شوند. در این بخش به تعریف این مفاهیم می‌پردازیم.

تعریف ضربان قلب: یک سیگنال قلبی نرمال مطابق شکل ۱، یک موج P-QRS-T است [۱۰]. ضربان قلب از موج P شروع و درست بعد از موج T پایان می‌یابد و شامل یک

جدول (۱): اطلاعات مربوط به دسته‌بندی ضربان‌های قلب براساس استاندارد AAMI EC57

نام دسته AAMI	توصیف دسته	نوع ضربان
N	Normal	Normal beat (NOR) Atrial escape beat (AE) Nodal (junctional) escape beat (NE) Left bundle branch block beat (LBBB) Right bundle branch block beat (RBBB)
S	Supraventricular ectopic beat	Atrial premature beat (AP) Nodal (junctional) premature beat (NP) Supraventricular premature beat (SP) Aberrated atrial premature beat (AAP)
V	Ventricular ectopic beat Premature ventricular contraction	Ventricular escape beat (VE) Premature ventricular contraction (PVC)
F	Fusion beat	Fusion of ventricular and normal beat (FVN)
Q	Unknown beat	Paced beat (P) Unclassifiable beat (U) Fusion of paced and normal beat (FPN)

## ۱-۲. بخش‌بندی سیگنال به ضربان

از آنجایی که سیگنال الکتروکاردیوگرام یک سیگنال پیوسته است لذا تشخیص یک دنباله P-QRS-T در این سیگنال به منظور جداسازی یک ضربان قلب، امری ضروری است. همان گونه که در شکل (۱) نشان داده شده است، ابتدا و انتهای یک ضربان به ترتیب با بازه‌های P و T مشخص می‌شوند. در یک ضربان قلب ناسالم تشخیص این بازه‌ها به آسانی مقدور نیست، لذا در اغلب روش‌های مربوط به تشخیص ضربان از تشخیص موج QRS پیچیده یا بازه R برای تشخیص و جداسازی یک ضربان استفاده می‌شود.

روش Pan-Tompkins از معروفترین و قدیمی‌ترین روش‌های بخش‌سازی سیگنال ECG است [۱۲]. در این روش یک بانک فیلتر شامل فیلترهای بالاگذر و پایین‌گذر و یک پنجره متحرک به همراه چند فیلتر دیگر پس از تشخیص بازه R، یک ضربان قلب را شناسایی می‌کنند. در بسیاری از مطالعات از این روش برای تقسیم کردن سیگنال الکتروکاردیوگرام به ضربان قلب استفاده شده است [۱۳].

در مطالعات بعدی به منظور بهبود شاخص‌های کارایی از راهکارهای دیگری برای تشخیص یک ضربان استفاده شد. در مطالعه زیدلمال و همکاران با استفاده از تبدیل ویولت گسسته، موج QRS پیچیده استخراج و به کمک آن

ضربان‌های زودرس بطنی<sup>۱۵</sup> (V): ضربان‌های اضافی قلب هستند که در یکی از دو محفظه پمپاژ پایینی قلب (بطن) شروع می‌شوند. این ضربان‌های اضافی ریتم منظم قلب را مختل می‌کنند و گاهی باعث ایجاد احساس لرزش در قفسه سینه می‌شوند. در این دسته انقباضات زودرس بطنی<sup>۱۶</sup> و ضربان‌های زودرس بطنی<sup>۱۷</sup> قرار دارند.

ضربان فیوژن<sup>۱۸</sup>: رخداد هم‌زمان یک ضربان نرمال و یک ضربان بطنی با یکدیگر موجب ایجاد ضربان فیوژن می‌شود. ضربان‌های ناشناخته (Q): ضربان‌های P، U و FPN<sup>۱۹</sup> در این دسته قرار دارند.

## ۲. کارهای مرتبط

در این بخش مختصری از کارهای انجام شده در حوزه تشخیص ناهنجاری‌های قلبی با استفاده از تکنیک‌های یادگیری ماشین آمده است. مسئله تشخیص ناهنجاری قلبی با استفاده از سیگنال‌های ECG را می‌توان به دو بخش تقسیم نمود: (۱) بخش‌بندی سیگنال به ضربان و (۲) دسته‌بندی ضربان. در ادامه به مرور تحقیقات انجام شده در این دو دسته می‌پردازیم.

15- Premature ventricular contraction

16- Premature ventricular complexes

17- Ventricular premature beats

18- Fusion beat

19- Paced beat, Unclassified beat, and Fusion of paced and Normal beat

الگوریتم نزدیکترین همسایه برای دسته‌بندی مجموعه داده MIT-BIH به پنج رده استفاده شده است [۲۰]. همچنین در منابع [۲۱، ۲۲] به ترتیب روش‌های لجستیک رگرسیون و درخت تصمیم<sup>۲۰</sup> برای دسته‌بندی سیگنال ECG استفاده شده‌اند. در برخی پژوهش‌ها، روش‌های مبتنی بر یادگیری گروهی مانند XGboost به منظور بهبود نتایج در روش‌های رده‌یک به کار برده شده است [۲۳].

با توسعه روش‌های یادگیری عمیق، محققان بسیاری به استفاده از این روش‌ها برای حل مسئله تشخیص ناهنجاری در سیگنال ECG روی آوردند. مدل‌های مختلفی از شبکه‌های یادگیری عمیق برای این منظور به کار گرفته شد. در برخی مطالعات از شبکه‌های خودککننده پشته‌ای (SAE)<sup>۲۱</sup> استفاده شده است. یک مدل تُنک از شبکه‌های SAE در سال ۲۰۱۸ در مطالعه فرهادی و همکاران مورد استفاده قرار گرفت [۲۴]. شبکه‌های SAE اغلب به نتایج خوبی در این زمینه دست یافته‌اند اما از آنجایی که همیشه رسیدن به بالاترین نتیجه مد نظر است محققان به سایر رویکردهای عمیق توجه نمودند. آلتان و همکاران در یک پژوهش از شبکه‌های باور عمیق (DBN)<sup>۲۲</sup> برای همین مسئله بهره بردند [۲۵]. مدل پیشنهادی در این مطالعه از چندین ماژول DBN برای دسته‌بندی چهار نوع از ناهنجاری‌های قلبی (V, S, N) و F استفاده می‌نماید. مدل پیشنهادی در این مطالعه گرچه به نتایج خوبی دست یافت اما مدل پیچیدگی قابل توجهی دارد. از آنجایی که شبکه‌های عصبی بازگشتی (RNN)<sup>۲۳</sup> با داده‌های سری زمانی سازگاری خوبی دارند، در برخی مطالعات از شبکه‌های RRN برای دسته‌بندی سیگنال الکتروکاردیوگرام استفاده شده است. به عنوان نمونه، منبع [۲۶]، یک شبکه بازگشتی با ماژول‌های LSTM به منظور دسته‌بندی سیگنال ECG به کار برده است. دسته‌بندی در شبکه‌های RNN غالباً با استفاده از ماژول‌های LSTM و CNN انجام می‌شود که برای بهبود نتایج لازم است

ضربان قلب تشخیص داده می‌شود [۱۴]. شناسایی سیگنال به این روش نیازمند تعریف یک حد آستانه از پیش تعریف شده است. در سال ۲۰۱۲، روش SEEHT پیشنهاد شد که در آن موج QRS پیچیده با استفاده از آنتروپی شانون و انتقال هیلبرت شناسایی گردید [۱۵]. پس از آن شیوه‌های بهبودیافته دیگری برای تشخیص ضربان قلب با الهام از روش SEEHT با نام‌های PSEE [۱۶] و ISEE [۱۷] ارائه گردید. این شیوه‌ها از پیچیدگی کمتری نسبت به مدل SEEHT برخوردار بودند و در تشخیص ضربان قلب کارایی بهتری داشتند.

## ۲-۲. دسته‌بندی

به منظور دسته‌بندی سیگنال‌های الکتروکاردیوگرام روش‌های مختلفی مورد استفاده قرار می‌گیرد. این روش‌ها در سه دسته کلی روش‌های مبتنی بر خوشه‌بندی، روش‌های مبتنی بر یادگیری ماشین سنتی و روش‌های مبتنی بر یادگیری عمیق، قرار دارند [۱۰].

الگوریتم K-means یکی از معروف‌ترین الگوریتم‌های خوشه‌بندی است که در مطالعه ویراوالیی و همکاران [۱۸] برای تشخیص نوع ناهنجاری قلبی به کار برده شده است. روش‌های مبتنی بر خوشه‌بندی روش‌های بدون نظارتی هستند که با توجه به ماهیت پیچیده مجموعه داده MIT-BIH غالباً به نتایج خوبی دست نمی‌یابند. روش‌های رده‌یک یادگیری ماشین شامل طیف وسیعی از روش‌هاست که در اینجا به بیان چند نمونه بسنده می‌شود. در بسیاری از روش‌های رده‌یک یادگیری ماشین، مدل با محاسبه یک معیار فاصله یا شباهت، قادر به دسته‌بندی سیگنال‌های الکتروکاردیوگرام است. در منبع [۱۹] با محاسبه ویژگی DTW، دسته‌بندی ضربان قلب انجام شده است. استفاده از این مدل‌های مبتنی بر روش‌های رده‌یک نیز نیاز به تعریف حد آستانه شباهت یا تفاوت دارند. استفاده از الگوریتم‌های دسته‌بندی یادگیری ماشین، راه حل دیگری در این دسته از روش‌هاست که می‌توان برای تشخیص نوع ناهنجاری قلبی به کار برد. در مطالعه چریستوو و همکاران از

20- Logistic regression and Decision Tree

21- Stacked Auto-encoders

22- Deep belief network Deep

23- Recurrent neural network



پیچیدگی مدل افزایش یابد.

در سال‌های اخیر به‌صورت گسترده‌ای از شبکه‌های هم‌آمیختی برای دسته‌بندی ناهنجاری‌های قلبی استفاده شده است. در مطالعه موسوی و همکاران در سال ۲۰۱۹ [۲۷]، از یک شبکه هم‌آمیختی برای دسته‌بندی استفاده شده است که شامل یک شبکه RNN و یک شبکه LSTM است. همانگونه که در مقدمه نیز ذکر شد در مطالعه کاجویی و همکاران [۵]، از یک شبکه عمیق هم‌آمیختی برای دسته‌بندی سیگنال‌های ECG استفاده شده است. پس از آن مطالعات زیادی از ساختار بهبودیافته شبکه هم‌آمیختی برای این منظور استفاده نمودند که تعداد کمی از کارهای انجام شده در این حوزه از سازوکارهای مبتنی بر هزینه برای بهبود نتایج مدل استفاده کرده‌اند [۶]. با توجه به این کاستی، در مطالعه پیش‌رو، سعی در بهبود نتایج یک شبکه هم‌آمیختی با استفاده از روش‌های مبتنی بر هزینه شده است.

### ۳. روش پیشنهادی

در این بخش روش پیشنهادی برای دسته‌بندی نامنظمی ارائه می‌شود که شامل سه مرحله اصلی است: ۱- بخش‌بندی مجموعه داده ۲- آموزش شبکه ۳- دسته‌بندی. در مرحله بخش‌بندی داده، سیگنال ورودی که به‌صورت یک سیگنال پیوسته و وابسته به زمان است توسط الگوریتم بخش‌بندی به زیردنباله‌هایی با طول مساوی که هر کدام شامل دو پیک R هستند تقسیم می‌شوند. مرحله آموزش و دسته‌بندی مدل پیشنهادی که مبتنی بر یک شبکه هم‌آمیختی است از دو بلوک اصلی هم‌آمیختی تشکیل شده است که وظیفه دسته‌بندی مجموعه داده ورودی را به عهده دارد. در ادامه این بخش جزئیات بیشتری از مدل پیشنهادی آمده است.


#### ۳-۱. بخش‌بندی سیگنال به ضربان قلب

نوعی از بخش‌بندی سیگنال ضربان قلب در مطالعه [۶] پیشنهاد شده است که از آن با نام روش RR یاد می‌کنیم. همان‌گونه که در شکل ۲ مشهود است این روش بخش‌بندی ضربان قلب برخلاف روش‌های معمول که شامل یک موج


کامل P-QRS-T هستند، می‌باشد. در این روش یک سیگنال ضربان قلب از یک پیک R آغاز می‌شود و به میزان ۱/۲ برابر زمان میانه بازه RR در یک پنجره ۱۰ ثانیه با فرکانس ۳۶۰ هرتز ادامه دارد. این روش بخش‌بندی باعث می‌شود بازه‌های معنی‌داری همچون PR و RR و QT در یک سیگنال موجود باشد که در دسته‌بندی سیگنال‌های ECG کاربرد دارند. ضربان‌های قلب شناسایی شده به این روش طول مساوی دارند. در شکل (۲)، یک بخش سیگنال ضربان قلب به روشی که در مطالعه کاجویی (سمت چپ) بخش شده است در مقابل یک بخش سیگنال ضربان قلب به روش RR نشان داده شده است. در مطالعه کاجویی و همکاران یک ضربان قلب شامل یک موج کامل P-QRS-T است که با فرکانس ۱۲۵ هرتز نمونه‌برداری شده است [۵]. استاندارد AAMI یک سیگنال ضربان قلب را در مجموعه داده MIT-BIH در موقعیت پیک R برچسب‌گذاری و تفسیر می‌کند. در روش RR این برچسب براساس برچسب پیک R دوم در مجموعه داده تفسیر می‌شود.

#### ۳-۲. معماری شبکه هم‌آمیختی

در شکل (۳)، معماری شبکه برای دسته‌بندی مجموعه داده قلب نشان داده شده است. ورودی شبکه ضربان‌های قلبی است که در قسمت ۳-۱ استخراج شده‌اند. این شبکه دارای سه بلوک اصلی می‌باشد. هر بلوک شامل سه لایه هم‌آمیختی یک بعدی است. هر لایه هم‌آمیختی از یک فیلتر ۲۵۶ با اندازه ۲ و گام ۱ برای استخراج ویژگی‌های مجموعه داده استفاده می‌کند. خروجی سه لایه هم‌آمیختی از یک لایه نرمال‌ساز دسته‌ای و حذف عبور می‌کنند. لایه نرمال‌ساز دسته‌ای برای نرمال کردن داده‌ها و تنظیم فعال‌سازها کاربرد دارد. این تابع ثبات و کارایی دسته‌بندی کننده را بهبود می‌بخشد و یادگیری آن را با گرادینان نزولی تسریع می‌کند. در این لایه پس از نرمال‌سازی داده، دنباله‌ای از عملیات shift و scale مطابق رابطه زیر انجام می‌شود.



شکل (۲): بخش بندی یک سیگنال الکتروکاردیوگرام: سمت راست مدل RR، سمت چپ مدل P-QRS-T [۵].



شکل (۳): معماری شبکه هم آمیختی در مدل پیشنهادی

$$\sigma(\vec{z}_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2)$$

در این رابطه  $\sigma$  تابع softmax،  $\vec{z}_i$  بردار ورودی و  $k$  تعداد رده‌ها است.

### ۳-۳. وزن دهی رده‌ها

همان‌گونه که در بخش مقدمه نیز گفته شد مسئله دسته‌بندی مجموعه داده الکتروکاردیوگرام یک مسئله یادگیری نامتعادل است که معمولاً الگوریتم دسته‌بندی به سمت رده‌های اکثریت گرایش می‌یابد. یکی از راه‌های غلبه بر مسئله، استفاده از سازوکار وزن‌دهی در سطح رده است. در این حالت با محاسبه وزن هر رده و تاثیر این وزن در مرحله آموزش شبکه و تابع هزینه سبب می‌شود گرایش شبکه در مرحله آموزش تعدیل گردد. روش وزن‌دهی در مدل پیشنهادی براساس معکوس تعداد نمونه‌ها به صورت رابطه (۳) محاسبه می‌شود.

$$y_i = \gamma x_i + \beta \quad (1)$$

که در آن  $\gamma, \beta$  پارامترهای یادگیری هستند. لایه بعدی (Dropout) با حذف تصادفی نرون‌ها برای پیشگیری از بیش‌برازش اعمال می‌شود. مجموعه داده ورودی پس از گذشت از سه بلوک هم آمیختی از یک لایه Global Average Pooling و Fully connected عبور می‌کنند. لایه Global average Pooling به منظور نگاشت بردار ویژگی به هر دسته از رده‌هاست که در شبکه‌های هم آمیختی استفاده می‌شود. لایه Fully connected برای معکوس کردن عملیات شبکه و بازگرداندن داده‌های شبکه به یک تنسور یک بعدی است و در نهایت لایه softmax احتمال عضویت هر داده به هر یک از پنج رده در مجموعه نوار قلب را با توجه به خروجی‌های مرحله قبل محاسبه می‌کند (رابطه (۲)). از بهینه‌ساز Adam در شبکه برای عملیات بهینه‌سازی استفاده می‌شود.



است که توسط کاربر تعریف می‌شود.  $M_{oph}^*$  یک ماتریس وزن‌دهی اولیه است که می‌تواند به صورت دستی توسط فرد خبره و یا براساس ماتریس آشفتگی حاصل از اجرای مدل بدون استفاده از جمله دوم رابطه (۵) محاسبه و تکمیل شود. برای جزییات بیشتر در مورد نحوه محاسبه این ماتریس  $M_{oph}^*$  به منبع [۲۹] مراجعه شود.  $M_{ij}$  نشان‌دهنده هزینه هر عضو رده  $i$ ام است که به صورت اشتباه در رده  $j$ ام دسته‌بندی شود.

#### ۴. مجموعه داده

مجموعه داده مورد استفاده در این مطالعه مشابه با بسیاری از مطالعات این حوزه، مجموعه داده MIT-BIH Arrhythmia است. این مجموعه داده که در بین سال‌های ۱۹۷۵ تا ۱۹۸۰ میلادی ثبت شده است شامل اطلاعات سیگنال‌های برگزیده ECG مربوط به ۴۸ بیمار است که هر نیم ساعت ذخیره و به صورت دو کاناله نمونه‌برداری شده‌اند. ۲۳ رکورد از این مجموعه شامل بیماران تصادفی است که ۶۰ درصد آن را بیماران بستری و ۴۰ درصد را بیماران سرپایی تشکیل می‌دهند. ۲۵ رکورد دیگر شامل نامنظمی‌های کم‌تکرار اما بسیار مهم از نظر بالینی هستند. رکوردها بر حسب کد بیمار نامگذاری شده‌اند. مجموعه MIT-BIH حاوی ۱۵ نوع ضربان قلب است که مطابق جدول ۱ در ۵ گروه براساس استاندارد AAMI EC57 دسته‌بندی شده‌اند [۲۸].

#### ۵. معیارهای ارزیابی

معیارهای ارزیابی عملکرد مدل پیشنهادی در این مطالعه عبارتند از صحت، دقت<sup>۲۷</sup>، یادآوری<sup>۲۸</sup> و معیار F<sup>۲۹</sup> که توسط روابط (۶-۹) تعریف می‌شوند.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$W_i = \frac{samples_{total}}{(n * samples_i)} \quad (3)$$

که در این رابطه،  $W_i$  وزن رده  $i$ ام،  $samples_{total}$  تعداد کل نمونه‌ها،  $samples_i$  تعداد نمونه‌ها در رده  $i$ ام و  $n$  تعداد کل رده‌هاست.

#### ۳-۴. تابع ضرر مبتنی بر هزینه

تابع ضرر<sup>۲۴</sup> تابعی است که یک رویداد و یا مقادیر چند متغیر را به یک عدد طبیعی نگاشت می‌کند. در مسائل مربوط به آموزش یک شبکه یادگیری عمیق، بهینه‌سازی منجر به کمینه‌سازی تابع هزینه می‌شود. آنتروپی شانون<sup>۲۵</sup> یا تابع ضرر کراس-آنتروپی برای محاسبه هزینه یک رویداد در یک مسئله دسته‌بندی از منفی لگاریتم احتمال آن رویداد مطابق رابطه (۴) استفاده می‌کند.

$$\mathcal{L}_{CE}(\hat{y}, y) = \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (4)$$

در این رابطه  $\hat{y} \in [0,1] \times \dots \times [0,1]$  برچسب تخصیص داده شده توسط مدل به صورت one-hot است و  $y \in \{0,1\} \times \dots \times \{0,1\}$  برچسب رده‌ای است که واقعا به آن تعلق دارد و  $k$  تعداد کل رده‌هاست.

در مسائل دسته‌بندی مربوط به مجموعه داده‌های نامتوازن، یک راه حل استفاده از تنظیم‌کننده‌های<sup>۲۶</sup> مبتنی بر هزینه است که سبب بهبود این گرایش می‌گردند. در مدل پیشنهادی از یک روش مبتنی بر هزینه که در مطالعه گالدرن و همکاران [۲۹] معرفی شده، به عنوان تنظیم‌کننده هزینه استفاده می‌نمایم. این روش پس از محاسبه مقدار تابع ضرر پایه که در اینجا کراس-آنتروپی می‌باشد، ضرر کل را براساس رابطه (۵) محاسبه می‌نماید.

$$\mathcal{L}_{CS}(\hat{y}, y) = \mathcal{L}_{CE}(\hat{y}, y) + \lambda(M(y, 0), \hat{y}), \quad (5)$$

$$M = (M^{(2)} + I + M_{oph}^*)/2$$

$$M_{ij}^{(2)} = \|i - j\|_2^2$$

در این رابطه،  $M^{(2)}$  یک ماتریس  $n \times n$  و  $\lambda$  پارامتری

27- Precision

28- Recall

29- F-score

24- Loss Function

25- Cross Entropy

26- Regulator

جدول (۲): پارامترهای مدل پیشنهادی

نام پارامتر	مقدار پارامتر	نام پارامتر	مقدار پارامتر
فیلتر	۲۵۶	پدینگ	۲
اندازه فیلتر	۲	سافت ماکز	۱
لایه مخفی	۱۲۸	بهبینه ساز	Adam
نرخ حذف	۰٫۵	تکرار	۵۰۰
اندازه دسته	۱۲۸	لامبدا	۵

از محاسبه این جمله در تشکیل ماتریس هزینه صرف نظر شده است.

### ۶-۲. آموزش شبکه

به منظور ایجاد قابلیت مقایسه بین نتایج تحقیقات مختلف بر روی مجموعه MIT-BIH، رکوردها به دو مجموعه DS1 و DS2 تقسیم می‌شوند که در مرحله آموزش مجموعه DS1 و در مرحله آزمایش مجموعه DS2 مورد استفاده می‌گیرد. این تقسیم‌بندی در مطالعه چازال و همکاران [۲۰] پیشنهاد شده است که از آن با نام روش inter-patient یاد می‌شود. دو مجموعه DS1 و DS2 به شکل زیر تعریف می‌شوند:

DS1 = {۲۰۵، ۲۰۳، ۲۰۱، ۱۲۴، ۱۲۲، ۱۱۹، ۱۱۶، ۱۱۴، ۱۱۵، ۱۰۸، ۱۰۶، ۱۰۱، ۲۳۰، ۲۲۰، ۲۲۳، ۲۰۹، ۲۱۵، ۲۰۸، ۲۰۷، ۱۰۹، ۱۱۲}

DS2 = {۲۱۳، ۲۱۲، ۲۱۰، ۲۰۲، ۲۰۰، ۱۲۳، ۱۲۱، ۱۱۷، ۱۱۳، ۱۰۰، ۲۳۴، ۲۳۳، ۲۳۱، ۲۳۱، ۲۳۱، ۲۲۸، ۲۲۲، ۲۲۱، ۲۱۹، ۲۱۴، ۱۰۳، ۱۰۵، ۱۱۱}

که هر عدد نشان‌دهنده کد یک بیمار است و رکوردهای ۲۱۷، ۱۰۷، ۱۰۴ و ۱۰۲ حذف شده‌اند [۲۹]. اطلاعات بیشتر در مورد توزیع مجموعه‌های آموزش و آزمایش مجموعه داده MIT-BIH مورد استفاده در مدل پیشنهادی در جدول (۳) آمده است.

### ۶-۳. آزمایش‌ها

مدل پیشنهادی مطابق آنچه در زیربخش‌های ۶-۱ و ۶-۲ گفته شده است پیکره‌بندی و آموزش داده شد. همچنین به منظور ایجاد نتایج مقایسه‌ای در آزمایش‌ها از یک مدل پایه به همراه چهار مدل دیگر استفاده گردیده است. یک مدل

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$F - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (9)$$

که در آن مثبت واقعی (TP)، منفی واقعی (TN)، مثبت کاذب (FP) و منفی کاذب (FN) از ماتریس درهم‌ریختگی<sup>۳۰</sup> به دست می‌آید.

معیار F نسبت به سایر شاخص‌ها، معیار بهتری برای نشان دادن میزان کارایی مدل‌های دسته‌بندی داده‌های نامتعادل می‌باشد چرا که در این روش‌ها معیارهایی نظیر صحت با توجه به وجود رده‌های اکثریت اغلب مقادیر نزدیک به یک نشان می‌دهند که به تنهایی قابلیت تفسیر عملکرد یک مدل را ندارند.

### ۶-۴. آزمایش‌های تجربی

به منظور ارزیابی کارایی مدل پیشنهادی، در این بخش آزمایش‌های مختلفی طراحی و اجرا شده است. در ادامه، ابتدا جزییات مربوط به پیاده‌سازی مدل پیشنهادی و پارامترهای شبکه معرفی می‌شوند. سپس نحوه آموزش شبکه با مجموعه داده MIT-BIH و در انتهای بخش، آزمایش‌های انجام شده به همراه نتایج حاصل و بحث و بررسی آنها ارائه شده است.

### ۶-۱. پیکره‌بندی مدل پیشنهادی

کلیه پیاده‌سازی‌های مربوط به مدل پیشنهادی با زبان پایتون نسخه ۳٫۸ و پایتورچ نسخه ۱٫۶ و کودا ۱۲ بر روی سیستمی با سیستم‌عامل لینوکس ابونتو LTS 22.04.1، پردازنده AMD Ryzen Threadripper CPU 1950X (۳۲) 3.400HZ، حافظه رم 16G و کارت گرافیک GPU NVIDIA Geforce RTX 2080 Ti Rev انجام شده است. پارامترهای مربوط به شبکه هم‌آمیختگی به شرح جدول (۲) می‌باشد.

همچنین با توجه به عدم وجود فرد خبره جهت تکمیل ماتریس  $M_{opt}^*$  در شبیه‌سازی‌های مربوط به این مطالعه

30- Confusion Matrix

جدول (۴): نتایج مدل پیشنهادی بر روی مجموعه MIT-BIH

معیار F	صحت	یادآوری	دقت	
۰/۸۰۶	۰/۶۹۲	۰/۶۹۲	۰/۹۶۶	N
۰/۵۶۷	۰/۵۵۳	۰/۵۵۳	۰/۵۸۲	S
۰/۲۹۱	۰/۸۵۰	۰/۸۵	۰/۱۷۶	V
۰/۰۰۲	۰/۰۰۳	۰/۰۰۳	۰/۰۰۲	F
۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	Q

نمونه‌ها در مرحله آموزش نشان از عملکرد موفق مدل دارد. لازم به ذکر است که هیچ کدام از مدل‌های به کار برده شده در این مطالعه قادر به تشخیص نمونه‌های رده Q نشدند.

برای ایجاد امکان مقایسه بهتر، نتایج مدل پیشنهادی، در جدول (۵)، نتایج شبیه‌سازی مدل پایه به همراه مدل پیشنهادی ارائه شده است. نتایج مدل پایه با شبیه‌سازی بدون احتساب هزینه و وزن‌دهی نسبت به مدل پیشنهادی تأثیر عملکرد این دو سازوکار را بهتر نشان می‌دهد. در این جدول نیز نتایج به تفکیک رده آمده است. جدول نشان می‌دهد که مدل پایه تنها قادر به تشخیص نمونه‌های رده اکثریت است و همانطور که پیش‌بینی می‌شد، دسته‌بندی به سمت رده اکثریت گرایش یافته است و در تشخیص نمونه‌های مربوط به سایر رده در بیشتر موارد موفق عمل ننموده است به نحوی که مقادیر شاخص‌ها در دسته‌های S و F صفر گزارش شده در حالی که این شاخص‌ها پس از اعمال وزن‌دهی و تابع ضرر مبتنی بر هزینه در مدل پیشنهادی به میزان قابل توجهی بهبود داشته‌اند. بخصوص این مقدار برای دسته S به عدد قابل توجه ۰/۵۶۷ برای معیار F رسیده است. همچنین در رده V تعداد ۲۷۳۹ نمونه از ۳۲۲۱ مورد توسط مدل قابل تشخیص بوده است که برتری آن در شاخص‌های صحت و یادآوری مشاهده می‌شود.

در جدول (۶) نتایج کلی شبیه‌سازی سایر مدل‌ها به همراه نتایج مدل پیشنهادی آمده است. در این جدول برای هر مدل دو مقدار میانگین محاسبه شده است. میانگین کل که نشان‌دهنده میانگین مقادیر یک شاخص در همه

جدول (۳): اطلاعات مربوط به توزیع داده‌ها در مجموعه MIT-BIH

دسته	آموزش	آزمایش
N	۴۵۸۶۶	۴۴۲۵۹
S	۹۴۴	۱۸۳۷
V	۳۷۸۸	۳۲۲۱
F	۴۱۵	۳۸۸
Q	۸	۷
کل مجموعه	۵۱۰۲۱	۴۹۷۱۲

پایه که معماری و پیکره‌بندی آن مطابق مدل پیشنهادی در بخش ۳ است و فاقد تابع ضرر مبتنی بر هزینه و وزن‌دهی رده‌ای است و تنها از تابع ضرر کراس-آنتروپی بهره می‌برد. علاوه بر مدل پایه، مدل کاقویی که یک مدل مبتنی بر شبکه هم‌آمیختگی است و تاکنون در مطالعات بسیاری مورد استفاده قرار گرفته است پیاده‌سازی و اجرا گردید. همچنین سایر مدل‌های مقایسه‌ای شامل الگوریتم‌های درخت تصمیم، لجستیک رگرسیون و XGboost هستند که از نسخه پیاده‌سازی شده آنها در بسته sklearn<sup>۳۱</sup> استفاده شده است. همان‌گونه که مشهود است به منظور فراهم‌سازی شرایط رقابت عادلانه با مدل پیشنهادی، روش‌های رقیب در این آزمایش‌ها شامل هر سه طیف مدل‌های معرفی شده در بخش کارهای مرتبط می‌باشند.

نتایج حاصل از شبیه‌سازی مدل پیشنهادی براساس شاخص‌های گفته شده در بخش ۶ در جدول (۴) به تفکیک دسته‌های نامنظمی آمده است. این جدول نشان می‌دهد که مدل پیشنهادی با معیار F تقریباً ۰/۸ قادر به تشخیص رده نرمال است. اگرچه مقدار این شاخص و سایر شاخص‌ها برای سایر دسته‌های نامنظمی کمتر از دسته نرمال است اما با توجه به بسیار نامتعادل بودن مجموعه داده (حدود ۸۹ درصد نمونه‌ها در مجموعه آموزش متعلق به دسته نرمال است و به ترتیب رده V دارای ۰/۰۷ درصد نمونه، بیشترین و رده Q با حدود ۰/۰۰۰۰۱ درصد نمونه، کمترین تعداد نمونه در مرحله آموزش) این نتایج قابل توجه است. بخصوص نتایج برای رده S با وجود تعداد بسیار کم

جدول (۵): مدل پیشنهادی در مقابل مدل پایه به تفکیک دسته ها

مدل پیشنهادی				مدل پایه				
معیار F	صحت	یادآوری	دقت	معیار F	صحت	یادآوری	دقت	
۰/۸۰۶	۰/۶۹۲	۰/۶۹۲	۰/۹۶۶	۰/۸۹۱	۰/۸۵۵	۰/۸۵۵	۰/۹۳	N
۰/۵۶۷	۰/۵۵۳	۰/۵۵۳	۰/۵۸۲	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	S
۰/۲۹۱	۰/۸۵۰	۰/۸۵	۰/۱۷۶	۰/۴۲۳	۰/۷۷۷	۰/۷۷۷	۰/۲۹	V
۰/۰۰۲	۰/۰۰۳	۰/۰۰۳	۰/۰۰۲	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	F
۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	Q

جدول (۶): مقایسه مدل پیشنهادی با سایر مدل ها

معیار F	صحت	یادآوری	دقت		
۰/۳۳۳	۰/۴۲۰	۰/۳۴۵	۰/۶۹۲	مدل پیشنهادی	
۰/۲۱۵	۰/۳۵۲	۰/۱۹۰	۰/۶۸۹	میانگین رده‌های غیر نرمال	
۰/۳۲۴	۰/۳۵۰	۰/۳۰۶	۰/۸۱۶	میانگین کل	
۰/۱۷۰	۰/۲۰۴	۰/۱۴۷	۰/۵۵۳	میانگین رده‌های غیر نرمال	
۰/۲۸۷	۰/۳۳۸	۰/۲۶۹	۰/۸۰۶	میانگین کل	
۰/۱۳۶	۰/۲۱۱	۰/۱۰۱	۰/۲۶۹	میانگین رده‌های غیر نرمال	
۰/۲۰۴	۰/۲۹۸	۰/۲۲۵	۰/۵۵۱	میانگین کل	
۰/۰۷۶	۰/۲۲۸	۰/۱۱۲	۰/۳۲۴	میانگین رده‌های غیر نرمال	
۰/۲۰۵	۰/۳۲۹	۰/۲۲۶	۰/۵۵۰	میانگین کل	
۰/۰۷۸	۰/۲۶۷	۰/۰۵۰	۰/۳۲۶	میانگین رده‌های غیر نرمال	

یک سازوکار جدید برای تقسیم مجموعه داده ورودی به ضربان‌های قلب با طول مساوی استفاده شد. یک شبکه هم‌میختی با بهره‌گیری از تابع ضرر مبتنی بر هزینه، دسته‌بندی مجموعه بسیار نامتعادل ورودی را بر عهده دارد. سازوکار محاسبه ضرر مبتنی بر هزینه برای حل مشکل گرایش مدل‌های دسته‌بندی در دسته‌بندی مجموعه‌های بسیار نامتعادل لحاظ شده است. مدل پیشنهادی همچنین در مجموعه داده ورودی از یک راه حل وزندهی سطح رده‌ای بهره می‌برد. نتایج حاصل از شبیه‌سازی مدل پیشنهادی بر روی مجموعه داده MIT-BIH نشان از برتری عملکرد آن نسبت به سایر مدل‌های رقیب می‌دهد. نویسندگان مقاله حاضر در توسعه‌های آتی سعی در بهبود عملکرد مدل با ایجاد قابلیت محاسبه خودکار ماتریس وزندهی در تابع ضرر مبتنی بر هزینه دارند.

دسته‌هاست و میانگین رده‌های غیر نرمال که میانگین مقادیر یک شاخص در همه دسته‌ها به جز دسته نرمال (N) است. به دلیل بسیار نامتعادل بودن مجموعه داده، از شاخص میانگین رده‌های غیر نرمال برای نشان دادن میزان عملکرد مدل در تشخیص دسته‌های غیر نرمال استفاده شده است. همان گونه که در جدول (۶) قابل مشاهده است عملکرد مدل پیشنهادی در تقریباً همه شاخص‌ها بجز یک شاخص (دقت) از سایر مدل‌های مقایسه‌ای بهتر است. بخصوص این برتری در معیار F با میانگین رده‌های غیر نرمال با مقدار ۰/۲۱۵ در مقابل بهترین نتیجه سایر مدل‌ها با مقدار ۰/۱۷۰ برای مدل کچویی مشاهده می‌شود. همچنین بهترین میانگین کل صحت با مقدار ۰/۴۲۰ برای مدل پیشنهادی نسبت به سایر مدل‌ها نشان از کارایی مدل پیشنهادی دارد.

### نتیجه‌گیری

مطالعه حاضر با استفاده از مدل‌های یادگیری عمیق مبتنی بر هزینه، سعی بر حل مسئله دسته‌بندی انواع ناهنجاری‌های قلبی داشته است. در مدل پیشنهادی از

- [16] H. Zhu and J. Dong, "An R-peak detection method based on peaks of Shannon energy envelope," *Biomed. Signal Process. Control*, vol. 8, no. 5, pp. 466–474, Sep. 2013, doi: 10.1016/j.bspc.2013.01.001.
- [17] M. Rakshit, D. Panigrahy, and P. K. Sahu, "An improved method for R-peak detection by using Shannon energy envelope," *Sādhanā*, vol. 41, no. 5, pp. 469–477, May 2016, doi: 10.1007/s12046-016-0485-8.
- [18] B. Veeravalli, C. J. Deepu, and D. Ngo, "Real-Time, Personalized Anomaly Detection in Streaming Data for Wearable Healthcare Devices," 2017, pp. 403–426.
- [19] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet," *Circulation*, vol. 101, no. 23, Jun. 2000.
- [20] I. Christov, G. Gómez-Herrero, V. Kraševa, I. Jekova, A. Gotchev, and K. Egiazarian, "Comparative study of morphological and time-frequency ECG descriptors for heartbeat classification," *Med. Eng. Phys.*, vol. 28, no. 9, pp. 876–887, Nov. 2006, doi: 10.1016/j.medengphy.2005.12.010.
- [21] M. A. Escalona-Moran, M. C. Soriano, I. Fischer, and C. R. Mirasso, "Electrocardiogram Classification Using Reservoir Computing With Logistic Regression," *IEEE J. Biomed. Heal. Informatics*, vol. 19, no. 3, pp. 892–898, May 2015.
- [22] M. Hadjem and F. Nait-Abdesselam, "An ECG T-wave anomalies detection using a lightweight classification model for wireless body sensors," in *2015 IEEE International Conference on Communication Workshop (ICCW)*, Jun. 2015, pp. 278–283, doi: 10.1109/ICCW.2015.7247191.
- [23] S. K. Pandeyz, R. R. Janghel, and V. Gupta, "Cardiac Arrhythmia Detection and Classification From ECG Signals Using XGBoost Classifier," in *Machine Learning Algorithms and Applications*, Wiley, 2021, pp. 141–157.
- [24] J. Farhadi Sedehi, G. Attarodi, N. Jafarnia Dabanloo, M. Mo-handespor, and M. Eslamizadeh, "Classification Atrial Fibrillation Using Stacked Autoencoders Neural Networks," Dec. 2018, doi: 10.22489/CinC.2018.011.
- [25] G. Altan, Y. Kutlu, and N. Allahverdi, "A Multistage Deep Belief Networks Application on Arrhythmia Classification," *Int. J. Intell. Syst. Appl. Eng.*, vol. 4, no. Special Issue-1, pp. 222–228, 2016, doi: 10.18201/IJISAE.270367.
- [26] Ö. Yildirim, "A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification," *Comput. Biol. Med.*, vol. 96, pp. 189–202, May 2018, doi: 10.1016/j.compbiomed.2018.03.016.
- [27] S. Mousavi and F. Afghah, "Inter- and Intra- Patient ECG Heartbeat Classification for Arrhythmia Detection: A Sequence to Sequence Deep Learning Approach," in *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, May 2019, pp. 1308–1312, doi: 10.1109/ICASSP.2019.8683140.
- [28] "AAMI (Association for the Advancement of Medical Instrumentation)," *J. Japan Soc. Comput. Aided Surg. J. JSCAS*, vol. 3, no. 1, pp. 36–37, 2001.
- [29] A. Galdran, J. Dolz, H. Chakor, H. Lombaert, and I. Ben Ayed, "Cost-Sensitive Regularization for Diabetic Retinopathy Grading from Eye Fundus Images," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12265 LNCS, pp. 665–674, 2020, doi: 10.1007/978-3-030-59722-1\_64.
- [30] P. De Chazal, M. O'Dwyer, and R. B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 7, pp. 1196–1206, 2004, doi: 10.1109/TBME.2004.2690004.
- [31] Z. Ebrahimi, M. Loni, M. Daneshdatab, and A. Gharehbaghi, "A review on deep learning methods for ECG arrhythmia classification," *Expert Syst. with Appl.* X, vol. 7, p. 100033, 2020, doi: 10.1016/j.eswa.2020.100033.
- [32] V. Gupta, N. K. Saxena, A. Kanungo, A. Gupta, P. Kumar, and Salim, "A review of different ECG classification/detection techniques for improved medical applications," *Int. J. Syst. Assur. Eng. Manag.*, vol. 13, no. 3, pp. 1037–1051, 2022, doi: 10.1007/s13198-021-01548-3.
- [33] M. Ayar and S. Sabamoniri, "An ECG-based feature selection and heartbeat classification model using a hybrid heuristic algorithm," *Informatics Med. Unlocked*, vol. 13, pp. 167–175, 2018, doi: 10.1016/j.imu.2018.06.002.
- [34] Q. Du, W. Gu, L. Zhang, and S.-L. Huang, "Attention-based LSTM-CNNs for time-series classification," in *Proceedings of the 16th ACM conference on embedded networked sensor systems*, 2018, pp. 410–411.
- [35] M. Kachuee, S. Fazeli, and M. Sarrafzadeh, "ECG heartbeat classification: A deep transferable representation," *Proc. - 2018 IEEE Int. Conf. Healthc. Informatics, ICHI 2018*, pp. 443–444, 2018, doi: 10.1109/ICHI.2018.00092.
- [36] T. F. Romdhane, H. Alhichri, R. Ouni, and M. Atri, "Electrocardiogram heartbeat classification based on a deep convolutional neural network and focal loss," *Comput. Biol. Med.*, vol. 123, p. 103866, 2020, doi: 10.1016/j.compbiomed.2020.103866.
- [37] M. Cao, T. Zhao, Y. Li, W. Zhang, and P. Benharash, "ECG Heartbeat classification using deep transfer learning with Convolutional Neural Network and STFT technique."
- [38] D.-H. Shin, R. C. Park, and K. Chung, "Decision Boundary-Based Anomaly Detection Model Using Improved AnoGAN From ECG Data," *IEEE Access*, vol. 8, pp. 108664–108674, 2020, doi: 10.1109/ACCESS.2020.3000638.
- [39] J. Tanha, Y. Abdi, N. Samadi, N. Razzaghi, and M. Asadpour, "Boosting methods for multi-class imbalanced data classification: an experimental review," *J. Big Data*, vol. 7, no. 1, 2020, doi: 10.1186/s40537-020-00349-y.
- [40] H. Zu Li and P. Boulanger, "A survey of heart anomaly detection using ambulatory electrocardiogram (ECG)," *Sensors (Switzerland)*, vol. 20, no. 5, 2020, doi: 10.3390/s20051461.
- [41] C. Pater, "Methodological considerations in the design of trials for safety assessment of new drugs and chemical entities," *Curr. Control. Trials Cardiovasc. Med.*, vol. 6, pp. 1–13, 2005, doi: 10.1186/1468-6708-6-1.
- [42] J. Pan and W. J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Trans. Biomed. Eng.*, vol. BME-32, no. 3, pp. 230–236, Mar. 1985, doi: 10.1109/TBME.1985.325532.
- [43] S. Choi, M. Adnane, G.-J. Lee, H. Jang, Z. Jiang, and H.-K. Park, "Development of ECG beat segmentation method by combining lowpass filter and irregular R-R interval checkup strategy," *Expert Syst. Appl.*, vol. 37, no. 7, pp. 5208–5218, Jul. 2010, doi: 10.1016/j.eswa.2009.12.069.
- [44] Z. Zidelmal, A. Amirou, M. Adnane, and A. Belouchrani, "QRS detection based on wavelet coefficients," *Comput. Methods Programs Biomed.*, vol. 107, no. 3, pp. 490–496, Sep. 2012, doi: 10.1016/j.cmpb.2011.12.004.
- [45] M. S. Manikandan and K. P. Soman, "A novel method for detecting R-peaks in electrocardiogram (ECG) signal," *Biomed. Signal Process. Control*, vol. 7, no. 2, pp. 118–128, Mar. 2012, doi: 10.1016/j.bspc.2011.03.004.

## ۸. مراجع