

تحلیل سیگنال‌های الکتروکاردیوگرام قلب انسان با استفاده از تکنیک یادگیری ماشین

چکیده

حسین اخوان، فاطمه رضائی*

گروه بیوفتونیک، دانشکده فیزیک، دانشگاه
خواجه نصیرالدین طوسی، تهران، ایران.

دریافت: ۱۴۰۴/۰۱/۱۶ ویرایش: ۱۴۰۴/۰۱/۲۲ پذیرش: ۱۴۰۴/۰۲/۲۴ آنلاین: ۱۴۰۴/۰۳/۰۱

زمینه و هدف: الکتروکاردیوگرام روشی غیرتهاجمی برای دریافت سیگنال‌های قلب است. با وجود پیشرفت در روش‌های عکس‌برداری، الکتروکاردیوگرام هنوز نقش مهمی در تشخیص بیماری‌های قلبی ایفا می‌کند. تحلیل سیگنال‌های الکتروکاردیوگرام نقش مهمی در شناسایی زودهنگام بیماری‌های قلبی نظیر آریتمی‌ها و سکنه‌های قلبی دارد. امروزه با پیشرفت علم و فناوری، روش‌های رایانه‌ای بیش از پیش مورد توجه پزشکان قرار گرفته‌اند. در این مطالعه، از روش‌های یادگیری ماشین برای دسته‌بندی ضربان‌های قلبی طبیعی و غیرطبیعی استفاده شده است.

روش بررسی: داده‌های مورد بررسی از مجموعه داده‌ای تحت عنوان Heartbeat که در سایت کگل منتشر شده، استخراج شده‌اند. این مجموعه شامل نمونه‌هایی از سیگنال‌های صوتی می‌باشد که به دو دسته سالم و ناسالم تقسیم می‌شوند. در ابتدا، داده‌ها مورد پیش‌پردازش قرار گرفتند و نرمال‌سازی شدند تا برای ورود به مدل آماده شوند. سپس، ویژگی‌های زمانی و فرکانسی از سیگنال‌ها استخراج گردیده است. در ادامه، یک مدل ترکیبی شامل لایه‌های کانولوشنی یک‌بعدی طراحی و آموزش داده شده است. همچنین، با بهره‌گیری از روش توقف زودهنگام، از بیش‌برازش جلوگیری شد و پایداری مدل بهبود یافت.

یافته‌ها: در این پژوهش نشان داده شد که با بهره‌گیری از یادگیری عمیق به ویژه استفاده از CNN و Conv 1D به دقت ۹۹٪ و زیان ۰/۰۳۵۰ برای داده‌های تست در تشخیص ضربان‌های قلب طبیعی و غیرطبیعی می‌توان رسید. این مدل توانایی تحلیل ساختارهای پیچیده و دینامیک زمانی سیگنال‌های ECG را داشته است و قادر است الگوهای مرتبط با اختلالات قلبی را تشخیص دهد.

نتیجه‌گیری: امروزه الکتروکاردیوگرام بیش از پیش مورد توجه قرار گرفته است. انتخاب مناسب مدل، استانداردسازی داده‌ها و گستره کیفی داده‌ها از عوامل دقت بالا در این پژوهش است. این پژوهش می‌تواند گامی موثر در توسعه سامانه‌های هوشمند تشخیص اختلالات قلبی باشد و در کاربردهای پزشکی، به‌ویژه در حوزه پایش مستمر بیماران، مورد استفاده قرار گیرد.

کلمات کلیدی: آریتمی، یادگیری عمیق، سیگنال ECG، الکتروکاردیوگرام، یادگیری ماشین.

*نویسنده مسئول: تهران، دانشگاه خواجه نصیرالدین
طوسی، دانشکده فیزیک، گروه بیوفتونیک.

تلفن: ۰۲۱-۲۳۰۶۴۴۵۴

E-mail: fatemehrezaei@kntu.ac.ir

مقدمه

نموداری گزارش می‌شود که به پزشک در تشخیص عملکرد قلب و در نتیجه شناخت بیماری‌های قلبی کمک می‌کند.^۱ قلب از سیگنال‌های الکتریکی برای پمپاژ خون استفاده می‌کند و دستگاه الکتروکاردیوگرام این سیگنال‌ها را از طریق الکترودهای روی پوست

الکتروکاردیوگرام یک تست پزشکی غیرتهاجمی است که فعالیت‌های الکتریکی قلب را ثبت می‌کند. این تست به صورت

پردازش‌های رایانه‌ای را در این زمینه نشان دادند به گونه‌ای که یادگیری ماشین در عرصه‌های دیگری مانند طیف‌سنجی لیزری هم مورد استفاده قرار می‌گیرد.^{۱۳،۱۲} همچنین در پژوهش Bui و همکاران نشان داده شده است که از بین پنج مدل مختلف یادگیری عمیق اعم از اینسپیشن، DenseNet ۲۰۱، MobileNetV2، NASNetLarge و VGG16 که در طبقه‌بندی سیگنال‌های ECG بررسی شده‌اند، مدل VGG16 با لید V4 و امتیاز F1 ۹۸/۱۱٪، بهترین عملکرد را در بین مدل‌های مورد بررسی داشته است.^{۱۴} در مقاله‌ای از Tanveer و همکاران که از مدل CWT-SqueezeNet استفاده شده بود، دقت ۹۸/۷٪، حساسیت ۹۹/۱٪، امتیاز F1 ۹۸/۳۳٪ و ویژگی ۹۹/۲٪ در طبقه‌بندی آریتمی‌های قلبی گزارش شده بود.^{۱۵}

در این پژوهش به بررسی نقش یادگیری عمیق در تحلیل سیگنال‌های ECG پرداخته شده است و دقت روش‌های نوین یادگیری ماشین در ارزیابی ضربان قلب طبیعی و غیرطبیعی مورد سنجش قرار گرفته است.

روش بررسی

برای یادگیری عمیق در هر حوزه‌ای به یک مجموعه داده مناسب جهت آموزش نیاز است. در این پژوهش، با توجه به محدودیت‌های موجود در منابع، از مجموعه داده‌ای استفاده شده است که قبل‌تر جمع‌آوری شده بود. مجموعه داده استفاده شده در این آزمایش، از پلتفرم کگل دانلود شده است.^{۱۶} این داده‌ها به دو دسته شامل افراد با ضربان قلب طبیعی و غیرطبیعی تقسیم شده‌اند. فرکانس نمونه‌برداری در این مجموعه از داده‌ها، ۱۲۵ هرتز و شامل ۱۴۵۵۲ نمونه می‌باشد که از این میان، ۴۰۴۶ نمونه نرمال و ۱۰۵۰۶ غیرنرمال می‌باشند. همچنین جهت در نظر گرفتن ملاحظات اخلاقی در این مجموعه داده هیچ مشخصاتی از فرد مراجعه کننده مانند نام، سن و یا جنسیت ثبت نشده است که این موضوع سبب حفظ حریم خصوصی فرد می‌شود.^{۱۶}

برای نوشتن برنامه، از زبان برنامه‌نویسی پایتون نسخه ۳،۱۲،۱۱ استفاده شده و کدها در بستر گوگل کولب اجرا شده‌اند. در این قسمت ابتدا داده‌ها از مخزن Kaggle که تحت نام shayanfazeli/heartbeat قرار دارد و شامل داده‌های نرمال و غیرنرمال

دریافت می‌کند و آنها را نمایش می‌دهد. به‌طورکلی، الکتروکاردیوگرام بیماری‌هایی مانند آریتمی قلبی، فرآیندهای التهابی (به‌عنوان مثال، پریکاردیت)، سکت قلبی (انفارکتوس میوکارد) یا نشانه‌های حمله قلبی قلبی، بزرگ شدن یا ضخیم شدن عضله قلب و انسداد در جریان خون قلب را می‌تواند نشان دهد.^{۱-۶} همچنین، از این دستگاه برای ارزیابی میزان خطرناکی یک دارو، بررسی اثرات دارو بر قلب و پیش‌بینی خطر آریتمی که می‌تواند تهدید کننده جان فرد باشد، استفاده می‌شود.^۱ از جمله اولین مواردی که ECG در آن تأثیر مثبتی داشته است، توانایی آن در شناسایی آسیب حاد میوکارد بوده است.^۷ امروزه اهمیت این تصاویر بسیار بیشتر از پیش نمایان شده است به‌طوری که حدود ۵/۲ میلیون نفر در ایالات متحده از فیبریلاسیون دهلیزی که شایع‌ترین آریتمی قلبی پایدار است و بزرگسالان با آن مواجه می‌شود، رنج می‌برند.^۸

با وجود پیشرفت‌هایی که در سال‌های اخیر در روش‌های تصویربرداری صورت گرفته است، ECG هنوز هم یکی از سریع‌ترین و غیرتهاجمی‌ترین ابزارها در کمک به تشخیص پراکندگی‌های محیطی و تامپوناد قلبی است. شایان توجه است که حساسیت الکتروکاردیوگرام، در تشخیص تامپوناد قلبی بسیار کم است. بنابراین، به تنهایی برای رد تامپون قلبی قابل استناد نمی‌باشد.^۹ بیش از ۵۰ سال از به‌کارگیری تجزیه و تحلیل رایانه‌ای به منظور استخراج و تحلیل تصاویر ECG می‌گذرد.^{۱۰} هرچند که پیشرفت فناوری و به طبع آن تغییر روش‌های الگوریتم‌های رایانه‌ای به منظور تجزیه و تحلیل تصاویر مرتب بهبود می‌یابد اما در چند دهه گذشته، دقت محدودتری نسبت به انسان‌ها داشتند. در سال ۱۹۹۱، ارزیابی سیستمیک از تفسیر ECG مبتنی بر رایانه نشان داد که دقت برنامه رایانه ۶/۶٪ پایین‌تر از متخصصان قلب و عروق است.^{۱۱} همچنین، باید خاطرنشان کرد که تنوع در روش‌های رایانه‌ای به منظور تحلیل تصاویر ECG بیشتر از روش‌های معمول انسانی است.^{۱۱} امروزه تجزیه و تحلیل ECG رایانه‌ای بسیار گسترده شده است و به این که سواد ECG در بین پزشکان در حال کاهش است، متکی است. با پیشرفت‌های فناوری اخیر، استفاده از الگوریتم‌های هوش مصنوعی (ECG (AI-ECG) پتانسیل ایجاد طبقه‌بندی، تشخیص و حتی تفسیر ECG را نشان داده است. همه این موارد می‌تواند تأثیر چشمگیری در مراقبت از بیمار و گردش کار بالینی داشته باشد.^{۱۱} مطالعه‌های جدیدتر، پیشرفت قابل توجه

گرفتن در شبکه‌یکانولوشنی یک‌بعدی به داده‌های ترتیبی نیاز دارند تا به قالب (نمونه، زمان، ویژگی) درآیند. با توجه به اینکه ویژگی داده‌ها در این مجموعه داده، یک بعدی است بنابراین بعد سوم یک می‌باشد. اینکار سبب می‌شود تا به‌عنوان مثال مدل بتواند از توالی داده، شناسایی الگوی تکرار شونده در سیگنال الکتروکاردیوگرام استفاده کند.

شبکه CNN استفاده شده در این پژوهش، به کمک لایه‌های کانولوشنی یک‌بعدی می‌تواند ویژگی‌های محلی از سیگنال ECG را استخراج نماید. سپس، با بکارگیری از لایه‌های MaxPooling1D، اندازه داده کاهش می‌یابد و اطلاعات مهم‌تر حفظ می‌شوند. این ویژگی‌ها به لایه Dense منتقل می‌شوند که با تابع فعال‌سازی Softmax عملیات طبقه‌بندی نهایی را انجام می‌دهد. این مدل از دقت بالایی برخوردار است و در پژوهش‌های متعدد، دقتی بیش از ۹۸٪ گزارش شده است.^{۱۷،۱۸}

اگر k کلاس داشته باشیم و بردار خروجی مدل ما به صورت $z=[z_1, z_2, z_3, \dots, z_k]$ باشد، فرمول ریاضی تابع Softmax برای هر مولفه به صورت زیر تعریف می‌گردد:

(۱)

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_j^k e^{z_j}}$$

که در آن z_i امتیاز خام کلاس i و e^{z_i} نمای logit می‌باشد.^{۱۹} تابع ریاضی $\text{softmax}(z_i)$ برای هر مولفه، مقداری بین صفر تا یک دارد و $\sum_j^k \text{softmax}(z_j)=1$ می‌باشد.^{۱۹}

در مرحله بعدی، مدل آموزش می‌بیند و با استفاده از بهینه‌ساز Adam و تابع هزینه برای طبقه‌بندی کامپایل می‌شود. Adam با استفاده از تخمین‌های مرتبه اول و دوم شیب پارامترها، نرخ یادگیری را به صورت تطبیقی تغییر می‌دهد. به این ترتیب مومنت مرتبه اول از رابطه زیر محاسبه می‌شود:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2)$$


که در معادله فوق، g_t گرادیان در گام t ، β_1 ضریب کاهش و m_t مومنتوم مرتبه اول می‌باشند. همچنین، برای محاسبه مومنتوم مرتبه دوم از رابطه زیر استفاده می‌شود:

از فعالیت‌های قلبی می‌باشد دریافت شده است و در خروجی چاپ می‌شوند. پس از آن داده‌ها که شامل دو فایل CSV برای ضربان قلب نرمال و غیرنرمال است، بارگزاری شده‌اند و آماده پیش‌پردازش می‌شوند. پیش‌پردازش داده، راه را برای یادگیری بهتر ماشین آماده می‌کند. این فرایند می‌تواند شامل چند مرحله مانند از بین بردن نویز و نرمالیزاسیون باشد.^{۱۲}

برای اینکار از چندین لایه استفاده شده است. لایه نخستین یک کانولوشن یک بعدی با ۳۲ فیلتر و اندازه کرنل سه می‌باشد که وظیفه استخراج ویژگی‌های محلی از سیگنال‌های قلبی را بر عهده دارد. سپس به منظور جلوگیری از بیش‌برازش و ساده‌سازی محاسبات ابعاد سیستم کاهش یافته است. پس از آن از یک لایه کانولوشن دیگر با فیلتر ۶۴ به منظور استخراج ویژگی‌های پیچیده‌تر استفاده شده است و مانند حالت پیش ابعاد سیستم را دوباره کاهش داده شده است. سپس داده‌ها برای ورود به لایه تمام متصل با ۱۲۸ نورون که وظیفه یادگیری ویژگی‌های غیر خطی را دارد به بردار تبدیل می‌شوند. توسط Dropout 50 درصد از نورون‌ها در زمان آموزش حذف می‌شوند. اینکار برای جلوگیری از بیش‌برازش صورت می‌گیرد. سپس توسط یک لایه با دو نورون برای دو کلاس، احتمال هر کلاس نشان داده می‌شود.

در واقع می‌توان روش کار مدل را این‌طور توضیح داد که در پیش‌پردازش، داده‌ها با استفاده از Standard Scaler استاندارد می‌شوند تا میانگین آنها صفر و انحراف معیارشان یک شود. اینکار به منظور یادگیری بهتر صورت می‌گیرد. پس از این قسمت، داده‌ها به دو قسمت آموزش و اعتبارسنجی تقسیم می‌شوند. علت این امر در این است که اگر تمام داده‌ها برای آموزش استفاده شوند، نمی‌توان از صحت شبکه عصبی در درستی تشخیص، اطمینان حاصل کرد. بدین دلیل که ماشین این قابلیت را دارد که ویژگی داده‌هایی که آموزش دیده‌اند را حفظ کند.

به بیان دیگر اگر همه داده‌ها فقط برای آموزش استفاده شوند، نمی‌توان عملکرد آن‌ها را در داده‌های دیده نشده بررسی کرد. در این شبکه، از ۸۰٪ از داده‌ها برای آموزش و از ۲۰٪ برای تست با گام تصادفی ۴۷ استفاده شده است که تضمین می‌کند این نسبت در اجراهای مختلف یکسان باشد. این کار همچنین به مقایسه نتایج در اجراهای مختلف کمک می‌کند. در قدم بعدی، داده‌ها به منظور قرار



شکل ۱: نمودار دقت بر حسب اپاک

شکل ۲ نمودار تابع خطا (هزینه) بر حسب اپاک را نشان می‌دهد. در هر دو مجموعه، یادگیری و اعتبارسنجی با افزایش یادگیری مقدار خطا کاهش می‌یابد. همچنین، مقدار خطا در هر دو مجموعه با هم اختلاف کمی دارد که این موضوع نشان دهنده عدم بیش برازش مدل است. در مدل‌هایی که بیش برازش رخ می‌دهد، داده در مجموعه یادگیری عملکرد مناسبی دارد ولی در هنگام اعتبارسنجی، مقدار خطا افزایش و دقت کاهش می‌یابد. مقدار اولیه خطا برای داده‌های آموزشی بیش از ۰/۳ است و به تدریج با پیشرفت اپاکها تا حدود ۰/۰۳۵ کاهش یافته است، که نشان‌دهنده بهبود پیوسته عملکرد مدل در تخمین درست برچسب‌ها است. مقدار خطا مربوط به مجموعه اعتبارسنجی نیز روند نزولی دارد، اما با نوسانات بیشتری همراه است، به ویژه در اپاک‌های میانی و پایانی. این نوسانات معمولاً ناشی از پیچیدگی داده‌های اعتبارسنجی یا احتمال کمی بیش‌برازش در مراحل پایانی آموزش است.

استفاده از نمودار چگالی بجای نمودار ستونی، امکان مشاهده دقیق‌تری از پراکندگی داده‌ها را فراهم می‌سازد. شکل ۳ نمودار توزیع آماری شامل دو کلاس طبیعی و غیرطبیعی است. این نمودار نشان دهنده نقش ویژگی در تفکیک بین دو کلاس است. به این معنی که آیا ویژگی مورد نظر در تفکیک ویژگی، نقش معنا داری را ایفا می‌کند یا خیر. رنگ آبی در نمودار برای کلاس نرمال و رنگ قرمز برای کلاس غیرطبیعی استفاده می‌شود. همانطور که در شکل ۳ مشخص است، این دو کلاس دارای الگوی توزیع متفاوتی هستند و

(۳)

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

که β_2 ضریب کاهش و v_t مومنتوم مرتبه دوم هستند. پس از محاسبه مومنتوم مرتبه دوم، تصحیح اریب محاسبه می‌شود.

(۴)

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

(۵)

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

$\hat{m}_t$ و $\hat{v}_t$ مقدارهای تصحیحی برای مرتبه اول و دوم مومنتوم

هستند. در آخر پارامترها به روزرسانی می‌شوند.

(۶)

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t$$

در معادله بالا، θ_t پارامتر مدل در گام t ، η نرخ یادگیری و ϵ مقداری بسیار کوچک به منظور جلوگیری از صفر شدن منخرج است. سپس، مدل طی ۲۰ دوره و با اندازه دسته ۳۲ آموزش می‌بیند. در هر دوره، عملکرد مدل بر روی داده‌های اعتبارسنجی نیز ارزیابی می‌شود تا از بروز بیش‌برازش جلوگیری شود.

یافته‌ها


شکل ۱ تغییرات دقت بر حسب اپاک را نشان می‌دهد. همان‌طور که در شکل ۱ نشان داده شده است، دقت در مدل برای مجموعه یادگیری از حدود ۸۵٪ آغاز و پس از ۲۰ اپاک به نزدیکی ۱۰۰٪ می‌رسد و برای مجموعه اعتبارسنجی، این عدد از ۹۱٪ آغاز و به ۹۹٪ می‌رسد.

روند یادگیری در هر دو مجموعه مثبت است که این امر نشان از عملکرد درست مدل دارد. دقت در هر دو مجموعه در ابتدا با شیب تندی شروع می‌شود و پس از حدود هشت اپاک، نوسانات تقریباً کوچک می‌شوند و دقت به مقدار نسبتاً پایداری می‌رسد که این رفتار حاکی از عملکرد درست مدل می‌باشد. به عبارت دیگر، این رفتار نشان‌دهنده توانایی خوب مدل در تعمیم‌پذیری روی داده‌هایی است که قبلاً مشاهده نکرده است. همچنین، با توجه به این که فاصله بین دقت در مجموعه آموزش و اعتبارسنجی کم است، می‌توان گفت که بیش‌برازش شدیدی در مدل اتفاق نیفتاده است.

$$\sigma = \sqrt{\sum_{i=1}^N \frac{(x_i - \mu)^2}{N}} \quad (7)$$

که در آن σ انحراف معیار جامعه، N تعداد داده‌ها در جامعه، x_i مقدار هر داده و μ میانگین جامعه می‌باشد.^{۲۲}


شکل ۴ تغییرات انحراف معیار برای کلاس‌های نرمال و غیرنرمال را نشان می‌دهد. در این شکل، رنگ آبی و نارنجی به ترتیب متعلق به کلاس‌های نرمال و غیرنرمال هستند. از آنجایی که داده‌های ECG در این پروژه به صورت بردارهایی با حدود ۱۹۰ ویژگی هستند، بنابراین نمودار انحراف معیار برای هر ویژگی نشان داده شده است. عدد صفر در نمودار نشان دهنده اول ویژگی است. اگر مقدار انحراف معیار زیاد باشد یعنی فاصله ویژگی‌ها از هم زیاد و اگر کم باشد ویژگی‌ها به هم نزدیکند. شکل ۴ نشان می‌دهد که برخی داده‌ها در کلاس نرمال تغییرات کمتری دارند درحالی که همان ویژگی‌ها در کلاس غیرنرمال انحراف معیار بیشتری دارند و بالعکس که این امر سبب تشخیص بهتر کلاس در مدل یادگیری می‌شود. به‌طورکلی، ویژگی‌هایی که تفاوت بیشتری دارند، در تشخیص تمایز دو کلاس موثرتر عمل می‌کنند.



شکل ۴: نمودار انحراف معیار برای کلاس‌های نرمال و غیرنرمال

شکل ۵ ماتریس درهم‌ریختگی برای کلاس‌های نرمال و غیرنرمال را نشان می‌دهد. در این مدل مقدار منفی یعنی تعداد نمونه‌هایی که ضربان طبیعی داشتند و مدل درست تشخیص داده‌اند،

چگالی‌های این دو کلاس در بازه‌های متفاوتی از محور افقی توزیع شده‌اند. با توجه به این موضوع، می‌توان اینطور استنباط کرد که ویژگی شماره ۱۰ می‌تواند به‌عنوان یک شاخص کلیدی در طبقه‌بندی مؤثر باشد. در این مدل، همپوشانی دو کلاس کم است و هر چه همپوشانی کمتر باشد، مدل یادگیری عملکرد بهتری از خود نشان می‌دهد.




شکل ۲: نمودار خطا (زیان) بر حسب ایپاک.



شکل ۳: نمودار چگالی ویژگی شماره ۱۰


یکی از پارامترهایی که در سنجش مدل می‌توان از آن استفاده کرد انحراف معیار است که پراکندگی یا تغییرپذیری داده‌ها را حول میانگین نشان می‌دهد. انحراف معیار به صورت زیر محاسبه می‌شود:

است. هرچه عدد به یک نزدیک تر باشد دقت مدل بیشتر است. مساحت زیر نمودار خطچین آبی برابر ۰/۵ است که این عدد بیانگر پاسخدهی اتفاقی مدل می‌باشد. اگر این عدد از ۰/۵ کمتر باشد یعنی مدل حتی از جواب اتفاقی هم بدتر عمل کرده است. هر چه مقدار این عدد به یک نزدیک‌تر باشد دقت مدل بالاتر است که در مدل استفاده شده در این پژوهش این عددی تقریباً برابر یک است.^{۲۵،۲۶}



شکل ۶: نمودار ROC

برابر با ۸۰۴ و نمونه‌هایی که ضربان نرمال داشتند ولی مدل غیرنرمال تشخیص داده‌اند، ۳۰ است. همچنین تعداد مثبت واقعی یعنی نمونه‌هایی که دارای ضربان قلب غیرنرمال بودند، ولی مدل درست تشخیص داده است ۲۰۶۶ مورد بوده است. همچنین ۱۱ مورد منفی کاذب یعنی نمونه‌هایی که شبکه آن‌ها را نرمال تشخیص داده است ولی دارای ضربان غیرنرمال بودند مشاهده شده است.



شکل ۵: نمودار ماتریس درهم‌ریختگی

شکل ۷ بیانگر نمودار واریانس برای دو کلاس طبیعی و غیرطبیعی مدل یادگیری ماشین است. محور افقی شماره ویژگی و محور عمودی واریانس آن را نشان می‌دهد. این کمیت نشان دهنده میزان فاصله داده‌ها از میانگین است.^{۲۶} فرمول واریانس بصورت زیر است.^{۲۷}

$$var(x) = \sum_{i=1}^n \frac{(\mu - x_i)^2}{n} \quad (۸)$$

که در آن x_i مقادیر داده‌ها، μ میانگین و n تعداد داده‌ها می‌باشد.^{۲۷} هرچه که میزان واریانس بیشتر باشد، آن مدل قدرت تفکیک بالاتری خواهد داشت.^{۲۸}

در شکل ۷ نمودار برای دو کلاس طبیعی (خط آبی) و غیر طبیعی (خط نارنجی) رسم شده است. مشخص است که بعضی از

امروزه استفاده از مدل‌های ترکیبی به دلیل عملکرد موفق‌تری که دارند بیش از پیش مورد توجه قرار گرفته است. در مطالعه‌ای از Halder که از مدل ترکیبی CNN-LSTM در تشخیص آریتمی قلبی استفاده کرده است، مدل با دقت ۹۸/۲۴٪ عملکرد موفق‌تری داشته است.^{۲۱} در تحقیقی که توسط Y. Zhang در رابطه با طبقه‌بندی سیگنال‌های ECG به کمک مدل ترکیبی استفاده شد، دقت حدود ۹۸/۵۰٪ گزارش شده بود.^{۲۳}

شکل ۶ نمودار ROC که بیانگر ارزیابی یک مدل طبقه‌بندی به‌کار می‌رود. این نمودار به ویژه در مسائل دودویی مانند این پژوهش کاربرد دارد. محور افقی نشان می‌دهد که چه درصدی از داده‌های منفی Normal به اشتباه مثبت Abnormal پیش‌بینی شدند و محور عمودی بیانگر آن است که چه درصدی از داده‌های مثبت Abnormal به‌درستی شناسایی شدند. مساحت زیر منحنی عددی بین صفر و یک

مدل است. همان‌گونه که در جدول ۱ نشان داده شده است، مقدار خطا برای داده‌های تست، اندکی کمتر از خطای داده‌های واقعی است و دقت در حدود ۰/۵ درصد بیشتر از دقت داده‌های واقعی می‌باشد که با توجه به تفاوت تعداد نمونه‌ها در داده‌های تست و واقعی این تفاوت قابل چشم‌پوشی است. شایان ذکر است که فایل نهایی در سیستم ذخیره شده است تا مناسب استفاده در برنامه‌های پزشکی و فضای ابری بدون آموزش مجدد باشد.

ویژگی‌های این کلاس‌ها دارای واریانس بالاتری هستند بنابراین تفکیک پذیری بالاتری دارند و آن ویژگی‌هایی که دارای واریانس نزدیک به صفر هستند تغییرات زیادی نداشته‌اند.

در این پژوهش، برنامه با دقت ۹۹/۵٪ و با خطای ۰/۰۱۵۳ برای داده‌های تست و دقت ۹۹٪ و با خطای ۰/۰۳۵۰ برای داده‌های واقعی، عملکرد خوبی را از خود نشان داد. همچنین، امتیاز F1 برای هر دو گروه داده ۹۹٪ گزارش شده است که نشان‌دهنده عملکرد مناسب

جدول ۱: مقایسه نتایج برای داده‌های آموزشی و واقعی

نوع داده	F1_score (درصد)	accuracy (درصد)	loss
داده تست	۹۹/۰	۹۹/۵	۰/۰۱۵۳
داده واقعی	۹۹/۰	۹۹/۰	۰/۰۳۵۰

بحث

نتیجه‌گیری، الکتروکاردیوگرام به‌عنوان یک روش سریع، غیرتهاجمی و سریع عمل می‌کنند. امروزه با پیشرفت سریع فناوری، روش‌های نوین پردازش رایانه‌ای در حال جایگزین شدن با روش‌های سنتی هستند. این پژوهش با بکارگیری روش‌های یادگیری عمیق با توسعه مدل CNN و مدل D Conv۱ موفق به تشخیص سیگنال‌های نرمال و غیرنرمال قلب با دقت ۹۹٪ شده است. شایان ذکر است که عواملی نظیر پیش‌پردازش داده‌ها، استانداردسازی و شبکه عصبی مناسب نقش مهمی در افزایش دقت داشتند.

در این پژوهش به علت محدودیت در داده‌ها، از داده‌های پلتفرم کگل استفاده شده است و از این رو نیاز به بررسی گسترده‌تر بالینی برای دریافت نمونه‌های بیشتر است. در آینده با توسعه روش‌های یادگیری ماشین و یادگیری عمیق و همچنین داده‌های بالینی بیشتر، توسعه و دقت شبکه‌های عصبی رایانه‌ای بیش از پیش افزایش می‌یابد.

سپاسگزاری: این مقاله حاضر برگرفته از از طرح تحقیقاتی تحت عنوان "Heartbeat categorization dataset" در مقطع دکتری در سال ۱۳۹۶ در دانشگاه MIT اجرا شده است.

نتایج به‌دست آمده در این تحقیق تقریباً با مقالات جدید که در این زمینه صورت گرفته‌اند، برابری می‌کند. به‌عنوان مثال، در تحقیقی که توسط Bai و همکاران در سال ۲۰۲۴ با استفاده از معماری CNN-BiGRU صورت گرفت به دقت ۹۹/۴٪ و امتیاز F1 992/0 دست یافته‌اند.^{۲۹} همچنین Pandey و همکاران با استفاده از CNN-BiLSTM و ماژول M2MASC به نتایج مشابهی دست یافته‌اند.^{۳۰} این موضوع می‌دهد که حتی با یک معماری نسبتاً سبک‌تر، می‌توان به دقت و F1 بسیار بالا دست یافت، به شرط آنکه پیش‌پردازش داده‌ها و آموزش مدل به‌درستی انجام شود. از نظر کاربردی این مدل، از بسیاری از مدل‌های ارائه شده مانند BLF-Net یا Residual-BiLSTM با توجه سطح ضربان سبک‌تر بوده و به راحتی می‌تواند در برنامه‌های پزشکی مورد استفاده قرار گیرد.^{۳۱، ۳۲} هرچند از این نکته نباید غافل شد که هنوز فرصت‌ها و محدودیت‌هایی وجود دارد که از جمله آنها می‌توان به بررسی مدل روی دیتاست‌های خارجی، شرایط ضبط متفاوت و تحلیل اثر نویز اشاره کرد.

References

1. N. Rafie, A. H. Kashou, and P. A. Noseworthy, ECG interpretation: Clinical relevance, challenges, and advances, *Hearts*, 2021; 2(4), 505–513.
2. D. Cuevas-González, J. P. García-Vázquez, and M. L. González-Ramírez, ECG Standards and Formats for Interoperability between mHealth and Healthcare Information Systems: A Scoping Review, *Sensors*, 2022; 22(19), 7220.
3. A. H. Ribeiro et al., Automatic diagnosis of the 12-lead ECG using a deep neural network, *arXiv preprint arXiv:1904.01949*, 2019.
4. S. Raghunath et al., Deep neural networks can predict mortality from 12-lead electrocardiogram voltage data, *arXiv preprint arXiv:1904.07032*, 2019.
5. ISO/IEEE 11073-10406:2012, Health informatics Personal health device communication Part 10406: Device specialization Basic electrocardiograph (ECG), *International Organization for Standardization*. 2012.
6. P. W. Macfarlane et al., Recommendations for the Standardization and Interpretation of the Electrocardiogram, *Circulation*. 2007; 115(10), 1306–1324.
7. B. Lüderitz and A. B. de Luna, The history of electrocardiography. *Journal of Electrocardiology*. 2017; 50, 539.
8. D. M. German, M. M. Kabir, T. A. Dewland, C. A. Henrikson, and L. G. Tereshchenko, Atrial fibrillation predictors: Importance of the electrocardiogram, *Ann. Noninvasive Electrocardiol.* 2016; 21(1), 20–29.
9. K. P. Ang, R. B. Nordin, S. C. Y. Lee, C. Y. Lee, and H. T. Lu, Diagnostic value of electrocardiogram in cardiac tamponade. *Medical Journal of Malaysia*. 2019; 74(1), 51-56.
10. A. H. Kashou, W.-Y. Ko, Z. I. Attia, M. S. Cohen, P. A. Friedman, and P. A. Noseworthy, A comprehensive artificial intelligence-enabled electrocardiogram interpretation program. *Cardiovascular Digital Health Journal*. 2020; 1(2), 62-70.
11. J. Schläpfer and H. J. Wellens, Computer-interpreted electrocardiograms: Benefits and limitations. *Journal of the American College of Cardiology*. 2017; 70(10), 1183-1192.
12. R. Singh, A. Gupta, P. Saini, S. Jaiswal, A. K. Saini, and S. Kumar, Pre-Processing techniques and artificial intelligence algorithms for ECG signal analysis. *Computer Methods and Programs in Biomedicine*. 2023; 233, 107483.
13. M. Rezaei, F. Rezaei, and P. Karimi, Different hybrid prediction's machine learning algorithms for quantitative analysis in laser-induced breakdown spectroscopy. *Journal of Applied Spectroscopy*. 2023; 90(3), 489-501.
14. M. N. Bui, R. R. Gutierrez, A. Balakrishnan, S. S. Hossain, and R. Lakshmanan, Deep Learning-Driven Single-Lead ECG Classification: A Rapid Approach for Comprehensive Cardiac Diagnostics. *Diagnostics*. 2025; 15(3), 384.
15. M. Tanveer, H. Ullah, A. Rehman, F. Al-Turjman, and M. M. Kamal, Deep learning-assisted arrhythmia classification using 2-D ECG spectrograms. *EURASIP Journal on Advances in Signal Processing*. 2024; 2024(1), 10.
16. S. Fazeli, M. Kachuee, and M. Sarrafzadeh, *ECG Heartbeat Categorization Dataset*. 2018.
17. M. Tanveer, H. Ullah, A. Rehman, F. Al-Turjman, and M. M. Kamal, Deep learning-assisted arrhythmia classification using 2-D ECG spectrograms. *EURASIP Journal on Advances in Signal Processing*. 2024; 2024(1), 10.
18. R. Singh et al., Pre-Processing techniques and artificial intelligence algorithms for ECG signal analysis. *Computer Methods and Programs in Biomedicine*. 2023; 233, 107483.
19. I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, Cambridge, MA, USA: MIT Press. 2016.
20. D. P. Kingma and J. Ba, Adam: A Method for Stochastic Optimization, *Proc. 3rd International Conference on Learning Representations (ICLR)*. 2015.
21. A. Halder, A. Sengupta, and P. Mitra, Deep Learning for ECG Classification: A Comparative Study of 1D and 2D CNNs. *Biomedical Signal Processing and Control*. 2024; 92, 105316.
22. D. G. Altman and J. M. Bland, Standard Deviation and Standard Error: Which One to Use?, *BMJ*, 2005; 331(7521), 903.
23. Y. Zhang et al., An Arrhythmia Classification Model Based on a CNN-LSTM-SE Network. *Sensors*. 2024; 24(19), 6306.
24. Y. Chen, C. Gao, C. Zhang, and S. Liu, Optimizing Two-way Partial AUC with an End-to-end Framework. *arXiv*. 2022; arXiv:2206.11655.
25. J. Li, Area under the ROC Curve has the most consistent evaluation for binary classification. *PLoS ONE*, 2024; Vol. 19, No. 8, Art. e0316019, Public Library of Science (PLOS), San Francisco, CA, USA.
26. A. M. Mood, F. A. Graybill, and D. C. Boes, *Introduction to the Theory of Statistics*. McGraw-Hill, 1974; 3rd ed., New York, NY, USA.
27. G. Casella and R. L. Berger, *Statistical Inference*. Duxbury. 2002; 2nd ed., Pacific Grove, CA, USA.
28. I. Guyon and A. Elisseeff, An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*. 2003; 3, 1157–1182.
29. Bai, X., et al. A hybrid deep learning network for automatic diagnosis of ECG (CNN-BiGRU + Attention). *Scientific Reports*, 2024.
30. Pandey, A., et al. Enhancing heart disease classification with CNN-BiLSTM and M2MASC integration. *Scientific Reports*, 2024.
31. Alkhawaldeh, F., et al. DeepResidualBiLSTM: Residual CNN + BiLSTM for arrhythmia classification. *Springer*, 2023.
32. Jing, L., et al. Beat-level Fusion Net (BLF-Net) for ECG classification. *PubMed*, 2023.

Analysis of human electrocardiogram (ECG) signals using machine learning techniques

Hossein Akhavan M.D.
Fatemeh Rezaei Ph.D.*

Department of Biophotonic, Physics
Faculty, K. N. Toosi University of
Technology, Tehran, Iran.

Abstract

Received: 05 Apr. 2025 Revised: 11 Apr. 2025 Accepted: 14 May. 2025 Available online: 22 May. 2025

Background: An Electrocardiogram is a non-invasive method for receiving heart signals. Despite advances in imaging methods, the electrocardiogram still plays an important role remains a vital tool in the diagnosis of heart diseases. Analysis of electrocardiogram signals plays an important role in the early detection of heart diseases such as arrhythmias and heart attacks. Today, with the advancement of science and technology, computer methods have received more and more attention from doctors. In this study, machine learning methods were used to classify normal and abnormal heartbeats.

Methods: The data under study were extracted from a dataset called Heartbeat published on the Kaggle website. This dataset includes samples of audio ECG signals that are divided into healthy and unhealthy categories. First, the data were preprocessed and normalized to prepare them for input into the model. Then, temporal and frequency features were extracted from the signals. Next, a hybrid model consisting of one-dimensional convolutional layers was designed and trained. Also, by using the early stopping method, overfitting was prevented and the stability of the model was improved.

Results: In this study, it was shown that by using deep learning, especially using CNN and 1D Conv, an accuracy of 0.99% and a loss of 0.0350 for test data in detecting normal and abnormal heartbeats can be achieved. This model has the ability to analyze complex structures and temporal dynamics of ECG signals and is able to detect patterns related to cardiac disorders.

Conclusion: Today, the electrocardiogram has received more attention than ever before. Appropriate selection of the model, data standardization, and a qualitative range of data are among the factors of high accuracy in this study. This study can be an effective step in the development of intelligent systems for diagnosing cardiac disorders and can be used in medical applications, especially in the field of continuous patient monitoring.

Keywords: arrhythmia, deep learning, ECG signal, electrocardiogram, machine learning.

*Corresponding author: Department of Biophotonic, Physics Faculty, K. N. Toosi University of Technology, Tehran, Iran.
Tel: +98-21-23064454
E-mail: fatemehrezaei@kntu.ac.ir