



Computational Intelligence in Electrical Engineering
Vol. 15, No. 2, 2024
pp. 97-114
Research Paper

Deep Features Representation of Wearable Sensors to Cardiovascular Events Prediction of Blood Vessels

Sina Dami ^{*1}, Mahtab Yahaghizadeh ²

¹ Assistant Professor, Dept. of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

² M.A., Dept. of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

Abstract:

One of the leading causes of death in today's world is arterial events, which can occur in the form of myocardial infarction, stroke, fainting, etc., leading to heart failure and premature death. Hence, it is essential to inform people before the occurrence of unpleasant events to prevent and warn of abnormal conditions. In this paper, we used a deep learning approach to predict arterial events during the weeks/months before the event using 5 minutes of ECG signals recording by extracting the temporal and frequency characteristics. For this purpose, the long short-term memory (LSTM) neural network was used due to the possibility of learning long-term dependencies to quickly identify and prevent these types of events. A deep belief network (DBN) was also used to represent and select more effective and efficient features of the recorded dataset. This approach is briefly called LSTM-DBN. Four publicly-available datasets in the field of health care were used to evaluate the proposed approach. These data were collected from ECG signal recording wearable sensors along with demographic characteristics. The prediction results of the LSTM-DBN network with 88.42% mean accuracy compared to other deep learning approaches and traditional classifications indicate the superiority of the proposed approach.

Keywords: Cardiovascular Events Prediction, Wearable Sensors, Feature Representation, Deep Learning, LSTM, DBN, ECG Signal Recording.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/ISEE.2023.120151.1303>

بازنمایی عمیق ویژگی‌ها در حسگرهای پوشیدنی برای پیش‌بینی رویدادهای مرتبط با

رگ‌های خونی قلب و عروق

سینا دامی^{۱*}، مهتاب یاحقی‌زاده^۲

۱- استادیار، گروه مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

dami@wtiau.ac.ir

۲- کارشناسی ارشد، گروه مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

mahtab.yahaghizadeh@gmail.com

چکیده: امروزه یکی از عوامل مرگ‌ومیر در دنیا وقوع رویدادهای شریانی است که به شکل آنفارکتوس قلبی، سکنه مغزی، غش و غیره رخ می‌دهند و باعث از کارافتادگی قلب و مرگ زودرس می‌شوند؛ بنابراین، ضروری است قبل از وقوع حوادث ناگوار برای پیشگیری و هشدار شرایط غیرعادی به افراد اطلاع‌رسانی شود. در این مقاله، از یک رویکرد یادگیری عمیق برای پیش‌بینی رویدادهای شریانی طی چند هفته / ماه قبل از رویداد با ۵ دقیقه ثبت سیگنال‌های قلبی (ECG) و استخراج ویژگی‌های زمانی و فرکانسی استفاده شده است. برای این منظور، از شبکه عصبی LSTM به دلیل امکان یادگیری وابستگی‌های بلندمدت برای شناسایی و پیشگیری هرچه سریع‌تر این نوع رویدادها بهره گرفته شد. همچنین، از یک شبکه باور عمیق (DBN) برای بازنمایی و استخراج ویژگی‌های بهینه و مؤثر از مجموعه داده‌های جمع‌آوری شده استفاده شد. این رویکرد به اختصار LSTM-DBN نامیده می‌شود. برای ارزیابی رویکرد پیشنهادی از ۴ مجموعه داده در دسترس عموم در حوزه مراقبت‌های بهداشتی استفاده شد. این داده‌ها از حسگرهای پوشیدنی مربوط به ثبت سیگنال‌های ECG همراه با ویژگی‌های جمعیت‌شناختی جمع‌آوری شده‌اند. نتایج حاصل از پیش‌بینی شبکه LSTM-DBN با میانگین صحت ۸۸/۴۲ درصد در مقایسه با سایر رویکردهای یادگیری عمیق و طبقه‌بندی سنتی نشان‌دهنده برتری رویکرد پیشنهادی‌اند.

واژه‌های کلیدی: پیش‌بینی رویدادهای قلبی، حسگرهای پوشیدنی، بازنمایی ویژگی‌ها، یادگیری عمیق، LSTM، DBN.

ثبت سیگنال‌های ECG.

۱- مقدمه

و غیره اشاره می‌کند که بر سیستم قلبی عروقی تأثیر می‌گذارد. بر طبق انجمن قلب آمریکا، ۱۷ میلیون نفر به علت بیماری قلبی سالانه فوت می‌کنند و این رقم تا سال ۲۰۳۰ به ۲۳/۶ میلیون نفر افزایش می‌یابد [۱].

یادگیری عمیق به یک رویکرد محبوب و فراگیر از یادگیری ماشین تبدیل شده است که پیشرفت‌های چشمگیری را در حوزه‌های یادگیری ماشین سنتی به دست آورده است [۲]. دستگاه‌های اینترنت اشیا و حسگرهای تعبیه‌شده در پوشش، بدن یا در محیط تعاملی با انسان‌ها برای نظارت و کنترل شرایط بیماران در معرض حملات قلبی عروقی، در حال تولید حجم داده‌های فراوانی در هر

بیماری‌های قلبی عروقی یکی از مهم‌ترین عوامل مرگ‌ومیر در سراسر جهان‌اند. بیماری‌های قلبی عروقی به هر نوع بیماری از قبیل آنفارکتوس قلبی، سکنه مغزی، غش

^۱ تاریخ ارسال مقاله: ۱۳۹۸/۰۹/۰۳

تاریخ پذیرش مقاله: ۱۴۰۰/۰۴/۰۶

نام نویسنده مسئول: سینا دامی

نشانی نویسنده مسئول: ایران - تهران - دانشگاه آزاد اسلامی واحد تهران غرب - دانشکده فنی و مهندسی

لحظه‌اند که این داده‌ها برای پیش‌بینی و کنترل وضعیت بیمار باید تحلیل شوند.

فناوری اینترنت اشیا یک رویکرد صحیح و ساخت‌یافته را برای رسیدگی به جنبه‌های تحویل خدمات مراقبت‌های بهداشتی از لحاظ سلامت موبایل و نظارت بیمار از راه دور ارائه می‌دهد. در این مقاله از حسگرهای پوشیدنی نظارت بر ضربان قلب برای اندازه‌گیری تغییرات ضربان قلب استفاده شده است.

به‌تازگی یکی از رویکردهایی که برای پیش‌بینی و تشخیص بیماری‌های قلبی پیشنهاد می‌شود، استفاده از الکتروکاردیوگرام‌ها^۱ (ECG) است که با نظارت و اندازه‌گیری سیگنال‌های ECG، به صحت و پیش‌بینی دقیق‌تری می‌توان دست یافت.

چندین الگوریتم برای شناسایی خودکار انواع بیماری‌های قلبی براساس مورفولوژی‌های ECG توسعه داده شده‌اند. برخی از سیستم‌ها که برای شناسایی بیماری‌های قلبی از سیگنال‌های ECG استفاده می‌کنند، داده‌ها را به‌طور برون‌خط ذخیره و پردازش می‌کنند و برخی سیستم‌های دیگر، فناوری پردازش از راه دور را پیشنهاد می‌دهند [۱]. در این مقاله ما از ترکیب شبکه عصبی با حافظه کوتاه‌مدت ماندگار^۲ (LSTM) و شبکه باور عمیق^۳ (DBN) به‌عنوان روش بازنمایی ویژگی‌ها برای پیش‌بینی رویدادهای قلبی استفاده کردیم. از شبکه عصبی LSTM برای هشدار شرایط در زمانی استفاده می‌شود که شخص در معرض خطر قرار می‌گیرد. مدل شبکه عصبی LSTM برای پیش‌بینی موضوعاتی مناسب است که وابسته به زمان و گذشته دور هستند؛ برای مثال، کارایی بسیار چشمگیری برای بیمارانی دارد که ممکن است به اطلاعات ذخیره‌شده خود در چند هفته گذشته یا اطلاعات دورتر نیاز داشته باشند.

در این مطالعه از رویکرد یادگیری عمیق برای پیش‌بینی بیماری‌های قلبی عروقی استفاده می‌شود که از طریق حسگرهای پوشیدنی بر سیگنال‌های ECG نظارت دارند و داده‌های به‌دست‌آمده از این سیگنال‌ها، برای تحلیل،

اندازه‌گیری و بررسی می‌شوند. در مدل پیشنهادی ما، بیمار از سه حسگر نظارت و کنترل بر سیگنال‌های ECG شامل حسگر تنفسی، حسگر نوری و حسگر کنترل ضربان قلب استفاده می‌کند که از طریق اینترنت و فناوری Wifi به یک مرکز پردازش داده متصل‌اند. داده‌های به‌دست‌آمده از سیگنال‌های ECG به مرکز پردازش داده ارسال می‌شوند و همراه با پرونده‌های الکترونیکی پزشکی^۴ (EHR) موجود بیمارانی که می‌توانند پایه‌های پیش‌بینی بیمارانی در دوره‌های اخیر یا پیش‌تر باشند، برای شناسایی و تجزیه و تحلیل بیماری‌های قلبی بررسی می‌شوند. الگوریتم شبکه عصبی LSTM برای طبقه‌بندی، تجزیه و تحلیل و پیش‌بینی بیماری‌های قلبی به‌همراه تکنیک بازنمایی ویژگی شبکه باور عمیق برای کاهش ابعاد داده‌ها و استخراج ویژگی‌های مؤثر روی این داده‌ها اجرا می‌شوند و به محض پیش‌بینی بیماری یا رویداد قلبی، هشدار تولید می‌کند و موقعیت بیمار را به تمامی ذی‌نفعان ارسال می‌کند. DBN شبکه را به‌طور مناسب مقداردهی اولیه می‌کند و تا حدودی از افتادن در کمینه محلی ضعیف جلوگیری می‌کند و همچنین، چون در DBN فرایند آموزش بدون سرپرست است، ضرورت وجود داده برچسب‌گذاری شده برای آموزش از بین می‌رود.

از مجموعه داده‌های تولیدشده توسط حسگرهای پوشیدنی نظارت بر ضربان قلب برای ارتباط با بیمار درباره وضعیت عمومی قلب او برای پیش‌بینی سالم یا بیمار بودن افراد استفاده می‌شود که این موضوع می‌تواند با انجام اقدامات مناسب و به‌موقع از وقوع رویدادهای خطرناک قلبی عروقی جلوگیری کند. ما از ویژگی‌های تغییرپذیری ضربان قلب^۵ (HRV) مستخرج از ۵ دقیقه انتخابی از ۲۴ ساعت مجموعه داده‌های الکتروکاردیوگرافی بالینی از بیمارانی قلبی استفاده کردیم. در این مقاله ویژگی‌های سیگنال قلبی در دو فضای زمانی و فرکانسی، استخراج و هر دو نوع ویژگی استخراج‌شده به شبکه داده می‌شوند و نتایج صحت تشخیص با یکدیگر مقایسه می‌شوند.

دلیل مطلوبیت و کارایی بهتر رویکرد پیشنهادی (LSTM-DBN) ممکن است به دلیل توانایی LSTM برای

فرکانس زمانی^{۱۱} (TF) و ویژگی‌های غیرخطی از HRV سیگنال‌های ECG را توسعه داده‌اند. برای نشان دادن ECG نرمال از شخص سالم و شخصی که مبتلا به مرگ ناگهانی قلبی است از شبکه عصبی چندلایه‌ای پرسپترون^{۱۱} (MLP) و طبقه‌بند K نزدیک‌ترین همسایه (k-NN) استفاده شده است. ویژگی‌ها از HRVهای فواصل زمانی یک دقیقه‌ای استخراج شده‌اند (برای مثال، اولین یک دقیقه، دومین یک دقیقه، سومین یک دقیقه و چهارمین یک دقیقه قبل از SCD) و نیز با HRVهای نرمال یک دقیقه‌ای مقایسه شده‌اند. مشکل این رویکرد این است که بین ECG عادی و آن بیمارانی که مستعد SCD هستند، تفاوت چشمگیری با استفاده از بردار ویژگی ترکیبی پیشنهاد شده وجود ندارد و علائم SCD می‌توانند حتی ۴ دقیقه قبل از SCD مشاهده شوند. به عبارت دیگر، صرف‌نظر از متخصصان کاردیوگرافی و الکتروکاردیوگرافی نمی‌توان بین ECG عادی و بیمارانی مبتلا به SCD تشخیصی قائل شد. ویژگی‌های استخراج شده پیشنهادی برای پیش‌بینی SCD می‌توانند استفاده شوند که یادآوری می‌کنند فواصل زمانی که به SCD نزدیک‌ترند قابلیت بیشتری برای پیش‌بینی SCD دارند.

ملیلو و همکارانش^{۱۲} [۶] مدل‌های پیشگویانه جدیدی را برای تهیه یک ابزار طبقه‌بندی خودکار هشدار خطر برای بیمارانی با فشارخون بالا توسعه داده‌اند. آنها از چندین رویکرد داده‌کاوی برای توسعه طبقه‌بندی پیش‌بینی رویداد قلبی براساس ویژگی‌های HRV استفاده کرده‌اند؛ از جمله طبقه‌بندی بیز ساده^{۱۳} (NB)، درخت‌های تصمیم با الگوریتم استنتاجی C4.5، جنگل تصادفی^{۱۴} (RF)، تقویت رویکرد فرایادگیری^{۱۵} نظیر Adaboost، SVM و شبکه‌های عصبی مصنوعی با یک پرسپترون چندلایه (MLP). بهترین مدل پیش‌بینی براساس جنگل تصادفی بوده است. این یافته‌ها تأیید می‌کنند HRV می‌تواند یک پیش‌بینی‌کننده خوب رویدادهای شریانی در آینده در میان بیمارانی با فشار خون بالا باشد.

جیانگ و همکاران^{۱۶} [۷] با استفاده از دستگاهی در بستر

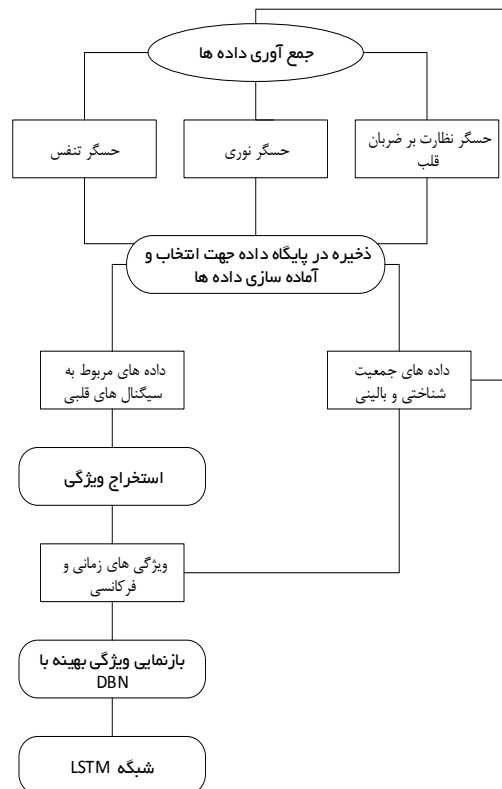
پیش‌بینی موضوعات وابسته به زمان و گذشته دور باشد که در ترکیب با DBN به‌عنوان بازنمایی ویژگی بهینه که مزیت‌های چشمگیری در یادگیری ویژگی‌های داده‌های ورودی دارد، بهترین کارایی را ارائه می‌دهد.

۲- کارهای گذشته

در این بخش، ادبیات مربوط به پیش‌بینی رویدادهای شریانی مطالعه می‌شود که از روش‌ها و رویکردهای مختلفی اعم از یادگیری عمیق و مدل‌های سنتی یادگیری ماشین استفاده شده است. الگوریتم‌هایی برای استخراج ویژگی‌های موج R، از طریق یک طبقه‌بند مبتنی بر آستانه مناسب^۱ از تبدیل موجک برای محاسبه ویژگی‌ها از سیگنال‌های ECG استفاده می‌کنند؛ زیرا تخمین دقت ضربان قلب و تغییرات ضربان قلب می‌تواند از ویژگی موج R استخراج شود [۳]. بلشی^۷ و همکاران [۴] یک رویکرد خاص را برای بیمار به‌منظور پیش‌بینی تشنج با استفاده از خصوصیات الکتروکاردیوگرام (ECG) توسعه داده‌اند. الگوریتم در یک مجموعه داده از ۱۵ بیمار با ۳۸ نوع مختلف از تشنج استفاده کرده است. در این راستا یک طبقه‌بند ماشین بردار پشتیبان (SVM) برای دسته‌بندی مراحل پیش‌تشنج و درون‌تشنج ایجاد شده است. سپس برای بیمارانی که حداقل ۳ تشنج داشتند یک رویکرد اعتبارسنجی دوگانه^۸ استفاده شد که برای پیش‌بینی تشنج‌های مشاهده‌نشده براساس آموزش قبلی خود بود. نتایج بر طبق نوع تشنج کاملاً متغیر بودند و بهترین عملکرد در بیمارانی با تشنج بیشتر استریوتیپیکال به دست آمد. نتایج تجربی نشان دادند این رویکرد در صورت پیش‌روی بیماری خاص قادر به پیش‌بینی تشنج احتمالی است. این رویکرد در مجموعه داده‌ای بسیار محدود ارزیابی شده است.

ابراهیم‌زاده و همکارانش [۵] مطالعه‌ای روی رویکردی برای پیش‌بینی مرگ ناگهانی قلب^۹ (SCD) با استفاده از تجزیه و تحلیل سیگنال‌های ECG و بررسی ویژگی‌های HRV داشته‌اند. آنها با ارائه رویکردهای مناسب برای کمک به پزشکان به‌منظور پیش‌بینی دقیق مرگ ناگهانی قلب،

جمع‌آوری داده‌ها، انتخاب و آماده‌سازی داده‌ها، استخراج ویژگی‌ها، بازنمایی و یادگیری عمیق ویژگی‌ها و پیش‌بینی رویدادها با شبکه LSTM روی مجموعه داده‌های مراقبت بهداشتی تشریح می‌شوند. شکل ۱، جزئیات سیستم پیشنهادی را نشان می‌دهد.



شکل (۱): جزئیات سیستم پیشنهادی

۳-۱-۱- ملزومات سیستم پیشنهادی

این بخش، ملزومات موردنیاز برای اجرای سیستم پیشنهادی در بستر اینترنت اشیا را بررسی می‌کند.

۳-۱-۱- شبکه‌های بی‌سیم بدن

شبکه‌های بی‌سیم بدن^{۱۷} (WBAN)، شبکه‌های حسگر مستقلى برای اتصال به حسگرهای مختلف پزشکی و لوازم خانگی هستند که در داخل و خارج از بدن انسان می‌توانند باشند [۱۱].

بیمارانی که به WBAN مجهز هستند، نیازی نیست منظم به‌صورت فیزیکی به بیمارستان مراجعه کنند که این

اینترنت اشیا، تشخیص سطح استرس یک فرد را از راه دور با استفاده از خواندن ضربان قلب افراد پیشنهاد داده است. این کار از یک حسگر ضربان برای شناسایی تپش‌هایی استفاده کرده است که توسط آن میزان ضربان قلب محاسبه می‌شود. از طریق نقشه‌برداری از استرس و ضربان قلب می‌توان موارد بسیاری را شناسایی کرد؛ برای مثال، آیا فرد عصبی است یا خیر، آیا فرد دلهره دارد یا می‌ترسد، آیا فرد در حال کارکردن است، آیا فرد بیش از حد آموزش دیده است. با وجود این، سنجش‌های سنتی تنها یک قابلیت پیش‌بینی‌کننده جزئی داشتند.

در این مقاله، برای پیشرفت پیش‌بینی رویدادهای شریانی در بیماران مستعد از مدل LSTM-DBN برای پیش‌بینی و استخراج ویژگی‌های بهینه استفاده شده است. دلیل مطلوبیت کارایی بهتر LSTM-DBN نسبت به مقالات مطالعه شده ممکن است توانایی LSTM در حل مشکل وابستگی‌های بلندمدت [۸] باشد. همچنین، شبکه عصبی LSTM در مقایسه با سایر رویکردهای سنتی مانند درخت‌های تصمیم حافظه زیادی مصرف نمی‌کند یا مانند جنگل تصادفی زمان زیادی را به دلیل تولید درختان متعدد از ما نمی‌گیرد و مانند SVM [۹] محدودیتی در سرعت و اندازه در آموزش و آزمون ندارد و علی‌رغم تمامی اینها می‌تواند پیش‌بینی را با استفاده از ویژگی مدیریت وابستگی‌های بلندمدت خود در دوره‌های به‌مراتب دورتر به‌خوبی انجام دهد که با ترکیب با شبکه باور عمیق (DBN) به‌عنوان بازنمایی ویژگی بهینه بهترین کارایی را ارائه می‌دهد؛ زیرا علاوه بر اینکه DBN توانایی خودتطبیقی از خودتنظیمی شبکه عصبی عمومی را دارد [۱۰]، از نقص شبکه پس‌انتشار نیز اجتناب می‌کند که به راحتی به کمینه محلی سقوط می‌کند. همچنین، DBN از یک ساختار شبکه‌ای متشکل از شبکه‌های چنگانه RBM استفاده می‌کند که برای مدل‌سازی داده‌های تک‌بعدی مؤثرتر است.

۳- روش پیشنهادی

در این بخش، جزئیات سیستم پیشنهادی شامل

که برخی از داده‌های تولیدشده ساختار خاصی دارند؛ بنابراین، ضروری است تمام اطلاعات برای تحلیل داده‌ها و اتخاذ یک تصمیم و انجام اقدامات مناسب جمع‌آوری شوند.

۳-۱-۴- جمع‌آوری داده‌ها از حسگر نظارت بر ضربان قلب

این حسگرها در هر یک ساعت سه دقیقه از ضربان قلب هر فرد را با کمک تغییرات ضربان قلب (HRV) ردیابی می‌کنند.

۳-۱-۵- جمع‌آوری داده‌ها از حسگر تنفس

از استخراج اطلاعات در دستگاه Spire که شامل یک ماژول سنجش تنفس است می‌توان سیگنال‌های تنفس را با استفاده از یک مقاومت سنجش - نیرو و یک خازن بین کاربر و رابط اندازه‌گیری کرد. همچنین، در آن یک بخش برای تکمیل سنجش وجود دارد که سیگنال‌هایی مانند ویژگی‌های قلبی و اطلاعات سیستم موقعیت‌یابی جهانی را در زمان نفس کشیدن شخص شناسایی می‌کند [۱۲].

۳-۱-۶- جمع‌آوری داده‌ها از حسگر نوری

حسگر در Being از نورهای LED استفاده می‌کند که از پوست برای شناسایی هر تغییری در حجم خون یک شخص و ضربان قلب برای اعلام وضعیت فرد منعکس می‌شوند [۱۲].

۳-۲- انتخاب و آماده‌سازی داده‌ها

در ابتدا مجموعه داده‌هایی انتخاب می‌کنیم که می‌خواهیم برای تحلیل استفاده کنیم. ممکن است بسیاری از الگوریتم‌های جمع‌آوری داده فقط با پایگاه داده‌های همگن کار کنند که این مسئله در جمع‌آوری داده‌ها محدودیت محسوب می‌شود. ما از پایگاه داده به‌عنوان مخزنی برای داده‌های تولیدشده از حسگرهای استفاده‌شده در حوزه سلامت در بستر اینترنت اشیا استفاده می‌کنیم تا از این طریق بتوانیم تصمیم‌گیری‌های راهبردی را اتخاذ کنیم و اقدامات

امر سبب کاهش هزینه نیز خواهد شد و همچنین باعث می‌شود اطلاعات پزشکی بیمار که در پرونده‌های پزشکی الکترونیکی بیمار ثبت شده است در گذشته‌های دورتری مطالعه و بررسی شود. مراقبان از راه دور با استفاده از این اطلاعات اقدامات لازم را برای کمک به بیمار انجام می‌دهند.

۳-۱-۲- سیستم نظارت بر سلامت

در سیستم‌های پزشکی هوشمند برخی حسگرها می‌توانند در بدن بیمار کاشته شوند، به بیمار پوشیده شوند یا در محیط اطراف بیمار قرار داده شوند. ما در این مقاله از حسگرهای پوشیدنی نظارت بر ضربان قلب استفاده کرده‌ایم. در این مطالعه حسگرهایی که ناظر بر افراد دارای بیماری قلبی خطرناک‌اند، علائم حیاتی و سیگنال‌های ECG برگرفته از داده‌های حسگر را به‌طور پیوسته جمع‌آوری می‌کنند و این اطلاعات را به سرور محلی گزارش می‌دهند. سرور محلی اطلاعات را ذخیره می‌کند و حین پردازش اطلاعات چنانچه نشانه‌های غیرطبیعی دریافت کند و تشخیص دهد این علائم به حملات ناگهانی قلبی یا مرگ منجر می‌شوند سریعاً یک هشدار به بخش بهداشت و درمان از راه دور^{۱۸} (UHR) ارسال می‌کند. UHR هشدار را ارزیابی می‌کند و اقدام مناسب و به‌موقع برای کمک به بیمار و نجات زندگی او انجام می‌دهد. از یک روش فشرده‌سازی به‌منظور کاهش ترافیک برای انتقال سیگنال‌ها به سرور استفاده می‌شود.

۳-۱-۳- جمع‌آوری و پیش‌پردازش داده‌ها

در این مرحله پس از پالایش مجموعه داده‌هایی که توسط حسگرهای پوشیدنی نظارت بر ضربان قلب، حسگر تنفس و حسگر نوری (که همگی وضعیت ضربان قلب را منعکس می‌کنند) به دست آمده‌اند، چندین منبع داده‌ای در یک انبار داده قرار می‌گیرند. به عبارت دیگر، اطلاعات جمع‌آوری‌شده باید در یک پایگاه داده تحلیلی ذخیره شوند تا در صورت نیاز داده‌کاوی شوند. حسگرهایی که در حوزه مراقبت‌های بهداشتی در بستر اینترنت اشیا از آنها استفاده می‌شود هر روزه حجم فراوانی از اطلاعات را تولید می‌کنند

موج R با استفاده از الگوریتم Pan-Tampkins [۱۳] به دست می‌آید و از کنار هم قرار دادن فواصل RR متوالی، سیگنال HRV تشکیل داده می‌شود و به این ترتیب، سیگنال‌های HRV پیش‌پردازش شده برای استخراج ویژگی آماده می‌شوند.

۳-۲-۲- ویژگی‌های جمعیت‌شناختی و بالینی

اطلاعات جمعیت‌شناختی و بالینی شامل ۱۲ ویژگی سن، جنسیت، وزن، قد، ناحیه سطح بدن^{۱۹} (BSA)، شاخص توده بدنی^{۲۰} (BMI)، سیگاری بودن یا نبودن، فشار خون سیستولیک^{۲۱} (SBP)، فشار خون دیاستولیک^{۲۲} (DBP)، ضخامت پوشش داخلی رگ^{۲۳} (IMT)، شاخص توده بطنی چپ^{۲۴} (LVMI) و درصد خونی که با هر انقباض از قلب بیرون می‌آید^{۲۵} (EF) هستند که تمامی این ویژگی‌ها به‌عنوان اطلاعات در پرونده‌های پزشکی الکترونیکی (HER) بیماران ثبت شده‌اند [۱۴]. EHR می‌تواند یکی از منابع ارزشمندی باشد که ما را در موارد پیش‌بینی و مدل‌سازی‌های پیشگویانه یاری کند.

۳-۳- استخراج ویژگی

۳-۳-۱- استخراج ویژگی‌های زمانی و فرکانسی

سیگنال

سیگنال‌های قلبی سالم و همچنین، موج QRS قلب دارای مشخصه‌هایی است که به کمک آن می‌توان بیماری و حتی دسته‌بندی بیماری را تشخیص داد. ما تغییرات ضربان قلب (HRV) را روی سیگنال‌های ECG برای تشخیص افراد سالم و بیمار استفاده می‌کنیم.

۳-۳-۲- ویژگی‌های حوزه زمان

ویژگی‌های حوزه زمان شامل مجموعه‌ای از ویژگی‌های آماری است. این ویژگی‌ها عبارت‌اند از [۱۵] MNN (میانگین فواصل RR موجود در هر قطعه از سیگنال HRV) - SDNN (انحراف معیار فواصل RR موجود در هر قطعه از سیگنال HRV) - RMSSD (جذر میانگین مربعات اختلاف فواصل RR موجود در هر قطعه از سیگنال

لازم را انجام دهیم. داده‌های تولیدشده در پایگاه داده به‌صورت منسجم و یکپارچه ذخیره می‌شوند. سپس ما داده‌های مرتبط را انتخاب کرده‌ایم و آنها را برای عملیات داده‌کاوی آماده می‌کنیم. آماده‌سازی داده‌ها یکی از مراحل مهم برای بهبود و تسهیل فرایند داده‌کاوی است. در این مطالعه، آماده‌سازی داده‌ها در فرایند پیش‌بینی رویداد یکی از بحرانی‌ترین مراحل موجود است؛ زیرا در این پژوهش ۷۰ درصد از تلاش کلی برای مهندسی ویژگی‌ها، صرف آماده‌سازی داده‌ها می‌شود و هدف، به دست آوردن کارایی حداکثر و پردازش حداقل با استفاده از به‌کارگیری داده‌های مناسب است.

بنابراین، نتیجه می‌گیریم با انتخاب داده‌های درست و کامل از هر ۴ پایگاه داده، الگوریتم پیشنهادی مبتنی بر رویکرد یادگیری عمیق LSTM-DBN، سریع‌تر به الگوی مدنظر خواهد رسید و نتایج حاصل از آن برای کاربر فهم‌پذیرتر و راحت‌تر خواهد بود.

در این پژوهش با شناخت داده‌ها و استفاده از رویکرد LSTM-DBN برای آماده‌سازی داده‌ها اقدام شده است و مشخصات اصلی داده‌ها به دست آمده‌اند. ما در این مرحله ویژگی‌های به‌دست‌آمده از سیگنال‌های ECG را با ویژگی‌های جمعیت‌شناختی و بالینی تلفیق می‌کنیم. استفاده از ابزار برای نمایش گرافیکی، ساختارهای شرطی، زبان‌های طبیعی و تکنیک‌های دیگر در این مرحله به ما کمک کرده‌اند.

۳-۲-۱- ویژگی‌های مربوط به سیگنال‌های قلبی

در این مطالعه، با انتخاب ۵ دقیقه از ECG‌های ثبت‌شده از مجموعه داده‌های الکتروکاردیوگرافی بیماران قلبی در ۲۴ ساعت [۶]، ویژگی‌های HRV استخراج شده‌اند. منظور از HRV تغییرات در فواصل زمانی بین دو موج R است که در دو سیکل متوالی قلبی در سیگنال ECG است که به آن بازه زمانی RR می‌گویند. در پردازش HVR، با استفاده از یک نرم‌افزار منبع باز، مجموعه‌ای از وقفه‌های RR از سیگنال‌های ثبت‌شده ECG به دست می‌آیند. برای این منظور از یک قسمت ثابت به‌طور تصادفی از ۵ دقیقه ثبت‌شده از سیگنال‌های ECG در طول روز استفاده شد.

محدود^{۳۶} (RBM) ساخته شده‌اند. با روی هم قرار دادن RBMها می‌توان شبکه‌های باور عمیق را برای پردازش‌های سلسله‌مراتبی به وجود آورد. یکی از مزایای شبکه باور عمیق، یادگیری ویژگی است که با کمک داده‌های برجسب‌نخورده می‌توان ویژگی‌های سطح بالایی از داده‌های آموزشی را استخراج کرد و قدرت تمایز بین دسته‌های مختلف در داده‌ها را افزایش داد. DBNها دارای اتصالات بدون جهت در دو لایه بالایی‌اند که یک ماشین بولتزمن محدود تشکیل داده و دارای اتصالات جهت‌دار در لایه‌های پایینی‌اند. DBN یک مدل مولد احتمالی است که توزیع احتمال مشترک روی داده‌های قابل مشاهده و برجسب‌ها را فراهم می‌کند. یک DBN ابتدا از یک استراتژی یادگیری حریصانه بهینه لایه‌به‌لایه برای مقاردهی اولیه (پارامترهای) شبکه عمیق استفاده کرده است و سپس تمامی وزن‌ها را به‌طور مشترک با خروجی‌های مورد انتظار به‌دقت تنظیم می‌کند. در این فرایند علاوه بر حفظ ویژگی‌های اصلی مجموعه داده‌ها برای تفسیر مدل و استخراج دانش [۱۶] با محدودکردن نیازمندی‌های ذخیره‌سازی به کاهش هزینه‌ها و بصری‌سازی فرایند کسب دانش کمک می‌شود. شکل ۳، ساختار پایه‌ای DBN را نشان می‌دهد که از یک لایه ورودی و لایه‌های پنهان r تشکیل شده است. هر دو لایه مجاور یک RBM را ایجاد می‌کنند که به‌طور متوالی به‌عنوان RBM1 تا RBMr در نظر گرفته شده است. واحدهای گره در لایه‌های آشکار و پنهان به‌ترتیب به‌عنوان v و h در نظر گرفته شده‌اند. هر واحد در لایه آشکار به‌عنوان v_i ($i = 1, 2, \dots, m$) و هر واحد در لایه پنهان به‌عنوان h_j ($j = 1, 2, \dots, n$) نمایش داده می‌شود. n و m تعداد واحدها در لایه‌های آشکار و پنهان‌اند. یک RBM فرض می‌کند هر واحد باید یک توزیع باینری را با عنوان $v_i \in \{0, 1\}$ و $h_j \in \{0, 1\}$ برآورده کند. هر واحد دارای یک تابع فعال‌سازی $\sigma(x)$ است که معمولاً به‌عنوان عملکرد یک سیگموئید انتخاب شده است $\sigma(x) = 1/(1 + e^{-x})$. یک واحد، زمانی فعال می‌شود که در حالت ۱ قرار می‌گیرد. خروجی‌های واحدها در لایه پایین به‌عنوان ورودی‌های واحدها در لایه بالایی استفاده می‌شوند.


کارکرد انرژی یک ماشین RBM به‌صورت (۱) است:

(HRV) - SDS (انحراف معیار اختلاف بین فواصل RR موجود در هر قطعه از سیگنال HRV) - PNN50 (درصد تعداد فواصل RR موجود در هر قطعه از سیگنال HRV که اختلافشان بیشتر از ۵۰ میلی‌ثانیه است). این ویژگی‌ها به تشخیص طبقه‌بندی سالم و بیمار کمک می‌کنند.

۳-۳-۳- ویژگی‌های حوزه فرکانس

در این مرحله، انرژی سیگنال در باند فرکانسی خیلی پایین (۰/۰۴-۰/۰۰۳ هرتز) و باند فرکانسی پایین (۰/۱۵-۰/۰۴ هرتز) و باند فرکانسی بالا (۰/۱۵-۰/۴ هرتز) با استفاده از روش تخمین طیف (PSD) استخراج شده است. فرکانس‌های بالا در طیف توان سیگنال HRV نشان‌دهنده فعالیت بخش پاراسمپاتیک سیستم عصبی و همچنین، فرکانس‌های پایین نشان‌دهنده فعالیت بخش سمپاتیک سیستم عصبی خودکار کنترل‌کننده نرخ ضربان قلب است؛ از این رو، نسبت انرژی سیگنال در باند فرکانسی پایین (LF) به انرژی سیگنال در باند فرکانسی بالا (HF) می‌تواند به‌عنوان یک ویژگی استفاده شود که تعادل سمپاتیک و پاراسمپاتیک را ارزیابی می‌کند. طیف توان سیگنال (PSD) با استفاده از روش پارامتریک Burg محاسبه شده است [۱۵].

نمونه ضربان‌های فرد سالم و بیمار در شکل ۲ نشان داده شده است.



شکل (۲): نمونه ضربان‌های فرد سالم و بیمار

۳-۴- بازنمایی ویژگی بهینه با DBN

شبکه‌های باور عمیق از لایه‌هایی به نام ماشین بولتزمن

۳-۵- پیش‌بینی رویداد با شبکه LSTM

در این مطالعه از یک شبکه عصبی LSTM استفاده شده که نوعی از شبکه عصبی بازگشتی (RNN) است و برای مطالعه داده‌های سری زمانی و پیوسته بسیار مناسب است. یکی از خصوصیات شبکه LSTM این است که می‌تواند وابستگی‌های بلندمدت را بین مراحل زمانی یک توالی یاد بگیرد. لایه LSTM می‌تواند به توالی زمانی روبه‌جلو نگاه کند؛ درحالی‌که لایه LSTM دوطرفه می‌تواند به توالی زمانی روبه‌جلو و روبه‌عقب نگاه کند. در این مطالعه از لایه LSTM دوطرفه استفاده شده است.

برخلاف شبکه بازگشتی سنتی که صرفاً جمع متوازن سیگنال‌های ورودی را محاسبه می‌کند و سپس از یک تابع فعال‌سازی عبور می‌دهد، هر واحد LSTM از یک حافظه C_t در زمان t بهره می‌برد. خروجی h_t یا فعال‌سازی واحد LSTM به صورت $h_t = T_o \cdot \tanh(C_t)$ است که در آن T_o دروازه خروجی است که کنترل‌کننده میزان محتوایی است که از طریق حافظه ارائه می‌شود. دروازه خروجی از طریق عبارت $T_o = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o)$ محاسبه می‌شود که در آن σ تابع فعال‌سازی سیگموئید است. W_o نیز یک ماتریس اریب است. سلول حافظه C_t نیز با فراموشی نسبی حافظه فعلی و اضافه کردن محتوای حافظه جدید \hat{C}_t به صورت $\hat{C}_t = T_f \cdot C_{t-1} + T_u \cdot \hat{C}_t$ به‌روزرسانی می‌شود که در آن محتوای حافظه جدید از طریق عبارت $\hat{C}_t = \tanh(WC \cdot [h_{t-1}, X_t] + b_c)$ به دست می‌آید. آن میزان از حافظه فعلی که باید فراموش شود توسط دروازه فراموشی T_f کنترل می‌شود و آن میزانی از محتوای حافظه جدید که باید به سلول حافظه اضافه شود توسط دروازه به‌روزرسانی (یا گاهی به دروازه ورودی معروف است) انجام می‌گیرد. این عمل با محاسبات (۶) و (۷) صورت می‌گیرد:

$$T_f = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (۶)$$

$$T_u = \sigma(W_u \cdot [h_{t-1}, X_t] + b_u)$$

$$h_{t,b} = \tanh(W_t x_{t,b} + W_2 h_{t-1,b} + b_h) \quad (۷)$$

$$o_{t,b} = \text{soft max}(W_3 h_{t,b} + b_o)$$

شکل ۴، ساختار یک واحد حافظه LSTM را نشان

$$E(v, h) = \sum_{i=1}^m a_i v_i + \sum_{j=1}^n b_j h_j + \sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j \quad (۱)$$

جایی که w_{ij} وزن بین واحد i در لایه آشکار و واحد j در لایه پنهان است، a_i بایاس^{۳۷} از واحد i در لایه آشکار است، b_j بایاس از واحد j در لایه پنهان است. w_{ij} ، a_i و b_j پارامترهایی هستند که یاد گرفته می‌شوند و در مجموع به‌عنوان θ ارائه شده‌اند. بر طبق اصل ترمودینامیک آماری، یک واحد حالت (v, h) دارای تابع توزیع احتمال مشترک (۲) است:


$$p(v, h) = e^{E(v, h)} / \sum_{v, h} e^{E(v, h)} \quad (۲)$$

مشابه سایر توابع توزیع احتمالی شرطی و مشترک بیشتر با (۳) تا (۵) تعریف می‌شوند [۱۷].

$$p(v) = \sum_h e^{E(v, h)} / \sum_{v, h} e^{E(v, h)} \quad (۳)$$

$$p(h|v) = e^{E(v, h)} / \sum_h e^{E(v, h)} \quad (۴)$$

$$p(v|h) = e^{E(v, h)} / \sum_v e^{E(v, h)} \quad (۵)$$




شکل (۳): ساختار یک شبکه باور عمیق (DBN)

شریانی معمولاً در چنین شرایطی رخ می‌دهند و HRV بالا نشان‌دهنده فرد سالم است که از وقفه‌های (RR) نامنظم نتیجه می‌شود.

کار شرح داده شده در این مقاله با استفاده از ۴ پایگاه داده ارائه شده است که در ادامه، خصوصیات هریک از پایگاه‌های داده معرفی می‌شود. اولین پایگاه داده با نام اختصاری DB1 از آرشیو مجموعه داده‌های مربوط به بیماری‌های قلبی سایت KAGGLE^{۲۸} گرفته شده است که دارای ۷۰۰۰۰ نمونه (شامل ۴۵۵۳۰ زن و ۲۴۴۷۰ مرد) است. این نمونه‌ها در سال ۲۰۰۹ جمع‌آوری شده‌اند. این مجموعه داده ۱۲ ویژگی دارد و دارای افراد بیمار و سالم است و به‌طور تقریبی ۵۰ درصد داده‌ها مربوط به بیماران و ۵۰ درصد مربوط به افراد سالم می‌شود. پایگاه داده دوم با نام اختصاری DB2 شامل ۲۰۰۰۰ نمونه است که با همکاری مرکز تحقیقات بیمارستان شهید بهشتی، یکی از بزرگ‌ترین بیمارستان‌های تخصصی قلب واقع در شهر تهران پایتخت ایران انجام شده است. در این پایگاه داده از مجموعه داده‌های واقعی استفاده شده که به دلایل محرمانگی، خصوصیات این مجموعه داده محفوظ است. پایگاه داده سوم با نام اختصاری DB3 از وب‌سایت Physionet^{۲۹} دانلود شده است که متعلق به ۱۳۹ نمونه مبتلا به فشار خون بالا است و در مرکز فشار خون بیمارستان دانشگاه ناپلز فدریکوی ایتالیا تازه ثبت شده‌اند. بیماران، ۵۵ ساله و بیشتر (شامل ۴۹ زن و ۹۰ مرد، سن ۷۲-۷ ساله) برای ۱۲ ماه به‌منظور ثبت اصلی رویدادهای قلبی عروقی و رگ‌های خونی مربوط به مغز پیگیری شدند. چهارمین پایگاه داده با نام اختصاری DB4 از آرشیو مجموعه داده‌های سایت UCI^{۳۰} گرفته شده است که ۳۰۳ نمونه (شامل ۹۶ زن و ۲۰۷ مرد) دارد و در سال ۱۹۸۸ جمع‌آوری شده است. این پایگاه داده ۷۶ ویژگی دارد که ما با استخراج ویژگی‌های بهینه از ۱۲ ویژگی اصلی آن استفاده می‌کنیم. برچسب داده‌های هدف در پایگاه داده‌های DB1، DB2، DB4، بیمار / سالم و در پایگاه داده DB3 غش / بیمار / سالم است. همان‌طور که در جدول ۱ نشان داده شده است، ۱۲ ویژگی از مجموعه داده‌ها به‌همراه نوع داده‌ها و نوع مدل استخراج ویژگی بهینه بررسی شده‌اند.

می‌دهد که در هر مرحله زمانی، محتوای هر سلول با مقادیر جدید از مرحله زمانی قبل و ورودی جدید جایگزین می‌شود؛ بنابراین، بردار حافظه پنهان توانایی تأثیرگذاری در برخی از مراحل زمانی بسیار محدود فعلی را دارد.



شکل (۴): ساختار یک واحد حافظه LSTM

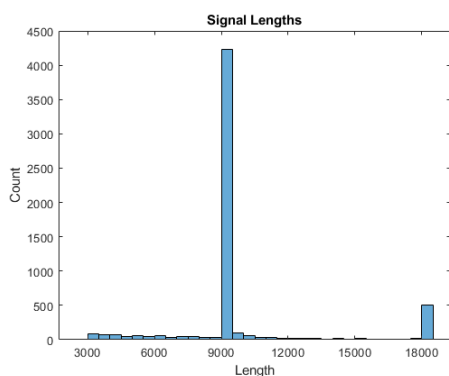
۴- نتایج تجربی

در این بخش، ضمن بیان جزئیات پیاده‌سازی سیستم پیشنهادی LSTM-DBN کارایی آن با استفاده از ۴ مجموعه داده بررسی می‌شود. پس از آن، نتایج پیش‌بینی رویکرد پیشنهادی با سایر رویکردهای یادگیری سستی و عمیق در حالت‌های بدون / با یادگیری ویژگی (DBN) مقایسه می‌شوند و در نهایت برای درک بیشتر نمودارهای ROC و معیارهای ارزیابی دقت، صحت و سنجش F پس از محاسبات ترسیم می‌شوند.

۴-۱- مجموعه داده‌ها

به‌طور کلی داده‌ها به دو قسمت سیگنال و برچسب تقسیم می‌شوند. سیگنال آرایه‌ای است که داده‌های ECG را نگه می‌دارد و برچسب آرایه‌ای است که برچسب‌های مربوط به سیگنال‌ها را نگه می‌دارد و یک هیستوگرام از طول سیگنال تولید می‌شود که بیشتر سیگنال‌ها ۹۰۰۰ طول هستند؛ برای نمونه، می‌توان یک قطعه از یک سیگنال (در حدود ۵ دقیقه) را در دو کلاس سالم و بیمار براساس تغییرپذیری ضربان قلب (HRV) بررسی کرد. HRV پایین نشان‌دهنده وقفه‌های (RR) منظم است که رویدادهای

است. با استفاده از DBN ویژگی‌های مؤثرتری به‌منظور افزایش دقت عملیات پیش‌بینی از داده‌ها استخراج می‌شوند. با به‌کارگیری DBN در مجموعه داده‌ها به‌طور متوسط ۶۰ درصد ویژگی‌ها کاهش یافت. پس از اعمال DBN روی مجموعه داده‌ها و حذف ویژگی‌های غیرمرتبط و تکراری به‌منظور آماده‌سازی برای آموزش به الگوریتم LSTM داده می‌شود.



شکل (۵): هیستوگرام مجموعه داده‌ها

از سیگنال‌های انتخاب‌شده در بخش قبل برای طراحی طبقه‌بند استفاده می‌شود؛ به‌گونه‌ای که سیگنال‌ها به یک مجموعه آموزش و یک مجموعه آزمون تقسیم می‌شوند. ما در شبکه عصبی LSTM، ۷۰ درصد داده‌ها را برای یادگیری و ۳۰ درصد داده‌ها را برای آزمون در نظر گرفته‌ایم.

برای پیاده‌سازی شبکه عصبی LSTM از ۵ لایه شامل لایه‌های ورودی، لایه پنهان (با ۱۰۰ واحد مخفی)، ۲ لایه کاملاً متصل، لایه بیشینه هموار (softmax) و لایه خروجی طبقه‌بند استفاده شد که روی یک واحد پردازشگر مرکزی با تعداد ۴ خوشه و ۱۰ هسته اجرا شده است. شبکه استفاده‌شده در این پژوهش، ساختار و مقادیر تعیین‌شده دارد که در جدول ۲ نشان داده شده‌اند.

جدول (۲): تنظیم پارامترها در شبکه عصبی LSTM

پارامتر	توصیف	مقدار
MaxEpochs	حداکثر تعداد واحدهای ورودی	۱۰
MiniBatchSize	حداقل اندازه نمونه‌های ورودی	۱۵۰
InitialLearnRate	نرخ یادگیری	۰/۰۱
SequenceLength	طول توالی	۱۰۰۰
GradientThreshold	حد آستانه گرادیان	۱

جدول (۱): ویژگی‌های مجموعه داده‌ها

ویژگی‌ها	توصیف	نوع داده
Age	سن	پیوسته
Sex	زن/ مرد	متنی
Weight	وزن	عددی
Height	قد	عددی
BSA	ناحیه سطح بدن	عددی
BMI	شاخص توده بدنی	عددی
Smoking	سیگاری بودن یا نبودن	عددی
SBP	فشار خون سیستولیک	عددی
IMT	ضخامت پوشش داخلی رگ	عددی
LVMI	شاخص توده بطنی چپ	عددی
EF	درصد خونی که با هر انقباض از قلب بیرون می‌آید	عددی
IMT	ضخامت پوشش داخلی رگ	عددی

۴-۲- جزئیات پیاده‌سازی سیستم پیشنهادی

برای ارزیابی سیستم پیشنهادی، ابتدا داده‌ها به دسته‌های کوچک تقسیم می‌شوند. سپس سیگنال‌های ECG در این دسته‌های کوچک، کوتاه و همگی دارای طول یکسان می‌شوند. اگر سیگنال‌ها بیش از اندازه کوتاه شوند، بر کارایی شبکه تأثیر منفی می‌تواند داشته باشند؛ زیرا ممکن است شبکه یک سیگنال را مبنی بر اطلاعات حذف یا اضافه شده به نادرستی تفسیر کند.

همان‌طور که در نمودار هیستوگرام شکل ۵ نشان داده شده است، بیشتر داده‌ها ۹۰۰۰ نمونه دارند؛ بنابراین، سیگنال‌های ECG همگی شامل ۹۰۰۰ نمونه هستند که سیگنال‌های کمتر از ۹۰۰۰ نمونه نادیده گرفته می‌شوند. سیگنال‌هایی که بیش از ۹۰۰۰ نمونه طول دارند، تا جایی که امکان‌پذیر باشد به گونه‌ای می‌شکنند که نمونه‌های باقی‌مانده نادیده گرفته شوند.

در این مقاله برای پیاده‌سازی DBN-LSTM از نرم‌افزار متلب در سیستمی با گرافیک 1070، پردازنده COREi7 G7 و 16 گیگابایت استفاده شده است. DBN در سیستم پیشنهادی شامل سه لایه پنهان (با ۵۰ واحد مخفی در هر لایه)، دو مشکل سرعت پایین آموزش و گیرافتادن در کمینه محلی را حل می‌کند و در این مطالعه به‌عنوان یک روش بازنمایی و استخراج ویژگی استفاده شده

Sensitivity: حساسیت یا فراخوانی است و نسبت

موارد مثبتی است که به درستی طبقه‌بندی شده‌اند.

$$TPR = \frac{TP}{TP + FN} \quad (9)$$

F-measure: میانگین هارمونیک یا میانگین وزنی و از

نمرات **Sensitivity** و **Precision** است.

$$F - measure = 2 * \frac{P * TPR}{P + TPR} \quad (10)$$

Accuracy: صحت است و نسبت نتایج درست (هم

مثبت درست و هم منفی درست) به کل جامعه است.

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

Fall-out: نسبت مثبت نادرست است؛ به عبارتی نسبت

موارد منفی است که به نادرست مثبت طبقه‌بندی شده‌اند.

$$FPR = \frac{FP}{FP + TN} \quad (12)$$

Miss rate: نسبت منفی نادرست است؛ به عبارتی

نسبت موارد مثبتی است که به نادرست منفی طبقه‌بندی

شده‌اند.

$$FNR = \frac{FN}{FN + TP} \quad (13)$$

Specificity: نسبت منفی درست است؛ به عبارتی

نسبت موارد منفی است که به درستی طبقه‌بندی شده‌اند.

$$TNR = \frac{TN}{TN + FP} \quad (14)$$

برای خلاصه کردن محاسبه اندازه‌گیری‌ها و نتایج آزمون

الگوریتم، می‌توان از ماتریس اغتشاش استفاده کرد که در

شکل ۵ نشان داده شده است.

شکل ۷ (ج) دارای سه کلاس سالم، بیمار و غش است.

این شکل برای کلاس غش نشان می‌دهد ۹۰ بیمار در

کلاس غش درست پیش‌بینی شده است و ۷ بیمار در کلاس

ایست قلبی و ۳ بیمار در کلاس سالم اشتباه پیش‌بینی شده

است؛ به همین ترتیب، برای کلاس‌های سالم و بیمار

در این مطالعه از الگوریتم بهینه‌سازی گرادیان کاهشی

تصادفی (SGD) برای آموزش شبکه‌ها بهره گرفته شد. این

الگوریتم روشی مبتنی بر تکرار برای بهینه‌سازی یک تابع

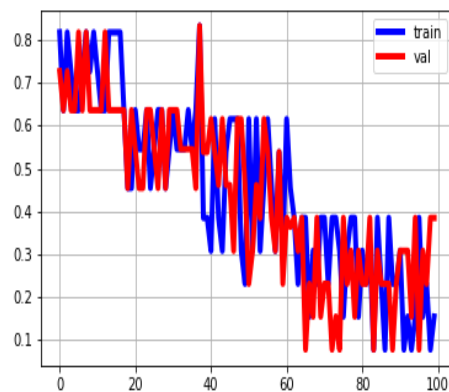
مشق‌پذیر به نام تابع زیان (به‌طور پیش‌فرض آنروپی

متقابل) است که یک تقریب تصادفی از روش گرادیان

کاهشی است. شکل ۶، روند یادگیری روش پیشنهادی را

براساس تابع زیان در طول دوره آموزش و اعتبارسنجی

داده‌های DB1 نشان می‌دهد.



شکل (۶): فرایند یادگیری شبکه LSTM-DBN براساس تابع زیان در طول دوره آموزش و اعتبارسنجی

۴-۳- معیارهای ارزیابی

در این مرحله از رایج‌ترین شاخص‌های ارزیابی برای

مدل پیشنهادی LSTM-DBN استفاده می‌شود. ما از

معیارهای **Precision**, **Recall**, **F-measure**, **Accuracy**,

Fall-out, **Miss rate** و **Specificity** استفاده می‌کنیم که

برای به دست آوردن مقادیر مربوط به آنها از ماتریس

اغتشاش استفاده می‌شود. ماتریس اغتشاش، چگونگی

عملکرد الگوریتم دسته‌بندی را با توجه به مجموعه داده

ورودی به تفکیک انواع دسته‌های مسئله دسته‌بندی نمایش

می‌دهد. برای محاسبه هر یک از این معیارها از روابط ۸ تا

۱۴ استفاده می‌شود.

Precision: دقت طبقه‌بندی است و نسبت تعداد

مثبت‌های درست به کل نتایج مثبت (هم مثبت‌های درست

و هم مثبت‌های نادرست) است.

$$PPV = \frac{TP}{TP + FP} \quad (8)$$

محاسبه انجام می‌شود.

مسئله مفقودشدن سریع اطلاعات در سلول‌های بازگشتی استفاده می‌شود که توانایی یادگیری وابستگی‌های بلندمدت را دارد. در مقایسه با سلول‌های sRNN که دو حالت را ذخیره می‌کنند، سلول‌های LSTM چهار حالت (مقدار کنونی و آخرین خروجی و مقدار کنونی و آخرین مقدار) را ذخیره می‌کنند. این سلول‌ها سه نوع گیت «ورودی»، «خروجی» و «فراموشی» دارند. واحد گیت بازگشتی (GRU) نیز نوعی از LSTM است که در مقایسه با آن تنها از دو گیت «به‌روزرسانی» و «بازنشانی» برای جلوگیری از مفقودشدن اطلاعات استفاده می‌کند. تعداد اتصالات کمتر باعث می‌شود GRU شفافیت کمتر و در عین حال سرعت بیشتر نسبت به LSTM داشته باشد.

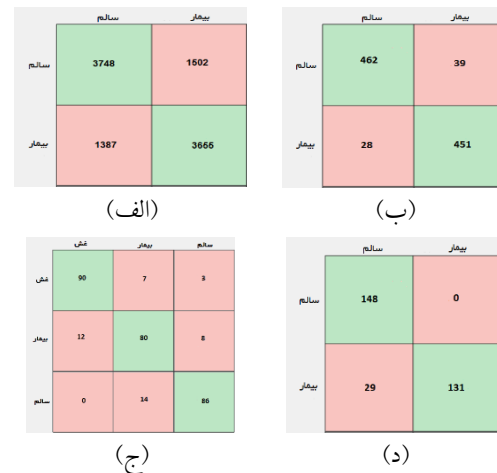
در ادامه برای بررسی قدرت پیش‌بینی با DBN تمامی این رویکردها را همراه با DBN با استفاده از همان مجموعه داده‌ها نیز آزمایش کردیم. نتایج عملکرد پیش‌بینی رویدادهای شریانی برای رویکرد پیشنهادی در مقایسه با سایر رویکردها در جدول‌های ۳ تا ۵ ارائه شده‌اند. تمامی مقادیر محاسبه‌شده در جداول، حاصل میانگین ۲۰ بار اجرا هستند. مقادیر مربوط به بازه اطمینان (CI) ۹۵ درصد در این جداول با محاسبه میانگین و انحراف معیار نمونه‌های تست روی ۴ مجموعه داده برای هر یک از شاخص‌های ارزیابی به دست آمدند. برای این منظور، ما از مقدار Z در (۱۵) برای فاصله اطمینان CI ۹۵ درصد از هر شاخص استفاده کردیم:

$$\bar{X} \pm Z \times \frac{S}{\sqrt{n}} \quad (15)$$

به طوری که در آن، \bar{X} میانگین، S انحراف معیار، n تعداد مشاهدات آزمون و مقدار Z برای CI ۹۵ درصد برابر با ۱/۹۶ است.

همان‌طور که نتایج آزمایش‌ها نشان می‌دهند، رویکرد پیشنهادی تقریباً در تمامی موارد عملکرد به‌مراتب بهتری نسبت به سایر رویکردهای یادگیری عمیق و یادگیری ماشین سنتی داشته است.

همچنین، مشاهده می‌شود تمامی روش‌ها همراه با یادگیری ویژگی (DBN) در مقایسه با آزمایش آنها بدون DBN کارایی بالاتری را نشان می‌دهند. مشهود است استفاده از DBN صحت و دقت پیش‌بینی بهتری را نسبت



شکل (۷): ماتریس اغتشاش برای پایگاه داده الف (DB1، ب)

DB2 (ج) DB3، د) DB4

۴-۴- نتایج ارزیابی و مقایسه

هدف اصلی این مطالعه ارزیابی عملکرد بهینه مدل LSTM-DBN برای پیش‌بینی رویدادهای شریانی است. در این بخش، مجموعه داده‌ها علاوه بر روش پیشنهادی روی سایر روش‌های یادگیری عمیق، یادگیری ماشین سنتی و همچنین، سایر تکنیک‌های استخراج ویژگی، آزمایش و نتایج برای بررسی کارایی پیش‌بینی با رویکرد پیشنهادی مقایسه شدند.

ما مطالعه‌ای مقایسه‌ای بین چهار رویکرد یادگیری عمیق Ensemble، LSTM-RNN، GRU-RNN، sRNN و MLP، [۱۸]، چهار رویکرد یادگیری ماشین سنتی (SVM، RF) و نیز دو روش استخراج ویژگی (PCA و AutoEncoder) را در پیش‌بینی رویدادهای مربوط به شریان‌های قلبی و عروقی انجام دادیم. یک شبکه عصبی بازگشتی ساده (sRNN) اساساً به مؤلفه زمانی اهمیت می‌دهد؛ به طوری که در آن هر سلول (حافظه) به صورت داخلی مقدار پیشین خود را ذخیره می‌کند. به دلیل آنکه مقدار پیشین مقداری است که از طریق تابع فعال‌سازی عبور داده می‌شود و هر به‌روزرسانی، این مقدار فعال‌شده را همراه با دیگر وزن‌ها از طریق تابع فعال‌سازی عبور می‌دهد، اطلاعات به‌طور مستمر (شبهه به یک حافظه فرار) مفقود می‌شوند. حافظه کوتاه‌مدت ماندگار (LSTM) برای حل

به سایر روش‌های استخراج ویژگی دربردارد. نتایج تجربی معروض حملات ناگهانی قلبی هستند، پیش‌بینی دقیق‌تری نشان می‌دهند حساسیت کاملاً در مدل LSTM-DBN در داشته باشد. مقایسه با سایر رویکردها می‌تواند زمانی که بیماران در

جدول ۳: مقایسه روش‌های یادگیری ماشین سنتی با LSTM-DBN برای

الف) پایگاه داده DB1 (۷۰۰۰۰ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	95.50±7.8	82.52±6.4	91.09±7.1	88.74±6.5	8.41±6.9	9.15±7.3	85.48±5.9
LSTM	81.32±5.8	86.42±6.6	83.79±6.3	90.95±6.8	34.30±3.9	24.47±2.2	86.67±5.7
MLP+DBN	31.10±4.3	27.78±2.4	29.34±2.3	14.51±1.4	36.77±2.6	42.34±2.7	25.41±1.8
MLP	21.24±1.7	34.42±2.6	26.26±2.2	19.74±1.7	21.35±1.8	27.42±2.4	33.32±2.9
REG+DBN	26.15±3.1	40.61±4.7	31.81±2.8	11.44±1.1	15.12±1.4	26.45±2.3	15.54±1.7
REG	30.90±4.1	30.45±2.5	30.67±2.6	33.44±2.9	35.45±3.2	21.65±1.8	34.12±3.1
SVM+DBN	11.23±0.9	19.42±1.5	14.23±1.3	24.22±2.1	21.85±1.8	25.45±2.4	28.10±2.7
SVM	37.75±3.4	32.84±2.9	35.12±3.1	29.45±2.7	25.41±2.3	22.75±1.9	30.55±2.7
RF+DBN	20.91±2.2	33.42±3.5	25.72±2.7	36.62±3.4	20.12±1.9	32.69±3.1	18.45±1.9
RF	29.23±3.1	17.93±1.5	22.22±2.0	21.32±1.9	37.17±3.5	23.14±2.1	15.35±1.3

ب) پایگاه داده DB2 (۲۰۰۰۰ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	83.15±6.9	83.45±6.7	83.29±5.8	93.24±7.1	11.23±1.3	10.10±0.9	89.14±6.8
LSTM	93.33±7.8	84.74±6.9	88.82±6.7	92.75±7.3	22.62±2.1	26.47±2.4	87.20±7.0
MLP+DBN	57.43±4.3	40.19±3.9	47.28±4.6	58.19±5.4	20.10±1.7	19.12±1.6	42.34±3.9
MLP	58.11±5.4	42.17±3.9	48.87±4.5	61.36±5.2	33.23±2.9	17.10±1.6	36.41±3.4
REG+DBN	40.03±3.7	39.10±3.6	39.55±3.6	39.85±3.5	14.16±1.2	23.05±2.1	27.15±2.8
REG	38.40±3.4	30.11±3.1	33.75±3.2	29.47±2.8	20.15±1.8	26.20±1.5	11.39±1.4
SVM+DBN	52.15±5.1	42.19±3.9	46.64±4.2	62.17±5.1	28.42±2.5	23.02±1.9	32.11±2.8
SVM	31.67±2.7	29.21±2.7	30.39±2.8	30.26±2.9	48.16±4.3	42.36±3.8	19.12±1.7
RF+DBN	21.90±2.0	30.35±2.7	25.44±2.1	32.45±2.8	20.03±1.9	20.14±2.0	29.10±2.6
RF	19.16±1.8	29.70±2.7	23.29±2.1	30.90±2.6	31.15±2.7	21.34±1.9	29.71±2.5

ج) پایگاه داده DB3 (۱۳۹ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	85.21±7.6	88.35±7.7	86.75±6.5	80.41±5.7	10.42±1.2	11.20±1.1	84.12±6.9
LSTM	88.01±6.9	84.14±7.1	86.03±6.8	90.38±8.4	24.75±2.3	21.41±2.2	88.42±7.7
MLP+DBN	91.12±8.6	82.56±6.7	86.62±7.3	86.15±7.9	41.31±4.3	33.35±3.4	82.42±7.4
MLP	86.44±7.4	81.42±7.2	83.85±7.3	89.13±7.8	32.45±2.8	24.15±2.1	91.32±8.5
REG+DBN	83.25±7.6	90.02±7.9	86.50±8.1	83.74±7.8	60.01±5.4	78.37±6.3	84.14±7.8
REG	81.45±7.6	87.10±7.9	84.18±7.3	87.65±7.7	30.14±2.8	27.39±2.6	80.25±7.7
SVM+DBN	81.36±7.8	86.19±7.9	83.70±7.5	80.36±7.1	20.67±2.0	22.15±2.1	88.64±8.1
SVM	85.75±7.8	87.34±7.5	86.53±7.6	88.45±7.8	42.21±4.1	40.34±3.9	84.45±7.6
RF+DBN	82.04±7.7	82.23±7.8	82.13±7.6	88.11±7.8	22.80±2.1	14.64±1.7	91.35±8.3
RF	83.14±7.4	89.10±7.8	86.01±7.6	89.35±7.9	60.04±5.8	51.12±4.9	92.75±8.4

د) پایگاه داده DB4 (۳۰۳ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	85.21±7.8	88.35±7.4	86.75±7.6	80.41±7.1	10.42±1.2	11.20±1.3	84.12±7.3
LSTM	88.01±7.9	84.14±8.1	86.03±8.2	90.38±8.8	24.75±2.3	21.41±2.2	88.42±8.4
MLP+DBN	91.12±8.5	82.56±7.8	86.62±7.4	86.15±7.5	41.31±3.7	33.35±3.2	82.42±3.9
MLP	86.44±7.8	81.42±7.8	83.85±7.9	89.13±7.8	32.45±2.9	24.15±2.3	91.32±8.7
REG+DBN	83.25±7.9	90.02±7.4	86.50±7.7	83.74±7.8	60.01±5.9	78.37±7.9	84.14±8.1
REG	81.45±7.9	87.10±8.6	84.18±7.7	87.65±7.8	30.14±3.1	27.39±2.2	80.25±7.7
SVM+DBN	81.36±7.6	86.19±8.1	83.70±7.9	80.36±7.8	20.67±2.1	22.15±2.4	88.64±8.3
SVM	85.75±8.2	87.34±8.4	86.53±8.3	88.45±8.5	42.21±4.3	40.34±4.1	84.45±8.2
RF+DBN	82.04±7.9	82.23±7.8	82.13±7.8	88.11±8.6	22.80±2.1	14.64±1.5	91.35±8.8
RF	83.14±8.0	89.10±8.7	86.01±8.4	89.35±8.6	60.04±6.2	51.12±5.3	92.75±8.9

جدول ۴: مقایسه روش‌های یادگیری عمیق با LSTM-DBN برای

الف) پایگاه داده DB1 (۷۰۰۰۰ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	95.50±8.9	82.52±8.1	91.09±8.8	88.74±8.6	8.41±8.2	9.15±8.8	85.48±8.3
LSTM	81.32±7.9	86.42±8.3	83.79±8.0	90.95±8.8	34.30±3.5	24.47±2.7	86.67±8.4
GRU+DBN	83.54±8.1	92.33±8.9	87.46±8.6	93.41±9.0	21.49±2.2	31.64±2.9	88.44±8.6
GRU	82.12±8.0	86.26±8.4	81.88±7.8	81.36±7.8	23.65±2.4	28.38±2.9	93.53±9.1
sRNN +DBN	92.50±8.8	91.78±8.8	92.41±9.3	90.45±8.9	44.15±4.5	40.13±4.1	80.77±7.7
sRNN	80.63±7.6	82.14±7.8	81.37±7.7	90.71±8.8	10.17±1.1	14.75±1.3	87.63±8.6
Ensemble +DBN	89.14±7.9	89.35±8.1	89.24±8.1	84.62±8.2	49.48±5.1	39.36±4.2	86.45±8.5
Ensemble [18]	91.19±8.8	92.14±9.0	91.66±8.9	92.31±9.0	17.63±	14.75±1.5	80.74±7.6

ب) پایگاه داده DB2 (۲۰۰۰۰ نمونه)

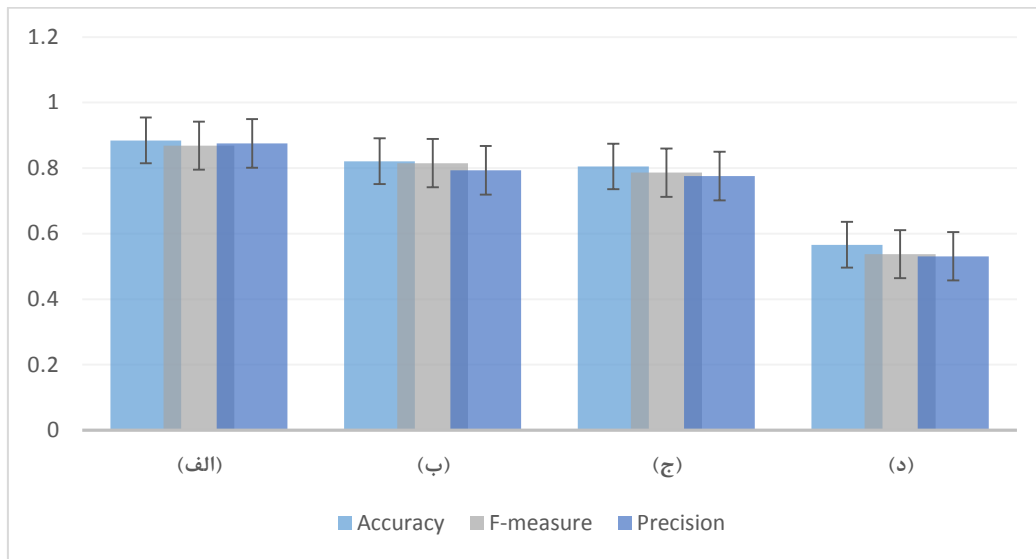
Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	95.50±8.4	82.52±7.9	91.09±8.8	88.74±8.6	8.41±7.9	9.15±8.7	85.48±7.7
LSTM	81.32±7.3	86.42±7.4	83.79±7.2	90.95±8.4	34.30±3.3	24.47±2.5	86.67±8.1
GRU+DBN	83.54±7.7	92.33±8.3	87.46±8.4	93.41±8.9	21.49±2.2	31.64±2.9	88.44±8.3
GRU	82.12±7.6	86.26±7.4	81.88±7.3	81.36±7.3	23.65±2.4	28.38±2.7	93.53±8.6
sRNN +DBN	92.50±8.5	91.78±8.5	92.41±8.4	90.45±8.2	44.15±4.3	40.13±3.9	80.77±7.8
sRNN	80.63±7.8	82.14±7.9	81.37±7.6	90.71±8.1	10.17±1.2	14.75±1.5	87.63±7.9
Ensemble +DBN	89.14±8.5	89.35±8.5	89.24±8.6	84.62±8.0	49.48±4.8	39.36±4.0	86.45±8.1
Ensemble [18]	91.19±8.7	92.14±8.8	91.66±8.7	92.31±8.8	17.63±1.8	14.75±1.5	80.74±7.8

ج) پایگاه داده DB3 (۱۳۹ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	85.21±8.1	88.35±8.3	86.75±8.2	80.41±7.8	10.42±1.2	11.20±1.3	84.12±8.0
LSTM	88.01±8.5	84.14±8.3	86.03±8.5	90.38±8.7	24.75±2.3	21.41±2.2	88.42±8.6
GRU+DBN	26.54±2.5	10.64±1.1	15.19±1.6	16.75±1.7	19.27±2.0	23.36±2.4	10.20±1.1
GRU	10.65±1.2	36.75±3.7	16.51±1.8	10.64±1.2	33.32±3.4	15.42±1.6	34.40±3.5
sRNN +DBN	31.14±3.2	31.36±3.2	31.24±3.2	32.34±3.3	34.14±3.5	23.65±2.4	19.56±2.0
sRNN	28.67±2.9	13.45±1.4	18.31±1.9	34.31±3.5	10.17±1.1	26.15±2.7	27.47±2.8
Ensemble +DBN	12.02±1.3	18.36±1.9	14.52±1.5	13.42±1.4	26.17±2.7	30.21±3.1	23.04±2.4
Ensemble [18]	30.78±3.1	11.41±1.2	16.64±1.7	34.17±3.5	20.68±2.1	34.39±3.5	40.36±4.1

د) پایگاه داده DB4 (۳۰۳ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
LSTM+DBN	86.21±8.3	86.22±8.3	86.21±8.3	91.30±8.7	12.14±1.3	11.55±1.2	83.42±7.8
LSTM	82.48±7.7	83.76±7.8	83.11±7.8	88.71±8.2	21.41±2.2	31.17±3.2	71.31±7.2
GRU+DBN	82.12±7.8	73.14±7.2	77.37±7.6	85.68±7.1	18.01±1.8	36.12±3.7	80.25±7.8
GRU	73.90±7.1	71.23±6.8	72.54±7.1	79.36±7.6	23.42±2.4	20.45±2.1	69.99±6.6
sRNN +DBN	80.17±7.6	71.15±6.7	75.39±6.9	80.61±7.2	26.12±2.7	42.12±4.4	69.63±6.5
sRNN	77.29±7.2	68.47±6.4	72.61±6.7	72.11±6.7	30.68±3.1	35.02±3.6	86.90±8.5
Ensemble +DBN	98.10±9.3	93.27±8.9	90.75±8.8	92.11±8.9	24.02±2.3	42.50±4.7	91.13±8.5
Ensemble [18]	97.11±9.1	90.14±8.7	93.49±8.9	90.29±8.8	30.47±3.6	31.62±3.7	86.35±8.4



شکل (۸): مقایسه میانگین مقادیر دقت، صحت و سنجش F در هر ۴ پایگاه داده با الف) رویکرد LSTM-DBN (ب) میانگین رویکردهای یادگیری عمیق، (ج) میانگین رویکردهای یادگیری سنتی، (د) میانگین رویکردهای استخراج ویژگی

جدول ۵: مقایسه عملکرد استخراج ویژگی DBN با سایر روش‌های استخراج ویژگی برای

الف) پایگاه داده DB1 (۷۰۰۰۰ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
DBN +LSTM	95.50±8.9	82.52±7.8	91.09±8.7	88.74±8.3	8.41±0.9	9.15±1.0	85.48±8.2
PCA+LSTM	72.23±6.8	82.62±7.8	77.07±7.5	71.75±6.6	35.67±3.4	37.42±3.6	82.26±7.8
AutoEncoder+LSTM	84.45±7.9	88.74±7.3	86.54±8.1	79.43±7.5	52.75±4.9	46.18±4.7	89.75±8.6
LSTM	78.44±7.6	91.26±8.7	84.36±8.0	70.60±6.7	44.37±4.1	51.61±4.7	85.56±8.2

ب) پایگاه داده DB2 (۲۰۰۰۰ نمونه)


Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
DBN +LSTM	83.15±7.9	83.45±8.0	83.29±7.9	93.24±8.8	11.23±1.2	10.10±1.1	89.14±8.4
PCA+LSTM	82.55±7.7	85.32±8.1	83.91±7.8	91.47±8.6	52.14±4.9	56.41±5.5	91.75±8.8
AutoEncoder+LSTM	72.64±6.8	90.25±8.7	80.49±7.6	89.15±8.5	42.64±4.1	43.42±4.4	93.26±8.9
LSTM	91.11±8.7	74.34±7.1	81.87±7.8	87.14±8.3	21.63±2.0	25.10±2.3	72.41±6.7

ج) پایگاه داده DB3 (۱۳۹ نمونه)

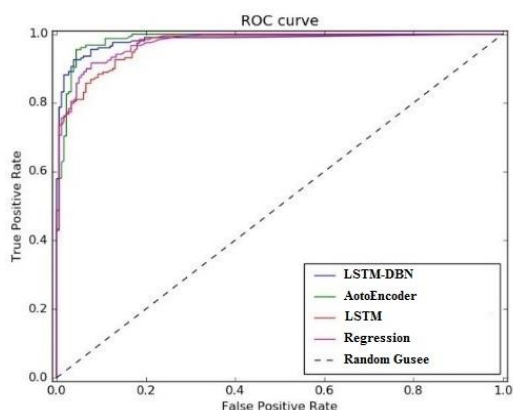
Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
DBN +LSTM	85.21±8.1	88.35±8.4	86.75±8.6	80.41±7.7	10.42±1.1	11.20±1.3	84.12±7.9
PCA+LSTM	91.20±8.8	93.45±8.9	92.31±8.7	87.31±8.3	28.13±2.8	28.30±2.9	85.15±8.1
AutoEncoder+LSTM	91.14±8.7	91.56±8.8	91.34±8.7	74.75±7.0	10.75±1.1	13.40±1.4	76.34±7.2
LSTM	91.36±8.7	79.14±7.5	84.81±8.0	90.35±8.6	29.20±3.0	33.32±3.4	89.03±8.4

د) پایگاه داده DB4 (۳۰۳ نمونه)

Method	Precision (95% CI)	Sensitivity (95% CI)	F-measure (95% CI)	Accuracy (95% CI)	Fall-out (95% CI)	Miss rate (95% CI)	Specificity (95% CI)
DBN +LSTM	86.21±8.2	86.22±8.2	86.21±8.1	91.30±8.7	12.14±1.2	19.10±2.0	83.42±7.9
PCA+LSTM	72.67±6.8	69.21±6.6	70.89±6.5	81.66±7.7	16.23±1.7	11.55±1.3	68.46±6.5
AutoEncoder+LSTM	68.02±6.4	71.36±6.7	69.64±6.5	81.30±7.7	20.36±2.2	25.30±2.6	75.45±7.1
LSTM	72.71±6.7	68.34±6.3	70.45±6.5	90.85±8.6	34.52±3.0	23.10±2.4	71.31±6.7



شکل ۹: منحنی ROC برای رویکرد پیشنهادی در چهار پایگاه داده



شکل ۱۰: منحنی ROC برای رویکردهای مختلف در پایگاه داده اول

۵- نتیجه‌گیری و پیشنهادات

هر ساله هزاران نفر بر اثر رویدادهای مربوط به قلب و عروق جان خود را از دست می‌دهند و به این ترتیب هزینه‌های هنگفتی بر افراد و دولت تحمیل می‌شود؛ از این رو، پیش‌بینی وقوع رویدادهای ناگهانی مربوط به قلب و عروق برای هشدار و انجام اقدامات لازم و به‌موقع ضروری است. در این مقاله از رویکرد شبکه عصبی عمیق LSTM-DBN برای پیش‌بینی رویدادهای مربوط به قلب و عروق استفاده شده است. LSTM یک معماری از شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است. در یک شبکه عصبی بازگشتی، LSTM می‌تواند برای حفظ

علاوه بر این، آزمایش دیگری با هدف بررسی عملکرد رویکرد پیشنهادی (LSTM-DBN) در مقایسه با میانگین عملکرد کل رویکردهای یادگیری عمیق، میانگین عملکرد کل رویکردهای یادگیری سنتی و میانگین عملکرد کل رویکردهای استخراج ویژگی معرفی شده در این مقاله انجام گرفته است.

نتایج این آزمایش در شکل ۸ نشان می‌دهند براساس معیارهای ارزیابی Accuracy، F-Measure و Precision میانگین عملکرد رویکرد LSTM-DBN کارایی به‌مراتب بالاتری نسبت به میانگین عملکرد سایر رویکردهای معرفی شده در این مقاله برای هر ۴ پایگاه داده دارد؛ این امر امیدبخش بودن رویکرد پیشنهادی را برای پیش‌بینی رویدادهای مربوط به شریان‌های قلبی و عروقی نشان می‌دهد.

در شکل ۹، منحنی ROC (برآورد شده روی مجموعه آزمون مستقل) برای پیش‌بینی رویدادهای شریانی با استفاده از روش LSTM-DBN در ۴ پایگاه داده ترسیم شده است. این منحنی به معنی مشخصه عملکرد سیستم است که در آن محور Y نمایش‌دهنده Sensitivity یا TPR و محور X نمایش‌دهنده Specificity یا FPR است. هر چقدر این منحنی به اندازه یک نزدیک‌تر باشد، به این معنی است که عملکرد سیستم قوی‌تر و دقیق‌تر بوده است. همان‌طور که در شکل ۸ نشان داده شده است، عملکرد LSTM-DBN در پایگاه داده‌های مختلف با اندازه‌های مختلف تقریباً یکسان بوده و عملکرد قابل قبولی از خود نمایش داده است.

در شکل ۱۰، منحنی ROC مربوط به پایگاه داده اول شامل ۷۰ هزار بیمار برای روش پیشنهادی LSTM-DBN در مقایسه با سایر روش‌ها نمایش داده شده است.

با محاسبه سطح زیر نمودار این منحنی (AUC)، LSTM-DBN با مقدار ۰/۹۶۷ به عدد یک نزدیک‌تر بوده و بالاتر از دیگر روش‌ها قرار گرفته است؛ به این معنی که روش، دقت و قدرت تشخیص بالاتری نسبت به دیگر روش‌ها دارد. پس از آن، AutoEncoder با مقدار ۰/۹۴۸ کارایی خوبی را کسب کرده است. بدترین کارایی مربوط به رویکردهای سنتی است.

مراجع

- حافظه فعلی از طریق دروازه‌های معرفی شده تصمیم‌گیری کند. همچنین، LSTM قادر است مشکل فراموشی وابستگی‌های طولانی را حل کند. از طرفی، شبکه‌های باور عمیق با کاهش ابعاد داده‌ها دو مشکل سرعت آموزش پایین و گرفتار شدن در کمینه محلی را برای شبکه‌های عصبی حل می‌کنند و به‌عنوان روشی برای استخراج ویژگی استفاده می‌شوند. یکی از مزایای استفاده از DBN در یادگیری ویژگی است که با کمک داده‌های برجسب‌نخورده می‌توان ویژگی‌های سطح بالایی از داده‌های آموزشی را استخراج و قدرت تمایز بین دسته‌های مختلف در داده‌ها را افزایش داد.
- برای ارزیابی روش پیشنهادی ۴ پایگاه داده (DB1، DB2، DB3 و DB4) با تعداد داده‌های محدود و کلان به کار گرفته شدند و نتایج عملکرد آنها با سایر رویکردهای یادگیری عمیق و یادگیری ماشین سنتی برای پیش‌بینی رویدادهای شریانی طی چند هفته / ماه قبل از رویداد با استفاده از ۵ دقیقه ثبت ECG و با استخراج ویژگی‌های زمانی و فرکانسی سیگنال‌های ECG مقایسه شدند. نتایج ارزیابی نشان دادند بهترین مدل پیش‌بینی براساس رویکرد LSTM-DBN است که قادر به پیش‌بینی بیماران قلبی با میانگین نرخ‌های صحت، حساسیت و اختصاصی به‌ترتیب ۸۸/۴۲ درصد، ۸۵/۱۳ درصد و ۸۵/۵۴ درصد در ۴ پایگاه داده است. طبقه‌بندی مبتنی بر تغییرات ضربان قلب در مدل پیشنهادی LSTM نسبت به سایر رویکردهای یادگیری عمیق و سنتی مقادیر پیش‌بینی شده بالاتری را نشان می‌دهد. همچنین، می‌توان نتیجه گرفت به کارگیری DBN به‌عنوان روش استخراج ویژگی باعث کاهش زمان‌های آموزش و آزمون سیستم می‌شود؛ در نتیجه، می‌توان گفت ترکیب اندازه‌گیری‌های تغییرات ضربان قلب تجزیه و تحلیل شده با الگوریتم LSTM-DBN، ابزار قابل اعتمادی برای شناسایی بیماران در معرض خطر بالای پیشرفت رویدادهای قلبی و عروقی در آینده است.
- کار آینده روی جمع‌آوری اطلاعات و تجزیه و تحلیل سیستم‌های مراقبت‌های بهداشتی برای توسعه سیستم شناسایی استرس و پیش‌بینی رویدادهای شریانی براساس الگوریتم‌های فراابتکاری برای آموزش شبکه LSTM و همچنین استخراج ویژگی‌های بهینه تمرکز خواهد کرد.
- [1] S. Dami, and M. Yahaghizadeh, "Predicting cardiovascular events with deep learning approach in the context of the internet of things," *Neural Computing and Applications*, Vol. 33, No. 13, pp. 7979-7996, 2021.
 - [2] X. Xie, D. Wu, S. Liu, and R. Li, "Iot data analytics using deep learning," *arXiv preprint arXiv:1708.03854*, 2017.
 - [3] Research on Improved Depth Belief Network-Based Prediction of Cardiovascular Diseases
 - [4] L. Billeci, D. Marino, L. Insana, G. Vatti, and M. Varanini, "Patient-specific seizure prediction based on heart rate variability and recurrence quantification analysis," *PloS one*, Vol. 13, No. 9, p. e0204339, 2018.
 - [5] E. Ebrahimzadeh, M. Pooyan, and A. Bijar, "A novel approach to predict sudden cardiac death (SCD) using nonlinear and time-frequency analyses from HRV signals," *PloS one*, Vol. 9, No. 2, p. e81896, 2014.
 - [6] P. Melillo, R. Izzo, A. Orrico, P. Scala, M. Attanasio, M. Mirra, N. De Luca, and L. Pecchia, "Automatic prediction of cardiovascular and cerebrovascular events using heart rate variability analysis," *PloS one*, Vol. 10, No. 3, p. e0118504, 2015.
 - [7] Q. Jiang, C. Tang, C. Chen, X. Wang, and Q. Huang, "Stock price forecast based on LSTM neural network," in *2018 International Conference on Management Science and Engineering Management*, 2018: pringer International Publishing, pp. 393-408.
 - [8] S. Dami, and M. Esterabi, "Predicting stock returns of Tehran exchange using LSTM neural network and feature engineering technique," *Multimedia Tools and Applications*, Vol. 80, No. 13, pp. 19947-19970, 2021.
 - [9] S. Dami, and M. Yahaghizadeh, "Efficient event prediction in an IOT environment based on LDA model and support vector machine," in *2018 6th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS)*, 2018: IEEE, pp. 135-138.
 - [10] A. Rezaei, S. Dami, and P. Daneshjoo, "Multi-document extractive text summarization via deep learning approach," in *2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI)*, 2019: IEEE, pp. 680-685.
 - [11] V. Shnayder, B. R. Chen, K. Lorincz, T. R. Jones, and M. Welsh, "Sensor networks for medical care," *Harvard computer science technical reports for 205*, TR-08-05, 2005. [Online]. Available: <https://dash.harvard.edu/handle/1/24829604>
 - [12] H. Thapliyal, V. Khalus, and C. Labrado, "Stress detection and management: A survey of wearable smart health devices," *IEEE Consumer Electronics Magazine*, Vol. 6, No. 4, pp. 64-69, 2017.
 - [13] J. Pan, and W. J. Tompkins, "A real-time QRS detection algorithm," *IEEE transactions on biomedical engineering*, Vol. 3, pp. 230-236, 1985.
 - [14] Q. Suo, F. Ma, Y. Yuan, M. Huai, W. Zhong, J. Gao, and A. Zhang, "Deep patient similarity

- networks,” *Journal of Information Science*, Vol. 44, No. 1, pp. 91-109, 2018.
- [17] L. Zhao, Y. Zhou, H. Lu, and H. Fujita, “Parallel computing method of deep belief networks and its application to traffic flow prediction,” *Knowledge-Based Systems*, Vol. 163, pp. 972-987, 2019.
- [18] L. Wang, W. Zhou, Q. Chang, J. Chen, and X. Zhou, “Deep Ensemble Detection of Congestive Heart Failure using Short-term RR Intervals,” *IEEE Access*, Vol. 7, pp. 69559-69574, 2019.
- learning for personalized healthcare,” *IEEE Transactions on Nanobioscience*, Vol. 17, No. 3, pp. 219-227, 2018.
- [15] E. Ebrahimzadeh, and M. Pooyan, “Prediction of sudden cardiac death (SCD) using time-frequency analysis of ECG signals,” *Computational Intelligence in Electrical Engineering*. Vol. 3, No. 4, pp. 15-26, 2013.
- [16] S. Dami, A. A. Barforoush, and H. Shirazi, “News events prediction using Markov logic

¹ Electrocardiogram

² Long-short Term Memory

³ Deep Belief Network

⁴ Electronic Health Records

⁵ Heart Rate Variability

⁶ Fine-tuned threshold

⁷ Lucia Billeci

⁸ Double-cross-validation

⁹ Sudden Cardiac Death

¹⁰ Time-Frequency

¹¹ Multilayer perceptron

¹² Melillo et al., 2015

¹³ Naïve Bayes

¹⁴ Random Forest

¹⁵ Meta-Learning

¹⁶ Jiang et al., 2018

¹⁷ Wireless Body area network

¹⁸ Unit Healthcare Remote

¹⁹ Body Surface Area

²⁰ Body Mass Index

²¹ Systolic Blood Pressure

²² Dyastolic Blood Pressure

²³ Intima Media Thickness

²⁴ Left Ventricular Mass Index

²⁵ Ejection Fraction

²⁶ Restricted Boltzman Machine

²⁷ Bias

²⁸ <https://www.kaggle.com/sulianova/cardiovascular-disease-dataset>

²⁹ <https://archive.physionet.org/pn6/shareedb/?C=D;O=A>

³⁰ <https://archive.ics.uci.edu/ml/datasets/heart+Disease>