

## ارائه‌ی یک سیستم پایش سلامت از راه دور بیماران در محیط اینترنت اشیاء مبتنی بر ابر

سینا دامی<sup>۱\*</sup>، احسان عرب‌قناد<sup>۲</sup>

<sup>۱</sup> استادیار، گروه مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران، ایمیل: [dami@wtiau.ac.ir](mailto:dami@wtiau.ac.ir)

<sup>۲</sup> دانشجوی ارشد، گروه مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران، ایمیل: [ehsanarabghannad@gmail.com](mailto:ehsanarabghannad@gmail.com)

### چکیده

سیستم‌های پایش سلامت، اهمیت ویژه‌ای در پزشکی مدرن امروز دارا هستند و از طرفی آمادگی ذاتی سیستم‌های ابری در پیوند با اینترنت اشیاء می‌تواند به ارتقای کارایی این سیستم‌ها، کمک شایانی نماید. در این مقاله، روشی برای پایش سلامتی بیماران در محیط ابری و اینترنت اشیاء ارائه شده است که مبتنی بر بوسستینگ بوده و از یادگیری عمیق سود می‌جوید. استفاده از بوسستینگ الگوریتم‌های یادگیری عمیق جهت حصول سطوح بالاتری از کارایی در پایش سلامت بیماران از جمله نوآوری‌های این مقاله محسوب می‌گردد. از مجموعه داده‌های پایش سلامتی بیماران در حوزه‌های قلب، ریه، کلیه و مغز استفاده شده است. برای سنجش کارایی روش پیشنهادی آن را با چند روش مطرح دیگر، مورد مقایسه قرار داده و با متریک‌های صحت و سنجش F مورد مقایسه واقع شد. نتایج آزمایشات مختلف نشان داد که روش پیشنهادی در اکثر موارد از سایر روش‌های مورد مقایسه، بهتر عمل کرده و به سطوح بالاتری از کارایی دست یافته است.

**واژه‌های کلیدی:** پایش سلامت بیماران، یادگیری عمیق، بوسستینگ، محیط ابری، اینترنت اشیاء

## ۱. مقدمه

اینترنت اشیاء<sup>۱</sup> (IOT) و تجهیزات هوشمند پزشکی با فراهم نمودن امکان کنترل و غربالگری از راه دور، شرایط سلامتی بیماران را در هر مکان و زمان بهبود بخشیده‌اند. به دلیل افزایش غیرمنتظره و زیاد تعداد بیماران در سالهای اخیر، نظارت پیوسته بر وضعیت سلامتی بیماران قبل از بروز هرگونه اختلال یا عفونت جدی، ضروری است. با توجه به انتقال حجم زیادی از اطلاعات حساس سلامتی مربوط به بیمارانی که نمی‌خواهند اطلاعات پزشکی شخصی آنها فاش شود، مواجهه با مسائل امنیتی داده‌های IOT، هنوز یک مسئله نگران‌کننده و چالش‌برانگیز است. در این پژوهش برای مواجهه با این چالش، یک مدل نظارت از راه دور ارائه شده است که از روشهای یادگیری ماشینی برای پیش‌بینی داده‌های مربوط به سلامتی و پزشکی در محیط IOT استفاده می‌کند. در این مدل، به دلیل اینکه تحلیل اطلاعات حساس بیماران توسط سیستم انجام می‌شود، وضعیت سلامتی آنها از طریق پیش‌بینی شرایط بحرانی و به وسیله روش‌های داده-کاوی برای تحلیل اطلاعات زیستی (حیاتی) توسط تجهیزات هوشمند پزشکی تعیین می‌شود که در آن از یادگیری ماشینی و اینترنت اشیاء در محیط ابری استفاده می‌شود. در این روش، به دلیل منابع محدود در چهارچوب‌های IOT، اثر کارآمد و حیاتی بر این نوع سیستم‌ها دارد. تکنیک‌های داده‌کاوی نقش مهمی در سیستم پزشکی ایفا می‌کند که سهم عمده‌ای در بهبود رشته پزشکی دارد. داده کاوی راه کشف الگوها و دانش معنی‌دار از مقدار زیادی از داده‌ها در پایگاه داده، وب یا داده ذخیره شده در مخازن اطلاعات مختلف است. در بسیاری از زمینه‌های مطالعاتی ضروری است برای کشف اطلاعات پنهان مجموعه داده‌های گسترده که به بیماران کمک می‌کند تا اطلاعات خود را در مدت کوتاهی درک و بازیابی کنند. تکنیک‌های مختلف داده کاوی برای رده‌بندی، پیش‌بینی و خوشه‌بندی اطلاعات برای تصمیم‌گیری درست و دقیق در بسیاری از سازمان‌ها استفاده می‌شود. در مراکز پزشکی (بیمارستان‌ها و یا سایر مراکز بالینی) استفاده از تکنیک‌های داده‌کاوی به درمان بیماران برای شناسایی فرد مبتلا به بیماری و برای تشخیص به موقع خودکار بیماران در نتیجه بازیابی کوتاه مدت کمک می‌کند.

با رشد عظیم حجم داده‌های امروز، نیاز به افزایش اطلاعات معنی‌دار از داده‌ها وجود دارد. داده‌کاوی به این مهم کمک می‌کند و کاربرد آن را در حوزه‌های مختلف متنوعی از جمله فناوری اطلاعات، خرده فروشی، بورس سهام، بانکداری و مراقبت‌های بهداشتی می‌یابد. افزایش جمعیت همراه با رشد بیماری‌ها، مستلزم گنجاندن داده‌کاوی در تشخیص پزشکی برای استخراج الگوی زمینه‌ای است.

از آنجایی که واحدهای مراقبت ویژه (ICUs) نقش افزایش یافته‌ای را در ارائه‌ی مراقبت سلامت بحرانی ایفا می‌کنند، پزشکان باید نیازهای مراقبتی از بیمار را در یک موقعیت خیلی سریع با داده‌های پربار پیش‌بینی کنند. تحلیل داده‌های مراقبت سلامت، یک گام بسیار مهم در بهبود مراقبت سلامت مدرن است و کمک به مراقبت در موقعیت‌های مراقبت واقعی و جمعیت‌های بیمار خواهد کرد. در دسترس‌پذیری گسترده‌ی داده‌های مراقبت سلامت الکترونیک، بررسی‌های جدید در حمایت از تصمیم مبتنی بر شواهد را امکان‌پذیر می‌کند که در آن می‌توانیم یادگیریم بیماران چه زمانی به یک مداخله‌ی معین نیاز دارند. پیش‌بینی مستمر و روبه‌جلوی رویدادها، مخصوصاً در موقعیت‌های مختلف کاربرد دارد که در آن می‌خواهیم نیازهای درحال‌رشد بالینی و اطلاعاتی درطول اقامت بیمار را حساب کنیم. از این رو است که در این مقاله روشی برای یک سیستم پایش سلامت از راه دور بیماران در محیط اینترنت اشیاء مبتنی بر ابر ارائه شده که بتواند بر مشکلات مذکور فایز آید.

## ۲. کارهای مرتبط

با توجه به همه‌گیری ویروس کرونا (COVID-19) جدید و با در نظر گرفتن افزایش جمعیت افراد سالمند و افرادی که دچار بیماری شدید زمینه‌ای بوده و با توجه به هزینه بالای مراقبت از این بیماران، نیاز روزافزون به پایش سلامت از راه دور، تبدیل به یک مسئله حیاتی در زندگی امروزه بشر شده است. پایش آنی بیماران و تحلیل وضعیت سلامتی آنها می‌تواند شرایط حیاتی و غیرعادی را آشکار کند که برای تشخیص زودهنگام هر مورد تهدیدآمیز، بسیار ارزشمند باشد. فناوری‌های اخیر مانند

<sup>1</sup> Internet of Things

تجهیزات اینترنت اشیاء پزشکی در کنار منابع ابری به صورت قابل ملاحظه‌ای در توسعه سیستم‌های پایش پزشکی از راه دور، کمک می‌کنند [۱].

در بیماران مبتلا به COVID-19 جدید، نرخ خارق‌العاده‌ای از بیماری قلبی عروقی<sup>۱</sup> (CVD) وجود دارد و بیش از ۷ درصد بیماران، درگیر آسیب ماهیچه‌های قلب هستند که در اثر عفونت ایجاد شده است (۲۲ درصد بیماران بدحال). وجود COVID-19 جدید، خطر مرگ در بیماران قلبی عروقی (CVD) را بالا برده است [۲]. در [۳] بررسی جامعی در مورد کاربرد سیستم‌های ابری و همچنین مبتنی بر مه در پایش سلامتی بیماران ارائه شده است. بسیاری از مقالاتی که تاکنون چاپ شده‌اند و مقالات مرتبط نشان می‌دهند که دیابت (بیماری قند)، فشار خون بالا و کلسترول (چربی خون) بالا، ارتباط نمایی با شدت بیماری COVID-19 جدید دارد [۴].

تشخیص زود هنگام و پیش‌بینی بیماری شدید و جدی می‌تواند به صورت گسترده‌ای به کاهش فشار سنگین درمانی بر جوامع سالمندی و افراد معلولی که معمولاً در معرض بیماری‌های جدی مانند بیماری قلبی عروقی (CVD)، اختلالات قلبی<sup>۲</sup> (HD)، فشار خون بالا<sup>۳</sup> (HTN)، دیابت<sup>۴</sup> (DM)، چربی خون بالا<sup>۵</sup> (HCLs) یا عفونت‌های مختلف مانند COVID-19 جدید هستند، کمک کند. در چنین شرایطی، استفاده از فناوری‌های رایانه‌ای، با ارائه تصمیمات بهداشتی و پزشکی دقیق و توصیه به درمان‌های به موقع و درمان‌های اولیه ضروری، نقش قابل توجهی دارد [۵].

در سال‌های اخیر، رشد اینترنت اشیاء و فناوری حسگر مرتبط با ابزارهای پزشکی قابل پوشش، کیفیت مراقبت از بیماران را از طریق سیستم‌های پایش سلامت از راه دور هوشمند، بالا برده است [۶]. امروزه، تجهیزات اینترنت اشیاء به صورت گسترده‌ای در سیستم‌های پایش سلامت و پزشکی از راه دور استفاده می‌شوند [۷] ترکیب ابر و IOT مزایای زیادی در جنبه‌های مدیریت منابع مانند توزیع منابع، پردازش قوی، اجتناب از چند بخش شدن داده‌ها در پایگاه‌های داده مختلف و پشتیبانی از قابلیت حرکت کاربر در سیستم‌های پایش دارد [۸]. یک سیستم پایش سلامت از راه دور جدید در محیط IOT ابری شامل مفهومی است که در آن اطلاعات زیستی بیماران به ابرهای داده منتقل شده و ذخیره شده و به اشتراک گذاشته می‌شود تا امکان تحلیل آنها در هر جا و هر زمان فراهم باشد [۹]. به دلیل انتقال اطلاعات پزشکی بیمار از طریق شبکه‌های IOT و ذخیره آنها در ابرها، مسائل مربوط به اطمینان و امنیت، یک نگرانی جدی در این سیستم‌ها است [۱۰]. بنابراین استفاده از شیوه‌های امنیت اطلاعات مانند روش‌های رمزگذاری بلوکی ساده برای منابع IOT پزشکی، یک ضرورت اجتناب ناپذیر می‌باشد که برای مدیریت امن و مطمئن اطلاعات پزشکی و بهداشتی به عنوان مهم‌ترین مسئله در چهارچوب‌های IOT محدود در سیستم‌های حیاتی استفاده می‌گردد [۱۱].

برای کسب اطلاعات تشخیصی به منظور پیش‌بینی تغییرات غیرعادی در سلامت بیماران، روش‌های داده‌کاوی گسترده‌ای در سیستم‌های پایش پزشکی استفاده می‌شوند که شامل روش‌های طبقه‌بندی، دسته‌بندی، شبکه‌های عصبی و سایر روش‌های مبتنی بر شیوه‌های یادگیری ماشینی مختلف است [۱۲].

به‌طور کلی، فرآیند پیش‌بینی بیماری توسط روش‌های بررسی داده به رویکردهای داده‌کاوی، وابسته است. اصولاً، داده‌کاوی شامل وظایف تشخیصی آنومالی (ناهنجاری)، رگرسیون و دسته‌بندی است. همچنین رویکردهای تحلیل داده‌کاوی، مختص آموزش و همین‌طور، یادگیری اصول، خوشه‌بندی و خلاصه‌سازی داده است. از طرف دیگر، رویکردهای داده‌کاوی تشریحی، برای مشخص کردن داده‌ها در مجموعه داده‌های مجزا است. تمامی رویکردهای توضیح داده شده برای شناخت الگوهای داده‌ها در وظایف داده‌کاوی، استفاده شده‌اند. در بسیاری از مقالات و همچنین پژوهش‌های اخیر برای پیش‌بینی تعدادی از بیماری‌ها، داده‌کاوی و رویکردهای یادگیری ماشینی مورد استفاده قرار گرفته‌اند. این رویکردها به‌طور معمول شامل موارد روبرو هستند:

<sup>1</sup> Cardiovascular disease

<sup>2</sup> heart Disorders

<sup>3</sup> Hypertension

<sup>4</sup> Diabetes Mellitus

<sup>5</sup> Hypercholesterolemia

(۱) خلاصه‌سازی آماری داده‌های پزشکی بیماران (۲) یادگیری نظارتی مانند تحلیل رگرسیون، شبکه‌های عصبی و دسته‌بندی خودکار که در سیستم‌های IOT پزشکی به‌طور گسترده استفاده شده است و (۳) یادگیری غیر نظارتی زمانیکه برچسب‌های رده داده‌ها حضور نداشته باشد. به‌طور کلی در این مقالات، برخی از عامل‌های ارزیابی چون صحت، دقت، بازخوانی و سنجش  $F$ ، برای ارزیابی عملکرد فرآیند پیش‌بینی بیماری، در نظر گرفته شده است. به‌طور عادی، مهم‌ترین چالش تکنیک‌های داده کاوی ممکن است مربوط به الگوهای شناختی نامربوط باشد. در نتیجه الگوها باید برای مورد استفاده قرار گرفتن، دقیق باشد. Xu و همکاران (۲۰۲۲) یک چارچوب تشخیص مبتنی بر ناهنجاری برای پیش سلامت بیماران ارائه دادند [۱۳]. نوآوری اصلی در این چارچوب، استفاده از یادگیری فعال و استفاده از الگوریتم AdaBoost است که هدف از آن کاهش کار دستی برچسب زدن و بهبود رده‌بندی الگوهای غیرعادی است. علاوه بر این، مساله رده‌بندی متعصبانه توسط مجموعه داده‌های نامتعادل نیز حل شده است. تبدیل بسته مویک نیز برای استخراج ویژگی‌ها از داده‌های شتاب استفاده شد. این روش‌ها ابتدا به طور دقیق در این پژوهش معرفی شدند و پس از آن دو مورد مطالعاتی به منظور تایید امکان‌سنجی چارچوب پیشنهادی برای تشخیص ناهنجاری داده‌ها مورد بررسی قرار گرفتند. اولین مورد، یک سری داده‌ها با بی‌قاعدگی‌ها از نظر سنتزی به داده‌های تاریخیچه زمان شتاب اضافه شده است که در آزمون‌های دینامیک ساختار شبکه، از جمله پنج نوع ناهنجاری از داده‌ها اندازه‌گیری می‌شوند. هر دو مجموعه داده‌های متوازن و نامتعادل مورد مطالعه و تجزیه و تحلیل قرار گرفتند، که در آن یک مطالعه تطبیقی بین الگوریتم‌های مختلف مبتنی بر نمونه‌گیری با همان آموزش و آزمایش انجام شد. نتایج نشان داد که AdaBoost در هر دو سناریو با دقت بالاتر و سرعت هم‌گرایی سریع‌تر عملکرد بهتری داشته‌است. مطالعه‌ی دیگری با پرس‌وجوهای انجام گرفته بر روی داده‌های شتاب با تنها مقدار محدودی از مجموعه آموزشی نشان داد که چارچوب پیشنهادی می‌تواند ۹۷.۹۵ درصد الگوهای ناهنجار مجموعه آزمون را شناسایی کرده و رده‌بندی کند که پتانسیل بالایی برای کاربرد بیشتر و گسترده‌تر در زمینه پردازش داده‌ها نشان می‌دهد.

### ۳. روش پیشنهادی

نمودار شکل ۱، گام‌های انجام پژوهش را نشان می‌دهد. در بخش پیش پردازش، ابتدا داده‌های ورودی به سیستم، مورد پردازش اولیه قرار می‌گیرند و مقادیر ویژگی‌ها نرمال‌سازی می‌شوند. سپس برای اینکه محاسبات را دقیق‌تر کنیم و زمان محاسبات نیز کاهش یابد اقدام به کاهش تعداد ابعاد داده‌های ورودی با شبکه باور عمیق<sup>۱</sup> (DBN) خواهیم نمود تا ویژگی‌هایی که اضافی هستند و در محاسبات مورد نیاز نیستند حذف شوند و تنها ویژگی‌هایی از داده‌های ورودی باقی بمانند که در انجام محاسبات موثر هستند. حال با استفاده از داده‌های آموزشی، اقدام به آموزش سیستم می‌کنیم و بدین‌صورت سیستم، الگوی وضعیت بیمار را برحسب ویژه‌گی‌های ورودی، یاد می‌گیرد. به این صورت، مدل نیز تشکیل می‌شود که این مدل در واقع اساس پیش‌بینی خواهد بود. در مرحله بعد با استفاده از مدل یادگیرنده‌ای که در بخش قبل ساختیم می‌توانیم تشخیص وضعیت بیمار را به سیستم برحسب داده‌های ورودی، انجام دهیم. برای تدقیق جواب‌های حاصله از دو شبکه عصبی CNN و LSTM استفاده کرده و نتایج آنها را در قالب بوستینگ با هم ترکیب می‌کنیم. در پایان با توجه به خروجی‌های سیستم در تشخیص وضعیت بیمار، ارزیابی می‌کنیم که تشخیص وضعیت بیمار به چه میزان بطور صحیح انجام شده است و دقت را بدست خواهیم آورد.

<sup>۱</sup> Deep belief network



شکل ۱- فرآیند انجام پژوهش

### ۱.۳. پیش پردازش داده‌ها

مجموعه داده‌ها دارای ویژگی‌های بسیار زیادی با مقادیر مختلف از مقادیر است. پردازش اطلاعات مستقیماً زمان‌گیر است و طبقه‌بندی ممکن است دقیق نباشد. از این رو بسته‌های داده قبل از کاهش بعدی، یک فرآیند نرمال سازی را متحمل می‌شوند. بسیاری از روش‌ها برای نرمال سازی موجود هستند. رایج‌ترین روش مورد استفاده Z - امتیاز، نرمال سازی کمینه - بیشینه و مقیاس بندی دهمی است. تکنیک نمره Z برای مدل پیشنهادی انتخاب شده است چون ساده‌ترین تکنیک نرمال سازی است. این روش محدوده (حداکثر و حداقل) را حفظ کرده و پراکندگی سری‌های (انحراف استاندارد/ واریانس) را معرفی می‌کند. نمره Z به صورت خطی داده‌ها را به چنین روشی تبدیل می‌کند، که مقدار متوسط داده‌های تغییر یافته برابر با صفر است در حالی که انحراف استاندارد آن‌ها برابر با ۱ است. مقادیر تبدیل شده خودشان در یک فاصله خاص مثل [۰، ۱] یا غیره قرار نمی‌گیرند.

### ۲.۳. انتخاب ویژگی‌ها با استفاده از شبکه باور عمیق

ایده اصلی آموزش شبکه‌های باور عمیق، با آموزش دوره‌ای ماشین‌های بولتزمن محدود<sup>۱</sup> (RBM) این است که پارامترهای مدل  $\theta$ ، که توسط RAM یادگرفته می‌شود و برای هر دو  $p(v|h, \theta)$  و توزیع اولیه در بردارهای خروجی لایه مخفی  $p(h|\theta)$  توزیع داده می‌شود. بعد از یادگیری پارامتر  $\theta$  و  $p(v|h, \theta)$  حال،  $P(h|\theta)$  را می‌توان به وسیله یک مدل بهبود یافته که با استفاده از بردارهای فعالیت پنهان  $H = h$  به عنوان داده‌های آموزشی لایه قابل مشاهده آموزش داده شده است را برای سایر RAM جایگزین کرد. این جایگزینی یک تغییر دسته پایین‌تر را روی احتمال داده‌های آموزشی بحث مدل کامپوزیت را بهبود می‌بخشد. این سه قانون در این مرحله لحاظ می‌شوند:

- اگر تعداد واحدهای پنهان در سطح بالا از یک آستانه پیش از تعریف عبور کند؛ ضرورتاً عملکرد در اطراف دقت مشخصی کاهش می‌یابد.

<sup>1</sup> Restricted Boltzmann machines

▪ عملکرد با افزایش تعداد لایه‌ها کاهش می‌یابد.

▪ همانطور که ما هر RBM را برای افزایش تعداد تعاملات آموزش می‌دهیم، عملکرد افزایش می‌یابد.

براساس مطالعات تجربی DBN، می‌توان آن را به عنوان یک روش استخراج ویژگی برای کاهش ابعاد، در صورت عدم استفاده از برچسب‌های کلاس و انتشار عقب در معماری DBN (آموزش بی نظم) به کاربرد (Hinton, 2006). از سوی دیگر، هنگام اتصال برچسب‌های کلاس با بردارهای ویژگی، DBN برای طبقه بندی استفاده می‌شود. دو نوع کلی از معماری طبقه بندی DBN وجود دارد که عبارتند از: انتشار عقب DBN (BP – DBN) و حافظه DBN (AM – DBN) (Marchette, 1999) برای هر دو معماری، زمانی که تعداد کلاس‌های احتمالی بسیار بزرگ است و توزیع فرکانس‌ها برای کلاس‌های مختلف یکنواخت نیست. ممکن است گاهی اوقات مفید باشد برای استفاده از کدگذاری‌های مختلف برای اهداف کلاس از کدگذاری نرم افزار استاندارد K استفاده شود.

شبکه باور عمیق (DBN) یک مدل شبکه عصبی عمیق است که توسط انباشته‌سازی RBM‌ها شکل گرفته و خروجی RBM به ورودی RBM بعدی متصل است. داده‌ها از طریق RBM پایینی به شبکه وارد شده و دو لایه‌ی بالا یک اتصال دوتایی است، بقیه لایه‌ها یک اتصال یک جهته است، DBM یک مدل گرافیکی بی جهت بوده و هیچ ارتباطی بین واحدهای یک لایه وجود ندارد ولی بین واحدهای ورودی و واحدهای پنهان وجود دارد. ساختار DBN از ماشین بولتزمن (BM) عمومی الهام گرفته شده که عبارت است از شبکه‌ای از واحدهای مبتنی بر تصمیمات احتمالی جهت تعیین حالت‌های فعال و غیرفعال‌شان. آموزش الگوریتم BM آسان است ولی در فرایند کند نمایش داده می‌شود. کاهش تعداد لایه‌های پنهان یک DBM به یک ماشین بولتزمن محدود (RBM) را ایجاد می‌کند. DBM در هنگامی که با منبع داده بزرگ بدون برچسب آموزش داده شود و با داده‌های برچسب دار خوب تنظیم می‌شود به عنوان یک دسته‌بندی کننده خوب عمل می‌کند. آموزش پشته‌ای از RBM‌ها و لایه‌های پنهان بسیار با استفاده از فعال‌سازی ویژگی روی یک RBM به عنوان ورودی برای لایه بعدی منجر به تشکیل شبکه باور عمیق (DBN) می‌شود.

### ۳.۳. تشخیص وضعیت بیمار با استفاده از CNN


شبکه عصبی کانولوشن<sup>۱</sup> (CNN) رده‌ای از شبکه‌های عصبی عمیق<sup>۲</sup> (DNN) هستند که به منظور کمینه کردن پیش‌پردازش‌ها از گونه‌ای از پرسپترون‌های چندلایه<sup>۳</sup> (MLP) استفاده می‌کنند. یک شبکه عصبی عمیق می‌تواند در قالب تلفیقی از مدل‌های ساده و غیرنظارتی نظیر ماشین‌های محدود شده بولتزمن (RBM) انگاشته شود، در شرایطی که هر RBM و لایه مخفی آن در قالب لایه مشهود برای RBM بعدی بکار گرفته می‌شود. یک RBM می‌تواند یک گراف دوطرفه از دو لایه نوروئی باشد: لایه مشهود و پنهان؛ ارتباطات بین نوروئ‌ها در یک لایه مجاز نیست.

ساختار شبکه‌های کانولوشن از فرایندهای زیستی قشر بینایی گریه الهام گرفته شده است. این ساختار به گونه‌ای است که تک‌نوروئ‌ها تنها در یک ناحیه محدود به تحریک پاسخ می‌دهند که به آن ناحیه پذیرش گفته می‌شود. نواحی پذیرش نوروئ‌های مختلف به صورت جزئی با هم هم‌پوشانی دارند به گونه‌ای که کل میدان دید را پوشش می‌دهند. شکل ۲، ساختار یک شبکه عصبی کانولوشن را نشان می‌دهد.

<sup>1</sup> Convolutional neural network

<sup>2</sup> Deep neural network

<sup>3</sup> Multilayer perceptron



شکل ۲- ساختار شبکه عصبی کانولوشن

همان‌طور که قابل مشاهده است، یک شبکه عصبی کانولوشن از یک لایه ورودی، یک لایه خروجی و تعدادی لایه پنهان تشکیل شده است. لایه‌های پنهان یا کانولوشن هستند، یا تجمعی یا کامل.

**لایه‌های کانولوشن:** این لایه یک عمل کانوال را روی ورودی اعمال می‌کند، سپس نتیجه را به لایه بعدی می‌دهند. این کانوال در واقع پاسخ یک تک‌نورون را به یک تحریک دیداری شبیه‌سازی می‌کند. هر نورون کانولوشن داده‌ها را تنها برای ناحیه پذیرش خودش پردازش می‌کند. مشبک کردن به شبکه‌های کانولوشن این اجازه را می‌دهد که انتقال، دوران یا اعوجاج ورودی را تصحیح کنند.

**لایه‌های تجمعی:** شبکه‌های عصبی کانولوشن ممکن است شامل لایه‌های تجمعی محلی یا سراسری باشند که خروجی‌های خوشه‌های نورونی در یک لایه را در یک تک‌نورون در لایه بعدی ترکیب می‌کند. به عنوان مثال روش حداکثر تجمع<sup>۱</sup> حداکثر مقدار بین خوشه‌های نورونی در لایه پیشین استفاده می‌کند. مثال دیگر میانگین تجمع<sup>۲</sup> است که از مقدار میانگین خوشه‌های نورونی در لایه پیشین استفاده می‌کند.

**لایه‌های کاملاً همبند:** هر نورون در یک لایه را به هر نورون در لایه دیگر متصل می‌کنند. این رویکرد در اصل مشابه کاری است که در شبکه عصبی پرسپترون چند لایه (MLP) انجام می‌شود.

برای دنبال نمودن چنین سیستم چندلایه‌ای، فرد نیازمند محاسبه گرادیانت تابع E کل انرژی در خصوص وزن در تمامی لایه‌ها خواهد بود. برای درک این اوزان و بیشینه نمودن تابع انرژی جهانی، رویکرد واگرایی متعارف احتمال بیشینه تقریبی نیاز است. این متد می‌تواند هر نمونه ترتیبی را برای مقدمه سازی لایه مشهود بکار ببرد. سپس از الگوریتم نمونه سازی گیبز برای بروز رسانی لایه مخفی و نیز بازسازی لایه مشهود تا زمان رویداد همگرایی استفاده می‌گردد. به عنوان یک نمونه می‌توان مدل رگرسیون لجستیک را برای درک نورن‌های دوگانه مخفی در نظر داشت. هر نورون مشهود را می‌توان نمونه‌ای از توزیع نرمال دانست. وضعیت مستمر  $z_j^h$  از نورون مخفی  $j$ ، با جهت گیری  $b_j$  یک مجموعه محاسبه شده بر تمامی نورون‌های مشهود مستمر است.

$$h_j = b_j + \sum_i v_i w_{ij}$$

<sup>1</sup> Max pooling

<sup>2</sup> Average pooling

در شرایطی که  $w_{ij}$  ارزش ارتباط موجود از نورون مشخص  $v_i$  تا نورون مخفی  $j$  محسوب می شود. موضع دوگانه  $h_j$  از نورون مخفی را می توان با تابع فعال سازی سیگموید تبیین کرد.


$$h_j = \frac{1}{1 + e^{-h_j}}$$

### ۴.۳. تشخیص وضعیت بیمار با استفاده از LSTM


در پردازش زبان طبیعی، تعداد زیادی از متن های بدون برچسب وجود دارد. زمانی که کامپیوترها متن را پردازش می کنند، تبدیل متن به یک فرمتی که کامپیوتر بفهمد بسیار ضروری است. بنابراین محققان "بردار کلمه" را پیشنهاد دادند که از یک سری از اعداد برای بیان کلمه استفاده می کند. ساده ترین روش بردار one-hot است که موقعیتی که کلمه به عنوان ۱ ظاهر می شود را بیان می کند و بقیه به عنوان ۰ مطرح می شود. اما این روش دو عیب اصلی دارد:

۱- بعد بردار کلمه مساوی با سایز دیکشنری است. اما سایز دیکشنری بسیار بزرگ است که بعد بردار بزرگ می شود و در نتیجه محاسبه را سخت می نماید.

۲- این بیان نمی تواند شباهت بین کلمات را برگشت دهد بنابراین این عمل به پردازش متن و تحلیل معنایی<sup>۱</sup> متن هیچ کمکی نمی کند.



شکل ۳- مدل زبان مبتنی بر شبکه عصبی بازگشتی (RNN)



شکل ۴- ساختار RNN لایه ویژگی

<sup>1</sup> semantic



جهت استخراج کامل اطلاعات از کپسول<sup>۱</sup>، محققان روش‌های یادگیری ماشین جدید که اساسا شامل RBM هستند و شبکه عصبی و ارتباط بین متن و کلمه را معرفی نمودند.

برای مدل زبان خاص، با دنباله کلمه  $(w_1, w_2, \dots, w_T)$ ، دنباله لایه مخفی  $(h_1, h_2, \dots, h_T)$  و دنباله لایه خروجی  $(y_1, y_2, \dots, y_T)$  در RNN در رابطه (۱) توصیف شده است:

$$h_t = \tanh(Ww_t + Uh_{t-1} + b_h)$$

$$y_t = Ah_t + b_y$$

در شکل قبل،  $w_t$  یک بردار one-hot کلمه  $t$  است و  $\theta = \{b_h, b_y, W, U, A\}$  مجموعه ای از پارامترهای یادگیری است. بردار ادغام شده کلمه یک ماتریس  $W$  است. اما RNN در پردازش یادگیری برای از بین بردن گرادین می‌باشد. بدین دلیل مدل گسترده شده RNN پیشنهاد شده است که یک لایه ویژگی به ساختار اصلی اضافه شده است. این ساختار در شکل قبل نشان داده شده است.

در شکل قبل لایه مخفی به صورت زیر بیان می‌شود:

$$h_t = \tanh(Ww_t + Uh_{t-1} + Ff(t) + b_h)$$

زمانی که لایه ویژگی  $f(t)$  اضافه شد، اطلاعات تلفات به صفر کاهش نمی یابد و از مساله از بین رفتن گرادین جلوگیری می‌کند.

از شبکه‌های حافظه‌ی کوتاه‌مدت طولانی (LSTM) به‌عنوان بخشی از مدل خود استفاده می‌کنیم. پس از دیدن توالی ورودی  $x_1 \dots x_t$  یک نمونه‌ی معین،  $\hat{y}_t$ ، یک توزیع احتمال در نتایج، با نتیجه‌ی خروجی  $y_t$  را پیش‌بینی می‌کنیم:

$$h_1 \dots h_t = LSTM(x_1 \dots x_t)$$

$$y_t = \text{softmax}(Wyht + b_y)$$

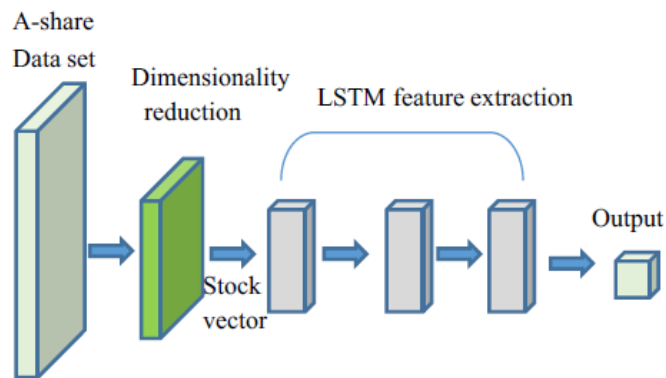
که در آن  $b_y \in R^{N_c}$ ،  $W_y \in R^{N_c \times L_2}$ ،  $x_i \in R^V$  که در آن  $V$  ابعاد ورودی (تعداد متغیرها)،  $N_c$  تعداد کلاس‌هایی است که پیش‌بینی می‌کنیم و  $L_2$  اندازه‌ی لایه‌ی پنهان دوم است. برای یک مدل الگووار، شکل بعد را ببینید و برای جزئیات بیشتر درمورد پیاده‌سازی مدل، ضمیمه را ببینید.

در مدل زمان بندی بالا، ماژول اصلی شبکه LSTM است.

۱- گام اول در LSTM ما تصمیم گرفتیم در اطلاعاتی که از حالت سلولی عبور می کند می‌باشد:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f)$$

<sup>1</sup> corpus



شکل ۵-دیاگرام ساختار شبکه LSTM

۲- گام بعدی تصمیم گیری در مورد اطلاعات جدیدی است که باید در حالت سلول ذخیره شود:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

۳) الان زمان آن رسیده است تا حالت سلول قدیمی در یک حالت سلول قدیمی به روز رسانی شود. گام‌های قبلی اخیراً تصمیم گرفتند تا چه کار انجام دهند. ما فقط نیاز به انجام واقعی آن داریم.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

۴) سرانجام، ما نیاز به تصمیم گیری در مورد خروجی مورد نیاز، داریم. این خروجی مبتنی بر حالت سلول ما خواهد بود. اما یک نسخه فیلتر شده خواهد بود.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

### ۵.۳. تشخیص وضعیت بیمار تقویت شده با ADABOOST

بوستینگ یک فرا-الگوریتم ترکیبی در حوزه یادگیری ماشینی است که برای کاستن عدم توازن و همچنین واریانس بکار می‌رود. این روش در یادگیری نظارت شده مورد استفاده است و از رده الگوریتم‌های یادگیری ماشینی بشمار می‌رود و روشی برای تبدیل سیستم‌های یادگیری ضعیف‌تر به قوی‌تر بر اساس ترکیب نتایج رده‌بندی‌های متفاوت است. هرچند که بوستینگ در قالب الگوریتمیک قرار ندارد ولی بشیر الگوریتم‌هایی که مبتنی بر بوستینگ طراحی می‌شوند، یادگیرنده‌های ضعیف‌تر را در صورت تکرار شونده آموزش داده و به مجموعه قبلی اضافه می‌کنند تا در نهایت به یک رده‌بند قوی‌تر دست یابد. یادگیرنده‌های ضعیف‌تر در حین اضافه شدن به مجموعه، وزن‌دهی می‌شوند و این وزن‌دهی عموماً براساس میزان دقت در رده‌بندی نمونه‌ها است. پس از اضافه شدن هر رده‌بند، داده‌ها نیز وزن‌دهی می‌شوند (اصلاح وزن مربوطه). وزن‌دهی داده‌ها بصورتی است که در هر گام، وزن داده‌هایی که بصورت درست رده‌بندی شده‌اند، کاهش یافته و وزن داده‌هایی که بدرستی رده‌بندی نشده‌اند نیز بیشتر می‌شود تا در گام‌های بعدی (توسط یادگیرنده‌های جدید) بیشتر مورد توجه بوده و با دقت بیشتری رده‌بندی شوند. بنابراین تمرکز یادگیرنده‌های جدید، اکثراً بر روی داده‌هایی خواهد بود که سیستم در مراحل قبلی قادر به رده‌بندی درست آنها نبوده است.

تاکنون الگوریتم‌های بوستینگ متعددی بوجود آمده است ولی نسخه اصلی این الگوریتم‌ها توسط Robert Schapire و Yoav Freund ارائه شده که Adaptive نبوده و امکان استفاده کامل از مزایای یادگیرنده‌های متعدد را ندارد. بعدها این دو نفر الگوریتم AdaBoost که یک الگوریتم بوستینگ سازگار<sup>۱</sup> بود را ارائه کردند و جایزه معتبر گودل را برنده شدند. آدابوست مخفف بوستینگ تطبیقی است و یک الگوریتم یادگیری ماشینی است که توسط یاو فروند و رابرت شاپیر ابداع شده است. در واقع آدابوست یک ابر الگوریتم است که به منظور ارتقای عملکرد و رفع مشکلات رده‌های نامتوزان همراه دیگر الگوریتم‌های یادگیری استفاده دارد. در این الگوریتم، رده‌بند هر مرحله جدید به نفع نمونه‌های نادرست رده‌بندی شده در مراحل قبل تنظیم می‌گردد. آدابوست نسبت به داده‌های نویزی و پرت حساس بوده ولی نسبت به مشکل بیش برزش از بیشتر الگوریتم‌های یادگیری برتری محسوسی دارد. رده‌بند پایه که در اینجا استفاده می‌شود فقط کافی است از رده‌بند تصادفی به میزان ۵۰٪ بهتر باشد و بدین ترتیب بهبود عملکرد الگوریتم با تکرارهای بیشتر بهبود خواهد یافت. حتی رده‌بندهای با خطاهای بالاتر از تصادفی با گرفتن ضریب منفی عملکرد کلی را بهبود می‌بخشند. در الگوریتم آدابوست در هر دور  $t = 1, \dots$  یک طبقه بند ضعیف اضافه می‌شود. در هر فراخوانی بر اساس اهمیت نمونه‌ها، وزن‌ها به روز می‌شوند. در هر دور، وزن نمونه‌های نادرست رده‌بندی شده افزایش یافته و وزن نمونه‌های درست رده‌بندی شده کاهش داده می‌شود و بنابراین رده‌بند جدید تمرکز بر نمونه‌هایی که سخت‌تر یادگرفته می‌شوند، خواهند داشت.

#### ۴. نتایج تجربی

در این بخش به بررسی نتایج آزمایشگاهی حاصله از روش پیشنهادی پرداخته می‌شود. ابتدا در مورد مجموعه داده‌ها صحبت می‌شود. در ادامه به آرایه معیارهای ارزیابی پرداخته می‌شود. در نهایت به بررسی و تحلیل نتایج پرداخته خواهد شد.

##### ۱.۴. مجموعه داده‌ها

داده‌های بیماران در ابر، توسط، روش‌های دسته‌بندی تحلیل می‌گردد. هدف اصلی، پیش‌بینی وضعیت سلامت بیماران برای شناخت HCLS و عوارض آن چون HTN و سطوح شدت آن و HD با به‌کارگیری روش‌های داده کاوی در داده‌های پزشکی بیماران است. در اینجا، هدف اصلی این است که بیماران می‌توانند با توجه به شدت HCLS، HTN و HD، توسط روش‌های رده‌بندی، دسته‌بندی گردند. ترکیبات مختلف اختلالات، شامل هیپرکلسترولمی (HCLS)، افزایش فشار خون (HTN) و سطح شدت آنها است (HTN1: پیش فشار خون؛ HTN2: مرحله ۱ از فشار خون؛ HTN3: مرحله ۲ از فشار خون؛ HTN4: مرحله بحرانی از فشار خون) و همچنین بیماری قلبی (HD) که در جدول زیر نشان داده شده است.

جدول ۱- ترکیب بیماری‌های در نظر گرفته شده

شماره بیماری	نوع بیماری
1	هیچیک
2	HCLS
3	HCLS, HTN1
4	HCLS, HTN2
5	HCLS, HTN3
6	HCLS, HTN4
7	HCLS, HD
8	HCLS, HTN1, HD
9	HCLS, HTN2, HD
10	HCLS, HTN3, HD
11	HCLS, HTN4, HD

<sup>1</sup> Adaptive

در مدل پایش سلامت پیشنهادی، برخی شیوه‌های دسته‌بندی بر روی نمونه‌های جمع‌آوری شده اعمال می‌شود. علائم حیاتی مورد نیاز برای همه نمونه‌ها توسط حسگرهای پزشکی IOT جمع‌آوری می‌شود و همچنین اطلاعات شناسایی و بالینی باید توسط حسگرهای IOT وارد شوند. خواص اطلاعات اصلی در ستون‌های اول تا چهارم جدول زیر ارائه شده‌اند که برای فرایند پیش‌بینی از بین همه نمونه‌ها مورد نیاز است. ستون ۵ شامل ترکیب‌های به دست‌آمده برای بیماری‌های پیش‌بینی شده است که شامل عادی؛ فقط چربی خون بالا؛ ترکیب چربی خون بالا و بیماری قلبی، ترکیب چربی خون بالا و فشار خون بالا؛ ترکیب چربی خون بالا، بیماری قلبی و فشار خون بالا است. از مجموعه داده‌های مذکور به تعداد ۴ زیر مجموعه به شرح زیر را برای این پژوهش در نظر گرفتیم.

جدول ۲- مجموعه داده‌های منتخب

نام مجموعه داده	علامت اختصاری
قلبی	HR
کلیوی	KD
ریوی	LG
مغزی	BR
نام مجموعه داده	علامت اختصاری

#### ۲.۴. معیارهای ارزیابی

برای ارزیابی موثر بودن فرآیند پیش‌بینی بیماری، چهار پارامتر محاسبه می‌گردد که شامل دقت، درستی، بازخوانی و سنجش  $F$  ( $F$ -score) است. برای بدست آوردن این عامل‌ها، ماتریس درهم ریختگی، در دسته‌بندی کننده‌های یادگیری ماشین مورد استفاده قرار می‌گیرد. ماتریس درهم ریختگی شامل نمونه‌هایی می‌شود که چهار مجموعه را دارند: TP که بعنوان نمونه‌های غیر عادی در نظر گرفته شده و به‌طور صحیح دسته‌بندی شده است. TN که بعنوان موارد نرمال نشان داده شده و به‌طور صحیح دسته‌بندی شده است. FP که بعنوان نمونه‌های غیر عادی معین شده و به‌طور غلط دسته‌بندی شده است. FN که بعنوان موارد نرمال مشخص شده و به‌طور غلط دسته‌بندی شده است. شاخص‌های ارزیابی با توضیحات‌شان و معادلات مربوطه مبتنی بر مجموعه‌های TP، TN، FP و FN به‌صورت زیر هستند.


- معیار صحت توسط رابطه  $\frac{TP+TN}{TP+TN+FP+FN}$  محاسبه می‌شود که مقدار دقت موارد پیش‌بینی شده درست را بعنوان مورد سلامتی یا غیر عادی بودن، نشان می‌دهد.
- معیار دقت توسط رابطه  $\frac{TP}{TP+FP}$  محاسبه می‌شود که مقدار پیش‌بینی مثبت را تعریف می‌کند و سهم نمونه‌های غیر عادی را در میان تمام نمونه‌ها نشان می‌دهد.
- معیار بازخوانی توسط رابطه  $\frac{TP}{TP+FN}$  محاسبه می‌گردد که سهم موارد غیر عادی را نشان می‌دهد که در تمامی نمونه‌های غیرعادی بدست آمده است.

$$2 \times \frac{\text{بازخوانی} \times \text{دستی}}{\text{دستی} + \text{بازخوانی}}$$

- معیار  $F$  توسط رابطه بدست می‌آید که عملکرد را توسط ترکیب دستی و مقدار بازخوانی نشان می‌دهد.


### ۳.۴. تحلیل نتایج حاصله

جهت ارزیابی نتایج روش پیشنهادی، آن را با روشهای مبتنی بر CNN، LSTM و RNN-GRU مقایسه کرده‌ایم. در ابتدا آزمایشاتی انجام شد مشخص شود روش پیشنهادی در مقایسه با سایر روش‌های مورد مقایسه به افزایش تعداد داده‌ها چه رفتاری از خودشان نشان می‌دهند. بنابراین داده‌های مربوط به بیماریهای قلبی را به ۵ بخش تقریباً مساوی تقسیم کردیم و به این ابتدا با یک پنجم داده‌ها، سپس با دو پنجم و همینطور تا داده‌های کامل بیماریهای قلبی با متریک صحت آزمودیم. شکل ۶، نمایش دهنده نحوه عملکرد روشهای مورد مقایسه است.




شکل ۶- میزان صحت حاصله به ازای رشد حجم داده‌ها

همانگونه که در شکل ۶ مشخص است، روش پیشنهادی با داده‌های حجم کمتر در میانه روش‌های مورد مقایسه عمل کرده ولی با افزایش حجم داده‌ها به مرور، عملکرد بهتری را از خود نشان داده و با افزایش حجم داده‌ها به وضوح عملکرد بهتری را از خود به نمایش گذاشته است. شکل ۷، عملکرد مقایسه‌ای روش پیشنهادی را نسبت به سایر روش‌های مورد مقایسه برحسب معیار صحت نمایش می‌دهد.



شکل ۷- مقایسه معیار صحت تشخیص بیماری‌ها به تفکیک انواع بیماری‌ها برای روش‌های مختلف

برای داده‌های HR روش پیشنهادی عملکرد مطلوبی را به نمایش گذاشته است و روش مبتنی بر CNN با فاصله از آن قرار دارد. در داده‌های KD روش پیشنهادی و روش مبتنی بر LSTM بسیار نزدیک به هم عمل کرده‌اند و روش پیشنهادی به میزان جزیی از روش مبتنی بر LSTM بهتر عمل کرده و سایر روش‌ها نیز نسبتاً با این دو روش دارای فاصله هستند. در داده‌های LG روش‌های مورد مقایسه همگی عملکرد مطلوبی داشته‌اند ولی روش پیشنهادی به میزان جزیی از سایر روش‌ها ضعیف‌تر عمل کرده است. در داده‌های BR روش پیشنهادی با فاصله قابل توجه از سایر روش‌های مورد مقایسه بهتر عمل کرده است. شکل ۸، عملکرد مقایسه‌ای روش پیشنهادی را نسبت به سایر روش‌های مورد مقایسه برحسب معیار  $F$  نمایش می‌دهد.



شکل ۸- مقایسه معیار F تشخیص بیماری‌ها به تفکیک انواع بیماری‌ها برای روش‌های مختلف

در سنجشی که با معیار  $F$  انجام شد، روش پیشنهادی در مجموعه داده‌های HR با فاصله از بقیه روش‌های مورد مقایسه بهتر عمل کرده است. در مجموعه های KD روش پیشنهادی با روش مبتنی بر LSTM بهترین عملکرد را داشته‌اند و روش پیشنهادی نسبت به روش مبتنی بر LSTM به میزان جزئی بهتر عمل کرده است. در مجموعه داده‌های LG روش پیشنهادی عملکرد مطلوبی نداشته و از سایر روش‌های مورد مقایسه ضعیف‌تر عمل کرده است. در مجموعه داده‌های BR نیز روش پیشنهادی با فاصله بسیار زیاد، بهتر از سایر روش‌های مورد مقایسه عمل کرده است.

##### ۵. نتیجه‌گیری و پیشنهادات

مواجهه با مسائل مرتبط با داده‌های اینترنت اشیاء هنوز یک مسئله مهم و چالش‌برانگیز است. پیش‌بینی مستمر و روبه‌جلوی رویدادها، بخصوص در موقعیت‌های مختلف کاربرد دارد که در آن می‌خواهیم نیازهای درحال‌رشد بالینی و اطلاعاتی درطول اقامت بیمار را تجزیه و تحلیل کنیم. در این پژوهش برای مواجهه با این چالش، یک مدل پایش از راه دور ارائه شده است که از

روش‌های یادگیری ماشین برای پیش‌بینی داده‌های مربوط به سلامتی و پزشکی در محیط اینترنت اشیاء استفاده می‌کند. برای این منظور از یک شبکه باور عمیق (DBN) جهت استخراج ویژگی‌ها و کاهش ابعاد داده‌های ورودی بهره برده‌ایم. سپس از دو شبکه عصبی CNN و LSTM استفاده کرده و نتایج آنها را در قالب بوستینگ با هم ترکیب نمودیم.

داده‌های بیماران در ابر، توسط روش‌های دسته‌بندی تحلیل می‌گردد. هدف اصلی، پیش‌بینی وضعیت سلامت بیماران برای شناخت HCLS و عوارض آن چون HTN و سطوح شدت آن و HD با به‌کارگیری روش‌های داده کاوی در داده‌های پزشکی بیماران است. از مجموعه داده‌های مذکور به تعداد ۴ زیر مجموعه برای این پژوهش در نظر گرفتیم. جهت ارزیابی نتایج روش پیشنهادی، آن را با روش‌های مبتنی بر CNN، LSTM، و RNN-GRU مقایسه کرده‌ایم. ابتدا در مجموعه داده‌های قلبی با یک روند افزایشی اقدام به مقایسه نتایج روش‌های مورد مقایسه کردیم و مشخص شد که با افزایش روند افزایش داده‌ها، کارایی روش پیشنهادی نیز نسبت به سایر روش‌های مورد مقایسه برتری می‌یابد. در مجموعه آزمایشاتی که با ۴ مجموعه داده مذکور انجام شد و با متریک‌های صحت و معیار  $F$  مورد مقایسه واقع شد، مشخص شد روش‌های پیشنهادی از بسیاری موارد نسبت به روش‌های مورد مقایسه عملکرد بهتری را حاصل نموده است.

یکی از موارد توسعه روش پیشنهادی این است که روش بوستینگ با ترکیب سایر روش‌های یادگیری عمیق و/یا یادگیری سنتی مورد آزمایش قرار بگیرد. از جمله موارد دیگر در توسعه روش پیشنهادی می‌توان به تطبیق آن در جهت کار با کلان داده‌ها اشاره نمود.

## مراجع

1. Chatzinikolaou T, Vogiatzi E, Kousis A, Tjortjis C. Smart Healthcare Support Using Data Mining and Machine Learning. In IOT and WSN based Smart Cities: A Machine Learning Perspective 2022 (pp. 27-48). Springer, Cham.
2. Kuruba C, Pushpalatha N, Ramu G, Suneetha I, Kumar MR, Harish P. Data mining and deep learning-based hybrid health care application. Applied Nanoscience. 2022 Feb 6:1-7.
3. Kaur N, Mittal A, Kumar A, Kumar R. Healthcare Monitoring Through Fog Computing: A Survey. ECS Transactions. 2022 Apr 24;107(1):7689..
4. Hudson J. Internet of Medical Things-driven Remote Monitoring Systems, Big Healthcare Data Analytics, and Wireless Body Area Networks in COVID-19 Detection and Diagnosis. American Journal of Medical Research. 2022;9(1):81-96.
5. Jenkins T. Wearable Medical Sensor Devices, Machine and Deep Learning Algorithms, and Internet of Things-based Healthcare Systems in COVID-19 Patient Screening, Diagnosis, Monitoring, and Treatment. American Journal of Medical Research. 2022;9(1):49-64.
6. Al-Turjman F (2020) Intelligence and security in big 5G-oriented IoNT: an overview- Futur Gener Comput Syst 102:357–368
7. Hosseinzadeh M, Koochpayehzadeh J, Bali AO, Asghari P, Souiri A, Mazaherinezhad A, et al- (2020) "A diagnostic prediction model for chronic kidney disease in internet of things platform," Multimedia Tools Appl pp- 1-18
8. Ghanavati S, Abawajy JH, Izadi D, Alelaiwi AA (2017) Cloudassisted IOT-based health status monitoring framework- Clust Comput 20:1843–1853
9. Darwish A, Hassanien AE, Elhoseny M, Sangaiah AK, Muhammad K (2019) The impact of the hybrid platform of internet of things and cloud computing on healthcare systems: opportunities, challenges, and open problems- J Ambient Intell Humaniz Comput 10:4151–4166



10. Saeed U, Shah SY, Ahmad J, Imran MA, Abbasi QH, Shah SA. Machine learning empowered COVID-19 patient monitoring using non-contact sensing: An extensive review. *Journal of pharmaceutical analysis*. 2022 Jan 4.
11. Luo E, Bhuiyan MZA, Wang G, Rahman MA, Wu J, Atiquzzaman M (2018) Privacyprotector: privacy-protected patient data collection in IOTbased healthcare systems- *IEEE Commun Mag* 56:163–168
12. Chaudhry SA, Alhakami H, Baz A, Al-Turjman F (2020) Securing demand response management: a certificate based access control in smart grid edge computing infrastructure- *IEEE Access*
13. Xu J, Dang D, Ma Q, Liu X, Han Q. A novel and robust data anomaly detection framework using LAL-AdaBoost for structural health monitoring. *Journal of Civil Structural Health Monitoring*. 2022 Jan 27:1-7.

## A Remote Health Monitoring System for Patients in a Cloud-based Internet of Things Environment

Sina Dami<sup>\*1</sup>, Ehsan ArabGhannad<sup>2</sup>

<sup>1</sup>Assistant Professor, Department of Computer Engineering, West Tehran Branch,

Islamic Azad University, Tehran, Iran, Email: dami@wtiau.ac.ir

<sup>2</sup>MSc. Student, Department of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran, Email: ehsanarabghannad@gmail.com

**Abstract**— Health monitoring systems have a special importance in today's modern medicine, and on the other hand, the inherent readiness of cloud systems in connection with the Internet of Things (IoT) can help improve the efficiency of these systems. In this paper, a method for monitoring the health of patients is presented in the cloud-based IoT environment, which is based on boosting and benefits from deep learning. The use of boosting deep learning algorithms to achieve higher levels of efficiency in patient health monitoring is one of the innovations of this paper. The patient health monitoring data sets have been used in the fields of heart, lung, kidney and brain. In order to measure the effectiveness of the proposed method, it was compared with some other prominent methods and compared with accuracy metrics and *F*-measure. The results of various tests showed that the proposed method performed better than other compared methods in most cases and achieved higher levels of efficiency.

**Keywords:** Patient health monitoring, deep learning, Boosting, Cloud environment, Internet of Things (IoT)