

# شناسایی فعالیت‌های انسانی مبتنی بر سنسورهای متحرک در اینترنت اشیا با استفاده از یادگیری عمیق

عباس میرزایی و فاطمه فرجی

در درمان کمک کند. معمولاً از تکنولوژی‌های شبکه حسگری برای دریافت داده از محیط استفاده می‌شود. حسگرها به افراد یا اشیا متصل می‌شوند تا داده‌های مورد نیاز را جمع‌آوری کنند. حسگرها می‌توانند به انسان‌ها متصل شوند؛ از جمله حسگرهای پوشیدنی مانند شتاب‌سنج، ژيروسکوپ، مغناطیس‌سنج یا دستگاه‌های پردازش علائم حیاتی مانند ضربان قلب یا دماسنج. با این حال، با این همه امکانات در برخی جاها نیاز است که فعالیت دریافتی از سنسور در شرایط مختلف، سنجیده شود. آموزش و اطلاع‌رسانی به مردم با ارائه اطلاعات در زمان مناسب، زمانی که آنها در طول محیط در حرکت هستند انجام می‌پذیرد. دانستن این که فرد در حال انجام چه کاری است در تعیین بهترین زمان برای ایجاد وقفه، برای ارائه اطلاعات مفید و یا پیام به ساکنین کمک خواهد کرد. در این حالت، نیاز به یک سیستم خودکار برای تشخیص فعالیت غیر عادی ضروری به نظر می‌رسد. تشخیص مناسب فعالیت‌های زندگی روزانه برای اجرای بسیاری از استراتژی‌های پیشنهادی در تشویق رفتارهای سالم مربوط به رژیم غذایی، ورزش و پایداری به درمان ضروری خواهد بود. در این راستا روشی مبتنی بر یادگیری عمیق و شبکه عصبی عمیق یا به اختصار  $DNN$  سی‌لایه‌ای برای تشخیص فعالیت‌های انسانی ارائه شده است. مفهوم تشخیص فعالیت انسانی و روش پیشنهادی در بخش ۱-۱ توضیح داده شده و در ادامه روش‌های تشخیص فعالیت موجود در بخش ۱-۲ بررسی و تحلیل گردیده‌اند. همچنین نحوه سازمان‌دهی مقاله در بخش ۱-۳ بیان شده است.

## ۱-۱ تشخیص فعالیت‌های انسانی

امروزه تشخیص فعالیت انسان  $(HAR)$  بسیار مورد توجه قرار گرفته است و در یک دسته‌بندی اصلی می‌توان دو دسته تشخیص فعالیت بر اساس سنسور و تشخیص فعالیت بر اساس ویدئو را در نظر گرفت. در تشخیص فعالیت مبتنی بر ویدئو، ویدئوها و تصاویر دریافتی از دوربین‌ها آنالیز می‌شوند. در حالی که در تشخیص فعالیت مبتنی بر سنسور، تمرکز روی داده‌های دریافتی از سنسورهایی مانند شتاب‌سنج است که تا کنون روش‌های مبتنی بر سنسور محبوب‌تر و رایج‌تر بوده‌اند. توانایی تشخیص فعالیت‌های پیچیده انسانی کاربردهای گوناگونی دارد و از جمله این کاربردها می‌توان نظارت اتوماتیک در مکان‌های عمومی و نظارت بر سلامت و کیفیت زندگی افراد به ویژه سالمندان را نام برد. این کاربردها نیازمند تشخیص حرکات و فعالیت‌های غیر معمول در مقابل فعالیت‌های عادی و معمول می‌باشند [۱].

چکیده: کنترل محدوده‌ها، اماکن و سنسورهای حرکتی در اینترنت اشیا نیازمند کنترل پیوسته و مستمر برای تشخیص فعالیت‌های انسانی در شرایط مختلف است که این مهم، خود چالشی از جمله نیروی انسانی و خطای انسانی را نیز در بر دارد. کنترل همیشگی توسط انسان نیز بر سنسورهای حرکتی اینترنت اشیا غیر ممکن به نظر می‌رسد. اینترنت اشیا فراتر از برقراری یک ارتباط ساده بین دستگاه‌ها و سیستم‌ها می‌باشد. اطلاعات سنسورها و سیستم‌های اینترنت اشیا به شرکت‌ها کمک می‌کند تا دید بهتری نسبت به کارایی سیستم داشته باشند. در این پژوهش روشی مبتنی بر یادگیری عمیق و شبکه عصبی عمیق سی‌لایه‌ای برای تشخیص فعالیت‌های انسانی روی مجموعه داده تشخیص فعالیت دانشگاه فوردهام ارائه شده است. این مجموعه داده دارای بیش از یک میلیون سطر در شش کلاس برای تشخیص فعالیت در اینترنت اشیا است. بر اساس نتایج به دست آمده، مدل پیشنهادی ما در راستای تشخیص فعالیت‌های انسانی در معیارهای ارزیابی مورد نظر کارایی ۹۰ درصد و میزان خطای ۲/۲ درصد را داشت. نتایج به دست آمده نشان از عملکرد خوب و مناسب یادگیری عمیق در تشخیص فعالیت است.

کلیدواژه: تشخیص فعالیت انسانی، یادگیری عمیق، یادگیری ماشین، شبکه عصبی عمیق، اینترنت اشیا.

## ۱- مقدمه

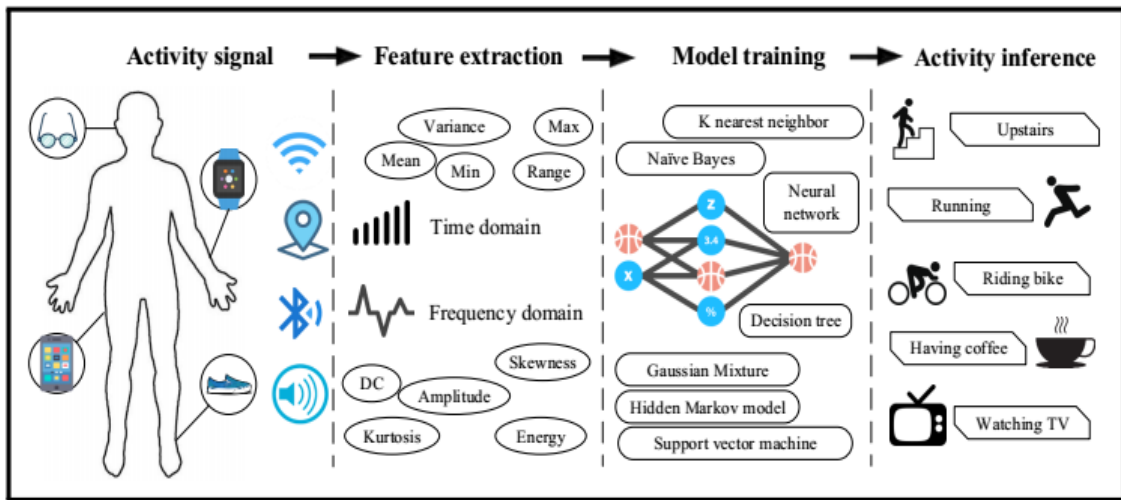
در دهه‌های گذشته تعداد دوربین‌های فیلم‌برداری در همه بخش‌های زندگی بشر افزایش چشم‌گیری داشته و در نتیجه حجم ویدئوهای ایجادشده نیز بسیار افزایش یافته است. از این رو شناسایی انسان به عنوان عنصر اصلی و مؤثر بسیاری از ویدئوها و درک فعالیت‌های او از اهمیت بالایی برخوردار می‌باشد. کاربردهایی همچون نام‌گذاری کردن ویدئو بر اساس محتوا و استخراج محتوا، استخراج بخش‌های اساسی و خلاصه کردن آن نیازمند به شناسایی فعالیت‌هایی است که در آن ویدئو اتفاق می‌افتد.

تشخیص فعالیت‌های روزمره، سیستم را قادر به نظارت و تشخیص تغییرات در الگوهای رفتاری می‌سازد که ممکن است شاخص‌های توسعه شرایط پزشکی جسمی یا روانی باشند. همچنین می‌تواند برای تعیین سطح استقلال افراد مسن، برای درک عوارض جانبی دارو و تشویق به پایداری


این مقاله در تاریخ ۲۹ مهر ماه ۱۳۹۹ دریافت و در تاریخ ۲۷ مهر ماه ۱۴۰۰ بازنگری شد.

عباس میرزایی (نویسنده مسئول)، گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران، (email: a.mirzaei@iauardabil.ac.ir).  
فاطمه فرجی، گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران، (email: f.faraji920@gmail.com).

1. Deep Neural Network
2. Human Activity Recognition



شکل ۱: تشخیص فعالیت با روش‌های تشخیص الگوی مرسوم [۵].



شکل ۲: تشخیص فعالیت با روش‌های یادگیری عمیق [۵].

موفقیت کمی داشته باشد. علاوه بر این، بر اساس تجربیات انسان فقط ویژگی‌های سطحی و کم‌عمق یاد گرفته می‌شوند. در نتیجه فعالیت‌های سطح پایین مانند دویدن و راه رفتن قابل تشخیص هستند و تشخیص فعالیت‌های سطح بالا مانند درست کردن قهوه سخت خواهد بود.

روش‌های تشخیص الگوی رایج اغلب به برچسب‌گذاری مناسب داده‌ها برای آموزش مدل نیاز دارند و اگر بر اساس روش‌های یادگیری بدون نظارت کار کنند، سیستم تشخیص فعالیت به خوبی عمل نخواهد کرد. از طرف دیگر بسیاری از روش‌های موجود بر داده‌های ایستا تمرکز دارند، در حالی که در واقعیت، داده‌های جریان‌دار هستند که نیاز به شمای یادگیری آنلاین دارند [۴]. یادگیری عمیق سعی در رفع محدودیت‌های مطرح‌شده دارد. شکل ۲ به کارگیری یادگیری عمیق را در تشخیص فعالیت نشان می‌دهد که از انواع مختلف شبکه مانند شبکه عصبی کانولوشن (CNN) و شبکه باور عمیق (DBN) بهره می‌برد. در مقایسه با شکل ۱، استخراج ویژگی و روال ساخت مدل به صورت هم‌زمان در مدل یادگیری عمیق انجام می‌شود. شبکه یادگیری عمیق قادر است به کمک لایه‌های عمیق، فعالیت‌های سطح بالا و پیچیده را شناسایی کند [۵].

یک شبکه عصبی مصنوعی (ANN) می‌تواند به یک تابع ریاضی انعطاف‌پذیر متصل شود، به گونه‌ای که روابط پیچیده بین ورودی‌ها

انواع مختلفی از فعالیت‌های انسانی وجود دارد. این فعالیت‌ها با توجه به پیچیدگی آنها به چهار سطح مختلف تقسیم‌بندی می‌شوند: (۱) حرکات دست، پا و صورت؛ حرکات اولیه اجزای بدن است که اتمیک بوده و برای توصیف حرکات معنی‌دار انسانی کاربرد دارد، مانند باز و بسته کردن دست از آرنج، مشت کردن دست و غیره. (۲) فعالیت‌های یک انسان؛ فعالیت‌های ساده را که می‌توانند شامل چندین حرکت از دسته اول در بعد زمان باشند در این دسته قرار می‌دهیم. به عبارت دیگر ترکیب حرکات اتمیک انسان، یک فعالیت مانند راه رفتن، دست تکان دادن و غیره را تشکیل می‌دهند. (۳) تعامل فعالیت‌های انسانی؛ در این دسته دو یا چند انسان و یا انسان و اشیاء با هم در ارتباط هستند، مانند دعوای دو انسان یا دزدیدن کیف فردی توسط دیگری. (۴) فعالیت‌های گروه: عملیاتی که توسط گروهی از انسان‌ها با یکدیگر یا با اشیاء صورت می‌گیرد، مانند رژه رفتن گروهی از سربازها.

شکل ۱، روندنمای مربوط به تشخیص فعالیت بر اساس روش‌های مرسوم قبلی در تشخیص الگو را نشان می‌دهد. در ابتدا ورودی‌های خام از انواع سنسورها و از طرق مختلف مانند تلفن‌های هوشمند، ساعت‌ها، بلوتوث، وای‌فای و غیره به دست می‌آید. سپس ویژگی‌ها از داده‌های خوانده‌شده به صورت دستی و بر اساس دانش انسان استخراج می‌شوند [۲] و [۳]. در نهایت این ویژگی‌ها برای آموزش مدل استفاده می‌گردند که اشکالاتی در این روش‌های مرسوم وجود دارد. استخراج دستی ویژگی‌ها به تخصص و تجربه فرد خیره بستگی دارد که ممکن است زمان‌بر بوده و

1. Convolution Neural Network
2. Deep Belief Network

داده و طبقه‌بندی کنند. در [۱۲]، با استفاده از مدل پرسپترون چندلایه و تکنیک آموزشی نظارتی و الگوریتم یادگیری Back-Propagation در زمان کم با دقت مناسب، نتایج مطلوبی در تشخیص فعالیت در خانه هوشمند به دست آمده است. نویسندگان در [۱۳] با استفاده از الگوریتم ژنتیک، رفتارهای غیر عادی را در خانه هوشمندی که برای مراقبت از افراد سالمند ایجاد شده است با دقت خوبی در مقایسه با الگوریتم‌های کلاسیک پیش‌بینی کرده‌اند. همچنین همین نویسندگان در [۱۴] با معرفی مدل بهبودیافته‌ای از Elman Neural Network و نیز با به کارگیری الگوریتم یادگیری تکاملی تفاضلی، موفق به کاهش خطا بین ورودی و خروجی مورد انتظار شدند.

در [۱۵] یک روش مبتنی بر فیلتر کانولوشن برای ۳۲ کاربر بر حسب سنسورهای ورودی استفاده شده که یک روش مبتنی بر یادگیری برای تشخیص فعالیت‌های ورودی است. در [۱۶] با استفاده از یک روش ترکیبی بر پایه ورودی سنسورهای حسگر در یک خانه هوشمند، سعی در بهبود عملکرد تشخیص فعالیت شده است. ابتدا با استفاده از روش تحلیل مؤلفه اصلی<sup>۵</sup> و روش تجزیه دیرلیکه<sup>۶</sup>، ویژگی‌های اصلی استخراج گردیده و سپس بر اساس شبکه باور عمیق<sup>۷</sup> سعی در طبقه‌بندی فعالیت شده است. یک روش خوشه‌بندی برای مدیریت برق و پسماندهای خانه‌های هوشمند نیز در [۱۷] استفاده گردید و محققان موفق شدند معیار صحت بر اساس مجموعه ورودی را به مقدار ۹۶/۷ درصد برسانند. همچنین تشخیص فعالیت‌ها بر پایه حسگرها از سه نظر روش مبتنی بر سنسور، مبتنی بر یادگیری عمیق و مبتنی بر کلاس‌بندی‌های معمولی مورد بررسی قرار گرفته است [۱۸].

در [۱۹]، در قسمت ترکیب‌بندی اعتماد از پارامترهای کیفیت سرویس، استفاده کرده‌اند که پارامترهای استفاده شده عبارتند از نسبت ارسال بسته انتها به انتها، مصرف انرژی و نسبت دریافت بسته می باشد. در این مقاله در قسمت تجمیع اعتماد از روش منطق فازی و جمع ثابت وزن‌ها استفاده شده است. به این صورت که در حالت تعامل مستقیم، از سه پارامتر ذکر شده استفاده می‌گردد و اگر مقدار به دست آمده از یک حد آستانه بیشتر باشد آنگاه تجربه تعامل با آن گره را مثبت و اگر کمتر بود تجربه تعامل را منفی در نظر می‌گیرند. با استفاده از منطق فازی تجربیات مختلف را در نظر گرفته و مقدار اعتماد حاصل می‌گردد. رای انتشار اعتماد نیز روش توزیع شده به کار می‌رود و هر گره مقدار اعتماد مخصوص به خود را دارد. برای انتشار اعتماد نیز روش توزیع شده به کار می‌رود و هر گره برای خودش مقدار اعتماد را به دست می‌آورد.

در [۲۰]، هم از ویژگی‌های کیفیت سرویس و هم از روابط اجتماعی استفاده شده است. نویسندگان در این مقاله از دو پارامتر صداقت و میزان مشارکت برای کیفیت سرویس و از پارامتر علایق گروهی به عنوان یک پارامتر مربوط به روابط اجتماعی استفاده کرده‌اند. در این روش نیز برای انتشار میزان اعتماد از روش توزیع شده استفاده گردیده که هر گره برای خویش اعتماد محاسبه کرده و برای بقیه ارسال می‌کند. در [۲۱] از یک روش مبتنی بر فراوانی وزنی TF-IDF (اصطلاح- معکوس فراوانی متن) و سپس یک شبکه عصبی عمیق برای کلاس‌بندی فعالیت در خانه هوشمند استفاده شده است.

نویسندگان [۲۲] مقاله ACM را در مورد امنیت نرم‌افزارها ارائه دادند.

(متغیرهای مستقل) و خروجی‌ها (متغیرهای وابسته) را نشان دهد [۶]. ابتدا شبکه عصبی با مجموعه‌ای از داده‌های آموزشی آموزش می‌بیند و برخی از فرایندهای بهینه‌سازی استفاده می‌شود تا خروجی‌های شناخته شده برای مجموعه‌ای از داده‌های ورودی پیش‌بینی گردد. شبکه عصبی پس از آموزش می‌تواند خروجی‌ها را به ازای هر مجموعه ورودی به دست آورد [۷]. در زمینه تشخیص فعالیت، ورودی‌ها معمولاً ویژگی‌های استخراجی از داده‌های حسگری هستند که به کلاس‌های مختلف فعالیت طبقه‌بندی می‌شوند. شبکه عصبی عمیق یکی از رایج‌ترین شبکه‌های عصبی است که شامل ورودی‌ها و خروجی‌هایی می‌باشد که از طریق گره‌های خاصی به هم متصل می‌گردند که در لایه‌های پنهان توزیع شوند [۸].

به عنوان یک مثال کاربردی، متخصصان پزشکی بر این باورند که یکی از بهترین راه‌های تشخیص یک بیماری در حال ظهور قبل از بحرانی شدن این است که تغییری در فعالیت‌های روزمره زندگی، ابزار فعالیت‌های روزمره و فعالیت‌های افزایش‌یافته زندگی روزمره جستجو شود. استفاده از شبکه‌های عصبی عمیق در این گونه مسایل کلاس‌بندی بسیار مورد توجه قرار می‌گیرد. با این حال، استفاده از یادگیری عمیق بر روی داده‌های مبتنی بر حسگر در محیط‌های اینترنت اشیا و داده‌های آن در تحقیقات گذشته مورد بررسی قرار نگرفته و به عنوان نوآوری محسوب می‌گردد. از این رو هدف ما در این مقاله استفاده از یادگیری عمیق در تشخیص فعالیت انسانی بر پایه سنسورهای حرکتی است. علاوه بر این، عملکرد مسئله تشخیص فعالیت را با استفاده از شبکه‌های عصبی عمیق بهبود خواهیم داد، زیرا استفاده از شبکه عصبی عمیق باعث بهبود معیارهای کلاس‌بندی، دقت<sup>۱</sup> و صحت<sup>۲</sup> در این مسئله خواهد شد.

## ۱-۲ کارهای مرتبط

برخی از روش‌های ارائه شده برای تشخیص فعالیت انسان قابل تعمیم برای انواع داده هستند، اما اکثر آنها مخصوص نوع داده‌های خاصی می‌باشند. از این لحاظ بر اساس [۹] می‌توان دسته‌بندی زیر را انجام داد:

- ۱) روش‌های مربوط به سنسورهای پوشیدنی
- ۲) روش‌های مربوط به سنسورهای اشیا
- ۳) روش‌های مربوط به سنسورهای محیط
- ۴) روش‌های مربوط به سنسورهای ترکیبی

سنسورهای پوشیدنی یکی از رایج‌ترین انواع است که توسط انسان‌ها پوشیده می‌شوند، مانند شتاب‌سنج، ژيروسکوپ و غیره. اغلب این سنسورها می‌توانند روی گوشی هوشمند، ساعت یا عینک نصب شوند. تا کنون چندین روش تشخیص فعالیت با یادگیری عمیق برای سنسورهای پوشیدنی ارائه شده که فعالیت‌های زندگی روزمره<sup>۳</sup> (ADL) را تشخیص می‌دهند. در این روش‌ها به جای استخراج ویژگی‌های آماری از داده‌های سنسورها، معمولاً داده‌های اصلی به طور مستقیم به عنوان ورودی شبکه مورد استفاده قرار می‌گیرد. به عنوان مثال نویسندگان [۱۰] نشان دادند که استفاده از الگوریتم یادگیری عمیق برای آموزش شبکه عصبی می‌تواند بسیار مؤثرتر از مدل آماری مارکوف و کلاس‌بند بیزین<sup>۴</sup> برای تشخیص فعالیت در خانه هوشمند باشد.

علاوه بر این، نویسندگان [۱۱] موفق شدند با استفاده از مدل شبکه کانولوشن، سه رفتار اصلی شامل نشستن، ایستادن و راه رفتن را تشخیص

1. Precision
2. Accuracy
3. Activities of Daily Living
4. Navy Bayes Classifier

5. Principal Component Analysis  
6. Linear Discriminant Analysis  
7. Deep Belief Network

جدول ۱: مقایسه مهمترین الگوریتم‌های مورد مطالعه.

سال پژوهش	مزایا و معایب	شرح پژوهش	پژوهشگرها
۲۰۱۳	برای انتشار میزان اعتماد از روش توزیع شده استفاده گردیده است که هر گره برای خودش اعتماد محاسبه کرده و برای بقیه ارسال می‌کند، اما این محاسبه کاملاً دقیق نیست.	هم از ویژگی‌های کیفیت سرویس و هم روابط اجتماعی استفاده شده است.	محایی و همکاران [۲۰]
۲۰۱۴	این الگوریتم می‌تواند مؤثرتر از مدل آماری مارکوف و کلاس‌بند بیزین در تشخیص فعالیت در خانه ی هوشمند باشد..	از الگوریتم یادگیری عمیق برای آموزش شبکه ی عصبی استفاده شده است..	فنگ و هو [۱۰]
۲۰۱۷	با استفاده از الگوریتم ژنتیک، دقت پیش بینی در مقایسه با الگوریتم های کلاسیک دیگر افزایش می‌یابد، اما خطا، بین ورودی و خروجی وجود دارد..	از الگوریتم ژنتیک، جهت پایش رفتارهای غیرعادی افراد مسن استفاده شده است.	لیووان و همکاران [۱۳]
۲۰۱۸	ویژگی‌های مهم را استخراج می‌شود و سپس بر پایه شبکه باور عمیق، طبقه‌بندی می‌گردد که این طبقه‌بندی از ترتیب مناسب کمتری برخوردار است.	روش ترکیبی بر پایه ورودی سنسورهای حسگر در یک خانه هوشمند سعی در بهبود عملکرد تشخیص فعالیت ارائه دادند.	حسن و همکاران [۱۶]
۲۰۱۹	روش ترکیبی استفاده شده دارای خطای نسبی است ولی این خطا کم و کمتر از ۱۰ درصد می‌باشد.	از یک روش مبتنی بر فراوانی وزنی (TF-IDF) اصطلاح- معکوس فراوانی (متن) و سپس از یک شبکه عصبی عمیق برای کلاسیک فعالیت در خانه هوشمند استفاده کردند..	ژئیو و همکاران [۲۱]
۲۰۱۶	در زمان کم با دقت مناسب، نتایج مطلوبی در تشخیص فعالیت در خانه ی هوشمند، به دست آوردند.	از مدل پرسپترون چند لایه و تکنیک آموزشی نظارتی و الگوریتم یادگیری پس از انتشار استفاده شده است..	اوکریچ و همکاران [۱۲]
۲۰۲۰	یک روش مبتنی بر یادگیری برای تشخیص فعالیت‌های ورودی است، میزان صحت و دقت کمتری نسبت به روش‌های یادگیری قبلی دارد.	یک روش مبتنی بر فیلتر کانولوشن برای ۳۲ کاربر بر حسب سنسورهای ورودی استفاده کردند.	ایگتوف و همکاران [۱۵]

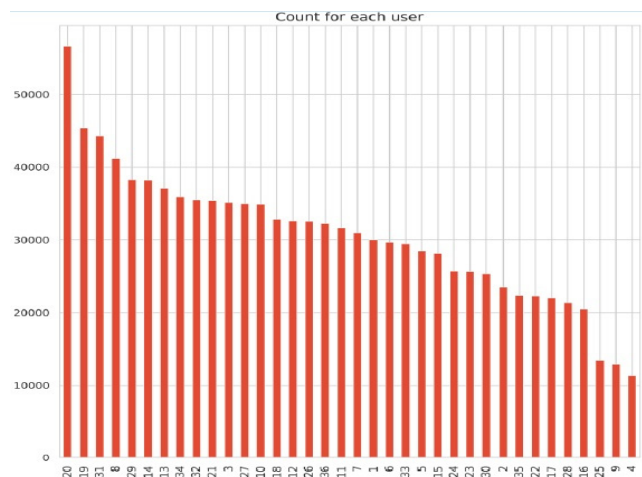
بخشد. سپس یک مکانیزم تلفیق داده‌های مبتنی بر چند حسگر برای ادغام یکپارچه داده‌های حسگر روی بدن، داده‌های حسگر زمینه و داده‌های نمایه شخصی با هم ایجاد می‌شود و یک روش طبقه‌بندی مبتنی بر حافظه کوتاه‌مدت (LSTM) برای شناسایی ریزدانه‌ها پیشنهاد می‌گردد. در [۲۷]، تشخیص فعالیت‌های انسانی جدید مبتنی بر بهبود شبکه تحول بیزی (IBCN) پیشنهاد شده است که به هر سیستم هوشمند اجازه می‌دهد تا داده‌ها را از طریق ارتباطات فرکانس رادیویی سنتی (RF) یا ارتباطات پراکندگی کم‌توان با کمک ابر بارگیری کند. در شبکه تحول بیزی، توزیع متغیر پنهان مدل طراحی شده و ویژگی‌ها با استفاده از لایه‌های کانولوشن استخراج می‌شوند و عملکرد IoT با ترکیب یک رمزگذار خودکار متغیر با یک طبقه‌بندی کننده شبکه عمیق استاندارد بهبود یافته است. علاوه بر این، شبکه بیزی به حل مسایل امنیتی با استفاده از طراحی یادگیری عمیق پیشرفته (EDL) با یک استراتژی بارگیری مؤثر کمک می‌کند. نتایج تجربی نشان می‌دهد که داده‌های جمع‌آوری شده از سنسور IoT پوشیدنی به منابع مختلف عدم قطعیت، یعنی آلتانوریک و معرفتی، به ویژه سر و صدا و قابلیت اطمینان حساس هستند. مهمترین روش‌های مورد مطالعه در جدول ۱ مقایسه شده‌اند.

### ۱-۳ سازمان‌دهی مقاله

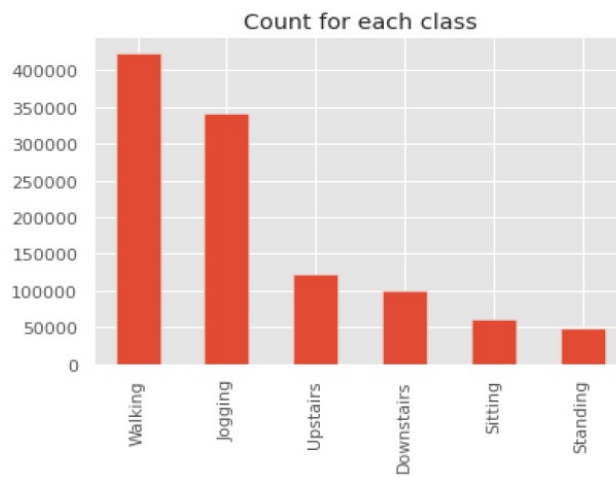
ادامه مقاله به صورت زیر سازمان‌دهی شده است. مدل شبکه عصبی عمیق پیشنهادی در بخش ۲ ارائه شده است. در این بخش جزئیات روش که مبتنی بر یادگیری عمیق و شبکه عصبی کانولوشن است برای تشخیص فعالیت‌های مبتنی بر اینترنت اشیا بررسی می‌شود. در ادامه، مدل پیشنهادی بر اساس معیارهای معینی در بخش ۳ ارزیابی و بررسی گردیده و نهایتاً مقاله در بخش ۴ جمع‌بندی می‌شود.

نرم‌افزارهای موجود در جهان به دلیل ارائه سریع و اختصاص زمان کم به طراحی آنها، دارای مشکلات امنیتی می‌باشند که در این مقاله با مشخص کردن الزامات امنیتی در مراحل تحلیلی و طراحی و با پردازش خود این مباحث را ارائه داده و برخی از اقدامات اصلاحی را برای رفع این فعالیت‌های مختلط ارائه می‌دهد. تغییرات پیشنهادی، فرایندهای نرم‌افزاری ایمن موجود را اصلاح می‌کند. در [۲۳]، شبکه‌های عصبی CNN به عنوان قالبی برای تجزیه تصاویر و ماتریسی بیان کردن آنها معرفی شده‌اند که با یادگیری توسعه یافته برای تشخیص تصاویر واقعی به کار می‌روند. داده‌های این شبکه به صورت یک داده چندمنظوره یا نمودار ساختار است که این ورودی‌ها می‌توانند ماتریس مجاورت یا لاپلاسیایی باشند. این فرایند با یک لایه به پایان می‌رسد که در آن یادگیری واقعی و تصویر به آن نزدیک می‌شود. در [۲۴]، شناخت یک فعالیت با یک نمونه با استفاده از روش‌های یادگیری متریک که یکی از روش‌های شناسایی چهره می‌باشد، بررسی شده است. برای کاهش مشکل عملکرد تشخیص، سیگنال‌ها رمزگذاری گردید. با استفاده از CNN تصاویر نمایش داده شد و سپس با استفاده از CNN باقیمانده، عمق تصاویر تجسم شد. برای پیش‌بینی مجموعه متنوعی از حرکات انسانی، یک مدل نمونه‌گیری جدید به اسم Diow در [۲۵] برای مدل‌های عمیق ارائه گردیده است. در این روش با یک مدل تولیدی عمیق با دسترسی به کدهای نهفته، عملکرد برتر در تولید نمونه‌های حرکتی متنوع نشان داده شده است.

در [۲۶]، بر HAR تقویت‌شده با یادگیری عمیق در محیط‌های IoHT تمرکز گردیده است. یک چارچوب یادگیری عمیق نیمه نظارت شده برای HAR دقیق‌تر طراحی و ساخته شده که به طور مؤثر از داده‌های حسگر دارای برچسب ضعیف برای آموزش مدل یادگیری طبقه‌بندی کننده استفاده و تجزیه و تحلیل می‌کند. برای حل بهتر مشکل نمونه برچسب‌گذاری نشده، یک طرح برچسب‌گذاری خودکار هوشمند مبتنی بر شبکه Q عمیق (DQN) با یک قانون پاداش مبتنی بر فاصله طراحی شده که می‌تواند کارایی یادگیری را در محیط‌های اینترنت اشیا بهبود



شکل ۴: تعداد سطرها به ازای هر کاربر.



شکل ۳: تعداد سطرها در شش کلاس مورد بررسی در مجموعه داده ورودی.

بهینه انجام می‌شود. شکل ۵ معماری و ساختار این مدل پیشنهادی مبتنی بر شبکه عصبی عمیق را نشان می‌دهد.

لایه سوم، لایه Dense است که در این لایه، ورودی‌های لایه قبله تمامی نورون‌ها متصل‌اند. لایه چهارم نرمال‌سازی<sup>۲</sup> را می‌توان تکنیکی برای بهبود عملکرد و پایداری شبکه‌های عصبی دانست. ایده این کار، نرمال‌سازی ورودی هر لایه با کمک میانگین و واریانس می‌باشد به شکلی که میانگین اعداد بردار نهایی برابر با صفر و واریانس آنها برابر با یک شود. این لایه باعث افزایش سرعت شبکه و لایه‌ها می‌گردد. لایه بعدی، لایه فعال‌سازی است که از یک تابع غیر خطی برای بهبود یادگیری استفاده می‌کند. در این لایه از تابع غیر خطی تانژانت هیپربولیک استفاده شده است. لایه ششم لایه حذف تصادفی<sup>۳</sup> است و این لایه وظیفه وظیفه کنترل پدیده بیش‌برازش<sup>۴</sup> را بر عهده دارد. بیش‌برازش زمانی اتفاق

می‌افتد که شبکه عصبی بر روی داده آموزشی بسیار خوب آموزش دیده باشد، اما بر روی مجموعه آزمایشی چندان قابلیت تعمیم نداشته باشد. بنابراین می‌توان ادعا کرد که مدل پیشنهادی با محیط‌های واقعی و شرایط مختلف مدل‌های انتشار تطبیق‌پذیر است.

در این پژوهش با احتمال  $0/3$  و  $0/2$  در برخی لایه‌ها و تکرارها، ورودی‌های لایه بعد حذف شده و دوباره آموزش می‌بینند. اصولاً لایه حذف کردن هیچ تأثیری در ورودی یا خروجی لایه بعد ندارد و صرفاً برای کنترل آموزش درست استفاده می‌شود. لایه‌های بعدی، به ترتیب لایه Dense، لایه حذف تصادفی، لایه Dense، لایه نرمال‌سازی دوم، لایه فعال‌سازی با تابع تانژانت هیپربولیک و لایه حذف تصادفی به عنوان لایه دوازدهم است. همین ترتیب تا لایه بیست و نهم تکرار می‌شود. لایه بیست و نهم لایه مسطح‌سازی است و این لایه، ورودی لایه‌های قبلی را به یک بردار متوالی و پیوسته بسیار بزرگ تبدیل می‌نماید. در نهایت لایه آخر یک لایه کاملاً متصل<sup>۵</sup> است که تعیین‌کننده کلاس نهایی فعالیت برای ورودی متناظر از بین شش کلاس شرح داده شده است. شکل ۶ ورودی و خروجی هر لایه را نشان می‌دهد.

روال مدل پیشنهادی سی‌لایه‌ای برای تشخیص فعالیت کاربر مورد نظر در اینترنت اشیا از بین شش کلاس متناظر در شکل ۷ نمایش داده شده

## ۲- مدل شبکه عصبی عمیق برای تشخیص فعالیت

اینترنت اشیا در حال تغییر دنیای اطرافمان از رانندگی گرفته تا خرید کردن است. تراشه‌ها و سنسورهای تعبیه‌شده در اینترنت اشیا، در حال انتقال داده‌های ارزشمندی هستند، اطلاعاتی که درک صحیح فعالیت‌هایشان و نحوه به اشتراک‌گذاری آنها با این حجم عظیم اطلاعات تبادل بسیار سخت است. در این بخش روش مبتنی بر یادگیری عمیق و شبکه عصبی کانولوشن برای تشخیص فعالیت‌های مبتنی بر داده‌های اینترنت اشیا معرفی می‌شود.

### ۱-۲ مجموعه داده‌های استفاده‌شده برای تشخیص فعالیت

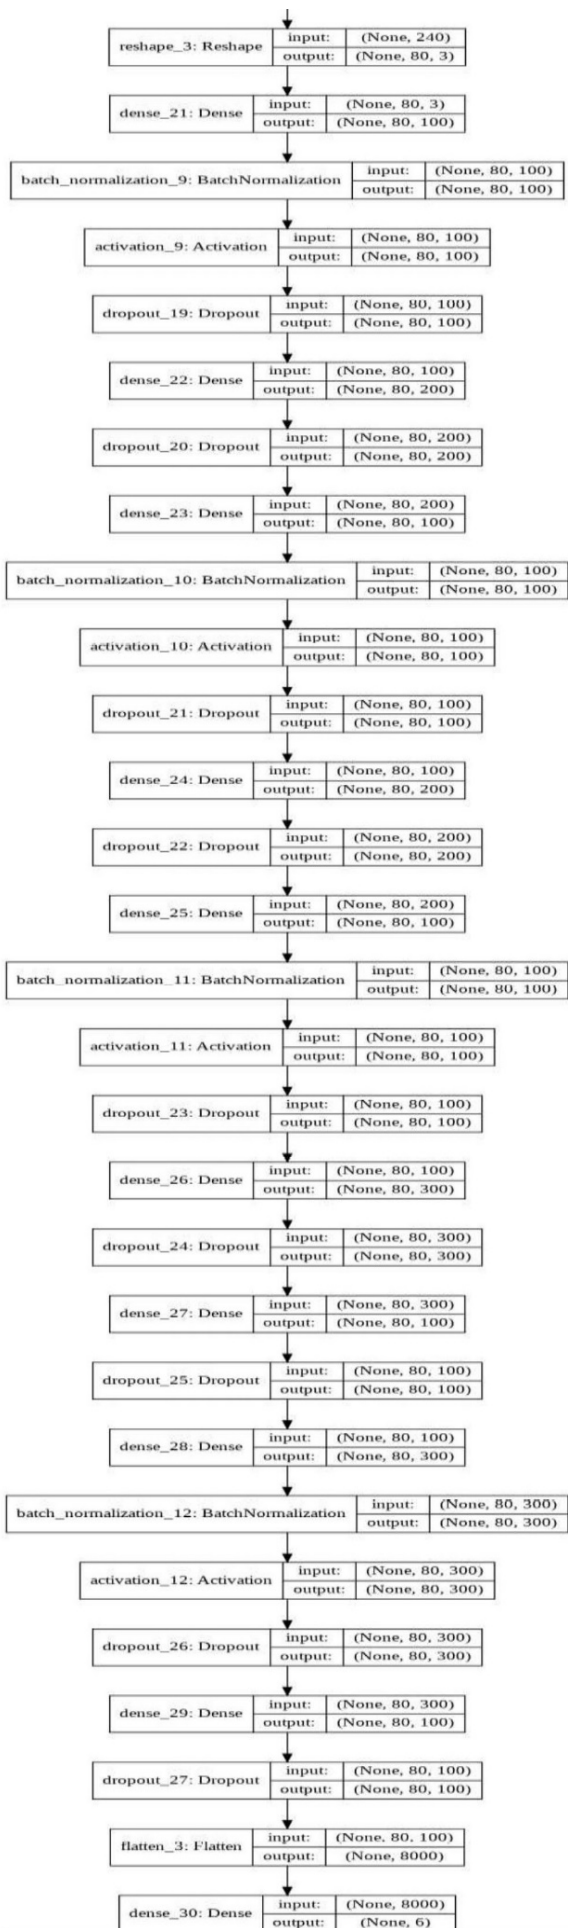
در این پژوهش از مجموعه داده تشخیص فعالیت در اینترنت اشیا در دانشگاه فوردهام استفاده گردیده [۲۸] که این مجموعه داده دارای ۱۰۹۸۲۰۷ سطر در شش کلاس مختلف از فعالیت‌های جمع‌آوری شده است. ۲۸/۶ درصد از کل مجموعه داده مرتبط با کلاس راه‌رفتن، ۳۲ درصد داده‌ها مربوط به کلاس آهسته دویدن، بیش از ۱۱ درصد مربوط به کلاس بالا رفتن از پله‌ها، ۹ درصد کلاس پایین آمدن از پله‌ها، ۵/۵ درصد کلاس نشستن و ۴/۴ درصد از کل داده‌ها شامل کلاس ایستادن است که در شکل ۳ نشان داده شده است [۲۹]. این مجموعه داده از ۳۶ نفر به تعداد فعالیت‌هایشان در محیط‌های مختلف اینترنت اشیا جمع‌آوری گردیده که در شکل ۴ تعداد فعالیت به ازای تعداد کاربر نشان داده شده است.

### ۲-۲ رویکرد مدل پیشنهادی

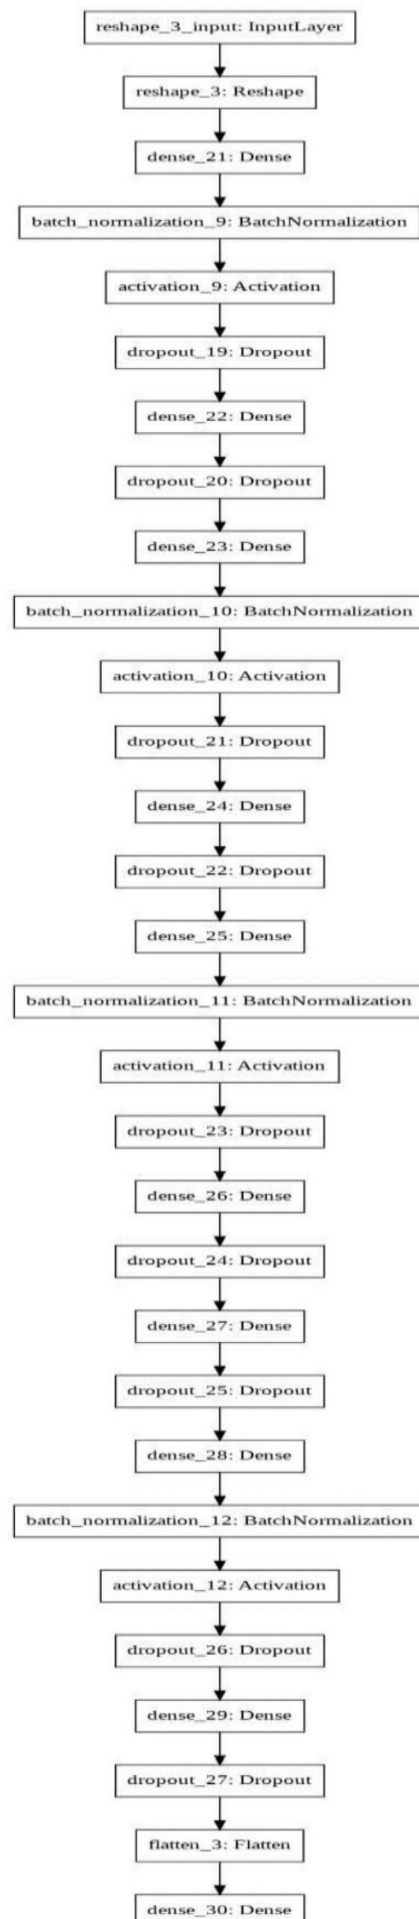
در این پژوهش برای تشخیص فعالیت از روی مجموعه داده ورودی یک مدل مبتنی بر شبکه عصبی عمیق ارائه شده است. مدل پیشنهادی دارای سی لایه متوالی برای استخراج و یادگیری از فعالیت‌ها و ویژگی‌های ورودی به صورت سلسله‌مراتبی و ترتیبی است. خروجی هر لایه به عنوان ورودی لایه بعد انتخاب می‌گردد. اولین لایه در مدل پیشنهادی لایه ورودی است. لایه دوم، لایه Reshape است که می‌توان برای تغییر ابعاد ورودی مورد استفاده قرار داد، بدون آن که تغییری در داده آن رخ دهد. دقیقاً مانند لایه مسطح‌سازی<sup>۱</sup>، تنها ابعاد تغییر پیدا می‌کند و در این حین هیچ داده‌ای در طی این فرایند کپی نمی‌شود، در نتیجه عملیات بسیار

2. Batch Normalization
3. Drop out
4. Over-Fitting
5. Fully-Connected

1. Flatten



شکل ۴: ورودی و خروجی متناظر هر لایه در مدل پیشنهادی سی لایه‌ای.



شکل ۵: معماری و ساختار مدل پیشنهادی.

جدول ۲: ماتریس درهم‌ریختگی برای یک مسئله دسته‌بندی دودسته‌ای.

نوع رکورد	رکوردهای تخمینی (Predicated Records)		
	دسته مثبت	دسته منفی	نوع دسته
رکوردهای واقعی (Actual Records)	FP	TN	دسته منفی
	TP	FN	دسته مثبت

معیار  $f_1$  و ماتریس درهم‌ریختگی<sup>۳</sup> استفاده شده است. این معیارها در ادامه مورد بررسی قرار گرفته و نتایج روش پیشنهادی بر مبنای آنها مورد ارزیابی قرار می‌گیرند.

### ۳-۱ معیارهای ارزیابی

در مدل پیشنهادی با استفاده از توابع و لایه‌های لازم، کل شبکه آموزش داده می‌شود. معیار صحت، معیار بیان می‌کند چند درصد از این داده‌ها درست دسته‌بندی شده‌اند. نمودار ROC نیز در واقع نمایش بصری با یک مقدار آستانه بر حسب مقدار True-Positive و False-Positive است. ماتریس درهم‌ریختگی نیز چگونگی عملکرد الگوریتم دسته‌بندی را با توجه به مجموعه داده ورودی به تفکیک انواع دسته‌های مسأله دسته‌بندی نمایش می‌دهد. جدول ۲ نشان‌دهنده کلیات ماتریس درهم‌ریختگی است. TN بیانگر تعداد رکوردهایی است که دسته واقعی آنها منفی بوده و الگوریتم دسته‌بندی نیز دسته آنها را به درستی منفی تشخیص داده است. TP بیانگر تعداد رکوردهایی است که دسته واقعی آنها مثبت بوده و الگوریتم دسته‌بندی نیز دسته آنها را به درستی مثبت تشخیص داده است. FP بیانگر تعداد رکوردهایی است که دسته واقعی آنها منفی بوده و الگوریتم دسته‌بندی، دسته آنها را به اشتباه مثبت تشخیص داده است. FN بیانگر تعداد رکوردهایی است که دسته واقعی آنها مثبت بوده و الگوریتم دسته‌بندی، دسته آنها را به اشتباه منفی تشخیص داده است.

معیارهای صحت، دقت، بازخوانی و  $f_1$  به ترتیب طبق روابط زیر به دست می‌آیند [۲۸]

$$Accuracy = \frac{TP_i + TN}{TP_i + FN + TN + FP_i} \quad (1)$$

$$Precision = \frac{TP_i}{TP_i + FP_i} \quad (2)$$

$$Recall = \frac{TP_i}{TP_i + FN_i} \quad (3)$$

$$f_1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

در حوزه هوش مصنوعی، ماتریس درهم‌ریختگی به ماتریسی گفته می‌شود که در آن عملکرد الگوریتم‌های مربوط نشان داده می‌شود. معمولاً چنین نمایشی برای الگوریتم‌های یادگیری با ناظر استفاده می‌شود، اگرچه در یادگیری بدون ناظر نیز کاربرد دارد. معمولاً به کاربرد این ماتریس در الگوریتم‌های بدون ناظر ماتریس تطابق می‌گویند. هر ستون از ماتریس، نمونه‌ای از مقدار پیش‌بینی شده را نشان می‌دهد، در صورتی که هر سطر نمونه‌ای واقعی (درست) را در بر دارد.

**ورودی:** مجموعه داده تشخیص فعالیت دانشگاه فوردهام

**خروجی:** طبقه‌بندی برای تعیین و تشخیص فعالیت از بین شش کلاس متناظر

راه رفتن، ایستادن، بالارفتن از پله، پایین آمدن از پله، آهسته دویدن و نشستن

گام ۱: بارگذاری کل مجموعه داده تشخیص فعالیت، انتخاب ۸۰ درصد به

عنوان داده آموزشی و ۲۰ درصد به عنوان داده آزمایشی

گام ۲: لایه ورودی برای کل مجموعه داده

گام ۳: لایه Reshape

گام ۴: لایه Dense اول

گام ۵: لایه نرمال‌سازی اول

گام ۶: لایه فعال‌ساز با تابع تانژانت هیپربولیک اول

گام ۷: لایه حذف تصادفی

گام ۸: لایه Dense دوم

گام ۹: لایه حذف تصادفی دوم

گام ۱۰: لایه Dense سوم

گام ۱۱: لایه نرمال‌سازی دوم

گام ۱۲: لایه فعال‌ساز دوم

گام ۱۳: لایه حذف تصادفی سوم

گام ۱۴: لایه Dense چهارم

گام ۱۵: لایه حذف تصادفی چهارم

گام ۱۶: لایه Dense پنجم با فعال‌ساز Relu

گام ۱۷: لایه نرمال‌سازی سوم

گام ۱۸: لایه فعال‌ساز تانژانت هیپربولیک سوم

گام ۱۹: لایه حذف تصادفی پنجم

گام ۲۰: لایه Dense پنجم

گام ۲۱: لایه حذف تصادفی ششم

گام ۲۲: لایه Dense پنجم

گام ۲۳: لایه حذف تصادفی هفتم

گام ۲۴: لایه Dense ششم

گام ۲۵: لایه Batch normalization

گام ۲۶: لایه فعال‌ساز چهارم

گام ۲۷: لایه Dense هفتم

گام ۲۸: لایه حذف تصادفی هشتم

گام ۲۹: لایه مسطح‌سازی برای تبدیل به یک بردار پیوسته

گام ۳۰: لایه کاملاً متصل برای انتخاب کلاس و فعالیت خروجی

شکل ۷: نحوه عملکرد روش پیشنهادی.

است. بهینه‌ساز استفاده شده در این تحقیق ادام<sup>۱</sup> تعداد تکرار ۱۰۰ در بسته یادگیری عمیق کراس با پشتیبانی تنسورفلو می‌باشد.

باید دقت داشت که در یک شبکه با ساختار غیر توزیع شده که با عنوان متمرکز شناخته می‌شود، مقدار ضرایب بهینه‌سازی از طریق گره‌های کنترلی محاسبه شده و برای تمام گره‌های IoT ارسال می‌گردند. اما در شبکه‌های با ساختار توزیع شده، این روال به این صورت نخواهد بود و لذا مقدار ضرایب بهینه‌سازی در هر تکرار محاسبه شده و با استفاده از پروتکل‌های مشارکتی در اختیار سایر گره‌ها قرار می‌گیرد. لذا در حل مسأله بهینه‌سازی باید دقت داشت طی هر تکرار، روالی ساده با پیچیدگی محاسباتی کم، مناسب برای به دست آوردن ضرایب معادلات خواهد بود.

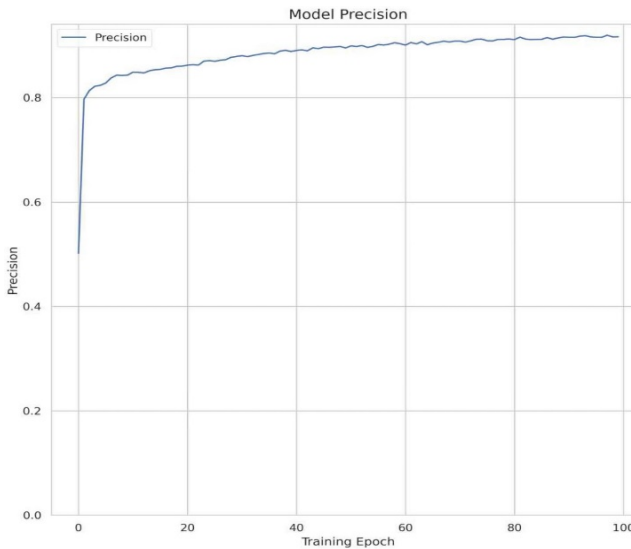
### ۳- ارزیابی روش پیشنهادی

به منظور ارزیابی مدل پیشنهادی از معیارهای صحت، دقت، بازخوانی<sup>۲</sup>،


2. Recall

3. Confusion Matrix

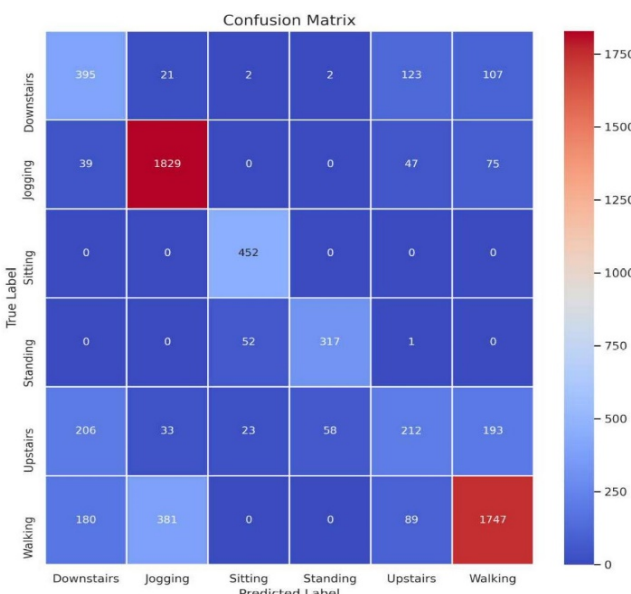
1. Adam




شکل ۱۰: میزان دقت مدل پیشنهادی.



شکل ۸: افزایش میزان درستی مدل پیشنهادی در صد تکرار.



شکل ۱۱: نمایش گرافیکی ماتریس درهم‌ریختگی برای شش کلاس مدل پیشنهادی.



شکل ۹: میزان بازخوانی مدل پیشنهادی.

شکل ۱۱ که نمایش کامل گرافیکی ماتریس درهم‌ریختگی مدل پیشنهادی را برای هر شش کلاس نمایش می‌دهد، میزان تشخیص‌های درست برای هر کلاس را نیز در بر دارد. مقادیر قطر اصلی، میزان پیشنهاد مدل پیشنهادی به واقعیت هستند که این مدل سی‌لایه‌ای پیشنهادی بسیار خوب توانسته است پیش‌بینی داشته باشد. در کلاس نشستن حتی یک پیش‌بینی نادرست نداشته و تمام مقادیر را به درستی پیش‌بینی کرده است.

میزان خطای مدل پیشنهادی برای پنج تکرار اول، میزان ۰٫۶ کاهش با شیب بسیار خوبی داشته است. تا تکرار بیستم میزان خطا ۰٫۲ نیز کاهش یافته و بین تکرار چهارم تا ششم، میزان خطا تا مقدار تقریباً ۰٫۲۲ نیز ادامه‌دار بوده که در شکل ۱۲ نشان داده شده است.

### ۳-۳ ارزیابی معیارهای کلاس‌بندی برای روش‌های دیگر

در این بخش، خروجی چندین الگوریتم کلاس‌بندی برای ورودی تشخیص فعالیت با شش کلاس بررسی می‌شود. با استفاده از الگوریتم  $k$ -نزدیک‌ترین همسایه، مقادیر معیارهای ارزیابی در حدود ۶۰ درصد و میزان درستی ۵۹٫۹۹ است که نشان از عملکرد انتخاب بسیار معمولی این

### ۲-۳ ارزیابی معیارهای کلاس‌بندی و خطا برای مدل پیشنهادی

اولین معیار بررسی‌شده، معیار درستی یا صحت است که به عنوان یکی از مهم‌ترین معیارهای کلاس‌بندی می‌باشد. شکل ۸ میزان درستی را در صد تکرار نمایش می‌دهد. همان‌طور که در شکل نیز نشان داده است، مدل پیشنهادی شیب صعودی بسیار خوبی دارد. مقدار درستی تنها در ۵ تکرار اول از مقدار ۴۰ درصد به نزدیک ۷۰ درصد افزایش یافته است. مقدار صحت بعد از ۲۰ تکرار به بالای ۸۰ درصد نیز رسیده است. بعد از ۸۰ درصد میزان درستی شیب، افزایشی ملایمی دارد و تقریباً در مقدار ۹۰ درصد برای صد تکرار ثابت شده است.

میزان بازخوانی مدل پیشنهادی در شکل ۹ قابل مشاهده است. همان‌طور که در شکل نیز دیده می‌شود، معیار بازخوانی نیز شیب بسیار خوب صعودی داشته و تقریباً در ۸۸ درصد ثابت شده است.

میزان دقت مدل پیشنهادی در شکل ۱۰ نشان داده شده است. میزان دقت در تکرارهای بین صفر تا ده نسبت به بازخوانی بسیار بهتر بوده و شیب بسیار تندتری برای رسیدن به مقادیر بالاتر در معیار دقت مشاهده می‌شود. میزان دقت بسیار سریع به مقدار ۸۰ درصد و حتی بالاتر می‌رسد.



جدول ۵: خروجی الگوریتم ماشین بردار پشتیبان خطی.

	Precision	Recall	F1-Score	Support
۰٫۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۶۵۰
۱٫۰	۰٫۶۰	۰٫۴۰	۰٫۴۸	۱۹۹۰
۲٫۰	۱٫۰۰	۰٫۹۱	۰٫۹۵	۴۵۲
۳٫۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۳۷۰
۴٫۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۷۲۵
۵٫۰	۰٫۴۳	۰٫۸۷	۰٫۵۸	۲۳۹۷
accuracy	-	-	۰٫۵۰	۶۵۸۴
macro ave	۰٫۳۴	۰٫۳۶	۰٫۳۳	۶۵۸۴
weighted ave	۰٫۴۱	۰٫۵۰	۰٫۴۲	۶۵۸۴

جدول ۶: خروجی الگوریتم ماشین بردار پشتیبان با هسته RBF.

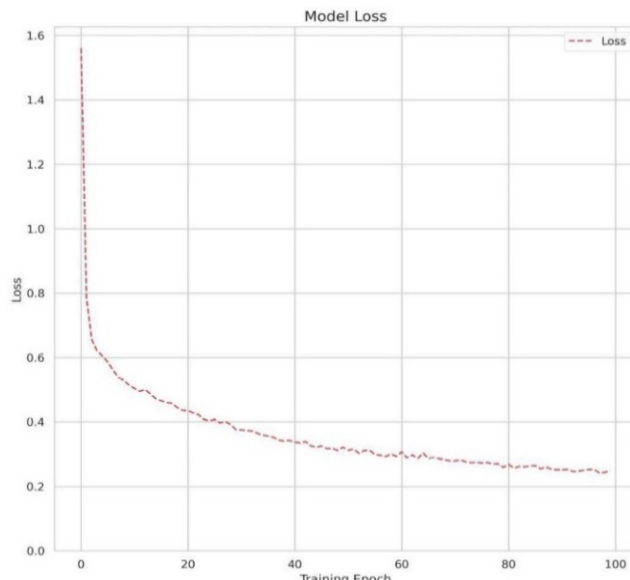
	Precision	Recall	F1-Score	Support
۰٫۰	۰٫۶۰	۰٫۲۵	۰٫۳۶	۶۵۰
۱٫۰	۰٫۸۲	۰٫۹۵	۰٫۸۸	۱۹۹۰
۲٫۰	۱٫۰۰	۰٫۹۱	۰٫۹۵	۴۵۲
۳٫۰	۰٫۸۴	۰٫۶۹	۰٫۷۶	۳۷۰
۴٫۰	۰٫۴۸	۰٫۴۳	۰٫۴۵	۷۲۵
۵٫۰	۰٫۷۸	۰٫۸۵	۰٫۸۱	۲۳۹۷
accuracy	-	-	۰٫۷۷	۶۵۸۴
macro ave	۰٫۷۵	۰٫۶۸	۰٫۷۰	۶۵۸۴
weighted ave	۰٫۷۶	۰٫۷۷	۰٫۷۶	۶۵۸۴

جدول ۷: خروجی الگوریتم گرادیان کاهشی تصادفی.

	Precision	Recall	F1-Score	Support
۰٫۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۶۵۰
۱٫۰	۰٫۵۰	۰٫۳۴	۰٫۴۱	۱۹۹۰
۲٫۰	۰٫۹۲	۰٫۷۴	۰٫۸۲	۴۵۲
۳٫۰	۰٫۰۶	۰٫۱۳	۰٫۰۸	۳۷۰
۴٫۰	۰٫۰۰	۰٫۰۱	۰٫۰۱	۷۲۵
۵٫۰	۰٫۴۵	۰٫۷۳	۰٫۵۶	۲۳۹۷
accuracy	-	-	۰٫۴۳	۶۵۸۴
macro ave	۰٫۳۳	۰٫۳۲	۰٫۳۱	۶۵۸۴
weighted ave	۰٫۳۹	۰٫۴۳	۰٫۳۹	۶۵۸۴

در این الگوریتم  $۸۰/۲۸$  باشد که برای شش کلاس خروجی برای تشخیص فعالیت از روی سنسورهای حرکتی مقدار قابل توجهی است. خروجی دو روش ماشین بردار پشتیبان با دو مرکز خطی و rbf در جداول ۵ و ۶ نشان داده شده است. الگوریتم خطی، کلاس‌ها را به صورت خطی تقسیم‌بندی می‌نماید و عملکرد معمولی دارد. ماشین بردار پشتیبان با مرکز rbf با توجه به روش کلاس‌بندی انتخابی عملکرد نسبتاً بهتری دارد. میزان درستی برای ماشین بردار پشتیبان خطی ۵۰ و برای ماشین بردار پشتیبان rbf  $۷۷/۱۸$  می‌باشد.

الگوریتم گرادیان کاهشی تصادفی، روشی مبتنی بر تکرار برای بهینه‌سازی یک تابع مشتق‌پذیر به نام تابع هدف است که تقریبی تصادفی از روش گرادیان کاهشی می‌باشد. روش گرادیان کاهشی تصادفی بر خلاف گرادیان کاهشی استاندارد که از تمام داده‌های آموزشی استفاده می‌کند، فقط از گروهی از داده‌های آموزشی که به طور تصادفی انتخاب می‌شوند برای بهینه‌سازی تابع هدف استفاده می‌کند. نتیجه خروجی این الگوریتم برای تشخیص فعالیت در محیط اینترنت اشیا در جدول ۷ نشان



شکل ۱۲: کاهش میزان خطای مدل پیشنهادی در صد تکرار.

جدول ۳: خروجی الگوریتم  $k$ -نزدیک‌ترین همسایه برای مجموعه داده.

	Precision	Recall	F1-Score	Support
۰٫۰	۰٫۰۶	۰٫۰۱	۰٫۰۲	۶۵۰
۱٫۰	۱٫۰۰	۰٫۶۱	۰٫۷۵	۱۹۹۰
۲٫۰	۰٫۶۸	۰٫۹۱	۰٫۷۸	۴۵۲
۳٫۰	۰٫۱۶	۰٫۹۵	۰٫۲۷	۳۷۰
۴٫۰	۰٫۰۹	۰٫۰۴	۰٫۰۵	۷۲۵
۵٫۰	۰٫۹۱	۰٫۸۱	۰٫۸۶	۲۳۹۷
accuracy	-	-	۰٫۶۰	۶۵۸۴
macro ave	۰٫۴۸	۰٫۵۵	۰٫۴۵	۶۵۸۴
weighted ave	۰٫۷۰	۰٫۶۰	۰٫۶۲	۶۵۸۴

جدول ۴: خروجی الگوریتم شبکه عصبی پرسپترون.

	Precision	Recall	F1-Score	Support
۰٫۰	۰٫۵۸	۰٫۲۸	۰٫۳۸	۶۵۰
۱٫۰	۰٫۹۸	۰٫۹۴	۰٫۹۶	۱۹۹۰
۲٫۰	۱٫۰۰	۰٫۹۱	۰٫۹۵	۴۵۲
۳٫۰	۰٫۸۶	۰٫۵۲	۰٫۶۵	۳۷۰
۴٫۰	۰٫۴۲	۰٫۵۴	۰٫۴۷	۷۲۵
۵٫۰	۰٫۸۰	۰٫۹۴	۰٫۸۷	۲۳۹۷
accuracy	-	-	۰٫۸۰	۶۵۸۴
macro ave	۰٫۷۷	۰٫۶۹	۰٫۷۱	۶۵۸۴
weighted ave	۰٫۸۱	۰٫۸۰	۰٫۸۰	۶۵۸۴

الگوریتم دارد. این الگوریتم نه بر اساس مشابه‌ترین‌ها بلکه بر اساس نزدیک‌ترین‌ها تصمیم می‌گیرد. نتایج خروجی این الگوریتم در جدول ۳ نشان داده شده است.

خروجی شبکه عصبی پرسپترون در جدول ۴ نشان داده شده است. این شبکه بعد از روش پیشنهادی، بهترین عملکرد را برای مجموعه داده تشخیص فعالیت ورودی دانشگاه فوردهام داشته است. پیش‌بینی‌های این شبکه با توجه به ترکیب خطی وزن‌دار ورودی الگوریتم انجام می‌شود. همچنین این الگوریتم به دلیل این که ورودی‌هایش را به صورت تک‌تک در زمان بررسی می‌کند، یک الگوریتم برخط نیز در نظر گرفته می‌شود. در نظر گرفتن وزن ورودی‌ها در این الگوریتم باعث شده که مقدار درستی

جدول ۸: خروجی الگوریتم جنگل تصادفی برای مجموعه داده ورودی.

	Precision	Recall	F1-Score	Support
۰/۰	۰/۶۶	۰/۱۸	۰/۲۸	۶۵۰
۱/۰	۰/۸۰	۰/۹۷	۰/۸۸	۱۹۹۰
۲/۰	۱/۰۰	۰/۸۹	۰/۹۴	۴۵۲
۳/۰	۱/۰۰	۰/۵۵	۰/۷۱	۳۷۰
۴/۰	۰/۶۱	۰/۲۷	۰/۳۷	۷۲۵
۵/۰	۰/۶۸	۰/۸۷	۰/۷۶	۲۳۹۷
Accuracy	-	-	۰/۷۵	۶۵۸۴
macro ave	۰/۷۹	۰/۶۲	۰/۶۶	۶۵۸۴
weighted ave	۰/۷۵	۰/۷۵	۰/۷۱	۶۵۸۴

جدول ۹: خروجی الگوریتم آداپوست برای مجموعه داده ورودی.

	Precision	Recall	F1-Score	Support
۰/۰	۰/۳۰	۰/۰۵	۰/۰۸	۶۵۰
۱/۰	۰/۶۰	۰/۵۳	۰/۵۶	۱۹۹۰
۲/۰	۱/۰۳	۰/۰۰	۰/۰۱	۴۵۲
۳/۰	۰/۷۷	۰/۶۲	۰/۶۹	۳۷۰
۴/۰	۰/۲۴	۰/۰۲	۰/۰۴	۷۲۵
۵/۰	۰/۴۵	۰/۸۱	۰/۵۸	۲۳۹۷
accuracy	-	-	۰/۵۰	۶۵۸۴
macro ave	۰/۴۰	۰/۳۴	۰/۳۳	۶۵۸۴
weighted ave	۰/۴۵	۰/۵۰	۰/۴۳	۶۵۸۴

جدول ۱۰: خروجی الگوریتم بیزین برنولی.

	Precision	Recall	F1-Score	Support
۰/۰	۰/۱۵	۰/۰۹	۰/۱۱	۶۵۰
۱/۰	۰/۷۷	۰/۷۷	۰/۷۷	۱۹۹۰
۲/۰	۰/۷۴	۰/۹۱	۰/۸۱	۴۵۲
۳/۰	۰/۱۳	۰/۴۰	۰/۲۰	۳۷۰
۴/۰	۰/۰۱	۰/۰۱	۰/۰۱	۷۲۵
۵/۰	۰/۶۲	۰/۴۶	۰/۵۳	۲۳۹۷
accuracy	-	-	۰/۵۰	۶۵۸۴
macro ave	۰/۴۰	۰/۴۴	۰/۴۱	۶۵۸۴
weighted ave	۰/۵۳	۰/۵۰	۰/۵۰	۶۵۸۴

جدول ۱۱: خروجی الگوریتم درخت تصمیم برای تشخیص فعالیت انسانی.

	Precision	Recall	F1-Score	Support
۰/۰	۰/۲۲	۰/۲۶	۰/۲۴	۶۵۰
۱/۰	۰/۸۰	۰/۷۷	۰/۷۸	۱۹۹۰
۲/۰	۰/۹۱	۰/۸۳	۰/۸۷	۴۵۲
۳/۰	۰/۸۵	۰/۵۶	۰/۶۸	۳۷۰
۴/۰	۰/۲۲	۰/۲۹	۰/۲۵	۷۲۵
۵/۰	۰/۶۶	۰/۶۴	۰/۶۵	۲۳۹۷
accuracy	-	-	۰/۶۱	۶۵۸۴
macro ave	۰/۶۱	۰/۵۶	۰/۵۸	۶۵۸۴
weighted ave	۰/۶۴	۰/۶۱	۰/۶۲	۶۵۸۴

الگوریتم جنگل تصادفی عملکرد مشابهی همچون گرادبان کاهشی داشته است. جنگل تصادفی یک الگوریتم ترکیبی شامل چندین درخت تصمیم تصادفی است. این درخت‌ها پیش‌بینی‌هایی بر روی مجموعه داده انجام می‌دهند و در نهایت از یک رأی اکثریت برای تصمیم‌گیری نهایی استفاده می‌کنند. با توجه به ترکیبی بودن این الگوریتم انتظار می‌رود برای تشخیص فعالیت عملکرد مناسبی داشته باشد. میزان دقت این الگوریتم ۷۵ است که نسبت به سایر مدل‌ها مقدار خوبی محسوب می‌شود. نتایج این الگوریتم در جدول ۸ نشان داده شده است.

الگوریتم آداپوست یک الگوریتم تطبیقی است و در این الگوریتم، طبقه‌بند در هر مرحله جدید به نفع نمونه‌های غلط طبقه‌بندی شده در مراحل قبل تنظیم می‌گردد. آداپوست نسبت به داده‌های نویز و پرت حساس است ولی نسبت به مشکل بیش‌برازش از اکثر الگوریتم‌های یادگیری برتر است. در داده‌های ورودی مجموعه داده، داده‌های نویز بعد از پیش‌پردازش‌ها کمتر شده است اما در کل برخی داده‌ها ممکن است اطلاعات نادرستی در اختیار کلاس‌بند قرار دهند. با این توصیفات عملکرد ضعیف آداپوست برای این مسئله قابل توجیه هست. نتایج مربوط به این الگوریتم در جدول ۹ نشان داده شده است.

خروجی الگوریتم بیزین برنولی در جدول ۱۰ نشان داده شده است. با توجه به اینکه این نوع از دسته بندی بیشترین کاربرد را در دسته بندی و تشخیص با احتمال دارد، در این مدل در حالت چندمتغیره فرض بر این است که موجود یا ناموجود بودن یک ویژگی در نظر گرفته می‌شود. عملکرد متوسط رو به ضعیف این مدل با مقدار درستی ۴۹/۵۱ نیز چندان بعید به نظر نمی‌رسد.

خروجی الگوریتم درخت تصمیم در جدول ۱۱ نشان داده شده است. اکثر درخت‌های تصمیم تنها از یک ویژگی برای شاخه‌زدن در گره‌ها استفاده می‌کنند، در صورتی که ممکن است ویژگی‌ها دارای توزیع توأم باشند. میزان عملکرد درخت تصمیم تقریباً ۶۰ درصد بوده که نسبت به دیگر الگوریتم‌های بررسی شده عملکرد معمولی محسوب می‌شود.

### ۳-۴ ابزارهای استفاده شده برای پیاده‌سازی

تسنورفلو یک کتابخانه نرم‌افزاری برای یادگیری عمیق در زبان پایتون ۳ می‌باشد و Notebook به عنوان محیط توسعه برای این آزمایش مورد استفاده قرار گرفته است. زبان برنامه‌نویسی زبان پایتون است. کتابخانه یادگیری عمیق تسنورفلو به همراه کراس استفاده شده است. کراس یک چهارچوب سطح بالا یادگیری عمیق پایتونی می‌باشد که توسط آقای François Chollet در سال ۲۰۱۵ تأسیس شده است. در حقیقت کراس یک فرانت‌اند<sup>۱</sup> برای فریمورک‌های یادگیری عمیق تسنورفلو و تیانو است و آنها پشت شبکه‌های عصبی را می‌سازند و آموزش چون کراس پیچیدگی استفاده از این کتابخانه‌ها را تا حد خوبی حذف می‌کند. یک ویژگی خاص دیگر کراس این است که محدود به یک کتابخانه یادگیری عمیق نیست و می‌توان از تسنورفلو، تیانو برای محاسبات استفاده کرد. در این پایان‌نامه از ابزار گوگل کولب که به صورت پیش‌فرض جویپتر نوت بوک و پکیج تسنورفلو، کراس در آن نصب شده است، به صورت رایگان در اختیار عموم می‌باشد و امکان موازی‌سازی بر روی GPUها را می‌دهد، استفاده شده است.

- Google-colab

- GPU-TPU

داده شده است. همان طور که از نتایج مشخص است گرادبان کاهشی عملکرد ضعیفی داشته و دارای دقت ۰/۳۹، بازخوانی ۴۳ و مقدار درستی ۴۲/۶۶ است که کمترین مقدار در بین الگوریتم‌های مقایسه‌ای می‌باشد.

کوتاه‌مدت و یا ترکیبی از چندین شبکه عصبی استفاده نمود.  
 (۳) استفاده از الگوریتم‌های فراابتکاری برای تشخیص فعالیت انسانی از جمله الگوریتم ذرات پرندگان، ژنتیک و یا ترکیبی از این دست الگوریتم‌ها به همراه مدل پیشنهادی نیز می‌تواند مبنای کارهای آتی قرار گیرد.

## مراجع

- [1] S. J. Preece, J. Y. Goulermas, L. P. J. Kenney, D. Howard, K. Meijer, and R. Crompton, "Activity identification using body-mounted sensors: a review of classification techniques," *Engineering, Medicine*, vol. 30, no. 4, pp. 221-243, Apr. 2009.
- [2] A. Mirzaei and A. R. Najafi Souha, "Towards optimal configuration in MEC neural networks: deep learning-based optimal resource allocation," *Wireless Personal Communications*, vol. 12, no. 1, pp. 221-243, 2021.
- [3] A. Rahimi, A. Ziaeddini, and S. Gonglee, "A novel approach to efficient resource allocation in load-balanced cellular networks using hierarchical DRL," *J. of Ambient Intelligence and Humanized Computing*, pp. 1-15, 2021.
- [4] L. Liu, Y. Peng, S. Wang, M. Liu, and Z. Huang, "Complex activity recognition using time series pattern dictionary learned from ubiquitous sensors," *Information Sciences, Computer Science*, vol. 340-341, pp. 41-57, May 2016.
- [5] P. Liu, X. Qiu, and X. Huang, "Recurrent neural network for text classification with multi-task learning," in *Proc. of the 25th Int. Joint Conf. on Artificial Intelligence*, pp. 2873-2879, New York, NY, USA, 9-15 Jul. 2016.
- [6] J. T. Heaton, Ian Goodfellow, Yoshua Bengio, and Aaron Courville, *Deep learning*, The MIT Press, p. 800, 2016.
- [7] M. Farhang, A. Mohajer, O. Zobeiravi, and A. Rahimzadegan, "Adaptive spectrum sensing algorithm based on noise variance estimation for cognitive radio applications," in *Proc. MASFOR Conf.*, 1 p., Istanbul, Turkey, 21-23 Jun. 2012.
- [8] A. Mirzaei Somarin, Y. Alaei, M. R. Tahernezhad, A. Mohajer, and M. Barari, "An efficient routing protocol for discovering the optimum path in mobile ad hoc networks," *Indian J. of Science and Technology*, vol. 8, no. S8, pp. 450-455, Apr. 2015.
- [9] R. Chavarriaga, H. Sagha, A. Calatroni, S. T. Digumarti, G. Troster, J. R. Millan, and D. Roggen, "The opportunity challenge: a benchmark database for on-body sensor-based activity recognition," *Pattern Recognition Letters*, vol. 34, no. 15, pp. 2033-2042, Nov. 2013.
- [10] H. Fang and C. Hu, "Recognizing human activity in smart home using deep learning algorithm," in *Proc. of the 33rd Chinese Control Conf.*, pp. 4716-4720, Nanjing, China, 28-30 Jul. 2014.
- [11] M. Papakostas, T. Giannakopoulos, F. Makedon, and V. Karkaletsis, "Short-term recognition of human activities using convolutional neural networks," in *Proc. of the 12th Int. Conf. on Signal Image Technology & Internet Systems*, pp. 302-307, Naples, Italy, 28 Nov.-1 Dec. 2016.
- [12] N. Oukrich, A. Maach, E. Sabri, E. Mabrouk, and K. Bouchard, "Activity recognition using back-propagation algorithm and minimum redundancy feature selection method," in *Proc. of 4th IEEE Int. Colloquium on Information Science and Technology*, pp. 818-823, Tangier, Morocco, 24-26 Oct. 2016.
- [13] Z. Liouane, T. Lemlouma, P. Roose, F. Weis, and H. Messaoud, "A genetic neural network approach for unusual behavior prediction in smart home," *Intelligent Systems Design and Applications*, vol. 557, pp. 738-748, Feb. 2017.
- [14] Z. Liouane, T. Lemlouma, P. Roose, F. Weis, and H. Messaoud, "An improved elman neural network for daily living activities recognition," *Intelligent Systems Design and Applications*, vol. 557, pp. 697-707, Feb. 2017.
- [15] A. Ignatov, "Real-time human activity recognition from accelerometer data using convolutional neural networks," *Applied Soft Computing*, vol. 62, pp. 915-922, Jan. 2018.
- [16] M. M. Hassan, Md. Zia Uddin, A. Mohamed, and A. Almogren, "A robust human activity recognition system using smartphone sensors and deep learning," *Future Generation Computer Systems*, vol. 81, pp. 307-313, Apr. 2018.
- [17] S. Ahmadi-Karvigh, A. Ghahramani, B. Becerik-Gerber, and L. Soibelman, "Real-time activity recognition for energy efficiency in buildings," *Applied Energy*, vol. 211, no. 1, pp. 146-160, Feb. 2018.

- Matplotlib
- Pandas
- Keras
- Seaborn
- Tensorflow
- Sklearn

گوگل کولب با در اختیار گذاشتن یک فضای پردازشی مبتنی بر ابر<sup>۱</sup> این امکان را فراهم نموده تا بتوان از سخت‌افزارهای قدرتمند برای آموزش مدل‌ها استفاده کرد. این ابزار تنها برای زبان برنامه‌نویسی پایتون ۲ و ۳ ارائه شده است. در این ابزار به صورت پیش‌فرض، کتابخانه‌های معروف نصب شده‌اند و در صورت نیاز به یک کتابخانه خاص، نصب کردن آن بسیار آسان است. در این پژوهش از ابزار گوگل کولب به دلیل حجم عظیم محاسبات و بزرگ بودن مجموعه ورودی استفاده گردیده است. تمامی محاسبات در محیط ابر و بر روی سرورهای گوگل که یکی از قوی‌ترین سرورهای رایگان در جهان هستند استفاده می‌شود. البته محدودیت گوگل کولب از نظر حافظه کاملاً مشهود بوده است. به این دلیل کلاً مجموعه ورودی از خود سایت مستقیماً بر روی گوگل کولب فراخوانی و اجرا گردیده است.

## ۴- نتیجه‌گیری

در این پژوهش برای تشخیص فعالیت از روی مجموعه داده، یک مدل مبتنی بر شبکه DNN ارائه کردیم. مدل پیشنهادی دارای سی لایه متوالی برای استخراج و یادگیری از فعالیت‌ها و ویژگی‌های ورودی به صورت سلسله‌مراتبی و ترتیبی است که خروجی هر لایه به عنوان ورودی لایه بعدی انتخاب می‌گردد. بهینه‌ساز استفاده‌شده در این تحقیق، ادام و تعداد تکرار صد در بسته یادگیری عمیق کراس با پشتیبانی تنسورفلو می‌باشد. نتایج حاصل از ارزیابی روش پیشنهادی و الگوریتم دیگر نشان داد که این روش نه تنها در مقایسه با روش‌های دیگر از لحاظ معیارهای دقت، درستی، بازخوانی و  $f_1$  عملکرد بهتری دارد، بلکه توانسته است در معیارهای مذکور به مقدار بسیار خوب ۹۰ درصد نیز برسد. همچنین میزان خطا در روش پیشنهادی نزدیک به ۰.۲۲ می‌باشد که نشان از عملکرد خوب مدل پیشنهادی دارد. در نتیجه مدل پیشنهادی در این پژوهش در زمینه تشخیص فعالیت مبتنی بر اینترنت اشیا عملکرد بسیار خوبی خواهد داشت.

روش پیشنهادی بر پایه شبکه عصبی DNN و مبتنی بر لایه‌های Dense به همراه دیگر لایه‌های نرمال‌ساز، حذف تصادفی و غیره بود که می‌توان برای کارهای آتی از شبکه‌های عصبی کانولوشن، LSTM و یا ترکیبی از چندین شبکه عصبی استفاده نمود. استفاده از الگوریتم‌های فراابتکاری برای تشخیص فعالیت انسانی و یا ترکیبی از این الگوریتم‌ها به همراه مدل پیشنهادی نیز می‌تواند مبنای کارهای آتی قرار گیرد. بنابراین برای کارهای آتی موارد زیر را می‌توان طرح‌ریزی کرد:

- (۱) با توجه به عملکرد خوب مدل پیشنهادی بر حسب معیارهای ارزیابی دقت، درستی، بازخوانی و میزان خطای بسیار قابل قبول در اینترنت اشیا، می‌تواند در ابزارهای دنیای واقعی و نرم‌افزارها استفاده شود.
- (۲) روش پیشنهادی بر پایه شبکه عصبی DNN و مبتنی بر لایه‌های Dense به همراه دیگر لایه‌های نرمال‌ساز، حذف تصادفی و ... بود و می‌توان برای کارهای آتی از شبکه‌های عصبی کانولوشن، بازگشتی

- using wearable IoT device," *IEEE Access*, vol. 8, pp. 86411-86418, May 2020.
- [28] B. Razavi, *RF Microelectronics (2nd Edition) (Prentice Hall Communications Engineering and Emerging Technologies Series)*, Prentice Hall Press One Lake Street Upper Saddle River, NJ United States, 1998.
- [29] A. Aghagolzadeh and M. A. Naji, "Multi-focus image fusion in DCT domain based on correlation coefficient," in *Proc. 2nd Int. Conf. on Knowledge-Based Engineering and Innovation*, pp. 632-639, Tehran, Iran, 5-6 Nov. 2015.
- عباس میرزایی** تحصیلات خود را در رشته مهندسی کامپیوتر در مقاطع کارشناسی و کارشناسی ارشد به ترتیب در سال‌های ۱۳۸۵ و ۱۳۸۷ از دانشگاه آزاد اسلامی قزوین و تبریز و در سال ۱۳۹۶ دکتری رشته مهندسی کامپیوتر را از دانشگاه صنعتی مالک اشتر تهران به پایان رسانده است و هم‌اکنون استادیار گروه کامپیوتر، دانشکده فنی و مهندسی دانشگاه آزاد اسلامی واحد اردبیل می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: امنیت و قابلیت اطمینان شبکه، هوش مصنوعی، کلان داده، داده‌کاوی، بهینه‌سازی شبکه‌های سلولی، شبکه‌های ناهمگن و تخصیص منابع شبکه‌های بی‌سیم.
- فاطمه فرجی** در سال ۱۳۹۳ مدرک کارشناسی مهندسی فناوری اطلاعات خود را از دانشگاه اسلامی آزاد تبریز و در سال ۱۳۹۹ مدرک کارشناسی ارشد مهندسی نرم‌افزار خود را از دانشگاه اسلامی آزاد اردبیل دریافت نمود. از سال ۱۳۹۵ تا سال ۱۳۹۹ به عنوان کارشناس کامپیوتر و طراح سایت مشغول به کار بود و پس از آن به دوره دکتری مهندسی کامپیوتر در دانشگاه یلدیز تکنیک در ترکیه وارد گردید و در حال حاضر دانشجوی دکتری این دانشگاه می‌باشد. زمینه‌های علمی مورد علاقه نام‌برده متنوع بوده و شامل موضوعاتی مانند یادگیری عمیق، رباتیک، مدیریت شبکه‌های کامپیوتری می‌باشد.
- [18] J. Wang, Y. Chen, S. Hao, X. Peng, and L. Hu, "Deep learning for sensor-based activity recognition: a survey," *Pattern Recognition Letters*, vol. 119, pp. 3-11, Mar. 2019.
- [19] F. Bao, I. R. Chen, and J. Guo, "Scalable, adaptive and survivable trust management for community of interest based Internet of Things systems," in *Proc. IEEE 11th Int. Symp. on Autonomous Decentralized Systems, ISADS'13*, 7 pp., Mexico City, Mexico, 6-8 Mar 2013.
- [20] P. N. Mahalle, P. A. Thakre, N. R. Prasad, and R. Prasad, "A fuzzy approach to trust based access control in internet of things," in *Proc. Wireless VITAE'13*, 5 pp., Atlantic City, NJ, USA, 24-27 Jun. 2013.
- [21] A. Mohajer, M. Barari, and H. Zarrabi, "Activity feature solving based on TF-IDF for activity recognition in smart homes," *Complexity*, vol. 2019, 9 Article ID: 5245373, 9 2019.
- [22] S. Zhang, M. Madakhani, M. Shafieezadeh, and A. Mirzae, "A novel approach to optimize power consumption in orchard WSN: efficient opportunistic routing," *Wireless Personal Communications*, vol. 108, pp. 1611-1634, 2019.
- [23] M. Herrera, M. Perez-Hernandez, A. K. Parlikad, and J. Izquierdo, "Multi-agent systems and complex networks: review and applications in systems engineering," *Processes*, vol. 108, no. 3, Article ID: 312, Mar. 2020.
- [24] A. Aghagolzadeh and M. Amin-Naji, "Multi-focus image fusion in DCT domain using variance and energy of laplacian and correlation coefficient for visual sensor networks," *J. of AI and Data Mining*, vol. 6, no. 2, pp. 233-250, Summer 2018.
- [25] M. Haghighat, *Biometrics for Cybersecurity and Unconstrained Environments*, Ph.D Thesis, University of Miami, USA, 2016.
- [26] X. Zhou, et al., "Deep-learning-enhanced human activity recognition for Internet of healthcare things," *IEEE Internet of Things J.*, vol. 7, no. 7, pp. 6429-6438, Jul. 2020.
- [27] Z. Zhou, H. Yu, and H. Shi, "Human activity recognition based on improved bayesian convolution network to analyze health care data