

# شناسایی پایدار فعالیت فیزیکی انسان بر اساس سنسورهای گوشی هوشمند

مهدی یزدیان دهکردی، زهرا عابدی و نسیم خانی

حسگرهای حرکتی در نقاط مختلف بدن مثل کمر، مچ دست، قفسه سینه و ران پا، نتایج با کارایی بالا را به همراه دارد [۶]. چالشی که در استفاده از این سنسورها وجود دارد این است که نصب آنها بر روی بدن برای استفاده یک فرد معمولی، مناسب و راحت نیست و به علاوه در این حالت امکان نظارت به صورت بلندمدت بر فعالیت‌های انسان نیز وجود ندارد.

با عمومی‌شدن استفاده از گوشی‌های هوشمند در جوامع امروزی، فرصت‌های جدیدی برای شناسایی فعالیت‌های انسان بر اساس این گوشی‌ها فراهم شده است. با توجه به این که داخل هر گوشی هوشمند، حسگرهای مختلفی مثل میکروفون، دوربین‌های دوگانه، شتاب‌سنج<sup>۲</sup>، ژيروسکوپ‌ها<sup>۳</sup> و غیره گنجانده شده است، این سنسورها می‌توانند اطلاعات مفهومی غنی از انسان را ثبت کنند. بنابراین با توجه به در دسترس بودن گوشی‌های هوشمند و عدم نیاز به نصب سنسور اضافی بر روی بدن فرد، سنسورهای گوشی‌های هوشمند مانند سنسور ژيروسکوپ و شتاب‌سنج، جایگزین مناسبی برای تشخیص فعالیت هستند.

Martin و همکارانش [۷] در سال ۲۰۱۳ شناسایی فعالیت بر اساس داده‌های گرفته‌شده از ژيروسکوپ، شتاب‌سنج و مغناطیس‌سنج<sup>۴</sup> گوشی هوشمند را با استفاده از یک جدول تصمیم انجام دادند. Shoaib و همکارانش [۸] در سال ۲۰۱۳ نشان دادند که ترکیب داده‌های ژيروسکوپ و شتاب‌سنج می‌تواند دقت مناسبی را به همراه آورد. در سال ۲۰۱۳ Anguita و همکارانش [۱] مجموعه داده‌های استاندارد با عنوان HAR منتشر کردند که شهرت زیادی در زمینه شناسایی فعالیت‌های انسانی مبتنی بر سیگنال‌های ژيروسکوپ و شتاب‌سنج گوشی‌های هوشمند پیدا کرده است. Suarez و همکارانش [۹] در سال ۲۰۱۵ نتایج حاصل از پیاده‌سازی طبقه‌بندی‌کننده‌های بیز ساده، درخت تصمیم و چند نزدیک‌ترین همسایه را بر روی این داده‌ها مورد مقایسه قرار دادند که روش چند نزدیک‌ترین همسایه بهترین دقت را به دست آورد. در سال ۲۰۱۶، Ronao و همکاران [۱۰] از شبکه‌های عصبی عمیق به عنوان یک روش استخراج ویژگی خودکار برای تشخیص فعالیت بهره بردند و در همین سال Tran و همکاران [۱۱]، الگوریتم ماشین بردار پشتیبان را برای این منظور به کار گرفتند. در برخی از پژوهش‌ها از روش‌های کاهش ابعاد برای کم‌کردن بعد داده‌ها استفاده شده است [۶]، [۹] و [۱۲]. Silva و همکارانش [۱۲] از روش انتخاب ویژگی پیش‌رو<sup>۵</sup> استفاده کرده‌اند تا تعداد ویژگی‌ها را کاهش دهند. Suarez و همکاران [۹] از ویژگی‌های ژيروسکوپ صرف نظر کرده و تنها از ویژگی‌های شتاب‌سنج استفاده کرده‌اند. در سال ۲۰۱۷ Doewes و همکاران [۶]، از معیار اطلاعات

چکیده: در سال‌های اخیر تشخیص فعالیت فیزیکی انسان از روی داده‌های گرفته‌شده توسط سنسورهای ژيروسکوپ و شتاب‌سنج در گوشی هوشمند، مورد توجه پژوهشگران قرار گرفته است. در این مقاله با به کارگیری روش تحلیل مؤلفه‌های اساسی، ویژگی‌هایی با بعد پایین و مناسب استخراج شده و کارایی چند طبقه‌بندی‌کننده مختلف شامل ماشین بردار پشتیبان، رگرسیون منطقی، ادابوست و شبکه عصبی کانولوشن برای طبقه‌بندی فعالیت‌ها بررسی و یک سیستم کارا برای این منظور پیشنهاد شده است. نتایج به دست آمده نشان می‌دهد که سیستم پیشنهادی توانسته است دقت تشخیص را نسبت به کارهای اخیر بهبود دهد. یکی از چالش‌هایی که لازم است در خصوص سیستم‌های تشخیص فعالیت مورد توجه قرار گیرد، میزان پایداری این سیستم‌ها نسبت به مدل‌های مختلف از گوشی‌های هوشمند است. با توجه به این که کیفیت سنسورها و نویز مرتبط با آنها از یک مدل گوشی به مدل دیگر متفاوت است، بنابراین بررسی میزان پایداری الگوریتم شناسایی فعالیت در نویزهای مختلف حایز اهمیت خواهد بود. در این مقاله کارایی و میزان پایداری طبقه‌بندی‌کننده‌ها در سطوح مختلف نویز نیز بررسی شده است. نتایج به دست آمده نشان می‌دهد که ماشین بردار پشتیبان با میانگین دقت ۹۶٫۳۴٪ پایداری بهتری نسبت به نویز در مقایسه با سایر طبقه‌بندی‌کننده‌ها داشته است.

کلیدواژه: ژيروسکوپ، شتاب‌سنج، شناسایی فعالیت فیزیکی انسان، کیفیت سنسور، گوشی هوشمند، نویز سنسور.

## ۱- مقدمه

تشخیص فعالیت‌های انسان (HAR)<sup>۱</sup>، یکی از زمینه‌های کاربردی در حوزه هوش مصنوعی است که در سال‌های اخیر توجه بسیاری از پژوهشگران در زمینه‌های مختلف را به خود جلب کرده است. هدف از یک سیستم تشخیص فعالیت، شناسایی فعالیت‌های انجام‌شده توسط انسان بر اساس مجموعه‌ای از مشاهدات وی و محیط اطرافش است [۱]. فرایند تشخیص می‌تواند بر اساس داده‌های ثبت‌شده توسط ویدئو [۲]، تصویر [۳] و یا سنسورهای دیگر باشد. نمونه‌ای از سنسورهای استفاده‌شده برای این منظور، حسگرهای محیطی [۴] یا حسگرهای پوشیدنی [۵] هستند که بر روی نقاط مختلف بدن نصب می‌شوند تا اطلاعات موقعیت فرد را ثبت کنند. پژوهش‌های مختلف نشان می‌دهد که استفاده از


این مقاله در تاریخ ۱۷ شهریور ماه ۱۳۹۸ دریافت و در تاریخ ۸ فروردین ماه ۱۳۹۹ بازنگری شد.

مهدی یزدیان دهکردی (نویسنده مسئول)، گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران، (email: yazdian@yazd.ac.ir).

زهرا عابدی، گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران، (email: Zahra.abedi@stu.yazd.ac.ir).

نسیم خانی، گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران، (email: n.khani@stu.yazd.ac.ir).

2. Accelerometer
3. Gyroscope
4. Magnetometer
5. Forward Feature Selection



شکل ۱: روندنمای مراحل انجام شده در سیستم پیشنهادی تشخیص فعالیت انسان.

## ۲- سیستم پیشنهادی

بخش‌های اصلی سیستم تشخیص فعالیت در این پژوهش در شکل ۱ آمده است. در بخش اول به منظور بررسی پایداری طبقه‌بندی‌کننده‌ها، داده‌های نویزی با سطوح مختلف نویز تولید می‌شوند. در مرحله بعد با پنجره‌گذاری بر روی سیگنال‌های ژيروسکوپ و شتاب‌سنج، ویژگی‌های آماری از داده‌ها استخراج می‌شود. سپس با استفاده از الگوریتم تحلیل مؤلفه‌های اصلی، ابعاد داده‌ها کاهش داده شده و در نهایت داده‌ها طبقه‌بندی می‌شوند. در ادامه توضیحات بیشتر در خصوص هر یک از مراحل آورده شده است.

### ۲-۱ تولید نمونه‌های نویزی

آزمایشات انجام شده در این پژوهش بر اساس داده‌های مشهور HAR انجام گردیده که این مجموعه داده‌ها در پژوهش‌های اخیر متعددی به کار گرفته شده است. سیگنال خام گرفته شده از ژيروسکوپ و شتاب‌سنج داخلی یک گوشی هوشمند مدل Samsung Galaxy S II ثبت شده است [۱]. در فضای واقعی کیفیت سنسورهای گوشی هوشمند و نویز داده‌های گرفته شده از آنها از یک مدل به مدل دیگر و حتی در گوشی‌های مختلف از یک مدل می‌تواند متفاوت باشد [۱۳]. بنابراین بررسی میزان تأثیر نویزهای مختلف بر روی دقت سیستم تشخیص فعالیت می‌تواند مفید باشد. بررسی‌ها نشان می‌دهد که نویز غالب در سنسورهای ژيروسکوپ و شتاب‌سنج نویز سفید<sup>۸</sup> است [۱۳] و [۱۴]. به منظور بررسی میزان تأثیر نویز در دقت تشخیص فعالیت مبتنی بر این سنسورها، نویز سفید با سطوح مختلف شامل ۵، ۱۰، ۱۵ و ۲۰ دسی‌بل به سیگنال خام اضافه شده و کارایی طبقه‌بندی‌کننده‌ها در این نویزها در داده‌های خام و همچنین داده‌های آغشته شده به نویز بررسی گردیده است.

### ۲-۲ استخراج ویژگی

برای مقایسه بهتر با کارهای اخیر که بر روی داده‌های HAR انجام شده است، مشابه کارهای قبلی در مرحله استخراج ویژگی با پنجره‌گذاری بر روی سیگنال‌های ژيروسکوپ و شتاب‌سنج در سه راستای  $x$ ،  $y$  و  $z$  ویژگی‌های آماری از جمله میانگین، انحراف معیار، میانه، ماکسیمم، مینیمم، مساحت دامنه سیگنال، انرژی، انتروپی، ضرایب رگرسیون و ضرایب همبستگی [۱] استخراج می‌شوند. لیست کامل ویژگی‌های استخراج شده در پژوهش [۱] آمده است. تعداد ویژگی‌های استخراج شده در این مرحله یک بردار ویژگی با اندازه ۵۶۱ را برای هر پنجره فعالیت ایجاد می‌کند.

مقابل<sup>۱</sup> و روش انتخاب ویژگی حداقل افزونگی- حداکثر ارتباط<sup>۲</sup> (MRMR) به همراه طبقه‌بندی‌کننده ماشین بردار پشتیبان جهت شناسایی فعالیت‌های فیزیکی بهره برده‌اند.

در این مقاله با به کارگیری روش استخراج ویژگی تحلیل مؤلفه‌های اصلی یا همان PCA<sup>۳</sup> و همچنین ارزیابی چندین طبقه‌بندی‌کننده مختلف، سعی کرده‌ایم تا ضمن کاهش ابعاد داده‌ها، دقت تشخیص فعالیت با استفاده از داده‌های ژيروسکوپ و شتاب‌سنج در گوشی‌های همراه را بهبود دهیم. برای این منظور ابتدا ویژگی‌های آماری پیشنهاد شده توسط Anguita و همکاران [۱] که در اکثر پژوهش‌های قبلی نیز استفاده شده‌اند را توسط روش تحلیل مؤلفه‌های اصلی کاهش بعد داده، سپس کارایی طبقه‌بندی‌کننده‌های رگرسیون منطقی یا LR<sup>۴</sup>، ماشین بردار پشتیبان یا SVM<sup>۵</sup>، ادابوست<sup>۶</sup> و همچنین شبکه عصبی کانولوشن یا CNN<sup>۷</sup> را بررسی کرده‌ایم. در این میان ویژگی‌های استخراج شده در کنار طبقه‌بندی‌کننده SVM توانسته است دقت تشخیص را نسبت به کارهای اخیر بهبود دهد.

بدون شک زمانی یک سیستم تشخیص مبتنی بر گوشی هوشمند ارزش عمومی پیدا می‌کند که بتواند بر روی هر بستر تبلت یا مدل‌های مختلف تلفن همراه کارایی مناسبی داشته باشد. این مسئله در حالی است که سیگنال‌های ثبت شده توسط سنسورهای ژيروسکوپ و شتاب‌سنج در گوشی‌های هوشمند با نویز همراه بوده و کیفیت این سیگنال‌ها می‌تواند از یک مدل گوشی به مدل دیگر و حتی در گوشی‌ها از یک مدل نیز متغیر باشد [۱۳].

برای آن که بتوان تأثیر نویز بر روی سیستم تشخیص فعالیت فیزیکی را ارزیابی نمود، در این مقاله علاوه بر داده‌های اصلی، داده‌های آغشته به نویز با سطوح مختلف تولید شده و میزان تأثیر آن بر روی سیستم تشخیص فعالیت فیزیکی انسان نیز ارزیابی شده است. به این منظور علاوه بر بحث در خصوص کارایی طبقه‌بندی‌کننده‌ها در سطوح مختلف نویز، میزان پایداری آنها در این رابطه نیز تحلیل شده است.

در ادامه مقاله در بخش ۲ به توضیح ساختار کلی سیستم پیشنهادی تشخیص فعالیت فیزیکی انسان و توصیف هر یک از بخش‌های آن پرداخته شده است. سپس در بخش ۳ نتایج ارائه گردیده و ارزیابی و تحلیل آنها آمده و نهایتاً در بخش آخر، نتیجه‌گیری و کارهای آینده پیشنهاد شده است.

1. Mutual Information
2. Minimum Redundancy Maximum Relevance
3. Principle Component Analysis
4. Logistic Regression
5. Support Vector Machine
6. Adaboost
7. Convolutional Neural Network

8. White Noise

مقابل یک<sup>۵</sup> که کارایی مناسبی را برای طبقه‌بندی چندکلاسه از خود نشان نشان داده است استفاده کرده‌ایم [۱۵] و [۱۶].

### ۲-۴-۲ رگرسیون منطقی

طبقه‌بندی‌کننده رگرسیون منطقی به صورت موفقیت‌آمیزی در کاربردهای مختلف استفاده شده است. این طبقه‌بندی‌کننده سعی می‌کند تا تابع احتمال پسین هر کلاس را با استفاده از تابع سافت‌مکس<sup>۶</sup> تخمین زده و کلاس با بیشترین احتمال را انتخاب کند [۱۷].

### ۲-۴-۳ ادابوست

ترکیب چند طبقه‌کننده ممکن است بتواند کارایی یک سیستم طبقه‌بندی را افزایش دهد. از معروف‌ترین و کاراترین طبقه‌بندی‌کننده‌های ترکیبی که در پژوهش‌های مختلف به کار گرفته شده، ادابوست است. این طبقه‌بندی‌کننده از ترکیب چند طبقه‌بندی‌کننده ساده و ضعیف برای ساخت یک طبقه‌بندی‌کننده قوی‌تر استفاده می‌کند [۱۸]. در اینجا از طبقه‌بند ریشه تصمیم<sup>۷</sup> که به کمک تعیین آستانه برای هر ویژگی، طبقه‌بندی را انجام می‌دهد، به عنوان طبقه‌بند ضعیف استفاده شده است [۱۹].

### ۲-۴-۴ شبکه عصبی کانولوشنال

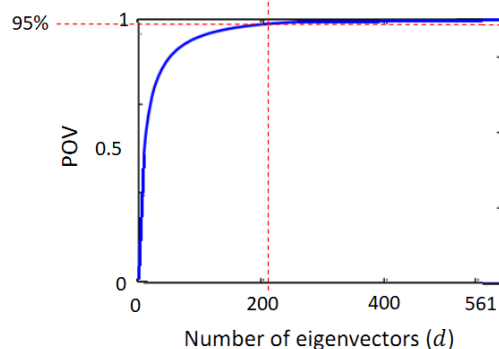
در سال‌های اخیر شبکه‌های عصبی عمیق به صورت موفق در کاربردهای مختلفی از جمله شناسایی و تشخیص نواحی خاص در تصویر [۲۰]، بخش‌بندی تصاویر [۲۱] و بازیابی تصاویر [۲۲] استفاده شده است. این شبکه برای تشخیص فعالیت‌های فیزیکی انسان بر مبنای گوشی‌های هوشمند نیز به کار گرفته شده [۸] و در اینجا کارایی این طبقه‌بندی‌کننده برای تشخیص در نوزدهای مختلف نیز بررسی شده است. شبکه عصبی کانولوشنال از یک سری لایه‌های کانولوشن و ادغام<sup>۸</sup> تشکیل شده است. خروجی این لایه‌ها به لایه آخر متصل می‌شود که به تعداد کلاس‌های مسئله دارای نرون بوده و به صورت اتصال کامل به خروجی لایه قبل متصل هستند. خروجی لایه آخر نوع کلاس داده ورودی را مشخص خواهد کرد [۲۳] و [۲۴].

در اینجا از سیگنال‌های ژيروسکوپ و شتاب‌سنج در سه محور  $x$ ،  $y$  و  $z$  که به صورت یک سری زمانی در طول زمان نمونه‌برداری شده‌اند نیز به عنوان ورودی شبکه کانولوشنال استفاده شده است. عملیات کانولوشن می‌تواند به طور مؤثری وابستگی زمانی-محلی<sup>۹</sup> سیگنال‌های سری زمانی را استخراج کرده و عملیات پولینگ، اثر حرکت‌های کوچک<sup>۱۰</sup> در ورودی را لغو می‌کند. بنابراین با استفاده از یک شبکه عصبی کانولوشنال چندلایه که میان لایه‌های آن پولینگ قرار دارد می‌توان ویژگی‌ها را به صورت خودکار از داده‌های حسگر سری زمانی خام استخراج کرد. در این حالت لایه‌های کمتر منجر به استخراج ویژگی‌های ساده‌تر و لایه‌های بالاتر ویژگی‌های پیچیده را استخراج خواهند کرد.

## ۳- تحلیل و ارزیابی نتایج

مجموعه داده استفاده‌شده برای ارزیابی روش‌ها، مجموعه داده معروف

5. One-vs-One
6. Softmax
7. Decision Stumps
8. Pooling
9. Temporally-Local Dependency
10. Small Translations



شکل ۲: چگونگی انتخاب تعداد ویژگی‌ها در هنگام کاهش بعد.

### ۲-۳ کاهش ابعاد ویژگی

یکی از روش‌های متداول در کاهش ابعاد ویژگی‌ها روش تحلیل مؤلفه‌های اصلی یا PCA است. این روش بر اساس مقادیر ویژه<sup>۱</sup> ماتریس کواریانس، داده‌ها را به گونه‌ای به فضای با بعد پایین‌تر نگاشت می‌کند که میزان پخشش داده‌ها در فضای جدید، بیشترین مقدار ممکن را به همراه داشته باشد. در فضای جدید ویژگی‌ها نسبت به یکدیگر ناهمبسته<sup>۲</sup> خواهند بود. برای انتخاب تعداد ویژگی‌های در فضای جدید از نسبت مجموع مقادیر ویژه از رابطه زیر استفاده شده است

$$POV = \frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^D \lambda_i} \quad (1)$$

که در این رابطه  $\lambda_i$  مقادیر ویژه،  $D$  تعداد کل ویژگی‌ها (۵۶۱) و  $d$  تعداد ویژگی‌ها در فضای جدید می‌باشد. برای انتخاب  $d$  مقدار  $POV$  برابر با ۹۵٪ در نظر گرفته شده است. به عبارتی تعداد ویژگی‌های به گونه‌ای انتخاب شده است (از بزرگ‌ترین مقدار ویژه تا کوچک‌ترین آن) که ۹۵ درصد مقادیر ویژه را دربرداشته باشند. شکل ۲ این فرایند را به صورت شماتیک نشان می‌دهد.

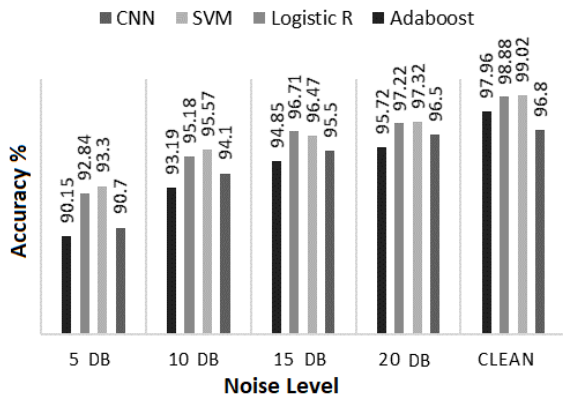
### ۲-۴ کاهش ابعاد ویژگی

پس از استخراج ویژگی، جهت مشخص کردن نوع فعالیت، بردار ویژگی به طبقه‌بندی‌کننده داده می‌شود. در اینجا عملکرد طبقه‌بندی‌کننده‌های مختلف با به کارگیری ویژگی‌های استخراج‌شده در مرحله قبل و در سطوح مختلف نويز ارزیابی شده تا مناسب‌ترین طبقه‌بندی‌کننده مشخص شود. با توجه به تجربه نویسندگان مقاله در پژوهش‌های یادگیری ماشین و همچنین با توجه به کارهای پیشین انجام‌شده در این حوزه، نحوه عملکرد طبقه‌بندی‌کننده‌های زیر بررسی و نتایج آن مورد بحث قرار گرفته‌اند.

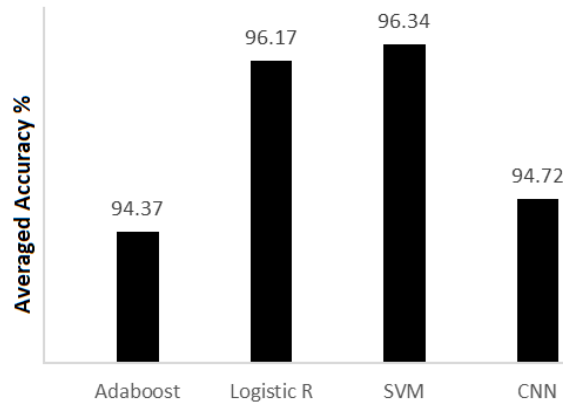
### ۲-۴-۱ ماشین بردار پشتیبان

این طبقه‌بندی‌کننده سعی می‌کند داده‌های دو کلاس را به گونه‌ای از یکدیگر جدا کند که بیشترین حاشیه<sup>۳</sup> از خط جداکننده تا داده‌های دو کلاس حاصل شود. به همین علت ماشین بردار پشتیبان معروف به داشتن عمومیت<sup>۴</sup> در داده‌ها است [۱۵]. در اینجا از طبقه‌بندی‌کننده یک در مقابل

1. Eigen Values
2. Uncorrelated
3. Margin
4. Generalization



شکل ۳: مقایسه روش‌های تشخیص فعالیت در سطوح نویز مختلف.



شکل ۴: میانگین دقت طبقه‌بندی‌کننده‌ها در سطوح نویز مختلف.

[۱] و این داده‌ها به عنوان ورودی به CNN داده شده تا ویژگی‌های مناسب به صورت بدون نظارت توسط شبکه استخراج گردد.

جدول ۱ نتایج مربوط به این روش‌ها را نشان می‌دهد. مشابه پژوهش‌های پیشین برای مقایسه الگوریتم‌ها از معیار دقت طبقه‌بندی استفاده شده است. در این جدول اولین - بهترین نتیجه به صورت زیرخطدار و برجسته نشان داده شده است. نتایج به دست آمده نشان می‌دهند که شبکه CNN در حالت استفاده از سیگنال‌های خام (CNN) نسبت به ویژگی‌های استخراج‌شده توسط PCA به نتیجه بهتری دست یافته است، با این حال CNN نسبت به سایر روش‌ها دقت کمتری داشته است. در مجموع ویژگی‌های استخراج‌شده توسط PCA به همراه طبقه‌بندی‌کننده SVM بهترین دقت را نسبت به روش‌های این مقاله و مقاله‌های پیشین به همراه داشته است.

جهت ارزیابی میزان پایداری هر طبقه‌بندی‌کننده نسبت به نویزهای مختلف، نحوه عملکرد طبقه‌بندی‌کننده‌ها در سطوح مختلف نویز نیز بررسی شده که نتایج آن در شکل ۳ آمده است. نتایج نشان می‌دهند که در سطوح مختلف نویز نیز طبقه‌بندی‌کننده SVM بالاترین دقت را داشته و پس از آن طبقه‌بندی‌کننده LR با اندکی تفاوت به دقت بالاتری نسبت به سایر طبقه‌بندی‌کننده‌ها دست یافته است. به طور کلی می‌توان دید که هرچه شدت نویز بیشتر شده، برتری دقت طبقه‌بندی‌کننده LR و به خصوص SVM بیشتر نمایان شده است. در مقابل نتایج نشان می‌دهند که دو طبقه‌بندی‌کننده Adaboost و CNN عملکرد ضعیف‌تری داشته‌اند و در مجموع در داده‌های نویزی طبقه‌بندی‌کننده Adaboost پایین‌ترین دقت را به همراه داشته است.

برای مقایسه بهتر، در شکل ۴ میانگین نتایج هر طبقه‌بندی‌کننده در نویزهای مختلف نیز نشان داده شده است. همان طور که میانگین دقت طبقه‌بندی‌کننده‌ها نیز نشان می‌دهد SVM به بهترین دقت با میانگین

جدول ۱: مقایسه با روش‌های اخیر.

روش‌ها	دقت طبقه‌بندی (%)
Silva, et al. [۱۲]	۸۶
IBk	۹۹
J۴۸	۹۷
JRip	۹۷
NaiveBayes	۸۴
OVO	۹۶
OVA	۹۴
K-NN	۹۰
Convnet+MLP	۹۴٫۷۹
tFFT+Convnet	۹۵٫۷۵
MRMR+SVM	۹۵٫۱۵
GA+SVM	۹۶٫۳۸
PCA+SVM	<u>۹۹٫۰۲</u>
PCA+LR	۹۸٫۸۸
PCA+Adaboost	۹۷٫۹۶
PCA+CNN	۹۵٫۲۰
CNN	۹۶٫۸۰

HAR است که به صورت عمومی در دسترس می‌باشد. در این پایگاه داده آزمایش‌هایی بر روی یک گروه ۳۰ نفره از داوطلبان، با سنین ۱۹ الی ۴۸ ساله، انجام شده و تعداد ۱۰۲۹۹ داده جمع‌آوری شده است. هر شخص در حالی که گوشی هوشمند (Samsung Galaxy S II) به دور کمر وی متصل شده است، شش فعالیت را انجام می‌دهد. این فعالیت‌ها عبارتند از راه‌رفتن، از پله بالا رفتن، از پله پایین آمدن، نشستن، ایستادن و دراز کشیدن. با استفاده از شتاب‌سنج وژیروسکوپ‌های نهفته گوشی هوشمند اطلاعات شتاب و گشتاور در سه راستای  $x$ ،  $y$  و  $z$  ثبت شده‌اند. برای ارزیابی یکسان پژوهش‌های مختلف، این مجموعه داده به صورت تصادفی به دو بخش مجموعه داده‌های آموزش (۷۰٪) و مجموعه داده‌های آزمون (۳۰٪) تقسیم شده است. در تمامی آزمایش‌ها، ابرپارامترهای هر یک از طبقه‌بندی‌کننده‌ها با به کارگیری ارزیابی متقابل مشخص شده و در نهایت طبقه‌بندی بر روی داده‌های آزمون با به کارگیری بهترین ابرپارامتر هر طبقه‌بندی‌کننده انجام شده است.

در ابتدا عملکرد چهار طبقه‌بندی‌کننده ماشین بردار پشتیبان SVM [۱۵]، رگرسیون منطقی LR [۱۷]، ادابوست Adaboost [۱۹] و شبکه عصبی کانولوشنالی CNN [۲۳] و [۲۴] نسبت به یکدیگر و نسبت به روش‌های پیشین مقایسه شده است. بر اساس ارزیابی متقابل انجام‌شده، ماشین بردار پشتیبان با  $c = ۵۷$  و  $\sigma = ۱۳$  به بهترین نتیجه خود دست یافته است. در شبکه عصبی کانولوشنالی از سه لایه کانولوشن که بعد از هر کدام از آنها لایه پولینگ و حذف تصادفی<sup>۲</sup> قرار دارد، استفاده شده و در نهایت به وسیله سه لایه متراکم کلاس‌بندی انجام شده است. در اینجا دو حالت ورودی برای شبکه عصبی کانولوشنالی ارزیابی شده است. در حالت اول مشابه سایر طبقه‌بندی‌کننده‌ها، ویژگی‌های به دست آمده بعد از اعمال PCA به عنوان ورودی شبکه CNN در نظر گرفته شده است. در حالت دوم از سیگنال‌های یک‌بعدی ژيروسکوپ و شتاب‌سنج در سه محور  $x$ ،  $y$  و  $z$  (جمعاً ۶ کانال) با نرخ ۱۲۸ نمونه‌برداری شده

1. <https://archive.ics.uci.edu/ml/datasets.html>

2. Dropout

- ACM Int. Joint Conf. on Pervasive and Ubiquitous Computing, pp. 1011-1015, Osaka, Japan, 7-11 Sept. 2015.
- [10] C. A. Ronao and S. B. Cho, "Human activity recognition with smartphone sensors using deep learning neural networks," *Expert Syst. Appl.*, vol. 59, no. 1, pp. 235-244, Oct. 2016.
- [11] D. N. Tran and D. D. Phan, "Human activities recognition in android smartphone using support vector machine," in *Proc. IntConf. on Intelligent Systems, Modelling and Simulation, ISMS'17*, pp. 64-68, Bangkok, Thailand, 25-27 Jan. 2016.
- [12] J. Silva, M. Monteiro, and F. Sousa, "Human activity classification with inertial sensors," *Studies in Health Technology and Informatics*, vol. 200, no. 1, pp. 101-104, Jun. 2014.
- [13] A. Kos, S. Tomazic, and A. Umek, "Evaluation of smartphone inertial sensor performance for cross-platform mobile applications," *Sensors (Switzerland)*, vol. 16, no. 4, pp. 477-492, Apr. 2016.
- [14] K. Nirmal, et al., "Noise modeling and analysis of an IMU-based attitude sensor: improvement of performance by filtering and sensor fusion," *Advances in Optical and Mechanical Technologies for Telescopes and Instrumentation II*, vol. 9912, no. 1, pp. 1-10, Jul. 2016.
- [15] C. K. I. Williams, "Learning with kernels: support vector machines, regularization, optimization, and beyond," *J. Am. Stat. Assoc.*, vol. 98, no. 462, pp. 489-489, Jun. 2003.
- [16] M. Galar, A. Fernandez, E. Barrenechea, H. Bustince, and F. Herrera, "An overview of ensemble methods for binary classifiers in multi-class problems: experimental study on one-vs-one and one-vs-all schemes," *Pattern Recognition*, vol. 44, no. 8, pp. 1761-1776, Aug. 2011.
- [17] C. J. Lin, R. C. Weng, and S. Sathya Keerthi, "Trust region Newton method for large-scale logistic regression," *J. of Machine Learning Research*, vol. 9, no. 7, pp. 627-650, Jun. 2007.
- [18] Y. Freund and R. E. Schapire, "Experiments with a new boosting algorithm," in *Proc. Int Conf. on Machine Learning*, vol. 96, pp. 148-156, Bari, Italy, 3-6 Jul. 1996.
- [19] W. Iba Ai and P. Langley, "Induction of one-level decision trees," in *Proc. of 9th Int. Conf. on Machine Learning*, vol. 1, pp. 233-240, Aberdeen, Scotland, 1-3 Jul. 1992.
- [20] S. U. Khan, N. Islam, Z. Jan, I. Ud Din, and J. J. P. C. Rodrigues, "A novel deep learning based framework for the detection and classification of breast cancer using transfer learning," *Pattern Recognit. Letter*, vol. 125, no. 1, pp. 1-6, Jul. 2019.
- [21] X. Zhao, Y. Wu, G. Song, Z. Li, Y. Zhang, and Y. Fan, "A deep learning model integrating FCNNs and CRFs for brain tumor segmentation," *Medical Image Analysis.*, vol. 43, no. 1, pp. 98-111, Jan. 2018.
- [22] L. Wang, X. Qian, Y. Zhang, J. Shen, and X. Cao, "Enhancing sketch-based image retrieval by CNN semantic re-ranking," *IEEE Trans. Cybern.*, vol. 50, no. 7, pp. 3330-3342, Jul. 2020.
- [23] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi, "A survey of deep neural network architectures and their applications," *Neurocomputing*, vol. 234, no. 1, pp. 11-26, Apr. 2017.
- [24] J. Schmidhuber, "Deep learning in neural networks: an overview," *Neural Networks*, vol. 61, no. 1, pp. 85-117, Jan. 2015.
- [25] B. Romera-Paredes, M. S. H. Aung, and N. Bianchi-Berthouze, "A one-vs-one classifier ensemble with majority voting for activity recognition," in *Proc. 21st European Symp on Artificial Neural Networks, Computational Intelligence and Machine Learning*, pp. 443-448, Bruges, Belgium, 24-26 Apr. 2013.
- [26] T. D. T. Nguyen, T. T. Huynh, and H. A. Pham, "An improved human activity recognition by using genetic algorithm to optimize feature vector," in *Proc. 10th Int. Conf. on Knowledge and Systems Engineering, KSE'18*, pp. 123-128, pp. 123-128, Ho Chi Minh City, Vietnam, 1-3 Nov. 2018.

**مهدی یزدیان دهکردی** مدرک کارشناسی مهندسی کامپیوتر گرایش نرم‌افزار را در سال ۱۳۸۵ از دانشگاه یزد و مدرک کارشناسی ارشد و دکترای خود را به ترتیب در سال‌های ۱۳۸۸ و ۱۳۹۴ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه شیراز اخذ کرد. ایشان از سال ۱۳۹۴ در بخش هوش مصنوعی دانشکده مهندسی کامپیوتر دانشگاه یزد مشغول به فعالیت گردید و اینک نیز عضو هیأت علمی این دانشکده است. زمینه‌های پژوهشی مورد علاقه ایشان یادگیری ماشین، یادگیری عمیق و بینایی ماشین است.

**زهرا عابدی** در سال ۱۳۹۲ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه فسا و در سال ۱۳۹۷ مدرک کارشناسی ارشد مهندسی کامپیوتر گرایش هوش مصنوعی خود را از دانشگاه یزد دریافت نمود. زمینه‌های علمی مورد علاقه نامبرده متنوع بوده و شامل موضوعاتی مانند پردازش تصویر، بینایی ماشین و یادگیری ماشین است.

۹۶/۳۴٪ و طبقه‌بندی‌کننده Adaboost به پایین‌ترین دقت با میانگین ۹۴/۳۷٪ رسیده است. نکته قابل تأملی که در نتایج مشاهده می‌شود، عملکرد ضعیف‌تر طبقه‌بندی‌کننده CNN نسبت به SVM و LR است. در این خصوص می‌توان گفت که به طور کلی شبکه‌های CNN نسبت به سایر طبقه‌بندی‌کننده‌ها به تعداد داده‌های زیادتری برای آموزش ایده‌آل نیاز دارند. در اینجا با توجه به زیادنبودن تعداد داده‌ها برای آموزش ایده‌آل شبکه CNN، این طبقه‌بندی‌کننده کارایی پایین‌تری را داشته است.

## ۴- نتیجه‌گیری و جمع‌بندی

در این مقاله استخراج ویژگی مبتنی بر تحلیل مؤلفه‌های اساسی و همچنین کارایی طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان، رگرسیون منطقی، ادابوست و شبکه عصبی کانولوشن به منظور ارائه یک سیستم کارا برای تشخیص فعالیت انسان بر اساس داده‌های گرفته‌شده توسط ژيروسکوپ و شتابسنج در گوشی هوشمند مورد بررسی قرار گرفت. نتایج به دست آمده نشان داد که روش ماشین بردار پشتیبان توانسته است دقت بالاتری را نسبت به سایر روش‌های اخیر کسب نماید. کیفیت سیگنال‌های ثبت‌شده توسط سنسورهای گوشی هوشمند از یک مدل گوشی به مدل دیگر تفاوت زیادی می‌کند و با میزان نویزهای متفاوتی همراه است. بنابراین برای رسیدن به یک سیستم پایدار در مقابل نویز، کارایی طبقه‌بندی‌کننده‌ها در سطوح مختلف نویز نیز مورد بررسی قرار گرفت. نتایج به دست آمده نشان داد که طبقه‌بندی‌کننده ماشین بردار پشتیبان می‌تواند گزینه مناسبی برای داشتن یک سیستم کارا با پایداری مناسب در مقابل نویز برای تشخیص فعالیت انسان بر اساس داده‌های شتابسنج و ژيروسکوپ باشد.

## مراجع

- [1] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "A public domain dataset for human activity recognition using smartphones," in *Proc. 21st European Symp. on Artificial Neural Networks, Computational Intelligence and Machine Learning*, pp. 437-442, Bruges, Belgium, 24-26 Apr. 2013.
- [2] S. Sun, Z. Kuang, L. Sheng, W. Ouyang, and W. Zhang, "Optical flow guided feature: a fast and robust motion representation for video action recognition," in *Proc. of the IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, pp. 1390-1399, Salt Lake City, UT, USA, 18-22 Jun. 2018.
- [3] M. Safaei, P. Balouchian, and H. Foroosh, "TICNN: a hierarchical deep learning framework for still image action recognition using temporal image prediction," in *Proc. Int. Conf. on Image Processing, ICIP'18*, pp. 3463-3467, Athens, Greece, 7-10 Oct. 2018.
- [4] B. Kwon, J. Kim, K. Lee, Y. K. Lee, S. Park, and S. Lee, "Implementation of a virtual training simulator based on 360° multi-view human action recognition," *IEEE Access*, vol. 5, no. 1, pp. 12496-12511, Jul. 2017.
- [5] J. Cao, W. Li, C. Ma, and Z. Tao, "Optimizing multi-sensor deployment via ensemble pruning for wearable activity recognition," *Inf. Fusion*, vol. 41, no. 1, pp. 68-79, May 2018.
- [6] A. Doewes, S. E. Swasono, and B. Harjito, "Feature selection on human activity recognition dataset using minimum redundancy maximum relevance," in *Proc. IEEE Int. Conf. on Consumer Electronics-Taiwan*, pp. 171-172, Taipei, Taiwan, 12-14 Jun. 2017.
- [7] H. Martin, A. M. Bernardos, J. Iglesias, and J. R. Casar, "Activity logging using lightweight classification techniques in mobile devices," *Pers. Ubiquitous Comput.*, vol. 17, no. 4, pp. 675-695, Apr. 2013.
- [8] M. Shoaib, H. Scholten, and P. J. M. Havinga, "Towards physical activity recognition using smartphone sensors," in *Proc. IEEE 10th Int. Conf. on Ubiquitous Intelligence and Computing, and IEEE 10th Int. Conf. on Autonomic and Trusted Computing*, pp. 80-87, Vietri sul Mare, Italy, 18-21 Dec. 2013.
- [9] I. Suarez, A. Jahn, C. Anderson, and K. David, "Improved activity recognition by using enriched acceleration data," in *Proc. of the*

نسیبم خانی در سال ۱۳۹۳ مدرک کارشناسی مهندسی فناوری اطلاعات را از دانشگاه صنعتی شیراز و در سال ۱۳۹۷ مدرک کارشناسی ارشد مهندسی کامپیوتر گرایش هوش مصنوعی را از دانشگاه یزد دریافت نمود. زمینه‌های مورد علاقه ایشان شامل موضوعاتی مانند یادگیری ماشین، یادگیری عمیق و بینایی ماشین است.