

# Automatic and non-invasive method for Ischemic stroke detection using a novel time-frequency model of plantar pressure signals

Zahra Atrachali, Peyvand Ghaderyan\*

Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran.  
E-mails: Zahra.atrachali6@gmail.com ; p\_ghaderyan@sut.ac.ir

\* Means corresponding author

## Abstract

The occurrence of stroke is due to the sudden degeneration of brain cells, which is caused by the lack of oxygen supply to the cells due to vascular blockage or their rupture and the interruption of blood flow to the brain, which can lead to disability of motor organs, especially walking disorder. Currently, brain imaging including magnetic resonance imaging, computed tomography and cerebral angiography are the main standard for stroke diagnosis, which cannot provide a quick, economical and non-invasive diagnosis. In this regard, the development of automatic, reliable and cost-effective diagnostic algorithms is crucial. Therefore, in this article, with the aim of providing an automatic, non-invasive and low-cost diagnostic method for ischemic stroke, computerized analysis of the plantar pressure signal has been used. The proposed method is based on extracting new time-frequency features of the foot pressure signal with the help of Tunable Q-factor Wavelet Transform (TQWT), selection of ReliefF feature and Support Vector Machine (SVM) classification, K-Nearest Neighborhood (KNN) and Random Forest (RF). The main feature of the proposed method is the ability to extract fluctuating components and transient information of non-stationary plantar pressure signal with the help of a new time-frequency method and the possibility of adapting to its time-varying characteristics. In order to check the diagnostic accuracy of the proposed method, the foot pressure signal data set of patients suffering from ischemic stroke while walking in a circular hallway has been used, which includes 46 healthy subject and 36 patients. The obtained results have shown the high diagnostic capability of the proposed method with the number of 35 simple statistical features with an average accuracy of 99.77%. Considering the significant diagnostic accuracy along with the low-cost and computational burden of the extracted simple statistical features, the proposed method is able to provide a suitable compromise between high diagnostic accuracy and low computational cost, which seems suitable for practical diagnostic applications.

## Keywords

Tunable q-factor wavelet transform, random forest, reliefF feature selection, machine learning

## Introduction

Stroke is the third leading cause of disability worldwide that permanently affects patients' walking patterns and limits their function and social interaction [1]. Therefore, early detection of stroke and its timely treatment are crucial for survival and functional improvement of patients [2]. Since stroke detection methods such as brain imaging, CT scan and cerebral angiography, etc. are expensive, time-consuming, or invasive, developing a system with features such as availability and low cost along with high time resolution and the non-invasive nature has been taken into consideration for accurate and clinical diagnosis in recent years. In this regard, the use of physiological signals such as the walking signal, which are non-invasive, available and low-cost, is suggested [3]. A review of past studies shows that a limited number of features have been used to extract the pathological effects of stroke on the gait signal. These features, which are mostly limited to simple features in the domain of time, may not be able to quantify all the effects of the disease due to the non-static and non-linear nature of changes in the walking pattern of a person. Most studies have focused on the use of statistical analysis methods, which face limitations due to their limited view of the mean or average of the data. Therefore, the next step of studies can be focused on developing the use of machine learning methods for automatic and computerized diagnosis of stroke with the help of extracting time-frequency characteristics or a higher level of the walking signal. For this reason, this study has proposed a new stroke detection system based on time-frequency domain features of plantar pressure signals and three different classifiers SVM, KNN and RF.

## Proposed Work and Methodology

Since stroke occurs in the elderly and affects the lower motor organs of these people, the main goal of this research is to provide a new and reliable computer system for automatic diagnosis and assessment of stroke, which is non-invasive and low cost is based on the recognition of the signal pattern of changes in foot pressure. To achieve this goal, the foot pressure signal has been evaluated and analyzed with the help of pattern recognition methods. Firstly, in order to evaluate and analyze pressure changes in different areas, the sole is divided into the areas of the heel, mid-foot, metatarsal (region 1, region 2 and region 3), toe and finger region [4]. In order to minimize the effects of the start and end of the movement, 10 seconds at the beginning and end of the signal have been removed [5]. Then, disaggregated pressure signals in different areas are divided into successive and non-overlapping 50 second windows using the windowing technique and used for feature extraction. Then, in order to reveal the effects of stroke on the function of the lower limbs of stroke patients, TQWT, which is a time-frequency transform to separate the fluctuating components of the signal, has been used. Next, in order to simplify the classification process and remove unnecessary features, the ReliefF feature selection technique has been used. Finally, by using three classifiers SVM, KNN, RF, healthy people have been separated from stroke patients. In this study, 46 healthy people and 36 stroke patients participated, and these people walked in a circular hallway for 12 minutes [6]. The pressure parameters were recorded by the Pedar directory system using insoles with 99 pressure-sensitive sensors with a sampling frequency of 50 Hz. The obtained results have shown that the proposed TQWT can accurately detect ischemic stroke with an average accuracy of 99.77%.

## Conclusion

Analysis of walking in a circular path compared to a straight path, the possibility of examining more realistic walking modes of people, especially stroke patients who are made possible by health maintenance issues. In this article, time-frequency information of the processed foot pressure signal has been extracted using TQWT algorithm. Then, in order to check the distribution of pressure in different regions of the soles, 99 sensors in the soles are divided into 7 different regions. Next, in order to improve the classification accuracy and reduce the training time, ReliefF feature selection technique was used and finally the three mentioned classifications were used. The obtained results show the high efficiency of this method in automatic, non-invasive and cost-effective diagnosis of ischemic stroke.

## تشخیص خودکار و غیرتهاجمی سکتهمغزی با استفاده از یک مدل جدید زمانی-فرکانسی سیگنال فشار کف پا

زهرا اتراچالی

دانشجوی کارشناسی ارشد، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

پیوند قادیان

دانشیار، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

چکیده

وقوع بیماری سکتهمغزی به دلیل انحطاط ناگهانی سلول‌های مغزی است که این مساله ناشی از کمبود اکسیژن-رسانی به سلول‌ها در اثر انسداد عروقی و یا پارگی آن‌ها و قطع جریان خون به مغز است که می‌تواند منجر به ناتوانی اندام‌های حرکتی به خصوص اختلال در راه رفتن شود. در حال حاضر، تصویربرداری‌های مغزی شامل تصویربرداری رزونانس مغناطیسی، توموگرافی کامپیوتری و آنژیوگرافی مغزی استاندارد اصلی تشخیص سکتهمغزی هستند که نمی‌توانند یک تشخیص سریع، اقتصادی و غیرتهاجمی را تامین کنند. در این راستا توسعه الگوریتم‌های تشخیصی خودکار، قابل اعتماد و مقرون به صرفه حائز اهمیت است. از این رو، در این مطالعه با هدف ارائه روش تشخیصی خودکار، غیرتهاجمی و کم هزینه برای سکتهمغزی ایسکمیک از تحلیل کامپیوتری سیگنال فشار کف پا استفاده شده است. روش پیشنهادی مبتنی بر استخراج ویژگی‌های جدید زمانی-فرکانسی سیگنال فشار کف پا به کمک تجزیه موجک عامل Q قابل تنظیم، انتخاب ویژگی ReliefF و طبقه‌بندی ماشین بردار پشتیبان، K-نزدیک‌ترین همسایگی و جنگل تصادفی می‌باشد. ویژگی اصلی روش پیشنهادی قابلیت استخراج اجزای نوسانی و اطلاعات گذرای سیگنال غیرایستای فشار کف پا به کمک یک روش جدید زمانی-فرکانسی و امکان انطباق با خصوصیات متغیر با زمان آن می‌باشد. جهت بررسی صحت تشخیصی روش پیشنهادی از مجموعه داده‌های سیگنال فشار بیماران مبتلا به سکتهمغزی ایسکمیک در حین راه رفتن در یک مسیر دایره‌ای استفاده شده است که شامل ۴۶ فرد سالم و ۳۶ بیمار می‌باشد. نتایج بدست آمده قابلیت تشخیصی بالای روش پیشنهادی را با تعداد ۳۵ ویژگی ساده آماری با میانگین صحت ۹۹/۷۷٪ نشان داده‌اند. با در نظر گرفتن دقت تشخیصی قابل توجه در کنار هزینه و بارمحاسباتی پایین ویژگی‌های ساده آماری استخراج شده، روش پیشنهادی قادر به ارائه مصالحه مناسب بین صحت تشخیصی بالا و هزینه محاسباتی پایین می‌باشد که برای کاربردهای عملی تشخیصی مناسب به نظر می‌رسد.

کلمات کلیدی

تجزیه موجک عامل Q قابل تنظیم، جنگل تصادفی، انتخاب ویژگی ReliefF، یادگیری ماشین.

نام نویسنده مسئول: دکتر پیوند قادیان

ایمیل نویسنده مسئول: p\_ghaderyan@sut.ac.ir

تاریخ ارسال مقاله: ۱۴۰۳/۰۷/۱۰

تاریخ(های) اصلاح مقاله: ۱۴۰۳/۰۹/۲۱

تاریخ پذیرش مقاله: ۱۴۰۳/۱۰/۲۶

### ۱- مقدمه

های پزشکی آنان شود. جهت ارزیابی و تشخیص سکتهمغزی از روش‌های متعددی تاکنون استفاده شده است که از جمله مهم‌ترین آن‌ها می‌توان به تصویربرداری‌های مغزی شامل تصویربرداری رزونانس مغناطیسی، توموگرافی کامپیوتری، آنژیوگرافی مغزی و همچنین ارزیابی فعالیت حرکتی و یا عصبی افراد به کمک سیگنال‌های پزشکی اشاره نمود [۱۲، ۱۳]. تصویربرداری‌های پزشکی در کنار آنژیوگرافی مغزی که شواهدی از اندازه و محل ضایعه ایسکمیک یا هموراژیک را ارائه می‌دهد، غالباً پرهزینه و یا تهاجمی هستند، این در حالی است که استفاده از سیگنال‌های پزشکی مانند سیگنال راه رفتن امکان ارزیابی کم‌هزینه، غیرتهاجمی، کلینیکی و قابل دسترس را با رزولوشن زمانی بالا فراهم می‌آورند [۱۲، ۱۳]. از این رو، توجه این مطالعه به استفاده از سیگنال راه رفتن به عنوان یک ابزار غیرتهاجمی و در دسترس با قابلیت اطمینان بالا جهت تشخیص خودکار سکتهمغزی معطوف شده است.

مطالعات پیشین متعددی، بروز اختلال و تغییرات غیرطبیعی در نحوه راه رفتن فرد مانند عدم پایداری و عملکرد حرکتی محدود را به عنوان یک نقص شایع عصبی در افراد مبتلا به سکتهمغزی آشکار کرده‌اند [۱۴، ۱۵]. همچنین

سکتهمغزی یک بیماری شایع عصبی است که سالانه حدود ۱۳/۷ میلیون نفر در جهان دچار آن می‌گردند [۷، ۸]. این بیماری یکی از عوامل اصلی مرگ و میر، ناتوانی و اختلالات عصبی در جمعیت جهان به خصوص در کشورهای بزرگ و توسعه یافته می‌باشد [۷، ۹]. سکتهمغزی را می‌توان به دو نوع سکتهمغزی ایسکمیک که به دلیل انسداد عروق خونی و سکتهمغزی هموراژیک که به دلیل خونریزی رخ می‌دهد، تقسیم‌بندی نمود که ۸۰ درصد از موارد رخ داده سکتهمغزی، مربوط به نوع ایسکمیک و ۲۰ درصد آن از نوع هموراژیک می‌باشد [۱۰]. ناتوانی‌های رایج پس از سکتهمغزی شامل اختلالات حرکتی مانند همی-پارزی (ضعف سمت چپ یا راست بدن)، همی‌پلژی (فلج در سمت چپ یا راست بدن) و فلج مرکزی صورت می‌باشند که می‌توانند تأثیرات قابل توجهی بر انجام فعالیت‌های روزمره و کیفیت زندگی بیماران داشته باشند [۱۱]. بنابراین تشخیص دقیق و به موقع این بیماری، می‌تواند منجر به دسترسی بیمار به راهکارهای درمانی موثر، اتخاذ تصمیمات درست در مورد روش‌های توانبخشی و بهبود عملکرد اندام حرکتی این افراد و در نتیجه مدیریت بهتر زمان و هزینه-

از آنجایی که بیشتر اطلاعات و مشخصه‌های سیگنال‌های متغیر با زمان و غیرایستای پزشکی در اجزای گذرا و محلی آن‌ها نهفته است [۱۸، ۳۱]. تجزیه کردن این سیگنال‌ها و انتقال آنها به حوزه زمان-فرکانس امکان شناسایی رفتارهای پیچیده و پنهان سیگنال و همچنین تفکیک اجزای همپوشان آنها را به شکل دقیقی فراهم می‌سازد [۱۸]. از این روش استخراج ویژگی از ضرایب توام زمان-فرکانسی، با استفاده از مزیت‌های استفاده از اطلاعات مکمل و توام زمان-فرکانسی و امکان غلبه بر محدودیت ویژگی تک حوزه‌ها، می‌تواند عملکرد بالاتری را برای بازشناسی الگوی سیگنال‌های غیرخطی و غیرایستا فراهم آورد [۳۰]. در این راستا، تجزیه موجک از جمله معمول‌ترین رویکردهای زمان-فرکانسی است که در سال‌های اخیر مورد توجه قرار گرفته است، ولی از معایب آن می‌توان به عدم امکان تنظیم فاکتور کیفیت و چالش انتخاب شکل موجک مادر اشاره نمود که این مسئله ممکن است باعث عدم شناسایی تمامی الگوهای گذرا به دلیل تفاوت در اطلاعات فرکانسی شود [۳۰، ۳۲، ۳۳]. جهت مواجهه با این محدودیت‌ها در سال‌های اخیر یک رویکرد زمان-فرکانسی بنام تکنیک تجزیه موجک عامل  $Q$  قابل تنظیم<sup>۱</sup> ارائه شده است که روشی موثر و پارامتریک برای استخراج اجزای نوسانی سیگنال‌های غیرایستا می‌باشد [۳۴]. از مزیت‌های این روش می‌توان به امکان تنظیم فاکتور کیفیت مطابق با نوسان سیگنال، استخراج نوسانات سیگنال و اطلاعات توام زمان-فرکانس و مشخصه‌های محلی سیگنال اشاره نمود [۳۵، ۳۶]. علاوه بر این، در مقایسه با سایر روش‌ها، روش تجزیه موجک عامل  $Q$  قابل تنظیم یک روش ساده با پیچیدگی محاسباتی کم و عملکرد سریع می‌باشد [۳۶]. در این روش می‌توان پارامترهای ورودی را مطابق با نوسانات و رفتار سیگنال ورودی تنظیم نمود تا امکان ارائه نمایش مناسبی از سیگنال‌های نوسانی فراهم گردد. از این رو در این مطالعه جهت کمی‌سازی تغییرات پاتولوژیک در راه رفتن بیماران مبتلا به سکتهمغزی، از یک روش جدید استخراج ویژگی زمان-فرکانس مبتنی بر تجزیه موجک عامل  $Q$  قابل تنظیم که امکان کمی‌سازی نوسانات موجود در فشار کف پا در زمان‌ها و فرکانس‌های مختلف می‌دهد را برای تشخیص کامپیوتری و مقرون به صرفه سکتهمغزی استفاده شده است.

بعد از مرحله استخراج ویژگی فشار کف پا، گام نهایی تحلیل قدرت تفکیک-پذیری ویژگی‌های استخراج شده جهت تصمیم‌گیری در مورد وضعیت سلامت افراد می‌باشد. مطالعاتی که در راستای تجزیه و تحلیل سیگنال فشار کف پا به منظور تشخیص بیماری سکتهمغزی انجام شده‌اند، به صورت کلی از دو روش (۱) ارزیابی به کمک تحلیل آماری و (۲) تصمیم‌گیری مبتنی بر الگوریتم‌های یادگیری ماشین استفاده نموده‌اند [۳۰]. مرور کلی روش‌های ارائه شده در این زمینه نشان می‌دهد که تعداد بسیار زیادی از این مطالعات بعد از استخراج ویژگی فشار کف پا از آزمون‌های آماری مختلفی مانند آزمون من-ویتنی [۱۴، ۳۷، آزمون شاپیرو ویلک [۳۸]، آزمون‌های کروسکال-والیس [۱۴]، آزمون‌های تحلیل واریانس [۱۹-۲۱، ۲۳، ۳۸، ۳۹]، آزمون‌های سری  $t$  [۱۹-۲۵، ۲۱، ۳۸]، آزمون رتبه بندی ویلکاکسون [۱۴، ۲۷]، ضریب همبستگی پیرسون [۳۹]، آزمون‌های بونفرونی پست هاک [۱۴، ۲۱، ۳۸]، همبستگی‌های رتبه اسپیرمن [۱۴]، ضریب تغییر [۲۰] استفاده نموده‌اند. از آنجایی که هدف بیشتر این روش‌ها، بررسی تفاوت موجود در میانه و یا میانگین ویژگی‌های استخراج شده از سری‌های زمانی در دو گروه می‌باشد [۳۰، ۴۰، ۴۱] و کل محدوده تغییرات داده‌ها در بسیاری از این روش‌ها مورد توجه قرار نمی‌گیرد، این آزمون‌ها امکان پیش‌بینی و تشخیص‌های دقیقی را ارائه نمی‌دهند [۳۰]. جهت رفع این محدودیت‌ها، در سال‌های اخیر استفاده از روش‌های یادگیری ماشین به عنوان یکی از ابزارهای مفید جهت تجزیه و تحلیل خودکار داده‌های راه رفتن [۴۱]،

ریسک بیشتر بروز مشکلات حرکتی در میچ و قسمت انتهایی پا نسبت به لگن و زانو در مطالعات دیگری گزارش شده است که امکان شناسایی علائم بیماری را به کمک اندازه‌گیری فشار کف پا ممکن می‌سازد [۱۴، ۱۶]. از این رو، تحلیل سیگنال راه رفتن و بخصوص فشار کف پا که به عنوان شاخصی از وضعیت جسمانی و راه رفتن فرد مورد بررسی قرار می‌گیرد، می‌تواند به صورت یک روش تشخیصی کم‌هزینه و غیرتهاجمی برای شناسایی بیماری‌های عصبی مثل سکتهمغزی استفاده شود [۱۷].

مطالعاتی که در راستای تجزیه و تحلیل سیگنال فشارکف پا به منظور تشخیص بیماری سکتهمغزی انجام شده است، از ویژگی‌های مختلفی استفاده کرده‌اند که می‌توان آنها را در دو حوزه ویژگی‌های زمانی و یا فرکانسی تقسیم‌بندی نمود. پردازش سیگنال در حوزه زمان، تغییرات و رفتار دامنه سیگنال را در طول زمان و یا یک پنجره زمانی خاص آشکارسازی می‌نماید [۱۸]. از جمله ویژگی‌های زمانی که در این راستا برای ارزیابی و تشخیص بیماری سکتهمغزی در مطالعات پیشین مورد ارزیابی قرار گرفته‌اند، می‌توان به ضرایب همبستگی متقاطع بین اندام استخراج شده از سری مرکز فشار [۱۹]، جابجایی مرکز فشار [۲۰]، بیشترین مقدار فشار در زیر پا و قسمت انتهایی آن [۲۰]، درصد زمان ایستایی [۲۱، ۲۲]، طول قدم [۲۱]، درصد زمان حمایت دوگانه [۲۱-۲۳]، تقارن موقعیت مرکز فشار [۲۱]، حداکثر فشار جلوی پا [۲۴]، نسبت بین فشار جلوی پا در نقطه حداکثر فشار پاشنه و حداکثر فشار جلوی پا [۲۴]، طول الگوی فشار قدامی-خلفی [۲۴]، نسبت بین حداکثر فشار جلوی پا و حداکثر فشار پاشنه پا [۲۴]، طول و محل فشار قدامی-خلفی [۲۴]، طول و موقعیت فشار جانبی [۲۴]، آهنگ [۲۲]، زمان قدم [۲۲]، زمان چرخه [۲۲]، درصد زمان نوسانی [۲۲]، درصد زمان حمایت تک گانه [۲۲، ۲۳]، مرکز فشار [۲۵-۲۷]، موقعیت و حداکثر جابجایی [۲۵]، سرعت متوسط [۲۵]، فاز نوسانی [۲۳]، نسبت های فشار جزئی پا [۱۴]، نسبت طول قدامی خلفی مرکز فشار [۱۴]، فاصله حرکت رو به عقب فشار مرکز تا طول پا [۱۴]، انحراف معیار [۱۹، ۲۸]، ضریب همبستگی [۱۹]، مسیر مرکز فشار [۲۰]، مقدار میانگین [۲۸] و واریانس [۲۸] اشاره نمود. با توجه به ماهیت غیرخطی و غیرایستای سیگنال‌های پزشکی و همچنین نویزپذیر بودن این سیگنال‌ها، استفاده از ویژگی‌های حوزه زمان که حساسیت بالایی به آرتیفکت و نویزها داشته و امکان نمایش رفتارهای پیچیده سیگنال را به شکل موثری ندارد، ممکن است قدرت تفکیکی مناسبی را به تنهایی ارائه ندهند [۱۸]. از این رو در سال‌های اخیر جهت رفع این مشکل، از انتقال سیگنال به حوزه فرکانس به کمک تبدیلاتی نظیر تبدیل فوریه و استخراج ویژگی‌های فرکانسی اقدام نموده‌اند. پردازش سیگنال در حوزه فرکانس، میزان تغییر در مقادیر دامنه سیگنال در طول باندهای فرکانسی آن را نشان می‌دهد [۱۸]. در مطالعات پیشین تعدادی از ویژگی‌های حوزه فرکانس برای ارزیابی و تشخیص بیماری سکتهمغزی مورد استفاده قرار گرفته‌اند که شامل فرکانس گام [۲۹]، توان در فرکانس غالب اول [۲۸]، توان در فرکانس غالب دوم [۲۸]، فرکانس غالب اول [۲۸]، فرکانس غالب دوم [۲۸] و همچنین توان کل [۲۸] می‌باشند. از آنجایی که انتقال اطلاعات از حوزه زمان به فرکانس به کمک تبدیل فوریه باعث حذف اطلاعات زمانی اجزای فرکانسی شده و همچنین امکان نمایش تغییرات گذرای سیگنال را ندارد، در تحلیل سیگنال‌های غیرایستا محدودیت‌هایی را به همراه خواهد داشت و ممکن است به دلیل استخراج ویژگی‌های عمومی سیگنال سبب کاهش صحت تشخیصی روش پیشنهادی گردد [۱۸، ۳۰]. از این رو، در این مطالعه برای حل مشکلات دو حوزه فوق، به استخراج ویژگی‌های سیگنال فشار به کمک یک روش توام زمان-فرکانس پرداخته شده است.

نزدیک‌ترین همسایگی به عدم نیاز به داشتن اطلاعات در مورد نحوه توزیع داده‌ها و همچنین خصوصیات مناسب تکنیک ماشین بردار پشتیبان در ارائه نتایج مناسب روی داده‌های ساختاریافته و شبه ساختاریافته و استراتژی تقریب محلی آن بوده است [۴۶، ۴۷]. همچنین در این مطالعه توسعه یک طبقه‌بند که کاربرد جدیدی در حوزه تشخیص بیماری سکتهمغزی به کمک تحلیل سیگنال فشار پا دارد، به نام جنگل تصادفی، در دستور کار قرار گرفته است. این روش یک طبقه‌بندی‌کننده غیرپارامتری ارائه می‌دهد که قابلیت ارائه صحت طبقه‌بندی بالا و تعیین اهمیت متغیرها را دارد. علاوه بر این، طبقه‌بند جنگل تصادفی یک الگوریتم برای تخمین مقادیر از دست‌رفته ارائه می‌دهد و به همین دلیل برای تحلیل و ارزیابی داده‌ها انعطاف‌پذیر می‌باشد [۴۸].

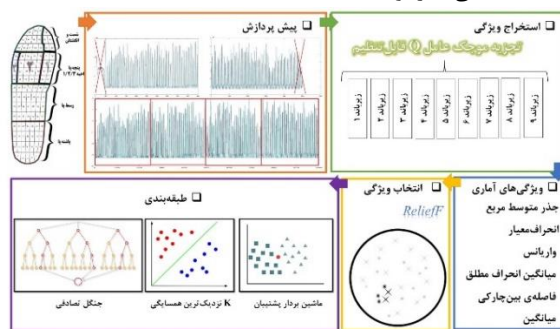
ساختار کلی مقاله به شرح زیر سازماندهی شده است: در بخش ۲، پایگاه داده راه رفتن و مراحل مختلف پیشنهادی (پیش‌پردازش داده، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی) توضیح داده شده است. در بخش ۳، نتایج تجربی گزارش شده و در بخش ۴ نتایج بدست آمده مورد بحث و بررسی قرار گرفته و با نتایج سایر مقالات مقایسه شده است. نهایت در بخش ۵، یک نتیجه‌گیری کلی از روش پیشنهادی، ارائه شده است.

## ۲- روش

شکل ۱، نگره روش پیشنهادی را برای تشخیص کامپیوتری بیماری سکتهمغزی ایسکمیک به کمک تحلیل سیگنال فشار کف پا را نشان می‌دهد. همانطوری که از این شکل مشخص است این روش شامل چندین مرحله پیش-پردازش، استخراج ویژگی مبتنی بر تجزیه موجک عامل Q قابل تنظیم، انتخاب ویژگی به کمک روش ReliefF و در انتها طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین شامل ماشین بردار پشتیبان، K نزدیک‌ترین همسایگی و جنگل تصادفی است. در ادامه توضیحات مربوط به هر قسمت در زیربخش مربوطه ارائه شده است. همچنین از آن جایی که عملکرد تشخیص سکتهمغزی در هر ناحیه از کف پا متفاوت باشد، در یک مطالعه مقایسه‌ای به بررسی اثر نواحی مختلف کف پا و همچنین عوامل تکنیکی در عملکرد تشخیصی نیز پرداخته شده است تا جنبه‌های اثرگذار مختلف در این راستا مورد ارزیابی قرار گرفته باشند.

پیشنهاد شده است، هرچند در حیطه تشخیص بیماری سکتهمغزی با کمک تحلیل فشارکف پا تعداد بسیار اندکی از مطالعات از این روش‌ها استفاده نموده‌اند. از سوی دیگر مکان و ناحیه تحت تاثیر قرار گرفتن مغز در سکتهمغزی می‌تواند از فردی به فرد دیگر متفاوت باشد، این مساله می‌تواند منجر به الگوی متفاوت راه رفتن و تغییرات فشارکف پا در بیماران باشد. از این‌رو ممکن است یافتن یک تک مشخصه عمومی که قابل اعمال به همه افراد بوده و صحت تشخیصی بالا ارائه دهد، دشوار باشد. یکی از راه‌های مواجهه با این مشکل استخراج چندین ویژگی از نواحی مختلف کف پا می‌باشد. این مساله سبب تعدد ویژگی‌های استخراجی شده که می‌تواند با افزایش بارمحاسباتی همراه شود و به دلیل وجود اطلاعات تکراری و همبسته، در مواقعی عملکرد طبقه‌بندی را تحت تاثیر قرار می‌دهد [۴۲]. از آنجایی که تعدد مشخصه‌های راه‌رفتن و داشتن مشخصه‌های پیچیده، سبب دشواری تحلیل این داده‌ها می‌گردد، استفاده از روش‌های انتخاب ویژگی در کنار تکنیک‌های مختلف یادگیری ماشین می‌تواند ابزار موثر و مناسبی جهت شناسایی قابلیت تفکیک‌پذیری هر کدام از مشخصه‌ها و همچنین بهبود صحت تشخیصی روش‌های یادگیری ماشین جهت شناسایی بیماران مبتلا به سکتهمغزی باشد [۴۱]. جهت رفع این مشکل در مطالعه حاضر از تکنیک انتخاب ویژگی ReliefF جهت شناسایی ویژگی‌های تفکیک‌پذیر و مواجهه با تعدد ویژگی‌ها و در نتیجه کاهش زمان آموزش استفاده شده است. از خصوصیات اصلی این روش می‌توان به سادگی، مقاوم بودن در برابر نویز و قابلیت مناسب آن در مواجهه با ویژگی‌های وابسته اشاره نمود که استفاده از آن را در پردازش سیگنال‌های پزشکی مناسب می‌سازد [۴۳، ۴۴].

در مطالعات پیشین، جهت ارزیابی و تشخیص سکتهمغزی از الگوریتم‌های یادگیری مختلفی شامل K نزدیک‌ترین همسایگی [۱۱، ۳۷]، ماشین بردار پشتیبان [۱۱، ۳۷، ۴۵]، رگرسیون لاجستیک [۱۱]، الگوریتم‌های درخت تصمیم [۱۱، ۳۷] و شبکه‌های عصبی پرسپترون چند لایه [۳۷] استفاده گردیده است. بررسی این مطالعات نشان از عملکرد مناسب روش‌های K نزدیک‌ترین همسایگی و ماشین بردار پشتیبان به عنوان پرتکرارترین و موثرترین طبقه‌بندهای استفاده شده در راستای تشخیص سکتهمغزی داشته است. بنابراین، در این مطالعه از دو طبقه‌بند فوق جهت تشخیص کامپیوتری و مقرون به صرفه سکتهمغزی استفاده شده است. انتخاب این دو روش علاوه بر عملکرد مناسب در مطالعات پیشین، به دلیل مزایای دیگری مانند سادگی اجرا و قابلیت K



شکل ۱- چارچوب روش پیشنهادی مبتنی بر تشخیص سکتهمغزی با استفاده از تحلیل فشار کف پا

این پایگاه داده، تمامی شرکت‌کنندگان به مدت ۱۲ دقیقه در یک راهروی دایره‌ای راه رفته‌اند. پارامترهای فشار پا، نیرو و زمان راه رفتن با استفاده از کفی‌هایی با ۹۹ حسگر حساس به فشار با فرکانس نمونه‌برداری ۵۰ هرتز که امکان اندازه‌گیری دقیق نقشه فشار پا در حین راه رفتن را فراهم می‌کنند، ثبت شده‌اند. در این پژوهش از سیستم پدار برای اندازه‌گیری دقیق فشار کف پا با رزولوشن مکانی ۲/۲-۱/۶ سانتی‌متر و فرکانس نمونه‌برداری ۵۰ هرتز استفاده شده است [۶]. حسگرهای پدار از فناوری خازنی استفاده می‌کنند که دقت بالایی را برای اندازه‌گیری فشار روی بدن انسان ارائه می‌دهند. این پایگاه داده شامل

## ۲-۱- پایگاه داده

در این مطالعه، به منظور تشخیص کامپیوتری و کم‌هزینه سکتهمغزی، از پایگاه داده‌ای که دربرگیرنده سیگنال فشار کف پا مربوط به افراد سالم و بیماران مبتلا به سکتهمغزی ایسکمیک در حین فعالیت روزانه است، استفاده شده است [۶]. این پایگاه داده توسط Vera Novak و همکاران گردآوری شده است و حاوی داده‌های چندوجهی از یک مطالعه بزرگ است که اثرات سکتهمغزی ایسکمیک بر تنظیم عروق مغزی را بررسی می‌کند [۴۹، ۵۰]. در

استخراج شده‌اند، محدود به ویژگی‌های ساده زمانی و یا فرکانسی بوده‌اند. این در حالی است که با توجه به ماهیت متغیر با زمان و غیرایستای سیگنال فشار کف پا، استفاده از روش‌هایی که اطلاعات توأم زمانی-فرکانسی را آشکار می‌نمایند، می‌توانند اجزای گذرا و محلی سیگنال را تفکیک نموده و به استخراج اطلاعات پنهان آنها کمک شایانی نمایند.

تجزیه موجک عامل  $Q$  قابل تنظیم یک تبدیل زمانی-فرکانسی بهبود یافته گسسته است که امکان تطبیق ضریب کیفیت را متناسب با رفتار نوسانی سیگنال فراهم می‌آورد و یک روش موثر برای کمی‌سازی نوسانات و شناسایی اطلاعات پنهان در سیگنال‌های نوسانی است [۵۱، ۵۲]. در تجزیه سیگنال به کمک این روش امکان انتخاب و تنظیم سه پارامتر اصلی ضریب کیفیت، افزونگی و تعداد سطوح تجزیه متناسب با رفتار نوسانی سیگنال و همچنین استخراج اطلاعات گذرا و محلی آن وجود دارد که کاربرد آن را در تحلیل سیگنال‌های غیرایستای بیومدیکال مناسب می‌سازد [۳۲، ۳۶]. ضریب کیفیت، رفتار نوسانی و شکل موج‌های مورد استفاده در این روش را کنترل می‌کند. این پارامتر برای سیگنال‌های نوسانی، عدد بزرگتری انتخاب می‌شود که در این حالت رزولوشن فرکانسی بهبود می‌یابد و برای سیگنال‌هایی با نوسانات ضعیف، مقادیر کمتر انتخاب می‌شود که در این حالت، مقدار  $Q$  طوری تنظیم می‌شود که موجک بنیادی، دارای پاسخ فرکانسی گسترده‌تر با نوسانات کمتر باشد [۳۲، ۵۲، ۵۳]. ضریب  $Q$  طبق معادله زیر تعریف می‌شود [۳۲]:

$$Q = \frac{f_c}{BW} \quad (1)$$

که در این رابطه  $f_c$  فرکانس مرکزی و  $BW$  پهنای باند است. همچنین رابطه پهنای باند به صورت زیر می‌باشد [۵۴]:

$$BW = \frac{1}{2} \beta \alpha^{J-1} \pi \quad (2)$$

$\alpha$  و  $\beta$  پارامترهای بانک فیلتر هستند که از رابطه زیر به دست می‌آیند [۵۴]:

$$\beta = \frac{2}{Q+1}, \alpha = 1 - \frac{\beta}{\gamma} \quad (3)$$

افزونگی به عنوان شاخصی از میزان همپوشانی پاسخ‌های فرکانسی مجاور و مشخصه محلی شده موجک‌ها در زمان است [۵۴]. افزایش پارامتر  $r$  برای یک مقدار ثابت  $Q$ ، باعث افزایش همپوشانی بین پاسخ‌های فرکانسی مجاور می‌شود. بنابراین، برای مقادیر بالای  $r$ ، سطوح بیشتری برای پوشش طیف فرکانسی یکسان و برای  $r$  پایین، سطوح کمتری مورد نیاز است که در بیشتر مطالعات، مقدار آن را برابر عدد سه در نظر گرفته شده است. این پارامتر از رابطه زیر بدست می‌آید [۵۴، ۵۵]:


$$\gamma = \frac{\beta}{1-\alpha} \quad (4)$$

در روش تجزیه موجک عامل  $Q$  قابل تنظیم از یک ساختار بانک فیلتر تکراری با دو کانال برای تجزیه سیگنال‌ها استفاده می‌کند که تعداد بانک‌های فیلتر به صورت  $J$  نشان داده می‌شود. سیگنال ورودی  $x(n)$  در هر سطح به یک زیرباند پایین‌گذر و چندین زیرباند فرعی بالاگذر تجزیه می‌شود که به ترتیب دارای فرکانس‌های نمونه‌برداری  $\alpha f_s$  و  $\beta f_s$  می‌باشند، که  $\alpha$  و  $\beta$  پارامترهای مقیاس هستند و در نهایت تعداد  $J+1$  زیرباند در خروجی ایجاد می‌شود. زیرباند پایین‌گذر با استفاده از فیلتر پایین‌گذر  $F_1^J(\omega)$  و مقیاس پایین‌گذر  $LPS\alpha$  تولید می‌شود. به‌طور مشابه، زیرباندهای فرعی بالاگذر توسط یک فیلتر بالاگذر  $F_2^J(\omega)$  و مقیاس بالاگذر  $HPS\beta$  ایجاد می‌شوند [۳۲]. در شکل (۳-الف) تصویری از مراحل مختلف تجزیه شدن سیگنال فشار کف پا با استفاده از تجزیه

۳۶ بیمار مبتلا به سکتته مغزی (۱۹ زن و ۱۷ مرد با میانگین سنی ۶۴/۵۲) و ۴۶ فرد سالم (۲۷ زن و ۱۹ مرد با میانگین سنی ۶۸/۱۳) می‌باشد [۶]. معیارهای انتخاب افراد سالم این مطالعه شامل عدم ابتلا به بیماری دیابت و نارسایی‌های قلبی بود. افراد مبتلا به سکتته نیز از بین شرکت کنندگان با رده سنی ۶۰-۸۰ سالی انتخاب شده بودند که برای اولین بار دچار عارضه سکتته مغزی ایسکمیک شده بودند. بروز سکتته مغزی ایسکمیک این افراد توسط روش‌های تصویربرداری توموگرافی کامپیوتری شده و همچنین تشدید مغناطیسی و آزمایشات عصبی و بالینی به اثبات رسیده بود [۶].

## ۲-۲- پیش پردازش

با توجه به مطالعات گذشته و مشاهده تفاوت‌هایی در تغییرات فشار کف پا در قسمت‌هایی مانند انگشتان و یا قسمت‌های پنجه پا در بیماران مبتلا به سکتته مغزی، در این مطالعه جهت ایجاد امکان تحلیل ناحیه‌ای و مقایسه و ارزیابی فشار نواحی مختلف، کف پا به نواحی مختلفی تقسیم شده و به صورت مجزا مورد تحلیل و مقایسه قرار گرفته‌اند. تقسیم‌بندی اعمال شده مطابق با نواحی پیشنهادی در مطالعات پیشین بوده است که کف پا را به ۷ ناحیه مجزا شامل پاشنه، وسط پا، پنجه پا (ناحیه ۱، ناحیه ۲ و ناحیه ۳)، شست پا و انگشتان پا به نحوی که در شکل ۲ نشان داده شده است تفکیک کرده است [۴]. در ادامه، به منظور به حداقل رساندن اثرات گذرای شروع و پایان حرکت، ۱۰ ثانیه ابتدای و انتهای سیگنال حذف شده است [۵]. سپس سیگنال‌های فشار ثبت شده از افراد به کمک تکنیک پنجره‌بندی، به پنجره‌های متوالی و بدون همپوشانی ۵۰ ثانیه‌ای تقسیم‌بندی شده و جهت استخراج ویژگی مورد استفاده قرار گرفته‌اند. از آنجایی که فرکانس نمونه‌برداری سیگنال فشار در این مطالعه ۵۰ هرتز می‌باشد، هر پنجره تفکیک‌شده شامل ۲۵۰۰ نمونه از سیگنال‌های فشار می‌باشد که از ۹۹ سنسور کف پا ثبت شده‌اند.



شکل ۲- تقسیم بندی سنسورهای پدار برای ناحیه بندی کف پا

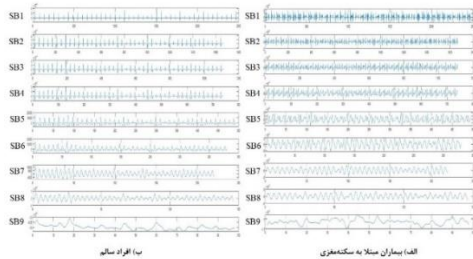

در نگاره روش پیشنهادی در شکل ۱ چگونگی اعمال مراحل پیش‌پردازش در نمونه‌ای از سیگنال فشار کف پا نشان داده شده است. در این مطالعه با توجه به اینکه حسگرهای متعددی در زیر هر کدام از پاها در نواحی مختلف قرار گرفته است، روش پیش‌پردازش پیشنهادی بر همه سیگنال‌های ثبت شده از هر دو پا به صورت یکسان اعمال شده است. بعد از اعمال ناحیه‌بندی ذکر شده نیز، پنجره‌های استخراج شده از نواحی مختلف پا جهت کمی‌سازی تغییرات، وارد مرحله استخراج ویژگی شده‌اند.

## ۲-۳- استخراج ویژگی

در این مطالعه، یک الگوریتم مبتنی بر تبدیل موجک عامل  $Q$  قابل تنظیم برای نخستین بار جهت استخراج اطلاعات زمانی-فرکانسی مرتبط با سیگنال فشار کف پا به منظور تشخیص خودکار سکتته مغزی توسعه داده شده است. این روش با هدف تجزیه سیگنال و استخراج اطلاعات زمانی-فرکانسی متناسب با نوسانات آن ارائه شده است. همان طوری که در مقدمه عنوان گردید، ویژگی‌هایی که تاکنون برای تشخیص بیماری سکتته مغزی بر روی داده‌های فشار کف پا

موجک عامل Q قابل تنظیم و همچنین در قسمت ب همین شکل (۳-ب)، ساختار مرحله اول بانک فیلتر نشان داده شده است.

شکل ۳- ساختار تجزیه موجک عامل Q قابل تنظیم؛ الف) تجزیه با استفاده از تجزیه موجک عامل Q قابل تنظیم. ب) ساختار مرحله اول بانک فیلتر



شکل ۴- نمونه ای از سیگنال تجزیه شده توسط تجزیه موجک عامل

Q قابل تنظیم برای دو گروه الف) بیماران مبتلا به سکتهمغزی، ب) افراد سالم

در مطالعه حاضر، جهت ارائه یکسری مشخصه‌های تفکیک کننده از زیرباند‌های مستخرج از سیگنال فشار کف پا، از ویژگی‌های آماری شامل جذر متوسط مربع، انحراف معیار، واریانس، میانگین انحراف مطلق، فاصله بین-چارکی و میانگین استفاده شده است. مزیت این ویژگی‌ها در داشتن بارمحاسبی کم، جهت کمی سازی گستردگی ضرایب زمانی-فرکانسی و نحوه توزیع دامنه آن‌ها می باشد که روابط مربوط به هریک از ویژگی‌ها در جدول ۱ ارائه شده است. این ویژگی‌های آماری، از تمامی زیرباند‌های تجزیه شده سیگنال فشار کف پای مربوط به دو گروه سالم و بیمار به صورت مجزا محاسبه شده و مورد طبقه بندی قرار گرفته اند. در روش پیشنهادی حاضر، به کمک روش تجزیه موجک عامل Q قابل تنظیم، سیگنال فشار کف پا به تعداد J+1 زیر باند تفکیک شده و از هر زیر باند نیز ۶ ویژگی آماری محاسبه شده است، بنابراین تعداد ویژگی‌های استخراج شده از هر ناحیه برابر (تعداد حسگرها در هر ناحیه برابر ۶ × (J+1)) می باشد. لازم به ذکر است که با توجه به ناحیه بندی انجام شده تعداد حسگرهای ناحیه پاشنه، وسط پا، ناحیه ۱، ناحیه ۲، ناحیه ۳ پنجه پا، شست و انگشتان پا به ترتیب برابر با ۵۲، ۵۶، ۱۶، ۳۲، ۸، ۱۰ و ۲۴ عدد می باشد. در ادامه با توجه به تعداد این ویژگی‌ها، جهت انتخاب ویژگی‌های تفکیک کننده و حذف اطلاعات تکراری و همبسته از تکنیک انتخاب ویژگی ReliefF استفاده شده است.

جدول ۱- روابط ریاضی مربوط به ویژگی‌های آماری

معادله	نام ویژگی
$\sqrt{\frac{1}{n} \sum x_i^2}$	جذر متوسط مربع
$\sqrt{\frac{\sum (x_i - \mu)^2}{N}}$	انحراف معیار
$\frac{\sum (x_i - \bar{x})^2}{n-1}$	واریانس
$\frac{1}{n} \sum_{i=1}^n  x_i - m(X) $	میانگین انحراف مطلق
$Q_3 - Q_1$	فاصله بین چارکی

شکل ۳- ساختار تجزیه موجک عامل Q قابل تنظیم؛ الف) تجزیه با استفاده از تجزیه موجک عامل Q قابل تنظیم. ب) ساختار مرحله اول بانک فیلتر

پاسخ فرکانسی زیرباند‌های ذکر شده در قسمت قبلی با معادلات  $F_1^J(\omega)$  و  $F_2^J(\omega)$  به صورت زیر محاسبه می شوند [۳۲]:

$$F_1^J(\omega) = \begin{cases} \prod_{j=0}^{J-1} H_0\left(\frac{\omega}{\alpha^j}\right), & |\omega| \leq \alpha^j \pi \\ 0, & \alpha^j \pi \leq |\omega| \leq \alpha^{j+1} \pi \end{cases} \quad (5)$$

$$F_2^J(\omega) = \begin{cases} H_1\left(\frac{\omega}{\alpha^j}\right) \prod_{j=0}^{J-2} H_0\left(\frac{\omega}{\alpha^j}\right), & for(1-\beta)\alpha^{j-1}\pi \leq |\omega| \leq \alpha^{j-1}\pi \\ 0, & for other, \omega \in [-\pi, \pi] \end{cases} \quad (6)$$

که در معادلات ۵ و ۶،  $F_1^J(\omega)$  و  $F_2^J(\omega)$  با استفاده از روابط زیر بدست می آیند [۳۲]:

$$F_1^J(\omega) = \theta \left( \frac{\omega + (\beta-1)\pi}{\alpha + \beta - 1} \right) \quad (7)$$

$$F_2^J(\omega) = \theta \left( \frac{\alpha\pi + \omega}{\alpha + \beta - 1} \right) \quad (8)$$

در معادله ۷ و ۸،  $\theta$  نشان دهنده پاسخ فرکانسی دابچیز<sup>۲</sup> است.

در روابط ذکر شده، حداکثر تعداد سطوح تجزیه برای سیگنال ورودی، با طول N، با فرمول زیر محاسبه می گردد [۳۲]:

$$J_{\max} = \left( \frac{\log(\beta N / 8)}{\log(1/8)} \right) \quad (9)$$

در این مطالعه، استخراج ویژگی از پنجره‌های پیش پردازش شده فشار کف پا در دو مرحله انجام پذیرفته است، در مرحله اول، الگوریتم تبدیل موجک عامل Q قابل تنظیم به سیگنال‌های پیش پردازش شده ۷ ناحیه کف پا به صورت جداگانه اعمال گردیده و ضرایب نوسانی در باندهای مختلف استخراج شده است. در مرحله دوم، ویژگی‌های آماری از ضرایب مربوط به هر زیرباند جهت کمی سازی تفاوت بین دو گروه محاسبه شده اند. همچنین در یک آزمایش مقایسه ای تاثیر مقادیر مختلف Q و J در قدرت تفکیکی ویژگی‌های استخراجی مورد تحلیل و مقایسه قرار گرفته است. بدین منظور در ابتدا، جهت تجزیه سیگنال از پارامترهای Q=1, r=3, J=8 استفاده شده است. در ادامه در یک آزمایش مقایسه ای سه مقدار متفاوت (۳، ۲، ۱) برای پارامتر ضریب کیفیت و چهار مقدار

<sup>2</sup>Daubechies

## ۲-۴- انتخاب ویژگی

می‌باشد که قادر است بردار ویژگی‌های را در فضایی با ابعاد بالا مجسم می‌کند [۱۳]. این طبقه‌بند برای مسائل رگرسیون و تفکیک کلاس‌ها مناسب می‌باشد [۶۱]. هدف اصلی این الگوریتم یافتن یک مرز تصمیم‌گیری با حداکثر حاشیه بین کلاس‌ها در فضای ویژگی با ابعاد بالاتر می‌باشد که جهت نیل به این هدف از یک تابع کرنل در مسائل غیرخطی استفاده می‌گردد [۳۷، ۶۲]. در مطالعه حاضر جهت یک طبقه‌بندی دو کلاسه از روش ماشین بردار پشتیبان با استفاده از هسته تابع پایه شعاعی (RBF) به منظور نگاشت به فضایی با ابعاد بالاتر بهره گرفته شده است.

### • K- نزدیک‌ترین همسایگی

طبقه‌بند K- نزدیک‌ترین همسایگی یکی از شناخته‌شده‌ترین الگوریتم‌های طبقه‌بندی برای طبقه‌بندی نظارت‌شده غیرپارامتریک می‌باشد [۶۲، ۶۳]. عملکرد این طبقه‌بند مبتنی بر فاصله بوده و ویژگی‌های مشابه را در فضای محاسباتی به کمک محاسبه فواصل و همسایگی بین آن‌ها جستجو می‌کند [۶۴، ۶۵]. در این طبقه‌بند انتخاب همسایه‌ها بر اساس پارامتر فاصله انجام می‌پذیرد. برای تصمیم‌گیری نهایی به کمک این طبقه‌بند، بعد از تعیین تعداد نزدیک‌ترین همسایگی K و روش محاسبه فاصله، فاصله بین نمونه‌های آموزشی و آزمایشی محاسبه می‌گردد و سپس مقادیر این فاصله‌ها به صورت ترتیبی مرتب می‌شوند و K سطر اول آن انتخاب می‌گردد. سپس، برچسب هر نمونه آموزشی بر اساس بیشترین رای از میان K همسایگی تعیین می‌شود و این فرآیند برای تمامی اعضای گروه تکرار می‌شود. بنابراین دقت طبقه‌بندی با کمک این روش به انتخاب تابع فاصله و همچنین تعداد همسایگی‌های K بستگی دارد [۶۶]. در این مطالعه، با روش سعی و خطا تعداد همسایگی‌های مورد استفاده برابر ۳ در نظر گرفته شده و از تابع فاصله همینگ<sup>۳</sup> برای آموزش طبقه‌بند استفاده گردیده است.

### • جنگل تصادفی

طبقه‌بند جنگل تصادفی اولین بار توسط Breiman ارائه شد [۶۷]. این طبقه‌بند یکی از الگوریتم‌های یادگیری ماشین بانظارت می‌باشد [۶۸]. دقت و توانایی نسبتاً بالای این طبقه‌بند و ماهیت ساده آن، توجه بسیاری از محققان را به خود جلب کرده است که این الگوریتم در بسیاری از کاربردهای پزشکی مانند تشخیص آپنه خواب انسدادی، پیش‌بینی حملات آسم، طبقه‌بندی غیرتجانسی فشارخون ریوی، طبقه‌بندی تصاویر سکنه‌مغزی و غیره کاربرد دارد [۴۳، ۶۷، ۶۸]. ساده‌ترین راه برای توصیف جنگل تصادفی، در نظر گرفتن آن به عنوان مجموعه‌ای از درختان رگرسیون مختلف می‌باشد. یک درخت رگرسیون با تقسیم متوالی داده‌ها در مجموعه‌ای از مستطیل‌ها ساخته می‌شود. در هر تقسیم، فضای ویژگی به دو بخش تقسیم می‌شود که به عنوان گره ذخیره می‌گردند. این گره‌ها بیشتر تقسیم می‌شوند تا زمانی که یک معیار توقف برآورده شود. سپس پاسخ نهایی با میانگین‌گیری مقادیر در هر گروه پیش‌بینی می‌گردد [۶۹]. از مزایای این طبقه‌بند می‌توان به مقاومت در برابر بیش‌برازش و نویز، همچنین سرعت بالا و عدم نیاز به نرمال‌سازی اشاره نمود [۷۰].

## ۳- نتایج

در این قسمت نتایج ارزیابی روش پیشنهادی تشخیص سکنه مغزی ایسکمیک به کمک پایگاه داده معرفی شده و معیارهای طبقه‌بندی صحت، حساسیت و اختصاصیت خلاصه شده است. با توجه به امکان اثرگذاری پارامترهای مختلف تکنیکی و کلینیکی در صحت تشخیص بیماری سکنه مغزی

روش‌های انتخاب ویژگی در بسیاری از زمینه‌های مربوط به تحلیل داده، به ویژه در تشخیص الگو و بیوانفورماتیک، جهت استفاده از ویژگی‌های تفکیک‌کننده‌تر و مرتبط در مجموعه داده‌هایی با ابعاد بالا و همچنین به منظور کم‌تر نمودن بعد ماتریس ویژگی‌ها استفاده شده و می‌تواند نقش مفیدی را در بهبود صحت طبقه‌بندی ایفا کند [۵۶]. از آنجایی که وجود اطلاعات همبسته و تکراری در ویژگی‌ها می‌تواند منجر به مشکلات چالش‌برانگیز هنگام پردازش و تحلیل داده‌ها شود، روش‌های انتخاب ویژگی معمولاً برای ساده‌سازی فرآیند طبقه‌بندی و کاهش زمان آموزش، حذف ویژگی‌های غیرضروری از مجموعه داده‌ها، فشرده سازی داده‌ها و صرفه‌جویی در فضای ذخیره‌سازی استفاده می‌گردند [۵۶، ۵۷]. از آنجایی که حضور اطلاعات تکراری در ویژگی‌های استخراج‌شده ممکن است تاثیر منفی بر عملکرد طبقه‌بند داشته باشد، فرآیند انتخاب ویژگی، بهترین ویژگی‌های معنادار برای پردازش را پیدا نموده و آن‌ها را به عنوان ورودی به طبقه‌بند اعمال می‌کند [۵۶]. در این مطالعه، به منظور انتخاب ویژگی‌های معنادار و مفید از تکنیک انتخاب ویژگی Relief که یک روش کاهش ابعاد که توسط Kira and Rendell [۵۸] توسعه داده شده است، استفاده گردیده است. این تکنیک برای داده‌های با ابعاد بالا و همچنین طبقه‌بندی باینری مناسب می‌باشد [۵۷]. از مهم‌ترین ویژگی‌های این الگوریتم می‌توان به نمایان کردن سازگاری‌های موجود در ویژگی‌های استخراج‌شده و همچنین تشخیص ویژگی‌های مهم در مجموعه داده‌ها با پیدا کردن نزدیک‌ترین نمونه‌های همسایگی در دسته‌های مختلف هر نمونه اشاره نمود [۳۶، ۵۹]. عملکرد این الگوریتم بدین صورت است که نزدیک‌ترین نمونه‌های همسایگی را در دسته‌های مختلف هر نمونه پیدا کرده و انتخاب می‌کند. با توجه به یک نمونه R که به طور تصادفی انتخاب شده است، روش Relief دو تا از نزدیک‌ترین همسایگی خود که یکی از همان کلاس (H: نزدیک‌ترین همسایگی) و دیگری از یک کلاس متفاوت (M: نزدیک‌ترین خطا) را جست و جو می‌کند [۶۰]. این فرآیند برای هر داده ویژگی بروز رسانی شده و m بار تکرار می‌شود و مجموعه داده جدیدی شامل وزن ویژگی‌ها به دست می‌آید.

## ۲-۵- طبقه‌بندی

در مطالعه حاضر به منظور تفکیک ویژگی‌های آماری استخراج شده از ضرایب زمانی-فرکانسی از سه روش یادگیری ماشین تحت عنوان ماشین بردار پشتیبان، K- نزدیک‌ترین همسایگی و درخت تصمیم استفاده شده است که در ادامه معرفی شده و نحوه استفاده از آنها تشریح می‌شوند. لازم به ذکر است که در تمامی روش‌های یادگیری ماشین استفاده شده در این مطالعه، به منظور تفکیک بیماران مبتلا به سکنه مغزی ایسکمیک از افراد سالم، از روش اعتبارسنجی متقابل پنج‌گانه برای تقسیم کل نمونه‌ها به نمونه آموزشی و آزمایشی استفاده گردیده است. بدین معناست که نمونه‌های اصلی به ۵ زیرمجموعه مساوی تقسیم می‌شوند، سپس آموزش طبقه‌بند با ۴ زیرمجموعه انجام شده و در نهایت عملکرد تشخیص با ۱ زیرمجموعه آزمایش می‌گردد. جهت ارزیابی دقیق، فرآیند فوق ۵ بار تکرار شده و هر بار یک قسمت جدید از داده‌ها به عنوان داده آزمایش مورد استفاده قرار می‌گیرند.

### • ماشین بردار پشتیبان

طبقه‌بند ماشین بردار پشتیبان یک الگوریتم یادگیری نظارت‌شده است که بر اساس مطالعات انجام شده، یکی از بهترین روش‌های یادگیری آماری

<sup>3</sup>Hamming

### جدول ۳- بررسی اثر انتخاب ویژگی ReliefF در عملکرد تشخیصی

#### روش پیشنهادی به کمک طبقه‌بند جنگل تصادفی

تعداد ویژگی	صحت (%)	حساسیت (%)	اختصاصیت (%)
۵	۸۳/۱۷	۷۳/۲۴	۹۰/۴۵
۱۰	۹۲/۲۲	۸۶/۹۶	۹۶/۶۲
۱۵	۹۷/۹۳	۹۵/۹۴	۹۹/۴۰
۲۰	۹۸/۷۴	۹۸/۶۴	۹۸/۸۱
۲۵	۹۹/۲	۹۸/۳۷	۹۹/۸۰
۳۰	۹۹/۵۴	۹۹/۴۵	۹۹/۶۰
۳۵	۹۹/۷۷	۹۹/۷۲	۹۹/۸۰
۴۰	۹۹/۳۱	۹۹/۱۸	۹۹/۴

از آن جایی که یکی دیگر از عوامل اثرگذار در روش پیشنهادی انتخاب تعداد سطوح تجزیه سیگنال و انتخاب پارامتر ضریب کیفیت Q در الگوریتم تجزیه موجک عامل Q قابل تنظیم می‌باشد، در این قسمت اثر انتخاب تعداد سطوح تجزیه مختلف و تغییر پارامتر Q در تشخیص بیماری سکنه مغزی مورد مقایسه قرار گرفته است. در جدول شماره ۴ نتایج این بررسی با ویژگی میانگین و طبقه‌بند جنگل تصادفی که در بررسی‌های قبل بهترین نتیجه را داشتند، گزارش شده‌اند. بدین منظور تاثیر سه مقدار ۱، ۲ و ۳ برای پارامتر ضریب کیفیت انتخاب و مقایسه شده‌اند. همچنین، تعداد زیرباند‌ها از عدد ۱ به عدد ۱۲ با گام ۴ افزایش یافته و مورد مقایسه قرار گرفته‌اند. انتخاب این اعداد بر مبنای خواص نوسانی خود سیگنال فشار کف پای تحلیل شده و سایر مقالاتی می‌باشد که از این روش برای تحلیل سیگنال‌های فیزیولوژیکی استفاده کرده‌اند [۵۳]. مقایسه نتایج هر دو جدول، آشکارکننده این مساله است که روش پیشنهادی با پارامترهای تکنیکی مختلف نیز قادر به ارائه نتایج مطلوب می‌باشد که این نتایج، مقاوم بودن روش پیشنهادی در برابر تغییر این دو پارامتر تکنیکی روش تجزیه موجک عامل Q قابل تنظیم در صحت تشخیصی بیماری سکنه مغزی را به اثبات می‌رساند.

### جدول ۴- مقایسه عملکرد تشخیصی روش پیشنهادی با پارامترهای

#### تکنیکی مختلف

پارامتر ضریب کیفیت	صحت (%)	حساسیت (%)	اختصاصیت (%)
۱	۹۹/۰۸	۹۷/۸۳	۱۰۰
۲	۹۹/۶۵	۹۹/۱۸	۱۰۰
۳	۹۹/۴۲	۹۸/۹۱	۹۹/۸۰
تعداد سطوح تجزیه			
۱	۹۹/۶۵	۹۹/۱۸	۱۰۰
۴	۹۹/۶۵	۹۹/۴۵	۹۹/۸۰
۸	۹۹/۰۸	۹۷/۸۳	۱۰۰
۱۲	۹۸/۷۴	۹۷/۲۹	۹۹/۸۰

### ۴- بحث

از آنجایی که سیگنال‌های پزشکی مانند سیگنال فشار کف پای غیرخطی و غیرایستا هستند و در بیشتر موارد اطلاعات آن‌ها در اجزای گذرا و موضعی آن‌ها

به کمک تجزیه موجک عامل Q قابل تنظیم، تاثیر هر کدام نیز به صورت جداگانه گزارش و تحلیل شده است. عملکرد تشخیصی بیماری سکنه مغزی را به کمک روش تجزیه موجک عامل Q قابل تنظیم با پارامترهای  $r=3, J=8, Q=1$  و سه طبقه‌بند مختلف در هفت ناحیه مختلف کف پا در جدول ۲ قابل مشاهده می‌باشد. نتایج بدست آمده نشان از برتری طبقه‌بند جنگل تصادفی نسبت به سایر روش‌های یادگیری ماشین دارد. به نحوی که این طبقه‌بند بهترین نتیجه را با میانگین صحت ۹۹.۸٪، حساسیت ۹۷.۸۳٪ و اختصاصیت ۱۰۰٪ ارائه داده است. همچنین ویژگی‌های استخراج شده در نواحی مختلف کف پا در تشخیص به کمک این طبقه‌بند نیز نشان از عملکرد مناسب روش پیشنهادی در همه نواحی و عدم تفاوت معنادار بین آنها را دارد که مقاومت آن را در برابر تغییر نواحی پا نشان می‌دهد. این مساله امکان استفاده از سنسورهای کمتر برای تشخیص سکنه مغزی ایسکمیک بدون اثرگذاری معنادار در صحت بدست آمده و ایجاد مصالحه بین صحت تشخیصی و بارمحاسباتی کم را مبتنی بر الگوریتم زمان-فراکانسی تجزیه موجک عامل Q قابل تنظیم و درخت تصمیم‌گیری به اثبات می‌رساند.

### جدول ۲- عملکرد تشخیص سکنه مغزی به کمک روش‌های پیشنهادی

#### در مناطق مختلف کف پا

طبقه‌بند	نواحی کف پا	تعداد سنسورها	صحت (%)	حساسیت (%)	اختصاصیت (%)
ماشین بردار پشتیبان	پاشنه پا	۵۲	۸۴/۸۹	۶۹/۴۵	۹۶/۲۲
	وسط پا	۵۶	۹۰/۱۵	۸۲/۴۳	۹۵/۸۲
	پنجه پا ۱	۱۶	۸۲/۲۶	۷۱/۶۲	۹۰/۰۸
	پنجه پا ۲	۳۲	۸۸/۹۰	۸۱/۹۴	۹۴/۲۵
	پنجه پا ۳	۸	۷۳/۴۵	۵۰	۹۰/۶۶
	شست پا	۱۰	۷۹/۴۰	۶۴/۵۹	۹۰/۲۷
K	پاشنه پا	۲۴	۸۵/۴۶	۷۱/۸۹	۹۵/۴۳
	وسط پا	۵۲	۵۹/۴۹	۸۵/۹۴	۴۰/۰۸
	پنجه پا ۱	۱۶	۷۷/۹۱	۷۵/۹۴	۷۹/۳۶
	پنجه پا ۲	۳۲	۷۰/۵۹	۶۴/۰۵	۷۵/۳۹
	پنجه پا ۳	۸	۵۸/۶۹	۵۷/۵۶	۵۹/۵۲
	شست پا	۱۰	۶۴/۷۵	۳۵/۱۳	۸۶/۴۹
جنگل تصادفی	پاشنه پا	۲۴	۶۹/۴۴	۶۴/۳۲	۷۳/۱۹
	وسط پا	۵۲	۹۸/۷۴	۹۹/۴۵	۹۸/۲۱
	پنجه پا ۱	۱۶	۹۸/۰۵	۹۷/۰۲	۹۸/۸۰
	پنجه پا ۲	۳۲	۹۸/۵۱	۹۷/۸۳	۹۹
	پنجه پا ۳	۸	۹۸/۰۵	۹۶/۴۸	۹۹/۲۰
	شست پا	۱۰	۹۶/۵۶	۹۶/۸۶	۹۷/۸۱
جنگل تصادفی	پاشنه پا	۲۴	۹۸/۱۷	۹۷/۰۲	۹۹
	وسط پا	۵۶	۹۹/۰۸	۹۷/۸۳	۱۰۰
	پنجه پا ۱	۱۶	۹۸/۰۵	۹۷/۰۲	۹۸/۸۰
	پنجه پا ۲	۳۲	۹۸/۵۱	۹۷/۸۳	۹۹
	پنجه پا ۳	۸	۹۸/۰۵	۹۶/۴۸	۹۹/۲۰
	شست پا	۱۰	۹۶/۵۶	۹۶/۸۶	۹۷/۸۱

در این مرحله، بررسی اثر انتخاب ویژگی ReliefF در کاهش تعداد ویژگی‌ها و عملکرد طبقه‌بندی مورد ارزیابی قرار گرفته است. از آن جایی که این روش در ناحیه وسط پا و طبقه‌بند جنگل تصادفی بهترین عملکرد تشخیصی سکنه مغزی را مطابق آزمایش قبلی نشان داده است، اثر انتخاب ویژگی در این منطقه با کمک جنگل تصادفی مورد آزمایش قرار گرفته و نتایج در جدول ۳ خلاصه شده است. نتایج بدست آمده در این جدول به صورت آشکار تاثیر مثبت روش کاهش ویژگی ReliefF را در کاهش قابل توجه تعداد ویژگی‌ها را از ۳۰۲۴ به ۳۵ عدد در عین حفظ کارایی تشخیصی و حتی بهبود جزئی آن در رابطه با طبقه‌بند جنگل تصادفی نشان می‌دهد. مطابق این نتایج، با استفاده از تنها ۳۵ امکان ارائه نتایج قابل توجه با بهترین عملکرد وجود دارد. این مساله به ایجاد مصالحه بهتر بین نتایج بدست آمده و کاهش بار محاسباتی به کمک کم نمودن تعداد ویژگی‌ها کمک می‌نماید که از دیدگاه کلینیکی حائز اهمیت می‌باشد.

روش به مقاومت در برابر بیش برآزش، توانایی کار مؤثر با مجموعه داده های بزرگ، سرعت بالا، مقاومت در برابر نویز و عدم نیاز به نرمال سازی باشد [۷۰]. برای ارزیابی بهتر روش پیشنهادی در این مطالعه، نتایج آن با نتایج سایر مطالعات پیشین مورد مقایسه قرار گرفته است. در بررسی های به عمل آمده در زمینه تشخیص سکتهمغزی به کمک تحلیل سیگنال فشار کف پا در مطالعات گذشته نیز مشخص می گردد که با وجود قابلیت روش های یادگیری ماشین، تعداد محدودی از مطالعات برای تفکیک افراد سالم از بیماران مبتلا به سکتهمغزی از این روش ها بهره گرفته اند و توجه مطالعات بیشتر به سوی استفاده از روش های تحلیل آماری معطوف بوده است. با توجه به اینکه ارزیابی روش های آماری از میزان تفکیک پذیری دو گروه به بررسی تفاوت میانه یا میانگین داده ها معطوف بوده و تمامی محدوده تغییر ویژگی ها را در نظر نمی گیرند، نتایج آنها با محدودیت های مواجه هستند. از سوی دیگر روش های یادگیری ماشین با فراهم نمودن امکان تصمیم گیری خودکار و تجزیه و تحلیل ویژگی های چند بعدی مزیت های بیشتری به همراه دارند و توجهات زیادی را در سالهای اخیر به خود معطوف نموده اند. جدول ۵ به مقایسه تنها مطالعه ای که از روش های یادگیری ماشین در راستای تشخیص سکتهمغزی با استفاده از سیگنال فشار کف پا و شتاب حرکت استفاده نموده، پرداخته است. همانطوری که از نتایج این جدول مشخص می گردد، روش پیشنهادی این مقاله توانسته است تنها با تحلیل تک سیگنال فشار کف پا عملکرد بهتری را به کمک یک ویژگی جدید زمانی-فرکانسی با بار محاسباتی مناسب ارائه دهد.

نهفته است. از این رو تجزیه آنها به اجزای پایه ای مناسب و استخراج نوسانات مختلف، امکان کمی سازی اطلاعات گذرا و محلی سیگنال را به طور مؤثر فراهم می آورد که یکی از راه های انجام این کار، استفاده از تبدیل های زمان-فرکانس می باشد [۱۸]. اما از آنجایی که میزان نوسانات سیگنال های مختلف متفاوت می باشد، انتخاب موجک مناسب و میزان همپوشانی این موجک ها در تبدیلات زمانی-فرکانسی به یک مساله چالش برانگیز تبدیل شده است. از این رو در این مطالعه، هدف استفاده از روش تجزیه زمانی-فرکانسی است که امکان استخراج اجزای نوسانی سیگنال را با تنظیم پارامترهای ضریب کیفیت و افزونگی و تعداد سطوح تجزیه، متناسب با رفتار نوسانی خود سیگنال فشار کف پا به کمک تبدیل موجک عامل Q قابل تنظیم فراهم کند. با کمک این روش امکان استخراج اطلاعات گذرا و محلی نوسانات سیگنال فشار کف پا که به علت همپوشانی به صورت پنهان در سیگنال وجود دارند، فراهم می شود [۱۸]. از این رو در این مطالعه، با تجزیه سیگنال فشار کف پا به کمک این روش زمانی-فرکانسی و استخراج ویژگی های آماری از زیرباندهای مختلف، ویژگی های متمایزکننده موثری از بیماران سکتهمغزی و افراد سالم ارائه شده است. نتایج روش های تشخیصی بدست آمده به کمک روش های یادگیری ماشین بردار پشتیبان، K-نزدیکترین همسایگی و جنگل تصادفی نیز نشان دهنده قدرت مناسب تشخیصی روش پیشنهادی است. در این میان برتری روش جنگل تصادفی در تشخیص سکتهمغزی آشکار گردید که می تواند به دلیل مزیت این

جدول ۵- مقایسه الگوریتم پیشنهادی با سایر مطالعات

نویسنده	هدف	سیگنال	استخراج ویژگی	طبقه بندی	نتایج
Park و همکاران [۱۱]	تشخیص سکتهمغزی	فشار پا و سیگنال شتاب سنج	نیروی واکنش زمین، پارامترهای فشار راه رفتن، شتاب پا	رگرسیون لجستیک، SVM، CART، C4.5، درختان تصمیم	۸۷-۹۸
روش پیشنهادی	تشخیص سکتهمغزی	سیگنال فشار کف پا	تبدیل موجک عامل Q قابل-تنظیم	ماشین بردار پشتیبان، K-نزدیکترین همسایگی، جنگل تصادفی	جنگل تصادفی = ۹۹/۷۷

## ۵- نتیجه گیری

سکتهمغزی یکی از شایع ترین بیماری های عصبی در جهان و از عوامل مهم بروز ناتوانی در افراد مبتلا می-باشد که کیفیت زندگی آنها را به شدت تحت تاثیر قرار داده و نیازمند تشخیص مناسب جهت درمان و یا کنترل عوارض می باشد. در این مطالعه یک رویکرد جدید غیرتهاجمی، کم هزینه و کلینیکی برای تشخیص کامپیوتری و خودکار بیماری سکتهمغزی توسط تحلیل سیگنال فشار کف پا در حین راه رفتن فرد توسعه یافته است. چهار فرآیند اصلی پیش پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه بندی در این رویکرد پیشنهادی اعمال شده است. در فرآیند استخراج ویژگی از تجزیه موجک عامل Q قابل تنظیم و استخراج شش ویژگی آماری به نام های جذر متوسط مربع، انحراف معیار، واریانس، میانگین انحراف مطلق، فاصله ی بین چارکی و میانگین استفاده شده است و در مرحله بعدی ویژگی های بهینه توسط روش Relief انتخاب شده و با کاهش ابعاد ماتریس ویژگی به کاهش بار محاسباتی کمک شده است. در انتها نیز طبقه بند جنگل تصادفی توانسته است با کمک ویژگی های استخراجی از ناحیه وسط پا با صحت ۹۹/۷۷ درصد بهترین عملکرد تشخیصی سکتهمغزی ایسکمیک را ارائه دهد. نتایج این تحقیق اهمیت اطلاعات توام زمانی-فرکانسی سیگنال فشار کف پا را در تشخیص دقیق، کم هزینه و غیرتهاجمی سکتهمغزی نشان می دهد.

## مراجع

- [1] R. S. da Silva et al., "Psychometric properties of wearable technologies to assess post-stroke gait parameters: a systematic review," *Gait & Posture*, 2024.
- [2] S. Chen et al., "MSA-YOLOv5: Multi-scale attention-based YOLOv5 for automatic detection of acute ischemic stroke from multi-modality MRI images," *Computers in Biology and Medicine*, vol. 165, p. 107471, 2023.
- [3] D. Joshi, A. Khajuria, and P. Joshi, "An automatic non-invasive method for Parkinson's disease classification," *Computer methods and programs in biomedicine*, vol. 145, pp. 135-145, 2017.
- [4] J. M. Melvin, *The effects of heel height, shoe volume and upper stiffness on shoe comfort and plantar pressure*. University of Salford (United Kingdom), 2014.
- [5] P. Ghaderyan and G. Fathi, "Inter-limb time-varying singular value: a new gait feature for Parkinson's disease detection and stage classification," *Measurement*, vol. 177, p. 109249, 2021.
- [6] V. Novak et al., "Cerebral flow velocities during daily activities depend on blood pressure in patients with chronic ischemic infarctions," *Stroke*, 2010.
- [7] E. C. Lee et al., "Utility of exosomes in ischemic and hemorrhagic stroke diagnosis and treatment," *International Journal of Molecular Sciences*, vol. 23, no. 15, p. 8367, 2022.
- [8] Y. Zhang et al., "Detection of acute ischemic stroke and backtracking stroke onset time via machine learning analysis of

- [27] C. Le Bocq, M. Rousseaux, N. Buisset, W. Daveluy, S. Blond, and E. Allart, "Effects of tibial nerve neurotomy on posture and gait in stroke patients: a focus on patient-perceived benefits in daily life," *Journal of the Neurological Sciences*, vol. 366, pp. 158-163, 2016.
- [28] A. Mannini, D. Trojaniello, A. Cereatti, and A. M. Sabatini, "A machine learning framework for gait classification using inertial sensors: Application to elderly, post-stroke and huntington's disease patients," *Sensors*, vol. 16, no. 1, p. 134, 2016.
- [29] E. Bergamini, M. Iosa, V. Belluscio, G. Morone, M. Tramontano, and G. Vannozzi, "Multi-sensor assessment of dynamic balance during gait in patients with subacute stroke," *Journal of biomechanics*, vol. 61, pp. 208-215, 2017.
- [30] M. Saljuqi and P. Ghaderyan, "A novel method based on matching pursuit decomposition of gait signals for Parkinson's disease, Amyotrophic lateral sclerosis and Huntington's disease detection," *Neuroscience Letters*, vol. 761, p. 136107, 2021.
- [31] R. Polikar, "The wavelet tutorial," ed, 1996.
- [32] H. S. Pal, A. Kumar, A. Vishwakarma, and M. K. Ahirwal, "Electrocardiogram signal compression using tunable-Q wavelet transform and meta-heuristic optimization techniques," *Biomedical Signal Processing and Control*, vol. 78, p. 103932, 2022.
- [33] S. C. KS, A. Mishra, V. Shirhatti, and S. Ray, "Comparison of matching pursuit algorithm with other signal processing techniques for computation of the time-frequency power spectrum of brain signals," *Journal of Neuroscience*, vol. 36, no. 12, pp. 3399-3408, 2016.
- [34] I. Selesnick, "Wavelet transform with tunable Q-factor IEEE transactions on signal processing. 2011 Aug; 8 (59) pp: 3560-75. doi: 10.1109," TSP, 2011.
- [35] S. Taran, V. Bajaj, G. Sinha, and K. Polat, "Detection of sleep apnea events using electroencephalogram signals," *Applied Acoustics*, vol. 181, p. 108137, 2021.
- [36] M. Baygin, "An accurate automated schizophrenia detection using TQWT and statistical moment based feature extraction," *Biomedical Signal Processing and Control*, vol. 68, p. 102777, 2021.
- [37] M. Li, S. Tian, L. Sun, and X. Chen, "Gait analysis for post-stroke hemiparetic patient by multi-features fusion method," *Sensors*, vol. 19, no. 7, p. 1737, 2019.
- [38] D. Yoo, Y. Son, D.-H. Kim, K.-H. Seo, and B.-C. Lee, "Technology-assisted ankle rehabilitation improves balance and gait performance in stroke survivors: a randomized controlled study with 1-month follow-up," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 12, pp. 2315-2323, 2018.
- [39] J. C. Dean, A. E. Embry, K. H. Stimpson, L. A. Perry, and S. A. Kautz, "Effects of hip abduction and adduction accuracy on post-stroke gait," *Clinical Biomechanics*, vol. 44, pp. 14-20, 2017.
- [40] P. Ghaderyan and S. M. G. Beyrami, "Neurodegenerative diseases detection using distance metrics and sparse coding: A new perspective on gait symmetric features," *Computers in Biology and Medicine*, vol. 120, p. 103736, 2020.
- [41] M.-G. Tan, J.-H. Ho, H.-T. Goh, H. K. Ng, L. A. Latif, and M. Mazlan, "A new fractal-based kinetic index to characterize gait deficits with application in stroke survivor functional mobility assessment," *Biomedical Signal Processing and Control*, vol. 52, pp. 403-413, 2019.
- [42] P. Ghaderyan and A. Abbasi, "A novel cepstral-based technique for automatic cognitive load estimation," *Biomedical Signal Processing and Control*, vol. 39, pp. 396-404, 2018.
- [43] M. Pourezzat and H. Danandeh Hesar, "Development of a New Adaptive Method Based on Empirical Fourier Decomposition for the Diagnosis of Obstructive Sleep Apnea Using Electrocardiogram Signal Analysis," *TABRIZ JOURNAL OF ELECTRICAL ENGINEERING*, vol. 53, no. 3, pp. 159-170, 2023.
- [44] R. J. Urbanowicz, M. Meeker, W. La Cava, R. S. Olson, and J. H. Moore, "Relief-based feature selection: Introduction and review," *Journal of biomedical informatics*, vol. 85, pp. 189-203, 2018.
- [45] M. Wang et al., "Research on abnormal gait recognition algorithms for stroke patients based on array pressure sensing system," in 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), IEEE, pp. 1560-1563, 2019.
- metabolomics," *Biomedicine & Pharmacotherapy*, vol. 155, p. 113641, 2022.
- [9] G. Das and P. Kumar, "Potential key genes for predicting risk of stroke occurrence: A computational approach," *Neuroscience Informatics*, vol. 2, no. 2, p. 100068, 2022.
- [10] Y.-H. Wang et al., "Lumbrokinase regulates endoplasmic reticulum stress to improve neurological deficits in ischemic stroke," *Neuropharmacology*, vol. 221, p. 109277, 2022.
- [11] S. J. Park, I. Hussain, S. Hong, D. Kim, H. Park, and H. C. M. Benjamin, "Real-time gait monitoring system for consumer stroke prediction service," in 2020 IEEE International conference on consumer electronics (ICCE), IEEE, pp. 1-4, 2020.
- [12] S. S. Bidabadi, I. Murray, G. Y. F. Lee, S. Morris, and T. Tan, "Classification of foot drop gait characteristic due to lumbar radiculopathy using machine learning algorithms," *Gait & posture*, vol. 71, pp. 234-240, 2019.
- [13] S. M. G. Beyrami and P. Ghaderyan, "A robust, cost-effective and non-invasive computer-aided method for diagnosis three types of neurodegenerative diseases with gait signal analysis," *Measurement*, vol. 156, p. 107579, 2020.
- [14] K. Echigoya, K. Okada, M. Wakasa, A. Saito, M. Kimoto, and A. Suto, "Changes to foot pressure pattern in post-stroke individuals who have started to walk independently during the convalescent phase," *Gait & Posture*, vol. 90, pp. 307-312, 2021.
- [15] C. Beyaert, R. Vasa, and G. E. Frykberg, "Gait post-stroke: Pathophysiology and rehabilitation strategies," *Neurophysiologie Clinique/Clinical Neurophysiology*, vol. 45, no. 4-5, pp. 335-355, 2015.
- [16] M. Jacquelin Perry, "Gait analysis: normal and pathological function," New Jersey: SLACK, 2010.
- [17] A. Sant'Anna and N. Wickström, "A symbol-based approach to gait analysis from acceleration signals: Identification and detection of gait events and a new measure of gait symmetry," *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, no. 5, pp. 1180-1187, 2010.
- [18] S. Krishnan and Y. Athavale, "Trends in biomedical signal feature extraction," *Biomedical Signal Processing and Control*, vol. 43, pp. 41-63, 2018.
- [19] W. Wang, K. Li, N. Wei, C. Yin, and S. Yue, "Evaluation of postural instability in stroke patient during quiet standing," in 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), IEEE, pp. 2522-2525, 2017.
- [20] F. Valentini, B. Granger, D. Hennebelle, N. Eythrib, and G. Robain, "Repeatability and variability of baropodometric and spatio-temporal gait parameters—results in healthy subjects and in stroke patients," *Neurophysiologie Clinique/Clinical Neurophysiology*, vol. 41, no. 4, pp. 181-189, 2011.
- [21] K. Hirata et al., "Adaptive changes in foot placement for split-belt treadmill walking in individuals with stroke," *Journal of Electromyography and Kinesiology*, vol. 48, pp. 112-120, 2019.
- [22] P. Lopez-Meyer, G. D. Fulk, and E. S. Sazonov, "Automatic detection of temporal gait parameters in poststroke individuals," *IEEE Transactions on Information Technology in Biomedicine*, vol. 15, no. 4, pp. 594-601, 2011.
- [23] K. van Kammen, A. M. Boonstra, L. H. van der Woude, H. A. Reinders-Messelink, and R. den Otter, "Differences in muscle activity and temporal step parameters between Lokomat guided walking and treadmill walking in post-stroke hemiparetic patients and healthy walkers," *Journal of neuroengineering and rehabilitation*, vol. 14, pp. 1-11, 2017.
- [24] M. Muñoz-Organero, J. Parker, L. Powell, and S. Mawson, "Assessing walking strategies using insole pressure sensors for stroke survivors," *Sensors*, vol. 16, no. 10, p. 1631, 2016.
- [25] K. J. Nolan, M. Yarossi, and P. McLaughlin, "Changes in center of pressure displacement with the use of a foot drop stimulator in individuals with stroke," *Clinical biomechanics*, vol. 30, no. 7, pp. 755-761, 2015.
- [26] M. Muñoz-Organero, J. Parker, L. Powell, R. Davies, and S. Mawson, "Sensor optimization in smart insoles for post-stroke gait asymmetries using total variation and L1 distances," *IEEE Sensors Journal*, vol. 17, no. 10, pp. 3142-3151, 2017.

- analysis of noisy nonlinear and non-stationary signals," *Digital Signal Processing*, vol. 45, pp. 55-68, 2015.
- [65] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, "A comprehensive survey on support vector machine classification: Applications, challenges and trends," *Neurocomputing*, vol. 408, pp. 189-215, 2020.
- [66] Y. Narayan, "SEMG signal classification using KNN classifier with FD and TFD features," *Materials Today: Proceedings*, vol. 37, pp. 3219-3225, 2021.
- [67] J. Zhou et al., "Predicting Stroke and Mortality in Mitral Regurgitation: A Machine Learning Approach," *Current Problems in Cardiology*, p. 101464, 2022.
- [68] A. Subudhi, M. Dash, and S. Sabut, "Automated segmentation and classification of brain stroke using expectation-maximization and random forest classifier," *Biocybernetics and Biomedical Engineering*, vol. 40, no. 1, pp. 277-289, 2020.
- [69] G. Cattani, "Combining data envelopment analysis and Random Forest for selecting optimal locations of solar PV plants," *Energy and AI*, vol. 11, p. 100222, 2023.
- [70] C. Donos, M. Dümpelmann, and A. Schulze-Bonhage, "Early seizure detection algorithm based on intracranial EEG and random forest classification," *International journal of neural systems*, vol. 25, no. 05, p. 1550023, 2015.
- [46] S. Osowski, K. Siwek, and T. Markiewicz, "MLP and SVM networks-a comparative study," in *Proceedings of the 6th Nordic Signal Processing Symposium, NOR SIG 2004.*, 2004: IEEE, pp. 37-40, 2004.
- [47] S. Ray, "An analysis of computational complexity and accuracy of two supervised machine learning algorithms—K-nearest neighbor and support vector machine," in *Data Management, Analytics and Innovation: Proceedings of ICDMAI 2020, Volume 1*, Springer, pp. 335-347, 2021.
- [48] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez, "An assessment of the effectiveness of a random forest classifier for land-cover classification," *ISPRS journal of photogrammetry and remote sensing*, vol. 67, pp. 93-104, 2012.
- [49] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals," *circulation*, vol. 101, no. 23, pp. e215-e220, 2000.
- [50] V. Novak et al., "Cerebral flow velocities during daily activities depend on blood pressure in patients with chronic ischemic infarctions," *Stroke*, vol. 41, no. 1, pp. 61-66, 2010.
- [51] V. Bajaj, S. Taran, S. K. Khare, and A. Sengur, "Feature extraction method for classification of alertness and drowsiness states EEG signals," *Applied Acoustics*, vol. 163, p. 107224, 2020.
- [52] A. R. Hassan, S. Siuly, and Y. Zhang, "Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating," *Computer methods and programs in biomedicine*, vol. 137, pp. 247-259, 2016.
- [53] G. Kaushik, P. Gaur, R. R. Sharma, and R. B. Pachori, "EEG signal based seizure detection focused on Hjorth parameters from tunable-Q wavelet sub-bands," *Biomedical Signal Processing and Control*, vol. 76, p. 103645, 2022.
- [54] I. W. Selesnick, "Wavelet transform with tunable Q-factor," *IEEE transactions on signal processing*, vol. 59, no. 8, pp. 3560-3575, 2011.
- [55] A. Sharma, S. Patidar, A. Upadhyay, and U. R. Acharya, "Accurate tunable-Q wavelet transform based method for QRS complex detection," *Computers & Electrical Engineering*, vol. 75, pp. 101-111, 2019.
- [56] G. Manikandan and S. Abirami, "An efficient feature selection framework based on information theory for high dimensional data," *Applied Soft Computing*, vol. 111, p. 107729, 2021.
- [57] S. Kilicarslan, K. Adem, and M. Celik, "Diagnosis and classification of cancer using hybrid model based on ReliefF and convolutional neural network," *Medical hypotheses*, vol. 137, p. 109577, 2020.
- [58] K. Kira and L. A. Rendell, "A practical approach to feature selection," in *Machine learning proceedings*, Elsevier, 1992, pp. 249-256, 1992.
- [59] B. Zhang, Y. Li, and Z. Chai, "A novel random multi-subspace based ReliefF for feature selection," *Knowledge-Based Systems*, vol. 252, p. 109400, 2022.
- [60] M. Robnik-Šikonja and I. Kononenko, "An adaptation of Relief for attribute estimation in regression," in *Machine learning: Proceedings of the fourteenth international conference (ICML'97)*, vol. 5: Citeseer, pp. 296-304, 1997.
- [61] R. Altilio, A. Rossetti, Q. Fang, X. Gu, and M. Panella, "A comparison of machine learning classifiers for smartphone-based gait analysis," *Medical & Biological Engineering & Computing*, vol. 59, pp. 535-546, 2021.
- [62] P. Patil, K. S. Kumar, N. Gaud, and V. B. Semwal, "Clinical human gait classification: extreme learning machine approach," in *2019 1st international conference on advances in science, engineering and robotics technology (ICASERT)*, IEEE, pp. 1-6, 2019.
- [63] N. Biswas, K. M. M. Uddin, S. T. Rikta, and S. K. Dey, "A comparative analysis of machine learning classifiers for stroke prediction: A predictive analytics approach," *Healthcare Analytics*, vol. 2, p. 100116, 2022.
- [64] J. P. Amezcua-Sanchez and H. Adeli, "A new music-empirical wavelet transform methodology for time-frequency