

Detection freezing of gait (FOG) in Parkinson's patients using wearable sensors and deep learning

Maryam Talebvand¹

Amir Lakizadeh²

Faranak Fotouhi³

Abstract

Freezing of the gait (FOG) is a complication of Parkinson's disease (PD) that leads to the patient's inability to perform motor activities. The occurrence of FOG reduces patients' independence in daily activities and generally reduces their quality of life. The use of computational methods can provide non-pharmacological support and complementary information about the disease to neurologists by carefully examining patients' FOG status and increasing the likelihood of a more effective treatment. This paper presents a method for FOG detection based on deep learning and signal processing techniques. The data used for this paper is the Daphnet data collection, which is collected by the wearable sensors on the patient's body. The proposed method detects FOG by providing a deep neural network architecture based on two-way short-term memory networks (BDL-FOG). Experimental results show that the proposed method, due to its better compatibility with time-series data, has been able to improve the FOG detection process to achieve higher accuracy than the best available methods.

Keywords: Deep learning, Freezing of gait, Parkinson's disease, Recursive neural networks.

¹ MSc. Student, Computer Engineering Department, University of Qom, Qom, Iran

² Assistant Prof., Computer Engineering Department, University of Qom, Qom, Iran,

³ Assistant Prof., Computer Engineering Department, University of Qom, Qom, Iran

m.talebvand@stu.qom.ac.ir

lakizadeh@qom.ac.ir

f-fotouhi@qom.ac.ir

تشخیص انجماد راه رفتن در بیماران مبتلا به پارکینسون با استفاده از حسگرهای پوشیدنی و یادگیری عمیق

مریم طالب وند^۱

امیر لکی زاده^۲

فرا تک فتوحی^۳

چکیده

انجماد راه رفتن (FOG) یکی از عوارض بیماری پارکینسون (PD) است که منجر به ناتوانی بیمار در انجام فعالیت‌های حرکتی می‌شود. وقوع FOG باعث کاهش استقلال بیماران در انجام فعالیت‌های روزمره و بطور کلی کاهش کیفیت زندگی آنها می‌شود. استفاده از روش‌های محاسباتی می‌تواند با بررسی دقیق وضعیت FOG در بیماران، پشتیبانی غیردارویی و اطلاعات تکمیل‌کننده‌ای را درمورد بیماری به متخصصان مغز و اعصاب ارائه دهد و احتمال ارائه یک درمان موثرتر را افزایش دهد. این مقاله، روشی را برای تشخیص FOG براساس تکنیک‌های یادگیری عمیق و پردازش سیگنال ارائه می‌دهد. داده‌های بکار رفته، مجموعه داده Daphnet می‌باشد که از طریق سنسورهای پوشیدنی قرارگرفته بر روی بدن بیماران، جمع‌آوری شده‌اند. روش پیشنهادی، پس از پالایش و پیش‌پردازش داده‌ها، به تشخیص FOG از طریق ارائه یک معماری شبکه عصبی عمیق مبتنی بر شبکه‌های حافظه کوتاه‌مدت دوطرفه (BDL-FOG) می‌پردازد. نتایج تجربی نشان می‌دهد که روش پیشنهادی به دلیل سازگاری بیشتر با داده‌های سری زمانی، توانسته است ضمن بهبود فرآیند تشخیص FOG، به دقت بالاتری نسبت به بهترین روش‌های موجود دست یابد.

واژه‌های کلیدی: انجماد راه رفتن، بیماری پارکینسون، شبکه‌های عصبی بازگشتی، یادگیری عمیق

^۱ دانشجوی کارشناسی ارشد مهندسی فناوری اطلاعات، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران m.talebvand@stu.qom.ac.ir

^۲ استادیار گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران lakizadeh@qom.ac.ir

^۳ استادیار گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران f-fotouhi@qom.ac.ir

مقدمه

بیماری پارکینسون^۱ یا به اختصار PD، برای اولین بار توسط دانشمند بریتانیایی دکتر جیمز پارکینسون در سال ۱۸۱۷ میلادی توصیف شد [۴،۱۰،۱۳،۸،۹]. این بیماری سیستم حرکتی بدن را مختل می‌کند و علتش تخریب سلول‌های مغزی تولیدکننده دوپامین می‌باشد. دوپامین ماده‌ای است که با بخش کنترل‌کننده حرکات بدن در مغز، در ارتباط است. سیگنال‌هایی که دوپامین به مغز می‌فرستد به ماهیچه‌ها اجازه حرکت می‌دهد و هنگامی که فرد به پارکینسون مبتلا می‌شود، این سلول‌های عصبی از کار می‌افتند و دوپامین به اندازه کافی ترشح نمی‌شود. در نتیجه، مکانیسم راه‌رفتن از حالت خودکار خارج و راه‌رفتن با مشکل روبه‌رو می‌شود که در اصطلاح پزشکی، انجماد راه‌رفتن^۲ (FOG) [۵،۷،۴،۱۵] نامیده می‌شود.

امروزه پزشکان دو روش ارزیابی بالینی فعلی برای FoG استفاده می‌کنند. در روش اول FoG با استفاده از آزمون‌های خاص راه‌رفتن، مقیاس واحد درجه‌بندی بیماری پارکینسون^۳ (UPDRS) یا تست زمان‌بندی‌شده (TUG) ارزیابی می‌شود. در روش دوم بررسی FoG با استفاده از پرسشنامه خاص FoG صورت می‌گیرد که در طول انجام فعالیت‌های روزمره زندگی از بیمار جمع‌آوری می‌شود [۱۸،۱۲،۱]. این دو روش با اینکه در هر دو زمینه بالینی و تحقیقاتی برتری دارند ولی تنها اطلاعات جزئی و گاهی اشتباه در مورد وضعیت بیمار ارائه می‌دهند. به‌علاوه که این ارزیابی‌ها در هر ۳ تا ۶ ماه در طول بیماری توسط یک متخصص مغز و اعصاب انجام می‌شوند و هر بیمار در این بازه باید برای تعیین میزان پیشرفت بیماری‌اش به پزشک متخصص مراجعه کند. این استراتژی‌ها می‌توانند اطلاعات غلطی برای بیمار ارائه دهند، زیرا در مقایسه با خانه بیماران، آزمایش‌ها در محیطی مصنوعی، کوچک و با تنظیمات کنترل‌شده آزمایشگاهی انجام می‌شوند. اختصاص نیروی انسانی متخصص برای کنترل کلیه بیماران مبتلا به پارکینسون به دلیل شیوع آن، یک راه‌حل غیرممکن است. بنابراین، نظارت مداوم از راه دور می‌تواند، یک راه‌حل مناسب و کارآمد

¹. Parkinson's disease

². Freezing of gait

³. Unit parkinson's disease rating scale

برای تعیین میزان پیشرفت بیماری پارکینسون و مشکلات ناشی از آن در فواصل زمانی مشخص با هزینه کمتری باشد. به همین دلیل، در چند سال اخیر تشخیص خودکار مبتنی بر حسگرهای پوشیدنی، توجه زیاد جامعه پژوهش را برای تشخیص علائم FOG به خود جلب کرده است و محققان تلاش می کنند تا روشی مناسب برای ارزیابی و نظارت مداوم به جای روش های ذهنی که از آزمون های ارزیابی بالینی استفاده می کنند، بیابند [۲، ۱۱، ۱۶].

پیشرفت های تکنولوژیکی اخیر، دستگاه های سبک و راحتی را تولید کرده است که می توانند به راحتی کار جمع آوری و پردازش داده ها را انجام دهند. ولی برای دستیابی به عملکرد بهتر تشخیص FOG، نیاز به یک ابزار ریاضی دقیقی برای مقابله با فضای بزرگ داده می باشد. برای این منظور، تکنیک یادگیری ماشین ابزار مهمی است و کاربرد آن برای تشخیص FOG نیز در چندین مطالعه اخیر گزارش شده است. همچنین در سال های اخیر، تکنیک های یادگیری ماشین و یادگیری عمیق نقش بزرگی را در زمینه تشخیص، نظارت و پیش بینی داشته است و امروزه، بسیاری از پروژه های در حال انجام جهت اجرای الگوریتم های هوش مصنوعی برای وظایف مانیتورینگ علامت FOG به وسیله فناوری های پوشیدنی سبک وزن، تلاش می کنند [۳، ۲].

در این پژوهش، به پیاده سازی روش هایی مبتنی بر یادگیری عمیق برای تشخیص FOG در بیماران مبتلا به پارکینسون با استفاده از سیگنال های جمع آوری شده از حسگرهای پوشیدنی پرداخته شده است. برای تشخیص FOG با توجه به اینکه داده ها در این پژوهش ماهیت سری زمانی دارند و الگوریتم های یادگیری عمیق بر روی این نوع داده ها بهتر جواب می دهند و با توجه به اینکه این نوع داده ها نیاز به حافظه دارند، از شبکه های عصبی بازگشتی استفاده شده است. در واقع در این مقاله، سعی بر این بوده که به یک مدل یادگیری عمیق سازگارتر با نوع داده و مسئله دست یابیم. به همین دلیل، به منظور بررسی دقیق و ارائه بهترین روش تشخیص FOG در بیماران، سه معماری متفاوت از شبکه عصبی عمیق به نام های CNN-FOG، FFL-FOG و BDL-FOG ارائه و پیاده سازی شد و بر پایه

ارزیابی‌های مختلف نشان داده شد که مدل BDL-FOG توانسته‌است به بهترین کارایی با میانگین هندسی ۸۷ درصد در فرآیند تشخیص FOG دست یابد، درحالی‌که، پژوهش‌های دیگر با مجموعه داده Daphnet، نتوانستند به میانگین هندسی بالاتر از ۸۳ درصد دست یابند.

نتایج به دست آمده از این مقاله می‌تواند به متخصصان مغز و اعصاب و کادر پزشکی کمک کند تا بتوانند علائم FoG در بیماران مبتلا به پارکینسون را قبل از اینکه خیلی دیر شود، شناسایی کنند. در نهایت این کار منجر به بهبود نظارت پزشکی بر پیشرفت FoG در بیماران مبتلا به PD می‌شود. با تکیه بر نتایج این پژوهش، نیاز به حضور فیزیکی پزشک و پرستار برطرف می‌شود و پزشک می‌تواند از راه دور از وضعیت بیمار مطلع شود که باعث کاهش هزینه‌ها، زمان و نیروی انسانی می‌شود. بخش‌های اصلی این مقاله شامل چکیده، مقدمه، پیشینه پژوهش، مجموعه داده، روش‌های پیشنهادی، نتایج و در پایان نتیجه‌گیری و بحث می‌باشد که در ادامه بیان می‌شود.

مروری بر کارهای پیشین

مطالعات فراوانی در زمینه تشخیص FOG انجام شده‌است که در این مقاله به تعدادی از آنها اشاره می‌شود. نویسندگان در پژوهش [۱۴] برای جمع‌آوری داده‌ها، نوسان‌پا را با استفاده از دو سنسور شتاب‌سنج دو محوره در دو فرد مبتلا به پارکینسون و پنج فرد سالم اندازه‌گیری کردند. تحقیقات آنها بیان می‌کند که فرکانس شتاب FOG (۶ تا ۸ هرتز) در هر فرد مبتلا به پارکینسون به‌طور قابل توجهی بالاتر از راه‌رفتن معمولی (۲ هرتز) است. آنها مشکل طبقه‌بندی را به صورت عادی، FOG و حالت استراحت تدوین کرده و با ارزیابی تفاوت‌های سطح قدرت موجک در باندهای مختلف فرکانس، آن را حل کردند.

اولین تلاش برای شناسایی اتوماتیک FOG توسط مور و همکارانش در سال ۲۰۰۸ [۱۲] انجام شد. داده‌های آنها از یک سنسور شتاب‌سنج سه‌بعدی توسط سیستم‌های میکروالکترومکانیکی (MEMS) قرار گرفته در ساق پای بیمار جمع‌آوری شد. رویکرد آنها شامل یک آستانه شاخص انجماد (FI) بود که در آن FI به عنوان نسبت بین چگالی طیف

قدرت در باند انجماد راهرفتن (FB) یعنی ۳ تا ۸ هرتز (Hz) و باند حرکتی (LB) تعریف شده بود. آنها توانستند FOG را با دقت ۷۸ درصد تشخیص دهند. علاوه بر این، کالیبره کردن آستانه برای هر بیمار عملکرد روش را تا ۸۹ درصد بهبود بخشید. با این حال، آنها ارزیابی ضعیفی را روی داده‌های حاوی ۴۶ رویداد FOG گزارش کردند. مطالعه آنها به عنوان نقطه عطفی در این زمینه شناخته شد زیرا FI همچنان رایج‌ترین ویژگی استخراج شده برای تشخیص FOG است. در سال ۲۰۱۰ [۶]، بچلین و همکارانش، روش مور را بسط دادند و دو تغییر اصلی بر روی آن اعمال کردند:

(۱) یک آستانه شاخص قدرت (PI) اضافی برای سیگنال در ۰/۵ تا ۸ هرتز معرفی کردند تا داده‌های ایستادن فرد را به عنوان موارد کاندید FOG نادیده بگیرند.

(۲) یک مدت زمان ۴ ثانیه را برای پنجره بکار گرفتند.

آنها ۷۳/۱ درصد و ۸۱/۶ درصد را برای معیارهای حساسیت^۱ و شناسا^۲ گزارش کردند، به دلیل سادگی، روش MBFA به عنوان مرجع اصلی عملکرد برای تشخیص اتوماتیک FOG در داده‌های حسگرهای اینرسی در بیماران PD شناخته شد. آنها از مجموعه داده Daphnet استفاده کردند. در [۱۸]، شش بیمار مبتلا به PD با استفاده از پنج سنسور یکپارچه شتاب در قالب شلوار هوشمند، یک مسیر استاندارد را طی کردند. آنها برای شناسایی وقایع انجماد از یک الگوریتم با آستانه غالب فرکانس استفاده کردند، داده‌های ضبط شده از سنسورها توسط الگوریتم‌های آنالیز شده برای تشخیص FOG مورد تجزیه و تحلیل قرار گرفتند. این روش با نام MiMed-Pants در حالت وابسته به کاربر به دقت ۸۵/۳ درصد و ۸۸/۳ درصد در معیارهای شناسا و حساسیت دست یابد. با این وجود، آنها اذعان کردند که مدل آنها نمی‌تواند آکینزیا را در طی یک FOG تشخیص دهد و محدودیت دیگر این روش، وابسته به کاربر بود.

اثر بچلین و همکاران [۶] توسط مازیلو در سال ۲۰۱۲ ادامه یافت [۵]. آنها رویکرد

¹. Sensitivity (True positive rate, recall)

². Specificity (True negative rate)

جدیدی را برای نظارت بر FOG در بیماران مبتلا به PD بر روی مجموعه داده Daphnet ارائه دادند که ترکیبی از تلفن‌های هوشمند و شتاب‌سنج‌های پوشیدنی برای جمع‌آوری داده بود. در این پژوهش، برای اولین بار از الگوریتم‌های یادگیری ماشین (ML) برای تشخیص آنلاین FOG استفاده شد. برخی از الگوریتم‌های ML که آنها آزمایش کردند عبارتند از: جنگل‌های تصادفی، درخت تصمیم‌گیری، naiveBayes و k-NN. آنها به ترتیب مقادیر ۶۶/۲۵ درصد و ۹۵/۳۸ درصد را برای حساسیت و شناسا با استفاده از تنظیمات مستقل از بیمار گزارش کردند و از جنگل‌های تصادفی به‌عنوان الگوریتم طبقه‌بندی استفاده شد.

پژوهش [۲۱] نتایج مطالعه برای تشخیص زودهنگام FOG در بیماران مبتلا به PD را با استفاده از سیگنال‌های EEG نشان می‌دهد. در این پژوهش به‌جای داده‌های شتاب‌سنج، از سیگنال‌های الکتروانسفالوگرام (EEG) استفاده شد. هدف از این مطالعه، دستیابی به تشخیص زودهنگام FOG و کمک به بیماران برای جلوگیری از حوادث بعدی FOG است. میانگین دقت، حساسیت و شناسا در این پژوهش حدود ۷۵ درصد است.

در [۱۶] یک روش برای تشخیص خودکار FOG پیشنهاد شد. روش آنها شامل چهار مرحله بود: تمیز کردن داده‌ها، فیلتر کردن، استخراج ویژگی‌ها و طبقه‌بندی. آنها بهترین نتیجه را با استفاده از الگوریتم جنگل‌های تصادفی، با نتایج ۸۱/۹۴ درصد و ۹۸/۷۴ درصد برای حساسیت و شناسا به‌دست آوردند.

در [۲۲]، پژوهشگران، مطالعه‌ای را با هدف تشخیص FOG در بیماران مبتلا به PD در طول زندگی روزمره انجام داده و ماشین‌های بردار پشتیبان (SVM) را برای کار طبقه‌بندی باینری FOG ارائه دادند. بالاترین نتایج به‌دست آمده با استفاده از یک پنجره ۱/۶ ثانیه به دست آمد که ۸۹/۷۷ درصد را به‌عنوان میانگین مهندسی (GM) بین حساسیت و شناسا گزارش کرد.

در پژوهش بعدی از الگوریتم یادگیری عمیق برای مدل تشخیص FoG استفاده شد [۲۰]. در این مطالعه، پس از استخراج ویژگی‌های سیگنال‌های الکتروانسفالوگرام (EEG)

به کمک محاسبات تبدیل موجک گسسته، از تکنیک‌های تشخیص الگو استفاده شد. این مدل توانست میانگین عملکرد برای کاربر ویژه را با صحت، حساسیت و شناسا حدود ۷۵ درصد گزارش کند.

در [۳] یک سیستم تشخیص FOG جدید ارائه شد که مبتنی بر شبکه‌های عصبی کانولوشنی (CNN) بود. سیستم پیشنهادی، از داده‌های سری زمانی شتاب نمونه برداری شده از شتاب‌سنج در موقعیت مچ پا، زانو و کمر استفاده می‌کند. در آزمایشات مستقل از بیمار، عملکرد طبقه‌بندی یک نتیجه متوسط از حساسیت ۶۹/۲۹ درصد و شناسا ۹۰/۶۰ درصد بود که با این مقادیر برای این مدل میانگین هندسی ۷۹/۲۳ درصد به دست آمد. این نتایج نشان می‌دهد که سیستم مبتنی بر CNN می‌تواند در تشخیص FOG و توانبخشی بیماران و کمک به راه رفتن آنها مفید باشد.

در [۱۹] از یک مدل ترکیبی الگوریتم FFT و طبقه‌بندی رگرسیون لجستیک برای تشخیص FOG استفاده شد. این روش می‌تواند در تشخیص بیماری پارکینسون براساس تنها یک سنسور استفاده شود. این مدل به مقادیر ۱۰۰ درصد و ۶۲/۵ درصد برای حساسیت و شناسا و میانگین هندسی ۷۹/۰۵ درصد و دقت ۸۱/۳ درصد دست یافت. در جدول ۱، خلاصه‌ای از روش‌های مختلف تشخیص انجماد و نحوه کار آنها همراه با دقت گزارش شده در مقاله اصلی (در صورت وجود) ذکر شده است.

جدول ۱. خلاصه پژوهش‌های بررسی شده در پیشینه پژوهش

| مرجع | ویژگی روش | حساسیت | شناسا | میانگین هندسی |
|------|--|--------|-------|---------------|
| [۱۴] | تشخیص حالت انجماد از عدم انجماد با استفاده از ویژگی‌های مربوط به دامنه فرکانس | - | - | - |
| [۱۲] | تشخیص حالت انجماد مبتنی بر تفاوت‌های سطح قدرت موجک در باندهای مختلف فرکانس انجماد و عدم انجماد | - | - | - |
| [۶] | اعمال دو تغییر اصلی بر روی روش Moor تعریف آستانه شاخص قدرت (PI) power index | ۷۳/۱ | ۸۱/۶ | ۷۷/۲۳ |

| مرجع | ویژگی روش | حساسیت | شناسا | میانگین هندسی |
|------|---|--------|-------|------------------|
| | در نظر گرفتن پنجره‌های به طول ۴ ثانیه بر روی ورودی | | | |
| [۱۸] | استفاده از سنسورهای پوشیدنی در پا به منظور اندازه‌گیری حرکات به کمک یک حد آستانه فرکانس | ۸۸/۳ | ۸۵/۳ | ۸۶/۷۸ |
| [۵] | استفاده از الگوریتم‌های یادگیری ماشین | ۶۶/۲۵ | ۹۵/۳۸ | ۷۹/۴۹ |
| [۲۱] | تجزیه و تحلیل سیگنال‌های EEG | - | - | ۷۵ |
| [۱۶] | استفاده از الگوریتم‌های یادگیری ماشین | ۸۱/۹۴ | ۹۸/۷۴ | ۸۹/۹۴ |
| [۲۲] | (SVM ماشین‌های بردار پشتیبان) | ۹۱/۷ | ۸۷/۰۴ | ۸۹/۵۲ |
| [۲۰] | تجزیه و تحلیل سیگنال‌های EEG | - | - | ۷۵ |
| [۳] | (CNN شبکه عصبی کانولوشنی) | ۶۹/۲۹ | ۹۰/۶۰ | ۷۹/۲۳ |
| [۱۹] | استفاده از مدل ترکیبی FFT و طبقه‌بندی رگرسیون لجستیک | ۱۰۰ | ۶۲/۵ | ۷۹/۰۵ |

از سال ۲۰۰۳ پژوهشگران به توسعه روش‌های مختلف به منظور تشخیص FOG پرداخته‌اند و هنوز پژوهش‌ها برای حل این مسئله با رویکردهای مختلف ادامه دارد. در اوایل، از تجزیه و تحلیل سیگنال‌ها و الگوریتم‌های تشخیص آستانه انجماد بدین منظور استفاده شد و سپس در سال‌های بعد، روش‌های یادگیری ماشین و یادگیری عمیق توسعه یافت. ملاک ارزیابی مدل‌ها برای تشخیص FOG میانگین هندسی بین حساسیت و شناسا می‌باشد. در این پژوهش از مجموعه داده Daphnet که یک مجموعه داده در دسترس و معتبر برای حل مسئله تشخیص FOG است، استفاده شده است. داده‌ها در این مجموعه داده از نوع سری زمانی هستند و الگوریتم‌های یادگیری عمیق بر روی این نوع داده‌ها بهتر

جواب می‌دهند. همچنین، از آنجا که در روش‌های یادگیری عمیق، عمل استخراج ویژگی به‌جای دستی (و توسط انسان خبره) به‌صورت خودکار و مبتنی بر مجموعه داده انجام می‌گیرد، منجر به استخراج ویژگی‌های کارآتر و در نتیجه بهبود فرآیند تشخیص FOG می‌شود.

مجموع داده‌ها

در این مقاله، از مجموعه داده Daphnet Freezing of Gait [۶]، استفاده شده است. این مجموعه داده، یک مجموعه داده عمومی، معتبر و دردسترس عموم برای مسئله تشخیص FOG می‌باشد که پژوهش‌های بسیاری تاکنون از جمله پژوهش‌های [۵]، [۶]، [۱۷] و بسیاری از پژوهش‌های اخیر از این مجموعه داده استفاده می‌کنند. این مجموعه داده، برای ثبت اتوماتیک وقایع FOG، از ۳ سنسور شتاب‌سنج سه‌محوره (Z, Y, X) پوشیدنی که به پاها، ران و تنه بیمار متصل می‌شوند، استفاده می‌کند. محور X شتاب افقی روبه‌جلو، محور Y شتاب عمودی فرد و محور Z شتاب جانبی افقی فرد را اندازه‌گیری می‌کند. حسگرها، شتاب‌های سه‌بعدی را ضبط کرده و داده‌های شتاب به یک سیستم پوشیدنی که به تنه افراد وصل شده است، منتقل می‌شود. این حسگرها به‌صورت بی‌سیم به سیستم پوشیدنی متصل شده‌اند. مجموع اطلاعات شتاب اندازه‌گیری شده در این مجموعه داده برابر ۸ ساعت و ۲۰ دقیقه می‌باشد. داده‌های این مجموعه داده، چندمتغیره و از نوع سری زمانی هستند.

این مجموعه داده نتیجه تحقیقاتی است که توسط آزمایشگاه Gait و نورودینامیک در مرکز پزشکی تل‌آویو سورااسکی (TASMC) در اسرائیل و آزمایشگاه محاسبات پوشیدنی در ETH زوریخ در سوئیس انجام شده است. داده‌ها از ۱۰ فرد مبتلا به پارکینسون جمع‌آوری شده که FOG را تجربه کرده‌اند و افراد مورد مطالعه ۷ مرد و ۳ زن در سنین ۵۹ تا ۷۵ سال هستند. در این بررسی، بیماران مبتلا به پارکینسون که دارای علائم بیماری‌های دیگر مانند زوال عقل، شنوایی سخت و کاهش بینایی می‌باشند از مطالعه خارج شده‌اند. شایان ذکر است که در مجموعه داده اولیه Daphnet یک کلاس اضافی با برچسب صفر

وجود دارد. از آنجا که بخشی از آزمایش نمی‌باشد و مربوط به فعالیت‌های غیر مرتبط با پروتکل است در مرحله پیش‌پردازش، این برجسب از مجموعه داده حذف شد و در نتیجه نمونه داده‌ها به صورت دو کلاس با مقدار یک برای حالت بدون انجماد و مقدار دو بیانگر حالت انجماد در نظر گرفته شد. در این پژوهش، مرحله اول شامل نمونه‌برداری (کاهش حجم داده‌ها) از سیگنال‌های سنسور و محاسبه مقدار سیگنال‌های شتاب است. مرحله بعدی، استفاده از روش‌های پنجره‌سازی است، جایی که مقداری از سیگنال‌های حسگر در پنجره‌هایی باهم تداخل دارند. پس از تقسیم‌بندی، ویژگی‌ها از هر پنجره استخراج می‌شوند و بردارهای ویژگی حاصل به عنوان داده‌های ورودی آموزش استفاده می‌شوند.

روش پیشنهادی

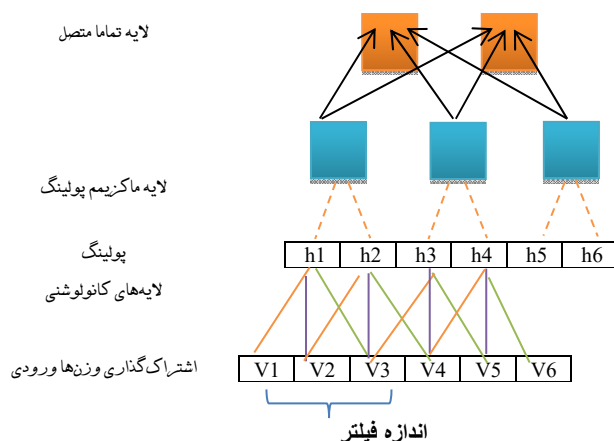
داده‌های ثبت شده از حرکات بیمار ماهیت سری زمانی دارند و الگوریتم‌های یادگیری عمیق بر روی این داده‌ها کارایی بهتری دارند [۳]. پس یادگیری عمیق این پتانسیل را دارد که بهبود قابل توجهی در تشخیص FOG داشته باشد. همچنین، استفاده از یادگیری عمیق می‌تواند روش‌های استخراج ویژگی دستی را که فاقد پایه فیزیولوژیکی قوی هستند با روش‌های استخراج ویژگی خودکار جایگزین کند. با این حال، انتخاب مناسب‌ترین روش یادگیری عمیق برای تشخیص FOG با توجه به اینکه ماهیت داده‌ها از نوع سری زمانی هستند امر دشواری است، زیرا این نوع داده‌ها نیاز به حافظه دارند. در این پژوهش به منظور بررسی دقیق مسئله و ارائه بهترین روش تشخیص FOG در بیماران، سه معماری متفاوت شبکه عصبی عمیق با نام‌های CNN-FOG، FFL-FOG و BDL-FOG ارائه و پیاده‌سازی شد و برحسب آزمایش‌های مختلف نشان داده شد که مدل BDL-FOG می‌تواند به کارایی بهتری در فرآیند تشخیص اختلال FOG دست یابد. در ادامه مطالب این بخش، پس از معرفی مراحل پیش‌پردازش داده و استخراج ویژگی‌ها، سه مدل ارائه شده شرح داده می‌شود.

مدل شبکه عصبی کانولوشنی CNN-FOG

یکی از موفق‌ترین شبکه‌های یادگیری عمیق، شبکه‌های عصبی کانولوشنی (CNN)

¹. Convolution neural networks

هستند. هر CNN شامل لایه‌های کانولوشنی، پولینگ و لایه تماما متصل است. اولین مدل ارائه شده در این پژوهش به نام CNN-FOG مبتنی بر معماری شبکه کانولوشنی می باشد. لایه ورودی CNN-FOG سیگنال‌های شتاب‌سنج‌ها را دریافت می کند. در این پژوهش، سیگنال‌های سنسور با پنجره کشویی به اندازه ۳/۴ ثانیه (۸۵ نمونه)، همپوشانی ۵۰ درصد و نرخ نمونه برداری ۲۵ هر تیز است. تعداد کانال‌ها (ابعاد ورودی) با توجه به سه سنسور سه بعدی موجود، برابر ۹ عدد است. شکل ۱ ساختار مدل CNN-FOG و جدول ۲ مقادیر هایپر پارامترهای متناظر با آن را نشان می دهد.



شکل ۱. معماری مدل پیشنهادی CNN-FOG.

جدول ۲. مقادیر هایپر پارامترهای مدل پیشنهادی CNN-FOG.

| نام پارامتر | مقدار | نام پارامتر | مقدار |
|---------------------|----------------------|----------------|----------|
| Input_width | ۸۵ | Hidden_layer | ۲ |
| input_height | ۱ | layer_pool | max_pool |
| num_labels | ۲ | training_epoch | ۲۰۰ |
| N_channels | ۹ | learning_rate | ۰.۰۰۰۵ |
| num_hidden | ۵۱۲ | Batch_size | ۱۲۸ |
| activation function | relu | Srtide_size | ۲ |
| loos_function | softmaxcross_Entropy | depth_1 | ۱۲۸ |

| نام پارامتر | مقدار | نام پارامتر | مقدار |
|---------------|-------|-------------|-------|
| kernel_size_1 | ۷ | depth_2 | ۱۲۸ |
| kernel_size_2 | ۳ | depth_3 | ۱۲۸ |
| kernel_size_3 | ۱ | Optimizer | adam |

مدل شبکه عصبی بازگشتی FFL-FOG

یکی از مزیت‌های مهم شبکه‌های عصبی بازگشتی ۱، توانایی آنها در استفاده از اطلاعات سری زمانی در هنگام نگاشت بین توالی ورودی و خروجی است. در این شبکه‌ها، تأثیر یک ورودی خاص با دور شدن از اطراف اتصال بازگشتی شبکه، به صورت نمایی کاهش می‌یابد. در ادبیات علمی به این مسئله ناپدیدشدن گرادیان ۲ می‌گویند. در دهه ۱۹۹۰، حجم زیادی از پژوهش‌ها برای حل مشکل ناپدیدشدن گرادیان برای RNNها انجام شد. یک رویکرد مطلوب برای حل کردن مشکل ناپدیدشدن گرادیان، معماری حافظه کوتاه مدت ماندگار 3 (LSTM) بود که توسط Hochreiter & Schmidhuber در سال ۱۹۹۷ منتشر شد [۲۳]. LSTM نوعی شبکه عصبی بازگشتی است که از مجموعه‌ای از اتصالات بازگشتی و بلوک‌های حافظه متناوب تشکیل شده است. بطور کلی، یک شبکه LSTM شباهت زیادی به شبکه عصبی بازگشتی دارد، با این تفاوت که لایه‌های پنهان آن شامل بلوک‌های حافظه است و لایه‌های خروجی آن همانند RNNهای سنتی است.

بعد از پیاده‌سازی مدل CNN-FOG پیشنهادی، برای یافتن مدلی مناسب‌تر تصمیم به پیاده‌سازی مدلی مبتنی بر شبکه‌های عصبی بازگشتی گرفته شد. مدل دوم این پژوهش، یک LSTM عمیق روبه‌جلو به نام FFLSTM می‌باشد. FFLSTM دارای چندین لایه واحد بازگشتی است که به موقعیت‌های روبه‌جلو متصل می‌شود. LSTM روبه‌جلو، گام زمان فعلی را براساس مواردی که قبلاً دیده است، متناسب می‌کند و ذاتاً برای کاربردهای بلادرنگ مناسب است. جایی که در زمان استنتاج، "آینده" هنوز مشخص نیست. در این معماری، به منظور ایجاد یک مدل که قادر به یادگیری بهتر داده‌ها باشد، یک شبکه عصبی با دو لایه LSTM ایجاد شد. با توجه به داده‌های شتاب‌سنج سه‌بعدی جمع‌آوری شده، در

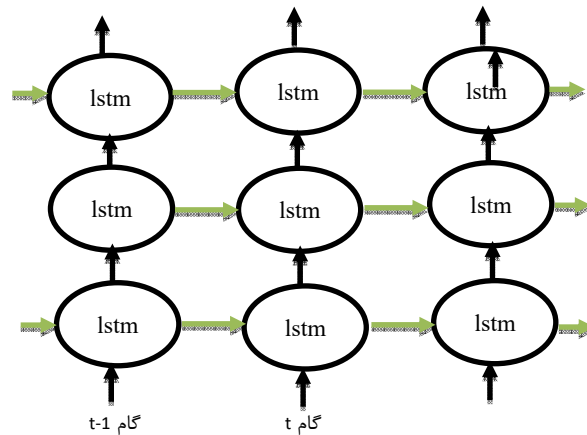
¹. Recurrent Neural Network (RNN)

². Vanishing Gradient

³. Long short-term memory

این مقاله از یک پنجره کشویی به طول ۳/۴ ثانیه استفاده شد. از هر پنجره ویژگی‌هایی استخراج و از آنها به‌عنوان ورودی برای مدل مبتنی بر LSTM استفاده شد. در مدل‌های RNNs، ورودی به جای دو بعد شامل سه بعد (اندازه دنباله، اندازه دسته و تعداد ویژگی‌ها) است.

در هر آزمایش از این پژوهش، ورودی مدل FFL-FOG، به گروهی از ویژگی‌های استخراج شده برای تغذیه شبکه بستگی دارد. پس از دریافت مقادیر ورودی، لایه ورودی با اولین لایه بازگشتی LSTM با چندین بلوک حافظه (نورون‌های هوشمند) تغذیه می‌شود و پس از آن، لایه دوم بازگشتی LSTM قرار دارد. سرانجام از آنجا که پیش‌بینی FoG به‌عنوان یک مسئله طبقه‌بندی دودویی می‌باشد، لایه دوم LSTM، به یک لایه کاملاً متصل به یک تابع فعال‌سازی سیگموئید متصل می‌شود و پیش‌بینی‌ها را برای دو کلاس انجاماد و عدم انجاماد انجام می‌دهد. شکل ۲ ساختار مدل FFL-FOG و جدول ۳ مقادیر هایپر پارامترهای متناظر با آن را نشان می‌دهد.




شکل ۲. معماری مدل پیشنهادی FFL-FOG.

جدول ۳. مقادیر هایپر پارامترهای مدل پیشنهادی FFL-FOG.

| پارامتر | مقدار | پارامتر | مقدار |
|---------------------|-------|----------------|----------------------|
| Input_width | ۸۵ | num_hidden | ۶۴ |
| input_height | ۱ | Hidden_layer | ۲ |
| num_labels | ۲ | training_epoch | ۱۰۰ |
| N_channels | ۹ | learning_rate | ۰.۰۰۱ |
| Batch_size | ۶۴ | loss_function | softmaxcross_Entropy |
| activation function | Relu | Optimizer | Adam |

معماری BDL-FOG پیشنهادی

معماری سوم ارائه شده در این پژوهش با نام BDL-FOG مبتنی بر شبکه‌های عصبی LSTM دوطرفه یا Bi-LSTM می‌باشد و شامل دو لایه پنهان بازگشتی می‌باشد که به آینده و گذشته از زمان فعلی اشاره دارد و حالت‌های داخلی خود را برای زمان t سازگار می‌کند. هر لایه پنهان نیز شامل بلوک‌های LSTM می‌باشد. بین این دو لایه پنهان هیچ اتصالی وجود ندارد. هر دو لایه پنهان به یک خروجی متصل می‌شوند. در این نوع شبکه‌ها، هر دنباله ورودی در دو جهت زمانی روبه جلو و روبه عقب، به دو لایه پنهان بازگشتی (مجزا) داده می‌شود. مقدار خالص رسیده شده به لایه خروجی وزن‌دار، مقدار خالص دو لایه Forward و Backward است. BDL-FOG هم از محتوا آینده و هم گذشته برای تفسیر ورودی در گام زمانی t استفاده می‌کند. شکل ۳ ساختار مدل FFL-FOG و جدول ۴ مقادیر هایپر پارامترهای متناظر با آن را نشان می‌دهد.



شکل ۳. معماری شبکه BDL-FOG پیشنهادی

جدول ۴. مقادیر هایپر پارامترهای مدل پیشنهادی BDL-FOG.

| پارامتر | مقدار | پارامتر | مقدار |
|--------------|-------|----------------|-------|
| Input_width | ۸۵ | training_epoch | ۵۰ |
| input_height | ۱ | learning_rate | 0/001 |

| مقدار | پارامتر | مقدار | پارامتر |
|----------------------|---------------------|-------|--------------|
| ۶۴ | Batch_size | ۲ | num_labels |
| Relu | activation function | ۹ | N_channels |
| ۰/۵ | forget_bias | ۶۴ | num_hidden |
| softmaxcross_Entropy | loos_function | ۱۰ | display_step |
| ۱۰۰۰۰۰ | training_iters | adam | Optimizer |

نتایج

تشخیص FoG یک وظیفه طبقه‌بندی دودویی (وجود و یا عدم انجماد) نامتوازن است. معروف‌ترین معیارهای ارزیابی در تشخیص FOG، حساسیت (نرخ بازخوانی مثبت) و شناسا (نرخ بازخوانی منفی) می‌باشد. عملکرد پیش‌بینی مبتنی بر ارزیابی پنجره است. خروجی طبقه‌بندی‌کننده برای هر پنجره (دنباله) از داده‌های ورودی با برچسب واقعی مرجع مقایسه می‌شود.

پنجره‌هایی که به‌طور صحیح به‌عنوان رخداد "انجماد" برچسب‌گذاری شده‌اند و مدل توانسته‌است آنها را به‌درستی تشخیص دهد، به‌عنوان مثبت واقعی (TP) شمارش می‌شوند. پنجره‌هایی که به‌طور صحیح به‌عنوان رخداد "انجماد" برچسب‌گذاری شده‌اند ولی مدل نتوانسته آنها را به‌درستی تشخیص دهد، به‌عنوان منفی کاذب (FN) شمرده می‌شوند. پنجره‌هایی که به‌عنوان رخداد های بدون "انجماد" برچسب‌گذاری شده‌اند ولی مدل اشتباها آنها را درست تشخیص دهد، به‌عنوان مثبت کاذب (FP) شمرده می‌شوند و در انتها پنجره‌هایی که به‌عنوان رخداد "عدم انجماد" برچسب‌گذاری شده‌اند و مدل نتوانسته آنها را به‌درستی به‌عنوان عدم انجماد تشخیص دهد، به‌عنوان منفی واقعی (TN) محاسبه می‌شوند. حساسیت (فرمول ۱) نسبت پنجره‌های FOG با برچسب درست تشخیص داده شده به تعداد کل پنجره‌های FOG مرجع را اندازه‌گیری می‌کند، درحالی‌که شناسا (فرمول ۲) نسبت پنجره‌های بدون FOG درست تشخیص داده شده به تعداد کل پنجره‌های بدون FOG مرجع را محاسبه می‌کند. معیار دقت (فرمول ۳) نیز ساده‌ترین معیار است. معیار مهم که در این مقاله برای ارزیابی نهایی مدل در نظر گرفته شده‌است، میانگین هندسی (فرمول

۴) می‌باشد. میانگین هندسی یکی از انواع میانگینی است که برای محاسبه نرخ رشد استفاده می‌شود، همچنین به منظور محاسبه میانگین برای مقادیری که با مرتبه‌های متفاوت درجه‌بندی می‌شوند از آن استفاده می‌شود. همچنین یادآوری می‌گردد که در تمام ارزیابی‌های مدل در این بخش، از روش ده فولد ولیدیشن به منظور استخراج مقدار نهایی هر معیار ارزیابی استفاده شده‌است.

$$Sens = \frac{TP}{TP + FN} \quad (1)$$

$$Spec = \frac{TN}{TN + FP} \quad (2)$$

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \quad (3)$$

$$GM = \sqrt{Sens * Spec} \quad (4)$$

در مدل CNN-FOG برای این پژوهش مقادیر حساسیت، شناسا و میانگین و دقت به ترتیب، ۸۹ درصد، ۸۳ درصد، ۸۶ درصد، ۸۹ درصد شد. این مدل در مدت زمان ۳۵۷۵/۱۸ ثانیه اجرا شد. در مدل FFL-FOG پیشنهادی در این پژوهش، دقت ۸۹ درصد، حساسیت ۹۰ درصد و خاصیت ۷۳ درصد و میانگین هندسی ۸۱ درصد در مدت زمان ۴۵۶۱/۸۴ ثانیه به دست آمد. محدودیت این روش نسبت به مدل CNN-FOG مدت زمان اجرای زیاد و مقدار میانگین هندسی پایین تر آن بود. به همین دلیل تصمیم به پیاده‌سازی مدلی دیگر ولی مبتنی بر شبکه‌های عصبی بازگشتی گرفته شد. در مدل BDL-FOG پیشنهادی، دقت ۸۸ درصد، حساسیت ۸۸ درصد و خاصیت ۸۶ درصد و میانگین هندسی ۸۷ درصد در مدت زمان اجرای این مدل ۱۲۰۲/۳۴ به دست آمد. تمامی مقادیر فوق در جدول ۵ نشان داده شده‌است.

جدول ۵. خلاصه نتایج سه مدل پژوهش


| | دقت (acc) % | میانگین هندسی (gm) % | شناسا (spe) | حساسیت (sen) % |
|---------|-------------|----------------------|-------------|----------------|
| CNN-FOG | ۸۹ | ۸۶ | ۸۳ | ۸۹ |
| FFL-FOG | ۸۹ | ۸۱ | ۷۳ | ۹۰ |
| BDL-FOG | ۸۸ | ۸۷ | ۸۶ | ۸۸ |

با توجه به نتایج به دست آمده و مقایسه آنها در جدول ۵ از مدل BDL-FOG و نتایج مدل‌های CNN-FOG و FFL-FOG نتیجه گرفته می‌شود که BDL-FOG بهترین نتایج را نسبت به دو مدل قبلی در مدت زمان اجرای کمتر داشته است. همچنین به دلیل ماهیت داده‌ها که از نوع سیگنال و سری زمانی هستند و بین آنها وابستگی زمانی وجود دارد، معماری‌های شبکه عمیق مبتنی بر RNN برای مدل کردن آنها مناسب‌تر است. لذا روش پیشنهادی BDL-FOG به عنوان روش پیشنهادی برتر و مدل نهایی در این پژوهش معرفی می‌شود.

در جدول ۶ و شکل ۴ مقایسه نتایج روش پیشنهادی با بهترین روش‌های موجود نشان داده شده است. با توجه به جدول، همانطور که مشاهده می‌شود روش BL-FOG نسبت به روش‌های دیگر بهترین نتایج را دارد. مقدار GM در این پژوهش ۸۷٪ ولی در روش‌های دیگر حداکثر ۷۹ درصد است. همچنین مقدار دقت مدل نسبت به روش‌های دیگر بیشتر است. در شکل ۴ خط چین قرمز رنگ تفاوت مقدار GM در روش BL-FOG با بهترین روش‌های موجود را نشان می‌دهد.

جدول ۶: مقایسه روش BL-FOG با تعدادی از روش‌های اخیر در مسئله تشخیص FOG.

| مرجع | حساسیت | شناسا | GM |
|----------------|--------------|--------------|--------------|
| [۶] | ۷۳/۱ | ۸۱/۶ | ۷۷/۲۳ |
| [۵] | ۶۶/۲۵ | ۹۵/۳۸ | ۷۹/۴۹ |
| [۲۱] | - | - | ۷۵/۰۰ |
| [۲۰] | - | - | ۷۵/۰۰ |
| [۲] | ۶۹/۲۹ | ۹۰/۶۰ | ۷۹/۲۳ |
| BDL-FOG | ۸۸/۰۰ | ۸۶/۰۰ | ۸۷/۰۰ |



شکل ۴. مقایسه نتایج روش پیشنهادی با بهترین روش های موجود.

نتیجه گیری و بحث

در این مقاله، به منظور تشخیص اختلال حرکتی FOG در بیماران مبتلا به پارکینسون، به ارائه سه مدل CNN-FOG و FFL-FOG و BDL-FOG با استفاده از رویکرد یادگیری عمیق پرداخته شد. ضمن تحلیل مجموعه داده ها و بر مبنای مقایسه با بهترین روش های موجود، نشان داده شد که از بین سه مدل پیشنهادی، مدل BDL-FOG توانسته است به خوبی ویژگی های سری زمانی داده ها را مدل نماید به گونه ای که بیشترین دقت را در فرآیند تشخیص بر حسب پارامترهای ارزیابی مختلف به دست آورد. لذا به عنوان یک روش پیشنهادی مطمئن در تشخیص اختلال حرکتی FOG در بیماران مبتلا به پارکینسون پیشنهاد می شود. به عنوان کار آینده، پژوهشگران می توانند بر روی بهینه کردن مقادیر پارامترها در مدل پیشنهادی و یا ارائه روش های جدید مبتنی بر سایر معماری های عصبی عمیق به منظور افزایش دقت فرآیند تشخیص، تمرکز نمایند.

منابع

- [1] Aich, S., Pradhan, P. M., Park, J., Sethi, N., Vathsa, V. S. S., & Kim, H. C. (2018). A validation study of freezing of gait (FoG) detection and machine-learning-based FoG prediction using estimated gait characteristics with a wearable accelerometer. *Sensors*, 18(10), 3287.
- [2] M. J. Sannella, Constraint Satisfaction and Debugging for Camps, J., Sama, A., Martin, M., Rodriguez-Martin, D., Perez-Lopez, C., Arostegui, J. M. M., ... & Prats, A. (2018). Deep learning for freezing of gait detection in Parkinson's disease patients in their homes using a waist-worn inertial measurement unit. *Knowledge-Based Systems*, 139, 119-131.
- [3] Xia, Y., Zhang, J., Ye, Q., Cheng, N., Lu, Y., & Zhang, D. (2018). Evaluation of deep convolutional neural networks for detection of freezing of gait in Parkinson's disease patients. *Biomedical Signal Processing and Control*, 46, 221-230.
- [4] Post, B., Merkus, M. P., De Haan, R. J., Speelman, J. D., & CARPA Study Group. (2007). Prognostic factors for the progression of Parkinson's disease: a systematic review. *Movement disorders*, 22(13), 1839-1851.
- [5] Tanner, C. M., & Goldman, S. M. (1997). Epidemiology of Tourette syndrome. *Neurologic clinics*, 15(2), 395-402.
- [6] Bachlin, M., Plotnik, M., Roggen, D., Maidan, I., Hausdorff, J. M., Giladi, N., & Troster, G. (2009). Wearable assistant for Parkinson's disease patients with the freezing of gait symptom. *IEEE Transactions on Information Technology in Biomedicine*, 14(2), 436-446.
- [7] De Lau, L. M., & Breteler, M. M. (2006). Epidemiology of Parkinson's disease. *The Lancet Neurology*, 5(6), 525-535.
- [8] Gandhi, S., & Plun-Favreau, H. (2017). Mutations and mechanism: how PINK1 may contribute to risk of sporadic Parkinson's disease. *Brain*, 140(1), 2-5.
- [9] Giri, A., Mok, K. Y., Jansen, I., Sharma, M., Tesson, C., Mangone, G., ... & Díez-Fairen, M. (2017). Lack of evidence for a role of genetic variation in TMEM230 in the risk for Parkinson's disease in the Caucasian population. *Neurobiology of aging*, 50, 167-e11.
- [10] Jankovic, J. (2008). Parkinson's disease: clinical features and diagnosis. *Journal of neurology, neurosurgery & psychiatry*, 79(4), 368-376.
- [11] Moore, O., Peretz, C., & Giladi, N. (2007). Freezing of gait affects quality of life of peoples with Parkinson's disease beyond its relationships with mobility and gait. *Movement disorders: official journal of the Movement Disorder Society*, 22(15), 2192-2195.
- [12] Moore, S. T., MacDougall, H. G., & Ondo, W. G. (2008). Ambulatory monitoring of freezing of gait in Parkinson's disease. *Journal of neuroscience methods*, 167(2), 340-348.
- [13] Polymeropoulos, M. H., Lavedan, C., Leroy, E., Ide, S. E., Dehejia, A., Dutra, A., ... & Stenroos, E. S. (1997). Mutation in the α -synuclein gene identified in families with Parkinson's disease. *science*, 276(5321), 2035-2047.
- [14] Han, J. H., Lee, W. J., Ahn, T. B., Jeon, B. S., & Park, K. S. (2003, September). Gait analysis for freezing detection in patients with movement disorder using three dimensional acceleration system. In *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439) (Vol. 2, pp. 1863-1865)*. IEEE.
- [15] Schaafsma, J. D., Balash, Y., Gurevich, T., Bartels, A. L., Hausdorff, J. M., & Giladi, N. (2003). Characterization of freezing of gait subtypes and the response of each to levodopa in Parkinson's disease. *European journal of neurology*, 10(4), 391-398.

- [16] Tripoliti, E. E., Tzallas, A. T., Tsiouras, M. G., Rigas, G., Bougia, P., Leontiou, M., ... & Fotiadis, D. I. (2013). Automatic detection of freezing of gait events in patients with Parkinson's disease. *Computer methods and programs in biomedicine*, 110(1), 12-26.
- [17] Bächlin, M., Hausdorff, J. M., Roggen, D., Giladi, N., Plotnik, M., & Tröster, G. (2009, April). Online detection of freezing of gait in Parkinson's disease patients: a performance characterization. In *Proceedings of the Fourth International Conference on Body Area Networks* (pp. 1-8).
- [18] Niazmand, K., Tonn, K., Zhao, Y., Fietzek, U. M., Schroeteler, F., Ziegler, K., ... & Lueth, T. C. (2011, November). Freezing of Gait detection in Parkinson's disease using accelerometer based smart clothes. In *2011 IEEE Biomedical Circuits and Systems Conference (BioCAS)* (pp. 201-204). IEEE.
- [19] Polat, K. (2019, April). Freezing of Gait (FoG) Detection Using Logistic Regression in Parkinson's Disease from Acceleration Signals. In *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)* (pp. 1-4). IEEE.
- [20] Handojoseno, A. A., Shine, J. M., Nguyen, T. N., Tran, Y., Lewis, S. J., & Nguyen, H. T. (2012, August). The detection of Freezing of Gait in Parkinson's disease patients using EEG signals based on Wavelet decomposition. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 69-72). IEEE.
- [21] Handojoseno, A. A., Shine, J. M., Nguyen, T. N., Tran, Y., Lewis, S. J., & Nguyen, H. T. (2012, August). The detection of Freezing of Gait in Parkinson's disease patients using EEG signals based on Wavelet decomposition. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 69-72). IEEE.
- [22] Carlos P'erez-Lo'pez Andreu Catal`a Berta Mestre Sheila Alcaine `Angels Bay`es Daniel Rodr'iguez-Mart'in, Albert Sam`a. Comparison of Features, Window Sizes and Classifiers in Detecting Freezing of Gait in Patients with Parkinson's Disease Through a Waist-Worn Accelerometer, volume 288 of *Frontiers in Artificial Intelligence and Applications*. 2016.
- [23] Chollet, F. (2018). *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. MITP-Verlags GmbH & Co. KG.

شناسه دیجیتال (DOI): 10.22091/JEMSC.2022.6990.1151

استناد به این مقاله:

طالب‌وند، مریم؛ لکی‌زاده، امیر؛ فتوحی، فرانک. (۱۴۰۰). «تشخیص انجماد راهرفتن در بیماران مبتلا به پارکینسون با استفاده از حسگرهای پوشیدنی و یادگیری عمیق». *مدیریت مهندسی و رایانش نرم*، ۱۴ (۸)، ۸۳-۱۰۴.