

Parkinson's Diagnosis Based on Gait Patterns Using Artificial Intelligence

Farzin Zeinaddini Meymand, Mahkame Sharbatdar*^{ID}

Mechanical Engineering Department, K. N. Toosi University of Technology, Tehran, Iran

ARTICLE INFO

Article Type

Original Research

Article History

Received: May 28, 2025

Revised: July 19, 2025

Accepted: July 25, 2025

ePublished: August 23, 2025

ABSTRACT

Parkinson's disease is recognized as a progressive neurological disorder that leads to motor impairments. Due to the necessity of early and accurate diagnosis for effective disease management, a novel approach has been proposed for detecting and predicting the progression stages of Parkinson's disease. In this study, gait signals were processed using Empirical Mode Decomposition (EMD), and temporal features were extracted by employing a hybrid CNN-LSTM deep neural network architecture. The gait data were collected using sixteen force sensors placed beneath the left and right feet of 93 individuals with Parkinson's disease and 73 healthy controls. The signals were then preprocessed, and their intrinsic frequency components were extracted.

To evaluate model performance, two training strategies were applied: a conventional train-test split, and K-Fold cross-validation. Temporal dynamics associated with disease progression were effectively extracted through the CNN-LSTM model. According to the results, the cross-validation-based model demonstrated superior accuracy of 96.44%, compared to 84.27% achieved by the simple split approach. These findings indicate that the proposed method can be reliably utilized as an intelligent, non-invasive clinical decision-support tool for the diagnosis and staging of Parkinson's disease.

Keywords: Parkinson, Gait Signal, Neural Network, Disease diagnosis

How to cite this article

Zeinaddini Meymand F, Sharbatdar M, Parkinson's Diagnosis Based on Gait Patterns Using Artificial Intelligence. Modares Mechanical Engineering; 2025;25(06):359-371.

*Corresponding author's email: farzinzeinaddini@gmail.com

*Corresponding ORCID ID: 0000-0002-0881-6122



Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.



تشخیص پارکینسون براساس الگوی حرکتی با استفاده از هوش مصنوعی

فرزین زین الدینی میمند، مهکامه شربتدار*

دانشکده مهندسی مکانیک، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران

چکیده

بیماری پارکینسون به عنوان یک اختلال عصبی پیش رونده شناخته می شود که منجر به اختلالات حرکتی می گردد. با توجه به اهمیت تشخیص زودهنگام و دقیق برای مدیریت مؤثر این بیماری، رویکردی نوین برای شناسایی و پیش بینی مرحله پیشرفت پارکینسون پیشنهاد شده است. در این مطالعه، سیگنال های راه رفتن با استفاده از الگوریتم تجزیه حالت ذاتی (EMD) پردازش گردیده و از شبکه عصبی عمیق ترکیبی CNN-LSTM به منظور استخراج ویژگی های زمانی بهره گرفته شده است. داده های حرکتی از طریق شازنده حسگر نیرو که در زیر پای چپ و راست ۹۳ فرد مبتلا به پارکینسون و ۷۳ فرد سالم نصب شده بود، گردآوری و پیش پردازش شده اند. سپس مؤلفه های فرکانسی ذاتی استخراج گردیده اند. برای ارزیابی عملکرد مدل، از دو رویکرد آموزشی استفاده شده است: نخست، تقسیم ساده داده ها به مجموعه های آموزش و آزمون؛ و دوم، روش اعتبارسنجی متقابل K-Fold. ویژگی های زمانی مرتبط با پیشرفت بیماری توسط ساختار CNN-LSTM استخراج گردیده اند. بر اساس نتایج به دست آمده، مدل مبتنی بر اعتبارسنجی متقابل با دقت ۹۶/۴۴٪ عملکرد بهتری نسبت به مدل ساده با دقت ۸۴/۲۷٪ ارائه داده است. این نتایج بر قابلیت بالای مدل پیشنهادی به عنوان ابزاری هوشمند، غیرتهاجمی و پشتیبان تصمیم گیری بالینی برای تشخیص و مرحله بندی بیماری پارکینسون دلالت دارند.

اطلاعات مقاله

نوع مقاله

مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۴/۰۳/۰۷

بازنگری: ۱۴۰۴/۰۴/۲۸

پذیرش: ۱۴۰۴/۰۵/۰۳

ارائه آنلاین: ۱۴۰۴/۰۶/۰۱

کلیدواژه ها: پارکینسون، سیگنال راه رفتن، شبکه عصبی، تشخیص بیماری

نحوه ارجاع به این مقاله

فرزین زین الدینی میمند، مهکامه شربتدار، تشخیص پارکینسون براساس الگوی حرکتی با استفاده از هوش مصنوعی، مهندسی مکانیک مدرس.

۳۷۱-۳۵۹-۲۵(۰۷):۱۴۰۴

*پست الکترونیکی نویسنده عهده دار مکاتبات: farzinzeinadini@gmail.com

*شناسه ارجید نویسنده عهده دار مکاتبات: ۶۱۲۲-۰۸۸۱-۰۰۰۲-۰۰۰۰-۰۰۰۰



۱- مقدمه

بیماری پارکینسون (Parkinson's Disease - PD) پس از آلزایمر، به عنوان دومین اختلال شایع عصبی-تحلیل‌برنده (Neurodegenerative) شناخته می‌شود که با تخریب تدریجی نورون‌های دوپامین‌ساز در مسیرهای حرکتی مغز، منجر به بروز اختلالات حرکتی و افت کیفیت زندگی در بیماران می‌گردد [۱]. تشخیص زودهنگام و دقیق این بیماری نقش حیاتی در مدیریت اثربخش، بهینه‌سازی درمان‌های فردمحور، و کاهش هزینه‌های مراقبتی دارد. با این حال، تمایز دقیق PD از سایر اختلالات حرکتی به دلیل شباهت علائم و پیچیدگی سیر پیشرفت بیماری، همواره چالش برانگیز بوده است. علاوه بر این، تعیین دقیق مراحل بیماری برای انتخاب راهکارهای درمانی مناسب و پایش روند پیشرفت بیماری ضروری است.

از میان علائم حرکتی بیماری، الگوهای راه رفتن بیماران از اهمیت بالایی برخوردارند و می‌توانند اطلاعات ارزشمندی درباره وضعیت نورولوژیکی آن‌ها فراهم کنند. تجزیه و تحلیل دقیق سیگنال‌های راه رفتن می‌تواند به عنوان یک ابزار تشخیصی و مرحله‌بندی غیرتهاجمی مورد استفاده قرار گیرد. با این حال، ماهیت پیچیده و غیرخطی این سیگنال‌ها، نیازمند بهره‌گیری از تکنیک‌های پیشرفته پردازش سیگنال و مدل‌های یادگیری ماشین است که توانایی درک هم‌زمان ویژگی‌های زمانی و فرکانسی داده را داشته باشند. در این راستا، مطالعه حاضر با هدف ارتقای دقت تشخیص و پیش‌بینی مراحل بیماری پارکینسون، رویکردی ترکیبی بر پایه‌ی تجزیه حالت ذاتی (Empirical Mode Decomposition - EMD) و شبکه‌های عصبی عمیق CNN-LSTM ارائه می‌دهد. استفاده از الگوریتم EMD برای استخراج مؤلفه‌های فرکانسی ذاتی از سیگنال‌های راه رفتن، در کنار بهره‌گیری از شبکه‌های عصبی هیبریدی، این امکان را فراهم می‌سازد تا ویژگی‌های پیچیده سیگنال با دقت بالاتری تحلیل شوند. انتظار می‌رود این رویکرد نه تنها باعث بهبود عملکرد تشخیص و مرحله‌بندی PD شود، بلکه زمینه را برای توسعه روش‌های درمانی هوشمند و هدفمند نیز فراهم کند.

در مطالعات مربوط به تشخیص و رتبه‌بندی شدت بیماری پارکینسون بر اساس تحلیل الگوهای راه رفتن، تاکنون از رویکردهای متنوعی شامل روش‌های آماری، یادگیری ماشین و یادگیری عمیق بهره گرفته شده است. این روش‌ها با هدف شناسایی ویژگی‌های حرکتی متمایز در بیماران و ارتقای دقت تشخیص مورد استفاده قرار گرفته‌اند.

در حوزه روش‌های آماری، یکی از مطالعات شاخص در سال ۲۰۱۰ [۲] با استفاده از روش‌های ناپارامتری مانند پنجره پازرن، به تخمین توابع چگالی احتمال (PDF) فواصل قدم و زیرفازهای آن پرداخته است. با بهره‌گیری از پارامترهایی مانند میانگین و انحراف معیار استخراج شده از این PDFها، تغییرپذیری ریتم راه رفتن

بیماران بررسی شده است. همچنین، شمارش دورهای سیگنال (STC) برای ارزیابی تغییرات زمانی راه رفتن به کار گرفته شده‌اند. این ویژگی‌ها نهایتاً با استفاده از تحلیل تمایز خطی (LDA) و ماشین بردار پشتیبان با هسته غیرخطی (LS-SVM) طبقه‌بندی شدند و دقت تشخیصی قابل توجهی به دست آمده است.

در دسته روش‌های یادگیری ماشین، مطالعه‌ای در سال ۲۰۱۵ [۳] با استفاده از رویکرد نرمال‌سازی رگرسیونی چندگانه و الگوریتم‌هایی نظیر جنگل‌های تصادفی (Random Forest) و SVM، ویژگی‌های راه رفتن بیماران را تجزیه و تحلیل کرده است. نتایج نشان داده‌اند که روش نرمال‌سازی مذکور منجر به بهبود دقت طبقه‌بندی شده است و دقت مدل RF را به ۹۲.۶٪ رسانده است. این یافته‌ها حاکی از پتانسیل بالای الگوریتم‌های یادگیری ماشین در شناسایی الگوهای حرکتی مرتبط با بیماری پارکینسون هستند.

در حوزه یادگیری عمیق، مطالعه‌ای در سال ۲۰۱۹ [۴] معماری شبکه عصبی پیچشی یک‌بعدی (1D-CNN) را برای تشخیص و پیش‌بینی شدت بیماری به کار برده است. برخلاف روش‌های سنتی که نیاز به استخراج دستی ویژگی‌ها دارند، این مدل داده‌های خام ثبت شده از سنسورهای کف پا را مستقیماً پردازش کرده و موفق به دستیابی به دقت تشخیصی ۹۸.۷٪ و پیش‌بینی شدت بیماری با دقت ۸۵.۳٪ بر اساس مقیاس UPDRS شده است. این نتایج نشان‌دهنده ظرفیت بالای مدل‌های عمیق در تحلیل داده‌های خام و تصمیم‌گیری دقیق می‌باشند.

همانطور که گفته شد بسیاری از مطالعات پیشین یا به کارگیری روش‌های سنتی مانند ماشین بردار پشتیبان (SVM) و جنگل‌های تصادفی (RF) بسنده کرده‌اند، یا از ساختارهای یادگیری عمیق بدون تحلیل مؤلفه‌های فرکانسی سیگنال‌های راه رفتن استفاده نموده‌اند. نوآوری اصلی این پژوهش در به کارگیری هم‌زمان تجزیه حالت ذاتی (EMD) و معماری ترکیبی CNN-LSTM به منظور استخراج و تحلیل جامع ویژگی‌های زمانی و فرکانسی سیگنال راه رفتن نهفته است. علاوه بر این، به جای تقسیم‌بندی ساده داده‌ها، از اعتبارسنجی متقابل K-Fold برای افزایش قابلیت تعمیم‌پذیری مدل بهره گرفته شده است. این تلفیق از پیش‌پردازش مؤثر، ساختار یادگیری عمیق پیشرفته و اعتبارسنجی منظم، چارچوبی نوین و دقیق برای تشخیص مراحل بیماری پارکینسون ارائه می‌دهد.

جدول ۱ خلاصه از تحقیقات انجام شده را ارائه می‌دهد. همچنین در پژوهشی که در سال ۲۰۲۲ صورت گرفته است با استفاده از داده‌های VGRF و شبکه عصبی مصنوعی، مدلی برای تشخیص پارکینسون با دقت بالایی توسعه دادند که یافته‌های آن هم‌راستا با رویکرد حاضر است.

جدول ۱ تحقیقات انجام شده در زمینه پارکینسون

Table 1 Studies Conducted in the Field of Parkinson's Disease

Category	Author	Method	Discription	Data Statistics
Statistical	Krishnan and Wu, (2010)	SVM	Use of the Parzen window technique to estimate the variability of gait in Parkinson's patients and achieving 90.32% diagnostic accuracy.	Healthy group includes 16 individuals, and Parkinson's group includes 15 individuals.
Statistical	Prabhu et al. [5] (2018)	PNN	Use of gait signals to diagnose neurodegenerative diseases. patients and achieving 96% diagnostic accuracy	A total of 26 individuals, including 13 patients and 13 healthy subjects.
Machin Learning	Khoury et al. [6] (2019)	KNN, DT, BC, SVM	Use of machine learning algorithms for classifying gait disorders, and using the Wrapper method for feature selection with accuracy between 86% and 90%.	A total of 166 individuals, including 93 patients and 73 healthy subjects.
Machin Learning	Balaji et al. [7] (2020)	SVM, DT, BC	Time-series analysis of VGRF to identify key features and compare the performance of machine learning algorithms with accuracy of 98.4% .	A total of 166 individuals, including 93 patients and 73 healthy subjects.
Deep Learning	El Maachi et al. (2020)	CNN	Use of 1D CNN for multi-class classification and tenfold cross-validation technique for model validation with accuracy of 85.3% .	A total of 166 individuals, including 93 patients and 73 healthy subjects.
Deep Learning	Kocer and Oktay [8] (2020)	LSTM	Use of LSTM for diagnosing Parkinson's disease and evaluating its severity with 90% accuracy.	A total of 40 individuals, including 23 Parkinson's patients and 17 individuals with essential tremor.

۲- روش انجام مطالعه


۲-۱- دیتاست

ابتدا به معرفی داده VGRF پرداخته شده است: داده‌های VGRF به نیروی عمودی واکنش زمین اشاره دارد که در هنگام راه رفتن یا دویدن توسط بدن به سطح وارد می‌شود و از طریق حسگرهای نیرو یا فشار اندازه‌گیری می‌شود. در مطالعات حرکتی و بیومکانیکی، VGRF یک پارامتر مهم برای ارزیابی پویایی‌های راه رفتن است، زیرا این نیرو اطلاعات مهمی در مورد توزیع وزن، تعادل و تغییرات در فشار وارد بر سطح زمین ارائه می‌دهد. این داده‌ها می‌توانند به شناسایی اختلالات راه رفتن و مقایسه بین افراد سالم و بیماران مبتلا به بیماری‌هایی مثل پارکینسون کمک کنند. در ادامه به بررسی حالت‌های راه رفتن اشاره شده است.

شکل ۱- الف، مراحل مختلف چرخه راه رفتن را نشان می‌دهد. چرخه راه رفتن معمولاً به دو فاز عمده swing (آویزان) و stance (ایستاده) تقسیم می‌شود. فاز stance که حدود ۶۰٪ از چرخه راه رفتن را تشکیل می‌دهد، به دوره‌ای اشاره دارد که پا در تماس ثابت با زمین است. به طور مشابه، فاز swing که ۴۰٪ باقی‌مانده از چرخه راه رفتن را به خود اختصاص می‌دهد، دوره‌ای است که پا از زمین جدا است. علاوه بر این، فاز راه رفتن می‌تواند به شش رویداد تقسیم شود: ضربه پاشنه (heel strike)، میانه فاز ایستاده (mid-stance)، سطح پا (foot flat)، جدا شدن پاشنه (heel-off)، میانه فاز آویزان (mid-swing) و جدا شدن انگشتان پا (toe-off). برخی از ویژگی‌های فضایی برجسته شامل طول گام (stride length)، طول قدم (step length)، سرعت راه رفتن (gait speed) و آهنگ راه رفتن (cadence) است. به طور مشابه، ویژگی‌های زمانی اصلی شامل زمان گام (stride time)،

زمان قدم (step time)، زمان فاز ایستاده (stance time) و زمان فاز آویزان (swing time) است [۶ و ۸].

دیتاستی که برای مدل سازی استفاده شده است، دیتاست موجود در بانک اطلاعاتی فیزیوت (Gait in Parkinson's Disease, 2021) است. این مجموعه داده توسط سه گروه مستقل به نام های Yoge et al [۱۰]، Hausdorff et al [۱۱] و Frenkel- Toledo et al [۱۲] برای آزمون های مختلف راه رفتن جمع آوری شده است. این مجموعه داده شامل الگوی راه رفتن از ۹۳ بیمار مبتلا به بیماری پارکینسون و ۷۳ فرد سالم است. برای مطالعه دینامیک قدم به قدم بیماران پارکینسون، الگوی راه رفتن در سه شرایط مختلف جمع‌آوری شده است. مجموعه داده‌ای که توسط Yoge et al جمع‌آوری شده است، شامل الگوی راه رفتن در هنگام راه رفتن عادی بر روی سطح صاف است، و مجموعه داده‌ای که توسط Hausdorff ارائه شده، شامل چرخه راه رفتن در هنگام راه رفتن با سرعت نرمال و استفاده از تحریکات صوتی ریتمیک (RAS) است. همچنین، داده‌های ارائه‌شده توسط Frenkel- Toledo شامل سری زمانی راه رفتن بر روی تردمیل است. از آنجا که پایداری راه رفتن در بیماران مبتلا به پارکینسون مختل می‌شود، بررسی دینامیک راه رفتن از طریق داده‌های حسگر نیرو می‌تواند جنبه‌های اختلال در کنترل حرکت را آشکار سازد و به کمی‌سازی تغییرپذیری قدم به قدم کمک کند [۱۳]. بنابراین برای کمی‌سازی اختلال راه رفتن در افراد دارای ریتم های خارجی و بدون ریتم های خارجی از این مجموعه دیتاست استفاده شده است تا شدت بیماری پارکینسون شناسایی شود. برای سهولت در نمایش، سه مجموعه دیتاست به صورت Ga [۱۰]، Ju [۱۱] و Si [۱۲] نمایش



شکل ۱ الف) چرخه راه رفتن، ب) موقعیت سنسورها

Fig. 1 a) Gait cycle, b) Sensor Positions

جدول ۲ اطلاعات مربوط به افراد سالم و بیمار برای سه مجموعه دیتاست
Table 2 Information related to healthy and diseased individuals for three datasets.

Dataset	Group	Subjects	Male	Female	Age Mean $\pm$ SD	Age Range	Height (metre)	Weight (Kg)
Ga	Healthy	18	10	8	57.9 $\pm$ 6.7	37-70	1.68 $\pm$ 0.08	74.2 $\pm$ 12.7
Ga	PD	29	20	9	61.6 $\pm$ 8.8	36-77	1.67 $\pm$ 0.07	73.1 $\pm$ 11.2
Ju	Healthy	26	12	14	39.31 $\pm$ 18.51	20-74	1.83 $\pm$ 0.08	66.8 $\pm$ 11.07
Ju	PD	29	16	13	66.80 $\pm$ 10.85	44-80	1.87 $\pm$ 0.15	75.1 $\pm$ 16.89
Si	Healthy	29	18	11	64.5 $\pm$ 6.8	53-77	1.69 $\pm$ 0.08	71.5 $\pm$ 11.0
Si	PD	35	22	13	67.2 $\pm$ 9.1	61-84	1.66 $\pm$ 0.07	70.3 $\pm$ 8.4

جدول ۳ رتبه‌بندی شدت بیماری پارکینسون براساس معیار H&Y

Table 3 Ranking of Parkinson's disease severity based on the H&Y (Hoehn and Yahr) scale.


Scale	Functionality	Stage
1	Unilateral involvement only	No functional disability (NFD)
1.5	Unilateral and axial involvement	NFD but initial phase
2	Bilateral	Without impairment of balance
2.5	Mild bilateral disease with recovery on pull test	With impairment of balance
3	Mild to moderate bilateral disease	With impaired postural reflexes
4	Severe disability	Still able to walk or stand unassisted
5	Confined to bed or wheelchair bound	Completely Disabled

داده می‌شوند. در جدول ۲ اطلاعات مربوط به افراد سالم و بیمار برای سه مجموعه دیتاست آورده شده است [۷]. دو مقیاس ارزیابی بالینی که به طور گسترده برای پیشرفت بیماری پارکینسون استفاده می‌شوند، مقیاس UPDRS و مقیاس H&Y هستند [۱۴ و ۱۵]. مقیاس UPDRS ابزاری جامع برای ارزیابی علائم حرکتی و غیرحرکتی، از جمله رفتارهای ذهنی، خلق و خو و تعاملات اجتماعی است. مقیاس H&Y وضعیت بدن، تحرک و لرزش را با در نظر گرفتن علائم حرکتی اندازه‌گیری می‌کند [۱۶]. مقیاس H&Y شامل پنج مرحله است و همچنان به دلیل کارایی آن در ارائه تأیید کلی شدت بیماری بر اساس ناتوانی عملکردی، به عنوان یک مقیاس ارزیابی جهانی پذیرفته شده است. در جدول ۳ معرفی هریک از پنج مرحله آورده شده است [۷].

۲-۲- جمع‌آوری دیتاست

برای اندازه‌گیری نیروهای زیر پا به عنوان تابعی از زمان، سیستم ثبت الگوی راه رفتن شامل یک جفت کفش همراه با سنسور و یک واحد ثبت اطلاعات است که به کمر افراد متصل می‌شود و به مدت دو دقیقه با نرخ نمونه برداری ۱۰۰ هرتز، نمونه برداری انجام می‌شود. همان‌طور که در شکل ۱-ب، نشان داده شده است، هر کفش دارای هشت حسگر نیروی واکنش عمودی زمین (VGRF) است [۹]. نمونه‌ای از سیگنال‌های فرد سالم و بیمار از سه مجموعه دیتاست در شکل ۲ نشان داده شده است. این داده‌ها که الگوی راه رفتن نمونه‌ای از یک فرد سالم و فرد مبتلا به بیماری پارکینسون را از سه مجموعه داده نشان می‌دهند، تأکید می‌کنند که نیروی وارده به کف پا توسط بیمار مبتلا به پارکینسون در هنگام راه رفتن تقریباً نصف نیروی وارده توسط افراد سالم است. علاوه بر این، شکل چپ نشان می‌دهد که در مجموعه داده ارائه شده، هنگامی که فرد مبتلا به پارکینسون با استفاده از نشانه‌های خارجی از طریق تحریک شنیداری ریتمیک راه می‌رفت، تحرک به طور قابل توجهی افزایش یافته است و سرعت راه رفتن افراد به‌طور چشمگیری افزایش یافته است [۷].


همان‌طور که گفته شد سیگنال‌های VGRF به مدت دو دقیقه با نرخ نمونه‌برداری ۱۰۰ هرتز جمع‌آوری شده است [۹]. دیتاست خام این مجموعه شامل ۲۸۲ فایل اکسل است که بعد از فرآیند پیش‌پردازش دیتاست و به دست آوردن سائز غالب، تعداد این فایل‌ها به ۱۶۰ عدد می‌رسد که شامل ۶۴ فرد سالم و ۹۶ فرد دارای پارکینسون است. برای به‌دقت رساندن تأثیرات شروع و پایان در سیگنال‌های (VGRF)، نمونه‌های ۱۰ ثانیه‌ای از ابتدا و نمونه‌های ۲۰ ثانیه‌ای از انتها حذف می‌شوند. سپس، برای هموار کردن سیگنال و حذف داده‌های پرت، داده‌های VGRF با استفاده از فیلتر میانه، فیلتر می‌شوند. فیلتر میانه با استفاده از یک پنجره متحرک با اندازه فرد (در این مطالعه ۵) بر روی سیگنال یا تصویر



شکل ۲ سیگنال‌های راه‌رفتن برای فرد بیمار و سالم در هر سه مجموعه دیتاست
Fig. 2 Gait signals for both healthy and patient individuals across all three datasets.

۲-۴- تخمین PSD

در ادامه با استفاده از روش Welch بیشترین PSD برای هر IMF بدست آمده است و سیگنالی که بیشترین چگالی طیفی توان را داشته باشد (متناسب با دامنه فرکانس) به عنوان سیگنال منتخب هر ستون در یک فایل اکسل دیگر ذخیره شده است. Error! Reference source not found. این روند برای تمام فایل‌ها تکرار می‌شود. در مرحله آخر فایل‌هایی که سایز یکسان دارند، به عنوان فایل نهایی انتخاب شده‌اند. سایز هر فایل انتخاب شده (9117*16) است. قابل ذکر است به دلیل کمبود تعداد فایل‌های مربوط به شدت S3 و ایجاد خطا در مدل، از مجموعه دیتاست نهایی کنار گذاشته شد. جدول ۴ اطلاعات دیتاست بعد از پردازش تعداد افراد سالم و بیمار پس از پردازش را گزارش می‌دهد.



شکل ۴ مشخص کردن IMF دارای بیشترین چگالی طیفی توان
Fig. 4 Identification of the IMF with the highest spectral power density

جدول ۴ اطلاعات دیتاست بعد از پردازش

Table 4 Processed Dataset Information


Class name	labels	Normal model		Model with K-Fold method	
		Train data	Test data	Train data	Test data
Healthy	2	48	17	58	6
S2	0	52	18	62	7
S2.5	1	21	5	24	3
Sum		121	39	144	16
Sum of all data		160		160	

اعمال می‌شود. در هر موقعیت، مقادیر درون پنجره مرتب شده و مقدار میانه به عنوان جایگزین مقدار مرکزی انتخاب می‌شود. این فرآیند با حرکت تدریجی پنجره روی کل داده تکرار شده و نویزهای ناگهانی را حذف کرده و سیگنال را هموار می‌کند.

۲-۳- الگوریتم EMD

بعد از اعمال فیلتر، الگوریتم EMD بر روی ستون‌های منتخب همه فایل‌های اکسل پیاده‌سازی شده است. الگوریتم EMD با شناسایی اکسترمم‌های محلی و ساخت پوسته‌های بالا و پایین از طریق درونیابی اسپلاین مکعبی آغاز می‌شود. سپس، میانگین این دو پوسته محاسبه شده و از سیگنال اصلی کسر می‌شود تا یک مؤلفه جدید (IMF) استخراج شود. این مؤلفه به عنوان اولین IMF در نظر گرفته می‌شود، این مراحل تا زمانی ادامه دارد که باقی‌مانده سیگنال به یک تابع یکنواخت تبدیل شود. در نهایت، سیگنال اصلی به مجموع تمام IMFها و باقیمانده تجزیه می‌شود. شکل ۳ نحوه تجزیه سیگنال اصلی به IMFها را نشان می‌دهد.

$$\begin{aligned}
 h(t) &= x(t) - m(t) \\
 r(t) &= x(t) - IMF_i(t) \\
 x(t) &= \sum_i IMF_i(t) + r(t)
 \end{aligned} \quad (1)$$



شکل ۳ استخراج توابع حالت ذاتی
Fig. 3 IMF extraction





Fig. 5 K-Fold cross validation

جدول ۵ تقسیم‌بندی دیتاست برای دو مدل

Table 5 Split dataset for two models

Type	Dataset	
	Ga [8]	Si [9]
Healthy	35	29
Serverity 2	41	28
Serverity 2.5	20	7
Sum	160	



شکل ۶ نمای کلی از ساختار شبکه

Fig. 6 Overview of the Network Architecture

۷-۲- استخراج ویژگی از شبکه CNN

به‌طور معمول، یک شبکه عصبی پیچشی (CNN) شامل سه لایه اصلی است: ورودی (Input)، پنهان (Hidden) و خروجی (Output) [۱۶].

لایه پنهان معمولاً از لایه کانولوشن (Convolutional layer)، لایه نمونه‌برداری یا کاهش ابعاد (Pooling layer) و یک لایه ReLU که نقش تابع فعال‌ساز را ایفا می‌کند، تشکیل شده است. در لایه کانولوشن، مجموعه‌ای از فیلترهای قابل آموزش (Learnable Filters) بر روی داده‌های ورودی (VGRF (نیروی عکس‌العمل عمودی زمین)) با توجه به یک تابع کرنل (Kernel Function) حرکت می‌کنند تا ویژگی‌های برجسته و مهم استخراج شوند. عملیات کانولوشن ضمن حفظ ساختار محلی داده، موجب کاهش تعداد پارامترها در مدل می‌شود که این امر باعث می‌گردد شبکه ترکیبی (مانند CNN-LSTM) عمق بیشتری پیدا کند بدون آنکه دچار بیش‌برازش یا بار محاسباتی شدید شود.

اگر $x_i^0 = [x_1, x_2, x_3, \dots, x_n]$ بردار ورودی باشد فرآیند نگاشت ویژگی‌ها را می‌توان به صورت زیر نمایش داد:

$$y_{ij} = f \left(\sum_{m=1}^M w_{m,j} x_{i+m-1,j}^0 + b_j \right) \quad (2)$$

۵-۲- تقسیم‌بندی دیتاست

ابتدا روش اعتبارسنجی متقابل (K-Fold Cross Validation) شرح داده شده است.

روشی برای ارزیابی عملکرد یک مدل یادگیری ماشین روی داده‌هایی که دیده نشده‌اند. در این روش، مجموعه داده به K بخش تقسیم می‌شود، مدل روی K-1 بخش آموزش داده می‌شود و روی بخش باقی‌مانده تست می‌شود. این فرایند K بار تکرار می‌شود و هر بار از یک بخش متفاوت برای تست استفاده می‌شود. میانگین نتایج از همه K تکرار، برآورد جامعی از عملکرد مدل ارائه می‌دهد.

فرایند را نشان می‌دهد.

همان‌طور که اشاره شده است، تعداد کل فایل‌ها ۱۶۰ عدد است. در مدل اول تعداد داده‌ها به دو قسمت آموزش و تست تقسیم بندی شده اند به گونه ای که ۲۵ درصد آنها به داده های تست و ۷۵ درصد از آنها به داده های آموزش اختصاص داده شده اند. در مدل دوم با توجه به اینکه Num fold برابر ۱۰ است، در هر fold تعداد ۱۰ درصد از داده ها به داده های تست و ۹۰ درصد از داده ها به داده های آموزش تقسیم بندی می‌شوند

جدول ۵.

۶-۲- شبکه‌های CNN و LSTM


شبکه CNN-LSTM ترکیبی از شبکه کانولوشنی (CNN) برای استخراج ویژگی‌های محلی و شبکه حافظه بلندمدت (LSTM) برای یادگیری وابستگی‌های زمانی در داده‌ها است. این ترکیب برای داده‌های سری زمانی بسیار کارآمد است، زیرا CNN روابط زمانی را حفظ می‌کند. بخش CNN قادر است ویژگی‌های عمیق را از ماتریس مؤلفه‌های تابع ذاتی (IMFs) استخراج کند، در حالی که LSTM این ویژگی‌های استخراج شده را برای طبقه‌بندی الگوی راهرفتن مورد استفاده قرار می‌دهد. مزیت اصلی این ساختار، بهبود دقت مدل در تشخیص الگوهای زمانی پیچیده و افزایش مقاومت در برابر نویز است. Error! Reference source not found. نمای کلی از ساختار شبکه را نشان می‌دهد.

۹-۲- تابع سافت مکس (Softmax)

این تابع در شبکه‌های عصبی برای طبقه‌بندی استفاده می‌شود و مقادیر خروجی خام (Logist) را به توزیع احتمالی تبدیل می‌کند. هر مقدار خروجی در محدوده (۰،۱) قرار دارد و مجموع همه مقادیر برابر ۱ است.

$$\sigma(x)_i = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}}$$

این تابع به‌ویژه در لایه نهایی یک شبکه عصبی برای طبقه‌بندی چند کلاسه مفید است، زیرا به انتخاب محتمل‌ترین کلاس کمک می‌کند. این تابع قابل‌تفکیک است و بنابراین برای بهینه‌سازی مبتنی بر گرادیان مناسب است. Error! Reference source not found.



شکل ۸ الف) تابع ReLU، ب) تابع Softmax

Fig. 8 a) ReLU Function, b) Softmax Function

۱۰-۲- کاهش بیش‌برازش (Minimizing Overfitting)

۱۰-۲-۱- حذف تصادفی (Dropout)

حذف تصادفی یک تکنیک تنظیم‌گر (Regularization) است که به‌صورت تصادفی بخشی از خروجی یک لایه را هنگام آموزش حذف می‌کند. برخلاف روش‌های تنظیم‌گر که با تغییر تابع هزینه عمل می‌کنند، Dropout ساختار شبکه را با حذف تصادفی نورون‌ها در حین آموزش تغییر می‌دهد.

انگیزه اصلی از به‌کارگیری لایه Dropout این است که در یک لایه کاملاً متصل (Fully Connected)، ممکن است نورون‌ها به دلیل

که در آن b, w, M به ترتیب اندازه کرنل (Kernel size)، وزن نگاشت و ویژگی و مقدار بایاس را نشان می‌دهد. تابع f یک تابع فعال ساز است که تابع ReLU را برای رفتار غیرخطی در نظر می‌گیریم. که به صورت زیر تعریف می‌شود. Error! Reference source not found.

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0 & \text{if } x < 0 \end{cases} \quad (۳)$$


لایه Pooling که به آن لایه زیرنمونه‌گیری (Subsampling) نیز گفته می‌شود، یک عملیات کاهش ابعاد (Downsampling) را اجرا می‌کند تا اندازه نگاشت و ویژگی کاهش یابد و پایداری نسبت به انتقال (Translation Invariance) تضمین شود. این لایه با تقسیم نگاشت ویژگی به بلوک‌های مستطیلی کوچک، برای هر بلوک تنها یک مقدار خروجی تولید می‌کند. دو روش متداول در این عملیات، نمونه‌برداری ماکزیمم (Max Pooling) و نمونه‌برداری میانگین (Average Pooling) هستند. در این مطالعه، از روش نمونه‌برداری ماکزیمم برای کاهش ابعاد نگاشت ویژگی استفاده شده است.

۸-۲- حافظه کوتاه مدت - بلند مدت (LSTM) برای طبقه‌بندی

نوعی شبکه عصبی بازگشتی پیشرفته است که برای حل مشکلات وابستگی‌های بلندمدت و گرادیان ناپدیدشونده (Vanishing Gradient) در شبکه‌های عصبی بازگشتی سنتی طراحی شده است. این شبکه دارای سلول‌های حافظه‌ای است که با استفاده از دروازه‌هایی مانند دروازه فراموشی (f_t)، دروازه ورودی (i_t) و دروازه خروجی (o_t)، جریان اطلاعات را در طول زمان کنترل می‌کنند. حالت سلول (c_t) به عنوان مسیر اصلی انتقال اطلاعات در زمان عمل کرده و با حفظ گرادیان‌ها، یادگیری در طول دنباله‌های زمانی بلند را ممکن می‌سازد. این ساختار، شبکه را برای وظایف وابسته به زمینه طولانی‌مدت بسیار مناسب می‌سازد [۱۷]. Error!

Reference source not found..

$$\begin{aligned} f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\ x(t) &= \sigma(W_i x_t + U_i h_{t-1} + b_i) \\ \hat{C}_t &= \tanh(W_c x_t + U_c h_{t-1} + b_c) \\ C_t &= f_t \odot C_{t-1} + i_t \odot \hat{C}_t \\ o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\ h_t &= o_t \odot \tanh(C_t) \end{aligned} \quad (۴)$$



شکل ۷ ساختار شبکه LSTM

Fig. 7 LSTM Network Architecture

-	1	2	-	-	Max-pooling
Relu	2	-	3	128	convolution
-	1	2	-	-	Max-pooling
Relu	2	-	3	128	convolution
-	1	2	-	-	Max-pooling
Relu	2	-	3	256	convolution
-	1	2	-	-	Max-pooling
Relu	2	-	3	256	convolution
-	1	2	-	-	Max-pooling
Relu	2	-	3	512	convolution
-	1	2	-	-	Max-pooling
-	-	-	-	50	LSTM
-	-	-	-	-	Dropout(0.5)
-	-	-	-	50	LSTM
-	-	-	-	-	Flatten
Relu	-	-	-	-	Dense(100)
Softmax	-	-	-	-	Dense(3)

جدول ۷ تعداد کل پارامترهای شبکه و هایپر پارامترهای تنظیم شده

Table 7 Total number of network parameters and hyperparameters tuned

Call-backs	epochs	Batch-size	optimizer	Learning rate	Trainable params
Early-stopping	70	16	Adam	0.0001	916827

جدول ۸ معیارهای سنجش

Table 8 Preformance Metris

parameters	Normal model	Model with K-Fold method
Training Accuracy(%)	84.27	96.44
Validation Accuracy(%)	74.94	85.81
Precision(%)	85.53	95.24
Recall(%)	88.34	95.24
F1-Score(%)	86.03	94.87
Specificity(%)	91.54	95.67
MCC(%)	76.31	90.74

۲-۱۳- معیارهای سنجش (Performance metrics)

برای ارزیابی مدل، از معیارهای دقت (Accuracy)، درستی (Precision)، حساسیت (sensitivity)، F1-score، specificity و MCC استفاده شده است.

$$Acc(\%) = \frac{TN + TP}{TN + TP + FN + FP} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (7)$$

$$F1 - Score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity} \quad (8)$$

$$Specificity = \frac{TN}{TN + FP} \quad (9)$$

$$MCC = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (10)$$

داشتن وزن‌های اتصال یکسان، ویژگی‌های مشابهی را از داده ورودی استخراج کنند؛ به این حالت "هم‌سازی" (Co-adaptation) گفته می‌شود. Dropout با حذف تصادفی نورون‌ها، از این هم‌سازی جلوگیری کرده و به مدل کمک می‌کند تا ویژگی‌های متنوع‌تری را یاد بگیرد، که در نتیجه، توانایی تعمیم شبکه افزایش می‌یابد.

۲-۱۱- بهینه‌ساز Adam (Adaptive Moment Estimation)

یک الگوریتم بهینه‌سازی پرکاربرد در یادگیری عمیق است که برای به‌روزرسانی وزن‌های شبکه‌های عصبی طراحی شده است. این الگوریتم با استفاده همزمان از میانگین و واریانس گرادیان‌ها، نرخ یادگیری را به صورت تطبیقی برای هر پارامتر تنظیم می‌کند. Adam به دلیل عملکرد پایدار و کارآمد، به ویژه در مسائل شامل داده‌های نویزی، بزرگ، یا با ویژگی‌های پراکنده، بسیار مؤثر است. از مهم‌ترین مزایای آن می‌توان به سرعت همگرایی بالا، کاهش نیاز به تنظیمات دستی نرخ یادگیری (Learning Rate)، و عملکرد مناسب در آموزش شبکه‌های عمیق اشاره کرد. این ویژگی‌ها Adam را به یکی از انتخاب‌های اصلی در بسیاری از کاربردهای یادگیری عمیق تبدیل کرده است.

۲-۱۲- پارامترهای شبکه

در فرآیند طراحی معماری شبکه CNN-LSTM، تنظیم مقادیر هایپرپارامترها نظیر تعداد فیلترها، اندازه کرنل، اندازه stride و pool، تعداد لایه‌های LSTM و تعداد نرون‌های لایه‌های تمام‌متصل (Dense)، از طریق روش سعی و خطا و براساس ارزیابی تجربی عملکرد مدل روی مجموعه داده صورت گرفته است. به منظور دستیابی به بهترین دقت ممکن، چندین پیکربندی متفاوت مورد آزمون قرار گرفته و معماری نهایی با در نظر گرفتن معیارهایی مانند دقت (Accracy)، درستی (Precision) و F1-score انتخاب شده است. این شبکه شامل چهارده لایه ابتدایی که متشکل از لایه‌های کانولوشن و pooling می‌باشد، تشکیل شده است و دولایه LSTM در ادامه آنها قرار دارد. تابع فعال ساز برای لایه‌های کانولوشن از نوع تابع Relu می‌باشد و در لایه طبقه بندی از تابع فعال ساز Softmax استفاده شده است. اندازه کرنل در نظر گرفته شده برای لایه‌های کانولوشن، مقدار ۳ تعیین شده است. در جدول ۶ مقادیر تعیین شده برای تشکیل لایه‌های شبکه را به صورت کامل نشان داده شده است. جدول ۷ پارامترهای لازم برای راه‌اندازی شبکه را نشان می‌دهد.

جدول ۶ ساختار لایه‌های شبکه

Table 6 Network Layer Structure

activation	stride	Pool-size	Kernel_size	filter	layers
Relu	2	-	3	64	convolution
-	1	2	-	-	Max-pooling
Relu	2	-	3	64	convolution

۳- نتایج

۳-۱- معیارهای سنجش

معیارهای سنجش از دو مدل در

جدول ۸ قابل مشاهده است.

۴- نتیجه‌گیری و پیشنهادات

در این پروژه، با بهره‌گیری از دو ساختار مختلف برای مدل‌سازی شبکه عصبی، تلاش شده است تا با استفاده از داده‌های نسبتاً محدود موجود، دو مدل متمایز توسعه داده شود و در نهایت مدلی با عملکرد بهتر به عنوان خروجی نهایی انتخاب گردد. همان‌طور که در

جدول ۸ نشان داده شده است، مقایسه شاخص‌های ارزیابی عملکرد دو مدل حاکی از برتری ساختاری است که در آن از روش اعتبارسنجی متقابل K-Fold استفاده شده است، به‌طوری‌که دقت این مدل به ۹۶/۴۴٪ رسیده است، در حالی‌که مدل ساده‌تر دقتی معادل ۸۴/۲۷٪ ارائه داده است.

علاوه بر این، بر اساس مرور مطالعات پیشین ارائه‌شده در جدول ۱، مدل‌های مختلفی نظیر RF، SVM، D-CNN و CNN-LSTM برای تشخیص بیماری پارکینسون پیشنهاد شده‌اند که دقت آن‌ها در بازه‌ای بین ۹۱٪ تا ۹۵/۶٪ قرار دارد. در مقایسه با این مطالعات، مدل CNN-LSTM پیشنهادی این پژوهش عملکرد دقیق‌تری را نشان داده و توانسته است با استخراج مؤثر ویژگی‌های زمانی و مکانی از سیگنال‌های راه‌رفتن، عملکرد بهتری نسبت به مدل‌های پیشین و روش‌های کلاسیک داشته باشد. بنابراین، می‌توان نتیجه گرفت که ساختار بهینه‌شده‌ی CNN-LSTM مبتنی بر K-Fold نه تنها نسبت به مدل ساده‌تر داخلی، بلکه در مقایسه با مدل‌های مطرح در ادبیات پژوهش نیز برتری نسبی دارد.

با این حال، یکی از محدودیت‌های مهم این مطالعه آن است که ارزیابی مدل صرفاً بر روی یک مجموعه داده انجام شده و عملکرد آن بر روی داده‌های مستقل از منابع دیگر یا بیماران متفاوت آزموده نشده است. این موضوع می‌تواند قابلیت تعمیم‌پذیری مدل در شرایط واقعی یا کاربردهای بالینی را با چالش مواجه سازد. لذا برای اعتبارسنجی دقیق‌تر، پیشنهاد می‌شود در پژوهش‌های آینده از مجموعه داده‌های مستقل و چندمرکزی برای ارزیابی و تحلیل عملکرد مدل استفاده شود. با افزایش حجم داده‌های آموزشی، نه تنها امکان استفاده از ساختارهای پیچیده‌تر شبکه‌های عصبی فراهم می‌شود، بلکه خطر بیش‌برازش کاهش یافته و قابلیت تعمیم‌پذیری مدل افزایش می‌یابد؛ موضوعی که به‌طور گسترده در مطالعات حوزه یادگیری عمیق نیز مورد تأکید قرار گرفته است [۹].

بهبود روند تشخیص بیماری پارکینسون مستلزم جمع‌آوری داده‌های باکیفیت و در حجم زیاد است که به استفاده از دستگاه‌های دقیق برای جمع‌آوری داده‌ها و ترکیب انواع مختلف اطلاعات مانند داده‌های حرکتی و تصویربرداری عصبی اشاره دارد. این رویکرد شامل ادغام الگوریتم‌های پیشرفته یادگیری ماشین با منابع داده چندانگانه، از جمله ژنتیک و حسگرهای پوشیدنی، برای

۳-۲- ماتریس درهم ریختگی (Confusing Matrix)

در شکل ۹-الف مدل اول در مجموع ۳۴ پیش‌بینی درست از ۴۰ نمونه داشته است. این مدل در تشخیص کلاس افراد با شدت دو (S2) بسیار خوب عمل کرده و تنها یک مورد را به اشتباه به عنوان افراد سالم تشخیص داده است. برای کلاس افراد با شدت دو و نیم (S2.5)، عملکرد دقیق داشته است. در مورد کلاس افراد سالم، چهار مورد را به اشتباه به عنوان کلاس افراد با شدت دو (S2) و یک مورد را به عنوان کلاس افراد با شدت دو و نیم (S2.5) تشخیص داده است. در شکل ۹-ب مدل دوم با وجود تعداد کمتر نمونه‌ها، عملکرد بهتری نشان داده است. از ۱۶ نمونه، ۱۵ مورد را درست پیش‌بینی کرده است. این مدل در تشخیص افراد با شدت دو و نیم (S2.5) و افراد سالم کاملاً دقیق بوده و هیچ خطایی نداشته است. تنها یک خطا در پیش‌بینی کلاس افراد با شدت دو (S2) داشته که آن را به اشتباه، کلاس افراد سالم تشخیص داده است. به‌طور کلی، مدل دوم عملکرد بهتری نسبت به مدل اول دارد. مدل دوم با کاهش زیان هم‌زمان در هر دو مجموعه داده و افزایش هم‌زمان دقت بدون نوسانات زیاد، و همچنین پیش‌بینی‌های بادقت زیاد به نظر می‌رسد که مدل مناسب‌تری باشد. با توجه به مقایسه صورت گرفته و

جدول ۸ مشاهده می‌شود که مدل استفاده شده با روش K-Fold نتیجه بهتری نسبت به مدل عادی داشته است.

۳-۳- نمودار دقت و هزینه (Loss)

همان‌طور که در شکل ۱۰-الف مشاهده می‌شود، مقدار تابع هزینه برای هر دو مجموعه داده (آموزشی و تست) به مرور زمان کاهش یافته است. اگرچه کاهش هزینه برای داده‌های آموزشی نسبت به داده‌های تست به طور یکنواخت‌تری رخ داده، اما در انتها به نظر می‌رسد که تفاوت کمی بین آنها وجود دارد. همچنین دقت داده‌های آموزشی به تدریج افزایش یافته و به

مقدار بالایی رسیده است، اما دقت تست به طور متناوب نوسان داشته و در انتها به دقت آموزشی نزدیک نشده است. این ممکن است نشان‌دهنده احتمال بیش‌برازش در مدل اول باشد.

همچنین در شکل ۱۰-ب کاهش هزینه به صورت پیوسته برای هر دو مجموعه داده مشاهده می‌شود. اما تفاوت‌ها میان داده‌های آموزشی و تست کمتر است و روند کاهشی برای هر دو تقریباً مشابه است. این نشان‌دهنده یک مدل پایدارتر است که احتمال بیش‌برازش کمتری دارد. در مورد دقت، برای داده‌های آموزشی و تست هر دو به مرور زمان افزایش یافته و در پایان تقریباً به هم


تاییدیه‌های اخلاقی

این پژوهش نیازی به اخذ تاییدیه‌های اخلاقی نداشته است.


تعارض منافع

تعارض منافی وجود ندارد.

شناسایی نشانگرهای زیستی و الگوهای تشخیصی جدید است. استفاده از روش‌های متنوع مانند پردازش تصویر و پردازش سیگنال می‌تواند به گسترش فرایندهای تشخیص کمک کند. در آینده، توسعه ابزارهای غیرتهاجمی (ابزارهایی که بدون نیاز به ورود به بدن برای درمان یا تشخیص بیماری بکار می‌روند) و مقرون به صرفه و ادغام هوش مصنوعی با فناوری‌های هوشمند در پزشکی فردی، می‌تواند به تشخیص زودهنگام و کاهش پیشرفت بیماری کمک کند.



(b)



(a)

شکل ۹ ماتریس درهم‌ریختگی برای الف) مدل عادی ب) مدل با تقسیم‌بندی K-Fold

Fig. 9 Confusing Matrix



(a)



(b)

شکل ۱۰ نمودار دقت و هزینه برای مدل الف) عادی، ب) مدل با تقسیم‌بندی k-Fold

Fig. 10 Accuracy and Loss Curves for a) normal model, b) model with K-Fold splitting

[9] B. Vidya and S. P. , "Parkinson's disease diagnosis and stage prediction based on gait signal analysis using EMD and CNN-LSTM network," *ELSEVIER*, vol. 114, p. 16, 2022.

doi: <http://doi.org/10.1016/j.engappai.2022.105099>

[10] G. Yogev, N. Giladi, C. Peretz, S. Springer, E. S. Simon and J. M. Hausdorff, "Dual tasking, gait rhythmicity, and Parkinson's disease:," *European Journal of Neuroscience*, vol. 22, no. 5, pp. 1248-1256, 2005.

doi:<http://doi.org/10.1111/j.1460-568.2005.04298.x>

[11] J. M. Hausdorff, J. Lowenthal, T. Herman, L. Gruendlinger, C. Peretz and N. Giladi, "Rhythmic auditory stimulation modulates gait variability," *European Journal of Neuroscience*, vol. 26, no. 8, pp. 2369-2375, 2007.

doi:<http://doi.org/10.1111/j.1460-568.2007.05810.x>

[12] S. F. Toledo, N. Giladi, C. Peretz, T. Herman, L. Gruendlinger and J. M. Hausdorff, "Treadmill Walking as an External Pacemaker to Improve Gait," *Movement Disorders*, vol. 20, no. 9, pp. 1109-1114, 2005.

doi: <http://doi.org/10.1002/mds.20507>

[13] N. Giladi, C. Peretz, T. Herman, L. Gruendlinger, J. M. Hausdorff and S. F. Toledo, "Effect of gait speed on gait rhythmicity in Parkinson's disease: variability of stride time and swing time respond differently," *NeuroEngineering and Rehabilitation*, vol. 2, no. 23, p. 7, 2005.

doi: <http://doi.org/10.1186/1743-0003-2-23>

[14] C. G. Goetz, W. Poewe, O. Rascol and G. T. Stebbins, "Movement Disorder Society Task Force report on the Hoehn and Yahr staging scale: Status and recommendations The Movement Disorder Society Task Force on rating scales for Parkinson's disease," *Movement Disorders*, vol. 19, no. 9, pp. 1020-1028, 2014.

doi: <http://doi.org/10.1002/mds.20115>

[15] L. J. Evers, J. H. Krijthe, M. J. Meinders, B. R. Bloem and T. M. Heskes, "Measuring Parkinson's disease over time: The real-world within-subject reliability of the MDS-UPDRS," *Movement Disorders*, vol. 36, no. 10, pp. 2444-2451, 2019.

منابع

[1] W. Poewe, K. Seppi, C. M. Tanner, G. M. Halliday, P. Brundin, J. Volkman, A. Eleonore Schrag and A. E. Lang, "Parkinson disease," *Nature Reviews Disease Primers*, vol. 3, no. 1, pp. 1-21, 2017.

doi: <http://doi.org/10.1038/nrdp.2017.13>

[2] Y. Wu and S. Krishnan, "Statistical Analysis of Gait Rhythm in Patients With Parkinson's Disease," *IEEE Xplore*, vol. 18, no. 2, pp. 150-158, 2010.

doi: <http://doi.org/10.1109/TNSRE.2009.2033062>

[3] W. Ferdous, K. B. Rezaul, J. H. Chris, S. Halmuge and C. A. David, "Classification of Parkinson's Disease Gait Using Spatial-Temporal Gait Features," *IEEE Xplore*, vol. 23, no. 6, pp. 973-982, 2015.

doi: <http://doi.org/10.1109/TNSRE.2015.2404812>

[4] I. E. Maachi, G.-A. B. and W. B. , "Deep 1D-Convnet for accurate Parkinson disease detection and severity prediction from gait," *ELSEVIER*, vol. 143, p. 113075, 2020.

doi: <http://doi.org/10.1016/j.eswa.2019.113075>

[5] P. P. A. K. H. A. and N. P. , "Classification of gait signals into different neurodegenerative diseases using statistical analysis and recurrence quantification analysis," *ELSEVIER*, vol. 117, pp. 1-7, 2018.

doi: <http://doi.org/10.1016/j.patrec.2018.04.005>

[6] N. Khoury, F. Attal, Y. Amirat, L. Oukhellou and S. Mohammed, "Data-Driven Based Approach to Aid Parkinson's," *Sensors*, vol. 19, no. 2, p. 242, 2019.

doi: <http://doi.org/10.3390/s19020242>

[7] B. E. B. D and B. R. , "Supervised machine learning based gait classification system for early detection and stage classification of Parkinson's disease," *ELSEVIER*, vol. 49, p. 106494, 2020.

doi: <http://doi.org/10.1016/j.asoc.2020.106494>

[8] A. B. Oktay and A. Kocer, "Differential diagnosis of Parkinson and essential tremor with convolutional LSTM networks," *ELSEVIER*, vol. 56, p. 6, 2020.

doi: <http://doi.org/10.1016/j.bspc.2019.101683>

doi: <http://doi.org/10.1002/mds.27790>

[16] D. Joshi, A. Khajuria and P. Joshi, "An automatic non-invasive method for Parkinson's disease classification," ELSEVIER, vol. 145, pp. 135-145, 2017.

doi: <http://doi.org/10.1016/j.cmpb.2017.04.007>

[17] Vahid Mehdipour, "Mahsa Memarianfard," Modares Civil Engineering, vol. 18, no. 5, pp. 217-226, 2019.

doi: <http://doi.org/20.1001.1.24766763.1397.18.5.3.3>

[18] M. S. T. R. J. G. M. S. Mahsa Vaghefi, "Polymer Gear Fault Detection Based on Audio Signal and Wavelet Packet," Modares Mechanical Engineering, vol. 24, no. 6, pp. 351-362, 2024.

doi: <http://doi.org/10.48311/MME.24.6.351>