



Computational Intelligence in Electrical Engineering  
Vol. 15, No. 3, 2024  
pp. 137-150  
Research Paper

## Improving the Accuracy of Early Detection of Parkinson's Disease Using Brain Signals Based on Feature Selection in Machine Learning

Shamimeh Sadat Nabavi Monfared<sup>1</sup>, Mohammad Reza Yousefi<sup>2\*</sup>

<sup>1</sup> M.Sc., Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran

<sup>2</sup> Assistant Professor, Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran

### Abstract:

The diagnosis of Parkinson's disease (PD) is usually done clinically by a doctor. This diagnosis is based on the initial symptoms, motor symptoms, and meditation of the doctor's experience. Since the diagnosis is made with the help of a doctor and based on the clinical description and received information, there is always an error in the diagnosis. Also, early clinical diagnosis is very difficult and almost impossible. Using methods based on machine learning is very useful for early diagnosis of Parkinson's disease. Brain signals and brain function can be a suitable solution for early diagnosis of this disease. Conventional methods are not effective due to the dynamics and complexity of the brain signal. Machine learning methods are a suitable solution with their high capabilities in the process of disease diagnosis. In this article, an efficient method based on machine learning is presented. In this method, after brain signals are pre-processed, time and frequency domain features are extracted from each signal and the best features are selected with the help of the improved intelligent gray wolf algorithm. The selected features are classified using a support vector machine classifier, K nearest neighbor, and random forest. Accuracy higher than 97% shows the superiority of the method in predicting Parkinson's disease.

**Keywords:** Parkinson's Disease, Brain Signal, Machine Learning, Feature Selection, Intelligent Gray Wolf Algorithm.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/isee.2024.139761.1665>

## بهبود دقت تشخیص زود هنگام بیماری پارکینسون با استفاده از سیگنال‌های مغزی مبتنی بر

### انتخاب ویژگی در یادگیری ماشین

شمیمه سادات نبوی منفرد<sup>۱</sup>، محمدرضا یوسفی<sup>۲\*</sup>

۱- کارشناسی ارشد، دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

shamimnabavi3@gmail.com

۲- استادیار، دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

mr-yousefi@iaun.ac.ir

**چکیده:** برای تشخیص زود هنگام بیماری پارکینسون (PD) استفاده از روش‌های مبتنی بر یادگیری ماشین بسیار مفید است. سیگنال‌های مغزی و عملکرد مغز می‌تواند یک راه‌کار مناسب برای تشخیص زود هنگام این بیماری باشد. روش‌های متداول به‌علت پویایی و پیچیدگی سیگنال مغزی، کارایی لازم را ندارند. روش‌های یادگیری ماشین با قابلیت‌های بالایی که در فرایند تشخیص بیماری دارند، یک راه‌کار مناسب هستند. در این مقاله یک روش کارآمد مبتنی بر یادگیری ماشین ارائه شده است. در این روش در مرحله پیش‌پردازش حذف نویز و آرتیفکت به کمک یک فیلتر وینر انجام شده است. سپس ویژگی‌های حوزه زمان شامل الگوهای متداول محلی و گرادیان همسایه محلی با وزن متقارن و طیف توان در حوزه فرکانس از هر سیگنال، استخراج و به کمک الگوریتم بهبود یافته گرگ خاکستری هوشمند بهترین ویژگی‌ها انتخاب می‌شوند. ویژگی‌های انتخاب شده به کمک طبقه‌بند ماشین بردار پشتیبان، K نزدیک‌ترین همسایگی و جنگل تصادفی دسته‌بندی شده‌اند. روش پیشنهاد شده روی پایگاه داده متشکل از ۲۸ فرد مبتلا به PD و ۲۸ فرد سالم همسان با سن و جنس پیاده‌سازی شده است. دقت و صحت بالاتر از ۹۷ درصد نشان‌دهنده برتری روش در پیش‌بینی بیماری پارکینسون است.

**واژه‌های کلیدی:** انتخاب ویژگی، بیماری پارکینسون، سیگنال مغزی، الگوریتم گرگ خاکستری هوشمند، یادگیری ماشین.

### ۱- مقدمه

میزان شیوع بیماری پارکینسون در ایران چیزی حدود دو در هزار نفر است؛ این میزان برای افراد بالای ۶۵ سال ده برابر می‌شود و به دو نفر در هر صد نفر می‌رسد. براساس آمارهای سال ۲۰۲۳، در ایران حدود ۲۵۰ هزار فرد مبتلا به پارکینسون وجود دارد؛ البته آمار مبتلایان رو به افزایش است. در زمان حاضر بیشتر بیماران پارکینسون در ایران متولد دهه‌های ۳۰ و ۴۰ هستند؛ اما زنگ خطر برای دهه ۵۰ و ۶۰ به صدا در آمده است [۲، ۳].

بیماری پارکینسون یک بیماری عصبی پیش‌رونده است که معمولاً بر اثر کمبود یا فقدان نورون‌های دوپامین در بدن رخ می‌دهد. در مراحل پیشرفته این بیماری، نشانه‌های حرکتی باعث اختلال‌های شدید حرکتی در افراد خواهد شد که بیشتر به صورت حرکتی نشان داده می‌شود [۴، ۵]. ثبت الکتروانسفالوگرافی<sup>۲</sup> (EEG) برای تشخیص این بیماری

براساس گزارش سازمان جهانی بهداشت<sup>۱</sup> (WHO) تا سال ۲۰۵۰ بیش از یک و نیم میلیارد آدم سالمند روی کره زمین زندگی خواهند کرد که با بیماری‌های گوناگونی درگیر خواهند شد. برخی از این بیماری‌ها به صورت پیش‌رونده هستند و زندگی افراد را با چالش مواجه خواهند کرد [۱]. یکی از این بیماری‌ها بیماری پارکینسون است که با افزایش طول عمر میزان شیوع آن نیز افزایش خواهد یافت.

<sup>۱</sup> تاریخ ارسال مقاله: ۱۴۰۲/۰۸/۲۰

تاریخ پذیرش مقاله: ۱۴۰۲/۱۱/۰۸

نام نویسنده مسئول: محمدرضا یوسفی

نشانی نویسنده مسئول: ایران، نجف‌آباد، دانشگاه آزاد اسلامی، واحد نجف‌آباد، دانشکده مهندسی برق

معمولاً یک روش غیرتجانسی، ارزان و قابل اعتماد است. نوار مغزی می‌تواند اطلاعات فعالیت مغزی را به‌خوبی ثبت کند و رفتار نورون‌های مغزی و فعالیت‌های نورون‌ها را به‌خوبی زیر نظر بگیرد [۷،۶]. تغییرات رفتاری نورون‌هایی مانند عدم کارکرد صحیح فعالیت‌های شناختی، پیچیدگی حرکتی، تغییرات جسمی و بیماری‌های اختلال خواب را نشان دهد [۹،۸]. استفاده از روش‌های مبتنی بر یادگیری ماشین<sup>۲</sup> یک راه‌کار مناسب برای تشخیص این بیماری حتی در مراحل شروع است [۱۱،۱۰].

الگوریتم یادگیری ماشین با استفاده از مجموعه‌ای از ویژگی‌ها، کلاس‌بندی را می‌تواند انجام دهد. در سال‌های گذشته دامنه ویژگی‌ها در برنامه‌های کاربردی یادگیری ماشین یا تشخیص الگو، از ده‌ها تا صدها ویژگی گسترده شده است. به‌طور کلی انتخاب ویژگی به درک بهتر از داده‌ها، کاهش نیازمندی‌های محاسباتی، کاهش اثر مخرب ابعاد و بهبود کارایی پیش‌بینی‌شده کمک می‌کند [۱۳،۱۲]. تمرکز انتخاب ویژگی روی انتخاب زیرمجموعه‌ای از متغیرهای ورودی است که می‌تواند داده‌های ورودی را به‌صورت مؤثرتری شرح دهد، تأثیرات نویز و متغیرهای نامربوط را کاهش دهد و در عین حال به‌خوبی نتایج پیش‌بینی‌شده را فراهم کند [۱۴]. بزرگ‌ترین مشکل سیگنال‌های مغزی، داشتن دامنه گسترده‌ای از ویژگی‌ها است که به غیراستاندارد شدن کلاس‌بندی‌ها و افزایش هزینه آنها منجر می‌شود که با روش‌های کاهش ابعاد یا انتخاب ویژگی این مشکل برطرف می‌شود [۱۵].

پژوهش‌های متعددی برای تشخیص بیماری پارکینسون در سیگنال‌های مغزی به کمک یادگیری ماشین ارائه شده‌اند. در مرجع [۱۶] از تبدیل موجک تحلیلی انعطاف‌پذیر<sup>۴</sup> (FAWT) و تحلیل واریانس<sup>۵</sup> (ANOVA) برای انتخاب ویژگی استفاده شده است. در مرجع [۱۷] یک رویکرد انتخاب ویژگی ترکیبی برای به دست آوردن اطلاعات متقابل و حذف ویژگی‌های بازگشتی<sup>۱</sup> (MIRFE) پیشنهاد شده است. در مرجع [۱۸] با استفاده از ویژگی‌های مبتنی بر همبستگی جهت‌دار نسبی (PDC) به تشخیص پارکینسون<sup>۷</sup> (PD) اشاره شده است. در مرجع [۱۹] برای تشخیص پارکینسون از درخت جنگل تصادفی برای پیش‌بینی استفاده

شده است. در مرجع [۲۰] استفاده از کدینگ پیش‌بینی خطی در ویژگی‌های طیفی برای تشخیص بیماری پارکینسون پیشنهاد شده است. در مرجع [۲۱] ارتباط و همبستگی بین ویژگی‌ها و نمرات بیماری پارکینسون از طریق اعمال الگوریتم انتخاب مبتنی بر اطلاعات متقابل با آزمون جایگشت و تغذیه داده‌ها با ویژگی‌های انتخابی براساس بیشترین ارتباط حداقل افزونگی<sup>۸</sup> (mRMR) در یک طبقه‌بندی‌کننده ماشین بردار پشتیبان<sup>۹</sup> (SVM) ارزیابی شده است. در مرجع [۲۲] با استفاده از ویژگی‌های خود مشابه و خطی به تشخیص بیماری پارکینسون از نوار مغزی اشاره شده است. در مرجع [۲۳] با مانیتورکردن پیشرفت بیماری پارکینسون به کمک استخراج ویژگی و رگرسیون غیرخطی به تشخیص پارکینسون پرداخته‌اند. در مرجع [۲۴] از طبقه‌بند ماشین بردار پشتیبان بهبودیافته به کمک الگوریتم بهینه‌ساز باکتری و همچنین انتخاب ویژگی قابل تسکین برای تشخیص پارکینسون استفاده شده است. مقایسه روش‌های مبتنی بر یادگیری عمیق در جدول (۱) نشان داده شده است. در روش پیشنهادی یک تابع هزینه چندهدفه به‌عنوان تابع برازندگی در نظر گرفته خواهد شد که با توجه به تابع هدف آن، یعنی انتخاب مؤثرترین ویژگی‌ها، شناسایی بیماری پارکینسون با بالاترین دقت ممکن انجام می‌شود. انتخاب تابع هزینه چندهدفه باعث خواهد شد الگوریتم گرگ خاکستری در حداقل‌های محلی قرار نگیرد و در نتیجه زیرمجموعه ویژگی انتخاب‌شده بهینه‌ترین زیرمجموعه باشد. در مقایسه با سایر الگوریتم‌های فراکتشافی یا تکاملی، این الگوریتم دارای سرعت همگرایی بیشتری است و همچنین، احتمال اینکه در بهینه‌سازی مسائل در حداقل‌های موضعی قرار بگیرد بسیار کم است [۲۵].

الگوریتم‌های فراکتشافی<sup>۱۱</sup> در واقع یکی از انواع الگوریتم‌های بهینه‌سازی احتمالی هستند که دارای راه‌کارهای برون‌رفت از بهینه‌سازی محلی‌اند و برای طیف گسترده‌ای از مسائل کاربرد دارند [۲۶]. عامل مهم در این روش‌ها، تعادل پویا بین استراتژی‌های تنوع‌بخشی و پر قدرت‌سازی است [۲۷].

در این مقاله برای تشخیص پارکینسون مراحل پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و دسته‌بندی

## ۲- استخراج ویژگی

هر سیگنال از افراد سالم و بیمار شرکت کننده در آزمایش به منظور در پایگاه داده به مدت ۴۰۰۰ میلی ثانیه ثبت شده است. به منظور استخراج ویژگی هر سیگنال به ۲۰ بازه مساوی ۲۰۰ میلی ثانیه تقسیم بندی شده است. به منظور استخراج ویژگی سه روش شامل دو روش الگوهای متداول محلی (CSP) و الگوی گرادیان همسایه محلی با وزن متقارن<sup>۱۱</sup> (SWLNGP) در دسته روش های استخراج ویژگی در حوزه زمان و یک روش بردار طیف توان<sup>۱۲</sup> (SPV) در حوزه فرکانس ارائه شده اند.

### ۲-۱- بردار توان طیفی

آنالیز طیف توان یکی از راه های مناسب برای استخراج ویژگی از سیگنال های مغزی است. ویژگی های طیف توان استخراج شده از سیگنال EEG در یک بردار (ماتریس سطری یا ستونی) قرار داده می شود. این بردار، بردار توان طیفی (SPV) نامیده می شود. آنالیز طیف توان برای تخمین چگالی طیفی روی تبدیل طیفی انجام می شود. پس از اینکه پیش پردازش روی هر کانال انجام شد، روی آن تبدیل فوریه سریع با تبدیل فوریه اعمال خواهد شد. سپس هر مقدار ضریب فوریه به توان دو می رسد و در هر ریزباند با یکدیگر جمع می شود. رابطه زیر نشان دهنده SPV محاسبه شده در هر کانال است [۲۸].

وجود دارند. در مرحله پیش پردازش معمولاً حذف آرتیفکت<sup>۲</sup> و همچنین نویز از سیگنال های مغزی صورت می گیرد. سپس در گام استخراج ویژگی، ویژگی های حوزه زمان، فرکانس یا چند رزلوشنه استخراج خواهند شد. این ویژگی ها یک بردار را تشکیل خواهند داد. به عبارت دیگر، هر ویژگی های استخراج شده از هر سیگنال مغزی را می توان به صورت یک بردار نشان داد که هر عنصر آن، یک ویژگی است. این بردار به عنوان بردار ویژگی در نظر گرفته می شود که تعداد درایه های این بردار برای پردازش ممکن است بالا باشد. برای در دست داشتن مؤثرترین ویژگی ها در این مقاله از الگوریتم فراکتشافی گرگ خاکستری استفاده شده است. از نوآوری های تحقیق می توان به موارد زیر اشاره کرد:

- انتخاب ویژگی به کمک الگوریتم گرگ خاکستری دودویی انطباقی هوشمند

- طراحی یک تابع هزینه چندهدفه به عنوان تابع برانزنگی برای انتخاب مؤثرترین ویژگی ها

- تشخیص بیماری پارکینسون با بالاترین دقت ممکن در ادامه، ساختار مقاله به این شرح است. در بخش دوم، روش های استخراج ویژگی استفاده شده، اشاره و در بخش سوم، روش پیشنهادی با جزئیات بیان شده است. در بخش چهارم، نتایج به دست آمده با استفاده از روش پیشنهادی تحلیل می شوند و در نهایت در بخش پنجم، نتیجه گیری بیان شده است.

جدول (۱): مقایسه روش های پیشین

مرجع	روش پیشنهادی	مزایا	معایب
[۱۴]	تبدیل موجک تحلیلی انعطاف پذیر (FAWT)	مناسب بودن سیستم پیشنهادی برای متخصصان مغز و اعصاب در طول فرایند تشخیصی	پیچیدگی محاسباتی، بیش برآزش در طبقه بندیها بر اثر ویژگی های استخراج شده
[۱۵]	رویکرد انتخاب ویژگی ترکیبی MIRFE	جلوگیری از بیش برآزش، رسیدن به دقت بالا	پیچیدگی محاسباتی
[۱۶]	استفاده ویژگی های مبتنی بر همبستگی جهت دار نسبی (PDC)	جلوگیری از بیش برآزش	دقت پایین تشخیص، قابلیت تفکیک پذیری ویژگی های استخراج شده
[۱۷]	روش بهبود یافته مبتنی بر جنگل تصادفی	جلوگیری از بیش برآزش، دقت بالای تشخیص	پیچیدگی محاسباتی و هزینه محاسباتی بالا
[۱۸]	کدینگ پیش بینی خطی در ویژگی های طیفی	روش کدینگ پیش بینی خطی در انتخاب ویژگی قوی است	طبقه بندی به کار گرفته شده قابلیت بالایی در طبقه بندی ندارد
[۱۹]	الگوریتم انتخاب مبتنی بر اطلاعات متقابل با آزمون	جلوگیری از بیش برآزش	دقت پایین در تشخیص بیماری

		جایگشت و تغذیه داده‌ها با ویژگی‌های انتخابی	
[۲۰]	استفاده از ویژگی‌های خود مشابه و خطی	ویژگی‌های حوزه زمان استخراج می‌شوند و دیگر نیازی به روش‌های مبتنی بر تبدیل نیست	حساس بودن روش پیشنهادی به نویز
[۲۱]	استخراج ویژگی با تکنیک‌های رگرسیون خطی و غیرخطی	هزینه محاسباتی پایین	دقت پایین در تشخیص بیماری
[۲۲]	طبقه‌بند ماشین بردار پشتیبان به کمک الگوریتم بهینه‌ساز باکتری	قابلیت بالای تعمیم روش پیشنهادی و جلوگیری از بیش‌برازش	پیچیدگی محاسباتی و هزینه محاسباتی بالا

$$f = \log(wC_2 w^T) = \log(\text{var}(w X_2)) \quad (3)$$

$$SPV = \sum_{i=1}^N |x_i(f)|^2 \quad (1)$$

## ۲-۳- الگوی گرادیان همسایه محلی با وزن

### مقارن

الگوی گرادیان همسایه محلی با وزن مقارن از الگوریتم الگوهای محلی دودویی<sup>۱۴</sup> (LBP) استنباط شده است. LBP شامل بررسی دقیق مناطق غیرهمپوشانی سیگنال مغزی در برابر یک مقدار نام‌گذاری شده است [۳۶،۳۵]. یک رقم بولی که نتیجه را نشان می‌دهد به هم متصل می‌شود تا رشته‌ای با طول هشت بیت در هر مقایسه تشکیل شود. سپس رشته بولی به فرمت اعشاری تبدیل می‌شود. از طریق پردازش مکرر، مجموعه‌ای از مقادیر منحصر به فرد نشان‌دهنده روند الگوهای محلی دودویی LBP از سیگنال مغزی به دست می‌آید. LBP به دلیل توانایی خود در ثبت تغییرات سراسری، شناخته شده و بسیار به آن توجه شده است؛ اما داده‌های سیگنال مغزی دارای نویز هستند و حتی با انجام پیش‌پردازش هنوز در این سیگنال‌ها نویز وجود خواهد داشت [۳۸،۳۷]؛ از این رو، الگوی گرادیان همسایه محلی با وزن مقارن مطابق رابطه زیر ارائه شده است.

$$LBP = \sum_{i=1}^n (b[i] \times 2^{n-i}) \quad (4)$$

الگوی گرادیان همسایه محلی با وزن مقارن یک گام فراتر از LBP می‌رود تا اطمینان حاصل کند هم تغییرات کلی و هم برخی از تفاوت‌های محلی در سیگنال ثبت می‌شوند. همچنین، نویز و آرتیفکت کمترین تأثیر را در استخراج ویژگی دارند؛ از این رو، در این روش مقدار نقطه

## ۲-۲- الگوهای مکانی متداول (CSP)

الگوهای مکانی متداول<sup>۱۳</sup> به کمک یادگیری یک ترکیب خطی از ویژگی‌های حوزه مکان انجام می‌شوند [۳۰،۲۹]. برای ساخت این ویژگی‌ها از فیلترهای حوزه مکان استفاده می‌شود. فیلترها به گونه‌ای طراحی می‌شوند که واریانس سیگنال فیلترشده برای یک کلاس حداکثر باشد؛ اگر برای کلاس‌های دیگر در حداقل مقدار خود قرار بگیرد، جدا از اینکه کاهش بُعد نیز صورت می‌گیرد، ویژگی‌های CSP می‌توانند برای بازیابی خود سیگنال مغزی استفاده شوند [۳۲،۳۱]. در صورتی که یک تبدیل مکانی روی سیگنال مغزی اعمال شود، می‌توان بردار ویژگی را به صورت رابطه زیر تعریف کرد [۳۴،۳۳].

$$J_{CSP}(w) = \frac{wX_1X_1^T w^T}{wX_2X_2^T w^T} = \frac{wC_1 w^T}{wC_2 w^T} \quad (2)$$

در این رابطه،  $x_i$  و  $c_i$  به ترتیب ماتریس سیگنال فیلترشده میانی و ماتریس کوواریانس برای کلاس  $i$ ام هستند. همچنین، سیگنال فیلترشده مکانی برای کلاس  $i$ ام،  $wX_iX_i^T w^T$  واریانس سیگنال فیلترشده است. برای رسیدن به بیشترین مقدار  $J_{CSP}(w)$  باید نسبت درون‌کلاسی سیگنال حداکثر شود. برای حل این مسئله از تجزیه مقادیر ویژه استفاده می‌شود. فیلتر  $w$  به گونه‌ای است که مقدار  $J_{CSP}(w)$  را حداکثر می‌کند؛ بنابراین،  $w$  بردار ویژگی نهایی است که  $C_2$  و  $C_1$  نیز مقادیر ویژه هستند؛ در نهایت، بردار ویژگی نهایی به صورت رابطه زیر تعریف می‌شود [۲۸].

اجتماعی گرگ‌ها براساس ساختار اجتماعی آنها، یک پارامتر به نام هوشمندی تعریف شده است. این پارامتر بسیار به نوع گرگ مدنظر بستگی دارد. پارامتر هوشمندی برای هر گرگ به صورت نسبی تعریف می‌شود. گفتنی است این پارامتر یک عدد تصادفی است که با توجه به نوع گرگ متغیر خواهد بود. در حل مسئله انتخاب ویژگی، ویژگی‌های مناسب از مجموعه ویژگی‌ها استخراج خواهند شد. بهبود ارائه شده شامل ایجاد یک استراتژی جست‌وجوی جدید به کمک به روزرسانی موقعیت گرگ‌ها براساس پارامتر هوشمندی هر گرگ است. گرگ‌ها به صورت تصادفی در فضای مسئله توزیع می‌شوند. این توزیع در بازه  $[l_i+u_i]$  انجام می‌شود.

$$X_{ij} = l_j + \text{rand}_j[0,1] \times (u_j - l_j) \quad (7)$$

$i \in [1, N], j \in [1, D]$

موقعیت گرگ نام در  $t$  امین تکرار به صورت بردار با مقادیر حقیقی زیر است:

$$X_i(t) = \{X_{i1}, X_{i2}, \dots, X_{iD}\} \quad (8)$$

که در آن،  $D$  ابعاد مسئله است. تمام جمعیت گرگ‌ها در ماتریس جمعیت ذخیره خواهند شد. این ماتریس  $N$  سطر و  $D$  ستون دارد. علاوه بر شکار گروهی، شکار شخصی رفتار دیگری است که در جامعه گرگ‌ها انجام می‌شود. به بیان دیگر، شکار تکی هر گرگ رفتار مورد علاقه هر گرگ است. در مرجع [۴۲] از این انگیزه برای بهبود الگوریتم گرگ خاکستری استفاده شده و روش I-GWO ارائه شده است.

در این مقاله یک پارامتر جدید به نام شکار مبتنی بر یادگیری بعد<sup>۱</sup> (DLH) تعریف شده است. در DLH هر گرگ رفتار همسایه خود را برای انتخاب موقعیت جدید در نظر می‌گیرد و موقعیت جدید را انتخاب می‌کند. آنچه حائز اهمیت است موقعیت هر گرگ در حلقه‌زدن به دور شکار، و در نهایت متوقف‌شدن و حمله نهایی به شکار، به پارامترهای دیگری نیز بستگی دارد. پارامترهایی از جمله ذکاوت و تجربه گرگ در قرارگیری در موقعیت مدنظر که در این مقاله با نام پارامتر هوشمندی نامیده می‌شود، در تعیین موقعیت نهایی، به منظور شکار استفاده خواهد شد. هر

میانی انتخاب شده است و مقادیر آن براساس تفاوت آنها با نقاط میانی انتخاب شده منطقه محاسبه می‌شود. همچنین، مقادیر مشتق شده برای تشکیل یک مقدار آستانه میانگین می‌شوند. برخلاف LBP، مشتقات جدید به جای نقطه میانی با مقدار آستانه مقایسه می‌شوند و تغییرات محلی عمده را نیز به تصویر می‌کشند. رابطه زیر این فرایند را نشان می‌دهد.

$$SWLNDP = \sum_{i=1}^n (b[i] \times 2^{n-i}) + \sum_{i=\frac{n}{2}+1}^n (b[i] \times 2^{i-\frac{n}{2}}) \quad (5)$$

مقدار آستانه با استفاده از رابطه زیر محاسبه می‌شود [۴۰، ۳۹]:

$$\text{Threshold} = \frac{1}{2} \times \sum_{i=1}^n |x[i] - c| \quad (6)$$

## ۲-۴- الگوریتم گرگ خاکستری در انتخاب ویژگی

این الگوریتم با تعداد تصادفی گرگ شروع می‌شود و تابع برازندگی موقعیت گرگ‌ها را ارزیابی می‌کند [۴۱]. سپس مراحل مدنظر تکرار می‌شود، بسیار توقف زمانی ایجاد می‌شود که به تعداد تکرارهای از پیش تعیین شده MaxIter رسیده باشد یا اینکه تابع هدف مدنظر به دست آمده باشد. در هر تکرار، سه گرگ نخست بهترین مقدار برازندگی را خواهند داشت. موقعیت‌ها به صورت سه گام مدنظر، بهینه و حمله به شکار انجام می‌شود. اگرچه الگوریتم گرگ خاکستری ساده و پیاده‌سازی راحتی دارد، با توجه به اینکه تنوع جمعیتی کمی دارد، تعادل بین فضای جست‌وجو و اکتشاف و همگرایی به راحتی انجام نمی‌شود. در GWO اصلی، موقعیت هر گرگ به کمک گرگ‌های  $\alpha$ ،  $\beta$  و  $\delta$  تعیین می‌شود. این کار سبب می‌شود همگرایی به‌کندی انجام شود. تنوع کم جمعیت اولیه نیز سبب می‌شود این مشکل بیشتر شود [۴۲، ۴۳].

در این مقاله یک روش جدید انتخاب ویژگی مبتنی بر گرگ خاکستری هوشمند نسبی پیشنهاد شده است. در روش پیشنهاد شده پس از استفاده از مفاهیم هوشمندی در زندگی

استفاده شده در این تحقیق، ۲۸ فرد مبتلا به PD و ۲۸ فرد سالم همسان با سن و جنس حضور دارند. همه گروه‌های کنترل با سن و جنس با یک فرد مبتلا به PD مطابقت دارند. فقط پرسشنامه افسردگی بک<sup>۱۶</sup> (BDI) بین گروه‌ها متفاوت بود (PD>HC). آزمون وضعیت ذهنی کوچک<sup>۱۷</sup> (MMSE)، تست خواندن بزرگسالان آمریکای شمالی<sup>۱۸</sup> (NAART)، مقیاس رتبه‌بندی بیماری پارکینسون متحد<sup>۱۹</sup> (موتور) (UPDRS)، دوز معادل ال‌دوپا<sup>۲۰</sup> (LED) و تشخیص پارکینسون اطلاعات دیگر گرفته شده از این پایگاه داده است [۴۸].

### ۳-۲- فیلتر وینر

روش‌های فیلترینگ متعددی در حذف مصنوعات از سیگنال مغزی استفاده شده است که می‌توان به فیلتر تطبیقی، فیلتر وینر و فیلتر بایاس اشاره کرد که روش‌های مختلف با اصول بهینه‌سازی متفاوت پیاده‌سازی شده‌اند [۴۹]؛ با وجود این، برای به حداقل رساندن میانگین مربعات خطا بین EEG پیش‌بینی شده با حذف آرتیفکت و نویز و EEG اولیه، یک ضریب وزنی W تطبیق داده می‌شود. فیلتر وینر به‌عنوان فیلتر تطبیقی یک فیلتر بهینه است؛ با این حال، روش فیلتر وینر یک روش فیلتر آماری خطی است که برای تخمین داده‌های سیگنال مغزی واقعی با هدف ایجاد یک فیلتر خطی ثابت زمان برای به حداقل رساندن میانگین مربعات خطا بین خالص استفاده می‌شود. فیلتر خطی با تخمین چگالی طیفی توان سیگنال اندازه‌گیری شده و سیگنال مصنوعی پیدا می‌شود؛ زیرا هیچ دانش قبلی دربارهٔ آمار وجود ندارد. فیلتر وینر محدودیت مرجع اضافی را از بین می‌برد؛ اما نیاز به کالیبراسیون پیچیدگی کاربرد آن را اضافه می‌کند. در این تحقیق از فیلتر وینر برای حذف آرتیفکت استفاده شده است. فیلتر وینر استفاده شده از مرتبه اول و به‌صورت فرکانس پایین است.

### ۳-۳- انتخاب ویژگی و طبقه‌بندی

انتخاب ویژگی به کمک گرگ‌های هوشمند و یادگیر در محیط صورت گرفته است. مراحل انتخاب ویژگی در روش

گرگ در ساختار اجتماعی گله گرگ براساس هوشمندی و ذکاوت خود قرار دارد. به بیان دیگر، گرگ آلفا با هوش‌ترین گرگ است و سپس گرگ بتا و درنهایت گرگ دلتا قرار دارد. تغییر موقعیت گرگ‌ها در حلقه‌زدن به دور شکار و به‌روزرسانی موقعیت در تنگ‌ترکردن حلقه به هوش و ذکاوت گرگ مدنظر بستگی دارد. پیاده‌سازی الگوریتم پیشنهادی به‌منظور GWO بسیار ساده است. در الگوریتم گرگ خاکستری، با توجه به اینکه تنوع جمعیت آن پایین است، تعادل بین اکتشاف و جست‌وجو و در نتیجه تعادل نهایی در همگرایی نهایی ایجاد می‌شود. همچنین، به‌روزرسانی معادلات موقعیت GWO پیشنهادی در بهره‌برداری به‌خوبی انجام می‌شود؛ در نتیجه، با احتمال کمتری در حداقل‌های محلی قرار خواهد گرفت. همچنین، سرعت همگرایی بالاتر خواهد بود.

### ۳-۳- روش پیشنهادی

تشخیص PD به‌ویژه از سیگنال‌های EEG چالش‌برانگیز است؛ زیرا هیچ الگوی مشخصی بین علائم یا پیشرفت بیماری وجود ندارد و معمولاً برای هر فردی متفاوت است [۴۶، ۴۵، ۴۴]. در برخی موارد، تشخیص قطعی پس از مرگ طی کالبد شکافی زمانی امکان‌پذیر است که دسترسی فیزیکی به گانگلیون‌های پایه وجود دارد [۴۷]. روش‌های مبتنی بر یادگیری ماشین در تشخیص بیماری در سیگنال‌های EEG از مراحل متعددی مطابق شکل (۱) تشکیل شده‌اند که عبارت‌اند از دریافت و ثبت سیگنال، پیش‌پردازش برای حذف نویز و آرتیفکت سیگنال، استخراج ویژگی، انتخاب ویژگی و درنهایت، آموزش طبقه‌بند برای دسته‌بندی سیگنال‌ها.

### ۳-۱- پایگاه داده

سیگنال الکتروانسفالوگرافی که به‌عنوان پاداش مثبت (RewP) شناخته می‌شود، با خطای پیش‌بینی پاداش پس از دریافت پاداش مقیاس می‌شود. این سیگنال از نظر محاسباتی با فرایند یادگیری مبتنی بر دوپامین مربوط به اختلاف بین انتظار پاداش و کسب پاداش یکسان است. در پایگاه داده

سیگنال EEG آموزش و پایگاه داده ویژگی سیگنال EEG آزمون و ماتریس تعیین کلاس هر یک از نمونه‌ها هستند. ج- طبقه‌بند جنگل تصادفی با تعداد درختان مختلف برای جنگل آزمایش شده است. این طبقه‌بند در فاز آموزش با استفاده از پارامتر تعداد درختان و داده‌های آموزشی و کلاس داده‌های آموزشی یک مدل طراحی می‌کند که این مدل در فاز پیش‌بینی، کلاس داده‌های آزمون را پیش‌بینی می‌کند.

#### ۴- معیارهای ارزیابی

ارزیابی روش پیشنهادی روی سیگنال‌های موجود در پایگاه داده انجام خواهد شد. معیارهای صحت و دقت برای ارزیابی استفاده شده‌اند که به ترتیب عبارت‌اند از [۵۱،۵۰]:

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}} \times 100 \quad (9)$$

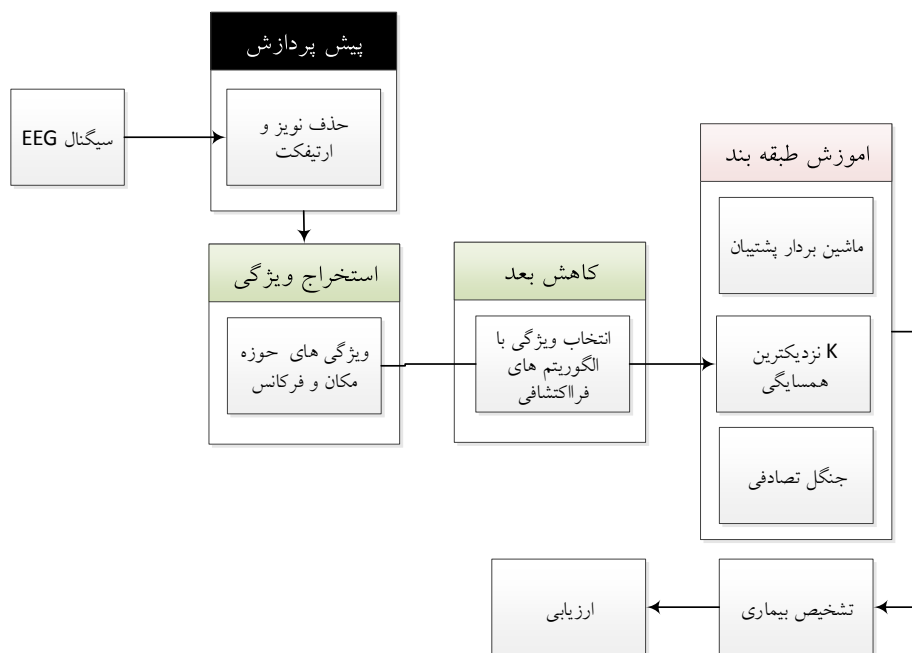
$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100 \quad (10)$$

پیشنهادی در شکل (۲) نشان داده شده است. به‌منظور انتخاب ویژگی در روش پیشنهادی از تابع هدف خطای طبقه‌بندی و طبقه‌بند k نزدیک‌ترین همسایگی استفاده شده است. فرایند طبقه‌بندی و آموزش طبقه‌بندها بعد از انتخاب ویژگی صورت می‌گیرد. در فرایند طبقه‌بندی، ۷۰ درصد از داده‌ها برای آموزش و ۳۰ درصد برای آزمون استفاده می‌شود. به‌منظور شبیه‌سازی و پیش‌بینی پارکینسون از سه طبقه‌بند زیر استفاده شده است:

الف- ماشین بردار پشتیبان با هسته خطی، تابع پایه شعاعی<sup>۲۱</sup> (RBF)، چندجمله‌ای<sup>۲۲</sup> (MLP)، درجه دوم<sup>۲۳</sup> و فاصله کسینوسی و اقلیدسی آزمایش شده است.

ورودی‌های این طبقه‌بند، پایگاه داده ویژگی‌های استخراج‌شده EEG آموزش و پایگاه داده ویژگی سیگنال EEG آزمون و ماتریس تعیین کلاس هر یک از نمونه‌های آموزشی است.

ب- طبقه‌بند k نزدیک‌ترین همسایگی با شعاع همسایگی ۱، ۳، ۵، ۷ و ۹ و فاصله اقلیدسی و کسینوسی استفاده شده است. ورودی‌های این طبقه‌بند، دو پارامتر شعاع همسایگی و فاصله به همراه پایگاه داده ویژگی



شکل (۱): مراحل تشخیص بیماری پارکینسون از سیگنال‌های مغزی در روش پیشنهادی



نتیجه را در پنجره RBF نشان می‌دهد. با تغییر پارامترهای متغیر مربوط به طبقه‌بندها، نتایج مختلفی در تشخیص پارکینسون به دست خواهند آمد.

جدول (۲): ارزیابی صحت شناسایی روش پیشنهادی با

طبقه‌بندهای مختلف در پنجره تابع پایه شعاعی

	ماشین بردار پشتیبان	k نزدیک‌ترین همسایگی	جنگل تصادفی
ویژگی حوزه فرکانس (SPV)	۹۳	۹۱	۹۰
ویژگی‌های حوزه زمان (SWLNGP+CSP)	۹۷/۵	۹۰	۹۱

در طبقه‌بند SVM نوع کرنل و معیار فاصله در طبقه‌بند KNN مقدار k تغییر خواهد کرد. در تمام ارزیابی‌ها با ویژگی‌های استخراج و انتخاب شده، هر آزمایش ۱۰ بار تکرار خواهد شد. گفتنی است هر بار داده‌های موجود در پایگاه داده به بخش‌های آموزش ۷۰ درصد و آزمون ۳۰ درصد تقسیم شده است. سپس بازه اطمینان همراه با میانگین و انحراف معیار روی سه طبقه‌بند جنگل تصادفی، k نزدیک‌ترین همسایگی و ماشین بردار پشتیبان محاسبه و مقایسه می‌شود. این تکرار برای جلوگیری از تصادفی شدن نتایج است. سپس میانگین دقت و صحت این ۱۰ بار به عنوان نتیجه خروجی ثبت خواهد شد. ارزیابی سطح اطمینان صحت روش پیشنهادی با جنگل تصادفی، k نزدیک‌ترین همسایگی، ماشین بردار پشتیبان در جدول (۳) آمده است. با توجه به نتایج به دست آمده، صحت ویژگی‌های حوزه زمان (SWLNGP+CSP) نسبت به ویژگی‌های حوزه فرکانس (SPV) برای هر سه طبقه‌بند بهتر شده است. ماشین بردار پشتیبان با صحت میانگین ۹۷/۵ بیشترین صحت شناسایی را دارد و طبقه‌بند مناسب‌تری نسبت به سایر طبقه‌بندها است.

۱	بارگذاری پایگاه داده مدنظر
۲	مقادیر اولیه الگوریتم بهینه‌ساز گرگ‌های خاکستری پیشنهادی را تعیین کن. $A=[-2, 2]$ $C=[0, 2]$
۳	تعداد گرگ‌های خاکستری
۴	$X\alpha$ گرگ آلفا به عنوان بهترین راه‌حل اول
۵	$X\beta$ گرگ بتا به عنوان بهترین راه‌حل دوم
۶	$X\delta$ گرگ دلتا به عنوان بهترین راه‌حل سوم
۷	$\vec{D}_\Omega$ گرگ امگا به عنوان بهترین راه‌حل سوم
۸	// شرط خاتمه براساس تعداد تکرار الگوریتم
۹	تعیین Z شرط خاتمه الگوریتم
۱۰	تا پایان و رسیدن به شرط خاتمه
۱۱	براساس ماتریس ویژگی نقاط اولیه شکار تعیین شد.
۱۲	به‌روزرسانی موقعیت گرگ‌های $X\alpha$ ، $X\beta$ و $X\delta$ .
۱۳	تعیین نقطه تعیین‌شده به عنوان خوشه انتخابی
۱۴	تکرار الگوریتم تا تعیین تعداد ویژگی‌های مدنظر تعیین‌شده توسط کاربر به دست آید
۱۵	برو به ۱۰ و تعیین ویژگی بعدی
۱۶	برای شرط خاتمه و پایان هر تکرار از گرگ‌های خاکستری
۱۷	تعیین تمام ویژگی‌ها در انتخاب ویژگی
۱۸	خاتمه

شکل (۲): شبه کد انتخاب ویژگی در روش پیشنهادی

## ۵- تحلیل نتایج

ارزیابی تشخیص پارکینسون مبتنی بر ویژگی‌های استخراج‌شده از سیگنال مغزی در دو حالت با کاهش بعد و بدون کاهش بعد انجام شده که در ادامه بیان شده است. ویژگی‌های حوزه فرکانس مانند (SPV) و حوزه زمان مانند (SWLNGP+CSP) به صورت جداگانه وارد طبقه‌بندهای مدنظر می‌شوند. الگوهای متداول محلی CSP و الگوی گرادیان همسایه محلی با وزن متقارن (SWLNGP) در دسته روش‌های استخراج ویژگی در حوزه زمان (SWLNGP+CSP) هستند و روش آنالیز طیف توان (SPV) در حوزه فرکانس است. صحت روش پیشنهادی در جدول (۲) ارزیابی شده است. طبقه‌بند ماشین بردار پشتیبان در ویژگی‌های حوزه زمان (SWLNGP+CSP) بهترین

جدول (۳): ارزیابی سطح اطمینان صحت روش پیشنهادی با طبقه‌بندهای مختلف

ارزیابی بازه سطح اطمینان	نوع طبقه‌بند	میانگین	انحراف معیار	بازه اطمینان
ویژگی حوزه فرکانس (SPV)	جنگل تصادفی	۸۹/۶۰	۱/۷۲	[۸۸/۳۶، ۹۰/۸۳]
	k نزدیک‌ترین همسایگی	۸۷/۹۵	۱/۹۵	[۸۶/۵۵، ۸۹/۳۴]
	ماشین بردار پشتیبان	۹۵/۵۰	۰/۹۴	[۹۷/۱۷، ۹۵/۳۲]
ویژگی‌های حوزه زمان (SWLNGP+CSP)	جنگل تصادفی	۹۱/۵۵	۲/۱۷	[۹۱/۹۸، ۸۷/۹۹]
	k نزدیک‌ترین همسایگی	۹۰/۰۵	۳/۲۷	[۹۱/۳۹، ۸۷/۷۰]
	ماشین بردار پشتیبان	۹۷/۵۰	۰/۵۹	[۹۸/۸۷، ۹۵/۰۲]

### ۵-۱- ارزیابی بدون کاهش بعد

در این قسمت نتایج تشخیص پارکینسون با روش پیشنهادی در طبقه‌بندهای مدنظر در حالت بدون کاهش بعد ارائه شده‌اند. جدول (۴) نتایج حاصل از معیار صحت و همچنین دقت را در ترکیب سری ویژگی‌های حوزه فرکانس (SPV) و حوزه زمان (SWLNGP+CSP) قبل از اعمال کاهش بعد نشان می‌دهد.

بر اساس نتایج به‌دست‌آمده، مقدار صحت طبقه‌بند SVM با کرنل RBF در مقایسه با سایر روش‌ها در ویژگی‌های مبتنی بر ترکیب سری ویژگی‌ها دارای مقدار بهتری است. این برتری در معیار دقت نیز درک می‌شود. RF نیز نتایج مناسبی در مقایسه با سایر طبقه‌بندهای بررسی شده نشان می‌دهد؛ اما به دلیل ضعف موجود در تعمیم مدل پیش‌بینی در طبقه‌بندی نسبت به SVM نتایج ضعیف‌تری را ارائه داده است. برتری روش SVM را می‌توان به قابلیت تعمیم و همچنین ترسیم و طراحی ابرصفحه جداکننده در طبقه‌بند و استفاده بهینه از آنها در ویژگی‌های مبتنی بر ترکیب سری بدون انتخاب ویژگی در روش پیشنهادی بیان کرد. گفتنی است در معیار دقت، در میان هر سه طبقه‌بند، طبقه‌بند ماشین بردار پشتیبان نتایج بهتری را نشان می‌دهد.

مبتنی بر حوزه زمان، ویژگی‌های حوزه فرکانس و ترکیب سری ویژگی‌های حوزه فرکانس و حوزه زمان پس از کاهش بعد با بهینه‌سازی گرگ خاکستری هوشمند را نشان می‌دهد. بر اساس نتایج به‌دست‌آمده در این حالت مانند بدون کاهش بعد، مقدار صحت طبقه‌بند SVM در مقایسه با سایر روش‌ها در ویژگی‌های انتخاب‌شده توسط الگوریتم بهینه‌سازی گرگ خاکستری هوشمند پیشنهادی دارای مقدار بهتری است.

نتایج به‌دست‌آمده در طبقه‌بند RF نیز مانند حالت قبلی خودش نسبت به حالت بدون انتخاب ویژگی برتر است. طبقه‌بند KNN نیز در حالت انتخاب ویژگی نتایج بهتری نسبت به حالت بدون انتخاب ویژگی تعیین کرده است. از مقایسه نتایج به‌دست‌آمده، مشاهده می‌شود طبقه‌بند SVM دارای بهترین نتیجه است و سپس KNN و در نهایت، RF قرار دارد.

جدول (۴): صحت تشخیص پارکینسون با ترکیب سری ویژگی‌های حوزه زمان و حوزه فرکانس قبل از انتخاب ویژگی

معیار	طبقه‌بند	
	دقت	صحت
k نزدیک‌ترین همسایگی	۹۳/۰۱	۹۳/۴۷
جنگل تصادفی	۹۰/۸۹	۹۱/۰۵
ماشین بردار پشتیبان	۹۴/۱۱	۹۵/۱۴

### ۵-۲- ارزیابی به همراه کاهش بعد

در این قسمت نتایج روش انتخاب ویژگی مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری هوشمند با هدف کاهش ابعاد ویژگی‌ها و بهبود صحت تشخیص بیماری پارکینسون ارائه شده‌اند. به صورت مشابه، جدول (۵) معیار ارزیابی صحت در سه طبقه‌بند مدنظر در انتخاب ویژگی‌های

جدول (۵): صحت و دقت تشخیص پارکینسون پس از انتخاب ویژگی

معیار	طبقه‌بند	
	دقت	صحت
k نزدیک‌ترین همسایگی	۹۶/۳۱	۹۷/۱۲
جنگل تصادفی	۹۴/۹۹	۹۵/۱۹
ماشین بردار پشتیبان	۹۷/۱۹	۹۷/۵۰

بهتری نسبت به سایرین داشته است. پس از آن، روش KNN نسبت به دیگر طبقه‌بندها نتایج بهتری داشته است. روش RF نتایج ضعیف‌تری نسبت به دو طبقه‌بند دیگر در تشخیص پارکینسون نشان داده است. روش طبقه‌بند SVM با ثبت صحت تشخیص ۹۷/۵ در حالت انتخاب ویژگی از ترکیب سری، بهترین نتیجه به دست آمده در این مقاله بوده است.

در جدول (۶) مقایسه بین روش پیشنهادی با چند روش مرتبط آمده است.

طبقه‌بند SVM پس از کاهش بعد، نتایج بهتری در مقایسه با سایر روش‌های طبقه‌بندی کسب کرده است. با کاهش بعد نتایج به دست آمده به مراتب بهتر از عدم کاهش بعد است. در معیار دقت، این برتری مانند صحت برای طبقه‌بند ماشین بردار پشتیبان است. در سایر طبقه‌بندها نیز این معیار پس از کاهش بعد بهبود نشان داده است. انتخاب ویژگی مبتنی بر روش پیشنهادی سبب شده است بردار ویژگی انتخاب قابلیت تفکیک‌پذیری بالایی داشته باشد.

## ۶- نتیجه‌گیری

بیماری پارکینسون یک بیماری پیش‌رونده عصبی و مغزی است و یک اختلال جهانی پیش‌رونده است. در این مقاله سیگنال‌های مغزی EEG جمع‌آوری شده در پایگاه مدنظر تجزیه و تحلیل شدند و یک روش براساس انتخاب ویژگی مبتنی بر یادگیری ماشین برای تشخیص بیماری پارکینسون پیشنهاد شده است. پس از استخراج ویژگی‌های حوزه زمان (SWLNPG+CSP) و ویژگی‌های حوزه فرکانس (SPV)، این ویژگی‌ها به کمک الگوریتم گرگ خاکستری هوشمند کاهش بعد داده شده‌اند. سپس به کمک انواع طبقه‌بند دسته‌بندی صورت گرفت و معیار فاصله و کرنل مختلف به آنها اعمال شده است. معیار صحت و دقت برای ارزیابی عملکرد روش پیشنهادی استفاده شده است. براساس نتایج طبقه‌بند SVM با کاهش بعد روی ترکیب ویژگی‌ها، نتایج به مراتب بهتری نسبت به سایر طبقه‌بندهای مدنظر مانند k نزدیک‌ترین همسایگی داشته است. صحت تشخیص پارکینسون در روش پیشنهادی، در حالت انتخاب ویژگی نسبت به حالت بدون انتخاب ویژگی بهبود داشته است. ویژگی‌های مبتنی بر حوزه زمان (SWLNPG+CSP) نتایج بهتری نسبت به ویژگی‌های حوزه فرکانس (SPV) در حالت انتخاب ویژگی و بدون انتخاب ویژگی داشته‌اند.

ترکیب سری ویژگی‌ها، هم در حالت انتخاب ویژگی و هم بدون انتخاب ویژگی، نتایج به مراتب بهتری نسبت به ویژگی‌های تکی از خود نشان داده است. در مقایسه طبقه‌بندهای بررسی شده، طبقه‌بند SVM نتایج به مراتب

جدول (۶): مقایسه روش پیشنهادی با چند روش دیگر

مرجع	روش مطالعه	نتایج
[۵۴]	یک سیستم ترکیبی با استفاده از GMM برای وزن‌دهی ویژگی‌ها، روش PCA و LDA برای کاهش بعد و روش SBS و SFS برای انتخاب ویژگی و سه طبقه‌بندی‌کننده نظارت‌شده LS-SVM و PNN و GRNN	پیش‌بینی صحت روش ۹۵ درصد است؛ اما هزینه پردازش آن بسیار بالا است.
[۵۵]	چند الگوریتم الهام‌گرفته از طبیعت	بیشترین دقت روش‌های FPA و BA برابر ۹۳ درصد است.
[۵۶]	روش تشخیصی هیبریدی (پروانه‌ای) با نام RF+BFO+SVM	از BFO+SVM روش‌های PSO+SVM و Grid+SVM بهتر عمل کرده است. صحت روش BFO+SVM برابر با ۹۳/۴۲ محاسبه شده است.
روش پیشنهادی	روش الگوریتم گرگ خاکستری هوشمند با ۳ طبقه‌بند SVM و KNN و RF	روش طبقه‌بند SVM با ثبت صحت تشخیص ۹۷/۵ در حالت انتخاب ویژگی از ترکیب سری، بهترین نتیجه به دست آمده در این مقاله بوده است.

## مراجع

- disease: A systematic review", *Applied Sciences*, Vol. 12, No. 14, p. 6967, 2022, <https://doi.org/10.3390/app12146967>.
- [12] H.U. Amin, A.S. Malik, R.F. Ahmad, N. Badruddin, N. Kamel, M. Hussain, W. T. Chooi, "Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques", *Australasian Physical and Engineering Sciences in Medicine*, Vol. 38, pp. 139-149, 2015, <https://doi.org/10.1007/s13246-015-0333-x>.
- [13] R. Hamzehyan, F. Razzazi, A. Behrad, "Printer forensics based on identity vectors of image texture segmentation", *Journal of Intelligent Procedures in Electrical Technology*, Vol. 13, No. 49, pp. 67-82, 2022, <https://dor.org/20.1001.1.23223871.1401.13.49.5.4>.
- [14] N. Talebi, A.M. Nasrabadi, I. Mohammad-Rezazadeh, R. Coben, "nCREANN: Nonlinear causal relationship estimation by artificial neural network; applied for autism connectivity study", *IEEE Trans. on Medical Imaging*, Vol. 38, No. 12, pp. 2883-2890, 2019, <https://doi.org/10.1109/TMI.2019.2916233>.
- [15] L. Parisi, N. RaviChandran, M.L. Manaog, "Feature-driven machine learning to improve early diagnosis of Parkinson's disease", *Expert Systems with Applications*, Vol. 110, pp. 182-190, 2018, <https://doi.org/10.1016/j.eswa.2018.06.003>
- [16] P. Chawla, S. B. Rana, H. Kaur, K. Singh, R. Yuvaraj, and M. Murugappan, "A decision support system for automated diagnosis of Parkinson's disease from EEG using FAWT and entropy features," *Biomedical Signal Processing and Control*, Vol. 79, p. 104116, 2023, <https://doi.org/10.1016/j.bspc.2022.104116>.
- [17] R. Lamba, T. Gulati, and A. Jain, "A Hybrid Feature Selection Approach for Parkinson's Disease Detection Based on Mutual Information Gain and Recursive Feature Elimination," *Arabian Journal for Science and Engineering*, pp. 1-14, 2022, <https://doi.org/10.1007/s13369-021-06544-0>.
- [18] A. P. S. de Oliveira, M. A. de Santana, M. K. S. Andrade, J. C. Gomes, M. C. Rodrigues, and W. P. dos Santos, "Early diagnosis of Parkinson's disease using EEG, machine learning and partial directed coherence," *Research on Biomedical Engineering*, Vol. 36, No. 3, pp. 311-331, 2020, <https://doi.org/10.1007/s42600-020-00072-w>.
- [19] H. Byeon, "Is the Random Forest Algorithm Suitable for Predicting Parkinson's Disease with Mild Cognitive Impairment out of Parkinson's Disease with Normal Cognition?", *International Journal of Environmental Research and Public Health*, Vol. 17, No. 7, Article Number: 2594, 2020, <https://doi.org/10.3390/2Fijerph17072594>
- [20] M. F. Anjum, S. Dasgupta, R. Mudumbai, A. Singh, J. F. Cavanagh, and N. S. Narayanan, "Linear predictive coding distinguishes spectral EEG features of Parkinson's disease," *Parkinsonism and Related Disorders*, Vol. 79, pp. 79-85, 2020,
- [1] L. Baghai-Ravary, S.W. Beet, "Automatic speech signal analysis for clinical diagnosis and assessment of speech disorders", *Springer Science and Business Media*, 2012, <https://doi.org/10.1007/978-1-4614-4574-6>.
- [2] L.J. Dommershuijsen, A. Heshmatollah, S.K.L. Darweesh, P.J. Koudstaal, M.A. Ikram, M.K. Ikram, "Life expectancy of parkinsonism patients in the general population", *Parkinsonism and Related Disorders*, Vol. 77, pp. 94-99, 2020, <https://doi.org/10.1016/j.parkreldis.2020.06.018>.
- [3] F. Khudaei, H.R. Taheri, M. Sohrobi, M.S. Zare, "The effects of attentional instructions and exercise with resistance socks on the static and dynamic balance of parkinson's patients", *Salmand: Iranian Journal of Ageing*, Vol. 15, No. 1, pp. 68-81, 2020, <http://dx.doi.org/10.32598/sija.13.10.430>.
- [4] S. Aich, M. Sain, J. Park, K.-W. Choi, and H.-C. Kim, "A mixed classification approach for the prediction of Parkinson's disease using nonlinear feature selection technique based on the voice recording", *Proceeding of the IEEE/ICICI*, pp. 959-962, 2017, <https://doi.org/10.1109/ICICI.2017.8365279>.
- [5] M. Ciocca, B.M. Seemungal, Y.F. Tai, "Spinal Cord Stimulation for Gait Disorders in Parkinson's Disease and Atypical Parkinsonism: A Systematic Review of Preclinical and Clinical Data", *Neuromodulation: Technology at the Neural Interface*, Vol. 26, No. 7, pp. 1339-1361, 2023, <https://doi.org/10.3233/JPD-223284>.
- [6] M. Dorvashi, N. Behzadfar, G. Shahgholian, "Electroencephalogram signal during neurofeedback training", *Signal and Data Processing*, Vol. 19, No. 3, pp. 163-174, 2022, <http://dx.doi.org/10.52547/jsdp.19.3.163>.
- [7] S. Karimi-Shahraki, M. Khezri, "Identification of attention deficit Hyperactivity disorder patients using wavelet-based features of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, Vol. 12, No. 47, pp. 1-11, 2021, <https://doi.org/20.1001.1.23223871.1400.12.3.1>.
- [8] K.Z. Mao, "Orthogonal forward selection and backward elimination algorithms for feature subset selection", *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 34, No. 1, pp. 629-634, 2004, <https://doi.org/10.1109/TSMCB.2002.804363>.
- [9] S. Singh, W. Xu, "Robust detection of parkinson's disease using harvested smartphone voice data: A telemedicine approach", *Telemedicine and e-Health*, Vol. 26, No. 3, pp. 327-334, 2020, <https://doi.org/10.1089/tmj.2018.0271>.
- [10] K. Saranya, M. Paulraj, M. Brindha, "A survey on feature selection and classification techniques for EEG signal processing", *Proceedings of the Springer/ICDLCI*, pp. 155-165, 2022, <https://doi.org/10.1007/978>.
- [11] A.M. Maitin, J.P. Romero Muñoz, Á.J. García-Tejedor, "Survey of machine learning techniques in the analysis of EEG signals for parkinson's

- [31] S. Liang, W. Hang, M. Yin, H. Shen, Q. Wang, J. Qin, K.S. Choi, Y. Zhang, "Deep EEG feature learning via stacking common spatial pattern and support matrix machine", *Biomedical Signal Processing and Control*, Vol. 74, Article Number: 103531, 2022, <https://doi.org/10.1016/j.bspc.2022.103531>.
- [32] S. Hatamikia, A.M. Nasrabadi, "Subject transfer BCI based on composite local temporal correlation common spatial pattern", *Computers in Biology and Medicine*, Vol. 64, pp. 1-11, 2015, <https://doi.org/10.1016/j.compbimed.2015.06.001>.
- [33] Q. Wei and X. Ding, "Intra- and inter-subject common spatial pattern for reducing calibration effort in mi-based BCI", *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, Vol. 31, pp. 904-916, 2023, <https://doi.org/10.1109/tnsre.2023.3236372>.
- [34] Y.E. Karabacak, N/G. Özmen, "Common spatial pattern-based feature extraction and worm gear fault detection through vibration and acoustic measurements", *Measurement*, Vol. 187, Article Number: 110366, 2022, <https://doi.org/10.1016/j.measurement.2021.110366>.
- [35] T. Tuncer, S. Dogan, U.R. Acharya, "Automated EEG signal classification using chaotic local binary pattern", *Expert Systems with Applications*, Vol. 182, Article Number: 115175, 2021, <https://doi.org/10.1016/j.eswa.2021.115175>.
- [36] A.K. Tiwari, R.B. Pachori, V. Kanhangad, B.K. Panigrahi, "Automated diagnosis of epilepsy using key-point-based local binary pattern of EEG signals", *IEEE Journal of Biomedical and Health Informatics*, Vol. 21, No. 4, pp. 888-896, 2017, <https://doi.org/10.1109/JBHI.2016.2589971>.
- [37] H. Pei, S. Yanqing, T. Chaowei, Z. Siman, "Center-symmetric local binary pattern based on weighted neighbor contribution", *Optik*, Vol. 127, No. 23, pp. 11599-11606, 2016, <https://doi.org/10.1016/j.ijleo.2016.09.040>.
- [38] N.J. Sairamya, M.S.P. Subathra, S.T. George, "EEG-based classification of normal and seizure types using relaxed local neighbour difference pattern and artificial neural network", *Knowledge-Based Systems*, Vol. 249, Article Number: 108508, 2022, <https://doi.org/10.1016/j.knosys.2022.108508>.
- [39] M. Yazid et al., "Simple detection of epilepsy from EEG signal using local binary pattern transition histogram", *IEEE Access*, Vol. 9, pp. 150252-150267, 2021, <https://doi.org/10.1109/ACCESS.2021.3126065>.
- [40] S. J. Priya, A. J. Rani, M. Subathra, M. A. Mohammed, R. Damaševičius, and N. Ubendran, "Local pattern transformation based feature extraction for recognition of Parkinson's disease based on gait signals," *Diagnostics*, Vol. 11, No. 8, p. 1395, 2021, <https://doi.org/10.3390/diagnostics11081395>.
- [41] M. Afrozeh, H.R. Abdolmohammadi, M.E. Nazari, "Apply a mutation in gray wolf optimization algorithm to solve the economic-environmental dispatch problem of integrated power plants including thermal and wind", *Journal of Energy Conversion*, Vol. 42, No. 1, pp. 1-10, 2021, <https://doi.org/10.1016/j.parkreldis.2020.08.001>.
- [21] D. Kaya, "The mRMR-CNN based influential support decision system approach to classify EEG signals", *Measurement*, Vol. 156, Article Number: 107602, 2020, <https://doi.org/10.1016/j.measurement.2020.107602>.
- [22] A. A. Bhurane, S. Dhok, M. Sharma, R. Yuvaraj, M. Murugappan, and U. R. Acharya, "Diagnosis of Parkinson's disease from electroencephalography signals using linear and self-similarity features," *Expert Systems*, p. e12472, 2019, <https://doi.org/10.1111/exsy.12472>.
- [23] S.-H. Wang, Y.-D. Zhang, M. Yang, B. Liu, J. Ramirez, and J. M. Gorriz, "Unilateral sensorineural hearing loss identification based on double-density dual-tree complex wavelet transform and multinomial logistic regression," *Integrated Computer-Aided Engineering*, Vol. 26, No. 4, pp. 411-426, 2019, <https://doi.org/10.3233/ICA-190605>.
- [24] M. C. Biagioni, K. Sharma, H. A. Migdadi, and A. Cucca, "Non-invasive neuromodulation therapies for Parkinson's disease," in *Parkinson's Disease-Understanding Pathophysiology and Developing Therapeutic Strategies: IntechOpen*, 2018, <https://doi.org/10.5772/intechopen.75052>.
- [25] A. Benba, A. Jilbab, and A. Hammouch, "Discriminating between patients with Parkinson's and neurological diseases using cepstral analysis", *IEEE transactions on neural systems and rehabilitation engineering*, Vol. 24, No. 10, pp. 1100-1108, 2016, <https://doi.org/10.1109/TNSRE.2016.2533582>.
- [26] R. Jain, D. Gupta, A. Khanna, "Usability feature optimization using MWOA", *Proceeding of the ICICC*, pp. 453-462, 2019, [https://doi.org/10.1007/978-981-13-2354-6\\_47](https://doi.org/10.1007/978-981-13-2354-6_47).
- [27] S. Mahendru, S. Agarwal, "Feature selection using Metaheuristic algorithms on medical datasets", *Harmony Search and Nature Inspired Optimization Algorithms: Springer*, pp. 923-937, 2019, [https://doi.org/10.1007/978-981-13-0761-4\\_87](https://doi.org/10.1007/978-981-13-0761-4_87).
- [28] R. Parameshwara, S. Narayana, M. Murugappan, R. Subramanian, I. Radwan, and R. Goecke, "Automated Parkinson's Disease Detection and Affective Analysis from Emotional EEG Signals," *arXiv preprint arXiv:2202.12936*, 2022, <https://doi.org/10.48550/arXiv.2202.12936>.
- [29] H. Fan, J. Lyu, Z. Chang, X. He, S. Guo, "Spatial patterns and characteristics of global piracy analyzed using a geographic information system", *Marine Policy*, Vol. 157, Article Number: 105816, 2023, <https://doi.org/10.1016/j.marpol.2023.105816>.
- [30] B. Wang et al., "Common spatial pattern reformulated for regularizations in brain-computer interfaces", *IEEE Trans. on Cybernetics*, Vol. 51, No. 10, pp. 5008-5020, 2021, <https://doi.org/10.1109/TCYB.2020.2982901>.

- <https://doi.org/10.1016/j.brainres.2019.146541>.
- [50] M. R. Yousefi, A. Dehghani, H. Taghaavifar, "Enhancing the accuracy of electroencephalogram based emotion recognition through Long Short-Term Memory recurrent deep neural networks", *Front Hum Neurosci*, Vol. 17, Article Number: 1174104, 2023, <https://doi.org/10.3389%2Ffnhum.2023.1174104>.
- [51] M. Dorvashi, N. Behzadfar, G. Shahgholian, "Classification of alcoholic and non-alcoholic individuals based on frequency and non-frequency features of electroencephalogram signal", *Iranian Journal of Biomedical Engineering*, Vol. 14, No. 2, pp. 121-130, 2020, <http://dx.doi.org/10.22041/ijbme.2020.119841.1551>.
- [52] A. Tobeiha, N. Behzadfar, M.R. Yousefi-Najafabadi, H. Mahdavi-Nasab, G. Shahgholian, "Choosing the distinguishing frequency feature of people addicted to heroin from healthy while resting", *Signal and Data Processing*, Vol. 19, No. 3, pp. 49-64, 2022, <http://dx.doi.org/10.52547/jsdp.19.3.49>.
- [53] M. Dorvashi, N. Behzadfar, G. Shahgholian, "An efficient method for classification of alcoholic and normal electroencephalogram signals based on selection of an appropriate feature", *Journal of Medical Signals and Sensors*, Vol.13, No. 1, pp. 11-20, 2023, [https://doi.org/10.4103/jmss.jmss\\_183\\_21](https://doi.org/10.4103/jmss.jmss_183_21).
- [54] B. M. A. Mohammed, M. Elhoseny, K.H. Abdulkareem, S.A. Mostafa, M.S. Maashi, "A multi-agent feature selection and hybrid classification model for Parkinson's disease diagnosis", *ACM Transactions on Multimedia Computing Communications and Applications*, Vol. 17, No. 2, pp. 1-22, 2021, <https://doi.org/10.1145/3433180>.
- [55] S. Shafiq, S. Ahmed, M. S. Kaiser, M. Mahmud, M. S. Hossain and K. Andersson, "Comprehensive analysis of nature-inspired algorithms for parkinson's disease diagnosis", *IEEE Access*, Vol. 11, pp. 1629-1653, 2023, <https://doi.org/10.1109/ACCESS.2022.3232292>.
- [56] Upadhyaya, S. Sachin, A. Tripathi, R. Jain, "Comparative analysis of feature selection in epilepsy seizure recognition using cuckoo, gravitational search and bat algorithm", *International Journal of Information Systems and Management Science*, Vol. 1, No. 1, 2018, <https://ssrn.com/abstract=3363832>.
- of Intelligent Procedures in Electrical Technology, Vol. 14, No. 56, pp. 59-76, 2024, <https://sid.ir/paper/1035023/en>.
- [42] M.H. Nadimi-Shahraki, S. Taghian, S. Mirjalili, "An improved grey wolf optimizer for solving engineering problems", *Expert Systems with Applications*, Vol. 166, Article Number: 113917, 2021, <https://doi.org/10.1016/j.eswa.2020.113917>.
- [43] H. Zhou, X. Wu, Y. Li, Z. Fan, W. Chen, J. Mao, P. Deng, T. Wik, "Model optimization of a high-power commercial PEMFC system via an improved grey wolf optimization method", *Fuel*, Vol. 357, Article Number: 129589, 2024, <https://doi.org/10.1016/j.fuel.2023.129589>.
- [44] M. R. Yousefi, A. Dehghani, S. Golnejad, M. M. Hosseini, "Comparing EEG-Based Epilepsy Diagnosis Using Neural Networks and Wavelet Transform", *Applied Sciences*, Vol. 13, Article Number: 10412, 2023, <https://doi.org/10.3390/app131810412>.
- [45] B.O. Olcay, F. Onay, G.A. Öztürk, A. Öniz, M. Özgören, T. Hummel, Ç. Güdücü, "Using chemosensory-induced EEG signals to identify patients with de novo Parkinson's disease", *Biomedical Signal Processing and Control*, Vol. 87, Article Number: 105438, 2024, <https://doi.org/10.1016/j.bspc.2023.105438>.
- [46] M. Jafari, A. Shoeibi, M. Khodatars, S. Bagherzadeh, A. Shalhaf, D.L. García, J.M. Gorriz, U.R. Acharya, "Emotion recognition in EEG signals using deep learning methods: A review", *Computers in Biology and Medicine*, Vol. 165, Article Number: 107450, 2023, <https://doi.org/10.1016/j.compbimed.2023.107450>
- [47] F. Lotte et al., "A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update," *Journal of neural engineering*, Vol. 15, No. 3, p. 031005, 2018, <https://doi.org/10.1088/1741-2552/aab2f2>.
- [48] P. He, M. Kahle, G. Wilson, and C. Russell, "Removal of ocular artifacts from EEG: A comparison of adaptive filtering method and regression method using simulated data", *Proceeding if the IEEE/IEMBS*, pp. 1110-1113, 2006, <https://doi.org/10.1109/iembs.2005.1616614>.
- [49] D. R. Brown, S. P. Richardson, and J. F. Cavanagh, "An EEG marker of reward processing is diminished in Parkinson's disease," *Brain Research*, Vol. 1727, p. 146541, 2020,

---

<sup>1</sup> World health organization

<sup>2</sup> Electroencephalography

<sup>3</sup> Machine learning

<sup>4</sup> Flexible analytic wavelet transform

<sup>5</sup> Analysis of variance

<sup>6</sup> Mutual information gain and recursive feature elimination

- 7 Partial directed
- 8 Minimum redundancy maximum relevance
- 9 Support vector machine
- 10 Metaheuristic algorithm
- 11 Symmetrically weighted local neighbor gradient pattern
- 12 Spectral power vector
- 13 Common spatial patterns
- 14 Local binary pattern
- 15 Dimension learning-based hunting
- 16 Beck Depression Inventory
- 17 Mini mental state exam
- 18 North American adult reading test
- 19 United Parkinson's disease rating scale
- 20 L-Dopa equivalence dose
- 21 Radial bias function
- 22 Melty layer perceptron
- 23 Quadratic