

## Parkinson's Disease Detection Using EEG Signals Analysis Based on Walsh Hadamard Transform

Yasamin Ezazi<sup>1</sup>, Peyvand Ghaderyan<sup>2\*</sup>

1. Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran. [ya\\_ezazi98@sut.ac.ir](mailto:ya_ezazi98@sut.ac.ir)
2. Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran. (*Corresponding Author*)  
[p\\_ghaderyan@sut.ac.ir](mailto:p_ghaderyan@sut.ac.ir)

### Abstract

**Background:** Parkinson's disease (PD) is one of the most important diseases of the nervous system that occurs due to the degeneration of dopaminergic neurons in the substantia nigra. Because of increasing prevalence rate, lack of specific treatment, and aggravation symptoms over time, PD detection is very important for the optimal control of patients' life. Therefore, the development of non-invasive, low-cost and reliable clinical diagnostic methods play an essential role to help doctors in diagnosis, slowing progressions of the disease and providing better control strategies to improve the quality of patients' life. Among diagnostic methods, recording and analyzing the electroencephalogram (EEG) signal as a low-cost and non-invasive approach has attracted a lot of attention.

**Method:** EEG signal analysis in the time domain contains important information, but does not include the frequency information. Hence, this study is based on extracting new frequency features from the EEG signal using Walsh-Hadamard transform (WHT). WHT converts the signal from the time domain into the frequency domain and decompose it into orthogonal and rectangular waves. In this method, after calculating the Walsh coefficients, a set of features such as entropy, impulsive metrics, basic and high-order statistical features have been extracted from these coefficients. Subsequently, the discriminating capability of the presented method has been assessed using two classifiers namely support vector machine and k-nearest neighbor to classify PD patients from the healthy group.

**Results:** The proposed method has been evaluated using the EEG signals of 28 healthy individuals and 28 patients with PD in two medication states (ON and OFF) during the reinforcement learning task. The obtained results have shown that this method is able to detect PD by using the entropy feature, support vector machine, and k nearest neighbor with acceptable accuracy of 99.95% and 99.98%, respectively. The good performance of entropy feature in comparison of other ones can be attributed to non-linear and non-stationary nature of EEG signal.

**Conclusion:** In this study, a non-invasive, low-cost, and reliable method for PD detection using EEG signal analysis has been proposed. This algorithm is a multi-stage technique with a feature extraction approach based on WHT, entropy feature, and support vector machine and k-nearest neighbor classifiers. The reported results indicate that this method is effective in PD detection while being simple and easy, as well as being robust to the clinical factor of medication status.

سال دوم، تابستان ۱۴۰۰  
شماره دوم، صص: ۱ - ۸

تاریخ دریافت: ۱۳۹۹/۱۲/۰۲  
تاریخ پذیرش: ۱۴۰۰/۰۲/۲۵

## تشخیص بیماری پارکینسون با استفاده از تحلیل سیگنال‌های الکتروانسفالوگرام مبتنی بر تبدیل والش هادامارد

یاسمین اعزازی<sup>۱</sup>، پیوند قادریان<sup>۲\*</sup>

۱. دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران. ya\_ezazi98@sut.ac.ir

۲. دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران. (نویسنده مسئول) p\_ghaderyan@sut.ac.ir

**چکیده:** بیماری پارکینسون یکی از مهم‌ترین بیماری‌های سیستم عصبی است که به دلیل انحطاط نورون‌های دوپامینرژیک در جسم سیاه مغز رخ می‌دهد. از آنجاکه این بیماری درمان قطعی ندارد، بنابراین تشخیص کلینیکی و به‌موقع آن می‌تواند نقش اساسی در کندکردن سیر پیشرفت بیماری و ارائه راهکارهای کنترلی برای بهبود کیفیت زندگی بیماران ایفا کند. در این مطالعه از تحلیل سیگنال الکتروانسفالوگرام به‌عنوان یک مشخصه کم‌هزینه، غیرتهاجمی و قابل‌اعتماد برای تشخیص استفاده شده است. روش پیشنهادی بر مبنای استخراج اطلاعات فرکانسی سیگنال به کمک تبدیل والش و محاسبه مجموعه‌ای از ویژگی‌ها مانند آنتروپی، معیارهای تکانش، ویژگی‌های آماری پایه و مرتبه بالا از ضرایب استخراج شده است. سپس، برای ارزیابی قدرت تفکیکی روش ارائه شده، از ماشین بردار پشتیبان و  $k$  نزدیک‌ترین همسایگی به‌منظور تفکیک بیماران از گروه سالم استفاده شده است. قابلیت تشخیص روش با استفاده از داده‌های الکتروانسفالوگرام ۲۸ فرد سالم و ۲۸ بیمار مبتلا به پارکینسون در حین انجام تکلیف یادگیری-تقویتی مورد ارزیابی قرار گرفته است. نتایج به دست آمده نشان داده‌اند که روش پیشنهادی قادر است با استفاده از ویژگی آنتروپی، ماشین بردار پشتیبان و  $k$  نزدیک‌ترین همسایگی بیماری پارکینسون را به ترتیب با صحت بالای ۹۹/۹۵٪ و ۹۹/۹۸٪ تشخیص دهد.

**واژه‌های کلیدی:** بیماری پارکینسون، تکلیف یادگیری-تقویتی، تبدیل والش هادامارد،  $k$  نزدیک‌ترین همسایگی، ماشین بردار پشتیبان.

## ۱. مقدمه

براساس گزارش سازمان جهانی بهداشت، تا سال ۲۰۵۰ حدود ۱/۵ میلیارد سالمند در جهان زندگی خواهند کرد که این افزایش سن جمعیت می‌تواند منجر به رشد سریع بیماری‌های مزمن و حاد بیماران کهنسال شود [۱]. این بیماری‌ها و اثرات آن‌ها می‌توانند زندگی بیماران را به شدت تحت تأثیر قرار داده و هزینه‌های سنگینی بر جامعه و فرد تحمیل کنند. بنابراین، ارائه روش‌های تشخیصی مناسب می‌تواند کمک شایانی به پزشکان در تشخیص، کند نمودن پیشرفت بیماری و کنترل بهتر آن نمایند [۲]. تاکنون روش‌های تشخیصی متنوعی مانند تصویربرداری‌های مغزی و آزمایشات تشخیصی ارائه شده است [۳] که هزینه بالا، تهاجمی بودن، زمان بر بودن و محدودیت در دوز تابشی روش‌های تصویربرداری کاربرد آن‌ها را محدودتر کرده است [۳]. در این بین، روش‌های ثبت و تحلیل سیگنال‌های فیزیولوژیکی مانند سیگنال الکتروانسفالوگرام یکی از روش‌های غیرتهاجمی و کم‌هزینه با قابلیت تکرار بالا است [۴] که فعالیت الکتریکی سلول‌های عصبی قشر مغز را ثبت نموده و دانشی از ساختار عمیق مغز در اختیار قرار می‌دهد [۴]. این دانش، امکان ایجاد روش‌های مبتنی بر محاسبات جدید را برای ایجاد بینش در مورد پاتوفیزیولوژی و الکتروفیزیولوژی اختلالات مغزی مانند بیماری پارکینسون فراهم می‌کند که می‌تواند در درمان و تشخیص پزشکی مناسب باشد [۴].

بیماری پارکینسون یک بیماری شایع و پیش‌رونده سیستم عصبی است که براساس آمار گزارش شده، شیوع آن ۱-۲ نفر در هر ۱۰۰۰ نفر است [۵، ۶]. این بیماری به دلیل انحطاط نورون‌های دوپامینرژیک در جسم سیاه مغز رخ می‌دهد [۷]. با انحطاط تدریجی این نورون‌ها و کاهش سطح دوپامین در شکاف سیناپسی فعالیت مغز تغییر می‌کند و علائم حرکتی و غیر حرکتی بیماری به تدریج ظاهر می‌شود [۸]. علائم حرکتی در ابتدا در یک سمت بدن ظاهر می‌شود و به تدریج هر دو سمت بدن را درگیر می‌کند [۸]. نظر به اینکه بیماری پارکینسون درمان مشخص ندارد، میزان شیوع آن با افزایش سن افزایش می‌یابد و علائم در گذر زمان شدیدتر می‌شود [۸]، بنابراین تشخیص این بیماری با تحلیل سیگنال الکتروانسفالوگرام به عنوان یک مشخصه غیرتهاجمی و کم‌هزینه از اهمیت بالایی برخوردار است. تاکنون محققان تلاش‌های زیادی در زمینه استخراج ویژگی‌های مختلف از این سیگنال برای تحلیل و استخراج

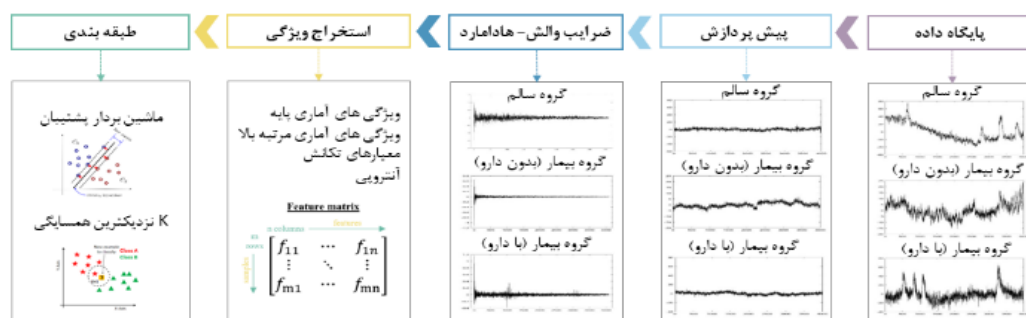
اطلاعات نهفته به منظور تشخیص بیماری پارکینسون انجام داده‌اند [۳]. ویژگی‌های استخراج شده در مطالعات قبلی را می‌توان در دو گروه ویژگی‌های خطی از جمله طیف توان [۹، ۱۰] و ویژگی‌های غیرخطی از جمله آنتروپی [۱۰، ۱۱]، نمای لیاپانوف [۱۱، ۱۲] و بعد فراکتال [۱۱] طبقه‌بندی کرد.

هدف اصلی مطالعه حاضر، ارائه یک روش قابل اعتماد، آسان و سریع برای تشخیص بیماری پارکینسون براساس استخراج ویژگی‌های جدید فرکانسی از سیگنال الکتروانسفالوگرام است. بدین منظور، روش پیشنهادی مبتنی بر تبدیل والش هادامارد است که همچون تبدیل فوریه یک روش بررسی در حوزه فرکانس است [۱۳]. مزایای این تبدیل، محاسبه سریع ضرایب، نیاز به فضای کم ذخیره‌سازی ضرایب و بازسازی سریع سیگنال در مقایسه با تبدیل فوریه است [۱۴]. زیرا تبدیل والش از عملیات ساده جمع و تفریق اعداد حقیقی استفاده می‌کند، در حالی که تبدیل فوریه از اعداد مختلط در محاسبات استفاده می‌کند [۱۵]. همچنین با استفاده از این تبدیل می‌توان بر مشکلات تداخل<sup>۲</sup> مانند اعوجاج<sup>۳</sup> و نشت<sup>۴</sup> که ممکن است در تبدیل فوریه به وجود آید، غلبه کرد [۱۴]. اهداف دیگر این مطالعه، مقایسه قدرت تفکیکی دسته‌های مختلفی از ویژگی‌های آماری مستخرج از ضرایب فرکانسی و بررسی تأثیر مصرف دارو در قدرت تشخیصی الگوریتم ارائه شده است. با توجه به مزایا و دلایل ذکر شده و اهداف مطالعه، این روش در کنار سایر روش‌های یادگیری ماشین بررسی شده است.

ساختار کلی مقاله در ادامه بدین شرح است: پایگاه داده مورد استفاده، پیش‌پردازش داده‌گان، استخراج ویژگی و طبقه‌بندی در بخش ۲ تحت عنوان مواد و روش‌ها معرفی شده است. در بخش ۳ نتایج حاصل از پیاده‌سازی الگوریتم پیشنهادی گزارش شده است. جمع‌بندی کلی در بخش ۴ صورت گرفته است.

## ۲. مواد و روش‌ها

بلوک دیاگرام روش پیشنهادی با هدف تشخیص بیماری پارکینسون در شکل ۱ نشان داده شده است. مطابق با آن، الگوریتم از مراحل مختلفی شکل گرفته است که عبارتند از: پایگاه داده، پیش‌پردازش، اعمال تبدیل والش، استخراج ویژگی و طبقه‌بندی. هر یک از مراحل در زیر بخش‌های مربوطه به تفصیل بیان شده است.



شکل ۱: بلوک دیاگرام روش پیشنهادی

## ۱.۲. پایگاه داده

در مطالعه حاضر، از داده‌های الکتروانسفالوگرام ۲۸ فرد مبتلا به پارکینسون (۱۷ مرد و ۱۱ زن) و ۲۸ فرد سالم (۱۷ مرد و ۱۱ زن) که در مطالعه براون و همکاران<sup>۵</sup> در حین انجام تکلیف یادگیری-تقویتی گردآوری شده، استفاده شده است [۱۶]. افراد مبتلا به پارکینسون دو بار با فاصله زمانی هفت روز به آزمایشگاه مراجعه کردند: یکبار با مصرف نسخه‌های دارویی دوپامینرژیک برای درمان بیماری و یکبار بدون مصرف دارو (ثبت داده، پس از ۱۵ ساعت از مصرف آخرین دارو بوده است) [۱۶]. به همین دلیل داده‌های بیماران دو بار ثبت شده است. داده‌های الکتروفیزیولوژی با ۶۴ الکتروود نقره-نقره کلرید تعبیه شده در یک کلاهک کشتی، با نرخ نمونه برداری ۵۰۰ هرتز و با فرکانس‌های قطع ۱۰۰-۰/۰۱ هرتز ثبت شده است [۱۶]. الکتروود CPz به عنوان الکتروود مرجع و الکتروود FPz به عنوان الکتروود زمین دنظر گرفته شده است [۱۶]. همچنین فعالیت الکترواکولوگرام عمودی<sup>۶</sup> ایجاد شده از چشمک زدن، توسط دو الکتروود که بالاتر و پایین تر از مردمک چشم چپ قرار گرفته بودند، ثبت شده است [۱۶].

## ۲.۲. پیش پردازش

در این مرحله جهت حذف نویزها و تداخل‌های موجود در سیگنال، ابتدا الکتروود CPz از طریق محاسبه میانگین مرجع دوباره بازسازی شده است [۱۶]. سپس روش تجزیه و تحلیل مؤلفه‌های مستقل<sup>۷</sup> برای حذف فعالیت‌های چشم اعمال شده است [۱۶]. در انتها، پس از اعمال این روش، ۶۰ کانال بدون نویز و آرتیفکت حاصل شده که به پنجره‌های ۸ ثانیه‌ای بدون همپوشانی برای پردازش‌های بعدی تقسیم بندی شده‌اند.

## ۳.۲. تبدیل والش هادامارد

تبدیل والش تعمیم یافته تبدیل فوریه است که به عنوان یک ابزار در زمینه‌های مختلف کدگذاری تصویر و ویدیو، فشرده سازی داده، ارتباطات، پردازش گفتار و پردازش سیگنال کاربرد دارد [۱۷]. این تبدیل، مشهور به تبدیل متعامد غیرسینوسی است [۱۸] و از سریع ترین تبدیل‌های متعامد شناخته شده تاکنون است [۱۹]. تبدیل والش سیگنال را از حوزه زمان، به صورت نمایش فرکانسی تبدیل می‌کند و آن را به شکل موج‌های مستطیلی و متعامد تجزیه می‌کند [۱۳]. ویژگی این تبدیل این است که سیگنال‌های شامل یک اختلال شدید را دقیق تر شناسایی می‌کند [۱۳]. ضرایب والش حاصل ضرب یک دنباله داده به طول  $N \times N$  و ماتریس والش با ابعاد  $N \times N$  است که با رابطه ریاضی (۱) محاسبه می‌شود [۱۵]:

$$X_w = XW_n \quad (1)$$

در این رابطه  $X$  و  $X_w$  به ترتیب دنباله داده و ضرایب والش است. همچنین  $W_n$  ماتریس والش است که با رابطه (۲) تعریف می‌شود [۱۳]:

$$W_n = \frac{1}{(\sqrt{2})^n} \begin{pmatrix} W_{n-1} & W_{n-1} \\ W_{n-1} & -W_{n-1} \end{pmatrix} \quad (2)$$

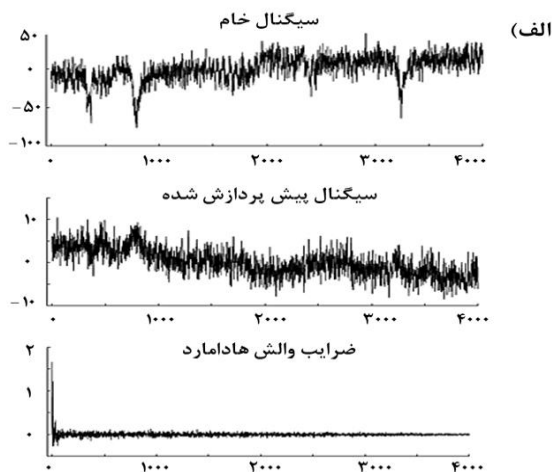
این ماتریس به ازای  $n$  برابر با ۱ و ۲ به ترتیب در روابط (۳) و (۴) بیان شده است:

$$W_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad (3)$$


$$W_2 = \frac{1}{2} \begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & -1 & 1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & -1 & 1 \end{pmatrix} \quad (4)$$

با توجه به اینکه ماتریس والش یک ماتریس مربعی با بعد  $N=2^n$  است، مطابق با رابطه (۱) روی داده‌هایی با طول  $2^n$  کار می‌کند [۱۳]. اگر طول داده کمتر از  $2^n$  باشد، پیش از پردازش طول آن با افزودن صفر تا توان بعدی ۲، پرمی شود [۱۳].

از مزایای تبدیل والش، آسان و سریع بودن در مقایسه با تبدیل فوریه و تبدیل کسینوسی است [۱۹]. زیرا ماتریس والش تنها دارای دو مقدار +۱ و -۱ است و سیگنال به دست آمده بعد از این تبدیل غیرسینوسی است و این ویژگی با انجام عملیات جمع و تفریق به جای ضرب، پیچیدگی پردازش سیگنال را کاهش می‌دهد [۱۹، ۲۰]. شکل ۲ نمونه‌ای از سیگنال خام، پیش پردازش شده و ضرایب والش سه گروه سالم، بیماران بدون دارو و بیماران با مصرف دارو را نشان می‌دهد.



$x_{SF} = \frac{x_{rms}}{\frac{1}{N} \sum_{i=1}^N  x_i }$	ضریب شکل Shape factor
<b>ویژگی‌های آماری مرتبه بالا</b>	
$S = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\sigma^3}$	چولگی Skewness
$K = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4}$	کشیدگی Kurtosis
<b>معیارهای تکانش</b>	
$x_p = \max  x_i $	مقدار اوج Peak value
$x_{crest} = \frac{x_p}{x_{rms}}$	ضریب اوج Crest factor
$x_{IF} = \frac{x_p}{\frac{1}{N} \sum_{i=1}^N  x_i }$	ضریب ضربه Impulse factor
$x_{Clear} = \frac{x_p}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i }\right)^2}$	ضریب آزادی Clearance factor
<b>آنتروپی</b>	
$EN_{Shannon} = \sum_{i=1}^N p_i \log_2 p_i$	آنتروپی شانون Shannon Entropy
$EN_{log\_energy} = \sum_{i=1}^N (S_n)^2$	آنتروپی انرژی لگاریتمی Log energy Entropy



شکل ۲: نمونه سیگنال خام، پیش‌پردازش شده و ضرایب والش هادامارد سه گروه (الف) سالم (ب) بیمار (ج) بیمار با دارو

## ۴.۲. استخراج ویژگی

در این مرحله، مجموعه ویژگی‌ها شامل ویژگی‌های آماری پایه<sup>۸</sup>، ویژگی‌های آماری مرتبه بالا<sup>۹</sup> و معیارهای تکانش<sup>۱۰</sup> از ضرایب والش محاسبه شده است. آنتروپی شانون<sup>۱۱</sup> و آنتروپی انرژی لگاریتمی<sup>۱۲</sup> نیز به عنوان ویژگی غیرخطی و معیاری برای ارزیابی تغییرات و بی‌نظمی این ضرایب استخراج شده است [۲۱]. روابط ویژگی‌های استخراج شده در جدول ۱ تعریف شده است.

جدول ۱: ویژگی‌های استخراج شده از ضرایب والش و روابط آن‌ها

ویژگی‌های آماری پایه	
$\mu = \frac{1}{N} \sum_{i=1}^N x_i$	میانگین Mean
$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$	انحراف معیار Standard deviation
$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	مجذور میانگین مربعات Root mean square

## ۵.۲. طبقه‌بندی

ماشین بردار پشتیبان و k نزدیک‌ترین همسایگی دو الگوریتم با نظارت یادگیری ماشین است که به طور گسترده‌ای در زمینه‌های مختلف برای طبقه‌بندی به کار رفته است.

هدف ماشین بردار پشتیبان یافتن ابر صفحه‌ای در فضای ویژگی است تا نقاط داده برچسب‌دار را به صورت خطی دسته‌بندی کند [۲۲]. در بین چندین ابر صفحه احتمالی برای تفکیک دو کلاس، ابر صفحه‌ای که حداکثر حاشیه بین نقاط داده هر دو کلاس را داشته باشد، بهترین است [۲۲]. به حداکثر رساندن حاشیه باعث می‌شود تا نقاط داده بدون برچسب دقیق‌تر و با اطمینان بیشتری طبقه‌بندی شوند [۲۲]. ماشین بردار پشتیبان برای داده‌هایی با توزیع غیرخطی از یک تابع هسته استفاده می‌کند تا داده‌ها را به فضای ویژگی جدید نگاشت کند که به صورت خطی قابل تفکیک باشند [۲۳]. در این مطالعه از تابع هسته پایه شعاعی استفاده شده است.

مبنای k نزدیک‌ترین همسایگی بر رویکرد فواصل بین داده‌ها است و داده‌های بدون برچسب را بدون یادگیری و صرفاً بر اساس شباهت با

داده‌های برچسب‌دار طبقه‌بندی می‌کند [۲۴]. در این الگوریتم ساده، فاصله داده جدید با داده‌های برچسب‌دار محاسبه می‌شود و سپس،  $k$  داده آموزشی با کم‌ترین فاصله انتخاب می‌شود [۲۴]. برچسب داده جدید برحسب بیشترین رای از بین  $k$  داده تصمیم‌گیری می‌شود [۲۴]. در این مطالعه،  $k = 1$  انتخاب و از فاصله اسپیرمن برای محاسبه فواصل استفاده شده است.

همچنین روش اعتبارسنجی متقابل پنج‌گانه<sup>۱۳</sup> برای اعتبارسنجی نتایج طبقه‌بندی و تقسیم داده‌ها به داده‌های آموزشی (۸۰ درصد داده‌ها) و داده‌های آزمایشی (۲۰ درصد داده‌ها) به کار گرفته شده است. در مرحله نهایی سه شاخص صحت<sup>۱۴</sup>، حساسیت<sup>۱۵</sup> و ویژگی<sup>۱۶</sup> برای ارزیابی طبقه‌بندی‌ها استفاده شده است که به ترتیب با روابط (۵)، (۶) و (۷) قابل محاسبه است [۲۵]:

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

$$Sensitivity = \frac{TP}{TP + FN} \quad (6)$$

$$Specificity = \frac{TN}{TN + FP} \quad (7)$$

اصطلاحات به کاررفته در روابط بالا به صورت زیر تعریف می‌شوند:

- TN: تعداد افراد سالم که به درستی سالم تشخیص داده شده‌اند.
- FP: تعداد افراد سالم که به اشتباه بیمار تشخیص داده شده‌اند.
- FN: تعداد بیمارانی که به اشتباه سالم تشخیص داده شده‌اند.
- TP: تعداد بیمارانی که به درستی بیمار تشخیص داده شده‌اند.


### ۳. ارزیابی و نتایج

هدف از مطالعه حاضر، ارائه یک روش تشخیصی برای بیماری پارکینسون و تفکیک گروه سالم از گروه بیمار با دقت بالا است. بدین منظور، پس از حذف نویز و آرتیفکت سیگنال‌ها، از تبدیل والش برای استخراج اطلاعات فرکانسی استفاده شده است. در ادامه به کمک چهار مجموعه ویژگی‌های آماری و آنتروپی، نحوه توزیع، شکل گسترده‌گی و بی‌نظمی این ضرایب کمی‌سازی شده است و طبقه‌بندی‌های ماشینی بردار پشتیبان و نزدیک‌ترین همسایگی برای ارزیابی قدرت تشخیص الگوریتم پیشنهادی استفاده شده‌اند. نتایج حاصل از پیاده‌سازی الگوریتم در بسته نرم‌افزار MATLAB در جدول ۱

گزارش شده و نمودار گرافیکی در شکل ۳ نشان داده شده است. نتایج ارائه شده، قابلیت روش پیشنهادی در تشخیص بیماری با صحت بالا را نشان داده است. همان‌گونه که مشاهده می‌شود، ویژگی آنتروپی ضرایب والش با صحت بالای ۹۹ درصد قابلیت تشخیص افراد مبتلا به پارکینسون از گروه سالم را فراهم کرده است. همچنین مطابق با جدول، الگوریتم قادر به تفکیک گروه سالم از بیمارانی در دو حالت مصرف دارو و بدون مصرف دارو است و روش پیشنهادی تحت تأثیر دارو قرار نگرفته است.

جدول ۲: نتایج حاصل از طبقه‌بندی

ویژگی‌ها	شاخص ارزیابی	طبقه‌بند / گروه طبقه‌بندی			
		ک نزدیک‌ترین همسایگی / سالم و بیمار (با دارو)	ک نزدیک‌ترین همسایگی / سالم و بیمار (بدون دارو)	ماشین بردار پشتیبان / سالم و بیمار (با دارو)	ماشین بردار پشتیبان / سالم و بیمار (بدون دارو)
آمار پایه					
صحت	۹۱/۶۰	۹۱/۵۶	۸۲/۸۶	۸۲/۲۲	
حساسیت	۹۱/۶۲	۹۱/۶۰	۸۹/۲۴	۹۰/۸۸	
ویژگی	۹۲/۶۰	۹۱/۵۳	۷۶/۲۹	۷۳/۹۰	
آمار مرتبه بالا					
صحت	۸۳/۵۲	۸۳/۷۲	۸۵/۲۵	۸۶/۷۵	
حساسیت	۸۴/۲۰	۸۶/۶۰	۸۸/۳۹	۸۸/۴۰	
ویژگی	۸۲/۸۵	۸۰/۹۶	۸۲/۱۹	۸۵/۱۶	
معیارهای تکانش					
صحت	۸۵/۸۰	۸۵/۹۸	۹۶/۳۵	۹۷/۶۱	
حساسیت	۸۴/۷۰	۸۵/۴۰	۹۶/۴۵	۹۶/۴۵	
ویژگی	۸۶/۸۶	۸۶/۵۳	۹۶/۲۶	۹۸/۷۳	
آنتروپی					
صحت	۹۹/۹۵	۹۹/۹۰	۹۹/۹۸	۹۹/۹۵	
حساسیت	۹۹/۹۱	۹۹/۸۰	۹۶/۲۶	۹۸/۷۳	
ویژگی	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۴	



شکل ۳: نمودار گرافیکی صحت طبقه‌بندی

جدول ۳: مقایسه عملکرد مطالعه حاضر با مطالعات قبلی

نویسندگان	استخراج ویژگی	بهترین طبقه‌بندی	بالاترین صحت
رایلو و همکاران	توان و آنتروپی	رگرسیون منطقی	۸۵/۵
خاره و همکاران	تبدیل موجک Q	ماشین بردار پشتیبان	۹۷/۶۵
یووراج و همکاران	طیف مرتبه بالاتر	ماشین بردار پشتیبان	۹۹/۶۲
روش پیشنهادی	تبدیل والش	k نزدیک‌ترین همسایگی	۹۹/۹۸

#### ۴. نتیجه‌گیری و جمع‌بندی

بیماری پارکینسون یک بیماری پیش‌رونده سیستم عصبی مرکزی است که زندگی بیماران را تحت تأثیر قرار می‌دهد. به همین دلیل ارائه یک روش تشخیصی کارآمد و دقیق در کند کردن سیر پیشرفت بیماری و کمک به درمان حائز اهمیت است. بدین منظور از سیگنال الکتروانسفالوگرام به عنوان یک مشخصه غیرتهاجمی، کم‌هزینه و قابل اعتماد در این مطالعه استفاده شده است. مطالعات نشان داده است، استخراج ویژگی‌ها از حوزه فرکانس سیگنال الکتروانسفالوگرام می‌تواند حاوی اطلاعات مهمی از تأثیرات پاتولوژیک بیماری پارکینسون باشد. بنابراین، الگوریتم پیشنهادی یک طرح چندمرحله‌ای با رویکرد استخراج ویژگی‌های فرکانسی مبتنی بر تبدیل والش و طبقه‌بندی ماشین بردار پشتیبان و k نزدیک‌ترین همسایگی است. مطالعات پیشین در زمینه تشخیص پارکینسون با سیگنال الکتروانسفالوگرام نشان داده است که با توجه به ماهیت غیرخطی و غیرایستا سیگنال الکتروانسفالوگرام، ویژگی‌های غیرخطی نتایج بهتری را ارائه می‌دهد [۲۶]. با توجه به نتایج ذکر شده ویژگی آنتروپی به عنوان یک ویژگی غیرخطی در مقایسه با سایر ویژگی‌ها نتایج بالا و قابل قبولی را ارائه داده است که این مهم را تأیید می‌کند. همچنین با مقایسه نتایج مطالعه حاضر با عملکرد مطالعات قبلی که در جدول ۳ ارائه شده است، می‌توان گفت این روش صحت قابل توجه بالایی ۹۹٫۹ درصد را در عین سریع و آسان بودن، ارائه داده است. در زمینه کارهای آتی، توسعه روش‌هایی برای تشخیص مراحل بیماری، بررسی سیگنال در حوزه زمان- فرکانس، بررسی اثر روش‌های کاهش بعد در صحت طبقه‌بندی و ارزیابی تأثیر کانال‌ها و لوب‌های مغزی در تشخیص بیماری پیشنهاد می‌شود.

#### سپاسگزاری

بر خود فرض می‌دانیم مراتب تشکر صمیمانه‌مان را از ستاد توسعه علوم و فناوری‌های شناختی، که ما را در انجام این پژوهش حمایت و یاری کرده‌اند، اعلام کنیم.

#### مراجع

- [1] 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, pp. 311-331, 2020.
- [2] X. Wang, Y. Zhang, C. Zhu, G. Li, J. Kang, F. Chen, and L. Yang, "The diagnostic value of SNpc using NM-MRI in Parkinson's disease: meta-analysis," *Neurological Sciences*, vol. 40, pp. 2479-2489, 2019.
- [3] A. M. Maitín, A. J. García-Tejedor, and J. P. R. Muñoz, "Machine Learning Approaches for Detecting Parkinson's Disease from EEG Analysis: A Systematic Review," *Applied Sciences*, vol. 10, p. 8662, 2020.
- [4] L. Luu, P. Pham, and T. Q. Le, "Feature Extraction and Electrophysiological Modeling in Personalized Deep Brain Structure Using Electroencephalography

- [19] X. Xiang, J. Zhou, X. An, B. Peng, and J. Yang, "Fault diagnosis based on Walsh transform and support vector machine," *Mechanical Systems and Signal Processing*, vol. 22, pp. 1685-1693, 2008.
- [20] S. Sareen, S. K. Sood, and S. K. Gupta, "An automatic prediction of epileptic seizures using cloud computing and wireless sensor networks," *Journal of medical systems*, vol. 40, pp. 1-18, 2016.
- [21] A. Shoeibi, N. Ghassemi, R. Alizadehsani, M. Rouhani, H. Hosseini-Nejad, A. Khosravi, M. Panahiazar, and S. Nahavandi, "A comprehensive comparison of handcrafted features and convolutional autoencoders for epileptic seizures detection in EEG signals," *Expert Systems with Applications*, vol. 163, p. 113788, 2021.
- [22] D. A. Pisner and D. M. Schnyer, "Support vector machine," in *Machine Learning*, ed: Elsevier, 2020, pp. 101-121.
- [23] S. Abe, *Support vector machines for pattern classification* vol. 2: Springer, 2005.
- [24] P. Cunningham and S. J. Delany, "k-Nearest neighbour classifiers: (with Python examples)," *arXiv preprint arXiv*, 2020, 2004/04523.
- [25] A. Tharwat, "Classification assessment methods," *Applied Computing and Informatics*, 2020.
- [26] S. L. Oh, Y. Hagiwara, U. Raghavendra, R. Yuvaraj, N. Arunkumar, M. Murugappan, and U. R. Acharya, "A deep learning approach for Parkinson's disease diagnosis from EEG signals," *Neural Computing and Applications*, pp. 1-7, 2018.
- [27] S. K. Khare, V. Bajaj, and U. R. Acharya, "PDCNN: An automatic framework for the detection of Parkinson's Disease using EEG signals," *IEEE Sensors Journal*, 2021.
- [28] R. Yuvaraj, U. R. Acharya, and Y. Hagiwara, "A novel Parkinson's Disease Diagnosis Index using higher-order spectra features in EEG signals," *Neural Computing and Applications*, vol. 30, pp. 1225-1235, 2018.
- [5] J. Jankovic, "Parkinson's disease: clinical features and diagnosis," *Journal of neurology, neurosurgery & psychiatry*, vol. 79, pp. 368-376, 2008.
- [6] O.-B. Tysnes and A. Storstein, "Epidemiology of Parkinson's disease," *Journal of Neural Transmission*, vol. 124, pp. 901-905, 2017.
- [7] W. Poewe, K. Seppi, C. M. Tanner, G. M. Halliday, P. Brundin, J. Volkman, A.-E. Schrag, and A. E. Lang, "Parkinson disease," *Nature reviews Disease primers*, vol. 3, pp. 1-21, 2017.
- [8] S. Bhat, U. R. Acharya, Y. Hagiwara, N. Dadmehr, and H. Adeli, "Parkinson's disease: Cause factors, measurable indicators, and early diagnosis," *Computers in biology and medicine*, vol. 102, pp. 234-241, 2018.
- [9] H. Railo, I. Suuronen, V. Kaasinen, M. Murtojarvi, T. Pahikkala, and A. Airola, "Resting state EEG as a biomarker of Parkinson's disease: Influence of measurement conditions," *BioRxiv*, 2020.
- [10] R. Yuvaraj, M. Murugappan, N. M. Ibrahim, K. Sundaraj, M. I. Omar, K. Mohamad, and R. Palaniappan, "Optimal set of EEG features for emotional state classification and trajectory visualization in Parkinson's disease," *International Journal of Psychophysiology*, vol. 94, pp. 482-495, 2014.
- [11] R. Yuvaraj and M. Murugappan, "Hemispheric asymmetry non-linear analysis of EEG during emotional responses from idiopathic Parkinson's disease patients," *Cognitive neurodynamics*, vol. 10, pp. 225-234, 2016.
- [12] A. Saikia, V. Majhi, M. Hussain, A. R. Barua, and S. Paul, "Performance Analysis of various Neural Network functions for Parkinson's disease Classification using EEG and EMG," *EXECUTIVE EDITOR*, vol. 11, p. 541, 2020.
- [13] M. Subathra, M. A. Mohammed, M. S. Maashi, B. Garcia-Zapirain, N. Sairamy, and S. T. George, "Detection of focal and non-focal electroencephalogram signals using fast Walsh-Hadamard transform and artificial neural network," *Sensors*, vol. 20, p. 4952, 2020.
- [14] V. K. Dave, V. Vakharia, and S. Singh, "Ball Bearing Fault Diagnosis Using Mutual Information and Walsh-Hadamard Transform," in *Reliability, Safety and Hazard Assessment for Risk-Based Technologies*, ed: Springer, 2020, pp. 607-616.
- [15] D. Sawant, V. Padwal, J. Joshi, T. Keluskar, R. Lalwani, T. Sharma, and R. Daruwala, "Classification of Motor Imagery EEG Signals using MEMD, CSP, Entropy and Walsh Hadamard Transform," in *2019 IEEE Bombay Section Signature Conference (IBSSC)*, 2019, pp. 1-6.
- [16] 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.
- [17] V. Dave and V. Vakharia, "Fault Diagnosis of Ball Bearing Using Walsh-Hadamard Transform and Random Tree Classifier," *Reliability and Risk Assessment in Engineering*, p. 373, 2020.
- [18] N. Ahmed and K. R. Rao, *Orthogonal transforms for digital signal processing*: Springer Science & Business Media, 2012.

## پی نوشت

1. Walsh Hadamard Transform
2. Aliasing
3. Distortion
4. Leakage
5. Brown et.al
6. Vertical Electrooculogram
7. Independent Component Analysis
8. Basic Statistics
9. Higher Order Statistics
10. Impulsive Metrics
11. Shannon Entropy
12. Log Energy Entropy
13. Five-Fold Cross Validation
14. Accuracy
15. Sensitivity
16. Specificity