

Automatic Detection of Parkinson's Disease Motor Impairment Severity Using a Hierarchical Unsupervised Model and Siamese Neural Networks Based on Wearable Sensors

Arabzadeh, Saeid¹ / Almasganj, Farshad^{2*} / Ahmadi, Mohamad Mahdi³

¹ - Ph.D. Student, Intelligent Processing of Biological One-Dimensional and Image Signals Lab, Biomedical Engineering, Amirkabir, Tehran, Iran

² - Professor, Intelligent Processing of Biological One-Dimensional and Image Signals Lab, Biomedical Engineering, Amirkabir, Tehran, Iran

³ - Professor, Biomedical Circuits and Systems Laboratory, Biomedical Engineering, Amirkabir, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2026.2086193.2022

Received: 22-2-2026

Revised: 7-7-2026

Accepted: 8-7-2026

KEYWORDS

Parkinson Disease's, Deep Learning, Hierarchical Model, Classification with templet matching, Auto encoder, Convolutional Neural Network, Wearable Sensors


ABSTRACT

The dynamic nature of Parkinson's disease motor disorders makes clinical assessments based on the UPDRS rating scale a time-consuming and expert-dependent process. Although the use of wearable sensors and machine learning algorithms provides an objective solution for analyzing these disorders, the complexity of motor patterns and the scarcity of labeled data have limited the efficiency of these models, particularly in the application of deep learning methods. In this study, a two-stage framework is proposed to diagnose and determine the severity of Parkinson's disease motor disorders, relying on unsupervised feature extraction and similarity-based classification. In the first stage, a hierarchical feature extraction model based on the unsupervised HUF framework is utilized. By combining convolutional networks and autoencoders, this model systematically performs the extraction and fusion of motor features at three levels: sensor channels, co-located sensors, and the entire set of sensors involved in each movement. In the second stage, to overcome the challenge of limited labeled data, an approach based on meta-learning and Siamese networks is introduced for feature classification. Rather than using data labels directly, this method maps motor features into a novel representation space and makes decisions by measuring the similarity between the feature distributions and a predefined set of reference features, ultimately selecting the class with the highest similarity. The proposed model was evaluated on the PD-BIOSTAMP21 dataset for three motor tasks, including walking, pronation-supination of right and left hand. For Parkinson's detection, the results achieved accuracies of 90%, 93%, and 86%, respectively. Additionally, for determining the disease severity level, by adopting a hierarchical one-vs-one classification strategy, accuracies of 79%, 74%, and 77% were obtained for the three mentioned movements, respectively. These results demonstrate that the proposed unsupervised framework has a high capability in extracting and classifying motor patterns using multi-channel data from wearable sensors.

***Corresponding Author**

Address: Intelligent Processing of Biological One-Dimensional and Image Signals Lab, Biomedical Engineering, Amirkabir, Tehran, Iran
E-Mail: almas@aut.ac.ir





تشخیص خودکار شدت اختلالات حرکتی بیماری پارکینسون با استفاده از مدل سلسله مراتبی بدون نظارت و شبکه‌های عصبی سایامیز مبتنی بر حسگرهای پوشیدنی

عرب زاده، سعید^۱ / الماس گنج، فرشاد^{۲*} / احمدی، محمد مهدی^۳

^۱ - دانشجو دکترا، آزمایشگاه پردازش علائم زیستی تک بعدی و تصویری، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران
^۲ - دانشیار، آزمایشگاه پردازش علائم زیستی تک بعدی و تصویری، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران
^۳ - دانشیار، آزمایشگاه مدارها و سیستم‌های زیست پزشکی، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2026.2086193.2022

پذیرش: ۱۴۰۵/۴/۱۷

بازنگری: ۱۴۰۵/۴/۱۶

ثبت در سامانه: ۱۴۰۴/۱۲/۳

واژه‌های کلیدی	چکیده
بیماری پارکینسون یادگیری عمیق مدل سلسله مراتبی طبقه‌بندی بر پایه‌ی تطبیق الگو خودرمنگار شبکه‌ی پیچشی حسگر پوشیدنی	ماهیت پویای اختلالات حرکتی بیماری پارکینسون، ارزیابی‌های بالینی مبتنی بر معیار UPDRS را به فرآیندی زمان‌بر و وابسته به تخصص پزشک تبدیل می‌کند. اگرچه استفاده از حسگرهای پوشیدنی و الگوریتم‌های یادگیری ماشین راهکاری عینی برای تحلیل این اختلالات ارائه می‌دهند، اما پیچیدگی الگوهای حرکتی و کمبود داده‌های برچسب‌دار، کارایی این مدل‌ها را، بویژه در کاربرد روش‌های یادگیری عمیق، با محدودیت‌های مواجهه ساخته است. در این پژوهش یک چارچوب دو مرحله‌ای به‌منظور تشخیص و تعیین شدت اختلالات حرکتی بیماری پارکینسون، با تکیه بر استخراج ویژگی بدون نظارت و طبقه‌بندی مبتنی بر شباهت پیشنهاد شده است. در مرحله‌ی نخست، از یک مدل استخراج ویژگی سلسله‌مراتبی بر پایه‌ی چارچوب بدون سرپرستی HUF بهره گرفته شده که با ترکیب شبکه‌های پیچشی و خودرمنگاریها، فرآیند استخراج ادغام ویژگی‌های حرکتی را به‌صورت ساختار یافته در سه سطح کانال حسگر، حسگرهای هم‌مکان و مجموعه حسگرهای دخیل در هر حرکت انجام می‌دهد. در مرحله‌ی دوم، به‌منظور غلبه بر چالش کمبود داده‌های برچسب‌دار، رویکردی مبتنی بر فرایادگیری و شبکه‌های سایامیز برای طبقه‌بندی ویژگی‌ها ارائه شده که در مقابل استفاده مستقیم برچسب داده‌ها، ویژگی‌های حرکتی را در یک فضای بازنمایی جدید نگاشت داده و فرآیند تصمیم‌گیری را بر اساس سنجش میزان شباهت میان توزیع ویژگی‌ها با یک مجموعه ویژگی‌های مرجع از پیش تعیین شده مقایسه می‌کند و کلاس با بیشترین شباهت را بر می‌گزیند. مدل پیشنهادی بر روی مجموعه داده‌ی PD-BIOSTAMP برای سه آزمون حرکتی شامل راه‌رفتن، و چرخش مچ دست راست و چپ مورد ارزیابی قرار گرفت. نتایج در حالت تشخیص پارکینسون، به ترتیب به صحت‌های ۹۰٪، ۹۳٪ و ۸۶٪ دست یافته‌است. همچنین در حالت تعیین سطح بیماری، با اتخاذ راهبرد طبقه‌بندی سلسله‌مراتبی یکی-مقابل-یکی، صحت‌های ۷۹٪، ۷۴٪ و ۷۷٪ به ترتیب برای سه حرکت مذکور حاصل شد. این نتایج اثبات می‌کند که چارچوب بدون سرپرست پیشنهادی، توانایی بالایی در استخراج و طبقه‌بندی الگوهای حرکتی با استفاده از داده‌های چندکاناله‌ی حسگرهای پوشیدنی دارد.

*نویسنده‌ی مسئول

نشانی: آزمایشگاه پردازش علائم زیستی تک بعدی و تصویری، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

پست الکترونیک: almas@aut.ac.ir



۱- مقدمه

بیماری پارکینسون (PD)^۱ یک اختلال پیشرونده و مزمن عصبی-تباہ‌کننده^۲ است [۱] که به عنوان دومین بیماری شایع عصبی، میلیون‌ها نفر را در سراسر جهان تحت تأثیر قرار داده است [۲]. مشخصه اصلی این بیماری از دست دادن سلول‌های عصبی تولیدکننده دوپامین در جسم سیاه مغز است که منجر به بروز علائم حرکتی از قبیل لرزش در حالت استراحت، کندی حرکت^۳، سفتی عضلانی^۴ و اختلال در تعادل می‌شود. بدلیل تغییر شدت این علائم در طول روز و دوزهای داروی مصرفی، ارزیابی دقیق و مداوم وضعیت شخص، نه تنها برای تشخیص به موقع، بلکه برای تنظیم دوز بهینه داروها و بهبود کیفیت زندگی وی الزامی است [۳]. در حال حاضر، معتبرترین استاندارد برای ارزیابی شدت بیماری پارکینسون، مقیاس یکپارچه رتبه‌بندی بیماری پارکینسون (UPDRS)^۵ است [۴]. UPDRS شامل چهار بخش شناختی و حرکتی می‌باشد که با محدودیت‌هایی شامل ماهیت ذهنی ارزیابی، وابستگی به قضاوت بالینی لحظه‌ای پزشک، ثبت لحظه‌ای، عدم در نظر داشتن شرایط بیماری در طول روز و زمان‌بر بودن اجرای کامل تمامی آزمون‌ها همراه است [۵، ۶]. با توجه به گزارش‌های مطالعات پیشین، تا ۲۵ درصد خطا در ارزیابی‌های بالینی [۵، ۶] به هنگام استفاده از UPDRS امکان دارد. این نتایج نیاز به توسعه یک ابزار پایش عینی، خودکار و غیرتهاجمی را ضروری می‌سازد که بتواند شدت پارکینسون را با دقت بالا در محیط‌های طبیعی زندگی بیمار و کلینیک‌ها ارزیابی کند.

در سال‌های اخیر، استفاده از حسگرهای پوشیدنی، به ویژه واحدهای اندازه‌گیری اینرسی (IMU)^۶ شامل شتاب‌سنج وژیروسکوپ، به عنوان یک راه حل در انجام ارزیابی خودکار آزمون‌های حرکتی UPDRS ظهور کرده است [۷-۱۲]. این حسگرها امکان ثبت دقیق داده‌های کینماتیک حرکت بدن را در شرایط واقعی فراهم می‌کنند؛ با این حال، تحلیل داده‌های حرکتی چند حسگر با چالش‌های فنی خاصی روبروست که عبارتند از استخراج ویژگی‌های مرتبط با حرکت و ادغام آن‌ها در بین حسگرهای نصب شده بر روی بدن و افزون بر آن، کمبود داده‌های برچسب‌دار بر پایه‌ی معیار UPDRS.

برای حل این مشکلات مطالعات بسیاری مبتنی بر روش‌های سنتی استخراج ویژگی (مانند ویژگی‌های آماری یا فرکانس-

زمان) که از نظر محاسباتی ساده‌تر هستند ارائه شده‌اند [۷-۱۴]. روش‌های تحلیل سیگنال‌های IMU ارائه شده در این مطالعات در مواجهه با داده‌های نویزی و متغیر، پایداری و دقت کمتری را نشان می‌دهند که بیانگر وابستگی آن‌ها به یک نوع داده‌ی خاص می‌باشد [۱۵، ۱۶]. از سوی دیگر، با پیشرفت روش‌های یادگیری عمیق (DL)^۷ و موفقیت‌های آن در تحلیل سیگنال‌های حرکتی، توجه محققان این حوزه را نیز به خود جلب کرده است. با این حال، استفاده از مدل‌های DL به دلیل نیاز بالای آن‌ها به حجم عظیمی از داده‌های برچسب‌دار، با محدودیت‌های جدی در حل مشکلات تحلیل سیگنال‌های حرکتی پارکینسون مواجه است [۱۵، ۱۷].

در این پژوهش، با هدف غلبه بر چالش‌های موجود در تشخیص و تعیین سطح بیماری پارکینسون، یک چارچوب یادگیری عمیق دو مرحله‌ای برای ارزیابی عینی شدت بیماری پارکینسون پیشنهاد می‌دهیم. این چارچوب در گام نخست، به استخراج سلسله مراتبی و بدون نظارت ویژگی‌های حرکتی می‌پردازد و در گام دوم، با بهره‌گیری از مفاهیم فرایادگیری^۸، امکان طبقه‌بندی دقیق را با اتکا به حداقل داده‌های برچسب‌دار فراهم می‌کند.

در مرحله‌ی استخراج ویژگی، یک مدل بهینه‌سازی شده بر پایه‌ی چارچوب HUF^۹ معرفی شده در [۱۷]، متناسب با ویژگی‌های حرکتی بیماران مبتلا به پارکینسون توسعه داده شده است. این مدل با بهره‌گیری از ترکیب شبکه‌های پیچشی (CNN)^{۱۰} و خودرمنگارها، قادر است ویژگی‌های حرکتی را به صورت خودکار، بدون نظارت و در قالب یک ساختار سلسله مراتبی استخراج و ادغام کند. در این ساختار، اطلاعات حرکتی در سه سطح شامل کانال حسگر، حسگرهای هم‌مکان و مجموعه‌ی حسگرهای درگیر در هر حرکت مورد تحلیل قرار می‌گیرند.

در مرحله‌ی طبقه‌بندی، مدلی مقایسه‌گر مبتنی بر شبکه‌های عصبی سایامیز (SNN)^{۱۱} ارائه داده‌ایم که در مقابل استفاده‌ی مستقیم از برچسب کلاس‌ها، فرآیند تصمیم‌گیری را بر اساس شباهت میان ویژگی‌ها انجام می‌دهد. در این رویکرد، ویژگی‌های استخراج شده از افراد بیمار با الگوهای حرکتی مرجع افراد سالم مقایسه شده و میزان انحراف آن‌ها سنجیده می‌شود. چنین ساختاری که بر اصول فرایادگیری استوار است،

⁸ Meta-learning⁹ Hierarchical Unsupervised Feature extraction and Fusion (HUF) method¹⁰ Convolutional Neural Network¹¹ Siamese Neural Network¹ Parkinson's Disease² Neurodegenerative³ Bradykinesia⁴ Rigidity⁵ Unified Parkinson's disease rating scale⁶ Inertial Measurement Unit⁷ Deep Learning



۲- پژوهش‌های مرتبط

تحلیل هوشمند سیگنال‌های حاصل از حسگرهای پوشیدنی جهت پایش بیماری پارکینسون، در دو شاخه‌ی اصلی روش‌های مبتنی بر استخراج ویژگی دستی^۷ و روش‌های یادگیری عمیق قابل بررسی است.

در رویکردهای شاخه‌ی اول، پژوهش‌ها عمدتاً معطوف به طراحی و مهندسی ویژگی‌ها به‌صورت صریح از سیگنال‌های خام بوده است [۷-۱۲]. در این رویکرد، ویژگی‌های حوزه‌های زمان [۱۰، ۱۱، ۱۸]، فرکانس (مانند تبدیل فوریه) و زمان-فرکانس استخراج شده [۱۲-۱۴] و پس از کاهش ابعاد، به طبقه‌بندهای کلاسیک داده می‌شوند. به عنوان نمونه، در پژوهش [۱۳]، با نصب حسگرهای شتاب‌سنج و ژيروسکوپ بر روی مچ پا، از تبدیل موجک گسسته برای استخراج ویژگی حرکتی در کنار ویژگی‌های پیچیده‌ی آشوبی^۸ استفاده شد. این ویژگی‌ها پس از ادغام توسط الگوریتم تحلیل مولفه‌های اساسی (PCA)^۹، به عنوان ورودی طبقه‌بندهای ماشین بردار پشتیبان (SVM)^{۱۰} و درخت تصمیم در نظر گرفته شده‌اند. در مطالعه‌ی دیگر [۱۹]، تشخیص پدیده‌ی یخ‌زدگی حین راه رفتن (FOG)^{۱۱} در بیماران پارکینسونی با تکیه بر استخراج ویژگی‌های حوزه‌ی دامنه از سیگنال‌های IMU انجام شده است؛ به‌طوری‌که سه حسگر در پشت ساق پاها و ناحیه‌ی کمری افراد نصب شده‌اند. هسیانی و همکارانش [۱۲] با پنجره‌بندی سیگنال‌ها و استخراج ویژگی‌های فرکانسی از هر پنجره، از طبقه‌بند SVM برای تشخیص پارکینسون استفاده کرده است. در این پژوهش نشان می‌دهد که افزایش تعداد حسگرها در ثبت سیگنال‌ها سبب افزایش دقت تشخیص پارکینسون می‌شود. افزون بر تحقیقات یاد شده، سلجوقی و قادریان [۲۰] با بهره‌گیری از ویژگی‌های زمان-فرکانسی متقارن سیگنال راه رفتن و استفاده از طبقه‌بندهای تنک، موفق به تفکیک بیماری‌های پارکینسون، هانتینگتون و ALS شدند. در رویکردی دیگر مبتنی بر دینامیک غیرخطی، مالکی و منفرد جهرمی [۲۱] با استفاده از ویژگی‌های تحلیل کمی بازگشتی (RQA)^{۱۲} بر روی سیگنال‌های راه رفتن، یک سیستم طبقه‌بند چهارکلاسه مبتنی بر SVM را با صحت بالا توسعه دادند. استفاده از این ویژگی‌های آشوبی برای ارزیابی شدت بیماری نیز مورد توجه بوده است؛ به‌طوری‌که حسنی و مالکی [۲۲] با

امکان دستیابی به عملکردی پایدار و دقیق را حتی در شرایط کمبود نمونه‌های برچسب‌دار فراهم می‌سازد.

مهم‌ترین نوآوری‌ها و مشارکت‌های این پژوهش عبارتند از:

- ما مدلی متناسب با HUF برای استخراج ویژگی از سه حرکت راه رفتن، چرخش مچ دست‌ها مطابق با مساله‌ی تشخیص اختلالات بیماری پارکینسون بهبود داده‌ایم. با استفاده از این مدل یک چارچوب استخراج ویژگی ابتدا تا انتهای^۱ سلسله مراتبی^۲ مبتنی بر ترکیب شبکه‌های پیچشی و خودرمنگاره‌ها^۳ بدست آورده‌ایم که ویژگی‌های حرکتی را به صورت خودکار و بدون نظارت، در سه سطح کانال حسگر، حسگر هم‌مکان و حسگرهای دخیل در تحلیل یک حرکت استخراج و ادغام می‌کند.

- ما مدلی طبقه‌بند مقایسه‌گر بر پایه‌ی شبکه‌های سایامیز و الگوریتم تطابق الگو^۴ به منظور طبقه‌بندی ویژگی‌های گسترده با استفاده از داده‌ها اندک ارائه داده‌ایم. در این مقاله با طراحی و به‌کارگیری یک شبکه‌ی سایامیز به عنوان یک مدل مقایسه‌گر^۵ به جای طبقه‌بند کلاسیک، میزان انحراف ویژگی‌های استخراج شده از فرد بیمار را با الگوی حرکتی افراد سالم مقایسه می‌کنیم. همچنان نشان داده‌ایم که رویکرد فرایادگیری، طبقه‌بندی در شرایط نمونه‌های محدود^۶ را با صحت بالاتری امکان‌پذیر می‌کند.

- ما در این مقاله مدل طبقه‌بند سایامیز را از ایده‌ی دو کلاسه به چند کلاسه با استفاده از روش یکی در مقابل یکی تعمیم داده‌ایم و با استفاده از این روش طبقه‌بندی چند کلاسه متناسب با داده‌ها اندک ایجاد کرده‌ایم. ساختار باقیمانده مقاله به شرح زیر است: در بخش دوم، مروری بر کارهای مرتبط ارائه می‌شود. بخش سوم به تشریح معماری مدل‌های پیشنهادی شامل چارچوب HUF و شبکه‌ی سایامیز اختصاص دارد و عملکرد طبقه‌بند سایامیز در حالت دو کلاسه و چند کلاسه بررسی می‌شود. در بخش چهارم، مجموعه داده‌ها PD-BIOSTAMP RC21، مراحل پیش‌پردازش و تنظیمات آزمایش‌ها تشریح می‌گردد. بخش پنجم نتایج پیاده‌سازی مدل‌ها و تحلیل عملکرد آن‌ها در قالب معیارهای ارزیابی مختلف را ارائه می‌دهد و در نهایت، بخش ششم و هفتم به جمع‌بندی نتایج، بحث و ارائه‌ی چشم‌انداز پژوهش‌های آتی اختصاص دارد.

⁷ Handcrafted Features

⁸ Chaotic

⁹ Principal Component Analysis

¹⁰ Support Vector Machine

¹¹ Freezing of gait

¹² Recurrence quantification analysis

¹ End-to-End

² Hierarchical

³ Autoencoders

⁴ Templet Matching

⁵ Comparison-based Model

⁶ Few-shot classification

گرفته‌اند. در مطالعه [۲۶]، از شبکه‌های LSTM دوکاناله برای بررسی همزمان لرزش و کندی حرکت در دست و پا استفاده شد. در نتایج این تحقیق، اهمیت ادغام ۳ کانال اطلاعات اندام‌های مختلف را در لایه‌های متراکم شبکه اثبات می‌کند. بات و همکاران [۲۷] این ایده را با استفاده از شبکه‌های Bi-LSTM گسترش دادند تا بتوانند وابستگی‌های زمانی را هم از گذشته به آینده و هم برعکس در پارامترهای بیومکانیکی گام تحلیل کنند. همچنین شنوی و همکاران [۲۸] نشان دادند که مدل‌های شبکه عصبی بازگشتی در تحلیل داده‌های ترسیمی برای تشخیص نقص‌های حرکتی ظریف بسیار کارآمد هستند که به نوعی اهمیت ادغام اطلاعات از حسگرهای متفاوت را نشان می‌دهد.

ج) مدل‌های ترکیبی و پیشرفته: نسل جدیدتر مقالات به ترکیب ویژگی‌های مکانی و زمانی پرداخته‌اند. به عنوان مثال، مدل‌های CNN-LSTM معرفی شده در [۱۶] و [۲۹]، توانستند با استخراج ویژگی‌های مکانی توسط CNN و تحلیل روند زمانی توسط LSTM، دقت تشخیص را به طرز چشمگیری افزایش دهند. گو و همکاران [۳۰] از شبکه‌های پیچشی گرافی (GCN) با ساختار درختی استفاده کردند. در این روش با استفاده از یادگیری تقابلی^۵ که آموزش مدل‌ها با داده‌ها اندک را امکان‌پذیر می‌کند، بازنمایی‌های قوی‌تری از ساختار اسکلتی دست استخراج کرده‌اند. همچنین میایو و همکاران [۳۱] با به کارگیری شبکه‌های عمیق پسماند^۶ مشکل محو شدن گرادیان در شبکه‌های بسیار عمیق را حل کرده و دقت تشخیص FOG را بهبود بخشیدند.

د) تحلیل چندوجهی^۷: در مدل‌های ارائه شده در قبل، استفاده شبکه‌های ساده به سمت بکارگیری شبکه‌های پیچیده را می‌توان مشاهده کرد. اما در این روند بدلیل مشکل جدی ترکیب اطلاعات حسگرهای متفاوت و همچنین آموزش شبکه‌هایی با تعداد لایه‌های بالا کمتر مورد توجه بوده است. بیشتر مدل‌های ارائه شده در حوزه‌ی تحلیل اختلالات حرکتی پارکینسون، توجه کمتری به ادغام اطلاعات از حسگرهای متفاوت داشته‌اند و قالباً تمامی حسگرها را به صورت یک دسته ورودی در نظر گرفته‌اند. از سوی دیگر، مطالعات تحلیل حرکت با استفاده از حسگرهای IMU، نشان داده است که در نظر داشتن مدل‌های بدون سرپرستی در ترکیب سیگنال‌های حرکتی سبب افزایش استخراج ویژگی‌های حرکتی و افزایش

تحلیل ویژگی‌های RQA بر روی داده‌های شتاب‌سنج دست در حین آزمون نواخت انگشت، نشان دادند که الگوهای بازخداد دارای تفاوت‌های معناداری در سطوح مختلف بیماری پارکینسون هستند. همچنین، قابلیت‌های مفاهیم بازگشتی به سیگنال‌های مغزی نیز تعمیم یافته است؛ طالش جفادیده و زارعی [۲۳] با استخراج ویژگی‌های کمی‌سازی بازگشتی از سیگنال‌های EEG^۱ و به کارگیری مدل‌های یادگیری ماشین مانند k-نزدیک‌ترین همسایه صحت مطلوبی در تشخیص پارکینسون به دست آوردند.

اگرچه روش‌های کلاسیک یاد شده به دلیل پیچیدگی محاسباتی پایین و امکان پیاده‌سازی روی سخت‌افزارهای ارزان قیمت مورد توجه هستند، اما به دلیل نادیده گرفتن برهم‌کنش بین حسگرها و وابستگی شدید به نوع حرکت و محل حسگر، از پایداری و تعمیم‌پذیری محدودی نسبت به روش‌های نوین شبکه عصبی برخوردارند [۱۵]. برای رفع محدودیت‌های استخراج ویژگی دستی، از شبکه‌های عصبی عمیق با قابلیت یادگیری خودکار ویژگی‌های انتزاعی استفاده شده است. این رویکردها بر اساس معماری شبکه به دسته‌های مختلفی تقسیم می‌شوند:

الف) شبکه‌های پیچشی و تحلیل مکانی: این دسته از مدل‌ها با بخش‌بندی سیگنال‌های IMU به پنجره‌های زمانی، به صورت مستقیم از خود سیگنال‌ها یا تصاویر حاصل از تبدیل آن‌ها استخراج ویژگی می‌کنند. به عنوان مثال، در پژوهش [۲۴]، داده‌های نه حسگر مختلف به صورت یک ماتریس یکپارچه به یک شبکه CNN عمیق چند لایه تزریق شد تا الگوهای FOG شناسایی شوند. [۱۵] در رویکردی متفاوت، سیگنال‌های IMU نوک انگشتان افراد را ابتدا به تصاویر اسپکتروگرام تبدیل می‌کند. این تصاویر سپس توسط یک CNN دو بعدی پردازش شده و در نهایت یک لایه Dense شدت لرزش دست را در چهار کلاس طبقه‌بندی نمود. تونگ و همکاران [۲۵] نیز نشان دادند که حتی بدون تبدیل به تصویر، استفاده از CNN یک بعدی مستقیماً روی سیگنال خام شتاب‌سنج، دقت بالاتری نسبت به روش‌های آماری در تشخیص لرزش ارائه می‌دهد.

ب) شبکه‌های بازگشتی و تحلیل زمانی: به دلیل ساختار توالی محور حرکات پارکینسونی و وابستگی آن‌ها به اطلاعات زمانی، شبکه‌های عصبی بازگشتی و به ویژه گونه‌های پیشرفته‌تر آن‌ها (LSTM^۲) برای تحلیل این حرکات مورد استفاده قرار

^۵ Contrastive Learning^۶ ResNets^۷ Multimodal^۱ Electromyogram^۲ Long Short-Term Memory^۳ Fusion^۴ Graphical Convolutional Neural Network



HUF، مدلی مبتنی بر خودرمنزنگارها توسعه داده‌ایم که فرآیند استخراج ویژگی‌ها را در سه گام زیر انجام می‌دهد:

- جایگذاری پنجره‌های حرکتی به ابعاد بالاتر،
 - ادغام ویژگی‌های حسگرهای دارای موقعیت یکسان،
 - ادغام ویژگی‌های حسگرهای دخیل در آزمون حرکتی
- تشخیص پارکینسون.

پیش از شروع به توضیحات این روش، لازم است نحوه تبدیل داده‌ها و تنظیم آن‌ها به صورت یک تنسور بیان شود. از این رو پیش از معرفی سه گام روش HUF، ابتدا تنسور ورودی به این روش را بررسی خواهیم کرد.

۳-۱-۱ ورودی شبکه‌ی HUF

حسگرهای IMU مورد استفاده در داده‌ها این مقاله دارای سه کانال حرکتی برای هر واحد شتابسنج هستند و می‌توان آن‌ها را برای یک برش N نمونه‌ای از کل فعالیت فرد به صورت $[a_x[n], a_y[n], a_z[n]]$ در نظر گرفت که در آن n مقداری از $(0, N)$ است. در صورت در نظر داشتن s حسگر IMU در یک آزمون حرکتی پارکینسون، تمامی این حسگرها را می‌توان به صورت تنسوری مطابق رابطه‌ی (۱) در نظر گرفت:

$$X = \begin{bmatrix} a_{x_1}[n] & a_{y_1}[n] & a_{z_1}[n] \\ \vdots & \vdots & \vdots \\ a_{x_s}[n] & a_{y_s}[n] & a_{z_s}[n] \end{bmatrix}_{s,3} \quad (1)$$

در این مقاله هر یک از اجزای X را به صورت $x_i[n]$ در نظر می‌گیریم و در سه گام مطابق با شکل یک، استخراج و ادغام ویژگی‌های آن‌ها را به منظور تفسیر الگوی حرکتی موجود در X انجام خواهیم داد.

۳-۱-۲ گام ابتدایی - بازنمایی پنجره‌های

حرکتی در ابعاد بالای ویژگی‌ها

مطابق با شکل (۱) و رابطه (۱)، هر یک از مولفه‌های ورودی X به منظور استخراج ویژگی‌های اولیه و جایگذاری به فضایی با ابعاد بالاتر، به شبکه‌ی خودرمنزنگار پشته‌ای بازنمایی داده (DR-SAE)^۱ اعمال می‌شوند. با توجه به شکل (۲)، معماری DR-SAE را از پنج لایه پیچشی یک‌بعدی (1D-CNN) همراه با تابع فعالیت SELU طراحی کرده‌ایم. هدف این معماری، تجزیه اطلاعات نهفته در سیگنال خام و بازنمایی آن در قالب ۲۵۶ نقشه‌ی ویژگی^۲ است. به عبارت دیگر، DR-SAE سیگنال ورودی را به مولفه‌های سازنده‌ی آن تجزیه کرده و ویژگی‌هایی

نتایج حاصل از تحلیل آن‌ها می‌شود. به عنوان مثال، در پژوهشی داده‌ها FOG حسگرهای حرکتی و EEG مغز را با ارایه مدلی چند وجهی ادغام کرده است حال آنکه در پژوهشی مشابه، تنها از بخش حسگرهای حرکتی استفاده کرده‌اند اما تحلیل سیگنال‌ها را بر پایه‌ی روش‌های بدون سرپرستی انجام داده‌اند که نتایج بالاتری کسب کرده‌اند [۱۷، ۳۲].

مرور مطالعات پیشین نشان می‌دهد که روند پژوهش‌ها از روش‌های مبتنی بر استخراج ویژگی دستی به سمت استفاده از معماری‌های عمیق و پیچیده شبکه‌های عصبی حرکت کرده است. با این حال، چالش اساسی در بسیاری از مدل‌های موجود، نحوه ادغام مؤثر اطلاعات چند حسگر و پایداری مدل در برابر تغییر الگوی حرکت‌های مختلف پارکینسون است. اغلب روش‌ها تمامی حسگرها را به صورت یک ورودی یکپارچه و غیرقابل تنظیم در نظر گرفته‌اند و توجه محدودی به یادگیری ساختارمند و تطبیقی روابط بین حسگرها داشته‌اند. از سوی دیگر، نتایج برخی مطالعات تشخیص حرکت نشان می‌دهد که بهره‌گیری از روش‌های بدون سرپرستی در استخراج و ادغام ویژگی‌های حرکتی چند حسگر، می‌تواند به بازنمایی غنی‌تر الگوهای حرکتی و بهبود عملکرد تشخیص حرکت منجر شود [۱۷]. از این رو، رویکرد پیشنهادی در این مقاله با تمرکز بر ادغام هوشمند و بدون سرپرستی اطلاعات حسگرهای حرکتی با افزایش دقت و پایداری تشخیص اختلالات پارکینسونی است.

۳-۲ روش

مدل ارایه شده در این مقاله، مطابق با شکل (۱) دارای دو بخش کلی استخراج ویژگی‌های حرکتی و طبقه‌بندی آن‌ها بر اساس میزان شباهت نسبت به ویژگی‌های یک فرد مشخص از کلاس خود می‌باشد. در بخش ابتدایی، مدل استخراج ویژگی‌ها بر اساس روش HUF می‌باشد که متناسب با شرایط داده‌ها پارکینسون تطبیق داده شده است. در بخش دوم، پیشنهاد مدل طبقه‌بندی ویژگی‌ها بر اساس شباهت با یک دسته ویژگی فرد از پیش مشخص شده به صورت دو کلاس و چند کلاس بر پایه‌ی شناسایی الگو و ادغام آن با شبکه‌های تشخیص شباهت سایمیز ارایه خواهد شد.

۳-۱ مدل تعمیم یافته‌ی HUF


با توجه به اهمیت استخراج و ادغام ویژگی‌ها به صورت بدون نظارت در بیماران پارکینسون، در این پژوهش با الهام از روش

² Feature Map

¹ Data Representation Stacked AE

تجزیه، گامی موثر برای ادغام اطلاعات هر کانال با سایر کانال‌های حرکتی در مراحل بعد است.

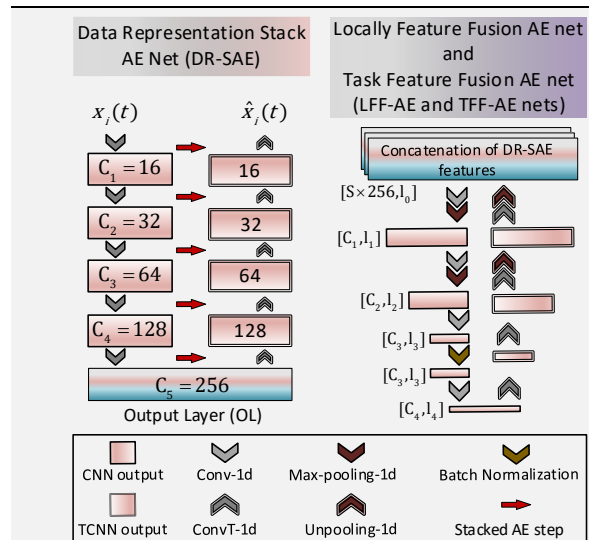
را استخراج می‌کند که ممکن است متناظر با باندهای فرکانسی خاص، مشخصه‌های حوزه زمان و ... باشند [۱۷]. این فرآیند



شکل (۱) - ساختار کلی مدل پیشنهادی در این مقاله به منظور استخراج و ادغام ویژگی‌ها به صورت بدون سرپرستی از سیگنال‌های حرکتی و طبقه‌بندی آن‌ها بر اساس مدل سایمیز برای داده‌های اندک.

معماری DR-SAE را به صورت فرا-کامل^۱ طراحی کرده‌ایم تا با افزایش ابعاد فضای ویژگی نسبت به ورودی، ظرفیت شبکه برای حفظ جزئیات سیگنال افزایش یابد. ساختار دقیق و تعداد کانال‌های اطلاعاتی در هر لایه از این خودرمنگار را می‌توان در شکل (۲) مشاهده کرد. فرآیند آموزش این DR-SAE را با رویکرد خودرمنگار پشته‌ای^۲ و طی شش مرحله متوالی (فلش‌های قرمز رنگ شکل (۲) - DR-SAE) انجام داده‌ایم. بردارهای ویژگی حاصل از لایه‌ی نهان، حاوی مولفه‌های اساسی الگوی حرکتی ضبط شده در هر کانال هستند. این شیوه از بازنمایی، امکان ادغام ویژگی‌ها در سطوح درون‌حسگری و بین‌حسگری را به صورت کاملاً بدون سرپرستی تسهیل کرده و موجب ارتقای عملکرد مدل در گام‌های بعدی می‌شود.

۳-۱-۳ گام دوم: ادغام ویژگی‌های درون حسگری
در دومین مرحله از روش پیشنهادی HUF، به منظور یکپارچه‌سازی اطلاعات استخراج شده از کانال‌های مختلف یک



شکل (۲) - ساختار شبکه‌ی DR-SAE (شبکه‌ی بازنمایی سیگنال‌های حرکتی در ابعاد بالاتر) و شبکه‌ی LFF-AE و TFF-AE (ادغامگر ویژگی‌های محلی و سراسری) در روش HUF

² Stacked AE

¹ Over-complete



ادغام اطلاعات مکانی توزیع شده در حسگرهای مختلف، بازنمایی کند. بدین منظور، شبکه‌ای تحت عنوان خودرمزنگار ادغام‌گر ویژگی‌های حرکت (TFF-AE)^۷ طراحی کرده‌ایم. در این مرحله، بردارهای ویژگی خروجی از واحدهای LFF-AE که هر کدام نماینده‌ی ویژگی‌های پالایش شده‌ی یک حسگر خاص هستند، مطابق با ساختار آناتومیکی بدن و نوع آزمون حرکتی، به یکدیگر الحاق شده و بردار ورودی شبکه‌ی TFF-AE را تشکیل می‌دهند. وظیفه‌ی این شبکه، کشف و مدل‌سازی همبستگی‌های پیچیده و غیرخطی میان اندام‌های مختلف است. برای مثال، هماهنگی میان حرکت دست‌ها و گام در آزمون راه رفتن یا حرکت دست و چرخش بدن در آزمون چرخش مچ دست‌ها را می‌توان نام برد.

اگرچه معماری پایه‌ی TFF-AE از نظر چیدمان لایه‌های پیچشی و مکانیزم رمزگذاری-رمزگشایی مشابهت ساختاری با شبکه LFF-AE دارد، اما پیکربندی داخلی و ابعاد لایه‌های آن متفاوت است. این تفاوت ناشی از حجم پایین‌تر داده‌های ورودی (تجمع تمام حسگرها) و نیاز به سطح بالاتری از فشرده‌سازی در فضای ویژگی نهایی است. جزییات دقیق تفاوت ابرپارامترها، ابعاد نقشه‌های ویژگی و تنظیمات لایه‌ها برای هر دو شبکه در جدول (۱) مقایسه شده است. خروجی نهایی این شبکه، برداری است که به عنوان بیان‌گر الگوی حرکتی بیمار در آن آزمون خاص، به بخش طبقه‌بند ارسال می‌گردد.

جدول (۱) - مشخصات پارامترهای استفاده شده در دو شبکه‌ی ادغام‌گر ویژگی‌های درون حسگری (LFF-AE) و بین حسگری (LFFT-AE). S بیانگر تعداد حسگرها است که در حرکت‌های متفاوت قابل تغییر می‌باشد.

مشخصات پارامترها					نوع شبکه
C_4	C_3	C_2	C_1	C_0	تعداد
۱۲۸	۱۲۸	۱۲۸	۱۲۸	3×256	
					ابعاد
لایه‌ی ۴	لایه‌ی ۳	لایه‌ی ۲	لایه‌ی ۱		
1×3	1×3	1×3	1×3		
					ابعاد
لایه‌ی ۲ (کرل، گام)		لایه‌ی ۱ (کرل، گام)			
$2, 1 \times 3$		$2, 1 \times 4$			
C_4	C_3	C_2	C_1	C_0	تعداد
۳۲	۳۲	۳۲	۳۲	$S \times 128$	
					ابعاد
لایه‌ی ۴	لایه‌ی ۳	لایه‌ی ۲	لایه‌ی ۱		
1×3	1×3	1×3	1×3		
					ابعاد
لایه‌ی ۲ (کرل، گام)		لایه‌ی ۱ (کرل، گام)			
$2, 1 \times 2$		$2, 1 \times 2$			

حسگر واحد، شبکه‌ای تحت عنوان خودرمزنگار ادغام‌گر ویژگی‌های محلی (LFF-AE)^۱ طراحی کرده‌ایم. هدف این شبکه، ترکیب ویژگی‌های تجزیه شده توسط شبکه DR-SAE است که همبستگی‌های میان کانالی را در سطح یک حسگر فیزیکی مدل‌سازی کند. با توجه به شکل (۲) معماری LFF-AE شامل هشت لایه CNN، چهار لایه ادغام^۲ و یک لایه نرمال‌سازی دسته‌ای^۳ (BN) است که در قالب یک ساختار خودرمزنگار پیکربندی کرده‌ایم. همان‌گونه که در شکل (۲) نمایش داده شده است، بردارهای ویژگی خروجی از مرحله‌ی قبل، مطابق رابطه‌ی (۲) به صورت برداری الحاق^۴ شده، ماتریس ورودی شبکه LFF-AE را تشکیل می‌دهند:

$$LFF - AE_{Input} = Concatenation(OL(a_x[n]), OL(a_y[n]), OL(a_z[n])) \quad (2)$$

در طراحی بخش رمزنگار این شبکه، پس از دو لایه ابتدایی شبکه‌های پیچشی از لایه‌های بیشینه-ادغام^۵ استفاده کرده‌ایم. تعبیه این لایه‌ها نقش موثری در افزایش پایداری و مقاوم‌سازی مدل در برابر نویزهای محیطی و اغتشاشات لحظه‌ای ایفا می‌کند [۳۳]. این اغتشاشات می‌توانند ناشی از تغییرات ناگهانی شتاب (مثلاً برخورد دست با بدن) یا جابجایی‌های جزیی حسگر در طول انجام آزمون باشند. افزون بر این، با بکارگیری یک لایه نرمال‌سازی دسته‌ای در لایه سوم، ضمن استانداردسازی توزیع داده‌ها و کنترل دامنه سیگنال [۳۴]، فرآیند همگرایی را در آموزش خودرمزنگار سریع‌تر کرده‌ایم. شایان ذکر است که ساختار بخش رمزگشا به صورت قرینه‌ی بخش رمزگذار در نظر گرفته‌ایم، با این تفاوت که به منظور بازسازی دقیق‌تر سیگنال، لایه BN را از این بخش حذف کرده‌ایم. جزییات مربوط به ابرپارامترهای^۶ بهینه این شبکه، که بر اساس آزمون‌های تجربی و ارزیابی تأثیر آن‌ها بر تفکیک‌پذیری کلاس‌های حرکتی تعیین شده‌اند [۱۷]، در جدول (۱) نیز ارائه شده است.

۳-۱-۴ گام سوم: ادغام سراسری ویژگی‌های بین حسگری

در سومین مرحله از معماری سلسله مراتبی HUF، فرآیند استخراج ویژگی از سطح محلی به سطح سراسری برای یک حرکت ارتقا می‌یابد. هدف اصلی در این گام، دستیابی به یک بردار ویژگی واحد است که بتواند الگوی حرکت شخص را با

⁵ Max-Pooling

⁶ Hyperparameters

⁷ Task Feature Fusion AE

¹ Locally Feature Fusion AE

² Pooling

³ Batch Normalization

⁴ Concatenate

همان‌گونه که در شکل (۳) نمایش داده شده است، این شبکه از دو زیر شبکه‌ی کاملاً یکسان تشکیل شده است. ویژگی کلیدی این معماری، اشتراک وزن دو شبکه است؛ بدین معنا که هر دو زیر شبکه دارای معماری، پارامترها و وزن‌های دقیقاً یکسانی هستند و به‌روزرسانی وزن‌ها در حین آموزش به صورت همزمان برای هر دو شاخه اعمال می‌شود.

در این ساختار، دو ورودی مجزا (که در این مقاله بردار ویژگی‌های استخراج شده از روش HUF هستند) به نام‌های X_1 و X_2 به شبکه وارد می‌شوند. هر زیر شبکه، ورودی مربوطه را به یک فضای ویژگی با ابعاد پایین‌تر بازنشانی می‌کند. اگر تابع عملکرد هر شبکه را با $G_W(\cdot)$ نشان دهیم، بردارهای خروجی به صورت زیر خواهند بود:

$$V_1 = G_W(X_1), \quad (3)$$

$$V_2 = G_W(X_2). \quad (4)$$

هدف SNN، ایجاد فضایی جدید از ویژگی‌ها است که در آن ویژگی‌های متعلق به یک کلاس (در حالت دو کلاسه، افراد سالم یا مبتلا به پارکینسون) را به یکدیگر نزدیک کرده و ویژگی‌های کلاس متفاوت را از یکدیگر دور سازد. برای سنجش میزان شباهت، از فاصله‌ی اقلیدوسی بین دو بردار خروجی به صورت زیر استفاده می‌شود:

$$D_W(X_1, X_2) = \|G_W(X_1), G_W(X_2)\|_2, \quad (5)$$

در این رابطه، D_W معیاری از عدم شباهت است؛ به‌طوری که مقادیر کمتر بیانگر شباهت بیشتر بین ویژگی‌ها هستند.

به منظور آموزش شبکه‌ی سایامیز، از تابع هزینه تضادی استفاده شده است. این تابع هزینه شبکه را وادار می‌کند تا فاصله‌ی بین زوج نمونه‌های مشابه را کمینه و فاصله‌ی بین زوج نمونه‌های نامشابه را بیشینه نماید. در صورتی که برچسب باینری زوج ورودی را Y در نظر بگیریم، به طوری که اگر X_1 و X_2 از یک کلاس باشند $Y = 0$ و اگر از دو کلاس متفاوت باشند $Y = 1$ باشد، تابع هزینه برای یک زوج داده به صورت زیر تعریف می‌شود [۳۷]:

$$L(W, Y, X_1, X_2) = (1 - Y)/2 * D_W^2 + Y/2 \{\max(0, m - D_W)\}^2. \quad (6)$$


در رابطه‌ی (۶)، m یک فرامتر کلیدی به نام حاشیه^۵ است که حداقل فاصله‌ی قابل قبول میان زوج‌ها با کلاس متفاوت را تعیین می‌کند. به بیان دیگر، شبکه تنها در حالتی برای زوج‌های نامشابه جریمه می‌شود که فاصله‌ی آن‌ها کمتر از مقدار m

۲-۳ طبقه‌بندی ویژگی‌ها بر پایه‌ی مقایسه

در تحلیل سیگنال‌های زیستی، به‌ویژه در پایش بیماری پارکینسون، کمبود داده‌های برچسب‌دار و عدم تعادل کلاسی از چالش‌های اساسی در به‌کارگیری روش‌های یادگیری عمیق به شمار می‌رود. استفاده از طبقه‌بندهای چندلایه‌ی تمام متصل (DLC)^۱ در چنین شرایطی، به دلیل تعداد بالای پارامترهای قابل آموزش، اغلب منجر به بیش‌برازش و در نتیجه کاهش دقت در طبقه‌بندی و تعیین سطح شدت بیماری می‌شود که در بخش چهارم مشاهده خواهیم کرد. از سوی دیگر، روش‌های کلاسیک نظیر SVM نیز در مواجهه با بردارهای ویژگی با ابعاد بسیار بالا (در حد هزاران ویژگی برای هر پنجره‌ی زمانی) و حجم محدود داده، از کارایی مطلوب برخوردار نیستند [۳۵]. این محدودیت‌ها ضرورت استفاده از ساختاری را آشکار می‌سازد که ضمن توانایی پردازش تعداد زیاد ویژگی، برای یادگیری داده‌های کم‌حجم نیز مناسب باشد. بر این اساس، در این پژوهش یک چارچوب طبقه‌بندی مبتنی بر یادگیری متریک^۲ و با تکیه بر SNN پیشنهاد می‌دهیم. این رویکرد با جایگزینی طبقه‌بندی مستقیم با مقایسه‌ی زوج نمونه‌ها در فضای ویژگی، امکان یادگیری موثر الگوهای حرکتی پارکینسونی را حتی در شرایط کمبود داده فراهم می‌کند و بستر مناسبی برای تفکیک دقیق‌تر سطوح مختلف بیماری ایجاد می‌نماید.

۱-۲-۳ معماری شبکه سایامیز و تابع هزینه تضادی^۳

شبکه‌های سایامیز، نوعی از معماری‌های شبکه‌ی عصبی هستند که بر خلاف یادگیری مستقیم از برچسب‌ها، میزان شباهت میان دو ورودی را یاد می‌گیرند. این ویژگی، شبکه را قادر می‌سازد تا در شرایط یادگیری با یک نمونه^۴ عملکردی بسیار دقیق و پایدار داشته باشد [۳۶].



شکل (۳) - معماری شبکه عصبی سایامیز. در این ساختار، دو زیر شبکه با وزن‌های اشتراکی (W)، ویژگی‌های ورودی‌ها را به فضای برداری نگاشت کرده و میزان شباهت آن‌ها از طریق محاسبه‌ی فاصله اقلیدوسی (D_W) تعیین می‌گردد.


^۴ One shot learning

^۵ Margin

^۱ Dense Layer Classifier

^۲ Metric Learning

^۳ Contrastive Loss



۳-۲-۱ طبقه‌بندی دو کلاس

در این سناریو، هدف تشخیص وقوع بیماری پارکینسون است. استراتژی اتخاذ شده در این پژوهش، تفکیک توزیع ویژگی‌های یک نمونه‌ی ورودی ناشناخته (X_q)، از نمونه‌های مجموعه پشتیبان سالم (SS_h) است و میانگین این فواصل را به عنوان نمره انحراف در نظر می‌گیریم. به بیان شفاف‌تر، مطابق با رابطه‌ی (۱۰):

$$D_W(X_q, SS_h) = \frac{1}{N} \sum_{i=1}^N \|G_W(X_q) - G_W(X_h^{(i)})\|_2, \quad (10)$$

ورودی X_q با تمامی N عضو مجموعه پشتیبان مقایسه می‌شود که با محاسبه‌ی میانگین آن‌ها ضریب تشابه محاسبه خواهد شد. در این شرایط، میزان انحراف بدلیل مقایسه‌ی ویژگی‌های ورودی با کل مجموعه‌ی سیگنالی حرکتی افراد مجموعه‌ی پشتیبان مقایسه می‌شود. با در نظر داشتن مقدار حاشیه‌ی (m) مناسب می‌توان قانون تصمیم‌گیری سالم یا بیمار بودن ویژگی‌های فرد وارد شده را مشخص کرد که در رابطه (۶) ذکر شده است.

طراحی شبکه‌ی سایامیز را برای طبقه‌بندی داده‌ها سالم از بیماران پارکینسون بر پایه‌ی شبکه‌های چند لایه‌ی تمام متصل انجام داده‌ایم. تصویر مدل شبکه‌ی $G(0)$ را می‌توان در شکل (۵) مشاهده کرد. این شبکه از سه لایه‌ی نورونی تشکیل شده است که جزییات هر لایه در جدول (۲) بیان شده است. لازم به ذکر است، به منظور مقایسه تاثیر تعداد لایه‌ها، همین ساختار را با پنج لایه مطابق با جدول (۲) نیز پیاده‌سازی کرده‌ایم.

باشد؛ امری که به شکل‌گیری مرزهای تفکیک‌پذیرتر در فضای ویژگی منجر می‌شود.

۳-۲-۲ تعمیم معماری شبکه‌ی سایامیز به طبقه‌بند دو و چند کلاس

اگرچه خروجی ذاتی شبکه‌ی سایامیز معیاری از فاصله یا عدم شباهت است، اما می‌توان با اتخاذ استراتژی‌های تصمیم‌گیری مبتنی بر آستانه و مقایسه با مجموعه پشتیبان (SS)، این معماری را برای طبقه‌بندی دو کلاس (تشخیص بیماری) و چندکلاس (تعیین شدت بیماری) تعمیم داد. به عنوان مثال، مجموعه‌ای از داده‌های حرکتی یک یا چند فرد سالم را به عنوان مرجع در نظر داشت و دیگر افراد را با این مجموعه مقایسه کرد. در صورت تشابه با مجموعه پشتیبان، شخص از اعضای گروه پشتیبان می‌باشد و در صورت عدم تشابه به این گروه تعلق ندارد.

محاسبه‌ی فاصله اقلیدسی در این مقاله به معنای کمی‌سازی میزان انحراف کلی الگوی حرکتی فرد از الگوی مرجع است. این فاصله، تجمعی از اختلاف‌ها در تمام ابعاد ویژگی‌های استخراج شده (نظیر دامنه، فرکانس و پیوستگی حرکت) می‌باشد. به عبارت بهتر در صورتی که خروجی شبکه‌ی سایامیز را k نورون در نظر بگیریم برای یک فرد سالم و یک فرد بیمار دو بردار V_1 و V_2 به صورت زیر تعریف خواهد شد:

$$V_1 = [p_1, p_2, \dots, p_k], \quad (7)$$

$$V_2 = [h_1, h_2, \dots, h_k], \quad (8)$$

در این صورت فاصله‌ی تک تک ویژگی‌ها از یکدیگر به صورت زیر محاسبه می‌شود:

$$D = \sqrt{(h_1 - p_1)^2 + (h_2 - p_2)^2 + \dots + (h_k - p_k)^2} \quad (9)$$


در واقع در فضای ویژگی‌ها در صورتی که توزیع ویژگی‌ها مشابه باشد، آن ویژگی به یک فرد سالم تعلق دارد و در غیر این صورت مربوط به یک فرد بیمار است. این ویژگی می‌تواند مشخصه‌ای فرکانسی از حرکت شخص، فرکانس لرزش، نرمی حرکت یا ترکیبی از چندین مشخصه‌ی فرد باشد. می‌توان تفسیر بیان شده در قبل را نیز در شکل (۴) به عنوان یک مثال با سه ویژگی مشاهده کرد. در این شکل ویژگی‌های یک فرد سالم به رنگ آبی نمایش داده شده است و ویژگی یک فرد بیمار به رنگ قرمز است. مشاهده می‌شود که در یک فضای سه بعدی ویژگی‌های فرد سالم از یک فرد بیمار تفاوت قابل ملاحظه‌ای دارد.

³ Support Set_{healthy}

¹ Support Set

² X_{query}


با توجه به ماهیت آموزش شبکه‌های سایامیز که مبتنی بر مقایسه‌ی زوج ورودی‌ها بوده و به‌طور خاص برای یادگیری مؤثر از داده‌ها با حجم محدود طراحی شده‌اند، در این مقاله، استفاده از راهبرد سری در طبقه‌بندی چندکلاسه امکان‌پذیر و کارآمد خواهد بود. شایان ذکر است که در تمامی مراحل، معماری شبکه‌ی پایه را مطابق با ساختار شکل (۵) در نظر گرفته‌ایم.



۴- داده‌ها و پیش پردازش

در این پژوهش، از مجموعه‌داده‌ی معتبر و عمومی PD-BIOSTAMP21 برای آموزش و ارزیابی مدل پیشنهادی استفاده شده است [۳۸]. این پایگاه داده شامل سیگنال‌های حرکتی ثبت شده از بیماران مبتلا به پارکینسون در حین انجام آزمون‌های استاندارد بوده و مستندات به همراه داده‌های خام آن، از طریق مخزن داده‌های IEEE به‌صورت آنلاین در دسترس پژوهشگران قرار دارد [۳۹].

داده‌ها شامل اطلاعات ۱۷ فرد مبتلا به پارکینسون و ۱۷ فرد سالم است که پس از حذف نمونه‌های نامعتبر و همسان‌سازی سنی، استخراج شده‌اند. سیگنال‌های حرکتی توسط پنج حسگر پوشیدنی BioStamp MC10 ثبت شده‌اند که در موقعیت‌های دو بازو، دو ران و قفسه سینه نصب گردیده‌اند. هر حسگر، شتاب خطی سه محوره $[x, y, z]$ را با نرخ نمونه‌برداری ۳۱/۲۵ هرتز ثبت می‌کند. شرکت کنندگان پس از یک جلسه ارزیابی کلینیکی، به مدت ۴۸ ساعت حسگرها را در محیط زندگی روزمره خود پوشیده‌اند. اگر چه بخش عمده‌ای از داده‌ها فاقد



شکل (۵) - ساختار $G_W(0)$ در طراحی طبقه‌بند دو کلاسه‌ی شبکه‌ی سایامیز تشخیص بیماری پارکینسون از افراد سالم.

جدول (۲) - مشخصات شبکه‌ی $G_W(0)$ در حالت پنج و سه لایه. در این ساختار l_0 تعداد ویژگی‌های استخراج شده بوسیله‌ی روش HUF می‌باشد.

مشخصات پارامترها							نوع شبکه
تعداد	l_0	l_1	l_2	l_3	l_4	l_5	
	32×58	۱۰۰۰	۵۰۰	۳۰۰	۲۰۰	۱۰۰	۱
تعداد	l_0	l_1	l_2	l_3			۲
	32×58	۷۰۰	۳۰۰	۱۰۰			

۳-۲-۲-۲ طبقه‌بندی چند کلاسه

به‌منظور به‌کارگیری شبکه‌های عصبی سایامیز به‌عنوان یک طبقه‌بند چندکلاسه مبتنی بر راهبرد یکی در مقابل یکی^۱ مطابق با شکل (۶)، فرآیند طبقه‌بندی چندکلاسه را به صورت مجموعه‌ای از تصمیم‌گیری‌های دوتایی متوالی مدل‌سازی کرده‌ایم. در این چارچوب، مسئله‌ی چند کلاسه به چندین مقایسه‌ی دوه‌دو میان کلاس‌ها تجزیه می‌گردد.

بر اساس ساختار شکل (۶)، ابتدا نمونه‌ی ورودی X_q با مجموعه‌ای از نمونه‌های افراد سالم مقایسه می‌شود. در صورتی که شباهت معناداری با این گروه مشاهده نشود، ورودی مذکور در گام بعدی با داده‌های مربوط به بیماران مبتلا به پارکینسون سطح یک مقایسه خواهد شد. در صورت تشخیص شباهت در این مرحله، X_q به عنوان بیمار پارکینسون سطح یک برچسب‌گذاری می‌شود. در غیر این صورت، این نمونه با داده‌های مربوط به سطح دو پارکینسون مقایسه می‌گردد؛ چنانچه شباهت با این دسته تشخیص داده شود، ورودی به عنوان سطح دو در نظر گرفته شده و در غیر این صورت، به طور خودکار در کلاس سطح سه قرار می‌گیرد.

¹ One-vs-One



تخصیص یافته‌اند. استراتژی SWS تضمین می‌کند که ارزیابی مدل کاملاً مستقل از هویت افراد دیده شده در فاز آموزش باشد.

۵- پیاده‌سازی و نتایج

۵-۱ استخراج ویژگی

با بهره‌گیری از روش HUF، ویژگی‌های حرکتی مرتبط به سه حرکت راه رفتن و چرخش مچ دست‌ها در بیماری پارکینسون در سه گام متوالی استخراج شده‌اند. در این بخش، به‌منظور تشخیص بیماری و تعیین سطح آن، دو رویکرد متفاوت برای طبقه‌بندی این ویژگی‌ها مورد استفاده قرار می‌گیرد که عبارتند از طبقه‌بندی مبتنی بر روش DLC و طبقه‌بندی بر اساس میزان شباهت ویژگی‌ها با استفاده از شبکه‌های سایمیز. هر یک از طبقه‌بندی‌های مورد استفاده به‌صورت مستقل آموزش داده شده‌اند و عملکرد آن‌ها به‌طور جداگانه مورد ارزیابی قرار می‌گیرند. در ادامه، ابتدا پارامترهای تنظیمی و نحوه‌ی آموزش هر یک از این دو طبقه‌بند به تفصیل بیان می‌شود و سپس، نتایج حاصل از هر روش به‌صورت مقایسه‌ای بررسی خواهد شد. لازم به ذکر است که فرآیند استخراج ویژگی‌ها مبتنی بر پنجره‌های حرکتی با طول ۳۰۰ نمونه انجام شده است. بنابراین، تشخیص بیماری و تعیین سطح پارکینسون در این پژوهش به‌صورت پنجره محور صورت می‌گیرد.

۵-۱-۱ آموزش شبکه‌های DR-SAE

در نخستین گام، به منظور پردازش سیگنال‌های تغییر شتاب و استخراج ویژگی‌های اولیه‌ی حرکتی، ساختار DR-SAE مطابق با شکل (۲) و پارامترهای یاد شده درون شکل تنظیم شده است. شکل (۷) روند تغییرات خطای آموزش این شبکه‌ها را برای هر یک از کانال‌های حرکتی نمایش می‌دهد.

با توجه به استفاده از پنج حسگر شتاب‌سنج خطی سه محوره، در مجموع ۱۵ کانال حرکتی مورد تحلیل قرار گرفته است. بر این اساس، ۱۵ شبکه‌ی خودرمنگار مستقل، بدون در نظر گرفتن برچسب شدت بیماری یا نوع حرکت (راه رفتن یا حرکات دست)، به صورت کاملاً بدون سرپرستی آموزش داده شده‌اند. نتایج نشان می‌دهد که خطای بازسازی تمامی شبکه‌ها در پایان فرآیند آموزش به مقادیری کمتر از 10^{-4} همگرا شده است که بیانگر توانایی مناسب شبکه‌های DR-SAE در یادگیری و بازنمایی فشرده و پایدار از سیگنال‌های حرکتی است.

برچسب است، اما نواحی متناظر با آزمون‌های حرکتی UPDRS به‌صورت دقیق نشانه‌گذاری شده‌اند. در این پژوهش، تنها بخش‌های مربوط به آزمون راه رفتن، چرخش مچ دست راست و چپ آزمون UPDRS مورد استفاده قرار گرفته است که برای هر فرد، بازه‌هایی با طول تقریبی ۱۰ تا ۳۰ ثانیه در هر آزمون حرکتی را شامل می‌شود.

مطابق دستورالعمل UPDRS، شدت بیماری به صورت پنج سطح حرکتی تعریف می‌شود؛ به طوری که کلاس صفر متناظر با افراد سالم بوده و کلاس‌های یک تا سه سطوح مختلف پارکینسون را نمایش می‌دهند. سطح چهار به دلیل عدم وجود نمونه‌ی معتبر در این مجموعه داده، در تحلیل‌ها لحاظ نشده است. این برچسب‌گذاری، امکان ارزیابی همزمان تشخیص بیماری و تعیین سطح شدت پارکینسون را در چارچوب پیشنهادی فراهم می‌کند.


لازم به ذکر است که تمامی سیگنال‌های حرکتی ثبت شده، در گام نخست با استفاده از تبدیل فوریه به نرخ ۳۰۰ هرتز بازنمونه‌برداری شده‌اند. علت اصلی این بازنمونه‌برداری، تامین طول توالی زمانی مناسب برای تغذیه‌ی شبکه‌های عمیق استخراج ویژگی است. از آنجا که معماری HUF از چندین لایه پیچشی و ادغام تشکیل شده است، استفاده از نرخ نمونه‌برداری اولیه منجر به در نظر داشتن ۳۱ نمونه برای طول پنجره‌ی یک ثانیه‌ای می‌شود. به دلیل کاهش سریع این ابعاد در لایه‌های پنهان، شکل‌گیری یک شبکه‌ی عمیق امکان‌پذیر نیست اما با تبدیل نرخ نمونه‌برداری به ۳۰۰ هرتز، طول توالی به اندازه‌ی کافی گسترش می‌یابد. پس از این مرحله، سیگنال‌ها با در نظر گرفتن پنجره‌هایی به طول ۳۰۰ نمونه (معادل یک ثانیه) و هم‌پوشانی ۵۰٪ به بخش‌های کوتاه‌تر تقسیم‌بندی شده‌اند تا امکان استخراج و تحلیل پایدار ویژگی‌های زمانی فراهم شود. در ادامه، با توجه به توزیع نمونه‌ها در کلاس‌های مختلف، تفکیک داده‌ها به‌صورت کاملاً فرد محور مبتنی بر روش تقسیم‌بندی فردمحور (SWS)^۱ انجام شده است؛ به طوری که تمامی پنجره‌های استخراج شده از یک فرد مشخص، منحصراً در یکی از دو مجموعه‌ی آموزش یا آزمایش قرار می‌گیرند تا از بروز هرگونه نشت اطلاعات بین داده‌ها جلوگیری شود. در این رویکرد، افراد هر کلاس با نسبت تقریبی ۷۰ درصد برای مجموعه‌ی آموزش و ۳۰ درصد^۲ برای مجموعه‌ی آزمایش

¹ Subject-Wise Split (SWS)

با توجه به محدودیت تعداد افراد حاضر در برخی کلاس‌ها، این نسبت ممکن است با ²

تقریب همراه باشد. به عنوان مثال، در کلاس سطح سه که مجموعاً ۳ فرد حضور دارند، داده‌های یک فرد برای مجموعه‌ی آزمایش و دو فرد برای آموزش انتخاب شده‌اند.

لازم به ذکر است که به دلیل ساختار لایه‌به‌لایه‌ی شبکه‌ی LFF-AE، فرآیند فشرده‌سازی تنها محدود به بعد ویژگی نبوده و ویژگی‌ها از نظر طولی (زمانی) نیز فشرده می‌شوند. نتایج آموزش شبکه‌های LFF-AE که منحنی خطای بازسازی آن‌ها در شکل (۸) نشان داده شده است، بیانگر آن است که پس از حدود ۵۰ چرخه آموزش، مقدار خطای بازسازی به کمتر از 10^{-3} کاهش یافته و در نهایت آموزش شبکه‌ها در چرخه ۱۵۰ متوقف شده است.




شکل (۸) - میانگین و انحراف معیار خطای آموزش در هر چرخش از آموزش شبکه‌های LFF-AE (● میانگر میانگین و هاله‌های هر نقطه انحراف معیار را نمایش می‌دهد).

۳-۱-۵ آموزش شبکه‌های TFF-AE

در سومین گام از روش HUF، فرآیند آموزش شبکه‌های ادغام ویژگی‌های بین‌حسگری (TFF-AE) برای حرکات مشخص مورد بررسی قرار می‌گیرد. همان‌گونه که در بخش‌های پیشین اشاره شد، در این پژوهش دو حرکت اصلی راه رفتن و چرخش مچ دست‌ها به عنوان حرکت‌های ارزیابی مدل در نظر گرفته شده‌اند. بر این اساس، سه پیکربندی متفاوت از شبکه‌های TFF-AE تعریف می‌شود که هر یک متناسب با حسگرهای درگیر در آن حرکت خاص طراحی شده‌اند. نوع حرکات و حسگرهای متناظر با هر یک در جدول (۳) ارائه شده است. شکل (۹) منحنی خطای بازسازی ویژگی‌ها را برای هر یک از شبکه‌های TFF-AE نمایش می‌دهد. نتایج نشان می‌دهد که پس از حدود ۴۵۰ چرخه‌ی آموزش، خطای بازسازی شبکه برای حرکت چرخش دست‌ها به مقدار تقریبی 0.005 و برای حرکت راه رفتن به حدود 0.01 همگرا می‌شود. این اختلاف در مقدار خطای همگرایی را می‌توان به پیچیدگی بالاتر الگوهای حرکتی در راه رفتن و درگیری تعداد بیشتری از حسگرها نسبت داد.

در طی فرآیند آموزش، اسپایک‌های مقطعی در مقدار خطای آموزش مشاهده می‌شوند. این نوسانات به فرآیند آموزش لایه‌به‌لایه^۱ در شبکه‌های DR-SAE باز می‌گردد. به‌طور مشخص، پس از افزودن هر لایه‌ی جدید، پارامترهای بهینه‌ساز آن لایه با مقادیر اولیه‌ی تصادفی مقداردهی می‌شوند. در این حال، وزن‌های لایه‌های پیشین ثابت نگه داشته می‌شوند و آموزش از سرگرفته می‌شود؛ از این رو، مقدار خطای آموزش به‌طور موقت افزایش می‌یابد اما پس از چند چرخه آموزش (در حدود پنج تکرار)، شبکه مجدداً به حالت پایدار بازگشته و مقدار خطا به سطح پیشین یا پایین‌تر همگرا می‌شود.



شکل (۷) - میانگین و انحراف معیار خطای آموزش در هر چرخش از آموزش شبکه‌های DR-SAE (● میانگر میانگین و هاله‌های رنگی هر نقطه انحراف معیار را نمایش می‌دهد).

۲-۱-۵ آموزش شبکه‌های LFF-AE

پس از استخراج ویژگی‌های هر یک از کانال‌های حرکتی در مرحله‌ی پیشین، به‌وسیله‌ی شبکه‌های LFF-AE فرآیند ادغام ویژگی‌ها برای حسگرهایی با محل نصب یکسان انجام می‌شود. در این مرحله، مطابق با مدل ارائه شده در شکل (۲) و توضیحات مربوط به آن، ویژگی‌های استخراج شده از کانال‌های هر حسگر به‌صورت انباشته در کنار یکدیگر قرار گرفته و به‌عنوان ورودی شبکه‌های LFF-AE مورد استفاده قرار می‌گیرند. با توجه به اینکه تعداد ویژگی‌های استخراج شده برای هر پنجره در خروجی شبکه‌ی DR-SAE برابر با ۲۵۶ است (مطابق با لایه‌ی کد در شکل (۲))، بردار ورودی هر یک از شبکه‌های LFF-AE دارای ابعاد 3×256 می‌باشد که متناظر با سه کانال حرکتی هر حسگر است. این بردار ورودی، پس از فرآیند ادغام ویژگی‌ها در شبکه‌ی LFF-AE، به نمایش فشرده‌تری با بعد ۱۲۸ کاهش می‌یابد.

¹ Stack wise training



شده‌اند و عملکرد آن‌ها به‌طور جداگانه مورد ارزیابی قرار می‌گیرد.

۵-۲-۱ آموزش شبکه‌ی طبقه‌بند DLC


شبکه‌های تمام‌متصل یکی از پرکاربردترین ساختارها برای طبقه‌بندی ویژگی‌های با ابعاد بالا به‌شمار می‌روند و در بسیاری از پژوهش‌های مبتنی بر استخراج ویژگی با استفاده از شبکه‌های پیچشی و بازگشتی با سرپرستی، به عنوان بخش نهایی طبقه‌بندی مورد استفاده قرار می‌گیرند. این شبکه‌ها که در قالب پرسپترون چندلایه (MLP)^۱ پیاده‌سازی می‌شوند، به دلیل ساختار تمام متصل توانایی ادغام انواع مختلف ویژگی‌ها، مدل‌سازی روابط غیرخطی میان آن‌ها و کاهش بعد متناسب با مسایل طبقه‌بندی چند کلاسه را دارند.

در این پژوهش، ساختاری مشابه با آنچه در شکل (۵) و جدول (۲) ارائه شده است در نظر گرفته‌ایم که جزئیات دقیق آن در جدول (۴) بیان شده‌اند. لازم به ذکر است که در فرآیند آموزش مدل، به‌منظور کاهش پدیده‌ی بیش‌برازش، از لایه‌ی حذف تصادفی با ضریب ۰/۲ استفاده کرده‌ایم. منحنی خطای آموزش به‌همراه مقادیر صحت آموزش و آزمایش برای سه حرکت مورد بررسی با استفاده از شبکه دس پنج لایه را در شکل (۱۰) مشاهده می‌کنیم. مطابق با نتایج به دست آمده، پس از حدود ۹۰ چرخه‌ی آموزش، شبکه صحت کامل در طبقه‌بندی دادگان آموزش دست یافته است، در حالی که صحت طبقه‌بندی بر روی داده‌های آزمایش به حدود ۷۰٪ رسیده است. جزئیات مربوط به مقادیر خطا و صحت شبکه بر روی داده‌های آموزش و آزمایش در شکل (۱۱) و جدول (۵) ارائه شده است. با توجه به جدول (۵)، اگرچه شبکه به صحت و حساسیت حدود ۷۰٪ دست یافته است اما مقدار دقت آن برخلاف دو معیار دیگر بسیار بالا می‌باشد که به معنای تشخیص بیشتر افراد به صورت یک فرد بیمار است. به عبارت بهتر، مدل DLC تمامی افراد را بیمار دانسته و برخی از افراد سالم را به درستی تشخیص داده است. در صورت کاهش تعداد لایه‌های شبکه از پنج به سه، ضمن حفظ عملکرد کلی مدل، پایداری آن در طبقه‌بندی ویژگی‌های مربوط به حرکت راه رفتن نیز حفظ شده است. در این حالت، تعداد ویژگی‌های مورد استفاده برای طبقه‌بندی داده‌ها مشابه ساختار پنج‌لایه باقی مانده است، با این تفاوت که تعداد نورون‌های هر لایه کاهش یافته و در نتیجه، پیچیدگی مدل کمتر شده است.

در پایان این مرحله، برای هر حرکت مجموعه‌ای از ویژگی‌ها با ابعاد 58×32 استخراج می‌شود. لازم به ذکر است، اگرچه ورودی شبکه‌ی TFF-AE می‌تواند شامل تعداد متفاوتی از ویژگی‌ها (متناسب با تعداد حسگرهای درگیر در هر حرکت) باشد، اما در فرآیند بازسازی، بعد خروجی شبکه همواره ثابت باقی می‌ماند. به بیان دیگر، تعداد ویژگی‌های خروجی شبکه‌ی TFF-AE مستقل از بعد ورودی بوده و این ویژگی‌ها، امکان ادغام یکنواخت اطلاعات بین حسگری را برای حرکت‌های مختلف فراهم می‌سازند.

جدول (۳) - نوع حرکت و حسگرهای درگیر در فرآیند ادغام ویژگی‌های بین حسگری

نوع حرکت	حسگرهای درگیر
راه رفتن	دست راست، دست چپ، سینه، پای راست، پای چپ
چرخش دست راست	دست راست، سینه
چرخش دست چپ	دسته چپ، سینه



شکل (۹) - میانگین خطای آموزش در هر چرخش از آموزش شبکه‌های TFF-AE برای سه حرکت راه رفتن و پرونیشن - سوپینیشن دستان

۵-۲ تشخیص بیماری پارکینسون

با بهره‌گیری از روش HUF، ویژگی‌های حرکتی مرتبط با حرکت‌های مورد نظر در بیماری پارکینسون را در سه گام متوالی استخراج کردیم. در این بخش، به‌منظور تشخیص بیماری و تعیین سطح آن، دو رویکرد متفاوت را برای طبقه‌بندی این ویژگی‌ها مورد استفاده قرار می‌دهیم. در رویکرد اول از طبقه‌بندی مبتنی بر روش DLC استفاده خواهیم کرد و در رویکرد بعدی طبقه‌بندی بر اساس میزان شباهت ویژگی‌ها با استفاده از شبکه‌های سایمیز را پیاده‌سازی خواهیم کرد. هر یک از طبقه‌بندی‌های مورد استفاده به‌صورت مستقل آموزش داده

¹ Multi Layers Perceptron

پنج لایه	True label	Pronation Supination RIGHT		Pronation Supination LEFT		Gait	
		0	1	0	1	0	1
سه لایه	0	0.29	0.71	0.17	0.83	0.18	0.82
	1	0.07	0.93	0.16	0.84	0.05	0.95
	0	0.32	0.68	0.14	0.86	0.16	0.84
	1	0.06	0.94	0.12	0.88	0.04	0.96
		Predicted		Predicted		Predicted	

شکل (۱۲) - خطای آموزش، دقت آموزش و آزمایش شبکه‌های DLC برای ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.


جدول (۵) - مقدار صحت، دقت و حساسیت آموزش شبکه‌ی DLC در تشخیص بیماری پارکینسون.

نوع حرکت	صحت	دقت	حساسیت
پنج لایه			
راه رفتن	۷۰/۱٪	۹۲/۷۹٪	۷۰/۸٪
چرخش دست راست	۷۳/۵٪	۹۵/۷۷٪	۷۵/۰٪
چرخش دست چپ	۵۳/۸٪	۸۶/۲۷٪	۵۳/۷٪
سه لایه			
راه رفتن	۷۰/۴٪	۹۴/۴۰٪	۷۰/۷٪
چرخش دست راست	۷۵/۵٪	۹۵/۷۷٪	۷۰/۶٪
چرخش دست چپ	۵۴/۸٪	۸۴/۳۱٪	۵۵/۶٪

۵-۲-۲ آموزش شبکه‌های طبقه‌بند سایامیز دو کلاسه

بر اساس نتایج به دست آمده از شبکه‌های DLC در دو پیکربندی سه لایه و پنج لایه، مشاهده شد که این نوع شبکه‌ها توانایی کافی برای تفکیک داده‌های بیماران مبتلا به پارکینسون از افراد سالم را ندارند. مهم‌ترین دلیل این مسئله را می‌توان تعداد بالای پارامترهای آموزش این شبکه‌ها نسبت به حجم محدود داده‌های مورد استفاده در فرآیند آموزش دانست. از این رو، در این پژوهش به منظور طبقه‌بندی داده‌های پارکینسون از مدل‌های فرآزمایشی مبتنی بر یادگیری متریک بهره برده‌ایم. مطابق با توضیحات ارائه شده در بخش ۳-۲، برای تشخیص بیماری پارکینسون از دو شبکه‌ی سایامیز چند لایه استفاده کرده‌ایم. مشابه با رویکرد اتخاذ شده در شبکه‌های DLC، در این بخش نیز دو پیکربندی متفاوت شامل هسته‌ی داخلی DLC پنج لایه و سه لایه برای شبکه‌ی سایامیز در نظر گرفته‌ایم که مشخصات معماری هر یک در جدول (۲) ارائه شده‌اند.


نتایج حاصل از آموزش شبکه‌ی سایامیز با هسته‌ی داخلی پنج لایه‌ی DLC نشان می‌دهد که صحت تشخیص بیماری




شکل (۱۰) - خطای آموزش، دقت آموزش و آزمایش شبکه‌های DLC پنج لایه برای ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.

جدول (۴) - ساختار شبکه‌های DLC بکارگرفته شده به منظور طبقه‌بندی دو کلاسه ویژگی‌های استخراج شده از روش HUF.

نوع شبکه	مشخصات پارامترها					
	تعداد	l_0	l_1	l_2	l_3	l_4
۱	۳۲ × ۵۸	۱۰۰۰	۳۰۰	۱۰۰	۲۵	۲
۲	۳۲ × ۵۸	۷۰۰	۷۵	۲		



شکل (۱۱) - خطای آموزش، دقت آموزش و آزمایش شبکه‌های DLC سه لایه برای ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.



شکل (۱۴) - خطای آموزش، دقت آموزش و آزمایش شبکه‌های

سایامیز با هسته‌ی داخلی DLC سه لایه برای تشخیص بیماری پارکینسون با استفاده از ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.

	Pronation Supination RIGHT		Pronation Supination LEFT		Gait	
	0	1	0	1	0	1
True label 0	0.77	0.23	0.75	0.25	0.95	0.05
True label 1	0.00	1.00	0.00	1.00	0.53	0.47
True label 0	0.83	0.17	0.82	0.18	0.71	0.29
True label 1	0.00	1.00	0.00	1.00	0.00	1.00
	Predicted		Predicted		Predicted	


شکل (۱۵) - ماتریس درهم‌ریختگی شبکه‌ی طبقه‌بند سایامیز با هسته‌ی داخلی DLC برای تشخیص بیماری پارکینسون با استفاده از ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.

جدول (۶) - مقدار صحت، دقت و حساسیت آموزش شبکه‌ی سایامیز با هسته‌ی داخلی DLC در تشخیص بیماری پارکینسون

نوع حرکت	صحت	دقت	حساسیت
پنج لایه			
راه رفتن	۶۲/۷٪	۴۷/۵٪	۹۴/۹٪
چرخش دست راست	۹۳/۱٪	۹۳/۱٪	۹۱/۰٪
چرخش دست چپ	۸۶/۰٪	۸۶/۵٪	۷۵/۵٪
سه لایه			
راه رفتن	۹۰/۸٪	۱۰۰٪	۸۸/۱٪
چرخش دست راست	۹۳/۱٪	۱۰۰٪	۹۱/۰٪
چرخش دست چپ	۸۶/۰٪	۱۰۰٪	۷۵/۵٪

پارکینسون در دو حرکت چرخش مچ دست راست و چپ بهبود یافته است. با این حال، مطابق با ماتریس‌های درهم‌ریختگی نمایش داده شده در شکل (۱۵)، در این حرکات، اگر چه دقت مدل به مقادیر بالایی رسیده است، اما میزان حساسیت تناسب لازم با دو پارامتر ارزیابی دیگر را ندارد. همچنین در حرکت راه رفتن، علی‌رغم دستیابی مدل به صحت حدود ۹۰٪، این عملکرد از پایداری کافی برخوردار نیست و پس از چرخه‌ی ۵۰ آموزش کاهش خواهد یافت (شکل (۱۳) بخش راه رفتن).

به‌طور کلی، استفاده از شبکه‌ی سایامیز با هسته‌ی پنج‌لایه اگر چه نسبت به طبقه‌بند DLC ساده بهبود محسوسی از نظر صحت ایجاد کرده است، اما از نظر پایداری مدل همچنان با محدودیت‌هایی همراه است. در مقابل، با کاهش تعداد لایه‌های هسته‌ی داخلی شبکه‌ی سایامیز از پنج به سه، علاوه بر حفظ نتایج کسب شده، پایداری مدل در طبقه‌بندی ویژگی‌های مربوط به حرکت راه رفتن نیز بهبود یافته است. افزون بر این، دو معیار دقت و حساسیت در این پیکربندی افزایش قابل ملاحظه‌ای را نشان می‌دهند. در این ساختار، تعداد ویژگی‌های مورد استفاده برای طبقه‌بندی داده‌ها مشابه حالت پنج‌لایه باقی مانده است، با این تفاوت که تعداد نورون‌های هر لایه کاهش یافته و در نتیجه پیچیدگی مدل کمتر شده است. با این وجود، کاهش بیشتر لایه‌ها پیشنهاد نمی‌گردد، زیرا تقلیل ظرفیت مدل در نگاشت ویژگی‌های پیچیده استخراج شده از روش HUF به کلاس‌های هدف، طبقه‌بند را با پدیده‌ی کم‌برازش^۱ مواجه می‌سازد.



شکل (۱۳) - خطای آموزش، دقت آموزش و آزمایش شبکه‌های

سایامیز با هسته‌ی داخلی DLC پنج لایه برای تشخیص بیماری پارکینسون با استفاده از ویژگی‌های سه حرکت راه رفتن، چرخش دست راست و چپ.

¹ Underfitting

۵-۳ تشخیص و تعیین سطح بیماری


پارکینسون

بر اساس نتایج ارایه شده در بخش پیشین، شبکه‌های DLC به دلیل محدودیت در تعمیم‌پذیری و حساسیت به حجم اندک داده‌های برچسب‌دار، توانایی کافی برای تشخیص قابل اعتماد بیماری پارکینسون نشان ندادند. در مقابل، روش پیشنهادی این پژوهش عملکرد به مراتب پایدارتری را در شرایط داده‌های محدود ارایه کرد. از این رو، در این بخش چارچوب طبقه‌بندی مبتنی بر فراآموزش را گسترش داده‌ایم و فرآیند تعیین سطح بیماری را به صورت تصمیم‌گیری یکی در مقابل یکی^۱ پیاده‌سازی کرده‌ایم. در این چارچوب، سه گام متوالی شامل: (۱) تشخیص وجود بیماری پارکینسون، (۲) تفکیک بیماران سطح یک از سایر بیماران، و (۳) تمایز میان سطوح دو و سه بیماری را در نظر گرفته‌ایم.

برای پیاده‌سازی این راهبرد، از شبکه‌های سایامیز با سه مجموعه وزن مستقل استفاده کرده‌ایم، به‌گونه‌ای که هر شبکه به‌طور مجزا و با داده‌های مقایسه‌ای متناسب با همان گام

آموزش داده می‌شود. در نتیجه، تابع هزینه، بهینه‌ساز و فرآیند یادگیری هر مرحله به صورت مستقل تنظیم شده و هیچ اشتراک وزنی میان شبکه‌های مراحل مختلف وجود ندارد. بر این اساس، سه مجموعه مقایسه‌ی مجزا شامل داده‌های افراد سالم، بیماران سطح یک، و بیماران سطح دو در نظر گرفته‌ایم تا امکان مقایسه‌ی ویژگی‌ها میان هر کلاس و سایر کلاس‌ها فراهم شود.

مطابق با ساختار نشان داده شده در شکل (۶)، در آموزش شبکه‌ی تشخیص بیماری پارکینسون، تمامی افراد سالم و بیمار مورد استفاده قرار می‌گیرند. در مقابل، آموزش شبکه‌ی تشخیص سطح یک تنها با داده‌های بیماران انجام شده و به‌طور مشابه، در مرحله‌ی تفکیک سطوح دو و سه، فقط داده‌های مربوط به این دو سطح وارد فرآیند آموزش می‌شوند. این ساختار سلسله‌مراتبی موجب می‌شود که در مرحله‌ی آموزش، عملکرد شبکه‌ی سطوح پایین‌تر به شبکه‌های مراحل پیشین تأثیر نگذارد. به عبارت دیگر، هرگونه خطا در تشخیص اولیه‌ی بیماری، می‌تواند به مراحل بعدی منتقل شده و تجمع یابد که در پیشنهاد ارایه شده این اتفاق نخواهد افتاد.




شکل (۱۶) - خطای آموزش و آزمون طبقه‌بندی سلسله‌مراتبی مبتنی بر شبکه‌های سایامیز پیشنهادی برای تشخیص و تعیین سطح بیماری پارکینسون. ستون یک خطای صحت داده‌ها آموزش و آزمایش برای تمامی داده‌ها سه مجموعه‌ی حرکتی نمایش داده شده است و سه ستون بعدی خطای هر یک از زوج کلاس‌ها به صورت مستقل در مراحل مختلف شامل تشخیص بیماری، تفکیک سطح یک از سایر بیماران و تمایز میان سطوح دو و سه را نمایش می‌دهد.

¹ One-Versus-One



است. چارچوب پیشنهادی این پژوهش، دقیقاً با هدف حل این تناقض فنی و فراهم‌سازی امکان آموزش پایدار مدل‌های عمیق در شرایط پویای محدودیت داده توسعه یافته است.



جدول (۷) - مقدار صحت، آموزش شبکه‌ی سایمیز چند کلاسه با هسته‌ی DLC سه لایه در تعیین سطح بیماری پارکینسون

نوع حرکت	صحت
راه رفتن	٪۷۷/۴۹
چرخش دست راست	٪۷۳/۷۵
چرخش دست چپ	٪۷۹/۰۷

بخش قابل توجهی از پژوهش‌های پیشین به دلیل فقدان داده‌ها عمومی و معتبر، از داده‌های اختصاصی و محدود خود برای آموزش و ارزیابی مدل‌ها بهره برده‌اند. این ناهمگنی در طراحی آزمایش، نوع فعالیت‌ها، پروتکل‌های ثبت، تعداد بیماران و معیارهای ارزیابی، مقایسه‌ی مستقیم عملکرد مدل‌ها را با چالش مواجه می‌سازد. بنابراین، انجام یک مقایسه‌ی کاملاً هم‌تراز میان روش پیشنهادی و تمامی رویکردهای موجود، به لحاظ تجربی امکان‌پذیر نیست. با این وجود، جدول (۸) مجموعه‌ای از مطالعات منتخب را که از نظر نوع حسگر، سناریوی حرکتی یا هدف تشخیصی بیشترین شباهت را به این پژوهش دارند، ارائه می‌کند. بر اساس نتایج گزارش شده، استفاده از روش‌های مبتنی بر یادگیری ماشین و رویکردهای یادگیری جمعی (Ensemble Learning) در سایر مطالعات، در بخش تشخیص پارکینسون صحت‌هایی در بازه‌ی تقریبی ۷۴ تا ۸۶ درصد را به

به‌منظور تحلیل دقیق این وابستگی، در شکل (۱۶) خطای آموزش و آزمون هر یک از زوج کلاس‌ها به صورت مستقل (ستون اول تا چهارم)، در کنار خطای کلی تشخیص سطح بیماری پارکینسون (ستون اول) ترسیم شده است. نتایج نشان می‌دهد که کاهش خطای شبکه‌ی تشخیص بیماران پارکینسونی از افراد سالم، به طور مستقیم منجر به بهبود صحت در تعیین سطح بیماری (ستون اول) می‌شود. این وابستگی برای سایر مراحل طبقه‌بندی نیز مشاهده می‌شود. در نتیجه، ممکن است یک زوج کلاس به خوبی آموزش داده شده باشند، اما به دلیل ضعف در مرحله‌ی پیش از آن‌ها، عملکرد کلی سیستم همچنان محدود باقی بماند. از این رو، صحت نهایی سیستم در صورت آموزش هم‌زمان و هماهنگ هر سه شبکه‌ی سایمیز انجام می‌شود. با گذشت حدود ۳۰۰ چرخه‌ی آموزش هر سه شبکه کاملاً پایدار و آموزش دیده‌اند.

شکل (۱۷) نتایج و همچنین ماتریس برهم‌ریختگی حاصل از طبقه‌بندی سطوح متفاوت پارکینسون را نمایش می‌دهد. با توجه به این شکل، هر یک از سه شبکه در آموزش و طبقه‌بندی بخش خود با صحت قابل قبولی آموزش دیده‌اند. با این حال، هر سه شبکه در تمامی حرکت‌ها دارای دقت بسیار بالاتری از صحت هستند. جدول (۷) نیز صحت طبقه‌بند چهار کلاسه‌ی سیستم پیشنهادی را نمایش می‌دهد. با وجود آن‌که تمامی شبکه‌های سایمیز در مرحله‌ی آموزش و آزمون دو کلاسه به صحتی بالاتر از ٪۸۰ دست یافته‌اند (مطابق با شکل (۱۷))، در حالت چهارکلاسه به دلیل انباشت خطا در ساختار سلسله مراتبی، صحت نهایی طبقه‌بندی در هر سه حرکت به مقادیری حدود ٪۸۰ کاهش یافته است. این کاهش عملکرد بیانگر اثر مستقیم انتقال خطا از یک مرحله به مرحله‌ی دیگر در فرآیند تصمیم‌گیری چند مرحله‌ای است. باید دقت داشت که این نتایج تنها بر اساس یک پنجره‌ی کوتاه زمانی بدست آمده است که بیانگر غنای ویژگی‌های استخراج شده در بخش HUF می‌باشد.

۶- مقایسه با پژوهش‌های پیشین

مجموعه دادگان بالینی PD-BiostampRC21 به دلیل ثبت هم‌زمان سیگنال‌های حرکتی از موقعیت‌های آناتومیکی متعدد، در فاز تحلیل در زمره‌ی موارد پردازشی بسیار سنگین قرار می‌گیرد که استخراج الگوهای پنهان و نوسانی آن، نیازمند به‌کارگیری روشهایی همانند یادگیری عمیق است. با این حال، این دادگان با چالش محدودیت در تعداد نمونه‌های دارای برچسب آموزش مواجه است. این تقابل سبب توجه کمتر به استفاده از مدل‌های یادگیری عمیق در رویکردهای پیشین شده

معماری سلسله مراتبی HUF در کنار طبقه‌بند مقایسه‌ای سایامیز، توانایی بالایی در غلبه بر پیچیدگی‌های این دادگان چالش‌برانگیز دارد.

همراه داشته است. در مقایسه با این مطالعات، رویکرد پیشنهادی این پژوهش با دستیابی به صحت ۹۳/۱٪ در حرکت چرخش مچ دست راست و ۹۰/۸٪ در حرکت راه‌رفتن، عملکردی کاملاً برتر ارائه می‌دهد. این نتایج ثابت می‌کند که

جدول (۸) - مقایسه‌ی روش‌های ارائه شده بر روی دیگر داده‌ها پارکینسون با روش بدون سرپرستی پیشنهادی HUF و طبقه‌بندی مقایسه‌ای - PS = چرخش مچ دستان

مرجع	نوع حسگر	نوع حرکت	روش	نوع یادگیری	تعداد کلاس‌ها	صحت
[۴۰]	IMU مچی	راه رفتن	ویژگی دستی + CNN	نظارتی	۲	۸۵٪
[۲۴]	IMU متصل به کمر	راه رفتن و گردش ۱۸۰ درجه	SWS ^۱ نه لایه CNN	نظارتی	۲	۸۹٪
[۳۸]	شتاب‌سنج*	راه رفتن، چرخش مچ دستان	ویژگی آماری	-	۲	$p = ۰/۰۴$
[۴۱]	شتاب‌سنج	لرزش در حین راه رفتن	ویژگی آماری	نظارتی	۲	۸۷٪
[۴۲]	الکترومایوگرام ^۲	لرزش در حین راه رفتن	ویژگی آماری	نظارتی	۲	۹۰/۲٪
-	شتاب‌سنج	راه رفتن، PS-راست، PS-چپ	HUF and Siamese CF	بدون نظارتی - مقایسه‌ای	۲	۹۰/۸٪ = راه رفتن ۹۳/۱٪ = PS - راست ۸۶/۰٪ = PS - چپ
-	شتاب‌سنج	راه رفتن، PS-راست، PS-چپ	HUF and Siamese CF	بدون نظارتی - مقایسه‌ای	۴	۷۷/۴۹٪ = راه رفتن ۷۳/۸٪ = PS - راست ۷۹/۰۷٪ = PS - چپ

بیماری پارکینسون ارائه دادیم. در گام استخراج ویژگی، نسخه‌ی اصلاح شده‌ی مدل HUF به‌عنوان یک روش بدون ناظر برای استخراج و ادغام ویژگی‌های حرکتی از سیگنال‌های IMU معرفی گردید. این مدل با بهره‌گیری از ادغام چند منبعی ویژگی‌ها و استفاده از ساختار -

های خودرمنگار، توانست نمایش‌هایی پایدار و غنی از الگوهای حرکتی تولید کند؛ به‌گونه‌ای که حتی در شرایط کمبود داده‌ها افت عملکرد محدودی داشته باشد.

در ادامه، به منظور غلبه بر محدودیت‌های روش‌های متداول طبقه‌بندی نظیر DLC در شرایط داده‌ها اندک، یک رویکرد نوین مبتنی بر شبکه‌های سایامیز و فرایادگیری برای طبقه‌بندی ویژگی‌ها پیشنهاد شد. برخلاف طبقه‌بندهای مرسوم که مستقیماً به برچسب کلاس‌ها در فرآیند آموزش وابسته‌اند، ایده‌ی مطرح شده در این پژوهش بر یادگیری شباهت بین نمونه‌ها استوار است. در این چارچوب، شبکه‌ی سایامیز بدون اتکا به استفاده‌ی مستقیم از برچسب‌های کلاسی، با یادگیری

در سناریوی طبقه‌بندی چندکلاسه نیز، مدل پیشنهادی در مقایسه با اغلب روش‌های گزارش شده، عملکرد برتری ارائه می‌دهد که این امر بیانگر قابلیت تعمیم‌پذیری چارچوب سلسله مراتبی و مبتنی بر شباهت آن در تفکیک سطوح مختلف شدت بیماری است. شایان ذکر است که مطالعات علامت‌گذاری شده با ستاره در جدول، از داده‌ها PD-BIOSTAMP استفاده کرده‌اند؛ با این حال، نتایج به دست آمده در چارچوب پیشنهادی در تمامی این موارد برتر گزارش شده است. این برتری را می‌توان به بهره‌گیری از استخراج ویژگی بدون نظارت، ساختار سلسله مراتبی و راهبرد فرایادگیری نسبت داد که امکان یادگیری موثر در شرایط داده‌ی محدود و برچسب‌گذاری ناقص را فراهم می‌کند.

۷- نتیجه‌گیری

در این مقاله، یک چارچوب جامع برای استخراج، ادغام و طبقه‌بندی ویژگی‌های حرکتی با هدف تشخیص و تعیین سطح

^۱ Spectral Window stacked Representation

^۲ Electromyography

[10] Z. Lin *et al.*, "Quantification of parkinsonian bradykinesia based on axis-angle representation and SVM multiclass classification method," *IEEE Access*, vol. 6, pp. 26895-26903, 2018.

[11] S. Memar, M. Delrobaei, M. Pieterman, K. McIsaac, and M. Jog, "Quantification of whole-body bradykinesia in Parkinson's disease participants using multiple inertial sensors," *Journal of the neurological sciences*, vol. 387, pp. 157-165, 2018.

[12] M. D. Hssayeni, M. A. Burack, J. Jimenez-Shahed, and B. Ghoraani, "Wearable-based Mediation State Detection in Individuals with Parkinson's Disease," *arXiv preprint arXiv:1809.06973*, 2018.

[13] S. Aghanavasi, F. Bergquist, D. Nyholm, M. Senek, and M. Memedi, "Motion sensor-based assessment of Parkinson's disease motor symptoms during leg agility tests: results from levodopa challenge," *IEEE journal of biomedical and health informatics*, vol. 24, no. 1, pp. 111-119, 2019.

[۱۴] س. ع. ز. نسری، "تشخیص بیماری پارکینسون و طبقه‌بندی سطح بیماری بر پایه معیار MDS-UPDRS استفاده از دادگان شتاب،" کارشناسی ارشد کارشناسی ارشد، مهندسی پزشکی، امیرکبیر، بیوالکترونیک، ۱۳۹۷-۲۰۱۸.

[15] H. B. Kim *et al.*, "Wrist sensor-based tremor severity quantification in Parkinson's disease using convolutional neural network," *Computers in biology and medicine*, vol. 95, pp. 140-146, 2018.

[16] M. D. Hssayeni, J. Jimenez-Shahed, M. A. Burack, and B. Ghoraani, "Ensemble deep model for continuous estimation of Unified Parkinson's Disease Rating Scale III," *Biomedical engineering online*, vol. 20, no. 1, pp. 1-20, 2021.

[17] S. Arabzadeh, F. Almasganj, and M. M. Ahmadi, "CNN Autoencoders for Hierarchical Feature Extraction and Fusion in Multi-sensor Human Activity Recognition," *arXiv preprint arXiv:2502.04489*, 2025.

[18] L. Di Biase *et al.*, "Quantitative analysis of bradykinesia and rigidity in Parkinson's disease," *Frontiers in neurology*, vol. 9, p. 121, 2018.

[19] M. Bertoli, U. Della Croce, A. Cereatti, and M. Mancini, "Objective measures to investigate turning impairments and freezing of gait in people with Parkinson's disease," *Gait & posture*, vol. 74, pp. 187-193, 2019.

[۲۰] م. سلجوقی و پ. قادریان، "تشخیص بیماری‌های عصبی پیش‌رونده‌ی تدریجی با استفاده از ویژگی‌های زمان-فرکانسی متقارن سیگنال راه رفتن،" نشریه علمی مهندسی پزشکی زیستی، vol. 15, no. 1, pp. 59-71, 2021, doi: 10.22041/ijbme.2021.141428.1645.

[۲۱] ع. مالکی و ن. منفرد جهرمی، "طبقه‌بندی بیماری‌های نورودیجنریتیو با استفاده از تحلیل کمی بازگشتی سیگنال راه رفتن،" نشریه علمی مهندسی پزشکی زیستی، vol. 19, no. 2, pp. 245-258, 2025, doi: 10.210.22041/ijbme.2025.2052006.1953۲۰۴۱.

[۲۲] ح. حسینی و ع. مالکی، "اثر پیش‌رفت بیماری پارکینسون بر ویژگی‌های آشوبی RQA،" نشریه علمی مهندسی پزشکی زیستی، vol. 16, no. 3, pp. 207-218, 2022, doi: 10.22041/ijbme.2022.560449.1793.

[۲۳] ع. طالش جفادی و ا. زارعی، "روشی نوین در تشخیص بیماری پارکینسون: کمی‌سازی بازگشت مبتنی بر سیگنال‌های الکتروانسفالوگرافی و یادگیری ماشین،" نشریه علمی مهندسی پزشکی زیستی، vol. 18, no. 3, pp. 259-271, 2024, doi: 10.22041/ijbme.2025.2052278.1956.

[24] J. Camps *et al.*, "Deep learning for freezing of gait detection in Parkinson's disease patients in their homes using a waist-worn inertial measurement unit," *Knowledge-Based Systems*, vol. 139, pp. 119-131, 2018.

[25] L. Tong, J. He, and L. Peng, "CNN-based PD hand tremor detection using inertial sensors," *IEEE Sensors Letters*, vol. 5, no. 7, pp. 1-4, 2021.

[26] M. D. Hssayeni, J. Jimenez-Shahed, M. A. Burack, and B. Ghoraani, "Symptom-based, Dual-channel LSTM Network for The Estimation of Unified Parkinson's Disease Rating Scale III," in *2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 2019: IEEE, pp. 1-4.

[27] A. H. Butt, F. Cavallo, C. Maremmani, and E. Rovini, "Biomechanical parameters assessment for the classification of Parkinson disease using bidirectional long short-term memory," in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2020: IEEE, pp. 5761-5764.

یک تابع شباهت، به مقایسه‌ی بازنمایی‌های ویژگی استخراج‌شده توسط مدل HUF نسبت به یک مجموعه‌ی مرجع می‌پردازد و میزان نزدیکی یا تمایز میان آن‌ها را برآورد می‌کند. این ایده با تعمیم به یک طبقه‌بند چند کلاسه‌ی سلسله‌مراتبی، امکان تشخیص بیماری پارکینسون و تعیین سطوح مختلف آن را فراهم می‌سازد. ساختار پیشنهادی با تفکیک مساله‌ی چندکلاسه به چند تصمیم دوتایی مستقل، ضمن کاهش پیچیدگی آموزش، قابلیت تطبیق بالاتری با داده‌ها نامتوازن و محدود را نشان داده است. تحلیل ماتریس‌های درهم‌ریختگی و نتایج تجربی بیانگر آن است که عملکرد این طبقه‌بند به‌طور قابل توجهی به غنای مجموعه‌های مقایسه‌ای وابسته است؛ به‌گونه‌ای که انتخاب مناسب نمونه‌های مرجع نقش کلیدی در کاهش خطای انباشته و افزایش صحت نهایی ایفا می‌کند. نتایج این پژوهش نشان می‌دهد که ترکیب استخراج ویژگی بدون ناظر با مدل اصلاح شده‌ی HUF و طبقه‌بندی مبتنی بر یادگیری شباهت در شبکه‌های سایامیز، چارچوبی کارآمد و قابل تعمیم برای تحلیل حرکات انسانی و تشخیص بیماری‌های عصبی فراهم می‌آورد. این رویکرد به‌ویژه در کاربردهایی با محدودیت داده‌های برچسب‌دار، می‌تواند جایگزین مناسبی برای روش‌های کلاسیک طبقه‌بندی باشد.

۱- مراجع

[1] L. V. Kalia and A. E. Lang, "Parkinson's disease," *The lancet*, vol. 386, no. 9996, pp. 896-912, 2015.

[2] E. R. Dorsey *et al.*, "Global, regional, and national burden of Parkinson's disease, 1990–2016: a systematic analysis for the Global Burden of Disease Study 2016," *The Lancet Neurology*, vol. 17, no. 11, pp. 939-953, 2018.

[3] J. Jankovic, "Parkinson's disease: clinical features and diagnosis," *Journal of neurology, neurosurgery & psychiatry*, vol. 79, no. 4, pp. 368-376, 2008.

[4] R. B. Postuma *et al.*, "MDS clinical diagnostic criteria for Parkinson's disease," *Movement disorders*, vol. 30, no. 12, pp. 1591-1601, 2015.

[5] S. Dosen *et al.*, "Online tremor suppression using electromyography and low-level electrical stimulation," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 23, no. 3, pp. 385-395, 2014.

[6] G. Vivar, D.-L. Almanza-Ojeda, I. Cheng, J. C. Gomez, J. Andrade-Lucio, and M.-A. Ibarra-Manzano, "Contrast and Homogeneity Feature Analysis for Classifying Tremor Levels in Parkinson's Disease Patients," *Sensors*, vol. 19, no. 9, p. 2072, 2019.

[7] N. Kostikis, D. Hristu-Varsakelis, M. Arnaoutoglou, and C. Kotsavasiloglou, "A smartphone-based tool for assessing parkinsonian hand tremor," *IEEE journal of biomedical and health informatics*, vol. 19, no. 6, pp. 1835-1842, 2015.

[8] M. Lang *et al.*, "A Multi-Layer Gaussian Process for Motor Symptom Estimation in People With Parkinson's Disease," *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 11, pp. 3038-3049, 2019.

[9] C. L. Pulliam, D. A. Heldman, E. B. Brokaw, T. O. Mera, Z. K. Mari, and M. A. Burack, "Continuous assessment of levodopa response in parkinson's disease using wearable motion sensors," *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 1, pp. 15, ۱۶۴-۹, ۲۰۱۷.



- [28] A. S. AV, M. A. Lones, S. L. Smith, and M. Vallejo, "Evaluation of Recurrent Neural Network Models for Parkinson's Disease Classification Using Drawing Data," in *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2021: IEEE, pp. 1702-1706 .
- [29] A. B. Oktay and A. Kocer, "Differential diagnosis of Parkinson and essential tremor with convolutional LSTM networks," *Biomedical Signal Processing and Control*, vol. 56, p. 101683, 2020.
- [30] R. Guo, H. Li, C. Zhang, and X. Qian, "A tree-structure-guided graph convolutional network with contrastive learning for the assessment of parkinsonian hand movements," *Medical Image Analysis*, vol. 81, p. 102560, 2022.
- [31] R. Miao, S. Shokur, A. C. D. L. Pardini, D. Boari, and M. Bouri, "Detecting Freezing of Gait in Parkinson's Disease Patient via Deep Residual Network," in *2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 2021: IEEE, pp. 320-325 .
- [32] R. Bajpai, S. Khare, and D. Joshi, "A multimodal model-fusion approach for improved prediction of freezing of gait in Parkinson's disease," *IEEE Sensors Journal*, vol. 23, no. 14, pp. 16168-16175, 2023.
- [33] Y. Bengio, "Learning Deep Architectures for AI," ed: Now Publishers Inc, 2009.
- [34] S. Ioffe, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *arXiv preprint arXiv:1502.03167*, 2015.
- [35] T. Hur, J. Bang, T. Huynh-The, J. Lee, J.-I. Kim, and S. Lee, "Iss2Image: A novel signal-encoding technique for CNN-based human activity recognition," *Sensors*, vol. 18, no. 11, p. 3910, 2018.
- [36] G. Koch, R. Zemel, and R. Salakhutdinov, "Siamese neural networks for one-shot image recognition," in *ICML deep learning workshop*, 2015, vol. 2, no. 1: Lille, pp. 1-30 .
- [37] R. Hadsell, S. Chopra, and Y. LeCun, "Dimensionality reduction by learning an invariant mapping," in *2006 IEEE computer society conference on computer vision and pattern recognition (CVPR'06)*, 2006, vol. 2: IEEE, pp. 1735-1742 .
- [38] J. L. Adams *et al.*, "A real-world study of wearable sensors in Parkinson's disease," *npj Parkinson's Disease*, vol. 7, no. 1, p. 106, 2021.
- [39] J. L. Adams *et al.*, "Pd-biostampc21: Parkinson's disease accelerometry dataset from five wearable sensor study," *IEEE Dataport*, vol. 10, pp. g2g8-1503, 2020. [Online]. Available: <https://dx.doi.org/10.21204/g2g8-1503>.
- [40] N. Y. Hammerla, S. Halloran, and T. Plötz, "Deep, convolutional, and recurrent models for human activity recognition using wearables," *arXiv preprint arXiv:1604.08880*, 2016.
- [41] S. Hur, J. Zhang, M.-H. Kim, and T.-M. Chung, "Real-world parkinson's hand tremor detection using ensemble learning techniques," *IEEE Access*, 2025.
- [42] L. Igene, A. Alim, M. H. Imtiaz, and S. Schuckers, "A machine learning model for early prediction of parkinson's disease from wearable sensors," in *2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)*, 2023: IEEE, pp. 0734-0737 .