

شناسایی بیماری های تخریب عصبی بر مبنای مدل خودبازگشتی چند متغیره سیگنال گیت و هم جوشی در طبقه بندهای هوشمند

پویا قلیان محمدی^۱، دکتر محمدرضا یوسفی^۲*

۱- دانشکده مهندسی برق، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

puyagholian96@gmail.com

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

*mr-yousefi@iaun.ac.ir

چکیده

تشخیص بیماری ها به کمک روش های جدید بسیار مورد توجه قرار گرفته است. یکی از این بیماری ها، بیماری اسکلروز جانبی آمیوتروفیک است. در این بیماری نورون های باعث تخریب پیشرونده و غیرقابل ترمیم در دستگاه عصبی مرکزی (مغز و نخاع) و دستگاه عصبی محیطی می شود علائم نورون محرکه فوقانی و هم نشانه های نورون محرکه تحتانی دیده می شود. تشخیص این بیماری از داده های آنالیز دینامیک حرکتی امکان پذیر است. روش های کلینیکی در تخیص این بیماری با خطای قابل توجهی مواجه هستند. روش های مبتنی بر یادگیری ماشین یک راه کار موثر در تشخیص این بیماری ها هستند. روش پیشنهاد شده این تحقیق شامل پنج مرحله است. پیش پردازش، استخراج ویژگی، کاهش بعد، طبقه بندی و ارزیابی. نوآوری این مقاله در به کار گیری همجوشی طبقه بندها در تشخیص این بیماری است. در همجوشی طبقه بندها، انواع طبقه بندهای خطی و غیر خطی در یک روش همجوشی با یکدیگر، بیماری را با دقت بالاتری تشخیص خواهند داد. کلمات کلیدی: بیماری های انحطاط عصبی، آنالیز دینامیک راه رفتن، طبقه بندی، آنالیز مؤلفه های اصلی، همجوشی طبقه بندها

۱- مقدمه

روش های تشخیص بیماری های انحطاط عصبی در محیط های کلینیکی بیشتر به صورت کیفی است به صورتی که تشخیص این دسته از بیماری ها محدود به ترسیم شکل های هندسی مدور (نظیر دایره یا بیضی)، شکستن گردو و یا انجام اعمال ریتمیک است. مطالعاتی که در حوزه شناسایی بیمارهای انحطاط عصبی هستند، اگرچه در حال رشد هستند؛ اما همچنان در مراحل اولیه از لحاظ پردازشی هستند. به نظر می رسد هیچ روش خاص پیش پردازش و کاهش نویز برای این نوع از سیگنال در مطالعات، باتوجه به ناشناخته ماندن محدوده فرکانسی و منابع نویز در مراحل اولیه هستند.

به دست آوردن حرکت های انشان یکی از مهم ترین تحقیق در بیومکانیک است. در قدیم برای کشف بیماری های مربوط به اسکلت و ماهیچه و همچنین توانبخشی استفاده می شود. با وجود تحلیل حرکت در بیمارستان ها و مراکز درمانی بسیار مفید است. استفاده از تحلیل راه رفتن در بیمارستان ها و مراکز درمانی بسیار محدود است و رشد قابل توجهی نداشته است. لازم به ذکر است که استفاه از روش های تحلیل حرکت در این مراکز بسیار ارزشمند است. از یک طرف دیگر در هزینه و زمان جمع آوری و پردازش و تفسیر داده ها به صرفه جویی خواهد شد. برای تشخیص بیماری های مربوط به راه رفتن می بایست در ابتدا پارامترهای لازم برای

بررسی حرکت اسنان به دست آید و هم چنین در رابطه با مشکلات و مسائل راه رفتن دانش کسب شود [۱]. اگر به راه رفتن افراد دقت کنیم خواهیم دید که علی رغم اینکه حرکت و راه رفتن اتوماتیک به نظر می‌رسد. اما پیچیده است. برای این منظور دست‌ها را عقب و جلو برده و تقریباً با یک آهنگ قدم بر می‌دارند. در این میان عده‌ی محدودی هم وجود دارند که نوع راه رفتن آن‌ها متفاوت است و در واقع قادر نیستند مانند افراد عادی راه بروند. به این مسئله و مشکل راه رفتن^۱ گویند. در واقع در میان انواع مدل‌های متفاوت راه رفتن تنها یک مدل صحیح می‌باشد. به منظور سازماندهی مدل‌ها هر چند تا از آن‌ها در یک گروه خاص گنجانده شده‌اند [۲].

بیماری‌های نورودژنراتیو یکی از پیچیده‌ترین و شایع‌ترین بیماری‌های عصبی هستند که در دهه اخیر از جنبه‌های مختلف حرکتی و شناختی مورد بررسی قرار گرفته‌اند. تشخیص به هنگام این عوارض می‌تواند در درمان سریع‌تر کمک شایانی کند لذا لازم است روشی پیشنهاد شود که اولاً از نظر بار هزینه‌ی غربالگری مناسب و بهینه باشد و ثانیاً تفکیک پذیری روش برای کلاس‌های مختلف از بیماری‌ها در مقایسه با گروه کنترل معنادار باشد. در این مطالعه سعی می‌شود یک تکنیک بهینه مبتنی بر استخراج ویژگی‌های زمانی، فرکانسی، آماری و غیرخطی و کاربرد طبقه بندی‌های خطی و غیرخطی برای سیگنال دینامیک راه رفتن ارائه شود. در این مطالعه به بررسی و تعیین ویژگی‌های مناسب برای طبقه بندی کننده‌های خطی و غیر خطی پرداخته می‌شود و با این حال تلاش می‌شود ملزومات دیگر مراحل به نحوی برآورده شود که نتیجه‌ی مطلوب به دست آید.

همچنین آنالیزهای انجام شده در حوزه‌ی پردازش سیگنال راه رفتن محدود به پردازش‌های زمانی است که حساس به نویز هستند و به آنالیز این سیگنال در حوزه‌ی زمان-فرکانس و غیرخطی کم‌تر پرداخته شده است. همچنین روش‌های کاهش بعد ویژگی‌ها به عنوان یک ابزار در افزایش سرعت و دقت طبقه بندی و افزایش تفکیک پذیری کم‌تر مورد توجه قرار گرفته است. در نهایت ساختارهای طبقه بندی خطی و غیرخطی در یک مجموعه و یا یک ساختار شورایی به صورت تطبیقی مورد ارزیابی نشده‌اند [۳]

دینامیک راه رفتن توسط سیستم عصبی تنظیم می‌شود. اعتقاد بر این است که حلقه‌ی نظارتی بازخورد از یک سیستم فیزیولوژیک در مقیاس‌های زمانی و مکانی لازم است، تا قادر به انطباق با محیط باشد [۴]. بنابراین سری زمانی فواصل گام برداشتن، می‌تواند نمایشی از این قدرت انطباق در شرایط مختلف باشد [۵]. در مطالعات اخیر، ابزارهای تشخیصی مبتنی بر کامپیوتر برای اندازه گیری پارامترهای فاصله راه رفتن در بزرگسالان سالم و همچنین برای توصیف ویژگی‌های متمایز از راه رفتن در بیماران مبتلا به عارضه‌ی انحطاط عصبی استفاده شده است.

در [۶] سری زمانی گام برداشتن مستخرج از سیگنال راه رفتن را به صورت توالی از نمادها^۲ (یعنی تبدیل فواصل راه رفتن به صورت مجموعه‌ای از نمادها و علائم) نمایش دادند. آن‌ها سپس از یک آستانه وابسته به اعمال روش آنتروپی نمادین به منظور تحلیل پیچیدگی راه رفتن بهره جستند. در [۷] از مدل (SCPG^۳) برای شبیه سازی دینامیک راه رفتن انسان، و همچنین ارزیابی ویژگی‌های تصادفی و آشوبگونه راه رفتن در بیماران مبتلا به اسکروز جانبی آمیوتروفیک، هانتینگتون و پارکینسون استفاده کردند. در [۸] یک روش تجزیه و تحلیل آماری برای طبقه بندی راه رفتن افراد مبتلا به اسکروز جانبی آمیوتروفیک و افراد سالم ارائه کردند. در روش پیشنهادی ایشان، تابع چگالی احتمال آهنگ راه رفتن با استفاده از روش پنجره پارزن^۴ تخمین زده شد و پس از آن دیورژانس Kullback-Leibler استخراج شد. در [۹] فرض شده است که تعداد نوسانات فواصل

¹ Gait problem

² Symbols

³ Super Central Pattern Generator

⁴ Parzen Window

گام برداشتن در بیماران مبتلا به اسکروز جانبی آمیوتروفیک با افراد سالم متفاوت است. در [۱۰] دقت طبقه بندی ۸۹.۶۶ درصد را برای طبقه بندی افراد سالم و افراد مبتلا به اسکروز جانبی آمیوتروفیک به همراه داشت. در [۱۱] عدم تقارن راه رفتن را در بیماران مبتلا به عارضه‌ی انحطاط عصبی با استفاده از تجزیه و تحلیل آنتروپی چند نرخه از نوسانات زمان گام مورد بررسی قرار دادند. در [۱۲] برای آنالیز الگوها و طبقه‌بندی، ماشین بردار پشتیبان (SVM) برای متمایز کردن افراد سالم از بیماران مبتلا به بیماری پارکینسون، بیماری هانتینگتون و اسکروز جانبی آمیوتروفیک به کار برده شده است. نتایج این مطالعه نشان داد که تنها با استفاده از فواصل زمانی گام برداشتن، می‌توان از این نگاشت برای طبقه بندی کلاس‌های بیماری‌های انحطاط عصبی بهره جست.

از جمع بندی مطالعات محققان می‌توان چنین نتیجه گرفت که خلاء اساسی مطالعات، در نحوه‌ی پیش پردازش داده‌ها، عدم بررسی و پردازش بهینه‌ی سیگنال در حوزه‌ی تبدیل و عدم بررسی روش‌های ترکیب در سطح ویژگی‌ها و در سطح طبقه بندهاست. نوآوری‌های این مقاله عبارت است از:

۱. پیش پردازش بهینه‌ی سیگنال راه رفتن به صورتی که الگوهای زمانی و فرکانسی و بهبود شاخص نسبت سیگنال به نویز است.
۲. استفاده از آنالیز مؤلفه‌های اصلی در کاهش تعداد ویژگی‌ها بر مبنای آنالیز مؤلفه‌های اصلی که پیش از این بیش تر بر مبنای تست‌های آماری بوده است.
۳. ترکیب در سطح طبقه بندهای هوشمند در قالب یک سامانه‌ی ماشین شورایی که پیش تر از الگوهای طبقه بندی تک تصمیم گیر بوده است.

ساختار این مقاله در ادامه به صورت زیر است. در بخش ۲ روش‌های همجوشی ارائه خواهد شد. در بخش ۳ روش پیشنهاد شده مورد بررسی قرار خواهد گرفت. در بخش ۴ ارزیابی طبقه بندی‌ها انجام خواهد شد. در نهایت در بخش ۵ نتیجه گیری مقاله ارائه می‌شود.

۲- همجوشی طبقه بندها

به منظور بهبود دقت یادگیری، می‌توان نتایج طبقه بندهای مختلف را با هم ترکیب نمود و یک سیستم شورایی بوجود آورد. در واقع به کارگیری نتایج چند طبقه بند با عنوان یادگیری دسته جمعی یک راهکار مؤثر در بهبود عملکرد سیستم‌های شناسایی به حساب می‌آید. در ابتدا باید طبقه بندهای پایه‌ی مناسبی (نوع و تعداد) انتخاب شوند. سپس خروجی طبقه بندها به نحوی ترکیب شوند که بهترین نتیجه برای طبقه بندی الگوها حاصل گردد. نکته‌ی قابل توجه در ایجاد طبقه بندهای پایه، گوناگونی در خطای هر طبقه بند نسبت به دیگری به منظور بهبود نرخ بازشناسی سیستم کلی است. همچنین ویژگی‌های هر طبقه بند باید به نحوی انتخاب گردد که نرخ بازشناسی آن طبقه بند به تنهایی قابل قبول باشد. با توجه به کاربرد و نیازمندی‌های مسأله، نوع طبقه بندها، تعداد آنها و تعیین نحوه ترکیب خروجی انتخاب می‌شود. هدف اصلی پیشینه بودن نرخ بازشناسی سیستم طبقه بندی ترکیبی است. در مسأله‌ی تشخیص الگو، ترکیب طبقه بندها و ویژگی‌ها اهمیت ویژه‌ای دارد. با توجه به متعدد بودن قواعد برای ترکیب ویژگی‌ها یا نتایج خروجی طبقه بندها، می‌توان به چند دیدگاه اشاره کرد [۲۳].

الف: قدرت بازشناسایی الگوها در هر طبقه بند محدود است؛ بنابراین نمی‌توان طبقه بندی یافت که در تمام شرایط قادر به تشخیص صحیح کلیه‌ی الگوها باشد. از این رو به دلیل عدم توانایی برآورده کردن نرخ بازشناسی مورد نیاز توسط یک طبقه بند، ترکیب چند طبقه بند برای یک کاربرد خاص نیاز است.

ب: هر الگو با توجه به ویژگی‌های مختلفی که در سیگنال ایجاد می‌کند، می‌تواند به صورت‌های متفاوتی بازمی‌نماید. به این منظور بازشناسی هر الگو معمولاً نیازمند استخراج ویژگی‌های متفاوت است.

به استخراج برخی ویژگیها، منجر به پیدایش یک بردار ویژگی بزرگ می‌شود. تحلیل بردارهای ویژگی بزرگ توسط یک طبقه بند، زمان پردازش را بسیار طولانی می‌کند. این موضوع در کاربردهایی نظیر سیستمهای بیومتریکی مشکل ایجاد می‌کند. ترکیب طبقه بندها، این امکان را فراهم می‌آورد که بردارهای ویژگی با ابعاد بزرگ به بردارهای کوچکتری تقسیم شده و با طبقه بندهای کوچکتر و ساده‌تر به صورت همزمان پردازش شوند. طبقه بندی نهایی با ترکیب نتایج این طبقه بندها صورت می‌گیرد [۱۳]. در واقع کارایی سیستم تشخیص الگو مخصوصاً در مورد الگوهای پیچیده با استفاده از ترکیب نتایج طبقه بندها بهبود می‌یابد.

روش‌های ترکیب واحدهای طبقه بندی^۱

یک ترکیب خودش الگوریتم یادگیری تحت نظارت است، زیرا می‌توان آن را آموزش داد و سپس برای پیش بینی استفاده کرد. می‌توان نشان داد ترکیبها، انعطاف پذیری بیشتری در عملکردهایی که می‌توانند ارائه کنند دارند. این انعطاف پذیری در علم نظری آنها را قادر می‌سازد تا یک مدل را برای داده‌های آموزشی استفاده شده بیش از حد مناسب کنند. اما در عمل بعضی از روش‌های ترکیب (مخصوصاً bagging) تمایل به کاهش مشکلات مربوط به over-fitting داده‌های آموزشی دارند [۱۱].

به طور تجربی، ترکیبها تمایل دارند نتایج بهتری را زمانی که تنوع قابل توجهی در مدل‌ها وجود دارد، ارائه کنند [۱۲]. بنابراین، بسیاری از روش‌های ترکیب به دنبال ترویج تنوع در میان مدل‌های آنها هستند. نشان داده شده است استفاده از انواع مختلف الگوریتم‌های یادگیری قوی، اثربخشی بیشتری نسبت به استفاده تکنیک‌هایی که می‌کوشد مدل‌ها را به منظور ترویج تنوع ساده کنند، دارد [۱۲]. بعضی از روشهای رایج ترکیبها شامل: طبقه بندی مطلوب بیز^۲، (bagging) Bootstrap aggregating، Boosting، Adaboost و غیره هستند؛ که در این مطالعه از bagging و boosting وزیرمجموعه‌های آن‌ها استفاده شده است.

پشته سازی

عبارت پشته سازی^۳ از bootstrap aggregation آمده است. همان طور که اسم آن نشان می‌دهد دو عنصر مهم bagging شامل بوت استرپ^۴ و تجمیع^۵ است. می‌دانیم که ترکیب یادگیرنده‌های پایه‌ی مستقل منجر به کاهش چشمگیر خطاها می‌شود؛ از این رو می‌خواهیم یادگیرنده‌های پایه تا حد ممکن مستقل باشند. نمونه برداری از تعدادی از زیرمجموعه‌های داده‌های غیر همپوشان و سپس آموزش یادگیرنده پایه از هر زیر مجموعه راهکاری در این راستا می‌باشد. اما از آنجایی که ما اطلاعات آموزشی بی نهایت نداریم، چنین فرآیندی به نمونه‌های بسیار کوچک که منجر به عملکرد پایین یادگیرنده‌های پایه می‌شود، منجر می‌شود [۱۳].

Bagging به طور دقیق، با دادن مجموعه داده‌های آموزشی که حاوی m نمونه آموزشی است، یک زیر مجموعه از مجموعه داده‌ی اصلی به هر کدام از طبقه بندها داده می‌شود. یعنی هر طبقه بند یک قسمت از مجموعه‌ی داده را مشاهده کرده و باید مدل خود را بر اساس همان قسمت از داده‌ها که در اختیارش قرار گرفته است، بسازد (یعنی کل دیتاست به هر کدام از طبقه بندها داده نمی‌شود). در واقع برای هر کدام از طبقه بندها، یک زیرمجموعه از داده‌های اصلی انتخاب می‌شود که انتخاب این زیر مجموعه با جایگزینی خواهد

¹ Ensemble methods

² Bayes optimal classifier

³ bagging

⁴ bootstrapt

⁵ aggregation

بود. یعنی یک نمونه می‌تواند چند بار هم انتخاب شود. بنابراین بعضی نمونه‌های اصلی بیش از یک بار به نظر می‌رسد، در حالی که برخی از نمونه‌های اصلی در نمونه وجود ندارد. T بار این روند انجام می‌گیرد و T نمونه از نمونه‌های آموزشی M به دست می‌آیند. سپس، از هر نمونه یک یادگیرنده پایه را می‌توان با استفاده از الگوریتم یادگیری پایه آموزش داد [۱۳].

Bagging معروف‌ترین استراتژی‌ها را برای تجمع خروجی‌های طبقه بندها، یعنی رأی‌گیری برای طبقه بندی و میانگین‌گیری برای رگرسیون، استفاده می‌کند. هر یک از طبقه بندها پیش‌بینی خود را بیان می‌نمایند که به عنوان یک رأی در رأی‌گیری نهایی بر مبنای رأی اکثریت مورد استفاده قرار می‌گیرد. در حالت پیش‌بینی و استفاده از روش bagging مقدار پیش‌بینی نهایی از متوسط پیش‌بینی‌های هر یک از سیستم‌های پیش‌بینی تحت ترکیب حاصل می‌گردد [۱۳]. الگوریتم bagging به صورت زیر می‌باشد:

$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ مجموعه داده
 \mathcal{L} الگوریتم یادگیری پایه
 T تعداد یادگیرنده‌های پایه
 1- for $t=1, \dots, T$:
 2- $h_t = \mathcal{L}(D, D_{bs})$ (D_{bs} توزیع بوت استرپ است)
 3- end
 Output: $H(x) = \operatorname{argmax} \sum_{t=1}^T \mathbb{1}(h_t(x) = y) \quad y \in Y$

بوستینگ

اصطلاح بوستینگ^۱ یک فرا الگوریتم ترکیبی در حوزه یادگیری ماشین است که برای کاهش عدم توازن و همچنین واریانس به کار می‌رود. این روش در یادگیری با نظارت مورد استفاده قرار گرفته و از خانواده الگوریتم‌های یادگیری ماشین به شمار می‌رود. این تکنیک، روشی برای تبدیل سیستم‌های یادگیری ضعیف به قوی بر اساس ترکیب نتایج طبقه بندهای مختلف است [۱۳].

در boosting به هر نمونه آموزشی وزنی اختصاص داده می‌شود. یک سری از k عدد طبقه بند به صورت تکراری آموزش می‌یابند. بعد از آن که طبقه بند M_i آموزش یافت، وزن‌ها برای طبقه بند بعدی M_{i+1} به روز می‌شوند به نحوی که توجه بیشتری بر روی داده‌هایی از حوزه داده‌های آموزشی اعمال شود که توسط کلاس بند قبلی یعنی M_i به درستی دسته بندی نشده‌اند. کلاس بند boost شده نهایی رأی کلاس بندهای مجزا را با یکدیگر ترکیب کرده و در این ترکیب رأی هر کلاس بند وزن دار می‌شود، وزنی که به نتیجه خروجی هر کلاس بند اعمال می‌گردد، تابعی از صحت کلاس بند است [۲۳]. الگوریتم می‌تواند برای پیش‌بینی مقادیر پیوسته نیز توسعه یابد. روند عمومی روش boosting به صورت زیر است:

ورودی:

توزیع نمونه D

الگوریتم آموزش پایه \mathcal{L}

¹ boosting

تعداد دوره‌های آموزش T

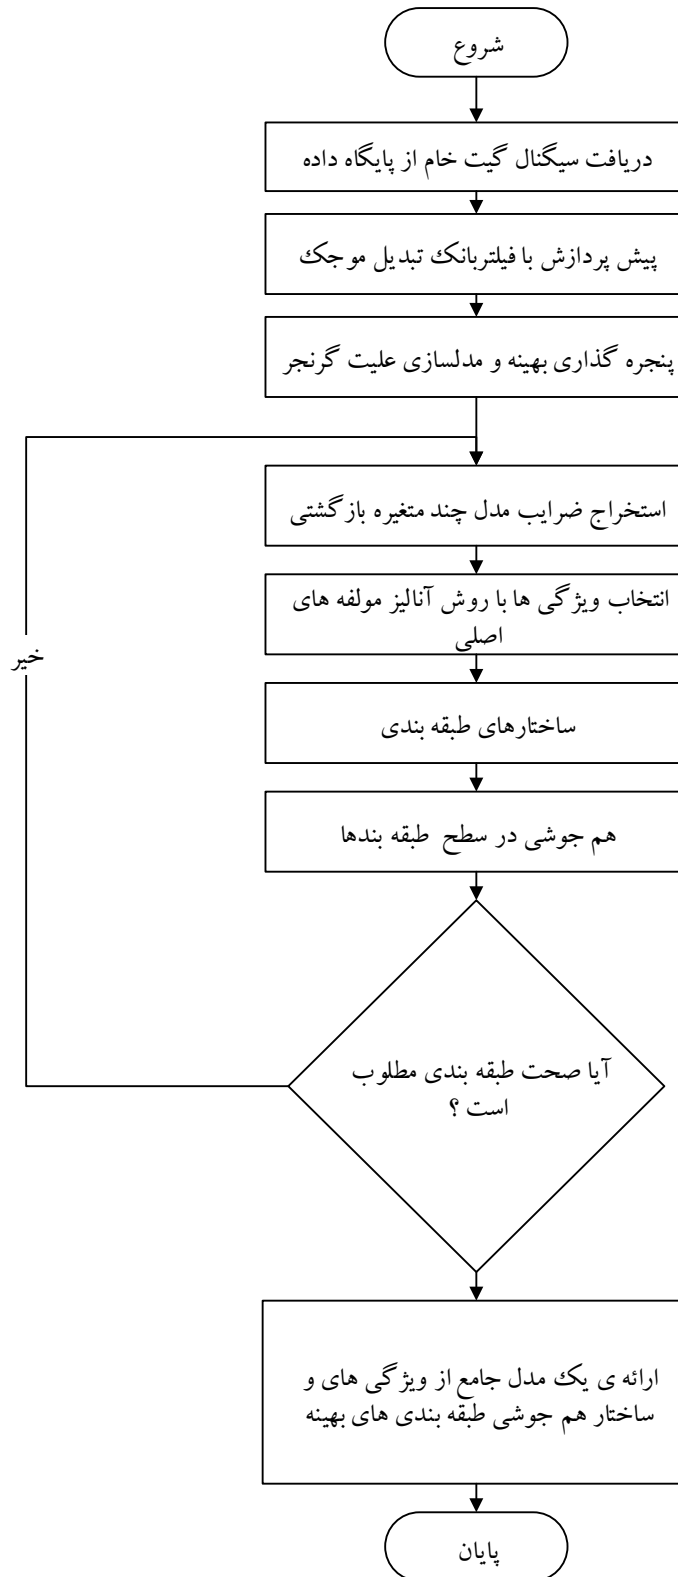
- 1- $D_1 = D_0$ (توزیع اولیه را آغاز کنید)
- 2- **for** $t=1, \dots, T$:
- 3- $h_t = \mathcal{L}(D_t)$; (یک یادگیرنده ضعیف از توزیع D_t آموزش دهید)
- 4- $\epsilon_t = p_x \sim D_t(h_t(x) \neq f(x))$; (خطای h_t را محاسبه کنید)
- 5- $D_{t+1} = \text{Adjust_Distribution}(D_t, \epsilon_t)$
- 6- **end**

Output; $H(x) = \text{Combine_Outputs}(\{h_1(x), \dots, h_t(x)\})$

اصلاح می‌گردد). وزن دهی نمونه‌ها به صورتی است که در هر مرحله، وزن نمونه‌هایی که به صورت صحیح طبقه‌بندی می‌شوند کاهش یافته و وزن نمونه‌هایی که به درستی طبقه‌بندی نشده‌اند، بیشتر می‌شود تا در مراحل بعدی (توسط یادگیرنده‌های جدید) بیشتر مورد توجه بوده و با دقت بیشتری طبقه‌بندی گردند؛ بنابراین تمرکز یادگیرنده‌های ضعیف جدید، بیشتر بر روی داده‌های خواهد بود که سیستم در مراحل قبلی قادر به طبقه‌بندی صحیح آنها نبوده است [۱۴].

۳- روش پیشنهادی

به منظور تشخیص عارضه و بیماری، از یک روش مبتنی بر یادگیری ماشین استفاده شده است که در آن با همجوشی طبقه بندها، بهبود دقت طبقه بندی و تشخیص بیماری فراهم آمده است. بلوک دیاگرام روش پیشنهادی در شکل ۱ نشان داده شده است.



شکل ۱. الگوریتم کلی روش پیشنهادی

مرحله اول جمع آوری داده

در این مطالعه از پایگاه داده‌ی فیزیونت برای بیماری‌های انحطاط عصبی استفاده شده است^۱. این پایگاه داده شامل یک دسته داده‌ی ثبت شده توسط سنسورهای مقاوم‌ی حساس به نیرو برای آنالیز دینامیک راه رفتن که در زیر پا قرار می‌گیرند استفاده گردیده است. این دادگان در پایگاه داده‌ی فیزیونت قرار دارد و شامل ۱۵ ثبت از بیماران پارکینسونی، ۲۰ ثبت از بیماران هانتینگتون، ۱۳ ثبت از بیماری اسکروز جانبی آمیوتروفیک و ۱۶ ثبت برای گروه کنترل است. پس از دانلود داده‌های هر نفر، یک فایل زیپ برای هر نفر در نظر گرفته گردیده است که در آن یک فایل mat قرار دارد و یک فایل اکسل که حاوی اطلاعات مربوط به نمونه‌ای است که از وی ثبت گرفته گردیده است. ابعاد هر ماتریس پس از ورود به متلب ۲ سطر و ۹۰۰۰۰ ستون است که دو سطر مربوط به داده‌های پای چپ و راست و ۹۰۰۰۰ مربوط به نمونه‌های ثبت شده در واحد زمان است. فرکانس نمونه برداری دستگاه ۳۰۰ هرتز بوده است، بنابراین می‌توان نتیجه گرفت که طول زمانی هر ثبت ۳۰۰ ثانیه معادل ۵ دقیقه بوده است. سایر پایگاه داده‌ها در جدول ۱ نشان داده شده است.

جدول ۱. مقایسه‌ی پایگاه‌های در دسترس برای آنالیز حرکت انسان برای بیمارهای نورودژنراتیو


نام پایگاه داده	سال ثبت داده	تعداد ارجاعات	موضوع پایگاه	فراوانی نمونه‌ها	سطح دسترسی	مزایا	معایب
Gait in Aging and Disease Database [۱۵]	۱۹۹۹	۵۲۵	پایگاه داده‌ی سیگنال راه رفتن افراد مسن، جوان، و پارکینسون	ثبت از ۱۵ نمونه به صورت سه دسته‌ی پنجگانه از سیگنال راه رفتن افراد مسن، جوان، و پارکینسونی است.	آزاد- فیزیونت	تعریف مسئله‌ی سن بر روی بیماری پارکینسون	تعداد نمونه‌های کم
Gait in Neurodegenerative Disease Database [۶]	۲۰۰۰	۲۸۱	پایگاه داده‌ی سیگنال راه رفتن افراد سالم و بیماران مبتلا به عارضه نورودیجنریتو	۵ ثبت از بیماران پارکینسونی، ۲۰ ثبت از بیماران هانتینگتون، ۱۳ ثبت از بیماری اسکروز جانبی آمیوتروفیک و ۱۶ ثبت برای گروه کنترل	آزاد- فیزیونت	متنوع بودن بیماری‌های مورد مطالعه	عدم برچسب گذاری سطح بیماری
Gait in Parkinson's Disease [۱۶]	۲۰۰۵	۱۴۳	پایگاه داده‌ی سیگنال راه رفتن افراد سالم و بیماران مبتلا	۹۳ ثبت از سیگنال راه رفتن بیماران مبتلا به پارکینسون	آزاد- فیزیونت	تعداد بالای نمونه‌ها و تعریف سطح بیماری پارکینسون	تمرکز این پایگاه فقط بر بیماری پارکینسون

^۱ <https://www.physionet.org/physiobank/database/gaitnnd/>

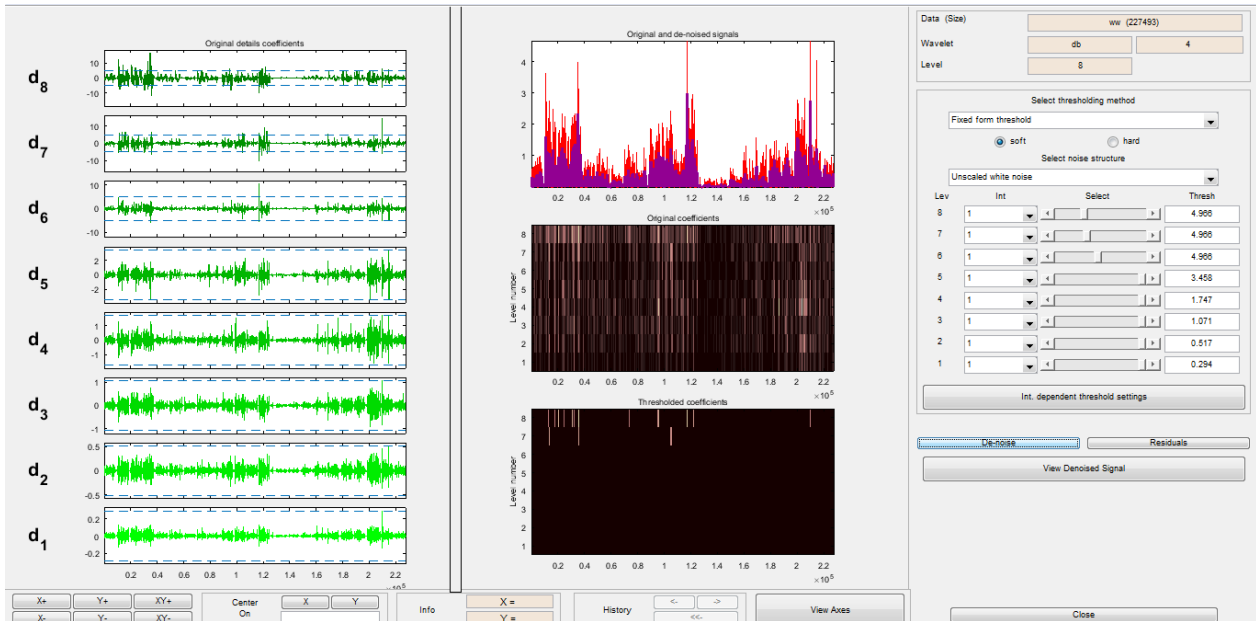
			که میانگین سنی آنها حدود ۶۶ سال بده است و ۷۳ ثبت از سیگنال راه رفتن افراد عادی	به عارضه پارکینسون		
--	--	--	--	--------------------	--	--

مرحله دوم: پیش پردازش

به منظور کاهش نویز از داده‌ها از جعبه ابزار تبدیل موجک نرم افزار MATLAB استفاده گردیده است. همان طور که پیش از این نیز اشاره شد، به منظور کاهش نویز از ضرایب پیش فرض تبدیل موجک در حذف نویزهایی با منابع غیر مشخص استفاده گردیده است. مطالعات محققان نشان داده است که موجک دایبجیز ۴ با هشت سطح تجزیه پس از نگاه داشتن ضرایب تقریب (کلیات) اطلاعات اصلی سیگنال را حفظ می‌کند. به منظور اعمال تبدیل موجک با نوشتن دستور wavemenu در پنجره‌ی فرمان و استفاده از تبدیل موجک یک بعدی عملیات حذف نویز انجام گردیده است. البته مجموعه‌ی عملیات حذف نویز با استفاده از دستور ddencomp در صفحه‌ی editor محقق گردیده است. حذف نویز برای هر حرکت، هر تکرار و هر الکتروود به صورت مجزا انجام شده است و مجدداً ماتریس حذف نویز شده برای اجرای فرآیند پردازش مورد استفاده قرار گرفته است. شکل (۲) و (۳) خلاصه‌ی این فرآیند را با استفاده از رابط گرافیکی نرم افزار MATLAB به تصویر می‌کشد. به منظور ارزیابی فرآیند کاهش نویز از روش سعی و خطا استفاده گردید.



شکل ۲. تجزیه‌ی الکتروود اول سیگنال به هشت سطح با موجک مادر دایبجیز ۴



شکل ۳ حذف نویز از الکتروود اول سیگنال پس از هشت سطح تجزیه با موجک مادر دایجیز ۴

مرحله سوم : استخراج ویژگی

از ماتریس خروجی مرحله‌ی پردازش ویژگی‌ها استخراج می‌گردند. مجموع ۱۱ ویژگی از هر الکتروود استخراج می‌گردد بنابراین اگر تعداد ستون‌های ماتریس ویژگی بیان کننده‌ی تعداد ویژگی‌های استخراج گردیده باشد، به ازای هر یک از یک الکتروود ۱۱ ویژگی محاسبه می‌گردد که جمعاً ۲۲ ستون برای ماتریس ویژگی تولید می‌کند. ویژگی‌ها پس از محاسبه با ماکزیمم مقدار هر ویژگی در هر الکتروود نرمالیزه شده‌اند و نمودارهای جعبه‌ای آن‌ها ترسیم که گزارش این نمودارها برای حرکات برای بررسی تغییرات ویژگی برای هر الکتروود و هر حرکت در فصل بعدی گزارش گردیده است.

مرحله چهارم : کاهش فضای ویژگی

به منظور کاهش فضای ویژگی از تحلیل مؤلفه‌های اصلی استفاده گردیده است. در روش تحلیل مؤلفه‌های اصلی یا تعداد ویژگی‌های باقیمانده براساس ترتیب مقادیر ویژه تعیین کننده‌ی حجم فضای ویژگی است یا اینکه می‌بایست به گونه‌ای عمل کرد که درصدی از اطلاعات ماتریس فضای ویژگی را تعیین و براساس آن، کاهش فضای ویژگی صورت پذیرد. برای اعمال تحلیل مؤلفه‌های اصلی از جعبه ابزار machine learning استفاده گردیده است که در شکل (۴) آمده است.

Output Class	1	28 73.7%	7 18.4%	80.0% 20.0%
	2	3 7.9%	0 0.0%	0.0% 100%
		90.3% 9.7%	0.0% 100%	73.7% 26.3%
		1	2	Target Class

شکل ۴. نمونه‌ی یک ماتریس درهم ریختگی

مرحله‌ی پنجم: طبقه بندی و تشخیص


به منظور طبقه بندی ویژگی‌های استخراج شده و ویژگی‌های کاهش یافته از چهار ساختار طبقه بندی که در بخش‌های پیشین به آن‌ها اشاره شد، استفاده گردید.

برای طبقه بند ماشین بردار پشتیبان، کرنل‌های خطی و غیر خطی مورد استفاده قرار گرفتند، معیار توقف آموزش براساس اعتبارسنجی متقابل ۵ استفاده شد و داده‌ها به صورت تصادفی در هر نوع حرکت به ورودی طبقه بندی کننده در نظر گرفته گردیدند. درصد داده‌های آموزش ۷۵ درصد کل داده‌ها و ۲۵ درصد برای تست در نظر گرفته شدند. برای طبقه بند نزدیک‌ترین همسایه تنظیمات مشابه ماشین بردار پشتیبان اعمال شد و معیار k برای طبقه بند نزدیک‌ترین همسایه ۱۰ استفاده گردید.

برای شبکه‌ی عصبی چند لایه پرسپترون، از یک شبکه با یک لایه‌ی پنهان با تعداد نورون‌های مختلف در لایه‌ی پنهان استفاده شد. تعداد نورون‌های لایه‌ی پنهان مطابق با مطالعه‌ی Man-chung و همکاران (۲۰۰۰) به اندازه‌ی نصف جمع ورودی‌ها و خروجی‌ها در نظر گرفته گردد. همچنین تعداد نورون‌های لایه‌ی پنهان بنابر مطالعه‌ی Freisleben (۱۹۹۲) برابر با ریشه‌ی دوم مجموع ورودی‌ها و خروجی‌ها و مطابق با مطالعه‌ی Gencay و همکاران (۱۹۹۹) برابر با لگاریتم در پایه‌ی طبیعی تعداد ورودی‌ها در نظر گرفته گردید و نتایج با یکدیگر مقایسه شد. ۷۰ درصد داده‌ها برای آموزش ۲۵ درصد برای تست و ۵ درصد برای اعتبارسنجی و توقف فرآیند آموزش استفاده گردیدند. الگوریتم آموزش نیز نزول گرادینان بوده است.


۴- نتایج

در بخش بعدی از روش پیشنهادی نتایج حاصل از ترکیب در سطح طبقه بندها بعد از اعمال کاهش در فضای ویژگی برای دسته حرکات ترکیب ارائه شده است. در فرآیند ترکیب فقط از سه نوع طبقه بند دیگر بهره‌گیری شد. شکل (۵) نتایج حاصل از ترکیب در سطح طبقه بندها را برای k-fold با ضریب ۵ نمایش می‌دهد. نتایج حاصل نشان می‌دهد که ترکیب در سطح طبقه بندها سبب بهبود نتایج شده است و در این میان روش decision template و روش دمپستر-شفر بهترین روش ترکیب طبقه بندها بوده است و سبب بهبود در نتایج طبقه بندی شده است.



شکل ۴. صحت طبقه بندی پس از ترکیب در سطح طبقه بندها به ازای ۵ بار تست و ۹ روش ترکیب


برای مقایسه‌ی تکرارپذیری نتایج حاصل از ترکیب در سطح طبقه بندها، شکل (۶) ارائه شده است. در این شکل نتایج صحت طبقه بندی برای روش‌های ۹ گانه‌ی ترکیب ارائه شده است. این نمودار نشان می‌دهد که حداکثر تکرار پذیری برای روش رأی اکثریت و حداقل تکرار پذیری برای روش بی‌زین بدست آمده است. چرا که نمودار سه بار اجرای الگوریتم برای روش بی‌زین سبب جدا شدن نمودارهای صحت از هم شده است، بنابراین تکرارپذیری مناسبی نداشته است. این درحالی است که نمودارهای صحت در روش رأی اکثریت در هر سه بار اجرای الگوریتم ترکیب بر هم منطبق شده و تکرارپذیری بهتری دارند.



شکل ۵. صحت طبقه بندی پس از ترکیب در سطح طبقه بندها به ازای ۳ بار اجرا و ۹ روش ترکیب

همچنین مقایسه‌ی نتایج طبقه بندهای بهینه یعنی ماشین بردار پشتیبان (با کرنل غیرخطی گوسی)، نزدیک‌ترین همسایه گوسی ریز مقیاس و شبکه‌های عصبی چندلایه پرسپترون با یک لایه‌ی پنهان و تعداد

نورون در لایه‌ی پنهان معادل با مجذور مجموع ورودی‌ها و خرجی برای k -fold با ضریب ۵ در شکل (۶) ترسیم شده است.



شکل ۶. تکرارپذیری صحت طبقه بندی برای سه نوع طبقه بند

نتایج حاصل از تحلیل این نمودار نشان می‌دهد که ماشین بردار پشتیبان صحت بالاتری را در مقایسه با دو طبقه بند دیگر داشته است. این درحالی است که تکرار پذیری برای این طبقه بند نیز در مقایسه با دیگر طبقه بندها بهتر است.

۵- بحث نتایج

نتایج حاصل از شبیه سازی‌ها نشان داد که استفاده از فیلتر بانک تبدیل موجک در بهبود سیگنال و کاهش نویز کارایی لازم را دارد. نتایج طبقه بندی نشان می‌دهد، می‌توان چنین استنتاج کرد که ماشین بردار پشتیبان با کرنل غیر خطی و طبقه بند نزدیک‌ترین همسایه با مقیاس ریز در طبقه بندی ویژگی‌ها با بازدهی بالا را دارد. این مسئله را می‌توان چنین توجیه کرد که چون ویژگی‌های حرکت اول جداپذیر خطی نیستند، طبقه بندهای خطی کارایی لازم را در طبقه بندی ندارند. کاهش فضای ویژگی در بهبود پارامترهای دقت، صحت و حساسیت همه‌ی طبقه بندها و کاهش زمان محاسبات مؤثر بوده است.

منابع و مراجع

- [۱] G.-M. Jeong, P. H. Truong, and S.-I. Choi, "Classification of three types of walking activities regarding stairs using plantar pressure sensors," *IEEE Sensors Journal*, vol. 17, no. 9, pp. 2638-2639, 2017.
- [۲] M. Batoool, A. Jalal, and K. Kim, "Sensors Technologies for Human Activity Analysis Based on SVM Optimized by PSO Algorithm," in *2019 International Conference on Applied and Engineering Mathematics (ICAEM)*, 2019, pp. 145-150: IEEE.
- [۳] L. Sun, Y.-X. Yuan, Q. Zhang, and Y.-C. Wu, "Human Gait Classification Using Micro-Motion and Ensemble Learning," in *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018, pp. 6971-6974: IEEE.
- [۴] J. M. Hausdorff, "Gait dynamics, fractals and falls: finding meaning in the stride-to-stride fluctuations of human walking," *Human movement science*, vol. 26, no. 4, pp. 555-589, 2007.
- [۵] J. Hollman, M. K. Watkins, A. C. Imhoff, C. E. Braun, K. A. Akervik, and D. K. Ness, "Complexity and Fractal Dynamics of Gait in Treadmill Ambulation: Implications for Rehabilitation Providers," *Archives of Physical Medicine and Rehabilitation*, vol. 97, no. 10, p. e82, 2016.
- [۶] Y. Wu and S. Krishnan, "Computer-aided analysis of gait rhythm fluctuations in amyotrophic lateral sclerosis," *Medical & biological engineering & computing*, vol. 47, no. 11, pp. 1165-1171, 2009.

- [۷] M. R. Daliri, "Automatic diagnosis of neuro-degenerative diseases using gait dynamics," *Measurement*, vol. 45, no. 7, pp. 1729-1734, 2012.
- [۸] D. Blokh and I. Stambler, "The application of information theory for the research of aging and aging-related diseases," *Progress in neurobiology*, vol. 157, pp. 158-173, 2017.
- [۹] N. Scafetta, R. E. Moon, and B. J. West, "Fractal response of physiological signals to stress conditions, environmental changes, and neurodegenerative diseases," *Complexity*, vol. 12, no. 5, pp. 12-17, 2007.
- [۱۰] A. F. Costa, G. Humpire-Mamani, and A. J. M. Traina, "An efficient algorithm for fractal analysis of textures," in *2012 25th SIBGRAPI Conference on Graphics, Patterns and Images*, 2012, pp. 39-46: IEEE.
- [۱۱] O. C. Yurdakul, M. Subathra, and S. T. George, "Detection of Parkinson's Disease from gait using Neighborhood Representation Local Binary Patterns," *Biomedical Signal Processing and Control*, vol. 62, p. 102070, 2020.
- [۱۲] A. Alharbi, "A genetic-ELM neural network computational method for diagnosis of the Parkinson disease gait dataset," *International Journal of Computer Mathematics*, vol. 97, no. 5, pp. 1087-1099, 2020.
- [۱۳] M. Woźniak, M. Grana, and E. Corchado, "A survey of multiple classifier systems as hybrid systems," *Information Fusion*, vol. 16, pp. 3-17, 2014.
- [۱۴] R. E. Singh, K. Iqbal, G. White, and J. K. Holtz, "A review of EMG techniques for detection of gait disorders," *Artificial Intelligence-Applications in Medicine and Biology*, 2019.
- [۱۵] N. Scafetta, D. Marchi, and B. J. West, "Understanding the complexity of human gait dynamics," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 19, no. 2, p. 026108, 2009.
- [۱۶] Y. Wu and L. Shi, "Analysis of altered gait cycle duration in amyotrophic lateral sclerosis based on nonparametric probability density function estimation," *Medical engineering & physics*, vol. 33, no. 3, pp. 347-355, 2011.