

طبقه‌بندی حالات پاتولوژیک راه رفتن با استفاده از ویژگی‌های فضای فاز و ترکیب اطلاعات مفصل

سهیلا اولیازاده^۱، دانشجو کارشناسی ارشد، عاتکه گشوارپور^۲، دکترای تخصصی

۱- کارشناسی ارشد، گروه مهندسی پزشکی - دانشگاه بین‌المللی امام رضا (ع) - مشهد - ایران - soheylaolyazadeh@gmail.com

۲- استادیار، گروه مهندسی پزشکی - دانشگاه بین‌المللی امام رضا (ع) - مشهد - ایران - ak_goshvarpour@imamreza.ac.ir

چکیده: الگوهای راه رفتن اطلاعات پزشکی مهمی را به منظور تصمیمات پزشکی و بالینی در اختیار قرار می‌دهند که تحت تاثیر ویژگی‌های فیزیکی و سلامت ارتوپدی و اسکلتی بدن هستند. ضعف یا آسیب به برخی از اعضای بدن می‌تواند باعث الگوی راه رفتن غیرعادی شود. هدف اصلی در این پژوهش طبقه‌بندی حالت‌های مختلف پاتولوژیک با استفاده از ویژگی‌های استخراج شده مبتنی بر دینامیک فضای فاز با استفاده از داده‌های سه بعدی ثبت شده از ۲۵ مفصل شرکت‌کنندگان است. در این مطالعه، از سیگنال‌های موجود در پایگاه داده در دسترس عموم، که شامل ۶ حالت راه رفتن در حالت طبیعی و پنج حالت پاتولوژیک است، استفاده می‌شود. در فرایند جمع‌آوری داده‌ها ده فرد سالم شرکت کردند و از آنها خواسته شد تا راه رفتن‌های هر یک از شش حالت را شبیه‌سازی کنند. هر فرد هر نوع راه رفتن را ۲۰ بار تکرار کرده است. ابتدا فضای فاز هریک از داده‌های زیر جداگانه بازسازی می‌شود: ۱- ادغام اطلاعات بردارهای xyz مفصل با استفاده از فاصله اقلیدسی (برآیند)، ۲- ادغام اطلاعات بردارهای xyz مفصل با استفاده از اطلاعات زاویه، ۳- نگاشت اطلاعات با ترکیب جدیدی از جهت xyz به فضای جدید با استفاده از تحلیل مولفه اصلی. سپس چندین ویژگی هندسی از آن استخراج می‌گردد. هریک از ویژگی‌های بدست آمده از مراحل ۱ تا ۳ به صورت جداگانه و همچنین با هم به طبقه‌بندی ماشین بردار پشتیبان، کی-نزدیک‌ترین همسایه، جنگل تصادفی و طبقه‌بند ترکیبی داده می‌شوند. در نتیجه بهترین طبقه‌بند با مشخصه تمام ویژگی‌ها، طبقه‌بند جنگل تصادفی با صحت ۹۹ درصد است.

واژه‌های کلیدی: طبقه‌بندی، پاتولوژیک، راه رفتن، فضای فاز، ترکیب اطلاعات مفصل.

Classification of Pathological Gait Modes Using Phase Space Features and Combining Joints Information

Soheila Olyazadeh^{1,3}, Ateke Goshvarpour^{2,3}

1 Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran. Email:

soheylaolyazadeh@gmail.com <https://orcid.org/0000-0003-2209-5998>

2 Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran. Email:

ateke.goshvarpour@gmail.com; ak_goshvarpour@imamreza.ac.ir; ORCID: 0000-0002-5185-5645

3 Health Technology Research Center, Imam Reza International University, Mashhad, Razavi Khorasan, Iran.

Abstract: Gait patterns provide valuable medical information for making medical and clinical decisions influenced by physical characteristics, orthopedic health, and skeletal health. Weakness or injury in certain body parts can lead to an abnormal walking pattern. The primary objective of this research is to classify different pathological states using features extracted through phase space dynamics based on 3D data obtained from the joints of 25 participants. This study utilizes a freely accessible database containing six walking modes - one healthy normal and five pathological modes. Ten healthy individuals participated in the data collection process and were instructed to simulate the gaits for each of the six modes. Each participant repeated each walking type twenty times. The first step involves separately reconstructing the phase space for the following data: 1) Integration of XYZ vector information from the joints using Euclidean distance, 2) Integration of XYZ vector information from the joints using angle information, and 3) Mapping the information to a new space by combining the XYZ directions through principal component analysis. Subsequently, several geometric features are extracted from the reconstructed data. Each of the features obtained from steps 1 to 3 is inputted individually, as well as their combinations into support vector machine, k-nearest neighbor, random forest, and hybrid classifiers. The random forest classifier demonstrates the highest accuracy of 99% when considering all features.

Keywords: Classification, Pathobiology, Gait, Phase Space, Combination of joint information

تاریخ ارسال مقاله: ۱۴۰۲/۰۲/۲۱

تاریخ اصلاح مقاله: ۱۴۰۲/۱۱/۱۶

تاریخ پذیرش مقاله: ۱۴۰۴/۰۶/۱۵

نام نویسنده مسئول: عاتکه گشوارپور

نشانی نویسنده مسئول: گروه مهندسی پزشکی، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران.

۱- مقدمه

راه رفتن انسان به تعامل پیچیده‌ای از بخش‌های اصلی دستگاه عصبی، اسکلتی، عضلانی، قلبی و تنفسی بستگی دارد. راه رفتن طبیعی نیاز به تعادل ظریف بین دستگاه‌های عصبی در حال تعامل مختلف دارد و از سه جزء اصلی تشکیل شده است که شامل حرکت: از جمله شروع، حفظ گام‌های ریتمیک و تعادل که توانایی سازگاری با محیط است می‌باشد. اختلال در عملکرد هر یک از این دستگاه‌ها می‌تواند راه رفتن را مختل کند [۱]. بیشتر مشکلات سرپایی در افراد مسن ناشی از اختلال عملکرد همزمان چندین دستگاه است. راه رفتن فرد بالغ دارای ضربه پاشنه با افزایش سرعت، آهنگ، طول گام، زمان ایستادن تک اندام، و نسبت فاصله لگن به حرکت مچ پا زمانی که هر دو پا روی زمین هستند همراه می‌باشد [۲]. اختلالات راه رفتن در افراد مسن شایع است و با افزایش سن شیوع آن‌ها افزایش می‌یابد که یکی از دلایل جراحت و مرگ در این گروه جمعیتی است. در سن ۶۰ سالگی، ۸۵ درصد افراد دارای راه رفتن طبیعی هستند، اما در سن ۸۵ سالگی یا بالاتر، این نسبت به ۱۸ درصد کاهش یافته است [۳]. از طرفی افزایش سن جمعیت جهان یکی از چالش‌های مطرح عصر حاضر است. این افزایش سن در کنار عمر طولانی برای انسان مشکلاتی را نیز به همراه خواهد داشت که یکی از این مشکلات اختلالات راه رفتن است که در سنین بالا شایع می‌شود و این اختلالات موجب مرگ و یا افزایش آسیب و شکستگی‌های حاد می‌شود که این در نوع خود می‌تواند موجب تحمیل هزینه فراوان درمان و نگهداری از افراد در سامانه بهداشتی شود [۴]. راه رفتن فقط ادغام حرکت هر مفصل انسان نیست، بلکه ادغام تمام عملکرد ارگانیسم انسان از جمله مهارت‌های شناختی، عملکرد حسی و توانایی حرکتی است. چندین آزمایش کمی برای یافتن رابطه بین الگوی راه رفتن غیرطبیعی و وضعیت سلامتی انجام شد. برخی از الگوهای راه رفتن غیرطبیعی ناشی از مشکلات فیزیکی مانند آسیب، مشکلات مفصلی یا ضعف و فلج عضلات خاص است. همچنین مشکلات مربوط به دستگاه عصبی، عملکرد حسی و توانایی مغزی می‌تواند باعث الگوی راه رفتن غیرطبیعی شود [۵]. الگوهای راه رفتن اطلاعات پزشکی مهمی را به منظور تصمیمات پزشکی و بالینی در اختیار قرار می‌دهند که تحت تاثیر ویژگی‌های فیزیکی و سلامت ارتوپدی و اسکلتی بدن هستند. طبقه‌بندی الگوهای راه رفتن غیرعادی می‌تواند به شناسایی قسمت‌های ضعیف بدن و تعیین اینکه چه بیماری یا مشکل سلامتی ممکن است فرد را تحت تاثیر قرار دهد کمک می‌کند و در انتخاب روش درمانی و یا پیشگیری از رشد اختلال موثر باشد [۴]. در تشخیص و ارزیابی اختلالات حرکتی غالباً از مشاهدات بالینی، شرح حال و خودارزیابی‌های بیمار استفاده می‌شود. این روش‌ها اگرچه اطلاعات مفیدی ارائه می‌دهند اما رویکرد دقیقی برای شناسایی به‌شمار نمی‌روند. از این رو، اخیراً ارزیابی الگوهای حرکتی افراد با استفاده از الگوریتم‌های هوشمند و مبتنی بر تحلیل کامپیوتری مورد توجه محققان قرار گرفته است.

جون^۱ و همکاران [۴] شبکه عصبی واحد بازگشتی گیتی^۲ را برای طبقه‌بندی راه رفتن‌های پاتولوژیک بکار بردند و عملکرد آن را با سایر طبقه‌بندی‌کننده‌های مبتنی بر یادگیری ماشین مقایسه کردند. علاوه بر این، گروه‌های مفصلی مختلفی را برای شناسایی مفاصل مهم و نامربوط برای طبقه‌بندی در نظر گرفتند. هنگامی که تمام داده‌های اسکلتی استفاده شد، طبقه‌بندی کننده GRU به صحت طبقه‌بندی ۹۰/۱۳٪ دست یافت. آن‌ها دریافتند که صحت طبقه‌بندی GRU به گروه‌های مفصلی در نظر گرفته شده بستگی دارد و صحت طبقه‌بندی زمانی که فقط مفاصل پا در نظر گرفته می‌شود به ۹۳/۶۷٪ افزایش می‌یابد.

چاروی^۳ و همکاران [۷] ویژگی فضایی-زمانی جدیدی ارائه دادند که نمایشی از مجموعه اسکلت‌های متوالی را بر اساس مکان سه بعدی مفاصل اسکلتی ارائه می‌داد. با استفاده از دستگاه RGB_D تاریخچه حرکت مفصل^۴ به عنوان ویژگی استخراج شد و برای راه رفتن عادی مدلی با استفاده از الگوریتم کیسه کلیدی^۵ آموزش دید. آزمایش با مجموعه داده‌ها و روش‌های ارزیابی مختلف نشان داد که الگوریتم پیشنهادی می‌تواند راه رفتن غیرعادی را با قابلیت اعتماد بالا تشخیص دهد.

لی^۶ و همکاران [۸] با استفاده از مسیر حرکت مفاصل اسکلت سه بعدی انسان که توسط یک حسگر کینکت^۷ گرفته شده است، ارائه دادند. داده‌های ۱۴ فرد (۲۰ مفصل) با بکارگیری الگوریتم کی-نزدیک‌ترین همسایه^۸ به سه کلاس با صحت ۹۰٪ طبقه‌بندی شد.

نگوین^۹ و همکاران [۹] مدلی بر اساس موقعیت‌های مفاصل انسان (اسکلت) در سری‌های زمانی ایجاد کردند. هر وضعیت لحظه‌ای انسان با یک بردار ویژگی نشان داده شد که روابط بین جفت مفاصل استخوانی واقع در پایین بدن را توصیف می‌کرد. سپس چنین بردارهایی با استفاده از تکنیک خوشه‌بندی به کلمات رمز تبدیل شدند. در مرحله تشخیص، چرخه راه رفتن با احتمال نرمال زیر یک آستانه، (که به طور خودکار در مرحله تمرین تعیین شد) به عنوان یک ناهنجاری در نظر گرفته شد. نتایج تجربی نشان داد که روش آن‌ها در تشخیص راه رفتن عادی و غیر طبیعی دقت کلی ۹۰/۱۲٪ را داشته است.

¹ Jun² Gated Recurrent Unit; GRU³ Chaaraoui⁴ Joint Motion History; JMH⁵ Bagofkeyposes⁶ Li⁷ Kinect⁸ K-Nearest Neighbors; KNN⁹ Nguyen

تحلیل داده‌های ۸ فرد (۲۰ مفصل) نشان دادند که ساختار مفصل اسکلت انسان را می‌توان با یک درخت نشان داد. JRMF برای هر مفصل اسکلت شامل موقعیت نسبی، سرعت و شتاب این مفصل نسبت به همه مفصل است. وضعیت لحظه‌ای مفصل، اسکلت را بهتر از موقعیت‌های مفصلی توصیف می‌کند. شبکه HST-RNN با ساختار درختی مشابه مفصل اسکلت انسان ساخته شد. هر گره درخت یک GRU بود و یک مفصل اسکلت را نشان می‌داد. نتایج تجربی نشان داد که HST-RNN پیشنهادی با JRMF به صحت ۹۴٪ دست یافته است.

دو^{۱۴} و همکاران [۱۴] یک RNN سلسله مراتبی برای تشخیص عملکرد (مبتنی بر اسکلت) پیشنهاد کردند. با حسگر کینکت اطلاعات ۲۰ مفصل از ۱۰ فرد اخذ شد. در این روش اسکلت را با توجه به ساختار فیزیکی انسان به پنج قسمت تقسیم کردند و سپس به طور جداگانه آنها را به پنج زیرشبکه تغذیه کردند. نتایج تجربی نشان داد که مدل آنها به عملکردی با راندمان محاسباتی بالا دست می‌یابد.

جون^{۱۵} و همکاران [۲۴]، یک روش طبقه‌بندی ناهنجاری‌های راه رفتن مبتنی بر یادگیری عمیق را ارائه نمودند که هم از اسکلت سه‌بعدی (به‌دست‌آمده با دوربین) و هم فشار کف پای استفاده می‌کرد. در روش پیشنهادی، داده‌های اسکلت و فشار متوسط پا به ترتیب به لایه‌های رمزگذاری مبتنی بر شبکه عصبی بازگشتی و لایه‌های رمزگذاری مبتنی بر شبکه عصبی کانولوشن وارد شد. در نهایت، ویژگی‌های خروجی به لایه‌های طبقه‌بندی متصل شدند. مدل‌های تک وجهی مبتنی بر فشار و اسکلت به ترتیب به صحت طبقه‌بندی ۶۸/۸۲٪ و ۹۳/۴۰٪ دست یافتند. مدل ترکیبی چندوجهی پیشنهادی با استفاده از داده‌های فشار اسکلت و پا با هم عملکرد بهبودیافته‌ای را با صحت ۹۵/۶۶٪ نشان داد. بهبود مدل ترکیبی با استفاده از روش آموزشی سه مرحله‌ای صحت را به ۹۷/۶۰٪ افزایش داد.

در مطالعه ای دیگر، جون و همکاران [۲۵] روشی برای پایش راه رفتن انسان در محیط‌های داخلی با استفاده از یک ربات متحرک و هوش مصنوعی پیشنهاد نمودند. این ربات به صورت دوره‌ای داده‌های اسکلت سه بعدی را با استفاده از یک دوربین جمع‌آوری می‌کرد که داده‌های جمع‌آوری شده برای استخراج پارامترهای راه رفتن و طبقه‌بندی راه‌رفتن‌های معمولی، آنتالژیک، پاهای سفت، استپ‌پیچ، لورچینگ و ترنلنبرگ از طریق سیستم پیشنهادی استفاده می‌شد. محققان از اسکلت‌های سه بعدی و داده‌های زاویه مبتنی بر مفصل برای دستیابی به بهبود عملکرد طبقه‌بندی راه رفتن پاتولوژیک استفاده نمودند. بکارگیری شبکه عصبی واحد بازگشتی گیتی دوجهته با اتخاذ استراتژی ادغام در سطح ویژگی صحت ۹۷/۶۴٪ را نتیجه داد؛ در حالی که صحت ۹۷/۶۳٪ و ۹۴/۱۷٪ به ترتیب برای ورودی اسکلت و زاویه مفصل به مدل حاصل شد.

لی^۱ و همکاران [۱۰] یک سامانه تشخیص راه رفتن را پیشنهاد دادند. سامانه آن‌ها از اطلاعات سه بعدی مفصل (که با استفاده از چندین حسگر کینکت به دست آمده است) و شبکه عصبی بازگشتی-حافظه طولانی کوتاه مدت^۲ استفاده می‌کرد. آزمایش‌ها با مقایسه صحت آزمون بر روی ۱۴ ترکیب از مفصل انسان انجام شد. از طریق این آزمایش، مفصل بهینه را برای نشان دادن نتایج برجسته انتخاب کردند تا مدل تشخیص راه رفتن عملکرد بهینه‌ای داشته باشد. نتایج نشان داد که مفصل مج‌پا، مج دست و سر تأثیرگذارترین مفصل در مدل RNN-LSTM هستند. آن‌ها از اطلاعات ۲۵ مفصلی بدن انسان بر روی ۴ نفر برای تشخیص الگوهای راه رفتن استفاده کردند و به صحت بیش از ۹۷٪ رسیدند.

لوریرو و کوریا^۳ [۱۱] تصویر انرژی اسکلت^۴ را پیشنهاد کردند تا برخی از ویژگی‌هایی که بیشتر برای اهداف تشخیص بیومتریک مفید هستند، مانند شکل بدن، حفظ شود. نمایش SEI پیشنهادی نتایج طبقه‌بندی آسیب‌شناسی راه رفتن بهتری نسبت به تصویر انرژی راه رفتن^۵ بدست داد. همچنین، با ترکیب هر دو نمایش، عملکرد سامانه بیشتر بهبود می‌یافت. این مطالعه مجموعه داده راه رفتن جدیدی، با توالی‌های به‌دست‌آمده از ۱۰ آزمودنی ارائه کرد که چهار نوع مختلف از اختلالات راه رفتن را شبیه‌سازی می‌کرد. سامانه طبقه‌بندی اختلالات راه رفتن پیشنهاد شده در این مقاله از الگوریتم شبکه عصبی کانولوشنی^۶ استفاده کرد که حداکثر صحت ۹۳٪ را بدست آورد.

چاکرابورتی^۷ و همکاران [۱۲] داده‌های ۸ فرد را جمع‌آوری کردند و از بردارهای ویژگی ۶ زاویه مفصلی (زاویه باسن، زانو و مج پا در هر دو طرف) استفاده کردند. تجزیه و تحلیل مقایسه‌ای بین مدل‌های رگرسیون لجستیک، ماشین بردار پشتیبان^۸ و خطوط رگرسیون تطبیقی چندگانه^۹ انجام شد. سری‌های زمانی سینماتیک، استخراج شده از مفصل مختلف اندام تحتانی، به مدل‌ها وارد شدند. بردارهای ویژگی از ۶ زاویه مفصلی ساخته شدند و برای دقت بیشتر در محدوده نمونه زمانی چندگانه ادغام شدند. مدل MARS با ۸۸/۳٪ صحت تشخیص نسبت به سایر مدل‌ها عملکرد بهتری داشت.

وی^{۱۰} و همکاران [۱۳] ویژگی حرکت نسبی مفصل^{۱۱} و شبکه جدید عصبی بازگشتی^{۱۲} درخت اسکلت انسانی^{۱۳} را پیشنهاد دادند. با

¹ Lee

² Recurrent Neural Network_Long Short-Term Memory; RNN-LSTM

³ Loureiro and Correia

⁴ Skeleton Energy Image; SEI

⁵ Gait Energy Image; GEI

⁶ Convolutional Neural Network; CNN

⁷ Chakraborty

⁸ Support-Vector Machines; SVM

⁹ Multiple Adaptive Regression Splines; MARS

¹⁰ Wei

¹¹ Joint Relative Motion Feature; JRMF

¹² Recurrent Neural Network; RNN

¹³ Human Skeleton Tree RNN; HST-RNN

¹⁴ Du

¹⁵ Jun

از تحلیل مؤلفه‌های اساسی^۸، سپس، فضای فاز داده‌های سه بعدی مفصل و ترکیب آنها بازسازی شد. فضای فازها با ویژگی‌های مختلف کمی‌سازی شدند. در آخر، طبقه‌بندهای SVM، kNN و جنگل تصادفی^۹ و همچنین طبقه‌بندی جمعی^{۱۰} استفاده شد تا شش حالت پاتولوژیک راه رفتن تفکیک گردد. به منظور اعتبارسنجی طبقه‌بندها از اعتبارسنجی متقابل یک‌طرفه^{۱۱} استفاده شد.

۲- روش بررسی دادگان

در این پژوهش از داده‌های اسکتی موجود در پایگاه داده در دسترس و آزاد^{۱۲} استفاده شد [۴].

در این پایگاه داده مختصات سه بعدی ۲۵ مفصل (مطابق شکل ۲) که با استفاده از کینکت جمع‌آوری شده است، قابل دستیابی است. برای این منظور، سامانه کینکت چند جانبه با استفاده از ۶ حسگر ایجاد و هر حسگر کالیبره شده است. برای کالیبراسیون هر حسگر از نشانگر ثابتی به نام آریوکو استفاده شده است. گوشه پایین سمت چپ نشانگر آریوکو به عنوان مبدا تنظیم می‌شود و جهت x و y نیز به ترتیب از مبدأ به سمت راست و به سمت بالا به عنوان بردار تنظیم می‌شود. جهت z بطور عمود بر جهت x و جهت y تعیین شد. با اعمال ماتریس چرخش و انتقال، دستگاه مختصات کینکت xyz به دستگاه مختصات xyz نشانگر آریوکو تبدیل گردید، سه نشانگر آریوکو به زمین وصل شدند.

در مطالعه آذری^۱ و همکاران [۲۶]، از پایگاه داده مورد بررسی در مطالعه حاضر برای پیش بینی حرکت انسان استفاده شد. بدین منظور، از شبکه‌های متخاصم تکمیل-مولد^۲ است که براساس تابع ضرر هویر آموزش دیده است. آنها، سری‌های زمانی-محل اتصال سه بعدی را به سری‌های زمانی چندمتغیره تغییر داده و آنها را به یک CGAN منتقل نمودند. نتایج با شبکه‌های LSTM و MLP مقایسه شد. نتایج نشان می‌داد که روش پیشنهادی از نظر معیارهای ریشه میانگین مربعات خطا^۳، میانگین خطای مطلق^۴، نسبت سیگنال به نویز^۵، شاخص تشابه ساختاری^۶ نسبت به روش‌های دیگر برتری داشته است.

آوکی^۷ و همکاران [۲۷]، رویکردی مبتنی بر یادگیری عمیق برای طبقه‌بندی چرخه راه رفتن با و بدون خستگی از طریق یک شبکه عصبی بازگشتی ارائه دادند، که به آن هر چرخه راه رفتن به صورت یک سری زمانی از مختصات سه بعدی مفصل بدن ارائه می‌شد. ارزیابی مدل بر چرخه‌های راه رفتن هشت نفر سطح کلی زیر منحنی ۰/۸۶ برای طبقه‌بندی خستگی در اعتبارسنجی با روش حذف یک شرکت کننده را نتیجه داد.

مرور تحقیقات پیشین نشان می‌دهد اغلب مطالعات اطلاعات ۲۰ مفصل و یا کمتر را پردازش نموده‌اند [۷، ۹، ۱۴، ۱۲]. به علاوه، بیشتر مطالعات [۴، ۱۰، ۱۳، ۱۴] از طبقه‌بندهای کانولوشنی مثل GRU و یا RNN استفاده کردند. از طرفی، برای طبقه‌بندی اغلب صرفاً همان داده اولیه و خام استفاده شده است. در مطالعه‌ی حاضر، ۴ نوع ترکیب اطلاعات داده‌های سه بعدی ۲۵ مفصل در پنج اختلال راه رفتن و طبیعی [۴] و ویژگی‌های فضای فاز را مورد بررسی قرار می‌دهیم. از طرفی، سه نوع طبقه‌بندی مرسوم با حالت‌های مختلف را برای بررسی دقیق‌تر ارزیابی می‌کنیم. از این رو، هدف اصلی در این پژوهش طبقه‌بندی حالت‌های مختلف پاتولوژیک با استفاده از ویژگی‌های استخراج شده مبتنی بر دینامیک فضای فاز با استفاده از داده‌های سه بعدی ثبت شده از ۲۵ مفصل شرکت‌کنندگان است. شکل ۱ بلوک دیاگرام روند انجام تحقیق را نشان می‌دهد.

ابتدا داده‌های سه بعدی مفصل (۲۵ مفصل) در ۶ حالت راه رفتن مختلف (طبیعی و پاتولوژیک) از پایگاه داده [۴] اخذ شد. این داده‌ها با رویکردهای مختلف باهم ترکیب شدند: ۱- ادغام اطلاعات بردارها با استفاده از فاصله‌ی اقلیدسی (برآیند). ۲- ادغام اطلاعات بردارها با استفاده از اطلاعات زاویه (فارغ از دامنه به بررسی زاویه مفصل پرداختیم). ۳- نگاشت اطلاعات با ترکیب جدیدی از سه بعد با استفاده

¹ Azari

² Completion-Generative Adversarial Networks; CGAN

³ Root mean square error

⁴ Mean absolute error

⁵ Signal-to-noise ratio

⁶ Structural similarity index

⁷ Aoki


⁸ Principle Component Analysis; PCA

⁹ Random Forest

¹⁰ Ensemble Classifier

¹¹ Leave-One-Subject-Out Cross Validation

¹² https://github.com/kooksung/pathological_gait_datasets




شکل ۲: داده‌های اسکلت از کینکت

شش حالت راه رفتن معرفی شد که عبارتند از: ۱- راه رفتن طبیعی^۱، ۲- راه رفتن آنتالژیک^۲، ۳- راه رفتن پاصاف^۳، ۴- راه رفتن همراه با تلو تلو خوردن^۴، ۵- راه رفتن استپاژ^۵ و ۶- راه رفتن ترندلنبرگ^۶، عوامل و نشانه‌های هر یک از حالات پاتولوژیک در جدول ۲ بیان گردیده است.

جدول ۲: شرح پنج حالت راه رفتن پاتولوژیک

اختلال راه رفتن	نشانه‌ها	عوامل
آنتالژیک	کاهش وزن بر روی پای آسیب‌دیده به منظور کاهش درد، کوتاه کردن زمان ایستادن بر روی پای آسیب‌دیده	درد در پا، مچ پا، زانو، باسن
پاصاف	سفت بودن پای مشکل‌دار در راه رفتن، ساختن یک نیم دایره به سمت بیرون در حین چرخاندن پای مشکل‌دار	آسیب‌شناسی‌های مرتبط با مفصل، مانند آرتريت روماتوئید
همراه با تلو تلو	خم کردن تنه به سمت عقب در هنگام ضربه پاشنه پای مشکل‌دار برای جبران ضعف اکستنشن مفصل ران	ضعف یا فلج عضله سربینی ماکسیموس
استپاژ	مشکل دورسی فلکشن در پای مشکل‌دار بالاتر از حد طبیعی است تا انگشتان پا از روی زمین جدا نشوند	ضعف یا فلج تیپالیس قدامی
ترندلنبرگ	حرکت دادن لگن مشکل‌دار به سمت بالا و لگن مخالف به پایین در مرحله ایستادن برای متعادل کردن سطح باسن، به حرکت درآوردن تنه به سمت پای مشکل‌دار.	ضعف یا فلج گلوئوس مدیوس و گلوئوس مینیموس

ده فرد سالم در فرایند جمع‌آوری داده‌ها شرکت کردند و از آن‌ها خواسته شد تا راه رفتن‌های هر یک از شش حالت را شبیه‌سازی کنند [۴]. بدین منظور، دستورالعمل‌هایی برای شبیه‌سازی ۵ نوع گام پاتولوژیک تهیه شد. در این ۵ دستورالعمل شبیه‌سازی، نحوه راه رفتن



شکل ۱: بلوک دیاگرام روند انجام تحقیق.

جدول ۱:

۰- پایه ستون فقرات	۱۳- زانوی چپ
۱- وسط ستون فقرات	۱۴- مچ پای چپ
۲- گردن	۱۵- پای چپ
۳- سر	۱۶- باسن راست
۴- شانه چپ	۱۷- زانوی راست
۵- آرنج چپ	۱۸- مچ پای راست
۶- مچ چپ	۱۹- پای راست
۷- دست چپ	۲۰- شانه ستون فقرات
۸- شانه راست	۲۱- نوک دست چپ
۹- آرنج راست	۲۲- انگشت شست چپ
۱۰- مچ راست	۲۳- نوک شست راست
۱۱- دست راست	۲۴- انگشت شست راست
۱۲- لگن چپ	

¹ Normal Gait

² Antalgic Gait

³ Stiff-Legged Gait

⁴ Lurching Gait

⁵ Steppage Gait

⁶ Trendelenburg Gait

را ادغام و به فضای جدیدی نگاشت می‌کنیم تا اطلاعات مفید و ترکیبی از هر سه مؤلفه مفصل بدست آید.

۳-۳- فضای فاز^۱

فرض کنید که سیگنال موجود $A = [a_1, \dots, a_m]$ است به طوری که m طول داده باشد. دینامیک فضای فاز^۲ سیگنال راه رفتن برای $n=1, 2, \dots, m-(d-1)\tau$ به شرح زیر است [۱۵]:

$$PSD = (A_n, A_{n+\tau}, \dots, A_{n+(d-1)\tau}) \quad (3)$$

انتخاب پارامترهای d و τ اثر مستقیمی بر اطلاعات داده‌شده توسط PSD دارد. با تعیین نادرست این پارامترها، PSD نمی‌تواند رفتار آشوبگون سیگنال راه رفتن را نشان دهد. تخمین این پارامترها با اطلاعات متقابل و الگوریتم نزدیک‌ترین همسایه کاذب، زمان زیادی می‌برد. در واقع، این الگوریتم‌ها موجب پیچیدگی محاسباتی شده و استفاده از آنها برای کاربردهای بلادرنگ کارآمد نیست. در مطالعات قبلی، $d=2$ و $z=1$ برای تحلیل سیگنال‌های بیولوژیکی توصیه شده‌اند. در نتیجه PSD، داده با یک تأخیر به فضای دوبعدی نگاشت می‌شود. این بدان معنی است که PSD سیگنال‌های راه رفتن از طریق رسم یک A_n در مقابل A_{n+1} بدست می‌آید. بنابراین، معادله PSD را می‌توان برای سیگنال راه رفتن نمونه $A = [a_1, \dots, a_m]$ به صورت زیر بازنویسی کرد [۱۶]:

$$[PSD = A_n, A_{n+1}] = [(a_1, a_2), (a_2, a_3), \dots, (a_{i-1}, a_i)] \quad (4)$$

۳-۴- استخراج ویژگی

در این قسمت به ویژگی‌های استخراج شده و توضیح هریک می‌پردازیم.

شش ویژگی غیرخطی گرافیکی از PSD استخراج شد. بر این اساس، رفتار آشوبناک سیگنال‌های راه رفتن کمی می‌شود. توضیح و معادلات ریاضی برای ۶ ویژگی گرافیکی در بخش‌های زیر داده شده‌است. [۲۳]

حاصلجمع مساحت دوایر متوالی^۳: فرض می‌شود که هر دو نقطه متوالی شکل $((a_i, a_{i+1}), (a_{i+1}, a_{i+2}))$ PSD قطر یک دایره باشد. SCCA برای ارزیابی تغییرات دامنه سیگنال در حوزه زمان به صورت زیر محاسبه می‌شود. شکل ۳- با فرض اینکه C_i مساحت هر دایره باشد $(CC_5 + C_4 + C_3 + C_2 + C_1 = SCCA)$.

$$SCCA = \sum_{i=1}^{m-2} \frac{\pi}{4} ((a_i + 1 - a_i)^2 + (a_i + 2 - a_i + 1)^2) \quad (5)$$

برای ۵ گام آسیب‌شناسی برای هر افراد توضیح داده شده است [۴]. دستورالعمل‌های شبیه‌سازی ۵ گام پاتولوژیک به شرح زیر بودند: هنگام شبیه‌سازی راه رفتن آنالژیک، وزن را پایین نگه‌دارید. پا و زمان تماس آن پا با زمین را به حداقل برسانید- هنگام شبیه‌سازی راه رفتن با پاهای سفت، زانوی یک پا را خم نکنید و هنگام چرخاندن آن پا، یک نیم دایره به سمت بیرون ایجاد کنید- هنگام شبیه‌سازی راه رفتن، تنه را با ضربه پاشنه یک پا به سمت عقب خم کنید- هنگام شبیه‌سازی راه رفتن پله‌ای، زمین را با آن خراش دهید انگشت یک پا و زانوی آن پا را بالاتر از حد معمول بلند کنید- هنگام شبیه‌سازی راه رفتن ترندلبرگ، باسن یک پا را بالا بیاورید و تنه را به سمت کنار ساق پا خم کنید وقتی پای ساق با زمین برخورد کرد.

سپس هر فرد هر نوع اختلال را در مسیر مشخص شده ۲۰ بار پیموده است [۴].

۳- استخراج ویژگی

در این قسمت به ویژگی‌های استخراج شده و توضیح هریک می‌پردازیم.

۳-۱- فاصله اقلیدوسی (برایند)

فاصله اقلیدوسی بین دو نقطه در فضای اقلیدوسی طول قطعه خطی بین دو نقطه است. فاصله بین دو جسم (که نقطه نیستند) معمولاً به صورت کوچکترین فاصله بین جفت نقطه از دو جسم تعریف می‌شود. برای محاسبه فاصله روابط متعددی معرفی شده‌اند. به عنوان مثال، در برخی از کاربردهای آمار و بهینه‌سازی، از مربع فاصله اقلیدوسی به جای خود فاصله استفاده می‌شود [۱۹]. در اینجا ما از مربع فاصله اقلیدوسی استفاده کرده‌ایم، بدین صورت که هر مفصل دارای سه بعد (xyz) است در نتیجه ما با توجه به فرمول زیر برآیند هر مفصل (ادغام اطلاعات بردار) را در نظر گرفته‌ایم:

$$W = \sqrt{X^2 + Y^2 + Z^2} \quad (1)$$

۳-۱- زاویه مفصل

در اینجا ما، زاویه هریک از مفاصل (فارغ از دامنه) را، [۱۷] با توجه به فرمول زیر بدست می‌آوریم:

$$W_2 = \tan^{-1}(Y/X) \quad (2)$$


۳-۲- انتخاب ویژگی با استفاده از تحلیل مولفه اصلی

ترکیب اطلاعات مفاصل با استفاده از تحلیل مولفه اصلی PCA یک روش محبوب کاهش خطی ابعاد است. تمرکز PCA بر روی اجزای اصلی ماتریس ویژگی‌ها می‌باشد که بیشترین واریانس را حفظ می‌کنند. PCA یک تکنیک بدون نظارت است، به این معنی که از اطلاعات بردار هدف استفاده نمی‌کند و فقط ماتریس ویژگی را در نظر می‌گیرد. [۲۰] در واقع در اینجا ما با استفاده از PCA اطلاعات X, Y, Z

¹ PSD; phase space dynamic

² Phase Space Dynamic; Psd

³ Summation of Consecutive Circles Area; Scca




شکل ۵: ویژگی گرافیکی SSVL

مجموع کوتاه‌ترین فاصله از هر نقطه نسبت به خط ۴۵ درجه^۳:
برای تعیین کمیت نرخ پراکندگی داده‌ها در اطراف خط ۴۵ درجه، از SH45 استفاده می‌شود. SH45 عرض شکل PSD را از دو بخش نواحی مثلثاتی اول و سوم اندازه‌گیری می‌کند که به با خط $y = x$ شناخته می‌شود. معادله SH45 به شرح زیر است (در شکل ۶، SHi کوتاه‌ترین فاصله از هر نقطه نسبت به خط ۴۵ درجه است و بنابراین، SH45=

$$(SH1 + SH2 + SH3 + SH4 + SH5)$$


$$SH45 = \sum_{i=1}^{m_1} \frac{|a_{i+1} - a_i|}{\sqrt{2}} \quad (۸)$$



شکل ۶: ویژگی گرافیکی SH45

مجموع کوتاه‌ترین فاصله از هر نقطه نسبت به خط ۱۳۵ درجه^۴:
نرخ پراکندگی داده‌ها در اطراف خط ۱۳۵ درجه را نشان می‌دهد. SH135 عرض شکل PSD سیگنال را از نیم‌ساز نواحی مثلثاتی دوم و چهارم اندازه‌گیری می‌کند، که تحت عنوان خط $y = -x$ شناخته می‌شود. معادله SH45 به شرح زیر است (در شکل ۷، SHi کوتاه‌ترین فاصله از هر نقطه نسبت به خط ۱۳۵ درجه است و بنابراین، SH135=

$$(SH1 + SH2 + SH3 + SH4 + SH5)$$




شکل ۳: ویژگی گرافیکی SCCA

مجموع فواصل بین دایره هرون^۱: تغییرات شکل PSD سیگنال را کمی می‌کند. می‌توان از آن به عنوان یک پارامتر مهم برای ارزیابی پیچیدگی PSD سیگنال استفاده کرد. معادله SDHC به صورت زیر تعریف می‌شود که در شکل ۴ بصورت گرافیکی نمایش داده شده است (در شکل ۴، Di فاصله میان مراکز دو دایره متوالی است و بنابراین،

$$(SDHC = D1 + D2 + D3)$$

$$SDHC = \sum_{i=1}^{m-4} \sqrt{\left(\frac{a_{i+1} + a_{i+2} + a_{i+3}}{3} - \frac{a_i + a_{i+1} + a_{i+2}}{3} \right)^2 + \left(\frac{a_{i+2} + a_{i+3} + a_{i+4}}{3} - \frac{a_{i+1} + a_{i+2} + a_{i+3}}{3} \right)^2} \quad (۶)$$



شکل ۴: ویژگی گرافیکی SDHC

مجموع طول بردارهای متوالی^۲: تغییرات سیگنال را کمی می‌کند و با معادله زیر محاسبه می‌شود (شکل ۵)، Li طول بردار دو نقطه متوالی است و بنابراین،

$$SSVL = L1 + L2 + L3 + L4 + L5 \quad (۷)$$

$$SVL = \sum_{i=1}^{m_2} \sqrt{(a_{ai+2} - a_{i+1})^2 + (a_{i+1} - a_i)^2}$$

^۳ Summation of The Shortest Distance from Each Point Relative to the 45-Degree Line; Sh45

^۴ Summation of the Shortest Distance from Each Point Relative to the 135-Degree Line; Sh135

^۱ Summation of Distances Between Heron's Circular; Sdhc

^۲ Summation of Successive Vector Lengths; Ssvl

۴- طبقه‌بندی

طبقه‌بندی چند کلاسه^۲: مسائلی از طبقه‌بندی را که داده‌ها متعلق به بیش از ۲ کلاس باشد را مسائل چند کلاسه، گویند. به طور مثال، در اینجا بر اساس داده، ۶ کلاس (حالت راه رفتن) داریم. برای این کار ما با استفاده از الگوریتم‌های مختلف، داده را طبقه‌بندی کرده‌ایم که در ادامه به معرفی آنها می‌پردازیم.

۱- ماشین بردار پشتیبانی

یکی از روش‌های یادگیری با نظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. [۱۸] این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی نشان داده است. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. هریک از مسائل با یک جدا کننده دودویی حل می‌شود. سپس خروجی جدا کننده‌های دودویی SVM با هم ترکیب شده و به این ترتیب مسئله چند کلاس حل می‌شود.


تئوری کاور بیان می‌کند که اگر داده‌ای داشته باشیم که به صورت غیرخطی تفکیک‌پذیر باشد، می‌توان با یک تبدیل غیرخطی از فضای غیرخطی به فضای خطی نگاشت داد که در این فضا داده‌ها به صورت خطی تفکیک‌پذیر می‌شوند. برای نگاشت داده‌ها از فضای غیرخطی به فضای خطی، ویژگی‌ها را به صورت غیرخطی باهم ترکیب می‌کنیم و یک سری ویژگی‌هایی می‌سازیم که داده توسط این ویژگی‌ها به صورت خطی تفکیک‌پذیر می‌شود و حال می‌توان همان مسأله بهینه‌سازی مسائل خطی را در این فضا برای پیدا کردن مرز بدست آورد. مرز خطی که در فضای جدید (فضای ویژگی) بدست می‌آید معادل همان مرز غیرخطی در فضای اصلی است.

برای ترکیب غیرخطی ویژگی‌ها هم هسته‌های مختلفی مثل هسته تابع پایه شعاعی^۳، هسته گاوسی^۴، هسته درجه دوم^۵ و مکعبی^۶ را می‌توان استفاده کرد. ما در روش خود از SVM با استفاده از سه هسته مختلف (گاوسی، درجه دوم و مکعبی) برای طبقه‌بندی داده و یافتن بهترین روش طبقه‌بندی استفاده کردیم.

۲- نزدیک‌ترین همسایه

در باز شناخت الگو کی- نزدیک‌ترین همسایه (kNN) یک روش ناپارامتری است که برای طبقه‌بندی آماری و رگرسیون استفاده می‌شود [۱۸]. در هر دو حالت کی شامل نزدیک‌ترین مثال آموزشی در فضای داده‌ای می‌باشد و خروجی آن بسته به نوع مورد استفاده در طبقه‌بندی و رگرسیون متغیر است. در حالت طبقه‌بندی با توجه به


$$SH135 = \sum_{i=1}^{m_1} \frac{|a_{i+1} + a_i|}{\sqrt{2}} \quad (9)$$



شکل ۷: ویژگی گرافیکی SH135

مجموع مساحت مثلث‌های ایجاد شده با دو نقطه متوالی نگاشت و مرکز مختصات^۱: اگر فرض شود که هر دو نقطه متوالی روی صفحه مختصات یعنی (a_i, a_{i+1}) و (a_{i+2}, a_{i+1}) دو گوشه یک مثلث و مرکز مختصات (یعنی $(0, 0)$) گوشه سوم باشد، شکل دوبعدی سیگنال به مثلث‌های متوالی با یک رأس مشترک (یعنی همان مرکز مختصات) تبدیل می‌شود. در این حالت، مجموع مساحت مثلث‌هایی که نقاط متوالی و مرکز مختصات شکل می‌دهند، محاسبه می‌شود. این روش نرخ تغییرات شکل PSD سیگنال را اندازه‌گیری می‌کند. معادله زیر نشان‌دهنده TACR است:

$$TACR = \frac{1}{2} \sum_{i=1}^{m_2} \left| \det \begin{bmatrix} 0 & a_i & a_{i+1} \\ 0 & a_{i+1} & a_{i+2} \\ 1 & 1 & 1 \end{bmatrix} \right| \quad (10)$$



شکل ۸: ویژگی گرافیکی TACR

در شکل ۸، مساحت هر مثلث است که توسط نقاط متوالی PSD و مرکز مختصات ساخته شده است، از این رو، $TACR = Tcr1 + Tcr2 + Tcr3 + Tcr4$ خواهد بود.

^۲ Multi-Class Classification; Mcc^۳ Radial Basis Function; Rbf^۴ Gaussian^۵ Quadratic^۶ Cubic^۱ Summation of the Area of the Triangles Making Successive Points and Coordinate Center; Tacr

بلوک سازنده یادگیری ماشین در نظر می‌گیرند. در این پژوهش نیز از الگوریتم کیسه‌ای با تعداد درخت‌های متفاوت [۳۰ و ۱۰۰ و ۲۰۰] استفاده کرده‌ایم.

در این پژوهش برای اعتبارسنجی، از اعتبارسنجی متقابل یک‌طرفه^۳ که یک روش استاندارد برای برآورد عملکرد یک الگوریتم یادگیری ماشین بر روی مجموعه داده است، استفاده کرده‌ایم. برای ارزیابی مدل، از جدولی که اصطلاحاً ماتریس درهم ریختگی نام دارد استفاده می‌شود. جدول یا ماتریس درهم ریختگی، نتایج حاصل از طبقه‌بندی را براساس اطلاعات واقعی موجود، نمایش می‌دهد. حال براساس این مقادیر می‌توان معیارهای مختلف ارزیابی دسته‌بندی را تعریف کرد. در مطالعه حاضر، عملکرد سامانه با سه معیار صحت^۴، ویژگی^۵ و اندازه F^۶ برآورد شد.

۵- یافته‌ها

جدول ۳: نتایج بهترین طبقه‌بند.

صحت: ۹۹٪					
۱	۲۰۰				
۲		۱۹۸		۱	۱
۳	۱		۱۹۶	۳	
۴	۲		۱	۱۹۷	
۵		۲			۱۹۸
۶		۱			۱۹۹
	۱	۲	۳	۴	۵

کلاس پیش‌بینی شده

جدول ۳ ماتریس درهم ریختگی را برای بهترین نتایج طبقه‌بندی با اعمال تمام ویژگی‌ها، طبقه‌بند جنگل تصادفی با تعداد درخت‌ها ۲۰۰ بدست آمده است را نشان می‌دهد. در حالت کلی تعداد کل داده‌ها ۱۲۰۰ است (۱۰ فرد که ۶ حالت پاتولوژیک را با ۲۰ تکرار شبیه‌سازی کرده‌اند) در خروجی ۶ کلاس داریم. بر اساس ۶ حالت پاتولوژیک که به ترتیب به شرح زیر است؛ کلاس ۱: راه رفتن طبیعی، کلاس ۲: راه رفتن آنتالژیک، کلاس ۳: راه رفتن پا صاف، کلاس ۴: راه رفتن همراه با توتلو خوردن، کلاس ۵: راه رفتن استپاژ و کلاس ۶ مربوط به حالت راه رفتن ترندلنبرگ است که با روش یک‌طرفه اعتبارسنجی شده است. همانطور که جدول نشان می‌دهد صحت به ۹۹٪ رسیده است.

جدول ۴: نتایج بر اساس صحت (%).

ویژگی	ادغام تمام	تحلیل مولفه	زاویه مفاصل	فاصله اقلیدوسی	فضای فاز
-------	------------	-------------	-------------	----------------	----------

^۳ Leave-one-subject-out

^۴ Accuracy

^۵ Specificity

^۶ F1-Score

مقدار مشخص شده برای کی، به محاسبه فاصله نقطه‌ای که می‌خواهد برچسب آن را مشخص کند با نزدیک‌ترین نقاط می‌پردازد و با توجه به تعداد رأی حداکثری این نقاط همسایه، در رابطه با برچسب نقطه مورد نظر تصمیم‌گیری می‌کند. برای محاسبه این فاصله می‌توان از روش‌های مختلفی استفاده کرد که یکی از مطرح‌ترین این روش‌ها، فاصله اقلیدسی است. در حالت رگرسیون نیز میانگین مقادیر بدست آمده از کی خروجی آن می‌باشد بهترین انتخاب k بستگی به داده‌ها دارد؛ به‌طور کلی، مقادیر بزرگ k باعث کاهش خطا در طبقه‌بندی می‌شود، اما وضوح مرز بین کلاس‌ها را کمتر می‌کند. k مناسب را می‌توان با استفاده از تکنیک‌های مختلف انتخاب کرد. در این پژوهش، طبقه‌بندی با استفاده از الگوریتم kNN، با مقدار ۲ و ۵ و ۱۰ برای k پردازش شده‌اند تا بررسی شود که با کدام مقدار k نتیجه بهتری حاصل می‌شود.

۳- الگوریتم جنگل تصادفی

یک الگوریتم محبوب یادگیری ماشین از زیرمجموعه هوش مصنوعی است که به تکنیک یادگیری نظارت شده تعلق دارد. می‌تواند برای مشکلات طبقه‌بندی و رگرسیون (پیش‌بینی و بیان تغییرات یک متغیر براساس اطلاعات متغیر دیگر) در یادگیری ماشین استفاده شود. هنگام ساخت زیر مجموعه داده برای درختان، کلمه "تصادفی" به تصویر می‌آید. زیر مجموعه‌ای از داده‌ها با انتخاب تصادفی x تعداد ویژگی (ستون) و تعداد y نمونه (ردیف) از مجموعه اصلی n ویژگی و m مثال ساخته می‌شود.

همانطور که از نام این الگوریتم پیداست، الگوریتم جنگل تصادفی یک طبقه‌بندی است که شامل تعدادی درخت تصمیم در زیرمجموعه‌های مختلف مجموعه داده قرار دارد و برای بهبود دقت پیش‌بینی آن مجموعه داده، میانگین می‌گیرد. جنگل تصادفی به جای تکیه بر یک درخت تصمیم، پیش‌بینی را از هر درخت و براساس اکثریت آرا پیش‌بینی می‌کند و نتیجه نهایی را به عنوان خروجی در نظر می‌گیرد. تعداد بیشتر درختان در جنگل منجر به دقت بالاتری می‌شود و از بروز مشکل بیش‌برازش^۱ جلوگیری می‌کند. جنگل تصادفی یک الگوریتم یادگیری نظارت شده محسوب می‌شود. همانطور که از نام آن مشهود است، این الگوریتم جنگلی را به‌طور تصادفی می‌سازد. «جنگل» ساخته شده، در واقع گروهی از «درخت‌های تصمیم» است. کار ساخت جنگل با استفاده از درخت‌ها اغلب اوقات به روش «کیسه‌گذاری»^۲ انجام می‌شود. ایده اصلی روش کیسه‌گذاری آن است که ترکیبی از مدل‌های یادگیری، نتایج کلی مدل را افزایش می‌دهد. یکی از مزایای جنگل تصادفی قابل استفاده بودن آن، هم برای مسائل دسته‌بندی و هم رگرسیون است که غالب سامانه‌های یادگیری ماشین کنونی را تشکیل می‌دهند. در اینجا، عملکرد جنگل تصادفی برای انجام «دسته‌بندی» تشریح خواهد شد، زیرا گاهی دسته‌بندی را به عنوان

^۱ Overfitting

^۲ Bagging

جدول ۶: نتایج بر اساس اندازه F (%)

ویژگی طبقه‌بند	ادغام تمام ویژگی‌ها	تحلیل مولفه اصلی	زاویه مفاصل	فاصله اقلیدوسی	فضای فاز
ماشین بردار پشتیبان (درجه دوم)	۹۷/۰۳	۹۰/۸۲	۸۴/۰۵	۹۰/۶۵	۹۴/۸۴
ماشین بردار پشتیبان (مکعبی)	۹۸	۹۰/۵۱	۸۲/۳۹	۸۹/۸۲	۹۵/۷۵
ماشین بردار پشتیبان (گوسی)	۵۴/۲۱	۶۵/۴۲	۶۳/۵	۸۴/۲۶	۷۷/۴۴
کی-۲ نزدیک‌ترین همسایه	۹۰/۳۶	۸۱/۲۴	۶۸/۱۴	۷۷/۴۹	۹۰/۵۲
کی-۵ نزدیک‌ترین همسایه	۹۲/۲۵	۸۳/۹۹	۷۳/۲۵	۸۳/۴۶	۹۲/۴۱
کی-۱۰ نزدیک‌ترین همسایه	۹۱/۳۸	۸۴/۴۴	۷۱/۹۹	۸۰/۶۸	۹۲/۴۴
کیسه‌ای (درخت=۳۰)	۹۸/۵۹	۸۸/۲۶	۸۵/۱۷	۸۳/۸۸	۹۳/۴۱
کیسه‌ای (درخت=۱۰۰)	۹۹/۲۵	۸۹/۳۲	۸۷/۵۷	۸۳/۹۱	۹۵/۰۱
کیسه‌ای (درخت=۲۰۰)	۹۹/۱۶	۸۹/۵۶	۸۷/۸۳	۸۴/۷۹	۹۵/۷۶

جداول ۴ تا ۶ به ترتیب نشان دهنده نتایج طبقه‌بندی بر اساس صحت، ویژگی^۱ و اندازه F^۲ است. همانطور که در این جدول مشاهده می‌کنید هنگامی که تمام ویژگی‌ها به طبقه‌بند جنگل تصادفی داده شده است، بهترین نتایج حاصل شده است و بعد از آن بهترین نتایج با ماشین بردار پشتیبان با هسته‌های^۳ درجه دوم و مکعبی حاصل شده است که در این حالت نرخ تفکیک حالات حدود ۹۷٪ بوده است. طبق این جداول برای مقایسه بین رویکردهای ترکیب اطلاعات مفاصل، به این نتیجه می‌رسیم که زمانی که اطلاعات سه بعدی داده‌ها بطور مستقیم و بدون ترکیب اطلاعات به فضای فاز برده می‌شوند نتیجه‌ی بهتری دارند. از میان رویکردهای ترکیب اطلاعات مفاصل، زمانی که از نگاشت PCA استفاده می‌شود بهترین نتایج حاصل می‌گردد. از میان رویکردهای طبقه‌بندی، الگوریتم SVM با هسته گوسی ضعیف‌ترین عملکرد را داشته است. در الگوریتم kNN زمانی که k برابر ۵ بوده است نتایج بهتری حاصل شده است.

¹ Specificity² F-Score³ Kernels

طبقه‌بند	ویژگی‌ها	اصلی	۸۲/۶	۹۰/۴	۹۴/۷
ماشین بردار پشتیبان (درجه دوم)	۹۷/۴	۹۰/۸	۸۲/۶	۹۰/۴	۹۴/۷
ماشین بردار پشتیبان (مکعبی)	۹۷/۷	۹۰/۸	۸۱/۵	۹۰/۹	۹۵/۶
ماشین بردار پشتیبان (گوسی)	۴۳/۹	۵۷/۸	۶۰/۳	۸۳	۷۱/۱
کی-۲ نزدیک‌ترین همسایه	۸۸/۹	۸۱/۳	۶۷/۲	۷۵/۹	۹۰/۱
کی-۵ نزدیک‌ترین همسایه	۹۰/۱	۸۳/۳	۷۰/۳	۸۱/۱	۹۱/۸
کی-۱۰ نزدیک‌ترین همسایه	۸۹/۳	۸۳/۵	۶۸/۳	۷۸/۲	۹۱/۳
کیسه‌ای (درخت=۳۰)	۹۸/۳	۸۶/۸	۸۳/۴	۸۰/۸	۹۲/۸
کیسه‌ای (درخت=۱۰۰)	۹۹	۸۸/۲	۸۶/۵	۸۱	۹۳/۸
کیسه‌ای (درخت=۲۰۰)	۹۹	۸۸/۲	۸۶/۴	۸۱/۸	۹۴/۸

جدول ۵: نتایج بر اساس ویژگی (%)

ویژگی طبقه‌بند	ادغام تمام ویژگی‌ها	تحلیل مولفه اصلی	زاویه مفاصل	فاصله اقلیدوسی	فضای فاز
ماشین بردار پشتیبان (درجه دوم)	۹۹/۴۱	۹۸/۱۵	۹۶/۸	۹۸/۱۳	۹۸/۹۶
ماشین بردار پشتیبان (مکعبی)	۹۹/۶	۹۸/۱	۹۶/۴۷	۹۷/۹۵	۹۹/۱۵
ماشین بردار پشتیبان (گوسی)	۸۹/۸۵	۹۲/۳	۹۲/۲۸	۹۶/۸۲	۹۴/۷۵
کی-۲ نزدیک‌ترین همسایه	۹۸/۰۸	۹۶/۲۷	۹۳/۹۲	۹۵/۶۲	۹۸/۱
کی-۵ نزدیک‌ترین همسایه	۹۸/۴۵	۹۶/۸۲	۹۴/۷۸	۹۶/۷۲	۹۸/۴۸
کی-۱۰ نزدیک‌ترین همسایه	۹۸/۲۷	۹۶/۹۲	۹۴/۵۲	۹۶/۱۷	۹۸/۴۸
کیسه‌ای (درخت=۳۰)	۹۹/۷۲	۹۷/۶۷	۹۷/۰۳	۹۶/۷۸	۹۸/۶۸
کیسه‌ای (درخت=۱۰۰)	۹۹/۸۵	۹۷/۸۷	۹۷/۵۲	۹۶/۷۸	۹۹
کیسه‌ای (درخت=۲۰۰)	۹۹/۸۳	۹۷/۹۲	۹۷/۵۷	۹۶/۹۵	۹۹/۱۵

۶- بحث و نتیجه گیری

در این پژوهش سعی کردیم با استفاده از ویژگی‌های مبتنی بر دینامیک فضای فاز که حاصل از اطلاعات سه بعدی (x,y,z) بدست آمده از مختصات ۲۵ مفصل بود و ترکیب آنها به تفکیک حالات پاتولوژیکی راه رفتن بپردازیم. در این رویکرد به ادغام اطلاعات بردارها با استفاده از ویژگی فاصله‌ی اقلیدسی، ادغام اطلاعات بردارها با استفاده از اطلاعات زاویه و نگاشت اطلاعات با ترکیب جدیدی از جهت xyz با استفاده از PCA پرداختیم. همین‌طور عملکرد سامانه در تفکیک ۶ کلاس و استفاده از طبقه‌بندهای مختلف با شرایط متفاوت، را مقایسه کردیم. بطور خلاصه، جنبه‌های نوآوری پژوهش را می‌توان بصورت زیر خلاصه کرد: ۱- استفاده از ویژگی‌های مبتنی بر دینامیک فضای فاز با استفاده از اطلاعات سه بعدی (x,y,z) بدست آمده از مختصات ۲۵ مفصل. ۲- ادغام اطلاعات بردارها با استفاده از ویژگی فاصله‌ی اقلیدسی (برآیند) ۳- ادغام اطلاعات بردارها با استفاده از اطلاعات زاویه مفصل. ۴- نگاشت اطلاعات با استفاده از PCA. ۵- بررسی عملکرد سامانه در ۶ حالت راه رفتن. ۶- استفاده از طبقه‌بندهای مختلف با شرایط مختلف برای مقایسه دقیق‌تر.

جدول ۷: مقایسه کارهای انجام شده در طبقه‌بندی ناهنجاری‌های راه رفتن.

مطالعه	داده‌ها	روش تحلیل	صحت (%)
[۴]	داده‌های اسکلت	شبکه عصبی واحد بازگشتی گیتی	۹۳/۶۷
[۸]	داده‌های اسکلت	مسیر حرکت و کی-نزدیک‌ترین همسایه	۹۰
[۹]	داده‌های اسکلت	موقعیت‌های مفاصل، خوشه‌بندی و آستانه‌گذاری	۹۰/۱۲
[۱۰]	داده‌های اسکلت	شبکه عصبی بازگشتی - حافظه طولانی کوتاه مدت	۹۷
[۱۱]	تصویر انرژی اسکلت	شبکه عصبی کانولوشنی	۹۳
[۱۲]	داده‌های اسکلت	رگرسیون لجستیک، ماشین بردار پشتیبان و خطوط رگرسیون تطبیقی چندگانه	۸۸/۳
[۱۳]	داده‌های اسکلت	حرکت نسبی مفصل و شبکه عصبی بازگشتی درخت اسکلت انسانی	۹۴
[۲۴]	داده‌های اسکلت و فشار کف پا	شبکه عصبی بازگشتی و لایه‌های رمزگذاری مبتنی بر شبکه عصبی کانولوشن	۹۷/۶
[۲۵]	داده‌های اسکلت و فشار کف پا	شبکه عصبی واحد بازگشتی گیتی دوچهره	۹۷/۶۴
مطالعه حاضر	داده‌های اسکلت	دینامیک فضای فاز و ادغام اطلاعات و یادگیری ماشین	۹۹

با این رویکرد، حداکثر نرخ بازشناسی ۹۹٪ برای تفکیک شش حالت مختلف راه رفتن بدست آمد.

جدول ۷ نتایج مطالعه حاضر را با مطالعات پیشین مقایسه می‌کند. مرور مطالعات پیشین بیانگر آن است که تنها در دو مطالعه [۱۰] و [۴] از ۲۵ مفصل استفاده شده است و در سایر مطالعات، تعداد مفاصل کمتری مورد بررسی قرار گرفته‌اند. ما نیز از داده‌های سه بعدی ۲۵ مفصل استفاده کردیم. در این پژوهش برای اولین بار از ویژگی‌های مبتنی بر دینامیک فضای فاز استفاده شد. در حالی که در مطالعات گذشته عموماً تنها پردازش بر روی خود اسکلت انجام می‌شد [۷]. در مطالعه [۸] لی و همکاران الگوریتم طبقه‌بند را تنها بر روی اختلالات راه رفتن ناشی از بیماری‌های عصبی مانند پارکینسون ارائه کردند. اما در مطالعه‌ی [۴] که ما نیز از داده‌های آن بهره گرفته‌ایم، یک حالت راه رفتن نرمال و پنج حالت راه رفتن پاتولوژیک طبقه‌بندی شده است. نرخ تفکیک در مطالعه‌ی [۴] که بر اساس گروه‌بندی مفاصل انجام شد، برای طبقه‌بند kNN ، ۶۲٪ و برای طبقه‌بند جنگل تصادفی ۷۴٪ بوده است. اما در پژوهش حاضر با بهره‌گیری از ویژگی‌های فضای فاز و ترکیب اطلاعات مفاصل ماکزیمم نرخ طبقه‌بندی kNN به ۸۹٪ و جنگل تصادفی به ۹۹/۵٪ رسیده است. چاکرباتی و همکاران [۱۲] نیز از طبقه‌بند SVM استفاده کردند که صحت ۸۸٪ را دارا بوده است. اما در پژوهش حاضر با نوآوری ویژگی‌ها، نرخ صحت ۹۷٪ برای طبقه‌بند SVM حاصل شد. همچنین در مطالعه [۹] تنها به دو کلاس جهت طبقه‌بندی اکتفا شده است، در حالی که در این پژوهش داده‌ها بر اساس نوع راه رفتن به ۶ کلاس طبقه‌بندی شده‌اند.

در مطالعات [۴، ۹، ۱۳] مفاصل گروه‌بندی شده و هر گروه به طبقه‌بند داده شده است. بدین منظور پیشنهاد می‌شود در کارهای آتی این رویکرد جهت مقایسه‌ی دقیق‌تر مفاصل موثر در اختلالات راه رفتن به کار اضافه گردد.

بطور کلی، برخی از محدودیت‌های مطالعه حاضر به شرح زیر است: (۱) مطالعه بر حجم نمونه محدود (فقط داده‌های ۱۰ نفر از افراد سالم) انجام شد. اندازه نمونه بزرگ‌تر و متنوع‌تر، نتایج مقاوم‌تر و قابل‌تعمیم بیشتری ارائه می‌دهد. (۲) از شرکت‌کنندگان خواسته شد تا حالت‌های مختلف راه رفتن را به جای نمایش طبیعی آنها شبیه‌سازی کنند. در نتیجه، الگوهای راه رفتن ممکن است به طور کامل سناریوهای دنیای واقعی را منعکس نکنند و می‌توانند متفاوت از حالت‌های پاتولوژیک واقعی باشند. (۳) این مطالعه ویژگی‌های هندسی را بر اساس سه روش مختلف (فاصله اقلیدسی، اطلاعات زاویه، تجزیه و تحلیل مؤلفه‌های اصلی) استخراج کرد، اما در مورد انتخاب یا کفایت این ویژگی‌ها توضیحی ارائه نکرد. روش‌های استخراج ویژگی جامع‌تر و پیچیده‌تر می‌تواند در مطالعات آتی مورد بررسی قرار گیرد. (۴) در مطالعه حاضر طبقه‌بندی‌کننده‌های محدود در نظر گرفته شده‌اند. فقط ماشین بردار پشتیبان، k نزدیک‌ترین همسایه، جنگل تصادفی و طبقه‌بندی‌های ترکیبی در مطالعه استفاده شد. سایر طبقه‌بندی‌کننده‌های پیشرفته یا تکنیک‌های گروهی را می‌توان برای دستیابی به صحت حتی بهتر مورد بررسی قرار داد. به عنوان مثال، می‌توان به جای بهره‌گیری از

IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 542-545). IEEE. 2019.

[11] Loureiro J., Correia P. L. Using a Skeleton Gait Energy Image for Pathological Gait Classification, 2020 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020), Buenos Aires, Argentina, 2020, pp. 503-507, doi: 10.1109/FG47880.2020.000064.

[12] Chakraborty, S., Jain, S., Nandy, A. and Venture, G., "Pathological gait detection based on multiple regression models using unobtrusive sensing technology". *Journal of Signal Processing Systems*, vol. 93, n.1, pp. 1-10. 2021.

[13] Wei, S., Song, Y. and Zhang, Y., *Human skeleton tree recurrent neural network with joint relative motion feature for skeleton based action recognition*. In 2017 IEEE international conference on image processing (ICIP) (pp. 91-95). IEEE. 2017.

[14] Du, Y., Wang, W. and Wang, L., *Hierarchical recurrent neural network for skeleton based action recognition*. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1110-1118). 2015.

[15] R. Sharma, R. B. Pachori, "Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions, Expert Syst". *Appl.* Vol. 42, n. 3, pp. 1106-1117 2015.

[16] H. Akbari, et al., "Depression recognition based on the reconstruction of phase space of EEG signals and geometrical features", *Appl. Acoust.* Vol. 179, p. 108078. 2021.

[17] Zhang, sh., Ye, Y., Zhang, R., Jin, X., Chen, Y., Ning, G. *Optimization of Center -of -Pressure-Based indices for assessing balance ability*. This full text paper was peer-reviewed at the direction of IEEE instrumentation and Measurement Society prior to the acceptance and publication. 2018.

[18] Tiwari, A & Joshi, D. "Template - Based insoles for the center of pressure estimation in different foot sizes." *IEEE Sensors letters*. vol. 4, n. 8, 2020.

[19] Shu, L.; Hua, T.; Wang, Y.; Li, Q.; Feng, D. D. "In-shoe plantar pressure measurement and analysis system based on fabric pressure sensing array" *IEEE transactions on information technology in biomedicine*. vol. 14, n. 3. 2010.

[20] M. T. Sadiq, et al., "Motor imagery EEG signals decoding by multivariate empirical wavelet transform-based framework for robust brain-computer interfaces", *IEEE Access*, vol. 7, pp. 171431-171451. 2019.

[21] P. Tichavský, A. -H. Phan, A. "Cichocki, Krylov-Levenberg-marquardt algorithm for structured Tucker tensor decompositions.", *IEEE J. Sel. Top. Signal Process.* vol. 15, n. 3, pp. 550-559. 2021.

[22] Baratloo A, Hosseini M, Negida A, El Ashal G. "Part 1: Simple Definition and Calculation of Accuracy, Sensitivity and Specificity". *Emergency*. vol. 3, n. 2, pp. 48-9. 2015.

[23] Hesam Akbari, Sedigheh Ghofrani, et al., "Schizophrenia recognition based on the phase space dynamic of EEG signals and graphical features" *ELSEVIER Biomedical Signal Processing and Control*, vol. 69, p. 102917. 2021.

[24] K. Jun, S. Lee, D. -W. Lee and M. S. Kim, "Deep Learning-Based Multimodal Abnormal Gait Classification Using a 3D Skeleton and Plantar Foot Pressure," in *IEEE Access*, vol. 9, pp. 161576-161589, 2021, doi: 10.1109/ACCESS.2021.3131613

[25] K. Jun, S. Oh, S. Lee, D. -W. Lee and M. S. Kim, "Automatic pathological gait recognition by a mobile robot using ultrawideband-based localization and a depth camera," 2022 31st IEEE International Conference on Robot and Human Interactive Communication (RO-MAN), Napoli, Italy, 2022, pp. 652-659, doi: 10.1109/RO-MAN53752.2022.9900734

[26] M. Azari, H. Rafiei and M. -R. Akbarzadeh-T, "Robust Human Movement Prediction by Completion-Generative Adversarial Networks with Huber Loss," 2022 29th National and 7th International Iranian Conference on Biomedical Engineering (ICBME), Tehran, Iran, Islamic Republic of, 2022, pp. 198-204, doi: 10.1109/ICBME57741.2022.10052859

[27] K. Aoki, H. Nishikawa, Y. Makihara, D. Muramatsu, N. Takemura and Y. Yagi, "Physical Fatigue Detection From Gait Cycles via a Multi-Task Recurrent Neural Network," in *IEEE Access*, vol. 9, pp. 127565-127575, 2021, doi: 10.1109/ACCESS.2021.3110841.

طبقه‌بندی‌های مرسوم مانند مطالعات [۱۴، ۱۳، ۴، ۱۰] از طبقه‌بندی‌های کانولوشنی مثل GRU و یا RNN استفاده کرد. (۵) این تحقیق در میان شرکت‌کنندگان ویتنامی انجام شد و مشخص نیست که آیا یافته‌ها و صحت طبقه‌بندی برای سایر جمعیت‌ها با ویژگی‌های دموگرافیک و بدن متفاوت است یا خیر. (۶) در مطالعه حاضر، تمام محاسبات با استفاده از پردازنده Intel®Core™i7-8550U CPU@1.80 GHz انجام شده است. زمان انجام محاسبات کل فرآیند ۵۴۰/۷۲ ثانیه بوده است. ادغام ویژگی‌ها به سه روش مختلف و بازسازی فضای فاز و استخراج ویژگی به طور بالقوه می‌تواند بار محاسباتی را افزایش دهد. با این حال، توجه به این نکته مهم است که مناسب بودن سامانه برای عملیات بلادرنگ به سخت‌افزار خاص و زمان پاسخ مطلوب وابسته است. برای کاهش پیچیدگی محاسباتی، تکنیک‌های مختلف بهینه‌سازی برای کاهش تعداد ویژگی‌ها و بهبود کارایی زمان اجرا را می‌توان مورد بررسی قرار داد، مانند روش‌های کاهش ابعاد یا انتخاب ویژگی. علاوه بر این، پیشرفت در قابلیت‌های سخت‌افزاری و پردازش موازی می‌تواند امکان‌سنجی عملیات بلادرنگ را افزایش دهد.

در این مقاله از دادگان مقاله [۴] استفاده شده است. این مقاله فاقد هرگونه مطالعه با شرکت‌کنندگان انسانی است که دادگان آن توسط نویسندگان مقاله حاضر اخذ شده باشد.

مراجع

- [1] Snijders, A. H., Van De Warrenburg, B. P., Giladi, N. and Bloem, B. R., "Neurological gait disorders in elderly people: clinical approach and classification". *The Lancet Neurology*, vol. 6, n. 1, pp. 63-74. 2007.
- [2] Wren, T. A., Gorton III, G. E., Ounpuu, S. and Tucker, C. A., "Efficacy of clinical gait analysis: A systematic review". *Gait & posture*, vol. 34, n. 2, pp. 149-153. 2011.
- [3] Brognara, L., Palumbo, P., Grimm, B. and Palmerini, L., *Assessing gait in Parkinson's disease using wearable motion sensors: a systematic review*. Diseases 2019.
- [4] Jun, K., Lee, Y., Lee, S., Lee, D. W. and Kim, M. S., "Pathological Gait Classification Using Kinect v2 and Gated Recurrent Neural Networks". *IEEE Access*, vol. 8, pp. 139881-139891. 2020. Available at: https://github.com/kooksung/pathological_gait_datasets
- [5] Clark, R. A., Mentiplay, B. F., Hough, E. and Pua, Y. H., "Three-dimensional cameras and skeleton pose tracking for physical function assessment: A review of uses, validity, current developments and Kinect alternatives". *Gait & posture*, vol. 68, pp. 193-200. 2019.
- [6] Païement, A., Tao, L., Hannuna, S., Camplani, M., Damen, D. and Mirmehdi, M., September. *Online quality assessment of human movement from skeleton data*. In British Machine Vision Conference (pp. 153-166). BMVA press. 2014.
- [7] Chaaraoui, A. A., Padilla-López, J. R. and Flórez-Revuelta, F., May. *Abnormal gait detection with RGB-D devices using joint motion history features*. In 2015 11th IEEE international conference and workshops on automatic face and gesture recognition (FG) (Vol. 7, pp. 1-6). IEEE. 2015.
- [8] Li, Q., Wang, Y., Sharf, A., Cao, Y., Tu, C., Chen, B. and Yu, S., "Classification of gait anomalies from kinect". *The Visual Computer*, vol. 34, n. 2, pp. 229-241. 2018.
- [9] Nguyen, T. N., Huynh, H. H. and Meunier, J., "Skeleton-based abnormal gait detection". *Sensors*, vol. 16, n. 1, p. 1792. 2016.
- [10] Lee, D. W., Jun, K., Lee, S., Ko, J. K. and Kim, M. S., *Abnormal gait recognition using 3D joint information of multiple Kinect's system and RNN-LSTM*. In 2019 41st Annual International Conference of the