



Research Article

Neural Network Model Validation for Gait Length Prediction Using Three Markers Attached to the Pelvis, Trunk, and Head

Mostafa Haj Lotfalian^{1,4,*} , Mohammad Javad Razi² , Fateme Zare Bidoki³

1. Department of Physical Education and Sports Science, Faculty of Psychology and Educational Sciences, Yazd University, Yazd, Iran

2. Department of Physical Education, Farhangian University, P.O. Box 889-14665, Tehran, Iran

3. Department of Sport Injuries and Biomechanics, Faculty of Sports and Health Sciences, Tehran University, Tehran, Iran

4. Center of Excellence for Support Systems in Health Development, Yazd University, Yazd, Iran

Received: 22/02/2022, Accepted: 12/08/2025, Online Published: 18/01/2025

* Corresponding Author: Mostafa Haj Lotfalian, E-mail: m.hajlotfalian@yazd.ac.ir

How to Cite: Haj Lotfalian, M.; Razi, M.J.; & Zare Bidoki, F. (2025). Neural Network Model Validation for Gait Length Prediction Using Three Markers Attached to the Pelvis, Trunk, and Head. *Sport Medicine Studies*, 17(45), 57-72. In Persian. Doi: [10.22089/smj.2025.17634.1790](https://doi.org/10.22089/smj.2025.17634.1790)

Extended Abstract

Background and Purpose

Motion analysis is essential for understanding human movement, with traditional approaches relying heavily on marker-based optical systems valued for their high accuracy and temporal resolution. Nonetheless, these systems are typically costly, time-consuming, and confined to controlled laboratory environments. Recent advancements have shifted attention towards more practical alternatives, including reduced-marker and markerless motion capture technologies. Reducing marker count streamlines setup while still capturing critical gait parameters. Markerless systems, empowered by deep learning and computer vision, enable natural, unrestricted gait assessments in real-world contexts. Despite some limitations in distal segment accuracy, these approaches are increasingly viable in research and clinical applications. Deep neural networks are central to this progress by facilitating automated anatomical landmark tracking. This study aims to validate a neural network model that estimates step length during walking using only three anatomical markers positioned on the pelvis, trunk, and head, balancing data simplicity and predictive efficacy.

Methods

Twenty-eight healthy young males (22.2 ± 2.09 years), recruited via purposive sampling, participated after providing informed consent; the protocol was approved by Yazd University Institutional Review Board (IR.YAZD.REC.1403.078). Participants performed treadmill walking at three speeds (preferred, slow, fast) for minimum durations of 40 seconds per speed while being recorded by a 3D motion capture system (Optitrack Duo120, USA) sampling at 120 Hz. Reflective marker clusters were placed on participants' pelvis and back of the head; single



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

markers were positioned on the C7 vertebra and heels. Marker positions were averaged to extract linear displacement data for head, trunk, and pelvis.

Raw data were filtered with a fourth-order Butterworth low-pass filter (6 Hz cutoff) and analyzed in MATLAB (R2021b). A custom script converted local to global coordinates, segmented gait cycles, normalized marker positions relative to participant height, and extracted step length at initial double support phase. Final data matrices comprised 4,710 time-normalized frames per marker. Thirteen predictor sets combining 3 to 9 features across sagittal, frontal, and transverse planes from pelvis, trunk, and head markers were created.

A two-layer feedforward neural network with 20 hidden neurons was trained using Levenberg–Marquardt optimization. Data were partitioned into training (70%), validation (15%), and test (15%) subsets. Step length served as the target variable. Model performance was appraised by Bland–Altman plots, mean error, coefficient of variation (CV), root mean square error (RMSE), and Pearson correlation coefficients — interpreted as weak (≤ 0.40), moderate (0.40 – 0.74), or strong (≥ 0.75). Analyses were conducted using MATLAB custom scripts.

Results

Mean step length based on heel markers was 29.8% of participant height (SD = 1.5%). From 4,710 gait cycles, 707 (15%) random samples validated the model predictions, with statistical characteristics mirroring the full dataset. The top-performing model utilized six features representing frontal and sagittal plane movements of all three markers, achieving a strong correlation with direct step length measures ($R = 0.93$), coefficient of determination (R^2) of 86.5%, and RMSE of 7.59 cm. The poorest performance occurred when using only lateral marker movements ($R = 0.31$). Ten out of thirteen predictor configurations demonstrated strong to very strong correlations, all statistically significant, reinforcing the feasibility of accurate step length estimation with minimal upper-body markers.

Conclusion

This study validates a neural network-based approach to estimate step length during walking using just three anatomical markers on the pelvis, trunk, and head. The highest accuracy arose when incorporating anterior-posterior and superior-inferior directional data, aligning with biomechanical principles where forward progression and vertical center-of-mass oscillations predominate gait dynamics. Models incorporating medial-lateral data alone exhibited poorer performance due to minimal variance in those directions. Integrating multiple markers and movement planes yields comprehensive gait characterization, while reliance on single markers suffers from reduced informational content and increased signal variability, underscoring the benefit of multi-input neural network models.

These results concur with prior studies employing machine learning or wearable sensor methods (IMUs), which reported correlations ranging from 0.79 to 0.95 for kinematic and kinetic estimates. Marker-based approaches without wearables similarly showed strong correlations (0.85–0.94), dependent on marker placement and target variables.

The utilization of central body anatomical landmarks, more reliably detected in markerless systems compared to distal limb markers, represents a meaningful advancement in simplifying gait analysis, reducing equipment needs, and accelerating data processing. This method holds promise especially in clinical and sports settings constrained by resource limitations.

Keywords: Validation, Neural Network, Step Length Prediction, Gait Analysis

Article Message

Step length estimation via a neural network trained on minimal motion data from pelvis, trunk, and head markers in primary movement directions offers high predictive validity relative to

traditional heel-marker measures. Leveraging central anatomical landmarks enhances practicality and cost-effectiveness of gait assessment without sacrificing accuracy, facilitating widespread adoption in diverse applied settings.

Ethical Considerations

The study was approved by the Institutional Review Board of Yazd University (Approval Code: IR.YAZD.REC.1403.078). Participant consent and ethical guidelines were rigorously observed.

Authors' Contributions

Conceptualization: Mostafa Haj Lotfalian (33%), Mohammad Javad Razi (33%), Fatemeh Zare Bidoki (33%)

Data Collection: Mostafa Haj Lotfalian (60%), Mohammad Javad Razi (20%), Fatemeh Zare Bidoki (20%)

Data Analysis: Mostafa Haj Lotfalian (40%), Mohammad Javad Razi (30%), Fatemeh Zare Bidoki (30%)

Manuscript Writing: Mostafa Haj Lotfalian (33%), Mohammad Javad Razi (33%), Fatemeh Zare Bidoki (33%)

Review and Editing: Mostafa Haj Lotfalian (30%), Mohammad Javad Razi (35%), Fatemeh Zare Bidoki (35%)

Literature Review: Mohammad Javad Razi (50%), Fatemeh Zare Bidoki (50%)

Project Management: Mostafa Haj Lotfalian (100%)

Conflict of Interest

The authors declare no conflicts of interest related to this article.

Acknowledgments

The authors sincerely thank all participants for their valuable contributions to this study.



نوع مقاله: پژوهشی

اعتباریابی مدل شبکه عصبی برای پیش بینی طول گام حین گیت با استفاده از سه مارکر متصل به لگن، تنه و سر

مصطفی حاج لطفعلیان^{۱،۴}، محمدجواد رضی^۲، فاطمه زارع بیدکی^۳

۱. گروه تربیت بدنی و علوم ورزشی، دانشکده روانشناسی و علوم تربیتی، دانشگاه یزد، یزد، ایران
۲. گروه آموزش تربیت بدنی، دانشگاه فرهنگیان، تهران، ایران
۳. گروه آسیب شناسی و بیومکانیک ورزشی، دانشکده علوم ورزشی و تندرستی، دانشگاه تهران، تهران، ایران
۴. هسته سامانه های پشتیبان در توسعه سلامت، دانشگاه یزد، یزد، ایران

تاریخ دریافت: ۱۴۰۳/۱۰/۲۹، تاریخ پذیرش: ۱۴۰۴/۰۵/۲۱، تاریخ انتشار آنلاین: ۱۴۰۴/۰۵/۳۱

نویسنده مسئول: مصطفی حاج لطفعلیان، M.hajlotfalian@yazd.ac.ir

How to Cite: Haj Lotfalian, M.; Razi, M.J.; & Zare Bidoki, F. (2025). Neural Network Model Validation for Gait Length Prediction Using Three Markers Attached to the Pelvis, Trunk, and Head. *Sport Medicine Studies*, 17(45), 57-72. In Persian. Doi: 10.22089/smj.2025.17634.1790

چکیده

تحلیل حرکتی یکی از ارکان کلیدی تحقیقات آنالیز گیت است که به تازگی تحت تأثیر پیشرفت های سیستم های ضبط حرکت و هوش مصنوعی قرار گرفته است. هدف مطالعه حاضر، اعتباریابی مدل شبکه عصبی برای پیش بینی طول گام با استفاده از سه مارکر متصل به لگن، تنه و سر بود. از ۲۸ مرد جوان حاضر در مطالعه خواسته شد تا به مدت دو دقیقه با سه سرعت روی تردمیل راه روند. جابه جایی خطی و سه بعدی لگن، تنه و سر با استفاده از نشانگرهای متصل به این اندام ها جمع آوری شد و در سیزده ترکیب مختلف وارد مدل شبکه عصبی شد. از دو نشانگر متصل به پاشنه برای محاسبه مستقیم طول گام استفاده شد. اطلاعات طول گام به عنوان داده هدف و به منظور آموزش شبکه عصبی وارد مدل شد. از الگوریتم لونیگ-مارکوارت برای آموزش و برای اعتبارسنجی نتایج از روش بلاند-آلتمن استفاده شد. نتایج اعتبارسنجی نشان داد، در تخمین طول گام، بهترین عملکرد مربوط به حرکت خطی سه مارکر در راستای بالایی-پایینی و قدامی-خلفی با ضریب تعیین ۸۶/۵ درصد بود. ضعیف ترین پیش بینی نیز مربوط به حرکت چپی-راستی سه مارکر لگن، تنه و سر با ضریب تعیین ۹/۶۵ درصد بود. همچنین در هفت حالت از سیزده حالت بررسی شده، همبستگی بین روش مستقیم و پیش بینی عالی به دست آمد. نتایج نشان داد، تخمین طول گام با استفاده از سه مارکر تعیین شده، همبستگی زیادی با روش های مرسوم اندازه گیری دارد. این روش نه تنها دقت بسیاری را ارائه می دهد، بلکه هزینه ها و زمان پردازش را نیز کاهش می دهد و در محیط های کلینیکی و ورزشی با تجهیزات محدود، مزیت مناسبی را ایجاد می کند.

واژگان کلیدی: اعتبارسنجی، شبکه عصبی، پیش بینی طول گام، تحلیل گیت.



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

مقدمه

تحلیل حرکتی یکی از پایه‌های اصلی تحقیقات حرکت انسان است که بینش ارزشمندی در مورد زوایای مفاصل و الگوهای حرکتی فراهم می‌کند. با ترکیب داده‌های حرکتی با منابع دیگر، مانند داده‌های نیرو، محققان می‌توانند درک جامعی از حرکت انسان به دست آورند (۱). این امر پیامدهای مهمی برای زمینه‌های مختلفی مانند بیومکانیک ورزشی، ارزیابی خطر آسیب و توان بخشی دارد (۲). مهم‌ترین مزیت سیستم‌های آنالیز حرکت، کمی‌سازی ارزیابی‌ها، تکرارپذیری و عینی سازی تحلیل‌ها در مقایسه با مشاهدات بصری است (۳، ۴).

یکی از رایج‌ترین فناوری‌ها برای تحلیل حرکت، استفاده از سیستم‌های تحلیل حرکت مبتنی بر نشانگر^۱ است. سیستم‌های ضبط حرکت مبتنی بر نشانگر مادن قرمز^۲ برای ردیابی حرکات پیوسته در فضای سه‌بعدی طراحی شده‌اند (۵). این سیستم‌ها به دلیل دقت زیاد خود به عنوان استاندارد طلایی در تحلیل راه رفتن و در ردیابی دقیق حرکات انسانی شناخته می‌شوند (۶)؛ با این حال، این روش‌ها محدودیت‌هایی دارند: نخست، آن‌ها به نصب تعداد زیادی نشانگر روی بدن فرد نیاز دارند که فرایندی زمان‌بر است و باید در آزمایشگاه و شرایط کنترل‌شده انجام شود. (۷)؛ علاوه بر این، این سیستم‌ها معمولاً هزینه‌بر هستند و باید توسط کارکنان متخصصی که بتوانند نشانگرها را به درستی نصب کرده و داده‌های ثبت‌شده را تجزیه و تحلیل کنند، مدیریت شوند (۷)؛ بنابراین، این فرایند به منابع انسانی و زمانی زیادی نیاز دارد؛ به همین دلیل، در سال‌های اخیر، تلاش‌های متعددی برای یافتن روش‌های ارزان‌تر، سریع‌تر و ساده‌تر برای توصیف و تحلیل حرکات انسانی صورت گرفته است (۸). در میان گزینه‌های موجود، سیستم‌های مبتنی بر حسگرهای پوشیدنی، مانند واحدهای اندازه‌گیری اینرسی (IMU) و همین‌طور سیستم‌های آنالیز حرکت بدون نشانگر به دلیل هزینه‌های کمتر، به عنوان جایگزین‌های معقولی شناخته می‌شوند (۵). سنسورهای اینرسی (IMU) به عنوان رایج‌ترین نوع سنسورهای پوشیدنی برای تحلیل راه رفتن شناخته می‌شوند. این سیستم‌ها به دلیل اندازه کوچک و هزینه کمتر در مقایسه با سیستم‌های ضبط حرکت نوری محبوب شده‌اند و این امر منجر به افزایش استفاده از آن‌ها در تشخیص‌های بالینی شده است (۹). نتایج مطالعات اخیر حاکی از روایی و پایایی مطلوب این سنسورها در بررسی مؤلفه‌های مرتبط با گام‌برداری مانند طول و زمان استراید است (۱۰، ۱۱)؛ با وجود این، این سنسورها همواره با مشکل کاستی در ادغام داده‌ها مواجه هستند که این امر می‌تواند به تخمین‌های نادرستی در موقعیت منجر شود. (۱۲). تلاش‌های اخیر برای توسعه روش‌های آنالیز حرکت بدون نشانگر، این امکان را فراهم کرده است تا تجزیه و تحلیل حرکت در محیط خارج از آزمایشگاه و در شرایط طبیعی‌تر و بدون محدودیت انجام شود (۱۳). با توجه به پیشرفت‌های اخیر در تکنیک‌های بینایی کامپیوتری و افزایش توان پردازشی، سیستم‌های ضبط حرکت بدون نیاز به نشانگرها بهبودهای چشمگیری در دقت و زمان پردازش پیدا کرده‌اند و اکنون به عنوان محصولات تجاری دردسترس هستند. این سیستم‌ها به دلیل نبود وابستگی به نشانگرهای متصل به پوست، به آزمودنی‌ها این امکان را می‌دهند که لباس‌های معمولی خود را بپوشند و نیازی به استفاده از لباس‌های محدودکننده نباشد (۱۴). این ویژگی نه تنها راحتی بیشتر برای آزمودنی‌ها به همراه دارد، بلکه به آن‌ها اجازه می‌دهد تا وظایف فیزیکی را طبیعی‌تر انجام دهند و نتایج واقعی‌تری به دست آید. این روش به محققان این امکان را می‌دهد که مجموعه‌ای از تصاویر با برچسب‌های مشخص را جمع‌آوری کنند و یک شبکه عصبی را برای ردیابی خودکار نقاط مدنظر در ویدئو آموزش دهند (۱۵، ۱۶). این ابزار از انعطاف‌پذیری بیشتری نسبت به سایر سیستم‌های ضبط حرکت بدون نشانگر برخوردار است. به جای پیگیری مجموعه‌ای از ویژگی‌ها یا نشانه‌های مشخص، این سیستم می‌تواند هر ویژگی

1. Marker-Based Motion Capture

2. Infrared Marker-Based Motion Capture Systems

دلخواهی را ردیابی کند؛ با این حال، برخی از مطالعات نشان داده‌اند که سیستم‌های بدون نشانگر در تحلیل حرکات نسبت به سیستم‌های مبتنی بر نشانگر از دقت کمتری برخوردارند؛ به‌ویژه دقت سیگنال‌های حرکتی ثبت‌شده از پاها و مچ پاها کمتر از نواحی حساس‌تری مانند لگن، تنه و سر است (۱۷، ۱۸).

در عصر حاضر، هوش مصنوعی^۱ به نقطه عطفی اساسی در دنیای فناوری تبدیل شده و پیشرفت‌های چشمگیری در زمینه یادگیری عمیق به وقوع پیوسته است. این فرایند که به کمک تکنیک‌های یادگیری ماشین به سطح بالایی دست یافته است، به طور درخور ملاحظه‌ای دقت تشخیص ویژگی‌ها را افزایش داده است. هوش مصنوعی، به‌ویژه با بهره‌گیری از یادگیری عمیق و شبکه‌های عصبی، نقش مهمی در تحلیل راه رفتن ایفا می‌کند و کاربردهای متعددی در این زمینه دارد (۱۹، ۲۰). یکی از کاربردهای اصلی، شناسایی الگوهای حرکتی است که شامل سرعت، طول گام و توزیع وزن بدن می‌شود و می‌تواند در تحلیل وضعیت بالینی و طراحی برنامه‌های آموزشی مؤثر باشد. همچنین هوش مصنوعی قادر است رفتار افراد را از طریق داده‌های جمع‌آوری‌شده از سنسورها و دوربین‌ها پیش‌بینی کند که این امر می‌تواند به پیشگیری از سقوط و آسیب‌های ناشی از اختلالات حرکتی کمک کند (۲۱-۲۴). به‌علاوه، با تجزیه و تحلیل داده‌های حرکتی، این فناوری به درک بیومکانیک راه رفتن کمک می‌کند و می‌تواند اطلاعات ارزشمندی را برای بهینه‌سازی پروتزها و ارتوزها فراهم آورد (۲۵). همچنین هوش مصنوعی به شناسایی زودهنگام بیماری‌هایی نظیر پارکینسون کمک می‌کند و از طریق تحلیل ناهنجاری‌های حرکتی، تشخیص‌های دقیق‌تری را ممکن می‌کند (۲۶). درنهایت، در حوزه ورزش، این فناوری با تجزیه و تحلیل دقیق حرکات به بهبود تکنیک‌های راه رفتن و دویدن ورزشکاران کمک می‌کند و به آن‌ها امکان می‌دهد عملکرد خود را افزایش دهند (۲۷).

به‌منظور استفاده هر چه بیشتر از سیستم‌های بدون نشانگر، ضروری است دقت سیگنال‌های حرکتی ثبت‌شده از اندام تحتانی بهینه شود. از طرفی تخمین دقیق طول گام در راه رفتن از اهمیت بسیاری برخوردار است. این تخمین نه‌تنها می‌تواند به بهبود درک ما از الگوهای حرکتی فردی کمک کند، بلکه اطلاعات حیاتی در زمینه بررسی و تشخیص اختلالات حرکتی و بیماری‌های مرتبط با سیستم عصبی نیز فراهم می‌آورد؛ از این‌رو مطالعه حاضر در پی اعتبارسنجی مدل یادگیری ماشین مبتنی بر شبکه‌های عصبی برای پیش‌بینی طول گام در هنگام راه رفتن با استفاده از سه نشانگر نصب‌شده در نواحی لگن، تنه و سر بود. این رویکرد نه‌تنها به بهبود دقت پیش‌بینی کمک خواهد کرد، بلکه می‌تواند افق‌های جدیدی در تحلیل حرکتی ایجاد کند و حوزه بیومکانیک را به سوی نوآوری‌های بیشتر نیز هدایت کند.

روش پژوهش

آزمودنی‌ها

این تحقیق شامل ۲۸ شرکت‌کننده (سن: $22/2 \pm 2/09$ ، قد: $174/5 \pm 6/44$ ، وزن: $71/5 \pm 8/8$) بود که از طریق نمونه‌گیری دردسترس هدفمند از جامعه‌ای متشکل از مردان جوان انتخاب شدند. حجم نمونه براساس مطالعه گلوئر^۲ و همکاران برآورد شد. این مطالعه نشان داد، درجه آزادی برابر با ۲۷، اطمینان معقولی برای ارزیابی تکراری پذیري فراهم می‌کند (۲۸). معیار خروج از مطالعه وجود درد و ناهنجاری در پایین‌تنه و بروز آسیب در پایین‌تنه طی شش ماه گذشته بود. این مطالعه توسط هیئت بررسی سازمانی دانشگاه یزد تأیید شد (کد: IR.YAZD.REC.1403.078) و همه آزمودنی‌ها رضایت آگاهانه کتبی برای شرکت در آن ارائه دادند.

1. Artificial Intelligence

2. gluer

ثبت داده

این مطالعه شامل یک جلسه ثبت الگوی گام برداری به منظور اعتباریابی پیش‌بینی حاصل از مدل شبکه عصبی بود؛ بر این اساس، آزمودنی‌ها پس از آگاهی از روند آزمون می‌بایست برای زمان حداقل ۲ دقیقه روی تردمیل راه می‌رفتند. ابتدا سرعت ترجیحی آزمودنی‌ها محاسبه شد و مقادیر ۲۰ درصد کمتر و بیشتر از سرعت ترجیحی به ترتیب به عنوان سرعت کم و زیاد برآورد شد (۲۹). به منظور ثبت اطلاعات حرکتی آزمودنی‌ها بنابر هدف مطالعه حاضر، دو مارکر خوشه‌ای (حداقل سه مارکر غیر همسطح) به پشت سر و پشت لگن متصل شد. با توجه به اینکه در این پژوهش موقعیت خطی مارکرها مدنظر بود، برآیند موقعیت مارکرها متصل به مارکهای خوشه‌ای به عنوان موقعیت سر و لگن در نظر گرفته شد. همچنین برای بررسی حرکت تنه، یک مارکر به لندمارک C7 و به منظور بررسی طول گام، دو مارکر به پاشنه پای چپ و راست متصل شد.



شکل ۱- دستگاه مختصات زمین و موقعیت قرارگیری مارکرها روی بدن آزمودنی‌ها

Figure 1- Ground coordinate system and the position of markers on the subjects' body

سپس از آزمودنی‌ها خواسته شد تا در وضعیت ایستادن آناتومیکی روی تردمیل (Hp Cosmos Mercury, Germany) قرار بگیرند و به محض روشن شدن تردمیل شروع به راه رفتن کنند. سرعت تردمیل از قبل روی یکی از سه سرعت کم، ترجیحی و زیاد تنظیم شده بود و پس از گام برداری توسط آزمودنی، به صورت تصادفی روی دو سرعت دیگر قرار می‌گرفت. در مجموع، آزمودنی‌ها هریک از سرعت‌ها را برای حداقل ۴۰ ثانیه طی کردند. کل این فرایند با استفاده از سیستم آنالیز حرکت سه‌بعدی (Optitrack Dou120, USA) برای سه مرتبه با فرکانس داده‌برداری ۱۲۰ هرتز ثبت شد. از فیلتر باترورث مرتبه ۴ با فرکانس قطع ۶ هرتز برای هموارسازی موقعیت مارکرها استفاده شد.

تحلیل داده‌ها

برای آماده‌سازی داده‌ها به منظور ورود به مدل شبکه عصبی، دستورالعملی شخصی‌سازی شده در نرم‌افزار متلب (R2021b) نگاشته شد. طبق این دستورالعمل، ابتدا اطلاعات خروجی از سیستم آنالیز حرکت، به دستگاه مختصات زمین منتقل شد و سپس برچسب‌گذاری^۱ شد و اطلاعات هریک از ۲۸ نفر آزمودنی در یک ماتریس ۱۴۴۰ ردیفه و ۱۵ ستونی ثبت شد. ردیف‌های این ماتریس بیانگر موقعیت سه‌بعدی مارکرها در هر $\frac{1}{۱۳}$ ثانیه که مربوط به تمام ۱۲۰ ثانیه گام برداری آزمودنی بود و ستون‌ها نیز بیانگر موقعیت سه‌بعدی پنج مارکر متصل به سر، تنه، لگن، پاشنه راست و چپ بود. در ادامه با استفاده

1. Labeling

از دو مارکر پاشنه راست و پاشنه چپ، طول گام راست و طول گام چپ در لحظه ابتدایی فاز حمایت دوغانه به دست آمد. اطلاعات ۱۵ ستون ماتریس مذکور، در تمام لحظاتی که طول گام در آن ثبت شده بود، جدا و مجدد ذخیره سازی شد. در این مرحله، ماتریسی شامل ۱۶۰ تا ۱۸۰ ردیف و ۱۵ ستون برای هریک از آزمودنی به دست آمد. برای افزایش جامعیت نتایج، طول قد هریک از آزمودنی ها بر اطلاعات این ماتریس تقسیم و در صد ضرب شد؛ به عبارتی، موقعیت مارکرهای انتخابی به صورت درصدی از قد آزمودنی ها بیان شد. در ادامه اطلاعات خروجی ۲۸ آزمودنی در یک ماتریس نهایی که شامل ۴۷۱۰ ردیف و ۱۵ ستون بود، ذخیره شد. از این ماتریس، ستون های مربوط به حرکت قدامی-خلفی، چپی-راستی و بالایی-پایینی سه مارکر سر، تنه و لگن به عنوان آرایه های سازنده ماتریس پیش بین^۱ نگه داشته شد و ستون های مربوط به موقعیت پاشنه پای راست و چپ حذف شد. اطلاعات طول گام که در مرحله قبل به دست آمده بود نیز به عنوان مؤلفه پاسخ^۲ در نظر گرفته شد. ماتریس پیش بین در سیزده حالت مختلف با حداقل سه مؤلفه به شبکه عصبی وارد شد که در جدول (۱) آمده است.

جدول ۱- ماتریس های پیش بین در ۱۳ حالت مختلف برای ورود به مدل شبکه عصبی

Table 1- Predictive matrices in 13 different modes for entering the neural network model

درجات آزادی Degrees of freedom	ابعاد ماتریس پیش بین Dimensions of the predictor matrix	ماتریس پیش بین Predictor matrix
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی لگن	4710*3	لگن
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی تنه	4710*3	تنه
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی سر	4710*3	سر
راستای قدامی-خلفی لگن، تنه و سر	4710*3	ساجیتال
راستای چپی-خلفی لگن، تنه و سر	4710*3	هریزنتال
راستای بالایی-پایینی لگن، تنه و سر	4710*3	فرونرال
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی لگن و تنه	4710*6	لگن-تنه
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی لگن و سر	4710*6	لگن-سر
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی تنه و سر	4710*6	تنه-سر
راستای قدامی-خلفی و چپی-راستی لگن، تنه و سر	4710*6	ساجیتال-هریزنتال
راستای قدامی-خلفی و بالایی-پایینی لگن، تنه و سر	4710*6	ساجیتال-فرونرال
راستای چپی-راستی و بالایی-پایینی لگن، تنه و سر	4710*6	هریزنتال-فرونرال
سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی لگن، تنه و سر	4710*9	لگن-تنه-سر

از یک شبکه پیشخور دو لایه با ۲۰ لایه پنهان برای آموزش و ارزیابی میزان تطبیق استفاده شد. در این شبکه، الگوریتم بهینه ساز لونیبرگ-مارکوارت^۳ برای آموزش شبکه به کار رفت. از ۷۰ درصد داده ها برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای تست شبکه عصبی استفاده شد. برای پیاده سازی شبکه، اپلیکیشن تطبیق شبکه عصبی^۴ در نرم افزار متلب به کار رفت.


1. Predictor
2. Response
3. Levenberg-Marquardt
4. Fitting Neural Network

تجزیه و تحلیل آماری

برای اعتباریابی نتایج پیش‌بینی طول گام با استفاده از تک‌مارک‌های متصل به لگن، تنه و سر از روش بلاند-آلتمان^۱، اختلاف میانگین، ضریب تغییر، خطای جذر میانگین مربعات و همبستگی پیرسون استفاده شد. آستانه‌های همبستگی به صورت ضعیف ($\geq 0/40$)، متوسط ($0/40-0/74$) و عالی ($\geq 0/75$) تعیین شد. همه تجزیه و تحلیل آماری با استفاده از تابع بلاند-آلتمان در نرم‌افزار متلب انجام شد.

نتایج


نتایج ارزیابی طول گام با استفاده از سیستم آنالیز حرکت از طریق مارک‌های متصل به پاشنه در ۴۷۱۰ داده ورودی دارای میانگین ۲۹/۸ و انحراف استاندارد ۵/۱ درصدی از قد افراد به دست آمد. پس از انجام مرحله آموزش شبکه عصبی، ۱۵ درصد از ۴۷۱۰ داده ورودی که شامل ۷۰۷ سری داده بود، به صورت تصادفی برای اعتبارسنجی شبکه عصبی در پیش‌بینی طول گام با استفاده از مارک‌های متصل به لگن، تنه و سر انتخاب شد. میانگین و انحراف استاندارد این ۷۰۷ داده به ترتیب ۲۹/۹ و ۵/۲ درصدی طول قد بود که قرابت بسیار زیادی با شاخص‌های مرکزی و پراکندگی کل داده‌ها داشت. شکل (۲) نمودار هیستوگرام داده‌های کل و تست را پس از محاسبه مستقیم طول گام از مارک‌های متصل به پاشنه نشان می‌دهد.



شکل ۲- نمودار هیستوگرام داده‌های کل و تست حاصل از اندازه‌گیری مستقیم طول گام از مارک‌های متصل به پاشنه
Figure 2- Histogram of the full and test datasets based on direct measurement of step length using heel-attached markers.

شکل (۳) آمار توصیفی داده‌های حاصل از محاسبه طول گام را که به صورت غیرمستقیم با استفاده از شبکه عصبی به دست آمده و همچنین طول گام محاسبه‌شده به روش مستقیم از طریق مارک‌های متصل به پاشنه را نشان می‌دهد. همان‌طور که مشاهده می‌شود، مقادیر میانگین به‌دست‌آمده از سیزده حالت شبکه عصبی، به میانگین طول گام حاصل

از مارکرهای پاشنه نزدیک است. انحراف استانداردهای به دست آمده از دوازده مدل شبکه عصبی، به فراخور متنوع است و در برخی حالتها تفاوت‌های محسوسی با روش محاسبه مستقیم طول گام دارد.



شکل ۳- میانگین و انحراف استاندارد طول گام پیش‌بینی شده با شبکه عصبی (نمودارهای خاکستری) و اندازه‌گیری مستقیم از موقعیت پاشنه‌ها (نمودار مشکی)

Figure 3- Mean and standard deviation of step length predicted by the neural network (grey plots) compared to direct measurements from heel positions (black plots).

جدول (۲) نتایج حاصل از اعتباریابی سیزده حالت مختلف پیش‌بینی طول گام را با استفاده از شبکه عصبی و مارکرهای لگن، تنه و سر نشان می‌دهد. همان‌طور که مشاهده می‌شود، در شش حالت صرفاً از سه ویژگی (درجه آزادی) استفاده شده است. از بین این شش حالت، استفاده از حرکت خطی سه مارکر در راستای بالایی-پایینی (فرونال)، کمترین خطای جذر میانگین مربعات را داشت (۹/۸۶) و بیشترین همبستگی (۰/۸۶) و ضریب تعیین (۷۳/۹ درصد) را به خود اختصاص داد. ضعیف‌ترین پیش‌بینی نیز مربوط به انتخاب حرکت چپی-راستی سه مارکر لگن، تنه و سر بود که همبستگی ۰/۳۱ و ضریب تعیینی معادل ۹/۶ درصد با اندازه‌گیری مستقیم داشت. از بین سیزده حالت ماتریس پیش‌بین، در شش حالت نیز از شش ویژگی استفاده شد. همان‌طور که در جدول (۲) مشاهده می‌شود، در پنج حالت مقادیر ضریب همبستگی با اندازه‌گیری مستقیم، عالی بود و تنها در حالتی که از اطلاعات حرکتی سه مارکر لگن، تنه و سر در دو راستای جلویی-عقبی و چپی-راستی استفاده شد، ضریب همبستگی متوسط بود. از بین این شش حالت، انتخاب درجات آزادی حرکت مارکرها در دو راستای جلویی-عقبی و بالایی-پایینی ضریب همبستگی ۰/۹۳ و ضریب تعیین ۸۶/۵ درصد را با روش اندازه‌گیری مستقیم نشان می‌دهد. دقت این حالت در پیش‌بینی طول گام بسیار نزدیک و البته مقداری بیشتر از زمانی است که از سه راستای هر سه مارکر لگن، تنه و سر استفاده شده است. شایان ذکر است، مقادیر همبستگی هر سیزده حالت با روش اندازه‌گیری مستقیم از نظر آماری معنادار بود.

جدول ۲- اعتبار سنجی ۱۳ حالت ورودی مدل شبکه عصبی

Table 2- Validation results of the 13 input configurations for the neural network model

T-test	ضریب تعیین (R ²)	ضریب همبستگی (R)	خطای جذر میانگین مربعات (RMSE)	جمع باقیمانده مربعات (SSE)	تفاوت میانگین‌ها Mean Difference	ضریب پراکندگی Coefficient of Variation	تعداد ویژگی Number of Features	ماتریس پیش‌بین Predictor Matrix
0.440	31.3	0.56	15.25	164350	-0.49	50.88	3	لگن Pelvis
0.635	42.2	0.65	14.00	138710	-1.23	46.37		تنه Trunk
0.228	24.0	0.49	15.92	179350	-0.24	53.26		سر Head
0.461	16.8	0.41	16.83	200430	-0.68	56.16		ساجیتال Sagittal
0.172	9.6	0.31	17.35	212870	-0.51	58.01		هریزنتال Horizontal
0.485	73.9	0.86	9.86	68772	0.17	32.93	6	فرونتال Frontal
0.467	67.2	0.82	11.22	89086	-1.20	37.05		لگن-تنه Pelvis-trunk
0.687	56.2	0.75	12.48	110110	-0.93	41.37		لگن-سر Pelvis-head
0.950	72.2	0.85	10.17	73246	-0.51	33.84		تنه-سر Trunk-head
0.500	28.9	0.53	15.55	170960	-0.50	51.88		ساجیتال-هریزنتال Sagittal-horizontal
0.782	86.5	0.93	7.59	40780	0.085	25.32		ساجیتال-فرونتال Sagittal-frontal
0.841	77.4	0.88	9.34	61624	-0.58	31.00		هریزنتال-فرونتال Horizontal-frontal
0.822	84.6	0.92	7.68	41724	0.083	25.60		لگن-تنه-سر Pelvis-trunk-head

بحث و نتیجه‌گیری

هدف این مطالعه، اعتبارسنجی مدل یادگیری ماشین بر پایه شبکه عصبی برای پیش‌بینی طول گام هنگام راه رفتن با استفاده از سه مارکر در ناحیه لگن، تنه و سر بود. برای انجام این کار، به مدل یادگیری ماشین آموزش دادیم تا طول گام را با استفاده از نشانه‌های آناتومیکی از تصویربرداری حرکتی پیش‌بینی کند. در این پژوهش به صورت کلی دریافتیم که شبکه عصبی به‌عنوان ابزاری برای پیش‌بینی، می‌تواند به‌خوبی تغییرات پیچیده داده‌های حرکتی را تحلیل کرده و نتایج معناداری را ارائه دهد.

تجزیه و تحلیل داده‌ها نشان داد، مدل یادگیری ماشین در حالتی که از اطلاعات حرکتی سه مارکر (لگن، تنه و سر) در راستای قدامی-خلفی و بالایی-پایینی استفاده شد، بیشترین ضریب همبستگی ($0/93$) را داشت و در این حالت طول گام را با دقت بیشتری پیش‌بینی کرد. در حالتی که از اطلاعات سه مارکر در سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی استفاده شد، ضریب همبستگی $0/92$ به دست آمد که بسیار نزدیک به حالت قبلی بود و پیش‌بینی دقیقی را می‌توان با این اطلاعات به دست آورد. در حالت‌های دیگر، ضریب همبستگی به‌ترتیب برای سه مارکر در راستای چپی-راستی و بالایی-پایینی $0/88$ ، برای اطلاعات مارکر در راستای بالایی-پایینی $0/86$ و برای دو مارکر سر و تنه در سه راستای قدامی-خلفی، چپی-راستی و بالایی-پایینی $0/85$ بود. همچنین برای دو مارکر لگن و تنه، ضریب همبستگی $0/82$ و برای دو مارکر لگن و سر $0/75$ به دست آمد. در این هفت حالت، میزان ضریب همبستگی در سطح عالی بود و می‌توان از آن‌ها برای پیش‌بینی طول گام با دقت زیاد، استفاده کرد.

این یافته‌ها در راستای تحقیقات قبلی است که به بررسی دقت مدل‌های یادگیری ماشین با استفاده از سنسورها و مارکرهای مختلف در پیش‌بینی مؤلفه‌های کینماتیک و کینتیک پرداخته‌اند و اعتبار زیادی را گزارش کرده‌اند. در تحقیقاتی که به اعتبارسنجی مدل‌های یادگیری ماشین با سیستم‌های مبتنی بر حسگرهای پوشیدنی، مانند واحدهای اندازه‌گیری اینرسی (IMU) پرداختند، میزان اعتبار سنسورها را $0/79-0/95$ گزارش کردند ($34-30$). در مطالعاتی که از اطلاعات مارکرهای آناتومیکی برای بررسی اعتبار سیستم‌های ضبط حرکت بدون نیاز به نشانگر استفاده کردند، میزان اعتبار با توجه به موقعیت مارکر و نوع مؤلفه ارزیابی شده از $0/94-0/85$ گزارش شد ($37-35$). اوت^۱ و همکاران، اعتبار حسگرهای کینکت^۲ را در حرکات عملکردی بررسی کردند و دریافتند که میزان دقت در محور هوریزنتال کمترین و در محورهای ساجیتال و فرونتال بیشترین بوده است. همچنین در این مطالعه، مارکرهای سنترال و پروگزیمال دقت بیشتری را نشان دادند (18). مطالعات گذشته بیان کردند که دقت مدل یادگیری ماشین در سنجش مؤلفه‌های کینماتیکی در راستاهای حرکتی مختلف متفاوت است ($38, 18$). در مدل مطالعه ما اختلاف در میزان همبستگی در راستاهای مختلف احتمالاً به این دلیل است که راستای قدامی-خلفی در جهت گام برداشتن است و اطلاعات درمورد پیشروی بدن ارائه می‌دهد. همچنین راستای بالایی-پایینی نقش مهمی در تعادل و مکانیک گام دارد و تغییرات آن نشان‌دهنده نوسانات مرکز جرم بدن است که بر طول گام اثر می‌گذارد و به‌علاوه در این راستا نوسانات حین راه رفتن کمتر است (39)؛ بنابراین اطلاعات در این دو راستا با ترکیب مارکرهای آناتومیکی باعث همبستگی زیاد در نتایج مطالعه حاضر شده است؛ اما راستای چپی-راستی در طول گام تغییرات کمی دارد و تأثیر مستقیم بر طول گام ندارد و در مطالعه حاضر اطلاعات این راستا برای تخمین طول گام، کمترین میزان همبستگی با روش گلد استاندارد دارد ($31, 0$). مارکرهای لگن، تنه و سر اطلاعات متفاوتی درباره نحوه تعامل بخش‌های مختلف بدن فراهم می‌کند و در صورت ترکیب اطلاعات سه مارکر،

1. Otte

2. Kinect

پیش‌بینی دقیق‌تر و در صورت استفاده تنها یکی از مارکرها، اطلاعات محدودتر می‌شود و دقت پیش‌بینی کاهش می‌یابد. وقتی داده‌های مربوط به لگن، تنه و سر به طور هم‌زمان استفاده می‌شوند، مدل می‌تواند به درک بهتری از چگونگی تعامل این بخش‌ها برای تولید طول گام برسد. این تعاملات شامل تغییرات دینامیکی در هر سه راستا است که اطلاعات جامعی را فراهم می‌کند. در راستای قدامی-خلفی و بالایی-پایینی به دلیل ارتباط مستقیم با انتقال وزن بدن و تنظیم تعادل در طول گام، دقت تخمین طول گام افزایش می‌یابد. استفاده ترکیبی از مارکرهای آناتومیکی و راستاهای حرکتی مختلف می‌تواند دقت پیش‌بینی را افزایش دهد؛ در حالی که استفاده از یک مارکر به تنهایی یا در راستاهای محدود، منجر به کاهش همبستگی و دقت تخمین می‌شود. در مطالعه حاضر، زمانی که از اطلاعات سه مارکر لگن، تنه و سر هر کدام به تنهایی و در دو راستای جلویی-عقبی و چپی-راستی با هم و راستای جلویی-عقبی به تنهایی استفاده شد، ضریب همبستگی متوسط مشاهده شد. درواقع، هر مارکر اطلاعات متفاوتی درباره نحوه تعامل بخش‌های مختلف بدن فراهم می‌کند و در صورت استفاده یکی از مارکرها اطلاعات محدود می‌شود و دقت پیش‌بینی کاهش می‌یابد. احتمالاً به هنگام استفاده از اطلاعات یک مارکر به تنهایی، تغییر نوسانات اطلاعات مارکر در حین راه رفتن بیشتر است و احتمال خطا نیز افزایش می‌یابد.

پیام مقاله

تخمین طول گام با مدل یادگیری ماشین بر پایه شبکه عصبی و استفاده از اطلاعات حرکتی سه مارکر در راستای بالایی-پایینی و جلویی-عقبی، همبستگی زیادی را با روش محاسبه مستقیم طول گام با استفاده از مارکرهای روی پاشنه نشان داد که برای پیش‌بینی طول گام اعتبار بسیاری دارد. استفاده از لندمارک‌های آناتومیکی ناحیه مرکزی بدن که تشخیص آن‌ها در سیستم‌های آنالیز حرکت بدون مارکر، دقت مطلوب‌تری نسبت به اندام‌های دور از تنه دارد، در تشخیص موقعیت اندام‌های تحتانی، پیشرفت بزرگی در ساده‌سازی فرایند تحلیل گیت محسوب می‌شود. این روش می‌تواند هزینه‌های تجهیزات و زمان پردازش را به شدت کاهش دهد، در حالی که دقت زیادی را ارائه می‌دهد. چنین کاربردی به‌ویژه برای محیط‌های کلینیکی یا ورزشی که منابع و تجهیزات محدودتری دارند، بسیار ارزشمند است.

ملاحظات اخلاقی

این مطالعه توسط هیئت بررسی سازمانی دانشگاه یزد تأیید شد (کد: IR.YAZD.REC.1403.078)

مشارکت نویسندگان

ایده‌پردازی: مصطفی حاج لطفعلیان (۳۳ درصد)، محمدجواد رضی (۳۳ درصد) و فاطمه زارع بیدکی (۳۳ درصد)
جمع‌آوری داده‌ها: مصطفی حاج لطفعلیان (۶۰ درصد)، محمدجواد رضی (۲۰ درصد) و فاطمه زارع بیدکی (۲۰ درصد)
تحلیل داده‌ها: مصطفی حاج لطفعلیان (۴۰ درصد)، محمدجواد رضی (۳۰ درصد) و فاطمه زارع بیدکی (۳۰ درصد)
نوشتن مقاله: مصطفی حاج لطفعلیان (۳۳ درصد)، محمدجواد رضی (۳۳ درصد) و فاطمه زارع بیدکی (۳۳ درصد)
بازبینی و ویرایش: مصطفی حاج لطفعلیان (۳۰ درصد)، محمدجواد رضی (۳۵ درصد) و فاطمه زارع بیدکی (۳۵ درصد)
مرور ادبیات: محمدجواد رضی (۵۰ درصد) و فاطمه زارع بیدکی (۵۰ درصد)
مدیر پروژه: مصطفی حاج لطفعلیان (۱۰۰ درصد)

تعارض منافع

بنابر اظهار نویسندگان، این مقاله تعارض منافع ندارد.

تشکر و قدردانی

از تمامی شرکت کنندگان در این مطالعه تشکر و قدردانی می‌شود.

منابع

1. Winter DA. Biomechanics and motor control of human gait: normal, elderly and pathological. Waterloo: University of Waterloo Press; 1991.
2. Colyer SL, Evans M, Cosker DP, Salo AI. A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system. Sports Medicine-Open. 2018;4:1-5. <https://doi.org/10.1186/s40798-018-0139-y>
3. Wren TA, Tucker CA, Rethlefsen SA, Gorton III GE, Öunpuu S. Clinical efficacy of instrumented gait analysis: Systematic review 2020 update. Gait & posture. 2020;80:274-9. <https://doi.org/10.1016/j.gaitpost.2020.05.031>
4. Carneros-Prado D, González-Velázquez S, Dobrescu CC, González I, Fontecha J, Hervás R. Automation of observational gait assessment through an optical 3D motion system and transformers. Applied Intelligence. 2025;55(3):1-21. <https://doi.org/10.1007/s10489-024-06163-w>
5. Moro M, Marchesi G, Hesse F, Odone F, Casadio M. Markerless vs. marker-based gait analysis: A proof of concept study. Sensors. 2022;22(5):2011. <https://doi.org/10.3390/s22052011>
6. Van der Kruk E, Reijne MM. Accuracy of human motion capture systems for sport applications; state-of-the-art review. European Journal of Sport Science. 2018;18(6):806-19. <https://doi.org/10.1080/17461391.2018.1463397>
7. Carse B, Meadows B, Bowers R, Rowe P. Affordable clinical gait analysis: An assessment of the marker tracking accuracy of a new low-cost optical 3D motion analysis system. Physiotherapy. 2013;99(4):347-51. <https://doi.org/10.1016/j.physio.2013.03.001>
8. Desmarais Y, Mottet D, Slangen P, Montesinos P. A review of 3D human pose estimation algorithms for markerless motion capture. Computer Vision and Image Understanding. 2021;212:103275. <https://doi.org/10.1016/j.cviu.2021.103275>
9. He Y, Chen Y, Tang L, Chen J, Tang J, Yang X, Su S, Zhao C, Xiao N. Accuracy validation of a wearable IMU-based gait analysis in healthy female. BMC Sports Science, Medicine and Rehabilitation. 2024;16(1):2. <https://doi.org/10.1186/s13102-023-00792-3>
10. Park S, Yoon S. Validity evaluation of an inertial measurement unit (IMU) in gait analysis using statistical parametric mapping (SPM). Sensors. 2021;21(11):3667. <https://doi.org/10.3390/s21113667>
11. Kobsar D, Charlton JM, Tse CT, Esculier JF, Graffos A, Krowchuk NM, Thatcher D, Hunt MA. Validity and reliability of wearable inertial sensors in healthy adult walking: A systematic review and meta-analysis. Journal of Neuroengineering and Rehabilitation. 2020;17:1-21. <https://doi.org/10.1186/s12984-020-00685-3>
12. Zhou L, Tunca C, Fischer E, Brahms CM, Ersoy C, Granacher U, Arnrich B. Validation of an IMU gait analysis algorithm for gait monitoring in daily life situations. In: 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). 2020 (pp. 4229-4232). IEEE. <https://doi.org/10.1109/EMBC44109.2020.9176827>
13. Cronin NJ, Rantalainen T, Ahtiainen JP, Hynynen E, Waller B. Markerless 2D kinematic analysis of underwater running: A deep learning approach. Journal of Biomechanics. 2019;87:75-82. <https://doi.org/10.1016/j.jbiomech.2019.02.021>
14. Kanko RM, Laende E, Selbie WS, Deluzio KJ. Inter-session repeatability of markerless motion capture gait kinematics. Journal of Biomechanics. 2021;121:110422. <https://doi.org/10.1016/j.jbiomech.2021.110422>
15. Mathis A, Mamidanna P, Cury KM, Abe T, Murthy VN, Mathis MW, Bethge M. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. Nature neuroscience. 2018;21(9):1281-9. <https://doi.org/10.1038/s41593-018-0209-y>
16. Mathis A, Schneider S, Lauer J, Mathis MW. A primer on motion capture with deep learning: principles, pitfalls, and perspectives. Neuron. 2020;108(1):44-65. <https://doi.org/10.1016/j.neuron.2020.09.017>

17. Bertram J, Krüger T, Röhling HM, Jelusic A, Mansow-Model S, Schniepp R, Wuehr M, Otte K. Accuracy and repeatability of the Microsoft Azure Kinect for clinical measurement of motor function. PLoS One. 2023;18(1):e0279697. <https://doi.org/10.1371/journal.pone.0279697>
18. Otte K, Kayser B, Mansow-Model S, Verrel J, Paul F, Brandt AU, Schmitz-Hübsch T. Accuracy and Reliability of the Kinect Version 2 for Clinical Measurement of Motor Function. PLoS One. 2016;11(11): e0166532. <https://doi.org/10.1371/journal.pone.0166532>
19. Khan A, Galarraga O, Garcia-Salicetti S, Vigneron V. Deep Learning for Quantified Gait Analysis: A Systematic Literature Review. IEEE Access. 2024. <https://doi.org/10.1109/ACCESS.2024.3434513>
20. Hussain S, Spratford W, Goecke R, Kotecha K, Jamwal PK. Deep learning-driven analysis of a six-bar mechanism for personalized gait rehabilitation. Journal of Computing and Information Science in Engineering. 2025; 25:011001-1. <https://doi.org/10.3390/jimaging7070109>
21. Youssfi Alaoui A, Tabii Y, Oulad Haj Thami R, Daoudi M, Berretti S, Pala P. Fall detection of elderly people using the manifold of positive semidefinite matrices. Journal of Imaging. 2021;7(7):109. <https://doi.org/10.3390/jimaging7070109>
22. Sethi D, Prakash C, Bharti S. Estimation of lower extremity parameters for marker-less gait analysis. Multimedia Tools and Applications. 2024;83(13):40125-45. <https://doi.org/10.1007/s11042-023-17195-8>
23. Wang H, Su B, Lu L, Jung S, Qing L, Xie Z, Xu X. Markerless gait analysis through a single camera and computer vision. Journal of Biomechanics. 2024;165:112027. <https://doi.org/10.1016/j.jbiomech.2024.112027>
24. Kanko RM, Laende EK, Strutzenberger G, Brown M, Selbie WS, DePaul V, Scott SH, Deluzio KJ. Assessment of spatiotemporal gait parameters using a deep learning algorithm-based markerless motion capture system. Journal of Biomechanics. 2021;122:110414. <https://doi.org/10.1016/j.jbiomech.2021.110414>
25. Nayak S, Das RK. Application of artificial intelligence (AI) in prosthetic and orthotic rehabilitation. InService Robotics. 2020. IntechOpen. <https://doi.org/10.5772/intechopen.93903>
26. Reddy A, Reddy RP, Roghani AK, Garcia RI, Khemka S, Pattoor V, Jacobs M, Reddy PH, Sehar U. Artificial intelligence in parkinson's disease: early detection and diagnostic advancements. Ageing Research Reviews. 2024:102410. <https://doi.org/10.1016/j.arr.2024.102410>
27. Molavian R, Fatahi A, Abbasi H, Khezri D. Artificial intelligence approach in biomechanics of gait and sport: a systematic literature review. Journal of Biomedical Physics & Engineering. 2023;13(5):383. <https://doi.org/10.31661/jbpe.v0i0.2305-1621>
28. Glüer CC, Blake G, Lu Y, Bluntl BA, Jergasl M, Genantl HK. Accurate assessment of precision errors: how to measure the reproducibility of bone densitometry techniques. Osteoporosis International. 1995;5:262-70. <https://doi.org/10.1007/BF01774016>
29. Fleiss, J. L. Design and analysis of clinical experiments. John Wiley & Sons; 2011.
30. McCabe Megan V. Utilizing neural networks and wearables to quantify hip joint angles and moments during walking and stair ascent. ENGS. 2020, 17.
31. Liang W, Wang F, Fan A, Zhao W, Yao W, Yang P. Deep-learning model for the prediction of lower-limb joint moments using single inertial measurement unit during different locomotive activities. Biomedical Signal Processing and Control. 2023;86:105372. <https://doi.org/10.1016/j.bspc.2023.105372>
32. Chen S, Bangaru SS, Yigit T, Trkov M, Wang C, Yi J. Real-time walking gait estimation for construction workers using a single wearable inertial measurement unit (IMU). In2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM) 2021 (pp. 753-758). IEEE. <https://doi.org/10.1109/AIM46487.2021.9517592>
33. Byun S, Han JW, Kim TH, Kim KW. Test-retest reliability and concurrent validity of a single tri-axial accelerometer-based gait analysis in older adults with normal cognition. PLoS One. 2016;11(7):e0158956. <https://doi.org/10.1371/journal.pone.0158956>
34. Godfrey A, Del Din S, Barry G, Mathers JC, Rochester L. Instrumenting gait with an accelerometer: A system and algorithm examination. Medical engineering & physics. 2015 ;37(4):400-7. <https://doi.org/10.1016/j.medengphy.2015.02.003>

35. Liu D, He M, Hou M, Ma Y. Deep learning-based ground reaction force estimation for stair walking using kinematic data. *Measurement*. 2022; 198:111344. <https://doi.org/10.1016/j.measurement.2022.111344>
36. Boswell MA, Uhlich SD, Thomas K, Kolesar JA, Gold GE, Beaupre GS, Delp SL. A neural network to predict the knee adduction moment in patients with osteoarthritis using anatomical landmarks obtainable from 2D video analysis. *Osteoarthritis and cartilage*. 2021;29(3):346-56. <https://doi.org/10.1016/j.joca.2020.12.018>
37. Kim, Y.K., et al., A deep-learning approach for automatically detecting gait-events based on foot-marker kinematics in children with cerebral palsy—Which markers work best for which gait patterns? *Plos one*. 2022.17(10):e0275878. <https://doi.org/10.1371/journal.pone.0275878>
38. Geerse DJ, Coolen BH, Roerdink M. Kinematic validation of a multi-Kinect v2 instrumented 10-meter walkway for quantitative gait assessments. *PloS one*. 2015;10(10):e0139913. <https://doi.org/10.1371/journal.pone.0139913>
39. Kuo AD, Donelan JM. Dynamic principles of gait and their clinical implications. *Physical Therapy*. 2010;90(2):157-74. <https://doi.org/10.2522/ptj.20090125>