



Fall Prediction in the Elderly Using a Single Inertial Sensor during Walking: a Narrative Review

Yassaman Jafari¹ , Elham Shirzad Araghi² 

1. Biomechanics group, Faculty of Biomedical Engineering, Amir Kabir University of Technology, Tehran, Iran. E-mail: jdjdjafari@aut.ac.ir
2. Corresponding Author, department of sports medicine and novel technologies, Faculty of Sport Sciences and Health, University of Tehran, Tehran, Iran. E-mail: eshirzad@ut.ac.ir

Received: 11 October 2025 ; Received: 8 December 2025 ; Accepted: 17 December 2025

ABSTRACT

Introduction: Falls in the elderly are a major public health challenge that leads to severe injuries and loss of independence. Wearable technologies, especially inertial measurement units (IMUs), provide accurate assessment of fall risk. This narrative review examines the use of inertial sensors in predicting falls in the elderly and analyzes the relevant evidence.

Methods: A narrative review was conducted based on a structured search in Scopus and Web of Science (2015-2025). Inclusion criteria included research studies using IMUs in the elderly (60 years and older). A total of 12 studies were analyzed. Data were extracted using a standard form including study characteristics, demographics, sensor specifications, assessment protocols, and extracted variables.

Results: IMUs placed in the core regions of the body (lower lumbar vertebrae) provided 76 to 89.4% accuracy in distinguishing fallers from non-fallers. The Up-and-Go test and stability limits provided better discrimination when combined with linear and nonlinear indices. Prospective studies (81.6% accuracy) had greater clinical superiority than internal cross-validation (89.4% accuracy). Monitoring in the real-world environment provided greater ecological validity.

Conclusion: IMUs, when properly placed and using composite indices, are effective tools for assessing fall risk. The main limitations include small sample size and lack of standardization. Future solutions include the creation of a public database and the development of better algorithms.

Keywords: *IMU, fall Risk Assessment, Aging, Machine Learning, Gait Analysis.*

Cite this article: Jafari, Y., & Shirzad, A. E., (2025). Fall Prediction in the Elderly using a Single Inertial Sensor during Walking: a Narrative Review. *Journal of Healthy ageing and exercise*, 1 (3), 1-12. DOI: [10.22059/jhae.2025.408090.1023](https://doi.org/10.22059/jhae.2025.408090.1023)

Copyright © 2025: Journal of Healthy Ageing and Exercise. This open-access article is available under the [Creative Commons Attribution-NonCommercial 4.0 \(CC BY-NC 4.0\)](https://creativecommons.org/licenses/by-nc/4.0/) International License, which allows for the copying and redistribution of the material only for noncommercial purposes, provided that the original work is properly cited.

Publisher: University of Tehran Press.

Extended Abstract

Introduction

Falls in the elderly population represent a critical public health challenge with severe consequences including injuries, loss of independence, and increased mortality. Falls are the second leading cause of accidental deaths and affect approximately 40% of elderly individuals in daily activities. In Canada, falls are the primary cause of injury in older adults, with 33% of hospitalized cases transferred to long-term care facilities. Risk factors encompass intrinsic elements (physiological and psychological) and extrinsic factors (environmental). Traditional assessment tools such as the Timed Up and Go (TUG) test and Berg Balance Scale provide qualitative fall risk evaluation, whereas wearable sensors offer quantitative assessment. Inertial measurement units (IMUs) provide precise measurement of movement pattern changes and body posture during walking. Research activity has increased substantially since 2013, with significant advances in machine learning applications. Bibliometric analysis identified 221 studies in this field from 2000–2024, with the Journal of Neurology and IEEE Transactions publishing the most articles.

Methods

This narrative review analyzed evidence regarding inertial sensor applications in elderly fall risk assessment. A narrative approach was selected due to the heterogeneous nature of research in this emerging technology field, enabling deep qualitative analysis of diverse methodologies.

Structured searches were conducted in Web of Science and Scopus using keywords: (wearable sensor OR inertial measurement unit OR IMU OR accelerometer) AND (fall risk OR fall prediction OR fall detection) AND elderly. Time frame: 2015–2025; English language. Inclusion criteria: cross-sectional, case-control, prospective cohort, validation, and algorithm development studies using IMUs in elderly (≥ 60 years) reporting fall-related outcomes. Exclusion criteria: review studies, conference abstracts, non-wearable sensors, populations < 60 years, simulations, and animal studies. Twelve studies met criteria and underwent detailed analysis.

Data extraction included: study characteristics, demographics, sensor specifications (type, placement location, sampling frequency), assessment protocols, extracted variables (stride length, gait speed, Lyapunov exponent, entropy), analytical methods, and outcomes (prediction accuracy, sensitivity/specificity).

Results

Sensor Placement

IMUs positioned in core body regions, particularly lower lumbar vertebrae (3rd–5th), demonstrated optimal effectiveness. Wang et al. (2024) achieved 88% area under receiver operating characteristic curve, the best discrimination between high and low-risk groups. Buisseret et al. (2022) achieved 76% accuracy with 4th lumbar vertebral placement. This location's superiority stems from high sensitivity to trunk changes and body stability during position transitions. Liu (2012) achieved 86.7% sensitivity with sternum placement versus 73% for foot-based sensors (Neira, 2023), due to time-series analysis independent of step detection, eliminating errors in shuffling gait patterns common in elderly. However, Saadeh et al. achieved 98% prediction accuracy with thigh sensors but had limited generalizability due to small sample size (20 subjects) and lack of prospective validation.

Assessment Protocols

The TUG test was used in 7 of 12 studies and revealed specific deficits when instrument-augmented. Qiu et al. integrated three assessment domains (TUG, stability limits test, five-time sit-to-stand) achieving 89.4% accuracy using Support Vector Machine, substantially outperforming simpler approaches using only gait speed analysis (Bautmans: 2011 variance analysis only).

Diverse assessment methods showed significant differences. Lockhart's 10-meter walk test with prospective design (6-month follow-up) achieved 81.6% predictive accuracy with better generalizability than Neira's 15-minute free walking (73% accuracy, case-control). Real-world monitoring provided greater validity: van Schooten et al. (2015) conducted one-week ambulatory monitoring using logistic regression, while Handelzalts et al. (2020) identified 18 of 22 trip events (82%) in daily-life conditions. In contrast, Rivolta et al. (2019) achieved 89% laboratory accuracy with artificial neural networks but lacked real-world applicability.

Gait Parameters and Feature Extraction

Linear spatiotemporal gait parameters consistently discriminated fallers from non-fallers: gait speed in 9 of 12 studies, variability indices in 6 of 12, and step frequency in 7 of 12. Liu's combined approach using linear features (step timing) with nonlinear indices (multiscale entropy and recurrence quantification analysis) achieved 81.6% prospective accuracy, outperforming purely linear approaches (Bautmans, van Schooten). Nonlinear indices demonstrate superior sensitivity to subtle gait deterioration. Howcroft achieved 84% accuracy using maximum Lyapunov exponent in a

neural network. Qiu achieved 89.4% using frequency-domain features in Support Vector Machine frameworks. However, linear variability measures depend on accurate step detection and fail in shuffling gait patterns. Frequency-domain features are environment-sensitive, as Wang demonstrated with superior discrimination in stair descent versus level walking.

Algorithm Comparison

Ensemble tree methods (Random Forest) and margin-based methods (Support Vector Machine) provide optimal balance between accuracy and generalizability. Rivolta's neural network was trained on Tinetti scores, an imperfect criterion not fully reflecting real-world fall occurrence.

Prospective vs. Retrospective Validation

Prospective studies demonstrated superior clinical prediction validity. Liu's Random Forest algorithm with 6-month prospective follow-up achieved 81.6% accuracy and proved more clinically reliable than Qiu's Support Vector Machine (89.4%) based on internal cross-validation without external testing. Neira's Support Vector Machine using foot sensors (73% accuracy) was limited by retrospective case-control design, reducing predictive power for future falls. Real-world monitoring advantages are evident: Handelzalts' ecological validity (82% sensitivity) versus simplified laboratory environments demonstrates superior clinical utility,

though with limitations such as missed events (4 of 22 self-reported trips undetected).

Conclusion

IMUs positioned optimally in core body regions, particularly lower lumbar spine (3rd–5th vertebrae), represent effective fall risk assessment tools achieving 76–89.4% accuracy. Combined TUG and stability limit tests with linear (speed, stride length, variability) and nonlinear indices (multiscale entropy, Lyapunov exponent) provide superior discrimination. Machine learning algorithms including Support Vector Machine and Random Forest demonstrate higher performance than decision trees. Prospective studies (Liu: 81.6% over 6 months) show superior validity compared to internal cross-validation (Qiu: 89.4%), while real-world monitoring provides greater ecological validity.

Primary limitations include small sample sizes causing model overfitting, lack of standardization regarding sensor placement and parameters, and poor data quality (mostly simulated laboratory falls). Future directions include: establishing public databases with standardized protocols, integrating diverse sensors for comprehensive monitoring, utilizing Internet of Things with personalized feedback, and developing advanced analytical methods (deep reinforcement learning, recurrent neural networks) for detecting dynamic fall risk patterns in real-world environments.

Footnotes

Authors' contribution

Study concept and design: E. SH.; Analysis and interpretation of data: Y. D.; Drafting of the manuscript: Y. D.; Critical revision of the manuscript: E. SH.

Funding

Non.

Conflict of interest

According to the authors, this article has no conflict of interest.

پیش بینی سقوط سالمندان با استفاده از تک حسگر اینرسی در حین راه رفتن: یک مرور روایتی

یاسمن جعفری^۱ , الهام شیرزاد عراقی^۲ 

۱. گروه بیومکانیک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران. رایانامه: jdjdjafari@aut.ac.ir

۲. نویسنده مسؤول، گروه طب ورزشی و فناوری های نوین، دانشکده علوم ورزشی و تندرستی، دانشگاه تهران، تهران، ایران. رایانامه: eshirzad@ut.ac.ir

دریافت: ۱۹ مهر ۱۴۰۴؛ بازنگری: ۱۷ آذر ۱۴۰۴؛ پذیرش: ۲۶ آذر ۱۴۰۴

چکیده

مقدمه: سقوط در سالمندان چالش اصلی بهداشت عمومی است که منجر به آسیب های شدید و کاهش استقلال می شود. فناوری های پوشیدنی، به ویژه حسگرهای اینرسی، ارزیابی دقیق خطر سقوط را فراهم می کنند. این مرور روایتی به بررسی کاربرد حسگرهای اینرسی در پیش بینی سقوط سالمندان می پردازد و شواهد مرتبط را تحلیل می کند.

روش پژوهش: یک مرور روایتی بر اساس جستجوی ساختارمند در پایگاه های اسکوپوس و Web of Science (۲۰۱۵-۲۰۲۵) انجام شد. معیارهای ورود شامل مطالعات پژوهشی با استفاده از حسگر اینرسی در سالمندان (۶۰ سال به بالا) بود. تعداد ۱۲ مطالعه نهایی تجزیه و تحلیل شد. داده ها با استفاده از فرم استاندارد شامل ویژگی های مطالعه، جمعیت شناسی، مشخصات حسگر، پروتکل های ارزیابی، و متغیرهای استخراج شده استخراج شد.

یافته ها: حسگرهای اینرسی محل شده در مناطق مرکزی بدن (مهره های پایین کمر) دقت ۷۶ تا ۸۹.۴٪ را در تمایز سقوط کنندگان از غیرسقوط کنندگان ارائه دادند. تست برخاستن و رفتن و محدودیت های پایداری هنگام ترکیب با شاخص های خطی و غیرخطی تمایز بهتری ایجاد کردند. مطالعات آینده نگر (دقت ۸۱/۶ درصد) برتری بالینی بیشتری نسبت به اعتبارسنجی متقابل داخلی (دقت ۸۹/۴٪) داشتند. نظارت در محیط واقعی اعتبار اکولوژیک بیشتری فراهم کرد.

نتیجه گیری: حسگرهای اینرسی با قرارگیری مناسب و استفاده از شاخص های ترکیبی، ابزارهای مؤثری برای ارزیابی خطر سقوط هستند. محدودیت های اصلی شامل حجم نمونه کم و عدم استانداردسازی است. راهکارهای آینده شامل ایجاد پایگاه داده عمومی، ترکیب حسگرهای متنوع، و توسعه الگوریتم های بهتر است.

کلید واژه ها: حسگر اینرسی، ارزیابی ریسک سقوط، سالمندی، یادگیری ماشین، آنالیز راه رفتن

استناد: جعفری، یاسمن و شیرزاد عراقی، الهام (۱۴۰۴). پیش بینی سقوط سالمندان با استفاده از تک حسگر اینرسی در حین راه رفتن: یک مرور روایتی، نشریه سالمندی سالم و ورزش، ۱ (۳)، ۱-۱۲. DOI: 10.22059/jhae.2025.408090.1023

ورزش، ۱ (۳)، ۱-۱۲. DOI: 10.22059/jhae.2025.408090.1023

حق چاپ © ۱۴۰۴، نشریه سالمندی سالم و ورزش. این مقاله با دسترسی آزاد تحت مجوز بین المللی Creative Commons Attribution-Noncommercial 4.0 (CC BY-NC 4.0) منتشر شده

است. این مجوز اجازه کپی و بازتوزیع مطالب را تنها برای مقاصد غیرتجاری می دهد، به شرطی که به اثر اصلی به درستی استناد شود.

ناشر: انتشارات دانشگاه تهران.

مقدمه

سقوط در میان سالمندان به عنوان یکی از چالش‌های اصلی بهداشت عمومی شناخته می‌شود که منجر به آسیب‌های شدید، کاهش استقلال و افزایش مرگ‌ومیر می‌گردد (۱). بر اساس بررسی‌های شیوع شناسی، سقوط دومین علت اصلی مرگ‌های تصادفی هستند و حدود ۴۰ درصد سالمندان را در فعالیتهای روزانه مختل می‌کنند، که این امر با کاهش سلامت جسمی و ذهنی، شکستگی‌ها، افت در توانایی شناختی و مرگ مرتبط است (۲، ۳). فناوری‌های پوشیدنی، به ویژه حسگر اینرسی، ارزیابی دقیق تغییرات ایجاد شده در الگوی حرکتی و وضعیت بدن را در حین راه رفتن فراهم می‌آورند و عوامل مرتبط با خطر سقوط را شناسایی می‌کنند (۱، ۴). این بررسی‌ها نشان می‌دهند که از سال ۲۰۱۳، فعالیت پژوهشی در این حوزه با تمرکز بر تعادل، راه رفتن و خطر سقوط افزایش چشمگیری یافته است و پیشرفت‌های وسیعی در زمینه استفاده از یادگیری ماشین در آنالیز داده‌های حسگرهای اینرسی رخ داده است (۱).

سقوط باعث ایجاد آسیب‌های جسمی مانند ضربه به سر یا تنه می‌شود، ترس از سقوط را القا می‌کند و فعالیتهای بیرون از منزل را محدود می‌سازد، که این عوامل باعث تشدید احتمال سقوط می‌گردد (۱، ۵، ۶). در کانادا، سقوط علت اصلی آسیب در سالمندان است و ۳۳ درصد بستری‌شدگان به مراکز مراقبت بلندمدت منتقل می‌شوند (۷). عوامل خطر شامل عوامل درونی (فیزیولوژیکی و روانشناختی) و عوامل بیرونی (محیطی) هستند که به صورت مشترک عمل می‌کنند (۸). ابزارهای سنتی مانند آزمون برخاستن و رفتن^۱، آزمون تعادل برگ^۲ و چک‌لیست‌های ارزیابی، خطر سقوط را به طور کیفی بررسی می‌کنند، اما حسگرهای پوشیدنی، ارزیابی کمی ارائه می‌دهند (۹-۱۱). نجفی و همکاران (۱۲)، ابزار ژيروسکوپ را برای پایش نوسانات وضعیت بدن معرفی کردند که می‌تواند جایگزینی مناسب برای روش‌های سنتی باشد. همچنین هاوکرفت^۳ و همکاران (۱۳) بررسی بر پایه حسگر اینرسی را ارائه دادند که با استفاده از پارامترهای راه رفتن وجه تمایز افراد در معرض سقوط را تعیین کردند.

حسگرهای اینرسی پرکاربردترین ابزارها برای ارزیابی خطر سقوط هستند، زیرا ابزاری ارزان قیمت با ابعاد کوچک است که می‌تواند شتاب خطی و سرعت زاویه‌ای را به طور دقیق اندازه‌گیری می‌کنند (۱۴، ۱۵). قرارگیری حسگرها به طور معمول در ناحیه تحتانی (بر روی مهره پنجم کمری)، ساکروم، ران، یا استخوان استرنوم است تا راستای قرارگیری بدن، پایداری وضعیت بدن و نوسان آن را ثبت کنند (۱۶، ۱۷). پارامترهای استخراج‌شده از این حسگرها شامل متغیرهای فضایی-زمانی (سرعت راه رفتن، طول گام، نرخ گام‌برداری)، متغیرهای زاویه‌ای (دامنه حرکتی مفاصل) و متغیرهای غیرخطی هستند (۱۸-۲۰).

در تحلیل کتابخانه‌ای پایگاه اسکوپوس در بین سالهای ۲۰۲۴-۲۰۰۰ تعداد ۲۲۱ مطالعه در این زمینه یافت شده است. دو مجله علمی معتبر بین المللی، نشریه عصب شناسی^۴ و نشریه تخصصی انجمن بین المللی مهندسان الکترونیک^۵، بیشترین مقالات را در این حوزه منتشر کرده‌اند. کلمات کلیدی پرکاربرد در این زمینه شامل تعادل / سقوط، راه رفتن و یادگیری ماشین بوده است (۱).

چالش‌های مطرح شده در مطالعات شامل افت مقدار داده‌های خروجی حسگرها، مصرف باتری آن‌ها، نرخ نمونه‌برداری پایین در حسگر (۵۰ هرتز)، طریقه ادغام داده‌ها و کمبود مطالعات آینده‌نگر و واقعی است (۲۱). باتومالای^۶ استانداردسازی استفاده از حسگر اینرسی و دسترسی عادلانه به آن‌ها را ضروری دانست.

روش‌شناسی پژوهش

این مرور روایتی با هدف تلفیق جامع و تحلیلی شواهد موجود در زمینه کاربرد فناوری‌های مبتنی بر حسگر اینرسی در ارزیابی خطر سقوط در سالمندان انجام شد. انتخاب رویکرد روایتی، به‌جای مرور نظام‌مند با معیارهای سخت‌گیرانه، به‌دلیل ماهیت چندوجهی و ناهمگون

1. Time Up and Go
2. Berg Balance Scale
3. Howcroft
4. Journal of Neurology
5. IEEE Transactions
6. Batumalai

پژوهش‌ها در این حوزه صورت گرفت. این نوع مرور امکان تحلیل کیفی عمیق روش‌های متنوع پژوهشی و رویکردهای تحلیلی مرتبط با سقوط را فراهم می‌کند و برای حوزه‌های فناوری نوظهور که انسجام طرح‌های پژوهشی در آن‌ها پایین است، مناسب‌تر است. جستجوی ساختارمند در دو پایگاه داده Web of Science و Scopus در بازه زمانی ۲۰۱۵ تا ۲۰۲۵ و محدودیت زبان انگلیسی اعمال شد. کلمات کلیدی با استفاده از ترکیب واژگان استاندارد حوزه حسگرهای پوشیدنی و سقوط به صورت زیر طراحی شد:

- حسگر پوشیدنی یا واحد اندازه‌گیری اینرسی یا IMU یا شتاب‌سنج
- خطر سقوط یا پیش‌بینی سقوط یا تشخیص سقوط یا ارزیابی خطر سقوط یا ارزیابی ریسک سقوط
- سالمند

معیارهای ورود

مطالعات پژوهشی شامل طرح‌های مقطعی، مورد-شاهدی، کوهورت آینده‌نگر، مطالعات اعتبارسنجی و پژوهش‌های توسعه الگوریتم با موضوعات: استفاده از حسگر اینرسی در جمعیت سالمندان (۶۰ سال به بالا)؛ و گزارش موارد مرتبط با سقوط مانند ارزیابی، پیش‌بینی یا تحلیل پارامترهای راه رفتن و تعادل.

معیارهای خروج

انواع مطالعات مروری، چکیده‌های کنفرانس، مطالعات مبتنی بر حسگرهای غیرپوشیدنی، جمعیت‌های زیر ۶۰ سال، شبیه‌سازی‌های رایانه‌ای و مطالعات حیوانی.

بر اساس معیارهای ورود و خروج تعداد ۱۲ مطالعه مورد بررسی قرار گرفت.

استخراج داده‌ها

داده‌ها با استفاده از فرم استاندارد شامل حوزه‌های زیر استخراج شد:

- ویژگی‌های مطالعه: نوع طرح، محل انجام، منابع مالی
- جمعیت‌شناسی: سن، جنس، سابقه سقوط
- مشخصات حسگر: نوع حسگر، محل نصب (کمر، مچ پا، مهره‌های ۳-۵ کمری)، فرکانس نمونه‌برداری
- پروتکل ارزیابی: آزمون‌هایی مانند برخاستن و رفتن، آزمون تعادلی برگ، راه رفتن روی تردمیل یا زمین
- متغیرهای استخراج‌شده: طول گام، سرعت راه رفتن، نمای لیاپانوف، آنتروپی نمونه
- روش تحلیل: هموار سازی سیگنال، روش‌های یادگیری ماشین، اعتبارسنجی
- پیامدها: دقت پیش‌بینی سقوط، حساسیت و ویژگی روش، پارامترهای تمایزدهنده بین سالمندان با خطر سقوط بالا و پایین

یافته‌های پژوهش

محل قرارگیری حسگر

در مطالعاتی که از تک حسگر اینرسی استفاده کرده‌اند، مهره‌های سوم، چهارم یا پنجم پایین کمر شایع‌ترین و مؤثرترین مکان گزارش شده است. وانگ و همکاران (۲۲) سنسور را دقیقاً بین مهره‌های سوم تا پنجم کمر قرار دادند تا شتاب سه‌محوره و سرعت زاویه‌ای (به‌ویژه بیشینه سرعت زاویه‌ای حول محور عمودی در فاز چرخش به منظور نشستن^۱) را در آزمون برخاستن و رفتن ثبت کنند، که با سطح زیر

1. Turn to sit

نمودار منحنی ویژگی عملیاتی گیرنده^۱ برابر با ۰/۸۸، بهترین تمایز بین گروه‌های پرخطر و کم‌خطر را نشان داد. بویسره^۲ و همکاران (۲۳) نیز با قرار دادن حسگر بر روی مهره چهارم کمری با دقت ۷۶ درصد متغیرهای راه رفتن و زمان برخاستن و رفتن را اندازه‌گیری کردند. این مکان مرکزی به دلیل حساسیت بالا به تغییرات حول محور میانی-جانبی تنه و پایداری وضعیت بدن، انتخاب اول برای نظارت بر تعادل در حین انتقال از یک وضعیت به وضعیت دیگر محسوب می‌شود (۱۶).

مقایسه دقیق‌تر نشان می‌دهد که قرارگیری حسگر در محل استرنوم در مطالعه لیو^۳، با تمرکز بر دینامیک تنه، حساسیت بالاتری (۸۶/۷ درصد) نسبت به قرارگیری حسگر بر روی پا در مطالعه نیرا^۴ با دقت ۷۳ درصد ارائه داد؛ این تفاوت به دلیل تمرکز لیو بر تحلیل سری زمانی غیروابسته به تشخیص گام بود که در سالمندان با راه رفتن شافلینگ (الگوی راه رفتن کوتاه، کند و کشیدن پا روی زمین است که در سالمندان بسیار رایج است)، خطای تشخیص گام را حذف می‌کند (۲۴-۲۶). در مقابل در مطالعه ساده^۵ و همکاران با نصب حسگر MPU6050 بر روی ران، دقت پیش‌بینی ۹۸ درصد کسب کرد اما حجم کوچک نمونه (۲۰ نفر) و فقدان اعتبارسنجی آینده‌نگر، قابلیت تعمیم آن را محدود ساخت (۲۷).

پروتکل‌های ارزیابی و محیط‌ها

تست برخاستن و رفتن در ۷ از ۱۲ مطالعه به عنوان پروتکل غالب استفاده شد، و نسخه‌های مجهز شده به ابزار آن (که حسگر در حین آزمون بر روی بدن آزمودنی قرار گرفته است) نقص‌های خاص سقوط‌کنندگان را آشکار ساخت. بویسره^۶ و همکاران تست برخاستن و رفتن را با تحلیل تغییرپذیری راه رفتن (در حالیکه حسگر بر روی مهره چهارم کمری مستقر شده بود) ترکیب کرد و دقت ۷۶ درصد را کسب کرد، نتایج این مطالعه از بوتمن و همکاران پیشی گرفت. آنها تنها از تحلیل ساده سرعت راه رفتن (تحلیل واریانس) استفاده کرده بود (۲۳، ۲۸).

کیو^۷ و همکاران سه حوزه ارزیابی را با هم ادغام کردند: آزمون برخاستن و رفتن، آزمون محدوده پایداری، و آزمون پنج بار نشستن و بلند شدن و با استفاده از الگوریتم ماشین بردار پشتیبان^۸، دقت ۸۹/۴٪ را به دست آوردند؛ این عملکرد از داده‌های ساده‌تر جوترایی^۹ و همکاران (۲۰۲۳) که فقط آزمون ۳ متری برخاستن و رفتن با ۳ تکرار را داشت، بسیار بهتر بود (۲۹، ۳۰).

تنوع روش‌های ارزیابی راه رفتن تفاوت‌های معناداری را نشان داد: لاکهارت^{۱۰} آزمون راه رفتن ۱۰ متری را با طرح‌ریزی آینده‌نگر (بررسی ۶ ماهه در حالیکه مشاهده گر تنها به گزارشات آزمودنی گوش فرا می‌دهد) انجام داد و دقت پیش‌بینی‌کننده ۸۱/۶٪ را کسب کرد، که نسبت به نیرا (تست ۱۵ دقیقه‌ای راه رفتن آزاد با طرح مورد-شاهد، ۷۳٪ دقت) قابلیت تعمیم بهتری داشت. داده‌های هر دو از وانگ^{۱۱} و همکاران (تست پله‌های پایین) بهتر بودند، زیرا آنها فقط همبستگی را نشان دادند بدون اعتبارسنجی الگوریتم یادگیری ماشینی (۲۲، ۲۴، ۲۶). نظارت در محیط واقعی اعتبار بیشتری فراهم کرد: ون شوتن^{۱۲} و همکاران یک هفته پایش در محیط زندگی آزاد انجام دادند و از رگرسیون لجستیک استفاده کردند، در حالیکه هندلزالت^{۱۳} و همکاران ۱۸ مورد لغزش ناشی از گیر کردن پا را در مدت دو هفته با حسگر اینرسی و ضبط صوت همزمان شده تشخیص داد (۱۸، ۳۱). این نتایج در تقابل شدید با مطالعه ریولتا^{۱۴} و همکاران (۳۲) بودند که آزمون خود را

1. Receiver operating characteristic curve (ROC curve)
2. Buisseret
3. Liu
4. Neira
5. Saadeh
6. Buisseret
7. Qiu
8. Support Vector Machine (SVM)
9. Juthraee
10. Lockhart
11. Wang
12. Van Schooten
13. Handelzalts
14. Rivolta

محدود به آزمایشگاه کردند؛ آن‌ها با نصب شتاب‌سنج روی سینه و شبکه عصبی مصنوعی دقت ۸۹٪ کسب کردند اما چون تنها بر معیار طلایی تینتی^۱ متکی بودند، کاربردی برای محیط واقعی نداشتند.

پروتکل‌های آینده‌نگر و محیط‌واقعی (مطالعات لیو، هندلزالت و ون شوتن) توانستند سقوط‌های آینده را در شش ماه پیش‌بینی کنند. آزمون برخاستن و رفتن در محیط آزمایشگاهی پیچیدگی‌های محیط واقعی را ساده‌سازی می‌کند در نتیجه دقت بویسره از بوتمن بیشتر است، و فاصله‌های کوتاه راه‌رفتن تشخیص الگوهای ناپایداری غیرخطی راه‌رفتن را محدود می‌کند (۲۴).

پارامترهای راه‌رفتن و استخراج ویژگی

پارامترهای خطی فضایی-زمانی راه‌رفتن، تقریباً در همه مطالعات بین سقوط‌کنندگان و غیرسقوط‌کنندگان تمایز ایجاد کردند؛ سرعت راه‌رفتن در ۹ از ۱۲ مطالعه، شاخص‌های نوسان‌پذیری یا ضریب تغییرات در ۶ از ۱۲ مطالعه، و فرکانس گام برداری در ۷ از ۱۲ مطالعه به عنوان شاخص‌های کلیدی گزارش شده‌اند. در کار لیو، ترکیب ویژگی‌های خطی مانند زمان گام با شاخص‌های غیرخطی مانند آنترپوی چندمقیاسی و تحلیل کمی بازگشت دقت آینده‌نگر ۸۱٫۶٪ را به دست داد و عملکرد بهتری نسبت به رویکردهای صرفاً خطی مانند مطالعه بوتمن (فقط سرعت راه رفتن با تحلیل واریانس) و ون شوتن (نسبت هارمونیک + نوسان‌پذیری) نشان داد؛ این موضوع حساسیت بالاتر شاخص‌های غیرخطی به تغییرات کوچک راه‌رفتن را تأیید می‌کند (۲۸، ۲۴، ۱۸). هاوکرافت با استفاده از نمای لیاپانوف بیشینه و نسبت هارمونیک‌های زوج به فرد در یک شبکه عصبی به دقت ۸۴ درصد رسید، و کیو نیز با به‌کارگیری ویژگی‌های حوزه فرکانس در چارچوب ماشین بردار پشتیبان به دقت ۸۹٫۴ درصد دست یافت؛ هر دو نسبت به مطالعه ریولتا که با ۲۱ ویژگی عمدتاً خطی و شبکه عصبی مصنوعی ۸۹٪ دقت گزارش کرده بود، یک گام تحلیلی جلوتر بودند (۳۲، ۲۹، ۱۹). در مطالعه ساده و همکاران، ویژگی‌های استخراج‌شده از حسگر اینرسی مستقر بر روی ران، شامل ضریب تغییرات و میانگین انحراف دامنه، دقت ۹۸ درصد برای پیش‌بینی سقوط به دست دادند، هرچند این نتایج در یک طرح آینده‌نگر بلندمدت اعتبارسنجی نشدند (۲۷).

مزیت اصلی این رویکردها آن است که شاخص‌های غیرخطی (مانند آنچه در مطالعات لیو و هاوکرافت استفاده شد) می‌توانند بی‌ثباتی اولیه و پیش‌علامتی راه‌رفتن را قبل از بروز سقوط بالینی آشکار کنند (۲۴، ۱۹). با این حال، محدودیت‌های مهمی نیز وجود دارد؛ سنج‌های خطی نوسان‌پذیری به تشخیص دقیق گام وابسته‌اند و در الگوهای راه‌رفتن شافلینگ (کشیدن پا روی زمین) عملکرد مطمئنی ندارند، نکته‌ای که خود لیو نیز به آن اشاره کرده است (۲۴). همچنین ویژگی‌های حوزه فرکانس به محیط اجرای آزمون حساس هستند؛ به‌طور مثال وانگ^۲ نشان داد پارامترهای به‌دست‌آمده از پایین آمدن از پله‌ها همبستگی قوی‌تری با پروفایل فیزیولوژیک ریسک سقوط نسبت به راه‌رفتن روی سطح صاف دارند، که نشان می‌دهد انتخاب شرایط حرکتی بر پایداری این شاخص‌ها تأثیر مستقیم دارد (۲۲).

جدول ۱ دقت و حساسیت الگوریتم‌های یادگیری ماشین در مطالعات مختلف را بررسی کرده است. در مطالعه لیو، الگوریتم جنگل تصادفی در چارچوب یک طرح آینده‌نگر خود اظهاری با پیگیری ۶ ماهه، دقت ۸۱/۶ درصد را به دست آورد و از مدل ماشین بردار پشتیبان استفاده شده در مطالعه کیو که دقت ۸۹/۴ درصد آن فقط بر اساس اعتبارسنجی متقابل داخلی و بدون آزمون آینده‌نگر گزارش شده بود، از نظر شواهد تعمیر و کارایی بالینی قابل اعتمادتر ارزیابی شد (۲۹، ۲۴). مدل ماشین بردار پشتیبان مبتنی بر سنسورهای کف پا در مطالعه نیرا با دقت ۷۳ درصد عقب‌تر ماند، زیرا بر اساس طراحی مورد-شاهد توسعه یافته بود و نه یک کوهورت آینده‌نگر؛ در نتیجه توان کمتری برای پیش‌بینی سقوط‌های آینده و داده‌های واقعاً نادیده گرفته‌شده داشت (۲۶). شبکه‌های عصبی نیز مانند پرسپترون^۳ چندلایه هاوکرافت با دقت ۸۴ درصد و شبکه عصبی مصنوعی ریولتا با دقت ۸۹ درصد توانستند با ویژگی‌های فضایی-زمانی پیچیده به‌خوبی کنار بیایند، اما هیچ‌یک اعتبارسنجی بیرونی یا پیگیری طولانی‌مدت قابل مقایسه با پیگیری ۶ ماهه لیو ارائه نکردند (۳۲).

1. Tinetti
2. Wang
3. Perceptron

جدول ۱. مقایسه عملکرد یادگیری ماشین

مدل	مطالعات برتر	دقت	حساسیت/ویژگی	اعتبارسنجی	مزایا	معایب
جنگل تصادفی	لیو	۸۱/۶٪	۸۰/۳٪ / ۸۶/۷٪	آینده نگر (خوداظهاری)	خطی+غیرخطی، مقاوم	حسگر تکی
ماشین بردار پشتیبان	کیو و نیرا	۷۳-۸۹/۴٪	۷۳-۸۵٪ / ۹۲٪	متقابل	چندحسگری	گذشته نگر
شبکه عصبی	هاوکرافت و ریولتا	۸۴-۸۹٪	بالا	متقابل	الگوهای پیچیده	بیش برآزش
درخت تصمیم	بویسره	۷۶٪	-	متقابل	تفسیرپذیر	دقت پایین

به طور کلی، روش های گروهی مبتنی بر درخت مانند جنگل تصادفی و روش های حاشیه محور مانند ماشین بردار پشتیبان، در صورت طراحی و اعتبارسنجی صحیح، تعادلی مناسب بین دقت و قابلیت تعمیم فراهم می کنند. در مقابل، درخت تصمیم ساده که در مطالعه بویسره برای طبقه بندی ریسک سقوط بر اساس پارامترهای تست برخاستن و رفتن استفاده شد، اگرچه بسیار قابل تفسیر است، ضعیف ترین عملکرد را در میان مدل های مقایسه شده نشان داد. شبکه های عصبی، با وجود توان بالا، دچار محدودیت های قابل توجهی در اعتبارسنجی و تکیه بر معیارهای بالینی نه چندان ایده آل هستند؛ برای مثال، مدل ریولتا بر اساس نمره آزمون تینتی آموزش داده شد، معیاری که وقوع واقعی سقوط در محیط زندگی را به طور کامل بازتاب نمی دهد.

اعتبارسنجی آینده نگر در برابر گذشته نگر

طرح های آینده نگر، از نظر پیش بینی بالینی معنادار، بهترین عملکرد را داشتند. در مطالعه لیو، یک کوهورت با پیگیری آینده نگر ۶ ماهه به دقت ۸۱/۶ درصد برای پیش بینی سقوط های آینده رسید و در مطالعه ون شوتن^۱، مانیتورینگ یک هفته ای در محیط زندگی واقعی با استفاده از رگرسیون لجستیک توانست سقوط های بعدی را پیش بینی کند (۲۴، ۱۸). در مقابل، مطالعات هاوکرافت، ریولتا و کیو اگرچه دقت های بالاتری در بازه ۸۴ تا ۸۹ درصد گزارش کردند، اما همگی بر داده های گذشته نگر و صرفاً بر پایه اعتبارسنجی متقابل داخلی تکیه داشتند و هیچ آزمون آینده نگر کور و زمان جدا شده ای ارائه نکردند (۳۲، ۲۹، ۱۹).

در حوزه نظارت واقعی، مطالعه هندلزالت با استفاده از حسگر اینرسی همگام با ضبط صوت توانست ۱۸ مورد از ۲۲ رویداد «گیر کردن پا» را در شرایط زندگی روزمره شناسایی کند (۸۲ درصد)، و به این ترتیب پلی میان پروتکل های کاملاً آزمایشگاهی و واقعیت روزمره ایجاد کرد؛ پلی که در کار کاملاً آزمایشگاهی ساده با دقت ۹۸ درصد پیش بینی در محیط آزمایشگاه وجود نداشت (۲۷، ۳۱). مزیت اصلی طرح های آینده نگر و محیط واقعی مانند لیو و ون شوتن، اعتبار اکولوژیک و توانایی آن ها در پیش بینی سقوط های آینده فراتر از داده های آموزش و اعتبارسنجی متقابل است؛ در حالی که مدل های گذشته نگر در معرض خطر بیش برآزش قرار دارند (مانند ماشین بردار پشتیبان با دقت ۸۹/۴ درصد در مطالعه کیو که فقط به صورت داخلی اعتبارسنجی شده است)، و حتی در مطالعات محیط واقعی نیز محدودیت هایی مانند از دست رفتن برخی رویدادها دیده می شود؛ همان طور که در کار هندلزالت، ۴ مورد از ۲۲ لغزش و گیر کردن پا خود گزارش شده در داده های حسگر اینرسی شناسایی نشد (۳۱، ۲۹، ۲۴، ۱۸).

نتیجه گیری

حسگرهای اینرسی قرارداده شده در مناطق مرکزی بدن، به ویژه ناحیه پایین تنه (مهره های سوم تا پنجم کمری)، مؤثرترین ابزارهای ارزیابی ریسک سقوط هستند و دقت ۷۶ تا ۸۹/۴ درصد را در تمایز سقوط کنندگان از غیرسقوط کنندگان ارائه می دهند. تست برخاستن و رفتن و حدود ثبات و پنج بار نشستن و بلند شدن هنگام ترکیب با شاخص های خطی (سرعت، طول گام، تغییرپذیری گام) و غیرخطی (آنترپی چندمقیاسی، نمای لیاپانوف) تمایز بهتری ایجاد می کند. الگوریتم های یادگیری ماشینی مانند ماشین بردار پشتیبان و جنگل تصادفی نسبت به درخت تصمیم عملکرد بالاتری داشته اند، اما مطالعات آینده نگر (مانند لیو با ۸۱/۶ درصد دقت در پیگیری شش ماهه) برتری واقعی نسبت

به نتایج اعتبار سنجی متقابل^۱ (کیو: ۸۹/۴ درصد) دارند. نظارت در محیط واقعی (هندلزال: ۸۲٪ در تشخیص ۱۸ مورد لغزش، ون شوتن: ۱ هفته نظارت آزاد) اعتبار اکولوژیک بیشتری فراهم می‌کند و مؤثرتر از محیط‌های آزمایشگاهی ساده‌شده (ریولتا: ۸۹ درصد اما بر اساس معیار تینتی ضعیف) است.

محدودیت‌های اصلی شامل حجم نمونه کم (اکثر مطالعات کمتر از ۱۰۰ نفر آزمودنی داشتند که منجر به بیش‌برازش مدل می‌شود)، عدم استانداردسازی محل حسگر و پارامترهای استخراج‌شده (تغییرات در دستگاه‌ها منجر به نتایج ناسازگار می‌شود)، و کیفیت داده پایین (بیشتر سقوط‌ها شبیه‌سازی‌شده در آزمایشگاه و بدون انعکاس شرایط زندگی واقعی می‌باشد) است. چالش‌های فناورانه شامل تعادل میان مصرف انرژی و دقت، محدودیت برد انتقال داده (بیشتر بر بلوتوث متکی است)، و سفارش‌سازی دستگاه برای اندازه‌های مختلف کفش و تناسب بدن‌های متفاوت می‌باشد. راهکارهای آینده عبارتند از: (الف) ایجاد پایگاه داده عمومی با پروتکل استاندارد برای مقایسه سیستم‌های جدید، (ب) ترکیب حسگرهای متنوع (فشار، الکترومیوگرافی، الکتروکاردیوگرافی، دما) در یک دستگاه برای نظارت جامع، (ج) استفاده از اینترنت اشیاء با بازخورد شخصی‌سازی شده برای کمک کردن به سالمندان برای تغییر رفتار و کاهش ریسک سقوط، و (د) توسعه روش‌های تحلیل بهتر (یادگیری تقویتی عمیق، شبکه‌های عصبی تکراری) برای تشخیص الگوهای پویای ریسک سقوط در محیط واقعی.

پی‌نوشت

مشارکت نویسندگان

مفهوم و طراحی مطالعه: الهام شیرزاد عراقی؛ تحلیل و تفسیر داده‌ها: یاسمن جعفری؛ نگارش پیش‌نویس مقاله: یاسمن جعفری؛ بازنگری مقاله: الهام شیرزاد عراقی.

حمایت مالی

این پژوهش توسط هیچ سازمانی حمایت مالی نشده است.

تعارض منافع

طبق اظهار نویسندگان، این مقاله هیچ گونه تضاد منافی ندارد.

منابع

1. Batumalai P, Thazhakkattu Vasu D, Selvakumar K, Choon Hian G. A bibliometric analysis of wearable sensors for fall-risk assessment in the elderly population. *Medicine (Baltimore)*. 2025;104(35):e44118.10.1097/MD.00000000000044118
2. Cui Y, Choi M, editors. Assessment of the daily living activities of older people (2004–2023): A bibliometric and visual analysis. *Healthcare*; 2024: MDPI ;
3. Shishov N, Komisar V, Marigold DS, Blouin JS, Robinovitch SN. Interactions during falls with environmental objects: evidence from real-life falls in long-term care captured on video. *BMC Geriatr*. 2024;24(1):726.10.1186/s12877-024-05306-5
4. Majumder S, Mondal T, Deen MJ. Wearable Sensors for Remote Health Monitoring. *Sensors (Basel)*. 2017;17(1):130.10.3390/s17010130
5. Subramaniam S, Faisal AI, Deen MJ. Wearable Sensor Systems for Fall Risk Assessment: A Review. *Front Digit Health*. 2022;4:921506.10.3389/fdgh.2022.921506
6. Marquez G, Veloz A, Minonzio JG, Reyes C, Calvo E, Taramasco C. Using Low-Resolution Non-Invasive Infrared Sensors to Classify Activities and Falls in Older Adults. *Sensors (Basel)*. 2022;22(6):2321.10.3390/s22062321

7. McCarthy M. Falls are leading cause of injury deaths among older people, US study finds. British Medical Journal Publishing Group; 20.^{۱۶}
8. Perell KL, Nelson A, Goldman RL, Luther SL, Prieto-Lewis N, Rubenstein LZ. Fall risk assessment measures: an analytic review. J Gerontol A Biol Sci Med Sci. 2001;56(12):M761-6.10.1093/gerona/56.12.m761
9. Shumway-Cook A, Baldwin M, Polissar NL, Gruber W. Predicting the probability for falls in community-dwelling older adults. Phys Ther. 1997;77(8):812-9.10.1093/ptj/77.8.812
10. Muir SW, Berg K, Chesworth B, Speechley M. Use of the Berg Balance Scale for predicting multiple falls in community-dwelling elderly people: a prospective study. Phys Ther. 2008;88(4):449-59.10.2522/ptj.20070251
11. Bohlke K, Redfern MS, Rosso AL, Sejdic E. Accelerometry applications and methods to assess standing balance in older adults and mobility-limited patient populations: a narrative review. Aging Clin Exp Res. 2023;35(10):1991-2007.10.1007/s40520-023-02503-x
12. Najafi B, Aminian K, Loew F, Blanc Y, Robert PA. Measurement of stand-sit and sit-stand transitions using a miniature gyroscope and its application in fall risk evaluation in the elderly. IEEE Trans Biomed Eng. 2002;49(8):843-51.10.1109/TBME.2002.800763
13. Howcroft J, Kofman J, Lemaire ED. Review of fall risk assessment in geriatric populations using inertial sensors. J Neuroeng Rehabil. 2013;10(1):91.10.1186/۱۰۰۰۰۳-۱۷۴۳/۶
14. Hsu Y-C, Zhao Y, Huang K-H, Wu Y-T, Cabrera J, Sun T-L, et al. A novel approach for fall risk prediction using the inertial sensor data from the timed-up-and-go test in a community setting. IEEE sensors journal. 2020;20(16):9339-50
15. Seel T, Raisch J, Schauer T. IMU-based joint angle measurement for gait analysis. Sensors (Basel). 2014;14(4):6891-909.10.3390/s140406891
16. Guimarães V, Ribeiro D, Rosado L, editors. A smartphone-based fall risk assessment tool: measuring one leg standing, sit to stand and falls efficacy scale. 2013 IEEE 15th International Conference on e-Health Networking, Applications and Services (Healthcom 2013); 2013: IEEE ;
17. Yu L, Zhao Y, Wang H, Sun TL, Murphy TE, Tsui KL. Assessing elderly's functional balance and mobility via analyzing data from waist-mounted tri-axial wearable accelerometers in timed up and go tests. BMC Med Inform Decis Mak. 2021;21(1):108.10.1186/s12911-021-01463-4
18. van Schooten KS, Pijnappels M, Rispens SM, Elders PJ, Lips P, van Dieën JH. Ambulatory fall-risk assessment: amount and quality of daily-life gait predict falls in older adults. J Gerontol A Biol Sci Med Sci. 2015;70(5):608-15.10.1093/gerona/glu225
19. Howcroft J, Lemaire ED, Kofman J. Wearable-Sensor-Based Classification Models of Faller Status in Older Adults. PLoS One. 2016;11(4):e0153240.10.1371/journal.pone.0153240
20. Riva F, Toebe M, Pijnappels M, Stagni R, Van Dieën J. Estimating fall risk with inertial sensors using gait stability measures that do not require step detection. Gait & posture. 2013;38(2):170-4
21. Iijima H, Takahashi M. State of the Field of waist-mounted sensor algorithm for gait events detection: A scoping review. Gait Posture. 2020;79:152-61.10.1016/j.gaitpost.2020.03.021
22. Wang X, Cao J, Zhao Q, Chen M, Luo J, Wang H, et al. Identifying sensors-based parameters associated with fall risk in community-dwelling older adults: an investigation and interpretation of discriminatory parameters. BMC Geriatr. 2024;24(1):125.10.1186/s12877-024-04723-w
23. Buisseret F, Catinus L, Grenard R, Joczzyk L, Fievez D, Barvaux V, et al. Timed up and go and six-minute walking tests with wearable inertial sensor: one step further for the prediction of the risk of fall in elderly nursing home people. Sensors. 2020^{۳۲}:۷:(۱۱)^{۲۰};
24. Liu J, Zhang X, Lockhart TE. Fall risk assessments based on postural and dynamic stability using inertial measurement unit. Saf Health Work. 2012;3(3):192-8.10.5491/SHAW.2012.3.3.192
25. Rafanelli M, Walsh K, Hamdan MH, Buyan-Dent L. Autonomic dysfunction: Diagnosis and management. Handb Clin Neurol. 2019;167:123-37.10.1016/B978-0-12-804766-8.00008-X
26. Neira-Álvarez M, Jimenez-Ruiz AR, Neira-García G, Huertas-Hoyas E, Espinoza-Cerda MT, Pérez-Delgado L, et al. Assessing falls in the elderly population using G-STRIDE foot-mounted inertial sensor. 2023

27. Saadeh W, Butt SA, Altaf MAB. A Patient-Specific Single Sensor IoT-Based Wearable Fall Prediction and Detection System. IEEE Trans Neural Syst Rehabil Eng. 2019;27(5):995-1003.10.1109/TNSRE.2019.2911602
28. Bautmans I, Jansen B, Van Keymolen B, Mets T. Reliability and clinical correlates of 3D-accelerometry based gait analysis outcomes according to age and fall-risk. Gait Posture. 2011;33(3):366-72.10.1016/j.gaitpost.2010.12.003
29. Qiu H, Rehman RZU, Yu X, Xiong S. Application of wearable inertial sensors and a new test battery for distinguishing retrospective fallers from non-fallers among community-dwelling older people. Scientific reports. 2018;8(1):16349
30. Jutharee W, Paengkumhag C, Limpornchitwilai W, Mo WT, Chan JH, Jennawasin T, et al. Fall risk assessment dataset: older-adult participants undergoing the time up and go test. Data Brief. 2023;51:109653.10.1016/j.dib.2023.109653
31. Handelzalts S, Alexander NB, Mastruserio N, Nyquist LV, Strasburg DM, Ojeda LV. Detection of Real-World Trips in At-Fall Risk Community Dwelling Older Adults Using Wearable Sensors. Front Med (Lausanne). 2020;7:514.10.3389/fmed.2020.00514
32. Rivolta MW, Aktaruzzaman M, Rizzo G, Lafortuna CL, Ferrarin M, Bovi G, et al. Evaluation of the Tinetti score and fall risk assessment via accelerometry-based movement analysis. Artif Intell Med. 2019;95:38-47.10.1016/j.artmed.2018.08.005