

Research Paper

Clustering Kinematic Patterns of Runners: A Comparative Study of Hierarchical, K-Means, and Deep Temporal Clustering Algorithms



Zanir Mohamadi¹ , *Mansour Eslami¹ , Rohollah Yousefpour²

1. Department of Sports Biomechanics, Faculty of Sports Sciences, University of Mazandaran, Babolsar, Iran.

2. Department of Computer Sciences, Faculty of Mathematical Sciences, University of Mazandaran, Babolsar, Iran.



Citation Zanir Z, Eslami M, Yousefpour R. [Clustering Kinematic Patterns of Runners: A Comparative Study of Hierarchical, K-Means, and Deep Temporal Clustering Algorithms (Persian)]. *Scientific Journal of Rehabilitation Medicine*. 2025; 14(5):698-709. <https://dx.doi.org/10.32598/SJRM.14.5.3363>

<https://dx.doi.org/10.32598/SJRM.14.5.3363>

ABSTRACT

Background and Aims Current biomechanical studies lack a comprehensive investigation of deep learning clustering algorithms for identifying homogeneous movement patterns in runners. This study aims to compare the performance of principal component analysis (PCA)-based hierarchical clustering and K-means algorithms with an end-to-end deep temporal clustering (DTC) approach in analyzing ankle joint kinematics of runners with homogeneous movement patterns.

Methods Three-dimensional ankle joint angles were obtained from 108 recreational runners (55 males and 53 females; age: 22.45 ± 2.42 years, height: 1.69 ± 0.11 m, body mass: 64.64 ± 9.54 kg) during barefoot running at a speed of 3.0 ± 3 meters per second. DTC, hierarchical, and K-means algorithms were trained using ankle joint angles during running. After clustering, the performance and accuracy of each algorithm in identifying clusters with homogeneous movement patterns were evaluated by calculating the Silhouette score, the Calinski-Harabasz index (CHI), and the Davies-Bouldin index (DBI).

Results In cluster separation, the DTC algorithm demonstrated superior performance and accuracy compared to the other two algorithms (silhouette score=0.74, DBI=0.35). This algorithm identified three distinct clusters with a clustering inconsistency rate of 6%. The hierarchical clustering method achieved a silhouette score of 0.68 and a DBI value of 0.52 in 10 seconds with a 15% inconsistency rate. The K-means method showed a silhouette score of 0.63 and a DBI of 0.78 in 3 seconds with an 18% inconsistency rate.

Conclusion The DTC algorithm outperforms hierarchical clustering and K-means clustering in identifying homogeneous movement patterns among runners. Its higher accuracy and lower learning error make it a suitable choice for analyzing kinematic data in biomechanical research. The findings can enhance the understanding and analysis of movement patterns and contribute to the development of effective strategies for prescribing targeted interventions.

Keywords Running, Ankle joint, Deep temporal clustering (DTC), Hierarchical clustering, K-means clustering

Received: 04 May 2025

Accepted: 21 May 2025

Available Online: 22 Nov 2025

* Corresponding Author:

Mansour Eslami, Associate Professor.

Address: Department of Sports Biomechanics, Faculty of Sports Sciences, University of Mazandaran, Babolsar, Iran.

Tel: +98 (911) 1124005

E-Mail: msehlami@gmail.com



Copyright © 2025 The Author(s);
This is an open access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC; <https://creativecommons.org/licenses/by-nc/4.0/legalcode.en>), which permits use, distribution, and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

Extended Abstract

Introduction

Running has become one of the most popular exercises due to its accessibility and low cost. However, the repetitive nature of running leads to a high incidence of over-use injuries. Epidemiological studies have reported an annual running-related injury rate of 19-79%, with 70% of cases involving the knee and lower limbs. Despite widespread preventive interventions, injury prevalence has not significantly decreased in recent decades, probably due to individual variability in response to treatments. This suggests that identifying homogeneous movement patterns and developing personalized interventions can be an effective strategy for injury prevention. While traditional clustering algorithms have been used to cluster runners with homogeneous movement patterns, their effectiveness is limited by challenges in processing biomechanical time-series data and capturing nonlinear movement features. Recent advances in deep temporal clustering (DTC) algorithms, utilizing deep autoencoders, have demonstrated superior capability in extracting complex temporal patterns and identifying homogeneous movement groups [7] also known as temporal clustering, is a challenging problem in machine learning. Here we propose a novel algorithm, DTC. This study aims to compare the performance of the DTC algorithm and conventional methods, including principal component analysis (PCA)-based K-means clustering and hierarchical clustering, for analyzing runners' ankle kinematic data. We hypothesize that the DTC algorithm has greater accuracy due to its ability to model nonlinear relationships and preserve temporal dependencies in movement data.

Methods

The study examined 108 recreational runners (Mean age: 22.45 ± 2.42 years) using motion capture systems to analyze their ankle kinematics during running at a speed of 3.0 ± 3 meters per second. Ankle kinematics were transformed into 101-point stance phase matrices for DTC and were reduced to 12 principal components for traditional clustering

methods. Three clustering methods were utilized: 1) DTC algorithm employing a one-dimensional-convolutional neural network (1D-CNN) and a bidirectional long short-term memory (Bi-LSTM) model to extract temporal features and cluster data in latent space; 2) Hierarchical clustering with Ward's linkage on PCA-reduced data; and 3) K-means clustering ($k=2-8$), optimized using the Calinski-Harabasz index (CHI). The cluster validity metrics included Silhouette score for cluster cohesion and Davies-Bouldin index (DBI) for inter-cluster separation; higher Silhouette scores (up to 1) and lower Davies-Bouldin values indicate better clustering performance. The DTC architecture was specifically designed to address limitations of convolutional methods in processing biomechanical time-series data through its temporal autoencoder design (Figure 1).

Results

The results showed that the DTC algorithm achieved superior cluster separation with a silhouette score of 0.74 and DBI value of 0.35, despite requiring a longer execution time (20 seconds). The DTC algorithm also showed the lowest clustering inconsistency rate (6%) and successfully identified three distinct clusters. Hierarchical clustering yielded a silhouette score of 0.68 and DBI value of 0.52, with an execution time of 10 seconds and a clustering inconsistency rate of 15%, and was able to identify three clusters. In contrast, the K-means method emerged as the fastest algorithm with an execution time of only 3 seconds, but showed relatively poorer clustering quality (silhouette score: 0.63; DBI: 0.78) and a higher clustering inconsistency rate (18%). The comparative analysis highlighted DTC's superior performance in capturing meaningful movement patterns despite its greater computational time (Table 1).

Conclusion

There are significant differences in performance between hierarchical, K-means, and DTC algorithms in analyzing 3D ankle joint kinematics during running. DTC has superior clustering quality despite a longer execution time. Its integrated dimensionality reduction and clustering architecture, featuring an autoencoder and specialized

Table 1. Performance comparison of three clustering algorithms

Algorithm	Silhouette Score	DBI	CHI	Clustering Inconsistency Rate (%)	Execution Time (s)	No. of Clusters
Hierarchical clustering	0.68	0.52	120	15	10	3
K-means clustering	0.63	0.78	90	18	3	3
DTC	0.74	0.35	150	6	20	3



Scientific Journal of
Rehabilitation Medicine

Figure 1. The DTC architecture

Note: It involves encoding the input signal into a latent space using a convolutional autoencoder, followed by a BI-LSTM model. This combination forms a temporal autoencoder. The latent representation from the BI-LSTM is then passed to a temporal clustering layer to generate cluster assignments.

clustering layer, has a lower clustering inconsistency rate and can effectively capture complex movement patterns. These results confirm DTC's advantages over conventional clustering methods for movement pattern analysis. Conventional algorithms showed limitations primarily due to PCA-based dimensionality reduction, which eliminates nonlinear relationships in movement data. While PCA scaling is common, it alters data structure and complicates biomechanical interpretation. The DTC algorithm overcame these limitations by processing complete stance phase data without dimensionality reduction, preserving subtle movement variations. The DTC's end-to-end unsupervised learning framework provides researchers with an improved tool for precise movement pattern analysis. Unlike traditional methods that may produce ambiguous results, DTC maintains data integrity while enabling meaningful clinical interpretation. This has particular promise for developing targeted interventions in running biomechanics, though additional validation studies are warranted to establish its clinical utility across diverse populations and movement conditions.

Ethical Considerations

Compliance with ethical guidelines

This study was approved by the Ethics Committee of the [University of Mazandaran](#), Babolsar, Iran (Code: IR.UMZ.REC.1403.097). All ethical principles were considered in this study. The participants were informed about the research objectives and methods. They were also assured

of the confidentiality of their information and were free to leave the study at any time, and if desired, the research results would be available to them.

Funding

This study was extracted from the dissertation of Zaniar Mohamadi at the Department of Sports Biomechanics, [University of Mazandaran](#). This research did not receive any specific grant from funding agencies in the public, commercial, or not-for profit sectors.

Authors' contributions

All authors contributed equally to the conception and design of the study, data collection and analysis, interpretation of the results, and drafting of the manuscript. Each author approved the final version of the manuscript for submission.

Conflict of interest

The authors declared no conflict of interest.

Acknowledgments

The authors would like to thank all the patients who participated in this study for their cooperation.



مقاله پژوهشی

خوشه‌بندی الگوی سینماتیکی دوندگان: مطالعه مقایسه‌ای الگوریتم‌های سلسله‌مراتبی، K-Means و خوشه‌بندی زمانی عمیق

زانبار محمدی^۱، منصور اسلامی^۱، روح الله یوسف‌پور^۲

۱. گروه بیومکانیک ورزشی، دانشکده علوم ورزشی، دانشگاه مازندران، بابلسر، ایران.

۲. گروه علوم کامپیوتر، دانشکده ریاضی، دانشگاه مازندران، بابلسر، ایران.



Citation Zaniar Z, Eslami M, Yousefpor R. [Clustering Kinematic Patterns of Runners: A Comparative Study of Hierarchical, K-Means, and Deep Temporal Clustering Algorithms (Persian)]. *Scientific Journal of Rehabilitation Medicine*. 2025; 14(5):698-709. <https://dx.doi.org/10.32598/SJRM.14.5.3363>

doi <https://dx.doi.org/10.32598/SJRM.14.5.3363>

چکیده

مقدمه و اهداف: در پژوهش‌های بیومکانیکی، عملکرد الگوریتم‌های خوشه‌بندی یادگیری عمیق معمولاً برای شناسایی الگوهای حرکتی همگن در دوندگان هنوز ناشناخته است. هدف این مطالعه مقایسه عملکرد الگوریتم‌های خوشه‌بندی سلسله‌مراتبی و K-means بر PCA با الگوریتم خوشه‌بندی زمانی عمیق مبتنی بر نگاشت سرتاسری داده‌ها در شناسایی گروه‌های دوندگان با الگوی حرکتی مشابه، براساس داده‌های سینماتیک مفصل مچ پا بود.

مواد و روش‌ها: زوایای سه‌بعدی مفصل مچ پا از ۱۰۸ دونده سالم تفریحی (سن: ۲۲/۴۵±۲/۴۲ سال، قد: ۱/۶۹±۰/۱۱ متر، توده بدن: ۶۴/۶۴±۹/۵۴ کیلوگرم، جنسیت: ۵۵ مرد، ۵۳ زن) حین دویدن با پای برهنه با سرعت ۳±۰/۳ متر بر ثانیه، به دست آمد. الگوریتم‌های خوشه‌بندی عمیق زمانی، سلسله‌مراتبی و K-means با استفاده از زوایای مفصل مچ پا حین دویدن آموزش داده شدند. پس از خوشه‌بندی، عملکرد و دقت خروجی هر الگوریتم در شناسایی خوشه‌های الگوی حرکتی همگن با محاسبه شاخص‌های ارزیابی خوشه‌بندی (ضریب سیلوئت، شاخص دیویس-بولدین و شاخص کالینسکی-هاراباز)، مورد ارزیابی قرار گرفتند.

یافته‌ها: در تفکیک خوشه‌ها، الگوریتم خوشه‌بندی عمیق زمانی با امتیاز سیلوئت ۰/۷۴ و شاخص دیویس-بولدین برابر با ۰/۳۵، نشان داد در مقایسه با ۲ الگوریتم دیگر از عملکرد و دقت خروجی بهتری برخوردار است. این الگوریتم ۳ خوشه مجزا را با نرخ ناسازگاری ۶ درصد شناسایی کرد. خوشه‌بندی سلسله‌مراتبی دارای امتیاز سیلوئت ۰/۶۸ و ۰/۵۲ در شاخص دیویس-بولدین با زمان اجرای ۱۰ ثانیه و نرخ ناسازگاری ۱۵ درصد بود. K-means دارای امتیاز سیلوئت ۰/۶۳ و ۰/۷۸ در شاخص دیویس-بولدین بود که در ۳ ثانیه با نرخ ناسازگاری ۱۸ درصد اجرا شد.

نتیجه‌گیری: یافته‌های این مطالعه نشان می‌دهد الگوریتم خوشه‌بندی زمانی عمیق در مقایسه با روش‌های سنتی، مانند خوشه‌بندی سلسله‌مراتبی و K-means، عملکرد بهتری در شناسایی الگوی حرکتی همگن مفصل مچ پایدونندگان دارد. دقت بالاتر و نرخ ناسازگاری پایین‌تر این الگوریتم، آن را به گزینه‌ای مناسب برای تحلیل داده‌های سینماتیک در پژوهش‌های بیومکانیکی تبدیل می‌کند. این نتایج می‌تواند درک و تحلیل الگوهای حرکتی را بهبود بخشد و به تدوین استراتژی‌های کارآمد جهت تجویز مداخلات هدفمند کمک کند.

کلیدواژه‌ها: دویدن، زوایای مفصل مچ پا، الگوریتم خوشه‌بندی عمیق زمانی، الگوریتم خوشه‌بندی سلسله‌مراتبی، خوشه‌بندی k-means

تاریخ دریافت: ۱۴ اردیبهشت ۱۴۰۴

تاریخ پذیرش: ۳۱ اردیبهشت ۱۴۰۴

تاریخ انتشار: ۰۱ آذر ۱۴۰۴

* نویسنده مسئول:

دکتر منصور اسلامی

نشانی: بابلسر، دانشگاه مازندران، دانشکده علوم ورزشی، گروه بیومکانیک ورزشی.

تلفن: ۹۸ (۹۱۱) ۱۱۲۴۰۰۵

رایانامه: msealami@gmail.com



Copyright © 2025 The Author(s);

This is an open access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC: <https://creativecommons.org/licenses/by-nc/4.0/legalcode.en>), which permits use, distribution, and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

مقدمه و اهداف

دویدن به دلیل دسترسی آسان و هزینه‌های پایین، یکی از رایج‌ترین فعالیت‌های ورزشی محسوب می‌شود و در میان عموم مردم محبوبیت زیادی یافته است [۱]. با این حال با افزایش مشارکت و به دلیل ماهیت تکراری این فعالیت، بروز آسیب‌های ناشی از پرکاری در میان دوندگان رایج شده است [۲، ۳]. براساس مطالعات اپیدمیولوژیک نرخ بروز آسیب‌های مرتبط با دویدن بین ۱۹ تا ۷۹ درصد در سال بوده که ۷۰ درصد در زنان و بخش‌های تحتانی زانو گزارش شده است [۴]. با وجود استفاده گسترده از مداخلات پیشگیرانه و درمانی، شیوع آسیب‌های ناشی از دویدن طی دهه‌های اخیر کاهش معناداری نداشته است [۵]. این نتایج ممکن است ناشی از تفاوت‌های فردی در پاسخ به مداخلات پیشگیرانه از قبیل کفش‌های مخصوص دویدن باشد. براین اساس، شناسایی الگوهای حرکتی در گروه‌های همگن و طراحی مداخلات متناسب می‌تواند به تدوین دستورالعمل‌های مؤثرتر درمانی یا پیشگیرانه کمک کند [۵].

اخیراً با استفاده از الگوریتم‌های خوشه‌بندی بدون نظارت، مطالعاتی جهت شناسایی خوشه‌هایی از دوندگان با الگوی حرکتی همگن انجام شده است [۶، ۷، ۹]. اگرچه الگوریتم‌های خوشه‌بندی سنتی در برخی مطالعات به کار رفته‌اند، اما این روش‌ها اغلب برای داده‌های استاتیک^۱ با ابعاد کم طراحی شده‌اند و با داده‌های سری‌زمانی^۲ سازگاری مناسبی ندارند [۸، ۱۱، ۱۰]. بنابراین، استفاده از این الگوریتم‌ها برای پردازش داده‌های بیومکانیکی با چالش بزرگی ابعاد داده‌ها مواجه است [۱۱]. جهت رفع این چالش، معمولاً از روش تحلیل مؤلفه‌های اصلی^۳ استفاده می‌شود [۱۲]. به این ترتیب که مجموعه‌ای از مؤلفه‌های اصلی که دربرگیرنده ۷۰ تا ۸۰ درصد از واریانس کل داده‌ها است، به عنوان ورودی الگوریتم استفاده می‌شود. با این حال این روش با مشکلاتی نظیر نادیده گرفتن تفاوت‌های ظریف در الگوی حرکتی مواجه است [۱۲]. برای مثال در یک پژوهش که گروه‌بندی عملکردی براساس سینماتیک پا و مچ پا در حین دویدن صورت گرفت، مقادیر پایین شاخص سیلوئت^۴ (۰/۱۳) و ضریب همبستگی کوفنتیک^۵ (۰/۳۸) نشان‌دهنده ناهمگنی گروه‌های شناسایی شده بود [۶]. به‌طور کلی، ناتوانی روش‌های اخیر در گروه‌بندی عملکردی را می‌توان ناشی از محدودیت‌هایی از قبیل نادیده گرفتن پیوستگی زمانی [۱۳]، مقیاس‌بندی مجدد داده‌ها جهت تفسیر [۵]، نادیده گرفتن روابط غیرخطی بین متغیرها [۱۴]، وابستگی به محورهای انتخاب‌شده و همچنین محدود بودن معیارهای سنجش شباهت میان الگوها دانست [۱۴].

برای غلبه بر این محدودیت‌ها، استفاده از الگوریتم‌های یادگیری عمیق، به‌ویژه خوشه‌بندی زمانی عمیق^۶، پیشنهاد شده است [۸]. مزیت اصلی این الگوریتم، استفاده از ساختار خودمزنگار^۷ عمیق است که قادر به نگاشت اطلاعات غیرخطی و استخراج ویژگی‌های پیچیده سری‌زمانی در یک فضای پنهان^۸ است. پس از نگاشت داده‌ها به فضای پنهان، لایه خوشه‌بندی زمانی با استفاده از معیارهای متنوع برای اندازه‌گیری شباهت یا عدم شباهت، امکان شناسایی الگوهای حرکتی گروه‌های همگن را فراهم می‌کند که متناسب با نیاز و کاربرد قابل تنظیم است [۸]. علاوه بر این، این الگوریتم توانایی شناسایی موضعی رویدادهای داده‌های سری‌زمانی بدون برچسب را دارد و برخلاف رویکردهای جعبه‌سیاه، اطلاعاتی درباره مؤثرترین ویژگی‌ها در فرایند خوشه‌بندی ارائه می‌دهد. در یک تحقیق که روش خوشه‌بندی مبتنی بر نگاشت سرتاسری داده‌ها^۹، با روش‌های خوشه‌بندی مبتنی بر یادگیری ماشین^{۱۰} مقایسه شد، نتایج نشان داد روش سرتاسری با میانگین نمودار مشخصه عملکرد ۰/۹۲ نسبت به روش‌های خوشه‌بندی مبتنی بر یادگیری ماشین با میانگین نمودار مشخصه عملکرد^{۱۱} ۰/۸۸ برتری دارد [۸]. الگوریتم خوشه‌بندی زمانی عمیق در ۱۳ مجموعه داده سری‌زمانی متشکل از داده‌هایی با تعداد نمونه، توالی زمانی و نسبت توزیع خوشه گوناگون به‌طور کلی عملکرد بهتری نسبت به روش‌های خوشه‌بندی مبتنی بر یادگیری ماشین داشته است.

با این حال، بیشتر تحقیقات انجام‌شده در این زمینه بر داده‌های مربوط به حوزه‌های هوافضا و محیط زیست متمرکز بوده‌اند. از آنجاکه داده‌های بیومکانیکی نیز ماهیت سری‌زمانی دارند و ویژگی‌های ویسکوالاستیسیته بافت‌های بدن انسان دارای خصوصیات منحصربه‌فردی هستند، بررسی کارایی این روش‌ها بر روی داده‌های بیومکانیکی ضروری به نظر می‌رسد [۱۵]. به‌منظور اطمینان از عملکرد بهینه این روش‌ها بر روی داده‌های بیومکانیکی، انجام تحلیل مقایسه‌ای بین روش‌های مختلف خوشه‌بندی پیشنهاد می‌شود [۱۱]. براساس مرور منابع موجود، تاکنون هیچ مطالعه‌ای به‌طور تجربی عملکرد الگوریتم‌های مذکور را در تحلیل داده‌های بیومکانیکی دوندگان بررسی نکرده است.

هدف مطالعه حاضر، مقایسه عملکرد الگوریتم‌های خوشه‌بندی سلسله‌مراتبی^{۱۲} و K-means^{۱۳} مبتنی بر تحلیل مؤلفه‌های اصلی با الگوریتم خوشه‌بندی عمیق زمانی مبتنی بر نگاشت سرتاسری داده‌ها جهت شناسایی گروه‌های همگن دوندها بود. این مطالعه

6. Deep temporal clustering (DTC)

7. Autoencoder

8. Latent space

9. End-to-end

10. Machine learning

11. Performance characteristic curve

12. Hierarchical Clustering

13. K-means Clustering

1. Static data

2. Time series

3. Principle component analysis (PCA)

4. Silhouette Index (SI)

5. Kendall's Tau Coefficient

می‌کوشد به بررسی اثربخشی روش‌های مختلف خوشه‌بندی یادگیری عمیق در تحلیل داده‌های سری‌زمانی جهت شناسایی گروه‌های دوندگان با الگوی حرکتی مشابه بپردازد. فرضیات تحقیق:

۱. الگوریتم خوشه‌بندی عمیق زمانی، به دلیل قابلیت‌های پیشرفته در استخراج ویژگی‌های پیچیده داده‌های سری‌زمانی، در مقایسه با الگوریتم خوشه‌بندی K-means مبتنی بر تحلیل مؤلفه‌های اصلی، عملکرد و دقت بیشتری دارد.

۲. الگوریتم خوشه‌بندی عمیق زمانی، به دلیل بهره‌گیری از ساختار خودرمنگار عمیق و توانایی در مدل‌سازی الگوهای غیرخطی، در مقایسه با الگوریتم خوشه‌بندی سلسله‌مراتبی مبتنی بر تحلیل مؤلفه‌های اصلی، دقت و کارایی بالاتری ارائه می‌دهد.

مواد و روش‌ها

۱۰۸ دونده سالم تفریحی (سن: $22/45 \pm 2/42$ سال، قد: $1/69 \pm 0/11$ متر، جرم بدن: $64/64 \pm 9/54$ کیلوگرم، جنسیت: ۵۵ مرد، ۵۳ زن) وارد مطالعه شدند. معیارهای ورود: نداشتن سابقه جراحی، شکستگی، سوختگی، مشکلات عصبی-عضلانی، آسیب‌های حاد یا آسیب‌های ناشی از دویدن، نداشتن ضربات جدی در اندام تحتانی و عدم استفاده از اندام مصنوعی در ران، زانو و مچ پا، نداشتن ناهنجاری‌های ساختاری و عملکردی، مانند گودی کمر، صافی کمر، کف پای صاف و گود و همچنین زانوی ضربدری و پرانتری، عدم استفاده از هرگونه کفی، نداشتن دیابت و بیماری‌های مربوط به اعصاب پیرامونی در ۶ ماه قبل از آزمون و نداشتن هیچ‌گونه دردی در ۳ ماه قبل از آزمون. اطلاعات مربوط به تست غربالگری توسط فیزیوتراپ متخصص کنترل شد.

یک صفحه نیروی Kistler (سوئیس) با فرکانس نمونه‌برداری ۱۰۰۰ هرتز در مرکز مسیر ۱۵ متری نصب شد. برای کنترل سرعت، زمان طی شدن فاصله ۵ متری از نقطه شروع تا برخورد با صفحه نیرو توسط ۲ ارزیاب مستقل به‌صورت هم‌زمان و با استفاده از کرنومتر دیجیتال Q&Q-VQ47 (ژاپن) با دقت ۰/۰۱ ثانیه اندازه‌گیری شد. معیارهای پذیرش: ۱. اختلاف زمانی کمتر از ۰/۰۵ ثانیه بین اندازه‌گیری‌های ۲ ارزیاب؛ ۲. سرعت در بازه ۲/۷ تا ۳/۳ متر بر ثانیه (متر بر ثانیه $3 \pm 0/3$). تحلیل قابلیت اطمینان، مقادیر خطای استاندارد اندازه‌گیری (متر بر ثانیه $0/11 = SEM$) و حداقل تغییر قابل تشخیص (متر بر ثانیه $0/3 = 95\%$ MDC) را نشان داد که بیانگر دقت مناسب روش اندازه‌گیری برای اهداف مطالعه بود. در این تحقیق، از مدل سینماتیکی دو بخشی برای مدل‌سازی ساق پا و پا به‌عنوان اجسام صلب بهره‌گیری شد که منطبق بر مدل‌های استاندارد ۶ درجه آزادی است و به‌ویژه در مطالعات مرتبط با دویدن رایج است [۱۶]. ۷ نشانگر بازتابی بر روی برجستگی‌های استخوانی اپی‌کوندیل‌های داخلی و خارجی ران، قوزک‌های داخلی و خارجی، مرکز استخوان پاشنه در محل اتصال تاندون آشیل، انتهای دیستال استخوان‌های متاتارس ۱ و ۵ و همچنین پایه استخوان متاتارس دوم قرار داده شدند. همچنین یک کلاستر شامل ۳ نشانگر روی ساق، به‌عنوان نشانگرهای آناتومیک و رهگیری استفاده شد (تصویر شماره ۱).

داده‌های سینماتیکی با استفاده از ۶ دستگاه دوربین فیلم‌برداری شرکت Simi Motion ساخت آلمان با سرعت تصویربرداری ۲۰۰ هرتز جمع‌آوری شدند. برای هر آزمودنی ۳ تلاش موفق ثبت شد. مرحله استقرار دویدن با استفاده از نیروی عمودی عکس‌العمل زمین که حاصل از صفحه نیروسنج بود تعیین شد. داده‌های خام با استفاده از پالایه پایین‌گذر باترورث مرتبه چهارم در فرکانس برشی ۱۶ هرتز (تعیین‌شده براساس



تصویر ۱. چیدمان نشانگره

در مرحله اول، یک شبکه عصبی پیچشی یک‌بعدی^{۱۵} (1D-CNN) برای استخراج ویژگی‌های محلی از داده‌های سری‌زمانی به کار گرفته شد.

مرحله دوم شامل استفاده از شبکه حافظه کوتاه‌مدت - بلندمدت دوطرفه^{۱۶} برای مدل‌سازی روابط زمانی میان مقاطع مختلف داده بود.

در مرحله سوم، با بهره‌گیری از نمایش نهفته تولیدشده، خوشه‌بندی ناپارامتری در فضای زمانی مکانی انجام شد که منجر به شناسایی خوشه‌های حرکتی همگن شد (تصویر شماره ۳).

الگوریتم خوشه‌بندی سلسله‌مراتبی: به منظور شناسایی الگوهای همگن در زوایای سه‌بعدی مفصل مچ پا، از الگوریتم خوشه‌بندی سلسله‌مراتبی مبتنی بر مؤلفه‌های اصلی استفاده شد [۱۷، ۱۸]. این رویکرد شامل ۳ مرحله اصلی بود (تصویر شماره ۴): محاسبه ماتریس فاصله بین آزمودنی‌ها براساس مؤلفه‌های اصلی استخراج‌شده؛ ادغام تدریجی خوشه‌ها با استفاده از روش پیوند^{۱۷} و ساخت دندروگرام و تعیین تعداد خوشه‌ها با ارزیابی دندروگرام و استفاده از آستانه ناسازگاری^{۱۸} که مقادیر بالاتر آن نشان‌دهنده تمایز بهتر خوشه‌ها هستند [۱۷].

الگوریتم خوشه‌بندی K-means: الگوریتم K-means یکی از روش‌های خوشه‌بندی بدون نظارت است که هدف آن گروه‌بندی نمونه‌ها براساس الگوهای نهفته در داده‌هاست [۱۹]. در این الگوریتم، ابتدا تعداد خوشه‌ها (k) به صورت پیش‌فرض یا برپایه تحلیل‌های آماری مشخص می‌شود. سپس مراکز اولیه خوشه‌ها به صورت تصادفی انتخاب شده و هر نمونه براساس کمترین فاصله اقلیدسی به نزدیک‌ترین مرکز اختصاص می‌یابد [۱۹، ۲۰]. پس از

روش تحلیل باقی‌مانده) پالایه شد (تصویر شماره ۲) [۱۵]. با استفاده از مختصات، زوایای سه‌بعدی مفصل مچ پا به روش توالی (XYZ) کاردان در محیط نرم‌افزار متلب نسخه ۲۰۲۲ محاسبه و داده‌ها از نظر زمانی به ۱۰۰ درصد مرحله استقرار دوییدن هنجار شد [۱۵]. در نهایت برای هر آزمودنی یک ماتریس به ابعاد 3×101 تشکیل (جدول شماره ۱) و به عنوان ورودی الگوریتم خوشه‌بندی به نرم‌افزار پایتون منتقل شد.

ماتریس داده

برای الگوریتم خوشه‌بندی زمانی عمیق، داده‌های هر آزمودنی در قالب ماتریسی با ابعاد 3×101 سازماندهی شد که سه ستون آن نمایانگر زوایای مفصل مچ پا در سه صفحه حرکتی (سهمی، عرضی و افقی) و ۱۰۱ ردیف آن متناظر با ۱۰۱ درصد مرحله استقرار دوییدن بود. در نتیجه ۱۰۸ ماتریس مجزا به دست آمد. این داده‌ها در فایل‌های اکسل ذخیره و به عنوان ورودی الگوریتم عمیق زمانی^۴ (DTC) به کار گرفته شدند (جدول شماره ۱). به منظور استفاده در الگوریتم‌های K-means و سلسله‌مراتبی، داده‌ها به صورت یک ماتریس 108×303 (تعداد ویژگی $\times$ تعداد آزمودنی) ادغام شدند. سپس با بهره‌گیری از تحلیل مؤلفه‌های اصلی (PCA)، مؤلفه‌هایی انتخاب شدند که در مجموع حداقل ۹۵ درصد از واریانس داده‌ها را پوشش می‌دادند [۱۲]. در نهایت، ۱۲ مؤلفه اصلی استخراج و در قالب ماتریسی با ابعاد 108×12 به الگوریتم‌های خوشه‌بندی کلاسیک منتقل شدند (جدول شماره ۲).

الگوریتم خوشه‌بندی عمیق زمانی

در محیط نرم‌افزار پایتون نسخه ۳/۸ الگوریتم خوشه‌بندی عمیق زمانی با هدف خوشه‌بندی الگوهای سینماتیک اجرا شد. این الگوریتم در ۳ مرحله پیاده‌سازی شد.


15. Convolutional neural network

16. Bidirectional long short-term memory (Bi-LSTM)

17. Ward linkage

18. Inconsistency Coefficient

14. Deep Temporal Clustering Algorithm (DTCA)



تصویر ۲. نمودار مقدار باقی‌مانده، محور افقی مقادیر فرکانس برشی و محور عمودی مقادیر باقی‌مانده را نشان می‌دهد

جدول ۱. ساختار ماتریس داده‌های خام زاویه مفصل مچ پا برای همه آزمودنی‌ها

مفصل	مچ پا	صفحه‌های حرکتی
افقی ۱×۱۰۱	عرضی ۱×۱۰۱	سه‌می ۱×۱۰۱
آزمودنی		
۱	مجموع آزمودنی = ۱۰۸	
.	ماتریس هر آزمودنی = ۳ (صفحه حرکتی) × ۱۰۱ (نقطه داده)	
.	ابعاد ماتریس: [۱۰۸×۳۰۳]	
۱۰۸		

طب توانبخش

نادرست هستند. شاخص دیویس - بولدین نیز با بررسی نسبت میانگین فشردگی درون خوشه به فاصله بین خوشه‌ها، عملکرد الگوریتم را ارزیابی می‌کند. مقادیر پایین‌تر نشان‌دهنده کیفیت بالاتر خوشه‌بندی هستند [۲۲]. شاخص کالینسکی - هاراباز با محاسبه نسبت واریانس بین خوشه‌ای به درون خوشه‌ای، معیار کمی جداسازی خوشه‌ها را ارائه می‌دهد. مقادیر بالاتر نشان‌دهنده ساختار خوشه‌ای قوی‌تر هستند.

یافته‌ها

این مطالعه به مقایسه عملکرد ۳ الگوریتم خوشه‌بندی سلسله‌مراتبی، K-means و خوشه‌بندی عمیق زمانی در تحلیل داده‌های سینماتیکی سه‌بعدی مفصل مچ پای دوندگان پرداخته است. نتایج نشان می‌دهد خوشه‌بندی عمیق زمانی با نمره سیلوئت ۰/۷۴ و نمره ۰/۳۵ در شاخص دیویس - بولدین عملکرد مطلوبی در تفکیک خوشه‌ها به ثبت رسانده است. هرچند زمان اجرای آن ۲۰ ثانیه بود. همچنین این الگوریتم کمترین نرخ ناسازگاری (۶ درصد) را نشان داد و موفق به شناسایی ۳ خوشه مجزا شد. خوشه‌بندی سلسله‌مراتبی نیز نمره سیلوئت ۰/۶۸ و نمره ۰/۵۲ در شاخص دیویس - بولدین را به همراه زمان اجرای ۱۰ ثانیه و نرخ ناسازگاری ۱۵ درصد به دست آورد، درحالی‌که تعداد خوشه‌های آن نیز ۳ بود. در مقابل K-

تخصیص اولیه، مراکز خوشه‌ها با میانگین‌گیری از نقاط منتسب به هر خوشه به‌روزرسانی می‌شوند و این فرایند به‌صورت تکراری تا هم‌گرایی الگوریتم ادامه می‌یابد (تصویر شماره ۵).

باتوجه به وابستگی الگوریتم K-means به مقداردهی اولیه مراکز خوشه‌ها و احتمال قرارگیری در بهینه‌های موضعی (بدون دستیابی به بهینه سراسری)، تعیین مقدار بهینه پارامتر k از اهمیت ویژه‌ای برخوردار است [۲۰]. در این مطالعه، با استناد به پیشینه پژوهش‌های بیومکانیکی که بازه ۲ تا ۸ خوشه را مناسب می‌دانند، الگوریتم در این بازه برای مقادیر مختلف k اجرا شد. سپس، کیفیت هر مدل با استفاده از شاخص کالینسکی - هاراباز^{۱۹} ارزیابی شد تا مناسب‌ترین تعداد خوشه شناسایی شود [۲۰، ۲۱].

معیار ارزیابی: برای ارزیابی عملکرد الگوریتم‌های خوشه‌بندی، از ۳ شاخص رایج شامل ضریب سیلوئت^{۲۰}، شاخص دیویس - بولدین^{۲۱} و شاخص کالینسکی - هاراباز استفاده شد [۲۲]. ضریب سیلوئت میزان شباهت هر نمونه را به خوشه خود، نسبت به نزدیک‌ترین خوشه دیگر می‌سنجد. مقادیر نزدیک به ۱ نشان‌دهنده کیفیت بالای خوشه‌بندی، مقادیر نزدیک به صفر نشانه‌ی مرزی بودن نمونه‌ها و مقادیر منفی بیانگر تخصیص

19. Calinski-Harabasz
20. Silhouette Index
21. Davis-Bouldin Index

جدول ۲. ماتریس خروجی دستگاه PCA

مفصل	مچ پا	صفحه‌های حرکتی
افقی ۱×۴	عرضی ۱×۴	سه‌می ۱×۴
آزمودنی		
۱	مجموع آزمودنی = ۱۰۸	
.	۱×۱۲ (ماتریس هر آزمودنی) = ۳ (صفحه حرکتی) × ۴ (نقطه داده)	
.	ابعاد ماتریس: ۱۰۸ × ۱۲	
۱۰۸		

طب توانبخش

جدول ۳. نتایج اجرای الگوریتم‌های خوشه‌بندی

الگوریتم	سیلوئت	شاخص			زمان اجرا (ثانیه)	تعداد خوشه
		دیویس - بولدین	کالینسکی - هاراباز	نرخ ناسازگاری خوشه‌بندی (%)		
خوشه‌بندی سلسله‌مراتبی	۰/۶۸	۰/۵۲	۱۲۰	۱۵	۱۰	۳
خوشه‌بندی K-means	۰/۶۳	۰/۷۸	۹۰	۱۸	۳	۳
خوشه‌بندی عمیق زمانی	۰/۷۴	۰/۳۵	۱۵۰	۶	۲۰	۳

طبتوانبخشه

نتایج پژوهش نشان‌دهنده برتری عملکرد الگوریتم خوشه‌بندی عمیق زمانی با شاخص سیلوئت ۰/۷۴ و شاخص کالینسکی - هاراباز ۱۵۰ نسبت به ۲ الگوریتم دیگر بود. این الگوریتم که از یک رمزگذار خودکار^{۲۲} برای کاهش ابعاد و لایه‌های تخصصی خوشه‌بندی استفاده می‌کند، با وجود زمان اجرای ۲۰ ثانیه‌ای، نرخ ناسازگاری پایینی (۶ درصد) نشان داد (جدول شماره ۳). این عملکرد مطلوب ناشی از یکپارچه‌سازی بهینه فرایندهای کاهش ابعاد و خوشه‌بندی در معماری الگوریتم است که توانایی شناسایی الگوهای پیچیده حرکتی را فراهم می‌کند [۲۳، ۱۱، ۸].


تحلیل جامع شاخص‌های ارزیابی نشان می‌دهد الگوریتم خوشه‌بندی عمیق زمانی در تمامی معیارهای سنجش کیفیت خوشه‌بندی، نتایج بهتری نسبت به الگوریتم‌های سلسله‌مراتبی و K-means به‌دست آورده است (جدول شماره ۳). این یافته‌ها فرضیه برتری دقت و کارایی الگوریتم عمیق زمانی را تأیید می‌کند. عملکرد ضعیف‌تر الگوریتم‌های سنتی احتمالاً به دلیل محدودیت‌های ذاتی روش تحلیل مؤلفه‌های اصلی در پردازش داده‌های پیچیده است [۱۲]. این روش ضمن کاهش ابعاد داده‌ها، منجر به حذف بخشی از اطلاعات و روابط غیرخطی موجود در داده‌های حرکتی می‌شود [۱۴، ۱۲] که به‌طور محسوسی بر

means با نمره سیلوئت ۰/۶۳ و نمره ۰/۷۸ در شاخص دیویس - بولدین، به‌عنوان سریع‌ترین الگوریتم شناخته شد و تنها ۳ ثانیه برای اجرا نیاز داشت، اما با نرخ ناسازگاری ۱۸ درصد و مقادیر پایین‌تر شاخص‌های ارزیابی کیفیت خوشه‌بندی، در مقایسه با دیگر روش‌ها، از نظر کیفیت خوشه‌بندی چندان قابل توجه نبوده است. همچنین جدول شماره ۳ شامل نتایج اجرای هریک از الگوریتم‌های خوشه‌بندی به همراه شاخص‌های سیلوئت، زمان اجرا، نرخ ناسازگاری و دیگر موارد مرتبط است (جدول شماره ۳).

بحث

این مطالعه به مقایسه عملکرد ۳ الگوریتم خوشه‌بندی سلسله‌مراتبی، K-means و خوشه‌بندی عمیق زمانی در تحلیل داده‌های سینماتیکی سه‌بعدی مفصل مچ پای دوندگان پرداخته است. ارزیابی عملکرد الگوریتم‌ها با استفاده از شاخص‌های سیلوئت، شاخص دیویس - بولدین و شاخص کالینسکی - هاراباز همراه با بررسی زمان اجرا و نرخ ناسازگاری انجام شد. یافته‌ها تفاوت‌های معناداری در عملکرد این الگوریتم‌ها نشان داد آن‌ها می‌توانند مبنای مناسبی برای انتخاب الگوریتم بهینه در خوشه‌بندی الگوهای حرکتی باشند.

22. Autoencoder




طبتوانبخشه

تصویر ۳. معماری الگوریتم خوشه‌بندی زمانی عمیق، داده‌های سری زمانی ورودی با استفاده از یک رمزگذار خودکار کانولوشنی (1D-CNN) و به دنبال آن شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه (BI-LSTM) در یک فضای پنهان کدگذاری می‌شود. رمزگذار خودکار کانولوشنال و شبکه عصبی حافظه طولانی کوتاه‌مدت، یک رمزگذار خودکار زمانی (TAE) را تشکیل می‌دهند. سپس نمایش نهفته BI-LSTM به یک لایه خوشه‌بندی زمانی داده می‌شود و انتساب‌های خوشه‌های را ایجاد می‌کند.

برخوردار است [۹، ۵]. فرایند مقیاس‌بندی داده‌ها می‌تواند موانع جدی در شناسایی خوشه‌های بالینی و بیومکانیکی معنادار ایجاد کند، چالشی که به‌وضوح در پژوهش‌های مبتنی بر الگوریتم‌های سنتی خوشه‌بندی مشهود است [۱۳، ۱۴].

الگوریتم خوشه‌بندی زمانی عمیق، الگوهای حرکتی همگن را شناسایی و خوشه‌بندی می‌کند. برخلاف روش‌های سنتی که عموماً از تحلیل مؤلفه‌های اصلی به‌منظور کاهش ابعاد داده‌ها استفاده می‌کنند، این الگوریتم به‌طور کامل تمامی داده‌های مرحله استقرار دوییدن را مدنظر قرار می‌دهد تا شباهت میان الگوهای حرکتی را مشخص کند [۸]؛ بنابراین با لحاظ تفاوت‌های ظریف الگوهای حرکتی، این الگوریتم قادر است تحلیل دقیق‌تری از الگوهای حرکت دوییدن ارائه دهد و به خوشه‌بندی بهینه دست یابد [۱۰]. همچنین ترکیب کاهش ابعاد و خوشه‌بندی زمانی در یک چارچوب یادگیری سرتاسری بدون نظارت، این الگوریتم را به ابزاری مؤثر برای شناسایی الگوهای حرکتی همگن تبدیل می‌کند [۸]؛ بدین ترتیب، الگوریتم خوشه‌بندی عمیق زمانی، روشی بهبودیافته را برای پژوهشگران فراهم می‌آورد تا با دقت و کارایی بیشتر، الگوهای حرکتی را تجزیه و تحلیل و گروه‌بندی کنند.

نتایج مقایسه عملکرد ۲ الگوریتم خوشه‌بندی K-means و سلسله‌مراتبی در تحلیل داده‌های بیومکانیکی با پیش‌پردازش تحلیل مؤلفه‌های اصلی^{۳۳} (PCA) نشان داد. الگوریتم خوشه‌بندی K-means از لحاظ سرعت پردازش (۳ ثانیه) نسبت به روش سلسله‌مراتبی (۱۰ ثانیه) برتری دارد. با این حال، ارزیابی شاخص‌های کیفی، شامل نمره سیلوئت (۰/۶۸) در مقابل (۰/۶۳)، شاخص دیویس - بولدین (۰/۸۷) در مقابل (۰/۵۲) و نرخ ناسازگاری (۱۵ درصد در مقابل ۱۸ درصد) نشان‌دهنده عملکرد مطلوب الگوریتم سلسله‌مراتبی در شناسایی الگوهای حرکتی




تصویر ۴. نمایش درختواره، ناسازگاری و سازگاری پیوندها

دقت شناسایی الگوهای همگن حرکتی تأثیر منفی گذاشته است [۶]. بنابراین به نظر می‌رسد استفاده از روش‌های نوین مبتنی بر یادگیری عمیق می‌تواند گامی مؤثر در جهت بهبود دقت و کارایی خوشه‌بندی الگوهای حرکتی پیچیده باشد.

استفاده از روش‌های مقیاس‌بندی داده‌ها مانند تجزیه و تحلیل مؤلفه‌های اصلی برای هم‌وزن‌سازی متغیرها در الگوریتم‌های خوشه‌بندی سلسله‌مراتبی و K-means، اگرچه رویکردی متداول در پردازش داده‌ها محسوب می‌شود، اما چالش‌های مهمی را در مطالعات بیومکانیکی ایجاد می‌کند. این فرایند می‌تواند منجر به تغییر در ساختار ذاتی داده‌ها شده و در نتیجه تفسیر بالینی و بیومکانیکی نتایج را با مشکلات اساسی مواجه کند [۶]. در مطالعات کاربردی در حوزه حرکتی، صرف شناسایی خوشه‌ها کافی نیست و تحلیل دقیق تغییرات الگوهای حرکتی بین خوشه‌های مختلف اهمیت بالایی دارد [۲۴]. به‌ویژه در تحلیل‌های بیومکانیکی، درک زمان‌بندی و علل تغییرپذیری داده‌ها نسبت به خود فرایند گروه‌بندی از اولویت بالاتری

23. Principal Component Analysis (PCA)



تصویر ۵. مثالی از نحوه عملکرد خوشه‌بندی K-means

انتخاب روش‌های بهینه در پژوهش‌های آینده مورد استفاده قرار گیرد.

پژوهش حاضر همانند بسیاری از مطالعات دیگر محدودیت‌هایی داشته است. با وجود اینکه عوامل مختلف تأثیرگذار بر شناسایی الگوی حرکتی گروه‌های همگن در پژوهش حاضر کنترل شد، ضروری است عملکرد این الگوریتم‌ها بر روی نمونه بزرگ‌تری از داده‌های بیومکانیکی متنوع آزمایش و تأیید شود. همچنین بررسی کارایی الگوریتم‌های مختلف خوشه‌بندی در بررسی تأثیر مداخلات و پاسخ گروه‌های شناسایی‌شده بر مداخلات درمانی و پیشگیرانه می‌تواند بینش‌های ارزشمندی را در مورد کاربرد روش‌های نوین در تحقیقات بیومکانیکی ارائه دهد.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

در اجرای پژوهش ملاحظات اخلاقی مطابق با دستورالعمل کمیته اخلاق **دانشگاه مازندران** در نظر گرفته شده و کد اخلاق به شماره (IR.UMZ.REC.1403.097) دریافت شده است. در این مطالعه تمام اصول اخلاقی رعایت شد. اهداف و روش‌های مطالعه به شرکت‌کنندگان توضیح داده شد. همچنین به آن‌ها در مورد محرمانه ماندن اطلاعاتشان اطمینان داده شد و در هر زمان که می‌توانستند از مطالعه خارج شوند و در صورت تمایل، نتایج تحقیق در اختیار آن‌ها قرار می‌گرفت.

حامی مالی

این مقاله برگرفته از رساله دکتری زانبار محمدی در گروه بیومکانیک ورزشی **دانشگاه مازندران** است. این پژوهش هیچ گونه کمک مالی از سازمان‌های دولتی، خصوصی و غیرانتفاعی دریافت نکرده است.

مشارکت‌نویسندگان

همه نویسندگان به‌طور یکسان در مفهوم و طراحی مطالعه، جمع‌آوری و تجزیه و تحلیل داده‌ها، تفسیر نتایج و تهیه پیش‌نویس مقاله مشارکت داشتند.

تعارض منافع

بنابر اظهار نویسندگان، این مقاله تعارض منافع ندارد.

تشکر و قدردانی

نویسندگان از همکاری همه بیمارانی که در این مطالعه شرکت کردند، تشکر می‌کنند.

همگن بود (**جدول شماره ۳**). با وجود این، باید توجه داشت استفاده از PCA به‌عنوان روش کاهش ابعاد، با محدودیت‌هایی در پردازش داده‌های سری‌زمانی بیومکانیکی همراه است که می‌تواند بر تفسیر نتایج تأثیرگذار باشد [۱۳، ۱۲].

قبل از اجرای الگوریتم‌های خوشه‌بندی سلسله‌مراتبی و K-means، یک تحلیل مؤلفه‌های اصلی (PCA) به‌صورت یکجا بر روی کل مجموعه داده‌های سینماتیکی انجام شد. اگرچه این رویکرد به اجزای کاهش‌یافته اجازه می‌دهد تا الگوهای حرکتی را در تمام سطوح به‌طور هم‌زمان نشان دهند، ابعاد مجموعه داده را افزایش می‌دهد و اعتبار خارجی و پایداری PCA را محدود می‌کند [۱۳، ۱۲]. علاوه بر این تفسیر معنای عملی مؤلفه‌ها در هر صفحه پیچیده‌تر و مبهم شده و احتمال بروز نتایج متناقض را افزایش می‌دهد [۱۳، ۶]. در مقابل، الگوریتم‌های خوشه‌بندی زمانی عمیق با حفظ ویژگی‌های اصلی داده‌ها، امکان تجزیه و تحلیل دقیق‌تر و تفسیر معنادار بالینی را فراهم می‌آورند.

پژوهش‌های پیشین نشان داده‌اند ویژگی‌های زیره میانی کفش به‌طور معناداری بر پارامترهای سینماتیکی و سینتیکی [۵، ۲۵] و همچنین الگوی فعالیت عضلانی [۲۷] در حین حرکت تأثیر می‌گذارد. در مطالعه حاضر، خوشه‌بندی براساس ارزیابی دویدن در شرایط پای برهنه اجرا شد (**تصویر شماره ۱**). این رویکرد با این فرضیه طراحی شد که الگوی حرکتی پای برهنه می‌تواند به‌عنوان معیار پایه و نمایانگر الگوی حرکتی طبیعی شرکت‌کنندگان در نظر گرفته شود.

نتیجه‌گیری

این مطالعه به مقایسه عملکرد الگوریتم‌های خوشه‌بندی سلسله‌مراتبی و K-means مبتنی بر تحلیل مؤلفه‌های اصلی با الگوریتم خوشه‌بندی عمیق زمانی در تحلیل داده‌های سینماتیکی مفصل مچ پای دوندگان پرداخته است. یافته‌ها نشان داد الگوریتم خوشه‌بندی عمیق زمانی با بهره‌گیری از معماری پیشرفته مبتنی بر یادگیری عمیق، عملکرد مطلوب‌تری در شناسایی الگوهای پیچیده حرکتی و تفکیک خوشه‌ها دارد. این برتری عمدتاً به دلیل توانایی این الگوریتم در حفظ ساختار غیرخطی داده‌ها و یکپارچه‌سازی بهینه فرایندهای کاهش ابعاد و خوشه‌بندی است.

مقایسه سیستماتیک این روش‌ها نشان می‌دهد اگرچه الگوریتم‌های سنتی (سلسله‌مراتبی و K-means) به‌طور گسترده در تحقیقات بیومکانیکی استفاده می‌شوند، محدودیت‌های ذاتی روش PCA در پردازش داده‌های پیچیده حرکتی می‌تواند بر دقت نتایج تأثیر بگذارد. در مقابل، رویکردهای نوین مبتنی بر یادگیری عمیق با قابلیت استخراج خودکار ویژگی‌های مرتبط، پتانسیل بالایی برای بهبود تحلیل الگوهای حرکتی در مطالعات بیومکانیکی دارند. این یافته‌ها می‌تواند به‌عنوان مبنایی برای

References

- [1] Lee DC, Brellenthin AG, Thompson PD, Sui X, Lee IM, Lavie CJ. Running as a Key Lifestyle Medicine for Longevity. *Progress in Cardiovascular Diseases*. 2017; 60(1):45-55. [DOI:10.1016/j.pcad.2017.03.005] [PMID]
- [2] Foch E, Milner CE. Influence of previous iliotibial band syndrome on coordination patterns and coordination variability in female runners. *Journal of Applied Biomechanics*. 2019; 35(5):305–11. [DOI:10.1123/jab.2018-0350] [PMID]
- [3] Wilder RP, Sethi S. Overuse injuries: Tendinopathies, stress fractures, compartment syndrome, and shin splints. *Clinics in Sports Medicine*. 2004; 23(1):55-81, vi. [DOI:10.1016/S0278-5919(03)00085-1] [PMID]
- [4] Hamill J, Palmer C, Van Emmerik RE. Coordinative variability and overuse injury. *Sports Medicine, Arthroscopy, Rehabilitation, Therapy & Technology : SMARTT*. 2012; 4(1):45. [DOI:10.1186/1758-2555-4-45] [PMID]
- [5] Nigg BM. *Biomechanics of sport shoes*. Calgary: University of Calgary; 2010. [Link]
- [6] Watari R, Suda EY, Santos JPS, Matias AB, Taddei UT, Sacco ICN. Subgroups of foot-ankle movement patterns can influence the responsiveness to a foot-core exercise program: A hierarchical cluster analysis. *Frontiers in Bioengineering and Biotechnology*. 2021; 9:645710. [DOI:10.3389/fbioe.2021.645710] [PMID]
- [7] Senevirathna AM, Pohl AJ, Jordan MJ, Edwards WB, Ferber R. Differences in kinetic variables between injured and uninjured rearfoot runners: A hierarchical cluster analysis. *Scandinavian Journal of Medicine & Science in Sports*. 2023; 33(2):160-18. [DOI:10.1111/sms.14249] [PMID]
- [8] Sai Madiraju N, Sadat SM, Fisher D, Karimabadi H. Deep temporal clustering: Fully unsupervised learning of time-domain features. *arXiv e-prints*. eprint arXiv:1802.01059. 2018. [DOI:10.48550/arXiv.1802.01059]
- [9] Hoerzer S, von Tscharnner V, Jacob C, Nigg BM. Defining functional groups based on running kinematics using Self-Organizing Maps and Support Vector Machines. *Journal of Biomechanics*. 2015; 48(10):2072-9. [DOI:10.1016/j.jbiomech.2015.03.017] [PMID]
- [10] Alqahtani A, Ali M, Xie X, Jones MW. Deep time-series clustering: A review. *Electronics*. 2021; 10(23):3001. [DOI:10.3390/electronics10233001]
- [11] Aghabozorgi S, Seyed Shirkhorshidi A, Ying Wah T. Time-series clustering - A decade review. *Information Systems*. 2015; 53:16-38. [DOI:10.1016/j.is.2015.04.007]
- [12] Phinyomark A, Hettinga BA, Osis S, Ferber R. Do intermediate- and higher-order principal components contain useful information to detect subtle changes in lower extremity biomechanics during running? *Human Movement Science*. 2015; 44:91-101. [DOI:10.1016/j.humov.2015.08.018] [PMID]
- [13] Jolliffe IT, Cadima J. Principal component analysis: A review and recent developments. *Philosophical Transactions. Series A, Mathematical, Physical, and Engineering Sciences*. 2016; 374(2065):20150202. [DOI:10.1098/rsta.2015.0202] [PMID]
- [14] Ghoghgh B, Crowley M, Karray F, Ghodsi A.. Principal Component Analysis. In: *Elements of Dimensionality Reduction and Manifold Learning*. Cham: Springer; 2023. [DOI:10.1007/978-3-031-10602-6_5]
- [15] Winter DA. *Biomechanics and motor control of human movement*. New Jersey: John Wiley & Sons, Inc; 2009. [DOI:10.1002/9780470549148]
- [16] Chalmers O, Page R, Langley B. A step towards dynamic foot classification: Functional grouping using ankle joint frontal plane motion in running. *Gait & Posture*. 2022; 97:35-9. [DOI:10.1016/j.gaitpost.2022.07.005] [PMID]
- [17] Ran X, Xi Y, Lu Y, Wang X, Lu Z. Comprehensive survey on hierarchical clustering algorithms and the recent developments. *Artificial Intelligence Review*. 2023; 56(8):8219-64. [DOI:10.1007/s10462-022-10366-3]
- [18] Martin JA, Stiffler-Joachim MR, Wille CM, Heiderscheid BC. A hierarchical clustering approach for examining potential risk factors for bone stress injury in runners. *Journal of Biomechanics*. 2022; 141:111136. [DOI:10.1016/j.jbiomech.2022.111136] [PMID]
- [19] Chong B. K-means clustering algorithm: A brief review. *Academic Journal of Computing & Information Science*. 2021; 4(5). [DOI:10.25236/AJCIS.2021.040506]
- [20] Oti EU, Olusola MO, Eze FC, Enogwe SU. Comprehensive Review of K-means Clustering Algorithms. *International Journal of Advances in Scientific Research and Engineering*. 2021; 7(8):22-3. [DOI:10.31695/IJASRE.2021.34050]
- [21] Rodriguez MZ, Comin CH, Casanova D, Bruno OM, Amancio DR, Costa LDF, et al. Clustering algorithms: A comparative approach. *PLoS One*. 2019; 14(1):e0210236. [DOI:10.1371/journal.pone.0210236] [PMID]
- [22] Dudek A. Silhouette Index as Clustering Evaluation Tool. In: Jajuga K, Batóg J, Walesiak M, editors. *Classification and Data Analysis. SKAD 2019. Studies in Classification, Data Analysis, and Knowledge Organization*. Cham: Springer; 2020. [DOI:10.1007/978-3-030-52348-0_2]
- [23] Tomašev N., Radovanović M. Clustering evaluation in high-dimensional data. In: Celebi M, Aydin K, editors. *Unsupervised Learning Algorithms*. Cham: Springer; 2016. [DOI:10.1007/978-3-319-24211-8_4]
- [24] Hoitz F, von Tscharnner V, Baltich J, Nigg BM. Individuality decoded by running patterns: Movement characteristics that determine the uniqueness of human running. *PLoS One*. 2021; 16(4):e0249657. [DOI:10.1371/journal.pone.0249657] [PMID]
- [25] Hardin EC, van den Bogert AJ, Hamill J. Kinematic adaptations during running: Effects of footwear, surface, and duration. *Medicine and Science in Sports and Exercise*. 2004; 36(5):838-44. [DOI:10.1249/01.MSS.0000126605.65966.40] [PMID]
- [26] Cole GK, Nigg BM, Fick GH, Morlock MM. Internal loading of the foot and ankle during impact in running. *Journal of applied biomechanics*. 1995; 11(1):25-46. [Link]
- [27] Wakeling JM, Pascual SA, Nigg BM. Altering muscle activity in the lower extremities by running with different shoes. *Medicine and Science in Sports and Exercise*. 2002; 34(9):1529-32. [DOI:10.1097/00005768-200209000-00021] [PMID]