



Original Article

The Estimation of Ground Reaction Force Using Kinematic Data During Running: Can Machine Learning Methods Solve the Limitations?

Fatimah Ahmadi Godini¹, Mansour Eslami², Roholla Yousefpour³

1. Ph.D. Candidate, Department of Sports Biomechanics, Faculty of Sports Sciences, University of Mazandaran, Babolsar, Iran.
2. Associate Professor, Department of Sports Biomechanics, Faculty of Sports Sciences, University of Mazandaran, Babolsar, Iran.
3. Associate Professor, Department of Mathematics, Faculty of Sciences, University of Mazandaran, Babolsar, Iran.

Received: 04/09/2023, **Revised:** 29/10/2023, **Accepted:** 15/11/2023

* Corresponding Author: Mansour Eslami, E-mail: m.eslami@umz.ac.ir

How to Cite: Ahmadi Godini, F; Eslami, M; & Yousefpour, R. (2024). The Estimation of Ground Reaction Force Using Kinematic Data During Running: Can Machine Learning Methods Solve the Limitations?. Sport Medicine Studies, 16(40), 17-46. In Persian.

Extended Abstract

Background and Purpose

In running analysis and evaluating athletes' performance, ground reaction force (GRF) components are essential parameters in estimating joint reaction forces and joint moments. In a biomechanics lab, Force platforms, instrumented treadmills and wearable sensors are the most common and reliable tools to measure GRF. However, using these tools require specific spaces such as motion analysis laboratories, skilled operators and they may alter foot-ground interaction and shoe stiffness. Furthermore, the mechanical and repeated stress applied to these sensors is high, so that the sensors can be easily worn or damaged. Because of these limitations, researchers have recently focused on indirect model in the estimation of GRF from kinematics data.

In biomechanical models, most of the proposed methods require modeling of the biomechanical system. This modeling, in turn, requires extensive knowledge of the subject's special parameters, such as mass of segments, dimensions, moment of inertia and etc. This inevitably brings inaccuracy and uncertainty. To calculate the mechanical parameters of each segment, extensive use of standard tables is required. Such statistical values may cause inaccuracies in the estimation of the desired values and they may not be generalizable to all societies.

In statistical models, many of the anatomical features of people are not considered. Therefore, this method may not be applicable for activities that involve repeated loads, such as running or during a



Copyright: © 2023 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/>).

training session. Furthermore, the accuracy of the estimated GRF by the statistical model is lower than that of other methods.

Recently, the use of machine learning methods, as a modern approach to the GRF estimation, are in the spotlight. These methods are based on the hypothesis that there is a relationship between the acceleration of each segment and the ground reaction forces. Machine learning methods do not require prior knowledge of model and build their own model using the training data obtained in previous experiments. Artificial neural network (ANN) is reported to be a good flexible tool for nonlinear modeling and very efficient for GRF estimation. Indeed, the use of neural networks simplifies modeling and data collection strategies. However, the disadvantages of ANNs include the sensitivity to the chosen input parameters, computationally expensive, as well as requiring a large amount of data for training the system to achieve acceptable accuracy.

According to the review conducted in the current study, most of the reviewed articles reported an acceptable estimation of the vertical component of GRF, while a few focused on its medial-lateral components. However, finding was attributed to the lower absolute values of the medial-lateral force components. Furthermore, while the correlation between body acceleration and vertical GRF was good in most cases, the absolute values of GRF were not correctly estimated. A combination of methods based on biomechanical modeling and machine learning, as well as the use of more sophisticated algorithms, seems to be a promising way to increase the overall accuracy, even in estimating the medial-lateral component of GRF.

Ground reaction force (GRF) components are critical parameters in running analysis, as they are essential for estimating joint reaction forces and joint moments, which are key to evaluating athletes' performance. Traditionally, GRF is measured using force platforms, instrumented treadmills, and wearable sensors, which are considered reliable tools in biomechanics laboratories. However, these methods require specialized spaces, skilled operators, and may alter natural foot-ground interactions and shoe stiffness. Additionally, the mechanical and repeated stress applied to these sensors can lead to wear and damage, further limiting their practicality. Due to these limitations, researchers have increasingly focused on indirect methods for estimating GRF from kinematic data.

Traditional biomechanical models for GRF estimation require detailed modeling of the biomechanical system, which involves extensive knowledge of subject-specific parameters such as segment mass, dimensions, and moments of inertia. This reliance on statistical data from standard tables can introduce inaccuracies and uncertainties, making the results less generalizable across different populations. Statistical models, on the other hand, often overlook many anatomical features, reducing their applicability for activities involving repeated loads, such as running or training sessions. Moreover, the accuracy of GRF estimation using statistical models is generally lower compared to other methods.

Recent advancements in machine learning (ML) methods have provided a promising alternative for GRF estimation. These methods are based on the hypothesis that a relationship exists between segmental accelerations and ground reaction forces. Unlike traditional approaches, machine learning methods do not require prior knowledge of the biomechanical model and can build their own models using training data from previous experiments. Artificial neural networks (ANNs), in particular, have been reported as flexible and efficient tools for nonlinear modeling, making them highly suitable for GRF estimation. However, ANNs are sensitive to the choice of input parameters, computationally expensive, and require large datasets for training to achieve acceptable accuracy. A review of the current literature indicates that most studies report acceptable estimation accuracy for the vertical component of GRF, while fewer studies focus on the medial-lateral components. This

discrepancy is attributed to the lower absolute values of medial-lateral forces, which are more challenging to estimate accurately. Although a strong correlation between body acceleration and vertical GRF has been observed in many cases, the absolute values of GRF are often not estimated correctly. To address these limitations, a combination of biomechanical modeling and machine learning methods, along with the use of more sophisticated algorithms, appears to be a promising approach for improving the overall accuracy of GRF estimation, including the medial-lateral components.

Machine learning methods, particularly ANNs, offer a promising solution to the limitations of traditional GRF estimation techniques. By leveraging the relationship between kinematic data and GRF, these methods can simplify modeling and data collection strategies. However, challenges such as sensitivity to input parameters, computational costs, and the need for large training datasets must be addressed to improve their accuracy and applicability. Future research should focus on integrating biomechanical modeling with machine learning and developing more advanced algorithms to enhance the estimation of both vertical and medial-lateral GRF components.

Keywords: Ground Reaction Force (GRF), Running, Kinematic Data, Machine Learning, Artificial Neural Networks (ANNs), Biomechanical Modeling

Article message

Machine learning methods, especially neural networks, are a promising alternative to traditional biomechanical models in estimating ground reaction force during running using kinematic data.



مرور روش‌های برآورد نیروی عکس‌العمل زمین از داده‌های کینماتیک در دویدن، آیا روش یادگیری ماشین می‌تواند محدودیت‌ها را رفع نماید؟

فاطمه احمدی گودینی^۱ , منصور اسلامی^۲ , روح الله یوسف پور^۳ 

۱. دانشجوی دکتری بیومکانیک ورزشی، دانشکده علوم ورزشی، دانشگاه مازندران.

۲. دانشیار گروه بیومکانیک ورزشی، دانشکده علوم ورزشی، دانشگاه مازندران.

۳. دانشیار گروه آموزشی ریاضی، دانشکده ریاضی، دانشگاه مازندران.

تاریخ دریافت: ۱۴۰۲/۰۶/۱۳، **تاریخ اصلاح:** ۱۴۰۲/۰۸/۰۷، **تاریخ پذیرش:** ۱۴۰۲/۰۸/۲۴

* Corresponding Author: Mansour Eslami, E-mail: m.eslami@umz.ac.ir

How to Cite: Ahmadi Godini, F; Eslami, M; & Yousefpour, R. (2024). The Estimation of Ground Reaction Force Using Kinematic Data During Running: Can Machine Learning Methods Solve the Limitations?. Sport Medicine Studies, 16(40), 17-46. In Persian.

چکیده

تاکنون مطالعه نظام‌مند به منظور دسته‌بندی روش‌های برآورد غیرمستقیم نیروی عکس‌العمل زمین با استفاده از داده‌های کینماتیک حین تکلیف دویدن و به‌ویژه اطلاع‌رسانی درباره‌ی مطالعات انجام‌شده در این زمینه با استفاده از روش جدید هوش مصنوعی انجام نشده است. بنابراین، مطالعه‌ی مروری حاضر، مطالعات انجام‌شده در زمینه‌ی برآورد نیروی عکس‌العمل زمین با استفاده از داده‌های کینماتیک حین دویدن را از سال ۲۰۱۰ تا ۲۰۲۳ جمع‌آوری و بررسی کرده است. این مقالات از طریق جستجو در وبسایت‌های Scopus، IEEE، Kinetics، Kinematics، Ground Reaction Force، PubMed و ScienceDirect، Medline، Xplore، Camera، Video Analysis، IMU، Accelerometer، Running in field و ترکیبی از آن‌ها، پیدا شدند. ۲۱۳ مقاله در منابع مختلف یافت شد که پس از تطبیق با معیارهای ورود به تحقیق، در نهایت ۱۷ مطالعه بررسی گردید. مرور مقالات نشان داد به علت چالش‌هایی که پژوهشگران هنگام به‌کاربردن ابزارهای اندازه‌گیری مستقیم نیرو با آن مواجه هستند، برآورد غیرمستقیم نیرو از داده‌های کینماتیک مورد توجه قرار گرفته است. از میان روش‌های برآورد غیرمستقیم، مدل بیومکانیکی و آماری دقت و اطمینان پایین‌تری دارند. روش‌های یادگیری ماشین به‌عنوان یک ابزار انعطاف‌پذیر برای مدل‌سازی غیرخطی نیازی به دانش قبلی مدل ندارند و مدل خود را براساس الگوریتم‌های شبکه عصبی مصنوعی که یک رابطه‌ای بین متغیرهای ورودی و هدف می‌یابند، ایجاد می‌کنند. به همین دلیل، امروزه استفاده از روش‌های یادگیری ماشین به‌عنوان یک رویکرد مدرن که مدل‌سازی و استراتژی‌های جمع‌آوری داده‌ها را ساده می‌کند، برای برآورد نیرو در کانون توجه قرار گرفته است.



Copyright: © 2023 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/>).

واژگان کلیدی: یادگیری ماشین، نیروی عکس‌العمل زمین، کینماتیک، برآورد، دویدن**۱. مقدمه**

مقدار نیروی عکس‌العمل زمین^۱ (GRF) حین اجرای تکالیف ورزشی معمولاً چندین برابر وزن بدن^۲ (BW) ورزشکار است (۱). برای مثال، اوج GRF در بسکتبالیست‌ها، والیبالیست‌ها و دوندگان حدود دو تا پنج برابر وزن بدن است (۲). در تمرینات پلايومتریک اندام تحتانی، این مقدار حدود چهار و نیم تا هفت برابر وزن بدن است (۳). در فرود از حرکت وارو ژیمناست‌ها، این مقدار به ۱۶ برابر وزن بدن می‌رسد (۱).

در طول یک مسابقه‌ی دوی پنج کیلومتر، پاهای دونده به طور متوسط ۳۰۰۰ بار با زمین برخورد می‌کند. این باعث بارگذاری حدود دو تا سه برابر وزن بدن روی هر پا در هر قدم می‌شود (۲). شکستگی ناشی از خستگی درشت‌نی یکی از شایع‌ترین آسیب‌ها در میان افرادی است که به طور تفریحی و منظم به ورزش دو مشغول می‌باشند. این آسیب‌ها اساساً به دلیل فعالیت بیش از حد و تعدد ضربات و بار وارده طی دویدن ایجاد می‌شود (۴).

در ورزشکاران تفریحی (حداقل دو جلسه‌ی ۴۵ دقیقه‌ای در هفته ورزش می‌کنند)، اوج نیروی عکس‌العمل عمودی زمین^۳ (vGRF) حین فرود، هنگام خستگی ۳/۴٪ تا ۶/۵٪ بزرگتر دیده شده است (۵). این افزایش نیروهای برشی و گشتاوری نامناسبی حول مفاصل ایجاد می‌کند (۶). با افزایش تعداد دوندگان تفریحی و متعاقباً آسیب‌های دویدن در دهه‌های گذشته (۷)، اندازه‌گیری و محاسبه‌ی متغیرهایی مانند سرعت بارگذاری نیروی عکس‌العمل (۸)، سفتی پا (۹-۱۱)، محاسبات دینامیک معکوس (ID)، نیرو و گشتاور عکس‌العمل مفاصل (۱۲، ۶)، توان مفصلی (۱۳)، کار و انرژی مکانیکی (۱۴-۱۶) و بسیاری متغیرهای بیومکانیکی دیگر نیاز به مقادیر دقیق GRF دارد. بنابراین، توسعه‌ی تکنیک‌ها و فن‌آوری‌های موثر برای دستیابی به GRF دقیق و واقعی در میادین ورزشی هنگام اجرای مهارت‌های ورزشی در ارزیابی‌های بیومکانیک ورزشی ضرورت دارد. روش‌های رایج اندازه‌گیری مستقیم GRF شامل صفحه‌ی نیروسنج، تردمیل تجهیز شده^۴، و کفش تجهیز شده^۵ است. صفحات نیروی نصب شده کف زمین در محیط آزمایشگاه به‌عنوان اندازه‌گیری استاندارد طلایی^۶ (GSM) شناخته می‌شوند (۱۷). این صفحات با دقت بالا، روایی و تکرارپذیری قابلیت ادغام با ابزارهایی نظیر الکترومایوگرافی، سیستم‌های ضبط نوری^۷ و حسگرهای نیرو (۱۸) را دارند. با وجود این مزایا، این ابزار گران‌قیمت بوده و علاوه بر نیاز به اپراتور ماهر و محیط آزمایشگاهی، تنها یک ناحیه محدود برای قرار دادن پا دارند که این می‌تواند راه رفتن یا دویدن طبیعی را مختل کند. به‌علاوه، صفحه‌ی نیروسنج اندازه‌گیری GRF را تنها برای یک سیکل ممکن می‌سازد و قادر به ارزیابی تکالیف چرخه‌ای (مانند ثبت چندین سیکل راه رفتن یا دویدن) نیست و ممکن است تغییرات طبیعی تکلیف چرخه‌ای را نشان ندهد (۱۹).

در صورت نیاز به آزمایش‌های چرخه‌ای مکرر می‌توان از تردمیل مجهز به سنسورهای نیرو که قادر به اندازه‌گیری دقیق و مستقیم GRF، گشتاور^۸ (GRM) و همچنین مرکز فشار (COP)، هستند، استفاده کرد (۲۰). این ابزار نیز علاوه بر قیمت بالا

1. Ground reaction force
2. Body weight
3. Vertical GRF
4. Instrumented treadmill
5. Instrumented shoe
6. Golden standard measurement
7. Optical system
8. Ground reaction moment

و نیاز به اپراتور بسیار ماهر و محیط آزمایشگاهی، فقط می تواند GRF را زمانی که فرد در یک خط مستقیم با سرعت ثابت حرکت می کند، ثبت کند (۱۹). افراد ممکن است هنگام حرکت روی تردمیل، استراتژی گام برداری خود را تغییر دهند (۲۱). اخیراً حسگرهای تعبیه شده در کفی کفش (لایه نازکی از مبدل فشارسنج (۲۲)، فیلم کوپلمری پیزوالکتریک (۲۳) یا سنسورهای نیرو) جهت امکان اندازه گیری GRF، GRM و CoP توسعه یافته اند (۲۴). اما کفش تجهیز شده، دارای سنسور کفش ضخیم است که می تواند رابطه طبیعی بین زمین و کف پا را تغییر داده و بر شرایط گام برداری، اصطکاک بین سطوح حرکت، ارتفاع و وزن مؤثر کفی تأثیر بگذارد (۲۵).

این محدودیت های آزمایشگاهی در اندازه گیری GRF، یافتن روشی مقرون به صرفه، با استفاده آسان، در دسترس عموم و قابل استفاده در خارج از آزمایشگاه برای برآورد GRF را به یک موضوع تحقیقاتی چالش برانگیز تبدیل کرده است. روش آزمایشگاهی مرسوم برای اندازه گیری پارامترهای کینماتیکی، استفاده از یک سیستم اپتوالکترونیکی^۱ (OS) است. سیستم OS شامل چندین دستگاه دوربین با سرعت نمونه برداری بالا می باشد که با تصویربرداری از مارکرهای نصب شده بر روی اندام ها، قادر به ردیابی موقعیت سه بعدی آن ها است. از سوی دیگر، با استفاده از دوربین و به کمک نرم افزارهای تحلیل حرکت و شتاب سنج ها، اندازه گیری میدانی پارامترهای کینماتیک امکان پذیر است. واحدهای اندازه گیری اینرسی^۲ (IMU) نیز با استفاده از حسگرهای کوچک و پوشیدنی شتاب سنج،ژیروسکوپ و مغناطیس سنج، قادر به اندازه گیری پارامترهای کینماتیک در خارج از آزمایشگاه هستند.

به دلیل محدودیت های اندازه گیری در محیط آزمایشگاهی، مطالعه میدانی عملکرد ورزشی در بیومکانیک هنوز یک چالش بزرگ برای متخصصان این حوزه است. با توجه به قانون دوم نیوتن که رابطه بین جرم بدن، شتاب و نیروی حاصل را به وضوح توصیف می کند و پیشرفت هایی که در ابزارها و تکنیک های اندازه گیری میدانی پارامترهای کینماتیکی رخ داده است، این سؤال مطرح می شود که آیا می توان با استفاده از داده های کینماتیکی، راهی برای تجزیه و تحلیل کینتیکی و آزمایش عملکرد در خارج از آزمایشگاه هموار کرد و نیاز به تجهیزات آزمایشگاهی را به حداقل رساند؟ مطالعه حاضر به طور نظام مند تکنیک ها و فناوری هایی را که به منظور برآورد غیرمستقیم GFR از پارامترهای کینماتیک حین دویدن توسعه یافته اند، به ترتیب زمانی مرور کرده است. پس از تحلیل نقاط قوت و کاستی های این تکنیک ها، چشم انداز توسعه ای آن ها در آینده نیز موشکافی شده است.

۲. روش

در پژوهش حاضر، مقالات انگلیسی زبان منتشر شده در زمینه ی برآورد GRF بر اساس داده های کینماتیک از پایگاه های اطلاعاتی Scopus، IEEE Xplore، Medline، ScienceDirect و PubMed جستجو شد. کلیدواژه های Ground Reaction، Kinematics، Kinetics، Camera، Video Analysis، Accelerometer، IMU، Running in field و ترکیبی از آن ها استفاده شدند. آخرین جستجوی پایگاه داده در ژوئن ۲۰۲۳ انجام شد. پس از حذف یافته های تکراری، ۲۱۳ مقاله جمع آوری شد که ابتدا بر اساس عنوان، کلمات کلیدی و چکیده ارزیابی شدند. از ۶۲ مقاله ی باقیمانده، مقالات مربوط به تکالیف غیر از دویدن حذف و متن آن ها بررسی شد. مقالات بیشتر با استفاده از استناد در مقالات بررسی شده شناسایی شدند. در پایان

-
1. Optoelectronic System
 2. Inertial measurement unit

فرآیند غربالگری، ۱۷ مقاله که در آن‌ها GRF به‌صورت غیرمستقیم با استفاده از داده‌های کینماتیکی حین دویدن برآورد شده بود، در این مطالعه وارد شدند. اطلاعات هر مقاله در یک جدول از پیش طراحی شده سازماندهی شد.

۳. یافته‌ها

جدول ۱ نتایج ۱۷ مطالعه که GRF را با روش‌های مختلف در تکالیف دویدن برآورد کرده‌اند، نشان می‌دهد. همچنین مدل‌های به‌کاربرده شده و دقت برآورد براساس متغیرهای پیش‌بین در جدول مشاهده می‌شود. براساس اطلاعات جدول، تعداد چهار مطالعه که از قانون حرکت نیوتن، مدل اسکلتی عضلانی، فنر ساده و دو مولفه‌ی گسسته‌ی جرم بدن استفاده کرده‌اند، در دسته‌ی مدل بیومکانیکی قرار می‌گیرند. چهار مطالعه که با استفاده از تکنیک‌های آماری و رگرسیون، ارتباط بین کینماتیک و GRF را ارائه کرده‌اند، در گروه مدل‌های آماری هستند. تعداد نه مطالعه‌ی دیگر که از شبکه عصبی مصنوعی و الگوریتم‌های یادگیری ماشین و یادگیری عمیق استفاده کرده‌اند، به‌عنوان روش شبکه عصبی مصنوعی شناخته می‌شوند.

جدول ۱- اطلاعات مقالات جمع‌آوری شده که GRF را با روش‌های مختلف در تکالیف دویدن برآورد کرده‌اند
Table 1 - Information on collected articles that have estimated GRF using various methods in running tasks

نویسنده Author	تکلیف Task	متغیرهای پیش‌بین Predictor Variables	هدف Objective	تکنیک Technique	دقت، خطا Accuracy, Error
نوگبائر ^۱ ۲۰۱۲	راه رفتن و دویدن	شتاب 2D ایلیاک کمرست	اوج V-GRF	رگرسیون اثرات مختلط رگرسیون تعمیم‌یافته	$r^2=0.967$ خطا 5.2% $r^2=0.877$ خطا 9%
واندرسیتز ^۲ ۲۰۱۳	دویدن و تغییر جهت	شتاب تنه (T2)	اوج GRF	قانون حرکت نیوتن	خطای مطلق 24%
نوگبائر ۲۰۱۴	راه رفتن و دویدن	شتاب 3D ایلیاک کمرست	اوج V-GRF و brake-GRF	رگرسیون اندازه‌های مکرر تعمیم‌یافته	خطای عمودی: 8.3% خطای یرشی: 17.8%
کلارک ^۳ ۲۰۱۴	دویدن	جرم بدن، زمان تماس، زمان پرواز و شتاب عمودی اندام تحتانی	V-GRF	مدل فنر ساده	$R^2 = 0.97$
کلارک ۲۰۱۷	دویدن	جرم بدن، زمان تماس، زمان پرواز و شتاب عمودی اندام تحتانی	V-GRF	مدل جرم-فنر	$R^2 = 0.95$ $RMSE = 0.21W_b$
تیل ^۴ ۲۰۱۸	دویدن	IMU سه‌بعدی روی ساق	اوج GRF	مدل‌سازی خطی	میانگین درصد خطا 33.32%

1. Neugebauer
2. Wundersitz
3. Clark
4. Thiel

جدول ۱- اطلاعات مقالات جمع‌آوری شده که GRF را با روش‌های مختلف در تکالیف دویدن برآورد کرده‌اند

Table 1 - Information on collected articles that have estimated GRF using various methods in running tasks

نویسنده Author	تکلیف Task	متغیرهای پیش‌بین Predictor Variables	هدف Objective	تکنیک Technique	دقت، خطا Accuracy, Error
رپر ^۱ ۲۰۱۸	دویدن	شتاب سه‌بعدی تیپیا	اوج V-GRF	قانون حرکت نیوتن	ضریب همبستگی 0.974 درون‌گروهی
وودا ^۲ ۲۰۱۸	دویدن	جهت و شتاب سنسورهای IMU روی پلويس و شنک	V-GRF	یادگیری ماشین	RMSE =0.27 BW
جانسون ^۳ ۲۰۱۸	راه رفتن، دویدن، پرش جانبی	جرم، جنسیت، قد و ردیابی موقعیت سه‌بعدی ۸ مارکر	GRF	تحلیل مولفه‌های اصلی (PLS)	r=0.9804
وایت ^۴ ۲۰۱۹	دویدن	نرخ گام‌برداری، زاویه‌ی کف کفش با زمین، اندام تحتانی، زانو و آکسکورشن کل عمودی	V-GRF	رگرسیون خطی	R ² = 0.56 خطای میانگین = 0.04
کوماریس ^۵ ۲۰۱۹	دویدن	شتاب سه‌بعدی ساق پا	GRF	یادگیری ماشین	میانگین خطا: عمودی 0.134BW قدامی 0.041 و جانبی 0.042
داویدسون ^۶ ۲۰۱۹	راه رفتن و دویدن	شتاب و سرعت زاویه‌ای بالاتنه	V-GRF	یادگیری عمیق (الگوریتم LSTM)	= 4.48% NRMSE
پوگسون ^۷ ۲۰۲۰	دویدن	شتاب بالاتنه	GRF	یادگیری ماشین	میانگین r ² حدود 0.9
گیرکا ^۸ ۲۰۲۰	دویدن	سری‌های زمانی خام ۸ مارکر	اوج GRF	۵ مدل طبقه‌بندی یادگیری عمیق	ضریب همبستگی 81.09%
تدسکو ^۹ ۲۰۲۰	دویدن	شتاب خطی عمودی ساق پا	V-GRF	یادگیری ماشین	RMSE=0.148BW

1. Raper
2. Wouda
3. Johnson
4. White
5. Komaris
6. Davidson
7. Pogson
8. Girka
9. Tedesco

جدول ۱- اطلاعات مقالات جمع‌آوری شده که GRF را با روش‌های مختلف در تکالیف دویدن برآورد کرده‌اند

Table 1 - Information on collected articles that have estimated GRF using various methods in running tasks


نویسنده	تکلیف	متغیرهای پیش‌بین	هدف	تکنیک	دقت، خطا
Author	Task	Predictor Variables	Objective	Technique	Accuracy, Error
جانسون ۲۰۲۱	دویدن	شتاب سه‌بعدی اندام تحتانی و زمان	GRF	یادگیری عمیق (CaffeNet و ResNet)	همبستگی عمودی 0.97 قدامی 0.96 و جانبی 0.87
شارما ^۱ ۲۰۲۱	راه رفتن و دویدن	سرعت، شتاب و سرعت زاویه‌ای بالاتنه	V-GRF	یادگیری عمیق (الگوریتم LSTM)	NRMSE= 8.38%

۴. بحث

در این مطالعات، از داده‌های کینماتیک اندازه‌گیری شده (یعنی موقعیت سه‌بعدی، جابجایی خطی و زاویه‌ای سه‌بعدی، سرعت و شتاب سگمنت‌های بدن) همراه با یک مدل بدن انسان برای برآورد GRF استفاده شده است. براساس یافته‌ها، تکنیک‌های برآورد GRF بر اساس داده‌های کینماتیکی را می‌توان به سه دسته تقسیم کرد: مدل بیومکانیکی، مدل آماری و شبکه عصبی مصنوعی.

۴-۱. مدل بیومکانیکی

مطالعاتی که با استفاده از قوانین مکانیک، دینامیک معکوس و مدل‌سازی بدن، تلاش کردند GRF را از داده‌های کینماتیک برآورد کنند، در این دسته قرار گرفتند. در ادامه، این روش‌ها مورد بررسی قرار می‌گیرند. واندرسیتز و همکاران (۲۶) برای برآورد اوج GRF در دویدن، فقط از یک شتاب‌سنج سه‌محوری (دامنه $\pm 8g$ ، فرکانس نمونه‌برداری ۱۰۰ هرتز) نصب شده در بالاتنه استفاده کردند. فرضیه اساسی این بود که اوج GRF در دویدن ناشی از برخورد پا با زمین است (۲۷) و چون جرم ثابت است، شتاب اندازه‌گیری شده متناسب با نیرو است (۲۸). اوج GRF برآورد شده توسط این روش با خروجی صفحه‌ی نیروسنج مقایسه شد، در حالی که آزمودنی‌ها چندین تکلیف دویدن و تکالیف تغییر جهت را انجام دادند. هموارسازی سیگنال شتاب برای به‌دست‌آوردن داده‌های قابل‌اعتماد ضروری بود و خطای مطلق ۲۴٪ به‌دست آمد (۲۶).




شکل ۱- مدل ارائه شده توسط کلارک و همکاران (۲۰۱۷) (A) مدل representative multi-element spring-mass-damper و (B) مدل two-mass

Figure 1 - Model presented by Clark et al. (2017) (A) Representative multi-element spring-mass-damper model and (B) Two-mass model

بابت و همکاران (۲۹) نشان دادند که می‌توان از شتاب‌های جمع شده‌ی هفت جزء جرم بدنی (سر، بازوها، تنه، قسمت بالایی پای تماسی، جرم کل پای غیرتماسی و قسمت پایینی پای تماسی) با سرعت متوسط، عملکرد شکل موج کل را برآورد کرد. اما کلارک و همکاران (۳۰) با مدل فنر ساده، تعداد جرم‌های مورد نیاز برای برآورد شکل موج کامل را از هفت به دو کاهش دادند. رویکرد آن‌ها جرم بدن را به دو جزء شامل جرم اندام تحتانی (m_1 ، $1/5$ ، 8% یا 16% کل جرم بدن) و باقیمانده جرم بدن (m_2 ، $9/5$ ، 92% یا 84% کل جرم بدن) تقسیم می‌کند (شکل ۱).

این مدل از نظر تئوری اجازه می‌دهد تا شکل موج کامل نیرو- زمان عمودی به کمک نیروی مربوط به دو جزء جرم بدن برآورد شود. ضربه ۱ از برخورد عمودی m_1 با سطح دویدن و ضربه ۲ از شتاب عمودی m_2 در طول دوره تماس با زمین حاصل می‌شود. تلاش مقدماتی کلارک و همکاران قادر به محاسبه‌ی همه‌ی تغییرات موجود در چهار شکل موج نیروی عمودی- زمان (دامنه‌ی $0/98-0/95$ ، $R^2 = 0/97 \pm 0/01$ میانگین) بود (۳۰).

در پژوهشی دیگر کلارک و همکاران (۳۰) به کمک مدل جرم- فنر ($m_1 = 0/08m_b$ و $m_2 = 0/92m_b$) با ورودی جرم بدن، زمان تماس، زمان پرواز و شتاب عمودی اندام تحتانی (یک مارکر روی میچ پا) شکل موج‌های نیروی عکس‌العمل عمودی زمین- زمان را در دویدن (سرعت‌های $3/0$ تا $11/1$ متر بر ثانیه) برآورد کردند. پیش‌فرض اساسی مدل این است که کل شکل موج نیروی عکس‌العمل عمودی زمین از دو ایمپالس زنگوله‌ای روی هم تشکیل شده است که به دلیل ضربه‌ی اندام تحتانی (J_1) و بقیه بدن (J_2) در هنگام تماس با زمین است. ضربه‌ی کل عکس‌العمل زمین J_T مجموع J_1 و J_2 است و می‌تواند توسط کل نیروی عکس‌العمل عمودی زمین $F_{T,avg}$ ، در طول زمان تماس t_c تعیین شود (شکل ۲).



شکل ۲- شکل موج نیرو-زمان کلارک و همکاران (۲۰۱۷). سمت چپ ضربه‌ی ۱ (قرمز) و ۲ (سبز) که شکل موج نیرو (آبی) را می‌سازند. سمت راست نیروی برآورد شده (آبی) و اندازه‌گیری‌شده (سیاه)

Figure 2 - Force-time waveform by Clark et al. (2017). The left side shows impacts 1 (red) and 2 (green) that compose the force waveform (blue). The right side shows the estimated force (blue) and measured force (black).


روابط مورد نیاز جهت محاسبه‌ی نیروی عکس‌العمل زمین در ادامه آمده است:

$$J_T = J_1 + J_2 = F_{T,avg} t_c \quad (۱)$$

$$F_{T,avg} = m_b g \frac{t_c + t_a}{t_c} \quad (۲)$$


$$F(t) = \frac{A}{2} \left[1 + \cos\left(\frac{t-B}{C} \pi\right) \right] \quad (۳)$$

که در آن A برابر است با $2F_{avg}$ ، B زمان اوج، C نصف فاصله‌ی زمانی و $B-C \leq t \leq B+C$.



شکل ۳- نیروی برآوردشده (آبی) توسط مدل کلارک و همکاران (۲۰۱۷)، نیروی اندازه‌گیری‌شده (سیاه) و ضربه‌ی ۱ (نقطه‌چین قرمز) برای مکانیک ضربه‌ی پا RFS، با مقادیر مختلف m_1 (به ترتیب از چپ به راست: ۱/۵٪، ۸٪ و ۱۶٪) و در سرعت‌های مختلف (از بالا به پایین به ترتیب ۳، ۵ و ۷/۲ متر بر ثانیه)

Figure 3 - Estimated force (blue) by Clark et al. (2017) model, measured force (black), and impact 1 (red dashed line) for foot strike mechanics (RFS) with different m_1 values (from left to right: 1.5%, 8%, and 16%) at various speeds (from top to bottom: 3, 5, and 7.2 meters per second).



شکل ۴- نیروی برآوردشده (آبی) توسط مدل کلارک و همکاران (۲۰۱۷)، اندازه‌گیری‌شده (سیاه) و ضربه‌ی ۱ (نقطه‌چین قرمز) برای مکانیک ضربه‌ی پا FFS، با مقادیر مختلف m_1 (به ترتیب از چپ به راست: ۱/۵٪، ۸٪ و ۱۶٪) و در سرعت‌های مختلف (از بالا به پایین به ترتیب ۳، ۵ و ۱۰ متر بر ثانیه)

Figure 4 - Estimated force (blue) by Clark et al. (2017) model, measured force (black), and impact 1 (red dashed line) for foot strike mechanics (FFS) with different m_1 values (from left to right: 1.5%, 8%, and 16%) at various speeds (from top to bottom: 3, 5, and 10 meters per second).

ضریب همبستگی و RMSE برای شرایط مختلف آزمایش، شامل سرعت‌های مختلف، مکانیک ضربه‌ی پا (پشت پا^۱ (RFS)، جلوی پا^۲ (FFS)) و جرم موثر متفاوت (۱/۵٪، ۸٪ و ۱۶٪ جرم کل بدن) در شکل‌های ۳ و ۴ قابل مشاهده است (۳۱). با وجود همبستگی بالای آزمایش‌های فوق، رویکرد ارائه‌شده دارای محدودیت‌هایی است، زیرا از مقدار زمان تماس استفاده می‌کند که باید بر اساس داده‌های ضبط حرکت یا داده‌های ویدئویی برآورد شود، مگر اینکه با صفحه‌ی نیرو اندازه‌گیری شود. در این مورد، برآورد زمان تماس منبع اصلی خطا در مدل است.

راپر و همکاران (۳۲) پروتکلی برای اندازه‌گیری GRF با استفاده از یک IMU (شتاب‌سنج سه‌محوری ۱۰۰ هرتز) نصب‌شده در قسمت میانی استخوان درشت‌نی طراحی کردند و با مقایسه‌ی نتیجه با صفحه نیروی پیزوالکتریک، قابلیت اطمینان این پروتکل را ارزیابی کردند. تحلیل با استفاده از نرم‌افزار ارائه‌شده توسط سازنده انجام شد که محاسبه اوج GRF را از مولفه‌ی عمودی شتاب درشت‌نی فراهم می‌کند. مقدار مطلق GRF که با IMU اندازه‌گیری شد، با مقدار ثبت‌شده‌ی صفحه‌ی نیروسنج تقریباً ۴۰۰ نیوتن تفاوت داشت. این خطا به دلیل تاخیر بین اوج شتاب و اوج نیروی اعمال‌شده است. همچنین نویسندگان توصیه کردند که نیروی حاصل از IMU نباید با واحد اندازه‌گیری نیوتن بیان شود. با این حال IMU قادر است بار اندام تحتانی را در تکالیف دویدن با دقت تا ۸۳/۹۶٪ و قابلیت اطمینان با ضریب همبستگی درون گروهی ۰/۹۷ برآورد کند.

منابع اصلی خطا در برآورد GRF از داده‌های کینماتیک به کمک مدل بیومکانیکی عبارتند از:

۱- این روش‌ها برای برآورد سیگنال‌های $GRF(t)$ به یک مدل انسانی متکی هستند. نشان داده شده که دقت سیگنال‌های $GRF(t)$ برآورد شده به ویژگی‌های مدل انسانی مانند مدل‌های پا (۳۳) و مفصل زانو (۳۴) بسیار حساس است که می‌تواند باعث ایجاد خطا در خروجی‌های مدل باشد.

۲- خطا در داده‌های اندازه‌گیری شده، به ویژه خطا در جهت‌های اندازه‌گیری شده در موارد استفاده از IMUهای پوشیدنی (۳۵).

۳- استفاده از مفروضات ساده در مدل دینامیک بدن و تحلیل دینامیک معکوس، مانند سگمنت‌های صلب و مفاصل بدون اصطکاک.

۴- عدم دقت در داده‌های آنتروپومتریک، به ویژه اندازه، چگالی و وزن سگمنت‌های بدن، محل مراکز مفصل و محل مرکز جرم هر سگمنت بدن.

۵- خطای ناشی از بافت نرم^۲ (STA) (۳۶، ۳۷)

۶- خطاهای محاسباتی روش‌های استفاده شده.

۲-۴. مدل آماری

مطالعاتی که با استفاده از روش‌های مختلف آماری، در تکلیف دویدن به دنبال برآورد GRF، از داده‌های کینماتیک بودند، در این بخش بررسی شدند.

نویسندگان و همکاران (۳۸) از یک مدل آماری برای برآورد اوج مولفه‌ی عمودی GRF در هنگام راه رفتن و دویدن استفاده کردند. با استفاده از یک شتاب‌سنج دو محوری (فرکانس ۴۰ هرتز و دامنه $\pm 7g$) روی خارجی‌ترین لبه‌ی تاج ایلایک راست، حداکثر

-
1. Rear-foot strike
 2. Fore-foot strike
 3. soft-tissue artefacts

شتاب در دو محور ثبت و اوج نیروی عکس‌العمل عمودی زمین در طی فازهای ساپورت، بر اساس یک مدل رگرسیون اثرات مختلط اندازه‌گیری‌های مکرر و یک مدل رگرسیون تعمیم یافته برآورد شد. چنین مدلی با در نظر گرفتن تأثیر متغیرهای مختلف، به دنبال رابطه‌ای خطی یا لگاریتمی بین متغیرها و هدف است (۳۹). این مدل بر اساس معادلات بنیادی حرکت بر این فرض استوار است که جنسیت، جرم بدن و نوع حرکت، عوامل پیش‌بینی‌کننده‌ی خوبی برای رابطه‌ی بین شتاب و GRF هستند. تحلیل داده‌ها نشان داد که جرم بدن در واقع یک عامل پیش‌بینی‌کننده‌ی خوب است و اوج GRF که به طور لگاریتمی تبدیل شده، به خوبی با استفاده از مدل رگرسیون اثر مختلط، برآورد شده است. میانگین اختلاف مطلق بین GRF برآورد و اندازه‌گیری شده برای مدل‌های مختلط $(\pm 1.1/6) \%$ و $(\pm 0.5/2) \%$ تعمیم یافته $(\pm 0.4/2) \%$ بود. در حالی که حداکثر خطای مشاهده شده 17.5% بود (۳۸). این روش به دلیل حسگر استفاده شده، محدودیت‌های زیادی داشت. نوع حسگر و موقعیت آن اجازه اندازه‌گیری پارامترهای مکانی-زمانی و همچنین پروفایل‌های زمانی GRF را نمی‌دهد. علاوه بر این، این روش به جای مدل بیومکانیکی دقیق‌تر، از یک روش آماری استفاده کرده است، بنابراین بسیاری از ویژگی‌های آناتومیکی افراد مورد توجه قرار نگرفته است. بنابراین، این روش ممکن است برای فعالیت‌هایی که شامل بارهای متمرکز و مکرر هستند، مانند پرش یا در طول یک جلسه تمرین، مناسب نباشد.


نوگبائر و همکاران (۴۰) در مطالعه‌ی دیگر با هدف محاسبه‌ی اوج GRF عمودی (pGRFvert) و قدامی-خلفی (pGRFbrake)، به کمک یک مدل ریاضی مبتنی بر رگرسیون خطی، شتاب‌ها را با استفاده از شتاب‌سنج سه‌محوره (فرکانس ۱۰۰ هرتز و حداکثر دامنه $\pm 6g$) که در جانبی‌ترین قسمت کمر، بر روی تاج ایلیاک راست واقع شده بود (شتاب در مفصل ران) ثبت کردند. میانگین درصد مطلق تفاوت pGRFvert و pGRFbrake واقعی با مقادیر برآورد شده به ترتیب $8/17 \%$ و $3/8 \%$ بود. نویسندگان دریافتند که شتاب اندازه‌گیری‌شده با استفاده از یک شتاب‌سنج نصب‌شده روی مفصل ران، ممکن است نمایانگر دقیقی از بار تحمل‌شده توسط بدن نباشد. در حقیقت، مدل توسعه‌یافته، اوج GRF را به‌ویژه در آن دسته از تکالیف مرتبط با GRF بزرگ‌تر، مانند دویدن برآورد می‌کند. علاوه بر این، نویسندگان مشاهده کردند که در برخی موارد، اوج شتاب در ران، هنگام دویدن، می‌تواند بالاتر از $11g \pm$ باشد (۴۰) در حالی که دامنه شتاب‌سنج $6g \pm$ بود. بنابراین، این روش باید با احتیاط استفاده شده و شتاب‌سنج با دامنه‌ی بزرگ‌تر به کار رود.

تیل و همکاران (۴۱) GRF را در حین دوی سرعت با استفاده از IMUها آزمایش کردند. آن‌ها از دو IMU متشکل از شتاب‌سنج سه‌بعدی ($16g \pm$ و فرکانس ۲۵۰ هرتز)، ژيروسکوپ ($200^\circ/s \pm$) و مغناطیس‌سنج استفاده کردند. IMUها بر روی ساق بالاتر از قوزک داخلی قرار گرفتند. از ورزشکاران خواسته شد در یک مسیر دویدن تجهیز شده با صفحه‌ی نیرو (فرکانس ۱۰۰۰ هرتز) بدونند. مولفه عمودی GRF با معادله خطی زیر به شتاب ساق مرتبط می‌شود:

$$F_v = c_1(n)a_x + c_2(n)a_y + c_3(n)a_z \quad (۴)$$

که در آن $a_{x,y,z}$ مولفه‌های شتاب اندازه‌گیری شده و $c_{1,2,3}$ ضرایب تجربی و n شماره‌ی استراید هستند.

$$c_1(n) = 9.47n - 111 \quad c_2(n) = -4.0n - 143 \quad c_3(n) = -47.6n + 180 \quad (۵)$$



شکل ۳- اوج نیروی عمودی اندازه‌گیری شده (قرمز) و برآورد شده (آبی) توسط تیل و همکاران (۲۰۱۸)

Figure 5 - Measured vertical peak force (red) and estimated vertical peak force (blue) by Thiel et al. (2018)

ضرایب برای هر پا با بهره‌گیری از نیروی ثبت‌شده در گام‌های اول تعیین شد. ثابت شد که این نوع مدل‌سازی برای چهار گام اول دوی سرعت که انتظار می‌رود یک GRF ثابت داشته باشد، کمترین خطا را دارد و بنابراین یک مدل‌سازی خطی مناسب است. علاوه بر این، از سرعت زاویه‌ای ساق پا برای شناسایی فازهای ایستایی و پرواز و در نتیجه، زمان رسیدن به اوج GRF استفاده شد (۴۱).

نویسندگان دریافتند که این روش برای هر شرکت‌کننده قابل اعتماد نیست، حتی اگر بتواند به طور دقیق اوج GRF را برای یک آزمودنی برآورد کند (شکل ۵). منابع احتمالی خطا می‌تواند میرایی نیرو در مچ پا به دلیل ساختار اسکلتی عضلانی و جذب کفش دویدن باشد. این اثر ممکن است با استفاده از یک روش کالیبراسیون کاهش یابد.

در مطالعه‌ی وایت و همکاران (۴۲)، ۱۰ شرکت‌کننده با مارک‌هایی نصب‌شده بر PSIS، ASIS، اپی‌کندیل خارجی ران، قوزک خارجی، قسمت تحتانی خلفی ساق پا بالای تاندون آشیل (دو مارکر) و بالای خط وسط پاشنه (دو مارکر) روی یک تردمیل با سرعت خودانتخابی دویدند. دوربین ساجیتال به طور همزمان حرکات را ضبط می‌کرد. نرخ گام شرکت‌کننده (Step.Rate) محاسبه شد. به کمک نرم‌افزار Kinovea، زاویه کفش با تردمیل در تماس اولیه (Shoe.Ang)، زاویه ساق در تماس اولیه (Leg.Ang)، خم شدن زانو در تماس اولیه (KN_FL_IC)، خم شدن زانو در میانه‌ی استنس (KN_FL_MS)، موقعیت عمودی مرکز تخمینی جرم (مرکز خط اتصال ASIS و PSIS) و موقعیت اکسکورشن عمودی مرکز جرم تخمینی (COM.VtEx) (KN_FL_IC از KN_FL_MS کم شد) و خم شدن کل زانو (KN.FL.Tot) محاسبه گردید. با استفاده از یک رگرسیون خطی استپوایز فوروارد و به کمک نرم‌افزار SPSS، رابطه‌ی زیر جهت برآورد اوج نیروی عمودی عکس‌العمل زمین (pVGRF) به دست آمد:

$$pVGRF = -1.094 + (0.007 * Shoe.Ang) + (-0.001 * Leg.Ang) + (-0.021 * KN.FL.Tot) + (0.108 * COM.VtEx) + (0.018 * Step.Rate) \quad (6)$$


برای پیش‌بینی pVGRF آزمون t-test معنی‌دار نشد. $R^2 = 0.56$ و خطای میانگین 0.4 به دست آمد. نتایج این مطالعه نشان می‌دهد که متغیرهای کینماتیک اندازه‌گیری شده در صفحه ساجیتال و سرعت گام می‌توانند برآورد معقولی از نیروی عکس‌العمل زمین در طول دویدن روی تردمیل ارائه دهند.

۳-۴. شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN)، مدل‌هایی محاسباتی مبتنی بر ساختار و عملکرد مغز انسان هستند. در ۳۰ سال گذشته، ANN در زمینه‌های مختلفی مطالعه شده است. با این حال، کاربرد آن‌ها در بیومکانیک تنها در سال‌های گذشته توجه پژوهشگران را به خود جلب کرده است. مطالعاتی که با استفاده از الگوریتم‌های مختلف ANN، GRF را از داده‌های کینماتیک در تکلیف دویدن برآورد کردند، در این بخش بررسی شدند.

وودا و همکاران (۴۳) GRF عمودی را حین دویدن با استفاده از تنها سه سنسور IMU که در پایین پاها و لگن قرار داده شده بودند، برآورد کرده‌اند. این روش بر اساس دو شبکه عصبی به هم پیوسته آموزش دیده بود. اولین شبکه از شتاب‌های اندازه‌گیری شده برای برآورد زاویه‌های مفصل اندام تحتانی (کینماتیک) استفاده کرد. داده‌ها متعاقباً به شبکه عصبی دوم منتقل شدند که هدف آن برآورد GRF عمودی بود. این معماری، که در شکل ۶ نشان داده شده است، امکان آموزش مستقل دو شبکه و آموزش مجدد انتخابی هر شبکه را در صورت تغییر در شرایط خارجی فراهم می‌کند.


داده‌های کینماتیک به طور همزمان توسط: (۱) یک OS (فرکانس ۱۰۰ هرتز) و (۲) یک سیستم IMU کامل بدن (IMU ۱۷) (فرکانس ۲۴۰ هرتز)، و داده‌های کینتیک توسط یک تردمیل ابزاردار مجهز به صفحه‌ی نیروسنج یک‌بعدی (فرکانس نمونه‌برداری ۱۰۰۰ هرتز)، ثبت شده و فرکانس همه با اینترپولیت خطی ۱۲۰ هرتز یکسان‌سازی شد. از مدل پیوند Xsens MVN برای حل کینماتیک کل بدن استفاده شد. تمام پردازش داده‌ها و تجزیه و تحلیل‌های آماری در MATLAB و طراحی، آموزش و ارزیابی ANN‌ها در "Neural Network Toolbox" اجرا شد و نتایج حاصل از مدل با داده‌های کینماتیک و کینتیک به‌دست‌آمده توسط OS و تردمیل تجهیز شده مقایسه شد. دو سناریوی ارزیابی مختلف مورد استفاده قرار گرفت:



شکل ۴- شماتیک شبکه‌های عصبی به کار رفته توسط وودا و همکاران (۲۰۱۸) و ورودی‌ها و خروجی‌های آن‌ها

Figure 6 - Schematic of the neural networks used by Wouda et al. (2018) and their inputs and outputs


- سناریوی ۱: برای هر آزمودنی، آموزش با سرعت‌های ۱۰ km/h و ۱۴ km/h و ارزیابی با سرعت ۱۲ km/h انجام شد.



شکل ۵- نیروی برآوردشده بوسیله‌ی مدل وودا و همکاران (۲۰۱۸)

Figure 7 - Estimated force by the model by Wouda et al. (2018)

سناریوی ۲: تمام داده‌های ۷ آزمودنی برای آموزش و تمام داده‌های یک آزمودنی برای ارزیابی استفاده شد (شکل ۷). در این پژوهش، زاویه‌ی فلکشن/اکستنشن زانو با دقت کمتر از 5° و نیروی عکس‌العمل زمین با دقت کمتر از $0.2YBW$ برآورد شد. این آزمون با سرعت‌های مختلف تکرار شد و بهترین نتایج با سرعت دویدن 12 km/h مشاهده شد (شکل ۸).



شکل ۶- دقت برآورد V-GRF توسط مدل وودا و همکاران (۲۰۱۸) در سرعت‌های مختلف

Figure 8 - Accuracy of V-GRF estimation by the Wouda et al. (2018) model at different speeds

مسئله اصلی، نیاز به مرحله آموزش برای هر آزمودنی بود که هر آزمودنی جدید را ملزم به انجام یک مرحله آموزشی می‌کند، زیرا هنگام استفاده از داده‌های آموزش از همان آزمودنی، بهترین نتایج مشاهده شد. ممکن است طبق سناریوی ۲ از داده‌های آموزش سایر افراد استفاده شود، که به طور بالقوه می‌تواند یک مدل عمومی‌تر ایجاد کند، اما در این حالت باید انتظار کاهش عملکرد مدل وجود داشته باشد. به علاوه، به دلیل صفحه‌ی نیروسنج یک‌بعدی که برای جمع‌آوری داده‌های آموزش استفاده شد، برآورد GRF به مولفه عمودی آن محدود بود. به طور کلی، برآورد مولفه‌های داخلی-خارجی و قدامی-خلفی GRF از داده‌های کینماتیک دارای دقت ضعیفی است (۴۴). اما روش پیشنهادی توسط وودا و همکاران ممکن است با داده‌های چندمولفه‌ای آموزش دیده و برای برآورد مولفه‌های جانبی GRF اجرا شود.

جانسون و همکاران (۴۵) از داده‌های سال‌های ۲۰۰۰ تا ۲۰۱۵ موجود در دو آزمایشگاه بیومکانیک ورزشی دانشگاه وسترن استرالیا (UWA)، مربوط به طیف گسترده‌ای از حرکات عمومی مانند راه رفتن و دویدن، و همچنین حرکات خاص ورزشی مانند شوت فوتبال و پرتاب بیسبال، استفاده کرده و یازده روش رگرسیون Partial Least Squares (PLS) را برای یادگیری رابطه‌ی بین داده‌های موشن کپچر و GRF/MS تحلیل کردند. PLS یک کلاس از تکنیک‌های رگرسیون چند متغیره نظارت‌شده است که داده‌ها را به فضایی با ابعاد پایین‌تر می‌فرستد و در آن کوواریانس بین متغیرهای پیش‌بینی‌کننده و پاسخ به حداکثر می‌رسد (۴۶). PLS به طور کلی یک تکنیک رگرسیون چند خطی (MLR) نامیده می‌شود، با این حال، می‌تواند رگرسیون غیرخطی را با نمایش داده‌ها به فضای غیرخطی با ابعاد بالاتر انجام دهد که در آن رابطه بین دو نوع متغیر خطی است (۴۶).

$$X = \begin{bmatrix} K_{1,1}^1 & K_{2,1}^1 & \dots & K_{1,2}^1 & \dots & K_{m,f}^1 & \dots & m^1 & s^1 & h^1 \\ K_{1,1}^2 & K_{2,1}^2 & \dots & K_{1,2}^2 & \dots & K_{m,f}^2 & \dots & m^2 & s^2 & h^2 \\ \vdots & \vdots & & \vdots & & \vdots & & \vdots & \vdots & \vdots \\ K_{1,1}^i & K_{2,1}^i & \dots & K_{1,2}^i & \dots & K_{m,f}^i & \dots & m^i & s^i & h^i \end{bmatrix}$$

$$y = \begin{bmatrix} F_{x,1}^1, F_{y,1}^1, F_{z,1}^1, M_{x,1}^1, M_{y,1}^1, M_{z,1}^1, F_{x,2}^1, F_{y,2}^1, F_{z,2}^1, M_{x,2}^1, M_{y,2}^1, M_{z,2}^1, \dots, F_{x,f}^1, F_{y,f}^1, F_{z,f}^1, M_{x,f}^1, M_{y,f}^1, M_{z,f}^1 \\ F_{x,1}^2, F_{y,1}^2, F_{z,1}^2, M_{x,1}^2, M_{y,1}^2, M_{z,1}^2, F_{x,2}^2, F_{y,2}^2, F_{z,2}^2, M_{x,2}^2, M_{y,2}^2, M_{z,2}^2, \dots, F_{x,f}^2, F_{y,f}^2, F_{z,f}^2, M_{x,f}^2, M_{y,f}^2, M_{z,f}^2 \\ \vdots \\ F_{x,1}^i, F_{y,1}^i, F_{z,1}^i, M_{x,1}^i, M_{y,1}^i, M_{z,1}^i, F_{x,2}^i, F_{y,2}^i, F_{z,2}^i, M_{x,2}^i, M_{y,2}^i, M_{z,2}^i, \dots, F_{x,f}^i, F_{y,f}^i, F_{z,f}^i, M_{x,f}^i, M_{y,f}^i, M_{z,f}^i \end{bmatrix}$$


شکل ۷- ماتریس ورودی (x) و هدف (y) مدل جانسون و همکاران (۲۰۱۸). مارکرها K(x,y,z)، نیروها F، گشتاورها M، شماره مارکر

m، فریم f و نمونه یا تریال i، متغیرهای m، s و h به ترتیب جرم، جنسیت و قد

Figure 9 - Input matrix (x) and target (y) of the model by Johnson et al. (2018). Markers K(x,y,z), forces F, moments M, marker number m, frame f, and sample or trial i, variables m, s, and h refer to mass, gender, and height, respectively.


متغیرهای ورودی (پیش‌بین) شامل ردیابی حرکت هشت مارکر، جرم، جنسیت و قد شرکت‌کننده در آرایه‌ی X و متغیرهای هدف شش بردار $F_x, F_y, F_z, M_x, M_y, M_z$ در آرایه‌ی Y جمع‌آوری شدند که نمونه‌ای از فرمت مورد استفاده در رگرسیون چندگانه است (شکل ۹). ۳۵۳ نمونه (۸۰ درصد داده‌ها) به‌عنوان مجموعه داده‌ی آموزشی و ۸۸ نمونه (۲۰ درصد) در مجموعه‌ی ارزیابی در نظر گرفته شد. داده کاوی با استفاده از MATLAB همراه با Biomechanical ToolKit v0.3 صورت گرفت.

روش R-spls SIMPLS، با میانگین ضریب همبستگی $r=0.9804$ برای GRF و $r=0.9143$ برای GRM با‌عنوان قوی‌ترین روش شناسایی شد (شکل ۱۰). این ضرایب همبستگی بالا این فرضیه را اثبات کرد که نیرو، جرم و شتاب تفسیر شده با روش‌های انتزاعی ضبط حرکت مبتنی بر نشانگر، برای ایجاد یک رابطه قوی با خروجی صفحه‌ی نیروسنج آنالوگ کافی بودند. روش‌های PLS طبیعتاً ویژگی‌های ورودی مفید برای پیش‌بینی را حفظ می‌کنند، بنابراین R-spls SIMPLS می‌تواند برای نشان دادن تأثیر نسبی نشانگرها و جرم/جنسیت/قد استفاده شود.



شکل ۸- نیروی برآوردشده (قرمز) توسط جانسون و همکاران (۲۰۱۸) با استفاده از سه مدل از قوی‌ترین مدل‌های PLS و نیروی اندازه‌گیری‌شده (آبی)

Figure 10 - Estimated force (red) by Johnson et al. (2018) using the three strongest PLS models and measured force (blue)




شکل ۹- شبکه عصبی مورد استفاده توسط کوماریس و همکاران (۲۰۱۹)

Figure 11 - Neural network used by Komaris et al. (2019)

کوماریس و همکاران (۴۷) شتاب ساق پای ۲۸ ورزشکار که با سرعت‌های مختلف (۲/۵، ۳/۵ و ۴/۵ متر بر ثانیه) روی تردمیل تجهیز شده (۳۰۰ هرتز) دویدند را به کمک مارکرهای اندام تحتانی ثبت‌شده بوسیله‌ی دوازده دوربین (۱۵۰ هرتز) محاسبه کرده و برای برآورد مولفه‌های سه‌بعدی GRF به سه شبکه عصبی مصنوعی دادند. هر ANN از سه لایه‌ی ورودی (۱۰۰ نورون)، لایه‌ی پنهان (۱۰ نورون) و لایه‌ی خروجی (۱۰۰ نورون) برای برآوردهای GRF در ۱۰۰ نقطه داده تشکیل شد (شکل ۱۱). هر یک از این سه شبکه با یک مولفه از سیگنال شتاب سه‌بعدی تغذیه و به GRF مربوطه اختصاص داشت. نمونه‌ها به طور تصادفی به سه دسته‌ی آموزش ۱۶ آزمودنی (۶۰٪)، اعتبارسنجی ۶ آزمودنی (۲۰٪) و ارزیابی ۶ آزمودنی (۲۰٪) تقسیم شدند. پردازش داده‌ها در MATLAB و سه ANN نظارت‌شده در پایتون ۳ (منبع Tensorflow) اجرا شد. میانگین خطاها برای مولفه‌ی عمودی نیرو 0.134 ± 0.027 BW، مولفه‌ی قدامی-خلفی 0.041 ± 0.007 BW و مولفه‌ی میانی-جانبی 0.042 ± 0.006 BW گزارش شد. هیچ تفاوت آماری معنی‌داری بین سرعت‌های دویدن برای برآورد مولفه‌ی

عمودی و قدامی - خلفی نیرو وجود نداشت، در حالی که نتایج میانی - جانبی برای سرعت‌های دویدن پایین، به‌طور قابل توجهی دقیق‌تر بودند ($P=0.010$) (شکل ۱۲).

تعداد آزمودنی به کار رفته برای این تجزیه و تحلیل، در مقایسه با تعداد آزمودنی مطالعات مشابه اخیر در ادبیات، به‌طور قابل توجهی بزرگتر (۲۸ آزمودنی) و مسلماً باعث آموزش بهتر الگوریتم است (به‌عنوان مثال هفت آزمودنی توسط وودا و همکاران (۴۳)). میانگین خطاهای تقریب مولفه‌های قدامی - خلفی و میانی - جانبی نیرو در مقایسه با حالت عمودی، نسبتاً پایین بود که به دلیل اندازه کم آن مولفه‌ها در مقایسه با وزن بدن آزمودنی است. با این حال، چنین خطاهای کم ممکن است به دلیل روش تقسیم‌پذیری اتخاذ شده باشد، که منجر به وجود داده‌های یک آزمودنی در هر دو مجموعه‌ی آموزش و ارزیابی، و در نتیجه سوگیری عملکرد مدل شد. علاوه بر این، در ادبیات به خوبی گزارش شده است (به عنوان مثال (۴۸)) که LOSO مناسب‌ترین روش اعتبارسنجی متقابل برای ارزیابی کارایی و تعمیم‌پذیری یک مدل برای کاربرانی است که در مجموعه داده‌ها گنجانده نشده‌اند، به‌ویژه برای مجموعه داده‌هایی که بوسیله‌ی تعداد محدودی از افراد تشکیل شده‌اند.




شکل ۱۰- نیروی برآورد شده توسط کوماریس و همکاران (۲۰۱۹)

Figure 12- Estimated force by Komaris et al. (2019)

داویدسون و همکاران (۴۹) یک شبکه‌ی عصبی بیسیک شامل یک یا چند لایه‌ی بازگشتی واحدهای حافظه طولانی کوتاه مدت^۱ (LSTM) و واحد بازگشتی دروازه‌دار^۲ (GRU)، چند لایه noise/dropout برای بهبود تعمیم و یک لایه fully-connected dense با دو خروجی مستقل و تابع فعال‌سازی واحد خطی اصلاح‌شده^۳ (ReLU) را به کار بردند. این شبکه با استفاده از اطلاعات موقعیت، سرعت، شتاب، جهت و سرعت زاویه‌ای آپترانک، GRF را حین راه رفتن و دویدن با سرعت ۱ تا ۸ متر بر ثانیه برآورد کرد.

1. long short-term memory
2. gated recurrent unit
3. Rectified linear unit

اطلاعات ورودی این شبکه با استفاده از سنسورهای شتاب‌سنج، ژيروسکوپ، قطب‌نما، فشارسنج و گیرنده‌ی GPS نصب شده روی بالاتنه، از شش ساعت فعالیت سه آزمودنی (بیش از چهل هزار گام، تقریباً نصف آن‌ها مربوط به دویدن) جمع‌آوری شدند. از بین این اطلاعات، شش ویژگی شتاب سه‌بعدی و سرعت زاویه‌ای سه‌بعدی مهم‌تر است که از بین آن‌ها نیز دو ویژگی شتاب عمودی و فوروارد برای دقت آموزش شبکه‌ی عصبی مهم‌تر است. NRMSE برای برآورد GRF حین راه رفتن و دویدن به ترتیب برای پای چپ و راست ۰/۴۸/۴ و ۰/۴۸/۳ به‌دست آمد.




شکل ۱۱- مراحل آموزش (سمت چپ) و ارزیابی (سمت راست) مدل ارائه شده توسط پوگسون و همکاران (۲۰۲۰)

Figure 13 - Training (left) and evaluation (right) phases of the model presented by Pogson et al. (2020)

پوگسون و همکاران (۵۰) یک روش شبکه عصبی را برای برآورد سری‌های زمانی GRF از شتاب تنه (TA) استفاده کردند. ۱۵ ورزشکار آزمایش‌های دویدن تندشونده، کندشونده و سرعت ثابت را روی زمین (بین ۲ تا ۸ متر بر ثانیه با افزایش ۱ متر بر ثانیه) انجام دادند (تقریباً ۴۰ کارآزمایی برای هر آزمودنی، بسته به حداکثر سرعت دویدن آن‌ها) و داده‌های شتاب‌سنج (۱۰۰ هرتز) و فورس‌پلیت (۳۰۰۰ هرتز) ثبت شد.

تجزیه و تحلیل مؤلفه اصلی (PCA) برای کاهش نویز در برآوردها، روی مولفه‌های TA و GRF انجام شد. سپس پرسپترون چند لایه (MLP) برای نگاشت TA (ورودی‌های مدل) بر روی مولفه‌های GRF (خروجی‌های مدل) استفاده شد که با استفاده از لایه‌های پنهان، ورودی‌ها را بر اساس تابع فعال‌سازی و وزن‌ها ترکیب و یک رگرسیون غیرخطی بین ورودی‌ها و خروجی‌ها ایجاد می‌کند (شکل ۱۳). مدل در پایتون ۲/۷ با استفاده از کتابخانه Scikit-learn و Pyswarm برنامه‌ریزی شد.

GRF با میانگین r^2 حدود ۰/۹ برای سری زمانی هر ضربه پیش‌بینی شد. همبستگی r^2 برای اوج ضربه، در بین فعالیت‌ها ۰/۷۴ بود که در مقایسه با رویکردهای تحلیل همبستگی مطلوب بود. شکل ۱۴ نمونه‌ای از برآوردهای سری زمانی برای سرعت‌های مختلف را نشان می‌دهد.



شکل ۱۲- نمونه‌ای از برآوردهای سری زمانی برای سرعت‌های مختلف توسط پوگسون و همکاران (۲۰۲۰). خطوط یکپارچه GRF برآورده شده و خطوط نقطه‌چین داده‌های مرجع را نشان می‌دهند. (a)-(c) به ترتیب برآوردهای خوبی برای مثالی از دویدن ثابت، تندشونده و کندشونده و (d)-(f) برآوردهای ضعیف‌تر


Figure 14 - Sample time series estimates for different speeds by Pogson et al. (2020). The solid lines represent the estimated GRF and the dashed lines represent the reference data. (a)-(c) show good estimates for examples of steady, accelerating, and decelerating running, respectively, and (d)-(f) show poorer estimates.

این پژوهش اهمیت مکان سنسور بر روی بدن را در نظر نگرفته است. سیگنال TA مورد استفاده قرار گرفت زیرا مسلماً گسترده‌ترین سیگنال شتاب اندازه‌گیری شده در میدان است (۵۱). نتایج ممکن است با قرار دادن شتاب‌سنج در جای دیگری روی بدن بهبود یابد و از آنجایی که اوج ضربه احتمالاً مربوط به شتاب‌های اندام تحتانی در هنگام فرود است (۲۹،۳۱)، افزودن سیگنال‌ها از اندام‌های تحتانی ممکن است برآوردها را بهبود بخشد. در حالی که مشخص شده که این روش به خوبی در بین افراد تعمیم می‌یابد، باید توجه داشت که همه افراد در این مطالعه از نظر سن، وزن و ورزش مشابه بودند. در حالی که می‌توان انتظار داشت که نرمال‌سازی GRF توسط جرم بدن آزمودنی‌ها به دلیل رابطه نیوتنی با شتاب، برآوردها را بهبود بخشد، اما در مطالعه‌ی پوگسون تأثیر معنی‌داری نداشت که ممکن است منعکس‌کننده‌ی شباهت آزمودنی‌ها باشد. در حالی که هدف این مطالعه ارائه‌ی برآوردهایی از حداقل اطلاعات بود، اما اهمیت عوامل دیگر از جمله طول اندام‌ها و جرم سگمنت‌های بدن نیز باید مورد بررسی قرار گیرد.

گیرکا و همکاران (۵۲) پنج مدل شبکه عصبی کانولوشن^۱ (CNN) را برای تحلیل طبقه‌بندی باینری به کار بردند. هدف این مطالعه برآورد ظاهر یک اوج برخورد بر روی سیگنال GRF عمودی با استفاده از سری‌های زمانی خام بود. در اندازه‌گیری‌ها، ۱۳۵ فرد سالم شامل دوندگان نخبه و تفریحی (با سرعت‌های خود انتخابی ۲ تا ۵ متر بر ثانیه، با میانگین 3.71 ± 0.77 متر

1. Convolutional neural network

بر ثانیه) شرکت کردند (هر آزمودنی از ۱ تا ۲۴ کارآزمایی). اطلاعات جنسیتی در این تحقیق ردیابی نشد. سیگنال‌های خام (قسمت قدامی و خلفی لگن، پاشنه، مچ پا و انگشتان پای راست و چپ) در صفحه ساجیتال، توسط سیستم ضبط حرکت (هشت دوربین مادون قرمز ۳۰۰ هرتز) و پنج صفحه‌ی نیروسنج (۱۵۰۰ هرتز) جمع‌آوری شد.



شکل ۱۳- سیگنال مولفه‌ی عمودی GRF و اوج‌های آن در مطالعه‌ی گیرکا و همکاران (۲۰۲۰). سمت چپ نمودار نیروی بدون اوج ضربه و سمت راست دارای اوج ضربه


Figure 15 - Vertical component signal of GRF and its peaks in the study by Girka et al. (2020). The left chart shows the force without an impact peak and the right chart shows the force with an impact peak.

تنها یک بعد برای کاهش تعداد ورودی‌ها برای ANN در نظر گرفته شد، یعنی محور عمودی، زیرا تمرکز این تحقیق بر GRF عمودی بود. برچسب‌گذاری داده‌ها با جستجوی اوج برخورد در سری زمانی GRF با مشتق انجام شد. گام در این تحقیق به عنوان فازی بین دو نقطه‌ی اوج موقعیت COM تعریف شد (۴۰۹۸ نمونه (گام)). ۹۶۷ نمونه بدون اوج برخورد بودند (شکل ۱۵). به‌طور تصادفی از بین نمونه‌های دارای اوج برخورد، ۱۰۵۹ نمونه انتخاب شدند. مدل‌ها با Python 2.7 و کتابخانه Keras (v2.1.2) برای یادگیری عمیق با چارچوب Tensorflow (v1.41) پیاده‌سازی شدند. تفاوت بین مدل‌ها در بخش طبقه‌بندی‌کننده است: بر اساس طبقه‌بندی‌کننده پرسپترون چندلایه^۱ (MLP)، ماشین بردار پشتیبان^۲ (SVM)، رگرسیون منطقی^۳، k-نزدیک‌ترین همسایگان^۴ (kNN)، و الگوریتم‌های جنگل تصادفی^۵. عملکرد طبقه‌بندی‌کننده‌ها با استفاده از آزمون ANOVA با آزمون تعقیبی بونفرونی مقایسه شد.

بدترین عملکرد توسط الگوریتم kNN نشان داده شد. عملکرد MLP در مرتبه‌ی بعد قرار داشت. سپس SVM، رگرسیون منطقی و جنگل تصادفی عملکرد مشابهی را نشان دادند. آزمون‌های انجام‌شده نشان داد که برای هیچ معیاری بین سه طبقه‌بندی‌کننده SVM، رگرسیون منطقی و جنگل تصادفی از نظر آماری تفاوت معناداری وجود ندارد. علاوه بر این، عملکرد طبقه‌بندی‌کننده MLP برای اکثر معیارها از نظر آماری تفاوت معنی‌داری با گروه سه طبقه‌بندی‌کننده ذکر شده در بالا ندارد.

1. Multi-layer perceptron
2. Support vector machine
3. Logistic regression
4. K-nearest neighbor
5. Random Forest

بالاترین دقت به دست آمده و معیار اندازه‌گیری نیرو برای طبقه‌بندی جنگل تصادفی به ترتیب $2/58 \pm 81/09$ درصد و $2/31 \pm 82/07$ درصد است. علیرغم اینکه از یک طرف، ظاهر اوج برخورد حتی برای یک متخصص همیشه واضح نیست، و از طرف دیگر، روش تشخیص اوج برخورد به کارگرفته شده کامل نیست و هنوز جای بهبود وجود دارد، اما نتیجه امیدوارکننده است. داشتن یک مجموعه داده بزرگ‌تر ممکن است به آموزش بهتر مدل‌ها کمک کند. همچنین، یک رویکرد سیستماتیک‌تر برای انتخاب پیش‌بینی‌کننده‌ها می‌تواند ورودی‌های مدل را با قدرت پیش‌بینی بیشتر به دست آورد. این پژوهش با موفقیت به عنوان یک آزمایش اولیه از کاربرد یک رویکرد یادگیری عمیق برای این نوع داده‌ها، یعنی سیگنال‌های خام برای دویدن، عمل کرده و مبنایی برای تحقیقات آینده در مورد برآورد سایر ویژگی‌های GRF عمودی، و متعاقباً خود سیگنال GRF است. تدسکو و همکاران (۵۳) به کمک شبکه عصبی مصنوعی فیدفوروارد^۱ با استفاده از شتاب خطی عمودی جمع‌آوری شده با دو IMU روی قسمت لترال ساق پای راست و چپ، VGRF را با RMSE برابر با $0/148$ BW برآورد کردند. چهارده دونه در حالی که کفی کفش‌های آن‌ها مجهز به حسگرهای اندازه‌گیری نیرو شده بود، با سرعت ۸، ۱۰ و ۱۲ کیلومتر بر ساعت روی تردمیل دویدند. برای هر تکلیف، ۳۰ ثانیه داده‌ها ثبت شد. دو مدل به منظور برآورد V-GRF به کار گرفته شد: (۱) شبکه عصبی فیدفوروارد با لایه‌ی ورودی (۱۰۰ نورون)، پنهان (تعداد نورون‌های مختلف ۳، ۵ و ۱۰ نورون) و خروجی (۱۰۰ نورون)، تابع فعال‌سازی tanh، روش رگولایزاسیون^۲ dropout، تابع ضرر RMSE و الگوریتم بهینه‌سازی^۳ backpropagation و Adam؛ (۲) شبکه‌ی عصبی ذکر شده به علاوه‌ی PCA؛ نمودار بهترین نتایج ANN و PCA (لایه‌ی پنهان با ۱۰ نورون و ۱۰ مولفه‌ی اصلی) در شکل ۱۶ آمده است.



شکل ۱۶- GRF برآوردشده توسط تدسکو و همکاران (۲۰۲۰) (نارنجی) و GRF واقعی (آبی). از چپ به راست به ترتیب نمودارهای مربوط به سرعت‌های دویدن ۸، ۱۰ و ۱۲ کیلومتر بر ساعت. ردیف بالا نمودارهای حاصل از مدل ANN و ردیف پایین مدل

ANN+PCA

Figure 16 - Estimated GRF by Tedesco et al. (2020) (orange) and actual GRF (blue). From left to right, the charts correspond to running speeds of 8, 10, and 12 kilometers per hour. The top row shows charts from the ANN model, and the bottom row shows charts from the ANN+PCA model.

1. feed-forward
2. Regularization method
3. Optimizer


جانسون و همکاران (۵۴) از مدل‌های یادگیری عمیق CNN برای برآورد GRF/GRM چندبعدی استفاده کردند. جانسون برای آموزش از داده‌های ردیابی مارکر (ساکروم، ران و تیبیای راست و چپ) ورزشکاران جوان مربوط به سال‌های ۲۰۰۱ تا ۲۰۱۷ موجود در آرشیو UWA (جمع‌آوری شده از چندین آزمایشگاه بیومکانیک)، و برای ارزیابی از داده‌های پنج شتاب‌سنج (لگن، ران و ساق دو طرف) مربوط به نوامبر ۲۰۱۷ تا فوریه ۲۰۱۸ استفاده کرد.

داده‌های دویدن به سه دسته‌ی آهسته (۲-۳ متر بر ثانیه)، متوسط (۴-۵ متر بر ثانیه) و سریع (> ۶ متر بر ثانیه) تقسیم‌بندی شد. دو الگوریتم AlexNet و ResNet-50 طبقه‌بندی‌کننده‌های تصویر هستند که با ورودی چهار بعدی شتاب‌های سه‌بعدی به‌علاوه زمان (فلت شده به تصاویر دوبعدی) و خروجی شکل موج شش برداری GRF/GRM مدل‌سازی شدند.

به این منظور از Python 2.7، MATLAB و محیط OpenCV استفاده شد. بیشترین همبستگی برای F_z عمودی 0.97 (rRMSE = $13\%/92$) با استفاده از CaffeNet برای سرعت متوسط دویدن یافت شد. F_y قدامی با همبستگی تا 0.96 ($17\%/06$) (rRMSE = $21\%/56$) هر دو با ResNet-50 برای دویدن آهسته برآورد شد.

در رقابت بین مدل کلاسیک CaffeNet و ResNet-50 جدیدتر، به نظر می‌رسید که CaffeNet در جایی که قدرت سیگنال بیشتری وجود دارد، به‌عنوان مثال F_z ، قوی‌تر عمل می‌کند. از طرف دیگر، ResNet-50 در شرایط نویز بیشتر مانند F_x ، بهتر از CaffeNet عمل کرد (شکل ۱۷).

محدودیت اصلی این مطالعه انتخاب مکان حسگر است. در حالی که شتاب‌های حسگر ساق قادر به شناسایی موفقیت‌آمیز اندام ایستاده بودند، مشخصات شتاب عمودی در ساق برای شناسایی رویداد FS کافی نیست. کوچک بودن شتاب میانی-جانبی (F_x) برای آزمایش‌های دویدن منجر به همبستگی‌های پایین میانگین GRF مرتبط شد، زیرا مدل CNN قادر به تشخیص سیگنال از نویز برای این حرکات نیست.



شکل ۱۷- نیروی برآوردشده توسط جانسون و همکاران (۲۰۲۱) به وسیله مدل‌های CaffeNet و ResNet. منحنی قرمز GRF برآوردشده و آبی GRF مرجع

Figure 17 - Estimated force by Johnson et al. (2021) using CaffeNet and ResNet models. The red curve represents the estimated GRF and the blue curve represents the reference GRF.

شارما و همکاران (۵۵) vGRF را به کمک شبکه عصبی LSTM و شتاب و سرعت زاویه‌ای سه‌بعدی برآورد کردند. دو آزمودنی در حالی که کفش آن‌ها به حسگرهای اندازه‌گیری نیرو (Moticon) تجهیز و سیستم ردیابی IMU به همراه GPS (INS/GPS) روی آپرتراک نصب شده بود، روی تردمیل با سرعت ۰/۷۷ تا ۵/۹۰ متر بر ثانیه تکلیف راه رفتن و دویدن را انجام دادند.


داده‌های آموزش شامل ۱۷۴۳ استراید از آزمودنی اول بود که ۱۵۵۹ استراید آن مربوط به راه رفتن و ۱۸۴ استراید دویدن بود. دو مجموعه ارزیابی استفاده شد که اولی شامل ۳۸۸ استراید (۲۷۸ استراید راه رفتن و ۱۱۰ استراید دویدن) از آزمودنی اول؛ و دومی ۵۶۵ استراید (۳۵۲ استراید راه رفتن و ۲۱۳ استراید دویدن) از آزمودنی دوم می‌شد. انتخاب ویژگی‌ها از طریق رویکردهای consider only one و leave-one-out انجام شد که نشان دادند شتاب قدامی و عمودی، بردارهای ورودی مهمتری هستند، شتاب جانبی و سرعت زاویه‌ای سه‌بعدی تا اندازه‌ای برآورد را بهبود می‌بخشند و ویژگی‌های ورودی بیشتر دقت برآورد را بهبود نمی‌دهند.

شبکه عصبی شامل دو لایه LSTM همراه با یک لایه نویز ورودی بین آن‌ها بود. لایه نویز تنها در طول مرحله آموزش، نویز zero-mean Gaussian اضافی را عمداً به داده‌های ورودی اعمال می‌کند که برآورد بیش‌برازش^۱ مدل را کاهش دهد. برای بهبود تعمیم از طریق کاهش تصادفی نسبت خاصی از نورون‌ها dropout rate، بعد از لایه دوم LSTM، یک لایه dropout و نهایتاً تابع فعال‌سازی ReLU برای لایه fully connected dense برای نگاشت لایه پنهان به خروجی هدف، اضافه شد و الگوریتم بهینه‌سازی adam و تابع ضرر mean_squared_error استفاده شد.

NRMSE در برآورد vGRF برای پای چپ و راست به ترتیب برابر با ۸/۳۸٪ و ۸/۵۴٪ محاسبه شد. نیروی اندازه‌گیری‌شده بوسیله سنسورهای کفی کفش به دلیل فشاری که قسمت عقب یا جلوی پا وارد می‌کنند، در تمام مرحله پرواز صفر نبوده

1. Overfitting

و این امر باعث اختلاف بیشتر بین نیروی برآورد شده و اندازه‌گیری شده می‌گردد. بنابراین دقت برآورد شبکه عصبی LSTM بهتر از مقدار ارائه شده در مطالعه‌ی شارما و همکاران است. شکل ۱۸ نمودار VGRF برآورد شده و اندازه‌گیری شده مربوط به مجموعه‌ی ارزیابی اول را برای پای چپ و راست نشان می‌دهد.



شکل ۱۸- V-GRF برآورد شده بوسیله‌ی شبکه‌ی عصبی LSTM توسط شارما و همکاران (۲۰۲۱)
Figure 18- Estimated V-GRF by LSTM Neural Network by Sharma et al. (2021)

۵. نتیجه‌گیری

استفاده از روش‌های یادگیری ماشین به عنوان یک رویکرد مدرن برای برآورد GRF در کانون توجه قرار گرفته است. این روش‌ها بر اساس این فرضیه بنا شده‌اند که بین شتاب اندازه‌گیری شده در هر جایی از بدن انسان و نیروهای عکس‌العمل زمین رابطه وجود دارد. روش‌های یادگیری ماشین نیازی به دانش قبلی مدل ندارند و با استفاده از داده‌های آموزشی به‌دست آمده در آزمایش‌های قبلی، مدل خود را ایجاد می‌کنند.

ANN یک ابزار انعطاف‌پذیر خوب برای مدل‌سازی غیرخطی و بسیار کارآمد برای برآورد GRF گزارش شده‌اند. در واقع، استفاده از شبکه‌های عصبی، مدل‌سازی و استراتژی‌های جمع‌آوری داده‌ها را ساده می‌کند.

با این حال، ANN‌ها به پارامترهای ورودی انتخاب شده حساس هستند، از نظر محاسباتی گران هستند و به مقدار زیادی داده برای آموزش سیستم نیاز دارند تا به دقت قابل قبولی برسند.

طبق بررسی انجام شده در این تحقیق، اکثر مقالات بررسی شده، برآورد مؤلفه‌ی عمودی GRF را تأیید کردند که در بیشتر موارد قابل قبول بود، در حالی که تعداد کمی بر مؤلفه‌های جانبی تمرکز کردند و پایایی ضعیفی در برآورد چنین مقادیری یافتند. این نتیجه به مقادیر مطلق کمتر مؤلفه‌های جانبی نیرو نسبت داده شد. علاوه بر این، در حالی که همبستگی بین شتاب بدن و GRF عمودی در بیشتر موارد خوب بود، مقادیر مطلق GRF به درستی برآورد نشد. ترکیبی از روش‌های مبتنی بر مدل‌سازی بیومکانیکی و یادگیری ماشین، و همچنین استفاده از الگوریتم‌های پیچیده‌تر، راه امیدوارکننده‌ای برای افزایش دقت کلی، حتی در برآورد مؤلفه‌ی جانبی GRF، به نظر می‌رسد.

پیام مقاله

روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی، جایگزینی امیدبخش برای مدل‌های بیومکانیکی سنتی در برآورد نیروی عکس‌العمل زمین حین دویدن با استفاده از داده‌های کینماتیکی هستند.

۶. منابع

1. Slater A, Campbell A, Smith A, Straker L. Greater lower limb flexion in gymnastic landings is associated with reduced landing force: a repeated measures study. *Sport Biomech.* 2015;14(1):45–56.
2. Cavanagh PR, LaFortune MA. Ground reaction forces in distance running. *J Biomech.* 1980;13(5):397–406.
3. Donoghue OA, Shimojo H, Takagi H. Impact Forces of Plyometric Exercises Performed on Land and in Water. 2011;3(3):303–9.
4. Eslami M, Gandomkar A, Hosseini nejad SE, Jahedi V, Gandomkar E. Comparison of the Effect of unstable and control Shoes on the Variables Related to Tibia Stress Fracture during Running in Recreational Runners. *J Res Rehabil Sci.* 2014;9(6). (Persian)
5. Pappas E, Sheikhzadeh A, Hagins M, Nordin M. The effect of gender and fatigue on the biomechanics of bilateral landings from a jump: Peak values. *J Sport Sci Med.* 2007;6(1):77–84.
6. Hedayat Pour N, Shabani M, Eslami M. The effect of muscle fatigue on ankle joint moment and center of pressure during perturbation of single-leg stance. *Razi J Med Sci.* 2013; 20 (106) :57-64. (Persian)
7. Bassiri Z, Eslami M, Ghaemy M, Hosseninejad SE, Rabiei M. The Effect of Shoe Outsole Containing Nanoclay Particles on Knee Joint Power during the Stance Phase of Running. *Ann Appl Sport Sci.* 2014;2(3):33–40.
8. Hoseini SZ, Eslami M. Effect of Five-Finger Shoes on Vertical Ground Reaction Force Loading Rates and Perceived Comfort during the Stance Phase of the Running. *J Sport Biomech.* 2015;37–47. (Persian)
9. Tazike Lamski Z, Eslami M, Habibi Tirtashi F. The Effect of Shoe Insole Stiffness on Leg Stiffness during Stance Phase of Running in Two Different Speeds among Active Men. *J Res Rehabil Sci.* 2016;12(1):34–41. (Persian)
10. Hoseinzadeh E, Eslami M, Taghipur M, Fayyaz-Movaghar A. The Role of Leg Stiffness in Prediction of Medial Tibial Stress Syndrome in Active People: A Prospective Cohort Study. *J Res Rehabil Sci.* 2017;13(5):286-95. (Persian)
11. Hatami Joushghan Z, Eslami M. The Effect of Fatigue on the Stiffness Changes in Legs, Ankle and Knee Joints in Lower Limb During a Thirty-Second Continuous Vertical Jump Test in Female Volleyball Players. *J Sport Biomech.* 2015;1(2):15–23. (Persian)
12. Eslami M, Begon M, Hinse S, Sadeghi H, Popov P, Allard P. Effect of foot orthoses on magnitude and timing of rearfoot and tibial motions, ground reaction force and knee moment during running. *J Sci Med Sport.* 2009;12(6):679–84.
13. Gandomkar A, Eslami M, Hosseini nejad SE, Jahedi V. Effect of unstable shoes on lower extremity joint power during stance phase of running. *Razi J Med Sci.* 2014;21(124):44-43. (Persian)
14. Boroushak N, Eslami M, Khoshnoodi H. A Review on the Impact Skills Analysis Using two Physical Principles; Impulse- Momentum and Work- Energy in Martial Arts. *J Sport Biomech.* 2017;3(3):57-67.
15. Eslami M, Hoseininejad E, Fayyaz A, Sadeghi H. Do minimal shoes imitate barefoot running? Lower limbs mechanical energy using component analysis. *J Appl Exerc Physiol.* 2017;87–96. (Persian)
16. Eslami M, Hoseninejad SE, Salari Esker F, Yousefpour R, Fayyaz Movaghar A, Sadeghi H. Determination of functional groups in different levels in running gait; lower limb mechanical energy analysis. In: 35th Conference of the International Society of Biomechanics in Sports, Cologne, Germany. 2017. P. 378–9.
17. Jiang X, Napier C, Hannigan B, Eng JJ, Menon C. Estimating Vertical Ground Reaction Force during Walking Using a Single Inertial Sensor. *Sensors.* 2020;20(15):4345.

18. Ancillao A. Stereophotogrammetry in Functional Evaluation: History and Modern Protocols. In 2018. p. 1–29.
19. Veltink PH, Liedtke C, Droog E, van der Kooij H. Ambulatory measurement of ground reaction forces. *IEEE Trans Neural Syst Rehabil Eng*. 2005;13(3):423–7.
20. Owings TM, Grabiner MD. Measuring step kinematic variability on an instrumented treadmill: how many steps are enough? *J Biomech*. 2003;36(8):1215–8.
21. van der Krogt MM, Sloot LH, Harlaar J. Overground versus self-paced treadmill walking in a virtual environment in children with cerebral palsy. *Gait Posture*. 2014;40(4):587–93.
22. Davis BL, Perry JE, Neth DC, Waters KC. A Device for Simultaneous Measurement of Pressure and Shear Force Distribution on the Plantar Surface of the Foot. *J Appl Biomech*. 1998 ;14(1):93–104.
23. Razian MA, Pepper MG. Design, development, and characteristics of an in-shoe triaxial pressure measurement transducer utilizing a single element of piezoelectric copolymer film. *IEEE Trans Neural Syst Rehabil Eng*. 2003;11(3):288–93.
24. Abdul Razak AH, Zayegh A, Begg RK, Wahab Y. Foot Plantar Pressure Measurement System: A Review. *Sensors*. 2012;12:9884–9912.
25. Fong DT-P, Chan Y-Y, Hong Y, Yung PS-H, Fung K-Y, Chan K-M. Estimating the complete ground reaction forces with pressure insoles in walking. *J Biomech*. 2008;41(11):2597–601.
26. Wundersitz DWT, Netto KJ, Aisbett B, Gastin PB. Validity of an upper-body-mounted accelerometer to measure peak vertical and resultant force during running and change-of-direction tasks. *Sport Biomech*. 2013;12(4):403–12.
27. Nigg BM, Liu W. The effect of muscle stiffness and damping on simulated impact force peaks during running. *J Biomech*. 1999;32(8):849–56.
28. Young WB, Hepner J, Robbins DW. Movement Demands in Australian Rules Football as Indicators of Muscle Damage. *J Strength Cond Res*. 2012;26(2):492–6.
29. Bobbert MF, Schamhardt HC, Nigg BM. Calculation of vertical ground reaction force estimates during running from positional data. *J Biomech*. 1991 Jan;24(12):1095–105.
30. Clark KP, Weyand PG. Are running speeds maximized with simple-spring stance mechanics? *J Appl Physiol*. 2014;117(6):604–15.
31. Clark KP, Ryan LJ, Weyand PG. A general relationship links gait mechanics and running ground reaction forces. *J Exp Biol*. 2017; 220(2):247–58.
32. Raper DP, Witchalls J, Philips EJ, Knight E, Drew MK, Waddington G. Use of a tibial accelerometer to measure ground reaction force in running: A reliability and validity comparison with force plates. *J Sci Med Sport*. 2018;21(1):84–8.
33. Oosterwaal M, Telfer S, Tørholm S, Carbes S, van Rhijn LW, Macduff R, et al. Generation of subject-specific, dynamic, multisegment ankle and foot models to improve orthotic design: a feasibility study. *BMC Musculoskelet Disord*. 2011;12(1):256.
34. Vanheule V, Andersen MS, Wirix-Speetjens R, Jonkers I, Victor J, Sloten J Vanden. Aalborg Universitet Modeling of patient-specific knee kinematics and ligament behavior using force- dependent kinematics. In: XXIV Congress of the International Society of Biomechanics. 2013.
35. de Vries WHK, Veeger HEJ, Baten CTM, van der Helm FCT. Magnetic distortion in motion labs, implications for validating inertial magnetic sensors. *Gait Posture*. 2009;29(4):535–41.
36. Leardini A, Chiari L, Croce U Della, Cappozzo A. Human movement analysis using stereophotogrammetry. *Gait Posture*. 2005;21(2):212–25.
37. Alexander EJ, Andriacchi TP. Correcting for deformation in skin-based marker systems. *J Biomech* . 2001 Mar;34(3):355–61.
38. Neugebauer JM, Hawkins DA, Beckett L. Estimating Youth Locomotion Ground Reaction Forces Using an Accelerometer-Based Activity Monitor. Garatachea N, editor. *PLoS One*. 2012;7(10):e48182.
39. Fox J, Weisberg S. Mixed-effects models in R. *An R Companion to Applied Regression*; SAGE: Thousand Oaks, CA, USA. 2002.

40. Neugebauer JM, Collins KH, Hawkins DA. Ground Reaction Force Estimates from ActiGraph GT3X+ Hip Accelerations. Hug F, editor. PLoS One. 2014;9(6):e99023.
41. Thiel D V., Shepherd J, Espinosa HG, Kenny M, Fischer K, Worsey M, et al. Predicting Ground Reaction Forces in Sprint Running Using a Shank Mounted Inertial Measurement Unit. In: The 12th Conference of the International Sports Engineering Association. Basel Switzerland: MDPI; 2018. p. 199.
42. White JD, Carson N, Baum BS, Reinking MF, McPoil TG. Use of 2-dimensional sagittal kinematic variables to estimate ground reaction force during running. *Int J Sports Phys Ther.* 2019;14(2):174–9.
43. Wouda FJ, Giuberti M, Bellusci G, Maartens E, Reenalda J, van Beijnum B-JF, et al. Estimation of Vertical Ground Reaction Forces and Sagittal Knee Kinematics During Running Using Three Inertial Sensors. *Front Physiol.* 2018;9:218.
44. Ren L, Jones RK, Howard D. Whole body inverse dynamics over a complete gait cycle based only on measured kinematics. *J Biomech.* 2008;41(12):2750–9.
45. Johnson WR, Mian A, Donnelly CJ, Lloyd D, Alderson J. Predicting athlete ground reaction forces and moments from motion capture. *Med Biol Eng Comput.* 2018;56(10):1781–92.
46. De Bie T, Cristianini N, Rosipal R. Eigenproblems in Pattern Recognition. *Handb Geom Comput.* 2005;129–67.
47. Komaris D-S, Perez-Valero E, Jordan L, Barton J, Hennessy L, O’Flynn B, et al. Predicting Three-Dimensional Ground Reaction Forces in Running by Using Artificial Neural Networks and Lower Body Kinematics. *IEEE Access.* 2019;7:156779–86.
48. O’Reilly M, Caulfield B, Ward T, Johnston W, Doherty C. Wearable Inertial Sensor Systems for Lower Limb Exercise Detection and Evaluation: A Systematic Review. *Sport Med.* 2018;48(5):1221–46.
49. Davidson P, Virekunnas H, Sharma D, Piché R, Cronin N. Continuous Analysis of Running Mechanics by Means of an Integrated INS/GPS Device. *Sensors.* 2019;19(6):1480.
50. Pogson M, Verheul J, Robinson MA, Vanrenterghem J, Lisboa P. A neural network method to predict task- and step-specific ground reaction force magnitudes from trunk accelerations during running activities. *Med Eng Phys.* 2020;78:82–9.
51. Akenhead R, Nassis GP. Training Load and Player Monitoring in High-Level Football: Current Practice and Perceptions. *Int J Sports Physiol Perform.* 2016;11(5):587–93.
52. Girka A, Kulmala J, Äyrämö S. Deep learning approach for prediction of impact peak appearance at ground reaction force signal of running activity. *Comput Methods Biomech Biomed Engin.* 2020;23(14):1052–9.
53. Tedesco S, Perez-Valero E, Komaris D, Jordan L, Barton J, Hennessy L, et al. Wearable motion sensors and artificial neural network for the estimation of vertical ground reaction forces in running. In: 2020 IEEE SENSORS. IEEE; 2020. p. 1–4.
54. Johnson WR, Mian A, Robinson MA, Verheul J, Lloyd DG, Alderson JA. Multidimensional Ground Reaction Forces and Moments From Wearable Sensor Accelerations via Deep Learning. *IEEE Trans Biomed Eng.* 2021;68(1):289–97.
55. Sharma D, Davidson P, Müller P, Piché R. Indirect Estimation of Vertical Ground Reaction Force from a Body-Mounted INS/GPS Using Machine Learning. *Sensors.* 2021;21(4):1553.