

IMU-based Estimation of the Knee Contact Force using Artificial Neural Networks

Rezaie Zangene, Alireza ¹ / Abedi Azar, Ramila ² / Naserpour, Hamidreza ^{3*} / Hosseini Nasab, Seyyed Hamed ⁴

¹ - M.Sc. Department of Biomechanics and Sports Injuries, Faculty of Physical Education and Sport Sciences, Kharazmi University, Tehran, Iran / National Brain Mapping Laboratory, Tehran, Iran

² - Ph.D. Student, Department of Biomedical Engineering, Amirkabir University of Technology, Tehran, Iran

³ - Instructor, Department of Biomechanics and Sports Injuries, Faculty of Physical Education and Sport Sciences, Kharazmi University, Tehran, Iran

⁴ - Researcher, Laboratory for Movement Biomechanics, ETH Zürich, Zürich, Switzerland

ARTICLE INFO

DOI: 10.22041/ijbme.2023.1998736.1834

Received: 19 March 2023

Revised: 21 June 2023

Accepted: 30 July 2023

KEYWORDS

Inertial Measurement Unit
Knee Contact Force
Knee Osteoarthritis
Continuous Estimation
Artificial Neural Networks
Musculoskeletal Modeling
OpenSim

ABSTRACT

Knee joint contact force (KCF) plays a significant role in the occurrence and progression of knee osteoarthritis (KOA) disease. KCF can be used in monitoring rehabilitation progress after knee arthroplasty surgery and the design of prostheses. Currently, measuring KCF is dependent on the data extracted from gait laboratories. The combination of artificial neural networks (ANNs) and wearable technology can overcome the limitations imposed by lab-based analysis in measuring KCF. Therefore, the present study aimed to investigate the potential of a fully-connected neural network (FCNN) in predicting the KCF via three inertial measurement unit (IMU) sensors attached to the pelvis, thigh, and shank segments. Ten healthy male volunteers participated in this study. The 3D marker trajectories and ground reaction forces (GRF) were captured at 200 Hz and 1000 Hz sampling frequencies during level-ground walking. Using a generic OpenSim model, the KCF was estimated through static optimization. The resultant KCF estimated by the musculoskeletal model was then used as the target of the neural network, while linear acceleration and 3D angular velocity data captured by three IMUs were considered as the network inputs. The network performance was investigated at intra- and inter-subject levels. Based on our findings, the proposed network of this study enables the prediction of KCF with 89% and 79% accuracy (based on the Pearson correlation coefficient) at the intra- and inter-subject levels, respectively. The results of this study promise the possibility of using IMU sensors in predicting KCF outside the lab and during daily activities.

*Corresponding Author

Address	Department of Biomechanics and Sports Injuries, Faculty of Physical Education and Sport Sciences, Kharazmi University, Tehran, Iran		
Postal Code	15447-33111	Tel	+98-21-22228001
E-Mail	std_hamidreza.naserpour@khu.ac.ir	Fax	+98-21-22269547





برآورد نیروی تماسی زانو مبتنی بر واحد اندازه‌گیری اینرسی با استفاده از شبکه‌های عصبی مصنوعی

رضائی زنگنه، علیرضا^۱ / عابدی آذر، رامیلا^۲ / ناصرپور، حمیدرضا^{۳*} / حسینی‌نسب، سیدحامد^۴

^۱ - کارشناسی ارشد، گروه بیومکانیک و آسیب‌شناسی ورزشی، دانشکده‌ی تربیت بدنی و علوم ورزشی، دانشگاه خوارزمی، تهران، ایران / آزمایشگاه ملی نقشه‌برداری مغز ایران، تهران، ایران

^۲ - دانشجوی دکتری، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۳ - مربی، گروه بیومکانیک و آسیب‌شناسی ورزشی، دانشکده‌ی تربیت بدنی و علوم ورزشی، دانشگاه خوارزمی، تهران، ایران

^۴ - پژوهشگر، آزمایشگاه بیومکانیک حرکت، موسسه‌ی فناوری فدرال زوریخ، زوریخ، سوئیس

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2023.1998736.1834

پذیرش: ۸ مرداد ۱۴۰۲

بازنگری: ۳۱ خرداد ۱۴۰۲

ثبت در سامانه: ۲۸ اسفند ۱۴۰۱

واژه‌های کلیدی

واحد اندازه‌گیری اینرسی

نیروی تماسی زانو

آرتروز مفصل زانو

برآورد پیوسته

شبکه‌های عصبی مصنوعی

مدل سازی اسکلتی-عضلانی

اپن‌سیم

چکیده

نیروی تماسی مفصل زانو نقش مهمی در بروز و پیش‌رفت بیماری استئوآرتریت زانو دارد که از آن به عنوان معیاری برای رصد فرایند توان‌بخشی پس از جراحی آرتروپلاستی زانو و طراحی پروتز استفاده می‌شود. در حال حاضر سنجش نیروی تماسی زانو مبتنی بر داده‌های استخراج شده از آزمایشگاه‌های تجزیه و تحلیل حرکت است. استفاده از ترکیبی از شبکه‌های عصبی مصنوعی و فناوری حس‌گرهای پوشیدنی می‌تواند به رفع محدودیت‌های تحمیل شده در اندازه‌گیری نیروی تماسی مفصل توسط تجزیه و تحلیل‌های آزمایشگاهی غلبه کند. بنابراین مطالعه‌ی حاضر با هدف بررسی پتانسیل یک شبکه‌ی عصبی تماماً متصل در برآورد پیوسته‌ی نیروی تماسی مفصل زانو از طریق داده‌های مستخرج از سه واحد اندازه‌گیری اینرسی متصل به سگمنت‌های لگن، ران و ساق صورت گرفته است. نیروهای عکس‌العمل زمین و داده‌های سه‌بعدی مارکرهای متصل به ۱۰ داوطلب مرد سالم حین راه رفتن به ترتیب با نرخ نمونه‌برداری ۱۰۰۰ و ۲۰۰ هرتز ثبت شده است. با استفاده از یک مدل عمومی از نرم‌افزار اپن‌سیم و از طریق روش بهینه‌سازی استاتیکی، نیروی تماسی مفصل زانو برآورد شده و به عنوان سیگنال هدف شبکه‌ی عصبی در نظر گرفته شده است. هم‌چنین داده‌های سه‌بعدی شتاب خطی و سرعت زاویه‌ای محاسبه شده توسط سه حس‌گر اینرسیایی به عنوان ویژگی‌های ورودی شبکه‌ی عصبی در نظر گرفته شده و عمل‌کرد شبکه در دو سطح درون و میان آزمودنی مورد بررسی و ارزیابی قرار گرفته است. نتایج نشان داده که شبکه‌ی عصبی مورد استفاده در این پژوهش پیش‌بینی پیوسته‌ی نیروی تماسی مفصل زانو را به ترتیب با دقت ۸۹٪ و ۷۹٪ در سطوح درون و میان آزمودنی انجام داده است. نتایج این پژوهش نوید دهنده‌ی امکان به کارگیری حس‌گرهای اینرسیایی در پیش‌بینی پیوسته‌ی نیروی تماسی مفصل زانو حین زندگی روزمره و فعالیت‌های ورزشی بدون نیاز به تجهیزات گران‌قیمت آزمایشگاهی و دانش تخصصی است.

*نویسنده‌ی مسئول

نشانی گروه بیومکانیک و آسیب‌شناسی ورزشی، دانشکده‌ی تربیت بدنی و علوم ورزشی، دانشگاه خوارزمی، تهران، ایران

کد پستی ۱۵۴۴۷-۳۳۱۱۱ تلفن +۹۸-۲۱-۲۲۲۲۲۸۰۰۱

پست الکترونیک std_hamidreza.nasarpour@khu.ac.ir داورنگار +۹۸-۲۱-۲۲۲۶۹۵۴۷



۱- مقدمه

با وجود این که مدل‌سازی اسکلتی-عضلانی یک ابزار انعطاف‌پذیر بوده که تخمین غیرتهاجمی KCF را ممکن می‌سازد، تجزیه و تحلیل‌های زمان‌بر آن مستلزم دانش تخصصی می‌باشد که کاربرد گسترده‌ی آن در حوزه‌ی بیومکانیک محاسباتی را با محدودیت مواجه کرده است. از این رو برآورد پیوسته و مستمر KCF با استفاده از شبکه‌های عصبی مصنوعی^{۱۲} (ANN) اخیراً مورد توجه پژوهش‌گران حوزه‌ی تجزیه و تحلیل حرکت قرار گرفته است.

در مطالعات پیشین از ANN برای برآورد پیوسته‌ی سری‌های زمانی بیومکانیکی مانند زوایا و گشتاورهای مفصلی استفاده شده است [۱۹-۲۱]. با این حال مطالعات محدودی با هدف برآورد پیوسته‌ی سیگنال KCF از طریق ANN صورت گرفته است. از میان این مطالعات، در مقاله‌ی اردستانی و هم‌کارانش از یک شبکه‌ی عصبی تماماً متصل^{۱۳} (FCNN) برای پیش‌بینی KCF حین راه رفتن به دو شیوه‌ی اصلاح یافته‌ی نوسان تنه^{۱۴} و رانش داخلی^{۱۵} استفاده شده است [۲۲]. در این پژوهش از خط سیر^{۱۶} مارک‌های انعکاسی^{۱۷}، سیگنال‌های الکترومایوگرافی سطحی^{۱۸} (sEMG) و نیروهای عکس‌العمل زمین^{۱۹} (GRF) به عنوان ویژگی‌های پیش‌بین شبکه استفاده شده و نشان داده شده که شبکه‌ی پیشنهادی قادر است KCF قسمت داخلی زانو^{۲۰} را در طول راه رفتن به شیوه‌های رانش داخلی و نوسان تنه با دقت قابل قبولی با حدود ۱۳ درصد خطای تخمین بر اساس خطای ریشه‌ی میانگین مربع نرمال شده^{۲۱} (NRMSE) تخمین بزند. رویکرد مشابهی نیز توسط گیارماتزیس و هم‌کارانش برای تخمین KCF قسمت‌های داخلی و جانبی زانو در طول راه رفتن روی تردمیل در پنج سرعت مختلف (۳ تا ۷ کیلومتر در ساعت) مورد استفاده قرار گرفته است [۲۳]. در پژوهش آن‌ها کینماتیک^{۲۲} زاویه‌ای اندام تحتانی، لگن و تنه همراه با GRF به عنوان ورودی شبکه‌ی عصبی پیشنهادی در نظر گرفته شده و گزارش شده که FCNN از الگوریتم رگرسیون بردار پشتیبان^{۲۳} در برآورد پیوسته‌ی سیگنال هدف بهتر عمل

مفصل زانو یکی از آسیب‌پذیرترین نقاط ورزش‌کاران رشته‌های تیمی و انفرادی با رویکرد تغییر مسیرهای مداوم، پرش و فرود مکرر است [۱-۳]. مفصل زانو همواره در معرض نیروهای چند جهته بوده [۴] و از این رو در معرض آسیب‌های متعددی از جمله استئوآرتریت^۱ [۵]، پارگی رباط صلیبی قدامی^۲ و سندروم درد کشکی رانی^۳ [۶] قرار دارد. بنا بر تحقیقات صورت گرفته، بیش از ۱۹ درصد از بزرگسالان آمریکایی بالای ۴۵ سال به استئوآرتریت زانو^۴ (KOA) مبتلا هستند [۷] و شیوع KOA از اواسط قرن بیستم دو برابر شده است [۸]. این بیماری علاوه بر هزینه‌های بالای درمانی و اقتصادی موجب درد، ناتوانی و کاهش کیفیت زندگی فرد نیز می‌شود [۹]. در این بیماری، غضروف‌های مفصلی در طول بارگذاری مداوم تخریب شده و افزایش نیروهای مفصلی نهایتاً منجر به بروز علائم مختلفی از جمله درد، سفتی مفصلی، تورم و محدودیت‌های حرکتی می‌شود. با توجه به تاثیر نیروی تماسی زانو^۵ (KCF) در بروز KOA [۱۰]، اندازه‌گیری KCF برای ارزیابی KOA [۱۱]، بررسی روند توان‌بخشی [۱۲] و طراحی پروتزهای^۶ مفصل زانو از اهمیت بالایی برخوردار است [۱۳].

در حالت ایده‌آل، KCF را می‌توان از طریق ایمپلنت‌های^۷ مفصلی مجهز به حس‌گرهای نیروسنج اندازه‌گیری کرد [۱۴]، اما داده‌های به دست آمده صرفاً محدود به گروه‌های کوچکی از افراد بوده که تحت جراحی تعویض مفصل زانو قرار گرفته‌اند. یک رویکرد جایگزین، تخمین KCF از طریق مدل‌سازی اسکلتی-عضلانی در محیط‌های شبیه‌سازی مختلف مانند این‌سیم^۸ [۱۶] و انی‌بادی^۹ [۱۷] است. اخیراً کورلی و هم‌کارانش (۲۰۲۱) در پژوهشی با استفاده از سه مدل مختلف اسکلتی-عضلانی، KCF را حین راه رفتن برآورد کرده‌اند که نتایج آن‌ها تطابق بالایی با نیروهای مستخرج از ایمپلنت‌های زانوی مجهز به حس‌گرهای نیروسنج داشته است (ضریب تعیین^{۱۰} برای مدل راجاگوپال^{۱۱} برابر با ۰/۸۰ بوده است) [۱۸].

^{۱۲} Fully-Connected Neural Network

^{۱۳} Trunk Sway

^{۱۴} Medial Thrust

^{۱۵} Trajectory

^{۱۶} Reflective Marker

^{۱۷} Surface Electromyography

^{۱۸} Ground Reaction Forces

^{۱۹} Compartment

^{۲۰} Normalized Root Mean Squared Error

^{۲۱} Kinematics

^{۲۲} Support Vector Regression

^۱ Osteoarthritis

^۲ Anterior Cruciate Ligament Rupture

^۳ Patellofemoral Pain Syndrome

^۴ Knee Osteoarthritis

^۵ Knee Contact Force

^۶ Prosthesis

^۷ Implant

^۸ Opensim

^۹ Anybody

^{۱۰} Coefficient of Determination

^{۱۱} Rajagopal Model

^{۱۲} Artificial Neural Network



۲- مواد و روش‌ها

۲-۱- ملاحظات اخلاقی

در مطالعه‌ی نیمه‌تجربی حاضر تمام مراحل پژوهش برای همه‌ی آزمودنی‌ها تشریح شده و پیش از شروع آزمون، رضایت‌نامه‌ی کتبی شرکت در تحقیق توسط آن‌ها مطالعه و امضا شده است. مطالعه‌ی حاضر مطابق با اعلامیه‌ی اخلاق هلسینکی^۹ ۲۰۱۳ بوده و کلیات آن توسط کمیته‌ی ملی اخلاق در مطالعات زیست پزشکی در تاریخ ۱۴۰۱/۴/۸ تایید و با شماره‌ی ارجاع SSRI.REC-2206-1733 ثبت شده است.

۲-۲- آزمودنی‌ها و گردآوری داده

ده مرد سالم بدون سابقه‌ی آسیب اندام تحتانی با سن $24/5 \pm 5/3$ سال، وزن $90/8 \pm 13/4$ کیلوگرم و قد $180/6 \pm 5/5$ سانتی‌متر به صورت داوطلبانه در این مطالعه شرکت کرده‌اند. جهت اندازه‌گیری پارامترهای کینماتیک سه‌بعدی (فرکانس ۲۰۰ هرتز) از ده دوربین شرکت وایکان^{۱۰} ساخت کشور انگلستان و برای بررسی متغیرهای کینتیکی حین حرکت (فرکانس ۱۰۰۰ هرتز) از دو صفحه‌ی نیرو با مارک تجاری کیستلر^{۱۱} با ابعاد 50×60 سانتی‌متر ساخت کشور سوئیس استفاده شده است. نحوه‌ی مارکرگذاری در این پژوهش مبتنی بر روش خوشه‌ای^{۱۲} بوده که برای بررسی و ره‌گیری حرکات تنه، لگن و اندام تحتانی مناسب است [۲۷]. در این مطالعه از سه ماژول IMU با برند BSN ساخت ایران (ژیروسکوپ $2000 \pm$ درجه بر ثانیه، شتاب‌سنج $16 \pm$ g و مغناطیس‌سنج $4800 \pm$ uT) با نرخ نمونه‌برداری ۱۶۰ هرتز استفاده شده که دو ماژول در زیر کلاسترهای سگمنت‌های ران و ساق پا و یک ماژول با دقت در میان دو مارکر خار خارصه‌ای فوقانی خلفی راست و چپ^{۱۳} (RPSI و LPSI) قرار داده شده است (شکل ۱).

۲-۳- مدل‌سازی اسکلتی-عضلانی

داده‌های مربوط به مارکرها و GRF به ترتیب با استفاده از یک فیلتر پایین‌گذر ۶ و ۳۰ هرتز (باترورت فاز صفر مرتبه‌ی چهارم) فیلتر شده است [۲۸]. جهت تعیین لحظه‌ی برخورد و ترک پا از زمین از مولفه‌ی عمودی نیروی عکس‌العمل زمین استفاده شده و آستانه‌ی آن برابر با ۲۰ نیوتن در نظر گرفته شده است

کرده است. در مطالعه‌ی برتون دوم و هم‌کارانش نیروهای تماسی مربوط به مفاصل ران و زانو از طریق چهار مدل یادگیری ماشین^۱ (سه نوع ANN و یک مدل رگرسیون خطی) با استفاده از پارامترهای پیش‌بین آنترپومتریکی^۲، GRF و زوایای مفصلی حین راه رفتن با ضریب همبستگی بین ۰/۹۳ تا ۰/۹۴ که نشان گر قابلیت اطمینان بوده تخمین زده شده است [۲۴].

پیش‌بینی‌های صورت گرفته در مطالعات پیشین کاملاً بر اساس داده‌های جمع‌آوری شده در محیط آزمایشگاهی بوده است. استخراج داده‌های کینماتیکی و کینتیکی^۳ از طریق آزمایشگاه‌های بیومکانیکی مجهز به دوربین‌های ثبت حرکت^۴ و صفحه‌ی نیرو^۵ یکی از روش‌های متداول بوده که با محدودیت‌هایی از جمله فضای آزمایشگاهی محدود، تجهیزات بسیار گران‌قیمت و فرایند زمان‌بر مواجه است [۲۵]. بنابراین استفاده از داده‌های حاصل از فناوری پوشیدنی^۶ برای پیش‌بینی KCF ممکن است یک روش امیدوار کننده برای برطرف ساختن محدودیت‌های تجزیه و تحلیل‌های آزمایشگاهی باشد.

حس‌گرهای پوشیدنی مانند حس‌گرهای واحد اندازه‌گیری اینرسی^۷ (IMU) ارزان‌قیمت، قابل حمل و سبک هستند. بنابراین آن‌ها با موفقیت در کنترل ربات‌های آگرواسکلتون^۸ و سایر فناوری‌های کمکی [۲۶] و همچنین تخمین زوایا و گشتاورهای مفصلی انسان مورد استفاده قرار گرفته‌اند [۲۰، ۲۱]. هدف اصلی این مطالعه برآورد میان آزمودنی KCF محوری با استفاده از یک FCNN بر اساس سیگنال به دست آمده از سه حس‌گر IMU است. یافته‌های مطالعه‌ی حاضر می‌تواند به توسعه‌ی یک سیستم ارزیابی میدانی قابل حمل برای کمی‌سازی و رصد مستمر سیگنال KCF در طول زندگی روزمره یا فعالیت‌های ورزشی کمک کند.

مشارکت‌های این مطالعه در حوزه‌ی بیومکانیک محاسباتی که در ادبیات گذشته مورد توجه نبوده به شرح زیر است.

۱- برآورد مستمر KCF محوری در طول راه رفتن با استفاده از داده‌های سه حس‌گر IMU متصل به آزمودنی‌ها از طریق یک شبکه‌ی عصبی مصنوعی تماماً متصل

۲- بررسی عمل‌کرد شبکه در دو سطح درون و میان آزمودنی با هدف ارزیابی تعمیم‌پذیری شبکه در حضور تفاوت‌های منحصر به فرد هر آزمودنی

^۸ Exoskeleton

^۹ Helsinki

^{۱۰} 6×IR Cameras: MX T40-S VICON and 4× IR Vero v2.2

^{۱۱} KISTLER-9260AA6

^{۱۲} Cluster Marker Placement

^{۱۳} Right and Left Posterior Superior Iliac Spine

^۱ Machine Learning

^۲ Anthropometric

^۳ Kinetics


^۴ Motion Capture

^۵ Force Plate


^۶ Wearable Technology

^۷ Inertial Measurement Unit

پس از فرایند سنکرون‌سازی، سیگنال‌های KCF محاسبه شده از طریق اپن‌سیم (هدف شبکه‌ی عصبی) و سیگنال‌های مستخرج از حس‌گرهای IMU (ویژگی‌های پیش‌بین شبکه‌ی عصبی) با استفاده از روش اسپلاین^۸ به ۱۰۱ نمونه مجدداً نمونه‌برداری شده است [۲۸]. یک تابع اسپلاین از تعدادی چندجمله‌ای تشکیل شده است که در حوزه‌ی بیومکانیک به صورت گسترده به منظور نرمال‌سازی زمانی از طریق درون‌یابی مورد استفاده قرار می‌گیرد.



شکل (۱) - محل قرارگیری سه IMU در الف) ساق، ب) ران و ج) ساکرال، د) IMU مورد استفاده در این پژوهش



شکل (۲) - مدل اسکلتی-عضلانی مربوط به نرم‌افزار اپن‌سیم و بارگذاری و گشتاورهای مفصل زانو از نمای قدامی، در این شکل F_{total} (بردار قرمز) نمایان‌گر KCF فشاری مستخرج از مدل‌سازی اسکلتی-عضلانی نرم‌افزار اپن‌سیم است

[۲۹]. داده‌ها از سیستم مختصات آزمایشگاهی به سیستم مختصات نرم‌افزار اپن‌سیم منتقل شده است. در مطالعه‌ی حاضر از یک مدل عمومی اپن‌سیم (gait 2392) برای انجام مدل‌سازی اسکلتی-عضلانی استفاده شده است [۳۰] (شکل ۲). این مدل برای منطبق شدن با آنتروپومتری آزمودنی‌ها بر اساس موقعیت مارکرها در وضعیت استاتیک^۱ مقیاس‌بندی شده است. سپس مختصات مفاصل با استفاده از ابزار کینماتیک معکوس^۲ اپن‌سیم محاسبه شده است. علاوه بر این گشتاورهای مفصلی با استفاده از ابزار استاندارد دینامیک معکوس^۳ ارائه شده در نرم‌افزار محاسبه شده است. در مرحله‌ی بعد نیروهای عضلانی با استفاده از روش بهینه‌سازی استاتیکی برآورد شده است [۳۱]. این روش مبتنی بر الگوریتم‌های بهینه‌سازی گرادیان نزولی بوده که از طریق محاسبه‌ی گرادیان تابع هزینه، مقدار کمینه‌ی تابع را شناسایی می‌کند. نهایتاً ابزار تجزیه و تحلیل نیروی عکس‌العمل مفصلی اپن‌سیم برای محاسبه‌ی نیروی تیبیو-فمورال^۴ در طول چرخه‌ی راه رفتن مورد استفاده قرار گرفته است. در این مطالعه صرفاً نیروی تماسی برآیند مفصلی از طریق نرم‌افزار اپن‌سیم محاسبه شده است. لذا برای محاسبه‌ی نیروهای تماسی قسمت داخلی و خارجی مفصل زانو می‌توان از مدل‌های دیگر بهره گرفت (شکل‌های ۲ و ۳).

۲-۴- سنکرون‌سازی سیگنال‌ها

داده‌های شتاب خطی و سرعت زاویه‌ای به دست آمده از هر سه ماژول IMU با استفاده از فیلتر پایین‌گذر ۶ هرتز (باترورت فاز صفر مرتبه‌ی چهارم) فیلتر شده است [۲۸]. سپس از روش همبستگی متقاطع^۵ (CC) [۲۱] برای سنکرون‌سازی^۶ سیگنال‌های IMU و داده‌های مربوط به سیستم ثبت حرکت استفاده شده است. ابتدا با استفاده از نرم‌افزار Visual3D یک مارکر مجازی بین مارکرهای RPSI و LPSI ایجاد شده که موقعیت این مارکر مجازی تقریباً نشان دهنده‌ی محل ماژولی بوده که روی ساکرال^۷ قرار گرفته است. این مارکر مجازی این امکان را فراهم می‌کند تا از داده‌های مربوط به شتاب آن برای سنکرون‌سازی ماژول‌های IMU و سیستم ثبت حرکت استفاده شود. به این منظور تاخیری که بر حسب آن همبستگی میان شتاب خطی ماژول قرار گرفته روی ساکرال و شتاب خطی مارکر مجازی بیشینه می‌شود محاسبه شده و از طریق این تاخیر دو سیگنال سنکرون شده است [۲۱].

^۵ Cross-Correlation

^۶ Synchronization

^۷ Sacral

^۸ Spline Method

^۱ Static

^۲ Inverse Kinematics

^۳ Inverse Dynamic

^۴ Tibio-Femoral Force



مشکل از ۴۵ نورون استفاده شده است. تابع میانگین مربعات خطا^۱ (MSE) تابع هزینه‌ی شبکه‌ی تماماً متصل در نظر گرفته شده و با الگوریتم بهینه‌سازی آدم^۲ کمینه شده است. یک لایه‌ی ریزش^۳ (با نرخ ریزش ۲۰ درصد) در معماری شبکه در هر دو سطح در نظر گرفته شده است تا از بیش‌برازش^۴ جلوگیری شود. تنظیم فرآپارامترهای^۵ این شبکه از طریق جست‌وجوی شبکه‌ای^۶ صورت گرفته است [۳۲].

۳- یافته‌ها

مطابق شکل (۳) الگوی KCF تخمین زده شده توسط مدل اسکلتی-عضلانی، دو قله‌ی مجزا را در ۱۵ تا ۳۵ درصد و ۶۵ تا ۸۵ درصد مرحله‌ی سکون راه رفتن نشان می‌دهد که به خوبی با الگوهای نیروی *in vivo* گزارش شده در مجموعه‌ی داده‌های CAMS-Knee مطابقت دارد (به منظور دستیابی به درکی عمیق از بیومکانیک مفصل زانو، در پروژه‌ی CAMS-Knee مجموعه‌ای از داده‌های بیومکانیکی از جمله کینماتیک کل بدن، نیروی عکس‌العمل زمین و بارگذاری مفصلی محاسبه شده از طریق ایمپلنت‌های مفصلی به صورت هم‌گام از چندین آزمودنی اندازه‌گیری شده و در اختیار محققان قرار داده شده است) [۳۳]. در ادامه میانگین بزرگی قله‌های اول و دوم به ترتیب معادل با ۲۴۹۱- و ۳۵۴۲- نیوتن به دست آمده که منطبق با مقادیر مربوطه در مجموعه‌ی داده‌های CAMS-Knee است (مقادیر معادل گزارش شده در CAMS-Knee برابر با ۲۷۴۷- برای قله‌ی اول و ۳۱۸۴- برای قله‌ی دوم است) [۳۳]. پیش‌بینی FCNN و سیگنال هدف (KCF) در سطوح درون و میان آزمودنی برای دو آزمودنی نمونه که به صورت تصادفی انتخاب شده در شکل‌های (۴) و (۵) نشان داده شده است. توجه به شکل (۴) الگوی کلی سیگنال هدف با انحرافی اندک (به جز ابتدا و انتهای سیگنال) و دقتی بالا پیش‌بینی شده است. با این حال در سطح دوم دقت کلی کاهش یافته، به خصوص در پیش‌بینی قله‌ی اول که با توجه به چالش برانگیز بودن پیش‌بینی در سطح دوم قابل انتظار است (شکل ۵).

بر اساس نتایج ارائه شده در جدول (۱) عمل‌کرد شبکه در سناریوی درون آزمودنی، همبستگی بالایی میان تخمین FCNN و سیگنال KCF هدف را نشان می‌دهد (۰/۹۵±۰/۰۵). برای آزمودنی شماره‌ی ۱ و ۰/۹۵±۰/۰۴ برای آزمودنی شماره‌ی ۲. با این حال در مقایسه با سطح درون آزمودنی، دقت

۲-۵- معیارهای دقت و پروتکل ارزیابی

به منظور بررسی تعمیم‌پذیری پیش‌بینی، عمل‌کرد شبکه‌ی پیشنهادی در دو سطح درون و میان آزمودنی مورد ارزیابی قرار گرفته است. در سطح اول (درون آزمودنی)، شبکه‌ی عصبی n بار مورد ارزیابی قرار گرفته است (n : تعداد تریال‌های هر آزمودنی). در هر مرحله شبکه‌ی عصبی توسط $n-1$ تریال آموزش داده شده و برای تریال باقی‌مانده مورد آزمایش قرار گرفته است. این شبکه ۱۰ بار (تعداد آزمودنی‌ها) در سطح دوم مورد ارزیابی قرار گرفته است. در هر مرحله شبکه با داده‌های ۹ نفر از ۱۰ شرکت‌کننده آموزش داده شده و روی نفر دهم آزمایش شده است. برای ارزیابی دقت پیش‌بینی‌ها از ریشه‌ی میانگین مربعات خطای نرمال شده (NRMSE) و ضریب همبستگی پیرسون (ρ) استفاده شده است (روابط ۱ و ۲).

$$NRMSE = \sqrt{\frac{\sum_{t=1}^N (\tilde{\theta}_t - \theta_t)^2}{N}} \times 100 \quad (1)$$

$$\rho = \frac{\frac{1}{N} \sum_{t=1}^N (\theta_t - \bar{\theta})(\tilde{\theta}_t - \bar{\tilde{\theta}})}{\sqrt{\frac{1}{N} \sum_{t=1}^N (\theta_t - \bar{\theta})^2} \sqrt{\frac{1}{N} \sum_{t=1}^N (\tilde{\theta}_t - \bar{\tilde{\theta}})^2}} \quad (2)$$

در این روابط $\tilde{\theta}_t$ خروجی شبکه در لحظه‌ی t ، θ_t نیروی تماسی واقعی زانو (محاسبه شده از طریق مدل‌سازی اسکلتی-عضلانی) در لحظه‌ی t ، N طول سری زمانی، $\bar{\theta}$ و $\bar{\tilde{\theta}}$ به ترتیب مقادیر میانگین برای سری‌های زمانی هدف و پیش‌بینی و θ_{max} و θ_{min} مقادیر بیشینه و کمینه‌ی سیگنال KCF حقیقی است.

۲-۶- شبکه‌ی عصبی تماماً متصل

در این مطالعه از یک FCNN برای تخمین KCF فشاری در طول راه رفتن بر اساس خروجی سه حس‌گر IMU استفاده شده است. ورودی این شبکه یک ماتریس متشکل از ۱۸ ستون به صورت $3 \times [\vec{\omega}_x, \vec{\omega}_y, \vec{\omega}_z, \vec{a}_x, \vec{a}_y, \vec{a}_z]$ بوده که در آن $\vec{\omega}_x, \vec{\omega}_y, \vec{\omega}_z$ و $\vec{a}_x, \vec{a}_y, \vec{a}_z$ به ترتیب سرعت‌های زاویه‌ای حول محورهای x, y و z و اجزای سه‌بعدی شتاب‌های خطی به دست آمده از حس‌گرهای IMU است. سیگنال هدف این شبکه بردار KCF بوده که با مدل‌سازی اسکلتی-عضلانی در این سیم محاسبه شده است. برای پیش‌بینی در سطح اول از یک لایه‌ی پنهان با ۱۵ نورون و برای پیش‌بینی در سطح دوم از یک لایه‌ی پنهان

^۱ Overfitting

^۲ Hyperparameters

^۳ Grid Search

^۱ Mean Squared Error Function

^۲ Adam

^۳ Dropout

نیروی تماسی مفصل زانو در کل چرخه‌ی راه رفتن در سطوح اول و دوم با میانگین خطای $۰/۱۵/۶ \pm ۴/۵$ و $۰/۲۴/۱ \pm ۴/۴$ است.


پیش‌بینی مدل در سطح دوم برای تمام افراد پایین‌تر است. به طور کلی شبکه‌ی عصبی پیشنهادی قادر به پیش‌بینی سیگنال

جدول (۱) - نتایج پیش‌بینی شبکه بر اساس شاخص‌های NRMSE و

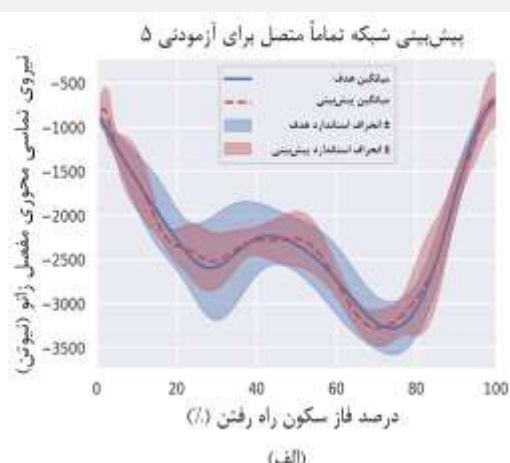
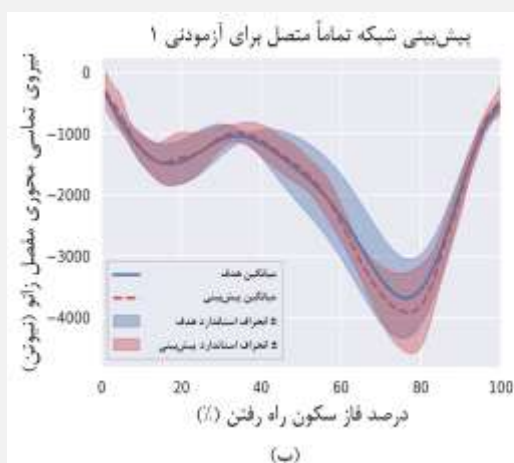
ρ برای ده آزمودنی در سناریوهای درون و میان آزمودنی

میان آزمودنی		درون آزمودنی		آزمودنی
ρ	NRMSE	ρ	NRMSE	
$۰/۸۱ \pm ۰/۰۵$	$۲۸/۱ \pm ۴/۱$	$۰/۹۵ \pm ۰/۰۵$	$۱۲/۷ \pm ۶/۷$	۱
$۰/۸۷ \pm ۰/۰۷$	$۳۲/۴ \pm ۱۲/۵$	$۰/۸۸ \pm ۰/۰۸$	$۱۷/۰ \pm ۸/۷$	۲
$۰/۷۶ \pm ۰/۰۱$	$۲۲/۲ \pm ۹/۲$	$۰/۹۳ \pm ۰/۰۴$	$۱۲/۷ \pm ۴/۵$	۳
$۰/۹۱ \pm ۰/۰۳$	$۲۲/۰ \pm ۱۰/۹$	$۰/۹۴ \pm ۰/۰۷$	$۱۳/۴ \pm ۴/۴$	۴
$۰/۸۷ \pm ۰/۰۱۲$	$۱۷/۶ \pm ۶/۱$	$۰/۸۶ \pm ۰/۰۱۴$	$۱۵/۴ \pm ۷/۶$	۵
$۰/۶۹ \pm ۰/۰۱۵$	$۲۹/۰ \pm ۶/۷$	$۰/۷۳ \pm ۰/۰۸$	$۲۶/۶ \pm ۷/۵$	۶
$۰/۷۳ \pm ۰/۰۱۲$	$۲۳/۷ \pm ۷/۴$	$۰/۹۵ \pm ۰/۰۴$	$۱۱/۴ \pm ۳/۴$	۷
$۰/۶۵ \pm ۰/۰۱$	$۲۳/۷ \pm ۵/۷$	$۰/۹۲ \pm ۰/۰۳$	$۱۶/۶ \pm ۵/۷$	۸
$۰/۷۸ \pm ۰/۰۰۸$	$۲۰/۴ \pm ۱۰/۱$	$۰/۹۲ \pm ۰/۰۶$	$۱۲/۱ \pm ۳/۴$	۹
$۰/۸۱ \pm ۰/۰۱$	$۲۲/۵ \pm ۵/۵$	$۰/۷۹ \pm ۰/۰۱۷$	$۱۸/۷ \pm ۷/۱$	۱۰
$۰/۷۹ \pm ۰/۰۰۸$	$۲۴/۱ \pm ۴/۴$	$۰/۸۹ \pm ۰/۰۰۷$	$۱۵/۶ \pm ۴/۵$	میانگین

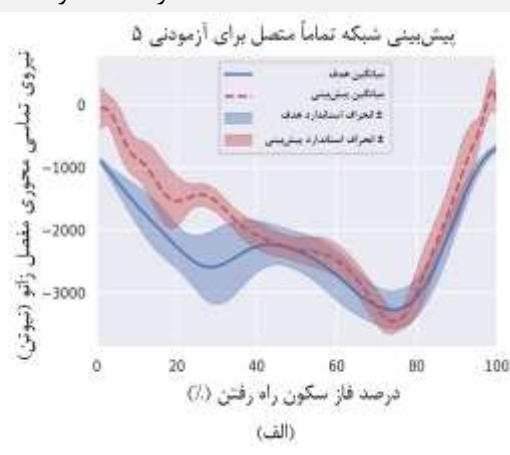
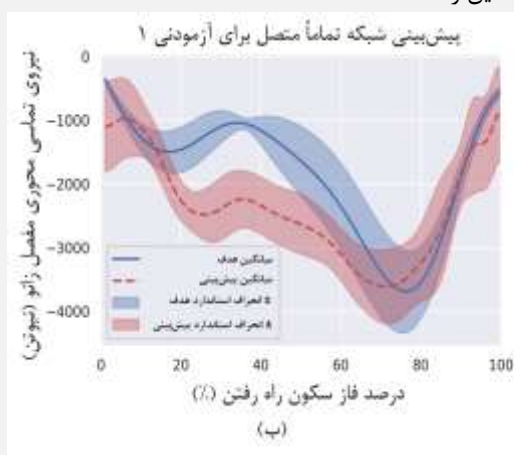
پیش‌بینی KCF مربوط به آزمودنی‌های ۱ و ۵ در اشکال (۴) و (۵) ارائه شده است



شکل (۳) - مقدار میانگین KCF بین تمام آزمودنی‌ها مستخرج از مدل‌سازی اسکلتی-عضلانی، در این شکل خط آبی توپر و میله‌های نارنجی به ترتیب نشان‌گر میانگین و انحراف استاندارد (STD) است



شکل (۴) - پیش‌بینی FCNN در مقایسه با KCF فشاری هدف در سطح درون آزمودنی برای الف) آزمودنی شماره ۵ و ب) آزمودنی شماره ۱، خط توپر آبی و باند آبی به ترتیب مقدار میانگین و انحراف معیار KCF حقیقی و نقطه‌چین قرمز و باند قرمز به ترتیب مقدار میانگین و انحراف استاندارد KCF تخمین زده شده است



شکل (۵) - پیش‌بینی FCNN در مقایسه با KCF فشاری هدف در سطح میان آزمودنی برای الف) آزمودنی شماره ۵ و ب) آزمودنی شماره ۱، خط توپر آبی و باند آبی به ترتیب مقدار میانگین و انحراف معیار KCF حقیقی و نقطه‌چین قرمز و باند قرمز به ترتیب مقدار میانگین و انحراف استاندارد KCF تخمین زده شده است



۴- بحث

مطالعه‌ی حاضر با هدف بررسی امکان‌سنجی استفاده از یک FCNN به منظور پیش‌بینی KCF محوری در طول راه رفتن بر اساس سیگنال‌های مستخرج از سه حس‌گر IMU متصل به سگمنت‌های لگن، ران و ساق انجام شده است. نتایج نشان داده که شبکه‌ی پیشنهادی این مطالعه قادر است بر حسب داده‌های مستخرج از سه ماژول IMU سیگنال هدف را در سطوح درون و میان آزمودنی با دقت نسبتاً بالایی پیش‌بینی کند.

نتایج نشان داده که در سطح درون آزمودنی، شبکه‌ی پیشنهادی قادر به پیش‌بینی KCF با میانگین خطای ۱۵/۶ درصد بر اساس ضریب همبستگی پیرسون است. با این حال خطای پیش‌بینی در سطح میان آزمودنی برای تمام آزمودنی‌ها با مقدار متوسط ۲۴/۱ درصد برجسته‌تر است، عمدتاً به این دلیل که پیش‌بینی KCF در سطح میان آزمودنی نیاز به تعمیم‌پذیری بیشتری دارد. در تحقیقات آینده می‌توان به این مساله از طریق افزایش تعداد آزمودنی‌ها و استفاده از شبکه‌های عصبی با ساختارهای پیچیده‌تر که می‌توانند وابستگی‌های بلند مدت را یاد بگیرند (به عنوان مثال شبکه‌ی حافظه‌ی کوتاه-بلند مدت [۳۴]) پرداخت.

مقایسه‌ی مطالعه‌ی حاضر با کارهای قبلی با محدودیت مواجه بوده زیرا تمرکز تحقیقات قبلی عمدتاً بر پیش‌بینی نیروهای تماسی مفصلی از طریق داده‌های مستخرج از آزمایشگاه‌های ثبت حرکت (داده‌های مربوط به خط سیر مارکرها، کینماتیک زاویه‌ای مفاصل، الکترومایوگرافی و نیروهای عکس‌العمل زمین) است [۲۲-۲۴]. در مطالعه‌ی نسبتاً مرتبط برابندر و هم‌کارانش از مدل رگرسیون خطی منظم^۱ و یک تلفن همراه برای تخمین مقدار ضربه^۲ (یک مقدار گسسته برای هر چرخه‌ی راه رفتن) در مفاصل لگن و زانو در حین راه رفتن، حرکت روی پله و سایر حرکات استفاده شده است [۳۵]. در مطالعه‌ی آن‌ها ضربه‌ی مربوط به مفصل زانوی پای چپ و راست به ترتیب با ۳۲/۱ درصد و ۴۸/۲ درصد خطا (بر حسب میانگین خطای مطلق^۳) پیش‌بینی شده است. در مقایسه با تحقیق انجام شده توسط برابندر و هم‌کارانش، شبکه‌ی پیشنهادی در مطالعه‌ی حاضر دقت بالاتری در پیش‌بینی KCF داشته (به ترتیب ۱۵/۶٪ و ۲۴/۱٪ خطا برای سطوح درون و میان آزمودنی) و همچنین امکان پیش‌بینی مستمر و پیوسته را نیز مهیا کرده در حالی که در مطالعه‌ی برابندر و هم‌کارانش صرفاً یک مقدار گسسته برای

هر چرخه‌ی راه رفتن پیش‌بینی شده است. در نتیجه شبکه‌ی پیشنهادی KCF را به صورت پیوسته در کل چرخه‌ی راه رفتن پیش‌بینی کرده که برای بررسی بارگذاری مفصلی به هنگام وقوع رخداد‌های مختلف راه رفتن و سایر وظایف حرکتی تناوبی (مثل دویدن) حیاتی است. همچنین در پژوهش حاضر از حس‌گرهای IMU استفاده شده است که به دلیل اندازه‌ی کوچک و وزن سبک‌تر در مقایسه با تلفن‌های همراه استفاده شده توسط برابندر و هم‌کارانش [۳۵]، انعطاف‌پذیری بیشتری دارند و در طول فعالیت‌های روزمره‌ی زندگی و اجرای حرکات ورزشی راحت‌تر به یک مکان آناتومیکی خاص متصل می‌شوند. در مجموع، نتایج مطالعه‌ی حاضر نوید دهنده‌ی امکان کاربری حس‌گرهای IMU در پیش‌بینی KCF در طول فعالیت‌های روزانه و هنگام اجرای حرکات ورزشی پیچیده است. استفاده از فناوری پوشیدنی همراه با هوش مصنوعی می‌تواند بر محدودیت‌های مربوط به ثبت حرکت سنتی مبتنی بر آزمایشگاه در تخمین بارگذاری مفصلی غلبه کند.

۵- نتیجه‌گیری

شاخص KCF یکی از برجسته‌ترین و پراهمیت‌ترین فاکتورهای بیومکانیکی برای ارزیابی عمل کرد مفصل زانو است که می‌توان از آن در طراحی پروتزهای زانو و رصد فرایند توان‌بخشی پس از جراحی آرتروپلاستی زانو استفاده کرد. در این مقاله یک شبکه‌ی عصبی تماماً متصل برای تخمین پیوسته و مستمر سیگنال KCF بر اساس ورودی‌های مستخرج از سه حس‌گر IMU ارائه شده است. در این پژوهش دو سناریوی ارزیابی مختلف شامل سطوح تست درون و میان آزمودنی برای بررسی توانایی تعمیم‌پذیری شبکه‌ی پیشنهادی در نظر گرفته شده است. با توجه به نتایج به دست آمده یک شبکه‌ی تماماً متصل با ساختاری ساده می‌تواند KCF را با دقت ۸۹٪ در سناریوی درون آزمودنی و دقت ۷۹٪ در سناریوی چالش برانگیزتر میان آزمودنی تخمین بزند. رویکرد شرح داده شده در این مطالعه می‌تواند منجر به توسعه‌ی یک سیستم میدانی قابل حمل شود که قادر به ارزیابی نیروی تماسی مفصل زانو در محیط خارج از آزمایشگاه و در هنگام زندگی روزمره است. در کارهای آینده می‌توان از الگوریتم‌های پیچیده‌تر مانند شبکه‌ی حافظه‌ی کوتاه-بلند مدت^۴ (LSTM) یا انواع آن مانند LSTM دوطرفه^۵ برای پیش‌بینی دقیق‌تر سیگنال هدف در حضور تفاوت‌های

^۱ Long Short-Term Memory

^۵ Bi-Directional LSTM

^۱ Regularized Linear Regression Model

^۲ Impulse

^۳ Mean Absolute Error



- 10.1073/PNAS.1703856114.
- [9] D. Kobsar et al., "Wearable inertial sensors for gait analysis in adults with osteoarthritis-A scoping review," *Sensors (Basel)*, vol. 20, no. 24, p. 7143, 2020, doi: 10.3390/S20247143.
- [10] M. Blagojevic, C. Jinks, A. Jeffery, and K. P. Jordan, "Risk factors for onset of osteoarthritis of the knee in older adults: a systematic review and meta-analysis," *Osteoarthritis Cartilage*, vol. 18, no. 1, pp. 24–33, 2010, doi: 10.1016/j.joca.2009.08.010.
- [11] C. Richards and J. S. Higginson, "Knee contact force in subjects with symmetrical OA grades: differences between OA severities," *J. Biomech.*, vol. 43, no. 13, pp. 2595–2600, 2010, doi: 10.1016/j.jbiomech.2010.05.006.
- [12] B. J. Fregly, J. A. Reinbolt, K. L. Rooney, K. H. Mitchell, and T. L. Chmielewski, "Design of patient-specific gait modifications for knee osteoarthritis rehabilitation," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 9, pp. 1687–1695, 2007, doi: 10.1109/TBME.2007.891934.
- [13] S. M. Zingde and J. Slamin, "Biomechanics of the knee joint, as they relate to arthroplasty," *Orthop. Trauma*, vol. 31, no. 1, pp. 1–7, 2017, doi: 10.1016/j.mporth.2016.10.001.
- [14] D. D. D'Lima, N. Steklov, S. Patil, and C. W. Colwell, "The Mark Coventry award: In vivo knee forces during recreation and exercise after knee arthroplasty," *Clin. Orthop. Relat. Res.*, vol. 466, no. 11, pp. 2605–2611, 2008, doi: 10.1007/S11999-008-0345-X.
- [15] R. D. Komistek, T. R. Kane, M. Mahfouz, J. A. Ochoa, and D. A. Dennis, "Knee mechanics: a review of past and present techniques to determine in vivo loads," *J. Biomech.*, vol. 38, no. 2, pp. 215–228, 2005, doi: 10.1016/j.jbiomech.2004.02.041.
- [16] S. L. Delp et al., "OpenSim: open-source software to create and analyze dynamic simulations of movement," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 11, pp. 1940–1950, 2007, doi: 10.1109/TBME.2007.901024.
- [17] M. Damsgaard, J. Rasmussen, S. T. Christensen, E. Surma, and M. de Zee, "Analysis of musculoskeletal systems in the AnyBody Modeling System," *Simul. Model. Pract. Theory*, vol. 14, no. 8, pp. 1100–1111, 2006, doi: 10.1016/J.SIMPAT.2006.09.001.
- [18] C. Curreli, F. Di Puccio, G. Davico, L. Modenese, and M. Viceconti, "Using Musculoskeletal Models to Estimate in vivo Total Knee Replacement Kinematics and Loads: Effect of Differences Between Models," *Front. Bioeng. Biotechnol.*, vol. 9, p. 611, 2021, doi: 10.3389/FBIOE.2021.703508.
- [19] A. R. Zangene and A. Abbasi, "Continuous Estimation of Knee Joint Angle during Squat from sEMG using Artificial Neural Networks," 2020 27th National and 5th International Iranian Conference on Biomedical Engineering (ICBME), pp. 75–78, 2020, doi: 10.1109/ICBME51989.2020.9319429.

منحصر به فرد میان آزمودنی استفاده کرد. هم‌چنین در تحقیقات آینده می‌توان بر پیش‌بینی KCF در طول سایر حرکات انسانی مانند دویدن، چمباتمه زدن و پریدن تمرکز کرد. به علاوه با توجه به این مساله که قسمت داخلی مفصل زانو بیش از قسمت خارجی مستعد بیماری آرتروز مفصلی است، تمرکز تحقیقات آینده می‌تواند بر پیش‌بینی نیروهای تماسی قسمت داخلی و خارجی زانو به صورت مجزا باشد.

۶- سپاس‌گزاری

نویسندگان مایل هستند از آزمودنی‌هایی که برای شرکت در این مطالعه داوطلب شده‌اند تشکر کنند.

۷- مراجع

- [1] Q. A. Louw, J. Manilall, and K. A. Grimmer, "Epidemiology of knee injuries among adolescents: a systematic review," *Br. J. Sports Med.*, vol. 42, no. 1, pp. 2–10, 2008, doi: 10.1136/BJSM.2007.035360.
- [2] J. E. Taunton, M. B. Ryan, D. B. Clement, D. C. McKenzie, D. R. Lloyd-Smith, and B. D. Zumbo, "A retrospective case-control analysis of 2002 running injuries," *Br. J. Sports Med.*, vol. 36, no. 2, pp. 95–101, 2002, doi: 10.1136/BJSM.36.2.95.
- [3] H. Naserpour, E. Shirzad, M. Khaleghi Tazji, and A. Letafatkar, "The comparison of selected kinetic factors during a cross-cutting maneuver in soccer players with athletics groin pain and healthy ones: Implications for injury prevention," *Journal of Exercise Science and Medicine*, 12(2).
- [4] D. D. D'Lima, B. J. Fregly, S. Patil, N. Steklov, and C. W. Colwell Jr, "Knee joint forces: prediction, measurement, and significance," *Proc. Inst. Mech. Eng. H*, vol. 226, no. 2, pp. 95–102, 2012, doi: 10.1177/0954411911433372.
- [5] A. J. Baliunas et al., "Increased knee joint loads during walking are present in subjects with knee osteoarthritis," *Osteoarthritis Cartilage*, vol. 10, no. 7, pp. 573–579, 2002, doi: 10.1053/JOCA.2002.0797.
- [6] K. Weiss and C. Whatman, "Biomechanics Associated with Patellofemoral Pain and ACL Injuries in Sports," *Sport. Med.*, vol. 45, no. 9, pp. 1325–1337, 2015, doi: 10.1007/S40279-015-0353-4.
- [7] R. C. Lawrence et al., "Estimates of the prevalence of arthritis and other rheumatic conditions in the United States. Part II," *Arthritis Rheum.*, vol. 58, no. 1, pp. 26–35, 2008, doi: 10.1002/ART.23176.
- [8] I. J. Wallace et al., "Knee osteoarthritis has doubled in prevalence since the mid-20th century," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 114, no. 35, pp. 9332–9336, 2017, doi:

- [27] C. D. Pollard, B. C. Heiderscheit, R. E. A. van Emmerik, and J. Hamill, "Gender differences in lower extremity coupling variability during an unanticipated cutting maneuver," *J. Appl. Biomech.*, vol. 21, no. 2, pp. 143–152, 2005, doi: 10.1123/jab.21.2.143.
- [28] D. G. E. Robertson, G. E. Caldwell, J. Hamill, G. Kamen, and S. N. Whittlesey, *Research Methods in Biomechanics*, 2nd ed. Champaign, IL: Human Kinetics, 2013.
- [29] C. E. Milner and M. R. Paquette, "A kinematic method to detect foot contact during running for all foot strike patterns," *J. Biomech.*, vol. 48, no. 12, pp. 3502–3505, 2015, doi: 10.1016/j.jbiomech.2015.07.036.
- [30] S. L. Delp, J. P. Loan, M. G. Hoy, F. E. Zajac, E. L. Topp, and J. M. Rosen, "An Interactive Graphics-Based Model of the Lower Extremity to Study Orthopaedic Surgical Procedures," *IEEE Trans. Biomed. Eng.*, vol. 37, no. 8, pp. 757–767, 1990, doi: 10.1109/10.102791.
- [31] F. C. Anderson and M. G. Pandy, "Static and dynamic optimization solutions for gait are practically equivalent," *J. Biomech.*, vol. 34, no. 2, pp. 153–161, 2001, doi: 10.1016/s0021-9290(00)00155-x.
- [32] F. Pedregosa et al., "Scikit-learn: Machine learning in Python", *J. Mach. Learn. Res.*, vol. 12, pp. 2825–2830, Feb. 2011.
- [33] M. J. Dreyer et al., "European Society of Biomechanics S.M. Perren Award 2022: Standardized tibio-femoral implant loads and kinematics," *J. Biomech.*, vol. 141, p. 111171, 2022, doi: 10.1016/J.JBIOMECH.2022.111171.
- [34] A. R. Zangene, A. Abbasi, and K. Nazarpour, "Estimation of lower limb kinematics during squat task in different loading using sEMG activity and deep recurrent neural networks," *Sensors (Basel)*, vol. 21, no. 23, p. 7773, 2021, doi: 10.3390/S21237773.
- [35] A. De Brabandere, J. Emmerzaal, A. Timmermans, I. Jonkers, B. Vanwanseele, and J. Davis, "A machine learning approach to estimate hip and knee joint loading using a mobile phone-embedded IMU," *Front. Bioeng. Biotechnol.*, vol. 8, p. 320, 2020, doi: 10.3389/FBIOE.2020.00320.
- [20] M. Mundt et al., "Estimation of Gait Mechanics Based on Simulated and Measured IMU Data Using an Artificial Neural Network," *Front. Bioeng. Biotechnol.*, vol. 8, p. 41, 2020, doi: 10.3389/FBIOE.2020.00041.
- [21] S. Cerfoglio, M. Galli, M. Tarabini, F. Bertozzi, C. Sforza, and M. Zago, "Machine learning-based estimation of Ground Reaction Forces and knee joint kinetics from inertial sensors while performing a Vertical Drop Jump," *Sensors (Basel)*, vol. 21, no. 22, p. 7709, 2021, doi: 10.3390/S21227709.
- [22] M. M. Ardestani et al., "Feed forward artificial neural network to predict contact force at medial knee joint: Application to gait modification," *Neurocomputing*, vol. 139, pp. 114–129, 2014, doi: 10.1016/j.neucom.2014.02.054.
- [23] G. Giarmatzis, E. I. Zacharaki, and K. Moustakas, "Real-time prediction of joint forces by motion capture and machine learning," *Sensors (Basel)*, vol. 20, no. 23, p. 6933, 2020, doi: 10.3390/S20236933.
- [24] W. S. Burton 2nd, C. A. Myers, and P. J. Rullkoetter, "Machine learning for rapid estimation of lower extremity muscle and joint loading during activities of daily living," *J. Biomech.*, vol. 123, no. 110439, p. 110439, 2021, doi: 10.1016/j.jbiomech.2021.110439.
- [25] K. Lebel, P. Boissy, M. Hamel, and C. Duval, "Inertial measures of motion for clinical biomechanics: comparative assessment of accuracy under controlled conditions - effect of velocity," *PLoS One*, vol. 8, no. 11, p. e79945, 2013, doi: 10.1371/JOURNAL.PONE.0079945.
- [26] F. Gao, G. Liu, F. Liang, and W. H. Liao, "IMU-Based Locomotion Mode Identification for Transtibial Prostheses, Orthoses, and Exoskeletons," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, no. 6, pp. 1334–1343, 2020, doi: 10.1109/TNSRE.2020.2987155.