

استفاده از سیگنال های الکترومیوگرافی از طریق

شبکه عصبی مصنوعی در مهندسی پزشکی

امیرحسین رخشانی فر

کارشناسی مهندسی پزشکی، موسسه آموزش عالی خاوران، مشهد، ایران

اطلاعات مقاله

چکیده:

همواره، فازهای استقرار و نوسان را رویدادهای کانونی در بسیاری از برنامه های حرکتی می شناسند. اگرچه تشخیص رویدادهای حرکتی از طریق سیگنال های الکترومیوگرافی موجب توسعه تجهیزات کمکی نظیر ربات اسکلت خارجی، ارتزها و پروتزها می شود، اما، فازهای استقرار و نوسان همواره از این سیگنال ها بی بهره بوده اند. در این پژوهش، یک سیستم طبقه بندی جهت فازهای استقرار و نوسان براساس سیگنال های الکترومیوگرافی ارائه شده است. با استخراج الگوهای سیگنال های الکترومیوگرافی از ویژگی های حوزه زمان و اعمال آن ها به طبقه بندی کننده شبکه عصبی مصنوعی این امر تحقق می یابد. به علاوه، تعدادی از ویژگی های متفاوت به عنوان ورودی و دو الگوریتم مشهور آموزش شبکه عصبی مصنوعی در این تحقیق به کار گرفته شده است. هشت آزمودنی مورد مطالعه به دو دسته داده آموزش دیده (هفت نفر اول) و آموزش ندیده (نفر آخر) تقسیم شده اند. در پایان این آزمایش می توان گفت بررسی رویدادهای راه رفتن با استفاده از سیگنال های الکترومیوگرافی از طریق شبکه عصبی مصنوعی امکان پذیر است.

تاریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۱/۰۳/۱۰

تاریخ پذیرش مقاله: ۱۴۰۱/۰۳/۲۰

تاریخ انتشار مقاله: ۱۴۰۱/۰۴/۰۱

واژگان کلیدی: رویداد حرکتی، شبکه

عصبی مصنوعی، ویژگی های حوزه زمان.

Using electromyographic signals through artificial neural network in medical engineering

Amirhossein Rakhshanifar

Bachelor of Medical Engineering, Khavaran Institute of Higher Education, Mashhad, Iran

Invariably, the establishment and swing phases are known as focal events in many movement programs. Although the detection of movement events through electromyography signals leads to the development of auxiliary equipment such as exoskeleton robots, orthoses and prostheses, the phases of establishment and oscillation have always been without these signals. In this research, a classification system for establishment and oscillation phases based on electromyography signals is presented. This is realized by extracting patterns of electromyographic signals from time domain features and applying them to the artificial neural network classifier. In addition, a number of different features as input and two well-known artificial neural network training algorithms are used in this research. The eight studied subjects are divided into two groups: trained (the first seven) and untrained (the last). At the end of this experiment, it can be said that it is possible to investigate walking events using electromyography signals through artificial neural network.

۱- مقدمه

همواره، از روند روبه رشد تشخیص رویداد حرکتی می توان به عنوان روشی مؤثر در درمان توان بخشی نام برد. علاوه بر بهبود یافتن معاینات بیماری پارکینسون [۱]، تجزیه و تحلیل و نظارت بر رویدادهای حرکتی در درمان کودکان مبتلا به فلج مغزی [۲] و آسیب های عضلانی نیز مؤثر است [۳ و ۴]. یان و همکاران در گزارش خود به تاثیر بسیار زیاد تشخیص رویداد حرکتی در توسعه دستگاه های کمکی بدن از جمله ربات های اسکلت خارجی و ارتزهای مچ پا «AF»، زانو-لگن «HK» و زانو-مچ پا «KAF» اشاره کردند [۵]. فازهای استقرار و نوسان را می توان محل توسعه ارتزهای HK، KAF و AF فعال و غیرفعال دانست [۶-۹]. به علاوه، از تأثیر مثبت این رویدادها - هرچند کوتاه مدت- بر روی ارتزهای کینماتیک مچ پا [۱۰] و افزایش ظرفیت راه رفتن نمی توان چشم پوشی کرد [۱۱]. بنابراین، مقیاس بندی حرکتی دو فاز برای همگام سازی موتورهای فعال حسگرهای پوشیدنی در شبیه سازی الکتریکی کاربردی کافی است [۱۲]. در توسعه تجهیزات کمکی، از حسگرهای پوشیدنی مانند شتاب سنج و ژيروسکوپ جهت کنترل محرک استفاده شد. حسگرهای پوشیدنی نیازمند جبران ساز گرانش، جابجایی صحیح جهت استفاده از حسگرها و کالیبراسیون دقیق هستند و در صورت نیاز به زاویه، باید محاسبات دقیق انجام شود تا از بروز خطاهای انحراف و خطاهای با درصد منفی جلوگیری شود [۱۲ و ۱۵]. رشد تجهیزات کمکی موجب استفاده هرچه بیشتر سیگنال های الکترومیوگرافی «EMG» در کنترل تعاملات بین انسان و ماشین شده است [۱۹]. به عنوان مثال، ترکیب این سیگنال ها با حسگرهای مکانیکی/سینماتیکی در تشخیص قصد انجام عمل [۲۰] و آغاز گام برداشتن [۲۱] در افراد قطع عضو بسیار امیدوارکننده بود. چنین رویکردی موجب به کارگیری تجهیزات پروتز، ویلچر برقی [۲۲]، بازوی رباتی [۲۳] و ربات های اسکلت خارجی [۲۴] از طریق عضلات کاربران می شود. در سال ۲۰۱۶، ارتزهای AF غیرفعال با کمک سیگنال های EMG و موقعیت یابی مچ پا بهبود یافتند [۲۵]. با این وجود، سیگنال های EMG در طول فازهای استقرار و نوسان بررسی نشده بودند [۱۲ و ۲۷]. یک الگوی متناوب مانند سیگنال های EMG معمولاً با استفاده از رویکرد یادگیری ماشین طبقه بندی می شود [۲۸]. چنین رویکردی قادر به برقراری روابط بین داده ها - مستقیماً از داده های مدل- است و توانایی نشان دادن هر دو رابطه خطی و غیرخطی را دارد [۱۹]. از این جهت، رویکرد یادگیری ماشین نظیر شبکه های عصبی مصنوعی «ANN»، می تواند در تجزیه و تحلیل و طبقه بندی الگوهای پیچیده مؤثر واقع شود. توانایی ANN در بررسی و برقراری ارتباط بین داده های سیگنال های EMG جهت حرکت اندام فوقانی [۲۹] و بیماری های عصبی عضلانی [۳۰] اثبات شده است. اما، پژوهشی جهت حرکت اندام تحتانی به ویژه فازهای استقرار و نوسان انجام نشده است. دقت محاسباتی همانند کاربردی بودن یک سیستم از اهمیت بالایی برخوردار است. بهره مندی از ویژگی های مناسب و مؤثر جهت تضمین دقت بالا امری ضروری است. ویژگی های حوزه زمان «TD» به طور وسیعی در تشخیص حرکات اندام فوقانی به کار گرفته شده اند، زیرا، محاسبه ویژگی ها براساس سری های زمانی خام EMG بوده و نیازمند تغییر نیست [۲۹، ۳۱، ۳۲، ۵۵]. لازم به ذکر است، مجموعه ویژگی های منفرد و چندگانه از دقت های متمایزی برخوردار هستند [۳۲ و ۳۳]. در این پژوهش، سیگنال های EMG جهت تعیین کمیت فازهای استقرار و نوسان - طی رویدادهای طبیعی راه رفتن- بین افراد جوان و سالم به کار گرفته شده اند. امید است نتایج حاصل در ایجاد سیستمی با دقت مناسب جهت تشخیص فازهای استقرار و نوسان ثمربخش باشد. سیستم پیشنهادی از طریق برخی از ویژگی های TD به نمایش سیگنال های EMG مربوط به عضلات درشت نئی قدامی (TA) و دوقلو داخلی (mGas) می پردازد. همچنین، پس از محاسبه ویژگی ها از طریق طبقه بندی کننده ANN، عملکرد تک واحدی و ترکیبی ویژگی ها بایکدیگر مقایسه می شوند. ANN طراحی شده ابتدا با س آموزش دیده و آموزش ندیده ارزیابی شده و در مرحله بعدی میزان سازگاری آن با طبقه بندی EMG بررسی می شود. براساس فازهای استقرار و نوسانی مشخص شده توسط سیستم، ابتدا زمان بندی این مراحل شناسایی و سپس جهت اعتبارسنجی با داده های سوئیچ پا مقایسه شدند.


۲- مواد و روش ها

۲-۱ جمع آوری و پردازش داده ها


در این تحقیق، هشت نفر مرد با محدوده سنی ۲۳ تا ۲۶ سال و قد ۱۶۳ تا ۱۸۳ سانتی متر شرکت کردند. این افراد فاقد هرگونه آسیب دیدگی فیزیولوژیکی یا عصبی - که ممکن بود راه رفتن را تحت تأثیر قرار دهد- بودند. باتوجه به میزان خطای کمتر سیستم مقاومت های سنجش نیرو (FSR) در مقایسه با سیستم شتاب سنج [۳۴]، در سایر حسگرهای پوشیدنی نظیر شتاب سنج ها [۳۵،۳۶]، ژيروسکوپ ها [۳۷-۳۹] و IMU [۴] از مرجعی مبتنی بر سوئیچ پا جهت شناسایی رویدادهای حرکتی استفاده شد. به طور مشابه، در پژوهش های [۱۸ و ۴۰] از داده های سوئیچ پا به عنوان مرجع استفاده شد، بدین صورت که با تجزیه و تحلیل سیگنال های EMG، داده های سوئیچ پا تعیین کننده شروع و پایان گام بودند. دو FSR زیر کف پای آنها - زیر انگشت شست و پاشنه پا- قرار داده شد [۴۱]. داده های سوئیچ پا از طریق سیستم سوئیچ بار (DKH، ژاپن) با نیروی فعال سازی 0.3N ثبت شد. از آنجایی که خروجی های سوئیچ های پا به سیگنال های مرجع تبدیل می شوند، صحت عملکرد آنها با حرکت کف پای افراد بررسی و تصدیق شد. فاز استقرار با تماس اولیه پا آغاز شد که ضربه پاشنه «HS» نامیده می شود - زیرا فشار در پاشنه افزایش می یابد. در همین حال، تماس پا یا انگشت پا «TO»، با شروع فاز نوسان پایان یافت. در این پژوهش، HS هنگام تماس پاشنه با زمین و TO هنگام جدا شدن انگشت شست از زمین بود. شناسایی سیگنال های EMG از طریق قرارگیری الکترودهای حسگر EMG -الکترودها به صورت چسبیده دوطرفه بوده و بر روی پوست قرار می گیرد- بر روی عضلات TA و mGas صورت پذیرفت که به نوعی از الکترومیوگرافی سطحی جهت ارزیابی غیر تهاجمی -الکتروککشک- مشتق شده است. لازم به ذکر است، جهت کاهش امپدانس پوست، موهای روی پوست قبل از اتصال الکترودها تراشیده شده و پوست با پنبه آغشته به الکل ضد عفونی می شود. پردازش آنلاین سیگنال های EMG سطحی از طریق دستگاه دو کاناله EMG (نیهون کوهن، ژاپن) با قطر الکترودها ۳۰ میلی متر، فاصله بین الکترودها ۱۰ میلی متر، امپدانس ورودی بزرگتر از 10^{15} اهم و نویز ارجاع به ورودی ۱،۲ میکرو ولت انجام شد. دستگاه توسط یک تقویت کننده چند کاناله با پهنای باندی بین ۱۵ تا ۱۰۰۰ هرتز تقویت شد. سپس سیگنال های خام EMG جهت کاهش اثر تداخل و فرکانس های ناخواسته (۵۰/۶۰ هرتز) با فیلترهای مرتبه دوم پایین گذر و بالاگذر باترورت به ترتیب در ۲۰ و ۵۰۰ هرتز فیلتر شدند [۲۸]. همچنین، یک مبدل آنالوگ به دیجیتال ۶۴ کاناله (مدل NAC، ZO-928، ژاپن) به سیگنال های EMG و داده های سوئیچ پا متصل شد (شکل ۱). علاوه بر این، نمونه برداری سیگنال های EMG و داده های سوئیچ پا با استفاده از نرم افزار کرتکس و با نرخ ۱۰۰۰ هرتز صورت گرفت. در شکل «۲»، نمونه ای از سیگنال های EMG ثبت شده از عضلات TA و mGas یکی از افراد نشان داده شده است. افراد با پای برهنه و با سرعت دلخواه، روی تردمیلی که برای ۶۰ ثانیه روی سرعت ۳ کیلومتر در ساعت تنظیم شده بود، راه رفتند. با کمک نرم افزار MATLAB الگوریتمی جهت تشخیص زمان سیگنال های HO، TS و EMG در عضلات TA و mGas طراحی شد. باتوجه به داده های سوئیچ پا، زمان بندی HS و TO یک و سایرین صفر ثبت شد. همچنین، ابتدا، مقادیر زمینه تقسیم سیگنال های EMG در عضلات TA و mGas فراهم و پس از آن، کل داده های سیگنال های EMG به بخش های همپوشانی تقسیم شدند. آنها دارای ۲۰۰ مقدار داده همراه با یک تاخیر زمانی جهت بخش بعدی هستند. چنین طولی حاوی اطلاعات کافی جهت تخمین الگوی سیگنال های EMG بود. شایان ذکر است، استخراج ویژگی به عنوان روشی مؤثر و مهم در استخراج اطلاعات مفید از سیگنال های EMG شناخته می شود. به علاوه، ویژگی ها در TD به طور گسترده جهت حل مشکلات تشخیص الگو استفاده می شوند. MAV نه تنها یکی از مشهورترین ویژگی های مورد استفاده در تجزیه و تحلیل سیگنال های EMG است [۴۲]، بلکه فینیومارک و همکاران ویژگی های MAV را بر اساس روش اطلاعات انرژی پیشنهاد می کنند [۳۱]. این دستاورد را نیز می توان تایید کننده ترکیب MAV و WL پیشنهاد شده توسط اسکویی و همکاران با استفاده از سیگنال EMG چهار کاناله در انقباضات ایزومتریک دانست. در این پژوهش ویژگی های TD نظیر مجذور میانگین مربعات «RMS»، انحراف استاندارد

«SD»، میانگین قدرمطلق «MAV»، EMG یکپارچه «IEMG» و طول شکل موج «WL» به کار گرفته شدند [۳۲ و ۲۹]. ویژگی های SD، MAV، IEMG و WL متعلق به عضلات TA و mGas به ترتیب به P_1 تا P_5 و P_6 تا P_{10} اختصاص داده شدند. ویژگی های ذکر شده براساس گزارش ارائه شده توسط نندزری و همکاران در زمینه سیگنال های EMG در انقباضات ایزومتریک- انتخاب شدند [۴۳]. این تحقیق موجب توسعه تحقیقات در زمینه انقباضات ایزوتونیک می شود - ویژگی های واریانس با ویژگی SD پیشنهاد شده توسط داود [۴۴] جایگزین شده است. در همین حال، ویژگی های MAV براساس روش اطلاعات انرژی توصیه شد [۳۱]. علاوه بر آن، ترکیب MAV و WL در تجزیه و تحلیل سیگنال های EMG در طول انقباضات ایزومتریک توسط اسکویی و همکاران پیشنهاد شد [۳۲].

محاسبه ویژگی های TD از طریق سیگنال های EMG تقسیم بندی شده سی مرحله ای انجام شد. این کار بر روی همه افراد تحت آزمایش صورت پذیرفت. پس از آن، تمام ویژگی های TD طی فازهای استقرار و نوسان به عنوان ورودی به یک طبقه بندی کننده شبکه عصبی داده شد. توجه به این نکته ضروری است که مجموعه ویژگی های منفرد و چندگانه دقت های متفاوتی را به دست آورده اند [۳۲]. بنابراین، عملکرد MAV و ویژگی های چندگانه - گروه اول شامل ویژگی های MAV و WL و گروه دوم متشکل از ویژگی های SD، MAV، IEMG و WL است - بررسی خواهد شد.



شکل ۱- تجهیزات مورد استفاده در آزمایش




شکل ۲- نمونه خروجی ثبت شده عضلات TA و mGas.

۲-۲ شبکه عصبی مصنوعی

در هر شبکه عصبی تعداد موارد آموزش مورد نیاز به میزان تغییرپذیری الگوهای طبقه‌بندی شده توسط شبکه بستگی دارد [۴۵]. از آنجایی که این پژوهش در مورد فازهای استقرار و نوسان است، مجموعه داده‌های آموزش شامل ویژگی‌های استخراج شده از رویدادهای راه رفتن افراد بود. در مجموع، ۲۴۵۷۶۳ مجموعه داده از بردارهای ورودی و هدف داده‌های آموزش دیده فازهای استقرار و نوسانی (هفت نفر اول) در ANN محاسبه شد. در این تحقیق از یک شبکه عصبی مصنوعی پرسپترون چندلایه استفاده شده است. ساختار این شبکه به صورت سه لایه پیش‌خور -لایه ورودی، لایه پنهان و لایه خروجی- است. به طور کلی، بردار ورودی P با ردیف های L را می‌توان به صورت $P_1, P_2, \dots, P_R$ نشان داد. بردار ورودی در ماتریس وزن «W1» ضرب شده و ورودی‌های وزن دار شده به صورت $w_{1,1}, w_{2,1}, \dots, w_{s1,L}$ نمایش داده می‌شوند که «S1» نشان‌دهنده تعداد نورون‌هاست. در این پژوهش، از ۱۰ نورون با تابع فعال‌ساز سیگموئید تانژانت استفاده شد که عملکرد بهتری نسبت به ۲۰ و ۳۰ نورون پنهان داشتند [۲۹]. همچنین «b» یک بردار بایاس، «n» خروجی لایه قبل از تابع انتقال و «a» بردار خروجی یک لایه است. پس از طراحی ANN، یک الگوریتم آموزش مناسب جهت تنظیم بایاس‌ها و وزن‌های سیناپس در لایه‌های مختلف مورد نیاز بود. الگوریتم آموزش -برای به حداقل رساندن میانگین مربعات خطا «MSE»- با استفاده از گرادیان تابع عملکرد وزن‌ها و بایاس‌ها را تنظیم می‌کند. دو نوع الگوریتم آموزش ANN عبارتند از لوببرگ-مارکوات «LM» و گرادیان مزدوج مقیاس‌بندی شده «SCG». بهینه‌سازی عددی مبتنی بر LM جهت آموزش شبکه‌های عصبی پیش‌خور با سایز متوسط در مقایسه با SCG از عملکرد سریع‌تر و بهتری برخوردار بود [۲۹ و ۴۶]. بنابراین، هر دو الگوریتم جهت بررسی سازگاری و سطح عملکرد در شبکه عصبی مصنوعی به کار گرفته شدند. مدت زمان آموزش ANN برای هر دو الگوریتم بین ۱ تا ۴۰ دقیقه بود. داده‌های ورودی آموزش جهت جلوگیری از بیش‌برازش به طور تصادفی تقسیم شدند: ۷۰ درصد جهت آموزش، ۱۵ درصد جهت اعتبار سنجی و ۱۵ درصد جهت آزمایش. همچنین، هفت نفر اول به عنوان داده‌های مدل جهت طراحی شبکه عصبی مصنوعی در نظر گرفته شدند. باتوجه به سه ویژگی موجود، سه معماری مختلف ANN با مقادیر $L=2$ ، $L=4$ و $L=10$ طراحی و تمام ویژگی‌های TD داده‌های آموزش دیده و بردار هدف آن برای هر مدل آموزش داده شد. شبکه سه مرتبه آموزش دید که در پایان هر دوره شاخص‌هایی نظیر زمان سپری‌شده، رگرسیون «R»، MSE و نرخ طبقه‌بندی ثبت شدند. مدل ANN آموزش دیده با نرخ طبقه‌بندی بالاتر همراه با داده‌های آموزش دیده و آموزش ندیده (نفر آخر باقی‌مانده) در سیمولینک متلب ذخیره شد. علاوه بر این، ویژگی‌های TD فرد در عرض پنج ثانیه -که با اهداف مطابقت نداشتند- وارد ANN آموزش دیده شدند. این فرآیند جهت بررسی تعمیم‌دهی و عملکرد ANN آموزش دیده در طبقه‌بندی فازهای استقرار و نوسان صورت پذیرفت. در مرحله بعد، تفاوت زمانی بین خروجی این مدل با مقدار مرجع -داده‌های سوئیچ پا جهت تشخیص HS و TO- ارزیابی شد. همچنین، مقدار میانگین تفاضل مطلق برای داده‌های آموزش دیده و آموزش ندیده نیز محاسبه شد. برای داده‌های

آموزش دیده، میانگین تفاضل مطلق «MAD» تشخیص HS و TO بین سیستم پیشنهادی و داده های کلید پا - با کمک آزمون های ویلکاکسون رتبه علامت دار و تنظیم $P < 0.05$ - تجزیه و تحلیل شد. روند کلی پژوهش در شکل «۳» نشان داده شده است.



شکل ۳- فرآیند کلی پژوهش

۳- نتایج

در جدول «۱» عملکرد و پاسخ های شبکه توابع آموزش برحسب دوره های توقف، زمان سپری شده و مقدار رگرسیون طبقه بندی شده است. همانطور که در بالا ذکر شد، هر مدل ANN سه مرتبه آموزش داده شد. ساخت یک مدل ANN با استفاده از SCG (۵-۱ ثانیه) در مقایسه با تابع آموزش LM سریعتر بود. شکل «۴» میانگین طبقه بندی هر دو الگوریتم آموزش را - که هر کدام مربوط به مجموعه ویژگی مشخصی هستند - نشان می دهد. همانطور که مشاهده می شود بیشترین و

کمترین مقدار MSE به ترتیب مربوط به ویژگی های MAV با استفاده از الگوریتم SCG (۰,۱۴۹) و ویژگی های گروه دوم با استفاده از الگوریتم LM (۰,۰۹۴) است. همچنین میانگین دقت طبقه بندی الگوریتم SCG برحسب درصد برای MAV، گروه اول و گروه دوم به ترتیب برابر است با: ۷۷,۶، ۸۰,۵ و ۸۳,۶. از سوی دیگر، این اعداد برای الگوریتم LM به ترتیب برابر با ۱,۸، ۳,۸ و ۱,۸ هستند. از آنجایی که گروه دوم با تابع آموزش LM بالاترین دقت را داشت، این مدل با داده های آموزش دیده و آموزش ندیده بیشتر ارزیابی شد. همچنین، نمونه ای از ویژگی های TD استخراج شده از داده های آموزش ندیده سیگنال های EMG و خروجی طبقه بندی این شبکه در جدول «۲» نشان داده شده است. اعداد پررنگ نشان دهنده شبکه هایی هستند که رویداد راه رفتن را با موفقیت طبقه بندی کرده اند - دارای بیشترین مقدار و نزدیک به یک هستند. به طور کلی، درصد فازهای استقرار و نوسان در یک چرخه کامل راه رفتن به ترتیب ۶۰ و ۴۰ درصد است [۴۸]. در این پژوهش، عملکرد مدل ANN در طبقه بندی فازهای استقرار و نوسان - در مدت زمان پنج ثانیه - برای داده های آموزش دیده و آموزش ندیده در جدول «۳» برحسب درصد ارائه شده است. بر اساس نتایج حاصل از طبقه بندی، تشخیص HS و TO توسط ANN آموزش دیده و داده های سوئیچ پا - در عرض پنج ثانیه - برای داده های آموزش دیده و آموزش ندیده به ترتیب در شکل های «۵» و «۶» نشان داده شده است. در شکل «۷» میانگین اختلاف زمانی بین رویدادهای HS و TO شناسایی شده توسط ANN و سوئیچ پا (16 ± 18) میلی ثانیه و (21 ± 18) میلی ثانیه (برای داده های آموزش دیده ارائه شده است). نتیجه آزمون ویلکاکسون جهت تعیین میزان اختلاف بین میانگین تفاضل مطلق HS و TO در روش پیشنهادی و مرجع مبتنی بر سوئیچ پا در شکل «۸» ارائه شده است - فرض صفر پذیرفته شده است $(p < 0.05)$. همچنین، میانگین اختلاف زمانی بین داده های ANN و سوئیچ پا برای HS و TO به ترتیب 25 ± 35 میلی ثانیه و 15 ± 49 میلی ثانیه بود که در شکل «۹» نشان داده شده است. اختلاف منفی بیان کننده شناسایی HS و TO توسط ANN قبل از سوئیچ پا است.

جدول ۱- خلاصه عملکرد طبقه بندی ANN با معماری های متفاوت.

تابع آموزش	ویژگی های TD	دوره های توقف	زمان سپری شده	R	نرخ طبقه بندی	اعتبارسنجی	آزمایش	کل
SCG	گروه اول	۱۳۶	۱,۰۳	۰,۶۲۱۲۵	۷۶,۹	۷۷,۲	۷۷,۳	۷۷
		۳۳۳	۲,۳	۰,۶۳۸۳۴	۷۸	۷۸,۱	۷۸,۳	۷۸
		۴۷۰	۳,۳۹	۰,۶۴۲۸	۷۷,۸	۷۷,۶	۷۸,۱	۷۷,۸
SCG	گروه اول	۳۶۷	۲,۵۹	۰,۶۸۱۹۳	۸۰,۶	۸۰,۶	۸۰,۷	۸۰,۶
		۳۳۵	۲,۴۳	۰,۶۷۹۳	۸۰,۶	۸۰,۸	۸۰,۴	۸۰,۶
		۳۵۷	۲,۵۴	۰,۶۷۷۳۹	۸۰,۴	۸۰,۲	۸۰,۵	۸۰,۴
	گروه دوم	۴۰۹	۳,۵۹	۰,۷۳۴۶۴	۸۳,۵	۸۳,۵	۸۳,۵	۸۳,۵
		۴۵۳	۴,۳۸	۰,۷۲۲۷۲	۸۲,۷	۸۲,۴	۸۳	۸۲,۷
		۵۵۴	۵,۳۹	۰,۷۴۹۸۳	۸۴,۷	۸۴,۷	۸۴,۲	۸۴,۶
		۱۰۴	۹,۲۱	۰,۶۵۱۹۴	۷۸,۷	۷۸,۵	۷۸,۷	۷۸,۷
LM	گروه اول	۵۳۴	۳۶,۱۶	۰,۶۵۶۸	۷۹,۱	۷۹,۲	۷۹,۲	۷۹,۱
		۱۸۷	۱۳,۱۱	۰,۶۴۲۵۱	۷۸	۷۸,۱	۷۷,۹	۷۸
		۱۷۲	۱۸,۴۱	۱۸,۴۱	۸۲,۴	۸۲,۳	۸۲,۵	۸۲,۴
		۲۱۹	۱۵,۵۴	۱۵,۵۴	۸۲,۴	۸۲,۴	۸۲	۸۲,۳

۴۷۲	۵۵,۰۴	۵۵,۰۴	۸۲	۸۱,۸	۸۱,۹	۸۲
۱۳۳	۲۴,۳۳	۲۴,۳۳	۸۷,۲	۸۷,۲	۸۷,۱	۸۷,۲
۲۲۵	۲۴,۱۷	۲۴,۱۷	۸۷,۸	۸۷,۳	۸۷,۵	۸۷,۷
۳۳۸	۳۹,۴۸	۳۹,۴۸	۸۷,۵	۸۷,۳	۸۷,۵	۸۷,۴


گروه دوم

جدول ۲- بردار ورودی و ویژگی داده های آزمایش و خروجی طبقه بندی از طریق مدل آموزش دیده ANN.


بردار ورودی											خروجی های مورد انتظار و شبیه سازی				
P ₁	P ₂	P ₃	P ₄	P ₅	P ₆	P ₇	P ₈	P ₉	P ₁₀						
۰,۰۲۸	۰,۰۴۲	۰,۰۱۸	۰,۰۳۱	۰,۰۲۲	۰,۰۲۹	۴,۴۴۱	۵,۸۳۵	۳,۶۹۷	۴,۲۶۳	۱	۰	۰,۶۲۹	۰,۳۵۸		
۹	۸	۵	۵	۲	۱	۷	۰	۵	۲			۹	۶		
۰,۰۲۸	۰,۰۴۲	۰,۰۱۸	۰,۰۳۰	۰,۰۲۲	۰,۰۲۸	۴,۴۳۴	۵,۷۴۰	۳,۶۸۵	۴,۱۶۹	۱	۰	۰,۶۳۶	۰,۳۵۲		
۹	۱	۵	۹	۱	۷	۹	۷	۰	۰			۱	۶		
۰,۰۲۸	۰,۰۴۲	۰,۰۱۸	۰,۰۳۰	۰,۰۲۲	۰,۰۲۸	۴,۴۴۰	۵,۷۴۰	۳,۶۶۴	۴,۱۵۳	۱	۰	۰,۶۳۵	۰,۳۵۳		
۹	۱	۵	۹	۲	۷	۶	۷	۰	۹			۷	۲		
۰,۰۲۸	۰,۰۴۲	۰,۰۱۸	۰,۰۳۱	۰,۰۲۲	۰,۰۲۸	۴,۴۲۵	۵,۷۰۵	۳,۶۶۹	۴,۱۶۰	۱	۰	۰,۶۳۲	۰,۳۵۶		
۸	۰	۵	۰	۱	۵	۰	۷	۲	۹			۰	۸		
۰,۰۳۹	۰,۰۳۳	۰,۰۲۴	۰,۰۲۰	۰,۰۳۰	۰,۰۲۶	۶,۱۳۴	۵,۳۶۵	۵,۰۶۶	۴,۵۹۱	۰	۱	۰,۲۵۸	۰,۷۳۷		
۲	۴	۵	۰	۶	۸	۹	۲	۰	۶			۲	۴		
۰,۰۳۹	۰,۰۳۳	۰,۰۲۴	۰,۰۲۰	۰,۰۳۰	۰,۰۲۶	۶,۱۲۵	۵,۳۸۲	۵,۰۷۵	۴,۵۷۴	۰	۱	۰,۲۶۷	۰,۷۲۸		
۲	۶	۵	۱	۶	۹	۸	۷	۲	۶			۷	۰		
۰,۰۳۹	۰,۰۳۳	۰,۰۲۴	۰,۰۲۰	۰,۰۳۰	۰,۰۲۶	۶,۱۳۱	۵,۳۶۸	۵,۰۹۴	۴,۵۷۴	۰	۱	۰,۲۷۵	۰,۷۲۰		
۲	۴	۵	۰	۶	۸	۳	۰	۵	۵			۱	۵		
۰,۰۳۹	۰,۰۳۳	۰,۰۲۴	۰,۰۲۰	۰,۰۳۰	۰,۰۲۶	۶,۱۰۶	۵,۳۵۳	۵,۰۸۹	۴,۵۶۹	۰	۱	۰,۲۷۰	۰,۷۲۵		
۱	۴	۶	۰	۵	۷	۵	۲	۱	۷			۰	۵		

جدول ۳- عملکرد طبقه بندی ANN باتوجه به داده های مرجع هر داده.


داده ها	سوئیچ پا بر حسب درصد	ANN بر حسب درصد				
	فاز استقرار	فاز نوسان	فاز استقرار	فاز نوسان	کل	
آموزش دیده	۶۱	۳۹	۵۵,۸	۳۱,۷	۸۷,۵	
آموزش ندیده	۶۷	۳۳	۴۷,۳	۲۹,۷	۷۷	




شکل ۴- دقت طبقه بندی و MSE برای الگوریتم های آموزش با ویژگی های متفاوت به عنوان ورودی.




شکل ۵- تشخیص HS و TO از طریق ANN آموزش دیده با داده های سوئیچ پا برای داده های آموزش دیده.




شکل ۶- تشخیص HS و TO از طریق ANN آموزش دیده با داده های سوئیچ پا برای داده های آموزش ندیده.



شکل ۷- اختلاف زمانی بین رویدادهای شناسایی شده از طریق ANN آموزش دیده و سوئیچ پا برای داده های آموزش ندیده.



شکل ۸- آزمون ویلکاکسون برای داده های آموزش دیده: (a) HS، (b) TO.



شکل ۹- اختلاف زمانی بین رویدادهای شناسایی شده از طریق ANN آموزش دیده و سوئیچ پا برای داده های آموزش ندیده.

۴- بحث و بررسی

تحقیق حاضر قابلیت سیستم پیشنهادی جهت تشخیص فازهای راه رفتن براساس سیگنال های EMG را نشان داد. همچنین، اعتبارسنجی با مرجع استاندارد طلایی -داده های سوئیچ پا- امیدوارکننده بود.

۴-۱ تحلیل سیگنال های EMG

فعالیت عصبی-عضلانی بدن از اهمیت ویژه ای برخوردار بوده و این اطلاعات را می توان با استفاده از سیگنال های EMG استخراج کرد. سیگنال های EMG با سه روش زنجیره ای شامل پیش پردازش داده، استخراج ویژگی و طبقه بندی قابل تشخیص هستند. دقت طبقه بندی تا حد زیادی به ویژگی های استخراج شده بستگی دارد. اسکوئی و هو [۳۲] نشان دادند که عملکرد چهار ویژگی به صورت ترکیبی بهتر از یک یا دو ویژگی برای حرکت اندام فوقانی است. نتایج حاصل از این پژوهش نشان از عملکرد بهتر پاسخ های شبکه پنج ویژگی TD گروه دوم در مقایسه با سایر ویژگی ها دارد. اگرچه رویدادهای راه رفتن با دقت بیشتری طبقه بندی شده است، اما، زمان محاسباتی بیشتری در مقایسه با یک ویژگی منفرد صرف شده است -با اختلاف تقریباً ۱ تا ۴ ثانیه برای الگوریتم آموزش SCG و ۱۵ تا ۳۰ ثانیه برای الگوریتم آموزش LM. همچنین، همبستگی بهتر و طبقه بندی مطلوب تر مورد انتظار بود. در سویی دیگر، ویژگی های MAV درصد کمی از دقت را نشان دادند که با نتایج حاصل از تحقیق [۳۱] در ارتباط با حرکت دست در تناقض بود. اما، با اضافه شدن ویژگی های WL دقت به همان میزان درصد افزایش یافت که نشان دهنده پایداری و مطابقت آن ها با سیگنال های EMG اندام فوقانی است [۳۲]. انتخاب مدل جهت تشخیص فازهای استقرار و نوسان با در نظر گرفتن پاسخ R بود. مقدار R نشان دهنده میزان همبستگی بین خروجی ها و اهداف است. مقدار R برابر با یک یا صفر به ترتیب نشان دهنده رابطه ای نزدیک یا رابطه ای تصادفی است [۴۷]. به طور کلی، برای همه ویژگی های TD مقدار R الگوریتم LM بیشتر از الگوریتم SCG است. مقدار R برای ویژگی های گروه دوم تقریباً برابر با یک است که نشان می دهد خروجی های الگوریتم LM تقریباً به اهداف خود نزدیک تر هستند و آموزش شبکه مطابق با آن است. تجزیه و تحلیل نتایج حاکی از رابطه ای نزدیک بین خروجی ها و اهداف در الگوریتم LM دارد. در واقع می توان گفت، الگوریتم آموزش LM از نرخ یادگیری تطبیقی استفاده می کند و هیچ رفتار نوسانی در طول یادگیری از خود نشان نمی دهد [۲۹]. بنابراین، در مقایسه با الگوریتم آموزشی SCG از دقت بالاتری بهره مند است. باتوجه به شکل «۴»، مدل ANN آموزش دیده با الگوریتم LM دارای کمترین MSE و بالاترین نرخ طبقه بندی در مقایسه با الگوریتم SCG بود. همچنین الگوریتم آموزش LM نسبت به SCG از دقت بیشتری برخوردار بود. براساس مشاهدات قبل، ویژگی های گروه دوم با الگوریتم LM دارای دقت ۸۷٫۷ درصد بودند، در حالی که پس از جفت شدن با الگوریتم SCG این میزان دقت تقریباً ۵ درصد کاهش یافت -مطابق با گزارش ارائه شده توسط ابراهیمی و همکاران در ارتباط با حرکات دست [۲۹]. باتوجه به طبقه بندی کارآمد سیگنال های EMG، ویژگی های گروه دوم با دقت متوسط ۸۷٫۴ درصد از طبقه بندی بهتری در رویدادهای حرکتی -فاز استقرار و نوسان- برخوردارند. این پژوهش با برخی از تحقیقات قبلی مقایسه شد. باتوجه به رویداد راه رفتن، مدل ANN در شرایط مختلف راه رفتن دقت ۸۲٫۲ درصد را از طریق دستگاه سنجش اینرسی «IMU» قرار گرفته بر روی پا نشان می دهد [۴۸]. میزان دقت طبقه بندی توسط شتابسنج ها نیز پس از پنج مرحله راه رفتن ۸۲ درصد بود [۱۳]. در پژوهش حاضر، طبقه بندی فازهای استقرار و نوسان با دقت ۸۷٫۷ درصد توسط سیگنال های EMG از طریق ANN نشان داد که بالاترین میزان دقت تاکنون بوده است. این موضوع برای عضلات TA و mGas مهم است، زیرا، تأثیر مستقیمی در رویداد راه رفتن [۴۰] و توسعه وسایل کمکی برای ساق پا دارند [۴۹]. در تحقیق [۵۰] سیستمی مبتنی بر سیگنال های EMG جهت قرارگیری در عضلات چهارسر ران، همسترینگ، TA و mGas پیشنهاد شد. میزان دقت طبقه بندی هشت مرحله راه رفتن با استفاده از معیار اطلاع بیزی-شوارتز و آنالیز تشخیص خطی ۸۰ درصد بود. هرچند، این سیستم تنها برای فرد مورد آزمایش طراحی شده بود و برای سایر افراد مناسب نبود. برای پیشنهاد سیستمی که ممکن است برای هر فردی اعمال شود، تعمیم ANN آموزش دیده با الگوریتم آموزش LM بر روی داده های آموزش نشده سیگنال های EMG آزمایش شد. این تحقیق نشان داد که سیستم پیشنهادی می تواند رویداد

راه رفتن را با موفقیت برای داده های آموزش دیده و آموزش ندیده پیش بینی کند. یکی از یافته های جالب این بود که دقت طبقه بندی قبل و بعد از رویداد برای داده های آموزش دیده تفاوت چندانی نداشت. میزان صحت طبقه بندی فازهای استقرار و نوسان از طریق شبکه عصبی مصنوعی در مقایسه با داده های سوئیچ با به ترتیب ۹۲ و ۸۲ درصد بود. با کمال تعجب، اختلاف درصد زیادی در فاز استقرار بین مدل سوئیچ پا و ANN برای داده های آموزش ندیده وجود دارد که ممکن است بر دقت طبقه بندی کلی تأثیرگذار باشد. به طور کلی، عملکرد داده های آموزش دیده - با دقت طبقه بندی ۸۷٫۵ درصد - از داده های آموزش ندیده بهتر بود. بنابراین، تشخیص فازهای ایستادن و نوسان بر اساس سیگنال های EMG مورد اطمینان است.

۴-۲ تشخیص HS و TO

اگرچه قابلیت اطمینان سنسورهای سوئیچ پا مورد تردید واقع شده بود، اما، درصد فازهای استقرار و نوسان داده های سوئیچ پا با تئوری چرخه راه رفتن مطابقت داشت، زیرا ۶۰ درصد چرخه کامل فاز استقرار بود و ۴۰ درصد باقی مانده فاز نوسانی بود [۱۲]. در این پژوهش، درصد فازهای استقرار و نوسان طبقه بندی شده از طریق ANN در مقایسه با داده های سوئیچ پا برای داده های آموزش به ترتیب ۵٫۲ و ۷٫۳ درصد کاهش یافته است. در حالی که، برای داده های آموزش ندیده میزان اختلاف فازهای استقرار و نوسانی به ترتیب ۱۹٫۷ و ۳٫۳ درصد بوده است. این نتایج نشان می دهد توانایی ANN برای تشخیص دقیق رویداد راه رفتن به مجموعه داده های آموزش - که توسط میلر [۴۵] بیان شده است - بستگی دارد. هدف از این تحقیق به کارگیری یک رویکرد یادگیری ماشین برای پیش بینی HS و TO از طریق سیگنال های EMG بود. پیش بینی HS و TO از طریق رویکرد یادگیری ماشین به ترتیب با میانگین خطای 18 ± 6 و 18 ± 21 میلی ثانیه همراه بود. نتایج به دست آمده نشان داد که سیگنال های EMG هنگام راه رفتن روی زمین دارای تنوع کمی هستند که با گزارش ارائه شده در [۱۸] مطابقت دارد. خطاهای به دست آمده در پژوهش حاضر در مقایسه با مطالعه انجام شده توسط میلر [۴۵] بیشتر بود، زیرا، میانگین اختلاف داده های جمع آوری شده توسط سیستم الکترونیک نوری همراه با نیروهای عکس العمل زمین برای HS و TO به ترتیب 10 ± 7 و 16 ± 8 میلی ثانیه بود. هیچ یک از حسگرهای غیرقابل پوشیدن نیازهای برنامه های کاربردی تشخیص رویداد راه رفتن قابل حمل از جمله شبیه سازی الکتریکی عملیاتی و نظارت و بازخورد زیستی حین راه رفتن [۳۴] را رفع نکردند. یادگیری ماشین یکی از روش های کاربردی جهت تشخیص رویداد راه رفتن خودکار است [۴۲، ۴۷]. گزارشی توسط سانچز-والدز و همکاران برای نشان دادن قابلیت منطق فازی جهت تشخیص پنج الگوی راه رفتن مختلف از طریق شتاب سنج ها - با دقت کلی ۸۴ درصد - ارائه شد [۱۳]. با رویکردی مشابه، هفت مرحله راه رفتن را می توان بر اساس حسگرهای IMU متمایز کرد [۱۵]. با در نظر گرفتن پاسخ بارگذاری و پیش نوسان جهت نشان دادن رویدادهای HS و TO، میانگین خطاهای حاصل از تحقیق به ترتیب 92 ± 11 و 44 ± 66 میلی ثانیه بود. نتایج حاصل احتمالاً به مقادیر آستانه قواعد منطق فازی مربوط می شود، زیرا، الگوریتم های مبتنی بر آستانه باید به صورت فردی تصمیم گیری شوند و برای افراد مختلف تنظیم شوند [۵۱]. در مطالعات گذشته از رویکرد اکتشافی جهت تشخیص HS و TO استفاده شده است. فورمنتو و همکاران [۳۷] با استفاده از رویکردی اکتشافی میزان خطای TO و HS را - از طریق ژيروسکوپ - به ترتیب 44 ± 132 و 36 ± 38 میلی ثانیه گزارش کردند. پس از مدتی، ترکیب اکتشافی و موجک جهت شناسایی TO - بر اساس یک شتاب سنج به کار گرفته شده در پا - پیشنهاد شد [۵۲]. اگرچه از عملکرد بهتری در مقایسه با مطالعه پیشین برخوردار بود، اما، هنگامی که طراحی سیستم، قرارگیری حسگر و یا نوع راه رفتن تغییر کند، از تکنیک های اکتشافی نمی توان استفاده مجدد داشت [۵۳]. از لحاظ تعمیم سیستم پیشنهادی، در پژوهش حاضر اختلاف زمانی بیشتری برای داده های آموزش ندیده حاصل شد. تشخیص HS بر اساس رویکرد پیشنهادی نسبت به داده های سوئیچ پا بین ۴ تا ۵۶ میلی ثانیه با تأخیر همراه بود. با این وجود، تنها یک HS زودتر از داده های سوئیچ پا بود (۵۵ میلی ثانیه) که منجر به $MAD (25 \pm 35)$ میلی ثانیه شد. برخلاف تشخیص TO، تشخیص همه مراحل با استفاده از روش پیشنهادی در مقایسه با داده های سوئیچ پا سریع تر بود. با این حال، MAD از HS بیشتر بود (49 ± 15 میلی ثانیه). این نتایج حاکی از آن است که فاز ایستادن نسبتاً دقیق است، در حالی که مرحله نوسان باید با احتیاط بیشتری تفسیر شود. با این حال،

حداکثر تأخیر شناسایی شده بالینی برای پاسخ پروتز ۲۰۰ تا ۳۰۰ میلی ثانیه است [۵۴]. همچنین، این مطالعه نشان داد که اختلاف MAD در HS و TO بین روش پیشنهادی و داده های سوئیچ پا -در همه افراد- ناچیز بوده است. لازم به ذکر است، مقدار بیشتر MAD ممکن است به دلیل دقت طبقه بندی سیستم پیشنهادی و حسگر کلید پا باشد.

۳-۴ محدودیت ها

اگرچه مدل ANN در طبقه بندی سیگنال های EMG جهت تشخیص رویداد راه رفتن نسبتاً موفق عمل کرده است، اما، باتوجه به محدودیت های موجود، روش های دیگر یادگیری ماشین نیازمند ارزیابی بیشتری هستند. در کارهای آینده باید دقت طبقه بندی بهبود بخشیده شود، زیرا ممکن است بر زمان بندی HS و TO تأثیر بگذارد. در این تحقیق، خطای زمان بندی در مقایسه با سایر سنسورهای پوشیدنی قابل قبول در نظر گرفته شد. با این وجود، پیامدهای عملی خطای زمان بندی در بازخورد زیستی دستگاه های کمکی هنوز بررسی نشده است. در تحقیق حاضر، استاندارد طلایی جهت تشخیص HS و TO وابسته به داده های سوئیچ پا بود. اگرچه سنسورهای سوئیچ پا دارای هزینه کم، فرم دهی ساده سیگنال و پاسخ دینامیکی سریع هستند، اما، اتصالات سیم و نحوه قرارگیری FSR ممکن است دقت را تحت تأثیر قرار دهند. سبک های مختلف راه رفتن می تواند منجر به قرارگیری اشتباه FSR شود. این موضوع در راه رفتن آهسته، نرمال و تغییر یافته مشاهده شده است، زیرا میانگین خطای نسبی FSR در تشخیص HS 2.8 ± 1.5 میلی ثانیه بوده است [۳۴]. بنابراین، در آینده نزدیک می توان از مرجع متفاوتی مانند GRF استفاده کرد.

۵- نتیجه گیری

هدف اصلی در این پژوهش تعیین میزان قابلیت سیگنال های EMG در تشخیص رویدادهای راه رفتن، به خصوص مراحل استقرار و نوسان بود. میزان توانایی و کاربردی بودن سیگنال های EMG جهت ارزیابی مراحل استقرار و نوسان تشریح شد. داده های نهایی نشان می دهند با استفاده از ویژگی های گروه دوم می توان داده ها را با دقت بیشتری طبقه بندی کرد. دلیل این امر به صفر نزدیک شدن بسیاری از خطاهای MSE در حین آموزش است. به طور کلی، به کارگیری روش های یادگیری ماشین در تشخیص فازهای استقرار و نوسان امکان پذیر است. در مجموع، باتوجه به اختلاف جزئی بین مقادیر MAD با مرجع استاندارد طلایی -در همه افراد- استفاده از سیگنال های EMG در تشخیص HS و TO امیدوار کننده به نظر می رسد. همچنین، حسگرهای سوئیچ پا مرجعی قابل اطمینان به شمار می روند.

منابع

- [1] S.R. Hundza, W.R. Hook, C.R. Harris, S.V. Mahajan, P.A. Leslie, C.A. Spani, L.G. Spalteholz, B.J. Birch, D.T. Commandeur, N.J. Livingston, Accurate and reliable gait cycle detection in parkinson's disease, IEEE Trans. Neural Syst. Rehabil. Eng. 22 (1) (2014) 127–137.
- [2] J. Taborri, E. Scalona, E. Palermo, S. Rossi, P. Cappa, Validation of inter-subject training for hidden markov models applied to gait phase detection in children with cerebral palsy, Sensors 15 (2015) 24514–24529.
- [3] R. Selles, M. Formanoy, J. Bussmann, P. Janssens, H. Stam, Automated estimation of initial and terminal contact timing using accelerometers; development and validation in transtibial amputees and controls, IEEE Trans. Neural Syst. Rehabil. Eng. 13 (2005) 81–88.
- [4] J.M. Jasiewicz, J.H. Allum, J.W. Middleton, A. Barriskill, P. Condie, B. Purcell, R.C. Tin Li, Gait event detection using linear accelerometers or angular velocity transducers in able-bodied and spinal-cord injured individuals, Gait Posture 24 (2006) 502–509.
- [5] T. Yan, M. Cempini, C.M. Oddo, N. Vitiello, Review of assistive strategies in powered lower-limb orthoses and exoskeletons, Robot. Auton. Syst. 64 (2015) 120–136.
- [6] T. Kikuchi, S. Tanida, K. Otsuki, T. Yasuda, J. Furusho, Development of third-generation intelligently controllable ankle-foot orthosis with compact MR fluid brake, IEEE International Conference on Robotics and Automation (2010) 2209–2214.
- [7] A. Mannini, A.M. Sabatini, Gait phase detection and discrimination between walking-jogging activities using hidden Markov models applied to foot motion data from a gyroscope, Gait Posture 36 (2012) 657–661.
- [8] J.A. Blaya, H. Herr, Adaptive control of a variable-impedance ankle-foot orthosis to assist drop-foot gait, IEEE Trans. Neural Syst. Rehabil. Eng. 12 (1) (2004) 24–31.

- [9] K. Shamaei, P.C. Napolitano, A.M. Dollar, Design and functional evaluation of aquasi-passive compliant stance control knee-ankle-foot orthosis, *IEEE Trans. Neural Syst. Rehabil. Eng.* 22 (2) (2014) 258–268.
- [10] C.D. Nikamp, M.S. Hobbelenk, J.V.D. Palen, H.J. Hermens, J.S. Rietman, J.H. Buurke, A randomized controlled trial on providing ankle-foot orthoses inpatients with (sub-)acute stroke: short-term kinematic and spatiotemporal effects and effects of timing, *Gait Posture* 55 (2017) 15–22.
- [11] O. Mazumder, A. Kundu, P. Lenka, S. Bhaumik, Robotic AFO to enhance walking capacity: initial development, *Electron. Lett.* 52 (22) (2016) 1840–1841.
- [12] J. Taborri, E. Palermo, S. Rossi, P. Cappa, Gait partitioning methods: a systematic review, *Sensors* 16 (66) (2016) 1–20.
- [13] D. Sanchez-Valdes, A. Alvarez-Alvarez, G. Trivino, Walking pattern classification using a granular linguistic analysis, *Appl. Soft Comput.* 33 (2015) 100–113.
- [14] C.M. Senanayake, S.M.N. Arosha Senanayake, Computational intelligent gait-phase detection system to identify pathological gait, *IEEE Trans. Inf. Technol. Biomed.* 14 (5) (2010) 1173–1179.
- [15] F.D. Nardo, G. Ghetti, S. Fioretti, Assessment of the activation modalities of gastrocnemius lateralis and tibialis anterior during gait: a statistical analysis, *J. Electromyogr. Kinesiol.* 23 (2013) 1428–1433.
- [16] E.J. Rechy-Ramirez, Huosheng, Bio-signal based control in assistive robots: a survey, *Digit. Commun. Netw.* (2015) 85–101.
- [17] A.J. Young, T.A. Kuiken, L.J. Hargrove, Analysis of using EMG and mechanical sensors to enhance intent recognition in powered lower limb prostheses, *J. Neural Eng.* 11 (056021) (2014) 1–12.
- [18] E. Wentink, V. Schut, E. Prinsen, J. Rietman, P. Veltink, Detection of the onset of gait initiation using kinematic sensors and EMG in transfemoral amputees, *Gait Posture* 39 (2014) 391–396.
- [19] G. Jang, J. Kim, S. Lee, Y. Choi, EMG-based continuous control scheme with simple classifier for electric-powered wheelchair, *IEEE Trans. Ind. Electron.* 63(6) (2016) 3695–3705.
- [20] T. Ogawa, T. Sato, S.-I. Takahiko Ogata, K. Yamamoto, N. Nakazawa, Kawashima, Rhythmic arm swing enhances patterned locomotor-like muscle activity in passively moved lower extremities, *IEEE Trans. Biomed. Eng.* 6 (8) (2013) 2205–2213.
- [21] H. Hel, K. Kiguchi, A study on EMG-based control of exoskeleton robots for human lower-limb motion assist, 6th International Special Topic Conference on ITAB (2007) 292–295.
- [25] D. Adiputra, S.A. Ubaidillah, H. Mazlan, M.A.A. Zamzuri, Rahman, Fuzzy logic control for ankle foot orthoses equipped with magnetorheological brake, *J. Teknol.* 78 (11) (2016) 25–32.
- [22] N. Nazmi, S.-I. Yamamoto, M.A. Abdul Rahman, S.A. Ahmad, D. Adiputra, H. Zamzuri, S.A. Mazlan, Fuzzy logic for walking patterns based on surface electromyography signals with different membership functions, *Proceedings of 2016 6th International Workshop on Computer Science and Engineering (WCSE 2016)*, vol. 16 (2016) 636–639.
- [23] N. Nazmi, M.A. Abdul Rahman, S.-I. Yamamoto, S.A. Ahmad, H. Zamzuri, S.A. Mazlan, A review of classification techniques of EMG signals during isotonic and isometric contractions, *Sensors* 16 (2016) 1–28.
- [24] M.I. Ibrahimy, M.R. Ahsan, O.O. Khalifa, Design and optimization of Levenberg-Marquardt based neural network classifier for EMG signals to identify hand motions, *Meas. Sci. Rev.* 13 (3) (2013) 142–151.
- [25] I. Elamvazuthi, N. Duy, Z. Ali, S. Su, M. Ahamed Khan, S. Parasuraman, Electromyography (EMG) based classification of neuromuscular disorders using multi-layer perceptron, *Proc. Comput. Sci.* 76 (2015) 223–228.

- [26] A. Phinyomark, P. Phukpattaranont, C. Limsakul, Feature reduction and selection for EMG signal classification, *Expert Syst. Appl.* 39 (2012) 7420–7431.
- [32] M.A. Oskoei, H. Hu, Support vector machine-based classification scheme for myoelectric control applied to upper limb, *IEEE Trans. Biomed. Eng.* 55 (8) (2008) 420–426.
- [27] N.A.I. Mohd Rosli, M.A.A. Rahman, M. Balakrishnan, T. Komeda, S.A. Mazlan, H. Zamzuri, Improved gender recognition during stepping activity for rehabilitation using the combinatorial fusion approach of EMG and HRV, *Appl. Sci.* 7 (4) (2017) 1–21.
- [28] M. Hanlon, R. Anderson, Real-time gait event detection using wearable sensors, *Gait Posture* 30 (2009) 523–527.
- [29] J. Taborri, E. Palermo, S. Rossi, P. Cappa, Gait partitioning methods: a systematic review, *Sensors* 16 (66) (2016) 1–20.
- [30] D. Sanchez-Valdes, A. Alvarez-Alvarez, G. Trivino, Walking pattern classification using a granular linguistic analysis, *Appl. Soft Comput.* 33 (2015) 100–113.
- [31] C.M. Senanayake, S.M.N. Arosha Senanayake, Computational intelligent gait-phase detection system to identify pathological gait, *IEEE Trans. Inf. Technol. Biomed.* 14 (5) (2010) 1173–1179.
- [32] F.D. Nardo, G. Ghetti, S. Fioretti, Assessment of the activation modalities of gastrocnemius lateralis and tibialis anterior during gait: a statistical analysis, *J. Electromyogr. Kinesiol.* 23 (2013) 1428–1433.
- [33] E.J. Rechy-Ramirez, N. Huosheng, Bio-signal based control in assistive robots: a survey, *Digit. Commun. Netw.* (2015) 85–101.
- [34] A.J. Young, T.A. Kuiken, L.J. Hargrove, Analysis of using EMG and mechanical sensors to enhance intent recognition in powered lower limb prostheses, *J. Neural Eng.* 11 (056021) (2014) 1–12.
- [35] E. Wentink, V. Schut, E. Prinsen, J. Rietman, P. Veltink, Detection of the onset of gait initiation using kinematic sensors and EMG in transfemoral amputees, *Gait Posture* 39 (2014) 391–396.
- [36] G. Jang, J. Kim, S. Lee, Y. Choi, EMG-based continuous control scheme with simple classifier for electric-powered wheelchair, *IEEE Trans. Ind. Electron.* 63(6) (2016) 3695–3705.
- [37] T. Ogawa, T. Sato, S.-I. Takahiko Ogata, K. Yamamoto, N. Nakazawa, Kawashima, Rhythmic arm swing enhances patterned locomotor-like muscle activity in passively moved lower extremities, *IEEE Trans. Biomed. Eng.* 6 (8) (2013) 2205–2213.
- [38] H. Hel, K. Kiguchi, A study on EMG-based control of exoskeleton robots for human lower-limb motion assist, 6th International Special Topic Conference on ITAB (2007) 292–295.
- [39] D. Adiputra, S.A. Ubaidillah, H. Mazlan, M.A.A. Zamzuri, Rahman, Fuzzy logic control for ankle foot orthoses equipped with magnetorheological brake, *J. Teknol.* 78 (11) (2016) 25–32.
- [40] N. Nazmi, S.-I. Yamamoto, M.A. Abdul Rahman, S.A. Ahmad, D. Adiputra, H. Zamzuri, S.A. Mazlan, Fuzzy logic for walking patterns based on surface electromyography signals with different membership functions, *Proceedings of 2016 6th International Workshop on Computer Science and Engineering (WCSE 2016)*, vol. 16 (2016) 636–639.
- [41] N. Nazmi, M.A. Abdul Rahman, S.-I. Yamamoto, S.A. Ahmad, H. Zamzuri, S.A. Mazlan, A review of classification techniques of EMG signals during isotonic and isometric contractions, *Sensors* 16 (2016) 1–28.

- [42] M.I. Ibrahimy, M.R. Ahsan, O.O. Khalifa, Design and optimization of Levenberg-Marquardt based neural network classifier for EMG signals to identify hand motions, Meas. Sci. Rev. 13 (3) (2013) 142–151.
- [43] I. Elamvazuthi, N. Duy, Z. Ali, S. Su, M. Ahamed Khan, S. Parasuraman, Electromyography (EMG) based classification of neuromuscular disorders using multi-layer perceptron, Proc. Comput. Sci. 76 (2015) 223–228.
- [44] R. Selles, M. Formanoy, J. Bussmann, P. Janssens, H. Stam, Automated estimation of initial and terminal contact timing using accelerometers; development and validation in transtibial amputees and controls, IEEE Trans. Neural Syst. Rehabil. Eng. 13 (2005) 81–88.
- [45] J.M. Jasiewicz, J.H. Allum, J.W. Middleton, A. Barriskill, P. Condie, B. Purcell, R.C. Tin Li, Gait event detection using linear accelerometers or angular velocity transducers in able-bodied and spinal-cord injured individuals, Gait Posture 24 (2006) 502–509.
- [46] T. Yan, M. Cempini, C.M. Oddo, N. Vitiello, Review of assistive strategies in powered lower-limb orthoses and exoskeletons, Robot. Auton. Syst. 64 (2015) 120–136.
- [47] T. Kikuchi, S. Tanida, K. Otsuki, T. Yasuda, J. Furusho, Development of third-generation intelligently controllable ankle-foot orthosis with compact MR fluid brake, IEEE International Conference on Robotics and Automation (2010) 2209–2214.
- [48] A. Mannini, A.M. Sabatini, Gait phase detection and discrimination between walking-jogging activities using hidden Markov models applied to foot motion data from a gyroscope, Gait Posture 36 (2012) 657–661.
- [49] J.A. Blaya, H. Herr, Adaptive control of a variable-impedance ankle-foot orthosis to assist drop-foot gait, IEEE Trans. Neural Syst. Rehabil. Eng. 12 (1) (2004) 24–31.
- [50] K. Shamaei, P.C. Napolitano, A.M. Dollar, Design and functional evaluation of a quasi-passive compliant stance control knee-ankle-foot orthosis, IEEE Trans. Neural Syst. Rehabil. Eng. 22 (2) (2014) 258–268.
- [51] C.D. Nikamp, M.S. Hobbelen, J.V.D. Palen, H.J. Hermens, J.S. Rietman, J.H. Buurke, A randomized controlled trial on providing ankle-foot orthoses in patients with (sub-)acute stroke: short-term kinematic and spatiotemporal effects and effects of timing, Gait Posture 55 (2017) 15–22.
- [52] M. Hanlon, R. Anderson, Real-time gait event detection using wearable sensors, Gait Posture 30 (2009) 523–527.
- [53] J. Taborri, E. Palermo, S. Rossi, P. Cappa, Gait partitioning methods: a systematic review, Sensors 16 (66) (2016) 1–20.
- [54] D. Sanchez-Valdes, A. Alvarez-Alvarez, G. Trivino, Walking pattern classification using a granular linguistic analysis, Appl. Soft Comput. 33 (2015) 100–113.
- [55] C.M. Senanayake, S.M.N. Arosha Senanayake, Computational intelligent gait-phase detection system to identify pathological gait, IEEE Trans. Inf. Technol. Biomed. 14 (5) (2010) 1173–1179.