



Hand Gesture and Movement Recognition based on Electromyogram Signals using Soft Ensembling Feature Selection and Optimized Classifier

Rezaee, Khosro ^{1*} / Ghaderi, Fardin ² / Taheri Gorji, Hamed ³ / Haddadnia, Javad ⁴

¹ - Assistant Professor, Biomedical Engineering Group, Department of Engineering, Meybod University, Meybod, Iran

² - Instructor, Biomedical Engineering Group, Department of Engineering, Meybod University, Meybod, Iran

³ - Ph.D. Student, School of Electrical Engineering and Computer Science, University of North Dakota, Grand Forks, ND 58202 USA

⁴ - Professor, Biomedical Engineering Group, Department of Engineering, Hakim Sabzevari University, Sabzevar, Iran.

ARTICLE INFO

DOI: 10.22041/IJBME.2020.123570.1580

Received: 26 March 2020

Revised: 24/6/2020-12/8/2020

Accepted: 12 August 2020

KEYWORDS

Electromyogram
Hand Gesture
Hand Movement
Fractal Dimension
Soft Ensembling
Optimal Classifier


ABSTRACT

In modern prostheses, accurate processing of surface electromyogram (sEMG) signals has a significant effect on optimal muscle control. Although these signals are useful for diagnosing neuromuscular diseases, controlling prosthetic devices and detecting hand movements, non-robustness of EMG signal-based recognition will give rise to various movement disorders. In this paper, we present an optimal approach to classify EMG signals for hand gesture and movement recognition, whose purpose is to be used as an efficient method of diagnosing neuromuscular diseases, determining the type of treatment and physiotherapy. The main assumption of this study is to improve the accuracy of recognition and therefore, we proposed a novel hand gesture and movement recognition model consists of three steps: (1) EMG signal features extraction based on time-frequency domain and fractal dimension features; (2) feature selection by soft ensembling of three procedures in which includes two sample T-tests, entropy and common wrapper feature reduction, and (3) classification based on kernel parameters optimization of SVM classifier by using Gases Brownian Motion Optimization (GBMO) algorithm. Two UC2018 DualMyo and UCI datasets have been considered to evaluate the proposed model. The first dataset is used to classify eight hand gestures and the second dataset is employed for the classification of six types of movement. The experiment results and statistical tests reveal that the designed approach has desirable performance with an average accuracy of above 98% in both datasets. Contrary to similar methods that perform classifications in finite classes with high error rates, the integrated method has satisfactory accuracy, robustness and reliability. Not only the proposed method contributes to the design of prostheses, but also provides effective outcomes for rehabilitation applications and clinical diagnosis processes.

*Corresponding Author

Address	Biomedical Group, Department of Engineering, Meybod University, Meybod, Iran		
Postal Code	8961699557	Tel	+98-35-32357500
E-Mail	kh.rezaee@meybod.ac.ir	Fax	+98-35-32353004





بازشناسی ژست‌ها و حالت‌های حرکتی دست در سیگنال‌های الکترومایوگرام با استفاده از روش هم‌جوشی نرم در انتخاب ویژگی و طبقه‌بندی کننده‌ی بهینه

رضائی، خسرو^{۱*} / قادری، فردین^۲ / طاهری گرجی، حامد^۳ / حدادنیا، جواد^۴

^۱ - استادیار، گروه مهندسی پزشکی، دانشکده‌ی فنی و مهندسی، دانشگاه میبد، میبد، ایران

^۲ - مربی، گروه مهندسی پزشکی، دانشکده‌ی فنی و مهندسی، دانشگاه میبد، میبد، ایران

^۳ - دانشجوی دکتری مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه نورث داکوتا، گرندفورکس، آمریکا

^۴ - استاد، گروه مهندسی پزشکی، دانشکده‌ی فنی و مهندسی، دانشگاه حکیم سبزواری، سبزوار، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2020.123570.1580

پذیرش: ۲۲ مرداد ۱۳۹۹

بازنگری: ۱۳۹۹/۵/۲۲-۱۳۹۹/۴/۴

ثبت در سامانه: ۷ فروردین ۱۳۹۹

چکیده

واژه‌های کلیدی

در پروتزهای مدرن، طبقه‌بندی سیگنال‌های الکترومایوگرام سطحی (sEMG) تا حد زیادی بر کنترل مطلوب عضلات اثر دارد. اگر چه این سیگنال‌ها در تشخیص بیماری‌های عصبی-عضلانی، کنترل دستگاه‌های پروتز و تشخیص حالات دست مفید هستند، بازشناسی غیرمقاوم آن‌ها می‌تواند باعث بروز عارضه‌های مختلف حرکتی شود. در این مقاله با هدف ایجاد رویکردی بهینه در طبقه‌بندی سیگنال‌های الکترومایوگرام سطحی در تشخیص نوع حرکت و نیز شناسایی ژست دست، مدلی جدید طراحی شده است که می‌تواند در تشخیص بیماری‌های عصبی-عضلانی، تعیین نوع درمان و فیزیوتراپی مورد استفاده قرار گیرد. با در نظر گرفتن چالش‌های موجود در شناسایی کلاس‌های حرکتی دست، روش پیشنهادی از سه گام تشکیل شده است. در گام اول قاب‌بندی و استخراج ویژگی از سیگنال توسط توصیف‌گرهای حوزه‌ی زمان-فرکانس و بعد فراکتال انجام شده، در مرحله‌ی دوم انتخاب ویژگی با استفاده از یک روش جدید هم‌جوشی نرم سه رویکرد آزمون-T، آنتروپی و پیش‌چسب عام صورت گرفته و در گام سوم طبقه‌بندی حالات حرکتی و ژست دست با تکیه بر بهینه‌سازی پارامترهای کرنل ماشین بردار پشتیبان توسط الگوریتم حرکت کاتوره‌ای گاز انجام شده است. دو مجموعه‌ی داده‌ی UC2018 و DualMyo جهت ارزیابی روش پیشنهادی در نظر گرفته شده که از داده‌ی نخست برای دسته‌بندی ۸ ژست حرکتی و از داده‌ی دوم برای طبقه‌بندی ۶ نوع حالت حرکت استفاده شده است. عمل کرد راه‌کار پیشنهادی با میانگین صحت بالای ۹۸٪ در هر دو مجموعه‌ی داده رضایت‌بخش می‌باشد. برخلاف رویکردهای مشابه که در آن‌ها طبقه‌بندی در تعداد طبقه‌های محدود و با سطح خطای بالا اجرا شده، روش پیشنهادی از دقت، ثبات و اعتمادپذیری قابل قبولی برخوردار است. به کارگیری این روش در طراحی پروتزهای دست موثر بوده و می‌تواند در کاربردهای توان‌بخشی و فرایندهای تشخیص بالینی نیز تاثیرگذار باشد.

*نویسنده‌ی مسئول

نشانی: گروه مهندسی پزشکی، دانشکده‌ی فنی و مهندسی، دانشگاه میبد، میبد، ایران
کد پستی: ۸۹۶۱۶۹۵۵۷
تلفن: ۳۲۳۵۷۵۰۰-۲۵-۹۸
پست الکترونیک: kh.rezaee@meybod.ac.ir
دورنگار: ۳۲۳۵۳۰۰۴-۲۵-۹۸



۱- مقدمه

تغییرات پتانسیل الکتریکی عضله از طریق ثبت سیگنال الکترومایوگرافی^۱ (یکی از سیگنال‌های زیست‌پزشکی) از فعالیت الکتریکی عضلات منقبض شده به دست می‌آید [۱، ۲]. فعالیت الکتریکی ماهیچه در طول انقباض باعث تولید سیگنال‌های الکترومایوگرافی سطحی^۲ شده که می‌تواند در تشخیص برخی از ناهنجاری‌ها موثر باشد. بر خلاف برخی از شیوه‌های دریافت سیگنال حیاتی، سیگنال‌های EMG را می‌توان به صورت غیرتهاجمی و با به کارگیری الکترودهای سطحی ثبت نمود. الکترودها روی سطح پوست قرار گرفته و یا الکترودهای سوزنی در یک واحد حرکتی عضله وارد می‌شود. در میان سیگنال‌های حیاتی، پردازش سیگنال‌های الکترومایوگرام از سهولت نسبی برخوردار بوده و از این رو تحلیل بیماری‌های خاص عضلانی، عصبی-عضلانی یا مفصلی را ممکن می‌سازد [۳].

رد پای سیگنال‌های EMG در کاربردهایی چون کنترل به دست گرفتن اجسام [۴، ۵]، دنیای مجازی [۶]، صفحه‌کلید مجازی [۷]، کنترل بازوی رباتیک [۸]، پروتزها [۹-۱۱]، کنترل صدلی چرخ‌دار [۱۲، ۱۳]، بازی‌های واقعیت مجازی، توسعه و کنترل واسط انسان-رایانه^۳ [۱۴]، فعالیت‌ها و مراقبت‌های ورزشی، ارگونومی، بیوفیدبک، طب ورزشی و فیزیوتراپی [۱۵] قابل مشاهده است. در یک مدل کنترل ماهیچه‌ای استوار بر مبنای تشخیص الگو، در ابتدا بردارهای ویژگی با استفاده از شیوه‌های مختلف توصیف صفات^۴ از سیگنال‌های ماهیچه‌ای استخراج شده و سپس برای ایجاد یادگیری در مدل‌هایی چون شبکه‌ی عصبی، ماشین بردار پشتیبان، k-نزدیک‌ترین همسایگی، درخت تصمیم، رگرسیون منطقی و شبکه‌ی بیزین ساده به کار گرفته می‌شوند. پس از آموزش طبقه‌بند، مدل توسط سیگنال‌های آزمودنی ارزیابی می‌شود. ساز و کار تشخیص الگو باید به گونه‌ای باشد که با استخراج ویژگی‌های حاصل از سیگنال EMG، امکان دست‌یابی به پاسخ مناسب فراهم شود. تا کنون فعالیت‌های متنوعی در زمینه‌ی تشخیص حرکات یا حالات اشاره‌ی دست صورت گرفته است. در مقاله‌ی [۱۶] گزارش شده است که می‌توان از سیگنال‌های EMG در تعیین عوارض و ناهنجاری‌های حرکت دست بهره گرفت. در این مقاله از الکترودهای مختلف با تعداد کانال‌های چندگانه در ثبت سیگنال استفاده شده، ویژگی‌های مختلفی استخراج گردیده و طبقه‌بندی‌هایی چون شبکه‌ی عصبی به کار گرفته شده است.

در مقاله‌ی تاکور و متیو [۱۷] برای استخراج ویژگی از تبدیل موجک گسسته استفاده شده و هم‌جوشی در طبقه‌بندی به عنوان نوآوری ذکر شده است. در این مقاله محک‌هایی چون دقت، F-Score، ماتریس مبهم و چند معیار مشابه در نظر گرفته شده، از یک مجموعه‌ی داده شامل ۶ وضعیت دست از پایگاه داده‌ی UCI [۱۸] استفاده شده و در نهایت مقدار بیشینه‌ی دقت طبقه‌بندی برابر با ۹۸٪ به دست آمده است.

در تحقیق روانگپایسام و جاین [۱۹] در گام استخراج ویژگی از بهینه‌سازی کمینه‌ی متوالی^۵ و تجزیه‌ی مقادیر منفرد^۶ روی پایگاه داده‌ی UCI استفاده شده است. تعداد ویژگی‌های بهینه برابر با ۵۰ بوده تا خروجی با دقت مناسب توسط طبقه‌بندهای k-NN، تئوری بیز، شبکه‌ی عصبی و درخت تصمیم تولید شود. در پژوهش سراوانی و هم‌کارانش [۲۰] استخراج ویژگی با روش تبدیل موجک تحلیلی انعطاف‌پذیر^۷ روی داده‌های UCI (۲۰۱۱) [۲۱] و بررسی ۱۰۰۰۰ نمونه‌ی دریافتی از ۳ مرد و ۱ زن انجام شده و معیارهای دقت، حساسیت و اختصاصیت با به کارگیری ماشین با امکان یادگیری حداکثری^۸ و قرار دادن یک کلاس در برابر سایر کلاس‌ها محاسبه شده است. دقت به دست آمده برای ۱۰ حالت طبیعی دست برابر با ۹۹/۳۶٪ بوده که در مقایسه با راه‌کارهای مشابه دقت مناسبی به حساب می‌آید.

در مقاله‌ی نایک و هم‌کارانش [۲۲] برای استخراج و کاهش ابعاد ویژگی‌ها از تحلیل مولفه‌های مستقل از سیگنال‌های پایگاه داده‌ی UCI [۲۳] استفاده شده است. این مجموعه‌ی داده شامل ۲۲ فرد (۱۱ فرد دارای درد زانو) بوده و سه وضعیت نشستن، قدم زدن و ایستادن مورد تحلیل قرار گرفته است. در تحقیق موخوپادیا و ساموئی [۲۴] با شبکه‌های عصبی عمیق به تحلیل و طبقه‌بندی اندام حرکتی فوقانی پرداخته شده است. در مقاله‌ی چانگ و هم‌کارانش [۲۵] برای طبقه‌بندی حالات زبان اشاره از روش تحلیل همبستگی کانونیکال سیگنال‌های الکترومایوگرام استفاده شده و محک‌هایی نظیر دقت برای وضعیت چندکلاسه‌ی حالات اشاره به دست آمده است.

در پژوهش شی و هم‌کارانش [۲۶] برای طبقه‌بندی حالات گوناگون حرکت بخش‌های مختلف دست از روش k-NN استفاده شده و ویژگی‌هایی چون مقدار مطلق متوسط، اندازه‌ی طول موج و تغییر وضعیت علامت اشاره استخراج شده است. در پژوهشی مشابه تحقیق [۲۰]، برای استخراج ویژگی از روش تبدیل موجک Q-عاملی قابل تنظیم استفاده شده، طبقه‌بندی

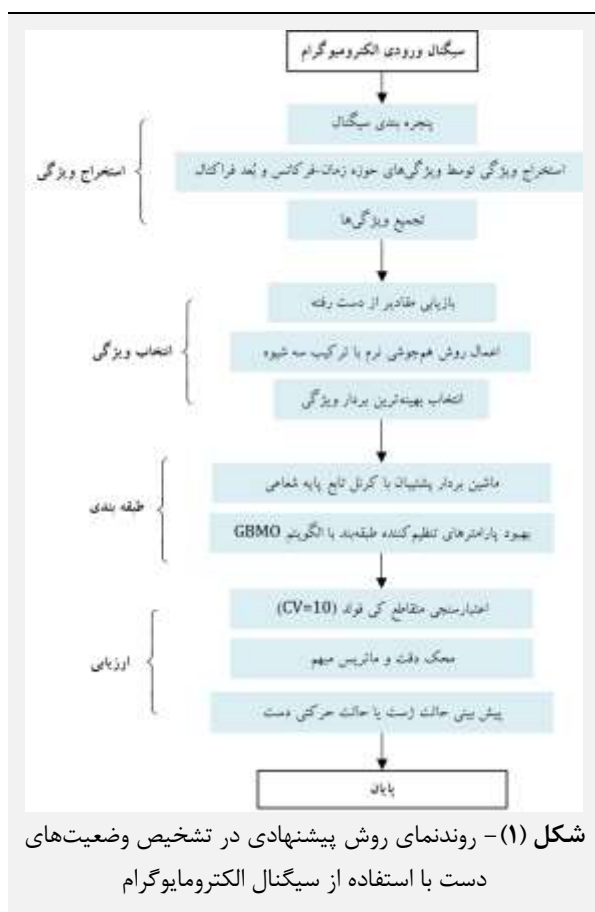
^۵ Sequential Minimal Optimization (SMO)^۶ Singular Value Decomposition (SVD)^۷ Flexible Analytic Wavelet Transform (FAWT)^۸ Extreme Learning Machine (ELM)^۱ Electromyography (EMG)^۲ Surface Electromyography (sEMG)^۳ Human-Computer Interface (HCI)^۴ Feature Description

است. شیوه‌ی استخراج ویژگی ترکیبی با به کارگیری ویژگی‌های حوزه‌ی زمان-فرکانس تا حد زیادی روی فرایند استخراج ویژگی از سیگنال‌های sEMG موثر بوده است. روش هم‌جوشی نرم سبب شده است تا بهترین دسته‌ی ویژگی‌ها از مجموعه‌ی بردار ویژگی استخراج شده به دست آید. طبقه‌بندی شامل ماشین بردار پشتیبان بهینه شده توسط مدل بهینه‌سازی حرکت کاتوره‌ای گاز است که یکی دیگر از نوآوری‌های روش پیشنهادی به شمار می‌رود.

در ادامه در بخش ۲، بخش‌های مختلف الگوریتم روش پیشنهادی شرح داده شده، در بخش ۳، مراحل اجرای الگوریتم و نتایج آزمایشی ارائه شده و در نهایت در بخش ۴ نتیجه‌گیری از تحقیق انجام شده است.

۲- مواد و روش‌ها

در روش پیشنهادی، گام‌های پنجره‌بندی سیگنال، استخراج ویژگی، بازیابی مقادیر از دست رفته، هنجارسازی، انتخاب ویژگی، طبقه‌بندی بهینه شده و در نهایت ارزیابی انجام شده است. در ادامه هر یک از مراحل به تفکیک مطابق با روندنمای شکل (۱) معرفی شده است.



۱۰ حالت حرکتی دست با روش چندکلاسی ماشین بردار پشتیبان بهینه شده با روش کم‌ترین مربعات خطا انجام شده و در نهایت دقت ۹۷/۷۴٪ به دست آمده است.

ردپای استفاده از مدل‌های یادگیری جدید چون انتقال یادگیری^۱ مبتنی بر شبکه‌های عمیق [۲۹] یا شبکه‌های عصبی بازگشتی [۳۰] برای تشخیص حالات دست در تحلیل سیگنال‌های الکترومیوگرام نیز به چشم می‌خورد.

سیگنال‌های EMG به طور مستقیم با حرکت عضلات انسان در ارتباط است. این سیگنال‌ها در زمینه‌های مختلف تشخیص ناهنجاری حرکت، شناسایی بیماری‌های عصبی-عضلانی و نیز در توان‌بخشی با ایجاد سیگنال‌های کنترلی در پروتزهایی نظیر پروتز دست، بازوها و اندام تحتانی در ارتباطات مدرن میان انسان و ماشین کاربرد دارند [۱، ۲۴]. طراحی یک دست مصنوعی می‌تواند کیفیت زندگی افراد معلول را تا حد زیادی ارتقا دهد [۳۱، ۳۲]. برخی از ویژگی‌های موثر را می‌توان از سیگنال‌های الکترومیوگرام استخراج کرد که اطلاعاتی در مورد فعالیت عضلات برای کنترل پروتز ارائه می‌دهند. با این حال تشخیص دقیق حرکات دست با استفاده از سیگنال‌های الکترومیوگرام با چالش‌های مختلفی همراه است. برای از بین بردن این مشکلات و بهبود عمل‌کرد طبقه‌بندی باید از ترکیب مناسب روش‌های استخراج یا انتخاب ویژگی و رویه‌های کاهش ابعاد استفاده شود. علاوه بر این به کارگیری طبقه‌بندی بهینه شده باعث کاهش خطا و به تبع آن انتخاب صحیح کلاس مربوط به حرکت بر اساس سیگنال الکترومیوگرام می‌شود [۳۳].


اگر چه پروتزهای دست توسط سیگنال‌های EMG کنترل می‌شوند، اما بازشناسی غیرمقاوم حرکات دست با به کارگیری این سیگنال باعث بروز عارضه‌های مختلف حرکتی می‌شود. به منظور کاهش این عوارض و بهبود تشخیص اندام حرکتی درگیر، به مدل‌های مناسبی نیاز است که توانایی پردازش سیگنال‌های sEMG با ماهیت غیرایستا را داشته باشند.

در این تحقیق یک روش ترکیبی کارآمد در تشخیص سیگنال الکترومیوگرام برای کنترل پروتز دست ارائه شده است. روش پیشنهادی شامل برهم‌نهی ویژگی‌های حوزه‌ی زمان-فرکانس و بعد فراکتال بوده که تا حد قابل ملاحظه‌ای در آنالیز سیگنال‌های حیاتی موثر واقع می‌شود. در هر دو مجموعه‌ی داده، انتخاب بهترین ویژگی‌ها به شیوه‌ی هم‌جوشی نرم با استفاده از سه شیوه‌ی موثر انجام شده است. هدف این تحقیق ارائه‌ی روشی برای طبقه‌بندی سیگنال‌های الکترومیوگرام در کنترل موثر پروتز دست در توسعه‌ی مدل بازشناسی مقاوم

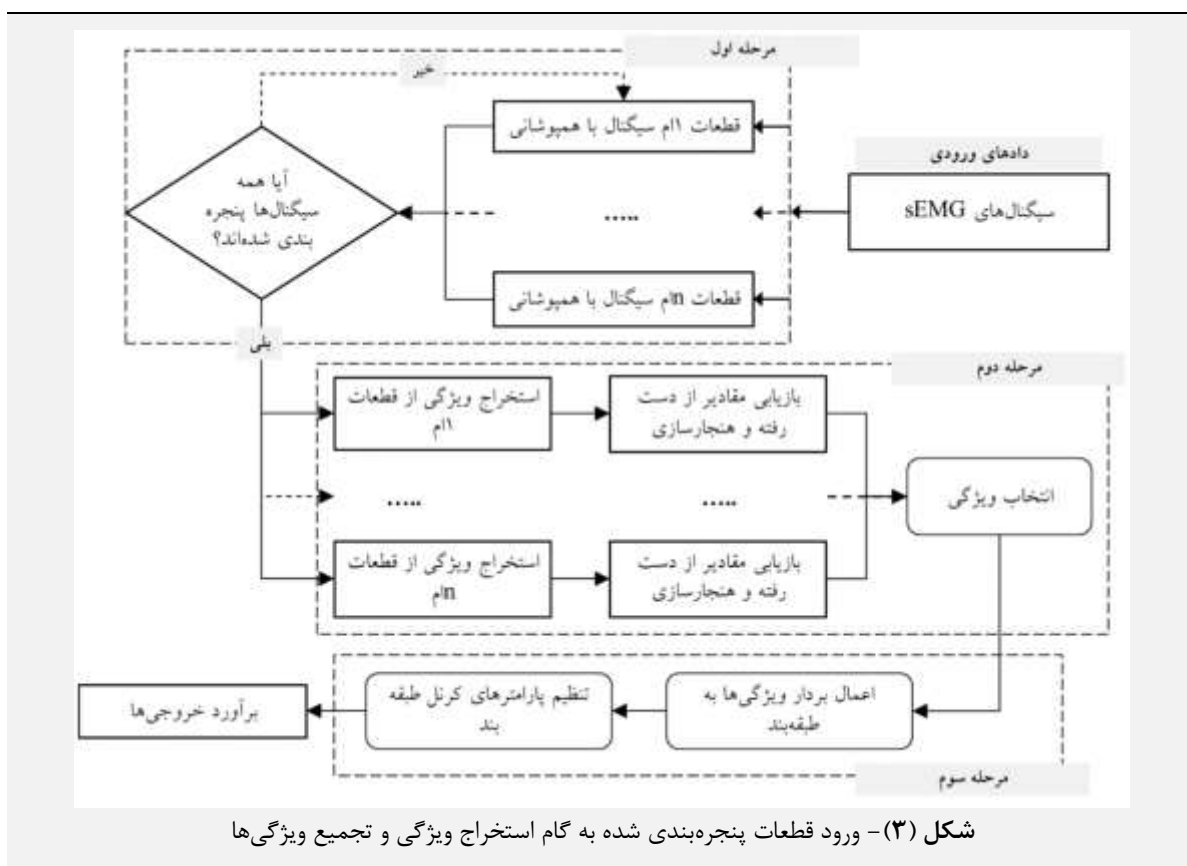
^۱ Transfer Learning

۱-۲- استخراج ویژگی

از آن‌جا که سیگنال EMG در وضعیت‌های مختلف دارای طول زیادی است، بر اساس فرکانس نمونه‌برداری به قطعات برابر تقسیم شده است. بدین منظور از یک قاب استفاده شده که به فواصل زمانی مشخص روی سیگنال اصلی قرار گرفته است. طول زمانی هر قاب بنا به دقت نهایی تعیین شده و حدود ۲۰ تا ۵۰ درصد هم‌پوشانی میان دو پنجره در نظر گرفته شده است. نحوه‌ی قاب‌بندی جهت ایجاد قطعات استخراج ویژگی در شکل (۲) و روندنمایی از پنجره‌بندی سیگنال و آماده‌سازی آن جهت استخراج ویژگی در شکل (۳) ارائه شده است.



شکل (۲) - قاب‌بندی سیگنال الکترومایوگرام جهت استخراج ویژگی



شکل (۳) - ورود قطعات پنجره‌بندی شده به گام استخراج ویژگی و تجمیع ویژگی‌ها

ویژگی فرکانس متوسط، فرکانس میانگین، پیک فرکانسی، توان متوسط، توان نهایی و نسبت فرکانسی) می‌باشد. دسته‌ی دوم ویژگی‌های استخراج شده ویژگی‌های بعد فراکتال شامل ابعادی چون کتز، هیگوچی، پتروسین، بعد همبستگی و موارد مشابه دیگر بوده که به صورت زیر تعریف می‌شوند.

۱-۱-۲- بعد همبستگی

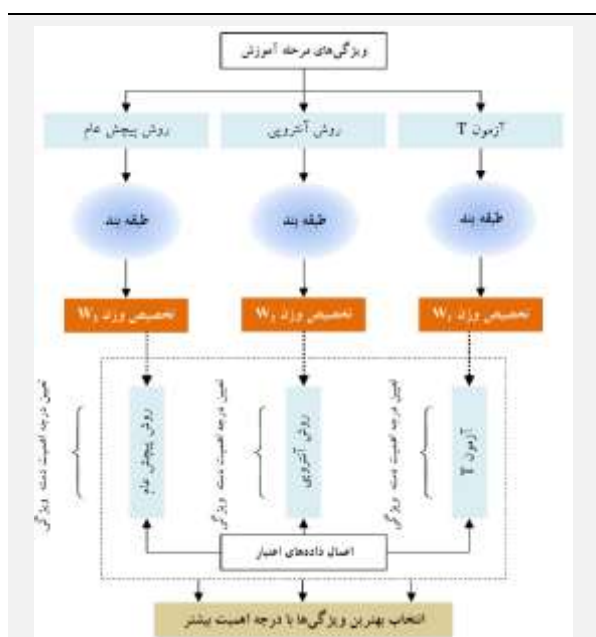
در تئوری فراکتال یک سیگنال، ابعاد همبستگی (۷) معیاری از ابعاد فضای اشغال شده توسط مجموعه‌ای از نقاط تصادفی بوده که اغلب به عنوان نوعی بعد فراکتال شناخته می‌شود. در بعد اول، در گام نخست فاصله‌ی میان هر دو جفت از نقاط داخل

چالش اصلی پیاده‌سازی پروتز کنترل مایوالکتریک، ابعاد بالای داده‌های موجود در سیگنال‌های الکترومایوگرام است. برای کاهش ابعاد داده‌ها، دو دسته‌ی ویژگی با قابلیت حفظ اطلاعات سیگنال‌ها از داده‌ها استخراج شده است. ویژگی‌های دسته‌ی اول شامل ویژگی‌های حوزه‌ی زمان (۱۴) ویژگی انتگرال سیگنال، مقدار متوسط مطلق، مقدار مطلق گشتاورهای زمانی مرتبه‌ی ۳، ۴ و ۵، واریانس سیگنال، ریشه‌ی میانگین مربعات، طول شکل موج، عبور از صفر، میانگین مطلق متوسط انحراف، ضرایب خودکار پس‌رونده، مرتبه‌های ۷، انتگرال مربعات جدایی‌پذیر و ساده، میانگین تغییر دامنه، تفاوت مقدار انحراف استاندارد مطلق و دامنه‌ی ویلسون) و حوزه‌ی فرکانس (۶

استفاده شده تا بهترین خط تقریبی با روش مربعات کم‌ترین میزان خطا در $\text{Log}(L(k))$ و بر اساس $\text{Log}(k^{-1})$ شکل گیرد.

۲-۲- انتخاب ویژگی

پیش از انتخاب ویژگی، با استفاده از روش‌های K نزدیک‌ترین همسایگی و کمینه-بیشینه به ترتیب به بازیابی مقادیر از دست رفته‌ی احتمالی و هنجارسازی ویژگی‌ها پرداخته شده و انتخاب ویژگی به شیوه‌ی هم‌جوشی نرم از طریق سه روش آزمون T ، آنتروپی و معیار پیچش عام پیاده‌سازی شده است (شکل ۴).



شکل (۴) - اعمال هم‌جوشی نرم و تعیین وزن‌های سه روش انتخاب ویژگی برای به کارگیری جهت اعمال به داده‌های اعتبار

۲-۲-۱- آزمون T

این رویکرد دو نمونه‌ی آزمون فرضی پارامتری را در بر گرفته و استقلال تفاوت میانگین میان دو نمونه را از داده‌ی معنی‌دار بررسی می‌کند (رابطه‌ی ۸) [۳۴].

$$t = (\mu_1 - \mu_2) \times \left(\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2} \right)^{-0.5} \quad (8)$$

در این رابطه، μ_1 و μ_2 میانگین، σ_1 و σ_2 انحراف استاندارد و n_1 و n_2 اندازه‌ی نمونه‌ها می‌باشد.

۲-۲-۲- آنتروپی

این معیار با نام‌های فاصله‌ی کولبک-لایبلا^۴ یا واگرایی نیز شناخته شده [۳۵] و در آن فرض می‌شود که کلاس‌های مورد

فضای ویژگی و در محیط فاز محاسبه شده و در گام دوم انتگرال همبستگی $C(N, r)$ و D_2 با روابط (۳-۱) تخمین زده شده است.

$$C(N, r) = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1}^N \theta(r - \|v(j) - v(i)\|), \quad i \neq j \quad (1)$$

$$\theta(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (2)$$

$$D_2 = \lim_{r \rightarrow 0} \frac{\log_2 C(N, r)}{\log_2(r)} \quad (3)$$

در این روابط، علامت نرم نمایان‌گر فاصله‌ی اقلیدسی، r شعاع همسایگی اطراف $V(j)$ ، N تعداد نقاط، θ تابع پله‌ی واحد و V بردار فضای فاز بوده که به صورت رابطه‌ی (۴) تعیین شده و در آن m بعد جاسازی و τ تاخیر زمانی است.

$$V_m(i) = X(i), X(i + \tau), \dots, X(i + (m - 1)\tau) \quad (4)$$

۲-۱-۲- بعد فراکتال

میزان پیچیدگی، بی‌نظمی و آشوب‌ناکی سیگنال با بعد فراکتال تعیین می‌شود. برای برآورد بعد فراکتال الگوریتم‌های زیادی مانند روش پتروسین^۱، الگوی کنتز^۲ و شیوه‌ی هیگوجی^۳ وجود دارد که در میان آن‌ها روش هیگوجی تخمین مناسبی را از بعد فراکتال در مورد بخش‌های کوتاه سیگنال با سرعت بالا در اختیار قرار می‌دهد. برای برآورد بعد فراکتال از سری داده‌های ورودی X سری جدیدی مطابق روابط (۵) و (۶) در نظر گرفته شده است.

$$X = \{X(1), X(2), \dots, X(N)\} \quad (5)$$

$$X_m^k = \left\{ X(m), X(m+k), X(m+2k), \dots, X\left(m + \left\lceil \frac{N-m}{k} \right\rceil k\right) \right\} \quad (6)$$

در این روابط، m نقطه‌ی ابتدایی هر سری و $[\]$ علامت جز صحیح است و x_m^k و طول $L_m(k)$ به صورت زیر تعریف می‌شود.

$$L_m(k) = \frac{\sum_{i=1}^{N-m} |X(m+ik) - X(m+(i-1)k)| (N-1)}{\left\lceil \frac{N-m}{k} \right\rceil k} \quad (7)$$

در این رابطه N بیان‌گر تعداد نمونه‌های مورد نیاز است. برای هر مقدار K ، تعداد K طول برآورد شده و میانگین آن به عنوان طول میانگین محاسبه شده است. این فرایند تا K_{\max} تکرار شده و $L(k)$ بعدی برابر با k^{-1} به دست آمده است. سپس از هیگوجی

^۳ Higuchi

^۴ Kullback-Liebler

^۱ Petrosian

^۲ Katz

برگزیده شود، کارایی ماشین بردار پشتیبان در دسته‌بندی صحیح افزایش می‌یابد.

$$K(X, X_i) = \exp(-\gamma \|X - X_i\|^2 \times (2\sigma^2)^{-1}) \quad (11)$$

دلیل استفاده از این کرنل در طبقه‌بندی، توانایی آن در آنالیز داده‌های با ابعاد بالا و تعداد کم پارامترهای تنظیم‌کننده‌ی کرنل (γ و σ) در مقایسه با سایر کرنل‌ها است. برای استفاده از این کرنل باید دو پارامتر σ و γ (پارامترهای تنظیم‌کننده‌ی ابر صفحه) به طور دقیق تعیین شود. در الگوریتم بهینه‌سازی کاتوره‌ای گاز با الهام از ماهیت حرکت مولکولی در گازها روشی برای جست‌وجوی فضای مساله‌ی بهینه‌سازی الگوریتم SVM ارائه شده که مراحل آن به صورت زیر است.

۱- در فضای جست‌وجو یک سری از مولکول‌های گاز به طور تصادفی تولید می‌شود.

۲- برای هر مولکول به طور تصادفی شعاعی در فاصله‌ی $[0, 1]$ در نظر گرفته می‌شود.

۳- مقداردهی اولیه‌ی دمای سیستم (پارامتری برای اطمینان از هم‌گرایی الگوریتم) انجام می‌شود.

۴- سرعت (v_t) و موقعیت (x_t) مولکول‌ها با استفاده از روابط زیر محاسبه و به‌روزرسانی می‌شود که در آن m وزن و k ثابت بولتزمن (مربوط به انرژی و دمای محیط) است (واحدهای SI).

$$v_t = v_{t-1} + (3kT \times m^{-1})^{1/2} \quad (12)$$

$$X_t = X_{t-1} + v_t \quad (13)$$

۵- تابع هزینه برای ارزیابی پاسخ‌های دریافتی فراخوانی شده و بهترین پاسخ‌ها برای مقایسه با نتایج حفظ می‌شود.

۶- هر مولکول به جای جهات مختلف در شعاع‌های مختلف نوسان می‌کند [۳۶].

۷- برای ارزیابی پاسخ‌ها از عمل‌کرد تابع هزینه استفاده شده و بهترین پاسخ‌ها برای مقایسه با نتایج نگهداری می‌شود.

پارامترهای کرنل توسط داده‌های اعتبار تعیین شده و به مرحله‌ی نخست تولید داده‌ی آموزش اول و داده‌ی آزمایشی منتقل می‌شود. دقت نهایی آزمایش بر اساس پارامترهای تنظیم‌کننده‌ی است که با تابع هزینه برآورد می‌شود. در واقع الگوریتم کاتوره‌ای دارای یک تابع هزینه بوده که با استفاده از روال تعیین شده در آن در صدد کمینه‌سازی خطا است. خطای تابع هزینه را می‌توان بر اساس الگوریتم ماشین بردار پشتیبان به این صورت تعریف کرد که خطای ناشی از طبقه‌بندی داده‌های

نظر در آزمون به صورت نرمال توزیع یافته است. این رابطه که امتیاز آنتروپی نیز نام دارد به صورت زیر بیان می‌شود.

$$e = \frac{1}{2} \left[\left(\frac{\sigma_1^2}{\sigma_2^2} + \frac{\sigma_2^2}{\sigma_1^2} - 2 \right) + \left(\frac{1}{\sigma_2^2} + \frac{1}{\sigma_1^2} \right) (\mu_1 - \mu_2)^2 \right] \quad (9)$$

۲-۲-۳- پیش‌عام

در این روش ابتدا ویژگی‌های مربوط به صفات استخراجی در چند گروه مشخص تقسیم‌بندی شده و برای هر گروه (G_i) یک امتیاز (Sc_i) مطابق رابطه‌ی (۱۰) تعلق می‌گیرد. سپس گروه‌ها بر اساس امتیاز دریافتی مرتب شده و گروهی که بر اساس بهترین ویژگی‌ها در راس این امتیازبندی قرار گیرد به عنوان خروجی اولیه در نظر گرفته می‌شود.

$$Sc_i = \frac{\delta_{i+} - \varepsilon_{i+}}{\delta_{i-} + \varepsilon_{i-}} \quad (10)$$

در این رابطه، δ_{i+} و ε_{i+} به ترتیب نمایانگر انحراف متوسط و انحراف استاندارد صفات استخراجی و δ_{i-} و ε_{i-} به ترتیب بیانگر انحراف متوسط و انحراف استاندارد نمونه‌های غیر از کلاس مورد بررسی می‌باشند.

در مرحله‌ی آموزش این مدل دسته‌ی صفاتی به عنوان ویژگی با اهمیت برگزیده شده که در بین سه طبقه‌بند مشابه بیش‌ترین رای وزنی را از آن خود کند. تقسیم داده‌های آموزش و اعتبار با روش K-fold ($CV=10$) انجام شده و میانگین دقت فولدها در مرحله‌ی آموزش به عنوان وزن نهایی هر روش انتخاب ویژگی در نظر گرفته شده است. با اعمال داده‌های اعتبار، ویژگی‌ها بر اساس درجه‌ی اهمیت آن‌ها در مرحله‌ی آموزش مرتب‌سازی شده است. این تطابق متناسب با حداقل تعداد صفاتی است که بالاترین دقت را ایجاد کند. طبقه‌بند مورد استفاده جهت ایجاد وزن گام آموزش، SVM با کرنل تابع پایه‌ی شعاعی است.

۲-۳- طبقه‌بندی

در این‌جا از طبقه‌بند ماشین بردار پشتیبان^۱ استفاده شده که هدف اصلی آن یافتن یک فرافضه‌ی (برصفحه^۲) بهینه به عنوان یک سطح تصمیم‌گیری است به طوری که حاشیه‌ی میان کلاس‌ها را بیشینه کند. در واقع بهینه‌سازی بدون هیچ تغییری در ماهیت مساله با به کارگیری تابع انتقال Φ انجام شده و داده‌ها به فضایی با ابعاد بالاتر نگاشت شده تا در این فضا سطح تصمیم‌گیری به صورت خطی تعیین شود. به طور معمول زمانی که کرنل غیرخطی و به خصوص پایه‌ی شعاعی یا چندجمله‌ای

^۱ Hyper-Plane

^۱ Support Vector Machine (SVM)

صورت ۱۶ کاناله از ۱۱۰ سوژه و با فرکانس نمونه‌برداری ۲۰۰ هرتز گردآوری شده و در بر دارنده‌ی حالات استراحت (G_0)، مشت بسته (G_1)، دست بسته (G_2)، ژست موج دست به سمت داخل (G_3)، ژست موج به سمت بیرون (G_4)، دوبار ضربه (G_5)، دست به سمت پایین (G_6) و دست به سمت بالا (G_7) است. هرچند برخی از ژست‌ها در این حالت دارای هم‌پوشانی در عضله‌ی فعال هستند اما امکان دسته‌بندی با خطای کم و با انتخاب روش مناسب وجود دارد. هر سیگنال در طول زمانی ۵۰ ثانیه ضبط شده و در نتیجه گام زمانی معادل ۱۰۰۰۰ است. مطابق روش‌های محاسبه‌ی تعداد قاب مناسب [۳۹]، طول بازه‌ی زمانی هر پنجره را می‌توان در فاصله‌ی ۲۰۰-۳۰۰ میلی‌ثانیه در نظر گرفت که البته تعداد درست آن به دقت نهایی طبقه‌بندی وابسته است. طول هر قاب برابر با ۲۰۰ میلی‌ثانیه در نظر گرفته شده که با فرض ۴۰٪ هم‌پوشانی میان قاب‌ها، تعداد کل آن‌ها برای یک ژست از سیگنال EMG برابر با ۱۲۴۴ است. از آن‌جا که از هر فرد ۸ ژست دریافت شده و در مجموع ۱۱۰ سوژه وجود دارد، حدود ۱،۱۰۰،۰۰۰ نمونه برای تمام ژست‌ها ایجاد شده است.

اعتبار اعمال شده به آن را کمینه کند. از این رو مولکول‌های گاز با انتشار در فضای جواب به عنوان پاسخ‌های اولیه‌ی σ و γ با جست‌وجو در فضای جواب و برازش در هر مرحله از الگوریتم کاتوره‌ای گاز منجر به برآورد دقت می‌شود. کم‌ترین میزان خطای ناشی از جست‌وجو توسط مولکول‌های گاز با در نظر گرفتن σ و γ منجر به ذخیره‌ی این مقادیر شده و در مرحله‌ی بعد با اعمال داده‌های آزمایشی به مدل از آن‌ها برای برازش دقت استفاده می‌شود.

۳- یافته‌ها و بحث

رایانه‌ی مورد استفاده جهت پیاده‌سازی دارای پردازنده‌ی Intel(R), Core(TM), Core i7, GB ۴ RAM و سیستم عامل ۶۴ بیتی می‌باشد. هم‌چنین از محیط برنامه‌نویسی متلب نسخه‌ی ۲۰۱۹b استفاده شده و نتایج در قالب خروجی‌های کمی و کیفی ارائه شده است. برای ارزیابی روش نیز از دو مجموعه‌ی سیگنال الکترومایوگرام استفاده شده است. در مجموعه‌ی اول^۱ (۲۰۱۸) سیگنال‌های EMG شامل ۸ حالت دست در وضعیت اشاره است (شکل ۵) [۳۷، ۳۸]. داده‌ها به



شکل (۵) - حالات مختلف حرکت در وضعیت اشاره‌ی دست شامل حالت‌های استراحت (G_0)، مشت بسته (G_1)، دست بسته (G_2)، ژست موج دست به سمت داخل (G_3)، ژست موج به سمت بیرون (G_4)، دوبار ضربه (G_5)، دست به سمت پایین (G_6) و دست به سمت بالا (G_7)

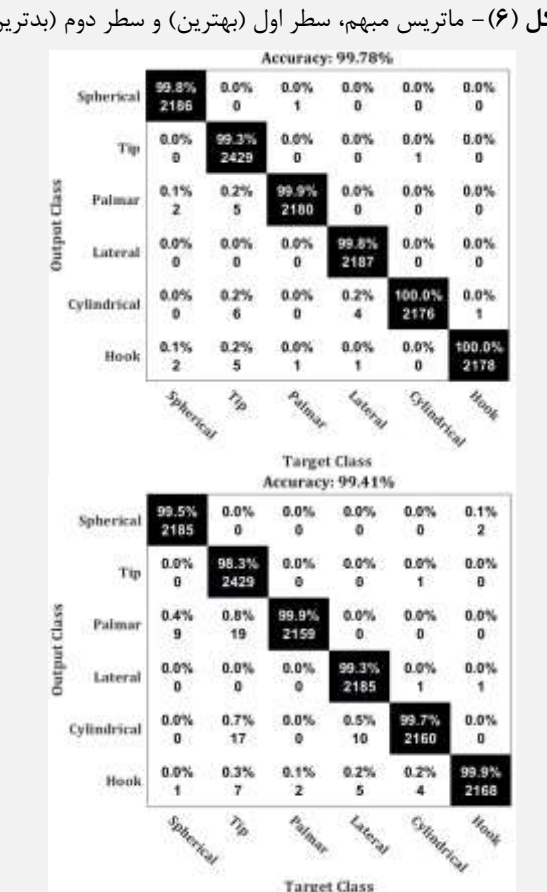
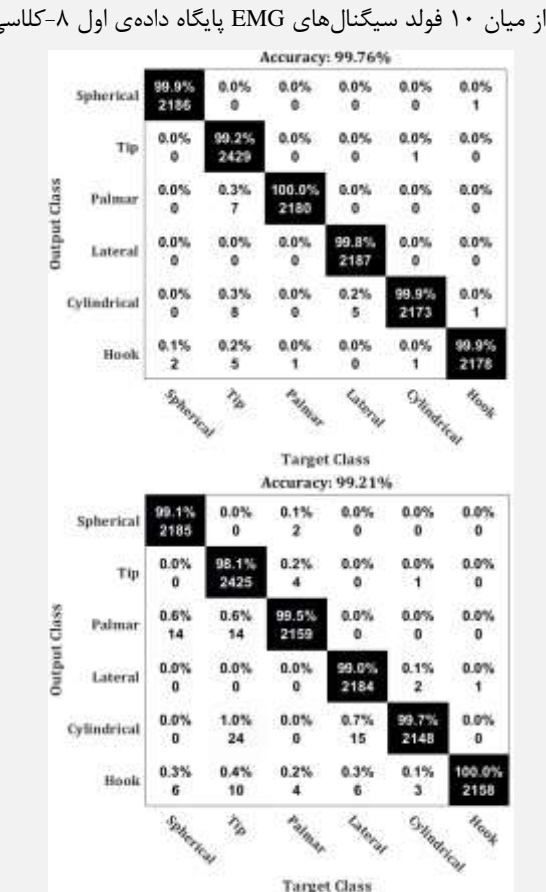


بنابراین در مجموع حدود ۱۳۵،۰۰۰ نمونه از ۵ سوژه و ۶ حالت حرکتی وجود دارد.

نتایج بر اساس ماتریس مبهم در طبقه‌بندی با روش اعتبارسنجی K-Fold ($CV=10$) برای بهترین دو فولد و بدترین دو فولد در داده‌های اول و دوم به ترتیب در شکل‌های (۶) و (۷) ارائه شده است.

برای محاسبه‌ی دقت متوسط نهایی در هر پایگاه داده، آزمایش برای ۵ مرتبه با دسته‌ی فولدهای ۱۰-تایی تکرار شده و نتایج به تفکیک برای هر دو مدل سیگنال با شرایط مختلف اعمال ویژگی‌ها در جدول (۱) ارائه شده که در آن انتخاب ویژگی در هر سه مدل از ویژگی‌ها به شیوه‌ی هم‌جوشی اعمال شده است.

مجموعه‌ی دوم شامل سیگنال‌های sEMG [۴۰] بوده که در UCI منتشر شده و در بر گیرنده‌ی ۶ حالت حرکت دست (شامل نگه داشتن دست برای اجسام کروی، اجسام کوچک، با کف دست و انگشتان، اشیای نازک، اجسام استوانه‌ای و با قلاب کردن به دور جسم) از ۵ فرد سالم (۳ زن و ۲ مرد، بدون هیچ‌گونه سابقه‌ی اختلالات عضلانی) است. فرکانس نمونه‌برداری برابر با ۵۰۰ هرتز بوده، سوژه‌ها هر حرکت را ۶ ثانیه با ۳۰ بار تکرار انجام داده و نویز سیگنال‌ها توسط فیلترهای باترورث و ناچ زدوده شده است. مانند حالت قبل با فرض ۴۰٪ هم‌پوشانی میان قاب‌ها و طولی معادل ۲۰۰ میلی‌ثانیه، تعداد کل پنجره‌ها برای یک حالت حرکتی از سیگنال EMG برابر با ۴۴۹۴ قاب است.

^۱ UC2018 DualMyo



شکل (۶) - ماتریس مبهم، سطر اول (بهترین) و سطر دوم (بدترین) ۴ فولد از میان ۱۰ فولد سیگنال‌های EMG پایگاه داده‌ی اول ۸-کلاسی

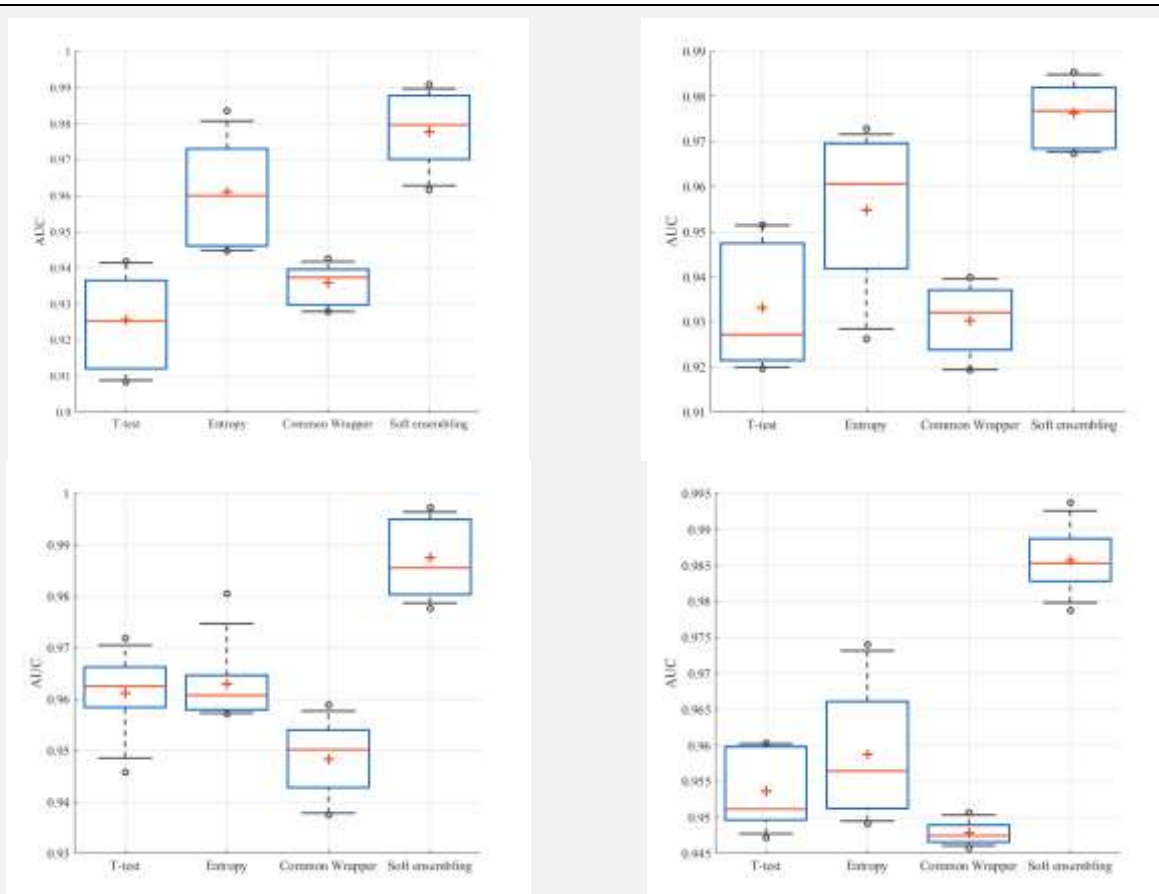
شکل (۷) - ماتریس مبهم، سطر اول (بهترین) و سطر دوم (بدترین) ۲ فولد از میان ۱۰ فولد سیگنال‌های sEMG پایگاه داده‌ی دوم ۶-کلاسی

جدول (۱) - نتایج حاصل از طبقه‌بندی به روش K-Fold با $K=10$ در ۵ بار تکرار روش و اعمال سه مدل از ویژگی

نوع ویژگی‌ها	پایگاه داده‌ی اول (ژست دست)			پایگاه داده‌ی دوم (حالات حرکتی)		
	بهترین مقدار	مقدار متوسط	بدترین مقدار	بهترین مقدار	مقدار متوسط	بدترین مقدار
10-fold (1)	زمان-فرکانس	0.93 ± 0.04	0.91 ± 0.05	0.89 ± 0.07	0.94 ± 0.05	0.94 ± 0.06
	بعد فراکتال	0.95 ± 0.03	0.92 ± 0.04	0.91 ± 0.05	0.94 ± 0.03	0.93 ± 0.04
	تجمیع ویژگی	0.99 ± 0.01	0.98 ± 0.01	0.98 ± 0.01	0.99 ± 0.01	0.99 ± 0.01
10-fold (2)	زمان-فرکانس	0.91 ± 0.04	0.88 ± 0.06	0.86 ± 0.06	0.92 ± 0.06	0.90 ± 0.07
	بعد فراکتال	0.94 ± 0.03	0.91 ± 0.03	0.89 ± 0.07	0.95 ± 0.03	0.95 ± 0.04
	تجمیع ویژگی	0.98 ± 0.01	0.98 ± 0.01	0.97 ± 0.01	0.99 ± 0.01	0.98 ± 0.01
10-fold (3)	زمان-فرکانس	0.90 ± 0.04	0.90 ± 0.04	0.88 ± 0.06	0.93 ± 0.03	0.93 ± 0.05
	بعد فراکتال	0.92 ± 0.02	0.91 ± 0.04	0.87 ± 0.05	0.96 ± 0.03	0.95 ± 0.04
	تجمیع ویژگی	0.99 ± 0.01	0.98 ± 0.01	0.97 ± 0.01	0.99 ± 0.01	0.98 ± 0.01
10-fold (4)	زمان-فرکانس	0.89 ± 0.05	0.88 ± 0.05	0.86 ± 0.06	0.93 ± 0.04	0.93 ± 0.04
	بعد فراکتال	0.92 ± 0.03	0.92 ± 0.04	0.90 ± 0.04	0.95 ± 0.04	0.95 ± 0.05
	تجمیع ویژگی	0.98 ± 0.01	0.98 ± 0.01	0.97 ± 0.01	0.99 ± 0.01	0.99 ± 0.01
10-fold (5)	زمان-فرکانس	0.93 ± 0.05	0.91 ± 0.05	0.89 ± 0.06	0.93 ± 0.04	0.92 ± 0.05
	بعد فراکتال	0.95 ± 0.02	0.92 ± 0.04	0.91 ± 0.04	0.96 ± 0.03	0.95 ± 0.04
	تجمیع ویژگی	0.98 ± 0.01	0.98 ± 0.01	0.97 ± 0.01	0.99 ± 0.01	0.98 ± 0.01

تکرار ارائه شده و مقایسه‌ای میان روش هم‌جوشی نرم و سه روش دیگر انجام شده است.

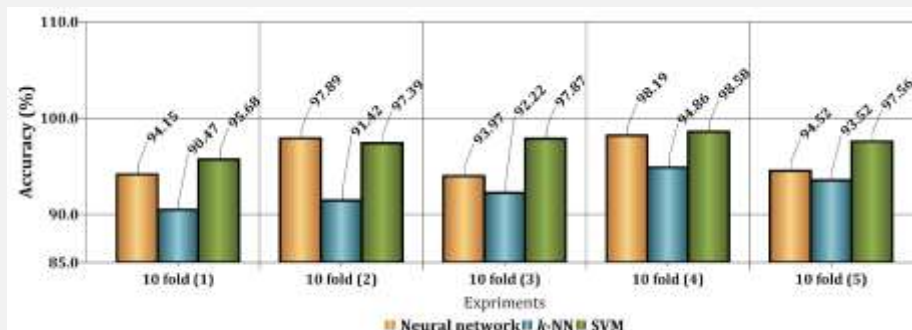
در مجموعه‌ی شکل (۸) با محاسبه‌ی مساحت زیر منحنی ROC نمودار جعبه‌ای از روش‌های انتخاب ویژگی در دو بار



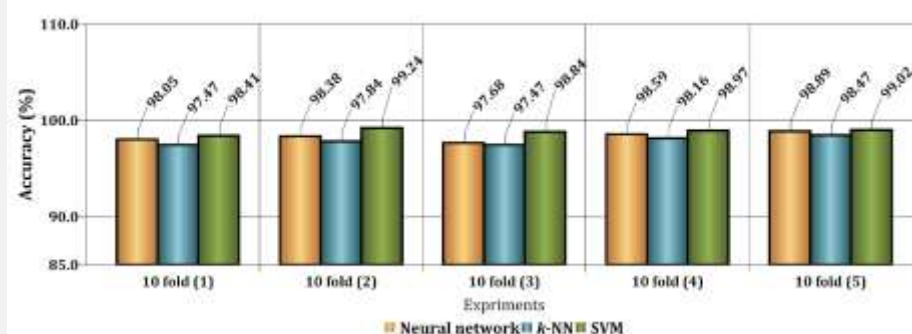
شکل (۸) - مقایسه‌ی عمل کرد روش‌های انتخاب ویژگی بر اساس معیار مساحت زیر منحنی ROC، سطر اول و دوم با دو بار تکرار آزمایش برای داده‌ی اول و دوم

در شکل‌های (۱۱) و (۱۲) با محاسبه‌ی معیار کاپا (نمایان‌گر میزان تعمیم‌پذیری) به منظور بیان دلیل به کارگیری، مقایسه‌ای میان عمل‌کرد الگوریتم کاتوره‌ای گاز و الگوریتم‌های ژنتیک و ازدحام ذرات برای تنظیم پارامترهای طبقه‌بند صورت گرفته است.

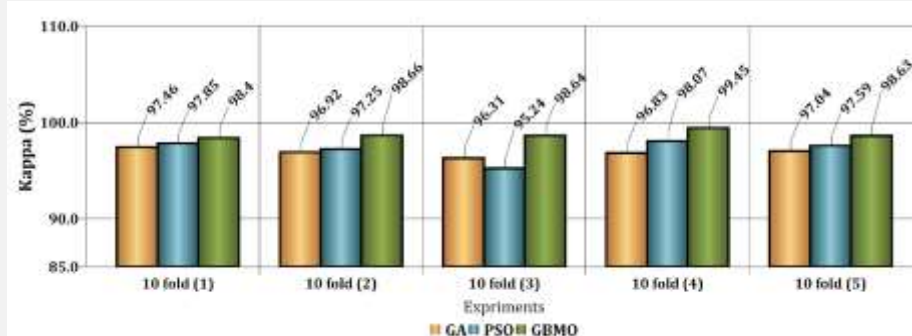
برای محاسبه‌ی AUC در حالت چندکلاسه از شیوه‌ی یکی در برابر همه (یک کلاس در مقابل سایر کلاس‌ها) استفاده شده است. مقایسه‌ای میان طبقه‌بندها و دلیل استفاده از ماشین بردار پشتیبان با روش‌های شبکه‌ی عصبی و k-NN برای هر دو مجموعه‌ی داده در شکل‌های (۹) و (۱۰) انجام شده است.



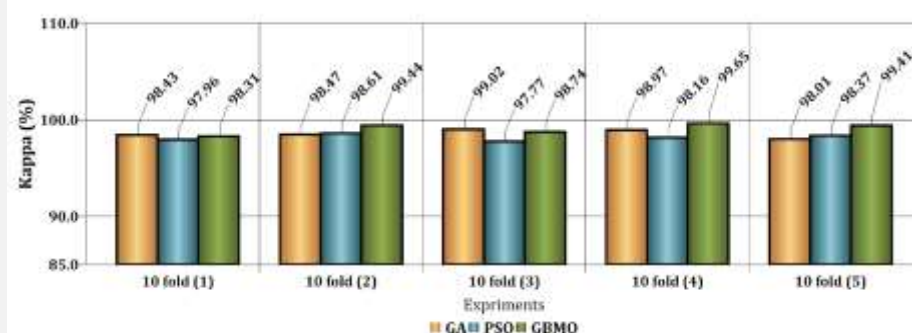
شکل (۹) - مقایسه‌ی عمل‌کرد طبقه‌بندهای مرسوم با طبقه‌بند ماشین بردار پشتیبان در داده‌ی نخست جهت اثبات دلیل استفاده



شکل (۱۰) - مقایسه‌ی عمل‌کرد طبقه‌بندهای مرسوم با طبقه‌بند ماشین بردار پشتیبان در داده‌ی دوم جهت اثبات دلیل استفاده



شکل (۱۱) - مقایسه‌ی عمل‌کرد روش بهینه‌سازی پارامترهای تنظیم‌کننده با روش‌های متداول برای داده‌ی اول



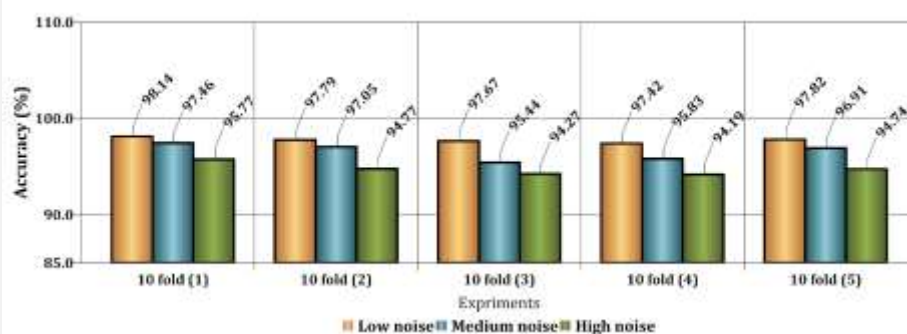
شکل (۱۲) - مقایسه‌ی عمل‌کرد روش بهینه‌سازی پارامترهای تنظیم‌کننده با روش‌های متداول برای داده‌ی دوم

نورون) و لایه‌های دیگری جهت جلوگیری از تکرار الگوریتم در پیدا کردن کم‌ترین مقدار میانگین توان دوم خطای برآوردگر


در دسته‌بندی با شبکه‌ی عصبی از شبکه‌ی عصبی تغذیه‌ی رو به جلو با لایه‌ی مخفی اول (۱۰ نورون)، لایه‌ی مخفی دوم (۵

شده است. با این حال اثر میزان نویز بر سیگنال و طبقه‌بندی رضایت‌بخش است. نتیجه‌ی این آزمایش به ترتیب در شکل‌های (۱۳) و (۱۴) ارائه شده است. در روش‌های پیشین [۱، ۲۰، ۲۲، ۲۴، ۲۹، ۳۰، ۳۹] از الگوریتم‌های هم‌جوشی و یا تکاملی برای ارائه‌ی یک مدل ترکیبی بهره گرفته نشده و تنها به مدل‌های غیربهینه اتکا شده است. با وجود مرحله‌ی انتخاب ویژگی در این روش‌ها، مسائلی چون عدم قطعیت و یا بهبود دقت در تکرارهای مختلف به طور کامل مورد بررسی قرار نگرفته است. از شبکه‌های عصبی عمیق در برخی تحقیقات پیشین استفاده شده است [۲۴، ۲۹] اما دارای مشکلاتی مانند نیاز به داده‌های بیش‌تر جهت آموزش، صرف زمان بیش‌تر و احتمال بلادرنگ نبودن بوده و به تعریف پارامترهای زیادی نیاز دارد که اغلب تنها با ستر سخت‌افزاری قدرتمند می‌تواند مفید باشد. در برخی تحقیقات نیز مساله‌ی ثبات در پاسخ در حضور نویز بررسی نشده است. بر خلاف مقالاتی مانند [۱، ۲۰] که در آن‌ها از انتخاب ویژگی استفاده نشده، در سایر پژوهش‌ها بحثی پیرامون هم‌گرا شدن پاسخ بهینه صورت نگرفته و آثار ویژگی‌های مطلوب با در نظر گرفتن داده‌های آموزشی، آزمایشی و یا اعتبار لحاظ نشده است. برای به دست آوردن سطوح کمینه و بیشینه‌ی خطا، حل مساله‌ی عدم قطعیت در جهت اعتماد به خروجی‌های حاصل شده با تکرار آزمون صورت پذیرفته است. اختلاف نتایج آزمون در شرایط تکرارپذیر، ناچیز بوده و این موضوع بیان‌گر تناسب نتایج و قابلیت اعتماد به نتایج به دست آمده از آزمایش است.

برای ساختارهای مختلف استفاده شده است. اگر عامل خطا از یک مقدار مشخص (۰/۱۰) کم‌تر باشد شبکه‌ی متناظر به عنوان شبکه‌ی پایه انتخاب شده و در غیر این صورت کمینه‌ی خطا و متناظر با آن ساختار شبکه‌ی مورد نظر برگزیده شده است. با توجه به سخت‌افزار مورد استفاده، پیچیدگی محاسباتی روش و زمان پردازش آن اندک بوده و می‌تواند به صورت بلادرنگ و یا نزدیک به بلادرنگ مورد استفاده قرار گیرد. زمان پردازش برای یک حرکت با یک قاب به طول ۰/۲۱ میلی‌ثانیه (با فرض ۴۴۰۰ قاب برای هر حرکت) کم‌تر از ۱ ثانیه (در حدود ۹۲۴ میلی‌ثانیه) است. یکی از موارد در نظر گرفته شده جهت بررسی ثبات الگوریتم در شناسایی حالات حرکتی و یا ژست دست، اضافه شدن نویز به سیگنال می‌باشد. بدین منظور سه سطح کم، متوسط و زیاد نویز به نمونه‌ی سیگنال‌ها اعمال شده و سپس دقت در هر آزمایش دسته‌ی فولد برآورد شده است. نویز از نوع سفید گوسی با اندازه‌ی متغیر در فاصله‌ی $3/9653$ تا $4/6517$ و نسبت سیگنال به نویز در حدود $2/83$ - دسی‌بل بوده (به دلیل بزرگ‌تر بودن میزان RMS نویز نسبت به RMS سیگنال) و در نتیجه نسبت انرژی/توان نویز به انرژی/توان سیگنال بالاتر از $1/9$ برآورد شده است. هم‌چنین میانگین و انحراف معیار تابع چگالی احتمال گوسی به ترتیب برابر با صفر ($\mu=0$) و $\sigma=2/5 \times 10^{-4}$ است. پراکندگی در پاسخ‌های به دست آمده از هر فولد در هر دو مجموعه‌ی داده از ۲٪ بیش‌تر نبوده اما در سطح‌های سه‌گانه تا ۷٪ نیز افزایش پراکندگی مشاهده



شکل (۱۳) - اعمال سه سطح نویز به سیگنال‌های EMG و بررسی ثبات و عدم قطعیت روش در دسته‌بندی صحیح ژست دست در داده‌ی اول



شکل (۱۴) - اعمال سه سطح نویز به سیگنال‌های EMG و بررسی ثبات و عدم قطعیت روش در دسته‌بندی صحیح ژست دست در داده‌ی دوم



Prosthetic Hand”, Journal of Bionic Engineering, vol. 14, pp. 47-59, 2017.

- [10] L. Bi, A. G. Feleke, C. Guan, “A review on emg-based motor intention prediction of continuous human upper limb motion for humanrobot collaboration”, Biomed Signal Proces., vol. 51, pp. 113-127, 2019.
- [11] S., Pancholi, A. M. Joshi, “Portable EMG data acquisition module for upper limb prosthesis application”, IEEE Sensors J., vol. 18, no. 8, pp. 3436-3443, Apr. 2018.
- [12] G. Jang, J. Kim, S. Lee, Y. Choi, “EMG-based continuous control scheme with simple classifier for electric-powered wheelchair”, IEEE Trans. Ind. Electron., vol. 63, no. 6, pp. 3695-3705, Jun. 2016.
- [13] A.S. Kundu, O. Mazumder, P.K. Lenka, S. Bhaumik, “Hand Gesture Recognition Based Omnidirectional Wheelchair Control Using IMU and EMG Sensors”, Journal of Intelligent and Robotic Systems, vol. 91, pp. 529-541, 2018.
- [14] I. M. Skavhaug, K. R. Lyons, A. Nemchuk, S. D. Muroff, S. S. Joshi, “Learning to modulate the partial powers of a single sEMG power spectrum through a novel human-computer interface”, Human Movement Science, vol. 47, pp. 60-69, June 2016.
- [15] M.R. Al-Mulla, F. Sepulveda, M. Colley, “Evolved pseudo-wavelet function to optimally decompose SEMG for automated classification of localized muscle fatigue”, Medical Engineering & Physics, vol. 33, no. 4, pp. 411-417, May 2011.
- [16] R. H. Chowdhury, M. B. I. Reaz, M. A. B. M. Ali, A. A. A. Bakar, K. Chellappan, T. G. Chang, “Surface electromyography signal processing and classification techniques”, Sensors (Basel Switzerland), vol. 13, no. 9, pp. 12431-12466, 2013.
- [17] N. Thakur, L. Mathew, “sEMG Signal Classification Using Ensemble Learning Classification Approach and DWT”, 2018 International Conference on Current Trends towards Converging Technologies (ICCTCT), pp. 1-4, 2018.
- [18] C. Sapsanis, A. Tzes, G. Georgoulas, UCI Machine Learning Repository. <http://archive.ics.uci.edu/ml>
- [19] Y. Y. Ruangpaisarn, S. Jaiyen, “SEMG signal classification using SMO algorithm and singular value decomposition”, Envisioning the Trend of Computer Information and Engineering ICITEE 2015, pp. 46-50, 2015.
- [20] C. Sravani, V. Bajaj, S. Taran, A. Sengur, “Flexible analytic wavelet transform based features for physical action identification using sEMG signals”, IRBM, vol. 41, no. 1, pp. 18-22, 2020.
- [21] D. Dheeru, E. Karra Taniskidou, UCI Machine Learning Repository. <http://archive.ics.uci.edu/ml>.

۴- نتیجه‌گیری

در این تحقیق یک مدل ترکیبی با امکان استخراج ویژگی و نیز انتخاب ویژگی به شیوه‌ی هم‌جوشی نرم از سیگنال‌های sEMG ارائه شده است. بهینگی پارامترهای کرنل طبقه‌بند نیز با اتکا به الگوریتم حرکت کاتوره‌ای گاز شکل گرفته است. نتایج در دسته‌بندی حالات حرکتی و ژست دست رضایت‌بخش بوده اما می‌توان در تحقیقات آتی برخی از چالش‌های پیش رو را ارتقا بخشید. کم کردن پیچیدگی محاسباتی و زمان پردازش می‌تواند بلادرنگ شدن مدل را به همراه داشته باشد. در تحقیقات آینده سعی بر آن است تا یک مدل برخط برای حجم وسیعی از داده‌ها طراحی شود.

۵- مراجع

- [1] T. Tuncer, S. Dogan, A. Subasi, “Surface EMG signal classification using ternary pattern and discrete wavelet transform based feature extraction for hand movement recognition”, Biomed. Signal Process. Control, Vol. 58, pp. 101872, 2020.
- [2] Z. Zhang, F. Sup, “Activity recognition of the torso based on surface electromyography for exoskeleton control”, Biomed. Signal Process. Control, vol. 10, pp. 281-288, 2014.
- [3] R. Merletti, S. Muceli, “Surface EMG detection in space and time: Best practices”, Journal of Electromyography and Kinesiology, vol. 49, pp. 102363, 2019.
- [4] Akhtar et al., “A Low-Cost Open-Source Compliant Hand for Enabling Sensorimotor Control for People with Transradial Amputations”, Conf Proc IEEE Eng Med Biol Soc, 2017.
- [5] I. Hussain, G. Spagnoletti, G. Salvietti, D. Prattichizzo, “Toward wearable supernumerary robotic fingers to compensate missing grasping abilities in hemiparetic upper limb”, Int. J. Robot. Res., vol. 36, no. 13-14, pp. 1414-1436, Dec. 2017.
- [6] D. Blana, T. Kyriacou, J. M. Lambrecht, E. K. Chadwick, “Feasibility of using combined EMG and kinematic signals for prosthesis control: a simulation study using a virtual reality environment”, Journal of ElectroMyography and Kinesiology, vol. 29, pp. 21-27, 2016.
- [7] Y. Nam et al., “GOM-Face: GKP EOG and EMG-Based Multimodal Interface With Application to Humanoid Robot Control”, IEEE Transactions on Biomedical Engineering, vol. 61, no. 2, pp. 453-462, 2014.
- [8] S. Lo, S. Q. Xie, “Exoskeleton robots for upper-limb rehabilitation: State of the art and future prospects”, Medical Engineering & Physics, vol. 34, no. 3, pp. 261-268, 2012.
- [9] N. Wang, K. Lao, X. Zhang, “Design and Myoelectric Control of an Anthropomorphic

- [31] G. Venugopal, M. Navaneethakrishna, S. Ramakrishnan, "Extraction and analysis of multiple time window features associated with muscle fatigue conditions using sEMG signals", *Expert Syst. Appl.*, vol. 41, no. 6, pp. 2652-2659, 2014.
- [32] A. A. Gijssberts et al., "Movement error rate for evaluation of Machine Learning methods for sEMG-based hand movement classification", *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 22, no. 4, pp. 735-744, Jul. 2014.
- [33] M. Kurzynski, M. Krysmann, P. Trajdos, A. Wolczowski, "Multiclassifier system with hybrid learning applied to the control of bioprosthetic hand", *Computers in Biology and Medicine*, vol. 69, pp. 286-297, 2016.
- [34] T. Nguyen, A. Khosravi, D. Creighton, S. Nahavandi, "A novel aggregate gene selection method for microarray data classification", *Pattern Recognition Letter*, vol. 60-61, pp. 16-23, 2016.
- [35] M. M. Mafarja, S. Mirjalili, "Hybrid binary ant lion optimizer with rough set and approximate entropy reducts for feature selection", *Soft Computing*, pp. 1-17, 2018.
- [36] M. Abdechiri, M. R. Meybodi, H. Bahrami, "Gases brownian motion optimization: an algorithm for optimization (gbmo)", *Applied Soft Computing*, vol. 13, no. 5, pp. 2932-2946, 2013.
- [37] M. Simao, P. Neto, O. Gibaru, "Uc2018 dualmyo hand gesture ~ dataset" URL: <https://doi.org/10.5281/zenodo.1320922>.
- [38] M. A. Simão, P. Neto, O. Gibaru, "Unsupervised gesture segmentation by motion detection of a real-time data stream", *IEEE Trans. Ind. Inform.*, vol. 13, no. 2, pp. 473-481, Apr. 2017.
- [39] A. Ullah S. Ali, I. Khan, M. A. Khan, S. Faizullah, "Effect of Analysis Window and Feature Selection on Classification of Hand Movements Using EMG Signal." arXiv preprint arXiv, vol. 2002, pp. 00461, 2020.
- [40] C. Sapsanis, G. Georgoulas, A. Tzes, and D. Lymberopoulos, "Improving EMG based classification of basic hand movements using EMD," in *Proc. 35th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, Jul. 2013, pp. 5754-5757.
- [22] G. R. Naik, S. E. Selvan, S. P. Arjunan, A. Acharyya, D. K. Kumar, A. Ramanujam, H. T. Nguyen, "An ica-ebm-based semg classifier for recognizing lower limb movements in individuals with and without knee pathology", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 3, pp. 675-686, 2018.
- [23] O. F. A. Sanchez, J. L. R. Sotelo, M. H. Gonzales, and G. A. M. Hernandez, "EMG dataset in lower limb data set - UCI machine learning repository," 2013.
- [24] A. K. Mukhopadhyay, S. Samui, "An experimental study on upper limb position invariant EMG signal classification based on deep neural network", *Biomed. Signal Process. Control* vol. 55, pp. 101669, 2020.
- [25] J. Cheng, F. Wei, C. Li, Y. Liu, A. Liu, X. Chen, "Position-independent gesture recognition using sEMG signals via canonical correlation analysis", *Comput. Biol. Med.* vol. 103, pp. 44-54, 2018.
- [26] W. T. Shi, Z. J. Lyu, S. T. Tang, T. L. Chia, C. Y. Yang, "A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study", *Biocybernetics and Biomedical Engineering*, vol. 38, no. 1, pp. 126-135, 2018.
- [27] A. Al-Timemy, R. Khushaba, G. Bugmann, J. Escudero, "Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees", *IEEE Trans Neural Syst Rehabil Eng*, vol. 24, no. 6, pp. 650-661, 2016.
- [28] S. Chada, S. Taran, V. Bajaj "An efficient approach for physical actions classification using surface EMG signals" *Health Information Science and Systems*, vo. 8, no. 1, p 3, 2020.
- [29] U. Côté-Allard et al., "Deep learning for electromyographic hand gesture signal classification using transfer learning", *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 27, no. 4, pp. 760-771, Apr. 2019.
- [30] M. Simão, P. Neto, O. Gibaru, "EMG-based online classification of gestures with recurrent neural networks", *Pattern Recognition Letters*, vol. 128, pp. 45-51, 2019.