

تفکیک سیگنال الکترومایوگرافی تک کاناله حرکات اساسی دست با استفاده از روش های یادگیری ماشین

شیوا کاظم بیگی برزی^۱، علی قنبر^۲، سروین توحیدی^۳، امیرعلی علیلویی^۴، بابک رضایی افشار^{۵*}.

۱- دانشجوی کارشناسی، گروه مهندسی پزشکی، دانشکده علوم و فناوری های پزشکی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران

۲- دانشجوی کارشناسی، گروه مهندسی پزشکی، دانشکده علوم و فناوری های پزشکی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران

۳- دانشجوی کارشناسی، گروه مهندسی پزشکی، دانشکده علوم و فناوری های پزشکی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران

۴- دانشجوی کارشناسی، گروه مهندسی پزشکی، دانشکده علوم و فناوری های پزشکی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران

۵- دکتری مهندسی پزشکی، گروه ارتز و پروتز، دانشکده توانبخشی، دانشگاه علوم پزشکی ایران، تهران

چکیده

تفکیک و تشخیص حرکات دست در تعاملات انسانی و انسان و کامپیوتر نقش مهمی را ایفا می کند. تشخیص الگوی الکترومایوگرافی (EMG) برای تشخیص حرکات سال ها در مطالعات اعضای مصنوعی و سیستم های توان بخشی مورد بررسی بوده است. داده های الکترومایوگرافی حاوی اطلاعات درباره فعالیت الکتریکی عضلات است. در این مطالعه داده های EMG از عضله فلکسور کربی اولناریس بازو شش نفر زنان ۲۱ ساله جمع آوری شد و پس از اعمال فیلترها و استخراج ۲۴ ویژگی مناسب، داده ها توسط پنج طبقه بند شامل ماشین بردار پشتیبان، K نزدیک ترین همسایگی، مدل مخلوط گاوسی، نقشه خود سازمانده و درخت تصمیم مورد تفکیک و طبقه بندی قرار گرفتند. تحلیل های آماری نشان داد طبقه بند درخت تصمیم نتیجه بهتر و صحت بالاتری را نسبت به طبقه بند های مورد استفاده دارا می باشد. از چالش های این مطالعه جامعه آماری و پراکندگی ویژگی کم در بین افراد شرکت کننده بود. برای مطالعات آینده استفاده از جامعه آماری بهتر با پراکندگی ویژگی بالاتر، بررسی اثر اختلالات فعالیت های ماهیچه ای و استفاده از داده ها برای کنترل اعضای مصنوعی یا ویلچر هوشمند پیشنهاد می شود.

کلمات کلیدی: پردازش سیگنال، الکترومایوگرافی، درخت تصمیم، حرکات دست، فیلتر باترورث، EMG، یادگیری ماشین

* Corresponding author: Babak Rezaee Afshar
Email: Babak.rezaee@srbiau.ac.ir

۱. مقدمه

الکترومایوگرافی* (EMG) پتانسیل الکتریکی ایجاد شده توسط تپون های مختلف در طول عضلات است که در زمان انقباض ماهیچه ها تولید می شوند [۱] و میتواند به عنوان یک روش غیر تهاجمی به راحتی از عضلات ساعد استخراج شود [۲].

الکترومایوگرافی سطحی به صورت گسترده ای برای کاربرد هایی نظیر کاربرد های کلینیکال، ارزیابی بالینی [۳] و تخمین سلامت [۴] استفاده گردیده و همچنین کاربرد هایی برای طبقه بندی انواع مختلف حرکات دست و انگشتان دارد [۵]. علاوه بر این از الکترومایوگرافی برای تشخیص حرکات و مدت خستگی ماهیچه ها نیز استفاده می شود [۶]. این سیگنال رایج ترن سیگنالی است که در اندازه گیری حرکات و فعالیت های ماهیچه ها به کار رفته است و همچنین در تعامل انسان با رایانه، کنترل اعضای مصنوعی و دستگاه های پزشکی نیز از این روش استفاده شده است [۷، ۸].

در بازنگری ای از مقالات ۲۰۱۶ تا ۲۰۱۸ مشخص شد شبکه عصبی مصنوعی (ANN) بیشترین استفاده را در بین سیستم های طبقه بندی داشته است [۹]. آقای ویمال شانموگاناتان و همکاران از شبکه عصبی پیچشی ناحیه ای (R-CNN) و استخراج ویژگی موجک برای تشخیص حرکات دست استفاده کردند و به صحت ۹۶.۴۸ درصدی رسیدند [۱۰]. آقای پراتیک آنارامچاندرا یاداو و همکاران در مروری بر روش های یادگیری ماشین برای تشخیص حرکات دست در عین بیان مزایای این روش به کاستی های موجود نیز اشاره کرده و مواردی همچون کاهش تعداد داده ها، افزایش سرعت تصمیم گیری و افزایش صحت طبقه بندی را از ملزومات مورد نیاز برای بهبود این روش دانسته اند [۱۱]. همچنین در مطالعه ای، آقای هارون گونش و همکاران با استفاده از تحلیل موجک پیوسته[‡] (CWT) و یادگیری عمیق CNN سیگنال های را به تصویر تبدیل کردند و به بیش از ۸۸.۸۹ درصد صحت دست پیدا کردند [۱۲]. خانم ملک فورا و همکاران از طبقه بند KNN برای طبقه بندی حرکات دست استفاده کردند و به صحتی تا ۹۵ درصد رسیدند [۱۳].

درخت تصمیم[§] (DT) نوعی یادگیری ماشین تحت نظارت و یک نمودار برای نمایش انتخاب ها و نتایج آنها به شکل درخت است. گره های نمودار نشان دهنده یک رویداد یا انتخاب هستند و لبه های نمودار بیانگر قوانین یا شرایط تصمیم گیری هستند. هر درخت از گره ها و شاخه ها تشکیل شده است. هر گره نشان دهنده ویژگی هایی از گروه است که قرار است طبقه بندی شوند و هر شاخه نشان دهنده مقداری است که گره می تواند بگیرد [۱۴].

درخت تصمیم یکی از روش های رایج و قوی برای استفاده در حوزه های مختلف از جمله پردازش تصویر [۱۵]، طبقه بند ابزار های دقیق با صحت بالا [۱۶]، کنترل دست مصنوعی [۱۷] و حتی در حوزه تشخیص بیماری ها مانند دیابت [۱۸] می باشد. در مطالعه ای در سال ۲۰۱۹ از درخت تصمیم برای تشخیص اعداد دست نوشته شده استفاده شد و صحتی برابر با ۸۳.۴ درصد حاصل شد [۱۹]. همچنین در پژوهشی در حوزه دیرینه شناسی مشخص شد یادگیری ماشین و درخت تصمیم نتایج طبقه بندی بهتری را دارا هستند و در برخی موارد به صحتی تا ۹۶ درصد نیز می رسند [۲۰]. تشخیص حرکات دست بخش مهمی از تقابل و برهمکنش انسان و رایانه است که توانایی اخذ و تفسیر حرکات دست و در ادامه اجرا یا ارائه دستورات را به رایانه می دهد [۹].

با توجه به افزایش مداوم تقاضا برای محلی سازی نشانه ها در تشخیص حرکات دست، نیاز به یک سیستم پایدار، هوشمند و قابل اعتماد برای تشخیص حرکات دست وجود دارد. در پژوهشی چندین حرکت که در ارتباط روزمره به عنوان نشانه در مکالمات استفاده می شوند مورد بررسی قرار گرفت [۲۱]. همچنین در مطالعاتی مربوط به طبقه بندی حرکات دست

* Electromyography

† Region-Based Convolutional Neural Network

‡ Continuous Wavelet Transform

§ Decision Tree


در سال ۲۰۲۲ در حدود پنج تا شش حرکت مورد استفاده در زندگی روزمره برای بررسی انتخاب شدند [۱، ۱۲]. در برخی پژوهش‌ها نیز از حرکات دستوری مانند چهار حرکت برای استفاده در محیط‌های بصری مانند بازی‌های کامپیوتری [۲۲]، شش حرکت مربوط به دستور چنگ زدن در محیط‌های مجازی [۲۳] و همچنین چهار حالت دستوری برای کنترل ویلچر هوشمند [۲۴] استفاده شده است.

توانایی ماشین و رایانه در تشخیص حرکات متفاوت دست می‌تواند در طیف گسترده‌ای از موضوعات از جمله کنترل دست مصنوعی، کنترل بازی‌ها، ترجمه زبان اشاره، ویلچر هوشمند و غیره به کار بیاید [۲۵-۲۷]. این اهداف به دلایلی همچون افزایش مشکلات و آسیب‌های شنوایی [۲۶، ۲۸]، استفاده‌های روزافزون از رابط‌های غیرلمسی در برنامه‌های مبتنی بر بینایی و همچنین بازی‌ها و تلویزیون‌های هوشمند و محیط‌های واقعیت مجازی [۲۸] روز به روز متداول‌تر می‌شوند. در پژوهشی در سال ۲۰۲۰ از چهار ویژگی در حوزه زمان شامل مقدار مطلق میانگین (MAV)، شیب تغییرات علامت (SSC)، طول شکل موج (WL)، عبور از صفر (ZC) و همچنین چند ویژگی پیشرفته حوزه زمان مانند ضریب اتورگرسیو (AC) و ریشه میانگین مربعات (RMS) استفاده شد و باعث کاهش پیچیدگی مدل و افزایش صحت طبقه‌بندی شد [۸]. در مطالعات دیگر ویژگی‌هایی نظیر چگالی طیف توان (PSD) [۵] نیز سنجیده شده است.

با توجه به مطالعات انجام شده و نظر به اهمیت موضوع تفکیک حرکات دست به نظر می‌رسد روش‌های نوین یادگیری ماشین می‌تواند به خوبی تفکیک حرکات دست را برای کاربردهایی همچون پروتزهای مایوالکتریک انجام دهد. در این میان اختلاف نظر اساسی بر روی ویژگی‌های مورد قبول و قابل اتکا در استخراج از سیگنال بوده و به نظر می‌رسد استفاده از ویژگی‌های مناسب بتواند در تفکیک حرکات نقش اساسی ایفا نماید. همچنین استفاده از روش‌های یادگیری ماشین به روز و جدید احتمال یافتن مسیری کم‌خطا تر را برای تفکیک داده‌ها هموار خواهد کرد.

۲. مواد و روش‌ها

در این پژوهش تعداد ۶ نفر شامل زنان سالم ۲۱ ساله راست دست برای جمع‌آوری داده از دست غالب شرکت کردند. برای ثبت سیگنال‌های الکترومایوگرافی از دستگاه تقویت‌کننده EMG-1000 با فرکانس نمونه‌برداری ۱۰۰۰ هرتز و پهنای باند ۲۰-۴۰۰ هرتز استفاده شد. الکتروده‌های متصل شامل یک الکتروده مرجع متصل به استخوان اولنا در مفصل مچ و دو الکتروده دیگر روی عضلات مورد نظر (فلکسور کربی اولناریس)* مطابق شکل ۱ با فاصله ۲ سانتی‌متر چسبانده شد.




شکل ۱- سمت راست محل اتصال الکتروده‌ها بر روی عضله و سمت چپ نحوه اتصال آردوینو به چیپ ست

برای اخذ سیگنال از مازول‌های سابل استفاده شد. (شکل ۱- سمت چپ) مازول‌های سابل ابزاری برای اخذ و تقویت سیگنال‌های حیاتی مختلف از جمله الکترواکولوگرافی، الکتروکاردیوگرافی، الکترورتینوگرافی و الکترومایوگرافی است. این مازول‌ها می‌تواند به شما در برخی از امور از جمله تحقیقات در حوزه‌هایی همچون درمان، مهندسی پزشکی، مهندسی ورزش، پزشکی، تربیت بدنی و همچنین در ایده‌هایی برای ساخت تجهیزات پزشکی و ورزشی نیز کمک کند.

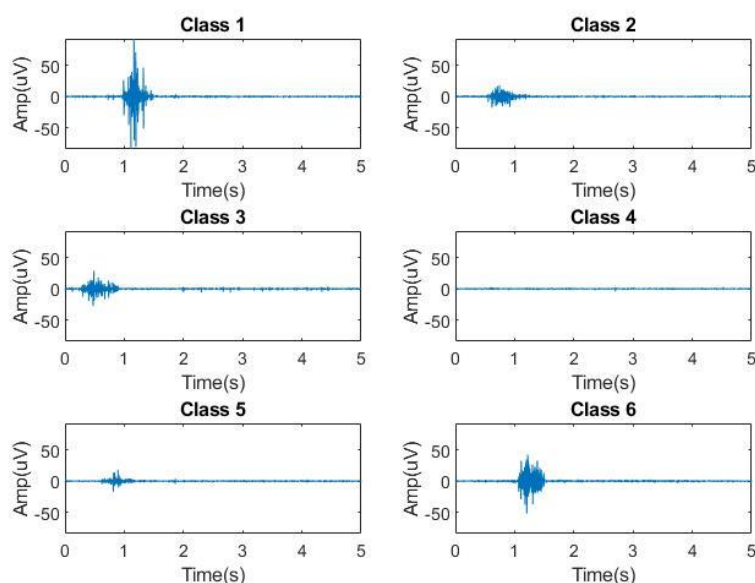
* Flexor carpi ulnaris

فرایند داده‌گیری برای هر کلاس در ۱۶۰ ثانیه انجام شده است؛ بنابراین هر نفر در هر کلاس ۳۰ بار حرکت مربوطه را تکرار کرد. شش کلاس مطابق شکل ۲ از حرکات مختلف دست شامل مشت کردن، گرفتن عدد دو، حالت استراحت، انقباض به سمت چپ، راست و پایین توسط هر نفر انجام شد و داده‌های آن مطابق نمونه‌ای که در شکل ۳ آمده است ثبت شد.



شکل ۲- حرکات دست

هدف انتخاب این حرکات دست استفاده در دستورات کنترل ویلچر هوشمند توسط سیگنال الکترومایوگرافی و یا ساخت دست مصنوعی در مطالعات آینده است.



شکل ۳- نمونه‌ای از داده‌ها در هر کلاس (به ترتیب حرکت مشت، چپ، دو، استراحت، راست و پایین)

۷۰ درصد از داده‌های اخذ شده برای آموزش و ۳۰ درصد باقی مانده برای تست طبقه‌بند مورد نظر استفاده شده است. داده‌ها با استفاده از نرم‌افزار MATLAB ورژن ۲۰۱۸a مورد تجزیه و تحلیل قرار گرفت. پس از وارد کردن داده‌ها در نرم‌افزار متلب و اصلاح خط مبدا از فیلتر باترورث مرتبه ۴ بر روی آن‌ها استفاده شد. این فیلتر نوعی فیلتر میان‌گذر است و داده‌هایی که در محدوده فرکانس مشخص شده نیستند را تضعیف می‌کند. پاسخ فرکانسی ایده‌آل یک فیلتر با نام دیوار آجری شناخته می‌شود. هرچه مرتبه فیلتر بیشتر باشد، تعداد طبقات آبخاری موجود در طراحی فیلتر نیز بیشتر می‌شود و پاسخ فرکانسی فیلتر به یک پاسخ ایده‌آل یا دیوار آجری نزدیک‌تر می‌شود. برای یافتن مرتبه بهینه چندین مرتبه از این فیلتر آزمایش شد و در نهایت از مرتبه‌ای که بهترین نتیجه را داد استفاده شد.

به منظور تقسیم داده‌ها از تکنیک پنجره‌گذاری با همپوشانی صفر درصد بهره‌گرفته شد. داده‌ها به پنجره‌های پنج‌تاییه‌ای شامل هر انقباض تقسیم‌بندی شده و مورد تجزیه و تحلیل قرار گرفتند. پس از پنجره‌گذاری مجموعاً ۲۴ ویژگی در حوزه‌های زمان و فرکانس مطابق جدول ۱ از داده‌ها استخراج شد.

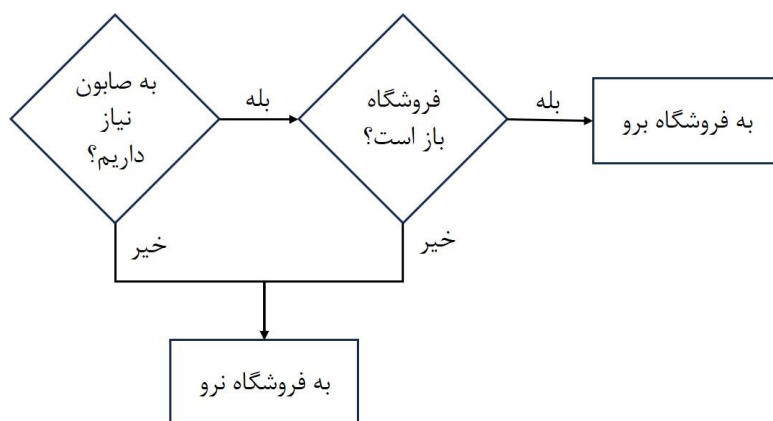
جدول ۱- ویژگی‌های مستخرج

عنوان ویژگی	وضعیت	رابطه	عنوان ویژگی	وضعیت	رابطه
میانگین	مجموع مقادیر تقسیم بر تعداد مقادیر سیگنال	$\frac{1}{n} \sum_{i=1}^n x_i$	طول شکل موج	طول تجمعی شکل موج EMG در طول بخش زمانی	$\sum_{i=1}^{n-1} x_{i+1} - x_i $
میانه	-	$\begin{cases} x_{(n+1)/2}, & \text{if } n \text{ is odd} \\ x_{\frac{n}{2}} + x_{(\frac{n}{2}+1)}, & \text{if } n \text{ is even} \end{cases}$	میانگین تغییرات دامنه	تقریباً مشابه ویژگی بالایی با این تفاوت که میانگین گرفته شده است.	$\frac{1}{n} \sum_{i=1}^{n-1} x_{i+1} - x_i $
واریانس	میانگین مربعات مقادیر	$\frac{1}{n-1} \sum_{i=1}^n x_i^2$	معیار مطلق انحراف	مقدار انحراف استاندارد طول موج	$\sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{i+1} - x_i)^2}$
میانگین ریشه	-	$\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$	انفجاری اول دامنه	اولین نقطه با تغییرات بیش از آستانه	$\Delta x_i > \text{threshold} \rightarrow AFB = x_i$
تعداد عبور از صفر	تعداد دفعات تغییر علامت سیگنال	$\sum_{i=1}^{n-1} [sgn(x_i \times x_{i+1}) \cap x_i - x_{i+1} \geq \text{threshold}]$ $sgn(x) = \begin{cases} 1, & \text{if } x \geq th \\ 0, & \text{otherwise} \end{cases}$	فرکانس میانگین	مجموع حاصلضرب طیف توان و فرکانس، تقسیم بر مجموع کل طیف توان	$\sum_{j=1}^m f_j P_j / \sum_{j=1}^m P_j$

$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j$ $= \frac{1}{2} \sum_{j=1}^M P_j$	فرکانسی که طیف در آن به دو ناحیه با دامنه مساوی تقسیم می‌شود.	فرکانس میانه	$\sum_{i=1}^n x_i $	مجموع مقادیر مطلق دامنه سیگنال	EMG یکپارچه
$PKF = \max(P_j)$ $j = 1 \dots M$	فرکانسی است که در آن ماکسیمم توان ظاهر می‌شود.	فرکانس پیک	$\sum_{i=1}^n x_i^2$	مجموع مقادیر مربعات دامنه سیگنال	انتگرال مربعات ساده
$\sum_{j=1}^M P_j / M$	میانگین طیف توان	توان میانگین	$\left \frac{1}{n} \sum_{i=1}^n x_i^n \right $	توصیف توزیع یک سیگنال در گذر زمان	ای مرتبه سه، گشتاور لحظه
$\sum_{j=1}^M P_j$	به عنوان مجموعه از طیف توان EMG تعریف می‌شود.	توان کل	$\left(\frac{1}{N} \sum_{i=1}^N X_i^v \right)^{\frac{1}{v}}$	آشکارسازی غیرخطی برای تخمین نیروی عضلانی	مرتبه V
$\sum_{j=1}^M P_j f_j$	یک روش تحلیل آماری جایگزین برای استخراج ویژگی‌ها از طیف توان	گشتاور لحظه ای درجه ۱	$\frac{1}{n} \sum_{i=1}^n \log(x_i)$	آشکارسازی لگاریتمی برای تخمین نیروی عضلانی	آشکارساز لگاریتمی
$\sum_{j=1}^M P_j f_j^2$	-	لحظه ای گشتاور	$\sum_{j=1}^M P_j f_j^3$	-	لحظه ای گشتاور

برای طبقه بندی داده‌ها طبقه بندی‌های مختلفی نظیر ماشین بردار پشتیبان، کا نزدیک ترین همسایگی، مدل مخلوط گاوسی، نقشه خود سازمانده و درخت تصمیم ارزیابی شدند و در نهایت طبقه بند درخت تصمیم که بالاترین صحت را داشت انتخاب شد.


این شیوه ی یادگیری ماشین نمونه ای سلسله مراتبی از روابط دانش است که شامل گره ها و ارتباطات است. هنگامی از روابط برای طبقه بندی استفاده می‌شود، گره‌ها نشانگر اهداف هستند [۲۹]. مثالی ساده از درخت تصمیم در شکل ۴ قابل مشاهده است.



شکل ۴- نمونه ای از یک درخت تصمیم ساده

۳. نتایج

نتایج اصلی این پژوهش شامل داده های جمع آوری شده از سیگنال های الکترومیوگرافی از ۶ فرد در حال انجام شش کلاس منتخب از حرکات دست است که مورد بررسی و تحلیل قرار گرفتند. پس از استخراج ۲۴ ویژگی از داده ها، طبقه بندی های مختلف با صحت، دقت، ویژگی و حساسیت متفاوت شامل ماشین بردار پشتیبان با صحت ۱۷ درصدی، ک نزدیک ترین همسایگی با صحت ۵۳ درصدی، مدل مخلوط گاوسی با صحت ۶۸ درصدی، نقشه خود سازماندهی با صحت ۳۲ درصدی و درخت تصمیم با صحت ۹۸.۴۴ درصدی به هدف تفکیک شش حرکت منتخب دست بر روی آن ها اعمال شدند. داده ها با نرخ ۷۰ درصدی برای آموزش و نرخ ۳۰ درصدی برای آزمون طبقه بندی استفاده شدند. مشخص شد که درخت تصمیم بهترین نتایج و بالاترین صحت با را در میان طبقه بندی های مورد استفاده دارد. شکل ۵ سمت راست رابطه بین دو ویژگی RMS (مربوط به حوزه زمان) و MDF (مربوط به حوزه فرکانس) را نسبت به یکدیگر نشان می دهد. مطابق آن طبقه بندی درخت تصمیم در کلاس های ۱، ۲ و ۶ دچار خطا شده است. شکل ۵ سمت چپ نیز ماتریس تصمیم ارزیابی ۶ حرکت اخذ شده با ۳۰ بار تکرار از ۶ نفر را نشان می دهد.



شکل ۵- سمت راست نمودار داده ها بر حسب دو ویژگی حوزه زمان و فرکانس و سمت چپ ماتریس تصمیم داده ها

۳. بحث و نتیجه گیری

در این مطالعه ۲۴ ویژگی در حوزه های زمان و فرکانس از داده ها استخراج شدند که همگی حاوی اطلاعات و تغییرات مناسب برای استفاده در تفکیک داده ها بودند.

این مطالعه نشان داد حرکات دست را میتوان با تقریب بالاتری نسبت به مطالعات و روش های پیشین با استفاده از طبقه بند درخت تصمیم و بدون بار محاسباتی سنگین تفکیک و شناسایی کرد. همچنین هم مسیر با خانم زهرا کاراپینار و همکاران این مطالعه نیز چندین طبقه بند را مقایسه و طبقه بند بهینه را انتخاب کرد [۳۰].

این دستاورد می تواند واقعیت های بسیاری در حوزه های مختلف از جمله درمان، دست مصنوعی، کنترل ویلچر هوشمند، ترجمه زبان اشاره و تشخیص حرکات دست در محیط های بصری و بازی های ویدیویی را تسهیل کند. طبق مطالعات انجام شده در گذشته تفکیک حرکات دست و تکنیک های یادگیری ماشین از جمله موضوعات پرمخاطب و به روز در حوزه الکترومایوگرافی و یادگیری ماشین می باشد و این مطالعه در صدد کمک به دانش امروزی شکل گرفته است.

از تکنیک یادگیری ماشین برای کاهش کار انسانی بهره گرفته می شود [۲۹]. از مزایای این تکنیک کاهش بار محاسباتی با پرداختن به اعداد کوچکتر در محاسبات و ایجاد سهم یکسان بین ویژگی ها می باشد [۳۰]. با اینکه منبع داده ی این پژوهش مقدار کمی نبود و حرکات با تعداد تکرار بالا انجام می شدند اما تعداد کم افراد مورد بررسی از چالش های این پژوهش است. با افزایش تعداد افراد شرکت کننده در اخذ سیگنال می توان عملکرد طبقه بند و میزان صحت تفکیک را بهبود بخشید. در مطالعات آینده میتوان از جامعه آماری بزرگتر و گوناگون تر با ویژگی های بیشتر نظیر طیف بیشتر جنسیت و سن بهره گرفت و همچنین تاثیر اختلال های ماهیچه ای را نیز مورد بررسی قرار داد.

۴. مراجع

۱. Li, Q. and R. Langari, *EMG-based HCI Using CNN-LSTM Neural Network for Dynamic Hand Gestures Recognition*. IFAC-PapersOnLine, 2022. **55**(37): p. 426-431.
۲. Cheng, Y., et al., *Gesture recognition based on surface electromyography-feature image*. Concurrency and Computation: Practice and Experience, 2021. **33**(6): p. e6051.
۳. Cappellini, G., et al., *Clinical relevance of state-of-the-art analysis of surface electromyography in cerebral palsy*. Frontiers in Neurology, 2020. **11**: p. 583296.
۴. Felici, F. and A. Del Vecchio, *Surface electromyography: what limits its use in exercise and sport physiology?* Frontiers in neurology, 2020. **11**: p. 578504.
۵. Anvaripour, M. and M. Saif. *Hand gesture recognition using force myography of the forearm activities and optimized features*. in *2018 IEEE International Conference on Industrial Technology (ICIT)*. 2018. IEEE.
۶. Kuthe, C.D., R.V. Uddanwadiker, and A.A. Ramteke, *Surface electromyography based method for computing muscle strength and fatigue of biceps brachii muscle and its clinical implementation*. Informatics in Medicine Unlocked, 2018. **12**: p. 34-43.
۷. Lei, G., et al., *Investigation on the sampling frequency and channel number for force myography based hand gesture recognition*. Sensors, 2021. **21**(11): p. 3872.
۸. Chen, L., et al., *Hand gesture recognition using compact CNN via surface electromyography signals*. Sensors, 2020. **20**(3): p. 672.
۹. Yasen, M. and S. Jusoh, *A systematic review on hand gesture recognition techniques, challenges and applications*. PeerJ Computer Science, 2019. **5**: p. e218.
۱۰. Shanmuganathan, V., et al., *R-CNN and wavelet feature extraction for hand gesture recognition with EMG signals*. Neural Computing and Applications, 2020. **32**: p. 16723-16736.

- .۱۱ Yadav, M.P.A., *HAND GESTURE RECOGNITION USING MACHINE LEARNING*. HAND, 2021. **8**(۸)
- .۱۲ GÜNEŞ, H. and A.E. AKKAYA, *Using Wavelet Analysis and Deep Learning for EMG-Based Hand Movement Signal Classification*. Sakarya University Journal of Science, 2023. **27**(1): p. 214-225.
- .۱۳ Fora, M., et al. *Hand gesture recognition based on force myography measurements using KNN classifier*. in *2021 18th International Multi-Conference on Systems, Signals & Devices (SSD)*. 2021. IEEE.
- .۱۴ Mahesh, B., *Machine learning algorithms-a review*. International Journal of Science and Research (IJSR).[Internet], 2020. **9**(1): p. 381-386.
- .۱۵ Assegie, T.A. and P.S. Nair, *Handwritten digits recognition with decision tree classification: a machine learning approach*. International journal of electrical and computer engineering (IJECE), 201 :۵)۹ .۹p. 4446-4451.
- .۱۶ Pan, T.-Y., et al., *A hierarchical hand gesture recognition framework for sports referee training-based EMG and accelerometer sensors*. IEEE Transactions on Cybernetics, 2020. **52**(5): p. 3172-3183.
- .۱۷ Ha, N., G.P. Withanachchi, and Y. Yihun. *Force myography signal-based hand gesture classification for the implementation of real-time control system to a prosthetic hand*. in *Frontiers in Biomedical Devices*. 2018. American Society of Mechanical Engineers.
- .۱۸ Posonia, A.M., S. Vigneshwari, and D.J. Rani. *Machine learning based diabetes prediction using decision tree J48*. in *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)*. 2020. IEEE.
- .۱۹ Yang, J., J. Pan, and J. Li. *sEMG-based continuous hand gesture recognition using GMM-HMM and threshold model*. in *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. 2017. IEEE.
- .۲۰ Wills, S., C.J. Underwood, and P.M. Barrett, *Learning to see the wood for the trees: machine learning, decision trees, and the classification of isolated theropod teeth*. Palaeontology, 2021. **64**(1): p. 75-99.
- .۲۱ Ansar, H., et al., *Hand gesture recognition based on auto-landmark localization and reweighted genetic algorithm for healthcare muscle activities*. Sustainability, 2 :۵)۱۳ .۰۲۱ p. 2961.
- .۲۲ Rautaray, S.S., *Real time hand gesture recognition system for dynamic applications*. International Journal of ubicomp (IJU), 2012. **3**(۱)
- .۲۳ Jiang, X., Z.G. Xiao, and C. Menon, *Virtual grasps recognition using fusion of Leap Motion and force myography*. Virtual Reality, 2018. **22**: p. 297-308.
- .۲۴ Mahmud, S., et al. *A multi-modal human machine interface for controlling a smart wheelchair*. in *2019 IEEE 7th conference on systems, process and control (ICSPC)*. 2019. IEEE.
- .۲۵ Zhang, Z., C .He, and K. Yang, *A novel surface electromyographic signal-based hand gesture prediction using a recurrent neural network*. Sensors, 2020. **20**(14): p. 3994.
- .۲۶ Al-Hammadi, M., et al., *Hand gesture recognition for sign language using 3DCNN*. IEEE access, 20 :۸ .۲۰ p. 79491-79509.
- .۲۷ Al-Hammadi, M., et al., *Deep learning-based approach for sign language gesture recognition with efficient hand gesture representation*. IEEE Access, 2020. **8**: p. 192527-192542.
- .۲۸ Al-Hammadi, M., et al., *Hand gesture recognition using 3D-CNN model*. IEEE Consumer Electronics Magazine, 2019. **9**(1): p. 95-101.



۲۹. Charbuty, B. and A. Abdulazeez, *Classification based on decision tree algorithm for machine learning*. Journal of Applied Science and Technology Trends, 2021. **2**(01): p. 20-2.8
۳۰. Karapinar Senturk, Z. and M. Sevgul Bakay, *Machine Learning-Based Hand Gesture Recognition via EMG Data*. 2021.



Single-Channel Electromyography Signal Classification of Essential Hand Gestures Using Machine Learning Methods

Shiva Kazembeigbarzi, Ali ghanbar, Sarvin Tohidi, Amirali Alilooie

Bachelor student, Department of Medical Engineering, Faculty of Medical Sciences and Technologies, Islamic Azad University, Science and Research Branch
Tehran, Iran

kbbshiva@gmail.com; Alighanbar.ag@gmail.com; svtohidi@mail.ir;
amirali.alilooei@srbiau.ac.ir; Babak.rezaee@srbiau.ac.ir

ABSTRACT

Hand gestures recognition and classification play an important role in human machine interactions. Electromyography (EMG) pattern recognition for gestures recognition has been a part of research in fields of prosthesis limbs and rehabilitation systems for years. Electromyography data contains information about muscle electrical activity. In this study, EMG data were collected from the flexor carpi ulnaris muscle of six 21-years-old females, and after applying filters and extracting 24 suitable features, the EMG data were classified by five classifiers, including Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Gaussian Mixture Model (GMM), Self-Organizing Map (SOM) and Decision Tree (DT). Statistical analysis showed that the decision tree classification has better results and higher accuracy than the other used classifiers. Small statistical population and low dispersion among the participants were some of the challenges of this study. Choosing a better statistical population with more dispersion, investigating the effects of muscle activity disorders and using the data for artificial prosthesis control or smart wheelchair are suggested for future studies.

KEYWORDS: signal processing, electromyography, decision tree, hand gestures, machine learning, Butterworth filter, EMG