



دانشکده مهندسی برق و رباتیک

پایان نامه کارشناسی ارشد مهندسی مخابرات سیستم

طبقه بندی حرکت دست با استفاده از تحلیل زمان-فرکانس سیگنال

های الکترومایوگرام سطحی

نگارنده: پوریا شریفی

استاد راهنما

دکتر هادی گرایلو

شهریور ۱۳۹۷

شماره: ۱۲۰۰، ۲۰۰
تاریخ: ۲۱، ۶، ۹۷

باسمه تعالی




مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای پوریا شریفی با شماره دانشجویی ۹۵۰۸۵۷۴ رشته مهندسی مخابرات گرایش سیستم تحت عنوان: طبقه بندی حرکت دست با استفاده از تحلیل زمان - فرکانس سیگنال های الکترومایوگرام سطحی که در تاریخ ۱۳۹۷/۰۶/۲۱ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می گردد:

<input type="checkbox"/> مردود	<input checked="" type="checkbox"/> قبول (با درجه: <u>خیلی خوب</u>)
<input type="checkbox"/> عملی	<input checked="" type="checkbox"/> نظری

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	هادی گزالیو	استاد	
۲- استاد راهنمای دوم	—	—	—
۳- استاد مشاور	—	—	—
۴- نماینده تحصیلات تکمیلی	نعمت الله احمدی	استاد	
۵- استاد ممتحن اول	علین بربر	دانشیار	
۶- استاد ممتحن دوم	علیرضا زاهدی	دانشیار	



نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:

تبصره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).



تقدیم بابوسہ بردستان پدرم

به او که نمی دانم از بزرگی اش بگویم یا مردانگی، سخاوت، سکوت، مهربانی و پدرم راه
تمام زندگیست... پدرم دنجوشی، بمشکیت...

و تقدیم به تو ای مادر، ای شوق زیبایی نفس کشیدن

مادرم، هستی من ز، هستی تو ست تا، هستم و، هستی دارم دست دوست.

نگلسار جاودانی مادر است... چشم سار مهربانی مادر است...

و در نهایت تقدیم به کسی که حضورش نشانه لطف الهی در زندگی من است و سایه مهربانش سایه
سار زندگی من است کسی که اسوه صبر و تحمل بوده و مشکلات مسیر را با عشق برایم تسهیل نمود

تشکر و قدردانی

سپاس خدای را که سخنوران، در ستودن او بمانند و شمارندگان، شمردن نعمت های او ندانند و کوشندگان، حق او را گزاردن نتوانند. و سلام و درود بر محمد و خاندان پاک او، طاهران معصوم، هم آنان که وجودمان وامدار وجودشان است؛ و نفرین پیوسته بر دشمنان ایشان تا روز رستاخیز... بدون شک جایگاه و منزلت معلم، اجل از آن است که در مقام قدردانی از زحمات بی شائبه ی او، با زبان قاصر و دست ناتوان، چیزی بنگاریم.

اما از آنجایی که تجلیل از معلم، سپاس از انسانی است که هدف و غایت آفرینش را تامین می کند و سلامت امانت هایی را که به دستش سپرده اند، تضمین؛ بر حسب وظیفه و از باب "من لم یشکر المنعم من المخلوقین لم یشکر الله و جل" : از پدر و مادر عزیزم، این دو معلم بزرگووارم، که همواره بر کوتاهی و درستی من، قلم عفو کشیده و کریمانه از کنار غفلت هایم گذشته اند و در تمام عرصه های زندگی یار و یاور بی چشم داشت برای من بوده اند؛ از استاد با کمالات و شایسته؛ جناب آقای دکتر گرایلو که در کمال سعه صدر، با حسن خلق و فروتنی، از هیچ کمکی در این عرصه بر من دریغ ننمودند و زحمت راهنمایی این پایان نامه را بر عهده گرفتند، کمال تشکر و قدردانی را دارم.

همچنین بر خود واجب می دانم از تمامی اساتید گروه برق مخابرات و الکترونیک دانشگاه صنعتی شاهرود تشکر و قدردانی لازم را نموده باشم.

پوریا شریفی

شهریور ۱۳۹۷

تعهدنامه

اینجانب پوریا شریفی دانشجوی دوره کارشناسی ارشد رشته مخابرات – گرایش مخابرات سیستم دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه "طبقه بندی حرکت دست با استفاده از تحلیل زمان-فرکانس سیگنال های الکترومایوگرام سطحی" تحت راهنمایی آقای دکتر هادی گرایلو متعهد می‌شوم: تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.

- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
 - مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
 - کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « **Shahrood University of Technology** » به چاپ خواهد رسید .
 - حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده‌اند در مقالات مستخرج از پایان نامه رعایت می‌گردد.
 - در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
 - در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .
- تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه‌های رایانه‌ای ، نرم افزارها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی‌باشد.

چکیده

استفاده از پروتز مصنوعی برای فرد یا افرادی که دچار قطع عضو هستند یا به صورت مادرزادی با اختلال جسمی متولد شده اند می تواند بسیاری از فرصت های زندگی و شغلی را به آن ها باز گرداند. جزء اساسی بسیاری از پروتزه های مدرن، سیستم کنترل مایوالکتریک است که از سیگنال های الکترومایوگرام دریافت شده از عضلات فرد برای کنترل و حرکت پروتز استفاده می شود. اگرچه تحقیقات زیادی در این حوزه صورت گرفته که شامل تشخیص و یا بازسازی حرکات دست می شود، اما در حوزه تشخیص و شناسایی حرکات تکی و ترکیبی انگشتان به این مسئله توجه زیادی نشده است.

هدف از تحقیق و گردآوری این پایان نامه ایجاد رویکردی بهینه برای طبقه بندی سیگنال های مایوالکتریک مجموعه ای از حرکات تکی و ترکیبی انگشتان دست است. قسمت عمده ی این پایان نامه به بررسی دقیق و تشخیص حرکات تکی و ترکیبی انگشتان دست با استفاده از سیگنال های EMG سطحی می پردازد، به طوری که می توان موقعیت های انگشت یک دست رباتیک را در پاسخ کنترل کرد.

تعداد الکترودها در جمع آوری سیگنال و دقت طبقه بندی نقش به سزایی دارد به نحوی که استفاده از الکترودها بیش تر معمولاً موجب افزایش دقت طبقه بندی کلاس های حرکتی می شود ولی در طرف مقابل موجب افزایش هزینه و پیچیدگی محاسباتی خواهد شد. در این پایان نامه سعی شده است با حداقل تعداد الکترودها به بالاترین دقت ممکن دست پیدا کنیم. بدین منظور، از پایگاه داده ای که از دو الکترودها EMG واقع بر ساعد دست برای جمع آوری داده های EMG از ده شرکت کننده استفاده کرده است بهره برده ایم. مجموعه ای از ویژگی های مختلف در دو حوزه ی زمان و فرکانس به طریقی استخراج و پیش بینی می شود که حداکثر قابلیت تشخیص (تفکیک) بین حرکات انگشتان دست را دارا باشد. به منظور تحلیل در حوزه فرکانس از تبدیل استاکول (تبدیل S) استفاده شده

است. بعد از مرحله استخراج ویژگی برای کم کردن هزینه ی محاسباتی و کاهش ابعاد از الگوریتم تجزیه و تحلیل مولفه های اصلی برای کاهش ویژگی ها استفاده نموده ایم طوری که دقت طبقه بندی کاهش چشم گیری پیدا نکند. در نهایت با استفاده از سه طبقه بند شبکه عصبی مصنوعی، ماشین بردار پشتیبان و نزدیک ترین K همسایه، داده ها طبقه بندی شده و کلاس های حرکتی مشخص می شوند. نتایج عملی و آزمون های آماری نشان می دهد که روش پیشنهادی با میانگین دقت $92.28 \pm 0.55\%$ قابلیت طبقه بندی ۱۰ حرکت مختلف تکی و ترکیبی انگشتان را دارد که در مقایسه با دیگران نتیجه ی مطلوبی داشته که اهمیت روش پیشنهادی ما را نشان می دهد.

کلمات کلیدی: سیگنال الکترومایوگرام، استخراج ویژگی، حوزه زمان-فرکانس، تبدیل استاکول،

طبقه بندی.

فهرست مطالب

صفحه	عنوان
۱.....	فصل اول : مقدمه
۲.....	۱-۱ مقدمه
۴.....	۲-۱ ضرورت انجام تحقیق
۶.....	۳-۱ روش پیشنهادی
۶.....	۵-۱ ساختار پایان نامه
۹.....	فصل دوم : مروری بر کارهای انجام شده
۱۰.....	۱-۲ مقدمه
۱۱.....	۲-۲ مروری بر کارهای انجام شده
۴۷.....	فصل سوم : مباحث تئوری
۴۸.....	۱-۳ مقدمه
۴۸.....	۲-۳ معرفی سیگنال الکترومایوگرام
۶۰.....	۳-۳ تبدیل استاکول S
۶۵.....	فصل چهارم : روش پیشنهادی
۶۶.....	۱-۴ مقدمه
۶۷.....	۲-۴ روش پیشنهادی
۶۸.....	۳-۴ جمع آوری سیگنال الکترومایوگرام
۷۱.....	۴-۴ پیش پردازش سیگنال الکترومایوگرام
۷۴.....	۵-۴ استخراج ویژگی
۷۸.....	۱-۵-۴ ویژگی ها
۷۸.....	۱-۱-۵-۴ میانگین قدر مطلق
۷۹.....	۲-۱-۵-۴ ریشه میانگین مربعات (مقدار موثر)
۸۰.....	۳-۱-۵-۴ طول شکل موج
۸۰.....	۴-۱-۵-۴ تغییر علامت شیب
۸۱.....	۵-۱-۵-۴ ضریب اتورگرسیو
۸۱.....	۶-۱-۵-۴ نرخ عبور از صفر
۸۲.....	۷-۱-۵-۴ واریانس

۸۲.....	۴-۵-۱-۸ بیشترین مقدار
۸۲.....	۴-۵-۱-۹ کمترین مقدار
۸۲.....	۴-۵-۱-۱۰ میانگین سیگنال
۸۲.....	۴-۵-۱-۱۱ فرکانس میانه
۸۳.....	۴-۵-۱-۱۲ فرکانس متوسط
۸۴.....	۴-۵-۱-۱۳ انتگرال سیگنال الکترومایوگرام
۸۴.....	۴-۵-۱-۱۴ متوسط انرژی سیگنال
۸۴.....	۴-۵-۱-۱۵ میانگین توان سیگنال
۸۵.....	۴-۶ طبقه بندی
۸۹.....	فصل پنجم : نتایج شبیه سازی و مقایسه
۹۰.....	۵-۱ مقدمه
۹۰.....	۵-۲ حوزه زمان
۹۰.....	۵-۲-۱ نتایج شبیه سازی و مقایسه مبتنی بر شبکه عصبی مصنوعی
۹۶.....	۵-۲-۲ نتایج شبیه سازی و مقایسه مبتنی بر ماشین بردار پشتیبان
۱۰۲.....	۵-۲-۳ نتایج شبیه سازی و مقایسه مبتنی بر نزدیکترین k همسایه
۱۱۰.....	۵-۳ حوزه زمان - فرکانس
۱۱۰.....	۵-۳-۱ نتایج شبیه سازی و مقایسه مبتنی بر شبکه عصبی مصنوعی
۱۱۴.....	۵-۳-۲ نتایج شبیه سازی و مقایسه مبتنی بر ماشین بردار پشتیبان
۱۱۷.....	۵-۳-۳ نتایج شبیه سازی و مقایسه مبتنی بر نزدیکترین k همسایه
۱۲۰.....	۵-۳-۴ مقایسه نتایج تحلیل حوزه فرکانس با استفاده از سه طبقه بند مورد استفاده
۱۲۵.....	فصل ششم : نتیجه گیری و پیشنهاد راهکارهای آینده
۱۲۶.....	۶-۱ مقدمه
۱۲۶.....	۶-۲ نتیجه گیری
۱۲۸.....	۶-۳ پیشنهاد راه کارهای آینده
۱۳۰.....	مراجع

فهرست شکل‌ها

صفحه	عنوان
۱۱	شکل ۱-۲ الف) مایوآرمبند ب) محل قرار گیری سنسور های حساس به فشار [۱۶]
۱۲	شکل ۲-۲ بیست و یک حرکت تعریف شده در [۱۶]
۱۳	شکل ۳-۲ میانگین دقت طبقه بندی با انتخاب پانزده K متفاوت [۱۶]
۱۴	شکل ۴-۲ چهار حرکت: الف) خم کردن به سمت بیرون ب) خم کردن به سمت داخل ج) باز کردن د) بستن [۱۸]
۱۵	شکل ۵-۲ شش حرکت انجام شده در [۱۹]
۱۶	شکل ۶-۲ پنج حرکت انجام شده در [۲۲]
۱۷	شکل ۷-۲ مقایسه دقت طبقه بندی با هر یک از ویژگی های استخراج شده بین طبقه بند ماشین بردار پشتیبان و نزدیک ترین K همسایه [۲۳]
۱۸	شکل ۸-۲ محل قرار گیری الکتروود ها به منظور ثبت سیگنال [۲۴]
۱۸	شکل ۹-۲ هشت حرکت تعریف شده [۲۴]
۱۹	شکل ۱۰-۲ ساختار کلی روش ارائه شده در [۲۴]
۲۰	شکل ۱۱-۲ الف) حرکت تعریف شده ب) محل قرار گیری الکتروودها و فاصله از یکدیگر [۲۵]
۲۰	شکل ۱۲-۲ ساختار دیاگرام بلوکی روش ارائه شده در [۲۶]
۲۱	شکل ۱۳-۲ محل قرار گیری الکتروود ها به منظور جمع آوری سیگنال [۲۶]
۲۱	شکل ۱۴-۲ هشت حرکت تعریف شده در [۲۶]
۲۲	شکل ۱۵-۲ سیگنال مربوط به بستن دست و تقسیم آن به پنج بازه با ۲۰۰۰ نمونه [۲۶]
۲۰	شکل ۱۶-۲ سیگنال های ثبت شده از هشت حرکت تعریف شده [۲۶]
۲۳	شکل ۱۷-۲ اعمال تبدیل موجک گسسته بر روی سیگنال مربوط به حرکت بستن دست [۲۶]
۲۵	شکل ۱۸-۲ بلوک دیاگرام روش پیشنهادی در [۲۷]
۲۶	شکل ۱۹-۲ نمونه سیگنال ثبت شده الف) حرکت گرفتن ماژیک ب) حرکت بستن دست [۲۷]
۲۷	شکل ۲۰-۲ هفت حرکت تعریف شده در [۲۷]
۲۸	شکل ۲۱-۲ معماری طبقه بند تطبیقی استنتاج فازی [۲۷]
۳۰	شکل ۲۲-۲ الف) دستگاه ثبت کننده سیگنال الکترومایوگرام ب) ۱۶ الکتروود [۲۹]
۳۰	شکل ۲۳-۲ هشت حرکت تعریف شده [۲۹]
۳۱	شکل ۲۴-۲ بلوک دیاگرام روش ارائه شده در [۳۰]
۳۳	شکل ۲۵-۲ نمونه سیگنال ثبت شده از شخص اول مربوط به حرکت بستن دست [۳۰]

- شکل ۲-۲۶ شش حرکت انجام شده در [۳۲] ۳۵
- شکل ۲-۲۷ هشت حرکت تعریف شده در [۳۳] ۳۶
- شکل ۲-۲۸ مکان قرارگیری الکترودها بر روی ساعد [۳۳] ۳۷
- شکل ۲-۲۹ میانگین دقت طبقه بندی هشت حرکت با استفاده از شبکه عصبی احتمالاتی برای هر فرد شرکت کننده [۳۳] ۳۷
- شکل ۲-۳۰ میانگین دقت طبقه بندی هشت حرکت با استفاده از شبکه عصبی احتمالاتی برای هر پنج نفر شرکت کننده [۳۳] ۳۸
- شکل ۲-۳۱ (الف) دستگاه الکترومایوگرام (ب) پنج حرکت تعریف شده در [۳۵] ۳۸
- شکل ۲-۳۲ بلوک دیاگرام روش پیشنهادی [۳۹] ۴۰
- شکل ۲-۳۳ سیگنال های خام ثبت شده بدون پیش پردازش از ۶ کانال [۳۹] ۴۱
- شکل ۲-۳۴ سیگنال های ثبت شده فیلتر شده و یکسوسازی شده در [۳۹] ۴۲
- شکل ۲-۳۵ شش حرکت تعریف شده در [۴۵] ۴۴
- شکل ۳-۱ مقایسه دامنه و فرکانس EMG با سیگنالهای حیاتی دیگر ۵۰
- شکل ۳-۲ انواع الکتروود: سطحی - سوزنی - سیمی [۴۸] ۵۲
- شکل ۳-۳ نمونه ای از الکتروود سطحی [۴۸] ۵۴
- شکل ۳-۴ حرکات مرتبط با عضلات پوسترپور و انتریور [۵۰] ۵۶
- شکل ۳-۵ عضلاتی که وظیفه باز کردن انگشتان را بر عهده دارد [۵۰] ۵۶
- شکل ۳-۶ عضلاتی که وظیفه بستن انگشتان را بر عهده دارد [۵۰] ۵۸
- شکل ۳-۷ موقعیت مطلوب الکتروود را نشان می دهد [۵۰] ۵۸
- شکل ۳-۸ موقعیت یک الکتروود دو قطبی به طور صحیح بر روی یک عضله فلکسور دیجیتالوروم پروفاندوس نشان داده شده [۵۰] ۵۹
- شکل ۳-۹ اسپکتروگرام سیگنال [۵۴] ۶۱
- شکل ۳-۱۰ اعمال تبدیل S اصلاح شده بر روی سیگنال [۵۴] ۶۲
- شکل ۴-۱ دیاگرام بلوکی روش پیشنهادی ۶۸
- شکل ۴-۲ (الف) مکان قرار گیری الکتروود اول بر روی ساعد دست راست (ب) مکان قرار گیری الکتروود دوم و الکتروود مرجع بر روی ساعد و مچ دست راست [۱۴] ۶۹
- شکل ۴-۳ ده حرکت مورد نظر جهت تشخیص و طبقه بندی [۱۴] ۷۰
- شکل ۴-۴ نمونه ای از سیگنال خام ثبت شده از حرکت بستن دست ۷۱
- شکل ۴-۵ (الف) نمونه ی سیگنال الکترومایوگرام که تحت تاثیر سیگنال قلبی قرار گرفته است. (ب) اثر سیگنال قلبی با استفاده از فیلتر باترورث حذف شده است [۷۷] ۷۳

- شکل ۴-۶ (الف) نمونه ای از سیگنال الکترومایوگرام که تحت تاثیر نوبیز تداخل برق شهر قرار گرفته است. (ب) اثر نوبیز برق شهر با استفاده از یک فیلتر ناچ ۵۰ هرتزی حذف شده است [۷۷]..... ۷۳
- شکل ۴-۷ نمونه ای از سیگنال الکترومایوگرام که دچار آرتیفکت شده است [۷۷]..... ۷۳
- شکل ۴-۸ یک نمونه از اعمال تبدیل استاکول بر روی سیگنال الکترومایوگرام مربوط به شخص اول و حرکت بستن دست برای الکتروود اول..... ۷۷
- شکل ۴-۹ یک نمونه از اعمال تبدیل استاکول بر روی سیگنال الکترومایوگرام مربوط به شخص اول و حرکت بستن دست برای الکتروود دوم..... ۷۷
- شکل ۵-۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه..... ۹۲
- شکل ۵-۲ تاثیر طول پنجره زمانی بر دقت طبقه بندی..... ۹۳
- شکل ۵-۳ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از شبکه عصبی..... ۹۴
- شکل ۵-۴ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه..... ۹۷
- شکل ۵-۵ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از ماشین بردار پشتیبان..... ۹۸
- شکل ۵-۶ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از ماشین بردار پشتیبان..... ۹۹
- شکل ۵-۷ انتخاب k های مختلف جهت کسب بهترین نتیجه برای دقت طبقه بند نزدیکترین همسایه با استفاده از ۳ ویژگی..... ۱۰۲
- شکل ۵-۸ انتخاب k های مختلف جهت کسب بهترین نتیجه برای دقت طبقه بند نزدیکترین همسایه با استفاده از ۳۲ ویژگی..... ۱۰۳
- شکل ۵-۹ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه..... ۱۰۴
- شکل ۵-۱۰ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از نزدیکترین همسایه..... ۱۰۵
- شکل ۵-۱۱ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از نزدیکترین همسایه..... ۱۰۶
- شکل ۵-۱۲ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳۲ ویژگی..... ۱۰۹
- شکل ۵-۱۳ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳ ویژگی..... ۱۰۹
- شکل ۵-۱۴ تاثیر طول پنجره زمانی بر دقت طبقه بندی با استفاده از ۳ ویژگی..... ۱۱۰
- شکل ۵-۱۵ تاثیر طول پنجره زمانی بر دقت طبقه بندی با استفاده از ۳۲ ویژگی..... ۱۱۱
- شکل ۵-۱۶ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی و ۳ ویژگی..... ۱۱۲

- شکل ۵-۱۷ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی و ویژگی ۳۲ و ویژگی ۱۱۴.....
- شکل ۵-۱۸ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان و ۳ ویژگی و ویژگی ۱۱۵.....
- شکل ۵-۱۹ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان و ۳۲ ویژگی و ویژگی ۱۱۷.....
- شکل ۵-۲۰ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه و ۳ ویژگی و ویژگی ۱۱۸.....
- شکل ۵-۲۱ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه و ۳۲ ویژگی و ویژگی ۱۲۰.....
- شکل ۵-۲۲ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳ ویژگی در حوزه زمان-فرکانس..... ۱۲۱.....
- شکل ۵-۲۳ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳۲ ویژگی در حوزه زمان-فرکانس..... ۱۲۱.....

فهرست جدول‌ها

عنوان	صفحه
جدول ۱-۲ دقت طبقه بندی هشت حرکت با شبکه یادگیری عمیق [۲۴].....	۱۸
جدول ۲-۲ نتایج طبقه بندی هشت حرکت با یک سطح تجزیه تبدیل موجک [۲۶].....	۲۴
جدول ۳-۲ تاثیر نرخ نمونه برداری بر دقت طبقه بندی با استفاده از ۳ طبقه بند متفاوت [۲۹].....	۳۱
جدول ۴-۲ تاثیر سطوح مختلف تجزیه حال تجربی سیگنال بر دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی [۳۰].....	۳۲
جدول ۵-۲ پارامتر های مهم در هنگام ثبت سیگنال در [۳۰].....	۳۳
جدول ۶-۲ انتخاب بهترین تعداد لایه مخفی برای شبکه عصبی مصنوعی به منظور پیدا کردن بالاترین دقت [۳۰].....	۳۴
جدول ۷-۲ میانگین دقت طبقه بندی شش حرکت برای دست چپ و راست ده شرکت کننده با استفاده از شبکه عصبی [۳۰].....	۳۴
جدول ۸-۲ مقایسه دقت طبقه بندی با دو روش دیگر با استفاده از طبقه بند نزدیکترین همسایه [۳۲].....	۳۵
جدول ۹-۲ نتایج دقت طبقه بندی با روش های مختلف با استفاده از طبقه بند نزدیکترین همسایه [۳۵].....	۳۹
جدول ۱۰-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزا ساز زیر فضایی [۴۵].....	۴۵
جدول ۱۱-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند نزدیکترین همسایه [۴۵].....	۴۵
جدول ۱۲-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزاساز خطی [۴۵].....	۴۶
جدول ۱۳-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزا ساز خطی مرتبه دوم [۴۵].....	۴۶
جدول ۱-۴ ویژگی های استخراج شده در مقالات تشخیص حرکت دست با استفاده از الکترومایوگرام در سال های ۲۰۱۳ تا ۲۰۱۷.....	۷۵
جدول ۱-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه.....	۹۱
جدول ۲-۵ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی.....	۹۲
جدول ۳-۵ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۶ ویژگی.....	۹۴
جدول ۴-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه.....	۹۵
جدول ۵-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۱۶ ویژگی و طول پنجره ۵۰۰ میلی ثانیه.....	۹۶
جدول ۶-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه.....	۹۷
جدول ۷-۵ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی.....	۹۸

- جدول ۵-۸ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۶ ویژگی ۱۰۰
- جدول ۵-۹ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه ۱۰۱
- جدول ۵-۱۰ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۱۵ ویژگی و طول پنجره ۵۰۰ میلی ثانیه ۱۰۱
- جدول ۵-۱۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه ۱۰۴
- جدول ۵-۱۲ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی ۱۰۵
- جدول ۵-۱۳ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۴ ویژگی ۱۰۷
- جدول ۵-۱۴ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه ۱۰۸
- جدول ۵-۱۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۱۴ ویژگی و طول پنجره ۵۰۰ میلی ثانیه ۱۰۸
- جدول ۵-۱۶ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۳ ویژگی ۱۱۲
- جدول ۵-۱۷ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۳۲ ویژگی ۱۱۳
- جدول ۵-۱۸ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۳ ویژگی ۱۱۵
- جدول ۵-۱۹ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۳۲ ویژگی ۱۱۶
- جدول ۵-۲۰ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۳ ویژگی ۱۱۸
- جدول ۵-۲۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۳۲ ویژگی ۱۱۹
- جدول ۵-۲۲ مقایسه روش پیشنهادی با کارهای انجام شده ۱۲۴



فصل اول

مقدمه

۱-۱ مقدمه

الکترومایوگرافی^۱ روشی پزشکی برای ذخیره و اندازه گیری پتانسیل الکتریکی برون سلولی^۲ تولید شده توسط عضلات است. الکترومایوگرافی عمدتاً برای تشخیص حالت نرمال عضله از حالت ضعف ایجاد شده در اثر اختلالات عصبی به کار می رود. این معمولاً به وسیله الکترودهای دو قطبی که از روی پوست به داخل عضله فرو می روند انجام می پذیرد و این سیگنال هنگام انقباض عضلات روی صفحه مانیتور به نمایش در می آید. الکترومایوگرافی در کنترل ربات پوشیدنی^۳ و پروتز^۴ نیز مورد استفاده قرار می گیرد. الکترودهای سوزنی^۵ که داخل عضله فرو می روند، برای این منظور به علت دردآور بودن مناسب نمی باشند. برای این منظور از الکترودهای سطحی استفاده می شود. دقت این الکترودها به نسبت کمتر است ولی در عین حال برای اندازه گیری میزان فعالیت عضله مناسب هستند. به تکنیک استفاده از این الکترودهای روی پوست، الکترومایوگرافی سطحی اطلاق می شود [۱]. سیگنال الکترومایوگرام یکی از مهمترین سیگنال های حیاتی می باشد که در تشخیص بیماری های مختلف ماهیچه ای کاربرد دارد. سیگنال الکترومایوگرام در مباحث مربوط به جابجایی انسان و تشخیص های عصبی ماهیچه ای مطرح می شود. همچنین در زمینه های فیزیولوژی عصبی بالینی و طب تشخیصی الکترودی استفاده شود. این سیگنال به دو صورت تهاجمی و غیر تهاجمی اخذ می شود. در روش تهاجمی از الکترودهای سوزنی استفاده می کنند. الکترودهای سوزنی را متناسب با حرکت مورد نظر وارد پوست شخص و محل قرارگیری مرتبط با آن ماهیچه می کنند. الکترودهای سوزنی سیگنال ناشی از ماهیچه (یا ماهیچه های) خاصی را ثبت می کنند و به علت نزدیکی به منبع ایجاد سیگنال دارای کیفیت بالاتری نسبت به روش غیرتهاجمی هستند. ولی با این وجود استفاده از روش تهاجمی در همه جا ممکن نیست، زیرا برای ثبت سیگنال در این روش حضور پزشک متخصص

¹ Electromyographi (EMG)

² Extracellular

³ Exoskeleton

⁴ Prosthesis

⁵ Needle Electrodes

جهت شناسایی ماهیچه و جاگذاری الکتروود سوزنی الزامی است. از طرف دیگر تهاجمی بودن روش تاثیری منفی بر بیمار می گذارد و باعث افزایش زمان ثبت سیگنال نیز می شود. از این رو علیرغم کیفیت و قابلیت های بالای این روش پزشکان تمایل به استفاده از روش غیرتهاجمی دارند. به عنوان مثال در سال های اخیر با توجه به پیشرفت هایی که در تکنولوژی انجام شده است، مطالعاتی برای بررسی امکان ثبت سیگنال واحد های حرکتی توسط الکتروود های سطحی صورت گرفته است [۲]. در روش غیر تهاجمی که در این پایان نامه از آن استفاده شده است، الکتروودهای ثبت کننده سیگنال در روی سطح پوست قرار میگیرند. حسن این روش غیر تهاجمی بودن و امکان ثبت سیگنال در هر مکان و زمان می باشد (عدم نیاز به پزشک متخصص و ثبت سیگنال توسط کاربر) و عیب آن تداخل زیاد با نویز های ناخواسته می باشد، که به علت قرارگیری الکتروودها بر روی سطح پوست هرگونه تداخل محیطی مثل نویز دستگاه های الکترومغناطیسی مجاور، بشدت بر سیگنال ثبت شده تاثیر می گذارد در حالی که تداخل محیطی در روش تهاجمی، بعلاوه نزدیکی به منبع ایجاد سیگنال بسیار ناچیز می باشد [۲]. مطالعاتی که در مورد سیگنال الکترومایوگرام صورت گرفته به هیچ وجه کافی نیست و نیاز به پژوهش های بیشتر و کامل تر در این زمینه مشهود است و این موضوع در مورد نحوه اخذ سیگنال و مدل های ارایه شده برای سیگنال هم نیز مشهود می باشد، بطوریکه در اغلب مدل های مطرح شده نگرش بصورت کلی می باشد و مدل های کمتری برای حرکات خاص بیان شده است. آنچه که در مدلسازی اهمیت فراوانی دارد شناخت صحیح و کافی از ماهیچه و جایگاه آنها و نقش هر ماهیچه در حرکات انگشتان می باشد [۲].

تحقیقات اولیه در مورد شناسایی و کنترل بر پایه مایوالکتریک در دهه ۱۹۴۰ انجام شد [۳]، اما با توجه به تکنولوژی محدود در آن زمان، حتی با گذشت چندین دهه در این حوزه پیشرفت چشمگیری حاصل نشد. در اواخر دهه ۱۹۶۰ تا اواسط دهه ۱۹۷۰ [۴] اولین سیستم شناسایی الگوها با استفاده از ورودی های مایوالکتریک توسعه داده شد، گام مهم بعدی در این حوزه زمانی رخ داد که هاجنز و همکارانش [۵] یک سیستم چند منظوره کنترل مایوالکتریک را در سال ۱۹۹۳ معرفی

کردند که عملکرد خوبی در طبقه بندی حرکات چندگانه با استفاده از ویژگی های چندگانه و یک طبقه بند شبکه عصبی مصنوعی به دست آورد. در تحقیقات بعدی که در این زمینه صورت گرفت از یک ساختار مشابه برای طبقه بندی چند منظوره، استفاده شد و این تحقیقات تا به امروز ادامه پیدا کرد. با هدف به حداکثر رساندن دقت طبقه بندی برای مجموعه ای از حرکات، تمرکز اغلب تحقیقات بر روی عناصر مختلف سیستم های تشخیص و کنترل دست مانند مجموعه ویژگی ها و طبقه بندها صورت گرفت. تحقیق در سیستم های کنترل و تشخیص حرکات چند منظوره مبتنی بر سیگنال الکترومایوگرام، معمولاً شامل مجموعه ای از مراحل کلیدی می باشد [۶]. که این مراحل به شرح زیر می باشد: در ابتدا، مجموعه ای از حرکات اندام را به طور مشخص تعریف می نماییم. پس از آن، از افرادی که غالباً سالم هستند، می خواهیم که این حرکات را انجام دهند، در این زمان با استفاده از کانال های متعدد (الکترودهای دستگاه الکترومایوگرام) اطلاعات مورد نیاز را از مکان های عضلانی که به حرکات مد نظر ما مربوط می شوند، جمع آوری می کنیم. سپس یک پنجره زمانی از هر کانال انتخاب شده است و مجموعه ای از ویژگی ها از پنجره مورد نظر استخراج می شود، بعد از آن با استفاده از روش های موجود، ویژگی های استخراج شده اضافی حذف می شود، و سپس برای تصمیم گیری به یک طبقه بند داده می شود [۶].

۱-۲ ضرورت انجام تحقیق

از دست دادن دست و انگشتان یک معضل بزرگ برای افراد معلول محسوب می شود. این اتفاق ممکن است عواقب جدی و منفی را در کیفیت زندگی فردی و گروهی این اشخاص به ویژه در محیط های کاری، ایجاد کند. توسعه یک سیستم کنترل هوشمند و دقیق بر پایه سیگنال های الکترومایوگرام با قابلیت کنترل دست و انگشتان می تواند دریچه امیدی برای این افراد باشد که بتوانند در محیط زندگی و یا کاری از پس امور روزمره خود بر بیایند. علاوه بر کاربرد در ساخت پروتز های مصنوعی، یک سیستم کنترل مایوالکتریک با قابلیت حرکت دست و انگشتان دارای کاربردهای

بالقوه تجاری است، که می توان به رابط های پیشرفته بین انسان و کامپیوتر در علوم نظامی، پزشکی و رباتیک اشاره کرد. اگرچه مطالعات زیادی در این حوزه انجام شده است که شامل شناسایی و کنترل حرکات در ناحیه مچ دست ساعد و بازو [۷] می شود اما مطالعات نسبتا کمی در شناسایی حرکات مربوط به انگشتان تکی و ترکیبی شده است [۸]. بنابراین هدف از این کار توسعه یک روش بهینه برای طبقه بندی حرکات تکی و ترکیبی انگشتان است که در آینده می تواند به عنوان یک سیستم کنترل حسی مایو الکترونیک از آن استفاده شود. مهمترین و اساسی ترین فاکتور برای کنترل دست مایو الکترونیک، سیگنال مایو الکترونیک یا الکترومیوگرام است که فعالیت عصبی عضلانی را اندازه گیری می کند که به طور مستقیم از داخل عضله یا از سطح پوست ثبت می شود. یک سیستم الکترومیوگراف مجموعه ای از اطلاعات را از یک عضله خاص به صورت سیگنال به ما نشان می دهد. این نوع سیستم می تواند در ساخت و کنترل دست و بازوهای رباتیک برای موارد صنعتی و یا افراد معلول مورد استفاده قرار گیرد، زیرا کاربر را قادر می سازد تا به طور طبیعی حرکت پروتز را کنترل کند. یک سیستم کنترل بر پایه الکترومیوگرام زمانی قابل قبول می باشد که بتواند عملکرد عضلانی را با دقت و زمان مناسب پاسخ پذیری نشان دهد. سه مسئله مهم که در موفقیت یک سیستم کنترل مایو الکترونیک حائز اهمیت است عبارت است از : دقت، زمان پاسخ پذیری، وزن و توان مصرفی که رضایت اپراتور به این عوامل بستگی دارد. بدیهی است که عملکردی سیستم کنترل باید به نحوی باشد که پروتز انجام کار مورد نظر توسط اپراتور را با دقت نزدیک به ۱۰۰٪ انجام دهد. با وجود اینکه سیستم های کنترل به بهترین شکل و با روش های روز آموزش داده می شود اما میزان موفقیت این سیستم ها هنوز به نرخ ۱۰۰٪ نرسیده است [۹]. زمان پاسخ سیستم کنترل مایو الکترونیک نباید توسط کاربر قابل تشخیص باشد، به این معنا که وقتی شخص معلول تصمیم به یک حرکت می کند تا انجام آن حرکت توسط سیستم نباید برای کاربر محسوس باشد و معمولا گفته می شود که این زمان در سیستم ها باید کمتر از ۳۰۰ میلی ثانیه باشد [۱۰]. از طرفی هرچه ار الکتروود کمتری برای جمع آوری سیگنال استفاده نماییم به شرط آنکه دقت پایین نیاید باعث می شود دستگاه قابلیت حمل

آسان تری داشته باشد، همچنین موجب می‌گردد مصرف انرژی آن کاهش یابد و نیازی به باتری های سنگین وزن نباشد و حمل آن برای کاربر راحت تر خواهد بود. به همین جهت در این پایان نامه سعی شده است تا حد امکان با استفاده از کمترین الکتروود به بالاترین دقت تفکیک بین حرکات برسیم.

۳-۱ روش پیشنهادی

با توجه به بررسی مقالات و پایان نامه های ارائه شده در زمینه طبقه بندی سیگنال های الکترومایوگرام خواهیم دید که عمده توجه نویسندگان بر روی شناسایی و طبقه بندی حرکات مربوط به مچ دست بوده و برای تحلیل سیگنال های جمع آوری شده از ماهیچه ها تمرکز ویژه ای در حوزه ی زمان داشته اند. در این پایان نامه سعی شده تا حرکات مربوط به انگشتان به ویژه حرکات ترکیبی بررسی شود. برای تحلیل سیگنال ها از حوزه ی زمان-فرکانس استفاده شده است تا بتوانیم به طور همزمان اطلاعات مربوط به زمان و هم فرکانس را مورد ارزیابی قرار دهیم که میتواند همزمان اطلاعات مفیدی از زمان و از فرکانس در مورد عضله مورد نظر به ما دهد که بدین منظور از تبدیل S یا استاکول استفاده کرده ایم. تبدیل استاکول در مقایسه با تبدیل فوریه زمان کوتاه، در فرکانس های بالا تفکیک پذیری زمانی بهتر و در فرکانس های پایین تفکیک پذیری فرکانسی بهتری ایجاد می کند [۱۱]. از طرفی می توان تبدیل S را ترکیبی از تبدیل فوریه زمان کوتاه و تبدیل موجک پیوسته دانست به این علت که هم می تواند طیف فرکانسی سیگنال را مانند STFT نمایش دهد و همچنین می تواند مانند موجک مولفه های زمانی و فرکانسی سیگنال را به صورت همزمان گزارش دهد.

۴-۱ ساختار پایان نامه

پایان نامه ارائه شده شامل بررسی یک رویکرد بهینه برای طبقه بندی و شناسایی حرکات تکی و ترکیبی انگشتان دست بر اساس ساختاری که در مقدمه ذکر شده است می باشد. در فصل دوم به مروری بر کارهای انجام شده بر اساس حوزه تحلیل و نوع طبقه بند مورد استفاده برای تفکیک

سیگنال های الکترومایوگرام می پردازیم. در فصل سوم به معرفی مفاهیم اولیه و معرفی سیگنال الکترومایوگرام و چالش های موجود برای ثبت سیگنال و همچنین به مباحث تئوری که در روش پیشنهادی از آن استفاده شده خواهیم پرداخت. در فصل چهارم روش پیشنهادی ارائه شده است. در فصل پنجم به نتایج شبیه سازی بر روی پایگاه داده مورد استفاده و همچنین مقایسه آن با کارهای موجود خواهیم پرداخت. همچنین نتیجه گیری و پیشنهادات برای کارهای آتی در فصل ششم ذکر شده است.



فصل دوم

مروری بر کارهای

پیشین

۲-۱ مقدمه

تحقیق در حوزه کنترلر پروتز مبتنی بر الکترومایوگرام با استفاده از شناسایی آماری الگو به دو بخش عمده تقسیم می شود که عبارت است از: استخراج ویژگی و طبقه بندی، کارهای انجام شده در بخش استخراج ویژگی عمدتاً از سیگنال در حوزه زمان استخراج ویژگی صورت گرفته است که می توان به ویژگی های هودینز^۱ اشاره کرد که برای اولین بار در سال ۱۹۹۳ از چند ویژگی ساده ی حوزه زمان برای کنترل دست مصنوعی بهره برد که پاسخ نسبتاً مطلوبی در برداشت [۱۲]. تا به امروز با اینکه تلاش های بسیاری برای ابداع ویژگی های جدید در حوزه ی فرکانس [۱۳] صورت گرفته است اما باز هم ویژگی های زمانی توانسته اند موقعیت خود را به عنوان یک مجموعه ی ویژگی ساده و در عین حال با قابلیت جداسازی بالا حفظ نمایند. از جمله این ویژگی ها که در حوزه زمان از آن ها استفاده شده است می توان به ریشه میانگین مربعات، میانگین مقدار مطلق، طول شکل موج، تغییر شیب علامت، نرخ عبور از صفر و اشاره کرد. در بخش طبقه بندی عمده روش های استفاده شده می توان به شبکه عصبی مصنوعی، ماشین بردار پشتیبان، نزدیکترین همسایه K، تفکیک کننده خطی، مدل مخفی مارکوف، سیستم های فازی، مدل مخلوط گوسی و اشاره کرد.

در سال های اخیر با پیشرفت روزافزون تکنولوژی، توجه ویژه ای به رابط های انسان- کامپیوتر شده است بدین منظور نویسندگان به بررسی و طبقه بندی سیگنال های الکترومایوگرام پرداخته اند. مهمترین نکاتی که از بررسی این روش ها می توان دریافت عبارتند از: (۱) طول پنجره زمانی انتخاب شده بر روی سیگنال، تاثیر زیادی در دقت طبقه بندی خواهد داشت [۱۴]. (۲) انتخاب و تعیین ویژگی مناسب جهت استخراج ویژگی از سیگنال های الکترومایوگرام می تواند دقت طبقه بندی را بهبود ببخشد. (۳) افزایش تعداد الکتروود جهت ثبت و جمع آوری سیگنال می تواند دقت طبقه بندی را افزایش دهد و در مقابل موجب افزایش هزینه محاسباتی و مالی شود [۱۵]. (۴)

¹ Hudgins

نوع الگوریتم مورد استفاده جهت طبقه بندی سیگنال های حرکتی می تواند در نتیجه تاثیر گذار باشد [۱۴]. در این فصل سعی شده است تا مطالب روز مرتبط با این موضوع ارائه شود.

۲-۲ مروری بر کارهای انجام شده

در [۱۶] یک روش جدید بر اساس ترکیبی از سیگنال های الکترومایوگرام و سیگنال های فشار برای تشخیص حرکات ریز دست ارائه شده است. در این روش از نوار بازویی ثبت الکترومایوگرام^۱ که دارای هشت الکتروود برای ثبت سیگنال الکترومایوگرام ساعد است استفاده می شود که نرخ نمونه برداری ۲۰۰ هرتز می باشد و بطور همزمان پنج سنسور حساس در برابر نیرو^۲ بر روی پشت انگشتان مطابق شکل (۱-۲) بر روی پشت دست قرار می گیرد. به منظور انجام این آزمایش از سی نفر شرکت کننده سی ساله، دوازده زن و هجده مرد که همگی راست دست هستند و هیچ گونه بیماری در عضلات خود ندارند استفاده شده است. شرکت کنندگان به طور تصادفی به سه گروه تقسیم می شوند. شرکت کنندگان باید ۲۱ حرکت از پیش تعریف شده را انجام دهند. حرکات در شکل (۲-۲) نشان داده شده است.



(الف)



(ب)

شکل ۱-۲ (الف) مایوآرمبند (ب) محل قرار گیری سنسور های حساس به فشار [۱۶]

¹ MyoArmband

² force sensitive resistors

UP	DOWN	LEFT	RIGHT	FIST	SPREAD	PF	OK	TMC	TRC	TPC
YEAH	FLT	FLI	FLM	FLR	GOOD	POINT	PEN	PB	WB	

شکل ۲-۲ بیست و یک حرکت تعریف شده در [۱۶]

به منظور طبقه بندی سیگنال های حاصل از حرکات ویژگی هایی از سیگنال های الکترومایوگرام و سیگنال های فشار استخراج شده است. این مقاله ویژگی های حوزه زمانی، حوزه فرکانسی و حوزه زمان-فرکانس سیگنال های حرکتی را استخراج کرده است که عبارت اند از ریشه میانگین مربعات^۱، انحراف معیار^۲، مرتبه چهارم ضریب اتورگرسیو^۳، میانگین توان فرکانسی^۴ و میانگین فرکانس^۵. که همه ی این ویژگی ها از هشت کانال الکترومایوگرام و پنج کانال فشار استخراج شده است که در مجموع صد و چهار ویژگی استخراج گردیده است در ادامه از نرم افزار سایکیت لرن^۶ برای انتخاب ویژگی و طبقه بندی استفاده شده است. سایکیت لرن یک ماژول پایتون است که طیف گسترده ای از الگوریتم های یادگیری ماشین را ادغام می کند. در نهایت داده های آموزشی بین ۱- و ۱ نرمال می شود به امید آنکه دقت نتیجه را بهبود ببخشد. پنجاه ویژگی با بالاترین نمره برای طبقه بندی در مرحله بعد استخراج می شود. بنابراین یک حرکت را می توان به عنوان یک بردار ویژگی ۱×۵۰ بعد ارائه کرد. در نهایت بردار های ویژگی به منظور تفکیک به طبقه بند نزدیکترین k همسایه^۷ داده شده است. الگوریتم اصلی نزدیکترین همسایه توسط کاور و هارت در سال ۱۹۶۸ پیشنهاد شد و به لحاظ نظری مورد تجزیه و تحلیل و مطالعه قرار گرفت که جزو یکی از مهمترین روش های غیر پارامتریک محسوب می شود [۱۷]. دلیل این که الگوریتم نزدیکترین همسایه را انتخاب می کنند، این است که

¹ Root Mean Square

² Standard Deviation

³ A Fourth-order Autoregressive Model


⁴ Mean Power Frequency

⁵ Median Frequency

⁶ Scikit Learn

⁷ K nearest neighbors

این الگوریتم برای زمانی که تعداد نمونه ها کم باشد کارآمد است. از طرفی این الگوریتم آسان و دارای محاسبات ساده ای است. این الگوریتم عمدتاً به انتخاب یک "مقدار مناسب k " بستگی دارد. اگر k خیلی کوچک باشد، الگوریتم تعداد کمی از همسایگان را دریافت می کند و دقت طبقه بندی را کاهش می دهد. با این حال، اگر k بیش از حد بزرگ باشد، محاسبات زیاد خواهد شد. در این مقاله بهینه ترین k از طریق اعتبارسنجی متقابل^۱ بدست آمده است. الگوریتم از طریق ده مرتبه اعتبارسنجی متقابل در مجموعه داده ها، دقت اعتبارسنجی متقابل را از مقادیر مختلف پارامتر k محاسبه و انتخاب می کند. به عنوان مثال، الگوریتم، k را از یک تا پانزده آزمایش کرده است، دقت اعتبارسنجی متقابل در شکل (۲-۳) نشان داده شده است. ملاحظه می شود که k با مقدار هشت بهترین نتیجه را حاصل می کند. هنگامی که یک بردار ویژگی از یک حرکت جدید وارد شود، فاصله ۸ تا از نزدیکترین همسایه به داده های آموزشی را محاسبه می کند. این آزمایش نشان می دهد که الگوریتم ارائه شده در این مقاله دارای دقت طبقه بندی ۹۶/۰۵ درصد برای ۲۱ حرکت دست از پیش تعیین شده است. نشان داده می شود که ترکیبی از الکترومایوگرام و سنسورهای فشار به طور قابل ملاحظه ای دقت شناسایی حرکات کوچک و ریز دست را افزایش میدهد.



شکل ۲-۳ میانگین دقت طبقه بندی با انتخاب پانزده K متفاوت [۱۶]

در [۱۸] برای ثبت سیگنال از سه نفر (۱ زن، ۲ مرد) از نوار بازویی ثبت الکترومایوگرام با هشت الکتروود به منظور ثبت چهار حرکت که در شکل نمایش داده شده است استفاده شده است. از هر

¹ Cross Validation

شرکت کننده خواسته شد تا هر حرکت را ده مرتبه تکرار کند. بعد از جمع آوری سیگنال ها به دلیل تفاوت در دامنه سیگنال که از فرد به فرد متفاوت است، بین ۰ و ۱ نرمال شد. از هرکانال هفت ویژگی میانگین مقادیر مطلق^۱، ریشه میانگین مربعات، واریانس^۲، انحراف معیار، نرخ عبور از صفر^۳، تغییر علامت شیب^۴ و طول موج^۵ استخراج شده است و در نهایت بردارهای ویژگی مربوط به هر سیگنال به منظور طبقه بندی به یک شبکه عصبی مصنوعی^۶ روبه جلو^۷ داده شده است. هفتاد درصد داده ها به آموزش^۸ و ۱۵٪ به آزمایش^۹ و ۱۵٪ به اعتبارسنجی اختصاص داده شده در نهایت روش پیشنهادی میانگین دقت ۹۸٪ را برای تشخیص چهار حرکت ارائه شده در شکل (۲-۴) نشان می دهد.



شکل ۲-۴ چهار حرکت: الف) خم کردن به سمت بیرون ب) خم کردن به سمت داخل ج) باز کردن د) بستن [۱۸]

در [۱۹] یک روش برای طبقه بندی حرکات مختلف دست از سیگنال های الکترومایوگرام سطحی مطرح شده است. سیگنال الکترومایوگرام سطحی به بازه های^{۱۰} زمانی کوچک تقسیم می شود و سپس از هر زیر فریم ضرایب اتورگرسیو استخراج می شود. این ضرایب به عنوان ویژگی های ورودی به طبقه بند نزدیکترین k همسایه به منظور طبقه بندی شش حرکت داده می شود. از یک پایگاه داده معتبر برای بررسی نتایج استفاده شده است [۲۰]. مجموعه داده ها از پنج فرد سالم (دو مرد و

¹ Mean Absolute Value

² Variance

³ Zero Crossing

⁴ Slope Sign Change

⁵ Waveform Length

⁶ Artificial Neural Network


⁷ Feed Forward

⁸ Train

⁹ Test

¹⁰ Frame

سه زن) تقریباً یکسان (۲۲-۲۲ سال) جمع آوری شده است. حرکات دست، در شکل (۲-۵) نمایش داده شده است.



شکل ۲-۵ شش حرکت انجام شده در [۱۹]

از داوطلبان خواسته شده تا شش حرکت دست را با سرعت و نیروی مناسب به مدت شش ثانیه انجام دهند و از هر حرکت سی بار ثبت صورت گرفت. بنابراین در مجموع برای هر فرد صد و هشتاد بار ثبت سیگنال صورت گرفته است. سیگنالها با نرخ پانصد هرتز نمونه برداری شده است. به منظور حذف نویز یک فیلتر باتروورث^۱ با فرکانس قطع^۲ پایین پانزده هرتز و فرکانس قطع بالای پانصد هرتز و یک فیلتر ناچ^۳ در پنجاه هرتز برای حذف اثر تداخل برق شهر به سیگنالها اعمال شده است. روش دقیق جمع آوری دادهها در [۲۱] شرح داده شده است. در نهایت با استفاده از طبقه بند نزدیکترین همسایه به دقت ۸۷/۸۷ درصد برای شناسایی ۶ حرکت رسیده است.


در [۲۲]، دادههای الکترومایوگرام از طریق نوار بازویی ثبت الکترومایوگرام با هشت الکتروود بر روی ساعد و از یازده فرد سالم به طور داوطلبانه با نرخ نمونه برداری دویست هرتز ثبت شده است. از داوطلبان درخواست شده که هر یک از پنج حرکت مورد نظر شکل (۲-۶) را پنج مرتبه به طوری

^۱ Butterworth Filter

^۲ Cutoff Frequency

^۳ Notch Filter

که طول زمان انقباض مربوط به هر حرکت سی ثانیه و زمان استراحت بین هر پنج بار تکرار سه ثانیه باشد انجام دهند بنابراین تعداد کل، برابر دویست و هفتاد و پنج است (۱۱×۵×۵).



شکل ۲-۶ پنج حرکت انجام شده در [۲۲]

پس از انجام فرایند ثبت، بر روی داده ها در هر کانال روند نرمال سازی انجام می گیرد. سپس چهار ویژگی در حوزه زمان از سیگنال استخراج شده است. این ویژگی ها عبارت اند از: مجموع پیک ها ^۱، مقدار میانگین مطلق، دامنه ویلسون ^۲، ریشه میانگین مربعات. در نهایت به منظور طبقه بندی، داده ها به طبقه بند نیو بیزین ^۳ داده می شود. دقت طبقه بندی برابر است با ۱۸۱۸/۹۰٪ که مربوط است به دویست و چهل هشت نمونه از دویست و هفتاد و پنج نمونه که به درستی تشخیص داده شده است.


سیگنال های مورد استفاده در [۲۳] از پایگاه داده UCI گرفته شده است. این سیگنال ها توسط یک دستگاه ثبت سیگنال الکترومایوگرام دو کاناله و از روی عضلات ساعد با نرخ نمونه برداری پانصد هرتز ثبت و جمع آوری شده است. این داده ها متعلق به ۵ فرد سالم (۲ مرد، ۳ زن) با سن تقریباً یکسان هستند. به منظور حذف نویز بر روی سیگنال ها یک فیلتر باترورث با فرکانس قطع پایین پانزده هرتز و فرکانس قطع بالای پانصد هرتز و یک فیلتر ناچ پنجاه هرتز به منظور حذف تداخل برق شهری اعمال شده است. سپس از هر سیگنال هفت ویژگی میانگین ارزش مطلق، ریشه میانگین مربعات،

¹ Sum Of Peak

² Willison Amplitude

³ Naive Bayesian Classification

انتگرال جذر نمونه^۱، طول شکل موج، میانگین تغییرات دامنه^۲، تفاوت مقدار مطلق انحراف معیار^۳، آشکارساز لگاریتم^۴ استخراج شده است. در نهایت داده ها به ۲ طبقه بند ماشین بردار پشتیبان^۵ و نزدیکترین همسایه داده می شود. نتایج شکل (۷-۲) نشان می دهد طبقه بند ماشین بردار پشتیبان نتایج مطلوب تری نسبت به نزدیکترین همسایه دارد.



شکل ۷-۲ مقایسه دقت طبقه بندی با هر یک از ویژگی های استخراج شده بین طبقه بند ماشین بردار پشتیبان و نزدیک ترین K همسایه [۲۳]

در [۲۴] برای طبقه بندی سیگنال های الکترومایوگرام حاصل از حرکات دست از شبکه یادگیری عمیق کانولوشن^۶ استفاده شده است. با استفاده از پنج الکتروود بر روی ساعد شکل (۸-۲)، سیگنال های مرتبط با هشت حرکت شکل (۹-۲) ثبت و جمع آوری شده است. سپس بر روی هر یک از سیگنال ها تبدیل فوریه زمان کوتاه^۷ اعمال شده است و سپس به ورودی شبکه داده شده و عمل یادگیری صورت گرفته است. ساختار کلی روش پیشنهاد شده در شکل (۱۰-۲) نمایش داده شده است. علت استفاده از این روش برای طبقه بندی این است که، با وجود اینکه شبکه های یادگیری عمیق کانولوشن برای یادگیری خیلی زمان بر هستند و برای کاربرد های بلادرنگ کاربرد ندارند ولی این مزیت را دارا هستند که فقط با یکبار یادگیری بتوانند در هر روز یا زمان دیگر سیگنال های

¹ Simple Square Integral

² Average Amplitude Change

³ Absolute Standard Deviation Value Difference


⁴ Log Detector

⁵ Support Vector Machine


⁶ Deep Learning Convolution

⁷ Short Time Fourier Transform

الکترومایوگرام جدیدی را شناسایی کرده و حرکات را با دقت بسیار مطلوبی طبقه بندی نمایند که نتایج حاصل از هر حرکت در جدول (۱-۲) ارائه شده است.



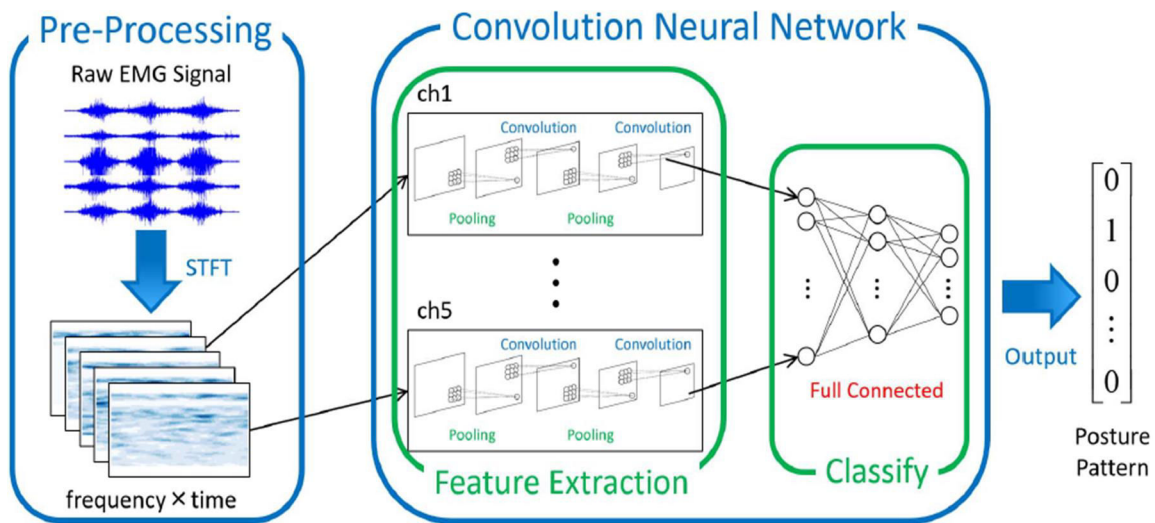
شکل ۸-۲ محل قرار گیری الکتروود ها به منظور ثبت سیگنال [۲۴]



شکل ۹-۲ هشت حرکت تعریف شده [۲۴]

جدول ۱-۲ دقت طبقه بندی هشت حرکت تعریف شده با شبکه یادگیری عمیق [۲۴]

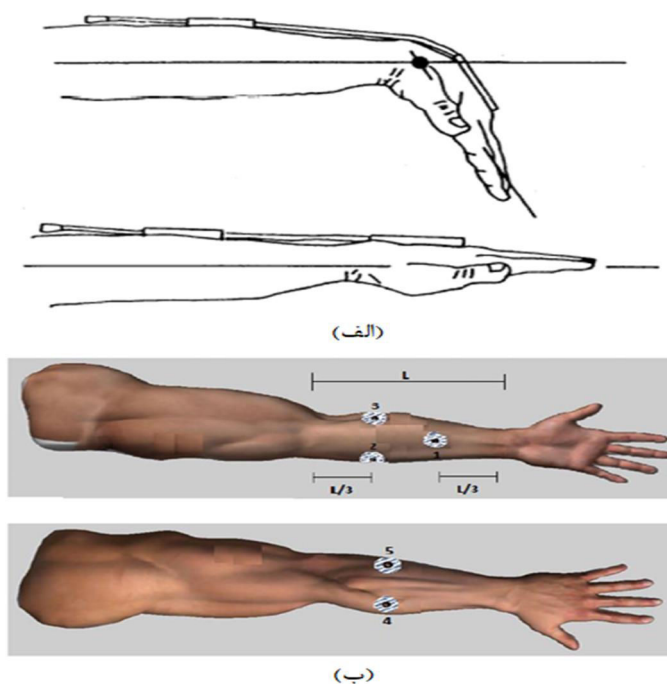
Day	Classification posture							
	1	2	3	4	5	6	7	8
1	100	93	97	54	100	100	100	99
2	100	100	100	76	100	100	100	100
3	100	100	100	0	100	100	0	100



شکل ۲-۱۰ ساختار کلی روش ارائه شده در [۲۴]

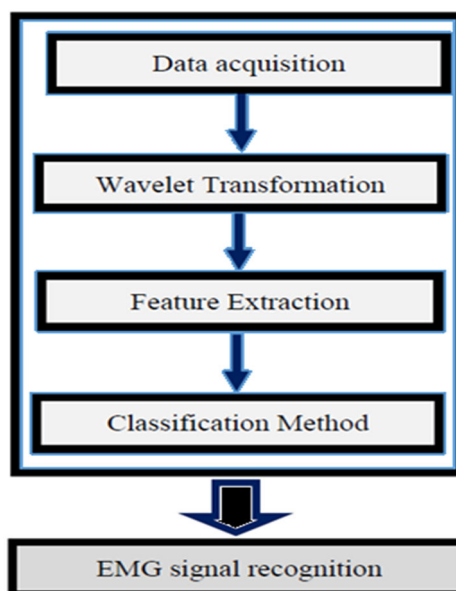
در [۲۵] یک الگوریتم شناسایی مبتنی بر الکترومایوگرام را برای شناسایی و تشخیص نوع حرکت دست در طی حرکات سلسه بار از سیگنال الکترومایوگرام، با استفاده از یک شبکه عصبی مصنوعی به عنوان طبقه بند را پیشنهاد می کند. در مرحله جمع آوری سیگنال از ده شخص سالم و از هر شخص پنج بار با نرخ نمونه برداری ۲۰۰۰ هرتز و با استفاده از الکترودهای از جنس نقره کلرید^۱ بر روی ساعد سیگنال ثبت شده است. همچنین به منظور شناسایی زاویه مچ دست از یک دستگاه بیومتریک SG65 استفاده شده است. شکل (۲-۱۱) محل قرار گیری الکترودها و حرکت خم کردن را نمایش می دهد.

^۱ Ag-AgCl Electrode



شکل ۱۱-۲ (الف) حرکت تعریف شده (ب) محل قرار گیری الکترودها و فاصله از یکدیگر [۲۵]

در [۲۶] از تبدیل موجک گسسته^۱ و طبقه بند شبکه عصبی مصنوعی به منظور طبقه بندی حرکات دست استفاده شده است. مراحل و ساختار کلی در شکل (۲-۱۲) آورده شده است.



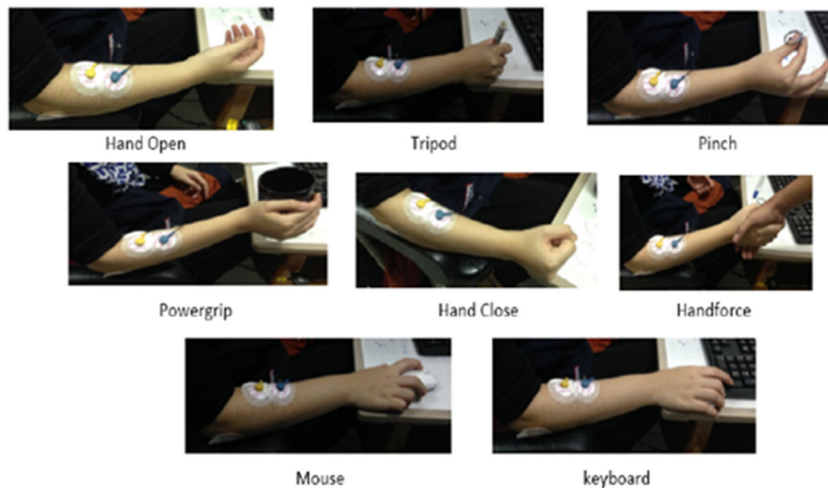
شکل ۲-۱۲ ساختار دیاگرام بلوکی روش ارائه شده در [۲۶]

¹ Discrete Wavelet Transform

در ابتدا سیگنال های الکترومایوگرام دست از عضله رادیال کاریبی فلکسور^۱ با استفاده از دو الکتروود با فاصله دو سانتی متر از یکدیگر ثبت شده است. محل قرار گیری الکتروودها و همچنین هشت حرکت مورد نظر به ترتیب در شکل (۲-۱۳) و (۲-۱۴) نشان داده شده است.



شکل ۲-۱۳ محل قرار گیری الکتروودها به منظور جمع آوری سیگنال [۲۶]




شکل ۲-۱۴ هشت حرکت تعریف شده در [۲۶]

جمع آوری داده ها از پانزده فرد، که هر فرد هر یک از هشت حرکت مورد نظر را هشت بار تکرار می کند صورت گرفته است (از پنج تکرار صرفه نظر شده است). هر سیگنال الکترومایوگرام به بخش های

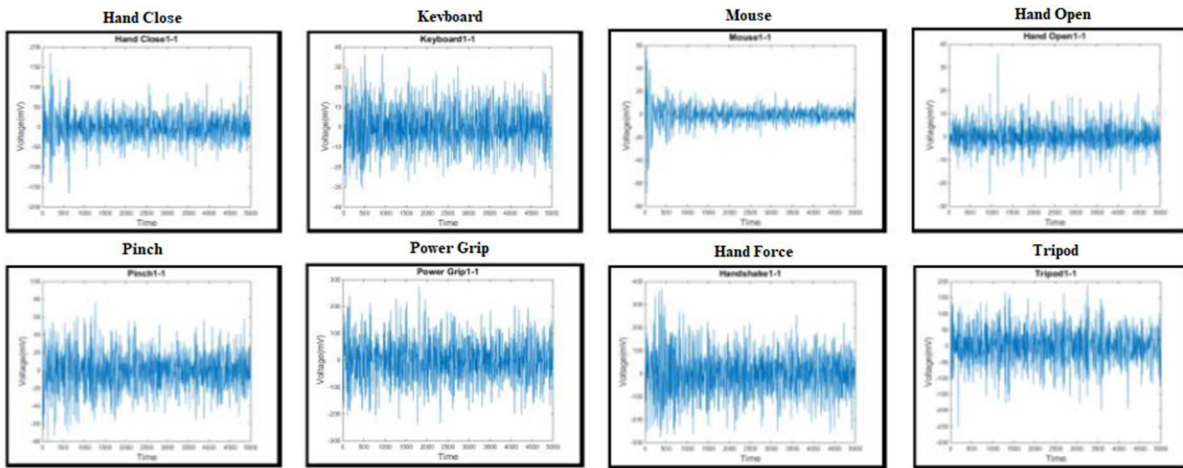
^۱ Flexor Carpi Radialis

^۱ ۲۰۰۰ نمونه ای تقسیم میشود و هر بخش بر روی نمودار زمانی رسم می شود که این فریم بندی به صورت مجزا صورت گرفته است. شکل (۲-۱۵) یک مثال از تقسیم سیگنال برای حرکت بستن دست را نشان می دهد. در شکل (۲-۱۶)، سیگنال های ثبت شده مربوط به هشت حرکت را مشاهده می کنید. در فرایند بعدی تبدیل موجک گسسته با استفاده از نرم افزار متلب بر روی سیگنال ها اعمال می شود که هر سیگنال را به شش زیر مجموعه تقریب و جزئیات تقسیم می کند که در شکل (۲-۱۷) نشان داده شده است.




شکل ۲-۱۵ سیگنال مربوط به بستن دست و فریم بندی آن به پنج بازه با ۲۰۰۰ نمونه [۲۶]

¹ Segments



شکل ۲-۱۶ سیگنال های ثبت شده از هشت حرکت تعریف شده [۲۶]



شکل ۲-۱۷ اعمال تبدیل موجک گسسته بر روی سیگنال مربوط به حرکت بستن دست [۲۶]

گام بعدی فرآیند استخراج ویژگی است که استخراج اطلاعات مفید موجب می گردد بتوانیم سیگنال های مرتبط به هر حرکت را به خوبی شناسایی کنیم و آن را از مابقی سیگنال های مرتبط با حرکات تفکیک نماییم. پنج معیار برای استخراج ویژگی در این مقاله مورد مطالعه قرار گرفته است. سه معیار در حوزه زمان عبارت اند از: کشیدگی^۱، چولگی^۲ و ریشه میانگین مربعات و دو معیار دیگر در حوزه فرکانس عبارت اند از: توان کل^۳ و میانگین توان^۴. در نهایت ویژگی های استخراج شده به عنوان ورودی به یک شبکه عصبی مصنوعی داده شده است تا طبقه بندی را انجام دهد نتایج طبقه بندی مربوط به حرکات در جدول (۲-۲) زیر نمایش داده شده است.

جدول ۲-۲ نتایج طبقه بندی هشت حرکت با یک سطح تجزیه تبدیل موجک [۲۶]

Finger movement	True Classification							
	Hand open	Tripod	Pinch	Power grip	Hand close	Hand force	Mouse	Key-board
Hand open	5	0	0	0	0	0	0	0
Tripod	0	5	0	0	0	0	0	0
Pinch	0	0	4	0	0	0	1	0
Power grip	0	0	0	4	4	0	0	2
Hand close	0	0	0	0	1	0	0	0
Hand force	0	0	1	0	0	5	0	0
Mouse	0	0	0	0	0	0	4	0
Keyboard	0	0	0	1	0	0	0	3
Accuracy (%)	100	100	80	80	20	100	80	60
Overall accuracy (%)	77.5							

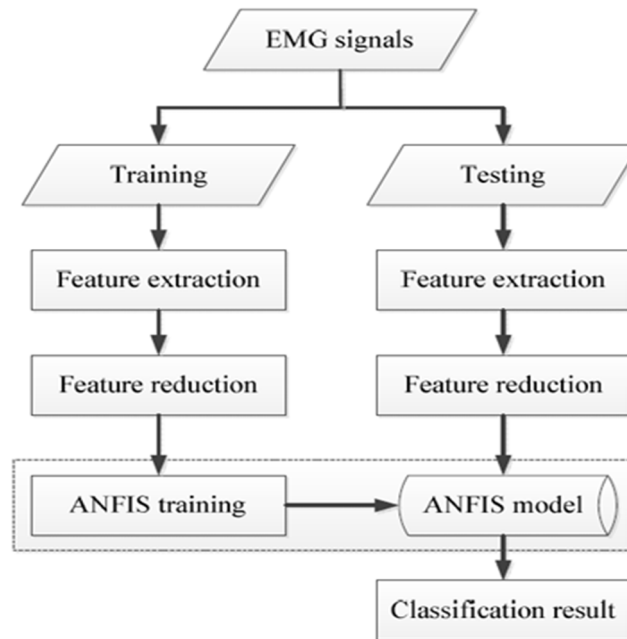
¹ Kurtosis

² Skewness

³ Total Power

⁴ Mean Power

در [۲۷] به مقایسه دو طبقه بند تطبیقی استنتاج فازی عصبی^۱ و ماشین بردار پشتیبان به منظور طبقه بندی سیگنال های الکترومایوگرام پرداخته است. شکل (۲-۱۸) بلوک دیاگرام روش پیشنهادی در [۲۷] را نمایش می دهد.




شکل ۲-۱۸ بلوک دیاگرام روش پیشنهادی در [۲۷]


مجموعه داده های الکترومایوگرام از پنج شخص جمع آوری شده است. ابتدا به منظور جمع آوری سیگنال الکترومایوگرام از پنج فرد که این افراد همه بدون اختلالات عصبی یا ماهیچه ای بوده اند و قبل از شرکت در این تحقیق فرم رضایت آگاهانه دریافت کرده اند خواسته شد تا بر روی صندلی نشسته، بازوی خود را در یک موقعیت ثابت و بی حرکت قرار دهند. به منظور جلوگیری از اثر فعالیت عضلات مختلف بر روی سیگنال الکترومایوگرام تولید شده [۲۸] الکترودها بر روی عضلات فلکسور به صورت سطحی قرار گرفت و سیگنال با نرخ نمونه برداری هزار هرتز جمع آوری شد. همه ی شرکت کنندگان به منظور انجام حرکت از حالت انقباض به استراحت با استفاده از یک علامت شنیداری تعلیم داده شده اند که هر حرکت ده ثانیه زمان برد. هر حرکت ۱۰ بار تکرار شد و دوره استراحت

^۱ Neuro Fuzzy Inference Adaptive

بین پنج تا هفت ثانیه بین آزمایشات بود. یک نمونه از سیگنال های الکترومایوگرام و هفت حرکت مربوط به ترتیب در شکل (۱۹-۲) شکل (۲۰-۲) نشان داده شده است.



شکل ۱۹-۲ نمونه سیگنال ثبت شده الف) حرکت گرفتن ماژیک ب) حرکت بستن دست [۲۷]



شکل ۲-۲۰ هفت حرکت تعریف شده در [۲۷]

در [۲۷] شانزده روش استخراج ویژگی بررسی شده است که این ویژگی ها به شرح زیر است [۲۸]:
 انتگرال سیگنال الکترومایوگرام^۱، میانگین مقدار مطلق اصلاح شده، نوع اول میانگین مقدار مطلق اصلاح شده، نوع دوم میانگین مقدار مطلق، انتگرال جذر نمونه، واریانس، ریشه میانگین مربعات، طول شکل موج، تفاوت مقدار مطلق انحراف معیار، ضریب اتورگرسیون، هیوراکتیویته^۲، هیورمبیلیته^۳ و هیور کامپلیسیتی^۴. در نهایت به منظور کاهش محاسبات با استفاده از الگوریتم تحلیل مولفه اصلی^۵، تعداد ویژگی ها به سه کاهش پیدا کرده است. طبقه بند تطبیقی استنتاج فازی عصبی یک نوع خاص از روش طبقه بندی فازی عصبی است که قابلیت سازگاری شبکه عصبی مصنوعی و منطق فازی را در خود جای می دهد. معماری این شبکه شامل پنج لایه می باشد که در شکل (۲-۲۱) نشان داده شده است.


¹ Integrated Electromyogram

² Hjorth activity

³ Hjorth mobility

⁴ Hjorth complexity

⁵ Principal component analysis



شکل ۲-۲۱ معماری طبقه بند تطبیقی استنتاج فازی [۲۷]

در نهایت نتایج با استفاده از دو طبقه بند تطبیقی استنتاج فازی عصبی و ماشین بردار پشتیبان و الگوریتم تحلیل مولفه اصلی بررسی و مقایسه می شود. در ابتدا داده ها با استفاده از ماشین بردار پشتیبان و تحلیل مولفه اصلی مورد آزمایش قرار گرفت و دقت ۸۲/۸۶ درصد را ارائه داد. سپس با استفاده از طبقه بند تطبیقی استنتاج فازی و تحلیل مولفه اصلی دقت طبقه بندی به ۹۱/۴۳ درصد افزایش یافت.

در [۲۹] هدف، بررسی روشی برای کاهش هزینه سیستم الکترومایوگرام است که این کار با بررسی اثر نرخ نمونه برداری بر دقت تشخیص حرکات دست صورت پذیرفته است. دو گروه داده، گروه درونی^۱ و گروه متقابل^۲ برای ارزیابی دقت طبقه بندی در فرکانس های مختلف سیگنال الکترومایوگرام تهیه شده است. در مقایسه با فرکانس نمونه برداری در یک کیلوهرتز، فرکانس نمونه برداری پایین تر در چهارصد هرتز می تواند دقت تشخیص را به میزان چهل و سه درصد برای طبقه بند نزدیکترین همسایه و هشتاد و سه درصد برای طبقه بند ماشین بردار پشتیبان در مقایسه با ۹۹/۴۰٪ و ۹۸/۶۷٪ کاهش دهد. این بدان معنی است که کاهش مناسب فرکانس نمونه برداری می تواند یک انتخاب خوب برای تعادل هزینه و عملکرد یک سیستم الکترومایوگرام چند کاناله برای طبقه بندی حرکت دست مبتنی بر استخراج ویژگی باشد. بنابراین هدف از [۲۹]، کشف تأثیر نرخ کم نمونه برداری بر

¹ Inner Group

² Cross Group


دقت تشخیص حرکت با سیگنال الکترومایوگرام و تعیین اینکه آیا انتخاب نرخ کم نمونه برداری یک گزینه مناسب در سیستم ها است، انجام شده است. پنج داوطلب ظاهرا سالم (۱ زن، ۴ مرد، سن: ۲۱-۳۱، قد: ۱۶۵-۱۷۷ سانتی متر، وزن: ۵۸-۷۰ کیلوگرم)، فرم رضایت آگاهانه دریافت کرده اند، و تحت دستورالعمل های خاص، برای انجام آزمایش در این کار شرکت داده شده اند. برای ثبت سیگنال از دستگاه ثبت سیگنال الکترومایوگرام سطحی با شانزده الکتروود استفاده شده است (شکل ۲-۲). در مرحله پیش پردازش سیگنال از یک فیلتر میان گذر (۲۰ هرتز / ۵۰۰ هرتز) و یک فیلتر ناچ ۵۰ هرتز به منظور حذف نویز استفاده شده است. در هنگام جمع آوری سیگنال الکترومایوگرام، افراد بر روی یک صندلی ثابت نشسته و بازوی آن ها به منظور جلوگیری از نویز حاصل از عضلات دیگر با یک چسب ثابت شده است. در این کار، از هر شخص سه بار ثبت سیگنال صورت گرفته است. به منظور اینکه عضله در یک سطح از خستگی باقی بماند بین هر دو ثبت سی دقیقه فاصله ایجاد شد. همانطور که در شکل (۲-۲۳) نشان داده شده است، در مجموع هشت حرکت انجام شده است. در هر حرکت از هر کاربر بیشترین انقباض با بالاترین قدرت درخواست می شود. همچنین به منظور تشخیص تغییرات قدرت از یک سنسور نیرو استفاده شده است. در مرحله بعد چهار ویژگی اتورگرسیو، ریشه میانگین مربعات و میانگین مقدار مطلق در حوزه زمان از سیگنال های حرکتی استخراج شده است. در نهایت به منظور بررسی روش ارائه شده ویژگی ها به سه طبقه بند ماشین بردار پشتیبان، نزدیکترین k همسایه و تجزیه و تحلیل خطی^۱ داده شد.

نتایج در جدول (۲-۳) قابل مشاهده است.

^۱ Linear Discriminant Analysis



شکل ۲-۲۲ الف) دستگاه ثبت کننده سیگنال الکترومایوگرام (ب) ۱۶ الکتروود [۲۹]



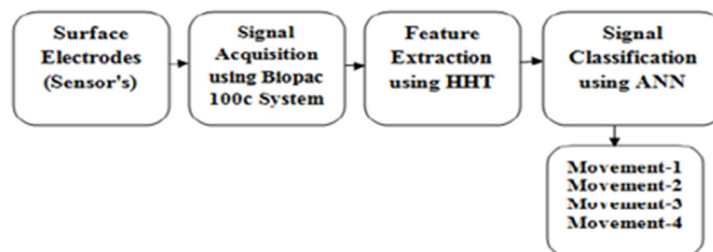
شکل ۲-۲۳ هشت حرکت تعریف شده [۲۹]

جدول ۲-۳ تاثیر نرخ نمونه برداری بر دقت طبقه بندی با استفاده از ۳ طبقه بند متفاوت [۲۹]

Featruce		RMS			WL		
Method		KNN	SVM	LDA	KNN	SVM	LDA
Sampling							
1000Hz		0.9969	0.9955	0.9172	0.9987	0.9945	0.9521
800Hz		0.9932	0.9943	0.9107	0.9981	0.9938	0.9425
600Hz		0.9961	0.9906	0.8964	0.9960	0.9886	0.9254
500Hz		0.9960	0.9937	0.9047	0.9965	0.9915	0.9285
400Hz		0.9955	0.9920	0.8967	0.9942	0.9863	0.9168
300Hz		0.9921	0.9859	0.8677	0.9899	0.9759	0.8843
200Hz		0.9827	0.9621	0.8374	0.9831	0.9659	0.8638
100Hz		0.9468	0.9175	0.7736	0.9555	0.9240	0.8047
60Hz		0.8961	0.8514	0.7214	0.9013	0.8545	0.7391
40Hz		0.8593	0.8014	0.6737	0.8432	0.7974	0.6885
20Hz		0.7793	0.7050	0.5574	0.7680	0.6735	0.5492

Featruce		MAV			AR4		
Method		KNN	SVM	LDA	KNN	SVM	LDA
Sampling							
1000Hz		0.9963	0.9930	0.9045	0.9977	0.9910	0.9813
800Hz		0.9960	0.9920	0.8965	0.9970	0.9742	0.9687
600Hz		0.9951	0.9865	0.8811	0.9973	0.9479	0.9473
500Hz		0.9952	0.9883	0.8899	0.9982	0.9386	0.9601
400Hz		0.9946	0.9895	0.8785	0.9969	0.8909	0.9523
300Hz		0.9916	0.9816	0.8586	0.9964	0.8661	0.9279
200Hz		0.9785	0.9398	0.8162	0.9854	0.7830	0.8526
100Hz		0.9409	0.8849	0.7574	0.9649	0.6458	0.7059
60Hz		0.8882	0.8203	0.6986	0.9141	0.5388	0.5563
40Hz		0.8414	0.7590	0.6478	0.8300	0.5778	0.4977
20Hz		0.7545	0.6752	0.5374	0.6031	0.5577	0.3950

در [۳۰] از تبدیل هیلبرت هوانگ^۱ برای استخراج ویژگی و از طبقه بند شبکه عصبی مصنوعی برای طبقه بندی حرکات دست استفاده شده است. بلوک دیاگرام روش پیشنهادی در شکل (۲-۲۴) نمایش داده شده است.



شکل ۲-۲۴ بلوک دیاگرام روش ارائه شده در [۳۰]

^۱ Hilbert Huang Transform

در ابتدا با استفاده از دستگاه ثبت سیگنال الکترومایوگرام سطحی سیگنال مربوط به شش حرکت مختلف از ده فرد سالم (سن ۲۳-۳۰) ثبت و جمع آوری شده است. در زمان جمع آوری سیگنال از اشخاص عمل ثبت را چندین بار انجام دادیم و بهترین سیگنال را انتخاب نموده ایم. الکترودهای سطحی مربوط به کانال یک بر روی ساعد دست راست و کانال دو بر روی ساعد دست چپ قرار گرفته است. سپس با استفاده از روش حذف نویز مرتبه بالا^۱ نویزهای اضافه حذف گردیده است. در مرحله بعد با استفاده از روش تجزیه حالت تجربی^۲ سیگنال به یک زیر سطح^۳ تجزیه شده است. در این کار به منظور کسب بهترین نتیجه سطوح مختلف تجزیه بررسی شده و بهترین سطح انتخاب شده است که نتایج در جدول (۲-۴) مشخص شده است.

جدول ۲-۴ تاثیر سطوح مختلف تجزیه حال تجربی سیگنال بر دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی

[۳۰]

Intrinsic Mode function (Decomposition level)	Classification Accuracy (%)
IMF level 1	91.1
IMF level 2	90.0
IMF level 3	75.0
IMF level 4	58.3
IMF level 5	53.3
IMF level 6	48.3
IMF level 7	36.7

سپس تبدیل هیلبرت هوانگ بر روی سیگنال‌ها اعمال شده است. تبدیل هیلبرت هوانگ بهترین رویکرد غیر خطی و غیر استان در سیگنال‌های حیاتی است [۳۰]. در جدول (۲-۵) موارد مهمی که در هنگام جمع آوری سیگنال‌ها اهمیت داشته است به اختصار ذکر شده است. در شکل (۲-۲۵) نمونه سیگنال ثبت شده از شخص اول مربوط به حرکت بستن دست را مشاهده میکنید.


¹ High Order Elimination

² Emperical Mode Decomposition

³ IMF1-Level

جدول ۲-۵ پارامترهای مهم در هنگام ثبت سیگنال در [۳۰]

Setting	Value
Channels Used	2
Lower Cut Off Frequency	10hz
Higher Cut Off Frequency	500hz
Amplifier Gain	2000
Sampling Frequency	1000hz
Recording Time	5 Sec
Mode For Data Acquisition	Differential



شکل ۲-۲۵ نمونه سیگنال ثبت شده از شخص اول مربوط به حرکت بستن دست [۳۰]

در مجموع با استفاده از تبدیل هیلبرت و ویژگی‌های میانگین^۱، انحراف معیار، انرژی^۲، آنتروپی^۳، بیشینه مقدار^۴، کمینه مقدار^۵ و تفاضل بیشینه کمینه، بیست و یک ویژگی در حوزه زمان - فرکانس استخراج شده است. متوسط دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی با نظارت و روش مزدوج گرادیان برای حرکات دست چپ با یک سطح تجزیه برابر با ۸۶/۷ درصد می باشد. همچنین به منظور انتخاب بهترین تعداد لایه مخفی، نتایج با استفاده از لایه های مختلف مورد آزمایش قرار گرفته است که نتایج در جدول (۲-۶) مشخص شده است. نتایج دقت طبقه بندی به صورت میانگین برای هر ۱۰ شرکت کننده در جدول (۲-۷) آورده شده است. از این سیستم می توان برای ساخت پروتز و طبقه بندی حرکات دست در آینده استفاده کرد.

¹ Mean

² Energy

³ Entropy

⁴ Maximum Value

⁵ Minimum Value

جدول ۲-۶ انتخاب بهترین تعداد لایه مخفی برای شبکه عصبی مصنوعی به منظور پیدا کردن بالاترین دقت [۳۰]

No of Hidden Layers	Classification Accuracy (%)
1	31.7
2	48.3
3	53.3
4	60
5	66.7
6	70
7	71.7
8	73.3
9	75
10	78.3
20	70

جدول ۲-۲۷ میانگین دقت طبقه بندی شش حرکت برای دست چپ و راست ده شرکت کننده با استفاده از شبکه عصبی [۳۰]

Type Of Movement Left Hand	Average (%)	Type of Movement Right Hand	Average (%)
HAND CLOSE	87.03	HAND CLOSE	93.17
FLEXION	85.99	FLEXION	87.69
PRONATION	92.24	PRONATION	91.17
HAND OPEN	82.42	HAND OPEN	83.17
EXTENSION	79.29	EXTENSION	82.29
SUPINATION	88.21	SUPINATION	80.08


در [۳۱]، یک مدل جدید برای تشخیص حرکت دست به صورت بلادرنگ پیشنهاد شده است. ورودی این سیستم، سیگنال الکترومایوگرام جمع آوری شده با استفاده از نوار بازویی ثبت الکترومایوگرام هشت الکتروود می باشد. سیگنال ها با نرخ نمونه برداری دویست هرتز از روی ساعد ده شخص جمع آوری شده است. خروجی این سیستم هر حرکتی که کاربر انجام داده است را نشان می دهد. مدل پیشنهادی بر اساس الگوریتم نزدیک ترین k همسایه و الگوریتم دینامیک تایم ورپینگ^۱ است. برای ارزیابی عملکرد مدل ارائه شده، دقت و صحت آن در تشخیص پنج کلاس حرکتی با دقت یک سیستم شناسایی حرکت مقایسه شده است. در نتیجه این ارزیابی، ملاحظه می شود که مدل معرفی شده دارای دقت ۸۶ درصد و سیستم شناسایی حرکت دارای دقت ۸۳ درصد است.

در [۳۲]، یک روش موثر برای طبقه بندی حرکات دست حاصل از سیگنال های الکترومایوگرام سطحی بر اساس تجزیه مقدار منفرد^۲ و تحلیل مولفه اصلی ارائه شده است. در ابتدا سیگنال های

¹ Dynamic Time Warping

² Singular Value Decomposition

الکترومایوگرام سطحی به بازه هایی با همپوشانی^۱ تقسیم شده است. سپس به منظور پیدا کردن مقادیر منفرد، بر روی هر یک از این بازه تجزیه مقدار منفرد اعمال شده است. پایگاه داده شده مشابه است با پایگاه داده شرح داده شده در [۱۳] همچنین ۶ حرکت مورد نظر در شکل (۲-۲۶) نمایش داده شده است.



شکل ۲-۲۶ شش حرکت انجام شده در [۳۲]


روش پیشنهادی ارائه شده در [۳۲] شامل سه مرحله می باشد: ایجاد ماتریس زیر فریم از هر بازه، استخراج ویژگی با استفاده از تجزیه مقدار منفرد، و طبقه بندی با استفاده از الگوریتم نزدیکترین همسایه صورت گرفته است. نتایج در جدول (۲-۸) ارائه شده است.

جدول ۲-۸ مقایسه دقت طبقه بندی با دو روش دیگر با استفاده از طبقه بند نزدیکترین همسایه [۳۲]


Subject	Percentage Accuracy		
	<i>Proposed method h. c.</i>	<i>Proposed method t. c.</i>	[9]
Female 1	79.33	82.78	68.56
Female 2	80.33	87.67	83.33
Female 3	78.22	83.11	69.22
Male 1	89.89	90	88.78
Male 2	90.22	90	80.67
Average accuracy	83.60	86.71	77.51

¹ Overlapp

در [۳۳]، هشت حرکت نوسانی انگشتان دست از ۵ فرد مورد ارزیابی و طبقه بندی قرار گرفته است. تعداد کانال های مورد استفاده به منظور ثبت سیگنال در [۳۳] برابر با شش می باشد. هشت حرکت مورد نظر و مکان الکتروود ها به ترتیب در شکل (۲-۲۷) و شکل (۲-۲۸) نشان داده شده است. اگر چه میزان تشخیص با افزایش تعداد کانال ها بهبود چشم گیری خواهد یافت اما از طرفی موجب افزایش هزینه خواهد شد [۳۴]. برای هر بار ثبت سیگنال، شخص حرکت دست را با نیروی ثابت و نوسان کوچکی در یک ثانیه انجام می دهد. نرخ نمونه برداری برای ثبت سیگنال برابر با ۲۰۰۰ هرتز می باشد.




شکل ۲-۲۷ هشت حرکت تعریف شده در [۳۳]




شکل ۲-۲۸ مکان قرارگیری الکترودها بر روی ساعد [۳۳]

سیگنال خام الکترومایوگرام با استفاده از مدل انورگرسیو در حوزه زمان استخراج ویژگی شده است. از روش تجزیه و تحلیل مولفه اصلی برای کاهش ابعاد و سپس نرمال کردن ماتریس ویژگی استفاده شده است. یک مدل شبکه عصبی احتمالاتی افزوده شده^۱ برای آموزش و پیش بینی حرکت دست استفاده شده است. میانگین موفقیت در شناسایی حرکات دست ۹۲/۲٪ می باشد. در مقایسه با روش های معمول، این روش می تواند بصورت همزمان هم حالت دست و هم نوسانات ریز انگشتان را از سیگنال های الکترومایوگرام سطحی عضلات ساعد با دقت بالا و قابلیت اطمینان مناسبی پیش بینی کند.

نتایج دقت طبقه بندی مربوط به هر حرکت و برای هر فرد در شکل (۲-۲۹) و همچنین میانگین دقت برای هر حرکت برای هر پنج فرد در شکل (۲-۳۰) ارائه شده است.



شکل ۲-۲۹ میانگین دقت طبقه بندی هشت حرکت با استفاده از شبکه عصبی احتمالاتی برای هر فرد شرکت کننده [۳۳]



¹ Augmented Probabilistic Neural Network

شکل ۲-۳۰ میانگین دقت طبقه بندی هشت حرکت با استفاده از شبکه عصبی احتمالاتی برای هر پنج نفر شرکت کننده [۳۳]

در [۳۵]، یک مدل شناسایی نوع حرکت دست به صورت بلادرنگ پیشنهاد شده است. جمع آوری سیگنال الکترومایوگرام توسط نوار بازویی ثبت الکترومایوگرام با هشت الکتروود بر روی ساعد صورت پذیرفته است. در این آزمایش از ده نفر که شامل زن و مرد می شود استفاده شده است و پنج حرکت مختلف به صورت بلادرنگ مورد بررسی قرار گرفته است. برای ثبت سیگنال هر حرکت، پنج بار به مدت ۲ ثانیه انجام شده است که هر ۵ حرکت و دستگاه الکترومایوگرام در شکل (۲-۳۱) نشان داده شده است.



شکل ۲-۳۱ الف) دستگاه الکترومایوگرام ب) پنج حرکت تعریف شده در [۳۵]

اشاره به این نکته اهمیت دارد که مدل پیشنهادی مختص به هر کاربر است به این دلیل که نیرو و سرعت هر حرکت بین افراد متفاوت است. علاوه بر این، ویژگی های زمان و فرکانس سیگنال الکترومایوگرام با ضخامت و درجه حرارت پوست، ضخامت چربی بین عضله و پوست، سرعت جریان خون و محل حسگرها می تواند تغییر کند. عواملی دیگر همچون خستگی عضلانی، پیری، و بیماری های عصبی-عضلانی می تواند الگوی الکترومایوگرام را برای یک حرکت مشخص تحت تاثیر قرار دهد

[۳۶]. برای مرحله پیش پردازش سیگنال، عملیاتی مانند یکسوسازی^۱ و همچنین استفاده از فیلتر باترورت بر روی سیگنال اعمال شده است. برای مرحله طبقه بندی، از الگوریتم نزدیک ترین همسایه [۳۷] و الگوریتم دینامیک تایم ورپینک [۳۸] استفاده شده است. نتایج در جدول (۲-۹) ارائه شده است.

جدول ۲-۹ نتایج دقت طبقه بندی با روش های مختلف با استفاده از طبقه بند نزدیکترین همسایه [۳۵]

Model	Accuracy (%)	Average time (ms)
Proposed model (with muscle activity detection)	89.5	193.1
Model without muscle activity detection	86.0	245.5
Proprietary system of the Myo	83.1	-----
General model	53.7	1803.5

در [۳۹]، یک مدل برای تشخیص نوع حرکت دست به صورت بلادرنگ مبتنی بر سیگنال های الکترومیوگرام سطحی و تکنیک های یادگیری ماشین^۲ توسعه داده شده است. تشخیص حرکات با استفاده از سیگنال الکترومیوگرام کار بی اهمیتی نیست، زیرا در زمان حرکت چندین فرایند فیزیولوژیکی در عضلات اسکلتی صورت می گیرد که شامل اطلاعاتی مفیدی می باشد. در مقالات علمی، مدل های مختلفی برای تشخیص حرکت دست وجود دارد، اما آنها در تعداد حرکات شناخته شده (به عنوان مثال، کلاس ها) و همچنین در زمان پردازش دارای محدودیت هستند. بنابراین هدف اصلی در [۳۹]، دستیابی به یک مدل تشخیص حرکت دست به صورت بلادرنگ و تشخیص تعداد حرکات بیشتر برای برنامه های کاربردی مختلف در زمینه پزشکی و مهندسی با دقت شناسایی بیشتر نسبت به مدل های بلادرنگ ارائه شده در مقالات علمی است.


مدل پیشنهادی در [۳۹] دارای پنج مرحله اصلی است: شکل (۲-۳۲)

• جمع آوری سیگنال الکترومیوگرام

¹ Rectification

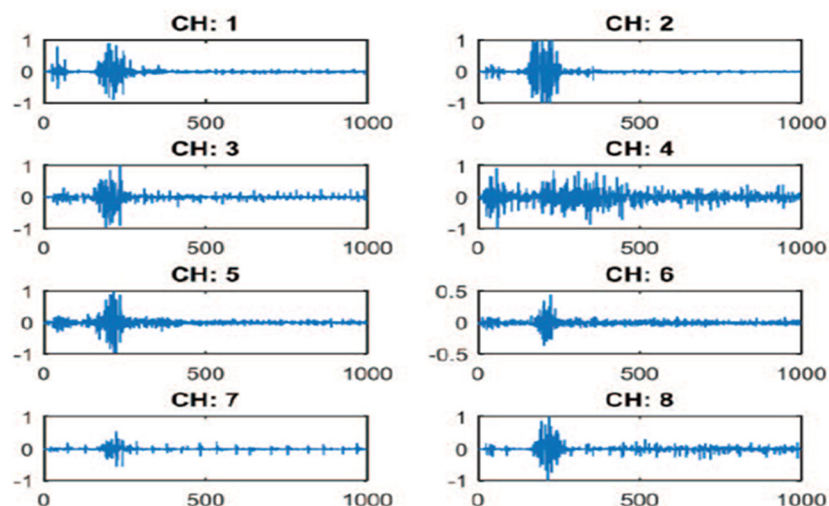
² Machine Learning

- پیش پردازش (به عنوان مثال، اصلاح و فیلتر کردن)
 - استخراج ویژگی (به عنوان مثال ویژگی های زمان، فرکانس و فرکانس-زمان)
 - طبقه بندی (به عنوان مثال طبقه بندهای پارامتریک و غیر پارامتری)
 - پس پردازش
- به طور کلی، عمده مشکلات اصلی مدل های تشخیص حرکت دست مبتنی بر الکترومایوگرام با استفاده از یادگیری ماشین عبارت اند از: رفتار پر نویز سیگنال، تعداد کم کلاس های حرکتی نسبت به تعداد داده های تولید شده توسط هر حرکت.



شکل ۲-۳۲ بلوک دیاگرام روش پیشنهادی [۳۹]

در [۳۹] به منظور ثبت و جمع آوری سیگنال از یک نوار بازویی ثبت الکترومایوگرام هشت الکتروود استفاده شده است. مرحله پیش پردازش بسیار حائز اهمیت است تا نویز را از سیگنال الکترومایوگرام حذف کند تا فقط سیگنال خالص باقی بماند. در شکل (۲-۳۳) سیگنال های الکترومایوگرام بدون پیش پردازش نشان داده شده است.



شکل ۲-۳۳ سیگنال های خام ثبت شده بدون پیش پردازش از ۶ کانال [۳۹]

در [۳۹] از دو نوع پیش پردازش استفاده شده است:

- یکسوسازی

- فیلتر کردن


سیگنال های الکترومایوگرام دارای مقادیر منفی و مثبت برای قطبی^۱ و غیر قطبی کردن^۲ فیبر هستند به همین جهت یکسوسازی صورت می گیرد. به دلیل استخراج اطلاعات مفید از سیگنال اعمال فیلتر بر روی سیگنال الکترومایوگرام و حذف نویز ضروری است. در [۳۹] قبل از فیلتر کردن، تجزیه و تحلیل جامعی از اجزای فرکانسی سیگنال الکترومایوگرام صورت گرفته تا اطلاعات ارزشمند در فرآیند فیلتر کردن از دست نرود. بدین منظور در [۳۹] فیلتر های پاسخ ضربه بی نهایت^۳ و پاسخ

¹ Polarization

² Depolarization

³ Infinite Impulse Response

ضربه محدود^۱ مورد بررسی قرار گرفته است. در شکل (۲-۳۴) بعد از تصحیح و فیلتر کردن سیگنال های الکترومایوگرام نشان داده شده است.



شکل ۲-۳۴ سیگنال های ثبت شده فیلتر شده و یکسوسازی شده در [۳۹]

در [۳۹]، تکنیک های مختلف استخراج ویژگی در حوزه های زمان، فرکانس و زمان-فرکانس مورد بررسی قرار گرفته است تا اطلاعات معنی دار برای هر کلاس شناسایی شود. در حوزه زمان، ویژگی هایی زیر مورد بررسی قرار گرفته است: میانگین مقدار مطلق، ضریب اتورگرسیو مرتبه n ، نرخ عبور از صفر، طول سیگنال^۲، میانگین مقدار مطلق اصلاح شده، تغییر علامت شیب، انتگرال جذر نمونه، ریشه میانگین مربعات، میانگین، واریانس، آشکارساز لگاریتمی، متوسط تغییرات دامنه^۳، حداکثر طول فراکتال^۴، انتگرال سیگنال الکترومایوگرام، هیستوگرام دامنه ویلسون^۵، ضرایب سپسترال^۶، آنتروپی. در حوزه فرکانس، ویژگی هایی مورد بررسی قرار گرفته عبارت است از: طیف توان^۷،

¹ Finite Impulse Response

² Length Of The Signal

³ Average Amplitude Change

⁴ Maximum Fractal Length

⁵ Willison Amplitude Histogram

⁶ Cepstral Coefficients

⁷ Power Spectrum

متوسط فرکانس، میانگین فرکانس، هیستوگرام فرکانس^۱ و متوسط توان [۴۱] و در حوزه زمان-فرکانس، تبدیل موجک مورد بررسی قرار گرفته است [۴۰]. مرحله طبقه بندی تعیین کننده این است که یک بردار ویژگی استخراج شده از سیگنال های EMG متعلق به کدام کلاس (حرکت) است. بدین منظور از دو نوع طبقه بند پارامتریک و غیر پارامتری در [۳۹] استفاده شده است. طبقه بندهای پارامتریک مورد ارزیابی قرار گرفته عبارت است از: مجزا ساز خطی، رگرسیون لجستیک^۲، نیو بیزین، شبکه عصبی مصنوعی، ماشین بردار پشتیبان و طبقه بندی های غیر پارامتریک مورد ارزیابی قرار گرفته عبارت است از: نزدیکترین k همسایه و درخت تصمیم گیری^۳. متداول ترین طبقه بندی های مورد استفاده در تشخیص حرکت دست با الکترومایوگرام، ماشین های بردار پشتیبانی [۴۲] و شبکه های عصبی [۴۳] هستند. در برخی از مطالعات از طبقه بندی های ترکیبی استفاده شده است، در [۴۴] نویسندگان ترکیبی از درخت تصمیم گیری، خوشه بندی^۴ و مدل مخفی مارکوف^۵ را استفاده کرده اند. در [۴۳] نویسندگان ترکیبی از بردارهای پشتیبانی و مدل مخفی مارکوف را استفاده کرده اند.

در [۴۵] شش حرکت مختلف دست (حرکت چنگ زدن^۶) که معمولا هر روز توسط انسان انجام می شود شناسایی و طبقه بندی شده است. طبقه بندی چنین حرکاتی می تواند به توسعه بازوهای مصنوعی با توان کنترل الکتریکی بالا برای افراد معلول کمک کند. شش ویژگی پس از پیش پردازش از سیگنال های الکترومایوگرام خام استخراج می شود و سپس به ورودی طبقه بند داده می شود. از آنجایی که مجموعه داده ها متشکل از شش گروه از حرکات مشابه به هم است که بسیار ریز هستند، انتخاب ویژگی های مناسب برای طبقه بندی مناسب امری ضروری است. به منظور ثبت سیگنال از یک مرد ۲۲ ساله در [۴۵] استفاده شده است که شش حرکت گرفتن (چنگ زدن) را ۱۰۰ بار با

¹ Frequency Histogram

² Logistic Regression


³ Deciduous Tree

⁴ Clustering K-means

⁵ Hidden Markov Model

⁶ Grap

محدوده زمانی ۵ ثانیه برای هر حرکت انجام می دهد. سیگنال از طریق یک فیلتر میان گذر ۲۰-۵۰۰ هرتز فیلتر شده است و فرکانس ۵۰ هرتز برای حذف تداخل های الکتریکی فیلتر شده است. تبدیل آنالوگ به دیجیتال با نرخ نمونه برداری ۵۰۰ هرتز انجام می شود. شش حرکت مورد نظر در شکل (۲-۳۵) نمایش داده شده است.



شکل ۲-۳۵ شش حرکت تعریف شده در [۴۵]

در مرحله بعد از سیگنال الکترومایوگرام با استفاده از تکنیک های مختلف ویژگی ها استخراج می شوند که این ویژگی ها عبارتند از: اتورگرسیو، میانگین مقدار مطلق، ریشه میانگین مربعات، نرخ عبور از صفر، تغییر شیب علامت و طول شکل موج. در نهایت به منظور انتخاب بهترین طبقه بند چهار الگوریتم مجزا ساز خطی مرتبه دوم^۱ و خطی، نزدیکترین k همسایه و گروه مجزاساز زیرفضا^۲ نیز مورد استفاده قرار گرفته است و نتایج آن در جدول (۲-۱۰) و (۲-۱۱) و (۲-۱۲) و (۲-۱۳) ارائه شده است.

¹ Quadratic Discriminant Analysis

² Subspace Discriminant Ensemble

جدول ۱۰-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزا ساز زیر فضایی [۴۵]

Parameters		Features Used for Classification	
	<i>AR + ZC + MAV + RMS + SSC + WL (Proposed)</i>	<i>AR</i>	<i>ZC + MAV + RMS + SSC + WL</i>
Accuracy (%)	83.33	80	64.17
Error (%)	16.67	20	35.83
Sensitivity (%)	83.33	66.67	50
Specificity (%)	91.67	93.75	90.63

جدول ۱۱-۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند نزدیکترین همسایه [۴۵]

Parameters		Features Used for Classification	
	<i>AR + ZC + MAV + RMS + SSC + WL (Proposed)</i>	<i>AR</i>	<i>ZC + MAV + RMS + SSC + WL</i>
Accuracy (%)	80	76.67	72.5
Error (%)	20	23.33	27.5
Sensitivity (%)	41.67	37.5	54.17
Specificity (%)	96.88	93.75	92.71

جدول ۲-۱۲ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزاساز خطی [۴۵]

Parameters		Features Used for Classification	
	<i>AR + ZC + MAV + RMS + SSC + WL (Proposed)</i>	<i>AR</i>	<i>ZC + MAV + RMS + SSC + WL</i>
Accuracy (%)	79.17	80.83	65
Error (%)	20.83	19.17	35
Sensitivity (%)	70.83	62.5	50
Specificity (%)	92.71	92.71	90.63

جدول ۲-۱۳ دقت طبقه بندی با استفاده از سه دسته ویژگی و طبقه بند مجزاساز خطی مرتبه دوم [۴۵]

Parameters		Features Used for Classification	
	<i>AR + ZC + MAV + RMS + SSC + WL (Proposed)</i>	<i>AR</i>	<i>ZC + MAV + RMS + SSC + WL</i>
Accuracy (%)	80	80	65.83
Error (%)	20	20	34.17
Sensitivity (%)	70.83	54.17	50
Specificity (%)	93.75	94.79	90.63



فصل سوم

مباحث تئوری

۳-۱ مقدمه

در این فصل ابتدا خواص سیگنال های حیاتی گفت شده است. سپس به معرفی سیگنال الکترومایوگرام و همچنین به چگونگی تولید آن پرداخته ایم. همچنین به منظور ایجاد یک پایگاه داده مناسب راه کارها و روش ثبت سیگنال الکترومایوگرام ارائه شده است تا بتوان از آن در آینده بهره گرفت. سپس به مباحث تئوری مورد نیاز که در این پایان نامه از آن ها استفاده شده پرداخته ایم.

۳-۲ معرفی سیگنال الکترومایوگرام

سیگنال الکترومایوگرام از ترکیب اجزای کوچکتی به نام پتانسیل عمل واحد حرکتی^۱ که توسط واحد های مختلف تولید می شود تشکیل شده است. واحد حرکتی کوچکترین واحد عملکردی یک ماهیچه است که می تواند به طور ارادی فعال شود. پتانسیل های الکتریکی در دو طرف غشاء، عملاً در تمام سلول های بدن وجود دارند. سلول های عصبی و عضلانی، سلول های قابل تحریک هستند یعنی قادر به تولید پالس های الکتروشیمیایی در غشاء خود هستند. هر فیبر عصبی به طور طبیعی به دفعات زیاد منشعب شده و ۳ الی چند فیبر عضلانی را تحریک می کند. سیگنال های عصبی توسط پتانسیل های عمل که تغییرات سریع در پتانسیل غشاء سلول های عصبی هستند، انتقال می یابند. پتانسیل عمل برای هدایت سیگنال عصبی در طول فیبر عصبی به حرکت در می آید تا اینکه به انتهای فیبر می رسد. محل تماس رشته های عصبی با فیبر عضلانی تقریباً در وسط آن و به نام محل تماس عصبی عضلانی^۲ می باشد به طوریکه پتانسیل عمل در هر دو جهت به سوی انتهای فیبر عضلانی سیر می کند. فیبر عصبی در انتهای خود منشعب شده و مجموعه ای از ترمینال های منشعب شده عصبی تشکیل می دهد که در یک فرو رفتگی از سطح فیبر عضلانی قرار می گیرد، اما به طور کامل در خارج غشاء پلاسمایی فیبر عضلانی قرار دارد. فرو رفتگی غشاء فیبر عضلانی موسوم به نودان سیناپسی و فضای بین ترمینال عصبی و غشاء فیبر عضلانی موسوم به شکاف سیناپسی است

¹ Motor Unit Action Potential


² Neuro Muscular Junction

[۴۶]. در نهایت در اثر انتقال سیگنالهای عصبی به عضله، تارهای عضلانی فعال شده و ایجاد پتانسیل عمل می نماید که به آن الکترومایوگرام گویند که در واقع تجلی اراده انسان برای انجام حرکت است. انتشار این پتانسیل های عمل در طول عضله ادامه یافته و بر روی پوست قابل دریافت می گردند. با نصب الکترودهای پوستی می توان این سیگنالها را از سطح پوست دریافت نمود. سیگنال الکترومایوگرام به عنوان یک ابزار غیر تهاجمی برای کنترل دست مصنوعی به کار می رود. این سیگنال حاوی اطلاعات زیادی در حوزه زمان و فرکانس است که محققان با تبدیلات ریاضی متنوع، سعی در استخراج و تحلیل اینگونه اطلاعات داشته اند. سیگنالهای الکترومایوگرام از نظر فرکانسی عمدتاً در محدوده ۲۵ تا ۵۰۰ هرتز تغییر می کنند و دامنه های سیگنال بسته به نوع سیگنال و الکترودهای استفاده شده از ۱۰۰ میکروولت تا ۹۰ میلی ولت تغییر می کنند. با این حال، قالب انرژی سیگنال الکترومایوگرام بین ۵۰ تا ۲۵۰ هرتز [۴۶] است. بنابراین تقویت کننده های الکترومایوگرام نسبت به تقویت کننده های الکتروکاردیوگرام^۱ پاسخ فرکانسی وسیعتری را پوشش می دهند ولی در عوض لازم نیست فرکانسهای بسیار پایین را مانند الکتروانسفالوگرام^۲ پوشش دهند و این امر بدلیل وجود آرتیفکت^۳ ناشی از حرکت، در فرکانسهای پایین بسیار مطلوبست چرا که می توانند بدون تحت تأثیر قرار دادن سیگنال مؤثر، فیلتر شوند. در شکل (۳-۳) مقایسه ای بین محدوده تغییرات فرکانس و ولتاژ سیگنال الکترومایوگرام و سیگنالهای متداول دیگر انجام شده است:

^۱ Electrocardiogram

^۲ Electroencephalogram

^۳ Artifact



شکل ۱-۳ مقایسه دامنه و فرکانس EMG با سیگنالهای حیاتی دیگر^۱

همانطور که ملاحظه می کنید سیگنال الکترومایوگرام نسبت به سیگنالهای الکترواکولوگرام^۲، الکتروانسفالوگرام و الکتروکاردیوگرام محدوده فرکانسی وسیعتری را شامل می شود و همینطور شامل فرکانسهای خیلی کم نمی شود و نسبت به آنها دامنه بزرگتری نیز دارد. اگر از الکترودهای سوزنی فرو رونده در ماهیچه استفاده شود، سیگنالهای الکترومایوگرام می توانند دارای دامنه ای در حدود دو برابر حالت قبلی شوند و در نتیجه به بهره کمتری برای تقویت نیاز دارند. در مراکز بهداشتی و درمانی الکترومایوگرام اغلب به روش سوزنی انجام می شود و روش سطحی با وجود بهداشتی بودن و عدم درد، به ندرت به کار می رود زیرا این روش دارای شکل موج کاملا تصادفی است و استخراج پارامترهای آن بدون استفاده از روشهای پردازش کامپیوتری امکان پذیر نیست، ولی اخیرا با پیشرفتهای انجام گرفته در روشهای پردازش کامپیوتری به تدریج استفاده از الکترودها سطحی در ثبت سیگنال الکترومایوگرام رو به افزایش است. یکی از مناسبترین روشهای تحلیل الکترومایوگرام همراه با الکترودهای سطحی، بررسی محتوای فرکانسی سیگنال و استخراج ویژگیهای آن با استفاده از تابع چگالی طیف توان است. مطالعه گسترده تر از ویژگی های سیگنال الکترومایوگرام را می توان در [۴۷] یافت.

^۱ عکس از سرچ اینترنت برگرفته شده است

^۲ Electrooculogram

➤ منابع نويز موثر بر سيگنال الكترومايوگرام

بطور کلی سيگنال الكترومايوگرام توسط دو نوع منبع نويز می پذيرد:


- منابع بيولوژيک
- منابع غير بيولوژيک

منابع بيولوژيکی شامل حرکات ساير عضلات مانند عضله قلب و حرکات ناشی از ضربان رگهای خونی است و منابع غير بيولوژيکی شامل سيستمهای اندازه گيري و تداخلات برق شهر و محيط اطراف آن و حرکات شخص آزمایش دهنده و حرکت الكترودها می باشد. دستگاه ثبت کننده الكترومايوگرام شامل مدارهایی است که می تواند سيگنال بسيار ضعيف الكترومايوگرام را که حداکثر دامنه ای به اندازه یک میکروولت دارد و دارای نويز نیز می باشد، را پردازش کرده و با کمترین نويز و دامنه قابل قبول در خروجی ظاهر سازد. در طراحی مدار ثبت کننده الكترومايوگرام بدليل اینکه پهنای باند فرکانسی اين سيگنال عموماً بين ۲۵ تا ۱۰۰۰ هرتز است، از یک فيلتر بالا گذر و یک فيلتر پايين گذر استفاده شده است. ثبت کننده سيگنالهای حياتی با به کارگيري از تجهيزات الکترونیکی که بعضی از وقایع فیزیولوژیکی نرمال و یا غير نرمال درونی انسان را به شکل سيگنالهای سمعی و بصری نمایش می دهد نشان داده می شود. در زمینه مسائل مربوط به توان بخشی مفيد ترين ثبت کننده، الكترومايوگراف^۱ است. اما سيگنال الكترومايوگرام به تنهایی قابل استفاده نیست چون که بیمار و پزشک معالج سيگنالهای الكترومايوگرام را نمی بینند و اين سيگنالها باید به علائم صوتی و تصویری قابل درک تبديل شوند. یکی از اهداف اوليه همه ثبت کننده های الكترومايوگراف، قادرسازی بیمار به اعمال کنترل ارادی بر عضلات خود است که به منظور افزایش فعاليت ماهيچه های ضعيف و کاهش فعاليت ماهيچه های متشنج به کار می رود. در آموزش کلينیکی، بیمار از طريق سيگنالهای سمعی و بصری، از انقباضهای خیلی کوچک و خیلی بزرگ ماهيچه اش آگاه می شود.

^۱ Electromyograph

➤ الکترودهای ثبت سیگنال

الکترودهای الکترومغناطیسی رویدادهای زیستی الکتریکی را ثبت می کنند. الکترودهای ثبت کننده سیگنال از انواع مختلفی برخوردار هستند، مانند سیمی، سوزنی و الکترودهای سطحی که در شکل (۳-۴) نشان داده شده اند [۴۸]. الکترودهای سیمی و سوزنی از طریق پوست به داخل بافت عضلانی وارد می شوند. در حالی که الکترودهای سطحی روی سطح پوست قرار می گیرند. الکترودهای سیمی و سوزنی برای دسترسی به واحد موتور حرکتی ماهیچه های عمیق مفید است و برای استفاده از آن ها نیاز به پرسنل آموزش دیده است.



شکل ۳-۲ انواع الکترودهای سطحی - سوزنی - سیمی [۴۸]

در پایگاه داده استفاده شده در این پایان نامه، از الکترودهای سطحی استفاده شده است زیرا آنها بسیار کم خطر هستند که می توانند بدون درد و کم هزینه باشند. الکترودهای سطحی زیادی براساس انواع شکل ها، اندازه ها و مواد تشکیل دهنده وجود دارد. مانند الکترودهای تک قطبی، الکترودهای دو قطبی، الکترودهای سه قطبی، الکترودهای چند قطبی، بریر^۱، پیچ^۲ و الکترودهای بلی تاندون^۳. در استراتژی استفاده از الکترودهای تک قطبی از یک الکترودهای نظارت بر سیگنال های الکترومایوگرام از عضله

¹ Barrier

² Patch

³ Belly Tendon

و یک الکتروود دیگر به عنوان مرجع استفاده می شود، که بر روی بافت های غیر الکتریکی مانند استخوان قرار می گیرد. این استراتژی از عدم توانایی آن برای فیلتر کردن سیگنال های ناخواسته الکتریکی از منابع ناشی از نویز و عضلات اطراف عضله مورد نظر رنج می برد [۴۸].

الکتروودهای دوقطبی مشکل الکتروودهای تک قطبی را ندارند و اطلاعات هر ۲ قطب را ترکیب می کنند. از طرفی این الکتروودها از نوع غیر تهاجمی هستند علاوه بر این، با تکنیک ضبط دو قطبی ما می توانیم نویز را در سیگنال الکترومایوگرام کاهش دهیم، به همین دلیل به استفاده از این نوع الکتروود در کارهای پژوهشی تاکید شده است. الکتروود دو قطبی از تکنیک دیفرانسیل تقویت استفاده می کند که تفاوت ولتاژ بین دو نقطه خاص را اندازه گیری می کند. بنابراین، یک گره برای ورودی مثبت استفاده می شود، و دیگری برای یک ورودی منفی برای تقویت کننده دیفرانسیل استفاده می شود. از آنجا که تقویت کننده تفاضلی نوعی تقویت کننده ی الکترونیکی است که تفاوت دو ورودی را تقویت می کند و موجب تضعیف مشابه آن دو می شود در واقع هر سیگنالی که برای هر دو ورودی از آمپلی فایر، یعنی سیگنال حالت معمول، مشترک است، به این ترتیب به عنوان یکسان، اما مخالف لغو می شود و در خروجی ظاهر نمی شود. به این ترتیب، منابع مرتبط با نویز و سایر سیگنال های ناخواسته اغلب حذف می شوند و نسبت سیگنال به نویز به طور قابل توجهی افزایش می یابد و سپس سیگنال باقی مانده تقویت می شود. با این حال فاصله بین الکتروودها می تواند نتیجه اندازه گیری را تحت تأثیر قرار دهد. قرار دادن الکتروودهای با فاصله بیش از حد از یکدیگر می تواند سیگنال ضعیفی ایجاد کند. از طرف دیگر، قرار دادن آنها در نزدیکی نیز ممکن است داده های غیر قابل استفاده تولید کند. از طرفی شکل الکتروود، اندازه الکتروود، فاصله بین دو الکتروود و جنس آن می تواند ثبت و جمع آوری سیگنال الکترومایوگرام را تحت تاثیر قرار دهد [۴۸].

➤ شکل الکتروود


الکتروودها از جنس رسانای خوب الکتریکی ساخته شده اند. الکتروودها در اشکال مختلف مانند الکتروودهای دایره ای، مربعی و نواری شکل هستند [۴۸]. نکته مهم این است که سطح مقطع برای هر دو الکتروود باید یکسان باشد، بنابراین امپدانس ورودی در هر دو الکتروود مشابه می شود.

➤ اندازه الکتروود

منظور از اندازه الکتروود سطح مقطع آن می باشد. اندازه الکتروودها نباید بیش از ۱۰ میلیمتر حدود ۰/۴ اینچ باشد، زیرا با افزایش اندازه در جهت فیبرهای عضلانی، اثر منفی بر روی سیگنال الکترومایوگرام سطحی می گذارد و موجب افزایش دامنه و کاهش محتوای فرکانس بالا می شود [۴۸].

➤ فاصله بین الکتروودها

منظور از فاصله بین دو الکتروود به فاصله مرکز تا مرکز هر الکتروود اطلاق می شود. کاهش فاصله بین دو الکتروود موجب می شود که فقط اطلاعات عمقی از عضله را در نقطه ای خاص به دست آوریم از طرفی موجب می شود نتوانیم اطلاعات کلی سیگنال حاصل از عضله را دریافت نماییم و پهنای باند سیگنال به فرکانس های بالاتر تغییر می کند. فاصله بین دو الکتروود نباید بیش از ۱ اینچ [۴۹] باشد، همانطور که در شکل (۳-۵) نشان داده شده است.



شکل ۳-۳ نمونه ای از الکتروود سطحی [۴۸]

➤ جنس الکتروود


برای ثبت سیگنال های استفاده شده در پایگاه داده استفاده شده در این پایان نامه از الکترودهای نقره کلرید با ژل استفاده شده است. زیرا بهترین الکترودهای توصیه شده برای ثبت و جمع آوری سیگنال الکترومایوگرام به دلایل زیر می باشند [۴۸]:

۱. الکترودهای از جنس نقره کلرید لایه ی تماسی بسیار خوبی با پوست ایجاد می کند.
۲. امپدانس کم الکتروود با پوست را حفظ می کند.
۳. رفتاری بسیار پایدار در زمان دارد یعنی با گذشت زمان باعث تغییر در سیگنال نمی شود.

➤ مکان قرارگیری الکتروودها

برای قرار دادن الکتروود در بهترین موقعیت ممکن و به منظور رسیدن به سیگنال الکترومایوگرام سطحی پایدار باید اطلاعاتی در مورد آناتومی ساعد دست بدانیم زیرا سیگنال ها از روی عضلات ساعد که حرکات انگشتان و دست را کنترل می کنند جمع آوری می شوند. همان طور که در بخش قبل گفته بودیم عضلات ساعد به دو گروه عضلانی تقسیم می شود: [۵۰]

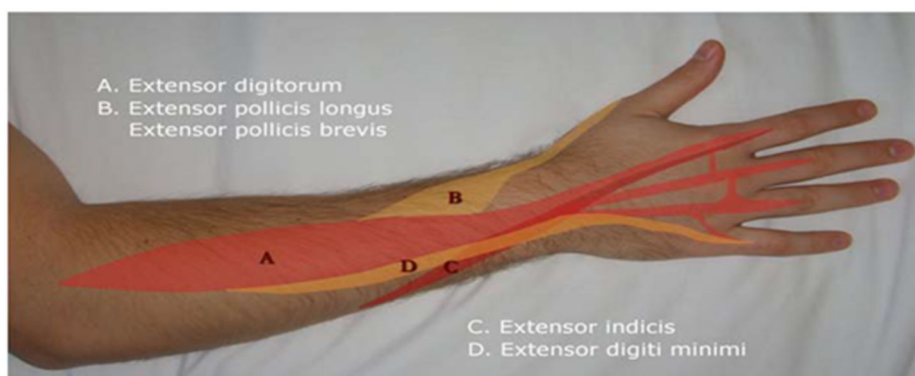
۱. گروه عضله پوستریور: وظیفه باز کردن به سمت بیرون (اکستنسور) و چرخاندن به سمت داخل (سوپینیتور) را برای مچ دست و انگشتان بر عهده دارند.
۲. گروه عضله انتریور: وظیفه جمع کردن به سمت داخل (فلکسور) و چرخاندن به سمت خارج (پرونیاتور) را برای مچ دست و انگشتان بر عهده دارند شکل (۳-۷).



شکل ۳-۴ حرکات مرتبط با عضلات پوستریور و انتریور [۵۰]

عضلات اکستنسور که در قسمت پشتی ساعد واقع شده اند، مسئولیت گسترش انگشتان به سمت جلو را در ابتدا زمانی که جنبش شروع می شود دارند. عضلات فلکسور که عموماً در قسمت جلوی ساعد قرار دارند، مسئول جمع کردن مفاصل انگشت هستند.

در شکل (۳-۸) [۵۰]، عضلاتی که وظیفه باز کردن انگشتان را بر عهده دارد نشان داده شده است. عملکرد هر عضله در زیر شرح داده شده است:



شکل ۳-۵ عضلاتی که وظیفه باز کردن انگشتان را بر عهده دارد [۵۰]

➤ عضله اکستنسور دیجیتوروم

مسئول باز کردن مچ دست و انگشت است، تمرکز این عضله برای کنترل بیشتر بر روی انگشت حلقه و میانه هست و همچنین تمرکز کمی هم بر روی انگشت اشاره و کوچک دارد [۵۰].

➤ عضله اکستنسور پالیسیس لانگوس و برویس

هر دوی این عضله مسئول باز کردن انگشت شست و خم کردن مچ دست به سمت بیرون هستند.

➤ عضله اکستنسور ایندیسیس

مسئول باز کردن انگشت اشاره هستند.

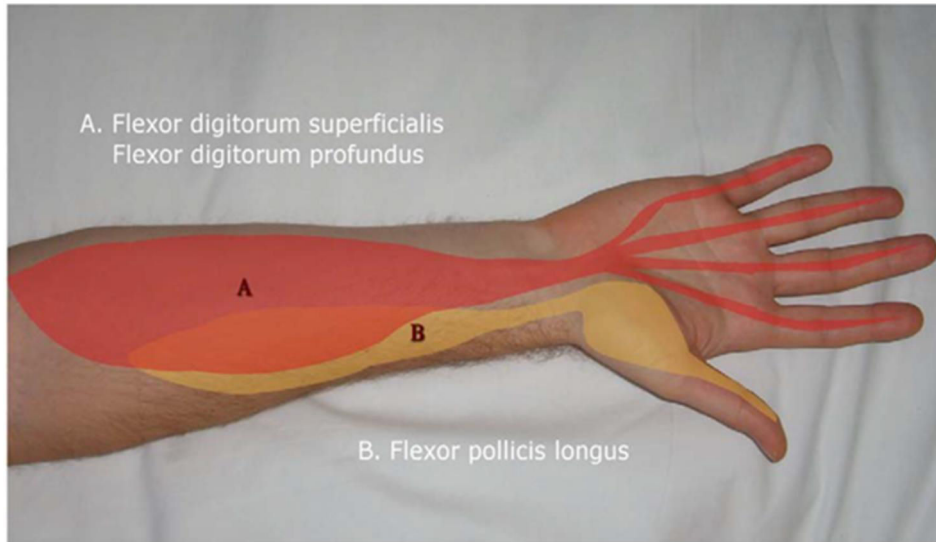
➤ عضله اکستنسور دیجیتای مینیمی

مسئول باز کردن انگشت کوچک است.

عضله اکستنسور ایندیسیس در لایه ای عمیق عضلانی بازوی قرار گرفته و با عضلات اکستنسور دیجیتوروم و عضله اکستنسور دیجیتای مینیمی پوشیده شده است [۵۰]. مکان های تقریبی این عضلات در شکل (۳-۹) نشان داده شده است. به طور طبیعی، محل عمیق این عضلات تاثیر منفی بر روی انرژی دارد که الکترومیوگرافی سطحی می تواند آن را تشخیص دهد.

در شکل (۳-۹) [۵۰]، عضلاتی که وظیفه بستن انگشتان را بر عهده دارد نشان داده شده است. عضلات فلکسور دیجیتوروم سوپرفیشیالیس و فلکسور دیجیتوروم پروفاندوس هر دو مسئول خم کردن چهار انگشت و مچ دست هستند، در حالی که عضله فلکسور پالیسی لانگوس وظیفه خم کردن

انگشت شست را بر عهده دارد. با درک پایه ای آناتومی انسان، ما بهتر آماده می شویم که عضلات هدف را تعیین کرده و موقعیت مطلوب الکتروود را تعیین کنیم.




شکل ۳-۶ عضلاتی که وظیفه بستن انگشتان را بر عهده دارد [۵۰]

➤ موقعیت مطلوب برای قرار دادن الکتروودها

شکل (۳-۱۰) [۵۰] موقعیت مطلوب الکتروود را نشان می دهد. مراحل زیر مراحل لازم برای قرار

دادن الکتروود به صورت صحیح را شرح می دهد:

- برای دریافت قوی تر و هرچه بهتر سیگنال لازم است که الکتروودها به صورت موازی بر روی عضله قرار گیرند که در شکل (۳-۱۰) نشان داده شده است.



شکل ۳-۷ موقعیت مطلوب الکتروود را نشان می دهد [۵۰]

- بهترین نقطه قرار گیری بر روی شکم عضله می باشد.
- الکتروود ها نباید روی لبه بیرونی عضله قرار بگیرند به این دلیل که دیگر عضلات می توانند با عضله مورد نظر نیز تداخل ایجاد کنند و فاصله بین دو الکتروود تقریبا ۲ سانتی متر باشد.
- به منظور دریافت بهتر سیگنال پیشنهاد می شود محل قرار گیری الکتروود به خوبی با الکل تمیز شود و ترجیحا موهای زائد در آن ناحیه اصلاح شود و در پایان پس از خشک شدن کامل پوست الکتروود ها در محل مورد نظر نصب شود.
- قبل از شروع آزمایش محل دقیق الکتروود مرتبط با حرکت مورد نظر و عضله مناسب را پیدا کنید و سپس الکتروود ها را به صورت موازی بر روی عضله نصب کنید.
- موقعیت یک الکتروود دو قطبی به طور صحیح بر روی یک عضله فلکسور دیجیتوروم پروفاندوس نشان داده شده در شکل (۳-۱۱).
- یک الکتروود تک قطبی را روی استخوان ران یا آرنج قرار دهید. الکتروود یکپارچه به عنوان مرجع عمل می کند (منطقه بی طرف الکتریکی) و معمولا طولانی ترین کابل است [۵۰].



شکل ۳-۸ موقعیت یک الکتروود دو قطبی به طور صحیح بر روی یک عضله فلکسور دیجیتوروم پروفاندوس نشان داده شده [۵۰]

- اطمینان حاصل شود که هر الکتروود کاملا محکم نصب شده باشد. انحناء بازو نباید باعث لغزش یا حرکت الکتروودها شود. از یک نوار چسب به منظور محکم و ثابت نگه داشتن الکتروود

تا پایان مدت زمان ثبتاستفاده کنید تا ثبات بیشتری فراهم شود چون لرزش می تواند روی سیگنال خروجی تاثیر گذار باشد.

نکاتی که بالا شرح داده شد به منظور کاهش زمان آموزش و خطای طبقه بندی از اهمیت فراوانی برخوردار است.

۳-۳ تبدیل استاکول S

➤ تبدیل S اصلاح شده

با توجه به [۵۱] می توان تبدیل S را یک مرحله ی میانی بین تبدیل STFT و تبدیل موجک پیوسته دانست. این تبدیل در سال ۱۹۹۶ توسط استاکول^۱ و همکاران معرفی شد [۱۱]. در متون علمی به این روش، تبدیل S یا تبدیل استاکول گفته می شود. این تبدیل چنین تعریف می شود:

$$S(\tau, f) = \int_{-\infty}^{\infty} y(t) \omega(\tau - t, f) e^{-j2\pi ft} dt \quad (1-3)$$

تابع پنجره ی $w()$ معمولاً به صورت گوسی و مقدار مثبت انتخاب می شود:

$$\omega(\tau - t, f) = \frac{|f|}{\sqrt{2\pi}} \exp\left(-\frac{f^2(\tau - t)^2}{2}\right) \quad (2-3)$$


این پنجره در فرکانس های بالا، باریک تر و در فرکانس های پایین، پهن تر می شود. تبدیل S در مقایسه با تبدیل STFT، در فرکانس های بالا تفکیک پذیری زمانی بهتر و در فرکانس های پایین تفکیک پذیری فرکانسی بهتری ایجاد می کند [۱۱]. این تبدیل معکوس پذیر بوده و جملات تداخلی تولید نمی کند. تاکنون پیشنهادات مختلفی جهت تعمیم و بسط تابع پنجره ارائه شده است [۵۲]. به ویژه در [۵۳] استفاده از پنجره ی زیر پیشنهاد شده است:

¹ Stockwell

$$\omega(\tau - t, f) = \frac{|f|}{k\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{f(\tau - t)}{k}\right)^2\right], k > 0 \quad (3-3)$$


با افزایش k تفکیک‌پذیری فرکانسی افزایش و تفکیک‌پذیری زمانی کاهش می‌یابد. در [۵۴] اصلاحیه‌ای برای تابع پنجره پیشنهاد شده است. بر مبنای این پیشنهاد، به انتخاب مقداری ثابت برای k ، این پارامتر را به صورت تابعی از فرکانس انتخاب کنیم؛ یعنی $k = mf + q$. بدین ترتیب تفکیک‌پذیری بهبود یافته‌ای حاصل خواهد شد. به منظور مقایسه‌ی عملکرد تبدیل STFT و تبدیل S در این جا از یک چیرپ خطی استفاده شده است.

شکل (۳-۱۲) اسپکتروگرام این سیگنال را نشان می‌دهد. تبدیل S اصلاح شده مطابق با پیشنهاد مطرح شده در [۵۴] به این سیگنال اعمال شده است و نتیجه در شکل (۳-۱۳) نمایش داده شده است. کاملاً واضح است که این نتیجه در مقایسه با نتیجه‌ی اسپکتروگرام خیلی کمتر مات و مبهم است. هر دو شکل (۳-۱۲) و (۳-۱۳) توسط برنامه‌ی متلب تولید شده‌اند. این برنامه مبتنی بر پیاده‌سازی انجام شده توسط داش^۱ است که از طریق سایت تبادل فایل شرکت Mathworks قابل دسترسی است.



شکل ۳-۹ اسپکتروگرام سیگنال [۵۴]

^۱ K. S. Dash



شکل ۳-۱۰ اعمال تبدیل S اصلاح شده بر روی سیگنال [۵۴]

تصور کنید یک موج سینوسی آغشته به نویز ضربه‌ای^۱ داریم. در [۱۱] نشان داده شده است که در روش STFT مشخص کردن این نویزهای ضربه‌ای مستلزم مشکلاتی است (این نویزها خود را به صورت جزیره‌هایی در صفحه‌ی زمان-فرکانس نشان می‌دهند) اما تبدیل S به راحتی این نویزها را آشکارسازی می‌کند. این مطلب روشی برای تحلیل کیفیت توان پیشنهاد می‌دهد^۲ [۵۵]. یک سناریوی جالب دیگر در حالت ترکیب چند سینوسی با فرکانس‌های مختلف است؛ تبدیل S دارای قابلیت تمیز و تشخیص دادن این سینوسی‌ها از یکدیگر است. برای مثال در [۵۶] از تبدیل S برای تجزیه‌ی سیگنال ارتعاش چرخ دنده استفاده شده است.

از جمله کاربردهای دیگر تبدیل S، طبقه‌بندی سیگنال‌های الکتروکورتیکوگرام (ECoG)^۳ چند طبقه در کاربرد واسط مغز-رایانه (BCI)^۴ [۵۷]، تحلیل داده‌های الکتروانسفالوگرافی (EEG)^۵ کودکان تازه متولد شده، حذف تداخل برق شهر از سیگنال‌های زیست‌پزشکی [۵۸]، حذف نویز سیگنال‌های لرزه

^۱ Spike

^۲ یعنی روشی داشته باشیم که کیفیت طیف توان را از نظر میزان آغشتگی به نویز تعیین کند.

^۳ Electrocorticogram

^۴ Brain-Computer Interface

^۵ Electroencephalographic data

نگاری^۱ [۵۹]، تحلیل صدای قلب [۶۰]، مطالعه‌ی نوسانات خاک و ساختمان [۶۱]، تحلیل اثرات الکل روی سیگنال مغزی EEG [۶۲]، فشرده‌سازی تصویر [۶۳] و غیره است. توابع پنجره‌ای که در تبدیل S استفاده می‌شوند باید در شرط زیر صدق کنند:

$$\int_{-\infty}^{\infty} \omega(\tau - t, f) d\tau = 1 \quad (۳-۴)$$

شرط فوق تضمین می‌کند که حاصل متوسط‌گیری از $S(\tau, f)$ روی تمام مقادیر τ برابر با $Y(f)$ ، یعنی تبدیل فوریه‌ی $y(t)$ خواهد بود [۵۴]؛ زیرا:

$$\begin{aligned} \int_{-\infty}^{\infty} S(\tau, f) d\tau &= \int_{-\infty}^{\infty} y(t) e^{-j2\pi ft} dt \\ &\times \int_{-\infty}^{\infty} \omega(\tau - t, f) d\tau dt = \int_{-\infty}^{\infty} y(t) e^{-j2\pi ft} dt \\ &= Y(f) \end{aligned} \quad (۵-۳)$$

حال (با توجه به رابطه‌ی فوق و نیز با توجه به این که از روی $Y(f)$ می‌توان سیگنال $y(t)$ را به طور کامل بازسازی کرد، تبدیل S دارای ویژگی معکوس‌پذیری است. (۵-۳)

¹ Seismogram



فصل چهارم

روش پیشنهادی

۴-۱ مقدمه

سیگنال های الکترومایوگرام توسط ماهیچه های اسکلتی (موتورهای که به ما اجازه ی حرکت می دهند) تولید می شوند [۶۴] و الکترومایوگرافی به جمع آوری سیگنال های الکتریکی تولید شده از ماهیچه که بوسیله ی سیستم عصبی کنترل و با انقباض ماهیچه تولید میشوند بر میگردد در واقع یک سیگنال الکترومایوگرام فعالیت الکتریکی واحد های حرکتی ماهیچه است و متناسب با نوع الکترو استفاده شامل دو نوع سطحی و داخلی می باشد. الکترومایوگرافی سطحی^۱ در زمینه های متعددی شامل زیستی پزشکی و بالینی، پروتزه های مصنوعی تعامل انسان ماشین و ... کاربرد دارد [۶۵]. الکترومایوگرام یکی از روش های غیر تهاجمی و ابزارهای نسبتا دقیق برای ارزیابی وضعیت و خستگی ماهیچه در فعالیت های فیزیکی نیز می باشد [۶۶]. خستگی ماهیچه می تواند به عنوان کاهش ظرفیت و توانایی ماهیچه در تولید نیرو تعریف گردد [۶۷]. که این خستگی اغلب نتیجه انجام یک کار ناصحیح است [۶۸]. ارزیابی خستگی عضلانی برای کشف اولیه و پیشگیری از ریسک های ماهیچه ای مربوط به کار اهمیت دارد [۶۶]. در این میان چگونگی استخراج ویژگی سیگنال های الکترومایوگرام از اهمیت ویژه ای برخوردار است. برای سیگنال های الکترومایوگرام سه نوع ویژگی وجود دارد. ویژگی حوزه زمان، حوزه فرکانس و حوزه زمان-فرکانس [۶۶]. Cifrek و همکارانش در سال ۲۰۰۹ طبقه بندی مناسبی از روش های استخراج ویژگی و پردازش سیگنال های الکترومایوگرام ارائه کردند [۶۹]. Kamaruddin دیگران نیز در سال ۲۰۱۵ در این زمینه مطالعه کرده و روش های استخراج ویژگی و همچنین طبقه بندی سیگنال های الکترومایوگرام را شرح داده اند [۷۰] تعدادی از محققان تبدیل فوریه [۷۱] و تبدیل موجک [۷۲] را به منظور تجزیه سیگنال و استخراج ویژگی از آن مورد استفاده قرار داده اند. تحلیل فوریه سیگنال را ایستان در نظر میگیرد در حالیکه سیگنال های الکترومایوگرافی ایستان نیستند بنابراین ممکن است تخمین قابل اعتمادی از خستگی ماهیچه ارائه ندهند [۷۳]. لذا تبدیل موجک برای تجزیه تحلیل سیگنال های الکترومایوگرام مناسب تر

¹ Surface Electromyography

است [۷۴]. به هر حال استفاده از تبدیل فوریه برای سیگنال های غیر ایستاد کار نادرستی نیست اما به زبان ساده رویدادهای زودگذری که در زمان قابل مشاهده هستند را آشکار نمی کند [۷۲] تبدیل فوریه زمان کوتاه^۱ با در نظر گرفتن بازه ها یا پنجره های زمانی این مشکل را حل کرد اما مشکل آن این است که فقط تفکیک پذیری فرکانسی دارد [۷۵]. ولی تبدیل موجک به طور هم زمان تفکیک پذیری زمانی و فرکانسی بهتری دارد [۶۶].

مطالعات بسیاری نیز در خصوص مقایسه ی روش های استخراج شده است که تعدادی از آنها به مقایسه تبدیل موجک و فوریه پرداخته و اغلب تبدیل موجک را روش مناسب تری معرفی کرده اند [۷۶] روش موجک سیگنال را به عنوان ترکیبی خطی از مجموعه ای ویژه از توابع موجک بیان می کند. که این توابع با شیفت دادن و اتساع کردن یک تابع به نام موجک مادر^۲ به دست آمده اند و سپس شباهت بین شکل موجک نتیجه شده با سیگنال محاسبه می شود [۷۴]. یکی از نکات اساسی در استفاده از تبدیل موجک انتخاب تابع ویولت مناسب می باشد که قانون مشخصی برای آن وجود ندارد. همانطور که در فصل سوم اشاره کردیم می توان تبدیل S را یک مرحله ی میانی بین تبدیل فوریه زمان کوتاه و تبدیل موجک پیوسته دانست [۵۳] که دارای یک پنجره گوسی است که در فرکانس ها بالا، باریک تر و در فرکانس های پایین، پهن تر می شود [۱۱]. تبدیل S در مقایسه با تبدیل تبدیل فوریه زمان کوتاه، در فرکانس های بالا تفکیک پذیری زمانی بهتر و در فرکانس های پایین تفکیک پذیری فرکانسی بهتری ایجاد می کند [۱۱].

۲-۴ روش پیشنهادی

هدف اصلی ما در ارائه روش پیشنهادی ارائه رویکردی جدید برای تحلیل سیگنال های الکترومایوگرام در حوزه زمان - فرکانس است که بدین منظور از تبدیل S یا استاکول^۳ استفاده کرده ایم که نسبت به سایر روش ها، تفکیک پذیری زمان فرکانسی را با کیفیت مناسبی مهیا میکند [۱۱].

¹ Short Time Fourier Transform

² Mother Wavelet

³ Stockwell

بدین منظور کار انجام شده در این پایان نامه با دو رویکرد ارائه شده است. رویکرد اول تحلیل در حوزه زمان می باشد و رویکرد دوم تحلیل سیگنال در حوزه زمان - فرکانس و با تبدیل استاکول صورت پذیرفته است که مراحل به سه دسته اصلی دسته بندی میشود: پیش پردازش، استخراج ویژگی و طبقه بندی. شمای کلی از روند روش پیشنهادی و هر دو رویکرد در شکل (۴-۱) مشاهده می شود که در ادامه هر کدام به اختصار توضیح داده خواهند شد.




شکل ۴-۱ دیاگرام بلوکی روش پیشنهادی

۴-۳ پایگاه داده مورد استفاده

در این پایان نامه به منظور تحلیل سیگنال از پایگاه داده استفاده شده در مقاله [۱۴] استفاده شده است. سیگنال های ثبت و جمع آوری شده در این مقاله از ده شخص، هفت مرد و ۳ زن که این افراد هیچگونه سابقه بیماری یا اختلال اسکلتی عضلانی مزمن نداشته و رضایت خود را به صورت کتبی برای شرکت در این تحقیق از طریق پرسش نامه قبل از ثبت سیگنال اعلام نموده اند، جمع آوری شده است. افراد بر روی صندلی نشسته و بازوی خود را در یک موقعیت ثابت کرده اند تا از

اثرات نامطلوب و نویزی مربوط به حرکت های ناخواسته بدن^۱ برای تولید سیگنال های الکترومایوگرام جلوگیری کنند. برای ثبت سیگنال الکترومایوگرام به صورت سطحی از الکترودهای نقره کلرید با قطر ۱۰ میلی متر استفاده شد. قبل از اتصال الکترودها، به منظور کاهش امپدانس پوست-الکترودها موقعیت عضله با الکلی تمیز و سپس دو الکترودها با آرایش دو قطبی (رجوع شود به فصل سوم) قرار گرفته اند. به منظور جلوگیری از حرکات ناخواسته و جدا شدن الکترودها چسب هایی بر روی هر یک از سنسورها زده شد تا سنسورها به خوبی به پوست بچسبند. از ناحیه استخوانی مچ دست به دلیل دارا بودن ناحیه غیر فعال الکتریکی به عنوان مرجع ثبت سیگنال^۲ استفاده گردید است و الکترودها مرجع در این نقطه متصل شده است. موقعیت این الکترودها در شکل (۴-۲) نشان داده شده است. ثبت سیگنال با استفاده از دستگاه Bagnoli Delsys Inc. EMG صورت گرفت و به دلیل اینکه سیگنال های الکترومایوگرام دارای دامنه کوچکی هستند با بهره^۳ ۱۰۰۰ تقویت شدند. با توجه به محدوده فرکانسی سیگنال الکترومایوگرام سطحی فرکانس نمونه برداری ۴۰۰۰ هرتز در نظر گرفته شده است.




شکل ۴-۲ الف) مکان قرار گیری الکترودها اول بر روی ساعد دست راست ب) مکان قرار گیری الکترودها دوم و الکترودها مرجع بر روی ساعد و مچ دست راست [۱۴]

^۱ Artifact

^۲ Dermatode Reference Electrode


^۳ Gain

در مجموع ده کلاس حرکتی ترکیبی و تکی از حرکات انگشتان دست تعریف شده است که شامل خم کردن هر یک از انگشتان تکی، یعنی انگشت شست (T)، انگشت شاخص (I)، انگشت میانه (M)، انگشت حلقه (R)، انگشت کوچک (L) و خم کردن ترکیبی شامل انگشت شست و شاخص (T-I)، انگشت شست و میانه (T-M)، انگشت شست و حلقه (T-R)، انگشت شست و کوچک (T-L) و در نهایت بستن دست (HC) می شود که در شکل (۳-۴) نمایش داده شده است.



شکل ۳-۴ ده حرکت مورد نظر جهت تشخیص و طبقه بندی [۱۴]

به منظور ثبت سیگنال از داوطلب ها، یک نشانه شنوایی بین اپراتور ثبت کننده سیگنال و داوطلب ها قرار داد شد. داوطلب ها با شنیدن این نشانه انگشتان خود را از حالت استراحت به حالت حرکت در آورده و یکی از کلاس حرکتی را انجام داده و به مدت ۵ ثانیه آن حرکت را حفظ می کنند. هر حرکت ۶ بار با دوره استراحت ۳ تا ۵ ثانیه بین آزمایشات تکرار شد. یک نمونه از سیگنال خام مربوط به حرکت بستن دست را در شکل (۴-۴) مشاهده می کنید. همانطور که در شکل مشخص است دامنه مربوط به الکتروود اول بیشتر از الکتروود دوم می باشد به این معنا که محل قرار گیری الکتروود اول جایی است که عضله مرتبط با حرکت بستن دست در آنجا قرار گرفته است که موجب افزایش دامنه شده است. این امر نشان می دهد محل نصب الکتروود ها بسیار حائز اهمیت می باشد. برای اطلاعات بیشتر در مورد عضلات و محل قرار گیری الکتروود ها به فصل سوم مراجعه شود.



شکل ۴-۴ نمونه ای از سیگنال خام ثبت شده از حرکت بستن دست



۴-۴ پیش پردازش سیگنال سیگنال الکترومایوگرام

قبل از انجام پردازش های مربوط به استخراج ویژگی، ابتدا بر روی سیگنال ثبت شده پیش پردازش انجام شده است. با توجه به اینکه ثبت سیگنال در محیطی نویزی صورت میگیرد که این نویزها میتواند نشات گرفته از عواملی همچون نویز برق شهر، دستگاه های الکترومغناطیسی، ماهیچه های کناری، تاثیر تپش قلب و حرکت های کاربر باشد، بدین منظور جهت حذف این عوامل باید چاره اندیشی شود تا اطلاعات زائد که موجب می شود در مرحله استخراج ویژگی و طبقه بندی، ما دچار خطا شویم تا حد امکان حذف شود. بدین ترتیب بایستی علاوه بر استفاده از یک الگوی موثر برای اخذ سیگنال از فیلترهای مناسب هم استفاده نماییم تا مقادیر نویز به حداقل رسیده و سیگنال تا حد ممکن عاری از هرگونه نویز شود. با توجه به محدوده فرکانسی سیگنال الکترومایوگرام سطحی، ابتدا



یک فیلتر باترورث^۱ با فرکانس قطع پایین ۲۰ هرتز و فرکانس قطع بالای ۴۵۰ هرتز بر روی سیگنال‌ها اعمال می‌شود تا اثرات مربوط به عضلات و به خصوص تاثیرات مربوط به سیگنال قلبی حذف شود. همچنین جهت حذف نویز برق شهر از یک فیلتر ناچ^۲ با فرکانس ۵۰ هرتز استفاده شده است. با اخذ اطلاعات سیگنال واقعی و به حداقل رساندن اثرات نویز دو اتفاق روی خواهد داد: اولاً حجم اطلاعات کاهش خواهد یافت و حافظه کمتری برای ذخیره سازی مورد نیاز خواهد بود ثانیاً حجم محاسبات را کاهش می‌دهد. در شکل (۴-۵) (الف) نمونه ای از سیگنال الکترومایوگرام که تحت تاثیر سیگنال قلبی قرار گرفته است را مشاهده می‌کنید. در شکل (۴-۵) (ب) اثر سیگنال قلبی یا استفاده از فیلتر باترورث میان گذر حذف شده است. شکل (۴-۶) (الف) نمونه ای از سیگنال الکترومایوگرام را که تحت تاثیر نویز تداخل برق شهری قرار گرفته است نمایش می‌دهد. در شکل (۴-۶) (ب) اثر نویز برق شهر با استفاده از یک فیلتر ناچ ۵۰ هرتز حذف شده است. شکل (۴-۷) نمونه ای از سیگنال الکترومایوگرام که در زمان ثبت دچار آرتیفکت شده است نمایش می‌دهد. به منظور حذف این نویز باید در زمان ثبت سیگنال با استفاده از چسب الکتروودها ثابت شوند و شخصی که از او سیگنال گرفته می‌شود در موقعیت ثابت و بی حرکت قرار گیرد.

¹ Butterworth


² Notch



شکل ۴-۵ (الف) نمونه ی سیگنال الکترومایوگرام که تحت تاثیر سیگنال قلبی قرار گرفته است. (ب) اثر سیگنال قلبی با استفاده از فیلتر باترورث حذف شده است [۷۷]



شکل ۴-۶ (الف) نمونه ای از سیگنال الکترومایوگرام که تحت تاثیر نویز تداخل برق شهر قرار گرفته است. (ب) اثر نویز برق شهر با استفاده از یک فیلتر ناچ ۵۰ هرتزی حذف شده است [۷۷]



شکل ۴-۷ نمونه ای از سیگنال الکترومایوگرام که دچار آرتیفکت شده است [۷۷]

۴-۵ استخراج ویژگی

در این مرحله اطلاعات مهم و معنادار از سیگنال های الکترومایوگرام استخراج می شود و این اطلاعات به جای سیگنال خام به طبقه بند ارسال می شود تا بتواند براساس ویژگی های سیگنال، طبقه بندی را انجام دهد. در واقع میتوان گفت فرآیند استخراج ویژگی به نوعی موجب کاهش ابعاد می شود هنگامی که مجموعه داده های ورودی بسیار زیاد باشد، از این مرحله برای تبدیل داده های ورودی به مجموعه ای از اطلاعات معنی دار استفاده می شود. از این رو، هدف از استخراج ویژگی حذف داده های اضافه و برجسته کردن داده های تاثیر گذار می باشد. این مرحله نقش مهمی در بهبود نتایج طبقه بندی دارد. همانطور که قبلا اشاره شد در فرایند کار مرحله استخراج ویژگی نقش به سزایی دارد. در این مرحله یک بررسی آماری دقیق و بهینه به منظور انتخاب ویژگی مناسب صورت پذیرفته است. به همین جهت به مطالعه و بررسی مقالات موجود در زمینه استخراج ویژگی از سیگنال های الکترومایوگرام از سال ۲۰۱۳ تا ۲۰۱۷ پرداخته شده است و یک جدول آماری بر اساس تعداد دفعات استفاده از ویژگی ها تهیه شده تا بر اساس آن بتوان ویژگی های مناسب را انتخاب کرد و از آنها استفاده نمود که این ویژگی ها در جدول (۴-۱) نمایش داده شده است.

جدول ۴-۱ ویژگی های استخراج شده در مقالات تشخیص حرکت دست با استفاده از الکترومایوگرام در سال های

۲۰۱۳ تا ۲۰۱۷

2017	2016	2015	2014	2013	Features
10	3	2	3	2	Root Mean Square
8	4	1	1	2	Mean Absolute Value
3	2	2	0	0	Simple Square Integral
7	2	1	2	2	Waveform Length
4	0	0	0	0	Average Amplitude Change
2	0	0	0	0	Log
1	3	0	0	0	DASDV
1	0	0	0	2	Kurtosis
1	1	0	0	0	Skewness
2	0	0	1	0	Mean Power
1	0	0	0	1	Total Power
3	2	3	0	2	Standard Deviation
7	2	1	3	1	Auto Regressive
2	1	0	2	3	Median Frequency
2	0	0	1	1	Mean Power Frequency
2	4	0	1	1	Variance
4	3	0	2	2	Zero Crossing
2	3	1	0	2	Slope Of Sign Changes
1	0	0	0	0	Sum Of Peak
2	2	1	0	1	Willision Amplitude
2	3	1	0	1	Integrated EMG
1	0	0	0	0	STFT
2	3	0	0	0	Wavelet Transform
1	1	0	0	0	Hjorth Activity
1	1	0	0	0	Hjorth Complexity
1	1	0	0	0	Hjorth Mobility
1	1	0	0	0	Hilbert Huang Transform
1	0	0	0	0	Energy
2	0	1	0	0	Entropy
1	0	1	2	0	Maximum Value
1	0	0	0	0	Minimum Value
1	0	0	0	0	Difference MaxMin
1	0	0	0	0	Singular Value Decomposition
2	0	0	0	0	Spectrum
7	2	1	1	1	EMG Integral
1	1	1	0	0	Cepstral coefficients
1	0	0	0	0	Frequency Histogram
1	0	0	0	0	Spectrul Moment
1	0	0	0	0	Maximum Fractal Lenght
0	1	0	0	0	Complexity
0	1	0	0	0	Mobility
0	1	0	0	0	Square Sum
0	1	0	0	0	Myopulse Percentage Rate
0	1	0	0	0	Average Value Rectifier
0	1	0	0	0	Top And Slop
0	0	0	0	1	Coefficient Of Variation
0	0	0	0	2	Empirical Mode Decomposition
0	3	1	0	1	Mean Frequency
0	0	0	0	1	Peak Frequency
0	1	0	0	1	Power Spectral Density

با توجه به این که سیگنال الکترومایوگرام دارای ماهیت تصادفی است لذا هر نمونه از سیگنال در هر لحظه می تواند حاوی اطلاعات کمی در ارتباط با عضله باشد [۷۸]. ویژگی ها از سیگنال پیش پردازش شده با استفاده از یک پنجره لغزنده محاسبه می شود که میتوان پنجره ها را به صورت مجزا^۱ و یا همپوشان^۲ در نظر گرفت [۷۹]. اثبات شده است که طرح همپوشانی پنجره عملکرد بهتری را نسبت به طرح پنجره مجزا برای طبقه بندی دارد [۷۹]. با این وجود این استراتژی منجر به افزایش هزینه های محاسباتی در مرحله آموزش و حتی در مرحله تست برای طبقه بندیها می شود [۸۰]. بنابراین، در این پایان نامه ما بر افزایش عملکرد طرح پنجره مجزا با توجه به سادگی آن و کاهش هزینه محاسبات تمرکز کرده ایم. سیگنال ثبت شده به بازه های^۳ ۵۰۰ میلی ثانیه تقسیم می شود که البته به منظور پیدا کردن بهترین نتیجه بازه های ۱۰۰، ۲۰۰، ۳۰۰، ۴۰۰ و ۶۰۰ میلی ثانیه هم مورد آزمایش قرار گرفت از طرفی برای انتخاب نوع پنجره، همینگ^۴ و مستطیلی^۵ مورد آزمایش قرار گرفت که مشخص شد انتخاب پنجره همینگ نتیجه بهتری در دقت طبقه بندی ایجاد خواهد کرد. توجه به این امر حائز اهمیت است که برای ساخت پروتز مصنوعی به منظور فرمان گرفتن بازوی رباتیک به صورت بلادرنگ از اپراتور باید پنجره زمانی انتخاب شده کمتر از ۳۰۰ میلی ثانیه باشد [۸۱]. همانطور که در مقدمه اشاره شد هدف ما تحلیل سیگنال ها در دو حوزه زمان و زمان-فرکانس می باشد. به منظور تحلیل در حوزه زمان از تمام فریم های سیگنال در حوزه زمان استخراج ویژگی صورت می گیرد سپس برای تحلیل در حوزه زمان-فرکانس بر روی هر یک از فریم های سیگنال ابتدا تبدیل استاکول اعمال میشود و سپس ویژگی های مورد نظر استخراج می شوند. در شکل (۴-۸) یک نمونه از اعمال تبدیل استاکول بر روی سیگنال الکترومایوگرام مربوط به شخص اول و حرکت بستن دست برای الکتروود اول و شکل (۴-۹) برای الکتروود دوم را مشاهده می کنید.

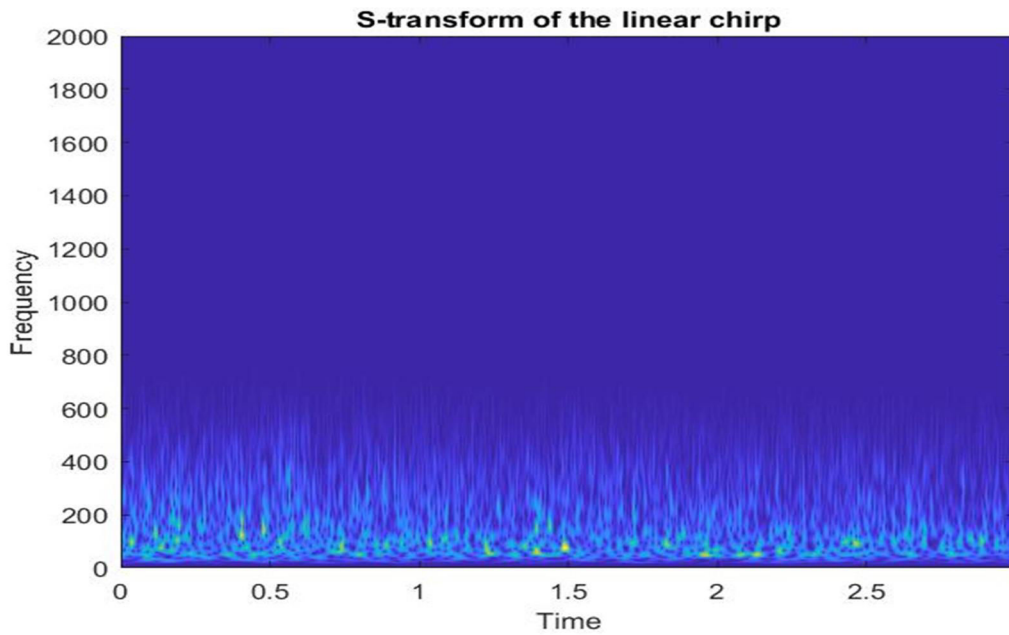
¹ Disjoint

² Overlap


³ Frame

⁴ Hamming

⁵ Rectangular



شکل ۴-۸ یک نمونه از اعمال تبدیل استاکول بر روی سیگنال الکترومایوگرام مربوط به شخص اول و حرکت بستن دست برای الکتروود اول



شکل ۴-۹ یک نمونه از اعمال تبدیل استاکول بر روی سیگنال الکترومایوگرام مربوط به شخص اول و حرکت بستن دست برای الکتروود دوم

سپس با استفاده از جدول (۴-۱) و آزمون و خطا ۱۶ ویژگی (در مجموع ۳۲ ویژگی برای هر سیگنال از هر الکتروود (۲×۱۶) انتخاب شد که در ادامه به معرفی این ویژگی ها خواهیم پرداخت. ویژگی های دامنه زمانی معمولاً سریع و آسان محاسبه می شوند، زیرا این ویژگی ها نیازی به تغییر یا

تبدیل ندارند، بر همین اساس بر روی الکترومایوگرام خام محاسبه می شود. ویژگیهای دامنه زمانی به طور گسترده ای در تحقیقات مربوط به پردازش سیگنال های حیاتی مورد استفاده قرار می گیرند [۸۲]. مشکل بزرگ ویژگی های این گروه این است که سیگنال الکترومایوگرام غیر ایستان است و خواص آماری آن با زمان تغییر می کند اما ویژگی های زمانی داده ها را به عنوان یک سیگنال ایستان فرض می کنند [۸۲]. علاوه بر این، با توجه به اینکه این ویژگی ها بر اساس مقادیر دامنه سیگنال الکترومایوگرام بدست می آیند نویزهایی که بر روی سیگنال الکترومایوگرام اثر گذاشته است می تواند این ویژگی ها را تحت تاثیر قرار دهد به خصوص ویژگی هایی که از انرژی سیگنال حاصل میشوند [۸۲]. با این حال، ویژگی های این گروه نیز به واسطه اینکه پیچیدگی محاسباتی کمتری نسبت به ویژگی های حوزه فرکانس و حوزه زمان-فرکانس دارند بیشتر استفاده شده اند. اما در مقابل از آن جا که سیگنال الکترومایوگرام، سیگنالی غیر ایستان می باشد و روش های زمان-فرکانس برخلاف آنالیزهای طیفی مبتنی بر تبدیل فوریه، نیازی به فرض ایستایی ندارند، می توان از تبدیل استاکول که تحلیل سیگنال غیر ایستان الکترومایوگرام سطحی را همزمان در دو بعد زمان و فرکانس فراهم می سازد، استفاده نمود [۸۲].

۴-۵-۱ ویژگی ها

در این بخش به بررسی و معرفی شانزده ویژگی مورد استفاده در این پایان نامه خواهیم پرداخت.

۴-۵-۱-۱ میانگین قدر مطلق

میانگین مقدار مطلق^۱ یکی از رایج ترین ویژگی های مورد استفاده در تجزیه و تحلیل سیگنال EMG است. میانگین مقدار مطلق به عنوان شاخص شروع، به خصوص در تشخیص سیگنال الکترومایوگرام سطحی برای کنترل پروتز مصنوعی استفاده می شود. با این حال، با نام های متعددی

¹ Mean Absolute Value

شناخته می شود؛ به عنوان مثال، میانگین مقدار اصلاح شده^۱، متوسط مقدار مطلق^۲، انتگرال مقدار مطلق^۳. این ویژگی میانگین مقدار مطلق دامنه سیگنال الکترومایوگرام را در یک بازه^۴ از سیگنال نمایش می دهد که به شکل زیر تعریف می شود [۸۲]:

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (1-4)$$

در رابطه (۱-۴) N بیانگر طول سیگنال می باشد.

X_i نشان دهنده سیگنال الکترومایوگرام در فریم (پنجره) i ام می باشد.

۴-۵-۱-۲ ریشه میانگین مربعات (مقدار موثر)

ریشه میانگین مربعات^۵ یکی دیگر از ویژگی های رایج در تجزیه و تحلیل سیگنال الکترومایوگرام است. این مدل به عنوان یک فرآیند تصادفی گوسی در دامنه مدل شده است. مقدار ریشه میانگین مربعات سیگنال الکترومایوگرام در ارتباط با واحد حرکتی، منعکس کننده ی، مدت زمان و سرعت سیگنال الکتریکی است. افزایش این ویژگی می تواند نشان دهنده ی بکارگیری تعداد فیبرهای عضلانی^۶ بیشتر برای یک نیروی خارجی ثابت باشد و شاخصی از پیشرفت خستگی است [۸۲].

تعریف ریاضی این ویژگی به شکل زیر می باشد:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (2-4)$$

¹ Average Rectified Value

² Average Absolute Value

³ Integral of Absolute Value

⁴ Segment

⁵ Root Mean Square

⁶ Motor Unit

در رابطه (۴-۲)، X_i ، سیگنال الکترومایوگرام در فریم i ام می باشد و N نشان دهنده طول سیگنال است. در محاسبه‌ی ریشه میانگین مربعات، پارامتر N که معرف طول پنجره می باشد، بهتر است متناسب با ماهیت فعالیت مورد بررسی باشد. به این معنی که باید برای حرکات کند، بازه طولانی و برای حرکات سریع، کوتاه باشد [۸۲].

۴-۵-۱-۳ طول شکل موج

طول شکل موج^۱ به فاصله بین دو قله متوالی موج یا بین هر دو نقطه تکراری موج که شکل یکسان دارند گفته می‌شود. در برخی از مقالات این ویژگی را با نام طول موج^۲ معرفی می کنند. تعریف ریاضی این ویژگی به شکل زیر می باشد [۸۲]:

$$WL = \sum_{i=1}^{N-1} |X_{i+1} - X_i| \quad (۳-۴)$$

۴-۵-۱-۴ تغییر علامت شیب

تغییر علامت شیب^۳ به صورت تعداد دفعاتی تعریف می شود که شیب سیگنال الکترومایوگرام تغییر می کند. این ویژگی نیز یک ویژگی زمانی دیگر است که مقدار آن برابر با تعداد تغییر علامت شیب سیگنال در بازه زمانی می باشد. به عبارت دیگر این ویژگی بیانگر تعداد پیکهای مثبت و منفی سیگنال در آن بازه است.

مقدار مناسب پارامتر آستانه برای این ویژگی معمولاً بین ۵۰ و ۱۰۰ میلی ولت انتخاب می شود [۸۲].

تعریف ریاضی این ویژگی به شکل زیر است:

$$SSC = \sum_{i=2}^{N-1} [f[(X_i - X_{i-1}) \times (X_i - X_{i+1})]] \quad (۴-۴)$$

¹ Waveform Length

² Wavelength

³ Slope Sign Change

$$f(X) = \begin{cases} 1 & \text{if } X > \text{Threshold} \\ 0 & \text{Otherwise} \end{cases}$$

۴-۵-۱-۵ ضریب اتورگرسیو

ضریب اتورگرسیو^۱ یک مدل پیش بینی است که هر نمونه از سیگنال الکترومایوگرام را به عنوان یک ترکیب خطی از نمونه های قبلی X به علاوه یک خطای نویز سفید W نشان می دهد. در طبقه بندی سیگنال های الکترومایوگرام ضرایب اتورگرسیو به عنوان بردار ویژگی استفاده می شوند. تعریف ریاضی این ویژگی به شکل زیر است:

$$X_t = \sum_{i=1}^P a_i X_{t-i} + w_t \quad (۵-۴)$$

در معادله فوق P نشان دهنده مرتبه مدل ضریب اتورگرسیو است. معمولاً از ضریب اتورگرسیو با مرتبه دوم یا سوم در مقالات استفاده شده است و X_t سری زمانی مورد بررسی می باشد [۸۲].

۴-۵-۱-۶ نرخ عبور از صفر

ویژگی نرخ عبور از صفر^۲ یک اندازه ساده است که در حوزه زمان محاسبه می گردد و با شمارش تعداد دفعاتی که سیگنال در بازه ی زمانی از خط صفر عبور کرده است مشخص میگردد [۸۲].

تعریف ریاضی این ویژگی به شکل زیر است:

$$ZC = \sum_{i=1}^{N-1} \text{Sgn}(-X_i X_{i+1}) \quad (۶-۴)$$

$$\text{Sgn}(X) = \begin{cases} 1 & \text{if } X > 0 \\ 0 & \text{Otherwise} \end{cases}$$

¹ Auto-Regressive Coefficients

² Zero Crossing

۴-۵-۱-۷ واریانس

مقدار واریانس^۱ مجذور انحراف معیار بوده بیان کننده این است که نمونه ها چقدر از یکدیگر متفاوت هستند یا به بیان دیگر معرف شدت تغییرات سیگنال است. از آنجا که مقدار میانگین سیگنال EMG نزدیک به صفر است ($\approx 10^{-10}$) لذا به شکل زیر تعریف می شود [۸۲].

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (X_i^2) \quad (۷-۴)$$

۴-۵-۱-۸ بیشترین مقدار

بیشترین مقدار^۲ سیگنال در یک بازه زمانی مشخص به عنوان یک ویژگی آماری مورد استفاده قرار گرفته است.

۴-۵-۱-۹ کمترین مقدار

کمترین مقدار سیگنال^۳ در یک بازه زمانی مشخص به عنوان یک ویژگی آماری مورد استفاده قرار گرفته است.

۴-۵-۱-۱۰ میانگین سیگنال

میانگین دامنه سیگنال در یک بازه زمانی مشخص به عنوان یک ویژگی آماری مورد استفاده قرار گرفته است.

۴-۵-۱-۱۱ فرکانس میانه

فرکانس میانه^۴ پس از محاسبه‌ی تابع چگالی توان سیگنال ورودی در حوزه‌ی فرکانس، محاسبه می‌شود. اگر سیگنال با $X(t)$ و چگالی طیف توان آن با $PSD(f)$ نمایش داده شود، نحوه‌ی محاسبه‌ی تابع چگالی توان سیگنال ورودی به صورت زیر است.

¹ Variance

² Maximum Value

³ Minimum Value

⁴ Median Frequency

$$PSD(f) = F\{X(t)\} \times F\{X(t)\}^* \quad (۸-۴)$$

فرکانس میانه، فرکانسی است که در آن، منحنی طیف توان به ۲ مساحت مساوی تقسیم می شود به عبارت دیگر فرکانس میانه برابر با نصف توان کل^۱ است که به شکل زیر تعریف می شود [۸۲].

$$MF = \frac{1}{2} \sum_{j=1}^M P_j \quad (۹-۴)$$

در رابطه (۹-۴) M طول طیف فرکانس و P طیف توان سیگنال ما در نقطه J می باشد.

۴-۵-۱-۱۲ فرکانس متوسط

فرکانس متوسط^۲ معرف آماری از رفتار فرکانسی سیگنال ورودی است. از رایج ترین متغیرهای فرکانسی در مطالعات EMG است، MNF طیف توان بوده و به صورت ممان مرتبه ی اول آن تعریف میگردد. فرکانس متوسط به صورت مجموع حاصل ضرب فرکانس در طیف توان سیگنال الکترومایوگرام و تقسیم بر مجموع طیف توان حاصل تعریف میشود فرکانس مرکزی f_c و طیف مرکزی از نامهای دیگر ویژگی فرکانس متوسط است که به شکل زیر تعریف می شود [۸۲].

$$MNF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (۱۰-۴)$$

که M طول طیف فرکانس است و f_j فرکانس ما در نقطه J ام و P طیف توان سیگنال ما در نقطه J می باشد. دو ویژگی فرکانس میانه و فرکانس متوسط در موارد زیادی به منظور فراهم نمودن اطلاعات پایه ای در مورد اینکه طیف توان چگونه در طول زمان تغییر میکند، مورد استفاده قرار میگیرند.

¹ Total Power

² Mean Power Frequency

۴-۵-۱-۱۳ انتگرال سیگنال الکترومایوگرام

ویژگی انتگرال سیگنال الکترومایوگرام^۱ برابر است با انتگرال (مجموع) قدر مطلق سیگنال، با معیار میانگین مقدار مطلق در یک ضرب متفاوت است که به شکل زیر تعریف می شود [۸۲].

$$IEMG = \sum_{i=1}^N |X_i| \quad (11-4)$$

N نشان دهنده طول سیگنال و i بیانگر شماره فریم سیگنال می باشد.

۴-۵-۱-۱۴ متوسط انرژی سیگنال

این ویژگی متوسط انرژی سیگنال^۲ را در یک بازه مشخص محاسبه می کند که از رابطه ی زیر انرژی سیگنال محاسبه میشود و اگر تقسیم بر طول فریم شود متوسط انرژی را می دهد [۸۲].
تعریف ریاضی این ویژگی به شکل زیر است:

$$E_s = \langle X(n), X(n) \rangle = \sum_{n=-\infty}^{\infty} |X(n)|^2 \quad (12-4)$$

۴-۵-۱-۱۵ میانگین توان سیگنال

این ویژگی میانگین توان سیگنال^۳ را در محدوده فرکانسی مشخص شده به ما می دهد [۸۲].

تعریف ریاضی این ویژگی به شکل زیر است:

$$MNP = \sum_{j=1}^M P_j / M \quad (13-4)$$

در رابطه (۱۳-۴) M طول طیف فرکانس و P طیف توان سیگنال ما در نقطه J می باشد.

¹ Integrated EMG

² Average Energy Signal

³ Average Power Signal

هر یک از ویژگی‌هایی که معرفی شد فقط یک ویژگی را در هر کانال عضلانی فراهم می‌کند که یک ویژگی کافی نبوده و باید با یکدیگر ترکیب شوند تا یک بردار ویژگی با قدرت تمایز بیشتر تولید کنند. با این حال ممکن است ویژگی‌های ما به حدی زیاد شود که بین آنها همبستگی ایجاد شود و موجب داده اضافه شده که این امر سبب میشود نتوانیم در فضای ویژگی داده‌ها را از هم تمییز دهیم. استفاده از ویژگی‌های بیشتر ممکن است کارایی بردار ویژگی متمایز کننده را افزایش دهد، اما تعداد ویژگی بیشتر باعث افزایش بار محاسباتی طبقه بند هم می‌شود. از این رو باید تا حد ممکن از کمترین تعداد ویژگی با بیشترین قابلیت متمایز کنندگی استفاده کنیم. با توجه به اینکه در نهایت قرار است طبقه بند با استفاده از این ویژگی‌ها تصمیم‌گیری کند به منظور جلوگیری از برجستگی یک ویژگی نسبت به سایر ویژگی‌ها در پایان، عملیات نرمال سازی را انجام می‌دهیم. به منظور کاهش پیچیدگی محاسبات و کاهش زمان محاسبات از الگوریتم تحلیل مولفه اصلی^۱ به منظور کاهش ابعاد ویژگی‌ها استفاده می‌کنیم. توجه به این نکته حائزه اهمیت است که باید تعداد ویژگی‌ها به اندازه‌ای کاهش یابد که به طور همزمان با کاهش بعد بردار، دقت طبقه بندی ما به صورت محسوسی کاهش نیابد.

۴-۶ طبقه بندی

در این مرحله که مرحله نهایی می‌باشد ویژگی‌های استخراج شده به طبقه بند داده می‌شود تا عملیات آموزش و تست صورت بگیرد تا در نهایت بتوانیم با دادن داده‌های تست به طبقه بند پیش بینی کنیم که هر حرکت مربوط به کدام کلاس می‌باشد. بدین منظور در این پایان نامه از سه طبقه بند شبکه عصبی مصنوعی^۲، ماشین بردار پشتیبان^۳ و نزدیکترین همسایه^۴ استفاده کرده ایم و به صورت مجزا نتایج با هر یک از سه طبقه بند مورد ارزیابی قرار گرفته است. با توجه به اینکه

¹ Principal Component Analysis

² Artificial neural network

³ Support Vector Machine

⁴ K nearest neighbors

ده داوطلب در این آزمایش شرکت کرده اند و از طرفی ده حرکت مختلف از انگشتان دست را تعریف کردیم و از هر حرکت شش مرتبه ثابت انجام دادیم تعداد کل سیگنال های تک کانال الکترومایوگرام ۶۰۰ سیگنال خواهد بود (۱۰×۱۰×۶۰۰). از مجموع این تعداد سیگنال ۷۰٪ درصد کل داده ها که به صورت اتفاقی انتخاب شده اند را برای آموزش شبکه اختصاص داده ایم که ۴۲۰ سیگنال برای آموزش و ۱۸۰ تای دیگر برای آزمایش استفاده شده است. از طبقه بند شبکه عصبی چند لایه^۱ رو به جلو^۲ که الگوریتم یادگیری و اصلاح وزن ها آن بر مبنای تابع پس انتشار خطا^۳ است، استفاده شده است. برای پیاده سازی شبکه عصبی چند لایه، در لایه ورودی قبل از اعمال PCA و کاهش بعد، ۳۲ نورون و در ۳ لایه مخفی به ترتیب ۵، ۱۰، ۲۰ نورون با توابع فعال ساز تانژانت هیپربولیک و دو سیگموئید استفاده نموده ایم. پارامتر ماکزیمم تعداد تکرار^۴ را برای پیدا کردن کمترین خطای وزن ها برابر ۱۷۰ قرار داده ایم. در این روش کلیه ی مراحل آموزش و آزمایش شبکه با توجه به تابع میانگین مربع خطا^۵ متوقف شده است. به منظور طبقه بندی با استفاده از نزدیک ترین k همسایه هر داده تست در فضای ویژگی فاصله آن با تک تک داده های دیگر سنجیده و سپس با توجه به اینکه کاربر چه مقدار از k را تعریف کرده است نزدیکترین همسایه ها به تعداد k شمارش می شود. بر اساس برچسب همسایه ها مشخص می شود که داده تست متعلق به کدام طبقه می باشد؛ به همین جهت باید یک k بهینه با سعی و خطا بدست آید که نتایج این کار در فصل پنجم با k های مختلف ارائه شده است. به منظور پیاده سازی الگوریتم نزدیکترین k همسایه در متلب باید پارامتر مربوط به تعداد k و توابع مربوط به فاصله تعریف شود که بدین منظور تمامی توابع فاصله: اقلیدسی^۶، ماهالانوبیس^۷، مینکووسکی^۸، همینگ^۹، چبیچو^۱، سیتی بلاک^۲، همبستگی^۳، کساین^۴، جاکارد^۵، سوکلیدین^۶ و اسپیرمن^۷ مورد

¹ Multilayer Perceptron

² Feed Forward

³ Levenberg Marquardt Backpropagation

⁴ Epoch

⁵ Mean Squared error

⁶ Euclidean

⁷ Mahalanobis

⁸ Minkowski

⁹ Hamming

آزمایش قرار گرفت تا بهترین نتیجه حاصل شود. در نهایت برای طبقه بندی با استفاده از ماشین بردار پشتیبان باید یک کرنل^۸ مناسب انتخاب شود تا بتواند ابعاد فضای ویژگی را برای تفکیک بهتر داده ها افزایش دهد. سه کرنل پایه شعاعی^۹، چند جمله ای^{۱۰} و خطی^{۱۱} مورد آزمایش قرار گرفت و برای طبقه بندی با ماشین بردار پشتیبان از کرنل چند جمله ای استفاده شده است.

¹ Chebychev
² Cityblock
³ correlation
⁴ Cosine
⁵ Jaccard
⁶ Seucclidean
⁷ Spearman
⁸ Kernel
⁹ Radial basis function
¹⁰ Polynomial
¹¹ Linear



فصل پنجم

نتایج شبیه سازی و

مقایسه

۵-۱ مقدمه

هدف از ارائه این فصل بررسی و تجزیه و تحلیل نتایج شبیه سازی شده در روش پیشنهادی می باشد. همچنین نتایج در دو حوزه زمان و فرکانس مورد تحلیل قرار گرفته است. در نهایت نتایج با استفاده از سه طبقه بند مختلف با کارهای موجود دیگر مقایسه شده است.

۵-۲ حوزه زمان

در ابتدای امر در این بخش سعی شده است تا نتایج مربوط به کار انجام شده در حوزه زمان ارائه شود. به این معنا که سیگنال های ثبت و جمع آوری شده در حوزه زمان تحلیل و استخراج ویژگی صورت می گیرد و سپس به عنوان ورودی برای تعیین نوع حرکت، داده های آزمایشی به طبقه بند داده می شود.


۵-۲-۱ نتایج شبیه سازی و مقایسه مبتنی بر شبکه عصبی مصنوعی

نتایج ارائه شده حاصل از پیاده سازی در متلب، به پارامترهای مختلفی بستگی دارد. به منظور حاصل شدن بهترین نتیجه باید تمامی این پارامترها مورد ارزیابی و بررسی قرار گیرد. پارامترهایی مختلفی که در این بخش مورد آزمایش قرار گرفته عبارت است از: طول بازه پنجره انتخابی، تعداد ویژگی های خروجی به منظور کاهش ابعاد بردار ویژگی و پارامترهای مورد نیاز برای طراحی شبکه عصبی مانند: تعداد لایه های مخفی و تعداد نورون انتخابی و نوع آموزش شبکه که سعی شده است تمامی نتایج به صورت جدول و نمودار نمایش داده شود. همانطور که در بخش چهارم توضیح داده شده سیگنال های حرکتی با استفاده از ۲ الکتروود از ده نفر (۷ مرد، ۳ زن) جمع آوری شده است. هر شرکت کننده هر حرکت را که شامل خم کردن هر یک از انگشتان تکی، یعنی انگشت شست (T)، انگشت شاخص (I)، انگشت میانه (M)، انگشت حلقه (R)، انگشت کوچک (L) و خم کردن ترکیبی شامل انگشت شست و شاخص (T-I)، انگشت شست و میانه (T-M)، انگشت

شست و حلقه (T-R)، انگشت شست و کوچک (T-L)، و در نهایت بستن دست (HC) می شود را ۶ بار تکرار کرده است (در مجموع ۶۰۰ داده برای هر الکتروود). از هر الکتروود ۱۶ ویژگی در یک پنجره زمانی استخراج شده است (در مجموع ۳۲ ویژگی) که تمامی محاسبات در نرم افزار متلب نسخه ۲۰۱۷ صورت گرفته است. در نهایت ویژگی های استخراج شده از داده های خام به دلیل تفاوت در دامنه سیگنال که از فرد به فرد متفاوت است، بین ۰ و ۱ نرمال شد. در ورودی شبکه، داده ها به صورت ستونی قرار می گیرد، به این ترتیب با احتساب استفاده از تمام ۳۲ ویژگی و استفاده نکردن از تحلیل مولفه اصلی ورودی شبکه ۳۲ خواهد بود، چون ۱۶ ویژگی و دو الکتروود وجود دارد. ۷۰ درصد از کل داده ها به صورت تصادفی برای آموزش شبکه و مابقی برای آزمایش و اعتبارسنجی استفاده می شود. در جدول (۱-۵) و شکل (۱-۵) نتایج حاصل از طبقه بندی برای یک بار اجرا با استفاده از تمام ویژگی ها و طول پنجره ۵۰۰ میلی ثانیه نمایش داده شده است.

جدول ۱-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	99.1667
I	Index	97.5
M	Middle	96.6667
R	Ring	94.1667
L	Little	93.3333
TI	Thumb-Index	96.6667
TM	Thumb-Middle	91.6667
TR	Thumb-Ring	90.8333
TL	Thumb-Little	93.3333
HC	Hand-close	100
Average	All Fingers	95.3333



شکل ۵-۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه


در این مرحله نتایج را با استفاده از پنجره زمانی ۱۰۰، ۲۰۰، ۳۰۰، ۴۰۰، ۵۰۰ میلی ثانیه محاسبه کرده ایم. از طرفی برای هر پنجره زمانی، کد را ۵ بار اجرا می کنیم و از نتایج برای هر حرکت میانگین و انحراف معیار را محاسبه می نمایم تا در نهایت گزارش دقیق تری حاصل شود. نتایج در جدول (۵-۲) نمایش داده شده است.

جدول ۵-۲ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی

دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی						
طول پنجره	600 ms	500 ms	400 ms	300 ms	200 ms	100 ms
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	93.33±1.70	98±1.62	98.2±1.81	97.66±1.98	96±2.96	93.83±2.40
I	94.2±1.92	95.3±2.25	95±2.94	96.7±2.2	93.5±4.69	90.02±2.73
M	92.5±1.82	96.2±0.95	94.83±1.08	96.5±2.85	95.33±2.25	92.2±1.26
R	92.5±2.17	95.2±1.37	95.33±1.72	94.2±5.24	94.5±3.51	92±2.54
L	95±1.67	94.4±2.84	94.66±3.03	94.2±2.64	93.5±1.80	89.8±1.99
TI	91.7±2.48	95.2±2.24	95.66±3.69	94.5±3.15	93.66±2.67	91±2.73
TM	95±1.70	94.67±1.91	95±1.76	94.17±2.88	92.17±1.82	89.17±6.42
TR	95±1.43	95.33±2.52	94.83±1.6	93.66±5.11	87.83±5.73	85.83±2.83
TL	95±1.7	95.37±1.73	96.33±0.95	95.3±2.54	91.83±3.69	87.8±1.92
HC	99.2±0.7	99.21±1.44	98±0.74	98.8±1.12	98±1.26	96.5±1.6
میانگین	94.3±0.92	95.83±0.79	94.77±1.09	94.5±2.4	93.63±1.22	90.8±0.88


با نگاه به شکل (۵-۲) مشاهده می نمایم که هر چه سیگنال را به بازه های بزرگتری تقسیم نمایم میانگین دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی افزایش خواهد یافت. البته باید

به این نکته اشاره کرد برای پردازش های بلادرنگ بهتر است طول پنجره بیشتر از ۳۰۰ میلی ثانیه انتخاب نشود.



شکل ۲-۵ تاثیر طول پنجره زمانی بر دقت طبقه بندی

حال می خواهیم با استفاده از تحلیل مولفه اصلی ویژگی ها را کاهش دهیم و بررسی کنیم که با کاهش ویژگی به چه اندازه دقت طبقه بندی تحت تاثیر قرار خواهد گرفت. بدین منظور با استفاده از پنجره زمانی ۵۰۰ میلی ثانیه دقت را با یکبار اجرا برنامه با تعداد ویژگی های مختلف مورد بررسی قرار دادیم که نتایج در شکل (۳-۵) نمایش داده شده است.



شکل ۳-۵ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از شبکه عصبی

همانطور که در شکل (۳-۵) مشاهده می شود با کاهش ۳۲ ویژگی به ۳ ویژگی دقت کاهش چشمگیری پیدا کرده است. ولی مشاهده می شود که در نقطه ۷ (۷ ویژگی) و نقطه ۱۶ (۱۶ ویژگی) دقت تشخیص نسبت به بالاترین دقت تفاوت چشم گیری ندارد بدین معنی که می توان به جای استفاده از ۳۲ ویژگی با ۱۶ ویژگی تخمین مناسبی از کلاس های حرکتی زد. توجه به این نکته حائز اهمیت است که کاهش تعداد ویژگی تاثیر بسزایی در کاهش هزینه و زمان به خصوص برای آموزش شبکه خواهد داشت. با این حال بسته به کاربرد، کاربر می تواند تصمیم بگیرد که دقت از اهمیت بیشتری برخوردار است و یا هزینه و زمان از ارجحیت بیشتری برخوردار می باشد. با توجه به شکل (۳-۵) و پیدا کردن ۳ نقطه که عمده تغییرات دقت در این نقاط رخ داده است می خواهیم دقت مربوط به هر حرکت را با ۵ بار تکرار برنامه و محاسبه میانگین و انحراف معیار در جدول (۳-۵) نمایش دهیم.

جدول ۳-۵ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۶ ویژگی

دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی			
طول پنجره		500ms	
تعداد ویژگی	3	7	16
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	89.33±2.52	94.16±1.55	97.5±0.58
I	88.5±2.79	90.16±1.98	95.8±1.32
M	80.3±4.55	90.83±2.82	96.8±1.18
R	64.2±2.37	89.50±2.92	94±2.2
L	79.7±4.88	90.66±3.40	95±2.28
TI	80.2±4.5	91.33±2.40	96.5±1.09
TM	83.17±5.18	89.33±3.30	94.67±1.91
TR	87.33±3.40	90.67±1.60	91.83±2.96
TL	88.8±1.62	90.17±2.75	94±1.09
HC	92.5±1.32	95.5±1.82	99±0.7
میانگین	83.4±3.31	91.23±0.68	95.6±0.67

با مقایسه نتایج دو جدول (۴-۵) و (۵-۵) مشاهده می شود که با ۱۶ ویژگی توانسته ایم به دقت مشابه با استفاده از ۳۲ ویژگی دست پیدا کنیم. در واقع هزینه و زمان مورد نیاز به اندازه ۵۰ درصد کاهش پیدا کرده است.

جدول ۴-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	99.1667
I	Index	97.5
M	Middle	96.6667
R	Ring	94.1667
L	Little	93.3333
TI	Thumb-Index	96.6667
TM	Thumb-Middle	91.6667
TR	Thumb-Ring	90.8333
TL	Thumb-Little	93.3333
HC	Hand-close	100
Average	All Fingers	95.3333



جدول ۵-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۱۶ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	97.5±0.58
I	Index	95.8±1.32
M	Middle	96.8±1.18
R	Ring	94±2.2
L	Little	95±2.28
TI	Thumb-Index	96.5±1.09
TM	Thumb-Middle	94.67±1.91
TR	Thumb-Ring	91.83±2.96
TL	Thumb-Little	94±1.09
HC	Hand-close	99±0.7
Average	All Fingers	95.6±0.67



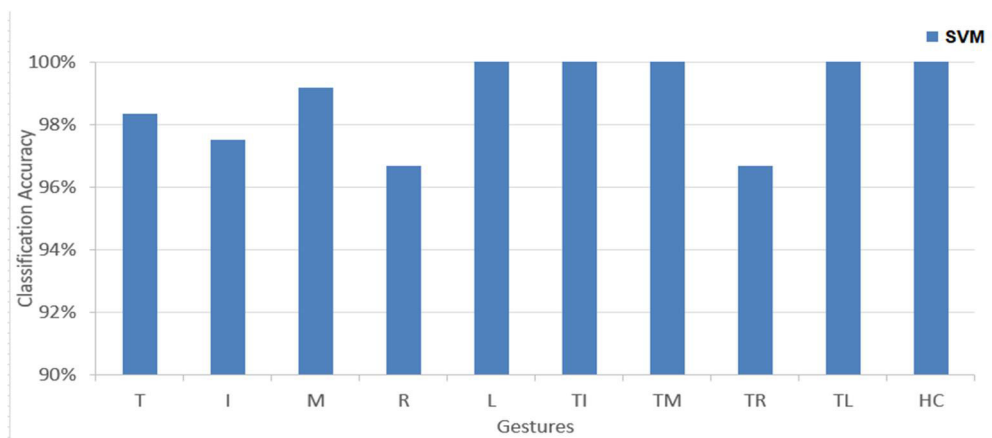
۲-۲-۵ نتایج شبیه سازی و مقایسه مبتنی بر ماشین بردار پشتیبان

همانطور که در بخش (۱-۲-۵) گفته شد پارامترهای مختلفی در دقت و تشخیص یک طبقه بند تاثیر گذار است. بدین منظور در این بخش سعی شده نتایج با استفاده از طبقه بند ماشین بردار پشتیبان مورد ارزیابی قرار بگیرد تا بتوان مقایسه مناسبی بین طبقه بندها انجام داد به همین جهت تمامی پارامترها مانند بخش (۱-۲-۵) انتخاب شده است به جز پارامتری به نام کرنل که در طبقه بند ماشین بردار پشتیبان استفاده می شود که ما در انجام این آزمایش ها از کرنل چند جمله ای^۱ استفاده کرده ایم. در جدول (۶-۵) و شکل (۴-۵) نتایج حاصل از طبقه بندی برای یک بار اجرا با استفاده از تمام ویژگی ها و طول پنجره ۵۰۰ میلی ثانیه نمایش داده شده است.

¹Polynomial

جدول ۵-۶ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	98.33
I	Index	97.5
M	Middle	99.1667
R	Ring	96.6667
L	Little	100
TI	Thumb-Index	100
TM	Thumb-Middle	100
TR	Thumb-Ring	96.6667
TL	Thumb-Little	100
HC	Hand-close	100
Average	All Fingers	98.8333




شکل ۵-۴ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

در این مرحله نتایج را با استفاده از پنجره های زمانی ۱۰۰، ۲۰۰، ۳۰۰، ۴۰۰، ۵۰۰ و ۶۰۰ میلی ثانیه محاسبه کرده ایم. از طرفی برای هر پنجره زمانی، کد را ۵ بار اجرا می کنیم و از نتایج برای هر حرکت میانگین و انحراف معیار را محاسبه می نماییم تا در نهایت گزارش دقیق تری حاصل شود. نتایج در جدول (۵-۷) نمایش داده شده است.

جدول ۵-۷ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی

دقت طبقه بندی با استفاده از ماشین بردار پشتیبان						
طول پنجره	600 ms	500 ms	400 ms	300 ms	200 ms	100 ms
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	99.5±0.45	100±0	99.66±0.45	99.83±0.37	99±0.2	99.16±1.0
I	98.3±1.02	98.8±0.46	98.33±1.31	99.1±0.48	98.16±1.6	98.3±1.18
M	98.5±1.09	99±1.37	98.33±1.31	99.2±1.02	98.83±1.26	98.7±1.26
R	99.3±0.37	99.7±0.75	98.66±1.72	99.7±0.46	100±0	98.7±1.92
L	98.5±0.37	98.8±0.75	99.16±0.83	99.5±0.75	98.16±0.91	98.3±1.32
TI	99.7±0.46	99.8±0.37	99.66±0.45	99.5±0.75	100±0	99.2±0.83
TM	99.17±0.58	99.67±0.745	99.16±1.02	99.5±0.74	99.7±0.41	98.5±1.36
TR	99.66±0.45	100±0	98.83±1.39	99.83±0.37	99.17±0.58	98.66±1.82
TL	99.2±1.18	99.2±0.59	99.33±0.69	99.3±0.91	98.5±1.08	97.7±0.91
HC	99.5±0.75	100±0	99.5±0.74	100±0	99.67±0.45	99.8±0.37
میانگین	99.1±0.36	99.5±0.39	99.3±0.38	99.1±0.3	99.01±0.19	98.7±0.34


با نگاه به شکل (۵-۵) مشاهده می شود که هر چه سیگنال را به بازه های بزرگتری تقسیم نماییم میانگین دقت طبقه بندی با استفاده از ماشین بردار پشتیبان افزایش خواهد یافت و از طرفی افزایش طول پنجره بیشتر از ۵۰۰ میلی ثانیه تغییری محسوسی در افزایش دقت ایجاد نمی کند و یا حتی ممکن است موجب کاهش دقت شود.



شکل ۵-۵ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از ماشین بردار پشتیبان

حال می خواهیم با استفاده از تحلیل مولفه اصلی ویژگی ها را کاهش دهیم و بررسی کنیم که با کاهش ویژگی به چه اندازه دقت طبقه بندی تحت تاثیر قرار خواهد گرفت. بدین منظور با استفاده از

پنجره زمانی ۵۰۰ میلی ثانیه دقت را با یکبار اجرا برنامه با تعداد ویژگی های مختلف مورد بررسی قرار دادیم که در شکل (۵-۶) نمایش داده شده است.



شکل ۵-۶ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از ماشین بردار پشتیبان

همانطور که در شکل (۵-۶) مشاهده می شود با کاهش ۳۲ ویژگی به ۳ ویژگی دقت کاهش چشمگیری پیدا کرده است. ولی مشاهده می شود که در نقطه ۹ (۹ ویژگی) و نقطه ۱۵ (۱۵ ویژگی) دقت تشخیص نسبت به بالاترین دقت تفاوت چشم گیری ندارد بدین معنی که می توان به جای استفاده از ۳۲ ویژگی با ۹ ویژگی تخمین مناسبی از کلاس های حرکتی زد. با توجه به شکل (۵-۶) و پیدا کردن ۳ نقطه آستانه که عمده تغییرات دقت در این نقاط رخ داده است می خواهیم دقت مربوط به هر حرکت را با ۵ بار تکرار برنامه و محاسبه میانگین و انحراف معیار در جدول (۵-۸) نمایش دهیم.

جدول ۵-۸ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۶ ویژگی

دقت طبقه بندی با استفاده از ماشین بردار پشتیبان			
طول پنجره	500ms		
	3	9	15
تعداد ویژگی	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	94.66±5.85	98.16±1.98	99±0.91
I	91.5±4.91	95±2.94	97.3±0.7
M	94±4.54	94.83±1.08	97.8±0.95
R	94.±5.38	96.3±1.72	99.3±0.7
L	92.5±2.64	96.49±1.98	97.7±0.91
TI	96±4.77	98.49±1.7	99.2±1.02
TM	90.83±5.88	97.17±2.17	98.83±0.95
TR	95.83±3.86	96.67±2.35	99.5±0.74
TL	87.3±5.54	97±0.95	99.2±1.02
HC	94.7±3.12	98.5±1.23	99.3±1.49
میانگین	91.1±3.53	96.87±1.54	98.7±0.32

با مقایسه نتایج ۲ جدول (۵-۹) و (۵-۱۰) مشاهده می شود که با ۱۵ ویژگی توانسته ایم به دقت مشابه با استفاده از ۳۲ ویژگی دست پیدا کنیم. در واقع هزینه و زمان مورد نیاز به اندازه ۵۰ درصد کاهش پیدا کرده است.


جدول ۹-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	98.33
I	Index	97.5
M	Middle	99.1667
R	Ring	96.6667
L	Little	100
TI	Thumb-Index	100
TM	Thumb-Middle	100
TR	Thumb-Ring	96.6667
TL	Thumb-Little	100
HC	Hand-close	100
Average	All Fingers	98.8333




جدول ۱۰-۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۱۵ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	99±0.91
I	Index	97.3±0.7
M	Middle	97.8±0.95
R	Ring	99.3±0.7
L	Little	97.7±0.91
TI	Thumb-Index	99.2±1.02
TM	Thumb-Middle	98.83±0.95
TR	Thumb-Ring	99.5±0.74
TL	Thumb-Little	99.2±1.02
HC	Hand-close	99.3±1.49
Average	All Fingers	98±0.32




۵-۲-۳ نتایج شبیه سازی و مقایسه مبتنی بر نزدیکترین k همسایه

در طبقه بند نزدیکترین همسایه علاوه بر پارامترهای بخش (۵-۲-۱) و (۵-۲-۲) که انتخاب شده است انتخاب ۲ پارامتر دیگر در این طبقه بند از اهمیت برخوردار می باشد. انتخاب بهترین k و معیار اندازه گیری فاصله باید در این نوع طبقه بند انتخاب شود. با توجه به اینکه هر داده آزمایش فاصله خود را با تک تک داده های برچسب خورده در فضای ویژگی میسنجد و سپس بر اساس اینکه کدام کلاس بیشترین داده را با کمترین فاصله با داده آزمایش دارد برچسب گذاری می شود. باید با انتخاب k مناسب تعیین نماییم که داده آزمایش فاصله خود را با چه تعداد از نزدیکترین داده های برچسب خورده محاسبه نماید. به همین منظور در ابتدا آزمایشی صورت دادیم تا بتوانیم k مناسب را انتخاب نماییم در این آزمایش به دلیل حجم محاسبات بالا و زمان بر بودن فقط این آزمایش را با بیشترین و کمترین تعداد ویژگی انجام داده ایم و در هر آزمایش از $k=1$ تا $k=15$ را مورد ارزیابی قرار دادیم که شکل (۵-۷) مربوط به یافتن بهترین k با استفاده از ۳ ویژگی و شکل (۵-۸) مربوط به یافتن بهترین k با استفاده از ۳۲ ویژگی می باشد. از بین تمامی توابع فاصله موجود که عبارت است از اقلیدسی، ماهالانوبیس، مینکووسکی، همینگ، چیچو، سیتی بلاک، همبستگی، کساین، جاکارد، سوکلیدین و اسپیرمن از تابع فاصله اقلیدسی استفاده کرده ایم.



شکل ۵-۷ انتخاب k های مختلف جهت کسب بهترین نتیجه برای دقت طبقه بند نزدیکترین همسایه با استفاده از ۳ ویژگی




شکل ۵-۸ انتخاب k های مختلف جهت کسب بهترین نتیجه برای دقت طبقه بند نزدیکترین همسایه با استفاده از ۳۲ ویژگی

با مشاهده شکل ۲ (۷-۵) و (۸-۵) در خواهیم یافت که هم در اجرای کد با ۳۲ ویژگی و هم با اجرای کد با ۳ ویژگی انتخاب پارامتر $K=5$ دارای بالاترین دقت می باشد به همین منظور در آزمایشات بعدی K را برابر با ۵ خواهیم گرفت.

در جدول (۵-۱۱) و شکل (۵-۹) نتایج حاصل از طبقه بندی با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه نمایش داده شده است.

جدول ۵-۱۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	96.6667
I	Index	95
M	Middle	99.1667
R	Ring	99.1667
L	Little	97.5
TI	Thumb-Index	99.1667
TM	Thumb-Middle	98.3333
TR	Thumb-Ring	100
TL	Thumb-Little	98.3333
HC	Hand-close	98.3333
Average	All Fingers	98.1667




شکل ۵-۹ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

در این مرحله مانند بخش (۵-۲-۲) نتایج را با استفاده از پنجره های زمانی ۱۰۰، ۲۰۰، ۳۰۰، ۴۰۰، ۵۰۰ و ۶۰۰ میلی ثانیه محاسبه کرده ایم. از طرفی برای هر پنجره زمانی، کد را ۵ بار اجرا می کنیم و از نتایج برای هر حرکت میانگین و انحراف معیار را محاسبه می نماییم تا در نهایت گزارش دقیق تری حاصل شود. نتایج در جدول (۵-۱۲) نمایش داده شده است.

جدول ۵-۱۲ دقت طبقه بندی با طول پنجره زمانی متفاوت حاصل از ۵ بار اجرای کد با ۳۲ ویژگی


دقت طبقه بندی با استفاده از نزدیکترین همسایه K						
طول پنجره	600 ms	500 ms	400 ms	300 ms	200 ms	100 ms
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	99±0.69	98.66±1.39	99.16±0.58	98.5±0.69	95.83±2.76	95.16±1.60
I	98.3±1.18	97.8±2.01	97±1.62	97.3±1.49	95.33±1.39	93.8±1.92
M	98.5±1.24	98.3±1.67	98.16±1.08	98.7±0.95	96.83±1.80	95.3±1.92
R	98.2±1.37	98.8±0.46	97.83±1.11	99.5±0.75	98.5±0.69	95.3±2.17
L	97.7±2.31	97.8±0.46	96.83±1.60	95.8±1.86	95.16±2.96	93±2.67
TI	97.7±1.81	98.8±1.26	96.5±1.80	98.2±1.24	97.33±1.90	95.5±2.47
TM	98.5±0.69	99±1.08	99.16±0.58	99.17±0.83	99±0.91	96.5±1.70
TR	97.66±1.23	99±0.69	98.67±0.95	98.16±2.07	98.67±1.11	95.83±1.44
TL	98.3±1.32	98.7±0.46	98.67±0.74	97.3±2.6	96.67±1.76	94.8±0.7
HC	99.8±0.37	99.7±0.75	100±0	100±0	99.67±0.74	99.3±0.7
میانگین	98±0.64	98.7±0.55	98.3±0.61	98.2±0.58	97.3±1.05	95.5±0.92

با نگاه به شکل (۵-۱۰) مشاهده می نمایم که هر چه سیگنال را به بازه های بزرگتری تقسیم نمایم میانگین دقت طبقه بندی با استفاده از ماشین بردار پشتیبان افزایش خواهد یافت و از طرفی افزایش طول پنجره بیشتر از ۵۰۰ میلی ثانیه تغییری محسوسی در افزایش دقت ایجاد نمی کند.



شکل ۵-۱۰ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از نزدیکترین همسایه

حال می خواهیم با استفاده از تحلیل مولفه اصلی ویژگی ها را کاهش دهیم و بررسی کنیم که با کاهش ویژگی به چه اندازه دقت طبقه بندی تحت تاثیر قرار خواهد گرفت. بدین منظور با استفاده از پنجره زمانی ۵۰۰ میلی ثانیه دقت را با یکبار اجرا برنامه با تعداد ویژگی های مختلف مورد بررسی قرار دادیم که نتایج در شکل (۵-۱۱) ارائه شده است.



شکل ۵-۱۱ بررسی تعداد ویژگی بر دقت طبقه بندی با استفاده از نزدیکترین همسایه

همانطور که در شکل (۵-۱۱) مشاهده می شود با کاهش ۳۲ ویژگی به ۳ ویژگی دقت کاهش چشمگیری پیدا کرده است. ولی مشاهده می شود که در نقطه ۷ (۷ ویژگی) و نقطه ۱۴ (۱۴ ویژگی) دقت تشخیص نسبت به بالاترین دقت تفاوت چشم گیری ندارد بدین معنی که می توان به جای استفاده از ۳۲ ویژگی با ۷ ویژگی تخمین مناسبی از کلاس های حرکتی زد. با توجه به شکل (۵-۱۱) و پیدا کردن ۳ نقطه آستانه که عمده تغییرات دقت در این نقاط رخ داده است می خواهیم دقت مربوط به هر حرکت را با ۵ بار تکرار برنامه و محاسبه میانگین و انحراف معیار در جدول (۵-۱۳) نمایش دهیم.


جدول ۵-۱۳ دقت طبقه بندی حاصل از ۵ بار اجرای برنامه برای ۱۰ حرکت دست با استفاده از ۳ و ۷ و ۱۴ ویژگی

دقت طبقه بندی با استفاده از نزدیکترین همسایه K			
طول پنجره		500ms	
تعداد ویژگی	3	7	14
انواع حرکات	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
T	95.16±5.67	98±1.91	95.5±1.72
I	94.3±4.01	95.33±3.25	95.2±1.09
M	94.3±4.06	95.16±1.60	97.3±0.91
R	94.7±2.25	96.33±1.72	98.5±0.7
L	94±3.65	95.83±1.76	97.2±1.26
TI	94.7±2.47	97.49±2.04	96.8±0.91
TM	94.83±5.38	96.67±1.55	97.83±0.95
TR	96.33±5.57	96.5±2.15	97.99±1.26
TL	95.8±2.64	96.67±0.58	96.7±0.59
HC	97.8±3.04	98.33±1.02	99.7±0.46
میانگین	90.2±3.76	97.63±1.30	98.3±0.19

با مقایسه نتایج ۲ جدول (۵-۱۴) و (۵-۱۵) مشاهده می شود که با ۱۴ ویژگی توانسته ایم به دقت مشابه با استفاده از ۳۲ ویژگی دست پیدا کنیم. در واقع هزینه و زمان مورد نیاز به اندازه ۵۰ درصد کاهش پیدا کرده است.


جدول ۵-۱۴ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای یک بار اجرا با استفاده از ۳۲ ویژگی و طول پنجره ۵۰۰ میلی ثانیه

Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	96.6667
I	Index	95
M	Middle	99.1667
R	Ring	99.1667
L	Little	97.5
TI	Thumb-Index	99.1667
TM	Thumb-Middle	98.3333
TR	Thumb-Ring	100
TL	Thumb-Little	98.3333
HC	Hand-close	98.3333
Average	All Fingers	98.1667



جدول ۵-۱۵ نتایج حاصل از طبقه بندی ۱۰ حرکت دست با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۱۴ ویژگی و طول پنجره ۵۰۰ میلی ثانیه


Gestures of Control		% Accuracy Level
Index	Gesture	
T	Thumb	95.5±1.72
I	Index	95.2±1.09
M	Middle	97.3±0.91
R	Ring	98.5±0.7
L	Little	97.2±1.26
TI	Thumb-Index	96.8±0.91
TM	Thumb-Middle	97.83±0.95
TR	Thumb-Ring	97.99±1.26
TL	Thumb-Little	96.7±0.59
HC	Hand-close	99.7±0.46
Average	All Fingers	98.3±0.19




برای بدست آوردن تمامی نتایج مربوط به حوزه زمان ۷۶ بار کد برنامه را برای شبکه عصبی، ۷۶ بار برای ماشین بردار پشتیبان و ۱۰۶ بار برای نزدیکترین همسایه k استفاده از کامپیوترهای محاسباتی متعلق به آزمایشگاه دانشکده برق و رباتیک دانشگاه صنعتی شاهرود اجرا نموده ایم.

➤ مقایسه نتایج بین سه طبقه بند مورد استفاده

در شکل (۵-۱۲) و شکل (۵-۱۳) نتایج دقت تشخیص هر ۳ طبقه بند به تفکیک هر حرکت با استفاده از ۳۲ ویژگی و ۳ ویژگی نشان داده شده است. با مشاهده هر دو مشخص می شود که بهترین عملکرد به ترتیب مربوط به ماشین بردار پشتیبان، نزدیکترین همسایه و شبکه عصبی می باشد.



شکل ۵-۱۲ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳۲ ویژگی




شکل ۵-۱۳ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳ ویژگی

۵-۳ حوزه زمان - فرکانس


در این بخش به گزارش و مقایسه نتایج بدست آمده در حوزه زمان- فرکانس خواهیم پرداخت. در پایان می خواهیم نشان دهیم که نتایج حاصل در حوزه زمان-فرکانس می تواند نتایج مطلوبی در برداشته باشد و حتی در مقایسه با نتایج حوزه زمان دارای برتری نسبتا خوبی باشد البته باید به این نکته اشاره کرد که تحلیل در این حوزه دارای چالش هایی می باشد که مهمترین آن افزایش حجم محاسبات خواهد بود که موجب طولانی شدن زمان اجرای برنامه خواهد شد. به همین دلیل این امکان وجود ندارد که مانند حوزه زمان نتایج را به صورت گسترده مورد ارزیابی و مقایسه قرار دهیم.

۵-۳-۱ نتایج شبیه سازی و مقایسه مبتنی بر شبکه عصبی مصنوعی

تمامی پارامترهای تنظیم شده برای اجرای کد مشابه با حوزه زمان می باشد. نتایج را با استفاده از ۳ پنجره زمانی ۱۰۰، ۳۰۰، ۵۰۰ مورد ارزیابی قرار داده ایم تا مشخص شود که انتخاب طول پنجره در حوزه زمان-فرکانس چه تاثیری در نتیجه می تواند داشته باشد. همچنین نتایج را یکبار با استفاده از ۳ و ۳۲ ویژگی مورد ارزیابی قرار داده ایم و در نهایت نتایج را با حوزه زمان مقایسه کرده ایم. در شکل (۵-۱۴) و (۵-۱۵) نتایج حاصل از دقت طبقه بندی با شبکه عصبی مصنوعی با طول پنجره ۱۰۰، ۳۰۰، ۵۰۰، با استفاده از ۳ و ۳۲ ویژگی را نمایش داده ایم.



شکل ۵-۱۴ تاثیر طول پنجره زمانی بر دقت طبقه بندی با استفاده از ۳ ویژگی




شکل ۵-۱۵ تاثیر طول پنجره زمانی بر دقت طبقه بندی با استفاده از ۳۲ ویژگی

با توجه به شکل (۵-۱۴) و (۵-۱۵) مشخص می شود که بر خلاف حوزه زمان، در تحلیل با حوزه زمان - فرکانس کوچک شدن پنجره زمانی نتیجه بهتری را حاصل می کند. اگر چه مشاهده می شود که با کوچک کردن پنجره زمان اجرای برنامه طولانی تر می شود. با توجه به اینکه در حوزه زمان بهترین نتیجه مربوط به پنجره ۵۰۰ ملی ثانیه بود و از طرفی مشخص شد که در حوزه زمان-فرکانس با کوچک انتخاب کردن پنجره دقت افزایش پیدا می کند به همین جهت در جدول (۵-۱۶) به مقایسه حوزه زمان و زمان - فرکانس می پردازیم. در جدول (۵-۱۶) دقت تشخیص هر ۱۰ حرکت با استفاده از طبقه بند شبکه عصبی مصنوعی ارائه شده است که در شکل (۵-۱۶) نتایج را با حوزه زمان مقایسه کرده ایم.

جدول ۵-۱۶ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۳ ویژگی

دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی		
تعداد ویژگی	3	
طول پنجره	100 ms	500 ms
انواع حرکات	زمان-فرکانس	زمان
T	88.66±1.33	89.33±2.52
I	91.16±2.25	88.5±2.79
M	92.83±0.95	80.3±4.55
R	92±0.32	64.2±2.37
L	50.5±1.37	79.7±4.88
TI	65.5±2.84	80.2±4.5
TM	92.83±2.24	83.17±5.18
TR	91.16±2.52	87.33±3.40
TL	92±1.73	88.8±1.62
HC	93.66±1.44	92.5±1.32
میانگین	85.3±1.69	83.4±3.31

با مشاهده جدول (۵-۱۶) خواهیم دید که میانگین دقت تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳ ویژگی در حوزه زمان-فرکانس دارای دقتی بالاتر نسبت به حوزه زمان می باشد.



شکل ۵-۱۶ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی و ۳ ویژگی

با مشاهده شکل (۵-۱۶) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳ ویژگی و طبقه بند شبکه عصبی می باشد مشخص می شود که تحلیل


در حوزه فرکانس نسبت به زمان با استفاده از طبقه بند شبکه عصبی تقریباً در تمامی حرکات به جز ۲ حرکت دارای برتری در دقت تشخیص می باشد.

حال می خواهیم نتایج را با استفاده از ۳۲ ویژگی بین دو حوزه زمان و زمان - فرکانس مقایسه نماییم که در حوزه زمان پنجره ۵۰۰ میلی ثانیه انتخاب شده است و در حوزه زمان - فرکانس پنجره ۱۰۰ میلی ثانیه انتخاب شده و برای هر یک، کد را ۵ بار اجرا نموده و نتایج را در جدول (۵-۱۷) نمایش داده شده است.

جدول ۵-۱۷ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان - فرکانس با استفاده از شبکه عصبی برای ۵ بار اجرا با استفاده از ۳۲ ویژگی

دقت طبقه بندی با استفاده از شبکه عصبی مصنوعی		
تعداد ویژگی	32	
طول پنجره	100 ms	500 ms
انواع حرکات	زمان-فرکانس	زمان
T	93.88±0.95	98±1.62
I	93.18±1.37	95.3±2.25
M	93.22±0.74	96.2±0.95
R	91.75±0.33	95.2±1.37
L	65.36±1.6	94.4±2.84
TI	73.55±0.9	95.2±2.24
TM	93.65±1.08	94.67±1.91
TR	94.91±2.23	95.33±2.52
TL	94.16±1.48	95.37±1.73
HC	94.5±0.83	99.21±1.44
میانگین	88.81±1.22	95.83±0.79

با مشاهده جدول (۵-۱۷) خواهیم دید که میانگین دقت تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳۲ ویژگی در حوزه زمان-فرکانس دارای دقتی کمتر نسبت به حوزه زمان می باشد بدین معنی که استفاده از تعداد ویژگی بیشتر نتیجه بهتری را در حوزه زمان به نسبت حوزه زمان-فرکانس حاصل می کند.



شکل ۵-۱۷ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از شبکه عصبی و ویژگی ۳۲ و ویژگی

با مشاهده شکل (۵-۱۷) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳۲ ویژگی و طبقه بند شبکه عصبی می باشد مشخص می شود که تحلیل در حوزه فرکانس نسبت به زمان با استفاده از طبقه بند شبکه عصبی و ۳۲ ویژگی نتیجه خوبی ندارد و در تمامی حرکت ها به نسبت حوزه زمان دقت پایین تری داشته است.


۵-۳-۲ نتایج شبیه سازی و مقایسه مبتنی بر ماشین بردار پشتیبان

در جدول (۵-۱۸) و شکل (۵-۱۸) نتیجه حاصل از مقایسه زمان و زمان-فرکانس با ۵ بار اجرای کد با استفاده از ۳ ویژگی و پنجره زمانی عرض ۵۰۰ و ۱۰۰ میلی ثانیه مشاهده می شود که طبقه بندی با استفاده از ماشین بردار پشتیبان صورت گرفته است.

جدول ۵-۱۸ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۳ ویژگی

دقت طبقه بندی با استفاده از ماشین بردار پشتیبان		
تعداد ویژگی	3	
طول پنجره	100 ms	500 ms
انواع حرکات	زمان-فرکانس	زمان
T	96.33±1.39	94.66±5.85
I	94.83±2.01	91.5±4.91
M	95.66±1.67	94±4.54
R	96±0.46	94±5.38
L	94.56±0.46	92.5±2.64
TI	78±1.26	96±4.77
TM	93.33±1.08	90.83±5.88
TR	97±0.69	95.83±3.86
TL	78.83±0.46	87.3±5.54
HC	98.3±0.75	94.7±3.12
میانگین	92.28±0.55	91.1±3.53

با مشاهده جدول (۵-۱۸) خواهیم دید که میانگین دقت تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳ ویژگی و طبقه بند ماشین بردار پشتیبان در حوزه فرکانس دارای دقتی بالاتر نسبت به حوزه زمان می باشد.



شکل ۵-۱۸ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان و ۳ ویژگی


با مشاهده شکل (۵-۱۸) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳ ویژگی و طبقه بند ماشین بردار پشتیبان می باشد مشخص می شود که تحلیل در حوزه زمان-فرکانس نسبت به زمان با استفاده از طبقه بند ماشین بردار پشتیبان تقریباً در تمامی حرکات به جز ۲ حرکت دارای برتری در دقت تشخیص می باشد.

حال می خواهیم نتایج را با استفاده از ۳۲ ویژگی و طبقه بند ماشین بردار پشتیبان بین دو حوزه زمان و زمان - فرکانس مقایسه نماییم. برای هر یک از دو حوزه کد را ۵ بار اجرا نموده و نتایج را در جدول (۵-۱۹) نمایش داده شده است.

جدول ۵-۱۹ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان برای ۵ بار اجرا با استفاده از ۳۲ ویژگی

دقت طبقه بندی با استفاده از ماشین بردار پشتیبان		
تعداد ویژگی	32	
طول پنجره	100 ms	500 ms
انواع حرکات	زمان-فرکانس	زمان
T	98.33±0.96	100±0
I	96.42±1.32	98.8±0.46
M	97.72±1.45	99±1.37
R	98.33±0.41	99.7±0.75
L	96.25±2.40	98.8±0.75
TI	88.12±1.77	99.8±0.37
TM	95.41±0.82	99.67±0.75
TR	99±1.23	100±0
TL	88.71±0.79	99.2±0.59
HC	99.5±0.26	100±0
میانگین	95.76±1.14	99.5±0.39

با مشاهده جدول (۵-۱۹) خواهیم دید که میانگین دقت با ماشین بردار پشتیبان برای تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳۲ ویژگی در حوزه زمان-فرکانس دارای دقتی کمتر از حوزه زمان می باشد بدین معنی که استفاده از تعداد ویژگی بیشتر نتیجه بهتری را در حوزه زمان به نسبت حوزه زمان-فرکانس حاصل می کند.



شکل ۵-۱۹ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از ماشین بردار پشتیبان و ویژگی ۳۲

با مشاهده شکل (۵-۱۹) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳۲ ویژگی و طبقه بند ماشین بردار پشتیبان می باشد مشخص می شود که تحلیل در حوزه زمان-فرکانس نسبت به زمان با استفاده از طبقه بند ماشین بردار پشتیبان و ۳۲ ویژگی نتیجه خوبی ندارد و در تمامی حرکت ها به نسبت حوزه زمان دقت پایین تری داشته است.


۳-۳-۵ نتایج شبیه سازی و مقایسه مبتنی بر نزدیکترین k همسایه

در جدول (۵-۲۰) و شکل (۵-۲۰) نتیجه حاصل از مقایسه تحلیل در حوزه زمان و زمان-فرکانس با ۵ بار اجرای کد با استفاده از ۳ ویژگی و پنجره زمانی به عرض ۱۰۰ و ۵۰۰ میلی ثانیه را مشاهده می شود که طبقه بندی با استفاده از نزدیکترین همسایه صورت گرفته است.

جدول ۵-۲۰ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۳ ویژگی

دقت طبقه بندی با استفاده از نزدیکترین همسایه K		
تعداد ویژگی	3	
طول پنجره	100 ms	500 ms
انواع حرکات	زمان-فرکانس	زمان
T	68±0.45	95.16±5.67
I	75.33±1.31	94.3±4.01
M	95.22±1.31	94.3±4.06
R	95.11±1.72	94.7±2.25
L	95.36±0.83	94±3.65
TI	94.55±0.45	94.7±2.47
TM	95.63±1.02	94.83±5.38
TR	97±1.39	96.33±5.57
TL	96.69±0.69	95.8±2.64
HC	97.55±0.74	97.8±3.04
میانگین	91.04±0.38	90.2±3.76

با مشاهده جدول (۵-۲۰) خواهیم دید که میانگین دقت تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳ ویژگی و طبقه بند نزدیکترین همسایه در حوزه زمان-فرکانس دارای دقتی بالاتر نسبت به حوزه زمان می باشد.



شکل ۵-۲۰ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه و ۳ ویژگی


با مشاهده شکل (۵-۲۰) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳ ویژگی و طبقه بند نزدیکترین همسایه می باشد مشخص می شود که تحلیل در حوزه زمان-فرکانس نسبت به زمان با استفاده از طبقه بند نزدیکترین همسایه تقریباً در تمامی حرکات به جز ۳ حرکت دارای برتری در دقت تشخیص می باشد.

حال می خواهیم نتایج را با استفاده از ۳۲ ویژگی و طبقه بند نزدیکترین همسایه بین دو حوزه زمان و زمان - فرکانس مقایسه نماییم. برای هر یک از دو حوزه کد را ۵ بار اجرا نموده و نتایج در جدول (۵-۲۱) نمایش داده شده است.

جدول ۵-۲۱ نتایج حاصل از طبقه بندی ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه برای ۵ بار اجرا با استفاده از ۳۲ ویژگی

دقت طبقه بندی با استفاده از نزدیکترین همسایه K		
تعداد ویژگی	32	
	100 ms	500 ms
طول پنجره	زمان-فرکانس	زمان
انواع حرکات	زمان-فرکانس	زمان
T	77.11±3.25	98.66±1.39
I	82.64±1.12	97.8±2.01
M	96.45±2.31	98.3±1.67
R	96.61±0.75	98.8±0.46
L	96.9±1.40	97.8±0.46
TI	95.23±0.92	98.8±1.26
TM	96.33±1.88	99±1.08
TR	98.6±1.23	99±0.69
TL	95.49±0.79	98.7±0.46
HC	97.66±0.26	99.7±0.75
میانگین	93.32±1.5	98.7±0.55

با مشاهده جدول (۵-۲۱) خواهیم دید که میانگین دقت با نزدیکترین همسایه برای تشخیص ۱۰ حرکت در ۵ بار اجرای کد با استفاده از ۳۲ ویژگی در حوزه زمان-فرکانس دارای دقتی کمتر از حوزه زمان می باشد بدین معنی که استفاده از تعداد ویژگی بیشتر نتیجه بهتری را در حوزه زمان به نسبت حوزه زمان-فرکانس حاصل می کند.



شکل ۵-۲۱ مقایسه نتایج دقت تشخیص ۱۰ حرکت دست در حوزه زمان و زمان-فرکانس با استفاده از نزدیکترین همسایه و ویژگی ۳۲


با مشاهده شکل (۵-۲۱) که مقایسه ای بین دقت تشخیص ۱۰ حرکت دست در دو حوزه زمان و زمان-فرکانس با استفاده از ۳۲ ویژگی و طبقه بند نزدیکترین همسایه می باشد مشخص می شود که تحلیل در حوزه زمان-فرکانس نسبت به زمان با استفاده از طبقه بند نزدیکترین همسایه و ۳۲ ویژگی نتیجه خوبی ندارد و در تمامی حرکت ها به نسبت حوزه زمان دقت پایین تری داشته است.

۵-۳-۴ مقایسه نتایج تحلیل حوزه زمان-فرکانس با استفاده از سه طبقه بند


مورد استفاده

در شکل (۵-۲۲) و (۵-۲۳) نتایج دقت تشخیص هر ۳ طبقه بند به تفکیک هر حرکت با استفاده از ۳ و ۳۲ ویژگی نشان داده شده است. با مشاهده این مقایسه مشخص می شود که بهترین عملکرد به ترتیب مربوط به ماشین بردار پشتیبان، نزدیکترین همسایه و شبکه عصبی می باشد. نکته مهمی که بعد از این نتایج بدست می آید این است که در هر ۳ طبقه بند نتایج حاصل در حوزه زمان-فرکانس دارای انحراف معیار کمتری می باشد به این معنی که در هر بار اجرای کد دقتی که حاصل می شود برای هر حرکت دارای اختلاف کمتری با اجرای بعدی می باشد در صورتی که با مشاهده نتایج حوزه زمان مشخص می شود انحراف معیار به نسبت حوزه زمان-فرکانس بالاتر می باشد. از طرفی نتایج نشان می دهد که با استفاده از ۳۲ ویژگی حوزه زمان از نتیجه بهتری برخوردار

است و در طرف مقابل با استفاده از ۳ ویژگی حوزه زمان-فرکانس نتیجه بهتری در مقابل حوزه زمان دارد.



شکل ۵-۲۲ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳ ویژگی در حوزه زمان-فرکانس



شکل ۵-۲۳ مقایسه دقت بین هر سه طبقه بند نزدیکترین همسایه k ، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ۳۲ ویژگی در حوزه زمان-فرکانس

در این قسمت سعی داریم تا نتایج روش پیشنهادی را با کارهای موجود انجام شده در قالب یک جدول (۵-۱۹) بر اساس پارامترهای مهم و تاثیر گذار مقایسه نماییم که سطر اول جدول مربوط به روش پیشنهادی است.

مرجع	سال	تعداد الکتروود	تعداد حرکات	تعداد داوطلب	نوع حرکت	تعداد ویژگی	حوزه	طبقه بند	میانگین صحت
SM	۲۰۱۸	۲	۱۰	۱۰	انگشت	۳	TF	SVM	٪۹۲/۲۸±۰/۵۵
								T	SVM
[۳۲]	۲۰	نامعلوم	۶	۵	دست	۱	T	KNN	٪۸۶/۷۱
[۳۵]	۲۰	نامعلوم	۵	۱۰	دست	نامعلوم	T	KNN	٪۸۹/۵
[۳۳]	۲۰۱	<	۶	۸	انگشت	۱	T	APNN	٪۹۲/۲
[۲۲]	۲۰	≥	۸	۵	دست	۴	T	NB	٪۹۰/۱۸۱۸
[۲۳]	۲۰۱	>	۲	نامعلوم	دست	۷	T	SVM	٪۶۲
[۲۴]	۲۰۱	>	۵	۸	نامعلوم	دست	F	CNN	٪۹۲/۸
[۲۶]	۲۰۱	>	۲	۸	دست	۵	TF	ANN	٪۷۷/۵
[۲۷]	۲۰۱	>	نامعلوم	۷	دست	۳	T	NFIA	٪۹۱/۴۳
[۳۰]	۲۰۱	>	۲	۶	دست	۲۱	TF	ANN	٪۸۶/۷
[۳۱]	۲۰۱	>	۸	۵	دست	نامعلوم	T	KNN	٪۸۶
[۴]	۲۰۱	>	۸	۶	دست	۶	T	SDE	٪۸۳/۳۳
[۱۶]	۲۰۱۷	۸+۵	۲۱	۳۰	دست انگشت	۵۰	T	KNN	٪۹۶/۰۵
[۱۹]	۲۰۱	>	نامعلوم	۶	دست	۱	T	KNN	٪۸۷/۸۷
[۱۸]	۲۰۱	>	۳	۴	دست	۷	T	ANN	٪۹۸
[۸۳]	۲۰۱	۹	۲	۸	دست	۱۶	T	ANN	٪۸۱/۲
[۸۴]	۲۰۱	۹	۳	۹	انگشت	۷	T	ANN	٪≈۹۳
[۸۵]	۲۰۱	۹	۴	۳	دست	۹	T	نامعلوم	٪۹۷-۹۳
[۸۶]	۲۰۱	۹	۸	۵	دست	۲۱	T	SVM	٪۹۲

[۸۷]	۲-۵	۱۶	۹	۱۳	دست	۲	T	ANN	% ۸۳/۴۳
[۸۸]	۲-۶	۸	۶	۱۰	دست	۱	TF	ANN	% ۹۲/۵۸
[۸۹]	۲-۳	۲	۶	۶	دست	۸	T	LDA	% ۷۴/۳۴
[۹۰]	۲-۳	۵	۱۰	۸	دست	۹	T	FGMM	% ۹۶/۰۷

جدول ۲۲-۵ مقایسه روش پیشنهادی با کارهای انجام شده



فصل ششم

نتیجه گیری و پیشنهاد

راهکارهای آینده

۶-۱ مقدمه

در این پایان نامه، رویکرد جدیدی را برای تشخیص ده حرکت تکی و ترکیبی انگشتان دست در حوزه فرکانس با استفاده از تبدیل S پیشنهاد داده ایم. به منظور اجرای روش پیشنهادی از پایگاه داده آقای رامی کوشایاب [۲۳] استفاده شده است. در ابتدا پیش پردازش های لازم را به منظور حذف نویز بر روی سیگنال های ثبت شده اعمال کرده ایم سپس سیگنال را به زیر فریم هایی تقسیم کرده و تبدیل S را بر روی هر یک از زیر فریم ها اعمال نموده ایم و سپس ۳۲ ویژگی را از سیگنال استخراج نموده ایم. به منظور کم شدن حجم داده ها از الگوریتم تحلیل مولفه اصلی برای کاهش ویژگی ها استفاده شده است و در نهایت بردار های ویژگی را در هر بار آزمایش به ۳ طبقه بند شبکه عصبی، ماشین بردار پشتیبان و نزدیکترین همسایه داده ایم.

۶-۲ نتیجه گیری

با بررسی نتایج شبیه سازی ارائه شده در فصل چهارم که به تفکیک با استفاده از سه طبقه بند در حوزه زمان و فرکانس صورت گرفت مزایا و معایب هر یک از دو حوزه تحلیل مشخص شد. به صورت کلی در دقت تشخیص حرکات واردی وجود دارد که در هر دو حوزه نقش بسیار به سزایی ایفا می کند. در ابتدا مهمترین عامل، ثبت سیگنال الکترومایوگرام می باشد که اولاً باید در محیط غیر نویزی صورت گیرد و دوماً نکاتی که در هنگام ثبت سیگنال مهم است، رعایت شود در غیر اینصورت از ابتدای امر سیگنال های ثبت شده با نویز خواهند بود که این امر سبب می شود دقت مناسبی در تشخیص حاصل نشود. بعد از رعایت این نکته باید نویز های غیر ارادی که در بدن وجود دارد مثل فعالیت های قلب و ماهیچه را که می تواند روی سیگنال ما تاثیر گذار باشد با شناخت از محدوده ی فرکانسی فعالیت آنها، با استفاده از فیلتر حذف نماییم. نکته مهم دیگری که در ثبت سیگنال دارای اهمیت است استفاده از تعداد الکتروود برای ثبت سیگنال می باشد که هر چه از تعداد بیشتری الکتروود استفاده نماییم دقت به در حالت کلی افزایش پیدا خواهد یافت و در مقابل، متحمل هزینه هایی

خواهیم شد. بعد از این موارد مهمترین مرحله که تاثیر بسیار زیادی در نتیجه می تواند حاصل کند انتخاب ویژگی های مناسب در مرحله استخراج ویژگی می باشد.

بالاترین میانگین دقت بدست آمده در حوزه زمان با استفاده از طبقه بند ماشین بردار پشتیبان حاصل شد که برای تشخیص ۱۰ حرکت ترکیبی و تکی انگشتان با استفاده از ۳۲ ویژگی به میانگین دقتی نزدیک به $99/5 \pm 0/39$ درصد دست پیدا کردیم که مشخص شد می توانیم با استفاده از تحلیل مولفه اصلی این تعداد ویژگی را به ۱۵ برسانیم تا حجم محاسبات به اندازه ۵۰ درصد کاهش یابد و دقت تشخیص هم کاهش چشمگیری پیدا نکند. از طرفی نشان دادیم که انتخاب پنجره های زمانی برای تقسیم سیگنال می تواند در نتیجه ما تاثیر گذار باشد طوری که با بزرگ کردن این پنجره تا ۵۰۰ میلی ثانیه دقت افزایش پیدا خواهد کرد و با بزرگتر کردن پنجره به بیش از ۵۰۰ میلی ثانیه در دقت تفاوت چشمگیری حاصل نشود و یا حتی در مواردی دقت کاهش هم پیدا کند. با کاهش تعداد ویژگی ها به سه ویژگی مشخص شد که تحلیل در حوزه زمان نتایج پایداری را در هر بار اجرای برنامه برای ما حاصل نمی کند به طوری که دقت حاصل از پنج بار اجرای کد با استفاده از سه ویژگی دقتی برابر با میانگین $91/1 \pm 3/53$ درصد را برای ما حاصل کرد که انحراف معیار در کمترین حالت برای حرکت خم کردن انگشت کوچک (L) برابر با $2/64$ و در بیشترین حالت مربوط به حرکت ترکیبی انگشت شست و میانه (TM) برابر با $5/88$ می باشد که این نتایج با این اختلاف مطلوب نمی باشد که البته با استفاده از ۳۲ ویژگی این مشکل حاصل نمیشد. در طرف مقابل با استفاده از روش پیشنهادی و تحلیل در حوزه فرکانس با استفاده از تبدیل S مشخص شد که دقت تشخیص تا حدودی نسبت به حوزه زمان افزایش پیدا می کند و بهترین نتیجه هم مانند حوزه زمان با استفاده از طبقه بند ماشین بردار پشتیبان حاصل می شود که به میانگین دقت $92/28 \pm 0/55$ درصد با استفاده از سه ویژگی دست یافته ایم. یکی دیگر از مزایای تحلیل در حوزه زمان - فرکانس پایداری در دقت تشخیص می باشد به طوری که در ۵ بار اجرای کد انحراف معیار در کمترین حالت برای دو حرکت خم کردن انگشت حلقه (R) و انگشت کوچک (L) برابر با $0/46$ و در بیشترین حالت مربوط به حرکت

انگشت اشاره برابر با ۲/۰۱ می باشد. اولاً این نتایج نشان می دهد میانگین دقت تشخیص حرکات در حوزه فرکانس نسبت به زمان نتیجه بهتری دارد دوماً در هر بار اجرای کد دقت بدست آمده دارای انحراف معیار کمتری می باشد. البته باید به این نکته اشاره کرد که تحلیل در حوزه فرکانس به نسبت حوزه زمان حجم محاسباتی و زمانی بسیار بیشتری را صرف می نماید.

۳-۶ پیشنهاد راه کارهای آینده

در طی اجرای روش پیشنهادی عوامل متعددی بر روی نتایج بدست آمده تاثیر گذار بودند. که در بخش ۲-۶ به آن ها اشاره شد. در ادامه بر اساس تاثیر این عوامل راه کار هایی ارائه شده که ممکن است برای ادامه ی این کار مفید باشد.

- روش های متفاوتی برای استخراج ویژگی از سیگنال های حیاتی وجود دارد که با بررسی بیشتر آن ها می توان به نتایج بهتری دست یافت به همین منظور می توان از الگوریتم ژنتیک در مرحله استخراج ویژگی استفاده نمود تا بهترین نتایج حاصل شود.
- با مشاهده نتایج ارائه شده در فصل چهارم دیدیم که با ترکیب نتایج حوزه زمان و فرکانس می توان بهترین نتایج را حاصل کرد. بنابراین پیشنهاد می شود در مورد ترکیب این دو حوزه کار بیشتری انجام شود.
- با توجه به اینکه طبقه بندی همچون شبکه عصبی دارای نقطه ضعف مینیمم محلی در بروزرسانی خطای شبکه و وزن های شبکه می باشد می توان از الگوریتم بهینه سازی ازدحام ذرات^۱ استفاده کرد تا نتایج مطلوب تری حاصل شود. همانطور که در این پایان نامه از ۳ طبقه بند مختلف به منظور طبقه بندی استفاده شد و نشان دادیم که هر طبقه بند می تواند

¹ Particle Swarm Optimization

نتایج متفاوتی حاصل کند به همین منظور می توان از طبقه بند های دیگری همچون نیو

بیزین^۱ یا مدل مخفی مارکوف^۲ و و یا از روش ترکیب طبقه بندها در آینده استفاده نمود.

¹ Naïve Bayesian

² Hidden Markov Model

مراجع

- [۱] حجازی م، (۱۳۹۵) ، پایان نامه ارشد: " کنترل یک ربات پوشیدنی بالاتنه دو درجه آزادی فعال با استفاده از سیگنال الکترومایوگرافی"، دانشگاه صنعتی شریف.
- [۲] عطا الله ع، (۱۳۸۴) ، پایان نامه ارشد: " شبیه سازی سیگنال الکترومایوگرام سطحی انگشتان دست"، دانشگاه صنعتی شریف.
- [3] R. Reiter, "Eine neu elektrokonstand," Grenzgebiete der Medicin, vol. 1, no. 4, pp. 133-135, 1948.
- [4] JH. Lyman, A. Freedy, R. Prior, "Fundamental and applied research related to the design and development of upper-limb externally powered prostheses," Bulletin of Prosthetics Research, pp. 184-195, Spring 1976.
- [5] Hudgins, B. Parker, P. Scott, "A new strategy for multifunction myoelectric control," IEEE Transactions on Biomedical Engineering, vol. 40, no. 1, pp. 82-94, Jan. 1993.
- [6] J. Alexander, (2008), M.Sc. thesis, "Finger Movement Classification Using Forearm EMG Signals", Electrical and Computer Engineering. Depart. Queen's University,
- [7] Y. Assaf, "Surface myoelectric signal analysis: dynamic approaches for change detection and classification," IEEE Transactions on Biomedical Engineering, vol. 53, no. 11, pp. 2248-2256, Nov. 2006.
- [8] G. Tsenov, A. Zeghib, F. Palis, N. Shoylev, V. Mladenov, "Neural networks for online classification of hand and finger movements using surface EMG signals," 8th Seminar on Neural Network Applications in Electrical Engineering (NEUREL 2006), pp. 167-171, Sep. 2006.
- [9] K. Nazarpour, A. Sharafat, S. Firoozabadi, "Application of higher order statistics to surface electromyogram signal classification," IEEE Transactions on Biomedical Engineering, vol. 54, no. 10, pp. 1762-1769, Oct. 2007.
- [10] K. Englehart, B. Hudgins, "A robust, real-time control scheme for multifunction myoelectric control," IEEE Transactions on Biomedical Engineering, vol. 50, no. 7, pp. 848-854, Jul. 2003.
- [11] R. Stockwell, L. Mansinha, R. Lowe, "Localization of the complex spectrum: the Stransform," IEEE Trans. Signal Process. 44(4), 998-1001 (1996)
- [12] B. Hudgins, P. Parker, R. Scott, "A new strategy for multifunction myoelectric control", IEEE transactions on biomedical engineering, Vol. 40, No. 1, 1993
- [13] D. Sijiang, "Feature Extraction for classification of Prehensile EMG Patterns", MS thesis, Fall 2003
- [14] K. Rami, S. Kodagoda, M. Takruri, G. Dissanayake, "Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals," ELSEVIER Expert Systems with Applications, Vol. 39, No.12, pp.10731-10738, 2012.
- [15] C. Pylatiuk, S. Schulz, L. Döderlein. "Results of an Internet survey of myoelectric prosthetic hand users," Prosthetics and orthotics international, 2007, 31(4): 362-370.

- [16] B. Wan, W. Rongrong, Z. Kaihuo , L. Lanxin , “A new subtle hand gestures recognition algorithm based on EMG and FSR,” IEEE 21st International Conference on Computer Supported Cooperative Work in Design, Vol. 978, No.1, pp.5090-6199, October. 2017, Wellington, New Zealand.
- [17] T. Cover , “Rates of convergence for nearest neighbor procedures,”.Hawaii International Conference on System Sciences. 1968.
- [18] M. Fonseca, G. Conceição, E. Simas Filho, “Artificial neural networks applied to the classification of hand gestures using eletromyographic signals,” IEEE Robotics Symposium (LARS) and Brazilian Symposium on Robotics (SBR), Vol. ,pp..2017, Curitiba, Brazil.
- [19] S. Zahin, C. Shahnaz, G. Rosul, “Basic Hand Action Classification Based on SurfaceEMG Using Autoregressive Reflection Coefficient,” IEEE Region 10 Conference, TENCON, Vol. ,pp.2017, Penang, Malaysia.
- [20] C. Sapsanis, G. Georgoulas, D. Lymberopoulos, “Improving EMG based Classification of basic hand movements using EMD”, in proc. 35th Annual International Conference of the IEEE EMBS,pp. 5754 – 5757, Osaka, Japan, 2013.
- [21] C. Sapsanis, G. Georgoulas, D. Lymberopoulos, “Improving EMG based Classification of basic hand movements using EMD”, in proc. 35th Annual International Conference of the IEEE EMBS,pp. 5754 – 5757, Osaka, Japan, 2013.
- [22] A. Falih, A. Dharma, S. Sumpeno, “Classification of EMG Signals From Forearm Muscles As Automatic Control Using Naive Baye,” IEEE International Seminar on Intelligent Technology and Its Applications, Vol. 978, No.1 ,pp. 5386-270.2017, Surabaya, Indonesia.
- [23] Y. Paul, V. Goyal, R. Jaswal, “Comparative Analysis between SVM & KNN Classifier for EMG Signal Classification on Elementary Time Domain Features,” 4th IEEE International Conference on Signal Processing, Computing and Control, september,2017, Solan, India.
- [24] Y. Yamanoi, R. Kato, “ Control method for myoelectric hand using convolutional neural network to simplify learning of EMG signals “ 2017 IEEE International Conference on Cyborg and Bionic Systems ,October. 2017, Beijing, China.
- [25] A. Orjuela, A. Ruíz, L. Forero, “ Deep neural network for EMG signal classification of wrist position: Preliminary results,” 2017 IEEE Latin American Conference on Computational Intelligence, February. 2018, Arequipa, Peru.
- [26] M. Arozi, F. Putri, M. Ariyanto, W. Caesarendra, “ Electromyography (EMG) Signal Recognition Using Combined Discrete Wavelet Transform Based on Artificial Neural Network (ANN), “IEEE 2nd International Conference of Industrial, Mechanical, Electrical, Chemical Engineering, April. 2017, Yogyakarta, Indonesia.
- [27] W. Caesarendra, T. Tjahjowidodo, D. Pamungkas, “EMG based classification of hand gestures using PCA and ANFIS, “IEEE International Conference on Robotics, Biomimetics, and Intelligent Computational Systems, December. 2017, Bali, Indonesia.
- [28] W. Caesarendra, M. Irfan, “Classification Method of Hand Gestures based on Support Vector Machine”, In: Proc. Of International Conference on Informatics, Robotics, Network, Control and Systems (IRONCONS), 23-25 Nov 2016.

- [29] H. Chen, Y. Zhang, Z. Zhang, Y. Fang, "Exploring the relation between EMG sampling frequency and hand motion recognition accuracy," 2017 IEEE International Conference on Systems, Man, and Cybernetics, December. 2017, Banff, AB, Canada.
- [30] A. Kukker, R. Sharma, H. Malik, "Forearm movements classification of EMG signals using Hilbert Huang transform and artificial neural networks," IEEE 7th Power India International Conference ,October. 2017, Bikaner, India.
- [31] M. Benalcázar, A. Jaramillo, J. Zea, A. Andaluz, "Hand gesture recognition using machine learning and the Myo armband,"IEEE 25th European Signal Processing Conference, October. 2017, Kos, Greece.
- [32] O. Iqbal, S. Fattah, S. Zahin, "Hand movement recognition based on singular value decomposition of surface EMG signal,"IEEE IEEE Region 10 Humanitarian Technology Conference, February. 2018, Dhaka, Bangladesh.
- [33] J. Fu, L. Xiong, X. Song, Z. Yan, Y. Xie, "Identification of finger movements from forearm surface EMG using an augmented probabilistic neural network," IEEE/SICE International Symposium on System Integration , February. 2018, Taipei, Taiwan.
- [34] C. Pylatiuk , S. Schulz , L. Döderlein, "Results of an Internet survey of myoelectric prosthetic hand users[J]. *Prosthetics and orthotics international*, 2007, 31(4): 362-370.
- [35] M. Benalcázar, C. Motoche, J. Zea, A. Jaramillo, C. Anchundia, P. Zambrano, M. Segura, F. Palacios, M. Pérez, "Real-time hand gesture recognition using the Myo armband and muscle activity detection,"IEEE Second Ecuador Technical Chapters Meeting (ETCM), January. 2018, Salinas, Ecuador
- [36] N.M. Major, M.D. Malinzak, "Musculoskeletal Anatomy," Elsevier,2011.
- [37] K. Murphy, "Machine Learning: a Probabilistic Perspective," MIT Press, 2013.
- [38] M. Müller, "Information Retrieval for Music and Motion," Springer, 2007.
- [39] A. Jaramillo, M. Benalcázar, "Real-time hand gesture recognition with EMG using machine learning,"IEEE Second Ecuador Technical Chapters Meeting (ETCM), January. 2018, Salinas, Ecuador.
- [40] DF. Stegeman, JH. Blok, Hj. Hermens, K. Roeleveld, "Surface emg models: properties and applications," *Journal of Electromyography and Kinesiology*, vol. 10, no. 5, pp. 313–326, 2000.
- [41] H. Huang, T. Li, C. Bruschini, C. Enz, V. M. Koch, J. Justiz, C. Antfolk, "Emg pattern recognition using decomposition techniques for constructing multiclass classifiers," in *Biomedical Robotics and Biomechatronics (BioRob)*, 2016 6th IEEE International Conference on. Ieee, 2016, pp. 1296–1301.
- [42] C. Savur, F. Sahin, "Real-time american sign language recognition system using surface emg signal," in *Machine Learning and Applications (ICMLA)*, 2015 IEEE 14th International Conference on. IEEE, 2015, pp. 497–502.
- [43] M. Rossi, S. Benatti, E. Farella, L. Benini, "Hybrid emg classifier based on hmm and svm for hand gesture recognition in prosthetics," in *Industrial Technology (ICIT)*, 2015 IEEE International Conference on. IEEE, 2015, pp. 1700–1705.
- [44] N. Stifani, "Motor neurons and the generation of spinal motor neuron diversity," *Frontiers in cellular neuroscience*, vol. 8, 2014.

- [45] A. Bhattacharya, A. Sarkar, P. Basak, "Time domain multi-feature extraction and classification of human hand movements using surface EMG," IEEE 4th International Conference on Advanced Computing and Communication Systems (ICACCS), August. 2017, Coimbatore, India.
- [46] G. Li et al., "Selection of sampling rate for EMG pattern recognition based prosthesis control," in Proc. 32nd Annu. Int. Conf. IEEE EMBS, Buenos Aires, Argentina, 2010, pp. 5058-5061.
- [47] C. J. De Luca. (2002, Aug. 13). Fundamental concepts in EMG signal acquisition [Online]. Available: http://www.delsys.com/Attachments_pdf/WP_Sampling1-4.pdf
- [48] S. Day. (2002, Oct. 18). Important factors in surface EMG measurement [Online]. Available: <http://www.bortec.ca/pages/resources.htm>
- [49] D. R. Ankrum, "Questions to ask when interpreting surface electromyography (SEMG) research," in Proc. Human Factors Ergonomics Soc. Annu. Meeting., San Diego, CA, 2000, pp. 530-533.
- [50] C. J. Miller, "Real-time feature extraction and classification of prehensile EMG," M.S. thesis, Dept. Comp. Sci., San Diego State Univ., CA, 2008.
- [51] S. Ventosa, C. Simon, M. Schimmel, J.J. Dañobeitia, A. Manuel, The S-transform from a wavelet point of view. IEEE Trans. Signal Process. 56(7), 2771–2780 (2008)
- [52] C.R. Pinnegar, L. Mansinha, The S-transform with windows of arbitrary and varying shape. Geophysics 68(1), 381–385 (2003).
- [53] L. Masinha, R.G. Stockwell, R.P. Lowe, Pattern analysis with two-dimensional spectral localization: applications of two dimensional S-transforms. Phys. A 239, 286–295 (1997)
- [54] S. Assous, B. Boashash, "Evaluation of the modified S-transform for time-frequency synchrony analysis and source localization" EURASIP J. Adv. Signal Process. 2012(49), 1–18 (2012)
- [55] P.K. Dash, K.B. Panigrahi, G. Panda, Power quality analysis using S-transform. IEEE Trans. Power Deliv. 18(2), 406–411 (2003)
- [56] P.D. McFadden, J.G. Cook, L.M. Forster, Decomposition of gear vibration signals by the generalised S-transform. Mech. Syst. Signal Process. 13(5), 691–707 (1999)
- [57] F. Xu, W. Zhou, Y. Zhen, Q. Yuan, Classification of ECoG with modified S-transform for brain-computer interface. J. Comput. Inf. Syst. 10(18), 8029–8041 (2014)
- [58] C.C. Huang, S.F. Liang, M.S. Young, F.Z. Shaw, A novel application of the S-transform in removing powerline interference from biomedical signals. Physiol.Meas. 30(1), 13–27 (2009)
- [59] S. Parolai, Denoising of seismograms using the S-transform. Bull. Seismol. Soc. Am. 99(1), 226–234 (2009)
- [60] G. Livanos, N. Ranganathan, J. Jiang, Heart sound analysis using the S-transform. Proceedings IEEE Comput. Cardiol. 27, 587–590 (2000)
- [61] R. Ditommaso, M. Mucciarelli, F.C. Ponzio, S-transform based filter applied to the analysis of non-linear dynamic behaviour of soil and buildings, in Proceedings of the 14th European Conference on Earthquake Engineering, vol. 30 (2010), pp. 1–8
- [62] K.A. Jones, B. Porjesz, D. Chorlian, M. Rangaswamy, C. Kamarajan, A. Padmanabhapillai, H. Begleiter, S-transform time-frequency analysis of p300 reveals deficits in individuals diagnosed with alcoholism. Clin. Neurophysiol. 117(10), 2128–2143 (2006)

- [63] Y. Wang, J. Orchard, On the use of the Stockwell transform for image compression Proc. IS&T/SPIE Electron. Imaging, 724504 (2009)
- [64] R. Merletti, P. Parker. Electromyography: physiology, engineering, and non-invasive applications. John Wiley & Sons; 2004 Jul 26
- [65] H. Mizuno, N. Tsujiuchi, and T. Koizumi, "Forearm motion discrimination technique using real-time emg signals," in Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE. IEEE, 2011, pp. 4435–4438.
- [66] RH. Chowdhury, M. Reaz, A. Bakar, K. Chellappan, T. Chang. Surface electromyography signal processing and classification techniques. Sensors. 2013 Sep 17;13(9):12431-66.
- [67] Bigliassi, Marcelo, P. Rogério, T. Ferreira, T. Abrão, A. Moraes, L. Ricardo. "Fourier and Wavelet Spectral Analysis of EMG Signals in 1-km Cycling Time-Trial." Applied Mathematics 2014 (2014).
- [68] Camata, V. Thiago, L. José. Dantas, T. Abrão, M. Brunetto, C. Antonio, R. Leandro. "Fourier and wavelet spectral analysis of EMG signals in supramaximal constant load dynamic exercise." In Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE, pp. 1364-1367. IEEE, 2010
- [69] Kumar, D. Kant, D. Nemeul, A. Bradley. "Wavelet analysis of surface electromyography." Neural Systems and Rehabilitation Engineering, IEEE Transactions on 11, no. 4 (2003): 400-406.
- [70] Cifrek, Mario, V. Medved, S. Tonković, S. Ostojić. "Surface EMG based muscle fatigue evaluation in biomechanics." Clinical Biomechanics 24, no. 4 (2009): 327 340.
- [71] E. Spyropoulos, E. Chroni, G. Athanassiou. "Muscle Fatigue Estimation in Repetitive Lifting Task Using Surface Electromyography-Based Analysis. ." Neural Systems and Rehabilitation Engineering, IEEE Transactions on 11, no. 5 (2015): 2165-7556.
- [72] Kamaruddin, N. Asyikin, P. Khalid, A. Shaameri. "The Use of Surface Electromyography in Muscle Fatigue Assessments—A Review." Jurnal Teknologi 74, no. 6 (2015).
- [73] Croce, Ronald, J. Miller, K. Chamberlin, D. Filipovic, W. Smith. "Wavelet analysis of quadriceps power spectra and amplitude under varying levels of contraction intensity and velocity." Muscle & nerve 50, no. 5 (2014): 844-853
- [74] Moshou, Dimitrios, I. Hostens, G. Papaioannou, H. Ramon. "Dynamic muscle fatigue detection using self-organizing maps." Applied Soft Computing 5, no. 4 (2005): 391-398.
- [75] Peñailillo, Luis, R. Silvestre, K. Nosaka. "Changes in surface EMG assessed by discrete wavelet transform during maximal isometric voluntary contractions following supramaximal cycling." European journal of applied physiology 113, no. 4 (2013): 895-904.
- [76] Chowdhury, S. Kanti, D. Ashish, Nimbarte. "Comparison of Fourier and wavelet analysis for fatigue assessment during repetitive dynamic exertion." Journal of Electromyography and Kinesiology 25, no. 2 (2015): 205-213.
- [77] D. Gordedn, E. Roberstsn, "Electromyography processing ", University of ottawa, Canada.
- [78] Farrell, T. R., & Weir, R. F. (2007). The optimal controller delay for myoelectric prostheses. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 15(1), 111–118.

- [79] A. Andrews, E. Morin, L. Mclean, "Optimal electrode configurations for finger movement classification using EMG". In Proceedings of the 31st annual international conference of the IEEE EMBS (pp. 2987–2990).
- [80] TR. Farrell, (2007). Multifunctional prosthesis control: The effects of targeting surface vs. intramuscular electrodes on classification accuracy and the effect of controller delay on prosthesis performance. Ph.D. Thesis. Northwestern University.
- [81] H. Mizuno, N. Tsujiuchi, T. Koizumi, "Forearm motion discrimination technique using real-time emg signals," in Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE, 2011, pp. 4435–4438.
- [82] A. Phinyomark, P. Phukpattaranont, "Feature reduction and selection for EMG signal classification," Elsevier Transactions on Expert Systems with Applications, Vol. 39, No.8, pp.7420-7431, June. 2012.
- [83] C. Wahyu, L. Syahara, M. Khusnul, W. Andri, W. Augie, (2016) "A Classification Method of Hand EMG Signals Based on Principal Component Analysis and Artificial Neural Network", International Conference on Instrumentation, Control and Automation (ICA), 22-27, Bandung, Indonesia.
- [84] H. Mohd, C. Pavan, R. Venkata, (2015) "EMG signal based finger movement recognition for prosthetic hand control", Communication, Control and Intelligent Systems (CCIS), 194-198, Mathura, India.
- [85] J. Mosarrat, Munish , B. Bharat, G. Babu , (2015) "Feature extraction and pattern recognition of EMG-based signal for hand movements", International Symposium on Advanced Computing and Communication (ISACC), Silchar, India.
- [86] C. Carolina, P. Carlos, C. Julian, (2016) "Individual hand motion classification through EMG pattern recognition: supervise and unsupervised methods", XXI Symposium on Signal Processing, Images and Artificial Vision (STSIVA), 1-6, Bucaramanga, Colombia.
- [87] A. Rocio, H. Stephen, M. Shawn, (2016) "Performance analysis of two ANN based classifiers for EMG signals to identify hand motions", SoutheastCon 2016, Norfolk, VA, USA.
- [88] M. Pla, G. Muñoz, S. Gutiérrez, D. Louis, (2014) "Hand movement classification using transient state analysis of surface multichannel EMG signal", Pan American Health Care Exchanges (PAHCE), Brasilia, Brazil.
- [89] S. Christos, G. George, T. Anthony, L. Dimitrios, (2013) "Improving EMG based classification of basic hand movements using EMD", 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 5754-5757, Osaka, Japan.
- [90] J. Zhaojie, O. Gaoxiang, W. Marzena, L. Honghai, "Surface EMG Based Hand Manipulation Identification Via Nonlinear Feature Extraction and Classification" IEEE Sensors Journal, Volume: 13, Issue: 9, pp 3302 – 3311.2013.

Abstract

Many previously lost opportunities for individuals who have suffered from different forms of amputation or were, in fact, born with a congenital physical impairment, such as the ability to work or pursue a chosen way of life, can be somewhat restored using artificial prostheses. In addition, the electromyography control system can be considered as the major component in a wide range of modern prostheses, this system utilizes Electromyogram (EMG) signals, stemmed from the individual's muscles in order to control and also change the position of the prosthesis. Although numerous research has been conducted in this field involving the detection and the restoration of functional hand movement, few studies have indeed investigated this concept in the detection of single and combined movements of fingers.

As a result, the purpose of the study in this dissertation was to develop an optimal approach for Electromyography signals classification of various single and combined movements of fingers. A considerable part of this thesis therefore meticulously examines the detection of single and combined movements of fingers using surface EMG signals, such that the positions of robotic hand's fingers can be fully controlled in response to these signals.

In addition, the number of electrodes play a crucial role in the signal accumulation and also the classification accuracy. In other words, the more electrodes used, the higher the movement classification accuracy, while on the other hand, operating costs can evidently increase. Thus, we made a conscious effort to achieve the highest possible accuracy while utilizing the minimum number of electrodes. Therefore, two EMG electrodes, located on the forearm, were employed to collect EMG data from ten participants. In order to ensure maximum detection capability with respect to the different finger movements, a collection of various features in two domains of time and time-frequency was extracted. It should be noted that Stockwell transform was incorporated so as to analyze the time-frequency domain. In order to diminish the computational costs and unnecessary dimensions in the analysis, Principal Component Analysis (PCA) algorithm was utilized to reduce the number of features such that the classification accuracy level remains rather constant. Finally, three algorithms of Artificial Neural Network (ANN), Support Vector Machines (SVM) and k-Nearest Neighbors (KNN) were implemented to classify the obtained data and also determine the movement classifications. Practical results and statistical tests revealed that the suggested method, with an average accuracy of 92.28 ± 0.55 , was, in fact, able to adequately classify various finger movements. Moreover, compared to other studies, more than satisfactory results were achieved which essentially show the significance of our proposed method.

Keywords: Electromyogram Signal, Feature Extraction, Time-Frequency Domain, Stockwell Transform, Classification.



Faculty of Electrical and Robotics Engineering
M.Sc. Thesis in Communication Systems Engineering

Hand motion classification based on time-frequency analysis of sEMG

By:

Pooria Sharifi

Supervisor:

Dr. Hadi Grailu

September 2018