

## Evaluation of Surface Electromyogram Signal Decomposition Methods in the Design of Hand Movement Recognition System

Maryam Karimi<sup>1,2</sup>, M.Sc., Mahdi Khezri<sup>1,2</sup>, Assistant Professor

<sup>1</sup> Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran

<sup>2</sup> Digital Processing and Machine Vision Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran

m.karami4141@gmail.com, mahdi.khezri@pel.iaun.ac.ir

### Abstract

One method for determining motor commands to control hand prostheses is to use surface electromyogram (sEMG) signal patterns. Due to the random and non-stationary nature of the signal, the idea of using signal information in small time intervals was investigated. In this study, with the aim of more accurate and faster detection of hand movements, two signal decomposition methods, namely discrete wavelet transform (DWT) and empirical mode decomposition (EMD) were evaluated. The sEMG signals of the Ninapro-DB1 dataset, which were extracted from 27 healthy subjects while performing hand and finger movements, were used to design the system. Simple time domain features with fast calculation capability were extracted for each subband of the decomposed signals. Also, support vector machine (SVM) using different kernel functions was applied as a classifier. The results show that the use of DWT and EMD methods with the ability to access the information of time and frequency sub-intervals of the signals, provides better results in identifying hand movements compared to previous studies. With the EMD method and eight intrinsic mode functions (IMF), the highest recognition accuracy of 83.3% was obtained for six movements. Also, the DWT with the Bior5.5 mother wavelet and five levels of decomposition, achieved 80% recognition accuracy for ten movements and with the Coif2 mother wavelet and six levels of decomposition, the accuracy was 83.33% for eight movements. The results show the better performance of the DWT decomposition method compared to EMD for the design of the hand movement recognition system using sEMG signal patterns.

**Keywords:** discrete wavelet decomposition, empirical mode decomposition, hand prosthesis, support vector machine, surface electromyogram signals

**Received:** 4 August 2022

**Revised:** 24 November 2022

**Accepted:** 1 December 2022

**Corresponding Author:** Dr. Mahdi Khezri

**Citation:** M. Karimi, M. Khezri, "Evaluation of surface electromyogram signal decomposition methods in the design of hand movement recognition system", Journal of Intelligent Procedures in Electrical Technology, vol. 15, no. 59, pp. 81-94, December 2024 (in Persian).

<https://dorl.net/dor/20.1001.1.23223871.1403.15.59.8.1>

مقاله پژوهشی

## ارزیابی روش‌های تجزیه سیگنال الکترومیوگرام سطحی در طراحی سیستم تشخیص حرکت‌های دست

مریم کرمی<sup>۱\*</sup>، دانش‌آموخته کارشناسی ارشد، مهدی خضری<sup>۱،۲</sup>، استادیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

m.karami4141@gmail.com, mahdi.khezri@pel.iaun.ac.ir

**چکیده:** یک روش برای تعیین فرمان‌های حرکتی برای کنترل پروتزهای دست، استفاده از الگوهای سیگنال الکترومیوگرام سطحی (sEMG) است. با توجه به ماهیت تصادفی و غیرایستای سیگنال، ایده استفاده از اطلاعات سیگنال در بازه‌های زمانی کوچک مورد بررسی قرار گرفت. در این مطالعه با هدف تشخیص دقیق‌تر و سریع‌تر حرکت‌های دست، دو روش تجزیه سیگنال شامل تبدیل موجک گسسته (DWT) و تجزیه مد تجربی (EMD) ارزیابی شده‌اند. سیگنال‌های مجموعه داده نیناپرو DB1 که از ۲۷ فرد سالم در حین انجام حرکت‌های دست و انگشتان استخراج شده‌اند، برای طراحی سیستم به کار رفته است. ویژگی‌های زمانی ساده با قابلیت محاسبه سریع برای هر زیرباند از سیگنال‌های تجزیه شده به کار گرفته شدند. همچنین ماشین بردار پشتیبان (SVM) با استفاده از توابع کرنل مختلف به عنوان طبقه‌بندی‌کننده مورد استفاده قرار گرفت. نتایج به دست آمده نشان می‌دهد، استفاده از روش‌های تبدیل موجک گسسته و تجزیه مد تجربی با قابلیت دسترسی به اطلاعات زیربازه‌های زمانی و فرکانسی سیگنال‌ها، نتایج بهتری در شناسایی حرکت‌های دست در مقایسه با مطالعات گذشته ارائه می‌کند. با روش تجزیه مد تجربی و تعداد هشت تابع مد ذاتی، بالاترین دقت تشخیص با مقدار  $83/3$  درصد برای شش حرکت به دست آمد. همچنین روش تبدیل موجک گسسته با مادر بای‌ارتوگونال  $5/5$  در پنج سطح تجزیه، دقت تشخیص  $80$  درصد را برای ده حرکت و با موجک مادر کویفلت ۲ در شش سطح تجزیه، دقت  $83/33$  درصد را برای شناسایی هشت حرکت کسب کرد. نتایج به دست آمده عملکرد بهتر روش تجزیه موجک در مقایسه با تجزیه مد تجربی را برای طراحی سیستم شناسایی حرکت‌های دست با استفاده از الگوهای سیگنال الکترومیوگرام سطحی نشان می‌دهد.

**کلمات کلیدی:** تجزیه موجک، تجزیه مد تجربی، دست مصنوعی، سیگنال الکترومیوگرام سطحی، ماشین بردار پشتیبان

تاریخ ارسال مقاله: ۱۴۰۱/۵/۱۳

تاریخ بازنگری مقاله: ۱۴۰۱/۹/۳

تاریخ پذیرش مقاله: ۱۴۰۱/۹/۱۰

نام نویسنده‌ی مسئول: دکتر مهدی خضری

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

## ۱- مقدمه

استفاده از اندام‌های مصنوعی<sup>۱</sup> هوشمند مانند دست و پای مصنوعی برای افرادی که دچار قطع عضو هستند، با توجه به این‌که می‌تواند بسیاری از فرصت‌های زندگی و شغلی را به آن‌ها بازگرداند، در سال‌های اخیر بسیار مورد توجه قرار گرفته است. در طراحی اندام‌های مصنوعی هوشمند، الگوهای فعالیت عضلات که به‌عنوان سیگنال الکترومیوگرام<sup>۲</sup> (EMG) از آن‌ها یاد می‌شود، به کار گرفته می‌شوند. در واقع با توجه به این‌که در حرکت‌های مختلف، سیگنال‌های EMG تولید شده توسط عضله ویژگی‌های منحصر به فردی دارند، به ما کمک می‌کند که با استفاده از اطلاعات کسب شده از سیگنال در یک سیستم تشخیص الگو بتوان نوع حرکت مدنظر را شناسایی و کنترل نمود. سیگنال EMG به‌صورت غیرتهاجمی (از طریق قراردادن الکترودهای سطحی بر روی عضله که به آن الکترومیوگرام سطحی<sup>۳</sup> (sEMG) گفته می‌شود) و یا به‌صورت تهاجمی (از طریق وارد کردن الکترودهای سوزنی به عضله مورد نظر) قابل ثبت و اندازه‌گیری است [۱، ۲]. از مزیت‌های الکترودهای سطحی می‌توان به راحتی فرد، عدم ایجاد جراحت در عضله، قابلیت تکرار بیشتر ثبت و مناسب بودن برای کاربردهای حرکتی، اشاره کرد. اما عیب الکترودهای سطحی این است که ناحیه آشکارسازی آن‌ها وسیع بوده و لذا پتانسیل‌هایی از عضلات کناری نیز ثبت می‌کنند. به‌علاوه، این الکترودها تنها برای عضلات سطحی کاربرد دارند [۳، ۴].

در این مطالعه، هدف طراحی سیستم تشخیص حرکت‌های دست با دقت مطلوب خواهد بود. به‌منظور تشخیص و طبقه‌بندی حرکت‌های دست با استفاده از سیگنال sEMG مطالعات متعددی صورت گرفته است. در همه این مطالعات، هدف افزایش نوع و تعداد حرکت‌های شناسایی شده و در واقع افزایش درجات آزادی دست در کنار کاهش پیچیدگی و زمان پاسخ‌دهی بوده است. در مرجع [۵] با استفاده از حسگرهای اندازه‌گیری اینرسی<sup>۴</sup> (IMU) و سیگنال EMG، یک روش تشخیص حرکت‌های پویا از حرکت‌های ایستا، پیشنهاد شده است. برای طراحی سیستم، از ویژگی‌های زمانی سیگنال EMG شامل مقادیر دامنه پایه، جمع مقادیر دامنه، جمع وزنی مقادیر دامنه و واریانس سیگنال استفاده شده و نتایج نشان می‌دهند که در نظر گرفتن حالت‌هایی که تنها شامل حرکت‌های بازو هستند، کمترین خطا توسط حسگر IMU به‌دست می‌آید. همچنین با ترکیب دو حسگر (EMG+IMU) بهترین عملکرد در شناسایی حرکت‌ها به‌دست آمد.

در مرجع [۶] با استفاده از دو کانال سیگنال EMG که بر روی عضلات خم‌کننده و بازکننده ساعد قرار داده شده، چهار حرکت دست با استفاده از ماشین بردار پشتیبان<sup>۵</sup> (SVM) شناسایی و طبقه‌بندی شده‌اند.

در مرجع [۷]، از سیگنال‌های sEMG پایگاه داده TeleMyob2400 G2 مربوط به ۵ زن و ۵ مرد، با نرخ نمونه‌برداری ۱۵۰۰ هرتز استفاده شده است. در این مطالعه از افراد شرکت‌کننده در آزمایش خواسته شد که شش حرکت مختلف دست را به تناوب و مداوم برای بیش از دو ساعت انجام دهند. به‌منظور انطباق با تغییرات تدریجی در ویژگی‌های sEMG، از شبکه عصبی موجک<sup>۶</sup> (WNN) به‌عنوان طبقه‌بند و روش یادگیری همبستگی منفی<sup>۷</sup> (NCL) برای آموزش آن استفاده شد. WNN یک شبکه عصبی جدید است که حاصل ترکیب تجزیه موجک و شبکه عصبی پس انتشار<sup>۸</sup> است. از تابع موجک مورلت<sup>۹</sup> به‌عنوان تابع فعال‌ساز در شبکه WNN، استفاده شد. پس از استخراج ویژگی، سطوح مختلف تجزیه با انواع موجک مادر<sup>۱۰</sup> مورد بررسی قرار گرفت. در سطح پنجم با موجک‌مادر کویفلت<sup>۱۱</sup> بالاترین دقت تشخیص برابر با ۹۶ درصد به‌دست آمد. با استفاده از روش پیشنهادی، حتی پس از یک دوره زمانی طولانی، نرخ میانگین دقت طبقه‌بندی شش حرکت دست در هشت آزمایش به میزان ۹۲/۱۷ درصد رسید. نتایج تجربی نشان داد که روش پیشنهادی به‌طور قابل توجهی میزان صحت طبقه‌بندی حرکت‌های دست را بهبود بخشیده است. در مرجع [۸] عملکرد SVM در طبقه‌بندی سیگنال EMG و شناسایی ده حرکت دست بررسی شده است. به این منظور سیگنال‌ها از یک پایگاه داده که شامل اطلاعات حرکتی هشت فرد سالم (دو زن و شش مرد) بود، انتخاب شدند. سیگنال‌های EMG به پنجره‌های هم‌اندازه و مناسب بخش‌بندی شدند و ویژگی‌های حوزه زمان همچون میانگین قدرمطلق<sup>۱۲</sup> (MAV)، جذر میانگین مربعات<sup>۱۳</sup> (RMS)، مقدار متوسط یکپارچه<sup>۱۴</sup> (IAV)، طول موج<sup>۱۵</sup> (WL) و مدل خودبازگشتی<sup>۱۶</sup> (AR) مرتبه چهارم، برای هر بخش تعیین شدند. ویژگی‌های استخراج شده پس از کاهش ابعاد با روش تحلیل مولفه‌های اصلی<sup>۱۷</sup> (PCA) توسط طبقه‌بند SVM، طبقه‌بندی شدند. دقت طبقه‌بندی حرکت‌های انگشت در کل افراد ۹۱/۴۰ درصد به‌دست آمد. اعتبارسنجی‌ها

نشان داد که طبقه‌بند SVM می‌تواند، سیگنال‌های EMG را به درستی با نرخ طبقه‌بندی بالاتر برای طراحی دست مصنوعی طبقه‌بندی کند.

در مطالعه دیگری، با استفاده از یک تجزیه و تحلیل آماری ابتکاری، چهار طبقه‌بندی کننده مختلف: رگرسیون لجستیک غیرخطی<sup>۱۸</sup> (NLR)، پرسپترون چند لایه<sup>۱۹</sup> (MLP)، SVM و آنالیز تفکیک خطی<sup>۲۰</sup> (LDA) برای شناسایی حرکت‌های دست مقایسه شدند [۹]. داده‌های sEMG از ۳۰ فرد دچار قطع عضو با حسگرهایی که روی دست آن‌ها قرار داشت، در حین انجام ۵ حرکت به تناوب جمع آوری شدند. تجزیه و تحلیل آماری براساس آزمون ویلکسون-رانک انجام و اهمیت آماری p کمتر ۰/۰۵ در نظر گرفته شد. دقت‌های تشخیص به دست آمده توسط SVM دارای بالاترین مقادیر و پس از آن MLP و سپس روش NLR قرار داشتند. برای بررسی بهترین عملکرد از نظر دقت شناسایی و پیچیدگی محاسباتی، شاخص بهینه‌سازی عامل<sup>۲۱</sup> (EOF) ارایه شد. نتایج نشان داد برای افرادی که دچار قطع عضو هستند و دارای سیگنال‌های EMG با ورودی بیش از پنج هزار هرتز هستند، بهترین طبقه‌بند، NLR (دارای بالاترین شاخص EOF) است که نتایج نزدیکی با MLP دارد. این نتیجه همچنین با تجزیه و تحلیل مقایسه‌ای LDA با ویژگی‌های حوزه زمان تأیید کرد، که MLP از نظر آماری تفاوت معنی‌داری با NLR نشان نمی‌دهد. تجزیه و تحلیل‌های پیشنهادی در این مطالعه، در چگونگی انتخاب مناسب‌ترین طبقه‌بند و نتایج مطلوب برای کنترل پروتز به ما کمک می‌کند. در مرجع [۱۰] از داده‌های نیناپرو DB-4 مربوط به ۱۰ فرد سالم برای شناسایی حرکت‌های دست استفاده شده و با هدف بررسی تأثیر طول پنجره سیگنال، روش‌هایی برای تشخیص نوع عضله و رمزگشایی گسسته سیگنال‌های EMG گذرا استفاده شده است. به منظور تجزیه سیگنال از روش تجزیه مد تجربی<sup>۲۲</sup> (EMD) و جهت استخراج ویژگی از ویژگی MAV و همچنین به منظور کسب بالاترین دقت، نتایج سه طبقه‌بند SVM، LDA و نزدیکترین همسایه<sup>۲۳</sup> (KNN) مورد بررسی قرار گرفتند. در این بین طبقه‌بند SVM با میزان ۹۱/۶۷ درصد بالاترین دقت را ارایه کرد. همچنین نتایج نشان داد که سیگنال EMG با چگالی نمونه‌های بالا برای رمزگشایی سیگنال EMG گذرا، مناسب‌تر است و افزایش طول پنجره مجموعه آموزشی می‌تواند دقت رمزگشایی را بهبود بخشد.

در مرجع [۱۱] روشی برای طبقه‌بندی سیگنال‌های EMG سطحی حرکت‌های دست براساس شبکه عصبی کانولوشن<sup>۲۴</sup> (CNN) و روش انباشتگی یادگیری گروهی<sup>۲۵</sup> پیشنهاد شده است. هدف از طراحی این روش جلوگیری از حذف ویژگی‌های مفید بود. در این روش، از دو طبقه‌بند استفاده شده است. روش طبقه‌بندی اول مبتنی بر CNN برای استخراج ویژگی‌های سیگنال‌های sEMG طراحی شد که از حذف اطلاعات ویژگی‌های مهم جلوگیری می‌کند. همچنین روش طبقه‌بندی دوم از ادغام سه طبقه‌بند اولیه براساس روش یادگیری انباشتگی برای بهبود بیشتر دقت طبقه‌بندی حرکت‌های دست، طراحی شد. چندین آزمایش بر روی مجموعه داده‌های نیناپرو DB5 برای ارزیابی مدل‌های پیشنهادی انجام شد. در این پژوهش به منظور تجزیه سیگنال از روش تبدیل موجک گسسته استفاده شد. سرانجام مشاهده شد وقتی در مرحله پنجره‌گذاری طول پنجره ۲۰۰ میلی ثانیه باشد، بهترین دقت طبقه‌بند اولیه و طبقه‌بند ثانویه به ترتیب ۷۰/۹۲ درصد و ۷۲/۰۹ درصد به دست می‌آید. در طول پنجره ۳۰۰ میلی‌متر، بهترین دقت طبقه‌بند اولیه و طبقه‌بند ثانویه به ترتیب ۷۵/۰۲ درصد و ۷۶/۰۲ درصد به دست می‌آید. سرانجام، نتایج مدل طراحی شده با نتایج دقت طبقه‌بندهای مشابه همچون LDA، حافظه کوتاه و بلند مدت شبکه عصبی کانولوشن<sup>۲۶</sup> (LCNN) و SVM مقایسه شد. در شرایط یکسان، میانگین دقت مدل طبقه‌بند پیشنهادی به ترتیب ۱۱/۵ درصد، ۱۳/۶ درصد و ۱۰/۱ درصد بالاتر از طبقه‌بندهای LDA، SVM و LCNN به دست آمد. در مرجع [۱۲] از سیگنال‌های EMG با چگالی بالا<sup>۲۷</sup> (HD-EMG) برای شناسایی حرکت‌های دست استفاده شده است. آرایه‌ای شامل ۶۰ الکتروود برای ثبت سیگنال‌های ۱۰ عضله دست به کار گرفته شدند. ویژگی‌های حوزه زمان و همچنین ویژگی‌های زمانی-مکانی برای سیگنال‌ها محاسبه شدند و برای آموزش طبقه‌بند ماشین بردار پشتیبان مکعبی<sup>۲۸</sup> ((CSVM) به کار گرفته شدند. سیگنال‌ها از پنج فرد در حین انجام ده حرکت ثبت شدند. حرکت‌های مورد نظر به طور مطلوب توسط روش پیشنهادی طبقه‌بندی شدند. میانگین دقت کسب شده برای همه شرکت‌کنندگان به طور مشخص با وضوح مکانی یعنی تعداد کانال‌های استفاده شده سیگنال EMG مرتبط بود. با استفاده از تعداد پنج کانال سیگنال، دقت ۴±۷۴ درصد به دست آمد که با افزایش تعداد کانال‌ها به ۴۱ کانال دقت تشخیص حرکت‌ها تا ۹۲±۲ افزایش یافت. در مرجع [۱۳] امکان تشخیص حرکت‌های دست با استفاده از سیگنال‌های EMG ثبت شده در مچ دست ارزیابی شده است. مقایسه

مستقیم سیگنال‌ها و اطلاعات به دست آمده از مچ دست و ساعد که به طور همزمان ثبت شدند، انجام می‌شود. هر دو سیگنال به طور همزمان از ۲۱ فرد جمع‌آوری شدند، در حالی که آن‌ها مجموعه‌ای از ۱۷ حرکت که شامل حرکت‌های مختلف تک انگشتی و چند انگشتی و حرکت‌های مچ بود را انجام دادند. سیگنال‌های EMG مچ دست به طور مشخص معیارهای کیفیت سیگنال بالاتری را (p کمتر از ۰/۰۵) نسبت به سیگنال‌های ساعد برای حرکت‌های ظریف ارائه می‌کردند، در حالی که کیفیت قابل مقایسه‌ای را برای حرکت‌های مچ حفظ می‌کردند. همچنین عملکرد هر دو نوع ویژگی‌های زمانی (میانگین قدر مطلق دامنه، واریانس، عبور از صفر، آنتروپی نمونه و ...) و فرکانسی (فرکانس میانگین، فرکانس میانه، فرکانس پیک، ممان طیفی اول، دوم و سوم، توان کل و ...) سیگنال EMG هنگام استفاده از سیگنال‌های مچ برای حرکت‌های تک انگشتی و چند انگشتی به طور قابل توجهی بهتر و برای حرکت‌های مچ قابل مقایسه بود. در طراحی سیستم شناسایی حرکت‌های دست، روش‌های جستجوی شناور ترتیبی رو به جلو<sup>۲۹</sup> (SFFS) و PCA به ترتیب برای انتخاب و نگاشت ویژگی‌ها به کار گرفته شدند. همچنین روش‌های LDA و SVM به عنوان طبقه‌بندی کننده مورد استفاده قرار گرفتند. بهترین نتایج کسب شده توسط طبقه‌بندی کننده‌ای که با سیگنال-های EMG مچ آموزش داده شده بود، بیانگر میانگین دقت ۹۲/۱ درصد برای حرکت‌های تک انگشتی، ۹۱/۲ درصد برای حرکت‌های چند انگشتی و ۹۴/۷ درصد برای حرکت‌های مچ بود.

اگرچه در پژوهش‌های اخیر، تلاش‌های فراوانی برای بهبود کارایی دست‌های مصنوعی انجام شده است ولی هنوز تا وضعیت مطلوب که دستیابی به یک پروتز کارآمد و کاربرپسند است، راهی طولانی پیش رو است. به منظور بهبود کیفیت زندگی افراد دچار قطع عضو، تشخیص الگوی سیگنال sEMG، با اهداف افزایش دقت تشخیص و شناسایی سریع و افزایش تعداد حرکت‌های تشخیص داده شده، صورت می‌گیرد. در مطالعه حاضر به منظور نیل به اهداف ذکر شده، استفاده از تحلیل‌های زمان-فرکانس مورد توجه قرار گرفته است. دستیابی به اطلاعات زمانی و فرکانسی سیگنال sEMG با تولید اطلاعات کاملتر در هر حرکت، می‌تواند در افزایش دقت تشخیص حرکت‌های و تفکیک پذیری تعداد بیشتری از حرکت‌ها مؤثر باشد. بدین منظور روش‌های تجزیه موجک<sup>۳۰</sup> (WT) و تجزیه مد تجربی در این مطالعه مورد توجه قرار گرفته‌اند. این روش‌ها در واقع سیگنال‌ها را بر اساس قواعد معینی به بازه‌های زمانی و زیرباند‌های فرکانسی مشخص تجزیه می‌کنند. به این ترتیب تعیین می‌شود که در هر لحظه، کدام مؤلفه‌های فرکانسی و با چه شدتی در سیگنال موجود هستند. با استفاده از روش‌های ذکر شده و تجزیه سیگنال‌ها در حوزه زمان و فرکانس، ویژگی‌های زمانی و فرکانسی برای آن‌ها محاسبه می‌شوند. ویژگی‌های استخراج شده سپس با اعمال به یک واحد طبقه‌بندی در تشخیص حرکت‌های مختلف دست به کار برده می‌شوند. عملکرد دو روش تجزیه WT و EMD در بهبود عملکرد سیستم یعنی افزایش دقت تشخیص و تعداد حرکت‌های قابل شناسایی، مورد ارزیابی قرار می‌گیرد.

## ۲- روش تحقیق

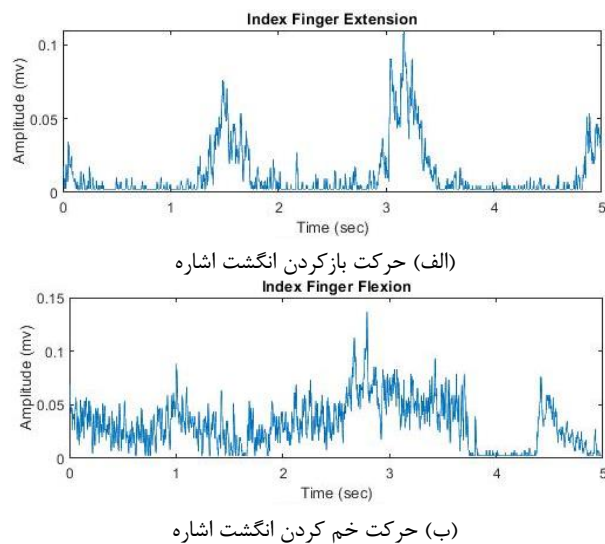
### ۲-۱- داده‌های استفاده شده

در این مطالعه از سیگنال‌های sEMG مجموعه داده نیناپرو (DB1) استفاده شده است. در ثبت سیگنال‌های این مجموعه داده، ۲۷ فرد سالم (۲۰ مرد و ۷ زن) با میانگین سنی ۲۵ تا ۳۱ شرکت کرده‌اند. در آزمایش از افراد خواسته شده ۵۲ حرکت را با انگشتان دست خود انجام دهند. سیگنال‌های sEMG این مجموعه داده با استفاده از ۱۰ الکتروود سطحی و با فرکانس نمونه‌برداری ۲ کیلوهرتز ثبت شده‌اند. افراد باید ۵۲ حرکت را مطابق با تصاویری که بر روی صفحه لپ‌تاپ نشان داده می‌شد، ده بار تکرار می‌کردند. مدت زمان تکرار هر حرکت ۵ ثانیه و پس از آن ۳ ثانیه استراحت بود. ۵۲ حرکت این آزمایش به سه گروه تقسیم شده‌اند که عبارتند از: الف- دوازده حرکت مربوط به حرکت‌های اساسی (خم کردن و باز کردن) انگشتان، ب- هفده حرکت مربوط به حرکت‌های ایزومتریک و ایزوتونیک انگشتان و حرکت‌های اساسی (خم کردن و باز کردن) مچ دست و ج- بیست و سه حرکت مربوط به درک انگشتان نسبت به لمس اجسام. در این مطالعه از داده‌های حاصل از تمرین اول یعنی حرکت‌های اساسی انگشتان دست مطابق با شکل (۱)، استفاده شده است [۱۴]. همچنین نمونه‌ای از سیگنال‌های مورد استفاده که از شرکت کننده اول برای دو حرکت خم کردن و باز کردن انگشت اشاره ثبت شده، در شکل (۲) نمایش داده شده است.



شکل (۱): نمونه حرکتهای مجموعه داده نیناپرو [۱۴]

Figure (1): Example of Ninapro-DB1 data set movements [14], a) Exercise A, b) Exercise B, c) Exercise C



شکل (۲): نمونه‌ای از سیگنال‌های EMG ثبت شده از نفر اول برای حرکتهای انگشت اشاره

Figure (2): An example of the recorded signals from the first subject for index finger, a) Extension movements, b) Flexion movements

برای کاهش تداخل‌ها و نویزهای موجود در سیگنال‌های فیزیولوژیکی و از جمله سیگنال sEMG می‌توان از روش‌های فیلترینگ استفاده کرد. اصلی‌ترین کار فیلترها، جداسازی مؤلفه‌های فرکانسی سیگنال‌ها و حذف نویز است. با توجه به وجود انواع نویزها بر روی سیگنال‌های sEMG مانند نویز آرتیفکت‌های حرکتی، نویز تجهیزات الکترومغناطیسی، نویز برق شهر و اثرات تداخلی، در مرحله فیلترینگ بررسی‌هایی برای به‌دست آوردن بهترین و مناسب‌ترین فیلتر، مرتبه و فرکانس قطع آن انجام گرفت. مجموعه داده DB1 با فرکانس نمونه‌برداری ۲۰۰۰ هرتز ثبت شده است. ابتدا تعداد نمونه‌ها به نصف کاهش داده شد. سپس فیلترهای پایین گذر باترورث<sup>۳۱</sup> و چبی‌شف<sup>۳۲</sup> که در فیلترینگ سیگنال‌های فیزیولوژیکی رایج هستند، در مرتبه‌ها و فرکانس‌های قطع مختلف مورد ارزیابی قرار گرفتند. فیلتر باترورث در باند عبور بسیار هموار و آهنگ افت آن ۲۰-دسی بل، به ازای هر قطب است. تغییر فاز سیگنال‌هایی که از این فیلتر می‌گذرند به صورت غیرخطی است. با توجه به نویز زیاد موجود در مجموعه داده DB1 نیناپرو، در مرحله فیلترینگ بررسی‌های گسترده‌ای برای به‌دست آوردن بهترین و مناسب‌ترین مرتبه فیلتر و فرکانس قطع انجام گرفت. با توجه به این‌که سیگنال‌های این مجموعه با فرکانس نمونه‌برداری ۲۰۰۰ هرتز ثبت شده است، مطابق با قضیه نایکوئیست سعی شد تمام بازه‌های فرکانس قطع کمتر از ۱۰۰۰ هرتز، در تمام مراتب مختلف فیلتر باترورث مورد بررسی قرار گیرند. در نهایت بهترین نتیجه با استفاده از فیلتر باترورث پایین گذر مرتبه ۱۰ با فرکانس قطع ۱۵۰ هرتز حاصل شد. با توجه به ماهیت غیرایستای سیگنال EMG و تغییرپذیری بالای آن، سیگنال‌ها به بخش‌هایی با بازه زمانی کوچک‌تر تقسیم شدند. برای بخش‌بندی سیگنال می‌توان از توابع مختلفی بهره گرفت که در این تحقیق از تابع پنجره مستطیلی استفاده شده است. به دلیل کاهش تعداد نمونه‌ها و بازه زمانی سیگنال‌ها و همچنین به‌منظور کاهش تغییرات، سیگنال‌ها به ۵ بخش تقسیم شدند.

### ۳-۲- روش‌های تجزیه سیگنال

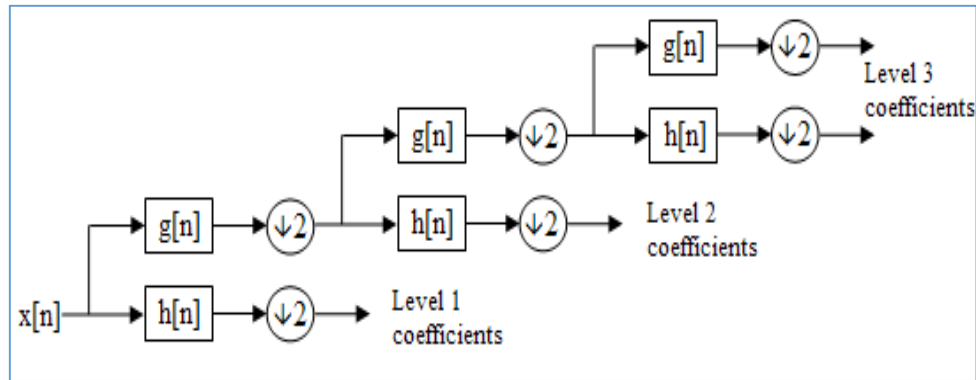
در این قسمت دو روش تبدیل موجک گسسته<sup>۳۳</sup> (DWT) و تجزیه مد تجربی به‌طور مختصر اشاره می‌شود. الف- تبدیل موجک گسسته: تبدیل موجک با هدف غلبه بر محدودیت‌های تبدیل فوریه ارایه شده است. این تبدیل را می‌توان برای دستیابی به اطلاعات فرکانسی و زمانی سیگنال‌های غیرایستا مورد استفاده قرار داد. با اعمال تبدیل موجک، سیگنال برحسب سطح تجزیه انتخاب شده به تعدادی زیرسیگنال با محدوده فرکانسی و زمانی مشخص تجزیه می‌شود [۱۵]. تبدیل موجک، دارای دو نوع مختلف گسسته و پیوسته است. تبدیل موجک پیوسته<sup>۳۴</sup> (CWT) توسط تابع زیر توصیف می‌شود:

$$x_{\omega}(a, b) = \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

که در آن  $\psi$  موجک مادر،  $a$  ضریب مقیاس و  $b$  میزان انتقال تابع است. در تبدیل موجک گسسته، مقادیر مقیاس و انتقال به صورت گسسته‌اند:

$$\left\{ \Psi_{j,n}(t) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{t-2^j n}{2^j}\right) \right\}_{(j,n \in \mathbb{Z})} \quad (3)$$

که  $z$  ضریب مقیاس و  $\Psi_j$  تابع موجک مادر است. تبدیل موجک، سیگنال‌هایی با انرژی محدود، بازه زمانی و پهنای باند فرکانسی کوچک تولید می‌کند. با تغییر موقعیت زمانی و فرکانسی تابع موجک مادر، می‌توان ویژگی‌های زمانی-فرکانسی سیگنال‌ها را با قابلیت تفکیک بالایی به‌دست آورد. همان‌طور که مشخص است هدف از تبدیل فوریه، محاسبه مولفه‌های فرکانسی دایمی و نوسانی سیگنال در کل زمان است، در حالی‌که هدف از تبدیل موجک، محاسبه مولفه‌های فرکانسی سیگنال است که به‌طور موضعی در محدوده زمانی مشخصی وجود دارند. به دلیل متغیر بودن طول پنجره موجک، تبدیل موجک قابلیت ارایه وضوح متفاوت زمانی-فرکانسی را داراست. ویژگی چند وضوحی تبدیل موجک (بررسی سیگنال‌ها در مقیاس‌های مختلف در یک بازه زمانی معین)، باعث شده که کاربرد زیادی در زمینه‌های مختلف پردازش سیگنال‌های گسسته، از جمله فشرده‌سازی سیگنال‌های ویدئو، گفتار و پردازش و فشرده‌سازی سیگنال‌های پزشکی داشته باشد [۱۶، ۱۷]. تبدیل موجک گسسته سیگنال  $x$  همان‌طور که در شکل (۳) نشان داده شده با عبور آن از مجموعه‌ای از فیلترهای پایین‌گذر و بالاگذر حاصل می‌شود. در ابتدا سیگنال از یک فیلتر پایین‌گذر با پاسخ ضربه  $g$  و به‌طور هم‌زمان از یک فیلتر بالاگذر با پاسخ ضربه  $h$  عبور داده می‌شود. از فیلتر بالاگذر، ضرایب جزئیات و از فیلتر پایین‌گذر، ضرایب تقریب به‌دست می‌آیند [۱۵].



شکل (۳): روش تجزیه تبدیل موجک گسسته [۱۵]

Figure (3): DWT decomposition method [15]

$$y_{low}[n] = \sum_{k=-\infty}^{\infty} x[k]g[2n-k] \rightarrow y_{low} = (x * g) \downarrow 2 \quad (۴)$$

$$y_{high}[n] = \sum_{k=-\infty}^{\infty} x[k]h[2n-k] \rightarrow y_{high} = (x * h) \downarrow 2 \quad (۵)$$

مطابق روابط بالا سیگنال‌های به دست آمده از فیلترها سپس در معرض کاهش نمونه با نسبت ۲ قرار می‌گیرند. این عمل تجزیه باعث نصف شدن وضوح زمانی سیگنال می‌شود. هر خروجی تولید شده نیمی از باند فرکانسی ورودی را دارد، بنابراین وضوح فرکانسی<sup>۳۵</sup>، دو برابر شده است. به منظور کسب بهترین نتایج در طراحی سیستم تشخیص حرکت‌های دست، موجک‌های مادر و سطوح تجزیه مختلف سیگنال‌ها مورد استفاده و ارزیابی قرار گرفتند.

ب- تجزیه مد تجربی: روش EMD هر سری زمانی را به مجموعه‌ای از اجزای مدولاسیون فرکانس و دامنه<sup>۳۶</sup> (FM-AM) یا عملکرد مد ذاتی<sup>۳۷</sup> (IMF) تجزیه می‌کند. اجزای IMF حالت‌های نوسانی موجود در سیگنال را بیان می‌کنند. در روش EMD هر IMF سیگنالی است که شرایط زیر را برآورده کند:

(۱) در تمام سری زمانی، تعداد بیشینه‌ها و کمینه‌ها و نقاط عبور از صفر باید برابر باشند یا حداکثر اختلاف یک داشته باشند.

(۲) در هر نقطه از سری زمانی، باید مقدار میانگین پوش بالا و پایین، برابر با صفر باشد [۱۵].

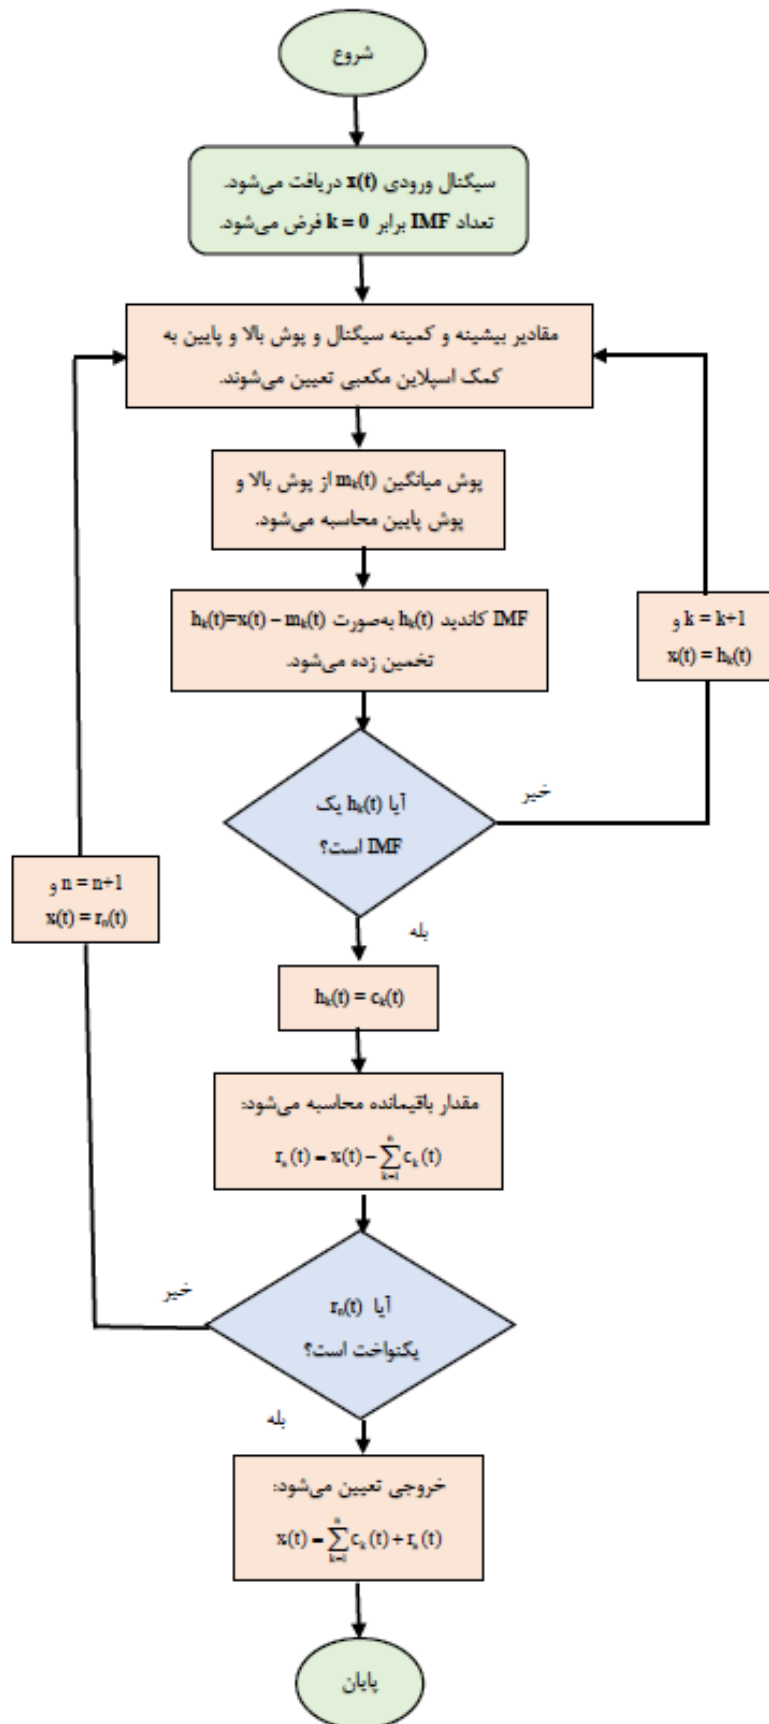
در هر دو روش EMD و DWT، سیگنال به بخش‌هایی با مقیاس‌های زمانی مختلف تجزیه می‌شود. با این حال، روش EMD کاملاً بر اساس ماهیت داده عمل می‌کند و نیازی به توابع موجک مادر از پیش تعیین شده ندارد. مراحل روش EMD برای تجزیه سیگنال  $x(t)$  به IMF‌های تشکیل دهنده در شکل (۴) نمایش داده شده است. مقادیر بیشینه و کمینه سیگنال و پوش بالا<sup>۳۸</sup> (UE) و پوش پایین<sup>۳۹</sup> (LE) به کمک اسپلاین مکعبی<sup>۴۰</sup> تعیین می‌شوند.

#### ۴-۲- طراحی سیستم تشخیص حرکت‌های دست با استفاده از الگوهای سیگنال الکترومایوگرام سطحی

الگوهای سیگنال sEMG که با حرکت‌های مختلف دست در ارتباط هستند، به وسیله ویژگی‌های استخراج شده از سیگنال توصیف می‌شوند. ویژگی‌های سیگنال در واقع اطلاعات موجود در سیگنال را که مرتبط با حرکت‌های مورد نظر هستند، ارائه می‌کنند. انتخاب و تعیین ویژگی‌های مؤثر نقش بسیار مهمی بر روی عملکرد طبقه‌بندی کننده و تشخیص دقیق حرکت‌ها دارد. به منظور کسب اطلاعات دقیق‌تر در رابطه با الگوهای حرکتی مورد نظر، سیگنال‌های sEMG با روش‌های DWT و EMD تجزیه شدند و ویژگی‌های مورد نظر از زیربازه‌های به دست آمده استخراج شدند.

در این تحقیق از ویژگی‌های حوزه زمان<sup>۴۱</sup> (TD) مانند میانگین قدر مطلق (MAV)، شیب میانگین قدر مطلق (MAVSLP)<sup>۴۲</sup>، واریانس<sup>۴۳</sup> (VAR)، عبور از صفر<sup>۴۴</sup> (ZC)، تغییرات علامت شیب<sup>۴۵</sup> (SSC)، میانگین قدر مطلق اولین تفاضل سیگنال خام، میانگین قدر مطلق اولین تفاضل سیگنال استاندارد، میانگین قدر مطلق تفاضل دوم سیگنال خام، میانگین قدر مطلق تفاضل دوم سیگنال استاندارد و RMS استفاده شده است. با تعیین مجموعه ویژگی‌ها به منظور کاهش ابعاد ویژگی‌ها و سرعت بخشیدن به فرایند آموزش سیستم، روش‌های PCA و SFFS مورد استفاده قرار گرفتند.





شکل (۴): مراحل روش تجزیه مد تجربی

Figure (4): Flowchart of EMD method

با روش SFFS به‌منظور دستیابی به بهترین نتایج، تمامی ترکیب‌ها و ویژگی‌های استخراج شده مورد بررسی قرار گرفتند. همچنین با روش PCA مجموعه داده‌های اولیه به فضایی با ابعاد کمتر تبدیل می‌شود؛ که داده‌ها در فضای جدید واریانس و قابلیت تفکیک بالاتری داشته باشند. در روش PCA، تعداد  $k$  تا از بردارهای ویژه متناظر با بزرگترین مقادیر ویژه ماتریس همبستگی داده‌های ورودی تعیین شده و ماتریس تبدیل توسط آن‌ها ساخته می‌شود. در طبقه‌بندی سیگنال sEMG هدف تشخیص و تفکیک حرکت‌های انجام شده با بیشترین دقت ممکن است ماشین بردار پشتیبان یکی از روش‌های یادگیری نظارت شده است که از آن برای طبقه‌بندی استفاده می‌شود. روش SVM می‌تواند برای دسته‌بندی داده‌های خطی و غیرخطی استفاده شود. SVM در حالت خطی با تعیین خطی با بیشترین مرز نسبت بین داده‌ها به طبقه‌بندی آن‌ها می‌پردازد. همچنین در حالت غیرخطی با کمک یک نگاشت غیرخطی، فضای مجموعه داده‌های آموزشی را به یک بعد بالاتر تبدیل می‌کند و سپس در این بعد جدید به دنبال ابرصفحه‌ای خواهد بود که نمونه‌های یک کلاس را از نمونه‌های دیگر جدا کند. با یک نگاشت غیرخطی مناسب، مجموعه داده‌های دو دسته می‌توانند توسط یک ابرصفحه جدا شوند.

در مرجع [۱۸] روشی برای ایجاد طبقه‌بندی غیرخطی با استفاده از تابع کرنل برای پیدا کردن ابرصفحه با بیشترین حاشیه، پیشنهاد شده است. برای استفاده از بردارهای پشتیبان در مورد داده‌های واقعی، چندین نکته باید رعایت شود تا نتایج قابل قبولی به دست آید. پالایش داده‌ها و حذف داده‌های پرت، به‌هنگار کردن مقادیر ویژگی‌ها در محدوده مشخص از جمله اقدامات لازم بر روی مقادیر ویژگی‌ها قبل از اعمال به طبقه‌بندی‌کننده است. همچنین کرنل‌های مختلف روش SVM می‌تواند بررسی شود و در صورت نیاز پارامترهای موجود تغییر داده شوند تا پاسخ‌های بهتری حاصل گردد. در این تحقیق به‌منظور به دست آوردن بهترین دقت، از طبقه‌بند SVM با کرنل‌های مختلف استفاده شده است. در هر دو روش EMD و DWT در تمام سطوح تجزیه، از کرنل‌های گوسین، خطی و چندجمله‌ای استفاده شد و نتایج حاصل مورد بررسی قرار گرفت. همچنین با توجه به این که روش SVM یک طبقه‌بندی‌کننده دو دسته است، در پیاده‌سازی آن از روش یک دسته در مقابل بقیه<sup>۴۶</sup> استفاده شده است.

### ۳- نتایج و بحث

به‌منظور طراحی سیستمی که قادر به شناسایی بیشترین تعداد حرکت‌های دست با دقت و سرعت مطلوب باشد، تجزیه سیگنال-های EMG برای دستیابی به اطلاعات زمان-فرکانس آن‌ها مورد توجه قرار گرفت. با توجه به این که سیگنال EMG سیگنالی تصادفی و با تغییرپذیری زیاد است، راه‌کار تجزیه سیگنال می‌تواند با تعیین زیرباندهای زمانی و فرکانسی، اطلاعات دقیق‌تری را برای تشخیص دقیق حرکت‌های دست در اختیار قرار دهد. برای هر یک از زیرسیگنال‌های تعیین شده با روش‌های تبدیل موجک و تجزیه مد تجربی، ویژگی‌های معرفی شده محاسبه شدند. همچنین به‌منظور کسب بهترین نتایج، مقادیر مختلف سطوح تجزیه مورد توجه قرار گرفتند. روش‌های SFFS و PCA، برای کاهش ابعاد و نگاشت مجموعه ویژگی‌های ایجاد شده و SVM به‌عنوان طبقه‌بندی‌کننده برای تشخیص حرکت‌های مورد نظر به کار گرفته شدند. همچنین روش یک نمونه بیرون<sup>۴۷</sup> (LOO) برای اعتبارسنجی نتایج اعمال شد. با این روش برای مجموعه داده‌های ۲۷ نفر، در هر مرحله ویژگی‌های یک نفر به‌عنوان داده‌های آزمایش و ویژگی‌های مربوط به ۲۶ نفر دیگر به‌عنوان داده‌های آموزش استفاده شدند. متوسط نتایج به دست آمده، به‌عنوان دقت نهایی گزارش شده‌اند. عملکرد سیستم تشخیص حرکت‌های دست با معیارهای دقت<sup>۴۸</sup>، صحت<sup>۴۹</sup>، حساسیت<sup>۵۰</sup> و معین‌پذیری<sup>۵۱</sup> که با رابطه‌های زیر تعریف می‌شوند، ارزیابی شدند [۲۱-۱۹]:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۶)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (۷)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (۸)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (۹)$$

که در آن TP بیانگر حالت مثبت حقیقی<sup>۵۲</sup>، TN منفی حقیقی<sup>۵۳</sup>، FP مثبت کاذب<sup>۵۴</sup> و FN بیانگر منفی کاذب<sup>۵۵</sup> هستند. با توجه به این که یکی از اهداف این مطالعه، بررسی امکان افزایش تعداد حرکت‌های شناسایی شده است، سیستم تشخیص با تعداد حرکت‌های مختلف طراحی گردید که در ادامه نتایج به دست آمده با دو روش تجزیه مورد استفاده ارائه می‌شوند.

### ۱-۳- نتایج به دست آمده با روش تجزیه مد تجربی

سیگنال‌های EMG با استفاده از روش تجزیه EMD به تعداد هشت تابع مد ذاتی (IMF) تجزیه شدند. سپس برای هر یک از توابع به دست آمده ویژگی‌های زمانی مورد نظر محاسبه شدند. هدف این مطالعه علاوه بر افزایش دقت تشخیص، بررسی قابلیت سیستم طراحی شده در شناسایی بیشترین تعداد ممکن از حرکت‌ها است.

بهترین نتایج به دست آمده برای تعداد شش، هشت، ده و دوازده حرکت با ترکیب ویژگی‌های مختلف در جدول (۱) ارائه شده است. بالاترین دقت کسب شده در این حالت برابر با ۸۳/۳۳ درصد و برای شش حرکت به دست آمده است. همانطور که مشاهده می‌شود ویژگی‌های MAV، RMS و MAVSLP و توابع کرنل گوسین<sup>۵۶</sup> و چندجمله‌ای<sup>۵۷</sup> برای طبقه‌بندی کننده SVM عملکرد مطلوبی ارائه کرده‌اند. با افزایش تعداد حرکت‌ها، دقت سیستم طراحی شده با استفاده از ویژگی‌های EMD روند کاهشی را نشان می‌دهد. به گونه‌ای که برای تعداد هشت حرکت دقت سیستم تا مقدار ۶۲/۵ درصد کاهش یافته است. نتایج ارائه شده در جدول (۱)، بالاترین دقت‌های به دست آمده و کمترین میزان خطای آموزش برای طراحی سیستم تشخیص حرکت‌های دست با تعداد شش، هشت، ده و دوازده حرکت بوده است.

### ۲-۳- نتایج به دست آمده با روش تجزیه تبدیل موجک گسسته

در بررسی روش DWT، سطوح تجزیه ۲ تا ۶ و همچنین تمامی موجک‌های مادر دابلیو جیز<sup>۵۸</sup> (Db) مرتبه ۱ تا ۱۰، بای‌ارتوگونال<sup>۵۹</sup> (Bior) مرتبه ۱/۳ تا ۶/۸، کویفلت (Coif) مرتبه ۱ تا ۵، برای تعداد حرکت‌های شش، هشت، ده و دوازده حرکت با ترکیب‌های ویژگی‌های مختلف بررسی شدند.

نتایج حاصل همان‌طور که در جدول (۲) ارائه شده نشان می‌دهد که ویژگی‌های زمانی MAV، MAVSLP و VAR عملکرد بهتری در مقایسه با سایر ویژگی‌ها ارائه می‌کنند. بالاترین دقت کسب شده برابر با ۸۳/۳۳ درصد برای تعداد شش و هشت حرکت به دست آمده است. همچنین برای تعداد ده حرکت دقت ۸۰ درصد با پنج سطح تجزیه و موجک‌مادر ۵/۵ بای‌ارتوگونال کسب شده است. در این حالت تابع کرنل چندجمله‌ای برای طبقه‌بندی کننده SVM عملکرد مطلوبی ارائه کرده است. نتایج کسب شده توسط سیستم تشخیص احساسات با دو روش تجزیه استفاده شده، بیانگر عملکرد بهتر روش تجزیه موجک نسبت به روش تجزیه مد تجربی است. با روش تجزیه موجک با توجه به سطح تجزیه انتخاب شده، زیرباندهای فرکانسی مختلفی در اختیار خواهد بود که اطلاعات سیگنال EMG را می‌توان به‌طور مطلوب در هر حرکت از آن‌ها استخراج نمود.

Table (1): The best results obtained in recognizing different hand movements using the EMD decomposition method  
جدول (۱): بهترین نتایج کسب شده در تشخیص حرکت‌های مختلف دست با استفاده از روش تجزیه مد تجربی

تعداد حرکت	ویژگی‌های انتخاب شده	نوع کرنل	درصد خطای آموزش	درصد دقت	درصد صحت	درصد حساسیت	درصد معین پذیری
۶	MAV, MAVSLP	کرنل گوسین	۳/۲	۸۳/۳۳	۹۶/۸	۸۵/۷۲	۸۱/۰۴
۶	MAVSLP, RMS	کرنل گوسین / کرنل پلی نومیال	۶/۴	۸۳/۳۳	۹۳/۶	۸۵/۷۲	۸۱/۰۴
۶	MAV, MAVSLP, RMS	کرنل گوسین / کرنل پلی نومیال	۰	۸۳/۳۳	۱۰۰	۸۵/۷۲	۸۱/۰۴
۸	MAV, ZC	کرنل گوسین	۸/۱۵	۶۰/۵۰	۹۱/۸۵	۶۴/۸۹	۶۰/۲۱
۱۰	MAV, MAVSLP	کرنل گوسین	۳/۴۷	۵۰	۹۶/۵۳	۶۷/۹۷	۴۷/۷۱
۱۲	MAV, RMS	کرنل گوسین	۴/۷	۴۱/۶۶	۹۵/۳	۸۹/۷۴	۳۹/۳۷

Table (2): The best results obtained in recognizing different hand movements using the DWT decomposition method  
جدول (۲): بهترین نتایج کسب شده در تشخیص حرکتهای مختلف دست با استفاده از روش تجزیه تبدیل موجک گسسته

تعداد حرکت	ویژگی‌های انتخاب شده	نوع موجک مادر	سطح تجزیه	نوع کرنل	درصد دقت	درصد صحت	درصد حساسیت	درصد معین پذیری
۶	MAVSLP, VAR	Bior3.7	پنج	پلی نومیال	۸۳/۳۳	۸۹/۵۲	۸۵/۷۲	۸۷/۱۷
۸	MAV, MAVSLP, VAR	Coif2	شش	گوسین / پلی نومیال	۸۳/۳۳	۸۹/۵۲	۸۵/۷۲	۸۷/۱۷
۱۰	MAV, MAVSLP, VAR	Bior5.5	پنج	پلی نومیال	۸۰	۹۲/۹۷	۸۳/۹۶	۸۳/۱۴
۱۲	MAV, MAVSLP	Db5	چهار	گوسین	۵۰	۶۵/۶۲	۵۶/۸۴	۵۹/۳۶

Table (3): Comparison of the results obtained in the present study with the results of previous works using the NinaPro dataset  
جدول (۳): مقایسه نتایج به دست آمده در این مطالعه با نتایج مطالعات قبلی با استفاده از مجموعه داده نیناپرو

مطالعه انجام شده	پایگاه داده Ninapro	افراد شرکت کننده	نوع سیگنال	روش تجزیه	ویژگی استخراج شده	طبقه‌بندی کننده	درصد دقت
[۲۲]	DB-۱۰	۴۵ نفر (۵ فرد قطع عضو و ۴۰ فرد سالم)	EMG سطحی به همراه شتاب سنج	DWT	mDWT	KRLS	افراد دچار قطع عضو
							۷۷ درصد
[۱۰]	DB-۴	۱۰ فرد سالم	EMG سطحی	EMD	MAV	SVM	۹۱/۶۷
[۲۳]	DB-۱ DB-۲ DB-۳	۷۸ نفر (۱۱ فرد قطع عضو و ۶۷ فرد سالم)	EMG سطحی به همراه شتاب سنجی	DWT	mDWT, RMS, HIST, TD	SVM / KNN / Random Forests / LDA	(جنگل تصادفی) DB-۱
							(جنگل تصادفی) DB-۲
							(SVM) DB-۳
مطالعه حاضر	DB-۱	۲۷ فرد سالم	EMG سطحی	EMD	MAV, MAVSLP, RMS	SVM	۸۳/۳۳
مطالعه حاضر	DB-۱	۲۷ فرد سالم	EMG سطحی	DWT	MAV, MAVSLP, VAR	SVM	۸۰

با استفاده از روش DWT تعداد حرکت بیشتری با دقت قابل قبول شناسایی شده‌اند. همان‌طور که در جدول (۲) مشاهده می‌شود، تعداد ۵ و ۶ سطح تجزیه برای سیگنال عملکرد بهتری ارائه کرده‌اند. جدول (۳) بهترین نتایج کسب شده در این مطالعه را به همراه نتایج مطالعات گذشته که از مجموعه داده نیناپرو استفاده کرده‌اند، ارائه می‌کند. با توجه به نتایج کسب شده عملکرد مطلوب سیستم پیشنهادی تأیید می‌شود. نکته‌ای که لازم است به آن توجه شود این است که در مطالعه حاضر از مجموعه داده DB1 نیناپرو استفاده شده که شامل تعداد سیگنال ثبت شده از ۲۷ نفر داوطلب شرکت کننده در آزمایش است؛ در صورتی که مجموعه DB4 تنها شامل داده‌های ۱۰ شرکت کننده سالم بوده و مجموعه DB10 علاوه بر سیگنال EMG شامل داده‌های شتاب‌سنجی نیز هست. همچنین در بعضی از مطالعات گذشته همان‌طور که در جدول (۳) نیز مشاهده می‌شود، از روش‌های پردازشی با پیچیدگی محاسباتی به‌طور نسبی بالا مانند تبدیل موجک گسسته مرزی<sup>۶</sup> (mDWT) و هیستوگرام<sup>۶</sup> (HIST) در

استخراج ویژگی‌ها و کمترین مربعات تنظیم شده با کرنل  $\epsilon^2$  (KRLS) به منظور طبقه‌بندی استفاده شده است. در سیستم طراحی شده در این مطالعه از ویژگی‌های زمانی ساده و طبقه‌بند با قابلیت محاسبه سریع استفاده شده است. بدیهی است در صورتی که علاوه بر ویژگی‌های زمانی، ویژگی‌های فرکانسی یا دینامیکی سیگنال مانند آنتروپی، بعد همبستگی یا سایر ویژگی‌ها که رفتار غیرخطی سیگنال را مشخص می‌کنند استفاده شود، نتایج به‌طور قابل توجهی بهبود خواهد یافت.

#### ۴- نتیجه‌گیری

در این مطالعه با هدف تشخیص دقیق حرکت‌های مختلف دست با استفاده از الگوهای سیگنال sEMG، به مقایسه دو روش تجزیه موجک گسسته و تجزیه مد تجربی اشاره شد. سیگنال‌های sEMG از مجموعه داده نیناپرو DB1 برای طراحی سیستم به‌کار گرفته شدند. با استفاده از فیلتر باترورث مرتبه ده، اثر نویزها و تداخل‌های موجود بر روی سیگنال کاهش داده شد. به‌منظور کاهش تغییرات سیگنال و دستیابی به اطلاعات زیرباندهای مختلف، دو روش تجزیه موجک گسسته و تجزیه مد تجربی مورد ارزیابی قرار گرفتند و برای هر یک از زیرباندهای تشکیل شده، ویژگی‌های زمانی محاسبه شدند. ترکیبات مختلف ویژگی‌ها با روش‌های جستجوی شناور و PCA مورد بررسی قرار گرفته شده که نتایج نشان داد ویژگی‌های میانگین قدرمطلق دامنه، شیب میانگین قدرمطلق دامنه، واریانس و ریشه میانگین مربعات با هر دو روش تجزیه مورد استفاده عملکرد بهتری ارائه می‌کنند. همچنین روش طبقه‌بندی SVM با توابع کرنل مختلف برای شناسایی الگوهای حرکتی مورد بررسی قرار گرفت. با روش تجزیه EMD، بهترین دقت سیستم برابر با  $83/33$  درصد برای شناسایی شش حرکت و با استفاده از تابع کرنل گوسین به‌دست آمد. با روش تجزیه DWT، به‌طور نسبی عملکرد بهتری از سیستم مشاهده می‌شود؛ به‌گونه‌ای که با استفاده از موجک مادر Bior5.5 در پنج سطح تجزیه و اعمال تابع کرنل چندجمله‌ای، دقت  $80$  درصد برای شناسایی ده حرکت به‌دست می‌آید. همچنین روش DWT برای شناسایی تعداد شش و هشت حرکت مشابه با روش EMD دقت  $83/33$  درصد را به‌دست آورده است. نتایج کسب شده با هر دو روش تجزیه با وجود استفاده از ویژگی‌های زمانی ساده، قابل توجه است. عملکرد سیستم تشخیص حرکت‌های دست نشان می‌دهد در صورت استفاده از ویژگی‌های فرکانسی و یا دینامیکی سیگنال sEMG، عملکرد سیستم همچنان بهبود خواهد یافت.

#### سپاسگزاری

این مقاله مستخرج از پایان‌نامه دوره کارشناسی‌ارشد در دانشگاه آزاد اسلامی واحد نجف‌آباد است. نویسندگان بر خود لازم می‌دانند مراتب تشکر صمیمانه خود را از همکاران حوزه پژوهشی دانشگاه آزاد اسلامی و داوران محترم که ما را در انجام و ارتقای کیفی این مقاله یاری نموده‌اند، اعلام نمایند.

#### References

##### مراجع

- [1] M. Khezri, M. Jahed, "An inventive quadratic time-frequency scheme based on wigner-ville distribution for classification of sEMG signals", Proceeding of the IEEE/TTAB, pp. 261-264, Tokyo, Japan, Nov. 2007 (doi: 10.1109/ITAB.2007.4407397).
- [2] S. Mao, J. Li, A. Guo, T. Zhao, J. Zhang, "An active multielectrode array for collecting surface electromyogram signals using a-IGZO TFT technology on polyimide substrate", IEEE Trans. on Electron Devices, vol. 67, no. 4, pp. 1613-1618, April 2020 (doi: 10.1109/TED.2020.2974971).
- [3] R. Chowdhury, M. Raez, M. Ali, A. Bakar, K. Chellappan, T. Chang, "Surface electromyography signal processing and classification techniques", Sensors, vol. 13, no. 9, pp. 12431-12466, Sept. 2013 (doi: 10.3390/s130912431).
- [4] N. Behzadfar, "A brief overview on analysis and feature extraction of electroencephalogram signals", Signal Processing and Renewable Energy, vol. 6, no. 1, pp. 39-64, March 2022 (dor: 20.1001.1.25887327.2022.6.1.-3.9).
- [5] J. Lopes, M. Simão, N. Mendes, M. Safeea, J. Afonso, P. Neto, "Hand/arm gesture segmentation by motion using IMU and EMG sensing", Procedia Manufacturing, vol. 11, pp. 107-113, Sept. 2017 (doi: 10.1016/j.promfg.2017.07.158).

- [6] M. Tavakoli, C. Benussi, P. Alhais Lopes, L. B. Osorio, A.T. Almeida, "Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier", *Biomedical Signal Processing and Control*, vol. 46, pp. 121–130, Sept. 2018 (doi: 10.1016/j.bspc.2018.07.010).
- [7] F. Duan, L. Dai, "Recognizing the gradual changes in sEMG characteristics based on incremental learning of wavelet neural network ensemble", *IEEE Trans. on Industrial Electronics*, vol. 64, no. 5, pp. 4276–4286, May 2017 (doi: 10.1109/TIE.2016.2593693).
- [8] A. Islam, M.S. Alam, "Classification of electromyography signals using support vector machine", *Dujase*, vol. 4, no. 1, pp. 45–52, Jan. 2017.
- [9] A.D. Bellingegni, E. Gruppioni, G. Colazzo, A. Davalli, R. Sacchetti, E. Guglielmelli, Loredana Zollo, "NLR, MLP, SVM, and LDA: A comparative analysis on EMG data from people with trans-radial amputation", *Journal of Neuroengineering and Rehabilitation*, vol. 14, no. 82, Aug. 2017 (doi: 10.1186/s12984-017-0290-6).
- [10] Y. Li, Q. Zhang, N. Zeng, J. Chen, Q. Zhang, "Discrete hand motion intention decoding based on transient myoelectric signals", *IEEE Access*, vol. 7, no. 1, pp. 81630–81639, June 2019 (doi: 10.1109/ACCESS.2019.2923455).
- [11] S. Shen, K. Gu, X.-R. Chen, M. Yang, "Movements classification of multi-channel sEMG based on CNN and stacking ensemble learning", *IEEE Access*, vol. 7, pp. 137489–137500, Sept. 2019 (doi: 10.1109/ACCESS.2019.2941977).
- [12] J.E. Lara, L.K. Cheng, O. Röhrle, N. Paskaranandavadivel, "Muscle-specific high-density electromyography arrays for hand gesture classification", *IEEE Trans. on Biomedical Engineering*, vol. 69, no. 5, pp. 1758–1766, May 2022 (doi: 10.1109/TBME.2021.3131297).
- [13] F.S. Botros, A. Phinyomark, E.J. Scheme, "Electromyography-based gesture recognition: is it time to change focus from the forearm to the wrist?", *IEEE Trans. on Industrial Informatics*, vol. 18, no. 1, pp. 174–184, Jan. 2022 (doi: 10.1109/TII.2020.3041618).
- [14] M. Atzori, A. Gijsberts, S. Heynen, A. G. M. Hager, O. Deriaz, P. V. D. Smagt, C. Castellini, B. Caputo, H. Müller, "Building the ninapro database: A resource for the biorobotics community", *Proceeding of the IEEE/RAS-EMBS*, pp. 1258–1265, Rome, Italy, June 2012 (doi: 10.1109/BioRob.2012.6290287).
- [15] J. Kevric, A. Subasi, "Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system", *Biomedical Signal Processing and Control*, vol. 31, pp. 398–406, Jan. 2017 (doi: 10.1016/j.bspc.2016.09.007).
- [16] L. Chmelka, J. Kozumplik, "Wavelet-based wiener filter for electrocardiogram signal denoising", *Proceeding of the IEEE/CIC*, pp. 771–774, Lyon, France, Feb. 2005 (doi: 10.1109/CIC.2005.1588218).
- [17] M.S. Chaudhary, R.K. Kapoor, A.K. Sharma, "Comparison between different wavelet transforms and thresholding techniques for ECG denoising", *Proceeding of the IEEE/ICAETR*, pp. 1–6, Unnao, India, Aug. 2014 (doi: 10.1109/ICAETR.2014.7012899).
- [18] B.E. Boser, I. Guyon, "A training algorithm for optimal margin classifiers", *Proceeding of the AWCLT*, pp. 144–152, Pittsburgh Pennsylvania, USA, July 1992 (doi: 10.1145/130385.130401).
- [19] S. Karimi-Shahraki, M. Khezri, "Identification of attention deficit Hyperactivity disorder patients using wavelet-based features of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, vol. 12, no. 47, pp. 1–11, December 2021 (in Persian) (dor: 20.1001.1.23223871.1400.12.3.1.1)
- [20] G. Mardanian, N. Behzadfar, "A new method for detection of breast cancer in mammography images using a firefly algorithm", *Journal of Intelligent Procedures in Electrical Technology*, vol. 10, no. 40, pp. 23–32, March 2020 (in Persian) (dor: 20.1001.1.23223871.1398.10.40.3.3).
- [21] M. Dorvashi, N. Behzadfar, G. Shahgholian, "Classification of alcoholic and non-alcoholic individuals based on frequency and non-frequency features of electroencephalogram signal", *Journal Iranian Journal of Biomedical Engineering*, vol. 14, no. 2, pp. 121–130, July 2020 (doi: 10.22041/ijbme.2020.119841.1551).
- [22] M. Atzori, A. Gijsberts, H. Muller, B. Caputo, "Classification of hand movements in amputated subjects by sEMG and accelerometers", *Proceeding of the IEEE/ Engineering in Medicine and Biology Society*, pp. 3545–3549, Chicago, Aug. 2014 (doi: 10.1109/EMBC.2014.6944388).
- [23] M. Atzori, A. Gijsberts, C. Castellini, B. Caputo, A.G.M. Hager, S. Elsig, G. Giatsidis, F. Bassetto, H. Müller, "Electromyography data for non-invasive naturally-controlled robotic hand prostheses", *Scientific Data*, vol. 1, no. 1, pp. 1–13, Dec. 2014 (doi: 10.1038/sdata.2014.53).

1. Prosthesis
2. Electromyogram
3. Surface electromyogram
4. Inertial measurement units

5. Support vector machine
6. Wavelet neural network
7. Negative correlation learning
8. Back propagation
9. Morlet mother wavelet
10. Mother wavelet
11. Coiflet mother wavelet
12. Mean absolute value
13. Root mean squared
14. Integrated average value
15. Wavelength
16. Autoregressive model
17. Principal component analysis
18. Non-linear logistic regression
19. Multi-layer perceptron
20. Linear discriminant analysis
21. Embedding optimization factor
22. Empirical mode decomposition
23. K-nearest neighbors
24. Convolution neural network
25. Stacking ensemble learning
26. Long short-term memory-CNN
27. High density EMG
28. Cubic support vector machine
29. Sequential floating forward search
30. Wavelet transforms
31. Butterworth filter
32. Chebyshev filter
33. Discrete wavelet transform
34. Continuous wavelet transforms
35. Frequency resolution
36. Amplitude modulation-frequency modulation
37. Intrinsic mode function
38. Upper envelope
39. Lower envelope
40. Cubic spline
41. Time Domain
42. Mean absolute value slope
43. Variance
44. Zero crossing
45. Slope sign changes
46. One against all
47. Leave one out
48. Precision
49. Accuracy
50. Sensitivity
51. Specificity
52. True positive
53. True negative
54. False positive
55. False negative
56. Gaussian kernel function
57. Polynomial kernel function
58. Daubechies wavelet
59. Biorthogonal wavelet
60. Marginal discrete wavelets transform
61. Histogram
62. Kernel regularized least squares