



مروری بر پیشرفت‌های پردازش سیگنال الکترومیوگرافی سطحی (sEMG) در تشخیص حرکات دست و کنترل پروتزهای هوشمند

کوروش برزکار

دانشجوی کارشناسی ارشد مهندسی پزشکی دانشگاه آزاد اسلامی، مشهد، ایران

Kourosh.barzkar@iaui.ir

نرگس اعتضادجلی

مهندسی اپتیک ولیزر دانشگاه غیرانتفاعی خیام، مشهد، ایران

Nargesetezad4@gmail.com

چکیده

الکترومیوگرافی سطحی (Surface Electromyography یا sEMG) یکی از مهم‌ترین فناوری‌های غیرتهاجمی برای ثبت فعالیت الکتریکی عضلات اسکلتی است که در سال‌های اخیر توجه گسترده‌ای را در حوزه‌های مهندسی پزشکی، توانبخشی، رباتیک و رابط‌های انسان و ماشین به خود جلب کرده است. پیشرفت در طراحی حسگرهای پوشیدنی، توسعه روش‌های پردازش سیگنال و به‌کارگیری الگوریتم‌های یادگیری ماشین و یادگیری عمیق، موجب افزایش چشمگیر دقت تشخیص حرکات و کنترل پروتزهای میوالکتریک شده است. با وجود این پیشرفت‌ها، عواملی مانند نویز، تغییر محل قرارگیری الکترودها، تفاوت‌های فیزیولوژیکی افراد و خستگی عضلات همچنان از مهم‌ترین چالش‌های این حوزه محسوب می‌شوند. در این مقاله، با مرور پژوهش‌های کاربردی، روند پیشرفت فناوری‌های ثبت سیگنال، روش‌های پیش‌پردازش، استخراج ویژگی، الگوریتم‌های طبقه‌بندی و کاربردهای بالینی و صنعتی sEMG بررسی شده است. همچنین نقش معماری‌های نوین مبتنی بر یادگیری عمیق، به‌ویژه شبکه‌های کانولوشنی، شبکه‌های بازگشتی و مدل‌های مبتنی بر مکانیزم توجه (Transformer)، در افزایش دقت تشخیص حرکات مورد ارزیابی قرار گرفته است. نتایج مطالعات نشان می‌دهد که ترکیب حسگرهای پیشرفته با مدل‌های هوشمند می‌تواند عملکرد سامانه‌های کنترل پروتز و توانبخشی را به میزان قابل توجهی بهبود بخشد و زمینه توسعه نسل جدید رابط‌های انسان و ماشین را فراهم کند.

واژگان کلیدی: الکترومیوگرافی سطحی، پردازش سیگنال، پروتز میوالکتریک، یادگیری عمیق، Transformer، توانبخشی.

۱. مقدمه

الکترومیوگرافی سطحی یکی از پرکاربردترین روش‌های غیرتهاجمی برای ثبت فعالیت الکتریکی عضلات اسکلتی است که اطلاعات ارزشمندی درباره عملکرد سیستم عصبی و عضلانی در اختیار پژوهشگران قرار می‌دهد. این فناوری از طریق ثبت پتانسیل‌های الکتریکی ایجادشده در زمان انقباض عضلات، امکان تحلیل الگوهای حرکتی انسان را فراهم می‌کند و امروزه در حوزه‌هایی مانند کنترل پروتزهای هوشمند، توانبخشی بیماران، رباتیک پزشکی، رابط‌های انسان و ماشین، تحلیل حرکات ورزشی و حتی تشخیص زبان اشاره مورد استفاده قرار می‌گیرد (Lian Cheng et al, 2023)، (Muhammad Al-Ayyad et al, 2023). یکی از مهم‌ترین مزایای sEMG نسبت به روش‌های تهاجمی، عدم نیاز به ورود الکتروود به داخل بافت عضله است. این ویژگی علاوه بر افزایش ایمنی و راحتی کاربر، امکان استفاده مداوم از این فناوری را در محیط‌های بالینی و روزمره فراهم کرده است. با این حال، سیگنال‌های ثبت‌شده دارای ماهیتی غیرایستا بوده و تحت تأثیر عوامل مختلفی مانند نویز محیطی، تغییر محل قرارگیری الکتروود، خستگی عضلات، تفاوت‌های آناتومیکی و شرایط فیزیولوژیکی افراد قرار می‌گیرند. این عوامل استخراج اطلاعات دقیق از سیگنال را دشوار کرده و نیاز به استفاده از روش‌های پیشرفته پردازش سیگنال و هوش مصنوعی را افزایش داده‌اند (Muhammad Al-Ayyad et al, 2023)، (D. Xiong et al, 2024).


در سال‌های اخیر، پیشرفت‌های قابل توجهی در حوزه یادگیری ماشین و یادگیری عمیق موجب تحول اساسی در تحلیل سیگنال‌های sEMG شده است. در روش‌های کلاسیک، ابتدا ویژگی‌های سیگنال به صورت دستی استخراج شده و سپس الگوریتم‌های طبقه‌بندی مانند ماشین بردار پشتیبان (SVM)، تحلیل تشخیص خطی (LDA) یا جنگل تصادفی (Random Forest) برای تشخیص حرکات مورد استفاده قرار می‌گرفتند. اگرچه این روش‌ها در بسیاری از کاربردها عملکرد مناسبی داشته‌اند، اما وابستگی زیاد آن‌ها به کیفیت ویژگی‌های استخراج‌شده، استفاده از آن‌ها را در شرایط پیچیده محدود کرده است (Muhammad Al-Ayyad et al, 2023)، (Z. Wei et al, 2024).

با توسعه شبکه‌های عصبی عمیق، به‌ویژه شبکه‌های کانولوشنی (CNN)، شبکه‌های بازگشتی (LSTM) و معماری‌های مبتنی بر مکانیزم توجه (Transformer)، امکان استخراج خودکار ویژگی‌های پیچیده از داده‌های خام فراهم شده است. این مدل‌ها قادرند روابط زمانی و مکانی موجود در سیگنال را به‌طور هم‌زمان تحلیل کرده و دقت طبقه‌بندی حرکات را نسبت به روش‌های سنتی به میزان قابل توجهی افزایش دهند. به‌ویژه معرفی مدل Signal Transformer به‌عنوان یکی از جدیدترین رویکردهای تحلیل سیگنال‌های زیستی، افق جدیدی در توسعه سامانه‌های کنترل پروتز و رابط‌های انسان و ماشین ایجاد کرده است (Muhammad Al-Ayyad et al, 2023)، (S. Ni et al, 2024).

علاوه بر پیشرفت الگوریتم‌ها، توسعه حسگرهای پوشیدنی، الکترودهای انعطاف‌پذیر و سامانه‌های ثبت چندکاناله نیز نقش مهمی در افزایش کیفیت سیگنال‌های ثبت‌شده ایفا کرده است. این فناوری‌ها ضمن افزایش راحتی کاربران، امکان استفاده از سامانه‌های مبتنی بر sEMG را در محیط‌های خارج از آزمایشگاه و در فعالیت‌های روزمره فراهم کرده‌اند. همچنین مطالعات اخیر نشان داده‌اند که حتی در افراد مبتلا به نقص مادرزادی اندام فوقانی نیز می‌توان با تحلیل سیگنال‌های عضلات باقی‌مانده، الگوهای حرکتی قابل اعتمادی استخراج کرد و از آن‌ها برای کنترل پروتزهای میوالکتریک استفاده نمود (Aly Medhat Moslhi et al, 2024)، (Marcus A et al, 2024). هدف این مقاله، ارائه مروری جامع بر فناوری‌های ثبت سیگنال sEMG، روش‌های پردازش و استخراج ویژگی، الگوریتم‌های هوشمند طبقه‌بندی و کاربردهای بالینی و صنعتی این فناوری است. همچنین مهم‌ترین چالش‌های موجود و مسیرهای آینده پژوهش با تکیه بر مطالعات اخیر بررسی می‌شوند تا تصویری روشن از روند توسعه این حوزه ارائه شود.

۲. مروری بر فناوری ثبت سیگنال و پردازش سیگنال های sEMG


الکترومیوگرافی سطحی یا sEMG یکی از مهم ترین روش های غیرتهاجمی برای ثبت فعالیت الکتریکی عضلات اسکلتی است که در دهه های اخیر جایگاه ویژه ای در مهندسی پزشکی، علوم توانبخشی و سامانه های هوشمند پیدا کرده است. در این روش، اختلاف پتانسیل الکتریکی ایجاد شده در اثر انقباض عضلات توسط الکترودهایی که بر روی سطح پوست قرار می گیرند اندازه گیری می شود. برخلاف الکترومیوگرافی سوزنی، در این روش نیازی به ورود الکترود به داخل عضله وجود ندارد؛ از این رو، استفاده از آن ساده تر، ایمن تر و برای پایش مداوم بیماران مناسب تر است (Lian Cheng et al, 2023)، (Muhammad Al-Ayyad et al, 2023). سیگنال های sEMG بازتابی از فعالیت واحدهای حرکتی عضله هستند و اطلاعات ارزشمندی درباره شدت انقباض، زمان بندی فعالیت عضلات و الگوهای حرکتی در اختیار پژوهشگران قرار می دهند. همین ویژگی باعث شده است که این سیگنال ها در کنترل پروتزهای میوالکتریک، ربات های توانبخشی، اسکلت های بیرونی، سیستم های تشخیص حرکات دست، تحلیل عملکرد ورزشکاران و رابط های انسان و ماشین به طور گسترده مورد استفاده قرار گیرند. با این حال، این سیگنال ها دارای دامنه کم، ماهیت غیرایستا و حساسیت بالا نسبت به نویزهای محیطی هستند و همین موضوع پردازش آن ها را به یکی از مهم ترین چالش های این حوزه تبدیل کرده است (Muhammad Al-Ayyad et al, 2023)، (D. Xiong et al, 2024). کیفیت سیگنال ثبت شده تحت تأثیر عوامل متعددی قرار دارد. محل قرارگیری الکترودها، فاصله بین آن ها، ضخامت لایه چربی زیر پوست، تعریق، وضعیت پوست، حرکت الکترودها، فعالیت عضلات مجاور و حتی وضعیت جسمانی فرد می توانند دامنه و شکل سیگنال را تغییر دهند. علاوه بر این، نویز ناشی از تجهیزات الکترونیکی و تداخل فرکانس برق شهری نیز موجب کاهش نسبت سیگنال به نویز می شود. به همین دلیل، تقریباً تمام سامانه های مبتنی بر sEMG پیش از تحلیل داده ها از مراحل مختلف پیش پردازش استفاده می کنند تا کیفیت سیگنال افزایش یابد و اطلاعات واقعی مربوط به فعالیت عضلات حفظ شود (Muhammad Al-Ayyad et al, 2023)، (Z. Wei et al, 2024). شکل ۱ روند کلی پردازش سیگنال sEMG از ثبت تا طبقه بندی را نشان می دهد (Muhammad Al-Ayyad et al, 2023).



شکل ۱. روند کلی پردازش سیگنال sEMG از ثبت تا طبقه بندی

در بیشتر مطالعات، نخستین مرحله پیش پردازش، فیلترگذاری سیگنال است. معمولاً از فیلتر باندگذر در محدوده ۲۰ تا ۴۵۰ هرتز برای حذف نویزهای فرکانس پایین و بالا استفاده می شود. سپس فیلتر ناچ در فرکانس ۵۰ یا ۶۰ هرتز، تداخل ناشی از برق شهری را حذف می کند. پس از آن، سیگنال یکسوسازی شده و برای کاهش اختلاف دامنه بین کاربران مختلف، نرمال سازی انجام می شود. در نهایت، سیگنال به پنجره های زمانی کوتاه تقسیم می شود تا استخراج ویژگی و طبقه بندی با سرعت مناسب انجام گیرد. انتخاب طول پنجره یکی از عوامل مهم در طراحی سامانه است؛ زیرا پنجره های کوتاه زمان پاسخ را کاهش داده و پنجره های بلندتر معمولاً دقت بیشتری فراهم می کنند (D. Xiong et al, 2024)، (S. Ni et al, 2024). پس از آماده سازی سیگنال، مرحله استخراج ویژگی آغاز می شود. هدف این مرحله، کاهش حجم داده ها و استخراج اطلاعاتی است که بیشترین توانایی را در تفکیک حرکات مختلف داشته باشند. ویژگی های حوزه زمان مانند (Root Mean Square (RMS)، Mean Absolute Value (MAV)، Waveform Length (WL)، Zero Crossing (ZC) و Slope Sign Changes (SSC) به دلیل محاسبات ساده و سرعت بالا، همچنان در بسیاری از سامانه های بلادرنگ استفاده می شوند. در مقابل، ویژگی های حوزه فرکانس مانند Mean Frequency (MF) و Median Frequency (MDF) اطلاعات مفیدی درباره وضعیت عضلات و میزان خستگی آن ها ارائه می کنند (Lian et al, 2023)، (Muhammad Al-Ayyad et al, 2023).

به دلیل غیرایستایی سیگنال های عضلانی، استفاده از روش های زمان-فرکانس در سال های اخیر افزایش یافته است. تبدیل ویولت (Wavelet Transform) یکی از موفق ترین روش ها در این زمینه است که امکان تحلیل هم زمان تغییرات زمانی و فرکانسی را فراهم می کند. مطالعات مختلف نشان داده اند که ویژگی های استخراج شده با استفاده از ویولت در شرایط نویزی و هنگام تشخیص حرکات پیچیده عملکرد بهتری نسبت به روش های کلاسیک دارند. به همین دلیل، بسیاری از پژوهش های جدید از ترکیب ویژگی های حوزه زمان و زمان و فرکانس برای افزایش دقت استفاده کرده اند (Z. Wei et al, 2024)، (S. Ni et al, 2024). در کنار پیشرفت الگوریتم های پردازش، فناوری حسگرها نیز توسعه چشمگیری داشته است. استفاده از الکترودهای انعطاف پذیر، حسگرهای چاپی و تجهیزات پوشیدنی موجب افزایش کیفیت ثبت سیگنال، کاهش نویز ناشی از حرکت و افزایش راحتی کاربر شده است (D. Farina and A. Holobar, 2016). همچنین سامانه های ثبت چندکاناله امکان بررسی هم زمان فعالیت چندین عضله را فراهم کرده اند که این موضوع نقش مهمی در افزایش دقت سیستم های تشخیص حرکت و کنترل پروتزهای هوشمند ایفا می کند (Aly Medhat Moslhi et al, 2024)، (D. Xiong et al, 2024). شکل ۲ نمونه ای از سیگنال خام sEMG را نشان می دهد.



شکل ۲. نمونه سیگنال خام و سیگنال sEMG

جدول ۱. مقایسه روش‌های استخراج ویژگی در سیگنال‌های sEMG

روش استخراج ویژگی	مزایا	محدودیت	کاربرد
حوزه زمان	سرعت بالا، محاسبات ساده	حساسیت به نویز	کنترل بلادرنج
حوزه فرکانس	مناسب برای تحلیل خستگی عضله	از دست رفتن اطلاعات زمانی	تحلیل فعالیت عضلات
(Wavelet) زمان-فرکانس	مناسب برای سیگنال‌های غیرایستا	پیچیدگی محاسبات	تشخیص حرکات پیچیده
ویژگی‌های مبتنی بر یادگیری عمیق	استخراج خودکار ویژگی‌ها	نیاز به داده و توان پردازشی بالا	سامانه‌های هوشمند

۳. روش‌های هوشمند تحلیل سیگنال‌های sEMG و کنترل پروتزهای میوالکتریک

در سال‌های اخیر، افزایش پیچیدگی سامانه‌های کنترل پروتزهای هوشمند موجب شده است که استفاده از روش‌های سنتی پردازش سیگنال به‌تنهایی پاسخگوی نیازهای این حوزه نباشد. در گذشته، تشخیص حرکات دست عمدتاً بر اساس استخراج ویژگی‌های آماری و استفاده از الگوریتم‌های طبقه‌بندی کلاسیک انجام می‌شد؛ اما با توسعه هوش مصنوعی و افزایش توان پردازشی رایانه‌ها، الگوریتم‌های یادگیری ماشین و یادگیری عمیق به بخش اصلی سامانه‌های تحلیل سیگنال‌های sEMG تبدیل شده‌اند. این روش‌ها با یادگیری الگوهای پیچیده موجود در سیگنال‌های عضلانی، قادرند قصد حرکتی کاربر را با دقت بالاتری تشخیص داده و آن را به فرمان‌های کنترلی برای پروتز یا سایر تجهیزات هوشمند تبدیل کنند (Muhammad Al-Ayyad et al, 2023)، (D. Xiong et al, 2024).

در نسل نخست سامانه‌های تشخیص حرکت، الگوریتم‌هایی مانند Linear Discriminant Analysis (LDA)، Support Vector Machine (SVM)، K-Nearest Neighbor (KNN) و Random Forest (RF) بیشترین کاربرد را داشتند. این روش‌ها پس از استخراج ویژگی‌های مناسب، داده‌های آموزشی را تحلیل کرده و برای هر حرکت یک الگوی تصمیم‌گیری ایجاد می‌کردند. سادگی پیاده‌سازی، سرعت بالا و نیاز کم به توان پردازشی از مهم‌ترین مزایای این الگوریتم‌ها بود؛ با این حال، عملکرد آن‌ها وابستگی زیادی به کیفیت ویژگی‌های استخراج‌شده داشت و در مواجهه با تغییر محل الکترودها، نویز محیطی یا تفاوت‌های فیزیولوژیکی کاربران، دقت آن‌ها کاهش می‌یافت (Lian Cheng et al, 2023)، (Muhammad Al-Ayyad et al, 2023).

با گسترش کاربرد شبکه‌های عصبی عمیق، بسیاری از محدودیت‌های روش‌های سنتی برطرف شد. مهم‌ترین مزیت این شبکه‌ها، توانایی استخراج خودکار ویژگی‌ها از داده‌های خام است؛ بنابراین دیگر نیازی به طراحی دستی ویژگی‌ها وجود ندارد و مدل می‌تواند روابط پیچیده میان سیگنال‌های عضلانی و حرکات دست را به‌صورت مستقیم یاد بگیرد. این ویژگی موجب افزایش دقت تشخیص، کاهش وابستگی به دانش تخصصی استخراج ویژگی و بهبود عملکرد سیستم در شرایط واقعی شده است (Z. Wei et al, 2024)، (S. Ni et al, 2024). یکی از پرکاربردترین معماری‌های یادگیری عمیق در این حوزه، شبکه‌های عصبی کانولوشنی (CNN) هستند. این شبکه‌ها با استفاده از فیلترهای کانولوشنی، الگوهای محلی موجود در سیگنال را استخراج کرده و ویژگی‌های مؤثر را در چندین لایه یاد می‌گیرند. مطالعات متعدد نشان داده‌اند که CNN نسبت به روش‌های کلاسیک، به‌ویژه در طبقه‌بندی حرکات پیچیده انگشتان و مچ دست، عملکرد بهتری دارد و می‌تواند دقت طبقه‌بندی را به بیش از ۹۵ درصد برساند (Z. Wei et al, 2024).

در کنار CNN، شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM) نیز به دلیل توانایی مدل‌سازی وابستگی‌های زمانی، جایگاه ویژه‌ای در تحلیل سیگنال‌های sEMG پیدا کرده‌اند. سیگنال‌های عضلانی دارای ساختار زمانی هستند و نمونه‌های متوالی آن‌ها به یکدیگر وابسته‌اند. شبکه‌های LSTM با استفاده از واحدهای حافظه داخلی قادرند این وابستگی‌ها را حفظ کرده و تغییرات تدریجی فعالیت عضلات را با دقت بیشتری تحلیل کنند. به همین دلیل، این شبکه‌ها در کنترل بلادرنج پروتزها و پیش‌بینی حرکات

پیوسته عملکرد بسیار مناسبی از خود نشان داده‌اند (S. Ni et al, 2024)، (C. Lin et al, 2024). در بسیاری از پژوهش‌های جدید، برای بهره‌گیری هم‌زمان از مزایای CNN و LSTM، از ساختارهای ترکیبی استفاده شده است. در این معماری، ابتدا CNN ویژگی‌های مکانی را استخراج می‌کند و سپس LSTM وابستگی‌های زمانی را تحلیل می‌کند. نتایج این مطالعات نشان می‌دهد که ترکیب این دو شبکه نسبت به استفاده مستقل از هر یک، دقت بالاتر، پایداری بیشتر و مقاومت مناسب‌تری در برابر نویز و تغییر شرایط ثبت سیگنال دارد (Z. Wei et al, 2024)، (C. Lin et al, 2024).

یکی از مهم‌ترین پیشرفت‌های سال‌های اخیر، استفاده از معماری Transformer در تحلیل سیگنال‌های زیستی است. برخلاف CNN که بیشتر بر ویژگی‌های محلی تمرکز دارد، Transformer با استفاده از مکانیزم Self-Attention قادر است ارتباط میان تمام بخش‌های سیگنال را به صورت هم‌زمان بررسی کند. این ویژگی باعث می‌شود مدل بتواند وابستگی‌های بلندمدت موجود در سیگنال را نیز در فرآیند تصمیم‌گیری دخالت دهد و دقت طبقه‌بندی را افزایش دهد (Muhammad Al-Ayyad et al, 2023).

(Y. Liu et al, 2024). در معماری Signal Transformer، سیگنال پس از پیش‌پردازش و تقسیم به پنجره‌های زمانی، وارد لایه جاسازی (Embedding) شده و سپس توسط بلوک‌های Self-Attention تحلیل می‌شود. این معماری قادر است اهمیت نسبی هر کانال و هر بخش از سیگنال را تعیین کرده و ویژگی‌های مؤثر را بدون نیاز به استخراج دستی شناسایی کند. نتایج پژوهش‌های اخیر نشان داده‌اند که این مدل علاوه بر افزایش دقت، نسبت به تغییر محل قرارگیری الکترودها و نویزهای محیطی نیز مقاومت بیشتری دارد و گزینه‌ای مناسب برای سامانه‌های نسل آینده محسوب می‌شود (Muhammad Al-Ayyad et al, 2023)، (Y. Liu et al, 2024).

کاربرد این الگوریتم‌ها تنها به افراد دارای قطع عضو محدود نمی‌شود. یکی از مطالعات بررسی شده نشان داده است که حتی در افراد مبتلا به نقص مادرزادی اندام فوقانی نیز عضلات باقی‌مانده الگوهای الکتریکی قابل تشخیصی تولید می‌کنند. با استفاده از روش‌های مناسب پردازش سیگنال و الگوریتم‌های یادگیری عمیق، این الگوها می‌توانند برای کنترل پروتزهای هوشمند مورد استفاده قرار گیرند و استقلال عملکردی این بیماران را افزایش دهند (Aly Medhat Moslhi et al, 2024)، (Marcus A et al, 2024).

جدول ۲. مقایسه الگوریتم‌های طبقه‌بندی سیگنال‌های sEMG

الگوریتم	مزایا	محدودیت	دقت تقریبی
LDA	سرعت بالا، پیاده‌سازی ساده	مناسب مسائل ساده	۸۰-۹۰٪
SVM	دقت بالا و پایداری مناسب	وابسته به تنظیم پارامترها	۸۵-۹۵٪
Random Forest	مقاوم در برابر نویز	افزایش زمان پردازش	۸۵-۹۴٪
CNN	استخراج خودکار ویژگی	نیاز به داده آموزشی زیاد	۹۰-۹۸٪
LSTM	تحلیل وابستگی زمانی	آموزش زمان‌بر	۹۰-۹۷٪
CNN-LSTM	ترکیب ویژگی‌های مکانی و زمانی	پیچیدگی بیشتر	۹۴-۹۸٪
Signal Transformer	تحلیل وابستگی‌های بلندمدت و مقاومت در برابر نویز	نیاز به توان پردازشی بالا	۹۵-۹۹٪*

* بسته به نوع مجموعه داده و شرایط آزمایش.

۴. کاربردها، چالش‌ها و روندهای آینده

فناوری الکترومیوگرافی سطحی در سال‌های اخیر از یک ابزار تحقیقاتی به یکی از فناوری‌های کلیدی در مهندسی پزشکی، توانبخشی و رباتیک تبدیل شده است. مهم‌ترین کاربرد این فناوری در کنترل پروتزهای میوالکتریک اندام فوقانی است؛ باین حال، پیشرفت‌های اخیر موجب گسترش دامنه استفاده از آن در سامانه‌های توانبخشی، اسکلت‌های بیرونی (Exoskeleton)، ربات‌های کمکی، کنترل ویلچرهای هوشمند، تحلیل عملکرد ورزشکاران، رابط‌های انسان و ماشین و حتی سامانه‌های واقعیت مجازی شده



است. توانایی sEMG در ثبت غیرتهاجمی فعالیت عضلات باعث شده است این فناوری به یکی از مناسبترین گزینه‌ها برای تشخیص قصد حرکتی کاربران تبدیل شود (Lian Cheng et al,2023)، (D. Xiong et al,2024). در حوزه توانبخشی، سیگنال‌های sEMG نقش مهمی در ارزیابی عملکرد عضلات بیماران مبتلا به سکته مغزی، آسیب‌های نخاعی، بیماری‌های عصبی و عضلانی و اختلالات حرکتی ایفا می‌کنند. برخلاف روش‌های سنتی که عمدتاً بر ارزیابی کیفی پزشک متکی هستند، سامانه‌های مبتنی بر sEMG امکان اندازه‌گیری کمی فعالیت عضلات را فراهم کرده و روند بهبود بیمار را با دقت بیشتری نشان می‌دهند. علاوه بر این، ترکیب این فناوری با سامانه‌های بازخورد زیستی (Biofeedback) موجب افزایش مشارکت بیمار در فرآیند درمان و بهبود اثربخشی برنامه‌های توانبخشی شده است (Z. Wei et al,2024)، (C. Lin et al,2024).

یکی از مهم‌ترین کاربردهای عملی sEMG در کنترل پروتزهای میوالکتریک است. در نسل‌های اولیه این پروتزها، کاربر تنها قادر به اجرای یک حرکت در هر لحظه بود و تغییر عملکرد دستگاه نیازمند انقباض‌های خاص و از پیش تعیین شده بود. امروزه، با استفاده از شبکه‌های عصبی عمیق و مدل‌های مبتنی بر Transformer، امکان کنترل هم‌زمان چندین درجه آزادی فراهم شده است. این پیشرفت باعث شده است که حرکاتی مانند باز و بسته شدن انگشتان، چرخش مچ دست، گرفتن اجسام با اشکال مختلف و انجام فعالیت‌های روزمره با دقت و سرعت بیشتری انجام شوند (Muhammad Al-Ayyad et al,2023)، (S. Ni et al,2024). مطالعات انجام‌شده بر روی افراد دارای نقص مادرزادی اندام فوقانی نیز نشان داده‌اند که حتی در نبود کامل دست، عضلات باقی‌مانده ساعد سیگنال‌های الکتریکی قابل تحلیلی تولید می‌کنند. با استفاده از روش‌های مناسب پردازش سیگنال و الگوریتم‌های یادگیری ماشین، این سیگنال‌ها می‌توانند برای کنترل پروتزهای هوشمند مورد استفاده قرار گیرند. این موضوع اهمیت توسعه سامانه‌های شخصی‌سازی شده را برای گروه‌های مختلف بیماران نشان می‌دهد و می‌تواند نقش مهمی در افزایش استقلال عملکردی و کیفیت زندگی آنان داشته باشد (Aly Medhat Moslhi et al,2024)، (Marcus A et al,2024).

با وجود پیشرفت‌های چشمگیر، چالش‌های متعددی همچنان در مسیر توسعه سامانه‌های مبتنی بر sEMG وجود دارد. تغییر محل قرارگیری الکترودها، تعریق پوست، تغییر امپدانس الکترود، فعالیت عضلات مجاور، خستگی عضلات و تفاوت‌های آناتومیک افراد از مهم‌ترین عواملی هستند که موجب تغییر ویژگی‌های سیگنال و کاهش دقت طبقه‌بندی می‌شوند. علاوه بر این، بسیاری از مدل‌های یادگیری عمیق برای دستیابی به عملکرد مطلوب به حجم زیادی از داده‌های آموزشی نیاز دارند و جمع‌آوری چنین داده‌هایی در محیط‌های بالینی همواره امکان‌پذیر نیست (Muhammad Al-Ayyad et al,2023)، (Z. Wei et al,2024). از دیگر چالش‌های مهم می‌توان به کاهش دقت مدل‌ها هنگام انتقال از محیط آزمایشگاهی به شرایط واقعی اشاره کرد. بسیاری از الگوریتم‌ها در پایگاه‌های داده استاندارد عملکرد بسیار مطلوبی دارند، اما در استفاده روزمره به دلیل تغییر شرایط محیطی و تفاوت رفتار کاربران، دقت آن‌ها کاهش می‌یابد. به همین دلیل، توسعه روش‌های یادگیری انتقالی (Transfer Learning)، یادگیری تطبیقی (Adaptive Learning)، شخصی‌سازی مدل‌ها و استفاده از داده‌های مصنوعی (Data Augmentation) به یکی از مهم‌ترین موضوعات پژوهشی سال‌های اخیر تبدیل شده است (D. Xiong et al,2024)، (Y. Liu et al,2024).

روند تحقیقات نشان می‌دهد که آینده فناوری sEMG به سمت طراحی حسگرهای انعطاف‌پذیر، سامانه‌های پوشیدنی سبک، پردازش در لبه شبکه (Edge AI)، ادغام داده‌های sEMG با حسگرهای اینرسی (IMU) و توسعه مدل‌های مبتنی بر Transformer حرکت می‌کند. انتظار می‌رود ترکیب این فناوری‌ها نسل جدیدی از پروتزهای هوشمند، سامانه‌های توانبخشی خانگی و رابط‌های پیشرفته انسان-ماشین را ایجاد کند که از نظر سرعت، دقت و راحتی استفاده، عملکرد بسیار بهتری نسبت به سامانه‌های فعلی داشته باشند (S. Ni et al,2024)، (K. C. Wang et al,2024).



جدول ۳. مهم ترین چالش های سامانه های مبتنی بر sEMG و راهکارهای پیشنهادی

چالش	تأثیر بر عملکرد	راهکار پیشنهادی
جابه جایی الکتروود	کاهش دقت تشخیص	الکتروودهای انعطاف پذیر و کالیبراسیون خودکار
نویز محیطی	کاهش کیفیت سیگنال	فیلترهای تطبیقی و حذف نویز مبتنی بر هوش مصنوعی
خستگی عضلات	تغییر ویژگی های سیگنال	یادگیری تطبیقی و به روزرسانی مدل
تفاوت بین کاربران	کاهش قابلیت تعمیم	یادگیری انتقالی و شخصی سازی مدل
محدودیت داده	افت عملکرد یادگیری عمیق	افزایش داده و تولید داده مصنوعی

جدول ۴. مقایسه مطالعات انجام شده در حوزه تحلیل سیگنال های sEMG

مرجع	هدف پژوهش	روش یا الگوریتم	مهم ترین نتیجه
(Lian Cheng et al,2023)	مرور روش های پردازش سیگنال sEMG	مرور مطالعات	معرفی روش های استخراج ویژگی و کاربردهای sEMG
Muhammad Al-Ayyad (et al,2023)	طبقه بندی سیگنال با Signal Transformer	Transformer	افزایش دقت طبقه بندی و مقاومت بیشتر در برابر نویز
Aly Medhat Moslhi et (al,2024)	تحلیل sEMG در افراد دارای نقص مادرزادی	استخراج ویژگی و طبقه بندی	امکان کنترل پروتز از عضلات باقی مانده
(Marcus A et al.2024)	کنترل پروتزهای میوالکتریک	یادگیری ماشین	بهبود عملکرد کنترل حرکت
(D. Xiong et al,2024)	مرور تعامل انسان و ربات با EMG	Review	بررسی روندهای جدید و کاربردهای هوشمند
(Z. Wei et al,2024)	پیش بینی حرکت اندام فوقانی	CNN	افزایش دقت تشخیص حرکات
(S. Ni et ak,2024)	تشخیص حرکات دست	CNN-LSTM	بهبود تحلیل هم زمان اطلاعات زمانی و مکانی
(C. Lin et al,2024)	تخمین پیوسته حرکات دست	Transformer	افزایش دقت کنترل بلادرنگ
(Y. Liu et al,2024)	تشخیص حرکات با Transformer	Self-Attention	افزایش قابلیت تعمیم مدل
C. Lin and X. Zhang, (2024)	تخمین حرکت انگشتان	Inception + Transformer	کاهش خطای تخمین حرکت
(K. C. Wang et al,2024)	بهبود کیفیت سیگنال	TrustEMG-Net	افزایش کیفیت سیگنال پیش از طبقه بندی

۵. نتیجه گیری

نتایج این مرور نشان می دهد که الکترومیوگرافی سطحی به یکی از فناوری های کلیدی در مهندسی پزشکی، توانبخشی و کنترل پروتزهای هوشمند تبدیل شده است. پیشرفت در طراحی حسگرها، روش های پردازش سیگنال و الگوریتم های یادگیری ماشین و یادگیری عمیق، به ویژه معماری های مبتنی بر Transformer، موجب افزایش دقت تشخیص حرکات، بهبود عملکرد پروتزهای میوالکتریک و توسعه رابط های پیشرفته انسان و ماشین شده است. با وجود چالش هایی مانند نویز، تغییر محل الکتروودها، تفاوت های فیزیولوژیکی افراد و نیاز به داده های آموزشی گسترده، روند پژوهش ها نشان می دهد که استفاده از حسگرهای پوشیدنی، یادگیری انتقالی، هوش مصنوعی لبه و مدل های تطبیقی می تواند بسیاری از این محدودیت ها را برطرف کند. در مجموع، ترکیب فناوری های نوین ثبت سیگنال با الگوریتم های هوشمند، مسیر توسعه نسل آینده سامانه های توانبخشی و پروتزهای هوشمند را هموار کرده و می تواند نقش مؤثری در بهبود کیفیت زندگی افراد دارای اختلالات حرکتی ایفا کند.



منابع

Lian Cheng, Jun Li, Aiying Guo & Jianhua Zhang. **Recent advances in flexible noninvasive electrodes for surface electromyography acquisition.** Flexible Electronics volume 7, Article number: 39 (2023).

Muhammad Al-Ayyad, Hamza Abu Owida, Roberto De Fazio, Bassam Al-Naami and Paolo Visconti . **Electromyography Monitoring Systems in Rehabilitation: A Review of Clinical Applications, Wearable Devices and Signal Acquisition Methodologies.** Electronics 2023, 12, 1520.

Aly Medhat Moslhi, Hesham H. Aly and Medhat ElMessiery .**The Impact of Feature Extraction on Classification Accuracy Examined by Employing a Signal Transformer to Classify Hand Gestures Using Surface Electromyography Signals.** Sensors 2024, 24, 1259.

Marcus A. Battraw, Justin Fitzgerald, Eden J. Winslow, Michelle A. James ,Anita M. Bagley^{5,6}, Wilsaan M. Joiner& Jonathon S. Schofield .**Surface electromyography evaluation for decoding hand motor intent in children with congenital upper limb deficiency.** Scientific Reports / (2024) 14:31741.

D. Xiong, D. Zhang, Y. Chu, Y. Zhao, and X. Zhao, "**Intuitive Human-Robot-Environment Interaction With EMG Signals: A Review,**" IEEE/CAA Journal of Automatica Sinica, vol. 11, no. 5, pp. 1075–1091, 2024.

Z. Wei, Z. Q. Zhang, and S. Q. Xie, "**Continuous Motion Intention Prediction Using sEMG for Upper-Limb Rehabilitation: A Systematic Review of Model-Based and Model-Free Approaches,**" IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 32, pp. 1487–1504, 2024.

S. Ni, M. A. A. Al-Qaness, D. Al-Alimi, M. Abd Elaziz, and A. A. Ewees, "**A Survey on Hand Gesture Recognition Based on Surface Electromyography: Fundamentals, Methods, Applications, Challenges and Future Trends,**" Applied Soft Computing, vol. 158, Art. no. 112235, 2024.

C. Lin, C. Zhao, J. Zhang, C. Chen, N. Jiang, D. Farina, and W. Guo, "**Continuous Estimation of Hand Kinematics From Electromyographic Signals Based on Power- and Time-Efficient Transformer Deep Learning Network,**" IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2024.

Y. Liu, X. Li, L. Yang, and H. Yu, "**A Transformer-Based Gesture Prediction Model via sEMG Sensor for Human–Robot Interaction,**" IEEE Transactions on Instrumentation and Measurement, vol. 73, 2024.

C. Lin and X. Zhang, "**Fusion Inception and Transformer Network for Continuous Estimation of Finger Kinematics From Surface Electromyography,**" Frontiers in Neurorobotics, vol. 18, 2024.

K. C. Wang, K. C. Liu, P. C. Yeh, S. Y. Peng, and Y. Tsao, "**TrustEMG-Net: Using Representation-Masking Transformer With U-Net for Surface Electromyography Enhancement,**" IEEE Journal of Biomedical and Health Informatics, 2024.

D. Farina and A. Holobar, "**Characterization of Human Motor Units From Surface EMG Decomposition,**" Proceedings of the IEEE, vol. 104, no. 2, pp. 353–373, 2016.