

Real-Time Classification of Surface Electromyogram Signal using Correntropy

M. M. Ramezani¹, A. R. Sharafat^{2*}

¹ M.Sc Graduated, School of Electrical and Computer Engineering, Tarbiat Modares University,
Tehran, Iran, dm.ramezani@gmail.com

² Professor, School of Electrical and Computer Engineering, Tarbiat Modares University, Tehran, Iran

Abstract

In this paper, we propose a novel approach for classification of surface electromyogram (sEMG) signal with a view to controlling myoelectric prosthetic devices. The sEMG signal generated during isometric contraction is modeled by a stochastic process whose probability density function (PDF) is non-Gaussian for low levels of applied force. Since the PDF of ambient noise is assumed to be Gaussian, we extract correntropy features, as they contain information on non-Gaussian components (the sEMG signal) only; and utilize the linear discriminant analysis (LDA) to classify the sEMG signal using correntropy features. Our proposed method has lower classification error and requires much less computations as compared to other existing advanced methods.

Key words: Classification, Correntropy, Gaussain kernel, Myoelectric prosthesis, Pattern recognition, Surface Electromyogram Signal.

* Corresponding author

Address: Ahmad Reza Sharafat, School of Electrical and Computer Engineering, Tarbiat Modares, P. O. Box 141155-194, Tehran, Iran

Tel: +98 21 82884353

Fax: +98 21 82884325

E-mail: sharafat@modares.ac.ir

دسته‌بندی بی‌درنگ سیگنال الکترومایوگرام سطحی با استفاده از کورنتروپی

محمد مهدی رضانی^۱، احمدرضا شرافت^{۲*}

^۱ کارشناس ارشد، گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران dm.ramezani@gmail.com

^۲ استاد، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران

چکیده

در این مقاله با استفاده از کورنتروپی، روشی مؤثر برای دسته‌بندی سیگنال الکترومایوگرام سطحی به منظور کنترل پروتزهای مایوالکتریک ارائه شده است. چون سیگنال الکترومایوگرام سطحی در دامنه‌های پائین نیرو ماهیتی غیرگوسی دارد درحالی‌که اغتشاش محیط گوسی فرض می‌شود، از کورنتروپی برای استخراج ویژگی از این سیگنال استفاده می‌کنیم؛ زیرا کورنتروپی تنها دربرگیرنده اطلاعات مربوط به مؤلفه‌های غیرگوسی است و تخمین آن از نمونه‌های محدود بسیار ساده است. سپس با به‌کارگیری ویژگی‌های استخراج شده، از طبقه‌بندی کننده آنالیز تفکیک خطی برای دسته‌بندی سیگنال الکترومایوگرام سطحی استفاده می‌کنیم. نتایج به‌دست آمده با استفاده از روش پیشنهادی این مقاله، در مقایسه با نتایج سایر روش‌های پیشرفته شناسایی الگوی سیگنال الکترومایوگرام سطحی هم بهبود یافته و هم محاسبات کمتری دارد.

کلیدواژگان: پروتز مایوالکتریک، تشخیص الگو، سیگنال الکترومایوگرام سطحی، طبقه‌بندی، کرنل گوسی، کورنتروپی.

*عهده‌دار مکاتبات

نشانی: تهران، دانشگاه تربیت مدرس، دانشکده مهندسی برق و کامپیوتر، صندوق پستی ۱۹۴-۱۴۱۱۵


تلفن: ۸۲۸۸۴۳۵۳ دورنگار: ۸۲۸۸۴۳۲۵ پیام‌نگار: sharafat@modares.ac.ir

۱- مقدمه

مصرفی کنترل کننده‌های داخلی پروتزها ایجاد شد. استفاده از این روش‌ها موجب بهبود پایداری و درستی راهکارهای مبتنی بر تشخیص الگو شده‌اند [۶].

در گذشته، سیستم‌های کنترل مایوالکتتریک از سیگنال الکترومایوگرام گذرا به‌عنوان ورودی کنترل استفاده می‌کردند. مهم‌ترین اشکال این کار این است که انقباض باید از حالت سکون آغاز شود، یعنی تغییر از یک حرکت به حرکت دیگر مجاز نیست. برای اجتناب از این مشکل، در سال‌های اخیر روش‌های کنترل پیوسته مایوالکتتریک با بهره‌گیری از تحلیل بی‌درنگ سیگنال الکترومایوگرام سطحی ارائه شده‌اند. در این سیستم‌ها، طبقه‌بندی کننده به جای عمل کردن روی ثبت‌های جداگانه سیگنال الکترومایوگرام سطحی، دنباله‌ای از تصمیم‌گیری‌ها را با استفاده از پنجره لغزان روی سیگنال الکترومایوگرام سطحی تولید می‌کند. نحوه عملکرد این سیستم‌ها در شکل ۱ نشان داده شده است، که در آن یکی از کانال‌های سیگنال الکترومایوگرام سطحی نشان داده شده و از پنجره لغزان برای ایجاد دنباله‌ای از تصمیم‌گیری‌های طبقه‌بندی استفاده شده است [۳-۸].

در شکل ۱، اندازه R_i ، مدت زمان پنجره آنالیز i ام را نشان می‌دهد، مقدار τ ، بیانگر مجموع زمان‌های تأخیر ایجاد شده برای دریافت سیگنال و عملیات پردازشی (مثل فیلتر کردن، تقویت، استخراج ویژگی، طبقه‌بندی و مانند اینها) روی سیگنال الکترومایوگرام سطحی است، و M نشان دهنده میزان حرکت پنجره لغزان بوده و مقدار آن بر سرعت تصمیم‌گیری در مورد حرکت دست مؤثر است.



شکل ۱- پنجره لغزان آنالیز (با کسب اجازه از مؤلفان برای بازنشر) [۸]

سیگنال الکترومایوگرام سطحی^۱ (sEMG) سالهاست که به عنوان ورودی کنترل کننده‌های پروتزهای توانبخشی مورد استفاده قرار گرفته است. کنترل مایوالکتتریک^۲ در دهه ۱۹۴۰ معرفی شد، و اولین اقدام برای به کارگیری سیگنال‌های الکترومایوگرام برای کنترل پروتزهای توانبخشی به‌وسیله رینهولد رایتر^۳ صورت گرفت. او نتیجه کارهای خود را در سال ۱۹۴۸ به چاپ رساند. دست رایتر دارای الکترودهایی بود که روی ساعد قرار می‌گرفت اما به دلیل به‌کارگیری لامپ خلاء و تلفات الکتریکی زیاد، از آن عملاً استفاده‌ای نشد [۱]. هرچند فناوری آن زمان برای استفاده بالینی کافی نبود، ولی با توسعه ادوات نیمه هادی و به تبع آن، کوچک‌تر شدن قطعات و کاهش توان مصرفی آنها، تحقیقات و پیشرفت‌ها در این زمینه به‌طور شگفت‌آوری افزایش یافت.

به‌طور کلی سیگنال‌های بیومدیكال^۴ افراد مختلف از هم متفاوت هستند، اما تکرار پذیری آنها در یک شخص نسبتاً بالاست. سیستم‌های مبتنی بر تشخیص الگو برای کنترل مایوالکتتریک بر این فرض استوارند که مجموعه ویژگی‌هایی که سیگنال‌های مایوالکتتریک را توصیف می‌کنند برای وضعیت‌های معین عضله قابل تکرار بوده و از یک وضعیت فعالیت عضله تا وضعیت دیگر متفاوت هستند [۲]. کنترل مایوالکتتریک مبتنی بر تشخیص الگو را می‌توان به عنوان یک مسئله طبقه‌بندی با ناظر در نظر گرفت که در آن داده‌های آموزشی برای تعدادی از تکرارهای کنترل شده جمع‌آوری شده و برای هر تکرار، نوع (کلاس) حرکتی آن مشخص و ثبت می‌شود.

روش‌های پیشرفته پردازش سیگنال از تشخیص الگو، برای استخراج اطلاعات کنترلی ارزشمند از سیگنال الکترومایوگرام سطحی استفاده می‌کنند که در آن هر کلاس حرکتی با درجه‌ای از آزادی سیستم کنترل مصنوعی مطابقت دارد. اولین طرح‌های کنترل مبتنی بر تشخیص الگو در اواخر دهه ۱۹۶۰ و اوایل دهه ۱۹۷۰ پیشنهاد شدند [۳-۵]. از آن به بعد، بهبودهای فوق‌العاده‌ای در تشخیص الگو (استخراج ویژگی و طبقه‌بندی کننده‌ها)، همچنین سرعت، اندازه و توان

¹ Surface ElectroMyoGram

² Myoelectric Control

³ Reinhold Reiter

⁴ Biomedical

ضرب‌های داخلی بیانگر مشابهت بین بردارهاست، این تابع هم بیانگر برهم کنش‌های دوتایی بردارهای ویژگی برحسب تأخیر زمانی معینی در فضای ورودی است، و هم توزیع آماری و هم تغییرات زمانی را در بر می‌گیرد. تاکنون برای کورنتروپی کاربردهای متعددی از جمله به‌کارگیری در پردازش تصویر [۱۹]، جداسازی کور منابع [۲۰]، تعیین وجود و یا عدم وجود ساختار غیرخطی در سیستم‌ها [۲۱]، آنالیز غیرخطی مؤلفه‌های اصلی [۲۲] و فیلترهای تطبیقی مبتنی بر کورنتروپی [۲۳، ۲۴] ارائه شده است.

در این مقاله، کورنتروپی سیگنال الکترومایوگرام سطحی ثبت شده به عنوان ویژگی‌های سیگنال مذکور به‌دست می‌آید و برای طبقه‌بندی سیگنال‌های یک پایگاه معتبر سیگنال‌های الکترومایوگرام سطحی، سودمندی آن در مقایسه با سایر روش‌های پیشرفته موجود نشان داده می‌شود.

در ادامه، در مورد کرنل^{۱۱} گوسی و مفهوم هندسی آن و سپس کورنتروپی و خصوصیات آن توضیحاتی داده خواهد شد. پس از آن در مورد پایگاه داده سیگنال الکترومایوگرام مورد استفاده در این مقاله اطلاعاتی ارائه می‌شود و آزمایش‌ها و نتایج دسته‌بندی سیگنال الکترومایوگرام سطحی با استفاده از روش پیشنهادی در این مقاله را مطرح می‌گردد.

۲- مفهوم هندسی کرنل

تابع کرنل (κ)، تابعی انتگرال‌پذیر؛ حقیقی و غیرمنفی است که برای مشخص کردن یک نگاشت مورد استفاده قرار می‌گیرد و دو شرط مندرج در رابطه (۱) را برآورده می‌کند:

$$\int_{-\infty}^{+\infty} \kappa(u) du = 1 \quad (1)$$

$$\kappa(-u) = \kappa(u) \text{ for all values of } u$$

به طور معمول، انواع مختلفی از توابع کرنل استفاده می‌شوند که یکی از مهم‌ترین آنها کرنل گوسی است که به‌وسیله رابطه (۲) تعریف می‌شود:

$$\kappa(x-y) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (2)$$

که x و y متغیرهای تصادفی، کرنل گوسی و σ پهنای باند کرنل است. فرض کنید x_f یک فرایند تصادفی و

محدودیت‌های زمانی ایجاد شده توسط سیستم ایجاب می‌کنند که زمان تأخیر t ، کوتاه‌تر از میزان لغزش پنجره M باشد. به عبارت دیگر، پردازشگر قبل از این که گروه بعدی داده‌ها فرا برسد باید مجموعه ویژگی‌ها را محاسبه کرده و تصمیم‌گیری را انجام دهد [۷].

سیگنال الکترومایوگرامی که در شرایط انقباض عضلانی ایزومتریک^۵ از روی سطح پوست آشکار می‌شود، به صورت یک فرایند تصادفی مدل می‌شود. صرف نظر از چند تحقیق انگشت‌شمار که به بررسی تابع توزیع سیگنال الکترومایوگرام سطحی پرداخته‌اند [۹-۱۳]؛ در بسیاری از تحقیقات گذشته تابع توزیع این سیگنال، گوسی^۶ فرض شده است. در مراجع [۹، ۱۰] نشان داده شده است که در دامنه‌های پائین نیرو، تابع توزیع سیگنال الکترومایوگرام سطحی کاملاً غیرگوسی است و با افزایش این دامنه، توزیع این سیگنال به توزیع گوسی نزدیک‌تر می‌شود. در سال‌های اخیر استفاده از آمارگان مراتب بالا^۷ یا کامولنت^۸ها به عنوان روشی مفید برای آشکارسازی سیگنال‌های غیرگوسی آغشته به اغتشاش‌های گوسی مورد توجه قرار گرفته‌اند [۹]، زیرا آمارگان مراتب بالا نسبت به فرایندهای گوسی غیرحساس‌اند، یعنی آمارگان مراتب بالای آنها برابر صفر است. این ویژگی برای آمارگان مرتبه دوم صادق نیست؛ یعنی نمی‌توان از آمارگان مرتبه دوم یک فرایند غیرگوسی، برای تفکیک اغتشاش گوسی از آن فرایند استفاده کرد. همان‌طور که در مراجع [۹، ۱۱-۱۳] نشان داده شده، استفاده از آمارگان مراتب بالا (که نسبت به اغتشاش گوسی غیرحساس است) برای دسته‌بندی سیگنال الکترومایوگرام سطحی در دامنه‌های پایین نیرو (که ماهیتی غیرگوسی دارند) سودمند است.

اخیراً با الهام گرفتن از یادگیری بر مبنای تئوری اطلاعات [۱۴، ۱۵]، تابع همبستگی تعمیم یافته‌ای^۹ برای متغیرهای تصادفی به نام کورنتروپی^{۱۰} تعریف شده است [۱۶-۱۸]. این تابع شامل ممان‌های مراتب بالا بوده و تخمین آن از نمونه‌های محدود نسبت به بسط‌های متداول ممان‌ها بسیار ساده‌تر است. کورنتروپی به صورت ضرب‌های داخلی بردارها در فضای ویژگی کرنل تعریف می‌شود. چون اندازه

⁵ Isometric construction

⁶ Gaussian distribution

⁷ Higher-Order Statistics

⁸ Cumulant

⁹ Generalized Correlation Function

¹⁰ Correntropy

¹¹ Kernel

برای هر \mathbf{x}_{t_1} و \mathbf{x}_{t_2} و هر زیرمجموعه $\{c_1, \dots, c_n\}$ از اعداد حقیقی، بردارهای $\Phi(\mathbf{x}_{t_1})$ و $\Phi(\mathbf{x}_{t_2})$ وجود دارند به طوری که:

$$\kappa(\mathbf{x}_{t_1} - \mathbf{x}_{t_2}) = \langle \Phi(\mathbf{x}_{t_1}), \Phi(\mathbf{x}_{t_2}) \rangle \quad (۶)$$

رابطه (۶) نشان می‌دهد که با استفاده از کرنل گوسی (که شرایط مرسر را محقق می‌کند)، می‌توان ضرب داخلی بردارهای $\Phi(\mathbf{x}_{t_1})$ و $\Phi(\mathbf{x}_{t_2})$ در فضای ویژگی را محاسبه کرد، بدون اینکه لازم باشد نگاشت Φ را بدانیم. از طرفی ضرب داخلی بردارها بیانگر مقدار مشابهت بین آنهاست، بنابراین با استفاده از کرنل گوسی می‌توان بدون نیاز به نگاشت متغیرها به فضای غیرخطی، میزان مشابهت بین آنها را به سادگی محاسبه کرد.

۳- تعریف اتوکورنتروپی

فرض کنید \mathbf{x}_t یک فرایند تصادفی و متعلق به اعداد حقیقی باشد. نگاشت غیرخطی Φ که توسط کرنل گوسی ایجاد می‌شود، اطلاعات در لحظه t را به فضای ویژگی F نگاشت می‌کند که در آن اتوکورنتروپی^{۱۳} $V(t_1, t_2)$ که تنها دارای مقادیر حقیقی مثبت است، مشابهت فرایند تصادفی \mathbf{x}_t را در لحظات t_1 و t_2 بیان می‌کند [۱۶-۱۸]

$$V(t_1, t_2) = E[\langle \Phi(\mathbf{x}_{t_1}), \Phi(\mathbf{x}_{t_2}) \rangle_F] = E[\kappa(\mathbf{x}_{t_1} - \mathbf{x}_{t_2})] \quad (۷)$$

که $E[\cdot]$ امید ریاضی فرایند تصادفی \mathbf{x}_t و $\langle \cdot, \cdot \rangle$ نشان دهنده ضرب داخلی در فضای ویژگی F است. نام اتوکورنتروپی با توجه به مشابهت آن با تابع خودهمبستگی فرایندهای تصادفی، و این که متوسط این تابع روی تأخیرهای مختلف، بیانگر پتانسیل اطلاعات (یعنی آرگومان آنتروپی رنی^{۱۵} [۱۴، ۱۵]) است، انتخاب شده است.

با استفاده از بسط تیلور^{۱۶} برای کرنل گوسی، اتوکورنتروپی را می‌توان به صورت زیر بازنویسی کرد

$$V(t_1, t_2) = \frac{1}{\sqrt{2\pi\sigma}} \sum_{n=0}^{\infty} \frac{(-1)^n}{2^n \sigma^{2n} n!} E[\|\mathbf{x}_{t_1} - \mathbf{x}_{t_2}\|^{2n}] \quad (۸)$$

رابطه (۸) نشان می‌دهد که اتوکورنتروپی شامل همه ممات^{۱۷} های زوج فرایند تصادفی $\|\mathbf{x}_{t_1} - \mathbf{x}_{t_2}\|$ است. به طور خاص برای $n=1$ ، رابطه فوق متناسب است با:

متعلق به اعداد حقیقی باشد. تبدیل غیرخطی که توسط رابطه (۲) ایجاد می‌شود، نمونه‌های ورودی را روی کره‌ای در فضای ویژگی نگاشت می‌کند، زیرا:

$$\|\Phi(\mathbf{x}_t)\|^2 = \kappa(\mathbf{x}_t - \mathbf{x}_t) = \kappa(0) = \frac{1}{\sqrt{2\pi\sigma}} \quad (۳)$$

$\Phi(\mathbf{x}_t)$ برداری در فضای ویژگی است که از مبدأ تا نقطه نگاشت شده می‌توان ترسیم کرد و $\|\cdot\|$ بیانگر اندازه آن است. بنابراین فاصله بین بردارهای $\Phi(\mathbf{x}_{t_1})$ و $\Phi(\mathbf{x}_{t_2})$ روی کره (یعنی کوتاه‌ترین فاصله) متناسب با زاویه بین آنهاست (شکل ۲). به عبارت دیگر:


$$d(\Phi(\mathbf{x}_{t_1}), \Phi(\mathbf{x}_{t_2})) \propto \cos^{-1} \left(\frac{\langle \Phi(\mathbf{x}_{t_1}), \Phi(\mathbf{x}_{t_2}) \rangle}{\|\Phi(\mathbf{x}_{t_1})\| \|\Phi(\mathbf{x}_{t_2})\|} \right) \quad (۴)$$

$$= \cos^{-1}(\sqrt{2\pi\sigma} \kappa(\mathbf{x}_{t_1} - \mathbf{x}_{t_2}))$$

که $\langle \Phi(\mathbf{x}_{t_1}), \Phi(\mathbf{x}_{t_2}) \rangle$ بیانگر اندازه ضرب داخلی دو بردار $\Phi(\mathbf{x}_{t_1})$ و $\Phi(\mathbf{x}_{t_2})$ است. چون کرنل گوسی در رابطه (۲) تنها دارای مقادیر مثبت است، بنابراین زاویه مورد نظر تنها در بازه $[0, \pi/2]$ قرار دارد [۱۵].

نکته اصلی این نگاشت، تبدیل داده‌های \mathbf{x}_t از فضای ورودی به فضای ویژگی است، به طوری که در آن فضا می‌توان ضرب‌های داخلی بین بردارهای $\Phi(\mathbf{x}_t)$ را با استفاده از کرنل مثبت و معینی که شرایط مرسر^{۱۲} [۲۵] را محقق می‌کند، محاسبه کرد. قضیه مرسر بیان می‌کند که هر تابع کرنل پیوسته، متقارن، مثبت، و معین $\kappa(\mathbf{x}_{t_1} - \mathbf{x}_{t_2})$ به صورت ضرب نقطه‌ای بردارهای $\Phi(\mathbf{x}_{t_1})$ و $\Phi(\mathbf{x}_{t_2})$ قابل بیان است. به عبارت دیگر، اگر کرنل مثبت و معین باشد:

$$\sum_{i,j} \kappa(\mathbf{x}_{t_1} - \mathbf{x}_{t_2}) c_i c_j \geq 0 \quad (۵)$$



شکل ۲- نگاشت یک فرایند تصادفی توسط کرنل گوسی روی کره در فضای ویژگی (با کسب اجازه از مؤلفان برای بازنشر) [۱۶]

¹² Mercer

¹⁶ Taylor series

¹³ Autocorrentropy

¹⁷ Moment

¹⁴ Lag

¹⁵ Reny entropy argument

قدرت، این تابع، چگالی طیفی کورنتروپی^{۲۳} نامیده می‌شود [۱۶].

۲-۳- تعریف کورنتروپی متقاطع

کورنتروپی متقاطع^{۲۴}، که بیانگر مشابهت بین دو متغیر تصادفی اسکالر x و y است، به وسیله رابطه (۱۳) تعریف می‌شود:

$$V_{\sigma}(x, y) = E[\kappa_{\sigma}(x - y)] \quad (13)$$

چون تنها تعداد محدودی از سیگنال‌های الکترومایوگرام سطحی را در اختیار داریم $\{(x_i, y_i), i = 1, \dots, N\}$ ، از رابطه (۱۴) برای تخمین کورنتروپی استفاده می‌کنیم [۱۶-۱۸]:

$$\hat{V}_{N, \sigma}(x, y) = \frac{1}{N} \sum_{i=1}^N \kappa_{\sigma}(x_i - y_i) \quad (14)$$

ویژگی‌هایی که برای اتوکورنتروپی ذکر شدند، با اندکی تغییر برای کورنتروپی متقاطع نیز صادق هستند.

۴- پایگاه داده سیگنال الکترومایوگرام سطحی

در این مقاله از پایگاه داده در مراجع [۴، ۵] استفاده شده است. سیگنال‌های الکترومایوگرام سطحی مورد استفاده در این پایگاه داده از ۱۲ شخص سالم و به وسیله ۴ الکتروود سطحی جمع‌آوری شده‌اند. هر شخص ۶ حرکت دست را در ۴ جلسه انجام داده است. این افراد هر یک از ۶ حرکت دست را ۲ بار و هر انقباض عضله را در مدت ۵s در هر جلسه انجام داده‌اند. در مجموع هر شخص در ۴ جلسه ۶۰ ثانیه‌ای مشارکت داشته است. در جلسات اول و سوم، هر حرکت در توالی‌های از پیش تعیین شده زیر و در جلسات دوم و چهارم به صورت تصادفی اجرا شده‌اند:

۱. فلکسیون مچ^{۲۵}
۲. اکستنسیون مچ^{۲۶}
۳. سوپیناسیون ساعد^{۲۷}
۴. پروناسیون ساعد^{۲۸}
۵. بازکردن دست^{۲۹}
۶. بستن دست^{۳۰}

$$E[\|x_{t_1}\|^2] + E[\|x_{t_2}\|^2] - 2E[\langle x_{t_1}, x_{t_2} \rangle] \quad (9)$$

$$= \sigma_{x_{t_1}}^2 + \sigma_{x_{t_2}}^2 - 2R_x(t_1 - t_2)$$

که $R_x(t_1, t_2)$ کوواریانس^{۱۸} فرایند مورد نظر است. این رابطه بیانگر آن است که اطلاعات مربوط به کوواریانس (همان خودهمبستگی برای فرایندهای با میانگین صفر) در تابع جدید موجود است. همچنین با توجه به رابطه (۸)، شرط کافی برای اینکه $V(t, t - \tau) = V(\tau)$ باشد، این است که فرایند تصادفی ورودی باید روی ممان‌های زوج، ایستا^{۱۹} باشد. برای فرایند تصادفی زمان گسسته ایستا، اتوکورنتروپی را به صورت معادله (۱۰) تعریف می‌کنیم:

$$V[m] = E[\kappa(x_n - x_{n-m})] \quad (10)$$

که به سادگی توسط میانگین نمونه‌ای تخمین زده می‌شود:

$$\hat{V}[m] = \frac{1}{N - m + 1} \sum_{n=m}^N \kappa(x_n - x_{n-m}) \quad (11)$$

این تخمین برای همه طبقه‌بندی کننده‌هایی که از کرنل گوسی استفاده می‌کنند (شامل SVM^{۲۰}) با رعایت شرایط یاد شده قابل استفاده است.

۱-۳- ویژگی‌های اتوکورنتروپی

۱. اتوکورنتروپی تابعی متقارن است به عبارت دیگر $V[-m] = V[m]$
۲. اتوکورنتروپی تابعی مثبت و کران‌دار است، و $0 \leq V[m] \leq \frac{1}{\sqrt{2\pi}\sigma}$
۳. مقدار میانگین تخمین‌زن اتوکورنتروپی به طور مجانبی به تخمین پتانسیل اطلاعات به دست آمده از پنجره پارزن^{۲۱} با کرنل‌های گوسی میل می‌کند؛
۴. تخمین‌زن اتوکورنتروپی (معادله ۱۱)، بایاس ندارد و به صورت مجانبی دارای حد است؛
۵. تبدیل فوری^{۲۲} اتوکورنتروپی به صورت معادله (۱۲) تعریف می‌شود:

$$P(\omega) = \sum_{m=-\infty}^{\infty} V[m] e^{-j\omega m} \geq 0 \quad (12)$$

این تابع دارای همه ویژگی‌های تابع چگالی طیفی قدرت بوده و برای تحلیل دنباله‌های زمانی در حوزه فرکانس استفاده می‌شود. با توجه به مشابهت آن با تابع چگالی طیفی

¹⁸ Covariance

²² Fourier Transform

²⁶ Wrist Extension

³⁰ Hand Closing

¹⁹ Stationary

²³ Correntropy Spectral Density

²⁷ Forearm Supination

²⁰ State Vector Machine

²⁴ Cross Correntropy

²⁸ Forearm Pronation

²¹ Parzen

²⁵ Wrist Flexion

²⁹ Hand opening

بوده و تخمین آن از نمونه‌های محدود نسبت به بسط‌های متداول ممان‌ها بسیار ساده‌تر است.

توابع اتوکورنتروپی و کورنتروپی متقاطع به‌وسیله روابط (۱۵) و (۱۶) برآورد می‌شوند:

$$AC(m) = \frac{\sum_{n=1}^{N-m+1} \kappa(\mathbf{x}_n - \mathbf{x}_{n+m-1})}{N-m+1} \quad (15)$$

$$CC(m) = \frac{\sum_{n=1}^{N-m+1} \kappa(\mathbf{x}_n - \mathbf{y}_{n+m-1}) + \sum_{n=1}^{N-m+1} \kappa(\mathbf{y}_n - \mathbf{x}_{n+m-1})}{2(N-m+1)} \quad (16)$$

که \mathbf{x} و \mathbf{y} بردارهای مربوط به ثبت‌های سیگنال الکترومایوگرام سطحی در هر یک از ۴ کانال، σ پهنای باند کرنل، و $\kappa(\mathbf{x}-\mathbf{y})$ ، کرنل گوسی است.

در مرجع [۲۶] برای دسته‌بندی بی‌درنگ سیگنال‌های الکترومایوگرام سطحی از اتوکورنتروپی برای استخراج ویژگی استفاده شده است. در آن مقاله سیگنال‌های موجود برای استخراج ویژگی، به پنجره‌های ۲۵۶ عضوی تقسیم شدند. سپس هر یک از این پنجره‌های ۲۵۶ عضوی به ۴ تکه مساوی ۶۴ عضوی تقسیم و ویژگی‌های هر یک از این تکه‌ها تنها با استفاده از اتوکورنتروپی استخراج شدند. اگرچه این کار سبب بهبود در صحت دسته‌بندی سیگنال‌های الکترومایوگرام می‌شود، افزایش تعداد ویژگی‌های استخراج شده را نیز به همراه دارد.


برای اجتناب از این امر، در این مقاله به جای تقسیم‌بندی پنجره‌های ۲۵۶ عضوی؛ ویژگی‌های هر یک از آنها، مستقیماً با استفاده از توابع کورنتروپی متقاطع و اتوکورنتروپی در تأخیرهای زمانی مختلف استخراج شده‌اند. با این کار، تعداد ویژگی‌ها کم شده و نیاز به روش‌های کاهش ویژگی تا حد زیادی از بین می‌رود. همچنین در مرجع [۲۶] از یک شبکه عصبی مصنوعی پرسپترون^{۳۱} چند لایه برای دسته‌بندی سیگنال‌های الکترومایوگرام سطحی استفاده شده است.

در این مقاله، جلسات اول، دوم، و سوم به عنوان جلسات آموزشی و جلسه چهارم به عنوان جلسه آزمون در نظر گرفته شدند (مگر اینکه غیر از آن ذکر شود). به عبارت دیگر، ۲ جلسه با حرکات با توالی‌های معین و یک جلسه با ترتیب تصادفی به عنوان داده آموزشی در نظر گرفته شده است. در مراحل اکتساب داده و پردازش آن، محدودیت زمان حقیقی وجود دارد و تأخیر زمانی بزرگ‌تر از ۳۰۰ms، قابلیت استفاده کاربر از سیستم کنترل را کاهش می‌دهد. به این سبب، تحلیل روی پنجره‌های ۲۵۶ میلی ثانیه‌ای سیگنال الکترومایوگرام سطحی انجام می‌شود.

بیشترین خطای دسته‌بندی در گذار بین حرکات دست ایجاد می‌شود. این خطا نیز قابل پیش‌بینی است زیرا سیگنال الکترومایوگرام سطحی در گذار از یک حرکت به حرکت دیگر، وضعیتی نامعین دارد. اما به دلیل وجود اینرسی، پروتز به دسته‌بندی‌های سیگنال الکترومایوگرام سطحی در نواحی گذر پاسخ نمی‌دهد. به همین دلیل، پنجره نمونه‌ای ۲۵۶ میلی ثانیه‌ای که با نقطه گذار کلاس‌ها همپوشانی دارد؛ همراه با ۲ پنجره ۲۵۶ میلی ثانیه‌ای همسایه با آن را از داده‌های آموزشی و آزمون حذف می‌کنیم (شکل ۳).

۵- استخراج ویژگی

در این مقاله از توابع اتوکورنتروپی و کورنتروپی متقاطع برای استخراج ویژگی از سیگنال‌های الکترومایوگرام سطحی استفاده می‌شود. تابع همبستگی تعمیم یافته (کورنتروپی) به صورت ضرب‌های داخلی بردارها در فضای ویژگی کرنل تعریف می‌شود و چون ضرب‌های داخلی معیاری از مشابهت هستند، این تابع، برهم کنش‌های دوتایی بردارهای ویژگی را برحسب تأخیر زمانی معینی در فضای ورودی بیان می‌کند. این تابع شامل ممان^{۲۹}‌های مراتب بالاتر متغیرهای تصادفی



شکل ۳- حذف وضعیت‌های گذار در روش پنجره گذاری تفکیکی

(قسمت‌های سایه خورده، بخش‌های حذف شده را نشان می‌دهند) (با کسب اجازه از مؤلفان برای بازنشر) [۴].

³¹ Perceptron

در ۳ تأخیر زمانی و مقادیر اتوکورنتروپی در ۵ تأخیر زمانی محاسبه شده و از ترکیب آنها به عنوان بردار ویژگی نهایی استفاده می‌شود. با توجه به جدول ۱، میزان کاهش خطای دسته‌بندی نسبت به افزایش پیچیدگی محاسباتی ناشی از افزایش تعداد تأخیرهای زمانی بیش از ۳ برای کورنتروپی مقاطع، قابل ملاحظه نیست. در آزمایش‌های بعدی، از ترکیب ویژگی‌های فوق، برای دسته‌بندی سیگنال‌های الکترومایوگرام سطحی استفاده می‌کنیم. تعداد ویژگی‌ها را می‌توان از روابط زیر استخراج کرد:

$$20 = 5 \times \text{تأخیر زمانی} \times 4 \text{ کانال} = \text{تعداد ویژگی‌های اتوکورنتروپی}$$

$$18 = 3 \times \text{تأخیر زمانی} \times 6 \times \text{ویژگی بین کانال} = \text{تعداد ویژگی‌های اتوکورنتروپی مقاطع}$$

طی بررسی‌ها مشخص شد که مقادیر کورنتروپی کانال‌های ۱،۴ و همچنین ۳،۴ تأثیر چندانی در کاهش خطای دسته‌بندی سیگنال الکترومایوگرام سطحی ندارند، بنابراین آنها را از بردار ویژگی حذف می‌کنیم، در نتیجه بردار ویژگی نهایی دارای ۳۲ بعد خواهد بود.

۲-۶-۲- آزمایش دوم

در این آزمایش، متوسط خطای دسته‌بندی برای پهنای باندهای مختلف کرنل بررسی شده است. با توجه به نتایج نشان داده شده در شکل ۴، ملاحظه می‌شود که بهترین نتایج در پهنای باند کرنل در حدود یک حاصل می‌شود.

یکی از مشکلات شبکه‌های عصبی مصنوعی این است که آموزش آنها تا حدودی زمانبر بوده و به انبوهی از داده‌های آموزشی و تکرار آموزش نیاز دارند. به همین دلیل در این مقاله از دسته‌بندی کننده آنالیز تفکیک خطی^{۳۲} (LDA) که توانایی دسته‌بندی بی‌درنگ سیگنال‌های الکترومایوگرام سطحی را دارد، استفاده می‌کنیم.

۶- نتایج دسته‌بندی سیگنال‌های الکترومایوگرام

در این بخش، به شرح آزمایش‌های انجام شده روی پایگاه داده مورد استفاده، می‌پردازیم.

۱-۶-۱- آزمایش اول

در این آزمایش، توانمندی کورنتروپی مقاطع و اتوکورنتروپی و همچنین نحوه ترکیب تأخیرهای زمانی در محاسبه مقادیر مذکور در دسته‌بندی سیگنال‌های الکترومایوگرام سطحی مورد بررسی قرار گرفتند. پهنای باند کرنل برابر یک، و میزان لغزش پنجره برای مجموعه آموزشی برابر ۳۲ms در نظر گرفته شده است. متوسط نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی مربوط به ۱۲ نفر در جدول ۱ نشان داده شده است. مشاهده می‌شود که ترکیب اتوکورنتروپی و کورنتروپی مقاطع، کمترین خطای دسته‌بندی را ایجاد می‌کند.

با توجه به پیچیدگی محاسباتی بیشتر در استخراج کورنتروپی مقاطع نسبت به اتوکورنتروپی و نیز با توجه به نتایج نشان داده شده در جدول ۱، مقادیر کورنتروپی مقاطع

جدول ۱- نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی با استفاده از ترکیب‌های متفاوت


کورنتروپی در تأخیرهای زمانی مختلف

مقدار اتوکورنتروپی							خطای دسته‌بندی [%]	مقدار کورنتروپی مقاطع
۶ تأخیر زمانی	۵ تأخیر زمانی	۴ تأخیر زمانی	۳ تأخیر زمانی	۲ تأخیر زمانی	۱ تأخیر زمانی	۱ تأخیر زمانی		
۵/۶۳	۵/۴۴	۵/۶۲	۵/۹۲	۶/۵۲	۱۲/۴۸			
۳/۹۸	۳/۹۹	۴/۴۶	۴/۹۱	۵/۵۲	۶/۴۴	۱۴/۱۱	۱ تأخیر زمانی	
۳/۷۳	۳/۷۶	۴/۱۶	۴/۴۵	۴/۵۰	۴/۷۷	۸/۰۱	۲ تأخیر زمانی	
۳/۵۰	۳/۵۴	۳/۸۹	۴/۴۵	۴/۳۵	۴/۵۵	۵/۵۹	۳ تأخیر زمانی	
۳/۴۵	۳/۵۳	۳/۸۹	۴/۲۶	۴/۱۳	۴/۳۶	۵/۱۷	۴ تأخیر زمانی	
۳/۴۴	۳/۴۸	۳/۹۱	۴/۳۲	۴/۲۵	۴/۵۱	۴/۷۸	۵ تأخیر زمانی	
۳/۳۶	۳/۵۷	۳/۹۱	۴/۲۶	۴/۳۵	۴/۷۷	۴/۶۹	۶ تأخیر زمانی	


³² Linear Discriminant Analysis

۴-۶- آزمایش چهارم


در این آزمایش، اثر قاعده اکثریت آراء^{۳۳} (MV) و حذف وضعیت‌های گذار را در دسته‌بندی داده‌های آزمون نشان داده می‌شوند. تحلیل سیگنال الکترومایوگرام سطحی روی پنجره‌های ۲۵۶ میلی ثانیه‌ای انجام می‌شود، اما با استفاده از پنجره‌های لغزان همپوشان، به جای یک تصمیم‌گیری در هر پنجره ۲۵۶ میلی ثانیه‌ای؛ بسته به میزان لغزش پنجره، چندین تصمیم‌گیری انجام می‌گیرد. با توجه به این امر، می‌توان هریک از تصمیم‌گیری‌های مجاور را با یکدیگر ترکیب کرد تا بدین وسیله صحت دسته‌بندی بهبود یابد. ساده‌ترین روش برای پس‌پردازش توالی دسته‌بندی حرکات دست، این است که اکثریت آراء تصمیم‌گیری‌های اخیر را در نظر بگیریم. اکثریت آراء با استفاده از دسته‌بندی کنونی و هریک از دسته‌بندی‌های مربوط به پنجره اخیر به دست می‌آید. در این آزمایش، تصمیم‌گیری کنونی با ۸ تصمیم‌گیری پیشین ترکیب می‌شود، زیرا میزان لغزش پنجره برابر ۳۲ms در نظر گرفته شده است. شایان ذکر است استفاده از قاعده اکثریت آراء، سبب کاهش خطا در نقاطی غیر از گذر از یک حرکت به حرکت دیگر می‌شود (شکل ۶). نتایج این آزمایش در شکل ۷ نشان داده شده است.



شکل ۶- قاعده اکثریت آراء (با کسب اجازه از مؤلفان برای باز نشر) [۷]




شکل ۷- تأثیر استفاده از قاعده اکثریت آراء در دسته‌بندی سیگنال‌های الکترومایوگرام سطحی



شکل ۴- نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی با استفاده از کورتروپی برای پهنای باندهای مختلف کرنل


۳-۶- آزمایش سوم

در این آزمایش، اثر پنجره‌گذاری تفکیکی و پنجره‌های همپوشان با همپوشانی‌های ۳۲، ۶۴ و ۱۲۸ میلی‌ثانیه داده‌های آموزشی در دسته‌بندی سیگنال الکترومایوگرام سطحی بررسی شدند. همان‌طور که در شکل ۵ مشاهده می‌شود پنجره‌های همپوشان با لغزش ۳۲ میلی‌ثانیه‌ای کمترین خطای دسته‌بندی را در مقایسه با بقیه پنجره‌ها ایجاد می‌کنند. این نتیجه کاملاً منطقی است، زیرا پنجره‌های همپوشان در مجموعه آموزشی، داده‌های آموزشی بیشتری را نسبت به پنجره‌های مجزا از هم ایجاد می‌کنند. هرچند پنجره‌های همپوشان، سبب افزایش هزینه محاسباتی و افزایش حجم داده‌های آموزشی می‌شوند، اما این امر هنگامی اهمیت دارد که زمان طولانی برای آموزش مطلوب نباشد.



شکل ۵- اثر پنجره‌گذاری روی صحت دسته‌بندی سیگنال الکترومایوگرام سطحی

³³ Majority Vote



شکل ۹- اثر استفاده از پهنای باندهای کرنل انتخابی بر دسته‌بندی صحیح سیگنال‌های الکترومایوگرام سطحی

۷- بحث

در این مقاله از مقدار کورنتروپی به عنوان ویژگی مؤثر برای دسته‌بندی سیگنال الکترومایوگرام سطحی استفاده شد و در مجموع ۶ آزمایش انجام گرفت. در آزمایش اول یکبار از اتوکورنتروپی و کورنتروپی متقاطع به تنهایی، و بار دیگر از ترکیب آنها به عنوان بردار ویژگی بهره گرفتیم و با مقایسه نتایج حاصل شده نشان دادیم که ترکیب این ویژگی‌ها سبب کاهش خطای دسته‌بندی سیگنال‌های الکترومایوگرام سطحی می‌شود. از طرفی با مقایسه روابط (۱۵) و (۱۶) مشخص می‌شود که پیچیدگی محاسباتی کورنتروپی متقاطع تقریباً دو برابر اتوکورنتروپی است. با در نظر گرفتن این موضوع و همچنین با توجه به این که تعداد تأخیرهای زمانی بالاتر از ۳ در محاسبه ویژگی‌های کورنتروپی متقاطع کمک چندانی به کاهش خطای دسته‌بندی نمی‌کردند، مقادیر کورنتروپی متقاطع را تنها در ۳ تأخیر زمانی و مقادیر اتوکورنتروپی را در ۵ تأخیر زمانی محاسبه کردیم.


در آزمایش دوم به ارزیابی میزان مشارکت ممان‌های مراتب بالا در دسته‌بندی سیگنال‌های الکترومایوگرام سطحی پرداختیم. برای این منظور اثر پهنای باند کرنل مورد بررسی

۵-۶- آزمایش پنجم

در این آزمایش، اثر تعداد داده‌های آموزشی بر صحت دسته‌بندی سیگنال‌های الکترومایوگرام سطحی نشان داده می‌شود. در شکل ۸، مشاهده می‌شود که با کاهش داده‌های آموزشی به یک جلسه، خطای دسته‌بندی افزایش قابل ملاحظه‌ای دارد. همچنین مقادیر کورنتروپی با دو جلسه آموزشی (یک جلسه با توالی‌های معین و یک جلسه با ترتیب تصادفی)، برای ایجاد حداقل خطای دسته‌بندی کفایت می‌کند.

۶-۶- آزمایش ششم

در این آزمایش، نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی برای پهنای باند کرنل انتخابی مورد توجه قرار گرفته است. در شکل ۹، مشاهده می‌شود که با انتخاب پهنای باند کرنل بهینه برای هر نفر، می‌توان خطای دسته‌بندی را تا حد زیادی کاهش داد. جدول ۲، مقادیر پهنای باند کرنل بهینه را که بهترین نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی را برای هر نفر نتیجه می‌دهند، نشان می‌دهد.




شکل ۸- تأثیر تعداد جلسات آموزشی در دسته‌بندی صحیح سیگنال‌های الکترومایوگرام سطحی


جدول ۲- مقادیر پهنای باند کرنل بهینه برای هر نفر

شماره شخص	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
پهنای باند کرنل بهینه	۰/۴	۰/۹	۰/۵	۰/۹	۱/۸	۱/۴	۱/۵	۱/۳	۰/۳	۲/۴	۱/۱	۱/۳

مشاهده می‌شود که نتیجه به دست آمده با استفاده از روش پیشنهادی در این مقاله نسبت به بهترین نتایج به دست آمده در مرجع [۴]، بهبودی در حدود ۳۰٪ را نتیجه می‌دهد. ضمن این که بردار ویژگی استفاده شده در مرجع [۴]، ۴۴ بُعدیست که در مقایسه با بردار ویژگی مورد استفاده در این مقاله (با ۳۲ بُعد)، دارای ۱۲ بعد بیشتر است. با در نظر گرفتن اینکه برای استخراج هر ویژگی باید زمان معینی صرف شود، استخراج ویژگی‌های بیشتر به زمان بیشتری نیاز دارد و به علاوه برای دسته‌بندی بردارهای ویژگی با ابعاد بالاتر، زمان بیشتری مورد نیاز است. بنابراین با توجه به نتایج حاصل از این مقاله، استفاده از کورنتروپی برای دسته‌بندی سیگنال‌های الکترومایوگرام سطحی مناسب بوده و نسبت به سایر روش‌های موجود، پیچیدگی محاسباتی کمتری دارد.



الف



ب

شکل ۱۰- نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی برای آزمودنی شماره ۱۲: الف) بدون استفاده از قاعده اکثریت آراء؛ ب) با استفاده از قاعده اکثریت آراء

قرار گرفتند و مشاهده شد که به‌طور متوسط، کمترین خطا در پهنای باند کرنل در حدود یک برای داده‌های ۱۲ نفر حاصل می‌شود.

در آزمایش سوم مشاهده شد در صورت عدم اهمیت طولانی شدن زمان آموزش برای مجموعه آموزشی؛ طرح پنجره‌های همپوشان با میزان لغزش ۳۲ms بهترین نتایج را در بر دارد. این نتیجه کاملاً منطقیست، زیرا پنجره‌های همپوشان در مجموعه آموزشی، داده‌های بیشتری را نسبت به پنجره‌های تفکیکی ایجاد می‌کنند.

در آزمایش چهارم نشان داده شد که با توجه به دسته‌بندی‌های متوالی حاصل از به‌کارگیری پنجره‌های لغزان همپوشان، می‌توان نتیجه دسته‌بندی‌های مجاور را با یکدیگر ترکیب کرد تا صحت آن بهبود یابد.

در آزمایش پنجم نشان دادیم که مقدار داده‌های آموزشی نقش مهمی در کاهش خطای دسته‌بندی دارد. در نتیجه، استفاده از مقادیر کورنتروپی در دو جلسه آموزشی (یک جلسه با توالی‌های معین و یک جلسه با ترتیب تصادفی)، موجب کاهش خطای دسته‌بندی خواهد شد.

در آزمایش ششم مشاهده شد که با انتخاب پهنای باند کرنل بهینه برای هر نفر می‌توان متوسط خطای دسته‌بندی را کاهش داد. در شکل ۱۰، نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی برای یکی از افراد، یکبار بدون استفاده از قاعده اکثریت آراء و بار دیگر با استفاده از قاعده اکثریت آراء نشان داده شده است. همان‌طور که مشاهده می‌شود استفاده از قاعده اکثریت آراء سبب کاهش خطا در نقاطی غیر از گذر از یک حرکت به حرکت دیگر می‌شود.

در مرجع [۴]، از طبقه‌بندی کننده مدل مخلوط گوسی برای دسته‌بندی سیگنال‌های الکترومایوگرام سطحی پایگاه داده این مقاله استفاده شده است. در آن مقاله از ویژگی‌های مدل خودبازگشتی^{۳۴} (AR)، ویژگی ریشه دوم میانگین مربعات^{۳۵} (RMS)، و برخی از ویژگی‌های حوزه زمان^{۳۶} (TD) استفاده شده است. در جدول ۳، نتایج دسته‌بندی سیگنال‌های الکترومایوگرام سطحی در مرجع [۴] با نتایج حاصل از روش ارائه شده در این مقاله با هم مقایسه شده‌اند.

³⁴ Auto Regressive³⁵ Root Mean Square³⁶ Time Domain

جدول ۳- خطای دسته‌بندی برای ویژگی‌ها و طبقه‌بندی کننده‌های مختلف

نتایج گزارش شده در مرجع [۴]			نتایج با استفاده از روش پیشنهادی این مقاله		شماره شخص
طبقه‌بند GMM ($M=3$) AR+RMS (F=28)	طبقه‌بند GMM (M انتخابی) AR+RMS (F=28)	طبقه‌بند GMM (M انتخابی) AR+RMS+TD (F=44)	طبقه‌بند LDA $\sigma=1$ AC+CC (F=32)	طبقه‌بند LDA (σ انتخابی) AC+CC (F=32)	
۲/۷۴	۲/۵۱	۲/۴۵	۶/۴۶	۱/۸۱	۱
۳/۹۹	۳/۷۰	۳/۹۹	۲/۰۷	۱/۳۶	۲
۵/۸۲	۵/۲۹	۲/۷۳	۳/۳۲	۱/۱۱	۳
۳/۴۰	۳/۲۲	۳/۳۷	۸/۰۴	۷/۹۲	۴
۷/۰۱	۶/۳۶	۶/۶۶	۶/۷۶	۵/۶۴	۵
۱/۴۵	۱/۴۲	۱/۰۳	۶/۲۵	۴/۰۱	۶
۳/۰۳	۲/۹۶	۲/۲۷	۱/۱۲	۰/۹۹	۷
۸/۶۷	۶/۲۱	۳/۹۹	۰/۵۸	۰/۳۹	۸
۶/۲۲	۶/۲۲	۴/۳۶	۲/۷۷	۱/۵۹	۹
۳/۹۱	۲/۴۵	۱/۵۳	۰/۴۵	۰/۱۹	۱۰
۳/۷۲	۳/۲۲	۲/۴۸	۲/۱۰	۲/۰۳	۱۱
۱/۹۳	۱/۱۴	۲/۲۲	۰/۵۲	۰/۱۳	۱۲
۴/۳۲	۳/۷۲	۳/۰۹	۳/۳۷	۲/۲۶	میانگین
F: تعداد ویژگی‌ها					

۸- جمع‌بندی

هدف اصلی در کنترل پروتزهای دست، انجام حرکات اراده شده توسط شخص معلول با دقت زیاد و به صورت بی‌درنگ است. دقت و سرعت، پارامترهای بسیار مهمی هستند که توجه به آنها در کنترل پروتزهای دست ضروریست. ولی در بسیاری از مطالعات پیشین، تنها یکی از این دو پارامتر مورد توجه قرار گرفته و بهینه شده است. در این مقاله روش نوینی برای استخراج ویژگی از سیگنال الکترومایوگرام سطحی معرفی شد و نشان دادیم که استفاده از ویژگی‌های کورنتروپی در عین محاسبات کمتر، دقت زیادی در دسته‌بندی صحیح سیگنال‌های الکترومایوگرام سطحی دارد.

مهم‌ترین نتایج حاصل شده در این مقاله عبارت‌اند از:

- نحوه ترکیب مقادیر کورنتروپی سیگنال الکترومایوگرام سطحی در تأخیرهای زمانی مختلف، برای کاهش خطای دسته‌بندی، بسیار مهم است. دیدیم که با ترکیب مقادیر اتوکورنتروپی و کورنتروپی متقاطع به ترتیب در ۵ و ۳ تأخیر زمانی و استفاده از آن به عنوان بردار ویژگی، کمترین خطای دسته‌بندی به دست می‌آید.

- با توجه به رابطه (۸)، کورنتروپی شامل همه ممان‌های زوج متغیر تصادفی است. استفاده از ممان‌های مراتب بالاتر اطلاعات در کورنتروپی، به وسیله پهنای باند کرنل کنترل می‌شود. معمولاً پهنای باند کرنل به صورت تجربی تعیین می‌شود. با انتخاب بهترین پهنای باند کرنل برای هر نفر، می‌توان خطای دسته‌بندی سیگنال‌های الکترومایوگرام را تا حد زیادی کاهش داد.

- با توجه به دسته‌بندی‌های مکرر و متوالی در نتیجه استفاده از پنجره‌های لغزان دارای همپوشانی، می‌توان دسته‌بندی‌های مربوط به هر پنجره آنالیز را با هم ترکیب کرده و اکثریت آراء آنها را در نظر گرفت.

- در صورتی که طولانی شدن زمان آموزش مهم نباشد، استفاده از پنجره‌های همپوشان در مقایسه با استفاده از پنجره‌های مجزا از هم، نتایج بهتری را ارائه می‌کند.

- تعداد داده‌های آموزشی نقش مهمی را در کاهش خطای دسته‌بندی دارند. برخلاف نتایج به دست آمده در مرجع [۴]، دیدیم که استفاده از کورنتروپی در دو جلسه آموزشی (یک جلسه با توالی‌های معین و یک جلسه با ترتیب تصادفی)، برای ایجاد حداقل خطای دسته‌بندی کفایت می‌کند.

قدردانی

از آقای دکتر انگلهارت^{۳۳} که پایگاه داده سیگنال الکترومایوگرام سطحی خود را در اختیار مؤلفان قرار دادند، تشکر می‌کنیم.

مراجع

[۱] فلاح علی، کنترل تطبیقی دست سیبرنتیکی با کنترل کننده شبکه عصبی، رساله دکترا؛ دانشگاه تربیت مدرس، ۱۳۷۴.

[2] Hudgins B., Parker P., Scott R.N., A new strategy for multifunction myoelectric control; IEEE Trans Biomed Eng, 1993; 40(1): 82-94.

[3] Englehart K., Hudgins B., A robust, real-time control scheme for multifunction myoelectric control; IEEE Trans Biomed Eng, 2003; 50(7): 848-854.

[4] Huang Y., Englehart K.B., Hudgins B., Chan A.D.C., A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses; IEEE Trans Biomed Eng, 2005; 52(11): 1801-1811.

[5] Englehart K., Hudgins B., Chan A.D.C., Continuous multifunction myoelectric control using pattern recognition; Journal of Technology and Disability, 2003; 15(2): 95-103.

[6] Hargrove L.J., Englehart K., Hudgins B., A comparison of surface and intramuscular myoelectric signal classification; IEEE Trans Biomed Eng, 2007; 54(5): 847-853.

[7] Chan A.D.C., Green G.C., Myoelectric control development toolbox; Proc of the 30th Conf on Med and Biol Eng Society; Toronto, Canada, 2007.

[8] Englehart K., Hudgins B., Parker P.A., A wavelet-based continuous classification scheme for multifunction myoelectric control; IEEE Trans Biomed Eng, 2001; 48(3): 302-311.

[۹] نظریور کیانوش، طبقه بندی سیگنال الکترومایوگرام سطحی با استفاده از آمارگان مراتب بالا، پایان‌نامه کارشناسی ارشد؛ دانشگاه تربیت مدرس؛ ۱۳۸۴.

[10] Clancy E.A., Hogan N., Probability density of the surface electromyogram and its relation to amplitude detectors; IEEE Trans Biomed Eng, 1999; 46(6): 730-739.

[۱۱] نظریور کیانوش، شرافت احمدرضا، فیروزآبادی سیدمحمد، طبقه‌بندی سیگنال الکترومایوگرام سطحی با استفاده از آمارگان مرتبه بالا، مجله مهندسی پزشکی زیستی، دوره اول (جدید)؛ پائیز ۱۳۸۶، شماره سوم، صفحات ۱۸۹۰-۲۰۰.

[12] Nazarpour K., Sharafat A.R., Firoozabadi S.M.P.; A novel feature extraction scheme for myoelectric signals classification using higher order statistics; Proc of the

2nd Int IEEE EMBS Conf on Neural Eng, Arlington, Virginia, 2005: 5-8.

[13] Nazarpour K., Sharafat A.R., Firoozabadi S.M.P., Surface EMG signal classification using a selective mix of higher order statistics; Proc of the 27th IEEE Annual Conf on Medicine and Biology; Shanghai, China, 2005: 4208-4211.

[14] Principe J.C., Xu D., Zhao Q., Fisher J., Learning from examples with information theoretic criteria; Journal of VLSI Signal Processing-Systems, 2000; 26 (1-2): 61-77.

[15] Jenssen R., Erdogmd D., Principe J.C., Eltoft T., Towards a unification of information theoretic learning and kernel methods; IEEE Workshop on Machine Learning for Signal Processing, 2004: 93-102.

[16] Santamaria I., Pokharel P.P., Principe J.C., Generalized correlation function definition, properties, and application to blind equalization; IEEE Trans Signal Processing, 2006; 54(6): 2187-2197.

[17] Liu W., Pokharel P.P., Principe J.C., Correntropy a localized similarity measure; Proc of the Int Joint Conf on Neural Networks; Vancouver, BC, Canada, 2006: 4919-4924.

[18] Liu W., Pokharel P., Principe J., Correntropy properties and applications in non-Gaussian signal processing; IEEE Trans Signal Processing, 2007; 55(11): 5286-5298.

[19] Jeong K.H., Principe J.C., The correntropy mace filter for image recognition; Proc of the 16th IEEE Signal Processing Society Workshop on Machine Learning for Signal Processing; Arlington, 2006: 9-14.

[20] Li R., Liu W., Principe J.C., A unifying criterion for instantaneous blind source separation based on correntropy; Journal of Signal Processing, 2007; 1872-1881.

[21] Gunduz A., Hegde A., Principe J.C., Correntropy as a novel measure for nonlinearity tests; Proc of the Int Joint Conf on Neural Networks; Vancouver, BC, Canada, 2006: 1856-1862.

[22] Xu J.W., Pokharel P.P., Paiva A.R.C., Principe J.C., Nonlinear component analysis based on correntropy; Proc of the Int Joint Conf on Neural Networks; Vancouver, BC, Canada, 2006: 1851-1855.

[23] Pokharel P.P., Agrawal R., Principe J.C., Correntropy based matched filtering; IEEE Workshop on Machine Learning for Signal Processing, 2005: 341-346.

[24] Pokharel P.P., Xu J.W., Erdogmus D., Principe J.C., A closed form solution for a nonlinear wiener filter; Proc of the IEEE Int Conf on Acoustics, Speech and Signal Processing; Toulouse, France, 2006: 720-723.

[25] Vapnik V., The Nature of Statistical Learning Theory; Springer Verlag; New York, 1995: 140-146.

[۲۶] رضانی محمد مهدی، شرافت احمدرضا؛ کاهش خطا در طبقه‌بندی بی‌درنگ سیگنال‌های الکترومایوگرام سطحی با استفاده از کورتروپی؛ پانزدهمین کنفرانس مهندسی پزشکی ایران؛ دانشگاه آزاد اسلامی واحد مشهد؛ زمستان ۱۳۸۷.