

تشخیص بیماری‌های عصبی - حرکتی با تحلیل بافت تصاویر طیف سیگنال‌های ماهیچه‌ای

سیدمحمد طباطبائی^۱، دانشجوی دکتری؛ عبدالله چاله‌چاله^۲، استادیار

۱- گروه مهندسی کامپیوتر - دانشکده فنی و مهندسی - دانشگاه رازی - کرمانشاه - ایران - m.tabatabaei@pgs.razi.ac.ir

۲- گروه مهندسی کامپیوتر - دانشکده فنی و مهندسی - دانشگاه رازی - کرمانشاه - ایران - chalechale@razi.ac.ir

چکیده: مشکلات عصبی-حرکتی دربرگیرنده طیف وسیعی از بیماری‌ها هستند که موجب اختلال در عملکرد ماهیچه‌های ارادی و یا اعصاب می‌شوند. یکی از روش‌های تشخیص خودکار این بیماری‌ها، بررسی سیگنال‌های ماهیچه‌ای توسط برنامه‌های کامپیوتری است. برنامه‌هایی که به این منظور توسعه می‌یابند شامل چندین مرحله پردازش هستند که استخراج ویژگی و دسته‌بندی از مراحل اصلی آن‌ها است. در این مقاله روش مبتنی بر تحلیل بافت طیف سیگنال برای استخراج ویژگی ارائه شده است که برخلاف روش‌های زمانی، فرکانسی و زمان-فرکانسی مبتنی بر موجک، با استخراج توأمان روابط زمان و فرکانس از سیگنال‌های ماهیچه‌ای موجب تشکیل یک بردار ویژگی با قابلیت تمایز بالا و ابعاد پایین می‌گردد. همچنین، جهت دسته‌بندی ویژگی‌ها، ماشین بردار پشتیبان، k-نزدیک‌ترین همسایه، تحلیل تمایزی، رگرسیون منطقی و ترکیب آن‌ها در دو حالت کلی و با تفکیک باندهای فرکانسی مورد بررسی قرار گرفته‌اند. به منظور برآورد روش پیشنهادی در این تحقیق از پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی استفاده شده است. با توجه به نتایج به‌دست‌آمده از آزمایش‌ها، دقت دسته‌بندی ۸۹/۴۰٪ با استفاده از ماشین بردار پشتیبان با هسته RBF در حالت تفکیک باندهای فرکانسی حاصل شده است که به میزان ۳/۴۰٪ نسبت به بهترین روش قبلی دقیق‌تر است.

واژه‌های کلیدی: توزیع زمان-فرکانس، تصویر زمان-فرکانس، طیف‌نگار، تحلیل بافت، الگوی دودویی محلی، ماتریس هم‌رخداد.

Diagnosis of Neuromuscular Disorders Using Spectrogram Textural Features of EMG Signals

S. M. Tabatabaei¹, PhD. Student; A. Chalechale², Assistant Professor

1- Department of Computer Engineering, Faculty of Engineering, Razi University, Kermanshah, Iran,

Email: M.tabatabaei@pgs.razi.ac.ir

2- Department of Computer Engineering, Faculty of Engineering, Razi University, Kermanshah, Iran, Email: Chalechale@razi.ac.ir

Abstract: Neuromuscular disease includes many disorders that damage functioning of muscles or nerves. For automatic diagnosis of these abnormalities, surface EMG signals are processed using computer programs. Feature extraction and classification are two fundamental steps in processing EMG signals by the programs. This paper presents a novel approach based on textural analysis of time-frequency image of EMG signals. In contrast to previous time alone, frequency alone, and time-frequency wavelet-based approaches, exploiting relational time and frequency properties of spectral image of EMG signal, high discrimination is achieved in the form of a compact feature vector by the proposed method. To assign each feature to its respective class, various classification methods including: KNN, SVM, LDA, logic regression, and their combination are examined in two segmented and holistic modes in the present study. At last, EMG dataset in lower limb is utilized to evaluate the proposed method. Using SVM with RBF kernel to classify segmented features, the classification accuracy of 89.4% obtained by the proposed method. The obtained classification accuracy has been improved by 3.40% over the best previous result.

Keywords: Time-frequency distribution, time-frequency image, spectrogram, texture analysis, local binary pattern, grey level co-occurrence matrix.

تاریخ ارسال مقاله: ۱۳۹۵/۱۰/۰۲

تاریخ اصلاح مقاله: ۱۳۹۵/۱۱/۲۳

تاریخ پذیرش مقاله: ۱۳۹۶/۰۷/۲۸

نام نویسنده مسئول: عبدالله چاله‌چاله

نشانی نویسنده مسئول: ایران - کرمانشاه - باغ ابریشم - دانشگاه رازی - دانشکده فنی و مهندسی - گروه کامپیوتر

۱- مقدمه

برای استخراج سیگنال‌های ماهیچه‌ای از الکترودهایی استفاده می‌شود که به صورت سطحی روی پوست واقع شده و یا به صورت درون عضله‌ای، داخل ماهیچه قرار می‌گیرند [۱]. به عمل ثبت حالات مختلف سیگنال‌های ماهیچه‌ای توسط دستگاه ماهیچه‌نگار، ماهیچه‌نگاری و به نتیجه این عمل ماهیچه‌نگاشت گفته می‌شود [۲].

به منظور سنجش میزان انقباض ماهیچه‌ها و ثبت آن‌ها توسط ماهیچه‌نگار، از واحدهای حرکتی استفاده می‌شود. هر واحد حرکتی متشکل از یک فیبر عصبی و فیبرهای عضلانی متصل به آن است. جهت منقبض شدن فیبر عضلات، اختلاف پتانسیل‌هایی از فیبرهای عصبی این واحدهای حرکتی تولید می‌شود. مجموع اختلاف پتانسیل‌های واحدهای حرکتی واقع شده در ناحیه یک الکتروُد به عنوان اختلاف پتانسیل سیگنال ماهیچه‌ای در هر لحظه از زمان در نظر گرفته شده و توسط ماهیچه‌نگار به صورت سیگنال یکتای متغیر با زمان ثبت می‌گردد [۳].

یکی از کاربردهای پردازش سیگنال‌های ماهیچه‌ای تشخیص بیماری‌های عصبی-حرکتی است [۴]. در واقع این سیگنال‌ها توسط برنامه‌های کامپیوتری مورد پردازش قرار گرفته و از آن‌ها جهت تشخیص خودکار بیماری‌های عصبی-حرکتی استفاده می‌شود [۵]. به دلیل ماهیت پیش‌رونده، تشخیص دقیق و سریع این بیماری‌ها به‌ویژه در کودکان در اولویت بالایی قرار دارد [۶]. لذا در این مقاله به منظور ارائه یک چهارچوب کلی جهت تشخیص بیماری‌های عصبی-حرکتی روشی برای تشخیص بیماری‌های حرکتی اندام تحتانی ارائه شده است که هدف از آن بهبود کارایی روش‌های موجود است.

سیستم‌های خودکاری که جهت تشخیص بیماری‌های عصبی-حرکتی طراحی می‌شوند، می‌توانند در دو دسته سیستم‌های مبتنی بر اختلاف پتانسیل‌های واحدهای حرکتی و سیستم‌های مستقیم قرار گیرند [۷]. در سیستم‌های نوع اول از خصوصیات ریختی اختلاف پتانسیل‌های واحدهای حرکتی استخراج شده برای دسته‌بندی سیگنال‌های ماهیچه‌ای در سه گروه سالم، دچار ناراحتی ماهیچه‌ای و دچار بیماری اسکروز آمیوتروفیک جنبی (ALS)، استفاده می‌شود. در روش مستقیم که در این تحقیق نیز مورد استفاده قرار گرفته است، سیگنال‌های ماهیچه‌ای پنجره‌بندی شده مورد پردازش قرار گرفته و از آن‌ها ویژگی‌هایی جهت دسته‌بندی استخراج می‌شود.

استخراج ویژگی یک مرحله مهم و تأثیرگذار در این گونه سیستم‌ها است که به منظور کاهش بعد، کاهش هزینه محاسبات، امکان تعمیم‌دهی بهتر و فهم بهتر از خصوصیات اساسی سیگنال صورت می‌پذیرد [۸]. روش‌هایی که تاکنون برای استخراج خصوصیات جهت دسته‌بندی بیماری‌های عصبی-حرکتی استفاده شده‌اند در سه دسته کلی روش‌های حوزه زمان، روش‌های حوزه فرکانس و روش‌های زمان-فرکانس مبتنی بر تبدیل موجک دسته‌بندی می‌شوند [۹، ۷].

تاکنون مطالعات متعددی در زمینه تشخیص بیماری‌های عصبی-حرکتی با تحلیل سیگنال‌های ماهیچه‌ای صورت پذیرفته است. به دلیل اینکه هدف از این مقاله بهبود روش‌های استخراج خصوصیات بوده است روش‌های پیشین از این جنبه مورد بررسی قرار گرفته‌اند. روش‌های حوزه زمان روش‌هایی هستند که از اطلاعات تغییر دامنه سیگنال در حوزه زمان استفاده می‌کنند و مهم‌ترین خصوصیت آن‌ها سادگی محاسبات و سرعت آن‌ها است. مهم‌ترین روش‌های استخراج خصوصیات در حوزه زمان عبارتند از: میانگین مربعات ریشه، قدر مطلق مقدار میانگین، مقدار میانگین قدرمطلق شیب، نرخ عبور از صفر، تغییر علامت شیب و طول شکل موج [۹]. در [۱۰]، نرخ عبور از صفر، میانگین مربعات ریشه، طول شکل موج، مقدار قدرمطلق میانگین و ضرایب خودبازگشتی به عنوان ویژگی‌های زمانی جهت تشخیص بیماری‌های عصبی-حرکتی مورد استفاده قرار گرفته‌اند. همچنین، اطلاعات زمانی میانگین و انحراف از معیار در [۱۱، ۱۲] برای تشخیص بیماری پارکینسون استفاده شده‌اند. به علاوه از ویژگی زمانی ضرایب خودبازگشتی در [۱۳] به همین منظور بهره‌برداری شده است.

همان‌گونه که مشخص است روش‌های حوزه فرکانس از اطلاعات فرکانسی سیگنال به عنوان ویژگی استفاده می‌کنند. این روش‌ها عموماً برای تشخیص خستگی عضلانی با استفاده از سیگنال‌های ماهیچه‌ای مورد استفاده قرار گرفته‌اند [۱]. مهم‌ترین روش‌های حوزه فرکانس عبارتند از: چگالی طیف توان، فرکانس میانگین، فرکانس میانه، قدرت میانگین، فرکانس پیک و گشتاورهای طیفی [۹]. از ویژگی‌های فرکانسی چگالی طیف توان و طیف توان میانگین در [۱۴، ۱۵] جهت تشخیص بیماری پارکینسون استفاده شده است. همچنین در مطالعه‌ای که در سال ۲۰۱۳ صورت پذیرفته است از ترکیبی از ویژگی‌های زمان و فرکانس برای استخراج خصوصیات جهت دسته‌بندی سیگنال‌های ماهیچه‌ای مربوط به افراد سالم و افراد دچار بیماری عصبی-حرکتی پارکینسون استفاده شده است [۱۶].

در روش‌های حوزه زمان اطلاعات فرکانسی در دسترس نیستند و در روش‌های فرکانسی اطلاعات حوزه زمان از دست می‌روند، لذا برای مقابله با این مشکلات از روش‌های حوزه زمان-فرکانس مبتنی بر تبدیل موجک استفاده شده است. ضرایب تبدیل موجک و همچنین متغیرهای مربوط به این ضرایب مانند انرژی و آنتروپی موجک ویژگی‌هایی هستند که در این حوزه جهت توصیف سیگنال مورد استفاده قرار گرفته‌اند [۸]. به عنوان نمونه از ضرایب موجک در [۸، ۱۷] برای تشخیص بیماری پارکینسون استفاده شده است. همچنین این ویژگی‌ها در [۱۸، ۱۹] برای تشخیص بیماری ALS مورد بهره‌برداری قرار گرفته‌اند. مطالعات انجام شده در [۲۰، ۲۱] نیز از این ضرایب برای تشخیص بیماری‌های عصبی-حرکتی مربوط به زانو استفاده می‌نمایند. استفاده از تبدیل موجک باعث شکل‌گیری یک بردار ویژگی با ابعاد بالا خواهد شد که به کارگیری یک مرحله فشرده‌سازی مانند تحلیل مؤلفه اساسی را ضروری می‌سازد [۱].

این تصاویر در حوزه‌های موسیقی، صوت، سیگنال رادیویی، زلزله‌نگاری و پردازش سیگنال صدای انسان [۲۳] مورد استفاده قرار گرفته‌اند. همان‌گونه که ذکر شد، جهت تولید طیف‌نگارها از تبدیل فوری به زمان کوتاه استفاده می‌شود به عبارتی جهت تحلیل، ابتدا سیگنال در یک تابع پنجره ضرب شده و پنجره‌بندی می‌شود. توابع پنجره متعددی به این منظور می‌توانند به کار گرفته شوند که نمونه‌ای از آن‌ها تابع پنجره همینگ است که در این تحقیق مورد استفاده قرار گرفته است. رابطه (۱) حالت کلی این تابع پنجره را نشان می‌دهد.

$$w(n) = 0.54 - 0.46 \cos\left(2\pi \frac{n}{N}\right), \quad 0 \leq n \leq N \quad (1)$$


$$L = N + 1$$

در رابطه (۱)، L تعداد نقاطی است که برای محاسبه پنجره در نظر گرفته می‌شود. شکل ۱ نشان‌دهنده یک پنجره برای بازه زمانی با $L=128$ نمونه است. در این تحقیق برای تولید طیف‌نگار سیگنال ماهیچه‌ای از پنجره همینگ با طول ۵۱۲ میلی‌ثانیه و هم‌پوشانی ۵۱۱ میلی‌ثانیه استفاده شده است. بعد از ضرب سیگنال ورودی در تابع پنجره بر اساس رابطه (۲)، از حاصل این ضرب مطابق رابطه (۳) تبدیل فوری گرفته می‌شود.

$$X_w(t, \tau) = (X(t) w(t - \tau)) \quad (2)$$

$$Z_x^w = FT \{X_w(t, \tau)\} = \sum_{t=-\infty}^{t=+\infty} X(t) w(t - \tau) \times e^{-j2\pi f t} \quad (3)$$

در رابطه (۲)، $X(t)$ سیگنال خام ورودی و $w(t - \tau)$ تابع پنجره قرار داده شده به مرکز $t = \tau$ است. خروجی این ضرب، $X_w(t, \tau)$ است که همان سیگنال پنجره شده است. مطابق شکل ۱، تابع پنجره در مرکز خود دارای ماکزیمم مقدار است و هرچقدر به کناره‌ها حرکت می‌کنیم از این مقدار کاسته می‌شود، لذا خروجی ضرب نیز



شکل ۱: پنجره‌ی همینگ با ۱۲۸ نمونه

هدف از این مقاله ارائه یک روش مبتنی بر ویژگی‌های زمان-فرکانسی بوده است. در واقع این تحقیق روشی برای استخراج خصوصیات رابطه‌ای زمان-فرکانس از تصاویر طیف‌نگار سیگنال را پیشنهاد می‌نماید که موجب آشکار شدن روابط مابین فرکانس‌های مختلف در زمان‌های مختلف خواهد شد. همچنین به منظور کاهش طول بردار ویژگی و حذف اطلاعات غیر مهم از بردار ویژگی تشکیل شده یک مرحله انتخاب ویژگی صورت می‌پذیرد. در نتیجه روش پیشنهادشده در این مقاله یک بردار ویژگی در برگیرنده اطلاعات رابطه‌ای و توأمان زمان و فرکانس با ابعاد پایین و قابلیت تمایز بالا تولید می‌شود. به منظور بررسی میزان تأثیر روش استخراج ویژگی ارائه‌شده در این مقاله پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی مورد استفاده قرار گرفته است.

ادامه این مقاله به این صورت تنظیم شده است: اطلاعات مربوط به نحوه تولید تصاویر طیف‌نگار و توصیف‌گرهای بافت که برای استخراج خصوصیات از این تصاویر استفاده شده‌اند در بخش دوم این مقاله تشریح شده است. بخش سوم شامل دو قسمت است. در قسمت اول توضیحات مربوط به پایگاه داده استفاده شده در این مقاله و همچنین سایر پایگاه داده‌های موجود، ارائه شده و در قسمت دوم روش پیشنهادی توضیح داده شده است. بخش چهارم شامل آزمایش‌ها و نتایج به دست آمده از آن‌ها برای توصیف‌گرهای مختلف است. همچنین، این بخش بحث و مقایسه با کارهای پیشین را در بر می‌گیرد. در نهایت بخش پنجم شامل نتیجه‌گیری و پیشنهادات برای کارهای آینده است.

۲- طیف‌نگار و توصیف‌گرهای بافت

به دلیل اینکه چهارچوب کلی روش پیشنهادی مبتنی بر استخراج خصوصیات بافت از تصاویر طیف سیگنال است در قسمت اول این بخش موارد مربوط به نحوه تشکیل تصاویر طیف‌نگار توضیح داده شده است و قسمت دوم وسوم به ترتیب دربرگیرنده توضیحات مربوط به توصیف‌گرهای بافت الگوی دودویی محلی و ماتریس هم‌رخداد است.

۲-۱- طیف‌نگار

به تصویر تولیدشده از توزیع زمان-فرکانس یک سیگنال غیرثابت متغیر با زمان، تصویر زمان-فرکانس سیگنال گفته می‌شود. جهت تولید این تصاویر می‌توان از هسته‌های متفاوتی استفاده نمود [۲۲]. این هسته‌ها می‌توانند به گونه‌ای در نظر گرفته شوند که همانند تحلیل بسته‌ای موجک در فرکانس‌های بالا مشابه با فرکانس‌های پایین دقت کافی وجود داشته باشد. در صورتی که از تبدیل فوری به زمان کوتاه جهت تولید این تصاویر استفاده شود، به تصاویر تولید شده طیف‌نگار گفته می‌شود. لذا طیف‌نگارها در حالت کلی تغییر شدت محتوای فرکانسی موجود در طیف سیگنال را در هر لحظه از زمان به تصویر می‌کشند. طیف‌نگارها تاکنون به صورت گسترده‌ای در پردازش سیگنال‌های غیرثابت متغیر با زمان به کار گرفته شده‌اند. به عنوان نمونه

• در نظر گرفته خواهد شد. در نهایت الحاق کدهای به‌دست آمده الگوی دودویی محلی را در اطراف یک پیکسل تشکیل می‌دهد. رابطه (۵)، نشان‌دهنده نحوه محاسبه الگوی دودویی محلی است. در رابطه (۵)، $LBP_{P,R}^{All}$ ، الگوی دودویی محلی در یک همسایگی با شعاع R و با در نظر گرفتن P همسایه است.


$$LBP_{P,R}^{All} = \sum_{p=0}^{P-1} \xi(g_p - g_c) \quad (5)$$

$$\xi(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$$

g_p ، شدت سطح خاکستری پیکسل‌های همسایه و g_c شدت سطح خاکستری پیکسل مرکزی است. تابع $\xi(x)$ ، یک تابع علامت است که با توجه به نتیجه به‌دست آمده از تفاضل شدت سطح خاکستری پیکسل مرکزی و پیکسل همسایه، مقدار صفر و یا یک را برای آن همسایه منظور می‌نماید. شکل ۲ نمونه‌ای از محاسبه الگوی دودویی محلی در اطراف یک پیکسل با شدت ۸۳ است.

در مثال مطرح‌شده در شکل ۲، همان‌گونه که مشخص است نیمی از پیکسل‌های اطراف پیکسل مرکزی از آن شدت بیشتری دارند و نیم دیگر دارای شدت کمتری هستند، لذا این تغییر در تصویر نشان‌دهنده یک لبه است.

در نسخه اصلی الگوی دودویی محلی، نقطه شروع محاسبه کد دودویی، سمت راست‌ترین پیکسل است. لذا، این امر باعث می‌شود که این نسخه نسبت به چرخش حساس شده و موجب تولید الگوهای متفاوتی هنگام چرخیدن تصویر شود [۲۴]. $LBP_{P,R}^{ri}$ ، نسخه‌ای از الگوی دودویی محلی است که بعد از محاسبه کد دودویی، از عملگر شیفت چرخشی به راست استفاده نموده و کد تولید شده را شیفت می‌دهد تا بیشترین تعداد صفر در سمت چپ کد قرار گیرد و کوچک‌ترین عدد ممکن تولید شود. لذا این عملگر نسبت به نقطه شروع محاسبه کد دودویی غیرحساس شده و یک عملگر تغییرناپذیر با چرخش است. رابطه (۶) به‌صورت ریاضی نحوه محاسبه $LBP_{P,R}^{ri}$ را بیان می‌نماید.



$$LBP_{8,1}^{All} = 0 \times 0 + 1 \times 0 + 2 \times 0 + 4 \times 1 + 8 \times 1 + 16 \times 1 + 32 \times 1 + 64 \times 1 = 128$$

شکل ۲: محاسبه الگوی دودویی محلی در اطراف یک پیکسل با شدت

۸۳

$$LBP_{P,R}^{ri} = \min \{ROR(LBP_{P,R}^{All}, i) | i = 0, 1, \dots, P-1\} \quad (6)$$

بسته به مقدار تابع پنجره در هر لحظه متغیر بوده و در نظر گرفتن مقدار ماکزیمم تابع پنجره در مرکز به‌منظور بررسی دقیق محتوای سیگنال در لحظه $t = \tau$ از زمان است. خروجی Z_x^w در رابطه (۳)، تبدیل فوریه سیگنال پنجره شده است. به بیان دیگر Z_x^w ، معادل تبدیل فوریه زمان کوتاه سیگنال ورودی است. در پایان مطابق با رابطه (۴) با مربع نمودن بزرگی Z_x^w برای همه زمان‌ها، تصویر طیف‌نگار برای سیگنال محاسبه می‌گردد.

$$S_x^w = |Z_x^w|^2 \quad (4)$$

به دلیل اینکه در طیف‌نگارها اطلاعات زمان و فرکانس سیگنال، به‌صورت توأمان در دسترس هستند، با تحلیل این تصاویر همانند تحلیل موجک اطلاعات فرکانسی و زمانی سیگنال به‌صورت هم‌زمان آشکار می‌شوند.

۲-۲- الگوی دودویی محلی

الگوی دودویی محلی یک عملگر پردازش تصویر است که در سال ۲۰۰۲ توسط اوجالا و همکاران [۲۴] ارائه شد. یکی از کاربردهای مهم الگوی دودویی محلی شناسایی چهره [۲۵، ۲۶] و شناسایی حالت چهره [۲۷] است که از روش‌هایی مانند تبدیل موجک [۲۸] و خوشه‌بندی [۲۹] نیز برای استخراج خصوصیات جهت کاربردهای ذکر شده، استفاده شده است. علاوه بر این کاربردها، استفاده از الگوی دودویی محلی در کاربردهای متنوع دیگر ادامه دارد [۳۰]. یکی از زمینه‌های تحقیقاتی جدید استفاده از توصیف‌گر الگوی دودویی محلی به‌منظور تحلیل طیف‌نگار سیگنال‌های غیر ثابت متغیر با زمان است [۳۰]. در تحقیق جاری نیز به‌منظور کشف الگوهای زمان-فرکانسی در طیف‌نگارها از این عملگر استفاده شده است. الگوی دودویی محلی در حقیقت توصیف‌کننده ساختارهای مختلف موجود مانند: لبه‌ها با جهات مختلف، نقاط تاریک و روشن و غیره در اطراف پیکسل مرکزی است. تاکنون گونه‌های زیادی از الگوی دودویی محلی ارائه شده‌اند که هدف از آن‌ها کاربردهایی مانند: تغییرناپذیری نسبت به چرخش، تغییرناپذیری نسبت به نویز، تغییرناپذیری نسبت به مقیاس و غیره است [۳۰]. در این مقاله از نسخه اصلی الگوی دودویی محلی به همراه گونه‌های: تغییرناپذیر نسبت به چرخش، یکنواخت، و تغییرناپذیر نسبت به چرخش و یکنواخت، برای استخراج ساختارهای موجود در طیف‌نگار استفاده شده است، لذا موارد مربوطه در این قسمت توضیح داده شده‌اند.

نسخه اصلی الگوی دودویی محلی، تمام ساختارهای موجود در اطراف یک پیکسل مرکزی را توصیف می‌نماید. این ساختارها در فرم یک کد دودویی در نظر گرفته می‌شوند که از مقایسه پیکسل مرکزی با پیکسل‌های همسایه حاصل می‌شود. در واقع پیکسل‌های همسایه با پیکسل مرکزی مقایسه شده و در صورتی که مقداری بیشتر از پیکسل مرکزی داشته باشند، برای آن همسایه مقدار ۱ و در غیر این صورت مقدار

جهت متداول برای محاسبه ماتریس GLCM در این مقاله در نظر گرفته شده است. همچنین در این شکل مثالی از نحوه محاسبه ماتریس H برای فاصله یک در جهت 90° نشان داده شده است.

۳- روش پیشنهادی


در قسمت اول این بخش توضیحات مربوط به پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی ارائه شده است، و قسمت دوم دربرگیرنده مطالب مربوط به روش پیشنهادی است.

۳-۱- پایگاه داده

برخی پایگاه داده‌هایی که برای تشخیص بیماری‌های عصبی-حرکتی مورد استفاده قرار گرفته‌اند به صورت سفارشی طراحی شده‌اند [۱۹]-[۱۲] و [۱۰] و برخی قابل دستیابی به صورت عمومی و رایگان هستند. جدول ۱ دربرگیرنده پایگاه داده‌های عمومی و رایگان که در کارهای پیشین مورد استفاده قرار گرفته‌اند، است.

جدول ۱: پایگاه داده‌های مربوط به تشخیص بیماری‌های عصبی

حرکتی		
توضیحات	پایگاه داده	مرجع
۱۶ فرد سالم، ۱۳ فرد دچار بیماری ALS، ۱۵ فرد دچار بیماری پارکینسون و ۲۰ فرد دچار بیماری هانتینگتون	[۳۲]	[۱۱]
۱۰ فرد سالم، ۸ فرد دچار بیماری ALS، ۷ فرد دچار ناراحتی ماهیچه‌ای.	[۳۳]	[۷]
۱۱ نفر سالم، ۱۱ نفر دچار ناراحتی زانو	[۳۴]	[۲۱، ۲۰، ۸]



شکل ۳: نحوه محاسبه ماتریس GLCM: (الف) جهت مورد استفاده (ب) نحوه محاسبه در جهت 90° برای یک تصویر 4×4 نمونه

در این رابطه P ، تعداد همسایه‌ها، R ، شعاع محاسبه الگوی دودویی و ROR، عملگر شیفت چرخشی به راست است. لازم به ذکر است بالانویس i به معنی تغییر ناپذیری با چرخش است.

در میان الگوهای تولیدشده توسط $LBP_{p,R}^{All}$ ، تعدادی از الگوها، اطلاعات اساسی بافت را آشکار می‌سازند [۲۴]. این الگوها، یکنواخت نامیده شده و دارای حداکثر دو انتقال مابین صفر و یک در کد دودویی خود هستند. به عنوان مثال ۱۱۱۱۰۱۱۱، یک الگوی یکنواخت است. لازم به ذکر است جهت برآورد شرایط یکنواختی، کد دودویی به صورت چرخشی در نظر گرفته شده و تعداد انتقالات در ابتدا و انتهای کد نیز محاسبه می‌شود. اگر هنگام محاسبه هیستوگرام مربوط به این الگوهای دودویی محلی، برای هر الگو یک انبار به برچسبی برابر با تعداد یک‌های موجود در الگوی دودویی محلی یکنواخت در نظر گرفته شود، این الگوها علاوه بر خاصیت یکنواختی دارای خاصیت تغییرناپذیری با چرخش نیز خواهند بود. همچنین، هیستوگرام مربوط به آن‌ها دارای $P+2$ انبار برای هر ناحیه مشخص شده است که $P+1$ انبار برای حالات مختلف الگوهای یکنواخت و یک انبار برای سایر حالات یعنی الگوهای غیر یکنواخت است. رابطه (۷)، معرف الگوهای دودویی یکنواخت و تغییرناپذیر با چرخش و رابطه (۸) تعریف ریاضی یکنواختی است. بالانویس i در رابطه (۷) به معنی تغییرناپذیری با چرخش و یکنواختی است.

$$LBP_{p,R}^{riu2} = \begin{cases} \sum_{p=0}^{p-1} \xi(g_p - g_c) 2^p & \text{if } U(LBP_{p,R}) \leq 2 \\ P+1 & \text{else} \end{cases} \quad (7)$$

$$U(LBP_{p,R}) = |\xi(g_{p-1} - g_c) - \xi(g_0 - g_c)| + \sum_{p=1}^{p-1} |\xi(g_p - g_c) - \xi(g_{p-1} - g_c)| \quad (8)$$

لازم به ذکر است بعد از استخراج الگوهای موجود در یک تصویر، هیستوگرام این الگوها در حالت کلی به عنوان نماینده تصویر در نظر گرفته خواهد شد.

۳-۲- ماتریس هم‌رخداد

ماتریس هم‌رخداد به عنوان یکی از توصیف‌گرهای بافت، که روابط مابین شدت‌های پیکسلی مختلف را در جهات مختلف آشکار می‌سازد [۳۱]، در این مقاله جهت تحلیل طیف‌نگارها به کار گرفته شده است. این توصیف‌گر مطابق با رابطه (۹) تعریف می‌شود.

$$H_{\Delta x, \Delta y}(i, j) = \begin{cases} 1, & \text{if } I(l_1, l_2) = i \text{ and } I(l_1 + \Delta x, l_2 + \Delta y) = j \\ 0, & \text{Otherwise} \end{cases} \quad (9)$$

در این رابطه H ماتریس GLCM، i و j مقادیر شدت پیکسل‌های تصویر و همچنین اندیس سطر و ستون ماتریس H و $\Delta x, \Delta y$ فاصله‌هایی هستند که در جهت θ قرار دارند. مطابق شکل ۳، چهار

جدول ۲: محل قرارگیری الکترودها در پایگاه داده سیگنال‌های

ماهیه‌ای اندام تحتانی

۴	۳	۲	۱	کانال
نیم‌وتری	پهن میانی	دوسر ران	مستقیم رانی	ماهیه

با توجه به موارد ذکر شده این پایگاه داده شامل دو مجموعه سیگنال مربوط به افراد سالم و دچار ناراحتی زانو است که اطلاعات مربوط به هر مجموعه شامل سیگنال‌های ماهیه‌ای ۱۱ شخص است. برای هر شخص، سیگنال‌های مربوط به ۳ حرکت ایستادن، نشستن و راه رفتن وجود دارد، لذا هر مجموعه شامل ۳۳ سیگنال است.^۲


۲-۳- پیاده‌سازی روش پیشنهادی

همان‌گونه که ذکر شد در این مقاله روشی جهت استخراج خصوصیات از تصاویر طیف‌نگار سیگنال‌های ماهیه‌ای ارائه شده است. ارائه این روش به‌منظور برآورد اطلاعات زمان و فرکانس سیگنال به‌صورت توأمان و کشف روابط مابین آن‌ها با استفاده از توصیف‌گرهای بافت است. مراحل انجام کار در روش پیشنهادی در شکل ۵ نشان داده شده است. مطابق شکل، در مرحله اول تبدیلاتی بر روی سیگنال خام ورودی صورت می‌پذیرد. به این منظور سیگنال با آستانه‌گیری ضرایب تجزیه سطح اول تبدیل موجک سیملت ۴ با قانون انتخاب آستانه استین (SURE) حذف نویز می‌شود [۳۶]. سپس طیف‌نگار سیگنال محاسبه شده و به سطح خاکستری تبدیل می‌گردد.


شکل ۶، نمونه‌ای از طیف‌نگارهای محاسبه شده را برای سیگنال‌های نمونه از پایگاه داده سیگنال‌های ماهیه‌ای اندام تحتانی نشان می‌دهد. همان‌گونه که ذکر شد، سیگنال‌هایی که در این پایگاه داده وجود دارند مربوط به افراد سالم و افراد دچار ناراحتی‌های زانو است. قسمت الف شکل ۶ مربوط به افراد دچار ناراحتی زانو و قسمت ب مربوط به افراد سالم، برای حرکت قدم‌زدن است. مقایسه دیداری طیف‌نگار مربوط به این دو سیگنال، تفاوت بین بافت تصاویر به‌دست‌آمده از سیگنال‌های متعلق به کلاس‌های متفاوت را نشان

یکی از پایگاه داده‌هایی که در سال‌های اخیر ارائه شده و به‌صورت رایگان در دسترس است پایگاه داده سیگنال‌های ماهیه‌ای اندام تحتانی است که به‌دلیل جدید بودن و همچنین دسترسی رایگان در این مقاله برای تشخیص بیماری‌های عصبی-حرکتی مورد استفاده قرار گرفته است. این پایگاه داده قابل دستیابی از طریق منبع یادگیری ماشین دانشگاه کالیفورنیا، ایرواین است [۳۴]. سیگنال‌های ماهیه‌ای مربوط به ۲۲ مرد که ۱۱ نفر از آن‌ها دچار ناراحتی‌های زانو هستند در این پایگاه داده گردآوری شده است. هریک از افراد شرکت‌کننده در آزمایش‌ها سه حرکت نشستن، ایستادن و قدم زدن را جهت تولید سیگنال‌های ماهیه‌ای انجام داده‌اند و سیگنال‌ها توسط چهار الکتروود سطحی از ماهیه‌ای: مستقیم رانی، پهن میانی، دوسر ران، و نیم‌وتری استخراج شده‌اند. شکل ۴ نشان‌دهنده موقعیت این ماهیه‌ها در اندام تحتانی است.


نرخ نمونه‌برداری برای ثبت سیگنال‌ها معادل ۱۰۰۰ هرتز در نظر گرفته شده و ابزار ذخیره‌سازی برای ثبت، دستگاه MX8 تولید شده توسط شرکت BIOMETRICS است. محل قرارگیری الکترودها در جدول ۲ مشخص شده است.



شکل ۴: موقعیت ماهیه‌ها جهت قرارگیری الکترودها [۳۵]



شکل ۵: نمودار بلوکی روش پیشنهادی



شکل ۶: سیگنال‌های نمونه از پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی به همراه طیف‌نگارهای مربوطه

مجموع تعداد آن‌ها برابر با ۸۰٪ کل الگوهای موجود باشد. در فاز آزمایش نیز تنها همین الگوها برای محاسبه هیستوگرام بردارهای آزمایشی مورد استفاده قرار می‌گیرند.

شکل ۷ نشان‌دهنده هیستوگرام $LBP_{8,1}^{All}$ برای دو کلاس موجود در پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی است. همان‌گونه که ذکر شد، این هیستوگرام‌ها برای کلاس‌های مختلف با میانگین‌گیری خصوصیات آن‌ها به صورت عضویه ضو در بردار ویژگی به دست آمده است. مطابق با شکل ۷ سه‌الگویی که بیشترین تفاوت میانگین را مابین دو کلاس سیگنال‌های طبیعی و سیگنال‌های غیرطبیعی دارند عبارتند از: (۰۰۰۱۱۱۱۱) ۳۱، (۱۱۱۱۰۰۰۱) ۲۴۱ و (۱۱۰۰۰۱۱۱) ۱۹۹. شکل ۸ نشان‌دهنده این الگوها در همسایگی یک پیکسل است. مطابق آنچه در قسمت‌های قبلی بیان شد الگوهای دودویی محلی، نشان‌دهنده روابط پیکسلی مختلف در یک تصویر در فرم ساختارهای مختلف مانند: نقطه، لبه و غیره هستند. مطابق شکل ۸، این الگوها آشکارکننده لبه در تصویر هستند. به دلیل اینکه لبه‌ها در تصویر به معنی تغییرات شدید شدت‌های پیکسلی است، این الگوها در طیف‌نگار به معنی تغییرات

می‌دهد. پس از تشکیل طیف‌نگار سطح خاکستری، با استفاده از توصیف‌گرهای بافت مختلف: $LBP_{P,R}^{riu2}$ ، $LBP_{P,R}^{u2}$ ، $LBP_{P,R}^{ri}$ ، $LBP_{P,R}^{All}$ برای (۱۶ و $R=8$) و GLCM بردارهای ویژگی مربوطه استخراج می‌شود. لازم به ذکر است، در مرحله دوم برای استخراج بردارهای فراوانی مربوط به توصیف‌گرهای بافت، ویژگی‌ها یا به صورت کلی از تصویر استخراج می‌شوند و یا تصویر به نواحی فرکانسی با سایز یکسان تقسیم‌بندی شده و از هر ناحیه الگوهای مربوط به آن ناحیه استخراج می‌گردد.

در مرحله سوم به منظور کاهش بعد بردارهای ویژگی استخراج شده و همچنین حذف اطلاعات دارای رخداد کمتر و مشکوک به نویز [۲۴، ۳۷]، تنها الگوهایی جهت محاسبه هیستوگرام نماینده تصویر در نظر گرفته می‌شوند که شامل بیشترین اطلاعات از تصویر هستند. به این منظور، میانگین عضو به عضو بردارهای ویژگی آموزشی برای هر کلاس محاسبه می‌شود. سپس، تفاضل بردارهای میانگین برای کلاس‌ها به دست آمده و به صورت نزولی مرتب می‌گردد. در پایان، از بردار مرتب شده، الگوهایی به عنوان نماینده تصویر در نظر گرفته می‌شوند که

۴- نتایج آزمایش‌ها و مقایسه با کارهای پیشین


همان‌گونه که در بخش قبلی توضیح داده شد روش پیشنهاد شده در دو حالت کلی و تقسیم‌بندی شده و با استفاده از توصیف‌گرهای مختلف پیاده‌سازی شده است. جهت ارزیابی کارایی روش ارائه شده معیار دقت دسته‌بندی در این مقاله استفاده شده و مطابق با رابطه (۱۰) بیان می‌شود.

$$(10) \quad \text{تعداد پیش‌بینی صحیح} / \text{تعداد کل نمونه‌ها} = \text{دقت دسته‌بندی}$$

همچنین، جهت گزارش داده‌ها در جدول‌های بعدی از اعتبارسنجی متقابل ده‌لایی^۴ که یک روش رایج در برآورد دقت دسته‌بندی است استفاده شده است. در اعتبارسنجی متقابل ده‌لایی داده‌ها به ۱۰ قسمت تقسیم شده و در ۱۰ آزمایش جداگانه ۹ قسمت از داده‌ها برای آموزش و یک قسمت برای آزمایش مورد استفاده قرار می‌گیرد. به این صورت تمام داده‌ها برای آموزش و آزمایش به کار گرفته می‌شوند. لازم به ذکر است تقسیم داده‌ها به مجموعه‌های آموزش و آزمایش به صورت تصادفی صورت می‌پذیرد و دقت نهایی از میانگین دقت‌های به دست آمده در ۱۰ آزمایش مشخص می‌شود. به دلیل اینکه در پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی به طور کلی ۶۶ سیگنال در هر کانال وجود دارد که ۳۳ تا از آن‌ها مربوط به افراد سالم و ۳۳ تا مربوط به افراد دچار ناراحتی زانو هستند، این ۶۶ سیگنال به ده مجموعه (۶ یا ۷ تایی) تقسیم شده و در ۱۰ بار آزمایش ۹ مجموعه برای آموزش و یک مجموعه برای آزمایش مورد استفاده قرار می‌گیرد.

لازم به ذکر است نتایجی که در جدول‌های بعدی گزارش شده‌اند مربوط به توصیف‌گرهای بافتی می‌باشند که بیشترین دقت میانگین را برای چهار کانال تولید نموده‌اند. همچنین، نتایج مربوط به توصیف‌گر بافت ماتریس هم‌رخداد نیز به منظور مقایسه در این جدول‌ها درج شده است.


همان‌گونه که ذکر شد جهت اثبات قابلیت روش استخراج خصوصیات پیشنهاد شده در حضور دسته‌بندی‌های مختلف، ماشین بردار پشتیبان، k-نزدیک‌ترین همسایه، رگرسیون منطقی و تحلیل تمایزی در دو حالت کلی و با تفکیک باندهای فرکانسی مورد بررسی قرار گرفته‌اند.



شکل ۷: نمودار فراوانی مربوط به دو کلاس پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی

شدید فرکانسی همراه با زمان هستند. لذا، لبه‌ها، الگوهای هستند که بیشترین تمایز را در حالت میانگین مابین دو کلاس مختلف تولید می‌کنند.

در مرحله آخر، دسته‌بندی ویژگی‌ها با توجه به حالت استخراج الگوها در مرحله دو صورت می‌پذیرد. به این معنی که در حالت کلی، الگوها برای آموزش یک دسته‌بندی استفاده شده و این دسته‌بندی هنگام آزمایش برای طبقه‌بندی سیگنال‌های آزمایشی ورودی استفاده خواهد شد. در حالت استخراج الگوها از باندهای فرکانسی تفکیکی، برای الگوهای موجود در هر ناحیه یک دسته‌بندی آموزش داده شده و هنگام آزمایش، الگوهای استخراج شده مربوط به نواحی فرکانسی مختلف با استفاده از دسته‌بندی مربوط به خود طبقه‌بندی خواهند شد. در نهایت تصمیم‌گیری در مورد برچسب یک کلاس با دآوری مابین نتایج دسته‌بندی‌های مختلف برای نواحی مختلف مشخص می‌شود. منظور از تفکیک باندهای فرکانسی در نظر گرفتن خاصیت محلّیت فرکانس‌های مختلف در دسته‌بندی سیگنال‌های ورودی است. در این مقاله، از ده باند، برای تفکیک فرکانس‌ها استفاده شده است. به منظور بررسی کارایی روش استخراج خصوصیات پیشنهاد شده در حضور دسته‌بندی‌های مختلف، ماشین بردار پشتیبان، k-نزدیک‌ترین همسایه، تحلیل تمایزی و رگرسیون منطقی در مرحله دسته‌بندی مورد آزمایش قرار گرفته‌اند.



شکل ۸: الگوهای که بیشترین تمایز را مابین کلاس‌های مختلف ایجاد می‌کنند

همچنین لازم به توجه است روش پیشنهادی به‌طور کلی در حضور کلیه دسته‌بندها خوب عمل نموده است که این موضوع نشان‌دهنده قوت این روش استخراج خصوصیات است.

بالاترین دقت میانگین به‌دست آمده (برای توصیف‌گرهای مختلف) با استفاده از اطلاعات استخراج شده از کانال ۳ حاصل شده است. همچنین بیشترین دقت میانگین برای چهار کانال از توصیف‌گر $LBP_{8,1}^{riu2}$ در حالت بخش‌بندی شده به‌دست آمده است. بنابراین انتخاب توصیف‌گر و کانال مناسب جهت استخراج خصوصیات یک مرحله تأثیرگذار در دقت کلی روش پیشنهادی است که این مرحله می‌تواند به‌صورت یک فاز پیش‌آزمایشی در نظر گرفته شود.

چنانچه ذکر شد در پایگاه داده سیگنال‌های ماهیچه‌ای اندام تحتانی، بیشترین دقت میانگین با استفاده از توصیف‌گر $LBP_{8,1}^{riu2}$ به‌دست آمده است که نشان‌دهنده افزایش دقت با یکسان در نظر گرفتن ساختارهای چرخشی و یکنواخت است. در واقع یکسان در نظر گرفتن ساختارهای چرخشی به معنی حذف چرخش در الگوهای مانند لبه در تصاویر طیف‌نگار است. به دلیل اینکه لبه‌ها در طیف‌نگار به معنی تغییرات شدید فرکانسی هستند، یکسان در نظر گرفتن لبه‌ها در جهات مختلف به معنی یکسان در نظر گرفتن تغییرات فرکانسی با زمان در جهات مختلف است که به دلیل تفاوت موجود در ساختار فرکانسی سیگنال‌های موجود در دو دسته سالم و دچار ناراحتی‌های زانو، موجب تمایز بیشتر و افزایش دقت دسته‌بندی شده است. بنابراین، استفاده از توصیف‌گر $LBP_{8,1}^{riu2}$ جهت استخراج خصوصیات بافتی از کانال ۳ بهترین دقت دسته‌بندی را تولید نموده است.

در آزمایشی دیگر به‌منظور بررسی اطلاعات تمام کانال‌ها و استفاده از آن‌ها در پیش‌بینی نهایی، اطلاعات همه کانال‌ها در نظر گرفته شده و نتیجه نهایی با دآوری مابین آن‌ها با استفاده از رأی اکثریت صورت پذیرفته است. مطابق با نتایج به‌دست آمده استفاده از اطلاعات همه کانال‌ها موجب بهبود در نتیجه کلی نشده است که این موضوع به دلیل دخالت اطلاعات کانال‌هایی است که خصوصیات موجود در آن‌ها بد عمل می‌کند. بیشترین دقت به‌دست آمده از به‌کارگیری اطلاعات تمام کانال‌ها برابر $86/23\%$ با به‌کارگیری توصیف‌گر $LBP_{8,1}^{riu2}$ است که به میزان $3/17\%$ از بهترین دقت دسته‌بندی به‌دست آمده توسط همین توصیف‌گر در حالت تفکیک باندهای فرکانسی و با استفاده از اطلاعات کانال ۳ کمتر است. لذا با انتخاب کانال مناسب می‌توان از محاسبات زیاد جلوگیری نمود [۸].

در این قسمت، مقایسه‌های صورت پذیرفته با روش‌های پیشین، براساس اطلاعات حوزه زمان، اطلاعات حوزه فرکانس و روش‌های زمان-فرکانسی مبتنی بر موجک است. در روش ارائه‌شده در [۸] از نوعی الگوی دودویی محلی جهت استخراج اطلاعات زمانی سیگنال استفاده شده است. بیشترین میزان دقت دسته‌بندی حاصل شده از این روش با استفاده از دسته‌بند شبکه‌های عصبی حاصل شده است. سایر روش‌هایی که جهت استخراج خصوصیات به‌کار گرفته شده‌اند و نتایج

بنابر نتایج حاصل شده از آزمایش‌ها، در هر دو حالت بیشترین دقت دسته‌بندی میانگین (برای کانال‌ها و توصیف‌گرهای مختلف) با استفاده از ماشین بردار پشتیبان با هسته RBF حاصل شده است. بنابراین به‌منظور حفظ اختصار تنها نتایج مربوط به این دسته‌بند در جدول ۳ و جدول ۴ گزارش شده است. لازم به ذکر است جدول ۳ دربرگیرنده نتایج حاصل از روش کلی است.

جدول ۳: دقت دسته‌بندی (%) بدون استفاده از تفکیک باندهای

فرکانسی

ویژگی	کانال ۱	کانال ۲	کانال ۳	کانال ۴
$LBP_{16,2}^{riu2}$	۷۴/۲۰	۷۴/۲۰	۸۴/۸۰	۷۲/۷۰
$LBP_{8,1}^{u2}$	۸۳/۳۰	۶۹/۶۰	۸۳/۳۰	۶۹/۶۰
$LBP_{8,2}^{riu2}$	۸۳/۳۰	۷۴/۲۰	۷۵/۷۰	۷۱/۲۰
GLCM	۷۴/۲۰	۷۱/۲۰	۷۲/۷۰	۷۱/۲۰

نتایج به‌دست‌آمده از روش بخش‌بندی شده و با در نظر گرفتن باندهای فرکانسی در جدول ۴ گزارش شده است. با مقایسه جدول ۳ و جدول ۴ مشخص می‌شود که با استفاده از بخش‌بندی و محلی نمودن استخراج خصوصیات از باندهای فرکانسی دقت دسته‌بندی میانگین (برای توصیف‌گرها و کانال‌های مختلف) بیشتری در مقایسه با حالت کلی به‌دست آمده است. این موضوع نشان‌دهنده تأثیر رفتار فرکانسی محلی سیگنال در دقت روش پیشنهادی است.

جهت مقایسه، جدول ۵ بهترین نتایج به‌دست‌آمده از سایر دسته‌بندها و پارامترهای مرتبط با آن‌ها را برای روش بخش‌بندی شده نشان می‌دهد. همان‌گونه که از نتایج آزمایش‌ها مشخص است، دسته‌بند ماشین بردار پشتیبان بهتر از سایر دسته‌بندها عمل نموده و بهترین دقت دسته‌بندی از آن حاصل شده است و کمترین دقت دسته‌بندی با استفاده از دسته‌بند تحلیل تمایزی به‌دست آمده است.

جدول ۴: دقت دسته‌بندی (%) با تفکیک باندهای فرکانسی

ویژگی	کانال ۱	کانال ۲	کانال ۳	کانال ۴
$LBP_{8,1}^{riu2}$	۸۷/۹۰	۸۱/۸۰	۸۹/۴۰	۸۳/۳۰
$LBP_{8,2}^{u2}$	۸۴/۸۰	۸۱/۸۰	۸۷/۹۰	۷۸/۸۰
$LBP_{16,2}^{riu2}$	۸۷/۹۰	۷۸/۸۰	۸۶/۳۰	۷۸/۸۰
GLCM	۸۰/۳۰	۷۸/۸۰	۸۷/۹۰	۷۴/۲۰

جدول ۵: بهترین دقت دسته‌بندی (%) حاصل شده از دسته‌بندهای

گونگون با استفاده از روش تفکیک باندهای فرکانسی

دقت دسته‌بندی	پارامترها	هسته	دسته‌بند	خصوصیت
۸۹/۴۰	$\sigma=1, C=1$	RBF	SVM	$LBP_{8,1}^{riu2}$
۸۵/۸۰	$N=1$	اقلیدسی	KNN	$LBP_{8,1}^{u2}$
۸۱/۲۰	-	-	LR	$LBP_{8,1}^{riu2}$
۷۹/۷۰	کووارینانس قطری $R=$	خطی	DA	$LBP_{8,1}^{u2}$

به منظور مقایسه مورد بررسی قرار گرفته است. منظور از زمان صرف شده، زمانی است که جهت استخراج خصوصیات از سیگنال خام و یا تصاویر طیف‌نگار سیگنال نیاز است. جدول ۷ در برگزیده زمان محاسبات روش‌های مختلف است. مطابق جدول روش پیشنهادی در این مقاله علی‌رغم دستیابی به دقت بیشتر به زمان محاسباتی بیشتری نیز برای استخراج خصوصیات نیاز دارد. لازم به توجه است متغیرهای آماری به دلیل استخراج خصوصیات از حوزه زمان دارای کمترین زمان محاسبه است.

جدول ۷: مقایسه زمان استخراج خصوصیات با استفاده از روش پیشنهادی و روش‌های پیشین

زمان استخراج خصوصیات (ثانیه)	روش استخراج خصوصیات
۰/۰۳۷	متغیرهای آماری
۰/۰۴۹	انرژی و آنتروپی موجک
۰/۰۵۴	ضرایب خودکاهشی ^۳
۰/۰۶۷	$LBP_{8,1}^{nu2}$ (Proposed)

۵- نتیجه‌گیری و کارهای آینده

در این مقاله روشی جهت استخراج خصوصیات از سیگنال‌های ماهیچه‌ای برای تشخیص بیماری‌های عصبی-حرکتی ارائه شد. با استفاده از تحلیل بافت تصاویر طیف سیگنال‌های ماهیچه‌ای، اطلاعات رابطه‌ای زمان-فرکانس به صورت توأمان با استفاده از روش پیشنهادی استخراج می‌شود.

برای بررسی روش استخراج خصوصیات پیشنهاد شده در این مقاله در حضور دسته‌بندی‌های مختلف، ماشین بردار پشتیبان، رگرسیون منطقی، تحلیل تمایزی و K-نزدیک‌ترین همسایه در دو حالت کلی و با تفکیک باندهای فرکانسی مورد بررسی قرار گرفتند. نتایج به دست آمده از آزمایش‌ها نشان می‌دهد که با استفاده از ویژگی‌های رابطه‌ای زمان-فرکانس سیگنال در حالت تفکیک باندهای فرکانسی، دقت دسته‌بندی بالاتری در مقایسه با روش‌های حوزه زمان، فرکانس و روش‌های مبتنی بر اطلاعات حوزه موجک، حاصل می‌شود. همچنین به دلیل استفاده از یک مرحله انتخاب ویژگی، طول بردار ویژگی به دست آمده از روش پیشنهادی نسبت به روش‌های زمان-فرکانس مبتنی بر موجک کوتاه‌تر بوده و نیاز به مراحل فشرده‌سازی مانند تحلیل مؤلفه اساسی را غیر ضروری می‌سازد. تحلیل محاسباتی نتایج به دست آمده از آزمایش‌ها نشان‌دهنده نیاز به زمان بیشتر برای استخراج خصوصیات با استفاده از روش پیشنهادی است.

روش پیشنهاد شده در این مقاله برای دسته‌بندی خصوصیات مربوط به دو کلاس متفاوت استفاده شده است. لذا این روش می‌تواند تعمیم داده شده و برای دسته‌بندی حرکات چندگانه عضلات به کار گرفته شود.

حاصل از دسته‌بندی آن‌ها با روش ارائه شده در این مقاله مورد مقایسه قرار گرفته است عبارتند از: روش‌های حوزه زمان و فرکانس: متغیرهای آماری [۳۸، ۳۹]، ضرایب خودکاهشی [۳۹، ۴۰]، و روش‌های حوزه زمان-فرکانس: انرژی موجک و آنتروپی موجک [۴۰-۴۲] و ضرایب موجک [۲۰، ۲۱]. نتایج مربوط به این روش‌ها در جدول ۶ درج شده است. با توجه به نتایج به دست آمده، استفاده از تو صیف‌گرهای بافت جهت استخراج توأمان خصوصیات رابطه‌ای زمان-فرکانس در روش پیشنهادی، موجب بهبود دقت دسته‌بندی شده است. به دلیل اینکه در روش پیشنهادی از اطلاعات رابطه‌ای زمان و فرکانس استفاده می‌شود یعنی در بردار ویژگی حاصل شده علاوه بر حضور اطلاعات زمان و فرکانس به صورت توأمان روابط مابین فرکانس‌های مختلف در زمان‌های با استفاده از تو صیف‌گرهای بافت آشکار شده است، دقت دسته‌بندی بیشتری نسبت به سایر روش‌ها از جمله روش‌های زمانی و فرکانسی به دست آمده است. لازم به ذکر است متغیرهای آماری به کار رفته در این مقاله مجموعه: انرژی، میانگین، انحراف از معیار^۶، کجی و کشیدگی بوده‌اند. انرژی و آنتروپی موجک نیز از ضرایب تبدیل موجک در سطح اول تجزیه حاصل شده‌اند. نتایج آزمایش‌ها نشان‌دهنده برتری روش‌های تحلیل زمانی نسبت به روش‌های فرکانسی و همچنین انرژی و آنتروپی تبدیل موجک است. با این حال ضرایب موجک علی‌رغم اینکه ابعاد بالایی دارند به دلیل بردار داشتن اطلاعات زمان و فرکانس نسبت به روش‌های فرکانسی تنها و زمانی تنها بهتر عمل نموده‌اند. لازم به توجه است خصوصیات مورد مقایسه در جدول ۶ خصوصیات پایه‌ای هستند که در بسیاری از مقالات جدید نیز جهت استخراج خصوصیات مطابق با موارد مطرح شده در بخش مقدمه مقاله مورد استفاده قرار گرفته‌اند اما به دلیل اینکه هدف از مقایسه‌ها بررسی امتیاز روش استخراج خصوصیات با استفاده از تصاویر طیف‌نگار بوده است، تنها روش‌هایی در جدول ۵ بیان شده‌اند که بر روی پایگاه داده مورد استفاده در این مقاله پیاده‌سازی شده‌اند.

جدول ۶: مقایسه دقت دسته‌بندی حاصل شده از روش

پیشنهادهای روش‌های پیشین	دقت دسته‌بندی (%)
روش استخراج خصوصیات	
$LBP_{8,1}^{nu2}$ (Proposed)	۸۹/۴۰
ضرایب موجک [۲۰]	۸۶
$aLBP^{All}$	۸۴/۸۵
ضرایب موجک [۲۱]	۸۰
متغیرهای آماری	۷۲/۷۳
ضرایب خودکاهشی	۷۲/۷۳
انرژی موجک	۶۵/۱۵
آنتروپی موجک	۶۳/۶۴

از آنجایی که پیچیدگی محاسبات در روش‌های به کار گرفته شده از مرتبه $O(n)$ است (یک عدد ثابت است) ولی محاسبات زمانی متفاوت مشاهده می‌شود لذا زمان صرف شده توسط هریک از روش‌ها

مراجع

- during standardized gait tests,” In Engineering in Medicine and Biology Society (EMBC) 35th Annual International Conference of the IEEE, pp. 5781-5784, 2013.
- [17] N. H. Ghassemi, F. Marxreiter, C. F. Pasluosta, P. Kugler, J. Schlachetzki, A. Schramm and J. Klucken, “Combined accelerometer and EMG analysis to differentiate essential tremor from Parkinson's disease,” In Engineering in Medicine and Biology Society (EMBC), IEEE 38th Annual International Conference of the, pp. 672-675, 2016.
- [18] P. R. Pal, G. Goswami and N. P. Mohanty, “Expert system design based on wavelet transform and linear feature selection,” In Computer Networks and Intelligent Computing, pp. 502-510, Springer Berlin Heidelberg, 2011.
- [19] S. Kalwa and H. T. Patil, “Neuromuscular disease classification based on discrete wavelet transform of dominant motor unit action potential of EMG signal,” In Information Processing (ICIP), International Conference on, pp. 708-713, 2015.
- [20] J. Kohlschuetter, J. Peters and E. Rueckert, “Learning probabilistic features from EMG data for predicting knee abnormalities,” In XIV Mediterranean Conference on Medical and Biological Engineering and Computing, pp. 662-666, 2016.
- [21] M. Herrera-González, G. A. Martínez-Hernández, J. L. Rodríguez-Sotelo and Ó. F. Avilés-Sánchez, “Knee functional state classification using surface electromyographic and goniometric signals by means of artificial neural networks,” Ingeniería y Universidad, vol. 19, no. 1, pp. 51-66, 2015.
- [22] M. Musselman and D. Djurdjanovic, “Time-frequency distributions in the classification of epilepsy from EEG signals,” Expert Systems with Applications, vol. 39, no. 13, pp. 11413-11422, 2012.
- [23] J. L. Flanagan, *Speech Analysis Synthesis and Perception*, Springer Science & Business Media, Vol. 3, 2013.
- [24] T. Ojala, M. Pietikainen and T. Maenpaa, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 7, pp. 971-987, 2002.
- [25] H. Jin, Q. Liu, H. Lu and X. Tong, “Face detection using improved LBP under Bayesian framework,” In Image and Graphics (ICIG'04), Third International Conference on, pp. 306-309, 2004.
- [26] L. Zhang, R. Chu, S. Xiang, S. Liao and S. Z. Li, “Face detection based on multi-block lbp representation,” In International Conference on Biometrics, Springer Berlin Heidelberg, pp. 11-18, 2007.
- [27] C. Shan, S. Gong and P. W. McOwan, “Robust facial expression recognition using local binary patterns,” In Image Processing, ICIP IEEE International Conference on, vol. 2, pp. II-370, 2005.
- [28] حمید صادقی، فضائل آیت‌اللهی و ابوالقاسم اسدالله راعی، «شناسایی حالت چهره با استفاده از نرمالیزاسیون هندسی و تبدیل موجک مختلط Dual tree»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۵ شماره ۳، صفحه ۸۶-۸۰، پاییز ۹۴.
- [29] سجاد شفیع‌پور یوردشاهی، میرهادی سیدعربی، علی آقاگل‌زاده «شناسایی چهره بر اساس ظاهر در رشته‌های ویدئویی»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۵ شماره ۲، صفحه ۸۳-۷۵، تابستان ۹۴.
- [1] M. A. Oskoei and H. Hu, “Myoelectric control systems—A survey,” Biomedical Signal Processing and Control, vol. 2, no. 4, pp. 275-294, 2007.
- [2] G. Kamen and G. E. Caldwell, “Physiology and interpretation of the electromyogram,” Journal of Clinical Neurophysiology, vol. 13, no. 5, pp. 366-384, 1996.
- [3] E. Criswell, *Cram's Introduction to Surface Electromyography*, Jones & Bartlett Publishers, pp. 35-39, 2010.
- [4] R. Merletti and D. Farina, *Surface Electromyography: Physiology, Engineering and Applications*, John Wiley & Sons, pp. 300-302, 2016.
- [5] M. J. Aminoff, *Electromyography in Clinical Practice: Electrodiagnostic Aspects of Neuromuscular Disease*, Churchill Livingstone, 1987.
- [6] H. Jungbluth, T. Basil, H. Darras, Jr. Royden Jones, M. Monique Ryan and C. Danniell De Vivo, editors, *Neuromuscular Disorders of Infancy, Childhood and Adolescence—A Clinician's Approach*, Academic Press, pp. 1160, 2015.
- [7] A. S. U. Doulah, S. A. Fattah, W. P. Zhu and M. O. Ahmad, “Wavelet domain feature extraction scheme based on dominant motor unit action potential of EMG signal for neuromuscular disease classification,” IEEE Transactions on Biomedical Circuits and Systems, vol. 8, no. 2, pp. 155-164, 2014.
- [8] F. Ertugrul, Y. Kaya and R. Tekin, “A novel approach for sEMG signal classification with adaptive local binary patterns,” Medical & Biological Engineering & Computing, pp. 1-10, 2015.
- [9] A. Phinyomark, P. Phukpattaranont and C. Limsakul, “Feature reduction and selection for EMG signal classification,” Expert Systems with Applications, vol. 39, no. 8, pp. 7420-7431, 2012.
- [10] I. Elamvazuthi, N. H. X. Duy and Z. S. Ali, “Electromyography (EMG) based classification of neuromuscular disorders using multi-layer perceptron,” Procedia Computer Science, vol. 76, pp. 223-228, 2015.
- [11] S. Shetty and Y. S. Rao, “SVM based machine learning approach to identify Parkinson's disease using gait analysis,” In Inventive Computation Technologies (ICICT), International Conference on, vol. 2, pp. 1-5, 2014.
- [12] A. Goen, “Classification of EMG signals for assessment of neuromuscular disorders,” International Journal of Electronics and Electrical Engineering, vol. 2, no. 3, 2014.
- [13] S. Koçer and A. E. Tümer, “Classifying neuromuscular diseases using artificial neural networks with applied Autoregressive and Cepstral analysis,” Neural Computing and Applications, pp. 1-8, 2016.
- [14] O. Bazgir, J. Frounchi, S. A. H. Habibi, L. Palma and P. Pierleoni, “A neural network system for diagnosis and assessment of tremor in Parkinson disease patients,” In Biomedical Engineering (ICBME), 22nd Iranian Conference on, pp. 1-5, 2015.
- [15] H. Pourakbari, Y. Sarbaz, J. Parvin and M. H. Vojudi, “Proper features extraction from the multiple sclerosis disease postural disorders for decision support system definition,” In Applied Mechanics and Materials, vol. 666, pp. 230-234, 2014.
- [16] P. Kugler, C. Jaremenko, J. Schlachetzki, J. Winkler, J. Klucken and B. Eskofier, “Automatic recognition of Parkinson's disease using surface electromyography

- study,” *Journal of Mathematical Imaging and Vision*, vol. 40, no.3, pp. 259-268, 2011.
- [38] K. Nazarpour, A. R. Sharafat and S. M. P. Firoozabadi, “Surface EMG signal classification using a selective mix of higher order statistics,” In *IEEE Engineering in Medicine and Biology 27th Annual Conference*, pp. 4208-4211, 2006.
- [39] A. Phinyomark, S. Hirunviriyaya, C. Limsakul and P. Phukpattaranont, “Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation,” In *Electrical Engineering/Electronics Computer Telecommunications and Information Technology (ECTI-CON), International Conference on*, pp. 856-860, 2010.
- [40] Y. Al-Assaf, “Surface myoelectric signal analysis: dynamic approaches for change detection and classification,” *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 11, pp. 2248-2256, 2006.
- [41] K. Englehart, B. Hudgins, P. Parker and M. Stevenson, “Time-frequency representation for classification of the transient myoelectric signal,” In *Engineering in Medicine and Biology Society, Proceedings of the 20th Annual International Conference of the IEEE*, Vol. 5, pp. 2627-2630, 1998.
- [42] Ö. F. Ertuğrul, M. E. Tağluk, Y. Kaya and R. Tekin, “EMG signal classification by extreme learning machine,” In *Signal Processing and Communications Applications Conference (SIU)*, 21st, pp. 1-4, 2013.
- [30] E. Bingham, S. Kaski, J. Laaksonen and J. Lampinen, *Advances in Independent Component Analysis and Learning Machines*. Academic Press, pp. 199-202, 2015.
- [31] R. M. Haralick and K. Shanmugam, “Textural features for image classification,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 6, pp. 610-621, 1973.
- [32] J. M. Hausdorff, A. Lertratanakul, M. E. Cudkowicz, A. L. Peterson, D. Kaliton and A. L. Goldberger, “Dynamic markers of altered gait rhythm in amyotrophic lateral sclerosis,” *Journal of Applied Physiology*, vol. 88, pp. 2045-2053, 2000, <https://www.physionet.org/physiobank/database/gaitnidd>.
- [33] M. Nikolic, *Detailed Analysis of Clinical Electromyography Signals: EMG Decomposition, Findings and Firing Pattern Analysis in Controls and Patients With Myopathy and Amyotrophic Lateral Sclerosis*, Ph.D Thesis, 2001, <http://www.emglab.net>, data are available as dataset N2001.
- [34] A. Frank and A. Asuncion, *UCI Machine Learning Repository*, University of California, School of Information and Computer Science, Irvine, <http://archive.ics.uci.edu/ml>, 2014.
- [35] V. Cantarella, *Bones and Muscles. An Illustrated Anatomy*, New York: Wolf Fly Press, pp. 149-155, 1999.
- [36] D. L. Donoho and I. M. Johnstone, “Adapting to unknown smoothness via wavelet shrinkage,” *Journal of the American Statistical Association*, vol. 90, no. 432, pp. 1200-1224, 1995.
- [37] F. Bianconi and A. Fernández, “On the occurrence probability of local binary patterns: a theoretical

زیر نویس‌ها

□ EMG dataset in lower limb

□ Time-frequency distribution

□ Non-stationary

□ Time-frequency image

□ Kernel

□ Short time Fourier transform (STFT)

□ UCI (University of California, Irvine)

□ Rectus femoris

□ Vastus medialis

□ Biceps femoris

□ Semitendinosus

□ Symlet 4

□ Stein's Unbiased Risk threshold selection rule

□ Tenfold cross validation

□ Autoregressive coefficients

□ Energy

□ Mean

□ Standard deviation

□ Skewness

□ Kurtosis

□ Electromyograph

□ Electromyography

□ Electromyogram

□ Motor Unit Action Potential

□ Direct

□ Morphological

□ Amyotrophic Lateral Sclerosis (ALS)

□ Root mean square (RMS)

□ Mean absolute value (MAV)

□ Mean absolute value slope (MAVS)

□ Zero crossing (ZC)

□ Slope sign change (SSC)

□ Waveform length (WL)

□ Power Spectral Density (PSD)

□ Mean frequency (MNF)

□ Median frequency (MDF)

□ Mean power (MNP)

□ Peak frequency (PKF)

□ Spectral moments (SM)

□ Principal component analysis (PCA)