

تحلیل چنددامنه‌ای سیگنال‌های مغزی تحریک‌شده برای شناسایی محتوای بصری چندکلاسه: رویکردی

مبتنی بر ویژگی‌های زمان، فرکانس و فضا

حامد حکاک^۱، محمدمهدی خلیل‌زاده^{۲*}، مهدی آذرنوش^۲، حمیدرضا کبروی^۲

^۱ دانشجوی دکتری، گروه مهندسی پزشکی، دانشکده فنی و مهندسی، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

^۲ استادیار گروه مهندسی پزشکی، واحد مشهد، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، مشهد، ایران

چکیده

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۴/۰۶/۱۰

تاریخ پذیرش:

۱۴۰۴/۰۹/۱۵

کلیدواژه‌ها:

سیگنال EEG، تحلیل

زمان-فرکانس (TFDF)،

استخراج ویژگی سیگنال مغزی،

طبقه‌بندی محتوای بصری،

انتخاب ویژگی آماری

نویسنده مسئول:

mmkhalilzadeh@iau.ac.ir

در این مقاله، یک چارچوب جامع برای تحلیل و طبقه‌بندی محتوای بصری چندکلاسه مبتنی بر سیگنال‌های الکتروانسفالوگرافی تحریک‌شده ارائه شده است. با توجه به چالش‌های متعدد در استخراج ویژگی‌های معنادار از سیگنال‌های مغزی، رویکرد پیشنهادی بر تحلیل ترکیبی استخراج ویژگی در حوزه‌های زمانی، فرکانسی، زمان-فرکانس و محلی تمرکز دارد. ویژگی‌های استخراج‌شده با استفاده از روش‌های کلاسیک و ساختاری از سیگنال‌های الکتروانسفالوگرافی در کنار آزمون آماری Kruskal-Wallis انتخاب شده‌اند. سپس با بهره‌گیری از مدل‌های طبقه‌بندی متنوع، از جمله ماشین بردار پشتیبان، K-نزدیک‌ترین همسایه، پرسپترون چندلایه، درخت تصمیم و شبکه‌های عصبی کانولوشنی، عملکرد مدل‌ها ارزیابی گردید. نتایج نشان می‌دهد که ویژگی‌های حوزه زمان-فرکانس و سیگنال ثبت‌شده از کانال Fz، میانگین دقت ۸۴/۹۲٪ را در طبقه‌بندی چهارکلاسه بصری ارائه می‌دهند و بالاترین عملکرد را در میان سایر ترکیب‌ها دارد که نسبت به مراجع گذشته بین ۲ تا ۸ درصد بهبود داشته است. (با توجه به تعداد کلاس این افزایش مطلوب است) همچنین، روش‌های استخراج ویژگی D-LGP۱ و LNDP نیز با دقت‌های بالا (۸۳٪) و مقاومت در برابر تغییرات کلاس‌ها، عملکرد قابل توجهی نشان دادند. این چارچوب پیشنهادی علاوه بر افزایش دقت طبقه‌بندی، از نظر محاسباتی نیز کارآمد بوده و قابلیت به‌کارگیری در سیستم‌های زمان واقعی را دارد.

doi : 10.22034/ABMIR.2025.23463.1147

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.23463.1147)

/Author 2026. Published by Yazd University This is an open

access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



۱- مقدمه

تحلیل‌های آماری در بخش سوم ارائه شده و بخش‌های چهارم و پنجم به تفسیر یافته‌ها و ارائه مسیرهای آتی پژوهش اختصاص دارند.

۲- مواد و روش‌ها

برای ارزیابی چارچوب پیشنهادی، از داده‌های EEG ثبت‌شده طی یک آزمایش تحریک بصری چندکلاسه استفاده شد. این چارچوب شامل مراحل پیش‌پردازش سیگنال، استخراج ویژگی‌های چند دامنه، انتخاب ویژگی‌های بهینه و طبقه‌بندی است.

سیگنال‌ها از کانال‌های منتخب (Pz, Cz, Fz, F4, F3, Fp2) ثبت و با فیلتر باندهای حذف نویزهای محیطی و حرکتی پیش‌پردازش شدند [۴ و ۵]. ویژگی‌ها از حوزه‌های زمانی، فرکانسی، زمان-فرکانسی و مکانی استخراج و سپس با استفاده از آزمون کروسکال-والیس و تحلیل حساسیت، ویژگی‌های مؤثر انتخاب شدند [۱۹ و ۲۰].

در مرحله طبقه‌بندی، از الگوریتم‌های مختلف یادگیری ماشین شامل KNN، SVM، MLP، درخت تصمیم و CNN استفاده شد. عملکرد مدل‌ها بر اساس معیارهای دقت، حساسیت و FI-score ارزیابی و بهترین ترکیب ویژگی-مدل شناسایی گردید.

به‌طور خلاصه، این چارچوب منسجم، امکان تحلیل چنددامنه‌ای سیگنال EEG را فراهم کرده و قابلیت استفاده در شناسایی دقیق محتوای بصری چندکلاسه را نشان می‌دهد. مراحل کامل فرآیند در بلوک شکل ۱ ارائه شده است. که مراحل اصلی شامل: استخراج ویژگی، انتخاب ویژگی بهینه و طبقه‌بندی است.

نوآوری اصلی این پژوهش در طراحی یک چارچوب جامع و ساختارمند برای تحلیل چنددامنه‌ای سیگنال‌های الکتروانسفالوگرافی تحریک‌شده است که هدف آن طبقه‌بندی دقیق محتوای بصری چندکلاسه است. برخلاف رویکردهای مرسوم که تمرکز خود را تنها بر یک حوزه از سیگنال مغزی (مانند زمان یا فرکانس) قرار داده‌اند، چارچوب پیشنهادی با ترکیب هم‌زمان

تحلیل سیگنال^۱ EEG به دلیل غیرتجانسی بودن، دقت زمانی بالا و سهولت اجرا، در علوم اعصاب، پزشکی و واسط‌های مغز-رایانه کاربرد گسترده‌ای دارد [۱ و ۲]. با این حال، نسبت پایین سیگنال به نویز، رفتار غیرایستا و پیچیدگی فضا-زمان، استخراج اطلاعات معنادار از EEG را دشوار کرده است [۳-۵]. بنابراین توسعه روش‌های دقیق برای شناسایی محتوای ادراکی چندکلاسه، به‌ویژه در کاربردهای زمان واقعی، ضروری است [۸].

پژوهش‌های پیشین اغلب بر تحلیل تک‌دامنه‌ای یا ترکیب محدود دامنه‌ها تمرکز داشته‌اند [۶ و ۷] و به دلیل استفاده از پروتکل‌های غیراستاندارد یا داده‌های نامتوازن، تعمیم‌پذیری نتایج کاهش یافته است [۱۰]. این امر بر ضرورت طراحی چارچوب‌های منسجم برای مدل‌سازی هم‌زمان ابعاد چندگانه سیگنال تأکید دارد.

چالش اصلی در تحلیل چنددامنه‌ای، انتخاب ویژگی‌های نماینده پاسخ عصبی است. ترکیب اطلاعات زمانی، فرکانسی و فضایی ظرفیت بالایی در شناسایی الگوها دارد، اما انتخاب نادرست می‌تواند به افزایش پیچیدگی و افت دقت منجر شود [۱۱ و ۱۲]. علاوه بر این، برخی مطالعات مبتنی بر یادگیری ماشین به‌علت نبود داده متوازن یا ارزیابی جامع عملکرد ناپایداری داشته‌اند.

در این پژوهش، یک چارچوب یکپارچه چنددامنه‌ای ارائه می‌شود که شامل مراحل استخراج، انتخاب و طبقه‌بندی ویژگی‌ها است. ویژگی‌ها از سه حوزه زمانی، فرکانسی و زمان-فرکانسی استخراج و سپس با مدل‌های مختلف طبقه‌بندی ارزیابی شدند. نوآوری اصلی، ادغام نظام‌مند دامنه‌ها، طراحی آزمایش با پروتکل کنترل‌شده، استفاده از پایگاه داده متوازن چهارکلاسه و ارزیابی جامع است. این چارچوب می‌تواند پایه‌ای برای توسعه سامانه‌های دقیق در پایش شناختی، تشخیص اختلالات عصبی و واسط‌های مغز-رایانه باشد [۱۳ و ۱۴].

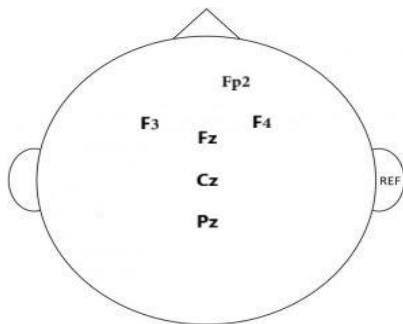
ساختار مقاله به‌صورت زیر تنظیم شده است: بخش دوم به تشریح طراحی آزمایش، ثبت سیگنال‌ها، محرک‌های تصویری و مراحل پیش‌پردازش می‌پردازد؛ همچنین، روش‌های استخراج و انتخاب ویژگی و همچنین مدل‌های طبقه‌بندی معرفی می‌شوند؛ نتایج و

¹ Electroencephalography

برچسب‌خورده استفاده شد. داده‌ها از ۲۰ شرکت‌کننده سالم (۱۰ زن، ۱۰ مرد، محدوده سنی ۲۰-۳۵ سال) در شرایط کنترل‌شده نور، صدا و دما در آزمایشگاه EEG دانشگاه آزاد مشهد گردآوری شد. سلامت روانی شرکت‌کنندگان با پرسشنامه پیش از آزمایش تأیید گردید.

در پروتکل طراحی‌شده، در هر مرحله ۳۰ تصویر از یکی از چهار دسته (حیوانات، غذا، وسایل اداری، وسایل نقلیه) به مدت ۳ ثانیه نمایش داده شد و بین نمایش تصاویر، فواصل استراحت برای بازیابی فعالیت پایه در نظر گرفته شد.

سیگنال‌ها با دستگاه میستار مدل ۲۰۲-۲۴ و نرخ نمونه‌برداری ۲۵۰ هرتز از شش الکتروود (Fp2, F3, F4, Fz, Cz, Pz) مطابق سیستم ۱۰-۲۰ ثبت شدند تا نواحی کلیدی مرتبط با ادراک، حافظه و توجه پوشش داده شود. این چینش به بهینه‌سازی کیفیت داده و کاهش نویز کمک کرد.



شکل (۲): محل قرارگیری الکترودهای ثبت

بر اساس شکل ۲ و الکترودهای مشخص‌شده، تمرکز اصلی آن بر ثبت فعالیت الکتریکی قشر مغز از نواحی پیشانی (Frontal; F3, F4, Fp2)، مرکزی (Central; Cz) و آهیانه‌ای (Parietal; Pz) است. این نواحی به‌طور ویژه در پردازش تصاویر، شناخت بصری، توجه، حافظه کاری و طبقه‌بندی محرک‌های پیچیده (مانند حیوانات، غذا، وسایل اداری و وسایل نقلیه) نقش حیاتی دارند. در شکل ۳ که برای یک سوژه به‌طور تصادفی نمایش داده شده است، در آن سیگنال ثبت‌شده برای همه کانال‌ها برای حالت مشاهده تصاویر حیوانات مشاهده می‌شود.

ویژگی‌های محلی، زمانی، فرکانسی و زمان-فرکانسی، بازنمایی چندبُعدی از پاسخ مغز به محرک‌های بصری فراهم می‌کند.



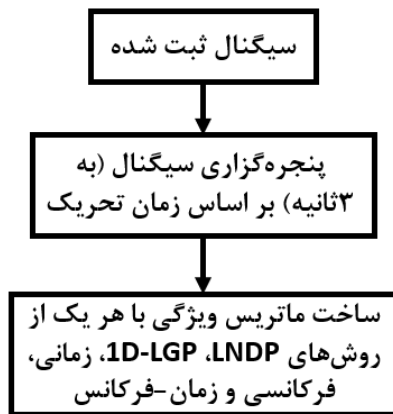
شکل (۱): بلوک کلی از روش کار این تحقیق

ترکیب تحلیل سیگنال با روش‌های محلی مقاوم به نویز نظیر الگوی توصیف همسایگی محلی و تغییرات محلی یک‌بعدی، همراه با به‌کارگیری آزمون آماری کروسکال-والیس^۱ برای انتخاب ویژگی‌های مؤثر، نوآوری مهمی در افزایش تفسیرپذیری و کارایی سیستم ارائه کرده است. علاوه بر این، بهره‌گیری از مجموعه‌ای از طبقه‌بندها با سطوح مختلف پیچیدگی مانند KNN, SVM, MLP و CNN، امکان ارزیابی عملکرد چارچوب را در سناریوهای گوناگون فراهم نموده است.

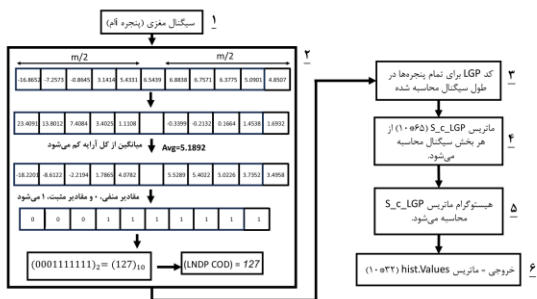
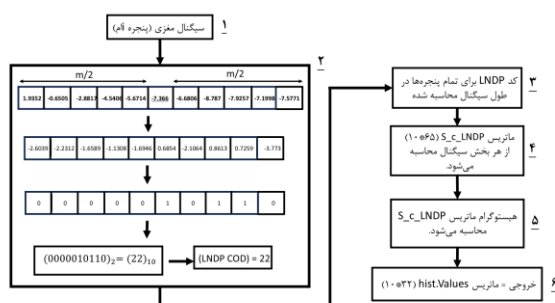
۲-۱ داده مورد استفاده و آماده‌سازی آن

برای ارزیابی چارچوب پیشنهادی، از یک مجموعه‌داده اختصاصی EEG شامل سیگنال‌های ثبت‌شده در پاسخ به تصاویر

¹ Kruskal-Wallis H Test




شکل (۴): بلوک استخراج ویژگی



شکل (۵): بلوک روش‌های LNDP (بالا) و 1D-LGP (پایین)

ویژگی‌های حوزه زمان شامل ۱۳ شاخص آماری و دینامیکی همچون میانگین مطلق، واریانس، عبور از صفر، ضریب عدم تقارن و کشیدگی استخراج شدند [۲۵-۲۸]. ویژگی‌های حوزه فرکانس با استفاده از تبدیل فوریه، شامل فرکانس میانگین، پیک فرکانسی، توان کل و نسبت فرکانسی در باندهای تنا



شکل (۳): سیگنال ثبت شده، برای ۶ کانال سیگنال چشم باز از یک سوژه

انتخاب آگاهانه محرک‌های تصویری بر اساس معیارهای شناختی و تنوع ادراکی، به منظور فعال‌سازی مسیرهای پردازشی متمایز و افزایش دقت طبقه‌بندی، یکی از جنبه‌های نوآورانه این مطالعه بود.

۲-۲ روش‌های استخراج ویژگی

در این پژوهش، پس از پیش‌پردازش سیگنال‌های الکتروانسفالوگرافی و حذف نویزهای فیزیولوژیکی و محیطی، مرحله استخراج ویژگی باهدف استخراج اطلاعات معنادار از پاسخ‌های مغزی به محرک‌های بصری آغاز شد. برای دستیابی به ویژگی‌هایی متمایزکننده و قابل تفکیک، ترکیبی از روش‌های استخراج در چهار حوزه محلی، زمانی، فرکانسی و زمان-فرکانس به کار گرفته شد (شکل ۴).


از چهار گروه ویژگی استفاده شد. ویژگی‌های محلی با استفاده از روش الگوی توصیف همسایگی محلی (LNDP^۱) و روش تغییرات محلی یک‌بعدی (1D-LGP^۲), از طریق کدگذاری باینری و ساخت ماتریس‌های هیستوگرام ۱۰×۳۲، همان‌طور که در شکل ۵ مشخص است، تغییرات محلی سیگنال را مدل‌سازی می‌کنند [۲۱-۲۴].

² 1D Local Gradient Pattern

¹ Local Neighborhood Description Pattern

۲-۳-۱ روش انتخاب ویژگی: آزمون کروسکال-والیس

برای انتخاب ویژگی‌های مؤثر از آزمون ناپارامتری کروسکال-والیس استفاده شد که بدون فرض نرمال بودن داده‌ها، تفاوت آماری میان کلاس‌ها را ارزیابی می‌کند و برای EEG مناسب است [۳۱]. ویژگی‌هایی با مقدار p بالاتر از 0.01 حذف شده و تنها ویژگی‌های معنادار حفظ شدند. این رویکرد با حذف نویز و داده‌های نامرتبط، بهینه‌سازی فضای ویژگی و افزایش دقت مدل‌های یادگیری ماشین را به دنبال داشت. (شکل ۷)



شکل (۷): بلوک روش انتخاب ویژگی: آزمون کروسکال-والیس


۲-۳-۲ آنالیز حساسیت برای انتخاب حوزه ویژگی و

کانال بهینه

برای تعیین بهینه‌ترین ویژگی و کانال EEG، آنالیز حساسیت انجام شد [۳۲]. در این تحلیل، اثر مجموعه ویژگی‌ها (زمانی، فرکانسی، زمان-فرکانس، LNDP و ID-LGP) و کانال‌های (Fz, F3, Fp2, F4, Cz, Pz) بر دقت طبقه‌بندی بررسی گردید. حوزه و کانالی که بالاترین دقت را ارائه کردند به‌عنوان گزینه‌های بهینه انتخاب شدند. این تحلیل بر مبنای خروجی طبقه‌بندی‌کننده‌ها و قدرت تفکیک ویژگی‌ها صورت گرفت. (شکل ۸)

(۴-۸ هرتز)، آلفا (۸-۱۲ هرتز) و بتا (۱۳-۳۰ هرتز) محاسبه گردیدند [۲۹].

در نهایت، ویژگی‌های حوزه زمان-فرکانس با توجه به شکل ۶، با تقسیم‌بندی سیگنال به پنجره‌های ۲ ثانیه‌ای با همپوشانی ۰/۱ ثانیه و تعریف ۲۳ باند فرکانسی ۴ هرتزی با همپوشانی ۱ هرتز (در محدوده ۴-۳۰ هرتز) استخراج شدند. از هر پنجره، یک ماتریس ویژگی 11×23 به‌عنوان نماینده دینامیک قدرت سیگنال استخراج گردید که قابلیت شناسایی تغییرات ERD^۱ و تمایز پاسخ به محرک‌های بصری را به‌طور چشمگیری افزایش می‌دهد [۳۰].



شکل (۶): بلوک روش زمان-فرکانس


به‌کارگیری ویژگی‌ها از حوزه‌های مختلف در این پژوهش نوآوری مهمی محسوب می‌شود، زیرا هر حوزه جنبه‌ای متفاوت از دینامیک مغزی را بازتاب می‌دهد. ویژگی‌های زمانی روند کلی و تغییرات آماری سیگنال را نشان می‌دهند، درحالی‌که ویژگی‌های فرکانسی نوسانات مرتبط با فعالیت‌های شناختی مانند توجه و حافظه را آشکار می‌سازند. تحلیل زمان-فرکانس با ترکیب این دو بُعد، امکان ردیابی تغییرات فرکانسی وابسته به زمان و بررسی پاسخ‌های گذرا به محرک‌های بصری را فراهم می‌کند.

۲-۳ انتخاب ویژگی بهینه

پس از استخراج ویژگی‌های متنوع از سیگنال‌های الکتروانسفالوگرافی در حوزه‌های زمانی، فرکانسی، زمان-فرکانس و ویژگی‌های محلی، مرحله انتخاب ویژگی بهینه برای بهبود دقت و کاهش پیچیدگی محاسباتی انجام شد. این فرآیند نقش کلیدی در افزایش کارایی الگوریتم‌های طبقه‌بندی و جلوگیری از پدیده بیش‌برازش^۲ ایفا می‌کند.

² Overfitting

¹ Entity-Relationship Diagram



شکل (۹): ساختار CNN پیشنهادی

با توجه به شکل ۹ که نشان‌دهنده ساختار کلی شبکه عصبی کانولوشنی مورد استفاده است، برای تنظیم پارامترهای شبکه کانولوشنی از مقادیر استفاده شده در کارهای مرتبط استفاده می‌شود. که در این تحقیق، طراحی معماری CNN، یک معماری CNN با سه لایه کانولوشن و یک لایه اتصال کامل طراحی می‌شود. مشخصات معماری CNN طراحی شده نیز در جدول ۱ آمده است.

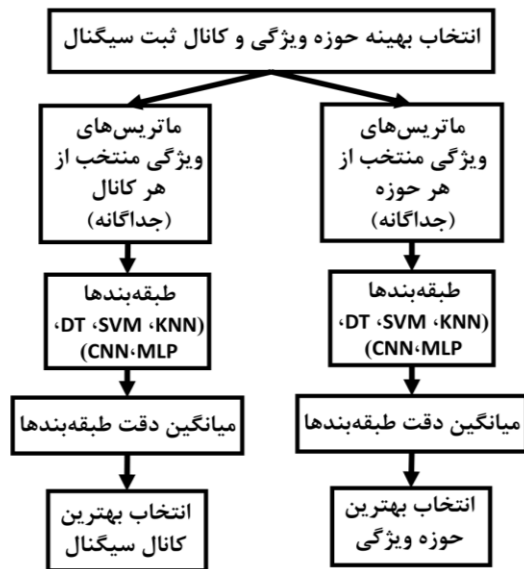
[۴۴]

جدول (۱): مشخصات معماری CNN طراحی شده

نام لایه	توضیحات
Input feature matrix	ماتریس ۱۰۰ در ۱۰۰ با نرمالیزاسیون به روش میانگین صفر
Convolutional Layers	۳ لایه کانولوشن با ۶۴ فیلتر کانولوشن $22 \times 22 \times 1$ با گام (stride) [1,1] و پدینگ [0,0]
ReLU	تابع یک‌سوسازی خطی
Max Pooling	با اندازه ۲ در ۲
Dropout	۵۰ درصد
Optimizer	Adam
Learning Rate	۰/۰۰۱
Loss function	Categorical Cross-Entropy
Batch Size	۳۲
Epochs	۵۰
Fully Connected (FC)	یک‌لایه اتصال کامل با ۹ نورون
SoftMax	SoftMax
Classification output	Cross entropy با "۱"، "۲" تا "۴"

³ Multilayer Perceptron

⁴ Convolutional neural network



شکل (۸): بلوک انتخاب حوزه ویژگی و کانال بهینه

۲-۴ الگوریتم‌های طبقه‌بندی

برای شناسایی بهینه‌ترین حوزه ویژگی و کانال EEG همان‌طور که در شکل ۸ هم مشخص است، از مجموعه‌ای متنوع از طبقه‌بندی‌کننده‌های نظارت‌شده استفاده شد. با توجه به غیرخطی و نویزی بودن سیگنال‌های مغزی، انتخاب مدل مناسب برای جداسازی الگوهای عصبی اهمیت دارد؛ زیرا ویژگی‌های استخراج‌شده به تنهایی قدرت تفکیک کافی ندارند. بهره‌گیری از الگوریتم‌های یادگیری ماشین امکان مدل‌سازی روابط پیچیده میان ویژگی‌ها و نوع محرک را فراهم می‌کند و حتی در حضور نویزهای حرکتی و چشمی نیز پاسخ واقعی مغز را شناسایی می‌نماید. داده‌ها با نسبت ۷۰٪ آموزش و ۳۰٪ آزمون و در ۱۰ تکرار مستقل ارزیابی شدند تا پایداری و مقایسه عادلانه تضمین شود. پنج طبقه‌بندی‌کننده منتخب شامل: ^۱KNN برای تحلیل فاصله‌ای [۳۳]، ^۲SVM برای مرزهای تصمیم‌گیری غیرخطی [۳۴ و ۳۵]، درخت تصمیم به‌عنوان روشی سریع و تفسیرپذیر [۳۶]، ^۳MLP برای یادگیری ترکیب‌های غیرخطی پیچیده [۱۸] و ^۴CNN برای استخراج ساختارهای مکانی-زمانی [۳۷] بودند.

¹ K-Nearest Neighbors

² Support Vector Machine

۳- نتایج

در این بخش، عملکرد مدل‌های طبقه‌بندی بر اساس ویژگی‌های استخراج‌شده از سیگنال EEG تحلیل شده است. هدف، ارزیابی اثربخشی ویژگی‌های چنددامنه‌ای در شناسایی محتوای بصری و بررسی شاخص‌هایی چون دقت، حساسیت و ویژگی است.

در مرحله اول، تحلیل ویژگی‌های استخراج‌شده نشان داد که ادغام ابعاد زمانی، فرکانسی و زمان-فرکانسی موجب افزایش دقت طبقه‌بندی می‌شود. به‌ویژه، ویژگی‌های ترکیبی زمان-فرکانس در کنار مدل‌های یادگیری ماشین عملکرد بهتری در تمایز کلاس‌های تصویری ارائه کردند.

انتخاب ویژگی با استفاده از تحلیل همبستگی و حساسیت صورت گرفت و منجر به کاهش ابعاد و بهبود سرعت پردازش شد. نتایج تجربی نشان داد که:

- ویژگی‌های زمان-فرکانسی با شبکه عصبی کانولوشنی دقتی معادل ۸۴/۹۲٪ کسب کردند.
- ویژگی‌های فرکانسی با ماشین بردار پشتیبان دقت ۸۱/۴۵٪ را ثبت کردند.

این نتایج بر اهمیت انتخاب بهینه ویژگی‌ها در ارتقاء عملکرد طبقه‌بندها تأکید دارد. همچنین تحلیل حساسیت نشان داد که ترکیب ویژگی‌های زمان-فرکانسی و مکانی بیشترین اثر را در بهبود دقت مدل‌ها داشته‌اند.

۳-۱ نتایج روش انتخاب ویژگی: آزمون کروسکال-والیس

والیس

برای شناسایی ویژگی‌های معنادار در تمایز کلاس‌های تصویری از سیگنال‌های EEG، از آزمون ناپارامتری کروسکال-والیس استفاده شد. در حوزه زمانی، هفت ویژگی آماری به‌عنوان مؤثرترین ویژگی‌ها در کاهش ابعاد و افزایش دقت شناسایی شدند. در حوزه فرکانسی، ۱۴ ویژگی مرتبط با باندهای تتا، آلفا و بتا انتخاب شدند که پاسخ مغزی را به‌خوبی متمایز می‌کردند. ترکیب ۱۰ ویژگی

نوآوری این بخش بر تحلیل درون مطالعه‌ای تأکید دارد، زیرا تفاوت‌های اجتناب‌ناپذیر در پروتکل‌ها و محرک‌ها، مقایسه مستقیم با پژوهش‌های دیگر را غیرقابل‌انکا می‌کند. در عوض، تمرکز بر تعیین ترکیب بهینه «حوزه ویژگی + کانال EEG» در چارچوب یکسان، امکان استنتاج دقیق‌تری از نقش ویژگی‌ها و کانال‌ها فراهم می‌سازد. تنوع طبقه‌بندی‌کننده‌ها نیز خطر بایاس ناشی از انتخاب یک مدل خاص را کاهش داده و اعتبار نتایج را تقویت می‌کند. این تحلیل، پایه‌ای برای بهینه‌سازی مدل نهایی و استخراج بینش‌های معتبر فیزیولوژیکی است.

۲-۵ معیارهای ارزیابی

در این پژوهش، جهت ارزیابی عملکرد طبقه‌بندهای مبتنی بر سیگنال الکتروانسفالوگرافی برای تشخیص نوع تصویر، مجموعه‌ای از معیارهای کمی استاندارد مورد استفاده قرار گرفته‌اند که به‌صورت گسترده در حوزه یادگیری ماشین و تحلیل داده‌های زیستی به کار می‌روند. این معیارها شامل دقت^۱، دقت مثبت^۲، حساسیت^۳، ویژگی^۴، امتیاز F1^۵ هستند. بهره‌گیری هم‌زمان از این معیارها امکان تحلیل دقیق‌تر عملکرد الگوریتم و بهینه‌سازی آن برای ترکیب هوشمند داده‌های مغزی و بصری را فراهم می‌سازد. [۱۹]

پارامترهای مورد استفاده در این معیارها شامل: TP: مواردی که مدل درست پیش‌بینی کرده است (مثبت واقعی). TN: مواردی که مدل درست پیش‌بینی کرده است (منفی واقعی). FP: مواردی که مدل اشتباه پیش‌بینی کرده است (مثبت کاذب). FN: مواردی که مدل اشتباه پیش‌بینی کرده است (منفی کاذب).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall/Sensitivity = \frac{TP}{TP + FN} \quad (3)$$

$$Specificity = \frac{TN}{TN + FP} \quad (4)$$

$$F1 - Score = \frac{Precision \cdot Recall}{Precision + Recall} \cdot 2 \quad (5)$$

⁴ Specificity

⁵ F1-Score

¹ Accuracy

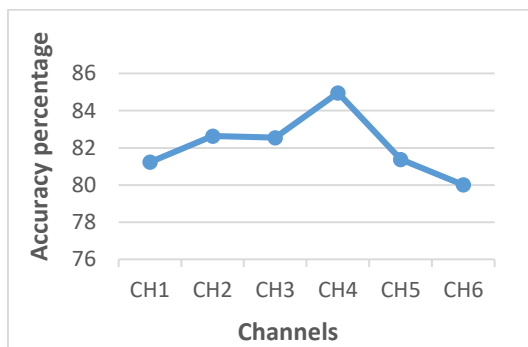
² Precision

³ Recall یا Sensitivity

در مجموع، نتایج نشان داد که حوزه زمان-فرکانس و روش‌های محلی مانند ID-LGP و LNDP بهترین تمایز میان کلاس‌ها را ایجاد کرده و همراه با انتخاب کانال‌های بهینه، می‌توانند مبنای طراحی مدل‌های دقیق‌تر باشند.

۳-۳ جمع‌بندی نتایج

در این بخش، جمع‌بندی نتایج حاصل از تحلیل سیگنال‌های مغزی با استفاده از روش‌های کلاسیک ارائه می‌شود. بررسی‌ها نشان می‌دهد که این روش‌ها، در استخراج اطلاعات معنادار از سیگنال الکتروانسفالوگرافی مؤثر بوده‌اند. طبق نتایج شکل ۱۰، کانال چهارم با بالاترین میانگین دقت، به‌عنوان کانال اصلی برای تحلیل نهایی انتخاب شد. تحلیل دقت در میان کانال‌ها نشان داد که عملکرد مدل وابسته به کانال و تغییرات قابل توجهی در دقت مشاهده می‌شود.



شکل (۱۰): تغییرات درصد دقت برای کانال‌ها به ازای تمام حالات حوزه ویژگی و طبقه‌بند

از میان حوزه‌ها، حوزه زمان-فرکانس بالاترین درصد دقت را به دست آورد. هرچند حوزه‌های الگوی توصیف همسایگی محلی و الگوی تغییرات محلی یک‌بعدی نیز دقتی نزدیک به حوزه زمان-فرکانس داشتند، اما به دلیل اهمیت حداقلی خطا و جلوگیری از افزایش بیش‌ازحد حجم محاسبات، زمان-فرکانس به‌عنوان حوزه نهایی استخراج ویژگی انتخاب گردید (مطابق شکل ۱۱). این انتخاب باعث دستیابی به تعادل میان دقت بالا و کارایی محاسباتی در مدل نهایی شد.

برای ارزیابی نهایی عملکرد مدل‌ها، میانگین دقت طبقه‌بندی در تمام ترکیب‌های کانال، حوزه‌های استخراج ویژگی و طبقه‌بندها محاسبه و در جدول ۲ ارائه شده است. این تحلیل به شناسایی مؤثرترین ترکیب‌ها کمک می‌کند.

فرکانسی و ۳ ویژگی زمانی نیز عملکرد پایدارتر و بهتری نسبت به استفاده مجزای هر حوزه نشان داد.

در حوزه زمان-فرکانس، اگرچه تنها ویژگی «فرکانس متوسط» از نظر آماری معنادار بود، اما استفاده از کل ماتریس ویژگی در شبکه‌های عصبی کانولوشنی (CNN) امکان تحلیل دقیق‌تری فراهم کرد. در روش‌های ساختاری، الگوریتم ID-LGP ویژگی‌های مقاوم به نویز با ابعاد 10×32 (و نسخه فشرده 1×32) تولید کرد و LNDP نیز از طریق کدگذاری باینری تطبیقی، ویژگی‌های پایدار در برابر نویز محیطی استخراج نمود.

در مجموع، ویژگی‌های حوزه زمان-فرکانس دقیق‌ترین تمایز بین کلاس‌ها را ارائه دادند، درحالی‌که روش‌های محلی نظیر ID-LGP و LNDP نیز عملکردی مشابه و مقاوم در برابر نویز نشان دادند. این نتایج بر اهمیت رویکردهای چنددامنه‌ای و انتخاب آماری ویژگی‌ها برای بهینه‌سازی طبقه‌بندی سیگنال EEG تأکید می‌کنند.

۳-۲ آنالیز حساسیت برای انتخاب ویژگی و کانال

بهینه

برای شناسایی ترکیب بهینه کانال و طبقه‌بند، ویژگی‌های استخراج‌شده از سیگنال EEG در حوزه‌های مختلف ارزیابی شدند. در حوزه زمانی، الگوریتم KNN با کانال چهارم بهترین نتیجه را با میانگین دقت $87/37\%$ ارائه داد. در حوزه فرکانسی، دقت بالاتری حاصل شد و CNN همراه با کانال چهارم به میانگین $81/6\%$ رسید که بیانگر توان بالای ویژگی‌های طیفی در مدل‌سازی پاسخ‌های بصری است.

ترکیب ویژگی‌های زمانی و فرکانسی موجب افزایش پایداری و بهبود دقت شد؛ به‌طوری‌که CNN دقت $81/75\%$ کسب کرد. در حوزه زمان-فرکانس، بالاترین عملکرد ثبت شد و CNN با کانال چهارم به دقت $92/84\%$ دست‌یافت که ظرفیت بالای این حوزه در نمایش هم‌زمان اطلاعات زمانی و طیفی را نشان می‌دهد.

از میان روش‌های ساختاری، ID-LGP با ویژگی‌های مقاوم در برابر نویز و ترکیب با CNN (کانال سوم) دقت $84/14\%$ به‌دست آورد، درحالی‌که LNDP در ترکیب با CNN و کانال پنجم دقت $83/98\%$ را ثبت کرد. هر دو روش با تمرکز بر ساختارهای محلی و مقاومت در برابر اغتشاشات عملکرد بالایی داشتند.

ساده‌تر و سریع‌تر هستند اما پوشش ساختاری محدودی دارند، درحالی‌که روش‌های محلی با تمرکز بر تغییرات جزئی سیگنال، دقت بالاتر و مقاومت بیشتری در برابر نویز نشان دادند. به‌ویژه LNDP با کدگذاری باینری تطبیقی و قابلیت استفاده مستقیم در شبکه‌های عصبی کانولوشنی، گزینه‌ای مناسب برای مدل‌های یادگیری عمیق محسوب می‌شود. درنهایت، روش زمان-فرکانس به دلیل توانایی در استخراج هم‌زمان دو بعد اطلاعاتی، برای کاربردهایی که نیاز به دقت بالا دارند بسیار کارآمد است.

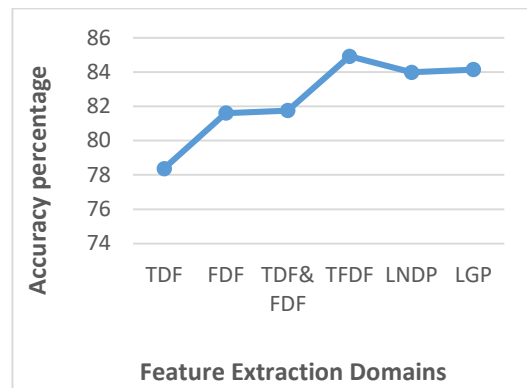
۴- بحث و گفت‌وگو

نتایج نشان دادند که ترکیب ویژگی‌های چنددامنه‌ای از سیگنال EEG دقت طبقه‌بندی محتوای بصری را به‌طور معناداری افزایش می‌دهد. چارچوب پیشنهادی با تمرکز بر چهار حوزه زمانی، فرکانسی، زمان-فرکانس و ساختارهای محلی و استفاده از انتخاب آماری، توانست چالش‌هایی مانند نویز و عدم ایستایی را مدیریت کند.

در حوزه زمانی، ویژگی‌های ساده‌ای چون RMS، واریانس و چولگی ضمن کاهش حجم داده، پایه مناسبی برای ترکیب با سایر دامنه‌ها فراهم کردند [۱۵]. در حوزه فرکانسی، باندهای آلفا، بتا و به‌ویژه تتا به‌عنوان نشانگرهای قوی فعالیت شناختی شناسایی شدند و نسبت‌های طیفی FFT نیز با یافته‌های Ji et al. (2019) همخوانی داشتند [۱۶].

تحلیل زمان-فرکانس با آزمون کروסקال-والیس و ماتریس 11×23 بالاترین دقت ($84/92\%$) را ارائه کرد و امکان بهره‌گیری در شبکه‌های عمیق را فراهم ساخت، درحالی‌که بسیاری از مطالعات پیشین تنها به تحلیل باندها پرداخته بودند [۱۵].

در حوزه ساختارهای محلی، الگوریتم‌های 1D-LGP و LNDP عملکرد قابل‌توجهی داشتند. 1D-LGP با استخراج الگوهای ترتیبی مقاوم به نویز و LNDP با باینری‌سازی تطبیقی، ویژگی‌هایی مناسب برای استفاده مستقیم در شبکه‌های CNN فراهم کردند. برخلاف Zhang et al. (2023) که تنها از CNN استفاده کردند [۱۷]، رویکرد حاضر بر پیش‌پردازش ساختاری و حذف نویز نیز تأکید دارد.



شکل (۱۱): تغییرات درصد دقت برای حوزه‌های ویژگی به ازای

تمام حالات کانال‌ها و طبقه‌بندها

نتایج نشان دادند که کانال Fz بالاترین دقت را در ثبت فعالیت‌های مرتبط با محتوای بصری دارد، درحالی‌که F3 و F4 عملکرد متوسط و کانال Pz کمترین دقت را ارائه داد که احتمالاً ناشی از نویز یا اهمیت کمتر اطلاعات آن است.

جدول (۲): میانگین درصد دقت برای تمام کانال‌ها، حوزه‌ها و

طبقه‌بندی‌کننده‌ها

channel	%	field	%
۱ (Fp1)	۸۱/۲۳	TDF	۷۸/۳۷
۲ (F3)	۸۲/۶۳	FDF	۸۱/۶
۳ (F4)	۸۲/۵۵	TDF& FDF	۸۱/۷۵
۴ (Fz)	۸۴/۹۶	TFDF ^۱	۸۴/۹۲
۵ (Cz)	۸۱/۳۸	LNDP	۸۳/۹۸
۶ (Pz)	۸۰/۰۱	LGP	۸۴/۱۴

در میان حوزه‌های استخراج ویژگی، زمان-فرکانس بهترین عملکرد را داشت و نشان داد که ترکیب اطلاعات زمانی و فرکانسی غنای بیشتری به مدل می‌دهد. روش‌های محلی مانند الگوی توصیف همسایگی محلی (LNDP) و الگوی تغییرات محلی یک‌بعدی (1D-LGP) نیز دقتی نزدیک به حوزه زمان-فرکانس داشتند و توانستند ویژگی‌های محلی و غیرخطی را به‌طور مؤثر استخراج کنند.

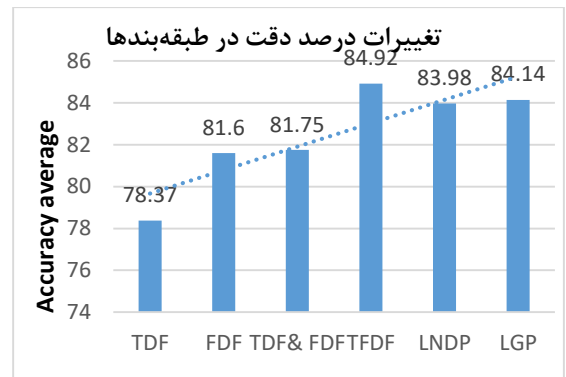
ترکیب کانال Fz با حوزه زمان-فرکانس به‌عنوان مؤثرترین ساختار در این پژوهش شناسایی شد و می‌تواند مبنای توسعه مدل‌های پیشرفته‌تر قرار گیرد. در مقایسه، روش‌های زمانی و فرکانسی

^۱حوزه زمان-فرکانس

ساختاری مانند الگوی توصیف همسایگی محلی و تغییرات محلی یک‌بعدی نیز عملکرد رقابتی و بسیار نزدیک داشتند (به ترتیب ۸۳/۴۸٪ و ۸۳/۹۰٪). این نتایج نشان می‌دهد که تلفیق ساختار سیگنال با اطلاعات زمانی-فرکانسی می‌تواند به طراحی مدل‌هایی مقاوم، دقیق و سبک بیانجامد. روش‌های صرفاً زمانی یا فرکانسی، به‌رغم سادگی، نسبت به سایر روش‌ها عملکرد پایین‌تری داشتند (زیر ۸۱٪).

تحلیل جدول ۳ نشان می‌دهد که روش ارائه‌شده در این مقاله، با دقت ۸۴/۹۲٪، بالاترین عملکرد را در میان روش‌های موجود داشته است. برخلاف بسیاری از مطالعات اخیر که برای دستیابی به دقت بالا به مدل‌های پیچیده‌ای همچون شبکه‌های attention یا انتقال یادگیری^۱ [۴۲] متکی هستند، چارچوب پیشنهادی با تکیه بر تحلیل چنددامنه‌ای (به‌ویژه زمان-فرکانس) و استفاده از ترکیب طبقه‌بندی‌های کلاسیک و عمیق توانسته است به دقت بالاتری نسبت به اغلب مقالات دیگر دست یابد.

در مجموع، این نتایج نشان دادند که ادغام هدفمند حوزه‌های تحلیلی و انتخاب آماری ویژگی‌ها موجب بهبود دقت و پایداری در تحلیل سیگنال مغزی می‌شود. در نمودار شکل ۱۲، عملکرد نسبی روش‌های مختلف استخراج ویژگی در این پژوهش به تصویر کشیده شده است:



شکل (۱۲): دقت طبقه‌بندی روش‌های مختلف استخراج ویژگی

EEG به ازای میانگین تمام طبقه‌بندی‌ها

همان‌طور که مشاهده می‌شود، ویژگی‌های ترکیبی زمان-فرکانس بالاترین دقت را ارائه داده‌اند (۸۴/۹۲٪)، درحالی‌که روش‌های

جدول (۳): مقایسه روش این مقاله با سایر تحقیقات این حوزه

ردیف	مقاله	سال	روش پیشنهادی	دامنه ویژگی‌ها	مدل طبقه‌بندی	دقت	نکته مهم
۱	Tang et al., IEEE TNSRE[۳۸]	۲۰۲۴	Multi-Scale + Feature Enhancement شبکه ترکیبی	فرکانس + زمان	ترکیبی CNN	~۸۲/۳	نیاز به داده زیاد
۲	Qin et al., JIM[۳۹]	۲۰۲۴	CSP + Hybrid Attention-Net	فضا + زمان	با توجه CNN مکانی-زمانی	۸۳/۷	حساس به تنظیمات
۳	Singh & Krishnan, Front AI[۴۰]	۲۰۲۳	تحلیل مقایسه‌ای ویژگی‌ها	زمان، فرکانس، ساختار	KNN, SVM	~۷۸	تحلیل نظری جامع
۴	Maddury, Front Signal Proc[۴۱]	۲۰۲۴	Domain-based feature extraction	EEG, ECG	ساده ML	~۷۵	برای بیماری خاص
۵	Wang et al., Front Hum Neurosci[۴۳]	۲۰۲۳	Joint Spatial-Frequency Features + Transfer Learning	فضا + فرکانس	SVM, LSTM	~۸۴	داده محدود و خاص
۶	روش انتخابی این مقاله	۲۰۲۵	تحلیل مقایسه‌ای ویژگی‌ها	زمان-فرکانس	MLP, DT, SVM, KNN, CNN	۸۴/۹۲	

¹ Transfer Learning

مانند LNDP و ID-LGP به دلیل مقاومت در برابر نویز و سادگی محاسباتی، گزینه‌های مناسبی برای محیط‌های با منابع محدود محسوب می‌شوند.

این یافته‌ها نشان می‌دهد که ترکیب دقیق دامنه‌های تحلیلی و انتخاب هدفمند ویژگی‌ها، درک عمیق‌تری از پاسخ‌های مغزی فراهم می‌سازد. درعین حال، استفاده از روش‌های سبک‌تر در شرایط عملیاتی محدود، همچنان نتایج قابل قبولی ارائه می‌دهد.

پیشنهاد برای پژوهش‌های آینده:

- ادغام یادگیری عمیق با مکانیزم‌های توجیه برای بهبود تعمیم‌پذیری و تحلیل تطبیقی.
- کار با داده‌های واقعی و چندکاناله خارج از محیط آزمایشگاهی جهت افزایش کارایی عملیاتی مدل‌ها.
- ارزیابی مدل در جمعیت‌های بالینی برای سنجش کاربردهای پزشکی و تشخیصی.

چارچوب پیشنهادی گامی مؤثر در طراحی سامانه‌های هوشمند برای کاربردهای علوم اعصاب، پزشکی و رابط‌های مغز-رایانه بوده و می‌تواند مبنای توسعه ابزارهای نسل جدید در پایش شناختی و تشخیص عصبی باشد.

References

- [1] L. Spillmann, & Werner, J. S. (Eds.), "Visual perception: the neurophysiological foundations," Elsevier, 2012.
- [2] E. N. Bruce, "Biomedical signal processing and signal modeling," (No Title), 2001.
- [3] H. Saadi, M. Ferroukhi, & M. Attari, "Development of wireless high immunity EEG recording system," In 2011 International Conference on Electronic Devices, Systems and Applications (ICEDSA) (pp. 120-124). IEEE, 2011, April.
- [4] M. D. McDonnell, & L. M. Ward, "The benefits of noise in neural systems: bridging theory and experiment," Nature Reviews Neuroscience, 12(7), 415-425, 2011.
- [5] D. Mahmood, H. Nisar, & Y. V. Voon, "Removal of physiological artifacts from electroencephalogram signals: a review and case study," In 2021 IEEE 9th Conference on Systems, Process and Control (ICSPC 2021) (pp. 141-146). IEEE, 2021, December.
- [6] S. Vaid, P. Singh, & C. Kaur, "EEG signal analysis for BCI interface: A review," In 2015 fifth

این دستاورد، بدون نیاز به داده‌های بسیار حجیم یا تنظیمات حساس مدل، به دست آمده است. علاوه بر آن، استفاده از روش‌های مقاوم به نویز مانند الگوی توصیف همسایگی محلی و تغییرات محلی یک‌بعدی، قابلیت پیاده‌سازی در سیستم‌های زمان واقعی و با منابع محاسباتی محدود را فراهم کرده است؛ موضوعی که بسیاری از روش‌های دیگر فاقد آن هستند. در نتیجه، رویکرد این مقاله نه تنها از نظر دقت، بلکه از منظر سادگی پیاده‌سازی، تفسیرپذیری و کارایی عملیاتی نیز برتری محسوس نسبت به سایر مطالعات دارد.

۵- نتیجه‌گیری

این پژوهش یک چارچوب چنددامنه‌ای برای تحلیل سیگنال EEG تحریک‌شده پیشنهاد کرد که با تلفیق نظام‌مند ویژگی‌های حوزه‌های زمانی، فرکانسی، زمان-فرکانس و ساختارهای محلی، بهبود معناداری در طبقه‌بندی محتوای بصری چندکلاسه حاصل شد. استفاده از آزمون کروسکال-والیس برای انتخاب ویژگی‌های معنادار و به‌کارگیری طبقه‌بندهای کلاسیک و عمیق، موجب افزایش دقت و پایداری مدل‌ها شد.

بهترین نتایج با ترکیب ویژگی‌های زمان-فرکانس، کانال Fz و شبکه عصبی کانولوشنی به دست آمد. همچنین، روش‌های محلی

- international conference on advanced computing & communication technologies (pp. 143-147). IEEE, 2015, February.
- [7] W. R. Rudnicki, M. Wrzesniec, & W. Paja, "Feature Selection for Data and Pattern Recognition," Studies in Computational Intelligence, 584, 2015.
 - [8] H. Yaacob, F. Hossain, S. Shari, S. K. Khare, C. P. Ooi, & U. R. Acharya, "Application of artificial intelligence techniques for brain-computer interface in mental fatigue detection: A systematic review (2011-2022)," IEEE Access, 11, 74736-74758, 2023.
 - [9] Z. L. Li, H. Cao, & J. S. Zhang, "Emotion Recognition in EEG Based on Multilevel Multidomain Feature Fusion," IEEE Access, 2024.
 - [10] S. Zhu, Z. Ye, Q. Ai, & Y. Liu, "EEG-ImageNet: An Electroencephalogram Dataset and Benchmarks with Image Visual Stimuli of Multi-Granularity Labels," arXiv preprint arXiv:2406.07151, 2024.
 - [11] X. Wang, Y. Pei, Z. Luo, S. Zhao, L. Xie, Y. Yan, ... & D. Ming, "Fusion of multi-domain EEG signatures improves emotion recognition," Journal of Integrative Neuroscience, 23(1), 18, 2024.

- [12] Z. Lu, & J. Wang, "A novel and efficient multi-scale feature extraction method for EEG classification," *AIMS Mathematics*, 9(6), 16605-16622, 2024.
- [13] Y. J. Chen, S. C. Chen, & C. M. Wu, "Multi-Domain Features and Multi-Task Learning for Steady-State Visual Evoked Potential-Based Brain-Computer Interfaces," *Applied Sciences*, 15(4), 2176, 2025.
- [14] Z. T. Al-Qaysi, A. S. Albahri, M. A. Ahmed, R. A. Hamid, M. A. Alsalem, O. S. Albahri, ... & A. M. Duham, "A comprehensive review of deep learning power in steady-state visual evoked potentials," *Neural Computing and Applications*, 36(27), 16683-16706, 2024.
- [15] L. Ghosh, P. Rakshit, & A. Konar, "Working memory modeling using inverse fuzzy relational approach," *Applied Soft Computing*, 83, 105591, 2019.
- [16] N. Ji, L. Ma, H. Dong, & X. Zhang, "EEG signals feature extraction based on DWT and EMD combined with approximate entropy," *Brain sciences*, 9(8), 201, 2019.
- [17] C. Zhang, Y. K. Kim, & A. Eskandarian, "EEG-inception: an accurate and robust end-to-end neural network for EEG-based motor imagery classification," *Journal of Neural Engineering*, 18(4), 046014, 2021.
- [18] Y. Kaya, M. Uyar, R. Tekin, & S. Yıldırım, "1D-local binary pattern-based feature extraction for classification of epileptic EEG signals," *Applied Mathematics and Computation*, 243, 209-219, 2014.
- [19] S. R. Das, D. Mishra, & M. Rout, "Stock market prediction using Firefly algorithm with evolutionary framework optimized feature reduction for OSELM method," *Expert Systems with Applications: X*, 4, 100016, 2019.
- [20] Sengur, "An expert system based on linear discriminant analysis and adaptive neuro-fuzzy inference system to diagnosis heart valve diseases," *Expert Systems with Applications*, 35(1-2), 214-222, 2008.
- [21] Jun, I. Choi, & D. Kim, "Local transform features and hybridization for accurate face and human detection," *IEEE transactions on pattern analysis and machine intelligence*, 35(6), 1423-1436, 2012.
- [22] K. Jaiswal, & H. Banka, "Local pattern transformation-based feature extraction techniques for classification of epileptic EEG signals," *Biomedical Signal Processing and Control*, 34, 81-92, 2017.
- [23] W. Zhang, D. Wu, J. Cao, L. Jiang, & T. Jiang, "Multibit local neighborhood difference pattern optimization for seizure detection of west syndrome EEG signals," *IEEE Sensors Journal*, 23(19), 22693-22703, 2023.
- [24] M. Verma, & B. Raman, "Local neighborhood difference pattern: A new feature descriptor for natural and texture image retrieval," *Multimedia Tools and Applications*, 77(10), 11843-11866, 2018.
- [25] Hudgins, P. Parker, & R. N. Scott, "A new strategy for multifunction myoelectric control," *IEEE transactions on biomedical engineering*, 40(1), 82-94, 1993.
- [26] H. P. Huang, & C. Y. Chen, "Development of a myoelectric discrimination system for a multi-degree prosthetic hand," In *Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No. 99CH36288C) (Vol. 3, pp. 2392-2397)*. IEEE, 1999, May.
- [27] R. Boostani, & M. H. Moradi, "Evaluation of the forearm EMG signal features for the control of a prosthetic hand," *Physiological measurement*, 24(2), 309, 2003.
- [28] S. Du, & M. Vuskovic, "Temporal vs. spectral approach to feature extraction from prehensile EMG signals," In *Proceedings of the 2004 IEEE International Conference on Information Reuse and Integration, IRI 2004. (pp. 344-350)*. IEEE, 2004, November.
- [29] Keil, EM. Bernat, MX. Cohen, M. Ding, M. Fabiani, G. Gratton, ES. Kappenman, E. Maris, KE. Mathewson, RT. Ward, N. Weisz, "Recommendations and publication guidelines for studies using frequency domain and time-frequency domain analyses of neural time series," *Psychophysiology*, 59(5):e14052, 2022 May.
- [30] F. Lotte, L. Bougrain, A. Cichocki, M. Clerc, M. Congedo, A. Rakotomamonjy, & F. Yger, "A review of classification algorithms for EEG-based brain-computer interfaces: a 10-year update," *Journal of neural engineering*, 15(3), 031005, 2018.
- [31] V. Bajaj, S. Taran, S. K. Khare, & A. Sengur, "Feature extraction method for classification of alertness and drowsiness states EEG signals," *Applied Acoustics*, 163, 107224, 2020.
- [32] S. Razavi, A. Jakeman, A. Saltelli, C. Prieur, B. Iooss, E. Borgonovo, ... & H. R. Maier, "The future of sensitivity analysis: an essential discipline for systems modeling and policy support," *Environmental Modelling & Software*, 137, 104954, 2021.
- [33] T. Zhang, W. Chen, & M. Li, "Fuzzy distribution entropy and its application in automated seizure detection technique," *Biomedical Signal Processing and Control*, 39, 360-377, 2018.
- [34] T. J. Luo, "Parallel genetic algorithm based common spatial patterns selection on time-frequency decomposed EEG signals for motor imagery brain-computer interface," *Biomedical Signal Processing and Control*, 80, 104397, 2023.
- [35] P. Agarwal, & S. Kumar, "Electroencephalography based imagined alphabets classification using spatial



- and time-domain features, ” International Journal of Imaging Systems and Technology, 32(1), 111-122, 2022.
- [36] E. Gokgoz, & A. Subasi, “Comparison of decision tree algorithms for EMG signal classification using DWT, ” Biomedical signal processing and control, 18, 138-144, 2015.
- [37] X. Wang, V. Liesaputra, Z. Liu, Y. Wang, Z. Huang, “An in-depth survey on Deep Learning-based Motor Imagery Electroencephalogram (EEG) classification, ” Artificial Intelligence in Medicine. 2:102738, 2023 Dec.
- [38] X. Tang, C. Yang, X. Sun, M. Zou, & H. Wang, “Motor imagery EEG decoding based on multi-scale hybrid networks and feature enhancement, ” IEEE Transactions on Neural Systems and Rehabilitation Engineering, 31, 1208-1218, 2023.
- [39] X. Wang, X. Dai, Y. Liu, X. Chen, Q. Hu, R. Hu, & M. Li, “Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer, ” Frontiers in Human Neuroscience, 17, 1175399, 2023.
- [40] A. K. Singh, & S. Krishnan, “Trends in EEG signal feature extraction applications, ” Frontiers in Artificial Intelligence, 5, 1072801, 2023.
- [41] S. Maddury, “The performance of domain-based feature extraction on EEG, ECG, and fNIRS for Huntington’s disease diagnosis via shallow machine learning, ” Frontiers in Signal Processing, 4, 1321861, 2024.
- [42] X. Wang, X. Dai, Y. Liu, X. Chen, Q. Hu, R. Hu, & M. Li, “Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer, ” Frontiers in Human Neuroscience, 17, 1175399, 2023
- [43] X. Wang, X. Dai, Y. Liu, X. Chen, Q. Hu, R. Hu, & M. Li, “Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer, ” Frontiers in Human Neuroscience, 17, 1175399, 2023.
- [44] Mahmoudi, N. S. Samani, A. Toumajian, “Enhancing the accuracy of hyperspectral image classification using an advanced convolutional neural network and deep learning. ” Journal of Spatial Information Technology Engineering. 2022 Mar 10;9(4):109-25.

Multidomain Analysis of Visually Evoked Brain Signals for Multiclass Visual Content Classification: An Integrated Framework Combining Temporal, Spectral, and Spatial Features

Hamed Hakkak¹, Mohammad Mahdi Khalilzadeh^{2*}, Mahdi Azarnoosh², Hamid Reza Kobravi²

¹PhD student, Department of Biomedical Engineering, Faculty of Technology and Engineering, Islamic Azad University, Mashhad, Iran

²Assistant Professor, Department of Biomedical Engineering, Faculty of Technology and Engineering, Islamic Azad University, Mashhad, Iran

Article Information

Original Research Paper

Received:

2025 September 01

Accepted:

2025 December 06

Keywords:

EEG signals, time–frequency domain analysis (TFDF), brain signal feature extraction, visual content classification, statistical feature selection

Corresponding Author*:

mmkhalilzadeh@iau.ac.ir

Abstract

This study proposes a comprehensive framework for the multidomain analysis and classification of multiclass visual content based on visually evoked electroencephalography (EEG) signals. Addressing the challenges inherent in extracting meaningful features from EEG data, the proposed approach integrates analyses across temporal, spectral, time–frequency, and local structural domains. Feature extraction leverages both classical and structural signal processing techniques, combined with statistical significance testing using the Kruskal–Walli’s method for feature selection. Subsequently, the classification performance of various machine learning models—including Support Vector Machines (SVM), k-Nearest Neighbors (KNN), Multilayer Perceptrons (MLP), and Convolutional Neural Networks (CNN)—was evaluated. The results demonstrate that time–frequency domain features (TFDF), particularly those derived from the Fz channel, achieve a mean accuracy of 84.92% in four-class visual content classification, outperforming other feature combinations. Moreover, local methods such as one-dimensional Local Gabor Patterns (1D-LGP) and Local Neighbor Descriptive Patterns (LNDP) exhibited high classification accuracy and robustness against noise. The proposed framework not only enhances classification accuracy but also maintains computational efficiency, making it a viable solution for real-time systems.

 : 10.22034/ABMIR.2025.23463.1147

E-ISSN: [2821-2037](#)

/The Author 2026. Published by Yazd University This is an open

access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

