

تشخیص احساسات با استفاده از ویژگی‌های چندفراکتالی سیگنال الکتروانسفالوگرام و روش‌های یادگیری ماشین

زهرا خسروی^۱، مهنوش تاجمیری ریاحی^۱

مقاله پژوهشی

چکیده

مقدمه: تشخیص احساسات مبتنی بر سیگنال‌های الکتروانسفالوگرام (Electroencephalogram) EEG، در کاربردهای گسترده‌ای همچون واسطه‌های مغز- رایانه، و سیستم‌های تعاملی هوشمند نقش دارد. پژوهش حاضر، تأثیر ویژگی‌های چندفراکتالی سیگنال EEG را در تشخیص دقیق و خودکار ابعاد احساسی در مدل‌های مبتنی بر هوش مصنوعی بررسی می‌کند.

روش‌ها: در این مطالعه داده‌های EEG از مجموعه دادگان برچسب گذاری شده DREAMER شامل ۱۴ کانال ثبت شده از ۲۳ شرکت کننده سالم استخراج شد. پس از اعمال مراحل پیش پردازش و تفکیک به باندهای فرکانسی آلفا، بتا، و گاما، ویژگی‌های چندفراکتالی سیگنال EEG با روش آنالیز نوسانات بدون برازش چندفراکتالی (MFDFA) محاسبه شدند. طبقه‌بندی در ابعاد احساسی برانگیختگی، ظرفیت و تسلط با بهره‌گیری از الگوریتم ماشین بردار پشتیبان (SVM) انجام گرفت.

یافته‌ها: ویژگی‌های استخراج شده از آنالیز چندفراکتالی باند آلفا بیشترین توان تمایزبخشی میان حالات احساسی را نسبت به سایر باندها داشتند. این ویژگی‌ها ضمن ساده‌سازی فرآیند محاسباتی، دقت تشخیص احساسات در هر بعد احساسی برانگیختگی، ظرفیت، و تسلط را به ترتیب به بیش از ۹۷، ۹۶ و ۹۳ درصد رساندند.

نتیجه‌گیری: ویژگی‌های چندفراکتالی، به‌ویژه در باند آلفا، در استخراج اطلاعات احساسی از سیگنال EEG بسیار مؤثرند. روش استخراج ویژگی از سیگنال EEG پیشنهاد شده در این مطالعه می‌تواند با دقت بالا ابعاد احساسی مختلف را تفکیک نماید و برای توسعه سیستم‌های هوشمند تعاملی عصبی به کار گرفته شود.

واژگان کلیدی: احساسات؛ الکتروانسفالوگرافی؛ فراکتال‌ها؛ پردازش سیگنال؛ یادگیری ماشین

ارجاع: خسروی زهرا، تاجمیری ریاحی مهنوش. تشخیص احساسات با استفاده از ویژگی‌های چندفراکتالی سیگنال الکتروانسفالوگرام و روش‌های یادگیری ماشین. مجله دانشکده پزشکی اصفهان ۱۴۰۵؛ ۴۴ (۸۶۲): ۷۲۳ – ۷۳۰.

مقدمه

تشخیص احساسات به‌عنوان یکی از حوزه‌های میان‌رشته‌ای در علوم اعصاب، روان‌شناسی و هوش مصنوعی، طی سال‌های اخیر توجه روزافزونی را به خود جلب کرده است. این حوزه کاربردهای متعددی در بهبود تعامل انسان و ماشین و توسعه سامانه‌های هوشمند دارد (۱، ۲). در این میان، سیگنال‌های EEG به دلیل ماهیت غیرتاهجی، هزینه پایین، دقت زمانی بالا، به‌عنوان منبعی غنی برای آنالیز حالات هیجانی شناخته می‌شوند. با وجود این، ساختار پیچیده و غیرخطی سیگنال EEG در کنار تفاوت‌های فردی، فرآیند آنالیز و طبقه‌بندی دقیق و خودکار احساسات را با چالش‌هایی جدی مواجه ساخته است (۳، ۴).

در پاسخ به این چالش‌ها، طراحی چارچوب‌های پردازشی مبتنی بر استخراج ویژگی‌های کارآمد و انتخاب الگوریتم‌های یادگیری مؤثر، به‌عنوان ارکان کلیدی در توسعه سامانه‌های تشخیص خودکار احساسات مطرح شده‌اند. رویکردهای موجود در این زمینه عمدتاً با بهره‌گیری از ویژگی‌های حوزه‌های زمانی، فرکانسی، زمان-فرکانسی (۱، ۵، ۶) و غیرخطی (۷، ۸) در ترکیب با الگوریتم‌های کلاسیک یادگیری ماشین و یادگیری عمیق ارائه شده‌اند که در مطالعات متعددی عملکرد قابل قبولی در بازه دقت ۶۲ تا ۹۹ درصد کسب کرده‌اند (۱، ۹). با وجود پیشرفت‌های قابل توجه، این رویکردها محدودیت‌هایی نیز دارند: بسیاری تنها بر یک یا دو نوع ویژگی تمرکز کرده‌اند و قادر به بازنمایی کامل سیگنال پیچیده و غیرخطی EEG

۱- گروه مهندسی پزشکی بیوالکتریک، دانشکده‌ی فناوری‌های نوین علوم پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

نویسنده‌ی مسؤول: مهنوش تاجمیری ریاحی؛ گروه مهندسی پزشکی بیوالکتریک، دانشکده‌ی فناوری‌های نوین علوم پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران
Email: Mtriah2000@amt.mui.ac.ir

استخراج ویژگی‌های چندفراکتالی

برای مدل‌سازی رفتار پیچیده و غیرخطی سیگنال‌های EEG، از الگوریتم MFDDFA استفاده شد که مبتنی بر نمای هرست (Hurst) وابسته به مرتبه‌ی گشتاور q است و تغییرات مشخصات آماری سیگنال در مقیاسهای مختلف را آشکار می‌سازد (۱۶، ۱۷). این روش که در الگوریتم ۱ مراحل آن مشخص شده‌اند، یک الگوریتم توسعه یافته برای آنالیز چندفراکتالی سیگنال‌های غیرایستا است که شامل مراحل اصلی چون محاسبه مجموع انباشته سری زمانی (رابطه ۱)، تقسیم سیگنال به پنجره‌های برابر (رابطه ۲)، محاسبه واریانس روند محلی با برازش چندجمله‌ای (رابطه ۳)، و محاسبه تابع نوسان برای مرتبه‌های مختلف q (رابطه ۴) است؛ در نهایت با تخمین نمای هرست وابسته به q یعنی $H(q)$ ، شاخص جرم $\tau(q)$ (رابطه ۵) و طیف چندفراکتالی $D(q)$ (رابطه ۶) استخراج می‌شود که ویژگی‌های پیچیده ساختار سیگنال را به تصویر می‌کشند (۱۸). پس از اعمال الگوریتم ۱، ۱۰ ویژگی مهم شامل میانگین، میانه، انحراف معیار، محدوده و رنج بین چارکی برای شاخص‌های نمای هرست $H(q)$ و طیف چندفراکتالی قلیل محاسبه خواهند بود. این ویژگی‌ها به تفکیک در ۱۴ کانال و در باندهای فرکانسی آلفا، بتا، و گاما سیگنال‌های EEG برای هر بعد احساسی ظرفیت، برانگیختگی، و تسلط محاسبه و در قالب برداری با ابعاد $14 \times 10 \times 18 \times 23$ برای هر بعد سازماندهی می‌شوند که به ترتیب از چپ به راست بیانگر تعداد آزمودنی‌ها، تریال‌ها (trials)، کانال‌ها و ویژگی‌ها می‌باشد. سپس، جهت ارزیابی تفاوت آماری بین دو کلاس بالا و پایین در هر یک از ابعاد احساسی ظرفیت، برانگیختگی، و تسلط، از آزمون t مستقل استفاده شد.

توسعه‌ی مدل تشخیص احساسات خودکار

برای بهبود عملکرد و پایداری مدل‌های یادگیری ماشین، ویژگی‌ها با استفاده از نرمال‌سازی خطی به بازه (۰، ۱) مقیاس‌بندی شدند تا مقادیر ویژگی‌ها با مقیاس‌های متفاوت تأثیر نامتناسب بر مدل نداشته باشند و همگی به‌طور متوازن در فرایند یادگیری مشارکت کنند. این روش به‌ویژه در الگوریتم‌های حساس به مقیاس داده مانند SVM، KNN و شبکه‌های عصبی، موجب بهبود عملکرد، پایداری و سرعت همگرایی مدل می‌شود، هرچند که نسبت به مقادیر پرت حساس است (۱۹).

برای طبقه‌بندی داده‌ها، الگوریتم SVM به کار گرفته شد (۲۰). داده‌ها به دو بخش آموزش و آزمون تقسیم شد که ۸۰ درصد به آموزش و ۲۰ درصد به تست اختصاص داده شد. در بعد احساسی برانگیختگی، مجموعه آموزش شامل ۲۵۵۴ نمونه و مجموعه تست

نیستند، عملکرد آن‌ها اغلب دیتاست‌محور است و تعمیم‌پذیری به مجموعه داده‌های دیگر محدود است، و ترکیب‌های مبتنی بر یادگیری عمیق با دقت بالا، نیازمند حجم بالای داده و منابع محاسباتی گسترده هستند (۵، ۸، ۱۰، ۱۱). در مقابل، روش پیشنهادی در مطالعه حاضر با بهره‌گیری از مجموعه‌ای جامع از ویژگی‌های چندفراکتالی و الگوریتم‌های کلاسیک، ضمن سادگی و سهولت پیاده‌سازی، توانایی بازنمایی کامل ویژگی‌های غیرخطی سیگنال EEG را فراهم می‌آورد. در همین راستا، در این مطالعه با تمرکز بر آنالیز چندفراکتالی مبتنی بر روش MFDDFA که از جمله روش‌های غیرخطی است، به بررسی امکان استخراج ویژگی‌های چندمقیاسی و مؤثر از سیگنال EEG پرداخته و عملکرد آن‌ها را در طبقه‌بندی ابعاد سه‌گانه احساسی شامل برانگیختگی (Arousal)، ظرفیت (Valence) و تسلط (Dominance) با بهره‌گیری از الگوریتم‌های یادگیری ماشین ارزیابی می‌کنیم. نوآوری این مطالعه در بهره‌گیری از شاخص‌های چندفراکتالی برای مدل‌سازی رفتار غیرخطی سیگنال و کاهش پیچیدگی داده با حفظ کیفیت طبقه‌بندی نهفته است که می‌تواند برای توسعه سامانه‌های بلادرنگ در کاربردهای هوش مصنوعی، نقش مهمی در ارتقای تعامل انسان و ماشین ایفا کند.

روش‌ها

دادگان و پیش‌پردازش

در این مطالعه، از پایگاه داده عمومی DREAMER استفاده شده است که شامل سیگنال‌های EEG ثبت‌شده از ۲۳ شرکت‌کننده سالم در بازه سنی ۲۲ تا ۳۳ سال است. داده‌ها در حین مشاهده ۱۸ کلیپ ویدیویی با محتوای عاطفی مختلف جمع‌آوری شده‌اند. سیگنال‌های EEG شامل ۱۴ کانال و با نرخ نمونه‌برداری ۱۲۸ هرتز، در دو وضعیت پایه (۶۱ ثانیه) و تحریک (۳۹۳-۶۵ ثانیه) ضبط شده‌اند. پس از هر کلیپ، شرکت‌کنندگان احساسات خود را در قالب سه شاخص برانگیختگی، ظرفیت، و تسلط در مقیاس ۱ تا ۵ گزارش کردند. این برچسب‌ها به‌منظور آنالیز طبقه‌بندی، به صورت باینری با آستانه ۲.۵ به دو دسته «بالا» و «پایین» تقسیم شدند (۱۲).

در این مطالعه فرایند پیش‌پردازش در چهار مرحله انجام شده است: ابتدا ۶۰ ثانیه پایانی سیگنال‌ها استخراج شد. سپس، برای حذف نویز و تداخلات محیطی، فیلتر فرکانسی در بازه فرکانسی ۲ تا ۵۰ هرتز اعمال گردید (۱۳). به‌منظور جبران اثرات پایه‌ای اصلاح خط پایه با کسر میانگین سیگنال در حالت استراحت از حالت تحریک انجام شد (۱۴). در نهایت، سیگنال‌های پاک‌سازی‌شده به سه باند فرکانسی مجزای آلفا (۸-۱۲ هرتز)، بتا (۱۲-۳۰ هرتز)، و گاما (۳۰-۵۰ هرتز) با استفاده از فیلترهای میان‌گذر فرکانسی تفکیک شدند.

$$l = 1, \dots, N ;$$

(۱) محاسبه مجموع انباشته سری‌های زمانی از میانگین

$$y(i) = \sum_{k=1}^i |x_k - \bar{x}| \quad (۱)$$

$$N_s = \text{int} \left(\frac{N}{s} \right) \quad (۲)$$

(۲) تعریف مجموعه‌ای از پنجره‌ها برای بخش غیرهمپوشان

$$v = N_s + 1, N_s + 2, N_s + 3, \dots, 2N_s$$

(۳) محاسبه واریانس با حداقل مربعات

$$F^*(s, v) = \frac{1}{s} \sum_{i=1}^s \{Y[N - (v - N_s)s + i] - y_{v(i)}\}^2 \quad (۳)$$

(۴) محاسبه تابع نوسانات مرتبه q

$$F_q(s) = \left(\frac{1}{2N_s} \sum_{v=1}^{2N_s} |F^*(s, v)|^{\frac{q}{2}} \right)^{\frac{1}{q}} \quad (۴)$$

$$F_q(s) \propto s^{H(q)}$$

(۵) محاسبه $F_q(s)$ برای سری‌های همبسته دوبرد

$$\tau(q) = qH(q) - 1 \quad (۵)$$

(۶) محاسبه شاخص جرم $\tau(q)$


$$\lim_{\epsilon \rightarrow \infty} \frac{\tau(q + \epsilon) - \tau(q)}{\epsilon} = h(q)$$

$$\frac{d\tau(q)}{dq} = D(q) \quad (۶)$$

(۷) تبدیل $\tau(q)$ به نقاط تکینگی $(h(q))$ با استفاده از مشتق تابع جرم و رسم

طیف تکینگی $(D(q))$ با مقیاس q

الگوریتم MADFA



شکل ۱. نمای کلی روش پیشنهادی تشخیص احساسات از سیگنال‌های EEG.


یافته‌ها

نمونه‌ای از طیف‌های چندفراکتالی سیگنال EEG در ابعاد احساسی به تفکیک باندهای فرکانسی و برخی ویژگی‌های استخراج شده در شکل ۲ نمایش داده شده‌اند. در ادامه، نتایج به‌دست‌آمده از دو منظر تست آماری و طبقه‌بندی با یادگیری ماشین بررسی شده‌اند. جهت ارزیابی معناداری آماری ویژگی‌های استخراج‌شده، آزمون t مستقل بین دو کلاس «بالا» و «پایین» در هر بعد احساسی و برای هر باند فرکانسی انجام شد. نتایج نشان داد که در بعدهای احساسی برانگیختگی و تسلط، اکثر ویژگی‌های چندفراکتالی بلند آلفا دارای تفاوت معنادار آماری بودند ($P < 0.05$). درحالی‌که، ویژگی‌های چندفراکتالی بلند بتا در بعد ظرفیت، تفاوت آماری معناداری داشتند.

شامل ۶۳۸ نمونه بود. برای بعد احساسی ظرفیت، ۳۶۰۶ نمونه برای آموزش و ۹۰۲ نمونه برای تست در نظر گرفته شد، و در بعد احساسی تسلط، مجموعه آموزش و آزمون به ترتیب شامل ۲۱۲۸ و ۵۳۲ نمونه بودند. برای هر بعد احساسی یک مدل مجزا توسعه داده شد و پارامترهای مدل‌ها با استفاده از اعتبارسنجی متقاطع ده‌گانه بهینه‌سازی گردیدند. عملکرد نهایی مدل‌ها بر اساس معیارهای استاندارد شامل صحت، دقت، حساسیت، اختصاصیت و امتیاز F ارزیابی شد. کلیه مراحل در محیط نرم‌افزاری MATLAB پیاده‌سازی شده‌اند. روند کلی روش در شکل ۱ نمایش داده شده است.

این مقاله با شناسه اخلاق IR.MUI.DHMT.REC.1403.078

تایید شده است.



شکل ۲. نمونه‌ای از طیف‌های چندفراکتالی. (a) نمونه‌ای از طیف‌های چندفراکتالی در باندهای آلفا، بتا و گاما در دو وضعیت برانگیختگی بالا و پایین، (b) نمونه‌ای از طیف‌های چندفراکتالی در باندهای آلفا، بتا و گاما در دو وضعیت ظرفیت بالا و پایین، (c) نمونه‌ای از طیف‌های چندفراکتالی در باندهای آلفا، بتا و گاما در دو وضعیت تسلط بالا و پایین، (d) نمایش برخی از ویژگی‌های چندفراکتالی استخراج شده از سیگنال EEG. محدوده، انحراف استاندارد، میانگین، میانه.

جدول ۱. ارزیابی عملکرد طبقه‌بند SVM بر داده‌های تست در ابعاد احساسی سه‌گانه و باندهای فرکانسی.

بعد احساسی	باندهای فرکانسی	صحت	دقت	حساسیت	اختصاصیت	امتیاز F
برانگیختگی	آلفا	$97/83 \pm 2/17$	$96/00 \pm 4$	$100/00 \pm 0/00$	$95/65 \pm 4/35$	$97/92 \pm 2/08$
	بتا	$98/92 \pm 1/08$	$97/37 \pm 2/63$	$100/00 \pm 0/00$	$98/22 \pm 1/78$	$97/65 \pm 2/35$
	گاما	$97/03 \pm 1/95$	$97/19 \pm 2/32$	$98/10 \pm 1/90$	$96/80 \pm 1/89$	$97/43 \pm 2/08$
ظرفیت	آلفا	$98/83 \pm 0/78$	$97/80 \pm 1/44$	$99/07 \pm 0/93$	$97/54 \pm 1/60$	$97/89 \pm 0/71$
	بتا	$98/44 \pm 1/56$	$100/00 \pm 0/00$	$96/88 \pm 3/12$	$100/00 \pm 0/00$	$98/39 \pm 1/61$
	گاما	$99/22 \pm 0/78$	$100/00 \pm 0/00$	$98/61 \pm 1/39$	$100/00 \pm 0/00$	$99/30 \pm 0/70$
تسلط	آلفا	$98/69 \pm 1/31$	$100/00 \pm 0/00$	$97/50 \pm 2/50$	$100/00 \pm 0/00$	$98/72 \pm 1/28$
	بتا	$96/49 \pm 1/93$	$93/22 \pm 3/49$	$100/00 \pm 0/00$	$93/17 \pm 4/16$	$96/81 \pm 1/89$
	گاما	$97/90 \pm 1/06$	$99/05 \pm 0/95$	$97/14 \pm 1/90$	$98/89 \pm 1/11$	$97/85 \pm 1/10$

جدول ۲. مقایسه‌ی عملکرد طبقه‌بندهای SVM، KNN و RF بر داده‌های تست در ابعاد احساسی سه‌گانه و باند فرکانسی آلفا.

بعد احساسی	طبقه‌بندها	صحت	دقت	حساسیت	اختصاصیت	امتیاز F
برانگیختگی	SVM	$97/83 \pm 2/17$	$96/00 \pm 4$	$100/00 \pm 0/00$	$95/65 \pm 4/35$	$97/92 \pm 2/08$
	KNN	$90/22 \pm 4/61$	$88/31 \pm 5/22$	$93/75 \pm 2/94$	$86/37 \pm 6/45$	$87/85 \pm 8/50$
	RF	$93/48 \pm 0/00$	$93/83 \pm 2/58$	$93/75 \pm 2/94$	$93/18 \pm 3/21$	$93/75 \pm 0/18$
ظرفیت	SVM	$98/83 \pm 0/78$	$97/80 \pm 1/44$	$99/07 \pm 0/93$	$97/54 \pm 1/60$	$98/89 \pm 0/71$
	KNN	$92/19 \pm 4/43$	$94/29 \pm 4/94$	$91/67 \pm 3/33$	$92/86 \pm 4/97$	$92/95 \pm 3/73$
	RF	$94/53 \pm 0/78$	$95/31 \pm 4/69$	$94/17 \pm 3/54$	$95/59 \pm 4/41$	$94/60 \pm 1/48$
تسلط	SVM	$98/69 \pm 1/31$	$100/00 \pm 0/00$	$97/50 \pm 2/50$	$100/00 \pm 0/00$	$98/72 \pm 1/28$
	KNN	$79/83 \pm 2/42$	$78/49 \pm 0/32$	$85/00 \pm 7/07$	$74/07 \pm 2/56$	$81/45 \pm 3/27$
	RF	$94/74 \pm 2/63$	$93/57 \pm 2/66$	$96/67 \pm 2/89$	$92/59 \pm 3/20$	$95/08 \pm 2/44$

بر این اساس، طبقه‌بندی داده‌ها در هر بعد احساسی مبتنی بر تمامی ده ویژگی استخراج‌شده والگوریتم SVM انجام شد و با نتایج الگوریتم‌های K- نزدیک‌ترین همسایه (KNN) و جنگل تصادفی (RF) مقایسه گردید.

جدول ۱، عملکرد الگوریتم SVM را به‌عنوان برترین مدل در طبقه‌بندی سه بعد احساسی و به تفکیک باندهای آلفا، بتا، و گاما نمایش می‌دهد. به‌طور مشخص، دقت طبقه‌بندی تست در برخی شرایط به ۱۰۰ درصد نیز رسیده است، که نشان‌دهنده توان بالای ویژگی‌های چندفراکتالی در بازنمایی حالات احساسی است. جدول ۲، مقایسه‌ای از عملکرد طبقه‌بندهای مختلف شامل SVM، KNN و RF را بر پایه ویژگی‌های چندفراکتالی استخراج‌شده از باند آلفا در سه بعد احساسی ارائه می‌دهد.

بحث

هدف اصلی این مطالعه، تشخیص دقیق ابعاد احساسی بر اساس ویژگی‌های استخراج‌شده از تحلیل چندفراکتالی باندهای مختلف سیگنال EEG و توسعه یک مدل خودکار بر مبنای یادگیری ماشین

است. مبتنی بر جدول ۱، یافته‌ها نشان دادند که ویژگی‌های استخراج‌شده باند فرکانسی آلفا، در تشخیص احساس در ابعاد برانگیختگی و تسلط از نظر حساسیت و دقت نقش برجسته‌ای ایفا می‌کنند. این نتیجه با پژوهش‌های پیشین از جمله مطالعات Khare و همکاران (۹)، Zhang و همکاران (۱)، He و همکاران (۴) همخوانی داشت، که به اهمیت سیگنال‌های آلفا در پردازش حالات هیجانی و توجه اشاره کرده‌اند. در مقابل، ویژگی‌های استخراج‌شده در باندهای بتا و گاما تفاوت آماری کمتری میان دو کلاس بالا و پایین نشان دادند، که این موضوع نیز مشابه نتایج Gaurav و همکاران (۷) بوده و نشان‌دهنده نقش محدودتر این باندها در بازنمایی احساسات است. از منظر طبقه‌بندی، الگوریتم SVM در تمامی ابعاد احساسی عملکرد بهتری نسبت به KNN و RF نشان داد. این یافته با نتایج مطالعات Wang و همکاران (۲۱)، Li و همکاران (۲۲) هم‌راستا بود که SVM را به‌عنوان روشی کارآمد برای آنالیز EEG در مسائل مربوط به شناخت و احساس معرفی کرده‌اند.

پیچیدگی محاسباتی روش پیشنهادی به تعداد نمونه‌ها و ویژگی‌های استخراج‌شده وابسته است. آزمایش‌ها در محیط

سن، جنسیت)، وابسته به فرد بودن مدل وجود دارد. همچنین، از نظر پیچیدگی زمانی، روش‌های مبتنی بر یادگیری ماشین کلاسیک، با توجه به تعداد نمونه‌ها و ویژگی‌های استخراج‌شده، زمان پردازش قابل‌قبولی دارند، در حالی که به‌کارگیری یادگیری عمیق برای داده‌های حجیم ممکن است نیازمند زمان پردازش قابل‌توجهی باشد. بنابراین؛ پژوهش‌های آینده می‌توانند با ترکیب ویژگی‌های چندمنظوره، بهره‌گیری از یادگیری عمیق همراه با استخراج ویژگی‌ها و گسترش به داده‌های چندوجهی و توسعه مدل‌های مستقل از فرد، عملکرد و قابلیت تعمیم‌پذیری سیستم‌های تشخیص احساسات EEG را بهبود بخشند.

نتیجه‌گیری

یافته‌های این پژوهش نشان داد که آنالیز چندفراکتالی مبتنی بر الگوریتم MFDDFA روشی مؤثر برای استخراج ویژگی‌های غیرخطی از سیگنال EEG در تشخیص احساسات است. ترکیب این ویژگی‌ها با الگوریتم‌های یادگیری ماشین، به‌ویژه SVM، دقت طبقه‌بندی را به بیش از ۹۳ درصد رسانده است. این رویکرد با وجود سادگی و هزینه اجرای پایین، قابلیت تعمیم به کاربردهای واقعی مانند تعامل انسان و ماشین در حوزه‌های بالینی دارد، و چشم‌انداز جدیدی برای توسعه سامانه‌های هوشمند تحلیل احساسات مبتنی بر EEG فراهم می‌سازد.

تشکر و قدردانی

این مقاله منتج از پایان‌نامه مقطع کارشناسی ارشد رشته‌ی مهندسی پزشکی با کد ۳۴۰۳۲۰۸ می‌باشد که در دانشگاه علوم پزشکی اصفهان به تصویب رسیده و با حمایت مالی دانشگاه علوم پزشکی اصفهان به انجام رسیده است. بدین‌وسیله از زحمات دکتر تاجمیر ریاحی تقدیر و تشکر می‌شود.

MATLAB نسخه R2022a بر روی سیستمی با پردازنده Intel Core i5-8250U و ۸ گیگابایت رم و سیستم عامل ۶۴ بیتی انجام شد. نتایج نشان داد که استخراج ویژگی‌های چندفراکتالی و آموزش الگوریتم‌های یادگیری ماشین و انتخاب مدل بهینه، حداکثر به مدت زمان حدود ۴۰ دقیقه نیاز داشت که نشان‌دهنده پیچیدگی محاسباتی محدود است. همچنین، زمان پردازش برای تست یک نمونه جدید معمولاً کمتر از ۱ دقیقه بود که توانایی امکان استفاده عملی و آنلاین روش پیشنهادی را فراهم می‌کند.

همچنین، تحقیقات پیشین نشان داده‌اند که تحلیل چندفراکتالی EEG می‌تواند اطلاعات غیرخطی ارزشمندی درباره حالات احساسی ارائه دهد. برای مثال، Paul و همکاران با استفاده از MFDDFA توانستند احساسات پایه را تشخیص دهند، هرچند تحلیل محدود به چند کانال و تعداد ویژگی‌ها کمتر نسبت به کار ما بود (۲۳).

Avramidis و همکاران با بهره‌گیری از تحلیل چندمقیاسی و طیف چندفراکتالی سیگنال‌های EEG، تشخیص احساسات القاشده توسط موسیقی را بررسی کردند و نشان دادند که ویژگی‌های غیرخطی بلند آلفا نقش مهمی در تفکیک حالات احساسی دارند. یافته‌های حاضر با این مطالعات همسو بود و علاوه بر تأکید بر اهمیت باند آلفا، شامل استخراج ویژگی‌های جامع‌تر و مقایسه عملکرد الگوریتم‌های SVM، KNN و RF در سه بعد احساسی برانگیختگی، ظرفیت، و تسلط است (۲۴).

با این وجود، سیگنال‌های EEG هر فرد منحصر به فرد هستند و تعمیم روش‌های آموزش دیده با استفاده از یک دیتاست محدود روی دیتاست‌های دیگر با چالش‌هایی مواجه است. از این‌رو، از محدودیت‌های این پژوهش می‌توان به حجم نمونه محدود اشاره کرد که ممکن است بر الگوهای EEG و پاسخ‌های احساسی تأثیرگذار باشند. همچنین، محدودیت‌هایی مانند عدم کنترل عوامل فردی (مانند

References

1. Zhang J, Yin Z, Chen P, Nichele S. Emotion recognition using multi-modal data and machine learning techniques: A tutorial and review. Information Fusion 2020; 59(1): 103-26.
2. Zhang Z, Wang X, Li P, Chen X, Shao L. Research on emotion recognition based on ECG signal. Journal of Physics Conference Series 2020; 1678(1): 012091.
3. Zheng W-L, Dong B-N, Lu B-L. Multimodal emotion recognition using EEG and eye tracking data. 2014 36th annual international conference of the IEEE engineering in medicine and biology society; Chicago, IL, USA; 2014.
4. He Z, Li Z, Yang F, Wang L, Li J, Zhou C, et al. Advances in multimodal emotion recognition based on brain-computer interfaces. Brain Sci 2020; 10(10): 687.
5. Yan Y, Wu X, Li C, He Y, Zhang Z, Li H, et al. Topological EEG nonlinear dynamics analysis for emotion recognition. IEEE Transactions on Cognitive and Developmental Systems 2022; 15(2): 625-38.
6. Doma V, Pirouz M. A comparative analysis of machine learning methods for emotion recognition using EEG and peripheral physiological signals. J Big Data 2020; 7(1): 18.
7. Gaurav G, Anand RS, Kumar V. EEG based cognitive task classification using multifractal detrended fluctuation analysis. Cogn Neurodyn 2021; 15(6): 999-1013.

8. Gao Z, Cui X, Wan W, Zheng W, Gu Z. Long-range correlation analysis of high frequency prefrontal electroencephalogram oscillations for dynamic emotion recognition. *Biomedical Signal Processing and Control* 2022; 72: 103291.
9. Khare SK, Blanes-Vidal V, Nadimi ES, Acharya UR. Emotion recognition and artificial intelligence: A systematic review (2014–2023) and research recommendations. *Information fusion*. 2024; 102: 102019.
10. Bagherzadeh S, Shalbaf A, Shoeibi A, Jafari M, Tan R-S, Acharya UR. Developing an EEG-based emotion recognition using ensemble deep learning methods and fusion of brain effective connectivity maps. *IEEE Access* 2024; 12: 50949-65.
11. Subasi A, Tuncer T, Dogan S, Tanko D, Sakoglu U. EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier. *Biomedical Signal Processing and Control* 2021; 68: 102648.
12. Katsigiannis S, Ramzan N. DREAMER: A database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices. *IEEE Journal of Biomedical and Health Informatics* 2017; 22(1): 98-107.
13. Sen D, Mishra BB, Pattnaik PK, editors. A review of the filtering techniques used in EEG signal processing. *Proceedings of the 7th International Conference on Trends in Electronics and Informatics (ICOEI)*; 2023: IEEE.
14. Oppenheim AV. *Discrete-time signal processing*. Pearson Education India; 1999.
15. Hu L, Xiao P, Zhang Z, Mouraux A, Iannetti GD. Single-trial time–frequency analysis of electrocortical signals: Baseline correction and beyond. *Neuroimage* 2014; 84: 876-87.
16. Bacry E, Delour J, Muzy J-F. Multifractal random walk. *Physical review E*. 2001; 64(2): 026103.
17. Márton L, Brassai ST, Bakó L, Losonczi L. Detrended fluctuation analysis of EEG signals. *Procedia Technology* 2014; 12: 125-32.
18. Ihlen EA. Introduction to multifractal detrended fluctuation analysis in Matlab. *Front Physiol* 2012; 3: 141.
19. Han J, Pei J, Tong H. *Data mining: concepts and techniques*. New York, NY: Morgan kaufmann; Elsevier Inc; 2022.
20. Theodoridis S, Koutroumbas K. *Pattern recognition*. New York, NY: Elsevier; 2006.
21. Wang F, Wang H, Zhou X, Fu R. A driving fatigue feature detection method based on multifractal theory. *IEEE Sensors Journal* 2022; 22(19): 19046-59.
22. Li W, Fang C, Zhu Z, Chen C, Song A. Fractal spiking neural network scheme for EEG-based emotion recognition. *IEEE J Transl Eng Health Med* 2023; 12: 106-18.
23. Paul S, Mazumder A, Ghosh P, Tibarewala D, Vimalarani G. EEG based emotion recognition system using MFDFA as feature extractor. *Proceedings of the International Conference on Robotics, Automation, Control and Embedded Systems (RACE)*; 2015: IEEE.
24. Avramidis K, Zlatintsi A, Garoufis C, Maragos P. Multiscale fractal analysis on EEG signals for music-induced emotion recognition. *Proceedings of the 29th European Signal Processing Conference (EUSIPCO)*; 2021: IEEE.

Emotion Recognition Using Multifractal Features of Electroencephalogram Signals and Machine Learning Methods

Zahra Khosravi¹, Mahnoosh Tajmiriahi¹

Original Article

Abstract

Background: Emotion recognition based on electroencephalogram (EEG) signals plays a significant role in a wide range of applications, such as brain-computer interfaces and intelligent interactive systems. The present study investigates the impact of multifractal features derived from EEG signals on the accurate and automatic detection of emotional dimensions using artificial intelligence-based models.

Methods: EEG data were obtained from the labeled DREAMER dataset, consisting of 14 channels recorded from 23 healthy participants. Following preprocessing steps and decomposition into alpha, beta, and gamma frequency bands, multifractal features of the EEG signals were extracted using the Multifractal Detrended Fluctuation Analysis (MFDFA) method. Classification of the emotional dimensions—arousal, valence, and dominance—was performed using the Support Vector Machine (SVM) algorithm.

Findings: Multifractal features extracted from the alpha band exhibited the highest discriminative power among emotional states compared to other frequency bands. These features not only simplified the computational process but also improved the accuracy of emotion recognition in the arousal, valence, and dominance dimensions to over 96%, 97%, and 93%, respectively.

Conclusion: Multifractal features—particularly in the alpha band—are highly effective in extracting emotional information from EEG signals. The proposed EEG-based feature extraction method can accurately distinguish between different emotional dimensions and can be utilized for the development of intelligent neuro-interactive systems.

Keywords: Emotions; Electroencephalography; Fractals; Signal processing; Machine learning

Citation: Khosravi Z, Tajmiriahi M. **Emotion Recognition Using Multifractal Features of Electroencephalogram Signals and Machine Learning Methods.** J Isfahan Med Sch 2026; 44(862): 723- 30.

1- Bioelectrical Engineering and Bioelectric Department, School of Advanced Technologies in Medical Sciences, Isfahan University of Medical Sciences, Isfahan, Iran

Corresponding Author: Mahnoosh Tajmiriahi, Bioelectrical Engineering and Bioelectric Department, School of Advanced Technologies in Medical Sciences, Isfahan University of Medical Sciences, Isfahan, Iran; Email: Mtriahi2000@amt.mui.ac.ir