

ترکیب داده‌های چندوجهی برای تشخیص افسردگی در تویتر

رضا رضایی^۱، ابوالفضل نادی^{۲*}

^۱ دانشجوی کارشناسی ارشد هوش مصنوعی، گروه علوم کامپیوتر، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکدگان علوم، دانشگاه

تهران، تهران، ایران

^۲ استادیار گروه علوم کامپیوتر، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکدگان علوم، دانشگاه تهران، تهران، ایران

مقاله پژوهشی

چکیده

افسردگی یکی از شایع‌ترین بیماری‌های روانی دنیای امروز است که می‌توان آن را با استفاده از اطلاعات موجود در شبکه‌های اجتماعی به‌طور مؤثری شناسایی کرد. استفاده از شبکه‌های اجتماعی برای مقاصد مختلف در سال‌های گذشته افزایش داشته است، زیرا این شبکه‌ها بیانگر اطلاعات مهمی هم از افراد و هم از جامعه هستند. پژوهشگران تلاش کرده‌اند تا افسردگی را با استفاده از وجوه مختلف اطلاعات مثل عکس، متن و صوت شناسایی کنند؛ اما بیشتر پژوهش‌ها تمرکز بر این موضوع داشتند که فقط از یک نوع اطلاعات مثل متن یا عکس برای تشخیص استفاده کنند که به نتایج قابل توجهی دست یافته‌اند. در این پژوهش یک مدل هوش مصنوعی چندوجهی از نوع شبکه‌های عمیق معرفی می‌شود که اطلاعات متن و عکس را با هم تحلیل کرده و افسردگی را تشخیص می‌دهد. این پژوهش از کدگذار متنی Bert و ResNet برای استخراج ویژگی استفاده می‌کند. این مدل نسبت به مدل‌های مشابه با استفاده از مقدار بسیار کمتری از مجموعه داده اصلی، دقت را نزدیک به ۵ درصد ارتقا داده است و به ۸۹/۸۷ درصد رسانده است.

تاریخ دریافت:

۱۴۰۳/۰۹/۰۹

تاریخ پذیرش:

۱۴۰۳/۱۰/۱۵

کلیدواژه‌ها:

تشخیص افسردگی، ترکیب داده‌های چندوجهی، تحلیل احساسات، شبکه‌های اجتماعی

نویسنده مسئول:

a.nadi@ut.ac.ir

doi : 10.22034/abmir.2025.22331.1080

E-ISSN: [2821-2037](https://doi.org/10.22034/abmir.2025.22331.1080) /© 2023. 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

می‌دهد که بتوان با استفاده از اطلاعات این شبکه‌ها بیماری‌های روانی از جمله افسردگی را تشخیص داده و اقدامات لازم را انجام دهند [۴].

امکان تشخیص زودهنگام افسردگی نیز یکی از نکات مهمی است که با استفاده از این روش‌ها ممکن می‌شود. افراد افسرده به علت اختلال در شخصیت خود معمولاً ارتباطات اجتماعی خود را کمتر می‌کنند و انتشار اطلاعات در شبکه‌های اجتماعی را با الگویی خاص دنبال می‌کنند. این امر باعث می‌شود که روش‌های روانکاوی دچار چالش‌هایی شوند، ولی در تحلیل افراد با استفاده از شبکه‌های اجتماعی، این چالش‌ها وجود ندارند.

با این حال، استفاده از شبکه‌های اجتماعی با چالش‌های قابل توجهی روبه‌رو است. در چند سال گذشته، پلتفرم‌های ارائه‌دهنده خدمات، سیاست انتشار اطلاعات خود را سخت‌گیرانه‌تر کرده‌اند. به‌طوری‌که مجموعه داده‌های بسیار کمی در این حوزه در دسترس پژوهشگران قرار دارد. سیاست حریم خصوصی کاربران در شبکه‌هایی مثل اینستاگرام و فیس‌بوک به شدت سخت‌گیرانه شده است. از سوی دیگر، برجسب‌زنی داده‌ها در این شبکه‌ها باید با دقت انجام شود و روش‌های مورد استفاده به درستی تنظیم شوند [۵].

در این راستا، استفاده از مدل‌های چندوجهی^۱ در شناسایی افسردگی و دیگر اختلالات روانی، پیشرفت قابل توجهی را ایجاد کرده است. مدل‌های چندوجهی با استفاده از ترکیب داده‌های مختلف از منابع گوناگون مانند متن، صدا و تصویر، به شناسایی دقیق‌تری از ویژگی‌های رفتاری و عاطفی افراد کمک می‌کنند. به‌عنوان مثال، در برخی از مطالعات، داده‌های متنی از شبکه‌های اجتماعی مانند پست‌ها و کامنت‌ها یا داده‌های صوتی و ویدئوهای مربوط به فرد مورد تحلیل قرار گرفته‌اند. این رویکرد باعث می‌شود که مدل قادر به شناسایی علائم افسردگی از ابعاد مختلف رفتار فرد باشد. یکی از دلایل این امر در این است که افراد افسرده معمولاً تغییرات خاصی در نحوه تعاملات کلامی، نوشتاری و حتی صوتی خود نشان می‌دهند.

در عصر امروز، شاهد گسترش روزافزون بیماری‌های روانی مثل افسردگی و اضطراب هستیم. این بیماری‌ها مخصوصاً برای سنین جوان به یک چالش تبدیل شده‌اند. به‌طوری‌که در چند سال گذشته، توجه به افسردگی به‌عنوان شایع‌ترین بیماری، بسیار زیاد شده است. افسردگی اثرات مخربی بر کیفیت زندگی افراد می‌گذارد و باعث کاهش سطح رضایت و بازدهی افراد می‌شود و حتی ممکن است در درجات حاد به خودکشی منجر شود.

تشخیص زودهنگام افسردگی بسیار اهمیت دارد؛ زیرا در مراحل ابتدایی، درمان بسیار راحت‌تر است. تشخیص افسردگی معمولاً از طریق روانکاوی بالینی انجام می‌شود. این کار نه تنها زمان‌بر است، بلکه زمانی که فرد در جلسه روانکاوی شرکت می‌کند، ممکن است اطلاعات درونی خود را به درستی آشکار نکند. یکی از دلایل این امر، شرایط خاص جلسه روانکاوی است. جلسات روانکاوی معمولاً استرس‌زا هستند. از طرفی، روانکاوی برای میلیون‌ها انسان امری بسیار هزینه‌بر و زمان‌بر است؛ لذا می‌توان از توانمندی هوش مصنوعی برای بررسی و روانکاوی افراد استفاده کرد.

در چند سال گذشته شاهد پیشرفت‌های بسیار شگفت‌آوری در حوزه علم هوش مصنوعی بوده‌ایم. این پیشرفت‌ها منجر به تولید ابزارهای بسیار قدرتمندی شده‌اند که توانمندی ایجاد تحول در علوم دیگر از جمله روان‌شناسی و پزشکی را دارند. هوش مصنوعی، با قابلیت‌های پیشرفته خود در تحلیل داده‌ها و شناسایی الگوها، امکان شناسایی نشانه‌های اولیه بیماری‌های روانی را فراهم می‌آورد. حال برای استفاده از پیشرفت‌های حاصل در حوزه هوش مصنوعی، نیاز داریم اطلاعات زیادی را جمع‌آوری کنیم، زیرا مدل‌های هوش مصنوعی جدید برای آموزش به میزان زیادی از داده نیاز دارند.

برای فراهم کردن این اطلاعات می‌توان از توانمندی شبکه‌های اجتماعی نیز استفاده کرد [۱]. شبکه‌های اجتماعی یکی از منابع اطلاعاتی مهم در عصر جدید هستند. این شبکه‌ها آینه وضعیت جامعه و افراد در حوزه‌های مختلف جامعه‌شناسی، روان‌شناسی و ... هستند [۲][۳]. این منبع عظیم به پژوهشگران این فرصت را

¹ Multi-modal

مصاحبه‌های روان‌درمانی با مدل‌های یادگیری ماشین متمرکز شده‌اند و نشان داده‌اند که این مدل‌ها می‌توانند علائم افسردگی را با دقت بالایی تشخیص دهند [۶].

ایبوتو و همکاران از مدل‌های یادگیری عمیق مانند شبکه‌های عصبی LSTM^۵ برای تحلیل داده‌های متنی جلسات روان‌درمانی استفاده کرده و موفق به شناسایی نشانه‌های افسردگی از داده‌های گفتاری و متنی شده‌اند. این مدل‌ها با تمرکز بر ویژگی‌های زبانی و تحلیل احساسات موجود در مکالمات می‌توانند تفاوت‌های میان بیماران مبتلا به افسردگی و سایرین را تشخیص دهند. همچنین، مطالعات دیگری از داده‌های متن محور در رسانه‌های اجتماعی مانند توییتر و انجمن‌های برخط^۳ برای شناسایی الگوهای مرتبط با افسردگی بهره برده‌اند تا به مدل‌هایی برای تشخیص زود هنگام علائم افسردگی دست یابند [۷].

این پژوهش‌ها که از داده‌هایی مانند مجموعه‌های DAIC-WOZ و GPC بهره برده‌اند، اغلب از رویکردهای چندوظیفه‌ای^۴ استفاده کرده‌اند تا علاوه بر تشخیص افسردگی، شدت آن را نیز ارزیابی کنند. این رویکردها به‌ویژه در سیستم‌های هوشمند سلامت روان، برای پشتیبانی از تشخیص‌های بالینی و کاهش زمان و هزینه‌های تشخیص مفید بوده‌اند [۶] [۷].

در سال‌های اخیر، داده‌های شبکه‌های اجتماعی به یکی از منابع مهم در این حوزه تبدیل شده است. همچنین پژوهش‌های اخیر، متمرکز بر ترکیب وجوه مختلف داده‌ها با یکدیگر بوده‌اند.

تکنیک‌های مختلفی، از جمله روش‌های آماری و کلاسیک یادگیری ماشین مانند بیز ساده^۵ و ماتریس‌های مشترک توجه^۶، و همچنین مدل‌های یادگیری تقویتی^۷، برای ترکیب داده‌های مختلف در این شبکه‌ها به کار گرفته شده‌اند [۸]. همچنین یادگیری عمیق^۸ در این حوزه به‌صورت گسترده استفاده شده است [۹] [۱۰] [۱۱] [۱۲]. این روش‌ها می‌توانند داده‌هایی با انواع مختلف را به‌طور مؤثر ترکیب کنند، مانند ترکیب متن و تصویر که دقت مدل‌ها را افزایش می‌دهد [۱۳] [۱۴].

مدل‌های چندوجهی می‌توانند اطلاعات مختلف را به‌طور هم‌زمان پردازش کرده و ویژگی‌های مختلف هر منبع را به هم پیوند دهند. به‌عنوان مثال، از مدل‌های پردازش زبان طبیعی برای تحلیل محتوای متنی استفاده می‌شود و از مدل‌های پردازش تصویر یا صدا برای تحلیل داده‌های غیرمتنی بهره گرفته می‌شود. تجمیع وجوه مختلف، دقت تشخیص را افزایش می‌دهد و به مدل این امکان را می‌دهد تا نشانه‌های غیرمستقیم و پیچیده‌تری از افسردگی را شناسایی کند که ممکن است در یک وجه به‌تنهایی قابل مشاهده نباشند. پیشرفت‌های صورت گرفته در هوش مصنوعی و همچنین منابع محاسباتی این امکان را به پژوهشگران می‌دهند که با استفاده از مدل‌های چندوجهی به تشخیص بهتر و دقیق‌تر دست پیدا کنند. در این پژوهش بر آنیم تا با استفاده از این مدل‌های چندوجهی به دقت بهتری در این حوزه دست پیدا کنیم.

ساختار مقاله به شرح زیر است: در بخش پیشینه پژوهش به بررسی پژوهش‌های انجام شده در حوزه تشخیص افسردگی با استفاده از داده‌های شبکه‌های اجتماعی و جلسات روانکاو پرداخته می‌شود. در بخش روش پیشنهادی ساختار مدل و اجزای آن شرح داده می‌شود. در بخش نتایج نیز به نتایج به‌دست آمده از آموزش و ارزیابی مدل پرداخته می‌شود.

۲- پیشینه پژوهش

در تشخیص افسردگی می‌توان از روش‌های مختلف و منابع داده مختلف استفاده کرد. یکی از این منابع، داده‌های جمع‌آوری شده از جلسات روانکاو و روان‌شناسی است. متن گفت‌وگوهای ردوبدل شده به‌عنوان یک منبع داده مهم می‌تواند در تشخیص افسردگی مورداستفاده قرار گیرد. این روش‌ها فقط متن را به‌عنوان وجه در نظر می‌گیرند و به‌عنوان روش‌های تک‌وجهی^۱ دسته‌بندی می‌شوند. کامینز و همکاران با بهره‌گیری از داده‌های متنی جلسات روان‌درمانی و داده‌های بالینی در تشخیص افسردگی، از روش‌های هوش مصنوعی و پردازش زبان طبیعی برای شناسایی نشانه‌های افسردگی استفاده کرده‌اند. بسیاری از این مطالعات بر تحلیل

⁵ Naive Bayesian

⁶ Joint Attention Matrix

⁷ Reinforcement Learning

⁸ Deep learning

¹ Single-modal

² Long short term memory

³ Online

⁴ Multi task

مقالاتی مانند [۱۱] و [۱۶] به دلیل اهمیت زمانی در رفتارهای کاربران، ویژگی‌های زمانی را به‌عنوان یکی از وجه‌های تحلیل افزوده‌اند. این پژوهش‌ها بر اساس ماهیت تغییرات زمانی در علائم افسردگی، از داده‌های مرتبط با توالی زمانی استفاده کرده‌اند. از سوی دیگر، مقالاتی مانند [۱۲] و [۱۵] که از داده‌های ویدئویی نیز بهره برده‌اند، به دلیل ماهیت چندوجهی این داده‌ها و ارتباط قوی آن‌ها با حالات عاطفی، این وجه را انتخاب کرده‌اند. این انتخاب‌ها نشان می‌دهد که هر مقاله بسته به نوع داده‌ها، دسترسی به اطلاعات، و اهداف پژوهش، وجه‌های متفاوتی را انتخاب کرده و تحلیل‌های خود را بر اساس آن‌ها تنظیم کرده است.

شن و همکارانش تلاش کردند تا روش‌های بیز ساده، یادگیری شبکه‌های اجتماعی چندگانه^۸ و یادگیری دیکشنری به روش واترشتاین^۹ را با یکدیگر مقایسه کنند. همچنین، روش پیشنهادی خود را با نام یادگیری لغت‌نامه‌ای افسردگی چندوجهی^{۱۰} با روش‌های قبلی مورد مقایسه قرار دادند. در این پژوهش، داده‌ها به کمک روش‌های کلاسیک مانند تحلیل تفکیک خطی^{۱۱} (LDA) به بردارهای ویژگی تبدیل شده و سپس در یک ماتریس مشترک خلوت^{۱۲} نمایش داده می‌شوند. در ادامه، با استفاده از ضرب ماتریسی، دسته‌بندی انجام می‌شود. روش پیشنهادی شن و همکاران در این کاربرد به دقت ۸۵ درصد رسیده است [۱۳].

در این مقاله ویژگی‌های مرتبط با شناسایی افسردگی به چندین دسته تقسیم شده‌اند. اول، ویژگی‌های شبکه اجتماعی نظیر میزان فعالیت، تعاملات اجتماعی (تعداد دنبال‌کننده‌ها و دنبال‌شوندگان)، و زمان ارسال توییت‌ها^{۱۳} که نشان‌دهنده کاهش فعالیت کاربران افسرده است. دوم، ویژگی‌های پروفایل کاربر که اطلاعات شخصی مانند سطح تحصیلات و وضعیت شغلی را بررسی می‌کند. همچنین، ویژگی‌های بصری مانند تحلیل عکس پروفایل بر اساس رنگ و روشنایی برای تفکیک کاربران افسرده از غیرافسرده به کار رفته‌اند. افزون بر این، موضوعات موردعلاقه کاربران افسرده و غیرافسرده

به‌عنوان مثال، یک نوشته^۱ اینستاگرام حاوی اطلاعات زیادی است مثل تصویر، متن، تاریخ و ساعت انتشار، تعداد پسند^۲ و نظر^۳ و همچنین اطلاعات حساب منتشرکننده. تحلیل کردن وجوه متفاوت از اطلاعات در تشخیص دقیق‌تر اهمیت دارد. زیرا افراد در زمانی که محتوایی را منتشر می‌کنند، از انتشار آن محتوا منظور و مقصودی دارند که اگر وجه حاوی این اطلاعات را در نظر نگیریم، این اطلاعات از دست می‌روند. دقت این روش‌ها از روش‌هایی که یک وجه را به‌تنهایی در نظر می‌گیرند بیشتر است [۹].

در ترکیب داده‌ها، سه لایه مختلف برای انجام عملیات وجود دارد: لایه تصمیم^۴، لایه اطلاعات^۵، و لایه داده خام^۶. در لایه تصمیم، مدل‌ها به‌طور جداگانه برای هر وجه داده به نتیجه می‌رسند و سپس این نتایج ترکیب می‌شوند. در لایه اطلاعات، ترکیب داده‌ها زمانی که به‌صورت بردار ویژگی‌ها هستند، انجام می‌شود. لایه داده خام به ترکیب داده‌هایی می‌پردازد که هنوز پردازش نشده‌اند. پژوهش‌های اخیر بیشتر بر ترکیب داده‌ها در لایه اطلاعات تمرکز کرده‌اند، چراکه این روش در فضای مفهومی^۷ به ترکیب داده‌ها می‌پردازد و معمولاً از دو روش دیگر مؤثرتر است [۲] [۱۵].

زمانی که مقالات مختلف را از لحاظ وجه‌های انتخابی مقایسه می‌کنیم، متوجه می‌شویم که معیارهای متفاوتی برای جداسازی وجوه وجود دارد. تفکیک وجوه برای تحلیل افسردگی به شرایط و اهداف هر پژوهش بستگی داشته است. به‌عنوان مثال، مقاله‌های [۹] و [۱۰] با توجه به در دسترس بودن داده‌های چندوجهی، از متن و تصاویر پست‌ها استفاده کرده‌اند تا ارتباطات معنایی و بصری را برای تشخیص افسردگی ترکیب کنند. در مقابل، مقاله [۱۳] با تمرکز بر تحلیل نوشتاری و تعاملات کاربران، متن و تعاملات اجتماعی را به‌عنوان وجه‌های کلیدی در نظر گرفته است، چرا که داده‌های بصری مانند تصاویر پروفایل در این پژوهش مدنظر قرار نگرفته‌اند.

⁸ Multiple Social Networking Learning

⁹ Wasserstein Dictionary Learning

¹⁰ Multimodal Depressive Dictionary Learning

¹¹ Linear Discriminant Analysis

¹² Joint Sparse Matrix

¹³ Tweet

¹ Post

² Like

³ Comment

⁴ Decision Layer

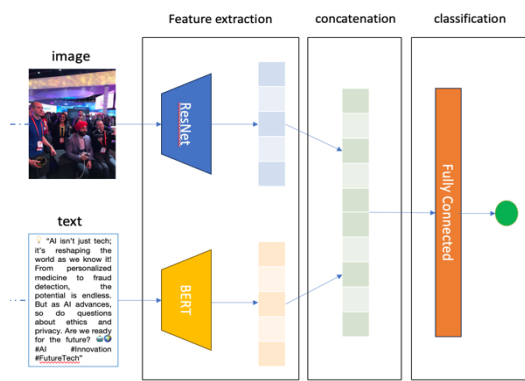
⁵ Information Layer

⁶ Raw data layer

⁷ Contextual Space

۳- روش پیشنهادی

همان‌طور که در بخش قبل گفته شد، مقاله [۱۳] انتخاب وجه‌های مورد تحلیل، نوع داده‌ها را در نظر نگرفته است و جوهی را انتخاب کرده است که به لحاظ نوع با هم فرقی ندارند. علاوه بر این موضوع، در این پژوهش عکس پست‌ها به‌عنوان یک وجه بسیار مهم در نظر گرفته نمی‌شوند. برای این موضوع، مدل پیشنهادی را ارائه می‌کنیم که عکس را نیز به‌عنوان یک وجه در نظر بگیرد.



شکل (۱): نمودار مدل پیشنهادی

وقتی یک کاربر عکسی را در یک پست شبکه اجتماعی منتشر می‌کند، این اقدام به احتمال زیاد از روی یک قصد خاص و برای انتقال پیامی است. تصاویر معمولاً بیشتر از متن‌ها می‌توانند احساسات، افکار و حتی جزئیات زیرساختی و فرهنگی مربوط به موضوعات خاص را منتقل کنند. به همین دلیل، انتخاب دقیق عکس برای کاربران اهمیت زیادی دارد و عکس‌ها معمولاً به طور غیرمستقیم اطلاعاتی در مورد وضعیت روانی یا اجتماعی فرد ارائه می‌دهند. در زمینه تشخیص اختلالات روانی مانند افسردگی، تحلیل تصاویر منتشرشده در شبکه‌های اجتماعی می‌تواند به پیش‌بینی وضعیت فرد کمک کند.

در حقیقت، بررسی دقیق این تصاویر به‌عنوان یک بعد از داده‌های چندوجهی در سیستم‌های تحلیل می‌تواند دقت مدل‌های تشخیص را بهبود دهد. به همین دلیل است که در بسیاری از مدل‌ها و پژوهش‌های جدید، مانند مدل‌های تشخیص افسردگی از داده‌های

به ۲۵ ویژگی موضوعی طبقه‌بندی شده است. در نهایت، ویژگی‌های خاص حوزه افسردگی شامل کلمات مرتبط با داروهای ضدافسردگی و علائم افسردگی، با گسترش واژگان از طریق مدل word2vec بررسی شده‌اند. این ویژگی‌ها، تنوع سبک‌های زبانی کاربران در توییت را پوشش داده و به بهبود دقت شناسایی افسردگی کمک می‌کنند [۱۳].

مان و پایلو تلاش کردند تا با استفاده از یک مدل تصویری و یک مدل متنی، دانشجویان دانشگاه را با توجه به اطلاعات اینستاگرامشان دسته‌بندی کنند. روش آن‌ها از مدل تصویری ResNet و مدل متنی ELMo به صورت جداگانه استفاده کرده است که به دقت‌های ۶۷ درصد و ۸۵ درصد به ترتیب رسیده است. آن‌ها با استفاده از ترکیب اطلاعات چندوجهی و به هم پیوستن ویژگی‌ها، دقت را تا ۹۲ درصد افزایش دادند [۱۴].

ژو و همکارانش با استفاده از مدل‌های یادگیری تقویتی، مدلی طراحی کرده‌اند که به صورت مرحله‌ای عکس و متن را گرفته و به ترتیب و با استفاده از مدل‌های VGG و comma به بردارهای ویژگی تبدیل می‌کند. در مرحله بعد با استفاده از این بردارهای ویژگی، مدل یادگیری تقویتی پیشنهادی را آموزش می‌دهد. دقت این روش پیشنهادی بر روی داده‌های یک‌وجهی از ۸۲ درصد عبور نمی‌کند، اما با استفاده از مدل‌های چندوجهی، دقت به ۹۲ درصد می‌رسد [۱۵].

بوکار مدلی بین‌وجهی^۱ طراحی کرده است که ابتدا ویژگی‌ها را از هر یک از وجوه مختلف استخراج کرده و سپس آن‌ها را به یک رمزگذار بین‌وجهی^۲ وارد می‌کند. پس از آن، ویژگی‌ها با استفاده از روش به هم پیوستن جمع می‌شوند. پس از جمع، اطلاعات به مدل مبدل^۳ منتقل می‌شوند و با استفاده از یک لایه کاملاً متصل^۴ دسته‌بندی انجام می‌شود. این پژوهش دقت را در تشخیص ۹۳ درصد اعلام می‌کند [۱۶].

پژوهش‌های موجود عموماً در نحوه انتخاب وجوه داده و روش ادغام دچار ضعف‌هایی هستند که با برطرف کردن ای ضعف‌ها می‌توان به نتایج بهتری در تشخیص دست‌یافت. در بخش بعدی به بررسی روش پیشنهادی در پژوهش حاضر می‌پردازیم.

³ Transformer

⁴ Fully Connected

¹ Cross Modal

² Cross Modal Encoder

مشخص شد، وزن‌های لایه‌های مختلف این مدل نیز به‌روزرسانی می‌شوند ResNet. از معماری با لایه‌های باقیمانده استفاده می‌کند که به مدل اجازه می‌دهد از مشکلات آموزش در شبکه‌های عمیق جلوگیری کند و مدل بتواند ویژگی‌های پیچیده‌تری را از تصاویر استخراج کند. مدل ResNet تصاویر را در یک مربع به‌اندازه ۲۲۴ به‌عنوان ورودی می‌گیرد و یک بردار به سایز ۲۰۴۸ تولید می‌کند که بیانگر ویژگی‌ها و مفاهیم تصویر است [۱۹].

در بخش بعدی، با استفاده از روش به‌هم‌پیوستن، دو بردار ویژگی حاصل از هر مدل با یکدیگر ترکیب می‌شوند و یک بردار ویژگی واحد تشکیل می‌دهند. در این مرحله، بردارهای ویژگی که از هر دو وجه تصویر و متن استخراج شده‌اند، در فضای مفهومی جداگانه قرار دارند. زمانی که این بردارها به‌هم‌پیوسته می‌شوند، بردار نهایی در یک فضای مفهومی بزرگ‌تر قرار می‌گیرد که شامل اطلاعات هر دو وجه است. این فرایند به این معناست که هیچ اطلاعاتی از هر یک از وجه‌ها در هنگام ترکیب از دست نمی‌رود.

جدول (۱): پارامترها و توضیحات مدل

مدل	پارامتر	توضیحات
Bert	مدل از پیش آموزش‌داده‌شده	Bert-base-uncased
	حداکثر طول دنباله	۱۲۸
	ابعاد خروجی	۷۶۸
ResNet	مدل پایه	ResNet18 (ImageNet)
	شکل ورودی	(۳، ۲۲۴، ۲۲۴)
	پولینگ	پولینگ میانگین کلی
Fusion	بعد ادغام	$۲۸۱۶ = ۲۰۴۸ + ۷۶۸$
	Dense	لایه مخفی
		لایه خروجی

همان‌طور که گفته شد، اندازه ورودی مدل BERT ۱۲۸ واحد است و اندازه بردار ویژگی خروجی از آن ۷۶۸ است. همچنین اندازه ورودی مدل ResNet ۲۲۴ واحد در ۲۲۴ واحد در ۳ طیف رنگی است. اندازه خروجی مدل تصویری نیز ۲۰۴۸ واحد است. در

شبکه‌های اجتماعی، گنجانیدن تصاویر به‌عنوان یکی از منابع تحلیل امری ضروری به نظر می‌رسد. این تصاویر نه‌تنها مکمل اطلاعات متنی هستند، بلکه خود نیز اطلاعات ویژه‌ای دارند که به‌صورت غیرکلامی منتقل می‌شوند و می‌توانند در فرایند تشخیص کمک کنند.

در روش پیشنهادی، یک مدل چندوجهی برای تحلیل و پردازش داده‌های متنی و تصویری به کار گرفته شده است. همان‌طور که در شکل ۱ نشان‌داده‌شده است، مدل از سه بخش اصلی تشکیل می‌شود. ابتدا در بخش جای‌گذاری^۱، از دو مدل کدگذار برای انتقال هر وجه به فضای ویژگی استفاده می‌شود. برای داده‌های متنی، از مدل پیش‌آموزش‌دیده BERT و برای داده‌های تصویری، از مدل پیش‌آموزش‌دیده ResNet استفاده می‌شود. این مدل‌ها هر یک بردار ویژگی‌های مربوط به خود را استخراج کرده و به بخش بعدی منتقل می‌کنند [۱۷] [۱۸] [۱۹].

در این پژوهش، مدل BERT حروف کوچک با داده‌های خاص مرتبط با علائم افسردگی از شبکه‌های اجتماعی تنظیم دقیق^۲ شده است [۱۸]. این فرایند شامل تنظیم وزن‌ها بر اساس داده‌های جدید به‌منظور بهبود توانایی مدل در تشخیص علائم افسردگی در متن‌های کوتاه و غیررسمی است. فرایند تنظیم دقیق به این صورت است که زمانی که برحسب کلاس توسط لایه کاملاً متصل پیش‌بینی شد، علاوه بر وزن‌های لایه کاملاً متصل، وزن‌های مدل BERT نیز به‌روزرسانی می‌شوند. این تنظیم دقیق باعث می‌شود تا مدل متنی فضای متون شبکه‌های اجتماعی را بهتر درک کند و در جهت طبقه‌بندی مجموعه داده عملکرد بهتری داشته باشد. در این کاربرد از وظیفه مدل‌سازی زبان ماسک شده^۳ استفاده شده است. به این صورت که متون به یک بردار ۱۲۸ واحدی تبدیل می‌شوند و به مدل BERT داده می‌شوند و این مدل یک بردار ۷۶۸ تایی تولید می‌کند که حاوی اطلاعات و مفاهیم متن موردنظر است [۱۸].

همچنین برای تحلیل تصاویر، مدل ResNet که یک مدل مبتنی بر شبکه عصبی عمیق است، برای پردازش داده‌های تصویری شبکه‌های اجتماعی تنظیم دقیق شده است [۱۹]. فرایند تنظیم دقیق مشابه با BERT است، به این صورت که زمانی که پیش‌بینی مدل

³ Masked Language Modeling

¹ Embedding

² Fine-Tune

این موارد قادر به دانلود تصاویر نبودیم. همچنین، API توییت‌ها برای کاربران ایرانی در دسترس نبود. در مجموع ۳۵۷، ۲۱۵ داده در اختیار قرار گرفت که از این تعداد ۳۴، ۳۹۳ داده دارای برچسب مثبت بودند. پس از بررسی، مشخص شد که جمع‌آوردندگان مجموعه داده تنها بخش کوچکی از آن را در سایت GitHub بارگذاری کرده‌اند؛ زیرا در مقاله [۱۳] حدود ۱۰۰، ۰۰۰ کاربر با برچسب مثبت ذکر شده‌اند، در حالی که تنها ۵، ۳۸۴ کاربر در پوشه مربوطه یافت شدند و این موضوع به عنوان یک مشکل در پیوند مجموعه داده ذکر شده است.

فرایند آماده‌کردن داده‌ها و آموزش روش پیشنهادی به این صورت است که یک جفت دوتایی از داده متنی و داده تصویری به مدل داده می‌شود. مدل ابتدا متن پست را با استفاده از بخش‌کننده متن^۲ استاندارد مدل BERT بخش‌بندی می‌کند. سپس مدل BERT پایه با حروف کوچک، توکن‌ها را به بردار ویژگی تبدیل می‌کند. به طور موازی، تصویر پست نیز پیش‌پردازش می‌شود تا ابعاد آن به یک اندازه ثابت تبدیل گردد. این پیش‌پردازش به گونه‌ای است که تصویر با حفظ نسبت طول به عرض، به اندازه‌ای بزرگ یا کوچک می‌شود که در یک پنجره با ابعاد خاص قرار گیرد و فضای خالی با میانگین رنگ‌های تصویر پر می‌شود.

پس از آن، تصویر آماده‌شده به مدل ResNet وارد می‌شود و تصویر نیز به بردار ویژگی تبدیل می‌گردد. در نهایت، بردار ویژگی‌های متن و تصویر با هم ترکیب شده و یک بردار بزرگ‌تر ایجاد می‌شود. در آخر، این بردار ویژگی ایجادشده به شبکه کاملاً متصل وارد می‌شود و خروجی این شبکه می‌تواند کاربران افسرده را از غیر افسرده تفکیک کند. همچنین باید در نظر داشت که خروجی مدل مشخص می‌کند که آیا این پست توسط یک فرد افسرده تولید شده است یا نه. یعنی خروجی مدل، پست‌های شبکه‌های اجتماعی را به لحاظ افسردگی دسته‌بندی می‌کند. همچنین در زمان اصلاح وزن‌ها، وزن‌های کدگذارهای متنی و تصویری نیز اصلاح می‌شوند. پارامترهای مدل در جدول ۲ توضیح داده شده‌اند.

نهایت، اندازه بردار تجمیع‌شده ۲۸۱۶ واحد است. این اطلاعات در جدول به تفصیل ذکر شده‌اند.

در بخش پایانی، برای طبقه‌بندی داده‌ها از یک لایه کاملاً متصل استفاده می‌شود. این لایه با در نظر گرفتن بردار ویژگی نهایی که از ترکیب داده‌های متنی و تصویری حاصل شده است، می‌تواند داده‌های مورد نظر را طبقه‌بندی کند. برای این منظور، از تابع هزینه آنتروپی متقاطع^۱ برای آموزش مدل استفاده می‌شود (فرمول شماره ۱).

$$\mathcal{L} = - \sum_{i=1}^N y_i \log(p_i) + (1 - y_i) \log(1 - p_i) \quad (1)$$

در این فرمول، N تعداد نمونه‌ها در دیتاست است و y_i برچسب واقعی برای نمونه i است که مقدار آن می‌تواند ۰ (کلاس منفی) یا ۱ (کلاس مثبت) باشد. p_i احتمال پیش‌بینی شده توسط مدل برای کلاس مثبت است که مقداری بین ۰ و ۱ دارد.

۴- نتایج

در این پژوهش از مجموعه داده استخراج‌شده از شبکه اجتماعی توییت‌ها استفاده شده است که توسط منبع [۱۳] جمع‌آوری گردیده است. روند استخراج به این صورت بوده است که اگر فردی در یکی از توییت‌های خود اعلام کرده باشد که «افسرده هستم/بودم/تشخیص داده شدم»، اطلاعات حساب کاربری آن فرد به همراه تمام توییت‌های منتشرشده تا یک ماه قبل استخراج می‌شود و به عنوان داده برچسب مثبت در نظر گرفته می‌شود. برای داده‌های برچسب منفی، افرادی انتخاب می‌شوند که کلمه depress را در هیچ‌یک از توییت‌های خود به کار نبرده‌اند.

چند نکته قابل ذکر است: تمامی توییت‌ها حاوی تصویر نیستند، لذا تنها توییت‌هایی که حاوی تصویر هستند از مجموعه داده اصلی استخراج می‌شوند و در نظر گرفته می‌شوند. البته در مجموعه داده فقط لینک تصاویر مربوط به توییت‌ها موجود است، به همین دلیل تصاویر را با استفاده از لینک‌های موجود در مجموعه داده دانلود کردیم. البته در روند دانلود به چالش‌هایی برخورد کردیم، مانند حذف پست‌ها یا تغییر وضعیت اکانت‌ها به حالت خصوصی که در

³ Tokenize

¹ Cross-entropy

² Tokenizer

می‌شوند. مدل پیشنهادی این پژوهش، با وجود استفاده از داده‌های کمتر نسبت به مدل مقاله [۱۳]، با اصلاح این کاستی‌ها و به‌کارگیری روش‌های جامع‌تر توانسته است تحلیلی دقیق‌تر ارائه دهد. دقت در مدل پیشنهادی ۸۹/۸۷ درصد گزارش می‌شود که نسبت به مدل مقاله [۱۳] به میزان ۴/۸۷ درصد افزایش داشته است. همچنین مدل پیشنهادی در معیار ارزیابی Recall عملکرد قابل‌توجهی نشان داده و به مقدار ۸۸/۱۲ درصد بهبود یافته است. علاوه بر این، در معیار Precision مدل پیشنهادی به مقدار ۸۹/۳۴ درصد دست یافته است که نشان‌دهنده ارتقای ۳/۸۹ درصدی نسبت به مدل مقاله [۱۳] است. ماتریس درهم‌ریختگی در جدول ۳ نمایش داده شده است.

جدول (۳): ماتریس درهم‌ریختگی

	پیش‌بینی کلاس ۰	پیش‌بینی کلاس ۱
برچسب کلاس ۰	۶۱۸۲	۶۰۴
برچسب کلاس ۱	۷۰۱	۶۱۱۰

۵- نتیجه‌گیری

در این پژوهش، بر اهمیت استفاده از مدل‌های چندوجهی در تشخیص افسردگی تأکید شد، زیرا این روش‌ها با تحلیل داده‌های چند منبع، مانند متن و تصویر، نقش بسزایی در افزایش دقت و کارایی تشخیص دارند. افسردگی به‌عنوان یکی از شایع‌ترین اختلالات روانی، اثرات مخربی بر کیفیت زندگی افراد دارد. از این رو، شناسایی زودهنگام آن اهمیت ویژه‌ای دارد. در گذشته، تشخیص افسردگی عمدتاً از طریق روانکاوایی بالینی انجام می‌شد که علاوه بر زمان‌بر بودن، با محدودیت‌هایی همچون عدم بیان دقیق احساسات از سوی بیمار همراه بود. تحولات اخیر در فناوری‌های هوش مصنوعی، به‌ویژه توسعه مدل‌های چندوجهی، امکان تحلیل هم‌زمان داده‌ها از منابع مختلف را فراهم کرده است. این قابلیت باعث ارتقای قابل‌توجه در دقت تشخیص می‌شود. تصاویر منتشرشده در شبکه‌های اجتماعی، به‌عنوان نمایه‌های غیرمستقیم احساسات و رفتارهای اجتماعی،

جدول (۲): پارامترهای آموزش مدل

پارامتر	مقدار
اندازه بسته ^۱	۱۲۸
بهینه‌ساز	Adam
تابع هزینه	Bianry Crossentropy
ارزیابی‌ها	Accuracy, Precision, Recall, F1

برای آموزش بخش کدگذار متنی و تصویری مدل، بعد از مرتب‌سازی داده‌ها، این داده‌ها به‌صورت جفت‌های دوتایی از عکس و متن در نظر گرفته می‌شوند. این جفت‌های دوتایی شامل متن و تصویر توپیت هستند. در صورتی‌که توپیت موردنظر ری‌توپیت^۲ باشد، توپیت‌های اصلی که از آن‌ها ری‌توپیت شده است، در نظر گرفته نمی‌شود. برای کاهش حجم داده‌ها و به دلیل محدودیت حافظه، مجموعه‌داده به بخش‌های ۱۰ هزارتایی تقسیم می‌شود. هر بخش به‌صورت جداگانه پیش‌پردازش شده و سپس در حافظه دیسک ذخیره می‌شود. در هر مرحله از فرایند آموزش، یکی از این بخش‌ها بارگذاری شده و برای آموزش مدل استفاده می‌شود. این روش کمک می‌کند تا علی‌رغم محدودیت حافظه رم، بتوان کل مجموعه‌داده را مدیریت و پردازش کرد [۲۰][۲۱].

هر بخش پس از بارگذاری به دسته‌های کوچک‌تر ۲۵۶ تایی تقسیم می‌شود و در هر دوره آموزشی^۳، یکی از این دسته‌ها به مدل داده می‌شود. این ساختار نه تنها امکان استفاده از مجموعه‌داده‌های بزرگ را فراهم می‌کند، بلکه باعث افزایش کارایی در مدیریت حافظه و آموزش مدل نیز می‌شود. مشخصات آموزشی به همین شکل تنظیم شده است [۲۲][۲۳][۲۴].

در مقاله [۱۳]، اگرچه وجوه مختلفی برای تحلیل داده‌ها در نظر گرفته شده است، این وجوه از نظر فنی به‌طور مستقل تعریف نشده‌اند. همچنین، عکس‌های توپیت‌ها که می‌توانند اطلاعات بصری مهمی ارائه دهند، در مدل استفاده‌شده نادیده گرفته شده‌اند. از سوی دیگر، ایموجی‌ها در مقاله مذکور به‌عنوان بخشی از متن بررسی شده و در نهایت حذف شده‌اند. اما در روش پیشنهادی، ایموجی‌ها نه حذف می‌شوند و نه به‌عنوان یک وجه مستقل طبقه‌بندی می‌گردند. بلکه ایموجی‌ها همراه با متن به مدل داده

³ Epoch

¹ Batch

² Retweet



- [3] C. B. Krishna, T. T. Marijn, L.-L. Lorenzo, A. R. Lauren, and B. Johan, "Individuals with depression express more distorted thinking on social media," **Nature Human Behaviour**, vol. 5, pp. 458–466, 2021.
- [4] S. C. Gullal, H. Sherzod, S. Abdul, M.-B. Eric, O. Christian, and R. E., "MM-Claims: A Dataset for Multimodal Claim Detection in Social Media," **arXiv preprint arXiv:2205.01989**, 2022.
- [5] B. Marouane, K. Mohammed, and B.-H. Abderrahim, "A comprehensive survey on sentiment analysis: Approaches, challenges and trends," 2023.
- [6] F. Cummins, D. Doyle, and G. McCarthy, "Towards Automatic Text-Based Estimation of Depression Through Symptom Prediction," 2022. [Online]. Available: <https://example-link1.com>
- [7] A. Ibitoye, O. Bamidele, and K. Dahunsi, "Deep Learning for Depression Detection from Textual Data," 2021. [Online]. Available: <https://example-link2.com>
- [8] D. L. Danxia, F. X. Lin, A. Farooq, S. Muhammad, and G. Jing, "Detecting and measuring depression on social media using a machine learning approach: Systematic review," **JMIR Mental Health**, vol. 9, p. e27244, 2022.
- [9] Z. Li, A. Zhengyi, C. Wenchuan, Z. Jiawei, Z. Fang, and H. Bin, "MHA: A multimodal hierarchical attention model for depression detection in social media," **Health Information Science and Systems**, vol. 11, p. 6, 2023.
- [10] M. A. H. Yazda, M. Saeid, B. Goonmeet, R. William, S. Amit, A. Hassan, T. Krishnaprasad, M. John, M. Annie, and H. Pascal, "Multimodal mental health analysis in social media," **PLoS One**, vol. 15, p. e0226248, 2020.
- [11] A.-M. Bucur, A. Cosma, P. Rosso, and L. P. Dinu, "It's just a matter of time: Detecting depression with time-enriched multimodal transformers," in **European Conference on Information Retrieval**, Springer, Jan. 13, 2023, pp. 200–215.
- [12] O. Adekanmbi, M. A. Adekanmbi, M. O. Adekanmbi, and O. O. Adekanmbi, "Algorithmic teenagers' depression detection on social media and automated instant engagement using therapy bot powered by multimodal deep learning and psychotherapy intervention," 2023.
- [13] G. Shen, J. Jia, L. Nie, F. Feng, C. Zhang, T. Hu, T.-S. Chua, and W. Zhu, "Depression detection

می‌توانند اطلاعات مفیدی درباره وضعیت روانی کاربران ارائه دهند. ترکیب این داده‌های تصویری با اطلاعات متنی در مدل‌های چندوجهی، به دلیل مکمل بودن اطلاعات غیرکلامی و کلامی، می‌تواند به شناسایی دقیق‌تر ویژگی‌ها و الگوهای مرتبط با افسردگی کمک کند.

نتایج این پژوهش نشان داد که مدل پیشنهادی با ترکیب داده‌های متنی و تصویری توانسته است دقت تشخیص افسردگی را به میزان تقریباً ۵ درصد نسبت به مدل‌های مشابه ارتقا داده و به دقت ۸۹/۸۷ درصد برساند. این افزایش دقت، بیانگر توانایی مدل‌های چندوجهی در شناسایی علائم پیچیده‌تر افسردگی است که ممکن است در مدل‌های تک‌وجهی نادیده گرفته شوند. افزون بر این، این مدل‌ها امکان تحلیل جامع‌تر الگوهای رفتاری و عاطفی را فراهم می‌کنند و با کاهش خطاها، در بهبود تشخیص افسردگی مؤثر هستند.

استفاده از مدل‌های چندوجهی نه تنها پتانسیل بالایی برای تشخیص دقیق‌تر افسردگی دارد، بلکه می‌تواند به عنوان ابزاری کارآمد در طراحی سیستم‌های پشتیبانی برای مداخله زود هنگام در حوزه سلامت روان مورد استفاده قرار گیرد. پیشنهاد می‌شود در مطالعات آینده، گسترش این مدل‌ها با در نظر گرفتن منابع داده‌ای متنوع‌تر و توسعه چارچوب‌های جامع‌تر مدنظر قرار گیرد.

۶- اقرار

در اینجا لازم می‌دانیم تا سپاسگزاری خود را از حمایت‌های بی‌دریغ اپراتور هوش مصنوعی اهورا (شرکت ایران جی‌پی‌یو) در راستای تأمین سخت‌افزار محاسباتی گرافیکی مورد نیاز این تحقیق ذیل تفاهم‌نامه به شماره ۰۳۰۹۱۳/۱۰۰ در جهت تعالی حوزه هوش مصنوعی کشور اعلام کنیم.

References

- [1] A. Jitimon, T. Suda, and A. Thara, "Big data analytics on social networks for real-time depression detection," **Journal of Big Data**, vol. 9, p. 69, 2022.
- [2] G. Shelley, S. Archana, and R. Jayanthi, "Multimodal, multiview and multitasking depression detection framework endorsed with auxiliary sentiment polarity and emotion detection," Jan. 19, 2023.



- [19] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016.
- [20] H. Liu, Y. You, and D. Darrow, "Deep Incubation: Training Large Models by Divide-and-Conquering," *arXiv preprint arXiv:2212.04129*, 2022.
- [21] J. Wang, Z. Liu, and T. Zhang, "Dataset Pruning: Reducing Training Data by Examining Generalization Influence," *arXiv preprint arXiv:2205.09329*, 2022.
- [22] T. F. Qu, Y. Zhang, and J. Liu, "Depression Detection Using Emotion Artificial Intelligence," in 2019 IEEE 10th International Conference on Awareness Science and Technology (iCAST), Morioka, Japan, 2019, pp. 1-5.
- [23] S. Orabi, P. Buddhitha, M. H. Orabi, and D. Inkpen, "Deep Learning for Depression Detection of Twitter Users," in Proceedings of the Fifth Workshop on Computational Linguistics and Clinical Psychology: From Keyboard to Clinic, New Orleans, LA, USA, 2018, pp. 88-97.
- [24] F. Ren and Y. Wu, "Predicting Depression Trends on Twitter Using Sentiment Analysis," in 2019 IEEE 13th International Conference on Semantic Computing (ICSC), Newport Beach, CA, USA, 2019, pp. 230-233.
- via harvesting social media: A multimodal dictionary learning solution," *IJCAI*, pp. 3838–3844, 2017.
- [14] T. Gui, L. Zhu, Q. Zhang, M. Peng, X. Zhou, K. Ding, and Z. Chen, "Cooperative multimodal approach to depression detection in Twitter," in *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, no. 01, pp. 110–117, 2019.
- [15] P. Xu, X. Zhu, and D. A. Clifton, "Multimodal learning with transformers: A survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 10, pp. 12113–12132, 2023.
- [16] A.-M. Bucur, A. Cosma, P. Rosso, and L. P. Dinu, "It's just a matter of time: Detecting depression with time-enriched multimodal transformers," in *European Conference on Information Retrieval*, Springer, pp. 200–215, 2023.
- [17] P. Mann, A. Paes, and E. H. Matsushima, "See and read: detecting depression symptoms in higher education students using multimodal social media data," in *Proceedings of the International AAAI Conference on Web and Social Media*, vol. 14, pp. 440–451, 2020.
- [18] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of deep bidirectional transformers for language understanding," in *Proceedings of NAACL-HLT*, pp. 4171–4186, 2019.



Multimodal Data Fusion for Depression Detection on Twitter

Reza Rezaei, Abolfazl Nadi*

Department of Computer Science, School of Mathematics, Statistics and Computer Science, College of Science,
University of Tehran, Tehran, Iran

Article Information

Original Research Paper

Received:

2024 November 29

Accepted:

2025 January 4

Keywords:

Depression Detection, Multi-Modal Data Fusion, Sentiment Analysis, Social Networks

Corresponding Author*:

a.nadi@ut.ac.ir

Abstract

Depression is one of the most significant and prevalent mental health disorders in today's world. Early detection of depression is critical, and this study aims to identify depression in individuals using information derived from social media. The use of social media for various purposes has grown in recent years, as these platforms provide valuable insights into both individuals and society. Social media can be effectively utilized to detect depression. Researchers have attempted to identify depression using various types of data, such as images, text, and audio. Most studies have focused on using only one type of data, such as text or images, for detection. While these methods have achieved notable results, they have limitations in accuracy that can be addressed by incorporating new methods and integrating multiple data modalities into the model. In this study, we propose a multimodal model that analyzes text and images together to detect depression. Compared to similar models, our approach achieves an approximate 5% improvement in accuracy, reaching 89.87%, while utilizing significantly less of the original dataset.

 : 10.22034/abmir.2025.22331.1080

E-ISSN: [2821-2037](https://doi.org/10.22034/abmir.2025.22331.1080) /© 2023. Published by Yazd University This is an open access article
under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

