

An Approach to Identify Epidemic Diseases Rumors in Social Networks using Deep Learning Techniques

Pezhman Eghbali¹, Sondos Bahadori^{2*} and Maryam Nooraei Abadeh³

1,2- Department of Computer Engineering, Ilam Branch, Islamic Azad University, Ilam, Iran,

3- Department of Computer Engineering, Abadan Branch, Islamic Azad University, Abadan, Iran.

¹pzh.eghbali@gmail.com, ^{2*}sondos.bahadori@iau.ac.ir, and ³ma.nooraei@iau.ac.ir

Corresponding author's address: Sondos Bahadori, Faculty of Electrical and Computer Engineering, Ilam Branch Islamic Azad University, Ilam, Iran.

Abstract- One of the most important issues in social networks is the high volume of rumors that are spread by human or machine agents. In such situations, automatic detection of rumors to keep public opinion safe from their potential dangers is of great importance. In this research, using deep learning techniques, a new solution for automatically detecting rumors related to epidemic diseases in social networks will be presented. In the proposed method, first the content of existing messages is prepared for processing in the next steps. Also, weight matrix format has been used to describe content characteristics. Then, in the second step of the proposed method, the convolutional neural network is used to extract the set of suitable features from the matrix of features obtained from the previous step. In this way, the matrix of content features is used as the input of the deep neural network, and the weight values obtained in the last fully connected layer of this neural network are used as the features extracted from it. Finally, the aggregation of several binary classifiers is used in order to detect rumors and classify the features extracted through convolutional neural network. For this purpose, the extracted features are simultaneously processed by several learning models and the final output of the proposed system is determined by voting the outputs of these three algorithms. The results of this research show that by using the proposed method, rumors can be detected with an average accuracy of 98.8%, which shows an improvement of at least 2.4% in detection accuracy compared to the previous methods.

Keywords- Social network, rumor propagation model, rumor detection, deep learning.

شناسایی شایعات در شبکه‌های اجتماعی در زمینه بیماری‌های همه‌گیر با استفاده از تکنیک‌های یادگیری عمیق

پژمان اقبالی، سندس بهادری*^۲، مریم نورائی آباده^۳

۱ و ۲- دانشکده مهندسی برق و کامپیوتر، واحد ایلام، دانشگاه آزاد اسلامی، ایلام، ایران.

۳- دانشکده مهندسی کامپیوتر، واحد آبادان، دانشگاه آزاد اسلامی، آبادان، ایران.

¹pzh.eghali@gmail.com, ²*sondos.bahadori@iau.ac.ir, ³ma.nooraei@iau.ac.ir

* نشانی نویسنده مسئول: سندس بهادری، دانشگاه ایلام، دانشکده مهندسی برق و کامپیوتر.

چکیده- یکی از مهم‌ترین مسائل در شبکه‌های اجتماعی حجم بالای شایعاتی است که توسط عوامل انسانی و یا ماشینی منتشر می‌شوند. در چنین شرایطی، تشخیص خودکار شایعات برای ایمن نگه‌داشتن افکار عمومی در برابر خطرات بالقوه آنها؛ از اهمیت بالایی برخوردار است. در این پژوهش، با استفاده از تکنیک‌های یادگیری عمیق یک راهکار جدید برای تشخیص خودکار شایعات مرتبط با بیماری‌های همه‌گیر در شبکه‌های اجتماعی ارائه شده است. در روش پیشنهادی، ابتدا محتوای پیام‌های موجود برای پردازش در گام‌های بعدی آماده‌سازی می‌شوند. همچنین از قالب ماتریس وزنی برای توصیف خصوصیات محتوایی استفاده شده است. سپس در گام دوم روش پیشنهادی، از شبکه عصبی کانولوشن به منظور استخراج مجموعه ویژگی‌های مناسب از ماتریس خصوصیات حاصل از گام قبل استفاده می‌شود. بدین ترتیب، ماتریس خصوصیات محتوایی به عنوان ورودی شبکه عصبی عمیق بکار می‌رود و مقادیر وزنی به دست آمده در آخرین لایه تماماً متصل این شبکه عصبی به عنوان ویژگی‌های استخراج شده از آن مورد استفاده قرار می‌گیرد. در نهایت، از جمع چند طبقه‌بند دودویی به منظور تشخیص شایعات و طبقه‌بندی ویژگی‌های استخراج شده از طریق شبکه عصبی کانولوشن استفاده می‌شود. بدین منظور، ویژگی‌های استخراج شده به صورت همزمان توسط چندین مدل یادگیری پردازش شده و خروجی نهایی سیستم پیشنهادی از طریق رای گیری خروجی‌های این سه الگوریتم تعیین می‌شود. نتایج حاصل از این تحقیق نشان می‌دهد که با استفاده از روش پیشنهادی می‌توان شایعات را با میانگین دقت ۹۸٫۸ درصد تشخیص داد که نشان از بهبود حداقل ۲٫۴ درصدی دقت تشخیص نسبت به روش‌های پیشین دارد.

واژه‌های کلیدی: شبکه اجتماعی، مدل انتشار شایعه، تشخیص شایعه، یادگیری عمیق

۱- مقدمه

شبکه‌ها بسیار سریع‌تر از دنیای واقعی خواهد بود [۱-۳]. اثر مخرب این شایعات، در شرایطی مانند شیوع بیماری‌های همه‌گیر بیشتر خود را نشان خواهد داد. در سال‌های همه‌گیری کووید-۱۹ شاهد این واقعیت بوده‌ایم و بویژه در دوره ابتدایی شیوع این بیماری، شایعات مختلفی در سطح شبکه‌های اجتماعی به صورت وسیع انتشار یافت [۳، ۴]. این امر موجب شکل‌گیری روش‌هایی برای تشخیص شایعه یا منابع منتشر کننده آنها شده است. با این

شبکه‌های اجتماعی به جزئی جدایی ناپذیر از دنیای ارتباطات تبدیل شده‌اند و به دلیل همین کاربرد گسترده، اطلاعات منتشر شده در این شبکه‌ها نقشی عمیق بر افکار عمومی دارند. طبیعی است که این سطح از اثرگذاری، مشکلات و چالش‌هایی را در پی خواهد داشت. یکی از این مشکلات انتشار شایعه می‌باشد. با توجه به سهولت ارتباطات در شبکه‌های اجتماعی، انتشار شایعه در این

۲- کارهای مرتبط

استفاده از تکنیک‌های یادگیری عمیق به منظور تجزیه و تحلیل محتوا و شناسایی اصالت اطلاعات منتشر شده در شبکه‌های اجتماعی از جنبه‌های جدید و نوآورانه این تحقیق است. نویسندگان در پژوهش‌های مختلفی نیز به تحلیل اطلاعات منتشر شده در شبکه‌های اجتماعی به منظور تحلیل اخبار و ایمیل‌های جعلی و شایعات پرداختند. در ادامه به برخی از جدیدترین این پژوهش‌ها اشاره می‌کنیم اما شبیه‌ترین آنها از لحاظ محتوا را به طور خلاصه در جدول ۱ جمع بندی می‌کنیم.

آنتوناکاکی و همکاران در سال ۲۰۲۱، در مقاله خود موضوعات پژوهشی فعلی در توییتر را با سه محور اصلی ترسیم می‌کنند: ساختار و ویژگی‌های نمودار اجتماعی، تجزیه و تحلیل احساسات و تهدیداتی مانند هرزنامه، ربات‌ها، اخبار جعلی و سخنان نفرت انگیز. همچنین مدل داده‌های اولیه توییتر و بهترین شیوه‌ها برای نمونه‌گیری و دسترسی به داده‌ها را ارائه می‌دهند. همراه با بررسی‌ها و مطالعات مقایسه‌ای موجود، همچنین در مورد یافته‌های کلیدی و وضعیت هنر در این روش‌ها بحث می‌کنند. به طور کلی، این نظرسنجی به محققان در ایجاد یک مدل مفهومی واضح از توییتر کمک می‌کند و به عنوان راهنمایی برای گسترش بیشتر موضوعات ارائه شده است [۷].

سایما صدیق و همکاران در سال ۲۰۲۱، در مقاله خود به چالش شناسایی خودکار تشخیص پرخاشگری در توییت‌های مجموعه داده سایبر ترول پرداخته‌اند. نتایج آماری ثابت کرد که این مدل پیشنهادی بهترین عملکرد را دارد و رفتار پرخاشگرانه را با دقت ۹۲٪ تشخیص می‌دهد [۸].

لوکاس ایلیاس، ایوانا روساکی در سال ۲۰۲۱، در مقاله خود به منظور شناسایی فعالیت‌های مخرب در توییتر با استفاده از تکنیک‌های یادگیری عمیق، از دو روش برای شناسایی سریع ربات‌ها در شبکه‌های اجتماعی استفاده کرده‌اند که عمدتاً مبتنی بر پردازش زبان طبیعی است تا کاربران قانونی را از ربات‌ها متمایز کند. در روش اول، با مجموعه داده‌های نامتعادل، زیر مجموعه ویژگی‌های انتخاب شده در الگوریتم‌های یادگیری ماشین تغذیه می‌شود. در روش دوم، یک معماری یادگیری عمیق برای شناسایی اینکه آیا توییت‌ها توسط کاربران واقعی ارسال شده اند یا توسط ربات‌ها تولید شده اند، ارائه شده است. نتایج به دست آمده نشان می‌دهد که روش پیشنهادی از نظر دقت به طور متوسط ۵.۷٪، از نظر فراخوانی به طور متوسط ۲۳.۶٪ و از نظر صحت ۷.۷٪ به طور کلی، یک موقعیت واحد وجود دارد که رویکرد پیشنهادی برای یکی دیگر از معیارهای ارزیابی عملکرد بهتری دارد [۹].

وجود، در شناسایی خودکار شایعات با چالش‌های مختلفی مواجه می‌باشیم که اغلب آنها از ماهیت پویای شبکه‌های اجتماعی، تنوع زبانی محتواها و همچنین حجم بالای داده‌ها ناشی می‌شوند [۳]. به عنوان مثال، با شروع همه‌گیری کووید-۱۹ حجم پیام‌ها و شایعات منتشر شده شبکه‌های اجتماعی در زمینه این بیماری به صورت قابل توجهی افزایش یافت. در چنین شرایطی، تشخیص خودکار شایعات برای ایمن نگه داشتن افکار عمومی در برابر خطرات بالقوه آنها؛ از اهمیت بالایی برخوردار می‌باشد. در این پژوهش، تلاش می‌شود تا با استفاده از تکنیک‌های یادگیری عمیق یک راهکار جدید برای تشخیص خودکار شایعات مرتبط با بیماری‌های همه‌گیر در شبکه‌های اجتماعی ارائه شود. از آنجایی که پیش‌بینی می‌شود روش پیشنهادی بتواند در بهبود کارایی سیستم‌های تشخیص شایعه در شبکه‌های اجتماعی موثر باشد؛ لذا مطالعه بر روی موضوع مورد بحث از ضروریات می‌باشد.

در این پژوهش، یک روش جدید به منظور شناسایی شایعات مرتبط با بیماری‌های همه‌گیری در شبکه‌های اجتماعی ارائه خواهد شد. مسئله شناسایی خودکار شایعات بر اساس ویژگی‌های محتوایی را می‌توان به دو زیرمسئله «استخراج ویژگی‌های بهینه» و «طبقه‌بندی ویژگی‌ها» تجزیه نمود. در روش پیشنهادی، برای حل مسئله اول از تکنیک‌های یادگیری عمیق استفاده خواهد شد. بدین منظور، از یک شبکه عصبی کانولوشن (CNN¹) برای استخراج ویژگی‌های بهینه و کاهش ابعاد داده بهره خواهیم برد. این شبکه عصبی کانولوشن، ماتریس وزنی کلمات برای هر پیام را به عنوان ورودی دریافت کرده و مقادیر وزنی حاصل از آخرین لایه تماماً متصل را به عنوان ویژگی‌های توصیف کننده محتوای پیام استخراج می‌کند. همچنین به منظور افزایش دقت طبقه‌بندی، در روش پیشنهادی از ترکیب چندین طبقه‌بند دودویی استفاده خواهد شد. در این سازوکار که تجمیع^۲ نامیده می‌شود؛ ویژگی‌های استخراج شده توسط شبکه عصبی کانولوشن به عنوان ورودی چندین مدل طبقه‌بندی مورد استفاده قرار می‌گیرد. هر مدل یادگیر به صورت جداگانه به طبقه‌بندی ویژگی‌ها پرداخته و در نهایت، خروجی مدل پیشنهادی از طریق رأی‌گیری بین خروجی مدل‌های یادگیر تعیین خواهد شد. به صورت نظری ثابت شده است که تکنیک تجمیع می‌تواند موجب بهبود دقت الگوریتم‌های طبقه‌بندی شود [۵، ۶]. براین اساس، پیش‌بینی می‌شود که روش پیشنهادی بتواند منجر به شکل‌گیری یک راهکار کارآمد در تشخیص خودکار شایعات در شبکه‌های اجتماعی گردد.

نمودار با ساختار زیر فضایی مبهم، شناسایی کند. روش پیشنهادی تشخیص عمیق جامعه می‌تواند جوامع با کیفیت بالا در شبکه‌های اجتماعی را به طور موثر شناسایی کند [۱۳].

ماریام اورابیچ و همکاران در سال ۲۰۲۰، یک روش شناسایی ربات‌ها در رسانه‌های اجتماعی ارائه داده‌اند که بررسی سیستماتیک مبتنی بر یک استراتژی جستجوی از پیش تعریف شده است و شامل ادبیات مربوط به روش‌های ربات ردیابی رسانه‌های اجتماعی است. نتایج نشان می‌دهد که ایجاد یک ردیاب قوی ربات رسانه‌های اجتماعی چالش برانگیز است، زیرا به دلیل فقدان مجموعه داده‌های واقعی بسیار دقیق با حاشیه نویسی و به دلیل تغییر ویژگی‌های ربات‌ها به عنوان تکامل دهندگان بات‌ها، در حال تغییر هستند [۱۴].

نور المواس و همکاران در سال ۲۰۲۰ [۱۵]، امکان استفاده از خروجی سیستم‌های طبقه بندی نظارت شده را که قبلاً پیشنهاد شده بود، به عنوان ابزاری برای کشف اسپرها بررسی کرده‌اند. نتایج طبقه بندی افزایش قابل توجهی را در فراخوانی و دقت حفظ شده نشان می‌دهد، تدوین مشکل تشخیص با یک چارچوب مدل گرافیکی غیرمستقیم به سیستم امکان می‌دهد عملکردهای بدتر طبقه بندی کننده‌های آماری پیشنهادی قبلی را بازیابی کرده و به طور موثر تأثیر تکامل هرزنامه را کاهش دهد. اورونسولو و همکاران در سال ۲۰۱۹، یک مدل پیش بینی مبتنی بر یادگیری ماشین برای بهبود کارایی طرح‌های ضد فیشینگ پیشنهاد کرده‌اند. مدل پیش بینی شامل یک مولفه انتخاب ویژگی^۳ است که برای ساخت بردار ویژگی موثر استفاده می‌شود. سیستم پیشنهادی از ماشین بردار پشتیبان و نایو بیز استفاده می‌کند که بر روی مجموعه ای از ویژگی‌های ۱۵ بعدی آموزش دیده اند [۱۶].

محمد الصارم و همکاران در سال ۲۰۲۱، یک مدل یادگیری عمیق ترکیبی جدید برای تشخیص شایعات مرتبط با COVID-19 در رسانه‌های اجتماعی بر اساس حافظه کوتاه مدت و شبکه‌های عصبی cnn موازی به هم پیوسته LSTM-PCNN پیشنهاد کردند [۱۷].

حیدری و همکاران در سال ۲۰۲۱ از تکنیک‌های آنالیز احساسات برای شناسایی پیام‌های مخرب خودکار در شبکه‌های اجتماعی از طریق ویژگی‌های محتوایی استفاده کرده‌اند. این تحقیق بر محتواهای منتشر شده به زبان هلندی در شبکه توییتر تمرکز کرده و پس از استخراج ویژگی‌های احساسی متون، آنها را توسط مدل‌های یادگیری مانند: شبکه عصبی، لجستیک رگرسیون، ماشین بردار پشتیبان و جنگل تصادفی طبقه بندی کرده است [۱۸].

پرادپ کومار روی و همکاران [۱۰] در سال ۲۰۲۰، در مقاله فوق از یادگیری عمیق برای طبقه بندی پیام‌های متنی Spam و Not-Spam استفاده نموده است. به طور خاص، شبکه عصبی کانولوشن و مدل‌های حافظه کوتاه مدت طولانی استفاده شده است. نتایج تجربی نشان داده است که مدل مبتنی بر CNN با پارامتر تنظیم بر روی داده اعتبارسنجی تصادفی ۱۰ برابر نمونه‌گیری تصادفی با اطمینان از دقت ۹۹.۴۴٪ برای فیلتر کردن پیام‌های متنی هرزنامه و ناخواسته، بهترین عملکرد را دارد. این رویکرد همچنین می‌تواند در زمینه‌های دیگر هرزنامه‌ها مانند معتبر در مقابل بررسی‌های جعلی آنلاین و اخبار واقعی در مقابل جعلی مورد آزمایش قرار گیرد.

ذوالفقار آوم و همکاران در سال ۲۰۲۰، برای شناسایی هرزنامه توییتر، یک روش جدید مبتنی بر تکنیک‌های یادگیری عمیق ارائه کرده‌اند. رویکرد آنها هم از طریق متن توییتر و هم از داده‌های متای کاربران (به عنوان مثال سن یک حساب، تعداد دنبال کنندگان / دنبال کنندگان و غیره) برای شناسایی هرزنامه‌ها استفاده می‌کند. آنها عملکرد رویکرد پیشنهادی خود را با پنج روش مبتنی بر یادگیری ماشین و دو روش مبتنی بر یادگیری عمیق بر روی دو مجموعه داده مختلف دنیای واقعی مقایسه کرده‌اند [۱۱]. کوآن کیانگ ژو و همکاران در سال ۲۰۲۰ [۱۲]، یک روش مبتنی بر یادگیری عمیق برای تشخیص حمله توصیه‌گر ارائه کرده‌اند. در این روش با استفاده از شبکه یادگیری عمیق ساخته شده از لایه‌های چند کانولوشن، لایه‌های چندرسانه‌ای و لایه‌های متصل چندگانه، عملکرد تشخیص حمله توصیه شده بهبود می‌یابد. آزمایشات روی هر دو مجموعه داده MovieLens 10M و MovieLens 20M نشان دهنده اثربخشی این روش در تشخیص حمله است. نتایج تجربی نشان می‌دهد که روش پیشنهادی می‌تواند حمله را به طور موثر و پایدار تشخیص دهد.

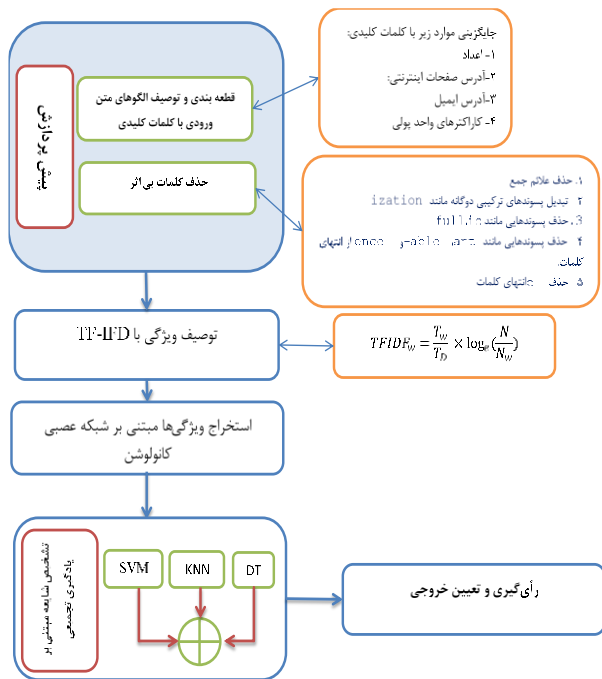
لینگ وو و همکاران در سال ۲۰۲۰، یک روش تشخیص جامعه با استفاده از یادگیری عمیق AE و CNN در شبکه‌های اجتماعی ارائه شده است، که شامل (۱) بازسازی ماتریس، (۲) استخراج ویژگی فضایی و (۳) تشخیص جامعه است. در آزمایشات، چهار مجموعه داده باز شبکه‌های اجتماعی عملی برای ارزیابی روش پیشنهادی انتخاب شدند و نتایج تجربی نشان می‌دهد که روش تشخیص جامعه عمیق پیشنهادی، مدولاسیون بالاتری نسبت به سایر روش‌های یادگیری عمیق به دست آورده است. استفاده از مدل ترکیبی AE و CNN در شناسایی جامعه و نتایج تجربی نشان می‌دهد که روش تشخیص عمیق جامعه می‌تواند به طور موثر جوامع با کیفیت بالا را برای هر مجموعه داده عملی، به ویژه برای

شبکه عصبی کانولوشن برای طبقه‌بندی ویژگی‌ها بهره می‌برد [۲۰]. فنگ و همکارانش در سال ۲۰۲۱ یک روش تشخیص پیام-های مخرب خودکار با نام BotRGCN⁴ ارائه کرده‌اند که از گراف رابطه‌ای و شبکه عصبی کانولوشن بهره می‌گیرد. در این روش علاوه بر خصوصیات محتوایی، یک گراف از ارتباطات کاربر تشکیل شده تا جایگاه آن در ساختار شبکه اجتماعی مشخص گردد [۲۱]. در منابع [۱۷، ۳۱-۲۲] روش‌هایی برای تشخیص شایعه به کار رفته است که تشابه بیشتری با روش ارائه شده در این مقاله دارند و در جدول زیر به مقایسه جزئیات این روش‌ها با روش پیشنهادی این مقاله می‌پردازیم.

رودریگز و همکاران در سال ۲۰۲۰ از ویژگی‌های محتوایی و مدل طبقه‌بندی یک کلاسه برای تشخیص بات‌ها در شبکه توئیتر استفاده کرده‌اند. راهبرد طبقه‌بندی یک کلاسه حالتی از یادگیری نظارت شده است که در آن، نمونه‌های آموزشی تنها متعلق به یک کلاس می‌باشند. در نتیجه هر نمونه‌ای که دارای ویژگی‌هایی مغایر با کلاس هدف باشد به عنوان کلاس منفی در نظر گرفته می‌شود [۱۹]. فنگ و همکارانش در سال ۲۰۲۰ روشی با عنوان BotFlowMon به منظور تشخیص بات در شبکه‌های اجتماعی ارائه کرده‌اند که تنها از داده‌های جریان‌های محتوای توئیترها برای تشخیص استفاده می‌کند. این روش شامل مراحل پیش‌پردازش، ترکیب جریان، تولید شناسه جریان و طبقه‌بندی بوده و از یک

جدول ۱. مقایسه با روش‌های مشابه

منبع	دیتاست	اندازه دیتاست	تکنیک	یافته‌ها	محدودیت‌ها
[۲۲]	مجموعه داده handcrafted COVID-19 به دست آمده از پلتفرم‌های چینی	۳۷۳۷ داده مربوط به شایعات	TextCNN و TextRNN	کارایی مدل ترکیبی که بیش از ۹۰ درصد است	مجموعه داده در دسترس نیست که اجرای مجدد مدل را غیرممکن می‌کند.
[۲۳]	داده‌های توئیتر-زبان عربی	۸۷۸۶ توئیتر	DL و ML	TF-IDF در این روش بیشتر برای ML مناسب است، در حالی که FastText برای روش‌های DL بیشتر قابل اعتماد است. طبقه بندی XGB بهترین طبقه بندی کننده برای شناسایی اطلاعات غلط عربی بود	محدودیت‌ها پیش‌پردازش
[۲۴]	زیر مجموعه ای از دیتاست‌های عمومی قابل دسترس	۲۳۱۳ نمونه شایعه و ۲۳۵۱ نمونه غیر شایعه	روش DL مبتنی بر توجه	بازخورد کاربر یک سیگنال شفاف برای تعیین روند شایعات ارائه کرد	نیاز به بهینه سازی عملکرد مدل و کاهش زمان آموزش
[۲۵]	مجموعه داده handcrafted COVID-19 به دست آمده از پلتفرم توئیتر	۲۰۰۰ توئیتر	ML	بالاترین دقت ۸۴.۰۳ درصد بود که توسط LR با بردار شمارش و SVM با TF-IDF به دست آمد.	فرآیند حاشیه نویسی به اندازه کافی واضح نیست
[۲۶]	داده‌های جمع آوری شده از وب	-	DL مبتنی بر فناوری بلاکچین	دقتی در حدود ۹۹.۶۳%	سایز داده بزرگ را پاسخگو نیست
[۲۷]	دیتاست ساختگی با جمع آوری داده‌های کووید از ژانویه تا ژوئن ۲۰۲۰	-	مدلی مبتنی بر های عصبی عمیق شبکه	کارایی روش در مقایسه با راه حل‌های پایه	-
[۲۸]	داده‌های توئیتر	42222 خبر	DL و ML	دقت ۹۶٪	نیاز به ارزیابی عملکرد طبقه بندی به منظور انتخاب طبقه بندی بهینه
[۱۷]	داده‌های توئیتر	۳۱۵۷ توئیتر شامل ۱۴۸۰ نمونه شایعه	روش یادگیری عمیق ترکیبی از LSTM و PCNN	استفاده و مقایسه تکنیک‌های word embedding مختلف	دقت 0.8399
[۲۹]	داده‌های توئیتر	-	ensemble-based deep learning	F1-score در حدود 0.99	عدم وزن دهی به واژگان معنی دار برای تشخیص بهتر شایعه
[۳۰]	داده‌های توئیتر	۲۷۰۵ توئیتر	Response LSTM به همراه BERT Embedding	در نظر گرفتن پاسخ‌های کاربران	عدم توجه به ساختار پاسخ‌های کاربران
[۳۱]	داده‌های توئیتر	۱۴۸۰ نمونه شایعه و ۱۶۷۷ توئیتر غیر شایعه	Bi-LSTM و CNN	وزن دهی به واژگان معنی دار برای تشخیص بهتر شایعه	عدم استفاده از word embedding مختلف



شکل ۱: دیاگرام بلوکی روش پیشنهادی

در انتهای این گام؛ با استفاده از یک فیلتر مبتنی بر کلمات کلیدی پیام‌های نامرتبط (پیام‌هایی که با موضوع هدف ارتباطی ندارند) حذف خواهند شد. در گام دوم، از شبکه عصبی کانولوشن به منظور استخراج مجموعه ویژگی‌های مناسب از ماتریس خصوصیات حاصل از گام قبل استفاده می‌شود. بدین ترتیب، ماتریس خصوصیات محتوایی حاصل از گام قبل به عنوان ورودی شبکه عصبی عمیق بکار می‌رود و مقادیر وزنی به دست آمده در آخرین لایه تماماً متصل این شبکه عصبی به عنوان ویژگی‌های استخراج شده از آن مورد استفاده قرار می‌گیرد. در گام سوم، از ترکیب چندین طبقه‌بند دودویی به منظور تشخیص شایعات و طبقه‌بندی ویژگی‌های استخراج شده استفاده می‌شود. این مدل‌های یادگیر عبارتند از: «ماشین بردار پشتیبان»، «درخت تصمیم» و «K نزدیک‌ترین همسایه». بدین منظور، ویژگی‌های استخراج شده به صورت همزمان توسط این مدل‌های یادگیر پردازش شده و خروجی نهایی سیستم پیشنهادی از طریق رای‌گیری خروجی‌های این سه الگوریتم تعیین خواهد شد. در ادامه این فصل، هریک از این مراحل محاسباتی به تفصیل شرح داده خواهد شد.

۳-۱- پیش‌پردازش و توصیف ویژگی

در این گام، به پردازش اولیه محتوای پیام‌های متنی به اشتراک گذاشته شده می‌پردازیم. بدین منظور، هر پیام به صورت یک سند متنی در نظر گرفته می‌شود و متن ورودی به جملات تشکیل دهنده آن قطعه بندی می‌شود. منظور از قطعه بندی متن، تجزیه

مشابه‌ترین پژوهش‌ها در تحلیل شایعات در خصوص بیماری‌های همه گیر از جمله کووید در جدول فوق با روش پیشنهادی این پژوهش مقایسه شده است.

۳-۲ مدل پیشنهادی

این روش از مراحل پیش‌پردازش و توصیف ویژگی‌های محتوایی، استخراج ویژگی‌های توسط شبکه عصبی کانولوشن CNN، تشخیص با استفاده از الگوریتم‌های یادگیری تجمیعی مانند K- (KNN) و (SVM) و درخت تصمیم تشکیل شده است. در مرحله نخست، متن‌های مرتبط با بیماری‌های همه‌گیر از توئیت‌ر جمع‌آوری می‌شوند. ابتدا توئیت‌ها پیش‌پردازش می‌شوند. سپس به منظور توصیف ویژگی‌های محتوایی توئیت‌ها، از تکنیک‌های پردازش متنی مانند TF-IDF استفاده می‌شود. برای استخراج ویژگی‌های مهم از توئیت‌ها، از یک شبکه عصبی کانولوشنی CNN استفاده می‌شود.

ویژگی‌های محتوایی که در مراحل قبلی استخراج شده‌اند، به مدل‌های یادگیری تجمیعی ارسال می‌شوند. این مدل‌ها شامل K- (KNN)، (SVM)، و درخت تصمیم هستند. این الگوریتم‌ها با تجزیه و تحلیل ویژگی‌های استخراج شده، قادرند تشخیص دهند که آیا یک توئیت حاوی شایعه در مورد بیماری‌های همه‌گیر می‌باشد یا خیر. خروجی‌های حاصل از سه الگوریتم SVM، KNN، و درخت تصمیم به مرحله نهایی تجمیعی ارسال می‌شوند. در این مرحله، با استفاده از روش رای‌گیری، تصمیم نهایی برای شناسایی شایعه بیماری‌های همه‌گیر اتخاذ می‌شود. این رویکرد ترکیبی از سه مدل یادگیری تجمیعی، به دقت بیشتر و کارایی بهتر در تشخیص شایعات منجر می‌شود.

در ادامه مراحل کلی روش پیشنهادی در تشخیص پیام‌های مرتبط با شایعه در شبکه‌های اجتماعی تشریح می‌گردد. روش پیشنهادی عمل شناسایی شایعه را در طی گام‌های زیر انجام می‌دهد: پیش‌پردازش و توصیف ویژگی‌های محتوایی، استخراج ویژگی مبتنی بر شبکه عصبی کانولوشن و تشخیص مبتنی بر یادگیری تجمیعی. دیاگرام بلوکی روش پیشنهادی در شکل ۱ نمایش داده شده است.

در اولین گام روش پیشنهادی، ابتدا محتوای پیام‌های موجود برای پردازش در گام‌های بعدی آماده‌سازی می‌شوند. لازمه انجام این کار، پردازش خصوصیات محتوایی با استفاده از فرایندهایی مانند: قطعه‌بندی متن، حذف کلمات بی‌اثر^۵ و ریشه‌یابی کلمات می‌باشد. همچنین از قالب ماتریس وزنی برای توصیف خصوصیات محتوایی استفاده می‌شود.

الگوریتم porter عمل ریشه یابی کلمات را از طریق گام‌های زیر انجام می‌دهد:

۱- حذف علائم جمع (s-es) و پسوندهای زمان مانند ed و ing از هر کلمه.

۲- تبدیل پسوندهای ترکیبی دوگانه مانند ization- به پسوندهای تکی مانند ize- و ation-

۳- حذف پسوندهایی مانند ness, full, ic و ... که از طریق گام دوم به دست آمده‌اند.

۴- حذف پسوندهایی مانند ant-, able- و ence- از انتهای کلمات.

۵- حذف e- انتهای کلمات و تبدیل II- به I- در صورتی که طول باقیمانده کلمه بیشتر از یک کاراکتر باشد.

پس از انجام عملیات پیش‌پردازش برای تمامی پیام‌های ورودی، یک لیست از کلمات یکتای پایگاه داده تولید خواهد شد. این لیست شامل مجموعه کل کلمات ریشه و کلمات کلیدی پایگاه داده بوده و برای توصیف هر پیام مورد استفاده قرار می‌گیرد. فرض کنیم با انجام این کار، برای پایگاه داده یک بردار مانند $F = \{w_1, \dots, w_n\}$ تولید شود. هر پیام می‌تواند از طریق وزن دهی به یک بردار ویژگی مانند $W = \{t_1, \dots, t_n\}$ توصیف شود که در این بردار، t_i مشخص کننده وزن مربوط به کلمه w_i در بردار F است.

پس از استخراج لیست کلمات یکتای موجود در متن، از معیار TF-IDF برای توصیف محتویات یک پیام استفاده می‌شود. در این گام، محتوای هر پیام براساس کلمات یکتای موجود در آن پیمایش می‌شود. سپس هر کلمه با استفاده از معیار TF-IDF وزن‌دهی می‌شود. برای وزن دهی یک کلمه مانند w از رابطه زیر استفاده می‌شود [۳۴]:

$$TFIDF_w = \frac{T_w}{T_D} \times \log_e \left(\frac{N}{N_w} \right) \quad (1)$$

که در رابطه فوق T_w تعداد تکرار کلمه w در پیام جاری، T_D تعداد کل کلمات موجود در پیام جاری و N تعداد کل پیام‌های پایگاه داده می‌باشد. همچنین N_w مشخص کننده تعداد پیام‌هایی در پایگاه داده است که کلمه w را در خود دارند. در روش پیشنهادی پس از محاسبه وزن هر کلمه، مقدار وزن به دست آمده در بردار ویژگی‌های W ذخیره می‌شود. با انجام این کار، یک ماتریس ویژگی حاصل خواهد شد که تعداد سطرهاى آن برابر با تعداد پیام‌ها و تعداد ستون‌های آن برابر با طول بردار ویژگی خواهد بود. بنابراین هر سطر ماتریس حاصل از این گام، توصیف کننده محتوای یک پیام خواهد بود. ماتریس حاصل از این فرآیند، به-عنوان ورودی گام دوم روش پیشنهادی مورد استفاده قرار می‌گیرد

یک سند به اجزای تشکیل دهنده آن از قبیل: پاراگراف، جمله و کلمات می‌باشد. در روش پیشنهادی ابتدا متن ورودی به پاراگراف‌های تشکیل دهنده آن قطعه‌بندی می‌شود. سپس هر پاراگراف را به جملات تقسیم‌بندی می‌کنیم.

محتوای یک پیام می‌تواند شامل هر نوع کاراکتری باشد. این ویژگی می‌تواند موجب کاهش دقت سیستم تشخیص شایعه گردد. از طرفی برخی کلمات یا عبارات موجود در متن می‌توانند از قالب خاصی پیروی کنند. به عنوان نمونه، آدرس ایمیل، آدرس صفحات وب، اعداد و موارد مشابه از الگویی خاص در متون پیروی می‌کنند. در مرحله پیش پردازش، این عبارات را شناسایی کرده و با کلمات کلیدی که مشخص کننده آن محتوا در متن می‌باشد جایگزین می‌کنیم. این الگوها عبارتند از:

- اعداد: در روش پیشنهادی هر عدد موجود در متن پیام با کلمه کلیدی NUMKEY جایگزین می‌شود.
- آدرس صفحات اینترنتی: هر گاه یک آدرس صفحه اینترنتی در متن موجود باشد، در مرحله پیش پردازش آن را با کلمه کلیدی WEBADDR جایگزین می‌کنیم.
- آدرس ایمیل: هرگاه در متن یک پیام به یک الگو که نشان دهنده ایمیل می‌باشد برخورد کنیم، آن را با کلمه کلیدی MAILADDR جایگزین می‌کنیم.

کاراکترهای واحد پولی: این دسته از کاراکترها در متن پیام‌های شایعه به دفعات بسیار زیادی استفاده می‌شود. از اینرو این کاراکتر را در متن پیام‌ها با کلمه کلیدی CURRKEY جایگزین می‌کنیم. پس از توصیف این الگوها توسط کلمات کلیدی تشریح شده، تمامی علائم باقیمانده غیر از حروف و اعداد در متن پیام را نادیده می‌گیریم. با انجام این عمل، متن پیام شامل مجموعه‌ای از کلمات و الگوهای خواهد بود که توسط کلمات کلیدی مشخص شده‌اند.

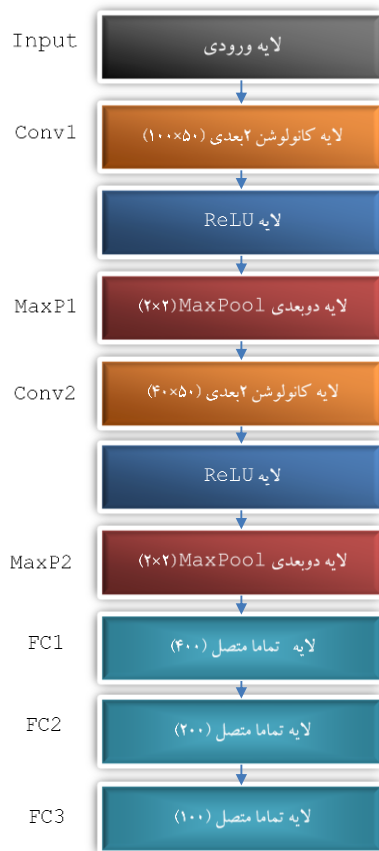
پس از قطعه بندی و توصیف الگوهای متن ورودی با کلمات کلیدی، کلمات بی‌اثر موجود در جملات هر سند را شناسایی کرده و آنها را حذف می‌کنیم. منظور از کلمات بی‌اثر، کلماتی مانند be, from, as و ... می‌باشد که وجود آنها در متن هیچ مفهوم کلیدی را بازتاب نخواهد داد [۳۲]. لذا حذف این کلمات در جملات هر سند متنی می‌تواند موجب بهبود روند استخراج ویژگی از متون شود.

پس از حذف کلمات بی‌اثر از جملات، متن به دست آمده را به کلمات تشکیل دهنده آن تجزیه کرده و عمل ریشه‌یابی را انجام می‌دهیم. زیرا استفاده از کلمات ریشه‌یابی شده موجب محدود کردن ابعاد بردار کلمات یا به بیان دیگر، بردار ویژگی‌ها خواهد شد. بر این اساس، برای هر کلمه در عنوان، پسوندها و پیشوندها را نادیده می‌گیریم. لازم به ذکر است که در روش پیشنهادی، برای انجام عمل ریشه‌یابی از الگوریتم porter [۳۳] استفاده می‌کنیم.

الگوریتم یک نمونه با رأی اکثریت از همسایه‌هایش دسته‌بندی می‌شود و این نمونه در عمومی‌ترین کلاس مابین k همسایه نزدیک تعیین می‌شود. K یک مقدار مثبت صحیح و عموماً کوچک است. اگر $k=1$ باشد نمونه به سادگی در کلاس همسایگان نزدیکش تعیین می‌گردد. فرد بودن مقدار k مفید می‌باشد چون با این کار جلوی آراء برابر گرفته می‌شود. روش k همسایه نزدیک، برای بسیاری از روش‌ها کاربرد دارد، زیرا اثربخش، غیرپارامتریک و دارای پیاده‌سازی راحت می‌باشد. با این حال زمان دسته‌بندی‌اش طولانی است و یافتن مقدار k بهینه مشکل است. انتخاب بهترین مقدار k ، وابسته به داده‌ها می‌باشد به طور کلی مقدار بزرگ از k اثر نوبز روی دسته‌بندی را کاهش می‌دهد، اما مرز مابین کلاس‌ها کمتر متمایز می‌شود [۳۵, ۳۶].

۳-۳-۲- تشخیص با استفاده از درخت تصمیم

الگوریتم درخت تصمیم یکی از روش‌های داده‌کاوی می‌باشد که باوجود اینکه برای طبقه‌بندی داده‌ها نیاز به محاسبات پیچیده ندارد و فهم آن نیز آسان است، دقت آن با سایر روش‌های طبقه‌بندی قابل رقابت می‌باشد، از این رو در مسائل مربوط به طبقه‌بندی کاربرد زیادی دارد. لذا در این بخش یک ساختار مبتنی



شکل ۲: ساختار شبکه عصبی عمیق مورد استفاده در روش پیشنهادی برای استخراج ویژگی

تا بر اساس آن، ویژگی‌های توصیف کننده هر پیام در قالبی فشرده توصیف گردد.

۳-۲- استخراج ویژگی‌ها مبتنی بر شبکه عصبی کانولوشن

در دومین گام از روش پیشنهادی، از شبکه عصبی کانولوشن به منظور استخراج ویژگی‌های پیام‌های پیش‌پردازش شده استفاده خواهد شد. ساختار شبکه عصبی عمیق مورد استفاده در روش پیشنهادی در شکل ۲ نمایش داده شده است. همانطور که در شکل ۲ نمایش داده شده است، شبکه عصبی کانولوشن مورد استفاده در روش پیشنهادی فاقد لایه‌های لازم برای طبقه‌بندی نمونه‌ها می‌باشد. چرا که در روش پیشنهادی، از این شبکه عصبی تنها برای هدف استخراج ویژگی از پیام‌های ورودی استفاده می‌شود. در نتیجه، خروجی حاصل از لایه تماماً متصل FC3 که برای هر نمونه ورودی به صورت یک بردار عددی با طول ۱۰۰ خواهد بود؛ توصیف کننده ویژگی‌های آن نمونه می‌باشد. هر لایه ReLU پس از لایه‌های کانولوشن در این شبکه عصبی، وظیفه تابع فعال ساز را برعهده دارد. هر لایه دوبعدی MaxPool نیز وظیفه انتقال داده‌های هر نمونه به فاز بعدی پردازش را برعهده خواهد داشت. سه لایه تماماً متصل تعریف شده در انتهای ساختار شبکه عصبی عمیق نیز به منظور توصیف ویژگی‌ها و فشرده‌سازی آن بکار خواهند رفت.

پس از استخراج ویژگی‌های پیام‌ها توسط شبکه عصبی کانولوشن، از تکنیک تجمیع به منظور طبقه‌بندی این ویژگی‌ها و تشخیص شایعه استفاده خواهد شد که در ادامه به تشریح آن خواهیم پرداخت.

۳-۳- تشخیص شایعه مبتنی بر یادگیری تجمیعی

در آخرین گام از روش پیشنهادی، از ترکیب سه طبقه‌بند در قالب یک مدل تجمیعی به منظور تشخیص پیام‌های حاوی شایعه استفاده خواهد شد. این مدل‌های یادگیر عبارتند از: مدل K نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان. در مدل تجمیعی پیشنهادی، ابتدا هریک از مدل‌های یادگیر ذکر شده به صورت مجزا به طبقه‌بندی نمونه‌ها پرداخته و سپس خروجی روش پیشنهادی از طریق رأی‌گیری بین خروجی مدل‌های یادگیر تعیین خواهد شد. در ادامه، به توضیح روند تشخیص شایعه با استفاده از این مدل‌های یادگیر می‌پردازیم.

۳-۳-۱- تشخیص با استفاده از K نزدیک‌ترین همسایه

روش K نزدیک‌ترین همسایه یک روش یادگیری موردی است و از جمله ساده‌ترین الگوریتم‌های یادگیری ماشین می‌باشد. در این

الگوریتم‌ها برای پیدا کردن خط جداکننده دسته‌ها، از دو خط موازی شروع کرده و این خطوط را در خلاف جهت یکدیگر حرکت می‌دهند تا هر کدام از خطوط به یک نمونه از یک دسته خاص در سمت خود برسد. پس از انجام این مرحله، میان دو خط موازی یک نوار یا حاشیه شکل می‌گیرد. هر چه پهنای این نوار بیشتر باشد، به این معنا است که الگوریتم توانسته حاشیه را بیشینه کند و هدف نیز بیشینه نمودن حاشیه است.

۳-۳-۴- ترکیب طبقه‌بندها با استفاده از تجمیع

آخرین مرحله به منظور تشخیص شایعه در روش پیشنهادی، استفاده از تکنیک رأی گیری می‌باشد. هدف از تکنیک رأی گیری، بهبود دقت طبقه‌بندی الگوریتم‌ها نسبت به حالتی است که هر یک از الگوریتم‌های به‌صورت جداگانه مورد استفاده قرار گیرند. این راهکار، یادگیری مبتنی بر رأی گیری یا تجمیع نامیده می‌شود. هر یک از الگوریتم‌های طبقه‌بندی ممکن است در طبقه‌بندی برخی نمونه‌ها دچار خطا شود؛ لذا هدف تکنیک‌های مبتنی بر رأی گیری، کاهش خطای حاصل و افزایش دقت در طبقه‌بندی نمونه‌ها می‌باشد. به‌صورت نظری ثابت شده است که استفاده از تکنیک رأی گیری می‌تواند موجب بهبود نتایج شود. بر این اساس، در آخرین گام روش پیشنهادی، مدل‌های طبقه‌بندی نایو بیز، درخت تصمیم و ماشین بردار پشتیبان به‌صورت مجزا عملیات طبقه‌بندی نمونه‌های آزمون را انجام داده و در نهایت با استفاده از رأی گیری نتایج هر سه مدل، خروجی نهایی سیستم تعیین می‌شود. پیاده‌سازی روش پیشنهادی با استفاده از نرم‌افزار MATLAB انجام شده است. به منظور افزایش اعتبار نتایج، آزمایشات را ۱۰ بار تکرار کرده و میانگین نتایج حاصل از تکرارها ارائه شده است. در روند آزمایشات، از پایگاه داده Twitter شامل ۱۰۰۰ پیام متنی استفاده شده است. در ادامه این فصل، ابتدا به تشریح مشخصات پایگاه داده و سناریوهای آزمون پرداخته و سپس به بیان نتایج حاصل از ارزیابی روش پیشنهادی خواهیم پرداخت.

۴- ارزیابی و نتایج

۴-۱- پایگاه داده

در این آزمایشات از یک پایگاه داده حاوی ۱۰۰۰ پیام در شبکه اجتماعی توییتر استفاده شده است. این تعداد پیام در یک بازه زمانی ۱۵۸ روزه بین ۷۲۳ کاربر ردوبدل شده است. پایگاه داده مذکور حاوی ۵۰۰ پیام دارای شایعه و اخبار دروغین مرتبط با بیماری کووید-۱۹ و همچنین ۵۰۰ پیام مربوط به تبادل پیام‌های نرمال می‌باشد. هدف این بخش، ارزیابی کارایی روش پیشنهادی در شناسایی و تمایز شایعات از پیام‌های نرمال با استفاده از راهبرد

بر درخت تصمیم و رگرسیون جهت تشخیص پیام‌های حاوی شایعه ارائه شده است.

درخت تصمیم و رگرسیون استفاده شده برای طبقه بندی، اندیس جینی^۵ را به عنوان معیار ناخالصی بکار می‌برد [۳۵]:

$$i(t) = 1 - \sum_{j=1}^J p^2(j|t) \quad (2)$$

در رابطه فوق، $p(j|t)$ احتمال تخمین زده شده برای تعلق داده t به کلاس j است و J تعداد کلاس‌ها را مشخص می‌کند. فرض کنید یک انشعاب، داده‌های t را به گره‌های سمت چپ t_L و سمت راست t_R تقسیم می‌کند. همچنین p_L و p_R به ترتیب بخش‌های t در گره‌های t_L و t_R باشند. درخت تصمیم و رگرسیون، انشعابی را ایجاد می‌کند که بتواند حداکثر کاهش در ناخالصی ($i(t) - (p_L i(t_L) - p_R i(t_R))$) را تولید کند. درخت تصمیم و رگرسیون بجای استفاده از قوانین توقف، با تولید یک درخت بزرگ دنباله‌ای از زیردرخت‌ها را تولید کرده و پس از آن عمل هرس^۶ درخت را تا زمانی که تنها گره ریشه باقی بماند انجام می‌دهد. در گام بعدی، از اعتبارسنجی متقابل^۷ برای تخمین هزینه طبقه بندی^۸ هر زیردرخت استفاده می‌شود. در نهایت، زیر درختی که کمترین هزینه تخمین زده شده را داشته باشد انتخاب می‌شود و مدل درخت تصمیم شکل می‌گیرد. در درخت نهایی، گره ریشه و سایر گره‌های والد مشخص کننده انشعاب و گره‌های برگ مشخص کننده کلاس‌های هدف می‌باشند. به منظور طبقه بندی یک داده‌ی ورودی، پیمایش درخت از گره ریشه آغاز شده و تا رسیدن به یک برگ ادامه می‌یابد [۳۵]. خروجی درخت تصمیم برای داده‌ی ورودی برابر با کلاسی خواهد بود که آن داده از طریق پیمایش انشعابات درخت به آن رسیده است.

۳-۳-۳- تشخیص با استفاده از ماشین بردار پشتیبان

آخرین الگوریتم بکار رفته به منظور تشخیص شایعه در مدل تجمیعی پیشنهادی، ماشین بردار پشتیبان می‌باشد. استفاده از بردارهای پشتیبان در مسائل دسته‌بندی، رویکرد کارآمدی است که از زمان معرفی آن مورد توجه بسیاری قرار گرفته است. ماشین‌های بردار پشتیبان دارای خواص مهمی هستند از جمله طراحی دسته‌بندی کننده با حداکثر تعمیم، توانایی رسیدن به بهینه سراسری تابع هزینه، تعیین خودکار ساختار و توپولوژی بهینه برای طبقه‌بندی کنند و مدل کردن توابع تمایز غیرخطی با استفاده از هسته‌های غیرخطی و مفهوم حاصل ضرب داخلی در فضای هیلبرت.

الگوریتم‌های مبتنی بر ماشین‌های بردار پشتیبان الگوریتم‌هایی هستند که سعی می‌کنند یک حاشیه^{۱۰} را بیشینه کنند. این

در شکل ۳-ب، ویژگی‌ها به صورت ستون‌های ماتریس ویژگی و نمونه‌ها در قالب سطرهای آن نمایش داده شده است. در این ماتریس، نیمه پایینی مربوط به ویژگی‌های استخراج شده از نمونه‌های نرمال و نیمه بالایی مربوط به نمونه‌های حاوی شایعه می‌باشد. همانطور که در شکل ۳ مشخص است، اولین ستون‌های ماتریس ویژگی استخراج شده، تفاوت‌های آشکارتری را بین دو کلاس هدف نشان می‌دهند و با پیشرفت در ویژگی‌های استخراج شده، این تفاوت کاهش می‌یابد. این ویژگی‌ها نشان می‌دهد که الگوریتم استخراج ویژگی مورد استفاده در روش پیشنهادی می‌تواند به طور کارآمد ویژگی‌ها را رتبه‌بندی کند. بنابراین، ویژگی‌هایی که می‌توانند تفاوت بین کلاس‌های هدف را واضح‌تر نشان دهند، در اولویت‌های اول قرار داده می‌شوند.

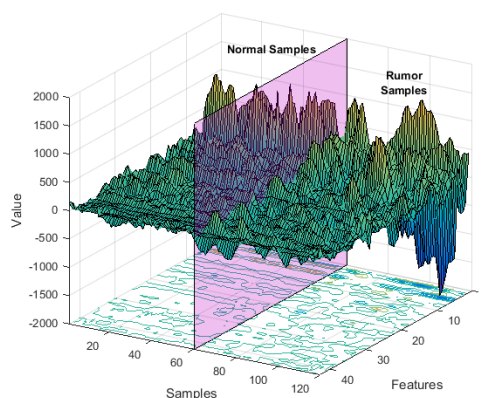
۴-۲- سناریوی آزمایش

پیاده‌سازی مدل پیشنهادی و آزمایش آن در محیط نرم‌افزار MATLAB صورت گرفته است. در آزمایش عملکرد روش پیشنهادی، نمونه‌های پایگاه داده به دو دسته نمونه‌های آموزش و نمونه‌های آزمون تقسیم‌بندی شده‌اند. به منظور بالا رفتن اعتبار نتایج آزمون، آزمایشات ۱۰ بار تکرار شده است. در هر بار تکرار ۹۰٪ داده‌ها برای آموزش مدل و ۱۰٪ باقی‌مانده برای آزمایش عملکرد آن استفاده می‌شوند. در هر تکرار داده‌های جدیدی برای آزمون مدل آموزش یافته استفاده می‌شود؛ بنابراین پس از ۱۰ بار تکرار آزمایش‌ها، تمامی داده‌ها در طی سناریو مورد آزمایش قرار می‌گیرند. این روند انتخاب نمونه در شکل ۴ نمایش داده شده است. این نوع ارزیابی را ارزیابی متقاطع ۱۱ می‌نامند. در شکل ۴ نمونه‌های انتخاب شده برای آموزش در هر تکرار به رنگ سفید و نمونه‌های انتخاب شده برای آزمایش مدل با رنگ قرمز نمایش داده شده‌اند.


جدول ۲. پارامترهای مدل یادگیری کانولوشن

Number of Convolution layers	2
Number of Pooling layers	2
Number of feature maps in convolutional layers	50,50
Receptive fields of convolutional layers	100×100 , 40×40
Pooling / subsampling layers	Max pooling
Receptive fields of Pooling layers	2×2
Activation function at fully connected layer	ReLU , Softmax
No. of Hidden nodes in hidden layers	400,200,100
No. of nodes in output layers	2 (2 classes)
Type of non-linearity	ReLU
Loss function	MSE
Learning rate	0.01
Optimization method	SGD

تحلیل محتوا می‌باشد. پیاده‌سازی روش پیشنهادی با استفاده از نرم‌افزار MATLAB انجام گرفته است. در این آزمایشات، عملکرد مدل پیشنهادی از زوایای مختلف مورد ارزیابی قرار گرفته و نتایج حاصل تفسیر شده است. مطابق روند تشریح شده در فصل قبل، ابتدا عمل پیش‌پردازش و استخراج ویژگی صورت می‌گیرد. نتیجه این گام، یک بردار ویژگی با طول ۲۲۰۲۶ کلمه برای توصیف هر رکورد پایگاه داده می‌باشد. با استفاده از شبکه عصبی کانولوشن، این ویژگی‌ها به ۱۰۰ عدد کاهش یافت. در نتیجه، پایگاه داده مورد استفاده در قالب یک ماتریس با ابعاد ۱۰۰۰×۱۰۰ توصیف گردید که در آن، هر سطر مشخص‌کننده ویژگی‌های یک پیام متنی می‌باشد. در شکل ۳، ساختار ماتریس ویژگی‌های استخراج شده توسط شبکه عصبی کانولوشن برای ۱۲۰ نمونه (۶۰ نمونه از هر کلاس هدف) نمایش داده شده است. لازم به ذکر است که به منظور نمایش بهتر این ماتریس، تنها ۴۰ ویژگی اول استخراج شده به تصویر کشیده شده است.



(الف)



(ب)

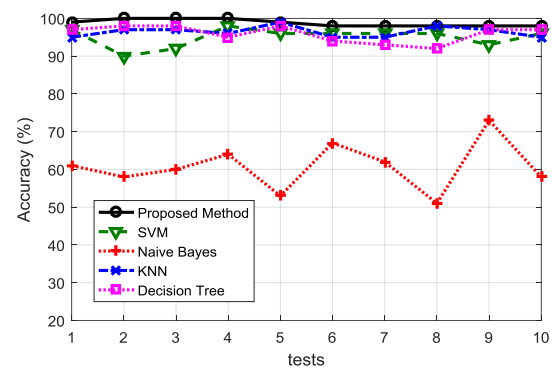
شکل ۳: ساختار ماتریس ویژگی‌های استخراج شده توسط شبکه عصبی کانولوشن (الف) در فضای سه بعدی (ب) در قالب ماتریسی

۳-۴- نتایج پیاده‌سازی

مطابق روند تشریح شده در بخش قبل، عمل تشخیص شایعه در شبکه‌های اجتماعی براساس تحلیل محتوای پیام‌های مبادله شده مطابق با پارامترهای مدل یادگیری کانولوشن جدول ۲ انجام شد. شکل ۵ نتایج مربوط به تشخیص صحیح به ازای هر تکرار توسط مدل پیشنهادی را نشان می‌دهد. در این نمودار دقت روش پیشنهادی با حالتی که از مدل‌های یادگیر ماشین بردار پشتیبان (SVM) با تابع هسته خطی، مدل K نزدیک‌ترین همسایه (KNN)، مدل نایو بیز (NB) و درخت تصمیم (CART) بجای طبقه‌بند تجمیعی استفاده شود؛ مقایسه شده است.

1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10

شکل ۴: روش انتخاب نمونه‌های آموزش و آزمایش از پایگاه داده




شکل ۵: نتایج مربوط به تشخیص روش پیشنهادی

نتایج نمایش داده شده در شکل ۵، درصد تشخیص صحیح برای هریک از ۱۰ بار تکرار آزمایش را نمایش می‌دهد. همانطور که این نمودار نمایش داده شده است، استفاده از یادگیری تجمیعی در روش پیشنهادی می‌تواند موجب بهبود دقت تشخیص شایعه در شبکه اجتماعی نسبت به سایر الگوریتم‌های مقایسه شده گردد. نتایج این آزمایش نشان می‌دهد که در حالت استفاده از سیستم تجمیعی پیشنهادی، کمترین دقت تشخیص صحیح شایعه در شبکه اجتماعی برابر با ۹۸.۰۰ درصد، بیشترین دقت تشخیص

صحیح برابر با ۱۰۰ شکل ۷ نتایج حاصل از آزمایش الگوریتم پیشنهادی برای تشخیص شایعه در شبکه‌های اجتماعی را نمایش می‌دهد. در این شکل، معیارهای حساسیت^{۱۲} و ویژگی^{۱۳} مورد مقایسه قرار گرفته‌اند. درصد و میانگین تشخیص صحیح برابر با ۹۸.۸ درصد می‌باشد. این در حالی است که در حالت استفاده از مدل KNN (به‌عنوان طبقه‌بندی که دارای نزدیک‌ترین عملکرد به روش پیشنهادی است)، کمترین دقت تشخیص صحیح شایعه برابر با ۹۵ درصد، بیشترین دقت تشخیص صحیح برابر با ۹۹ درصد و میانگین تشخیص صحیح برابر با ۹۶.۴ درصد می‌باشد. همچنین مدل‌های ماشین بردار پشتیبان، درخت تصمیم و مدل نایو بیز به ترتیب دارای میانگین دقت ۹۵ و ۹۵.۹ و ۶۰.۷ درصد می‌باشند.

نتایج نمایش داده شده در شکل ۵ نشان می‌دهد که روش پیشنهادی در طی تکرارهای مختلف علاوه بر میانگین دقت بالاتر، دارای بازه تغییرات محدودتری نیز می‌باشد. بررسی نتایج نشان می‌دهد که انحراف معیار استاندارد مقادیر دقت در روش پیشنهادی برابر با ۰.۹۱۹ و انحراف معیار استاندارد مقادیر دقت در مدل‌های K نزدیک‌ترین همسایه، درخت تصمیم، ماشین بردار پشتیبان و نایو بیز به ترتیب برابر با ۱.۴۳، ۲.۲۳، ۲.۴۹ و ۶.۴۳ می‌باشد. در شکل ۶ مقادیر میانگین دقت هر الگوریتم طبقه‌بندی به همراه بازه‌های تغییرات دقت آن نمایش داده شده است. در این نمودار، محدوده خط چین هر جعبه نشان دهنده کران بالا و پایین تغییرات دقت الگوریتم در تکرارهای مختلف می‌باشد. دایره میانی نمایش داده شده روی هر جعبه، مشخص کننده مقادیر میانه دقت هر الگوریتم در طی ۱۰ بار تکرار آزمایش می‌باشد. براساس نتایج نمایش داده شده در شکل ۶، روش پیشنهادی علاوه بر میانگین دقت بالاتر دارای مقادیر بیشتری و نزدیک به هم برای کران‌های تغییرات دقت در طی تکرارهای مختلف می‌باشد.

شکل ۶ نشان می‌دهد که در نیمی از تکرارها، روش پیشنهادی قادر به طبقه‌بندی دقیق تمامی نمونه‌ها بوده و نیمی دیگر، میزان



شکل ۶: میانگین تغییرات دقت الگوریتم‌های مختلف در طی ۵ بار تکرار آزمایشات

الگوریتم‌های مقایسه شده می‌باشد. شکل ۸ ماتریس درهم ریختگی^{۱۴} حاصل از تشخیص شایعه در مدل پیشنهادی را نمایش می‌دهد. در ماتریس در هم ریختگی نمایش داده شده، دسته‌بندی واقعی نمونه‌ها به صورت ستونی و دسته‌بندی تعیین شده توسط سیستم تجمیعی در روش پیشنهادی به صورت سطری ماتریس مشخص شده است. همچنین اعداد ۱ و ۲ که به صورت عنوان سطرها و ستون‌های ماتریس درهم ریختگی نمایش داده شده است؛ برترتیب مشخص کننده کلاس‌های: «نرمال» و «شایعه» می‌باشند. به عنوان نمونه، مجموع اعداد نمایش داده شده در ستون اول این ماتریس برابر با ۴۸۳ می‌باشد و این بدان معناست که ۴۸۳ نمونه از پایگاه داده متعلق به دسته نرمال می‌باشد. اما از طرفی اعداد موجود در سطر اول ماتریس درهم ریختگی نشان می‌دهد که سیستم تجمیعی پیشنهادی توانسته است ۴۷۷ نمونه از این مجموعه نمونه را به درستی در کلاس نمونه‌های نرمال قرار دهد (عدد ۴۷۷ در سطر اول و ستون اول ماتریس) و ۶ نمونه را اشتبهاً در دسته نمونه‌های حاوی شایعه قرار داده است. همچنین ۶ نمونه متعلق به دسته نمونه‌های حاوی شایعه را نیز اشتبهاً در دسته نمونه‌های نرمال قرار داده است (عدد ۶ در سطر اول و ستون دوم). تفسیر خروجی روش پیشنهادی برای کلاس نمونه‌های حاوی شایعه نیز به شیوه‌ای مشابه قابل انجام خواهد بود. این نتایج نشان می‌دهد که روش پیشنهادی در تشخیص نمونه‌های حاوی شایعه و فاقد آن به صورت میانگین دارای عملکرد مناسبی می‌باشد.

Proposed Method

Output Class	1	477 47.7%	6 0.6%	98.8% 1.2%
	2	6 0.6%	511 51.1%	98.8% 1.2%
		98.8% 1.2%	98.8% 1.2%	98.8% 1.2%
		1	2	
		Target Class		

شکل ۸: ماتریس درهم ریختگی حاصل از تشخیص شایعه در مدل پیشنهادی

همچنین نتایج ماتریس درهم ریختگی مربوط به الگوریتم‌های مقایسه شده دیگر در شکل ۹ نمایش داده شده است. در این نمودار، نتایج طبقه بندی مربوط به حالتی که از سایر مدل‌های یادگیر برای تشخیص شایعه یا دروغین بودن یک پیام استفاده شود؛ نشان داده شده است. مقایسه ماتریس‌های درهم ریختگی


دقت روش پیشنهادی برابر با ۹۸ درصد بوده است. معیار حساسیت برای اندازه گیری نسبت کل نمونه‌های دسته مثبتی (شایعه) است که بطور صحیح تشخیص داده شده‌اند و به صورت زیر محاسبه می‌شود [۳۷]:

$$Sensitivity = 100 \times \frac{TP}{TP+FN} \quad (3)$$

که در رابطه فوق، TP نمونه‌های دسته مثبتی است که به صورت صحیح تشخیص داده شده‌اند و FN نمونه‌های دارای دسته مثبتی است که به عنوان منفی (نرمال) تشخیص داده شده‌اند. معیار ویژگی برای اندازه گیری نمونه‌های منفی است که به صورت صحیح طبقه بندی شده‌اند بکار می‌رود. این معیار به صورت زیر محاسبه می‌شود:

$$Specificity = 100 \times \frac{TN}{TN+FP} \quad (4)$$

در رابطه فوق، TN نمونه‌های دسته منفی است که به صورت صحیح تشخیص داده شده‌اند و FP نمونه‌های دسته منفی است که به عنوان نمونه دسته مثبت تشخیص داده شده‌اند. همچنین مقادیر عددی به دست آمده برای این آزمون در جدول ۳ آورده شده است.



شکل ۷: مقادیر میانگین حساسیت و ویژگی حاصل از تشخیص شایعه در طی ۱۰ بار تکرار آزمایشات

جدول ۳: مقایسه کارایی روش پیشنهادی در تشخیص شایعه

الگوریتم	دقت (%)	حساسیت (%)	ویژگی (%)
روش پیشنهادی	98.8	98.758	98.839
SVM	95	92.34	97.485
Naive Bayes	60.7	25.256	93.81
KNN	96.4	97.516	95.358
Decision Tree	95.9	95.238	96.518

همانطور که نتایج شکل ۷ و جدول ۳ نشان می‌دهد، روش پیشنهادی هم از نظر درصد تشخیص صحیح و هم از نظر پارامترهای حساسیت و ویژگی دارای عملکرد بهتری نسبت

در شکل ۱۰، منحنی ROC برای آزمایشات صورت گرفته نمایش داده شده است. در این شکل سطح زیر منحنی ROC در حالت استفاده از روش پیشنهادی بیشتر از سایر الگوریتم‌های طبقه‌بندی مقایسه شده می‌باشد. این نمودار نشان می‌دهد که استفاده از روش پیشنهادی موجب کاهش در نرخ FP و افزایش نرخ TP نسبت به سایر الگوریتم‌ها خواهد شد. در نتیجه الگوریتم پیشنهادی در تشخیص شایعات در شبکه‌های اجتماعی کارایی بیشتری دارد.

۵- مقایسه نهایی

در این بخش مقایسه با یک مدل یادگیری عمیق ترکیبی جدید برای تشخیص شایعات مرتبط با COVID-19، LSTM-PCNN، CNN [۱۷]، که بر اساس حافظه کوتاه مدت و شبکه‌های عصبی موازی به هم پیوسته است انجام شده است. جداول ۴ و ۵ مقادیر متوسط به دست آمده در مقایسه با روش‌های دیگر را نشان می‌دهند. همانطور که نتایج مقایسه نشان می‌دهد، افزودن لایه‌های زیاد می‌تواند منجر به کاهش کارایی شود.

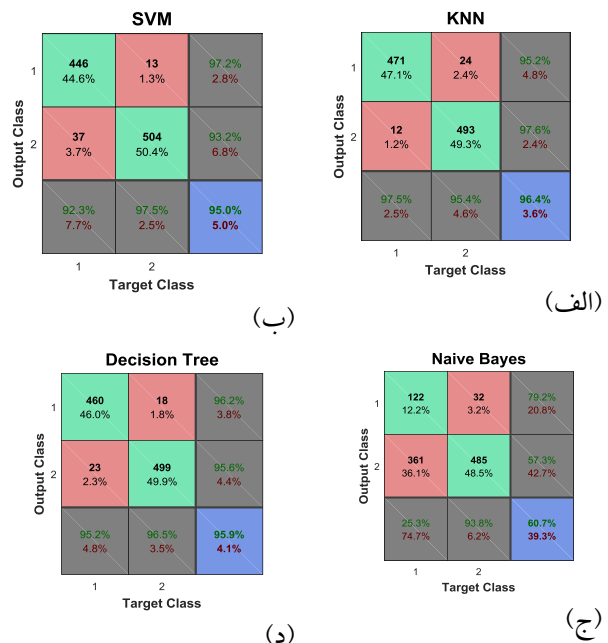
جدول ۴: مقادیر میانه به دست آمده با استفاده از یک لایه متراکم

Embedding Layers	Accuracy	Precision	Recall	F-Score
Word2Vec (CBOW)/ LSTM-PCNN	85.10%	0.8509	0.8510	0.8509
Word2Vec (Skip-gram)/ LSTM-PCNN	85.74%	0.86054	0.85737	0.8576
Fast Text (CBOW)/ LSTM-PCNN	85.42%	0.85577	0.85420	0.8538
Fast Text (Skip-gram)/ LSTM-PCNN	83.99%	0.84059	0.83994	0.8389
GloVe) LSTM-PCNN	85.42%	0.85584	0.85420	0.8544
روش پیشنهادی	0.9451	0.938	0.968	0.9457

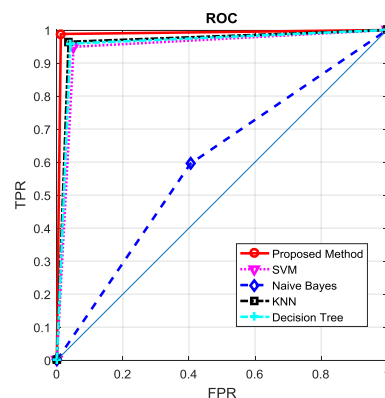
جدول ۵: مقادیر میانه به دست آمده با استفاده از چندین لایه متراکم

Embedding Layers	Accuracy	Precision	Recall	F-Score
Word2Vec (CBOW)/ LSTM-PCNN	84.79%	0.84762	0.84786	0.84760
Word2Vec (Skip-gram)/ LSTM-PCNN	84.79%	0.84971	0.84786	0.84775
Fast Text (CBOW)/ LSTM-PCNN	85.26%	0.85560	0.85261	0.85294
Fast Text (Skip-gram)/ LSTM-PCNN	86.05%	0.86406	0.86054	0.86084
GloVe / LSTM-PCNN	85.10%	0.85553	0.85103	0.85136
روش پیشنهادی	0.93681	0.9225	0.9347	0.9352

نشان می‌دهد که روش پیشنهادی در دسته‌بندی صحیح نمونه‌های مورد آزمون، دارای عملکرد بهتری نسبت به سایر مدل‌های یادگیر می‌باشد. این نتایج نشان از کارایی سیستم تجمیعی در بهبود دقت تشخیص دارد. منحنی ROC¹⁵ یک نمودار یا شمای گرافیکی است که با استفاده از میزان مثبت واقعی (حساسیت) بر روی محور افقی و میزان مثبت کاذب (ویژگی) بر روی محور عمودی در آستانه‌های مختلف (نقاط برش متفاوت) ایجاد می‌شود. بدیهی است هنگامی که حساسیت افزایش پیدا کند، میزان مثبت کاذب نیز افزایش می‌یابد. بنابراین منحنی ROC به ما اجازه می‌دهد تا میزان مثبت واقعی و مثبت کاذب را در هر نقطه بر روی منحنی بررسی و مقایسه کنیم. سطح زیر منحنی کیفیت کلی آزمون‌های تشخیصی (دقت) را به ما نشان می‌دهد. آزمون‌های با سطح زیر منحنی یکسان عملکرد کلی تشخیصی برابری دارند، ولی لزوماً حساسیت و ویژگی برابری ندارند.



شکل ۹: ماتریس درهم ریختگی حاصل از تشخیص شایعه توسط (الف) KNN (ب) SVM، (ج) نایو بیس و (د) درخت تصمیم



شکل ۱۰: منحنی ROC برای طبقه بندی روش پیشنهادی

الگوریتم‌های طبقه‌بندی مقایسه شد. نتایج حاصل از این تحقیق نشان داد که با استفاده از روش پیشنهادی می‌توان شایعات را با دقت میانگین ۹۸.۸ درصد تشخیص داده که نشان از بهبود حداقل ۲.۴ درصدی دقت تشخیص نسبت به روش‌های پیشین دارد.

در کارهای آتی می‌توان کاربرد سایر الگوریتم‌های استخراج ویژگی مانند تحلیل مولفه‌های اصلی را به منظور استخراج ویژگی‌های محتوایی مورد مطالعه قرار داد. همچنین بکارگیری الگوریتم‌های انتخاب ویژگی در روش پیشنهادی، ممکن است نتایج مفیدی را در راستای افزایش دقت تشخیص در پی داشته باشد. لذا در کارهای آتی می‌توان به بررسی این مورد پرداخت. با تغییر مدل‌های طبقه‌بندی بکار رفته در روش پیشنهادی ممکن است بتوان به دقت بالاتری در تشخیص دست یافت. در انتها پیشنهاد می‌شود که کاربرد روش پیشنهادی در سناریوهای مشابه مانند تشخیص بات‌نت‌ها در شبکه‌های اجتماعی مورد بررسی قرار گیرد.

جدول ۷: پارامترهای انتخابی برای مورد استفاده جهت مقایسه با

مقاله LSTM-PCNN

Layer (type)	Output Shape
conv1d_2 (Conv1D)	(None, 1, 512)
conv1d_3 (Conv1D)	(None, 1, 256)
flatten_1 (Flatten)	(None, 256)
dense_2 (Dense)	(None, 128)
dense_3 (Dense)	(None, 1)

نمونه ای از دیتاست استفاده شده در این مقایسه در جدول ۶ ارائه شده است. در انتها، در جدول ۷ پارامترهای انتخابی برای مقایسه با روش LSTM-PCNN ذکر شده است.

جدول ۶: نمونه دیتاست

متن شایعه به عربی	متن شایعه به انگلیسی
لن يتوفر لقاح قبل عام والجدل مستمر " حول استخدام الكلوروكين وبلازما النقاؤه لعلاج #كورونا	A vaccine will not be available for a year, and the controversy continues over the use of chloroquine and convalescent plasma to treat #Corona
بناء على نتائج الدراسات الوبائية فإنه لا يوجد خطر من انتقال فيروس كورونا الجديد عبر البضائع والطرود القادمة من الصين مع تمنياتنا للجميع بالصحة "والعافية"	Based on the results of epidemiological studies, there is no risk of transmission of the new Corona virus through goods and packages coming from China. We wish everyone health and wellness."
في الواقع #الثوم قد يحتوي على بعض الخصائص المضادة لل #ميكروبات ومع ذلك لا يوجد أي دليل على انه يحمي الاشخاص من #فيروس كورونا	In fact, #garlic may contain some anti-microbial properties. However, there is no evidence that it protects people from the #Coronavirus.
إن المعركة ضد #كوفيد-19 تُلزِمنا أيضاً بالتصدي للمعلومات المضللة احرصوا على تقصي المعلومات من مصادرنا قبل نشر أي شيء	The fight against #Covid_19 also requires us to combat misinformation. Make sure to check the information from its sources before publishing anything.
شبكات الجيل الخامس للهواتف المحمولة لا تساهم في انتشار مرض #كوفيد-19	5G mobile networks do not contribute to the spread of #Covid_19.

۶- نتیجه گیری و راهکارهای آتی

در این پژوهش یک روش جدید به منظور تشخیص شناسایی شایعات در شبکه‌های اجتماعی در زمینه بیماری‌های همه‌گیر با استفاده از ترکیب تکنیک‌های یادگیری ماشین ارائه شد. هدف اصلی این پژوهش، استفاده از شبکه‌های عصبی CNN به عنوان یک روش مؤثر برای استخراج ویژگی‌های متن مرتبط با شایعات است. سپس با استفاده از یادگیری تجمیعی SVM و DT و KNN، مدل‌های تشخیصی پیش‌بینی برای تشخیص شایعات توسعه داده شده‌اند.

روش پیشنهادی را می‌توان به این مراحل تجزیه نمود: پیش پردازش و توصیف ویژگی‌های محتوایی، استخراج ویژگی مبتنی بر شبکه عصبی کانولوشن، تشخیص مبتنی بر یادگیری تجمیعی و تعیین خروجی نهایی سیستم پیشنهادی از طریق رای‌گیری خروجی‌های این سه الگوریتم تعیین خواهد شد. به منظور پیاده‌سازی روش پیشنهادی از نرم‌افزار MATLAB استفاده شده و کارایی روش پیشنهادی در تشخیص شایعات با استفاده از داده‌های شبکه اجتماعی توپیتزر ارزیابی شده است. همچنین در طی این آزمایشات، از تکنیک ارزیابی متقاطع با ۱۰ تکرار استفاده شد. در نهایت، نتایج حاصل از پیاده‌سازی روش پیشنهادی با سایر

منابع

- [1] U. Can and B. Alatas, "A new direction in social network analysis: Online social network analysis problems and applications," *Physica A: Statistical Mechanics and its Applications*, vol. 535, p. 122372, 2019.
- [2] J. J. Lotf, M. A. Azgomi, and M. R. E. Dishabi, "An improved influence maximization method for social networks based on genetic algorithm," *Physica A: Statistical Mechanics and its Applications*, vol. 586, p. 126480, 2022.
- [3] M. Hosseini, A. J. Sabet, S. He, and D. Aguiar, "Interpretable fake news detection with topic and deep variational models," *Online Social Networks and Media*, vol. 36, p. 100249, 2023.
- [4] J. Chen and Y. Wang, "Social media use for health purposes: systematic review," *Journal of medical Internet research*, vol. 23, no. 5, p. e17917, 2021.
- [5] K. Zhou, Y. Yang, Y. Qiao, and T. Xiang, "Domain adaptive ensemble learning," *IEEE Transactions on Image Processing*, vol. 30, pp. 8008-8018, 2021.
- [6] N. Mungoli, "Adaptive Ensemble Learning: Boosting Model Performance through Intelligent Feature Fusion in Deep Neural Networks," *arXiv preprint arXiv:2304.02653*, 2023.
- [7] D. Antonakaki, P. Fragopoulou, and S. Ioannidis, "A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks," *Expert Systems with Applications*, vol. 164, p. 114006, 2021.
- [8] S. Sadiq, A. Mehmood, S. Ullah, M. Ahmad, G. S. Choi, and B.-W. On, "Aggression detection through

- Rumor Identification," in *Frontiers in Cyber Security: Third International Conference, FCS 2020, Tianjin, China, November 15–17, 2020, Proceedings 3*, 2020, pp. 65-82: Springer.
- [25] L. Alsudias and P. Rayson, "COVID-19 and Arabic Twitter: How can Arab world governments and public health organizations learn from social media?," in *Proceedings of the 1st Workshop on NLP for COVID-19 at ACL 2020*, 2020.
- [26] P. Rani, V. Jain, J. Shokeen, and A. Balyan, "Blockchain-based rumor detection approach for COVID-19," *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-15, 2022.
- [27] H.-y. Lu, J. Yang, W. Fang, X. Song, and C. Wang, "A deep neural networks-based fusion model for COVID-19 rumor detection from online social media," *Data Technologies and Applications*, no. ahead-of-print, 2022.
- [28] V. Mottaghi, M. Esmaeili, G. A. Bazaei, and M. A. Afshar Kazemi, "Providing a Hybrid Approach Based on Deep learning And Machine Learning to Detect fake news-A Case Study of Persian News in the Field of COVID-19," *Sciences and Techniques of Information Management*, vol. 8, no. 3, pp. 283-316, 2022.
- [29] A. Kumar, J. P. Singh, and A. K. Singh, "COVID-19 Fake News Detection Using Ensemble-Based Deep Learning Model," *IT Professional*, vol. 24, no. 2, pp. 32-37, 2022.
- [30] J. Yang and Y. Pan, "COVID-19 Rumor Detection on Social Networks Based on Content Information and User Response," *Frontiers in Physics*, vol. 9, p. 763081, 2021.
- [31] A. M. Almars, M. Almaliki, T. H. Noor, M. M. Alwateer, and E. Atlam, "Hann: Hybrid attention neural network for detecting covid-19 related rumors," *IEEE Access*, vol. 10, pp. 12334-12344, 2022.
- [32] C. Silva and B. Ribeiro, "The importance of stop word removal on recall values in text categorization," in *Proceedings of the International Joint Conference on Neural Networks, 2003.*, 2003, vol. 3, pp. 1661-1666: IEEE.
- [33] C. Ramasubramanian and R. Ramya, "Effective pre-processing activities in text mining using improved porter's stemming algorithm," *International Journal of Advanced Research in Computer and Communication Engineering*, vol. 2, no. 12, pp. 4536-4538, 2013.
- [34] K. Ghag and K. Shah, "SentitFIDF–Sentiment classification using relative term frequency inverse document frequency," *International Journal of Advanced Computer Science and Applications*, vol. 5, no. 2, 2014.
- [35] J. Han, M. Kamber, and J. Pei, "Data mining concepts and techniques third edition," *University of Illinois at Urbana-Champaign Micheline Kamber Jian Pei Simon Fraser University*, 2012.
- [36] R. R. Asaad and R. M. Abdulhakim, "The Concept of Data Mining and Knowledge Extraction Techniques," *Qubahan Academic Journal*, vol. 1, no. 2, pp. 17-20, 2021.
- [37] D. J. Hand, "Principles of data mining," *Drug safety*, vol. 30, pp. 621-622, 2007.
- deep neural model on twitter," *Future Generation Computer Systems*, vol. 114, pp. 120-129, 2021.
- [9] L. Ilias and I. Roussaki, "Detecting malicious activity in Twitter using deep learning techniques," *Applied Soft Computing*, vol. 107, p. 107360, 2021.
- [10] P. K. Roy, J. P. Singh, and S. Banerjee, "Deep learning to filter SMS Spam," *Future Generation Computer Systems*, vol. 102, pp. 524-533, 2020.
- [11] Z. Alom, B. Carminati, and E. Ferrari, "A deep learning model for Twitter spam detection," *Online Social Networks and Media*, vol. 18, p. 100079, 2020.
- [12] Q. Zhou, J. Wu, and L. Duan, "Recommendation attack detection based on deep learning," *Journal of Information Security and Applications*, vol. 52, p. 102493, 2020.
- [13] L. Wu, Q. Zhang, C.-H. Chen, K. Guo, and D. Wang, "Deep learning techniques for community detection in social networks," *IEEE Access*, vol. 8, pp. 96016-96026, 2020.
- [14] M. Orabi, D. Mouheb, Z. Al Aghbari, and I. Kamel, "Detection of bots in social media: a systematic review," *Information Processing & Management*, vol. 57, no. 4, p. 102250, 2020.
- [15] N. El-Mawass, P. Honeine, and L. Vercouter, "SimilCatch: Enhanced social spammers detection on twitter using Markov random fields," *Information processing & management*, vol. 57, no. 6, p. 102317, 2020.
- [16] A. A. Orunsolu, A. S. Sodiya, and A. Akinwale, "A predictive model for phishing detection," *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 2, pp. 232-247, 2022.
- [17] M. Al-Sarem, A. Alsaedi, F. Saeed, W. Boulila, and O. AmeerBakhsh, "A novel hybrid deep learning model for detecting COVID-19-related rumors on social media based on LSTM and concatenated parallel CNNs," *Applied Sciences*, vol. 11, no. 17, p. 7940, 2021.
- [18] M. Heidari, H. James Jr, and O. Uzuner, "An empirical study of machine learning algorithms for social media bot detection," in *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 2021, pp. 1-5: IEEE.
- [19] J. Rodríguez-Ruiz, J. I. Mata-Sánchez, R. Monroy, O. Loyola-Gonzalez, and A. López-Cuevas, "A one-class classification approach for bot detection on Twitter," *Computers & Security*, vol. 91, p. 101715, 2020.
- [20] Y. Feng, J. Li, L. Jiao, and X. Wu, "Towards learning-based, content-agnostic detection of social bot traffic," *IEEE Transactions on Dependable and Secure Computing*, vol. 18, no. 5, pp. 2149-2163, 2020.
- [21] S. Feng, H. Wan, N. Wang, and M. Luo, "BotRGCN: Twitter bot detection with relational graph convolutional networks," in *Proceedings of the 2021 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, 2021, pp. 236-239.
- [22] S. Chen, "Research on Fine-Grained Classification of Rumors in Public Crisis—Take the COVID-19 incident as an example," in *E3S Web of conferences*, 2020, vol. 179, p. 02027: E3S Web of Conferences.
- [23] S. Alqurashi, B. Hamoui, A. Alashaikh, A. Alhindi, and E. Alanazi, "Eating garlic prevents COVID-19 infection: Detecting misinformation on the Arabic content of Twitter," *arXiv preprint arXiv:2101.05626*, 2021.
- [24] L. Wang, W. Wang, T. Chen, J. Ke, and B. Tang, "Deep Attention Model with Multiple Features for

پاورقی‌ها:

- ¹ Convolutional Neural Network
- ² Ensemble
- ³ Feature Selection Module
- ⁴ Bot detection with Relational Graph Convolutional Networks
- ⁵ stop-word
- ⁶ Gini Index
- ⁷ Prune
- ⁸ cross-validation
- ⁹ Classification Cost
- ¹⁰ Margian
- ¹¹ cross validation
- ¹² Sensitivity
- ¹³ Specifity
- ¹⁴ Confusion Matrix
- ¹⁵ Received Operating Characteristics