

استفاده از رأی گیری بیشینه در شبکه های عصبی

گراف برای تحلیل احساسات مبتنی بر جنبه



علی بلوچی^{۱*}، مظفر بگ محمدی^۲، مجتبی کرمی^۳
کارشناس ارشد مهندسی کامپیوتر، دانشگاه ایلام، ایلام، ایران^{۱*}
دانشیار گروه مهندسی کامپیوتر، دانشگاه ایلام، ایلام، ایران^۲
استادیار گروه مهندسی کامپیوتر، دانشگاه ایلام، ایلام، ایران^۳

چکیده

درک عواطف و احساسات مبتنی بر جنبه، وظیفه ای کاربردی و مهم در حوزه پردازش زبان طبیعی است که دیدگاه های ظریفی را در داده های متنی آشکار می سازد و به تحلیل عمیق تر محتوای متنی کمک می کند. تجزیه و تحلیل احساسات در سطح جنبه، در تشخیص دقیق احساسات بیان شده نسبت به یافتن ویژگی های مثبت و منفی موضوعات مورد بحث، اهمیت فراوانی دارد و به همین دلیل در زمینه هایی مانند بررسی نظرات مشتریان، پایش شبکه های اجتماعی و بهبود سامانه های پیشنهاددهنده کاربردهای گسترده ای پیدا کرده است. در این مقاله، به تحلیل احساسات سطح جنبه با استفاده از شبکه های عصبی گراف (GCN) پرداخته می شود که این روش ها در ثبت روابط پیچیده درون داده ها نسبت به رویکردهای کلاسیک عملکرد بهتری داشته و برای تشخیص احساسات مرتبط با جنبه های خاص، گزینه ای مناسب به شمار می روند. روش پیشنهادی در این پژوهش شامل استفاده از ترکیب نتایج چند مدل پیاده سازی شده مبتنی بر الگوریتم های GCN بر روی مجموعه داده های معیار برای تحلیل احساسات سطح جنبه است. مدل های پیاده سازی شده شامل DualGCN، RDGCN، SSEGCN و R-GAT هستند که هر کدام با بهره گیری از دیدگاه ها و معماری های متفاوت، قابلیت های متنوعی در استخراج ویژگی های ساختاری و معنایی متن ارائه می دهند. این مدل ها با استفاده از رویکرد یادگیری جمعی که فرایند رأی گیری بیشینه را شامل می شود، ترکیب شده اند و در نتیجه پیشرفت های قابل توجهی را نسبت به مدل های فردی نشان می دهند. مجموعه داده انتخابی این پژوهش شامل SemEval2014 (زیرمجموعه های رستوران ۱۴ و لپ تاپ) و تویتر است. در مجموعه داده رستوران ۱۴، مدل نهایی شاهد افزایش ۲۰۱۵٪ در معیار دقت (Accuracy) و ۲۰۸٪ در معیار امتیاز F1 (F1-Score) نسبت به مدل های پایه بوده است؛ همچنین، در مجموعه داده لپ تاپ افزایش قابل توجهی معادل ۹۰۲ درصد در معیار دقت و ۱۱۰۷۴ درصد در معیار امتیاز F1 مشاهده شده است؛ در نهایت، در مجموعه داده تویتر، افزایش ۷۰۸٪ در معیار دقت و ۸۰۷٪ در معیار امتیاز F1 به ثبت رسیده است. نتایج نشان می دهند که رویکرد جدید و پیش گام این پژوهش توانسته است بالاترین درصد دقت را نسبت به پژوهش های اخیر در این حوزه به دست آورد.

واژگان کلیدی: پردازش زبان طبیعی، یادگیری عمیق، شبکه های عصبی گراف، تحلیل احساسات سطح جنبه، یادگیری جمعی.

Using Majority Voting in Graph Neural Networks for Aspect-Based Sentiment Analysis

Ali Balouchi^{*1}, Mozafar Bagmohmmadi² and Mojtaba Karami³

M.Sc in Computer Engineering, Ilam University, Ilam, Iran^{*1}

Associate Professor of Faculty of Computer Engineering, Ilam University, Ilam, Iran²

Assistant Professor of Faculty of Computer Engineering, Ilam University, Ilam, Iran³

Abstract

Aspect-Based Sentiment Analysis (ABSA) is a detailed subdomain of sentiment analysis that focuses on detecting sentiments toward specific aspects of entities, such as product features or service attributes, rather than providing a general sentiment polarity. This granular understanding is essential in domains such as customer feedback evaluation, social media opinion mining, and intelligent recommendation systems. However, capturing the syntactic and semantic dependencies required for accurate ABSA remains a challenge for conventional models. In this study, we propose an ensemble-based approach utilizing Graph Convolutional Networks (GCNs), which are particularly effective in learning structural relationships from sentence-level dependency trees. Our methodology involves the integration of four

* Corresponding author

* نویسنده عهده دار مکاتبات

advanced GCN-based models: DualGCN, RDGCN, SSEGCN, and R-GAT. Each model offers distinct strengths, ranging from dual-graph encoding and reinforcement-driven attention mechanisms to syntax-aware semantic enhancements. These models are trained individually and then aggregated through a majority voting mechanism to create a robust ensemble capable of improved sentiment prediction at the aspect level. The models were evaluated on benchmark datasets including SemEval-2014 (Rest14 and Laptops subsets) and Twitter, covering both formal and informal texts. Extensive preprocessing was conducted to standardize input formats and ensure fair comparison across models. Moreover, training was performed using both GLoVe and BERT embeddings, allowing the ensemble to benefit from a diverse range of semantic features. The proposed majority voting strategy aggregates the predictions of individual models and determines the final sentiment class based on the most frequent output. In case of a tie, the model with the highest validation accuracy takes precedence. This strategy effectively combines the complementary capabilities of multiple GCN variants, leading to improved performance and stability across diverse datasets. Experimental results show that the proposed ensemble method significantly outperforms both baseline models and recent state-of-the-art methods. On the Rest14 dataset, the ensemble achieved an accuracy of 88.47%, improving upon the best recent model (SAGCN + BERT) by +1.34%. On the Laptops dataset, it attained 85.44%, exceeding SAGCN's 85.12% by +0.32%. Similarly, on the Twitter dataset, our model reached 82.12%, surpassing SAGCN's 81.45% by +0.67%. Additionally, compared to individual baseline models, the proposed method improved accuracy by 2.15% and F1-score by 2.8% on Rest14, 9.2% and 11.74% on Laptops, and 7.8% and 8.7% on Twitter, respectively. These improvements highlight the robustness of the ensemble in handling varying linguistic structures and domains. We also explored alternative ensemble strategies including weighted voting, neural fusion, and combined embedding approaches, yet none outperformed the majority voting strategy in consistency or accuracy. This further reinforces the effectiveness and simplicity of our proposed method. In conclusion, this research introduces a novel and practical ensemble technique for ABSA using multiple GCN models and a majority voting strategy. The method achieves state-of-the-art accuracy across multiple benchmarks and demonstrates strong generalization, making it a valuable contribution to aspect-level sentiment analysis. Future work may extend this approach to multilingual and domain-specific contexts or integrate large pretrained language models such as RoBERTa or GPT to further enhance contextual understanding.

Keywords: Natural Language Processing, Deep Learning, Graph Neural Networks, Aspect Level Sentiment Analysis, Ensemble Learning.

در متن مورد بحث قرار می‌گیرند. به تازگی شبکه‌های عصبی گراف^۵ به دلیل توانایی در استخراج روابط پیچیده بین واژه‌ها و عبارات در متن، به عنوان ابزاری قدرتمند برای تحلیل احساسات سطح جنبه به کار رفته‌اند [۴، ۵].

روش‌های کلاسیک هوش مصنوعی استفاده شده برای تحلیل احساسات سطح جنبه، بیشتر بر رویکردهای دست‌ساز^۶ و دسته‌بندی‌کننده‌های^۷ کم‌عمق مانند شبکه عصبی چندلایه پرسپترون^۸ و ماشین بردار پشتیبان^۹ تکیه می‌کنند که توانایی محدودی برای گرفتن پیچیدگی زبان طبیعی دارند [۶]. شبکه‌های عصبی گراف (GCN) نوعی از الگوریتم یادگیری عمیق بر پایه ساختار گراف و قادر به یادگیری روابط بین واژه‌ها و عبارات در یک جمله هستند. این شبکه‌ها با ساخت گراف اولیه بر روی هر جمله، از اطلاعات ساختار دستوری و نحوی زبان برای بهبود دقت تجزیه و تحلیل احساسات و همچنین استخراج روابط بین واژگان استفاده می‌کنند [۷].

رویکردهای موجود برای تجزیه و تحلیل احساسات بیشتر بر ویژگی‌های دست‌ساز و روش‌های سنتی یادگیری ماشین تکیه می‌کنند که دارای دقت کمتری بوده و توسعه و نگهداری آن‌ها می‌تواند زمان‌بر و پرهزینه باشد. GCN ها

۱- مقدمه

تحلیل احساسات، زیرشاخه‌ای از پردازش زبان طبیعی^۱ است که برای شناسایی و استخراج احساسات نظرات در داده‌های متنی از الگوریتم‌های هوش مصنوعی استفاده می‌کند. هدف این الگوریتم‌ها این است که مشخص شود نویسنده متن، در حال ابراز احساسات مثبت، منفی و یا خنثی نسبت به موضوع، محصول، خدمات و یا رویداد خاصی است. تحلیل احساسات برای طبقه‌بندی خودکار داده‌های متنی بر اساس لحن احساسی آن‌ها استفاده می‌شود و می‌تواند در زمینه‌های مختلفی مانند بازاریابی، خدمات مشتریان و نظارت بر رسانه‌های اجتماعی استفاده شود [۱]. تحلیل احساسات مبتنی بر جنبه^۲ یک زیرشاخه با جزئیات دقیق از تحلیل احساسات است که بر شناسایی و طبقه‌بندی نظرات و احساسات ابراز شده نسبت به جنبه‌های خاص یک موجودیت، مانند ویژگی‌های یک محصول، خدمات ارائه شده یک مکان مانند رستوران تمرکز دارد [۲، ۳].

روش‌های یادگیری ماشین^۳ و یادگیری عمیق^۴ به طور گسترده برای تجزیه و تحلیل احساسات مورد استفاده قرار گرفته‌اند که در درک احساسات هر جنبه و طبقه‌بندی آن‌ها عملکرد خوبی نداشته‌اند [۳، ۴]. شناسایی جنبه مستلزم توانایی تشخیص و دسته‌بندی ویژگی‌های مختلفی است که

⁵ Graph Neural Networks (GNN)

⁶ Lexicon-based approach

⁷ Classifier

⁸ Multilayer Perceptron

⁹ Support Vector Machine

¹ Natural Language Processing (NLP)

² Aspect-Based Sentiment Analysis (ABSA)

³ Machine Learning

⁴ Deep Learning

حافظه طولانی کوتاه‌مدت دوجهته^۲ برای یادگیری بازنمایی ویژگی‌های یک جمله استفاده می‌کند. از یک GCN برای مدل‌سازی ساختار یک جمله از طریق درخت وابستگی آن استفاده می‌شود. رویکرد پیشنهادی هم اطلاعات زمینه‌ای و هم اطلاعات وابستگی را از واژگان نظری به واژگان جنبه‌ای منتشر می‌کند. استفاده از درخت وابستگی همراه با حافظه طولانی کوتاه‌مدت دوجهته به مدل اجازه می‌دهد تا اطلاعات متنی بین واژگان متوالی را درک کنند.

در مقاله [۱۰] پژوهش‌گران چهارچوبی جدید بر پایه توجه به نام (TD-GAT)^۳ ارائه می‌دهند که از ساختار نحوی یک جمله برای طبقه‌بندی احساسات سطح جنبه استفاده می‌کند؛ برخلاف روش‌های پیشین، این مقاله یک جمله را به‌عنوان یک گراف وابستگی به‌جای دنباله‌ای از واژگان نشان می‌دهد؛ همچنین از شبکه توجه گراف (Graph Attention Network - GAT) چندلایه برای انتشار ویژگی‌های احساسی از واژگان مهم در گراف همسایگی نحوی برای رسیدن به هدف جنبه‌ها استفاده شده‌است. در ادامه از یک لایه شبکه عصبی حافظه طولانی کوتاه‌مدت^۴ در معماری TDGAT استفاده شده‌است تا آشکارا اطلاعات مربوط به جنبه را در لایه‌های مختلف در طول گسترش همسایگی بازگشتی ضبط کنند. در مقاله [۱۱] نویسندگان یک GCN بر روی درخت وابستگی یک جمله برای بهره‌برداری از اطلاعات نحوی و وابستگی‌های واژه را ایجاد می‌کنند. در این پژوهش از یک سازوکار پوشاندن برای پالایه‌کردن واژگان غیرجنبه و حفظ ویژگی‌های خاص جنبه استفاده می‌شود.

نویسندگان در مقاله [۱۲] معماری را پیشنهاد می‌دهند که عملیات کانولوشن را بر روی گراف‌های نحوی و واژگان سلسله‌مراتبی انجام می‌دهد. این مدل از یک گراف واژگانی جهانی برای گرفتن اطلاعات هم‌زمانی واژه در سطح پیکره استفاده می‌کند. گراف واژگانی سراسری بازنمایی از نحوه به‌هم‌پیوستگی واژگان در مجموعه آموزشی است و درک وسیع‌تری از روابط واژگان فراتر از جملات فردی ارائه می‌دهد. این اطلاعات به‌عنوان بخشی از معماری پیشنهادی برای طبقه‌بندی احساسات سطح جنبه استفاده می‌شود؛ علاوه‌براین، یک سلسله‌مراتب مفهومی بر روی گراف‌های نحوی و واژگانی ایجاد می‌شود تا انواع مختلف روابط وابستگی یا روابط هم‌روی واژه را متمایز کند. هدف این مدل ارائه درک جامع‌تری از متن و بهبود طبقه‌بندی احساسات، با ترکیب هر دو نوع اطلاعات است. در مقاله [۱۳] نویسندگان مدل جدیدی به نام Inter-GCN^۵ پیشنهاد می‌کنند که به‌طور مشترک روابط جنبه‌محور و بین جنبه‌ای را با استفاده از GCN یاد می‌گیرد؛ نخست یک گراف وابستگی معمولی برای

به‌طور خاص می‌توانند بازنمایی^۱های (جاسازی‌ها) پیچیده‌تر و انتزاعی‌تری از احساسات را بیاموزند و می‌توانند در مجموعه داده‌های بزرگ و متنوع برای بهبود دقت و استحکام سامانه‌های تجزیه و تحلیل احساسات اعمال شوند. انجام پژوهش‌ها در تجزیه و تحلیل احساسات با استفاده از GCN و الگوریتم‌های زیرمجموعه آن می‌تواند به پیشرفت‌های قابل توجهی در درک احساسات انسانی، توسعه سامانه‌های تحلیل احساسات مؤثرتر و بهبود کیفیت تعامل انسان و ماشین در حوزه‌های مختلف منجر شود [۸]. تاکنون از فرایند رأی‌گیری بین نتایج مدل‌های مبتنی بر GCN در حوزه تحلیل احساسات سطح جنبه کاری ارائه نشده‌است.

سؤال اصلی این پژوهش این است که آیا ترکیب پیش‌بینی‌های مدل‌های GCN با استفاده از رأی‌گیری پیشینه می‌تواند دقت تحلیل احساسات سطح جنبه را بهبود دهد؟ فرضیه پژوهش حاضر این است که این رویکرد با بهره‌گیری از اجماع جمعی، خطاهای مدل‌های فردی را کاهش داده و عملکرد بهتری نسبت به روش‌های موجود ارائه می‌دهد.

با توجه به اینکه تاکنون استفاده از فرایند رأی‌گیری پیشینه برای ترکیب نتایج مدل‌های مبتنی بر GCN در تحلیل احساسات سطح جنبه بررسی نشده‌است؛ در این پژوهش، یک رویکرد نوآورانه پیشنهاد می‌شود که با بهره‌گیری از یادگیری جمعی و رأی‌گیری پیشینه، پیش‌بینی‌های چهار مدل پیشرفته GCN (شامل DualGCN، RDGCN، SSEGCN و R-GAT) را ترکیب می‌کند. این روش با تجمع نقاط قوت مدل‌های مختلف، دقت و استحکام تحلیل احساسات را در مجموعه داده‌های معیار بهبود قابل توجهی می‌دهد و گامی نو در این حوزه به‌شمار می‌رود.

این مقاله در بخش دوم به مرور کارهای گذشته، در بخش سوم به معرفی مجموعه داده‌ها، در بخش چهارم به تشریح روش پیشنهادی، در بخش پنجم به ارائه نتایج و در نهایت در بخش ششم به نتیجه‌گیری و ارائه پیشنهاد می‌پردازد.

۲- کارهای گذشته

در طول دهه گذشته ادغام GCN، نوآوری قابل توجهی را در حوزه NLP به‌وجود آورده‌است. این قسمت یک بررسی و تحلیل جامع از پژوهش‌های پیشین و تلاش‌های پژوهشی اختصاص داده‌شده به استفاده از قدرت GCN برای وظایف تحلیل احساسات سطح جنبه، از سال ۲۰۱۹ تا ۲۰۲۴ را ارائه می‌دهد. نویسندگان در مقاله [۹] روش جدیدی را برای تحلیل احساسات بر اساس درختان وابستگی پیشنهاد کردند. این رویکرد مبتنی بر یک شبکه عصبی است که از الگوریتم

^۱ Embedding

^۲ Bidirectional Long Short-Term Memory (Bi-LSTM)

^۳ Target-dependent Graph attention Network (TD-GAT)

^۴ Long Short-Term Memory (LSTM)

^۵ Inter-Aspect Relation Graph Convolutional Network (Inter-GCN)

هر جمله روی درخت وابستگی ساخته می‌شود؛ سپس گراف با در نظر گرفتن وابستگی‌های نحوی بین واژگان متنی و واژگان خاص جنبه اصلاح می‌شود تا نمودار متمرکز بر جنبه به دست آید.

در مقاله [۱۴] نویسندگان به این نتیجه رسیده‌اند که رویکردهای موجود برای تحلیل احساسات مبتنی بر جنبه، روابط پیچیده بین جنبه‌ها و نظرات را کامل نشان نمی‌دهند. آن‌ها رویکردی جدید برای تحلیل احساسات مبتنی بر جنبه با استفاده از GCN دوگانه (DualGCN) را پیشنهاد می‌کنند که ساختارهای نحوی و روابط معنایی را هم‌زمان در نظر می‌گیرد. برای پرداختن به این موضوع، یک ساختار گراف دوگانه، متشکل از یک گراف جنبه و یک گراف نظر معرفی می‌شود تا روابط بین جنبه‌ها و نظرات را جداگانه مدل‌سازی کنند. پیش‌بینی احساسات نهایی با تجمیع ویژگی‌های جنبه و نظر، با استفاده از سازوکارهای توجه به دست می‌آید. در مقاله [۱۵] نویسندگان از روش رمزگذاری اطلاعات نحوی استفاده کرده‌اند. درخت وابستگی جنبه‌محور در سه مرحله ساخته می‌شود؛ ابتدا درخت وابستگی یک جمله با استفاده از تجزیه‌کننده معمولی ساخته می‌شود؛ سپس، درخت وابستگی را تغییر شکل داده تا ریشه آن در یک جنبه هدف مورد نظر باشد؛ در نهایت، هرس درخت تنها برای حفظ لبه‌هایی با روابط وابستگی مستقیم با جنبه انجام می‌شود. چنین ساختار درختی یک پارچه مدل را قادر می‌سازد تا بر ارتباطات بین جنبه‌ها و واژگان نظر تمرکز کند. از یک شبکه توجه گراف رابطه‌ای (R-GAT)^۱ برای رمزگذاری ساختار درختی جدید در شناسایی قطبیت احساسات جنبه پیشنهاد شده‌است.

در مقاله [۱۶] روشی به نام (SSEGCN)^۲ پیاده‌سازی شد که هدف آن ادغام اطلاعات نحوی و معنایی با استفاده از سازوکارهای جدید است. SSEGCN از یک سازوکار توجه آگاه از جنبه^۳ و ماتریس‌های ماسک نحوی^۴ برای تقویت GCN استفاده می‌کند؛ ابتدا، با استفاده از رمزگذار جملات، بازنمایی‌های متنی واژه را تشکیل داده و سپس، مکانیسم توجه آگاهانه همراه با توجه به خود را ایجاد می‌کند. توجه آگاه به جنبه بر یادگیری اطلاعات معنایی مرتبط با جنبه متمرکز است که شامل اختصاص وزن‌های مختلف توجه به واژگان در جمله بر اساس ارتباط آن‌ها با اصطلاح جنبه است. مدل یاد می‌گیرد واژگانی را شناسایی و اولویت‌بندی کند که بیشترین کمک را به احساسات بیان‌شده نسبت به جنبه داده‌شده دارند. نویسندگان در مقاله [۱۷] استفاده کامل از اطلاعات نحوی ارائه‌شده به وسیله درختان وابستگی را با استفاده از روشی به نام

شبکه توجه گراف آگاه از نحو (BiSyn-GAT+)^۵ پیشنهاد می‌کنند. روش پیشنهادی به‌طور کامل از اطلاعات نحوی درخت تشکیل‌دهنده یک جمله برای مدل‌سازی بافت آگاه از احساسات هر جنبه و روابط احساسات در سراسر جنبه‌ها برای یادگیری استفاده می‌کند. بافت آگاه از احساسات هر جنبه به بافت جمله‌ای اشاره دارد که به جنبه خاص و احساس آن مربوط است.

در مقاله [۱۸] روشی به نام (RDGCN)^۶ ارائه شده‌است. این روش بر اساس یک معیار جدید برای محاسبه اهمیت وابستگی، استفاده از یادگیری تقویتی برای توابع اهمیت، معرفی مکانیزم توجه جهانی برای توابع مهم آن و ارائه یک چهارچوب جامع که به‌طور مؤثر هم فاصله و هم نحو نوع را نشان می‌دهد، طراحی شده‌است. این مدل نیاز به تعیین اهمیت هر وابستگی در تأثیرگذاری بر قطبیت احساسات دارد و به آن اجازه می‌دهد تا بر مرتبط‌ترین ارتباطات نحوی برای پیش‌بینی دقیق احساسات خاص جنبه‌ها تمرکز کند. در مقاله [۱۹] مدل جدیدی به نام (SAGCN)^۷ برای رفع برخی از کاستی‌های مدل‌های پیشین مانند استفاده نکردن کامل از اطلاعات جنبه‌های خاص در یک جمله و نادیده گرفتن ارتقای مدل به وسیله دانش عمومی خارجی از احساسات پیشنهاد شده‌است. مدل‌های تحلیل احساسات سنتی بیشتر در درک ساختارهای نحوی پیچیده و روابط بین واژگان در یک جمله شکست می‌خورند. در این روش از یک پارچه‌سازی ویژگی‌های نحوی با GCN استفاده می‌کند. ساختار و رویکرد هر کدام از مدل‌های یادشده در جدول (۱) نشان داده شده‌است.

(جدول ۱): ساختار و رویکردهای مدل‌های مبتنی بر GCN در

حوزه تحلیل احساسات مبتنی بر جنبه

(Table-1): The structure and approaches of GCN-based models in the field of aspect-based sentiment analysis

نام مدل	ساختار	نوع رویکرد
CDT [۹]	BiLSTM + GCN	فضایی
TD-GAT [۱۰]	BiLSTM + GAT	طیفی
ASGCN [۱۱]	GCN	فضایی
BiGCN [۱۲]	BiLSTM + GCN	فضایی
Inter-GCN [۱۳]	Dependency tree + BiLSTM + GCN	فضایی
DualGCN [۱۴]	Dependency tree + BiLSTM + GCN	فضایی
R-GAT [۱۵]	BiLSTM + GAT	طیفی
SSEGCN [۱۶]	BiLSTM + GCN	فضایی
BiSyn-GAT+	Dependency tree + BiLSTM + GAT	طیفی
RDGCN [۱۸]	Dependency tree + Reinforcement learning + GCN	فضایی
SAGCN [۱۹]	Dependency tree + BiLSTM + PCT + GCN	فضایی

^۵ Bi-Syntax aware Graph Attention Network (BiSyn-GAT+)

^۶ Reinforced Dependency Graph Convolutional Network (RDGCN)

^۷ Syntax-Aware and Graph Convolutional Network (SAGCN)

^۱ Relational Graph Attention network (R-GAT)

^۲ Syntactic and Semantic Enhanced Graph Convolutional Network (SSEGCN)

^۳ Aspect-aware Attention Mechanism

^۴ Syntactic Mask Matrices

(جدول-۲): تعداد توزیع قطبیت داده‌های آموزشی و آزمایشی در

هر مجموعه داده

(Table-2): The number of polarity distributions of training and test data in each dataset

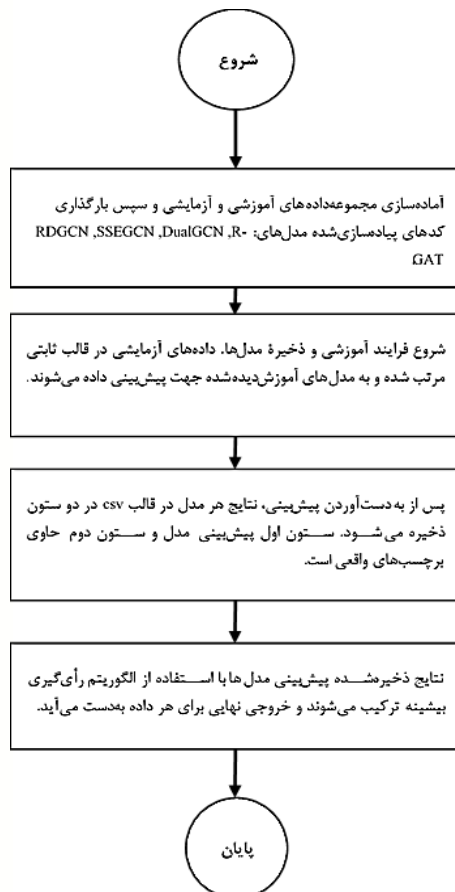
مجموعه داده	بخش	مثبت	منفی	خنثی
رستوران	آموزش	۲۱۶۴	۸۰۷	۶۳۷
	آزمایش	۷۲۷	۱۹۶	۱۹۶
لپ‌تاپ	آموزش	۹۷۶	۸۵۱	۴۵۵
	آزمایش	۳۳۷	۱۲۸	۱۶۷
تویتر	آموزش	۱۵۰۷	۱۵۲۸	۳۰۱۶
	آزمایش	۱۷۲	۱۶۹	۳۳۶

(جدول-۳): چند نمونه موجود در مجموعه داده به همراه جنبه و

قطبیت آن‌ها

(Table-3): Some examples in the dataset, along with their aspect and polarity

مجموعه داده	متن	جنبه‌ها	قطبیت
رستوران	غذا عالی بود اما سرویس دهی کند بود	غذا سرویس	غذا (مثبت) سرویس (منفی)
لپ‌تاپ	عمر باتری شگفت‌انگیز است	عمر باتری	مثبت
تویتر	عاشق آپدیت جدیدم	آپدیت	مثبت



(شکل-۲): روندنمای روش پیشنهادی

(Figure-2): Flowchart of the proposed method

۴- روش پیشنهادی

رأی‌گیری یک مفهوم اساسی در حوزه‌های مختلف مانند فرایندهای دموکراتیک در حکومت گرفته تا کاربرد آن در


با وجود پیشرفت‌های اخیر در استفاده از GCN برای تحلیل احساسات سطح جنبه، سه خلأ اصلی در پژوهش‌های گذشته مشاهده می‌شود: (۱) وابستگی بیش از حد به عملکرد یک مدل خاص که در داده‌های متنوع ناپایدار است؛ (۲) عدم استفاده از رویکردهای یادگیری جمعی برای ترکیب مدل‌ها و (۳) پیچیدگی محاسباتی روش‌های ترکیبی موجود. پژوهش حاضر با معرفی رأی‌گیری پیشینه برای ترکیب چهار مدل GCN، این محدودیت‌ها را برطرف کرده و با افزایش دقت و سادگی، اهمیت خود را در ارائه راه‌حلی کارآمد و قابل تعمیم نشان می‌دهد.

۳- مجموعه داده

در این پژوهش از دو مجموعه داده SemEval2014 و Tوییتر استفاده شده است [۲۰، ۲۱]. مجموعه داده SemEval2014 شامل دو فایل به نام Rest14 و لپ‌تاپ است که هر کدام حاوی اطلاعات نظرات و جنبه‌ها به همراه احساسات مرتبط با خود در حوزه‌های گفته شده است. مجموعه داده به گونه‌ای ساختار یافته است که هر ورودی شامل یک متن نظر، اصطلاحات جنبه‌ای که در نظرات یافت شده‌اند و احساسات مرتبط با هر عبارت جنبه است. مجموعه داده Tوییتر نیز به دلیل زبان غیررسمی و وجود واژگان عامیانه و اختصارات، آزمون چالش برانگیزتری را برای پژوهش در حوزه تحلیل احساسات سطح جنبه ارائه می‌کند. هر توییت در مجموعه داده با یک یا چند عبارت جنبه مرتبط است و هر عبارت جنبه دارای یک برچسب احساس است. توزیع داده‌ها شامل تعداد نمونه‌های آموزشی و آزمایشی قطبیت احساسات جنبه‌ها (مثبت، منفی و خنثی) برای هر مجموعه داده است. این توزیع به صورت کلی در شکل (۱) آورده شده و جزئیات آن در جدول (۲) نشان داده شده است.

(شکل-۱): توزیع کلی مجموعه داده‌های مورد استفاده

(Figure-1): General distribution of the used datasets



در جدول (۳) از هر مجموعه داده مورد استفاده در این پژوهش، یک مثال به همراه جنبه و قطبیت آن نشان داده شده است؛ برای مثال در مجموعه داده Rest14 جمله «غذا عالی بود اما خدمات دهی کند بود» نشان‌دهنده قطبیت مثبت برای جنبه کیفیت غذا و قطبیت منفی برای جنبه خدمات دهی است.

پیش‌بینی را کاهش داده و دقت کلی را افزایش می‌دهد. در شکل (۲) روندنمای روش پیشنهادی به همراه توضیحات آن رسم شده‌است.

۴-۱- پیش‌پردازش داده‌ها

در این پژوهش، برای آماده‌سازی مجموعه‌داده‌های SemEval2014 (شامل Rest14 و Laptops) و Twitter جهت استفاده در مدل‌های پیشنهادی، ابتدا فرایند پیش‌پردازش انجام شد؛ از آنجا که هر مدل به فرمت خاصی از داده‌ها نیاز داشت و داده‌های آزمایشی در برخی موارد (مانند SSEGCN) به‌صورت درهم‌ریخته ارائه شده بود، یک الگوریتم در محیط پایتون پیاده‌سازی شد تا داده‌ها به یک فرمت استاندارد و یکسان تبدیل شوند. این الگوریتم شامل مراحل زیر بود: (۱) حذف نوفه‌های متنی مانند کاراکترهای غیرضروری و فاصله‌های اضافی؛ (۲) تبدیل داده‌ها به ساختاری شامل متن، جنبه و برچسب احساسات، و (۳) یکسان‌سازی ترتیب و فرمت داده‌های آموزشی و آزمایشی برای تمامی مدل‌ها. این پیش‌پردازش تضمین کرد که مقایسه بین مدل‌ها منصفانه و قابل اعتماد باشد.

۴-۲- مدل‌های پایه استفاده‌شده

روش پیشنهادی این پژوهش بر ترکیب پیش‌بینی‌های چهار مدل پیشرفته مبتنی بر شبکه‌های عصبی گراف (GCN) استوار است که هر یک به‌طور مستقل برای تحلیل احساسات سطح جنبه طراحی شده‌اند. این مدل‌ها شامل DualGCN، RDGCN، SSEGCN و R-GAT هستند که در ادامه معرفی می‌شوند:

DualGCN: این مدل [۱۴] از دو گراف موازی (گراف جنبه و گراف نظر) برای مدل‌سازی روابط نحوی و معنایی بین جنبه‌ها و نظرات استفاده می‌کند. ترکیب این دو گراف با سازوکار توجه، دقت پیش‌بینی احساسات را افزایش می‌دهد.

RDGCN: این مدل [۱۸] با استفاده از یادگیری تقویتی و مکانیزم توجه جهانی، اهمیت وابستگی‌های نحوی را محاسبه کرده و بر روابط مرتبط با جنبه‌ها تمرکز می‌کند. این ویژگی آن را برای داده‌های پیچیده مناسب می‌سازد.

SSEGCN: این مدل [۱۶] اطلاعات نحوی و معنایی را با سازوکار توجه آگاه از جنبه و ماتریس‌های ماسک نحوی ترکیب می‌کند. این ساختار به شناسایی واژگان کلیدی مرتبط با جنبه‌ها کمک می‌کند.

R-GAT: این مدل [۱۵] از شبکه توجه گراف رابطه‌ای برای رمزگذاری درخت وابستگی جنبه‌محور استفاده می‌کند و با تمرکز بر روابط مستقیم جنبه‌ها، قطبیت احساسات را پیش‌بینی می‌کند. این مدل‌ها به‌دلیل توانایی بالای در مدل‌سازی روابط پیچیده در داده‌های متنی و عملکرد برجسته در پژوهش‌های اخیر انتخاب شدند.

یادگیری ماشین و سامانه‌های توصیه‌گر است. رأی‌گیری شامل انتخاب یا تجمیع ترجیحات، نظرات یا تصمیمات گروهی از افراد یا نهادها است که هدف آن رسیدن به یک تصمیم قطعی یا تعیین محبوب‌ترین انتخاب در میان مجموعه‌ای از گزینه‌ها است. در زمینه یادگیری ماشین، رأی‌گیری روشی است که در زمینه یادگیری جمعی^۱ از آن استفاده می‌شود و در آن چندین مدل جداگانه برای پیش‌بینی یا تصمیم‌گیری ترکیب می‌شوند. روش‌های رأی‌گیری انواع مختلفی دارد که شامل رأی‌گیری بیشینه^۲ (رأی‌گیری سخت)^۳، رأی‌گیری وزنی^۴ و رأی‌گیری نرم^۵ است؛ ازجمله مزایای این روش می‌توان به کاهش مشکل بیش‌ازحد برازش، بهبود دقت و مدیریت مجموعه‌داده‌های متنوع و پیچیده اشاره کرد. رویکرد پیشنهادی برای تحلیل احساسات سطح جنبه از قدرت مدل‌های GCN از طریق سازوکار رأی‌گیری استفاده می‌کند. هدف این رویکرد، افزایش دقت پیش‌بینی‌های احساسات با جمع‌آوری بینش‌های چهار مدل آموزش‌دیده بر روی مجموعه‌داده‌های مختلف به نام‌های RDGCN، SSEGCN، R-GAT و Dual-GCN است.

هر یک از این مدل‌ها به‌طور مستقل بر روی مجموعه‌داده‌های SemEval2014 و تویتر آموزش دیده و از جدیدترین و بهترین مدل‌های اخیر مورد استفاده در این حوزه‌اند [۲۰، ۲۱]. فرایند یک‌پارچه‌سازی شامل جمع‌آوری مجموعه‌داده‌ها در یک قالب ثابت و ترکیب پیش‌بینی‌های این مدل‌ها است؛ همچنین هر مدل دارای دو فایل خروجی است، یک فایل برای جاسازی‌های GLoVe و فایل دیگر برای جاسازی‌های BERT. هسته روش پیشنهادی، استفاده از سازوکار رأی‌گیری بیشینه برای ترکیب پیش‌بینی‌های چهار مدل پیشرفته GCN (DualGCN، RDGCN، SSEGCN و R-GAT) است. منظور از «چهار مدل»، مجموعه‌ای از مدل‌های مستقل است که هر یک به‌طور جداگانه آموزش دیده‌اند و پیش‌بینی‌هایشان در یک فرایند جمعی ادغام می‌شود. برای هر داده ورودی، هر مدل به‌طور مستقل آن را تجزیه و تحلیل می‌کند و یک پیش‌بینی احساسات برای هر جنبه تولید؛ سپس این پیش‌بینی‌ها جمع‌آوری و پیش‌بینی احساسات نهایی با گرفتن احساساتی که به‌وسیله بیشتر مدل‌ها پیش‌بینی می‌شود، تعیین خواهند شد.

استفاده از رأی‌گیری بیشینه در این پژوهش، یک نوآوری کلیدی است که برای نخستین‌بار در حوزه تحلیل احساسات سطح جنبه با مدل‌های GCN پیاده‌سازی شده‌است. این رویکرد با کاهش وابستگی به عملکرد یک مدل خاص و بهره‌گیری از اجماع جمعی، خطاهای

¹ Ensemble Learning

² Majority Voting

³ Hard Voting

⁴ Weighted Voting

⁵ Soft Voting

۴-۳- فرایند رأی‌گیری پیشینه

هسته روش پیشنهادی، استفاده از سازوکار رأی‌گیری پیشینه برای ترکیب پیش‌بینی‌های چهار مدل ذکر شده است. در این فرایند، هر مدل به‌طور مستقل داده ورودی (شامل متن و جنبه هدف) را تحلیل کرده و یک برچسب احساسات (مثبت، منفی یا خنثی) تولید می‌کند؛ سپس، پیش‌بینی‌های چهار مدل برای هر نمونه جمع‌آوری شده و برچسب نهایی بر اساس پیشینه آرا تعیین می‌شود؛ برای مثال، اگر سه مدل از چهار مدل برچسب «مثبت» را پیش‌بینی کنند، برچسب نهایی «مثبت» خواهد بود. در مواردی که آرا برابر باشند (برای مثال دو مدل مثبت و دو مدل منفی)، برچسب با اولویت مدل با بالاترین دقت روی داده‌های آموزشی انتخاب می‌شود. این رویکرد با جمع‌بندی دیدگاه‌های متنوع مدل‌ها، استحکام و دقت پیش‌بینی را افزایش می‌دهد.

۴-۴- شبیه‌سازی و چالش‌ها

شبیه‌سازی‌ها بر روی یک پیکربندی سخت‌افزاری با مشخصات پردازنده نسل یازدهم Core i7 اینتل، کارت گرافیک Tesla K80، ۲۴ GB رم و حافظه ۲T SSD NVME انجام شده‌است؛ پس از به‌دست‌آوردن کدهای پیاده‌سازی‌شده مدل‌ها از مخازن مربوطه GitHub، فرایند اولیه شامل اجرای کدها با پارامترهای پیش‌فرض آن‌ها است. به‌جز مدل RDGCN سایر مدل‌ها نیاز به به‌روزرسانی کتابخانه و ابزار پیاده‌سازی‌شده برای اجرای صحیح کدها داشتند. در مجموعه داده‌های انتخابی چالش‌هایی مانند داده‌های آزمایشی به‌هم‌ریخته و قالب‌بندی متفاوت در بین مدل‌ها برای ایجاد یک پایه استاندارد برای ارزیابی منسجم مورد بررسی قرار گرفت و در نهایت یک ساختار کلی برای فرایند رأی‌گیری انتخاب شد؛ برای مثال مدل SSEGNCN یک ساختار خاص برای درهم ریخته‌کردن داده‌ها را ارائه داده‌اند که چینه داده‌های آموزشی و آزمایشی را کامل تغییر می‌داد. برای اجرای فرایند رأی‌گیری باید تمامی داده‌های آزمایشی یک فرمت و چینه واحد داشته باشند؛ به این منظور در محیط پایتون برای یکسان‌سازی داده‌ها، الگوریتمی پیاده‌سازی شد که شبه‌کد زیر مراحل آن را نشان می‌دهد:

Algorithm: Data Standardization
Input: Raw_Dataset (Rest14, Laptops, Twitter)
Output: Standardized_Dataset
SART
1. For each sample in Raw_Dataset:
a. Remove noise (special characters, extra spaces)
b. Extract text, aspect, sentiment_label
c. Format into unified structure: {text, aspect, label}
2. Align training and test sets across all models
3. Return Standardized_Dataset
END

این الگوریتم تضمین می‌کند که داده‌ها برای تمامی مدل‌ها قابل‌استفاده باشند. هر مدل با توجه به معماری و پارامترهای پیش‌فرض خود تحت فرایند آموزش به‌صورت جدا قرار گرفت. برای دریافت تفاوت‌های ظریف زبانی مختلف، هر مدل با استفاده از دو جاسازی واژه متمایز GloVe و BERT تحت آموزش قرار گرفت. این استراتژی آموزشی دوگانه با هدف افزایش توانایی مدل‌ها برای تشخیص احساسات در زمینه‌های مختلف انجام شد. هم‌گرایی این تعبیه‌ها درک جامع‌تری از الگوهای احساسات در داده‌ها ارائه می‌کنند. تاکنون در پژوهش‌های صورت‌گرفته و نتیجه‌گیری از این دو رویکرد تعبیه برای ارزیابی مدل‌ها استفاده شده‌است. پس از آموزش، نتایج تجزیه و تحلیل احساسات برای هر مدل، با در نظر گرفتن هر دو جاسازی GloVe و BERT ذخیره شد؛ سپس این نتایج در یک فایل CSV ادغام شدند. این ادغام به‌عنوان مبنایی برای اعمال فرایند رأی‌گیری پیشینه عمل می‌کند. ماهیت فرایند رأی‌گیری پیشینه در تجمیع پیش‌بینی‌های احساسات هر چهار مدل نهفته است. با در نظر گرفتن بینش‌های جمعی حاصل از معماری‌ها و روش‌های آموزشی متنوع، فرایند رأی‌گیری پیشینه با هدف افزایش استحکام و قابلیت اطمینان نتایج تحلیل احساسات انجام شد که در ارزیابی به دقت بالاتری نسبت به آخرین روش‌های پیاده‌سازی‌شده تاکنون دست یافت.

۴-۵- مؤلفه‌های مدل

برای اجرای مدل‌ها، مؤلفه‌های اصلی هر یک بر اساس تنظیمات پیشنهادی در مقالات اصلی یا بهینه‌سازی روی داده‌های آموزشی تعیین شدند. جدول (۴) جزئیات این مؤلفه‌ها را نشان می‌دهد.

(جدول ۴): مؤلفه‌های استفاده‌شده در مدل‌های پایه

(Table-4): Parameters used in the basic models

نام مدل	نرخ یادگیری	تعداد لایه‌ها	اندازه جاسازی	بهینه‌ساز
DualGCN [۱۴]	۰.۰۰۱	۲	۳۰۰	Adam
RDGCN [۱۸]	۰.۰۰۲	۳	۳۰۰	Adam
SSEGNCN [۱۶]	۰.۰۰۱	۲	۳۰۰	Adam
R-GAT [۱۵]	۰.۰۰۱	۲	۳۰۰	Adam

۴-۶- دیگر روش‌های امتحان‌شده

علاوه بر روش اصلی (رأی‌گیری پیشینه)، ایده‌های بنیادی مختلفی برای تقویت فرایند تحلیل احساسات سطح جنبه با فرایند رأی‌گیری در نظر گرفته شد. یکی از مفاهیم اولیه مورد بررسی، استفاده از فرایند رأی‌گیری وزنی بود. در این روش، به هر مدل بر اساس دقت آن روی داده‌های آموزشی وزنی اختصاص یافت؛ برای مثال، وزن‌ها به‌صورت

نسبی و بر اساس عملکرد مدل‌ها روی یک زیرمجموعه اعتبارسنجی تعیین شدند؛ با این حال، این روش به دلیل پیچیدگی محاسباتی بیشتر و عدم بهبود قابل توجه در دقت (به دلیل نزدیک بودن عملکرد مدل‌ها به یکدیگر) کنار گذاشته شد و رأی‌گیری بیشینه به عنوان روش اصلی انتخاب شد. ایده دیگر شامل ادغام شبکه‌های عصبی در خط لوله^۱ تجزیه و تحلیل احساسات است. در این رویکرد، خروجی‌های چهار مدل به عنوان ورودی به یک شبکه عصبی چندلایه با معماری ساده شامل دو لایه مخفی (هر یک با ۱۲۸ و ۶۴ نورون) و تابع فعال‌سازی ReLU وارد شد. لایه خروجی با سه نورون (برای مثبت، منفی، خنثی) و تابع Softmax طراحی شد؛ در نهایت، این روش نسبت به فرایند رأی‌گیری بیشینه در جاسازی‌های GLoVE و BERT در تمامی مجموعه داده‌ها پیشرفت چشم‌گیری به همراه نداشت. رویکرد دیگر استفاده از ترکیب جاسازی‌های GLoVE و BERT است. خروجی‌های مدل‌هایی که جداگانه روی GLoVE و BERT آموزش داده شده‌اند ادغام شدند و در مجموع هشت مدل به وجود آمد، اما مشاهده شد که مدل‌های آموزش دیده شده بر روی جاسازی‌های GLoVE تأثیر ضعیف‌تری بر خروجی نهایی داشت. این مشاهدات از این واقعیت ناشی می‌شود که در فرایند رأی‌گیری بیشینه، تأثیر هر مدل به طور مساوی امتیاز داده می‌شود. در جدول (۵) در بخش نتایج، نتایج تمام ایده‌های امتحان شده به همراه جاسازی‌های مختلف نشان داده شده است. در این جدول از معیارهای F1-Score و دقت استفاده شده است. نتایج مدل‌های برتر در هر معیار برجسته شده‌اند.

۵- نتایج

در جدول (۶) نتایج روش‌های پیاده‌سازی شده به همراه نتیجه رأی‌گیری بیشینه بر روی جاسازی‌های GLoVE و BERT نشان داده شده است؛ بر اساس این جدول، مدل پیشنهادی این پژوهش در تمامی موارد عملکردی بهتر نسبت به آخرین روش‌های انجام شده در این حوزه تاکنون دارد. این نتایج حاکی از پیشرفت قابل توجهی در تحلیل احساسات سطح جنبه است و پتانسیل مدل پیشنهادی را برای عملکرد بهتر از روش‌های موجود را نشان می‌دهد.

همان‌طور که در جدول (۶) مشاهده می‌شود، روش پیشنهادی با استفاده از رأی‌گیری بیشینه و جاسازی BERT در تمامی مجموعه داده‌ها عملکرد بهتری نسبت به مدل‌های پایه و روش SAGCN [۱۹] ارائه می‌دهد؛ برای مثال، در مجموعه داده Rest14، دقت روش پیشنهادی به ۸۸.۴۷٪ می‌رسد که ۰.۶۷٪ بالاتر از بهترین روش دیگر (SAGCN با BERT) است. در مجموعه داده لپ‌تاپ‌ها، بهبود دقت به

۶- نتیجه‌گیری و پیشنهادها

یافته‌های کلیدی این پژوهش، شامل اجرای موفقیت‌آمیز فرایند رأی‌گیری بیشینه، غلبه بر چندین چالش مربوط به نسخه‌های قدیمی کتابخانه‌ها در محیط پایتون و قالب‌های آموزشی و آزمایشی متفاوت در بین مدل‌ها و دستیابی به دقت بهبود یافته در پیش‌بینی احساسات است. این پژوهش نشان داده است که فرایند رأی‌گیری بیشینه می‌تواند به طور مؤثری نقاط قوت مدل‌های مختلف را برای دستیابی به عملکرد بهتر ترکیب کند. یکی از حوزه‌های پیشنهادی برای کارهای آینده، استفاده از مجموعه داده‌های جدیدتر یا متنوع‌تر اعمال مدل پیشنهادی روی مجموعه داده‌های جدید به دلیل محدودیت زمانی، دسترسی ناکافی به مجموعه داده‌های استاندارد چندزبانه و تمرکز پژوهش حاضر بر اعتبارسنجی روش روی داده‌های معیار موجود انجام نشد. برای آموزش و آزمایش، مدل‌ها می‌تواند به افزایش استحکام و قابلیت تعمیم مدل‌ها کمک کند. استفاده از مجموعه داده‌های متنوع‌تر (مانند داده‌های چندزبانه یا متون با ساختار غیررسمی‌تر) می‌تواند تعمیم‌پذیری مدل‌ها را آزمایش کند؛ همچنین، استحکام در اینجا به توانایی مدل در حفظ دقت در برابر داده‌های نوفه‌ای یا ناهم‌گون اشاره دارد. موضوع دیگر استفاده از مدل‌های زبانی بزرگ^۲ مانند GPT-4 و RoBERTa است که قابلیت‌های قابل توجهی در درک و تولید متن‌های انسان‌مانند از خود نشان داده‌اند.

این مدل‌ها بر روی حجم وسیعی از داده‌ها آموزش می‌بینند و می‌توانند الگوهای پیچیده و تفاوت‌های ظریف را در زبان ثبت کنند. با وجود موفقیت روش پیشنهادی، محدودیت‌هایی مانند پیچیدگی محاسباتی در یک پارچه‌سازی مدل‌ها و نیاز به انتخاب بهینه مدل‌های پایه همچنان وجود دارد که در پژوهش‌های آینده قابل بررسی است. این پژوهش با معرفی یک رویکرد نوآورانه مبتنی بر رأی‌گیری بیشینه برای ترکیب مدل‌های GCN، گامی مهم در بهبود تحلیل احساسات سطح جنبه برداشته است؛ برخلاف روش‌های پیشین که تنها بر یک مدل یا ترکیب‌های پیچیده‌تر تکیه داشتند، این روش با سادگی و کارایی خود، دقت را در مجموعه داده‌های Rest14، لپ‌تاپ‌ها و توییتر به ترتیب به ۸۸.۴۷٪، ۸۵.۴۴٪ و ۸۲.۱۲٪ رسانده است که از بهترین روش‌های موجود پیشی می‌گیرد.

^۲ Large Language Model (LLM)

^۱ Pipeline

(جدول-۵): نتایج اولیه دیگر روش های امتحان شده
(Table-5): Initial results of other methods tested

نام مدل	مجموعه داده					
	Rest14		لپ تاپ ها		توییت ر	
	ACC%	F1%	ACC%	F1%	ACC%	F1%
R-GAT [۱۵]	۸۳.۳۰	۷۶.۰۸	۷۷.۴۲	۷۳.۷۶	۷۵.۵۷	۷۳.۸۲
DualGCN [۱۴]	۸۴.۲۷	۷۸.۰۸	۷۸.۸۴	۷۴.۷۴	۷۵.۹۲	۷۴.۲۹
SSEGCN [۱۶]	۸۴.۷۲	۷۷.۵۱	۷۹.۴۳	۷۶.۴۹	۷۶.۵۱	۷۵.۳۲
RDGCN [۱۸]	۸۴.۳۶	۷۸.۰۶	۷۹.۵۹	۷۶.۷۵	۷۶.۶۶	۷۵.۳۷
Weighted Voting	۸۳.۸۲	۷۷.۸۵	۷۷.۶۳	۷۴.۴۷	۷۳.۷۰	۷۰.۷۸
Neural Network	۸۶.۱۶	۷۷.۴۱	۸۲.۶۷	۷۹.۵۷	۷۸.۶۷	۷۷.۶۸
R-GAT + BERT [۱۵]	۸۶.۶۰	۸۱.۳۵	۷۸.۲۱	۷۴.۰۷	۷۶.۱۵	۷۴.۸۸
DualGCN + BERT [۱۴]	۸۷.۱۳	۸۱.۱۶	۸۱.۸۰	۷۸.۱۰	۷۷.۴۰	۷۶.۰۲
SSEGCN + BERT [۱۶]	۸۷.۳۱	۸۱.۰۹	۸۱.۰۱	۷۷.۹۶	۷۷.۴۰	۷۶.۰۲
RDGCN + BERT [۱۸]	۸۷.۴۹	۸۱.۱۶	۸۲.۱۲	۷۸.۳۴	۷۸.۲۹	۷۷.۱۴
Weighted Voting + BERT	۸۶.۵۹	۸۱.۷۳	۸۰.۵۳	۷۷.۹۰	۷۶.۶۶	۷۴.۲۶
Neural Network + BERT	۸۵.۷۱	۷۶.۳۳	۸۳.۴۶	۸۰	۷۶.۴۷	۷۵.۲۰
Mix Voting	۸۷.۶۶	۸۱.۶۵	۸۵.۱۲	۸۲.۲۹	۸۰.۹۴	۸۰

(جدول-۶): نتایج رأی گیری پیشینه با روش های پیاده سازی شده
(Table-6): Majority voting results with implemented methods

نام مدل	مجموعه داده					
	Rest14		لپ تاپ ها		توییت ر	
	ACC%	F1%	ACC%	F1%	ACC%	F1%
R-GAT [۱۵]	۸۳.۳۰	۷۶.۰۸	۷۷.۴۲	۷۳.۷۶	۷۵.۵۷	۷۳.۸۲
DualGCN [۱۴]	۸۴.۲۷	۷۸.۰۸	۷۸.۸۴	۷۴.۷۴	۷۵.۹۲	۷۴.۲۹
SSEGCN [۱۶]	۸۴.۷۲	۷۷.۵۱	۷۹.۴۳	۷۶.۴۹	۷۶.۵۱	۷۵.۳۲
RDGCN [۱۸]	۸۴.۳۶	۷۸.۰۶	۷۹.۵۹	۷۶.۷۵	۷۶.۶۶	۷۵.۳۷
SAGCN [۱۹]	۸۵.۱۰	۷۸.۵۰	۸۰.۲۰	۷۷.۱۰	۷۶.۸۰	۷۵.۶۲
Majority Voting	۸۵.۹۶	۷۹.۸۸	۸۲.۴۳	۷۹.۳۳	۸۰.۷۹	۷۹.۸۴
R-GAT + BERT [۱۵]	۸۶.۶۰	۸۱.۳۵	۷۸.۲۱	۷۴.۰۷	۷۶.۱۵	۷۴.۸۸
DualGCN + BERT [۱۴]	۸۷.۱۳	۸۱.۱۶	۸۱.۸۰	۷۸.۱۰	۷۷.۴۰	۷۶.۰۲
SSEGCN + BERT [۱۶]	۸۷.۳۱	۸۱.۰۹	۸۱.۰۱	۷۷.۹۶	۷۷.۴۰	۷۶.۰۲
RDGCN + BERT [۱۸]	۸۷.۴۹	۸۱.۱۶	۸۲.۱۲	۷۸.۳۴	۷۸.۲۹	۷۷.۱۴
SAGCN + BERT [۱۹]	۸۷.۸۰	۸۱.۷۰	۸۲.۵۰	۷۸.۹۰	۷۸.۶۰	۷۷.۵۰
Majority Voting + BERT	۸۸.۴۷	۸۳.۳۷	۸۵.۴۴	۸۲.۷۷	۸۲.۱۲	۸۱.۴۵

رمزگذار توجه»، نشریه پردازش علائم و داده ها، دوره ۲۰، شماره ۴، صص. ۱۲۱-۱۲۸، اسفند ۱۴۰۲.

- [3] S. Karimi and F. Jafarnejad, "Aspect-Based Sentiment Analysis using the Attentional Encoder Network," *Journal of Scientific Development and Planning (JSDP)*, vol. 20, no. 4, p. 8, 2024. [Online]. Available: <http://jsdp.rcisp.ac.ir/article-1-1321-fa.html>.

[۴] میر، مرضیه و نوفرستی، سمیرا، «به کارگیری روش های داده افزایی برای تحلیل احساسات کاربران درباره بازگشایی مدارس در دوران همه گیری کووید-۱۹»، نشریه پردازش علائم و داده ها، دوره ۲۱، شماره ۲، صص. ۱۴-۳، آبان ۱۴۰۳.

7-References

۷-مراجع

- [1] W. Medhat, A. Hassan, and H. Korashy, "Sentiment analysis algorithms and applications: A survey," *Ain Shams Engineering Journal*, vol. 5, no. 4, pp. 1093-1113, Dec. 2014, doi: 10.1016/j.asej.2014.04.011.
- [2] H. H. Do, P. W. Prasad, A. Maag, and A. Alsadoon, "Deep learning for aspect-based sentiment analysis: a comparative review," *Expert Systems with Applications*, vol. 118, pp. 272-299, 2019.
- [۳] کریمی، سمیه و جعفری نژاد، فاطمه، «تحلیل احساسات مبتنی بر جنبه با استفاده از شبکه

- pp. 3540–3549, doi: 10.18653/v1/2020.emnlp-main.286.
- [13] B. Liang, R. Yin, L. Gui, J. Du, and R. Xu, "Jointly Learning Aspect-Focused and Inter-Aspect Relations with Graph Convolutional Networks for Aspect Sentiment Analysis," in *Proceedings of the 28th International Conference on Computational Linguistics*, D. Scott, N. Bel, and C. Zong, Eds., Barcelona, Spain (Online), Dec. 2020, pp. 150–161, doi: 10.18653/v1/2020.coling-main.13.
- [14] R. Li, H. Chen, F. Feng, Z. Ma, X. Wang, and E. Hovy, "Dual Graph Convolutional Networks for Aspect-based Sentiment Analysis," in *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (ACL-IJCNLP)*, C. Zong, F. Xia, W. Li, and R. Navigli, Eds., Online, Aug. 2021, pp. 6319–6329, doi: 10.18653/v1/2021.acl-long.494.
- [15] K. Wang, W. Shen, Y. Yang, X. Quan, and R. Wang, "Relational Graph Attention Network for Aspect-based Sentiment Analysis," in *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics (ACL)*, D. Jurafsky, J. Chai, N. Schluter, and J. Tetreault, Eds., Online, Jul. 2020, pp. 3229–3238, doi: 10.18653/v1/2020.acl-main.295.
- [16] Z. Zhang, Z. Zhou, and Y. Wang, "SSEGCN: Syntactic and Semantic Enhanced Graph Convolutional Network for Aspect-based Sentiment Analysis," in *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, M. Carpuat, M.-C. de Marneffe, and I. V. Meza Ruiz, Eds., Seattle, United States, Jul. 2022, pp. 4916–4925, doi: 10.18653/v1/2022.naacl-main.362.
- [17] S. Liang, W. Wei, X.-L. Mao, F. Wang, and Z. He, "BiSyn-GAT+: Bi-Syntax Aware Graph Attention Network for Aspect-based Sentiment Analysis," in *Findings of the Association for Computational Linguistics: ACL 2022*, 2022, pp. 1835–1848, doi: 10.18653/v1/2022.findings-acl.144.
- [18] X. Zhao et al., "RDGCN: Reinforced Dependency Graph Convolutional Network for Aspect-based Sentiment Analysis," *arXiv*, Nov. 08, 2023, doi: 10.48550/arXiv.2311.04467.
- [19] Q. Gu, Z. Wang, H. Zhang, S. Sui, and R. Wang, "Aspect-Level Sentiment Analysis Based on Syntax-Aware and Graph Convolutional Networks," *Applied Sciences*, vol. 14, no. 2, p. 729, Jan. 2024, doi: 10.3390/app14020729.
- [20] M. Pontiki, D. Galanis, J. Pavlopoulos, H. Papageorgiou, I. Androutsopoulos, and S. Manandhar, "SemEval-2014 Task 4: Aspect Based Sentiment Analysis," in *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*, P. Nakov and T. Zesch, Eds., Dublin, Ireland, [4] M. Mir and S. Noforesti, "Using Data Augmentation Techniques for Sentiment Analysis of Users' Opinions on Reopening of Schools During the Covid-19 Epidemic," *Journal of Scientific Development and Planning (JSDP)*, vol. 21, no. 2, p. 1, 2024. [Online]. Available: <http://jsdp.rcisp.ac.ir/article-1-1385-fa.html>.
- [5] H. Liu, I. Chatterjee, M. Zhou, X. S. Lu, and A. Abusorrah, "Aspect-Based Sentiment Analysis: A Survey of Deep Learning Methods," *IEEE Transactions on Computational Social Systems*, vol. 7, no. 6, pp. 1358–1375, Dec. 2020, doi: 10.1109/TCSS.2020.3033302.
- [6] J. Zhou et al., "Graph neural networks: A review of methods and applications," *AI Open*, vol. 1, pp. 57–81, 2020.
- [7] W. Liao, B. Zeng, J. Liu, P. Wei, X. Cheng, and W. Zhang, "Multi-level graph neural network for text sentiment analysis," *Computers & Electrical Engineering*, vol. 92, p. 107096, Jun. 2021, doi: 10.1016/j.compeleceng.2021.107096.
- [8] H. T. Phan, N. T. Nguyen, and D. Hwang, "Aspect-level sentiment analysis: A survey of graph convolutional network methods," *Information Fusion*, vol. 91, pp. 149–172, Mar. 2023, doi: 10.1016/j.inffus.2022.10.004.
- [9] K. Sun, R. Zhang, S. Mensah, Y. Mao, and X. Liu, "Aspect-Level Sentiment Analysis Via Convolution over Dependency Tree," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, K. Inui, J. Jiang, V. Ng, and X. Wan, Eds., Hong Kong, China, Nov. 2019, pp. 5679–5688, doi: 10.18653/v1/D19-1569.
- [10] B. Huang and K. Carley, "Syntax-Aware Aspect Level Sentiment Classification with Graph Attention Networks," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, K. Inui, J. Jiang, V. Ng, and X. Wan, Eds., Hong Kong, China, Nov. 2019, pp. 5469–5477, doi: 10.18653/v1/D19-1549.
- [11] C. Zhang, Q. Li, and D. Song, "Aspect-based Sentiment Classification with Aspect-specific Graph Convolutional Networks," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, K. Inui, J. Jiang, V. Ng, and X. Wan, Eds., Hong Kong, China, Nov. 2019, pp. 4568–4578, doi: 10.18653/v1/D19-1464.
- [12] M. Zhang and T. Qian, "Convolution over Hierarchical Syntactic and Lexical Graphs for Aspect Level Sentiment Analysis," in *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, B. Webber, T. Cohn, Y. He, and Y. Liu, Eds., Online, Nov. 2020,

- [21] L. Dong, F. Wei, C. Tan, D. Tang, M. Zhou, and K. Xu, "Adaptive Recursive Neural Network for Target-dependent Twitter Sentiment Classification," in *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (ACL) (Volume 2: Short Papers)*, 2014.



علی بلوچی دانش آموخته

کارشناسی ارشد رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه ایلام است که موضوع پایان نامه ایشان «تجزیه و تحلیل احساسات سطح جنبه با استفاده از

شبکه های عصبی گراف» است و در حال حاضر به عنوان پژوهشگر در زمینه مدل های زبانی بزرگ فعالیت می کند.

نشانی رایانامه ایشان عبارت است از:

a.balouchi@ilam.ac.ir



مظفر بگ محمدی دانشیار گروه

مهندسی کامپیوتر دانشگاه ایلام است. ایشان دانش آموخته مقطع دکترا در رشته برق - معماری کامپیوتر از دانشگاه تهران است که تاکنون مقالات متعددی در نشریات و کنفرانس های

داخلی و خارجی در زمینه های شبکه های بی سیم و هوش مصنوعی به چاپ رسانده است.

نشانی رایانامه ایشان عبارت است از:

mozafar@ilam.ac.ir



مجتبی کرمی استادیار گروه

مهندسی کامپیوتر دانشگاه ایلام هستند. ایشان دانش آموخته مقطع دکتری رشته مهندسی کامپیوتر در گرایش هوش مصنوعی از دانشگاه صنعتی امیرکبیر است؛ همچنین

مقطع کارشناسی مهندسی کامپیوتر در گرایش سخت افزار از دانشگاه صنعتی شریف به پایان رساند. زمینه های پژوهشی ایشان یادگیری ماشین، یادگیری عمیق و الگوریتم های تکاملی است.

نشانی رایانامه ایشان عبارت است از:

m.karami@ilam.ac.ir

