

Automatic Identification of Personality Traits Using X Contents Based on Myers Briggs Index

Malika Kalhar¹, Mitra Mirzarezaee^{2*}, Touraj BaniRostam^{3,4}

¹ Department of Computer Engineering, SR.C., Islamic Azad University, Tehran, Iran

² Department of Computer Engineering, SR.C., Islamic Azad University, Tehran, Iran

³ Department of Computer Engineering, CT.C., Islamic Azad University, Tehran, Iran

⁴ Master of Data Analytics Department, University of Niagara Falls Canada, Ontario, Canada

Received: 16 January 2024, Revised: 18 January 2025, Accepted: 01 February 2025

Paper type: Research

Abstract

The personality of individuals encompasses their behaviors and ways of thinking in social settings and daily life. Psychologists typically use personality questionnaires to determine individuals' personalities. The increasing availability of online social data and the development of computational parsers capable of text analysis have sparked researchers' interest in exploring advanced computational methods for text-based personality psychology. Personality prediction using computational and machine learning models based on text is an emerging phenomenon with significant potential in the field of personality assessment. This study analyzes and evaluates individuals' personalities based on the Myers-Briggs Type Indicator (MBTI) using data from the social network X. The goal is to investigate how textual digital footprints can be utilized to predict users' personalities. The research introduces a novel prediction method leveraging a multimodal deep learning architecture combined with multiple pre-trained language models, including BERT, as well as two more advanced deep learning models, RoBERTa and XLNet. These models represent relatively new architectures in deep learning-based natural language processing. The proposed approach employs the mentioned models to extract features and determine individuals' personalities based on the MBTI framework. Finally, the system makes decisions based on an ensemble averaging of the model results. Using a dataset from social network X, the proposed method develops a predictive model for each personality trait using features extracted from pre-trained models. The results demonstrate that the proposed method outperforms similar research. Specifically, the study achieved an accuracy of 88.5% and an F1 score of 0.882 on one dataset and an accuracy of 86.2% with an F1 score of 0.912 on another dataset. This research lays the foundation for the development of a personality identification system that can assist organizations in recruiting and selecting suitable personnel and enhancing business relationships with customers.

Keywords: Social Networks, Character recognition, Myers Briggs, Deep learning, BERT.

* Corresponding Author's email: mirzarezaee@iau.ac.ir

شناسایی خودکار خصوصیات شخصیتی افراد در شبکه‌ی اجتماعی X براساس شاخص مایرز بریگز

ملیکا کلهر^۱، میترا میرزا رضایی^{۲*}، تورج بنی رستم^{۳،۴}

^۱گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

^۲گروه علمی مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

^۳گروه علمی مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد تهران مرکز، تهران، ایران.

^۴گروه تحلیل داده، دانشگاه نیاگارا فالز کانادا، آنتاریو، کانادا

تاریخ دریافت: ۱۴۰۲/۱۰/۲۶ تاریخ بازبینی: ۱۴۰۳/۱۰/۲۹ تاریخ پذیرش: ۱۴۰۳/۱۱/۱۳

نوع مقاله: پژوهشی

چکیده

شخصیت، مجموعه‌ای از رفتارها و شیوه تفکر افراد در محیط اجتماعی و زندگی روزمره است. روان‌شناسان به طور معمول از پرسش‌نامه‌های شخصیتی برای تعیین شخصیت افراد استفاده می‌کند. افزایش دسترسی به داده‌های اجتماعی آنلاین و توسعه تجزیه‌کننده‌های نحوی که قادر به تجزیه و تحلیل متن هستند، علاقه محققان را به مطالعه روش‌های پیشرفته برای روان‌شناسی شخصیت مبتنی بر متن، برانگیخته است. پیش‌بینی شخصیت توسط مدل‌های محاسباتی و یادگیری ماشین بر اساس متن، یک پدیده نوظهور با پتانسیل بالا در زمینه ارزیابی شخصیت اشخاص است. در این مقاله شخصیت افراد بر اساس شاخص مایرز بریگز با استفاده از داده‌های شبکه اجتماعی X مورد تجزیه تحلیل قرار گرفته است تا بررسی شود چگونه می‌توان از ردپای دیجیتالی مبتنی بر متن برای پیش‌بینی شخصیت کاربران استفاده کرد. در این مقاله از معماری یادگیری عمیق چند مدلی همراه با چندین مدل زبانی از پیش آموزش دیده برت، روبرتا و ایکس‌ال‌نت است برای استخراج ویژگی و تشخیص شخصیت افراد بر اساس شاخص مایرز بریگز استفاده شده است. در نهایت، سیستم بر اساس میانگین‌گیری نتایج مدل‌ها تصمیم‌گیری می‌کند. روش پیشنهادی با استفاده از مجموعه داده‌های شبکه اجتماعی X یک مدل پیش‌بینی‌کننده برای هر صفت شخصیتی با استفاده از ویژگی‌های مستخرج از مدل‌های از پیش آموزش دیده تولید می‌کند. نتایج نشان می‌دهد که روش پیشنهادی، از پژوهش‌های مشابه بهتر عمل کرده است. به طور دقیق‌تر، این مقاله به دقت ۸۸٫۵٪ و امتیاز اندازه‌گیری F1 ۰٫۸۸۲ بر روی یکی از مجموعه داده‌ها و دقت ۸۶٫۲٪ و امتیاز F1 برابر با ۰٫۹۱۲ برای مجموعه داده دیگر دست یافته است.

کلیدواژگان: شبکه‌های اجتماعی، شخصیت شناسی، مایرز بریگز، یادگیری عمیق، برت.

۱- مقدمه

استفاده قرار می‌گیرند.

با پرداختن به مسائل فوق، این مقاله یک معماری یادگیری عمیق چند مدلی را پیشنهاد می‌کند که بر روی مدل‌های مختلف زبانی از پیش آموزش دیده است. این سه معماری شامل رمزگذار دوطرفه از ترانسفورماتورها یا به اختصار برت^۱ و رویکرد بهینه شده قوی پیش‌آموزشی برت یا به اختصار روبرتا^۲ و در آخر معماری ایکسالنت^۳ که یک پیش‌آموزش خودرگرسیون تعمیم‌یافته^۴ برای درک زبان برای دریافت معنای متنی داده‌های مبتنی بر متن از رسانه‌های اجتماعی است می‌شوند. سپس، خروجی این سه مدل، با ویژگی‌های آماری دیگری در پردازش زبان‌های طبیعی نظیر تحلیل احساسی متون، وزن‌دهی با روش نوین TF-IGM و تحلیل متن ورودی بر اساس پایگاه داده واژگان احساسات شورای تحقیقات ملی (NRC^۵) ترکیب می‌شوند و برای ساخت یک مدل جهت پیش‌بینی ویژگی‌های شخصیتی به یک شبکه وارد می‌شوند.

۲- مروری بر پیشینه تحقیق

با توسعه رسانه‌های اجتماعی و استفاده گسترده از آن‌ها، فعالیت‌هایی نظیر تشخیص شخصیت افراد بر اساس فعالیت‌های اجتماعی و الگوهای زبانی، در این رسانه‌ها مورد توجه زیادی قرار گرفته است و با رشد روز افزون الگوریتم‌ها و سیستم‌های کامپیوتری این حوزه توسعه شگرفی یافته است. مدل‌های پیش‌بینی شخصیت موجود، از متدهای یادگیری عمیق و الگوریتم یادگیری ماشینی به همراه استخراج ویژگی برای بهبود دقت طبقه‌بندی استفاده می‌کنند. با این حال، به دلیل محدودیت‌های الگوریتم محاسباتی و استفاده از یک پیکره از پیش تعریف شده، این رویکردها دارای محدودیت‌هایی در استخراج عناصر متنی در جمله هستند علاوه بر این، حداقل تعداد مجموعه داده‌های مورد استفاده در توسعه سیستم‌های پیش‌بینی شخصیت، به ویژه هنگام استفاده از الگوریتم‌های یادگیری عمیق، به‌عنوان مانع اصلی برای به حداکثر رساندن عملکرد مدل شناسایی شده است. این بخش شامل بررسی مختصری از کارهای ابتدایی صورت گرفته در حوزه تحلیل شخصیت کاربران شبکه‌های اجتماعی در دو حوزه اصلی است: نخست، اقدامات انجام شده در زمینه تشخیص شخصیت با استفاده از تکنیک‌های یادگیری ماشینی را مورد بررسی قرار می‌دهد و سپس، مروری بر تحقیقات صورت گرفته در زمینه تشخیص شخصیت با استفاده از پیشرفته‌ترین

شخصیت یک فرد جنبه‌های گسترده‌ای از زندگی او را در بر می‌گیرد و بر فعالیت‌های روزمره وی نیز تأثیر می‌گذارد [1]. با شکوفایی رسانه‌های اجتماعی و استفاده روزافزون از این شبکه‌ها، جامعه آنلاین به اشتراک گذاشتن ایده‌ها، احساسات و نظرات با یکدیگر سوق داده شده‌اند. این مهم امکانات جدیدی را برای سیستم‌های استنباط خودکار ویژگی‌های شخصیتی ارائه می‌دهد. بدیهی است که بین خلق و خوی افراد و رفتاری که در شبکه‌های اجتماعی به صورت کامنت و یا پست از خود نشان می‌دهند، ارتباط محکمی وجود دارد [2]. در برخی موارد مانند سیستم‌های استخدام سیستم‌های مشاوره شخصی، بازاریابی آنلاین، سیستم‌های توصیه‌های شخصی و سیستم‌های امتیازدهی اعتبار در بانک می‌توان از این داده‌ها برای توصیف رفتار و شخصیت افراد استفاده کرد. امروزه تشخیص شخصیت از طریق سایت‌های شبکه‌های اجتماعی توجه محققان را برای توسعه سیستم‌های تشخیص خودکار شخصیت به خود جلب کرده است. پیش‌بینی شخصیت بر اساس پیام متنی که کاربر در رسانه‌های اجتماعی به اشتراک می‌گذارد، به دلیل ابهامات ذاتی زبان‌های طبیعی، می‌تواند کار بسیار دشواری باشد. پیشرفت‌های زیادی در زمینه پردازش زبان طبیعی در زمینه برخورد با این ابهامات حاصل شده است. تا به امروز، الگوریتم‌های پردازش زبان، کامپیوترها را قادر به درک کلمات یا جملات نوشته شده به زبان انسان کرده است. سیستم‌های پیش‌بینی شخصیت موجود از الگوریتم یادگیری عمیق و یادگیری ماشینی به همراه استخراج ویژگی واژگان باز برای بهبود دقت طبقه‌بندی استفاده می‌کند. با این حال، این رویکرد برای استخراج ویژگی‌های زمینه‌ای در جمله محدودیت‌هایی دارد که به دلیل محدودیت الگوریتم‌های محاسباتی و مشکلاتی نظیر استفاده از واژگانی که در پیکره استفاده شده هنگام آموزش مدل حضور نداشته‌اند، ناشی می‌شود. علاوه بر این، حجم پایین داده‌های موجود در مجموعه داده‌های مورد استفاده در ساخت سیستم پیش‌بینی شخصیت به‌ویژه با استفاده از الگوریتم یادگیری عمیق، مانع اصلی برای به حداکثر رساندن عملکرد مدل است. همچنین، شخصیت بر اساس ابعاد (صفات) مختلف تعریف می‌شود و این ویژگی‌ها اغلب با یک همبستگی غیر قابل اغماض همراه است که در تحقیقات تجربی روانشناسی نیز تأیید شده است. با این حال، چنین همبستگی‌های ضمنی ویژگی به ندرت مورد

⁴ Generalized Autoregressive Pretraining

⁵ National Research Council

¹ Bidirectional Encoder from Transformer (BERT)

² Robustly Optimized BERT Pretraining Approach (RoBERTa)

³ XLNet

الگوریتم‌های یادگیری عمیق مانند LSTM^۱ و Bi-LSTM^۲ و مدل برت را دارد.

۲-۱- مطالعات موجود در زمینه تشخیص شخصیت از طریق تکنیک‌های یادگیری ماشین

پیش‌بینی ویژگی‌های شخصیتی با استفاده از یادگیری ماشین شامل به تصویر کشیدن مدل‌های مختلف برای تجزیه و تحلیل الگوها و روابط درون داده‌های متنی است. روش‌های یادگیری ماشین همبستگی قابل توجهی را بین تمایلات رفتاری در میان داده‌های متنی رسانه‌های اجتماعی نشان می‌دهند و در این الگوریتم‌ها از تکنیک‌های جاسازی و مدل‌های یادگیری برای تحلیل متن زبان و محاسبه ویژگی‌های شخصیتی استفاده می‌شود.

چاهان سو در سال ۲۰۲۰ توانست ویژگی‌های شخصیتی افراد را با استفاده از روش‌های یادگیری ماشین و با مجموعه‌ای متشکل از ده مدل پیش‌بینی‌کننده تشخیص دهد. این مطالعه بر اساس مجموعه داده‌های متشکل از پاسخ‌های یک نظرسنجی در مورد ۹۱ شخصیت و سه مورد جمعیت‌شناختی است. چاهان سو توانست با استفاده از روش‌های اصلاح عدم تعادل کلاس مانند روش نمونه‌گیری SMOTE یا ADASYN به دقت ۷۴ درصد در داده‌های دیده نشده دست یابد [3].

مطالعه گسترده دیگری در سال ۲۰۲۱، توسط برلیان فیری و همکارانش با همان روش و به دنبال رویکرد ترکیبی نزدیک‌ترین همسایه ویرایش شده با SMOTE-ENN انجام شد، که توانست به دقت ۷۲ درصد دست یابد. این تحقیق حاکی از آن است که برای بهبود عملکرد طبقه‌بندی شخصیت به مطالعه بیشتر در مورد روش تعادل ترکیبی و مدل طبقه‌بندی دیگری نیاز است [4].

کاتیار و همکاران در سال ۲۰۲۰ از طبقه‌بندی MBTI به عنوان ابزاری برای استخدام تیم‌های پروژه با تمرکز بر داده‌های رسانه‌های اجتماعی به عنوان مثال، وبلاگ‌ها، شبکه اجتماعی نظیر X و استک‌اورفلو^۳ استفاده می‌کند. برای این منظور، مدلی مبتنی بر طبقه‌بندی Naïve Bayes و تعدادی TF-IDF با استفاده از مجموع پست‌های ۴۰ کاربر X و استک‌اورفلو ارزیابی می‌شود که نتایج آن نشان می‌دهد که ممکن است بتوان هم ویژگی‌های شخصیتی و هم مهارت‌های فنی را از متن برای تسهیل فرآیند جذب استخراج کرد [5].

سahونو و همکاران در سال ۲۰۲۰، با استفاده از پست‌های رسانه‌های اجتماعی در مجموعه داده Kaggle، و با تمرکز بر استخراج ویژگی شخصیتی بر اساس روش MBTI توانستند به دقت ۸۴٪ دست پیدا کنند. در این مطالعه برای پیش‌پردازش، از استخراج ویژگی با روش TF-IDF و برای طبقه‌بندی از ماشین بردار پشتیبانی^۴ استفاده شده است [6].

بوگدانچیکوف در سال ۲۰۲۱ برای طبقه‌بندی شخصیت افراد بر اساس شاخص MBTI در پلتفرم ApacheSpark مطالعاتی را انجام داد. او از سه الگوریتم طبقه‌بندی مختلف (رگرسیون لجستیک^۵، ساده بیز، ماشین پشتیبان بردار) برای آموزش و پیش‌بینی ویژگی‌های شخصیتی MBTI در مجموعه داده‌های Kaggle متشکل از ۸۶۷۵ توییت کاربر استفاده کردند و توانستند به دقت ۷۸ درصد دست یابند [7].

سوهارتونو در سال ۲۰۲۱ از طبقه‌بند XGBoost برای پیش‌بینی ویژگی‌های شخصیتی MBTI از متن استفاده کرده است، وی با استفاده از پیش‌پردازش و انتخاب ویژگی با استفاده از تکنیک‌های TF-IDF توانست به دقت ۷۹/۰۱ دست یابد [8].

پراسانا کومار و همکاران در سال ۲۰۲۳ از یک مدل ترکیبی متشکل از چهار مدل یادگیری ماشین نظیر مدل‌های رگرسیون لجستیک، ماشین بردار پشتیبان، بیز^۶ و جنگل تصادفی برای پیش‌بینی شخصیت افراد استفاده کردند. آن‌ها با انتخاب ویژگی PCA و Chi-square و روش‌های استخراج ویژگی مانند برچسب‌گذاری TF-IDF و با استفاده از الگوریتم‌های نظارت‌شده برای ارزیابی عملکرد صفات توانستند به دقت ۶۷ درصد با RF و ۷۳ درصد با LR، دست پیدا کنند [9].

خسوس سرانو و همکاران در سال ۲۰۲۴، برای توسعه یک مدل تشخیص شخصیت، چندین مدل یادگیری ماشین را با استفاده از ویژگی‌های معنایی و واژگانی مختلف، و الگوریتم‌های یادگیری عمیق، و تکنیک‌های جاسازی کلمه، ترکیب می‌کند. عملکرد مدل مجموعه پیشنهادی با استفاده از مجموعه داده استاندارد طلایی MyPersonality ارزیابی شده است. و به دقت متوسط ۷۲،۶۹٪ دست یافت. نتایج این مطالعه نشان داد چارچوب پیشنهادی بهتر از معماری‌های مدل گروهی یادگیری ماشین و الگوریتم‌های مبتنی بر یادگیری عمیق، عمل می‌کند [10].

⁴ SVM

⁵ Logistic regression

⁶ Naïve Bayes

¹ Long short-term memory

² Bidirectional Long Short-Term Memory

³ Stack Overflow

۲-۲- مطالعات موجود در زمینه تشخیص شخصیت از طریق تکنیک‌های یادگیری عمیق

یادگیری عمیق یک زیرمجموعه از یادگیری ماشین است که با شبکه‌های عصبی با لایه‌های چندگانه سروکار دارد. یادگیری عمیق قادر به مقابله با الگوهای پیچیده داده‌ها است. و در پردازش حجم زیادی از داده‌ها و استخراج ویژگی‌های سلسله مراتبی از آن‌ها نیز نسبت به روش‌های یادگیری ماشین برتری دارد. اما اغلب به منابع محاسباتی قابل توجه و مجموعه داده‌های بزرگ برای آموزش نیاز دارد. یادگیری عمیق شامل مدل‌ها شامل شبکه‌های کانولوشنال، شبکه‌های باور عمیق^۱ و شبکه‌های بازگشتی هستند.

امیرمحمد کاظمینی در سال ۲۰۲۰ یک رویکرد جدید مبتنی بر یادگیری عمیق را برای تشخیص خودکار شخصیت افراد از روی متن و مقاله نوشته شده توسط آن‌ها ارائه کرده است. او از پیشرفته‌ترین رویکردهای موجود در درک زبان طبیعی، یعنی مدل زبانی برت برای استخراج جاسازی مفهوم‌سازی شده کلمات از داده‌های متنی از مجموعه داده MBTI_1، برای تشخیص خودکار شخصیت نویسنده استفاده می‌کند. سپس از ماشین بردار پشتیبان برای دسته‌بندی داده‌ها استفاده می‌کند. این مقاله با استفاده از مجموعه داده‌ای که شامل مقالات متعدد است، روشی را برای تشخیص ویژگی‌های شخصیتی با استفاده از Bagged SVM بر روی تکنیک BERT Word Embedding Ensembles پیشنهاد می‌کند. این مدل ۱٫۴٪ نسبت به مدل‌های قبلی برتری دارد و همچنین از نظر محاسباتی برای آموزش کارآمدتر است. این مقاله از روش‌های Ensemble Learning و Bagged SVM برای تحلیل ویژگی‌های شخصیتی استفاده کرده است. همچنین برای تنظیم پارامترها از روش‌های جستجوی شبکه‌ای^۲، تکنیک Ensemble برای افزایش استحکام مدل و کاهش واریانس استفاده شده است [11].

کمال الدمرداس در سال ۲۰۲۱ یک مدل مبتنی بر یادگیری عمیق جدید را برای پیش‌بینی و طبقه‌بندی شخصیت با استفاده از ترکیب داده‌ها و سطوح مختلف طبقه‌بندی پیشنهاد می‌کند. این مدل از انتقال یادگیری در پردازش زبان طبیعی از طریق مدل‌های زبانی از پیش آموزش دیده یعنی Elmo، ULMFiT و برت بهره می‌برد. هنگام ارزیابی روش پیشنهادی، هر مجموعه داده را به ترتیب با داده‌های نسبت ۹۰ درصد آزمون، ۱۰ درصد آموزش تقسیم شد. نتایج، افزایش دقت رقابتی و قابل توجهی حدود ۱٫۲۵٪ و ۳٫۱۲٪

در مقایسه با جدیدترین نتایج برای دو مجموعه داده استاندارد طلایی Essays و myPersonality برای تشخیص شخصیت را نشان می‌دهد. در این مقاله، از روش‌های جستجوی شبکه‌ای برای بهینه‌سازی پارامترها استفاده شده است [12].

احمد و همکاران در سال ۲۰۲۱ یک مدل ترکیبی مبتنی بر یادگیری عمیق، یعنی شبکه عصبی کانولوشن الحاق شده با حافظه کوتاه مدت را برای استخراج ویژگی شخصیتی (درون‌گرایی-برون‌گرایی، شهود-احساس، تفکر) ارائه دادند. آن‌ها با استفاده از رویکرد ترکیبی CNN+LSTM و تکنیک جاسازی‌های کلمه با پیکربندی‌های مختلف از جمله تغییرات در لایه‌های مدل، واحدها، اندازه دسته‌ای و اندازه واژگان توانستند به دقت ۸۸ درصد دست یابند [13].

ساکدپات اونتوم و جانانان اچ چان در سال ۲۰۲۲ مدل "CRISP-DM" را که مخفف «فرآیند استاندارد بین صنعتی برای داده کاوی» است را برای هدایت فرآیند یادگیری در تشخیص مدل شخصیتی MBTI افراد از روی متن معرفی کردند. از آنجایی که "CRISP-DM" نوعی توسعه تکراری است، نویسندگان آن را با متدولوژی چابک که یک روش توسعه نرم‌افزار تکراری سریع است، ادغام کردند تا چرخه توسعه را به حداقل برسانند. در این مطالعه مجموعه داده‌ها به «۷۵ درصد آموزش» و «۲۵ درصد مجموعه‌های تست» تقسیم شدند و همچنین برای تنظیم پارامترها از روش بهینه‌سازی مبتنی بر گرادیان استفاده شده است [14].

محمد ازهرتلی در سال ۲۰۲۳، برای طبقه‌بندی ویژگی‌های شخصیتی با استفاده از پروفایل‌های رسانه‌های اجتماعی از مجموعه داده شخصیت یوتیوب استفاده کرده است. وی با استفاده از الگوریتم‌های یادگیری نیمه‌نظارت شده چند برجسی مانند شبکه عصبی کانولوشن، شبکه عصبی بازگشتی، LSTM، BiLSTM، GRU و BiGRU و با استفاده از اعتبارسنجی متقاطع ۱۰ مورد ارزیابی قرار گرفتند توانستند با استفاده از جستوی تصادفی به تنظیم دقیق پارامترها و به امتیاز F1 ۸۸ درصد دست پیدا کند [15].

هارشیت بهاردواج در ۲۰۲۳ از یک مدل DeepLSTM^۳ برای طبقه‌بندی ویژگی‌های شخصیتی با استفاده از سیگنال‌های الکتروانسفالوگرام استفاده کرد. هدف این مطالعه ارزیابی کارایی مدل DeepLSTM با طبقه‌بندی‌های پیشرفته یادگیری ماشینی موجود مانند MLP^۴، KNN^۵ و SVM و LibSVM است. مدل پیشنهادی از

^۴ پرسپترون چندلایه

^۱ Deep belief networks

^۲ Grid Search

^۵ K-Nearest Neighbors

^۳ یادگیری عمیق حافظه کوتاه مدت عمیق

طبقه‌بندهای موجود برای رویکرد پارتیشن‌بندی ۷۰-۳۰، با حداکثر دقت طبقه‌بندی ۹۰،۳۲٪ بهتر عمل می‌کند. این مقاله از روش‌های بهینه‌سازی استاندارد مانند Gradient Descent به همراه روش‌های تنظیم هایپرپارامترهایی مانند learning rate و batch size استفاده می‌شود [16].

سیراسپالی در سال ۲۰۲۳ یک مدل جدید پیش‌بینی شخصیت را ارائه می‌دهد. وی برای مواجه با مشکل کمبود در یادگیری عمیق، از تکنیک‌های ادغام داده‌ها و نقشه‌برداری منبع استفاده می‌کند. نتایج پس از نگاشت MBTI به Big Five و بعد از آن، ادغام با مجموعه داده‌های Essays و MyPersonality، توانست به بالاترین دقت ۸۷،۸۹ درصد و امتیاز اندازه‌گیری F1 ۰،۹۲۴ دست پیدا کند. این مطالعه برای تنظیم هایپرپارامترها از روش‌های جستجوی تصادفی بهره می‌برند [17].

در سال ۲۰۲۴ طایفه‌محمودی و همکاران یک چارچوب چندمرحله‌ای برای تحلیل محتوا در شبکه‌های اجتماعی ارائه می‌دهد. آن‌ها، استفاده صرف از واژگان حسی مثبت و منفی برای تعیین قطبیت متون را کافی ندانسته‌اند، زیرا این روش‌ها معمولاً همبافت، لحن بیان، دامنه موضوعی و مفاهیم معنایی را نادیده می‌گیرند. به همین دلیل، رویکردهای نوین، به‌ویژه در شبکه‌های اجتماعی، به سمت تحلیل مبتنی بر گزاره‌های معنایی و قواعد اگر-آنگاه رفته‌اند تا با توجه به لحن راوی، همبافت انتشار محتوا و پیام‌های مضمونی پنهان در متن، درکی دقیق‌تر و عمیق‌تر از نیت و نگرش مولف به دست آورند. این مقاله با معرفی پنج طبقه معنایی شامل عدالت/ صداقت‌باوری، حیا/ حرمت‌باوری، همیاری/ رواداری، دانستن/ اندیشیدن و تعالی‌باوری، چارچوبی مفهومی برای تحلیل احساس بر اساس محتوا و ارزش‌های فرهنگی-اجتماعی ارائه می‌دهد و با اعتبارسنجی آن بر روی داده‌های واقعی شبکه‌های اجتماعی، کارایی و جامعیت این روش را اثبات می‌کند. نتیجه مطالعه نشان می‌دهد مدل توانایی قابل توجهی در تمایز کاربران با سبک‌های نگارشی و رفتاری متفاوت دارد [21].

در سال ۲۰۲۴ شایگان‌فرد و ولی‌زاده با تحلیل پیام‌های گروهی تلگرام به استخراج ویژگی‌های شخصیتی کاربران پرداختند. آنها یک سیستم ترکیبی طراحی کرده‌اند که از سه الگوریتم Cosine Similarity، MLP و Bayes برای استنباط شخصیت کاربران از پیام‌های گروهی در تلگرام استفاده می‌کند، سپس بر اساس نتایج شخصیت‌شناسی، توصیه کانال‌های مرتبط به هر کاربر ارائه می‌شود. ارزیابی‌های انجام شده نشان می‌دهد که این سیستم موفق به کسب رضایت تقریبی ۶۵،۴۲٪ کاربران شده است [22].

در سال ۲۰۲۴، هو و همکاران از مدل‌های بزرگ زبانی برای تولید نسخه‌های معنایی و احساسی جایگزین متن استفاده کردند؛ سپس

طبقه‌بندهای موجود برای رویکرد پارتیشن‌بندی ۷۰-۳۰، با حداکثر دقت طبقه‌بندی ۹۰،۳۲٪ بهتر عمل می‌کند. این مقاله از روش‌های بهینه‌سازی استاندارد مانند Gradient Descent به همراه روش‌های تنظیم هایپرپارامترهایی مانند learning rate و batch size استفاده می‌شود [16].

سیراسپالی در سال ۲۰۲۳ یک مدل جدید پیش‌بینی شخصیت را ارائه می‌دهد. وی برای مواجه با مشکل کمبود در یادگیری عمیق، از تکنیک‌های ادغام داده‌ها و نقشه‌برداری منبع استفاده می‌کند. نتایج پس از نگاشت MBTI به Big Five و بعد از آن، ادغام با مجموعه داده‌های Essays و MyPersonality، توانست به بالاترین دقت ۸۷،۸۹ درصد و امتیاز اندازه‌گیری F1 ۰،۹۲۴ دست پیدا کند. این مطالعه برای تنظیم هایپرپارامترها از روش‌های جستجوی تصادفی بهره می‌برند [17].

در سال ۲۰۲۳ موهان و همکاران از داده‌های شبکه‌های اجتماعی مرتبط با MBTI و استفاده از تعبیه‌های Word2Vec ترکیب آن‌ها با مدل LSTM توانستند به دقت ۹۷ درصد در داده‌های آزمایشی دست یابند، زیرا روی توالی‌های از پیش‌پردازش شده و بالشتکی آموزش داده شده بود. با استفاده از لایه‌های LSTM، مدل بهتر می‌تواند اطلاعات متنی موجود در ورودی متن را درک کند و وابستگی‌های متوالی را به‌طور مؤثر دریافت کند [18].

در سال ۲۰۲۳ گروچ رویان و همکاران به بررسی پیش‌بینی تیپ شخصیتی مبتنی بر مدل MBTI از متن‌های نوشتاری پرداخته‌اند. آنها در این پژوهش بر چالش داده‌های نامتوازن در کلاس‌های MBTI تمرکز کرده داشتند و برای حل این مشکل، نویسندگان از تکنیک SMOTE^۱ برای ایجاد توازن میان کلاس‌ها استفاده کرده‌اند. داده‌های مورد استفاده شامل جملاتی از دیتاست MBTI-1 بودند که ویژگی‌های زبانی مرتبط با تیپ‌های شخصیتی را منعکس می‌کنند. پیش‌پردازش داده شامل توکن‌سازی، حذف توقف کلمات و تبدیل متن به تعبیه‌های عددی با استفاده از روش‌های پیشرفته پردازش زبان طبیعی (NLP) بوده است. نتایج نشان داد که استفاده از SMOTE توانست به طور قابل توجهی دقت و حساسیت مدل‌ها را در پیش‌بینی کلاس‌های نامتوازن افزایش دهد [19].

در سال ۲۰۲۴ نیمارا و همکاران با تمرکز بر تقویت پیش‌بینی شخصیت MBTI از داده‌های متنی از طریق تکنیک‌های پیشرفته جاسازی کلمه، مانند GloVe و BERT، اثربخشی طبقه‌بندهای مختلف یادگیری ماشین، از جمله Random Forest، XGBoost،

^۱ Synthetic Minority Oversampling Technique

در سال ۲۰۲۵، شاهنظری و ایوبزاده با استفاده از RoBERTa فاین تیون شده بر روی داده‌های مکالمه تلگرام تلاش کردند تا ویژگی‌های شخصیتی MBTI و جنسیت کاربران را از روی پیام‌های گفت‌وگویی تلگرام استخراج کنند، بی‌نیاز از برچسب‌های خوداظهاری. آنها مجموعه داده‌ای شامل ۱۳۸۰۸۶۶ پیام از ۱۰۶۰۲ کاربر با برچسب MBTI و ۱۹۵۰۱۶ پیام از ۲۰۵۹۸ کاربر با برچسب جنسیت جمع‌آوری کردند. مدل RoBERTa با در نظر گرفتن سطوح اعتماد توانست شخصیتی MBTI را با دقت ۸۶٫۱۶٪ و جنسیت را با دقت ۷۴٫۰۴٪ شناسایی کند. تحلیل ویژگی‌های شخصیتی نشان داد که افراد با گرایش‌های درون‌گرا و شهودی فعالیت بیشتری در تعامل نوشتاری دارند. پژوهشگران در این مقاله توانستند به دقت ۸۶٫۱۶٪ در تشخیص ضمنی تیپ شخصیتی برسند. این نتایج، قابلیت مدل‌های Transformer را در شناسایی ویژگی‌های ضمنی از زبان محاوره‌ای نشان می‌دهد، ضمناً نکاتی در مورد توازن میان دقت و پوشش داده‌ها مطرح می‌کند [26].

در سال ۲۰۲۵، استراکوالورسی و آگاتی با استفاده از یک مدل طبقه‌بندی XGBoost مبتنی بر ویژگی‌های TF-IDF و پردازش متن نظرات کاربران یوتیوب، طبقه‌بندی MBTI را با تنها ۱۰۰ کلمه متن در هر کاربر انجام دادند. آنها توانستند MBTI کاربران یوتیوب را با دقت بالایی پیش‌بینی کنند و توالی رایج تیپ‌ها را با تحلیل موضوع قرارگیری کاربران (مانند نظریه توطئه یا سفر) ارائه دادند [27].

۳- روش اجرای تحقق

۳-۱- شاخص مایرز بریگز

شاخص مایرز بریگز از ۵۵ سال گذشته یک تست ارزیابی شخصیتی شناخته شده و پذیرفته شده در سراسر جهان بوده است. این آزمون بر اساس نظریه کارلوژی یونگ کارل یونگ است و شخصیت انسان را در چهار بعد اساسی توصیف می‌کند. این بعد ها به ترتیب شامل برون‌گرایی^۳ در مقابل درون‌گرایی^۴، حسی^۵ در مقابل شهودی^۶، منطقی^۷ در مقابل احساسی^۸، داوری کننده^۹ در مقابل ملاحظه کار^{۱۰} هستند. و در نهایت شخصیت افراد را در یکی از شانزده گروه شناخته شده زیر قرار می‌دهد:

۱. ENFJ : برون‌گرا - شهودی - احساسی - قضاوتی،

از یادگیری تضاد^۱ برای آموزش encoder پایش و بازنمایی شخصیت بهره بردند. این روش روی مجموعه داده MBTI آزمایش شده و به بهبود قابل توجه در دقت تشخیص شخصیت نسبت به روش‌های قبلی دست یافتند. طبق نتایج این مقاله، مدل پیشنهادی TAE (Text Augmentation Enhanced) با استفاده از تقویت داده‌ها و غنی‌سازی برچسب‌ها توسط LLM، بهبود قابل توجهی در دقت تشخیص ویژگی‌های شخصیتی ارائه می‌دهد. بر اساس سنجه Macro-F^۱: در مجموعه داده کگل، مدل TAE به میانگین ۷۲٫۰۷٪ و در مجموعه داده پاندورا، به عملکرد ۶۳٫۰۵٪ رسید. همچنین مقایسه با BERTmean نشان می‌دهد که TAE در کگل بهبود چشمگیر ۵٫۸۳٪ داشته، و در پاندورا حدود ۶٫۵۳٪ ارتقاء یافته است [23].

در سال ۲۰۲۴، ژو و همکاران با طراحی یک مدل دوگانه با نام Dual Enhanced Network (DEN) که شخصیت کاربران را از دو منظر پایدار و مقطعی تحلیل می‌کند، روی دو مجموعه داده استاندارد شبکه‌های اجتماعی اجرا کردند و با مدل‌سازی تعامل دوجهته بین ویژگی‌های زبانی، به بهبود قابل توجهی در دقت طبقه‌بندی تیپ‌های MBTI نسبت به رویکردهای تک‌لایه رسیدند [24].

در سال ۲۰۲۵، شن و همکاران یک چارچوب خودنظارتی^۲ نوآورانه را برای شناسایی شخصیت کاربران بر اساس پست‌های متنی در شبکه‌های اجتماعی معرفی کردند. آنها با استفاده از یک مدل گراف عصبی پویا خودنظارتی که در آن گره‌ها و یال‌ها بر اساس داده تغییر می‌کنند و بهره‌برداری از LLM برای استخراج ویژگی‌های معنایی، گرافی دینامیک از پست‌های شبکه اجتماعی ساختند. پس از آن، با استفاده از شبکه‌های عصبی گراف (GNN)، مدل با سه هدف مشترک بازسازی گره‌ها، پیش‌بینی یال‌ها و یادگیری تضاد آموزش داده می‌شود تا پروفایل شخصیتی قوی‌تری ایجاد شود. نتایج نشان می‌دهد که این ترکیب بین فهم معنایی و ساختار پویا، نسبت به روش‌های مبتنی بر گراف‌های ثابت، در تشخیص شخصیت عملکرد بهتری دارد و مدل‌های سبک‌تری را قادر می‌سازد تا با دقت بالا پروفایل‌های شخصیتی استخراج کنند این روش روی مجموعه‌های کگل با دقت ۸۰٫۵۴٪ و پاندورا با دقت ۶۷٫۸۵٪ اجرا شد و عملکرد بهتری نسبت به روش‌های رایج در تشخیص شخصیت بدست آورد. [25]

⁶ INtuition
⁷ Feeling
⁸ Thinking
⁹ Judging
¹⁰ Perception

¹ Contrastive learning
² Self-supervised
³ Extraversion
⁴ Introversion
⁵ Sensational

ستون حاوی ۱۶ نوع شخصیت MBTI است که شامل ترکیبی از چهار دسته‌بندی درونگرایی/برونگرایی، حسی/شهودی، تفکری/احساسی، قضاوت‌گر/ادراکی است. هیچ ردیف تهي یا تکراری در داده‌ها ارائه نشد. این دیتاست برای تحلیل زبان طبیعی (NLP)، بررسی روابط بین شخصیت و الگوهای زبانی، و پیش‌بینی نوع شخصیت استفاده می‌شود.

۳-۲-۲-۲-۳ مجموعه داده MBTI500

مجموعه داده MBTI500 یک دیتاست جامع است که برای تحلیل تیپ‌های شخصیتی بر اساس شاخص مایرز-بریگز طراحی شده است. این دیتاست نسخه‌ای گسترده‌تر و دقیق‌تر از MBTI-1 است و این مجموعه داده شامل اطلاعاتی از ۵۰۰ فرد مختلف است که هر یک دارای تیپ شخصیتی مشخصی هستند. این مجموعه داده نیز مانند مجموعه داده قبلی دارای دو ستون پست‌ها و برچسب شخصیتی نویسنده است. در ستون پست‌ها، مجموعه‌ای از ۵۰ پست آخر نوشته‌شده توسط یک فرد قرار گرفته است که می‌تواند شامل نظرات، تجربیات یا هر نوع محتوای متنی دیگری باشد. متن‌های پست‌ها پیش‌پردازش شده‌اند و فاقد علائم نگارشی، کلمات توقف، یا لینک‌ها هستند. همچنین، عملیات ریشه‌یابی روی آن‌ها انجام شده و به قطعات هم‌اندازه ۵۰۰ کلمه‌ای تقسیم شده‌اند. ستون دوم نیز برچسب نوع شخصیت MBTI که شامل ۱۶ مقدار منحصر به فرد است. این مجموعه داده در حدود ۳۴۶,۰۵ مگابایت حجم دارد و شامل حدود ۱۰۶ هزار رکورد است. بخش اعظم داده‌ها از Reddit توسط Dylan Storey با استفاده از Google BigQuery جمع‌آوری شده است. مابقی داده‌ها از انجمن PersonalityCafe استخراج شده است. داده‌ها از منابع معتبر جمع‌آوری شده و تلاش شده تا تنوع زبانی و محتوایی بیشتری در این دیتاست وجود داشته باشد. MBTI-500 بیشتر در پژوهش‌های پیشرفته NLP و یادگیری عمیق (Deep Learning) مورد استفاده قرار می‌گیرد. هدف این دیتاست ارائه تعادل بهتر در داده‌هاست تا مدل‌های هوش مصنوعی بتوانند بدون سوگیری، الگوهای شخصیتی را شناسایی و پیش‌بینی کنند.

۳-۳-۳-۳-۳ چالش عدم تعادل در داده‌ها

همانطور که در شکل ۱ نشان داده شده است، این دو مجموعه داده نامتعادل هستند به طوری که تیپ شخصیتی INFP نمایش قوی‌تری را در مجموعه داده به خود اختصاص داده است که در دنیای واقعی غیرواقعی است. برای حل این مشکل، می‌توان با شکستن کلاس‌ها به چهار کلاس باینری، تعادل داده‌ها را برقرار و دقت مدل را بهبود بخشید.

۲. ENFP : برون‌گرا - شهودی - احساسی - ادراکی،
۳. ESFJ : برون‌گرا - حسی - احساسی - قضاوتی،
۴. ESFP : برون‌گرا - حسی - احساسی - ادراکی،
۵. INFJ : درون‌گرا - شهودی - احساسی - قضاوتی،
۶. INFP : درون‌گرا - شهودی - احساسی - ادراکی،
۷. INTJ : درون‌گرا - شهودی - منطقی - قضاوتی،
۸. INTP : درون‌گرا - شهودی - منطقی - ادراکی،
۹. ISFJ : درون‌گرا - حسی - احساسی - قضاوتی،
۱۰. ISFP : درون‌گرا - حسی - احساسی - ادراکی،
۱۱. ISTJ : درون‌گرا - حسی - منطقی - قضاوتی،
۱۲. ISTP : درون‌گرا - حسی - منطقی - ادراکی،
۱۳. ESTJ : برون‌گرا - حسی - منطقی - قضاوتی،
۱۴. ENTJ : برون‌گرا - شهودی - منطقی - قضاوتی،
۱۵. ENTP : برون‌گرا - شهودی - منطقی - ادراکی،
۱۶. ESTP : برون‌گرا - حسی - منطقی - ادراکی.

۳-۲-۳-۲-۳ مجموعه داده

داده‌های X منبع غنی از اطلاعات هستند که می‌توان از آن‌ها برای کسب اطلاعات در موارد گوناگون استفاده کرد. در این مطالعه، از دو دیتاست معروف در شناسایی و تشخیص شخصیت کاربران فضای مجازی به نام‌های MBTI-1 و MBTI500 استفاده شده است. هر دو شامل متون نوشتاری (مانند کامنت‌ها و پست‌ها) همراه با برچسب نوع شخصیت هستند. به دلیل رابطه مستقیم با الگوهای زبانی و روان‌شناختی، این دیتاست‌ها اهمیت بالایی در مطالعات شخصیت‌شناسی و تحلیل متن دارند.

۳-۲-۱-۲-۳ مجموعه داده MBTI-1


این مجموعه داده از طریق انجمن PersonalityCafe جمع‌آوری شده است و نمونه متنوعی از شخصیت افراد در حال تعامل در یک محیط اجتماعی آنلاین مانند X را ارائه می‌دهد و شامل تعاملات اجتماعی ۸۶۷۵ کاربر است که همه آن‌ها دارای برچسب MBTI نویسنده هستند. این مجموعه داده به صورت یک فایل CSV ارائه شده است و شامل دو ستون اصلی است. ستون اول شامل ۵۰ پست متفاوت است که توسط یک کاربر در پلتفرم‌های اجتماعی X نوشته شده است. این متن‌ها اغلب به صورت چند جمله یا پاراگراف کوتاه هستند و با نمادهای خاصی به صورت سه خط ("|||") از یکدیگر جدا شده‌اند. متون نوشته شده شامل موضوعات مختلفی مانند علاقه‌مندی‌ها، دیدگاه‌ها، نظرات و عادات روزانه هستند. در ستون دوم برچسب شخصیتی هر یک از کاربران درج گردیده است این

NLTK انجام می‌شود، که چندین عملکرد زبانی را برای کمک به پاکسازی داده‌های وضعیت رسانه‌های اجتماعی مانند نشانه گذاری، ریشه و فرهنگ لغت کلمات کلیدی ارائه می‌دهد. با این حال، یک مرحله اضافی در طول پیش‌پردازش داده‌های شبکه اجتماعی X وجود خواهد داشت که فرآیند حذف تمامی تایپ‌های شخصیتهای MBTI نوشته شده در متن است زیرا وجود آن‌ها می‌تواند در کارکرد مدل اختلال ایجاد کند. در نهایت همه داده‌ها توکنیزه می‌شوند. توکنیزه‌سازی، فرآیند تقسیم متن به بخش‌های کوچک‌تر به نام توکن است که ورودی مورد نیاز برای الگوریتم‌های طبقه‌بندی یادگیری ماشین است.

۳-۴-۲- استخراج ویژگی

در این مطالعه، با ترکیب دو روش استخراج ویژگی، شامل ویژگی‌های از پیش آموزش دیده شده و ویژگی‌های آماری، سعی بر آن شد تا مدلی نوین در استخراج شخصیت معرفی شود. منظور از ویژگی‌های از پیش آموزش دیده شده استفاده از مدل‌های معروف در یادگیری عمیق به نام‌های برت، روبرتا و ایکس‌ال‌نت است. هر یک از مدل‌های از پیش آموزش داده شده دارای اندازه ابعاد بدنه مخصوص خود هستند، مثلاً برت شامل ۳۰۵۲۲ کلمه، روبرتا شامل ۵۰۲۵۷ کلمه و ایکس‌ال‌نت شامل ۳۲۰۰۰ کلمه است.

هر یک از این کلمات در این مدل‌ها، در یک بعد ۷۶۸ در یک نمایش برداری نشان داده می‌شوند. در این مطالعه، از مدل برت تغییر یافته استفاده شده است. در این معماری، با افزودن چندین لایه خروجی اضافی به مدل برت و همچنین انجام تکنیک هرس لایه برای کاهش تعداد لایه‌ها، مدل برای تشخیص شخصیت، اصلاح شده است. برای پیش‌پردازش داده‌ها، به هر نمونه از ورودی در مجموعه داده، دو توکن‌های خاص [CLS] و [SEP] در ابتدا و انتهای جمله اضافه شده است. اضافه کردن یک لایه عصبی با فعال‌ساز SoftMax روی ورودی ادغام شده با [CLS]، در تشخیص جمله بعدی می‌تواند موثر واقع شود و توزیع احتمال متوالی بودن جملات الف و ب را نشان دهد. همچنین در پایان هر زیردنباله نیز یک توکن [SEP] اضافه می‌شود که به عنوان علامت خاتمه جملات است و مرز بین جملات را نشان می‌دهد. در نهایت خروجی این لایه‌های میانی به دنباله‌ای از توکن‌ها تبدیل شده و به عنوان ورودی به شبکه وارد می‌شود تا با آن‌ها آموزش ببیند. بر اساس رویکردی که در این مطالعه اتخاذ شد، توکن‌سازی با استفاده از روشی به نام توکن‌سازی WordPiece انجام شده است.



شکل ۱. نمودار توزیع نمونه‌ها برای ۱۶ نوع شخصیت در MBTI


۳-۴-۳- ساخت مدل

این مطالعه با تمرکز بر استفاده از داده‌های رسانه‌های اجتماعی X در سه مرحله، پیش‌پردازش داده‌ها، توسعه و ارزیابی مدل انجام شد. جزئیات مربوط به هر مرحله را می‌توان در شکل ۲ مشاهده کرد. تمام داده‌هایی که جمع‌آوری شده‌اند، به طور جداگانه پیش‌پردازش شدند. نتایج داده‌های پیش‌پردازش شده توسط فرآیند استخراج ویژگی و انتخاب ویژگی قبل از ورود به مرحله ساخت مدل انجام می‌شود. برای هر شخصیت بر اساس شاخص مایزر بریگز مدلی ساخته می‌شود که هدف آن پیش‌بینی هر شخصیت است.

۳-۴-۳-۱- پیش‌پردازش

در اولین گام تمام داده‌های موجود در مجموعه داده را پیش‌پردازش می‌کنیم. هدف اصلی از پیش‌پردازش، به حداکثر رساندن ویژگی‌های مفید استخراج شده است. ابتدا جهت یکسان‌سازی حروف و استانداردسازی فاصله‌ها، همه حروف با معادل استاندارد، و کلمات با املای درست خود جایگزین می‌گردند و جملات اختصاری نیز با فرم رسمی آن‌ها تبدیل می‌گردد.

سپس آدرس‌های اینترنتی، نمادها و کلمات اضافی مانند «از، به، که» و غیره از داده‌ها حذف خواهند شد. سپس جهت افزایش دقت در الگوریتم، تمامی ایموجی‌های استفاده شده در متن، با کلمات معادل خود جایگزین می‌گردند. در گام بعد جملات موجود به جملات ساده و مرکب و در نهایت واژه‌ها و عبارات خاص تبدیل خواهند شد. سپس این واژه‌ها با استفاده از توابع stemming، ریشه‌یابی می‌شود تا فرم به‌دست‌آمده از آن‌ها، یک کلمه شناخته شده در فرهنگ لغت باشد. این پیش‌پردازش با استفاده از کتابخانه



شکل ۲. خلاصه‌ای از مراحل به کار برده شده در استخراج ویژگی

«ها» تقسیم می‌شود. این به مدل کمک می‌کند تا یاد بگیرد واژه «پسر» و «پسر» با معانی کمی متفاوت اما کلمه ریشه یکسان تشکیل شده است. توکن‌های تولید شده در این بخش به صورت بردارهایی به طول ثابت ۷۶۸ نگاشت می‌شوند که به آن‌ها Token embedding می‌گویند. تبدیل توکن به بردار به منظور ثبت معنای لغات و محتوای آن‌ها را با مقادیر عددی است. Token Embedding تولید شده در قسمت قبل با بردارهای دیگری به نام‌های Segment

WordPiece یک روش توکن‌سازی مبتنی بر زیرکلمه است. توکن‌سازی مبتنی بر زیرکلمه راه‌حلی بین توکن‌سازی مبتنی بر کلمه و کاراکتر است. الگوریتم‌های توکن‌سازی مبتنی بر زیرکلمه، کلمات پرکاربرد را به زیرکلمه‌های کوچک‌تر تقسیم نمی‌کنند. بلکه کلمات را به زیرکلمه‌های معنادار کوچک‌تر تقسیم می‌کند. به عنوان مثال، واژه «پسر» تقسیم نمی‌شود، اما واژه «پسر» به «پسر» و

پیشنهادی این مقاله، مدل باید ویژگی‌های احساسی خاصی را در نظر بگیرد که در رمزگذاری متن وجود ندارد. در این کار سعی شده مدل با یک فرهنگ لغت عاطفی به نام تحلیل معنایی و واژگان هیجان NRC ترکیب شود تا مدل قادر به تشخیص دقیق‌تر شخصیت باشد.

آخرین ویژگی آماری استفاده شده در این قسمت استفاده از رویکرد تحلیل احساسات قطبی برای استخراج وزن برای کلاس مثبت، منفی و خنثی است. روش استخراج ویژگی مبتنی بر واژگان هیجان NRC، شامل ۱۴۰۰۰ مجموعه لغت به زبان انگلیسی است. که در آن رابطه هر کلمه با هشت احساس مشترک یعنی خشم، ترس، انتظار، اعتماد، تعجب، غم، شادی و انزجار برچسب‌دهی شده است. این روش به هر ورودی در مدل یکی از این ۸ برچسب را اختصاص می‌دهد. جدول ۱ خلاصه‌ای از ویژگی‌های آماری استفاده شده در این مطالعه را نشان می‌دهد.

۳-۵- مدل پیش‌بینی

در این مطالعه، به منظور بهبود عملکرد در پیش‌بینی شخصیت، یک معماری یادگیری عمیق چند مدلی معرفی شده است. این مدل شامل چهار طبقه‌بند برای تشخیص هر یک از بعدهای شخصیتی MBTI می‌باشد. شکل ۳ معماری مدل معرفی شده را نشان می‌دهد. در این معماری از سه مدل زبانی از پیش‌آموزش داده‌شده به نام‌های برت، روبرتا و ایکس‌ال‌نت برای مرحله استخراج ویژگی استفاده شد. این مدل‌ها متشکل از ۱۲ لایه رمزگذار، ۷۶۸ واحد مخفی، ۱۲ Attention head و توکن‌هایی با ابعاد ۷۶۸ هستند.

جدول ۱. ویژگی‌های استفاده شده در پیش‌پردازش داده‌ها

ویژگی	توضیحات	ابعاد
TF-IGM	روش آماری برای یافتن اهمیت یک کلمه در یک سند تحت تأثیر برچسب کلاس یک سند. این روش بر اساس مقایسه عملکردتحقیق بین TF-IDF و در طبقه‌بندی متن استفاده می‌شود.	۱۰۰
آنالیز احساسی متن	درصد TF-IGM مثبت، منفی و خنثی در وضعیت رسانه‌های اجتماعی. در این پایان نامه از رویکرد تحلیل احساسات قطبی برای استخراج وزن برای کلاس مثبت، منفی و خنثی استفاده شده است	۳
NRC	شامل ۱۴۰۰۰ مجموعه لغت به زبان انگلیسی و رابطه هر کلمه با هشت احساس مشترک یعنی خشم، ترس، انتظار، اعتماد، تعجب، غم، شادی و انزجار.	۸
مجموع ویژگی‌های آماری استخراج شده		۱۱۱

Embedding و Positional Embedding ترکیب شده تا معنای متنی بیشتری از ورودی استخراج و به مدل ارائه کنند. بردار Segment Embedding شامل دو بردار است. اولین بردار به تمام توکن‌های موجود در ورودی اول اختصاص داده می‌شود و دومین بردار به تمام توکن‌های موجود در ورودی دوم اختصاص داده می‌شود از سوی دیگر، بردار Positional Embedding شامل یک ماتریس در ابعاد کل جملات است. سطر اول نمایش برداری از هر کلمه در جمله اول است، ردیف دوم نمایش برداری از هر کلمه در جمله دوم و غیره است. ترکیب این سه Embedding که Input Embedding نامیده می‌شود، به عنوان راه حلی برای غلبه بر محدودیت‌های معماری‌های یادگیری عمیق مانند RNN که نمی‌توانند اطلاعات توالی را ضبط کنند، عمل می‌کند. در ادامه برای افزایش دقت مدل، ویژگی‌های استخراج شده را با ویژگی‌های آماری در پردازش زبان‌های طبیعی ادغام می‌کنیم. یکی از ویژگی‌های آماری استفاده شده در این مطالعه، معیار وزن‌دهی TF-IGM است که یکی از نسخه‌های بهبودیافته TF-IGM می‌باشد، معیار سنتی TF-IGM در فرآیند وزن‌دهی به کلمات از اطلاعات کلاس داده‌های آموزشی استفاده نمی‌کند و این اطلاعات را در فرآیند وزن‌دهی دخیل نمی‌کند، بنابراین وزن محاسبه شده نمی‌تواند به طور کامل نشان دهنده اهمیت کلمه در طبقه‌بندی متن باشد. در این پژوهش از یکی از نسخه‌های بهبودیافته TF-IGM که یک معیار وزن‌دهی با ناظر می‌باشد، استفاده می‌شود. در معیار وزن‌دهی TF-IGM تعداد حضور کلمات در کلاس‌های مثبت و منفی به صورت مجزا محاسبه شده و بیشترین مقدار برای محاسبه وزن استفاده می‌شود. هر کلمه در یک سند با یک مقدار TF-IGM شمارش می‌شود و سپس کلمات بر اساس بزرگ‌ترین مقدار مرتب می‌شوند. کلماتی که ارزش زیادی دارند به عنوان ویژگی برای ساخت مدل‌های طبقه‌بندی استفاده می‌شوند زیرا می‌توان فرض کرد که این کلمات حاوی معنای مهم یک سند با یک برچسب کلاس خاص هستند.

$$RTF_{IGM}(t_i) = \sqrt{TF(t_i, d_j) \times (1 + \lambda \times \frac{f_{i1}}{\sum_{r=1}^m f_{ir} \cdot r})} \quad (1)$$

در روابط فوق f_{ir} تعداد رخداد کلمه موردنظر در کلاس r ام است. m تعداد کلاس‌ها و $TF(t_i, d_j)$ تعداد رخداد کلمه موردنظر در سند d_j می‌باشد. و λ متغیری قابل تنظیم بین صفر تا ۱ است که یک تعادل نسبی بین وزن سراسری و محلی برقرار می‌کند. تنها تفاوت این دو معیار در مقدار TF است که در رابطه دوم ریشه آن در فرمول در نظر گرفته شده است. همچنین برخی از مطالعات نشان دادند، بین شخصیت و احساسات ارتباط وجود دارد. در مدل

این تابع باعث می‌شود که امتیاز بالاتر افزایش یابد و امتیاز پایین‌تر کاهش یابد، بنابراین به مدل اجازه می‌دهد تا در مورد کلمه مورد نظر مطمئن‌تر باشد. تابع SoftMax و تابع کوچک شده با فرمول زیر نشان داده شده است.

$$\text{softmax}_{ab} \left(q_{ij}^T k_{ab} \right) \quad (7)$$

در مرحله پنجم وزن توجه با بردار Value ضرب می‌شوند تا بردار خروجی به دست آید. امتیاز SoftMax بالاتر باعث می‌شود مدل یاد بگیرد که ارزش بالاتر کلمات به معنای مهم‌تر بودن است. نمرات پایین‌تر نیز به معنای کلمات نامربوط است که حذف می‌شوند.

$$y_{ij} = \sum_{a,b \in N_k(i,j)} \text{softmax}_{ab} (q_{ij}^T k_{ab}) v_{ab} \quad (8)$$

در مرحله آخر، بردارهای ارزش وزنی را که در مرحله قبل به دست آوردیم، جمع می‌کنیم، این خروجی توجه خود را برای کلمه داده شده، می‌دهد.

$$y_{ij} = \sum_{a,b \in N_k(i,j)} \text{softmax}_{ab} (q_{ij}^T k_{ab} + q_{ij}^T r_{a-i,b-j}) v_{ab} \quad (9)$$

رویه بالا برای تمام توالی‌های ورودی اعمال می‌شود. این مقدار نهایی با ویژگی‌های آماری ذکر شده در قسمت قبل ترکیب شده و در مجموع ۶۲۳ ویژگی به عنوان ورودی به یک شبکه پیشخور وارد می‌شود. هر شبکه از سه لایه متصل با تابع فعال‌سازی ReLU و نرمال‌سازی دسته‌ای تشکیل شده است (شکل ۴).

در این مطالعه از یک تابع Dropout نیز به منظور کاهش Overfitting و خطای تعمیم استفاده شده است. بدین ترتیب در هر دور آموزش، به جای استفاده از همه نورون‌ها، تنها برخی از نورون‌ها با احتمال p فعال شدند تا شبکه‌ها با هم تفاوت داشته باشند.

برای به حداکثر رساندن عملکرد مدل معرفی شده، از فرآیند تنظیم پارامترها، برای برخی از پارامترها نظیر اندازه دسته، دوره و نرخ یادگیری استفاده خواهیم کرد. برای این مهم از روش جستجوی شبکه‌ای برای انجام جستجوهای مکرر در یافتن پارامترهای بهینه استفاده می‌شود که حداکثر سطح عملکرد پیش‌بینی را ایجاد می‌کند.

Embedding های ایجاد شده، در مرحله استخراج ویژگی، قبل از ترکیب با ۱۱۱ ویژگی آماری، ابتدا به عنوان ورودی وارد مکانیزم توجه خود در هر یک از ۳ مدل برت، روبرتا و ایکس‌ال‌نت می‌شود. مکانیزم توجه به خود به مدل‌ها این امکان را می‌دهد که هر کلمه در ورودی را، به کلمات دیگر مرتبط کنند.

در این معماری برای دستیابی به مکانیزم خود توجه، ورودی را به سه لایه مجزا برای ایجاد بردارهای Query، Key و Value وارد می‌کنیم. اولین مرحله، ضرب هر یک از بردارهای ورودی با سه ماتریس وزنی (W_Q, W_K, W_V) است. این سه ماتریس در طول فرآیند آموزش مقداره‌ای می‌شوند. حاصل ضرب بردار ورودی در هر یک از این سه ماتریس، بردارهای Key، Query و Value را تشکیل می‌دهد.

$$\text{Query } q_{ij} = w_Q x_{ij} \quad (2)$$

$$\text{keys } k_{ab} = w_K x_{ab} \quad (3)$$

$$\text{value } v_{ab} = w_V x_{ab} \quad (4)$$


مرحله دوم در محاسبه مکانیزم خود توجه، ضرب بردار Query ورودی فعلی و بردار Key از ورودی‌های دیگر است. با ضرب ماتریسی این دو بردار، ماتریس امتیاز تولید می‌شود. ماتریس امتیاز میزان وابستگی هر کلمه را به کلمات دیگر تعیین می‌کند.

$$\text{Attention Score} = q_{ij}^T k_{ab} \quad (5)$$

در مرحله سوم مقدار امتیاز به دست آمده در فرآیند تقسیم بر جذر Query ابعاد و کلیدها (d_k) ، کوچک می‌شود. این فرآیند برای جلوگیری از اثر انفجاری بر روی مقدار امتیاز است، بنابراین گرادینان پایدارتر را ممکن می‌سازد و باعث می‌شود که برخی از امتیازات مکانیزم خود توجه، پس از اعمال تابع SoftMax در مراحل بعد، کوچک شوند.

$$\text{Scale}(x) = \frac{QK^T}{\sqrt{d_k}} \quad (6)$$

در مرحله چهارم، از تابع SoftMax، برای به دست آوردن وزن و دادن خروجی به شکل احتمال بین صفر و یک استفاده می‌شود. تابع SoftMax را بر روی تمام امتیازات مکانیزم خود، اعمال می‌کنیم. این تابع ورودی ماتریس خروجی را از تابع مقیاس شده (xi) و مجموع داده‌های داخل ماتریس (xj) دریافت می‌کند. به کارگیری



شکل ۴. نمایش خلاصه مدل پیشنهادی - داده‌های خام بعد از پیش پردازش وارد مرحله استخراج ویژگی شده و ویژگی‌های لازم با استفاده از سه مدل بَرت روبرتا و ایکس ال نت و ویژگی‌های آماری زبان (تحلیل احساسات، وزن دهی با معیار TF-IGM، تحلیل واژگان احساسی) از آنها استخراج می‌شود. سپس این ویژگی‌ها وارد سه شبکه پیشخور مجزا می‌شوند و در آخر با استفاده از میانگین‌گیری بدون وزن خروجی نهایی محاسبه خواهد شد.

$$y = \operatorname{argmax}(y_i^*, k) \quad (11)$$

۴- تجزیه و تحلیل داده‌ها

این فصل به مقایسه مدل ارائه شده با معماری‌های دیگری که با چندین روش استخراج ویژگی قادر به تولید بهترین پیش‌بینی‌های شخصیتی بودند، می‌پردازد. با این هدف، چندین سناریو شامل الگوریتم‌های مختلف به‌تنهایی و به همراه روش‌های استخراج ویژگی مختلف، برای تعیین عملکرد سیستم پیشنهادی استفاده شده است. به منظور در اختیار گرفتن یک افق دید مناسب برای ارزیابی نتایج از چند معیار ارزیابی شامل دقت و اندازه‌گیری معیار F1 استفاده شده است. با در نظر گرفتن هر کدام از این معیارها می‌توان ارزیابی مناسبی از نحوه عملکرد مدل پیشنهادی در اختیار داشت.

در نهایت، خروجی هر یک از سه شبکه پیشخور در یک تابع میانگین‌گیری گنجانده شده تا خروجی نهایی ایجاد گردد. بدین صورت که شبکه‌های عصبی استنتاج‌های خود را انجام می‌دهند و سپس از نتایج آن‌ها، میانگین‌گیری می‌شود. با توجه به کارهای صورت گرفته در مطالعات قبلی، در این تحقیق از روش میانگین‌گیری (بدون وزن) استفاده شده است. میانگین‌گیری از کلاس به صورت زیر محاسبه می‌شود. که در آن k تعداد کلاس‌ها و y برچسب شخصیتی پیش‌بینی شده برای یک ورودی است.

$$y_{i,k}^* = \frac{y_{i_1,k} + y_{i_2,k} + y_{i_3,k}}{3} \quad \forall k \in [1, \dots, k] \quad (10)$$

۴-۱- معیارهای ارزیابی

نتایج مدل ایجاد شده با استفاده از چندین روش اندازه‌گیری متریک به شرح زیر ارزیابی می‌شود:

۴-۱-۱- دقت - صحت - بازخوانی

معیار دقت، یکی از معیارهای ارزیابی عملکرد یک مدل در کلاس‌هایی با در داده‌های متعادل است. این معیار نسبت مقدار پیش‌بینی‌های درست را بر روی کل داده‌ها ارزیابی می‌کند.

$$Accuracy = \frac{TP + TN}{TN + TP + FN + FP} \quad (12)$$

این معیار، برای داده‌های نامتعادل یعنی داده‌هایی که تعداد برچسب‌های مثبت و منفی آن در دنیای واقعی از لحاظ عددی اختلاف بسیار زیادی دارند، معیار مناسبی نیست.

بر اساس تحقیقات قبلی، بسیاری از مدل‌های معرفی شده از این معیار اندازه به عنوان متریک ارزیابی استفاده کرده‌اند. بنابراین، برای مقایسه نتایج تحقیقات این مطالعه با مطالعات قبلی، از این متریک استفاده می‌شود

۴-۱-۲- اندازه‌گیری معیار F1

معیار F1، یک معیار مناسب برای ارزیابی دقت یک آزمایش است. این معیار Precision و Recall را با هم در نظر می‌گیرد. معیار F1 در بهترین حالت، یک و در بدترین حالت صفر است.

$$F1 \text{ Score} = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}} = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (13)$$

در این فرمول همانطور که مشاهده می‌کنید اگر یکی از دو مقدار عددی کوچک باشد، یا حتی صفر باشد، نتیجه نهایی عددی کوچک و یا صفر خواهد بود. توضیح این امر هم ساده است چون دو معیار بازخوانی و صحت اعدادی بین صفر تا یک هستند و در صورت کسر در هم دیگر ضرب شده‌اند بنابراین نتیجه نهایی به سمت عدد کوچک‌تر، متمایل خواهد بود و اگر هر دو با هم، عددی بزرگ (نزدیک ۱) باشند، نتیجه نهایی به سمت یک حرکت خواهد کرد.

۴-۲- سناریوهای بررسی شده

سناریوهای مختلفی در این پژوهش بررسی شده‌اند. ابتدا استفاده از مدل‌های از پیش آموزش دیده برت، روبرتا، و ایکس‌ال‌نت به طور

جداگانه مورد ارزیابی قرار گرفت. در گام بعد، تاثیر ویژگی‌های آماری NLP استخراج شده از پایگاه داده واژگان NRC، و احساسات استخراج شده از پست‌های کاربران و همچنین TF-IGM، شخصیت کاربران مورد بررسی قرار گرفت. در نهایت، معماری پیشنهادی که شامل ترکیب سه مدل برت، روبرتا و ایکس‌ال‌نت و ویژگی‌های آماری NLP است مورد ارزیابی قرار گرفت. جدول ۲ سناریوهای بررسی شده را نشان می‌دهد. هر یک از معماری‌های عمیق پیشنهادی با اندازه دسته و نرخ یادگیری متفاوت در مجموعه داده‌های رسانه‌های اجتماعی X تنظیم می‌شود.

در این پژوهش، تنظیم پارامترهای مدل شامل تعیین اندازه دسته و نرخ یادگیری با استفاده از اعتبارسنجی متقاطع انجام شد. تمام مدل‌های پیش‌بینی که ساخته شده‌اند با استفاده از معیارهای دقت و معیار F1 ارزیابی شده‌اند. نتایج ارزیابی مدل‌ها را می‌توانید در جداول ۶ و ۷ مشاهده کنید.

جدول ۲. سناریوهای بررسی شده

سناریو	مدل	اندازه دسته	نرخ آموزش
۱	برت	۱۶	۱,۰۰E±۰.۵
۲		۱۶	۳,۰۰E±۰.۵
۳		۳۲	۱,۰۰E±۰.۵
۴		۳۲	۳,۰۰E±۰.۵
۵	روبرتا	۱۶	۱,۰۰E±۰.۵
۶		۱۶	۳,۰۰E±۰.۵
۷		۳۲	۱,۰۰E±۰.۵
۸		۳۲	۳,۰۰E±۰.۵
۹	ایکس‌ال‌نت	۱۶	۱,۰۰E±۰.۵
۱۰		۱۶	۳,۰۰E±۰.۵
۱۱		۳۲	۱,۰۰E±۰.۵
۱۲		۳۲	۳,۰۰E±۰.۵
۱۳	برت + NLP	۱۶	۱,۰۰E±۰.۵
۱۴		۱۶	۳,۰۰E±۰.۵
۱۵		۳۲	۱,۰۰E±۰.۵
۱۶		۳۲	۳,۰۰E±۰.۵
۱۷	روبرتا + NLP	۱۶	۱,۰۰E±۰.۵
۱۸		۱۶	۳,۰۰E±۰.۵
۱۹		۳۲	۱,۰۰E±۰.۵
۲۰		۳۲	۳,۰۰E±۰.۵
۲۱	ایکس‌ال‌نت + NLP	۱۶	۱,۰۰E±۰.۵
۲۲		۱۶	۳,۰۰E±۰.۵
۲۳		۳۲	۱,۰۰E±۰.۵
۲۴		۳۲	۳,۰۰E±۰.۵
۲۵	مدل پیشنهادی (برت + روبرتا + ایکس‌ال‌نت + NLP)	۱۶	۱,۰۰E±۰.۵
۲۶		۱۶	۳,۰۰E±۰.۵
۲۷		۳۲	۱,۰۰E±۰.۵
۲۸		۳۲	۳,۰۰E±۰.۵

۳-۴- اعتبارسنجی

در این پژوهش از روش اعتبارسنجی 10 fold cross-validation برای کاهش خطر Overfitting استفاده شد. این روش یکی از روش‌های رایج برای ارزیابی عملکرد مدل‌های یادگیری ماشین است که به ویژه در مسائل داده‌ای با مجموعه داده‌های محدود مورد استفاده قرار می‌گیرد. این روش به صورت خاص برای ارزیابی دقت مدل به کار می‌رود و می‌تواند اطمینان بیشتری از کارایی مدل در داده‌های ناپایدار و مختلف فراهم کند. در اولین گام داده‌ها به ۱۰ بخش^۱ مساوی تقسیم می‌شوند. این بخش‌ها به گونه‌ای انتخاب می‌شوند که داده‌ها به طور تصادفی تقسیم شوند، به طوری که هر داده دقیقاً یکبار در داده‌های آزمایشی و چندین بار در داده‌های آموزشی استفاده شود. سپس مدل روی ۹ بخش از داده‌ها آموزش می‌بیند و سپس با استفاده از بخش باقی مانده ارزیابی می‌شود. این فرآیند ۱۰ بار تکرار می‌شود، به طوری که هر بخش به طور جداگانه برای تست مدل استفاده می‌شود. پس از انجام ارزیابی برای هر ۱۰ بخش، دقت و F1-score از هر مرحله محاسبه می‌شود و سپس میانگین این نتایج به عنوان عملکرد کلی مدل گزارش می‌شود. این روش کمک می‌کند تا ارزیابی دقیق‌تری از مدل به دست آید و از اثرات احتمالی داده‌های خاص^۲ جلوگیری شود.

۴-۴- نتایج استفاده از مجموعه MBTI500

جدول ۳ نتایج ارزیابی برای مجموعه داده MBTI500 را نشان می‌دهد. همانگونه که مشاهده می‌شود، مدل پیشنهادی، که از روش میانگین‌گیری مدل‌ها و ویژگی‌های آماری NLP استفاده کرده، بالاترین دقت را ارائه می‌دهد. در بعد شخصیتی درون‌گرا و یا برون‌گرا بودن مدل ارائه شده توانسته است به دقت ۹۰٫۲۵٪ و معیار F1 برابر با ۰٫۹۱۲ دست یابد. در ویژگی حسی و شهودی بودن نیز با دقت ۷۸٫۲۱٪ و معیار F1 برابر با ۰٫۷۰۹ عملکرد خوبی را نمایش داده است. برای ویژگی فکری و احساسی، مدل XLNet همراه با ویژگی‌های NLP دقت بالاتری از مدل پیشنهادی دارد، اما تفاوت‌ها جزئی هستند. (حدود ۰٫۷۴٪ در دقت و ۰٫۰۱۱ در معیار F1).

به‌طور کلی، میانگین دقت و معیار F1 نشان می‌دهد که معماری پیشنهادی با میانگین دقت ۸۵٫۴۶٪ و معیار F1 برابر با ۰٫۸۳۹۵ بهترین عملکرد را در پیش‌بینی شخصیت برای مجموعه داده MBTI500 ارائه داده است.

۴-۴-۱- نتایج استفاده از مجموعه MBTI1

جدول ۴ نتایج ارزیابی برای مجموعه داده MBTI1 را نشان می‌دهد. مشابه نتایج قبلی، مدل پیشنهادی بالاترین دقت و معیار F1 را ارائه داده و بهترین عملکرد را در پیش‌بینی ویژگی‌های شخصیتی دارد. بالاترین دقت تولید شده برای شناسایی هر بعد شخصیتی متعلق به مدل پیشنهادی این پژوهش است. بالاترین دقت در بعد درون‌گرا یا برون‌گرا ۱۷٫۸۹٪ می‌باشد. در بعد حسی یا شهودی دقت برابر ۸۷٫۹۸٪ می‌باشد. بعد فکری یا احساسی در مدلی که با استفاده از ایکس‌ال‌نت با افزودن ویژگی‌های NLP ایجاد می‌شود دارای دقت ۸۵٫۳۱٪ و امتیاز F1 ۰٫۹۳۷۵ است که نسبت به سایر مدل‌ها در این بعد پیشرفت خوبی دارد. در بعد ساختارگرا و منعطف مدل روبرتا با افزودن ویژگی‌های NLP توانسته است این بعد را به دقت ۷۰٫۸۷۴٪ و امتیاز F1 ۰٫۷۹۸۷ برساند.

در بررسی امتیاز F1 نتایج متفاوتی بدست آمد که این مهم به علت نامتوازن بودن داده‌های ورودی و متفاوت بودن فرمول محاسبه F1 است. بیشترین امتیاز F1 متعلق به گروه فکری/احساسی با امتیاز ۰٫۹۳۷۵ با استفاده از ایکس‌ال‌نت با افزودن ویژگی‌های NLP ایجاد شد. سپس در بعد شخصیتی درون‌گرا و یا برون‌گرا امتیاز بدست آمده ۰٫۸۸۲ می‌باشد. بعد ویژگی حسی/شهودی نیز در مقام سوم به امتیاز ۰٫۸۵۳ دست یافت.

۴-۵- تنظیم پارامترها

با توجه به اینکه اکثر یا همه مقالات از تکنیک‌های رایج برای تنظیم و بهینه‌سازی پارامترهای مدلشان استفاده کرده‌اند و به هدف اینکه مقایسه‌های انجام شده عادلانه باشد در این پژوهش ما نیز از روش جستجوی شبکه‌ای برای تنظیم پارامترهای مدل پیشنهادی خودمان استفاده کردیم. نتایج نشان می‌دهد که مدل مورد استفاده برای پیش‌بینی بعد شخصیتی درون‌گرا یا برون‌گرا و بعد شخصیتی ساختارگرا یا منعطف در هر دو مجموعه داده، اندازه دسته ۱۶ است. حال آنکه برای سایر صفات باقی‌مانده با اندازه دسته ۳۲ نتیجه بهینه دسته‌بندی را بدست می‌آورند. در مورد میزان یادگیری، همه صفات به جز بعد ویژگی فکری یا احساسی از نرخ یادگیری 3×10^{-5} برای عملکرد بهینه استفاده می‌کنند. در حالی که بعد ویژگی فکری یا احساسی در نرخ یادگیری 1×10^{-5} عملکرد بهینه خود را نشان داده است (جدول ۵).

² Bias

¹ Fold

جدول ۳. دقت شناسایی ابعاد شخصیتی در مجموعه داده MBTI

بعد شخصیتی		درون گرا / برون گرا	حسی / شهودی	فکری / احساسی	ساختار گرا / منعطف
برت	دقت	۷۶,۳۵	۷۸,۳۶	۸۲,۶۹	۶۳,۲۵
	F1	۰,۷۳۵	۰,۸۲۰۳	۰,۸۵۰۶	۰,۷۳۸۵
روبرتا	دقت	۸۲,۳۶	۷۳,۲۵	۷۹,۴۸	۶۶,۵۳
	F1	۰,۸۵۳۶	۰,۷۹۲۵	۰,۷۶۹۸	۰,۶۹۲۳
ایکس‌ال‌نت	دقت	۷۶,۱۴	۷۱,۴۶	۸۲,۶۷	۶۸,۷۸
	F1	۰,۷۵۶۹	۰,۷۶۸۵	۰,۷۹۲۶	۰,۶۹۶۹
برت + NLP	دقت	۸۹,۵۶	۷۳,۶۹	۸۹,۸۴	۷۳,۹۲
	F1	۰,۹۰۲۷	۰,۸۳۴۸	۰,۹۰۰۲	۰,۷۶۰۰
روبرتا + NLP	دقت	۷۳,۸۴	۶۳,۵۸	۷۹,۶۳	۸۹,۳۵
	F1	۰,۷۸۹۶	۰,۶۹۳۲	۰,۸۴۵۹	۰,۸۱۲۶
ایکس‌ال‌نت + NLP	دقت	۸۰,۴۶	۶۹,۵۹	۹۲,۹۳	۷۹,۸۹
	F1	۰,۷۹۶۵	۰,۷۸۶۹	۰,۹۱۷۵	۰,۸۰۰۶
مدل پیشنهادی	دقت	۹۰,۲۵	۷۸,۳۱	۹۲,۱۹	۸۱,۲۲
	F1	۰,۹۱۲	۰,۷۰۹	۰,۹۰۶۵	۰,۸۳۰۸

جدول ۴. دقت شناسایی ابعاد شخصیتی در مجموعه داده MBTI500

بعد شخصیتی		درون گرا / برون گرا	حسی / شهودی	فکری / احساسی	ساختار گرا / منعطف
برت	دقت	۷۸,۸۵	۷۶,۳۰	۷۶,۱۲	۶۷,۲۱
	F1	۰,۷۴۰	۰,۷۳۵	۰,۷۴۱	۰,۷۲۰
روبرتا	دقت	۷۷,۵۶	۷۶,۱۵	۷۵,۷۴	۶۷,۶۵
	F1	۰,۷۴۰	۰,۷۳۵	۰,۷۴۱	۰,۷۲۰
ایکس‌ال‌نت	دقت	۷۸,۶۷	۷۶,۶۵	۷۸,۵۲	۶۷,۶۸
	F1	۰,۷۵۰	۰,۷۶۰	۰,۷۸۹	۰,۶۹۳
برت + NLP	دقت	۸۶,۳۹	۸۵,۵۸	۸۲,۳۶	۷۲,۵۷
	F1	۰,۸۰۲	۰,۸۱۵	۰,۸۴۸	۰,۷۹۵
روبرتا + NLP	دقت	۸۴,۰۱	۸۴,۲۱	۸۲,۲۴	۷۹,۸۴
	F1	۰,۸۱۸	۰,۷۴۵	۰,۸۶۵	۰,۷۸۷
ایکس‌ال‌نت + NLP	دقت	۸۴,۳۵	۸۴,۴۲	۸۵,۳۱	۷۲,۸۷
	F1	۰,۷۹۹	۰,۷۹۵	۰,۹۳۷۵	۰,۷۹۵
مدل پیشنهادی	دقت	۸۹,۱۷	۸۷,۹۸	۸۳,۱۹	۷۷,۴۲
	F1	۰,۸۸۲	۰,۸۵۳	۰,۹۰۵	۰,۸۳۷

جدول ۵. اندازه دسته و نرخ آموزش مناسب برای هر بعد از ویژگی

ابعاد شخصیت	اندازه دسته	نرخ آموزش
درون گرا / برون گرا	۱۶	۳,۰۰E-۰۵
حسی / شهودی	۳۲	۳,۰۰E-۰۵
فکری / احساسی	۳۲	۱,۰۰E-۰۵
ساختار گرا / منعطف	۱۶	۳,۰۰E-۰۵

با مشاهده میانگین دقت تمامی آزمایش‌ها بر روی هر الگوریتم، مشخص شد که معماری مدل پیشنهادی بالاترین میانگین دقت و امتیاز F1 را دارد که برای سیستم پیش‌بینی شخصیت با استفاده از مجموعه داده انتخابی مدل مناسبی است.

علاوه بر این، نتایج بیان می‌کند که تمام طبقه‌بندها با ویژگی‌های

NLP در مقایسه با ویژگی‌های مدل از پیش آموزش‌دیده فردی عملکرد بهتری دارند. این بدان معناست که ارائه ویژگی‌های NLP عملکرد مدل را در پیش‌بینی ویژگی‌های شخصیتی افزایش می‌دهد.

در نهایت، برای مقایسه عملکرد کلی سیستم، نتایج به دست آمده از مدل پیشنهادی در این مطالعه را با چهار تحقیق از جدیدترین و برترین تحقیقات اخیر در جدول ۶ ارائه شده گردید. با تجزیه و تحلیل این مقادیر، می‌توان نتیجه گرفت که معماری یادگیری عمیق پیشنهادی قادر است در بعد های درون‌گرا/ برون‌گرا و فکری/ احساسی از سایر مقالات مشابه که روی همین مجموعه داده کار شده‌اند، بهتر عمل کند و دقت بالاتری را بدست آورد.

مدل ارائه شده در جدول ۶ عموماً از الگوریتم‌ها ترکیبی یادگیری ماشین کلاسیک و روش‌های یادگیری عمیق هستند. اگرچه این الگوریتم‌ها نتایج خوب و مفیدی را ارائه کردند، اما هنوز در طبقه‌بندی نوع شخصیت افراد بر اساس شاخص مایرز بریگز در بعضی از ابعاد شخصیتی نسبتاً غیرمعمول هستند. همانگونه که مشخص است مدل پیشنهادی در این مطالعه در اکثر بعدهای شخصیتی از تحقیقات اخیر بهتر عمل کرده و دقت بالاتری دارد.

جدول ۶. دقت به دست آمده در چند مطالعه اخیر و مقایسه

با دقت به دست آمده در روش پیشنهادی این مطالعه

منبع	تکنیک استفاده شده	E/I	S/N	T/F	J/P
[17]	CNN + LSTM	٪۸۸	٪۸۶	٪۸۹	٪۸۷
[18]	LSTM+ Word2Vec	٪۸۲	٪۸۴	٪۸۳	٪۸۵
[19]	SMOTE	٪۸۳	٪۸۴	٪۸۵	٪۸۴
[20]	BERT	٪۹۱	٪۸۹	٪۹۲	٪۹۰
مدل پیشنهادی					
		٪۹۰,۲۵	٪۷۸,۳۱	٪۹۲,۱۹	٪۸۱,۲۲

۵- نتیجه‌گیری

در این پژوهش سعی شده تا با ارائه روشی نوین و به‌کارگیری تکنیک‌های جدید یادگیری ماشین و پردازش زبان‌های طبیعی رویکرد جدیدی را در بالا بردن دقت تشخیص شخصیت افراد از روی متون انتشار یافته توسط آن‌ها در شبکه اجتماعی X ارائه دهد.

تحقیقات ما نشان می‌دهد که در برخورد با یک مجموعه داده MBTI نامتعادل به عنوان مسئله NLP طبقه‌بندی چند کلاسه، با استفاده از مدل‌های از پیش آموزش‌دیده، رویکرد ترکیب هر سه مدل از پیش آموزش دیده شده به همراه ترکیب با ویژگی‌های NLP، نتایج بهتری نسبت به مدل پایه و سایر روش‌های پیاده‌سازی شده در تحقیق ما ارائه می‌دهد. این بدان معناست که ارائه ویژگی‌های NLP عملکرد

- [6] M. Sahono, F. Sidiastahta, G. Shidik, A. Fanani, M. Muljono, S. Nuraisha and E. Lutfina, Extrovert and Introvert Classification based on Myers-Briggs Type Indicator(MBTI) using Support Vector Machine (SVM), 2020/09/19, pp. 572-577.
- [7] K. Orynbekova, A. Talasbek, A. Omar, A. Bogdanchikov, and S. Kadyrov, MBTI personality classification using Apache Spark, 2021, pp. 1-4.
- [8] N. Čerkez; V. Vareškić, "Machine Learning Approaches to Personality Classification on Imbalanced MBTI Datasets," 2021.
- [9] P. Kumar R, B. Mohan G and G. D. Sai, Ensemble Machine Learning Models in Predicting Personality Traits and Insights using Myers-Briggs Dataset, 2023, pp. 1-7.
- [10] J. Serrano-Guerrero, B. Alshouha, M. Bani-Doumi, F. Chiclana and F. P. R. a. J. A. Olivas, "Combining machine learning algorithms for personality trait prediction," *Egyptian Informatics Journal*, vol. 25, p. 100439, 2024.
- [11] Kazemeini, Amirmohammad and Fatehi, Samin and Mehta, Yash and Eetemadi, Sauleh and Cambria, Erik, "Personality Trait Detection Using Bagged SVM over BERT Word Embedding Ensembles," 07 2020.
- [12] Kamal El-Demerdash and Reda A. El-Khoribi and Mahmoud A. and Sherif Abdou, "Deep learning based fusion strategies for personality prediction," *Egyptian Informatics Journal*, vol. 23, pp. 47-53, 2022.
- [13] H. Ahmad, M. Asghar, M. Asghar, A. Khan and A. Mosavi, "A Hybrid Deep Learning Technique for Personality Trait Classification From Text," *IEEE Access*, vol. 9, pp. 146214-146232, 2021.
- [14] Sakdipat Ontoum, Jonathan H. Chan, "Personality Type Based on Myers-Briggs Type Indicator with Text Posting Style by using Traditional and Deep Learning," *CoRR*, vol. abs/2201.08717, 2022.
- [15] M. A. Teli and M. A. Chachoo, "Pre-trained Word Embeddings In Deep Multi-label Personality Classification Of YouTube Transliterations," in *2023 International Conference on Intelligent Systems, Advanced Computing and Communication (ISACC)*, 2023, pp. 1-6.
- [16] Bhardwaj, Harshit, Pradeep Tomar; Aditi Sakalle; Divya Acharya; Tapas Badal; Arpit Bhardwaj, "A DeepLSTM Model for Personality Traits Classification Using EEG Signals.," *IETE Journal of Research*, vol. 69, pp. 7272--7280, 2023.
- [17] Sirasapalli, Joshua ; Malla, Ramakrishna, "A deep learning approach to text-based personality prediction using multiple data sources mapping," *Neural Computing and Applications*, vol. 35, pp. 1-12, 2023.
- [18] Mohan, G Bharathi;Kumar, R Prasanna;R, Elakkiya;Gorantla, Sneetha, "Enhancing Personality Classification through Textual Analysis: A Deep Learning Approach Utilizing MBTI and Social Media Data," in *2023 International Conference on Network, Multimedia and Information Technology (NMITCON)*, 2023, pp. 01-06.
- [19] Ryan, Gregorius; Pricillia Katarina; Derwin Suhartono., "MBTI Personality Prediction Using Machine Learning and SMOTE for Balancing Data Based on Statement Sentences," *Information 14*, vol. 4, 2023.
- [20] N. Ashraf, R. qbal, S. Bano, H. M. Azeem and S. Naz, "Enhancing MBTI Personality Prediction from Text Data with Advance Word Embedding Technique.," *VFAST Transactions on Software Engineering*, p. 35, 08 12 2024.

[۲۱] مریم طایفه محمودی، امیرمنصور یادگاری، پروین احمدی، کامبیز بدیع، "افقی برای تحلیل سنجمان در شبکه‌های اجتماعی بر مبنای تفسیر محتوا"، *فصلنامه فناوری اطلاعات و ارتباطات ایران*، صفحات ۷۱ تا ۸۳ سال ۱۴۰۳.

[۲۲] محمدجواد شایگان فرد، محدثه ولی زاده م. شایگان فرد و م. ولی زاده، "یک سیستم توصیه گر بر اساس تحلیل ویژگی شخصیتی افراد در شبکه اجتماعی تلگرام"، *فصلنامه فناوری اطلاعات و ارتباطات ایران*، صفحات ۳۰۵ تا ۳۲۰ سال ۱۴۰۳.

مدل را در پیش‌بینی ویژگی‌های شخصیتی افزایش می‌دهد

این مهم به روانشناسان و اشخاص دیگر کمک می‌کند تا بدون صرف هزینه و وقت زیاد با بالاترین دقت به شخصیت مراجعین خود دسترسی داشته باشند. در این پژوهش ویژگی‌های مختلفی از افراد براساس پست‌های آن‌ها در شبکه اجتماعی X و به منظور پیش‌بینی شخصیت MBTI آن‌ها بررسی شد.

معماری یادگیری عمیق پیشنهادی با ترکیب مدل‌های برت، روبرتا، و ایکس‌ال‌نت به‌عنوان مدل زبان از پیش آموزش‌دیده از ویژگی‌های آماری استخراج شده استفاده می‌کند و نتیجه نهایی بر اساس میانگین‌گیری از نتایج سه مدل به کار رفته برت روبرتا و ایکس‌ال‌نت با تولید بالاترین دقت در هر چهار بعد و همچنین بالاترین امتیاز در معیار F1 بهتر از اکثر مدل‌های شخصیتی است که توسط کارهای قبلی ارائه شده است. علاوه بر این، افزودن ویژگی‌های آماری مانند TF-IGM، احساسات متن و پایگاه داده واژگان NRC به طور قابل توجهی به سیستم پیش‌بینی شخصیت در مجموعه داده‌ها کمک کرد و توانست عملکرد مدل را در مقایسه با استفاده از مدل‌های صرفاً از پیش آموزش‌دیده افزایش دهد.

ارزیابی نتایج حاصل از اجرای آزمایش‌ها بر مجموعه داده‌های معیار نشان می‌دهد مدل پیشنهادی می‌تواند به طور مؤثر ویژگی‌های شخصیتی کاربر را در مقایسه با تکنیک‌های پیشرفته استخراج نماید. به طور دقیق‌تر، شناسایی شخصیت افراد با دقت ۸۸٫۵٪ و امتیاز اندازه‌گیری F1 برابر ۰٫۸۸۲ برای یک مجموعه داده و میانگین دقت ۸۵٫۴۶٪ و معیار F1 برابر ۰٫۸۳۹۵ برای مجموعه داده دیگر انجام شده است.

مراجع

- [1] Majumder, Navonil and Poria, Soujanya and Gelbukh, Alexander and Cambria, Erik, "Deep Learning-Based Document Modeling for Personality Detection from Text," *IEEE Intelligent Systems*, vol. 32, pp. 74-79, 03 2017.
- [2] Xue, Di and Hong, Zheng and Guo, Shize and Gao, Liang and Wu, Lifa and Zheng, Jinghua and Zhao, Nan, "Personality Recognition on Social Media With Label Distribution Learning," *IEEE Access*, vol. 5, pp. 13478-13488, 2017.
- [3] Chaehan So, "Are You an Introvert or Extrovert? Accurate Classification With Only Ten Predictors," in *2020 International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, Fukuoka, Japan, 19-21 February 2020.
- [4] B. Fieri, J. La'la and D. Suhartono, "Introversion-Extraversion Prediction using Machine Learning," *INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION journal homepage: www.joiv.org/index.php/joiv INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION*, pp. 2154-2160, 2021.
- [5] Sandhya Katiyar, Sanjay Kumar, Himdweep Walia, "Personality Prediction from Stack Overflow by using Naïve Bayes Theorem in Data Mining," *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, vol. 9, no. 3, pp. 1555-1559, 2020.

- Dynamic Optimization for Graph-Based Personality Detection," 2025.
- [26] Kourosh Shahnazari;Seyed Moein Ayyoubzadeh, "Who Are You Behind the Screen? Implicit MBTI and Gender Detection Using Artificial Intelligence," *arxiv*, 2025.
- [27] Luisa Stracqualursi;Patrizia Agati, "Predicting MBTI personality of YouTube users," *Scientific Reports*, vol. 15, 2025.
- [23] Linmei Hu;Hongyu He;Duokang Wang;Ziwan Zhao;Yingxia Shao;Liqiang Nie, "LLMvsSmall Model? Large Language Model Based Text Augmentation Enhanced Personality Detection Model," *Computation and Language*, 2024.
- [24] Haohao Zhu;Xiaokun Zhang;Junyu Lu;Youlin Wu;Zewen Bai;Changrong Min;Liang Yang;Bo Xu; Dongyu Zhang ;Hongfei Lin, "Enhancing Textual Personality Detection toward Social Media: Integrating Long-term and Short-term Perspectives," 2024.
- [25] Lingzhi Shen, Yunfei Long, Xiaohao Ca; Guanming Chen;Yuhan Wang; Imran Razzak;Shoaib Jameel, "LL4G: Self-Supervised

UsERQA: An LLM-Driven User-Aware Community Question Answering System

Seyyede Zahra Aftabi¹, Saeed Farzi^{1*}

¹ Faculty of Computer Engineering, K. N. Toosi University of Technology, Tehran, Iran

Received: 09 September 2024, Revised: 05 February 2025, Accepted: 16 February 2025
Paper type: Research

Abstract

In the present era, question-and-answer communities have become vibrant platforms for sharing knowledge. Every year, millions of questions are posted on these forums with the hope of receiving answers from human experts. Nonetheless, many of these questions fail to receive timely or accurate answers due to experts' limited time or being duplicates. In recent years, a large body of research has focused on identifying entailed questions within community archives and using their accepted answers to fulfill the information needs of newly posed questions. Most of these studies match questions syntactically and semantically while resorting to external knowledge injection or increased model complexity to enhance question understanding. However, the critical role that the topics typically explored by questioners play in disambiguating their queries has been overlooked. This research addresses this gap by introducing UsERQA, a novel retrieval-augmented generation (RAG)-based question-answering system incorporating user knowledge. UsERQA utilizes large language models to represent the questioner's knowledge as a sequence of topical tags. In addition, it employs a question entailment recognition process as a post-retrieval strategy, with a new constraint, mandating the alignment between entailed questions and the questioner's knowledge. Afterward, another large language model generates the final answer using the accepted answers of top entailed questions as context. The goal is to imitate human writing patterns and leverage the knowledge contained in human responses to produce high-quality answers. Experimental results on the CQAD-ReQuEST dataset indicate the efficiency of UsERQA in modeling user knowledge and producing more accurate responses than its user-agnostic counterpart.

Keywords: Community question answering systems, Answer generation, Recognizing question entailment, User modeling, Query-focused multi-document summarization.

* Corresponding Author's email: saeedfarzi@kntu.ac.ir

UsERQA: سیستم پاسخ‌گویی به پرسش‌های انجمن آگاه به کاربر مبتنی بر مدل‌های زبانی بزرگ

سیده زهرا آفتابی^۱، سعید فرضی^{*۱}

^۱ دانشکده مهندسی کامپیوتر، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۶/۱۹ تاریخ بازبینی: ۱۴۰۳/۱۱/۱۷ تاریخ پذیرش: ۱۴۰۳/۱۱/۲۸

نوع مقاله: پژوهشی

چکیده

در عصر حاضر، انجمن‌های پرسش و پاسخ، به بسترهایی پویا برای تبادل دانش بدل شده‌اند. سالانه میلیون‌ها پرسش به امید دریافت پاسخ از متخصصین، راهی این انجمن‌ها می‌شوند. اما شمار زیادی از آنها به دلیل محدودیت زمان و منابع متخصصین یا داشتن محتوای تکراری، از دریافت پاسخ صحیح و زودهنگام بی‌نصیب می‌مانند. در این راستا، مطالعات بسیاری به شناسایی پرسش‌های با مضمون مشابه پرسش ورودی در بایگانی انجمن و بهره‌مندی از پاسخ‌های تأییدشده آنها جهت رفع نیاز اطلاعاتی پرسش پرداخته‌اند. عمده این پژوهش‌ها، از تطابق ویژگی‌های نحوی و معنایی زوج پرسش استفاده نموده و برای درک بهتر پرسش‌ها، به تزریق دانش خارجی یا افزایش پیچیدگی مدل متوسل شده‌اند. در این میان، نقش کلیدی دایره موضوعات مورد مطالعه پرسشگر در رفع ابهام از محتوای پرسش مغفول مانده‌است. پژوهش حاضر با ارائه یک سیستم مولد بازبازی‌افزوده برای پاسخگویی به پرسش‌ها موسوم به UsERQA که مبتنی بر مدل‌سازی دانش پرسشگر است، به رفع این شکاف تحقیقاتی می‌پردازد. UsERQA با بهره‌گیری از مدل‌های زبانی بزرگ، دانش پرسشگر را به‌صورت دنباله‌ای از برچسب‌های موضوعی توصیف نموده و شرط همسو بودن پرسش‌های متضمن با دانش پرسشگر را به فرآیند شناسایی پرسش‌های متضمن که یک فرآیند پسابازایی است می‌افزاید. سپس، یک مدل زبانی دیگر، به تولید پاسخی واحد بر پایه برترین پاسخ‌ها مبادرت می‌ورزد. به موجب این فرآیند می‌توان از سبک نوشتاری و دانش نهفته در پاسخ‌های انسانی، جهت تولید پاسخ باکیفیت، الگوبرداری کرد. نتایج آزمایش‌ها روی دادگان CQAD-ReQuEST، عملکرد موفق UsERQA در مدل‌سازی کاربر و بهبود کیفیت پاسخ‌ها نسبت به مدل مستقل از کاربر را نشان داد.

کلیدواژگان: سیستم‌های پاسخگویی به پرسش‌های انجمن، تولید پاسخ، شناسایی پرسش‌های متضمن، مدل‌سازی کاربر، خلاصه‌سازی چندسندی متمرکز بر پرسمان.

* رایانامه نویسنده مسؤول: saeedfarzi@kntu.ac.ir

۱- مقدمه

در دو دهه گذشته، با ظهور و توسعه انجمن‌های پرسش و پاسخ، تحول شگرفی در عرصه بازیابی اطلاعات و تبادل دانش به وجود آمده است. از جمله انجمن‌های محبوب در زبان انگلیسی می‌توان Stack Overflow، Quora و iCliniq را نام برد. کاربران این انجمن‌ها قادرند نیاز اطلاعاتی خود را در قالب پرسش‌هایی به زبان طبیعی مطرح نموده و پاسخ‌ها و دیدگاه‌های مختلف را از سایر کاربران انجمن، که از این پس با عنوان متخصص از آنها یاد می‌شود، دریافت نمایند [۱]. به محض آنکه پرسشگر، یکی از پاسخ‌های دریافتی را به عنوان بهترین پاسخ تأیید نماید، پرسش، حل شده^۱ تلقی شده و در بایگانی^۲ انجمن ذخیره می‌شود [۱-۴]. به این ترتیب، با گذر زمان، بایگانی انجمن به مخزنی غنی از اطلاعات مبدل می‌گردد.

بقای یک انجمن پرسش و پاسخ در گرو جلب رضایت کاربران و ترغیب آنها به مشارکت بیشتر است. در این راستا، سرعت حصول پاسخ و صحت پاسخ، دو رکن اصلی برای رضایت کاربران محسوب می‌شوند. این در حالیست که مطابق آمار منتشر شده از انجمن‌های مختلف، سالانه شمار زیادی از پرسش‌ها از دریافت پاسخ بی‌بهره می‌مانند [۵، ۶]. حال آنکه برای بسیاری از پرسش‌های جدیدالورود، پرسش‌های متضمنی^۳ در بایگانی انجمن وجود دارند که پیش‌تر، پاسخ صحیحی دریافت نموده‌اند [۷، ۸]. یک پرسش متضمن، پرسشی با معنای مشابه است که پاسخ صحیح ارائه‌شده برای آن می‌تواند به عنوان یک پاسخ صحیح کامل یا بخشی از پاسخ صحیح برای پرسش جدید نیز ارائه گردد [۹]. از این رو، انجمن‌ها، کاربران‌شان را به جستجو برای پرسش‌های متضمن و مطالعه پاسخ‌های آنها پیش از اقدام به ثبت یک پرسش جدید تشویق می‌کنند. با این وجود، بسیاری از کاربران، علیرغم صرف زمان قابل توجه برای جستجو، در دستیابی به پاسخ ناکام مانده و با این باور که پرسش آنها منحصر به فرد است، به ثبت پرسش‌های تکراری^۴ مبادرت می‌ورزند [۱۰، ۱۱]. انباشت تدریجی پرسش‌های تکراری نیز تلاش مضاعف متخصصین برای پاسخگویی و افزایش زمان انتظار کاربران برای دریافت پاسخ را در پی دارد. به همین علت، ساخت و توسعه سیستم‌های شناسایی پرسش‌های متضمن^۵ (RQE) که قادر باشند در سریع‌ترین زمان ممکن، فهرستی از پرسش‌های متضمن را بازیابی نمایند، به یکی از حوزه‌های تحقیقاتی پرمخاطب مبدل گشته است [۸، ۱۰-۱۶].

شناسایی پرسش‌های متضمن در میان انبوه پرسش‌های بایگانی، به این دلیل که افراد مختلف، پرسش‌های مشابه را با واژگان و ساختارهای زبانی متفاوت بیان می‌کنند [۱۰، ۱۷، ۱۸]، فرآیندی سخت و پیچیده است. مثال ۲ در جدول ۱، دو پرسش را نمایش می‌دهد که فاقد همپوشانی واژگانی^۶ بوده اما از نظر معنایی، متضمن یکدیگر می‌باشند. در حالتی دیگر، مطابق مثال ۳، دو پرسش ممکن است با وجود همپوشانی واژگانی، متضمن یکدیگر نباشند. در این راستا، اکثر پژوهش‌ها از مقایسه واژگان و ساختارهای نحوی زوج پرسش فراتر رفته و تمرکز خود را بر درک عمیق‌تر معانی، با تکیه بر اطلاعات بافتاری^۷ [۱۹-۲۲] و منابع دانش خارجی [۲۳-۲۶] معطوف نموده‌اند. با این وجود، مروری بر مطالعات انجام شده در این حوزه، وجود یک شکاف تحقیقاتی، مبنی بر نادیده گرفته شدن دانش و علایق کاربران در فرآیند بازیابی پرسش‌های متضمن را هویدا می‌سازد.

جدول ۱. نمونه‌هایی از زوج پرسش‌های متضمن و غیرمتضمن

مثال ۱. برچسب: متضمن

1. Why did they cut out the expanding granuloma which was due to Coccidiomycosis immitis, rather than just treat it medically?
2. Why did they cut out the Coccidiomycosis granuloma rather than treat it medically?

مثال ۲. برچسب: متضمن

1. Is this statement: "the letters have been troubling me since over a year" grammatically correct? Or should I instead use: "...for over a year".
2. Since is used to refer to a point of time in the past and for is used with time interval. However I've come across this phrase: "I haven't seen you since ages." Is this a correct usage of "since" since ages denotes an interval of time?

مثال ۳. برچسب: غیرمتضمن

1. Is this statement: "the letters have been troubling me since over a year" grammatically correct? Or should I instead use: "...for over a year".
2. My student writes a statement like this: "She hasn't gone out with him since one year ago." so, I want to know if this sentence is correct or wrong grammatically.

پژوهش حاضر بر آن است تا از زمینه‌های موضوعی مورد علاقه پرسشگر که به‌طور مکرر به جستجو پیرامون آنها می‌پردازد، به عنوان دانش کمکی جهت شناسایی دقیق‌تر پرسش‌های متضمن بهره‌مند گشته و بدین وسیله، صحت پاسخ‌های تولید شده برای کاربر را بهبود بخشد. برای این منظور، یک سیستم جامع پاسخگویی به پرسش با نام UserQA^۸، متشکل از زنجیره‌ای از مدل‌های زبانی بزرگ، ارائه شده است. این سیستم در چهار مؤلفه اصلی خود به مدل‌سازی دانش پرسشگر براساس سوابق فعالیت‌های وی در انجمن، بازیابی فهرستی از پرسش‌های مرتبط با پرسش ورودی، شناسایی برترین پرسش‌های متضمن در میان پرسش‌های بازیابی‌شده و در پایان، ارائه یک پاسخ

^۵ Recognizing question entailment (RQE)^۶ Word overlap^۷ Contextual^۸ User-aware Entailment Recognition-based Question Answering^۱ Resolved^۲ Archive^۳ Entailed questions^۴ Duplicate questions

هستند. در دسته اول، مجموعه‌ای از ویژگی‌ها به صورت دستی از پرسش‌ها استخراج می‌شوند [۲۹، ۲۸]. مهمترین نقطه ضعف این رویکردها را می‌توان ناتوانی معیارهای شباهت سنتی، در تشخیص هم‌ارزی‌های معنایی عنوان کرد [۳۱، ۳۰]. در دسته دوم، مهندسی ویژگی‌ها به مدل‌های شبکه عصبی سپرده می‌شود. تعدادی از پژوهش‌ها، بردارهای تعبیه را در سطح کلمه^۹ [۳۲، ۳۱، ۹] و تعدادی در سطح جمله^{۱۰} [۳۳] تولید نموده‌اند. در این میان، تحلیل خطاها از ناتوانی مدل‌های تعبیه ایستا^{۱۱} در مواجهه با چالش‌هایی نظیر چندمعنایی^{۱۲}، اصطلاحات تخصصی و واژگان خارج از لغت‌نامه حکایت داشته‌است. از این رو، با پیدایش مدل‌های تعبیه بافتاری، بسیاری از محققین به استفاده از آنها گرایش یافتند.

گروهی از پژوهش‌ها تلاش نمودند تا با تزریق دانش از طرق مختلف، بازنمایی‌های برداری را غنی‌تر نمایند. استفاده از مدل‌های پیش‌آموزش‌دیده^{۱۳} روی داده‌های خاص-دامنه^{۱۴}، یکی از راهکارهایی است که محققین برای تزریق دانش تخصصی پیشنهاد کردند. نگون و همکاران [۳۴] با هدف رفع ابهام از اصطلاحات تخصصی و اختصارات^{۱۵} در دامنه پزشکی، بهره‌برداری همزمان از تعبیه خاص-دامنه Bio-BERT و تعبیه حاصل از مدل دامنه-باز BERT^{۱۶} را پیشنهاد نمودند. محققین در [۳۵]، کیفیت تعبیه Word2vec در یک شبکه مبتنی بر Bi-LSTM^{۱۷} را با تعبیه حاصل از Bio-BERT در یک شبکه عصبی چندلایه مقایسه نموده و عملکرد برتر Word2vec را شاهد بودند. داده‌افزایی^{۱۸}، دیگر راهکاری است که پژوهشگران به منظور افزایش تعمیم‌پذیری بازنمایی‌ها، جلوگیری از بیش‌برازش^{۱۹} و تأمین داده برای آموزش مدل‌های زبانی به آن رجوع کردند. مرینی و همکاران [۳۶] با اثبات رابطه هم‌ارزی میان وظایف RQE و خلاصه‌سازی پرسش، رویکردی برای داده‌افزایی جهت تسهیل یادگیری چندوظیفه‌ای^{۲۰} پیشنهاد دادند. آنها از هر زوج پرسش در دادگان خلاصه‌سازی، یک زوج معادل برای دادگان RQE تولید نمودند. برخی محققین نیز استفاده از یادگیری انتقالی^{۲۱} را توصیه کردند. زو و همکاران [۳۷]، تنظیم دقیق^{۲۲} مدل MT-DNN^{۲۳} برای وظیفه استنتاج زبان طبیعی^{۲۴} را در بهبود عملکرد آن در وظیفه RQE مؤثر یافتند.

صحيح و يکپارچه به پرسشگر بر پایه پاسخ‌های تأییدشده^۱ برای پرسش‌های متضمن می‌پردازد. در واقع، سیستم پیشنهادی پژوهش حاضر، یک سیستم مولد بازبازی‌افزوده^۲ (RAG) توسعه‌یافته است که به یک مؤلفه پسابازی^۳ مجهز گشته است. این سیستم نه تنها از دانش جهانی^۴ مدل‌های زبانی بزرگ برای تولید پاسخ‌هایی مشابه پاسخ‌های انسانی بهره می‌برد، بلکه از چالش‌هایی نظیر تولید پاسخ‌های غیرواقعی^۵ که گریبان‌گیر این مدل‌ها است مصون می‌ماند. افزون بر این، با تکیه بر دانش و علایق پرسشگر، از ورود پاسخ‌های کاندید نامرتبط با نیاز اطلاعاتی به مرحله تولید پاسخ ممانعت نموده و اعتبار، دقت و صحت بالاتر را در پاسخگویی به ارمغان می‌آورد.

به‌طور کلی، نوآوری‌های مطالعه حاضر به شرح زیر است:

۱. ارائه سیستمی برای پاسخگویی خودکار و سریع به پرسش‌های انجمن و بهبود صحت و کیفیت پاسخ‌ها با کاهش خطا در مؤلفه‌های بازبازی پرسش و شناسایی پرسش‌های متضمن
۲. بهبود فرآیند شناسایی پرسش‌های متضمن از طریق افزودن شرط همسویی پرسش‌های کاندید با دانش و علایق پرسشگر
۳. مدل‌سازی دانش پرسشگر در قالب دنباله‌ای از برجسب‌های موضوعی با تکیه بر سوابق پرسش‌های وی در انجمن

ادامه این مقاله به شرح زیر سازمان‌دهی شده است. در بخش دوم مروری بر کارهای پیشین در حوزه شناسایی پرسش‌های متضمن ارائه می‌گردد. در بخش سوم، سیستم پیشنهادی و عملکرد هریک از مؤلفه‌های آن تشریح می‌شود. بخش چهارم به معرفی دادگان، تنظیمات سیستم، نتایج آزمایش‌ها و بحث پیرامون آنها پرداخته و بخش پنجم، با جمع‌بندی و ارائه پیشنهادات به آن خاتمه می‌دهد.

۲- کارهای مرتبط

با معرفی وظیفه تشخیص تضمین پرسش‌ها (RQE) توسط آباچا و همکاران در سال ۲۰۱۶ [۲۷]، مطالعات بسیاری، به ارائه مدل‌های RQE و ارتقاء عملکرد آنها از زوایای مختلف پرداختند.

بطور کلی، مدل‌های RQE از منظر روش تولید بازنمایی‌های^۶ برداری به دو دسته «مبتنی بر ویژگی^۷» و «مبتنی بر تعبیه^۸» قابل تقسیم

¹³ Pre-trained

¹⁴ Domain-specific

¹⁵ Abbreviations

¹⁶ Bidirectional Encoder Representations from Transformers

¹⁷ Bidirectional Long Short-Term memory

¹⁸ Data augmentation

¹⁹ Overfitting

²⁰ Multi-task learning

²¹ Transfer learning (TL)

²² Fine-tune

²³ Multi-task Deep Neural Network

²⁴ Natural Language Inference (NLI)

¹ Accepted answers

² Retrieval-augmented generation (RAG)

³ Post-retrieval

⁴ (Parametric) world knowledge

⁵ Hallucination

⁶ Representation

⁷ Feature-based approaches

⁸ Embedding-based approaches

⁹ Word embedding

¹⁰ Sentence-level embedding

¹¹ Static

¹² Polysemy

گروه دیگری از پژوهش‌ها، تقویت معماری مدل را در پیش گرفتند. به همین علت، گذار تدریجی از مدل‌های سنتی یادگیری ماشین [۲۸، ۲۹، ۳۲-۳۴] به سمت مدل‌های پیشرفته یادگیری عمیق را شاهد هستیم. به عنوان نمونه، فصیح و همکاران [۲۱] از ظرفیت شبکه‌های حافظه طولانی کوتاه‌مدت^۱ و شبکه‌های عصبی پیچشی^۲ (CNN) برای دریافت همزمان وابستگی‌های بلندمدت و محلی بهره‌مند شدند. بازنمایی‌های زوج پرسش، پس از تولید توسط مدل‌های فوق، برای دسته‌بندی به یک مدل پرسپترون^۳ ارائه شدند.

برخی مطالعات با ارائه مدل‌های پیچیده چندوظیفه‌ای، درصدد تزیق دانش به مدل برآمدند. یادگیری چندوظیفه‌ای، از طریق لایه‌های اشتراکی، امکان تبادل دانش بین وظایف مرتبط را فراهم می‌آورد [۳۸]. ژو و همکاران [۳۹] یک شبکه تخصصی^۴ برای وظایف RQE و پاسخگویی به پرسش، شامل یک رمزگذار^۵ مشترک، یک متمایزگر^۶ وظیفه و دو دسته‌بند طراحی نمودند. در این شبکه، متمایزگر با تشخیص نوع وظیفه، رمزگذار را بر حذف ویژگی‌های خاص-وظیفه^۷ از بازنمایی‌ها ترغیب می‌نمود. ناتوانی در درک پرسش‌های مبهم و اختصارات را می‌توان از نقاط ضعف روش پیشنهادی آنها برشمرد. شانگ و همکاران [۴۰] از یادگیری بدون نظارت^۸ چندوظیفه‌ای با یک رمزگذار مشترک، به منظور ارتقاء کیفیت بازنمایی‌ها بهره جستند. آنها وظایف تولید کلیدواژه برای پرسش و بازنمایی پرسش را به صورت توأم آموزش دادند. اگرچه آزمایش‌ها از عملکرد مؤثر مدل آنها در برخورد با پرسش‌های کوتاه حکایت دارد، اما کارایی آن برای پرسش‌های طولانی و پیچیده، مورد سؤال است. مرینی و همکاران [۱۹] یک مدل مبتنی بر BART^۹ شامل وظایف خلاصه‌سازی پرسش و RQE پیشنهاد نمودند. نوآوری اصلی آنها تعریف دو مؤلفه رمزگشا^{۱۰} با اشتراک تدریجی-نرم^{۱۱} در کنار یک رمزگذار مشترک بود. نتایج تجربی آنها مؤید نقش مؤثر خلاصه‌سازی پرسش در تقویت عملکرد RQE بود.

به عقیده برخی محققین، مدل‌های عمیق موجود در زمینه RQE، به دلیل اتکاء صرف بر دانش داخلی، فاقد جامعیت و ناتوان در استدلال در سطوح عمیق هستند [۴۱]. به همین علت، در ادبیات پژوهش می‌توان مطالعاتی را نیز یافت که به تزیق دانش دامنه‌ای

یا عمومی از طریق گراف‌های دانش^{۱۲} پرداخته‌اند. گودوین و همکاران [۲۶] از گراف دانش ConceptNet برای کسب دانش مستقل از وظیفه^{۱۳} بهره‌مند گشتند. یاداو و همکاران [۲۵] یک روش رمزگذاری دوگانه^{۱۴} مبتنی بر گراف دانش را معرفی کردند که در آن، همزمان با استخراج اطلاعات بافتاری محلی توسط مدل‌های زبانی، اطلاعات عمومی نیز در سه گام، شامل ساخت گراف هم‌آیندی^{۱۵} کلمات، تکمیل آن به کمک گراف‌های دانش خاص-دامنه و تولید تعبیه گرافی با استفاده از شبکه‌های پیچشی گرافی، استخراج می‌شد. آنگاه، یک مدل ترانسفورمر^{۱۶}، دو تعبیه مذکور را در هم آمیخته و بازنمایی حاصل به یک شبکه عصبی ارسال می‌شد. نتایج آنها توانایی این مدل در درک بهتر پرسش‌ها در دامنه پزشکی را نشان داد. اگرچه، پیچیدگی، تعمیم‌پذیری و مقیاس‌پذیری را می‌توان سه چالش مهم در مطالعه آنها دانست. جیانگ و همکاران [۴۱] از گراف ConceptNet، پایگاه دانش Wiktionary و مدل تعبیه BERT برای تولید بازنمایی دانش، و از یک مدل متشکل از چندین شبکه CNN و لایه‌های توجه^{۱۷} برای تولید بازنمایی زوج پرسش استفاده نمودند. سپس بازنمایی‌های حاصل را با بهره‌گیری از یک مکانیزم گیت^{۱۸} با یکدیگر تلفیق کردند. آزمایش‌ها اثربخشی و مقیاس‌پذیری روش پیشنهادی آنها روی دادگان مختلف را تأیید نموده است اما تحلیلی بر پیچیدگی مدل ارائه نشده است.

گروهی از محققین از فراداده‌های^{۱۹} پرسش به عنوان یک منبع دانش تکمیلی استفاده نمودند. برای مثال، از دیدگاه سان و همکاران [۴۲]، کیفیت پاسخ پرسش‌های کاندید، عامل مهمی است که باید در کنار شباهت‌های نحوی و معنایی، برای رتبه‌بندی پرسش‌ها لحاظ گردد. آنها پس از بازیابی پرسش‌های مرتبط به کمک نمایه معکوس^{۲۰} و TF-IDF^{۲۱}، کیفیت پاسخ هر پرسش مرتبط را توسط یک مدل مبتنی بر ELMo^{۲۲} سنجیده و این امتیاز را به همراه سایر امتیازات، به الگوریتم رتبه‌بندی ارائه نمودند. یافته‌های آنها، صرف‌نظر از افزایش حجم محاسبات زمان واقعی، مؤثر بودن ویژگی‌های منتخب را به اثبات رساند. قاسمی و شاکری [۲۳] یک مدل زبانی مبتنی بر ترجمه را برای وظیفه بازیابی پرسش ارائه دادند بطوریکه، علاوه بر بدنه پرسش، موضوع، عنوان و پاسخ‌ها نیز در آن مشارکت داشتند.

¹² Knowledge Graph (KG)

¹³ Task-agnostic

¹⁴ Dual-encoding

¹⁵ Co-occurrence

¹⁶ Transformer

¹⁷ Attention layers

¹⁸ Gating mechanism

¹⁹ Metadata

²⁰ Inverted index

²¹ Term Frequency-Inverse Document Frequency

²² Embeddings from Language Models

¹ Long Short-Term Memory network (LSTM)

² Convolutional Neural Network (CNN)

³ Multi-Layer Perceptron (MLP)

⁴ Adversarial

⁵ Encoder

⁶ Discriminator

⁷ Task-specific

⁸ Unsupervised

⁹ Bidirectional Auto-Regressive Transformers

¹⁰ Decoder

¹¹ Gradually-soft

بنای اصلی رویکرد آنها بر دو مدل BERT و GPT، به ترتیب برای پیش‌بینی دسته موضوعی پرسش جدید و مبسوط نمودن آن از طریق تولید و الحاق پاسخ، استوار بود. به این ترتیب، مدل مبتنی بر ترجمه، پرسش‌های کاندید را براساس شباهتشان به پرسش بسط‌یافته رتبه‌بندی می‌کرد. اگرچه مدل آنها در اختصاص رتبه‌های بالاتر به پرسش‌های مرتبط، موفق عمل کرد، اما سربار محاسباتی برخط، یکی از معایب آن به شمار می‌آید. جدول ۲ به مرور اجمالی مطالعات پیشین می‌پردازد.

جدول ۲. مروری بر کارهای پیشین در حوزه شناسایی متون متضمن


مرجع وظیفه	پیش‌پردازش	روش بازنمایی	مدل یادگیری	دادگان	دانش	نتایج
[۹] RQE	حذف کلمات توقف، ریشه‌یابی	Feature-based, GloVe	LR, MLP	SNLI, Multi-NLI, ClinicalQE, Quora	پرسش	برتری مدل LR، اثربخشی روش ترکیبی شامل بازیابی با روش‌های سنتی و رتبه‌بندی مجدد براساس نتایج RQE
[۳۲] RQE	حذف کلمات توقف، ریشه‌یابی	Feature-based, BioBERT	.NB, SVM, AdaBoost, KNN, LR, XGBoost	MediQA-RQE	پرسش	برتری مدل‌های ترکیبی نظیر AdaBoost و XGBoost بر مدل‌های محض
[۲۸] ISQ	بن‌یابی	Feature-based, Word2vec	SVM, MLP, CNN, NB	SemEval (2016)	پرسش، عنوان	عملکرد برتر مدل CNN نسبت به مدل‌های سنتی، افت نتایج در استفاده از رای اکثریت
[۳۱] DQD	-	GloVe	MLP, Siamese-CNN	Quora	پرسش	برتری قابل توجه CNN بر MLP
[۳۳] RQE	-	USE	LR, MLP	MediQA-RQE	پرسش	کیفیت قابل قبول تعبیه‌های USE با وجود سادگی مدل MLP
[۲۰] RQE	-	.ELMO, FastText, GloVe, InferSent, SciBERT, BioBERT	LR	MediQA-RQE	پرسش	برتری تعبیه در سطح جمله نسبت به تعبیه در سطح کلمه، برتری مدل‌های تعبیه خاص دامنه پزشکی بر مدل‌های عمومی
[۳۴] RQE	-	BioBERT, BERT	SVM	MediQA-RQE	پرسش	تأثیر مثبت ترکیب مدل‌های خاص-دامنه با مدل‌های عمومی در رفع نقاط ضعف آنها
[۳۵] RQE	-	BioBERT, Word2vec	Siamese-BiLSTM, MLP	MediQA-RQE	پرسش	عملکرد برتر مدل Siamese با تعبیه‌های word2vec نسبت به مدل‌های خاص-دامنه
[۳۷] RQE	گسترش اختصارات	SciBERT, BioBERT, MT-DNN, GloVe	.ESIM, BERT, RCNN-NLI, سایر	MediQA-RQE	پرسش، UMLS	حذف ویژگی‌های خاص-وظیفه و ارتقاء کیفیت بازنمایی‌ها با یادگیری تخصصی
[۲۳] DQD	حذف کلمات توقف، ریشه‌یابی	BERT	GPT-2, BERT, GPT-4, GPT-3	SemEval (2017)	پرسش، پاسخ، رده موضوعی	اثبات اهمیت فراداده‌ها، کارآمدی گسترش پرسش توسط LLMها در دقت بازیابی مؤثر بودن الحاق بازنمایی‌های LSTM و CNN در مدلسازی الگوهای پیچیده در داده و برتری این روش نسبت به BERT
[۲۱] DQD	حذف کلمات توقف و علائم نشانه‌گذاری، ریشه‌یابی	GloVe, Word2vec	.BiLSTM + CNN, BERT, AdaBoost, SVM, MLP, سایر	Stack Overflow (2019)	پرسش	تولید بازنمایی‌های برداری غنی‌تر از طریق تولید کلید واژه برای پرسش‌ها و یادگیری چندوظیفه‌ای بدون ناظر بر پایه کلیدواژه‌ها
[۴۰] QR	حذف کلمات توقف	.RoBERTa, BERT, LDA, سایر	-	.FAQIR, TREC-50, Stack Overflow, StackFAQ	پرسش	کارایی ادغام دانش خارجی در بازنمایی‌های برداری و بهره‌گیری از مکانیزم توجه در ارتقاء درک معانی، ضمن حفظ قابلیت تعمیم مدل
[۴۱] QR	-	attention + CNN, BERT	MLP	.MedNLI, SNLI, SICK, Quora, ConceptNet, Wiktionary	پرسش، سایر	مؤثر بودن تزریق دانش دامنه‌ای و جهانی درباره موجودیت‌ها به بازنمایی موجودیت‌ها
[۲۶] RQE	-	BERT	BERT	MediQA-RQE	پرسش، ConceptNet	بهبود درک محلی و سراسری با ترکیب مدل‌های عمومی و منابع دانش خاص-دامنه
[۲۵] RQE	-	attention + GCN + BERT, ClinicalBERT, BioBERT	MLP	MediQA-RQE	پرسش، UMLS, ICD-10, سایر	بهبود رتبه‌بندی پرسش‌های کاندید با نگاه به کیفیت پاسخ‌های آنها
[۴۲] QR	حذف کلمات توقف و علائم نشانه‌گذاری	.Word2vec, Feature-based, attention + BiLSTM	Ranking SVM	SemEval (2016, 2017)	پرسش، پاسخ	تولید بازنمایی‌های غنی‌تر از طریق یادگیری توأمان وظایف مرتبط
[۱۹]	-	BART	BART	MeQSum, iCliniq, MedQA-RQE, سایر	پرسش	

اختصارات: BERT: بازنمایی‌های رمزگذار دوسویه از ترانسفورمرها، BART: ترانسفورمر دوسویه خودبازگشتی، CNN: شبکه عصبی پیچشی، DQD: شناسایی پرسش‌های تکراری، GCN: شبکه پیچشی گرافی، GPT: ترانسفورمر پیش‌آموزش‌دیده مولد، ISQ: شناسایی پرسش‌های مشابه، KNN: k-نزدیکترین همسایه، LR: رگرسیون لجستیک، BiLSTM: شبکه حافظه طولانی کوتاه‌مدت دوسویه، MAP: میانگین متوسط دقت، MLP: پرسپترون چند لایه، MRR: میانگین معکوس رتبه، NB: بیز محض، QR: بازیابی پرسش، RCNN-NLI: شبکه عصبی بازگشتی پیچشی برای استنتاج زبان طبیعی، RQE: شناسایی پرسش‌های متضمن، SVM: ماشین بردار پشتیبان، UMLS: سیستم یکپارچه زبان پزشکی، USE: رمزگذار جهانی جملات

۳- سیستم پیشنهادی

گردد. به‌طور همزمان، مؤلفه بازیابی پرسش نیز با دریافت بدنه پرسش، اقدام به سنجش شباهت آن با پرسش‌های حل‌شده در بایگانی انجمن نموده و فهرستی از پرسش‌های مشابه را بازیابی می‌نماید. خروجی‌های این دو مؤلفه در گام بعد در اختیار مؤلفه شناسایی پرسش‌های متضمن قرار می‌گیرند. این مؤلفه با آگاهی از دانش و علایق پرسشگر، پرسش‌های مشابه را غربال^۲ نموده و پرسش‌هایی که پتانسیل ارائه یک پاسخ صحیح کامل یا جزئی به پرسش جدید را دارند شناسایی می‌کند. در گام آخر، پاسخ‌های تأییدشده برای برترین پرسش‌های متضمن، به مؤلفه تولید پاسخ ارائه می‌گردند تا در یک پاسخ واحد به زبان طبیعی، متمرکز بر نیاز پرسش، تجمیع گردند. در ادامه، عملکرد هر مؤلفه از سیستم، با جزئیات تشریح می‌شود.

UserQA یک سیستم هوشمند مولد پاسخ برای انجمن‌های پرسش‌وپاسخ است که با استفاده از زنجیره‌ای از مدل‌های زبانی بزرگ، به تحلیل علاقمندی‌های پرسشگر پرداخته و پاسخی جامع به زبان طبیعی برای تأمین نیاز اطلاعاتی وی ارائه می‌دهد. این سیستم، مطابق شکل ۱، از چهار مؤلفه اصلی شامل مدلسازی کاربر، بازیابی پرسش، شناسایی پرسش‌های متضمن و تولید پاسخ تشکیل شده است. در نخستین گام پس از ثبت یک پرسش جدید در انجمن، شناسه کاربری پرسشگر در اختیار مؤلفه مدلسازی کاربر قرار می‌گیرد تا با تحلیل سوابق فعالیت‌های این کاربر، دانش و علایق وی در قالب یک دنباله متنی، حاوی تعدادی عنوان^۱ کلیدی، توصیف



شکل ۱. نمای کلی از سیستم پیشنهادی پژوهش (UserQA)

² Filter

¹ Topic

۳-۱- مدلسازی کاربر

مؤلفه مدلسازی کاربر را می‌توان اصلی‌ترین نوآوری پژوهش جاری دانست. این مؤلفه مبتنی بر یک مدل زبانی بزرگ است که با بررسی سوابق فعالیت‌های یک کاربر، بر استنباط دانش پیش‌زمینه و موضوعات مورد علاقه وی اهتمام می‌ورزد. گام‌های اتخاذ شده در این فرآیند، در الگوریتم (۱) ارائه شده است.

Algorithm 1: User knowledge modeling

Inputs: User id u^l , Community questions $\mathbb{N}$, Number of topical tags k_1

Output: User knowledge $u'^l \in \mathbb{U}$

```

1.  $\square^l \leftarrow \{\}$ 
2. foreach  $\langle q_i, u_i \rangle$  in  $\mathbb{N}$  do
3.   if  $u_i = u^l$ : append  $q_i$  to  $\square^l$ 
4. end
5.  $\mathbb{T} \leftarrow \{\}$ 
6. foreach  $q_i$  in  $\mathbb{Q}^l$  do
7.    $p_i \leftarrow \text{prompt}(q_i)$ 
8.    $t'_i \leftarrow \text{Llama}(p_i)$ 
9.    $\mathbb{T} \leftarrow \text{union}(\mathbb{T}, t'_i.\text{split}(','))$ 
10. end
11.  $u' \leftarrow \text{unique}(\mathbb{T})$ 
12.  $u'.\text{sort}(\text{frequency}(\mathbb{T}), \text{order}(\mathbb{T}))$ 
13.  $u'^l \leftarrow \text{top}(u', k_1)$ 
14. return  $u'^l$ 

```

متابک الگوریتم (۱)، انجمنی متشکل از مجموعه کاربران $\mathbb{U}$ را در نظر بگیرید بطوریکه مجموعه $\mathbb{N}$ ، مجموعه تمام پرسش‌های ثبت‌شده در این انجمن باشد. چنانچه کاربر $u^l \in \mathbb{U}$ پرسش جدید q_{new}^l را در انجمن مطرح سازد، مؤلفه مدلسازی کاربر، در نخستین گام، کلیه پرسش‌هایی را که وی از بدو عضویتش تا به اکنون ثبت کرده است واکشی می‌نماید (خطوط ۱ تا ۴). در اینجا، $\mathbb{Q}^l$ معرف تاریخچه پرسش‌های ثبت‌شده توسط کاربر u^l است. پس از بازیابی سوابق کاربر، هریک از پرسش‌های $\mathbb{Q}^l$ ، به یک اعلان p_i^l با الگوی مشخص تبدیل شده و متعاقباً، به یک مدل زبانی Llama2 ارسال می‌شوند تا به ازای هر پرسش، یک دنباله متنی از برچسب‌ها^۲ که توصیفگر موضوعات محوری آن پرسش هستند تولید گردد (خطوط ۵ تا ۸). لازم به ذکر است که مدل Llama2، پیش‌تر برای وظیفه تولید برچسب‌های موضوعی، تنظیم دقیق می‌شود. در گام بعد، دنباله‌های تولیدشده که با نماد t'_i نمایش داده شده‌اند، به برچسب‌هایشان تفکیک شده و از اجتماع آنها، مجموعه $\mathbb{T}$ از

برچسب‌ها شکل می‌گیرد (خط ۹). این برچسب‌ها براساس بسامد^۳ و ترتیب وقوعشان مرتب شده و k_1 برچسب نخست، به عنوان مدل نهایی دانش کاربر (u'^l) انتخاب می‌گردند (خطوط ۱۱ تا ۱۴).

عدم وابستگی مؤلفه مدلسازی کاربر به پرسش ورودی را می‌توان از مهمترین نقاط قوت آن برشمرد. به عبارت دیگر، انجمن قادر خواهد بود با استفاده از این مؤلفه، زمینه‌های دانش همه کاربران را به‌صورت کاملاً برون‌خط^۴، استنتاج نموده و در صورت نیاز، به‌طور دوره‌ای آن را بروزرسانی کند. بعلاوه، با تعریف بازه‌های زمانی روی سوابق کاربر یا محدود نمودن این فرآیند به استفاده از جدیدترین پرسش‌های کاربر، می‌توان مسئله گذار تدریجی^۵ علایق کاربران را نیز مدیریت نمود.

۳-۲- بازیابی پرسش

به مجموعه تمامی پرسش‌های دارای پاسخ تأییدشده در انجمن، بایگانی انجمن می‌گویند. هدف اصلی پژوهش جاری، تولید پاسخ‌هایی صحیح و جامع برای پرسش‌های ورودی، برگرفته از پاسخ‌های تأییدشده برای پرسش‌های متضمن آنها در بایگانی انجمن است. از این‌رو، سرعت و کیفیت پاسخگویی، در گرو شناسایی سریع و دقیق پرسش‌های متضمن در بایگانی می‌باشد. این در حالی است که بایگانی انجمن‌ها، غالباً حجمی بالغ بر هزاران یا میلیون‌ها پرسش را در بر می‌گیرند. به این ترتیب، ضروریست که فضای جستجو، پیش از اقدام به شناسایی پرسش‌های متضمن، محدود گردد. در سیستم پیشنهادی پژوهش جاری، این وظیفه بر عهده مؤلفه بازیابی پرسش گذاشته شده است. الگوریتم (۲) به شرح وظایف این مؤلفه می‌پردازد.

Algorithm 2: Similar question retrieval

Inputs: Newly submitted question q_{new}^l , Community archive $\mathbb{A} \subset \mathbb{N}$, Number of similar questions k_2

Output: Top most similar questions $\mathbb{S}$

```

1.  $s \leftarrow []$ 
2.  $e_{new}^l \leftarrow \text{represent}(q_{new}^l)$ 
3. foreach  $q_i$  in  $\mathbb{A}$  do
4.    $e_i \leftarrow \text{represent}(q_i)$ 
5.    $S[i] \leftarrow \text{similarity}(e_{new}^l, e_i)$ 
6. end
7.  $\mathbb{M} \leftarrow \text{top}(\text{argsort}(s), k_2)$ 
8.  $\mathbb{S} \leftarrow \{\}$ 
9. foreach  $m$  in  $\mathbb{M}$  do
10.   append  $\langle q_m, s[m] \rangle$  to  $\mathbb{S}$ 
11. end
12. return  $\mathbb{S}$ 

```

^۴ Offline

^۵ Drift

^۱ Prompt

^۲ Tags

^۳ Frequency

این وظیفه آموزش دیده است ارسال می‌شوند. به این ترتیب، طبق رابطه (۴)، چنانچه پرسش q_j مرتبط با دامنه تخصصی پرسشگر بوده و از پاسخ‌های صحیح آن بتوان برای پاسخگویی به پرسش q_{new}^l استفاده کرد، عبارت "متضمن" و درغیراینصورت، عبارت "غیرمتضمن" توسط مدل زبانی تولید می‌گردد.

$$\mathcal{L}(q_j, q_{new}^l) = \text{Llama}(p_j) = \begin{cases} \text{Entailed} & (q_{new}^l \rightarrow q_j) \ \& \ (q_j \in u'^l) \\ \text{Not-entailed} & (\text{otherwise}) \end{cases} \quad (4)$$

۳-۴- تولید پاسخ

بقای یک انجمن پرسش‌وپاسخ در گرو جلب حداکثری رضایت کاربران آن است. برای این منظور، در سیستم پیشنهادی این پژوهش، مؤلفه تولید پاسخ مطابق الگوریتم (۳)، تعبیه شده است تا به جای آنکه پرسشگر، با ارائه چند پیوند^۵، به ریشه^۶ پرسش‌های متضمن هدایت شود، یک پاسخ صحیح، جامع و موجز را به‌طور مستقیم دریافت نماید.

Algorithm 3: Answer generation

Inputs: Newly submitted question q_{new}^l , Similar questions $\mathbb{S}$, Number of candidate answers k_3

Output: Final answer a_{new}^l

1. $\mathbb{C} \leftarrow \{\}$
2. **foreach** q_j in $\mathbb{S}$ **do**
3. **if** $\mathcal{L}(q_j, q_{new}^l) = \text{'Entailed'}$ **do**
4. append a_j to $\mathbb{C}$
5. **end**
6. **end**
7. $\mathbb{C} \leftarrow \text{top}(\mathbb{C}, k_3)$
8. $p \leftarrow \text{prompt}(\mathbb{C}, q_{new}^l)$
9. $a_{new}^l \leftarrow \text{LLM}(p)$
10. **return** a_{new}^l

سومین مدل زبانی بزرگ در سیستم پیشنهادی، در مؤلفه تولید پاسخ به کار گرفته می‌شود. در اولین گام از الگوریتم (۳)، پاسخ‌های تأییدشده متناظر با k_3 پرسشی که بیشترین شباهت را به پرسش ورودی داشته و برچسب متضمن دریافت کرده‌اند، واکشی می‌شوند (خطوط ۱ تا ۷). در اینجا، a_j معرف پاسخ تأییدشده برای پرسش $q_j \in \mathbb{S}$ می‌باشد. همچنین، یادآور می‌گردد که پرسش‌های مجموعه $\mathbb{S}$ ، قبلاً براساس میزان شباهتشان به پرسش ورودی، به صورت نزولی مرتب شده‌اند (الگوریتم ۲، خطوط ۷ تا ۱۱). در گام دوم، پرسش ورودی همراه با پاسخ‌های کاندید، به یک اعلان با الگوی مشخص

مطابق الگوریتم (۲)، مؤلفه بازیابی پرسش موظف است بازنمایی‌های برداری متناظر با پرسش ورودی q_{new}^l و یکایک پرسش‌های بایگانی $q_i \in \mathbb{A}$ را تولید نموده و شباهت میان آنها را در فضای برداری یکسان، اندازه‌گیری نماید (خطوط ۱ تا ۶). در پژوهش جاری، معیار شباهت کسینوسی، که توسط رابطه (۱) فرموله شده است، مورد استفاده قرار می‌گیرد.

$$\text{cosine-similarity}(e_{new}^l, e_i) = \frac{e_{new}^l \cdot e_i}{\|e_{new}^l\| \|e_i\|} \quad (1)$$

پس از سنجش شباهت، k_2 پرسشی که بیشترین شباهت را به پرسش ورودی دارند در خروجی ارائه می‌شوند (خطوط ۷ تا ۱۲).

۳-۳- شناسایی پرسش‌های متضمن

مطابق تعریف ارائه شده توسط آباچا و همکاران در [۹]، پرسش B یک پرسش متضمن برای پرسش A نامیده می‌شود ($A \rightarrow B$) اگر هر پاسخ صحیح ارائه شده برای پرسش B، یک پاسخ صحیح کامل یا جزئی برای پرسش A نیز محسوب شود. لذا، شناسایی پرسش‌های متضمن، نیازمند یک مدل دسته‌بند دودویی^۱ است که مطابق رابطه (۲) عمل کند.

$$f(A, B) = \begin{cases} 1 & (A \rightarrow B) \\ 0 & (A \nrightarrow B) \end{cases} \quad (2)$$

مطالعه جاری، مدل زبانی بزرگ Llama2 را جایگزین مدل‌های دسته‌بند سنتی نموده و فرآیند شناسایی پرسش‌های متضمن را در قالب فرآیند تولید متن^۲، مطابق رابطه (۳)، مدلسازی نموده است.

$$f(A, B) = \begin{cases} \text{Entailed} & (A \rightarrow B) \\ \text{Not-entailed} & (A \nrightarrow B) \end{cases} \quad (3)$$

اگرچه بررسی ویژگی‌های متنی پرسش‌های A و B می‌تواند تا حد زیادی وجود رابطه تضمن میان آنها را آشکار سازد، اما زوج پرسش‌هایی که خیلی کوتاه، مبهم، فاقد اشتراک واژگانی^۳، خیلی طولانی یا دربرگیرنده اطلاعات جانبی^۴ باشند ممکن است با تشخیص اشتباه مدل مواجه شوند [۱۵]. پژوهش حاضر، اطلاع از زمینه‌های دانش و علایق کاربران را در برجسته نمودن موضوعات اصلی پرسش‌ها و رفع ابهام از آنها، راهگشا دانسته و دومین نوآوری خود را بر این اساس بنا می‌نهد. در این راستا، مؤلفه شناسایی پرسش‌های متضمن، علاوه بر پرسش جدید q_{new}^l و پرسش کاندید $q_j \in \mathbb{S}$ ، دانش مدل‌شده برای پرسشگر، یعنی u'^l را نیز در ورودی دریافت می‌کند. ورودی‌های مذکور پس از تبدیل شدن به یک اعلان با ساختار مشخص (p_j)، برای یک مدل Llama2 که پیش‌تر برای

⁴ Peripheral details

⁵ Link

⁶ Thread

¹ Binary classification

² Text generation

³ Lexical overlap

دقیق مؤلفه شناسایی پرسش‌های متضمن استفاده می‌شوند. در پژوهش جاری همچنین، یک دادگان اعتبارسنجی، مشتمل بر ۵۰۰ زوج پرسش از دادگان CQADupStack، با هدف تنظیم پارامترها برای آموزش مؤلفه شناسایی پرسش‌های متضمن، استخراج شده است. این مجموعه داده با دادگان آزمون همپوشانی نداشته و از نظر توزیع مشابه آنها می‌باشد. برخی جزئیات آماری در مورد دادگان پژوهش در جدول ۳ ارائه شده است.

جدول ۳. مقدار پارامترهای مورد استفاده

مشخصات آماری	دادگان آموزش	دادگان آزمون	دادگان اعتبارسنجی
میانگین تعداد نشانه‌ها ^۴ در پرسش‌های Q^1	۱۱۳	۱۱۶	۸۸
میانگین تعداد نشانه‌ها در پرسش‌های Q^2	۱۱۲	۱۰۳	۹۰
میانگین طول دنباله برچسب‌های Q^1	۶	۶	-
بیشینه طول دنباله برچسب‌های Q^1	۲۷	۲۳	-
میانگین طول پاسخ‌های تأییدشده برای Q^1	۲۴۳	۲۵۳	-
تعداد زوج‌های متضمن	۳۹۸۸	۱۰۱۲	۲۵۰
تعداد زوج‌های غیرمتضمن	۴۰۱۲	۹۸۸	۲۵۰

تعداد ۱۱۰۱ مورد از پرسش‌های Q^1 در بخش آزمون، دارای پاسخ تأییدشده هستند که از این تعداد، تنها ۱۴۸ پرسش توسط کاربران انجمن به عنوان پرسش تکراری تشخیص داده شده‌اند. این مجموعه از پرسش‌ها برای ارزیابی عملکرد مؤلفه تولید پاسخ مورد استفاده قرار می‌گیرند. جدول الف در پیوست ۱ دو نمونه از داده‌های مطالعه را نشان می‌دهد.

۴-۲- پیکربندی و پارامترهای اجرا

آزمایش‌های این پژوهش با استفاده از زبان پایتون، بر بستر Google Colab با ۸۳،۵ GB رم سیستم و یک پردازنده گرافیکی NVIDIA A100-SXM4-40GB انجام شده است. برای پیاده‌سازی مدل زبانی Llama2 از نسخه ۷ بلیون پارامتری آن در کتابخانه Hugging face^۵ و برای GPT-4o mini از پلتفرم برخط آن^۶ استفاده شده است. جدول ۴، مقادیر ابرپارامترهای مورد استفاده در این مطالعه را گزارش می‌کند.

بیشینه طول دنباله ورودی در مؤلفه مدلسازی کاربر، با در نظر گرفتن مجموع سه مقدار، شامل تعداد نشانه‌ها در اعلان ورودی (شکل ۲)، میانگین تعداد نشانه‌ها در پرسش‌های Q^1 (جدول ۳) و بیشینه طول دنباله برچسب‌های Q^1 (جدول ۳)، برابر با ۲۵۶ تنظیم شده است. بیشترین تعداد نشانه‌های جدید نیز براساس بیشینه طول دنباله برچسب‌های Q^1 و با احتساب حداقل سه علامت کاما (,) در

تبدیل شده و برای یک مدل زبانی پیش‌آموزش‌دیده، نظیر Llama2 یا GPT-4o mini، ارسال می‌شوند (خطوط ۸ تا ۱۰). در این مرحله، مهندسی اعلان^۱ به منظور ارائه بهترین دستورالعمل^۲ جهت انجام وظیفه خلاصه‌سازی چند پاسخی متمرکز بر پرسش^۳، امری ضروری است.

۴- آزمایش‌ها و تحلیل نتایج

اصلی‌ترین پرسش‌های پژوهشی مطالعه حاضر به شرح زیر هستند:

۱. مؤلفه مدلسازی کاربر تا چه اندازه در تشخیص موضوعاتی که کاربر بطور متناوب دنبال می‌کند کارآمد است؟
۲. استفاده از کدام مدل بازنمایی برداری، دقت بالاتری را در بازیابی پرسش‌های مشابه به ارمغان می‌آورد؟
۳. مدلسازی دانش کاربر چه اندازه در بهبود فرآیند شناسایی پرسش‌های متضمن مؤثر است؟
۴. برتری مؤلفه شناسایی پرسش‌های متضمن آگاه به کاربر نسبت به شناسایی پرسش‌های متضمن مستقل از کاربر، در دستیابی به پاسخ‌های صحیح و جامع، چه میزان برآورد می‌شود؟

در ادامه، دادگان پژوهش، تنظیمات اولیه سیستم و معیارهای ارزیابی تبیین می‌گردند. سپس، شرح کاملی از نتایج آزمایش‌های انجام‌شده جهت ارزیابی عملکرد سیستم پیشنهادی ارائه می‌شود.

۴-۱- مجموعه داده

آموزش مؤلفه‌های سیستم پیشنهادی و ارزیابی عملکرد آنها با استفاده از دادگان CQADupStack [۴۳] و نسخه کوچکتر و تغییریافته آن، CQAD-ReQuEST [۴۴] انجام می‌پذیرد. دادگان CQADupStack، اطلاعات ۴۷۰،۳۴۴ پرسش، نظیر مشخصات پرسشگر، عنوان، برچسب‌ها، تاریخ ثبت، آراء مثبت و منفی، پاسخ‌های دریافتی و پاسخ تأییدشده برای هر کدام (در صورت وجود) را در ۱۲ شاخه موضوعی مختلف، شامل شده است. از این پرسش‌ها، ۲۴۸،۴۲۶ مورد (حدود ۵۲/۸٪) دارای پاسخ تأییدشده می‌باشند که در سیستم پیشنهادی پژوهش، با عنوان بایگانی انجمن از آنها یاد می‌شود.

دادگان CQAD-ReQuEST شامل ۸۰۰۰ زوج پرسش (Q^1, Q^2) در بخش آموزش و ۲۰۰۰ زوج در بخش آزمون است. پرسش‌های Q^1 و برچسب‌های متناظر آنها در دادگان آموزش، برای تنظیم دقیق مؤلفه مدلسازی کاربر و کلیه زوج پرسش‌های آموزش، برای تنظیم

^۴ Tokens

^۵ <https://huggingface.co/meta-llama/Llama-2-7b-chat-hf>

^۶ <https://chat.openai.com/>

^۱ Prompt engineering

^۲ Instruction

^۳ Question-focused multi-answer summarization

میان برچسب‌ها، برابر با ۳۰ تعیین شده‌است. این دو ابرپارامتر در مؤلفه تولید پاسخ نیز به ترتیب، براساس پیکربندی پیش‌فرض Llama2 و میانگین طول پاسخ‌های تأییدشده برای Q^1 (جدول ۳)، با مقادیر ۴۰۹۶ و ۲۴۰ مقداردهی شده‌اند.

تنظیم ابرپارامترهای مربوط به آموزش مؤلفه شناسایی پرسش‌های متضمن براساس داده‌های اعتبارسنجی انجام شده است که در بخش ۳-۴ به آن پرداخته می‌شود. علاوه‌براین، بیشینه طول دنباله ورودی در این مؤلفه، با در نظر گرفتن طول اعلان ورودی (شکل ۵)، میانگین طول پرسش‌های Q^1 و Q^2 (جدول ۳)، حداکثر ۱۰۰ نشانه برای دانش کاربر و پنج نشانه برای برچسب خروجی، برابر با ۵۱۲ تنظیم شده است. به‌منظور جلوگیری از سوگیری ناشی از تفاوت در طول برچسب‌های خروجی، به‌جای برچسب‌های "Entailed" و "Not-entailed" که به ترتیب دارای سه و چهار نشانه هستند، برچسب‌های "positive" و "negative" که دارای طول یکسان (یک نشانه) هستند به عنوان خروجی مدل استفاده شده‌اند.

جدول ۴. مقدار ابرپارامترهای مورد استفاده

نام پارامتر	شماره مؤلفه			
	۱	۲	۳	۴
max_epochs	۱۰	-	۱۰	-
learning_rate	2×10^{-4}	-	3×10^{-5}	-
Batch_size	۳۲	-	۳۲	-
max_seq_length	۲۵۶	-	۵۱۲	۴۰۹۶
max_new_tokens	۳۰	-	۱	۲۴۰
lora_r	۶۴	-	۶۴	-
lora_alpha	۱۶	-	۱۶	-
lora_dropout	۰/۱	-	۰/۳	-
temperature	۰/۹۷	-	۰/۹۷	۰
4- or 8-bit quantization	خیر	-	خیر	خیر
k	۱۰	۵۰	-	۳، ۵

۳-۴- معیارهای ارزیابی

در این مطالعه، شباهت نحوی و معنایی یک دنباله تولیدشده توسط سیستم پیشنهادی ($\hat{S}$) نسبت به دنباله هدف (S)، به ترتیب براساس معیارهای استاندارد Rouge [۴۵] و BERTScore [۴۶] ارزیابی می‌شود.

Rouge: برای محاسبه این معیار کفایت مطابق رابطه (۵) همپوشانی N -گرام‌های دنباله تولیدشده و دنباله هدف را بر تعداد کل N -گرام‌های دنباله هدف تقسیم نمود. خروجی این رابطه، عددی در بازه [۰، ۱] است بطوریکه، نزدیکتر بودن آن به مقدار ۱، بر همپوشانی واژگانی بیشتر و کیفیت بالاتر دنباله‌های تولیدشده دلالت

دارد.

$$\text{ROUGE-N} = \frac{\sum_{g_N \in S} \sum_{\hat{g}_N \in \hat{S}} 1(g_N == \hat{g}_N)}{\sum_{g_N \in S} 1} \quad (5)$$

در مواردی که ترتیب N -گرام‌ها نیز حائز اهمیت است استفاده از ROUGE-L که طبق رابطه (۶)، بزرگترین دنباله مشترک^۲ را ملاک قرار می‌دهد، توصیه می‌گردد.

$$\text{ROUGE-L} = \frac{\text{LCS}(S, \hat{S})}{|\hat{S}|} \quad (6)$$

BERTScore: برخلاف معیار Rouge که شباهت واژگانی را اندازه‌گیری می‌کند، معیار BERTScore بر سنجش شباهت معنایی میان دنباله هدف و دنباله تولیدشده متمرکز است. برای این منظور، ابتدا هر دو دنباله، به یک مدل ترانسفورمر مبتنی بر BERT ارائه شده و بردارهای تعبیه E^S و $E^{\hat{S}}$ تولید می‌شوند. سپس، براساس رابطه (۷)، امتیاز شباهت کسینوسی بردار تعبیه هر نشانه از دنباله هدف نسبت به یکایک نشانه‌های دنباله تولیدشده محاسبه شده و در پایان، با انجام یک تطابق حریصانه (تابع بیشینه) امتیاز نهایی در خروجی ارائه می‌شود.

$$\text{BERTScore}_{\text{Recall}} = \frac{1}{|\hat{S}|} \sum_{e_i \in E^{\hat{S}}} \max_{\hat{e}_j \in E^S} e_i^T \hat{e}_j \quad (7)$$

در این رابطه، e_i و $\hat{e}_i$ مبین بردارهای تعبیه i -امین نشانه در دنباله‌های S و $\hat{S}$ هستند.

۴-۴- تحلیل نتایج

در این بخش تحلیل نتایج آزمایش‌ها در چهار سناریو، متناظر با چهار پرسش اصلی پژوهش، ارائه می‌گردد.

۴-۴-۱- ارزیابی عملکرد مؤلفه مدلسازی کاربر

مدل زبانی Llama2 در مؤلفه مدلسازی کاربر موظف است برای هر پرسش از سوابق پرسشگر، دنباله‌ای از برچسب‌های موضوعی را تولید نماید. برای تحقق این امر، ابتدا مدل Llama2 با استفاده از دادگان آموزش CQAD-ReQuEST تنظیم می‌گردد. شکل ۲، الگوی اعلان ورودی و شکل ۳، سیر تغییرات تابع خطا در جریان آموزش را نشان می‌دهد. روند نزولی خطا در این نمودار، شاهدهی بر آموزش موفق مدل Llama2 و بهبود تدریجی عملکرد آن است. ضمن اینکه به نظر می‌رسد با افزایش تعداد تکرارهای آموزش بتوان به نتایج دقیق‌تر و پایدارتری دست یافت.

² Longest common sequence of words (LCS)

¹ Overlap

گام بروزرسانی پارامترهای مدل، محاسبه شده است. لازم به ذکر است، تعداد پارامترهای قابل آموزش در مدل شناسایی پرسش‌های متضمن برابر با ۳۳/۶ میلیون و متوسط زمان پیش‌بینی برچسب برای هر زوج پرسش، حدود ۰/۴۲۵ ثانیه است.

```
<s> [INST] <<SYS>>
Given two questions, Q1 and Q2, determine if Q1
entails Q2 or not.
<</SYS>>

Entailment means every answer to Q2 must fully or
partially answer Q1.
Note that, Q2 must align with the user's topics of
interest: ({UserKnowledge}).
Respond with "positive" or "negative" only.
Q1: {Question1}
Q2: {Question2}
### Answer:
[/INST]

{Label}
```

(الف)

```
<s> [INST] <<SYS>>
Given two questions, Q1 and Q2, determine if Q1
entails Q2 or not.
<</SYS>>

Entailment means every answer to Q2 must fully or
partially answer Q1.
Respond with "positive" or "negative" only.
Q1: {Question1}
Q2: {Question2}
### Answer:
[/INST]

{Label}
```

(ب)

شکل ۵. الگوی اعلان مورد استفاده برای تنظیم مؤلفه شناسایی پرسش‌های متضمن (الف) آگاه به کاربر (ب) مستقل از کاربر

نتایج ارائه شده در شکل ۶ (الف)، گویای آن است که افزایش مقادیر α و r ، افزایش ظرفیت مدل برای یادگیری و تسریع همگرایی را به همراه دارد. براساس این نتایج، مقادیر ۶۴ و ۱۶ به عنوان مقادیر بهینه برای این دو پارامتر انتخاب می‌شوند. شکل ۶ (ب) تأثیر مقادیر مختلف نرخ حذف نوروها بر عملکرد مدل را نشان می‌دهد. همانطور که ملاحظه می‌شود، در مراحل اولیه آموزش، مقادیر ۰/۱ و ۰/۲ کمترین خطای اعتبارسنجی را داشته‌اند. با این حال در ادامه، مدل مبتنی بر ۰/۳ توانسته است با شیب نزولی بیشتر، از آنها پیشی گرفته و جایگاه نخست را به خود اختصاص دهد. در مقابل، مقدار ۰/۴ به کم‌برازش مدل انجامیده و در جایگاه آخر قرار گرفته است.

مطابق شکل ۴، مدل BERT با اختلاف زیاد نسبت به سایر رقبا، بدترین عملکرد را ارائه داده و از چرخه آزمایش‌ها خارج می‌شود. در مقابل، مدل ترانسفورمر all-mpnet-base-v2 با تولید تعبیه‌های برداری در سطح جمله، جایگاه نخست را به خود اختصاص داده است. برتری این مدل را می‌توان ناشی از مدیریت بهتر جایگشت^۱ کلمات در جمله و در نتیجه درک بهتر روابط بافتاری دانست [۴۷].

جدول ۶. مقایسه مدل‌های مختلف بازنمایی برداری براساس میانگین

نام مدل	زمان تولید بازنمایی یک پرسش (s)
TF-IDF	$1/0.3 \times 10^{-1}$
paraphrase-MiniLM-L6-v2	$9/63 \times 10^{-1}$
paraphrase-multilingual-MiniLM-L12-v2	$1/71 \times 10^{-1}$
BERT-base-cased	$2/89 \times 10^{-1}$
all-mpnet-base-v2	$3/97 \times 10^{-1}$


مدل TF-IDF را نیز می‌توان بهینه‌ترین مدل از نظر زمان اجرا معرفی کرد؛ ضمن اینکه مطابق شکل ۴، کیفیت عملکرد آن نسبت به مدل‌های تعبیه بافتاری، قابل قبول ارزیابی می‌شود. در این میان، مدل‌هایی که برای وظیفه تشخیص بازنویسی^۲ آموزش دیده‌اند از نظر میانگین زمان بازنمایی، سریعتر از مدل mpnet عمل کرده و از نظر کیفیت بازنمایی‌ها، در رده متوسط قرار گرفته‌اند.

۴-۳- سنجش میزان اثربخشی مدلسازی کاربر در

فرآیند شناسایی پرسش‌های متضمن

این بخش از آزمایشات، نخست به تنظیم ابرپارامترها برای آموزش مؤلفه شناسایی پرسش‌های متضمن پرداخته و سپس، با مقایسه عملکرد این مؤلفه در حضور و عدم حضور دانش مدل‌شده برای کاربر، به سومین پرسش پژوهشی پاسخ می‌دهد. برای این منظور، مدل Llama2 براساس زوج پرسش‌های برچسب‌خورده در دادگان آموزش CQAD-ReQuEST تنظیم دقیق می‌شود. شکل ۵، الگوی اعلان را برای دو حالت آگاه به کاربر و مستقل از کاربر نمایش می‌دهد. در شکل ۶ نیز تغییرات خطای آموزش و اعتبارسنجی به ازای مقادیر مختلف ابرپارامترها به تصویر کشیده شده است. در این آزمایش‌ها، به دلیل محدودیت منابع محاسباتی و گستردگی فضای حالت، فرآیند آموزش به سه تکرار محدود شده است. به‌طور کلی، مقادیر ارائه شده در جدول ۴، به عنوان پیکربندی پایه در نظر گرفته شده و در هر آزمایش، تنها یکی از ابرپارامترها تغییر داده شده است تا تأثیر مستقل آن بر عملکرد مدل ارزیابی گردد. خطای اعتبارسنجی نیز به منظور پایش دقیق‌تر رفتار مدل، پس از هر ۱۰

² Paraphrase¹ Permutation



شکل ۶. مقایسه تغییرات تابع خطای آموزش و اعتبارسنجی در طول فرآیند آموزش مدل برای مقادیر مختلف پارامترهای (الف) r و α در $dora$ ، (ب) نرخ حذف نورون‌ها و (ج) نرخ یادگیری


شکل ۷ مقایسه تغییرات تابع خطا در طول فرآیند آموزش در دو اجرای مذکور را نمایش می‌دهد. در این نمودار، محور افقی مبین تکرارهای آموزش و محور عمودی نشان‌دهنده میزان خطای آموزش است. همانطور که ملاحظه می‌شود، رقابت تنگاتنگی میان دو مدل شکل گرفته است. تا تکرار هفتم آموزش، روند همگرایی دو مدل تقریباً یکسان بوده و هیچ‌کدام از آنها نتوانسته‌اند بر رقیب خود فائق آیند. اما با ادامه یافتن فرآیند آموزش و افزایش ناگهانی خطای مدل مستقل از دانش کاربر در تکرار هشتم، نتیجه به نفع مدل متمرکز بر دانش کاربر تغییر می‌کند. در واقع، چنین استنباط می‌شود که

در شکل ۶ (ج)، عملکرد مدل به ازای مقادیر مختلف نرخ یادگیری نشان داده شده است. به‌طور کلی، افزایش نرخ یادگیری سبب تسریع همگرایی در مراحل اولیه آموزش می‌گردد و همزمان، احتمال وقوع بیش‌برازش در مراحل آتی نیز بیشتر می‌شود. در این آزمایش، نرخ یادگیری 4×10^{-5} ، علیرغم آنکه شروع بهتری را رقم زده است با گذشت زمان، ناپایدار گشته و بر مدل مبتنی بر نرخ 3×10^{-5} مغلوب گشته است. بنابراین، نرخ یادگیری 3×10^{-5} با حفظ فاصله معنادار از سایر رقبای، به عنوان مقدار بهینه برای آزمایش‌های بعدی انتخاب می‌شود.

نموده و k_3 پرسش متضمن برتر را پس از شناسایی، به مؤلفه تولید پاسخ ارسال نمودیم. در جدول ۸، تعداد کل پرسش‌هایی که برچسب متضمن یا غیرمتضمن دریافت نموده‌اند، به تفکیک مدل مورد استفاده برای بازنمایی، گزارش شده است. همچنین، به ازای هریک از مقادیر ۳ و ۵ برای متغیر k_3 ، تعداد پرسش‌هایی که بطور مشابه توسط هر دو مدل آگاه به کاربر و مستقل از کاربر، به عنوان یک پرسش متضمن برتر شناسایی شده‌اند، شمارش شده است. همان‌طور که در جدول ۸ مشاهده می‌شود، مدل آگاه به کاربر در تمام اجراها، نسبت به مدل مستقل از کاربر، تعداد کمتری از پرسش‌ها را به عنوان متضمن شناسایی کرده است. این نتیجه می‌تواند ناشی از افزودن شرط همسویی پرسش‌ها با دانش پرسشگر بوده و تأییدی بر دقت بالاتر مدل پیشنهادی تلقی شود. ذکر این نکته ضروری است که هر دو مدل، دارای محدودیت در طول زوج پرسش ورودی بوده و این محدودیت، در مدل آگاه به کاربر، به دلیل اضافه شدن شرط تطابق با دانش کاربر، بیشتر است. به همین علت است که جمع تعداد پرسش‌های متضمن و غیرمتضمن در تمامی اجراها کمتر از ۷۴۰۰ است.

با مقایسه مدل‌های مختلف بازنمایی از نظر تعداد پرسش‌های متضمن شناسایی‌شده توسط مدل آگاه به کاربر، می‌توان به اهمیت کیفیت بازنمایی در دقت بازیابی پرسش‌های مشابه پی برد. نتایج نشان می‌دهند که هرچه مدل بازنمایی پیچیده‌تر بوده و توانایی بیشتری در درک روابط عمیق معنایی و بافتاری داشته باشد، کاندیداهای شایسته‌تری انتخاب شده و به تبع آن، تعداد بیشتری برچسب متضمن را دریافت می‌کنند. بنابراین، مدل‌های TF-IDF و paraphrase-MiniLM-L6-v2 نیز از چرخه ارزیابی‌ها کنار گذاشته می‌شوند. در تمام اجراها، بیش از ۸۳٪ پرسش‌های منتخب دو مدل، مشترک بوده و این اشتراک، با کاهش پارامتر k_3 افزایش می‌یابد. این شواهد نشان می‌دهند که دو مدل، غالباً در تصمیم‌گیری برای پرسش‌های ابتدا و انتهای فهرست پرسش‌های مشابه، اتفاق نظر دارند و اختلاف آنها، در میانه لیست که پرسش‌ها شباهت کمتری به پرسش جدید دارند برجسته‌تر می‌شود.

هر دو مدل در برخورد با اکثریت زوج پرسش‌ها که فاقد ابهام بوده‌اند، عملکرد یکسانی ارائه داده‌اند؛ اما مدل مبتنی بر دانش کاربر توانسته است با تصمیم‌گیری دقیق‌تر برای اقلیت مبهم پرسش‌ها، برتری خود را به اثبات رساند. ارزیابی عملکرد این دو مدل روی دادگان آزمون که نتایج آن در جدول ۷ ارائه شده است نیز استدلال فوق را تأیید می‌کند. به این ترتیب، مدل متمرکز بر کاربر با کسب ۱٪ دقت بالاتر، به عنوان مؤلفه پیشنهادی برای شناسایی پرسش‌های متضمن در سیستم پژوهش به کار گرفته می‌شود.



شکل ۷. تغییرات خطا در فرآیند آموزش مؤلفه شناسایی پرسش‌های متضمن در دو حالت آگاه به کاربر و مستقل از آن

جدول ۷. مقایسه عملکرد دو مدل شناسایی پرسش‌های متضمن آگاه به کاربر و مستقل از کاربر روی دادگان آزمون CQAD-ReQuEST

مدل	صحت	F1	دقت	فراخوانی
مستقل از کاربر	٪۹۴/۸	٪۹۴/۸	٪۹۴/۷	٪۹۵/۰
متمرکز بر کاربر	٪۹۵/۴	٪۹۵/۴	٪۹۵/۷	٪۹۵/۱

سؤالی که ممکن است به ذهن خطور کند این است که "۱٪ بهبود در دقت مؤلفه پیشنهادی برای شناسایی پرسش‌های متضمن، تا چه اندازه می‌تواند در بهبود کیفیت پاسخ‌های نهایی سیستم اثرگذار باشد؟" برای پاسخ به این پرسش، مدل‌های مذکور را بر روی ۵۰ پرسش مشابهی که برای هر پرسش ورودی بازیابی شده بودند اعمال

جدول ۸. توزیع برچسب‌های پیش‌بینی‌شده توسط دو مدل شناسایی پرسش‌های متضمن آگاه به کاربر و مستقل از کاربر

مدل بازنمایی	برچسب پیش‌بینی‌شده				مدل آگاه به کاربر		مدل مستقل از کاربر		اشتراک
	متضمن	غیرمتضمن	متضمن	غیرمتضمن	متضمن	غیرمتضمن	متضمن	غیرمتضمن	
TF-IDF	۵۰۶۵	۲۲۴۵	۶۰۳۹	۱۳۱۱	۳۸۷ (٪۸۷/۲)	۶۱۵ (٪۸۳/۱)	۳۸۷ (٪۸۷/۲)	۶۱۵ (٪۸۳/۱)	
paraphrase-MiniLM-L6-v2	۵۰۶۱	۱۷۲۹	۶۰۷۲	۸۴۴	۳۸۳ (٪۸۶/۳)	۶۲۴ (٪۸۴/۳)	۳۸۳ (٪۸۶/۳)	۶۲۴ (٪۸۴/۳)	
paraphrase-multilingual-MiniLM-L12-v2	۵۳۰۶	۱۴۸۴	۶۱۲۷	۷۸۲	۳۹۶ (٪۸۹/۲)	۶۵۱ (٪۸۸/۰)	۳۹۶ (٪۸۹/۲)	۶۵۱ (٪۸۸/۰)	
all-mpnet-base-v2	۶۳۲۲	۹۵۴	۶۸۰۷	۴۷۰	۴۲۰ (٪۹۴/۶)	۶۹۵ (٪۹۳/۹)	۴۲۰ (٪۹۴/۶)	۶۹۵ (٪۹۳/۹)	
تعداد کل زوج پرسش‌ها	۷۴۰۰				۴۴۴		۷۴۰		

جدول ۹. تحلیل کیفی عملکرد مدل شناسایی پرسش‌های متضمن آگاه به کاربر و مدل مستقل از کاربر

Why do we use their instead of his in this sentence? another driver flashes their lights.	پرسش ۱	مثال ۱	پرسش ۲	دانش کاربر	برچسب هدف	متضمن	پیش‌بینی مدل آگاه به کاربر:	متضمن	پیش‌بینی مدل مستقل از کاربر:	غیرمتضمن
Is there a pronoun I can use as a gender-neutral pronoun? Each student should save his questions until the end. Each student should save her questions until the end.										
meaning, word choice, grammar, single word requests										
I am writing my thesis and I am experiencing a problem with the space between numbering and the image name. You can see the problem in the picture I include in this question. It starts from 3.10. How can I fix that?	پرسش ۱	مثال ۲	پرسش ۲	دانش کاربر	برچسب هدف	متضمن	پیش‌بینی مدل آگاه به کاربر:	متضمن	پیش‌بینی مدل مستقل از کاربر:	غیرمتضمن
I'm preparing a document using the book class. In the table of contents, the indentation before the subsection title is too long. How to reduce it?										
tikz pgf, tables, table of contents										
I have the border points of a 2-D body and wish to fill its interior with a solid color. Let us say I have N such points stacked in the N×2 matrix A so that the first column indicates the x co-ordinates and the second column denotes the corresponding y co-ordinates. How can I get the co-ordinates of the convex hull of a piece of Text?	پرسش ۱	مثال ۳	پرسش ۲	دانش کاربر	برچسب هدف	متضمن	پیش‌بینی مدل آگاه به کاربر:	متضمن	پیش‌بینی مدل مستقل از کاربر:	غیرمتضمن
graphics, functions, qgis, arctgis desktop										
How do i multiply 2 array index variables given the following foo=(1 2) bar=(0.1 0.2) foobar=\$((foo[1]*price[1])) # this is wrong echo "\$foobar" Current output : 0 Correct/Expected output : 0.4	پرسش ۱	مثال ۴	پرسش ۲	دانش کاربر	برچسب هدف	متضمن	پیش‌بینی مدل آگاه به کاربر:	متضمن	پیش‌بینی مدل مستقل از کاربر:	غیرمتضمن
Using echo "20+5" literally produces the text "20+5". What command can I use to get the numeric sum, 25 in this case? Also, what's the easiest way to do it just using bash for floating point? For example, echo \$((3224/3807.0)) prints 0 :(. I am looking for answers using either the basic command shell ('command line') itself or through using languages that are available from the command line.										
linux, bash, shell script, graphics, functions, programming, ubuntu, programming languages										
For instance: For as long as it takes... but For as long we have a future... I know how to use them because I heard them being used, but I don't know whether there is a rule or not.	پرسش ۱	مثال ۵	پرسش ۲	دانش کاربر	برچسب هدف	غیرمتضمن	پیش‌بینی مدل آگاه به کاربر:	متضمن	پیش‌بینی مدل مستقل از کاربر:	غیرمتضمن
I would like to know whether or not the following sentences are correct and why: I have been sick since last week. I have been sick since the last week. I have been sick for the last week.										
meaning, word choice, grammar										

Generate a concise, single-paragraph answer to the question below based on the provided answers.

- Avoid unnecessary elaboration or examples.
- Focus on addressing the question's requirements.
- Ensure every provided answer is analyzed.
- Avoid using your world knowledge for answering. You can only use it for rephrasing answers to match the question requirement.

```
### Question: {Question}
### Answer1: {CandidateAnswer1}
### Answer2: {CandidateAnswer2}
### Answer3: {CandidateAnswer3}
### Response:
```

شکل ۸. الگوی اعلان مورد استفاده برای تولید پاسخ

۴-۴-۴- تحلیل عملکرد سیستم پیشنهادی در تولید پاسخ

در آخرین مؤلفه از سیستم پیشنهادی، پاسخ‌های تأییدشده متناظر با برترین پرسش‌های متضمن، به یک مدل زبانی مولد پاسخ ارسال می‌شوند. شکل ۸ الگوی اعلان ورودی به مدل زبانی را نمایش می‌دهد. جدول ۱۰ نیز نتایج ارزیابی پاسخ‌های تولیدشده نسبت به

مطالعه موردی. اگرچه ارزیابی کمی عملکرد مؤلفه شناسایی

پرسش‌های متضمن، برتری مدل آگاه به کاربر را نشان می‌دهد، تحلیل کیفی نیز می‌تواند مهر تأییدی بر این نتایج باشد. جدول ۹، در مثال‌های ۱ تا ۴، نمونه‌هایی را نشان می‌دهد که در آنها، آگاهی از دانش کاربر، به تشخیص صحیح ارتباط میان زوج پرسش انجامیده است. زوج پرسش مثال ۱، علیرغم عدم اشتراک واژگانی، مضمونی کاملاً مشابه یکدیگر دارند. در این حالت، تأکید بر موضوعاتی نظیر گرامر، معنا و گزینش کلمات در دانش کاربر، مدل را از تمرکز صرف بر تطابق واژگانی فراتر برده و آن را به درک عمیق‌تر مفهوم پرسش‌ها سوق داده است. البته، در موارد نادری نظیر مثال ۵، نادیده گرفتن تطابق واژگانی ممکن است نتیجه‌ای معکوس در پی داشته و موجب گمراهی مدل شود. به عنوان نمونه‌ای دیگر، پرسش اول در مثال ۴، اصلاح یک قطعه برنامه را از متخصصین طلب نموده است. این در حالیه که هیچ یک از کلمات linux, shell یا command به طور مستقیم در پرسش ذکر نشده‌اند. دانش کاربر، این شکاف واژگانی را پر نموده و پل ارتباطی میان زوج پرسش را برقرار کرده است.

و پاسخ‌های دریافتی‌اش را نمایش می‌دهد. در این مثال از یک مدل all-mpnet-base-v2 برای تولید بازنمایی و از GPT-4o mini برای تولید پاسخ استفاده شده و مقدار پارامتر k_3 برابر با ۵ در نظر گرفته شده است. مدل‌های مذکور، در دو مورد از پنج پاسخ کاندید بازیابی شده، اشتراک داشته و مابقی پاسخ‌های کاندید متفاوت بوده‌اند. از آنجا که پرسش ورودی شامل چند پرسش کوتاه‌تر در مورد موضوعات مختلف است، می‌توان آن را نسبتاً پیچیده دانست. همانطور که مشاهده می‌شود پاسخ ارائه شده توسط مدل آگاه به کاربر از ساختار منطقی و منسجم‌تری برخوردار بوده و تحلیل صحیحی در مورد ساختار گرامری جمله ارائه داده است. حال آنکه پاسخ ارائه شده توسط مدل مستقل از کاربر، ناکامل بوده و دارای توضیحات سطحی است.

پاسخ‌های تأییدشده برای پرسش‌های ورودی را گزارش می‌کند. این نتایج به وضوح بر برتری مدل آگاه به کاربر دلالت دارند. بطور خاص، اجرایی که از GPT-4o mini به عنوان مدل تولیدکننده پاسخ و از all-mpnet-base-v2 برای تولید بازنمایی استفاده کرده‌اند، به ازای ۳ پاسخ کاندید به بهبود ۱/۰۷٪ و به ازای ۵ پاسخ کاندید به بهبود ۳/۷۹٪ در معیار Rouge-1 مبتنی بر فراخوانی دست یافته‌اند. این اختلاف در معیارهای Rouge-2 و Rouge-L نیز قابل توجه است.

مطالعه موردی. با توجه به آنکه تعداد نمونه‌های آزمون برای مؤلفه تولید پاسخ محدود است، تنها تعداد انگشت‌شماری از پرسش‌ها را می‌توان یافت که پاسخ متفاوتی را از دو مدل آگاه به کاربر و مستقل از کاربر دریافت نموده‌اند. جدول ۱۱، یک نمونه از پرسش‌های آزمون

جدول ۱۰. ارزیابی کیفی پاسخ‌های تولیدشده نسبت به پاسخ‌های تأییدشده در دادگان پژوهش، به تفکیک مدل بازنمایی و مدل مولد پاسخ

مدل تولید پاسخ	مدل شناسایی	مدل بازنمایی	معیار ارزیابی (%)								
			BS-f	BS-r	RL-f	RL-r	R2-f	R2-r	R1-f	R1-r	
$k_3 = 3$	LLAMA2	paraphrase-multilingual-MiniLM-L12-v2	آگاه به کاربر	۸۲/۶۱	۸۲/۷۰	۱۳/۷۶	۲۲/۱۵	۴/۷۰	۷/۴۱	۲۳/۷۵	۳۵/۱۶
			مستقل از کاربر	۸۲/۵۷	۸۲/۷۳	۱۳/۶۳	۲۱/۹۷	۴/۶۷	۷/۳۸	۲۳/۷۰	۳۵/۰۸
			تفاوت	▲ ۰/۰۴	▽ ۰/۰۳	▲ ۰/۱۳	▲ ۰/۱۷	▲ ۰/۰۳	▲ ۰/۰۲	▲ ۰/۰۵	▲ ۰/۰۸
		all-mpnet-base-v2	آگاه به کاربر	۸۲/۸۹	۸۲/۵۷	۱۴/۳۲	۲۰/۸۶	۵/۰۶	۷/۲۷	۲۳/۹۶	۳۲/۵۴
			مستقل از کاربر	۸۲/۸۴	۸۲/۵۱	۱۴/۱۴	۲۰/۵۶	۴/۹۲	۶/۹۹	۲۳/۸۰	۳۲/۲۱
			تفاوت	▲ ۰/۰۴	▲ ۰/۰۷	▲ ۰/۱۸	▲ ۰/۳۰	▲ ۰/۱۴	▲ ۰/۲۸	▲ ۰/۱۶	▲ ۰/۳۴
	GPT-4o mini	paraphrase-multilingual-MiniLM-L12-v2	آگاه به کاربر	۸۲/۵۶	۸۲/۹۸	۱۲/۵۹	۲۴/۲۹	۴/۵۸	۹/۲۷	۲۲/۸۵	۳۹/۸۶
			مستقل از کاربر	۸۲/۵۶	۸۲/۶۹	۱۲/۵۱	۲۲/۵۴	۴/۲۳	۷/۶۷	۲۳/۱۷	۳۷/۴۱
			تفاوت	— ۰/۰۰	▲ ۰/۲۹	▲ ۰/۰۸	▲ ۱/۷۴	▲ ۰/۳۵	▲ ۱/۶۱	▽ ۰/۳۲	▲ ۲/۴۵
		all-mpnet-base-v2	آگاه به کاربر	۸۲/۹۶	۸۲/۶۴	۱۳/۶۵	۲۶/۶۶	۵/۵۴	۱۰/۰۰	۲۴/۴۱	۴۲/۸۳
			مستقل از کاربر	۸۲/۸۵	۸۲/۵۵	۱۳/۲۴	۲۵/۷۱	۵/۰۶	۹/۵۲	۲۳/۹۶	۴۱/۷۵
			تفاوت	▲ ۰/۱۱	▲ ۰/۰۹	▲ ۰/۴۱	▲ ۰/۹۵	▲ ۰/۴۸	▲ ۰/۴۸	▲ ۰/۴۶	▲ ۱/۰۷
$k_3 = 5$	LLAMA2	paraphrase-multilingual-MiniLM-L12-v2	آگاه به کاربر	۸۲/۵۲	۸۲/۶۱	۱۳/۵۱	۲۲/۸۷	۴/۵۶	۷/۶۱	۲۳/۰۶	۳۵/۷۶
			مستقل از کاربر	۸۲/۴۶	۸۲/۶۰	۱۳/۳۹	۲۲/۲۵	۴/۴۶	۷/۰۶	۲۳/۱۱	۳۵/۳۱
			تفاوت	▲ ۰/۰۶	▲ ۰/۰۱	▲ ۰/۱۱	▲ ۰/۶۲	▲ ۰/۱۰	▲ ۰/۵۵	▽ ۰/۰۵	▲ ۰/۴۵
		all-mpnet-base-v2	آگاه به کاربر	۸۲/۵۳	۸۲/۳۰	۱۳/۳۴	۲۰/۹۱	۴/۴۸	۶/۷۵	۲۲/۹۹	۳۳/۲۲
			مستقل از کاربر	۸۲/۶۰	۸۲/۳۶	۱۳/۴۵	۲۱/۰۴	۴/۴۷	۶/۷۳	۲۳/۰۰	۳۳/۲۸
			تفاوت	▽ ۰/۰۷	▽ ۰/۰۶	▽ ۰/۱۱	▽ ۰/۱۳	▲ ۰/۰۱	▲ ۰/۰۲	▽ ۰/۰۲	▽ ۰/۰۶
	GPT-4o mini	paraphrase-multilingual-MiniLM-L12-v2	آگاه به کاربر	۸۲/۲۹	۸۳/۱۶	۱۱/۹۴	۲۶/۵۳	۴/۴۲	۹/۴۹	۲۲/۱۴	۴۳/۲۳
			مستقل از کاربر	۸۲/۵۱	۸۲/۹۰	۱۲/۶۱	۲۴/۲۸	۴/۴۸	۸/۹۶	۲۳/۱۷	۳۹/۸۴
			تفاوت	▽ ۰/۲۲	▲ ۰/۲۶	▽ ۰/۶۷	▲ ۲/۲۵	▽ ۰/۰۶	▲ ۰/۵۳	▽ ۱/۰۲	▲ ۳/۴۰
		all-mpnet-base-v2	آگاه به کاربر	۸۲/۵۳	۸۳/۳۴	۱۲/۸۱	۲۶/۲۳	۴/۸۶	۹/۶۷	۲۳/۵۰	۴۲/۶۸
			مستقل از کاربر	۸۲/۴۹	۸۲/۹۱	۱۲/۵۹	۲۳/۷۵	۴/۲۷	۷/۵۸	۲۳/۱۵	۳۸/۸۹
			تفاوت	▲ ۰/۰۴	▲ ۰/۴۳	▲ ۰/۲۲	▲ ۲/۴۸	▲ ۰/۵۹	▲ ۲/۱۰	▲ ۰/۳۵	▲ ۳/۷۹

جدول ۱۱. مقایسه کیفیت پاسخ‌های ارائه شده در حضور و عدم حضور دانش کاربر

پرسش	Happy Holi to You and Your Family. Play Safe! Is anything grammatically wrong in above sentences? In which category does the second sentence fall? Can we replace <i>Play Safe!</i> with <i>Play Safely!</i> Are they equally true and depict same meaning? Is the usage of exclamation with both <i>safe</i> and <i>safely</i> correct?
پاسخ مدل RAG آگاه به کاربر	The second sentence, "Play Safe!", is grammatically correct but falls under an imperative mood, where it gives a directive. The phrase "Play Safely!" can replace "Play Safe!", but the meaning is slightly different: "Play Safely!" is an adverbial form that explicitly describes the manner of playing, whereas "Play Safe!" uses an adjective and has a more informal, idiomatic feel. Both versions are understood in the context of wishing someone a safe experience, but "Play Safe!" is more colloquial. Regarding the exclamation, both "Safe!" and "Safely!" can be used with an exclamation mark to emphasize urgency or excitement, though "Play Safe!" is the more commonly accepted version.
پاسخ مدل RAG مستقل از کاربر	The second sentence, "Play Safe!" is grammatically correct but uses an imperative verb with an adverbial expression. It falls into the category of an imperative sentence, where a command or suggestion is given. While "Play Safely!" can also be used, it is slightly more formal or precise, as "safely" is an adverb, describing the manner of playing. Both "Play Safe!" and "Play Safely!" convey the same general meaning, but "Play Safe!" may feel more informal. The usage of an exclamation mark with both is acceptable, as it emphasizes the message, although it may be seen as more common in informal contexts with "Play Safe!"
پاسخ مدل GPT-40 mini	The sentence "Happy Holi to You and Your Family. Play Safe!" is almost grammatically correct, but it can be refined for smoother flow. The second sentence, "Play Safe!" is an imperative sentence, giving a command or instruction. While "Play Safe!" and "Play Safely!" are both grammatically acceptable, there is a subtle difference in usage. "Play Safe!" is more idiomatic and commonly used in casual speech, often implying a general sense of caution or safety, while "Play Safely!" is the technically correct form, with "safely" being the proper adverb to describe how one should play. Both phrases convey nearly the same meaning, with "Play Safe!" being more informal and colloquial. The usage of the exclamation mark with both "safe" and "safely" is appropriate, as both are commands or encouragements, but "Play Safe!" is more often used with the exclamation mark in everyday language. Therefore, while both versions are acceptable, the choice between them depends on the tone you want to convey—informal and idiomatic or more formal and precise.
پاسخ تأیید شده	Happy Holi! Well, first of all, in the English language, most words are not capitalized unless they are at the beginning of a sentence, or in the case of a "title", of sorts. Proper names are capitalized, but "you", "your", and "family" are not proper nouns. The one exception to this is if you are making a card of some sort. If you want it to stand out on a greeting card, then the capitalization may be appropriate. In that situation, it is a matter of personal choice. However, in most day-to-day conversations (or a post on someone's Facebook wall), it's generally best to avoid capitalizing words that would not be capitalized in a book. <i>Happy Holi to you and your family!</i> As for the second part, I'm not entirely sure that either of those phrases reflect your intended meaning. First of all, I am assuming by, "In which category does the second sentence fall?" you are asking about what type of sentence it is. The sentence seems to be what is called an <i>imperative</i> sentence. An imperative sentence is, essentially, a command. The subject of the sentence is implied to be "you", the one to whom the sentence is spoken. As for the meanings of the phrases, the imperative sentence, "Play safely," would be the type of warning you would give to a child, to remind him or her to avoid doing anything overly dangerous. The reason I say child, specifically, is because it is generally considered condescending to tell adults to play in most contexts, as "play" is widely considered to be a childish activity. On the other hand, the imperative sentence, "Play safe," is a (slightly-off) variation of an idiomatic expression, "Play it safe," and it has an entirely different meaning. To "play it safe" is to avoid taking risks, rather than to just be safe. Basically, you are telling the individual to go out of their way to make sure that there is as little damage done to them as possible. For the sake of clarity, telling someone to "play it safe" is <i>not</i> considered condescending, as it is an idiom which has little to do with the modern meaning of the word "play", but it is the wrong phrase for the meaning you likely wish to convey. If you wish to offer someone a wish of good health, and safety is the concern (or if you simply want to wish someone luck in staying safe), then the sentence I would recommend would be a simpler phrase: <i>Happy Holi to you and your family! Be safe!</i> This avoids the questionable use of "play" (as well as the grammar issues regarding the word "safe" not being an adverb; only adverbs can describe verbs), and makes the meaning clear. It is another imperative, telling "you" to be safe. Totally lovely.

۵- نتیجه‌گیری و کارهای آتی

این مقاله، سیستمی با نام UserQA برای پاسخگویی به پرسش‌ها در انجمن‌های پرسش و پاسخ معرفی نموده‌است. این سیستم بر پایه شناخت پرسشگر از طریق تحلیل سوابق پرسش‌های وی در انجمن استوار است تا به واسطه آن، به درک عمیق‌تری از موضوع اصلی پرسش ورودی دست یافته و فهرست پرسش‌های متضمن را با دقت بالاتری از بایگانی انجمن بازیابی نماید. UserQA به مدد زنجیره‌ای از مدل‌های زبانی بزرگ، دانش پرسشگر را به صورت دنباله‌ای از برچسب‌های موضوعی، مدلسازی نموده و با دریافت یک زوج پرسش، وجود یا عدم وجود رابطه تضمین میان آنها را پیش‌بینی می‌کند. سپس، برترین پاسخ‌های کاندید را با تمرکز بر پرسش ورودی، در یک پاسخ واحد جمع می‌نماید. طبق بهترین دانش ما،

استفاده از دانش کاربر در شناسایی پرسش‌های متضمن، موضوعی است که تاکنون در ادبیات پژوهش به آن پرداخته نشده است. نتایج آزمایش‌ها روی دادگان CQAD-ReQuEST، عملکرد مطلوب سیستم پیشنهادی و بهبود کیفیت پاسخ‌ها را نشان داد. در مطالعات آتی می‌توان عملکرد سیستم پیشنهادی پژوهش را در پلتفرم‌های پاسخگویی به پرسش‌های خاص-دامنه همچون پزشکی و اقتصاد، که اعتبار و صحت پاسخ‌ها در آنها اهمیت دوچندان می‌یابد، ارزیابی نمود. علاوه‌براین، طراحی مؤلفه شناسایی پرسش‌های متضمن بین‌زبانی به منظور بهره‌گیری از پاسخ‌های ارائه شده در سایر زبان‌ها، آموزش مدل‌های زبانی بزرگ برای خلاصه‌سازی چند پاسخ متمرکز

226–234, doi: 10.1137/1.9781611976236.26.

- [15] D. Hoogeveen, A. Bennett, Y. Li, K. Verspoor, and T. Baldwin, 'Detecting Misflagged Duplicate Questions in Community Question-Answering Archives', *Proc. Int. AAAI Conf. Web Soc. Media*, vol. 12, no. 1, pp. 112–120, Jun. 2018, doi: 10.1609/icwsm.v12i1.15011.
- [16] P. K. Roy, S. Saumya, J. P. Singh, S. Banerjee, and A. Gutub, 'Analysis of community question- answering issues via machine learning and deep learning: State- of- the- art review', *CAAI Trans. Intell. Technol.*, vol. 8, no. 1, pp. 95–117, Mar. 2023, doi: 10.1049/cit2.12081.
- [17] N. Othman, R. Faiz, and K. Smaili, 'Enhancing Question Retrieval in Community Question Answering Using Word Embeddings', *Procedia Comput. Sci.*, vol. 159, pp. 485–494, 2019, doi: 10.1016/j.procs.2019.09.203.
- [18] G. Zhou, L. Cai, J. Zhao, and K. Liu, 'Phrase-based translation model for question retrieval in community question answer archives', *ACL-HLT 2011 - Proc. 49th Annu. Meet. Assoc. Comput. Linguist. Hum. Lang. Technol.*, vol. 1, pp. 653–662, 2011.
- [19] K. Mrini et al., 'A Gradually Soft Multi-Task and Data-Augmented Approach to Medical Question Understanding', in *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, 2021, pp. 1505–1515, doi: 10.18653/v1/2021.acl-long.119.
- [20] N. S. Tawfik and M. R. Spruit, 'Evaluating sentence representations for biomedical text: Methods and experimental results', *J. Biomed. Inform.*, vol. 104, no. February, p. 103396, Apr. 2020, doi: 10.1016/j.jbi.2020.103396.
- [21] M. Faseeh, M. A. Khan, N. Iqbal, F. Qayyum, A. Mehmood, and J. Kim, 'Enhancing User Experience on Q&A Platforms: Measuring Text Similarity Based on Hybrid CNN-LSTM Model for Efficient Duplicate Question Detection', *IEEE Access*, vol. 12, no. January, pp. 34512–34526, 2024, doi: 10.1109/ACCESS.2024.3358422.
- [22] V. Nguyen, S. Karimi, and Z. Xing, 'Combining Shallow and Deep Representations for Text-Pair Classification', *ALTA 2021 - Proc. 19th Work. Australas. Lang. Technol. Assoc.*, pp. 68–78, 2021.
- [23] S. Ghasemi and A. Shakeri, 'Harnessing the Power of Metadata for Enhanced Question Retrieval in Community Question Answering', *IEEE Access*, vol. 12, no. May, pp. 65768–65779, 2024, doi: 10.1109/ACCESS.2024.3395449.
- [24] A. M. Monea, 'Medical Question Entailment based on Textual Inference and Fine-tuned BioMed-RoBERTa', in *2021 IEEE 17th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 2021, pp. 319–326, doi: 10.1109/ICCP53602.2021.9733687.
- [25] S. Yadav, V. Pallagani, and A. Sheth, 'Medical Knowledge-enriched Textual Entailment Framework', in *Proceedings of the 28th International Conference on Computational Linguistics*, 2020, pp. 1795–1801, doi: 10.18653/v1/2020.coling-main.161.
- [26] T. R. Goodwin and D. Demner-Fushman, 'Bridging the Knowledge Gap: Enhancing Question Answering with World and Domain Knowledge', *CoRR abs/1910.07429*, Oct. 2019, [Online]. Available: <http://arxiv.org/abs/1910.07429>.
- [27] A. B. Abacha, D. Demner-fushman, and U. S. N. Library, 'Recognizing Question Entailment for Medical Question Answering', in *AMIA Annual Symposium Proceedings*, 2016, pp. 310–318.
- [28] T. Baldwin, H. Liang, B. Salehi, D. Hoogeveen, Y. Li, and L. Duong, 'UniMelb at SemEval-2016 Task 3: Identifying Similar Questions by combining a CNN with String Similarity Measures', in *Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016)*, 2016, pp. 851–856, doi:

بر پرسش، تنظیم نرم اعلان^۱ و مدیریت شروع سرد^۲ و پویایی کاربر از موضوعات تحقیقاتی بالقوه برای پژوهش‌های آتی به‌شمار می‌آیند.

مراجع

- [1] B. Patra, 'A survey of Community Question Answering', *CoRR, abs/1705.04009*, May 2017, [Online]. Available: <http://arxiv.org/abs/1705.04009>.
- [2] D. Hoogeveen, L. Wang, T. Baldwin, and K. M. Verspoor, 'Real and Misflagged Duplicate Question Detection in Community Question-Answering', 2018.
- [3] A. Figueroa, 'Automatically generating effective search queries directly from community question-answering questions for finding related questions', *Expert Syst. Appl.*, vol. 77, pp. 11–19, Jul. 2017, doi: 10.1016/j.eswa.2017.01.041.
- [4] I. Srba and M. Bielikova, 'A Comprehensive Survey and Classification of Approaches for Community Question Answering', *ACM Trans. Web*, vol. 10, no. 3, pp. 1–63, Aug. 2016, doi: 10.1145/2934687.
- [5] M. Sulir and M. Regeci, 'Software Engineers' Questions and Answers on Stack Exchange', in *2022 IEEE 16th International Scientific Conference on Informatics (Informatics)*, Nov. 2022, pp. 304–310, doi: 10.1109/Informatics57926.2022.10083403.
- [6] M. Asaduzzaman, A. S. Mashiyat, C. K. Roy, and K. A. Schneider, 'Answering questions about unanswered questions of Stack Overflow', in *2013 10th Working Conference on Mining Software Repositories (MSR)*, May 2013, pp. 97–100, doi: 10.1109/MSR.2013.6624015.
- [7] S. A. Bhaskar, R. Rungta, J. Route, E. Nyberg, and T. Mitamura, 'Sieg at MEDIQA 2019: Multi-task Neural Ensemble for Biomedical Inference and Entailment', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 462–470, doi: 10.18653/v1/W19-5049.
- [8] A. Merchant, N. Shenoy, A. Bharali, and A. K. M., 'Identifying Similar Questions in the Medical Domain Using a Fine-tuned Siamese-BERT Model', in *2022 IEEE 19th India Council International Conference (INDICON)*, Nov. 2022, pp. 1–6, doi: 10.1109/INDICON56171.2022.10040144.
- [9] A. B. Abacha and D. Demner-Fushman, 'A question-entailment approach to question answering', *BMC Bioinformatics*, vol. 20, no. 1, Dec. 2019, doi: 10.1186/s12859-019-3119-4.
- [10] Z. Xu and H. Yuan, 'Forum Duplicate Question Detection by Domain Adaptive Semantic Matching', *IEEE Access*, vol. 8, pp. 56029–56038, 2020, doi: 10.1109/ACCESS.2020.2982268.
- [11] L. Wang, L. Zhang, and J. Jiang, 'Duplicate Question Detection With Deep Learning in Stack Overflow', *IEEE Access*, vol. 8, pp. 25964–25975, 2020, doi: 10.1109/ACCESS.2020.2968391.
- [12] D. D. Koswate and S. Hettiarachchi, 'Optimized Duplicate Question Detection in Programming Community Q&A Platforms using Semantic Hashing', in *2021 10th International Conference on Information and Automation for Sustainability (ICIAfS)*, Aug. 2021, pp. 375–380, doi: 10.1109/ICIAfS52090.2021.9606030.
- [13] V.-T. Nguyen, A.-C. Le, and H.-N. Nguyen, 'A Model of Convolutional Neural Network Combined with External Knowledge to Measure the Question Similarity for Community Question Answering Systems', *Int. J. Mach. Learn. Comput.*, vol. 11, no. 3, pp. 194–201, May 2021, doi: 10.18178/ijmlc.2021.11.3.1035.
- [14] R. Zhang, Q. Zhou, B. Wu, W. Li, and T. Mo, 'What do questions exactly ask? mfae: duplicate question identification with multi-fusion asking emphasis', in *Proceedings of the 2020 SIAM International Conference on Data Mining, SDM 2020*, 2020, pp.

² Cold start

¹ Soft prompt tuning

- Transfer Learning with Data Augmentation for Recognizing Question Entailment in the Medical Domain', in *2021 IEEE 9th International Conference on Healthcare Informatics (ICHI)*, Aug. 2021, pp. 339–346, doi: 10.1109/ICHI52183.2021.00058.
- [39] H. Zhou, X. Li, W. Yao, C. Lang, and S. Ning, 'DUT-NLP at MEDIQA 2019: An Adversarial Multi-Task Network to Jointly Model Recognizing Question Entailment and Question Answering', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 437–445, doi: 10.18653/v1/W19-5046.
- [40] A. Shang, X. Zhu, M. Danner, and M. Rättsch, 'Unsupervised question-retrieval approach based on topic keywords filtering and multi-task learning', *Comput. Speech Lang.*, vol. 87, no. March, p. 101644, Aug. 2024, doi: 10.1016/j.csl.2024.101644.
- [41] K. Jiang, G. Jin, Z. Zhang, R. Cui, and Y. Zhao, 'Incorporating external knowledge for text matching model', *Comput. Speech Lang.*, vol. 87, no. March, p. 101638, Aug. 2024, doi: <https://doi.org/10.1016/j.csl.2024.101638>.
- [42] Y. Sun and J. Song, 'Research on question retrieval method for community question answering', *Multimed. Tools Appl.*, vol. 82, pp. 24309–24325, 2023, doi: <https://doi.org/10.1007/s11042-023-14458-2>.
- [43] D. Hoogveen, K. M. Verspoor, and T. Baldwin, 'CQADupStack: A Benchmark Data Set for Community Question-Answering Research', in *Proceedings of the 20th Australasian Document Computing Symposium*, Dec. 2015, pp. 1–8, doi: 10.1145/2838931.2838934.
- [44] S. Z. Aftabi, S. M. Seyyedi, M. Maleki, and S. Farzi, 'ReQuEST: A Small-Scale Multi-Task Model for Community Question-Answering Systems', *IEEE Access*, vol. 12, pp. 17137–17151, 2024, doi: 10.1109/ACCESS.2024.3358287.
- [45] C. Y. Lin, 'Rouge: A package for automatic evaluation of summaries', *Proc. Work. text Summ. branches out (WAS 2004)*, no. 1, pp. 25–26, 2004, [Online]. Available: [papers2://publication/uuid/5DDA0BB8-E59F-44C1-88E6-2AD316DAEF85](https://arxiv.org/abs/2004.04931).
- [46] T. Zhang, V. Kishore, F. Wu, K. Q. Weinberger, and Y. Artzi, 'BERTScore: Evaluating Text Generation with BERT', *CoRR abs/1904.09675*, pp. 1–43, Apr. 2019, [Online]. Available: <http://arxiv.org/abs/1904.09675>.
- [47] K. Song, X. Tan, T. Qin, J. Lu, and T.-Y. Liu, 'MPNet: Masked and Permuted Pre-training for Language Understanding', *Adv. Neural Inf. Process. Syst.*, vol. 2020-Decem, no. NeurIPS, pp. 1–11, Apr. 2020, [Online]. Available: <http://arxiv.org/abs/2004.09297>.
- 10.18653/v1/S16-1131.
- [29] A. B. Abacha and D. Demner-Fushman, 'On the Summarization of Consumer Health Questions', in *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 2019, pp. 2228–2234, doi: 10.18653/v1/P19-1215.
- [30] C. dos Santos, L. Barbosa, D. Bogdanova, and B. Zadrozny, 'Learning Hybrid Representations to Retrieve Semantically Equivalent Questions', in *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 2: Short Papers)*, 2015, vol. 2, no. 1, pp. 694–699, doi: 10.3115/v1/P15-2114.
- [31] D. A. Prabowo and G. Budi Herwanto, 'Duplicate Question Detection in Question Answer Website using Convolutional Neural Network', in *2019 5th International Conference on Science and Technology (ICST)*, Jul. 2019, no. 1, pp. 1–6, doi: 10.1109/ICST47872.2019.9166343.
- [32] A. Agrawal, R. Anil George, S. S. Ravi, S. Kamath S, and A. Kumar, 'ARS_NITK at MEDIQA 2019:Analysing Various Methods for Natural Language Inference, Recognising Question Entailment and Medical Question Answering System', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 533–540, doi: 10.18653/v1/W19-5059.
- [33] N. Tawfik and M. Spruit, 'UU_TAILS at MEDIQA 2019: Learning Textual Entailment in the Medical Domain', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 493–499, doi: 10.18653/v1/W19-5053.
- [34] V. Nguyen, S. Karimi, and Z. Xing, 'ANU-CSIRO at MEDIQA 2019: Question Answering Using Deep Contextual Knowledge', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 478–487, doi: 10.18653/v1/W19-5051.
- [35] D. Bandyopadhyay, B. Gain, T. Saikh, and A. Ekbal, 'IITP at MEDIQA 2019: Systems Report for Natural Language Inference, Question Entailment and Question Answering', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 517–522, doi: 10.18653/v1/W19-5056.
- [36] K. Mrini, F. Dernoncourt, W. Chang, E. Farcas, and N. Nakashole, 'Joint Summarization-Entailment Optimization for Consumer Health Question Understanding', in *Proceedings of the Second Workshop on Natural Language Processing for Medical Conversations*, 2021, pp. 58–65, doi: 10.18653/v1/2021.nlpmc-1.8.
- [37] W. Zhu et al., 'PANLP at MEDIQA 2019: Pre-trained Language Models, Transfer Learning and Knowledge Distillation', in *Proceedings of the 18th BioNLP Workshop and Shared Task*, 2019, pp. 380–388, doi: 10.18653/v1/W19-5040.
- [38] M. Sarrouiti, A. B. Abacha, and D. Demner-Fushman, 'Multi-Task

پیوست ۱

جدول الف. نمونه‌هایی از زوج پرسش‌های متضمن و غیرمتضمن در دادگان پژوهش

مثال ۱. برچسب: متضمن

شناسه پرسش	شناسه پرسشگر	تاریخ ثبت	شناسه نظرات	پاسخ‌ها	تعداد علاقمندان	امتیاز
۱۶۹۷۰۷	۱۸۴۹۵	۲۰۱۴-۰۴-۰۵T۰۹:۵۴:۳۴.۹۶۷	۳۹۰۶۵۵-۳۹۰۶۵۶-۳۹۰۷۳۰	۱۶۹۷۰۸	۰	۱
تعداد ملاقات‌ها	پرسش‌های تکراری	پرسش‌های مرتبط	برچسب‌ها	شناسه پاسخ تأییدشده	نام انجمن	
۷۷	۸۲۹۹۳	۸۲۹۹۳	memoir, chapters, naming	۱۶۹۷۰۸	Tex	

Replace the text 'Chapter' with custom text in Memoir

How can I replace the word 'Chapter' with some other text string in Memoir class? So, instead of Chapter 1, it appears as, say, MyChapter 1. Also, the text is in Devanagari script so MyChapter will be some Devanagari text string.

Use `\renewcommand{\chaptername}{MyChapter}` at any position before you the first chapter which should get another chapter name. If you want to rename all chapter names, put the command in the preamble.

مشخصات پرسش ۱

پاسخ تأییدشده

شناسه پرسش	شناسه پرسشگر	تاریخ ثبت	شناسه نظرات	پاسخ‌ها	تعداد علاقمندان	امتیاز
۸۲۹۹۳	۵۱۰	۲۰۱۲-۱۱-۱۶T۱۴:۲۴:۵۷.۰۵۰	-	۸۳۰۲۱-۸۸۳۳۰-۸۲۹۹۴	۵۰	۷۰
تعداد ملاقات‌ها	پرسش‌های تکراری	پرسش‌های مرتبط	برچسب‌ها	شناسه پاسخ تأییدشده	نام انجمن	
۱۰۳۶۱	۵۴۸۱۹	۵۴۸۱۹-۳۶۵۷۵-۶۲۲۱۳-۸۲۹۶۰	naming	۸۲۹۹۴	Tex	

How to change the name of document elements like Figure Contents Bibliography etc.

I'd like to modify the names used to typeset some of my document elements. For example, the caption of figure floats should change from "Figure" to "Fig.", and my \tableofcontents sectioning heading shouldn't read "Contents", but "Table of Contents". How can I do that? `\documentclass{article} % \usepackage[english]{babel} \begin{document} \tableofcontents \section{foo} \begin{figure}[h] \centering \rule{1cm}{1cm}% placeholder for graphic \caption{A figure} \end{figure} \end{document}`

The answer depends on whether or not you use the `\babel` [...] To change the formatting of the "Contents" heading, either [...] For captions, the `\caption` package offers a host of customization possibilities.

مشخصات پرسش ۲

پاسخ تأییدشده

مثال ۲. برچسب: غیرمتضمن

شناسه پرسش	شناسه پرسشگر	تاریخ ثبت	شناسه نظرات	پاسخ‌ها	تعداد علاقمندان	امتیاز
۱۵۳۷۷۸	۲۴۰۷۲	۲۰۱۴-۰۱-۱۳T۰۵:۳۰:۰۱.۲۳۷	۴۲۲۵۲۵	۱۵۳۷۹۰	۲	۳
تعداد ملاقات‌ها	پرسش‌های تکراری	پرسش‌های مرتبط	برچسب‌ها	شناسه پاسخ تأییدشده	نام انجمن	
۲۹۵	-	-	fonts	-	Tex	

Open dyslexic font

Is it straight forward to use the OpenDyslexic font in a latex document? What steps would be required?

-

شناسه پرسش	شناسه پرسشگر	تاریخ ثبت	شناسه نظرات	پاسخ‌ها	تعداد علاقمندان	امتیاز
۱۳۸۶۵	۴۳۲۲	۲۰۱۱-۰۳-۱۹T۰۹:۲۰:۱۷.۱۴۷	۲۵۴۷۵-۲۵۴۷۶-۲۵۴۹۰...	۱۳۸۶۸	۲۱	۳۵
تعداد ملاقات‌ها	پرسش‌های تکراری	پرسش‌های مرتبط	برچسب‌ها	شناسه پاسخ تأییدشده	نام انجمن	
۸۸۱۱	-	۳۷۹۷	online	۱۳۸۶۸	Tex	

How to use LaTeX on blogspot?

I'm trying to use LaTeX on my blog, but I could not figure out how. Has anyone done it before? Any feedback or related information would be greatly appreciated.

You can put a `\strut` just before `c` to enlarge the depth of your equation and if you still find the curly bracket too close, you can also define your own "strut": `<code> [...] </code>`

مشخصات پرسش ۳

پاسخ تأییدشده

Improving Sentiment Analysis in Persian text based on combination of Stacked Auto-Encoder and Transformer-BiLSTM-CNN

Sina Dami^{1*}, MohammadAli Sanagooye Moharrer²

¹ Assistant Professor of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

² MSc Graduate of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

Received: 05 November 2024, Revised: 29 January 2025, Accepted: 30 April 2025

Paper type: Research

Abstract

The expansion of the internet and the increasing amount of user-generated textual opinions on various topics have made sentiment analysis a crucial tool for understanding public sentiment towards different subjects. These insights are invaluable for businesses, policymakers, and society as a whole, but manually analyzing such a volume of data is costly and impractical. This study leverages automated and deep learning approaches by combining a Stacked Autoencoder (SAE) for feature extraction and a Transformer-BiLSTM-CNN model for sentiment classification, specifically designed for the Persian language. ParsBert, the Persian version of BERT, was used for data preprocessing. This combined approach demonstrated improved performance in key evaluation metrics such as accuracy, precision, recall, and F1 score, outperforming comparative models like Transformer-BiLSTM-CNN, SAE-LSTM, and CNN. Results on datasets including user reviews from the Taghcheh and Digikala platforms and Persian tweets affirm the effectiveness of this hybrid model.

Keywords: Sentiment Analysis, Feature Extraction, Transformer, Stacked Auto-Encoder.

* Corresponding Author's email : dami@wtiau.ac.ir

بهبود تحلیل احساسات در متن فارسی براساس ترکیبی از رمزگذار Transformer-BiLSTM-CNN و خودکار پشته‌ای

سینا دامی^{۱*}، محمدعلی ثناگوی محرر^۲

^۱ استادیار گروه مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

^۲ دانش‌آموخته ارشد مهندسی کامپیوتر، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۸/۱۵ تاریخ بازبینی: ۱۴۰۳/۱۱/۱۰ تاریخ پذیرش: ۱۴۰۴/۰۲/۱۰

نوع مقاله: پژوهشی

چکیده

با گسترش اینترنت و افزایش ثبت نظرات متنی کاربران درباره رویدادهای مختلف، تحلیل احساسات متنی اهمیت بالایی یافته است، زیرا می‌تواند احساسات مثبت، منفی یا خنثی کاربران را نسبت به موضوعات گوناگون نشان دهد و به شرکت‌ها، سیاست‌گذاران و جامعه، اطلاعات ارزشمندی ارائه دهد. اما تحلیل دستی این حجم از داده‌ها بسیار زمان‌بر و پرهزینه است؛ لذا پژوهشگران به روش‌های خودکار و یادگیری عمیق روی آورده‌اند. این پژوهش با ترکیب رمزگذار خودکار پشته‌ای (SAE) برای استخراج ویژگی‌ها و مدل ترکیبی Transformer-BiLSTM-CNN برای طبقه‌بندی، به بهبود تحلیل احساسات متنی در زبان فارسی پرداخته است. برای پیش‌پردازش داده‌ها نیز از مدل ParsBert، نسخه فارسی BERT، استفاده شد. این ترکیب در برخی معیارهای ارزیابی مانند دقت، صحت، یادآوری و امتیاز F1، نسبت به مدل‌های مشابه همچون Transformer-BiLSTM-CNN، SAE-LSTM و CNN عملکرد بهتری داشت و نتایج مطلوبی در مجموعه داده‌های نظرات کاربران طاقچه و دیجی کالا و توثیت‌های فارسی به دست آمد.

کلیدواژگان: تحلیل احساسات، استخراج ویژگی، تبدیل کننده، رمزگذار خودکار پشته‌ای.

* رایانامه نویسنده مسؤول: dami@wtiau.ac.ir

۱- مقدمه

با توسعه‌ی روزافزون شبکه‌های مجازی و تجارت الکترونیک، استفاده‌ی مردم از خدمات مبتنی بر وب افزایش پیدا کرده است. کاربران از فروشگاه‌های اینترنتی خرید می‌کنند و درباره‌ی محصولات، نظر می‌نویسند؛ این نظرات بر روی سایر خریداران نیز تاثیر می‌گذارد و به این ترتیب مردم برای خرید یک محصول، خود را محدود به نظرات خانواده و اطرافیان خود نمی‌کنند. مردم علاقه دارند درباره‌ی موضوعات مختلف صحبت کنند و احساسات خود را در مسائلی مانند سیاست بیان کنند. فضای مجازی باعث حضور اشخاص تاثیرگذار از حوزه‌های مختلف اعم از صاحبان کسب و کارها تا سیاستمداران شده که همین موجب می‌شود مردم نظرات مثبت، منفی و یا خنثی خود را درباره‌ی آن‌ها ثبت کنند؛ نظراتی که می‌تواند ناشی از عملکرد مثبت یا منفی آن‌ها باشد. تحلیل احساسات به دلیل کاربردهای گسترده‌ی خود، توجه زیادی از حوزه‌های صنعتی و دانشگاهی به خود جلب کرده است. تحلیل احساسات به طور خلاصه شامل تحلیل محاسباتی متن در پردازش زبان طبیعی^۱ (NLP) برای شناسایی، استخراج و طبقه‌بندی اطلاعات ذهنی از متن بدون ساختار است [۱].

عقیده کاوی کاربران می‌تواند کاربردهای فراوانی داشته باشد؛ به عنوان مثال فروشگاه‌های اینترنتی با تحلیل این اطلاعات می‌توانند تقاضاهای روز و آینده‌ی کاربران را پیشبینی کنند و محصولات را مطابق با آن تامین کنند، تولیدکننده‌ها و ارائه‌دهندگان خدمات، با استفاده از احساسات مثبت و منفی کاربران درباره‌ی محصولات و خدمات خود، می‌توانند نقاط ضعف و قوت خود را شناسایی کنند و کالا و خدمات ضعیف خود را بهبود ببخشند یا حذف کنند، یا تولید کالا یا ارائه خدمات محبوب خود را افزایش دهند یا از احساسات مثبت و منفی کاربران نسبت به موضوعات مختلف، برای محصولات و خدمات جدید خود ایده بگیرند. دولت‌ها می‌توانند از رضایت یا عدم رضایت مردم از موضوع خاصی مطلع شده وقوع بحران‌های امنیت ملی را پیشبینی و از آن جلوگیری کنند. اینکه بدانیم تظاهرات هنگ کنگ ۲۰۲۰، لندن [۲] و بهار عربی ۲۰۱۱ [۳] به وسیله‌ی شبکه‌های اجتماعی اینترنتی سازماندهی شد؛ ضرورت پایش، جمع‌آوری و تحلیل احساسات کاربران این شبکه‌ها را دوچندان می‌کند. از مهم‌ترین کاربردهای تحلیل احساسات همچنین می‌توان به پیش‌بینی یا تاثیرگذاری بر انتخابات و سود سهام اشاره کرد [۴].

تحلیل احساسات کاربران از متن‌های تولیدشده در فضای مجازی به یکی از ابزارهای کلیدی برای درک رفتار و ترجیحات آن‌ها تبدیل شده است. در این میان، تحلیل احساسات متنی به زبان فارسی به دلیل پیچیدگی‌های زبانی و کمبود منابع مناسب، با چالش‌های خاصی مواجه است. بهبود عملکرد مدل‌های تحلیل احساسات در این حوزه نه تنها می‌تواند به کسب‌وکارها و دولت در تصمیم‌گیری‌های استراتژیک کمک کند، بلکه به توسعه‌ی ابزارهای پردازش زبان طبیعی برای زبان‌های کم‌منبع نیز یاری می‌رساند.

هدف اصلی این پژوهش، ارائه یک مدل ترکیبی جدید برای بهبود دقت و کارایی تحلیل احساسات در متون فارسی است. با توجه به چالش‌های خاص زبان فارسی مانند پیچیدگی‌های صرفی و نحوی، و همچنین کمبود منابع پردازش زبان طبیعی در این زبان، نیاز به مدل‌های تخصصی و کارآمد احساس می‌شود. ما قصد داریم با ترکیب هوشمندانه مدل‌های یادگیری عمیق که در تحقیقات پیشین عملکرد قابل توجهی داشته‌اند، یک معماری جدید ارائه دهیم که بتواند عملکرد بهتری نسبت به مدل‌های موجود داشته باشد.

فرضیه اصلی ما در این پژوهش این است که ترکیب مدل‌های بهینه‌شده می‌تواند عملکرد تحلیل احساسات متنی را بهبود بخشد. این فرض بر این اساس شکل گرفته که هر یک از مدل‌های ParsBERT، رمزگذار خودکار پشته‌ای و Transformer-BiLSTM- شبکه عصبی کانولوشنال^۲ (CNN) در بخش‌های مختلف پردازش متن (پیش‌پردازش، استخراج ویژگی و طبقه‌بندی) نقاط قوت منحصر به فردی دارند. ParsBert به دلیل توانایی آن در پردازش متن‌های فارسی و استخراج ویژگی‌های معنایی عمیق استفاده شده است. همچنین، استفاده از رمزگذار خودکار پشته‌ای^۳ (SAE) به دلیل قابلیت آن در کاهش ابعاد داده‌ها و استخراج ویژگی‌های غیرخطی صورت گرفته است. ترکیب مدل‌های Transformer-BiLSTM-CNN نیز به این دلیل انتخاب شده است که Transformer توانایی پردازش متن‌های طولانی و وابستگی‌های بلندمدت را دارد، شبکه حافظه بلند و کوتاه مدت دو جهته^۴ (BiLSTM) برای مدل‌سازی ترتیب کلمات و ویژگی‌های متوالی مناسب است؛ و CNN نیز برای پردازش و تشخیص ویژگی‌های محلی و الگوهای موثر در تحلیل احساسات به کار می‌رود. این ترکیب به ما امکان می‌دهد تا از نقاط قوت هر مدل بهره‌برداری کرده و عملکرد کلی تحلیل احساسات را بهبود بخشیم.

نوآوری اصلی این پژوهش در ترکیب هوشمندانه سه مدل قدرتمند

³ Stacked Auto Encoder

⁴ Bidirectional Long Short-Term Memory Network

¹ Natural language processing

² Convolutional Neural Network

یادگیری عمیق است که هر کدام در حوزه خود عملکرد برجسته‌ای داشته‌اند. این ترکیب نه تنها باعث بهره‌برداری از نقاط قوت هر مدل می‌شود، بلکه با کنترل پیچیدگی محاسباتی، یک راه حل کارآمد برای تحلیل احساسات در متون فارسی ارائه می‌دهد.

ما در این پژوهش همچنین تلاش می‌کنیم تا به سوالات زیر پاسخ دهیم:

۱. چگونه با ترکیب مدل‌های یادگیری عمیق، عملکرد وظیفه تحلیل احساسات را در متن‌های فارسی بهبود دهیم؟

۲. چگونه می‌توان با بکارگیری مدل‌های بسیار عمیق باعث بهبود استخراج ویژگی‌ها در وظیفه تحلیل احساسات شد؟

در ادامه، نوآوری‌ها و دستاوردهای اصلی این تحقیق توضیح داده می‌شوند:

(۱) در این پژوهش، برای اولین بار ترکیبی از مدل‌های Transformer-BiLSTM-CNN با استفاده از SAE ارائه شده است. این ترکیب، مزایای مدل‌های مبتنی بر توجه برای پردازش و تشخیص روابط معنایی عمیق، توانایی BiLSTM در یادگیری وابستگی‌های زمانی بلندمدت، و قابلیت CNN در پردازش و تشخیص ویژگی‌های محلی را با یکدیگر ادغام کرده است. همچنین، استفاده از SAE به بهبود بازنمایی داده‌ها و کاهش ابعاد ویژگی‌ها کمک کرده است.

(۲) این پژوهش از ParsBERT به عنوان ابزار اصلی پیش‌پردازش و ایجاد بردارهای معنایی استفاده کرده است. این مدل، به دلیل تمرکز بر ویژگی‌های زبانی و ساختاری خاص زبان فارسی، امکان تحلیل دقیق‌تر احساسات را فراهم کرده است. همچنین، تکنیک‌های پیش‌پردازش خاصی نظیر نرمال‌سازی و حذف نویز به منظور بهبود کیفیت داده‌ها اعمال شده است.

(۳) یکی از جنبه‌های نوآورانه این پژوهش، ارزیابی مدل در شرایط داده‌های کم‌منبع است. این پژوهش نشان داده است که ترکیب مدل‌های پیشنهادی قادر است با داده‌های محدود نیز عملکرد قابل قبولی داشته باشد و این موضوع به‌ویژه در تحلیل متون زبان فارسی اهمیت بالایی دارد.

(۴) توسعه معماری برای کاربردهای چندزبانه: اگرچه تمرکز اصلی این پژوهش بر تحلیل متون فارسی است، ساختار پیشنهادی با تنظیمات مناسب می‌تواند به راحتی برای

زبان‌های دیگر نیز به کار رود. این ویژگی، پتانسیل گسترش روش در سایر حوزه‌ها و زبان‌ها را فراهم می‌کند.

(۵) کاهش نیاز به منابع محاسباتی: یکی از دستاوردهای کلیدی این پژوهش، استفاده از SAE برای کاهش ابعاد داده و بهبود بازنمایی ویژگی‌ها است که به طور مستقیم نیاز به منابع محاسباتی را کاهش داده و سرعت پردازش را افزایش داده است. این موضوع، امکان استفاده از مدل پیشنهادی در محیط‌های محدود به منابع را فراهم می‌کند.

ادامه‌ی ساختار این مقاله به شرح زیر است: در بخش دوم، مفاهیم اولیه و مبانی نظری مرتبط با تحلیل احساسات و روش‌های یادگیری عمیق مورد بررسی قرار می‌گیرد. در بخش سوم، مروری بر پژوهش‌های مرتبط انجام می‌شود. در بخش چهارم، روش تحقیق و مدل پیشنهادی به‌طور مفصل شرح داده می‌شود. در بخش پنجم، ارزیابی مدل پیشنهادی با استفاده از معیارهای استاندارد و مجموعه داده‌های مناسب ارائه می‌شود و در نهایت، در بخش ششم نتیجه‌گیری و پیشنهادات برای پژوهش‌های آینده ارائه خواهد شد.

۲- مفاهیم اولیه

در این قسمت مفاهیم اولیه شامل تعریف تحلیل احساسات متنی و یادگیری عمیق ارائه شده است و در ادامه شبکه‌های عصبی مورد استفاده در این مقاله معرفی می‌شود.

۲-۱- تحلیل احساسات متنی

محبوبیت اینترنت و سهولت دسترسی آن برای همه‌ی مردم، محتوای فراوانی را در فضای آنلاین تولید کرده است. مردم احساسات و نظرات خود را در شبکه‌های اجتماعی از طریق متن، تصویر و ویدئو بیان می‌کنند. همچنین نظرات خود را در مورد محصولات و خدمات خاص از طریق نظرات تعاملی در وب سایت‌های تجاری و بستر شبکه‌های اجتماعی بروز می‌دهند. محتوای متنی تولید شده در این بستر، بینش ارزشمندی در مورد نظر و احساسات نظردهنده در مورد موضوع مورد بحث، به دست می‌دهد. این نظرات به وسیله‌ی تکنیک‌های پردازش زبان طبیعی بهتر درک می‌شود و مورد استفاده قرار می‌گیرند. احساس معادل نشان دادن نظر و ارزیابی و نگرش است [۵] و تحلیل احساسات، فرآیند شناسایی، استخراج و طبقه‌بندی اطلاعاتی با مفاهیم خاص از محتوای متنی بدون ساختار است که به آن عقیده‌کاوی نیز گفته می‌شود و لحن عاطفی یا احساسات منتقل شده در داده‌های متنی را تعریف می‌کند [۶].

۲-۲-۲-۲ CNN

CNN یکی از مهمترین معماری‌های یادگیری عمیق است و یک مدل شبکه عصبی پیش‌خور^۶ چند لایه است و توانایی محاسبات موازی دارد [۷]. شبکه‌هایی که همه گره‌ها را می‌توان در لایه‌های متوالی سازمان‌دهی کرد، به طوری که هر گره ورودی را فقط از گره لایه‌های قبلی دریافت کند، شبکه عصبی پیش‌خور نام دارند [۹]. CNN، ویژگی‌ها را بر اساس اصل فضایی^۳ استخراج می‌کند. شبکه با این اصل می‌تواند الگوهای فضایی را در داده‌های ورودی تشخیص دهد و بهتر یاد بگیرد [۸]. CNN از سه لایه تشکیل شده است: لایه کانولوشن^۴، لایه ادغام^۵ و لایه کاملاً متصل^۶.

۲-۲-۲-۳ تبدیل کننده‌ها

این مدل شامل بلوک‌های رمزگذار و رمزگشا با یک تابع فعال‌سازی سافت مکس^۷ برای نرمال سازی احتمالات خروجی شبکه عصبی است. ورودی مدل یک داده متوالی است. بلوک‌های رمزگذار متشکل از توجه چند سر^۸ و یک شبکه پیش‌خور است. لایه‌های توجه چندسر، بردارهای توجه را برای هر ورودی محاسبه می‌کنند. رمزگشا دارای رمزگذار موقعیتی و لایه‌های توجه چندسر پوشانده شده است که مشابه بلوک رمزگذار عمل می‌کنند. مدل تبدیل کننده، که در ابتدا برای ترجمه ماشینی طراحی شده بود، برای مدل‌سازی زبان استفاده می‌شود و آن را برای سایر وظایف NLP مانند طبقه‌بندی متن، خلاصه‌سازی اسناد و پاسخ‌گویی به سؤال، قابل استفاده می‌کند [۱۰].

۲-۲-۴ نمایش رمزگذار دو جهته از تبدیل کننده‌ها^۹

(BERT)

BERT از رمزگذارهای موجود در یک تبدیل‌کننده به عنوان زیرساختی برای مدل‌های پیش‌آموزشی استفاده می‌کند و برای وظایف NLP مانند تحلیل احساسات، پاسخ به سؤالات، خلاصه‌سازی متن و... کاربرد دارد. مزایای BERT شامل توانایی آن در مدیریت استخراج اطلاعات متنی به دلیل قابلیت دو جهته آن است. سریع‌تر تمرین می‌کند و در طیف گسترده‌ای از برنامه‌های مدل‌سازی زبان استفاده شده است. با این حال، معایبی نیز دارد از جمله اینکه به طبقه‌بندی‌های تک زبانه محدود می‌شود، طول جملات ورودی نیز آن را محدود می‌کند، مشکل استنتاج عملی دارد [۱۰].

هدف از طبقه‌بندی احساسات، استخراج احساسات و نظرات از متن‌ها است. وظیفه‌ی تحلیل احساسات یک مسئله طبقه‌بندی متن محسوب می‌شود؛ زیرا متن را به دو دسته‌ی احساس مثبت و احساس منفی دسته‌بندی می‌کند. تشخیص طعنه، ذهنیت و سازماندهی متن از جمله مواردی هستند که این وظیفه را دشوار می‌کنند [۷].

۲-۲-۲-۲ یادگیری عمیق

در سال‌های اخیر الگوریتم‌های یادگیری عمیق به نتایج قابل توجهی در حوزه پردازش زبان طبیعی دست یافتند. اصطلاح "یادگیری عمیق" به شبکه‌های عصبی با لایه‌های متعدد پرسپترون الهم گرفته از مغز ما اشاره دارد و داده‌ها را در لایه‌های متعدد و متوالی نشان می‌دهند؛ تعداد لایه‌ها معیار مهمی برای نمایش عمق شبکه است. با این معماری می‌توان مدل‌های پیچیده‌تری را بر روی مجموعه داده‌های بسیار بزرگ‌تری آموزش داد و نتایج پیشرفته‌تری را در بسیاری از حوزه‌های کاربردی، از بینایی رایانه و تشخیص گفتار گرفته تا NLP، تولید کرد [۷]. همچنین این توانایی را دارند که ویژگی‌های نحوی جملات را به طور خودکار بدون تکنیک‌های استخراج ویژگی اضافی ذخیره کنند؛ بدون تکنیک‌هایی که منابع و زمان بیشتری را مصرف می‌کنند. به همین دلیل است که مدل‌های یادگیری عمیق توجه محققان پردازش زبان طبیعی را برای طبقه‌بندی احساسات به خود جلب کرده است [۱]. مجموعه داده‌های بزرگ در آموزش، پیشرفت در منابع سخت‌افزاری برای پردازش داده‌های بزرگ و بهبود در مدل‌های یادگیری عمیق باعث افزایش اثربخشی مدل‌های یادگیری عمیق می‌شود [۸].

۲-۲-۱-۲ BiLSTM

شبکه عصبی BiLSTM یکی از الگوریتم‌های شبکه عصبی بازگشتی، برای بهبود LSTM است و کار مدل سازی متوالی^۱ را بهتر از LSTM حل می‌کند. اطلاعات در LSTM، از عقب به جلو حرکت می‌کنند؛ اما در BiLSTM، اطلاعات در هر دو جهت حرکت می‌کنند؛ هم از عقب به جلو و هم از جلو به عقب، با استفاده از دو حالت پنهان در حرکت هستند. با این کار زمینه را بهتر یاد می‌گیرد و داده‌های ورودی اطلاعات گذشته و آینده حفظ می‌شود [۱].

^۶ fully connected

^۷ Softmax

^۸ multi-head attention

^۹ Bidirectional encoder representations from Transformers

^۱ task of sequential modeling

^۲ feed-forward

^۳ spatial principle

^۴ convolution

^۵ pooling

۲-۲-۵- رمزگذارهای خودکار

رمزگذار خودکار یک بلوک ساختمانی اساسی است که می‌تواند به صورت سلسله مراتبی برای ایجاد مدل‌های عمیق استفاده شود. آن‌ها ویژگی‌های سطح بالا را سازماندهی، فشرده و استخراج می‌کنند و امکان یادگیری بدون نظارت و استخراج ویژگی‌های غیرخطی را فراهم می‌کنند. رمزگذارهای خودکار دارای یک رمزگذار و یک رمزگشا هستند. رمزگذارهای خودکار شبکه‌های عصبی پیشخور هستند که به اطلاعات اجازه می‌دهند در یک جهت جریان پیدا کنند [۱۱].

۲-۲-۶- SAE

رمزگذار خودکار سنتی معمولاً از یک رمزگذار تک لایه استفاده می‌کند که استخراج ویژگی‌های عمیق را به چالش می‌کشد. برای تقویت استخراج ویژگی، یک استراتژی موثر، تعمیق ساختار شبکه عصبی است. با بکارگیری یک رویکرد یادگیری لایه‌ای، می‌توان چندین رمزگذار خودکار پایه را در کنار هم قرار داد تا یک SAE را تشکیل دهند که امکان استخراج ویژگی‌های داده پیچیده را فراهم می‌کند [۱۱]. SAE از دو رمزگذار و رمزگشا استفاده می‌شود که ویژگی‌های واقعی را به طور موثر کاهش می‌دهد؛ به طوری که طبقه‌بندی و انجام هر گونه عملیات بر روی داده‌های متنی آسان می‌شود [۱۲].

۳- مرور ادبیات و سوابق مربوطه

فضلی واحد و همکاران [۱۲]، مدلی ترکیبی و نوآورانه برای تحلیل احساسات ارائه کردند که از ترکیب دو روش قدرتمند SAE و LSTM بهره می‌برد. هدف اصلی این پژوهش، غلبه بر مشکلات مرتبط با استخراج ناکافی ویژگی‌های اطلاعاتی توسط LSTM و محدودیت‌های لایه سافت مکس در SAE برای طبقه‌بندی دقیق‌تر ویژگی‌ها بوده است. مدل پیشنهادی آن‌ها شامل استفاده از SAE با دو لایه رمزگذار و دو لایه رمزگشا است که برای استخراج ویژگی‌های اطلاعاتی و کاهش ابعاد داده‌ها طراحی شده است. پس از این مرحله، LSTM به کار گرفته می‌شود که به دلیل توانایی آن در یادگیری وابستگی‌های بلندمدت در متن، فرآیند طبقه‌بندی احساسات را براساس ویژگی‌های استخراج شده انجام می‌دهد. پیش‌پردازش داده‌ها در این مدل شامل حذف علائم نگارشی، کلمات توقف و توکن‌سازی متن است. نتایج به‌دست‌آمده نشان داد که مدل ترکیبی پیشنهادی دقت^۱ ۸۷ درصدی داشته و نسبت به مدل‌های سنتی

مانند LSTM با دقت ۸۲٫۲ درصد و CNN با دقت ۴۵٫۵ درصد عملکرد بهتری از خود نشان داده است. این برتری نه تنها در بهبود دقت طبقه‌بندی احساسات مشهود بود، بلکه در کاهش زمان اجرای مدل نیز تأثیرگذار بود. علاوه بر این، مدل در شرایط مختلفی از تقسیم داده‌های آموزشی و تستی نیز عملکرد مطلوبی داشت که نشان‌دهنده پایداری آن است. با این حال، محدودیت‌هایی در این پژوهش وجود داشت. به عنوان مثال، مدل تنها برای طبقه‌بندی دو کلاسه (مثبت و منفی) طراحی شده و قابلیت تحلیل احساسات چندکلاسه را ندارد. همچنین استفاده از مکانیزم‌های توجه برای بهبود تحلیل احساسات در آن بررسی نشده است.

مریگانک شوکلا و آخیل کومار [۶]، در پژوهشی جامع به مقایسه و ارزیابی مدل‌های مختلف شبکه‌های عصبی عمیق برای تحلیل احساسات پرداختند. هدف اصلی این پژوهش، شناسایی بهترین ترکیب از مدل‌های ترکیبی نظیر CNN، BiLSTM و Transformer همراه با انواع تعبیه‌های کلمات مانند Word2Vec، GloVe و FastText برای دستیابی به بالاترین دقت در تحلیل احساسات بود. در این مطالعه، هر یک از مدل‌ها نقش خاصی ایفا کردند. شبکه‌های CNN برای استخراج ویژگی‌های محلی از متن، BiLSTM برای یادگیری وابستگی‌های بلندمدت و اطلاعات دنباله‌ای، و Transformer برای بهره‌گیری از مکانیزم توجه و بهبود درک معنایی کلمات در متن به کار گرفته شدند. نتایج این پژوهش نشان داد که مدل Transformer-BiLSTM-CNN در ترکیب با تعبیه Word2Vec بهترین عملکرد را ارائه داده و به دقت ۸۹٫۰۴٪ دست یافته است. این برتری به ویژه زمانی که از ترکیب چندین تعبیه کلمات به عنوان کانال ورودی استفاده شد، آشکارتر بود. همچنین، افزودن لایه‌های Transformer به مدل‌های CNN و BiLSTM دقت را حدود ۲ تا ۳ درصد افزایش داد. با وجود این موفقیت‌ها، پژوهش با محدودیت‌هایی نیز مواجه بود. برای نمونه، مدل‌های پیشنهادی در مقایسه با مدل‌های پیش‌آموزش‌دیده‌ای چون BERT و ELMo دقت کمتری داشتند و آموزش مدل‌های ترکیبی با لایه‌های Transformer نیاز به منابع محاسباتی بیشتری داشت. علاوه بر این، استفاده از یک مجموعه داده محدود SST-2 می‌توانست تعمیم‌پذیری نتایج را کاهش دهد. پژوهش دیگری که به بررسی جامع مدل‌های تحلیل احساسات پرداخته، بر نقش ساختار مدل‌ها و نوع ورودی داده‌ها در عملکرد این مدل‌ها تمرکز داشته است. در این مطالعه، هشت مدل مختلف شامل نسخه‌های ساده و عمیق CNN و مدل‌های شبکه عصبی بازگشتی^۲ (RNN) نظیر LSTM و

² recurrent neural network

¹ Accuracy

بیش‌برازش^۷، از تکنیک اعتبار سنجی متقاطع^۸ k-fold بهره بردند. نتایج نشان داد که مدل پیشنهادی توانست به دقت ۹۵٫۱۱٪ در وظیفه E2E-ABSA دست یابد و به ترتیب دقت‌های ۹۷٫۷۸٪ و ۹۸٫۳۴٪ را در وظایف ATE و ASC کسب کند. این دستاورد، بهبود قابل توجهی نسبت به مدل‌های پیشین داشت که این دو وظیفه را جداگانه انجام می‌دادند. با این حال، این پژوهش با محدودیت‌هایی مواجه بود. نخست، محدودیت داده‌های موجود برای زبان عربی عملکرد مدل را تحت تأثیر قرار داد. دوم، مدل‌های انتها به انتها در تحلیل جملات پیچیده و طولانی کارایی کمتری داشتند. همچنین، آموزش مدل‌های پیش‌آمورخته‌ای چون AraBERT نیاز به منابع محاسباتی بالایی داشت. از دیگر محدودیت‌های تحقیقاتی قابل توجه می‌توان به عدم توسعه مدل‌هایی اشاره کرد که بتوانند چندین زیروظیفه ABSA را به‌طور همزمان انجام دهند و در داده‌های کم‌منبع نیز عملکرد مناسبی داشته باشند.

محمد الجبرین و همکاران [۱۴]، در پژوهشی به تحلیل احساسات کاربران در شبکه‌های اجتماعی، به‌ویژه توئیتر، پرداختند. هدف اصلی این تحقیق طبقه‌بندی خودکار احساسات کاربران نسبت به فناوری ChatGPT به سه دسته مثبت، منفی و خنثی بود. این مطالعه با ارائه یک مدل ترکیبی به نام MFOHDL-SA، از الگوریتم بهینه‌سازی پروانه شعله^۹ (MFO) و یادگیری عمیق ترکیبی^{۱۰} بهره گرفت تا دقت و کارایی تحلیل احساسات را بهبود بخشد. برای دستیابی به این هدف، یک فرآیند جامع پیش‌پردازش داده‌ها طراحی شد که شامل حذف ریتوییت‌ها، URL‌ها، علائم نگارشی، تبدیل ایموجی‌ها به کلمات، توکن‌سازی، نرمال‌سازی، حذف کلمات توقف و انجام Stemming و Lemmatization بود. سپس، از مدل TF-IDF برای استخراج ویژگی‌ها و بردارسازی داده‌ها استفاده شد. مدل ترکیبی CNN-LSTM برای طبقه‌بندی احساسات به کار گرفته شد و الگوریتم MFO برای تنظیم هایپرپارامترهای این مدل به منظور بهینه‌سازی عملکرد آن استفاده گردید. نتایج این پژوهش نشان داد که مدل MFOHDL-SA به دقت کلی ۹۵٫۰۹٪ در طبقه‌بندی احساسات دست یافت. در مرحله تست، دقت مدل برای کلاس‌های مثبت، منفی و خنثی به ترتیب ۹۶٫۸۵٪، ۹۴٫۶۷٪ و ۹۳٫۷۳٪ بود. این عملکرد به‌طور قابل توجهی بهتر از مدل‌های پایه‌ای مانند جنگل

واحد بازگشتی دروازه‌دار^۱ (GRU) با ورودی‌های سطح کلمه و کاراکتر ارزیابی شده‌اند. نتایج نشان داد که مدل‌های RNN با ورودی‌های سطح کلمه عملکرد بهتری نسبت به CNN داشتند، در حالی که CNN با ورودی سطح کاراکتر در برخی موارد، به ویژه در ساختارهای عمیق، نتایج مطلوب‌تری ارائه دادند. این پژوهش نیز محدودیت‌هایی مانند عدم استفاده از بردارهای پیش‌آموزش‌دیده و بررسی ترکیب CNN و RNN را داشت.

سکرین تام و همکاران [۱۱]، در پژوهش خود مدل ترکیبی نوینی به نام ConvBiLSTM را برای طبقه‌بندی احساسات معرفی کرده‌اند که از ادغام CNN و BiLSTM بهره می‌برد. هدف اصلی این تحقیق، بهبود دقت و عملکرد در تحلیل احساسات متون، به‌ویژه در تحلیل توئیتهای، بوده است. این مدل با استفاده از توانایی CNN در استخراج ویژگی‌های محلی و قابلیت BiLSTM در یادگیری وابستگی‌های بلند مدت متن، تلاش کرده است تا محدودیت‌های روش‌های پیشین را کاهش دهد. نتایج به‌دست آمده نشان داد که مدل ConvBiLSTM توانسته است در مقایسه با مدل‌های پایه نظیر CNN و BiLSTM، عملکرد بهتری ارائه دهد. این مدل در مجموعه داده توئیتهای به دقت ۹۴٫۱۳٪ و در مجموعه داده SST-2 به دقت ۹۱٫۱۳٪ دست یافت، در حالی که مدل CNN به ترتیب دقت ۹۱٫۸۹٪ و ۸۹٫۱۸٪ و مدل BiLSTM دقت ۹۱٫۵۲٪ و ۸۹٫۴۲٪ را به ثبت رسانده بودند. با وجود موفقیت‌های این مدل، پژوهش با محدودیت‌هایی نیز مواجه بود. از جمله این محدودیت‌ها می‌توان به نیاز به منابع محاسباتی بالا برای داده‌های حجیم و عدم استفاده از مکانیزم‌های توجه اشاره کرد.

شفیق و همکاران [۱۳]، در مطالعه‌ای به تحلیل احساسات مبتنی بر جنبه^۲ (ABSA) پرداختند که هدف اصلی آن شناسایی و تحلیل احساسات مرتبط با جنبه‌های خاص متن در زبان عربی بود. این تحقیق به‌طور ویژه به بررسی این سوال پرداخت که چگونه می‌توان با ترکیب روش‌های انتها به انتها^۳ (E2E)، عملکرد مدل‌های ABSA را بهبود بخشید. برای دستیابی به این هدف، آن‌ها از ترکیب AraBERT، یک مدل پیش‌آمورخته برای زبان عربی، با فیلدهای تصادفی شرطی^۴ (CRF) استفاده کردند. این رویکرد با ادغام وظایف استخراج اصطلاحات جنبه^۵ (ATE) و طبقه‌بندی احساسات مربوطه^۶ (ASC) در یک مدل واحد، توانست ارتباط میان این دو زیروظیفه را تقویت کند. همچنین، برای ارزیابی و جلوگیری از

⁶ Aspect Sentiment Classification

⁷ Overfitting

⁸ Cross validation

⁹ Moth Flame Optimization

¹⁰ Hybrid Deep Learning

¹ Gated Recurrent Unit

² Aspect-Based Sentiment Analysis

³ End-to-End

⁴ Conditional Random Fields

⁵ Aspect Term Extraction

و طبقه‌بندی احساسات مثبت، منفی و خنثی پرداخته‌اند. در این پژوهش، تمرکز اصلی بر استفاده از مدل‌های ترکیبی عمیق بوده است که با ترکیب ویژگی‌های مدل‌های مبتنی بر Transformer مانند RoBERTa و مدل‌های دنباله‌ای نظیر LSTM، BiLSTM و GRU بهبود دقت و عملکرد تحلیل احساسات را هدف قرار داده‌اند. در این مطالعه، مدل ترکیبی عمیقی معرفی شده است که شامل سه ساختار مجزا یعنی RoBERTa-LSTM، RoBERTa-BiLSTM و RoBERTa-GRU است. برای ترکیب نتایج این مدل‌های ترکیبی، دو روش میانگین‌گیری و رأی اکثریت به کار گرفته شد. همچنین، برای مقابله با مشکل عدم تعادل داده‌ها، از روش GloVe برای افزایش داده‌ها و ایجاد نمونه‌های بیشتر برای کلاس‌های اقلیت استفاده شده است. نتایج نشان داده که مدل پیشنهادی با استفاده از روش رأی اکثریت توانسته است دقتی معادل ۹۴٫۹ درصد در مجموعه داده IMDB، ۹۱٫۷۷ درصد در مجموعه داده Twitter US و ۸۹٫۸۱ درصد در مجموعه داده Airline Sentiment 140 به دست آورد. در این میان، استفاده از RoBERTa به عنوان لایه ابتدایی، عملکردی برتر نسبت به مدل‌های مشابه مانند BERT و ALBERT نشان داده است. با این وجود، این رویکرد با چالش‌هایی نیز روبروست. نیازمندی بالای منابع محاسباتی به دلیل استفاده از مدل‌های پیچیده مانند RoBERTa و مدل‌های دنباله‌ای، یکی از مهم‌ترین محدودیت‌های این روش است. علاوه بر این، افزایش داده‌ها با استفاده از GloVe گاهی ممکن است منجر به تولید نمونه‌های مصنوعی با کیفیت پایین شود.

کیان لانگ تن و همکاران [۱۷] همچنین پژوهشی قدیمی‌تر، با هدف بهبود دقت تحلیل احساسات ارائه کرده‌اند که در آن مدلی ترکیبی از قابلیت‌های مدل RoBERTa و LSTM بهره می‌گیرد. این مدل تلاش می‌کند تا با حل چالش‌هایی مانند وابستگی‌های بلندمدت در متن و تنوع واژگانی، عملکردی قابل توجه در تحلیل احساسات به نمایش بگذارد. در این راستا، از روش‌های پیشرفته‌ای همچون جاسازی‌های معنایی قدرتمند، تکنیک‌های افزایش داده برای مقابله با عدم توازن داده‌ها و پیش‌پردازش دقیق متن استفاده شده است. در این روش، مدل RoBERTa به عنوان ابزاری برای تبدیل متن به بازنمایی‌های عددی معنادار عمل می‌کند؛ در حالی که LSTM با قابلیت پردازش وابستگی‌های بلندمدت، ویژگی‌های زمانی متن را استخراج و تحلیل می‌کند. این بازنمایی‌های معنایی و زمانی در یک ساختار یکپارچه ادغام شده و با استفاده از لایه‌های تکمیلی نظیر Flatten و Dense به طبقه‌بندی نهایی منجر می‌شوند.

تصادفی، درخت تصمیم، ماشین بردار پشتیبانی^۱ (SVM)، CNN، XGBoost و ماشین یادگیری افراطی^۲ (ELM) بود. با وجود این موفقیت‌ها، مطالعه با محدودیت‌هایی نیز مواجه بود. از جمله، حجم داده‌ها محدود به ۶۰،۰۰۰ نمونه بود که ممکن است برای آموزش مدل‌های پیچیده کافی نباشد. همچنین، مدل‌های ترکیبی مانند CNN-LSTM منابع محاسباتی زیادی مصرف می‌کنند و زمان آموزش طولانی‌تری دارند. علاوه بر این، الگوریتم MFO در مواجهه با داده‌های بسیار بزرگ یا پیچیده ممکن است در تنظیم بهینه‌های هایپرپارامتری، کند عمل کند.

ایزابل کاروالو و همکاران [۱۵]، در پژوهشی به تحلیل احساسات در گفتگوها پرداختند، با تمرکز بر تعاملات انسان-ماشین و انسان-انسان. هدف اصلی این تحقیق بررسی تأثیر بافت بر بهبود عملکرد مدل‌های تحلیل احساسات بود. بافت در این مطالعه شامل جملات قبلی و نقش گوینده (مانند مشتری یا نماینده خدمات) بود. این پژوهش به سؤالاتی درباره تأثیر تعداد جملات قبلی، نقش گوینده، و انتخاب مدل مناسب برای تحلیل احساسات در گفتگوها پاسخ داد. برای دستیابی به این هدف، از ترکیبی از روش‌های سنتی مانند رگرسیون لجستیک، SVM، جنگل تصادفی و CRF، و مدل‌های پیشرفته یادگیری عمیق از جمله BERT، رویکرد BERT بهینه شده قوی^۳ (RoBERTa) و BERT-CRF استفاده شد. همچنین، مدل‌های یادگیری کم فرصت^۴ (FSL) مانند GPT-3 و OPT مورد بررسی قرار گرفتند. نتایج این پژوهش نشان داد که مدل‌های BERTimbu و RoBERTa بهترین عملکرد را در تحلیل احساسات با در نظر گرفتن بافت داشتند. در گفتگوهای انسان-ماشین، در نظر گرفتن بافت هر دو گوینده (مشتری و نماینده خدمات) بهبود عملکرد مدل را به همراه داشت. در حالی که در گفتگوهای انسان-انسان، در نظر گرفتن جملات مشتری کافی بود. روش‌های FSL نیز نتایج قابل قبولی ارائه دادند، اما به اندازه مدل‌های مبتنی بر BERT مؤثر نبودند. این پژوهش با محدودیت‌هایی مواجه بود. داده‌ها محدود به زبان پرتغالی بودند و نتایج ممکن است برای زبان‌های دیگر متفاوت باشد. مدل‌های FSL به دلیل هزینه‌های محاسباتی بالا و عملکرد ضعیف‌تر نسبت به BERT محدودیت داشتند. همچنین، برخی مدل‌ها مانند RoBERTa در پردازش جملات طولانی به مشکل برخوردند.

کیان لانگ تن و همکاران [۱۶]، در یکی از پژوهش‌های خود به بررسی و توسعه رویکردی جدید برای تحلیل احساسات و شناسایی

³ Robustly Optimized BERT Approach

⁴ Few-Shot Learning

¹ Support Vector Machine

² Extreme Learning Machine

مدل‌های مبتنی بر یادگیری عمیق در طبقه‌بندی احساسات ارائه داده‌اند. در این مطالعه، عملکرد مدل‌های مختلف CNN و RNN با تأکید بر دو نوع ورودی سطح کلمه و سطح کاراکتر مورد بررسی قرار گرفته است. این پژوهش شامل آزمایش مدل‌ها بر روی ۱۳ مجموعه داده متنوع بوده و تلاش کرده است نقش ویژگی‌های مجموعه داده، ساختار مدل، و نوع ورودی را در کارایی طبقه‌بندی احساسات روشن کند. پژوهشگران پرسش‌هایی کلیدی را مطرح کرده‌اند، از جمله اینکه تأثیر ویژگی‌های مجموعه داده بر تحلیل احساسات چگونه است؟ ساختارهای CNN و RNN چه نقشی در بهبود طبقه‌بندی احساسات دارند؟ و چگونه نوع ورودی می‌تواند عملکرد مدل‌ها را ارتقا بخشد؟ به منظور پاسخ به این پرسش‌ها، هشت مدل مختلف آزمایش شده‌اند که شامل CNN ساده با یک لایه کانولوشنال، CNN نه لایه، و CNN بسیار عمیق با ۲۹ لایه هستند. همچنین مدل‌های RNN شامل RNN پایه‌ای، LSTM، GRU، و نسخه‌های دوطرفه LSTM و GRU که قادر به پردازش اطلاعات از هر دو جهت هستند، مورد بررسی قرار گرفته‌اند. تمامی این مدل‌ها با ورودی‌های سطح کلمه و کاراکتر ارزیابی شده‌اند. نتایج این پژوهش نشان داده است که افزایش حجم داده‌های آموزشی به بهبود قابل توجه عملکرد مدل‌ها منجر می‌شود. مدل‌های RNN، به ویژه با ورودی سطح کلمه، در اکثر موارد عملکرد بهتری نسبت به CNN نشان داده‌اند. در میان این مدل‌ها، نسخه‌های دوطرفه LSTM و GRU بهترین نتایج را ارائه داده‌اند. با این حال، CNN با ورودی سطح کاراکتر در برخی موارد، به ویژه در ساختارهای عمیق‌تر، عملکرد بهتری داشته است. این پژوهش دارای نقاط قوت متعددی است، از جمله بررسی جامع مدل‌های CNN و RNN، استفاده از ۱۳ مجموعه داده متنوع برای تضمین قابلیت تعمیم‌پذیری، و ارائه بینش‌هایی عملی برای انتخاب مدل‌های مناسب تحلیل احساسات. با این وجود، محدودیت‌هایی نیز وجود دارد. برای مثال، این مطالعه تنها از بردارهای کلمه و کاراکتری که از ابتدا آموزش داده شده‌اند استفاده کرده و بردارهای از پیش آموزش‌دیده مانند BERT را در نظر نگرفته است. همچنین، ترکیب مدل‌های CNN و RNN و تأثیر ویژگی‌های زبانی خاص نظیر ساختارهای نحوی و معنایی بر عملکرد مدل‌ها بررسی نشده است.

نینگ ژینگ و همکاران [۱۹]، در پژوهشی جامع به توسعه و ارزیابی یک مدل یادگیری چندوظیفه‌ای برای تحلیل احساسات در نظرات کاربران درباره کالاهای مختلف پرداختند. این پژوهش با هدف ایجاد مدلی که بتواند ویژگی‌های محلی و جهانی متن را به طور همزمان

فرآیند آموزش مدل نیز با بهره‌گیری از بهینه‌ساز برآورد لحظه تطبیقی^۱ (Adam) و تابع زیان متقاطع طبقه‌ای^۲ بهینه‌سازی شده است. نتایج به دست آمده نشان می‌دهند که مدل ترکیبی RoBERTa-LSTM در مقایسه با روش‌های سنتی مانند نایبو بیز، SVM و LSTM عملکرد بهتری ارائه داده و توانسته است در مجموعه داده‌های مختلف به دقت بالایی دست یابد. تکنیک‌های افزایش داده نیز نقش کلیدی در بهبود دقت مدل به ویژه در مواجهه با داده‌های نامتوازن ایفا کرده‌اند و بهبود قابل توجهی در معیارهایی همچون امتیاز F1 ایجاد کرده‌اند. با وجود این دستاوردها، مدل پیشنهادی با محدودیت‌هایی نیز روبه‌رو است. از جمله این محدودیت‌ها می‌توان به نیاز به منابع محاسباتی بالا و زمان طولانی‌تر برای آموزش به دلیل پیچیدگی ساختار مدل اشاره کرد.

مهمت و ایلهان [۸]، مهمت و ایلهان در پژوهش خود به طراحی یک مدل ترکیبی نوآورانه برای طبقه‌بندی احساسات پرداخته‌اند که از ترکیب روش‌های مختلف یادگیری عمیق و تکنیک‌های تعبیه کلمات بهره می‌برد. هدف آن‌ها بهبود دقت تحلیل احساسات، به ویژه در بررسی توییت‌های ترکیبی، بوده است. مدل پیشنهادی آن‌ها از روش‌های متنوع تعبیه کلمات، از جمله Word2Vec، FastText و LSTM، BiLSTM، و GRU استفاده کرده است. نوآوری تعبیه در سطح کاراکتر، به همراه مدل‌های یادگیری عمیق نظیر CNN، LSTM، BiLSTM و GRU استفاده کرده است. نوآوری کلیدی در این پژوهش، ترکیب موازی CNN و BiLSTM با بهره‌گیری از تعبیه در سطح کاراکتر و FastText است که خروجی‌های این دو بخش پس از ترکیب، به یک لایه سافت مکس برای طبقه‌بندی نهایی منتقل می‌شوند. در این پژوهش، پیش‌پردازش داده‌ها با دقت بالایی انجام شده است و شامل مراحل نظیر تبدیل حروف به حروف کوچک، حذف علائم نگارشی و اعداد، تصحیح اشتباهات املائی با ابزار Zemberek، و جایگزینی لینک‌ها و نام‌های کاربری با برچسب‌های خاص بوده است. نتایج به دست آمده نشان داده است که مدل ترکیبی پیشنهادی، با دقت ۸۲٫۱۴٪ عملکرد بهتری نسبت به سایر مدل‌های پایه ارائه کرده است. برای مثال، مدل CNN با تعبیه در سطح کاراکتر دقت ۷۵٫۶۷٪ و مدل BiLSTM با FastText دقت ۸۰٫۴۴٪ داشته‌اند. با این حال، پژوهش آن‌ها با محدودیت‌هایی نظیر کمبود داده، دشواری در مدیریت اصطلاحات خاص و طعنه، و اهمیت یکسان برای تمام کلمات روبه‌رو بوده است.

سنونگ وان سو و همکاران [۱۸] پژوهشی جامع با هدف مقایسه

² Categorical Crossentropy

¹ Adaptive Moment Estimation

پیشنهادی آن‌ها توانست از طریق ترکیب CNN و یادگیری گسترده، ویژگی‌های محلی و الگوهای معنایی عمیقی از متن استخراج کند. بهره‌گیری از BERT به‌عنوان ابزار بازنمایی معنایی عمیق، قدرت مدل را در درک متن‌های پیچیده افزایش داد. در همین راستا، MMD نیز با کاهش شکاف دامنه‌ای و انتقال دانش میان دامنه‌ها، توانایی مدل را در انطباق با داده‌های دامنه هدف بهبود بخشید. در نهایت، Co-Training امکان بهره‌برداری بهتر از داده‌های محدود دامنه هدف را فراهم آورد و به بهبود دقت مدل کمک کرد. با این وجود، این پژوهش نیز با محدودیت‌هایی همراه بوده است. نیاز به منابع محاسباتی بالا و کمبود داده‌های برچسب‌گذاری‌شده در دامنه هدف از چالش‌های اصلی مدل پیشنهادی هستند. علاوه بر این، پیچیدگی‌های زبانی و محدودیت در پردازش متن‌های طولانی و پیچیده، گاهی منجر به کاهش عملکرد مدل شده است.

محمدرضا فیضی درخشی و همکاران [۲۱] پژوهشی با هدف توسعه مدلی نوآورانه برای تحلیل احساسات چندوجهی انجام داده‌اند که تلاش دارد با بهره‌گیری هم‌زمان از ویژگی‌های متنی و تصویری، دقت در طبقه‌بندی احساسات را بهبود بخشد. روش پیشنهادی آنان بر پایه شبکه‌های عمیق توجه‌محور طراحی شده است تا تعامل مؤثر میان این دو نوع ویژگی را تقویت کرده و بازنمایی معنایی عمیق‌تری از داده‌ها ارائه دهد. علاوه بر این، از روش‌های تفسیرپذیر مانند مدل تفسیری محلی - مدل توضیحی آگنوستیک^۴ (LIME) استفاده شده تا تصمیمات مدل برای کاربران شفاف و قابل‌درک باشد، امری که به اعتماد بیشتر به مدل کمک می‌کند. این مدل از شبکه‌های عصبی توجه چندوجهی عمیق^۵ (DMVAN) برای استخراج ویژگی‌های تصویری و متنی از چندین سطح و دیدگاه بهره می‌گیرد. مکانیزم‌های توجه چندوجهی در این مدل، تعامل میان این ویژگی‌ها را بهبود می‌بخشد، به گونه‌ای که بتوان ویژگی‌های احساسی تصاویر را با کمک متن بهتر شناسایی کرد. برای ادغام این ویژگی‌ها در یک ساختار جامع، از رویکرد ادغام چندوجهی همراه با مکانیزم‌های توجه چندسره استفاده شده است که تحلیل و بازنمایی دقیق‌تری از اطلاعات ارائه می‌دهد. همچنین، لایه‌های شبکه عصبی چندلایه^۶ (MLP) به مدل افزوده شده تا عمق تحلیل افزایش یابد و دقت در طبقه‌بندی بهبود پیدا کند. نتایج این پژوهش نشان می‌دهد که مدل پیشنهادی عملکردی بهتر از روش‌های پیشین داشته است. این موفقیت به دلیل استخراج بازنمایی‌های معنایی عمیق‌تر و تعامل مؤثرتر میان ویژگی‌های متنی و تصویری است. افزون بر این،

و مؤثر ترکیب کند، طراحی شده است. در مدل پیشنهادی، از ترکیب CNN چندمقیاسی برای استخراج ویژگی‌های محلی و LSTM برای شناسایی ویژگی‌های دنباله‌ای و جهانی استفاده شده است. این دو دسته ویژگی در نهایت در لایه‌ای موسوم به Fusion-Net ادغام شده‌اند تا نمایش یکپارچه و جامعی از متن به دست آید. یکی از ویژگی‌های کلیدی این مدل، استفاده از یادگیری چندوظیفه‌ای است که در آن، یک رمزگذار مشترک وظیفه استخراج ویژگی‌های کلی را بر عهده دارد؛ در حالی که رمزگذارهای خصوصی برای استخراج ویژگی‌های خاص هر نوع کالا به کار می‌روند. علاوه بر این، مکانیزم یادگیری خصمانه^۱ در ساختار مدل تعبیه شده است تا از استقلال ویژگی‌های مشترک از نوع کالا اطمینان حاصل شود و تداخل اطلاعات میان ویژگی‌های مشترک و خصوصی به حداقل برسد. نتایج این پژوهش نشان داد که مدل MTL-MSCNN-LSTM با دستیابی به دقت ۸۷٫۳۳ درصد و امتیاز F1 معادل ۰٫۸۷۳۴ عملکرد قابل‌توجهی در مقایسه با روش‌های سنتی نظیر رگرسیون لجستیک، SVM و جنگل تصادفی داشته است. این یافته‌ها همچنین نشان داد که یادگیری چندوظیفه‌ای به‌طور معناداری عملکرد مدل را نسبت به یادگیری تک‌وظیفه‌ای بهبود داده است. ترکیب ویژگی‌های محلی و جهانی از طریق Fusion-Net نیز تأثیر بسزایی در افزایش دقت مدل داشته است. با این حال، این مدل با محدودیت‌هایی نیز روبه‌روست. از جمله این که ساختار پیچیده آن نیازمند منابع محاسباتی بیشتری نسبت به روش‌های سنتی است و زمان آموزش مدل نیز به‌طور قابل‌توجهی افزایش می‌یابد. علاوه بر این، آزمایش‌ها تنها بر داده‌های مربوط به نظرات کاربران درباره کالاها انجام شده و کارایی مدل در سایر حوزه‌ها بررسی نشده است.

رونک زنگ و همکاران [۲۰] در پژوهشی تلاش کردند تا چالش‌های مربوط به طبقه‌بندی احساسات بین دامنه‌ای^۲ را برطرف کنند؛ مشکلی که ناشی از تفاوت‌های ساختاری و معنایی میان دامنه‌های مختلف است. به این منظور، آن‌ها روشی ترکیبی مبتنی بر CNN و یادگیری گسترده طراحی کردند که قادر است به‌طور هم‌زمان ویژگی‌های مشترک میان دامنه‌ها و ویژگی‌های خاص هر دامنه را استخراج کند. این رویکرد باعث شد که عملکرد طبقه‌بندی احساسات در دامنه‌های مختلف بهبود یابد. علاوه بر این، از ابزارهایی نظیر حداکثر اختلاف میانگین^۳ (MMD) برای کاهش اختلاف توزیع داده‌ها و Co-Training برای بهره‌برداری بهینه از داده‌های محدود برچسب‌گذاری‌شده در دامنه هدف استفاده شده است. مدل

⁴ local interpretable model-agnostic explanation model

⁵ deep multi-view attentive network

⁶ multi-layer perceptron

¹ Adversarial Learning

² Cross-Domain Emotion Classification

³ Maximum Mean Discrepancy

آموزش و پیش‌بینی شود.

مین دونگ و همکاران [۴] در این پژوهش مدلی جدید با نام شبکه عصبی کانولوشن متغیر و ادغام کانولوشن^۱ (VCPCNN) معرفی کرده‌اند که به‌منظور بهبود دقت طبقه‌بندی احساسات متنی طراحی شده است. هدف این مدل، بهینه‌سازی فرآیندهای کانولوشن و ادغام با استفاده از معماری‌های پیشرفته‌ای است که بر محدودیت‌های موجود در TextCNN غلبه می‌کنند. در این راستا، مدل VCPCNN از لایه‌های کانولوشنی متغیر و ترکیبی از روش‌های ادغام میانگین و حداکثر بهره می‌برد تا ویژگی‌های احساسی متن را با دقت بیشتری استخراج کند. این تغییرات ساختاری، امکان حفظ اطلاعات جزئی و حیاتی در بازنمایی‌های استخراج شده را فراهم می‌کند و به بهبود قابل توجه عملکرد مدل منجر شده‌اند. در این پژوهش، عملکرد VCPCNN با مدل‌های دیگری مانند TextCNN، MVCCNN، RCNN و BiLSTM مقایسه شده است. نتایج به‌دست‌آمده حاکی از بهبود عملکردی معادل ۱٫۹۷ درصد نسبت به TextCNN در چهار مجموعه داده متفاوت است. همچنین، در تحلیل داده‌های چنددسته‌ای چینی، VCPCNN توانسته است دقت بیشتری نسبت به مدل‌های پیشین ارائه دهد و سازگاری بهتری با داده‌های پیچیده و دسته‌بندی‌های متنوع نشان دهد. این موفقیت، توانایی بالای مدل در شناسایی ویژگی‌های حساس و مهم متن را به‌وضوح نشان می‌دهد. با این حال، مقاله به محدودیت‌هایی نیز اشاره دارد. یکی از این محدودیت‌ها، ضعف TextCNN در استخراج مناسب ویژگی‌های تعبیه کلمات است، که این مشکل در بسیاری از مدل‌های مشابه نیز دیده می‌شود. نویسندگان بر این باورند که مدل‌های موجود اغلب اطلاعات مربوط به ابعاد تعبیه کلمات را نادیده می‌گیرند و نیاز به بهبود در این زمینه کاملاً محسوس است.

ژو لیانگ لنگ و همکاران [۲۲] در پژوهش خود مدلی ترکیبی برای بهبود تحلیل احساسات متنی ارائه کرده‌اند که از ترکیب شبکه‌های عصبی بازگشتی نظیر BiLSTM و BiGRU با مکانیزم خودتوجهی چند سر تقویت شده^۲ بهره می‌برد. هدف این مدل، تقویت بازنمایی معنایی متن‌ها و بهبود دقت و عملکرد در تحلیل احساسات است. همچنین، استفاده از ساختار رمزگذار خودکار به بازتولید اطلاعات متنی و ارتقای دقت طبقه‌بندی کمک می‌کند. مکانیزم خودتوجهی چند سر تقویت شده نقش کلیدی در این مدل دارد؛ که از ساختار Transformer الهام گرفته شده است. این مکانیزم با حذف عملیات ماسک‌کردن و لایه‌های پیش‌خور، بر تعاملات معنایی بین کلمات تمرکز بیشتری دارد و بازنمایی‌های دقیق‌تر و معنایی‌تری ارائه

بهره‌گیری از روش تفسیرپذیر LIME به تحلیل شفاف‌تر تصمیمات مدل کمک کرده است، که این امر باعث افزایش اعتماد به کاربرد آن می‌شود. با این حال، نیاز به منابع محاسباتی قوی و کمبود داده‌های برچسب‌گذاری شده برای تحلیل احساسات چندوجهی از جمله چالش‌های اصلی پژوهش هستند. همچنین، پیچیدگی‌های زبانی و دشواری در پردازش متن‌های طولانی‌تر و پیچیده‌تر، از دیگر محدودیت‌های موجود به شمار می‌روند.

فالیان هوانگ و همکاران [۲] مدلی نوین با نام AEC-LSTM معرفی کرده‌اند که به‌منظور بهبود تحلیل احساسات متنی طراحی شده است. این مدل با ترکیب مکانیزم‌های توجه، هوش هیجانی، و شبکه‌های عصبی LSTM و CNN توانسته است گامی مؤثر در استخراج و تحلیل ویژگی‌های احساسی متن بردارد. نقطه تمرکز اصلی این مدل، بهره‌گیری از هوش هیجانی برای تقویت فرآیند یادگیری ویژگی‌های احساسی و استفاده از مکانیزم توجه مبتنی بر موضوع برای تنظیم وزن‌های بازنمایی پنهان متن است. این مکانیزم، ویژگی‌های احساسی مرتبط با موضوع را به شکلی دقیق‌تر و هدفمندتر استخراج می‌کند. در مدل AEC-LSTM، یک نسخه پیشرفته از LSTM به کار گرفته شده که هوش هیجانی را به طور مستقیم در فرآیند یادگیری اطلاعات احساسی دخیل می‌کند. این کار با استفاده از یک ماژول مبتنی بر هیجان و تخمین‌زننده هیجان انجام می‌شود که یادگیری ویژگی‌های احساسی را بهبود می‌بخشد. در همین راستا، مکانیزم توجه مبتنی بر موضوع به مدل امکان می‌دهد تا با تمرکز بر موضوعات خاص متن، بازنمایی‌های دقیق‌تر و غنی‌تری از احساسات ارائه دهد. علاوه بر این، CNN برای استخراج ویژگی‌های محلی متن طراحی شده‌اند و ترکیب آن‌ها با LSTM، امکان تحلیل وابستگی‌های بلندمدت و ویژگی‌های محلی را به‌صورت هم‌زمان فراهم کرده است. نتایج آزمایش‌های انجام‌شده بر روی مجموعه داده‌های واقعی مانند JDReview، Yelp2014، IMDB و SinaWeibo نشان می‌دهد که مدل AEC-LSTM در مقایسه با روش‌های پیشین عملکرد بهتری دارد. این مدل به لطف استفاده از مکانیزم‌های توجه و هوش هیجانی، دقت طبقه‌بندی احساسات را به طور قابل توجهی افزایش داده است. همچنین، ترکیب توانمندی‌های LSTM و CNN، این مدل را به ابزاری قدرتمند برای تحلیل احساسات تبدیل کرده است. با این حال، این مدل با محدودیت‌هایی نیز مواجه است. نیاز به منابع محاسباتی بالا و وابستگی به داده‌های برچسب‌گذاری شده از جمله چالش‌های اصلی آن محسوب می‌شود. همچنین، پیچیدگی ساختاری مدل می‌تواند منجر به افزایش زمان

² Enhanced Multi-Head Self-Attention

¹ variable convolution and pooling convolution neural network

پیشنهادی با دقت ۹۲,۳۳ درصد در سه مجموعه داده استاندارد شامل Hu and Liu, SemEval, و Bo Pang and Lillian Lee ارزیابی شده و عملکرد بهتری نسبت به روش‌های موجود مانند BERT-ADA, MGAN و LMIAN داشته است. این مدل به‌ویژه در تحلیل نظرات کوتاه و غیرساختاریافته عملکرد موفقی از خود نشان داده است. استفاده از RoBERTa برای درک معنایی دقیق‌تر متن و ترکیب آن با CNN تک بعدی و BiLSTM، دقت و تفسیرپذیری نتایج را به‌طور قابل توجهی بهبود بخشیده است. با این حال، مدل پیشنهادی با محدودیت‌هایی نیز مواجه است. برای مثال، در تحلیل داده‌های بسیار پیچیده یا نظرات دارای جنبه‌های متعدد، دقت مدل ممکن است کاهش یابد. همچنین، آموزش مدل نیازمند منابع محاسباتی بالایی است که ممکن است در شرایط محدودیت منابع به چالش تبدیل شود.

بوآسیدا یوسرا و مزالی حکیم [۲۴] در پژوهش خود به بررسی و توسعه مدل‌های ترکیبی برای تحلیل احساسات در پلتفرم‌های اجتماعی نظیر توئیتر پرداخته‌اند. هدف اصلی این تحقیق، بهبود تحلیل احساسات از طریق ترکیب مدل‌های Transformer و مدل‌های دنباله‌ای مانند BiLSTM بوده است. این پژوهش تلاش کرده تا شکاف میان توانایی‌های مدل‌های Transformer در درک مفهومی متن و نقاط قوت مدل‌های دنباله‌ای در پردازش وابستگی‌های زمانی را پر کند. در این مطالعه، سه مدل ترکیبی جدید معرفی شده است: RoBERTa-CNN-BiLSTM که از RoBERTa برای استخراج مفاهیم، CNN برای استخراج ویژگی‌های محلی و BiLSTM برای پردازش وابستگی‌های دنباله‌ای بهره می‌برد؛ BERT-BiLSTM که ترکیب BERT برای ایجاد تعبیه‌های مفهومی و BiLSTM برای تحلیل دنباله‌ای است؛ و DistilBERT-BiLSTM که با استفاده از نسخه سبک‌تر BERT و BiLSTM به کاهش منابع محاسباتی و افزایش دقت پرداخته است. داده‌های این پژوهش با مجموعه‌ی Sentiment140، شامل ۱,۶ میلیون توییت با برچسب‌های مثبت و منفی، ارزیابی شده‌اند و پیش‌پردازش‌هایی مانند توکن‌سازی، حذف کاراکترهای خاص و تبدیل متن به تعبیه‌های مدل Transformer نیز انجام گرفته است. نتایج نشان داده‌اند که مدل DistilBERT-BiLSTM با دقت ۸۱ درصد و معیارهای صحت و یادآوری به ترتیب ۸۲ و ۸۰ درصد، بهترین عملکرد را داشته است. مدل‌های BERT-BiLSTM و RoBERTa-CNN-BiLSTM نیز به ترتیب دقت‌های ۷۹ و ۷۷ درصد را ارائه داده‌اند. این یافته‌ها نشان‌دهنده بهبود قابل توجه مدل‌های ترکیبی

می‌دهد. در همین راستا، BiLSTM و BiGRU به‌عنوان لایه‌های رمزگذار و رمزگشا، به استخراج وابستگی‌های زمانی و بازنمایی ویژگی‌های عمیق کمک می‌کنند. همچنین، استفاده از BERT در پیش‌پردازش به جای Word2Vec، موجب تولید جاسازی‌هایی با دقت معنایی بالاتر شده است. نتایج این پژوهش نشان داده است که مدل RNN هیبریدی و خودتوجهی چند سر پیشرفته^۱ (HRNaEMSA) نسبت به روش‌های پایه نظیر Text-CNN، LSTM-Attention و RCNN در معیارهایی مانند دقت، صحت^۲، یادآوری^۳ و امتیاز F1 عملکرد بهتری دارد. به‌طور خاص، مکانیزم خودتوجهی چند سر تقویت شده به بازنمایی دقیق‌تر ویژگی‌های احساسی متن و افزایش دقت طبقه‌بندی کمک کرده است. بررسی‌ها همچنین نشان داده که BiLSTM در مقایسه با BiGRU از نظر دقت برتر است، اما BiGRU از لحاظ سرعت و کاهش تعداد پارامترها عملکرد بهتری دارد. علاوه بر این، بهره‌گیری از BERT در پیش‌پردازش، برتری قابل توجهی نسبت به مدل‌های پایه مبتنی بر BERT ایجاد کرده است. با وجود این دستاوردها، مدل HRNaEMSA با محدودیت‌هایی نیز روبه‌رو است. این مدل تنها بر روی دو مجموعه داده IMDB و SST-2 آزمایش شده و نیاز به ارزیابی در مجموعه داده‌های بزرگ‌تر و متنوع‌تر دارد. علاوه بر این، پیچیدگی مدل و تعداد بالای پارامترها منجر به افزایش زمان محاسباتی می‌شود و مکانیزم‌های ماسک‌کردن همچنان نیازمند بهینه‌سازی بیشتری هستند.

محمد رضوان رشید رعنا و همکاران [۲۳] در پژوهش خود روشی ترکیبی و نوآورانه برای ABSA ارائه کرده‌اند که از مدل‌های پیشرفته یادگیری عمیق بهره می‌برد. این روش از ترکیب CNN، RoBERTa، تک بعدی و BiLSTM برای استخراج ویژگی‌ها و طبقه‌بندی احساسات در نظرات کاربران استفاده می‌کند. هدف اصلی این رویکرد، بهبود دقت و کارایی تحلیل احساسات در نظرات کوتاه و غیرساختاریافته است. در این پژوهش، مدل RoBERTa برای استخراج ویژگی‌های متنی پیشرفته و ایجاد بردارهای تعبیه به کار گرفته شده است. سپس، CNN تک بعدی برای شناسایی وابستگی‌های محلی در متن و BiLSTM برای درک وابستگی‌های متوالی و بلندمدت به‌منظور طبقه‌بندی احساسات استفاده شده است. روش ترکیبی پیشنهادی، قدرت استخراج ویژگی‌های پیشرفته توسط RoBERTa را با توانایی CNN تک بعدی در شناسایی الگوهای محلی و قابلیت BiLSTM در تحلیل روابط بلندمدت ترکیب می‌کند. نتایج این پژوهش نشان داده است که مدل

³ Recall

¹ Hybrid RNN and Enhanced Multi- Head Self-Attention

² Precision

توسعه مدل‌های ترکیبی برای تحلیل احساسات در زمان واقعی، و ارتقای مدل‌ها برای داده‌های با جنبه‌های متعدد و پیچیده را شناسایی کرده است.

پژوهش ما با در نظر گرفتن تحقیقات پیشین و تمرکز بر تحلیل احساسات در زبان فارسی، با هدف رفع محدودیت‌های موجود، کاربردهای گسترده‌ای را برای تحلیل احساسات در شرایط کم‌منبع و زبان‌های دیگر، از جمله زبان عربی با رسم الخط مشابه، فراهم می‌کند. جدول ۱، خلاصه‌ای از توضیحات عملکرد مدل‌های پیشنهادی در پیشینه را ارائه می‌دهد.

نسبت به روش‌های سنتی در تحلیل احساسات تویتر هستند. از نقاط قوت این تحقیق می‌توان به ترکیب قابلیت‌های Transformer و BiLSTM، استفاده از DistilBERT به‌عنوان مدلی سبک‌تر برای کاهش نیاز به منابع محاسباتی و بهبود دقت تحلیل احساسات در داده‌های پیچیده و غیرساختاریافته اشاره کرد. با این حال، این پژوهش محدودیت‌هایی نیز دارد؛ برای مثال، مدل‌ها تنها بر روی مجموعه داده Sentiment140 ارزیابی شده‌اند و عملکرد آنها بر روی داده‌های دیگر نیازمند بررسی است. همچنین، منابع محاسباتی نسبتاً بالایی برای آموزش مدل‌ها نیاز است. این پژوهش محدودیت‌هایی مانند نیاز به تحلیل داده‌های چندزبانه و پیچیده‌تر،

جدول ۱ خلاصه ارزیابی پژوهش‌های پیشین

افراد مرتبط به مدل	نام مدل	توضیحات، مزایا و معایب مدل	عملکرد مدل
فضلی واحد و همکاران [۱۲]	SAE- LSTM	مزایا: دقت مدل ترکیبی با نسبت ۹۰ درصد آموزش و ۱۰ درصد آزمون، ۸۷ درصد را ثبت کرد که بهتر از مدل‌های یادگیری عمیق ساده است. معایب: عدم بررسی طبقه‌بندی چند طبقه‌ای که بی‌طرفی یا دوسوگرایی را نادیده می‌گیرد.	دقت ۸۷٪
مریگانک شوکلا و آخیل کومار [۶]	Transformer- BiLSTM- CNN	مزایا: دقت بالاتر و عملکرد بهتر نسبت به مدل‌های ساده مانند LSTM، BiLSTM و CNN، استفاده از لایه رمزگذار Transformer، دقت را تا ۲ الی ۳ درصد افزایش می‌دهد. معایب: پیچیدگی بالای مدل، ترکیب CNN و BiLSTM، دقت مدل CNN را افزایش چندانی نمی‌دهد.	دقت ۸۹٫۰۴٪
سکرین تام و همکاران [۱]	ConvBiLSTM	بهبود عملکرد طبقه‌بندی احساسات نسبت به مدل‌های ساده‌ی CNN، LSTM، Bi-LSTM و CNN-LSTM با تعبیه کلمه‌ی Word2Vec معایب: داده‌های مورد استفاده محدود بوده‌اند که قابل تعمیم به دنیای واقعی نیستند.	دقت ۹۴٫۱۳٪
شفیق و همکاران [۱۳]	AraBERT- CRF	مزایا: بعد از تنظیم پارامترهای مدل AraBERT برای E2E-ABSA، AraBERT با CRF در طبقه‌بندی بهتر از سافت مکس عمل می‌کند. معایب: نیازمند منابع محاسباتی قدرتمند از جمله پردازنده‌های قوی GPU، نیازمند داده آموزشی بیشتر و متنوع‌تری برای رسیدن به عملکرد بهینه، استفاده از CRF فضای جستجو را بزرگتر و پیچیده‌تر می‌کند.	دقت ۹۸٫۳۴٪ امتیاز F1 ۹۷٫۷۸٪
محمد الجبرین و همکاران [۱۴]	MFOHDL- SA	مزایا: مدل پیشنهادی نسبت به رویکردهای SVM، XGBoost و CNN بهبود یافته است. ترکیب الگوریتم MFO و CNN- LSTM باعث افزایش دقت طبقه‌بندی شد. معایب: پیچیده بودن الگوریتم MFO و پیاده‌سازی چالش‌برانگیز	دقت ۹۵٫۰۹٪ امتیاز F1 ۹۲٫۶۲٪
ایزابیل کاروالو و همکاران [۱۵]	BERTimbau	مزایا: دقت بالاتر در طبقه‌بندی احساسات نسبت به مدل‌های SVM، نایبو بیز و RNN ساده، در نظر گرفتن بافت بیشتر با استفاده از CRF معایب: پیچیدگی محاسباتی و زمان آموزش بالاتر نسبت به مدل‌های ساده‌تر، نیاز به تنظیم تعداد پارامترهای بیشتری نسبت به SVM و نایبو بیز، افت عملکرد با افزایش بیش از حد طول جمله‌ها.	امتیاز F1 ۸۴٪
کیان لانگ تن و همکاران [۱۶]	ensemble hybrid RoBERTa- LSTM (Majority)	مزایا: ترکیب چندین مدل یادگیری عمیق و استفاده از تکنیک‌های مجموعه موجب بهبود عملکرد، نسبت به RoBERTa- LSTM شد. معایب: پیچیدگی بیشتر نسبت به یک مدل تکی	دقت ۹۴٫۹٪
کیان لانگ تن و همکاران [۱۷]	RoBERTa- LSTM	مزایا: استفاده از LSTM موجب یادگیری معنای دنباله دار در جملات طولانی می‌شود. معایب: تنها LSTM مورد استفاده قرار گرفت، سایر مدل‌های توالی نظیر BiLSTM و GRU مورد بررسی قرار نگرفته‌اند و این مدل تکی، عملکرد ضعیف‌تری نسبت به مدل مجموعه‌ای ثبت کرد.	دقت ۹۲٫۹۶٪ امتیاز F1 ۹۳٪
مهمت و ایلهان [۸]	M-Hybrid (ترکیب CNN، LSTM، BiLSTM و GRU)	مزایا: ترکیب تعبیه‌ها با مدل‌های یادگیری عمیق عملکرد طبقه‌بندی احساسات را بهبود می‌بخشد، همچنین دقت مدل پیشنهادی از مدل‌های پایه CNN، LSTM، BiLSTM بالاتر بود. معایب: مجموعه داده‌های مورد استفاده در این مطالعه خیلی بزرگ نیست، صفت‌ها و قیده‌ها از نظر احساسی دارای اهمیت بیشتری نسبت به اسم‌ها دارند.	دقت ۸۲٫۱۴٪

افراد مرتبط به مدل	نام مدل	توضیحات، مزایا و معایب مدل	عملکرد مدل
ستونگ وان سو و همکاران [۱۸]	Bi-LSTM with word-level inputs	مزایا: بررسی جامع مدل‌های مختلف CNN و RNN با دو نوع ورودی. استفاده از ۱۳ مجموعه داده مختلف برای اطمینان از نتایج قابل تعمیم. معایب: استفاده از بردارهای کلمه و کاراکتر که از ابتدا آموزش داده شده‌اند و عدم استفاده از بردارهای از پیش آموزش دیده مانند BERT. عدم بررسی تأثیر ترکیب مدل‌های CNN و RNN در یک معماری ترکیبی.	AUROC (۰.۶۹ - ۰.۹۲)
نینگ ژینگ و همکاران [۱۹]	MTL-MSCNN-LSTM	مزایا: بهبود دقت طبقه‌بندی احساسات با استفاده از استخراج ویژگی‌های محلی و جهانی به طور همزمان. معایب: مدل پیشنهادی نیاز به منابع محاسباتی بیشتری نسبت به روش‌های سنتی مانند SVM و نایبو بیز دارد. زمان آموزش مدل به دلیل پیچیدگی ساختار شبکه‌های عمیق بیشتر است.	دقت ۸۷.۳۳٪ امتیاز F1 ۸۷.۳۴٪
رونک زنگ و همکاران [۲۰]	CBL CNN-Broad learnig	مزایا: استفاده از MMD برای کاهش شکاف دامنه‌ای و بهبود انتقال دانش بین دامنه‌ها. بهبود عملکرد طبقه‌بندی احساسات در دامنه‌های مختلف با استفاده از Co-Training. معایب: نیاز به منابع محاسباتی قوی برای آموزش مدل‌های ترکیبی. کمبود داده‌های برچسب‌گذاری شده در دامنه هدف. پیچیدگی‌های زبانی خاص که ممکن است بر عملکرد مدل تأثیر بگذارد.	دقت ۸۶.۴۱٪
محمدرضا فیضی درخشی و همکاران [۲۱]	DMVAN	مزایا: ترکیب هوشمندانه ویژگی‌های متنی و تصویری برای بهبود طبقه‌بندی احساسات. استفاده از مکانیزم‌های توجه چندوجهی برای استخراج ویژگی‌های احساسی و تشخیصی. معایب: نیاز به منابع محاسباتی قوی برای آموزش مدل‌های ترکیبی. کمبود داده‌های برچسب‌گذاری شده برای تحلیل احساسات چندوجهی. پیچیدگی‌های زبانی خاص که ممکن است بر عملکرد مدل تأثیر بگذارد.	دقت ۹۹.۸۰۱٪
فالیان هوانگ و همکاران [۲]	AEC-LSTM	مزایا: استفاده از هوش هیجانی برای بهبود یادگیری ویژگی‌های احساسی. مکانیزم توجه مبتنی بر موضوع که به مدل کمک می‌کند تا ویژگی‌های احساسی مرتبط با موضوع را بهتر استخراج کند. ترکیب LSTM و CNN که باعث می‌شود مدل هم ویژگی‌های محلی و هم وابستگی‌های بلندمدت را استخراج کند. معایب: نیاز به منابع محاسباتی بالا برای آموزش مدل‌های ترکیبی. وابستگی به داده‌های برچسب‌گذاری شده برای آموزش مدل. پیچیدگی مدل که ممکن است باعث افزایش زمان آموزش و پیش‌بینی شود.	دقت ۹۲.۹۶٪ امتیاز F1 ۹۳٪
مین دونگ و همکاران [۴]	VCPCNN	مزایا: مدل VCPCNN بهبود ۱.۹۷٪ نسبت به مدل TextCNN را در چهار مجموعه داده مختلف نشان داد. VCPCNN در مجموعه داده‌های چنددسته‌ای چینی عملکرد بهتری نسبت به مدل‌های پیشین داشته است. معایب: محدودیت‌های مدل TextCNN در استخراج ویژگی‌های تعبیه کلمات به خوبی پوشش داده نشده است. این مقاله نشان می‌دهد که مدل‌های موجود اغلب ویژگی‌های تعبیه کلمات را نادیده می‌گیرند.	دقت ۸۸٪
ژو لیانگ لنگ و همکاران [۲۲]	HRNaEMSA (BiLSTM)	مزایا: استفاده از ساختار autoencoder برای بازتولید اطلاعات متنی. بهبود دقت و عملکرد مدل در تحلیل احساسات. معایب: مدل هنوز نیاز به بهبود در استفاده از مکانیزم‌های ماسک‌کردن دارد. زمان محاسباتی و تعداد پارامترها می‌تواند برای مدل‌های بزرگ‌تر به چالش تبدیل شود. نیاز به آزمایش مدل بر روی مجموعه‌های داده بزرگ‌تر و متنوع‌تر.	دقت ۸۷.۴٪ صحت ۸۷.۵٪ یادآوری ۸۷.۴٪ امتیاز F1 ۸۷.۴٪
محمد رضوان رشید رعنا و همکاران [۲۳]	RoBERTa-1D-CNN-BiLSTM	مزایا: استفاده از RoBERTa برای استخراج ویژگی‌های پیشرفته و بهبود درک معنایی متن. ترکیب CNN یک بعدی و BiLSTM برای استخراج ویژگی‌های محلی و بلندمدت و بهبود طبقه‌بندی احساسات. قابلیت مدل در تحلیل نظرات کوتاه و غیرساختاریافته. معایب: مدل پیشنهادی ممکن است در مواجهه با داده‌های بسیار پیچیده یا نظرات با جنبه‌های متعدد دچار کاهش دقت شود. نیاز به منابع محاسباتی بالا برای آموزش مدل‌های ترکیبی.	دقت ۹۲.۳۳٪ امتیاز F1 ۹۱.۴۱٪
بوآسیدا یوسرا و مزالی حکیم [۲۴]	DistilBERT-BiLSTM	مزایا: ترکیب قابلیت‌های Transformer و مدل‌های دنباله‌ای برای بهبود تحلیل احساسات. استفاده از DistilBERT به عنوان یک مدل سبک‌تر که منابع محاسباتی کمتری نیاز دارد. بهبود دقت در تحلیل احساسات در داده‌های پیچیده و غیرساختاریافته توییت. معایب: مدل‌ها تنها بر روی یک مجموعه داده (Sentiment140) ارزیابی شدند و ممکن است در داده‌های دیگر عملکرد متفاوتی داشته باشند. نیاز به منابع محاسباتی نسبتاً بالا برای آموزش مدل‌های ترکیبی.	دقت ۸۱٪ صحت ۸۲٪ یادآوری ۸۰٪ امتیاز F1 ۸۱٪


۴- روش تحقیق

در این بخش کارهای انجام شده در این پژوهش به طور مفصل شرح داده شده است.

۴-۱- پیش‌پردازش داده‌ها با استفاده از ParsBERT

پیش‌پردازش داده‌ها مرحله‌ای حیاتی در فرآیند یادگیری ماشین

است که تأثیر مستقیمی بر عملکرد مدل نهایی دارد. این فرایند شامل مجموعه‌ای از عملیات است که داده‌ها را از حالت خام به قالبی مناسب برای مدل‌سازی تبدیل می‌کند. این فرآیند به‌طور جامع انجام می‌شوند تا داده‌ها برای آموزش مدل‌های یادگیری ماشین به بهترین نحو آماده شوند و دقت و عملکرد مدل نهایی به حداکثر برسد. ابتدا داده‌ها برای اطمینان از کیفیت و صحت آن‌ها پاکسازی



شکل ۱ ساختار مدل SAE در مدل پیشنهادی

Adam از نرخ یادگیری تطبیقی استفاده می‌کند که به هر پارامتر مدل، یک نرخ یادگیری متفاوت اختصاص می‌دهد. این ویژگی به مدل کمک می‌کند تا به سرعت به سمت نقطه بهینه همگرا شود. در فرآیند آموزش، داده‌های آموزشی و اعتبارسنجی به مدل داده می‌شوند تا مدل بتواند پارامترهای خود را بهینه کند. در این مرحله، مدل با استفاده از داده‌های ورودی تلاش می‌کند تا ویژگی‌های مهم را استخراج کرده و داده‌های ورودی را بازسازی کند. هدف از این فرآیند، به حداقل رساندن خطای بازسازی است که توسط تابع هزینه MSE اندازه‌گیری می‌شود. پس از آموزش مدل، از بخش رمزگذار برای استخراج ویژگی‌ها از داده‌های آموزشی، اعتبارسنجی و آزمایشی استفاده می‌شود. این ویژگی‌ها به عنوان ورودی برای مدل‌های یادگیری عمیق بعدی مورد استفاده قرار می‌گیرند. با استفاده از این ویژگی‌های فشرده شده، می‌توان عملکرد مدل‌های یادگیری عمیق مانند شبکه‌های عصبی BiLSTM و CNN را بهبود بخشید. در نهایت برای استفاده از برچسب‌های داده‌ها در مدل‌های یادگیری عمیق، این برچسب‌ها به فرمت One-Hot تبدیل می‌شوند. در این فرمت، هر برچسب به یک بردار باینری تبدیل می‌شود که تنها یک عنصر آن برابر با یک و بقیه عناصر برابر با صفر هستند. این فرمت به مدل‌های یادگیری عمیق کمک می‌کند تا برچسب‌های مختلف را به درستی تشخیص داده و کلاس‌بندی انجام شود.

۳-۴- طبقه‌بندی با استفاده از مدل ترکیبی

Transformer-BiLSTM-CNN

در نهایت ویژگی‌های استخراج شده در قسمت دوم، وارد مدل ترکیبی Transformer-BiLSTM-CNN شده و وظیفه‌ی طبقه‌بندی انجام می‌شود. این بخش ترکیبی از مدل‌های BiLSTM، CNN و تبدیل کننده برای طبقه‌بندی متن را پیاده‌سازی می‌کند. مدل‌های BiLSTM و CNN، به صورت موازی در کنار هم استفاده

می‌شوند. در این مرحله داده‌های نامعتبر، ناموجود و تکراری حذف می‌شوند. سپس با استفاده از توکنایزر هضم طول کلمات محاسبه می‌شود تا نظرات بسیار کوتاه و بلند شناسایی و مدیریت شود. سپس برای جلوگیری از عدم توازن در داده‌ها، تعداد نظرات مثبت و منفی برابر می‌شوند. در ادامه داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند که به ترتیب ۸۱٪، ۹٪ و ۱۰٪ از کل داده‌ها را شامل می‌شوند. در نهایت داده‌ها توکنایز می‌شوند. منظور از توکنایز، تبدیل متن به دنباله‌ای از واحدهای زبانی است. سپس در ادامه این دنباله‌ها به شناسه‌های عددی تبدیل می‌شوند تا مدل بتواند آن‌ها را پردازش کند. برای این توکن‌ها ماسک توجه نیز ایجاد می‌شود تا مدل به داده‌های مناسب، توجه بیشتر اختصاص دهد و به داده‌های نامناسب‌تر، توجه کمتری کند. این کار با استفاده از مدل پیش آموزش دیده ParsBERT^۱ انجام می‌شود که نظرات را به قالب ورودی مناسب برای مدل پیشنهادی تبدیل می‌کند. این کار برای مدل‌های مبتنی بر BERT، لازم است.

۴-۲- استخراج ویژگی با استفاده از SAE


داده‌ها پس از پیش پردازش، برای استخراج ویژگی وارد مدل SAE می‌شوند. رمزگذار در این مدل شامل سه لایه متراکم است که به ترتیب دارای ۵۱۲، ۲۵۶ و ۱۲۸ نورون هستند. هر یک از این لایه‌ها از تابع فعال‌سازی ReLU^۲ استفاده می‌کنند که به مدل کمک می‌کند تا روابط غیرخطی بین ویژگی‌ها را یاد بگیرد. در بخش رمزگشا، سه لایه متراکم دیگر قرار دارند که به ترتیب دارای ۲۵۶، ۵۱۲ و ۱۲۸ نورون هستند. در این بخش، از توابع فعال‌سازی ReLU و سیگموئید^۳ استفاده می‌شود. تابع سیگموئید خروجی نهایی را بین ۰ و ۱ محدود می‌کند. وظیفه‌ی این بخش بازسازی داده‌های ورودی از ویژگی‌های فشرده شده‌ای است که توسط بخش رمزگذار استخراج شده‌اند. شکل ۱، معماری مدل SAE را نمایش می‌دهد. برای آموزش مدل SAE، ابتدا مدل با استفاده از بهینه‌ساز Adam و تابع هزینه خطای میانگین مربعات^۴ (MSE) کامپایل می‌شود. MSE یکی از متداول‌ترین توابع هزینه در مسائل رگرسیون و بازسازی است. این تابع میزان اختلاف بین مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی را اندازه‌گیری می‌کند و هدف آن به حداقل رساندن این اختلاف است. بهینه‌ساز Adam نیز یک روش کارآمد برای بهینه‌سازی پارامترهای مدل‌های یادگیری عمیق است که ترکیبی از مزایای روش‌های AdaGrad و RMSProp را به همراه دارد.

³ Sigmoid


⁴ Mean Squared Error

¹ HooshvareLab/bert-fa-base-uncased


² rectified linear unit



شکل ۲ ساختار کلی مدل Transformer-BiLSTM-CNN



شکل ۳ ساختار بلوک Transformer



شکل ۴ ساختار بخش BiLSTM-CNN مدل

می‌شوند تا از قدرت هر کدام در استخراج ویژگی‌ها و الگوهای مختلف در داده‌های متنی بهره‌مند شویم. معماری کلی مدل ترکیبی Transformer-BiLSTM-CNN در شکل ۲ نمایش داده شده است.

در این مدل یک کلاس به نام بلوک تبدیل کننده تعریف شده است که شامل لایه‌های متفاوت است از جمله توجه چندسره که برای استخراج ویژگی‌های پیچیده از داده‌های ورودی استفاده می‌شود؛ لایه متراکم با فعالسازی ReLU و رگولاریزاسیون L2 برای پیاده‌سازی شبکه عصبی پیش‌خور؛ لایه‌ی نرمال‌سازی برای نرمال‌سازی ورودی‌ها به کار می‌رود و باعث پایداری بیشتر و سرعت‌بخشی به فرایند یادگیری می‌شود. نرمال‌سازی باعث می‌شود که میانگین خروجی‌ها صفر و انحراف معیار آن‌ها یک شود؛ لایه حذف تصادفی^۱ نورون‌ها برای جلوگیری از بیش‌برازش. این بلوک تبدیل کننده به عنوان بخشی از مدل اصلی برای استخراج ویژگی‌های سطح بالا از داده‌های متنی استفاده می‌شود. شکل ۳، معماری بلوک تبدیل کننده را نمایش می‌دهد. خروجی بخش تبدیل کننده به طور موازی به BiLSTM و CNN وارد می‌شود. BiLSTM قادر به یادگیری روابط زمانی در داده‌ها است و در مدل پیشنهادی برای استخراج ویژگی‌های زمانی دو سویه استفاده می‌شود و اطلاعات متنی را در هر دو جهت زمان استخراج می‌کند. سپس از لایه GlobalMaxPooling1D استفاده می‌شود. این لایه برای کاهش ابعاد و استخراج ویژگی‌های مهم از خروجی BiLSTM به کار می‌رود و بیشینه هر ویژگی را در طول دنباله‌های زمانی انتخاب می‌کند.

به طور موازی، CNN در مدل پیشنهادی برای استخراج ویژگی‌های محلی و فضایی استفاده می‌شود. این CNN شامل دو لایه کانولوشن یک بعدی با تعداد فیلترهای ۶۴ و اندازه هسته ۱ استفاده شده است که برای اعمال فیلترهای کانولوشن به داده‌ها استفاده می‌شوند. فیلترها به صورت هسته‌های کوچک بر روی داده‌ها اعمال می‌شوند و ویژگی‌های محلی را استخراج می‌کنند. سپس دو لایه MaxPooling1D با اندازه هسته ۱ استفاده شده است که برای کاهش ابعاد و فشرده‌سازی ویژگی‌های استخراج شده توسط لایه‌های کانولوشن به کار می‌روند. در نهایت لایه Flatten، لایه خروجی‌های چندبعدی لایه‌های قبلی را به یک بردار یک بعدی تبدیل می‌کند تا بتوان آن‌ها را به لایه‌های متراکم متصل کرد. معماری BiLSTM و CNN در شکل ۴ نمایش داده شده است.

^۱ DropOut Layer

می‌شود؛ مدلهایی که هدف آن‌ها پیش‌بینی یک برچسب دسته‌ای برای هر نمونه ورودی است. در شکل ۵، این جدول نمایش داده شده است [۸]. مثبت واقعی^۳ (TP): نتیجه آزمایشی که به درستی وجود یک وضعیت یا مشخصه را نشان می‌دهد. منفی واقعی^۴ (TN): نتیجه آزمایشی که به درستی فقدان شرایط یا ویژگی را نشان می‌دهد. مثبت کاذب^۵ (FP): نتیجه آزمایشی که به اشتباه نشان می‌دهد که یک شرایط یا ویژگی خاص وجود دارد. منفی کاذب^۶ (FN): نتیجه آزمایشی که به اشتباه نشان می‌دهد که یک شرط یا ویژگی خاص وجود ندارد. اندازه‌گیری دقت، صحت، یادآوری و امتیاز F1 با توجه به ماتریس سردرگمی در شکل ۵ محاسبه می‌شود.

		Predicted Values	
		Positive	Negative
Actual Values	Positive	TP	FP
	Negative	FN	TN

شکل ۵ ماتریس سردرگمی برای یک مسئله طبقه‌بندی باینری [۸]

دقت، نسبت تعداد پیش‌بینی‌های صحیح به تعداد کل پیش‌بینی‌ها و طبق رابطه (۱) است.

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

صحت، برآورد کل برچسب‌های کلاس است که به طور دقیق برای هر کلاس پیش‌بینی شده است. به عبارت دیگر، نسبت تعداد پیش‌بینی‌های صحیح از یک کلاس به تعداد کل پیش‌بینی‌ها از آن کلاس اندازه‌گیری، که در رابطه (۲) بیان شده است.

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

یادآوری، نسبت تعداد پیش‌بینی‌های صحیح از یک کلاس به تعداد کل نمونه‌های واقعی از آن کلاس که در رابطه (۳) آمده است.

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

امتیاز F1، برای ترکیب مقادیر صحت و یادآوری در یک اندازه‌گیری استفاده می‌شود. مقدار این اندازه‌گیری بین ۰ و ۱ است و اگر

خروجی‌های BiLSTM و CNN سپس با هم ادغام شده و به یک لایه متراکم با فعال‌سازی ReLU وارد می‌شوند و در نهایت به یک لایه خروجی با فعال‌سازی سافت مکس (برای طبقه‌بندی چندکلاسه) یا سیگموئید (برای طبقه‌بندی دودویی) متصل می‌شوند. این مدل ترکیبی سپس با استفاده از بهینه‌ساز Adam و تابع هزینه متناسب با نوع مسئله کامپایل می‌شود. به طوری که بسته به نوع داده‌ها از متقاطع طبقه‌ای برای طبقه‌بندی چندکلاسه و متقاطع باینری^۱ برای طبقه‌بندی دودویی استفاده می‌شود. سپس مدل با استفاده از داده‌های آموزشی و داده‌های اعتبارسنجی، آموزش داده می‌شود. این ترکیب به مدل امکان می‌دهد که از ویژگی‌های مختلف داده‌ها بهره‌برداری کند و عملکرد بهتری در وظایف طبقه‌بندی داشته باشد. در نهایت مدل آموزش‌دیده برای پیش‌بینی احتمالات تعلق هر نمونه به هر یک از کلاس‌ها استفاده می‌شود. به این ترتیب، مدل برای هر نمونه یک بردار احتمال تولید می‌کند که نشان می‌دهد هر نمونه با چه احتمالی به هر یک از کلاس‌های ممکن تعلق دارد. سپس، برای تعیین برچسب نهایی هر نمونه، بیشترین مقدار احتمال از بردار احتمال انتخاب می‌شود. این عمل به مدل امکان می‌دهد تا تصمیم‌گیری قطعی در مورد برچسب هر نمونه را بر اساس بالاترین احتمال موجود انجام دهد. این دو گام به طور مؤثر فرآیند طبقه‌بندی نمونه‌ها را با استفاده از مدل آموزش‌دیده به انجام می‌رسانند. سپس مدل با استفاده از معیارهای ارزیابی مناسب، ارزیابی می‌شود.

۵- ارزیابی مدل پیشنهادی

ما با استفاده از مدل پیشنهادی، سه مجموعه‌ی داده‌ی متفاوت را مورد بررسی قرار دادیم و نتیجه را با مدل‌های Transformer-CNN [۶] و BiLSTM-CNN [۱۲] و یک مدل ساده CNN مقایسه کردیم. برای اینکار این مدل‌ها را مشابه مدل پیشنهادی این پژوهش توسعه دادیم و نیز داده‌های فارسی ورودی برای این مدل‌ها را به طور مشابه پیش‌پردازش کردیم تا نتایج درستی داشته باشیم.

۵-۱- معیارهای عملکرد

ماتریس سردرگمی^۲، جدولی است که عملکرد یک مدل یادگیری ماشین را بر روی یک مجموعه داده آزمون خلاصه می‌کند. این جدول تعداد پیش‌بینی‌های صحیح و نادرست مدل را نشان می‌دهد. معمولاً برای اندازه‌گیری عملکرد مدل‌های طبقه‌بندی کننده استفاده

⁴ true negative

⁵ false positive

⁶ false negative

¹ Binary crossentropy

² confusion matrix

³ true positive

طبقه‌بندی کننده به درستی همه نمونه‌ها را طبقه‌بندی کند، مقدار ۱ را می‌گیرد. اندازه‌گیری امتیاز F1 در رابطه (۴) آورده شده است.

$$F1 = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

هرچقدر مقدار امتیاز F1 به ۱ نزدیک شود؛ برای موفقیت آن کلاس بهتر است.

۵-۲- معرفی مجموعه‌ی داده

ما از نظرات کاربران فارسی زبان برای آموزش و ارزیابی مدل پیشنهادی خود بهره بردیم، این داده‌ها شامل نظر متنی کاربران به همراه امتیاز احساسی تخصیص داده شده به هر نظر است. این اطلاعات در سایت kaggle در دسترس است و نظرات کاربران مربوط به محصولات مختلف در فروشگاه‌های اینترنتی متفاوت مانند دیجیکالا^۱ و کتاب‌های فروشگاه طاقچه^۲ و همچنین نظرات پراکنده‌ی کاربران فارسی زبان در شبکه اجتماعی توییتر^۳ است. مجموعه‌ی داده‌ی طاقچه حدود ۳۶,۰۰۰ نظر را برای مدل پیشنهادی فراهم کرده و نمره نظرات از ۰ تا ۵ دسته‌بندی شده بود که از ۰ تا ۲ به عنوان نظر منفی، و از ۳ تا ۵ به عنوان نظر مثبت تعیین شده‌اند. مجموعه‌ی داده‌ی دیجیکالا حدود ۲۰۰۰ نظر را فراهم کرد و نمره نظرات از ۰ تا ۱۰۰ دسته‌بندی شده بود که از ۰ تا ۶۵ نظرات منفی و از ۶۵ تا ۱۰۰ نظر مثبت تعیین شدند. مجموعه‌ی داده‌ی توییتر نیز حدود ۲۰۰۰ نظر فراهم کرد که داده‌های مثبت و منفی برچسب گذاری شده بودند.

۵-۳- بحث و تفسیر نتایج

نتایج به شرح جدول‌های ۲، ۳ و ۴ است. با توجه به نتایج بدست آمده، می‌بینیم که مدل پیشنهادی در برخی از معیارها و مجموعه داده‌ها بهبود عملکرد داشته است. به عنوان مثال مدل پیشنهادی با مجموعه داده‌ی طاقچه، در مقایسه با مدل‌های دیگر، عملکرد قابل توجهی را نشان می‌دهد. دقت مدل پیشنهادی ۵۲,۰۸۸٪ است که نسبت به مدل‌های SAE-LSTM و Transformer-BiLSTM-CNN با دقت به ترتیب ۵۰,۳۶۸٪ و ۵۰٪ بهبود یافته است. علاوه بر این، صحت مدل پیشنهادی ۵۲,۱۰۵٪ است، که در مقایسه با صحت مدل SAE-LSTM با صحت ۵۰,۲۰۶٪ بهبود یافته است. مدل Transformer-BiLSTM-CNN با صحت ۷۵٪ بهترین عملکرد را در این معیار دارد، اما دقت و یادآوری پایین‌تر آن، نشان‌دهنده


ناپایداری عملکرد کلی این مدل است. مدل پیشنهادی با امتیاز F1 برابر با ۵۲٪، عملکرد متعادلی را ارائه می‌دهد، که در مقایسه با مدل SAE-LSTM با امتیاز F1 برابر با ۶۵,۱۹۹٪ و مدل CNN با امتیاز F1 برابر با ۶۶,۷۱٪، نیاز به بهبود در برخی زمینه‌ها دارد اما نسبت به مدل Transformer-BiLSTM-CNN با امتیاز F1 ۳۳,۳۳٪ بهبود یافته است. در نهایت، مدل SAE-LSTM با یادآوری ۹۲,۹۵۸٪ بهترین عملکرد را در این معیار نشان می‌دهد، در حالی که مدل پیشنهادی با یادآوری ۵۲,۰۸۸٪ نیاز به بهبود در این زمینه دارد اما به نسبت مدل Transformer-BiLSTM-CNN با یادآوری ۵۰٪ بهبود یافته است. مدل پیشنهادی با مجموعه داده‌ی دیجیکالا، در مقایسه با مدل‌های دیگر، عملکرد متعادلی را نشان می‌دهد. دقت این مدل ۵۰,۲۶۱٪ است که در مقایسه با مدل SAE-LSTM با دقت ۵۲,۳۵۶٪، ضعیف‌تر است اما نسبت به مدل CNN با دقت ۴۷,۶۴٪ بهبود یافته است. مدل Transformer-BiLSTM-CNN با دقت ۶۰,۲۱٪ بهترین عملکرد را در این معیار دارد. صحت مدل پیشنهادی ۵۰,۲۵۹٪ است، که در مقایسه با صحت مدل SAE-LSTM ۵۴,۹۴۶٪، پایین‌تر است اما نسبت به مدل CNN با صحت ۴۷,۸۷٪ بهبود یافته است. مدل Transformer-BiLSTM-CNN با صحت ۶۰,۵۵٪ همچنان بهترین عملکرد را دارد. از نظر امتیاز F1، مدل پیشنهادی با امتیاز ۵۰,۲۵۹٪ عملکرد بهتر از مدل‌های SAE-LSTM و CNN با امتیازهای به ترتیب ۴۵,۷۹۷٪ و ۴۷,۳۷٪ دارد. مدل Transformer-BiLSTM-CNN با امتیاز F1 برابر با ۵۹,۸۳٪ بهترین عملکرد را در این زمینه دارد. در نهایت، از نظر یادآوری، مدل پیشنهادی با یادآوری ۵۰,۲۶۱٪ عملکردی بهتر از مدل CNN با یادآوری ۴۶,۸۸٪ دارد، اما نسبت به مدل‌های SAE-LSTM و Transformer-BiLSTM-CNN با یادآوری‌های به ترتیب ۵۲,۳۵۶٪ و ۶۰,۲۱٪، ضعیف‌تر عمل می‌کند. مدل پیشنهادی با مجموعه داده‌ی توییتر، در مقایسه با سایر مدل‌ها عملکرد متوسطی از خود نشان می‌دهد. دقت این مدل ۵۶,۲۸۱٪ است که در مقایسه با مدل SAE-LSTM با دقت ۴۹,۷۴۸٪، بهبود یافته است، اما نسبت به مدل Transformer-BiLSTM-CNN با دقت ۶۱,۳۱٪ و مدل CNN با دقت ۶۳,۸۲٪، ضعیف‌تر است. صحت مدل پیشنهادی ۵۶,۳۲۸٪ است که نسبت به صحت مدل SAE-LSTM با ۷۵٪ و مدل‌های Transformer-BiLSTM-CNN و CNN با صحت‌های به ترتیب ۶۱,۷۰٪ و ۶۶,۲۷٪، ضعیف‌تر است. از نظر امتیاز F1، مدل پیشنهادی با امتیاز ۵۶,۲۳۴٪ عملکرد بهتری نسبت به مدل SAE-LSTM با

³ <https://www.kaggle.com/datasets/mohammadalimkh/persian-twitter-dataset-sentiment-analysis>

¹ <https://www.kaggle.com/datasets/soheiltehranipour/digikala-comments-persian-sentiment-analysis>

² <https://www.kaggle.com/datasets/armitaraz/datasettaghcheccleaned/data>

بهبودها ناشی از استفاده از تکنیک‌های مختلف در پیش‌پردازش داده‌ها، استخراج ویژگی‌ها و ترکیب مدل‌های مختلف است که هر کدام از این مدل‌ها مزایای خاص خود را در بهبود دقت و صحت مدل به ارمغان می‌آورند.



شکل ۶. ماتریس سردرگمی مدل پیشنهادی

جدول ۲ نتایج روش پیشنهادی با مجموعه داده‌ی طاقچه

مدل	امتیاز F1	دقت	صحت	یادآوری
مدل پیشنهادی	۵۲٪	۵۲٫۰۸۸٪	۵۲٫۱۰۵٪	۵۲٫۰۸۸٪
Transformer-BiLSTM-CNN	۳۳٫۳۳٪	۵۰٪	۷۵٪	۵۰٪
SAE-LSTM	۶۵٫۱۹۹٪	۵۰٫۳۶۸٪	۵۰٫۲۰۶٪	۹۲٫۹۵۸٪
CNN	۶۶٫۷۱٪	۶۹٫۳۱٪	۷۲٫۹۳٪	۶۱٫۴۶٪

جدول ۳ نتایج روش پیشنهادی با مجموعه داده‌ی دیجیکالا

مدل	امتیاز F1	دقت	صحت	یادآوری
مدل پیشنهادی	۵۰٫۲۵۹٪	۵۰٫۲۶۱٪	۵۰٫۲۵۹٪	۵۰٫۲۶۱٪
Transformer-BiLSTM-CNN	۵۹٫۸۳٪	۶۰٫۲۱٪	۶۰٫۵۵٪	۶۰٫۲۱٪
SAE-LSTM	۴۵٫۷۹۷٪	۵۲٫۳۵۶٪	۵۴٫۹۴۶٪	۵۲٫۳۵۶٪
CNN	۴۷٫۳۷٪	۴۷٫۶۴٪	۴۷٫۸۷٪	۴۶٫۸۸٪

جدول ۴ نتایج روش پیشنهادی با مجموعه داده‌ی توییتر

مدل	امتیاز F1	دقت	صحت	یادآوری
مدل پیشنهادی	۵۶٫۲۳۴٪	۵۶٫۲۸۱٪	۵۶٫۳۲۸٪	۵۶٫۲۸۱٪
Transformer-BiLSTM-CNN	۶۰٫۹۳٪	۶۱٫۳۱٪	۶۱٫۷۰٪	۶۱٫۳۱٪
SAE-LSTM	۳۳٫۰۵۴٪	۴۹٫۷۴۸٪	۷۵٪	۴۹٫۷۴۸٪
CNN	۶۰٫۴۴٪	۶۳٫۸۲٪	۶۶٫۲۷٪	۵۵٫۵۶٪

امتیاز ۳۳٫۰۵۴٪ دارد، اما نسبت به مدل‌های Transformer-BiLSTM-CNN و CNN با امتیازهای به ترتیب ۶۰٫۹۳٪ و ۶۰٫۴۴٪، عملکرد ضعیف‌تری دارد. در نهایت، از نظر یادآوری، مدل پیشنهادی با یادآوری ۵۶٫۲۸۱٪ عملکرد بهتری نسبت به مدل SAE-LSTM و CNN با یادآوری‌های به ترتیب ۴۹٫۷۴۸٪ و ۵۵٫۵۶٪ دارد، اما نسبت به مدل Transformer-BiLSTM-CNN با یادآوری ۶۱٫۳۱٪، ضعیف‌تر عمل می‌کند.

۴-۵- بررسی ماتریس سردرگمی مدل

شکل ۶، ماتریس سردرگمی مدل پیشنهادی را نمایش می‌دهد. تعداد نمونه‌های مثبت واقعی که به درستی به عنوان مثبت پیش‌بینی شده‌اند، برابر با ۱۰۶۷ است. این مقدار نشان‌دهنده توانایی مدل در شناسایی صحیح نمونه‌های مثبت است. تعداد نمونه‌های منفی واقعی که به درستی به عنوان منفی پیش‌بینی شده‌اند، برابر با ۸۱۸ است. این مقدار نشان‌دهنده توانایی مدل در شناسایی صحیح نمونه‌های منفی است. تعداد نمونه‌های منفی واقعی که به اشتباه به عنوان مثبت پیش‌بینی شده‌اند، برابر با ۱۰۱۳ است. این مقدار نشان‌دهنده تعداد پیش‌بینی‌های نادرست مثبت است که مدل انجام داده است و ضعف عملکرد دقت مدل پیشنهادی را نمایان می‌کند. تعداد نمونه‌های مثبت واقعی که به اشتباه به عنوان منفی پیش‌بینی شده‌اند، برابر با ۷۶۵ است. این مقدار نشان‌دهنده تعداد پیش‌بینی‌های نادرست منفی است که مدل انجام داده است و ضعف عملکرد معیار یادآوری مدل پیشنهادی را نمایان می‌کند. به طور کلی، مدل در پیش‌بینی کلاس منفی و کلاس مثبت به صورت نابرابر عمل کرده است. مدل تعداد بیشتری از نمونه‌های مثبت را به درستی شناسایی می‌کند، اما در شناسایی نمونه‌های منفی ناتوان بوده است. این مشکلات ممکن است به دلیل پیچیدگی الگوهای داده‌ها باشد.

۵-۵- بررسی پرسش‌های پژوهش

در اینجا به بررسی پرسش‌های پژوهش می‌پردازیم.

(۱) سوال اول: چگونه با ترکیب مدل‌های یادگیری عمیق، عملکرد وظیفه تحلیل احساسات را در متن‌های فارسی بهبود دهیم؟

(۲) نتایج به دست آمده نشان می‌دهند که با ترکیب مدل‌های مختلف یادگیری عمیق مانند CNN، BiLSTM، و تبدیل‌کننده می‌توان عملکرد تحلیل احساسات را بهبود بخشید. مدل پیشنهادی در برخی موارد مانند مجموعه داده‌های طاقچه و توییتر عملکرد بهتری نسبت به مدل‌های دیگر داشته است. این

۳ سوال دوم: چگونه می‌توان با بکارگیری مدل‌های بسیار عمیق باعث بهبود استخراج ویژگی‌ها در وظیفه تحلیل احساسات شد؟

استفاده از مدل‌های بسیار عمیق مانند SAE-LSTM و Transformer-BiLSTM-CNN نشان داده که می‌توان ویژگی‌های متنی پیچیده‌تری را استخراج کرد که در نتیجه به بهبود دقت و صحت مدل‌ها کمک می‌کند. با این حال، مدل پیشنهادی نیز با استفاده از تکنیک‌های مختلف و ترکیب مدل‌ها توانسته است در برخی معیارها عملکرد بهتری داشته باشد. به عنوان مثال، مدل پیشنهادی در مجموعه داده‌های طاقچه نسبت به مدل‌های دیگر بهبود عملکرد در دقت و صحت نشان داده است. این نتایج نشان می‌دهند که استفاده از مدل‌های عمیق‌تر و تکنیک‌های پیشرفته‌تر در استخراج ویژگی‌ها می‌تواند بهبود عملکرد را به همراه داشته باشد.

۶- نتیجه‌گیری

در این پژوهش، مشکل اصلی تحلیل احساسات متنی در زبان فارسی بررسی شد که شامل چالش‌هایی نظیر پیچیدگی ساختار زبان، داده‌های کم‌منبع، و عدم تطبیق کامل مدل‌های موجود با ویژگی‌های زبانی و معنایی متن فارسی بود. این مشکلات انگیزه اصلی طراحی و ارائه یک مدل ترکیبی نوآورانه شد که با بهره‌گیری از معماری‌های پیشرفته یادگیری عمیق و تکنیک‌های پیش‌پردازش، بهبود قابل توجهی در دقت و کارایی تحلیل احساسات ارائه دهد. روش پیشنهادی با ترکیب مدل‌های Transformer-BiLSTM-CNN به منظور طبقه‌بندی احساسات و استفاده از SAE به منظور استخراج و کاهش ابعاد ویژگی‌ها طراحی شد. همچنین، ParsBERT برای پیش‌پردازش متن فارسی و تولید جاسازی‌های معنایی دقیق استفاده شد. مدل پیشنهادی توانست نقاط ضعف مدل‌های پیشین، مانند ناکارآمدی در تحلیل متون طولانی و محدودیت‌های منابع محاسباتی، را کاهش دهد و عملکرد بهتری نسبت به روش‌های دیگر نظیر SAE-LSTM، Transformer-BiLSTM-CNN و ارائه دهد. نتایج ارزیابی نشان داد که مدل پیشنهادی در معیارهایی نظیر دقت، F1-Score، صحت و یادآوری، عملکرد بالاتری نسبت به مدل‌های موجود دارد. همچنین، توانایی این مدل در تحلیل جملات طولانی و پیچیده فارسی، آن را برای استفاده در کاربردهای واقعی مناسب ساخته است. استفاده از SAE نیز به کاهش نیاز به منابع محاسباتی و افزایش کارایی منجر شده است. با وجود موفقیت‌های حاصل شده، این پژوهش همچنان با

محدودیت‌هایی همراه است. برای مثال مدل پیشنهادی برای تحلیل احساسات چندکلاسه هنوز نیاز به بهینه‌سازی بیشتری دارد. منابع محاسباتی مورد نیاز برای آموزش مدل‌های پیش‌آموزش‌دیده نظیر ParsBERT همچنان چالشی برای محیط‌های محدود به منابع است. داده‌های موجود برای زبان فارسی در مقایسه با زبان‌های دیگر همچنان کم‌تنوع هستند که می‌تواند عملکرد مدل را در کاربردهای خاص محدود کند. استفاده از مدل SAE برای استخراج ویژگی در حوزه تحلیل احساسات متنی بسیار جدید است و منابع محدودی در این زمینه موجود است.

در آینده، می‌توان پژوهش را به چندین جهت گسترش داد:

(۱) می‌توان برای بهبود عملکرد SAE، تعداد لایه‌های رمزگذار و رمزگشا را کاهش و یا افزایش داد. این لایه‌های رمزگذار، داده‌های متنی را رمزگذاری می‌کند و سپس با رمزگشایی از آن، ویژگی‌های مهم را استخراج کرد اما بسته به نوع داده‌ها و ویژگی‌های مهم، می‌توان تعداد لایه‌های رمزگذار و رمزگشا را تغییر داد تا متناسب با داده‌های ورودی، عملکرد بهتری در زمینه استخراج ویژگی داشته باشد.

(۲) می‌توان با استفاده از تکنیک‌هایی مانند خراش دادن مرورگر^۱ و خزیدن در مرورگر^۲ داده‌های متنوع و دست اول آورد و با استفاده از تکنیک‌های داده‌کاوی، داده‌ها را آماده‌ی استفاده در مدل پیشنهادی کرد.

(۳) این پژوهش برای بررسی و بهبود مدل‌های مشابه مورد استفاده قرار گرفت. این مدل پیشنهادی می‌تواند در یک پروژه‌ی کاربردی مورد استفاده قرار گیرد و وظیفه‌ی افکارسنجی را از کاربران فارسی زبان شبکه‌های اجتماعی، حول محور موضوعات اجتماعی، سیاسی و اقتصادی انجام دهد؛ تا این مدل، یک محک عملی هم ببیند.

مراجع

- [1] S. Tam, R. BenSaid and Ö. Ö. Tanrıöver, "A ConvBiLSTM Deep Learning Model-Based Approach for Twitter Sentiment Classification," IEEE Access, vol. 9, Mar. 2021
- [2] F. Huang, X. Li, C. Yuan, S. Zhang, J. Zhang and S. Qiao, "Attention-Emotion-Enhanced Convolutional LSTM for Sentiment Analysis," IEEE Transactions on Neural Networks and Learning Systems, vol. 33, Sept. 2022
- [3] L. Zhang, S. Wang and B. Liu, "Deep learning for sentiment analysis: A survey," wires data mining and knowledge discovery, vol. 8, Aug. 2018

² Web Crawler

¹ Web Scraping

- Learning Based Sentiment Classification Toward ChatGPT on Twitter," *IEEE Access*, vol. 11, Sept. 2023
- [15] I. Carvalho, H. G. Oliveira and C. Silva, "The Importance of Context for Sentiment Analysis in Dialogues," *IEEE Access*, vol. 11, Aug. 2023
- [16] K. L. Tan, C. P. Lee, K. M. Lim and K. S. M. Anbananthen, "Sentiment Analysis With Ensemble Hybrid Deep Learning Model," *IEEE Access*, vol. 10, Sept. 2022
- [17] K. L. Tan, C. P. Lee, K. S. M. Anbananthen and K. M. Lim, "RoBERTa-LSTM: A Hybrid Model for Sentiment Analysis With Transformer and Recurrent Neural Network," *IEEE Access*, vol. 10, Feb. 2022
- [18] S. Seo, C. Kim, H. Kim, K. Mo, P. Kang, "Comparative Study of Deep Learning-Based Sentiment Classification," *IEEE Access*, vol. 8, Jan. 2020
- [19] N. Jin, J. Wu, X. Ma, K. Yan and Y. Mo, "Multi-Task Learning Model Based on Multi-Scale CNN and LSTM for Sentiment Classification," *IEEE Access*, vol. 8, Apr. 2020
- [20] R. Zeng, H. Liu, S. Peng, L. Cao, A. Yang, C. Zong and G. Zhou, "CNN-Based Broad Learning for Cross-Domain Emotion Classification," *Tsinghua Science and Technology*, vol. 28, Apr. 2023
- [21] I. K. S. Al-Tameemi, M. R. F. Derakhshi, S. Pashazadeh and M. AssadPour, "Interpretable Multimodal Sentiment Classification Using Deep Multi-View Attentive Network of Image and Text Data," *IEEE Access*, vol. 11, Aug. 2023
- [22] X. L. Leng, X. A. Miao, and T. Liu, "Using recurrent neural network structure with Enhanced Multi-Head Self-Attention for sentiment analysis," *Multimedia Tools and Applications*, vol. 80, Jan. 2021
- [23] M. R. R. Rana, A. Nawaz, T. Ali, A. S. Alattas and D. S. Abdelminaam, "Sentiment Analysis of Product Reviews Using Transformer Enhanced 1D-CNN and BiLSTM," *Cybernetics and Information Technologies*, vol. 24, Sept. 2024
- [24] B. Yosra and M. Hakim, "Enhancing Twitter Sentiment Analysis Using Hybrid Transformer and Sequence Models," *Japan Journal of Research*, vol. 6, Oct. 2024.
- [4] M. Dong, Y. Li, X. Tang, J. Xu, S. Bi and Y. Cai, "Variable Convolution and Pooling Convolutional Neural Network for Text Sentiment Classification," *IEEE Access*, vol. 8, Jan. 2020
- [5] L. Yue, W. Chen, X. Li, W. Zuo and M. Yin, "A survey of sentiment analysis in social media," *Knowledge and Information Systems*, vol. 60, July. 2018
- [6] M. Shukla and A. Kumar, "An Experimental Analysis of Deep Neural Network Based Classifiers for Sentiment Analysis Task," *IEEE Access*, vol. 11, Apr. 2023
- [7] M. Birjali, M. Kasri and A. B. Hssane, "A comprehensive survey on sentiment analysis: Approaches, challenges and trends," *Knowledge-Based Systems*, vol. 226, Aug. 2021
- [8] M. U. Salur and I. Aydin, "A Novel Hybrid Deep Learning Model for Sentiment Classification," *IEEE Access*, vol. 8, Mar. 2020
- [9] D. W. O. Otter, J. R. Medina and J. K. Kalita, "A Survey of the Usages of Deep Learning for Natural Language Processing," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 32, Apr. 2020
- [10] F. A. Acheampong, H. N. Mensah and W. Chen, "Transformer models for text-based emotion detection: a review of BERT-based approaches," *Artificial Intelligence Review*, vol. 54, Feb. 2021
- [11] K. Berahmand, F. Daneshfar, E. S. Salehi, Y. Li and Y. Xu, "Autoencoders and their applications in machine learning: a survey," *Artificial Intelligence Review*, vol. 57, Feb. 2024
- [12] I. Kanwal, F. Wahid, S. Ali, A. UrRehman, A. Alkhayyat and A. Al-Radaei, "Sentiment Analysis Using Hybrid Model of Stacked Auto-Encoder-Based Feature Extraction and Long Short Term Memory-Based Classification Approach," *IEEE Access*, vol. 11, Sept. 2023
- [13] G. M. Shafiq, T. Hamza, M. F. Alrahmawy and R. El-Deeb, "Enhancing Arabic Aspect-Based Sentiment Analysis Using End-to-End Model," *IEEE Access*, vol. 11, Dec. 2023
- [14] M. Aljebreen, B. Alabdullah, M. M. Asiri, A. S. Salama, M. Assiri and S. S. Ibrahim, "Moth Flame Optimization With Hybrid Deep

Developing a Persian Sentiment Analysis Dataset for Social Media Texts

Parisa Mohamadi Kalkhoran¹, Mojgan Farhoodi^{2,*}

¹ IT Faculty, ICT Research Institute (ITRC), Tehran, Iran

² IT Faculty, ICT Research Institute (ITRC), Tehran, Iran

Received: 03 May 2024, Revised: 15 March 2025, Accepted: 29 March 2025

Paper type: Research

Abstract

This paper presents a Persian dataset for sentiment analysis of texts published on social media. The dataset creation process involved several key stages: First, a comprehensive methodology was developed for data collection and labeling. Next, data was extracted from the Twitter platform using keyword-based methods, hashtags, and high-engagement accounts. During the preprocessing stage, irrelevant data and textual noise were removed and corrected. The data labeling process was conducted manually through a crowdsourcing platform, where each tweet was labeled by three annotators, and the final label was determined based on majority voting. To ensure quality control, a calibrated dataset was prepared, and inter-annotator agreement was evaluated. The final dataset consists of over 5,000 tweets labeled as positive, negative, or neutral. Based on the results obtained from applying various models to this dataset, it can be concluded that this dataset serves as a reliable resource for developing and evaluating sentiment analysis models in the Persian language.

Keywords: Sentiment Analysis, Social Media, Twitter, Persian Dataset, Text Processing, Data Labeling

* Corresponding Author's email: farhoodi@itrc.ac.ir

سال هفدهم، شماره ۶۵، مهر ۱۴۰۴، شماره ویژه «هوش مصنوعی و تحلیل داده»، صفحه ۶۲ الی ۷۲

ایجاد مجموعه دادگان فارسی تحلیل احساس در متون منتشر شده در شبکه‌های اجتماعی

پریسا محمدی کلخوران^۱، مژگان فرهودی^{*۲}

^۱ پژوهشگر پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

^۲ عضو هیات علمی پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۲/۱۴ تاریخ بازبینی: ۱۴۰۳/۱۲/۲۵ تاریخ پذیرش: ۱۴۰۴/۰۱/۰۹

نوع مقاله: پژوهشی

چکیده


در این پژوهش، یک مجموعه دادگان فارسی برای تحلیل احساسات در متون منتشر شده در شبکه‌های اجتماعی تهیه شده است. فرآیند تهیه دادگان شامل چندین مرحله اساسی بوده است: ابتدا، یک شیوه‌نامه جامع برای جمع‌آوری و برچسب‌گذاری داده‌ها تدوین شد. سپس، داده‌ها از پلتفرم توییتر با استفاده از روش‌های مبتنی بر کلمات کلیدی، هشتک‌ها و اکانت‌های پرمخاطب استخراج گردید. در مرحله پیش‌پردازش، داده‌های نامرتب و نویزهای متنی حذف و اصلاح شدند. فرآیند برچسب‌گذاری داده‌ها به‌صورت انسانی و از طریق یک بستر جمع‌سپاری انجام شد، که طی آن هر توییت توسط سه نفر برچسب‌گذاری شد و برچسب نهایی بر اساس رأی اکثریت تعیین گردید. به‌منظور کنترل کیفیت، یک مجموعه داده کالیبره تهیه شد و میزان توافق بین برچسب‌گذاران مورد بررسی قرار گرفت. در نهایت، دادگان نهایی شامل بیش از ۵۰۰۰ توییت با برچسب‌های مثبت، منفی و خنثی آماده گردید. با توجه به نتایج حاصله از اعمال چندین مدل مختلف بر روی این مجموعه می‌توان گفت که این مجموعه داده می‌تواند به‌عنوان یک منبع معتبر برای توسعه و ارزیابی مدل‌های تحلیل احساسات در زبان فارسی مورد استفاده قرار گیرد.

کلیدواژگان: تحلیل احساسات، شبکه‌های اجتماعی، توییتر، مجموعه داده فارسی، پردازش متن، برچسب‌زنی داده‌ها.

* رایانامه نویسنده مسؤول: farhoodi@itrc.ac.ir

۱- مقدمه

سال ۲۰۱۴ به بعد، علاقه محققان به تحلیل احساسات توییتر در جهان در زمینه‌های مختلف مانند فیلم، موسیقی، ورزش، اخبار، سلامت، بازار سهام و غیره افزایش چشمگیری داشته است [۲].



شکل ۱. میزان علاقه پژوهشگران به تحلیل احساسات در شبکه اجتماعی توییتر

در ایران نیز با این که به دلیل محدودیت دسترسی، تنها ۹,۲۴ درصد از مردم از توییتر استفاده می‌کنند [۳]، اما این شبکه اجتماعی در میان اقشار مختلف کاربران ایرانی، از جمله روزمره‌نویس‌ها، دانشجویان و احزاب سیاسی پایگاه قابل توجه و تأثیرگذاری دارد (هرچند که درصد نفوذ آن کمتر از برخی شبکه‌های اجتماعی دیگر است).

با این که توییتر امکان به اشتراک‌گذاری فیلم و عکس را نیز برای کاربران فراهم کرده است، اما از آنجا که هنوز متن رایج‌ترین شکل ارتباط محسوب می‌شود [۴]، در مقاله جاری، فقط به تجزیه و تحلیل احساسات مبتنی بر متن توجه شده است.

در مقاله حاضر درصددیم تا ضمن شرح فرآیند آماده‌سازی این مجموعه دادگان، یک مطالعه مقایسه‌ای از مجموعه داده‌های موجود در زبان فارسی نیز داشته باشیم. این مقاله در ادامه شامل بخش‌های زیر است: بخش ۲ مروری مختصر است بر کارهای مشابه قبلی. بخش ۳، روال تهیه مجموعه دادگان را به تفصیل شرح می‌دهد در بخش ۴ نتایج حاصل از چندین مدل بر روی این مجموعه دادگان آورده است و در نهایت در بخش ۵ به نتیجه‌گیری و پیشنهاد فعالیت‌های آتی پرداخته خواهد شد.

۲- کارهای انجام شده

تجزیه و تحلیل احساسات یا عقیده‌کاوی فرآیندی است برای شناسایی و تشخیص یا طبقه‌بندی احساسات یا نظرات کاربران برای هرگونه خدمتی مانند فیلم، محصول، رویداد و مانند این‌ها که می‌تواند مثبت، منفی یا خنثی باشد [۱]. اولین مجموعه داده منتشر شده در زمینه تحلیل احساس به سال ۲۰۰۲ برمی‌گردد که Polarity Dataset نام دارد. این مجموعه داده براساس نظرات ۱۴۴

در سال‌های اخیر، شبکه‌های اجتماعی به بستری محبوب برای اشتراک‌گذاری افکار و نظرات مردم تبدیل شده‌اند. وبلاگ‌ها، میکروبلاگ‌ها، مجلات برخط، انجمن‌های گفتگو، فرم‌های نظرسنجی و دیگر امکانات ارتباطی مبتنی بر وب به مردم کمک می‌کنند تا احساسات خود را ابراز کرده و دیدگاه‌هایشان را در مورد موضوعات روزمره زندگی، مسائل اجتماعی، سیاسی و فرهنگی در سطح ملی و بین‌المللی با دیگران به اشتراک بگذارند. حجم گسترده و ماهیت متنوع اطلاعات متنی موجود در وب، همراه با تکامل مداوم آن، فرصتی منحصر به فرد برای مطالعه افکار عمومی و چالش‌های خاص موجود در پردازش این اطلاعات به وجود آورده است. درک و تفسیر حجم بالای داده‌های متنی منتشر شده در رسانه‌های اجتماعی، نیازمند ابزار قدرتمندی است که بتوان از بطن این متون، احساسات یا نظرات افراد را شناسایی کرده و آنها را طبقه‌بندی نمود. تجزیه و تحلیل احساسات فرایندی است که در آن، تلاش می‌شود که هیجانات، نظرات یا عواطف انسان از محتوای منتشرشده (مانند متن) به صورت خودکار شناسایی شود و کاربردهای زیادی دارد [۱]؛ از جمله کمک به تصمیم‌گیری (به عنوان مثال، برای انتخاب یک رستوران یا خرید یک محصول)، تحلیل میزان رضایت مشتری، انجام نظرسنجی و پیش‌بینی در مسائل تجاری، سیاسی و فرهنگی. روش‌های مختلفی برای تجزیه و تحلیل احساسات وجود دارد که در سال‌های اخیر روش‌های مبتنی بر یادگیری عمیق بیش از همه مورد توجه قرار گرفته‌اند که برای آموزش و آزمایش، وابسته به مجموعه داده‌ای باکیفیت هستند. با وجود آن که دادگان زبان انگلیسی در این حوزه نسبتاً غنی است، در زبان فارسی همچنان نیاز مبرمی به مجموعه داده‌های متنوع و مناسب وجود دارد، چرا که علیرغم وجود اشتراک بسیار در نحوه ابراز احساسات در میان انسان‌ها با نژادها و قومیت‌های مختلف، باید گفت که استفاده از دادگان ترجمه شده یک زبان به زبانی دیگر روش کارآمدی نیست، چرا که با توجه به فرهنگ و شرایط اجتماعی ممکن است یک واژه یا جمله در دو زبان و یا حتی در گویش‌های مختلف یک زبان، معانی متفاوت و گاه متضادی داشته باشد. با توجه به این نیاز، یکی از اهداف آزمایشگاه پارسی‌آزم در پژوهشگاه ارتباطات و فناوری اطلاعات، تهیه مجموعه داده‌ای با محوریت متون به‌دست‌آمده از رسانه‌های اجتماعی است که بتوان از آن برای توسعه و ارزیابی مدل‌های تحلیل احساس در متون فارسی استفاده کرد. در این راستا شبکه اجتماعی توییتر به عنوان منبع جمع‌آوری داده‌ها در نظر گرفته شد، چرا که توییتر با ایجاد ارتباط میان افرادی با پیشینه‌ها، فرهنگ‌ها و سنین مختلف، ارتباطات را متحول کرده است [۲]. شکل ۱ نشان می‌دهد که از

تبریک را پوشش می‌دهند [۱۹]. مجموعه داده چندوجهی MELD که در سال ۲۰۱۸ توسعه یافته، از افزایش و گسترش مجموعه داده متنی EmotionLines [۲۰] ایجاد شده است. EmotionLines شامل ۲۹۲۴۵ گفته از ۲۰۰۰ دیالوگ است که از گفتگوهای مجموعه تلویزیونی Friends و پیام‌رسان فیس‌بوک جمع‌آوری و در بستر جمع‌سپاری MTurk برچسب‌گذاری شده‌اند. MELD شامل همان نمونه گفتگوهای موجود در EmotionLines است، اما حالات صوتی و تصویری را نیز در کنار متن در بر می‌گیرد. MELD شامل بیش از ۱۴۰۰ گفتگو و ۱۳۰۰۰ گفته از گویندگان مختلف است. در هر گفتگو، هر گفتار غیر از برچسب هیجان، دارای حاشیه نویسی احساس (مثبت، منفی و خنثی) نیز هست [۲۱]. مجموعه دادگان GoEmotions، که در سال ۲۰۲۰ ارائه شده، شامل ۵۸۰۰۰ متن از شبکه اجتماعی ردیت از سال ۲۰۰۵ (شروع ردیت) تا ژانویه ۲۰۱۹ است که در ۲۷ طبقه برچسب‌گذاری شده‌اند (۱۲ طبقه مثبت، ۱۱ طبقه منفی، ۴ طبقه مبهم و یک طبقه خنثی) [۲۲]. مجموعه داده Twitter US Airline Sentiment که توسط CrowdFlower ایجاد شده است، حاوی بیش از ۱۴۰۰۰ توییت است که مشکلات شش شرکت هواپیمایی ایالات متحده را تجزیه و تحلیل می‌کند. این توییت‌ها از فوریه ۲۰۱۵ استخراج شده‌اند و دارای برچسب‌های مثبت، منفی یا خنثی هستند [۲۳].

در زبان فارسی، با توجه به منابع [۲۴] و [۳۶]، در طول سال‌های ۲۰۰۷ تا ۲۰۲۱، بیشتر مجموعه داده‌های واژگان احساسی مورد استفاده در مقالات از ترجمه مجموعه داده‌های انگلیسی به دست آمده‌اند. سایر مجموعه داده‌های متنی موجود، عمدتاً بر اساس نظرات مشتریان سایت‌ها درخصوص بررسی فیلم‌ها، محصولات فروشگاه‌های اینترنتی (بیش از همه دیجی‌کالا)، خدمات هتل، سرویس‌های سفارش غذا، فرستاده‌های شبکه‌های اجتماعی (توییتر و اینستاگرام) و نظرات مردم در آنها و تعداد محدودی بر مبنای سایت‌های خبری، سایت سازمان بورس و اوراق بهادار، اشعار فارسی و یا مجموعه داده‌های حاصل از ترجمه ماشینی یا ترجمه نظرات مشتریان در سایت‌های خرده‌فروشی آنلاین تهیه شده‌اند. از جمله این مجموعه داده‌ها می‌توان به [25] HelloKish، [26] MirasOpinion، [27] Iranian Stock Market، [28] Pars- ABSA، [29] Snappfood، [30] Digikala Sentiment، [31] JAMFA Corpus، [32] [24]، [33] SentiPers، [34] DeepSentiPers اشاره کرد. شکل ۲، مجموعه داده‌های مورد استفاده در مقالات منتشر شده طی سال‌های ۲۰۱۸ تا ۲۰۲۲ در زمینه تحلیل احساسات در زبان فارسی را نشان می‌دهد [۲۴].

کاربر در مورد فیلم‌های موجود در پایگاه اینترنتی IMDB تهیه گردیده است. داده‌های این مجموعه در سه دسته مثبت، منفی و خنثی طبقه‌بندی شده‌اند [۶]. مجموعه داده IMDB که در سال ۲۰۱۱ ارائه شد، شامل ۵۰۰۰۰ نقد فیلم انگلیسی با برچسب مثبت یا منفی است [۷]. مجموعه داده Stanford Sentiment Treebank (SST) که در سال ۲۰۱۳ منتشر شد، بر اساس نقدهای فیلم Rotten Tomatoes است و شامل ۱۰۶۶۲ جمله می‌باشد که از این میان، نیمی منفی و نیم دیگر مثبت هستند. مجموعه داده Yelp Reviews حاوی نظرات مربوط به بررسی محصولات یا خدمات ارائه شده در سایت آمازون است [۸].


هر چند شروع تحلیل احساس در شبکه‌های اجتماعی به سال‌های ابتدایی قرن ۲۱ برمی‌گردد، اما تنها با ظهور برخی رسانه‌های اجتماعی مانند توییتر، فیس‌بوک، اینستاگرام و تلگرام بود که این موضوع به طور گسترده‌ای محبوبیت پیدا کرد. یکی از اولین مجموعه داده‌ها برای تحلیل احساس در رسانه‌های اجتماعی Sentiment140 نام دارد. این مجموعه داده که توسط دانشگاه استنفورد در سال ۲۰۰۹ ارائه شد، حاوی ۱٫۶ میلیون توییت با برچسب مثبت، منفی و خنثی است که قطبیت توییت‌ها در آن، با ۰ برای منفی، ۲ برای خنثی و ۴ برای مثبت مشخص شده است [۱۴]. از ارزشمندترین مجموعه داده‌ها برای تجزیه و تحلیل احساسات، مجموعه دادگانی است که برای مسابقات SemEval تهیه شده‌اند. این مسابقات وظایف مختلفی را برای شرکت‌کنندگان مطرح می‌کنند که باید با استفاده از یک مجموعه داده مشترک انجام شوند. SemEval-2013 Task 2 [۱۵] و SemEval-2014 Task 9 [۱۶] نمونه‌هایی از مجموعه داده‌های با مقیاس بزرگ برای تجزیه و تحلیل احساسات در توییتر هستند. SemEval-2016 Task 4 [۱۷] شامل پنج زیرمسابقه مربوط به تجزیه و تحلیل احساس در توییت‌های منتشر شده در توییتر می‌باشد، در حالی که SemEval-2018 Task 1 [۱۸] با هدف طبقه‌بندی احساسات برای توییت‌ها به زبان‌های مختلف انگلیسی، عربی و اسپانیایی تهیه گردیده است. مجموعه داده RuSentiment، که در سال ۲۰۱۸ منتشر شد، شامل ۳۱۱۸۵ پست منتشر شده در شبکه اجتماعی VKontakte است که بزرگترین مجموعه داده در نوع خود برای زبان روسی می‌باشد. این مجموعه داده شامل سه دسته اصلی احساسات - مثبت، منفی و خنثی - و همچنین دو دسته اضافی است؛ که یکی از آنها دسته skip می‌باشد که شامل پست‌هایی نويزدار، پست‌های مبهم و یا پست‌هایی است که به زبان غیرروسی مانند اوکراینی منتشر شده‌اند و دسته دیگر، Speech Act نام دارد که در واقع زیرمجموعه‌ای از پست‌های مثبت است که رفتارهای رایج گفتاری مثبت مانند ابراز قدردانی، احوالپرسی و

جدول ۱: خلاصه‌ای از ویژگی‌های مجموعه داده‌های متنی فارسی مبتنی بر شبکه‌های اجتماعی

نام مجموعه داده	منبع	سال	موضوع	حجم	روش برچسب‌گذاری
Political tweets [9]	توییتر	۲۰۱۶	توییت‌های سیاسی فارسی درخصوص مذاکرات هسته‌ای	یک میلیون توییت که ۳۰۰۰ تایی آنها برچسب‌گذاری شده است	هر توییت در مقیاس ۱ تا ۵ (۱، ۲): منفی، ۳: خنثی، و ۴، ۵: احساسات مثبت (برچسب‌گذاری شده است).
Foreign-Vaccine and Homegrown Vaccine [10]	توییتر	۲۰۲۲	توییت‌های فارسی در خصوص واکسیناسیون کرونا از ۱ آوریل ۲۰۲۱ تا ۳۰ دسامبر ۲۰۲۱	دو مجموعه داده شامل به ترتیب ۴۰۰۸۳۹ و ۴۰۲۴۳۹ توئیت	برچسب‌گذاری خودکار/ سه دسته: مثبت (+۱)، منفی (-۱) و خنثی (۰)
Large-Scale Colloquial Persian 0.5 (LSCP) [11]	توییتر	۲۰۲۰	توییت‌های فارسی	۱۲۰ میلیون جمله فارسی مستخرج از ۲۷ میلیون توئیت	روش جمع‌سپاری نیمه خودکار/ برچسب قطبیت احساسات به صورت عددی بین ۰ و ۱
Insta-Text [12]	اینستاگرام	۲۰۲۰	نظرات کاربران در مورد پست‌های منتشر شده در صفحه اینستاگرام برنامه تلویزیونی «حالا خورشید»	۸۵۱۲ نظر	روش جمع‌سپاری/ سه دسته: مثبت (+۱)، منفی (-۱) و خنثی (۰)
Persian-English Code-mixed Texts [3]	توییتر	۲۰۲۱	توییت‌های ترکیبی فارسی-انگلیسی	۳۶۴۰ توییت	در این مجموعه داده از سه برچسب‌زن استفاده شده و در نهایت رای اکثریت به عنوان برچسب نهایی لحاظ شده است.
Insta-MultiDSenti [13]	اینستاگرام	۲۰۲۲	نظرات کاربران در مورد پست‌های منتشر شده در صفحه اینستاگرام برنامه تلویزیونی «حالا خورشید»	نظرات کاربران در مورد یک یا دو سلبریتی و استعدادیابی تلویزیونی عصر جدید (مجموعه آموزش شامل ۱۸۱۸۲ نمونه و مجموعه آزمون شامل ۶۷۰۲ نمونه)	داده‌ها در دو دسته برچسب‌گذاری شده‌اند: مثبت و منفی
Our dataset	توییتر	۲۰۲۳	توییت‌های فارسی از ۲۲ مارس ۲۰۲۰ تا ۲۲ مارس ۲۰۲۲	۵۲۵۳ توییت	سه دسته: مثبت (+۱)، منفی (-۱) و خنثی (۰)

Texts [۳] اشاره کرد. خلاصه‌ای از ویژگی‌های مجموعه داده‌های فارسی برگرفته از رسانه‌های اجتماعی در جدول ۱ آمده است. همان‌طور که ملاحظه می‌شود این مجموعه داده‌ها از یکی از دو شبکه اجتماعی اینستاگرام و یا توییتر استخراج شده‌اند که این دو شبکه از نظر طیف کاربران و مطالب منتشر شده در آنها فضای متفاوتی با هم دارند. تعدادی از این مجموعه‌های مورد اشاره، محدودیت موضوعی دارند (مثلاً فقط به حوزه خاصی مثل نظرات سیاسی درباره مذاکرات هسته‌ای و یا نظرات درباره واکسن‌های کرونا و یا نظرات درباره یک برنامه تلویزیونی و یا بازیگران مشهور محدود شده‌اند) و در نتیجه کاربردهای خاص‌تری دارند.

همچنین، بسیاری از این پژوهش‌ها از روش‌های برچسب‌گذاری انسانی بهره برده‌اند و لزوماً به روش‌های خودکار یا نیمه‌خودکار متکی نبوده‌اند. تفاوت کلیدی این پژوهش با مطالعات پیشین، استفاده از یک بستر بومی برای جمع‌سپاری داده‌ها و فرآیند دقیق برچسب‌گذاری انسانی است. در این پژوهش، تمامی مراحل از جمله تدوین شیوه‌نامه، آموزش برچسب‌گذاران، کنترل کیفیت و تهیه



شکل ۲: مجموعه داده‌های مورد استفاده در مقالات منتشر شده فارسی در سال‌های ۲۰۱۸ تا ۲۰۲۲ (تعداد و درصد)

در سال‌های اخیر، تمرکز بر تحلیل احساسات در رسانه‌های اجتماعی در زبان فارسی بیشتر شده است. از جمله مجموعه داده‌های مرتبط با این موضوع که شامل متون توییتر و یا اینستاگرام هستند، می‌توان به مجموعه دادگان Foreign-Vaccine and Homegrown Vaccine [10]، Insta-Text [12]، LSCP [11]، Vaccine [10]، Insta-MultiDSenti [۱۳] و مجموعه Persian-English Code-mixed

داشتند، از ادامه فرآیند حذف شدند.

- محدودیت‌های زبانی و محتوایی: توییت‌هایی که شامل زبان محاوره‌ای بیش‌ازحد، واژگان غیرمعمول یا دارای محتوای نامرتب بودند، از مجموعه داده حذف شدند. همچنین، توییت‌هایی که حاوی عبارات توهین‌آمیز یا محتوای غیراخلاقی بودند، از داده‌های برچسب‌گذاری شده کنار گذاشته شدند.

این شیوه‌نامه، مبنای اصلی برای اطمینان از دقت و صحت فرآیند برچسب‌گذاری بوده و یکی از نقاط قوت این پژوهش در مقایسه با مطالعات پیشین محسوب می‌شود.

در شیوه‌نامه تهیه شده سعی شد تا مثال‌های گوناگونی برای هر سه احساس ذکر شود تا رویکرد واحدی در مواجهه با متون متفاوت اتخاذ شود. در این شیوه‌نامه از فرد خواسته می‌شد که برای تعیین احساس توییت، به احساس کلی گوینده متن توجه کند و نه احساس وی نسبت به یک مقوله یا موجودیت خاص. براساس این دستورالعمل، در صورت مواجهه با جملات پیچیده (شامل احساسات مختلف) یا متون ترکیبی (شامل چند بند یا جمله)، احساس غالب ملاک انتخاب گزینه مناسب قرار می‌گرفت. همچنین از فرد برچسب‌زن خواسته شده بود که در انتخاب احساس، از تفسیر ذهنی و علائق و باورهای شخصی اجتناب کند و فقط بر مبنای تجزیه و تحلیل زبان مورد استفاده در متن تصمیم بگیرد. به عنوان مثال، در جمله «جنگ میلیون‌ها پناهنده ایجاد کرده است.» با توجه به متن، برچسب «منفی» را انتخاب می‌کنیم، هر چند که ممکن است نویسنده در بیان این مطلب، هیچ هیجانی نداشته باشد و قصدش فقط نقل یک خبر باشد.


۳-۲ جمع‌آوری داده‌ها

برای استخراج داده‌ها از توییت‌ها از کتابخانه SNScrape در پایتون استفاده شد. گردآوری توییت‌ها براساس دو رویکرد واژه‌محور و اکانت‌محور صورت پذیرفت. در رویکرد واژه‌محور، ابتدا ۵۰۰ کلمه که دارای بار عاطفی بودند از مجموعه Persian_NRC_EmoLex انتخاب گردید [۳۵]. این مجموعه واژگان که به اختصار به آن NRC Emotion Lexicon یا EmoLex نیز می‌گویند، شامل فهرستی از کلمات انگلیسی و ارتباط آنها با هشت هیجان اصلی (خشم، ترس، انتظار، اعتماد، تعجب، غم، شادی، انزجار) و دو احساس (منفی و مثبت) است که به صورت دستی برچسب‌گذاری شده‌اند. ترجمه این مجموعه واژگان به زبان‌های دیگر از جمله فارسی نیز موجود است. البته برای ترجمه آن از مترجم‌های ماشینی استفاده شده است و به همین دلیل برای زبان فارسی خیلی کیفیت مناسبی ندارد زیرا

داده‌های کالبره به‌گونه‌ای طراحی شده‌اند که بالاترین سطح دقت و پایایی در داده‌های برچسب‌خورده تضمین شود. این ویژگی‌ها باعث می‌شود که دادگان ارائه شده، به‌ویژه برای کاربردهای حساس در پردازش زبان طبیعی فارسی، از اعتبار بالاتری برخوردار باشد.

۳- تهیه مجموعه داده

تهیه مجموعه داده معرفی شده در این مقاله طی مراحل مختلفی ایجاد شد که در شکل ۳ نمایش داده شده است. در ادامه به شرح هریک از این مراحل پرداخته می‌شود.



شکل ۳: مراحل مختلف تهیه دادگان

۳-۱ تهیه شیوه‌نامه

به‌منظور اطمینان از کیفیت و یکپارچگی برچسب‌گذاری داده‌ها، پیش از شروع فرآیند جمع‌آوری و برچسب‌زنی، یک شیوه‌نامه جامع تدوین شد. این شیوه‌نامه شامل تعاریف دقیق از دسته‌بندی‌های احساسی، دستورالعمل‌های برچسب‌گذاری، معیارهای انتخاب داده‌ها، و نحوه برخورد با موارد مبهم بود. برخی از مهم‌ترین قواعد این شیوه‌نامه عبارت‌اند از:

- تعریف دقیق برچسب‌ها: توییت‌ها به سه دسته مثبت، منفی و خنثی تقسیم شدند. توییت‌هایی که بیانگر احساسات مثبت واضح (مانند شادی، رضایت یا قدردانی) و یا نزدیک به این موارد بودند، در دسته مثبت قرار گرفتند، در حالی که توییت‌های دارای احساسات منفی (مانند خشم، ناراحتی یا اعتراض) و یا نزدیک به این آنها در دسته منفی جای داده شدند. توییت‌های خبری، اطلاعاتی یا فاقد احساس مشخص در دسته خنثی برچسب‌گذاری شدند.
- نحوه برخورد با متون مبهم: در صورتی که یک توییت حاوی عبارات کنایه‌آمیز، طنز یا استعاره بود، برچسب‌گذاران موظف بودند براساس محتوای کلی و زمینه آن تصمیم‌گیری کنند. اگر همچنان ابهام وجود داشت، این موارد در دسته «داده‌های نامشخص» قرار می‌گرفتند و از مجموعه نهایی حذف می‌شدند.
- سیاست‌های کنترل کیفیت: هر توییت توسط سه نفر بررسی شد و برچسب نهایی براساس رأی اکثریت تعیین گردید. علاوه بر این، یک مجموعه داده کالبره برای ارزیابی دقت برچسب‌گذاران تهیه شد. برچسب‌گذارانی که دقت پایینی

حدود ۹۸۳۵ توییت استخراج گردید. در رویکرد دوم که همان رویکرد اکانت محور بود، ۴۰۰ اکانت پربازدید فارسی (در اینجا منظور اکانت‌هایی است که بیش از ۲۰۰۰۰ دنبال‌کننده دارند) به نحوی انتخاب شدند که با توجه به توضیحات صاحب اکانت در قسمت بیوگرافی، اکانت‌ها متنوع باشند؛ بدین ترتیب در بین اکانت‌های منتخب، اکانت‌های خبری و رسمی تا اکانت‌هایی که عموماً متن محاوره‌ای داشته و یا حتی سبک نوشتاری آنها ابداعی (یعنی حاوی کلمات خودساخته و یا املاهای تغییر یافته) است، وجود دارد. همچنین در انتخاب این اکانت‌ها تا حد امکان به جنسیت صاحبان آنها نیز توجه شد و سعی گردید که دادگان از این حیث نیز متعادل باشند. به این روش ۴۹۹۶ توییت، با محدودیت حداکثر ۲۰ توییت برای هر اکانت، استخراج شد.

لازم به ذکر است که در هنگام استخراج کلیه توییت‌ها، غیر از فیلتر بازه زمانی سعی شد موارد زیر نیز لحاظ شوند:

- حذف بازتوییت‌ها، توییت‌های غیرفارسی، توییت‌های غیرمتنی و توییت‌هایی که فقط یک آدرس اینترنتی یا یو.آر.آل بودند.
- حفظ نقل قول‌ها به دلیل این که حاوی اطلاعات متنی بودند.
- خلاصه‌ای از فرآیند استخراج داده‌ها در جدول ۲ آورده شده است.

جدول ۲: خلاصه‌ای از فرایند استخراج داده‌ها

تعداد توییت‌های استخراج شده	روش	رویکرد
حدود ۴۹۰۰۰ توییت (حداکثر ۲۰ توییت برای هر کلمه کلیدی)	۱- مبتنی بر کلمه کلیدی: - استفاده از ۵۰۰ کلمه کلیدی برگرفته از Persian_NRC_EmoLex در بازه زمانی ۲۱ مارس ۲۰۲۲ لغایت ۲۱ مارس ۲۰۲۳. - استفاده از بیش از ۴۰۰ کلمه (که اغلب آنها دارای احساسی مثبت بودند) با هدف ایجاد تعادل در مجموعه داده‌ها، در کل بازه زمانی ۲۱ مارس ۲۰۲۱ تا ۲۱ مارس ۲۰۲۲. ۲- مبتنی بر هشتگ: - با استفاده از جستجوی همان ۵۰۰ کلمه، این بار به صورت هشتگ، در بازه زمانی ۲۱ مارس ۲۰۲۲ تا ۲۱ مارس ۲۰۲۳. - استفاده از موضوعات پرتعداد	کلمه-محور
حدود ۵۰۰۰ توییت (حداکثر ۲۰ توییت برای هر اکانت)	استفاده از ۴۰۰ اکانت پربازدید فارسی	اکانت-محور

فارسی فراهم می‌کند و امکان نظارت دقیق بر فرایند برچسب‌زنی را میسر می‌سازد. بنابراین در این مرحله، اجزای مورد نیاز تعیین و تعریف و فرم‌های مربوط به فعالیت مزبور طراحی شدند.

۳-۴ پیش پردازش داده‌ها

این فرآیند از دو مرحله دستی و خودکار تشکیل شده است که در ادامه به شرح هریک پرداخته می‌شود:

الف) در مرحله پیش‌پردازش دستی برای افزایش کیفیت دادگان

بسیاری از واژه‌ها به درستی ترجمه نشده‌اند و یا معادل‌های فارسی آنها بار عاطفی زبان انگلیسی را ندارد. از این‌رو، در پژوهش حاضر، ۵۰۰ کلمه مذکور به صورت دستی و باتوجه به کاربردشان در زبان فارسی انتخاب شدند. از این ۵۰۰ کلمه در دو مرحله برای استخراج توییت‌ها استفاده شد. در مرحله اول، از این کلمات به عنوان یک پرس‌وجو استفاده شد؛ بدین ترتیب ۱۹۰۳۶ توییت استخراج گردید و در مرحله بعدی، از این کلمات به عنوان هشتگ استفاده شد و در هشتگ‌های مندرج در توییت‌ها فرایند جستجو انجام شد که با این روش نیز ۲۰۱۲۱ توییت استخراج گردید. در استخراج توییت‌های این دو مرحله، بازه زمانی یک ساله یعنی کل سال ۱۴۰۱ شمسی (از ۲۰۲۱/۳/۲۱ تا ۲۰۲۲/۳/۲۱) در نظر گرفته شد.

همچنین سعی شد از طریق جستجوی موضوعات داغ در فروردین ۱۴۰۲ نیز تعدادی توییت استخراج گردد که بدین ترتیب، ۹۶۸ توییت استخراج شد. همچنین برای تنوع بیشتر دادگان از جهت محتوا و بار احساسی، ۴۱۶ کلمه دیگر که اغلب آنها بار هیجانی مثبت داشتند نیز انتخاب گردید و از آنها برای جستجو به صورت هشتگ استفاده شد. به ازای جستجوی هر کلمه، حداکثر ۲۰ توییت استخراج شد و این بار محدوده زمانی کل سال ۱۴۰۰ (از ۲۰۲۰/۳/۲۱ تا ۲۰۲۱/۳/۲۱) در نظر گرفته شد. به این روش،

۳-۳ آماده‌سازی بستر جمع‌سپاری

یکی از نکات متمایز این پژوهش، استفاده از سامانه جمع‌سپاری بومی آزمایشگاه پارسی‌آزما است. در این بستر، کارهای مختلفی از جمله تعریف فعالیت برچسب‌زنی، تخصیص توییت‌ها به برچسب‌زن‌ها و درج دادگان کالبره (که جلوتر توضیح داده خواهند شد)، به صورت کاملاً شخصی‌سازی شده انجام می‌شود. بومی بودن این بستر، انعطاف و امنیت بالایی را برای گردآوری داده‌های زبانی

کارهای زیر انجام شد:

- حذف توییت‌هایی که متن آنها آنقدر کوتاه یا ناقص بود که تشخیص احساس آنها ممکن نبود.
 - حذف توییت‌های صرفاً تبلیغاتی که اطلاعات متنی ارزشمندی نداشتند.
 - حذف توییت‌هایی که صرفاً شامل هشتگ بودند.
 - حذف توییت‌هایی که به صورت بارز فاقد احساس بودند: این تصمیم به این دلیل اتخاذ شد که در مرحله اولیه جمع‌آوری داده‌ها، بخش قابل توجهی از توییت‌های استخراج‌شده، ماهیت خبری، اطلاع‌رسانی یا تبلیغاتی داشتند و در صورت باقی ماندن در دادگان، می‌توانستند باعث غلبه برچسب خنثی شوند. از آنجا که هدف اصلی این پژوهش، ایجاد مجموعه‌ای متوازن برای تحلیل احساسات در متون فارسی بود، سعی شد تا حد امکان از تسلط داده‌های خنثی بر مجموعه نهایی جلوگیری شود.
 - حذف توییت‌هایی که به لحاظ محتوایی مشکل سیاسی، اخلاقی و یا مذهبی داشتند.
 - حذف توییت‌هایی که درک احساس آنها منوط به بافت بود و یا مبهم بودند.
 - ب) در مرحله پیش پردازش خودکار، پیش از بارگذاری داده‌ها در بستر جمع‌سپاری، اقدامات زیر انجام شد:
 - حذف شکلک‌ها یا ایموجی‌ها: از آنجا که هدف این پژوهش، تحلیل بر پایه متن خام است و ایموجی‌ها (شکلک‌ها) می‌توانند نقش عاطفی قدرتمندی داشته باشند، حضور آن‌ها ممکن است الگوی زبانی را تحت تأثیر قرار دهد و منجر به تفسیر احساسی مستقیم (بدون پردازش زبانی متن) و در نهایت سوگیری یا ساده‌سازی بیش از حد شود. افزون بر این، بسیاری از ایموجی‌ها در متون فارسی ممکن است معادل واژگانی روشنی نداشته باشند یا این که در فرهنگ‌های گوناگون احساسات متفاوتی را منتقل کنند. به نظر می‌رسد که با حذف ایموجی‌ها، مدل‌های زبانی صرفاً بر پایه واژگان و عبارات نوشتاری آموزش خواهند دید و به ارزیابی دقیق‌تری خواهند رسید.
 - جایگزینی `<URL>`ها با `<URL>`
 - جایگزینی منشن‌ها با `<USERNAME@>`
 - حذف توییت‌هایی با طول کمتر از ۲۰ کاراکتر
 - حذف توییت‌های تکراری
 - حذف هشتگ‌های پایانی توییت‌ها برای پرهیز از سوگیری دادگان
- ### ۳-۵ تهیه دادگان کالیبره
- برای اطمینان از کیفیت و دقت فرآیند برچسب‌گذاری، از دادگان

- کالیبره استفاده شد. دادگان کالیبره شامل نمونه‌هایی از توییت‌ها بودند که به‌صورت دستی و با دقت بالا توسط دو خبره انتخاب و برچسب‌گذاری شدند. این نمونه‌ها به گونه‌ای انتخاب شدند که احساسات مثبت، منفی یا خنثی را به وضوح و بدون ابهام بیان می‌کردند. هدف اصلی از استفاده از دادگان کالیبره، ارزیابی عملکرد برچسب‌زن‌ها و اطمینان از این بود که برچسب‌ها با دقت و یکدستی لازم اعمال شوند.
- دادگان کالیبره از میان توییت‌های جمع‌آوری‌شده انتخاب شدند. این توییت‌ها به‌صورت دستی و با توجه به معیارهای زیر انتخاب شدند:
- وضوح احساس: توییت‌هایی که احساسات مثبت، منفی یا خنثی را به‌طور واضح و بدون ابهام بیان می‌کردند.
- تنوع موضوعی: توییت‌هایی که موضوعات مختلفی را پوشش می‌دادند تا اطمینان حاصل شود که برچسب‌زن‌ها با انواع مختلفی از متون مواجه می‌شوند.
- عدم ابهام: توییت‌هایی که حاوی طعنه، کنایه یا عبارات مبهم نبودند انتخاب شدند تا از خطا در برچسب‌گذاری جلوگیری شود.
- دادگان کالیبره که حدود ۱۰ درصد کل دادگان بودند، به‌صورت تصادفی در میان داده‌های اصلی قرار داده شدند. هر توییت توسط سه برچسب‌زن بررسی شد، و در طول فرآیند برچسب‌گذاری، عملکرد برچسب‌زن‌ها به‌صورت مداوم از طریق این نمونه‌های کالیبره ارزیابی می‌شد. اگر دقت برچسب‌زنی یک فرد در نمونه‌های کالیبره کمتر از ۷۰٪ بود، سیستم به‌صورت خودکار آن فرد را از فرآیند برچسب‌گذاری حذف می‌کرد و کارهای قبلی او به فرد دیگری واگذار می‌شد. این مکانیزم کنترل کیفیت، اطمینان حاصل کرد که برچسب‌زن‌ها با دقت و یکدستی لازم کار خود را انجام می‌دهند.
- استفاده از دادگان کالیبره چندین مزیت مهم داشت:
- ارزیابی عملکرد برچسب‌زن‌ها: دادگان کالیبره به‌عنوان معیاری برای ارزیابی دقت و قابلیت اطمینان برچسب‌زن‌ها عمل کردند. این امر به شناسایی برچسب‌زن‌هایی که عملکرد ضعیفی داشتند کمک کرد و اطمینان داد که تنها برچسب‌زن‌های دقیق و قابل اعتماد در فرآیند برچسب‌گذاری مشارکت داشته‌اند.
- شناسایی و اصلاح خطاها: با استفاده از دادگان کالیبره، خطاهای احتمالی در مراحل اولیه فرآیند برچسب‌گذاری شناسایی و اصلاح شدند. این موضوع به کاهش خطاهای سیستماتیک و افزایش کیفیت مجموعه دادگان نهایی کمک کرد.
- افزایش اعتبار مجموعه دادگان: استفاده از دادگان کالیبره و مکانیزم کنترل کیفیت مبتنی بر آن، اعتبار مجموعه دادگان نهایی را افزایش داد. این مجموعه دادگان اکنون می‌تواند به‌عنوان منبعی معتبر برای توسعه و ارزیابی مدل‌های تحلیل احساسات در زبان

کاهش هزینه‌ها، در صورت کسب دو رای یکسان، توییت از دسترسی دیگران خارج شد و نیازی به رای سوم نبود.

۳-۹ آماده‌سازی مجموعه دادگان نهایی


پس از مرحله جمع و کنار گذاشتن داده‌هایی که حداقل یکی از برچسب‌ها به حذف آنها رای داده بودند و حذف دادگان تکراری، داده‌هایی که حائز رای اکثریت نشده بودند، به برچسب‌ها چهارمی داده شدند. برچسب بسیاری از این دادگان، پس از دریافت آرای فرد چهارم، تعیین شد و تعداد کمی از مواردی که توافقی در موردشان حاصل نشده بود، کنار گذاشته شدند. برای ارزیابی میزان توافق بین برچسب‌ها از معیار فلیس-کاپا استفاده شد و مقدار ۰,۷۲ برای آن به دست آمد. این معیار با در نظر گرفتن توافق شانس، امتیاز توافق میان برچسب‌ها را محاسبه می‌کند.

به این ترتیب، مجموعه دادگان نهایی تحلیل احساس شامل ۵۲۵۳ توییت برچسب خورده است. این مجموعه در قالب CSV ذخیره شده و شامل ستون‌های شناسه توییت (id)، متن پردازش شده توییت (tweet)، نشانی وب (URL) هر توییت و سه ستون Negative، Positive و Neutral است که برچسب هر توییت، با مقدار ۱ در ستون مربوطه مشخص شده است.

توزیع برچسب‌ها در مجموعه داده نهایی به صورت جدول ۳ می‌باشد. همان‌طور که در جدول مشاهده می‌شود، تعداد دادگان خنثی در مقایسه با دو طبقه دیگر بسیار کمتر است و دلیل آن این است که بسیاری از دادگان فاقد احساس در مرحله پیش‌پردازش حذف شده بودند. شکل ۴ ابر کلمات مربوط به این مجموعه دادگان را نشان می‌دهد.

جدول ۳: توزیع دادگان در مجموعه دادگان ایجاد شده

برچسب	مثبت	منفی	خنثی
تعداد توییت‌ها در دسته	۱۹۴۸	۳۰۲۱	۲۸۴
درصد توییت‌ها در دسته	۳۶,۲	۵۵,۲	۸,۶
تعداد کل کلمات در دسته	۵۵۰۸۳	۹۶۵۱۲	۷۸۷۶



شکل ۴: ابر کلمات دادگان در مجموعه نهایی. تعداد کل کلمات

منحصر به فرد: ۲۰۳۶۰

فارسی مورد استفاده قرار گیرد.

در نهایت، دادگان کالیبره نه تنها به بهبود کیفیت برچسب‌گذاری کمک کردند، بلکه اطمینان دادند که مجموعه دادگان نهایی از دقت و قابلیت اطمینان بالایی برخوردارند. این رویکرد باعث شد که مجموعه دادگان ایجاد شده به عنوان یک منبع معتبر برای تحقیقات آینده در حوزه تحلیل احساسات در زبان فارسی مورد استفاده قرار گیرد.

۳-۶ آموزش برچسب‌ها

در فرایند برچسب‌زنی از ده نفر دعوت به همکاری شد که البته میزان مشارکت آنها متفاوت بود تعدادی از این افراد دانشجوی کارشناسی ارشد رشته زبان‌شناسی بودند و بقیه هم آشنا با حوزه زبان و ادبیات بودند. برای دستیابی به توافق بیشتر در نتایج برچسب‌زنی، ابتدا از این افراد خواسته شد که شیوه‌نامه تهیه شده را مطالعه کرده و سپس برای آشنایی با جوانب کار جلسات آموزشی متعددی به صورت حضوری یا مجازی برگزار شد. در راستای این جلسات، شیوه‌نامه مربوطه تکمیل و یا در مواردی اصلاح گردید.

۳-۷ برچسب‌گذاری دادگان

برای برچسب‌گذاری دادگان از بستر جمع‌سپاری توسعه داده شده در آزمایشگاه پارسی‌آزما استفاده گردید. سپس دادگان کالیبره به طور تصادفی در لابلای سایر داده‌ها قرار گرفت.

روند کار برچسب‌زنی در سامانه جمع‌سپاری پارسی‌آزما به این صورت بود که ابتدا متن توییت به همراه سه گزینه برای برچسب‌زنی نمایش داده می‌شد و از وی خواسته می‌شد که از طریق تجزیه و تحلیل زبان مورد استفاده در متن، بهترین گزینه مربوط به احساس نویسنده توییت را انتخاب کند. به افراد تاکید شد که توییت‌ها را براساس پیشینه و علایق خود (مثلاً فرهنگی، مذهبی) برچسب‌گذاری نکنند و فقط احساس یا هیجان نویسنده را در نظر بگیرند. ضمناً گزینه مجزایی هم در صفحه قرار داده شد تا اگر موردی نیاز به حذف داشت و یا بصورت سهوی در مرحله پیش‌پردازش حذف نشده بود، برچسب‌ها آن گزینه را انتخاب کنند.

۳-۸ جمع آوری

معیار نهایی برچسب احساس هر یک از توییت‌های موجود در مجموعه دادگان، رای اکثریت برچسب‌ها است. هر توییت توسط سه نفر برچسب‌گذاری گردید و اگر حداقل دو نفر از آنها به یک احساس خاص رای می‌دادند، آن احساس به عنوان برچسب توییت انتخاب می‌شد. برای افزایش سرعت برچسب‌گذاری و همچنین

۴- ارزیابی مجموعه دادگان

تهیه مجموعه داده بدون ارزیابی صحت و کارایی آن فاقد اصول علمی لازم برای یک پژوهش است. مجموعه دادگان تهیه شده در این پژوهش در رویداد پارسی آزما^۱ در قالب یک shared-task در اختیار تیم‌های مختلف قرار گرفت تا در یک فضای رقابتی مدل‌های بهینه ارائه کنند [37]. نتایج حاصل از مدل‌های سه تیم برتر روی دادگان تهیه شده در این مقاله در جدول ۴ آورده شده است.

جدول ۴: نتایج حاصل از اعمال مدل‌های مختلف بر روی دادگان

مدل	Word embedding	Precision	Recall	F-Score
Meta Classifier	BERT(PersPolix ² CrdiffNLP ³)	۰.۶۷	۰.۷۲	۰.۶۷
XLMLRoberta +CNN	XLMLRoberta	۰.۶	۰.۶۳	۰.۶
ALBERT	ALBERT	۰.۴۹	۰.۴۸	۰.۴۷

همانطور که در جدول ۴ هم مشخص است، بهترین نتیجه مربوط به مدل متاکلاسیفایر است که در آن از مدل BERT به گونه‌ای استفاده شده است که ابتدا با استفاده از مدل مبتنی بر BERT، text embeddings انجام گردیده و سپس پیش‌بینی‌های نهایی با استفاده از یک شبکه عصبی چندلایه یا شبکه عصبی کانولوشنال^۴ صورت گرفته شده است. علاوه بر این، از چندین طبقه‌بند در قالب مدل‌های ترکیبی استفاده شده تا از نقاط قوت مدل‌های فردی بهره‌برداری شود [38]. همچنین این تیم از مدل زبانی PersPolix که اولین مدل زبانی فارسی با تمرکز بر حوزه‌های اجتماعی-سیاسی است که برای داده‌های مکالمه‌ای و توییت‌ها طراحی شده استفاده نموده است. این مدل بر روی حدود نیم میلیون توییت فارسی آموزش داده شد که منجر به بهبود نتایج شده است.

۵- نتیجه‌گیری و کارهای آتی

عواطف انسانی پدیده‌های روانشناختی پیچیده‌ای هستند که تشخیص دقیق آنها از روی متن تقریباً غیرممکن است. آنچه در کارهای پژوهشی مربوط به تجزیه و تحلیل احساسات انجام می‌شود، در واقع تشخیص تجربه‌ای شکل گرفته از این عواطف است؛ تجربه‌ای که فرد آگاهانه آن را به زبان متن درآورده است. هنگام شناسایی احساسات از طریق رسانه‌های اجتماعی، باید بر بسیاری از مشکلات غلبه کرد. سبک نگارش غیررسمی کاربران، اشتباهات گرامری و نگارشی و همچنین زبان عامیانه، طعنه و کنایه، استفاده از زبان غیررسمی و کوتاهی طول پیام‌ها از جمله مواردی هستند که در پژوهش‌ها به آنها اشاره شده است. همچنین درک

عواطف انسانی به ویژه بر مبنای متن، امری ذهنی و مبهم است. در نتیجه استنباط و تفسیر صحیح حالات عاطفی نویسنده موضوعی چالش برانگیز است. همه این موارد باعث می‌شوند که تشخیص احساسات برای سامانه‌های خودکار امری دشوار باشد. موضوع مهم دیگر آن است که همه سامانه‌های خودکار نیازمند مجموعه داده مناسب هستند، اما به دلیل طیف گسترده موضوعات مورد بحث در رسانه‌های اجتماعی، ایجاد دستی مجموعه داده کاملی از داده‌های برجسب‌گذاری شده که شامل همه شرایط عاطفی قابل تصور باشد، دشوار است، مخصوصاً مجموعه داده‌ای که برای همه کاربردها بهینه باشد. با توجه به این چالش‌ها در پژوهش حاضر، شبکه اجتماعی توییتر که به نحوی همه پیچیدگی‌های ذکر شده را در بر می‌گیرد، برای تهیه دادگان انتخاب شد و با استفاده از بستر جمع‌سپاری که در آزمایشگاه پارسی آزما بومی‌سازی شده بود، مجموعه داده مناسبی (بدون محدودیت گستره موضوعی) حاوی بیش از ۵۰۰۰ توییت برجسب‌خورده، آماده شد.

اگرچه نتایج ارزیابی نشان‌دهنده کیفیت مناسب مجموعه دادگان است، اما محدودیت‌هایی نیز وجود دارد، مثلاً، حجم دادگان می‌تواند افزایش یابد تا مدل‌ها با داده‌های بیشتری آموزش ببینند و عملکرد بهتری داشته باشند. همچنین، در کارهای آینده می‌توان شدت احساسات (مثلاً بسیار مثبت، کمی مثبت، خنثی، کمی منفی، بسیار منفی) را نیز در نظر گرفت تا تحلیل احساسات دقیق‌تری انجام شود.

مراجع

- [1] S. Kusal, S. Patil, J. Choudrie, K. Kotecha, D. Vora, and I. Pappas, "A Review on Text-Based Emotion Detection -- Techniques, Applications, Datasets, and Future Directions." arXiv, Apr. 26, 2022. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/2205.03235>
- [2] A. Kumar and A. Jaiswal, "Systematic literature review of sentiment analysis on Twitter using soft computing techniques," *Concurrency and Computation*, vol. 32, no. 1, p. e5107, Jan. 2020, doi: 10.1002/cpe.5107.
- [3] N. Sabri, A. Edalat, and B. Bahrak, "Sentiment analysis of persian-english code-mixed texts," in 2021 26th International Computer Conference, Computer Society of Iran (CSICC), IEEE, 2021, pp. 1–4. Accessed: Oct. 15, 2023. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9420605/>
- [4] K. Sailunaz and R. Alhajj, "Emotion and sentiment analysis from Twitter text," *Journal of Computational Science*, vol. 36, p. 101003, 2019.
- [5] P. Mehta and S. Pandya, "A review on sentiment analysis methodologies, practices and applications," *International Journal of Scientific and Technology Research*, vol. 9, no. 2, pp. 601–609, 2020.
- [6] B. Pang and L. Lee, "Sentiment Polarity Dataset Version 2.0," Part of the Natural Language Tool Kit, for the Python computer language, 2002.

⁴ CNN

¹ Parsiazma.ir

² <https://huggingface.co/StateOfTheArtAUT/perspolix-persian-political-tweet-xlm-roberta-large>

³ <https://huggingface.co/cardiffnlp/twitter-xlm-roberta-base-sentiment>

- arXiv, Jun. 02, 2020. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/2005.00547>
- [23] F. Rustam, I. Ashraf, A. Mehmood, S. Ullah, and G. S. Choi, "Tweets classification on the base of sentiments for US airline companies," *Entropy*, vol. 21, no. 11, p. 1078, 2019.
 - [24] R. Asgarneshad and S. A. Monadjemi, "Persian sentiment analysis: feature engineering, datasets, and challenges," *Journal of applied intelligent systems & information sciences*, vol. 2, no. 2, pp. 1–21, 2021.
 - [25] S. Alimardani and A. Aghaie, "Opinion mining in Persian language using supervised algorithms," 2015, Accessed: Apr. 22, 2024. [Online]. Available: <https://www.sid.ir/paper/332700/en>
 - [26] S. A. A. Asli, B. Sabeti, Z. Majdabadi, P. Golazizian, R. Fahmi, and O. Momenzadeh, "Optimizing annotation effort using active learning strategies: A sentiment analysis case study in persian," in *Proceedings of the Twelfth Language Resources and Evaluation Conference*, 2020, pp. 2855–2861.
 - [27] A. Hatefi Ghahfarokhi and M. Shamsfard, "Tehran stock exchange prediction using sentiment analysis of online textual opinions," *Intell Sys Acc Fin Mgmt*, vol. 27, no. 1, pp. 22–37, Jan. 2020, doi: 10.1002/isaf.1465.
 - [28] T. S. Ataei, K. Darvishi, S. Javdan, B. Minaei-Bidgoli, and S. Eetemadi, "Pars-absa: an aspect-based sentiment analysis dataset for Persian," *arXiv preprint arXiv:1908.01815*, 2019.
 - [29] K. Darvishi, S. Javdan, B. Minaei-Bidgoli, and S. Eetemadi, "Pars-ABSA: a Manually Annotated Aspect-based Sentiment Analysis Benchmark on Farsi Product Reviews," in *Proceedings of the Thirteenth Language Resources and Evaluation Conference*, 2022, pp. 7056–7060.
 - [30] M. E. Basiri and A. Kabiri, "Words Are Important: Improving Sentiment Analysis in the Persian Language by Lexicon Refining," *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 17, no. 4, pp. 1–18, Dec. 2018, doi: 10.1145/3195633.
 - [31] A. Khodaei, A. Bastanfard, H. Saboohi, and H. Aligholizadeh, "Deep Emotion Detection Sentiment Analysis of Persian Literary Text," 2022, Accessed: Oct. 15, 2023. [Online]. Available: <https://www.researchsquare.com/article/rs-1796157/latest>
 - [32] M. Shirghasemi, M. H. Bokaei, and M. Bijankhan, "The impact of active learning algorithm on a cross-lingual model in a Persian sentiment task," in *2021 7th International Conference on Web Research (ICWR)*, IEEE, 2021, pp. 292–295. Accessed: Apr. 22, 2024. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9443156>
 - [33] P. Hosseini, A. A. Ramaki, H. Maleki, M. Anvari, and S. A. Mirroshandel, "SentiPers: A Sentiment Analysis Corpus for Persian," *arXiv*, Jan. 01, 2021. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/1801.07737>
 - [34] J. P. R. Sharami, P. A. Sarabestani, and S. A. Mirroshandel, "Deepsentipers: Novel deep learning models trained over proposed augmented persian sentiment corpus," *arXiv preprint arXiv:2004.05328*, 2020.
 - [35] S. M. Mohammad and F. Bravo-Marquez, "WASSA-2017 Shared Task on Emotion Intensity," *arXiv*, Aug. 11, 2017. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/1708.03700>
 - [36] A. Nazarizadeh, T. Banirostam, and M. Sayyadpour, "Sentiment Analysis of Persian Language: Review of Algorithms, Approaches and Datasets," *arXiv preprint arXiv:2212.06041*, 2022
 - [37] Farhoodi, M., Mahmoudi, M., & Bokaei, M. H. (2024). ParsiAzma Challenges on Persian Text Analysis in Social Media. *International Journal of Information & Communication Technology Research* (2251-6107), 16.(۳)
 - [38] Sobhi, M., & Mazochi, A. (2024). A Comparative Study of BERT-X for Sentiment Analysis and Stance Detection in Persian Social Media. *International Journal of Information & Communication Technology Research* (2251-6107), 16.(۳)
 - [7] K. Topal and G. Ozsoyoglu, "Movie review analysis: Emotion analysis of IMDb movie reviews," in *2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, IEEE, 2016, pp. 1170–1176. Accessed: Oct. 15, 2023. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7752387/>
 - [8] "Yelp." Accessed: Oct. 30, 2023. [Online]. Available: <https://www.yelp.com/dataset/challenge>
 - [9] E. Vaziripour, C. Giraud-Carrier, and D. Zappala, "Analyzing the political sentiment of tweets in Farsi," in *Proceedings of the International AAAI Conference on Web and Social Media*, 2016, pp. 699–702. Accessed: Oct. 25, 2023. [Online]. Available: <https://ojs.aaai.org/index.php/ICWSM/article/view/14791>
 - [10] Z. B. Nezhad and M. A. Deihimi, "Twitter sentiment analysis from Iran about COVID 19 vaccine," *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, vol. 16, no. 1, p. 102367, 2022.
 - [11] H. Abdi Khojasteh, E. Ansari, and M. Bohloulou, "Large-Scale Colloquial Persian 0.5," <https://iasbs.ac.ir/~ansari/lscp/>, Feb. 2020, Accessed: Oct. 25, 2023. [Online]. Available: <https://lindat.mff.cuni.cz/repository/xmlui/handle/11234/1-3195>
 - [12] M. Heidari and P. Shamsinejad, "Producing an instagram dataset for persian language sentiment analysis using crowdsourcing method," in *2020 6th International Conference on Web Research (ICWR)*, IEEE, 2020, pp. 284–287.
 - [13] M. Panahandeh Nigjeh and S. Ghanbari, "Leveraging ParsBERT for cross-domain polarity sentiment classification of Persian social media comments," *Multimedia Tools and Applications*, pp. 1–18, 2023.
 - [14] A. Go, R. Bhayani, and L. Huang, "Twitter sentiment classification using distant supervision," *CS224N project report*, Stanford, vol. 1, no. 12, p. 2009, 2009.
 - [15] H. Poursepanj, J. Weissbock, and D. Inkpen, "uOttawa: system description for SemEval 2013 task 2 sentiment analysis in twitter," in *Second Joint Conference on Lexical and Computational Semantics (* SEM)*, Volume 2: Proceedings of the Seventh International Workshop on Semantic Evaluation (SemEval 2013), 2013, pp. 380–383. Accessed: Oct. 15, 2023. [Online]. Available: <https://aclanthology.org/S13-2062.pdf>
 - [16] B. Velichkov et al., "SU-FMI: System description for SemEval-2014 task 9 on sentiment analysis in Twitter," in *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*, 2014, pp. 590–595. Accessed: Oct. 15, 2023. [Online]. Available: <https://aclanthology.org/S14-2103.pdf>
 - [17] P. Nakov, A. Ritter, S. Rosenthal, F. Sebastiani, and V. Stoyanov, "SemEval-2016 Task 4: Sentiment Analysis in Twitter." *arXiv*, Dec. 03, 2019, doi: 10.48550/arXiv.1912.01973.
 - [18] S. Mohammad, F. Bravo-Marquez, M. Salameh, and S. Kiritchenko, "Semeval-2018 task 1: Affect in tweets," in *Proceedings of the 12th international workshop on semantic evaluation*, 2018, pp. 1–17. Accessed: Oct. 15, 2023. [Online]. Available: <https://aclanthology.org/S18-1001/>
 - [19] A. Rogers, A. Romanov, A. Rumshisky, S. Volkova, M. Gronas, and A. Gribov, "RuSentiment: An enriched sentiment analysis dataset for social media in Russian," in *Proceedings of the 27th international conference on computational linguistics*, 2018, pp. 755–763. Accessed: Oct. 15, 2023. [Online]. Available: <https://aclanthology.org/C18-1064/>
 - [20] S.-Y. Chen, C.-C. Hsu, C.-C. Kuo, Ting-Hao, Huang, and L.-W. Ku, "EmotionLines: An Emotion Corpus of Multi-Party Conversations." *arXiv*, May 30, 2018. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/1802.08379>
 - [21] S. Poria, D. Hazarika, N. Majumder, G. Naik, E. Cambria, and R. Mihalcea, "MELD: A Multimodal Multi-Party Dataset for Emotion Recognition in Conversations." *arXiv*, Jun. 04, 2019. Accessed: Oct. 15, 2023. [Online]. Available: <http://arxiv.org/abs/1810.02508>
 - [22] D. Demszky, D. Movshovitz-Attias, J. Ko, A. Cowen, G. Nemade, and S. Ravi, "GoEmotions: A Dataset of Fine-Grained Emotions."

Analysis of User Reviews on Digikala Store with the Aim of Detecting Deceptive Reviews

Hosein Sarlak^{1*}, Alireza Sheikh²

¹ Master's graduate, Department of Information Technology Engineering, Amirkabir University of Technology, Tehran, Iran

² Faculty of Management, Science, and Technology, Amirkabir University of Technology, Tehran, Iran

Received: 22 August 2024 , Revised: 29 April 2025, Accepted: 02 May 2025

Paper type: Research

Abstract

The present study examines and analyzes user reviews on the Digikala store with the goal of detecting deceptive reviews. Initially, user review data were collected and pre-processed, followed by the identification of deceptive reviews using various machine learning models and large language models. The results showed that deceptive reviews were mostly written by users with lower credibility, and reviews that received more dislikes had lower credibility. Additionally, positive reviews were the most frequent, and users who left positive reviews often received more likes. This study demonstrated that using large language models and machine learning helps improve the detection of deceptive reviews, enhances the accuracy of user review monitoring systems, and better identifies valuable and influential users.

Keywords: Deceptive Reviews, Machine Learning, Large Language Models, User Review.

* Corresponding Author's email: hosein.sarlak@aut.ac.ir

تحلیل نظرات کاربران در فروشگاه دیجی کالا با هدف تشخیص نظرات فریبنده

حسین سرلک^{۱*}، علیرضا شیخ^۲

^۱ دانش آموخته کارشناسی ارشد، گروه مهندسی فناوری اطلاعات، دانشگاه صنعتی امیرکبیر (پلی تکنیک ایران)، تهران، ایران

^۲ استادیار دانشکده مدیریت، علم و فناوری، دانشگاه صنعتی امیرکبیر (پلی تکنیک ایران)، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۶/۰۱ تاریخ بازبینی: ۱۴۰۴/۰۲/۰۹ تاریخ پذیرش: ۱۴۰۴/۰۲/۱۲

نوع مقاله: پژوهشی

چکیده

کاربران معتبر، دارایی‌های ارزشمند یک پلتفرم به شمار می‌روند. پژوهش حاضر به بررسی و تحلیل نظرات کاربران در فروشگاه اینترنتی دیجی کالا با هدف تشخیص نظرات فریبنده پرداخته است. ابتدا، داده‌های نظرات کاربران جمع‌آوری و پیش‌پردازش شد و سپس با استفاده از مدل‌های مختلف یادگیری ماشین و مدل‌های زبانی بزرگ، شناسایی نظرات فریبنده صورت گرفت. نتایج نشان داد که نظرات فریبنده در بیشتر موارد، توسط کاربرانی با اعتبار پایین‌تر نوشته شده و نظراتی که تعداد دیس‌لایک^۱ بیشتری دریافت کردند، دارای اعتبار کمتری هستند. همچنین، نظرات مثبت بیشترین تعداد را دارند و کاربران با نظرات مثبت، در بیشتر مواقع لایک^۲های بیشتری دریافت می‌کنند. این پژوهش نشان داد که استفاده از مدل‌های زبانی بزرگ و یادگیری ماشین به بهبود تشخیص نظرات فریبنده و افزایش دقت سیستم‌های نظارت بر نظرات کاربران و همچنین شناسایی بهتر کاربران بارز و تأثیرگذار کمک می‌کند.

کلیدواژه‌گان: نظرات فریبنده، یادگیری ماشین، مدل‌های زبانی بزرگ، تحلیل نظرات کاربران، شبکه‌های عصبی عمیق.

* رایانامه نویسنده مسؤول: hosein.sarlak@aut.ac.ir

^۱ Dislike

^۲ Like

۱- مقدمه

امروزه، با گسترش فناوری اطلاعات در جهان و ورود سریع آن به زندگی روزمره، کسب‌وکار الکترونیکی جایگزین روش‌های سنتی شده است. مطالعات بسیاری نشان می‌دهند که در دنیای رقابتی کنونی، موفقیت شرکت‌ها وابسته به حفظ، نگهداری و ارتباط با مشتری می‌باشد (هسیائو^۱، ۲۰۰۹). به دنبال آن، دنیای بازاریابی شرایط جدیدی را تجربه کرده و در آینده نیز دستخوش تحولات بیشتری خواهد بود. علت اینکه بسیاری از شرکت‌ها در سطح جهان برای ترویج محصولات و خدمات خود به بازاریابی دهان به دهان گرایش نشان دادند، همین واقعیت است. یکی از مقرون به صرفه‌ترین، موثرترین و معتبرترین روش‌های بازاریابی مناسب برای این فضا، بازاریابی الکترونیکی به خصوص تبلیغات در شبکه‌های اجتماعی است (جعفرپیشه^۲، ۲۰۱۲). بنابراین، این روزها مشتریان به‌طور چشمگیری رفتارهایشان را همسو با فناوری و محیط اقتصادی دنیا تغییر می‌دهند. آنها حجم زیادی از اطلاعات را به دست آورده، از محصولات با خبر و با آنها آشنا شده و اعتمادشان را نسبت به تبلیغات از دست می‌دهند. محصولات و خدمات سفارشی را ترجیح داده و کانال‌های خرید خود را تغییر می‌دهند. بنابراین، کسب‌وکارها برای بقا مجبور به اصلاح یا حتی تغییر راهبردهای تبلیغاتی خود هستند تا از عهده تغییرات، حقایق و رفتارهای مشتریان برآیند (سیو^۳ و همکاران، ۲۰۱۸).

کسب‌وکار الکترونیک تعریفی گسترده‌تر و عمیق‌تری از تجارت الکترونیک دارد که نه تنها شامل خرید و فروش محصولات و خدمات می‌شود بلکه ارائه خدمات به مشتریان، مشارکت شرکای کسب‌وکار، آموزش الکترونیکی و مبادلات الکترونیکی درون سازمانی را نیز در برمی‌گیرد. نخستین بار شرکت آی.بی.ام، اصطلاح کسب‌وکار الکترونیک را به صورت زیر تعریف کرد: «رویکردی امن، انعطاف‌پذیر و یکپارچه برای دستیابی به ارزش در کسب‌وکارهای متفاوت به وسیله ایجاد ترکیبی از سیستم‌ها و فرآیندهایی که بر فعالیت اصلی کسب‌وکار با حفظ سادگی و استفاده از فناوری اینترنت استوار هستند». در شرایط کنونی یکی از مهمترین ساختارهای مربوط به کسب اطلاعات، نظرسنجی کاربران از یکدیگر است که در قدرت و اعتباربخشی به محصول و برند و یا تضعیفش نقشی کلیدی و اساسی دارد و به همین دلیل نظرات فریبنده و آسیب‌زا در این زمینه با آسیب به محصول و توسعه آن و شرایط برند همراه است که همین مسأله اهمیت پرداختن به

این موضوع را بسیار زیاد می‌کند.

با توجه به رشد روزافزون اخیر در تجارت الکترونیکی و سیستم ارائه خدمات به صورت برنامه‌های موبایلی و ارائه خدمات به صورت ارتباط کاربران با یکدیگر شناخت شرایط و مدل نظرات فریبنده بسیار مهم است. بنابراین، مدل‌سازی تشخیص نظرات در این زمینه و با هدف مقابله با این چالش به قصد رفتاری، اعتماد مشتریان و رضایت الکترونیکی مشتریان به‌ویژه در سیستم برنامه‌های موبایلی لازم و ضروری است و به توسعه و بهبود این فناوری در کشورمان کمک شایانی می‌کند. این ساختار، زمینه بهبود شرایط و محافظت از شرایط سازمان را فراهم می‌کند و منافع بسیاری برای سازمان دارد که می‌توان از آن در امر سیاست‌گذاری در این حوزه استفاده کرد. در کنار این مسأله، خلأ نظری و پژوهشی از دلایل دیگر اهمیت و ضرورت پژوهش حاضر در این حیطه است.

۲- مبانی نظری

۲-۱- نظرات برخط فریبنده

مصرف‌کننده آنلاین در عصر اقتصاد پلتفرم (یعنی شکل جدیدی از اقتصاد که از فناوری‌های دیجیتال و پلتفرم‌های اینترنتی برای هماهنگی و سازمان‌دهی منابع استفاده می‌کند) بسیار مهم است (وانا و لامبرشت، ۲۰۲۱؛ یو و همکاران، ۲۰۲۲). بررسی‌های برخط، اطلاعات ارزشمندی را برای خرید در اختیار مصرف‌کنندگان قرار می‌دهند (لی و همکاران، ۲۰۲۱؛ لی و همکاران، ۲۰۱۹). برای کسب‌وکارهای با الگوی تجارت الکترونیک، بررسی‌های برخط می‌تواند به درک بهتر نگرانی‌های مصرف‌کنندگان برای بهبود محصولات یا خدمات کمک کند (وانگ و همکاران، ۲۰۲۲). در نتیجه، بررسی‌های برخط به منبع اطلاعاتی مهمی برای مصرف‌کنندگان و کسب‌وکارهای تجارت الکترونیک تبدیل شدند (لمب و همکاران، ۲۰۲۰). بر اساس یک نظرسنجی عمومی، ۹۲٪ مصرف‌کنندگان در واقع از نظرات برخط به‌عنوان مرجع در خرید برخطشان استفاده می‌کنند و ۹۰٪ این مصرف‌کنندگان می‌گویند که نظرات مثبت، بیشتر به استفاده از یک محصول در تصمیم‌گیری‌های خرید به آنها کمک می‌کنند (ژانگ و همکاران، ۲۰۲۲). با وجود این، به دلیل عدم بررسی دقیق بررسی‌های برخط، تعداد زیادی از بررسی‌های فریبنده تولید و برای سودجویی استفاده می‌شوند و به مشکل بزرگی در عصر اقتصاد پلتفرم تبدیل شدند (پانگ و همکاران، ۲۰۲۲؛ ژوانگ و همکاران، ۲۰۱۸).

³ Cui

¹ Hsiao

² Jafarpishe

دریافت پاداش از فروشندگان و ارضای نیازهای روان شناختی خود - انگیزه درونی انجام دهند. سازوکار پاداش، انگیزه مهمی برای مصرف کنندگان برای ارسال نظرات منفی در این زمینه است (یو و همکاران، ۲۰۲۲). یک نظرسنجی از مصرف کننده نشان می دهد که پاداش های مالی مصرف کنندگان را به سمت ارسال نظرات برخط فریبده تر سوق می دهند (وو و همکاران، ۲۰۲۰) تا جایی که به نیازهای روانی مربوط می شود. اندرسون و سیمستر (۲۰۱۴)، معتقدند که گاهی بررسی های برخط فریبده برای ارضای نیازهای غیر پولی مصرف کنندگان مانند احترام از طرف گروه یا رهایی از خشم ناشی از تجربیات بد ارسال می شوند. کاربران برخط، گاهی هویت های مجازی متعددی را برای ارسال بررسی های برخط فریبده ایجاد کرده یا از هویت های جعلی برای ارسال اطلاعات همراه کننده در فضاهای مجازی برای جلب توجه دیگران استفاده می کنند (وانگ و همکاران ۲۰۱۹). مطالعات قبلی پیشنهاد می کردند که نیاز به تعامل اجتماعی، میل به انگیزه های اقتصادی و مشاوره جویی انگیزه های مهمی برای مصرف کنندگان برای نوشتن نظرات برخط هستند (کاپور و همکاران ۲۰۲۱؛ وانا و لامبرشت، ۲۰۲۱).

۲-۳- پیشینه پژوهش

لی^۲ و همکارانش [۱۴]، سعی کردند با استفاده از شبکه های عصبی کانوولوشنی (CNN)، عمل یادگیری را انجام دهند و برای تشخیص نظرات فریبده از این شبکه ها استفاده کردند. نتایجی که از این پژوهش به دست آمد نشان از کارآمدی شبکه های CNN در مسئله تشخیص نظرات فریبده داشت. رن^۳ و ژانگ^۴ (۲۰۱۶)، در مطالعه ای برای تشخیص نظرات فریبده از یادگیری در سطح سند استفاده کردند. در این مقاله، ابتدا یک سند به مدل داده می شود و با استفاده از CNN که با یک شبکه عصبی بازگشتی گیت گذاری شده^۵ ترکیب شده، جملات، ساختار آنها و نحوه نمایش آنها یادگیری می شود و بردارهای سند با این روش استخراج می شوند. سپس، این بردارها به صورت مستقیم برای یادگیری برای تشخیص نظرات فریبده استفاده می شوند. وانگ^۶ و همکارانش در سال ۲۰۱۸، مقاله ای را منتشر کردند که در آن با استفاده از شبکه های حافظه کوتاه مدت طولانی (LSTM) سعی در تشخیص نظرات داشتند. نکته قابل توجهی که در این مقاله وجود دارد این است که آنها با مقایسه روش های مختلف یادگیری ماشین و مقایسه آنها با روش های جدیدتر و مدل های یادگیری عمیق به این نتیجه رسیدند که از بین

نظرات فریبده شامل دیدگاه های همراه کننده ای هستند که با هدف تبلیغی یا ضدتبلیغ نگاشته و باعث فریفتگی در نظرکاو شده و نیز در کسب تحلیل معنایی اختلال ایجاد می کنند. در بیشتر موارد، بررسی های فریبده به تجربه های بد در خرید برخط منجر می شوند (جزیری، ۲۰۱۹؛ لمب و همکاران، ۲۰۲۰)، ضرر اقتصادی برای مصرف کنندگان برخط ایجاد می کنند و در نتیجه به اعتبار کسب و کارهای درگیر و بیشتر اقتصاد پلتفرم در کل آسیب می رسانند (ژانگ و همکاران، ۲۰۱۸). برای مثال، تحقیقات Daily Mail نشان داد که شرکت های آسیب زا در سایت آمازون^۱ نظرات فریبده ای را به خرده فروشان برخط می فروشند که میلیون ها مشتری آمازون را با تصمیم های خرید بد احتمالی در معرض خطر قرار می دهند. از آنجایی که بررسی های برخط فریبده به موضوعی فراگیر در اقتصاد پلتفرم امروزی تبدیل شدند، مطالعه بررسی های فریبده بیش از پیش توجه صنعت و دانشگاه را به خود جلب کرده است (ژانگ و همکاران، ۲۰۲۳).

۲-۲- انگیزه اثرگذار بر نظرات برخط فریبده

انگیزه بررسی های آنلاین فریبده، ناشی از ارزش تجاری آنهاست که با گسترش سریع این نوع بررسی ها در عصر اقتصاد پلتفرم همراه شده است (چاترجی و همکاران ۲۰۲۱؛ پلوتکینا و همکاران ۲۰۲۰). به طور کلی، کمبود چارچوب برای انگیزه های بررسی برخط فریبده در زمینه تجارت الکترونیک وجود دارد.

به طور کلی، انگیزه بررسی های برخط فریبده را می توان به انگیزه بیرونی و انگیزه داخلی تقسیم کرد (حسین و همکاران، ۲۰۱۸). بررسی های فریبده ناشی از انگیزه خارجی به دستکاری بررسی های برخط بوسیله فروشندگان برای انگیزه مالی اشاره دارد و در بیشتر موارد این نظرات فریبده بوسیله پوسترهای پولی (کومار و همکاران ۲۰۱۹) برای منافع مالی یا مزیت رقابتی ارسال می شوند (لی و همکاران ۲۰۱۸). در اینجا، پوسترهای پولی به بازبینان فریبده ای اشاره دارند که بوسیله فروشندگان برای ارسال نظرات برخط جعلی بر اساس اولویت های فروشندگان پول می گیرند. در فضای رقابتی فزاینده بازار، تعداد بیشتری از مشاغل تجارت الکترونیک نگران هستند که سایر مشاغل بررسی های برخط را دستکاری کنند و از این طریق بر عملکرد و سودآوری کسب و کار اثر منفی بگذارند (گاسلینگ و همکاران، ۲۰۱۸).

همچنین، مصرف کنندگان می توانند نظرات فریبده ای را برای

⁴ Zhang

⁵ RNN-Gated

⁶ Wang

¹ www.Amazon.com

² Lie

³ Ren

$$score = ((a * L) - (b * D)) + (c * C) \quad (1)$$

برای محاسبه امتیاز اعتبار کاربران از فرمولی استفاده می‌شود که در آن تعداد لایک‌ها (L)، تعداد دیس‌لایک‌ها (D) و محتوای کامنت (C) به‌عنوان ورودی در نظر گرفته می‌شوند. ضرایب a، b و c وزن نسبی هر ویژگی را مشخص می‌کنند. ضریب a اهمیت لایک‌ها، ضریب b اهمیت دیس‌لایک‌ها و ضریب c اهمیت محتوای کامنت را نشان می‌دهد. برای مثال، اگر لایک‌ها نسبت به محتوای کامنت اهمیت بیشتری داشته باشند ضریب a بیشتر از ضریب c در نظر گرفته می‌شود. این ضرایب این امکان را به ما می‌دهند تا تاثیر هر یک از ویژگی‌ها را روی امتیاز نهایی کاربر تنظیم کرده و امتیاز نهایی را بتوان به‌طور دقیق‌تری محاسبه کرد.

پس از محاسبه اعتبار خام کاربران، برای نرمال‌سازی این امتیازات در بازه ۰ تا ۱۰۰ از فرمول زیر استفاده می‌شود. همچنین، این نرمال‌سازی برای مقایسه بهتر و عادلانه‌تر امتیازات کاربران مختلف انجام می‌شود.

$$\frac{(\text{minScore} - \text{Score})}{(\text{minScore}_{\text{max}} - \text{Score})} \times 100 = \text{Normalized Score} \quad (2)$$

- برچسب‌گذاری:

یک رابط کاربری برای برچسب‌گذاری نظرات کاربران ایجاد کردیم که به کارشناسان خبره امکان می‌دهد تا با دقت و سرعت نظرات را ارزیابی و برچسب‌گذاری کنند. هر زمان که دکمه «بارگیری مجدد داده‌ها» کلیک شود، مجموعه‌ای از کامنت‌های یک محصول به کارشناس نمایش داده می‌شود. این کامنت‌ها شامل اطلاعاتی چون متن نظر، تعداد لایک‌ها و دیس‌لایک‌ها و امتیاز اعتبار کاربر هستند. در این رابط کاربری، کارشناس می‌تواند فراوانی احساسات نظرات را در سه دسته منفی، خنثی و مثبت مشاهده کند. این اطلاعات به کارشناسان کمک می‌کنند تا الگوهای کلی احساسات کاربران را درک کنند. همچنین، توزیع میانگین اعتبار کاربران در این سه دسته نیز نمایش داده می‌شود تا به کارشناسان نشان دهد که کاربران با چه سطح اعتباری نظرات خود را ارائه کردند. کارشناسان با توجه به این اطلاعات و همچنین با بررسی میزان لایک و دیس‌لایک هر کامنت قادر خواهند بود تا تصمیم‌گیری کنند که آیا یک نظر فریبنده است یا غیرفریبنده. این تصمیم‌گیری بر اساس تحلیل جامع از محتوای نظر، بازخورد کاربران و اعتبار نویسنده نظر انجام می‌شود.

۲-۵-۲- مرحله دوم: پردازش

در این پروژه، از مدل‌های زبان بزرگ (LLM) و به‌ویژه مدل

روش‌های مختلف، (وین‌ای) یادگیری عمیق برای این مسئله کارایی بهتری دارند و شبکه‌های LSTM نسبت به ماشین بردار پشتیبان (SVM) مناسب‌تر هستند. در پژوهش دیگری که در سال ۲۰۲۰ بوسیله ماها لاکشمی^۱ و همکارانش انجام شد نیز از شبکه‌های حافظه کوتاه‌مدت طولانی (LSTM) استفاده شد. آنها در این پژوهش از مجموعه داده OpSpam استفاده کرده و با دستیابی به دقتی در حدود ۸۰ تا ۸۵ درصد و مقایسه آن با مدل‌های کلاسیک یادگیری ماشین مانند ماشین بردار پشتیبان، k-نزدیک‌ترین همسایه و مدل‌های دیگر به دقت بهتری دست یافتند.

۲-۴- روش‌شناسی

پژوهش حاضر، با هدف تشخیص نظرات فریبنده فارسی ضمن ایجاد مجموعه داده مناسب پس از بررسی روش‌های منتخب یادگیری ماشین و یادگیری عمیق به اعمال و مقایسه این روش‌ها بر اساس سنجه‌های عملکردی دقت، صحت، امتیاز F1 و ... اقدام می‌کند. در این مطالعه، از مدل‌های یادگیری مختلفی برای انجام پروژه استفاده شد.

۲-۵- مدل اجرایی پژوهش حاضر

این پژوهش، به‌صورت عملیاتی در شرکت دیجی‌کالا انجام شد. مراحل انجام پژوهش به شرح زیر است:

۲-۵-۱- مرحله اول: جمع‌آوری، پیش‌پردازش و

برچسب‌گذاری

- جمع‌آوری:

با توجه به وب‌سرویس‌های عمومی دیجی‌کالا به دریافت نظر از ۶۰۰ هزار کاربر اقدام و با حذف داده‌های غیرضروری مجموعه داده‌ای مطابق جدول زیر ایجاد شد:

جدول ۱. ایجاد یک مجموعه داده جدید مبتنی بر مجموعه داده موجود

عنوان فیلد	توضیحات
Comment	متن کامنت افراد
User_ID	شناسه کاربر
Like	تعداد لایک‌های کامنت
Dislike	تعداد دیس‌لایک‌های کامنت
User_score	اعتبار کاربر

- پیش‌پردازش:

برای محاسبه اعتبار از فرمول زیر استفاده شد:

¹ Mahalakshmi

و پیش‌بینی‌های خود پردازند.

همچنین برای تشخیص بهتر و دقیق‌تر، باید متادیتای بیشتری در اختیار مدل قرار داد. این متادیتا شامل اطلاعات اضافی و مرتبط با هر نظر است که در فهم بهتر و دقیق‌تر نظرات به مدل کمک می‌کند. در پژوهش حاضر، متادیتای اضافه‌شده شامل تعداد لایک‌ها، تعداد دیس‌لایک‌ها، اعتبار کاربران و برچسب نظرات است. این اطلاعات به مدل کمک می‌کنند تا علاوه بر متن نظرات، ویژگی‌های دیگری که ممکن است بر تحلیل نظرات تأثیر بگذارند را نیز مد نظر قرار دهد.

۲-۵-۳- مرحله سوم: یادگیری و آزمایش و ذخیره

- تقسیم داده‌ها به مجموعه‌های آموزشی و آزمایشی

ابتدا داده‌ها به دو مجموعه آموزشی^۱ و آزمایشی^۲ تقسیم می‌شوند. این کار به منظور ارزیابی دقیق‌تر مدل انجام می‌شود. در این پروژه، ۷۵ درصد از داده‌ها برای آموزش و ۲۵ درصد برای آزمایش مدل استفاده شدند. همچنین، برای حفظ توزیع یکنواخت برچسب‌ها در هر دو مجموعه از روش طبقه‌بندی‌شده (stratified sampling) استفاده می‌شود.

• راه‌اندازی محیط PyCaret

برای ساده‌سازی فرآیند آموزش و ارزیابی مدل‌های یادگیری ماشین، از کتابخانه PyCaret استفاده می‌شود. PyCaret محیط یکپارچه‌ای برای پیش‌پردازش داده‌ها، آموزش مدل‌ها و ارزیابی عملکرد آنها فراهم می‌کند. در این مرحله، محیط PyCaret با مشخص کردن متغیر هدف و تنظیمات اولیه راه‌اندازی می‌شود تا فرآیند آموزش مدل‌ها به صورت خودکار انجام شود.

• مقایسه مدل‌ها

PyCaret قابلیت مقایسه خودکار مدل‌های مختلف یادگیری ماشین را فراهم می‌کند. در این مرحله، مدل‌های مختلف با استفاده از اعتبارسنجی متقابل^۳ مقایسه می‌شوند تا بهترین مدل بر اساس معیارهای مختلف ارزیابی انتخاب شود. این مقایسه شامل بررسی معیارهایی مانند دقت^۴، صحت^۵، یادآوری^۶ و غیره است.

• پیش‌بینی با بهترین مدل

پس از انتخاب بهترین مدل، این مدل برای پیش‌بینی روی مجموعه آزمایشی استفاده می‌شود. در این مرحله، عملکرد مدل در پیش‌بینی داده‌های جدید و ناشناخته ارزیابی می‌شود. مدل با استفاده از

ParsBert استفاده شد که مدل ترانسفورمری پیشرفته برای زبان فارسی است. این مدل‌ها قابلیت استخراج ویژگی‌های معنایی متن را دارند و به ما کمک می‌کنند تا داده‌های متنی را به بردارهای عددی قابل استفاده در مدل‌های یادگیری ماشین تبدیل کنیم.

نحوه تبدیل متن به بردار به اینصورت است که هر کلمه از متن به یک توکن (Token) تبدیل می‌شود. این فرآیند با استفاده از یک واژه‌نامه خاص انجام می‌شود که BERT از آن استفاده می‌کند. واژه‌نامه BERT شامل کلمات رایج و زیرکلمات است که به مدل کمک می‌کند تا حتی کلمات ناشناخته را به توکن‌های قابل فهم تبدیل کند. برای هر جمله، دو توکن خاص اضافه می‌شود: '[CLS]' در ابتدای جمله و '[SEP]' در انتهای جمله. '[CLS]' مخفف «classification» است و به‌عنوان نماینده کل جمله عمل می‌کند در حالی که '[SEP]' برای جداسازی جملات استفاده می‌شود.


توکن‌های ورودی به بردارهایی با ابعاد ثابت تبدیل می‌شوند که به این فرآیند Token Embedding گفته می‌شود. این بردارها شامل اطلاعاتی درباره خود توکن‌ها و همچنین موقعیت آنها در جمله هستند. علاوه بر بردارهای تعبیه‌شده شامل Segment Embedding و Position Embedding نیز هستند. Position Embedding مشخص می‌کند که هر توکن به کدام جمله (اگر بیش از یک جمله وجود داشته باشد) تعلق دارد و Position Embedding موقعیت هر توکن را در جمله نشان می‌دهد.

بردارهای تعبیه‌شده از توکن‌ها از طریق چندین لایه ترانسفورمر عبور می‌کنند. هر لایه شامل سازوکارهای Self-Attention و Feed-Forward Neural Networks است که به مدل کمک می‌کند تا وابستگی‌های پیچیده بین کلمات را درک کند. Self-Attention به مدل اجازه می‌دهد که به تمام کلمات در جمله توجه کند و اهمیت هر کلمه را نسبت به کلمات دیگر درک کند، در حالی که Feed-Forward Neural Networks اطلاعات پردازش شده را تقویت و اصلاح می‌کند.

پس از عبور از لایه‌های ترانسفورمر، بردار نهایی هر توکن استخراج می‌شود. بردار مربوط به توکن '[CLS]' به‌عنوان نماینده کل جمله در نظر گرفته می‌شود و می‌تواند به‌عنوان ورودی برای وظایف مختلف مانند طبقه‌بندی، ترجمه یا تولید متن استفاده شود. این بردار نهایی ترکیبی از تمام اطلاعات پردازش شده از جمله است و به مدل‌های یادگیری ماشین کمک می‌کند تا با دقت بیشتری به تحلیل

⁴ accuracy
⁵ precision
⁶ recall

¹ training set
² test set
³ cross-validation



شکل ۱. فلوجارت روش پیشنهادی

جدول ۲. مشخصات داده‌های استفاده‌شده

نام فیلد	نوع داده	توضیح
Comment	متن ^۱	متن نظر کاربر
Like	عدد صحیح ^۲	تعداد لایک‌هایی که نظر دریافت کرده
Dislike	عدد صحیح	تعداد دیس‌لایک‌هایی که نظر دریافت کرده
user_score	عدد اعشاری ^۳	امتیاز اعتبار کاربر (مقداری بین ۰ تا ۱۰۰)
sentiment	متن	احساس نظر (مثبت یا منفی)
User_ID	متن	شناسه یکتای کاربر
Date	عدد صحیح	تاریخ ارسال نظر به صورت یونیکس تایم‌استمپ ^۴
label	متن ^۵	برچسب نظر (گمراه‌کننده یا غیر گمراه‌کننده)
Brand_Id	عدد صحیح	شناسه برند محصول
Product_Id	متن	شناسه یکتای محصول

داده‌های آزمایشی امتحان می‌شود تا معیارهای مختلفی مانند دقت، دقت مثبت و یادآوری محاسبه و گزارش شوند.

• ترسیم ماتریس سردرگمی

برای بررسی عملکرد مدل در دسته‌بندی صحیح نمونه‌ها، ماتریس سردرگمی رسم می‌شود. این ماتریس نشان می‌دهد که مدل تا چه حد در دسته‌بندی صحیح نمونه‌ها موفق بوده است و تعداد نمونه‌های درست و نادرست دسته‌بندی شده را نمایش می‌دهد. این ارزیابی به درک بهتر نقاط قوت و ضعف مدل کمک می‌کند.

• ذخیره مدل

در نهایت، بهترین مدل به دست آمده ذخیره می‌شود تا در آینده بتوان از آن برای پیش‌بینی داده‌های جدید استفاده کرد. ذخیره مدل این امکان را به ما می‌دهد که بدون نیاز به آموزش مجدد از مدل آموزش دیده در محیط‌های مختلف و برای داده‌های جدید استفاده کنیم.

۲-۵-۴- مرحله چهارم: تشخیص

برای پیش‌بینی داده‌های جدید، تابعی طراحی می‌شود که بتواند با استفاده از مدل آموزش دیده، برچسب داده‌های جدید را پیش‌بینی کند. این تابع ابتدا داده‌های ورودی جدید را دریافت کرده و آنها را به بردارهای ویژگی عددی تبدیل می‌کند، همان‌طور که در مرحله پیش‌پردازش برای داده‌های آموزشی انجام شد. سپس، این بردارهای ویژگی به مدل ذخیره شده وارد می‌شوند و مدل با استفاده از الگوها و روابطی که در مرحله آموزش یاد گرفته است، برچسب مناسب را برای هر ورودی جدید پیش‌بینی می‌کند.

فلوجارت روش پیشنهادی در شکل ۱ نشان داده شد. مشخصات داده‌ها نیز در جدول ۲ قابل مشاهده است.

⁴ Unix Timestamp

⁵ String


¹ String

² Integer

³ Float

۳- یافته‌ها

ارزش و تاثیرگذار و همچنین به بهبود راهبردهای تعامل با کاربران کمک می‌کنند.



شکل ۲. ارتباط بین لایک‌های نظرات و اعتبار کاربر

۳-۱- مشخصات آزمایش‌های انجام‌شده

جدول عملکرد مدل‌های یادگیری ماشین در پیش‌بینی دسته‌ها (جدول ۳)، شامل معیارهای مختلفی برای ارزیابی مدل است که به تحلیل دقیق‌تر عملکرد مدل‌ها کمک می‌کند. این معیارها شامل دقت^۱، صحت^۲، بازخوانی^۳، امتیاز F1^۴، ضریب کاپا^۵، ضریب همبستگی متیوز^۶ و زمان اجرا^۷ هستند. دقت نشان می‌دهد که چه نسبتی از کل نمونه‌ها به درستی طبقه‌بندی شدند. دقت نشان می‌دهد که از بین تمام نمونه‌هایی که به‌عنوان مثبت پیش‌بینی شدند، چه نسبتی به درستی مثبت هستند که به‌ویژه در مسائلی با هزینه مثبت کاذب بالا اهمیت دارد. بازخوانی نشان می‌دهد که از بین تمام نمونه‌های مثبت، چه نسبتی به درستی به‌عنوان مثبت پیش‌بینی شدند که زمانی مهم است که هزینه منفی کاذب بالا باشد. امتیاز F1 میانگینی از دقت و بازخوانی است و توازن بین این دو معیار را نشان می‌دهد که به‌ویژه زمانی مفید است که توزیع داده‌ها نامتوازن است. ضریب کاپا معیاری برای سنجش میزان توافق مدل با واقعیت است که اثرات تصادفی را در نظر می‌گیرد. مقدار بالاتر کاپا نشان‌دهنده توافق بیشتر مدل با داده‌های واقعی است. ضریب همبستگی متیوز، یک معیار کلی برای سنجش عملکرد مدل‌های یادگیری ماشین است که هم داده‌های مثبت و هم منفی را در نظر می‌گیرد. این معیار به‌ویژه در مجموعه داده‌های نامتوازن کارایی بالاتری نسبت به دقت دارد و مقدار نزدیک به ۱ نشان‌دهنده عملکرد بهینه مدل است. زمان اجرا مدت‌زمان موردنیاز برای اجرای مدل را نشان می‌دهد و نقش مهمی در انتخاب مدل برای کاربردهای عملی

نظرات در سه سطح مثبت، خنثی و منفی بررسی می‌شوند. بیشترین تعداد نظرات در دسته نظرات مثبت قرار دارند که حدود ۷۰,۰۰۰ نظر را شامل می‌شود. این میزان بالای نظرات مثبت نشان‌دهنده رضایت کلی کاربران از محصولات و خدمات ارائه‌شده است. در مقابل، نظرات خنثی با حدود ۲۰,۰۰۰ نظر در مرتبه دوم قرار دارند که بیانگر عدم تمایل کاربران به ابراز نظر خاصی درباره محصولات یا خدمات است. در نهایت، نظرات منفی با حدود ۱۵,۰۰۰ نظر کمترین تعداد را به خود اختصاص داده‌اند که نمایانگر نارضایتی کاربران از برخی جنبه‌های محصولات یا خدمات است. این توزیع فراوانی نظرات به تحلیل‌گران کمک می‌کند تا درک بهتری از رضایت و نارضایتی کاربران نسبت به برند و محصولات کسب کنند و بتوانند به بهبود کیفیت خدمات و محصولات بپردازند.

همچنین، بررسی تغییرات نظرات نشان داد که نظرات مثبت طی سال‌ها به‌طور کلی روند افزایشی داشته و بیشترین تعداد نظرات مثبت در سال‌های ۲۰۱۹ و ۲۰۲۰ مشاهده شد که نشان‌دهنده افزایش رضایت کاربران در این سال‌ها است. نظرات خنثی نیز طی سال‌ها تا حدودی ثابت بوده و تغییرات کمتری نسبت به نظرات مثبت داشتند. این نظرات بیانگر کاربرانی هستند که نظر خاصی نسبت به محصولات یا خدمات نداشتند و روند آنها در طول زمان پایدار بود. نظرات منفی نیز طی سال‌ها تغییرات زیادی نداشته و تا حدودی ثابت باقی ماندند. با این حال، در برخی از سال‌ها مانند سال ۲۰۲۰، افزایش جزئی در تعداد نظرات منفی مشاهده می‌شود که نشان‌دهنده مشکلات خاصی در آن سال‌ها است. این توزیع فراوانی نظرات بر اساس سال به تحلیل‌گران کمک می‌کند تا تغییرات احساسات کاربران را در بازه زمان بررسی کرده و بتوانند به شناسایی روندها و نقاط قوت و ضعف محصولات و خدمات بپردازند.

نمودار ارتباط بین لایک‌های نظرات و اعتبار کاربر نشان می‌دهد که با افزایش تعداد لایک‌های نظرات، امتیاز اعتبار کاربران نیز به‌طور قابل توجهی افزایش می‌یابد. بیشتر کاربران با تعداد لایک‌های کمتر از ۵۰۰ دارای امتیاز اعتبار پایین‌تری هستند اما برخی کاربران با تعداد لایک‌های بالاتر، امتیاز اعتبار بسیار بالاتری دارند. این رابطه مثبت بین تعداد لایک‌ها و اعتبار کاربران نشان می‌دهد که نظرات مورد تایید بیشتر کاربران (با تعداد لایک بالا) اغلب بوسیله کاربران با اعتبار بالاتر نوشته شده است. این اطلاعات به شناسایی کاربران با

⁵ Kappa

⁶ MCC

⁷ TT

¹ Accuracy

² Precision

³ Recall

⁴ F1-score

دارد. مدل‌هایی با زمان اجرای کوتاه‌تر، در سیستم‌هایی که نیاز به پردازش سریع دارند، ارجحیت بیشتری خواهند داشت. این معیارها به ارزیابی عملکرد مدل‌ها به‌طور جامع و تصمیم‌گیری‌های بهتر برای بهبود مدل‌های یادگیری ماشین کمک می‌کنند.

جدول ۳. عملکرد مدل‌های یادگیری ماشین در پیش‌بینی دسته‌ها

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
knn	K Neighbors Classifier	0.9555	0.9749	0.9555	0.9569	0.9554	0.9106	0.9122	0.2720
xgboost	Extreme Gradient Boosting	0.9515	0.9753	0.9515	0.9538	0.9513	0.9025	0.9050	2.3200
lightgbm	Light Gradient Boosting Machine	0.9494	0.9708	0.9494	0.9516	0.9493	0.8985	0.9008	6.3420
ada	Ada Boost Classifier	0.9434	0.9730	0.9434	0.9445	0.9433	0.8865	0.8876	2.9060
gbc	Gradient Boosting Classifier	0.9393	0.9739	0.9393	0.9407	0.9392	0.8783	0.8798	9.8160
dt	Decision Tree Classifier	0.9130	0.9131	0.9130	0.9138	0.9130	0.8258	0.8265	0.3140
svm	SVM - Linear Kernel	0.8606	0.9485	0.8606	0.8739	0.8566	0.7185	0.7321	0.1680
rf	Random Forest Classifier	0.8178	0.8934	0.8178	0.8229	0.8174	0.6359	0.6406	0.7680
lr	Logistic Regression	0.7794	0.8816	0.7794	0.7848	0.7782	0.5583	0.5636	1.4760
et	Extra Trees Classifier	0.6336	0.6860	0.6336	0.6396	0.6320	0.2700	0.2740	0.4000
ridge	Ridge Classifier	0.6175	0.6407	0.6175	0.6190	0.6161	0.2339	0.2354	0.1600
nb	Naive Bayes	0.5789	0.6312	0.5789	0.5795	0.5780	0.1561	0.1570	0.2860
lda	Linear Discriminant Analysis	0.5385	0.5343	0.5385	0.5411	0.5346	0.0783	0.0796	0.2580
qda	Quadratic Discriminant Analysis	0.5203	0.5810	0.5203	0.5239	0.4041	0.0091	0.0196	0.1980
dummy	Dummy Classifier	0.5182	0.5000	0.5182	0.2686	0.3538	0.0000	0.0000	0.1380

ارزیابی مدل^۵ در کتابخانه PyCaret استفاده شد. این تابع با ارائه معیارهای جامع عملکرد مدل‌ها مانند دقت، سطح زیر منحنی، بازخوانی، درستی، F1-امتیاز، ضریب کاپا و MCC امکان بررسی و مقایسه عملکرد مدل‌های مختلف را با دقت بالا فراهم می‌کند. همچنین، این تابع نمودارهای ارزیابی متنوعی از جمله ماتریس سردرگمی، منحنی ROC، نمودار صحت - بازخوانی^۶ و نمودارهای ارتقاء و بهره^۷ را تولید می‌کند که به تحلیل بصری عملکرد مدل‌ها کمک شایانی می‌کند. با استفاده از این ابزار قدرتمند، توانستیم مدل‌های مختلف را به‌طور کامل ارزیابی کرده و بهترین مدل را برای تشخیص نظرات فریبده انتخاب کنیم. این ارزیابی دقیق، امکان ارتقای مدل‌های یادگیری ماشین را فراهم می‌کند.

۳-۱-۲- هاپیرپارامترهای مدل

جدول ۴، مقادیر هاپیرپارامترهای مدل را نمایش می‌دهد. هاپیرپارامترها تنظیماتی هستند که قبل از شروع فرآیند آموزش مدل تعیین می‌شوند.

۳-۱-۱- شرح خروجی

جدول ۳، تحلیل عملکرد مدل‌های مختلف یادگیری ماشین بر اساس معیارهای دقت، AUC، بازخوانی، درستی، امتیاز-F1، ضریب کاپا، MCC و زمان آموزش^۱ (TT) را ارائه می‌کند. مدل KNN با دقت ۰٫۹۵۵۵ و AUC ۰٫۹۷۴۹ عملکرد بسیار خوبی دارد و در زمان به نسبت کوتاهی آموزش دید (۰٫۲۷۲۰ ثانیه). مدل تقویت‌گرایان مضاعف^۲ نیز عملکرد بسیار خوبی با دقت ۰٫۹۵۱۵ و AUC ۰٫۹۷۵۳ دارد اما زمان آموزش آن بیشتر است (۲٫۳۲۰۰ ثانیه).

مدل تقویت‌گرایان ضعیف^۳ نیز با دقت ۰٫۹۴۹۴ و AUC ۰٫۹۷۰۸ عملکرد بالایی دارد اما زمان آموزشش زیاد است (۶٫۳۴۲۰ ثانیه). در مقابل، مدل دسته‌بندی دامی^۴ عملکرد بسیار ضعیفی با دقت ۰٫۵۱۸۲ و AUC ۰٫۵۰۰۰ دارد که نشان می‌دهد این مدل به هیچ وجه قابل اعتماد نیست.

برای ارزیابی مدل‌های یادگیری ماشین در این پژوهش، از تابع

^۵ Evaluate model

^۶ Precision-Recall

^۷ Gain

^۸ Hyperparameter

^۱ Training time

^۲ EXTRA boosting classifier

^۳ Light Gradient Boosting Machine


^۴ Dummy Classifier

خوب مدل در تفکیک کلاس‌ها است. این نمودار نشان می‌دهد که مدل KNN عملکرد بسیار خوبی در طبقه‌بندی داده‌ها دارد. مقدار AUC برابر ۰,۹۵ برای هر دو کلاس نشان می‌دهد که مدل قادر است با دقت بالایی نمونه‌های مثبت و منفی را تفکیک کند. این به معنای آن است که مدل نرخ پائینی از مثبت کاذب و منفی کاذب دارد و بنابراین می‌تواند به خوبی در کاربردهای واقعی استفاده شود.

۳-۱-۴- ماتریس درهم‌ریختگی

ماتریس درهم‌ریختگی مدل KNN، عملکرد آن را در تفکیک نمونه‌های دو کلاس ۰ و ۱ نمایش می‌دهد. این ماتریس شامل چهار مقدار کلیدی است: مثبت صحیح (TP) که نشان می‌دهد مدل ۹۵ نمونه از کلاس ۰ را به درستی شناسایی کرده، منفی صحیح (TN) که نشان می‌دهد ۱۰۳ نمونه از کلاس ۱ به درستی پیش‌بینی شده‌اند، مثبت کاذب (FP) که ۷ نمونه از کلاس ۰ را به اشتباه کلاس ۱ در نظر گرفته، و منفی کاذب (FN) که ۷ نمونه از کلاس ۱ را نادرست به عنوان کلاس ۰ طبقه‌بندی کرده است.

ماتریس درهم‌ریختگی^۷ در شکل ۴، تعداد پیش‌بینی‌های درست و نادرست مدل برای هر دسته را نشان می‌دهد.



شکل ۴. ماتریس درهم‌ریختگی مدل KNN

این نتایج، دقت بالای مدل در تشخیص صحیح کلاس‌ها را نشان می‌دهند. نرخ پایین نمونه‌های اشتباه طبقه‌بندی شده (FN و FP) نشان می‌دهد که مدل توانایی خوبی در تفکیک کلاس‌ها دارد. این عملکرد مناسب مدل در کاربردهای واقعی استفاده شده و به تصمیم‌گیری‌های دقیق‌تری منجر می‌شود.

۳-۱-۵- نمودار مرز تصمیم‌گیری


نمودار مرز تصمیم‌گیری در شکل ۵، مدل را در فضای ویژگی‌ها نمایش می‌دهد که نشان می‌دهد مدل چگونه داده‌ها را به دسته‌های

جدول ۴. هایپرپارامترهای مدل

مقدار/حالت	پارامترها
خودکار ۱	الگوریتم
۳۰	اندازه لیف
مینکوسکی ^۲	متریک
ندارد	پارامترهای متریک ^۳
-۱	تعداد شغل ^۴
۵	تعداد همسایگان
۲	p
یکنواخت	وزن

۳-۱-۳- مساحت زیر منحنی^۵ (AUC)

نمودار ROC^۶ در شکل ۳، منحنی مشخصه عملکرد سیستم یا منحنی عملیاتی گیرنده و مساحت زیر منحنی AUC را نشان می‌دهد که برای سنجش عملکرد کلی مدل در تشخیص درست دسته‌ها است.



شکل ۳. نمودار ROC برای مدل KNN

نمودار ROC برای مدل KNN- دسته‌بندی نزدیک‌ترین K- همسایگان را نشان می‌دهد. نمودار ROC ابزار مهمی برای ارزیابی عملکرد مدل‌های دسته‌بندی است. در این نمودار، مقدار AUC برای هر دو کلاس ۰ و ۱ برابر ۰,۹۵ است که نشان‌دهنده عملکرد بسیار

⁵ Area Under the Curve

⁶ Receiver Operating Characteristic

⁷ Confusion Matrix

¹ Auto

² Minkowski

³ Metric parameters


⁴ n_jobs

مختلف تقسیم می‌کند.

آستانه برای تفکیک بین دو کلاس در نظر گرفته می‌شود.

۳-۱-۶- نمودار پیش‌بینی خطا^۱

شکل ۶، پیش‌بینی خطای تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی را نشان می‌دهد. همچنین، این نمودار نشان می‌دهد که مدل در کدام کلاس‌ها عملکرد بهتری داشته و در کجاها دچار خطا شده است.



شکل ۶. نمودار خطای پیش‌بینی مدل KNN


نمودار خطای پیش‌بینی نشان می‌دهد که مدل KNN عملکرد بسیار خوبی در طبقه‌بندی داده‌ها دارد اما همچنان تعدادی نمونه را به اشتباه طبقه‌بندی کرده است. به‌طور خاص:

این مدل توانسته است بیشتر نمونه‌های کلاس ۰ را به درستی طبقه‌بندی کند اما ۷ نمونه را به اشتباه به‌عنوان کلاس ۱ پیش‌بینی کرد. همچنین، این مدل بیشتر نمونه‌های کلاس ۱ را به درستی طبقه‌بندی کرده است اما ۷ نمونه را به اشتباه به‌عنوان کلاس ۰ پیش‌بینی کرد.

این نمودار نشان‌دهنده نقاط قوت و ضعف مدل در پیش‌بینی دسته‌های مختلف است و می‌تواند به بهبود مدل و کاهش خطاهای پیش‌بینی کمک کند. به‌طور کلی، مدل KNN عملکرد مناسبی داشته و توانسته است بیشتر نمونه‌ها را به درستی طبقه‌بندی کند اما همچنان جای بهبود دارد.

۳-۱-۷- منحنی یادگیری^۲

منحنی یادگیری نحوه تغییر عملکرد مدل با افزایش اندازه داده‌های آموزشی را نشان می‌دهد.



شکل ۵. نمودار مرز تصمیم‌گیری مدل KNN

نمودار مرز تصمیم‌گیری مدل KNN در شکل ۵، نشان می‌دهد که مدل چگونه فضای ویژگی‌ها را برای طبقه‌بندی داده‌ها به دو کلاس ۰ و ۱ تقسیم می‌کند. این مرزها نشان‌دهنده تصمیم‌گیری مدل بر اساس ویژگی‌های داده‌ها هستند. هرچند مدل عملکرد خوبی در طبقه‌بندی داده‌ها دارد اما برخی اشتباهات طبقه‌بندی نیز وجود دارد که در نقاط داده‌های اشتباه طبقه‌بندی شده مشاهده می‌شوند.

در تحلیل دیگر نمودارها نمودار Lift نشان می‌دهد که مدل KNN در پیش‌بینی دسته‌ها به‌طور کلی بهتر از یک مدل تصادفی عمل می‌کند. در ابتدا، مدل توانسته است با دقت بالایی دسته‌بندی‌ها را انجام دهد اما با افزایش تعداد نمونه‌های بررسی‌شده، عملکرد مدل به‌تدریج به مدل تصادفی نزدیک‌تر می‌شود. این نمودار به شناسایی قسمت‌های داده با عملکرد بهتر و قسمت‌های داده نیازمند بهبود کمک می‌کند. نمودار تجمعی بهره نشان می‌دهد که مدل KNN در تشخیص دسته‌ها بسیار بهتر از یک مدل تصادفی عمل می‌کند. منحنی‌های بهره نشان می‌دهند که این مدل تعداد زیادی از نمونه‌ها را به درستی و با سرعت دسته‌بندی می‌کند و با افزایش درصد نمونه‌ها، عملکرد مدل بهبود می‌یابد. نمودار آستانه نشان می‌دهد که چگونه عملکرد مدل KNN با تغییر آستانه تصمیم‌گیری تغییر می‌کند. در اینجا، خط نقطه‌چین عمودی ممکن است نشان‌دهنده آستانه پیشنهادی یا بهینه باشد که بر اساس معیارهای مختلف ارزیابی انتخاب شده است. این نمودار به شما کمک می‌کند تا عملکرد مدل را در سطوح مختلف آستانه درک کنید و تصمیم‌گیری‌های بهتری برای بهبود مدل خود بگیرید. در بررسی نمودار آستانه یافته‌ها بیانگر آستانه‌ای است که بیشترین مقدار آماره $K-S$ ، ۹۲۴، در آن نقطه مشاهده می‌شود. این نقطه به‌عنوان بهترین

² Learning Curve

¹ Prediction Error Curve


برخی از بازه‌های احتمال پیش‌بینی شده به خوبی کالیبره شده و در برخی دیگر دچار اشکال است. به طور خاص:

در بازه‌های احتمال پایین (نزدیک به ۰,۲)، مدل به درستی کالیبره شده است.

در بازه‌های احتمال بالاتر (نزدیک به ۰,۴ و ۰,۶)، مدل به خوبی کالیبره نشده و تفاوت زیادی بین احتمالات پیش‌بینی شده و فراوانی وقوع واقعی وجود دارد.

۳-۱-۹- منحنی اعتبارسنجی^۳

منحنی اعتبارسنجی، عملکرد مدل را در مقابل مقادیر مختلف یک هایپرپارامتر خاص نشان می‌دهد.




شکل ۹. نمودار اعتبارسنجی مدل KNN

نمودار اعتبارسنجی برای مدل KNN نشان می‌دهد که این مدل در تعداد همسایگان دچار بیش‌برازش کمتری می‌شود زیرا دقت آموزشی بسیار بالا و دقت اعتبارسنجی پایین‌تر است. با افزایش تعداد همسایگان، دقت اعتبارسنجی بهبود می‌یابد و مدل تعمیم بهتری پیدا می‌کند. در این نمودار، مقدار بهینه هایپرپارامتر تعداد همسایگان حدود ۵ تا ۷ به نظر می‌رسد زیرا در این محدوده هر دو دقت آموزشی و اعتبارسنجی به سطح به نسبت ثابتی می‌رسند و فاصله بین آنها کمترین است.

۴- نتیجه‌گیری

در این پایان‌نامه، نتایج حاصل از تحلیل داده‌ها و ارزیابی مدل‌های یادگیری ماشین برای مقایسه عملکرد الگوریتم‌های KNN و XGBoost و دیگر مدل‌های رایج یادگیری ماشین استفاده از مدل‌های زبانی بزرگ (LLM) و به ویژه مدل ParsBERT برای




شکل ۷. منحنی یادگیری مدل KNN

نمودار منحنی یادگیری برای مدل KNN نشان می‌دهد که مدل با افزایش تعداد نمونه‌های آموزشی عملکرد پایداری دارد و دقت بالایی در هر دو مجموعه داده‌های آموزشی و اعتبارسنجی نشان می‌دهد. هرچند مقداری بیش‌برازش مشاهده می‌شود اما این بیش‌برازش به حدی نیست که عملکرد مدل را به طور جدی تحت تأثیر قرار دهد.

۳-۱-۸- منحنی کالیبراسیون^۱

این نمودار نشان می‌دهد که چگونه احتمالات پیش‌بینی شده بوسیله مدل با توزیع واقعی داده‌ها سازگار هستند.



شکل ۸. نمودار کالیبراسیون

خط به طور کامل کالیبره شده^۲: این خط که با نقطه چین سیاه نشان داده شد مدلی را نشان می‌دهد که به طور کامل کالیبره شد که در آن احتمالات پیش‌بینی شده به طور دقیق با فراوانی وقوع واقعی مطابقت دارند.

منحنی آبی (KNN): این منحنی نشان‌دهنده عملکرد مدل KNN است.

نمودار کالیبراسیون برای مدل KNN نشان می‌دهد که این مدل در

^۳ Validation Curve

^۱ Calibration Curve

^۲ Perfectly calibrated

طبق نمودار macro-average ROC مدل KNN عملکرد بسیار خوبی در طبقه‌بندی داده‌ها نشان داد. مقدار AUC برابر ۰٫۹۵ برای هر دو کلاس نشان می‌دهد که مدل قادر است با دقت بالایی نمونه‌های مثبت و منفی را تفکیک کند و نرخ پایینی از مثبت کاذب و منفی کاذب دارد و بنابراین می‌تواند به خوبی در کاربردهای واقعی استفاده شود. نمودار ماتریس درهم‌ریختگی نیز دقت بالای مدل در تشخیص صحیح کلاس‌ها ۰٫۹۳۱٪ نمونه‌های کلاس ۰ و ۰٫۹۳۶٪ نمونه‌های کلاس ۱ را نشان داد که تایید بر عملکرد به نسبت خوب مدل KNN در طبقه‌بندی نمونه‌ها بود. نمودار مرز تصمیم‌گیری مدل KNN نشان‌دهنده عملکرد خوب مدل در طبقه‌بندی داده‌ها بود. منحنی‌های بهره مدل KNN به‌طور قابل‌توجهی از خط Baseline قرار داشتند که نشان‌دهنده عملکرد بهتر مدل نسبت به مدل تصادفی بود.

نمودار تجمعی بهره نشان داد که مدل KNN در تشخیص دسته‌ها بسیار بهتر از یک مدل تصادفی عمل می‌کند. و با سرعت تعداد زیادی از نمونه‌ها را به درستی دسته‌بندی می‌کند و با افزایش درصد نمونه‌ها، عملکرد مدل بهبود می‌یابد. در سطوح آستانه پایین، دقت مدل بالا بود. با افزایش آستانه، دقت مدل کاهش یافت. در سطوح آستانه پایین، بازخوانی پایین بود زیرا مدل تعداد زیادی از نمونه‌های مثبت واقعی را به‌عنوان منفی طبقه‌بندی می‌کند. با افزایش آستانه، مدل نمونه‌های مثبت بیشتری را به درستی شناسایی می‌کند و بازخوانی افزایش یافت.

نمودار Precision-Recall برای مدل KNN با میانگین دقت برابر ۰٫۹۴ حاکی از عملکرد بالای مدل بود.

نمودار خطای پیش‌بینی نیز نشان داد که با وجود طبقه‌بندی اشتباه تعدادی نمونه مدل KNN عملکرد بسیار خوبی در طبقه‌بندی داده‌ها دارد. دقت و بازخوانی بالای مدل (برای نمونه‌های کلاس ۱ برابر ۰٫۹۳۶ و برابر ۰٫۹۳۱ برای نمونه‌های کلاس ۰) نشان داد مدل KNN در طبقه‌بندی داده‌ها بسیار موثر بوده و توانسته است به خوبی دسته‌بندی‌های صحیح را انجام دهد. دقت مدل در داده‌های آموزشی با افزایش تعداد نمونه‌های آموزشی کمی نوسان دارد اما به‌طور کلی در سطح بالایی (حدود ۰٫۹۶ تا ۰٫۹۸) باقی می‌ماند که حاکی از عملکرد بسیار خوب مدل در داده‌های آموزشی است و می‌تواند بیشتر نمونه‌های آموزشی را به درستی طبقه‌بندی کند. دقت مدل در داده‌های اعتبارسنجی نیز با افزایش تعداد نمونه‌های آموزشی کمی نوسان دارد اما در سطح پایین‌تری نسبت به دقت آموزشی (حدود ۰٫۹۴ تا ۰٫۹۶) باقی می‌ماند. در این نمودار، دو منحنی (آموزشی و اعتبارسنجی) به هم نزدیک هستند که بیش‌برازش اندک

تحلیل احساسات نظرات کاربران و شناسایی بهترین مدل در تشخیص نظرات فریبده در فروشگاه‌های برخط منابع باز و وب‌سرویس‌های دیجی کالا بررسی شد. داده‌های مورد استفاده در این تحقیق شامل نظرات کاربران با ویژگی‌های مختلفی از جمله متن نظر، نام کاربر، تعداد لایک و دیس لایک، امتیاز کاربر، تاریخ ارسال نظر و غیره در فروشگاه‌های برخط است. بر اساس توزیع فراوانی نظرات مبتنی بر احساسات پیام، نظرات مثبت بیشترین تعداد نظرات (حدود ۷۰،۰۰۰ نظر) بود که نشان‌دهنده رضایت کلی کاربران از محصولات و خدمات ارائه شده است. در مقابل، نظرات خنثی با حدود ۲۰،۰۰۰ نظر بیانگر عدم تمایل کاربران به ابراز نظر خاصی درباره محصولات یا خدمات است. نظرات منفی با حدود ۱۵،۰۰۰ نظر کمترین تعداد را به خود اختصاص دادند که نارضایتی کاربران از برخی جنبه‌های محصولات یا خدمات را نشان می‌دهد. توزیع فراوانی سالانه نظرات نشان داد نظرات مثبت به‌طور کلی روند افزایشی داشته و بیشترین تعداد نظرات مثبت در سال‌های ۲۰۱۹ و ۲۰۲۰ بود. نظرات خنثی تا حدودی ثابت بوده و تغییرات کمتری نسبت به نظرات مثبت داشتند. نظرات منفی با وجود افزایش جزئی در برخی سال‌ها مانند ۲۰۲۰، تغییرات زیادی نداشته و تا حدودی ثابت باقی ماندند. توزیع فراوانی نظرات بر اساس اعتبار کاربر نشان داد که بیشتر نظرات از سوی کاربران با اعتبار پایین ارسال شدند که می‌تواند به دلیل تعدد کاربران جدید یا غیرفعال با اعتبار پایین باشد. بر اساس توزیع فراوانی لایک‌ها و دیس لایک‌ها تعداد لایک‌ها به‌طور کلی بیشتر از تعداد دیس لایک‌ها بود و به‌طور کلی روند افزایش نوسانی را نشان می‌داد. نمودار ارتباط بین لایک‌های نظرات و اعتبار کاربر نشان داد که تعداد لایک‌های نظرات تاثیر مستقیمی بر امتیاز اعتبار کاربران داشت. رابطه مثبت بین تعداد لایک‌ها و اعتبار کاربران نشان‌دهنده نظرات مورد تایید بیشتر کاربران (با تعداد لایک بالا) بوسیله کاربران با اعتبار بالاتر بود.

داده‌های عملکرد مدل‌های یادگیری ماشین در پیش‌بینی دسته‌ها نشان داد که مدل KNN با دقت ۰٫۹۵۵۵ و AUC ۰٫۹۷۴۹ یکی از بهترین مدل‌ها است. مدل Boosting Extreme Gradient نیز با دقت ۰٫۹۵۱۵ و AUC ۰٫۹۷۵۳ عملکرد بسیار خوبی از خود نشان داد. مدل‌های Ada Boost و LightGBM نیز به ترتیب با دقت‌های ۰٫۹۴۹۴ و ۰٫۹۴۳۴ و AUC‌های ۰٫۹۷۰۸ و ۰٫۹۷۳۰ در رتبه‌های بعدی قرار گرفتند. مدل‌های دیگر نیز بسته به معیارهای مختلف ارزیابی، عملکرد متفاوتی داشتند. به‌طور کلی، مدل‌های Boosting و KNN در این پژوهش عملکرد بهتری نسبت به سایر مدل‌ها داشتند.

محورهای اصلی سوالات کاربران حول محصول بوسیله هوش مصنوعی از دیگر موارد پیشنهاد شده در این بخش است.

مرجع

- [1] Anderson ET, Simester DI (2014) Reviews without a purchase: Low ratings, loyal customers, and deception. *J. Mark. Res.* 51:249–269. <https://doi.org/10.1509/jmr.13.0209>
- [2] Cao H (2020) Online review manipulation by asymmetrical firms: Is a firm's manipulation of online reviews always detrimental to its competitor? *Inf. Manag.* 57:103244. <https://doi.org/10.1016/j.im.2019.103244>
- [3] Chatterjee S, Goyal D, Prakash A, Sharma J (2021) Exploring healthcare/health-product ecommerce satisfaction: A text mining and machine learning application. *J. Bus. Res.* 131:815–825. <https://doi.org/10.1016/j.jbusres.2020.10.043>
- [4] Chen J, Yang Y, Liu H (2021) Mining bilateral reviews for online transaction prediction: A relational topic modeling approach. *Inf. Syst. Res.* 32:541–560. <https://doi.org/10.1287/ISRE.2020.0981>
- [5] Dong X, Lian Y (2021) A review of social media-based public opinion analyses: Challenges and recommendations. *Technol. Soc.* 67:101724. <https://doi.org/10.1016/j.techsoc.2021.101724>
- [6] Ho SM, Hancock JT (2019) Context in a bottle: Language-action cues in spontaneous computer-mediated deception. *Comput. Human Behav.* 91:33–41. <https://doi.org/10.1016/j.chb.2018.09.008>
- [7] Huang G, Liang H (2021) Uncovering the effects of textual features on trustworthiness of online consumer reviews: A computational-experimental approach. *J. Bus. Res.* 126:1–11. <https://doi.org/10.1016/j.jbusres.2020.12.052>
- [8] Hussain S, Guangju W, Jafar RMS, Ilyas Z, Mustafa G, Jianzhou Y (2018) Consumers' online information adoption behavior: Motives and antecedents of electronic word of mouth communications. *Comput. Human Behav.* 80:22–32. <https://doi.org/10.1016/j.chb.2017.09.019>
- [9] Ke Z, Liu D, Brass DJ (2020) Do online friends bring out the best in us? The effect of friend contributions on online review provision. *Inf. Syst. Res.* 31:1322–1336. <https://doi.org/10.1287/isre.2020.0947>
- [10] Kumar N, Venugopal D, Qiu L, Kumar S (2019) Detecting anomalous online reviewers: An unsupervised approach using mixture models. *J. Manag. Inf. Syst.* 36:1313–1346. <https://doi.org/10.1080/07421222.2019.1661089>
- [11] Kumar N, Venugopal D, Qiu L, Kumar S (2018) Detecting review manipulation on online platforms with hierarchical supervised learning. *J. Manag. Inf. Syst.* 35:350–380. <https://doi.org/10.1080/07421222.2018.1440758>
- [12] Lamb Y, Cai W, McKenna B (2020) Exploring the complexity of the individualistic culture through social exchange in online reviews. *Int. J. Inf. Manage.* 54:102198. <https://doi.org/10.1016/j.ijinfomgt.2020.102198>
- [13] Lee SY, Qiu L, Whinston A (2018) Sentiment manipulation in online platforms: An analysis of movie tweets. *Prod. Oper. Manag.* 27:393–416. <https://doi.org/10.1111/poms.12805>

مدل را نشان می‌دهد.

نمودار منحنی یادگیری نشان داد با افزایش تعداد نمونه‌های آموزشی مدل KNN عملکرد پایدار و دقت بالا در هر دو مجموعه داده‌های آموزشی و اعتبارسنجی دارد. خوشه‌های مجزا برای کلاس‌های ۰ و ۱ نشان داد که مدل KNN داده‌ها را به خوبی بر اساس ویژگی‌هایشان تفکیک کرد.

زمان اجرای t-SNE نشان‌دهنده سرعت بالای پردازش الگوریتم بود.

نمودار کالیبراسیون برای مدل KNN نشان می‌دهد که این مدل در برخی بازه‌های احتمال پیش‌بینی شده به خوبی کالیبره شده و در برخی دیگر دچار اشکال است. در بازه‌های احتمال پایین (نزدیک به ۰،۲)، مدل به درستی کالیبره شده و در بازه‌های احتمال بالاتر (نزدیک به ۰،۴ و ۰،۶)، مدل به خوبی کالیبره نشده نشان از تفاوت زیاد بین احتمالات پیش‌بینی شده و فراوانی وقوع واقعی بود. دقت بسیار بالای مدل در داده‌های آموزشی با کاهش تعداد همسایگان (حدود ۱) و کاهش آن با افزایش تعداد همسایگان (حدود ۰،۹۶) نشان داد مدل تمایل به بیش‌برازش دارد زیرا تمامی نقاط آموزشی را به درستی دسته‌بندی می‌کند. با افزایش تعداد همسایگان، دقت اعتبارسنجی مدل از حدود ۰،۹ به حدود ۰،۹۶ بهبود می‌یابد.

نمودار اعتبارسنجی برای مدل KNN نشان می‌دهد که این مدل در تعداد همسایگان^۱ کمتر به دلیل دقت آموزشی بسیار بالا و دقت اعتبارسنجی پایین‌تر دچار بیش‌برازش می‌شود. بر اساس نتایج ارزیابی‌ها، مدل KNN با دقت ۰،۹۵۵۵ و AUC ۰،۹۷۴۹ به‌عنوان یکی از بهترین مدل‌ها شناخته شد. مدل Extreme Gradient Boosting نیز با دقت ۰،۹۵۱۵ و AUC ۰،۹۷۵۳ عملکرد بسیار خوبی از خود نشان داد. مدل‌های Ada Boost و LightGBM نیز به ترتیب با دقت‌های ۰،۹۴۹۴ و ۰،۹۴۳۴ و AUC‌های ۰،۹۷۰۸ و ۰،۹۷۳۰ در رتبه‌های بعدی قرار گرفتند. مدل‌های دیگر نیز بسته به معیارهای مختلف ارزیابی، عملکرد متفاوتی داشتند. به‌طور کلی، مدل‌های تقویتی^۲ و همسایگی (KNN) در این پژوهش عملکرد بهتری نسبت به مدل‌های دیگر داشتند. در پایان بر اساس یافته‌های بدست‌آمده برای شناسایی نظرات جعلی و فریبنده به کمک هوش مصنوعی پیشنهاد می‌شود سیستم توصیه‌گر محصول بوسیله دستیار هوشمند خرید مبتنی بر نیاز کاربر بوسیله مدل زبان بزرگ ایجاد شود. همچنین استفاده از سیستم هوشمند پرسش و پاسخ در زمینه محصولات مبتنی بر هوش مصنوعی و سیستم خلاصه‌ساز متن نظرات یک محصول بوسیله هوش مصنوعی و سیستم استخراج

² Boosting

¹ n_neighbors

- [24] Wu PF (2019) Motivation crowding in online product reviewing: A qualitative study of amazon reviewers. *Inf. Manag.* 56:103163. <https://doi.org/10.1016/j.im.2019.04.006>
- [25] Xu W, Zhang C(2018) Sentiment, richness, authority, and relevance model of information sharing during social Crises—the case of #MH370 tweets *Comput. Human Behav.* 89:199–206. <https://doi.org/10.1016/j.chb.2018.07.041>
- [26] Yang, Y, Zhang, K, 2022. sDTM: A Supervised Bayesian Deep Topic Model for Text Analytics. *Inf. Syst. Res.* <https://doi.org/10.1287/isre.2022.1124>
- [27] Yu Y, Khern-am-nuai W, Pinsonneault A (2022) When paying for reviews pays off: The case of performance-contingent monetary incentives. *MIS Q. Manag. Inf. Syst* 46:609–626. <https://doi.org/10.25300/MISQ/2022/15488>
- [28] Zhang D, Zhou L, Kehoe JL, Kilic IY (2016) What online reviewer behaviors really matter? Effects of verbal and nonverbal behaviors on detection of fake online reviews. *J. Manag. Inf. Syst.* 33:456–481. <https://doi.org/10.1080/07421222.2016.1205907>
- [29] Zhang W, Du Y, Yoshida T, Wang Q (2018) DRI-RCNN: An approach to deceptive review identification using recurrent convolutional neural network. *Inf. Process. Manag.* 54:576–592. <https://doi.org/10.1016/j.ipm.2018.03.007>
- [30] Zhang W, Xie R, Wang Q, Yang Y, Li J (2022) A novel approach for fraudulent reviewer detection based on weighted topic modelling and nearest neighbors with asymmetric Kullback–Leibler divergence. *Decis. Support Syst.* 157:113765. <https://doi.org/10.1016/j.dss.2022.113765>
- [31] Zhou Y, Lv X, Wang L, Li J, Gao X (2023) What increases the risk of gamers being addicted? An integrated network model of personality–emotion–motivation of gaming disorder. *Comput. Human Behav.* 141:107647. <https://doi.org/10.1016/j.chb.2022.107647>
- [32] Zhuang M, Cui G, Peng L (2018) Manufactured opinions: The effect of manipulating online product reviews. *J. Bus. Res.* 87:24–35. <https://doi.org/10.1016/j.jbusres.2018.02.016>
- [33] Lakshami, S., Muthumani, S.(2017). Building Brand Power. *IOP Conference Series: Materials Science and Engineering*. 197,<https://iopscience.iop.org/article/10.1088/1757-899X/197/1/01>
- [14] [14] Lei Z, Yin D, Zhang H (2021) Focus within or on others: The impact of reviewers’ attentional focus on review helpfulness. *Inf. Syst. Res.* 32:801–809. <https://doi.org/10.1287/ISRE.2021.1007>
- [15] Li L, Lee KY, Lee M, Yang SB (2020) Unveiling the cloak of deviance: Linguistic cues for psychological processes in fake online reviews. *Int. J. Hosp. Manag.* 87:102468. <https://doi.org/10.1016/j.ijhm.2020.102468>
- [16] Li L, Yang L, Zhao M, Liao M, Cao Y (2022) Exploring the success determinants of crowdfunding for cultural and creative projects: An empirical study based on signal theory. *Technol. Soc.* 70:102036. <https://doi.org/10.1016/j.techsoc.2022.102036>
- [17] Pang H, Liu J, Lu J (2022) Tackling fake news in socially mediated public spheres: A comparison of Weibo and WeChat. *Technol. Soc.* 70:102004. <https://doi.org/10.1016/j.techsoc.2022.102004>
- [18] Qiao D, Lee SY, Whinston AB, Wei Q (2020) Financial incentives dampen altruism in online prosocial contributions: A study of online reviews. *Inf. Syst. Res.* 31:1361–1375. <https://doi.org/10.1287/isre.2020.0949>
- [19] Sporer SL (1997) The less travelled road to truth: verbal cues in deception detection in accounts of fabricated and self-experienced events. *Appl. Cogn. Psychol.* 11:373–397. [https://doi.org/10.1002/\(SICI\)1099-0720\(199710\)11:53.0.CO;2-0](https://doi.org/10.1002/(SICI)1099-0720(199710)11:53.0.CO;2-0)
- [20] Wang H, Du R, Shen W, Qiu L, Fan W (2022a) Product reviews: a benefit, a burden, or a trifle? How seller reputation affects the role of product reviews. *MIS Q. Manag. Inf. Syst* 46:1243–1272. <https://doi.org/10.25300/misq/2022/15660>
- [21] Wang Q, Zhang W, Li J, Mai F, Ma Z (2022b) Effect of online review sentiment on product sales: The moderating role of review credibility perception. *Comput. Human Behav.* 133:107272. <https://doi.org/10.1016/j.chb.2022.107272>
- [22] Wang Y, Goes P, Wei Z, Zeng D (2019) Production of online word-of-mouth: Peer effects and the moderation of user characteristics. *Prod. Oper. Manag.* 28:1621–1640. <https://doi.org/10.1111/poms.13007>
- [23] Wu C, Mai F, Li X (2021) The effect of content depth and deviation on online review helpfulness: Evidence from double-hurdle model. *Inf. Manag.* 58:103408. <https://doi.org/10.1016/j.im.2020.103408>

Analysis of the Impact of Artificial Intelligence Application in the Employment Sector and Proposing Priority Solutions for Iran

Azam Sadat Mortazavi Kahangi¹, Hassan Yeganeh^{2*}, Anita Hadizadeh³

¹ Faculty of Strategic Studies & Digital Economic, ICT Research Institute (ITRC), Tehran, Iran

² Faculty of Strategic Studies & Digital Economic, ICT Research Institute (ITRC), Tehran, Iran

³ Faculty of Strategic Studies & Digital Economic, ICT Research Institute (ITRC), Tehran, Iran

Received: 05 January 2025, Revised: 26 June 2025, Accepted: 02 July 2025

Paper type: Research

Abstract

The rapid growth of transformative technologies has created numerous opportunities and challenges for economic sectors. The impact of artificial intelligence (AI) on the economy and labor market, along with future projections, has drawn the attention of policymakers and decision-makers to this field. Studies and forecasts evaluate these impacts differently depending on the level of development of various countries. Therefore, preparing for the effects of AI application in the labor market, considering its role in the national economy, requires thorough examination. This study proposes and prioritizes strategies to address AI-related challenges in employment in Iran. Through a qualitative approach, the study identifies higher-level policy documents using a document-based methodology and analyzes their content to derive relevant considerations. By mapping these considerations to recommendations from international organizations, initial strategies were developed and finalized through the Delphi method, involving 14 experts in the field. These strategies were then prioritized using the AHP method and Super Decision software. The findings reveal that the strategy "focusing policymakers' and regulators' efforts on drafting and updating regulations for relevant sectors and establishing suitable enforcement mechanisms" ranks highest in the education and skills dimension. The strategy "investing in strengthening the technological and digital skills of the current and future workforce by updating skill indicators in recruitment and workforce evaluation processes" is prioritized in the workforce employment dimension, while the strategy "policy-making to promote digital literacy mechanisms and enhance public digital culture" is paramount in the digital literacy dimension.

Keywords: Application of artificial intelligence, employment, solution, upstream documents, prioritization.

* Corresponding Author's email: yeganeh@itrc.ac.ir

سال هفدهم، شماره ۶۵، مهر ۱۴۰۴، شماره ویژه «هوش مصنوعی و تحلیل داده»، صفحه ۸۸ الی ۱۰۴

تحلیل اثرات کاربست هوش مصنوعی در حوزه اشتغال و پیشنهاد راهکارهای اولویت‌دار برای ایران

اعظم سادات مرتضوی کهنکی^۱، حسن یگانه^۲، آنیته هادیزاده^۳

^۱ گروه مطالعات تنظیم‌گری و سازماندهی فاوا، پژوهشکده مطالعات راهبردی فاوا و اقتصاد دیجیتال، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

^۲ گروه مطالعات تنظیم‌گری و سازماندهی فاوا، پژوهشکده مطالعات راهبردی فاوا و اقتصاد دیجیتال، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

^۳ گروه مطالعات تنظیم‌گری و سازماندهی فاوا، پژوهشکده مطالعات راهبردی فاوا و اقتصاد دیجیتال، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۱۰/۱۶ تاریخ بازبینی: ۱۴۰۴/۰۴/۰۵ تاریخ پذیرش: ۱۴۰۴/۰۴/۱۱

نوع مقاله: پژوهشی

چکیده

همزمان با رشد سریع فناوری‌های تحول‌آفرین، فرصت‌ها و چالش‌های بسیاری پیش روی بخش‌های اقتصادی قرار گرفته است. تأثیرات کاربست هوش مصنوعی بر اقتصاد و بازار کار به همراه پیش‌بینی‌های صورت گرفته، توجه سیاست‌گذاران و تصمیم‌گیران را به این مقوله جلب کرده است. مطالعات و پیش‌بینی‌ها، این تأثیرات را با توجه به نوع توسعه‌یافتگی کشورها متفاوت ارزیابی می‌کنند. از این‌رو، اهمیت آمادگی برای اثرات کاربست هوش مصنوعی در بازار کار با توجه به نقش آن در اقتصاد کشور نیازمند بررسی عمیق است. هدف از این پژوهش ارائه راهکارهای پاسخ‌گویی به چالش‌های هوش مصنوعی در حوزه اشتغال در ایران و اولویت‌بندی آنها است. در این پژوهش کیفی به شناسایی اسناد بالادستی با استفاده از روش اسنادی پرداخته و با تحلیل مضمون، ملاحظات این اسناد تبیین خواهد شد و با نداشت آنها با توصیه‌های نهادهای بین‌المللی، راهکارهای پیشنهادی اولیه ارائه شده و از طریق روش دلفی و نظر ۱۴ خبره این حوزه، راهکارها نهایی می‌شود. سپس این راهکارها با استفاده از روش AHP و نرم‌افزار سوپردسیژن اولویت‌بندی می‌گردد. نتیجه این پژوهش نشان می‌دهد که راهکار "تمرکز سیاست‌گذاران و مقررات‌گذاران در تدوین و به‌روزرسانی مقررات بخش‌های مرتبط و تدوین ضمانت اجرایی مناسب" در بُعد آموزش و مهارت، راهکار "سرمایه‌گذاری در تقویت مهارت‌های فناورانه و دیجیتال نیروی کار فعلی و آتی با به‌روآوری شاخص‌های مهارتی در فرایند استخدام و یا ارزیابی نیروی کار" در بُعد استخدام نیروی کار و راهکار "سیاست‌گذاری به‌منظور ایجاد سازوکارهای ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال" در بُعد سواد دیجیتال اولویت دارند.

کلیدواژگان: کاربست هوش مصنوعی، اشتغال، راهکار، اسناد بالادستی، اولویت‌بندی.

* رایانامه نویسنده مسؤول: yeganeh@itrc.ac.ir

۱- مقدمه

مصنوعی در کشورهای پیشرفته و کمتر توسعه‌یافته در زمینه اشتغال می‌شود [۶]. میزان تأثیر هوش مصنوعی به لحاظ اقتصادی و به طور خاص در اشتغال متفاوت بوده و نکته مهم این است که با توجه به اینکه ورود و نفوذ هوش مصنوعی به اقتصاد در جوامع مختلف اجتناب‌ناپذیر است، فارغ از آثار مثبت یا منفی آن، تمام زوایای بازار کار از جمله کمیت و کیفیت مشاغل، توزیع درآمد، بهره‌وری، کنترل و نظارت و قواعد بازی متأثر از هوش مصنوعی خواهد بود و این ضرورت نگرش و مدیریت چالش پیش‌رو را نشان می‌دهد [۷].

به این منظور، راهکارهایی توسط نهادهای متخصصین و سازمان‌های بین‌المللی مرتبط، از جمله توانمندسازی نیروهای کار به مهارت‌های لازم، حصول اطمینان از بازتوزیع عادلانه مزیت‌های هوش مصنوعی، ارائه برنامه‌های آموزشی و حمایت از افراد آسیب‌دیده ناشی از جابه‌جایی‌های شغلی و فراهم‌سازی دسترسی این افراد به فرصت‌های جدید در بازار کار، بالا بردن کیفیت مشاغل و تقویت کارآفرینی و بهره‌وری، با هدف تضمین اشتراک منصفانه مزایای کاربست هوش مصنوعی ارائه شده است. اما نکته قابل تأمل این است که پیامدهای منفی هوش مصنوعی، با توجه به توسعه‌یافتگی، اقتصاد، فرهنگ و حکمرانی آن کشور می‌تواند متغیر باشد. مدیریت صحیح پاسخ‌گویی به این چالش‌ها نیازمند بررسی ملاحظات به‌کارگیری هوش مصنوعی در کشور با توجه به چشم‌انداز و اسناد بالادستی مربوطه و نگاشت توصیه‌های سازمان‌های بین‌المللی در تجارب پیشین است. با وجود تحقیقات متعدد در زمینه تأثیر هوش مصنوعی بر اشتغال، مطالعات موجود عمدتاً به بررسی‌های کلی و جهانی پرداخته و راهکارهای متناسب با شرایط خاص ایران کمتر مورد توجه قرار گرفته‌اند. علاوه بر این، در سیاست‌گذاری‌های مرتبط با اشتغال، بررسی اسناد بالادستی و تحلیل تطبیقی توصیه‌های بین‌المللی به‌صورت نظام‌مند انجام نشده و تاکنون چارچوبی مشخص برای این بررسی ارائه نشده و این موضوع به‌عنوان یک خلأ پژوهشی مطرح است. از این رو، این پژوهش با بهره‌گیری از تحلیل اسناد و روش دلفی، تلاش دارد تا راهکارهای اولویت‌دار برای مواجهه با پیامدهای هوش مصنوعی در حوزه اشتغال در ایران را ارائه کند.

به این ترتیب، هدف از این پژوهش، ارائه راهکارهای اولویت‌دار برای رفع چالش‌ها و اثرات منفی کاربست هوش مصنوعی برای حوزه اشتغال با استناد به اسناد بالادستی مربوطه و توصیه‌های بین‌المللی است و در این راستا پاسخ به پرسش‌های زیر مورد نظر است:

- چه راهکارهایی برای کاهش اثرات منفی هوش مصنوعی و بهره‌برداری بهینه از آن در حوزه اشتغال ایران وجود دارد؟

هوش مصنوعی در دهه‌های اخیر، تأثیر تحول‌آفرینی بر اقتصاد و بازار کار جهانی داشته است. راهکارهای هوش مصنوعی همچون یادگیری ماشینی و شبکه‌های عصبی، به وسیله کامپیوترها و سیستم‌ها، توانایی انجام وظایف پیچیده و محاسبات سریع را دارند. در حال حاضر هوش مصنوعی در محصولات و خدمات مختلف به کار رفته و موجب افزایش کارایی آنها می‌شود از این رو، شرکت‌ها در بخش‌ها و فرآیندهای مختلف از هوش مصنوعی استفاده می‌کنند. براساس پیش‌بینی گارتنر هوش مصنوعی مولد طی سال‌های آینده روند روبه‌رشد سریعی خواهد داشت. تا جایی که این مؤسسه تحقیقاتی پیش‌بینی می‌کند ۸۰ درصد شرکت‌ها تا سال ۲۰۲۶ از برنامه‌های مبتنی بر هوش مصنوعی که توسط خود یا سایر شرکت‌ها توسعه یافته، استفاده خواهند کرد [۱]. تمایل شرکت‌ها در کاربست مزایای هوش مصنوعی، مانند نوآوری‌های پیشین، فرصت‌ها و مشاغل جدیدی را به همراه دارد و در عین حال برای برخی مشاغل خاص نیز خطراتی دارد. گارتنر پیش‌بینی می‌کند که کاربردهای هوش مصنوعی می‌تواند میلیون‌ها شغل را حذف کند و بهبودهای بیشتر در هوش مصنوعی می‌تواند به جای کمک به مشاغل، به ضرر آنها باشد. در عین حال می‌تواند دو میلیون شغل جدید نیز تا سال ۲۰۲۵ از طریق هوش مصنوعی ایجاد شود [۲]. همچنین، مطالعاتی که بر تحلیل وظایف شغلی متمرکز هستند، ۳۶۷ شغل را شناسایی کرده‌اند که در برابر پیشرفت‌های فناوری آسیب‌پذیر هستند. رشد اشتغال در این مشاغل در سال‌های اخیر کمتر از مشاغل غیرآسیب‌پذیر بوده، که می‌تواند نمایان‌گر تأثیر منفی فناوری بر برخی مشاغل باشد [۳]. به‌عنوان مثال، در شغل مترجمی موجب کاهش درخواست جذب و درآمد می‌شود، در حالی که توسعه‌دهندگان وب از بهبودهای هوش مصنوعی بهره‌مند می‌شوند [۴]. به این ترتیب، در عین حال که هوش مصنوعی فرصت‌های بی‌شماری را در رشد و تغییر اقتصاد جهانی فراهم می‌کند، پیش‌بینی پیامدهای کاربست آن برای اقتصادها و جوامع به‌ویژه در حوزه اشتغال و بازار کار دشوار بوده و تأثیر آن براساس نقش‌های شغلی و بخش‌ها متفاوت است و پتانسیل افزایش نابرابری را داشته و باعث ایجاد تغییرات عمیق بالقوه در بسیاری از مشاغل و بخش‌ها می‌شود [۵]. به‌گونه‌ای که باوجود چشم‌انداز افزایش بهره‌وری به واسطه هوش مصنوعی، تهدید جایگزینی انسان در برخی مشاغل هم‌اکنون از دغدغه‌های سیاست‌گذاران این حوزه است. بررسی‌ها و مطالعات نشان می‌دهد که تفاوت در ساختارهای شغلی و زیرساخت‌های مربوط به توسعه فناوری باعث عمق تأثیر هوش

• اولویت‌بندی این راهکارها چگونه است؟

برای پاسخ به این سوالات، ابتدا اسناد بالادستی کشور ایران و توصیه‌های نهادهای بین‌المللی در حوزه هوش مصنوعی و اشتغال تحلیل می‌شوند. سپس، با استفاده از روش دلفی، گروهی از ۱۴ خبره در این حوزه برای تکمیل و نهایی‌سازی راهکارهای پیشنهادی استفاده می‌شود. در نهایت، برای اولویت‌بندی راهکارها، از روش AHP و نرم‌افزار سوپردسیژن بهره گرفته می‌شود.

ساختار این مقاله به این صورت است که در بخش دوم، روش پژوهش بیان شده است. در بخش سوم، چالش‌ها و اثرات کاربست هوش مصنوعی در حوزه اشتغال بیان می‌شود. در بخش چهارم، تحلیل یافته‌ها ارائه می‌شود. در نهایت، در بخش پنجم، نتیجه‌گیری و پیشنهاد برای پژوهش‌های آتی بیان خواهد شد.

۲- روش پژوهش

این پژوهش، از نظر هدف، کاربردی و از نظر ماهیت، پژوهشی-کیفی است که به مرور اسناد کتابخانه‌ای می‌پردازد. برای انجام این پژوهش در گام اول نیاز به شناسایی و انتخاب اسناد بالادستی است که به این منظور از روش اسنادی استفاده می‌شود. برای انتخاب اسناد بالادستی، اولین تأکید این است که از اسناد راهبردی ملی انتخاب شود و معیارهایی همچون ارتباط با موضوع هوش مصنوعی و اشتغال، اهمیت اسناد در سیاست‌گذاری و جامعیت آن‌ها در نظر گرفته شود. پس از انتخاب اسناد بالادستی، با روش تحلیل مضمون، این اسناد بررسی عمیق شده و ملاحظات مربوطه، استنتاج می‌شود. تحلیل مضمون فرایندی برای تحلیل داده‌های متنی است و داده‌های پراکنده و متنوع را به داده‌هایی غنی و تفصیلی تبدیل می‌کند [۸]. تحلیل مضمون مهارت‌های اساسی مورد نیاز برای بسیاری از تحلیل‌های کیفی را فراهم می‌کند [۹]. از این رو، در این پژوهش ابتدا اسناد مرور شده و بندهای مرتبط با موضوعات هوشمندسازی و اشتغال، انتخاب شده و مضمون اولیه آن استخراج می‌شود. در مرحله بعد با دسته‌بندی و تجمیع این مضامین اولیه، مضامین اصلی و کلیدی نگاشت می‌شود. سپس این مضامین اصلی و کلیدی نیز دسته‌بندی شده تا ملاحظات برگرفته از اسناد تبیین شود. در این پژوهش، در تحلیل اسناد و استخراج مضامین کلیدی، تلاش شده تا خلأها و نواقص موجود در این حوزه، با استناد به اسناد، در تدوین راهکارهای پیشنهادی مورد توجه قرار گیرد. در تکمیل آن توصیه‌های سازمان‌های معتبر بین‌المللی در این زمینه لحاظ شده و نتایج تحلیل می‌شود. در مرحله بعد راهکارهای پیشنهادی در فرایند دلفی در اختیار خبرگان قرار گرفته و در فرایند دلفی راهکارها،

حذف، اصلاح و افزوده شده و در نهایت این راهکارها با استفاده از پرسش‌نامه به روش AHP و نرم‌افزار سوپردسیژن اولویت‌بندی می‌شود. برای این منظور، ابتدا اسناد مرور شده و بندهای مرتبط با موضوعات هوش مصنوعی و اشتغال استخراج می‌گردند. سپس، تحلیل مضمون برای شناسایی الگوها و نکات کلیدی به کار گرفته می‌شوند. در نهایت، راهکارهای موجود دسته‌بندی و در فرآیند دلفی با مشارکت خبرگان بررسی و اصلاح خواهند شد تا اطمینان حاصل شود که این راهکارها متناسب با شرایط ایران قابل اجرا باشند. در نهایت، در این پژوهش راهکارهای اولویت‌دار به منظور پاسخ‌گویی به چالش‌ها و پیامدهای منفی هوش مصنوعی در حوزه اشتغال معرفی می‌شود. لازم به ذکر است، در ارائه راهکارهای پیشنهادی، این پژوهش با تحلیل اسناد موجود، خلأهای مرتبط با سیاست‌گذاری در حوزه هوش مصنوعی و اشتغال را نیز در نظر گرفته و نقاط ضعف احتمالی در اسناد مورد مطالعه را شناسایی نموده است.

در خصوص انتخاب روش AHP در این پژوهش، نکات زیر مورد توجه قرار گرفته است:

۱. ساختار سلسله‌مراتبی و نبود وابستگی بین معیارها: ساختار مسأله پژوهش حاضر بر اساس سه بُعد اصلی (آموزش و مهارت، استخدام نیروی کار، و سواد دیجیتال) و مجموعه‌ای از راهکارهای پیشنهادی در هر بُعد، به گونه‌ای طراحی شده که میان ابعاد و نیز میان راهکارها وابستگی متقابل مستقیم وجود ندارد. به عبارتی، هر راهکار در بُعد خود و به صورت مستقل اولویت‌بندی شده و تأثیرگذاری بین راهکارها یا میان ابعاد مدل در نظر گرفته نشده است. از این رو، استفاده از مدل سلسله‌مراتبی کاملاً با منطق AHP سازگار بوده است.

۲. پشتیبانی روش AHP از مدل‌های سیاست‌گذاری با ساختار خطی: مطالعات متعددی نشان داده‌اند که در مدل‌های سیاست‌گذاری که اولویت‌بندی راهکارها در چارچوبی سلسله‌مراتبی و غیروابسته انجام می‌شود، روش کارآمدی است. به عنوان نمونه، ساعتی (۲۰۰۸) که بنیان‌گذار روش AHP است، اشاره می‌کند که "روش AHP برای مسائلی مناسب‌تر است که بتوان آن‌ها را به صورت سلسله‌مراتبی ساختاردهی کرد، به طوری که سطوح مشخص و عناصری مستقل در هر سطح وجود داشته باشند [۱۰]."

۳. عدم نیاز به مدل‌سازی شبکه‌ای پیچیده در مسئله حاضر: از آنجا که در این پژوهش هدف صرفاً اولویت‌بندی نهایی راهکارها بر اساس قضاوت خبرگان بوده و نه تحلیل بازخورهای درونی یا تعاملات درونی بین معیارها یا راهکارها، استفاده از سایر روش‌های

انجام داده و نتایج مطالعات خود را ارائه کرده است. سازمان توسعه و همکارهای اقتصادی^۵ نیز رصدخانه سیاست‌گذاری هوش مصنوعی^۶ را تأسیس کرده است. این رصدخانه تجزیه و تحلیل سیاست‌های مبتنی بر شواهد و داده‌ها را در مورد حوزه‌های تأثیر هوش مصنوعی ارائه می‌دهد و طرح سیاستی هوش مصنوعی (در بیش از ۶۰ کشور و منطقه) را در داشبوردهای کشوری ارائه می‌دهد که قابل مرور و مقایسه است [۱۴ و ۱۵].

مطالعات این سازمان‌ها نشان می‌دهد که هوش مصنوعی تأثیرات مثبت و منفی بر بازار کار کشورها دارد. این مطالعات نشان می‌دهد که حدود یک‌سوم از مشاغل، به‌ویژه در مشاغل با مهارت‌های تخصصی، در ایالات متحده به‌شدت در معرض تأثیرات هوش مصنوعی هستند [۱۶]. از نگاه صندوق بین‌المللی پول، در کشورهای توسعه‌یافته این اثر بیشتر خود را نشان می‌دهد و سهم مشاغلی که از توسعه هوش مصنوعی متأثر می‌شوند، تا ۶۰ درصد می‌رسد. پیش‌بینی این صندوق آن است که تقریباً در نیمی از این مشاغل، اثرگذاری یکپارچه‌سازی هوش مصنوعی در قالب بهره‌مندی از مزایا و بهبود بهره‌وری ظهور کند و همزمان در نیمی دیگر، با عهده‌دار شدن وظایف کلیدی که پیش‌تر توسط انسان‌ها انجام می‌شد، به کاهش میل کارفرمایان به استخدام افراد و همچنین کاهش درآمد نیروهای کار بینجامد. با نگاه بدبینانه نیز توسعه این فناوری در برخی موارد حتی می‌تواند به حذف کامل برخی مشاغل بینجامد. در سمت مقابل، شرایط برای بازارهای نوظهور و کشورهای کم‌درآمد تا حدی متفاوت خواهد بود و میزان اثر پذیرفتن آن به ترتیب ۴۰ و ۲۶ درصد برآورد شده است. همچنین فراگیری هوش مصنوعی می‌تواند باعث ایجاد نابرابری‌های ثروت و درآمدی درون کشورها نیز شود. افراد توانمند و ماهر در به‌کارگیری فناوری‌ها می‌توانند به حقوق دریافتی بالاتری دست یابند و نیروهای مسن، برای تطبیق با شرایط جدید کار دچار چالش خواهند شد [۱۷]. به این مفهوم که هوش مصنوعی نابرابری‌های بازار کار را بیشتر می‌کند - به‌ویژه بین نیروهای کاری که مهارت‌های استفاده مؤثر از هوش مصنوعی را دارند و افرادی که این مهارت را ندارند [۱۸]. گزارش اتحادیه اروپا در سال ۲۰۲۱، پیرامون آینده کار و اشتغال نیز ادعان دارد اثر تغییر فناوری بر کار و اشتغال چندوجهی است. از یک سو، فناوری بر سطح اشتغال با افزایش یا جابجایی مشاغل تأثیر می‌گذارد و با تغییر سطح دستمزد اثرات متفاوتی بر مشاغل دارد. از سوی دیگر، فناوری بر ماهیت و کیفیت کار نیز تأثیر می‌گذارد و نحوه انجام کار و تخصیص وظایف

تصمیم‌گیری چند معیاره همچون ANP و DANP که مدل‌سازی شبکه‌ای پیچیده‌تری دارند، در این سطح از تصمیم‌گیری نه تنها ضرورتی ندارد، بلکه می‌تواند باعث افزایش غیرضروری پیچیدگی شود، بدون آنکه ارزش تحلیلی افزوده‌ای ارائه دهد.

۴. تطابق AHP با مطالعات مشابه در زمینه سیاست‌گذاری عمومی و اجتماعی: در حوزه‌هایی نظیر برنامه‌ریزی راهبردی، توسعه سیاست‌های عمومی و تحلیل پیامدهای فناوری‌های نو، استفاده از AHP رایج است [۱۱].

بر این اساس، انتخاب روش AHP در این پژوهش با ساختار مدل، اهداف مطالعه، سطح تحلیل و داده‌های گردآوری‌شده از خبرگان همخوانی دارد و به دلیل سادگی، شفافیت، و قابلیت تفسیر بالا؛ گزینه‌ای مناسب برای تحلیل و اولویت‌بندی راهکارها می‌باشد.

۳- چالش‌ها و اثرات کاربست هوش مصنوعی در حوزه اشتغال

همزمان با پیشرفت‌های عظیم و انقلاب‌های فناورانه، حداقل به‌طور موقت مشکلات جدی را در زمینه اشتغال به‌همراه داشته است. توسعه هوش مصنوعی نیز به عنوان یک فناوری تحول‌آفرین، باعث نگرانی‌های عمده‌ای می‌شود. زیرا با از میان رفتن برخی مشاغل و الزام به جایگزینی مشاغل دیگر تعمیق نابرابری به همراه خواهد داشت. در زمینه تحلیل پیامدهای فناوری‌های نوظهور مانند هوش مصنوعی بر بازار کار، سازمان‌های معتبری فعالیت دارند. به طور مثال صندوق بین‌المللی پول^۱ که یک نهاد مالی است با هدف ایجاد ثبات در ارزها و اقتصاد جهانی تأسیس شده است. یکی از جنبه‌هایی که این صندوق بررسی می‌کند، حوزه مشاغل و نیروی کار است و گزارشاتی را در تحلیل اثرات هوش مصنوعی بر بازار کار، کارگران و اشتغال ارائه کرده است. سرویس تحقیقات پارلمان اروپا^۲ نهاد دیگری است که در زمینه مخاطرات هوش مصنوعی برای بازار کار اتحادیه اروپا گزارشات تحلیلی را ارائه کرده است. این نهاد مأموریت دارد تجزیه و تحلیل مستقل، عینی و معتبر در مورد موضوعات سیاستی مرتبط با اتحادیه اروپا ارائه دهد [۱۲]. بانک جهانی نیز نهاد اداری داخلی تحت مدیریت خود با نام کمیته هوش مصنوعی^۳ دارد که بر اجرای سیاستهای بانک جهانی در زمینه دسترسی به اطلاعات و هوش مصنوعی فعالیت می‌کند و گزارشات سالانه در این زمینه ثبت می‌کند [۱۳]. سازمان جهانی کار^۴ نیز در زمینه اثرات هوش مصنوعی مولد بر کمیت و کیفیت شغل ارزیابی

^۵ International Labour Organization (ILO)

^۶ Organization for Economic Co-operation and Development (OECD)


^۷ AI Policy Observatory

^۱ International Monetary Fund

^۲ European Parliamentary Research Service (EPRS)

^۳ AI Committee

بازارهای نوظهور و اقتصادهای در حال توسعه که اغلب هنوز به کار فیزیکی و صنایع سنتی متکی هستند، ممکن است در ابتدا با اختلالات ناشی از هوش مصنوعی کمتر مواجه شوند. با این حال، این اقتصادها با توجه به کمبود زیرساخت و نیروی کار ماهر، ممکن است دستاوردهای اولیه بهره‌وری مبتنی بر هوش مصنوعی را نیز از دست بدهند. با گذشت زمان، شکاف هوش مصنوعی می‌تواند نابرابری‌های اقتصادی موجود را تشدید کند، به‌طوری که اقتصادهای پیشرفته از هوش مصنوعی برای مزیت رقابتی استفاده می‌کنند در حالی که بازارهای نوظهور و اقتصادهای در حال توسعه با ادغام هوش مصنوعی در مدل‌های رشد خود دست و پنجه نرم می‌کنند (شکل ۱) [۲۳].



شکل ۱. پیشران‌های اولیه و موانع بعدی توسعه هوش مصنوعی در بازار کار کشورهای در حال توسعه و کشورهای توسعه یافته

برای پاسخ به جهانی شدن، ایجاد تغییرات در بیشتر مشاغل در کشورهای در حال توسعه اتفاق می‌افتد که در نتیجه، هزینه‌های نسبی کلی نیروی کار را کاهش می‌دهد. اتوماسیون منجر به تقاضای کمتر برای نیروی کار تولیدی در همه جا می‌شود. فناوری‌های تحول‌آفرین نظیر هوش مصنوعی باعث می‌شوند که شرکت‌ها توانایی خودکارسازی داشته و نیروی کار را با ماشین‌های تولیدی جایگزین کنند و با نوآوری نیز تعداد وظایف و محصولات را افزایش دهند. در پاسخ به اتوماسیون، اشتغال در بخش‌های قدیمی کاهش می‌یابد. در پاسخ به نوآوری‌های تحول‌آفرین، بخش‌ها یا وظایف جدید پدیدار می‌شوند. به این ترتیب، آینده کلی اشتغال به نوآوری، اتوماسیون، مهارت نیروی کار و نیز مهارت بخش‌ها یا وظایف جدیدی که ظهور می‌کنند، بستگی دارد [۲۴].

همچنین آمارها نشان می‌دهد که تقریباً همه مشاغل تحت تأثیر اتوماسیون قرار خواهند گرفت. اما تنها حدود ۵ درصد مشاغل به طور کامل خودکار می‌شوند و در واقع حدود ۳۰ درصد از فعالیت‌ها در ۶۰ درصد از مشاغل می‌توانند خودکار باشند. این بدان معنی است که اکثر کارگران در کنار ماشین‌هایی که به سرعت در حال تکامل هستند کار خواهند کرد و ماهیت این مشاغل تغییر خواهد کرد [۲۵]. آمارهایی نیز به صورت بدبینانه تر مطرح می‌شوند و بیان می‌کنند که حدود ۱۵ درصد از نیروی کار جهانی، یا حدود ۴۰۰

در مشاغل بستگی به نوع فناوری دارد. همان‌طور که فناوری ممکن است به بهبود مهارت‌ها و بالا بردن کیفیت کار کمک کند، می‌تواند فرآیندهای مهارت زدایی را ایجاد کند و کار کم درآمد و دارای استقلال کمتر ایجاد کند [۱۹]. یکی از ابعاد مهمی که باید در نظر گرفت، مقبولیت اجتماعی هوش مصنوعی است. مقبولیت ممکن است بسته به نقش‌های شغلی متفاوت باشد. عدم اطمینان به ویژه در بازارهای کار آشکار می‌شود. همچنین هوش مصنوعی ممکن است راه را برای جابه‌جایی شغلی قابل توجه هموار کند و منجر به ظهور بخش‌ها و نقش‌های شغلی جدید و ناپدید شدن سایرین شود. فراتر از اثرات فوری شغلی، یکی دیگر از ابعاد مهم اقتصادی کانال درآمد سرمایه است. از آنجایی که هوش مصنوعی باعث کارایی و نوآوری می‌شود، کسانی که صاحب فناوری‌های هوش مصنوعی هستند یا در صنایع مبتنی بر هوش مصنوعی سهام دارند، ممکن است افزایش درآمد سرمایه را تجربه کنند. این تغییر به‌طور بالقوه می‌تواند نابرابری‌ها را تشدید کند [۲۰].

هوش مصنوعی این باور را به چالش می‌کشد که فناوری عمدتاً مشاغل متوسط و در برخی موارد با مهارت‌های پایین را تحت تأثیر قرار می‌دهد: الگوریتم‌های پیشرفته آن اکنون می‌توانند نقش‌های با مهارت بالا را که قبلاً در برابر اتوماسیون مصون بودند، تقویت یا جایگزین کنند. حتی مشاغل با مهارت بالا که قبلاً به دلیل پیچیدگی و اتکا به تخصص عمیق، از اتوماسیون مصون بودند، اکنون با اختلالات احتمالی مواجه می‌شوند. مشاغلی که نیاز به قضاوت دقیق، حل خلاقانه مسئله، یا تفسیر پیچیده داده دارند - به طور سنتی حوزه حرفه‌ای با تحصیلات عالی - اکنون ممکن است با الگوریتم‌های هوش مصنوعی پیشرفته جایگزین شود که به طور بالقوه نابرابری را در بین مشاغل و درون مشاغل تشدید می‌کند [۲۱]. به‌طور مثال، در شغل مهندسی نرم‌افزار که در دسته مشاغل با مهارت بالا قرار دارد، در آینده نیازمند مهارت‌های پیچیده‌تری در برنامه‌نویسی و مهارت‌های نرم مانند حل مسئله و ارتباطات بین‌فردی است و هوش مصنوعی می‌تواند بسیاری از وظایف مهندسان نرم‌افزار را خودکار نماید. بنابراین این مشاغل نیاز به کسب مهارت لازم برای تطبیق با این تغییرات دارند [۲۲].

همچنین احتمالاً تأثیر هوش مصنوعی در کشورهای مختلف در سطوح مختلف توسعه یا با ساختارهای اقتصادی متفاوت به طور قابل توجهی متفاوت است. اقتصادهای پیشرفته، با صنایع بالغ و اقتصادهای مبتنی بر خدمات، معمولاً دارای تمرکز بالاتری از مشاغل در بخش‌هایی هستند که به وظایف پیچیده شناختی نیاز دارند. بنابراین، این اقتصادها هر دو مستعدتر و در عین حال موقعیت بهتری برای بهره‌مندی از نوآوری‌های هوش مصنوعی دارند. برعکس،

اقتصادی، اجتماعی، فرهنگی و سیاسی و آیین نامه حمایت از آزادکاران فعال در حوزه اقتصاد دیجیتال می‌باشد. در بررسی عمیق این اسناد، مضمون‌های اولیه از داخل محتوای بندها استخراج شد که نمونه آن در جدول زیر مشاهده می‌شود.

جدول ۱. نمونه استنتاج مضامین اولیه

سند تحول دیجیتال			
کد	شماره بند	متن	مضمون اولیه
۲	سیاست ۴-۴	توسعه محیط کار دیجیتال با تمرکز بر ارتقای مهارت‌های نرم و سخت دیجیتال نیروی کار	توانمندسازی کارکنان در مهارت‌های دیجیتال
۳	سیاست ۷-۱۰	توسعه فرهنگ عمومی دیجیتال	ایجاد فرهنگ دیجیتال
سند راهبردی ج.ا. در فضای مجازی			
کد	شماره بند	متن	مضمون اولیه
۴	ج-۱۷	تربیت و توانمندسازی شبکه سرمایه انسانی متخصص در منطقه و ایجاد مزیت راهبردی برای کشور در این حوزه	توانمندسازی نیروی انسانی متخصص
۵	د-۲۸	ترویج و ارتقای سواد فضای مجازی (از قبیل فرهنگ کاربری و هشیارسازی)	ارتقای مهارت دیجیتالی و فرهنگ دیجیتالی عمومی
سند ملی آمایش سرزمین			
کد	شماره بند	متن	مضمون اولیه
۱۴	۹	توسعه زیرساخت‌ها و توانمندی‌های ارائه خدمات علمی، آموزشی و درمانی به شهروندان کشورهای همسایه در شهر منطقه‌های استان‌های مرزی	توسعه زیرساخت‌ها و توانمندی‌های ارائه خدمات علمی، آموزشی و درمانی
۱۵	۹۴	ارتقاء سطح آموزش، پژوهش و بهره‌وری نیروی کار در جهت افزایش سهم منابع انسانی در ترکیب عوامل مؤثر در تولید ثروت ملی متناسب با تخصص‌ها، ظرفیت‌ها و مزیت‌های منطقه‌ای	ارتقاء سطح آموزش، پژوهش و بهره‌وری نیروی کار جهت افزایش سهم منابع انسانی در ترکیب عوامل تولید
سیاست‌های کلی اشتغال			
کد	شماره بند	متن	مضمون اولیه
۲۳	بند ۳	ایجاد فرصت‌های شغلی پایدار با تأکید بر استفاده از توسعه فناوری و اقتصاد دانش‌بنیان و آینده‌نگری نسبت به تحولات آنها در سطح ملی و جهانی	استفاده از فناوری و توسعه مهارت‌های مورد نیاز با توجه به تحولات در ایجاد فرصت‌های شغلی
سیاست کلی تولید ملی و حمایت از کار و سرمایه ایرانی			

میلیون کارگر، ممکن است تا ۲۰۳۰ با ایجاد اتوماسیون شغل خود را از دست بدهند و در بدبینانه‌ترین حالت ممکن این رقم به ۳۰ درصد یا ۸۰۰ میلیون کارگر افزایش می‌یابد. در خوش‌بینانه‌ترین حالت آن، تنها حدود ۱۰ میلیون نفر، نزدیک به صفر درصد از نیروی کار جهانی، شغل خود را از دست می‌دهند [۲۶]. در آماری که توسط مؤسسه تحقیقاتی BCG منتشر شده است، بیان شده که طی ۵ سال از سال ۲۰۲۰ حدود ۷,۱ میلیون شغل از بین می‌رود و ۴۷٪ از مشاغل ممکن است با استفاده از هوش مصنوعی جایگزین می‌شود. در حقیقت باوجودی که رشد فناوری می‌تواند در ارتقای اشتغال کمک کند اما اثرات منفی آن سیاست‌گذاران و دولت‌ها را به تدوین راهکار به منظور مقابله با این اثرات ملزم کرده است [۲۷].

ایران نیز از این قاعده مستثنی نیست...

۴- تحلیل یافته‌ها

به منظور استنتاج ملاحظات اشتغال و نیروی کار در عصر هوش مصنوعی به اسناد مرتبط با حوزه دیجیتالی شدن و هوشمندسازی پرداخته می‌شود. برای شناسایی اسناد، از روش اسنادی استفاده شد. روش نمونه‌گیری در روش پژوهش اسنادی به دو صورت نمونه‌گیری عمدی و نظری و نمونه‌گیری گلوله برفی است [۲۸]. در این پژوهش با روش نمونه‌گیری عمدی و نظری با توجه به محورها و اهداف پژوهش، اسناد بالادستی بررسی و گزینش نهایی می‌شوند. اسناد بالادستی از جنس قوانین و مقررات هستند و به تصویب عالی‌ترین سطوح مقررات‌گذاری و قانون‌گذاری در نظام حقوقی رسیده‌اند. اسناد بالادستی شامل سیاست‌های کلی نظام (مصوب مجمع تشخیص مصلحت نظام و ابلاغ مقام رهبری)؛ لوایح دولت؛ آیین‌نامه‌های دولت (مصوب هیئت وزیران)؛ مصوبات و آیین‌نامه‌های داخلی مجلس؛ شورای عالی انقلاب فرهنگی؛ شورای عالی فضای مجازی؛ لایحه برنامه هفتم توسعه می‌باشد. فهرست اولیه‌ای از اسناد تهیه شده و سپس با توجه به هدف پروژه و ابعاد آن شامل موضوعات مرتبط با نیروی انسانی، نیروی کار و ماهر و موضوعات مرتبط با فناوری جدید و هوش مصنوعی می‌باشد. اسنادی که برای بررسی عمیق از بین اسناد بالادستی انتخاب شد، شامل سند تحول دیجیتال، سند راهبردی ج.ا. در فضای مجازی، تبیین الزامات شبکه ملی اطلاعات (مصوبه ۳۵)، طرح کلان و معماری شبکه ملی اطلاعات (مصوبه ۶۶)، سند راهبردی بخش ارتباطات و فناوری اطلاعات در برنامه ششم توسعه کشور، سند راهبردی توسعه رایانش ابری ج.ا.ا، سند ملی آمایش سرزمین، سند راهبردی کشور در امور نخبگان، سیاست کلی تولید ملی و حمایت از کار و سرمایه ایرانی، سیاست‌های کلی اشتغال، لایحه برنامه پنج‌ساله هفتم توسعه

		۱۵	ارتقاء سطح آموزش، پژوهش و بهره‌وری نیروی کار جهت افزایش سهم منابع انسانی در ترکیب عوامل تولید
		۱۶	لزوم تقویت زیرساخت‌های آموزشی، پژوهشی و مهارتی در مناطق مختلف برای نخبگان
		۱۷	لزوم فراهم سازی امکانات لازم جهت فعالیت‌های علمی
		۱۸	پشتیبانی از توانمندسازی افراد و گروه‌های نخبه در تولید و ارائه محصولات بومی
		۲۱	لزوم استفاده از دانش و فناوری در عرصه تولید و نیاز به کسب مهارت نیروی تولید برای به‌کارگیری فناوری
		۲۲	لزوم آموزش نیروی انسانی متخصص، ماهر و کارآمد متناسب با نیازهای بازار کار
N2	استخدام نیروی انسانی ماهر	۹	نظارت بر پایگاه و سکویای نرم افزاری به منظور رعایت منصفانه بودن و شفافیت قراردادهای کاری و حقوق طرفین
		۱۹	لزوم تأمین نیروی انسانی ماهر و متخصص لازم با همکاری وزارت ارتباطات و فناوری اطلاعات و سازمان اداری و استخدامی کشور
		۲۰	لزوم پرداخت اعتبارات از محل منابع عمومی و در قالب بودجه‌های سنواتی به دانشگاه‌ها و موسسات آموزشی، پژوهشی و فناوری با هدف ارتقای بهره‌وری افزایش اثربخشی منابع آموزش عالی، پژوهش و فناوری
		۲۳	استفاده از فناوری و توسعه مهارت‌های مورد نیاز با توجه به تحولات در ایجاد فرصت‌های شغلی
N3	تقویت فرهنگ و سواد دیجیتال	۳	ایجاد فرهنگ دیجیتال
		۵	ارتقای مهارت دیجیتالی و فرهنگ دیجیتالی عمومی
		۱۱	توسعه سواد دیجیتال
		۱۴	توسعه زیرساخت‌ها و توانمندی‌های ارائه خدمات علمی، آموزشی و درمانی

جدول ۳ مضامین اصلی و کلیدی و کد مضامین اولیه ذیل آن را نشان می‌دهد.

کد	شماره بند	متن	مضمون اولیه
۲۱	بند ۳	گسترش اقتصاد دانش‌بنیان با تأکید بر توسعه مؤلفه‌های اصلی آن، از جمله: زیرساخت‌های ارتباطی، زمینه‌های تسهیل تبدیل دستاوردهای پژوهش به فناوری و گسترش کاربرد آن، حمایت قانونی از حقوق اشخاص حقیقی و حقوقی و مرتبط کردن بخشهای علمی و پژوهشی با بخشهای تولیدی کشور	لزوم استفاده از دانش و فناوری در عرصه تولید و نیاز به کسب مهارت نیروی تولید برای به‌کارگیری فناوری

به این ترتیب ۲۲ مضمون اولیه از محتوای اسناد استخراج شد و در گام بعد روش تحلیل مضمون، تعیین مضامین اصلی و کلیدی با دسته‌بندی مضامین اولیه و کدگذاری آنها انجام شد. جدول ۲ نتایج حاصل از انجام این گام از فرایند است.

جدول ۲. تعیین مضامین اصلی و کلیدی

کد	مضمون اولیه	مضمون اصلی و کلیدی	کد
۱	برنامه‌های آموزش مهارت‌های دیجیتال برای کارکنان	آموزش و تقویت تخصص و مهارت دیجیتال نیروی انسانی	N1
۲	توانمندسازی کارکنان در مهارت‌های دیجیتال		
۴	توانمندسازی نیروی انسانی متخصص		
۶	تحقق استقلال شبکه ملی اطلاعات با اصول حاکم بر مدیریت آن (خودگردانی با نیروهای متخصص داخلی)		
۷	ایجاد بستر حمایتی برای ارتقای مهارت‌های فعالان حوزه آزادکاری		
۸	برنامه‌های آموزشی به منظور توانمندسازی فارغ‌التحصیلان رشته‌های مرتبط با اقتصاد دیجیتال و فعالان این حوزه		
۱۰	شناسایی رشته‌ها و تخصص‌های مورد نیاز دانشگاهی برای رشد و ارتقای سطح منابع انسانی		
۱۲	به‌روزرسانی ساختار آموزش، مهارت و توانمندی نیروهای تخصصی مطابق با فناوری‌های نوین		
۱۳	تدوین و اجرای دوره های آموزشی و توانمندسازی نیروی انسانی متخصص فعلی		

جدول ۳. مضامین اصلی و کلیدی و کد مضامین اولیه

کد مضامین اصلی و کلیدی	مضمون اصلی و کلیدی	کدهای مضامین اولیه
N1	آموزش و تقویت تخصص و مهارت دیجیتال نیروی انسانی	۱،۲،۴،۶،۷،۸،۱۰، ۱۲،۱۳،۱۵،۱۶، ۱۷،۱۸،۲۱،۲۲
N2	استخدام نیروی انسانی ماهر	۹،۱۹،۲۰،۲۳
N3	تقویت فرهنگ و سواد دیجیتال	۳،۵،۱۱،۱۴

۴-۱- ملاحظات استنتاج شده از اسناد بالادستی

در این مرحله به منظور استنتاج ملاحظات اسناد بالادستی برای اشتغال در حوزه هوش مصنوعی با تعیین شدن مضامین اصلی و کلیدی، حوزه‌های کلیدی نیز تبیین شد. بنابراین ابتدا این حوزه‌ها تحلیل می‌شود و سپس براساس تحلیل صورت گرفته برای هریک ملاحظات مربوطه بیان می‌شود.

درسند راهبردی بخش ارتباطات و فناوری اطلاعات در برنامه ششم توسعه کشور بر اصلاح فرآیندهای آموزشی و انطباق مهارت‌ها و توانمندی‌های نیروی انسانی در راستای تأمین نیازهای فعلی و آتی بخش ارتباطات و فناوری اطلاعات تأکید شده است. در سند تبیین الزامات شبکه ملی اطلاعات نیز تقویت نیروهای تخصصی داخلی به منظور استقلال در مدیریت شبکه ملی اطلاعات تأکید شده است. همچنین سند تحول دیجیتال کشور بر توسعه محیط کار دیجیتال با تمرکز بر ارتقای مهارت‌های نرم و سخت دیجیتال و ارتقای مهارت‌های دیجیتال کارکنان دولت تأکید شده و بیان شده که شاخص‌های مهارتی بزرگسالان در حوزه فناوری اطلاعات و ارتباطات و تربیت و توانمندسازی شبکه سرمایه انسانی متخصص در منطقه باید ارتقا یابد. لذا لازم است در تحقق اهداف حوزه اشتغال در عصر فناوری‌های نوظهور، به توانمندسازی نیروی انسانی توجه شده و برنامه‌های آموزشی تخصصی و مهارتی لازم تدوین گردد. در این راستا، برنامه‌ریزی به منظور توسعه آموزش، نظارت و تشویق نیروهای انسانی به کسب تخصص و آموزش برای پیشبرد اهداف توسعه بخش انجام گیرد.

همان‌گونه که ذکر شد هوش مصنوعی علاوه بر ازبین بردن مشاغل

و ایجاد ریسک در حوزه اشتغال، فرصت‌های بی‌شماری را نیز به همراه دارد. چنانچه موضوع حذف مشاغل و بیکار شدن افراد به طور قابل توجهی بیشتر از ایجاد مشاغل جدید باشد، بدون شک، چالش‌های که به وجود می‌آید نیازمند راهکارها و استراتژی‌های خلاقانه‌ای است که شامل حمایت از توسعه مهارت‌ها و ایجاد مشاغل جدید می‌شود. بنابراین، در گام نخست، تربیت نیروی کار توانمند تقویت آموزش و آموزش‌های حرفه‌ای، ارتقای نوآوری و کارآفرینی، و ایجاد مدل‌های کاری انعطاف‌پذیرتر از جمله راه‌حل‌های پیشنهادی هستند. دولت‌ها نیز می‌توانند با ارائه مشوق‌های خاص برای بخش‌هایی که کمتر در معرض اتوماسیون قرار دارند یا اعطای معافیت‌های مالیاتی به شرکت‌هایی که در نیروی کار سرمایه‌گذاری می‌کنند، نقش مؤثری ایفا کنند. برای رسیدن به هدف توسعه اشتغال، تدوین و اجرای برنامه‌های آموزشی با محوریت توانمندسازی فارغ‌التحصیلان رشته‌های مرتبط و فعالان این حوزه، به همراه نظارت بر پژوهش‌های مرتبط برای ارتقای دانش، ضروری است. هم‌زمان با پرورش نیروی کار متخصص، باید محیط‌های کاری دیجیتال تقویت شوند و تمرکز ویژه‌ای بر توسعه مهارت‌های نرم و سخت دیجیتالی نیروی کار صورت گیرد. علاوه بر آن، توسعه سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال، مطابق با تأکید اسناد مورد اشاره، از اهمیت بالایی برخوردار است. در نتیجه، می‌توان ملاحظات این اسناد را در سه حوزه اصلی یعنی آموزش و مهارت، استخدام نیروی کار، و سواد دیجیتال دسته‌بندی کرد.

• بُعد آموزش و مهارت

آموزش و مهارت به مجموعه‌ای از فرآیندهای ترکیبی اطلاق می‌شود که شامل کسب دانش از طریق یادگیری رسمی (آموزش) و توسعه توانایی‌ها و شایستگی‌های عملی (مهارت‌ها) است؛ فرآیندهایی که افراد را قادر می‌سازند تا وظایف مشخصی را انجام داده و به اهداف معین دست یابند [29 و 30]. به این ترتیب این مضمون ملاحظه زیر را دربرمی‌گیرد:

○ رصد مستمر تخصص‌های مورد نیاز در توسعه زیرساخت‌های حوزه هوشمندسازی و تدوین برنامه‌های آموزشی به‌روزرسانی ساختار آموزش به منظور توانمندسازی فارغ‌التحصیلان رشته‌های مرتبط و فعالان این حوزه و بهبود مهارت‌های دیجیتال نیروی انسانی در راستای تأمین نیازهای فعلی و آتی در فضای دیجیتال و هوشمند

• بُعد استخدام نیروی کار

استخدام نیروی کار به فرآیند جذب، گزینش و به کارگیری افراد برای انجام وظایف اقتصادی در سازمان‌ها اطلاق می‌شود. این مفهوم نه تنها به استخدام رسمی، بلکه به اشتغال انعطاف‌پذیر، خوداشتغالی و اشکال نوظهور اشتغال در اقتصاد دیجیتال نیز اشاره دارد [۳۱]. به این ترتیب این مضمون ملاحظه زیر را دربرمی‌گیرد:

○ افزودن شاخص‌های ارزیابی مهارت‌های مورد نیاز برای عصر هوشمند در فرایند استخدام نیروهای جدید و به‌روزرسانی شاخص‌های مهارتی به منظور توسعه محیط کار دیجیتال و هوشمند

• بُعد سواد دیجیتال

سواد دیجیتال به توانایی دستیابی، مدیریت، درک، یکپارچه‌سازی، ارتباط، ارزیابی و تولید اطلاعات از طریق فناوری‌های دیجیتال، به‌صورت ایمن و مناسب اطلاق می‌شود. این مفهوم شامل شایستگی‌هایی است که تحت عناوین مختلفی مانند سواد رایانه‌ای، سواد فناوری اطلاعات و ارتباطات (ICT)، سواد اطلاعاتی و سواد رسانه‌ای شناخته می‌شوند [۳۲]. به این ترتیب این مضمون ملاحظه زیر را دربرمی‌گیرد:

○ ایجاد سازوکارهایی به منظور ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال

۴-۲- توصیه‌های سازمان‌های بین‌المللی

در بررسی تأثیرات احتمالی فناوری‌هایی مانند هوش مصنوعی بر اقتصاد و جامعه، ضروری است که از پیش، برنامه‌ریزی دقیقی انجام شود تا مشاغل و بخش‌هایی که بیشترین تأثیر را تجربه می‌کنند شناسایی شوند. همچنین باید طرح‌هایی برای بازآموزی نیروی کار یا ایجاد فرصت‌های شغلی جدید پیش‌بینی شود [۳۳]. موفقیت در بهره‌گیری از مزایای هوش مصنوعی وابسته به آمادگی کشورها و توانایی نیروی کار در سازگاری با این فناوری نوین است. اقتصادهای پیشرفته و برخی بازارهای نوظهور، به دلیل زیرساخت‌های مناسب و سطح بالای آمادگی، در موقعیت مطلوبی برای بهره‌برداری از هوش مصنوعی قرار دارند. در مقابل، اقتصادهای کمتر توسعه‌یافته و بازارهای نوظهور با مشکلاتی نظیر ضعف زیرساخت‌ها، کمبود مهارت در نیروی کار و نبود چارچوب‌های نهادی مناسب مواجه هستند که این عوامل می‌تواند آن‌ها را در معرض تهدیدات رقابتی قرار دهد. مرحله توسعه اقتصادی هر کشور، تأثیر مستقیمی بر اولویت‌های آمادگی برای پذیرش هوش مصنوعی دارد. برای بهینه‌سازی مزایای

این فناوری، اقداماتی نظیر تدوین چارچوب‌های تنظیم‌گری، سرمایه‌گذاری در نوآوری‌های مکمل، تقویت زیرساخت‌های دیجیتال و توسعه سرمایه انسانی پیشنهاد می‌شود. این سرمایه‌گذاری‌ها می‌توانند به کاهش شکاف مهارتی، افزایش بهره‌وری و بهبود رقابت‌پذیری کمک کنند. چالش‌های ناشی از هوش مصنوعی نیازمند رویکردی پیشگیرانه از سوی سیاست‌گذاران است. در دوره انتقال، تغییرات شغلی و نابرابری در توزیع درآمد می‌تواند پیامدهای اقتصادی و اجتماعی چشمگیری داشته باشند. سیاست‌گذاری‌ها باید بر ترویج استفاده عادلانه و اخلاقی از هوش مصنوعی متمرکز شوند و نسل جدید نیروی کار را برای انطباق با این فناوری‌ها آموزش دهند. همچنین باید از نیروی کار فعلی که در معرض تغییرات سریع قرار دارند حمایت شود. ابعاد فرامرزی هوش مصنوعی چالش‌های اخلاقی و امنیت داده‌ها را برجسته‌تر کرده و بر اهمیت همکاری بین‌المللی تأکید می‌کند. این همکاری‌ها برای تضمین استفاده مسئولانه از هوش مصنوعی ضروری است، چرا که کشورها در ظرفیت‌های خود برای مدیریت این مسائل تفاوت‌های چشم‌گیری دارند. بنابراین، نیاز به هماهنگی میان اصول جهانی و قوانین محلی بیش از پیش احساس می‌شود [۳۴].

صندوق بین‌المللی پول در گزارش اخیر خود شاخصی با عنوان «شاخص آمادگی هوش مصنوعی» را طراحی کرده است تا به کشورها در انطباق بهتر با تحولات ناشی از این فناوری و تدوین سیاست‌های کارآمد کمک کند. این شاخص، میزان آمادگی کشورها را در حوزه‌هایی مانند زیرساخت‌های دیجیتال، ظرفیت انسانی، بازار کار، نوآوری، یکپارچگی اقتصادی و قوانین و مقررات ارزیابی می‌کند. بر اساس این شاخص، آمادگی ۱۲۵ کشور جهان برای مواجهه با هوش مصنوعی بررسی شده است. نتایج نشان می‌دهد که کشورهای ثروتمندتر تمایل بیشتری به تجهیز ساختارهای خود با این فناوری دارند. در مقابل، در بخش پایانی این گزارش تأکید شده است که کشورهای توسعه‌یافته باید نوآوری و یکپارچه‌سازی هوش مصنوعی را به‌عنوان اولویت اصلی خود در نظر بگیرند. از سوی دیگر، برای کشورهای درحال توسعه، تمرکز بر تدوین و تقویت چارچوب‌ها و مقررات برای مدیریت بهتر توسعه این فناوری پیشنهاد شده است. این کشورها می‌توانند از طریق سرمایه‌گذاری در زیرساخت‌های دیجیتال و ارتقای مهارت‌های فناورانه نیروی کار، گام‌های مؤثری برای بهره‌برداری از ظرفیت‌های هوش مصنوعی بردارند [۳۵].

سازمان توسعه و همکاری‌های اقتصادی پیشنهاد می‌کند که سیاست‌گذاران و قانون‌گذاران باید با نظارت و انجام تحقیقات گسترده‌تر در بازار کار، تغییرات آتی را به دقت رصد کنند. این

جدول ۴. راهکارهای اولیه پیشنهادی در بعد آموزش

راهکارهای پیشنهادی	بعد
- بسترسازی برای تعاملات بین‌المللی در زمینه آموزش و انتقال دانش - تدوین دستورالعمل اجرایی سند جامع مهارت و فناوری - تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و به‌روزرسانی مقررات بخشهای مرتبط و تدوین ضمانت اجرایی مناسب به منظور نظارت صحیح و کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و استفاده اخلاقی از کاربردهای هوش مصنوعی - پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناوریانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار - رصد مستمر نیازهای آموزشی در تحولات ناشی از فناوریها نظیر هوش مصنوعی و به‌روآوری برنامه‌های آموزشی دانشگاه‌ها و رشته‌های دانشگاهی به منظور توانمندسازی فارغ‌التحصیلان دانشگاهی - اتخاذ راهبردهای حمایتی و تشویق به سرمایه‌گذاری برای توسعه مهارتهای کار با هوش مصنوعی و مهارتهای دیجیتال	آموزش و مهارت

جدول ۵. راهکارهای اولیه پیشنهادی در بعد استخدام

راهکارهای پیشنهادی	بعد
- سرمایه‌گذاری در تقویت مهارتهای فناوریانه و دیجیتال نیروی کار - فعلی و آتی با به‌روآوری شاخص‌های مهارتی در فرایند استخدام و یا ارزیابی نیروی کار با هدف توسعه محیط کار دیجیتال و هوشمند - ایجاد سازوکار به‌کارگیری نیروی مهارتی و تخصصی خارجی در حوزه‌های کاربردی هوش مصنوعی - همکاری در انجام پروژه‌های برون مرزی با استفاده از تخصص نیروهای داخلی مهارتی به منظور ایجاد زمینه‌های فعالیت شرکتهای داخلی فناور در حوزه هوش مصنوعی - تدوین الزامات استخدام نیروهای جدید بازیگر در حوزه هوش مصنوعی	استخدام نیروی کار

جدول ۶. راهکارهای اولیه پیشنهادی در بعد سواد دیجیتال

راهکارهای پیشنهادی	بعد
- تدوین سیاستها و راهبردهای حمایتی برای سرمایه‌گذاری در توسعه زیرساختهای دیجیتال - ایجاد سازوکارهای حمایت اجتماعی و مشارکت اجتماعی سازنده برای انطباق با تغییرات ناشی از فناوری - سیاست‌گذاری به منظور ایجاد سازوکارهای ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال - تدوین برنامه‌های فرهنگ‌سازی توسعه و کاربرد هوش مصنوعی در سازمان‌ها	سواد دیجیتال

در این مرحله نیاز است که راهکارهای پیشنهادی در فرایند دلفی در اختیار خبرگان حوزه قرار گیرد. برای به‌کارگیری تکنیک دلفی ابتدا افراد خبره در زمینه هوش مصنوعی، اشتغال و مقررات‌گذاری انتخاب شدند. تعداد اعضای گروه خبرگان، پنج تا بیست نفر پیشنهاد

سازمان تأکید دارد که تشویق به سرمایه‌گذاری و حمایت از مهارتهایی که در تعامل با هوش مصنوعی ارزشمند هستند، مانند مهارتهای دیجیتال، می‌تواند رویکردی فعالانه برای آماده‌سازی نیروی کار باشد. علاوه بر آموزش و ارتقای مهارتهای لازم، سیاست‌گذاران باید اطمینان حاصل کنند که بازار کار توانایی انطباق با تغییرات فناوریانه را دارد. این امر می‌تواند از طریق ایجاد مکانیسم‌های حمایت اجتماعی، طراحی استراتژی‌هایی برای تقویت اشتغال‌زایی، و ترویج مشارکت اجتماعی سازنده تحقق یابد. چنین اقدامات سیاست‌گذاری، زمینه را برای کاهش تأثیرات منفی تغییرات تکنولوژیک و بهبود سازگاری نیروی کار فراهم می‌کند [۳۶].

۴-۳- تحلیل و ارائه راهکارهای اولویت‌دار

در تحلیل اسناد بالادستی در سه بُعد (۱) آموزش و مهارت، (۲) استخدام نیروی کار و (۳) سواد دیجیتال ملاحظات مربوطه ارائه شد. در بررسی توصیه‌های سازمان‌های بین‌المللی مرتبط نیز، صندوق بین‌المللی پول، برای کشورهای در حال توسعه دو توصیه ارائه کرده است:

۱. تمرکز بر تدوین و تقویت چارچوبها و مقرراتی که به کنترل

بهرتر توسعه هوش مصنوعی می‌انجامد

۲. سرمایه‌گذاری بیشتر روی زیرساخت‌های دیجیتال و تقویت

مهارتهای فناوریانه نیروهای کار

سازمان توسعه و همکاری‌های اقتصادی نیز سه توصیه اصلی ارائه کرده است:

۳. پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار

۴. اتخاذ رویکرد فعالانه با تشویق به سرمایه‌گذاری و حمایت از

مهارتهای کار با هوش مصنوعی و مهارتهای دیجیتال

۵. ایجاد ساز و کارهای حمایت اجتماعی، استراتژی تقویت

اشتغال‌زایی و مشارکت اجتماعی سازنده برای انطباق با

تغییرات ناشی از فناوری

به منظور تحلیل و پیشنهاد راهکار، نگاشتی از ملاحظات استنتاج شده از اسناد بالادستی و توصیه‌های سازمان‌های بین‌المللی در هریک از ابعاد تهیه شده و سپس براساس آن راهکارهای پیشنهاد شده در فرایند دلفی به خبرگان حوزه، مطابق با جداول ۴، ۵ و ۶ ارائه می‌شود.

پیشنهادی حذف نشد و راهکار جدیدی نیز پیشنهاد نشد و لیستی از موارد اجماع و عدم اجماع به منظور اطمینان در دور پنجم در اختیار خبرگان قرار گرفت تا دیدگاه نهایی خود را اعلام نمایند. تعداد مراحل انجام این روش، پنج دور بود که پس از آن اجماع و جمع‌بندی شد و ۱۳ راهکار در ۳ بُعد به منظور رسیدگی به مخاطرات و چالش‌های به‌کارگیری هوش مصنوعی در حوزه اشتغال تدوین شد.

جدول ۷. راهکارهای پیشنهادی برای پاسخ‌گویی به چالش‌ها و اثرات هوش مصنوعی در حوزه اشتغال

ابعاد	راهکارهای پیشنهادی
آموزش و مهارت	- بسترسازی برای تعاملات بین‌المللی در زمینه آموزش و انتقال دانش - تدوین دستورالعمل اجرایی سند جامع مهارت و فناوری - تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و به‌روزرسانی مقررات بخشهای مرتبط و تدوین ضمانت اجرایی مناسب به منظور نظارت صحیح و کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و استفاده اخلاقی از کاربردهای هوش مصنوعی - پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناورانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار - رصد مستمر نیازهای آموزشی در تحولات ناشی از فناوریها نظیر هوش مصنوعی و به‌روآوری برنامه‌های آموزشی دانشگاه‌ها و رشته‌های دانشگاهی به منظور توانمندسازی فارغ‌التحصیلان دانشگاهی - اتخاذ راهبردهای حمایتی و تشویق به سرمایه‌گذاری برای توسعه مهارت‌های کار با هوش مصنوعی و مهارت‌های دیجیتال
استخدام نیروی کار	- سرمایه‌گذاری در تقویت مهارت‌های فناورانه و دیجیتال نیروی کار فعلی و آتی با به‌روآوری شاخص‌های مهارتی در فرایند استخدام و یا ارزیابی نیروی کار با هدف توسعه محیط کار دیجیتال و هوشمند - ایجاد سازوکار به‌کارگیری نیروی مهارتی و تخصصی خارجی در حوزه‌های کاربردی هوش مصنوعی - همکاری در انجام پروژه‌های برون مرزی با استفاده از تخصص نیروهای داخلی مهارتی به منظور ایجاد زمینه‌های فعالیت شرکتهای داخلی فناور در حوزه هوش مصنوعی - تدوین الزامات استخدام نیروهای جدید بازیگر در حوزه هوش مصنوعی
سواد دیجیتال	- تدوین سیاستها و راهبردهای حمایتی برای سرمایه‌گذاری در توسعه زیرساختهای دیجیتال - ایجاد سازوکارهای حمایت اجتماعی و مشارکت اجتماعی سازنده برای انطباق با تغییرات ناشی از فناوری - سیاست‌گذاری به منظور ایجاد سازوکارهای ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال - تدوین برنامه‌های فرهنگ‌سازی توسعه و کاربرد هوش مصنوعی در سازمان‌ها

می‌شود. بنابراین ۱۴ نفر حایز شرایط و دارای دانش لازم انتخاب شده و سپس پرسش‌نامه باز دلفی به گروه خبرگان ارسال شد. در بخشی از این پرسش‌نامه، خبرگان می‌توانند راهکارهای پیشنهادی خود را که در لیست راهکارها نیست در پرسش‌نامه اضافه نمایند. انجام مراحل دلفی تا آنجا ادامه می‌یابد که خبرگان به جمع‌بندی و اجماع برسند و دانش و آرای آنها همگرا شود. به‌دلیل اینکه اعتبار روش دلفی به اعتبار علمی خبرگان آن است، حجم نمونه در این پژوهش کیفی، ۱۴ نفر از متخصصان و خبرگان در زمینه هوش مصنوعی، اشتغال و مقررات‌گذاری بود. برای انجام روش دلفی، پرسش‌نامه، در مراحل مختلف در اختیار خبرگان قرار داده شد تا امتیازات از ۱ تا ۵ را به آنها اختصاص دهند و همچنین پیشنهادات خود را نیز ارائه دهند. به این ترتیب، راهکارهای پیشنهادی که در هر دور، امتیاز کمتر از ۴ داشتند، حذف گردید و همچنین راهکارهایی که مورد نظر خبرگان بود، به لیست افزوده شد.

به‌عنوان مثال، راهکار پیشنهادی رصد تخصص‌های مورد نیاز در توسعه زیرساخت‌های فضای دیجیتال و ایجاد بانک اطلاعاتی متخصصین از بعد آموزش و مهارت حذف شد. همچنین راهکار پیشنهادی «پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناورانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار» طبق نظر خبرگان به بُعد آموزش و مهارت اضافه شد و راهکار پیشنهادی «تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و تقویت مقررات بخشهای مرتبط به منظور کنترل توسعه هوش مصنوعی» حذف گردید و راهکار پیشنهادی «تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و به‌روزرسانی مقررات بخشهای مرتبط و تدوین ضمانت اجرایی مناسب به منظور نظارت صحیح و کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و استفاده اخلاقی از کاربردهای هوش مصنوعی» جایگزین راهکار حذفی شد. همچنین با توجه به افزوده شدن راهکار «پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناورانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار» راهکار «پایش تحولات آینده و رصد مستمر نیازهای آموزشی در تحولات ناشی از فناوریها نظیر هوش مصنوعی و به‌روآوری برنامه‌های آموزشی دانشگاه‌ها و رشته‌های دانشگاهی به منظور توانمندسازی فارغ‌التحصیلان دانشگاهی» اصلاح شده و پایش تحولات آینده از ابتدای آن حذف شد. همچنین در بعد استخدام نیروی کار راهکار استفاده از متخصصین بخش خصوصی در توسعه مهارت‌های دیجیتال حذف شد زیرا راهکارهای کلان این بعد مشتمل بر این راهکار نیز بودند. در دور چهارم، هیچ راهکار

اولویت اول خبرگان بوده است. پس از آن به ترتیب راهکارهای "اتخاذ راهبردهای حمایتی و تشویق به سرمایه‌گذاری برای توسعه مهارت‌های کار با هوش مصنوعی و مهارت‌های دیجیتال"، "رصد مستمر نیازهای آموزشی در تحولات ناشی از فناوری‌ها نظیر هوش مصنوعی و به‌روزرسانی برنامه‌های آموزشی دانشگاه‌ها و رشته‌های دانشگاهی به منظور توانمندسازی فارغ‌التحصیلان دانشگاهی"، "پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناوریانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار"، "تدوین دستورالعمل اجرایی سند جامع مهارت و فناوری" و "بسترسازی برای تعاملات بین‌المللی در زمینه آموزش و انتقال دانش" در رتبه ۲ تا ۶ قرار گرفته‌اند.

آموزش و مهارت

Bastarsazi	0.05441
Dastoorol-	0.12181
Payesh e ~	0.13369
Rahborde ~	0.18952
Rasad e n~	0.16648
Tamarkoz ~	0.33409

استخدام نیروی کار

Hamkari d~	0.17240
Ijad e Sa~	0.12151
Sarmayego~	0.38905
Tadin e e~	0.31704

سواد دیجیتال

Ijad e he~	0.23902
Syasatgoz~	0.33971
Tadin e ~	0.14042
Tadin e ~	0.28085


شکل ۴. خروجی اولویت‌بندی راهکارها در ابعاد آموزش و مهارت، استخدام نیروی کار، سواد دیجیتال

در بُعد استخدام نیروی کار نیز راهکار "سرمایه‌گذاری در تقویت مهارت‌های فناوریانه و دیجیتال نیروی کار فعلی و آتی با به‌روزرسانی شاخص‌های مهارتی در فرایند استخدام و یا ارزیابی نیروی کار با هدف توسعه محیط کار دیجیتال و هوشمند" در رتبه اول و راهکار "تدوین الزامات استخدام نیروهای جدید بازیگر در حوزه هوش مصنوعی" در رتبه دوم و راهکارهای "همکاری در انجام پروژه‌های برون مرزی با استفاده از تخصص نیروهای داخلی مهارتی به منظور ایجاد زمینه‌های فعالیت شرکتهای داخلی فناور در حوزه هوش مصنوعی" و "ایجاد سازوکار به‌کارگیری نیروی مهارتی و تخصصی خارجی در حوزه‌های کاربردی هوش مصنوعی" در رتبه سوم و چهارم قرار گرفتند.

در بُعد سواد دیجیتال اولویت‌بندی راهکارها به این صورت بود که ابتدا راهکار "سیاست‌گذاری به منظور ایجاد سازوکارهای ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال" در رتبه اول و

پس از نهایی شدن راهکارهای پیشنهادی در فرایند دلفی، در این مرحله به منظور اولویت‌بندی راهکارهای پیشنهادی از پرسش‌نامه مقایسات زوجی استفاده شد. در این پرسش‌نامه در هر یک از سه بُعد آموزش و مهارت، استخدام نیروی کار و سواد دیجیتال، راهکارها دو به دو مقایسه شده و سوالات مقایسه‌ای در طیف لیکرت ۵ تایی مطرح شد. پرسش‌نامه در اختیار خبرگان قرار گرفت و جدول مقایسات زوجی در نرم‌افزار سوپردسیژن وارد شده و نتایج و خروجی‌های نرم‌افزار برای تحلیل و اولویت‌بندی راهکارها استخراج شد که در ادامه این فرایند تشریح شده است.

ابعاد سه‌گانه شامل (۱) آموزش و مهارت، (۲) استخدام نیروی کار و (۳) سواد دیجیتال به عنوان کلاسترها و راهکارهای ذیل هریک به عنوان نودهای آن در نرم‌افزار، مطابق با شکل ۲ مدل‌سازی شد.



شکل ۲. مدل پیاده‌سازی شده شامل ابعاد سه‌گانه و راهکارهای پیشنهادی خبرگان

پس از وارد کردن مقادیر پرسش‌نامه و جداول مقایسات زوجی، با استفاده از نرم‌افزار، مقایسات مورد تحلیل قرار گرفت. شکل ۳ بخشی از این فرایند را برای بُعد آموزش و مهارت نشان می‌دهد.

Comparisons with "Amoozesh o Maharat" node in "Rahkar" cluster									
Dastoorolamal is strongly more important than Bastarsazi									
	Bastarsazi	Dastoorolamal	Payesh e Tahavolat	Rasad e نیاز	Rahborde hemayat	Tamarkoz ~			
1.	Bastarsazi	>>9.5	9	7	6	5	4	3	2
2.	Bastarsazi	>>9.5	9	7	6	5	4	3	2
3.	Bastarsazi	>>9.5	9	7	6	5	4	3	2
4.	Bastarsazi	>>9.5	9	7	6	5	4	3	2
5.	Bastarsazi	>>9.5	9	7	6	5	4	3	2
6.	Dastoorolamal	>>9.5	9	7	6	5	4	3	2
7.	Dastoorolamal	>>9.5	9	7	6	5	4	3	2
8.	Dastoorolamal	>>9.5	9	7	6	5	4	3	2
9.	Dastoorolamal	>>9.5	9	7	6	5	4	3	2
10.	Payesh e Tahavolat	>>9.5	9	7	6	5	4	3	2
11.	Payesh e Tahavolat	>>9.5	9	7	6	5	4	3	2
12.	Payesh e Tahavolat	>>9.5	9	7	6	5	4	3	2
13.	Rahborde hemayat	>>9.5	9	7	6	5	4	3	2
14.	Rahborde hemayat	>>9.5	9	7	6	5	4	3	2
15.	Rasad e نیاز	>>9.5	9	7	6	5	4	3	2

شکل ۳. مراحل ورود اطلاعات و انجام تحلیل بُعد آموزش و مهارت در نرم‌افزار

همان‌گونه که در شکل ۴ مشاهده می‌شود در بُعد آموزش و مهارت، راهکار "تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و به‌روزرسانی مقررات بخش‌های مرتبط و تدوین ضمانت اجرایی مناسب به منظور نظارت صحیح و کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و استفاده اخلاقی از کاربردهای هوش مصنوعی"

۲- تدوین سیاست‌ها و راهبردهای حمایتی برای سرمایه‌گذاری در توسعه زیرساخت‌های دیجیتال
۳- ایجاد سازوکارهای حمایت اجتماعی و مشارکت اجتماعی سازنده برای انطباق با تغییرات ناشی از فناوری
۴- تدوین برنامه‌های فرهنگ‌سازی توسعه و کاربرد هوش مصنوعی در سازمان‌ها

به این ترتیب مقادیر ناسازگاری برای استخدام نیروی کار ۰,۰۳۰۴۴، برای آموزش و مهارت ۰,۰۹۸۳۹ و در نهایت سواد دیجیتال ۰,۰۲۲۷۱ می‌باشد. از آنجا که این مقادیر کمتر از ۰,۱ می‌باشند از نظر سازگاری قابل قبول هستند.

در این پژوهش، برای اطمینان از صحت و دقت ابزارهای اندازه‌گیری و جمع‌آوری داده‌ها، پرسش‌نامه بر اساس مبانی نظری و پیشینه تحقیق طراحی و مستقیماً به گروه خبرگان ارسال شد. ابزار جمع‌آوری داده‌ها شامل یک پرسش‌نامه باز دلفی بود که در آن به خبرگان این امکان داده شده بود که در صورت تمایل، راهکارهای پیشنهادی خود را اضافه کنند. پرسش‌نامه به‌گونه‌ای طراحی شده بود که به‌طور مستقیم به اهداف پژوهش پاسخ دهد و از آنجایی که گروه خبرگان دارای تخصص و تجربه‌های لازم در حوزه‌های هوش مصنوعی، اشتغال بودند. در زمینه روایی و پایایی نتایج این پژوهش لازم به ذکر است که روایی و پایایی برای روش‌های کیفی همانند روش‌های کمی نیست و با معیارها و روش‌های دیگری سنجیده می‌شود. روایی و پایایی روش دلفی نیز به‌آسانی به دست نمی‌آید، بنابراین، استفاده از پرسشنامه‌های پی‌درپی و دریافت پاسخ از خبرگان حوزه مورد نظر است که به افزایش روایی محتوای دلفی کمک می‌کند. در نهایت، اعتبار نتایج حاصل از روش دلفی، تحت تأثیر میزان پاسخ‌دهی است [۳۷].
به‌طور کلی، راهکارهای پیشنهادی برای انجام بهتر مطالعات دلفی شامل موارد زیر است:

۱. انتخاب افراد خبره مورد بررسی جهت مشارکت در مطالعه [۳۸]: در این پژوهش از چهارده خبره حوزه فضای مجازی و مشغول به فعالیت در حوزه‌های مرتبط همچون هوش مصنوعی، اشتغال بهره گرفته شده است.

۲. تعریف موضوع مورد بررسی جهت جلوگیری از سردرگمی خبرگان در پژوهش [۳۹]: برای کلیه خبرگان، دغدغه موضوع اشتغال و هوش مصنوعی و نیز شناسایی اولویت‌های آن تشریح شد.
۳. انتخاب خبرگان علاقه‌مند و توجیه مناسب آنها [۴۰]: پس از تفسیر موضوع برای خبرگان، از ایشان دعوت شد تا در صورت تمایل در این فرایند همکاری نمایند.

سپس راهکارهای "تدوین سیاست‌ها و راهبردهای حمایتی برای سرمایه‌گذاری در توسعه زیرساخت‌های دیجیتال"، "ایجاد سازوکارهای حمایت اجتماعی و مشارکت اجتماعی سازنده برای انطباق با تغییرات ناشی از فناوری" و "تدوین برنامه‌های فرهنگ‌سازی توسعه و کاربرد هوش مصنوعی در سازمان‌ها" در رتبه ۲ تا ۴ قرار گرفتند.

- آموزش و مهارت

۱- تمرکز سیاست‌گذاران و مقررات‌گذاران به تدوین و به‌روزرسانی مقررات بخش‌های مرتبط و تدوین ضمانت اجرایی مناسب به منظور نظارت صحیح و کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و استفاده اخلاقی از کاربردهای هوش مصنوعی

۲- اتخاذ راهبردهای حمایتی و تشویق به سرمایه‌گذاری برای توسعه مهارت‌های کار با هوش مصنوعی و مهارت‌های دیجیتال

۳- رصد مستمر نیازهای آموزشی در تحولات ناشی از فناوری‌ها نظیر هوش مصنوعی و به‌روزرآوری برنامه‌های آموزشی دانشگاه‌ها و رشته‌های دانشگاهی به منظور توانمندسازی فارغ‌التحصیلان دانشگاهی

۴- پایش تحولات آینده از طریق نظارت و تحقیقات بیشتر بر بازار کار به منظور پاسخ‌گویی سریع به پیامدهای فناورانه و شناسایی نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار

۵- تدوین دستورالعمل اجرایی سند جامع مهارت و فناوری
۶- بسترسازی برای تعاملات بین‌المللی در زمینه آموزش و انتقال دانش

- استخدام نیروی کار

۱- سرمایه‌گذاری در تقویت مهارت‌های فناورانه و دیجیتال نیروی کار فعلی و آتی با به‌روزرآوری شاخص‌های مهارتی در فرایند استخدام و یا ارزیابی نیروی کار با هدف توسعه محیط کار دیجیتال و هوشمند

۲- تدوین الزامات استخدام نیروهای جدید بازیگر در حوزه هوش مصنوعی

۳- همکاری در انجام پروژه‌های برون مرزی با استفاده از تخصص نیروهای داخلی مهارتی به منظور ایجاد زمینه‌های فعالیت شرکت‌های داخلی فناور در حوزه هوش مصنوعی

۴- ایجاد سازوکار به‌کارگیری نیروی مهارتی و تخصصی خارجی در حوزه‌های کاربردی هوش مصنوعی

- سواد دیجیتال

۱- سیاست‌گذاری به منظور ایجاد سازوکارهای ترویج سواد دیجیتال و ارتقای فرهنگ عمومی دیجیتال

۴. تخصیص زمان کافی برای ارائه نظرات خبرگان با توجه به شرایط مطالعه [۴۱]: زمان کافی تخصیص داده شد و پاسخ مناسب به پرسش‌های مطرح‌شده از سوی خبرگان ارائه شد.

۵. مشخص کردن معیارهای رسیدن به اجماع و توافق نظر بر اساس نظرات اعضای هیئت پیش از شروع مطالعه [۴۲]: پیش از ارائه پرسشنامه، شیوه امتیازدهی به آرای خبرگان تشریح شد.

۶. قرار دادن گروهی از محققان با هدف پاسخ‌گویی و شفاف‌سازی هرگونه پرسش و ابهام در تمام مراحل انجام پژوهش [۴۳]: در جلسات هم‌اندیشی، گروه نویسندگان ضمن پاسخگویی به هرگونه پرسش و ابهام در مراحل انجام پژوهش، شفاف‌سازی‌های لازم را انجام دادند.

۷. مصاحبه با افراد محقق و آگاه برای تأیید اعتبار یافته‌ها [۴۴]: تأیید نظر خبرگان در خصوص اولویت‌بندی یافته‌ها سرانجام انجام شد.

۵- بحث و نتیجه‌گیری

کشورهای پیشرفته، با صنایع بالغ و اقتصادهای مبتنی بر خدمات، معمولاً دارای تمرکز بالاتری از مشاغل در بخش‌هایی هستند که به وظایف پیچیده شناختی نیاز دارند. بنابراین، این کشورها در ابتدا تأثیرپذیرتر بوده و در عین حال موقعیت بهتری برای بهره‌مندی از نوآوری‌های هوش مصنوعی در آینده دارند. برعکس، بازارهای نوظهور و اقتصادهای در حال توسعه که اغلب هنوز به کار یدی و صنایع سنتی متکی هستند، ممکن است در ابتدا کمتر با اختلالات ناشی از هوش مصنوعی مواجه شوند. با این حال، این کشورها با توجه به کمبود زیرساخت و نیروی کار ماهر، ممکن است دستاوردهای اولیه بهره‌وری مبتنی بر هوش مصنوعی را نیز از دست بدهند. با گذشت زمان، شکاف هوش مصنوعی می‌تواند نابرابری‌های اقتصادی موجود را تشدید کند، به طوری که اقتصادهای پیشرفته از هوش مصنوعی برای مزیت رقابتی استفاده می‌کنند. در حالی که بازارهای نوظهور و اقتصادهای در حال توسعه با ادغام هوش مصنوعی در مدل‌های رشد خود دست و پنجه نرم می‌کنند. بنابراین، برای پاسخ به جهانی شدن، تغییر بیشتر مشاغل در کشورهای در حال توسعه اتفاق می‌افتد و این چالش برای کشورهای در حال توسعه متفاوت خواهد بود. از این رو، با توجه به اینکه ورود و نفوذ هوش مصنوعی به اقتصاد در جوامع مختلف اجتناب‌ناپذیر است، چالش پیش‌رو و کنترل اثرات آن نیازمند ایجاد آمادگی، مدیریت صحیح و اتخاذ رویکرد پیشگیرانه از سوی سیاست‌گذاران دارد.

این پژوهش در پی یافتن راهکارهای اولویت‌دار به منظور حل این چالش‌ها و درک اثرات، به بررسی ابعاد چالش‌ها و اثرات کاربست

هوش مصنوعی در انواع اقتصادهای توسعه یافته و در حال توسعه پرداخته است. همچنین با استفاده از روش اسنادی با شناسایی و انتخاب اسناد بالادستی به مرور این اسناد پرداخته شده و با استفاده از روش تحلیل مضمون، اسناد بالادستی کشور تحلیل و ملاحظات آن استخراج شد. در این خصوص، توصیه‌های نهادهای بین‌المللی نیز لحاظ شده و با نداشت آنها، راهکارها در سه بُعد (۱) آموزش و مهارت، (۲) استخدام نیروی کار و (۳) سواد دیجیتال پیشنهاد داده شده و در فرایند دلفی (۵ دور) با نظر خبرگان این حوزه اصلاح و نهایی شد. سپس با استفاده از روش AHP راهکارهای اولویت‌دار برای هریک از سه بُعد معرفی شد.

به این ترتیب پیشنهاد می‌شود با توجه به نوع توسعه‌یافتگی اقتصاد ایران، در آموزش و مهارت نیروی کار فعلی و جدید، با پایش تحولات و رصد نیازهای آموزشی، نیازهای فعلی و آتی تخصصی و مهارتی نیروی کار شناسایی شده و فرایند استخدام و یا ارزیابی نیروی کار به‌روزرسانی شود.

با توجه به رشد سریع تغییرات فناوری همکاری‌های بین‌الملل در زمینه انتقال دانش می‌تواند آسیب‌های احتمالی را کنترل نماید. به این منظور بسترسازی برای تعاملات بین‌المللی در زمینه آموزش و انتقال دانش می‌تواند راهکاری مناسب باشد. همچنین نیاز به سیاست‌گذاری، تدوین راهبردها و اصلاح مقررات در این حوزه برای نظارت بر توسعه هوش مصنوعی در حوزه اشتغال است که علاوه بر کنترل توسعه هوش مصنوعی مسئولیت‌پذیر و نظارت بر آن، ضمانت اجرای مناسب در این خصوص نیز تعیین شود. در زمینه سواد دیجیتال نیز لازم است برای توسعه زیرساخت‌های دیجیتال و ارتقای فرهنگ عمومی دیجیتال، سازوکارهای لازم تعیین شده و برای حمایت از سرمایه‌گذاری در این حوزه، تمهیدات لازم در نظر گرفته شود. در این راستا به منظور فرهنگ‌سازی توسعه و کاربرد هوش مصنوعی در سازمان‌ها تدوین برنامه و سیاست‌گذاری به‌عنوان یکی از راهکارهای کاربردی پیشنهاد می‌شود. در ادامه برای تکمیل این مطالعات پیشنهاد می‌شود، در هریک از بخش‌های صنعت، مطالعات کیفی با مصاحبه با خبرگان در زمینه چالش‌های کاربست هوش مصنوعی در مشاغل آن بخش و نیازهای آموزشی و مهارتی برای نیروی کار فعلی و آتی صورت گیرد. همچنین با انجام مطالعات کمی برای مشاغل خاص که در معرض آسیب هستند، نیازها و الزامات راهبردی تعیین شود. این مطالعات کمک می‌کند که سیاست‌گذاران و تصمیم‌گیران در این خصوص اولویت‌ها را در نظر گرفته و سیاست‌ها و راهبردهای مناسب را برای هر نیاز شناسایی شده در آن بخش تدوین نمایند.

- [15] AI is likely to significantly impact jobs. https://www.oecd-ilibrary.org/science-and-technology/oecd-artificial-intelligence-papers_dee339a8-en.
- [16] Emilio Colombo, Fabio Mercorio, Mario Mezzananza, Antonio Serino. (2024). "Towards the Terminator Economy: Assessing Job Exposure to AI through LLMs", arXiv:2407.19204v1.
- [17] J. E. Triplett, (1999). "The Solow productivity paradox: What do computers do to productivity?" The Canadian Journal of Economics, vol. 32, no. 2, pp. 309-334.
- [18] D. H. Autor, (2015). "Why are there still so many jobs? The history and future of workplace automation," Journal of Economic Perspectives, vol. 29, no. 3, pp. 3-30.
- [19] EPRS, (2021). "Digital Automation and the Future of Work. Brussels," European Union.
- [20] E. Brynjolfsson and A. McAfee, (2014). "The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies", W. W. Norton & Company.
- [21] C. B. Frey and M. A. Osborne, (2017). "The future of employment: How susceptible are jobs to computerization?" Technological Forecasting and Social Change, vol. 114, pp. 254-280.
- [22] Sabina-Cristiana Necula. (2023). "Artificial Intelligence Impact on The Labour Force -- Searching for The Analytical Skills of The Future Software Engineers", arXiv:2302.13229v1.
- [23] S. P. Mohanty, U. Choppali, and E. Kougiannos, (2016). "Everything you wanted to know about smart cities: The Internet of things is the backbone," IEEE Consumer Electronics Magazine, vol. 5, no. 3, pp. 60-70.
- [24] World Bank, (2019). The Changing Nature of Work.
- [25] D. H. Autor, F. Levy, and R. J. Murnane, (2003). "The skill content of recent technological change: An empirical exploration," The Quarterly Journal of Economics, vol. 118, no. 4, pp. 1279-1333.
- [26] J. Manyika et al., (2017). "Jobs lost, jobs gained: What the future of work will mean for jobs, skills, and wages," McKinsey Global Institute.
- [27] Yu Yang, (2020). "Analysis of the Impact of Artificial Intelligence Development on Employment", IEEE.
- [۲۸] صادقی فسایی، سهیلا؛ عرفان منش، ایمان. (۱۳۹۴). مبانی روش شناختی پژوهش اسنادی در علوم اجتماعی مورد مطالعه: تأثیرات مدرن شدن بر خانواده ایرانی. راهبرد فرهنگ، شماره بیست و نهم، بهار.
- [29] UNESCO (2015). Education 2030: Incheon Declaration and Framework for Action
- [30] OECD (2022). OECD work on EDUCATION & SKILLS Directorate for Education and Skills. https://www.oecd.org/content/dam/oecd/en/about/directorates/EDU/OECD-Education-Brochure.pdf/_jcr_content/renditions/original./OECD-Education-Brochure.pdf
- [31] International Labour Organization (ILO) (2021). World Employment and Social Outlook: The role of digital labour platforms in transforming the world of work. https://www.ilo.org/global/research/global-reports/weso/2021/WCMS_771749/lang-en/index.htm
- [32] Law, N. W. Y., Woo, D. J., De la Torre, J., & Wong, K. W. G. (2018). A global framework of reference on digital literacy skills for indicator 4.4. 2. Information Paper No. 51. UNESCO UIS/2018/ICT/IP/51
- [33] House of Commons Science, Innovation and Technology Committee. (2023). "The governance of artificial intelligence: interim report", Ninth Report of Session 2022-23.
- از آن جا که پژوهشی آینده نگر با ساختاری شبکه‌ای و با در نظر گرفتن تعاملات و وابستگی‌های متقابل بین راهکارها و ابعاد می‌تواند ارزش افزوده داشته باشد، پیشنهاد می‌شود در پژوهش‌های آتی، با بهره‌گیری از سایر روش‌های تصمیم‌گیری چندمعیاره مانند ANP، DEMATEL، DANP یا BWM، به تحلیل دقیق‌تری از روابط میان مؤلفه‌ها پرداخته شود.
- همچنین می‌توان با ترکیب این روش‌ها با تکنیک‌های نوین یادگیری ماشین یا سناریونویسی، چارچوب‌هایی هوشمندتر برای سیاست‌گذاری و تحلیل پویای اثرات متقابل در حوزه اشتغال و تحولات دیجیتال ارائه داد. بهره‌گیری از داده‌های میدانی، مشارکت ذی‌نفعان و استفاده از سیستم‌های پشتیبان تصمیم‌گیری نیز می‌تواند دقت و اثربخشی نتایج را در مطالعات آتی ارتقا بخشد.
- ### مراجع
- [1] <https://www.gartner.com/en/newsroom/press-releases/2023-10-11-gartner-says-more-than-80-percent-of-enterprises-will-have-used-generative-ai-apis-or-deployed-generative-ai-enabled-applications-by-2026>.
- [2] <https://www.gartner.com/en/newsroom/press-releases/2017-12-13-gartner-says-by-2020-artificial-intelligence-will-create-more-jobs-than-it-eliminates>.
- [3] Iftekhairul Islam, Fahad Shaon. (2020). If the Prospects of Some Occupations Are Stagnating with Technological Advancement? A Task Attribute Approach to Detect Employment Vulnerability. arXiv:2001.02783v1.
- [4] Dandan Qiao, Huaxia Rui, Qian Xiong. (2024). AI and Jobs: Has the Inflection Point Arrived? Evidence from an Online Labor Platform.
- [5] International Monetary Fund, (2024). "Gen-AI: Artificial Intelligence and the Future of Work".
- [6] Gmyrek, P., Berg, J., & Bescond, D. (۲۰۲۳). Generative AI and Jobs: A global analysis of potential effects on job quantity and quality. ILO Working Paper.
- [۷] باشگاه اقتصاددانان، آثار هوش مصنوعی بر بازار کار، دنیای اقتصاد، شماره ۵۸۷۰، آبان ۱۴۰۲.
- [8] Braun, V. & Clarke, V. (2006). "Using thematic analysis in psychology", Qualitative Research in Psychology, Vol. 3, No. 2, Pp. 77-101.
- [9] Holloway, I. & Todres, L. (2003). "The Status of Method: Flexibility, Consistency and Coherence", Qualitative Research, Vol. 3, No. 3, Pp. 345-357.
- [10] Saaty, T. L. (2008). Decision making with the analytic hierarchy process. International Journal of Services Sciences, 1(1), 83-98
- [11] Vaidya, O. S., & Kumar, S. (2006). Analytic hierarchy process: An overview of applications. European Journal of Operational Research, 169(1), 1-29
- [12] <https://www.europarl.europa.eu/at-your-service/en/stay-informed/research-and-analysis>.
- [13] <https://www.worldbank.org/en/access-to-information/ai-committee>.
- [14] <https://www.oecd.org/digital/artificial-intelligence/>

- [40] Ahmadi, Fazlollah. Nasiriani, Khadijeh. & Abazari, Parvaneh. 2008. Delphi technique: a tool for research. *Iranian Journal of Medical Education* 8 (1): 85-175.
- [41] Walker, A. M., & Selfe, James. 1996. The Delphi method: a useful tool for the allied health researcher. *British Journal of Therapy and Rehabilitation* 3 (12): 677-681.
- [42] Skulmoski, Gregory J., Hartman, T. Hartman & Krahn, Jennifer. 2007. The Delphi method for graduate research. *Journal of Information Technology Education* 6 (1): 1-21
- [43] Habibi Arash, Sarafrazi, Azam, Izadyar, Sedigheh . 2014. Delphi technique theoretical framework in qualitative research. *The International Journal of Engineering and Science* 3 (4): 8-13
- [44] Story, Victoria; Hurdley, Louise; Smith, Gareth; & Saker, James. 2000. Methodological and practical implications of the Delphi technique in marketing decision-making: a re-assessment. *The Marketing Review* 1 (4): 487-504
- [34] V. Dignum, (2019). "Responsible Artificial Intelligence: How to Develop and Use AI in a Responsible Way", Springer.
- [۳۵] ۴۰ درصد از مشاغل جهان تحت تاثیر هوش مصنوعی | ITIRAN – آی تی ایران
- [36] OECD, (2021). "Artificial Intelligence and Employment: New Evidence from Occupations Most Exposed to AI".
- [۳۷] رحمانی عبدالله، وزیری‌نژاد رضا، احمدی‌نیا حسن، رضائیان محسن. ۱۳۹۹. مبانی روش‌شناختی و کاربردهای روش دلفی: یک مرور روایی. مجله علمی دانشگاه علوم پزشکی رفسنجان. ۱۹(۵): ۵۳۸-۵۱۵.
- [38] Andrews, Charles. G, & Allen, Jeff. M. 2002. Utilization of technology-enhanced Delphi techniques. In *Workforce Education Forum* 29 (1): 1-15.
- [39] Windle, Pamela. E. 2004. Delphi technique: assessing component needs. *Journal of Perianesthesia nursing: official journal of the American Society of PeriAnesthesia Nurses* 19 (1): 46

Computational Models of Opinion Formation in Social Networks and Their Dimensions

Alireza Mansouri^{1*}

¹ Information Technology Faculty, ICT Research Institute, Tehran, Iran

Received: 01 April 2024, Revised: 28 August 2025, Accepted: 04 October 2025

Paper type: Research

Abstract

Opinion formation is a propagation process in social networks, examining the dynamics of people's opinion dynamics under the influence of others. Several computational opinion formation models have been proposed to study the dynamics of opinion and the process of creating situations such as consensus, bipolarity/multi-polarization, or the diversity of opinions in a society. Due to the growing trend of online social networks and considering the speed and convenience of producing and publishing content in these networks, an appropriate opinion formation model should be used in related studies. This study surveys the major opinion formation models and introduces a set of dimensions distinguishing opinion formation models. These dimensions are comprised of 1) opinion space, 2) discrete/continuous time, 3) interaction network, 4) interaction limitation, 5) degree of influence, 6) time dependency, and 7) linearity of model. Moreover, some conditions could be considered on the models that affect opinion formation model, including 1) homogeneity/heterogeneity of interacting people, 2) the number of dimensions of opinion space, 3) first impression, and 4) deterministic/noisy modeling. The results of this study help the researchers in the field of opinion formation to choose the appropriate opinion formation model according to the conditions and characteristics of the subject under investigation, and even to expand opinion formation models, if necessary.

Keywords: Opinion Formation, Opinion Dynamics, Modeling, Computational Social Science.

* Corresponding Author's email: amansuri@itrc.ac.ir

مدل‌های محاسباتی برای شکل‌گیری عقیده در شبکه‌های اجتماعی و ابعاد آنها

علیرضا منصوری^{*}

^۱ استادیار، پژوهشکده فناوری اطلاعات، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۱/۱۳ تاریخ بازبینی: ۱۴۰۴/۰۶/۰۶ تاریخ پذیرش: ۱۴۰۴/۰۷/۱۲
نوع مقاله: پژوهشی

چکیده

شکل‌گیری عقیده در شبکه‌های اجتماعی به بررسی پویایی تغییر عقیده افراد تحت تأثیر سایرین و در نتیجه تغییر عقیده در کل جامعه می‌پردازد. شکل‌گیری عقیده از مباحث علوم اجتماعی است، اما برخی مدل‌های محاسباتی برای آن ارائه شده‌اند که بررسی پویایی عقیده و نحوه ایجاد وضعیت‌هایی مانند اجماع، دوقطبی/چندقطبی شدن، و یا اختلاف عقاید افراد جامعه در شرایط مختلف را با روش‌های محاسباتی توجیه نمایند. با روند روبه‌رشد شبکه‌های اجتماعی بر خط و با توجه به سرعت و سهولت تولید و انتشار محتوا در این شبکه‌ها، انتخاب و استفاده از مدل شکل‌گیری عقیده مناسب از اهمیت زیادی برخوردار است. در این پژوهش مدل‌های شکل‌گیری عقیده و ابعاد مختلفی که این مدل‌ها را نسبت به یکدیگر متمایز می‌کنند، بررسی شده و بر اساس این ابعاد، جایگاه مدل‌های شکل‌گیری عقیده نیز مشخص شده است. این ابعاد عبارتند از: (۱) فضای عقیده، (۲) گسسته/پیوسته بودن زمان (۳) شبکه تعامل، (۴) محدودیت تعامل، (۵) میزان تأثیر، (۶) وابستگی به زمان و (۷) خطی/غیرخطی بودن. به علاوه، شرایطی را در مدل‌های شکل‌گیری عقیده می‌توان در نظر گرفت که روی پویایی و نتیجه تأثیرگذار است، شامل (۱) همگونی/ناهمگونی جامعه، (۲) تعداد ابعاد فضای عقیده، (۳) تصور اولیه جامعه، (۴) قطعی یا نویزی بودن مدل. نتایج این پژوهش به پژوهشگران حوزه شکل‌گیری عقیده کمک می‌کند مدل شکل‌گیری عقیده مناسب با توجه به شرایط و ویژگی‌های موضوع مورد بررسی انتخاب کنند و حتی در صورتی که نیاز به گسترش مدل‌های شکل‌گیری عقیده است، چه ابعاد و ویژگی‌هایی را مد نظر قرار دهند.

کلیدواژگان: شکل‌گیری عقیده، انتشار عقیده، پویایی عقیده، مدل‌سازی، علوم اجتماعی محاسباتی.

* رایانامه نویسنده مسؤول: amansuri@itrc.ac.ir

۱- مقدمه

عقیده به معنای دیدگاه، باور، قضاوت، و برآورد فکری فرد درباره موضوع خاص است. با نگاه ریاضی، می‌توان عقیده را به صورت قطبیت یا عددی در یک بازه مشخص نسبت به ویژگی خاصی از یک موجودیت تعریف نمود [۱] که می‌تواند گسسته یا پیوسته باشد و بیان‌کننده میزان رضایت‌مندی، خواست یا ترجیح فرد باشد [۲].

در یک گروه یا جامعه از افراد که با هم در تعامل هستند، کنش‌های کوچک و ساده افراد ممکن است باعث اثرگذاری در دیگران و انتشار عقاید در جامعه شود و نهایتاً منجر به بروز تغییرات مهم در جامعه شود. در واقع زنجیره‌هایی از تأثیرگذاری افراد روی عقاید یکدیگر و به عبارتی یک رفتار جمعی شکل می‌گیرد [۳] که تحت عنوان پویایی عقیده^۱ یا شکل‌گیری عقیده^۲ از آن یاد می‌شود. شاید تک‌تک افراد تعامل کننده در فضای مجازی که حتی ناشناس هستند، تأثیر چندانی روی تغییر عقیده افراد نداشته باشند، اما طبق فرضیه «قدرت ارتباطات ضعیف» [۴]، حجم زیاد ارتباطات، اگر چه هر یک با تأثیرگذاری کم، در مجموع قدرت فراوانی تولید می‌کند که می‌تواند عقیده غالب جامعه را به سمت خاصی سوق دهد. بنابر این، شکل‌گیری عقیده از مصادیق فرآیند انتشار^۳ و رفتار جمعی^۴ است [۵] و [۶].

در سال‌های اخیر با توجه به رشد شبکه‌های اجتماعی، امکان انتشار عقیده بسیار سریع‌تر و فراگیرتر شده است [۷]. روش‌های علوم اجتماعی محاسباتی [۸] نیز در تحلیل این پدیده‌های اجتماعی به کار می‌روند. علوم اجتماعی محاسباتی با جمع‌آوری داده‌ها و اطلاعات از فضای مجازی و تحلیل آنها و نیز روش‌های مدل‌سازی و شبیه‌سازی، جامعه‌شناسان را به ابزاری مجهز می‌کنند که شناخت دقیق‌تری از عقاید جامعه و روند آن داشته باشند و در قیاس، به مثابه تلسکوپ برای اخترشناسان است [۹].

شکل‌گیری عقیده در شبکه‌های اجتماعی در کاربردهای مختلفی مورد بررسی قرار می‌گیرد، مثل اقتصاد و تجارت [۱۰]، بازاریابی برخط [۱۱]، انتخابات سیاسی [۱۲، ۱۳] و حکمرانی دیجیتال با شبکه‌های اجتماعی [۱۴]. در راستای این اهداف، انتشار شایعات و اخبار جعلی نیز بسیار استفاده شده است و البته در چند سال اخیر، کشف آنها به یک حوزه تحقیقاتی پرطرفدار تبدیل شده است و روش‌های مختلفی برای آن پیشنهاد شده است [۱۵-۱۸].


از طرفی، شکل‌گیری عقیده به عنوان زیرمجموعه‌ای از مسائل در حوزه شبکه‌های پیچیده^۵ و پویایی شبکه^۶ مطرح هستند که عموماً راه‌حل‌های ساده ندارند. مهم‌ترین دلیل این پیچیدگی را می‌توان پیچیدگی افراد و ذهنیت آنها، به عنوان اجزای سیستم تحت مطالعه دانست. اما برای بررسی شبکه‌ای که هر گره آن یک انسان است که به تنهایی دارای پیچیدگی فراوانی است [۱۹] و فرآیندهای شناختی او روی باورها و تصمیم‌گیری‌هایش بسیار تأثیرگذار است [۲۰]، مدل‌های نسبتاً ساده‌ای از تغییر عقیده هر فرد در نظر گرفته می‌شود که بتوان بر این پیچیدگی فائق آمد. به همین دلیل بسیاری از پژوهش‌ها در زمینه شکل‌گیری عقیده با دنیای واقعی فاصله دارند و دلیل عمده آن را می‌توان در نظر نگرفتن رفتار واقعی و دقیق اجتماعی افراد دانست [۲۱]. در دنیای واقعی عوامل متعددی می‌توانند بر تأثیرگذاری دو نفر روی عقاید یکدیگر مؤثر باشند که مدل‌های مختلف تمامی این ابعاد را در نظر نمی‌گیرند، مثل شناخت افراد نسبت به هم، نوع رابطه (دوستی)، میزان اعتماد یا صمیمیت، موضوع مورد تعامل، و حالت هیجانی دو طرف. در مقیاس اجتماعی که تغییر عقاید در یک جمعیت مورد توجه است، باید به این موارد، ویژگی‌های اجتماعی را نیز اضافه نمود، مثلاً ساختار ارتباطات افراد در جامعه و جایگاه ساختاری افراد تأثیرگذار و تأثیرپذیر در جامعه. عقیده افراد نه تنها تحت تأثیر افراد تعامل‌کننده، بلکه تحت تأثیر سایر عوامل، مثل رسانه‌های جمعی نیز قرار می‌گیرند. ضمناً واکنش افراد در برابر عوامل اثرگذار بر تغییر عقیده نیز متفاوت است و تا حد زیادی به شخصیت، خلق‌و‌خو و ویژگی‌های مردم‌شناسی آنها وابسته است.

با وجود عوامل متعدد در شکل‌گیری عقیده، پژوهش‌های مختلف از دیدگاه‌های متفاوت موضوع را بررسی می‌کنند و هر یک از مدل‌های شکل‌گیری عقیده برای شرایط و همبافت^۷ خاصی مناسب‌تر است و البته برخی مدل‌ها در تکامل مدل دیگری ارائه شده‌اند. با استفاده از مدل‌های شکل‌گیری عقیده، بررسی پویایی میکروسکوپی با روش‌هایی نظیر مکانیک آماری و نظریه جنبشی، الگوی شکل‌گیری عقیده در مقیاس ماکرو و رفتار جمعی استخراج و بررسی می‌شود [۲۲]. بیشترین کاربرد مدل‌های شکل‌گیری عقیده در مدل‌سازی و شبیه‌سازی مبتنی بر عامل برای بررسی جامعه است. ایده اصلی در مدل‌سازی و شبیه‌سازی مبتنی بر عامل این است که به جای پرداختن به کلیت یک سیستم، آن سیستم به اجزای تشکیل‌دهنده

⁵ Complex Networks⁶ Network Dynamics⁷ Context¹ Opinion Dynamics² Opinion Formation³ Diffusion Process⁴ Collective Behaviour

۴. مقایسه اشتراک‌ها و افتراق‌های مدل‌های شکل‌گیری عقیده و استخراج ابعاد و ویژگی‌های مدل‌های شکل‌گیری عقیده

در گام اول از گام‌های فوق آمار به دست آمده از جستجوی کلیدواژه‌ها که در شکل ۱ نشان داده شده است بیانگر روند افزایشی تحقیقات در موضوع شکل‌گیری عقیده در ۲۵ سال اخیر است، به طوری که بر اساس پایگاه Google scholar تعداد آثار منتشر شده از ۱۷ عنوان در سال ۲۰۰۰ به ۳۰۷ عنوان در سال ۲۰۲۴ رسیده است (در زمان نگارش این مقاله در سپتامبر ۲۰۲۵ نیز تعداد ۲۱۶ اثر مربوط به سال ۲۰۲۵ در پایگاه علمی گوگل ثبت شده‌اند).



شکل ۱. تعداد مقالات مرتبط با شکل‌گیری عقیده با جستجوی کلیدواژه‌های «Opinion formation»، «Opinion dynamics» و «Opinion forming» منتشر شده در پایگاه Google Scholar طی سال‌های ۲۰۰۰ تا ۲۰۲۴

در گام دوم، مقالات مورد غربالگری قرار گرفتند. در این گام، مقالاتی که دیدگاه محاسباتی نسبت به موضوع شکل‌گیری عقیده نداشتند، از فهرست حذف شدند.

گام سوم در این پژوهش از اهمیت زیادی برخوردار است زیرا تعداد زیادی از مدل‌های شکل‌گیری عقیده قبل از سال ۲۰۰۰ ابداع شده‌اند و بدیهی است که در بازه زمانی مورد جستجو قرار ندارند. این مقالات با بررسی ارجاعاتی که در مقالات پیدا شده، خصوصاً آنها که جنبه مروری دارند [۶، ۷، ۱۱، ۱۹، ۲۸-۳۱]، مشخص شدند.

برخی از مدل‌های ارائه شده نیز با اعمال تغییر جزئی در یک مدل اولیه ایجاد شده‌اند که در این بررسی از این مدل‌ها نیز صرف‌نظر

(عامل‌ها) خرد می‌شود و از کنش‌ها و تعامل‌های اجزاء، رفتار کل سیستم بررسی می‌شود. به این ترتیب مدل‌سازی و شبیه‌سازی مبتنی بر عامل برای تحلیل سیستم‌های پیچیده و پدیده‌هایی مانند شکل‌گیری عقیده در علوم اجتماعی رویکرد مناسبی است [۲۳-۲۶] و روش‌هایی مثل تحلیل گرافیکی برای غلبه بر پیچیدگی‌های آن ارائه شده است [۲۷]. با این توضیح، در ادامه از کلمه «عامل» به عنوان مترادف با «فرد» استفاده می‌شود.

یکی از چالش‌هایی که در پژوهش‌های مرتبط با شکل‌گیری عقیده وجود دارد، انتخاب مدل مناسب برای شکل‌گیری عقیده است. در این مقاله علاوه بر معرفی مدل‌های اصلی شکل‌گیری عقیده، وجوه اشتراک و افتراق این مدل‌ها بیان می‌شود که نوآوری اصلی این مقاله است. به این منظور، ابعاد مدل‌های شکل‌گیری عقیده با بررسی مدل‌های مختلف احصاء شده‌اند که می‌تواند راهنمای مناسبی برای انتخاب مدل مناسب برای شکل‌گیری عقیده و حتی ارائه مدل جدیدی برای شرایط و همبافت خاص باشد. دسته‌بندی مدل‌های مشهور شکل‌گیری عقیده بر اساس این ابعاد به درک بهتر جایگاه این مدل‌ها کمک می‌کند.

در ادامه، ابتدا در بخش ۲ روش پژوهش معرفی می‌شود، سپس در بخش ۳ الگوهای توزیع عقاید در جامعه توضیح داده می‌شوند. بخش ۴ مدل‌های شکل‌گیری عقیده را به اختصار معرفی می‌کند و در بخش ۵، ابعاد یا ویژگی‌های مدل‌های شکل‌گیری عقیده توضیح داده می‌شوند. نهایتاً بخش ۵ مقاله را جمع‌بندی می‌کند.

۲- روش

در این پژوهش به منظور پوشش دادن مدل‌های شکل‌گیری عقیده، گام‌های زیر طی شده است:

۱. جستجوی کلیدواژه‌های مرتبط در عنوان آثار علمی در پایگاه علمی Google Scholar با استفاده از عبارت پرس‌وجوی زیر: `allintitle: "Key_words"` که طی سال‌های ۲۰۰۰ تا ۲۰۲۵ منتشر شده‌اند و `Key_words` در سه مرحله، هر بار با یکی از عبارات زیر جایگزین شده است:

- Opinion formation ○
- Opinion dynamics ○
- Opinion forming ○

۲. بررسی عنوان و خلاصه آثار عملی بازبایی شده در گام قبل و حذف موارد غیرمرتبط از فهرست یافته‌ها.

۳. بررسی ارجاع‌های آثار باقیمانده و پیدا کردن و افزودن آثار مرتبط که قبل از سال ۲۰۰۰ منتشر شده‌اند به فهرست موارد.

قاعدتاً دلیلی برای تغییر این الگوی اولیه وجود ندارد. بنابر این، مسأله بررسی شکل‌گیری عقیده را می‌توان به این صورت توضیح داد که در شرایط اولیه با الگوی خاصی از توزیع عقاید در جامعه، با اعمال یک مدل شکل‌گیری عقیده خاص، پس از مدت مشخصی، الگوی نهایی شکل‌گیری عقیده در جامعه چگونه خواهد بود.

۴- مدل‌های شکل‌گیری عقیده

مدل‌های شکل‌گیری عقیده به این موضوع می‌پردازند که چگونه عقاید افراد، تحت تأثیر اطلاعات دریافتی از محیط اجتماعی خود تغییر می‌کند [۳۴]. مهم‌ترین مدل‌های شکل‌گیری عقیده در این بخش معرفی می‌شوند. ممکن است برخی مدل‌های شکل‌گیری عقیده که گونه‌ای از یکی از این مدل‌ها یا ترکیبی از آنها تلقی می‌شوند، در این فهرست نباشند. مدل‌های شکل‌گیری عقیده در این بخش به ترتیب روند تاریخی ابداع آنها است که تاریخچه تکامل آنها را نیز نشان می‌دهد.

۴-۱- مدل آیزینگ

مدل آیزینگ به نام فیزیکدان آلمانی، ارنست آیزینگ^۱ است که یک مدل فیزیکی در سال ۱۹۲۴ برای بررسی حالت خاصی از زنجیره خطی ذرات مغناطیسی که می‌توانند یکی از دو حالت مغناطیسی بالا یا پایین را داشته باشند و با نزدیک‌ترین همسایه‌های خود تعامل دارند، ارائه کرد. آیزینگ نشان داد مغناطیسی شدن خودبخودی با این مدل در حالت یک بعدی قابل توصیف نیست، اما بعدها نشان داد نسخه دوی بعدی از این مدل که اینک به عنوان مدل آیزینگ شناخته می‌شود، می‌تواند این پدیده را توصیف نماید. از این نگاه میکروسکوپی و نتیجه‌گیری ماکروسکوپی از آن، به سرعت در سیستم‌های پیچیده مختلف در زیست‌شناسی، مالی، اجتماعی، و نیز در شکل‌گیری عقیده استفاده شد. بنابر این اگر چه مدل آیزینگ به عنوان مدل شکل‌گیری عقیده ارائه نشد، اما یکی از قدیمی‌ترین مدل‌های شکل‌گیری عقیده در نظر گرفته می‌شود که جهت ذرات مغناطیسی، نشان دهنده جهت عقیده افراد است و اثر مغناطیسی هر ذره بر ذرات اطراف خود، مشابه تأثیرگذاری فرد بر عقاید افرادی است که با آنها در تعامل است.

۴-۲- مدل فرنچ

مدل فرنچ در سال ۱۹۵۶ توسط فرنچ^۲ ارائه شد و از اولین مدل‌های توصیف چگونگی تأثیر عقاید افراد روی سایرین است. در این مدل

شده است. مدل‌های باقیمانده که در فصل ۴ به آنها پرداخته خواهد شد را می‌توان مدل‌های اصلی و اصیل شکل‌گیری عقیده تلقی کرد. در گام چهارم، مدل‌های اصلی و اصیل باقیمانده با هم مقایسه شده‌اند و ابعاد و ویژگی‌هایی برای مقایسه آنها استخراج شده است. قبل از پرداختن به مدل‌های اصلی شکل‌گیری عقیده و ابعاد آنها، الگوهای توزیع عقاید در جامعه در فصل بعد معرفی می‌شوند. شناخت این الگوها برای توضیح مدل‌های شکل‌گیری عقیده اهمیت دارند.

۳- الگوهای توزیع عقاید در جامعه

توزیع عقاید در افراد جامعه به شکل‌های مختلفی ممکن است، به عبارتی با وقوع یک فرآیند انتشار عقیده (که ممکن است بر اساس یک مدل شکل‌گیری عقیده توجیه شود)، به شکل‌های مختلفی ممکن است آن عقیده بین افراد جامعه توزیع شود، شامل [۳۲، ۳۳]:

- اجماع: افراد جامعه عقاید یکسان دارند و گاهی بین «اجماع کامل» که تمامی افراد جامعه بدون استثناء عقیده یکسان دارند و «اجماع» که تقریباً تمام افراد عقیده یکسان دارند (و ممکن است یک اقلیت قابل اغماض عقیده دیگری داشته باشند)، تمایز قائل می‌گردد، در این مقاله، منظور از اجماع، همان اجماع کامل است.
- قطبیت: وجود دو عقیده مخالف با نسبت تقریباً مساوی در جامعه است. قطبیت در شرایطی ممکن است که عقیده ماهیت گسسته دودویی داشته باشد.
- خوشه‌ای: عقیده، ماهیت گسسته با بیش از دو وضعیت دارد و جمعیت‌های قابل توجهی از جامعه به برخی یا تمام مقادیر ممکن عقیده نسبت داده می‌شوند.
- اختلاف عقاید: شرایطی است که افراد جامعه با توزیع تقریباً یکنواخت عقاید مختلف ممکن را پذیرفته باشند و در واقع عقیده‌ای را نتوان به عنوان عقیده غالب در جامعه مشخص کرد. این حالت مشابه قطبیت است اما برای عقاید با مقادیر گسسته چندتایی و عقاید با مقادیر پیوسته نیز قابل تعریف است.

نکته مهم دیگر در الگوهای توزیع عقاید در جامعه این است که شرایط اولیه جامعه در شکل‌گیری الگوی نهایی مهم است. مثلاً اگر جامعه‌ای در حالت اجماع کامل باشد و هیچ عقیده مخالفی وجود نداشته باشد (و عوامل خارجی تأثیرگذاری هم وجود نداشته باشند)،

² French

¹ Ernst Ising

شکل‌گیری عقیده لحاظ کرد، شامل مقاومت نسبت به تغییر عقیده که میزان این مقاومت نیز ثابت نیست و نیز نرخ تعامل که این نرخ نیز ثابت نیست.

۴-۵- مدل دیگروت

در مدل دیگروت^۳ [۳۹] که در ۱۹۷۴ ارائه شد، عقیده افراد (k نفر)، پیوسته است و هر فرد در ابتدا عقیده‌ای نسبت به موضوع دارد ($O_1, \dots, O_k$). هر فرد، وزن p_i به افراد گروه (شامل خودش و با مجموع برابر ۱) تخصیص می‌دهد و به‌نگام‌سازی عقیده فرد در هر گام زمانی با محاسبه متوسط وزن دار عقیده‌ها طبق رابطه زیر انجام می‌شود:

$$\sum_{i=1}^k p_i o_i$$

در شکل ماتریسی، سطر i ام از ماتریس P شامل وزن‌هایی می‌شود که فرد i به عقیده افراد گروه تخصیص می‌دهد و جمع هر سطر، یک است. بنابر این، ماتریس P یک ماتریس اتفاقی^۴ است. اگر عقاید اولیه افراد با ماتریس O شامل k سطر و یک ستون نشان داده شود، این عقاید پس از یک مرحله تعامل در گروه، به ماتریس $O^{(1)}$ تبدیل می‌شود که حاصل ضرب P و O است:

$$O^{(1)} = PO$$

و اگر به همین ترتیب گام‌های زمانی بعدی نیز طی شوند:

$$O^{(n)} = PO^{(n-1)} = P^n O, \quad n = 2, 3, \dots$$

فرض می‌شود این روند تا بی‌نهایت یا تا زمانی ادامه یابد که اجماع حاصل شود، به طوری که:

$$O^{(n+1)} = O^{(n)}.$$

انتقال به هر حالت، فقط به حالت قبل بستگی دارد که با ماتریس اتفاقی P انتقال انجام می‌شود، به این ترتیب این فرآیند، یک فرآیند بی‌حافظه^۵ یا مارکوف^۶ است و قضایای مربوط به آن قابل اعمال است. دیگروت اثبات کرد اگر عدد صحیح n وجود داشته باشد که تمامی درایه‌های حداقل یک ستون از ماتریس $P^{(n)}$ مثبت باشند، اجماع اتفاق می‌افتد و مقدار آن قابل محاسبه است.

۴-۶- مدل رأی‌دهنده

در مدل رأی‌دهنده^۷ [۴۰] (سال ۱۹۷۵) عقیده‌ها گسسته هستند و

عقیده هر نفر به صورت یک عدد حقیقی نمایش داده می‌شود. در هر نقطه زمانی، اعضای یک گروه بطور همزمان عقاید خود را به مقداری که متوسط عقاید خود و دیگرانی که به‌طور مستقیم با آنها ارتباط (عقیده‌ای) دارند، تغییر می‌دهند. اگر عضوهای j و k عقاید خود را با عضو i در میان بگذارند، پس از یک واحد زمانی، عقیده i طبق این رابطه محاسبه می‌شود:

$$(1/3)(o_i + o_j + o_k),$$

که در آن، o_i ، o_j و o_k به ترتیب عقیده i ، j و k هستند. در واقع، در زمان t تمام افراد به موقعیت‌هایی حرکت می‌کنند که مجموع مربع فاصله‌های بین آنها و سایر افراد تأثیرگذار در $t-1$ کمینه شود. فرنج نتیجه‌گیری کرد که وابسته به ساختار ارتباطات تأثیرگذار بین افراد، عقاید اعضاء طی زمان به یک عقیده واحد همگرا می‌شود. استنتاج فرنج در مورد تأثیر ساختار ارتباطات روی دستیابی به اجماع، با این فرضیه روانشناسان اجتماعی سازگار بود که وقوع عقاید مشترک در یک جمعیت، به همبستگی آنها در ساختار ارتباطی وابسته است. فرنج نتیجه گرفت که در جمعیتی با ارتباطات قویاً همبند یا همبند یک‌طرفه اجماع اتفاق می‌افتد [۳۵].

۴-۳- مدل ابلسون

مدل ابلسون^۱ [۳۶] که در ۱۹۶۴ ارائه شد، مشابه مدل دیگروت یا مدل کلاسیک HK (که در ادامه توضیح داده می‌شوند) است و به‌نگام‌سازی عقاید عامل‌ها با متوسط عقاید همسایه‌های عامل انجام می‌شود. نکته بارز این مدل، پیوسته بودن زمان است و به سبب همین نگرش به سیستم، پویایی سیستم با معادلات دیفرانسیل (به جای معادلات تفاضل در مدل‌های با زمان گسسته) مدل شده است [۳۸، ۳۷].

۴-۴- مدل تیلر

مدل تیلر^۲ [۳۸] در ۱۹۶۸ معرفی شد. این مدل از معدود مدل‌هایی است که بر اساس مدل ابلسون است و (مشابه ابلسون) با معادلات دیفرانسیل شکل‌گیری عقیده را مدل‌سازی می‌کند. تفاوت این مدل با مدل ابلسون در این است که ابلسون تغییر عقیده افراد جامعه را فقط تحت تأثیر سایر افراد تعامل‌کننده می‌دانست، اما تیلر علاوه بر سایر افراد، نقش منابع ثابت تأثیرگذار یعنی رسانه‌های اجتماعی را نیز در نظر گرفت. مدل تیلر همچنین دو عامل دیگر را نیز در

⁵ Memoryless

⁶ Markov

⁷ Voter

¹ Abelson

² Taylor

³ DeGroot

⁴ Stochastic

i می‌شود. به عبارت دیگر هر عامل روی همسایه‌های دیگر تأثیر می‌گذارد و او را با خود، هم‌عقیده می‌نامید. از دیدگاه دیگر می‌توان گفت وقتی دو همسایه با هم اختلاف دارند، همسایه‌های دیگر آنها نیز با آنها مخالفت می‌کند.

شکل ۲ دو قاعده فوق را به خوبی نمایش می‌دهد. صورت‌هایی که به چپ یا راست نگاه می‌کنند، یکی از دو عقیده ممکن را دارند و صورت‌هایی که روبرو را نگاه می‌کنند، هنوز عقیده‌ای انتخاب نکرده‌اند و یکی از دو مقدار ممکن به آنها اختصاص خواهد یافت.

قاعده اول در این مدل، قاعده اعتبارسنجی اجتماعی^۴ است. طبق این قاعده، در بعضی شرایط که نمی‌دانیم چکار کنیم، به دیگران نگاه می‌کنیم و همان کاری را انجام می‌دهیم که آنها انجام می‌دهند. این موضوع در آزمایش‌های مختلف اثبات شده است [۴۴].

مثلاً در شرایطی مثل مجلس نمایندگان که در مورد موضوعی قرار است رأی‌گیری انجام شود را در نظر بگیرید. نمایندگان روی صندلی‌های خود نشسته‌اند و با نمایندگانی که در صندلی‌های نزدیک‌تر نشسته‌اند راحت‌تر می‌توانند صحبت کنند و روی آنها تأثیر بگذارند. این مدل می‌تواند برای توصیف این شرایط مناسب باشد.

بدیهی است که این مدل یک بعدی برای جوامع بزرگ خیلی مفید نیست. مدل دوبعدی اشتوفر یک قدم به واقعیت نزدیک‌تر است.

۴-۹- مدل اشتوفر

اشتوفر^۵ [۴۵] مدل خود را در سال ۲۰۰۰ بر مبنای مدل اشنید اما روی شبکه^۶ $L \times L$ ارائه کرد. در این مدل نیز هر فرد (عامل) یکی از دو قطبیت ممکن را دارد و از دو قاعده زیر استفاده می‌شود:

- اگر تمامی چهار همسایه دارای قطبیت یکسان نباشند، هشت همسایه آنها بدون تغییر باقی می‌مانند.
- یک جفت همسایه، تمام شش همسایه خود را با خود هم‌جهت می‌کنند اگر و تنها اگر این دو همسایه هم‌جهت باشند.

با این دو قاعده، همیشه در حالت پایدار^۷، اجماع به دست خواهد آمد. به علاوه، انتقال فاز نیز قابل مشاهده است به طوری که اگر چگالی اولیه ذرات با جهت بالا کمتر از ۰.۵ باشد، تمام ذرات با جهت پایین خواهند بود و برعکس. شکل ۳ تغییرات را نشان می‌دهد (نقاط، ذراتی هستند که می‌توانند جهت بالا یا پایین بگیرند).

به هر عامل، یک متغیر دودویی $s = \pm 1$ تخصیص داده می‌شود. عامل‌ها و ارتباطات آنها، یک گراف جهت‌دار قویاً همبند^۱ فرض می‌شود. در هر مرحله، گره‌ای به صورت تصادفی انتخاب می‌شود و این گره یکی از همسایه‌های خود (شامل خودش) را تصادفی انتخاب می‌کند و عقیده آن را به عنوان عقیده خودش انتخاب می‌کند. در واقع طبق این قاعده، عامل‌ها از همسایه خود تقلید می‌کنند. می‌توان نشان داد که این الگوریتم به اجماع می‌رسد [۱۹].

۴-۷- مدل FJ

در مدل FJ^2 [۴۱، ۴۲] ارائه شده در ۱۹۹۰، فرد، عقیده ابتدایی خود را با وزن مشخص g_i حفظ می‌کند و وزن دیگری برای تمامی همسایگان قائل است. پس عقیده عامل i ام در زمان $t+1$ با رابطه زیر به دست می‌آید که a_{ij} وزنی است که عامل i برای عامل j قائل است:

$$o_i(t+1) = g_i o_i(0) + (1 - g_i)(a_{i1} o_1(t) + \dots + a_{in} o_n(t))$$

و فرم ماتریسی آن که تغییر عقیده برای تمامی عامل‌ها را بیان می‌کند به این صورت است:

$$O(t+1) = GO(0) + (1 - G)AO(t) \quad \text{for } t \in T$$

که در آن، G ماتریس قطری است با g_i در قطر که $0 \leq g_i \leq 1$ و I ماتریس همانی است.

۴-۸- مدل اشنید

اشنید^۳ مدل خود را که بر اساس مدل آیزینگ است، در سال ۲۰۰۰ ارائه کرد [۴۳] و در سال ۲۰۰۵ نسخه کامل‌تری [۴۴] ارائه نمود. در مدل اشنید، سیستم از تعدادی عامل تشکیل شده که عقیده هر عامل، تنها می‌تواند انتخابی بین دو گزینه مشخص باشد. سیستم به صورت زنجیره آیزینگ در نظر گرفته می‌شود. در هر گام زمانی دو عامل i (که به صورت تصادفی انتخاب می‌شود) و عامل $i+1$ روی نزدیک‌ترین همسایه‌های خود، یعنی عامل‌های $i-1$ و $i+2$ تأثیر می‌گذارند. قاعده پویایی به صورت زیر است:

- اگر عقاید عامل‌های i و $i+1$ برابرند، روی همسایه‌ها یعنی عامل‌های $i-1$ و $i+2$ تأثیر می‌گذارند و عقاید همگی یکسان می‌شود.
- اگر عقاید عامل‌های i و $i+1$ مخالف یکدیگرند، عقیده عامل $i-1$ برابر عقیده عامل $i+1$ و عقیده عامل $i+2$ برابر عقیده عامل

⁵ Stauffer

⁶ Lattice

⁷ Steady state

¹ Strongly connected

² Friedkin and Johnsen

³ Sznajd

⁴ Social validation

مدل را روی شبکه پیچیده اجرا کرده‌اند، ساختارهای شبکه‌ای جهان کوچک^۲، بی‌مقیاس^۳، و گراف کامل نیز استفاده شده‌اند، و علاوه بر تغییر در ساختار شبکه، ابعاد دیگری نیز در پژوهش‌ها در نظر گرفته شده‌اند، مانند افزایش قلمرو تعامل و تعداد متغیرهای حالت [۴۴].

۴-۱۱- مدل دوفان

دوفان^۴ یک مدل شکل‌گیری عقیده در سال ۲۰۰۰ ارائه کرد و گسترش‌هایی روی همین مدل را در سال‌های ۲۰۰۲ با اعمال عدم قطعیت و ۲۰۰۴ با معرفی و اعمال مفهومی به نام «محدوده اعتماد نرم» ارائه کرد. مدل دوفان [۴۶] یک مدل پیوسته است که در هر گام زمانی دو عامل از N عامل موجود به طور تصادفی انتخاب می‌شوند و اگر اختلاف عقیده آنها از آستانه مشخص d کمتر باشد، عقاید آنها، o_i و o_j ، با پارامتر همگرایی μ (بین صفر و 0.5) طبق روابط زیر به هم نزدیک می‌شوند:


$$\begin{cases} o_i(t+1) = o_i(t) + \mu(o_j(t) - o_i(t)) \\ o_j(t+1) = o_j(t) + \mu(o_i(t) - o_j(t)) \end{cases}$$

تعداد قطب‌ها یا خوشه‌هایی که نهایتاً توسط این مدل تولید می‌شود، به d بستگی دارد به طوری که بیشترین تعداد قطب‌ها، p_{max} از رابطه $p_{max} = 1/(2d)$ تبعیت می‌کند، اما مقادیر μ و N روی زمان همگرایی تأثیر می‌گذارند.


مدل دوفان برای بررسی میزان و روند عقاید مردم در مواردی مانند دین، مذهب، جناح سیاسی، و امثال اینها مناسب است. مثلاً دو نفر شیعه مذهب ممکن است در مورد جزئیات یک حکم شرعی اختلاف نظر داشته باشند و با هم مباحثه کنند، اما قاعده‌تاً یکی از این دو در این خصوص با یک فرد مسیحی بحث نمی‌کند زیرا اختلاف نظر آنها (d در مدل دوفان) خیلی زیاد است. البته قابل تصور است که مباحثه بین یک مسلمان و یک مسیحی روی اصل دین و انتخاب آنها باشد. ضمناً چنین مباحثاتی با افراد مختلف انجام می‌شود و حتی اگر دویه‌دو هم نباشد، در مدل‌سازی قابل تبدیل به مباحثات دویه‌دو است و در دوره‌های مختلف تکرار می‌شود.

در گسترشی روی مدل اولیه دوفان، مفهوم توافق نسبی^۵ جایگزین مفهوم اعتماد محدود می‌شود که در مدل اولیه استفاده شده بود. ضمناً در این مدل، علاوه بر عقیده، عدم قطعیت نیز می‌تواند در اثر تعاملات تغییر کند. در اعتماد محدود، عامل‌ها در صورتی روی عقیده یکدیگر اثر می‌گذارند که اختلاف عقیده آنها از آستانه‌ای^۶

مثال مجلس نمایندگان که در مدل اشنید مطرح شد، در اینجا نیز قابل تصور است با این تعمیم که هر نماینده علاوه بر نمایندگانی که در چپ و راست خود قرار دارد، با نمایندگانی که در ردیف‌های جلوتر و عقب‌تر نشسته‌اند نیز گفتگو می‌کند.




شکل ۲. تأثیر عامل‌های همسایه روی عقیده عامل در مدل یک‌بعدی اشنید



شکل ۳. تأثیر عامل‌ها روی عقیده عامل‌های همسایه در مدل دو بعدی اشتوفر [۴۴]

۴-۱۰- مدل گلم

گلم^۱ در سال ۲۰۰۰ نشان داد قاعده بهنگام‌سازی یک بعدی در مدل اشنید می‌تواند در مدل دوبعدی نیز دقیقاً اعمال شود، به این صورت که قاعده یک بعدی برای هر یک از چهار زنجیره (دو زنجیره افقی و دو زنجیره عمودی) که توسط چهار ذره وسط یک مشبک ایجاد می‌شود، اعمال گردد (شکل ۴).



شکل ۴. تأثیر عامل‌ها روی عقیده عامل‌های همسایه در مدل دو بعدی گلم [۴۴]

اما افراد در یک مشبک دوبعدی با یکدیگر ارتباط برقرار نمی‌کنند. پژوهش‌های مختلفی در جهت نزدیک‌تر کردن این مدل به دنیای واقعی انجام شده، مثلاً برخی ساختار مشبک را تغییر داده‌اند، برخی

⁴ Deffuant

⁵ Relative agreement

⁶ Threshold

¹ Galam

² Small world

³ Scale free

دوفان در مدل دیگری [۴۸] اعتماد محدود نرم^۲ را به مدل خود اضافه کرد و این پدیده روانشناسی اجتماعی را مد نظر قرار داد که وقتی از گروهی خواسته می‌شود در مورد یک سؤال کلی به اجماع برسند، در طی بحثی که بین خود انجام می‌دهند، به اجماعی دست می‌یابند که به جای اینکه متوسط نظرات اولیه افراد باشد، نظرات به صورت افراطی به یکی از دو انتهای طیف گرایش دارند و آزمایش‌های مختلف این موضوع را اثبات کرده است. همچنین برخی مطالعات نشان داده که هر چه فضای بحث، غیررسمی و آزاد یا به اصطلاح بحث داغ^۳ باشد، اجماع نهایی به افراط نزدیک‌تر است و در مقابل، فضای بحث رسمی و با محدودیت، منجر می‌شود اجماع به میانگین عقاید اولیه افراد نزدیک‌تر باشد.

در این مدل، افراد مشابه مدل قبلی دوفان یک عقیده پیوسته و یک عدم قطعیت دارند که با هم به صورت تصادفی تعامل می‌کنند. تأثیر افراد روی عقیده یکدیگر متناسب با یک تابع گاوسی از فاصله بین دو عقیده است. طبق این مدل، اگر بین جمعیت، افراط‌گرایی حضور داشته باشند، انتقال به یکی از دو انتهای طیف انجام می‌شود، حتی اگر تعداد افراط‌گرایان در دو انتهای طیف برابر باشند.

در مدل اولیه دوفان، مطابق مفهوم اعتماد محدود، دو عامل که در محدوده اعتماد هم قرار می‌گرفتند و تعامل می‌کردند، نظر عامل دیگر را بر اساس ضریب ثابتی به سمت خود جلب می‌کردند. اما در این مدل، مفهوم اعتماد محدود نرم معرفی و استفاده شده که در آن، میزان جلب نظر عامل مقابل متناسب است با تابع گاوسی^۴ از فاصله بین عقاید و انحراف معیار عدم قطعیت عامل. لحاظ نمودن این ویژگی در مدل و انجام آزمایش‌های مختلف، نحوه گرایش عقاید به حدود یک انتهای طیف عقاید را توجیه می‌نماید.

عامل‌های افراط‌گرا در این مدل، عامل‌هایی هستند که عقیده آنها در یک انتهای طیف قرار دارد و عدم قطعیت آنها خیلی کم است و سایر عامل‌ها که می‌توان آنها را میانه‌رو^۵ نامید، در بازه عقاید توزیع شده‌اند و عدم قطعیت بیشتری دارند.

در این مدل، تأثیر عامل با عقیده $o(t)$ و عدم قطعیت $u(t)$ پس از بحث، بر روی عامل با عقیده $o'(t)$ و عدم قطعیت $u'(t)$ با تابع گاوسی زیر بیان می‌شود:

$$g_u(o - o') = \exp\left(-\left(\frac{o - o'}{u}\right)^2\right)$$

کمتر باشد، این آستانه می‌تواند به عنوان یک عدم قطعیت در اطراف عقیده تلقی گردد که افراد به عقاید خارج از محدوده عدم قطعیت خود، توجه نمی‌کنند [۴۷].

هر عامل i با دو متغیر بازنمایی می‌شود، عقیده o_i و عدم قطعیت u_i که هر دو، اعداد حقیقی هستند. محدوده از $o_i - u_i$ تا $o_i + u_i$ ، قطعه^۱ عقیده عامل i نامیده می‌شود. با این فرض که عقاید در محدوده -1 تا $+1$ قرار گیرند، دو عامل به طور تصادفی با یکدیگر تعامل می‌کنند و ممکن است روی عقیده یکدیگر تأثیر بگذارند. تغییرات o_j (عقیده عامل j) تحت تأثیر عامل i متناسب است با همپوشانی بین قطعات آنها (میزان توافق آنها) تقسیم بر عدم قطعیت قطعه تأثیرگذار (که دلیل نامگذاری نسبی را توجیه می‌کند). نکته قابل توجه این است که عامل‌های با عدم قطعیت متفاوت، تأثیر واقعی‌شان متقارن نیست، به دلیل تقسیم عدم قطعیت عامل تأثیرگذار.


شکل ۵ تأثیر عامل i با عقیده o_i و عدم قطعیت u_i بر روی عامل j با عقیده o_j و عدم قطعیت u_j را نشان می‌دهد. c_{ij} همپوشانی بین عقاید دو عامل است و $2u_i \cdot c_{ij}$ بخشی از i است که با j همپوشانی ندارد. در سمت راست شکل، موقعیت قطعه‌ها قبل از تعامل با خط‌چین، و بعد از تعامل با خط توپر نشان داده شده‌اند. توافق، همپوشانی منهای ناهمپوشانی است، طبق این رابطه:

$$c_{ij} - (2u_i - c_{ij}) = 2(c_{ij} - u_i)$$

و توافق نسبی، حاصل تقسیم توافق به طول قطعه عقیده عامل i یعنی $2u_i$ است. بنابر این توافق نسبی خواهد بود:

$$\frac{2(c_{ij} - u_i)}{2u_i} = \frac{c_{ij}}{u_i} - 1$$

در شکل ۵ پارامترهای مورد استفاده در رابطه فوق مشخص شده‌اند.



شکل ۵. تأثیر عامل روی عقیده عامل دیگر در مدل توافق نسبی دوفان [۴۷]

⁴ Gaussian function

⁵ Moderate

¹ Segment

² Smooth Bounded Confidence

³ Warm discussion

نشان دهنده قدرت تأثیر او روی دیگران است. این دو پارامتر شامل پارامتر قدرت متقاعدسازی^۳ p_i ، و پارامتر قدرت پشتیبانی^۴ s_i است. پارامتر قدرت متقاعدسازی برای تغییر عقیده دیگران و پارامتر قدرت پشتیبانی برای ثابت نگه داشتن عقیده آنها است. فرض می‌شود این دو پارامتر اعداد تصادفی با متوسط به ترتیب p و s باشند. به این ترتیب اغتشاش در سیستم ایجاد می‌شود و دینامیک پیچیده در مدل برقرار می‌شود. در ساده‌ترین حالت، جمع تأثیرات، I_i ، که یک فرد i از محیط جامعه خودش تجربه می‌کند طبق رابطه زیر است:

$$I_i = \left[\sum_{j=1}^N \frac{p_j}{d_{ij}^\alpha} (1 - o_i o_j) \right] - \left[\sum_{j=1}^N \frac{s_j}{d_{ij}^\alpha} (1 - o_i o_j) \right]$$

که α سرعت کاهش تأثیر متناسب با فاصله d_{ij} بین دو نفر را بیان می‌کند. جمله اول در معادله بالا تأثیر متقاعدسازی توسط عامل‌های با عقیده مخالف است (برای عامل‌های موافق، $1 - o_i o_j$ برابر صفر است) و جمله دوم، تأثیر تداوم عقیده یعنی اصرار عامل‌های هم‌عقیده i برای باقی ماندن i روی عقیده فعلی خود می‌باشد (در این حالت برای عامل‌های مخالف، $1 + o_i o_j$ برابر صفر است). در هر دو حالت، تأثیر هر عامل روی i متناسب با قدرت متقاعدسازی/ تداوم عقیده اوست. اگر مجموع تأثیر برای تغییر عقیده فرد i بیش از مجموع تأثیر برای ثابت ماندن عقیده‌اش باشد، I_i مثبت می‌شود.

پویایی عقیده در این مدل توسط رابطه زیر بیان می‌شود:

$$o_i(t+1) = -\text{sign}[o_i(t)I_i(t) + h_i],$$

که در آن h_i یک مقدار تصادفی برای بیان تأثیر تمام منابع غیر از تأثیر اجتماعی بر روی عقیده است. با فرض $h_i=0$ ، طبق این معادله، اگر فشار تغییر عقیده بر فشار تداوم عقیده فعلی غلبه کند، $I_i > 0$ و فرد عقیده‌اش را تغییر می‌دهد. اما h_i می‌تواند غیر صفر باشد و فشار توسط منابعی غیر از افراد تعامل‌کننده در جهت یکی از عقاید ممکن را در مدل وارد کند.

از این مدل مثلاً می‌توان برای بررسی عقاید جامعه و روند تغییرات آن در یک فضای انتخابات عمومی بین دو گزینه مثل انتخابات ریاست جمهوری بین دو نامزد استفاده کرد. اگر رسانه‌های عمومی به سمت نامزد خاصی گرایش داشته باشند، h_i مقداری غیر صفر دارد که تأثیرگذاری به سمت یکی از نامزدها را نشان می‌دهد. در مباحثاتی که در شبکه‌های اجتماعی برخط یا گروه‌ها انجام می‌شوند هر بار یک نفر در تأیید یا رد یکی از نامزدها اظهار نظر می‌کند و تأثیری در مخاطبان می‌گذارد (p_j یا s_j)، وابسته به شناخت مخاطبان

بنابر این، تغییرات عقیده و عدم قطعیت عامل در یک گام زمانی با روابط زیر بیان می‌شود:

$$o(t+1) = \frac{o(t) + o'(t)g_u(o(t) - o'(t))}{1 + g_u(o(t) - o'(t))},$$

$$u(t+1) = \frac{u(t) + u'(t)g_u(o(t) - o'(t))}{1 + g_u(o(t) - o'(t))}.$$

۴-۱۲- مدل شکل‌گیری عقیده تأثیر اجتماعی

فرضیه تأثیر اجتماعی در روانشناسی توصیف می‌کند که چگونه افراد تحت تأثیر دیگران قرار می‌گیرند و به نوبه خود روی دیگران تأثیر می‌گذارند. طبق تعریف، هر گونه تأثیرگذاری و تأثیرپذیری روی احساس، افکار، یا رفتار فرد که بر اثر حضور یا عمل واقعی، ضمنی، یا تصور شده دیگران باشد، تأثیر اجتماعی^۱ است [۴۹]. آس^۲ نیز در دهه ۱۹۵۰ با مطالعات و آزمایش‌های تجربی اثبات کرده بود که عقیده افراد تحت تأثیر اطرافیان آنها و فشار گروهی قرار می‌گیرد [۵۰، ۵۱]. بر همین مبنا، مدل‌های شکل‌گیری عقیده مبتنی بر فرضیه تأثیر اجتماعی ابداع شدند [۵]. بر اساس این فرضیه، تأثیر یک گروه اجتماعی روی یک فرد به موارد زیر بستگی دارد:

- تعداد افراد گروه: هر چه تعداد افراد بیشتری مخالف عقیده فرد باشند و با او تعامل کنند، تأثیر بیشتری در تغییر عقیده فرد دارند و به‌طور مشابه اگر تعداد افراد بیشتری با او هم‌عقیده باشند و با او تعامل کنند، استوار ماندن فرد بر عقیده فعلی خود بیشتر می‌شود.
- قدرت متقاعد کردن گروه متقاعدکننده: افراد دارای قدرت‌های متفاوتی در متقاعد کردن هستند. این متقاعد کردن می‌تواند در جهت تغییر عقیده (توسط فردی با عقیده مخالف) یا در جهت تقویت عقیده فعلی فرد (توسط فرد هم‌عقیده) باشد.
- فاصله گروه متقاعدکننده از فرد: این فاصله می‌تواند فاصله فیزیکی و/یا فاصله تجربی باشد و حتی فاصله زمانی از زمان تعامل نیز می‌تواند ملاک قرار گیرد. هر اندازه فاصله گروه متقاعدکننده از فرد کمتر باشد، تأثیرگذاری روی فرد بیشتر است.

طبق مدل شکل‌گیری تأثیر اجتماعی در نقطه شروع، N فرد وجود دارند که هر فرد i یکی از دو عقیده مخالف $o_i = \pm 1$ را دارد. ضمناً برای هر فرد دو پارامتر با مقادیر حقیقی در نظر گرفته می‌شود که

³ Persuasiveness


⁴ Supportiveness

¹ Social impact

² Solomon E. Asch

۴-۱۴- مدل قاعده اکثریت

مدل قاعده اکثریت^۳ [۵۲] در سال ۲۰۰۲ معرفی شد و مناظره و اظهار نظر عموم پس از آن را توصیف می‌کند. در این مدل، عقیده‌های دودویی به یک جمعیت N تایی از عامل‌ها تخصیص می‌یابند. عامل‌های با عقیده $+1$ و با عقیده -1 به ترتیب نسبت $p+$ و $p-$ از کل جمعیت عامل‌ها را تشکیل می‌دهند ($p=1-p+$). برای سادگی فرض کنید تمام عامل‌ها می‌توانند با هم ارتباط داشته باشند و شبکه اجتماعی ارتباطات، یک گراف کامل است. در هر تکرار، گروهی از r عامل به عنوان گروه مباحثه به صورت تصادفی انتخاب می‌شوند و به عنوان نتیجه تعامل، تمام عامل‌های گروه با عقیده اکثریت عامل‌های درون گروه هم‌عقیده می‌شوند. اندازه گروه، r ثابت نیست و در هر گام، از یک توزیع تصادفی انتخاب می‌شود (شکل ۶).



شکل ۶. مدل قاعده اکثریت: تأثیر عقیده اکثریت گروه به تمام اعضای گروه [۱۹]

گونه‌های مختلفی از مدل قاعده اکثریت نیز بررسی شده است، مثلاً عقیده چندحالتی، امکان حرکت عامل‌ها در فضا، امکان تعامل عامل با تعداد متغیری از همسایه‌ها، وجود افراد مخالف نظر جمع^۴، و وجود عامل‌های غیرمنعطف که همیشه روی نظر خود پافشاری می‌کنند [۱۹].

مثلاً بعد از پخش یک مناظره تلویزیونی بین نامزدهای یک انتخابات عمومی که مردم شناخت کافی از آنها ندارند، افراد جامعه در جمع‌های کوچک دو یا چند نفری نظرات خود را با هم در میان می‌گذارند و به یک جمع‌بندی (هر چند موقت) می‌رسند و البته تمایل آنها تحت تأثیر این تعامل‌ها در جمع‌های مختلف ممکن است بارها تغییر کند. مدل قاعده اکثریت برای این شرایط مدل مناسبی است. اگر این محدودیت را قائل شویم که فقط جمع‌های دونفری شکل بگیرد، مدل رأی‌دهنده که پیشتر بررسی شد، مدل مناسب‌تری است.

از گوینده (نظردهنده)، تأثیرپذیری متفاوت است (d_{ij} و α) و در طی گام‌های زمانی متوالی، عقیده جامعه و تصمیم نهایی در انتخاب نامزد و تعیین برنده نهایی انتخابات مشخص‌تر می‌شود. قاعده‌تاً مدل‌ساز بر اساس شناخت خود از جامعه، نمونه‌گیری‌ها و آمارگیری‌ها، پارامترها را تخمین می‌زند و مدل را اجرا (شبیه‌سازی) می‌کند.

۴-۱۳- مدل HK

مدل HK^۱ در سال ۲۰۰۲ [۳۷] ارائه شد. در این مدل N عامل در سیستم وجود دارند که هر عامل عقیده پیوسته $O_i(t)$ دارد و مشابه مدل اولیه دوفان طبق قاعده اعتماد محدود، هر فرد همسایه‌های مرتبط را انتخاب می‌کند و فقط با همسایه‌هایی ارتباط دارد که عقایدشان به اندازه کافی به او نزدیک است. در مدل دوفان، در هر گام زمانی عامل تحت تأثیر یک عامل دیگر قرار می‌گیرد اما در این مدل، تحت تأثیر عامل‌های دیگر (بین صفر تا تمام عامل‌ها) قرار می‌گیرد و بر اساس وزنی که به آنها تخصیص می‌دهد، عقیده‌اش تغییر می‌کند. هر عامل i یک وزن a_{ij} برای عقیده سایر عامل‌های j قائل است به طوری که جمع a_{ij} ها یک می‌شود و شکل‌گیری عقیده عامل i در هر گام زمانی طبق رابطه زیر تغییر می‌کند:

$$O_i(t+1) = a_{i1}O_1(t) + a_{i2}O_2(t) + \dots + a_{in}O_n(t)$$

اما ضرایب ممکن است با زمان تغییر کنند، در این صورت a_{ij} تابع زمان و/یا کل عقاید عامل‌ها، یعنی $O(t)$ است، بنابر این:

$$a_{ij} = a_{ij}(t, O(t)),$$

و اگر تمامی این وزن‌های متغیر طی زمان در یک ماتریس جمع‌آوری شوند، ماتریس زیر با n سطر و n ستون ساخته می‌شود که یک ماتریس اتفاقی^۲ است، ماتریسی نامنفی است که جمع هر سطر آن، یک است:

$$A(t, O(t)) = (a_{ij}(t, O(t))).$$

به این ترتیب معادله زیر مدل عمومی را بیان می‌کند.

$$O(t+1) = A(t, O(t))O(t) \quad \text{for } t \in T$$

حالت خاصی از این مدل که ضرایب با زمان تغییر نکنند، مدل کلاسیک یا همان مدل دیگروت است و حالت خاص دیگر، مدل FJ است که عامل برای عقیده خود یک وزن و برای عقاید سایر عامل‌ها نیز یک وزن قائل می‌شود. مدل آبلسون نیز مدل مشابهی است اما زمان را پیوسته در نظر می‌گیرد.

³ Majority rule

⁴ Contrarians

¹ Hegselmann and Krause

² Stochastic

۴-۱۵- مدل آلتافینی

آلتافینی^۱ مدل‌هایی در سال‌های ۲۰۱۲، ۲۰۱۳، و ۲۰۱۵ ارائه کرد. او پویایی عقیده را برای حالت خاصی در گراف عامل‌ها در نظر گرفت که روابط خصمانه^۲ نیز بین عامل‌ها وجود دارد و روابط خصمانه بین عامل‌ها را در شبکه تأثیرگذاری عقاید با علامت منفی نشان داد [۵۳]. در حالت خاصی که گراف علامت‌دار را بتوان به دو قسمت تقسیم کرد به‌طوری که گره‌های هر قسمت دارای علامت‌های مثبت بین خود باشند و تمام لبه‌های بین دو گره متعلق به دو قسمت مختلف، منفی باشند، این گراف متوازن ساختاری^۳ است. گراف بدون علامت منفی حالت خاصی است که یکی از این دو بخش، تهی است. آلتافینی نشان داد اگر گراف تأثیر عقاید، متوازن ساختاری باشد، می‌توان با تبدیل‌هایی علامت‌های منفی در شبکه را حذف کرد و پویایی آن را با اصول و روابط حاکم بر سیستم‌های یکنوا^۴ تحلیل نمود.

در اغلب مدل‌ها چنین در نظر گرفته شده که عامل‌ها با تعامل همکارانه^۵ سعی می‌کنند به اجماع برسند در صورتی که نمونه‌هایی در دنیای واقع می‌توان یافت که برخی عامل‌ها با یکدیگر رقابت^۶ می‌کنند. آلتافینی در [۵۴] نشان داد در شرایط خاص، دو قطبی ایجاد می‌شود به‌طوری که افراد به دو دسته با عقاید مخالف تقسیم می‌شوند. این اتفاقی است که مثلاً در سیستم‌های سیاسی دوحزبی، بازارهای انحصار دوقطبی^۷، بلوک‌های رقیب بین‌المللی و امثال اینها وجود دارد.

در [۵۵] حالت خاصی در نظر گرفته شده که عامل‌ها ضمن وجود برخی روابط رقابتی باید به یک اجماع برسند، مشابه مسابقه‌ای که بین دو گروه رقیب برگزار می‌شود و در پایان تنها یک نتیجه اعلام می‌شود. در ضمن شرط توازن ساختاری نیز برداشته شده و گراف جهت‌دار علامت‌دار قویاً همبند^۸ در نظر گرفته شده است.

۴-۱۶- مدل BEBA

بر اساس ادعای ابداع‌کنندگان مدل BEBA^۹ [۵۶]، مدل‌های شکل‌گیری عقیده عمدتاً بر اساس قواعد ساده‌ای از تأثیرپذیری افراد تحت تأثیر اجتماع اطراف، بنا شده‌اند، در حالی که در دنیای امروزی که غالباً محتوا از طریق شبکه‌های برخط و در بسیاری موارد با استفاده از ابزارهای هوش مصنوعی تولید و منتشر می‌شود، دو پدیده

اجتماعی نقش مهمی دارند: (۱) نتیجه معکوس (که استعاره آن، پس زدن آتش تفنگ است) و (۲) جذب متعصبانه. منظور از نتیجه معکوس آن است که یک عقیده مخالف ممکن است باعث تثبیت بیشتر عقیده فرد شود، به این معنی که نه تنها باعث تعدیل عقیده او نشود، بلکه او را در عقیده فعلی خود راسخ‌تر نماید. جذب متعصبانه نیز به این معنی است که اگر عقیده فرد دیگری تأییدکننده عقیده فرد باشد، عقیده او را می‌پذیرد. مدل BEBA در واقع گسترش یافته‌ای از مدل دیگروت است که نتیجه معکوس نیز در آن لحاظ شده است.

۴-۱۷- سایر مدل‌های شکل‌گیری عقیده

مهمترین و مشهورترین مدل‌های شکل‌گیری عقیده به اختصار معرفی شدند. سایر مدل‌های شکل‌گیری عقیده، عمدتاً گونه‌هایی از این مدل‌ها با تغییراتی در برخی ابعاد آنها و یا ترکیب‌هایی از آنها محسوب می‌شوند.

۵- ابعاد مدل‌های شکل‌گیری عقیده

برای مدل‌های مختلف شکل‌گیری عقیده می‌توان ابعاد یا ویژگی‌های مختلفی قائل شد. در [۳۴] سه ویژگی برای دسته‌بندی مدل‌های شکل‌گیری عقیده ذکر شده است: (۱) زمان (پیوسته/ گسسته)، (۲) عقیده (پیوسته/ گسسته)، و (۳) تمام فرضیاتی که در خصوص تأثیر اجتماعی در مدل انجام می‌شود. در [۲۹] مقالات منتشر شده در حوزه استفاده از مدل‌سازی مبتنی بر عامل برای شکل‌گیری عقیده بررسی شده‌اند و ویژگی‌هایی که در این مدل‌های مبتنی بر عامل شناسایی شده‌اند، عبارتند از: فضای عقیده، جهت تأثیرگذاری عامل‌ها روی یکدیگر (دوطرفه، یک‌طرفه)، عامل‌های طرف تعامل (دوبه‌دو، هر دو عامل ممکن، نزدیک‌ترین همسایه‌ها)، تابع به‌روزرسانی (مثلاً متوسط یا متوسط وزن‌دار تأثیر عامل‌های تأثیرگذار)، تواتر به‌روزرسانی عقاید عامل‌ها (به‌روزرسانی منظم یا دوره‌ای تمام عامل‌ها در هر گام زمانی، یا به‌روزرسانی نامنظم)، و تابع مطلوبیت^{۱۰} که در برخی بررسی‌ها عامل‌ها بر اساس تابع مطلوبیت رفتار می‌کنند.

در این پژوهش، ویژگی‌های جامع‌تری از مدل‌های شکل‌گیری عقیده با مطالعه مدل‌های شکل‌گیری عقیده و بررسی نقاط اشتراک و

⁶ Compete⁷ Duopolistic⁸ Strongly connected signed digraph⁹ Backfire Effect and Biased Assimilation¹⁰ Utility function¹ Claudio Altafini² Antagonistic³ Structurally balanced⁴ Monotone systems⁵ Collaborative

افتراق آنها استخراج شده‌اند که در ادامه بررسی می‌شوند.

۵-۱- فضای عقیده

در مدل کردن عقیده، به دو صورت می‌توان به عقیده کمیّت داد:

- عقیده گسسته: در مدل‌های با عقیده گسسته، عامل‌ها دارای مقادیر گسسته مثلاً صفر و یک به عنوان عقیده خود هستند و سعی می‌کنند با تعامل با دیگران عقیده‌شان با آنها هماهنگ شوند [۲]. از مدل‌های مشهور این دسته، مدل‌های اِشنید^۱، رأی‌دهنده، قاعده اکثریت و مدل تأثیر اجتماعی است.
- عقیده پیوسته: در مدل‌های پیوسته، مثل مدل‌های دوفان، عقیده هر عامل می‌تواند عددی حقیقی در یک بازه عددی مثل $[0,1]$ باشد. این بازه، فضای عقیده نامیده می‌شود.

۵-۲- زمان گسسته / پیوسته

زمان در مدل‌های شکل‌گیری عقیده به دو صورت گسسته یا پیوسته تلقی می‌شود:

- زمان گسسته: تغییرات عقیده به صورت رویدادهای گسسته فرض می‌شود و در مدل‌سازی تحلیلی آن از معادلات تفاضل^۲ استفاده می‌شود. اغلب مدل‌های شکل‌گیری عقیده، زمان گسسته هستند.
- زمان پیوسته: در مدل‌سازی با زمان پیوسته، اختلاف زمانی بین رویدادها به سمت صفر میل می‌کند و بنابر این از معادلات دیفرانسیل^۳ برای مدل‌سازی تحلیلی استفاده می‌شود، مانند مدل‌های ابلسون و تیلر.

۵-۳- شبکه عامل‌ها

می‌توان برای شبکه عامل‌هایی که با هم تبادل عقیده می‌کنند یا می‌توانند تبادل عقیده کنند، دسته‌بندی قائل شد:

- خطی یا یک بعدی: عامل‌ها به صورت زنجیره با یکدیگر تعامل دارند و هر عامل فقط با دو عامل دیگر (چپ و راست) تعامل دارد، مانند مدل اِشنید و آیزینگ یک‌بعدی.
- مشبک^۴ دو بعدی: شبکه به صورت گراف مسطح و منظمی است که هر گره (جز گره‌های مرزی در اطراف شبکه) با چهار

- گره دیگر (چپ، راست، بالا، پایین) تعامل دارد. مدل‌های اِشنید دو بعدی، اِشتوفر^۵ و گَلم^۶ چنین ساختاری دارند.
- گراف کامل: هر گره با تمامی سایر گره‌ها تعامل دارد یا می‌تواند داشته باشد.
- گراف تصادفی: از گراف‌های تصادفی نظیر گراف تصادفی اردوش-رینی^۷ [۵۷]، گراف جهان کوچک^۸ [۵۸]، و گراف بی‌مقیاس^۹ [۵۹] برای شبکه ارتباط عامل‌ها استفاده می‌شود.

۵-۴- محدودیت تعامل عامل‌ها

در برخی مدل‌های شکل‌گیری عقیده، علاوه بر ساختار حاکم بر عامل‌های تعامل‌کننده، محدودیت‌هایی روی تعامل عامل‌ها در نظر گرفته می‌شود، طبق دسته‌بندی زیر:

- بدون محدودیت: برخی مدل‌ها محدودیتی روی عامل‌های تعامل‌کننده ندارند و هر دو عاملی که با هم ارتباط دارند (در گراف مدل، لبه‌ای بین آنها وجود دارد)، می‌توانند با هم تعامل کنند.
- اعتماد محدود^{۱۰}: با این محدودیت، عامل‌ها تنها در صورتی با یکدیگر تعامل می‌کنند که عقاید آنها از آستانه مشخص که اعتماد محدود نامیده می‌شود، به هم نزدیک‌تر باشند [۳۱]. از مشهورترین مدل‌های این دسته، مدل دوفان و مدل HK هستند.
- سایر محدودیت‌ها: علاوه بر اعتماد محدود که ذکر شد، محدودیت‌های دیگر نیز می‌توانند اعمال شوند، مثل توافق نسبی^{۱۱} که در مدل توافق نسبی دوفان استفاده شده است.

۵-۵- میزان تأثیر عامل‌ها

میزان تأثیر عامل‌های تعامل‌کننده یا پارامتر همگرایی^{۱۲}: این شاخص تعیین می‌کند وقتی عامل با یک یا چند عامل دیگر تعامل می‌کند، چقدر و در چه جهتی تغییر عقیده در عامل اتفاق می‌افتد. این شاخص می‌تواند نوع رابطه بین عامل‌ها تلقی شود که در برخی مدل‌ها یکسان و در برخی، متفاوتند. برخی مهمترین انواع آنها به شرح زیر است اما محدود به اینها نیست:

- ضریب ساده: در برخی مدل‌ها مثل مدل اولیه دوفان تأثیر عامل‌ها روی عقیده هم با یک ضریب ساده بیان می‌شود.

⁷ Erdős-Rényi

⁸ Small-world

⁹ Scale-free

¹⁰ Bounded confidence

¹¹ Relative agreement

¹² Convergence

¹ Sznajd

² Difference Equations

³ Differential Equations

⁴ Lattice

⁵ Stauffer

⁶ Galam

خطی) اصل برهم‌نهی برقرار نیست.

تحلیل مدل‌های خطی نسبت به مدل‌های غیرخطی ساده‌تر است و به صورت سیستماتیک توسط روش‌های تحلیل خطی مانند تئوری ماتریس، زنجیره مارکوف و تئوری گراف می‌توان آنها را تحلیل کرد. مدل‌های فرنج، آلبسون و FJ از این دسته هستند. وقتی ساختار مدل تغییر می‌کند یا وزنی که عامل‌ها به عقیده عامل‌های دیگر تخصیص می‌دهند به خود عقیده‌ها وابسته باشد، مدل غیرخطی می‌شود. در این دسته از مدل‌ها ابزارهای ریاضی مانند زنجیره مارکوف دیگر قابل اعمال نیستند و برای تحلیل این مدل‌ها، شبیه‌سازی گزینه مناسبی است. مدل‌های دوفان و HK که در آنها شرط اعتماد محدود لحاظ شده، در این دسته قرار می‌گیرند.

۵-۸- سایر ویژگی‌های مدل‌های شکل‌گیری عقیده

علاوه بر ابعاد یا ویژگی‌هایی که ذکر شدند، ویژگی‌های دیگری نیز می‌توان برشمرد که مختص مدل‌های خاصی نیستند و در این بخش بررسی می‌شوند. این ویژگی‌ها را در اغلب مدل‌های شکل‌گیری عقیده می‌توان در نظر گرفت و در بررسی شکل‌گیری عقیده جامعه با مدل‌های شکل‌گیری عقیده، آنها را لحاظ نمود.

۵-۸-۱- همگونی/ناهمگونی جامعه

برحسب اینکه رفتار تمامی عامل‌ها یکسان است یا خیر، مدل‌سازی را به دو دسته زیر می‌توان دسته‌بندی نمود:

- با عامل‌های همگون: عامل‌ها و رفتار آنها همگی مشابه هم هستند و عامل‌ها از یک (مجموعه) قاعده برای تصمیم‌گیری و رفتارشان استفاده می‌کنند.
- با عامل‌های ناهمگون: عامل‌ها را می‌توان به دو دسته یا بیشتر تقسیم کرد که هر دسته تفاوتی با سایر دسته‌ها دارد، چنانکه در دنیای واقع نیز در حوزه شکل‌گیری عقیده مثلاً برخی افراد در موضوعی خبره و صاحب‌نظر هستند و عقیده آنها دقیق‌تر است و تأثیر بیشتری روی دیگران دارند، یا از نظر اعتماد و آستانه اعتماد تفاوت دارند. در بررسی جنبش‌های اجتماعی که رهبر(ها) و پیروان در آن نقش دارند، افراد (عامل‌ها) نقش‌های یکسانی ندارند، مثلاً در [۶۲] و [۶۳] نقش رهبر به ترتیب در مدل‌های دوفان و HK بررسی شده‌اند.

- وزن‌دار: در مدل‌هایی مثل دیگروت و HK، میزان تأثیر بر اساس وزن‌هایی است که عامل به هر یک از عامل‌های دیگر تخصیص می‌دهد. این وزن‌ها می‌توانند متفاوت باشند و ممکن است طی زمان تغییر کنند. در برخی مدل‌ها به جای متوسط حسابی، روش‌های دیگری مانند متوسط هندسی یا متوسط همساز^۱ استفاده می‌شود [۶۰].
- بر اساس میزان اشتراک: میزان اشتراک و اختلاف عقیده می‌تواند ملاک میزان تأثیر عامل‌ها روی یکدیگر باشند. مثلاً توافق نسبی یا تابع گاوسی^۲ در برخی مدل‌های دوفان مثالی از این دسته هستند.
- تأثیر مخالف: برخی مدل‌ها رابطه دشمنانه را نیز بین عامل‌ها در نظر می‌گیرند به‌طوری که عقیده عامل در تعامل با عامل دشمن، از او دور می‌شود. در مدل آلتافینی روابط دشمنانه در نظر گرفته شده‌اند.

۵-۶- وابستگی به زمان

بر اساس وابستگی به زمان، مدل‌های شکل‌گیری عقیده را به دو دسته می‌توان تقسیم کرد:

- وابسته به زمان: اگر شرایط و محدودیت‌های حاکم بر مسأله در طی زمان تغییر کند، مدل، وابسته به زمان است. مستقل از زمان: بر خلاف مدل‌های وابسته به زمان، در مدل‌های مستقل از زمان، شرایط و محدودیت‌های حاکم در طی زمان تغییر می‌کنند. مهمترین شرط، تأثیرپذیری یا تأثیرگذاری عامل‌ها روی عقیده یکدیگر است که در اغلب مدل‌ها با ماتریس تعامل نشان داده می‌شود. به عنوان نمونه، در [۳۷] و [۶۱] چنین مدل‌هایی بررسی شده‌اند.

۵-۷- خطی/غیرخطی

مدل‌های شکل‌گیری عقیده را از منظر دیگری می‌توان به دو دسته خطی یا غیرخطی تفکیک کرد:

- مدل‌های خطی: در مدل‌های خطی (و به طور کلی در سیستم‌های خطی) از اصل برهم‌نهی^۳ پیروی می‌شود. طبق اصل برهم‌نهی پاسخ تولید شده به ازای دو محرک در زمان و مکان واحد، برابر است با مجموع پاسخ‌های تولید شده توسط هر یک از دو محرک.
- مدل‌های غیرخطی: در مدل‌های غیرخطی (بر خلاف مدل‌های

³ Superposition

¹ Harmonic mean

² Gaussian function

۵-۸-۲- تعداد ابعاد فضای عقیده

از این دیدگاه نیز می‌توان دسته‌بندی زیر را قائل شد:

- فضای عقیده یک‌بعدی: عقیده تنها با یک متغیر مدل می‌شود، مثل متغیر دودویی برای موافقت/مخالفت، یا در یک طیف عددی (مثل تخمین جمعیت جهان در ۱۰ سال آینده یا نسبت دادن احتمال وقوع در بازه پیوسته صفر تا یک به یک اتفاق).
- فضای عقیده چندبعدی: عقیده دارای بیش از یک بعد است. مثلاً در [۶۴] هر عامل باید عقیده‌ای در مورد نحوه تخصیص منابع محدود به n پروژه داشته باشد، پس برای هر پروژه باید یک مقدار مشخص از منابع در نظر بگیرد و به این ترتیب، عقیده n بعدی است. در فضای چندبعدی برای اندازه‌گیری فاصله عقیده‌ها از هم باید از معیاری مناسب مانند فاصله اقلیدسی استفاده کرد.

۵-۸-۳- تصور اولیه جامعه

تصور اولیه^۱ یا عقیده اولیه افراد نسبت به موضوع در مدل‌های کلاسیک معمولاً توزیع یکنواخت در نظر گرفته می‌شود. تغییر تابع توزیع تصور اولیه افراد (عامل‌ها) یا مقادیر اولیه آنها می‌تواند در شکل‌گیری حالت‌های خاص مانند اجماع، دوقطبی، و چندقطبی شدن جامعه و عقیده گروه‌های مختلف جامعه و سرعت همگرایی مؤثر باشد [۶۵].

۵-۸-۴- قطعی/نویزی

در مدل کردن رفتار انسان‌ها در تغییر عقیده، از نویز یا عدم قطعیت یا رفتار تصادفی نمی‌توان صرف‌نظر کرد، به این معنی که نمی‌توان

پویایی عقیده افراد جامعه را با یک مدل قطعی^۲ بیان کرد [۶۶]. با این حال، مدل‌های شکل‌گیری عقیده را از این منظر به دو دسته می‌توان تقسیم کرد:

- مدل‌های قطعی: در برخی مدل‌ها مثل مدل دیگروت، تغییر عقیده بر اساس یک تابع قطعی تخمین زده می‌شود.
- مدل‌های نویزی: در برخی مدل‌ها نظیر مدل تأثیر اجتماعی [۵] و مدل آیزینگ [۶۷]، به نویز توجه ویژه‌ای شده است. نویز در مدل‌های شکل‌گیری عقیده به مثابه نقش گرما در انتقال فاز^۳ در برخی مدل‌های فیزیکی است که مثلاً برای توجیه رفتار مواد فرومغناطیس در مغناطیسی شدن یا تبدیل حال مواد (از مایع به گاز، گاز به مایع، جامد به مایع و سایر تغییر حالت‌ها) است [۶۸-۷۱]. انتقال فاز می‌تواند پاسخ به این سوال اکسلرود [۷۲] نیز پاسخ دهد که «اگر افراد تمایل دارند عقایدشان به هم نزدیک شود پس چرا این همه تعارض عقاید وجود دارد؟» اگر چه این تمایل به نزدیک شدن افکار (و حتی به طور عام در فرهنگ) وجود دارد و انتظار می‌رود اختلاف‌ها کم شوند، اما از طرف دیگر افرادی وجود دارند که نیروی دافعه یا مخالفتی با همسایگان در شبکه ارتباطی خود دارند که موجب ایجاد یک همگرایی محلی می‌شود که می‌تواند گسترش یابد و به یک قطبیت در کل جامعه تبدیل شود و البته این نیروی دافعه یا مخالفت در افراد مسن‌تر کمتر انتظار می‌رود [۷۳].

مدل‌های شکل‌گیری عقیده که در این مقاله بررسی شدند و ویژگی آنها در ابعاد مختلفی که ذکر شدند در جدول ۱ خلاصه شده‌اند.

³ Phase Transition

¹ First Impression

² Deterministic

جدول ۱. مقایسه اجمالی مدل‌های شکل‌گیری عقیده از منظر ابعاد مختلف

ردیف	مدل	سال ابداع	خلاصه مدل	فضای عقیده	زمان گسسته / پیوسته	شبکه عامل‌ها	محدودیت تعامل عامل‌ها	میزان تأثیر عامل‌ها	وابستگی به زمان	خطی / غیر خطی
۱	آیزینگ (Ising)	۱۹۲۴	مدل فیزیکی برای توجیه مغناطیسی شدن خودبخودی	گسسته	گسسته / پیوسته	خطی / شبکه دویعدی	بدون محدودیت	بر اساس تأثیر (انرژی) همسایه‌ها	مستقل	خطی
۲	فرنچ (French)	۱۹۵۶	هربار متوسط عقیده خود و دیگران	پیوسته	گسسته	گراف	بدون محدودیت	متوسط عقاید	مستقل	خطی
۳	ابلسون (Abelson)	۱۹۶۴	هربار متوسط وزن‌دار عقیده خود و دیگران	پیوسته	پیوسته	گراف	بدون محدودیت	متوسط وزن‌دار	مستقل	خطی
۴	تیلر (Taylor)	۱۹۶۸	مشابه ابلسون، با لحاظ کردن تأثیر رسانه‌ها، مقاومت به تغییر و نرخ تأثیر متغیر	پیوسته	پیوسته	گراف	بدون محدودیت	متوسط وزن‌دار	مستقل	خطی
۵	دیگروت (DeGroot)	۱۹۷۴	هربار متوسط وزن‌دار عقیده خود و دیگران	پیوسته	گسسته	گراف	بدون محدودیت	متوسط وزن‌دار	مستقل	خطی
۶	رای‌دهنده (Voter)	۱۹۷۵	هربار تصادفی یک عامل انتخاب و از او تقلید می‌شود	گسسته	گسسته / پیوسته	گراف جهت‌دار قویاً همبند	بدون محدودیت	تقلید کامل	مستقل	خطی
۷	FJ (Friedkin-Johnsen)	۱۹۹۰ و ۱۹۹۹	وزن مشخصی برای عقیده ابتدایی خود و وزن دیگری برای تمامی همسایگان	پیوسته	گسسته	گراف	بدون محدودیت	متوسط وزن‌دار: وزن g برای عقیده ابتدایی خود و $1-g$ برای متوسط وزن‌دار سایر عامل‌ها	مستقل	خطی
۸	اِشنید (Sznajd)	۲۰۰۰	بر اساس آیزینگ – یک بعدی	گسسته	گسسته	خطی	بدون محدودیت	بر اساس عقیده دو همسایه در زنجیره خطی	مستقل	خطی
۹	اِشتوفر (Stauffer)	۲۰۰۰	مشابه اِشنید، و دویعدی	گسسته	گسسته	دویعدی	بدون محدودیت	بر اساس هم عقیده بودن ۴ عامل همسایه در شبکه 2×2	مستقل	غیر خطی
۱۰	گَلم (Galam)	۲۰۰۰	مشابه اِشتوفر (دویعدی است) و مشابه اِشنید (از نظر تأثیر زنجیره‌های عامل‌ها)	گسسته	گسسته	دویعدی	بدون محدودیت	بر اساس ۴ عامل همسایه در شبکه 2×2	مستقل	غیر خطی
۱۱	دوفان (Deffuant)	۲۰۰۰	هربار دو عامل به شرط اعتماد محدود به ضریب مشخص به هم نزدیک می‌شوند	پیوسته	گسسته	گراف	اعتماد محدود	پارامتر همگرایی	مستقل	غیر خطی
		۲۰۰۲ (با عدم قطعیت)	معرفی و استفاده از مفهوم توافق نسبی	پیوسته	گسسته	گراف	توافق نسبی	متناسب با توافق نسبی	مستقل	خطی
		۲۰۰۴ (با محدوده اعتماد نرم)	معرفی و استفاده از مفهوم اعتماد محدود نرم	پیوسته	گسسته	گراف	اعتماد محدود نرم	متناسب با تابع گاوسی فاصله دو عامل و عدم قطعیت آنها	مستقل	خطی

ردیف	مدل	سال ابداع	خلاصه مدل	فضای عقیده	زمان گسسته / پیوسته	شبکه عامل ها	محدودیت تعامل عامل ها	میزان تأثیر عامل ها	وابستگی به زمان	خطی / غیر خطی
۱۲	تأثیر اجتماعی (Social impact)	۲۰۰۲	هربار تحت تأثیر دو گروه مخالف و موافق برای: تغییر و تداوم عقیده	گسسته	گسسته / پیوسته	گراف	بدون محدودیت	بر اساس پارامترهای تنظیمی	مستقل	غیر خطی
۱۳	HK (Hegselmand-Krause)	۲۰۰۲	هربار عامل تحت تأثیر متوسط وزن دار تمام عامل ها	پیوسته	گسسته	گراف	اعتماد محدود	متوسط وزن دار	وابسته	غیر خطی
۱۴	قاعده اکثریت (Majority rule)	۲۰۰۲	انتخاب تصادفی گروه مباحثه در هر گام و یکدستی عقاید حسب اکثریت	گسسته	گسسته	گراف کامل	بدون محدودیت	بر اساس تعداد عامل ها در یکی از گروه های عقیده	مستقل	غیر خطی
۱۵	آلتافینی (Altafini)	۲۰۱۲	روابط خصمانه نیز وجود دارد	پیوسته	پیوسته	گراف با توازن ساختاری	بدون محدودیت	بر اساس رابطه دوستانه / خصمانه	مستقل	غیر خطی
		۲۰۱۳	روابط خصمانه و دو قطبی شدن عقاید	پیوسته	پیوسته	گراف با توازن ساختاری			مستقل	خطی / غیر خطی
		۲۰۱۵	روابط خصمانه و لزوم اجماع	پیوسته	گسسته / پیوسته	گراف جهت دار قویاً همبند			مستقل	خطی
۱۶	BEBA	۲۰۲۱	مشابه دیگروت با نتیجه معکوس (Backfire)	پیوسته	گسسته	گراف	شبکه	متوسط وزن دار و لحاظ کردن تعصب به عقیده خود و نتیجه معکوس عقاید مخالف	مستقل	خطی

۶- جمع‌بندی و نتیجه‌گیری

به منظور استفاده از محاسبات و پردازش در بررسی روند و پیش‌بینی تغییرات عقاید در علوم اجتماعی محاسباتی از مدل‌های شکل‌گیری عقیده استفاده می‌شود. تنوعی از مدل‌های شکل‌گیری عقیده ارائه شده‌اند که اگرچه به شکلی تقلیل‌گرا سعی در ساده‌سازی تغییر عقاید انسان‌ها دارند، اما حسب مورد و شرایط می‌توانند در بررسی‌ها استفاده شوند.

در این مقاله، مهمترین مدل‌های شکل‌گیری عقیده معرفی شدند. مدل‌های دیگر، عمدتاً گسترش، حالت خاص، یا ترکیبی از این مدل‌های اصلی هستند. همچنین بر اساس این مطالعه، ابعادی برای مدل‌های شکل‌گیری عقیده استخراج شدند که عبارتند از: (۱) فضای عقیده (گسسته/پیوسته)، (۲) گسسته/پیوسته بودن زمان (۳) شبکه تعامل، (۴) محدودیت تعامل، (۵) میزان تأثیر، (۶) وابستگی به زمان و (۷) خطی/غیرخطی بودن. علاوه بر این ابعاد، شرایطی نیز ذکر شدند که در مدل‌های شکل‌گیری عقیده می‌توان در نظر گرفته که روی پویایی و نتیجه شکل‌گیری عقیده موثر هستند، شامل (۱) همگونی/ناهمگونی جامعه، (۲) تعداد ابعاد فضای عقیده، (۳) تصور اولیه جامعه، (۴) قطعی یا نویزی بودن مدل. انتخاب مدل شکل‌گیری عقیده مناسب برای پژوهش‌های مختلف در حوزه شکل‌گیری عقیده به شرایط مورد بررسی بستگی دارد و نتایج این بررسی به پژوهشگر کمک می‌کند که مدل شکل‌گیری عقیده مناسب را انتخاب نماید و حتی با توجه به ابعاد و شرایطی که ذکر شد، مدل مناسب را طراحی و استفاده نماید.

موضوع شکل‌گیری عقیده را می‌توان از زوایای مختلف مورد بررسی قرار داد. این مقاله به ابعاد مدل‌های شکل‌گیری عقیده پرداخت و در پژوهش‌های آتی می‌توان موضوعاتی مانند کاربردها و شرایطی که هر مدل برای آن مناسب است، روش‌های مدل‌سازی و حل مدل، چالش‌ها، ماهیت شناختی فردی و اجتماعی را مورد توجه قرار داد. همچنین روش‌های «تحلیل میدان متوسط»^۱ که ریشه در مکانیک آماری دارند نیز برای بررسی برخی مدل‌های شکل‌گیری عقیده استفاده می‌شوند [۷۴] که می‌تواند موضوع پژوهشی در آینده باشد.

مراجع

- [3] I. N. Lympopoulos and G. D. Ioannou, "Understanding and modeling the complex dynamics of the online social networks: a scalable conceptual approach," *Evolving Systems*, vol. 7, pp. 207-232, 2016.
- [4] M. S. Granovetter, "The strength of weak ties," *American journal of sociology*, vol. 78, pp. 1360-1380, 1973.
- [5] J. A. Holyst, K. Kacperski, and F. Schweitzer, "Social impact models of opinion dynamics," *Annual reviews of computational physics*, vol. 9, pp. 253-273, 2002.
- [6] Y. Dong, M. Zhan, G. Kou, Z. Ding, and H. Liang, "A survey on the fusion process in opinion dynamics," *Information Fusion*, vol. 43, pp. 57-65, 2018.
- [7] H. Noorazar, "Recent advances in opinion propagation dynamics: A 2020 survey," *The European Physical Journal Plus*, vol. 135, pp. 1-20, 2020.
- [8] D. Lazer, A. Pentland, L. Adamic, S. Aral, A.-L. Barabási, D. Brewer, et al., "Computational social science," *Science*, vol. 323, pp. 721-723, 2009.
- [9] H. Lietz, A. Schmitz, and J. Schaible, "Social Network Analysis with Digital Behavioral Data," *easy_social_sciences*, pp. 41-48, 2021.
- [10] C. Coquidé, J. Lages, and D. L. Shepelyansky, "Opinion formation in the world trade network," *Entropy*, vol. 26, p. 141, 2024.
- [11] R. Urena, G. Kou, Y. Dong, F. Chiclana, and E. Herrera-Viedma, "A review on trust propagation and opinion dynamics in social networks and group decision making frameworks," *Information sciences*, vol. 478, pp. 461-475, 2019.
- [12] K. Lichtenegger and T. Hadzibeganovic, "The interplay of self-reflection, social interaction and random events in the dynamics of opinion flow in two-party democracies," *International Journal of Modern Physics C*, vol. 27, p. 1650065, 2016.
- [13] A. Hanifa, C. Debora, M. F. Hasani, and P. Wicaksono, "Analyzing Views on Presidential Candidates for Election 2024 Based on the Instagram and X Platforms with Text Clustering," *Procedia Computer Science*, vol. 245, pp. 730-739, 2024.
- [14] S. Hong and S. H. Kim, "Political polarization on twitter: Implications for the use of social media in digital governments," *Government Information Quarterly*, vol. 33, pp. 777-782, 2016.
- [15] A. Mansouri, M. Mahmoudi, M. Farhoodi, and S. M. Mirsarraf, "Persian Rumor Detection Using a MultiClassifier Fusion Approach," *International Journal of Information and Communication Technology Research*, vol. 16, pp. 33-43, 2024.
- [16] A. Bondielli and F. Marcelloni, "A survey on fake news and rumour detection techniques," *Information sciences*, vol. 497, pp. 38-55, 2019.
- [17] K. Sharma, F. Qian, H. Jiang, N. Ruchansky, M. Zhang, and Y. Liu, "Combating fake news: A survey on identification and mitigation techniques," *ACM transactions on intelligent systems and technology (TIST)*, vol. 10, pp. 1-42, 2019.
- [18] X. Zhou and R. Zafarani, "A survey of fake news: Fundamental theories, detection methods, and opportunities," *ACM Computing Surveys (CSUR)*, vol. 53, pp. 1-40, 2020.
- [19] C. Castellano, S. Fortunato, and V. Loreto, "Statistical physics of social dynamics," *Reviews of modern physics*, vol. 81, p. 591, 2009.
- [20] S. V. Gana and E. S. Asemah, "Psychological Factors Influencing Public Opinion Formation," *Communication and Media Dynamics*, p. 84, 2024.

[1] B. Liu and L. Zhang, "A survey of opinion mining and sentiment analysis," in *Mining text data*, ed: Springer, 2012, pp. 415-463.

[2] M. Jalili, "Social power and opinion formation in complex networks," *Physica A: Statistical Mechanics and its Applications*, vol. 392, pp. 959-966, 2013.

¹ Mean field analysis

- [43] K. Sznajd-Weron and J. Sznajd, "Opinion evolution in closed community," *International Journal of Modern Physics C*, vol. 11, pp. 1157-1165, 2000.
- [44] K. Sznajd-Weron, "Sznajd model and its applications," *arXiv preprint physics/0503239*, 2005.
- [45] D. Stauffer, A. O. Sousa, and S. M. De Oliveira, "Generalization to square lattice of Sznajd sociophysics model," *International Journal of Modern Physics C*, vol. 11, pp. 1239-1245, 2000.
- [46] G. Deffuant, D. Neau, F. Amblard, and G. Weisbuch, "Mixing beliefs among interacting agents," *Advances in Complex Systems*, vol. 3, pp. 87-98, 2000.
- [47] G. Deffuant, F. Amblard, G. Weisbuch, and T. Faure, "How can extremism prevail? A study based on the relative agreement interaction model," *Journal of artificial societies and social simulation*, vol. 5, 2002.
- [48] G. Deffuant, F. Amblard, and G. Weisbuch, "Modelling group opinion shift to extreme: the smooth bounded confidence model," *arXiv preprint cond-mat/0410199*, 2004.
- [49] A. Nowak, J. Szamrej, and B. Latané, "From private attitude to public opinion: A dynamic theory of social impact," *Psychological review*, vol. 97, p. 362, 1990.
- [50] S. E. Asch, "Opinions and social pressure," *Scientific american*, vol. 193, pp. 31-35, 1955.
- [51] S. E. Asch, "Studies of independence and conformity: I. A minority of one against a unanimous majority," *Psychological monographs: General and applied*, vol. 70, p. 1, 1956.
- [52] S. Galam, "Minority opinion spreading in random geometry," *The European Physical Journal B-Condensed Matter and Complex Systems*, vol. 25, pp. 403-406, 2002.
- [53] C. Altafini, "Dynamics of opinion forming in structurally balanced social networks," *PloS one*, vol. 7, p. e38135, 2012.
- [54] C. Altafini, "Consensus problems on networks with antagonistic interactions," *IEEE transactions on automatic control*, vol. 58, pp. 935-946, 2013.
- [55] C. Altafini and G. Lini, "Predictable dynamics of opinion forming for networks with antagonistic interactions," *IEEE Transactions on Automatic Control*, vol. 60, pp. 342-357, 2015.
- [56] X. Chen, P. Tsaparas, J. Lijffijt, and T. De Bie, "Opinion dynamics with backfire effect and biased assimilation," *PloS one*, vol. 16, p. e0256922, 2021.
- [57] P. Erdős and A. Rényi, "On random graphs I," *Publ. Math. Debrecen*, vol. 6, pp. 290-297, 1959.
- [58] D. J. Watts and S. H. Strogatz, "Collective dynamics of 'small-world' networks," *nature*, vol. 393, pp. 440-442, 1998.
- [59] A.-L. Barabási and R. Albert, "Emergence of scaling in random networks," *science*, vol. 286, pp. 509-512, 1999.
- [60] U. Krause, "A discrete nonlinear and non-autonomous model of consensus formation," *Communications in difference equations*, pp. 227-236, 2000.
- [61] D. N. Sotiropoulos, C. Bilanakos, and G. M. Giaglis, "Opinion formation in social networks: a time-variant and non-linear model," *Complex & Intelligent Systems*, vol. 2, pp. 269-284, 2016.
- [62] E. Kurmyshev and H. A. Juárez, "What is a leader of opinion formation in bounded confidence models?," *arXiv preprint arXiv:1305.4677*, 2013.
- [63] S. Wongkaew, M. Caponigro, and A. Borzi, "On the control through leadership of the Hegselmann-Krause opinion formation model," *Mathematical Models and Methods in Applied Sciences*, vol. 25, pp. 565-585, 2015.
- [21] P. Sobkowicz, "Modelling opinion formation with physics tools: Call for closer link with reality," *Journal of Artificial Societies and Social Simulation*, vol. 12, p. 11, 2009.
- [22] B. Düring, J. Franceschi, M.-T. Wolfram, and M. Zanella, "Breaking consensus in kinetic opinion formation models on graphons," *Journal of Nonlinear Science*, vol. 34, p. 79, 2024.
- [23] F. Klügl and A. L. Bazzan, "Agent-based modeling and simulation," *AI Magazine*, vol. 33, p. 29, 2012.
- [24] C. M. Macal and M. J. North, "Tutorial on agent-based modelling and simulation," *Journal of simulation*, vol. 4, pp. 151-162, 2010.
- [25] C. Macal and M. North, "Introductory tutorial: Agent-based modeling and simulation," in *Proceedings of the 2014 Winter Simulation Conference*, 2014, pp. 6-20.
- [26] F. Schweitzer, T. Krivachy, and D. Garcia, "How emotions drive opinion polarization: An agent-based model," *arXiv preprint arXiv:1908.11623*, 2019.
- [27] C. A. Devia and G. Giordano, "Graphical analysis of agent-based opinion formation models," *Plos one*, vol. 19, p. e0303204, 2024.
- [28] M. Tomaiuolo, G. Lombardo, M. Mordonini, S. Cagnoni, and A. Poggi, "A Survey on Troll Detection," *Future Internet*, vol. 12, p. 31, 2020.
- [29] L. Mastroeni, P. Vellucci, and M. Naldi, "Agent-based models for opinion formation: A bibliographic survey," *IEEE Access*, vol. 7, pp. 58836-58848, 2019.
- [30] O. Abid, S. Jamoussi, and Y. B. Ayed, "Deterministic models for opinion formation through communication: A survey," *Online Social Networks and Media*, vol. 6, pp. 1-17, 2018.
- [31] J. Lorenz, "Continuous opinion dynamics under bounded confidence: A survey," *International Journal of Modern Physics C*, vol. 18, pp. 1819-1838, 2007.
- [32] C. A. Devia and G. Giordano, "A framework to analyze opinion formation models," *Scientific Reports*, vol. 12, p. 13441, 2022.
- [33] C. A. Devia and G. Giordano, "Probabilistic analysis of agent-based opinion formation models," *Scientific Reports*, vol. 13, p. 20152, 2023.
- [34] I. V. Kozitsin, "A general framework to link theory and empirics in opinion formation models," *Scientific reports*, vol. 12, p. 5543, 2022.
- [35] N. E. Friedkin, "A formal theory of social power," *Journal of Mathematical Sociology*, vol. 12, pp. 103-126, 1986.
- [36] R. P. Abelson, "Mathematical models of the distribution of attitudes under controversy," *Contributions to mathematical psychology*, vol. 14, pp. 1-160, 1964.
- [37] R. Hegselmann and U. Krause, "Opinion dynamics and bounded confidence models, analysis, and simulation," *Journal of Artificial Societies and Social Simulation*, vol. 5, 2002.
- [38] M. Taylor, "towards a mathematical theory of Influence and attitude change," *Human Relations*, vol. 21, pp. 121-139, 1968.
- [39] M. H. DeGroot, "Reaching a consensus," *Journal of the American Statistical Association*, vol. 69, pp. 118-121, 1974.
- [40] R. A. Holley and T. M. Liggett, "Ergodic theorems for weakly interacting infinite systems and the voter model," *The annals of probability*, pp. 643-663, 1975.
- [41] N. E. Friedkin and E. C. Johnsen, "Social influence and opinions," *Journal of Mathematical Sociology*, vol. 15, pp. 193-206, 1990.
- [42] N. E. Friedkin and E. C. Johnsen, "Social influence networks and opinion change," *Advances in Group Processes*, vol. 16, pp. 1-29, 1999.

- [70] A. Mansouri and F. Taghiyareh, "Effect of segregation on the dynamics of noise-free social impact model of opinion formation through agent-based modeling," *International Journal of Web Research*, vol. 2, pp. 36-44, 2019.
- [71] J. A. Holyst, K. Kacperski, and F. Schweitzer, "Phase transitions in social impact models of opinion formation," *Physica A: Statistical Mechanics and its Applications*, vol. 285, pp. 199-210, 2000.
- [72] R. Axelrod, "The dissemination of culture: A model with local convergence and global polarization," *Journal of conflict resolution*, vol. 41, pp. 203-226, 1997.
- [73] J. Llabrés, S. Oliver-Bonafoux, C. Anteneodo, and R. Toral, "Aging in some opinion formation models: A comparative study," *Physics*, vol. 6, pp. 515-528, 2024.
- [74] L. Bungert, T. Roith, and P. Wacker, "Polarized consensus-based dynamics for optimization and sampling," *Mathematical Programming*, vol. 211, pp. 125-155, 2025.
- [64] J. Lorenz, "Continuous opinion dynamics of multidimensional allocation problems under bounded confidence: More dimensions lead to better chances for consensus," *arXiv preprint arXiv:0708.2923*, 2007.
- [65] P. Liu and X. Chen, "An overview on opinion spreading model," *Journal of Applied Mathematics and Physics*, vol. 3, p. 449, 2015.
- [66] E. Alraddadi, "Opinion formation among mobile agents," Cardiff University, 2021.
- [67] R. Chhimpa and A. C. Yadav, "\$1/f \$ noise in the Ising model," *arXiv preprint arXiv:2503.04105*, 2025.
- [68] A. Mansouri and F. Taghiyareh, "Phase Transition in the Social Impact Model of Opinion Formation in Scale-Free Networks: The Social Power Effect," *Journal of Artificial Societies and Social Simulation*, vol. 23, p. 3, 2020.
- [69] A. Mansouri and F. Taghiyareh, "Phase transition in the social impact model of opinion formation in log-normal networks," *Journal of Information Systems and Telecommunication (JIST)*, vol. 1, pp. 1-14, 2021.

Application of Artificial Intelligence in the Art of Music: A Systematic Review

Majid Akhshabi^{1*}

¹ Faculty Member of Payame Noor University, Tehran, Iran

Received: 14 August 2024, Revised: 05 October 2024, Accepted: 07 February 2025

Paper type: Review

Abstract

Despite its relatively short lifespan, which began around 1960 by John McCarthy, artificial intelligence technology has made significant inroads into almost all fields, including the art of music and leading to remarkable advancements. This study aims to understand and introduce the applications of artificial intelligence in music by systematically reviewing the literature on artificial intelligence and its applications in the art of music. To achieve this goal, five major research and practical areas of artificial intelligence in music have been considered. Subsequently, information from all relevant scientific documents related to these five areas has been extracted from the Scopus citation database and in each of the five areas, the countries and universities that published the most articles, along with the top authors, were identified and introduced. Additionally, the temporal trend of publishing scientific documents related to each area was determined, and subsequently, the various AI methods and algorithms that have been used in each of the areas, along with their corresponding articles, were identified and introduced. Finally, it was concluded that deep learning is transforming and improving results across all areas, leading to a quantitative growth in scientific research in the field of music. Furthermore, generative AI has achieved remarkable growth in the realm of music production. Finally, the challenges and future research topics across various fields were also examined and presented. The creation of suitable datasets for different areas will shape the future development of AI applications in the art of music and This will ultimately lead to more desirable and broadly adopted applications of artificial intelligence.

Keywords: Artificial Intelligence, Music, Music generation, Deep learning.

* Corresponding Author's email: majidakhshabi@pnu.ac.ir

سال هفدهم، شماره ۶۵، مهر ۱۴۰۴، شماره ویژه «هوش مصنوعی و تحلیل داده»، صفحه ۱۲۵ الی ۱۵۰

کاربرد هوش مصنوعی در هنر موسیقی: بررسی نظام‌مند

مجید اخشابی^{۱*}

^۱ عضو هیأت علمی، دانشگاه پیام نور، تهران، ایران

تاریخ دریافت: ۱۴۰۳/۰۵/۲۴ تاریخ بازبینی: ۱۴۰۳/۰۷/۱۴ تاریخ پذیرش: ۱۴۰۳/۱۱/۱۹

نوع مقاله: مروری

چکیده

فناوری هوش مصنوعی علی‌رغم عمر کوتاهش که از حدود سال ۱۹۶۰ توسط جان مک‌کارتی آغاز شد، تقریباً به تمامی عرصه‌ها از جمله هنر موسیقی ورود جدی داشته و موجب شگفتی‌های بسیار شده است. پژوهش حاضر با هدف شناخت و معرفی کاربردهای هوش مصنوعی در موسیقی، به بررسی نظام‌مند ادبیات موضوع هوش مصنوعی و کاربردهای آن در هنر موسیقی می‌پردازد. برای نیل به این هدف ابتدا پنج حوزه پرکاربرد تحقیقاتی و کاربردی هوش مصنوعی در موسیقی مدنظر قرار گرفت. سپس اطلاعات تمامی اسناد علمی مرتبط با این پنج حوزه از پایگاه استنادی اسکوپوس استخراج شد و در هر یک از پنج حوزه، کشورها و دانشگاه‌هایی که بیشترین مقالات را چاپ کرده‌اند به همراه نویسندگان برتر مورد شناسایی و معرفی واقع شدند. علاوه بر این روند زمانی چاپ اسناد علمی مرتبط با هر حوزه نیز تعیین گردید و در ادامه روش‌ها و الگوریتم‌های مختلف هوش مصنوعی که در هر یک از حوزه‌ها مورد استفاده قرار گرفته‌اند نیز به همراه مقالات متناظر مشخص و معرفی شدند. در نهایت چنین استنتاج گردید که یادگیری ژرف در تمامی حوزه‌ها در حال تغییر و بهبود نتایج بوده و سبب رشد کمی پژوهش‌های علمی در حوزه موسیقی شده است. علاوه بر این هوش مصنوعی مولد در حیطه تولید موسیقی رشد چشمگیری را رقم زده است. در پایان چالش‌ها و موضوعات آینده تحقیقاتی حوزه‌های مختلف نیز مورد بررسی و معرفی قرار گرفت. تهیه مجموعه دادگان مناسب برای حوزه‌های مختلف، توسعه کاربردهای هوش مصنوعی را در آینده هنر موسیقی رقم خواهد زد و کارکردهای مطلوب تر و مقبول تری از هوش مصنوعی را سبب خواهد شد.

کلیدواژگان: هوش مصنوعی، موسیقی، تولید موسیقی، یادگیری ژرف.

* رایانامه نویسنده مسؤول: majidakhshabi@pnu.ac.ir

۱- مقدمه

هوش مصنوعی^۱ یک فناوری چندرشته‌ای است که قابلیت یکپارچه‌سازی شناخت، تشخیص احساسات، تعامل انسان با کامپیوتر، ذخیره‌سازی داده‌ها و تصمیم‌گیری را دارد. در این تلفیق می‌توان بیش از بیست زیر شاخه برای هوش مصنوعی برشمرد که از بین آنها یادگیری ماشین^۲، شناخت الگو^۳، پردازش زبان طبیعی^۴، رباتیک^۵، سامانه‌های خبره^۶، شبکه‌های عصبی^۷، منطق فازی^۸ و الگوریتم ژنتیک^۹، از جمله مهم‌ترین آنها هستند [۱]. در سال‌های اخیر، هوش مصنوعی به سرعت توسعه یافته و سبک زندگی افراد را تغییر داده است. در این زمینه بسیاری از کشورها سیاست‌های ترجیحی و از پیش تعیین شده‌ای را در جهت به کارگیری این فناوری معرفی و تقویت کرده‌اند تا در دور جدیدی از رقابت‌های بین‌المللی پیشگام باشند. هدف هوش مصنوعی، الهام گرفتن از هوش طبیعی و شناخت بهتر هوش انسان، در جهت تولید نرم‌افزارها و خلق و توسعه دستگاهی است که بتواند فکر کند، ببیند، بشنود، راه برود، صحبت کند و حتی احساس کند. به عبارتی حقیقت عمده هوش مصنوعی، توسعه عملکردهای رایانه‌ای مشابه عملکردهای هوش انسانی است [۲].

امروزه به دلیل گسترش روز افزون دانش و پیچیده‌تر شدن فرآیند تصمیم‌گیری و حل مسئله، بهره‌گیری از سامانه‌های هوش مصنوعی، اهمیت بیشتری پیدا کرده است [۳]. هوش مصنوعی قادر است تا رفتارهایی مشابه رفتارهای هوشمند انسانی، نظیر درک شرایط پیچیده، شبیه‌سازی فرآیندهای فکری و شیوه‌های استدلالی انسان و پاسخ موفق به آن، یادگیری و توانایی کسب دانش و استدلال را برای حل مسائل داشته باشد [۴]. در این زمینه برنامه نویسی هوش مصنوعی بر سه مهارت شناختی؛ یادگیری، استدلال و اصلاح فرآیندهای حل مسئله به روش دستیابی به داده‌ها و ایجاد قوانینی برای چگونگی تبدیل داده‌ها به اطلاعات عملی، تمرکز دارد [۵]. از دیگر ویژگی‌های اساسی هوش مصنوعی، عمدتاً می‌توان به حرکات ربات‌ها، تشخیص زبان، تشخیص تصویر، پردازش زبان طبیعی و سیستم خبره- برنامه‌های کامپیوتری که قضاوت و رفتار یک متخصص را شبیه‌سازی می-

کنند اشاره کرد که هدف آن کشف ماهیت هوش و استفاده از آن برای توسعه یک ماشین هوشمند با قدرت تجزیه و تحلیل، تفکر، قضاوت و حتی ادراک؛ مشابه مغز انسان است. با ظهور نظریه کارکردگرایی ذهن که با رشد و پیشرفت برق آسای رایانه‌ها در دهه‌های ۱۹۵۰ و ۱۹۶۰ همراه بود، در سال ۱۹۵۶ عده‌ای از پژوهشگران برای تشکیل یک علم جدید در دانشگاه دارتموث ایالات متحده، گرد هم آمده بودند. آنان برای اولین بار در سال ۱۹۵۶، در کنفرانسی در این دانشگاه، به طور رسمی اصطلاح «هوش مصنوعی» را پیشنهاد کردند [۶]. این نخستین گام تحقیق و مطالعه در چگونگی شبیه‌سازی فعالیت‌های هوشمند انسان بود. با این حال آنچه امروزه بعنوان هوش مصنوعی مطرح است از حوالی سال ۱۹۶۰ توسط جان مک کارتی بوجود آمد. او هوش مصنوعی را به سه نوع پردازش دسته‌بندی کرد: فیزیکی، بیولوژیکی و روان‌شناختی. وی اظهار داشت طراحی سیستم‌های هوشمند، خود یک وظیفه‌ی شناختی است، سیستمی که مدام می‌تواند خود را بهتر کند. گرچه از وی به‌عنوان پدر علم و دانش تولید ماشین‌های هوشمند یاد می‌شود، اما ظهور این رشته علمی را دهه ۵۰ میلادی و زمانی عنوان می‌کنند که آلن تورینگ^{۱۰} این سوال را مطرح کرد که آیا ماشین می‌تواند فکر کند؟ تورینگ در مقاله‌ای با عنوان «ماشین محاسبه‌ای و هوشمند» در سال ۱۹۵۰ در نشریه ذهن^{۱۱}، موضوعی را مطرح کرد که امروز آن را آزمون تورینگ می‌خوانند. پس از آن که تورینگ مسئله اندیشیدن و آگاهی را برای ماشین مطرح کرد، این نظریه در بسیاری از حلقه‌ها و مراکز علمی مطرح و به آن توجه بسیار شد. در سال ۱۹۶۱، نیز ماروین مینسکی در همان دانشگاه، مقاله‌ای با عنوان «گام‌هایی به سوی هوش مصنوعی» چاپ کرد. از سال ۱۹۹۳ تاکنون، هوش مصنوعی به نقاط عطف بزرگی دست یافته است [۷].

در زمینه هنر نیز محققان بسیاری سعی کرده‌اند از هوش مصنوعی و الگوریتم‌های یادگیری ماشینی برای یادگیری سبک‌های هنرمندان و آثار موجود، جهت ترسیم خودکار این آثار با محتوای جدید و خلاقانه استفاده کنند. هنر به عنوان یکی از ابزارهای اولیه سازگاری، همواره در خدمت نیازهای کمال‌جویی، زیبا طلبی، تسکین آلام و سختی‌های زندگی بشر بوده است و موسیقی، شکلی از هنر می‌باشد که احساس، عاطفه و ادراک انسان را با کلام یا بی‌کلام منتقل می‌کند. موسیقی همچون زبان‌های رایج دنیا، نوعی بیان است که مناطق خاصی را در مغز فعال می‌کند که درک آن

¹ Artificial Intelligence (AI) Technology

² Machine Learning

³ Pattern Recognition

⁴ Natural Language Processin

⁵ Robotic

⁶ Expert System


⁷ Neural Network

⁸ Fuzzy Logic

⁹ Genetic Algorithm

¹⁰ Turing, A.

¹¹ Mind Journals



شکل ۱. مراحل اصلی پژوهش

۲-۱- استخراج حوزه‌های کاربردی

برای بررسی استفاده از هوش مصنوعی در هنر موسیقی می‌توان از مفهوم بازیابی اطلاعات موسیقی^۳ استفاده کرد. علی‌رغم اینکه این مفهوم یک زمینه تحقیقاتی چندرشته‌ای است که از علوم مختلفی مانند موسیقی‌شناسی، علوم کامپیوتر، مهندسی صدا و یادگیری ماشین بهره می‌برد اما تمامی موارد کاربرد هوش مصنوعی در هنر موسیقی را می‌توان ذیل این موضوع بررسی کرد.

بازیابی اطلاعات موسیقی بر تحلیل، پردازش و بازیابی اطلاعات موسیقی تمرکز دارد. هدف اصلی MIR، فراهم کردن ابزارها و روش‌هایی است که به ما امکان می‌دهد تا اطلاعات مفیدی از داده‌های موسیقی استخراج کنیم و آن‌ها را به طور مؤثر و کارآمد مدیریت کنیم. این اطلاعات می‌تواند شامل ویژگی‌های صوتی، ساختارهای موسیقایی، متن ترانه‌ها، و اطلاعات فراداده‌ای نظیر نام هنرمند، آلبوم و سبک موسیقی باشد.

به طور کلی، حوزه تحقیقاتی بازیابی اطلاعات موسیقی (MIR) در درجه اول به استخراج و استنتاج ویژگی‌های معنادار از موسیقی و نمایه‌سازی موسیقی با استفاده از این ویژگی‌ها، مربوط می‌شود. علاوه بر این توسعه طرح‌های جستجو و بازیابی مختلف (به عنوان مثال، جستجوی مبتنی بر محتوا، سیستم‌های توصیه موسیقی، یا رابط‌های کاربری برای مرور مجموعه‌های موسیقی بزرگ)، نیز شامل MIR می‌شود [۱۳]. حتی مواردی مانند تولید موسیقی^۴ نیز در دامنه MIR می‌گنجد. چرا که برای تولید اصوات مختلف ابتدا باید با استفاده از پردازش موسیقی اطلاعات مورد نیاز استخراج گردد و سپس با استفاده از روش‌های مختلف مبتنی بر هوش مصنوعی به تولید اصوات پرداخت.

همانطور که مشخص است دامنه حوزه‌های کاربردی MIR گسترده بوده و موارد زیادی را شامل می‌شود. با بررسی ادبیات موضوع، پنج حوزه به عنوان حوزه‌های اصلی تحقیقاتی و کاربرد هوش مصنوعی در هنر موسیقی شناسایی شد که در ادامه معرفی می‌شوند.

نیازمند آموزش است. موسیقی به راحتی می‌تواند مسیر روشن و لذت‌بخشی را فراروی هنرآموزان به دور از هرگونه سختی و مرارت و رنج طاقت فرسا بگستراند و آن‌ها را به سوی سرچشمه خلاقیت رهنمون سازد [۸]. در زمینه‌ی کاربرد هوش مصنوعی در هنر بسیاری از مکانیسم‌های دخیل در تولید موسیقی هنوز ناشناخته هستند و بعضی دیگر نیز آن‌چنان پیچیده‌اند که ابزارهای رایانه‌ای فعلی با وجود رشد و تحولی چشمگیر در مدت زمانی کوتاه، قادر به مدیریت آن‌ها نیستند [۹].

نخستین اقدامات کاربرد کامپیوتر در ساخت قطعات موسیقی توسط مورالس مانزارانس در سال ۱۹۷۰ انجام شد. وی سامانه‌ای به نام SICIB^۱ را توسعه داد که ساخت موسیقی را بر اساس حرکات بدن نوازنده انجام می‌داد. این سیستم اطلاعات را از سنسورهای متصل به بدن نوازنده می‌گرفت و بی‌درنگ براساس اطلاعات دریافتی موسیقی متناسب را ایجاد می‌کرد. یکی دیگر از این سامانه‌ها، EMI^۲ است که توسط دیوید کوب در سال ۱۹۸۹ ابداع شد که موسیقی را بر اساس سبک آهنگساز می‌سازد [۱۰]. اما این الگوریتم‌ها به لحاظ نت به نت بودن و تفاوت خوشایندی موسیقی ساخته شده با موسیقی طبیعی، کاملاً قابل تشخیص توسط سیستم شنوایی انسان نیست و در معرض خطا است [۱۱]. از این رو، ساخت موسیقی نوآورانه‌ای که برای انسان مطلوب باشد یکی از چالش‌های مهم استفاده از هوش مصنوعی در موسیقی است. از طرفی امروزه حجم مطالعات دانشگاهی با سرعتی بالا و روز افزون پیش می‌رود به طوریکه هر ۱۰ سال حجم دانش در یک حوزه دو برابر می‌گردد. لذا مرور این حجم از دانش با روش‌های مناسب و در یک زمینه منتخب موجب شناسایی شکاف‌های دانش در آن حوزه و ایجاد ایده‌های تحقیقاتی جدید می‌شود [۱۲]. در این جهت پژوهش حاضر با هدف مرور نظام‌مند در مطالعات کاربردی هوش مصنوعی در هنر موسیقی انجام شد. نتایج این مطالعه می‌تواند راهگشای انجام تحقیقات سودمند پژوهشگران خلاق و علاقه‌مند در این حوزه باشد.

۲- روش پژوهش

پژوهش حاضر از نوع مطالعات توصیفی-تحلیلی است که با توجه به روش اجرا، مروری نظام‌مند در زمینه کاربرد هوش مصنوعی در هنر موسیقی است. شکل ۱ مراحل کلی پژوهش را نشان می‌دهد که در ادامه هر مرحله تشریح و نتایج هر یک مشخص خواهد شد.

^۳ Music Information Retrieval (MIR)

^۴ Music Generation

^۱ - Sistema Interactivo De Composicion Improvisacion Para Bailarines

^۲ - Experiments In Music Intelligence

۲-۲- دسته‌بندی موسیقی

دسته‌بندی موسیقی^۱ یکی از کاربردهای مهم و جذاب در زمینه بازیابی اطلاعات موسیقی است. هدف از دسته‌بندی موسیقی، شناسایی قطعات موسیقی بر اساس ویژگی‌های مختلف آن اعم از ژانر، سازها، هنرمند، دوره زمانی، احساسات (و یا هر ویژگی دیگری که بتوان آن را به صورت کمی و کیفی تحلیل کرد) می‌باشد. در این فرآیند با اختصاص یک یا چند برچسب، قطعات موسیقی را براساس ویژگی‌های مشخص آن‌ها در گروه‌های مختلف دسته‌بندی می‌کنند. این برچسب‌ها می‌توانند ژانر (مانند جاز، راک، کلاسیک)، هنرمند، یا هر ویژگی دیگری باشند که به کمک آن‌ها می‌توان قطعات موسیقی را دسته‌بندی و متمایز نمود. طبقه‌بندی صحیح موسیقی می‌تواند به بهبود و سهولت تجربه کاربری در سامانه‌های پخش موسیقی و سرویس‌های توصیه‌گر کمک کند.

۲-۳- سامانه‌های توصیه‌گر موسیقی^۲

این سامانه‌ها با استفاده از اطلاعاتی که از رفتار کاربران و ویژگی‌های موسیقی‌ها به دست می‌آورند، موسیقی‌های مشابه را پیشنهاد می‌کنند. هدف اصلی این سامانه‌ها، شخصی‌سازی تجربه کاربری و افزایش رضایت کاربران است. پیشنهادها می‌توانند بر اساس سابقه شنیداری کاربران، ویژگی‌های موسیقی و تعاملات اجتماعی باشند. سیستم‌های توصیه‌گر به طور کلی به دو دسته اصلی تقسیم می‌شوند:

توصیه‌گرهای مبتنی بر محتوا^۳: این سامانه‌ها براساس ویژگی‌های خود موسیقی (مانند ژانر، تمپو، ملودی) پیشنهادهایی ارائه می‌دهند. برای مثال، اگر کاربری به شنیدن موسیقی‌های با ریتم تند علاقه‌مند باشد، سیستم‌های مبتنی بر محتوا، موسیقی‌هایی با ویژگی‌های موردنظر را پیشنهاد می‌دهند.

۲-۳-۱- توصیه‌گرهای مبتنی بر کاربر^۴: این سامانه‌ها براساس

رفتار و ترجیحات کاربران مشابه پیشنهاد ارائه می‌دهند. به عنوان مثال، اگر دو کاربر ترجیحات مشابهی داشته باشند، موسیقی‌هایی که یکی از آن‌ها گوش داده است به دیگری پیشنهاد می‌شود. این روش نیز به دو نوع اصلی تقسیم می‌شود: توصیه‌گر مشارکتی مبتنی بر کاربر، که در آن پیشنهاد موسیقی بر اساس شباهت بین کاربران و توصیه‌گر مشارکتی مبتنی بر

مورد، که پیشنهاد موسیقی بر اساس شباهت بین خود موسیقی‌ها صورت می‌پذیرد.

۲-۳-۲- **توصیه‌گرهای ترکیبی**: این توصیه‌گرها سعی در استفاده از مزایای هر دو روش گفته شده، یعنی مبتنی بر ترجیحات کاربر و مبتنی بر محتوا دارند.

۲-۴- جداسازی منابع (اصوات تشکیل دهنده) موسیقی^۵

یک حوزه مهم و پیچیده در پردازش سیگنال‌های صوتی است که هدف آن تفکیک اجزای مختلف یک قطعه موسیقی به منابع صوتی جداگانه است. به طور ساده، این فرآیند تلاش می‌کند تا سازهای مختلف و صدای خواننده را از یکدیگر جدا کند. این فناوری در کاربردهای مختلفی از جمله میکس و مسترینگ، بازسازی و بازآفرینی موسیقی، حذف نویز، و همچنین در زمینه‌های تحقیقاتی و آموزشی استفاده می‌شود. دو زیرمجموعه مهم این حوزه عبارتند از:

۲-۴-۱- شناسایی سازهای موسیقی^۶: این فرآیند که نقشی

اساسی در حوزه آموزش سازهای موسیقی دارد با پردازش سیگنال‌های صوتی مرتبط است و هدف آن تشخیص و شناسایی نوع سازهای موسیقی از روی سیگنال صوتی آنها است. این فرآیند می‌تواند در کاربردهای مختلفی مانند سیستم‌های توصیه‌گر موسیقی، تحلیل موسیقی، ویرایش و میکس موسیقی و حتی در توسعه اپلیکیشن‌های آموزشی مورد استفاده قرار گیرد.

۲-۴-۲- شناسایی هنرمندان موسیقی^۷: هدف از این فرآیند،

تشخیص و شناسایی هنرمند یا گروه موسیقی از روی سیگنال صوتی آهنگ‌ها است. این فناوری در کاربردهای مختلفی از جمله سیستم‌های توصیه‌گر موسیقی، پایگاه‌های داده موسیقی، ویرایش و مدیریت محتوا، و حتی در اپلیکیشن‌های آموزشی و تحلیلی استفاده می‌شود.

همانطور که مشخص است برای حوزه جداسازی منابع موسیقی پردازش سیگنال‌های صوتی نقشی اساسی ایفا می‌کند.

۲-۴-۳- رونویسی خودکار^۸: این حوزه در برگیرنده مجموعه

فعالیت‌هایی است که به استخراج مؤلفه‌هایی از یک قطعه

^۴ User Based

^۵ Music Source Separation


^۶ Music Instrument Recognition

^۷ Music Artist Recognition

^۱ Music Classification

^۲ Music Recommender Systems

^۳ Content Based



شکل ۲. حوزه‌های مورد بررسی مقاله حاضر

جدول ۱. کلمات و عبارات مورد استفاده در جستجوی اسناد

موضوع	کلمات کلیدی
دسته‌بندی موسیقی	"Music classification", "music genre classification", "music Emotion classification", "music artist classification", "music genre Recognition", "music Emotion Recognition"
سامانه‌های توصیه‌گر موسیقی	"MUSIC Recommender Systems", "music recommendation", "Collaborative Filtering" and "music recommendation", "Content based" AND "music recommendation", "Content oriented" AND "music recommendation"
جدا سازی منابع موسیقی	"Music Source Separation", "Music Instrument Recognition", "Music Artist Recognition", "Musical Instrument Recognition", "Music Recognition"
رونویسی خودکار	"Automatic Music Transcription", "Automatic Lyric Transcription", "AI" AND "Lyric Transcription", "AI" AND "music Transcription"
تولید موسیقی	"Music Generation", "AI" AND "Music composition", "Artificial intelligence" AND "Music composition", "automatic music arrangement", "artificial intelligence" AND "Singing", "AI" AND "Singing", "Musical Instrument generation"

۲-۷- استخراج اطلاعات آماری اسناد علمی از منابع

معتبر

مطابق با کلمات کلیدی مشخص شده در جدول ۱، جستجو در پایگاه اطلاعاتی اسکوپوس معتبر صورت پذیرفت. فرآیند جستجو به این شکل بود که اگر در عنوان اسناد، چکیده و یا در بین کلمات کلیدی اسناد، هر یک از عبارات جدول ۱ وجود داشت تمامی اطلاعات اسناد از جمله عنوان، کلمات کلیدی، چکیده، اطلاعات مرتبط با نشریه و یا کنفرانس، اطلاعات نویسندگان و سایر اطلاعات همچون سال انتشار اسناد استخراج شده است. در جدول ۲ تعداد اولیه اسناد مرتبط با هر موضوع بر اساس کلمات کلیدی جدول ۱ و نیز بعد از حذف عناوین تکراری مشخص شده است.

موسیقی منتج می‌شود. این حوزه دو زیرمجموعه مهم دارد که در ادامه تشریح می‌گردد:

۲-۴-۳-۱- رنویسی خودکار موسیقی^۲: که در آن سیگنال‌های صوتی موسیقی به نت‌های موسیقی یا نمادهای قابل خواندن توسط انسان تبدیل می‌شوند. این فرآیند به ویژه در زمینه‌های مختلف از جمله تجزیه و تحلیل موسیقی، آموزش موسیقی، تولید نت‌های موسیقی، و همچنین در فرایندهای تحقیقاتی و خلاقانه مورد استفاده قرار می‌گیرد.

۲-۴-۳-۲- رنویسی خودکار ترانه آهنگ‌ها^۳: در این فرآیند متن آهنگ‌ها از سیگنال‌های صوتی استخراج می‌شود. این فناوری کاربردهای گسترده‌ای در حوزه ایجاد زیرنویس برای نماهنگ، جستجوی مبتنی بر متن در کتابخانه‌های موسیقی و تحلیل محتوا دارد. در این فرآیند علاوه بر روش پردازش سیگنال‌های صوتی باید از روش‌های پردازش زبان طبیعی^۴ نیز استفاده کرد.

۲-۵- تولید موسیقی

تولید موسیقی یکی از حوزه‌های هیجان‌انگیز در ترکیب هنر و هوش مصنوعی است که شامل استفاده از الگوریتم‌ها و مدل‌های یادگیری ماشین برای ساخت قطعات موسیقی به صورت خودکار است. این فناوری امکان تولید موسیقی‌های جدید و منحصر به فرد را با کمترین دخالت انسانی فراهم می‌کند و در کاربردهای مختلفی از جمله صنعت موسیقی، تولید محتوای دیجیتال و حتی در آموزش موسیقی مورد استفاده قرار می‌گیرد.

شکل ۲ حوزه‌های مورد بررسی این مقاله را نشان می‌دهد.

۲-۶- استخراج کلمات کلیدی برای جستجو

در اولین مرحله از فرآیند استخراج اسناد علمی مرتبط با هوش مصنوعی و هنر موسیقی نیاز به استخراج کلمات کلیدی برای جستجوی اسناد است. کلمات و عبارات مرتبط با هر یک از حوزه‌های معرفی شده در شکل ۲ به صورت جداگانه برای استخراج اسناد علمی استفاده شده است. جدول ۱ فهرست کلمات کلیدی استفاده شده در تحقیق حاضر را نمایش می‌دهد.

¹ Automatic Transcription

² Automatic Music Transcription


³ Automatic Lyric Transcription

⁴ National Languages Processing

با توجه به جدول ۲، بیش از ۶۸ درصد از اسناد را مقالات مروری و پژوهشی کنفرانس‌ها دربر می‌گیرد. همچنین حدود ۹۰ درصد از اسناد، شامل مقالات پژوهشی اعم از کنفرانسی و مجله‌ای می‌باشند.

۳-۲- روند زمانی چاپ اسناد

در شکل ۳ روند انتشار اسناد در موضوعات مختلف نمایش داده شده است. در نمودارهای نمایش داده شده در شکل ۳، اسناد سال ۲۰۲۵ حذف شده‌اند زیرا تعداد آن‌ها بسیار اندک بود. در خصوص مقالات مرتبط با سال ۲۰۲۴ نیز از آنجا که هنوز چند ماهی از این سال باقی است مسلم است که بر تعداد مقالات و اسناد این سال اضافه خواهد شد.



شکل ۳. روند زمانی چاپ اسناد مرتبط با دسته‌بندی موسیقی

قدیمی‌ترین سند که در گروه موضوعی جدا سازی منابع موسیقی قرار دارد مربوط به مقاله‌ای با عنوان «تشخیص موسیقی» است که در سال ۱۹۶۹ و به نویسندگی دیانا دواچ چاپ شده است. در این مقاله یک روش مبتنی بر شبکه عصبی برای تشخیص انتزاعاتی مشخص از موسیقی پیشنهاد شده است [۱۴]. از این مقاله می‌توان به عنوان اولین مقاله کاربردی هوش مصنوعی در هنر موسیقی نام برد. اولین مقاله در حوزه آهنگسازی مربوط به سال ۱۹۷۲ است که در نتیجه یک پروژه تحقیقاتی در دانشگاه استنفورد و توسط جیمز اندرسون مورر به چاپ رسیده است. در این مقاله یک برنامه کامپیوتری برای تولید یک قطعه موسیقی کوتاه توسعه داده شده و نتایج آن بررسی شده است [۱۵].

از سال ۱۹۶۹ تا سال ۱۹۸۵ تک مقالاتی در حوزه هوش مصنوعی و هنر موسیقی به چاپ رسیده است. به نحوی که تعداد کل مقالات در این سال‌ها از سالی ۲ عدد تجاوز نمی‌کرد. ذکر این نکته در این جا ضروری است که این بازه زمانی با عنوان زمستان هوش مصنوعی شناخته می‌شود و تعداد کم مقالات منتشر شده در این بازه می‌تواند معلول همین علت باشد.

جدول ۲. مجموع مقالات استخراج شده

موضوع	مجموع اسناد	مجموع اسناد بعد از حذف عناوین تکراری
دسته‌بندی موسیقی	۱۹۳۲	۱۷۲۳
سامانه‌های توصیه‌گر موسیقی	۲۹۹۶	۱۶۷۶
جدا سازی منابع موسیقی	۱۰۱۴	۸۶۱
رونویسی خودکار	۳۶۶	۳۶۵
تولید موسیقی	۱۴۵۷	۱۳۰۵
مجموع	۷۷۶۵	۵۹۳۰

در مرحله بعد تمامی ۵۹۳۰ سند مجدداً از منظر عدم تکرار بررسی شدند و در نهایت ۵۹۰۳ مقاله در تمامی موضوعات شناسایی شدند.

۳- تحلیل اطلاعات اسناد

در ادامه مقاله اطلاعات استخراج شده از اسناد علمی مورد بررسی قرار گرفت. بررسی فراوانی اسناد بر اساس نوع، روند زمانی چاپ اسناد، کشورهای برتر، دانشگاه‌ها و نویسندگان برتر مواردی است که به صورت آماری از اسناد مورد نظر استخراج گردید. علاوه بر این روش‌ها و الگوریتم‌های به کار گرفته در هر یک از موضوعات به تفکیک مورد بررسی قرار گرفته و چالش‌های به کارگیری هوش مصنوعی نیز در هر یک از موضوعات شناسایی شد.


۳-۱- فراوانی اسناد بر اساس نوع

در این بخش بر اساس نوع، اسناد شناسایی شده در موضوعات مختلف مورد بررسی قرار گرفت. در جدول ۳ نتایج حاصل نمایش داده شده است.


جدول ۳. فراوانی اسناد بر اساس نوع سند

نوع سند	دسته‌بندی موسیقی	سامانه‌های توصیه‌گر موسیقی	جدا سازی منابع موسیقی	رونویسی خودکار	تولید موسیقی
سند داده ^۱	۱	۰	۰	۱	۱
اصلاحیه ^۲	۲	۵	۱	۰	۱
کتاب	۳	۶	۴	۱	۴
سلب اعتبار شده ^۳	۶	۶	۱	۰	۵
فصل کتاب ^۴	۲۹	۴۸	۱۱	۷	۲۷
سرمقاله ^۵	۰	۲	۰	۰	۲
یادداشت علمی ^۶	۰	۰	۱	۰	۱
مقاله مروری کنفرانسی	۹۵	۱۳۵	۳۲	۱۰	۷۰
مقاله مروری مجلات	۱۴	۱۵	۷	۴	۱۱
مقاله پژوهشی کنفرانسی	۱۰۷۴	۱۰۲۷	۵۲۷	۲۴۳	۸۲۷
مقاله پژوهشی مجلات	۴۹۹	۴۳۲	۲۷۷	۹۹	۳۵۶


است. این نسبت حتی از تجمیع اسناد نیز که ۴۹ درصد است نیز بیشتر است. از منظر تعداد نیز موضوع تولید موسیقی بیشترین تعداد اسناد منتشر شده در سال ۲۰۲۴ را دارد.




رشد زمانی چاپ اسناد مرتبط با سامانه‌های توصیه‌گر موسیقی



رشد زمانی چاپ اسناد مرتبط با جداسازی منابع موسیقی



رشد زمانی چاپ اسناد مرتبط با رونویسی خودکار



رشد زمانی چاپ اسناد مرتبط با تولید موسیقی

شکل ۴. روند زمانی چاپ اسناد

از سال ۱۹۸۵ تا سال ۲۰۰۰ میلادی شاهد رشد اندکی در اسناد منتشر شده هستیم. عمده اسنادی که در این بازه منتشر شده‌اند در حوزه‌های آهنگسازی و تلاش‌های مرتبط با حوزه جداسازی منابع موسیقی است. اولین مقاله در حوزه دسته‌بندی موسیقی نیز در این بازه زمانی یعنی در سال ۱۹۸۷ به نگارش درآمد. البته هدف اصلی مقاله مدنظر در حوزه آموزش موسیقی بود و نه ارائه مدلی برای دسته‌بندی موسیقی؛ اما برای نیل به همین هدف نیز نویسندگان ناچار به بکارگیری روشی برای دسته‌بندی بودند [۱۶]. با این وجود موضوع دسته‌بندی موسیقی از سال ۲۰۰۰ به طور جدی مورد بررسی قرار گرفت که تعداد مقالات و روش‌های ارائه شده از این سال به بعد به طور محسوسی افزایش یافته است. همانطور که پیش از این نیز گفته شد، یکی از مهم‌ترین کاربردهای دسته‌بندی موسیقی در سامانه‌های توصیه‌گر است. روند انتشار مقالات حوزه سامانه‌های توصیه‌گر نیز از سال ۱۹۹۹ و با مقاله ده‌رور و همکارانش که ارائه مدلی توصیه‌گر و مبتنی بر محتوا در حوزه موسیقی بود آغاز شد. سایمون دیکسون در سال ۱۹۹۷ اولین مقاله در حوزه رونویسی خودکار را ارائه داد [۱۷].

از سال ۲۰۰۰ به بعد، موضوع سامانه‌های توصیه‌گر موسیقی را می‌توان به عنوان جذاب‌ترین حوزه پژوهشی از بین حوزه‌های مورد بررسی در مقاله قلمداد کرد که از سال ۲۰۰۹ شاهد رشد قابل توجه اسناد مرتبط با این حوزه هستیم. حوزه رونویسی خودکار نیز در تمام روند زمانی حالت یکسانی را داشته است و کمترین استقبال را در میان پژوهشگران داشته است. اما حوزه‌ای که می‌توان از آن به عنوان داغ‌ترین حوزه پژوهشی در سال‌های اخیر یاد کرد، حوزه تولید موسیقی است. مطالعات پژوهشی حوزه تولید موسیقی اگرچه از سال ۱۹۷۲ آغاز و از سال ۱۹۸۳ استمرار بیشتری داشته است، اما رشد بسیار زیادی را از سال ۲۰۱۷ در این حوزه شاهد هستیم به نحوی که تعداد اسناد پژوهشی منتشر شده از سال ۲۰۱۷ تا نیمه سال ۲۰۲۴، ۳ برابر کل اسناد مرتبط از ۱۹۷۲ تا ۲۰۱۶ است. علت این رشد چشم‌گیر در پیشرفت و توسعه مدل‌های هوش مصنوعی مولد و الگوریتم‌های یادگیری ژرف است.

بررسی نسبت اسناد منتشر شده در سال ۲۰۲۴ و ۲۰۲۳ نیز نشان می‌دهد که موضوع تولید موسیقی نسبت به سایر موضوعات وضعیت بهتری را دارا است و تا ماه هفتم سال ۲۰۲۴، نسبت اسناد منتشر شده نسبت به ۲۰۲۳، ۵۳ درصد است. در حالی که این نسبت برای موضوع دسته‌بندی موسیقی ۴۸ درصد، برای سامانه‌های توصیه‌گر ۴۶ درصد، برای رونویسی خودکار ۳۰ درصد

۳-۳- کشورهای برتر

اطلاعات موسیقی استخراج شدند. جدول ۴ نتایج حاصل را نشان می‌دهد. در کنار چین و آمریکا که به عنوان سردمداران هوش مصنوعی در جهان شناخته می‌شوند، کشور هندوستان نیز در بین برترین کشورها جایگاه مناسبی دارد.

با بررسی وابستگی‌های سازمانی مرتبط با نویسندگان اسناد مورد بررسی ۱۰ کشور برتر در هر یک از موضوعات مرتبط با بازیابی

جدول ۴. کشورهای برتر در موضوعات مورد بررسی

دسته‌بندی موسیقی		سامانه‌های توصیه‌گر		جداسازی منابع موسیقی		رونویسی خودکار		تولید موسیقی	
کشور	تعداد مقالات	کشور	تعداد مقالات	کشور	تعداد مقالات	کشور	تعداد مقالات	کشور	تعداد مقالات
چین	۳۲۷	چین	۲۸۱	چین	۱۵۱	انگلستان	۴۷	چین	۲۷۲
هندوستان	۱۷۸	هندوستان	۲۵۵	آمریکا	۷۸	چین	۳۰	آمریکا	۱۵۴
آمریکا	۹۸	آمریکا	۱۵۰	اسپانیا	۷۵	آمریکا	۲۷	هندوستان	۹۳
آلمان	۵۸	ژاپن	۷۷	آلمان	۴۷	ژاپن	۲۴	انگلستان	۷۶
انگلستان	۵۶	انگلستان	۵۲	کانادا	۴۳	اسپانیا	۲۰	ژاپن	۵۸
کانادا	۴۵	اتریش	۴۸	هندوستان	۴۳	هندوستان	۱۷	ایتالیا	۴۵
برزیل	۴۳	اسپانیا	۴۵	ژاپن	۳۶	ایتالیا	۱۶	فرانسه	۴۱
ژاپن	۴۱	آلمان	۴۲	انگلستان	۲۹	فرانسه	۱۴	اسپانیا	۲۹
اسپانیا	۴۰	ایتالیا	۳۶	فرانسه	۲۳	سنگاپور	۱۳	کانادا	۲۸
لهستان	۳۷	برزیل	۳۱	لهستان	۱۷	آلمان	۱۲	آلمان	۲۳

۳-۴- دانشگاه‌های برتر

اطلاعات موسیقی استخراج شدند. جدول ۵ نتایج حاصل را نشان می‌دهد.

با بررسی وابستگی‌های سازمانی مرتبط با نویسندگان اسناد مورد بررسی ۱۰ دانشگاه برتر در هر یک از موضوعات مرتبط با بازیابی

جدول ۵. دانشگاه‌های برتر در موضوعات مورد بررسی

دسته‌بندی موسیقی		سامانه‌های توصیه‌گر		جداسازی منابع موسیقی		رونویسی خودکار		تولید موسیقی	
دانشگاه	تعداد نویسنده	دانشگاه	تعداد نویسنده	دانشگاه	تعداد نویسنده	دانشگاه	تعداد نویسنده	دانشگاه	تعداد نویسنده
ملی تایوان	۳۵	یوهانس کپلر آلمان	۳۹	آلیکانتِه اسپانیا	۴۷	کوئین مری لندن انگلستان	۵۰	کوئین مری لندن انگلستان	۳۵
چینهوا چین	۲۵	چجیانگ چین	۲۳	مک گیل کانادا	۴۳	کیوتو ژاپن	۱۰	ارتباطات چین	۲۸
ارتباطات چین	۲۵	پمپئو فابرا اسپانیا	۲۱	ایندیانا آمریکا	۲۵	ملی سنگاپور	۱۰	کارنگی ملون آمریکا	۱۹
گدانسک لهستان	۲۵	کالیفرنیا	۲۰	چارلز چک	۱۴	آلیکانتِه اسپانیا	۱۰	کالیفرنیا آمریکا	۱۸
پمپئو فابرا اسپانیا	۲۲	چینهوا چین	۱۸	لیدز انگلستان	۱۱	راچستر آمریکا	۸	چینهوا چین	۱۷
جداووپور هند	۱۵	ملی چنگ کونگ تایوان	۱۳	پلی تکنیک والنسیا اسپانیا	۱۱	فناوری و طراحی سنگاپور	۶	یورک کانادا	۱۴
کویمبرا پرتغال	۱۴	ریتسومیکان ژاپن	۱۲	جان هاپکینز آمریکا	۱۰	ویکتوریا کانادا	۶	فناوری و طراحی سنگاپور	۱۴
اوزاکا ژاپن	۱۳	بولزانو ایتالیا	۱۲	لندن انگلستان	۱۰	فلورانس ایتالیا	۶	پست و تلکام پکن چین	۱۲
ملی سنگاپور	۱۲	ملی سئول کره جنوبی	۱۱	ملی سئول کره جنوبی	۱۰	فناوری تامپره فنلاند	۶	واسدا ژاپن	۱۲
ارسطو تسالونیک یونان	۱۲	ارسطو تسالونیک یونان	۱۲	فناوری ورشو لهستان	۹	ملی سئول کره جنوبی	۵	ملی سنگاپور	۱۰

رشد می‌باشند.

۳-۵- نویسندگان برتر

با بررسی نویسندگان مقالات در موضوعات مورد بررسی برترین نویسندگان که در هر حوزه بیشترین مقاله منتشر شده را داشتند شناسایی و در جدول ۶ نمایش داده شده‌اند. لازم به توضیح است که برخی از نویسندگان در مقالات مختلف وابستگی سازمانی متفاوتی را ذکر کرده‌اند. به همین دلیل ممکن است برخی نویسندگان تعداد بیشتری مقاله نسبت به سازمان وابسته اصلی خود داشته باشند.

نکته‌ای که در بررسی دانشگاه‌های برتر قابل توجه است این است که در کشورهای چین و آمریکا، شاهد تعداد دانشگاه‌هایی هستیم که در حوزه هوش مصنوعی و موسیقی فعالیت می‌کنند. این تعداد در هندوستان نیز وجود دارد اما نمی‌توان دانشگاه خاصی را در این حوزه مشاهده کرد؛ ضمن اینکه در موضوعات جدیدتر و داغ‌تر دانشگاه‌های هندوستان فعالیت کمتری دارند. در کشورهایی نظیر اسپانیا، سنگاپور، ژاپن و کره جنوبی این مطالعات به صورت متمرکز در چند دانشگاه محدود صورت گرفته است.

در حوزه تولید موسیقی به عنوان داغ‌ترین موضوع، فعالیت دانشگاه‌های چین، آمریکا و انگلستان نسبت به سایر کشورها بسیار بیشتر است و دانشگاه‌های کشور سنگاپور در این زمینه در حال

جدول ۶. نویسندگان برتر در موضوعات مورد بررسی

دسته‌بندی موسیقی			
نام	تعداد مقالات	نام	تعداد مقالات
هی سیون یانگ ^۱	۴۵	هومر چن ^۲	۲۱
ایگور واتولکین ^۳	۱۸	بوزنا کوستک ^۴	۱۷
فابیان گویون ^۵	۱۲	باب ال استرام ^۶	۱۱
کیم هیونگ گوک ^۷	۱۱	یو چینگ لین ^۸	۱۱
الساندرو ال کوریخ ^۹	۱۰	کارلوس ان سیلا ^{۱۰}	۱۰
سامانه‌های توصیه‌گر			
نام	تعداد مقالات	نام	تعداد مقالات
مارکوس شدی ^{۱۱}	۳۶	فرانچسکو ریچی ^{۱۲}	۱۴
دیتمار جناخ ^{۱۳}	۱۱	پیتر نس ^{۱۴}	۱۰
کاترین وربرت ^{۱۵}	۱۰	ریشاب مهروتا ^{۱۶}	۱۰
آرتور فلکسر ^{۱۷}	۹	یوچنگ جین ^{۱۸}	۹
آرتو لحتینی ^{۱۹}	۹	ایمان کامه‌خوش ^{۲۰}	۸
جداسازی منابع موسیقی			
نام	تعداد مقالات	نام	تعداد مقالات
جرج کالو زاراگوزا ^{۲۱}	۶۵	ایچیرو فوجیناگا ^{۲۲}	۴۰

¹ Yi-Hsuan Yang

² Homer Chen

³ Igor Vatulkin

⁴ Bozena Kostek

⁵ Fabien Gouyon

⁶ Bob L. Sturm

⁷ Hyoung-Gook Kim

⁸ Yu-Ching Lin

⁹ Alessandro L. Koerich

¹⁰ Carlos N Silla

¹¹ Markus Schedl

¹² Francesco Ricci

¹³ Dietmar Jannach

¹⁴ Peter Knees

¹⁵ Katrien Verbert

¹⁶ Rishabh Mehrotra

¹⁷ Arthur Flexer

¹⁸ Yucheng Jin

¹⁹ Arto Lehtiniemi

²⁰ Iman Kamehkhosh

²¹ Jorge Calvo-Zaragoza

²² Ichiro Fujinaga

۱۲	آنا روبلو ^۲	۱۳	گابریل ویگلنسونی ^۱
۱۲	رافائل کریستوفر ^۴	۱۲	دیوید ریزو ^۳
۱۱	خوزه جی والرو ماس ^۶	۱۱	لورنت پوگین ^۵
۱۱	جیم اس کاردوسو ^۸	۱۱	فرانسیسکو کاستلانوس ^۷
رونویسی خودکار			
تعداد مقالات	نام	تعداد مقالات	نام
۱۷	سیمون دیکسون ^{۱۰}	۳۴	امانوئل بنتوس ^۹
۱۱	مارک دی پلامبلی ^{۱۲}	۱۴	سو لی ^{۱۱}
۷	جرج کالو زاراگوزا	۷	ژیائو دوان ^{۱۳}
۷	آنسی کالپوری ^{۱۵}	۷	اندرو مکلید ^{۱۴}
۶	اورت سباستین ^{۱۷}	۶	یی وانگ ^{۱۶}
تولید موسیقی			
تعداد مقالات	نام	تعداد مقالات	نام
۱۳	گاس ژیا ^{۱۸}	۱۷	هی سیون یانگ
۱۲	فرانسیوس پاچت ^{۲۰}	۱۳	دورین هرمانس ^{۱۹}
۱۰	ژئانوبینگ لی ^{۲۲}	۱۲	چی فانگ هوانگ ^{۲۱}
۸	سیمون کولتن ^{۲۴}	۹	دارل کانکلین ^{۲۳}
۸	دانکن ویلیامز ^{۲۶}	۸	کونگ جین ^{۲۵}

¹ Gabriel Vigliensoni

² Ana Rebelo

³ David Rizo

⁴ Christopher Raphael

⁵ Pugin, Laurent

⁶ Jose J.Valero-Mas

⁷ Francisco J. Castellanos

⁸ Jaime S.Cardoso

⁹ Emmanouil Benetos

¹⁰ Simon Dixon

¹¹ Li Su

¹² Mark D. Plumbley

¹³ Zhiyao Duan

¹⁴ Andrew Mcleod

¹⁵ Anssi Klapuri

¹⁶ Ye Wang

¹⁷ Sebastian Ewert

¹⁸ Gus Xia

¹⁹ Dorien Herremans

²⁰ François Pachet

²¹ Chih-Fang Huang

²² Xiaobing Li

²³ Darrell Conklin

²⁴ Simon Colto

²⁵ Cong Jin

²⁶ Duncan Williams

۳-۶- الگوریتم‌ها و روش‌های مورد استفاده

در این بخش از مقاله به بررسی روش‌های مورد استفاده در هر یک از پنج موضوع مدنظر مقاله پرداخته می‌شود. در هر یک از موضوعات روش‌هایی که در مقالات مختلف مورد استفاده قرار گرفته معرفی و نقاط قوت و ضعف هر یک به اختصار بیان شده است. علاوه بر این مقالاتی که در هر یک از موضوعات از روش‌های مدنظر استفاده کرده‌اند مشخص شده‌اند. برای انتخاب مقالات شرایط زیر در نظر گرفته شده است:

۳. الگوریتم، مدل یا چارچوبی برای موضوع مورد بررسی در مقاله توسعه داده شده باشند.

۴. مقالات پژوهشی کنفرانسی یا برای سال‌های ۲۰۲۳ و ۲۰۲۴ باشند و یا میزان ارجاع به آن‌ها حداقل ۱۰ ارجاع و در مواردی که برای مثال به دلیل جدید بودن حوزه، میزان ارجاعات پایین است حداقل پنج ارجاع باشد.

۳-۷- روش‌های مورد استفاده در دسته‌بندی موسیقی

با بررسی مقالات گوناگون مرتبط با دسته‌بندی موسیقی، عمده روش‌های هوش مصنوعی مورد استفاده در این حوزه در جدول ۷ نمایش داده شده است.

۱. مقالات از سال ۲۰۱۰ میلادی به بعد باشند.

۲. مقالات از نوع پژوهشی مجلات و پژوهشی کنفرانسی باشند.

جدول ۷. بررسی روش‌های مورد استفاده در دسته‌بندی موسیقی

روش	مزایا	معایب	مقالات
شبکه‌های بیزین (Bayesian)	پایه‌سازی آسان و مناسب برای مجموعه دادگان بزرگ و با ابعاد بالا	فرض اصلی استقلال بین ویژگی‌هاست که این فرض همیشه دقیق نیست.	[۱۸ - ۲۴]
K نزدیکترین همسایه	تفسیر پذیری، درک و پایه‌سازی آسان و دقت مناسب	وابستگی به تعداد همسایگان، زمان محاسبه و اجرای بالا	[۲۵ - ۲۶]
رگرسیون (Regression)	درک و تفسیر پذیری آسان	یافتن روابط بین متغیرها در همه مسائل به سادگی ممکن نیست.	[۲۷ - ۳۱]
درخت تصمیم (Decision Tree)	سهولت درک و تفسیر	بیش‌برازش و تغییرات شدید به هنگام تغییر جزئی در دادگان	[۳۲ - ۳۴]
جنگل تصادفی (Random Forest)	عملکرد بهتر نسبت به درخت تصمیم در حل مشکل بیش‌برازش	پیچیدگی بسیار زیاد	[۳۵ - ۳۸]
ماشین بردار پشتیبان (Support Vector Machines)	مناسب برای مدیریت داده‌های غیر خطی و مجموعه دادگان بزرگ و با ابعاد بالا	برای داده‌هایی با نویز زیاد عملکرد مناسبی ندارد	[۳۹ - ۴۷]
شبکه عصبی کانولوشن (Convolutional Neural Network)	مناسب برای مجموعه دادگان بزرگ و عملکرد خوب در انواع سیگنال‌های صوتی	پیچیدگی در تفسیر پذیری و نیاز به مقادیر بالای داده‌های برچسب‌گذاری شده	[۴۸ - ۵۷]
شبکه عصبی بازگشتی (Recurrent Neural Network)	مناسب برای مدیریت سیگنال‌های صوتی با طول زمانی متغیر	پیچیدگی در آموزش و نیاز به مقادیر بالای داده‌های برچسب‌گذاری شده	[۵۸ - ۶۲]
شبکه عصبی LSTM (Long-Short Term Memory Neural Network)	مشکل حافظه شبکه عصبی بازگشتی را حل کرده و محوشدگی اطلاعات ندارد	پیچیدگی بالا، پیچیدگی تنظیم پارامتر و مصرف بالای حافظه که نیازمند زمان بالا برای آموزش است.	[۶۳ - ۶۸]
روش‌های ترکیبی	استفاده از ظرفیت روش‌های مختلف جهت رفع مشکل دیگری و بهبود نتایج	تعمیم‌پذیری روش برای استفاده در سایر زمینه‌ها محل تشکیک است.	[۶۹ - ۷۸]

۳-۸- روش‌های مورد استفاده در سامانه‌های توصیه‌گر

موسیقی

با بررسی مقالات گوناگون مرتبط با سامانه‌های توصیه‌گر موسیقی، عمده روش‌های هوش مصنوعی مورد استفاده در این حوزه در جدول ۸ نمایش داده شده است.

۳-۱۰- روش‌های مورد استفاده در رونویسی خودکار

با بررسی مقالات گوناگون مرتبط با رونویسی خودکار، عمده روش‌های هوش مصنوعی مورد استفاده در این حوزه در جدول ۱۰ نمایش داده شده است.

۳-۱۱- روش‌های مورد استفاده در تولید موسیقی

با بررسی مقالات گوناگون مرتبط با تولید موسیقی، عمده روش‌های هوش مصنوعی مورد استفاده در این حوزه در جدول ۱۱ نمایش داده شده است.

۳-۹- روش‌های مورد استفاده در جداسازی منابع

موسیقی

با بررسی مقالات گوناگون مرتبط با جداسازی منابع موسیقی، عمده روش‌های هوش مصنوعی مورد استفاده در این حوزه در جدول ۹ نمایش داده شده است.

جدول ۸. بررسی روش‌های مورد استفاده در سامانه‌های توصیه‌گر موسیقی

روش	مزایا	معایب	مقالات
فیلترینگ مشارکتی ^۱	امکان شخصی‌سازی توصیه‌ها با استفاده از رصد رفتاری مخاطب	مشکل شروع سرد ^۲ و نیز مشکل در کار با داده‌های خنک ^۳	[۸۹ – ۷۹]
مبتنی بر محتوا	امکان توصیه بر اساس ویژگی‌های خاص موسیقی	عدم در نظر گرفتن ترجیحات کاربران	[۹۰ – ۱۰۰]
یادگیری ژرف	استخراج و یادگیری الگوهای پیچیده در سیگنال‌های صوتی	نیاز به مقادیر بالای داده‌های برچسب‌گذاری شده	[۱۱۸ – ۱۰۱]
تجزیه ماتریس ^۴	مدیریت داده‌ها در حجم بالا	زمان محاسبه و اجرای بالا	[۱۲۱ – ۱۱۹]
روش‌های ترکیبی	استفاده از نقاط قوت روش‌ها	پیچیدگی بالا	[۱۴۱ – ۱۲۲]

جدول ۹. بررسی روش‌های مورد استفاده در جداسازی منابع موسیقی

روش	مزایا	معایب	مقالات
یادگیری ژرف	انعطاف در مدل‌سازی ساختار موسیقی‌های چند صدایی و پیچیده	نیاز به منابع محاسباتی بسیار بالا و دادگان متنوع و حجیم	[۱۶۷ – ۱۴۲]
مدل‌های مخفی مارکوف (Hidden Markov Model)	مدیریت حجم زیادی از داده‌ها	مشکل در مدل‌سازی موسیقی‌های چند صدایی	[۱۷۶ – ۱۶۸]
ماشین بردار پشتیبان	امکان مدیریت دادگان با ابعاد نسبتاً بالا	کارایی کاهش در موسیقی‌هایی با اجزای ناشناس	[۱۸۲ – ۱۷۷]

جدول ۱۰. بررسی روش‌های مورد استفاده در رونویسی خودکار

روش	مزایا	معایب	مقالات
یادگیری ژرف	مدیریت حجم زیادی از داده‌ها، نمایش بهتر ویژگی‌های پیچیده موسیقی	نیاز به مقادیر بالای داده‌های برچسب‌گذاری شده و منابع محاسباتی زیاد	[۲۱۱ – ۱۸۳]
مدل‌های مخفی مارکوف	مدیریت حجم زیادی از داده‌ها، عملکرد مناسب در مدل‌سازی الگوهای متوالی	مشکل در مدل‌سازی ساختارهای پیچیده موسیقی	[۲۲۵ – ۲۱۲]
ماشین بردار پشتیبان	عملکرد مؤثر در مدیریت داده‌های سری زمانی و انعطاف‌پذیر در تطبیق عبارات موسیقی	مستعد خطا در مدل‌سازی موسیقی و محدودیت در تعداد ویژگی‌ها	[۲۲۹ – ۲۲۶]

^۱ Collaborative Filtering^۲ Cold start^۳ Data sparsity^۴ Matrix Factorization

جدول ۱۱. بررسی روش‌های مورد استفاده در تولید موسیقی

روش	مزایا	معایب	مقالات
الگوریتم‌های تکاملی (Evolutionary Algorithms)	امکان بهینه‌سازی کیفیت خروجی با تعریف تابع ارزیابی مناسب	استحکام و تعمیم‌پذیری پایین	[۲۳۷ – ۲۳۰]
شبکه عصبی بازگشتی	عملکرد مناسب در تولید موسیقی به شکل متوالی	مشکل بیش‌برازش	[۲۴۴ – ۲۳۸]
شبکه عصبی LSTM	افزایش زمان خروجی تولیدی،	پیچیدگی تعریف و تنظیم پارامتر	[۲۵۸ – ۲۴۵]
شبکه خودرمن‌نگار متغیر (Variational Autoencoder)	عملکرد مناسب در تولید داده‌های متنوع و با کیفیت	پیچیدگی زیاد و تنوع پایین خروجی نسبت به شبکه‌های مولد تخصصی	[۲۶۶ – ۲۵۹]
مبدل (Transformer)	بهترین گزینه برای تولید موسیقی طولانی و عملکرد مناسب در تولید داده‌های متوالی	پیچیدگی زیاد و امکان تولید موسیقی با کیفیت پایین	[۳۰۱ – ۲۶۷]
شبکه‌های مولد تخصصی (Generative Adversarial Network)	عملکرد خوب در تولید موسیقی‌های جدید	آموزش دشوار و عدم اطمینان از کیفیت موسیقی خروجی	[۳۱۰ – ۳۰۲]
زنجیره مارکوف (Markov Chain)	عملکرد مناسب در تولید بر اساس الگوی خاص و توالی مشخص	عدم اطمینان از تولید خروجی جدید و متنوع	[۳۱۹ – ۳۱۱]
روش‌های ترکیبی	تنوع و کیفیت بالای خروجی	پیچیدگی زیاد، نیاز به منابع محاسباتی بالا و تعمیم‌پذیری پایین	[۳۴۸ – ۳۲۰]

مقیاس‌پذیری سیستم با افزایش تعداد کاربران و آهنگ‌ها می‌شوند. در نهایت، موضوع تنوع در توصیه‌ها وجود دارد که برای اطمینان از اینکه کاربران در معرض سبک‌ها و ژانرهای مختلف موسیقی قرار می‌گیرند، ضروری است.

درخصوص **جداسازی منابع موسیقی**، چندصدایی‌ها چالش اساسی هستند. هم‌چنین عدم شناسایی سازهای گوناگون نیز چالش دیگری است که این حوزه با آن روبه‌روست. وجود طیف وسیع سازها در موسیقی‌های نواحی و مناطق مختلف و عدم وجود تعداد کافی داده برای هر یک از این سازها شناسایی سیگنال‌های مربوط به آن‌ها را در موسیقی‌های مختلف با مشکل مواجه کرده است. تشخیص آواهای گوناگون و موارد خلاقانه‌ای چون بیت‌باکس از دیگر چالش‌های مهم این حوزه است.

در حوزه **رونویسی خودکار**، چالش‌ها شبیه به حوزه جداسازی منابع موسیقی است. یکی از مهم‌ترین چالش‌ها موسیقی‌هایی چند صدایی و دارای چندین ساز است. این چالش توسط چالش دیگری تشدید می‌شود و آن نبود تعداد کافی داده برچسب‌گذاری شده برای سازهای گوناگون است. علاوه بر این در موسیقی‌های دارای سرعت‌های متغیر و تغییرات زیاد زبری و بمی صدا استفاده از روش‌های هوش مصنوعی در رونویسی با مشکل مواجه می‌شود. علاوه بر موارد فوق زبان‌ها، لهجه‌ها و گویش‌های مختلف امکان شناسایی و رونوشت خودکار اشعار موسیقی را دشوار می‌کند.

۳-۱۲- چالش‌های به‌کارگیری هوش مصنوعی در هنر موسیقی

در این بخش به بررسی چالش‌های استفاده از روش‌ها و الگوریتم‌های هوش مصنوعی در هر یک از موضوعات پنجگانه مورد بررسی در این مقاله پرداخته می‌شود.

چالش اصلی **دسته‌بندی موسیقی**، ابعاد گسترده ویژگی‌های موسیقی‌هاست که فرآیند آموزش مدل‌های دسته‌بندی را پیچیده و مشکل می‌سازد. تغییرپذیری سیگنال موسیقی و فقدان مجموعه داده‌های موسیقی برچسب‌دار دیگر چالش بزرگ این حوزه است. به‌علاوه، عدم استانداردسازی ژانرها، سبک‌ها و احساسات و حالات موسیقی نیز می‌تواند دسته‌بندی موسیقی را به چالش بکشد.

علیرغم موفقیت هوش مصنوعی در **سامانه‌های توصیه‌گر موسیقی**، چندین چالش دیگرهنوز باید برطرف شود. یکی از چالش‌های اصلی مشکل شروع سرد است، که زمانی رخ می‌دهد که یک سیستم نمی‌تواند برای کاربران جدیدی که هنوز سابقه شنیداری ارائه نکرده‌اند، توصیه‌هایی ارائه دهد. البته این چالش در روش‌های مبتنی بر محتوا برطرف شده اما ممکن است عدم درنظر گرفتن ترجیحات کاربران سبب کاهش کارایی توصیه‌گر شود. روش‌های ترکیبی پاسخ نسبتاً مناسبی می‌دهند اما این روش‌ها نیز همچون روش‌های مبتنی بر کاربر یا مبتنی بر محتوا دچار چالش

روندی رو به رشد دارد و محققان همچنان به دنبال کشف روش‌هایی برای بهبود توصیه‌ها هستند که یادگیری ژرف و ترکیب آن با روش‌های مرسوم، از داغ‌ترین موضوعات در این حوزه است.

حوزه جداسازی منابع موسیقی، نیاز به مجموعه دادگان مناسب برای سازهای گوناگون و جمع‌آوری و برچسب‌زنی این دادگان دارد که می‌تواند از موضوعات بسیار مهم برای مطالعات آینده باشد. در ایران نیز این موضوع می‌تواند حوزه تحقیقاتی جذابی باشد، چرا که تنوع سازهای موسیقی ایرانی زیاد است و تهیه مجموعه دادگان مرتبط با آن‌ها توسط افرادی به غیر از هنرمندان ایرانی که به خوبی با این سازها آشنا هستند، کمی غیرمعمول به نظر می‌آید.

حوزه رونویسی خودکار نیز نیاز به مجموعه دادگان دارد؛ دادگانی که نه تنها برای سازهای گوناگون، بلکه برای موسیقی‌های گوناگون با تنوع ضرب‌آهنگ‌های متفاوت و برای موسیقی‌ها با زبان‌ها، لهجه‌ها و گویش‌های مختلف باید تهیه گردد. علاوه بر این توسعه و انطباق مدل‌های مختلف برای کار بر روی این داده‌ها نیز از موضوعات پژوهشی است که می‌تواند در آینده پیگیری شود.

تولید موسیقی موضوع چالش برانگیز و رو به رشدی است که پیش‌بینی می‌شود روند تحقیقات در چند سال آینده بر روی ارائه مدل‌ها و روش‌های جدید برای تولید اصوات مختلف و تولید موسیقی تمرکز داشته باشد. تمرکز بر مدل‌های هوش مصنوعی مولد سعی در حل مشکل تنوع موسیقی تولید شده خواهد داشت. اما یکی از موضوعات مهم که می‌تواند در پژوهش‌های آتی مد نظر قرار گیرد، مسئله مالکیت معنوی و همچنین مسئله جعل عمیق است. در نهایت تهیه مجموعه دادگان مناسب برای حوزه‌های مختلف، توسعه کاربردهای هوش مصنوعی را در آینده هنر موسیقی رقم خواهد زد و کارکردهای مطلوب‌تر و مقبول‌تری از هوش مصنوعی را سبب خواهد شد.

مراجع

- [۱] کلاته، رحمانی و چهارده چریکی، معصومه. "هوش مصنوعی و کاربرد آن در حسابداری مالی"، کنکاش، صص ۱۳۵-۱۴۰، ۱۳۸۹.
- [۲] حشمدار، اکرم، کردی، مراد، "بررسی اثربخشی سیستم‌های هوش مصنوعی در کارکردهای منابع انسانی"، فصلنامه پژوهش‌های معاصر در علوم مدیریت و حسابداری، سال چهارم، شماره ۱۲، بهار ۱۴۰۱.
- [۳] زیودار، زهره، "کاربرد تکنیک‌های هوش مصنوعی در حوزه حسابداری و مالی"، فصلنامه رویکردهای پژوهشی نوین در مدیریت و حسابداری، سال ششم، شماره ۸۴، صص ۱۵۷۲-۱۵۵۷، ۱۴۰۱.

یکی از چالش‌های اصلی در تولید موسیقی، موضوع منحصر به فردی و تنوع است. این امر مستلزم درک عمیق تئوری و آهنگسازی موسیقی و توانایی درک ماهیت سبک‌های مختلف موسیقی است. علاوه بر این، نیاز به مقادیر زیادی داده برچسب‌گذاری شده از چالش‌های دیگر به کارگیری هوش مصنوعی در تولید موسیقی است. دیگر چالش پیش رو ارزیابی کیفیت موسیقی تولید شده است. همچنین چالش مهم و اساسی دیگر موضوع مالکیت معنوی و مسائل مرتبط با آن است که آینده هوش مصنوعی در موسیقی تحت شعاع این مورد قرار می‌گیرد.

۴- جمع‌بندی و نتیجه‌گیری

در میان حوزه‌های متعدد کاربرد هوش مصنوعی در هنر موسیقی، پنج حوزه دسته‌بندی موسیقی، سامانه‌های توصیه‌گر موسیقی، جداسازی منابع موسیقی، رونویسی خودکار و تولید موسیقی بیشترین سهم را میان تحقیقات علمی داشته که در این مقاله این پنج حوزه به تفصیل مورد بررسی قرار گرفت.

در میان این پنج حوزه، تولید موسیقی و سامانه‌های توصیه‌گر نسبت به سایر حوزه‌ها رشد بیشتری داشته و مطالعات بیشتری را به خود جلب نموده است. در حوزه تولید موسیقی در دو سال اخیر به علت توسعه مدل‌های هوش مصنوعی مولد رشد چشمگیری در مطالعات و پژوهش‌های علمی دیده می‌شود. درخصوص سامانه‌های توصیه‌گر موسیقی روند رشد مقالات از حدود سال ۲۰۱۰ آغاز شده است. به طور کلی سامانه‌های توصیه‌گر در این زمان رشد مناسبی داشته و به طبع آن در حیطه موسیقی نیز این روند مشاهده می‌شود.

استفاده از روش‌های مبتنی بر یادگیری ژرف در تمامی حوزه‌ها رو به افزایش است و در تولید موسیقی مبدل‌ها و هوش مصنوعی مولد نقشی اساسی ایفا می‌کنند.

در حوزه دسته‌بندی موسیقی در آینده، تحقیقات می‌تواند بر روی توسعه روش‌هایی متمرکز شود که با تعداد بالای ویژگی‌ها بتوانند مدلسازی نموده و تغییرات سیگنال‌های موسیقی را کنترل کنند. علاوه بر این دسته‌بندی موسیقی‌ها در زبان‌ها، فرهنگ‌ها و مناطق گوناگون احتمالاً در سال‌های آینده افزایش خواهد یافت. برای پیشرفت این حوزه اجماع و استانداردسازی در ژانرها، سبک‌ها و... می‌تواند کمک شایان توجهی کند.

درخصوص سامانه‌های توصیه‌گر، ادغام سایر داده‌ها نظیر استخراج علایق شخص از رسانه‌های اجتماعی یا ویژگی‌های شخصیتی و ... می‌تواند توصیه‌هایی شخصی‌سازی‌شده‌تری ارائه کند. این حوزه

- [22] J. Bai, K. Luo, J. Peng, J. Shi, Y. Wu, L. Feng, ... and Y. Wang, "Music emotions recognition by cognitive classification methodologies", In 2017 IEEE 16th International Conference on Cognitive Informatics & Cognitive Computing (ICCI* CC), 121-129, 2017.
- [23] F. Kurniawan, "Automatic music classification for Dangdut and campursari using Naïve Bayes", In Proceedings of the 2011 International Conference on Electrical Engineering and Informatics, 1-6, 2011.
- [24] Z. Fu, G. Lu, K. M. Ting, and D. Zhang, "Learning naive Bayes classifiers for music classification and retrieval", In 2010 20th international conference on pattern recognition, 4589-4592, 2010.
- [25] R. Rajan, and B. S. Mohan, "Distance Metric Learnt Kernel-Based Music Classification Using Timbral Descriptors", International Journal of Pattern Recognition and Artificial Intelligence, 35(13), 2151014, 2021.
- [26] M. Sudarma, M, and I. G. Harsemadi, "Design and analysis system of KNN and ID3 algorithm for music classification based on mood feature extraction", International Journal of Electrical and Computer Engineering, 7(1), 486, 2017.
- [27] Y. Li, X. Li, Z. Lou, and C. Chen, "Long short-term memory-based music analysis system for music therapy", Frontiers in Psychology, 13, 928048, 2022.
- [28] L. Wang, H. Zhu, X. Zhang, S. Li, and W. Li, "Transfer learning for music classification and regression tasks using artist tags", In Proceedings of the 7th Conference on Sound and Music Technology (CSMT) Revised Selected Papers, 81-89. Springer Singapore, 2020.
- [29] D. H. Lee, J. W. Park, and Y. S. Seo, "Multiple Regression-Based Music Emotion Classification Technique", KIPS Transactions on Software and Data Engineering, 7(6), 239-248, 2018.
- [30] K. Choi, G. Fazekas, M. Sandler, and K. Cho, "Convolutional recurrent neural networks for music classification", In 2017 IEEE International conference on acoustics, speech and signal processing (ICASSP), 2392-2396, 2017.
- [31] Y. Deng, Y. Lv, M. Liu, and Q. Lu, "A regression approach to categorical music emotion recognition", In 2015 IEEE International Conference on Progress in Informatics and Computing (PIC), 257-261, 2015.
- [32] H. Wu, and L. Zhu, Adaptive classification method of electronic music based on improved decision tree, International Journal of Arts and Technology, 15(1), 1-12, 2024.
- [33] V. Pavan, A. S. Vickram, and R. Dhanalakshmi, "Efficient prediction of music genre using support vector machine and decision tree", In AIP Conference Proceedings, AIP Publishing, 2853(1), 2024.
- [34] G. M. Bressan, B. C. de Azevedo, and E. A. S. Lizzi, "A decision tree approach for the musical genres classification", Applied Mathematics & Information Sciences, 11(6), 1703-1713, 2017.
- [35] V. Pavan, and R. Dhanalakshmi, "Performance evaluation of music genre prediction system using convolutional neural network and random forest", In AIP Conference Proceedings, AIP Publishing, 2853(1), 2024.
- [36] Z. Dai, and X. Huang, "Electronic Dance Music Classification Based on Machine Learning Methods", In 2022 International Conference on Electronics and Devices, Computational Science (ICEDCS), IEEE, 351-354, 2022.
- [37] S. V. Thambi, K. T. Sreekumar, C. S. Kumar, C. S. and P. R. Raj, "Random forest algorithm for improving the performance of speech/non-speech detection", In 2014 First International Conference on Computational Systems and Communications (ICCSC), IEEE, 28-32, 2014.
- [4] ترابی، علیرضا، احمدی‌زاد، آرمان و اصغرnia، مرتضی، "فرصتها و چالشها و روندهای جهانی فناوری تنظیم گری (مرور مبانی نظری)", فصلنامه توسعه تکنولوژی صنعتی، شماره ۸، صص ۳-۱۶، ۱۴۰۱.
- [۵] استخریان، امیررضا و آرزو، الهام، "مرور سیستماتیک مطالعات مرتبط با هوش مصنوعی و اینترنت اشیا در شرکت‌های کوچک و متوسط (SME)", اولین کنفرانس بین المللی برق و کامپیوتر، مکانیک و هوش مصنوعی، ۱۴۰۰.
- [۶] کارکن بیرق، حبیب، "نگرش انتقادی به مسئله هوش مصنوعی"، نشریه ذهن، شماره ۳۷، صص ۵۹-۸۴، ۱۳۸۸.
- [۷] بافنده، علی و شمول، داوود، "هوش مصنوعی و کاربرد آن در مدیریت"، فروغ تدبیر، سال ششم، شماره ۱۵، صص ۴۴-۴۹، ۱۳۸۷.
- [۸] اخشابی، مجید و درتاج، فریبرز، "شناسایی متغیرهای میانجی در رابطه میان آموزش موسیقی و افزایش خلاقیت، فصلنامه علمی پژوهشی علوم روانشناختی، شماره ۲۱، صص ۸۶-۸۵، ۱۴۰۱.
- [۹] نصیری مخم، فریا و روغنی‌زاده، راضیه، "ساخت هوشمند موسیقی با الگوریتم ژنتیک مبتنی بر جهش یکنواخت موتیف"، فصلنامه هوش محاسباتی در مهندسی برق، دوره ۵، شماره ۴، صص ۱۰۲-۸۵، ۱۳۹۳.
- [10] G. Papadopoulos, and G. Wiggins, "AI Methods for Algorithmic Composition: A Survey, a Critical view and Future Prospects", AISB Symposium on Musical Creativity, Edinburgh, UK, 1999.
- [11] B. Johanson, and R. Poli, R, "GP-Music: An Interactive Genetic Programming System for Music Generation with Automated Fitness Raters", Genetic Prog. Proc. of the Third Annual Conf. CSRP, 1998.
- [12] N. Lazar, and K. Chithra, "Comprehensive bibliometric mapping of publication trends in the development of Building Sustainability Assessment Systems", Environment, Development and Sustainability, 23(4), 4899-4923, 2021.
- [13] J. S. Downie, "Music information retrieval", Annual review of information science and technology, 37(1), 295-340, 2003.
- [14] D. Deutsch, "Music recognition", Psychological Review, 76(3), 300-307, 1969.
- [15] J. A. Moorer. "Music and computer composition", Commun, ACM 15(2), 104-113, 1972.
- [16] D. Gregory, and W. L. Sims, "Music Preference Analysis with Computers", Journal of Music Therapy, 24(4), 203-212, 1987.
- [17] S. Dixon, "Beat induction and rhythm recognition", In: Sattar, A. (eds) Advanced Topics in Artificial Intelligence, AI 1997, Lecture Notes in Computer Science, Springer, Berlin, Heidelberg, 1342, 1997.
- [18] X. Liu. "Research on Music Genre Recognition Based on Improved Naive Bayes Algorithm", Mobile Information Systems, 2022(1), 1909928, 2022.
- [19] T. Ren, F. Wang, and H. Wang, "A sequential naive Bayes method for music genre classification based on transitional information from pitch and beat", Statistics and Its Interface, 13(3), 361-371, 2020.
- [20] D. S. Rahardwika, E. H. Rachmawanto, C.A. Sari, C. Irawan, D. P. Kusumaningrum, and S.L. Trusthi, "Comparison of SVM, KNN, and NB classifier for genre music classification based on metadata", In 2020 international seminar on application for technology of information and communication (iSemantic), 12-16. 2020.
- [21] R. Malheiro, R. Panda, P. Gomes, and R.P. Paiva, "Emotionally-relevant features for classification and regression of music lyrics", IEEE Transactions on Affective Computing, 9(20), 240-254, 2016.

- [54] A. Arronte Alvarez, and F. Gómez, "Motivic pattern classification of music audio signals combining residual and LSTM networks", *International Journal of Interactive Multimedia and Artificial Intelligence*, 6(6), 208-214, 2021.
- [55] W. Bian, J. Wang, B. Zhuang, J. Yang, S. Wang, and J. Xiao, "Audio-based music classification with DenseNet and data augmentation", In *PRICAI 2019: Trends in Artificial Intelligence: 16th Pacific Rim International Conference on Artificial Intelligence*, Cuvu, Yanuca Island, Fiji, August 26-30, 2019, *Proceedings, Part III* 16, 56-65, 2019.
- [56] Y. M. Costa, L. S. Oliveira, and J. C. N. Silla, "An evaluation of convolutional neural networks for music classification using spectrograms", *Applied soft computing*, 52, 28-38, 2017.
- [57] C. Senac, T. Pellegrini, F. Mouret, and J. Pinquier, "Music feature maps with convolutional neural networks for music genre classification", In *Proceedings of the 15th international workshop on content-based multimedia indexing*, 1-5, 2017.
- [58] K. K. Khine, and C. Su, "Acoustic Scene Classification Using Deep C-RNN Based on Log Mel Spectrogram and Gammatone Frequency Cepstral Coefficients Features", In *2024 3rd International Conference on Artificial Intelligence For Internet of Things (AIIoT)*, IEEE, 1-6, 2024.
- [59] Q. He, "A Music Genre Classification Method Based on Deep Learning", *Mathematical Problems in Engineering*, 2022(1), 9668018, 2022.
- [60] H. Mukherjee, A. Dhar, M. Ghosh, S. M. Obaidullah, K. C. Santosh, S. Phadikar, and K. Roy, "Music chord inversion shape identification with LSTM-RNN", *Procedia Computer Science*, 167, 607-615, 2020.
- [61] J. Jakubik, "Evaluation of gated recurrent neural networks in music classification tasks", In *Information Systems Architecture and Technology: Proceedings of 38th International Conference on Information Systems Architecture and Technology-ISAT 2017: Part I*, Springer International Publishing, 27-37, 2018.
- [62] W. Zhao, Y. Zhou, Y. Tie, and Y. Zhao, "Recurrent neural network for MIDI music emotion classification", In *2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, IEEE, 2596-2600, 2018.
- [63] J. Yi, Y. Zhu, J. Xie, and Z. Chen, "Cross-modal variational auto-encoder for content-based micro-video background music recommendation", *IEEE Transactions on Multimedia*, 25, 515-528, 2021.
- [64] R. A. Sadek, A. A. Khalifa, and M. M. Elfattah, "Detecting digital stimulant music using bidirectional deep long short term memory", In *2021 9th international Japan-Africa conference on electronics, communications, and computations (JAC-ECC)*, IEEE, 150-154, 2021.
- [65] S. Deepak, and B. G. Prasad, "Music Classification based on Genre using LSTM", In *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*, IEEE, 985-991, 2020.
- [66] A. Ycart, and E. Benetos, "Learning and evaluation methodologies for polyphonic music sequence prediction with LSTMs", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 28, 1328-1341, 2020.
- [67] S. I. Kang, and S. Lee, Improvement of speech/music classification for 3GPP EVS Based on LSTM, *Symmetry*, 10(11), 605, 2018.
- [68] R. J. M. Quinto, R. O. Atienza, and N. M. C. Tiglaio, "Jazz music sub-genre classification using deep learning", In *TENCON 2017-2017 IEEE Region 10 Conference*, IEEE, 3111-3116, 2017.
- [69] Z. Li, Q. Huang, X. Yang, Q. Chen, and L. Zhang, "Automatic Composition System Based on Transformer-XL", *Applied Sciences*, 14(13), 5765, 2024.
- [38] A. Gómez de Silva Garza, and E. Herrera González, "Music Style Analysis Using the Random Forest Algorithm", In *DS 73-2 Proceedings of the 2nd International conference on Design Creativity*, 2, 343-350, 2012.
- [39] C. Wang, and X. Geng, "Simulation of music style classification model based on support vector machine algorithm", In *Sixth International Conference on Intelligent Computing, Communication, and Devices (ICCD 2023)*, SPIE, 12703, 266-272, 2023.
- [40] M. Xiang, "Music Vocal Spectrum Classification Model based on Improved SVM Algorithm", In *2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS)*, IEEE, 1244-1247, 2022.
- [41] E. Egivenia, G. Ryanie Setiawan, S. Shania Mintara, and D. Suhartono, "Classification of explicit music content based on lyrics, music metadata, and user annotation", In *Proceedings of the 6th International Conference on Sustainable Information Engineering and Technology*, 265-270, 2021.
- [42] X. Wang, "Research on recognition and classification of folk music based on feature extraction algorithm", *Informatica*, 44(4), 2020.
- [43] B. A. Achar, N. D. Aiyappa, B. Akshaj, M. N. Thippeswamy, and N. Pillay, "Activity-Based Music Classifier: A Supervised Machine Learning Approach for Curating Activity-Based Playlists", In *Emerging Research in Computing, Information, Communication and Applications: ERCICA 2018*, 2, 185-198, 2019.
- [44] F. Mahardhika, H. L. H. S. Warnars, and Y. Heryadi, "Indonesian's dangdut music classification based on audio features", In *2018 Indonesian association for pattern recognition international conference (INAPR)*, IEEE, 99-103, 2018.
- [45] B. K. Khonglah, and S. M. Prasanna, "Speech/music classification using vocal tract constriction aspect of speech", In *2015 Annual IEEE India Conference (INDICON)*, IEEE, 1-6, 2015.
- [46] C. Lim, and J. H. Chang, "Enhancing support vector machine-based speech/music classification using conditional maximum a posteriori criterion", *IET signal processing*, 6(4), 335-340, 2012.
- [47] C. Lim, S. R. Lee, and J. H. Chang, "Efficient implementation of an SVM-based speech/music classifier by enhancing temporal locality in support vector references", *IEEE Transactions on Consumer Electronics*, 58(3), 898-904, 2012.
- [48] Y. Yuan, and J. Liu, "Music Classification and Identification Based on Convolutional Neural Network", *Computer-Aided Design and Applications*, 21(S18), 205-221, 2024.
- [49] S. K. Mahanta, N. J. Basisth, E. Halder, A. F. U. R. Khilji, and P. Pakray, "Exploiting cepstral coefficients and CNN for efficient musical instrument classification", *Evolving Systems*, 1-13, 2023.
- [50] W. B. Zulfikar, Y. A. Gerhana, A. Y. P. Almi, D. S. A. Maylawati, and M. I. Al Amin, "Mood of Song Detection Using Mel Frequency Cepstral Coefficient and Convolutional Neural Network with Tuning Hyperparameter", In *2023 11th International Conference on Cyber and IT Service Management (CITSM)*, IEEE, 1-6, 2023.
- [51] W. Peng, Y. Tang, and Y. Ouyang, "Design of Computer-Aided Music Generation Model Based on Artificial Intelligence Algorithm", In *International Conference on Computational Finance and Business Analytics*, Cham: Springer Nature Switzerland, 229-237, 2023.
- [52] S. Li, and Y. Sung, "MelodyDiffusion: chord-conditioned melody generation using a transformer-based diffusion model", *Mathematics*, 11(8), 1915, 2023.
- [53] J. Zhang, "Music feature extraction and classification algorithm based on deep learning", *Scientific Programming*, 2021(1), 1651560, 2021.

- technique”, In *Networking Communication and Data Knowledge Engineering*, Springer Singapore, 1, 267-278, 2018.
- [88] H. Y. Chang, S. C. Huang, and J. H. Wu, “A personalized music recommendation system based on electroencephalography feedback”, *Multimedia Tools and Applications*, 76, 19523-19542, 2017.
- [89] J. Chen, Y. Liu, and D. Li, “Dynamic group recommendation with modified collaborative filtering and temporal factor”, *Int. Arab J. Inf. Technol.*, 13(2), 294-301, 2016.
- [90] H. Magadam, H. K. Azad, and H. Patel, “Music recommendation using dynamic feedback and content-based filtering”, *Multimedia Tools and Applications*, 1-20, 2024.
- [91] J. Patel, A. A. Padaria, A. Mehta, A. Chokshi, J. D. Patel, and R. Kapdi, “ConCollA-A Smart Emotion-based Music Recommendation System for Drivers”, *Scalable Computing: Practice and Experience*, 24(4), 919-939, 2023.
- [92] Y. Mao, G. Zhong, H. Wang, and K. Huang, “Music-CRN: An efficient content-based music classification and recommendation network”, *Cognitive Computation*, 14(6), 2306-2316, 2022.
- [93] A. Niyazov, E. Mikhailova, and O. Egorova, “Content-based music recommendation system”, In *2021 29th Conference of Open Innovations Association (FRUCT)*, IEEE, 274-279, 2021.
- [94] N. Yadav, A. Kumar Singh, and S. Pal, “Improved self-attentive Musical Instrument Digital Interface content-based music recommendation system”, *Computational Intelligence*, 38(4), 1232-1257, 2022.
- [95] M. Garanayak, S. K. Nayak, K. Sangeetha, T. Choudhury, and S. Shitharth, “Content and Popularity-Based Music Recommendation System”, *International Journal of Information System Modeling and Design (IJISMD)*, 13(7), 1-14, 2022.
- [96] F. Narducci, M. De Gemmis, and P. Lops, “A general architecture for an emotion-aware content-based recommender system”, In *Proceedings of the 3rd Workshop on Emotions and Personality in Personalized Systems*, 3-6, 2015.
- [97] M. Soleymani, A. Aljanaki, F. Wiering, and R. C. Veltkamp, “Content-based music recommendation using underlying music preference structure” In *2015 IEEE international conference on multimedia and expo (ICME)*, IEEE, 1-6, 2015.
- [98] B. Stasiak, and M. Papiernik, “Melody-based approaches in music retrieval and recommendation systems”, In *Multimedia Services in Intelligent Environments: Recommendation Services*, Heidelberg: Springer International Publishing, 125-153, 2013.
- [99] D. Bogdanov, M. Haro, F. Fuhrmann, A. Xambó, E. Gómez, and P. Herrera, “Semantic audio content-based music recommendation and visualization based on user preference examples”, *Information Processing & Management*, 49(1), 13-33, 2013.
- [100] D. Bogdanov, and H. Boyer, “How much metadata do we need in music recommendation?: A subjective evaluation using preference sets”, In Klapuri A, Leider C, editors. *12th International Society for Music Information Retrieval Conference (ISMIR 2011)*; 2011 Oct 24-28; Miami, USA. Montréal: ISMIR; 2011. p. 97-102. International Society for Music Information Retrieval (ISMIR), 2011.
- [101] G. B. Mohan, R. P. Kumar, S. Korravi, M. Harshitha, B. S. S. Chaithanya, K. Saiteja, and G. V. Rohan, “Emotion-Based Music Recommendation System-A Deep Learning Approach”, In *2024 Second International Conference on Emerging Trends in Information Technology and Engineering (ICETITE)*, IEEE, 1-7, 2024.
- [102] C. Li, and X. Zuo, “Classical music recommendation algorithm on art market audience expansion under deep learning”, *Journal of Intelligent Systems*, 33(1), 20230351, 2024.
- [70] P. Kaushik, S. P. S. Rathore, K. Chahal, S. Saraf, G. S. Chauhan, and P. Kumar, “RhythmQuest: Unifying Indian Music Classification and Prediction with Hybrid Deep Learning Techniques”, In *2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI)*, IEEE, 2, 1-6, 2024.
- [71] M. Ashraf, F. Abid, I. U. Din, J. Rasheed, M. Yesiltepe, S. F. Yeo, and M. T. Ersoy, “A hybrid cnn and rnn variant model for music classification”, *Applied Sciences*, 13(3), 1476, 2023.
- [72] J. Wang, “Research on the Integration Path of College Vocal Music Teaching and Traditional Music Culture Based on Deep Learning”, *Applied Mathematics and Nonlinear Sciences*, 2023.
- [73] J. Dai, “Intelligent Music Style Classification System Based on K-Nearest Neighbor Algorithm and Artificial Neural Network”, In *2022 IEEE International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)*, IEEE, 531-543, 2022.
- [74] Y. Yi, X. Zhu, Y. Yue, and W. Wang, “Music genre classification with LSTM based on time and frequency domain features”, In *2021 IEEE 6th International Conference on Computer and Communication Systems (ICCCS)*, IEEE, 678-682, 2021.
- [75] M. Ashraf, G. Geng, X. Wang, F. Ahmad, and F. Abid, “A globally regularized joint neural architecture for music classification”, *IEEE Access*, 8, 220980-220989, 2020.
- [76] C. Chen, and Q. Li, “A multimodal music emotion classification method based on multifeature combined network classifier”, *Mathematical Problems in Engineering*, 2020(1), 4606027, 2020.
- [77] H. Tang, and N. Chen, “Combining CNN and broad learning for music classification”, *IEICE TRANSACTIONS on Information and Systems*, 103(3), 695-701, 2020.
- [78] Q. D. A. P. Bayu, S. Suyanto, and A. Arifianto, “Hierarchical SVM-kNN to classify music emotion”, In *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 5-10, 2019.
- [79] C. Wu, “Music Therapy Music Selection Based on Big Data Analysis”, *Applied Mathematics and Nonlinear Sciences*, 9(1), 2024.
- [80] C. Yin, “Application of Recommendation Algorithms Based on Social Relationships and Behavioral Characteristics in Music Online Teaching”, *International Journal of Web-Based Learning and Teaching Technologies (IJWLTT)*, 19(1), 1-18, 2024.
- [81] H. Chen, “Music Transcription Based on Deep Learning”, *Proceedings of 2023 International Conference on New Trends in Computational Intelligence, NTCI 2023*, 62–65, 2024.
- [82] L. Tian, and F. Liu, “Design of Music Heritage Database System Based on Collaborative Filtering Algorithm”, In *Advances in Artificial Intelligence, Big Data and Algorithms*, IOS Press, 438-443, 2023.
- [83] Y. Niu, “Collaborative Filtering-Based Music Recommendation in Spark Architecture”, *Mathematical Problems in Engineering*, 2022(1), 9050872, 2022.
- [84] J. Sun, “Personalized music recommendation algorithm based on spark platform”, *Computational Intelligence and Neuroscience*, 2022(1), 7157075, 2022.
- [85] M. Lu, and F. Deng, “[Retracted] Application of Collaborative Filtering and Data Mining Technology in Personalized National Music Recommendation and Teaching”, *Security and Communication Networks*, 2021(1), 3140341, 2021.
- [86] Ning, Hui, Li, Qian, “Personalized Music Recommendation Simulation Based on Improved Collaborative Filtering Algorithm”, *Complexity*, 6643888, 2020.
- [87] M. Sunitha, and T. Adilakshmi, “Music recommendation system with user-based and item-based collaborative filtering

- [120] A. Vall, M. Skowron, P. Knees, and M. Schedl, "Improving Music Recommendations with a Weighted Factorization of the Tagging Activity", In ISMIR, 65-71, 2015.
- [121] M. S. Reddy, and T. Adilakshmi, "Music recommendation system based on matrix factorization technique-SVD", In 2014 international conference on computer communication and informatics, IEEE, 1-6, 2014.
- [122] S. V. Reddy, V. R. Krishna, R. J. Sapkal, J. Dhanke, S. P. Waghmare, and K. Kumar, "A cutting-edge artificial intelligence paradigm for entertainment-infused music recommendations", Entertainment Computing, 51, 100717, 2024.
- [123] S. Mukhopadhyay, A. Kumar, D. Parashar, and M. Singh, "Enhanced Music Recommendation Systems: A Comparative Study of Content-Based Filtering and K-Means Clustering Approaches", Revue d'Intelligence Artificielle, 38(1), 2024.
- [124] M. Nuo, X. Han, and Y. Zhang, "Contrastive learning-based music recommendation model", In International Conference on Neural Information Processing, Singapore: Springer Nature Singapore, 370-382, 2023.
- [125] V. Omowonuola, B. Wilkerson, and S. Kher, "Hybrid Context-Content Based Music Recommendation System", In Proceedings of the Future Technologies Conference, Cham: Springer International Publishing, 121-132, 2022.
- [126] J. P. Verma, P. Bhattacharya, A. S. Rathor, J. Shah, and S. Tanwar, "Collaborative filtering-based music recommendation in view of negative feedback system", In Proceedings of Third International Conference on Computing, Communications, and Cyber-Security: IC4S 2021, Singapore: Springer Nature Singapore, 447-460, 2022.
- [127] T. Zhang, and S. Liu, "[Retracted] Hybrid Music Recommendation Algorithm Based on Music Gene and Improved Knowledge Graph", Security and Communication Networks, 2022(1), 5889724, 2022.
- [128] P. Magron, and C. Févotte, "Neural content-aware collaborative filtering for cold-start music recommendation", Data Mining and Knowledge Discovery, 36(5), 1971-2005, 2022.
- [129] J. Singh, and V. K. Bohat, "Neural network model for recommending music based on music genres", In 2021 International Conference on Computer Communication and Informatics (ICCCI), IEEE, 1-6, 2021.
- [130] M. Pulis, and J. Bajada, "Siamese Neural Networks for Content-based Cold-Start Music Recommendation", In Proceedings of the 15th ACM Conference on Recommender Systems, 719-723, 2021.
- [131] A. N. Arnold, and S. Vairamuthu, "Music recommendation using collaborative filtering and deep learning", Int. J. Innov. Technol. Explor. Eng. (IJITEE), 8(7), 964-968, 2019.
- [132] F. Fessahaye, L. Perez, T. Zhan, R. Zhang, C. Fossier, R. Markarian, ... and P. Oh, "T-recsys: A novel music recommendation system using deep learning", In 2019 IEEE international conference on consumer electronics (ICCE), IEEE, 1-6, 2019.
- [133] D. Ayata, Y. Yaslan, and M. E. Kamasak, "Emotion based music recommendation system wearable physiological sensors", IEEE transactions on consumer electronics, 64(2), 196-203, 2018.
- [134] P. Darshna, "Music recommendation based on content and collaborative approach & reducing cold start problem", In 2018 2nd international conference on inventive systems and control (ICISC), IEEE, 1033-1037, 2018.
- [135] J. H. Su, W. Y. Chang, and V. S. Tseng, "Effective social content-based collaborative filtering for music recommendation", Intelligent Data Analysis, 21(S1), S195-S216, 2017.
- [136] D. Sánchez-Moreno, A. B. G. González, M. D. M. Vicente, V. F. L. Batista, and M. N. M. García, "A collaborative filtering method for music recommendation using playing coefficients for
- [103] H. Liu, and C. Zhao, "A Deep Learning Algorithm for Music Information Retrieval Recommendation System", Computer-Aided Design and Applications, 21(S13), 1-16, 2024.
- [104] N. Narkhede, S. Mathur, A. Bhaskar, and M. Kalla, M, "Music genre classification and recognition using convolutional neural network", Multimedia Tools and Applications, 1-16, 2024.
- [105] A. Kumble, S. Medatati, and A. Bhatt, "Emotion-Based Music Recommendation", In International Conference on Advanced Computational and Communication Paradigms, Singapore: Springer Nature Singapore, 147-155, 2023.
- [106] C. Kumar, M. Kumar, and A. Jindal, "Session-based song recommendation using recurrent neural network", In Machine Intelligence Techniques for Data Analysis and Signal Processing: Proceedings of the 4th International Conference MISIP 2022, Singapore: Springer Nature Singapore, 1, 719-728, 2023.
- [107] P. Linlin, "Tchaikovsky music recommendation algorithm based on deep learning", Mobile Information Systems, 2022(1), 1265451, 2022.
- [108] J. Xia, "Construction and implementation of music recommendation model utilising deep learning artificial neural network and mobile edge computing", International journal of grid and utility computing, 13(2-3), 183-194, 2022.
- [109] H. Gao, "Automatic recommendation of online music tracks based on deep learning", Mathematical Problems in Engineering, 2022(1), 5936156, 2022.
- [110] S. Wang, C. Xu, A. S. Ding, and Z. Tang, "A novel emotion-aware hybrid music recommendation method using deep neural network", Electronics, 10(15), 1769, 2021.
- [111] J. W. Chang, C. Y. Chiou, J. Y. Liao, Y. K. Hung, C. C. Huang, K. C. Lin, and Y. H. Pu, "Music recommender using deep embedding-based features and behavior-based reinforcement learning", Multimedia Tools and Applications, 1-28, 2021.
- [112] L. Danyang, and G. Mingxin, "Music Recommendation Method Based on Multi-Source Information Fusion". Data Analysis and Knowledge Discovery, 5(2), 94-105, 2021.
- [113] S. R. Chavare, C. J. Awati, and S. K. Shirgave, "Smart recommender system using deep learning", In 2021 6th international conference on inventive computation technologies (ICICT), IEEE, 590-594, 2021.
- [114] S. Joshi, T. Jain, and N. Nair, "Emotion based music recommendation system using LSTM-CNN architecture", In 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT), IEEE, 01-06, 2021.
- [115] A. Elbir, and N. Aydin, "Music genre classification and music recommendation by using deep learning", Electronics Letters, 56(12), 627-629, 2020.
- [116] A. Ferraro, D. Bogdanov, J. Yoon, K. Kim, and X. Serra, X. "Automatic playlist continuation using a hybrid recommender system combining features from text and audio", In Proceedings of the ACM Recommender Systems Challenge, 1-5, 2018.
- [117] H. T. Zheng, J. Y. Chen, N. Liang, A. K. Sangaiah, Y. Jiang, and C. Z. Zhao, "A deep temporal neural music recommendation model utilizing music and user metadata", Applied Sciences, 9(4), 703, 2019.
- [118] S. Oramas, O. Nieto, M. Sordo, and X. Serra. "A deep multimodal approach for cold-start music recommendation", In Proceedings of the 2nd workshop on deep learning for recommender systems, 32-37, 2017.
- [119] A. H. Nabizadeh, A. M. Jorge, S. Tang, and Y. Yu, "Predicting user preference based on matrix factorization by exploiting music attributes", In Proceedings of the ninth international c* conference on computer science & software engineering, 61-66, 2016.

- [152] H. Liu, L. Xie, J. Wu, and G. Yang, "Channel-wise subband input for better voice and accompaniment separation on high resolution music", arXiv preprint arXiv:2008.05216, 2020.
- [153] C. Lordelo, E. Benetos, S. Dixon, S. Ahlback, and P. Ohlsson, "Adversarial unsupervised domain adaptation for harmonic-percussive source separation", IEEE Signal Processing Letters, 28, 81-85, 2020.
- [154] B. Bhattarai, Y. R. Pandeya, and J. Lee, "Parallel stacked hourglass network for music source separation", IEEE Access, 8, 206016-206027, 2020
- [155] V. S. Kadandale, J. F. Montesinos, G. Haro, and E. Gómez, "Multi-channel u-net for music source separation", In 2020 IEEE 22nd international workshop on multimedia signal processing (MMSP), IEEE, 1-6, 2020.
- [156] E. Manilow, G. Wichern, P. Seetharaman, and J. Le Roux, "Cutting music source separation some Slakh: A dataset to study the impact of training data quality and quantity", In 2019 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA), IEEE, 45-49, 2019.
- [157] O. Slizovskaia, L. Kim, G. Haro, and E. Gomez, "End-to-end sound source separation conditioned on instrument labels", In ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 306-310, 2019.
- [158] P. Seetharaman, G. Wichern, S. Venkataramani, and J. Le Roux, "Class-conditional embeddings for music source separation", In ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 301-305, 2019.
- [159] F. Lluís, J. Pons, and X. Serra, "End-to-end music source separation: Is it possible in the waveform domain?", Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 2019-September, 4619-4623, 2018.
- [160] R. Kumar, Y. Luo, and N. Mesgarani, "Music Source Activity Detection and Separation Using Deep Attractor Network", In Interspeech, 347-351, 2018.
- [161] Z. C. Fan, Y. L. Lai, and J. S. R. Jang, "SVSGAN: singing voice separation via generative adversarial network", In 2018 IEEE international conference on acoustics, speech and signal processing (ICASSP), IEEE, 726-730, 2018.
- [162] Y. Luo, Z. Chen, J. R. Hershey, J. Le Roux, and N. Mesgarani, "Deep clustering and conventional networks for music separation: Stronger together", In 2017 IEEE international conference on acoustics, speech and signal processing (ICASSP), IEEE, 61-65, 2017.
- [163] P. Chandna, M. Miron, J. Janer, and E. Gómez, "Monoaural audio source separation using deep convolutional neural networks", In Latent Variable Analysis and Signal Separation: 13th International Conference, LVA/ICA 2017, Grenoble, France, February 21-23, 2017, Proceedings 13, Springer International Publishing, 258-266, 2017.
- [164] M. Miron, J. Janer Mestres, and E. Gómez Gutiérrez, "Generating data to train convolutional neural networks for classical music source separation", In Lokki T, Pätynen J, Välimäki V, editors. Proceedings of the 14th Sound and Music Computing Conference; 2017 Jul 5-8; Espoo, Finland. Aalto: Aalto University, 227-33, 2017.
- [165] S. I. Mimilakis, K. Drossos, T. Virtanen, and G. Schuller, G. "A recurrent encoder-decoder approach with skip-filtering connections for monaural singing voice separation", In 2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP), IEEE, 1-6, 2017.
- [166] M. Miron, J. Janer Mestres, and E. Gómez Gutiérrez, "Monaural score-informed source separation for classical music using convolutional neural networks", In Hu X, Cunningham SJ, artists and users", Expert Systems with Applications, 66, 234-244, 2016.
- [137] R. Cheng, and B. Tang, "A music recommendation system based on acoustic features and user personalities", In Trends and Applications in Knowledge Discovery and Data Mining: PAKDD 2016 Workshops, BDM, MLSDA, PACC, WDMBF, Auckland, New Zealand, April 19, 2016, Revised Selected Papers, Springer International Publishing, 20, 203-213, 2016.
- [138] X. Wang, and Y. Wang, "Improving content-based and hybrid music recommendation using deep learning", In Proceedings of the 22nd ACM international conference on Multimedia, 627-636, 2014.
- [139] J. Kim, K. Kim, K. H. You, and J. H. Lee, "An approach for music recommendation using content-based analysis and collaborative filtering", International Information Institute (Tokyo), Information, 15(5), 1985, 2012.
- [140] C. Musto, G. Semeraro, P. Lops, M. De Gemmis, and F. Narducci, "Leveraging social media sources to generate personalized music playlists", In E-Commerce and Web Technologies: 13th International Conference, EC-Web 2012, Vienna, Austria, September 4-5, 2012. Proceedings 13, Springer Berlin Heidelberg, 112-123, 2012.
- [141] N. Hariri, B. Mobasher, and R. Burke, "Using social tags to infer context in hybrid music recommendation", In Proceedings of the twelfth international workshop on Web information and data management, 41-48, 2012.
- [142] G. Richard, P. Chouteau, and B. Torres, "A fully differentiable model for unsupervised singing voice separation", In ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 946-950, 2024.
- [143] T. Zhang, "Application of Unet-SE-Bisru Algorithm for Music Signal Processing in Music Source Separation", Scalable Computing: Practice and Experience, 25(4), 2960-2972, 2024.
- [144] M. Schwabe, and M. Heizmann, "Improved Separation of Polyphonic Chamber Music Signals by Integrating Instrument Activity Labels", IEEE Access, 11, 42999-43007, 2023.
- [145] K. Schulze-Forster, G. Richard, L. Kelley, C. S. Doire, and R. Badeau, "Unsupervised music source separation using differentiable parametric source models", IEEE/ACM Transactions on Audio, Speech, and Language Processing, 31, 1276-1289, 2023.
- [146] Y. Zhu, K. Olszewski, Y. Wu, P. Achlioptas, M. Chai, Y. Yan, and S. Tulyakov, "Quantized gan for complex music generation from dance videos", In European Conference on Computer Vision, Cham: Springer Nature Switzerland, 182-199, 2022.
- [147] J. Luo, X. Yang, S. Ji, and J. Li, "MG-VAE: deep Chinese folk songs generation with specific regional styles", In Proceedings of the 7th Conference on Sound and Music Technology (CSMT) Revised Selected Papers, Springer Singapore, 93-106, 2020.
- [148] R. Zhang, J. Bai, X. Guan, and Q. Li, "Music Source Separation Method Based on Unet Combining SE and BiSRU", Huanan Ligong Daxue Xuebao/Journal of South China University of Technology (Natural Science), 49(11), 2021.
- [149] T. P. Chen, and L. Su, "Attend to Chords: Improving Harmonic Analysis of Symbolic Music Using Transformer-Based Models", Trans. Int. Soc. Music. Inf. Retr., 4(1), 1-13, 2021.
- [150] H. S. Choi, J. Lee, and K. Lee, "Spec2spec: Towards the general framework of music processing using generative adversarial networks", Acoustical Science and Technology, 41(1), 160-165, 2020.
- [151] S. Tahmasebi, T. Gajęcki, and W. Nogueira, "Design and evaluation of a real-time audio source separation algorithm to remix music for cochlear implant users, 2020, Frontiers in Neuroscience, 14, 434, 2020.

- [182] S. Kolozali, M. Barthet, G. Fazekas, and M. Sandler, "Automatic ontology generation for musical instruments based on audio analysis", *IEEE transactions on audio, speech, and language processing*, 21(10), 2207-2220, 2013.
- [183] B. Bhattarai, and J. Lee, "Korean Pansori Vocal Note Transcription Using Attention-Based Segmentation and Viterbi Decoding". *Applied Sciences*, 14(2), 492, 2024.
- [184] E. Hulme, D. Marshall, K. Sidorov, and A. Jones, "Acoustic Classification of Guitar Tunings with Deep Learning", In *Proceedings of the 11th International Conference on Digital Libraries for Musicology*, 6-14, 2024.
- [185] D. Kozlov, M. Bakulin, S. Pavlov, A. Zuev, M. Krylova, and I. Kharchikov, "Learning Properties of Holomorphic Neural Networks of Dual Variables", In *ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 1-5, 2023.
- [186] M. Scarpiniti, E. Sigismondi, D. Commiello, and A. Uncini, "A U-Net Based Architecture for Automatic Music Transcription", In *2023 IEEE 33rd International Workshop on Machine Learning for Signal Processing (MLSP)*, IEEE, 1-6, 2023.
- [187] W. Huang, Y. Yu, H. Xu, Z. Su, and Y. Wu, "Hyperbolic music transformer for structured music generation", *IEEE Access*, 11, 26893-26905, 2023.
- [188] M. Zehren, M. Alunno, and P. Bientinesi, "High-quality and reproducible automatic drum transcription from crowdsourced data", *Signals*, 4(4), 768-787, 2023.
- [189] Y. Telila, T. Cucinotta, and D. Bacciu, "Automatic Music Transcription using Convolutional Neural Networks and Constant-Q Transform", In *Ital-IA*, 526-531, 2023.
- [190] R. Zheng, X. Liu, and M. D. Butala, "Multi-Instrument Polyphonic Melody Transcription Based on Deep Learning", In *2023 3rd International Conference on Consumer Electronics and Computer Engineering (ICCECE)*, IEEE, 762-767, 2023.
- [191] I. S. Wahbi, H. T. Bahbouh, and K. M. Yahia, "Transcription of Arabic and Turkish Music Using Convolutional Neural Networks", In *2023 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*, IEEE, 5, 1-5, 2023.
- [192] J. Park, K. Choi, S. Oh, L. Kim, and J. Park, "Note-level singing melody transcription with transformers", *Intelligent Data Analysis*, 27(6), 1853-1871, 2023.
- [193] Y. Wang, "Piano automatic transcription based on transformer", *Journal of Intelligent & Fuzzy Systems*, (Preprint), 1-8, 2023.
- [194] J. Zhou, T. Niu, H. Zhu, and X. Wang, "CoCoFormer: A controllable feature-rich polyphonic music generation method", In *Summit on Music Intelligence*, Singapore: Springer Nature Singapore, 95-107, 2023.
- [195] P. Li, T. Song, and J. Hu, "Audio classification based on audio WSOLA and CNN algorithm", In *Second International Conference on Electronic Information Technology (EIT 2023)*, SPIE, 12719, 1145-1149, 2023.
- [196] C. Gupta, H. Li, and M. Goto, "Deep learning approaches in topics of singing information processing", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 30, 2422-2451, 2022.
- [197] C. de la Fuente, J. J. Valero-Mas, F. J. Castellanos, and J. Calvo-Zaragoza, "Multimodal image and audio music transcription", *International Journal of Multimedia Information Retrieval*, 11(1), 77-84, 2022.
- [198] C. Weiß, and G. Peeters, "Comparing deep models and evaluation strategies for multi-pitch estimation in music recordings", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 30, 2814-2827, 2022.
- Turnbull D, Duan Z. *ISMIR 2017, 18th International Society for Music Information Retrieval Conference*, 2017 Oct 23-27, Suzhou, China, [Canada]: ISMIR, 55-62, 2017.
- [167] Y. Fang, and T. Gui-fa, "Visual music score detection with unsupervised feature learning method based on k-means", *International Journal of Machine Learning and Cybernetics*, 6, 277-287, 2015.
- [168] Y. Chen, and H. Zheng, "The application of HMM algorithm based music note feature recognition teaching in universities", *Intelligent Systems with Applications*, 20, 200277, 2023.
- [169] J. Calvo-Zaragoza, A. H. Toselli, and E. Vidal, "Hybrid hidden Markov models and artificial neural networks for handwritten music recognition in mensural notation", *Pattern Analysis and Applications*, 22, 1573-1584, 2019.
- [170] G. J. Mysore, P. Smaragdis, and B. Raj, "Non-negative hidden Markov modeling of audio with application to source separation", In *International Conference on Latent Variable Analysis and Signal Separation*, Berlin, Heidelberg: Springer Berlin Heidelberg, 140-148, 2010.
- [171] K. Siedenburg, M. R. Schädler, and D. Hülsmeier, "Modeling the onset advantage in musical instrument recognition", *The journal of the Acoustical Society of America*, 146(6), EL523-EL529, 2019.
- [172] C. Jeyalakshmi, B. Murugeswari, and M. Karthick, "HMM and K-NN based automatic musical instrument recognition", In *2018 2nd International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC) I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*, IEEE, 350-355, 2018.
- [173] J. Calvo-Zaragoza, A. H. Toselli, and E. Vidal, "Handwritten music recognition for mensural notation: Formulation, data and baseline results", In *2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR)*, IEEE, 1, 1081-1086, 2017.
- [174] J. Calvo-Zaragoza, A. H. Toselli, and E. Vidal, E, "Early handwritten music recognition with hidden markov models", In *2016 15th International Conference on Frontiers in Handwriting Recognition (ICFHR)*, IEEE, 319-324, 2016.
- [175] E. Nakamura, P. Cuvillier, A. Cont, N. Ono, and S. Sagayama, "Autoregressive hidden semi-Markov model of symbolic music performance for score following", In *16th International Society for Music Information Retrieval Conference (ISMIR)*, 2015.
- [176] A. S. Krishna, P. V. Rajkumar, K. P. Saishankar, and M. John, "Identification of carnatic raagas using hidden markov models", In *2011 IEEE 9th International Symposium on Applied Machine Intelligence and Informatics (SAMI)*, IEEE, 107-110, 2011.
- [177] J. T. Fang, and C. W. Yang, "SINGLE-CHANNEL MUSIC SOURCE SEPARATION BY HARMONIC STRUCTURE MODEL AND SUPPORT VECTOR MACHINE", *電機工程學刊*, 29(2), 43-51, 2022.
- [178] Y. Liao, H. Xu, and K. Xu, "MusicGAIL: A Generative Adversarial Imitation Learning Approach for Music Generation", In *CAAI International Conference on Artificial Intelligence*, Singapore: Springer Nature Singapore, 505-516, 2023.
- [179] F. C. A. Ferano, A. Zahra, and G. P. Kusuma, "Stacking ensemble learning for optical music recognition", *Bulletin of Electrical Engineering and Informatics*, 12(5), 3095-3104, 2023.
- [180] X. Pan, B. Song, C. Liu, and H. Zhang, "Music detecting and recording system based on support vector machine", In *2019 International Conference on Communications, Information System and Computer Engineering (CISCE)*, IEEE, 244-248, 2019.
- [181] D. Johnson, and G. Tzanetakis, "Guitar model recognition from single instrument audio recordings", In *2015 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing (PACRIM)*, IEEE, 370-375, 2015.

- Transcription Systems with a Two-State Pitch-Wise HMM Method", In ISMIR, 523-530, 2017.
- [215] A. McLeod, R. Schramm, M. Steedman, and E. Benetos, "Automatic transcription of polyphonic vocal music", *Applied Sciences*, 7(12), 1285, 2017.
- [216] D. Cazau, Y. Wang, M. Chemillier, and O. Adam, "An automatic music transcription system dedicated to the repertoires of the marovany zither", *Journal of New Music Research*, 45(4), 343-360, 2016.
- [217] E. Nakamura, K. Itoyama, and K. Yoshii, "Rhythm transcription of MIDI performances based on hierarchical Bayesian modelling of repetition and modification of musical note patterns", In 2016 24th European Signal Processing Conference (EUSIPCO), IEEE, 1946-1950, 2016.
- [218] D. Cazau, G. Revillon, J. Krywyk, and O. Adam, "An investigation of prior knowledge in Automatic Music Transcription systems", *The Journal of the Acoustical Society of America*, 138(4), 2561-2573, 2015.
- [219] E. Benetos, and T. Weyde, "Explicit duration hidden markov models for multiple-instrument polyphonic music transcription", 2013.
- [220] Y. K. Suprpto, and Y. Triwidayastuti, "Saron music transcription based on rhythmic information using hmm on gamelan orchestra", *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 13(1), 103-117, 2015.
- [221] E. Benetos, and S. Dixon, "A shift-invariant latent variable model for automatic music transcription", *Computer Music Journal*, 36(4), 81-94, 2012.
- [222] C. T. Lee, Y. H. Yang, and H. H. Chen, "Multipitch estimation of piano music by exemplar-based sparse representation", *IEEE Transactions on Multimedia*, 14(3), 608-618, 2012.
- [223] M. Nakano, J. Le Roux, H. Kameoka, T. Nakamura, N. Ono, and S. Sagayama, "Bayesian nonparametric spectrogram modeling based on infinite factorial infinite hidden Markov model", In 2011 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA), IEEE, 325-328, 2011.
- [224] E. Benetos, and S. Dixon, "Joint multi-pitch detection using harmonic envelope estimation for polyphonic music transcription", *IEEE Journal of Selected Topics in Signal Processing*, 5(6), 1111-1123, 2011.
- [225] F. J. Cañadas Quesada, N. Ruiz Reyes, P. Vera Candeas, J. J. Carabias, and S. Maldonado, "A multiple-F0 estimation approach based on Gaussian spectral modelling for polyphonic music transcription", *Journal of New Music Research*, 39(1), 93-107, 2010.
- [226] M. Akbari, J. Liang, and H. Cheng, "A real-time system for online learning-based visual transcription of piano music", *Multimedia tools and applications*, 77, 25513-25535, 2018.
- [227] I. Barbancho, G. Tzanetakis, A. M. Barbancho, and L. J. Tardón, "Discrimination between ascending/descending pitch arpeggios", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 26(11), 2194-2203, 2018.
- [228] M. Fujieda, T. Murakami, and Y. Ishida, "An approach to multi-pitch estimation using a support vector machine", *International Journal of Computers and Applications*, 33(3), 202-210, 2011.
- [229] A. Tjahyanto, Y. K. Suprpto, M. H. Purnomo, and D. P. Wulandari, "Fft-based features selection for javanese music note and instrument identification using support vector machines", In 2012 IEEE International Conference on Computer Science and Automation Engineering (CSAE), IEEE, 1, 439-443, 2012.
- [230] J. Mycka, A. Żychowski, and J. Mańdziuk, "Toward human-level tonal and modal melody harmonizations", *Journal of Computational Science*, 67, 101963, 2023.
- [231] A. Wiafe, C. Nutrokor, E. Owusu, F. A. Kastriku, and I. Wiafe, "Using genetic algorithms for music composition: implications
- [199] H. Cuesta, and E. Gómez Gutiérrez, "Voice assignment in vocal quartets using deep learning models based on pitch salience", *Transactions of the International Society for Music Information Retrieval*, 5(1), 99-112, 2022.
- [200] D. Stefani, S. Peroni, and L. Turchet, L. "A comparison of deep learning inference engines for embedded real-time audio classification", In *Proceedings of the International Conference on Digital Audio Effects, DAFx, MDPI (Multidisciplinary Digital Publishing Institute)*, 3, 256-263, 2022.
- [201] C. Hernandez-Olivan, I. Zay Pinilla, C. Hernandez-Lopez, and J. R. Beltran, "A comparison of deep learning methods for timbre analysis in polyphonic automatic music transcription", *Electronics*, 10(7), 810, 2021.
- [202] F. Simonetta, S. Ntalampiras, and F. Avanzini, "Audio-to-score alignment using deep automatic music transcription", In 2021 IEEE 23rd International Workshop on Multimedia Signal Processing (MMSP), IEEE, 1-6, 2021.
- [203] P. Steiner, A. Jalalvand, S. Stone, and P. Birkholz, "Feature engineering and stacked echo state networks for musical onset detection", In 2020 25th International Conference on Pattern Recognition (ICPR), IEEE, 9537-9544, 2021.
- [204] X. Li, K. Wang, J. Soraghan, and J. Ren, "Fusion of Hilbert-Huang transform and deep convolutional neural network for predominant musical instruments recognition", In *Artificial Intelligence in Music, Sound, Art and Design: 9th International Conference, EvoMUSART 2020, Held as Part of EvoStar 2020, Seville, Spain, April 15-17, 2020, Springer International Publishing, Proceedings 9*, 80-89, 2020.
- [205] E. Demirel, S. Ahlbäck, and S. Dixon, "Automatic lyrics transcription using dilated convolutional neural networks with self-attention", In 2020 International Joint Conference on Neural Networks (IJCNN), IEEE, 1-8, 2020.
- [206] Y. T. Wu, B. Chen, and L. Su, "Multi-instrument automatic music transcription with self-attention-based instance segmentation", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 28, 2796-2809, 2020.
- [207] D. Yu, H. Duan, J. Fang, and B. Zeng, "Predominant instrument recognition based on deep neural network with auxiliary classification", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 28, 852-861, 2020.
- [208] D. Stoller, S. Durand, and S. Ewert, "End-to-end lyrics alignment for polyphonic music using an audio-to-character recognition model", In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 181-185, 2019.
- [209] C. D. Carthen, V. Le, R. Kelley, T. J. Kozubowski, and F. C. Harris Jr, "Rewind: An Automatic Music Transcription Web Application", *INTERNATIONAL JOURNAL OF COMPUTERS AND THEIR APPLICATIONS*, 20, 2017.
- [210] G. Burlet, and A. Hindle, "Isolated guitar transcription using a deep belief network", *PeerJ Computer Science*, 3, e109, 2017.
- [211] S. Sigtia, E. Benetos, and S. Dixon, "An end-to-end neural network for polyphonic piano music transcription", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 24(5), 927-939, 2016.
- [212] Y. Ojima, E. Nakamura, K. Itoyama, and K. Yoshii, "Chord-aware automatic music transcription based on hierarchical Bayesian integration of acoustic and language models", *APSIPA Transactions on Signal and Information Processing*, 7, e14, 2018.
- [213] E. Nakamura, E. Benetos, K. Yoshii, and S. Dixon, "Towards complete polyphonic music transcription: Integrating multi-pitch detection and rhythm quantization", In 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 101-105, 2018.
- [214] D. Cazau, Y. Wang, O. Adam, Q. Wang, and G. Nuel, "Improving Note Segmentation in Automatic Piano Music

- [245] Y. Bai, "A music generation model based on Bi-LSTM", In International Conference on Algorithm, Imaging Processing, and Machine Vision (AIPMV 2023), 12969, 430-435, 2024.
- [246] J. Li, L. Han, X. Wang, Y. Wang, J. Xia, Y. Yang, ... and H. Yan, "A hybrid neural network model based on optimized margin softmax loss function for music classification", *Multimedia Tools and Applications*, 83(15), 43871-43906, 2024.
- [247] F. Li, "Chord-based music generation using long short-term memory neural networks in the context of artificial intelligence", *The Journal of Supercomputing*, 80(5), 6068-6092, 2024.
- [248] A. Kasif, S. Sevgen, A. Ozcan, and C. Catal, "Hierarchical multi-head attention LSTM for polyphonic symbolic melody generation", *Multimedia Tools and Applications*, 83(10), 30297-30317, 2024.
- [249] Z. Zhang, Y. Yu, and A. Takasu, "Controllable lyrics-to-melody generation", *Neural Computing and Applications*, 35(27), 19805-19819, 2023.
- [250] M. N. Mohanty, V. Tripathy, and R. K. Pattanaik, "Music Regeneration with RNN Architecture Using LSTM", In 2023 International Conference in Advances in Power, Signal, and Information Technology (APSIT), IEEE, 538-542, 2023.
- [251] C. Shen, V. Z. Yao, and Y. Liu, "Everybody Compose: Deep Beats To Music", In Proceedings of the 14th Conference on ACM Multimedia Systems, 353-357, 2023.
- [252] H. Bihani, S. Bothe, A. Acharya, T. Desai, and P. Joglekar, "Automatic Music Melody Generation Using LSTM and Markov Chain Model", In International Conference on Information and Communication Technology for Intelligent Systems, 249-257, 2023.
- [253] P. Gupta, and P. Dwivedi, "Advancements in Music Generation: Leveraging RNN and LSTM Networks for Automated Composition", In 2023 2nd International Conference on Automation, Computing and Renewable Systems (ICACRS), IEEE, 434-439, 2023.
- [254] S. S. Patil, S. H. Patil, A. M. Pawar, R. Shandilya, A. K. Kadam, R. B. Jadhav, and M. S. Bewoor, "Music Generation Using RNN-LSTM with GRU", In 2023 International Conference on Integration of Computational Intelligent System (ICICIS), IEEE, 1-5, 2023.
- [255] G. Keerti, A. N. Vaishnavi, P. Mukherjee, A. S. Vidya, G. S. Sreenithya, and D. Nayab, "Attentional networks for music generation", *Multimedia Tools and Applications*, 81(4), 5179-5189, 2022.
- [256] J. Pan, S. Yu, Z. Zhang, Z. Hu, and M. Wei, "The Generation of Piano Music Using Deep Learning Aided by Robotic Technology", *Computational Intelligence and Neuroscience*, 2022(1), 8336616, 2022.
- [257] C. De Boom, S. Van Laere, T. Verbelen, and B. Dhoedt, "Rhythm, chord and melody generation for lead sheets using recurrent neural networks", In Machine Learning and Knowledge Discovery in Databases: International Workshops of ECML PKDD 2019, Würzburg, Germany, September 16–20, 2019, Springer International Publishing, Proceedings, Part II, 454-461, 2020.
- [258] J. Singh, and A. Ratnawat, "Algorithmic Music Generation for the stimulation of Musical Memory in Alzheimer's", In 2018 4th International Conference on Computing Communication and Automation (ICCCA), IEEE, 1-4, 2018.
- [259] M. Pezzat-Morales, H. Perez-Meana, and T. Nakashika, "Fast Jukebox: Accelerating Music Generation with Knowledge Distillation", *Applied Sciences*, 13(9), 5630, 2023.
- [260] L. Comanducci, D. Gioiosa, M. Zanoni, F. Antonacci, and A. Sarti, "Variational Autoencoders for chord sequence generation conditioned on Western harmonic music complexity", *EURASIP Journal on Audio, Speech, and Music Processing*, 2023(1), 24, 2023.
- of early termination on aesthetic quality", *International Journal of Information Technology*, 14(4), 1875-1881, 2022.
- [232] O. Lopez-Rincon, O. Starostenko, and A. Lopez-Rincon, A. "Algorithmic music generation by harmony recombination with genetic algorithm", *Journal of Intelligent & Fuzzy Systems*, 42(5), 4411-4423, 2022.
- [233] M. Farzaneh, and R. Mahdian Toroghi, "Music generation using an interactive evolutionary algorithm", In Pattern Recognition and Artificial Intelligence: Third Mediterranean Conference, MedPRAI 2019, Istanbul, Turkey, December 22–23, 2019, Springer International Publishing, Proceedings 3, 207-217, 2020.
- [234] A. Papadopoulos, P. Roy, and F. Pachet, "Assisted lead sheet composition using flowcomposer", In Principles and Practice of Constraint Programming: 22nd International Conference, CP 2016, Toulouse, France, September 5-9, 2016, Springer International Publishing, Proceedings 22, 769-785, 2016.
- [235] D. M. Hofmann, "A genetic programming approach to generating musical compositions", In Evolutionary and Biologically Inspired Music, Sound, Art and Design: 4th International Conference, EvoMUSART 2015, Copenhagen, Denmark, April 8-10, 2015, Springer International Publishing, Proceedings 4, 89-100, 2015.
- [236] S. Chakrabarty, S. Roy, and D. De, "Pervasive diary in music rhythm education: a context-aware learning tool using genetic algorithm", In Advanced Computing, Networking and Informatics-Volume 1: Advanced Computing and Informatics Proceedings of the Second International Conference on Advanced Computing, Networking and Informatics (ICACNI-2014), Cham: Springer International Publishing, 669-677, 2014.
- [237] D. Matić, "A genetic algorithm for composing music", *Yugoslav Journal of Operations Research*, 20(1), 157-177, 2010.
- [238] S. Ji, X. Yang, J. Luo, and J. Li, "RI-chord: Clstm-based melody harmonization using deep reinforcement learning", *IEEE Transactions on Neural Networks and Learning Systems*, 2023.
- [239] D. R. Vemula, S. K. Tripathi, N. K. Sharma, M. M. Hussain, U. R. Swamy, B. L. Polavarapu, "Music Generation Using Deep Learning", In: Kumar Singh, K., Bajpai, M.K., Sheikh Akbari, A. (eds) Machine Vision and Augmented Intelligence. Lecture Notes in Electrical Engineering, Springer, Singapore, 1007, 2023.
- [240] M. Kopel, D. Antczak, and M. Walczyński, "Generating Music for Video Games with Real-Time Adaptation to Gameplay Pace", In Asian Conference on Intelligent Information and Database Systems, Singapore: Springer Nature Singapore, 261-272, 2023.
- [241] S. Banerjee, M. Rath, T. Swain, and Samant, T, "Music generation using time distributed dense stateful char-RNNs", In 2022 IEEE 7th International conference for Convergence in Technology (I2CT), 1-5, 2022.
- [242] S. Sajad, S. Dharshika, and M. Meleet, "Music generation for novices using Recurrent Neural Network (RNN)", In 2021 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSSES), IEEE, 1-6, 2021.
- [243] G. Hadjeres, and F. Nielsen, "Anticipation-RNN: Enforcing unary constraints in sequence generation, with application to interactive music generation", *Neural Computing and Applications*, 32(4), 995-1005, 2020.
- [244] K. Goel, R. Vohra, and J. K. Sahoo, "Polyphonic music generation by modeling temporal dependencies using a rnn-dbn", In Artificial Neural Networks and Machine Learning-ICANN 2014: 24th International Conference on Artificial Neural Networks, Hamburg, Germany, September 15-19, 2014. Springer International Publishing, Proceedings 24, 217-224, 2014.

- Global Conference on Consumer Electronics (GCCE), 1082-1083, 2023.
- [278] M. Araneda-Hernandez, F. Bravo-Marquez, D. Parra, and R. F. Cádiz, "MUSIB: musical score inpainting benchmark", *EURASIP Journal on Audio, Speech, and Music Processing*, 2023(1), 19, 2023.
- [279] X. Li, Y. Yan, J. Soraghan, Z. Wang, and J. Ren, "A music cognition-guided framework for multi-pitch estimation", *Cognitive computation*, 15(1), 23-35, 2023.
- [280] L. Xu, Y. Chen, and L. Zhang, "Intelligent Composition Based on Fibonacci Sequence and Hidden Markov Model", In *Proceedings of the 2023 International Conference on Computer, Vision and Intelligent Technology*, 1-6, 2023.
- [281] S. Ji, and X. Yang, "Emomusictv: Emotion-conditioned symbolic music generation with hierarchical transformer vae", *IEEE Transactions on Multimedia*, 26, 1076-1088, 2023.
- [282] S. Li, and Y. Sung, "INCO-GAN: variable-length music generation method based on inception model-based conditional GAN", *Mathematics*, 9(4), 387, 2021.
- [283] J. Huang, X. Huang, L. Yang, and Z. Tao, "Dance-Conditioned Artistic Music Generation by Creative-GAN", *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, 107(5), 836-844, 2024.
- [284] H. Wang, S. Hao, C. Zhang, X. Wang, and Y. Chen, "Motif transformer: Generating music with motifs", *IEEE Access*, 11, 63197-63204, 2023.
- [285] N. Imasato, K. Miyazawa, C. Duncan, and T. Nagai, "Using a language model to generate music in its symbolic domain while controlling its perceived emotion", *IEEE Access*, 11, 52412-52428, 2023.
- [286] G. Wu, S. Liu, and X. Fan, "The power of fragmentation: a hierarchical transformer model for structural segmentation in symbolic music generation", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 31, 1409-1420, 2023.
- [287] S. L. Wu, and Y. H. Yang, "MuseMorphose: Full-song and fine-grained piano music style transfer with one transformer VAE", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 31, 1953-1967, 2023.
- [288] L. Mou, Y. Sun, Y. Tian, Y. Sun, Y. Liu, Z. Zhang, ... and R. Jain, "MemoMusic 3.0: considering context at music recommendation and combining music theory at music generation", In *2023 IEEE International Conference on Multimedia and Expo Workshops (ICMEW)*, 296-301, 2023.
- [289] X. Wei, J. Chen, Z. Zheng, L. Guo, L. Li, and D. Wang, "A Multi-Scale Attentive Transformer for Multi-Instrument Symbolic Music Generation", *arXiv preprint arXiv, 2305.16592*, 2023.
- [290] J. Tang, L. Yin, and J. Yu, "Partially Trained Music Generation based on Transformer", In *2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, 1133-1138, 2023.
- [291] W. Huang, Y. Xue, Z. Xu, G. Peng, and Y. Wu, "Polyphonic music generation generative adversarial network with Markov decision process", *Multimedia Tools and Applications*, 81(21), 29865-29885, 2022.
- [292] S. Adkins, P. Sarmiento, and M. Barthet, "LooperGP: a loopable sequence model for live coding performance using guitarpro tablature", In *International Conference on Computational Intelligence in Music, Sound, Art and Design (Part of EvoStar)* Cham: Springer Nature Switzerland, 3-19, 2023.
- [293] P. Sarmiento, A. Kumar, Y. H. Chen, C. J. Carr, Z. Zukowski, and M. Barthet, "GTR-CTRL: instrument and genre conditioning for guitar-focused music generation with transformers", In *International Conference on Computational Intelligence in*
- [261] J. Gillick, J. Yang, C. E. Cella, and D. Bamman, "Drumroll Please: Modeling Multi-Scale Rhythmic Gestures with Flexible Grids", *Transactions of the International Society for Music Information Retrieval*, 4(1), 156-167, 2021.
- [262] Y. Q. Lim, C. S. Chan, and F. Y. Loo, "Style-conditioned music generation", In *2020 IEEE International Conference on Multimedia and Expo (ICME)*, IEEE, 1-6, 2020.
- [263] T. Wang, J. Liu, C. Jin, J. Li, and S. Ma, "An intelligent music generation based on Variational Autoencoder", In *2020 International Conference on Culture-oriented Science & Technology (ICCSST)*, IEEE, 394-398, 2020.
- [264] Z. Ziegler, and A. Rush, "Latent normalizing flows for discrete sequences", In *International Conference on Machine Learning*, PMLR, 7673-7682, 2019.
- [265] Y. A. Wang, Y. K. Huang, T. C. Lin, S. Y. Su, and Y. N. Chen, "Modeling melodic feature dependency with modularized variational auto-encoder", In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 191-195, 2019.
- [266] R. Yang, T. Chen, Y. Zhang, and G. Xia, "Inspecting and interacting with meaningful music representations using VAE", *Proceedings of the International Conference on New Interfaces for Musical Expression*, 307-312, 2019.
- [267] J. Kang, S. Poria, and D. Herremans, "Video2music: Suitable music generation from videos using an affective multimodal transformer model", *Expert Systems with Applications*, 249, 123640, 2024.
- [268] Y. Xin, "MusicEmo: transformer-based intelligent approach towards music emotion generation and recognition", *Journal of Ambient Intelligence and Humanized Computing*, 1-11, 2024.
- [269] P. Li, T. M. Liang, Y. M. Cao, X. M. Wang, X. J. Wu, and L. Y. Lei, "A novel Xi'an drum music generation method based on Bi-LSTM deep reinforcement learning", *Applied Intelligence*, 54(1), 80-94, 2024.
- [270] Y. Zhang, X. Lv, Q. Li, X. Wu, Y. Su, and H. Yang, "An automatic music generation method based on RSCLN_Transformer network", *Multimedia Systems*, 30(1), 4, 2024.
- [271] Q. Zhu, A. Shankar, and C. Maple, "Grey wolf optimizer based deep learning mechanism for music composition with data analysis", *Applied Soft Computing*, 153, 111294, 2024.
- [272] D. Dalmazzo, K. Déguernel, and B. L. Sturm, "The Chordinator: Modeling Music Harmony by Implementing Transformer Networks and Token Strategies", In *International Conference on Computational Intelligence in Music, Sound, Art and Design (Part of EvoStar)*, Cham: Springer Nature Switzerland, 52-66, 2024.
- [273] N. Venkatachalam, "MusiciAI: A Hybrid Generative Model for Music Therapy using Cross-Modal Transformer and Variational Autoencoder", In *2024 2nd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, IEEE, 1176-1180, 2024.
- [274] B. S. Krishna, S. S. R. S. Chiluvuri, S. S. H. Kosuri, and S. S. H. Chimbili, "The Application of Long Short-Term Memory and Transformers for Music Generation", In *2023 IEEE International Conference on Big Data (BigData)*, IEEE, 4475-4478, 2023.
- [275] W. Xu, J. McAuley, S. Dubnov, and H. W. Dong, "Equipping Pretrained Unconditional Music Transformers with Instrument and Genre Controls", In *2023 IEEE International Conference on Big Data (BigData)*, IEEE, 4512-4517, 2023.
- [276] S. Li, and Y. Sung, "Transformer-based seq2seq model for chord progression generation", *Mathematics*, 11(5), 1111, 2023.
- [277] B. Cao, T. Fukumori, and Y. Yamashita, "Multi-Instruments Music Generation Based on Chord Input", In *2023 IEEE 12th*

- [308] C. Donahue, H. H. Mao, Y. E. Li, G. W. Cottrell, and J. McAuley, "LakhNES: Improving multi-instrumental music generation with cross-domain pre-training", arXiv preprint arXiv:1907.04868, 2019.
- [309] L. Zheng, and C. Li, "Real-Time Emotion-Based Piano Music Generation using Generative Adversarial Network (GAN)", IEEE Access, 2024.
- [310] L. Chen, L. Shen, D. Yu, Z. Wang, K. Qian, B. Hu, ... and Y. Yamamoto, "Multi-Track Music Generation with WGAN-GP and Attention Mechanisms", In 2023 IEEE 12th Global Conference on Consumer Electronics (GCCE), 606-607, 2023.
- [311] G. Barnabò, G. Trappolini, L. Lastilla, C. Campagnano, A. Fan, F. Petroni, and F. Silvestri, "Cycledrums: automatic drum arrangement for bass lines using cyclegan", Discover Artificial Intelligence, 3(1), 4, 2023.
- [312] D. Tian, J. Chen, Z. Gao, and G. Pan, "Linear Transformer-GAN: A Novel Architecture to Symbolic Music Generation", In International Conference on Artificial Neural Networks, Cham: Springer Nature Switzerland, 451-463, 2023.
- [313] X. Li, and Y. Niu, "[Retracted] Research on Chord-Constrained Two-Track Music Generation Based on Improved GAN Networks", Scientific Programming, 2022(1), 5882468, 2022.
- [314] P. L. Tomaz Neves, J. Fornari, and J. Batista Florindo, "Self-attention generative adversarial networks applied to conditional music generation", Multimedia Tools and Applications, 81(17), 24419-24430, 2022.
- [315] J. Hu, Z. Ge, and X. Wang, "[Retracted] The Psychological Education Strategy of Music Generation and Creation by Generative Confrontation Network under Deep Learning", Computational Intelligence and Neuroscience, 2022(1), 3847415, 2022.
- [316] Y. Xu, W. Wang, H. Cui, M. Xu, and M. Li, "Paralinguistic singing attribute recognition using supervised machine learning for describing the classical tenor solo singing voice in vocal pedagogy", EURASIP Journal on Audio, Speech, and Music Processing, 2022(1), 8, 2022.
- [317] X. Wang, C. Jin, and W. Zhao, "Beijing opera synthesis based on straight algorithm and deep learning", Advances in Multimedia, 2018(1), 5158164, 2018.
- [318] F. Maccarini, M. Oudin, M. Giraud, and F. Levé, "Co-creative orchestration of Angeles with layer scores and orchestration plans", In International Conference on Computational Intelligence in Music, Sound, Art and Design (Part of EvoStar), Cham: Springer Nature Switzerland, 228-245, 2024.
- [319] L. Highams, and J. I. Olszewska, "Markov-chain-based musical creative intelligent agent passing successfully the Turing Test", In 2023 IEEE 27th International Conference on Intelligent Engineering Systems (INES), 000215-000220, 2023.
- [320] P. Bodily, and D. Ventura, "Steerable Music Generation which Satisfies Long-Range Dependency Constraints", Transactions of the International Society for Music Information Retrieval, 5(1), 71-87, 2022.
- [321] M. Navarro-Caceres, H. G. Oliveira, P. Martins, and A. Cardoso, "Integration of a music generator and a song lyrics generator to create Spanish popular songs", Journal of Ambient Intelligence and Humanized Computing, 11(11), 4421-4437, 2020.
- [322] S. S. Garani, and H. Seshadri, "An algorithmic approach to South Indian classical music", Journal of Mathematics and Music, 13(2), 107-134, 2019.
- [323] D. Williams, V. J. Hodge, L. Gega, D. Murphy, P. I. Cowling, and A. Drachen, "AI and automatic music generation for mindfulness", In 2019 AES International Conference on Immersive and Interactive Audio: Creating the Next Dimension of Sound Experience. York, 2019.
- [294] Y. Zou, P. Zou, Y. Zhao, K. Zhang, R. Zhang, and X. Wang, "Melons: generating melody with long-term structure using transformers and structure graph", In ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 191-195, 2022.
- [295] B. Yu, P. Lu, R. Wang, W. Hu, X. Tan, W. Ye, ... and T. Y. Liu, "Museformer: Transformer with fine-and coarse-grained attention for music generation", Advances in Neural Information Processing Systems, 35, 1376-1388, 2022.
- [296] Z. Hu, Y. Liu, G. Chen, and Y. Liu, "Can machines generate personalized music? a hybrid favorite-aware method for user preference music transfer", IEEE Transactions on Multimedia, 25, 2296-2308, 2022.
- [297] C. Jin, T. Wang, X. Li, C. J. J. Tie, Y. Tie, S. Liu, ... and S. Huang, "A transformer generative adversarial network for multi-track music generation", CAAI Transactions on Intelligence Technology, 7(3), 369-380, 2022.
- [298] X. Yang, Y. Yu, and X. Wu, "Double linear transformer for background music generation from videos", Applied Sciences, 12(10), 5050, 2022.
- [299] Y. Tie, T. Wang, C. Jin, X. Li, and P. Yang, "Wireless Communications and Mobile Computing Multitrack Music Generation Network Based on Music Rules", Wireless Communications and Mobile Computing, 2022(1), 5845689, 2022.
- [300] W. Y. Hsiao, J. Y. Liu, Y. C. Yeh, and Y. H. Yang, "Compound word transformer: Learning to compose full-song music over dynamic directed hypergraphs", In Proceedings of the AAAI Conference on Artificial Intelligence, 35(1), 178-186, 2021.
- [301] S. Dai, Z. Jin, C. Gomes, and R. B. Dannenberg, "Controllable deep melody generation via hierarchical music structure representation", Proceedings of the 22nd International Conference on Music Information Retrieval, ISMIR 2021, 143-150, 2021.
- [302] D. Makris, K. R. Agres, and D. Herremans, "Generating lead sheets with affect: A novel conditional seq2seq framework", In 2021 International Joint Conference on Neural Networks (IJCNN), 1-8, 2021.
- [303] A. Muhamed, L. Li, X. Shi, S. Yaddanapudi, W. Chi, D. Jackson, ... and A. J. Smola, "Symbolic music generation with transformer-gans", In Proceedings of the AAAI conference on artificial intelligence, 35(1), 408-417, 2021.
- [304] A. Liutkus, O. Cifka, S. L. Wu, U. Simsekli, Y. H. Yang, and G. Richard, "Relative positional encoding for transformers with linear complexity", In International Conference on Machine Learning, 7067-7079, 2021.
- [305] S. Di, Z. Jiang, S. Liu, Z. Wang, L. Zhu, Z. He, ... and S. Yan, "Video background music generation with controllable music transformer", In Proceedings of the 29th ACM International Conference on Multimedia, 2037-2045, 2021.
- [306] J. Jiang, G. G. Xia, D. B. Carlton, C. N. Anderson, and R. H. Miyakawa, "Transformer vae: A hierarchical model for structure-aware and interpretable music representation learning", In ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 516-520, 2020.
- [307] C. Gan, D. Huang, P. Chen, J. B. Tenenbaum, and A. Torralba, "Foley music: Learning to generate music from videos", In Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28, 2020, Springer International Publishing, Proceedings, Part XI 16, 758-775, 2020.
- [307] K. Choi, C. Hawthorne, I. Simon, M. Dinculescu, and J. Engel, "Encoding musical style with transformer autoencoders", In International conference on machine learning, 1899-1908, 2020.

- [337] Y. U. Jinming, C. H. E. N. Zhuang, and H. A. I. Han, "Multi-style Chord Music Generation Based on Artificial Neural Network", *Journal of Donghua University (English Edition)*, 40(4), 2023.
- [338] K. Gupta, K. Srivastava, K. Singh, and R. Pillai, "Music Generation and Retrieval Using LSTM and VAE", In 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), 1-6, 2023.
- [339] M. Majidi, and R. M. Toroghi, "A combination of multi-objective genetic algorithm and deep learning for music harmony generation", *Multimedia Tools and Applications*, 82(2), 2419-2435, 2023.
- [340] S. L. Wu, and Y. H. Yang, "Compose & Embellish: Well-structured piano performance generation via a two-stage approach", In ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 1-5, 2023.
- [341] X. Liao, X. Li, Q. Xu, H. Wu, and Y. Wang, "Improving ant collaborative filtering on sparsity via dimension reduction", *Applied Sciences*, 10(20), 7245, 2020.
- [342] J. Min, Z. Liu, L. Wang, D. Li, M. Zhang, and Y. Huang, "Music generation system for adversarial training based on deep learning", *Processes*, 10(12), 2515, 2022.
- [343] C. Jin, F. Wu, J. Wang, Y. Liu, Z. Guan, and Z. Han, "MetaMGC: a music generation framework for concerts in metaverse", *EURASIP journal on audio, speech, and music processing*, 2022(1), 31, 2022.
- [344] S. Tanberk, D. B. Tükel, "Style-specific Turkish pop music composition with CNN and LSTM network", In 2021 IEEE 19th World Symposium on Applied Machine Intelligence and Informatics (SAMII), 000181-000185, 2021.
- [345] G. Li, S. Ding, and Y. Li, "Novel LSTM-gan based music generation", In 2021 13th International Conference on Wireless Communications and Signal Processing (WCSP), 1-6, 2021.
- [346] S. R. Hwang, and Y. C. Park, "Chord-based stepwise Korean Trot music generation technique using RNN-GAN", *The Journal of the Acoustical Society of Korea*, 39(6), 622-628, 2020.
- [347] M. Dua, R. Yadav, D. Mamgai, and S. Brodiya, "An improved RNN-LSTM based novel approach for sheet music generation", *Procedia Computer Science*, 171, 465-474, 2020.
- [348] A. Ç. Yiiksel, M. M. Karci, and A. Ş. Uyar, "Automatic music generation using evolutionary algorithms and neural networks", In 2011 International Symposium on Innovations in Intelligent Systems and Applications, 354-358, 2011.
- [324] P. Roy, and F. Pachet, "Enforcing meter in finite-length markov sequences", In Proceedings of the AAAI Conference on Artificial Intelligence, 27(1), 854-861, 2013.
- [325] E. Gale, O. Matthews, B. D. L. Costello, and A. Adamatzky, "Beyond markov chains, towards adaptive memristor network-based music generation", *International Journal of Unconventional Computing*, 10(3), 181-197, 2013.
- [326] W. Schulze, and B. Van Der Merwe, "Music generation with Markov models", *IEEE MultiMedia*, 18(03), 78-85, 2011.
- [327] L. Jing, "Evolutionary Deep Learning for Sequential Data Processing in Music Education", *Informatica*, 48(8), 2024.
- [328] W. Wang, J. Li, Y. Li, and X. Xing, "Style-conditioned music generation with Transformer-GANs", *Frontiers of Information Technology & Electronic Engineering*, 25(1), 106-120, 2024.
- [329] Q. Liang, and Y. Wang, "Drawlody: Sketch-Based Melody Creation with Enhanced Usability and Interpretability", *IEEE Transactions on Multimedia*, 2024.
- [330] Y. Xu, "Enhancing Music Generation With a Semantic-Based Sequence-to-Music Transformer Framework", *International Journal on Semantic Web and Information Systems (IJSWIS)*, 20(1), 1-19, 2024.
- [331] C. Ford, A. Noel-Hirst, S. Cardinale, J. Loth, P. Sarmiento, E. Wilson, ... and N. Bryan-Kinns, "Reflection Across AI-based Music Composition", In Proceedings of the 16th Conference on Creativity & Cognition, 398-412, 2024.
- [332] C. Hsu, and R. Greer, "Bridging Subjectivity and Objectivity in Evaluation of Machine-Generated Jazz Music: A Multimetric Approach", In 2023 IEEE International Symposium on Multimedia (ISM), 232-237, 2023.
- [333] A. Kurniawati, E. M. Yuniarno, Y. K. Suprpto, and A. N. Ikhsan Soewidiatmaka, "Automatic note generator for Javanese gamelan music accompaniment using deep learning", *International Journal of Advances in Intelligent Informatics*, 9(2), 2023.
- [334] H. Wang, S. Han, G. Li, and B. Zhao, "A Hybrid Neural Network for Music Generation Using Frequency Domain Data", In International Conference on Artificial Intelligence in China, Singapore: Springer Nature Singapore, 219-228, 2022.
- [335] H. W. Dong, K. Chen, S. Dubnov, J. McAuley, and T. Berg-Kirkpatrick, "Multitrack music transformer", In ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 1-5, 2023.
- [336] J. Grekow, "Generating Polyphonic Symbolic Emotional Music in the Style of Bach Using Convolutional Conditional Variational Autoencoder", *IEEE Access*, 11, 93019-93031, 2023.

¹ Data Paper

² Erratum

³ Retracted

⁴ Book Chapter

⁵ Editorial

⁶ Note

Future Scenario Development of Online Branding with Emphasis on the Impact of Artificial Intelligence in the 2025 Horizon

Yosef Amiri¹, Abdolreza Shahmohammadi^{2*}, Ahmadreza Shekarchi Zadeh³

¹Department of Management, Najafabad Branch, Islamic Azad University, Najafabad, Iran

²Assistant Professor, Department of Social Communication Sciences, Central Tehran Branch, Islamic Azad University, Tehran, Iran

³Assistant Professor, Department of Management, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Received: 10 December 2024, Revised: 01 March 2025, Accepted: 02 March 2025

Paper type: Research

Abstract

In today's digital world, online visioning has become one of the most essential ways to grow and develop businesses. Understanding the challenges and opportunities that exist in the shadow of new technologies, and of course, understanding solutions to deal with super-challenges such as economic problems, access to appropriate data, and how to exploit the uncertainty facing businesses are important issues that must be addressed in order to succeed by choosing effective strategies and creating a visionary identity in cyberspace, with the help of social media and cyber advertising, etc. Artificial intelligence has also witnessed success. In this research, an attempt was made to identify and build a better future with the help of futures studies as an interdisciplinary science and alternative tools such as scenario development. The aim of this analytical and descriptive research, which is developmental in nature and in terms of a mixed method approach, is to present images of possible and probable futures using a questionnaire tool using the Global Business Network (G.B.N.) method and relying on two key uncertainties: "government trade sanctions on specific visions or specific target communities" and "weakness of laws and regulations in the field of artificial intelligence applications," which is finally accompanied by providing strategic recommendations for the development of valid domestic visions and for the formation of a better future.

Keywords: Artificial intelligence, future studies, online branding, cyber space, scenario development.

* Corresponding author's email: a.shahmohammadi@iauctb.ac.ir

سناریوسازی آینده ویتژندسازی برخط با تأکید بر تأثیر هوش مصنوعی در افق ۲۰۲۵

یوسف امیری^۱، عبدالرضا شاه‌محمدی^{۲*}، احمدرضا شکرچی‌زاده^۳

^۱ گروه مدیریت، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

^۲ استادیار، گروه علوم ارتباطات اجتماعی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

^۳ استادیار، گروه مدیریت، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

تاریخ دریافت: ۱۴۰۳/۰۹/۲۰ تاریخ بازبینی: ۱۴۰۳/۱۲/۱۱ تاریخ پذیرش: ۱۴۰۳/۱۲/۱۲

نوع مقاله: پژوهشی

چکیده

در دنیای دیجیتال امروز، ویتژندسازی برخط به یکی از ضروری‌ترین راه‌ها برای رشد و توسعه کسب‌وکارها تبدیل شده و شناخت چالش‌ها و فرصت‌های موجود در سایه فناوری‌های نوآیند و البته شناخت راهکارهای مقابله با ابر چالش‌هایی چون معضلات اقتصادی، دسترسی به داده‌های مناسب و شیوه بهره‌جویی در فضای مملو از عدم قطعیت پیش روی کسب‌وکارها از موضوعات مهمی است که باید به آنها توجه نمود تا در سایه انتخاب راهبردهای مؤثر و ایجاد هویت ویتژند در فضای مجازی، به کمک رسانه‌های اجتماعی و تبلیغات سایبری و ... نیز هوش مصنوعی شاهد موفقیت را در کنار گرفت. در این پژوهش تلاش شد تا با مساعدت آینده‌پژوهی به‌عنوان یکی از علوم بینارشته‌ای و ابزار بدیلی همچون تدوین سناریو به شناخت و ساخت آینده‌ای بهتر بپردازیم. هدف این تحقیق تحلیلی و توصیفی که به لحاظ نوع توسعه‌ای و از نظر رویکرد آمیخته (MIXED METHOD) است، ارائه تصاویری از آینده‌های ممکن و محتمل به کمک ابزار پرسش‌نامه با روش شبکه جهانی کسب‌وکار (G.B.N) و با تکیه بر دو عدم قطعیت کلیدی «تحریم‌های تجاری دولت‌ها بر روی ویتژندهای خاص و یا جوامع هدف خاص» و «ضعف قوانین و مقررات حوزه کاربردی هوش مصنوعی» بوده که در انتها با ارائه تجویزهایی راهبردی به‌منظور توسعه ویتژندهای داخلی معتبر و برای شکل‌گیری آینده بهتر صورت همراه شده است.

کلیدواژگان: هوش مصنوعی، آینده‌پژوهی، ویتژندسازی برخط، فضای مجازی، سناریوسازی.

* رایانامه نویسنده مسؤول: a.shahmohammadi@iauctb.ac.ir

۱- مقدمه

هوش مصنوعی (AI) به طور فزاینده‌ای در صنایع مختلف، به‌ویژه در ویژندسازی دیجیتال، موردتوجه قرار گرفته است. برخی از مهم‌ترین علل اهمیت و کاربردهای آن تحلیل داده‌ها و بهبود بینش‌های مشتری، جمع‌آوری و تحلیلی داده‌ها و ... است. هوش مصنوعی به طور دقیق‌تری داده‌های مربوط به رفتار و ترجیحات مشتریان را تحلیل نموده الگوهای خرید، رفتار برخط و نظرات مشتریان در شبکه‌های اجتماعی را جمع‌بندی می‌نماید. همچنین با استفاده از الگوریتم‌های یادگیری ماشین، ویژندها می‌توانند تجربیات کاربری را به طور خاص برای هر کاربر طراحی کنند، به تحلیل عملکرد تبلیغات و بازخوردهای مرتبط با آن‌ها کمک بپردازند و به‌سرعت راهبردهای تبلیغاتی خود را بهینه کنند.

در این مسیر چت‌بات‌ها و دستیاران هوش مصنوعی در خدمات مشتری به طور ۲۴ ساعته و به‌صورت فوری به سؤالات و نیازهای مشتریان پاسخ می‌دهند و با پیش‌بینی تغییرات بازار و رفتار مشتریان، راهبردها را بر اساس روندهای آینده پیشنهاد می‌کنند و به کسب‌وکارها کمک می‌کنند تا به‌سرعت به تغییرات محیطی واکنش نشان دهند. الگوریتم‌های هوش مصنوعی می‌توانند به تولید محتوا کمک کنند و با تحلیل نظرات مشتریان از میان انبوه داده‌ها به درک بهتری از احساسات و نیازهای آن‌ها برسند.

به‌طور کلی با توجه به توانایی‌های هوش مصنوعی در جمع‌آوری، تحلیل و استفاده از داده‌ها، ویژندها می‌توانند به شیوه‌ای کارآمدتر و هوشمندانه‌تر با مشتریان خود ارتباط برقرار کنند و تجربه‌هایی منحصر به فرد و شخصی‌سازی شده ارائه دهند. بهره‌گیری از فناوری‌های هوش مصنوعی در ویژندسازی دیجیتال نه تنها می‌تواند موفقیت کسب‌وکارها را تضمین کند، بلکه آن‌ها را در رقابت‌های شدید بازار نیز متمایز کرده و به پیشرفت سریع‌تر آن‌ها کمک نماید؛ اما البته تحقق این شرایط به متغیرهای دیگری وابسته است که در خلال این پژوهش به آنها خواهیم پرداخت.

بنابراین، مسئله این تحقیق، تأثیر هوش مصنوعی بر آینده ویژندسازی برخط و پیامدهای آن بوده و ضرورت و اهمیت توجه به آن در ویژندسازی موضوعات مهمی چون شخصی‌سازی استفاده از داده‌ها، بهبود کارایی، کاهش هزینه‌ها و طبعاً توسعه کسب‌وکارها را و البته پیامدهای ناخوشایندی همچون کاهش رشد اقتصادی، از بین رفتن کسب‌وکارها و مسائل و معضلات اجتماعی فناوری‌های نوآیندی همچون هوش مصنوعی است.

۱-۱- پیشینه تحقیق

ساکی و مهربان (۱۳۹۷) در پژوهشی با عنوان «تأثیر بازاریابی رسانه‌های اجتماعی (وب‌سایت) بر روی وفاداری به برند با در نظر گرفتن نقش میانجیگرانه اعتماد به برند» (مطالعه موردی: شبکه اجتماعی اینستاگرام) نشان داد بازاریابی رسانه‌های اجتماعی (وب‌سایت) بر روی وفاداری به ویژند با در نظر گرفتن نقش میانجی‌گرانه اعتماد به ویژند اثرگذار است. [۱]

ژیا لیو و همکاران (۲۰۱۹) طی مقاله‌ای با عنوان «بررسی تأثیر بازاریابی رسانه اجتماعی ویژندهای لوکس بر جذب مشتری» با استفاده از کلان‌داده‌های استخراج شده از یک دوره ۶۰ ماهه در توئیتر (ژوئیه ۲۰۱۲ تا ژوئن ۲۰۱۷)، ۳/۷۸ میلیون توئیتر را از ۱۵ ویژند لوکس برتر با بالاترین تعداد فالوور توئیتر را تحلیل و ابراز داشتند برای بازاریابان، روش قدیمی کسب‌وکار ناپایدار است. مصرف‌کنندگان هنوز هم قصد فروش و ارزش افزوده نام تجاری را دارند. [۲]

هاباچی و همکاران (۲۰۲۳) طی مقاله‌ای با عنوان «رمزگشایی تأثیر تجربه بازی بر وفاداری به نام تجاری و قصد استفاده: نقش واسطه‌ای تعامل با ویژند مشتری» به مطالعه و بررسی تأثیر تجربه بازی بر نتایج رفتاری می‌پردازد. با اقتباس از نظریه محرک - ارگانیسم - پاسخ، مدل جدیدی را پیشنهاد و آزمایش می‌کند که رابطه بین تجربه بازی، وفاداری به ویژند و قصد استفاده از برنامه‌های کاربردی با ویژند بازی‌سازی شده در زمینه ورزش و تناسب‌اندام را بررسی می‌کند. علاوه بر این، نقش میانجی تعامل مشتری با ویژند و نقش تعدیل‌کننده تطابق تصویر از خود را بررسی می‌کند. [۳]

آگوس راهایو و همکاران (۲۰۲۱) در مقاله‌ای با عنوان «تأثیر نظرات مشتریان برخط بر قصد خرید در بازار برخط» به بررسی تأثیر بازخورد مشتریان برخط بر قصد خرید مشتریان با تأکید بر نقش ارزش بازخورد و شهرت ویژند می‌پردازد. این مقاله با روش کمی و با استفاده از پرسش‌نامه برای جمع‌آوری داده‌ها نشان می‌دهد که ارزش بازخورد و شهرت ویژند می‌توانند بر قصد خرید مشتریان تأثیرگذار باشند. همچنین، بازخورد مثبت می‌تواند بیشتر از بازخورد منفی بر روی قصد خرید مشتریان تأثیرگذار باشد، به شرطی که شهرت ویژند نیز در سطح مناسبی باشد. [۴]

امیری‌مقدم و همکاران (۱۳۹۷) در مقاله سناریوهای تهدیدات امنیتی عربستان علیه جمهوری اسلامی ایران در افق ۱۴۰۴، با کمک آینده‌پژوهی و روش تدوین سناریو به تدوین سناریوهای

تهدیدات امنیتی عربستان سعودی در افق ۱۴۰۴ را با روش «جی بی ان» پرداخته و ضمن ارائه چهار سناریوی بالاتر از سیاهی، افسارگسیخته، در مسیر تندباد و بازی خورده تنها، به کمک روش کوئست (دیدهبانی سریع محیطی) راهکارهایی را ارائه نموده‌اند. چنانچه پیش‌تر آمد و باتوجه به مرور ادبیات، استفاده از ابزار سناریو و سایر روش‌ها و ابزارهای آینده‌پژوهی در ویژند سازی فاقد سابقه بوده و از این جهت این تحقیق در نوع خود نوآورانه به شمار می‌رود. [۵]

۲- مبانی نظری

۲-۱- هوش مصنوعی در مهندسی دیجیتال

هوش مصنوعی شامل الگوریتم‌های یادگیری ماشین، پردازش زبان طبیعی و تحلیل داده‌های بزرگ است که به شرکت‌ها در تدوین راهبردهای بازاریابی کمک می‌کند [۶] از جمله کاربردهای آن در مهندسی دیجیتال می‌توان به تحلیل احساسات، تولید محتوای خودکار، چت‌بات‌های هوشمند و شخصی‌سازی تجربه کاربری اشاره کرد. [۷]

۲-۲- آینده‌پژوهی و رویکردهای آن

چشم‌انداز غالب آینده محدود به ادراکات و اقدامات حال حاضر است و پیش‌بینی و کاوش در آینده‌های بلندمدت جایگزین، اغلب نادیده انگاشته می‌شود. زمان آینده به‌طور کلی در فرایندهای شناختی مدیران به‌عنوان بخشی از تعامل مداوم حال در نظر گرفته می‌شود، به‌گونه‌ای که به افق زمانی آینده توجه نمی‌شود یا در بهترین حالت نگاهی کوتاه‌مدت مدنظر است. [۸] آینده‌پژوهی علم و هنر شناخت و ساخت آینده به کمک رصد تغییرات و تغییر سازها با هدف پیشینه‌کردن منافع مادی و معنوی کنشگر است. با افزایش تغییرات و دگرگونی‌ها، اتکا به روش‌های سنتی برنامه‌ریزی جوابگوی نیاز برنامه‌ریزان نبوده و سایه سنگین عدم قطعیت‌ها و ظهور ناپیوستگی‌ها، وضعیت را به‌گونه‌ای دگرگون کرده که پیش‌بینی آینده در دنیای پرتحول، امری مشکل به نظر می‌رسد. [۹]

ارزش آینده‌پژوهی بیش از آنکه به‌درستی پیش‌بینی‌ها باشد به مفیدبودن آن در برنامه‌ریزی و گشودن ذهن‌ها برای توجه بیشتر به فرصت‌های نوپدید و تغییر دستور کارهای سیاستی است. [۱۰] آینده‌پژوهی می‌کوشد تا نیروهای حال و آینده را شناسایی کند تا تصمیم‌های بهتری اتخاذ شود. یک انگیزه مهم برای کار

آینده‌پژوهی برآورد تغییر و آمادگی برای روبروشدن با آینده است. در مدیریت راهبردی، پابرجایی راهبرد اغلب به‌صورت تناسب راهبردی تخمین زده می‌شود؛ یعنی میزان انطباق سازمان با محیط و حمایت متقابل از یکدیگر موردنظر است. اگر محیط تغییر کند، آنگاه ما تناسب و انطباق را از دست می‌دهیم و سازمان شروع به سقوط می‌کند. اسلاوتر اعتقاد دارد آینده‌پژوهی پیش‌گویی نیست، به دنبال آن هم نیست، بلکه به شناخت مخاطرات مربوط می‌شود؛ چراکه همواره عواملی وجود دارد که تصمیمات روزمره ما را در معرض مخاطره قرار می‌دهد. [۱۱] تحقیقات علمی آینده‌پژوهی ایده‌های مختلفی را در مورد آینده ارائه می‌دهد که می‌تواند در مطالعات شبکه کسب‌وکار مورد استفاده قرار گیرد. در حالی که محققان سازمان عمدتاً بر روی جزئیات شرایط کنونی تمرکز دارند و مطالعه آینده تنها به‌عنوان یک بخش مرتبط با فعالیت‌های فعلی موردتوجه قرار می‌گیرد، مطالعات آینده‌نگر به دنبال درک زمان آینده هستند و به‌صراحت عدم قطعیت‌های آینده را مطالعه می‌کنند. آینده‌پژوهی ایده آینده‌های جایگزین را ترویج می‌کند، به دنبال درک احتمالات آینده است. [۸]

مطالعات آینده‌نگری یک رویکرد مناسب برای ایجاد پیش‌بینی شبکه ارائه می‌دهد که پیش‌بینی مشترک یا پیش‌بینی شبکه‌ای نامیده می‌شود. [۱۲]، [۱۳]. آینده‌نگری مشارکتی بر تعاملات بین شرکای تجاری و بازیگران سازمانی استوار است و پایگاه‌های مختلف دانش و تصاویر، ایده‌ها و باورهای مختلف آینده را با یکدیگر به تعامل وامی‌دارد [۱۲]، [۱۳]، [۱۴] آینده‌نگری به‌عنوان یک رویکرد عملی، بر «تصور و / یا پیش‌بینی آینده در سطح عملیاتی با برنامه‌ریزی برای تحقق موقعیت‌های پیش‌بینی‌شده یا جستجوی راه‌حل‌های جدید» تمرکز دارد. [۱۲] از بین روش‌های آینده‌پژوهی به‌یقین سناریونویسی جایگاه ویژه‌ای دارد، بسیاری سناریونویسی را قلب و مرکز آینده‌پژوهی می‌دانند و اعتقاد دارند سناریونویسی فن کلیدی جهت تمایزگذاری بین کار آینده‌پژوهان حرفه‌ای از دیگر مشاغل مرتبط با آینده است. [۱۵]

وندل بل به‌یقین یکی از بزرگان آینده‌پژوهی است که معتقد است سناریونویسی برای آینده‌پژوهی وحدت و یگانگی به ارمغان می‌آورد. [۱۶] سناریو را می‌توان روشی برای خلاصه‌سازی دستاورد تلاش‌های آینده‌پژوهی دانست؛ خواه این دستاوردها بر پایه روش‌های کمی استوار باشند که به پیش‌بینی‌ها و تسری‌های دقیق اما محدود می‌انجامند، خواه بر پایه روش‌های کیفی که از آینده تمامی جوامع و تمدن‌ها، تصویرهای بدیل فراگیر ارائه می‌دهند. او حتی پا را از این هم فراتر گذاشته و می‌گوید: «دستاورد تمامی

اغلب، منطق شهودی سناریوسازی، متداول ترین تکنیک های سناریوسازی در منابع موجود است، وظایف تصریح شده فرایند کار سناریوسازی به طور کلی در گروه های تسهیل شده انجام می شوند که در اصل گروه های خلاق و با اتکای سنگین به قضاوت های ذهنی و فردی یا شهود نظم یافته اعضای گروه است. [۲۰]

روش «GBN»^۱، حاصل کاربست فناوری سناریو از سوی شرکت شیل بود. در آغاز، پییر واک در سال های آغازین دهه شصت میلادی، کاربست مفاهیم هرمان کان را آغاز و به اصلاح و بهبود این مفاهیم پرداخت، این پژوهش نیز برای نگارش سناریو ابتدا بر تصویری کلی ترسیم و سپس بر مسائل جزئی تأکید داشت. چرا که توجه به جزئیات در آغاز کار، موجب از دست دادن ابعاد حیاتی فرایند ساخت می شود. روش مبتنی بر منطق شهودی سناریوسازی که در این پژوهش مورد استفاده قرار گرفته متداول ترین تکنیک سناریوسازی و متناسب با ارائه راهبردهای سریع مبتنی بر سناریو است. گام های این روش عبارت اند از:

۱. مرحله نخست، شناسایی موضوع یا تصمیم اصلی یعنی آینده ویژندسازی برخط با تأکید بر هوش مصنوعی است.
 ۲. مرحله دوم، شناسایی و مطالعه نیروهای کلیدی مؤثر در ویژندسازی برخط باتوجه به ظهور و بروز هوش مصنوعی است.
 ۳. مرحله سوم که برای یافتن نیروهای پیشران در کلان محیط انجام شد، گزاره هایی را پیش روی این پژوهش قرار داد. در این مرحله نیز پیشران بر اساس مدل «PESTEL» مرتب شدند.
 ۴. مرحله چهارم: رتبه بندی عوامل کلیدی و پیشران ها بر اساس میزان اهمیت و عدم قطعیت
 ۵. مرحله پنجم: انتخاب منطق سناریو بر اساس وزن و عدم قطعیت عوامل کلیدی و پیشران های روندها
 ۶. مرحله ششم: شکل دهی و توسعه سناریو باتوجه به عوامل کلیدی و پیشران ها
- و سرانجام بررسی مضامین سناریوهای توسعه یافته و انتخاب پیش نشانگرها در مراحل هفتم و هشتم.


۲-۳- مطالعه تطبیقی کشورهای منتخب

ایالات متحده آمریکا

آمریکا به عنوان پیشرو در حوزه فناوری های دیجیتال، از هوش مصنوعی برای بهینه سازی تبلیغات، تحلیل رفتار مصرف کنندگان و

روش های آینده پژوهی اساساً یکسان است: سناریو؛ داستانی درباره آینده...» [۱۶]

پیتر شوارتز سناریو را «ابزاری برای نظم بخشیدن به دریافت های ذهنی درباره محیط های آینده بدیل که در آن تصمیمات می توانند به اجرا گذاشته شوند» می داند. سیمپسون آن را «فرایند ساخت آینده های بدیل محیط بیرونی یک کسب و کار» خوانده است. بلوم و منفی سناریو را «توصیفی از یک آینده ممکن و یا محتمل خوانده اند» کالینز آن را «یک جهش خیال پردازانه به سوی آینده» دانسته، شومیکر آن را: «یک روش شناسی سازمند اصولی برای ترسیم آینده های ممکن که در آن تصمیم های اجرایی می توانند به اجرا در آیند». دانسته است [۱۷] سناریوها داستان های بدیل چگونگی ظاهر شدن آینده هستند. آن ها پیش بینی ها یا پیش نگر ها نیستند، اما داستان های قابل اعتماد، منسجم و چالش برانگیز جهت کمک به تمرکز بر روی عدم قطعیت های حیاتی و درک توازن نیروهای شکل دهنده به آینده هستند. [۱۸]



شکل ۱. چگونه از طریق سناریوها به آینده نگاه کنیم؟ [۱۹]

^۱Global Business Network (GBN)

تولید محتوای شخصی‌سازی‌شده استفاده می‌کند [۲۱]. شرکت‌هایی مانند گوگل و آمازون از سیستم‌های پیشرفته تحلیل داده و یادگیری ماشین برای بهبود تجربه مشتری بهره می‌برند [۲۲].

چین

چین یکی از کشورهای پیش‌تاز در توسعه فناوری هوش مصنوعی است [۷]. شرکت‌هایی مانند علی‌بابا و بایدو از الگوریتم‌های پیشرفته برای تحلیل کلان‌داده‌ها و ایجاد تبلیغات هدفمند استفاده می‌کنند [۶]. همچنین، استفاده از چت‌بات‌های هوشمند برای خدمات مشتریان در این کشور بسیار رایج است [۲۱].

آلمان

آلمان با تمرکز بر صنعت ۴،۰ و دیجیتال‌سازی ویتندها، از هوش مصنوعی برای بهینه‌سازی زنجیره تأمین، شخصی‌سازی تجربه مشتری و توسعه راهبردهای بازاریابی دیجیتال استفاده می‌کند [۲۲]. شرکت‌هایی مانند زیمنس و بی‌ام‌و از تحلیل داده‌های پیشرفته برای تقویت ویتند خود بهره می‌برند [۷].

۴-۲- هوش مصنوعی، تهدیدات و فرصت‌ها

امروزه استفاده از هوش مصنوعی زندگی بشر را دچار تحولات در خور توجهی نموده و دورنمای آن تصویری از ترس و امید را به نمایش گذاشته است. ترس ناشی از پیامدهای به‌کارگیری آن در ربات‌های انسان‌نما و جایگزینی آن با ذهن و فکر بشر ... و البته مسائل مرتبط با حریم و داده‌های خصوصی و قوانین و مقررات مناسب، چنانچه در داستان‌های تخیلی نمایش داده می‌شود و امید به حل مشکلات حل‌نشده‌ای که دهه‌ها فراروی بشر قرار داشته و شاید جاودانگی که همواره بخش جداناپذیر ذهن خلاق دانشمندان و حتی هنرمندان بوده است.

اما به‌هرحال یکی از جنبه‌های هوش مصنوعی (AI) که امروزه اهمیت زیادی یافته، استفاده از آن به‌عنوان یک ابزار قوی برای تجزیه و تحلیل و مدیریت کلان‌داده‌هاست. روش‌های مدیریت داده‌های مبتنی بر هوش مصنوعی [۲۱] در حال بهبود رویکردهای مدیریت داده‌های سنتی با حذف عملیات وقت‌گیر، استفاده از تجزیه و تحلیل داده‌ها برای ارائه بینش دقیق‌تر و امکان انتخاب‌های

مبتنی بر داده‌ها به کمک هوش مصنوعی است. [۲۲]

استفاده روبه‌رشد از سیستم‌عامل‌های هوش مصنوعی (AI) که طیف گسترده‌ای از برنامه‌ها و خدمات را ارائه می‌دهند، توسعه مهارت‌ها و ابزارهای جدید را تقویت کرده است. محبوبیت به‌دست‌آمده توسط مدل‌های GPT که زبان طبیعی و سیستم‌های هوش مصنوعی^۱ را پردازش می‌کنند تصاویری را ایجاد می‌کنند [۲۵] که کاربردهای مختلفی اعم از پاسخ‌های مبتنی بر متن و یا منتهی به هنر تولید شده توسط AI را نشان داده است. اما مشکل زمانی آغاز می‌شود که این فناوری که به‌سرعت در حال رشد است، نمی‌تواند یک اجماع مشترک در تعریف و مقررات خود پیدا کند؛ اما افزایش پذیرش آن نتیجه و علت توسعه فناوری‌های نوآورانه مورد استفاده (و سوءاستفاده) در میان رشته‌ها و صنایع مختلف است. [۲۶]، [۲۷]

یک پژوهش در مورد تأثیر هوش مصنوعی در آینده صنعت بانکداری ضمن تأکید بر اهمیت اعتماد مشتریان به هوش مصنوعی، شفافیت، امنیت و پاسخگویی را از موضوعات قابل توجه به‌کارگیری هوش مصنوعی در صنعت بانکداری و هم‌زمان بهره‌وری اقتصادی، بهینه‌سازی عملیاتی و تعامل پیشرفته با مشتریان (شخصی‌سازی خدمات) را از مهم‌ترین مزایای به‌کارگیری هوش مصنوعی در این صنعت روبه‌توسعه دانسته است. [۲۸] برخی دیگر از مزایای هوش مصنوعی در صنعت مذکور مدیریت ریسک و تقلب، تحلیل بازار، اصلاح فرایندها و تطبیق آنها با فرایندهای استاندارد، احراز هویت مشتریان، هوش تجاری و اخذ گزارش‌هایی دوره‌ای و موردی و ... دانسته‌اند. البته در مقابل چالش‌هایی هم وجود دارند که برخی از مهم‌ترین آنها عبارت‌اند از: حفظ و احترام به حریم خصوصی و امنیت داده‌ها، وابستگی نتایج به کیفیت داده‌ها، هزینه بالا و عدم شفافیت به دلیل الگوریتم‌های پیچیده مورد استفاده هوش مصنوعی، شکاف مهارت و دانش و سرانجام تعصب و مقاومت در برابر آن به سبب فرهنگ‌سازمانی. [۲۸]

اما با همه پیچیدگی‌هایی که مطرح می‌شود، موضوع چندان هم پیچیده نیست در واقع سیستم‌های هوش مصنوعی نرم‌افزارها و حتی گاه سخت‌افزارهایی هستند که توسط انسان طراحی شده‌اند تا در صورتی که یک تکلیف پیچیده به عهده آنان قرار گیرد آنان به‌صورت فیزیکی یا در ابعاد دیجیتال با درک محیط اطراف خود از طریق به‌دست‌آوردن داده‌ها و تحلیل و تفسیر داده‌های به دست

^۱ برنامه‌های کاربردی هوش مصنوعی یا یادگیری ماشین را می‌توان به عنوان «الگوریتم‌های یادگیری که داده‌ها را به اطلاعات مناسب برای کار داده شده دستکاری و تبدیل می‌کنند» تعریف کرد (محمد و همکاران، ۲۰۲۰).

• **کمبود داده‌های باکیفیت:** داده‌ها عامل اصلی آموزش و بهبود هوش مصنوعی هستند. اما در حال حاضر، داده‌های کافی، دقیق، متنوع، نماینده و بدون تعصب در دسترس نیستند. برخی از داده‌ها نامربوط، نامعتبر، نامتجانس یا نامتعادل هستند. برخی داده‌ها نقض حقوق فکری یا حقوق شخصی می‌کنند. برخی داده‌ها تأثیرات منفی بر روی جامعه یا محیط زیست دارند. [۳۴]

• کمبود راهبرد پیاده‌سازی، مسائل حقوقی و عدم درک

مدیران: بسیاری از سازمان‌ها در پیاده‌سازی هوش مصنوعی با چالش‌های فنی، سازمانی، فرهنگی و اخلاقی روبرو می‌شوند. آنها نیاز به یک راهبرد روشن و جامع برای تعیین اهداف، منابع، شرکا، فرایندها و معیارهای پروژه خود دارند. آنها باید قانون‌ها و مقررات مربوط به هوش مصنوعی را رعایت کنند و ریسک‌های حقوقی را کاهش دهند. آنها باید دانش و توانایی لازم برای درک و ارزیابی فناوری هوش مصنوعی را در سطح مدیریت خود افزایش دهند. [۳۵]

کوتاه‌سخن اینکه هوش مصنوعی همانند تمام فناوری‌ها در درون خود واجد فرصت‌ها و تهدیداتی است که باید برای مدیریت آنها و البته چگونگی بهره‌برداری بهینه از آن تدبیری اندیشیده شود.

۲-۵- ویژندسازی برخط، هوش مصنوعی و مدیریت توجه

پژوهش‌ها نشان داده‌اند که خریداران برخط بر اساس اطلاعات ارائه شده در مورد محصول (مثل اطلاعات محصول، تصاویر و تعداد مشاهدات) یک کالا را خریداری می‌کنند. این اطلاعات ارائه شده باعث به وجود آمدن دو جهت‌گیری رفتاری ارزش‌محور منفعت‌طلبانه و لذت‌جویانه می‌شود که توجه به آن‌ها دارای اهمیت زیادی می‌باشد، زیرا امروزه به ارزش‌های مشتری به‌عنوان نوعی از انگیزه و در حالت کلی نیروی محرکه در بازار نگرینسته می‌شود و میزان توانایی فروشگاه‌های برخط در برآورده کردن این دو نوع ارزش مشتریان به طور مستقیم بر شکل‌گیری نگرش مصرف‌کنندگان و خرید یک کالا اثر می‌گذارد. [۳۶]

با نگاهی به ویژندهای مطرح دنیا و چگونگی موفقیت روزافزون ویژندهای مطرحی چون آمازون، اپل، گوگل و حتی ویژندهای ایرانی چون دیجی‌کالا و اسنپ درمی‌یابیم نقش فضای مجازی و البته استفاده درست از تحلیل داده‌های مشتریان نقش بسزایی در رشد و توسعه ویژندهای یاد شده داشته است. برخی از مهم‌ترین این ویژندها عبارت‌اند از:

آورده ساختاریافته یا ساختاریافته، استدلال کردن بر اساس یافته‌ها، یا با تجزیه و تحلیل اطلاعاتی که از این داده‌ها به دست آورده‌اند عمل کنند و برای انجام دادن بهترین عمل با هدف انجام دادن تکلیف اولیه تصمیم بگیرند. سیستم‌های هوش مصنوعی می‌توانند قواعد نمادین یا مدل‌های اعدادی را یاد بگیرند. آنها همچنین می‌توانند رفتار خود را بر اساس تحلیل تأثیر اعمال قبلی خود بر محیط وفق دهند. [۲۹]

در اهمیت هوش مصنوعی همین بس که اندازه بازار هوش مصنوعی در سال ۲۰۲۱ برابر با ۳۲۷٫۵ میلیارد دلار بوده است و پیش‌بینی می‌شود تا سال ۲۰۳۰ به ۱٫۵۹۷٫۱ میلیارد دلار برسد [۳۰] همچنین نرخ رشد سالانه ترکیبی (CAGR) بازار هوش مصنوعی از سال ۲۰۲۲ تا ۲۰۳۰ برابر با ۳۸٫۱ درصد بوده است که عدد جالب توجهی به نظر رسیده دولت‌ها و شرکت‌های زیادی را ترغیب به سرمایه‌گذاری در این فناوری نموده است.

لازم به یادآوری است در حال حاضر آمریکا بزرگ‌ترین بازار هوش مصنوعی در جهان است و پیش‌بینی می‌شود تا سال ۲۰۲۶ حجم بازار آن به ۲۹۹٫۶۴ میلیارد دلار برسد [۳۱] و البته بخش‌های جالب توجه این بازار شامل خدمات مشتری، تبلیغات دیجیتال، بهینه‌سازی جستجو، واقعیت افزوده، ربات‌های هوشمند و غیره هستند و البته یکی دیگر از فاکتورهای قابل توجه در هوش مصنوعی تعداد افراد شاغل در این حوزه است که عدد آن تا سال ۲۰۲۵ به ۹۷ میلیون نفر خواهد رسید. [۳۲]

باید توجه داشت استفاده از هوش مصنوعی چالش‌هایی را نیز به همراه داشته که باید مورد توجه قرار گیرد، برخی از مهم‌ترین آنها عبارت‌اند از:

• **کمبود محیط قانونی و نظارتی:** هوش مصنوعی نیاز به قوانین و مقررات مناسب برای حفظ حریم خصوصی، امنیت سایبری، حقوق مالکیت فکری و مسئولیت‌پذیری دارد. اما در حال حاضر، چنین قوانین و مقرراتی کافی و یکسان نیستند و در بین کشورها و مناطق مختلف تفاوت دارند. [۳۳]

• **کمبود اعتماد، ترس و راه‌حل‌های کاهش ریسک:** بسیاری از افراد و سازمان‌ها به هوش مصنوعی اعتماد ندارند و ترس دارند که این فناوری به آنها آسیب بزند یا جایگزین آنها شود. برای رفع این ترس، لازم است که هوش مصنوعی شفاف، قابل فهم، قابل کنترل و قابل اصلاح باشد. همچنین، باید راه‌حل‌های مناسب برای جلوگیری از سوءاستفاده، خطای یا سوءتفاهم در استفاده از هوش مصنوعی وجود داشته باشد. [۳۳]

۱. **آمازون**^۱: این ویژند به عنوان بزرگ‌ترین فروشگاه برخط جهان شناخته می‌شود و محصولات گسترده‌ای از مواد غذایی تا خدمات بلوتوث ارائه می‌دهد.

۲. **ای‌ام‌جی لاکچری**^۲: این ویژند با ارائه محصولات لوکس به مشتریان خود خدمات می‌دهد و با توجه به کیفیت و خدمات بالا شناخته می‌شود.

البته ویژندهای بزرگی چون اپل^۳: با ارزش ۳ تریلیون دلار، بزرگ‌ترین ویژند جهان، مایکروسافت با ویژندی با ارزش ۲,۵ تریلیون دلار، گوگل^۴ با ویژندی با ارزش ۱,۶۵ تریلیون دلار، گوگل نیز که در صدر ویژندهای بزرگ جهان قرار دارد.

همچنین تسلا^۵ با ارزش ۹۴۰ میلیارد دلار، تسلا نیز از ویژندهای بزرگ جهان شناخته می‌شود، سامسونگ^۶ با ارزش ۴۶۰ میلیارد دلار و بالاخره وال‌مارت^۷ با ویژندی با ارزش ۴۳۰ میلیارد دلار، همگی از بزرگ‌ترین ویژندهای جهان امروز به شمار می‌روند که بخش قابل توجهی از موفقیت خود را مدیون استفاده از دنیای مجازی و هوش مصنوعی هستند.^۸

در عین حال طی ایام اخیر، شرکت‌های کسب‌وکار (B2B) با یک محیط کسب‌وکار به طور فزاینده پیچیده مواجه شده‌اند و بحران‌های اجتماعی پیش رو، کسب‌وکارهای مختلف را مختل کرده است [۸] اما با این همه به لطف فناوری‌های روزآمد عرصه‌های جدیدی فراروی کسب‌وکارها قرار گرفته که شاید مهم‌ترین آنها هوش مصنوعی است، این کلان روند فناورانه امکانات بی‌بدیلی را پیش روی کسب‌وکارها و رسانه‌های اجتماعی قرار داده از جمله ارتقای بهره‌برداری از داده‌های کلانی نظیر داده‌های رسانه‌های اجتماعی و موجب شده امکان مدیریت آن‌ها فراهم شود. به عنوان مثال در مورد کسب‌وکارها امکان تحلیل داده‌های کلان مرتبط با مشتریان و شخصی‌سازی خدمات و حتی ارائه مشاوره‌های برخط برای افزایش سرمایه یا بهبود فرایند مشتری‌مداری را فراهم نموده است.

در واقع، ابزارهای هوش مصنوعی آنگاه که در کنار کلان‌داده‌ها در بستر شبکه‌های اجتماعی قرار گرفتند، موجب شدند که دقت و هدفمندی رسانه‌های اجتماعی به طرز شگرفی بیشتر شده و

بازاریابی حساب کاربری محور^۹ که در واقع نوعی بازاریابی تأثیرگذار^{۱۰} است، شکل بگیرد. تا آنجا که رسانه‌های اجتماعی کاملاً «شخصی‌سازی شده»^{۱۱} ظهور پیدا کرده که در آن‌ها، با اتکا به ابزارهای هوش مصنوعی و بهینه‌سازی محتوا^{۱۲}، محتوای شخصی‌سازی شده به کاربران تحویل داده می‌شود. اینستاگرام، فیس‌بوک، گوگل، لینکدین، پینترست و اسنپ‌چت مثال‌هایی هستند که از اوایل دهه حاضر به صورت جدی وارد این عرصه شده و با سرمایه‌گذاری زیاد، درآمدهای چندبرابری داشته‌اند.

باید به این نکته نیز توجه کرد که به دلیل وجود فشارهای رقابتی شدید، یکی از مهم‌ترین راهبردهایی که سازمان‌های خدماتی از طریق آن می‌توانند به مزیت رقابتی پایدار دست یابند، بهبود ارتباطات و تبلیغات از طریق فضای دیجیتال است؛ لذا به کارگیری رویکرد بازاریابی دیجیتال در فعالیتهای بازار باعث تسهیل و توسعه رفتارهای راهبردی مدیران بازاریابی شرکت‌ها در فضای دیجیتال می‌شود. بنابراین، بازاریابی دیجیتال به عنوان یکی از اقلام مهم دارایی‌های راهبردی و ابزارهای بازاریابی نوین به شمار می‌آید و البته گردآوری و ارزیابی اطلاعات مربوط به شرکت‌های رقیب در امر تدوین رویکرد بازاریابی نوین دیجیتالی، نقشی حیاتی دارد.

از طرفی ظرفیت‌سازی برای توسعه بازاریابی دیجیتالی از یک سو مستلزم ارائه آموزش‌ها و مهارت‌های لازم با رویکرد دیجیتالی و رشد شرکت‌های تجاری و بر اساس نیازهای جامعه در همه سطوح بوده و از سوی دیگر توسعه و رشد کسب‌وکارهای حوزه دیجیتال نیازمند شناخت و رفع موانع و ایجاد زمینه‌های مناسب جهت توسعه فعالیت‌های خدماتی می‌باشد.

اتخاذ رویکردهای دیجیتال و به کارگیری توانمندی رسانه‌های اجتماعی به تدریج به یکی از حیاتی‌ترین راهبردهای بازاریابی برای سازمان‌ها تبدیل شده و رسانه‌های دیجیتال و اجتماعی منبعی ضروری برای گسترش زندگی اجتماعی افراد یا درک رفتار مصرف‌کنندگانند. بنابراین، برای بازاریابان و کسانی که می‌خواهند در لبه روندهای بازار بمانند، «بازاریابی دیجیتال» به یک پارادایم اجتناب‌ناپذیر در حوزه کسب‌وکار تبدیل شده است. [۳۷]

^۷ Walmart

^۸ <https://www.brandvm.com/post/10-biggest-brands-2024>

^۹ Account-Based Marketing

^{۱۰} Influencer Marketing

^{۱۱} Personalized

^{۱۲} Content Optimization

^۱ Amazon

^۲ Amazon Luxury Stores

^۳ Apple

^۴ Google

^۵ Tesla

^۶ Samsung

۳- بهینه‌سازی موتورهای جستجو، SEO: هوش مصنوعی می‌تواند به شرکت‌های برخط کمک کند تا با استفاده از پردازش زبان طبیعی، رانش داده‌ها و یادگیری عمیق، سئو^۲ وبسایت خود را بهبود بخشند. این روش باعث می‌شود که وبسایت در نتایج جستجو بالاتر قرار گیرد و ترافیک بیشتری جذب کند [۳۹]

۴- بهینه‌سازی تجربه خرید مشتری به کمک واقعیت افزوده: هوش مصنوعی می‌تواند به شرکت‌های برخط کمک کند تا با استفاده از واقعیت افزوده^۳، تجربه خرید مشتریان را جذاب‌تر و جالب‌تر کنند. این روش باعث می‌شود که مشتریان بتوانند محصولات را قبل از خرید به صورت سه بعدی و در محیط واقعی ببینند و با آنها تعامل داشته باشند. [۳۹] البته چندین عامل باعث رشد چشمگیر هوش مصنوعی شده‌اند که برخی از آنها عبارت‌اند از:

الف- دسترسی به کلان داده‌ها و ارتقای خدمات مشتریان: با پیشرفت فناوری‌های ذخیره‌سازی ابری، داده‌هایی که قبلاً به شدت حفاظت شده و در دسترس عموم نبودند، حالا به راحتی قابل دسترسی شده‌اند. این داده‌ها می‌توانند به آموزش و بهبود مدل‌های هوش مصنوعی و بهینه‌سازی تجربه مشتری مداری کمک کنند [۴۰]

ب- پیشرفت در نوآوری‌ها: با ظهور نسل جدیدی از پردازنده‌ها مانند واحد پردازش گرافیکی (GPU)، فرایند آموزش مدل‌های هوش مصنوعی سرعت بیشتری یافته است. این پردازنده‌ها دارای هزاران هسته هستند که می‌توانند محاسبات را به صورت موازی و سریع انجام دهند. [۴۱]

ج- رقابت در بهره‌وری و علاقه را افزایش می‌دهد: باتوجه به پتانسیل بالای هوش مصنوعی در افزایش سودآوری و کارآمدی، بسیاری از شرکت‌ها و سازمان‌ها در حال سرمایه‌گذاری و تحقیق در زمینه هوش مصنوعی هستند. این رقابت باعث می‌شود که نوآوری‌های جدید در حوزه هوش مصنوعی به وجود آمده ارائه خدمات به مشتریان اشکال جدید و بهینه‌ای را تجربه کند. [۴۰]

د- پیشرفت در یادگیری عمیق و ارتقای خدمات به مشتریان: یادگیری عمیق (Deep Learning) یک شاخه از یادگیری ماشین (Machine Learning) است که از شبکه‌های عصبی عمیق (deep Neural Networks) برای پردازش داده‌ها

نکته مهمی که در کسب‌وکارهای دیجیتال نباید از نظر دور داشته شود، وفاداری مشتری است که به دلیل ضرورت تداوم مسیر کسب‌وکار با همراهی مشتری موضوع مهمی تلقی می‌شود. عقیده کارشناسان هرچه فضای تجارت رقابتی‌تر می‌شود، مطالعات مربوط به وفاداری مشتریان و وفاداری ویژند، ضرورت بیشتری پیدا می‌کنند. بررسی‌ها نشان می‌دهد وفاداری به ویژند بر اساس دو مفهوم واکنش رفتاری و شناختی مشتریان می‌تواند ارزیابی شود. واکنش رفتاری مشتریان که در طول زمان دیده می‌شود و قابل مشاهده است و دیگر تغییرات نگرشی مخاطبان ویژند است که بر قصد خرید ایشان تأثیرگذار است. جونز و تیلور وفاداری را به عنوان ترجیح یک ارائه‌دهنده خدمات خاص یا یک محصول و خدمت به جایگزین آن توسط مصرف‌کننده تعریف کردند. مشتری وفادار ترجیح می‌دهد دوباره همان نام تجاری را خریداری کند و بنابراین، به یک ارائه‌دهنده خدمات خاص وفادار می‌شود. [۳۸]

در عرصه سیاسی نیز هوش مصنوعی که ابتدا در حوزه‌های بازاریابی مورد استفاده قرار گرفته بودند و موجب افزایش چشمگیر فروش محصولات بسیاری از شرکت‌ها شدند، به تدریج با اتکا به ابزارهایی نظیر Net base به تحلیل احساسات^۱ پرداخته و حتی با استفاده از ابزارهایی نظیر Cortex بر اساس پردازش داده‌های رسانه‌های اجتماعی به راهنمایی عملی برای تصمیمات خلاقانه تبدیل شده و البته در حوزه‌های تجاری نیز رشد و توسعه بیشتری را تجربه کرده و با روش‌های خلاقانه‌ای به بهبود ویژندسازی برخط کمک‌های شایانی نمود. برخی از این روش‌ها عبارت‌اند از:

۱- تبلیغات خودکار: هوش مصنوعی می‌تواند به شرکت‌های برخط کمک کند تا با استفاده از الگوریتم‌های پیشرفته، تبلیغات خود را به صورت خودکار و بهینه در کانال‌های مختلف قرار دهند. این روش باعث می‌شود که تبلیغات به مخاطبان مناسب و در زمان مناسب نمایش داده شوند و باعث افزایش بازدهی و کاهش هزینه‌ها شوند. [۳۹]

۲- شخصی‌سازی خدمات: هوش مصنوعی می‌تواند به شرکت‌های برخط کمک کند تا با استفاده از چت‌بات‌ها، تحلیل احساسات و تشخیص چهره، خدمات مشتری را به صورت سریع، دقیق و شخصی‌سازی شده ارائه دهند. این روش باعث می‌شود که مشتریان رضایت بیشتری از ویژند داشته باشند و احساس اعتماد و وفاداری نسبت به آن پیدا کنند. [۳۹]

³ Augmented Reality (AR)

¹ Sentiment Analysis

² Search Engine Optimization (SEO)

ویژندسازی حل نموده است؛ در ارتباط با تأثیر هوش مصنوعی در توجه بیشتر مشتری لازم است تأکید شود هوش مصنوعی به عنوان یکی از پیشرفت‌های مهم در صنعت فناوری، باعث تحول راهبردهای بازاریابی و برندسازی (ویژندسازی) شده و ضمن فراهم آوردن امکان جلب توجه مشتریان، فرصت‌های جدیدی برای بهینه‌سازی راهبردهای ویژندسازی برخط شرکت‌ها فراهم کرده است. [۴۳] استفاده از هوش مصنوعی در ویژندسازی برخط، به شرکت‌ها کمک می‌کند تا به مشتریان خود خدمات و محصولات بهتری ارائه دهند و توجه ایشان را جلب نماید.

چنانچه پیش‌تر نیز اشاره شد، بهبود تجزیه و تحلیل داده‌های کلان داده‌های گذشته، حال و آینده، شخصی‌سازی هم‌زمان یا RTP^۱ با استفاده از اطلاعات مشتریان، محتوای وبگاه و فراهم نمودن امکان تبلیغات لحظه‌ای و متناسب با هر کاربر [۴۴]. بهبود فرایند تصمیم‌گیری با قابلیت پردازش داده‌های بزرگ و تحلیل سریع آنها، همگی از نکات مهمی است که در ویژندسازی برخط به کمک هوش مصنوعی کسب‌وکارها را رونق داده و در جلب توجه مشتریان نقش به سزایی بازی نموده و خواهد نمود. [۴۵]

ویژندسازی برخط در ایران نیز به معنای ایجاد و توسعه هویت ویژند در فضای دیجیتال در سال‌های گذشته توسعه قابل‌قبولی را تجربه کرده است. این فرایند اغلب به کمک استفاده از وبگاه‌ها، گوگل، فیس‌بوک، اینستاگرام، پست وبلاگ و سایر کانال‌های بازاریابی برخط انجام می‌شود^۲ و هدف از آن افزایش دسترسی، شناخت و شهرت ویژند است. تعدادی از این ویژندهای مشهور از جمله اسنپ، دیجی‌کالا، آپ و ... در میان ویژندهای مشهور منطقه و حتی دنیا برای خود جایگاهی به دست آورده‌اند. جالب آنکه اغلب این ویژندها از هوش مصنوعی برای تجزیه و تحلیل داده‌های مشتریان با رعایت اصول حریم خصوصی بهره جسته و به عنوان نقطه قوتی در مشتری‌مداری خود به آن تمسک جسته‌اند.

۲-۶- مروری بر عوامل کلیدی و پیش‌ران‌های شکل‌دهنده آینده ویژندسازی برخط

اکنون با پیشرفت علم و فناوری، شکل نوینی از ارتباطات بین افراد در جوامع پدید آمده و در گذر زمان رشد روزافزون داشته است و تأثیرات متفاوتی بر بخش‌های گوناگون جوامع دارند. شکل نوین ارتباطات همچون شبکه‌های اجتماعی مجازی در زندگی شخصی افراد نفوذ کرده و نگرش‌ها و رفتارهای جدیدی را پدید آورده است.

استفاده می‌کند. این شبکه‌ها قادر به چکیده‌سازی و استخراج ویژگی‌های پیچیده و غیرخطی از داده‌های مشتریان هستند. با استفاده از چارچوب‌های نرم‌افزاری مانند TensorFlow، PyTorch، Keras و غیره، توسعه‌دهندگان می‌توانند به راحتی شبکه‌های عصبی عمیق را طراحی و پیاده‌سازی کنند. [۴۲]

در ارتباط با ویژندسازی برخط با رویکرد مدیریت توجه باید گفت که آنچه که در عصر رسانه‌های نوین ارتباطی و فناوری هوشمند برای بنگاه‌های اقتصادی حائز اهمیت است بهره‌گیری از شیوه‌ها و مدل‌های نوین تبلیغات و ویژندسازی برای بقا در عرصه رقابت‌های اقتصادی و مقابله با اقتصادهای نوظهور و استارت‌آپی است که هم راستا با دگرگونی‌های فرهنگی و اجتماعی حاصل پارادایم فناورانه جدید، اقتصادهای سنتی را بلعیده و حکمرانی اقتصاد جهانی را در دست گرفته‌اند.

مدیریت توجه به مدل‌ها و ابزارهایی برای حمایت از توجه در سطح فردی یا جمعی (ر.ک. اقتصاد توجه)، و در کوتاه‌مدت (نیمه واقعی) یا در طولانی‌مدت (در دوره‌های چند هفته‌ای یا ماه‌ها درازمدت) اشاره دارد. توانایی متمرکز ماندن برای تولید نتایج با کیفیت بالاتر ضروری است و در واقع هدف حمایت از مدیریت توجه ارائه تعداد معینی راه‌حل برای مشکلات توجه است. گزیده‌ای از این مشکلات عبارت‌اند از:

- محدودیت‌های شناختی ادراک افراد: مانند ظرفیت محدود حافظه کوتاه‌مدت انسان (میانگین تعداد ۴ مورد را می‌توان در یک زمان معین مدیریت کرد)، یا محدودیت نظری شناختی برای تعداد افرادی که می‌توان با آنها روابط اجتماعی پایدار را حفظ کنید.

- **اضافه بار اطلاعات:** فرایند دریافت اطلاعات بیش از حد به روش‌هایی که مانع از تصمیم‌گیری می‌شود.

- **تعامل اجتماعی بیش از حد:** مثلاً ممکن است از خدمات شبکه‌های اجتماعی برخط نشئت گرفته باشد که از آن افراد درخواست‌های زیادی دریافت می‌کنند.

- **وقفه:** این امر باعث افزایش توجه می‌شود. به گفته تابوش، افرادی که با درد مزمن منحرف می‌شوند یا حواسشان پرت می‌شود در وظایف توجه به طور قابل توجهی بدتر می‌شوند.

اما به نظر می‌رسد فناوری‌هایی چون هوش مصنوعی که امروز به کلان روند مهمی در شکل‌دادن به آینده بشر به شمار می‌رود به کمک کسب‌وکارها آمده و تا حد زیادی مشکلات آنها را از جمله در

^۲ <https://websazannovin.com/online-branding/?form=MG0AV3>

^۱ Real-Time Transport Protocol (RTP)

امکانات جدید و چالش‌های جدیدی را برای ویژندسازی برخط فراهم می‌کنند. این فناوری‌ها به شرکت‌های برخط کمک می‌کنند تا به صورت خودکار و بهینه داده‌های مشتریان را جمع‌آوری، تحلیل و استخراج کنند و با استفاده از الگوریتم‌های پیشرفته، پیشنهادات مناسب و سفارشی شده را به آنها ارائه دهند. همچنین، این فناوری‌ها به شرکت‌های برخط امکان می‌دهند تا تجربه خرید مشتریان را با افزودن عناصر بازی و تعاملات چند حسی بهبود بخشند.

• **محیطی (Environmental):** مسائل محیط زیستی نظیر تغییرات آب‌وهوایی، کاهش منابع طبیعی، کاهش زباله‌ها و کربن پایین نگرانی‌های جدی در جامعه هستند که بر روی ویژندسازی برخط نیز تأثیر می‌گذارند. شرکت‌های برخط باید نشان دهند که در راستای حفاظت از سلامت سیاره فعالیت می‌کنند و به عملکرد ESG (Environmental, Social and Governance) خود توجه دارند. برخی از روش‌های مؤثر در این زمینه عبارت‌اند از: استفاده از بسته‌بندی‌های قابل بازیافت و کم‌حجم، استفاده از منابع انرژی تجدیدپذیر، کاهش تأثیرات منفی حمل‌ونقل و لجستیک، حمایت از پروژه‌های حفاظت از محیط‌زیست و گزارش‌دهی شفاف در مورد پایبندی به استانداردهای محیط‌زیست.

• **قانونی (Legal):** قوانین و مقررات حقوقی محلی، ملی و بین‌المللی نظیر قوانین حقوق مصرف‌کننده، قوانین حقوق کار، قوانین حقوق تجارت، قوانین حقوق تألیف و نشر و قوانین حقوق فساد نیز بر روی ویژندسازی به‌ویژه ویژندسازی برخط تأثیر خواهد داشت.

بر اساس آنچه که از مرور ادبیات به دست می‌آید، برخی عدم قطعیت‌های مؤثر در آینده توسعه استفاده از هوش مصنوعی در ویژندسازی برخط ممکن است شامل موارد زیر باشد: - قابلیت اطمینان و اخلاق هوش مصنوعی یکی از عدم قطعیت‌های بزرگ در استفاده از هوش مصنوعی در ویژندسازی برخط است. ویژندهای برخط باید اطمینان حاصل کنند که هوش مصنوعی که از آن استفاده می‌کنند دارای استانداردهای اخلاقی و حقوقی مناسب است و به حریم خصوصی، امنیت و رضایت مشتریان احترام می‌گذارد. همچنین باید راه‌حل‌های مناسب برای پیشگیری و رفع خطاها، نقص‌ها و سوءاستفاده‌های احتمالی از هوش مصنوعی داشته باشند. - پذیرش و اعتماد مشتریان به هوش مصنوعی عامل

به‌گونه‌ای که استفاده از فناوری‌های ارتباطی یکی از ضرورت‌های زندگی شده است. علی‌رغم اهمیت رسانه‌های اجتماعی برای پذیرش مشتری، شناخت ما از این پدیده محدود است و نظریه‌های جدید می‌توانند به ویژگی‌های منحصربه‌فرد رسانه‌های اجتماعی کمک کنند [۴۶]

برای تحلیل عوامل کلیدی و پیش‌ران‌های شکل‌دهنده آینده این حوزه با استفاده از چارچوب^۱ PESTEL برخی از مهم‌ترین عوامل که از مرور ادبیات و در خلال مصاحبه خبرگان استخراج گردیده عبارت‌اند از:

• **سیاسی (Political):** سیاست‌های دولت‌ها و نهادهای بین‌المللی در زمینه حفظ حریم خصوصی، امنیت سایبری، حقوق مالکیت فکری و تحریم‌های تجاری بر روی فعالیت‌های ویژندسازی برخط تأثیر مستقیم دارند. برای مثال، قوانین جدید اتحادیه اروپا در زمینه حفاظت از داده‌های شخصی (GDPR) باعث شده است که بسیاری از شرکت‌های برخط باید روش‌های خود را در جمع‌آوری و پردازش اطلاعات مشتریان تغییر دهند

• **اقتصادی (Economic):** شرایط اقتصادی و رقابت بازار نیز بر روی راهبردهای ویژندسازی برخط تأثیرگذار هستند. با توجه به رشد قابل توجه بازار خرید برخط پس از شیوع کووید-۱۹، بسیاری از شرکت‌ها سرمایه‌گذاری‌های عظیمی را در زمینه بهبود تجربه مشتری، بهینه‌سازی زنجیره تأمین و افزایش قابلیت‌های فناورانه خود انجام داده‌اند. همچنین، نوسانات نرخ ارز، تورم و نرخ بهره نیز بر روی قدرت خرید مشتریان و سودآوری شرکت‌ها تأثیر دارند.

• **اجتماعی (Social):** عوامل اجتماعی و فرهنگی نظیر سلاقی، نگرش‌ها، باورها، رفتارها و الگوهای مصرف مشتریان نقش مهمی در شکل‌گیری ویژندسازی برخط دارند. شرکت‌های برخط باید به نحو مناسب با نظافت‌ها و خواسته‌های مخاطبان خود پاسخ دهند و با استفاده از هوش مصنوعی راه‌حل‌های شخصی‌سازی شده و جذاب را به آنها ارائه دهند. برای مثال، برخی از شرکت‌های برخط از فناوری‌های مانند تشخیص چهره، تحلیل احساسات و چت‌بات‌ها برای ایجاد ارتباط عاطفی با مشتریان خود استفاده می‌کنند.

• **فناورانه (Technological):** فناوری‌های نوین و نوآورانه در زمینه هوش مصنوعی، اینترنت اشیا، بلاک‌چین، رباتیک، واقعیت مجازی و واقعیت افزوده، رایانش داده‌ها و پردازش زبان طبیعی،

^۱ PESTEL مخفف Political, Economic, Social, Technological, Environmental و Legal است

است طولانی و پیچیده باشد و نیاز به منابع بسیاری داشته باشد؛ بنابراین، برای اطمینان از کیفیت نتایج، لازم است که فرایند آموزش مدل‌های هوش مصنوعی به‌درستی انجام شود.

۳. تعریف هدف: تعریف هدف در استفاده از هوش مصنوعی برای ویژندسازی برخط مهم است. اگر هدف‌های دقیق و مشخصی تعریف نشود، نتایج ممکن است نامطلوب باشند.

۴. تعامل با مشتری: برای استفاده مؤثر از هوش مصنوعی در ویژندسازی برخط، باید به‌درستی با مشتریان تعامل کرد و نیازهای آن‌ها را درک کرد. در غیر این صورت، ممکن است مدل‌های هوش مصنوعی نتایج نامطلوبی داشته باشند.

۵. تأثیرات ناشی از تصمیمات مدل: مدل‌های هوش مصنوعی ممکن است تصمیماتی بگیرند که تأثیرات ناخواسته‌ای بر روی ویژند داشته باشند. برای مثال، ممکن است مدل تصمیم بگیرد که یک تبلیغ خاص را به یک گروه خاص از مخاطبان نشان دهد که ممکن است برای ویژند ضرر بزرگی به همراه داشته باشد.

۶. ملاحظات اخلاقی و قانونی: ملاحظات اخلاقی و قانونی در به‌کارگیری هوش مصنوعی نیز موضوع مهمی است که می‌تواند این ابرپیشران مهم را به نحو مثبت و یا منفی در فضای آینده جلوه‌گر نماید. علی‌رغم تمام ویژگی‌های مثبت هوش مصنوعی، استفاده از آن در همه عرصه‌های زندگی بشر و از آن جمله ویژندسازی برخط نیازمند رعایت اصول اخلاقی و نظارت قانونی دقیق است.

در جدول ۱ میزان اهمیت و عدم قطعیت برخی از مهم‌ترین عوامل کلیدی و پیشران‌های مؤثر در آینده ویژندسازی برخط بر اساس نظر خبرگان آمده است.

۳- روش‌شناسی تحقیق

تحقیق توصیفی که اساس این تحقیق بوده است، یکی از مهم‌ترین اشکال تحقیق به شمار می‌رود که پدیده‌های موجود در دنیای ما را توصیف می‌کنند. [۴۸] و در عین حال روش‌شناسی، نقطه تمرکز و هسته آینده‌پژوهی کاربردی است. همان‌گونه که نظریه‌پردازان، ساختارهای تازه‌ای از مفاهیم جاری را پدید می‌آورند، روش‌شناسی‌ها نیز افزایش نیروی فکری و کاربردی اندیشه‌ها و نظریه را به دنبال دارند. [۴۹]

دیگری است که تأثیر زیادی بر آینده توسعه استفاده از هوش مصنوعی در ویژندسازی برخط دارد. ویژندهای برخط باید تلاش کنند تا مشتریان خود را با فواید و مزایای هوش مصنوعی آشنا کنند و نگرانی‌ها و شبهات آنها را رفع کنند برای این منظور، ویژندها باید با شفافیت و صداقت با مشتریان خود ارتباط برقرار کنند و نحوه عملکرد و منطق هوش مصنوعی را به آنها توضیح دهند.

- حمایت دولت‌ها به واسطه ایجاد تسهیلاتی برای توسعه هوش مصنوعی و به‌کارگیری آن در کسب‌وکارهای دیجیتال، تدوین قوانین مناسب و اتخاذ راهبردهای امنیتی برای جلب اعتماد مشتریان و بهره‌برداران از موضوعات مهمی است که نمی‌توان به‌سادگی از کنار آن گذشت.

- ایجاد محدودیت‌های جهانی و یا ارائه تسهیلات در دنیای سیاست‌زده امروز اغلب باعث توسعه فناوری‌ها در بخشی از کره خاکی و ممانعت از توسعه آن در بخش‌های دیگر است. این استانداردهای دوگانه اغلب به‌جای مدیریت شکاف دیجیتال بر ایجاد فاصله‌ها تمرکز داشته است.

- پاسخگویی به تغییرات و نوآوری‌های فناورانه چالش دیگری است که برای استفاده از هوش مصنوعی در ویژندسازی برخط وجود دارد. با پیشرفت روزافزون فناوری‌های نوظهور، ویژندهای برخط باید قادر باشند تا به‌صورت پویا و سریع به تغییرات بازار، رقبا، محصولات، خدمات و نظام‌های قانونی وارده باشید.

نکته مهم اینکه، ویژندها باید سطح دانش و تخصص خود را در زمینه هوش مصنوعی به‌روز نگه داشته و از فرصت‌های یادگیری، آزمایش، بهبود و نوآوری استفاده کنند [۴۷] چرا که استفاده از هوش مصنوعی در ویژندسازی برخط می‌تواند به‌شدت مؤثر باشد، اما البته به دلیل وجود عدم قطعیت‌هایی که بالاترین تأثیر احتمالی را در شکل‌گیری فضای آینده خواهند داشت، برخی از نتایج ممکن است غیرمنتظره باشند.

بعضی دیگر از عوامل کلیدی و پیشران‌های مؤثر به‌کارگیری هوش مصنوعی در ویژندسازی برخط عبارت‌اند از:

۱. کیفیت داده: برای استفاده از هوش مصنوعی در ویژندسازی برخط، داده‌های کافی و کیفیت بالا برای آموزش و استفاده از مدل‌های هوش مصنوعی لازم است. اگر داده‌ها کامل و کیفیت بالایی نباشند، نتایج قابل اطمینانی به دست نمی‌آید.

۲. فرایند آموزش: فرایند آموزش مدل‌های هوش مصنوعی ممکن

جدول ۱. برخی مهم ترین عوامل کلیدی و پیشران های مؤثر در آینده

ویژندسازی برخط

ردیف	نوع عامل	متغیر	میزان اهمیت ۱۰-۰	میزان عدم قطعیت ۱۰-۰
۱	سیاست های دولتی	سیاست های دولتها و نهادهای بین المللی در زمینه حفظ حریم خصوصی	۵،۷۱	۳،۴۳
		سیاست های به کارگیری شده دولتها در موضوع امنیت سایبری	۸،۲۹	۴،۴۳
		خط مشی های دولتی در حفظ حریم خصوصی کاربران و حقوق مالکیت معنوی	۶،۸۶	۴،۴۳
		تحریم های تجاری دولتها بر روی ویژندهای خاص و یا جوامع هدف خاص	۷،۲۹	۶،۴۳
۲	زیست محیطی	تأثیر تغییرات آب و هوایی، کاهش منابع طبیعی، کاهش زباله ها و کربن پایین در استقبال مردم از ویژندهای برخط ^۲	۶،۵۷	۴،۴۳
		تأثیر چگونگی بسته بندی ویژندها و تأثیر آن در آلودگی های زیست محیطی	۶،۴۳	۵
۳	فناوری و نوآوری	ضعف قوانین و مقررات حوزه کاربردی هوش مصنوعی	۶،۴۳	۶،۵۷
		کمبود راهبرد پیاده سازی، مسائل حقوقی و عدم درک مدیران از هوش مصنوعی	۶،۱۴	۵،۸۶
		پایبندی هوش مصنوعی به قوانین و مقررات محلی و ملی	۷،۱۴	۶،۱۴
۴	تجارت	کمبود داده های با کیفیت به عنوان ورودی	۷،۱۴	۶
		تأثیر هوش مصنوعی در توسعه و بهبود خدمات مشتری	۶،۸۶	۵،۵۷
		تغییرات و نظام های فناورانه در جمع آوری خودکار و بهینه داده های مشتریان و تحلیل و استخراج الگوریتم های پیشرفته به منظور ارائه پیشنهادات مناسب و سفارشی شده	۸،۱۴	۴،۸۶
		رانش داده ها و یادگیری عمیق و توسعه شخصی سازی خدمات به واسطه هوش مصنوعی	۷،۲۹	۴،۸۶
		توسعه بهینه سازی موتورهای جستجو با هدف بهینه سازی خدمات مشتریان و بازاریابی برخط	۷،۴۳	۵،۷۱
		بهبود تجربه خرید و خدمات دیجیتال با استفاده از واقعیت افزوده	۵،۲۹	۵،۸۶
		تحلیل حجم عظیم داده های مشتریان با هوش مصنوعی	۸	۴
		تأثیر فناوری های نوین از جمله هوش مصنوعی بر پذیرش ویژندسازی برخط	۶،۸۶	۳،۷۱
۵	فرهنگ و اخلاق	پذیرش ویژندهای برخط و وفاداری مشتریان به آن	۷	۵،۱۴
		قابلیت اطمینان و رعایت اصول اخلاقی در به کارگیری هوش مصنوعی	۶،۱۴	۶،۲۹
		پذیرش و اعتماد مشتریان به هوش مصنوعی	۵،۸۶	۶
		تأثیر عوامل اجتماعی و فرهنگی نظیر سلاقی، نگرش ها، باورها، رفتارها و الگوهای مصرف مشتریان	۶،۵۱	۴،۲۳
۶	مالی	تأثیر شبکه های اجتماعی بر ایده ها و سلاقی مشتریان	۶،۸۵	۴،۸۵
		تأثیر اقتصادی محدودیت های اقتصادی بر بازاریابی و توسعه ویژند	۷،۹	۵،۹۶
		تأثیر شرایط اقتصادی و رقابت بازار بر روی راهبردهای ویژندسازی برخط	۶،۷۸	۶،۲۱
		تأثیر نوسانات نرخ ارز، تورم و نرخ بهره بر روی قدرت خرید مشتریان و سودآوری شرکت ها	۶،۹۷	۶،۲۵
		تأثیر هوش مصنوعی در توسعه مشتری مداری و بهبود بازار	۷،۵۶	۵،۲۲
		تأثیر هوش مصنوعی در توسعه توجه بازارهای برخط	۷،۹۱	۴،۹۵

در انتخاب روش شناسی این امکان وجود دارد که نوعی از روش شناسی بکار گرفته شود که با جهان اجتماعی همانند جهان طبیعی برخورد کند و آن را پدیده ای خشک، واقعی و مستقل از انسان در نظر بگیرد درعین حال این امکان هم وجود دارد که برای جهان اجتماعی کیفیتی نرم تر، انسانی تر و ذهنی قابل شد. [۵۰]

بنابراین باتوجه به ارتباط روش شناسی با پارادایم های علم و ارتباط آن با روش های جمع آوری و تحلیل اطلاعات، آنگاه روش هایی که با کمک آینده پژوهی بکار گرفته می شوند، ضمن ایجاد تنوع ابزار با هدایت محقق به سوی روشی کامل تر برای جمع آوری اطلاعات تضمین بیشتری را برای موفقیت به همراه دارند و البته ارزش ها نیز در بطن روش های بکار گرفته لحاظ خواهند شد.

دسته بندی های گوناگونی از روش های مورد استفاده آینده پژوهان مطرح شده است. برای مثال گوردون بین روش های کمی و کیفی، از یک سو و بین روش های اکتشافی و هنجاری، از سوی دیگر تمایز قائل می شود. [۱۶] دلیو وارن ویگار^۳ در مقاله خود تحت عنوان «آینده پردازی» بر این باور است که روش های آینده پژوهی در طیفی گسترده از روش های مبتنی بر ریاضیات پیشرفته تا روش های شهودی و گمانه زنی گسترده شده اند. باین حال وی از پنج روش شناسی رایج و پر کاربرد نام می برد که هم اینک بیش از دیگر روش ها به کار گرفته می شوند؛ برون یابی روند، مدل سازی ریاضی، تکنیک دلفی، سناریو پردازی (می تواند تخیل علمی را نیز در بر بگیرد)، فن های پیش بینی (احتمال سنجی) [۴۹]

منطق شهودی که در این تحقیق برای نگارش سناریو مورد استفاده قرار گرفته نخستین بار توسط پیپر واک (۱۹۸۵) توصیف شد بهترین شیوه برای استفاده از اطلاعات در دسترس پیرامون آینده است و این پژوهش به دلایلی که ذیلاً مورد اشاره قرار گرفته آن را مورد استفاده قرار داده است.

و به عملکرد ESG خود توجه دارند. برخی از روش های موثر در این زمینه عبارتند از: استفاده از بسته بندی های قابل بازیافت و کم حجم، استفاده از منابع انرژی تجدید پذیر، کاهش تأثیرات منفی حمل و نقل و لجستیک، حمایت از پروژه های حفاظت از محیط زیست و گزارش دهی شفاف در مورد پایبندی به استانداردهای محیط زیست.

³ W.Warren Wagar

^۱ عدم قطعیت ها ناشناخته های مهم در مورد آینده اند که می توانند بیشترین تفاوت و تمایز را ایجاد نمایند. بدیهی است پیشران ها به شناسایی عدم قطعیت ها کمک شایانی بنمایند. نک: برنامه ریزی سناریو، راهنمایی به سوی آینده تالیف وید وودی ترجمه و تنظیم رصدخانه علم و فناوری پژوهشگاه شاخص پژوه، انتشارات دارخوین، اصفهان، ۱۳۹۳ص ۳۵

^۲ در این ارتباط باید تاکید شود امروزه شرایط به گونه ای است که شرکت های آنلاین باید نشان دهند که در راستای حفاظت از سلامت سیاره فعالیت می کنند

جدول ۲. مدل‌های طراحی سناریو [۱۹]

عنوان	مدل سازمانی	مدل مشارکتی	مدل متخصص
نحوه کار طرح	به‌تنهایی	با همکاری یک گروه در سازمان	با آموزش و راهنمایی سازمان
کنترل	طراح فرایند را کنترل می‌کند	طراح در فرایند شرکت کرده و آن را رهبری می‌کند	طراح بیرون از فرایند است
نتیجه	توسط طراح ارائه می‌شود	به دست گروه سپرده می‌شود و توسط همان گروه ارائه می‌شود	در دست سازمان قرار دارد
رابطه	طراح کار را کامل می‌کند	طراح رابطه با گروه را حفظ می‌کند	طراح مسئولیت را به گروه واگذار می‌کند

گام‌های روش GBN که در این تحقیق مورد بهره‌برداری قرار گرفته عبارت‌اند از:

(۱) مرحله نخست: شناسایی موضوع یا تصمیم اصلی یعنی آینده ویتند سازی برخط با تأکید بر هوش مصنوعی است.

(۲) مرحله دوم: شناسایی و مطالعه نیروهای کلیدی^۱ مؤثر در ویتند سازی برخط باتوجه به ظهور و بروز هوش مصنوعی است.

(۳) مرحله سوم: که برای یافتن نیروهای پیشران در کلان محیط انجام شد، گزاره‌هایی را پیش روی این پژوهش قرار داد. در این مرحله نیز پیشران بر اساس مدل «PESTEL» مرتب شدند.

(۴) مرحله چهارم: رتبه‌بندی عوامل کلیدی و پیشران‌ها بر اساس میزان اهمیت و عدم قطعیت

(۵) مرحله پنجم: انتخاب منطق سناریو بر اساس وزن و عدم قطعیت عوامل کلیدی و پیشران‌های روندها

(۶) مرحله ششم: شکل‌دهی و توسعه سناریو باتوجه به عوامل کلیدی و پیشران‌ها

و سرانجام بررسی مضامین سناریوهای توسعه‌یافته و انتخاب پیش‌نشانگرها در مراحل هفتم و هشتم.

لازم به یادآوری است تحقیق پیش رو به لحاظ رویکرد از نوع آمیخته اکتشافی است که در خلال آن داده‌ها در هر مرحله به‌صورت کیفی جمع‌آوری و سپس با کمک روش‌های کمی تجزیه و تحلیل، اولویت‌بندی و وزن‌دهی شده و سرانجام به اعتبارسنجی و نمایش داده پرداخته شده است. جامعه آماری این تحقیق که بیشتر بر اساس مطالعه ادبیات و اکتشاف به‌دست‌آمده شامل تعداد ۲۴ نفر از صاحب‌نظران، خبرگان، کارگزاران و متصدیان حوزه مدیریت و بازاریابی با مدارک تحصیلی دکتری و کارشناسی‌ارشد و کارشناسی که با موضوعات ویتند سازی، بازرگانی و فناوری اطلاعات آشنا بوده یا در این حوزه‌ها ذیل عناوین کارشناس و بالاتر مشغول به کار بوده‌اند به‌صورت هدفمند انتخاب گردیده‌اند.


نمونه‌برداری از جامعه آماری به‌صورت هدفمند کیفی بوده و با روش همتا گزینی و گلوله‌برفی توسعه‌یافته است. در ارتباط با حجم

این پژوهش ضمن بهره‌برداری از منطق شهودی، برای خلق و توسعه سناریو یکی از روش‌های توسعه سناریو را که مبتنی بر ترسیم دو محور، بر اساس عدم قطعیت‌های کلیدی است مورد استفاده قرار داده و باتوجه به وزن عوامل کلیدی و پیشران‌ها که از سوی خبرگان مورد اندازه‌گیری قرار گرفته و نیز میزان عدم قطعیت آنها و سرانجام باتوجه به دو عدم قطعیت کلیدی مدنظر خبرگان و البته با کمک هوش مصنوعی نسبت به توسعه سناریوها اقدام نموده است.

از آنجایی که این پژوهش به توسعه، بازبینی و بازشناسی مفاهیم در حوزه ویتندسازی برخط پرداخته و برای اصلاح، بهبود و گسترش شیوه جدیدی از تفکر و برنامه‌ریزی با استفاده از فضای ترسیم شده برای آزمون و بررسی پیامد تصمیمات متخذه تلاش نموده و درعین حال از آن جهت که در آن کوشش شده تا با استفاده از مهارت‌ها، فنون و روش‌های آینده‌پژوهی برای حل مشکل موردبحث اقدام شود بر مبنای نتایج و دستاوردها از نوع کاربردی است. همچنین باتوجه به اینکه در خلال آن به توسعه یکی از انواع روش‌های کیفی نگارش سناریو موسوم به GBN پرداخته شد، از نوع توسعه‌ای است. همچنین بر مبنای ماهیت و هدف باتوجه به اکتشاف عوامل کلیدی و پیشران‌های مؤثر در شکل‌گیری آینده تأثیر هوش مصنوعی در ویتندسازی برخط، از نوع اکتشافی و با عنایت به توصیف فضای آینده، توصیفی می‌باشد.

نیست نظیر تأثیر اخلاق و مولفه‌های اخلاقی در آینده هوش مصنوعی. نک: برنامه

^۱ پیشران یا نیروی محرک چیزی با احتمال ایجاد تغییری چشمگیر در آینده است که ممکن است یک روند باشد و یا متغیری که دارای احتمال تغییر در آینده بوده لکن به دلیل آنکه خود به چند عامل بستگی دارد خیلی قابل پیش‌بینی



شکل ۲. ماتریس سناریو و نواحی چهارگانه آن که تحت تأثیر عدم قطعیت‌های کلیدی مدنظر خبرگان شکل گرفته است

۴-۲- تحلیل یافته‌های تحقیق

سناریو ۱: «بهشت کسب‌وکارها؛ سیاست‌های حمایتی جهانی و قانون‌گذاری مناسب برای رشد هوش مصنوعی»

دولت‌ها راهکارهای مؤثری را برای تنظیم قوانین و مقررات هوش مصنوعی طراحی و اجرا می‌کنند و همکاری نزدیکی با ویژندها و جوامع هدف دارند.

در این سناریو، دولت‌ها قوانین حمایتی و شفاف‌ی برای کاربرد هوش مصنوعی وضع می‌کنند. امنیت سایبری تقویت می‌شود و تحلیل داده‌ها به کمک هوش مصنوعی بهبود می‌یابد. شرکت‌ها با استفاده از هوش مصنوعی خدمات شخصی‌سازی‌شده‌ای ارائه می‌دهند و راهبردهای پیاده‌سازی قوی دارند. اعتماد و اعتقاد مردم ضمن توسعه نظارت‌های قانونی و همکاری‌های بین‌المللی، رشد بازار هوش مصنوعی و کسب‌وکارهای مبتنی بر آن از جمله کلان‌داده‌ها و ... را به همراه داشته و این امر در نهایت رشد کسب‌وکارهای فضای مجازی و رفاه و آسایش بیشتری را به نمایش گذاشته است. رشد جرایم مبتنی بر فضای مجازی به دلیل همکاری‌های بین‌دولتی در کنترل دولت‌هاست.

نمونه نیز یک قانون کلی وجود دارد؛ «بزرگ‌ترین اندازه ممکن نمونه، مناسب است.» ضمن آن که نمونه‌گیری در تحقیقات کیفی تقریباً همیشه هدفمند است. حجم نمونه ۱۲ نفر از جامعه آماری بوده که به‌صورت هدفمند در دسترس و گلوله‌برفی‌گزینش شده‌اند. یادآور می‌شود قاعده کلی در تحقیق‌های کیفی، استفاده از حجم ۱ تا ۲۰ تایی است و برای تعیین حجم نمونه می‌توان با مرور ادبیات و از تحقیق‌های مشابه نیز بهره برد. [۴۸]

جمع‌آوری داده‌های این تحقیق عمدتاً کیفی با کمک بررسی‌های اسنادی، کتابخانه‌ای و وب‌گردی و در بخش کمی نیز با کمک مصاحبه و پرسش‌نامه گردآوری شده‌اند و در مراحل جمع‌آوری و تحلیل از هوش مصنوعی نیز استفاده نموده است.

برای روایی و پایایی ابزار تحقیق در این پژوهش (قابلیت اعتماد و باورپذیری) از روش‌های مثلث‌سازی (زاویه‌بندی) استفاده شده که در خلال آن از منابع متعدد، تعدد خبرگان در حوزه‌های فناوری، بازاریابی و دانشگاهی، استفاده از خروجی پژوهش‌شکده‌ها و پژوهشگران معتبر و ارزیابی‌های متعدد و متنوع بهره‌گیری شده و به‌منظور تعیین روایی صوری، محتوا و سازه از طریق مراجعه به آرای خبرگان بهره‌برده و سرانجام برای پایایی ابزار تحقیق (پرسش‌نامه) از محاسبه آلفای کرونباخ استفاده شده است که عدد ۰/۸۵، به‌دست‌آمده نشان دهند پایایی ابزار بوده است.

۴- نتیجه‌گیری و پیشنهادات

۴-۱- یافته‌های تحقیق (سناریوهای تدوین شده)

روش‌های سه و چهار سناریویی روش‌های معمول نگارش سناریو هستند. چهار سناریویی بدیل ویژندسازی برخط به کمک هوش مصنوعی در افاق ۲۰۲۵ با عنایت به عدم قطعیت‌های کلیدی تحریم‌های تجاری دولت‌ها بر روی ویژندهای خاص و یا جوامع هدف خاص و ضعف قوانین و مقررات حوزه کاربردی هوش مصنوعی به شرح زیر خواهد بود که در امتداد محورهای ناشی از عدم قطعیت‌ها به نگارش در خواهند آمد، این دو محور در شکل ۲ نشان داده شده‌اند.

برای تدوین چهار سناریو بر اساس روش هشت‌مرحله‌ای پیترو شوارتز و شبکه جهانی کسب‌وکار (G.B.N) باتوجه به عدم قطعیت‌های کلیدی مدنظر خبرگان، می‌توان به ارزیابی و تحلیل تهدیدها و فرصت‌ها در هر یک از حوزه‌ها پرداخت. در زیر چهار سناریو باتوجه به شرایط مختلف ارائه می‌شود.

سناریو ۲: «بحران داده و عدم امنیت؛ سیاست‌های حمایتی جهانی در شرایط قانون‌گذاری نامناسب دولت‌ها»

ضعف قوانین، ویژندها به دلیل سرقت داده‌ها و عدم تطابق با استانداردها آسیب می‌بینند؛ اما سیاست‌های تجاری حمایتی جهانی و فقدان تحریم‌ها رشد نسبی ویژندهای تجاری را به دنبال خواهد داشت.

در این سناریو، هوش مصنوعی پیشرفت‌هایی را تجربه می‌کند و تحلیل داده‌ها بهبود می‌یابد، اما قوانین و مقررات امنیت سایبری ضعیف هستند. این موضوع باعث افزایش حملات سایبری و مشکلات امنیتی می‌شود. شرکت‌ها خدمات شخصی‌سازی شده‌ای ارائه می‌دهند، اما با چالش‌های امنیتی زیادی مواجه هستند. حریم خصوصی مردم به دلیل ضعف قوانین با چالش‌هایی مواجه بوده و حکمرانی داده در دولت‌ها آسیب‌های را تجربه می‌کند. علی‌رغم سیاست‌های تجاری حمایتی بین‌الملل از ویژندهای برخط ضعف قوانین و مقررات داخلی آسیب‌های جدی به ویژندها وارد و اعتماد مردم را در مواردی با سستی همراه نموده است. تقلب و فریب ویژندهای برخط در سایه قوانین نه‌چندان مناسب داخلی دولت‌ها حجم بازار کسب‌وکارها در فضای مجازی را با اختلالاتی مواجه نموده به گونه‌ای که این کسب‌وکارها رشد متوسطی را تجربه می‌کنند تأثیر هوش مصنوعی در توسعه مشتری‌مداری و بهبود بازار متوسط و نسبتاً موفق بوده؛ اما آسیب ناشی از قوانین ناکارآمد چالش‌هایی را به مردم تحمیل می‌نماید.

به دلیل ضعف قانونی نارضایتی‌های اجتماعی در این زمینه شاهد رشد نسبی است، مشارکت‌های اجتماعی در حوزه فاوا، ویژندسازی و هوش مصنوعی کاهش یافته و رشد اقتصاد دیجیتال در G.D.P دولت‌ها قابل توجه نیست. سرمایه‌گذاری در توسعه فناوری‌ها به دلیل نگرانی‌ها از حمایت قانونی به‌ویژه در هوش مصنوعی و برندینگ کاهش یافته، آسیب‌پذیری‌های امنیت هم‌زمان شاهد افزایش نسبی است.

ویژگی‌ها:

- کاهش اعتماد مشتریان به ویژندها و خدمات برخط.
- هزینه‌های بالا برای جبران آسیب‌های ناشی از نقض داده‌ها
- عدم توانایی در بهره‌برداری مؤثر از امکان شخصی‌سازی به دلیل فقدان داده‌های قابل اعتماد

بهبود فضای کسب‌وکارهای دیجیتال توسعه ویژندسازی در فضای داخلی کشورها را به همراه داشته، نارضایتی‌های کمتری در محدوده ملی دولت‌ها را به دنبال خواهد داشت که این امر بهبود سرمایه اجتماعی و مشارکت‌های اجتماعی را به دنبال دارد. توسعه فناوری‌های ارتباطی و اطلاعاتی به دلیل بهبود فضای کسب‌وکار، سرمایه‌گذاری در این بازار را به همراه دارد که به دلیل نقش پیش‌رانی فناوری‌های نوآیند، سهم اقتصاد دیجیتال از G.D.P افزایش داشته، تسهیلات دولت‌ها برای توسعه این بخش از کسب‌وکارها به‌ویژه هوش مصنوعی که سهم بالایی از اقتصاد جهانی در حوزه فناوری‌های نوین به خود تخصیص می‌دهد.

ویژگی‌ها:

- جلب اعتماد مصرف‌کنندگان به دلیل شفافیت و انطباق قانونی.
- ویژندها از داده‌های مشتریان با اطمینان بیشتری استفاده می‌کنند و اعتماد مشتریان به ویژندها بالاتر است.
- شخصی‌سازی خدمات در سطح بالایی است.
- توجه دولت‌ها به بهبود قوانین کسب‌وکار دیجیتال و توسعه ویژندها بالاست.

چالش‌ها:

- نیاز به تغییر مستمر در شیوه‌های مدیریتی برای انطباق با قوانین روز
- رشد پیچیدگی جرایم رایانه‌های هم‌زمان با توسعه هوش مصنوعی
- چالش‌های حکمرانی داده و مدیریت کلان داده‌ها (چالش دزد و پلیس به دلیل رشد روزافزون تقلب)
- چالش‌های ناشی از رشد ویژندهای تقلبی و همکاری گروه‌های فرو دولتی متقلب

نشانه‌های^۱ وقوع این سناریو:

- توجه دولت‌ها به قوانین و مقررات حوزه فاوا و کنش‌گری فعال دولت و بخش خصوصی در این زمینه
- گشایش‌های بین‌المللی و توسعه ارتباطات بین‌بخشی جهانی برای توسعه ویژندها، هوش مصنوعی و قوانین مرتبط
- افزایش ویژندهای بین‌المللی
- توسعه سرمایه‌گذاری در هوش مصنوعی از سوی کنشگران غیردولتی و بخش خصوصی

¹ Leading Indicator

چالش‌ها:

- تقویت نیاز به تدوین راهبردهای امنیت سایبری قوی و مؤثر
- تقویت قوانین و مقررات و تلاش برای ترمیم آسیب‌های ناشی از آن

نشانه‌های وقوع این سناریو:

- بی‌توجهی و یا توجه منفعل دولت‌ها به قوانین و مقررات حوزه فاوا و کنش‌گری نه‌چندان کارآمد دولت و در عین حال تلاش بخش خصوصی در این زمینه به دلیل گشایش‌های جهانی
- حمایت‌های بین‌المللی و توسعه ارتباطات بین‌بخشی جهانی برای توسعه ویژندها، هوش مصنوعی در سایه حمایت قوانین بین‌المللی
- رشد نسبی ویژندهای بین‌المللی و رشد آهنگ مهاجرت ویژندها و شرکت‌های فعال و موفق
- کاهش نسبی سرمایه‌گذاری در توسعه هوش مصنوعی از سوی کنشگران غیردولتی و بخش خصوصی

سناریو ۳: «رشد در سایه؛ حمایت‌های قانونی کاربردی برای توسعه برندینگ برخط به کمک هوش مصنوعی همراه با تحریم تجاری بین‌الملل ویژندها»

دولت‌ها به سرعت به بهره‌برداری از هوش مصنوعی می‌پردازند؛ اما اعمال تحریم‌های فرا دولتی مشکلاتی را برای توسعه ویژندهای برخط به کمک هوش مصنوعی ایجاد نموده است.

توسعه ویژندهای برخط به کمک هوش مصنوعی احتمالاً به دلیل عدم درک مدیران از هوش مصنوعی با مشکلاتی مواجه می‌شود. دولت‌ها قوانین حمایتی را وضع می‌کنند که باعث توسعه نسبی ویژندسازی برخط و کسب‌وکارها می‌شود. امنیت سایبری تقویت می‌شود، اما تحلیل داده‌ها به دلیل توسعه تحریم‌ها آسیب جدی دیده و شخصی‌سازی خدمات بهبود اندک تا متوسطی را تجربه می‌کند.

توسعه شخصی‌سازی خدمات با وجود محدودیت‌های بین‌المللی به دلیل سیاست‌های داخلی و قوانین و مقررات مناسب در داخل کشورها رشد مناسبی را تجربه می‌کند و این امر وفاداری داخلی ویژندهای برخط و بهبود فضای کسب‌وکارهای مرتبط را به همراه داشته است. تلاش شبکه‌های اجتماعی برای مدیریت توجه مشتریان در سایه رشد قابل قبول هوش مصنوعی نقش شخصی‌سازی خدمات را پررنگ‌تر کرده است.

تحریم‌ها آهنگ رشد هوش مصنوعی و ویژندسازی جهانی در عرصه

جهانی را کاهش داده؛ اما حمایت‌های فعالانه داخلی به رشد نسبی سرمایه اجتماعی دولت انجامیده است. سهم اقتصاد دیجیتال در G.D.P رشد نسبی داشته دولت تلاش می‌کند فعالانه خدمات حمایتی در حوزه‌های ذی‌ربط از شرکت‌های فعال این حوزه را با ایجاد نهادها و قوانین مناسب افزایش دهد. هم‌زمان محرومیت‌های جهانی سرمایه‌گذاری در حوزه فاوا را کاسته به ممانعت از توسعه جهانی ویژندهای داخلی افزوده است.

ویژگی‌ها:

- افزایش سریع در استفاده از هوش مصنوعی و داده‌ها در داخل اما البته توأم با محدودیت‌های بین‌المللی
- افزایش تمایل ویژندها به شخصی‌سازی همراه با نگرانی از عواقب آن

چالش‌ها:

- نتیجه‌های غیرقابل پیش‌بینی و ایجاد چالش‌های اجتماعی به علت عدم درک کافی فناوری.
- چالش‌های بین‌المللی کسب‌وکارها و ویژندهای برخط

نشانه‌های وقوع این سناریو:

- توجه دولت‌ها به قوانین و مقررات حوزه فاوا و کنش‌گری فعال دولت و بخش خصوصی در این زمینه
- مضایق بین‌المللی و کاهش آهنگ توسعه ارتباطات بین‌بخشی جهانی برای توسعه ویژندها، هوش مصنوعی و قوانین مرتبط
- کاهش ویژندهای بین‌المللی
- کاهش آهنگ توسعه سرمایه‌گذاری در هوش مصنوعی از سوی کنشگران غیردولتی و بخش خصوصی به دلیل ممانعت‌های جهانی

سناریو ۴: «تعاونی نوآورانه؛ محدودیت‌های جهانی همراه با ضعف قوانین و مقررات دولتی»

شرایط: ویژندها در تلاش‌اند تا در سایه ضعف قوانین و مقررات داخلی دولت‌ها و سیاست‌های محدودکننده بین‌المللی با ایجاد همکاری‌های چندجانبه با جوامع هدف، به تدوین بهترین روش‌ها برای استفاده و توسعه هوش مصنوعی در کسب‌وکارهای دیجیتال و ویژندهای برخط بپردازند.

در این سناریو، محدودیت‌های شدیدی بر ویژندها و جوامع هدف خاص اعمال می‌شود و قوانین و مقررات هوش مصنوعی ضعیف و ناکافی کسب‌وکارهای فعال در فضای مجازی را در سایه امنیت سایبری ضعیف دچار مشکلات اساسی نموده و تحلیل داده‌ها با

- برندینگ از سوی کنشگران غیردولتی و بخش خصوصی
- فرار سرمایه‌های انسانی و اقتصادی از حوزه فاوا و برندینگ

۴-۳- برخی پیشنهادات برای توسعه ویژندسازی برخط به کمک هوش مصنوعی

شخصی‌سازی یکی از مزایای هوش مصنوعی برای کسب‌وکارها است که می‌تواند به کمک تحلیل داده‌های گردآوری شده را تسهیل می‌کند. به این ترتیب، ویژندهای برخط می‌توانند با کمک هوش مصنوعی و توجه به رفتار، علایق و نیازهای هر مشتری، پیام‌ها، محتوا، پیشنهادات و تخفیفات را سفارشی و ایشان را به فعالیت تجاری ترغیب نماید.

ارائه هوشمند خدمات به مشتری زمینه دیگری است که می‌تواند به کمک هوش مصنوعی تحولات شگرفی را تجربه کند. ویژندهای برخط می‌توانند از هوش مصنوعی برای ارائه پاسخ سریع، دقیق و مناسب به سؤالات و درخواست‌های مشتریان و حتی ارائه خدمات مشاوره به ایشان استفاده کنند. این کار با استفاده از چت‌بات‌ها، تحلیل داده‌های ورودی، شناسایی احساسات و تولید خودکار پاسخ صورت می‌گیرد.

بهبود راهبردهای ویژندسازی برخط به کمک هوش مصنوعی به ویژندهای برخط کمک می‌کند تا راهبردهای بازاریابی خود را بهینه‌سازی کنند. این شامل تعیین بازار هدف، طبقه‌بندی مشتریان، پیدا کردن الگوهای خرید، پروفایل‌سازی شخصی، پیش‌بینی نتایج و اندازه‌گیری بازدهی سرمایه‌گذاری خواهد بود.

هوش مصنوعی به ویژندهای برخط امکان می‌دهد تا نظارت و کنترل بیشتری بر روی نظرات و بازخوردهای مشتریان داشته باشند. با استفاده از هوش مصنوعی، ویژندها می‌توانند منابع مختلف رسانه اجتماعی، وبلاگ‌ها، فروم‌ها و وبگاه‌های بررسی را جستجو کنند و به صورت خودکار نظرات منفی را شناسایی، جمع‌بندی و رسیدگی کنند.

ایجاد خودکار محتوا به کمک هوش مصنوعی می‌تواند به ویژندهای برخط کمک کند تا محتوای جذاب و مفید را برای مخاطبان خود تولید کنند. این شامل ایجاد عنوان‌ها، خلاصه‌ها، متن‌ها، تصاویر، ویدئوها و صداها است. هوش مصنوعی می‌تواند با تحلیل داده‌های مشتریان و رقبا، محتوایی را ایجاد کند که بهترین عملکرد را در رسانه‌های اجتماعی، موتورهای جستجو و سایر کانال‌ها داشته باشد.

مشکلات زیادی مواجه است. شرکت‌ها در پیاده‌سازی هوش مصنوعی با چالش‌های زیادی روبرو هستند.

عدم پایبندی بهره‌برداران از هوش مصنوعی به قوانین و مقررات و ضعف قوانین مربوط به استفاده از داده‌های کلان، اغلب به توسعه جرایم رایانه‌های و کاهش وفاداری مشتریان منجر شده و به همین دلیل علی‌رغم توسعه شبکه‌های اجتماعی ویژندهای برخط در داخل و خارج کشورها آسیب‌های اساسی دیده‌اند.

اعتماد مشتریان به کسب‌وکارهای مجازی و هوش مصنوعی دچار آسیب جدی است و حجم بازارهای برخط کاهش شدیدی را تجربه کرده است. نارضایتی‌های اجتماعی و شرکت‌های فعال این حوزه به شدت روبه‌رشد بوده، سرمایه‌های انسانی و اقتصادی تلاش می‌کنند در پوشش‌های مختلف از کشور خارج شوند. سهم اقتصاد دیجیتال از G.D.P بسیار پایین‌تر از میزان جهانی است و رشد حوزه فاوا کاهش قابل توجهی را تجربه می‌کند. کاهش مشارکت‌های فعالانه بخش فاوا در اقتصاد، نارضایتی و گریز سرمایه‌های بخش خصوصی را به دنبال داشته است.

ویژگی‌ها:

- ایجاد راهبردهای مشترک که شامل تضمین امنیت داده‌ها و خصوصی‌سازی خدمات می‌شود.
- رشد آگاهی مدیران از مزایای هوش مصنوعی و نحوه اجرای مؤثر آن.
- کاهش شفافیت و اعتماد مشتریان به ویژندهای برخط و هوش مصنوعی.

چالش‌ها:

- نیاز به زمان و منابع برای آموزش و توسعه راهبردهای نوآورانه.
- چالش‌های شخصی‌سازی خدمات و اعتماد متقابل کسب‌وکارها و مشتریان.

نشانه‌های وقوع این سناریو:

- بی‌توجهی دولت‌ها به قوانین و مقررات حوزه فاوا و کنش‌گری منفعل و گاه بی‌توجهی دولت و نگرانی بخش خصوصی در این زمینه
- محدودیت‌های بین‌المللی و کاهش شدید آهنگ توسعه ارتباطات بین‌بخشی جهانی برای توسعه ویژندها، هوش مصنوعی
- کاهش ویژندهای بین‌المللی
- کاهش شدید توسعه سرمایه‌گذاری در هوش مصنوعی و

مراجع

- [۱۶] بل، وندل (۱۳۹۲) مبانی آینده‌پژوهی، ترجمه مصطفی تقوی، محسن محقق، تهران، انتشارات مرکز آینده‌پژوهی علوم و فناوری دفاعی
- [۱۷] چرماک توماس جی، (۱۳۹۳) ترجمه سعید خزایی و مریم وکیل‌زاده، برنامه‌ریزی بر پایه سناریو، اصفهان، انتشارات شاخص پژوه
- [۱۸] وندرهیدن، کیس و شارپ، بیل (۲۰۰۷) ترجمه مسعود منزوی، سناریو برای کسب موفقیت، تهران، مرکز آینده‌پژوهی علوم و فناوری دفاعی مؤسسه آموزشی و تحقیقاتی صنایع دفاعی
- [۱۹] مایترز، دانا و رگر، گویدو (۱۳۸۸)، ترجمه مسعود منزوی، رویکردها و دیدگاه‌های مختلف در سناریو، تاریخ، تفاوت‌ها، مزایا و کمبودها، تهران، مرکز آینده‌پژوهی علوم و فناوری دفاعی مؤسسه آموزشی و تحقیقاتی صنایع دفاعی
- [۲۰] برادفیلد، رون، (۱۳۸۶) ترجمه مسعود منزوی، سناریوها برای کسب موفقیت، تسهیل فرایند بسط سناریو: چند درس برای تسهیل‌گران، تهران، مرکز آینده‌پژوهی علوم و فناوری دفاعی مؤسسه آموزشی و تحقیقاتی صنایع دفاعی
- [21] A. Kaplan and M. Haenlein, "Rethinking AI: Learning from history," *Harvard Business Review*, vol. 97, no. 4, pp. 96-103, 2019
- [22] D. Chaffey, *Digital marketing: Strategy, implementation, and practice*, 7th ed. London, UK: Pearson Education, 2021.
- [23] O. Farshad et al., "Spermatotoxic effects of single-walled and multi-walled carbon nanotubes on male mice," *Frontiers in Veterinary Science*, vol. 7, Article 591558, 2020, doi: [10.3389/fvets.2020.591558]([https://doi.org/10.3389/fvets.2020.591558])
- [24] M. H. Tito, "A comparative analysis of organizational data management practices: Insights from literature and AI perspectives for business efficiency and effectiveness," Master's thesis, University of Oulu, 2023.
- [25] A. Haleem, M. Javaid, and R. P. Singh, "An era of ChatGPT as a significant futuristic support tool: A study on features, abilities, and challenges," *BenchCouncil Transactions on Benchmarks, Standards and Evaluations*, vol. 2, no. 4, 2023.
- [26] K. Colombi, "Ethical implications in the process of AI-powered research platforms," Polytechnic University of Milan, Firenze University Press, 2023
- [27] B. C. O'Neill et al., "The scenario model intercomparison project (ScenarioMIP) for CMIP6," *Geoscientific Model Development*, vol. 9, no. 9, pp. 3461-3482, 2016
- [28] S. Khan, "Understanding the rise of artificial intelligence in the Norwegian banking sector: Reflection and settlement of trust, perceived behavior and consequences," Abadar University Oslo, 2023
- [۲۹] ز. تخشید، "مقدمه‌ای بر چالش‌های هوش مصنوعی در حوزه مسئولیت مدنی،" حقوق خصوصی، دوره ۱۸، شماره ۱، ۱۴۰۰.
- [30] Artificial intelligence (AI) worldwide – Statistics & facts," Statista, 2023. [Online]. Available: [https://www.statista.com/topics/3104/artificial-intelligence-ai-worldwide/]([https://www.statista.com/topics/3104/artificial-intelligence-ai-worldwide/])
- [31] The state of AI in 2022 and a half decade in review," McKinsey & Company, 2022. [Online]. Available: [https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2022-and-a-half-decade-in-]
- [۱] م. ساکی و س. مهربان، "تأثیر بازاریابی رسانه‌های اجتماعی (وبسایت) بر روی وفاداری به برند با در نظر گرفتن نقش میانجی‌گرانه اعتماد به برند؛ (مطالعه موردی: شبکه اجتماعی اینستاگرام)،" مطالعات مدیریت و کارآفرینی، دوره ۴، شماره ۱/۱، صص. ۳۶-۴۵، بهار ۱۳۹۷.
- [2] X. Liu, H. Shin, and A. C. Burns, "Examining the impact of luxury brand's social media marketing on customer engagement: Using big data analytics and natural language processing," *Journal of Business Research*, vol. 125, pp. 815-826, 2021, doi: [10.1016/j.jbusres.2019.04.042]([https://doi.org/10.1016/j.jbusres.2019.04.042]).
- [3] S. Habachi, J. Matute, and R. Palau-Saumell, "Unlocking the effect of the gameful experience on brand loyalty and intention to use: The mediating role of customer brand engagement," *Journal of Marketing Management*, 2023.
- [4] R. Agus, D. Utama, and R. Novianty, "The impact of online customer reviews on purchase intention in online marketplace," *International Journal of Economics and Business Research*, vol. 10, no. 2, pp. 123-135, 2021
- [۵] ر. امیری‌مقدم، س. ج. امینی، م. نوروزی، و د. فیاضی، "مقاله پژوهشی: سناریوهای تهدیدات امنیتی عربستان علیه جمهوری اسلامی ایران در افق ۱۴۰۴،" امنیت ملی، جلد ۹، شماره ۳۲، صص. ۲۳-۴۹، ۱۳۹۸.
- [6] E. Brynjolfsson and A. McAfee, "The business of artificial intelligence," *MIT Sloan Management Review*, vol. 59, no. 1, pp. 1-10, 2017
- [7] X. Li and R. Du, "AI-powered branding: Opportunities and challenges," *Journal of Digital Marketing*, vol. 12, no. 3, pp. 45-60, 2020
- [8] A. Halinen and S. Nordberg-Davies, "Time to look forward: Supporting future orientation in business network research," *Journal of Business & Industrial Marketing*, vol. 38, no. 2, pp. 123-135, 2023
- [۹] م. نوروزی، د. فیاض، و ح. سیف، "آینده‌پژوهی عوامل مؤثر بر محور مقاومت با تأکید بر ناآرامی‌های اجتماعی عراق و لبنان،" فصلنامه علمی راهبرد دفاعی، سال نوزدهم، شماره ۷۴، ۱۴۰۰.
- [۱۰] ج. سی. گلن و ت. ج. گوردون، دانشنامه بزرگ روش‌های آینده‌پژوهی، ترجمه م. کیقبادی و ف. ملکی فر، تهران: انتشارات تیسرا، ۱۳۹۳
- [۱۱] ر. اسلاوتر و همکاران، نواندیشی برای هزاره نوین، ترجمه ع. ملکی فر و همکاران، تهران: مرکز آینده‌پژوهی علوم و فناوری دفاعی، ۱۳۸۶.
- [12] T. Jokinen et al., "Measurement report: Long-term measurements of aerosol precursor concentrations in the Finnish subarctic boreal forest," *Atmospheric Chemistry and Physics*, vol. 22, pp. 2237-2254, 2022, doi: [10.5194/acp-22-2237-2022]([https://doi.org/10.5194/acp-22-2237-2022]).
- [13] Heger, T, Boman, M (2015) - Technological Forecasting and Social Change, Zitiert von: 132 Ähnliche Artikel Alle 9 Versionen
- [14] P. A. Van der Duin, J. R. Ortt, and W. Aarts, "Contextual innovation management using a stage-gate platform: The case of Philips Shaving and Beauty," *Journal of Product Innovation Management*, vol. 31, no. 3, pp. 489-500, 2014
- [۱۵] بيشاپ، پيتر؛ هايترز، اندی و كالينز، تری (۱۳۸۸) ترجمه مسعود منزوی، وضعیت کنونی سناریونویسی و تکنیک‌های اجمالی آن، تهران، انتشارات مرکز آینده‌پژوهی صنایع دفاعی

- [40] <https://www.analyticsinsight.net/what-are-the-important-factors-that-drive-artificial-intelligence/>
- [41] The present and future of AI," Harvard SEAS, 2021. [Online]. Available: [\[https://seas.harvard.edu/news/2021/10/present-and-future-ai\]](https://seas.harvard.edu/news/2021/10/present-and-future-ai)(<https://seas.harvard.edu/news/2021/10/present-and-future-ai>).
- [42] <https://www.forbes.com/sites/janakirammsv/2018/05/27/here-are-three-factors-that->
- [43] <https://jdeiut.ir/the-effect-of-artificial-intelligence-on-the-branding-of-organizations/>
- [44] <https://1rose.ir>
- [45] <https://blog.kapila.com>
- [۴۶] م. مشهدی‌زاده و ب. ساعدی، "بررسی روابط میان مشارکت مشتری، ایجاد ارزش مشتری و چسبندگی مشتری به شبکه‌های اجتماعی در نظام بانکی"، فصلنامه علمی اقتصاد و بانکداری اسلامی، شماره ۳۲، ۱۴۰۰.
- [47] How to build brand authenticity with artificial intelligence," Forbes, 2021. [Online]. Available: [\[https://www.forbes.com/sites/forbestechcouncil/2021/03/19/how-to-build-brand-authenticity-with-artificial-intelligence/\]](https://www.forbes.com/sites/forbestechcouncil/2021/03/19/how-to-build-brand-authenticity-with-artificial-intelligence/)(<https://www.forbes.com/sites/forbestechcouncil/2021/03/19/how-to-build-brand-authenticity-with-artificial-intelligence/>).
- [۴۸] لیونبرگ و ایربای (۱۳۹۰). روش تحقیق و نگارش پایان‌نامه (ترجمه و قربانی‌زاده و م. حسینی مرام): تهران: سازمان انتشارات جهاد دانشگاهی.
- [۴۹] س. خزایی و ا. محمودزاده، آینده‌پژوهی، اصفهان: انتشارات پارس ضیاء شاخص پژوه، ۱۳۹۲.
- [۵۰] ب. گیبسون، گ. مورگان، و ب. بوریل، نظریه‌های کلان جامعه‌شناختی و تجزیه و تحلیل سازمان، ترجمه م. ت. نوروزی، قم: انتشارات حوزه علمیه قم، ۱۳۹۱.
- review](<https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2022-and-a-half-decade-in-review>)
- [32] AI statistics," Exploding Topics, 2023. [Online]. Available: [\[https://explodingtopics.com/blog/ai-statistics\]](https://explodingtopics.com/blog/ai-statistics)(<https://explodingtopics.com/blog/ai-statistics>)
- [33] The legal challenges of artificial intelligence," IURICORN, 2023. [Online]. Available: [\[https://www.iuricorn.com/the-legal-challenges-of-artificial-intelligence\]](https://www.iuricorn.com/the-legal-challenges-of-artificial-intelligence)(<https://www.iuricorn.com/the-legal-challenges-of-artificial-intelligence>).
- [34] Challenges of using artificial intelligence," Deloitte, 2023. [Online]. Available: [\[https://www2.deloitte.com/us/en/pages/consulting/articles/challenges-of-using-artificial-intelligence.html\]](https://www2.deloitte.com/us/en/pages/consulting/articles/challenges-of-using-artificial-intelligence.html)(<https://www2.deloitte.com/us/en/pages/consulting/articles/challenges-of-using-artificial-intelligence.html>).
- [35] <https://www.apa.org/monitor/2021/11/cover-artificial-intelligence>
- [۳۶] س. خدای، ب. اصائلو، و غ. سلیمانی، "شناسایی مزایای بازی‌وارسازی مشتریان فروشگاه‌های آنلاین مبتنی بر روش تحلیل تم"، چشم‌انداز مدیریت بازرگانی، جلد ۲۱، شماره ۵۱، صص. ۱۲۵-۱۵۲، ۱۴۰۱.
- doi: 10.52547/jbmp.2023.229954.1442
- [۳۷] م. حسین‌زاده و همکاران، "رائه چارچوب مفهومی استفاده از بازاریابی دیجیتال در بازار سرمایه بر اساس تئوری‌های رفتار برنامه‌ریزی شده و پذیرش فناوری مورد مطالعه: شرکت‌های کارگزاری بورس در تهران"، فصلنامه اقتصاد مالی، دوره ۱۶، شماره ۴، ۱۴۰۱.
- [۳۸] م. شیرخدایی و همکاران، "شناسایی عوامل مؤثر بر هم‌آفرینی برند در جوامع برند رسانه‌های اجتماعی"، مجله تحقیقات بازاریابی نوین، سال دوازدهم، شماره ۴، ۱۴۰۲.
- [39] <https://www.convinceandconvert.com/digital-marketing/artificial-intelligence-can-help-your-brand/>.