ITRC ICT Research Institute (Iran Telecommunication Research Center)

Journal of Information and Communication Technology

Iranian Society of Information and Communication Technology

Volume 17, Issue 65, Special Issue on "Artificial Intelligence and data analytics", October 2025, pp 1-19

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

Malika Kalhar[1], 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

دوفصلنامه
فناوری اطلاعات و ارتباطات ایران

سال هفدهم، شماره ۶۵، مهر ۱۴۰۴، شمارهٔ ویژهٔ «هوش مصنوعی و تحلیل داده»، صفحه ۱ الی ۱۹

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]

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

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

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

[۴] گروه 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 مایرزبریگز 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 آموزش‌دیده برت، روبرتا و ایکس‌ال‌نت است برای استخراج ویژگی و تشخیص شخصیت افراد بر اساس شاخص مایرزبریگز 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 پیش‌آموزش 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.

* رایانامهٔ نویسنده مسؤول: mirzarezaee@iau.ac.ir

۱- مقدمه

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 خلق‌وخوی 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 ماشین 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 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[1] و رویکرد بهینه شده قوی پیش‌آموزشی برت یا به اختصار روبرتا[2] و در آخر معماری ایکس‌ال‌نت[3] که یک پیش‌آموزش خودرگرسیون تعمیم‌یافته[4] 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[5]) 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 شده‌است. 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 ماشین را مورد بررسی قرار می‌دهد و سپس، مروری بر تحقیقات صورت گرفته در زمینه تشخیص شخصیت با استفاده از پیشرفته‌ترین

[1] Bidirectional Encoder from Transformer (BERT)
[2] Robustly Optimized BERT Pretraining Approach (RoBERTa)
[3] XLNet
[4] Generalized Autoregressive Pretraining
[5] National Research Council

الگوریتم‌های یادگیری عمیق مانند LSTM[1] و Bi-LSTM[2] 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 قابل‌توجهی 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 به‌عنوان مثال، وبلاگ‌ها، شبکه اجتماعی نظیر X و استک‌اورفلو[3] 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].

ساهونو 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[4] 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[5]، 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 مدل های رگرسیون لجستیک، ماشین بردار پشتیبان، بیز[6] 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 سرانوو 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].

[1] Long short-term memory
[2] Bidirectional Long Short-Term Memory
[3] Stack Overflow
[4] SVM
[5] Logistic regression
[6] Naïve Bayes

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[1] 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[2]، تکنیک Ensemble برای افزایش استحکام مدل و کاهش واریانس استفاده شده است [11].

کمال الدمرداش 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 مدل های 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 درصدآموزش 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].

ساکدیپات اونتوم و جاناتان 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 پارامتر ها 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 یوتیوپ استفاده کرده است. وی با استفاده از الگوریتم‌های یادگیری نیمه‌نظارت‌شده چند برچسبی مانند شبکه عصبی کانولوشن، شبکه عصبی بازگشتی، LSTM، BiLSTM، GRU و BiGRU و با استفاده از اعتبارسنجی متقاطع ۱۰ مورد ارزیابی قرار گرفتند توانستد با استفاده از جستوی تصادفی به تنظیم دقیق پارامتر ها و به امتیاز F1 ۸۸ درصد دست پیدا کند [15].

هارشیت بهاردواج در ۲۰۲۳ از یک مدل DeepLSTM[3] برای طبقه‌بندی ویژگی‌های شخصیتی با استفاده از سیگنال‌های الکتروانسفالوگرام استفاده کرد. هدف این مطالعه ارزیابی کارایی مدل DeepLSTM با طبقه‌بندهای پیشرفته یادگیری ماشینی موجود مانند MLP[4]، KNN[5]، SVM و LibSVM است. مدل پیشنهادی از

[1] Deep belief networks
[2] Grid Search
[3] یادگیری عمیق حافظه کوتاه مدت عمیق
[4] پرسپترون چندلایه
[5] K-Nearest Neighbors

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] .

سیراساپالی 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[1] 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 توقف‌کلمات 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 قابل‌توجهی 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، LinearSVC، SGD، Logistic Regression و CatBoost را در پیش‌بینی تیپ‌های شخصیتی MBTI بررسی می‌کند. علاوه بر این، تأثیر تکنیک‌های پیش‌پردازش مانند تمیز کردن متن، توکن‌سازی، بردارسازی TF-IDF، جاسازی‌های GloVe و BERT بر عملکرد طبقه‌بندی مورد بررسی قرار می‌گیرد. علاوه بر این، این تحقیق استراتژی‌هایی را برای پرداختن به عدم تعادل طبقاتی از طریق تکنیک‌های نمونه‌برداری بررسی می‌کند. نتایج حاکی از دقت و عملکرد بالا در بین طبقه‌بندهای چندگانه است که XGBoost به بالاترین دقت ۹۷,۳۳٪ دست یافته است [20] .

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

[1] Synthetic Minority Oversampling Technique

از یادگیری تضاد[1] برای آموزش encoder پایش و بازنمایی شخصیت بهره بردند. این روش روی مجموعه‌داده 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-F۱: 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[2] 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]

در سال ۲۰۲۵، شاه‌نظری و ایوبزاده با استفاده از RoBERTa فاین‌تیون‌شده 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 ۱۳۸،۸۶۶ پیام از ۱،۶۰۲ کاربر با برچسب MBTI و ۱۹۵،۰۱۶ پیام از ۲،۵۹۸ 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 کارولوژی یونگ کارل یونگ است و شخصیت انسان را در چهار بعد اساسی توصیف می‌کند. این بعد ها به ترتیب شامل برون‌گرایی[3]در مقابل درون‌گرایی[4]، حسی[5] در مقابل شهودی[6]، منطقی[7] در مقابل احساسی[8]، داوری کننده[9] در مقابل ملاحظه کار[10] هستند. و در نهایت شخصیت افراد را در یکی از شانزده گروه شناخته شده زیر قرار می دهد:

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

[1] Contrastive learning
[2] Self-supervised
[3] Extraversion
[4] Introversion
[5] Sensational
[6] INtuition
[7] Feeling
[8] Thinking
[9] Judging
[10] Perception

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- 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- 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 وشامل 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 گریده است این ستون حاوی ۱۶ نوع شخصیت MBTI است که شامل ترکیبی از چهار دسته‌بندی درونگرایی/ برونگرایی، حسی/ شهودی، تفکری /احساسی، قضاوت‌گر /ادراکی است. هیچ ردیف تهی 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- 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 پست ها و برچسب شخصیتی نویسنده است.درستون پست ها، 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 منحصربه‌فرد 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- 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.

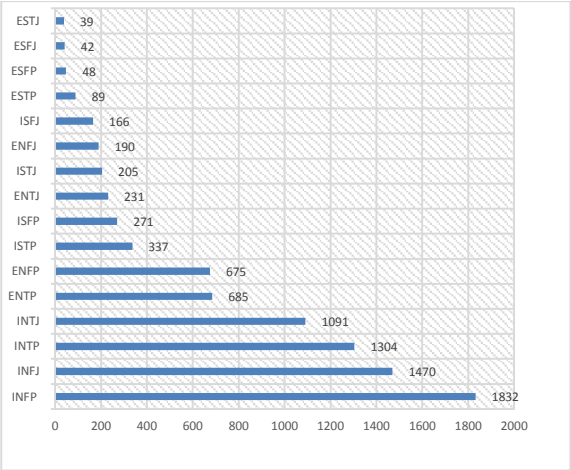

شکل ۱. نمودار توزیع نمونه‌ها برای ۱۶ نوع شخصیت در MBTI

۳-۴- 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.

۳-۴-۱- پیش‌پردازش

در اولین گام تمام داده‌های موجود در مجموعه داده را پیش‌پردازش می‌کنیم. هدف اصلی از پیش‌پردازش، به حداکثر رساندن ویژگی‌های مفید استخراج‌شده 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 درنهایت 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 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 شخصیتی 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 ۳۲۰۰۰۰ کلمه است.

هر یک از این کلمات در این مدل ها، 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 ببینند. بر اساس رویکردی که در این مطالعه اتخاذ شد، توکن‌سازی با استفاده از روشی به نام توکن‌سازی WordPiece انجام شده است.

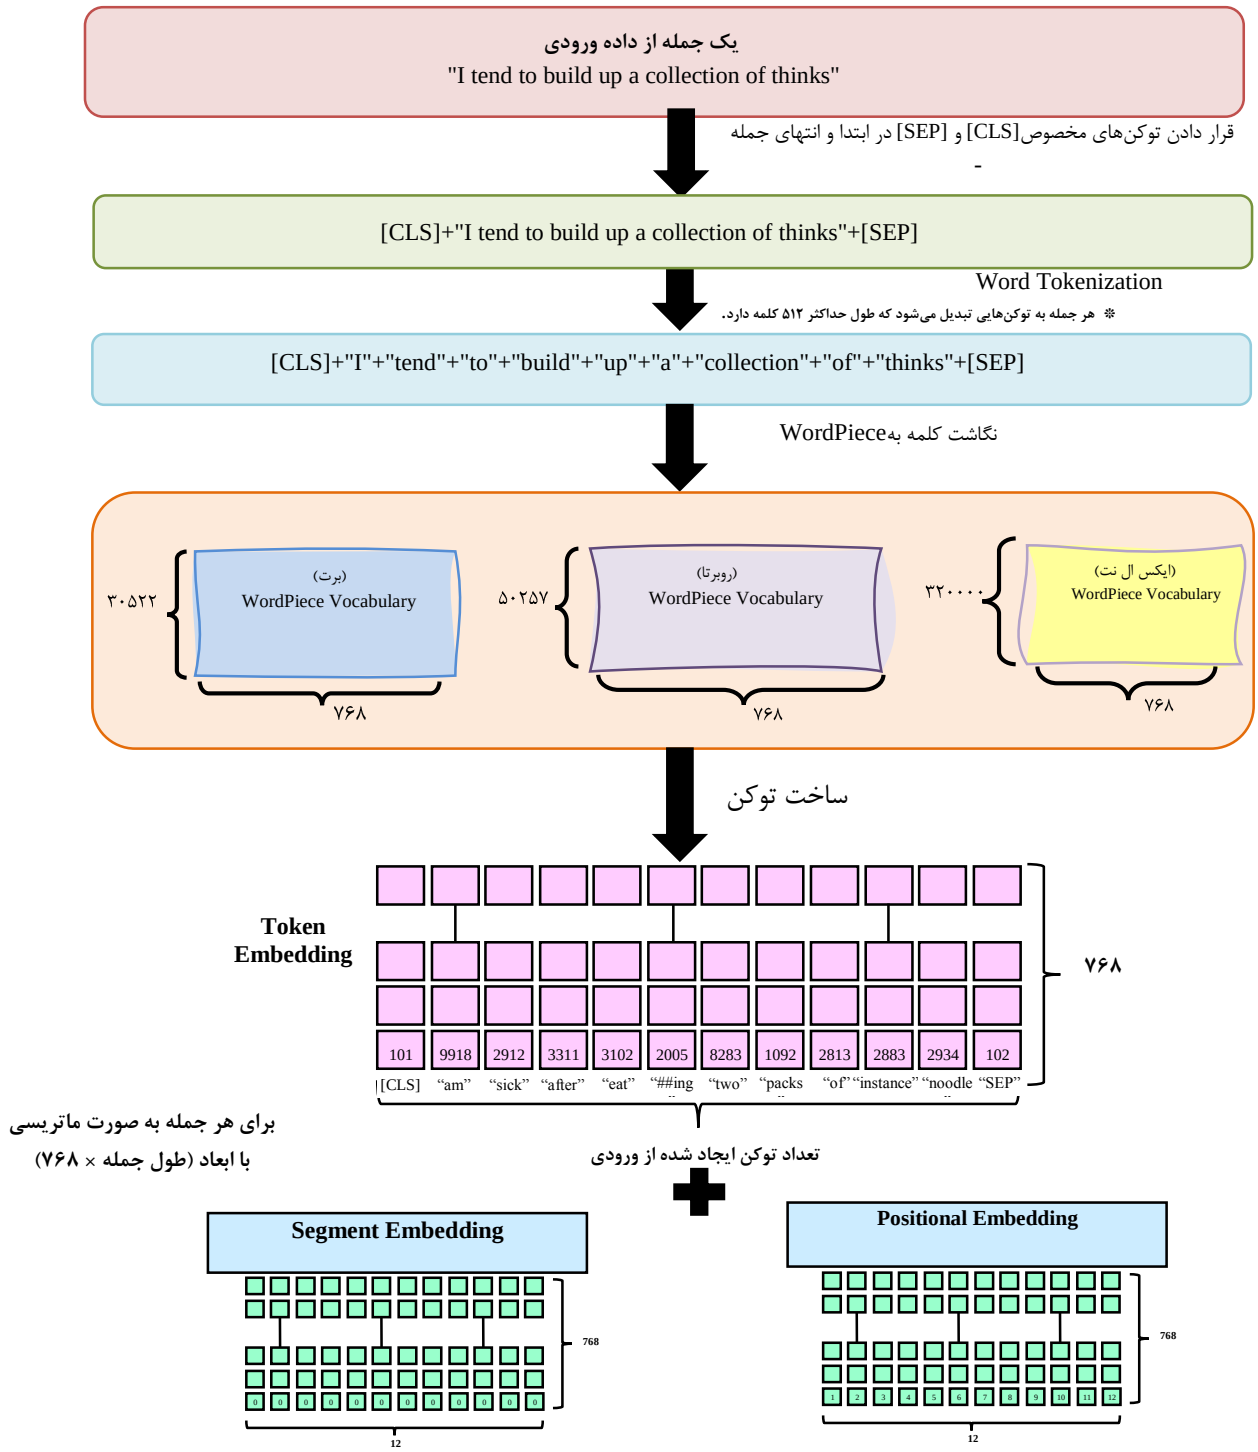

شکل ۲. خلاصه‌ای از مراحل به کار برده شده در استخراج ویژگی

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. به‌عنوان مثال، واژه «پسر» تقسیم نمی‌شود، اما واژه «پسرها» به «پسر» و «ها» تقسیم می‌شود. این به مدل کمک می‌کند تا یاد بگیرد واژه «پسرها» 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

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 به‌عنوان 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.

$$RTF_{IGM(t_i)} = \sqrt{TF\left(t_i, d_j\right)} \times (1 + \lambda \times \frac{f_{i1}}{\sum_{r=1}^{m} f_{ir.r}}) \qquad (۱)$$

در روابط فوق f_{ir} تعداد رخداد کلمه موردنظر در کلاس rام 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 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 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

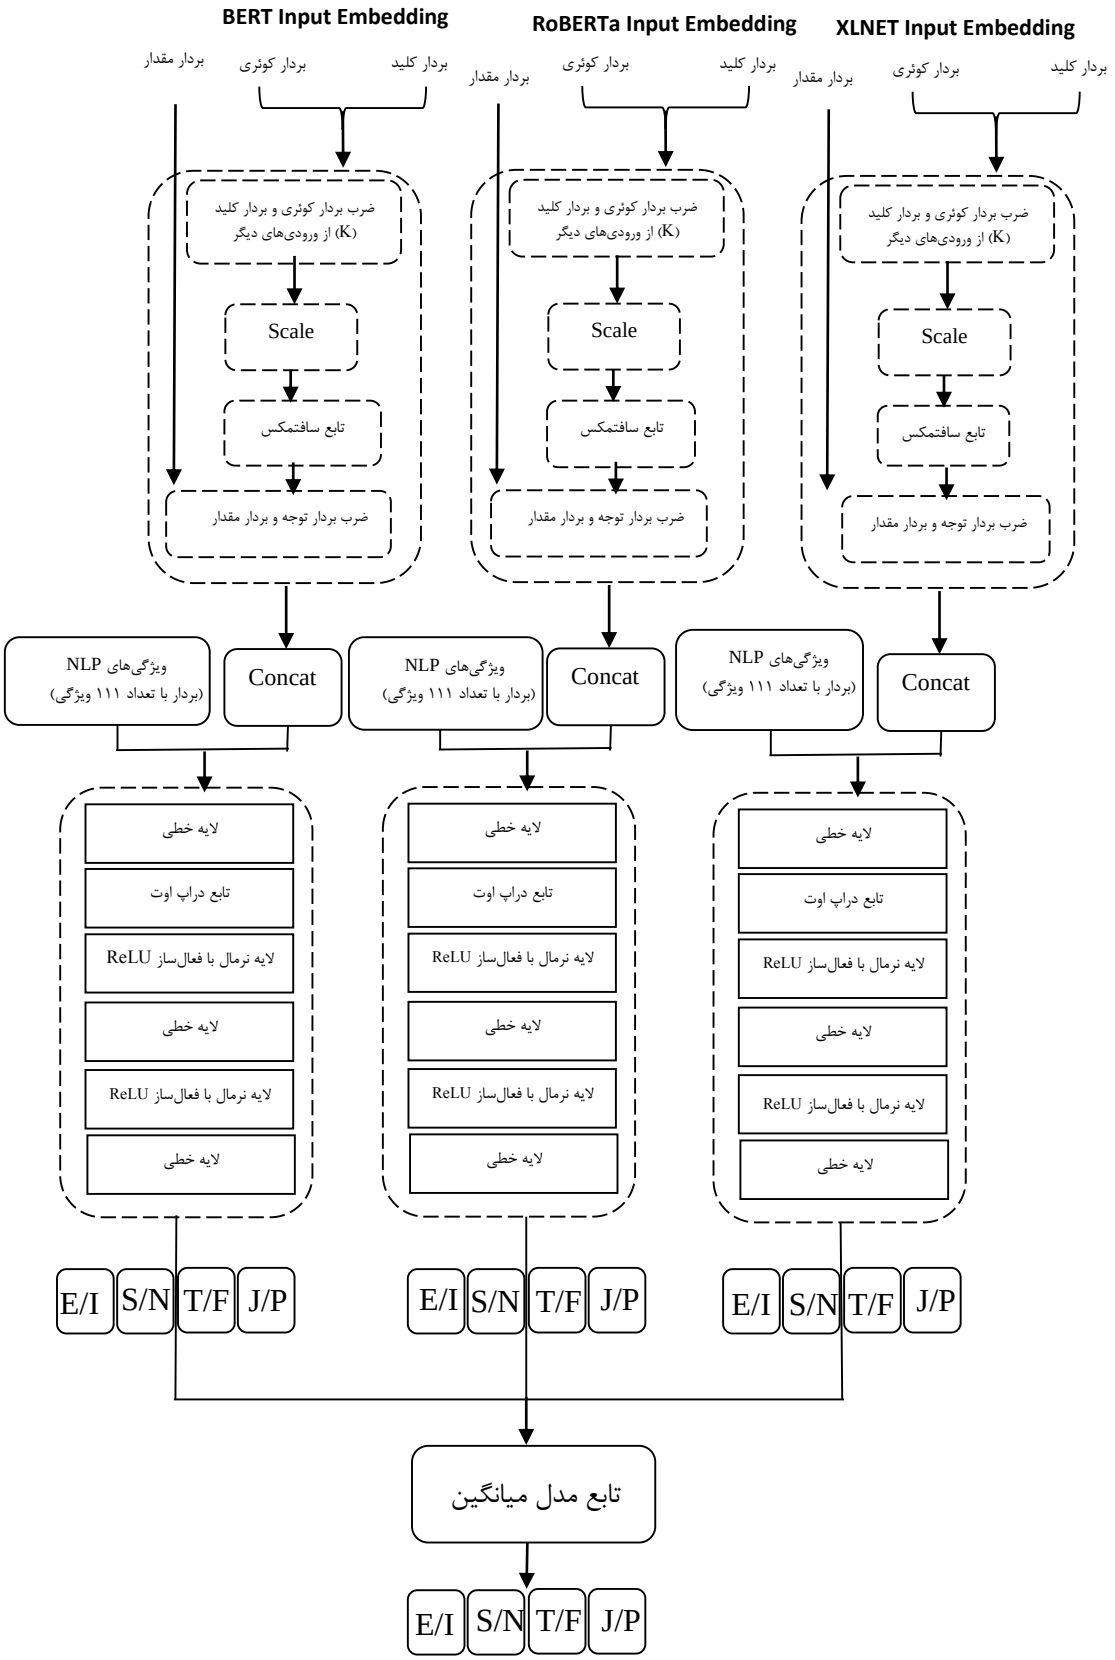

شکل ۳. معماری کلی پیشنهادی

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 مقداردهی می‌شوند. حاصل‌ضرب بردار ورودی در هر یک از این سه ماتریس، بردارهای Key، Query و Value را تشکیل می‌دهد.

$$Query\ q_{ij} = w_Q x_{ij} \quad (۲)$$

$$keys\ k_{ab} = w_K x_{ab} \quad (۳)$$

$$value\ v_{ab} = w_V x_{ab} \quad (۴)$$

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.

$$Attension\ Score = q_{ij}^{\mathrm{T}} k_{ab} \quad (۵)$$

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 گرادیان پایدارتر را ممکن می‌سازد و باعث می‌شود که برخی از امتیازات مکانیزم خود توجه، پس از اعمال تابع SoftMax در مراحل بعد، کوچک شوند.

$$Scale\left(x\right) = \frac{QK^{T}}{\sqrt{d_k}} \quad (۶)$$

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

$$softmax_{ab}\left(q_{ij}^{\mathrm{T}} k_{ab}\right) \quad (۷)$$

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.

$$y_{ij} = \sum_{a,b\epsilon\mathcal{N}_k(i,j)} softmmax_{ab}(q_{ij}^{T} k_{ab})\, v_{ab} \quad (۸)$$

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.

$$y_{ij} = \sum_{a,b\epsilon\mathcal{N}_k(i,j)} softmax_{ab}(q_{ij}^{\mathrm{T}} k_{ab} + q_{ij}^{\mathrm{T}} r_{a-i,b-j})\, v_{ab} \quad (۹)$$

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.

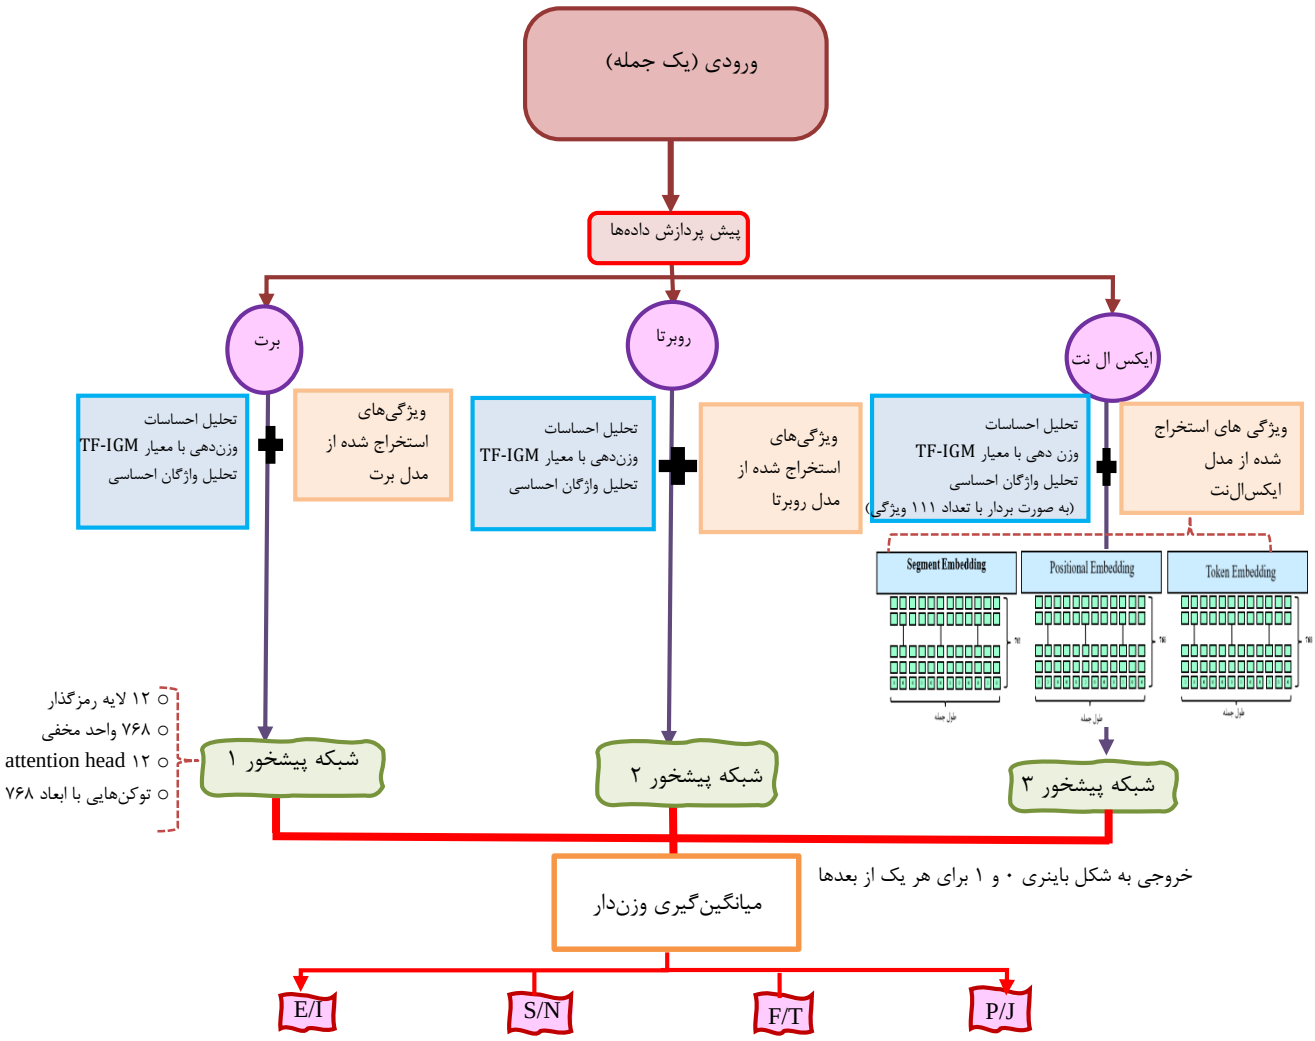

شکل ۴. نمایش خلاصهٔ مدل پیشنهادی– داده‌های خام بعد از پیش‌پردازش وارد مرحله استخراج ویژگی شده و ویژگی های لازم با استفاده از سه مدل برت روبرتا و ایکس‌ال‌نت و ویژگی‌های آماری زبان (تحلیل احساسات، وزن‌دهی با معیار TF-IGM، تحلیل واژگان احساسی) از آنها استخراج می‌شود. سپس این ویژگی‌ها وارد سه شبکه پیشخور مجزا می‌شوند و در آخر با استفاده از میانگین‌گیری بدون وزن خروجی نهایی محاسبه خواهد شد.

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.

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

$$y = \text{argmax}(y^*_i, k) \quad (11)$$

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 ازچند 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.

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 ازریابی عملکرد یک مدل در کلاس‌هایی با در داده‌های متعادل است. این معیار نسبت مقدار پیش‌بینی‌های درست را بر روی کل داده‌ها ارزیابی می‌کند.

$$Accuracy = \frac{TP + TN}{TN + TP + FN + FP} \quad (۱۲)$$

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.

$$F1\ Score = \frac{۲}{\frac{۱}{Recall} + \frac{۱}{Presicion}} = ۲ * \frac{Presicion * Recall}{Presicion + Recall} \quad (۱۳)$$

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±۰۵
۲		۱۶	۳,۰۰E±۰۵
۳		۳۲	۱,۰۰E±۰۵
۴		۳۲	۳,۰۰E±۰۵
۵	روبرتا	۱۶	۱,۰۰E±۰۵
۶		۱۶	۳,۰۰E±۰۵
۷		۳۲	۱,۰۰E±۰۵
۸		۳۲	۳,۰۰E±۰۵
۹	ایکس‌ال‌نت	۱۶	۱,۰۰E±۰۵
۱۰		۱۶	۳,۰۰E±۰۵
۱۱		۳۲	۱,۰۰E±۰۵
۱۲		۳۲	۳,۰۰E±۰۵
۱۳	برت + NLP	۱۶	۱,۰۰E±۰۵
۱۴		۱۶	۳,۰۰E±۰۵
۱۵		۳۲	۱,۰۰E±۰۵
۱۶		۳۲	۳,۰۰E±۰۵
۱۷	روبرتا + NLP	۱۶	۱,۰۰E±۰۵
۱۸		۱۶	۳,۰۰E±۰۵
۱۹		۳۲	۱,۰۰E±۰۵
۲۰		۳۲	۳,۰۰E±۰۵
۲۱	ایکس‌ال‌نت + NLP	۱۶	۱,۰۰E±۰۵
۲۲		۱۶	۳,۰۰E±۰۵
۲۳		۳۲	۱,۰۰E±۰۵
۲۴		۳۲	۳,۰۰E±۰۵
۲۵	مدل پیشنهادی (برت + روبرتا + ایکس‌ال‌نت) + NLP	۱۶	۱,۰۰E±۰۵
۲۶		۱۶	۳,۰۰E±۰۵
۲۷		۳۲	۱,۰۰E±۰۵
۲۸		۳۲	۳,۰۰E±۰۵

۴-۳- 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 داده ها به ۱۰ بخش[1] 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[2] جلوگیری شود.

۴-۴- نتایج استفاده از مجموعه MBTI500

جدول ۳ نتایج ارزیابی برای مجموعه‌داده 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 مجموعه‌داده MBTI500 ارائه داده است.

۴-۴-۱- نتایج استفاده از مجموعه MBTI1

جدول ۴ نتایج ارزیابی برای مجموعه‌داده 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 برون‌گر 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 تکنیک های رایج برای تنظیم و بهینه سازی پارامترهای مدلشان استفاده کرده‌اند و به هدف اینکه مقایسه های انجام شده عادلانه باشد در این پژوهش ما نیز از روش جستجوی شبکه ای 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 ۳,۰۰E-۰۵ برای عملکرد بهینه استفاده می‌کنند. در حالی که بعد ویژگی فکری یا احساسی در نرخ یادگیری ۱,۰۰E-۰۵ عملکرد بهینه خود را نشان داده است (جدول ۵).

[1] Fold

[2] Bias

جدول ۳. دقت شناسایی ابعاد شخصیتی در مجموعه داده MBTI1

بعد شخصیتی		درون‌گرا/ برون‌گرا	حسی/ شهودی	فکری/ احساسی	ساختارگرا/ 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	۰۷۹۲۶	۰٫۶۹۶۹
برت + NLP	دقت	۸۹٫۵۶	۷۲٫۶۹	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	۰۸۱۲۶
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	۷۸٫۲۱	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		درون‌گرا/ برون‌گرا	حسی/ شهودی	فکری/ احساسی	ساختارگرا/ 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
درون‌گرا / برون‌گر	۱۶	۳٫۰۰E-۰۵
حسی / شهودی	۳۲	۳٫۰۰E-۰۵
فکری/ احساسی	۳۲	۱٫۰۰E-۰۵
ساختارگرا / 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 الگویتم‌ها 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	٪۷۸٫۲۱	٪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

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 صرفا از پیش آموزش دیده 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 با 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 (ICAIIC)*, 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.

[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, Snehitha, "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*

[23] Linmei Hu;Hongyu He;Duokang Wang;Ziwang 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 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.