



تشخیص ویژگی‌های شخصیتی با استفاده از متن

ثمین فاتحی
دانشکده مهندسی کامپیوتر
دانشگاه علم و صنعت ایران
saminfatehir@gmail.com

چکیده

شخصیت افراد به صورت مجموعه‌ی رفتارها، شناخت‌ها و الگوهای احساسی ناشی از عوامل بیولوژیکی یا محیطی تعریف می‌شود. با توجه به این مسئله که شخصیت افراد در رفتارها، حرکات، چهره و نوشته‌های آن‌ها نمود پیدا می‌کند، می‌توان با بررسی این نمودها شخصیت افراد را کشف کرد. در این پروژه تلاش شده‌است با استفاده از متن‌های منتشرشده توسط افراد ویژگی‌های شخصیتی آن‌ها را تشخیص دهیم. آزمایش‌ها نشان داد با استفاده از امبدینگ‌های جدید و وابسته به بافت متن می‌توان نسبت به کارهای پیشین انجام شده در این زمینه که با استفاده از امبدینگ‌های ساده‌تر انجام شده‌بوده است، با دقت بیشتری ویژگی‌های شخصیتی افراد را با استفاده از متن نوشته شده توسط آنان تشخیص داد.

۱ مقدمه

تشخیص شخصیت انسان‌ها عموماً با استفاده از پرسش‌نامه و به صورت مستقیم توسط روان‌شناسان صورت می‌گیرد. اما می‌توان با استفاده از نمود شخصیت افراد در رفتار آن‌ها نیز، شخصیتشان را تشخیص داد. از کاربردهای تشخیص شخصیت افراد می‌توان به عنوان مثال به چند مورد اشاره کرد:

استخدام افراد: شخصیت انسان‌ها با توجه به وظایف افراد در مشاغل مختلف، می‌تواند روی عملکرد آن‌ها تاثیر داشته باشد. بنابراین تشخیص شخصیت افراد در هنگام استخدام می‌تواند مانند یک فیلتر عمل کرده و افراد نامناسب برای مشاغل را از همان ابتدا کنار بگذارد.

تشخیص قطبیت کلمات: وجود کلمات در متن یا گفتار افراد با شخصیت‌های متفاوت می‌تواند معانی مختلفی به مفاهیم مد نظر آن‌ها ببخشد. به عنوان مثال می‌توان با کمک شخصیت‌گینده‌ی یک عبارت، طعنه‌آمیز یا غیرطعنه‌آمیز بودن آن عبارت را بهتر تشخیص داد.

تبلیغات: با توجه به شخصیت افراد، انواع مختلفی از تبلیغات می‌تواند تاثیر بیشتری بر روی آن‌ها داشته باشد. دستیارهای صوتی: یک سیستم دستیار صوتی با توجه به شخصیت کاربر، ارتباط بهتری با وی برقرار کرده و قادر است خدمات بهتری ارائه دهد.

سامانه‌های توصیه‌گر: توصیه‌ی محصولات، فیلم، موسیقی یا غیره به افراد با شخصیت متفاوت، می‌تواند کاملاً متفاوت رخ دهد.

در این پروژه قصد داشتیم با استفاده از متن نوشته‌شده توسط افراد به تشخیص شخصیت آن‌ها با استفاده از روش‌های یادگیری عمیق بپردازیم.

۲ کارهای مرتبط

در زمینه‌ی تشخیص ویژگی‌های شخصیت تا کنون کارهای زیادی انجام شده‌است. این مطالعات بر روی مجموعه داده‌های مختلفی که برای این مسئله تهیه شده است صورت می‌گیرد. از مجموعه داده‌های مطرح در این زمینه می‌توان به مجموعه داده‌های Essays [۶]، PANDORA [۳] و Personality Cafe اشاره کرد.

به عنوان مثال از میان کارهای انجام شده بر روی مجموعه داده‌ی Essays می‌توان مطالعه‌ی [۵] را نام برد که در پژوهش‌شان با استفاده از Word2Vec مجموعه انشاهای دانشجویی را به بردار تبدیل کرده و با استفاده از شبکه‌ی عمیق حاوی لایه‌های کانولوشن به تشخیص شخصیت افراد پرداخته بودند. مجموعه داده‌ی PANDORA به تازگی منتشر شده و هنوز مطالعات به صورت جدی روی آن صورت نگرفته است. همچنین state of the art حل این مسئله به وسیله‌ی مدل‌های عمیق بر روی مجموعه داده‌ی Personality Cafe در مقاله‌ی [۴] ارائه شده است. اما این نتایج بعدتر توسط مدل‌های کلاسیک پشت سر گذاشته شده است. به عنوان مثال [۱] در یکی از جدیدترین مطالعات انجام شده بر روی این مجموعه داده با استفاده از الگوریتم گرادینان بودستینگ این نتایج را بهبود داده است.

این پروژه بر روی مجموعه داده‌ی Personality Cafe صورت گرفته‌است و جزئیات بیشتر نقطه‌ی شروع براساس کارهای پیشین در قسمت ۲.۳ بیان شده است.

۳ مدل پیشنهاد شده

۱.۳ مجموعه داده

مجموعه داده‌ی مورد استفاده در این پروژه، مجموعه ۵۰ پست از پست‌های افراد در فضای گفتگوی Personality Cafe است. برای هر یک از این افراد نیز تیپ شخصیتی آن‌ها بر اساس آزمون MBTI ثبت شده است. در این دسته بندی از تیپ‌های شخصیتی، ترجیحات شخصی افراد در ۴ حوزه‌ی سبک نگرش نسبت به ایده‌ها و انسان‌ها (برون‌گرایی-دورنگرایی)، سبک جمع‌آوری اطلاعات (شهودی-حسی)، سبک ارزیابی اطلاعات به دست آمده و تصمیم‌گیری براساس این اطلاعات (احساسی-منطقی) و نحوه‌ی مواجهه با جهان پیرامون (ادراکی-قضواتی) مشخص می‌شود. در این مجموعه داده، اطلاعات مربوط به تیپ شخصیتی و پست‌های ۸۶۷۵ فرد ثبت شده‌است.

۲.۳ نقطه‌ی شروع

به عنوان نقطه‌ی شروع این پژوهش، از آخرین پژوهش صورت گرفته در این زمینه و بر روی همین مجموعه داده بهره گرفتیم. در این بهترین مطالعه‌ای که تا کنون بر روی این مسئله و مجموعه داده توسط مدل‌های یادگیری عمیق صورت گرفته‌است، روش ارائه شده مدل ساده‌ی LSTM بوده است که در آن بردارهای TF-IDF جملات به عنوان ورودی به شبکه داده شده است [۴]. نتایج این مدل در جدول ۱ نشان داده شده است.

همچنین در مقاله‌ای جدیدتر یک مدل کلاسیک برای تشخیص تیپ‌های شخصیتی معرفی شده است که بهتر از مدل عمیق عمل می‌کند [۱]. در این پروژه ما تلاش کردیم نه تنها مدل عمیق معرفی شده را بهبود دهیم، بلکه به دقتی بهتر از بهترین مدل کلاسیک معرفی شده دست یابیم. نتایج مدل کلاسیک نیز در جدول ۱ نشان داده شده است.

ویژگی‌های TF-IDF، ویژگی‌هایی قوی برای بازنمایی ویژگی‌های متن نیستند. این ویژگی‌ها ارتباط معنایی کلمات با یکدیگر را به هیچ وجه در نظر نگرفته و همچنین بازنمایی عددی در فضای با ابعاد بسیار بالا را ایجاد می‌کنند. در سال‌های اخیر بازنمایی‌های دقیق‌تری برای متن ارائه شده است. یکی از این بازنمایی‌ها، با استفاده از شبکه‌ی pre-train شده‌ی BERT [۲] می‌باشد.

۳.۳ مدل پیشنهادی

به منظور بهبود نتایج تصمیم گرفتیم از دو نوع امبدینگ برای بازنمایی عددی متن بهره ببریم.

۱.۳.۳ BERT

به دو صورت می‌توان از شبکه‌ی pre-traine شده‌ی BERT بهره برد.

۱. استخراج ویژگی

در این روش، با استفاده از وزن‌های از پیش آموزش داده شده و ثابت شده‌ی BERT، برای متن ویژگی استخراج می‌کنیم. به صورت پیش‌فرض می‌توان به ازای هر کلمه یک بردار استخراج نمود. این بردار می‌تواند خروجی هر یک از لایه‌های شبکه‌ی BERT باشد. نویسندگان مقاله‌ی اصلی که شبکه‌ی BERT را ارائه کرده‌اند، اشاره کرده‌اند که تجربه نشان داده‌است بهترین نتیجه با پشت سر هم قرار دادن بردارهای خروجی ۴ لایه‌ی آخر شبکه‌ی BERT به دست می‌آید [۲]. به همین دلیل در این پروژه ما از خروجی چهارلایه‌ی آخر استفاده کردیم. روش‌هایی نیز برای استخراج ویژگی‌های جمله ارائه شده‌است. در این مرحله ما با استفاده از میانگین‌گیری بین بردارهای ۵۱۲ توکن ابتدایی متن، یک بردار ۳۰۷۲ تایی برای هر متن استخراج کردیم. آزمایش یک مدل ساده‌ی MLP بر روی این ویژگی‌ها نتایج خوبی حاصل نکرد.

با مشاهده‌ی نتایج اولیه متوجه شدیم که نتایج خوبی توسط این مدل کسب نمی‌شود. از آن‌جا که تشخیص دقیق‌های پارامترهای شبکه معمولاً کار سختی است، در این مرحله تلاش کردیم با استفاده از روش‌های بهینه‌سازی بهترین‌های پارامترها را برای شبکه به دست آوریم.

به صورت معمول از روش‌های مختلفی برای بهینه‌سازی‌های پارامترها مانند Random search، Grid search، الگوریتم ژنتیک و Bayesian optimizer استفاده می‌شود. در این پروژه ما از Bayesian optimizer بهره گرفتیم. در راستای استفاده از این روش، مشاهده شد که نتایج تا اندازه‌ی خوبی بهبود یافت. همچنین با استفاده از این روش‌های پارامترهای یک شبکه‌ی LSTM را نیز بهینه کردیم.

در این فرایند تعداد نورون‌های لایه‌های dense و یا لایه‌ی بازگشتی، ورودی لایه‌ی dropout، optimizer و تعداد epochها را متغیر در نظر گرفته و مقدار بهینه را به دست آوردیم. برای شبکه‌ی MLP فرایند ورودی تعداد تکرار فرایند ارزیابی را ۱۰۰ بار و برای LSTM این تعداد را ۵۰ بار تعیین کردیم.

۲. Fine-tuning

تجربه نشان داده است که روش موثرتر در استفاده از شبکه‌های pretrained استخراج ویژگی از آن‌ها نیست بلکه روش finetune کردن مدل روش موثرتری است. در این پروژه این روش نیز آزمایش شده است.

در این روش شبکه‌ای که از پی با داده‌های زیاد آموزش یافته است را در نظر گرفته و با داده‌های مسئله‌ی جدید، آموزش چند لایه‌ی آخر آن شبکه (که بیشتر مختص هر مسئله هستند) را ادامه می‌دهند. در این پروژه ما آموزش ۳ لایه‌ی آخر شبکه‌ی BERT را ادامه دادیم.

۲.۳.۳ SenticNet

این امبدینگ بیان‌کننده‌ی ویژگی‌های احساسی متن در سطح concept است. دو نوع امبدینگ در این پروژه برای استفاده مناسب به نظر می‌رسید.

۱. ویژگی‌های Hourglass

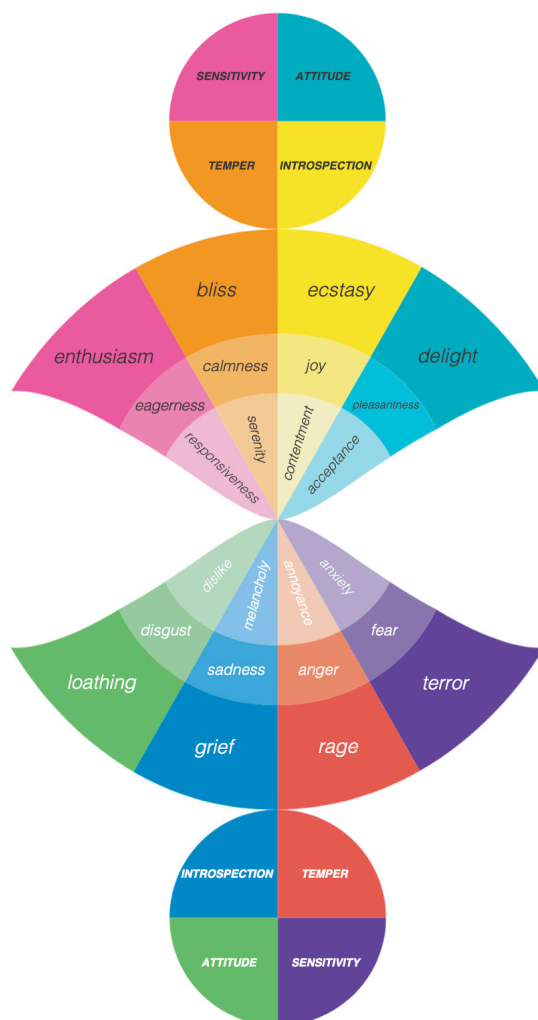
این ویژگی‌ها مجموعه‌ی چهار ویژگی اصلی احساسی را در متن بازنمایی می‌کند. شکل ۱ نشان دهنده‌ی این چهار ویژگی و ۲۴ زیر ویژگی آن است. (هر ویژگی بین ۱- تا ۱+ خواهد بود که این بازه نیز به ۶ قسمت تقسیم شده و می‌تواند ۲۴ ویژگی را نشان دهد.)

۲. ویژگی‌های AffectiveSpace

این ویژگی‌های که در مجموع با ۱۰۰ بعد داده‌ها را بازنمایی می‌کنند، با استفاده از مدل بزرگتر AffectNet به دست آمده‌اند. با توجه به این‌که احساسات مخفی در متن افراد می‌تواند نمایانگری از شخصیت آن‌ها باشد، در یک آزمایش نیز با افزودن این ویژگی‌ها به ویژگی‌های BERT سعی به پیش‌بینی شخصیت کردیم.

۴ نتایج و تحلیل

نتایج به صورت کلی در جدول ۱ نشان داده شده است. بر این اساس می‌توان بهبود نسبی مدل را هنگام استفاده از الگوریتم‌های بهینه‌سازی‌های پارامترها مشاهده کرد. همچنین مشاهده می‌شود استفاده از روش finetuning نسبت به روش استخراج ویژگی نتایج بهتری داشته است. چنان‌چه در سطر آخر جدول ۱ مشاهده می‌شود، finetune کردن مدل BERT می‌تواند بهتر



شکل ۱: مجموعه ۲۴ ویژگی hourglass

از تمامی کارهای پیشین بر روی این مجموعه داده عمل کرده و دقت به نسبت بهتری نسبت به آخرین مدل معرفی شده برای تشخیص شخصیت بر روی این مجموعه داده داشته باشد.

Traits	I/E	N/S	T/F	J/P
Baseline (deep models)	67.60	62	77.80	63.70
Baseline (Gradient Boosting)	78.17	86.06	71.78	65.70
MLP	75.82	86.05	56.21	55.05
MLP (with optimization)	75.61	87.51	57.40	65.69
MLP (with Sentic features)	78.11	86	60.58	60.35
BERT Finetuning	83.92	89.26	80.94	75.96

جدول ۱: نتایج به دست آمده از آزمایش‌های مختلف

- [1] M. H. Amirhosseini and H. Kazemian. Machine learning approach to personality type prediction based on the myers–briggs type indicator®. *Multimodal Technologies and Interaction*, 4(1):9, 2020.
- [2] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- [3] M. Gjurković, M. Karan, I. Vukojević, M. Bošnjak, and J. Šnajder. Pandora talks: Personality and demographics on reddit. *arXiv preprint arXiv:2004.04460*, 2020.
- [4] R. Hernandez and I. Knight. Predicting myers-bridge type indicator with text classification. In *Proceedings of the 31st Conference on Neural Information Processing Systems, Long Beach, CA, USA*, pages 4–9, 2017.
- [5] N. Majumder, S. Poria, A. Gelbukh, and E. Cambria. Deep learning-based document modeling for personality detection from text. *IEEE Intelligent Systems*, 32(2):74–79, 2017.
- [6] J. W. Pennebaker and L. A. King. Linguistic styles: Language use as an individual difference. *Journal of personality and social psychology*, 77(6):1296, 1999.