



صفحات ۱۹ تا ۲۸

## پردازش مفهوم زبانی پیام‌های کوتاه توییت‌ر با استفاده از شبکه عصبی عمیق CNN

زهرا دره شوری<sup>۱</sup>، حسین مومن‌زاده<sup>۲</sup>، حسن ارفعی نیا<sup>۳</sup>

<sup>۱</sup> دانشگاه غیرانتفاعی لیان بوشهر،

آدرس پست الکترونیکی

<sup>۲</sup> دانشگاه غیرانتفاعی لیان بوشهر

آدرس پست الکترونیکی

<sup>۳</sup> دانشگاه غیرانتفاعی لیان بوشهر

آدرس پست الکترونیکی

### چکیده

تجزیه و تحلیل احساسات در رسانه های اجتماعی مانند توییت‌ر (شبکه X) بسیار مهم و چالش برانگیز است. با توجه به ویژگی‌های چینی داده‌هایی نظیر طول توییت، اشتباهات املائی، اختصارات و کاراکترهای خاص، تجزیه و تحلیل احساسات نیازمند رویکردی غیرسنتی است. علاوه بر این، تجزیه و تحلیل احساسات رسانه های اجتماعی یک مسئله اساسی با کاربردهای جالب مانند هوش تجاری، نظارت پزشکی و امنیت ملی است. بیشتر روش‌های طبقه‌بندی احساسات رسانه‌های اجتماعی، قطبیت احساسات را بر اساس محتوای متنی قضاوت می‌کنند و از اطلاعات دیگر در این پلتفرم‌ها غفلت می‌کنند. در این تحقیق، ما چارچوب‌های مبتنی بر یادگیری عمیق را پیشنهاد می‌کنیم که اطلاعات رفتاری کاربر را نیز در در نظر می‌گیرد. در این مقاله، از این مدل‌های یادگیری چند وجهی CNN برای انجام تجزیه و تحلیل احساسات استفاده می‌کنیم. نتایج بدست‌آمده نشان می‌دهد که فراتر رفتن از محتوای یک سند در طبقه‌بندی احساسات سودمند است، زیرا درک عمیق‌تری از کار را در اختیار طبقه‌بندی‌کننده قرار می‌دهد و از لحاظ معیارهای دقت، صحت، حساسیت و F1 بهبود قابل توجهی گزارش می‌شود.

**کلمات کلیدی:** پیام‌های کوتاه توییت‌ر، شبکه های عصبی عمیق، مفهوم زبانی

## ۱- مقدمه

ظهور پلتفرم های رسانه های اجتماعی به کاربران وب فضایی برای بیان و به اشتراک گذاری افکار و نظرات خود در مورد انواع موضوعات و رویدادها داده است. یکی از محبوبترین شبکه های اجتماعی X (Twitter سابق) است. این شبکه به افراد اجازه می دهد پیام هایی را برای بیان علایق، علاقه مندی ها، نظرات و احساسات خود نسبت به موضوعات و مسائل مختلفی که در زندگی روزمره با آن مواجه می شوند منتشر کنند. این پیام ها توییت نامیده می شوند که بلادرنگ و حداکثر ۱۴۰ کاراکتر هستند. توییت حدود ۲۰۰ میلیارد توییت در سال، ۵۰۰ میلیون توییت در روز، ۳۵۰۰۰۰ توییت در دقیقه و ۶۰۰۰ توییت در ثانیه دارد [۱]. توییت امکان دسترسی به نماهای ناخواسته مجموعه وسیعی از کاربران در مورد محصولات یا رویدادهای خاص را فراهم می کند. نظرات یا ابراز احساسات در مورد سازمان ها، محصولات، رویدادها و افراد برای بازاریابی [۲] و مطالعات اجتماعی [۳] بسیار مفید است. تجزیه و تحلیل احساسات در نظرات بر رسانه های اجتماعی ارزشمند است زیرا به فرد اجازه می دهد تا بینش هایی در زمینه ها یا موضوعات خاص به دست آورد و در مجموعه های متنوعی از زمینه ها مانند بازاریابی و تبلیغات، رسانه های اجتماعی، اقتصاد و علوم سیاسی استفاده می شود. پلتفرم های رسانه های اجتماعی مانند توییت، فیس بوک و یوتیوب در حال حاضر از محبوبترین مکان ها برای بحث و بررسی محصولات و خدمات جدید در بازارهای مختلف برای مشتریان هستند. با این حال، ماهیت آشفته ذاتی محتوای رسانه های اجتماعی، چالش های جدی را برای کاربردهای عملی تحلیل احساسات، مانند استخراج بازخورد معنی دار برای محصولات یا خدمات، درک کیفیت محصول، یا برآورده کردن انتظارات مشتری ایجاد می کند [۴].

برخلاف متون استاندارد با کلمات زیاد که به جمع آوری آمار کافی کمک می کند، متون در رسانه های اجتماعی، به ویژه توییت، فقط از تعداد محدودی کاراکتر تشکیل شده است. علاوه بر این، هنگامی که یک کاربر پیامی (توییت) ارسال می کند، ممکن است دارای اختصارات یا کلمات اختصاری جدیدی باشد که به ندرت در اسناد متنی معمولی ظاهر می شوند. بنابراین، اعمال روش های سنتی در چنین محیطی عملکرد قابل قبولی را به همراه نخواهد داشت. علاوه بر این، اکثر رویکردهای موجود برای تجزیه و تحلیل احساسات در میکرو بلاگ ها، مانند توییت، متون نوشته شده توسط کاربران مختلف را به طور یکسان در نظر می گیرند و ویژگی های کاربر را کنار می گذارند [۵].

چنین رویکردهایی تحلیل احساسات را به عنوان یک پدیده زبانی، بدون تأکید بر جنبه های نویسنده (کاربر) و جنبه های خاص میکرو بلاگ، که از جنبه های غیر محتوایی بیرون می آیند، انجام می دهند. برای مثال، ویژگی های کاربر شامل حالات عاطفی (خلق) و سبک های نوشتاری است. جنبه های خاص میکرو بلاگ شامل فعالیت اجتماعی کاربر، تراکم شبکه، کمی سازی احساسات موضوع و غیره است. در این مقاله ما به تجزیه و تحلیل احساسات در میکرو بلاگ ها به عنوان وظیفه ای برای یکپارچه سازی اطلاعات از ابعاد مختلف، نه تنها از یک بعد (یعنی محتوا) نگاه می کنیم.

به طور کلی، سه روش اصلی برای تجزیه و تحلیل احساسات وجود دارد: (۱) روش مبتنی بر یادگیری ماشین (رویکرد نظارت شده)، (۲) روش مبتنی بر واژگان (رویکرد بدون نظارت)، و (۳) روش ترکیبی [۶]. اکثر مقالاتی که در مورد تحلیل احساسات محتوای رسانه های اجتماعی نوشته شده اند از رویکرد یادگیری ماشینی استفاده می کنند که در آن یک مجموعه داده برچسب گذاری شده برای آموزش یک الگوریتم استاندارد استفاده می شود [۴ و ۷-۱۰]. اشکال عمده این رویکرد توسعه مجموعه داده های مناسب است، زیرا طبقه بندی کننده های آموزش دیده عمده و وابسته به داده های برچسب گذاری شده ورودی هستند. الگوریتم های اصلی یادگیری ماشینی که در وظایف طبقه بندی احساسات (NB) Naive Bayes [۸] با دقت ۷۶ درصد و بردارهای ماشین پشتیبان (SVM) [۹] با دقت ۵۸ درصد هستند. J48 الگوریتمی برای تولید درخت تصمیم است که در مرجع [۱۰] پیشنهاد شده است. الگوریتم KNN، نزدیک ترین همسایه ها را در بین نمونه های آموزشی برچسب گذاری شده بر اساس برخی معیارهای شباهت جستجو می کند، و آن k همسایه ها را بر اساس امتیاز شباهت ها فهرست می کند [۴]. در روش مبتنی بر واژگان، از یک یا چند فرهنگ لغت حاوی واژگان عاطفی برای تخمین محتوای عاطفی بخش های متن استفاده می شود. اینها فهرستهای کلماتی هستند که در آنها به هر کلمه یک ارزش عاطفی اختصاص داده شده است، به عنوان مثال سطح مثبت یا منفی که معمولاً منتقل می کند [۱۱]. ذکر این نکته ضروری است که این رویکرد قواعد مختلف نثر و نحوی را با هم ترکیب می کند تا دقت آن را افزایش دهد [۱۲]. تعداد قابل توجهی از فرهنگ لغت وجود دارد که به صورت خودکار یا نیمه خودکار توسعه یافته اند، به عنوان مثال، General Inquirer (GI)، SentiWordNet، و WordNet-Affect. با این حال، اثربخشی رویکرد احساسات مبتنی بر واژگان با پوشش و دقت فرهنگ لغت مشخص می شود [۱۳]. همچنین در بسیاری از موارد تکیه بر کلمات عاطفی اغلب ناکافی است و به نتایج رضایت بخشی در تشخیص احساسات منجر نمی شود [۱۴]. روش ترکیبی، ترکیبی از یادگیری ماشین و رویکردهای مبتنی بر واژگان است. متن در ابتدا با استفاده از رویکرد مبتنی بر واژگان تحلیل می شود و خروجی تولید شده به عنوان داده های آموزشی به الگوریتم یادگیری ماشینی وارد می شود. خروجی فاز دوم متعاقباً برای گسترش فرهنگ لغت عاطفی استفاده می شود. کل فرآیند تا زمانی که برخی از معیارهای خاتمه برآورده شود تکرار می شود [۱۵]. یادگیری عمیق توسط بسیاری از محققین برای تحلیل احساسات توییت بررسی و اجرا شده است. یکی از مهمترین روشها، مدل های LSTM است که در طبقه بندی احساسات به عملکرد چشمگیری دست یافته اند [۳]. آنها توانایی مدیریت وابستگی های دوربرد را دارند. در مرجع [۱۶]، رویکردی برای یادگیری کلمات خاص احساسات از توییت های جمع آوری شده با استفاده از نظارت پیشنهاد شده است. سه شبکه عصبی برای یادگیری توسعه یافته است. سپس از کلمات آموخته شده برای ایجاد ویژگی هایی برای طبقه بندی احساسات توییت استفاده می شود. نویسندگان استدلال می کنند که عملکرد مناسب رویکرد آنها به این دلیل

حاصل می شود که شبکه اطلاعات احساسی متن را به جای بافت نحوی کلمات بدست می آورد. در مرجع [۱۷] از یک رویکرد یادگیری عمیق برای طبقه بندی توییت ها در هر دو سطح سند و عبارت، بر اساس شبکه های عصبی کانولوشنال استفاده کردند. در این مقاله از مدل شبکه عصبی برای مقاردهی اولیه کلمه embeddings استفاده می شود. این مدل بر روی مجموعه بزرگی از توییت ها آموزش داده شده است. مرحله دوم شامل اصلاح واژه embeddings است. سپس از یک شبکه عصبی کانولوشنال CNN و یک مجموعه بزرگ نظارت شده از راه دور استفاده می کنند. در نهایت از تعبیه های کلمه ایجاد شده و پارامترهای شبکه به دست آمده از مرحله دوم برای مقاردهی اولیه مدل استفاده می شود.


در این مقاله، می خواهیم، پیام های توییت و هشنگ های مختلف را نیز در الگوریتم CNN وارد کنیم و از چندین مدل مختلف مبتنی بر CNN برای شناسایی یک مدل یادگیری عمیق دقیق برای تحلیل احساسات و رسیدن به جواب بهتر بهره گیریم. این نوع رویکرد عملکرد و دقت وظایف طبقه بندی احساسات را در رسانه های اجتماعی افزایش می دهد.

در بخش دوم مقاله، مدل یادگیری عمیق CNN را بررسی می کنیم. در بخش سوم الگوریتم پیشنهادی با استفاده تکنیک های یادگیری عمیق ارائه می کنیم. در بخش چهارم نیز به ارزیابی عملکرد روش پیشنهادی خود خواهیم پرداخت. نتیجه گیری در بخش پنجم ارائه می شوند.

## ۲- شبکه عصبی کانولوشنال (CNN)

CNN یک شبکه عصبی عمیق است که از لایه هایی با فیلترهای کانولوشن استفاده می کند که روی مجموعه ای از ویژگی ها اعمال می شوند [۱۸]. یک شبکه عصبی کانولوشن از یک لایه ورودی، لایه های پنهان و یک لایه خروجی تشکیل شده است. در یک شبکه عصبی کانولوشن، لایه های پنهان شامل لایه هایی هستند که کانولوشن را انجام می دهند. معمولاً این شبکه شامل یک لایه است که حاصل ضرب نقطه ای هسته کانولوشن را با ماتریس ورودی لایه انجام می دهد. همانطور که هسته کانولوشن در طول ماتریس ورودی لایه می لغزد، عملیات کانولوشن یک نقشه ویژگی ایجاد می کند که به نوبه خود به ورودی لایه بعدی کمک می کند. به دنبال آن لایه های دیگری مانند لایه های pooling، لایه های کاملاً متصل و لایه های نرمال سازی قرار می گیرند [۱۹].

از لایه جدول جستجو به منظور ایجاد ویژگی های محلی در اطراف هر کلمه جمله استفاده می شود. این ویژگی ها از لایه های کانولوشن عبور می کنند. سپس ویژگی ها را در یک بردار ویژگی کلی ترکیب می کند که می تواند به لایه های کاملاً متصل تغذیه شود. این مدل در شکل ۱ نشان داده شده است. در این شکل مدل CNN دارای یک لایه کانولوشن است که در آن ویژگی ها به جای جملات کامل از پنجره کوچکی از کلمات استخراج می شوند.




شکل ۱: مدل CNN برای تجزیه و تحلیل کلمات

## ۲-۱- مدل های مرجع CNN

### ۲-۱-۱- شبکه VGG 16

VGGNet یک معماری از شبکه CNN است که از بلوک های متشکل از تعداد افزایشی لایه های کانولوشن با فیلترهای اندازه ۳×۳ استفاده می کند (شکل ۲). بلوک های جمع آوری حداکثر بین بلوک های کانولوشن پراکنده شده اند و اندازه این نقشه های فعال سازی را به نصف کاهش می دهند. در نهایت از یک بلوک طبقه بندی استفاده شده است که شامل دو لایه متراکم ۴۰۹۶ نرون و آخرین لایه که لایه خروجی است از ۱۰۰۰ نرون تشکیل شده است [۲۰].




شکل (۲): ساختار معماری VGGNet

۱۶ و ۱۹ به تعداد لایه های وزنی که هر شبکه دارد، اشاره دارد. مشکل VGGNet این است که از ۱۳۸ میلیون پارامتر تشکیل شده است که ۳۴٫۵ برابر بیشتر از GoogLeNet است که اجرای آن را در کامپیوترهای معمولی چالش برانگیز می کند [۲۱].

### ۲-۱-۲- شبکه Inception v3

شبکه Inception v3 در مقایسه با VGGNet و شبکه های Inception (GoogLeNet/Inception v1) هم از نظر محاسباتی کارآمدتر است، هم از نظر تعداد پارامترهای تولید شده توسط شبکه و هم از لحاظ سخت افزار استفاده شده (حافظه و سایر منابع). اگر قرار است تغییری در شبکه آغازین ایجاد شود، باید مراقب باشید که مزایای محاسباتی از بین نرود [۲۳].

بنابراین، انطباق یک شبکه Inception برای موارد استفاده مختلف به دلیل عدم اطمینان از کارایی شبکه جدید، یک مشکل است. در یک مدل Inception v3، چندین تکنیک برای بهینه سازی شبکه پیشنهاد شده است تا محدودیت ها را برای تطبیق آسان تر مدل کاهش دهند. این تکنیک ها شامل پیچیدگی های فاکتوریزه، منظم سازی، کاهش ابعاد و محاسبات موازی شده است (شکل ۳). تعداد پارامترهای آن، ۵ میلیون برای شبکه (V1) و ۲۳ میلیون برای شبکه V3 است.



شکل (۳): ساختار شبکه Inception v3

### ۳- روش پیشنهادی مبتنی بر شبکه CNN

برخلاف متون استاندارد با کلمات زیاد که به جمع آوری آماره کافی کمک می کند، متون در شبکه توپیتور، فقط از تعداد محدودی کاراکتر تشکیل شده است. علاوه بر این، هنگامی که یک کاربر توییتری را ارسال می کند، ممکن است دارای کلمات اختصاری جدیدی باشد که به ندرت در اسناد متنی معمولی ظاهر می شوند. بنابراین، اعمال روش های سنتی در چنین محیطی عملکرد قابل قبولی را به همراه نخواهد داشت. برای پرداختن به این موضوع، ما یک مدل مبتنی بر شبکه عصبی CNN را پیشنهاد می کنیم که ویژگی های متفاوت توپیتور و کاربر را در نظر می گیرد.

### ۳-۱- جاسازی کلمات

در سیستم های پردازش زبان طبیعی، کلمات به صورت نمادهای گسسته بیان می شوند. از آنجایی که این قالب رمزگذاری هر کلمه را به طور مستقل مورد بررسی قرار می دهد، هنگام تلاش برای شناسایی کلمات مشابه معنایی، اطلاعات اضافی را در اختیار سیستم قرار نمی دهد [۲۵]. جاسازی کلمه ها شامل فهرست هایی از کلمات  $w$  در یک فضای  $n$  بعدی است که در آن کلمات از نظر معنایی مشابه همسایه هایی هستند که می توانند با استفاده از فرهنگ لغت تولید شوند. اگر  $T \in \{w_1, w_2, \dots, w_n\}$  یک متن با  $n$  کلمه باشد که بر اساس متن متفاوت خواهد بود و  $f(w_i) = v_i$  یک تابع نگاشت باشد که کلمه  $w_i$  را در بردار  $v_i$  ترسیم می کند. روش های جاسازی کلمه به طور کلی به دو دسته، شامل تعبیه مبتنی بر فرکانس و مبتنی بر پیش بینی طبقه بندی می شوند [۲۶]. GloVe یک ابزار موثر مبتنی بر فرکانس است که از یک الگوریتم یادگیری بدون نظارت برای به دست آوردن نمایش های برداری برای

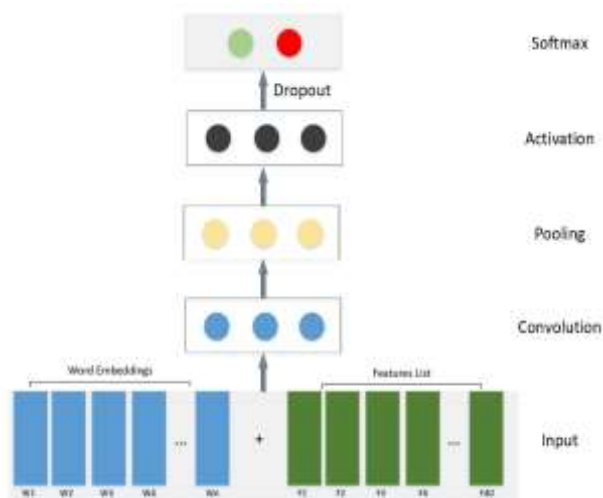
کلمات استفاده می کند. word2vec یکی از مدل های پیش بینی کارآمد محاسباتی برای یادگیری جاسازی کلمات از NLP است. word2vec از مجموعه کلمات پیوسته (CBOW) یا مدل Skip-gram [۲۶] استفاده می کند. در این مقاله از ما از روش word2vec استفاده کرده ایم. به منظور ساخت بردارهای تعبیه word2vec از طریق توییت های داده شده، از بسته Genism از پایتون استفاده کردیم. جدول ۱ فهرست پارامترهای مورد استفاده در مدل word2vec را شرح می دهد:

جدول ۱: پارامترهای استفاده شده در مدل Word2vec

Parameter name	Value(s)
Dimensionality of the word vectors (size)	100-300
Maximum distance between the current and predicted word within the distance (window)	5-15
Total frequency threshold (min count)	5-15
No of worker threads to train the model (workers)	8-10
Training iterations (epochs)	16-50
Maximum padding length	150-300

### ۳-۲- مدل پیشنهادی CNN

مدل پیشنهادی ما برای تحلیل احساسات از یک شبکه عصبی کانولوشنال تشکیل شده است. معماری سیستم در شکل ۴ ارائه شده است. این مدل با استفاده از کتابخانه Weka پیاده سازی شده است.



شکل ۴: ساختار مدل پیشنهادی CNN

اجزای اصلی شبکه عبارتند از: لایه های ورودی، کانولوشن، ادغام، فعال سازی و softmax. لایه ورودی شامل جاسازی های کلمه و لیستی از ویژگی ها است. Word Embedding به طور تصادفی مقداردهی اولیه شده است. علاوه بر این، ویژگی هایی که نویسنده توییت را توصیف می کنند به بردار تولید شده اضافه می شوند و سپس به لایه بعدی وارد می شوند. در لایه کانولوشن، هدف اصلی استخراج الگوها است. به منظور امکان یادگیری مرزهای تصمیم گیری غیر خطی، یک تابع فعال سازی غیر خطی در لایه فعال سازی قرار دارد. برای تابع فعال سازی از ReLU استفاده می کنیم زیرا سرعت آموزش را افزایش می دهد و نتایج دقیق تری نسبت به سایر توابع فعال سازی ایجاد می کند. مقادیر پارامترهای شبکه در جدول ۲ آورده شده است.

جدول ۲: مقادیر پارامترهای شبکه CNN

Parameter name	Value(s)
Maximum number of words (restricted for the same length)	30-42
Number of classes for output layer	2
Size of the vocabulary	25,000-30,000
Output dimensionality	140-200
Size of the kernel	3-8
Activation functions	relu, tanh
Batch size	16, 32, 64
Pooling types	2, maximum
Number of epochs (number of cycles)	20-50
Dropout rate probability	0.2-0.5
Optimizer	adagrad, adam
Loss function	Categorical crossentropy
Number hidden nodes	16-64

### جدول ۳: لیست ویژگی‌های مورد استفاده

F1	تعداد توییت‌های یک کاربر
{F2, F3, F4}	تعداد توییت‌های {مثبت، منفی، خنثی} ارسال شده توسط یک کاربر.
{F5, F6, F7}	احتمال نگرش {مثبت، منفی، خنثی} یک کاربر.
{F8, F9, F10}	میانگین تعداد توییت‌های {مثبت، منفی، خنثی} ارسال شده توسط یک کاربر.
F11	تعداد فالوورها.
F12	تعداد دوستان.
F13	تایید حساب.
F14, F15	تعداد صفت‌ها و میانگین آنها.
F16, F17	تعداد اسم‌ها و میانگین آنها.
F18, F19	تعداد قیدها و میانگین آنها.
F20, F21	تعداد افعال و میانگین آنها.
F22, F23	تعداد هشتگ‌ها و میانگین آنها.
F24, F25	تعداد اشاره‌ها (mention) و میانگین آنها.
F26, F27	تعداد URL‌ها و میانگین آنها.
F28, F29	تعداد شکلک‌ها و میانگین آنها.
F30, F31	تعداد علامت سوال و میانگین آنها.
F32, F33	تعداد علامت تعجب و میانگین آنها.
F34, F35	تعداد کلمات در هر توییت و میانگین آنها.
F36, F73	تعداد کلمات مثبت در واژگان بینگ لیو و میانگین آنها.
F38, F39	تعداد کلمات منفی در واژگان بینگ لیو و میانگین آنها.

جزئیات تمام ۴۰ ویژگی مورد استفاده برای آموزش مدل پیشنهادی در جدول ۳ آورده شده است. این ویژگی‌ها از مجموعه SemEval-2016 استخراج شده است.

### ۴- پیاده‌سازی و بررسی نتایج بدست آمده

ما مدل خود را بر روی دو مجموعه داده آموزش می‌دهیم که مجموعه داده‌های توییت هستند که توسط SemEval-2016 منتشر شده‌اند. مجموعه داده اول (SemEval-2016\_1) از ۷۷۴۲۴۴ توییت و دومین مجموعه (SemEval-2016\_2) از ۴۹۱۹۰۲ توییت تشکیل شده است. این دو مجموعه داده دارای شناسه توییت همراه با حاشیه‌نویسی با برچسب‌های مثبت و منفی هستند.

### ۴-۱- پیش پردازش داده ها

توییت‌های خام دارای داده‌های بی‌معنی و بدون ساختار و کلمات تکراری هستند. از این رو، هر آزمایش چند مرحله پیش پردازش را دنبال کرد تا تغییراتی در متن توییت‌ها ایجاد شود تا تجزیه و تحلیل متن بیشتر انجام شود. مجموعه داده‌ها مراحل پیش‌پردازش زیر را طی کردند:

- ۱) تبدیل متن به حروف کوچک
- ۲) حذف تمام ردیف‌های پوچ
- ۳) حذف تمام فضاهای خالی اضافی
- ۴) حذف تمام اعداد، حروف عددی و نقطه گذاری

### ۴-۲- گروه‌بندی مجموعه‌های ویژگی‌ها

از آنجایی که بسیاری از ویژگی‌ها در آزمایش‌های ما گنجانده شده‌اند، آن‌ها را در مجموعه‌ها گروه‌بندی کردیم. علاوه بر این، استفاده از مجموعه‌ها وضوح بیشتری را برای ما فراهم می‌کند که کدام مجموعه تأثیر بیشتری بر عملکرد مدل دارد. این مجموعه‌ها در جدول ۴ نشان داده شده است:

جدول ۴: استفاده از ویژگی‌ها در ترکیب‌های مختلف با دیتاست

Feature Set ID	Features Used
Set No. 1	F5, F6, and F7.
Set No. 2	F1 to F13.
Set No. 3	F2, F3, and F4.
Set No. 4	Word Embedding, F5, F6, and F7.
Set No. 5	Word Embedding.
Set No. 6	All features (F1 to F40).
Set No. 7	All features (F1 to F40) + Word Embedding.


### ۴-۳- نتایج بدست آمده

در اینجا ما یک ارزیابی عملکرد مقایسه‌ای از هر مدل از نظر پیش‌بینی صحیح ارائه می‌کنیم. نتایج جدول ۵ برای صحت، یادآوری، دقت، و F1 برای شش الگوریتم به دست آمده است.


به طور کلی، طبقه‌بندی‌کننده‌های یادگیری عمیق (CNN و LSTM) عملکرد خود را برخلاف سایر طبقه‌بندی‌کننده‌ها در یک روند ثابت نگه می‌دارند. بهترین دقت ۸۸،۷۱ درصد برای روش پیشنهادی CNN در مجموعه شماره ۴ بود، پس از آن LSTM با ۸۸،۱۳ درصد در همان مجموعه، و کمترین مقدار برای NB در مجموعه شماره ۲ ۴۸،۳۱ درصد بود. تأثیر مجموعه داده نامتعادل ۷ به وضوح بر روی NB و SVN مشاهده می‌شود. یکی از دلایل احتمالی که مجموعه داده نامتعادل تأثیر قابل توجهی بر عملکرد طبقه‌بندی‌کننده CNN پیشنهادی ندارد، نحوه محاسبه وزن‌ها در این نوع طبقه‌بندی‌کننده است. می‌توان مشاهده کرد که بهترین دقت عملکرد طبقه بندی توسط CNN (پیشنهادی)، LSTM و SVM به دست می‌آید. با این حال، همانطور که در شکل ۵ و ۶ نشان داده شده است، CNN دقت و یادآوری بالاتری نسبت به SVM در تمام مجموعه‌ها دارد.

جدول ۵: نتایج بدست آمده میزان دقت روش CNN (پیشنهادی)، SVM، NB، J48، KNN و LSTM

Set No.	1	2	3	4	5	6	7
CNN	82.63%	82.85%	82.93%	88.71%	87.08%	83.90%	88.46%
SVM	82.58%	82.58%	82.58%	86.84%	86.67%	82.58%	86.75%
NB	82.63%	48.31%	83.62%	85.16%	85.16%	59.38%	70.40%
J48	82.58%	82.25%	82.22%	87.25%	87.61%	82.33%	85.44%
KNN	81.78%	81.56%	80.96%	82.72%	82.66%	82.14%	82.83%
LSTM	83.63%	77.14%	84.29%	88.13%	84.83%	83.74%	86.48%



شکل ۵: معیار دقت برای برجسب‌های منفی



شکل ۶: معیار یادآوری (حساسیت) برای برجسب‌های منفی

این بدان معنی است که استفاده از دقت به عنوان تنها معیار اندازه‌گیری برای عملکرد طبقه‌بندی کننده کافی نیست. اگرچه تعداد نمونه‌های منفی در هر دو مجموعه داده کمتر از نمونه‌های مثبت است، مدل CNN پیشنهادی می‌تواند عملکرد خوب و پایداری را به ما ارائه دهد. عملکرد ضعیف NB تعجب‌آور نیست زیرا بر فرض استقلال مشروط در میان ویژگی‌ها متکی است، که به وضوح در اینجا درست نیست. همه ویژگی‌های مورد استفاده در آزمایش‌ها درجاتی از وابستگی را در بین آنها دارند.

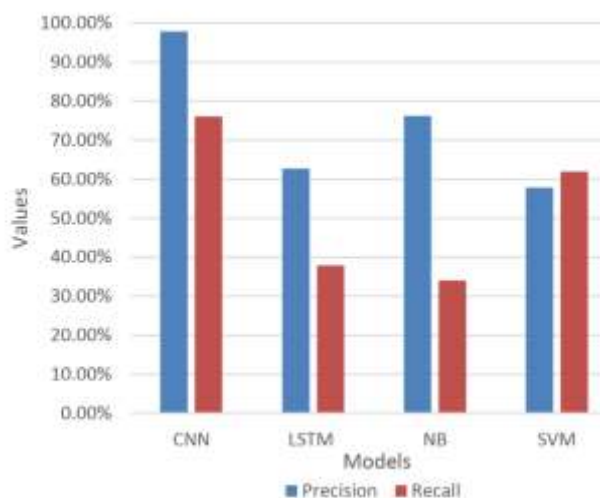
بر اساس مجموعه‌ها، بهترین دقت توسط مجموعه‌های شماره ۴ و ۷ به دست آمد. این انگیزه ما را برای استفاده از اطلاعات فراتر از محتوای یک توییت مشخص پشتیبانی می‌کند. برای بررسی نتایج این دو مجموعه برای تحلیل احساسات، F1 به همراه نمرات دقت و یادآوری شش مدل در هر دو مجموعه ۴ و ۷ در جدول ۶ آورده شده است. این معیارها بینش بیشتری در مورد عملکرد طبقه‌بندی‌کننده‌ها نسبت به متریک دقت به ما می‌دهند.

جدول ۶: امتیاز معیارهای F1، دقت و یادآوری شش مدل در مجموعه‌های شماره ۴ و ۷

	Precision		Recall		F1	
	Set No.		Set No.		Set No.	
	4	7	4	7	4	7
CNN	0.88	0.88	0.89	0.89	0.88	0.87
SVM	0.86	0.86	0.87	0.87	0.86	0.86
NB	0.85	0.83	0.85	0.70	0.85	0.74
J48	0.86	0.84	0.87	0.85	0.86	0.85
KNN	0.81	0.84	0.83	0.83	0.75	0.75
LSTM	0.87	0.86	0.88	0.86	0.86	0.83

در جدول ۶، بالاترین امتیازات F1 توسط مدل CNN پیشنهادی به دست آمده است (۰.۸۸، در مجموعه شماره ۴ و ۰.۸۷، در مجموعه شماره ۷). همچنین شایان ذکر است که مدل CNN عملکرد خوب ثابتی را در هر دو مجموعه نشان می‌دهد و به دنبال آن مدل LSTM قرار دارد. این نتایج تأیید می‌کند که استفاده از اطلاعات رفتاری کاربر علاوه بر محتوای متنی در تحلیل احساسات با بهبود دقت طبقه‌بندی می‌باشد.





شکل ۷: معیارهای یادآوری و دقت برای داده‌های برجسب مثبت

شکل ۷ نتایج به دست آمده از روش‌های پایه و مدل پیشنهادی را در دقت و یادآوری نشان می‌دهد. در بین مدل‌های پایه، بالاترین دقت، ۸۸،۶۹ درصد، در مجموعه داده ۴ با استفاده از LSTM، و ۷۷،۷۸ درصد در مجموعه داده ۷ با استفاده از SVM به دست آمده است. از سوی دیگر، NB کمترین عملکرد را در دقت در هر دو مجموعه داده ارائه می‌دهد. این شکل نشان می‌دهد که مدل پیشنهادی ما با یک حاشیه قابل توجه از همه مدل‌ها بهتر عمل می‌کند.

## ۵- نتیجه گیری

در این مقاله ما یک مدل تحلیل احساسات را ارائه کردیم که با ترکیب لیستی از ویژگی‌ها توسعه یافته است. ما معماری یک شبکه عصبی کانولوشنال (CNN) را پیشنهاد کردیم که نه تنها توییت‌های کاربر، بلکه رفتار کاربر را نیز در نظر می‌گیرد. ارزیابی ما کارایی مدل را در یک محیط رسانه اجتماعی نشان داد. مدل ما در دقت، یادآوری، دقت و F1 از روش‌های پایه بهتر عمل کرد. علاوه بر این، مدل پیشنهادی کمتر تحت تأثیر مسائل داده ناهمگن قرار گرفت. علاوه بر این، این رویکرد بر مسئله نیاز به مجموعه داده بزرگ برای آموزش مدل‌های یادگیری عمیق مانند LSTM غلبه کرد. نتایج تجربی اثربخشی رویکرد پیشنهادی را در مقایسه با سایر مدل‌های پایه که فقط از محتوای متنی استفاده می‌کنند، نشان داد. به طور خاص، نتایج بهبود قابل توجهی را در عملکرد و دقت وظایف طبقه‌بندی احساسات با رویکرد جدید نشان داد.

## مراجع

- [۱] A. S. M. Alharbi and E. de Doncker, "Enhance a Deep Neural Network Model for Twitter Sentiment Analysis by Incorporating User Behavioral Information", in, ser. Lecture Notes in Computer Science, D.-S. Huang, V. Bevilacqua, P. Premaratne, and P. Gupta, Eds., vol. 10361, Cham: Springer International Publishing, 2017, pp. 81–88, isbn: 978-3-319-63308-4. doi: 10.1007/978-3-319-63309-1\_8. [Online].
- [۲] A. S. M. Alharbi and E. de Doncker, "Emotional Awareness based Classification Model for Twitter Sentiment Analysis using a Deep Neural Network", in *Proceedings of the 21st International Conference on Artificial Intelligence ICAI'19*, CSREA Press, 2019, pp. 142–145, isbn: 1-60132-501-0.
- [۳] A. S. M. Alharbi and E. de Doncker, "Twitter sentiment analysis with a deep neural network: An enhanced approach using user behavioral information", *Cognitive Systems Research*, vol. 54, pp. 50–61, 2019, issn: 13890417. doi: 10.1016/j.cogsys. 2018.10.001. [Online].
- [۴] L. Jiang, M. Yu, M. Zhou, X. Liu, and T. Zhao, "Target-dependent Twitter Sentiment Classification", *Computational Linguistics*, pp. 151–160, 2021. [Online]. Available: <http://www.aclweb.org/anthology/P11-1016>.
- [۵] M. Thelwall, K. Buckley, and G. Paltoglou, "Sentiment in Twitter events", *Journal of the American Society for Information Science and Technology*, vol. 62, no. 2, pp. 406–418, 2021, issn: 15322882. doi: 10.1002/asi.21462. arXiv: 0912.3882.
- [۶] J. Lin, W. Mao, and D. D. Zeng, "Personality-based refinement for sentiment classification in microblog", *Knowledge-Based Systems*, vol. 132, pp. 204–214, 2019, issn: 09507051. doi: 10.1016/j.knosys.2017.06.031. [Online].
- [۷] J. W. Pennebaker, M. R. Mehl, and K. G. Niederhoffer, "Psychological Aspects of Natural Language Use: Our Words, Our Selves", *Annual Review of Psychology*, vol. 54, no. 1, pp. 547–577, 2022, issn: 0066-4308. doi: 10.1146/annurev.psych.54. 101601.145041. [Online].
- [۸] Social Networks", *Annual Review of Sociology*, M. McPherson, L. Smith-Lovin, and J. M. Cook, "Birds of a Feather: Homophily in vol. 27, no. 1, pp. 415–444, 2001, issn: 0360-0572. doi: 10.1146/annurev.soc.27.1.415. arXiv: 9702163 [cond-mat].



- massive-scale emotional contagion through social networks”, *Proceedings of the National Academy of Sciences*, vol. 111, no. 24, pp. 8788–8790, 2019, issn: 0027-8424. doi: 10.1073/pnas.1320040111. [۹]
- X. Hu, L. Tang, J. Tang, and H. Liu, “Exploiting social relations for sentiment analysis in microblogging”, in *Proceedings of the sixth ACM international conference on Web search and data mining - WSDM '13*, vol. 1, New York, New York, USA: ACM Press, 2018, p. 537, isbn: 9781450318693. doi: 10.1145/2433396.2433465. [۱۰]
- [11] and Explicit Similarity Network for User-Level Sentiment Classification of Microblogging”, in *PRICAI 2016: Trends in Artificial Intelligence: 14th Pacific Rim International Conference on Artificial Intelligence*, 2016, pp. 180–192, isbn: 978-3-319-42910-6. doi: 10.1007/978-3-319-42911-3. [Online]. Available: <http://link.springer.com/10.1007/978-3-319-42911-3>. [۱۱]
- J. Read, “Using emoticons to reduce dependency in machine learning techniques for sentiment classification”, in *Proceedings of the ACL Student Research Workshop on - ACL '05*, Morristown, NJ, USA: Association for Computational Linguistics, 2015, p. 43, isbn: 1932432515. doi: 10.3115/1628960.1628969. [Online]. [۱۲]
- L. Barbosa and J. Feng, “Robust Sentiment Detection on Twitter from Biased and Noisy Data”, in *Proceedings of the 23rd International Conference on Computational Linguistics: Posters*, Beijing, China, 2010, pp. 36–44, isbn: 1012341234. doi: 10.1016/j.sedgeo.2006.07.004. arXiv: 1702.08388. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1944566.1944571>. [۱۳]
- A. Bifet and E. Frank, “Sentiment Knowledge Discovery in Twitter Streaming Data”, in *Proceedings of the 13th international conference on Discovery science*, Canberra, Australia, 2010, pp. 1–15, isbn: 978-3-642-16183-4. doi: 10.1007/978-3-642-16183-4. [۱۴]
- A. Pak and P. Paroubek, “Twitter as a Corpus for Sentiment Analysis and Opinion Mining”, in *Seventh Conference on International Language Resources and Evaluation*, 2010, pp. 1320–1326. [۱۵]
- J. Cigarrán, Á. Castellanos, and A. García-Serrano, “A step forward for Topic Detection in Twitter: An FCA-based Approach”, *Expert Systems with Applications*, vol. 57, pp. 21–36, 2016, issn: 09574174. doi: 10.1016/j.eswa.2016.03.011. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0957417416301038>. [۱۶]
- A. Giachanou and F. Crestani, “Like It or Not: A Survey of Twitter Sentiment Analysis Methods”, *ACM Computing Surveys*, vol. 49, no. 2, pp. 1–41, 2016, issn: 0360-0300. doi: 10.1145/2938640. [Online]. Available: <http://dx.doi.org/10.1145/2938640>. [۱۷]
- Deep LSTM with Attention for Message-level and C. Baziotis, N. Pelekis, and C. Doukeridis, “DataStories at SemEval-2017 Task 4: Topic-based Sentiment Analysis”, in *Proceedings of the 11th International Workshop on Semantic Evaluation (SemEval-2017)*, Vancouver, Canada: Association for Computational Linguistics, 2017, pp. 747–754. [Online]. Available: <http://www.aclweb.org/anthology/S17-2126>. [۱۸]
- A. Bella, C. Ferri, J. Hernandez-Orallo, and M. J. Ramirez-Quintana, “Quantification via Probability Estimators”, in *2010 IEEE International Conference on Data Mining*, IEEE, 2010, pp. 737–742, isbn: 978-1-4244-9131-5. doi: 10.1109/ICDM.2010.75. [Online]. Available: <http://ieeexplore.ieee.org/document/5694031/>. [۱۹]
- G. Paltoglou and A. Giachanou, “Opinion Retrieval: Searching for Opinions in Social Media”, in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 8830, 2014, pp. 193–214, isbn: 10.1007/978-3-319-12511-4\_10. doi: 10.1007/978-3-319-12511-4\_10. [Online]. Available: <http://www.scopus.com/inward/record.url?eid=2-s2.0-84921407090&partnerID=40&md5=ab1923e2f9e3d1e308d0f2cdd664a480>[http://link.springer.com/10.1007/978-3-319-12511-4\\_10](http://link.springer.com/10.1007/978-3-319-12511-4_10). [۲۰]
- Trends@ in Information Retrieval*, vol. 2, no. 1-2, B. Pang and L. Lee, “Opinion Mining and Sentiment Analysis”, *Foundations and Applications*, pp. 1–135, 2008, issn: 1554-0669. doi: 10.1561/1500000001. [Online]. Available: <http://www.nowpublishers.com/article/Details/INR-001>. [۲۱]
- University Press, 2015, p. 367, isbn: 978-1-107-01789-4. B. Liu, *Sentiment Analysis Mining Opinions, Sentiment, and Emotions*. Cambridge [۲۲]
- D. Das and S. Bandyopadhyay, “Emotion Analysis on Social Media: Natural Language Processing Approaches and Applications”, *Spring-Verlag Wien*, pp. 19–37, 2014. doi: 10.1007/978-3-7091-1340-0. [Online]. Available: <http://link.springer.com/10.1007/978-3-7091-1340-0>. [۲۳]
- CEUR Workshop Proceedings*, vol. 718, pp. 81–92, D. Maynard and A. Funk, “Automatic detection of political opinions in tweets”, 2011, issn: 16130073. doi: 10.1007/978-3-642-25953-1\_8. [۲۴]
- S.-M. Kim, S.-M. Kim, E. Hovy, and E. Hovy, “Determining the sentiment of opinions”, *Proceedings of the 20th international conference on Computational Linguistics - COLING '04*, 1367–es, 2014. doi: 10.3115/1220355.1220555. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1220355.1220555>. [۲۵]
- A. Muhammad, N. Wiratunga, and R. Lothian, “A Hybrid Sentiment Lexicon for Social Media Mining”, in *2014 IEEE 26th International Conference on Tools with Artificial Intelligence*, IEEE, 2014, pp. 461–468, isbn: 978-1-4799-6572-4. doi: 10.1109/ICTAI.2014.76. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/>