



تجزیه و تحلیل احساسات با استفاده از سنجش نظرات

زهرا جاهد،^۱ جلال‌الدین نصیری^۲

^۱ دانشکده برق و کامپیوتر، دانشگاه آزاد اسلامی تهران شمال
^۲ دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس

چکیده

تجربه و تحلیل احساسات حوزه‌ای از پژوهش پردازش زبان طبیعی است که در مورد حالت یا فکر و المان‌های گوینده یک متن است. این پژوهش بر روی روش‌های مختلف استفاده شده برای طبقه بندی یک تکه متن زبان طبیعی است که بر روی نظر یا ایده بیان شده تمرکز می‌کند. به عنوان مثال آیا نگرش مثبت است یا منفی. همچنین ما روش دو مرحله‌ای (طبقه بندی که در آن تقارن اعمال شده است) از طبق یک نظر سنجی مورد بحث قرار می‌دهیم.

واژه‌های کلیدی: تجزیه و تحلیل احساسات؛ نظر کاوی؛ تشخیص حالت؛ یادگیری ماشین؛ NLP

۱- مقدمه

این مقاله بر روی روش‌های مختلف طبقه بندی یک تکه متن زبان طبیعی که بر روی نظرات بیان شده، تمرکز می‌کند. ما بر مبنای لغات و یادگیری ماشین بحث خواهیم کرد (در بخش ۳) سیستم پیشنهادی برای طبقه بندی نظرات (بازدید) مشتریان در بخش ۴ و در بخش ۵ راه اندازی آزمایش به همراه مشاهدات.

۲- کارمربوطه

دو حوزه اصلی این پژوهش در طبقه بندی احساسات روش‌های یادگیری ماشین و روش‌های مبنی بر لغت است. در روش لغوی: یک فرهنگ لغت آماده شده است که در آن میزان پلاریته لغات را در آن ذخیره می‌کنیم. برای محاسبه پلاریته یک متن، امتیاز پلاریته از یک لغت در یک متن، اگر در فرهنگ لغت موجود باشد یک امتیاز مثبت و اگر موجود نباشد یک امتیاز منفی دریافت می‌کند و بر همین اساس امتیاز دهی بر روزرسانی می‌شود. امتیاز آن به امتیاز کلی اضافه. اگر امتیاز پلاریته کلی از یک متن مثبت است، که متن به عنوان مثبت طبقه بندی شده است، در غیر این صورت منفی طبقه بندی شده است. گرچه این روش بسیار ابتدایی به نظر می‌رسد، انواع دیگری از این روش لغوی گزارش شده است که از دقت بالایی قابل توجهی برخوردار است.

از آنجایی که امتیاز پلاریته متن به امتیازی که از لغت نامه می‌گیرد بستگی دارد، حجم زیادی از کار به کشف لغاتی که مؤثرترند اختصاص داده شده است. Hatzivassiloglou و Wiebe دقت بیش از ۸۰٪ را با استفاده از برچسب گذاری دستی کلماتی که شامل صفات منحصر بفرد هستند برای ارزیابی عدم وابستگی (یا استقلال) جمله گزارش داده‌اند. با وجود این Kennedy و Inkpen، با استفاده از همان روش، نرخ دقت بسیار کمتر از ۶۲ درصد در یک مجموعه داده‌ها متشکل از بررسی‌های فیلم بدست آوردند. ترنی با استفاده از موتور جستجو در اینترنت میزان پلاریته کلمات را تعیین کرد. ترنی با استفاده از دو موتور جستجوی آلتا و ویستا پرس و جو را انجام داد. با برچسب گذاری به صورت خوب و برچسب گذاری به صورت بد، پلاریته از کلمه مورد نظر در کنار نتایج جستجو که بیشترین بازدید را داشت مشخص شد. این روش منجر به دقت ۶۵٪ است. (پلاریته توسط کلماتی که بیشترین تیک رو داشتند تعیین شد).

Kamps و همکاران و Andreevskaia و همکاران با استفاده از پایگاه داده WordNet میزان پلاریته کلمات تعیین کردند. آنها هر کلمه را با دو کلمه برچسب گذاری شده مقایسه کردند (معمولاً خوب و بد). برای یافتن نزدیکترین کلمه به کلمه مورد نظر در سلسله مراتب از کلمات نزدیکترین کلمه به کلمه مورد نظر امتیازی دریافت می‌کند که مقدار آن به امتیاز کل لغت‌نامه اضافه می‌شود. سطح دقت گزارش شده از این روش ۶۴٪ می‌باشد.

از سوی دیگر ترنی و شرکت Littman ارتباط معنایی بین کلمه هدف و هر کلمه از مجموعه انتخاب شده از کلمات مثبت و منفی با یک مقدار واقعی طرح ریزی کردند. و به این ترتیب اختلاف ارتباط کلمات از مجموعه داده مثبت و مجموعه داده منفی با نرخ ۸۲٪ بدست آمد.



در روش یادگیری ماشین، یک سری از بردارهای ویژگی انتخاب و مجموعه‌ای از بخش‌هایی برچسب زده شده برای آماده کردن این مدل مهیا می‌شوند. این مدل می‌تواند برای طبقه بندی بخش‌هایی از متن بدون برچسب قابل استفاده باشد. در روش‌های یادگیری ماشین، انتخاب ویژگی برای طبقه بندی نرخ موفقیت امری حیاتی است. تقریباً به طور عادی انواع نگاشت‌ها (یک کلمه از یک متن) یا (دو کلمه یا بیشتر از یک متن) به عنوان ویژگی انتخاب می‌شوند.

رایجترین تکنیک طبقه بندی به کار گرفته شده در یادگیری ماشینی (SVM) ماشین‌های بردار پشتیبانی، بیس ساده (Naive bayes)، حداکثر آنتروپی الگوریتم (maximum entropy algorithm) هستند. نتایج دقیق در این الگوریتم‌ها تا حد بسیار زیادی به ویژگی‌های انتخابی بستگی دارد.

روش‌ها

۱-۳- روش لغوی

روش لغوی! روش لغوی با یک پیش پردازش از متن که باید تحلیل شود، آغاز می‌گردد. مجموع امتیازدهی به لغات در متن در ابتدا برابر صفر مقداردهی می‌شود. در ادامه بررسی می‌شود که کلمه در لغت‌نامه وجود دارد یا نه. اگر داشته باشد یک امتیاز مثبت و اگر در لغت‌نامه نباشد، یک امتیاز منفی دریافت می‌کند که بر همین اساس، امتیازدهی، به روز رسانی می‌شود. امتیاز انواع روش لغوی عبارتند از:

۱-۱-۳- روش خط مبنا

در این روش دیکشنری به تعداد لغات برچسب زده به صورت مثبت و منفی محدود می‌شود.

۲-۱-۳- موتور جستجو (ریشه یابی)

اساساً به معنای خلاص شدن از پیشوند ها و پسوندهاست. الگوریتم پسوندهای نظیر `watching` , `watched` را از فعل `watch` جدا می‌کند. پس هر لغت قبل از به کارگیری ریشه‌یابی می‌شود. مثال: من واقعا این فیلم را دوست داشتم به این جمله تغییر می‌کند: من واقعا این فیلم را دوست دارم. `I really liked this movie` به `I really like this movie` تغییر می‌کند.

۳-۱-۳- برچسب دهی مقولات دستوری (مانند اسم، صفت، ضمیر و غیره)

در پیکره زبان شناسی، علاوه بر برچسب‌دهی مقولات دستوری (pos or post tagging) برچسب‌دهی دستوری که فرآیند نشان‌دار کردن یک کلمه در متن (بدنه) بر طبق مقوله دستوری و مفاهیم نامیده می‌شود.

۴-۱-۳- WordNet

WordNet کلمات انگلیسی را به سری‌هایی از مترادف‌ها تبدیل می‌کند که `synsets` نام دارند و تعریف کوتاه و عمومی‌ای فراهم می‌کند و ارتباطات معنایی مختلف بین این سری‌های مترادف را ثبت می‌کند.

WordNet اسم‌ها، فعل‌ها، قیدها، و صفات را تشخیص می‌دهد زیرا از قوانین گرامری متفاوتی استفاده می‌کند - ولی حرف اضافه، ضمیر و غیره را شامل نمی‌شود. این می‌تواند خیلی مفید باشد زیرا می‌تواند به ما بگوید که کدام کلمات صفت هستند مثل "بزرگ"، "فوق العاده"، "شگفت انگیز"، که در تحلیل احساس خیلی مفید هستند. همچنین ما می‌توانیم مترادف‌های تمام کلمات را بیابیم. مثلاً اگر شما با کلمه‌ی "شگفت انگیز" مواجه شوید در نتیجه می‌توانید از اطلاعاتی درباره‌ی مترادف‌های "شگفت انگیز" استفاده کنید تا نتایج بهتری را در دسته بندی جملات به عنوان مثبت و منفی به دست آورید.

۵-۱-۳- N-grams

به جای جدا در نظر گرفتن هر کلمه، کلمات پشت سر هم می‌توانند در نظر گرفته شوند تا عبارات عمومی پیدا شوند. این رشته‌های معمول از کلمات را `n-gram` می‌نامند. اگر عبارات طولانی تر را نیز بررسی کنید نتایج بهتری خواهید داشت. مثال داده شده‌ی "knock your socks off" (تحت تأثیر قرار دادن) یا فقط "socks off" (درآوردن جوراب) نمونه‌ی خوبی را نشان می‌دهد. مثال: "این فیلم شما را تحت تأثیر قرار می‌دهد".

۶-۱-۳- قوانین ربط:

هدف اصلی استفاده از قوانین ربط این است که معنای دقیق یک جمله با استفاده از قوانین گرامری استخراج شود. عموماً یک جمله فقط بیانگر یک معنا است مگر اینکه نوعی حرف ربط استفاده شود مثل "اما"، "اگرچه"، "با این حال"، "در حالی که"، که اینها جهت جمله را عوض می‌کنند. قوانین ربط در زیر بیان شده اند:

۱. اگرچه (عبارت A)، (عبارت B).



مثال: اگرچه این دوربین خوب است، متأسفانه عمر باتری آن پایین است.

در این حالت عبارت A را می توان حذف کرد، و عبارت B را می توان به عنوان شناسه ی احساس استفاده کرد.
۲. (عبارت A)، اما (عبارت B).

مثال: ظاهر این دوربین خوب نیست، اما عمر بالایی دارد.

در این حالت عبارت A را می توان حذف کرد، و عبارت B می تواند برای شناسایی احساس به کار شود.
با استفاده از قوانین ربط، جملات منطقی تر و واضح تر می شوند. Low و Hemnaath^۶ اثبات کردند که استفاده از قوانین ربط باعث افزایش دقت تحلیل احساس به میزان ۵٪ می شود.

۳-۱-۷- ایست واژه ها:

ایست واژه ها معمولاً کلماتی غیر معنایی هستند مثل حرف تعریف، حرف اضافه، حرف ربط، و ضمیر. حروف تعریف مثل "a" و "the" و ضمیری مثل "he"، "they"، و "I" اطلاعات کمی درباره ی احساس ارائه می کنند یا هیچ اطلاعاتی ارائه نمی کنند.
در کامپیوتر، ایست واژه ها کلمه هستند، که پس از پردازش داده ی زبان طبیعی (متن) یا قبل از آن فیلتر می شوند. می توانیم لیستی از چنین کلماتی را از اینترنت دریافت کنیم و از آن برای پیش پردازش استفاده کنیم تا از شر چنین کلماتی خلاص شویم زیرا می دانیم که آنها هیچ اطلاعاتی را ارائه نمی کنند. آنها اساساً فقط دسته بندی کننده را گیج می کنند و مشکل ایجاد می کنند.

۳-۱-۸- روش منفی کردن:

یک کلمه ی منفی کننده مثل "not" ارزش کلمه ای مؤثر را معکوس می کند. مثلاً "not good" مشابه کلمه ی "bad" است. با استفاده از تکنیکی که توسط Chen و Das^۹ ارائه شد، یک تگ "NOT_" را می توان به هر صفت بین کلمه ی منفی و اولین نقطه گذاری پس از آن قرار داد. مثال: "I do not like this movie" تبدیل می شود به "I do NOT_like this movie". در unigram ها ارزش "like (دوست داشتن)" مثبت است اما یک کلمه ی منفی کننده ی "not" وجود دارد، بنابراین جایگزین شده و به کلمه ی بعدی متصل می شود. در نتیجه 'NOT_like' می تواند ارزش کلمه را تغییر دهد و بنابراین قطبیت کل جمله تغییر می کند.

۳-۲- روش های یادگیری ماشین

مدل پایه برای ایجاد بردارهای ویژگی می تواند به شکل زیر باشد:

۱. یک تگ کننده ی POS را به هر نمونه در سری داده ی یادگیری بیفزایید.
۲. تمام صفات/قیود را از هر نمونه جمع آوری کنید.
۳. یک سری کلمات محبوب تشکیل شده از N صفت و قید را بسازید.
۴. از این سری کلمات محبوب برای ایجاد بردار ویژگی برای هر نمونه در سری داده ی تست استفاده کنید.

۳-۲- ماشین های بردار پشتیبانی (SVM):

یک SVM استاندارد یک سری داده ی ورودی را می گیرد و به ازای یک ورودی، پیش بینی می کند که کدام یک از کلاس های بالقوه، خروجی را شکل می دهند. وقتی یک سری نمونه ی یادگیری وجود داشته باشند که هر یک متعلق به دسته ای خاص هستند، الگوریتم یادگیری SVM یک مدل را می سازد که می تواند برای شناسایی نمونه های جدید در یک دسته به کار رود. یک مدل SVM به شکل نقاطی در فضا نشان داده می شود، که به طریقی نگاشت شده اند که اعضای دسته های جدا با فاصله ای تا حد ممکن زیادی از هم جدا شده باشند. سپس نمونه های جدید به همان فضا نگاشت می شوند و بر اساس اینکه در کدام سمت این فاصله قرار دارند پیش بینی می شود که به یکی از دسته ها تعلق دارند. به شکل رسمی تر، یک ماشین بردار پشتیبانی یک ابر صفحه یا یک سری ابر صفحه را در فضای نامحدود ایجاد می کند، که می تواند از آن (آنها) برای دسته بندی استفاده کند. طبیعتاً یک جداسازی خوب توسط ابر صفحه ای به دست می آید که بیشترین فاصله را با نزدیک ترین داده ی یادگیری در هر کلاس دارد. هر چه فاصله بزرگتر باشد، خطای تعمیم در دسته بندی کننده کمتر خواهد بود.



حداکثر دقت با Hong, Yu و Vasileios Hatzivassiloglou^{۱۰} با استفاده از Naive Bayes بدست آمد، که یک الگوریتم رایج یادگیری ماشین نظارت شده است. این روش فرض می کند که حداقل یک مجموعه از حروف تعریف با برچسب های عقیده و حقیقت از پیش تعیین شده در اسناد وجود دارند. آنها از تک کلمات بدون ریشه یابی و ایست واژه ها استفاده می کنند. Naive Bayes یک سند d را به کلاس c تخصیص می دهد، که P(c|d) را با استفاده از قانون Bayes حداکثر می کند.

(۱)

$$p(c | d) = \frac{p(c)p(c | d)}{p(d)}$$

۴-سیستم ارائه شده

در تحلیل احساس، قطبیت بسیاری از کلمات مخصوص به حوزه و بافت مورد استفاده است. مثلاً کلمه ی "long" در جمله ی "long battery life" (طول عمر بالای باتری) مثبت تلقی می شود، در حالی که در "long shutter lag" (وقفه ی طولانی دیافراگم دوربین) منفی تلقی می شود. نادیده گرفتن چنین عباراتی می تواند منجر به پوششی ضعیف شود در حالی که تگ کردن آنها با قطبیتی کلی ممکن است دقت ضعیفی را نتیجه دهد. B. Chen و J. Fang^{۱۱} نشان دادند که شناسایی واژه های حساس به بافت منجر به بهبود زیادی می شود. در مورد هر جمله در بازبینی، ما سعی می کنیم که جنبه ی محصول مورد بحث و سپس احساس مربوطه را شناسایی کنیم.

از آنجایی که ضروری است که حوزه ای که هر کلمه در موردش صحبت می کند را بدانیم، هدف ما ایجاد واژه های مخصوص به بافت های مختلف است که حوزه های مختلف و احساس های مختلف مربوط به آن حوزه ها را نشان دهند. مثلاً برای حوزه ی "کیفیت دوربین عکاسی" ما دو لیست داریم. یک لیست شامل کلمات و عباراتی مثل "تصویر، عکس، منظره، وضوح و غیره" است، که نشانگر های خوبی از موضوع مورد بحث "کیفیت عکس" هستند، و لیست دیگر شامل کلمات و عباراتی می شود که نشان دهنده ی احساس مثبت/منفی درباره ی کیفیت عکس هستند مثل "واضح، شارپ" که مثبت هستند در حالی که "تار" منفی است.

واژه های احساسی مخصوص حوزه های مختلف می توانند از ابتدا با استفاده از ترکیبی از فیلترهای پیکره، جستجوی اینترنت با استفاده از الگوهای زبانی و تکنیک توسعه ی دیکشنری ساخته شوند. لیستی که حاوی جنبه هایی از محصول است را می توان به شکل دستی تعریف کرد و سپس با استفاده از جستجوی اینترنتی و دیکشنری ها آن را توسعه داد. متودی که استفاده کردیم در زیر توضیح داده شده است:

پیکره ی یادگیری استفاده شده طوری است که هر بازبینی با یک جنبه و احساس مربوطه نشانه گذاری می شود. ما از LibSVM^{۱۲} استفاده می کنیم که کتابخانه ای برای دسته بندی SVM در هر دو مرحله است. از آنجایی که تحلیل قرار است دو بخشی باشد (شناسایی جنبه و شناسایی احساس)، ما به مدلی نیاز داریم که جنبه را دسته بندی کند و مدلی به ازای هر جنبه برای دسته بندی قطبیت مورد نیاز است. بنابراین اگر n جنبه وجود داشته باشند، ۱ مدل با n کلاس خروجی و n مدل با ۲ کلاس خروجی (مثبت و منفی) خواهیم داشت.

برای ایجاد مدل دسته بندی بعد، ویژگی های استفاده شده همگی واژه هایی در تمام بازبینی پس از پیش پردازش هستند. این فرایند در شکل ۱ نشان داده شده است. پیش پردازش باعث توکن بندی واژه ها می شود، باعث می شود که واژه ها قبل از اولین صفت یا قید بعدی نیایند، ایست واژه ها را حذف می کند و ریشه ی هر واژه را می یابد. از بین این ویژگی ها، ویژگی هایی با کمتر از ۴ تکرار یا بیشتر از ۳۰ تکرار که برای بیش از ۱ جنبه در بازبینی آمده اند حذف می شوند. دلیل این کار این است که واژه هایی با تکرار بیش از ۳۰ خیلی عمومی هستند (مثل "تلفن" در حوزه ی موبایل) و آنهایی که تکرار کمتر از ۴ دارند خیلی متمایز هستند و در بازبینی های زیادی ظاهر نمی شوند. آنها فقط طول ویژگی را افزایش داده و کمک چندانی نمی کنند.

برای ایجاد مدل هایی برای دسته بندی قطبیت، تمام واژه هایی که در بازبینی برای آن جنبه پس از پیش پردازش ظاهر شده اند (مشابه بالا) گزینش می شوند. این در شکل ۲ نشان داده شده است.

وقتی یک مدل برای دسته بندی جنبه و یک مدل برای دسته بندی قطبیت ایجاد شود، ما می توانیم بازبینی کاربر را بپذیریم. بازبینی کاربر ممکن است شامل بسیاری از زیرجملات و جملات باشد، که هر یک در مورد جنبه های مختلفی صحبت می کنند. ورودی در اطراف '، '، '، '، '، ' و ' شکسته می شود. شناسایی جنبه با استفاده از مدل اول برای هر زیرجمله انجام می شود. اگر زیرجملات مجاور در مورد جنبه ی یکسانی صحبت کنند با هم ترکیب می شوند. سپس شناسایی قطبیت در مورد هر بخش انجام می شود.


امتیاز نهایی برای بازبینی از قطبیت هر جنبه، تعداد نمونه های یادگیری برای آن جنبه و تعداد کلی نمونه های یادگیری محاسبه می شود. ما می توانیم بگوییم که یک جنبه ی خاص در صورتی برای کاربران مهمتر است که نمونه های بسیاری در داده ی یادگیری در مورد آن جنبه



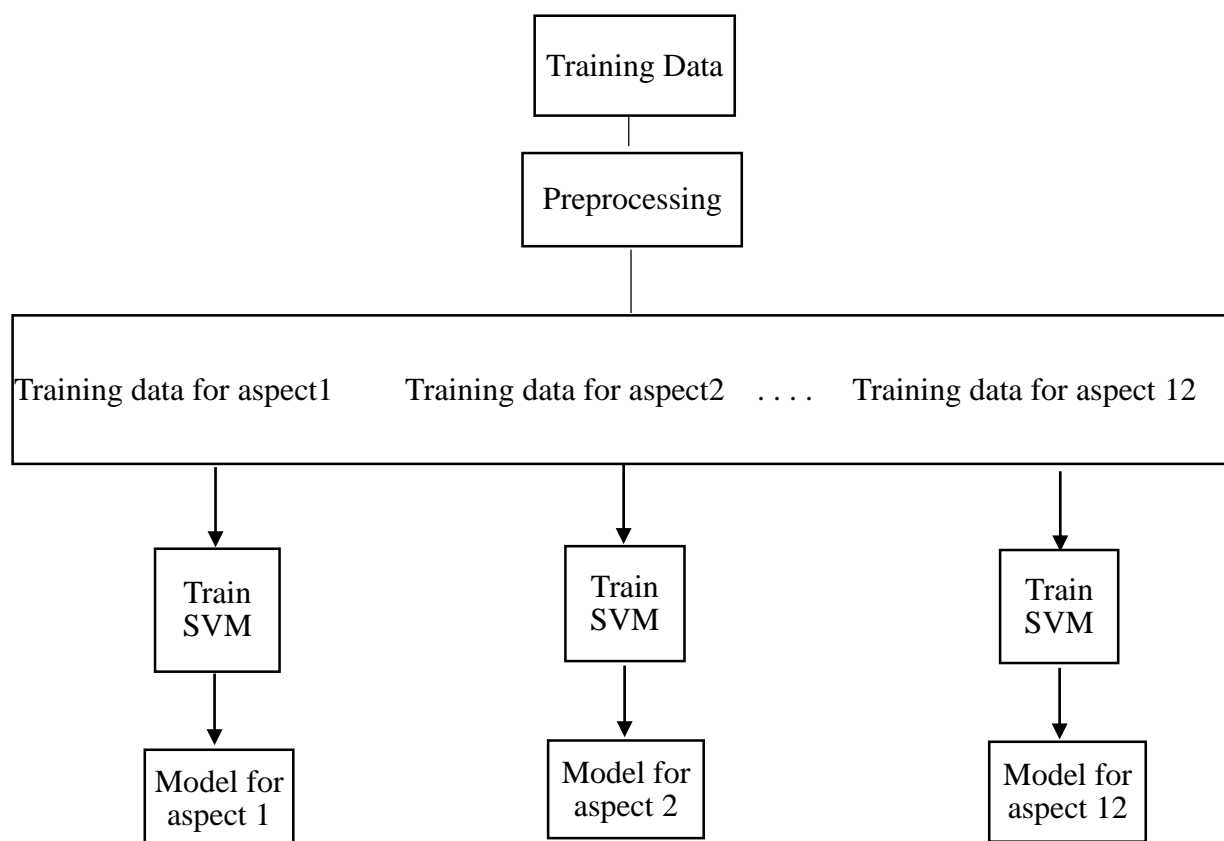
صحت کنند. بنابراین ما قطبیت را ضربدر تعداد نمونه ی آن جنبه می کنیم تا امتیاز نهایی محاسبه شود. اگر بیش از ۱ بخش از بازبینی در مورد یک جنبه صحت کند در نتیجه قطبیت آن جنبه، جمع مقادیر (مقادیر بالقوه برای قطبیت ۱ و 1- هستند) است.

۵- پیکربندی آزمایش و مشاهدات

ما یک پیکره ی یادگیری از ۱۹۴۰ بازبینی داشتیم که به شکل دستی جنبه و قطبیت بازبینی ها را مشخص کردیم. یک لیست ویژگی برای شناسایی جنبه شامل تمام واژه ها پس از پیش پردازش و حذف مواردی می شود که در بازبینی برای بیش از یک جنبه ظاهر شده اند و تعداد تکرار آنها خارج از محدوده ی 30-4 است. این لیست ویژگی برای ایجاد مدلی برای دسته بندی جنبه به کار رفت. ما تحلیل حوزه ی موبایل را انجام دادیم. ما ۱۲ جنبه ی مختلف را برای حوزه ی موبایل شناسایی کردیم. برای هر جنبه، واژه های ثابت کمی انتخاب شدند، مثل "os" برای جنبه ی "operating system (سیستم عامل)". این واژه های ثابت به لیست ویژگی ها برای دسته بندی جنبه افزوده شدند. این منجر به افزایش چشمگیری در دقت شد. برای هر جنبه، یک مدل برای دسته بندی قطبیت ایجاد شد. برای این مدلها، لیست ویژگی شامل تمام واژه هایی بود که پس از پیش پردازش برای آن جنبه ظاهر شدند. ما با استفاده از هسته ی خطی برای تمام دسته بندی کننده ها به حداکثر دقت دست یافتیم. دقت ما ۷۸٫۰۵٪ بود. تست با استفاده از ۴۱ بازبینی انجام شد. برای مقایسه، دقت های مختلف با هسته های مختلف در جدول ۱ و ۲ آمده اند.



شکل ۱. مدل پیش بعدی برای طبقه بندی پلاریته



شکل ۲. مدل برای دسته بندی بعدی

با بررسی های بعمل آمده از ۴۱ بازخورد کاربران مشخص گردید که پیش گام not در یک پیش پردازش منجر به افزایش نرخ دقت به میزان ۲/۴۴ درصد بوده است. که این افزایش مشاهده شده بخاطر بررسی هایی که شامل "doesn't" بودند، بود. مرحله رمزگذاری آن را تبدیل به "does n't" کرده و "n't" پیش گام ظهور فعل یا صفت بعدی میشود. و جدا کردن stopword، یک پیش پردازشی که منجر به افزایش دقت ۴/۸۹ درصدی می شود را ایجاد می کند. عبارت دیگر ریشه یابی، افزایش دقتی تا حدود ۱۲/۲ درصد را بدست می دهد. تمامی این افزایش ها در اندازه دقت، با استفاده از کرنل خطی، آزمایش شده اند.

جدول ۱. دقت دسته بندی بعدی

Kernel	T1=0	T1=1	T2=2	T1=3
Accuracy	70.73%	12.19%	12.19%	12.19%

جدول ۲. دقت پیش بندی برای طبقه بندی پلاریته

t1=0	t1=1	t1=2	t1=3
------	------	------	------



$t_2=0$	78.50%	65.85%	73.17%	70.73%
$t_2=1$	65.85%	46.34%	46.34%	46.345%
$t_2=2$	65.85%	46.34%	46.34%	46.34%
$t_2=3$	63.4%	46.34%	46.34%	46.34%

گزینه ی کرنل خطی (گزینه ی کرنل با 't' در LibSVM نشان داده شده است) دو بار استفاده شده است. ابتدا در طبقه بندی بُعد و دوم برای طبقه بندی قطب. زمانیکه تعداد ترکیبات از تعداد کرنل های خطی نمونه اطلاعات آموزشی بیشتر شد، بنظر می رسد که انتخاب درستی صورت پذیرفته است. لذا دقت در طبقه بندی بُعد، بستگی به یک مقدار مجرد از 't' دارد، درحالیکه دقت برای طبقه بندی پلاریته به ۲ مقدار از 't' بستگی دارد. مقادیر ۴ کرنل ممکن که می توانند در زمانهای $t=0/1/2/3$ بکار روند در زیر آورده شده است. جدول ۱ میزان دقت و صحت را برای طبقه بندی بُعد و جدول ۲ نتایج طبقه بندی پلاریته را نشان می دهد. گزینه کرنل اول با t_1 و گزینه ی کرنل دوم با t_2 نشان داده شده است.

۶- نتیجه و طرح نهایی

ما مجموعه ایی از تکنیک ها را برای طبقه بندی بُعد و تشخیص پلاریته منتهی از مقاله (یا تحقیق یا نظرات) را با استفاده از ترکیبی از ماشین یادگیری (SVM) و مجموعه واژه نامه ی مربوطه، اجرا کردیم. نتایج تجربی ما نشان می دهند که تکنیک های پیشنهادی، دقتی در حدود ۷۸٪ را بدست می دهند و نویدبخش انجام هرآنچه که از این تکنیک ها انتظار می رود، می باشند. ما معتقدیم استفاده ی هرچه بیشتر از مجموعه داده های وسیع تر اطلاعاتی از بررسی هایی (نظرات مشتریان) که در اینترنت در دسترس است، این اپلیکیشن را قابل استفاده تر کرده و قلمرو استفاده آن را وسیع تر می کند.

۷- مراجع

- [1] Hatzivassiloglou, V., Wiebe, J. *Effects of Adjective Orientation and Gradability on Sentence Subjectivity*. **Proceedings of the 18th International Conference on Computational Linguistics**, New Brunswick, NJ, 2000.
- [2] Kennedy, A., Inkpen, D. *Sentiment Classification of Movie and Product Reviews Using Contextual Valence Shifters*. **Computational Intelligence**. 2006. pp. 110-125.
- [3] Turney, P. *Thumbs Up or Thumbs Down Semantic Orientation Applied to Unsupervised Classification of Reviews*. **Proceedings of ACL**, Philadelphia, PA, July 2002. pp. 417-424.
- [4] Kamps, J., Marx, M., Mokken, R. J. *Using WordNet to Measure Semantic Orientation of Adjectives*. LREC 2004. Volume IV, pp. 1115-1118.
- [5] Andreevskaia, A., Bergler, S., Urseanu, M. *All Blogs Are Not Made Equal: Exploring Genre Differences in Sentiment Tagging of Blogs*. **International Conference on Weblogs and Social Media (ICWSM-2007)**, Boulder, CO, 2007.
- [6] Hemnaath, R., and Low, B. W. 2010. *Sentiment Analysis Using Maximum Entropy and Support Vector Machine*. Semantic Technology and Knowledge Engineering in 2010. Kuching, Sarawak
- [7] Turney, P.D., Littman, M.L. *Measuring Praise and Criticism: Inference of Semantic Orientation from Association*. **ACM Transactions on Information Systems**. 2003. pp. 315-346.
- [8] B. Pang, L. Lee and S. Vaithyanathan. *Thumbs up: sentiment classification using machine learning techniques*. In EMNLP '02: Proc. of the ACL-02 conf. on Empirical methods in natural language processing, pages 79-86. ACL, 2002.
- [9] Das and Chen. *Yahoo! for Amazon: Sentiment Extraction from Small Talk on the Web* *Management Science* 53(9), pp. 1375-1388, © 2007 INFORMS
- [10] H. Yu and V. Hatzivassiloglou. *Towards Answering Opinion Questions: Separating Facts from Opinions and Identifying the Polarity of Opinion Sentences*. Proc. 2003 **Conf. Empirical Methods in Natural Language Processing (Emnlp 03)**, ACM Press, 2003
- [11] Ji fang, Bi Chen. *Incorporating Lexicon Knowledge into SVM Learning to Improve Sentiment Classification*. **Proceedings of the Workshop on Sentiment Analysis where AI meets Psychology (SAAIP), IJCNLP 2011**, pages 94-100, Chiang Mai, Thailand, November 13, 2011
- [12] Chih-Chung Chang and Chih-Jen Lin. *LIBSVM: a library for support vector machines*. **ACM Transactions on Intelligent Systems and Technology**, 2:27:1-27
- [13] M. Annet and G. Kondrak. *A comparison of sentiment analysis techniques: Polarizing movie blogs*. **Advances in AI: 21st conference of the canadian society for computational studies of intelligence, Canadian AI 2008, Windsor, Canada, May 2008**, Proceedings.



Sentiment analysis by Measuring opinions

Zahra Jahed^a, Jalal A Nasiri^b

^aFaculty of Electrical & Computer , Islamic Azad University North Tehran Branch, E-mail:
zahra.jahed1687@gmail.com

^bElectrical and Computer Engineering, Tarbiat Modares University, E-mail: j.nasiri@modares.ac.ir

Abstract. Sentiment Analysis is an area of study within Natural Language Processing that is concerned with identifying the mood or opinion of subjective elements within a text. This paper focuses on the various methods used for classifying a given piece of natural language text according to the opinions expressed in it i.e. whether the general attitude is negative or positive. We also discuss the two-step method (aspect classification followed by polarity classification) that we followed along with the experimental setup..

Keywords: Sentiment Analysis; Opinion Mining; Mood Detection; Machine Learning; NLP.