

## Sentiment Classification of Opinions based on Multi-source Transfer Learning Using Structural Correspondence Learning

Saeed Dehghani Ashkezari<sup>1</sup>, Vali Derhami<sup>2\*</sup>, AliMohammad Zare Bidoki<sup>3</sup> and Mohammad Ehsan Basiri<sup>4</sup>

<sup>1,2\*,3-</sup> Computer Engineering Department, Yazd University, Daneshgah Blvd., Yazd, Iran

<sup>4-</sup> Computer Engineering Department, Shahrekord University, Rahbar Blvd., Shahrekord, Iran

<sup>1</sup>Sdehghani@stu.yazd.ac.ir, <sup>2\*</sup>Vderhami@yazd.ac.ir, <sup>3</sup>Alizareh@yazd.ac.ir, and <sup>4</sup>basiri@sku.ac.ir

Corresponding author address: Vali Derhami, Computer Engineering Department, Yazd University, Yazd, Iran, Post Code: 89158 – 18411.

**Abstract-** Sentiment classification of opinions is a field of Natural Language Processing which has been considered in recent years by researchers due to popularity of Internet stores and the possibility of expressing opinions about sold goods or services. To train classifier models, we need labeled datasets, but as there are not rich labeled samples and as labeling is a difficult and time-consuming process, we must employ labeled samples of other domains. In this article, a new method for binary classification of opinions is proposed based on multi-domain transfer learning. The proposed method tries to adapt different domains by using Structural Correspondence Learning; and based on repetitive procedure of the boosting algorithm, a weight is assigned to classified samples of different domains and the class of each opinion is specified by merging these classifiers. Weighting the dataset samples to boost the process of classification based on the Adaboost algorithm and combining it with the Structural Corresponding Learning is the most important innovation of the current research. The Amazon dataset of four different domains, each one containing 1000 positive and 1000 negative opinions is used for training the proposed model. Accuracy measures of %89.64, %93.97, %92.39 and %90.17 are obtained for Electronics, DVD, Books and Kitchen domains, respectively. It illustrates that the proposed method is very effective compared with the similar methods.

**Keywords-** Sentiment Classification of Opinions, Transfer Learning, Structural Correspondence Learning, Multi-source, Boosting Algorithm.

## دسته‌بندی احساسی عقاید مبتنی بر یادگیری انتقالی چندمنبعی با استفاده از دسته‌بند متناظر ساختاری وزن دار

سعید دهقانی اشکذری<sup>۱</sup>، ولی درهمی<sup>۲</sup>، علی محمد زارع بیدکی<sup>۳</sup>، محمداحسان بصیری<sup>۴</sup>

۱-۲،\* - دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران.

۳- دانشکده مهندسی کامپیوتر، دانشگاه شهرکرد، شهرکرد، ایران.

<sup>1</sup>Sdeghani@stu.yazd.ac.ir, <sup>2</sup>Vderhami@yazd.ac.ir, <sup>3</sup>Alizareh@yazd.ac.ir and <sup>4</sup>basiri@sku.ac.ir

\* نشانی نویسنده مسئول: ولی درهمی، یزد، بلوار دانشگاه، دانشگاه یزد، دانشکده مهندسی کامپیوتر، کد پستی: ۸۹۱۵۸-۱۸۴۱۱

چکیده - دسته‌بندی احساسی عقاید زمینه‌ای در پردازش زبان طبیعی است که در سال‌های اخیر با محبوب شدن فروشگاه‌های اینترنتی و امکان درج عقیده در مورد کالا یا سرویس خریداری شده مورد توجه پژوهش‌گران قرار گرفته است. برای آموزش مدل‌های دسته‌بند، به مجموعه داده‌های برچسب‌خورده نیاز است؛ اما با توجه به عدم وجود نمونه‌های برچسب‌خورده در همه دامنه‌ها و دشواری فرایند برچسب‌زدن نمونه‌ها، می‌بایست به نوعی از نمونه‌های موجود در دامنه‌های دیگر برای ساخت مدل‌ها استفاده نمود. در این مقاله روشی برای دسته‌بندی احساسی عقاید مبتنی بر یادگیری انتقالی چندمنبعی ارائه می‌شود. روش پیشنهادی این مقاله با استفاده از یادگیری متناظر ساختاری، اقدام به تطبیق دامنه‌های مختلف نموده و بر اساس روال تکرار شونده یک الگوریتم بوستینگ به نمونه‌های دسته‌بندی شده دامنه‌های مختلف، وزنی را تخصیص داده و با ادغام هر یک از دسته‌بندها، در مورد دسته هر عقیده تصمیم‌گیری می‌نماید. وزندهی به نمونه‌ها برای تقویت فرایند دسته‌بندی مبتنی بر فرایند بوستینگ و ترکیب آن با یادگیری متناظر ساختاری مهم‌ترین نوآوری پژوهش جاری است. از مجموعه داده‌های آمازون برای ۴ رده مختلف که هر کدام شامل ۱۰۰۰ نمونه مثبت و ۱۰۰۰ نمونه منفی هستند برای آموزش مدل پیشنهادی استفاده شده است. مقدار معیار درستی حاصل ۸۹٫۶۴٪، ۹۳٫۹۷٪، ۹۲٫۳۹٪ و ۹۰٫۱۷٪ به ترتیب برای رده‌های الکترونیک، دی‌وی‌دی، کتاب و آشپزخانه، حاکی از مؤثر بودن روش پیشنهادی در قیاس با روش‌های مشابه است.

واژه‌های کلیدی: دسته‌بندی احساسی عقاید، یادگیری انتقالی، یادگیری متناظر ساختاری، چندمنبعی، الگوریتم بوستینگ.

### ۱- مقدمه

داده و در دامنه‌ای که فاقد نمونه‌های برچسب‌خورده است به کار گرفت. عقاید مربوط به فیلم‌ها بیشترین سهم را در بین تحقیقاتی ارائه شده داشته و پس از آن عقاید درج‌شده برای کالاهایی که به صورت اینترنتی به فروش می‌رسند مورد توجه قرار گرفته‌اند. نتایج تحقیقاتی انجام‌شده در سامانه‌های برخط به طرق مختلفی مورد استفاده قرار گرفته تا کار توسعه‌دهندگان را راحت‌تر نماید و از طرفی دیگر رضایت کاربران سامانه را جلب نماید.

در سال‌های اخیر روش‌های یادگیری افتراقی<sup>۱</sup> به‌طور وسیعی در حوزه‌های مختلف پردازش زبان طبیعی مورد استفاده قرار گرفته است. این روش‌ها زمانی که مجموعه نمونه‌های آموزشی<sup>۲</sup> و نمونه‌های آزمون<sup>۳</sup> دارای توزیع یکسانی باشند بهترین عملکرد را به همراه خواهند داشت [۱]. با این حال در بسیاری از کاربردهای پردازش زبان طبیعی، عدم وجود مجموعه داده‌های برچسب‌خورده برای برخی از دامنه‌ها، چالشی جدی محسوب می‌شود. در این شرایط می‌بایست مدلی را بر پایه دامنه‌های برچسب‌خورده آموزش

جدول ۱: نمونه‌هایی از عقاید مثبت و منفی در دامنه‌های کتاب و دی‌وی‌دی

	دامنه کتاب	دامنه دی‌وی‌دی
+	A <b>good</b> book for anyone at any level of fitness who needs a <b>complete, handy</b> guide.	Nearly every part of the movie that deals with the race is quite <b>good and entertaining</b> .
+	A <b>must_read</b> for students of algebra as this one sets a context which is far <b>brilliant</b> than the dry subject textbook...	This one deserves a <b>5-star</b> rating both for its <b>excellent</b> picture and sound quality, and for the two <b>marvelous</b> and <b>unforgettable</b> cinema classics...
-	What a <b>waste</b> of time. This was like sitting through a very <b>boring</b> business course. I was <b>never interested</b> in turning the page...	This movie is the most <b>boring, uninteresting</b> piece of garbage I have ever <b>wasted</b> my money on.

وجود عقاید برچسب‌خورده نقش بسیار مهمی در نحوه عملکرد روش‌های ارائه‌شده در دامنه موردنظر ایفا می‌نماید. در برخی موارد ممکن است دامنه مبدأ<sup>۴</sup> با داده‌های آموزشی برچسب‌خورده وجود داشته باشد، اما هدف، پردازش داده‌های دامنه مقصد<sup>۵</sup> (که داده برچسب‌خورده نداشته و توزیع متفاوتی با دامنه منبع دارد) است. از آنجاکه تولید نمونه‌های آموزشی فرایندی سخت و زمان‌بر است، بایستی مدل آموزش داده‌شده بر پایه نمونه‌های مبدأ را برای استفاده در دامنه مقصد تطابق داد. یادگیری انتقالی<sup>۶</sup> حوزه‌ای در یادگیری ماشین است که در آن آموزش یک مدل بر پایه دامنه مبدأ و استفاده از آن برای دسته‌بندی نمونه‌های دامنه مقصد امکان‌پذیر می‌شود [۲-۴].

یکی از کاربردهای یادگیری انتقالی، دسته‌بندی عقاید مربوط به یک آیتم خاص مانند یک محصول به دو دسته مثبت و منفی<sup>۸</sup> است. عقاید مثبت و یا منفی در واقع، احساس کاربران را در مورد آن آیتم در زمان نوشتن عقیده نشان می‌دهد. به عبارت دیگر دسته‌بندی احساسی فرایند پیش‌بینی قطبیت احساسی یک سند (همانند یک عقیده یا مقاله) است. هدف اصلی در آن توسعه رویکردی خودکار برای دسته‌بندی قطبیت متون به دو دسته مثبت و منفی است. تعیین موضع کاربران برای یک آیتم در تحقیقات بازاریابی، مدیریت ارتباط با مشتریان، علوم اجتماعی و همانند آن مورد توجه قرار گرفته و روش‌های بسیاری برای این منظور ارائه گردیده است [۵]. در این مقاله تلاش می‌شود با استفاده از یادگیری انتقالی روشی را برای تطابق یک یا چند دامنه مبدأ با یک دامنه مقصد، برای دسته‌بندی عقاید ارائه گردد.

وجود عقاید برچسب‌خورده نقش بسیار مهمی در نحوه عملکرد روش‌های ارائه‌شده در دامنه موردنظر ایفا می‌نماید. در برخی موارد ممکن است دامنه مبدأ<sup>۴</sup> با داده‌های آموزشی برچسب‌خورده وجود داشته باشد، اما هدف، پردازش داده‌های دامنه مقصد<sup>۵</sup> (که داده برچسب‌خورده نداشته و توزیع متفاوتی با دامنه منبع دارد) است. از آنجاکه تولید نمونه‌های آموزشی فرایندی سخت و زمان‌بر است، بایستی مدل آموزش داده‌شده بر پایه نمونه‌های مبدأ را برای استفاده در دامنه مقصد تطابق داد. یادگیری انتقالی<sup>۶</sup> حوزه‌ای در یادگیری ماشین است که در آن آموزش یک مدل بر پایه دامنه مبدأ و استفاده از آن برای دسته‌بندی نمونه‌های دامنه مقصد امکان‌پذیر می‌شود [۲-۴].

یکی از کاربردهای یادگیری انتقالی، دسته‌بندی عقاید مربوط به یک آیتم خاص مانند یک محصول به دو دسته مثبت و منفی<sup>۸</sup> است. عقاید مثبت و یا منفی در واقع، احساس کاربران را در مورد آن آیتم در زمان نوشتن عقیده نشان می‌دهد. به عبارت دیگر دسته‌بندی احساسی فرایند پیش‌بینی قطبیت احساسی یک سند (همانند یک عقیده یا مقاله) است. هدف اصلی در آن توسعه رویکردی خودکار برای دسته‌بندی قطبیت متون به دو دسته مثبت و منفی است. تعیین موضع کاربران برای یک آیتم در تحقیقات بازاریابی، مدیریت ارتباط با مشتریان، علوم اجتماعی و همانند آن مورد توجه قرار گرفته و روش‌های بسیاری برای این منظور ارائه گردیده است [۵]. در این مقاله تلاش می‌شود با استفاده از یادگیری انتقالی روشی را برای تطابق یک یا چند دامنه مبدأ با یک دامنه مقصد، برای دسته‌بندی عقاید ارائه گردد.

برای مثال، عقاید موجود در جدول ۱ را در نظر بگیرید که برای دو دامنه کتاب و دی‌وی‌دی هستند. در این جدول، برچسب عقاید دامنه مبدأ (کتاب) در ستون اول مشخص شده است و هدف غایی، آموزش مدلی است که به کمک آن بتوان برچسب عقاید موجود در دامنه مقصد (دی‌وی‌دی) را مشخص نمود. کلماتی که بار احساسی نویسنده عقیده را نشان می‌دهند به صورت پررنگ مشاهده می‌شوند. همان‌طور که قابل مشاهده است در دامنه کتاب، کلماتی مانند **good**، **complete** و **must\_read** یک احساس مثبت و واژه‌هایی مانند

در پژوهش حاضر، از یادگیری متناظر ساختاری<sup>۱۱</sup> که یکی از روش‌های یادگیری انتقالی است، برای یافتن ویژگی‌های متناظر دامنه‌های مختلف استفاده شده و سعی می‌شود با تطابق دامنه‌های موجود عقاید را دسته‌بندی نمود. ایده اصلی در یادگیری متناظر ساختاری شناسایی ویژگی‌های متناظر دامنه‌های مختلف بر اساس ویژگی‌های محوری<sup>۱۲</sup> (همان کلمات تشکیل‌دهنده عقاید) است.

ویژگی‌های محوری آن دسته از ویژگی‌هایی هستند که در یادگیری افتراقی در دامنه‌های مبدأ و مقصد به صورت مشابه استفاده می‌شوند. ویژگی‌های غیرمحوری از دامنه‌های مختلف که همبستگی بالایی با ویژگی‌های محوری داشته باشند متناظر در نظر گرفته شده و مدل یادگیری افتراقی به صورت مشابه با آن‌ها برخورد می‌کند.

اکثر روش‌هایی که تاکنون در این زمینه ارائه شده‌اند، از یک منبع به‌عنوان مبدأ برای آموزش مدل استفاده نموده‌اند؛ در این پژوهش از چند منبع به‌طور هم‌زمان به‌عنوان مبدأ به‌گونه‌ای استفاده شده است؛ به‌طوری‌که مدلی نهایی در چند تکرار متوالی به‌صورت خودکار

موجب شکل‌گیری زمینه تحقیقاتی تحلیل عقاید گردیده است. همان‌طور که در جدول ۲ مشاهده می‌شود بسیاری از تحقیقات ارائه‌شده، از داده‌های آمازون برای ساخت مدل خود استفاده کرده‌اند. همچنین در این جدول خلاصه‌ای از مقاله‌ها شامل سال انتشار، نوآوری و مجموعه داده مورد استفاده در هر پژوهش آمده است. به‌طور کلی رویکردهای ارائه‌شده برای تحلیل عقاید را می‌توان از لحاظ انتخاب ویژگی برای پیدا کردن بهترین نظرات به دو گروه زیر تقسیم‌بندی نمود:

- استفاده از لغات به‌عنوان ویژگی: در این روش فقط از متن نظرات استفاده می‌شود؛ یعنی با استفاده از الگوریتم‌هایی ابتدا متن نظرات به لغات تشکیل‌دهنده خود تجزیه می‌شود و سپس از این لغات برای شناسایی بهترین نظرات بهره می‌برند.
- استفاده از سایر خصوصیات نظرات به‌عنوان ویژگی: در این روش از ویژگی‌هایی مانند اعتبار کاربر، ویژگی‌های اجتماعی و ویژگی‌های عاطفی در جهت تشخیص و ارائه بهترین نظرات استفاده می‌شود.

با توجه به افزایش عقاید و تفاوت در کیفیت آن‌ها در تارنماهای مختلف در سال ۲۰۰۶، کیم و همکاران [۱۲] به‌عنوان یکی از تحقیق‌های شاخص در این زمینه، به بررسی نظرات به‌عنوان پیش‌نیازهای بهبود تجارت الکترونیک پرداختند. آن‌ها با بررسی عوامل گوناگونی که در کیفیت عقاید تأثیرگذار است سامانه‌ای ارائه دادند که به کمک روش‌های یادگیری ماشین، عقاید را به دو دسته مفید و غیرمفید تقسیم می‌کردند. در روش آن‌ها عوامل مؤثر بر کیفیت عقیده به گروه‌های مختلف مانند ویژگی‌های ساختاری، ویژگی‌های لغوی، ویژگی‌های نحوی و ویژگی‌های معنایی تقسیم‌بندی شدند و با استفاده از ماشین بردار پشتیبان (SVM) بهترین ترکیب از ویژگی‌ها برای تشخیص بهترین نظرات شناسایی شد.

در [۱۳] به بررسی تأثیر عقاید کاربران در مورد کیفیت هتل‌ها پرداخته شده است؛ نویسندگان این مقاله به تأثیر به‌سزای نظرات مثبت بر انتخاب مشتریان اشاره کرده‌اند. نتیجه‌گیری ذکرشده در این مقاله حاکی از آن است که عقایدی که کاربران به‌صورت برخط درج می‌کنند نقش مهمی را در تصمیم‌گیری مشتریان دیگر ایفا می‌کنند.

خود را تقویت نموده و در نهایت پیش‌بینی را با بیشترین دقت انجام دهد.

به‌منظور بهره‌گیری از همه دانشی که در منابع مختلف وجود دارد از یک روال بوستینگ<sup>۱۳</sup> برای آموزش مدل بر پایه چند منبع استفاده شده است. روال کار بدین گونه است که نخست دسته‌بندی‌های اولیه‌ای بر پایه نمونه‌های آموزشی ایجاد شده، سپس با توجه به عملکرد هر دسته‌بند بر روی نمونه‌های دامنه مقصد و میزان خطای محاسبه‌شده، وزنی به آن دسته‌بند تخصیص می‌یابد. در گام سوم یک دسته‌بندی نامزد<sup>۱۴</sup> بر اساس دسته‌بندی‌های وزن‌دار ایجاد می‌شود. در ادامه وزن هر یک از دامنه‌های مبدأ و دامنه مقصد بر اساس میزان خطای دسته‌بند نامزد بر روی دامنه متناظر به‌روزرسانی می‌شود. در انتها همه دسته‌بندی‌های اولیه بر اساس نمونه‌های آموزشی با وزن به‌روز شده، مجدداً آموزش داده می‌شوند. این گام‌ها تا رسیدن به حد آستانه<sup>۱۵</sup> تکرارها تکرار می‌شود.

به‌عنوان نوآوری اصلی این مقاله باید به چگونگی وزن‌دهی به نمونه‌ها در فرایند تکرارشونده بوستینگ و ترکیب آن با یادگیری متناظر ساختاری برای دسته‌بندی عقاید دامنه‌های مختلف اشاره نمود.

ادامه مقاله به این صورت سازمان‌دهی شده است: بخش ۲ به مرور کارهای انجام‌شده می‌پردازد. در بخش ۳ به تشریح روش پیشنهادی برای دسته‌بندی احساسی عقاید پرداخته می‌شود. در بخش ۴ نتایج آزمایش‌ها تشریح شده است و بخش ۵ به جمع‌بندی و کارهای آینده اختصاص دارد.

## ۲- سابقه تحقیق

دسته‌بندی احساسی عقاید نخستین بار توسط پنگ<sup>۱۶</sup> و همکارانش [۶] مورد بررسی قرار گرفت. توماس<sup>۱۷</sup> و همکاران [۷] با بررسی ساختار رکوردها موفق به دسته‌بندی احساسی متن با دقت بیشتری شدند. پنگ و لی<sup>۱۸</sup> [۸] با بهره‌گیری از ماشین بردار پشتیبان (SVM)<sup>۱۹</sup>، تحلیل احساسی عقاید را در چارچوب یک مسئله رتبه‌بندی لحاظ نمودند. در مطالعات زیادی به وجود رابطه مستقیم بین عقاید کاربران و میزان فروش اقلام تجاری اشاره شده است [۹]، [۱۰]. اکثر این مقاله‌ها نشان داده‌اند که همبستگی مثبت بین امتیاز عقاید و میزان فروش محصولات وجود دارد. پارک<sup>۲۰</sup> و کیم<sup>۲۱</sup> [۱۱] رابطه بین مشتری و انواع مختلف عقاید را بررسی کرده‌اند. آن‌ها دریافتند که عقاید مشتریان در بازه‌های زمانی مختلف در مورد یک محصول متفاوت خواهد بود و به تولیدکنندگان پیشنهاد می‌کنند که استراتژی‌های مختلفی در بازه‌های زمانی متفاوت برای قشرهای مختلف مشتریان در نظر بگیرند.

تارنمای آمازون به‌عنوان بزرگ‌ترین فروشگاه اینترنتی جهان شامل بیشترین تعداد عقاید بوده و توجه به تعداد عقاید موجود در آن

جدول ۲: خلاصه‌ای از پژوهش‌های مرتبط

مقاله - سال انتشار	یافته‌ها	مجموعه داده‌ها
[۱۴] - ۲۰۰۳	عقاید مثبت و منفی هر دو با فروش هفتگی فیلم‌ها همبستگی دارند.	اطلاعات مربوط به ۲۰۰ فیلم منتشرشده بین سال‌های ۱۹۹۱ تا ۱۹۹۳
[۱۵] - ۲۰۰۶	عقاید در دو تارنمای فروش برخط، تأثیر مثبتی بر روی فروش دارند. تأثیر آرای با ۱ ستاره به محصول بیشتر از تأثیر آرای ۵ ستاره به آن محصول است.	داده‌های تارنماهای Amazon.com
[۱۶] - ۲۰۱۲	بر اساس نتایج به‌دست‌آمده از آزمایش‌ها نشان داده‌شده است که علاوه بر ویژگی‌های اصلی مانند متن عقیده، ویژگی‌های ثانویه مانند رتبه عقیده بر روی میزان مفید بودن عقاید تأثیرگذار است.	داده‌های تارنما Amazon.com
[۱۷] - ۲۰۱۱	ویژگی‌های معنایی نسبت به سایر ویژگی‌ها اثرگذاری بیش‌تری بر روی میزان مفید بودن عقیده دارند.	داده‌های تارنمای CENT Download
[۱۸] - ۲۰۱۳	تفاوت‌های اساسی بین عقاید درج‌شده برای فیلم‌ها در دو کشور چین و آمریکا. نتایج نشان داده است که عقیده‌های کاربران در کشور چین تأثیر بیش‌تری بر روی میزان مشاهده آن فیلم دارد.	داده‌های تارنمای IMDB
[۱۹] - ۲۰۱۰	سبک زبان، ساختار زبانی و سایر ویژگی‌های متنی عقیده تأثیر بسزایی بر روی میزان مفید بودن نظرات دارد.	داده‌های تارنما Amazon.com
[۲۰] - ۲۰۱۳	ویژگی‌های مبتنی بر محتوا تأثیر مستقیمی بر میزان مفید بودن عقاید دارند.	داده‌های سیستم Bulletin Board

در تطابق دامنه سعی می‌شود با انتقال دانش از یک دامنه (برچسب‌خورده) به دامنه دیگر (فاقد نمونه‌های برچسب‌خورده) دسته‌بندی در این دامنه صورت گیرد. تاکنون پژوهش‌های مختلفی در حیطه تطابق دامنه انجام شده است [۲۳-۲۵]. در برخی از پژوهش‌ها تلاش شده است با استفاده از منابع دانش خارجی، شکاف میان دامنه مبدأ و مقصد پر شود. برای مثال ونگ<sup>۲۴</sup> و همکارانش [۲۶] رویکرد خوشه‌بندی مشترک<sup>۲۵</sup> را با انتقال برچسب‌های بین دو دامنه به کمک ویکی‌پدیا به‌منظور نمایش اسناد بر اساس مفاهیم ارائه نموده‌اند. ژانگ<sup>۲۶</sup> و همکارانش [۲۷] رویکرد مشابه دیگری برای بهره‌برداری از ویکی‌پدیا و منابع دیگر در زمینه تطابق دامنه ارائه نموده‌اند. در دسته‌بندی احساسی نیز برخی روش‌ها از لغتنامه‌های احساسی به‌عنوان منابع خارجی استفاده می‌کنند. مدل JSTM [۲۸] نیز از یک لغتنامه احساسی به‌عنوان یک مخزن در اولویت‌بندی معنای احساسی کلمات استفاده نموده است. در [۲۹] از چنین روش‌هایی نیاز به وجود منابع خارجی قابل دسترس است و کارایی آن‌ها به کیفیت این منابع وابسته است.

بولگال<sup>۲۷</sup> و همکاران [۳۰] روشی برای دسته‌بندی احساسی عقاید ارائه نموده‌اند. در روش آن‌ها، یک اصطلاح‌نامه<sup>۲۸</sup> احساسی به‌طور خودکار از عقاید برچسب‌خورده در دامنه‌های مبدأ و عقاید بدون برچسب در دامنه مقصد ایجاد می‌شود که از آن در بسط بردار ویژگی نهایی استفاده می‌شود و درنهایت، دسته‌بند دودویی<sup>۲۹</sup> مناسب و کارآمدی آموزش داده می‌شود.

مانجوناتان<sup>۳۰</sup> در [۳۱] روشی برای دسته‌بندی احساسی عقاید ارائه نموده است. در روش وی، یک اصطلاح‌نامه توزیعی<sup>۳۱</sup> مبتنی بر قطبیت<sup>۳۲</sup> واژگان برای چندین دامنه مبدأ برچسب‌خورده و یک دامنه مقصد ایجاد شده، سپس بر اساس آن بردار ویژگی نهایی برای آموزش یک دسته‌بندی دودویی بسط داده می‌شود.

در [۳۲] روش LSF ارائه شده است. این روش بر پایه فاکتورگیری ماتریس<sup>۳۳</sup> عمل می‌کند. فاکتورگیری ماتریس یکی از قوی‌ترین ابزارها برای پیش‌بینی مقادیر نامعلوم است. جزء اصلی در فاکتورگیری ماتریس، تابع هدف است که مقادیر موردنظر را پیش‌بینی می‌کند. در این مقاله از همسایه‌های محلی و اطلاعات عقاید برای نگاشت ارتباط بین عقاید دامنه مبدأ و مقصد به یک فضای با ابعاد کم استفاده می‌شود. فرضیه اصلی این است که تنها d فاکتور بر روی ارتباط بین دامنه مبدأ و مقصد تأثیرگذار است. به‌عبارت‌دیگر ماتریس R (داده‌های عقاید) را می‌توان به‌صورت تقریبی به دو بخش U و S بر مبنای d فاکتور رتبه‌بندی شده تقسیم نمود: آزمایش‌ها در این مقاله بر مبنای مجموعه داده آمازون انجام شده است.

در [۲۱] چارچوبی برای توصیه و مقایسه محصولات به فروش رسیده در وبسایت‌های فروش الکترونیک بر مبنای عقیده‌کاوی ارائه شده است. از تکنیک‌های پردازش زبان طبیعی برای پردازش متن عقاید و همچنین از دسته‌بند نایو بیز<sup>۳۲</sup> برای تعیین متقارن بودن عقاید استفاده شده است. یکی دیگر از اقداماتی که در این منبع ارائه شده است، روشی برای استخراج ویژگی از عقاید کاربران بوده است.

توجه به متن عقاید و استخراج ویژگی‌ها از متن در سال ۲۰۰۸ توسط آقای لیو<sup>۳۳</sup> و همکاران [۲۲] مطرح شد. در این تحقیق میزان سودمندی نظرات بر اساس روش مبتنی بر آنتروپی مدل‌سازی شد. در این روش، ابتدا نظرات به دو دسته مفید و غیرمفید تقسیم‌بندی می‌شدند و سپس بعد از تجزیه نظرات به لغت‌های تشکیل‌دهنده خود و تخصیص امتیاز به هر لغت، امتیاز نهایی هر عقیده با جمع امتیازهای لغت‌های تشکیل‌دهنده آن به دست می‌آمد و با توجه به این امتیاز، نظرات رتبه‌بندی می‌شدند. از آنجایی که تعداد لغات هر زبان زیاد است، مشکل اصلی این روش محاسبه امتیاز هر لغت می‌باشد که امری زمان‌بر است.

۸۳٫۹ درصدی بهتر از الگوریتم‌هایی همچون K نزدیک‌ترین همسایه و ماشین بردار پشتیبان بوده است.

اخیرا پژوهش‌های متعددی نیز در زمینه برچسب‌گذاری عقاید در مقیاس بزرگ<sup>۲۸</sup> صورت گرفته است. به‌عنوان مثال، در [۳۸] گزارشی از برچسب‌گذاری عقاید دامنه کتاب (با مقیاس بزرگ) از سایت آمازون ارائه شده است. در این پژوهش، از مدل بیز ساده برای تعیین قطبیت (مثبت و منفی) عقاید با میزان درستی<sup>۲۹</sup> ۷۸٫۷۸ درصد و از مدل‌های K نزدیک‌ترین همسایه،<sup>۳۰</sup> ماشین بردار پشتیبان و LSTM- RNN برای برچسب‌گذاری چنددسته‌ای عقاید (از ۱ تا ۵ ستاره) استفاده شده که طبق نتایج حاصل، میزان درستی حاصل از روش LSTM- RNN بیشتر از سایر مدل‌ها بوده است.

در [۳۹] نیز برچسب‌گذاری عقاید در دامنه‌های تلفن همراه، الکترونیک و ابزارآلات موسیقی در مقیاس بزرگ مورد بررسی قرار گرفته است. در این پژوهش، پس از برچسب‌گذاری عقاید به صورت دستی و به‌کمک یادگیری فعال، استخراج ویژگی‌ها (با روش‌های بسته لغات، TF-IDF و Chi-Square) صورت می‌گیرد و در نهایت، روش‌های مختلف دسته‌بندی به‌کمک اعتبارسنجی متقابل مورد ارزیابی قرار می‌گیرد. نتایج حاصل از این تحقیق نشان می‌دهد که روش SVM خطی (به‌صورت 10-fold) نسبت به سایر روش‌های دسته‌بندی، نتایج مناسب‌تری (حدود ۹۴ درصد) را به دست می‌دهد. شایان ذکر است که پژوهش‌های فوق در دامنه‌های یکسان مبدا و مقصد و بنابراین فضای ویژگی یکسان انجام گرفته است، درحالی‌که پژوهش حاضر در دامنه‌های مبدا و مقصد متفاوت و بنابراین فضای ویژگی متفاوت صورت گرفته است که دست‌یابی به میزان درستی از حدود ۹۰ تا ۹۴ درصد به ازای دامنه‌های مختلف، از کارایی روش پیشنهادی حکایت می‌کند.

### ۳- روش پیشنهادی

در این قسمت ابتدا روش پیشنهادی به‌صورت کلی ذکر شده، آنگاه پیش از بیان فرآیند یادگیری هر یک از موضوعات مهم به‌صورت جداگانه به تفکیک بیان می‌شوند.

در دسته‌بندی احساسی با استفاده از تطابق دامنه تلاش می‌شود یک دسته‌بند بر روی یک دامنه آموزش داده شده و بر روی دامنه دیگر مورد استفاده قرار گیرد. برای مثال ممکن است از عقاید نوشته‌شده برای رده کتاب به‌منظور دسته‌بندی عقاید رده فیلم استفاده شود. یکی از روش‌هایی که در دسته‌بندی متن مورد استفاده قرار می‌گیرد، نمایش یک مجموعه داده به‌صورت ماتریس کلمات تشکیل‌دهنده اسناد است که به آن روش کیسه کلمات<sup>۴۱</sup> گفته می‌شود. در این روش، هر سند به‌صورت برداری از تکرار کلمات در نظر گرفته

در [۳۳] روش TCT<sup>۳۴</sup> ارائه شده است. روش آن‌ها بر پایه یادگیری مبتنی بر چند منبع بر اساس موضوعات مختلف است. به‌عبارتی روش آن‌ها موضوعات مختلف را بین دامنه مبدأ و مقصد به اشتراک گذاشته و نگاشت بین دو دامنه را بر اساس اطلاعات موضوعی انجام می‌دهد. فرض آن‌ها این است که هر دامنه موضوعات خاص خود را داشته و همچنین برخی از موضوعات بین دامنه‌های مختلف مشترک است. آموزش مدل پیشنهادی آن‌ها نیز بر اساس مجموعه داده آمازون بوده است. تفاوت اصلی این کار با پژوهش حاضر تلاش برای بررسی موضوعی هر یک از عقاید است درحالی‌که در الگوریتم پیشنهادی تنها بر روی دامنه‌ها متمرکز است. این در حالی است که بسیاری از نظرات ممکن است به دلایل مختلف همچون کوتاه بودن، استفاده از کلمات مجهول و یا تعلق داشتن به چند موضوع مختلف الگوریتم را با مشکل مواجه سازد از طرفی دیگر بسط دادن آن به همه دامنه‌ها (با توجه به وسعت موضوعی زیاد) دشوار است.

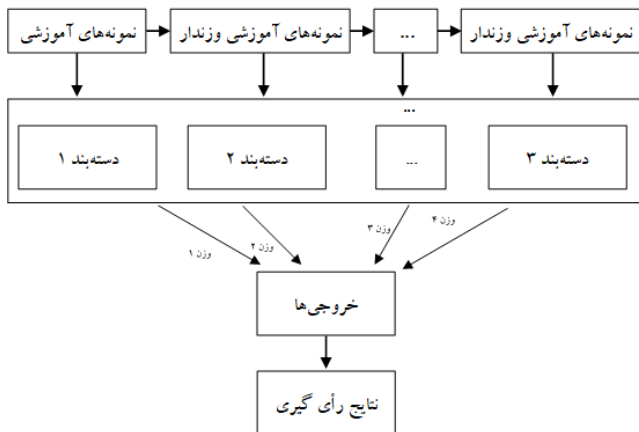
در [۳۴] ضمن تأکید بر اهمیت دسته‌بندی عقاید روشی برای دسته‌بندی ترکیبی<sup>۳۵</sup> عقاید ارائه شده است. تلاش آن‌ها برای استفاده ترکیبی از دسته‌بندی نایو بیز، ماشین بردار پشتیبان و کیسه کلمات<sup>۳۶</sup> بوده است. هرچند که روش آن‌ها در شرایط استفاده ترکیبی از دسته‌بندیها نتایج بهتری نسبت به استفاده جداگانه از هر یک از دسته‌بندیها داشته است اما به دلیل سادگی روال ترکیب یعنی روش رأی‌گیری اکثریت در مقایسه با روش‌های دیگر عملکرد ضعیف‌تری داشته است. این در حالی است که روش پیشنهادی مقاله حاضر بر روی وزن‌دهی کلمات بر مبنای یک مکانیسم بوستینگ عمل می‌کند و تنها به رأی هر دسته‌بند اکتفا نمی‌کند.

در [۳۵] بر روی قطبیت توییت‌های منتشرشده در توییت‌ر پژوهشی انجام شده است. نویسندگان مقاله اعتقاد دارند توییت‌ها دارای وجوه اشتراکی با عقاید هستند. طول هر توییت، مثبت/منفی یا خنثی بودن و مبتنی بر دامنه بودن از جمله نقاط مشترک توییت‌ها و عقاید است. با ذکر این موارد آن‌ها یک دسته‌بند بیز ساده را آموزش داده و دقت ۶۰ درصدی و معیار F ۴۹٫۲۵ درصدی را در آزمایش‌ها به دست آورده‌اند. مقاله [۳۶] نیز روالی مشابه به آنچه در [۳۵] مطرح شده است را ارائه نموده است. تفاوت اصلی کار آن‌ها استفاده از هشتک‌های درج‌شده در انتهای توییت‌ها است که می‌تواند جالب‌توجه بوده و ویژگی مفیدی در تعیین قطبیت توییت‌ها باشد.

در [۳۷] بر روی دسته‌بندی احساسی عقاید وب‌سایت IMDb تحقیق صورت گرفته است. دسته‌بندی آن‌ها بر روی ویژگی‌های ترکیبی عقاید همچون TF-IDF، تعداد کلمات، تعداد فعل، فاعل و غیره آموزش داده شده است. نتایج آزمایش نشان می‌دهد روش پیشینه به‌هم‌ریختگی<sup>۳۷</sup> با انتخاب ویژگی هم‌بستگی، با دقت میانگین

در این پژوهش بیش از یک دامنه به‌عنوان مبدأ انتخاب می‌شوند بنابراین چند دسته‌بند وجود خواهد داشت که هر یک بر روی یک مبدأ و یک مقصد ایجاد می‌شوند. برای یادگیری مبتنی بر چند مبدأ می‌بایست نتایج آن با یکدیگر ترکیب شود که این کار با استفاده از یک الگوریتم بوستینگ انجام شده است. با در نظر گرفتن چند دسته‌بند، الگوریتم AdaBoost به‌عنوان یک الگوریتم بوستینگ برای ترقی<sup>۲۲</sup> دسته‌بندها مورد استفاده قرار می‌گیرد. AdaBoost الگوریتم ترتیبی و تکرارشونده است که مبتنی بر چگونگی عملکرد آن چندین دسته‌بند توزیع نمونه‌های آموزشی را بر مبنای دسته‌بندهای پیشین تغییر داده و در نتیجه عملکرد آن‌ها بهبود می‌یابد.

همان‌طور که در شکل ۱ (نمودار روش پیشنهادی) مشاهده می‌شود عملکرد روش پیشنهادی به این صورت است که دسته‌بندها بر اساس نمونه‌های آموزشی ایجاد می‌شود؛ سپس بر اساس عملکرد دسته‌بند و دقتی که داشته است وزنی به خروجی آن تخصیص داده می‌شود. در ادامه بر اساس هر یک از این دسته‌بندهایی که دارای وزن هستند دسته‌بند جدیدی ساخته شده؛ آنگاه وزن هر یک از دامنه‌های مبدأ و دامنه مقصد بر اساس عملکرد دسته‌بند نامزد در فرآیند دسته‌بندی بر روی دامنه متناظر به مقداری می‌شود. در انتها همه دسته‌بندی‌های اولیه بر اساس نمونه‌های آموزشی با وزن به‌روزرسانی شده دوباره آموزش داده می‌شوند. روال ذکر شده تا رسیدن به حد آستانه مورد نظر به‌صورت تکرارشونده انجام می‌شود. در نهایت خروجی همه دسته‌بندها به‌صورت رأی‌گیری خواهد بود.



شکل ۱: چگونگی عملکرد روش پیشنهادی

### ۱-۳- یادگیری متناظر ساختاری

یادگیری متناظر ساختاری شامل دامنه‌های مبدأ و مقصد است. در هر دو دامنه نمونه‌های بدون برچسب وجود دارد ولی تنها دامنه مبدأ شامل نمونه‌های برچسب‌خورده آموزشی زیادی است. هر ورودی در هر دو دامنه مبدأ و مقصد به‌صورت برداری از ویژگی‌ها در یک فضای برداری متناهی نشان داده می‌شود. نخستین گام در یادگیری

می‌شود. در این رویکرد فاصله بین بردارها نشان‌دهنده میزان مشابهت اسناد است. از آنجاکه هر کلمه تشکیل‌دهنده یک بعد از بردار ویژگی اسناد است، هیچ معیاری برای سنجش ارتباط بین کلمات وجود ندارد؛ حتی اگر دو کلمه دارای معنای یکسانی باشند. برای مثال واژه زیبا با واژه قشنگ و زشت نامشابه در نظر گرفته می‌شود در حالی که زیبا و قشنگ معنای مشابهی دارند. ایده بردار ویژگی هیچ توجهی به معنای کلمات ندارد، در حالی که ممکن است بین کلمات ارتباط معناداری وجود داشته باشد. از طرفی زمانی که بیش از یک دامنه در مسئله وجود داشته باشد کشف روابط بین کلمات از اهمیت ویژه‌ای برخوردار است. برای مثال در صورتی که دامنه مبدأ کتاب و دامنه مقصد فیلم باشد کشف ارتباط بین کلماتی همچون <کتاب، فیلم> و <نویسنده، کارگردان> می‌تواند در افزایش قدرت مدل تأثیرگذار باشد.

با توجه به این فرض که در تطابق دامنه، حجم زیادی از نمونه‌های بدون برچسب در دامنه مبدأ و مقصد وجود دارد می‌توان تکنیک‌های مختلفی را برای کاوش بهتر توزیع کلمات دو دامنه به کار گرفت. یکی از اقداماتی که می‌توان انجام داد نگاشت شباهت بین کلمات دو دامنه است. این ایده بر پایه این فرض است که توزیع کلمات هم‌معنی مشابه بوده و همچنین کلماتی که به همراه آن‌ها تکرار می‌شوند یکسان است.

کشف همبستگی مخفی بین کلمات را می‌توان با استفاده از یادگیری متناظر ساختاری انجام داد. با یادگیری ساختار نمونه‌ها مبتنی بر پیش‌بینی کلمات با استفاده از کلماتی که اطراف هر کلمه آمده است انجام می‌شود. یادگیری متناظر ساختاری، در یک فضای پنهان ارتباط بین کلمات مختلف را بر اساس دسته‌بندی مبتنی بر ویژگی‌های محوری ایجاد می‌کند.

با انجام چنین کاری یک فضای ویژگی با کلمات مشترک بین دامنه مبدأ و مقصد ایجاد می‌شود. فرض اصلی این است که با آموزش یک مدل در دامنه مبدأ با ویژگی‌های مشترک قابل‌اعمال بر روی نمونه‌های دامنه مقصد است. ساخت این فضای ویژگی مبتنی بر یادگیری متناظر ساختاری انجام می‌شود. ایده اصلی در یادگیری متناظر ساختاری، تشخیص تناظر بین دامنه‌های مختلف بر اساس ویژگی‌های محوری است. ویژگی‌های محوری در یادگیری افتراقی در دامنه‌های مختلف همانند هم ظاهر شده و نقش یکسانی در تفکیک نمونه‌ها دارند. ویژگی‌های غیرمحوری دامنه‌های مختلف که با ویژگی‌های محوری همبستگی دارند متناظر در نظر گرفته شده و توسط مدل یادگیری افتراقی به‌صورت یکسان برخورد می‌شود. هر مدلی که در چنین فضایی آموزش داده می‌شود قادر به دسته‌بندی نمونه‌ها با توجه به یک دامنه مبدأ و یک مقصد می‌باشند.

چندمنبعی به یک مسئله استاندارد دسته‌بندی در فضای چند منبعی کاهش می‌یابد.

به‌منظور انتخاب ویژگی‌های محوری از بهره اطلاعاتی<sup>۴۴</sup> استفاده می‌شود که در این بخش به بیان آن پرداخته می‌شود. بهره اطلاعاتی بر اساس روابطی که در ادامه بیان خواهند شد، ویژگی‌هایی (همان کلمات تشکیل‌دهنده عقاید) که بیشترین نقش در یادگیری انتقالی از دامنه مختلف دارند را می‌یابد. بدین‌صورت که در گام نخست  $n_1$  کلمه که در هر دو دامنه بیش از  $th_{n_1}$  تکرار شده باشند به‌عنوان ویژگی‌های نامزد انتخاب می‌شوند. در گام بعدی  $n_2$  کلمه از بین مجموعه کلمات گام قبل بر اساس معیار فیشر<sup>۴۵</sup> (تابع رابطه ۱) انتخاب می‌شود:

$$ED(t_k) = \frac{E(t_k | P) - E(t_k | N))^2}{D(t_k | P) \times D(t_k | N)} \quad (1)$$

$ED(t_k | p)$  یک تابع معیار فیشر برای ویژگی  $t_k$  است که در آن  $E(t_k | N)$  و  $E(t_k | P)$  میانگین شرطی،  $D(t_k | P)$  و  $D(t_k | N)$  واریانس شرطی هستند.  $P$  نمونه مثبت و  $N$  نمونه منفی در مجموعه داده برجسب‌خورده دامنه مبدأ می‌باشد.  $E(t_k | P) - E(t_k | N)$  نشان‌دهنده اختلاف رخداد هم‌زمان ویژگی  $t_k$  در کلاس مثبت و منفی است و پراکندگی بین دو کلاس را نشان می‌دهد.  $D(t_k | P)$  و  $D(t_k | N)$  به ترتیب پراکندگی را در کلاس مثبت و منفی نشان می‌دهد.  $D(t_k | P) \times D(t_k | N)$  نیز پراکندگی درون کلاسی را با ویژگی  $t_k$  نشان می‌دهد. برای تخمین احتمال رخداد از فرکانس تکرار استفاده شده است. رابطه تقریبی محاسبه تابع معیار فیشر به‌صورت رابطه ۲ خواهد بود:

$$ED(t_k) \approx \frac{(IPW \times NNW - INW \times NPW)^2}{IPW \times NNW \times INW \times NPW} \quad (2)$$

در این رابطه  $IPW$  تعداد نمونه‌های مثبت شامل ویژگی  $t_k$ ،  $INW$  تعداد نمونه‌های منفی شامل ویژگی  $t_k$ ،  $NPW$  تعداد نمونه‌های مثبت فاقد ویژگی  $t_k$ ،  $NNW$  تعداد نمونه‌های منفی فاقد ویژگی  $t_k$  می‌باشند. هر چه ویژگی  $t_k$  مقدار بیشتری از این تابع کسب کند ارزش بیشتری در تفکیک نمونه‌های دو کلاس خواهد داشت. در انتها ویژگی‌هایی که بیشترین ارزش را دارا باشند به‌عنوان ویژگی‌های محوری انتخاب می‌شوند. ارزش اطلاعاتی بر اساس رابطه ۳ محاسبه می‌گردد:

ساختاری تعریف ویژگی‌های محوری بر مبنای داده‌های بدون برجسب از هر دو دامنه است. درواقع از نمونه‌های بدون برجسب برای یافتن جفت کلمات متناظر دامنه‌های مختلف استفاده می‌شود. سپس از این ویژگی‌های محوری برای نگاشت از فضای برداری اصلی هر دو دامنه، به فضای مشترک (با ابعاد کم) بین هر دو دامنه استفاده می‌شود. در طی فرآیند یادگیری از ویژگی‌های اصلی و ویژگی‌های نگاشت شده از دامنه مبدأ استفاده می‌شود. در زمان ارزیابی روش نیز از ویژگی‌های اصلی و نگاشت شده دامنه مقصد استفاده می‌گردد. در صورتی که نگاشت به‌درستی انجام شود، دسته‌بند آموزش داده‌شده بر روی دامنه مبدأ به‌خوبی بر روی دامنه مقصد عمل می‌کند.

با در اختیار داشتن مجموعه‌ای از اسناد برجسب‌خورده  $D_S = \{x_i, y_i\}_{i=1}^n$  برای دامنه مبدأ، فضای ویژگی دامنه مبدأ،  $X_T$  فضای ویژگی دامنه مقصد و  $Y$  مجموعه برجسب‌های کلاس است.  $X = X_S \cup X_T$  فضای ویژگی‌ها را نشان می‌دهد.  $V_S$  نشان‌دهنده مجموعه لغات دامنه مقصد، و  $V = V_S \cup V_T$  مجموعه کلیه واژگان است. علاوه بر مجموعه سندهای برجسب‌خورده آموزشی  $D_S$  برای دامنه مبدأ، مجموعه سندهای فاقد برجسب  $D_{T,U}$  و  $D_{S,U}$  به ترتیب برای دامنه مبدأ  $S$  و دامنه مقصد  $T$  وجود دارد.  $D_U$  نیز به  $D_{S,U} \cup D_{T,U}$  اشاره دارد. هدف ایجاد یک دسته‌بند برای دامنه  $T$  است که قادر است برجسب‌های نمونه‌های جدید مشاهده نشده در دامنه  $T$  را پیش‌بینی کند.

ایده کلیدی در یادگیری متناظر ساختاری شناسایی تناظر بین ویژگی‌های متناظر در بین دامنه‌های مبدأ و مقصد بر اساس مدل‌سازی همبستگی بین ویژگی‌های محوری که در هر دو دامنه رفتار مشابهی دارد، است. ویژگی‌های غیرمحوری از دامنه‌های مختلف که با برخی از ویژگی‌های محوری ارتباط دارند، متناظر در نظر گرفته می‌شوند.

### ۳-۲- ویژگی‌های محوری

همان‌طور که اشاره شد نخستین گام در یادگیری متناظر ساختاری انتخاب ویژگی‌های محوری بر اساس نمونه‌های بدون برجسب از هر دو دامنه است. مفهوم ویژگی محوری نخستین بار توسط بلیتزر<sup>۴۳</sup> و همکارانش ارائه گردیده و طبق تعریف آن‌ها ویژگی‌های محوری کلماتی هستند که پرتکرار بوده و رفتار یکسانی در دامنه‌های مختلف دارند [۲۵]. ویژگی‌های محوری تناظر کلمات دامنه مبدأ و مقصد را برقرار نموده و نقش اساسی در یادگیری متناظر ساختاری ایفا می‌کند. از این ویژگی‌ها برای یادگیری یک نگاشت  $\theta$  از فضای ویژگی اولیه هر دو دامنه به فضای ویژگی مشترک با ابعاد کمتر استفاده می‌شود. با یافتن چنین نگاشتی مسئله دسته‌بندی



سرانجام برای هر یک از  $D_l$  ها یک دسته‌بند بر مبنای بردار  $w_l$  آموزش داده می‌شود.

جدول ۳: ویژگی‌های محوری هر یک از رده‌ها به همراه برترین ویژگی‌ها

برترین ویژگی‌ها	تعداد	رده
easy, boring, important, novel, excellent, bad, waste	۶۰	کتاب
best, classic, bad, boring, awful	۴۱	DVD
easy, broken, nice, perfect, waste	۵۵	وسایل الکتریکی
best, worst, wonderful, poor, bad	۶۳	لوازم آشپزخانه

جدول ۴: تعداد کل ویژگی‌ها و ویژگی‌های غیرمحوری مورداستفاده در فرایند یادگیری در نمونه‌های برچسب‌خورده و بدون برچسب

ویژگی‌های غیرمحوری	تعداد کل ویژگی‌ها	رده
۱۱۳۵۰۲	۴۰۲۱۴۳	کتاب
۹۴۸۴۴	۳۲۶۵۰۳	DVD
۱۱۹۰۵۵	۴۴۱۵۶۹	وسایل الکتریکی
۱۴۷۸۱۷	۴۶۸۶۵۱	لوازم آشپزخانه

### ۴-۳- الگوریتم بوستینگ

همان‌طور که پیش‌ازاین ذکر شد از الگوریتم AdaBoost [۴۰] یکی از روش‌های بوستینگ است برای افزایش کارایی مدل یادگیری انتقالی استفاده شده است. هدف از انجام این کار استفاده بهتر از داده‌های برچسب‌خورده دامنه‌های مبدأ و بهبود فرایند یادگیری است. بر پایه ایده بوستینگ در الگوریتم AdaBoost می‌بایست نمونه‌های مرتبط با فرایند هدف در دامنه مبدأ شناسایی شده تا مدل نهایی با نمونه‌های آموزشی دامنه مقصد آشنا باشد. در روش پیشنهادی این پژوهش پس از انتخاب ویژگی‌های محوری برای هر یک از دامنه‌های مبدأ و دامنه مقصد، مدل دسته‌بند اولیه برای آن‌ها ایجاد می‌شود. در ادامه میزان خطای هر یک از این دسته‌بندها بر اساس نمونه‌های آزمون محاسبه شده و وزنی به هر یک از آن‌ها بر اساس خطای متناظرشان تخصیص می‌یابد. دامنه‌های مبدأ که دسته‌بندی متناظر آن‌ها دقت دسته‌بندی بیشتری داشته باشند، دربردارنده اطلاعات ارزشمندتری برای فرایند یادگیری دارا می‌باشند.

در توضیح چگونگی به‌کارگیری الگوریتم AdaBoost باید گفت که در ابتدای کار هر دسته‌بند بر روی مجموعه داده‌های آموزشی ایجاد می‌شود و عقاید را به دو دسته مثبت و منفی تقسیم‌بندی می‌کنند. همان‌طور که در شکل ۲ مشاهده می‌شود بر مبنای اینکه نمونه‌های هر دسته به‌درستی دسته‌بندی شده است یا خیر وزنی به آن برای

$$IG(t_k) = H(C) - H(C|t_k) = - \sum_{c \in C} p(c) \log(p(c)) \quad (3)$$

$$+ p(t_k) \sum_{c \in C} p(c|t_k) \log(p(c|t_k)) \log(p(c|t_k)) + p(\bar{t}_k) \sum_{c \in C} p(c|\bar{t}_k)$$

$$= - \left( \frac{P_{sen}}{P_{sen} + N_{sen}} \log \left( \frac{P_{sen}}{P_{sen} + N_{sen}} \right) - \frac{P_{sen}}{P_{sen} + N_{sen}} \log \left( \frac{P_{sen}}{P_{sen} + N_{sen}} \right) \right)$$

$$+ \left( \frac{IPW}{P_{sen}} \log \left( \frac{IPW}{P_{sen}} \right) + \frac{INW}{N_{sen}} \log \left( \frac{INW}{N_{sen}} \right) \right) \frac{INW + IPW}{P_{sen} + N_{sen}}$$

$$+ \left( \frac{NPW}{P_{sen}} \log \left( \frac{NPW}{P_{sen}} \right) + \frac{NNW}{N_{sen}} \log \left( \frac{NNW}{N_{sen}} \right) \right) \frac{NNW + NPW}{P_{sen} + N_{sen}}$$

در این رابطه  $P_{sen}$  تعداد نمونه‌های آموزشی کلاس مثبت و  $N_{en}$  تعداد نمونه‌های آموزشی با برچسب منفی است.  $H(C|t_k)$  آنترپوی شرطی ویژگی کلاس  $C$  در برای ویژگی  $t_k$  است.

در جدول ۳ تعداد ویژگی‌های محوری هر دامنه به همراه تعدادی از برترین (بر اساس روابط ذکرشده) مشاهده می‌شود. همان‌طور که مشاهده می‌شود بر اساس ویژگی‌های محوری به‌دست‌آمده که شامل کلماتی با بار احساسی فراوان (همچون Easy, Bad, Awful, Wonderful و همانند آن) است، می‌توان دانش احساسی موجود در عقاید را استخراج نمود.

همچنین در جدول ۴ تعداد کل ویژگی‌ها و ویژگی‌های غیرمحوری مورداستفاده در فرایند یادگیری مشاهده می‌شود. ویژگی‌هایی که در فرایند آموزش مدل مورد قرار نگرفته‌اند فاقد ارزش اطلاعاتی کافی بوده‌اند (برای مثال کلمات توقفی که در عقاید زیادی تکرار شده‌اند).

### ۴-۳- آموزش مدل دسته‌بند

در گام بعدی یادگیری ساختاری همبستگی بین ویژگی‌های محوری را با سایر کلمات بر مبنای آموزش یک مدل دسته‌بند مدل‌سازی می‌کند. مدل دسته‌بند، رخداد یا عدم رخداد ویژگی‌های محوری را بر اساس سایر کلمات در هر یک از اسناد پیش‌بینی می‌کند. برای این منظور به ازای هر یک از ویژگی‌های محوری  $p_t \in P$  یک مجموعه آموزشی  $D_l$  به‌صورت رابطه ۴ ایجاد می‌شود:

$$D_l = \{ (MASK(x, p_l), IN(x, p_l)) \mid x \in D_u \} \quad (4)$$

$MASK(x, p_l)$  تابعی است که یک کپی از  $x$  را پس از حذف  $p_l$  بازمی‌گرداند.  $IN(x, p_l)$  مقداری را بازمی‌گرداند که همبستگی بین ویژگی‌های غیرمحوری با ویژگی محوری متناظر را نشان می‌دهد.

می‌شود. تعداد نمونه‌های مثبت و منفی نمونه‌های بدون برچسب نیز متعادل است.

جدول ۵: تعداد نمونه‌های بدون برچسب مجموعه داده برای هر یک از

تعداد نمونه	دامنه
۴۴۶۵	کتاب
۳۵۸۶	دی‌وی‌دی
۵۶۸۱	وسایل الکتریکی
۵۹۴۵	لوازم آشپزخانه

#### ۲-۴- معیار ارزیابی

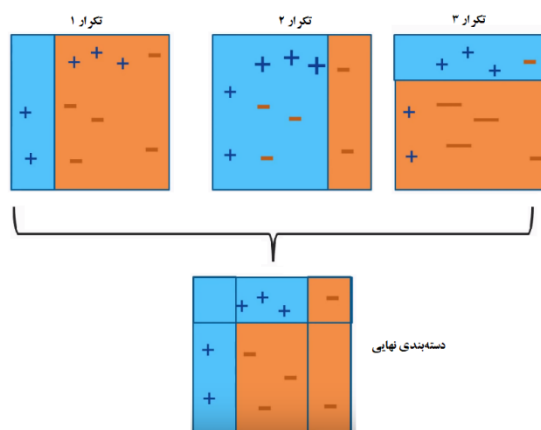
از معیار ارزیابی درستی<sup>۴۷</sup> برای ارزیابی روش‌های پیاده‌سازی شده استفاده می‌شود؛ با در نظر گرفتن ماتریس درهم‌ریختگی<sup>۴۸</sup> که این موارد در آن تعریف می‌شوند: مثبت واقعی (TP): مدل به درستی متعلق بودن عقیده را به یک کلاس پیش‌بینی کرده است؛ منفی واقعی (FP): مدل به اشتباه متعلق بودن عقیده را به یک کلاس پیش‌بینی کرده است. مثبت کاذب (TN): مدل به درستی عدم تعلق عقیده را به یک کلاس پیش‌بینی کرده است و منفی کاذب (FN): مدل به اشتباه عدم تعلق عقیده را به یک کلاس پیش‌بینی کرده است؛ درستی بر اساس رابطه ۵ محاسبه می‌شود:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

#### ۳-۴- نتایج

در این بخش ضمن بیان نتایج به دست آمده از انجام آزمایش‌ها مقایسه‌ای با روش‌های مشابه پیشین انجام می‌شود. در جداول ۶ تا ۸ نتایج روش پیشنهادی برای دامنه‌های مقصد مختلف و به ترتیب یک، دو و سه دامنه مبدأ مشاهده می‌شود. در جدول ۶ نتایج محدود به یک مبدأ می‌باشد. به عبارت دیگر، روال ترکیب دسته‌بندی‌های مختلف بر روی چند دامنه انجام نشده است. برای دامنه مقصد «الکترونیک»، دامنه مبدأ «کتاب» با میزان درستی ۷۸/۵۱ درصد؛ دامنه مقصد، «دی‌وی‌دی» دامنه مبدأ «کتاب» با میزان درستی ۸۳/۳۴ درصد؛ دامنه مقصد «کتاب»، دامنه مبدأ «آشپزخانه» با میزان درستی ۸۳/۶۴ درصد و دامنه مقصد «آشپزخانه»، دامنه مبدأ «دی‌وی‌دی» با میزان درستی ۸۱/۲۲ درصد بهترین نتایج را به همراه داشته است. همچنین در این جدول، نتایج مرجع [۴۱] ذکر شده است که در ادامه به آن پرداخته خواهد شد.

تکرارهای بعدی تخصیص می‌یابد. وزن بیشتر به معنی عدم دسته‌بندی صحیح و وزن کمتر به معنی دسته‌بندی صحیح است. در تکرار دوم یک فرایند دسته‌بندی دیگر بر روی مجموعه داده صورت گرفته و وزن‌ها مجدداً تغییر می‌یابند. همان‌طور که در شکل مشخص است وزن نمونه‌های مثبتی که در تکرار اول به اشتباه دسته‌بندی شده بودند (به عنوان نمونه منفی تشخیص داده شده بودند) بیشتر است (در شکل بزرگ‌تر هستند). در تکرار سوم نیز بر روی مجموعه داده‌ها با وزن‌های تکرار دوم دسته‌بندی انجام می‌شود. در این تکرار نیز برخی از نمونه‌های منفی به دلیل تشخیص غلط در گام قبل وزن بیشتری دارند. به همین شکل وزن‌ها بر اساس میزان خطا به صورت خودکار برای هر یک از دسته‌بندی‌ها به‌روز شده و در نهایت بر مبنای وزن‌های نهایی یک دسته‌بند قدرتمند خواهیم داشت.




شکل ۲: ترکیب دسته‌بندی‌ها بر اساس الگوریتم AdaBoost

#### ۴- آزمایش‌ها

##### ۴-۱- مجموعه داده

به منظور ارزیابی روش پیشنهادی از مجموعه داده‌های برچسب‌خورده آمازون<sup>۴۹</sup> استفاده شده است. مجموعه عقاید درج شده برای محصولات آمازون برای چهار نوع محصول مختلف شامل: کتاب، DVD، وسایل الکتریکی و لوازم آشپزخانه. در وبسایت آمازون به عقاید امتیاز ۱ تا ۵ داده می‌شود. در این مجموعه داده عقایدی که امتیاز نهایی آن‌ها از ۳ بزرگ‌تر باشد، برچسب مثبت و اگر از سه کوچک‌تر باشد برچسب منفی الصاق شده است. مابقی عقاید نیز از آنجاکه نمی‌توان قطبیت‌شان را مشخص نمود مبهم هستند و نادیده گرفته می‌شوند. در نهایت برای هر یک از دامنه‌ها ۱۰۰۰ نمونه مثبت و ۱۰۰۰ نمونه منفی در نظر گرفته شده است. علاوه بر داده‌های برچسب‌خورده برای هر یک از دامنه‌ها نمونه‌های بدون برچسبی نیز وجود دارد که تعداد آن‌ها در جدول ۵ مشاهده



شکل ۳: مقایسه نتایج روش پیشنهادی مقاله با روش ارائه‌شده در مرجع [۳۱] برای دامنه مقصد الکترونیک

یکی دیگر از روش‌هایی که نتایج قابل توجهی به همراه داشته روش [۴۱] SFA<sup>۴۹</sup> بوده است؛ آن‌ها با به‌کارگیری الگوریتم SFA کلمات مختص به دامنه<sup>۵۰</sup> را در خوشه‌های یکسان تطبیق داده و بر اساس کلمات مستقل از دامنه<sup>۵۱</sup> ارتباط بین دامنه‌های مختلف برقرار می‌شود به عبارت دیگر بین دامنه مبدأ و مقصد یک نگاشت<sup>۵۲</sup> صورت می‌گیرد.

همان‌طور که در جدول ۶ دیده شد نتایج تک‌منبعی مرجع [۴۱] با نتایج تک‌منبعی روش پیشنهادی این مقاله مشاهده می‌شود. مشخص است که روش پیشنهادی این پژوهش بر روی اکثر دامنه‌ها نتایج بهتری داشته است، هرچند نوآوری اصلی مقاله حاضر بر روی یادگیری انتقالی چند منبعی است ولی بازهم این نتایج حاکی از آن است روش پیشنهادی به‌طور کلی عملکرد بهتری داشته است.

در نمودار شکل ۴ نتایج این الگوریتم در بهترین حالت برای هر یک از دامنه‌های مقصد با بهترین نتایج روش‌های [33] TCT، [32] LSF، [41] SFA و روش پیشنهادی این مقاله مقایسه شده است. هر یک از نتایج با رنگ‌های مختلفی قابل تفکیک هستند. منظور از بهترین حالت انتخاب دامنه‌ای به‌عنوان دامنه مبدأ است که بیشترین مقدار درستی را به همراه داشته باشد. البته باید ذکر شود که در روش SFA تنها یک دامنه مبدأ وجود دارد برای مثال نتایج رده آشپزخانه برای این روش، زمانی به دست آمده (۰.۸۶) که رده الکترونیک به‌عنوان مبدأ استفاده شده است. روش پیشنهادی فاصله بین دامنه‌های مختلف مبدأ با دامنه مقصد را با خوشه‌بندی ویژگی‌های مختص به دامنه کاهش داده و با بوست دادن یک دسته‌بند ترکیبی نتایج بهتری نسبت به الگوریتم‌های دیگر ارائه می‌کند. همان‌طور که دیده می‌شود روش پیشنهادی این مقاله همواره نتایج بهتری را نسبت به روش‌های مشابه ارائه نموده است. به‌عنوان مثال، برای رده

جدول ۶: نتایج روش پیشنهادی (یک مبدأ)

شماره	مبدأ	مقصد	درستی	مرجع [۴۱]
۱	دی‌وی‌دی	الکترونیک	۷۶/۷۲	۷۳،۳۹
۲	کتاب	الکترونیک	۷۸/۵۱	۷۲،۸۱
۳	آشپزخانه	الکترونیک	۸۳/۸۶	۸۴،۶
۴	کتاب	دی‌وی‌دی	۸۳/۳۴	۸۱،۰۴
۵	آشپزخانه	دی‌وی‌دی	۷۹/۶۷	۷۷،۵۷
۶	الکترونیک	دی‌وی‌دی	۷۸/۶۱	۷۷،۵۴
۷	دی‌وی‌دی	کتاب	۸۲/۳۳	۷۷،۶۹
۸	آشپزخانه	کتاب	۸۳/۶۴	۷۴،۰۰
۹	الکترونیک	کتاب	۷۷/۹۴	۷۵،۷۱
۱۰	کتاب	آشپزخانه	۷۷/۹۴	۷۸،۴۰
۱۱	دی‌وی‌دی	آشپزخانه	۸۱/۲۲	۸۱،۰۶
۱۲	الکترونیک	آشپزخانه	۸۰/۶۰	۸۷،۱

جدول ۷: نتایج روش پیشنهادی (دو مبدأ)

شماره	مبدأ	مقصد	درستی
۱	{دی‌وی‌دی، کتاب}	الکترونیک	۸۳/۹۶
۲	{کتاب، آشپزخانه}	الکترونیک	۸۷/۱۶
۳	{آشپزخانه، دی‌وی‌دی}	الکترونیک	۸۶/۷۱
۴	{کتاب، آشپزخانه}	دی‌وی‌دی	۸۸/۹۱
۵	{آشپزخانه، الکترونیک}	دی‌وی‌دی	۸۴/۱۳
۶	{الکترونیک، کتاب}	دی‌وی‌دی	۸۲/۴۹
۷	{دی‌وی‌دی، آشپزخانه}	کتاب	۸۷/۰۱
۸	{آشپزخانه، الکترونیک}	کتاب	۸۴/۳۷
۹	{الکترونیک، دی‌وی‌دی}	کتاب	۸۴/۱۱
۱۰	{کتاب، دی‌وی‌دی}	آشپزخانه	۸۴/۹۳
۱۱	{دی‌وی‌دی، الکترونیک}	آشپزخانه	۸۷/۳۵
۱۲	{الکترونیک، کتاب}	آشپزخانه	۸۸/۳۹

جدول ۸: نتایج روش پیشنهادی (سه مبدأ)

شماره	مبدأ	مقصد	درستی
۱	{دی‌وی‌دی، کتاب، آشپزخانه}	الکترونیک	۸۹/۶۴
۲	{کتاب، آشپزخانه، الکترونیک}	دی‌وی‌دی	۹۳/۹۷
۳	{دی‌وی‌دی، آشپزخانه، کتاب}	کتاب	۹۲/۳۹
۴	{کتاب، دی‌وی‌دی، الکترونیک}	آشپزخانه	۹۰/۱۷

#### ۴-۴- مقایسه با روش‌های دیگر


همان‌طور که در شکل ۳ مشاهده می‌شود روش پیشنهادی این مقاله بر اساس مبدأهای مختلف همواره نتایج بهتری را نسبت به روش پیشنهاد شده در [۳۱] (که پیش از این به روش آن اشاره شد) برای دامنه مقصد الکترونیک داشته است. برای مثال در شرایط استفاده از سه دامنه مبدأ {دی‌وی‌دی، کتاب، آشپزخانه} مقدار معیار درستی برای این روش نزدیک به ۰.۸۴ بوده در حالی که این مقدار برای روش پیشنهادی بیش از ۰.۸۹ به دست آمده است.

داشته‌اند استفاده نمود. همچنین استفاده از یک مجموعه داده غنی برای زبان فارسی و یا تکنیک‌های یادگیری انتقالی چند زبانی برای دسته‌بندی عقاید فارسی می‌تواند بسیار ارزشمند باشد. نتایج آزمایش‌های انجام‌شده و مقایسه آن با روش‌های دیگری که در این زمینه انجام شده است نشان می‌دهد می‌توان الگوریتم این مقاله را در زمینه‌های دیگر، مجموعه داده‌های دیگر و حوزه‌هایی همچون شبکه‌های اجتماعی به کار گرفت.

## مراجع

- [1] L. Deng, "A tutorial survey of architectures, algorithms, and applications for deep learning," APSIPA Transactions on Signal Information Processing, Vol. 3, no 2, pp. 1-29, 2014.
- [2] S. J. Pan and Q. Yang, "A survey on transfer learning," IEEE Transactions on Knowledge and Data Engineering, Vol. 22, No 10, pp. 1345-1359, 2010.
- [3] W. Pan, E. Zhong, and Q. Yang, "Transfer learning for text mining," Mining Text Data, pp. 223-257, 2012.
- [4] J. Pan, X. Hu, Y. Zhang, P. Li, Y. Lin, H. Li, W. He, and L. Li, "Quadruple Transfer Learning: Exploiting both shared and non-shared concepts for text classification," Knowledge-Based Systems, Vol. 90, pp. 199-210, 2015.
- [5] G. Vinodhini and R. M. Chandrasekaran, "Sentiment analysis and opinion mining: a survey," International Journal of Advanced Research in Computer Science and Software Engineering, Vol. 2, No 6, pp. 282-292, 2012.
- [6] B. Pang, L. Lee, and S. Vaithyanathan, "Thumbs up? Sentiment Classification using Machine Learning Techniques," in Proceedings of the conference on Empirical methods in natural language processing (EMNLP), pp. 79-86, 2002.
- [7] M. Thomas, B. Pang, and L. Lee, "Get out the vote: Determining support or opposition from Congressional floor-debate transcripts," in Proceedings of the 2006 conference on empirical methods in natural language processing, pp. 327-335, 2006.
- [8] B. Pang and L. Lee, "Seeing stars: Exploiting class relationships for sentiment categorization with respect to rating scales," in Proceedings of the 43rd annual meeting on association for computational linguistics, pp. 115-124, 2005.
- [9] A. B. Rosario, F. Sotgiu, K. De Valck, and T. H. A. Bijmolt, "The effect of electronic word of mouth on sales: A meta-analytic review of platform, product, and metric factors," Journal of Marketing Science, Vol. 53, no 3, pp. 297-318, 2016.
- [10] A. Hervas-Drane, "Recommended for you: The effect of word of mouth on sales concentration," International Journal of Research in Marketing, Vol. 32, No 2, pp. 207-218, 2015.
- [11] D.-H. Park and S. Kim, "The effects of consumer knowledge on message processing of electronic word-of-mouth via online consumer reviews," Electronic Commerce Research and Applications, Vol. 7, No 4, pp. 399-410, 2008.
- [12] M. Hu and B. Liu, "Mining and summarizing customer reviews," in Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining, pp. 168-177, 2004.
- [13] S.-M. Kim, P. Pantel, T. Chklovski, and M. Pennacchiotti, "Automatically assessing review helpfulness," in Proceedings of the 2006 Conference on empirical methods in natural language processing, pp. 423-430, 2006.
- [14] S. Basuroy, S. Chatterjee, and S. A. Ravid, "How critical are critical reviews? The box office effects of film critics, star power, and budgets," Journal of Marketing, Vol. 67, No 4, pp. 103-117, 2003.
- [15] J. A. Chevalier and D. Mayzlin, "The effect of word of mouth on

آشپزخانه زمانی که رده‌های {کتاب، دی‌وی‌دی، الکترونیک} به‌عنوان دامنه مبدأ در نظر گرفته شوند، مقدار درستی برای روش پیشنهادی ۹۰ درصد به دست آمده است. از نتایج به‌دست‌آمده می‌توان دریافت استفاده از چندین دسته‌بندی به‌طور هم‌زمان در فرایند بوس‌تینگ موجب بهبود عملکرد دسته‌بندی شده است. در صورت عدم استفاده از نتایج دسته‌بندی‌های مختلف برای بوس‌ت دادن یک دسته‌بند قدرت‌مند، نمی‌توان از قدرت هر یک از آن‌ها در پیش‌بینی نمونه‌های مختلف استفاده نمود.



شکل ۴: مقایسه نتایج روش پیشنهادی مقاله با روش [41] SFA، [33] TCT و [32] LSF به تفکیک رده‌های مختلف مقصد

## ۵- نتیجه‌گیری و کارهای آینده

یادگیری متناظر ساختاری روشی کارآمد برای دسته‌بندی احساسی چندمنبعی متون است. این رویکرد از اسناد بدون برچسب برای یافتن جفت کلمات متناظر بین متون دامنه‌های مختلف استفاده می‌کند. در این مقاله روشی مبتنی بر یادگیری متناظر ساختار ارائه گردید که قادر است از چند دامنه به‌طور هم‌زمان به‌عنوان مبدأ استفاده نموده و مدل دسته‌بندی ترکیبی آموزش داده سپس از آن برای دسته‌بندی احساسی نمونه‌های آزمون دامنه مقصد استفاده نماید. سهم اصلی این مقاله بهره‌گیری از یک فرایند بوس‌تینگ به‌منظور ایجاد یک دسته‌بند ترکیبی قدرت‌مند بوده که بتواند نتایج چند دسته‌بند را به‌گونه‌ای ترکیب کند که بهترین دقت را داشته باشد. همان‌طور که مشاهده شد در قیاس با روش‌های مشابهی که تاکنون ارائه شده‌اند روش پیشنهادی این پژوهش کارایی بهتری را ارائه می‌نماید.

در کارهای آتی می‌توان دامنه‌های دیگری را از مجموعه داده‌هایی به‌غیر از آمازون به کار گرفت تا کارایی روش بهبود یابد. همچنین می‌توان از ایده مورد استفاده برای چندمنبعی کردن روش‌های دیگری که در دسته‌بندی چندمنبعی مورد نتایج خوبی به همراه

- [29] K. Denecke, "Are SentiWordNet scores suited for multi-domain sentiment classification?," 2009 Fourth International Conference on Digital Information Management (ICDIM 2009), pp. 1–6, 2009.
- [30] D. Bollegala, D. Weir, and J. Carroll, "Using multiple sources to construct a sentiment sensitive thesaurus for cross-domain sentiment classification," in Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies, Vol. 1, pp. 132–141, 2011.
- [31] N. Manjunathan, "Cross-Domain Opinion Mining Using a Thesaurus in Social Media Content," International Journal of Innovative Research in Computer and Communication Engineering, Vol. 2, No 5, 2014.
- [32] Liang, J., Zhang, K., Zhou, X., Hu, Y., Tan, J., and S. Bai, "Leveraging Latent Sentiment Constraint in Probabilistic Matrix Factorization for Cross-domain Sentiment Classification", The International Conference on Computational Science (ICCS 2016), Vol. 80, 366-375, 2016.
- [33] Zhou, G., Zhou, Y., Guo, X., Tu, X., and T. He, "Cross-domain sentiment classification via topical correspondence transfer", Neurocomputing, Vol. 159, Issue C, pp. 298-305, 2015.
- [34] C. Cagatay, and M. Nangir, "A sentiment classification model based on multiple classifiers", Applied Soft Computing, Vol. 50, pp. 135-141, 2017.
- [35] V. Malik, and A. Kumar, "Sentiment Analysis of Twitter Data Using Naive Bayes Algorithm", International Journal on Recent and Innovation Trends in Computing and Communication, Vol. 6, No 4, pp.120-125, 2018.
- [36] A. Hasan, S. Moin, A. Karim and S. Shamshirband, "Machine Learning-Based Sentiment Analysis for Twitter Accounts", Mathematical and Computational Applications, Vol. 23, No 11, pp. 2297-8747, 2018.
- [37] H. M. Keerthi Kumar, B. S. Harish and H. K. Darshan, "Sentiment Analysis on IMDb Movie Reviews Using Hybrid Feature Extraction Method", International Journal of Interactive Multimedia and Artificial Intelligence, Vol. 5, No 5, pp. 109-114, 2018.
- [38] M. Chen and Y. Sun, "Sentiment Analysis with Amazon Review Data", Stanford University, 2017, Available at <http://cs229.stanford.edu/proj2017/final-reports/5163147.pdf>.
- [39] T. Haque, N. N. Saber and F. M. Shah, "Sentiment Analysis on Large Scale Amazon Product Reviews", IEEE International Conference on Innovative Research and Development (ICIRD), pp. 1-6, 2018.
- [40] Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," in European conference on computational learning theory, pp. 23–37, 1995.
- [41] S. J. Pan, X. Ni, J.-T. Sun, Q. Yang, and Z. Chen, "Cross-domain sentiment classification via spectral feature alignment," in Proceedings of the 19th international conference on World Wide Web, pp. 751–760, 2010.
- [16] H. Baek, J. Ahn, and Y. Choi, "Helpfulness of online consumer reviews: Readers' objectives and review cues," International Journal of Electronic Commerce, Vol. 17, No 2, pp. 99–126, 2012.
- [17] Q. Cao, W. Duan, and Q. Gan, "Exploring determinants of voting for the 'helpfulness' of online user reviews: A text mining approach," Decision Support Systems, Vol. 50, No 2, pp. 511–521, 2011.
- [18] N. S. Koh, N. Hu, and E. K. Clemons, "Do online reviews reflect a product's true perceived quality? An investigation of online movie reviews across cultures," Electronic Commerce Research and Applications, Vol. 9, No 5, pp. 374–385, 2010.
- [19] W. Duan, B. Gu, and A. B. Whinston, "The dynamics of online word-of-mouth and product sales—An empirical investigation of the movie industry," Journal of Retailing, Vol. 84, No 2, pp. 233–242, 2008.
- [20] M. Li, L. Huang, C.-H. Tan, and K.-K. Wei, "Helpfulness of online product reviews as seen by consumers: Source and content features," International Journal of Electronic Commerce, Vol. 17, No 4, pp. 101–136, 2013.
- [21] M. L. Kushwaha and S. D. Rathod, "New Opinion Mining Technique For Online Product Reviews And Features," Multidisciplinary Journal of Research in Engineering and Technology, Vol. 2, No 4, pp. 852–858, 2015.
- [22] Y. Liu, X. Huang, A. An, and X. Yu, "Modeling and predicting the helpfulness of online reviews," ICDM '08 Proceedings of Eighth IEEE International Conference on Data Mining, pp. 443–452, 2008.
- [23] C. Banea, R. Mihalcea, J. Wiebe, and S. Hassan, "Multilingual subjectivity analysis using machine translation," in Proceedings of the Conference on Empirical Methods in Natural Language Processing, pp. 127–135, 2008.
- [24] P. Prettenhofer and B. Stein, "Cross-lingual adaptation using structural correspondence learning," ACM Transactions on Intelligent Systems and Technology, Vol. 3, No 1, pp. 13:1-13:22, 2011.
- [25] J. Blitzer, R. McDonald, and F. Pereira, "Domain adaptation with structural correspondence learning," in Proceedings of the 2006 conference on empirical methods in natural language processing, pp. 120–128, 2006.
- [26] P. Wang, C. Domeniconi, and J. Hu, "Using wikipedia for co-clustering based cross-domain text classification," ICDM '08 Proceedings of Eighth IEEE International Conference on Data Mining, pp. 1085–1090, 2008.
- [27] E. W. Xiang, B. Cao, D. H. Hu, and Q. Yang, "Bridging domains using world wide knowledge for transfer learning," IEEE Transactions on Knowledge and Data Engineering, Vol. 22, No 6, pp. 770–783, 2010.
- [28] Y. He, C. Lin, and H. Alani, "Automatically extracting polarity-bearing topics for cross-domain sentiment classification," in Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies, Vol. 1, pp. 123–131, 2011.

زیر نویس‌ها:

<sup>8</sup> Negative

<sup>9</sup> Unigram

<sup>10</sup> Bigram

<sup>11</sup> Structural Correspondence Learning

<sup>12</sup> Pivot Features

<sup>13</sup> Boosting

<sup>14</sup> Candidate

<sup>1</sup> Discriminative learning

<sup>2</sup> Training Samples

<sup>3</sup> Test Samples

<sup>4</sup> Source

<sup>5</sup> Destination

<sup>6</sup> Transfer Learning

<sup>7</sup> Positive

15	Threshold	34	Topical Correspondence Transfer
16	Pang	35	Hybrid
17	Thomas	36	Bagging
18	Lee	37	Maximum Entropy
19	Support Vector Machine	38	Large Scale
20	Park	39	Accuracy
21	Kim	40	KNN
22	Naïve Bayes	41	Bag of Words
23	Liu	42	Boosting
24	Wang	43	Blitzer
25	Co-clustering	44	Information Gain
26	Xiang	45	Fisher Criterion
27	Bollegala	46	Amazon.com
28	Thesaurus	47	Accuracy
29	Binary	48	Confusion Matrix
30	Manjunathan	49	Spectral Feature Alignment
31	Distributional	50	Domain Specific
32	Polarity	51	Domain Independent
33	Matrix Factorization	52	Mapping