

An Investigation into the Process of Organizing and Retrieving Web Texts based on the Integration of Semantic Concept in order to Organize Knowledge

Saeede Anbaee Farimani

PhD Candidate; Department of Computer Engineering;
Mashhad Branch; Islamic Azad University; Mashhad, Iran;
Email: anbaee@mshdiau.ac.ir

Hamid Tabatabaee*

PhD; Assistant Professor; Department of Computer Engineering;
Quchan Branch; Islamic Azad University; Quchan, Iran;
Email: h_tabatabaee@mshdiau.ac.ir

Mojtaba Kaffashan Kakhki

Assistant Professor; Knowledge and Information Science;
Academic Member of Ferdowsi University of Mashhad;
Email: kafashan@ferdowsi.um.ac.ir

Received: 07, Jan. 2019 Accepted: 09, May 2019

Iranian Journal of
Information
Processing and
Management

Abstract: Improvement in information retrieval performance relates to the method of knowledge extraction from large amounts of text information on web. Text classification is a way of knowledge extraction with supervised machine learning methods. This paper proposed Kullback-Leibler divergence KNN for classifying extracted features based on term weighting with Latent Dirichlet Allocation algorithm. LDA is Non-Negative matrix factorization method proposed for topic modeling and dimension reduction of high dimensional feature space. In traditional LDA, each component value is assigned using the information retrieval Term Frequency measure. While this weighting method seems very appropriate for information retrieval, it is not clear that it is the best choice for text classification problems. Actually, this weighting method does not leverage the information implicitly contained in the categorization task to represent documents. In this paper, we introduce a new weighting method based on Point wise Mutual Information for accessing the importance of a word for a specific latent concept, then each document classified based on probability distribution over the latent topics. Experimental result investigated when we used Pointwise Mutual

Iranian Research Institute
for Information Science and Technology
(IranDoc)
ISSN 2251-8223
eISSN 2251-8231
Indexed by SCOPUS, ISC, & LISTA
Vol. 34 | No. 4 | pp. 1879-1904
Summer 2019
<https://doi.org/10.35050/JIPM010.2019.025>



* Corresponding Author

Information measure for term weighing and K Nearest Neighbor with Kullback-Leibler distance for classification, accuracy has been 82.5%, with the same accuracy versus probabilistic deep learning methods.

Keywords: Text Mining, Text Classification, Topic Modeling, Latent Dirichlet Allocation, Document Representation, Knowledge Organization, Pointwise Mutual Information

جستاری بر فرایند سازماندهی و بازیابی متون و بی مبتنی بر تجمعیع مفاهیم معنایی در راستای سازماندهی دانش

سعیده انباری فریمانی

دانشجوی دکتری؛ گروه مهندسی کامپیوتر؛
واحد مشهد؛ دانشگاه آزاد اسلامی؛ مشهد، ایران؛
Anbaee@mshdiau.ac.ir

حمید طباطبایی

استادیار؛ گروه مهندسی کامپیوتر؛
واحد قوچان؛ دانشگاه آزاد اسلامی؛ قوچان، ایران؛
h_tabatabae@mshdiau.ac.ir

مجتبی کفاشان کاکخی

استادیار؛ گروه علم اطلاعات و دانش‌شناسی؛ دانشگاه
فردوسی مشهد؛ ایران ir kafashan@ferdowsi.um.ac.ir

دریافت: ۱۳۹۷/۰۱/۱۷

پذیرش: ۱۳۹۸/۰۲/۱۹

مقاله برای اصلاح به مدت چهار روز نزد پدیدآوران بوده است.



نشریه علمی | رتبه بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایراندک)
شما (جایی) ۲۲۵۱-۸۲۳۳
شما (الکترونیکی) ۲۲۵۱-۸۲۳۱
SCOPUS، ISC، LISTA، jipm.irandoc.ac.ir
دوره ۳۴ | شماره ۴ | صص ۱۸۷۹-۱۹۰۴
تاریخ: ۱۳۹۸
<https://doi.org/10.35050/JIPM010.2019.025>



چکیده: سازماندهی و بازیابی دانش منتشرشده در محیط وب به عنوان یکی از مهم‌ترین کاربردهای متن کاوی مطرح است. از جمله چالش‌های سازماندهی مجموعه عظیمی از متون در قالب یک پیکره متنی، ابعاد زیاد ویژگی‌ها و خلوت بودن ماتریس ویژگی‌های است. نحوه انتخاب ویژگی‌ها و کاهش آن‌ها در این مسئله تأثیر بهسزایی در بالاتر رفتان دقت سازماندهی و بازیابی متون دارد. در بسیاری از پژوهش‌ها به بررسی جداگانه این دو چالش پرداخته شده است. این پژوهش با رویکرد توجه همزمان به این دو چالش انجام گرفته است. پس از تعیین متون مرتبط با ۲۰ گروه خبری ویسی و پس از فاز پیش‌پردازش متون با استفاده از الگوریتم الگوسازی عنوان «الدی‌ای»، کیسه‌ای (تجمعی) از مفاهیم معنایی برای پیکره متنی مورد نظر ساخته شد. به منظور بررسی میزان تأثیر واژه‌های پیکره متون در هر مفهوم پنهان، به بررسی نحوه وزن‌دهی واژگان یک پیکره، در مفاهیم استخراج شده توسط الگوریتم «الدی‌ای» پرداخته شد. از این رو، برای هر متن یک توزیع احتمال رخداد حول هر عنوان استخراج گردید که برای سازماندهی و بازیابی دانش موجود در آن مورد استفاده قرار گرفت. برای سازماندهی آن از الگوریتم نزدیک‌ترین K همسایه با معیار شbahat و اگرای «کولبک لیبلر» که میزان فاصله دو توزیع احتمال را می‌سنجد؛ استفاده شد.

نتایج آزمون‌ها نشان داد که میزان صحت سازماندهی روش پیشنهادی در صورتی که از معیار وزن‌دهی واکنشی اطلاعات متقابل نقطه‌ای و الگوریتم KL-KNN استفاده شده باشد، ۸۲/۵ درصد است. نتایج تحلیل‌ها نشان داد که این روش دارای دقیقی مشابه با روش‌هایی است که از فنون یادگیری عمیق استفاده می‌نمایند. افزون بر این، روش به کارفته در این پژوهش نشان‌دهنده پیچیدگی کمتر در فرایند سازماندهی و بازیابی متون مورد مطالعه پژوهش بود.

کلیدواژه‌ها: متن کاوی، طبقه‌بندی متن، الگوسازی عنوان، بازیابی، سازماندهی دانش، واکنشی اطلاعات متقابل نقطه‌ای

۱. مقدمه

سازماندهی و بازیابی از مباحث مهم و مطرح در نظام‌های اطلاعاتی است؛ به گونه‌ای که بر اساس تحقیقات «جارولین و واکاری» (Järvelin & Vakkari 1993) از هر سه مقاله نوشه شده در علم اطلاع‌رسانی یک مقاله به سازماندهی و بازیابی اختصاص یافته است. افزون بر این، با گسترش و رشد وب و شبکه‌های اجتماعی، حجم متون منتشرشده به عنوان داده‌های بدون ساختار در حال گسترش است (Thiyagarajan & Shanthi 2017). فهم قدرت متون منتشرشده با در نظر گرفتن نقش آفرینی متن کاوی و داده کاوی در تولید دانش سطحی، دانش چندوجهی، دانش پنهان، و دانش عمیق دوچندان می‌گردد. متن کاوی به مثابة تحلیل هوشمند متن، کاوش متن و یا کشف و تولید دانش تلقی می‌شود (قاضی‌زاده و خزانه‌ها ۱۳۹۵). به عبارت دقیق‌تر، کشف و تولید دانش مستلزم توجه ویژه به فرایندهای سازماندهی و بازیابی دانش مندرج در متون است. سازماندهی و بازیابی متون، یکی از شاخه‌های مهم کاوش متن است که امروزه در بسیاری از زمینه‌ها از جمله دسته‌بندی اسناد خبری، طبقه‌بندی صفحات وب، تحلیل احساس در کاربران یک خدمت، فیلتر کردن اسپم‌ها و ... کاربرد دارد (Hotho & Paaß 2005). همچنین، سازماندهی و بازیابی متون از زمرة کاربردهای یادگیری ماشین و از جمله روش‌های یادگیری با ناظر است که در آن به ساخت یک الگو از یک پیکره متنی^۱ بر اساس داده‌های آموزشی دارای برچسب پرداخته می‌شود و سپس، با استفاده از الگوی تولیدشده، به سازماندهی سایر داده‌های بدون برچسب می‌پردازد. فرایند آموزش شامل پیش‌پردازش داده‌ها، انتخاب ویژگی‌های مناسب، کاهش ابعاد ویژگی‌ها، و آموزش الگوست. گروهی از روش‌ها برای ساخت ماتریس ویژگی از فراوانی تکرار

1. text corpus

واژه‌های موجود در متون یک پیکره استفاده می‌کند. بر این پایه، ممکن است بسیاری از واژه‌هایی که در متون فراوانی تکرار کمی داشته باشند، در مرحله کاهش ویژگی حذف شوند (Blei, Ng & Jordan 2003; Chen, Guo & Bai 2017; Chen & Li 2016; Zhao & Mao 2018).

این نحوه کاهش ویژگی سبب کاهش دقت سازماندهی و بازیابی دانش ارائه شده در متن مورد نظر می‌گردد. این فرایند در قالب مهار واژگانی تبیین می‌گردد. مهار واژگانی به مجموعه‌ای محدود از اصطلاح‌های مجاز نسبت داده می‌شود که باید در نمایه‌سازی و در جستجوی مدارک در یک نظام اطلاعاتی معین به کار رود (پائو ۱۹۸۹). در روش پیشنهادی در پژوهش حاضر تلاش می‌شود که بعد از انجام مراحل پیش‌پردازش، برای پیکره متن، ماتریسی از ویژگی‌ها با استفاده از روش کاهش ویژگی تخصیص دریکله^۱ به مفاهیم پنهان (یا ال‌دی‌ای^۲) به گونه‌ای طراحی شود که افزون بر مؤثر بودن فراوانی تکرار واژگان، میزان اهمیت آن واژه در پیکره متن نیز لحاظ شود و در نهایت، پس از استخراج ماتریس توزیع احتمال رخداد^۳ هر عنوان در اسناد پیکره با استفاده از طبقه‌بند مبتنی بر نزدیکترین^۴ همسایه با معیار فاصله «کولبک‌لیلیر»^۵ برای سازماندهی و بازیابی متون استفاده شود. «کولبک‌لیلیر» به عنوان معیار برای اندازه‌گیری واگرایی یک توزیع احتمال از یک توزیع احتمال ثانویه در نظر گرفته می‌شود. در روش الگوسازی عنوان^۶ «ال‌دی‌ای» حد آستانه‌ای از تکرار برای واژگان در نظر گرفته می‌شود و واژه‌هایی که کمتر از حد آستانه در متن تکرار شده باشند، از فرایند الگوسازی مفاهیم معنایی حذف می‌شوند؛ در

1. Dirichlet

۲. Latent Dirichlet Allocation یک الگوی تولیدی در آمار و یک روش الگوسازی عنوان است. این الگو برای الگوسازی تعدادی متغیرهای پنهان (عنوانین) در مجموعه‌ای از متن‌ها که شامل کلمات هستند، به وجود آمده است. از این رو، میزان تأثیر هر واژه با توجه به فراوانی تکرار آن در یک مفهوم معنایی و همچنین، میزان تأثیر هر مفهوم استخراج شده در هر متن تعیین می‌گردد.

۳. هر کدام از عنوانین استخراج شده بر اساس وزن مؤثر لغات هر عنوان، با یک میزان احتمال مشخص در یک سند وی ظاهر می‌گردد، به طوری که حاصل جمع مقادیر این احتمال‌ها یک شود.

۴. جستجوی K نزدیکترین همسایه، K همسایه نزدیک‌تر به نقطه پرس‌وجو را بر می‌گرداند. از این روش، به‌منظور تخمین یا دسته‌بندی یک نقطه بر اساس اجماع همسایگان آن استفاده می‌شود.

۵. Kullback Leibler میزان فاصله واگرایی «کولبک‌لیلیر» به عنوان معیاری برای اندازه‌گیری واگرایی یک توزیع احتمال از یک توزیع احتمال ثانویه در نظر گرفته می‌شود. به عبارت دیگر، مقدار صفر برای «کولبک‌لیلیر» نشان می‌دهد که ما می‌توانیم انتظار رفتاری مشابه (نه دقیقاً یکسان) از دو توزیع داشته باشیم؛ در حالی که مقدار ۱ برای این معیار نشان می‌دهد که دو توزیع رفتارهای متضادی دارند.

6. topic modeling

حالی که ممکن است این واژه‌ها دارای نقش مهمی در طبقه خود باشند. برای رفع این محدودیت در این پژوهش با اعمال ضربی و اکشی اطلاعات متقابل نقطه‌ای^۱، این واژه‌ها در نحوه استخراج مفاهیم معنایی مشارکت داده شد.

همسو با دیدگاه «ویکری و ویکری» (۱۹۸۹) اگر به مجموعه جملات موجود در یک متن بیندیشیم، می‌توانیم دریابیم که چه ساختار ارتباطی پیچیده‌ای دارد. درون جمله، واژه‌ها در طبقات نحوی جای می‌گیرند. در ورای این، جملات نیز به شیوه‌ای با یکدیگر ارتباط می‌یابند که بتوانند بحث موجود در یک متن را پیش ببرند. در نتیجه، با مجموعه‌ای از مفاهیم آشکار و پنهان در درون متن مواجه هستیم که روند ذخیره، سازماندهی و بازیابی آن را به شدت تحت الشاع خود قرار می‌دهد. در فرایند سازماندهی و بازیابی متن روش‌های مختلفی برای ارائه متن و اعمال طبقه‌بندی آن‌ها بر پایه نحوه ارائه آن وجود دارد. بنابراین، در این پژوهش ابتدا در بخش مفاهیم پایه به بررسی مفاهیم پایه‌ای ارائه متن پرداخته شده است. روش‌های کاهش ابعاد ویژگی‌ها و نحوه سازماندهی و بازیابی متن بیان شده و سپس، مقایسه‌ای بین این روش‌ها ذکر شده است. در ادامه، روش پیشنهادی پژوهش، ارزیابی روش، و در نهایت، نتیجه‌گیری و پژوهش‌های آتی ارائه شده است.

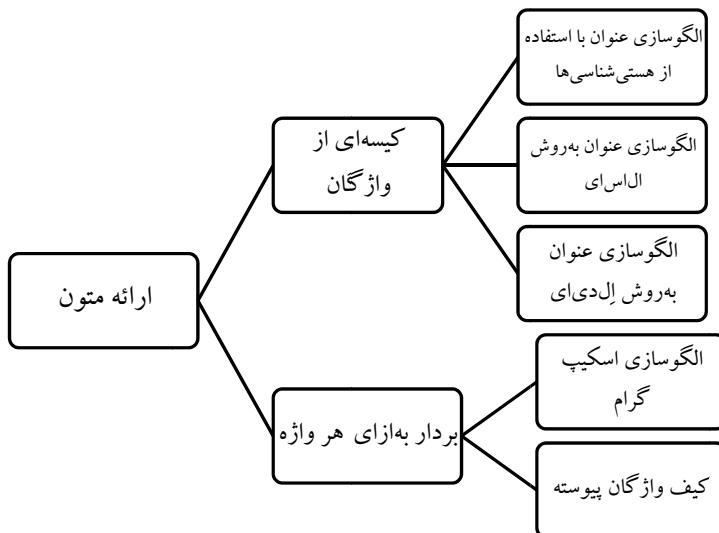
۲. مبانی نظری پژوهش

۱-۱. تبیین مفاهیم پایه در ارائه متن

یک پیکره متنی به مجموعه‌ای عظیم از اسناد متنی نسبت داده می‌شود. بزرگی یک پیکره متنی را با استفاده از تعداد واژه‌های موجود در فرهنگ لغات آن پیکره می‌سنجند. زیربنای بسیاری از کاربردهای متن کاوی، فرایند بازیابی متن است. این فرایند را می‌توان به شکل‌های مختلفی انجام داد. به طور کلی، روش‌هایی مانند روش متداول کیسه‌ای (تجمیع) از واژگان^۲ بردار به ازای هر واژه در متن، الگوسازی عنوان با استفاده از هستی‌شناسی‌ها و به کمک تجزیه نامنفی ماتریس‌ها در بازیابی متن مورد توجه قرار می‌گیرد. در این بخش به بیان جزئیات مربوط به هر کدام از روش‌های متداول یادشده پرداخته می‌شود. نمودار ۱، شمایی از روش‌های استفاده شده در ارائه متن جهت سازماندهی و بازیابی آن را نشان می‌دهد.

1. point wise mutual information

2. یک روش بازنمایی متن است که در آن هر لغت بر اساس فرکانس تکرار وزن دهی می‌گردد.



شکل ۱. شماتیک از روش‌های ارائه متن در فرایند سازماندهی دانش

۲-۲. سازماندهی و بازیابی متون به روش بردار به‌ازای هر واژه

روش بردار به‌ازای هر واژه در سال ۲۰۱۳ توسط «میکولو» و همکاران یکی از محققان گوگل ارائه شد (Mikolov et al. 2013). این روش به‌ازای هر واژه، برداری با طول کوچک تولید می‌کند. این روش مبتنی بر این نظر است که معنای یک متن یا سند با واژه‌هایی که در آن قرار دارند، بیان می‌شود (گراسمن و فریدر، ۲۰۰۴). این الگو در حقیقت الگویی پیش‌گو بوده و برای یادگیری بازنمایی‌های برداری از واژه‌ها استفاده می‌شود. هدف از روش‌های پیش‌گویانه این است که به کاوشگر اجازه می‌دهد یک ارزش ناشناخته را از یک متغیر مشخص پیش‌بینی نماید (قاضی‌زاده و خزانه‌ها ۱۳۹۵). در روش برداری فرض بر این است که بردارهای وزن-اصطلاحی^۱ مربوط به آن دسته از اسنادی که به عنوان باریط شناخته شده‌اند، شباهت‌هایی با یکدیگر دارند (به عبارت دیگر اسناد باریط به یکدیگر شبیه‌اند). افزون بر این، فرض بر آن است که اسناد بی‌ربط بردارهایی هستند که با اسناد باریط شباهتی ندارند. بر این پایه، تشکیل بردار پیش‌گو را می‌توان به دو

1. Grossman and Frieder

2. term-weight

روش کیف واژه‌های پیوسته^۱ و الگوی اسکیپ گرام^۲ انجام داد (Mikolov et al. 2013). برای افزایش دقیق این روش، مجموعه داده اولیه که برای یادگیری و آموزش الگو مورد نیاز است، حدود چند میلیارد واژه را که درون چندین میلیون سند یا متن به کار رفته، توسط مفون یادگیری عمیق طبقه‌بندی و در نهایت، سازماندهی می‌شود (Chen, Guo & Bai 2017). یادگیری و آموزش الگو، گونه‌ای از یادگیری خودکار یک الگو یا قالبی از دادگان است که به منظور فهم ماهیت اطلاعات و ساختن تصمیم معقول برای پرس‌وجوها و دادگان آتی اجرا می‌شود (قاضیزاده و خزانه‌ها ۱۳۹۵).

۲-۳. سازماندهی و بازیابی به روش کیس‌ای (تجمیعی) از واژگان معنایی

در روش تجمیعی، تعدادی از واژگان موجود در متون در یک پیکر متى به عنوان یک فرهنگ لغت در نظر گرفته می‌شود. سپس، بر اساس تعداد تکرار هر کدام از این واژه‌ها در متن، یک بردار به ازای آن متن ساخته می‌شود. در این روش، فرایند متن کاوی شامل ساختن ماتریس‌هایی از میزان فراوانی واژه‌ها در متن است. بر این پایه، دسته‌بندی استناد بر اساس این فرهنگ لغت انجام می‌شود. در شرایطی که تعداد واژه‌های موجود در فرهنگ لغت بسیار زیاد باشد، چالش‌هایی از جمله ابعاد بالای ماتریس‌های استخراج شده و یا مسئله ماتریس‌های خلوت به وجود می‌آید. بنابراین، باید به دنبال روش‌هایی برای کاهش ابعاد مسئله بود (Hotho, Paaß 2005). در این گروه از روش‌ها، در فرایند متن کاوی اغلب معنای واژه‌ها و عنوان‌های موجود در متن برای کاهش ویژگی‌ها در نظر گرفته می‌شود. فون مختلفی جهت کاهش ویژگی در این حوزه وجود دارد که می‌توان به خوشبندی واژه‌ها با استفاده از هستی‌شناسی‌ها، ویکی‌ها و همچنین الگوریتم‌های الگو‌سازی عنوان اشاره کرد. در نظر گرفتن سطح معنایی واژگان در متن و نیز معانی واژه در بافت جمله، زمینه بررسی واژه‌های چندمعنایی^۳ را فراهم می‌کند (مهراد و فلاحتی فومنی ۱۳۸۴).

1. Continues Bag of Words (CBOW)

۲. در الگوی Skip-gram به جای حدس یک کلمه، چندین کلمه حدس زده می‌شود. در این الگو یک کلمه به عنوان ورودی داده شده و دو کلمه قبل و دو کلمه بعد از آن حدس زده می‌شود.
۳. چند معنایی به حالتی اطلاق می‌گردد که در آن واژه‌ای دارای معانی متعدد اما مرتبط به هم باشد.

۴-۲. الگوسازی عنوان با استفاده از هستی‌شناسی‌ها

در روش پیشنهادی Zhao & Mao (2018) برای ارائه یک متن، پس از استخراج واژه‌های موجود در متن، گروهی از آن‌ها بر اساس فراوانی تکرار به عنوان واژه‌های پایه‌ای انتخاب شده و برای هر واژه پایه، خوش‌ای از واژه‌ها که ارتباط معنایی بین آن‌ها با استفاده از ویکی‌ها استخراج شده است، استخراج گردیده و از معیار شباهت کسینوسی به عنوان درجه عضویت فازی یک واژه به هر کدام از آن خوش‌ها جهت سازماندهی و بازیابی آن متن استفاده می‌شود. در واقع، برای هر واژه برداری از مقادیر فازی شباهت استخراج گردیده است. سپس، از طبقه‌بندی تحلیل افتراق خطی¹ برای دسته‌بندی استفاده شده است. بر این پایه، با خوش‌های واژه‌ها به ساخت مفاهیم معنایی جهت کاهش ویژگی‌های متون در راستای مواجهه با چالش‌های پیش‌گفته پرداخته می‌شود. در روش پیشنهادی Elhadad, Badran & Salama (2017) با بهره‌گیری از ساختار سلسله‌مراتبی هستی‌شناسی واژه‌هایی که با سایر دسته‌های نحوی ارتباطی ندارند، از فضای ویژگی‌ها حذف می‌گردد. در این روش، ابتدا هر متن الگوسازی می‌شود. سپس، به هر ویژگی‌ها استخراج شده، بر اساس تعداد تکرار آن در هر متن وزنی اختصاص داده می‌شود. در ادامه، با استفاده از معیارهای شباهت Meng, Huang & Gu (2013) به بررسی شباهت معنایی و نحوی واژه‌های استخراج شده پرداخته شده و تنها واژه‌هایی با میزان شباهت بیشتر انتخاب می‌گردد. این واژگان بر پایه تعداد تکرار در متن‌ها وزن‌دهی می‌شوند. همچنین، در روش پیشنهادی «مورینو-گارسیا» و همکاران به بررسی چند مجموعه داده مختلف پرداخته شد. نتایج بررسی نشان داد که صحت سازماندهی به نحوه استخراج مفاهیم مرتبط با واژه‌ها وابسته است. برای نمونه، نتایج بررسی چگونگی سازماندهی متون خبری در پژوهش آن‌ها نشان داد که با توجه به کم تکرار بودن واژه‌های کلیدی در متون خبری وجود معانی مختلفی از واژه‌ها و همچنین، مبهم بودن کاربرد برخی از واژه‌ها که دارای بیش از یک معنا هستند، روش‌های مبتنی بر هستی‌شناسی‌ها در مجموعه‌ای از متون گستره و بزرگ ناکارآمد هستند (Mouriño-García et al. 2016). بر این اساس، کاربرد هستی‌شناسی‌ها در فرایند سازماندهی و بازیابی دانش مستتر در متون وی گوناگون و متنوع با حجم بزرگ را باید با احتیاط بیشتری مورد توجه قرار داد.

1. linear discriminative analysis

۵-۲. الگوسازی عنوان به کمک تجزیه نامنفی ماتریس‌ها

در این روش به منظور شناسایی مفاهیم پنهان موجود در متون به استخراج ویژگی‌هایی جدید برای سازماندهی و بازیابی متون پرداخته می‌شود. این روش با یافتن مقادیر و بردارهای ویژه به حذف خشنه^۱ از فضای مسئله و سپس، به الگوسازی مفاهیم پنهان می‌پردازد (Arun, et al. 2010; Blei, Ng & Jordan 2003). این در حالی است که در روش تجمیعی از واژگان معنایی با اعمال وزن‌دهی ضریب واکنشی اطلاعات متقابل نقطه‌ای به تجزیه ماتریس ویژگی‌ها توجه می‌شود. در واقع، ابعاد مسئله به رخداد مفاهیم معنایی محدود خواهد شد که در هر متن، با توجه به واژگان همان متن رخ می‌دهد. از جمله نوآوری‌های روش پیشنهادی اعمال وزن‌دهی واکنشی اطلاعات متقابل نقطه‌ای نسبت به فراوانی تکرار در روش پایه تجمیعی است. این نحوه وزن‌دهی در واقع، اهمیت هر واژه را در هر متن نسبت به کل پیکره می‌سنجد و مفاهیم معنایی با توجه به چنین نحوه وزن‌دهی برای متون استخراج می‌شود. از این رو، پس از تجزیه ماتریس ویژگی‌ها به ماتریس مفاهیم و متون، یک توزیع احتمال رخداد از مفاهیم در هر متن ایجاد می‌شود.

۳. مروری بر پیشنهادات مرتبط

در زمینه کاوش متن فعالیت‌ها و نوآوری‌های زیادی در جریان است. اثری قدیمی از Salton (1989) در این زمینه وجود دارد و مرورهای بعدی و جدیدتر توسط Sievert (1996) به انجام رسیده است. Luhn (1958) از اولین کسانی بود که نقش الگوهای به کارگیری واژگان را در یافتن واژه‌هایی که موضوع متن را به نحو بهتری منعکس می‌کنند، برای مقاصد نمایه‌سازی و چکیده‌نویسی خود کار تشخیص داد. تلاش‌های جاری مربوط به کنسرسیوم وب جهانی در پیاده‌سازی وب معنایی است. وب، مجموعه‌ای از میلیون‌ها متن و سند است که هیچ سازماندهی خاصی بین آن‌ها وجود ندارد. با این حال، اسناد وبی پیوندهایی به اسناد و متون دیگر دارند که نشان می‌دهد به نوعی با یکدیگر ارتباط دارند. در واقع، کاوش در وب در بیشتر موارد کاوش واژگان یا نامدهای خاص یا ترکیبی از آن‌ها در رکوردهای موجود در وب است (میدو^۲ و همکاران ۱۹۹۲). بر این پایه، بر مبنای بررسی

1. noise

2. Meadow

متون پیشین در رابطه با کاوش واژگان، روش تجمیعی از واژگان معنایی اولین بار در سال ۲۰۰۳ توسط (Blei, Ng & Jordan 2003) ارائه شد. این روش یک شیوه بدون ناظر الگوسازی عنوان در متن است که با هدف یافتن مفاهیم معنایی پنهان متناسب با متن به کار می‌رود و در کاهش ابعاد چالش‌زای آن در مسائل مختلفی نظری تشخیص چهریزه‌ها و طبقه‌بندی متون کاربرد دارد (Chien, Lee & Tan 2018). در صورت کاربرد این روش در تحلیل متن فرض می‌شود که هر متن دارای ترکیبی از چند مفهوم پنهان است و هر مفهوم پنهان نیز دارای توزیع احتمالی روی واژه‌های آن پیکره است (Blei, Ng & Jordan 2003; Wilson Chew 2010 &). بنابراین، واژه‌های مشاهده شده در هر مفهوم پنهان متغیرهای چندجمله‌ای هستند و مفاهیم متناسب نیز متغیرهای «الدی‌ای» هستند (Chien, Lee & Tan 2018). در این روش با استفاده از توزیع دریکله و توزیع چندجمله‌ای به تعیین میزان تأثیر هر واژه از پیکره در هر مفهوم پنهان و همچنین، توزیع احتمال رخداد مفاهیم پنهان در متون پرداخته می‌شود. بر این پایه، وزن چندجمله‌ای هر واژه در هر مفهوم پنهان و همچنین وزن هر مفهوم در هر متن باید در نظر گرفته شود. ایده اصلی در وزن دادن به واژگان در کاوش متن، افزایش توان تمایز واژه از طریق تعیین اهمیت نسبی آن در پرسش است. این گونه وزن‌ها برای رتبه‌بندی متون از نظر شباهت به یک پرسش یا شباهت به متن یک سند دیگر نیز کاربرد دارد (میدو و همکاران ۱۹۹۲). بر این اساس، اغلب برای محاسبه راستی آزمایی حداقلی و قوع یک مفهوم در متن از الگوریتم‌های شیوه‌سازی استفاده می‌شود (Griffiths Steyvers 2004 &). با این حال، این که معنای واژه‌ای را ثبت کیم، به این مفهوم نیست که این واژه همه جا همان معنا را خواهد داشت، زیرا یک واژه در هر جا می‌تواند معنای متفاوتی داشته باشد و خواندن‌گان نیز ممکن است در همه جا تفاوت‌ها را تشخیص ندهند. «چن» و همکاران در پژوهشی بیان کردند که با توجه به کم‌تکرار بودن کلمات کلیدی در متن‌های خبری و وجود معانی مختلف از واژه‌ها و همچنین، مهم بودن کاربرد برخی از واژه‌ها که دارای بیش از یک معنا هستند، از الگوریتم «الدی‌ای» برای شناسایی مفاهیم موجود در متن جهت سازماندهی متون استفاده کردند (Chen et al. 2016). در روش پیشنهادی آنان با در نظر گرفتن ارتباط بین عنوان یک متن و واژه‌های موجود در آن، مقدار احتمال وقوع یک موضوع برای یک متن محاسبه و از نتیجه آن برای بهتر کردن نتایج سازماندهی و بازیابی استفاده شده است. در واقع، ایده اصلی آن‌ها ترکیب اطلاعات مربوط به موضوع متن و فراوانی تکرار واژگان موجود در آن متن بود. این کاهش با

انتخاب واژه‌هایی از متن انجام می‌گردد که مرتبط با عنوان آن متن هستند. همسو با دیدگاه «میدو» و همکاران (۱۹۹۲)، یکی دیگر از روش‌های به کار رفته در حوزه متن کاوی و سازماندهی دانش وبی، روش خوشه‌بندی متونی است که دارای ارزش‌ها و خصوصیت‌های مشابهی هستند یا توزیع فراوانی واژگان آن‌ها به یکدیگر مشابهت دارد. بررسی پیشینه‌های مرتبط با به کار گیری این روش نشان می‌دهد که مطالعات اولیه در این حوزه توسط «بونر» مطرح شده است. در این روش او ماتریسی از خصوصیات یک رکورد تدوین کرده و سپس، ماتریس دیگری تهیه نمود که نشان‌دهنده مشابهت رکوردهای بازیابی شده در ماتریس اول بود. در ماتریس سوم نیز تعداد خوشه‌ها را می‌توان مشخص کرد. سرانجام از بین فهرست خوشه‌های برگزیده، زیرمجموعه‌ای که بهترین تناسب را با کاربرد مورد نظر دارد، می‌توان انتخاب نمود (Bonner 1964). پس از مطالعات انجام شده توسط «بونر»، سایر پژوهشگران الگوریتم‌های متعددی را برای ایجاد خوشه‌ها طراحی و پیشنهاد دادند (Miyamoto 1990).

همان‌طور که مشاهده می‌شود، نمونه‌های محدود انجام شده در پژوهش‌های پیشین پس از فاز پیش‌پردازش، حد بالا و پایینی از فراوانی تکرار واژه برای انتخاب ویژگی‌های اولیه را در نظر می‌گیرند و واژگانی را که دارای فراوانی تکرار کمتر از حد آستانه پائین و بیشتر از حد آستانه بالا باشند، از مجموعه فرهنگ لغات حذف می‌کنند. همچنین، از فراوانی تکرار واژه‌ها به عنوان وزن مؤثر آن‌ها استفاده شده و دلیل حذف واژه‌ها به علت لحاظ نشدن این مسئله در الگوریتم «ال‌دی‌ای» است. در برخی از پژوهش‌های پیشین (مانند پژوهش Chen, Guo & Bai 2017; Wilson & Chew 2010; Yang et al. 2017) پژوهشگران نشان دادند در صورتی که از وزن‌دهی متناسب استفاده شود، نیازی به حذف چنین واژه‌هایی از مجموعه فرهنگ لغات هر متن نیست و می‌توان با وزن‌دهی متناسب از حذف واژه‌هایی که ممکن است از وزن مطلوبی برخوردار باشند، جلوگیری کرد. همچنین، برخی از پژوهش‌های مرتبط دیگر نیز نشان از به کار گیری الگوریتم‌های خوشه‌بندی به منظور سازماندهی و بازیابی دانش متون دارد. بر این اساس، بررسی پژوهش‌های پیشین در این زمینه نشان می‌دهد که مطالعات انجام شده در این حوزه موضوعی چندان گسترده نیست و با توسعه و آزمون سایر روش‌های پیشنهادی در متن‌های مختلف وبی به احتمال بتوان روند سازماندهی دانش آشکار و پنهان موجود در متون وبی را تسهیل نمود. از این رو، پژوهش حاضر در تلاش است که با حذف یا تعدیل چالش‌های پیش‌گفته در راستای سازماندهی

و بازیابی دانش مندرج در متون ویی، روش‌های جدیدی معرفی و پس از پیش‌پردازش، استخراج ویژگی‌ها، یادگیری و آموزش الگو را انجام داده و در نهایت، به آزمون و ارزیابی روش پیشنهادی پردازد. در ادامه، هر کدام از مراحل ذکر شده به تفکیک بیان می‌گردد.

۴. روش پژوهش

در این بخش به بیان مراحل مختلف روش پژوهش پرداخته شده است. روش پیشنهادی مورد مطالعه در پژوهش شامل مراحل پیش‌پردازش، استخراج ویژگی، تشکیل ماتریس واژگانی، فاز آموزش الگو و طبقه‌بندی است. نمودار ۲، شما بیان از روش پیشنهادی پژوهش را نشان می‌دهد.



شکل ۲. شما بیان از مراحل روش پیشنهادی پژوهش

از آنجا که روش پیشنهادی پژوهش حاضر برای پاسخ‌گویی به نیاز محققان در زمینه تحلیل عظیم داده‌ها سازمان یافته و تا جایی که می‌دانیم مجموعه داده خبری استانداردی با حجم عظیم به زبان فارسی موجود نیست، به منظور طراحی، پیکره عظیمی از داده‌های متنی ۲۰ گروه خبری خارجی که توالی انتشار منظمی داشتند، انتخاب شد و کل داده‌های متنی منتشرشده آن‌ها در فضای وب، پیکره متنی پژوهش را تشکیل داد. جدول ۱، ویژگی‌های مجموعه داده‌های گروه‌های ۲۰ گانه خبری را نشان می‌دهد. این مجموعه داده دارای حدود ۲۰۰۰۰ سند خبری از ۲۰ گروه خبری مختلف است و از مجموعه داده‌های متدالو در زمینه متن کاوی به شمار می‌رود. اکثر پژوهش‌هایی که بهنوعی روشی جدید در زمینه سازماندهی دانش ارائه داده‌اند، از این مجموعه داده استفاده نموده‌اند. در ادامه، روند اجرای پژوهش در قالب روش پیشنهادی (شکل ۲) به صورت تجربی مورد بررسی قرار می‌گیرد.

۵. تبیین مراحل اجرای روش پیشنهادی پژوهش

۵-۱. پیش‌پردازش

اولین گام در فرایند متن کاوی، فاز پیش‌پردازش است. از جمله مراحل متدالو در

فاز پیش‌پردازش شناسایی توکن‌ها، حذف کلمات توقف و حروف اضافه است (Chen, 2018; Chien, Lee & Tan 2018; Zhao & Mao 2018; Guo & Bai 2017). در این مرحله جهت آماده‌سازی متن، در هر متن ابتدا واژه‌ها از یکدیگر جداسازی و توکن‌ها شناسایی می‌شوند؛ حروف اضافه و کلمات توقف حذف شده و در نهایت، واژه‌های باقی‌مانده، فرهنگ‌گ لغات کل پیکرۀ متون مورد مطالعه را تشکیل می‌دهند. این فرایند در پژوهش داده‌های متنی به دست آمده از گروه‌های خبری مورد مطالعه نیز به انجام رسید.

۲-۵. استخراج ویژگی

از جمله روش‌های متداول برای کاهش ابعاد ویژگی‌ها روش «الدی‌ای» است (Griffiths & Steyvers 2004). این الگوریتم، تعداد متون موجود در پیکره را به صورت یک توزیع احتمال دریکله رخداد k مفهوم پنهان در آن الگوسازی می‌کند و واژه‌های پیکره نیز دارای توزیع چندجمله‌ای روی مفاهیم پنهان هستند. همان‌طور که پیش‌تر بیان شد، روش «الدی‌ای» به واژگان موجود در یک متن وی با توجه به فراوانی تکرار آن‌ها اهمیت داده و آن‌ها را با توجه به فراوانی تکرار در مفاهیم توزیع می‌کند. به همین دلیل، واژه‌هایی با فراوانی تکرار بسیار بالا و همچنین واژه‌های کم تکرار از این مجموعه حذف می‌شوند. در صورتی که از وزن‌دهی مناسبی استفاده شود، می‌توان از حذف واژه‌های دارای ارزش جلوگیری کرد و در واقع، واژه‌ها را دارای یک ضریب تأثیر در نظر گرفت که در توزیع شدن آن‌ها بین مفاهیم مؤثر باشد. میزان اطلاع یک واژه در پیکره را با استفاده از آنتروپی آن می‌سنجند. بعبارت دیگر، هر چه آنتروپی بیشتر باشد، واژه دارای بار اطلاعاتی کمتری در پیکره است. حال، رخداد واژه‌ای از پیکره در یک سند را در نظر می‌گیریم. آنچه به واژه در سند ارزش می‌بخشد، میزان اطلاع آن واژه از موضوع آن سند است. بنا بر اصل نظریه اطلاعات و نظریه احتمال شرطی، میزان اطلاعی که یک واژه از یک سند در بر دارد، با استفاده از معیار واکشی اطلاعات متقابل رخداد آن واژه در سند نسبت به کل پیکره متن سنجیده می‌شود. یک واژه در یک پیکره متنی را می‌توان یک رویداد در نظر گرفت که در کنار واژه‌های دیگر در یک سند متنی بخشی از اطلاع راجع به آن سند را تشکیل می‌دهد. بنابراین، می‌توان از معیار واکشی اطلاعات متقابل نقطه‌ای جهت

محاسبه ارزش واژه در سند استفاده کرد (Wilson & Chew 2010). معیار واکنشی اطلاعات متقابل با محاسبه مقدار متوسط اطلاعات متقابل نقطه‌ای به بررسی میزان وابستگی متقابل بین دو متغیر تصادفی می‌پردازد؛ در حالی که واکنشی اطلاعات متقابل نقطه‌ای به محاسبه میزان اطلاع واژه به‌ازای رخدادش در سند می‌پردازد. این است که از این معیار به منظور وزن‌دهی به واژه‌ها در سند استفاده شد.

الگوریتم «الدی‌ای» با استخراج ویژگی‌هایی جدید تحت عنوان مفاهیم معنایی، نقش به‌سزایی در کاهش ابعاد فضای مسئله دارد. بر طبق مطالب پیش‌گفته، در صورتی که هر مفهوم را یک سبد در نظر بگیریم که دارای توب‌هایی با رنگ‌های مختلف (هر رنگ به‌ازای هر لغت) و اندازه‌های مختلف است، توزیع شدن توب‌ها در هر کدام از سبد‌ها با توجه به اندازه آن‌ها (که توسط معیار واکنشی اطلاعات متقابل تعیین شد) و ضریب چندجمله‌ای انجام می‌پذیرد. بنابراین، روابط یادشده به شکل زیر بازنویسی و به‌اجرا درآمد:

$$p(z_{ij} = k \mid \emptyset^k) = \frac{w(x_i) N_{(.)k}^{-ij} + \beta}{\sum_w m(w) N_{(.)k}^{-ij} + W_\beta}$$

$$p(k \mid d_j) = \frac{\sum_w m(w) N_{(.)jk}^{-ij} + \alpha}{\sum_w m(w) N_{(.)k}^{-ij} + T_\alpha}$$

$w(x_i)$ وزن لغت x_i است که در ضریب چندجمله‌ای تأثیر گذاشته و بر اساس رابطه زیر محاسبه می‌گردد:

$$PMI(x_i, d) = -\log_2 \frac{p(x_i \mid d)}{p(x_i)}$$

$$\frac{(word \ x_i \ in \ document \ d)}{\#(word \ x_i)}$$

۳-۵. سازماندهی متون

خروجی فرایند استخراج ویژگی‌ها تعیین مفاهیم پنهان است. از آنجا که در ماتریس متون، مفاهیم هر متن دارای برچسب است و به شکل یک توزیع احتمال روی تعدادی

مفهوم بازیابی شده است، متونی که دارای توزیع‌های مشابهی روی مفاهیم باشند، به احتمال دارای برچسب مشابه نیز هستند. «هینز» برچسب‌گذاری متون مشابه را از زمرة ویژگی‌های میان کنش‌پذیری نظام‌های بازیابی می‌داند (۲۰۰۴). بنابراین، برای طبقه‌بندی می‌توان از معیار فاصله «کولبک‌لییر» که فاصله دو توزیع احتمال در بین متون مشابه را می‌سنجد، استفاده کرد (Wang, Kulkarni & Verdu 2009). باید این واقعیت را پذیرفت که ساختارهای لغوی با وجود ارتباط داشتن با یکدیگر، جدا از هم به نظر می‌رسند؛ لیکن تعیین ارتباط آن در قالب نظام‌های بازیابی دارای پیچیدگی‌های روان‌شناسی و زبانی است. در این پژوهش نیز برای مواجهه با این چالش از الگوریتم زیر استفاده شد:

$$KLD(p, q) = p * \log_2\left(\frac{p}{q}\right)$$

۴-۴. آزمون شبیه‌سازی

آزمایش شبیه‌سازی به منظور بررسی قابلیت سازماندهی و بازیابی مجموعه‌ای از متون در یک پیکره بزرگ طراحی می‌شود. در این پژوهش از مجموعه داده‌های ۲۰ گروه خبری وبی و اخبار منتشرشده آن‌ها تحت وب استفاده شد. این مجموعه داده دارای پیکره‌ای به بزرگی ۱۲۸۰۰۰ واژه و ۲۰۰۰۰ متن بود. داده‌های به کاررفته در پژوهش حاضر را می‌توان به عنوان یکی از بزرگ‌ترین پیکره‌های متنی خبری استاندارد تحت وب برشمرد. جدول ۱، ویژگی‌های این مجموعه داده را نشان می‌دهد.

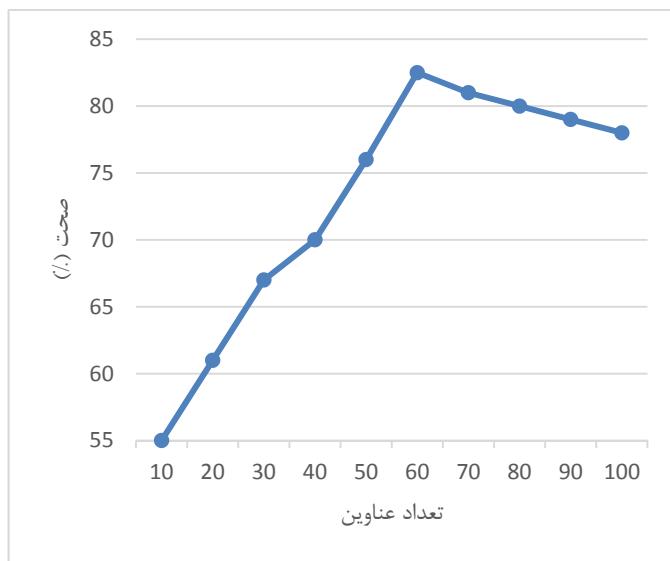
جدول ۱. ویژگی‌های مجموعه داده ۲۰ گروه خبری مورد مطالعه

گروه	تعداد اسناد
alt.atheism	1000
comp.graphics	999
comp.os.ms-windows.misc	1000
comp.sys.ibm.pc.hardware	1000
comp.sys.mac.hardware	1000
talk.politics.mideas	1000
comp.windows.x	1000
misc.forsale	1000

تعداد اسناد	کلمه
1000	rec.autos
1000	rec.motorcycles
1000	rec.sport.baseball
1000	talk.politics.guns
1000	talk.religion.misc
1000	rec.sport.hockey
1000	sci.crypt
1000	sci.electronics
1000	sci.med
1000	sci.space
997	soc.religion.christian
1000	talk.politics.misc

۵-۵. تنظیم پارامترهای «الدی‌ای»

بر مبنای مطالب پیش‌گفته، قبل از اعمال روش «الدی‌ای» باید در خصوص تعداد مفاهیم پنهان تصمیم‌گیری شود. می‌توان تعداد مفاهیم موجود را با استفاده از آزمون و خطای مقایسه دقت روش در هر تکرار محاسبه کرد. شکل ۳، دقت روش پیشنهادی را برای مقادیر مختلف واژه که تعداد مفاهیم پنهان است، آزموده است.

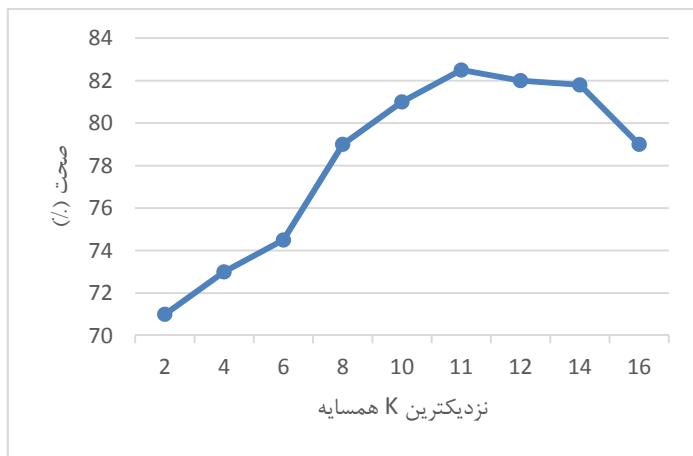


شکل ۳. صحت طبقه‌بندی به ازای تعداد عنوان‌ها

نتایج آزمایش این روش نشان داد که در $k = 60$ ، بهترین دقیق خود را که $82/5$ درصد است، کسب نموده است. دومین پارامتر در استفاده از الگوریتم استخراج مفاهیم پنهان، انتخاب تعداد اصطلاح‌های موجود در هر مفهوم است. روش‌هایی که از این الگوریتم و این مجموعه داده استفاده کرده‌اند، اغلب از ۱۰ اصطلاح پرارزش یک عنوان استفاده و تعداد مفاهیم را بر اساس تعداد ویژگی‌های اولیه انتخاب کرده‌اند.

۶- تنظیم پارامتر الگوریتم

در الگوریتم نزدیک‌ترین k همسایه، تنظیم پارامتر k که تعداد شبیه‌ترین همسایه است، اغلب با آزمایش تنظیم می‌شود. شکل ۴، نشان‌دهنده دقیق روش در مقادیر مختلف k است. نتایج نشان داد که در $k = 12$ روش، بیشترین دقیق را کسب نموده است.



شکل ۴. دقت طبقه‌بندی به‌ازای مقادیر مختلف از K همسایه در الگوریتم KL-KNN

۷-۵. ارزیابی

در بخش قبل، ویژگی‌های مجموعه داده و آزمایش‌های مربوط به تنظیم پارامترهای روش به کاررفته در پژوهش بیان شد. در این بخش، ابتدا به بررسی دقت طبقه‌بندی روش پیشنهادی بر هر کدام از دسته‌های مجموعه داده متنی تحت وب از ۲۰ گروه خبری پرداخته می‌شود. سپس، به مقایسه دقت KL-KNN با سایر دسته‌بندها و روش‌هایی که از «الدی‌ای» برای استخراج مفاهیم معنایی استفاده کرده‌اند، پرداخته و در نهایت، مقایسه دقت روش با سایر روش‌های ذکر شده در بخش مفاهیم پایه بیان می‌گردد. به باور «پائو» ارزیابی به معنای داوری درباره ارزشمندی و شایستگی موضوع مورد ارزیابی است و باید امور و عملکرد نظام سازماندهی و بازیابی مورد توجه قرار گیرد (۱۹۸۹). ارزیابی روش‌ها بر اساس ویژگی دقت^۱ که با استفاده از رابطه زیر محاسبه می‌شود، انجام گرفته است. در واقع، دقت، حاصل تقسیم تعداد اسنادی که به درستی دسته‌بندی شده‌اند بر تعداد کل اسناد است. اسنادی که به درستی دسته‌بندی شده‌اند، شامل دو دسته است: مثبت درست^۲ (روش

۱. KNN یکی از ساده‌ترین الگوریتم‌های داده کاوی و طبقه‌بندی است. این الگوریتم عملیات طبقه‌بندی را به صورت ساده انجام داده و نتایج قابل اطمینانی به عنوان پیش‌بینی بر می‌گرداند.

2. accuracy

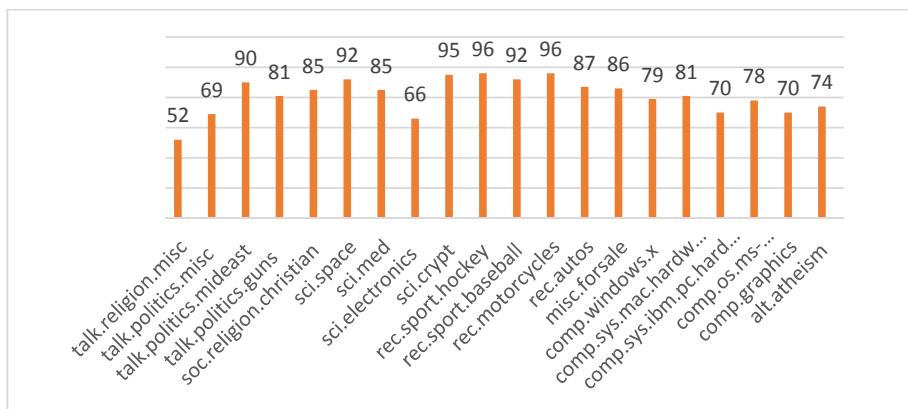
3. true positive

به درستی آن را در دسته‌ای که به آن تعلق داشته، جا داده است) و منفی درست^۱ (روش به درستی آن را در دسته‌ای که به آن تعلق نداشته، جا نداده است).

$$Accuracy = \frac{tp + tn}{n}$$

۶. ارزیابی دقت روش پیشنهادی

همان‌طور که پیش‌تر اشاره شد، مجموعه داده پژوهش متشكل از ۲۰ گروه خبری دارای ۲۰ دسته مختلف است که در این بخش به بررسی دقت الگوریتم هر دسته پرداخته شده است. پس از فاز پیش‌پردازش به استخراج توزیع احتمال رخداد هر کدام از مفاهیم معنایی روی هر متن پرداخته شد و با فرض داشتن یک فضای توزیع احتمال، از معیار «کولبک لیئر» به عنوان میزان شباهت در الگوریتم طبق‌بند KNN استفاده گردید. شکل ۵، دقت روش پیشنهادی در هر کدام از دسته‌های مجموعه داده گروه‌های خبری را نشان می‌دهد.



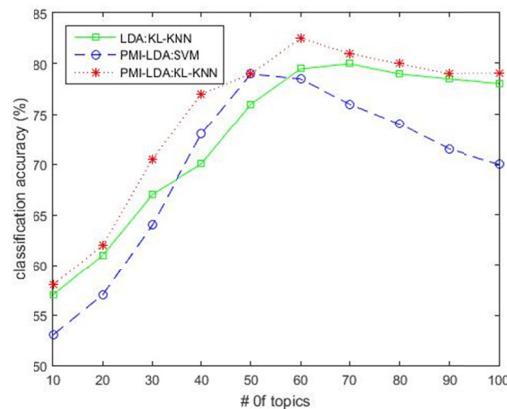
شکل ۵. دقت روش پیشنهادی بر هر کدام از دسته‌ها در مجموعه داده گروه‌های خبری

۶-۱. مقایسه دقت KL_KNN با سایر دسته‌بندها

در این بخش به مقایسه دقت روش پیشنهادی با روش‌هایی که از «الدی‌ای» به عنوان روش کاهش ویژگی استفاده نموده‌اند، می‌پردازیم. این روش‌ها اغلب از طبقه‌بند ماشین

1. true negative

بردار پشتیبانی^۱ (Chen et al. 2016; Pereira et al. 2018; Yang et al. 2017) یا طبقه‌بند بیز ساده^۲ (Kim, Kim & Jinseog 2016; Mouriño-García et al. 2016) به عنوان طبقه‌بند استفاده نموده‌اند. در روش پیشنهادی پژوهش حاضر از الگوریتم KL-KNN به عنوان طبقه‌بند استفاده شده است. در شکل ۶، دقت الگوریتم پایه «الدی‌ای» و الگوریتم پیشنهادی «الدی‌ای» واکنش اطلاعات متقابل نقطه‌ای^۳ که در هر دو ویژگی‌های جدید استخراج شده توسط طبقه‌بند KL-KNN طبقه‌بندی شده مقایسه شده‌اند. نتایج نشان می‌دهد زمانی که از معیار وزن‌دهی KL-KNN کسب شده است. همچنین، در شکل ۶، دقت الگوریتم «الدی‌ای» و واکنش اطلاعات متقابل نقطه‌ای با طبقه‌بندهای KL-KNN و ماشین بردار پشتیبانی مقایسه شده است. نتایج نشان می‌دهد که نظریه دسته‌بندی داده‌ها با استفاده از KL-KNN در یک فضای توزیع احتمالی نتایج بهتری نسبت به روش خطی ماشین بردار پشتیبانی کسب نموده است.



شکل ۶. مقایسه دقت الگوریتم با طبقه‌بند ماشین بردار پشتیبانی و KL-KNN

در پژوهش‌های Chen et al. (2016) و Chen & Li (2016) از دسته‌بند ماشین بردار پشتیبانی جهت طبقه‌بندی داده‌ها استفاده شد. نتایج روش پیشنهادی پژوهش حاضر نشان می‌دهد

۱. ماشین بردار پشتیبانی یا (SVM) Support vector machine یکی از روش‌های یادگیری با نظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. مبنای کار این طبقه‌بند دسته‌بندی خطی داده‌هast و جزو الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود.

۲. به‌طور ساده، طبقه‌بند بیز ساده (naive bayes) روشی برای دسته‌بندی پدیده‌ها، بر پایه احتمال وقوع یا عدم وقوع یک پدیده است.

3. Point wise Mutual Information-Latent Dirichlet Allocation -PMI-LDA

که طبقه‌بندی با استفاده از معیار «کولبکلیسر» نتایج بهتری را بر مجموعه داده گروه‌های خبری مورد مطالعه کسب نموده است. این امر بیانگر این مطلب است که دسته‌بندی داده‌های پژوهش با استفاده از الگوی توزیع احتمال آن‌ها حول مفاهیم معنایی دقت بهتری نسبت به دسته‌بندی خطی با ماشین بردار پشتیبانی کسب نموده است.

۲-۶. مقایسه دقت روش پیشنهادی با سایر روش‌ها

در بخش مفاهیم پایه، دسته‌بندی انواع روش‌های مرتبط با طبقه‌بندی متن ارائه شد. در این بخش به مقایسه دقت روش پیشنهادی با روش‌های بیان‌شده در بخش مفاهیم پایه پرداخته شده است. جدول ۲، مقایسه‌ای بین دقت روش‌های مختلف و همچنین، روش پیشنهادی پژوهش بر مجموعه داده وی گروه‌های خبری پژوهش را نشان می‌دهد. بر اساس نتایج آزمایش‌ها، مشاهده می‌شود که دقت روش پیشنهادی نسبت به برخی روش‌ها، که در بخش مفاهیم پایه بیان شده، بهتر شده است. در واقع، دقت روش نسبت به روش‌ایی که از هستی‌شناسی‌ها و ویکی‌ها برای کاهش ویژگی استفاده نموده‌اند (Chakraverty et al. 2015; Mouríño-García et al. 2016; Zhao & Mao 2018 وزن‌دهی بدون کاهش ویژگی فرایند سازماندهی و بازیابی را انجام داده‌اند (Chen et al. 2016)، بهبود داشته است. همچنین، روش پیشنهادی پژوهش دارای دقتی مشابه با روش‌هایی است که از الگوی مخلوط دریکله برای الگوسازی مفاهیم پنهان استفاده کرده‌اند (Chien et al. 2018). این روش دارای پیچیدگی محاسباتی بسیار بالایی است و نیازمند دقت در یافتن تعداد مخلوط‌های دریکله است؛ در حالی که روش پیشنهادی پژوهش با اعمال وزن‌دهی متفاوت بر الگوریتم پایه «الدی‌ای» دارای دقت مشابه یا بالاتری با این روش است. افزون بر این، روش پیشنهادی پژوهش نسبت به روش‌هایی مانند پژوهش (Yang et al. 2017) که از فنون یادگیری عمیق و الگوی بردار بهمازای هر واژه استفاده کرده‌اند، دقت مشابهی را کسب نمود. این مسئله اهمیت روش وزن‌دهی و به کارگیری روش کاهش ابعاد نسبت به سایر روش‌های پیچیده را نشان می‌دهد. در واقع، ویژگی مهم روش پیشنهادی پژوهش اعمال وزن مؤثر توزیع واژه‌ها در مفاهیم بر اساس میزان اطلاع آن‌ها از موضوع سند، نسبت به الگوریتم پایه «الدی‌ای» است و همچنین با استفاده از دسته‌بند KNN-CL به سازماندهی و بازیابی مفاهیم بر اساس نحوه توزیع احتمال آن‌ها حول هر طبقه پرداخته شده است. روش پیشنهادی (Gupta, Kumar & Pant 2018) با در نظر گرفتن چالش عظیم

داده‌ها، پیاده‌سازی روش خود را در بستر محیط توزیع شده «هادوپ»^۱ انجام داده است. ویژگی پردازش موازی و روش توزیع داده‌ها در این محیط سبب افزون شدن دقت این روش نسبت به روش پیشنهادی گردیده است.

جدول ۲. مقایسه دقت روش پیشنهادی پژوهش با سایر روش‌های سازماندهی و بازیابی متون وی

ردیف نام	روش سازماندهی	سال	روش طبقه‌بندی	صحت
۱	تجمیعی از واژه‌ها - فازی	۲۰۱۵	Fuzzy BOW +wiki	ماشین بردار پشتیبان ۷۵ در صد
۲	زنگیره‌ای از لغات زمینه‌ای واژه‌ها	۲۰۱۵	بهبودی بر تجمیعی از TF-IDF-RCF + ماشین بردار پشتیبان (بخشی از پیکره)	در صد ۹۰
۳	تجمیعی از مفاهیم زمینه‌ای برای طبقه‌بندی بیزی	۲۰۱۶	LSA	طبقه‌بند بیزی ۷۵ در صد
۴	تجمیعی از مفاهیم معنایی دریکله	۲۰۱۶	مفاهیم معنایی	LDA+SVM در صد ۹۴ (بخشی از پیکره)
۵	تجمیعی از مفاهیم معنایی	۲۰۱۷	Skip-gram + برچسب اسناد	شبکه عصبی عمیق ۸۲/۳ در صد
۶	توزیع مخلوط دریکله برای الگوسازی مفاهیم معنایی	۲۰۱۷	مفاهیم معنایی	مخلوط دریکله نظارت شده ۸۲ در صد
۷	تجمیعی از واژه‌ها وزن‌دهی بر بهبود یافته BOW اساس چکالی	۲۰۱۷	BOW	ماشین بردار پشتیبان ۷۹ در صد
۸	طبقه‌بندی متن در محیط توزیع شده	۲۰۱۸	BOW	طبقه‌بند بیزی در محیط هادوپ ۸۸/۸ در صد
۹	روش پیشنهادی	۲۰۱۸-۲۰۱۷ در صد ۸۲/۵	تجمیعی از مفاهیم معنایی وزن‌دهی شده همسایه با معیار واگرایی کولبک لیبلر	طبقه‌بند نزدیک ترین k بر اساس اطلاعات متقابل نقطه‌ای

۷. بحث و نتیجه‌گیری

در این پژوهش ابتدا به مرور گروهی از روش‌های مختلف سازماندهی و بازیابی متون پرداخته شد و ویژگی‌های هر گروه بیان گردید. از هر کدام از این روش‌ها می‌توان جهت

1. Hadoop

سازماندهی و بازیابی متون مبتنی بر وب استفاده کرد. از جمله مشکلات موجود در تمامی این روش‌ها، بالا بودن تعداد ویژگی‌ها در مسئله سازماندهی متن است. از این رو، در اینجا به مطالعه الگوریتم «الدی‌ای» به عنوان یک روش احتمالی در تجزیه غیرمنفی ماتریس‌ها جهت کاهش فضای ویژگی‌ها تمرکز گردید. در این الگوریتم تعدادی از ویژگی‌های متون مورد مطالعه که دارای فراوانی تکرار کم و یا بیشتر از حد آستانه هستند، حذف می‌گردد که ممکن است در این بین کلماتی که دارای نقش مهمی هستند نیز حذف شوند. همچنین، از معیار فراوانی تکرار واژگان در پیکره متنی به عنوان وزن آن واژه استفاده می‌گردد؛ بدون این که به درجه اهمیت آن واژه در متن توجه شود. بنابراین، از آنجا که انتخاب مجموعه ویژگی‌های هر متن نقش به‌سزایی در دقت الگوریتم‌های سازماندهی و بازیابی محتوای آن دارد، در این پژوهش یک روش وزن‌دهی متفاوت با روش پایه در الگوریتم «الدی‌ای» برای سازماندهی و بازیابی متون مورد نظر در پژوهش (گروه‌های خبری) استفاده شد. در روش پیشنهادی، پس از فاز پیش‌پردازش، که در آن تنها حروف اضافه و واژه‌های توقف حذف می‌شوند، سایر واژگان متن حفظ می‌گردد. وزن‌دهی با هدف تأثیر دادن میزان اهمیت هر واژه در متن که با معیار واکشی اطلاعات متقابل نقطه‌ای محاسبه گردید و همچنین، فراوانی تکرار آن در پیکره انجام شد. نتایج آزمایش‌ها نشان داد که زمانی که از معیار واکشی اطلاعات متقابل نقطه‌ای در الگوریتم «الدی‌ای» استفاده شود، دقت سازماندهی و بازیابی محتوا به گونه‌ای محسوس بهبود می‌یابد. برای دسته‌بندی ماتریس‌متون و مفاهیم استخراج شده توسط الگوریتم «الدی‌ای» و واکشی اطلاعات معیار، از طبقه‌بند KNN بر اساس معیارهای فاصله‌ای استفاده شد. این دسته‌بند با استفاده از معیار KLD فاصله دو توزیع احتمال رخداد مفاهیم معنایی در هر متن را با یکدیگر سنجید. بر پایه یافته‌های پژوهش، نتایج نشان داد که این نحوه سازماندهی و بازیابی محتوای متن معیار خوبی برای سازماندهی و بازیابی سایر متون تحت وب بر اساس موضوع آنها با توجه به احتمال رخداد مفاهیم مختلف در آنها، نسبت به سایر روش‌های سازماندهی و بازیابی محتوا مانند دسته‌بند ماشین بردار پشتیبانی (SVM) است.

همسو با دیدگاه «ویکری و ویکری» (۱۹۸۹) با توجه به اهمیت وزن‌دهی مناسب واژگان که مورد تأکید پژوهش نیز است، سازمان معناشناختی واژگان می‌تواند به شکلی مفید با یکدیگر در راستای وزن‌دهی مطلوب واژه‌ها و نشانه‌های متنی در تعامل باشند. تمام عناصر طراحی شده در هر الگوی ذخیره، سازماندهی و بازیابی در ابتدا با زبان بیان می‌شود. از این

رو، زبان‌شناسی نیز می‌تواند در تمامی زمینه‌های چالش برانگیز مورد نظر پژوهش بصیرت لازم را ایجاد نماید. چالش بزرگ پیش رو این است که محدودیت‌های ساختارهای معنایی نظام‌های بازیابی همواره نمی‌تواند مطابق با نیازهای پرسشگران گوناگونی تنظیم گردد. با این حال، توسعه پژوهش‌هایی از این دست می‌تواند تسهیل کننده حل چالش‌هایی مانند تعدد ویژگی‌های متنی یا محدودیت‌های ماتریس ویژگی‌ها در راستای سازماندهی و بازیابی مطلوب‌تر داشت آشکار و پنهان در متون عظیم وب‌پایه باشد. این پژوهش به عنوان نمونه‌ای کوچک به منظور به تصویر کشیدن کارکردهای متن کاوی در راستای سازماندهی و بازیابی دانش منتشر شده در محیط وب طراحی گردید. بر این پایه، با توجه به قابلیت‌های انجام و تکرار پژوهش در محیط‌های مشابه پیشنهاد می‌گردد که از روش‌های به عنوان در این پژوهش در الگوسازی و بازنمایی دانش در محیط‌های وب‌پایه از قبیل امور بانکی، متن کاوی برای مدیریت مؤسسات آموزشی، مدیریت بهینه وب‌سایت‌ها، مدیریت دانش، بررسی کتابخانه‌های دیجیتال، فرایندهای آموزش عالی، امور پژوهشی و تجاری و ... نیز استفاده شود. این امر نه تنها منجر به مقایسه و بازآزمون روش پیشنهادی پژوهش حاضر می‌گردد، بلکه زمینه غنای ادبیات نظری و پژوهش‌های عملیاتی بیشتر در این حوزه را با رویکردی بین رشته‌ای در پی خواهد داشت.

فهرست منابع

- پائو، میراندالی. ۱۹۸۹. مفاهیم بازیابی اطلاعات. ترجمه اسدآ... آزاد و رحمت... فتاحی. ۱۳۸۰. مشهد: دانشگاه فردوسی مشهد.
- قاضی‌زاده، حمید، و مهدیه خزانه‌ها. ۱۳۹۵. داده کاوی در علم اطلاعات و دانش‌شناسی مفاهیم و کاربرد. تهران: چاپار، اساطیر پارسی.
- گرامسن، دیوید، و افیر فریدر. ۲۰۰۴. بازیابی اطلاعات: الگوریتم‌ها و روش‌های اکتشافی. ترجمه جعفر مهراد و سارا کلینی. ۱۳۸۴. مشهد: انتشارات کتابخانه رایانه‌ای؛ شیراز: کتابخانه منطقه‌ای علوم و تکنولوژی.
- مهراد، جعفر، و محمدرضا فلاحتی فومنی. ۱۳۸۴. معناشناسی و بازیابی اطلاعات: هفت گفتار. شیراز: کتابخانه منطقه‌ای علوم و تکنولوژی.
- میدو، چالز تی،، برت آر. بویس، دونالد اچ. کرفت، و کارول باری. ۱۹۹۲. نظام‌های بازیابی اطلاعات متنی. ترجمه نجلا حریری. ۱۳۹۰. تهران: چاپار.
- ویکری، برایان، و الینا ویکری. ۱۹۸۹. علم اطلاع‌رسانی در نظر و عمل. ترجمه عبدالحسین فرج‌بهلو. ۱۳۸۰. مشهد: دانشگاه فردوسی مشهد.

هینز، دیوید. ۲۰۰۴. برداشتهای مدلیریت و بازیابی اطلاعات. ترجمه علیرضا سعادت علیجانی و فاطمه ذاکری فرد. ۱۳۸۵. تهران: چاپار.

References

- Arun, R., V. Suresh, C. E. Veni Madhavan, & M. N. Narasimha Murthy. 2010. *On Finding the Natural Number of Topics with Latent Dirichlet Allocation: Some Observations*. Berlin: Heidelberg.
- Blei, D. M., A. Y. Ng, & M. I. Jordan. 2003. Latent dirichlet allocation. *Journal of Machine Learning Research* 3:993-1022 :
- Bonner, R. E. 1964. On some clustering techniques. *IBM Journal of Research and Development* 8:(1) 22-32. doi:10.1147/rd.81.0022
- Chakraverty, S., B. Juneja, U. Pandey, & A. Arora. 2015. *Dual lexical chaining for context based text classification*. Paper presented at the 2015 International Conference on Advances in Computer Engineering and Applications. Ghaziabad, India.
- Chen, K., Z. Zhang, J. Long, & H. Zhang. 2016. Turning from TF-IDF to TF-IGM for term weighting in text classification. *Expert Systems with Applications* 66: 245-260. doi:<https://doi.org/10.1016/j.eswa.2016.09.009>
- Chen, Q., X. Guo, & H. Bai. 2017. Semantic-based topic detection using Markov decision processes. *Neurocomputing* 242: 40-50. doi:<https://doi.org/10.1016/j.neucom.2017.02.020>
- Chen, Y., & S. Li. 2016. *Using latent Dirichlet allocation to improve text classification performance of support vector machine*. Paper presented at the 2016 IEEE Congress on Evolutionary Computation (CEC). Vancouver, BC, Canada.
- Chien, J.-T., C.-H. Lee, & Z.-H. Tan. 2018. Latent Dirichlet mixture model. *Neurocomputing* 278: 12-22. doi:<https://doi.org/10.1016/j.neucom.2017.08.029>
- Elhadad, M. K., K. Badran, & G. I. Salama. 2017. *A novel approach for ontology-based dimensionality reduction for web text document classification*. Paper presented at the 2017 IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS). Wuhan, China.
- Griffiths, T. L., & M. Steyvers. 2004. Finding scientific topics. *Proceedings of the National Academy of Sciences of the United States of America*. 101(1): 5228-5235. doi:10.1073/pnas.0307752101
- Gupta, S., V. Kumar, & B. Pant. 2018. *Classification of Textual Data in Distributed Environment. 2018 Second International Conference on Advances in Computing, Control and Communication Technology (IAC3T)*, Allahabad, India120-124 ::.
- Hotho A., N. A., G. Paaß. 2005. A brief survey of text mining. *LDV Forum - GLDV Journal for Computational Linguistics and Language Technology* 20 (1): 19-62.
- Järvelin, K., & P. Vakkari. 1993. The evolution of library and information science 1965–1985: A content analysis of journal articles. *Information Processing & Management* 29 (1): 129-144 .doi:[https://doi.org/10.1016/0306-4573\(93\)90028-C](https://doi.org/10.1016/0306-4573(93)90028-C)
- Kim, H., J. Kim, & K. Jinseog. 2016. *Semantic text classification with tensor space model-based naïve Bayes*. Paper presented at the 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Budapest, Hungary.
- Luhn, H. P. 1958. The Automatic Creation of Literature Abstracts. *IBM Journal of Research and Development* 2 (2): 159-165. doi:10.1147/rd.22.0159
- Meng, L., R. Huang, & J. Gu. 2013. A review of semantic similarity measures in WordNet. *Journal of Intelligent & Fuzzy Systems* 36 (4): 3045-3059.
- Mikolov, T., G. S. Corrado, K. Chen, & J. Dean. 2013. Efficient Estimation of Word Representations in Vector Space. A computing research. *arXiv preprint arXiv:1301.3781*.

- Miyamoto, S. 1990. *Fuzzy Sets in Information Retrieval and Cluster Analysis*. Boston: Kluwer Academic Publishers.
- Mouriño-García, M., R. Pérez-Rodríguez, L. Anido-Rifón, & M. Gómez-Carballa. 2016. *Bag-of-Concepts Document Representation for Bayesian Text Classification*. Paper presented at the 2016 IEEE International Conference on Computer and Information Technology (CIT). Nadi, Fiji.
- Pereira, R. B., A. Plastino, B. Zadrozny, & L. H. C. Merschmann. 2018. Categorizing feature selection methods for multi-label classification. *Artificial Intelligence Review* 49 (1): 57-78. doi:10.1007/s10462-016-9516-4.
- Salton, G. 1989. *Automatic text processing: the transformation, analysis, and retrieval of information by computer*. Addison-Wesley: Longman Publishing Co., Inc.
- Sievert, M. C. 1996. Full-text information retrieval: Introduction. *Journal of the American Society for Information Science* 47 (4): 261-262. doi:10.1002/(sici)1097-4571(199604)47:4<261::aid-asi1>3.0.co;2-v
- Thiyagarajan, D., & N. Shanthi. 2017. A modified multi objective heuristic for effective feature selection in text classification. *Cluster Computing journal* 11: 1-11, doi:10.1007/s10586-017-1150-7.
- Wang, Q., S. R. Kulkarni, & S. Verdu. 2009. Divergence Estimation for Multidimensional Densities Via $\$k\$$ -Nearest-Neighbor Distances. *IEEE Transactions on Information Theory* 55 (5): 2392-2405. doi:10.1109/TIT.2009.2016060.
- Wilson, A. T., & P. A. Chew. 2010. *Term weighting schemes for Latent Dirichlet Allocation*. Paper presented at the Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics. Los Angeles, California.
- Yang, L., X. Chen, Z. Liu, & M. Sun. 2017. Improving Word Representations with Document Labels. *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 25 (4): 863-870. doi:10.1109/TASLP.2017.2658019.
- Zhao, R., & K. Mao. 2018. Fuzzy Bag-of-Words Model for Document Representation. *IEEE Transactions on Fuzzy Systems* 26 (2): 794-804. doi:10.1109/TFUZZ.2017.2690222.

سعیده انبایی فریمانی

متولد ۱۳۶۶ است. ایشان هم‌اکنون دانشجوی دوره دکتری تخصصی دانشگاه آزاد اسلامی واحد مشهد در رشته مهندسی کامپیوتر است و در حال تدوین رساله دکتری در زمینه پردازش زبان طبیعی و طبقه‌بندی سری‌های زمانی با ارائه مدل رفتار سرمایه‌گذاران در بازارهای مالی مبتنی بر شناسایی آنلاین رویدادهای خبری است.



حمدی طباطبائی

متولد ۱۳۵۳ است. دارای مدرک دکتری در رشته مهندسی برق گرایش کنترل هوشمند از دانشگاه فردوسی مشهد است. ایشان هم‌اکنون استادیار دانشگاه آزاد اسلامی واحد قوچان است.

محاسبات نرم، سیستم‌های هوشمند و مدیریت دانش و سیستم‌های مبتنی بر دانش از جمله علائق پژوهشی وی است.



مجتبی کفاشان کاخکی

متولد ۱۳۵۷ دارای مدرک دکتری علم اطلاعات و دانش‌شناسی از دانشگاه فردوسی مشهد است. ایشان هم‌اکنون استادیار گروه علم اطلاعات و دانش‌شناسی و مدیر گروه است. استراتژی‌های مدیریت دانش، فرایندهای مدیریت دانش، سازماندهی دانش و فلسفه دانش از جمله علایق پژوهشی وی است.

