جلد هفتم، شماره اول (بهار ۱۳۹۹): ۲۶-۱۵
http://hii.khu.ac.ir
مقاله اصیل پژوهشی

بررسی رویکردهای متن‌کاوی و عملکرد آن در کشف و استخراج موضوع

فاطمه زرمهر: دانشجوی دکتری علم اطلاعات و دانش شناسی، دانشگاه اصفهان، اصفهان، ایران
***علی منصوری**: استادیار گروه علم اطلاعات و دانش شناسی، دانشگاه اصفهان، اصفهان، ایران(نویسنده مسئول)a.mansouri@edu.ui.ac.ir
حسین کارشناس: استادیار گروه هوش مصنوعی ، دانشگاه اصفهان، اصفهان، ایران

چکیده

دریافت: ۱۳۹۸/۱۰/۲۷
پذیرش: ۱۳۹۸/۱۲/۲۱

زمینه و هدف : در این پژوهش چهار روش متن‌کاوی بررسی می‌شود و بر درک و شناسایی خصوصیات و محدودیت‌های آن‌ها در کشف موضوع تمرکز می‌کند. این چهار روش عبارت‌اند از ۱) تجزیه‌وتحلیل معنایی پنهان(LSA) ۲) تحلیل معنایی پنهان احتمالاتی(PLSA)، ۳) تخصیص دیریکله پنهان(LDA) و ۴) مدل‌سازی موضوعی همبسته(CTM).
روش پژوهش: پژوهش حاضر از نوع کتابخانه‌ای است که در آن، ادبیات حوزه متن‌کاوی و مدل‌سازی موضوعی مرور و تحلیل شده است.
یافته‌ها: تجزیه‌وتحلیل معنایی پنهان می‌تواند برای تشخیص موضوعات خاص و منحصربه‌فرد در مدارکی که تنها به یک موضوع پرداخته‌اند استفاده شود. سه روش دیگر متن‌کاوی، بر موضوعات و گرایش کلی متن متمرکز هستند. تحلیل معنایی پنهان احتمالاتی برای مدارکی که به یک موضوع پرداخته‌اند قابل‌استفاده است اما برخلاف تجزیه‌وتحلیل معنایی پنهان ، این روش در کشف موضوعات و مضامین کلی متن کاربرد دارد. درحالی‌که تخصیص دیریکله پنهان در مورد مدارکی که به چندین موضوع پرداخته‌اند کاربرد بیشتری دارد. روش مدل‌سازی موضوعی همبسته می‌تواند در تشخیص ارتباط بین دسته‌های موضوعی مختلف استفاده شود.
نتیجه‌گیری: رویکردهای متن‌کاوی به خاطر بهره‌گیری از تحلیل معنایی در کشف و استخراج موضوع متون مناسب است

کلیدواژه: متن‌کاوی، مدل‌سازی موضوعی، تحلیل معنایی، کشف موضوع

تعارض منافع: گزارش نشده است.
منبع حمایت کننده: حامی مالی نداشته است.

شیوه استناد به این مقاله

APA: Zarmehr, F., Mansouri, A., Karshenas, H.,(2020). A review of text mining approaches and their function in discovering and extracting a topic. *Human Information Interaction*. 7(1); 15-26 (Persian)

Vancouver: Zarmehr, F., Mansouri, A., Karshenas, H. A review of text mining approaches and their function in discovering and extracting a topic. *Human Information Interaction*. 2020; 7(1): 15-26 (Persian)

انتشار مجله تعامل انسان و اطلاعات با حمایت مالی دانشگاه خوارزمی انجام می‌شود.
انتشار این مقاله به صورت دسترسی آزاد مطابق با CC BY-NC-SA 3.0 صورت گرفته است.

[Downloaded from hii.khu.ac.ir on 2024-04-20]
[DOR: 20.1001.1.24237418.1399.7.1.5.7]

Human Information Interaction. Vol. 7, No. 1 (Spring 2020):15-26
http://hii.khu.ac.ir
Original Article

A review of text mining approaches and their function in discovering and extracting a topic

Fatemeh Zarmehr: PhD student in Information Science and Knowledge, University of Isfahan, Isfahan, Iran
***Ali Mansouri**: Assistant Professor, Department of Information Science, University of Isfahan, Isfahan, Iran (Corresponding Author) a.mansouri@edu.ui.ac.ir
Hossein Karshenas: Assistant Professor, Department of Artificial Intelligence, University of Isfahan, Isfahan, Iran

Received: 17/01/2020 Accepted: 11/03/2020

Abstract

Background and aim: Four text mining methods are examined and focused on understanding and identifying their properties and limitations in subject discovery.
Methodology: The study is an analytical review of the literature of text mining and topic modeling.
Findings: LSA could be used to classify specific and unique topics in documents that address only a single topic. The other three text mining methods focus on topics and general partiality of the text. PLSA is applicable to documents dealing with a topic, unlike the LSA, it is used to discover general themes and contexts. However, LDA is more applicable to documents that address several issues. The CTM, method can be used to identify relationship between different subject categories.
Conclusion: Text mining tactics are suitable for employing analysis in discovering and extracting the text subjects.

Keywords: Text mining, Topic Modeling, Semantic Analysis, Topic Discovery.

Conflicts of Interest: None
Funding: None.

How to cite this article

APA: Zarmehr, F., Mansouri, A., Karshenas, H.,(2020). A review of text mining approaches and their function in discovering and extracting a topic. *Human Information Interaction*. 7(1); 15-26 (Persian)

Vancouver: Zarmehr, F., Mansouri, A., Karshenas, H. A review of text mining approaches and their function in discovering and extracting a topic. *Human Information Interaction*. 2020; 7(1): 15-26 (Persian)

The journal of *Human Information Interaction* is supported by Kharazmi University, Tehran, Iran.
This work is published under CC BY-NC-SA 3.0 licence.

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

مقدمه

نظام‌های اطلاعاتی مدرن این امکان را فراهم کرده که به حجم زیادی از داده‌ها دسترسی ایجاد شود. بخش عمده‌ای از این داده‌ها، داده‌های ساختارمند هستند که می‌توانند با استفاده از نرم‌افزارهای پایگاه داده‌ای، به‌راحتی پردازش و در دسترس قرار گیرند. بااین‌حال به‌طور فزاینده، مقدار زیادی از داده‌ها مثل داده‌های متنی بدون ساختار هستند و تجزیه‌وتحلیل و درک آن‌ها را دچار مشکل کرده است. تجزیه‌وتحلیل دستی داده‌های متنی بدون ساختار عملاً ممکن نیست، و همین امر نیاز به ابزارهای جدیدی برای جستجو، سازمان‌دهی و فهم حجم بسیار اطلاعات درون آن را اجتناب‌ناپذیر کرده است (هوانگ و همکاران[1]، ۲۰۱۷). زیرا نظام‌های سنتی سازمان‌دهی و بازیابی اطلاعات که عمدتاً برای منابع چاپی طراحی‌شده‌اند، قادر به پاسخگویی در این زمینه و بستر نیستند (سورگل[2]، ۲۰۰۴؛بابو[3]، ۲۰۱۲؛هوانگ و همکاران، ۲۰۱۷؛ ابوسبا کاظمینی، ۱۳۹۰؛ نوروزی و خویدکی، ۱۳۹۳؛ ابراهیم‌زاده و حسینی بهشتی، ۱۳۹۵؛ خادمیان و کوکبی،۱۳۹۷). بنابراین برای فائق آمدن به این چالش، پرداختن به رویکردی جدید در سازمان‌دهی منابع اطلاعاتی لازم است.

رویکرد تخصیص خودکار موضوع به متون بر اساس روش‌های متن‌کاوی و الگوریتم‌های اختصاصی این روش، رویکردی جدید است که در پژوهش‌های مختلف سعی شده است جنبه‌هایی از نیاز کتابداران و متخصصان موضوعی را به‌منظور شناسایی موضوعات و تفسیر منابع و کارکرد آن در بازیابی بهینهٔ منابع موردبررسی قرار دهند (بیتر من و فیشر[4]، ۲۰۱۸؛ سان آندرس و همکارانش[5]، ۲۰۱۸؛ هاگن[6]، ۲۰۱۸؛ فانگ[7] و همکارانش، ۲۰۱۸؛ فیگرولا و همکارانش[8]، ۲۰۱۷؛ کین[9]، ۲۰۱۶؛ استیور[10] و همکارانش، ۲۰۰۴؛ نیومن[11] و همکارانش، ۲۰۰۷؛ محمدیان، ۱۳۹۳؛ رانی، دهار و ویاس[12]؛ ۲۰۱۷). در همین راستا، روش‌های متن‌کاوی به‌منظور خودکار سازی فرایند تجزیه‌وتحلیل این نوع داده‌ها توسعه پیدا کرد.

متن‌کاوی یا تجزیه‌وتحلیل متن یکی از حوزه‌های خاص داده‌کاوی است. ازآنجاکه بیشتر اطلاعات (بیش از ۸۰٪) به‌صورت متن ذخیره‌شده‌اند، و حاوی اطلاعات ارزشمند و نهفته‌ای هستند، اعتقاد بر این است که متن‌کاوی ارزش بالقوه بالایی دارد (گوپتا و لهال[13]، ۲۰۰۹). این فن نه‌تنها به تجزیه‌وتحلیل متن‌های حجیم همچون کتاب‌ها و مقالات مجلات دانشگاهی پرداخته، بلکه متن پست‌های الکترونیکی،توئیت‌ها و یا نظرات اعلام‌شده در شبکه‌های اجتماعی را نیز پوشش می‌دهد؛ بنابراین هر نوع فایل متنی غیر ساختارمند و ساختارمند به کمک متن‌کاوی قابل تجزیه‌وتحلیل است (دین[14]، ۲۰۱۴). ازجمله کاربردهای متن‌کاوی می‌توان به کشف موضوع، مدیریت ارتباط با مشتری و تبلیغات هدفمند و .... اشاره کرد.

مدل‌سازی موضوعی یکی از اشکال تجزیه‌وتحلیل متن به‌منظور بررسی رابطهٔ بین کلمات داخل مدرک است، جایی که کلمات در کنار یکدیگر تشکیل‌دهندهٔ درون‌مایه و موضوع اصلی متن است. با توجه به سه هدف اصلی تکنیک مدل‌سازی موضوعی مبنی بر کشف موضوعات پنهان (بیترمن و فیشر، ۲۰۱۸؛ هاگن، ۲۰۱۸؛ فیگرولا، گارسیا و پینتو، ۲۰۱۷ و محمدیان، ۱۳۹۳)، تفسیر اسناد بر اساس موضوعات (دبین فانگ و همکارانش[15]،۲۰۱۸)و نهایتاً سازمان‌دهی و طبقه‌بندی متون(سلوی و همکاران[16]، ۲۰۱۹؛ سهرابی و همکاران، ۲۰۱۷) می‌توان نوشتارهای مربوط به این حوزه را نیز به سه دسته عمده تقسیم نمود. بااین‌حال استفاده از این تکنیک فراتر از سه هدف مذکور در حال پژوهش و ارزیابی است. سایر کاربردهای این تکنیک با استناد به پژوهشهای انجام‌شده عبارتند از: ۱. بازیابی اطلاعات(کین[17]، ۲۰۱۶؛ مین چول کیم[18]، ۲۰۱۸) ، ۲. تحلیل سیر تحولی مفهومی در طول دوره های زمان(کوراتا و همکارانش[19]، ۲۰۱۸)، ۳. غنی سازی فهرست واژگان(رانی، دهار و یاس[20]، ۲۰۱۷).

با توجه به اهمیت نیاز به تجزیه‌وتحلیل و درک داده‌های متنی، در این مقاله سعی شده است روش‌های عمدهٔ متن‌کاوی در کشف موضوع موردمطالعه و بررسی قرار گیرد. این روش‌ها از رویکردهای ساده و اولیهٔ مدل‌سازی موضوعی است که از روش‌های شناسایی تفاوت ظاهری تا رویکردهای جدیدتر مبتنی بر احتمالات، متنوع هست. روش‌های احتمالاتی اخیر به محدودیت‌های روش‌های قبلی غلبه کرده و به محققان این امکان را داده است تا الگوی تولید داده‌های متنی را طی فرآیند مدل‌سازی متن فراهم کنند.در این پژوهش ویژگی‌ها و محدودیت‌های هر روش در فرایند تشخیص موضوع موردبررسی قرارگرفته است. هر یک از چهار روش استخراج متن معرفی‌شده دارای ویژگی‌های منحصربه‌فرد

[1] Hwang &et al
[2] Soergel
[3] Babu
[4] Bitterman, & Fischer
[5] Sanandres
[6] Hagen
[7] Fang
[8] Figuerola
[9] Kinyanjui
[10] Steyver
[11] Newman
[12] Rani, , Dhar & Vyas

[13] Gupta & Lehal
[14] Dean
[15] Debin Fang, Haixia, Baojun, Xiaojun
[16] Selvi & et al
[17] Cain
[18] Meen Chul kim
[19] Kurata & et al
[20] Rani, Dhar, Vyas

[Downloaded from hii.khu.ac.ir on 2024-04-20]
[DOR: 20.1001.1.24237418.1399.7.1.5.7]

خود است و استفادهٔ مؤثر از این ویژگی‌ها نقش مهمی در به دست آوردن عملکرد مذکور دارد.

مفاهیم و فرضیات

هر چهار روش اصلی متن‌کاوی که در ادامه توضیح داده خواهد شد بر اساس یک سری فرضیات پایه و هم‌چنین مدل فضای برداری است.

مدرک و کیسه کلمات[1]

واحد اصلی متن، کلمه است. کلمات حاوی کاراکترها هستند که معانی و مفاهیم از آن‌ها به وجود می‌آید. از ترکیب کلمات با قوانین دستور زبان، جمله ساخته می‌شود. جملات، واحدهای اصلی کارکردی در متن است که حاوی اطلاعاتی در مورد عملکرد بعضی موضوعات است. پاراگراف یا بندها، واحدهای اصلی تشکیل ساختار متن است که به موضوع خاصی می‌پردازد (استرانک[2]، ۲۰۰۷). هر چه طول متن در ساختار بخش‌ها، فصل‌ها و متن اصلی افزایش یابد، اشکال ساختاری اضافی به وجود می‌آید و درنهایت مجموعه‌ای از مدارک یا اسناد که به آن‌ها پیکره[3] نیز گفته می‌شود، شکل می‌گیرد.

در مطالعات متن‌کاوی برای تشخیص موضوع، مدرک به‌عنوان واحد اصلی تجزیه‌وتحلیل استفاده می‌شود، زیرا یک نویسنده معمولاً کلیت یک مدرک را در مورد یک موضوع واحد می‌نویسد. این مدرک می‌تواند یک مقاله یا یک کتاب باشد که بستگی به هدف نویسنده و نوع تجزیه‌وتحلیل وی از موضوع دارد. در بعضی موارد، یک مدرک ممکن است حاوی فقط یک‌فصل یا یک پاراگراف ساده و یا حتی یک جمله باشد. در مطالعات متن‌کاوی، گاهی ساختار نحوی یک جمله یا پاراگراف به عمد نادیده گرفته می‌شود تا بتوان به‌طور مؤثر فرایندهای بعدی را اجرا نمود. بنابراین یک جمله صرفاً به‌عنوان مجموعه‌ای از کلمات یا به‌اصطلاح کیسه‌ای از کلمات[4] در نظر گرفته می‌شود. این ایده که یک جمله، صرفاً کیسه‌ای از کلمات بدون در نظر گرفتن ساختار اضافه است، فرض اساسی در متن‌کاوی برای تشخیص موضوع است (فرنگ و همکارانش، ۲۰۱۸).

ازآنجا که گاهی ساختار نحوی متن در متن‌کاوی نادیده گرفته می‌شود، ترتیب کلمات بدون تأثیر درنتیجهٔ تحلیل می‌تواند تغییر کند. مفهوم کیسه کلمات به معنای قابلیت جابه‌جایی و تعویض کلمات در نظر گرفته می‌شود (همان، ۲۰۱۸). دو مشکل اساسی که در تجزیه‌وتحلیل متن به وجود می‌آیند، "مترادفات"[5] و "کلمات چند معنی"[6] است. این مشکل به طرق مختلف برطرف شده است (فانگ و همکارانش، ۲۰۱۸). زیرا در روش های متن‌کاوی مختلف رویکردهای متفاوتی برای مقابله با مترادفات و چند معنی بودن کلمات به کار گرفته‌شده است که در توضیح هر روش به آن اشاره می‌شود. در بخش بعدی به مدل فضای برداری اشاره خواهد شد که مفهوم اساسی دیگر در رویکردهای متن‌کاوی هست.

مدل فضا برداری[7](VSM)

یکی از مهم‌ترین کارهایی که درزمینهٔ استخراج ویژگی‌ها از اسناد و هم‌چنین نحوهٔ مقایسهٔ این ویژگی‌ها با یکدیگر انجام شد، نمایش اسناد در قالب شکل برداری است. یعنی هر یک از کلمات متن (بدون تکرار) به‌عنوان یک مؤلفهٔ برداری در نظر گرفته می‌شود و در کنار سایر کلمات متن تشکیل یک فضای برداری را می‌دهند. به‌این‌ترتیب یک متن معمولی که ممکن است شامل پانصد کلمه باشد به‌صورت یک بردار حدوداً دویست بعدی مدل می‌شود که البته تصور هندسی آن مطمئناً ساده نیست اما در عوض جنبه‌های محاسباتی قابل‌درک و ساده‌ای را به وجود می‌آورد که باعث می‌شود به‌صورت منطقی و قابل‌قبول دو متن، به‌عنوان دو بردار با یکدیگر مقایسه شوند. در مدل فضای برداری، یکی از روش‌های مقایسه، استفاده از کسینوس زاویه دو برداری است که بازنمایش متن هستند(تصویر۱). به همین دلیل به این معیار، شباهت کسینوسی گفته می‌شود (ونکات[8] و همکاران ، ۲۰۱۸). یکی از روش‌هایی که در رابطه با نحوهٔ وزن دهی به هر یک از مؤلفه‌ها و یا به‌عبارت‌دیگر بزرگی و میزان هر یک از ابعاد به کار می‌رود، معیار TF-IDF است که خود ترکیبی از دو روش وزن دهی TF[9] و IDF[10] است. ویژگی TF بیانگر تکرار کلمه است. زیرا فرض بر این است که کلماتی که در متن به تعداد زیاد تکرار شوند احتمالاً ارزش معنایی زیادی دارند. ویژگی IDF نیز معکوس تکرار در متون است. یعنی فرض بر این گرفته‌شده که اگر کلمه در یک متن بکار گرفته‌شده و این کلمه در متون دیگر تقریباً کمیاب باشد این مسئله نشان‌دهنده ارزش بیشتر این کلمه در متنی است که به‌کاربرده شده است. با داشتن نسبت TF و IDF مقدار TFIDF حاصل‌ضرب این دو مقدار خواهد بود. با محاسبه مقدار می‌توان مقداری که برای هر بعد از بردار متن لازم است را حساب کرده و درنهایت با مقایسه معیار کسینوسی نسبت به شباهت داشتن و یا شباهت نداشتن متون با یکدیگر تصمیم گرفت(نادژدا و الکسی[11]، ۲۰۱۸) .

[1] Bag of word
[2] Strunk
[3] corpus
[4] Bag-of- word
[5] synonymy
[6] polysemy
[7] Vector space model
[8] Venkat
[9] Term Frequency
[10] Inverse Document Frequency
[11] Nadezhda & Aleksey

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

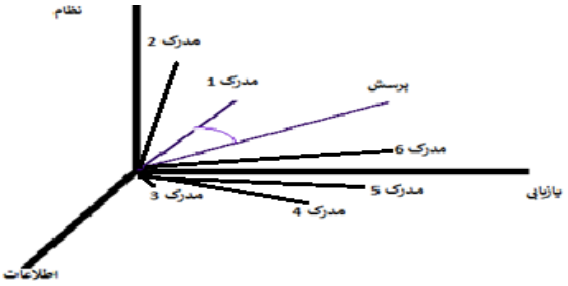

تصویر ۱. مدل فضا برداری مدارک(ونکات و همکاران، ۲۰۱۸)

پس به‌طور خلاصه در نظر گرفتن متن به‌صورت کیسه‌ای از کلمات و همچنین مدل فضا برداری متن، دو فرض اساسی درروش های متن‌کاوی است که بر اساس آن عمل می‌شود.

اما باید توجه داشت که مدل فضا برداری چهار محدودیت اصلی ایجاد می‌کند. اولاً در بازیابی اطلاعات، یک مدرک طولانی شباهت کمتری با پرسمان پیدا می‌کند زیرا مقدار نرمال شده مدرک، عددی بزرگ است. درنتیجه مدارک طولانی و پرحجم با پرسمان کمتر منطبق می‌شود. مشکل دوم ناشی از در نظر گرفتن ترتیب کلمات در متن است زیرا متن به‌صورت کیسه‌ای از کلمات در نظر گرفته می‌شود. درحالی‌که ساختار نحوی یک مدرک اطلاعات ارزشمندی در بردارد. سومین مشکل این است که کلمات پرسمان باید دقیقاً منطبق با کلمات درون‌متن باشد و این به خاطر در نظر نگرفتن مسئلهٔ مترادفات است. و چهارمین مسئله ، مشکل چند معنی بودن کلمه است، زیرا مدل فضا برداری تنها به شکل کلمه توجه می‌کرد (هاگن، ۲۰۱۸). برای غلبه بر مسئلهٔ مترادفات، تجزیه‌وتحلیل معنایی پنهان (LSA) توسعه داده شد که در ادامه به آن پرداخته خواهد شد.

چهار رویکرد مطرح در متن‌کاوی

متن‌کاوی برای شناسایی موضوعات با استفاده از مدل‌های متمایزکننده مثل تجزیه‌وتحلیل معنایی پنهان[1] تا مدل‌های مولد مثل تجزیه‌وتحلیل معنایی پنهان احتمالاتی[2] ، تخصیص دیریکله پنهان[3] و مدل‌سازی موضوعی همبسته[4] توسعه‌یافته است.

تجزیه‌وتحلیل معنایی پنهان

مدل فضای برداری نمی‌توانست مشکل مترادفات و چند معنی بودن یک کلمهٔ واحد را برطرف کند و بنابراین برای غلبه بر این مسئله تجزیه‌وتحلیل معنایی پنهان (LSA) طراحی شد (چائو و مائو[5]، ۲۰۱۸). تجزیه‌وتحلیل معنایی پنهان، ماتریس مدرک- کلمه یا بردار فضایی اصلی را در یک فضای عامل کوچک طراحی می‌کند. کاهش بعد ماتریس با استفاده از تجزیه مقادیر منفرد[6] انجام می‌گیرد که ماتریس عبارت- مدرک را به سه ماتریس عبارت- اندازه (T)، ماتریس مقدار منفرد (مقدار- مقدار)(S)، و D ماتریس مدرک- اندازه تجزیه می‌کند. تعداد اندازه‌ها نیز که رتبه ماتریس عبارت- مدرک است با r نشان داده می‌شود. در تحلیل معنایی پنهان، ماتریس‌های S، Tو D به میزان K کاهش می‌یابد. در تصویر۲ که نحوهٔ کاهش ماتریس را با استفاده از تجزیهٔ مقادیر منفرد توضیح می‌دهد، نواحی هاشور خوردهٔ ماتریس‌های D و T باقی می‌مانند چون مرتبط با بزرگ‌ترین مقادیر منفرد هستند و نواحی غیر هاشور خورده نیز حذف می‌شوند. هدف از کاهش اندازه در فرایند تجزیه مقادیر منفرد و فرآیند LSA، کاهش نوفه(پارازیت) در فضای پنهان است که باعث می‌شود تا ساختار را به واژگانی غنی‌تر تقلیل دهد و معانی پنهان کنونی مجموعه را آشکار سازد (استیوی و گریس[7]، ۲۰۰۷).

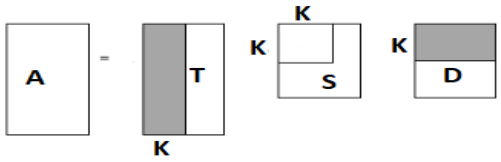

تصویر۲. نحوه کاهش ماتریس با استفاده از تجزیه مقادیر منفرد(دراکوس[8]، ۲۰۱۹)

به دلیل خاصیت متعامد یا عمود بر هم موضوعات در این روش که ناشی از همپوشانی نداشتن دسته‌های موضوعی است، کلمات در یک دسته‌بندی موضوعی ارتباط کمی با دستهٔ موضوعی دیگر دارد ولی کلمات درون یک دستهٔ موضوعی با یکدیگر ارتباط زیادی دارند. موضوعات در LSA بیشتر با مترادفات سروکار دارد تا کلمات چندمعنایی. کلمات درون دسته‌های موضوعی به‌عنوان کلمات مترادف و هم‌معنی در نظر گرفته می‌شوند زیرا همبستگی زیادی با یکدیگر درون یک دستهٔ موضوعی دارند. بااین‌حال در موارد چندمعنا بودن کلمه، که با توجه به معنی و مفهوم کلمه باید در دسته‌بندی‌های موضوعی مختلف قرار گیرد، این امر امکان‌پذیر نیست. برای مثال کلمهٔ شیر نه‌تنها باید در دستهٔ موضوعی لبنیات قرار گیرد بلکه در دسته‌بندی حیوانات نیز قابل‌نمایش باشد.

[1] Latent semantic analysis(LSA)
[2] Probability latent semantic analysis(PLSA)
[3] Latent Dirichlet allocation(LDA)
[4] Correlated topic modeling(CTM)
[5] Zhao & Mao

[6] Single Value Decomposition(SVD): یک روش ریاضی بر پایه جبر خطی و با استفاده از خواص ماتریس هاست که به عنوان یک روش کاهنده، یک ماتریس را به ضرب سه ماتریس و در حقیقت به تصاویر مشخصه سازنده اش تجزیه می کند، که دو ماتریس متعامد و سومی قطری است و می تواند در تصاویر مشخصه ابتدایی، پدیده های افقی را شناسایی نماید(مرتضوی و جواهریان، ۱۳۹۲)

[7] Stayver & Griffiths
[8] Derakos

[Downloaded from hii.khu.ac.ir on 2024-04-20]
[DOR: 20.1001.1.24237418.1399.7.1.5.7]

بنابراین نکتهٔ منفی در این روش این است که خاصیت متعامد (عمود بر هم بردار موضوعات) در LSA مانع از حضور کلمه در دسته‌های موضوعی مختلف می‌شود.

LSA در شاخه های مختلف علم اطلاعات مثل بازیابی اطلاعات، تشخیص موضوع، طراحی هستی‌شناسی اصطلاحات تخصصی نیمه‌خودکار، طبقه‌بندی موضوعات و امتیازدهی به مقالات به کار می‌رود و پایه‌ای برای عملکرد روش‌های پیشرفته است. به عنوان مثال چیِن (chien, 2016) در مطالعه‌ای امکان استفاده از الگوریتم LSA در ارتقای دسترسی به متون دیجیتال را موردبررسی قرار داد. وی به این نتیجه رسید که استفاده از این تکنیک در بازیافت موضوعات متون طبقه‌بندی نشده بسیار کاربردی بود. رانی، دهار و ویاس[1] نیز (۲۰۱۷) در مطالعهٔ خود به بررسی امکان استفاده از روش مدل‌سازی موضوعی و مقایسهٔ دو الگوریتم مدل‌سازی موضوعی یعنی LSI، SVD و LDA در طراحی هستی‌شناسی اصطلاحات تخصصی نیمه‌خودکار و طبقه‌بندی موضوعات پرداختند. هدف آن‌ها سنجش ارتباط آماری بین مدارک و اصطلاحات برای ساخت هستی‌شناسی موضوعی و ایجاد گراف هستی‌شناسی با حداقل دخالت انسان و بازیابی معنایی برای موضوع‌ها و تشخیص کلمات در یک حوزهٔ موضوعی بود. درواقع تحقیق آن‌ها با تمرکز بر مسائل یادگیری آنتولوژی مثل تبدیل خودکار متن به هستی‌شناسی بود. دومین ردیف جدول ۱ برنامه‌ها و کاربرد آن را نشان می‌دهد. LSA کاربرد مدل فضا برداری را با در نظر گرفتن مترادفات بهبود می‌بخشد اما سه محدودیت دارد:۱) کاهش بعد مستقیم از یک ماتریس است و بر اساس نظریهٔ احتمال قوی ساخته نشده است. ۲) تعداد کافی موضوع به‌صورت آماری قابل شناسایی نیست و تشخیص تعداد موضوعات بستگی به قضاوت انسان دارد. ۳)، مسئلهٔ چند معنی بودن یک کلمهٔ واحد در LSA به خاطر خاصیت متعامد بردارها قابل‌حل نیست (افسان و همکارانش، ۲۰۱۷؛ رانی، دهار و یاس، ۲۰۱۷). برای غلبه بر کاهش بعد مستقیم ماتریس و مسئلهٔ کلمات چندمعنایی، روش‌های مولد دیگری توسعه یافت که در بخش‌های بعدی به آن پرداخته می‌شود.

تجزیه‌وتحلیل معنایی پنهان احتمالاتی

تجزیه‌وتحلیل معنایی پنهان احتمالاتی فرض می‌کند که مدارک طی سه مرحله تولید می‌شوند. اول، یک مدرک d با احتمال P(d) ایجاد می‌شود. سپس، موضوع Z با احتمال P(z|d) در نظر گرفته می‌شود. در آخر، هر کلمهٔ W در یک موضوع با احتمال P(w|z) جای می‌گیرد (زمانی، دیانت و صادق زاده، ۱۳۹۱).

احتمال وقوع کلمه – سند P(d,w)، را می‌توان با P(d) $\Sigma_{z\epsilon Z}P(w|z)P(z|d)$ نمایش داد. PLSA با استفاده از الگوریتم ماکسیمم انتظار وقوع[2] (EM) که یک‌راه حل کلی در برآورد پارامترهای ناشناخته است، احتمالات موضوع P(z)، احتمال مدرک با توجه به موضوع P(d|z) و احتمال کلمه با توجه به موضوع P(w|z) را تخمین می‌زند. در الگوریتم PLSA مقادیر P(d|z), P(z) و P(w|z) به‌عنوان احتمال تفسیر می‌شود. به‌طورکلی PLSA موضوع کلی متن را مشخص می‌کند (حیدری، ۱۳۹۳).

از جمله کاربردهای این رویکرد در حوزه علم اطلاعات می‌توان به تشخیص موضوع در متن، خوشه بندی مفاهیم حوزه‌های علمی و غنی سازی فهرست واژگان اشاره کرد. هافمن همکارانش (۲۰۰۱) برای اولین بار از PLSA برای شناسایی موضوعات در مجله عصب‌شناسی و بازیابی اطلاعات استفاده کردند. هاگن نیز (Hagen,2018) در مطالعه‌ای به تجزیه‌وتحلیل محتوا و موضوعات اصلی دادخواست‌های الکترونیکی به کمک مدل‌سازی موضوعی پرداخت. هدف وی ارتقا و ارزیابی مدل‌های PLSA بود. نتایج پژوهشهای او نشان داد که موضوعات تولیدشده در مدل‌سازی موضوعی نسبت به موضوعات برگرفته از تجزیه‌وتحلیل دستی این مزیت را دارد که زمینه‌های مختلف مطرح در متن را بیان نموده که ممکن است از دید تحلیلگران موضوعی پنهان مانده باشد. لئو و همکارانش (۲۰۱۶) در بررسی مفاهیم حوزه بیوانفورماتیک، با بهره‌گیری از تکنیک مدل‌سازی موضوعی به خوشه‌بندی مفاهیم این حوزه پرداختند. سایر مقالات مشابه باهدف خوشه‌بندی مفاهیم در حوزه‌های علمی به کمک تجزیه و تحلیل پنهان احتمالاتی می‌توان به آثار کستلانی و همکارانش ؛۲۰۱۰، ماسرولی و همکارانش ؛ ۲۰۱۲، بیسگین و همکارانش ؛ ۲۰۱۳، لی و همکارانش ؛ ۲۰۱۴، فانگ و همکارانش ؛ ۲۰۱۵ اشاره کرد. سایر کاربردهای PLSA در جدول ۱ نمایش داده‌شده است. در رابطه با مسئلهٔ مترادفات، کلمات درون دسته‌های موضوعی در PLSA بیشتر از روش LSA به هم مرتبط هستند و در مورد کلمات چندمعنایی، کلمات درون دسته‌های موضوعی به روش PLSA می‌تواند به‌طور هم‌زمان در موضوعات دیگر نمایش داده شود. یکی از محدودیت‌های PLSA این است که تولید مدرک P(d) در مدل را در نظر نمی‌گیرد. برای نمایش روند تولید در سطح مدرک، تخصیص دیریکله پنهان توسعه پیدا کرد که در بخش بعدی به آن پرداخته می‌شود.

[1] Rani, Dhar & Vyas

[2] Exepectation-Maximization: الگوریتم بیشینه‌سازی – انتظار وقوع روشی است استاندارد برای تخمین ماکزیمم احتمال وقوع در مدلهای متغیرپنهان (هافمن، ۲۰۰۱)

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

تخصیص دیریکله پنهان

با توجه به محدودیت PLSA، روش تخصیص دیریکله[1] پنهان، از روند تولید مدارک با توزیع دیریکله استفاده می‌کند. طبق الگوریتم LDA هر مدرک طی سه مرحله تولید می‌شود. اول، تعداد کلمات استفاده‌شده در یک مدرک با نمونه‌گیری از توزیع پواسون (توزیع احتمالی گسسته) مشخص می‌شود. دوم، توزیع در موضوعات برای یک مدرک از توزیع دیریکله استخراج می‌شود. سوم، بر اساس توزیع اختصاصی مدرک، موضوعات ایجاد می‌شوند، و سپس کلمات برای هر موضوع ایجاد می‌شود (بلای و همکاران، ۲۰۰۳). مشابه PLSA، تخصیص دیریکله پنهان نیز موضوعاتی را ارائه می‌دهد که در آن کلمات دارای ارزش احتمالاتی است. تخصیص دیریکله پنهان برای مدل‌سازی مدارک طولانی حاوی چندین موضوع مناسب است. در رابطه با مسئلهٔ مترادفات درروش LDA، کلمات درون یک دستهٔ موضوعی معنای یکسان دارند، اما کلمات متشکل از صفت‌ها و اسم هستند مانند "صفحه خوب". این ساختار موصوف و صفت محققان را قادر می‌سازد تا به‌راحتی به دسته‌های موضوعی برچسب اختصاص دهند. تخصیص دیریکله در بسیاری از حوزه‌ها مثل تشخیص موضوع، تشخیص احساس، و ابهام‌زدایی از مفهوم کلمه به کار می‌رود. به عنوان مثل بیترمن و فیشر(۲۰۱۸) در مطالعه‌ای به کشف نقاط قوت موضوعی در نشریات حوزهٔ روان‌شناختی پرداختند و برای رسیدن به این هدف از ابزار مدل‌سازی موضوعی استفاده کردند. آن‌ها از الگوریتم موضوعی LDA برای کشف و استخراج موضوعات نهان در اسناد استفاده کردند و به این نتیجه رسیدند که با استفاده از این الگوریتم، می‌توان موضوعات خاصی را کشف کرد که با سیستم‌های طبقه‌بندی موجود امکان شناسایی آن آسان نیست.

در جدول ۱ به سایر کاربردهای این الگوریتم اشاره‌شده است. در مورد کلمات چندمعنایی نیز، این دسته از کلمات می‌توانند به‌طور هم‌زمان بر اساس معنای موردنظر در دسته‌های موضوعی مختلف قرار گیرند (افشان[2] و همکاران، ۲۰۱۷). با این‌حال تخصیص دیریکله پنهان ارتباط بین دسته‌های موضوعی مختلف را نمی‌تواند در نظر بگیرد. درحالی‌که با شناسایی ارتباط بین دسته‌های موضوعی می‌توان ساختار عمیق بین مدارک را بهتر درک کرد.

مدل‌سازی موضوعی همبسته (CTM) برای رفع محدودیت‌های LDA توسعه یافت.

مدل‌سازی موضوعی همبسته[3]

مدل‌سازی موضوعی همبسته، با استفاده از توزیع نرمال منطقی ارتباط بین دسته‌های موضوعی را شناسایی می‌کند. در تخصیص دیریکله پنهان(LDA)، فرض بر این است که کلمه درون دسته‌های موضوعی، توزیع چندجمله‌ای قرار دارد و موضوعات مختلف می‌تواند در یک مدرک ظاهر شود و سهم موضوعات طبق توزیع دیریکله متفاوت است. مدل‌سازی موضوعی همبسته از همان روند مولد LDA استفاده می‌کند اما برای کشف ارتباطات موضوعی به‌جای استفاده از توزیع دیریکله از توزیع نرمال منطقی[4] استفاده می‌کند (آینده[5]، ۲۰۱۱). در تخصیص دیریکله، دسته‌های موضوعی عملاً مستقل هستند، بنابراین مباحث نمی‌توانند با یکدیگر رابطه‌ای داشته باشند. این استقلال و ارتباط نداشتن مانع از ظهور کلمه در سایر موضوعات می‌شود. برای نمایش ارتباط موضوع‌ها، مدل‌سازی موضوعی همبسته از توزیع نرمال منطقی با در نظر گرفتن ساختار کوواریانس در بین اجزاء دسته‌های موضوعی استفاده می‌کند (همان، ۲۰۱۱). مدل‌سازی موضوعی همبسته در سایر حوزه‌ها مثل تشخیص موضوع و بازیابی تصویر استفاده می‌شود. در مورد مترادف‌ها نیز، کلمات درون هر دستهٔ موضوعی دارای معانی یکسان هستند و آن کلمه‌ها با کلمات موضوعات مشابه نیز مشابهت دارد. در مورد کلمات چندمعنایی نیز، کلمات با معانی مختلف می‌تواند به‌طور هم‌زمان در سایر دسته‌های موضوعی نمایش داده شود. مدل‌سازی موضوعی همبسته، راهی برای هموار کردن مشکل چندمعنایی بودن کلمات فراهم نمود. برای مثال، چون موضوع "برنامه‌نویسی جاوا" ارتباط نزدیک‌تری با موضوع "خدمات وب" دارد، این کلمه با سایر موضوعات مشابه ابهام‌زدایی می‌شود. خصوصیات و محدودیت‌های هر چهار روش متن‌کاوی در جدول ۱ خلاصه‌شده است.

---

[1] توزیع دیریکله در نظریه احتمال و آمار یک توزیع پیوسته است. این توزیع به‌طور کلی حالت گسترش یافته توزیع بتا برای توابع چندمتغیره است. معمولاً از توزیع دیریکله به عنوان توزیع پیشین در مدل سازی بیزی استفاده می‌شود

[2] Efsun

[3] Correlated topic modeling

[4] Logistic normal distribution

[5] Hinde

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

جدول ۱. ویژگی‌ها و محدودیت‌های روش‌های چهارگانهٔ متن‌کاوی

مدل‌ها	ویژگی‌ها/ محدودیت‌ها
LSA	**ویژگی‌ها:**
	کاهش بعد TF-IDF با استفاده از تجزیهٔ ارزش منفرد
	تشخیص کلمات مترادف
	محدودیت‌ها:
	مشکل تشخیص تعداد موضوعات
	مشکل تفسیر مقادیر احتمال
	مشکل برچسب‌گذاری به دسته‌های موضوعی در بعضی موارد با استفاده از کلمات درون دسته‌ها
PLSA	**ویژگی‌ها:**
	اجزای متن، متغیرهای تصادفی چندجمله‌ای هستند که می‌توانند به‌عنوان "موضوعات" بازنمایی شوند.
	هر کلمه از یک موضوع واحد تولید می‌شود. کلمات مختلف در یک مدرک می‌توانند از موضوعات مختلف ایجاد شوند
	تجزیه‌وتحلیل معنایی پنهان احتمالاتی مسئله چندمعنایی بودن کلمات را تا حدودی حل می‌کند.
	محدودیت‌ها:
	هیچ مدل احتمالی در سطح اسناد وجود ندارد.
LDA	**ویژگی‌ها:**
	ارائهٔ مدل با توزیع چندجمله‌ای برای کلمات در دسته‌های موضوعی و توزیع دیریکله در سطح دسته‌های موضوعی
	اجرای فرایند بر روی مدارک پرحجم و طولانی
	نمایش ویژگی‌های نحوی کلمه در دسته‌های موضوعی
	محدودیت‌ها:
	توانایی نداشتن در مدل‌سازی ارتباط بین دسته‌های موضوعی
CTM	**ویژگی‌ها:**
	در نظر گرفتن ارتباط بین دسته‌های موضوعی با استفاده از توزیع نرمال منطقی
	امکان ظهور کلمات در دسته‌های موضوعی مختلف
	امکان نمایش گراف موضوعات
	محدودیت‌ها:
	نیاز به محاسبه‌های پیچیده
	حضور بیش‌ازاندازهٔ کلمات عادی در دسته‌های موضوعی

درک نظری تفاوت‌های عملکردی چهار روش متن‌کاوی

روش‌های چهارگانهٔ متن‌کاوی اساساً مبتنی بر هم رخدادی و رابطه ترایایی[1] است (کنتوستاتیس و پوتنگر[2]،۲۰۰۶). در ریاضیات، بین سه عضو a و b و c از مجموعهA یک رابطه ترایا برقرار است هرگاه بتوان از وجود رابطه دوتایی بین a و b از یک‌سو، و b و c از سوی دیگر، نتیجه گرفت که a و c نیز دارای همان رابطه هستند. ترایایی یا تعدی پذیری مانند بازتاب و تقارن یکی از ویژگی‌های برخی از رابطه‌ها است (بلای و نفرتی[3]،۲۰۰۷).

به‌طورکلی، LSA از ساختاری منحصربه‌فرد بهره می‌گیرد اما سایر روش‌ها دارای همپوشانی در ساختار یا روش هستند. برای مثال، تصویر ۳ سه مدرک را نشان می‌دهد که مدرک ۱ (D1) حاوی سه موضوع (A,B,C) ، مدرک ۲ شامل موضوعات (B,D,E) و مدرک ۳ حاوی موضوعات (D,F,G) است. از منظر اسناد، بین مدارک ۱ و ۲ هم‌رخدادی در موضوع B و بین مدارک ۲ و ۳ هم‌رخدادی به خاطر موضوع D وجود دارد. مرتبهٔ دوم همبستگی یا هم‌رخدادی بین مدارک ۱و ۲ به خاطر ارتباط ترایا (A B D F) وجود دارد. درحالی‌که LSA موضوعات منحصربه‌فرد هر مدرک (A,C – E – F,G) را بر اساس ترتیب و نظم (B, D) در نظر می‌گیرد، مدل‌های احتمالاتی، ابتدا بخش‌های مشترک (B-D) را در نظر می‌گیرند.

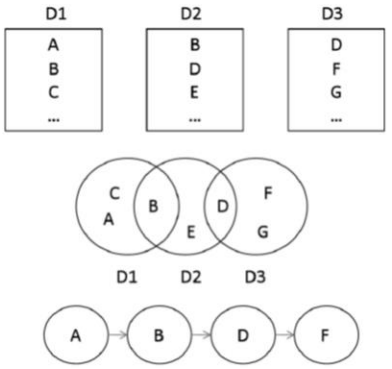

تصویر۳. ساختار هم‌رخدادی کلمات درون مدارک (لی، سانگ و کیم، ۲۰۱۰، ۴)

[1] Transitive relation
[2] Kontostathis, & Pottenger
[3] Blei & Lafferty

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

کنتوستاتیس و پوتنگر (۲۰۰۶) دریافتند که هم‌رخدادی مرتبهٔ دوم کلمات تأثیر به سزایی در نتایج LSA دارد. بنابراین، هنگام استفاده از چهار روش، محققان مدارک را تا سطح پاراگراف جداسازی می‌کنند تا الگوی هم رخدادی را غنی سازند. بنابراین، عملکرد هر چهار روش متن‌کاوی به‌طور اساسی تحت تأثیر هم رخدادی بالا و ارتباط ترایا است. ساختار هم رخدادی در تصویر ۱ می‌تواند با احتمالات شرطی(P(B|A), P(D|B و P(F|D) ، ارتباط A-B-D-F را نشان دهد. تنوع مدل‌های احتمالاتی ناشی از مدل‌سازی ساختار هم رخدادی است. PLSA، LDA و CTM این دانش قبلی را با هر مدل ترکیب می‌کند.

بررسی عملکرد چهار روش در تشخیص موضوع

تشخیص موضوع یکی از کاربردهای کلی تمام رویکردهای متن‌کاوی از LSA تا CTM است. با توجه به این‌که تمام چهار روش متن‌کاوی به‌طور مستقیم در مطالعات مربوط به تشخیص موضوع استفاده می‌شود، می‌توان تفاوت‌ها و شباهت‌های عملکردی این چهار روش را در یک آزمایش کلی بر روی یک دسته از مدارک نشان داد. لی، سانگ و کیم (۲۰۱۰) در مطالعه‌ای، به بررسی نظرات کاربران در رابطه با دوربین عکاسی از وب‌سایت آمازون پرداختند،که بعد از فرآیند پیش‌پردازش و حذف کلمات زائد، ماتریس کلمه- مدرک ایجاد گردید. سپس چهار روش متن‌کاوی روی این ماتریس اعمال شد. جدول زیر موضوعات استخراج‌شده در این چهار روش را نشان می‌دهد.

جدول ۲. موضوعات استخراج شده از بررسی نظرات کاربران در زمینهٔ دوربین عکاسی با ۴ روش متن کاوی

روش	موضوع	کلمات
LSA	#2	اجرا، مدیریت، توقف، شرکت، آرزو، مقایسه کردن، کارت‌ها
	#3	نامزد، حرفه‌ای، پیشنهاد، نوه، شکست، پیچیده، دوست داشتن، کتاب‌ها
PLSA	#1	دوربین، بسیار خوب، تصاویر، دیجیتال، ویژگی‌ها، کانن، دوربین‌ها، آسان، نقطه، خوب، کیفیت، تصاویر، قیمت
	#8	دوربین، باتری‌ها، خوب، تصاویر، فقط، باتری، عالی، مشابه، زمان‌بر، چراغ
LDA	#1	دوربین، باتری‌ها، خوب، باتری،کانن، تصاویر، فقط، می‌خواستم، ساده، مشابه، زندگی، نما
	#2	دوربین، فلش، خوب، مد، زوم، کانن، تصویر، تصویرها، بهتر، دستی، زمان، دیجیتال، عالی
CTM	#0	دوربین، تصویر، عالی، قدرت نما، نما، محصول، دیجیتال، خوب، مشابه، زوم، آمازون
	#5	دوربین، کانن، تصویر، دوربین‌ها، پارازیت، دیجیتال، تصاویر، کیفیت، عالی، نقطه، استفاده‌ها، خوب

موضوعات استخراج‌شده به روش LSA دارای دو ویژگی منحصربه‌فرد بود: حضور کلمات متمایز و منحصربه‌فرد در یک موضوع و وجود تمایز و انحصار بین موضوعات از طرف دیگر، در مدل LSA، فقط کاهش بعد، بدون در نظر گرفتن معانی قابل‌مشاهده بود و موضوعات نسبت به یکدیگر متمایز یا به‌اصطلاح متعامد[1] هستند. PLSA سه ویژگی مجزا را نشان داده است: ۱) نام محصول و لوازم جانبی آن از احتمال بالایی برخوردار بود. ۲)«دوربین» در بیش از چندین موضوع به‌طور هم‌زمان نشان داده‌شده، به‌طوری‌که مسئلهٔ چندمعنایی بودن کلمه احساس می‌شود هرچند معنی مشخص و واضح نیست. حداقل می‌توان تصور کرد که کلمه «دوربین» در موضوع اول در رابطه با «تصویر و عکس» است و در موضوع دوم در رابطه با «باتری». ۳) موضوعات استخراج‌شده به روش PLSA درباره موضوع یا گرایش کلی است. برای مثال، می‌توان تصور کرد که به‌طورکلی، موضوع ۱ در رابطه با موضوع عکس و موضوع دوم در رابطه با باتری است. از منظر مدل ایجادشده در این روش نیز باید گفت که، کلمات با احتمال بالا در ابتدا آمده است. از منظر ساختار هم‌رخدادی نیز، PLSA کلمات مشترک را استخراج می‌کند تا کلمات متمایز و منحصربه‌فرد را.

روش LDA نیز دارای سه ویژگی منحصربه‌فرد بود: ۱) مشابه PLSA ، موضوعات استخراج‌شده در LDA ترکیبی از نام محصول و لوازم جانبی آن است. این به خاطر احتمال وقوع زیاد این کلمات درون‌متن است. ۲) هم رخدادی صفات و اسم وجود دارد که امکان برچسب‌گذاری دسته‌های موضوعی را ساده کرده است. ۳) LDA مدل خوبی برای اسناد حجیم و طولانی ارائه می‌کند. از منظر ساختار هم رخدادی نیز، می‌توان حدس زد که چون کیفیت تصویر، قیمت و باتری از نگاه کاربر مهم بوده است، الگوی هم رخدادی این کلمات در مدارک به‌طور واضح دیده می‌شود.

نهایتاً عملکرد CTM ، ارائهٔ رابطهٔ بین دسته‌های موضوعی است. این روش نیز، حاوی اسم‌ها و صفت‌ها در هر دستهٔ موضوعی است که امکان برچسب‌گذاری دسته‌های موضوعی را راحت‌تر می‌کند. بعلاوه، CTM امکان تشخیص رابطهٔ بین موضوعات را نیز فراهم کرده است. برای مثال، می‌توان ۵ گروه موضوعی از ۱۰ موضوع ایجاد کرد مانند (۰، ۵)، (۱، ۶)، (۲، ۷)، (۳، ۸) و (۴ ، ۹). بنابراین ، CTM نه‌تنها در استخراج موضوع استفاده می‌شود بلکه در بیان رابطهٔ بین دسته‌های مختلف موضوعی استخراج‌شده نیز توانا است.

[1] orthogonal

[Downloaded from hii.khu.ac.ir on 2024-04-20]
[DOR: 20.1001.1.24237418.1399.7.1.5.7]

نتیجه‌گیری

متن‌کاوی یا تجزیه‌وتحلیل متن یکی از حوزه‌های خاص داده‌کاوی است. ازآنجاکه اکثر اطلاعات (بیش از ۸۰٪) به‌صورت متن ذخیره‌شده‌اند، و حاوی اطلاعات ارزشمند و نهفته‌ای هستند، اعتقاد بر این است که متن‌کاوی ارزش بالقوهٔ بالایی دارد. متن‌کاوی برای شناسایی موضوع از مدل‌های متمایزکننده مثل تجزیه‌وتحلیل معنایی پنهان تا مدل‌های مولد مثل تجزیه‌وتحلیل معنایی پنهان احتمالاتی، تخصیص دیریکله پنهان و مدل‌سازی موضوعی همبسته توسعه‌یافته است. در این مقاله ویژگی‌ها و محدودیت‌های چهار روش متن‌کاوی شامل LSA، PLSA، LDA و CTM موردبحث و بررسی قرار گرفت. زمینه‌های نظری در هر چهار روش بیان گردید و عملکرد چهار روش در تشخیص موضوع مورد مقایسه واقع شد. یافته‌ها نشان می‌دهد که در فرایند تشخیص موضوع، LSA می‌تواند برای تشخیص موضوعات خاص و منحصربه‌فرد در مدارکی که تنها به یک موضوع پرداخته‌اند استفاده شود. سه روش دیگر موردبررسی، بر موضوعات و گرایش کلی متن متمرکز هستند. PLSA برای مدارکی که به یک موضوع پرداخته‌اند قابل‌استفاده است اما برخلاف LSA، این روش در کشف موضوعات و مضامین کلی متن کاربرد دارد. درحالی‌که LDA در مورد مدارکی که به چندین موضوع پرداخته‌اند کاربرد بیشتری دارد. روش CTM می‌تواند در تشخیص ارتباط بین دسته‌های موضوعی مختلف استفاده شود. بنابراین رویکردهای متن‌کاوی به سبب بهره‌گیری از تحلیل معنایی در کشف و استخراج موضوع متون مناسب است. بر این پایه با توجه به قابلیت های تکنیک های مذکور پیشنهاد می گردد که به انجام پژوهش در زمینه کشف موضوعات و روابط پنهان در حوزه های علوم، بازیابی اطلاعات، دسته بندی مدارک بر اساس موضوعات، کشف الگوهای برجسته و رویدادهای در حال ظهور، خوشه بندی مفاهیم حوزه های علمی، تحلیل سیر تحول مفهومی در طول دوره های زمانی، غنی سازی فهرست واژگان، تعیین روابط سلسله مراتبی مفاهیم یک حوزه یا زمینه خاص علمی، و همچنین در الگوسازی و بازنمایی دانش در محیط های وب پایه مثل امور تجاری و بانکی، متن کاوی برای مدیریت ارگان های آموزشی و پژوهشی ، مدیریت دانش، بررسی پایگاه های اطلاعاتی استفاده شود. این امر منجر به غنای ادبیات نظری و پژوهش های عملیاتی بیشتر در این حوزه منجر خواهد شد.

تعارض منافع

گزارش نشده است.

منبع حمایت کننده

گزارش نشده است.

References

Abosaba Kazemaini, A(2011). Comparison of Comprehensiveness and Prevention of Recovered Information Based on Front and Back Storage Storage Systems in Persian Library Software. Master thesis. Department of Library & Information Science, Faculty of Educational Sciences and Psychology, Isfahan University.

Babu, P, B., Sarangi, A.K., & Madalli, D. P. (2012). "Knowledge Organization Systems for semantic digital Libraries". International Conference Trends in Knowledge and Information Dynamics. Bangolare, Pakistan. Retrieved from: http://eprints.rclis.org/19759/1/KOS semantic Digital Libraries.pdf

Bitterman, Andre; Fischer, Andreas (2018). How to identify hot topics in psychology using topic modeling. Zeitschrift fur psychologie. 226(1), 3-13.

Blei, D. M., & Lafferty, J. D. (2007). A correlated topic model of science. The Annals of Applied Statistics, 17-35.

Blei, D; Ng, A; Jordan, M (2003), "Latent dirichlet allocation," Journal, 3, 993–1022.

Blei, David & Lafferty, John (2007). A correlated topic model of science. The annual of applied statistics,1(1), 17-35.

Chien, Jt(2016). Hierarchical theme and topic modeling. IEEE trans neural netw learn syst.27(3): 565-578. Available at: https://www.researchgate.net/publication/274394886 Hierarchical Theme and Topic Modeling

Dean, J(2014). Bigdata, datamining & machine learning: Value creation for business leader and practitioners, Retrieved from: https://www.wiley.com/en-ir/Big Data, Data Mining, and Machine Learning: Value Creation for Business Leaders and Practitioners-p-9781118618042

Drakos, G(2019). NLP Tutorials: topic modeling with SVD and truncated SVD. GDcoder. Retrieved from: https://medium.com/@george.drakos62/nlp-tutorial-topic-modeling-with-singular-value-decomposition-svd-and-truncated-svd-fbpca-and-5fa612277c22.

Efsun ,S., Yadav, K., Chio, H. A (2017). Topic modeling based classification of clinical report. Association for computational linguistics, 67-73. Retrieved from: http://aclweb.org/anthology/P13-3010.

Fang EX, Li M-D, Jordan MI, Liu H (2018) Mining massive amounts of genomic data: a semi parametric topic modeling approach

Fang, D., Yang, H., Gao, B. and Li, X. (2018), "Discovering research topics from library electronic references using latent Dirichlet allocation", Library Hi Tech, 36(3), 400-410. https://doi.org/10.1108/LHT-06-2017-0132

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]

Figuerola, C.G., García Marco, F.J. & Pinto, M. Scientometrics (2017) 112: 1507. Retrrieved from: https://doi.org/10.1007/s11192-017-2432-9.

Gupta ,V.and G. Lehal(2009)"A Survey of Text Mining Techniques and Applications", Journal of Emerging Technologies In Web Intelligence, 1.

Hagen, Loni(2018). Content analysis of e-petition with topic modeling: how to train and evaluate LDA models? Information processing & management,54(6), 1292-1307.

Heydari, F(2014). Web users clustering and initial fetching of web pages using hidden probabilistic semantic analysis. Master thesis. Isfahan University of Technology.

Hinde J. (2011) Logistic Normal Distribution. In: Lovric M. (eds) International Encyclopedia of Statistical Science. Springer, Berlin, Heidelberg

Hofmann T.(2001) "Unsupervised learning by probabilistic latent semantic analysis," Machine learning, 42(1-2), 177-196.

Hwang, S.Y., Wei, C.P., Lee, C.H., & Chen, Y.S. (2017). Coauthor ship network based literature recommendation with topic model. Online Information Review, 41(3), 318-336.

Khademian, M., Kokabi, M(2018). Liberian Thing's Social Labels Versus Subject Headings in the Library of Congress: Review of Texts. Journal of Library and Information Science, 8 (1,) 313- 335. Retrieved 3/3/98, from : https://infosci.um.ac.ir/index.php/riis/article/view/57823

Kinyanjui, Daniel (2016) Subject cataloguing and the principles on which the choice of subject headings should be based, GRIN Verlag: Munich.

Koller, D., and Friedman, N.(2009), "Probabilistic Graphical Models: Principles and Techniques", The MIT Press.

Kurata, K & et al (2018). Analyzing library and information science full-text articles using a topic modeling approach. 81Annual meeting of the association for information science & technology I nVancouvar of Canada (10-14, November, 2018). Retrived from: https://www.researchgate.net/publication/330812928 Analyzing library and information science full-text articles using a topic modeling approach

lee, S., Song, J & Kim,Y(2010). An Empirical comparison of four text mining methods.Journal of computer information system. 51(1):1-10. Retrieved from: https://www.researchgate.net/publication/286840108 An empirical comparison of four text mining methods

Meen Ch & Yongjun, Zh (July 18th 2018). Scientometrics of Scientometrics: Mapping Historical Footprint and Emerging Technologies in Scientometrics, Scientometrics, Mari Jibu and Yoshiyuki Osabe, IntechOpen, DOI: 10.5772/intechopen.77951. Available from: https://www.intechopen.com/books/scientometrics/scientometrics-of-scientometrics-mapping-historical-footprint-and-emerging-technologies-in-scientome

Mohammadian, B (2014) Identification of scientific theft in Persian documents based on thematic modeling. Master thesis. Department of Computer, Faculty of Engineering, Kharazmi University.

Mortazavi, A., Javaherian, A(2013). Application of single value decomposition to random noise attenuation in synthetic and real seismic data. Oil Research. (80), 123-134. Retrieved from: https://pr.ripi.ir/article 459 85173420168d8944de96e91cba871aa2.pdf

Nadezhda, Y & Aleksey, F(2018). Improving the quality of information retrieval using syntactic analysis of search query. Retrieved from: https://www.semanticscholar.org/paper/Improving-the-Quality-of-Information-Retrieval-of-Yarushkina-Filippov/d0955103ee4e4cd78a0d24f880a1cda7f3b35d5e

Newman, D., Hagedorn, K., Chemudugunta, C., & Smyth, P. (2007). Subject metadata enrichment using statistical topic models. JCDL. Retrieved from: https://www.researchgate.net/publication/220924369 Subject Metadata Enrichment using Statistical Topic Models

Norouzi, Y.,Khavidaki, S(2014). Social Semantic Digital Library: A Perspective for Digital Libraries in Iran. Rahyaft, 57, 63-74. Retrieved 5/8/98 from http://rahyaft.nrisp.ac.ir/article 13557.html

Rani, M., Dhar, A, K., Vyas, O.P(2017). Semi- Automatic terminology ontology learning based on topic modeling. Engineering Application of Artificial Intelligence, 63, 108-125. Retrived from: https://www.researchgate.net/publication/317195300 Semi-Automatic Terminology Ontology Learning Based on Topic Modeling

Rani, M., Dhar, A., Kumar; Vyas, O.P(2017). Semi-Automatic terminology ontology learning based on topic modeling. Engineering Application of Artificial Intelligence, 63, 108-125.

Sanandres, E; Madariaga, C; Abello, R(2018). Topic modelling of twitter conversations. Retrieved from: https://www.researchgate.net/publication/326450126 Topic Modeling of Twitter Conversations/citations

Selvi, M & et al (2019). Classification of medical dataset along with topic modeling using LDA. Lecture notes in electrical engineering 511.Springer.

Soergel, D (2004) .Indexing language and thesauri: construction and maintenance. Los Angeles, CA: Melville

[Downloaded from hii.khu.ac.ir on 2024-04-20]
[DOR: 20.1001.1.24237418.1399.7.1.5.7]

Sohrabi, B; Raeesi vanani, I; Baranizade Shineh, M (2017). Topic Modeling and classification of cyberspace papers using text mining. Cyberspace studies, 2(1), 103- 125.

Steyvers, M., & Griffiths, T. (2007). Probabilistic topic models. Handbook of latent semantic analysis, 427(7), 424-440.

Steyvers, M; Smyth, P; Rosen-Zvi, M; Griffiths, T, (2004) "Probabilistic author-topic models for information discovery," in Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Seattle, Washington.

Strunk Jr, W.(2007), “The elements of style”, Filiquarian Publishing, LLC.

Venkat N. Gudivada, Amogh R. Gudivada(2018). Hand book of ststistic. USA, Elsevier. Retrieved from : https://www.sciencedirect.com/topics/computer-science/vector-space-models

Zamani, M., Dianat, R., Sadeghzadeh, M(2013). Classification of Persian Texts Using Probabilistic Hidden Semantic Analysis Method, 1st National Conference on Application of Intelligent Systems (Soft Computing) in Science and Technology, Quchan, Islamic Azad University of Quchan.

Zhao, R., & K. Mao. 2018. Fuzzy Bag-of-Words Model for Document Representation. IEEE Transactions on Fuzzy Systems لی.26 (2): 794-804. doi:10.1109/TFUZZ.2017.2690222.

[Downloaded from hii.khu.ac.ir on 2024-04-20]

[DOR: 20.1001.1.24237418.1399.7.1.5.7]