

ارائه روشی برای استخراج کلمات کلیدی و وزن دهنده

کلمات برای بهبود طبقه بندی متون فارسی

وحیده رضایی^۱، مجید محمدپور^۲، حمید پروین^۳ و صمد نجاتیان^{*۴}

^۱ گروه ریاضی، واحد یاسوج، دانشگاه آزاد اسلامی یاسوج، ایران

^۲ گروه مهندسی کامپیوتر، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۳ گروه مهندسی کامپیوتر، واحد نورآباد محسنی، دانشگاه آزاد اسلامی، نورآباد محسنی، ایران

^۴ گروه مهندسی برق، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۱، ^۲ و ^۴ باشگاه پژوهشگران و نخبگان، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۳ باشگاه پژوهشگران و نخبگان، واحد نورآباد محسنی، دانشگاه آزاد اسلامی، نورآباد محسنی، ایران

چکیده

با توجه به گسترش روزافزون اطلاعات و وجود حجم انبوه متون غیرساخت یافته، استفاده از کلمات کلیدی نقش مهمی در بازبایی اطلاعات دارد. این در حالی است که استخراج کلمات کلیدی به صورت دستی مشکلات زیادی دارد. بنابرین استخراج کلمات کلیدی به صورت خودکار از نیازهای ضروری فناوری امروزه است. در این پژوهش سعی شده با استفاده از اصطلاح نامه که از نظامی ساختارمند برخوردار است، کلمات کلیدی با معنایتری از متون استخراج کرد و با آن ها طبقه بندی متون فارسی را بهبود بخشید. مراحلی که برای افزایش جامعیت جستجو باید سپری شود به این صورت است که در مرحله نخست کلمات زائد حذف و باقی کلمات ریشه یابی می شود؛ سپس به کمک اصطلاح نامه کلمات هم معنی، اعم ها و اخص ها و همچنین وابسته ها پیدا و در ادامه برای مشخص شدن اهمیت نسبی کلمات یک وزن عددی به هر کلمه منسوب می شود که بیان گر میزان تأثیر کلمه در ارتباط با موضوع متن و در مقایسه با سایر کلمات به کار رفته در متن است. با توجه به مراحل بالا و به کمک اصطلاح نامه، طبقه بندی متون دقیق تر انجام می گیرد. در این روش از الگوریتم نزدیکترین همسایه (KNN) برای طبقه بندی استفاده می شود. الگوریتم KNN به خاطر سادگی و مؤثر بودن آن در طبقه بندی متون بسیار به کار برده می شود. مبنای کار این الگوریتم، مقایسه متن آزمایش داده شده با متون آموزشی داده شده و به دست آوردن میزان شباهت بین آن ها است. نتایج آزمایش ها بر روی چندین متن در موضوع های مختلف، نشان دهنده دقت و توانایی روش پیشنهادی در استخراج کلمات کلیدی منطبق با خواست کاربر و درنتیجه طبقه بندی دقیق تر متون است.

واژگان کلیدی: اصطلاح نامه، بازبایی اطلاعات، استخراج کلمات کلیدی، وزن دهنده.

An Approach for Extraction of Keywords and Weighting Words for Improvement Farsi Documents Classification

Vahideh Rezaei¹, Majid Mohammadpour², Hamid Parvin³ & Samad Nejatian^{*4}

¹ Department of Mathematics, Yasooj Branch, Islamic Azad University, Yadooj, Iran.

² Department of Computer Engineering, Yasooj Branch, Islamic Azad University, Yasooj, Iran.

³ Department of Computer Engineering, Nourabad Mamasani Branch, Islamic Azad University, Nourabad Mamasani, Iran

* Corresponding author

* نویسنده عهده دار مکاتبات

Abstract

Due to ever-increasing information expansion and existing huge amount of unstructured documents, usage of keywords plays a very important role in information retrieval. Because of a manually-extraction of keywords faces various challenges, their automated extraction seems inevitable. In this research, it has been tried to use a thesaurus, (a structured word-net) to automatically extract them. Authors claim that extraction of more meaningful keywords out of documents can be attained via employment of a thesaurus. The keywords extracted by applying thesaurus, can improve the document classification. The steps to be taken to increase the comprehensiveness of search should be such that in the first step the stop words are removed and the remaining words are stemmed. Then, with the help of a thesaurus are found words equivalent, hierarchical and dependent. Then, to determine the relative importance of words, a numerical weight is assigned to each word, which represents effect of the word on the subject matter and in comparison with other words used in the text. According to the steps above and with the help of a thesaurus, an accurate text classification is performed. In this method, the KNN algorithm is used for the classification. Due to the simplicity and effectiveness of this algorithm (KNN), there is a great deal of use in the classification of texts. The cornerstone of KNN is to compare with the text trained and text tested to determine their similarity between. The empirical results show the quality and accuracy of extracted keywords are satisfiable for users. They also confirm that the document classification has been enhanced. In this research, it has been tried to extract more meaningful keywords out of texts using thesaurus (which is a structured word-net) rather than not using it.

Keywords: thesaurus, information retrieval, extraction of keywords, weight.

شامل اطلاعاتی است که نسبت به محتوای متن، خارجی محسوب می‌شوند؛ مثل نام نویسنده، تاریخ و محل انتشار و نام منتشرکننده، بخش دوم شامل محتویات اصلی متن است. در کتابخانه‌ها بخش نخست با نام دسته‌بندی توصیفی¹ و بخش دوم با نام دسته‌بندی موضوعی² شناخته می‌شود. شاخص‌گذاری به عملیات شناخت محتوای متن گفته می‌شود، و هنگامی که این عملیات به‌کمک وسایل پیشرفته رایانه‌ای صورت پذیرد، شاخص‌گذاری خودکار نامیده می‌شود.
[28]

در سیستم‌های بازیابی متن، شاخص می‌تواند به‌طور کامل به‌صورت خودکار تولید شود. تحقیقات درباره ایجاد و یا بهبود روش‌های تولید خودکار شاخص و نیز جستجوی اطلاعات در متون برای زبان‌های مختلف همواره در جریان بوده است. حساس‌ترین و مشکل‌ترین مرحله‌ای که

¹ descriptive cataloging

² subject cataloging

۱- مقدمه

طبقه‌بندی متون با استفاده از شاخص‌های کلیدی نقش مهمی در بازیابی اطلاعات دارد. امروزه در بیشتر کتب و مقالات به‌خصوص در زمینه علمی و فنی با بررسی شاخص به مطالب و موضوعات مطرح شده می‌توان پی برد. ساخت شاخص برای متن‌ها، استفاده از آن‌ها را برای پژوهش‌گران و خوانندگان آسان می‌سازد. یکی از مشکل‌ترین وظایف سامانه‌های مدیریت متن، بازیابی متن و امکان جستجوی کارا روی اطلاعات متنی است. بنابراین در یک سامانه بازیابی متن، لازم است ابتدا سامانه، مجموعه اقداماتی را در جهت ساخت یک شاخص مناسب، مجهز، و کارآمد روی واژه‌های متن انجام دهد. پس از ساخت شاخص، سامانه با استفاده از آن، در جواب به پرس و جوی کاربر، متونی را که مربوط به واژه‌های مورد درخواست کاربر هستند، یافته و می‌تواند ارائه کند.

اصلًا هر متنی دارای دو بخش است: بخش نخست

فصلنامی

اطلاعاتی در مورد بخش‌های مورد علاقه آن‌ها می‌دهد. کاربران سامانه‌های بازیابی اطلاعات، نیازهای اطلاعاتی بسیار گسترده و متفاوتی دارند. این کاربران ممکن است، پژوهش‌گرانی باشند که به دنبال مقاله در مورد موضوع خاصی می‌گردد؛ و یا مهندسانی که می‌خواهند بدانند آیا ایده مورد نظر آن‌ها قبلاً به ثبت رسیده است؛ یا خردیاران کالایی خاص باشند که اطلاعات جدیدی در مورد آن کالا می‌خواهند پیدا کنند؛ و یا وکلایی که به دنبال قوانین، رویه‌ها، و احکام صادره محاکم قضایی هستند. به عبارت دیگر، کاربران سامانه‌های بازیابی اطلاعات، در زمینه‌های مختلفی کار می‌کنند و دلایل متفاوتی، آن‌ها را به استفاده از امکانات سامانه‌های بازیابی اطلاعات، مجبور می‌کند [7].

مزایای استفاده از شاخص‌ها و عبارت‌های کلیدی :

- ۱- استخراج خودکار عبارت‌های کلیدی، یک متن بلند را به خلاصه‌ای کوتاه تبدیل می‌کند.
- ۲- عبارت‌های کلیدی به عنوان قسمتی از نتایج جستجو، همراه با سایر مشخصه‌های متن، بازیابی شده (همانند عنوان، قسمت‌هایی از متن، URL و ...) یا به جای آن‌ها می‌توانند نمایش داده شوند.
- ۳- در مواردی که به مشخصه‌هایی بیش از نام‌گذاری صرف، بهمنظور درک سریع‌تر متن نیاز داریم، شاخص‌ها می‌توانند مفید باشند. به عنوان مثال، اگر نام یک فایل یا نامه الکترونیکی به عنوان برچسب با شاخص ادغام شوند، حالت بهتری را ایجاد می‌کند. در این حالت، مشاهده عبارت‌های کلیدی همراه با عنوان، به فهم محتوای نامه کمک بیشتری می‌کند.
- ۴- بر جسته‌کردن شاخص‌ها در متنون الکترونیکی به مرور سریع و اجمالی متن می‌تواند کمک کند.
- ۵- کمک به نویسنده یا ویراستار در تخصیص شاخص‌های کلیدی به متن. انجام این کار به صورت خودکار به عنوان یک استاندارد، نوعی یکدستی و مطابقت نوشته با کارکرد سامانه بازیابی اطلاعات و در نتیجه اطلاع‌رسانی صحیح‌تر را به همراه می‌تواند داشته باشد.
- ۶- در مواردی که با مشکل پنهانی خط یا مطابق با اصول نمایش گرافیکی اطلاعات با محدودیت فضای نمایشی مواجه هستیم، نمایش عبارت‌های کلیدی بسیار مفید است.

در روند شاخص‌گذاری خودکار باید طی شود، انتخاب واژه‌هایی است که برای ساخت شاخص به کار می‌روند.

در عمل، شاخص‌گذاری روی تمام واژه‌های متن، سربار بسیار زیاد دارد؛ ضمن این‌که شاخص‌گذاری روی تمام واژه‌ها یک کار غیرضروری است. کافی است تنها واژه‌هایی در شاخص به کار روند که نشان‌دهنده محتوای متن مربوطه هستند. در واقع واژه‌هایی که مورد علاقه کاربر بوده، و توسط وی جستجو می‌شوند.

در زمینه پردازش اطلاعات، سامانه‌های بسیاری ایجاد شده‌اند. این سامانه‌ها در پنج گروه عمده دسته‌بندی می‌شوند، که عبارتند از: سامانه‌های اطلاعات مدیریتی^۱، سامانه‌های مدیریت پایگاه داده^۲، سامانه‌های تصمیم‌گیری^۳، سامانه‌های پرسش و پاسخ^۴ و سامانه‌های بازیابی اطلاعات^۵ [33]. سامانه‌های بازیابی متن در گروه سامانه‌های بازیابی اطلاعات قرار می‌گیرند. از آن‌جا که شباهت‌های زیادی بین سامانه‌های بازیابی اطلاعات و سامانه‌های مدیریت پایگاه داده وجود دارد، گاهی برخی افراد این دو سامانه را به اشتباہ یکی در نظر می‌گیرند. اکنون به بررسی خصوصیات این دو سامانه می‌پردازیم:

وظیفه یک سامانه مدیریت پایگاه داده، ذخیره‌سازی، نگهداری و بازیابی دقیق داده‌های موجود در سامانه است. اطلاعات به شکل عناصر داده‌ای معینی است که در جداول ذخیره می‌شوند. هر درخواست جستجو باید بیان گر مقادیر معینی از مشخصه‌های رکورد باشد. خروجی در این‌گونه سامانه‌ها، رکوردهای مجزا، بخش‌هایی از رکوردها یا جداول و ... است.

در سامانه‌های بازیابی اطلاعات، عملیات پردازش اطلاعات بر روی مستند^۶ انجام می‌گیرد و وظیفه سامانه بازیابی، ذخیره، ارائه و ایجاد امکان دسترسی به مستندات یا نماینده آن‌ها است. در سامانه‌های بازیابی متن، اطلاعات ورودی به صورت متن زبان طبیعی است (متن کامل و یا گلچین یا چکیده متن کامل). خروجی سامانه‌های بازیابی اطلاعات در پاسخ به یک درخواست جستجو، به شکل مجموعه‌ای از ارجاعات است. این ارجاعات به کاربران سامانه،

¹ Management Information System

² Data Base Management System

³ Decision Support System

⁴ Question Answering System

⁵ Information Retrieval

⁶ document

یکی از مشکل‌ترین وظایف سامانه‌های مدیریت متن، بازیابی متن^۱ و امکان جستجوی کارا روی اطلاعات متنی است. بنابراین در یک سامانه بازیابی متن، لازم است تا ابتدا سامانه، مجموعه اقداماتی را در جهت ساخت یک شاخص مناسب، مجهز و کارآمد روی واژه‌های متن انجام دهد. پس از ساخت شاخص، سامانه می‌تواند با استفاده از آن، در جواب به پرس‌وجوی کاربر، متنی را که مربوط به واژه‌های مورد درخواست کاربر هستند، یافته و ارائه کند.

از آن‌جاکه تعداد مستندات الکترونیکی فارسی به سرعت رو به رشد است، به کارگیری روش‌های کارآمد جهت طبقه‌بندی اطلاعات فارسی بسیار مورد اهمیت است. کلمات کلیدی مجموعه‌ای از لغات مهم در یک مستند هستند که توصیفی از محتوای مستند را فراهم می‌آورند و برای اهداف مختلفی قابل استفاده هستند. به عنوان مثال در مقالات علمی برای این‌که خواننده بتواند درک مناسبی از مقاله داشته باشد، شاخص‌ها و کلمات کلیدی مقاله عنوان می‌شوند. استخراج شاخص‌ها از مستندات، یک عملیات مهم در فرآیندهای مانند طبقه‌بندی و یا استخراج اطلاعات معنایی است. هم‌چنین شاخص‌ها می‌توانند در موتورهای جستجو به منظور برگرداندن نتایج دقیق‌تر و در زمان کوتاه‌تر مورد استفاده قرار گیرند. شاخص‌ها نکات اصلی متن را توصیف می‌کنند؛ لذا می‌توانند به عنوان یک ابزار، برای اندازه‌گیری شباهت متن مختلف به منظور طبقه‌بندی متن مورد استفاده قرار گیرند. در مجموع شاخص‌ها ابزار مفیدی برای جستجوی حجم زیادی از مستندات در زمان کوتاه هستند. با وجود اهمیت سرشار، تعداد بسیار کمی از مستندات در حال حاضر حاوی شاخص هستند. در واقع بسیاری از نویسندهای تماشی به استخراج شاخص ندارند و تنها در صورتی که مجبور به استخراج آن‌ها باشند، آن‌ها را در مستندات قرار می‌دهند. استخراج شاخص به‌طور دستی فرایندی بسیار دشوار و زمان‌بر است؛ بنابراین نیاز به یک فرایند خودکار است که آن‌ها را از مستندات خارج کند.

جستجو بر اساس شاخص طبقه‌بندی، یک ابزار قابل استفاده و قدرتمند است که امکان جستجوی سریع اطلاعات را در مجموعه‌های بزرگ از اسناد به راحتی می‌سرمایسد. این امر کاربر را در فرآینری قواعد و دستور یک زبان پرس‌وجوی ساخت یافته، به عنوان مثال پرس‌وجوی بولی، SQL و XQuery یا SQL و درک معانی پیچیده آن‌ها آزاد می‌گذارد.

۷- استخراج خودکار عبارت‌های نمایه‌ای متون نشریات و صفحات وب، خواندن و جستجوی اطلاعات نشریات را برای خوانندگان تسهیل می‌کند.

۸- حضور شاخص‌های کلیدی در نتایج جستجو به اصلاح و تعریف مجدد فرمول جستجو و حتی تغییر دیدگاه کاربران از ساختار موجود در یک زمینه خاص می‌تواند کمک کند؛ یعنی کاربران با افزودن یا حذف واژگان، دامنه جستجو را محدودتر کرده و ضریب دقت را می‌توانند بالاتر ببرند؛ درنتیجه، به بالا بردن ضریب دقت یا گستردگردن دامنه جستجو و درنتیجه، بالا بردن ضریب بازیابی کمک می‌کند. بنابراین می‌توان عبارت‌های کلیدی را به عنوان جزئی لازم برای سامانه‌های بازیابی و طبقه‌بندی اطلاعات معرفی کرد.

۹- در مفاهیم سازمان‌دهی اطلاعات در سامانه‌های بازیابی و طبقه‌بندی اطلاعات به گونه‌ای مؤثر از شاخص‌های کلیدی در دسته‌بندی و طبقه‌بندی مدارک می‌توان استفاده کرد.

در الگوریتمی که در این پژوهش مطرح می‌شود، ضمن به کارگیری روابط اعم و اخص و هم‌چنین روابط هم‌خانوادگی میان لغات، میزان دقت در طبقه‌بندی متون فارسی بهبود می‌یابد.

۱-۱- هدف و ضرورت انجام پژوهش

هنوز هم پراستفاده‌ترین و حجمی‌ترین اطلاعات موجود، متون غیر ساخت‌یافته هستند. به عنوان مثال در سامانه‌های بایگانی، اطلاعات متی زیادی در قالب نامه‌ها، دستورالعمل‌ها، جزوای و ... وجود دارد، و یا در یک کتابخانه رقمی، غالب اطلاعات به صورت متن است. سامانه نگهداری و به روزرسانی قوانین (حقوقی، مالیاتی، جزایی، و ...)، سامانه نگهداری و بازیابی مقالات و آرشیو الکترونیکی روزنامه‌ها و مجلات، سامانه‌های تولید و نگهداری اطلاعات وب (www)، و نیز سامانه‌های بازیابی رایانه‌ای نمونه‌هایی دیگر از این دست هستند. کلمات کلیدی در حقیقت نقش کلیدی در بازیابی اطلاعات دارد. امروزه در بیشتر کتب و مقالات به خصوص در زمینه علمی و فنی به مطالب و موضوعات مطرح شده با بررسی شاخص می‌توان پی برد. ساخت شاخص برای متن‌ها، استفاده از آن‌ها را برای پژوهش‌گران و خوانندگان آسان می‌سازد.

^۱-Email

کرده اند و هر چه این اصطلاح نامه به مرور زمان تکمیل تر شود تجزیه و تحلیل متون فارسی با سرعت، دقت و اطمینان بیشتری در آینده مواجه خواهد بود.

۲-۱- تحقیق ساختار پژوهش

در این بخش ساختار مقاله و بخش های مربوطه به اجمال توصیف می شود. این مقاله شامل پنج بخش است: بخش نخست، مقدمه و کلیات را بیان می کند. در بخش دوم مروری بر کارهای گذشته صورت گرفته است. فصل سوم روش پیشنهادی را تشریح می کند. فصل چهارم روش پیشنهادی را مورد ارزیابی و آزمایش قرار می دهد. فصل پنجم به ارائه نتایج حاصل از تحقیق می پردازد و در نهایت پیشنهادهایی درخصوص کارهای آینده ارائه می شود.

طبقه بندی متون براساس شاخص، یک مسئله بسیار مهم در پردازش زبان فارسی است. در زبان فارسی کلمات صورت های نگارشی پیچیده ای دارند و پوشش کلیه حالات دستوری کلمات با به کار گیری یک سری قواعد معین، ناممکن است؛ به همین دلیل استخراج شاخص و طبقه بندی متون به طور خودکار از در مستندات فارسی دشوار و پیچیده است. از طرفی کارهای چندانی در زمینه استخراج شاخص در متون فارسی انجام نشده است. بدون استخراج شاخص بسیاری از کاربردهای بازیابی اطلاعات مانند جستجوی متن، طبقه بندی مستندات، پالایش اطلاعات و خلاصه سازی متن، به نتایج مطلوبی نمی توانند دست یابند. بنابراین در این مقاله یک روش طبقه بندی متون فارسی ارایه می شود؛ به گونه ای که کارایی روش های بازیابی و طبقه بندی اطلاعات را افزایش دهند.

در این مقاله سعی شده است تا با استفاده از روابط موجود بین کلمات به کمک اصطلاح نامه روش مناسبی برای ساخت خودکار شاخص در متون فارسی ارائه شود؛ ضمن این که با به کار گیری روش طبقه بندی KNN، متون موجود با دقت بر اساس محتوا و موضوع دسته بندی شوند.

هدف از این مقاله ارائه راه کاری جدید برای وزن دهنده کلمات به کمک اصطلاح نامه در طبقه بندی متون فارسی جهت افزایش جامعیت جستجو است. با توجه به رشد و گسترش حجم اطلاعات و به موازات آن ضرورت به کار گیری و استفاده مؤثر از منابع اطلاعاتی، یکی از مهم ترین و اساسی ظریف نیازهای موجود، قابلیت دست یابی به اطلاعات مورد نیاز در مدت زمان مناسب است. در واقع انجام جستجو و یافتن اطلاعات مورد نظر بر اساس خواسته های کاربر اهمیت بالایی دارد.

در واقع در این پژوهش یک الگوریتم مناسب، جهت طبقه بندی متون مختلف بر اساس مفاهیم روابط اخص اعم و هم خانواده بودن میان کلمات استفاده شده در متون ارائه شده است. استفاده از این روابط موجب می شود پس از جداسازی واژه های یک متن، دقت فرآیند وزن دهنده به کلمات افزایش یابد و طبقه بندی متون با ضریب اطمینان بیشتری صورت گیرد.

از آن جا که در این راستا پژوهش های زیادی در جهت کشف روابط مختلف بین کلمات در متون مختلف فارسی صورت گرفته، پژوهش گران این امر هر یک به نوعی نسبت به ثبت یافته های خود و روابط تعريف شده لغات با یکدیگر، در فرهنگ اصطلاحات زبان فارسی یا همان "اصطلاح نامه" اقدام

۲- ادبیات پژوهش و کارهای مرتبط

پیشین

در زمینه طبقه بندی متون، اصطلاحات و واژگانی وجود دارند که برخی از آنها به شرح جدول (۱) اعلام می شود [۲].

(جدول-۱): اصطلاحات و واژگان
(Table-1): Terminology and vocabulary

مجموعه های است که در آن تنظیم و مرتب کردن واژه ها و عبارت های زبان، نه بر حسب الفبا، بلکه بر حسب مفاهیمی است که بیان می کنند فرهنگ مفاهیمی فرهنگ لغات متفاوت است.	اصطلاح نامه ^۱
مجموعه های از نوشتار در یک زبان است که می توان ویژگی های زبان را با استفاده از آن بازنمایی نمود.	پیکره زبانی ^۲
مجموعه از لغات و کلیه مشتقات آن است که در بعضی اوقات قوانین تولید واژه را نیز شامل می شود.	واژگان ^۳
مجموعه اطلاعاتی است که برای آموزش الگوریتم های با ناظر استفاده می گردد.	مجموعه آموزشی
مجموعه اطلاعاتی است که برای آزمایش الگوریتم های با ناظر و یا بدون ناظر استفاده می گردد.	مجموعه آزمایشی
کلماتی هستند که هیچ گونه ارزش معنایی و یا مفهومی از نقطه نظر طبقه بندی ندارند.	کلمات بی ارزش
کلمات خاصی که یک متن می تواند بر مبنای آن	کلمه کلیدی

¹Thesaurus

²Corpus

³Lexicon

نمی باشد. در حقیقت این پیشفرضها اگرچه هزینه های طبقه بندی را افزایش می دهد، ولی برای قانونی بودن عملیات طبقه بندی متون اجباری است [12]. طبقه بندی بر مبنای دانش از درون، یعنی یک متن تنها بر اساس اطلاعات معنایی اش طبقه بندی می شود. در زمینه طبقه بندی متون، کارهای زیادی انجام گرفته که در ادامه به برخی از آن ها اشاره شده است.

در سال ۱۳۹۵، راد و همکارانش، یک روشی جدید را برای شاخص گذاری خودکار و استخراج کلمات کلیدی برای بازبایی اطلاعات و خوشه بندی متون ارائه داده است [1]. در این مقاله سعی شده است با استفاده از اطلاعات زبان شناختی و اصطلاح نامه، کلمات کلیدی با معنایتری ارائه شود. با استفاده از اصطلاح نامه که از نظامی ساختار مند برخوردار است شبکه کلمات کلیدی، شامل کلمات همارز، کلمات سلسله مراتبی و وابسته را می توان تکمیل کرده و افزایش داد. بنابراین توافق بین جستجوی کاربران و کلمات کلیدی متنی را بیشتر می توان کرد و جامعیت جستجو را افزایش داد. در مرحله نخست کلمات غیر مهم و عمومی حذف می شوند؛ سپس کلمات متن ریشه بیانی می شوند و در ادامه برای مشخص شدن اهمیت نسبی کلمات با استفاده از روش های وزن دهی یک وزن عددی به هر کلمه منسوب می شود که بیانگر میزان تأثیر کلمه در ارتباط با موضوع متن و در مقایسه با سایر کلمات به کار رفته در متن است. مجموعه عملیات بالا به خصوص استفاده از اصطلاح نامه باعث می شود که دسته بندی متون دقیق تر انجام گیرد و به نوعی رده علمی سلسله مراتبی متون در حوزه بازیابی اطلاعات نیز مشخص می شود [1].

در سال ۲۰۰۴، دیگان و همکارانش از دو منبع مختلف گنجوازه و صفحات خبری وب، برای استخراج کلمات استفاده کردند. آن ها برای هر لغت از مدل های احتمالی مارکوف و بین هر لغت و اصطلاح نامه از برچسب های معنایی استفاده کردند. در کار آن ها استخراج لغات کلیدی خروجی یک فرآیند پیچیده بود. دقت این سامانه بسیار قابل توجه بود و این نخستین سامانه ای بود که از گنجوازه استفاده می کرد [13].

در سال ۲۰۰۶، هیون سعی کرد از رابطه سلسله مراتبی و طبقه بندی علوم در استخراج کلمات کلیدی استفاده کند. مزیت این روش، استخراج ک کلمات کلیدی و محدودیت آن، این بود که فقط به بخشی از خواص گنجوازه که همان خاصیت طبقه بندی است، پرداخته شده بود [18].

نمی باشد. در حقیقت این پیشفرضها اگرچه هزینه های طبقه بندی را افزایش می دهد، ولی برای قانونی بودن عملیات طبقه بندی متون اجباری است [12]. طبقه بندی بر مبنای دانش از درون، یعنی یک متن تنها بر اساس اطلاعات معنایی اش طبقه بندی می شود. در زمینه طبقه بندی متون، کارهای زیادی انجام گرفته که در ادامه به برخی از آن ها اشاره شده است. <td>اندیس گذاری گردد. این کلمات یا عبارات به نوعی متن را طبقه بندی می کنند.</td>	اندیس گذاری گردد. این کلمات یا عبارات به نوعی متن را طبقه بندی می کنند.
در صورتی که مجموعه ای از متون $D = \{(d_1, y_1), \dots, (d_n, y_n)\}$ داشته باشیم، به طوری که n تعداد متون و $d_i = [w_i, 1, \dots, w_i, k, \dots, w_i, d_i]$ ، متن y_i این مجموعه باشد که w_i, k کلمه k ام متن i ام باشد و y_i به طبقه ای که $C = \{c_1, c_2, \dots, c_{ C }\}$ مجموعه طبقه های از پیش تعریف شده در سامانه باشد) اشاره کند. هدف در طبقه بندی متون استنتاج یک تابع رابطه ای f است به نحوی که $y_i = f(d_i)$ باشد. یا به صورت کامل تر، طبقه بندی متون تعیین یک مقدار بولی ^۱ برای هر جفت $\langle d_j, c_i \rangle \in \hat{ID} * C$ در جایی که D مجموعه ای از متون C مجموعه طبقه های از پیش تعیین شده است. مقدار T تعیین می کند که متن d_j به طبقه c_i متعلق است و مقدار F نیز عدم تعلق متن d_j به c_i را نشان می دهد. هدف اینجا به دست آوردن تخمین تابع $\{T, F\}$ است. از این قسمت به بعد فرض می شود (دانشگاه علم و صنعت ایران ۱۳۸۸) [2]:	
- طبقه ها تنها بر چسب های نمادین هستند و هیچ دانش اضافی (به لحاظ اجرایی یا تعریفی) با خود به همراه ندارند.	- دانش از بیرون ^۲ (اطلاعاتی از منبع خارجی جهت طبقه بندی) موجود نباشد. بنابراین طبقه بندی می بایست تنها بر اساس دانش از درون ^۳ (دانشی که از خود متن به دست می آید) انجام گیرد. به عبارت دیگر اطلاعات دیگر همچون نویسنده، تاریخ انتشار در دسترس نباشد.

روش های طبقه بندی متون که در مورد آن ها بحث خواهد شد، به طور کامل کلی بوده و برای یک زمینه خاص

¹ Boolean

² Exogenous Knowledge

³ Endogenous Knowledge

۱-۲- طبقه بندی متون

در صورتی که مجموعه ای از متون $D = \{(d_1, y_1), \dots, (d_n, y_n)\}$ داشته باشیم، به طوری که n تعداد متون و $d_i = [w_i, 1, \dots, w_i, k, \dots, w_i, |d_i|]$ ، متن y_i این مجموعه باشد که w_i, k کلمه k ام متن i ام باشد و y_i به طبقه ای که $C = \{c_1, c_2, \dots, c_{|C|}\}$ مجموعه طبقه های از پیش تعریف شده در سامانه باشد) اشاره کند. هدف در طبقه بندی متون استنتاج یک تابع رابطه ای f است به نحوی که $y_i = f(d_i)$ باشد. یا به صورت کامل تر، طبقه بندی متون تعیین یک مقدار بولی^۱ برای هر جفت $\langle d_j, c_i \rangle \in \hat{ID} * C$ در جایی که D مجموعه ای از متون C مجموعه طبقه های از پیش تعیین شده است. مقدار T تعیین می کند که متن d_j به طبقه c_i متعلق است و مقدار F نیز عدم تعلق متن d_j به c_i را نشان می دهد. هدف اینجا به دست آوردن تخمین تابع $\{T, F\}$ است. از این قسمت به بعد فرض می شود (دانشگاه علم و صنعت ایران ۱۳۸۸) [2]:

- طبقه ها تنها بر چسب های نمادین هستند و هیچ دانش اضافی (به لحاظ اجرایی یا تعریفی) با خود به همراه ندارند.

- دانش از بیرون^۲ (اطلاعاتی از منبع خارجی جهت طبقه بندی) موجود نباشد. بنابراین طبقه بندی می بایست تنها بر اساس دانش از درون^۳ (دانشی که از خود متن به دست می آید) انجام گیرد. به عبارت دیگر اطلاعات دیگر همچون نویسنده، تاریخ انتشار در دسترس نباشد.

روش های طبقه بندی متون که در مورد آن ها بحث خواهد شد، به طور کامل کلی بوده و برای یک زمینه خاص



مثال Zhang در سال ۲۰۰۶ از الگوریتم طبقه بندی C 5.0 استفاده کرده است [39]. چوبی و همکاران در سال ۲۰۱۴ [11] با استفاده n-gram و wordnet متون را در مورد تروریسم طبقه بندی کرده و به دقت قابل قبولی دست یافته‌اند. تانگیل و همکاران در سال ۲۰۱۴ [35] از طبقه بندی متون برای شناسایی بدافزارهای سیستم عامل اندروید استفاده کرده‌اند. آن‌ها طبقه بندی متون را بررسی کردند که برنامه‌های تحت اندروید اعمال کرده‌اند تا مشخص کنند که کدام کدهای منبع متعلق به بدافزارها هستند. کولاس و همکاران در سال ۲۰۱۴ [9] روشی برای طبقه بندی متون به صورت تک برچسب^۱ در حالتی که تعداد اسناد برچسب خورده کم باشند را ارائه دادند. روش آن‌ها برگرفته از تکنیک‌های Topic Modelling بوده و مبنی بر الگوریتم LDA کار می‌کرد.

۲-۲- سامانه‌های طبقه بندی متون و اهمیت آن

در ده سال اخیر مدیریت مبنی بر محتوای متون (که تحت عنوان کلی بازیابی اطلاعات شناخته می‌شوند) به علت رشد سریع و در دسترس قرار گرفتن متون به شکل دیجیتالی، از اهمیتی دوچندان برخوردار شده است. طبقه بندی متون یا عمل برچسب‌گذاری موضوعی متون زبان طبیعی، بر مبنای یک مجموعه از پیش تعیین شده، یکی از این موارد است. هم‌اکنون طبقه بندی متون در بسیاری از زمینه‌ها، از شخص‌گذاری متون بر مبنای یک لغتنامه کنترل شده^۲، فیلتر کردن متون، تولید خودکار فراداده، ابهام زدایی از کلمه^۳، تولید کاتالوگ‌های سلسله‌مراتبی از منابع وی^۴ و به طور کلی در هر کاربردی که نیاز به سازماندهی مستندات یا توزیع انتخابی و تطبیقی خاصی از مستندات مدنظر باشد، کاربرد دارد. از آن‌جا که برای ساختن طبقه‌ها نیازی به دانش مهندسی یا افراد خبره آن زمینه ندارد، مزایای این رهیافت، دقت قابل مقایسه در مقابل دقت به دست آمده از فرد خبره و کاهش قابل توجه در هزینه انسانی است.

¹ single label

² Controlled Dictionary

³ Word Sense Disambiguation

⁴ Population Of Hierarchical Catalogues Of Web Resources

در سال ۲۰۰۶، ویتن و مدلی سعی کرده‌اند که روشی جدید و پیشرفته برای استخراج کلمات کلیدی بر اساس اطلاعات معنایی پیشنهاد تا مشکلات موجود پیشین را حل کنند. آن‌ها یک الگوریتم بر اساس اندیس‌های گنجوازه برای مستندات که KE + نامیده می‌شد، ارائه دادند که در آن از روش‌های فی‌یادگیری ماشین و اطلاعات معنایی استفاده می‌شد. مزیت اصلی این سامانه فرهنگ لغات کنترل شده است [38].

مزدک و هسل یک سامانه به نام FarsiSum [20] ارائه دادند که نسخه تغییر یافته یک سیستم خلاصه‌سازی متون سوئدی به نام Swe Sum برای پوشش زبان فارسی است [14]. زمانی‌فر، مینایی و شریفی نیز یک سیستم خلاصه سازی برای متون فارسی با استفاده از استخراج کلمات کلیدی ارائه کرده‌اند. هم‌چنین آن‌ها به توسعه این سامانه پرداخته و راهکاری برای کشف مشابهت متون و بازیابی اطلاعات ارائه کرده‌اند [37].

آقای پروین و همکاران در مقاله خود روشی نوین برای بهبود طبقه بندی متون فارسی ارائه داده‌اند که در آن، از اصطلاح‌نامه به عنوان ابزاری سودمند برای دست‌یابی به تکرار کلمات در متون فارسی استفاده می‌شود. در اصطلاح‌نامه مورد استفاده، سه نوع رابطه در نظر گرفته شده که این نخستین تلاش برای به کارگیری اصطلاح‌نامه فارسی در زمینه بازیابی اطلاعات فارسی است [31].

لیو و همکارانش فرآیند کلی برای استخراج کلمات کلیدی را ارائه کرده‌اند که در این فرآیند ابتدا کلمات کلیدی نامزد، تشخیص و به هر کلمه وزنی اختصاص داده شده و در نهایت کلمات کلیدی با بیشترین وزن انتخاب می‌شوند [25].

فرانتری و همکارانش تحلیل آماری و زبان‌شناسی را با یکدیگر ترکیب کرده‌اند. آن‌ها معتقد بودند که اطلاعات آماری بدون اطلاعات زبان‌شناسی کلمات غیرمفید و غیرکلیدی را هم در نظر می‌گیرد [14].

Freitas and Kaestner در سال ۲۰۰۵ به دنبال پژوهش‌های قبلی و برای رفع مشکلات استخراج کلمات غیر کلیدی، با توجه به مجموعه‌ای از سندهای آموزشی و کلمات کلیدی مشخص برای آن‌ها، فرایند استخراج کلمات کلیدی را به عنوان یک مدل طبقه بندی کرده‌اند و کلمات بر اساس مشخصه‌هایی که دارند به "کلمات کلیدی" و "غیرکلیدی" طبقه بندی شدند و آن‌گاه احتمالات طبقه بندی به صورت آماری از مجموعه آموزشی یاد گرفته می‌شوند [16]. برای

گروه‌ها، بعضی دیگر را پوشش می‌دهند. از کاربردهای طبقه‌بندی متون به سامانه‌های خودکار پاسخ به سؤالات [30]، فیلترکردن اطلاعات، تشخیص موضوعیت داده‌ها و نامه‌های الکترونیکی بی‌ازش، تشخیص عنوان و دیگر زمینه‌های مرتبط می‌توان اشاره کرد [30]. از دیگر کاربردها مواردی همچون طبقه‌بندی گفتاری^۳ که ترکیبی از طبقه‌بندی متون و تشخیص گفتار^۴ است [32]، طبقه‌بندی متون چندرسانه‌ای^۵ از طریق عنوان‌های متنی [29].[32] تشخیص نویسنده برای متون ادبیاتی نامشخص یا مورد بحث [15]، تشخیص زبان برای متونی که زبان آن‌ها نامشخص است [8]، تشخیص خودکار جنس متن^۶ [22] و رتبه‌بندی خودکار کیفیت نوشتار^۷ [24] است.

۲-۳ - اصطلاح‌نامه

اصطلاح‌نامه مجموعه‌ای شامل واژه‌ها، اصطلاحات و اطلاعات مربوط به یک حوزه خاص از معرفت بشری است. این مجموعه، واژگان زبان نمایه‌ای کنترل شده‌ای است که طوری سازمان یافته تا روابط پیشین میان مفاهیم (اعم و اخص و ...) را روش‌ن کند [1]. واحد تشکیل‌دهنده اصطلاح‌نامه، واژه‌هایی است که تبلور اطلاعات و دربرگیرنده مسائل متن و مدرک مورد نظر است، که این‌ها را در اصطلاح واژه‌ها یا نشانه‌های کلیدی یا کلیدواژه می‌گویند. استخراج کلیدواژه از داخل متون و منابع به بازیابی اطلاعات متن کمک شایانی می‌کند. اصطلاح‌نامه، برای شاخص‌گذاری و جستجو مورد استفاده قرار می‌گیرد. برای استفاده افرادی که شاخص‌گذاری می‌کنند، ممکن است اصطلاح‌نامه‌ای ساده تهیه شود، که فقط فهرست الفبایی از واژه‌ها و اصطلاحات را با برقرارکردن یک نوع رابطه (رابطه همارز، مترادفات و شبه‌مترادفات) نشان دهد؛ ولی همان‌گونه که در تعریف اصطلاح‌نامه آمده است، باید اصطلاح‌نامه به شکل یک شبکه منطقی و سلسله‌مراتبی تنظیم شود که روابط معنایی و پیشین (در واقع موجود) میان اصطلاحات در یک حوزه علمی را در ساختاری منظم و گویا و در عین حال مستند و پویا ارائه کند. درواقع، هرگاه پژوهش‌گری اصطلاح‌نامه را به دست می‌گیرد و اصطلاحی را می‌یابد، روابط قبل و بعد و جایگاه اصلی و فرعی و بالا و

³ Speech Categorization

⁴ Speech Recognition

⁵ Multimedia Document Categorization

⁶ Automated Identification Of Text Genre

⁷ Automated Essay Grading

طبقه‌بندی متون به صورت دستی علاوه‌بر زمان‌بری و هزینه زیاد، معایب زیر را نیز با خود به همراه دارد [17].

۱- برای زمینه‌های تخصصی خاص، نیاز به دانش افراد

خبره دارد (مانند بانک‌های پزشکی، بانک‌های حقوقی)

۲- از آن‌جا که برچسب‌گذاری دستی مبتنی بر دانش و تجربه فرد می‌باشد، بسیار خط‌پذیر است.

۳- تصمیم دو فرد خبره در برچسب‌گذاری می‌تواند متفاوت و حتی ناسازگار باشد (سیستم ناسازگاری درونی دارد) [10].

امروزه بنابر آن‌چه گفته شد، طبقه‌بندی متون در تقاطع یادگیری ماشین و بازیابی اطلاعات مطرح است.

هم‌چنین برخی از مشخصات این مسئله، با مسائلی چون استخراج اطلاعات و دانش از متون و داده‌کاوی متون^۸

مشترک است [23]. با این حال مزد و تعریف دقیق آنها کماکان مورد بحث می‌باشد. داده‌کاوی متون با تحلیل

مقدار زیادی از متون و یافتن کاربرد الگوها، سعی می‌کند تا به استخراج احتمالی اطلاعات (تها با استفاده از

اطلاعات احتمالی) بپردازد. امروزه، این مسئله به‌طور روز افزون مورد استفاده قرار گرفته شده است. بر طبق این

دیدگاه، طبقه‌بندی متون یکی از نمودهای داده‌کاوی متون است. مفاهیم دسته‌بندی متون هم‌اکنون از یک ادبیات

عمیقی برخوردار گشته است؛ اما این مفاهیم عمده‌اً پراکنده بوده است. باید متذکر شد، گهگاه طبقه‌بندی خودکار متون در مقاله‌هایی مورد استفاده قرار می‌گیرد که با آن‌چه در

این‌جا مورد نظر است به‌طور کامل متفاوت است. از یک طرف تقسیم خودکار متون به طبقه‌های از پیش

تعریف شده، که در این‌جا مدعی نظر است و از طرف دیگر

تشخیص خودکار مجموعه‌ای از طبقه‌ها یا تشخیص خودکار

مجموعه‌ای از طبقه‌ها و گروه‌بندی متون بر مبنای آن که به‌طور معمول خوشبندی^۹ متون نامیده می‌شود و یا هر

کاری که برای قراردادن متون در گروه‌های خاصی باشد، قابل گسترش است [27].

مسئله طبقه‌بندی متون به کار آقای مارون برای

طبقه‌بندی متون به صورت احتمالی باز می‌گردد [28]. از آن

پس برای کاربردهای متنوع استفاده شده است. باید توجه داشت، از آن‌جا که بعضی از این گروه‌ها با هم هم‌پوشانی

دارند، مزه‌های بین این گروه‌ها دقیق نیست و بعضی از این

⁸ Text mining

⁹ Clustering

که محل آنها در مدرک مشخص شده پیدا کنند. یکی از پیشگامان شاخص گذاری خودکار که طرحی بر پایه تشخیص کثرت حضور اصطلاح در مدرک ارائه کرده است، اچ. پی. لون است[26].

این طرح به طور کلی از سه مرحله تشکیل شده است:

۱- تعداد واقعی هر مفهوم در هر مدرک تشخیص داده می شود.

۲- بر اساس نتایج مرحله نخست تعداد هر مفهوم در مجموعه مدارک محاسبه می شود.

۳- در پایان همه مفاهیمی که در بیشینه تعداد (H_{max}) یا در کمینه تعداد (H_{min}) ظاهر می شوند، جدا و سپس لغاتی که باقی می مانند به عنوان شاخص استفاده می شوند (ارزش های H_{max} و H_{min} با روش های مناسب تعیین می شوند).

این مراحل در روش لون در نگاه نخست بسیار ساده و قابل درک به نظر می رسد. در این روش همه مفاهیمی که به تعداد زیادی در یک پایگاه اطلاعاتی وجود دارند، به عنوان شاخص انتخاب نمی شوند. همچنین در این روش همه مفاهیمی که به ندرت در مدرک وجود دارند، بدون بار معنایی تلقی و فرض می شود که توان ارائه محتوای مدرک را ندارند. مزیت این روش در واقع گرایی آن و ضعف آن در تعیین فقط بیشترین و کمترین تعداد لغات است. به عبارت دیگر فرض بر آن است که مفاهیمی که اغلب در مجموعه داده ها وجود دارند، شاخص نیستند، چون با این مفاهیم مدارک را از یکدیگر نمی توان تفکیک کرد و مفاهیمی که به ندرت در مدارک می آیند، قابلیت ارائه محتوای مدارک را ندارند. با ضوابط مطرح شده طرح لون قواعد زیر را به دنبال دارد:

در این طرح از مرحله نخست دو عملکرد زیر امکان پذیر است:

۱- پس از مقایسه مدارک با اصطلاحات یک فهرست کلمات توقف، همه لغاتی که در این فهرست قرار دارند، انتخاب و حذف می شوند.

۲- مفاهیم باقیمانده بر اساس ریشه لغت تفکیک می شوند. بنابراین مفاهیم خانه، خانه ها بر اساس شکل خانه تفکیک می شوند.

در فهرست کلمات توقف یادشده حروف ریط، حروف تعریف، لغات دیگری از این قبیل وجود دارند که در متن بسیار زیاد هستند. آزمایش ها نشان می دهند که ۲۰٪ از بیشترین تعداد لغات متن به طور تقریبی ۷۰٪ از متن را شامل می شوند. مزیت روش لون واقع گرایی است؛ زیرا وظیفه اصلی

پایین آن را به سهولت می بیند، و شکی نیست که شناسایی جایگاه اصطلاح در علوم نقش مهمی در طرح ریزی موضوع و پژوهش دارد. به طور عمومی از اصطلاح نامه برای طبقه بندی، شاخص گذاری، ذخیره و بازیابی اطلاعات در بانک های اطلاعاتی می توان استفاده کرد.

۴-۲- اصطلاح نامه

رفع ابهام از کلمه^۱، یافتن درست کلمات همنویس در یک متن است. برای مثال "مرد" در معنای اسمی به انسان ذکور بالغ می تواند گفته شود و یا در معنای فعلی بن ماضی سوم شخص ساده از مصدر "مردن" باشد. بنابراین یکی از وظایف رفع ابهام انتخاب یکی از این دو حالت برای این کاربرد در جمله ماست. رفع ابهام برای بسیاری از کاربردها همچون بازیابی زبان های طبیعی، و شاخص بندی مستندات با استفاده از ترجیح نقش کلمه بر خود کلمه در حوزه بازیابی اطلاعات مورد توجه است. همچنین رفع ابهام ممکن است به صورت یکی از وظایف طبقه بندی متون دیده شود[13].

۵- بازیابی اطلاعات و استخراج کلمات کلیدی

بازیابی اطلاعات به طور اصولی مرتبط با بازیابی مستندات و مدارک است. کار معمول در بازیابی اطلاعات این است که بسته به نیاز مطرح شده از سوی کاربر، مرتبط ترین متون و مستندات را از میان دیگر مستندات یک مجموعه بیرون بکشد. این یافتن دانش نیست؛ بلکه تنها آن تعدادی از کلمات را که به نظرش مرتبط تر به نیاز اطلاعاتی جستجوگر است، به او تحويل می دهد. در بازیابی سند، اطلاعات، یک زیرمجموعه از اسناد هستند که در ظاهر مرتبط با پرس و جو است. تمام روش های جست و جو مبتنی بر مقایسه بین پرس و جو و سند ذخیره شده می باشند. بعضی مواقع این مقایسه به صورت غیر مستقیم و با مقایسه پرس و جو با کلمات کلیدی انجام می گیرد[6].

۶- شاخص گذاری خودکار

بر اساس استاندارد شاخص گذاری [26] (BS3700:1988) ^۲ شاخص ها مجموعه ای منظم از کلمات نشانه گذاری شده هستند تا کاربران را قادر سازند اطلاعاتی

¹ Word Sense Disambiguation (WSD)

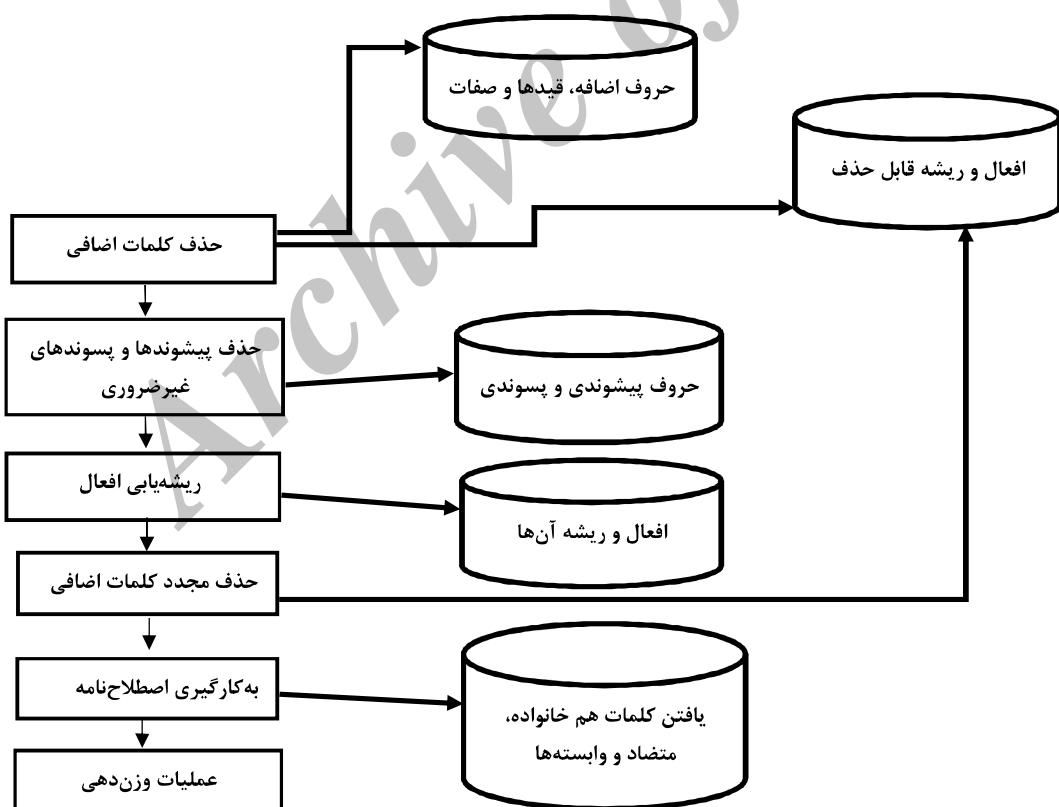
² British Indexing Standard

باعث شباهت مدارک به یکدیگر می‌شوند. چنین بسامد بالایی برای شاخص‌گذاری به هیچ وجه مناسب نیست [33]. براساس فرضیه هارتر در دو سطح با دو احتمال متفاوت برای یک اصطلاح تقسیم می‌شوند؛ سطح نخست برای مدارکی است که در آن‌ها یک اصطلاح وجود ندارد و سطح دوم برای مدارکی است که یک اصطلاح در آن حضور قابل توجهی دارد. هارتر نشان داد که احتمالات در سطح نخست اصطلاحات ناخواسته و بدون بار معنایی و در سطح دوم اصطلاحات معنی‌دار را بازیابی می‌کنند. بنابراین باید از روش‌های آماری مناسب و صحیح استفاده شود [19].

۳- راهکارهای پیشنهادی

در این بخش، روش پیشنهادی به منظور خودکارسازی طبقه-بندی متون فارسی به کمک اصطلاح‌نامه ارائه شده است. نمودار فرایند پیشنهادی در شکل (۱) نشان داده می‌شود. در ادامه این بخش تک‌تک مراحل معرفی شده در نمودار به تفصیل مورد بررسی قرار می‌گیرد.

محاسبه تعداد اصطلاحات و تفکیک آن‌ها بر اساس تعدادشان و مشکل این روش در تعیین مرز H_{min} و H_{max} است. حذف مفاهیمی با بیشینه تعداد جامعیت را می‌تواند پایین بیاورد و باعث شود که بسیاری از مدارک مرتبط نادیده گرفته شوند. حذف مفاهیمی با کمینه تعداد مانعیت را می‌تواند پایین بیاورد. سالتون بیان می‌کند که تا چه حد یک مفهوم در یک مدرک از یک مدرک دیگر قابل تشخیص است. در این روش در ابتدا عامل شباهت برای دو مدرک کی محسوبه می‌شود که شباهت میان آن‌ها باید مشخص شود. این شباهت هنگامی به عدد یک می‌رسد که هر دو مدرک به‌طور کامل مطابق یکدیگر شاخص‌گذاری شده‌اند. عامل شباهت برای هر جفت مدرک در نظر گرفته می‌شود و در پایان یک شباهت نسبی میان کل مدارک و انبوی مدارکی که مورد بررسی قرار می‌گیرند، حاصل و تفکیک آماری همه مفاهیم با یک کثرت نسبی محاسبه می‌شود. تفکیک آماری به صورت مثبت: برای مفاهیمی با بسامد متوسط باید هنگام شاخص‌گذاری ارجحیت قائل شویم. تفکیک آماری به صورت منفی: مفاهیمی که با تعداد زیاد در مدارک وجود دارند و



(شکل-۱): روش پیشنهادی
(Figure-1): Proposed Method

است
هست
....
من
ما
...
از
و
...

(شکل-۲): فایل متنی شامل کلمات اضافی که حذف آنها در مضمون کلی متن اثر ندارد.

(Figure-2): The text file contains stop word that have no effect on the overall text content.

دارد. کلمات انگلیسی دارای پیشوندها و پسوندهای فرموله شده‌ای هستند که با استفاده از این الگوریتم‌ها، امکان جداسازی آنها از ریشه کلمه وجود دارد. برای مثال: (go + ing) → going (soft + ness) → softness (soft + nesss) → softness ریشه با وجود ساخت‌یافتنی نسبی کلمات انگلیسی، این زبان استثنایی هم دارد که الگوریتم Porter قادر به شناسایی آنها نیست برای مثال کلمه "Bus" در این الگوریتم بهاشتباه یک کلمه جمع شناخته شده و "S" آن حذف می‌شود که خود ریشه است.

Bus-> Bu + s

اما دستور زبان فارسی استثنایی بیشتری دارد، که با استفاده از الگوریتم‌های فرموله‌بندی شده قابل تشخیص نبوده و در نتیجه امکان ریشه‌یابی آنها به‌طور صحیح وجود ندارد. قبل از آن که بیشتر به الگوریتم ریشه‌یابی پیشنهادی پرداخته شود، باید مشکل مرز بین واژگان حل شود. امروزه تمام سامانه‌های کامپیوتری ذخیره و بازیابی اطلاعات، با زبان فارسی از نظر فاصله میان واژه‌ها و عبارت‌ها مشکل دارند. در صورتی که خط فارسی صدها سال است که توانسته ارتباط میان افراد را برقرار کند و هیچ مشکل غیرقابل حلی هم نداشته باشد. مشکل از جایی شروع می‌شود که پای فناوری نوین به میان می‌آید. بنابراین می‌توان نتیجه گرفت که راه حل این مشکل را یا باید در رسم الخط فارسی و یا در فناوری نوین یافت.

یکی از منطقی‌ترین راه حل‌ها برای رفع این مشکل آن است که منتظر باشیم فرهنگستان زبان و ادب فارسی رسم الخط دقیق و مدون فارسی را ارائه کند. اگر چنین رسم الخطی تدوین شود، به‌حتم مشکل فاصله میان واژه‌ها و عبارت‌ها نیز حل خواهد شد. در آن زمان باحتمال همه یکسان عمل خواهند کرد و مشکلات رسم الخط فارسی

۳-۱- تحلیل واژگانی

متون الکترونیکی فارسی موجود به‌صورت خام دارای مشکلات زیر هستند:

۱- عدم وجود رسم الخط یکسان: متأسفانه متون فارسی موجود از یک رسم الخط واحد پیروی نمی‌کنند. یکی از مهم‌ترین این دلایل، متدائل‌بودن بعضی از حالت‌های چسبیدن وندهایی همانند "ها" "به اسم‌ها در زبان فارسی است. برای مثال "کتابها"، "کتاب ها"، "کتاب‌ها".

۲- وجود کدهای متفاوت برای حروف فارسی: اگرچه سیستم یونیکد، سعی در یکسان‌سازی کدها برای کلیه زبان‌ها کرده است، ولی با این حال در مواردی برای پشتیبانی از کلیه حالت‌ها ناچار به استفاده از کدهای بعضی متفاوت برای یک حرف کرده است.

۳-۲- حذف کلمات اضافی

واژه‌های عمومی زبان در شاخص گذاری ارزش کمی دارند؛ به‌همین علت روند کلی شاخص گذاری با حذف واژه‌های عمومی آغاز می‌شود. از دلایلی که سبب می‌شود حروف اضافی را حذف کنیم این است که این‌ها کمکی به طبقه‌بندی نمی‌کنند و این که حجم بالایی دارند. این واژه‌ها حدود سی تا پنجاه درصد متون را تشکیل می‌دهند. درواقع این واژه‌ها، واژه‌ایی هستند که کاربر مایل به جستجوی آنها نیست. حذف کلمات اضافی نظیر حروف اضافه، بسیاری از قیدها و صفات، برخی از افعال (که خود ریشه‌اند)، حروف ربط و غیره به‌طور عمومی در مضمون کلی متن تأثیر منفی نمی‌گذارد، بلکه باعث خلاصه‌سازی متن می‌شود؛ به‌همین دلیل این کلمات را در یک فایل متنی (شکل ۲) می‌توان وارد کرده در هنگام اجرای برنامه این کلمات از فایل خوانده شده و در ساختمان سریع جدول درهم‌سازی، ریخته می‌شوند (این ساختار نیاز به جستجوی ترتیبی ندارد). هنگام بررسی هر مستند فارسی، کلمات اضافی موجود در این صفحه با جستجو در جدول درهم سازی، شناخته شده و از مستند حذف می‌شوند. نکته قابل توجه این است که در این مرحله، ما تنها افعال ریشه را از مستند حذف می‌کنیم. حذف سایر افعال که ریشه نیستند، پس از مرحله ریشه‌یابی انجام می‌شود.

۳-۳- ریشه‌یابی کلمات فارسی

برای ریشه‌یابی کلمات انگلیسی از الگوریتم‌های مختلفی استفاده می‌شود که مشهورترین آن‌ها الگوریتم Porter نام

وازگان عملیات ریشه‌یابی انجام نمی‌شود و خود واژه به عنوان ریشه اصلی در نظر گرفته می‌شود؛ اما در صورتی که واژه در فهرست واژگان موجود نباشد، تا حد ممکن الگوریتم ریشه‌یابی روی آن واژه اجرا می‌شود. چنان‌چه واژه حاصل شده در هر مرحله از الگوریتم، در فهرست واژگان موجود بود، عملیات مورد قبول واقع می‌شود و کار به پایان می‌رسد. در طراحی ریشه‌یاب سعی بر آن بوده است که ضمن حفظ انسجام، اجزاء مستقل از یکدیگر باشند، بنابراین سامانه از چندین بخش تشکیل شده است، این بخش‌ها عبارتند از:

الف) مجموعه قوانین ریشه‌یابی (برای زدودن پسوند و پیشوند) که با استفاده از قوانین ساخت واژه در زبان فارسی استخراج شده‌اند؛

ب) فهرست مصادر فارسی (اعم از افعال ساده، پیشوندی، و مرکب و نیز عبارت‌های فعلی)؛

ج) فهرست واژگان جمع مكسر که برای هر واژه جمع مكسر، مفرد آن را مشخص می‌کند.

د) فهرست واژگان جامد که کلیه واژگان فارسی به غیر از افعال و مشتقات آن، جمع‌های مكسر و نیز مابقی واژگان مشتق را نگهداری می‌کند. بدلیل این‌که چنین فهرستی برای زبان آزمایشی را، که اکنون حدود نه هزار واژه را در بردارد، می‌توان به مرور تکمیل‌تر کرد. برای آن‌که بتوان ریشه واژگانی را که از زبان عربی وارد فارسی شده‌اند، استخراج کرد، دو روش به‌نظر می‌رسد. یکی این‌که قواعد و ریشه‌های واژگان زبان عربی را نیز، هر چند محدود، در سامانه وارد و یا این‌که با استفاده از یک فرهنگ ترداد ف تمامی واژگان هم‌خانواده را فهرست کنیم.

۳-۴ - حذف مجدد کلمات اضافی

در این مرحله به‌طور تقریبی تمام افعال و اسمی با ریشه‌ها جایگزین شده‌اند. حال طی یک مرحله، دوباره کلمات اضافی، بر اساس فایل کلمات اضافی که در مرحله اول استفاده شد، حذف و برخی از افعال پس از حذف شناسه به افعال ریشه تبدیل می‌شوند که قابل حذف است. در پایان این مرحله بخش عظیمی از کلمات اضافی از متن حذف می‌شوند. فهرست واژگانی که در جدول (۱) آمده است توسط دکتر بی‌جن‌خان ایجاد شده است که حدود هشت‌صد لغت است که تنها بخشی از آن در جدول (۲) آمده است.

کاهش خواهد یافت. ویژگی عمدۀ این راه حل آن است که هم با سامانه‌ها و کاربران از یک رسم الخط تبعیت می‌کنند و میزان ناهمانگی در پایین‌ترین حد خواهد بود. این راه حل یک مشکل اساسی دارد، یعنی معلوم نیست چه زمان رسم الخط یکسان شده نهایی تدوین خواهد شد. در مورد پیوسته‌نویسی یا جدانویسی ده‌ها سال است که بحث و گفتگو وجود دارد و هنوز به نتیجه قطعی نرسیده است. حتی اگر در زمانی خاص نتیجه نهایی به دست آید و رسم الخط دقیق فارسی مشخص شود، برای این‌که همه آن را اجرا کنند باز هم به سالیان بسیاری وقت نیاز است.

راه حل دیگری نیز برای حل مشکل رسم الخط فارسی پیشنهاد شده است. در این راه حل نرم افزارها به گونه‌ای طراحی می‌شوند که هرگاه وارد کننده اطلاعات به بود یا نبود فضای خالی میان واژه‌ها شک داشته باشد با زدن علامتی میان آن واژه‌ها، ورود اطلاعات را ادامه می‌دهد. اما به‌نظر نمی‌رسد، چنین پیشنهادی بتواند مشکل مرز بین واژه‌ها را حل کند. با تمام این احوال، به کارگیری پیشنهادهای زیر معقول به نظر می‌رسد:

- ۱- قبل از هر واژه فاصله خالی درج شود.
- ۲- بین حروف اصطلاحات و واژه‌های لاتین که به‌طور دقیق منعکس‌کننده لفظ خارجی است، فاصله خالی درج نشود.

۳- انواع پیشوندها و پسوندها، پیوسته یا بدون فاصله خالی نوشته شوند. اگر نیاز باشد تا پسوند یا پیشوند به واژه اصلی به‌طور کامل متصل نشود (به عنوان مثال پسوند اند هنگام اتصال به واژه شده، به جای شده‌اند به صورت شده‌اند درآید). باید از نویسه‌های کنترلی موجود در نرم‌افزارهای حروف‌چینی استفاده و از درج فاصله خالی اجتناب کرد.

می‌دانیم که هر قانونی که برای ریشه‌یابی به کار رود، به راحتی بی‌قاعده‌گی‌ها و استثنایات فراوانی برای آن قانون می‌توان یافت. برای حل چنین مشکلی دو راه حل به‌نظر می‌رسد. یکی این‌که فهرستی از استثنایات نگهداری شود؛ دیگری این‌که از یک فهرست برای تشخیص واژه‌های درست استفاده شود. با توجه به فراوانی استثنایات در قوانین ریشه‌یابی، راه حل دوم در عمل مناسب‌تر به‌نظر می‌رسد. اکنون به الگوریتم پیشنهادی، برای ریشه‌یابی پرداخته می‌شود. در این الگوریتم ابتدا واژه در فهرست واژگان که فقط اسمی جامد را در بر می‌گیرد و از قبل آماده شده است، جستجو می‌شود. در صورت وجود واژه در فهرست

(جدول-۲): فهرست واژه های عمومی (stop word)
(Table-2): Stop word list

هممیشه	هر	میشوند	گرچه	روی	خودشان	چند گانه	به	ای	آن
همین	هربک	میکند	گرفته	زیرا	خودم	چندین	بیشتر	ایشان	آنان
هنوز	هست	میکنند	لکن	سپس	خودمان	چنین	بین	این	آنجا
هیچ	هستند	نظر	لیکن	شامل	خویش	چه	پس	اینجا	آنچه
هیچکدام	هستیم	نمیتوان	ما	شاید	داده	چون	تا	اینست	آنکه
هیچگونه	هم	نوع	مابین	شد	دارای	چیز	تایی	اینگونه	آنگاه
و	همان	نیاز	مانند	شده	دارد	چیزی	تو	ایها	آنها
وجود	همانطور	نیز	مختلف	شما	داشته	چیست	با	از	
و گرنه	همانند	نیست	من	شود	در	حتی	باشد	است	
ولی	همچین	نیستند	مورد	صورت	درباره	خواهد	باید	اگر	
وی	همچون	ها	میباشد	فقط	دو	خواهیم	بدون	اگرچه	
یا	همدیگر	های	میتوان	کدام	دیگر	خود	بر	الان	
یک	همه	هایی	میتواند	کرد	دیگران	خودت	چنانچه	اما	
یکدیگر	همواره	هر	میدهد	کردن	دیگری	خودتان	چند	بنابر	انجام

متراff پژوهش هایی صورت گرفته و بر اساس نتایج آن برای کلمات متراff ضریب وزنی "۱" محاسبه شده که به طور دقیق معادل وزن خود کلمه است. یعنی بیشینه وزنی که به یک کلمه می توان اختصاص داد.

۳-۳- به کارگیری اصطلاح نامه

در این مرحله با استفاده از اصطلاح نامه برای ویژگی های اصلی استخراج شده از بخش پیش پردازش، کلمات هم خانواده، متراff، و وابسته ها (اعم و اخص) شناسایی می شوند. به عبارت دیگر، برای تک تک کلمات اصلی متن، کلمات هم خانواده، متراff، منضاد، اعم و اخص و وابسته استخراج و در جایی نگه داری می شود. از این کلمات بعدها برای وزن دهی استفاده خواهد شد. هدف آن است که در صورت دیدن کلمات هم خانواده در متن، به جای آن که به صورت مجزا برای هر یک وزنی در نظر گرفته شود، یک کلمه از میان آن ها به عنوان نماینده انتخاب شده و مجموع وزن کلمات هم خانواده و وابسته به نماینده در متن براساس یک ضریب وزنی مشخص به وزن کلمه نماینده اضافه می شود.

روش استخراج کلمات کلیدی از متن از یک زاویه به دو صورت است:

۱- شاخص گذاری مبتنی بر اصطلاح نامه

۲- شاخص گذاری مبتنی بر متن کامل

شاخص گذاری مبتنی بر متن کامل، بر اساس کلماتی است که در متن خود مدرک آمده است؛ ولی در شاخص گذاری مبتنی بر اصطلاح نامه، ممکن است واژه های برای شاخص گذاری انتخاب شود که در متن نیامده باشد؛ ولی هم خانواده های آن ها موجود باشد. در این مقاله کلمات انتخاب شده براساس اصطلاح نامه می آید.

۳-۴- رابطه متراff

در کارهای گذشته در خصوص کلمات و عبارات هم معنی و



گرفت؛ اما در اصطلاحنامه مورد استفاده همه این کلمات در زیر رده آموزش و پرورش قرار می‌گیرد. در صورت عدم استفاده از اصطلاحنامه ممکن است، طبقه‌بندی صحیح متن مورد نظر به دلیل پراکنده‌گی کلمات اصلی امکان‌پذیر نباشد؛ اما در روش پیشنهادی برای هر یک از این کلمات، اعم آنها که همان آموزش است در نظر گرفته شده و به این ترتیب کلمه کلیدی آموزش امتیاز بالایی در متن پیدا می‌کند.

۳-۵-۴- رابطه اخص

در این حالت از کلمات خیلی کلی‌تر به جزئی‌تر می‌رسیم. مثال شکل (۵) در مورد جانوران است.

جانوران بهطور کلی به دو گروه مهره‌داران و بی‌مهرگان تقسیم می‌شوند. مهره‌داران نیز خود به ۵ گروه مجلزا شامل ماهی‌ها، دوزیستان، خزنگان، پرنده‌گان و پستانداران تقسیم می‌شوند که هر یک از این گروه‌ها به‌نوبه خود زیر گروه‌هایی دارند. بهطور مثال سفره‌ماهی در زیر گروه ماهی‌های غضروفی است و ماهی سفید در زیر گروه ماهی‌های استخوانی فaramی‌گیرد.

(شکل-۵): متن حاوی واژه‌های اخص

(Figure-5): The text containing specific terms

(جانوران: ۱ بار، مهره‌داران: ۱ بار، ماهی‌ها: ۵ بار) در متن بالا که در آن کلمات جانوران، ماهی‌ها، پستانداران و... استفاده شده است، این‌ها کلمات کلی هستند. از این کلمات متوجه می‌شویم که متن راجع به جانوران است؛ ولی وارد زیر شاخه می‌شویم تا متوجه شویم به‌صورت جزئی به کدام دسته‌بندی اشاره دارد. اگر به اخص آن‌ها اشاره کنیم به کلمه ماهی‌ها بر می‌خوریم و چون ماهی‌ها با وزن معقولی در متن هم وجود داشت، می‌فهمیم به‌طور کلی متن در مورد کلمه ماهی است. بدین ترتیب می‌توانیم متن‌ها را با دقت بالاتری طبقه‌بندی کنیم و با همان دقت بالا به پرس‌وجوهای کاربر پاسخ صحیح دهیم. پس اگر کاربری به‌طور خاص راجع به متون ماهی‌ها درخواست می‌دهد، در درجه نخست متن‌های مستقیم با ماهی در اختیار او قرار خواهد گرفت و درجه‌های بعدی متون مربوط به مهره‌داران و جانوران به آنها پاسخ داده خواهد شد.

هدف در این پژوهش هم‌چنین، ارائه یک الگوریتم معین جهت یافتن یک ضریب وزنی مشخص و دقیق برای کلمات دارای رابطه اعم و اخص است.

۳-۶- مرحله وزن‌دهی

۳-۶-۱- وزن‌دهی برای کلمات هم‌خانواده

برای این نوع کلمات وزن‌دهی به این ترتیب انجام می‌شود که برای کلمات هم‌خانواده موجود در متن به کمک اصطلاحنامه،

مثال: در شکل (۳) متنی حاوی واژه‌های هم‌خانواده عنوان شده است.

در محیط پیرامون ما هر روز حوادث زیادی اتفاق می‌افتد. بروز هر حادثه الزاماً دلایلی دارد که باید در مورد هر دلیل تحقیق و بررسی لازم صورت گیرد. ممکن است افراد مختلف استدلال‌های متفاوتی ارائه نمایند. لزوماً دلیل‌ها همیشه واضح و قابل مشاهده نخواهند بود و نیاز به بررسی بیشتر دارد.

(شکل-۳): متن حاوی واژه‌های هم‌خانواده

(Figure-3): Text containing family terms

در متن بالا داریم :

(دلایل : ۱ بار، استدلال : ۱ بار، دلیل : ۱ بار)

اگر فقط بخواهیم تعداد تکرارهای کلمات موجود در متن را در نظر داشته باشیم، کلمات کلیدی مناسبی را انتخاب نخواهیم کرد. در حالی‌که با رجوع به اصطلاحنامه و در نظر گرفتن کلمات هم‌خانواده و وابسته، به‌طور مثال با دیدن کلمه "دلیل"، مشخص می‌شود که این کلمه هم خانواده "دلایل" است و لذا به کلمه مردج آن یعنی "دلایل" یک ضریب وزنی مشخص اضافه می‌شود. هم‌چنین در مورد کلمه "استدلال"، باعث می‌شود یک ضریب وزنی مشخص به فرکانس کلمه "دلایل" اضافه شود. یعنی درنهایت وزن "دلایل" در این متن به میزان دو ضریب وزنی اضافه می‌شود.

۳-۵-۳- رابطه اعم

اگرچه استفاده از کلمات هم‌خانواده با استفاده از اصطلاحنامه در وزن‌دهی کلمات موجود در متن کمک زیادی به فرآیند بازیابی و طبقه‌بندی متن می‌کند، اما لزوماً برای طبقه‌بندی صحیح متن‌ها در متون کافی نیست. در شکل (۴) مثالی در مورد آموزش و پرورش ارائه شده است:

نظام جدید آموزش متوسطه از سال ۱۳۷۱ در کشور آغاز گردید. وزارت آموزش و پرورش در جهت تاثیرگذاری مثبت بر سطح علمی و آموزش دانش‌آموزان کشور اقدامات زیادی انجام داد. در ابتدا برخی از مدارس کشور ملزم اجرای این طرح شدند. در ادامه در خصوص مدارس راهنمایی و دبستان‌ها نیز نظام آموزشی جدیدی وضع گردید که دروس جدیدی جهت تدریس در پایه‌های مختلف تحصیلی اضافه گردید.

(شکل-۴): متن حاوی واژه‌های اعم

(Figure-4): The text contains general terms

در این متن کلمات مدارس، آموزشگاه، دبستان، آموزش و.... بیش از سایر کلمات تکرار شده‌اند؛ اما همان‌طور که ملاحظه می‌شود، این کلمات هم‌معنی نیستند و یک کلمه را به عنوان نماینده همه آن‌ها نمی‌توان در نظر

فصل سی



مشخصه های مشترک بسیاری با اعمال بازیابی اطلاعات، هم چون جستجوی متن دارد. در این مرحله، پس از مشخص شدن وزن کلمات موجود در هر متن، نسبت به یافتن شاخص کلیدی متن اقدام می شود. برای این منظور کلماتی که دارای وزن بیشتری باشند، بیان گر این مفهوم هستند که اهمیت بیشتری در متن دارند و به عنوان شاخص کلیدی می توانند انتخاب شوند. پس از مشخص شدن شاخص های کلیدی و مهم در متون با توجه به نوع کاربرد موضوعی این شاخص ها، متون در دسته های از پیش تعیین شده قرار می گیرند.

۴- ارزیابی روش پیشنهادی

به منظور پیاده سازی روش پیشنهادی از روش طبقه بندی استفاده شده است. به این منظور، یک فضای برداری شامل تمامی کلمات موجود در پایگاه داده ای متن ایجاد می شود؛ درنتیجه هر متن به صورت برداری از کلمات در فضای برداری نمایش داده می شود که هر متن نقطه ای از این فضای برداری خواهد بود. با استفاده از روش طبقه بندی، متون مشابه و مربوط به یک موضوع، در یک دسته قرار می گیرد. پرس و جوی کاربر نیز به سادگی با مقایسه با مراکز دسته ها پردازش شده و نزدیک ترین دسته شامل شبیه ترین متن های موجود در طبقه به کاربر برگردانده می شود. در این روش از الگوریتم نزدیک ترین همسایه یا KNN برای طبقه بندی استفاده می شود. الگوریتم KNN یک الگوریتم تعلمی با سرپرستی است. در حالت کلی از این الگوریتم به دو منظور استفاده می شود: یکی برای تخمین تابع چگالی توزیع داده های آموزش و دوم برای طبقه بندی داده های آزمایش بر اساس الگوهای آموزش داده شده. برای آزمایش بر اساس الگوهای آموزش داده شده، KNN تخمین (x) را روی n نمونه تعلمی توسط الگوریتم KNN یک سلول به مرکزیت x می توانیم ایجاد کرده و اجازه k دهیم، شاع این سلول تا حدی گسترش پیدا کند که kn نمونه تعلمی را در بر گیرد. این نمونه ها kn نزدیک ترین همسایه های x هستند. در حالت کلی k را به صورت kn در نظر می گیریم که kn تابعی تعریف شده از n است. اگر چگالی نقاط تعلمی اطراف x زیاد باشد، سلول کوچک می شود و بنابراین نتیجه به دست آمده نتیجه بهتری است و در صورتی که چگالی نقاط تعلمی اطراف x کم باشد، سلول بزرگ می شود. روش KNN را در دسته ای طبقه بندی می کند که بیشترین تکرار را در بین k نزدیک ترین همسایه x دارد؛ در ضمن برای یافتن میزان ارتباط بین

ضریب وزنی Beta در نظر گرفته می شود. اگر چند کلمه هم خانواده در متن وجود داشته باشند، براساس اصطلاح نامه به ازای یافتن هر واژه هم خانواده برای یک لغت به میزان درصد وزنی Beta به وزن لغت اضافه می شود.

۳-۶-۲- وزن دهنده کلمات اعم و اخص

با توجه به این که برای کلمه اعم و اخص یک کلمه موجود در متن وزن مساوی با آن را نمی توان اختصاص داد؛ لازم است، روش ساخت یافته ای برای وزن دهنده کلمات موجود در متن و وابسته های آن ها ارائه شود. از آن جایی که اعم یک کلمه اصلی در متن لزوماً نمی تواند جای گزین آن کلمه شود و در صورت جای گزینی با کلمه اصلی مفهوم اصلی متن می تواند تغییر کند، نمی توان وزن مساوی برای کلمات اعم و اخص و کلمه نماینده در نظر گرفت. در چنین مواردی بر اساس نوع کاربرد و میزان دقت مورد نیاز در طبقه بندی وزنی کمتر یک برای کلمات اعم یک کلمه اصلی در نظر گرفته می شود. برای مثال برای هر سطح در ساختار درختی وزن های به ترتیب ضریبی از Alpha در نظر گرفته می شود که میزان Alpha در ادامه مطرح می شود.

۳-۶-۳- طبقه بندی متون

طبقه بندی متون به معنای ایجاد تناظر بین یک سند و مجموعه ای از طبقه های از پیش تعریف شده است. مراحل زیر را برای یک طبقه بندی کننده متون می توان در نظر گرفت:

- پردازش و بازنمایی اسناد: ایجاد یک بازنمایی عددی برای هر سند؛

- انتخاب ویژگی ها: این مرحله شامل انتخاب زیر مجموعه ای از کلمات موجود در مجموعه اسناد است که بهترین نحو توانایی بازنمایی این مجموعه را داشته باشد و هدف از آن بهبود کارایی و سرعت طبقه بندی کننده است؛

- وزن دهنده به کلمات: نسبت دادن یک مقدار عددی مناسب به هر یک از ویژگی های انتخاب شده تا تمایز هر سند از سایر اسناد نمود بیشتری داشته باشد؛

- آموزش طبقه بندی کننده: آموزش طبقه بندی کننده با استفاده از بازنمایی عددی اسناد آموزشی حاصل از مرحله قبل.

طبقه بندی متون به طور عمیقی متکی بر اصول حاکم بر بازیابی اطلاعات است. طبقه بندی متون یک عمل مدیریت متون مبتنی بر مفهوم است. به طوری که



و در غیراین صورت به رکورد متن مورد نظر در بانک اطلاعاتی پایگاه داده اضافه می‌شود. به این ترتیب با یک پویش ترتیبی، کلمات اضافه راچ در متن حذف می‌شوند.

۲-۴-۲-۲- مرحله دوم پیش پردازش

در مرحله دوم پیش پردازش با به کارگیری فرمول ساده‌ای برخی پیشوندها و پسوندهای متداول از کلمات باقی مانده جدا شده و سعی می‌شود ریشه کلمات باقی بماند. برای مثال کلمه‌ای مانند "درختان" که "ان"، پسوند جمع برای آن به حساب می‌آید، از کلمه درخت حذف می‌شود. قابل توجه است که به سبب وجود استثناهای فراوان در کلمات فارسی، انجام مرحله حذف پیشوندها و پسوندها همواره به سادگی امکان‌پذیر نیست. برای مثال برای کلمه‌ای مثل "باران" چون "ان" بخش اصلی کلمه است، امکان حذف نیست. درنتیجه در این مرحله به حذف پیشوندها و پسوندهای کلمات که حرف اصلی آن بیش از سه حرف باشد، اقدام کردۀ‌ایم. مشاهدات و بررسی‌ها نشان داده است که در بسیاری از موارد، درنظر گرفتن چنین معیاری منجر به حذف صحیح پیشوند و پسوند می‌شود. با این حال از روش‌های پیشرفت‌تری به منظور استخراج ریشه از کلمات اصلی می‌تواند استفاده شود. در جداول (۴) و (۵) برای هر دسته موضوعی نشان داده شده که عملیات پیش پردازش متن به طور متوسط چه حجمی از کلمات را بیرون ریخته و چه درصدی را به عنوان کلمات اصلی به کاربر ارائه می‌کند.

(جدول-۴): فایل‌های پالایش شده

(Table-4): Refined files

متوسط تعداد کلمات اضافی پس از حذف کلمات اضافی و ریشه‌یابی	متوسط تعداد کلمات مقابلات	دسته بندی موضوعی	ردیف
۱۴۹	۲۰۴	ورزشی	۱
۱۳۵	۱۹۹	اقتصادی	۲
۷۶	۱۲۳	شهری	۳
۱۱۵	۱۶۰	حوادث	۴
۱۲۴	۱۷۷	خارجی	۵

(جدول-۵): نتایج

(Table-5): Results

درصد کلمات اصلی که به اشتباه حزو کلمه اضافی شناسایی شدند	درصد کلمات اضافی که به اشتباه حزو کلمه اضافی شناسایی شدند	درصد کلمات اضافی که به اشتباه حزو کلمه اضافی شناسایی شدند	دسته بندی موضوعی	ردیف
۹%	۲۰%	ورزشی	۱	
۱۱%	۱۸%	اقتصادی	۲	
۱۲%	۲۲%	شهری	۳	
۱۴%	۱۶%	حوادث	۴	
۱۰%	۱۵%	خارجی	۵	

کلمات از ایده‌ای که در مقاله‌ای در سال ۲۰۱۰ توسط آقای George Tsatsaronis استفاده می‌شود [36].

۱-۴- نحوه انتخاب متون فارسی جهت آزمایش

به منظور آزمایش روش پیشنهادی، مجموعه مقالات روزنامه همشهری در پنج دسته مختلف از وب‌گاه همشهری^۱ گردآوری شده است. اطلاعات کلی این مقالات در جدول (۳) آرایه شده است.

(جدول-۳): اطلاعات اولیه متون

(Table-3): Basic Information of Texts

متوسط تعداد کلمات مقابلات	تعداد مقابلات	دسته بندی موضوعی	ردیف
۲۰۴	۱۴۶	ورزشی	۱
۱۹۹	۱۵۴	اقتصادی	۲
۱۲۳	۱۷۱	شهری	۳
۱۶۰	۸۹	حوادث	۴
۱۷۷	۱۳۰	خارجی	۵

مجموعه مقالات به گونه‌ای انتخاب شده‌اند که دایره وسیعی از کلمات مربوط به هر حوزه را پوشش دهند. به عبارت بهتر، از هر دسته، مقالاتی با نویسنده‌گان مختلف انتخاب شده که از دایره لغت‌های مختلفی برای نوشتن مقالات استفاده می‌کنند. به این ترتیب، توانایی راه‌کار پیشنهادی در شناسایی متون مختلف با کلمات گوناگون، اما در یک حوزه مشخص بهتر نشان داده می‌شود.

۲-۴- مراحل اجرا

همان‌گونه که در فصل قبل توضیح داده شد، این فرایند شامل چند مرحله اصلی است که در ادامه هر یک از مراحل شرح داده می‌شود.

۱-۴-۲- مرحله پیش پردازش

همان‌گونه که بیان شد، در این مرحله با استی کلمات اضافی هر متن حذف، ریشه کلمات استخراج و کلمات اصلی متن وارد پایگاه داده متن شود. برای انجام این کار، فایلی شامل کلمات اضافی متداول درنظر گرفته شده است. متن مورد نظر کلمه به کلمه خوانده شده و هر کلمه با کلمات موجود در فایل کلمات اضافی مقایسه می‌شود؛ درصورتی که کلمه مورد نظر در فایل کلمات اضافی وجود داشته باشد، از متن حذف

^۱ Site address: <http://www.hamshahrionline.ir>

در نظر گرفته می شود که حاوی مقادیر صفات است. صفات در اینجا کلیه کلمات اصلی موجود در بانک داده ای متنها هستند. بدین ترتیب هر عنصر از یک بردار نماینده، یک کلمه اصلی بوده و برای یک متن خاص در صورت دارا بودن کلمات مورد نظر، عنصر مربوطه در بردار، مقدار تکرار کلمه را گرفته و در صورت عدم حضور کلمه در متن مورد نظر، مقدار عنصر مورد نظر صفر خواهد بود. نمونه ای از یک بردار تهیه شده برای یک متن ذکر شده در شکل (۷) قابل مشاهده است. با ساخت بردارهای مربوط به متن های مختلف با استفاده از روش KNN متون موجود در بانک طبقه بندی می شود.

terms		term_relations	
keyword_id	keyword	type	keyword_en
28	رقص های آئینی	K	Ritual Dances
29	رقص جنگ	K	War Dance
30	آداب معاشرت	K	Etiquette
31	مراسم خاک سپاری	K	Burial Ceremony
32	آداب و رسوم مذهبی	K	Religious Customs
33	حج	K	Pilgrimage to Mecca
34	[نمایش]	K	Prayer
35	نمایش جماعت	K	Public Prayer
36	روزه	K	Fasting
37	زیارت [۱]	K	Pilgrimage
38	باران خواهی	K	Praying for Rain
39	درون پسند	K	
40	زوره	K	
41	پسناخانی	K	
42	نذر	K	Offering
43	طهارت	K	Purification

term_relations		
keyword_id	parent_keyword	relation_type
18	20	B
21	22	B
21	23	B
24	25	B
24	27	B
25	26	B
28	29	B
32	33	B
32	34	B
32	36	B
32	38	B
32	39	B
32	40	B

(شکل-۶): ساختار اصطلاح نامه

(Figure-6): The structure of the thesaurus

V	V	V	V	V	V	V125	V125
1	2	3	4	5	6	.	6	6
0	2	0	1	8	3	2	4

(شکل-۷): نمونه ای از یک بردار متن

(Figure-7): An example of a text vector

۴-۵- وزن دهنده کلمات اصلی

جهت ادامه روند کار و اجرای روش پیشنهادی، ضمن بررسی

۴-۲-۳- مرحله یافتن تعداد کلمات اصلی موجود

در متن

پس از انجام مراحل پیش پردازش متن که طی آن کلمات اصلی متن استخراج شدند، نوبت به شمارش تعداد تکرار کلمات موجود در متن می رسد. در روش هایی که تابه حال در زبان فارسی به این منظور استفاده شده، هم خانواده بودن وجود کلمات اعم و اخص در یک متن مورد توجه قرار نمی گرفته است. همان گونه که گفته شد از آن جایی که نویسنده گان متن، از کلمات هم خانواده برای شکل بودن متن استفاده کنند، عدم در نظر گرفتن هم خانواده ها و کلمات اعم و اخص باعث کاهش دقت فرایند طبقه بندی متن می شود. به عبارت دیگر چون یک کلمه به شکل های مختلفی در متن به کار رفته است، تعداد تکرار کلمه مورد نظر در متن توزیع می شود. درنتیجه شمارش ساده معیار مناسبی برای تعیین طبقه متن یا موضوع متن نیست. با استفاده از یک اصطلاح نامه به سادگی کلمات هم خانواده و اعم و اخص را می توان شناسایی کرده و برای همه این کلمات یک نماینده در متن در نظر گرفته شود و با دیدن کلمات هم خانواده و اعم و اخص در متن به میزان ضریب وزنی تعریف شده به فرکانس تکرار کلمه نماینده اضافه شود. برای پیاده سازی این مرحله از یک اصطلاح نامه کامل متون فارسی (اصفا) استفاده شده است که در فصل قبل به طور کامل مورد بررسی قرار گرفته است.

۴-۴- بررسی ساختار اصطلاح نامه

این ساختار در یک فایل اکسس قابل نمایش است که در شکل (۶) قسمتی از آن نشان داده می شود. ساختار اصطلاح نامه از ترکیبی از ساختار اصطلاح نامه اسلامی و اصفا گرفته شده و داده های آن از پایگاه کتابخانه ملی استخراج شده و پس از تبدیل به فرمت لازم برگردانده شده است. لازم به ذکر است که تهیه این اصطلاح نامه بسیار سخت بوده و قبل از به دست آوردن این اصطلاح نامه از اصطلاح نامه های زیادی استفاده شد که به علت کامل نبودن نتیجه خوبی به دست نیامد و تنها این اصطلاح نامه بود که نتایج خوبی از آن منتج شد.

۴-۴- ایجاد بردارها

پس از مشخص شدن تعداد تکرارهای کلمات موجود در متن با در نظر گرفتن هم خانواده ها، اعم و اخص های کلمات، نوبت به ایجاد بردار می رسد. بدین منظور برای هر متن یک بردار

را دیدیم $\alpha + \beta$ می‌شود. اگر کاینات هم در متن باید و چون جانور نوعی از کاینات است و گرگ نوعی جانور، پس وزن کاینات $\alpha^2 + \alpha + 1$ می‌شود و به وزن کلمه‌ی جانور یک α دیگر اضافه می‌شود و داریم $\alpha + \alpha + \beta$ و به وزن α^2 گرگ هم بدلیل این که اخص آن کاینات است یک α^2 اضافه می‌شود و داریم $\alpha^2 + \alpha + \beta$. پس نتیجه می‌گیریم یک الگوریتم حریصانه نمی‌توانیم ارائه دهیم چون وقتی یک کلمه می‌بینیم، ممکن است بخواهیم وزن کلمات بعدی را تغییر دهیم.

روش دوم این است که ابتدا بردار ویژگی‌ها را به دست آوریم و بعد آن را روی کلمات کلیدی اعمال کنیم. یعنی یکبار تا آخر متن می‌رویم؛ سپس کلمات کلیدی را روی بقیه ویژگی‌ها پخش می‌کنیم؛ که در این روش سربار زمانی خیلی کمتر است.

در روش نخست بهزادی هر کلمه باید برمی‌گشته باشد کلمات کلیدی را چک می‌کردیم؛ بنابراین سربار زمانی زیاد بود. به عنوان مثال اگر کلمه کلیدی جانور سیزده بار دیده شده باشد و گرگ یازده بار، درنتیجه برای وزن دهی $11 * \alpha$ بعلاوه‌ی جانور و $13 * \alpha$ بعلاوه‌ی گرگ می‌شود؛ پس اگر کلمات کلیدی زیاد باشد، بهتر است که نخست همه آن‌ها را استخراج کنیم و بعد یک کلمه را به سایر کلمات انتشار بدهیم. مسئله دیگری که مطرح می‌شود، این است که به عنوان مثال ممکن است، چهار کلمه شیر، پلنک، گرگ و خرس را در متن ببینیم که یکی چهار بار، یکی سه بار، یکی دو بار و دیگری یک بار تکرار شده است و کلمه دیگری به عنوان اعم یا اخص در متن نباشد؛ پس لازم است کلمه جانور را به متن اضافه کنیم. در غیر این صورت ممکن است با متن دیگری که فقط جانور در آن بوده تطابق پیدا نکند. در حقیقت اگر وزن از یک حدی گذشت باید خودبه‌خود کلمه عام‌تر (جانور) تولید شود. بنابراین باید یک سطح آستانه بگذاریم که ویژگی‌ها یا کلمات کلیدی‌هایی که از آن سطح آستانه بیشترند، ظاهر شوند؛ یعنی این چهار کلمه که کلمات خاصی از کلمه جانور هستند باعث می‌شوند کلمه جانور که اصلاً در متن نبود ظاهر شود. اگر این سطح آستانه را نگذاریم، همه کلمات تولید می‌شوند و به محض این که کلمه‌های اخص را دیدیم، هر کدام با وزنی ظاهر می‌شوند یکی 0.25 یکی 0.0625 و ...؛ پس بعد از گذاشتن سطح آستانه کلمات کلیدی را که زیر آن هستند، حذف می‌کنیم. به این ترتیب با یک پویش ترقیتی کلمات اصلی مشخص می‌شود که آیا از قبل هم خانواده آن کلمه در متن دیده شده

راه کارهای ممکن، از یک الگوریتم که در مقاله‌ای با عنوان Text Relatedness Based on a Word Thesaurus آقای George Tsatsaronis [36] ارائه شده بود و توضیحات آن در بخش‌های قبلی ارائه شد استفاده کردیم. در این مقاله پژوهش گر بدنبال بدست آوردن وزن مناسب با توجه به ارتباط معنایی بین کلمات است که بر اساس این اوزان، مناسب‌ترین شاخص‌های کلیدی را در متن بتواند استخراج کند. الگوریتم ارائه شده برای دسته‌بندی متون لاتین استفاده شده بود که در این مقاله از آن با پاره‌ای تغییرات برای زبان فارسی استفاده شده است. پس از یافتن شاخص‌های کلیدی متون به دست آمده می‌بایست طبقه‌بندی شوند که به این منظور از الگوریتم نزدیکترین فاصله KNN استفاده شده است. از آن جایی که در مرحله نخست هدف یافتن میزان تکرار کلمات هم خانواده در متن است، با شروع از متن کلمات اصلی، برای هر کلمه اصطلاح‌نامه مورد نظر مورد بررسی قرار می‌گیرد؛ در صورتی که کلمه خوانده شده هم خانواده کلمه دیگری باشد که قبلًا در متن خوانده شده بود، به جای اضافه کردن تکرار کلمه جدید خوانده شده، درصد وزنی معادل ضریب Beta (که بین صفر تا یک است) به شمارنده کلمه نخست نماینده اضافه می‌شود. همچنانی از آن جایی که برای کلمه نماینده اعم و اخص، وزنی مساوی کلمات تکرار کلمه نمی‌توان در نظر گرفت با دیدن اعم و اخص یک کلمه، به وزن کلمه نماینده درصد وزنی مشخصی معادل Alpha اضافه می‌شود (جلوئر در بخش نتایج، بر اساس آزمایش‌های بسیار زیاد و مقایسه‌های زیادی که برای به دست آوردن مقدار Alpha و Beta به صورت بهینه و مناسب انجام شده به این نتیجه خواهیم رسید که در حالتی مقدار شاخص‌های کلیدی بهترین حالت است؛ اما در حقیقت با یک پویش یعنی خواندن از نخست متن تا آخر متن ویژگی‌ها (کلمات کلیدی) را نمی‌توانیم مدیریت و بردار ویژگی‌ها را استخراج کنیم (الگوریتم حریصانه).

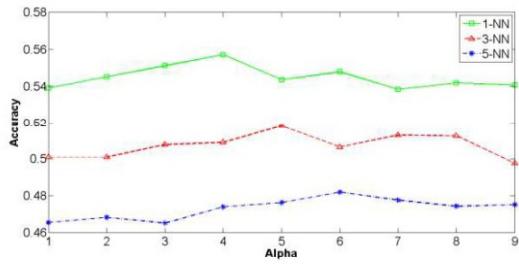
برای این که ویژگی‌ها را مدیریت کنیم دو روش وجود دارد؛ روش نخست این است که بهزادی هر کلمه باید برگردیم و تمام کلمات کلیدی را بررسی کنیم و برای متون مناسب است که تعداد کلمات کلیدی‌شان کم باشد. به عنوان مثال فرض می‌کنیم، نخستین کلمه‌ای که در متن دیدیم، گرگ است و دومین کلمه جانور. الان وزن گرگ یک است و وزن جانور بدلیل این که اخصوص یعنی گرگ را دیدیم α می‌شود. حال گرگ هم به خاطر این که اعمش یعنی جانور

میانگین نتایج برای α از 0.1 تا 0.9 با گام 0.1 ارائه شده است.

۱. از این شکل می فهمیم که NN - 1 بهتر از دیگر طبقه بندها است.

۲. از این شکل می فهمیم که بهترین نقطه برای β ، مقدار 0.3 است.

در شکل (۹) که برای $\beta = 0.3$ تنظیم شده است، α برابر 0.3 در نظر گرفته شده است و α را تغییر داده ایم. یعنی $\alpha = 0.4, \beta = 0.3, \alpha = 0.3, \beta = 0.3, \alpha = 0.2, \beta = 0.3$ و ... پس در این شکل β تغییر نمی کند، در نتیجه فقط α را میانگین گرفتیم.

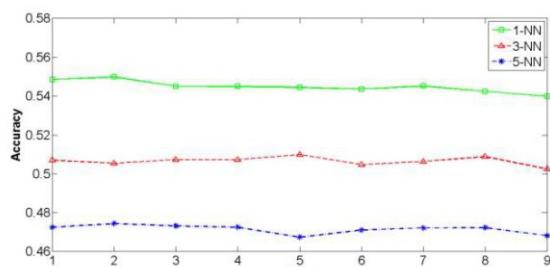


(شکل-۹): بهترین دقت (۱)
(Figure-9): Best accuracy (1)

همان طور که از شکل پیداست با تنظیم $\beta = 0.3$ و $\alpha = 0.4$ بهترین دقت به دست می آید.

۴-۶-۲- بهترین دقت برای Alpha

این بار بهترین دقت را برای میزان مشارکت روابط اعم و اخص می خواهیم به دست آوریم. روش کار همانند به دست آوردن دقت برای β است با این تفاوت که این بار α را از 0.1 تا 0.9 تغییر می دهیم و برای هر کدام از خانه های α (به عنوان مثال خانه نخست)، β را از 0.1 تا 0.9 تغییر می دهیم؛ بنابراین هر بار یک دقت به دست می آید.



(شکل-۱۰): دقت روابط اعم و اخص
(Figure-10): accuracy of the general and specific relationship

با توجه به شکل میانگین نتایج برای β از 0.1 تا 0.9 با گام 0.1 ارائه شده است.

۱. از شکل (۱۰) می فهمیم که 1-NN - 1 بهتر از دیگر طبقه بندها است.

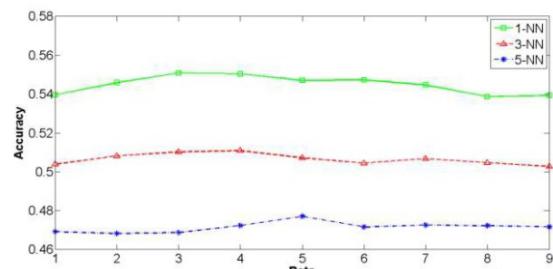
بود، که در این صورت درصد وزنی 0.4 به شمارنده کلمه نماینده اضافه می شود و اگر اعم یا اخص کلمه مورد نظر بود، مقدار 0.2 به شمارنده کلمه نماینده اضافه می شود.

۴-۶-۳- اجرای الگوریتم و تجزیه تحلیل نتایج

هدف از اجرای الگوریتم این است که بهترین ضریبی که برای پارامترهای Alpha (α) و Beta (β) می تواند در نظر گرفته شود، مشخص شوند. برای این منظور، ضریب های مختلفی (بین صفر تا یک) با دقت و فاصله 0.1 برای هر پارامتر در نظر گرفته و در هر بار الگوریتم پیاده سازی شده به ازای این مقادیر اجرا می شود و درنهایت کلیه پاسخ های به دست آمده مورد مقایسه و ارزیابی قرار می گیرد تا درنهایت به یک مقدار مناسب برای هر یک از پارامترها دست یافت. البته به صورت منطقی می توان حدس زد که مقداری که برای ضریب هم خانوادگی محاسبه می گردد، بیشتر از ضریبی باشد که برای کلمات اعم و اخص حاصل می شود. زیرا کلمات هم خانواده از یک ریشه به وجود می آیند و به طور عمومی این گونه کلمات دارای بار موضوعی مشابه تری نسبت به کلمات اعم و اخص دارند. با این حال دست یابی به میزان دقیق این پارامترها از طریق اجرای الگوریتم امکان پذیر است. معیار ارزیابی در این الگوریتم میزان دقت حاصل از اجرای برنامه است.

۴-۶-۴- بهترین دقت برای Beta

با توجه به شکل (۸) روش کار به این صورت است که پارامتر β از ۰,۱ تا ۰,۹ تغییر داده شده است و برای هر کدام از خانه های β (به عنوان مثال خانه نخست)، α نیز از ۰,۱ تا ۰,۹ تغییر داده شده است؛ بنابراین هر بار یک دقت به دست می آید. به عنوان مثال میانگین همه دقت ها در ردیبدن - ۵ NN برابر 0.47 شد. همین کار برای ردیبدن های ۱ - ۱ و ۳ - NN نیز انجام می شود. پس در نتیجه ۹ تا α ۰,۳ تا β ۰,۲، ۹ تا α ۰,۳ تا β ۰,۲ و ... داریم. درنتیجه هر کدام از ردیبدن ها ۸۱ بار میانگین گرفته شده است.

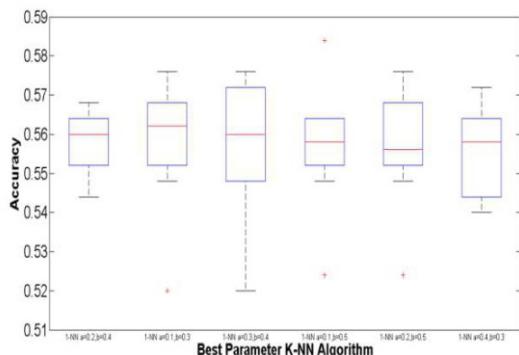


(شکل-۸): دقت روابط هم معنی

(Figure-8): meaning relationship accuracy

اختیار الگوریتم قرار داده می‌شود و ده درصد بقیه جهت آزمایش الگوریتم در نظر گرفته شده است؛ سپس با درنظرگرفتن داده‌های آموزشی مقدار مؤلفه‌ها و متغیرهای اصلی حدس زده می‌شود. جهت آزمایش و تأیید نتایج حاصله، از داده‌های آزمون؛ استفاده می‌شود. در این ارزیابی بسته برای دستیابی به نتیجه بهتر و افزایش دقت و حساسیت در کار، بهازای هر پارامتر، ده بار الگوریتم اجرا می‌شود و متوسط نتایج در نظر گرفته می‌شود. پارامترهایی که نتایجی بهتر و نزدیکتر به واقعیت ایجاد کنند، مورد نظر خواهند بود. همچنین برای بیان نحوه توزیع داده‌ها در هر مرحله از نمودار جعبه‌ای توزیع استفاده شده است (هر چه جعبه در نمودار کوچک‌تر و داده مجزای کمتری داشته باشد، نتیجه بهتر خواهد بود).

با توجه به توضیحات ارایه شده در نمودار جعبه‌ای شکل (۱۳)، بهازای شش مورد از بهترین α و β های به دست آمده الگوریتم را ده بار اجرا کرده و نتایج به دست آمده نشان داده شده است. همان‌گونه که مشاهده می‌شود در $\alpha = 0.2$ و $\beta = 0.4$ جعبه نمایان‌گر اجراهای منسجم‌تر بوده و بنابراین این نقطه بهترین نقطه از نظر این پژوهش خواهد بود.



(شکل-۱۳): نمودار جعبه‌ای برای الگوریتم ارائه شده
 (Figure-13): Box plot for the proposed algorithm

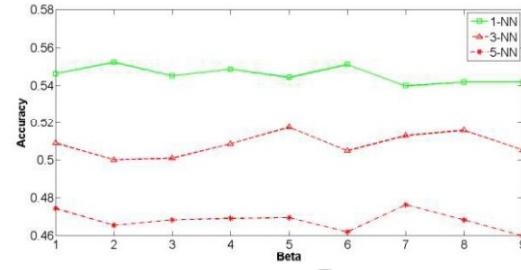
جدول (٦) دقت طبقه‌بندی را برای حالت استفاده از اصطلاح‌نامه و بدون اصطلاح‌نامه نشان می‌دهد.

(جدول-۶): مقایسه خروجی‌ها از نظر دقت
 (Table-6): Compare outputs in terms of accuracy

روش‌ها	عدم استفاده از اصطلاح نامه، $(\beta=0 \text{ و } \alpha=0)$	استفاده از اصطلاح نامه، تنهای در سطح متراو $(\beta=1 \text{ و } \alpha=0)$	استفاده از اصطلاح نامه با روش پیشنهادی و $\alpha=0.25$ $(\beta=0.3)$
1 - NN	۷۰/۹۳	۷۳/۲۱	۷۳/۶۸

۲. از این شکل می‌فهمیم که بهترین نقطه برای α است.

در شکل (۱۱) که برای $\alpha = 0.2$ تنظیم شده است و β را تغییر داده‌ایم. یعنی $\alpha = 0.2, \beta = 0.2$. $\alpha = 0.2, \beta = 0.4$ و ... پس در این شکل α تغییر نمی‌کند، در نتیجه فقط نُه بار میانگین گرفتیم.

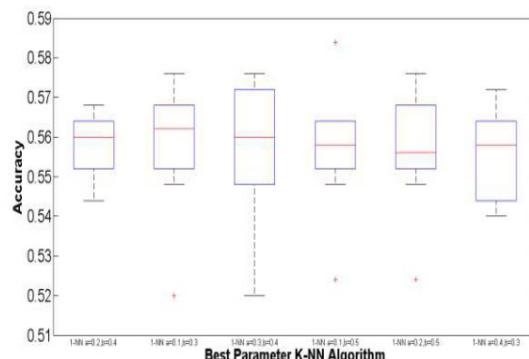


(شکل-۱۱): بهترین دقت (۲)
(Figure-11): Best accuracy (2)

همان طور که از شکل (۱) پیداست با تنظیم $\alpha = 0.2, \beta = 0.6$

۳-۶-۴- پنهانی دقت‌ها برای مدل K-NN

در شکل (۱۲)، نتایج شش تا از بهترین کارهایی که ثبت شده، ارائه شده است.



(Figure-12): Best accuracy for the K-NN model

این نتایج، α و β های گوناگونی هستند که بهترین دقتهای را به دست آورده‌اند. به این صورت که ۸۱ حالت را آزمایش کرده‌ایم (n حالت، α از ۰.۹ تا ۰.۱ و β از ۰.۹ تا ۰.۱) و شش تای برتر را در اینجا آورده‌ایم.

همان گونه که عنوان شد، مهم‌ترین پارامتر در کسب نتیجه بهتر، دارابودن دقت بالاتر در ارزیابی و تجزیه و تحلیل نتایج هر مرحله است؛ لذا بهمنظور انجام ارزیابی، الگوریتم اعتبارسنجی ۵۰ لایه به کار گرفته شده است. در این الگوریتم نود درصد از متون داده‌ای، به عنوان آموزش و تعلیم در

در این مقاله نکات زیر مورد توجه قرار گرفته است: با استفاده از اصطلاح نامه کلمات وابسته در متون فارسی شامل کلمات هم خانواده، کلمات اعم و اخص شناسایی شده‌اند. با استفاده از ارتباط بین کلمات موجود در متن با استفاده از اصطلاح نامه، وزن دهی دقیق انجام شده است و به این ترتیب شاخص کلیدی با دقت بیشتری استخراج می‌شوند. با تبدیل هر متن به یک فضای برداری که ابعاد آن شاخص‌های کلیدی همه متون هستند، عمل طبقه بندی متون بر اساس شاخص‌های استخراج شده انجام می‌شود. نتایج حاصل از به کارگیری اصطلاح نامه با توجه به روش پیشنهادی در استخراج کلمات کلیدی متون فارسی بر طبقه بندی آن‌ها با حالت بدون اصطلاح نامه و استفاده از اصطلاح نامه فقط در سطح مترادف مقایسه شد. نتایج بررسی شده نشان داد که استفاده از اصطلاح نامه با توجه به روش پیشنهادی به دسته‌بندی دقیق‌تر متون فارسی می‌تواند کمک کند. با توجه به پیاده‌سازی و اجرای الگوریتم ارائه شده و نتایج به دست آمده از تجزیه و تحلیل خروجی‌های الگوریتم این‌گونه به نظر می‌رسد که، چنان‌چه برای کلمات و واژه‌های دارای روابط اعم و اخص ضریب وزنی ۰.۲ و هم‌چنین برای کلمات دارای روابط هم خانواده از آزمایش داده‌ها و متون گرفته شود، شواهد به دست آمده از آزمایش داده‌ها و متون آزمایشی بیان‌گر انتخاب مناسب این پارامترها در تشخیص کلمات کلیدی و درنهایت دسته‌بندی متون می‌باشد. البته به صورت منطقی هم نتایج به دست آمده از الگوریتم که بیان‌کننده مقادیر ضریب وزنی است، قابل قبول است؛ زیرا کلمات هم خانواده که دارای ریشه مشترک هستند، به‌طور عمومی در یک موضوع و دسته خاص مورد استفاده قرار می‌گیرند و به همین دلیل ضریب بالاتری نیز خواهند داشت.

۱-۵- پیشنهادهای آینده

موارد زیر را به عنوان پیشنهاد جهت پژوهه‌های آینده می‌توان مطرح کرد:

- ۱- بهبود مرحله پیش‌پردازش؛
- ۲- استفاده از روش‌های دیگر طبقه‌بندی؛
- ۳- ارائه روش‌های مناسب‌تری جهت ابهام‌زدایی از کلمات؛
- ۴- تعیین بهترین ضریب برای روابط متضاد و همبسته؛
- ۵- به کارگیری روابط دیگر اصطلاح نامه.

3 - NN	۶۹/۹۱	۷۳/۰۷	۷۳/۱۰
5 - NN	۷۰/۵۷	۷۳/۱۴	۷۳/۶۱
MLP	۶۸/۰۲	۷۰/۸۴	۷۱/۲۸

همان‌گونه که از جدول (۶) پیداست استفاده از اصطلاح نامه با توجه به روش پیشنهادی به طبقه‌بندی دقیق‌تر متون فارسی می‌تواند کمک کند. هم‌چنین، چنان‌چه از دقت‌ها معلوم است، مدل KNN از مدل MLP بهتر است. هم‌چنین در بین KNN-های گوناگون، با افزایش K دقت بدتر می‌شود؛ یعنی بهترین مدل NN - 1 است.

۴-۶- مقایسه دقت روش پیشنهادی با سایر روش‌ها
در این بخش روش پیشنهادی با چندین روش دیگر از نظر دقت مورد مقایسه قرار می‌گیرد. نتایج حاصل شده از جدول (۷) حاکی از برتری روش پیشنهادی نسبت به سایر روش‌های مشابه است.

(جدول-۷): مقایسه روش پیشنهادی و سایر روش‌ها

(Table-7): Comparison of the proposed method and other methods

روش‌ها	دقت
روش پیشنهادی در بهترین حالت	۷۳/۶۸
روش نزدیکترین همسایه یغمایی و تعبدی [۳]	۶۷/۳۸
روش آراسته و همکارانش [۵]	۶۴/۶۳
روش علاقه‌بند و همکاران [۴]	۶۷/۶۴

۵- نتیجه‌گیری و کارهای آینده

امروزه با افزایش روزافرون حجم اطلاعات، وجود سامانه‌ای برای طبقه‌بندی خودکار متون ضروری به نظر می‌رسد. در این مقاله سامانه جدیدی برای طبقه‌بندی خودکار متون فارسی ارائه شد. این سامانه شامل چهار مرحله اصلی است: مرحله پیش‌پردازش، مرحله استفاده از اصطلاح نامه، مرحله وزن دهی و سپس مرحله طبقه‌بندی. در مرحله وزن دهی با پردازش داده‌های آموزشی بهترین ویژگی‌های نماینده هر طبقه استخراج شده و برای آموزش طبقه‌بندی کننده مبتنی بر KNN استفاده می‌شوند و سپس در مرحله طبقه‌بندی، بر قابل خواهد بود داده‌های آزمایش را به یکی از طبقه‌های آموزش داده شده نسبت دهد.

۶- مراجع

- [7] Borko, Harold, and Bernick, Myrna, "Automatic document classification", Journal of the ACM (JACM) 10, no. 2: 151-162, 1963.
- [8] Cavnar, B. William, and Trenkle, M. John, "N-gram-based text categorization", Ann Arbor MI 48113, no. 2: 161-175, 1994.
- [9] F. Colace, M. D. Santo, L. Greco, P. Napoletano, "Text classification using a few labeled examples", Journal of Computers in Human Behavior, Vol. 30, January 2014, pp. 689-697, 2014.
- [10] Cleverdon, Cyril, "Optimizing convenient online access to bibliographic databases", Information services and Use 4, no. 1: 37-47, 1984.
- [11] D. Choi, B. Ko, H. Kim, P. Kim, Text analysis for detecting terrorism-related articles on the web, Journal of Network and Computer Applications, Vol. 38, pp. 16-21, 2014.
- [12] A. Díaz, M. Buenaga, L. A. Ureña, and M. García, "Integrating Linguistic Resources in an Uniform Way for Text Classification Tasks", In First International Conference on Language Resources & Evaluation, Granada (Spain), 1998.
- [13] M. Deegan, "Keyword Extraction with Thesauri and Content Analysis", URL: http://www.rlg.org/en/page.php?Page_ID=17068, 2004.
- [14] Escudero, Gerard, Márquez, Lluís, and Rigau, German, "Boosting applied to word sense disambiguation", Springer Berlin Heidelberg, 2000.
- [14] K. Frantzi, S. Ananiadou and H. Mima, Automatic Recognition of Multi-word Terms: the C-value/NC-value Method, Digital Libraries, 3(2), pp. 115-130, 2000.
- [15] S. Forsyth, Richard, "New directions in text categorization", In Causal models and intelligent data management, pp. 151-185. Springer Berlin Heidelberg.
- [16] N. Freitas, and A. Kaestner, "Automatic text summarization using a machine learning approach", 16th Brazilian Symposium on Artificial Intelligence (SBIA), Brazil. Vol. 398, 2005.
- [17] Granitzer, Michael, Hierarchical text classification using methods from machine learning. Master's Thesis, Graz University of Technology, 2003.
- [18] D. Hyun, "Automatic Keyword Extraction Using Category Correlation of Data", Heidelberg, pp. 224-230, 2006.
- [19] Harter, Stephen P. "A probabilistic approach to automatic keyword indexing", Part II. An algorithm for probabilistic indexing. Journal of the American Society for Information Science 26, no. 5: 280-289, 1975.
- [1] F. Rad, H. Parvin, A. Dehbashi, B. Minaei, "A New Method for Automatic Indexing and Extracting Keywords for Information Retrieval and Clustering of Texts", Journal of Signal Processing and Data, Volume 27, No. 1, page 87-100, 2017.
- [2] Dehbashi Hashem, Atoosa, "Improved clustering of Persian texts based on keywords using linguistic information and thesaurus". Master thesis, 2010.
- [3] F. Yaghmaei, S. Tabodi, "Improving the Classification of Persian Texts in Weighted Neighboring Method", The First International Conference on Line Processing and Persian Language, 2012.
- [4] علاقه بند، م.ر، سعیدی محمدی، م.ر، دزفولیان، م.ح، خوشه‌بندی متون مبتنی بر مرکز دسته با استفاده از روش SVD و بهره‌گیری از نقاط همسایگی، نخستین کنفرانس بین‌المللی پردازش خط و زبان فارسی، ۱۳۹۱.
- [4] M.R., Alagheband, M.R Saeedi Mohammadi, M.H Dezfulian, "clustering of center-based texts using the SVD method and utilizing neighborhoods", the first international conference on processing Persian language and language, 2012.
- [5] A.R, Arasteh, M.H, Elahimanesh, A. Sharif, B. Minaei-Bidgoli, "Semantically Clustering of Persian Words", Proceeding of 1st International Conference on Persian Language Processing (ICPLP), Semnan, Iran, Sep. 5-6, 2012.
- [6] Berry, W. Michael, and Castellanos, Malu, eds, Survey of text mining. New York: Springer, 2004.

فصلنامی



- and Applications, pp. 391-398. Springer Berlin Heidelberg, 2011.
- [32] Sable, L. Carl, and Hatzivassiloglou, Vasileios. "Text-based approaches for non-topical image categorization", International Journal on Digital Libraries 3, no. 3: 261-275, 2000.
- [33] Salton, Gerard, and Yang, Chung-Shu, "On the specification of term values in automatic indexing", Journal of documentation 29, no. 4: 351-372, 1973.
- [34] Schapire, E. Robert, and Singer, Yoram, "BoosTexter: A boosting-based system for text categorization", Machine learning 39, no. 2-3: 135-168, 2000.
- [35] G. Tangil, J. E. Tapiador, P. Peris-Lopez, J. Blasco, Dendroid: A text mining approach to analyzing and classifying code structures in Android malware families, Journal of Expert Systems with Applications, Vol. 41, No. 4, March 2014, pp. 1104-1117, 2014.
- [36] G. Tsatsaronis, I. Varlamis, M. Vazirgiannis, "Text Relatedness Based on a Word Thesaurus", Journal of Artificial Intelligence Research, Vol. 37 pp.1-39, 2010.
- [37] A. Zamanifar, B. Minaei-Bidgoli, and Sharifi, Mohsen. "A new hybrid farsi text summarization technique based on term co-occurrence and conceptual property of the text. Software Engineering, Artificial Intelligence", Networking, and Parallel/Distributed Computing, SNP'D'08. Ninth ACIS International Conference on. IEEE, 2008.
- [38] W. Witten, I.H. Medley, Thesaurus based automatic keyphrase indexing, ACM/IEEE-CS JCDL '06 (Joint Conference on Digital Libraries), 2006.
- [39] Y. Zhang, N. Z. Heywood and E. Milios, "World Wide Web Site Summarization Web Intelligence and Agent Systems", Technical Report, 2006.
- [40] مجيد محمدپور دانشآموخته کارشناسی ارشد رشته نرمافزار از دانشگاه علوم تحقیقات تهران (کهگیلویه و بویراحمد) در سال ۱۳۹۳ است. وی هم‌اکنون در چندین واحد دانشگاهی در رشته کامپیوتر مشغول به تدریس است. ایشان هم‌اکنون عضو باشگاه پژوهش‌گران جوان و نخبگان دانشگاه آزاد اسلامی واحد یاسوج و در چندین واحد دانشگاهی در رشته کامپیوتر مشغول به تدریس است.
- [41] Hassel, Martin, and Mazdak, Nima, FarsiSum: a Persian text summarizer. Proceedings of the Workshop on Computational Approaches to Arabic Script-based Languages. Association for Computational Linguistics, 2004.
- [42] Huang, Yan. "Support vector machines for text categorization based on latent semantic indexing", Electrical and Computer Engineering Department, The Johns Hopkins University, Tech. Rep, 2003.
- [43] Kessler, Brett, Numberg, Geoffrey, and Schütze, Hinrich, Automatic detection of text genre. In Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics and Eighth Conference of the European Chapter of the Association for Computational Linguistics, pp. 32-38. Association for Computational Linguistics, 1997.
- [44] Knight, Kevin, Mining online text. Communications of the ACM 42, no. 11: 58-61, 1999.
- [45] Larkey, S. Leah, "Automatic essay grading using text categorization techniques", In Proceedings of the 21st annual international ACM SIGIR conference on Research and development in information retrieval, pp. 90-95. ACM, 1998.
- [46] Liu, Luying, Kang, Jianchu, Yu, Jing and Wang, Zhongliang, "A comparative study on unsupervised feature selection methods for text clustering. In Natural Language Processing and Knowledge Engineering", 2005. IEEE NLP-KE'05. Proceedings of 2005 IEEE International Conference on, pp. 597-601. IEEE, 2005.
- [47] H. P. Luhn, "11 Keyword-in-Context Index for Technical Literature (KWIC Index)", Readings in automatic language processing 1: 159, 1996.
- [48] Manning, D. Christopher, "Foundations of statistical natural language processing", Edited by Hinrich Schütze. MIT press, 1999.
- [49] Maron, Melvin Earl., "Automatic indexing: an experimental inquiry", Journal of the ACM (JACM) 8, no. 3: 404-417, 1961.
- [50] Myers, Kary, Kearns, Michael, Singh, Satinder, and Walker, A. Marilyn, "A boosting approach to topic spotting on subdialogues", Family Life 27, no. 3: 1, 2000.
- [51] Moschitti, Alessandro, "Answer filtering via text categorization in question answering systems", In Tools with Artificial Intelligence, Proceedings. 15th IEEE International Conference on, pp. 241-248. IEEE, 2003.
- [52] H. Parvin, B. Minaei-Bidgoli, and A. Dahbashi, "Improving persian text classification using persian thesaurus", In Progress in Pattern Recognition, Image Analysis, Computer Vision,



مجید محمدپور دانشآموخته کارشناسی ارشد رشته نرمافزار از دانشگاه علوم تحقیقات تهران (کهگیلویه و بویراحمد) در سال ۱۳۹۳ است. وی هم‌اکنون در چندین واحد دانشگاهی در رشته کامپیوتر مشغول به تدریس است. ایشان هم‌اکنون عضو باشگاه پژوهش‌گران جوان و نخبگان دانشگاه آزاد اسلامی واحد یاسوج و در چندین واحد دانشگاهی در رشته کامپیوتر مشغول به تدریس است.

زمینه‌های پژوهشی وی مباحثی نظری الگوریتم‌های بهینه‌سازی پویا، رده‌بندی و خوشبندی ترکیبی داده‌ها و پردازش سیگنال است.

نشانی رایانمه ایشان عبارت است از :
m.mohammadpour@iauyasooj.ac.ir



حمید پروین تحصیلات خود را در مقطع کارشناسی در دانشگاه چمران اهواز به پایان رساند. ایشان مدرک کارشناسی ارشد و دکترا را در دانشگاه علم و صنعت اخذ کردند و پس از آن به عضویت هیأت علمی دانشگاه آزاد واحد نورآباد ممتنی درآمدند. وی هم‌اکنون در چندین واحد دانشگاهی در رشته کامپیوتر مشغول به تدریس است. زمینه‌های پژوهشی وی مباحثی نظری الگوریتم‌های بهینه‌سازی، طبقه‌بندی و خوشبندی داده‌ها است.

نشانی رایانمه ایشان عبارت است از :
parvin@just.ac.ir



صمد نجاتیان تحصیلات خود را در مقطع کارشناسی در رشته مهندسی برق (الکترونیک) دانشگاه سیستان و بلوچستان در سال ۱۳۸۲ به پایان رساند. ایشان مدرک کارشناسی ارشد خود را در رشته برق (مخابرات)، از دانشگاه مشهد در سال ۱۳۸۶ اخذ کردند. وی مدرک دکترای تخصصی خود را در رشته برق (مخابرات)، در سال ۱۳۹۳ از دانشگاه UTM مالزی اخذ کردند. وی هم‌اکنون عضو هیئت علمی و معاونت پژوهشی دانشگاه آزاد اسلامی واحد یاسوج هستند.

نشانی رایانمه ایشان عبارت است از :
nejatian@iauyasooj.ac.ir



وحیده رضایی دارای مدرک تحصیلی در مقطع دکترای تخصصی رشته ریاضیات هستند. وی هم‌اکنون عضو هیئت علمی دانشگاه آزاد اسلامی واحد یاسوج است.

زمینه‌های پژوهشی ایشان، بهینه‌سازی ریاضی، متن‌کاوی، پردازش سیگنال، داده‌کاوی و خوشبندی داده‌ها
نشانی رایانمه ایشان عبارت است از :
v.rezaie@iauyasooj.ac.ir

فصلنامه

سال ۱۳۹۶ شماره ۴ پیاپی ۳۴

www.S

