

روش جدید متن‌کاوی برای استخراج اطلاعات زمینه کاربر به منظور بهبود رتبه‌بندی نتایج موتور جستجو

جواد داودی مقدم* و علی احمدی

دانشکده مهندسی کامپیوتر، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران



چکیده

یکی از بزرگ‌ترین مشکلات پیش‌روی موتورهای جستجو، رفع ابهاماتی است که در جستار کاربران وجود دارد. این ابهامات می‌تواند دلایل متعددی داشته باشد که از جمله آنها تعدد معانی و مفاهیم مرتبط با یک جستار یا کاربردهای مختلف آن جستار است. اگر موتور جستجو نتواند این ابهام را به شکل صحیح برطرف کند، در ارائه نتایج خود به کاربر دچار اختلال و خطأ خواهد شد و نیاز کاربر را برطرف نخواهد کرد. این موضوع نقش مهمی در تعیین میزان کارایی موتور جستجو خواهد داشت. در این مقاله هدف آن است تا با جمع‌آوری اطلاعات زمینه کاربر در طول زمان، به تفسیر جستار کاربر کمک کرده و درنتیجه آن رتبه‌بندی نتایج موتور جستجو را بهبود بخشیم. زمینه کاربر به هر اطلاعاتی گفته می‌شود که به شناخت ویژگی‌ها و خصوصیات کاربر کمک کند. در این مقاله متن صفات وی که کاربر از آن‌ها بازدید می‌کند، مورد پردازش قرار می‌گیرند تا مفاهیم اصلی و کلیدی آن‌ها استخراج شود. استخراج این مفاهیم (زمینه کاربر) که در سمت کاربر و بر روی سیستم وی اتفاق خواهد افتاد، با افزونه‌ای خواهد بود که به همین منظور تولید و بر روی مرورگر نصب می‌شود؛ سپس زمینه کاربر، در ساختاری خاص در سمت کاربر و برای هر کاربر به صورت خصوصی نگهداری می‌شوند. هنگامی که جستجویی انجام می‌شود (با توجه به خلاصه‌ای که موتور جستجو در ازای معرفی هر پیوند ارائه می‌دهد)، میزان شباهت نتایج موتور جستجو با زمینه کاربر مورد محاسبه قرار گرفته و به ازای هر نتیجه میزان شباهت آن با زمینه کاربر محاسبه می‌شود؛ سپس آن نتایجی به کاربر پیشنهاد می‌شوند (در مرورگر پرنگ می‌شوند) که با زمینه وی تطبیق بیشتری داشته باشند. همان‌طور که از نتایج آزمایش‌های پایان مقاله مشهود است، استفاده از زمینه کاربر در رتبه‌بندی نتایج موتور جستجو تاثیر قابل توجهی دارد. بررسی‌ها نشان می‌دهد که در ارائه ۱۰ نتیجه اول مربوط به ۳۰ جستار دارای ابهام، به طور میانگین روش پیشنهادی ۴۲٪ و موتور جستجوی ۱۶٪ از نتایج خود را مرتبط با مفهوم اصلی جستار مورد نظر ارائه کرده‌اند.

وازگان کلیدی: متن‌کاوی، بازیابی اطلاعات، زمینه کاربر، رتبه‌بندی نتایج موتور جستجو

A Novel Text Mining Method for User Context Extraction to Improve Search Engine Results Ranking

Javad Davoudi Moghaddam* & Ali Ahmadi

Computer Engineering Faculty, K. N. Toosi University of Technology, Tehran, Iran

Abstract

Today, the importance of text processing and its usages is well known among researchers and students. The amount of textual, documental materials increase day by day. So we need useful ways to save them and retrieve information from these materials. For example, search engines such as Google, Yahoo, Bing and etc. need to read so many web documents and retrieve the most similar ones to the user query. In this example, necessity of real time ability should be mentioned. Keyphrase extraction and some other fields like Information extraction, natural language processing, text summarization, query understanding, machine translation, and text similarity are subsets of text processing. So many efforts in text processing have been established, but there are still many open problems, especially in semantically document understanding

* Corresponding author

نویسنده عهده‌دار مکاتبات



subjects. Although these subjects seem not to be very hard for humankind but they are very complex and confusing for a computer, because there is no standard structure to save documents so that computers be able to extract semantics and contents.

Document understanding and keyphrase extraction are some of the most important text processing goals. Many statistical and linguistic approaches are proposed in order to address these complex goals. Some methods work based on multi documents and some others on single document which all are generally more difficult than multi documents methods. Some methods use learning algorithms with training data and some others do not. Using natural language processing tools or resources -like ontologies- are effective ways to improve results, but these tools are not reliable for all languages. There are some articles for keyphrase extraction based on co-occurrence and also some statistical methods. Moreover, sometimes it is an important feature for a method to make real time outputs. Based on these characteristics, many approaches have been proposed in the literature.

In this paper, we present a new approach for keyphrase extraction from a single document. We present a language-independent approach based on combination of statistical information extracted from document and some logical rules named fundamental text rules. In this approach, there is no need to any natural language processing, nor to ontology and nor to any document corpus. We illustrate a real time method to understand each document focuses by extracting its phrases from segmented document without using any learning algorithm. Then, the Score for each phrase is calculated based on its occurrence and its related phrases occurrences. Then, fundamental text rules omit some phrases based on their scores and their places in text. Remained phrases shows the document focuses. Evaluation shows that our approach takes a high recall and precision in key phrase extraction with very good accuracy in text focuses understanding. These keyphrases extracted of a text presents the most important concepts of that text and it is used to retrieve documents in search engines more efficiently.

Keywords: text mining, information retrieval, user context, search engine results ranking

اطلاعات زمینه‌ای او برای بالابردن دقت جستجو و بازیابی در موتورهای جستجو مورد توجه قرار می‌گیرد.

جستار به عبارتی اطلاعات می‌شود که برای جستجو در اختیار موتور جستجو قرار می‌گیرد. هدف جستار، ارائه یک نمایش جزئی و غیر مبهم از نیازهای کاربر است. فهم جستار دارای ابعاد گوناگونی است که از جمله آن‌ها می‌توان به بازیابی اطلاعات^۶، پردازش زبان طبیعی^۷ و جستجوی وب اشاره کرد. بر اساس آمار منتشرشده، به‌طور میانگین تعداد کلمات هر جستار دو تا سه کلمه است. کم‌بودن تعداد کلمات در یک جستار باعث ایجاد ابهام در جستار و درنتیجه منجر به نتایج نامرتبط در بازیابی می‌شود [۴]؛ همچنین اعلام شده است که بیش از نیمی از کاربران تنها به صفحه نخست نتایج بازیابی شده اکتفا می‌کنند و به صفحات بعد مراجعه نمی‌کنند. حتی گفته شده که هر کاربر به‌طور متوسط تنها به دو نتیجه از میان نتایج بازیابی شده سر می‌زند و از بررسی سایر نتایج منصرف می‌شود [۵]. این مورد نیز به ضرورت رفع ابهام از جستار و ارائه نتایج دقیق در همان نتایج اولیه اشاره دارد. ضمن اینکه پیچیدگی‌های زبانی نیز به این ابهام افزوده می‌شوند. به عنوان مثال زبان فارسی، زبانی ادبی است

۱- مقدمه

فهم منظور کاربر^۱ یا اطلاعات مورد نیاز وی که با یک جستار^۲ مشخص می‌شود، مدت‌هاست که به عنوان یک بخش حیاتی از بازیابی مؤثر اطلاعات شناخته می‌شود. عدم وجود ساختار برای ذخیره‌سازی منابع در اینترنت، بازیابی اطلاعات را با چالش‌ها و مشکلات بسیار عدیده و متنوعی روپرور می‌کند. برخلاف پیشرفت‌ها و پژوهش‌های فراوانی که در این خصوص صورت گرفته است، هنوز بسیاری از مسائل حل نشده باقی مانده‌اند [۱]. هدف جستجوگرها به‌طور اصولی بالابردن دو عامل دقت^۳ و فراخوانی^۴ [۲] است که به ترتیب نشان‌دهنده تعداد اسناد مرتبط بازیابی شده به تعداد کل اسناد بازیابی شده و تعداد اسناد مرتبط بازیابی شده به بازیابی شده به تعداد کل اسناد مرتبط بازیابی شده است. همچنین از عامل دیگری به نام معیار اف^۵ برای سنجش میزان موفقیت در بازیابی استفاده می‌شود [۳]. برای این منظور درک عمیق‌تر مفهوم جستار کاربر با استفاده از

⁶ Information retrieval

⁷ Natural language processing

¹ User intent

² Search

³ Precision

⁴ Recall

⁵ F_measure

برداشت معنی و مفهوم کلمه خاص کمک می کند. مطابق تعریف دی^۳ «هر اطلاعاتی که به کار برده می شود تا موقعیت یک موجودیت را مشخص کند، زمینه است». بنایاً تعريف، زمینه به جنبه های خاصی محدود نمی شود. بر همین اساس زمینه به دو دسته عمده تقسیم می شود: زمینه اولیه شامل اطلاعات محیطی مشترک یا اطلاعات ضروری، زمینه ثانویه شامل اطلاعات شخصی کاربر. به عنوان مثال اگر هویت فرد را داشته باشیم، می توانیم شماره تلفن او را که زمینه ثانویه محسوب می شود، به دست آوریم [7]. محاسبات آگاه به زمینه برای نخستین بار توسط آقایان شیت و تیمر^۴ در سال ۱۹۹۴ مطرح شد. آنها محاسبات آگاه به زمینه را نرم افزارهایی تعریف کردند که خود را با زمینه های کاربر منطبق می ساختند. تعاریف زیر برای محاسبات آگاه به زمینه رایج است [8]:

- قابلیت دستگاه های محاسباتی برای کشف و احساس و تفسیر و پاسخ به جنبه های محیطی کاربر
- عملکرد خود کار سامانه نرم افزاری بر اساس محتوا کاربر
- تغییر و تطبیق پویا مبتنی بر محتوا برای کاربر در این مقاله، زمینه کاربر به هر اطلاعاتی گفته می شود که به شناخت ویژگی ها، خصوصیات، عادت ها، رفتارها، حوزه کاری و تخصصی و... کاربر کمک کند. از جمله منابعی که این اطلاعات را از آن می توان استخراج کرد و در این مقاله مورد توجه قرار گرفته است، متن صفحات وبی است که کاربر از آنها بازدید می کند. این متن مورد پردازش قرار می گیرند تا مفاهیم اصلی و کلیدی آنها استخراج و در ساختاری مشخص برای همان کاربر ذخیره شود.

۳- کارهای مرتبط

اغلب کارهای ارائه شده برای پردازش جستار، اطلاعات زمینه ای کاربران را برای تصمیم گیری های کلی مورد استفاده قرار می دهد. بدین صورت که با تجمعی و پردازش تمامی اطلاعات زمینه ای که از کاربران جمع آوری کرده اند، جهت گیری کلی را در جستجوها مشخص می کنند. ویژگی ها و اطلاعات به دست آمده از این پردازش در تعیین سیاست های کلی موتور جستجو دخالت داده می شود. آنچه که در این پژوهش به آن توجه شده است، استفاده از

³ Dey
⁴ Theimer

که در آن کلمات دارای بار معنایی گوناگونی هستند که بیشتر کاربران نیز به آن توجهی ندارند. اگر ما اندکی در فهم جستار کاربر دچار خطا شویم، آنگاه نتایج بازیابی شده ممکن است، بسیار از هدف کاربر دور باشند. علاوه بر موارد بالا، برخی مشکلات دیگر در این قسمت عبارتند از: عدم وجود وردنت های^۱ تخصصی در زمینه های مختلف برای فهم جستار، محتوای پویای وب که به راحتی قابل تغییر و ویرایش است و تغییر مدام علاقه افراد [6]. هرچند که در روش پیشنهادی مشکل عدم وجود وردنت ها و تغییر محتوای وب همچنان باقی است؛ اما الگوریتم می تواند تغییر علاقه افراد را تعقیب و خود را با زمینه جدید کاربر وفق دهد. این مورد به این صورت اتفاق می افتد که کاربر به مرور زمان و با تغییر علاقه خود، صفحات وبی را که مشاهده می کند تغییر می دهد. از آنجا که در روش پیشنهادی منبع استخراج زمینه کاربر، محتوای وب مورد رجوع وی خواهد بود، به مرور زمان مفاهیمی که از قبل به عنوان زمینه وی، ذخیره شده اند، در صفحات وب کمتر دیده می شوند و در فرآیند ارزش دهی در طول زمان تنزل پیدا می کنند. در عوض بر اساس صفحات وبی که بر اساس علاقه جدید مورد رجوع قرار می گیرند، مفاهیم جدیدی به زمینه وی افروده می شوند که دارای ارزش بالاتری خواهند بود. بدین گونه زمینه کاربر در این مدل به طور کامل پویا و تطبیق پذیر با زمان طراحی شده است.

در ادامه ابتدا به تعریف و توصیف زمینه خواهیم پرداخت. در بخش سوم بر جسته ترین کارهای مرتبط با پردازش جستار با استفاده از اطلاعات زمینه ای ارائه خواهد شد. بخش چهارم، منبع استخراج زمینه کاربر و روش پیشنهادی این پژوهش را در استفاده از این زمینه کاربر می کند و در انتهای این بخش نحوه استفاده از زمینه کاربر برای بهبود رتبه بندی نتایج موتور جستجو توضیح داده می شود. در بخش پنجم، نحوه آزمایش و ارزیابی روش پیشنهادی در استخراج زمینه کاربر و همچنین تأثیر آن بر بهبود رتبه بندی نتایج موتور جستجو ارائه شده است. بخش ششم نیز حاوی پیشنهادهایی برای کارهای آتی است.

۲- زمینه کاربر

کلمه زمینه^۲ در اصطلاح به معنی قطعاتی از یک نوشه است یا سخن است که پیش یا پس از یک کلمه خاص می آید و به

¹ Wordnet

² Context

۳-۲ - تحلیل ساختاری و دستوری جستار

روش‌های متفاوتی برای این گونه پردازش جستار موجود است که در اینجا به برخی از آن‌ها اشاره می‌کنیم. برخی از روش‌ها تنها مبتنی بر تحلیل‌های زبانی و آماری هستند؛ [9، 10] اما برخی دیگر در پردازش‌های خود از اطلاعات زمینه‌ای کاربران نیز استفاده می‌کنند.

برخی از پژوهش‌گران از روش جایگزینی برای تولید جستارهای جدید بهره می‌برند؛ بدین صورت که با تغییر برخی عبارات موجود در جستار، جستار جدیدی را تولید می‌کنند که ارتباط معنایی با جستار اصلی دارد. در این روش (جایگزینی یک عبارت با عبارت دیگر) جستارهای جدید دارای طول یکسان از نظر تعداد کلمات با جستارهای اصلی هستند. برای انتخاب عبارات جایگزین از اطلاعات جستجوهای قبلی استفاده می‌شود؛ که می‌توان آن‌ها را به عنوان اطلاعات زمینه‌ای جمع‌آوری شده از کاربران در نظر گرفت [11]. روشی که شرح داده شد جزو روش‌های پالایش تعاملی جستار است. یعنی برنامه با همکاری و نظر کاربر اقدام به پردازش جستار می‌کند و به صورت خودکار کاری را انجام نمی‌دهد. در روش دیگری که از پالایش تعاملی جستار استفاده می‌کند، پس از آنکه جستار کاربر تعیین شد، برخی مفاهیم که ارتباط آن‌ها با جستار کنونی بر اساس اطلاعات جستجوهای قبلی مشخص شده است به کاربر نمایش داده می‌شود. کاربر حق انتخاب دارد که از میان مفاهیم ارائه شده یک مفهوم را که ارتباط بیشتری با جستار کنونی دارد، انتخاب کند؛ سپس از این مفهوم و مطالب مرتبط با آن که از قبل شناخته شده هستند برای گسترش جستار اصلی استفاده می‌شود [12].

در پژوهشی دیگر که از همین روش استفاده می‌کند، در روشی جدید ابتدا میزان مشابهت جستار را با جستارهای گذشته محاسبه می‌کند. بر اساس این محاسبات جستارهایی که به جستار مورد نظر شباهت قابل قبولی داشته باشند، مبنای پردازش‌های مشابه را به عنوان پیشنهاد به کاربر معرفی می‌کند تا بدین وسیله بتواند با ترغیب کاربر به استفاده از این جستارهای پیشنهادی از میزان ابهام جستار قبلی بکاهد [13].

در موتورهای جستجو نشانی‌هایی که کاربران پس از انجام جستجو کلیک می‌کنند، می‌تواند به عنوان یک بازخورد ضمنی از موفقیت جستجو در نظر گرفته شود. این بازخوردها

اطلاعات زمینه‌ای کاربر برای بهبود نتایج موتور جستجو برای همان کاربر است. یعنی اگر دو کاربر با اطلاعات زمینه‌ای متفاوت یک عبارت را جستجو کنند، ترتیب نمایش نتایج برای هر کدام متناسب با اطلاعات زمینه‌ای خود فرد باشد. این امر باعث می‌شود که نتایج نمایش داده شده برای هر کاربر خصوصی‌سازی و دقیق‌تر شود. آنچه در این بخش به آن پرداخته می‌شود، کارهای مرتبطی است که از اطلاعات زمینه‌ای تجمعی شده استفاده می‌کنند. در بخش‌های بعد نحوه استفاده از اطلاعات زمینه‌ای برای خصوصی‌سازی نتایج جستجو برای هر فرد بر اساس زمینه وی تشریح خواهد شد.

۱-۳- طبقه‌بندی هدف جستار

در یک نوع تقسیم‌بندی که بر اساس اطلاعات زمینه‌ای کاربران به دست آمده است، اهداف جستجو در سه محور پیوندی^۱، اطلاعاتی^۲ و منبع^۳ خلاصه می‌شوند. این اهداف به صورت زیر تشریح می‌شوند:

- پیوندی: هدف کاربر یافتن پیوند یا نشانی خاصی بوده است.
- اطلاعاتی: هدف کاربر یافتن اطلاعات در مورد موضوعی خاص است.
- منبع: هدف کاربر دریافت یک منبع مانند فایل یا نرم‌افزار یا ... است.

اطلاعات زمینه‌ای استفاده شده در این پژوهش، نحوه عملکرد و پایگاه‌هایی بوده است که کاربران پس از جستجو به آن‌ها مراجعه کرده‌اند. بر اساس پژوهش‌های برنارد جانسن که بر روی بیست هزار نمونه جستار انجام شده است، ۳٪/۵ از جستارها در گروه اطلاعاتی، ۵٪/۲۳ از جستارها در گروه پیوندی و ۳٪/۱۵ از جستارها در گروه منبعی دسته‌بندی شده‌اند [6]. از جمله چالش‌های پیش روی این روش آن است که تقسیم‌بندی بالا بر اساس تجربه و بررسی جستارها صورت گرفته است و به صورت دقیق نمی‌توان ادعا کرد که این تقسیم‌بندی تمام جستارهای کاربران را تحت پوشش قرار می‌دهد. همچنین مرزیندی میان گروه‌ها و دسته‌های موجود در این تقسیم‌بندی واضح و روشن نیست و نمی‌توان ادعا کرد که یک جستار، تنها به یک دسته تعلق دارد.

¹ Navigational

² Informational

³ Resource



برای دسته‌بندی جستار وجود داشته باشد که علاوه بر سرعت و دقت به تغییرات موجود در وب نیز توجه داشته باشد.
[18]

۳-۴- تولید گراف جریان جستار

گراف جریان جستار، نمایشی مجتمع از اطلاعات موجود در لاغ مربوط به جستار است. این گراف، اطلاعات موجود در جلسه‌های متفاوت جستجو را در یک گراف همگن مجتمع می‌کند. گره‌های این گراف جستارهای منحصر به فرد هستند و لبه از یک گره به گره دیگر وجود دارد؛ در صورتی که این دو جستار در یک جلسه جستجو به صورت متواالی مورد استفاده قرار گرفته باشند. از این گراف که پس از هر جستجو توسعه داده می‌شود، در تعیین جستارهای مرتبط با یک جستار خاص می‌توان استفاده کرد [19].

در پژوهشی دیگر برای تفسیر جستار از گرافی مشابه گراف معرفی شده در روش قبل استفاده می‌شود. در این روش هر جستار به همراه نتایجی که کاربر بر روی آنان کلیک می‌کند، ذخیره می‌شوند؛ سپس با استفاده از این داده یک گراف دو قسمتی ایجاد می‌شود. در یک قسمت به ازای هر جستار تمام نشانی‌هایی که کاربر بر روی آن‌ها کلیک کرده است، نگهداری می‌شوند (یک نشانی می‌تواند چندین پیوند از جستارهای مختلف داشته باشد) و در قسمت دیگر جستارهای مربوط به هر نشانی به آن متصل شده‌اند. از این گراف می‌توان فهمید که به ازای جستارهای مشابه چه صفحاتی مورد بازبینی قرار گرفته‌اند یا اینکه یک نشانی خاص بر اساس چه جستارهایی کلیک شده است. همچنین مفهوم جستار را با توجه به نشانی‌هایی که کلیک می‌شوند، می‌توان پیش‌بینی و از این پیش‌بینی در جستجوهای بعدی کاربر استفاده کرد [20]. برای آشنایی بیشتر با شیوه‌های استفاده از اطلاعات جریان جستار می‌توانید به منابع [21] و [22] مراجعه کنید.

۴- روش پیشنهادی

روش‌ها و شیوه‌های گوناگونی به منظور جمع‌آوری اطلاعات زمینه کاربران وجود دارد. همچنین بیان شد که زمینه کاربر شامل هرگونه اطلاعاتی می‌شود که در شناخت وی می‌تواند مؤثر باشد؛ لذا هر میزان که اطلاعات بیشتری راجع به کاربران جمع‌آوری شود، شناخت آن‌ها و درک درست از نیاز آن‌ها آسان‌تر خواهد شد. در اغلب موقع روش‌هایی مانند

کمک می‌کنند تا بتوان برای جستارهای مبهم بر اساس میزان شباهت با جستارهای قبلی نتایج مناسبی را بازیابی کرد یا برای پیشنهاد جستار به کاربر مورد استفاده قرارداد. برای مطالعه روش‌های بیشتر می‌توان به مراجع [14] و [15] مراجعه کرد.

۳-۳- شناخت ویژگی‌های پنهان جستار

برخی معتقدند که اگر بتوان با پردازش اطلاعات زمینه‌ای جمع‌آوری شده، ویژگی‌ها و ابعاد دیگری از جستار را شناسایی کرد، به گویا نشدن جستار کمک می‌شود و در نتیجه بازیابی اسناد به وسیله موتور جستجو دقیق‌تر خواهد شد. این ویژگی‌ها عبارت‌اند از: نوع جستار، عنوان جستار، هدف جستار، اختصاص جستار، دامنه جستار، حساسیت اعتبار، حساسیت‌های مکانی و زمانی [16].

بر اساس اطلاعاتی که از ثبت لاغ جستار بدست می‌آید، ویژگی‌های جستار را می‌توان استخراج کرد. به عنوان مثال طول جستار، تکرار جستار، تعداد صفحات مشاهده شده و طول جلسه جستجو را می‌توان استخراج کرد. همچنین از دیگر استفاده‌های لاغ جستار در فهم جستار می‌توان به طبقه‌بندی بر اساس هدف، معنا، مکان و زمان اشاره کرد. به طور معمول در لاغ جستار کاربران چهار دسته از اطلاعات موجود است که شامل اطلاعات مربوط به کاربر مانند نشانی آی‌پی^۱، اطلاعات مربوط به جستار مثل متن جستار و زمان جستجو، اطلاعات مربوط به نشانی‌های کلیک شده پس از جستجو و اطلاعات مربوط به نتایجی است که موتور جستجو به عنوان خروجی به کاربر نمایش می‌دهد. از فواید منحصر به فرد این روش آن است که جستار را از نظر حساسیت به مکان و زمان مورد تحلیل می‌توان قرار داد. برخی روش‌های آماری نیز مطرح شده‌اند که بر اساس تکرار جستار در روز، هفته و ماه می‌توانند حساسیت زمانی جستار را بر اساس اطلاعات لاغ جستار پیش‌بینی کنند [17].

البته یکی از مشکلاتی که همواره گریبان‌گیر دسته‌بندی جستار بوده است، هزینه پردازشی آن است. دسته‌بندی جستار باید به صورت آنی انجام گیرد تا کاربر متوجه این امر نشود؛ در صورتی که موتورهای جستجو روزانه ناچند صد میلیون جستار را پردازش می‌کنند. مشکل زمانی پیچیده‌تر می‌شود که در نظر داشته باشیم دسته‌بندی صفحات وب نیز در حال تغییر هستند. در نتیجه باید روشی

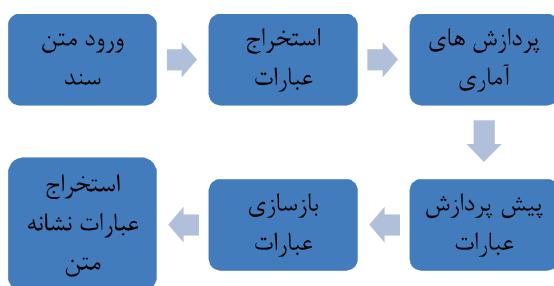
^۱ IP address



می‌دهد. این روش مبتنی بر ترکیب اطلاعات آماری استخراج شده از سند و برخی قوانین است. این روش از هیچ گونه پردازش‌های زبان طبیعی استفاده نمی‌کند؛ لذا به هستان‌شناسی و یا دادگان آموزشی نیاز ندارد. ارزیابی‌هایی که در بخش بعد از این شده‌اند، نشان می‌دهد که استفاده از این روش نتایج بسیار خوبی را در استخراج عبارات مهم از متن داشته است. در ادامه این بخش ابتدا مراحل استخراج محتوا و مفاهیم از صفحات وب به‌طور دقیق شرح داده و سپس به نحوه استفاده از زمینه برای بهبود گویایی منظور جستار اشاره می‌شود.

۱-۴-۱ فرآیند استخراج زمینه کاربر از صفحات وب

همان‌طور که بیان شد یکی از منابع مهم برای استخراج زمینه کاربر صفحاتی است که کاربر در مرورگر خود، مورد بازدید قرار می‌دهد. هدف این است که در هر صفحه اینترنتی چند عبارت به عنوان عبارات نشانه که بیان‌گر مفاهیم اصلی آن صفحه بوده و نقاط تمرکز و تکیه متن را روشن می‌سازند، استخراج شوند. بدین‌وسیله با جمع‌آوری مجموع اطلاعاتی که هر شخص در طول زمان با آن‌ها سر و کار دارد، زمینه‌ای جامع را از وی می‌توان به دست آورد. هرچند اطلاعاتی که از این طریق کسب می‌شوند ممکن است چندان صریح، روشن و ساخت‌یافته نباشند، اما در مجموع و با استفاده از روش‌های داده‌کاوی و پردازش متن کمک شایانی به شناخت زمینه کاربر می‌توانند بکنند. شکل (۱) مراحل به کاررفته را برای استخراج کلمات نشانه در روش پیشنهادی نشان می‌دهد.



(شکل-۱): مراحل به کاررفته برای استخراج عبارات نشانه
(Figure-1): Keyphrases extraction steps

۱-۴-۱-۱ استخراج عبارات
در این مرحله متن خام صفحه وب به عنوان ورودی در نظر گرفته می‌شود. این متن خام متنی است که پس از تجزیه^۳

تمکیل فرم‌ها و اظهارنامه‌ها برای دریافت زمینه کاربر مورد استفاده قرار می‌گیرد. می‌توان ادعا کرد که این روش‌ها جزو روش‌های دقیقی هستند که در آن زمینه کاربر به صورت صریح از وی پرسیده می‌شود؛ اما امروزه مشکلاتی اساسی گریبان گیر این روش‌ها شده‌اند که از جمله می‌توان به‌این موارد اشاره کرد: تنوع و گستردگی و متغیر بودن اطلاعات کاربران، خسته‌کننده و هزینه‌بر بودن پرکردن اظهارنامه. با توجه به این مشکلات، لزوم استفاده از روش‌هایی که در آن زمینه کاربران به صورت خودکار و ماشینی استخراج شود تا هم نیاز به تکمیل اظهارنامه‌ها توسط کاربران نباشد و هم بتوان تغییرات زمینه‌ای کاربران را در طول زمان رصد کرد، احساس می‌شود. این چنین روش‌هایی به شناختی پایدار از افراد می‌توانند کمک کنند.

با توجه به توضیحات بالا، اساسی‌ترین نیاز را یافتن بستری مناسب می‌توان دانست که از طریق آن بتوان زمینه کاربر را تا حد قابل قبولی به دست آورد و البته تغییرات زمینه‌ای را در آن بستر رصد کرد. استخراج زمینه کاربر از سطح وب شامل موارد متعددی مانند اطلاعات موجود در صندوق‌های پستی، شبکه‌های اجتماعی و... است؛ به عنوان مثال در پژوهشی با استفاده از پیام‌های موجود در شبکه اجتماعی توییتر^۱، کلمات کلیدی استخراج می‌شود که به عنوان تگ^۲ به کاربر تخصیص داده می‌شوند و کاربر با آن‌ها شناخته می‌شود [23]. در این روش‌ها سعی می‌شود با دسترسی به اطلاعات پروفایل شخصی کاربران در مورد آن‌ها اطلاعاتی کسب شود که بتوان برای تفسیر جستار از آن‌ها بهره جست. نمونه‌ای از این کارها را می‌توان در منابع [24] و [25] مشاهده کرد.

علاوه بر موارد بالا، یک مورد دیگر نیز وجود دارد که کمتر مورد توجه قرار گرفته است. این مورد همان صفحات وبی است که کاربر به صورت روزمره با آن‌ها سر و کار دارد. هر کدام از این سایتها نشان‌دهنده برخی ویژگی‌های فرد می‌توانند باشند. برای استخراج زمینه کاربر از صفحات وب، نیاز است تا مفاهیم موجود در این صفحات استخراج شوند؛ سپس با گردآوری و یکپارچه‌سازی مفاهیم استخراج شده به زمینه فرد می‌توان پی برد؛ لذا استخراج دقیق و صحیح مفاهیم از صفحات وب یک نیاز اساسی در این پژوهش به حساب می‌آید. این پژوهش روش جدیدی را برای استخراج عبارات مهم از یک سند (برای مثال یک صفحه وب) ارائه

³ Parsing

¹ Twitter

² Tag

○ افزایش طول عبارات استخراج شده منجر به افزایش زمان پردازش می شود؛ یعنی هرچه میزان طول عبارات استخراج شده بیشتر باشد، زمان مورد نیاز برای استخراج عبارت نیز به صورت نمایی افزایش خواهد داشت؛ لذا بیشینه طول عبارات باید به گونه ای انتخاب شود که اطلاعات استخراج شده از عبارات طولانی تر، ارزش هزینه زمانی مذکور را داشته باشد. با توجه به اینکه از عبارات با طول بیشتر از سه، اطلاعات کمی به دست می آید، از استخراج آن ها صرف نظر شده است. به عنوان نمونه اگر "این متن، یک پژوهش علمی است؛ پژوهش علمی، نیاز به ارزیابی دارد." را به عنوان متن یک سند در نظر بگیریم، طبق جدول (۱) ابتدا این متن به چهار زیرشته تبدیل می شود و از هر کدام از زیرشته ها عبارت یک تا سه کلمه ای استخراج می شوند.

(جدول-۱): استخراج عبارات یک تا سه کلمه از زیرشته های متن نمونه

(Table-1): Extraction of phrases up to three words from substrings of text

عبارات استخراج شده	زیر رشته
این- متن	این متن
این متن	
یک- پژوهش- علمی- است	یک پژوهش
یک پژوهش- پژوهش علمی- علمی است	علمی است
یک پژوهش علمی- پژوهش است	
پژوهش- علمی	پژوهش علمی
پژوهش علمی	
نیاز- به- ارزیابی- دارد	
نیاز به- ارزیابی- ارزیابی دارد	نیاز به ارزیابی
نیاز به ارزیابی- به ارزیابی دارد	دارد

۴-۱-۲- پیش پردازش عبارات

در این بخش به دنبال آن هستیم که عباراتی را که فاقد معنا و مفهوم معین و مهمی هستند، از دامنه عبارات موجود حذف کنیم. به همین منظور حذف ایست واژه ها^۲ و عبارات بی معنی در این بخش صورت گرفت.

ایست واژه ها یا ایست کلمات به کلمات و عباراتی اطلاق می شود که به طور معمول با تعداد تکرار بسیار زیاد در یک متن حضور دارند؛ اما از نظر مفهومی هیچ بار معنایی به خصوصی ندارند. از جمله این عبارات و کلمات می توان به

صفحه وب اصلی و حذف مطالب اضافی شامل کدها و... به دست می آید. درواقع صفحه وب به صورت یک متن یکپارچه، وروی این مرحله خواهد بود. این متن خام به صورت رشته ای از کلمات که به ترتیب در کنار یکدیگر قرار گرفته اند، در نظر گرفته می شود. این نکته بسیار اهمیت دارد که کلمات به صورت انفاقی در این رشته به دنبال هم قرار نگرفته اند، بلکه حضور یک کلمه در مکانی خاص از رشته بیانگر معنای خاصی است که در صورت تغییر مکان آن، دیگر پردازش متن مانند روش نایو بیز^۱ که به صورت آماری عمل می کنند، به مکان قرار گیری کلمات توجهی ندارند که این باعث می شود، بخش قابل توجهی از معانی و مفاهیم موجود در متن از بین برود. در این پژوهش با توجه به رویکرد پردازش معنایی متن، سعی بر این است تا کلمات و عبارات از بار معنایی جایگاه خود نیز بهره مند شوند. همان طور که در انتهای قسمت ۳-۱-۴ اشاره خواهد شد، علاوه بر شاخص هایی که برای ارزش دهی به هر عبارت معرفی می شوند، سه قاعده نیز برای تصمیم گیری در مورد هر عبارت ارائه شده است. قواعد دوم و سوم از این مجموعه ناظر بر تعیین اهمیت یک عبارت بر اساس عبارات پیشین و پسین آن هستند. درواقع این قواعد برای توجه به ارزش مکان قرار گیری هر عبارت در متن، پیشنهاد شده اند.

برای استخراج عبارات متن، ابتدا رشته کلمات متن با علائم نگارشی از هم جدا می شوند و متن به مجموعه ای از زیرشته ها افزایش می شود؛ سپس تمام عبارات تک کلمه ای تا سه کلمه ای که کلماتشان به ترتیب و پشت سر هم قرار گرفته اند، از هر زیرشته استخراج می شوند. دقت شود که قبل از این کار متن سند مورد نظر انتخاب بیشینه طول سه کلمه برای عبارات به دلایل زیر صورت گرفته است:

○ بیشتر عبارات معنی دار در بازه یک تا سه کلمه قرار می گیرند. این ادعا بر اساس یک پردازش آماری است که روی ده هزار عبارت یک تا پنج کلمه ای انجام شده است. این ده هزار عبارت از تعدادی متن به روش بالا استخراج شده اند؛ سپس هر کدام از این عبارات با عامل انسانی در دو دسته معنادار و بی معنی دسته بندی شده اند. نتیجه نشان داد که از بین ده هزار عبارت، ۶۳۰۰ عبارت معنادار هستند که بیش از ۹۲٪ از این عبارات معنادار دارای طول بین یک تا سه کلمه بودند.

² Stop word removal



از زبان بوده و یا ابزارهای زبانی را در زبان‌های متبوع در اختیار داشته باشیم. نخستین شاخصه‌ای که باید برای هر عبارت محاسبه شود، تعداد تکرار آن عبارت در متن مورد نظر است. برای Document_Frequency سهولت در ادامه این شاخصه را نام‌گذاری می‌کنیم. برای یک عبارت مهم در متن که بار مفهومی خاصی را بر عهده دارد، بسیار دور از انتظار است که تنها یکبار در متن ظاهر شود؛ لذا اگر عبارتی به موضوعی خاص در متن اشاره داشته باشد انتظار می‌رود که بیش از یکبار در متن مورد استفاده قرار بگیرد. با این پیش‌فرض اگر عبارتی تنها یکبار در متن ظاهر شده باشد، حد آستانه شاخصه Document_Frequency را که عدد دو است، ارضا نمی‌کند و باید از دامنه عبارات فعال حذف شود.

شاخصه دوم، تعداد زیر عبارت‌هایی برای هر عبارت است که آن زیر عبارت‌ها در بین عبارات فعال وجود داشته باشند. این شاخصه را Subphrase_Count می‌نامیم. این پارامتر نشان می‌دهد که تا چه میزان یک عبارت قابل اتکاست. در این پژوهش فرض بر این است که بین دو عبارت با طول مساوی، هر کدام که تعداد زیر عبارت‌های فعال بیشتری داشته باشد، احتمال حمل بار معنایی بیشتری دارد چرا که زیر عبارت‌های بیشتری از آن معنادار تشخیص داده شده‌اند. عبارات تک‌کلمه‌ای تنها دارای یک زیر عبارت هستند. اگر عبارتی دارای دو کلمه باشد. آنگاه سه زیر عبارت دارد که شامل یک عبارت دو کلمه‌ای و دو عبارت تک‌کلمه‌ای خواهد بود. این تعداد زیر عبارت‌ها با احتساب خود عبارت به عنوان بزرگ‌ترین زیر عبارت به دست می‌آید. توجه شود که زیر عبارت به ترتیبی از کلمات گفته می‌شود که در ترتیب کلمات عبارت اصلی ظاهر شود. حال اگر برخی از کلمات یک عبارت ایست واژه باشند، با توجه به مراحل قبل تعدادی از زیر عبارت‌ها از دامنه عبارات فعال حذف می‌شوند و تعداد آن‌ها کمتر از مقدار معرفی شده خواهد شد. باید مقدار شاخصه Superstring_Count برای عبارت تک‌کلمه‌ای و دو کلمه‌ای به ترتیب دست‌کم دو و چهار باشد. اگر عبارتی این حد آستانه را برای شاخصه Superstring_Count ارضا نکند از دامنه عبارات فعال حذف می‌شود.

پارامتر سوم که Subphrase_Freqency نام دارد، برای مجموع تعداد تکرار زیر عبارت‌های هر عبارت است. این پارامتر معیار خوبی برای ارزش‌دهی به عبارت طولانی‌تر می‌تواند باشد؛ به خصوص عباراتی که در متن کمتر

ضمایر، قیدها، حروف ربط، حروف اضافه، نام‌آواها و... اشاره کرد. این عبارات بار مفهومی خاصی را در متن حمل نمی‌کنند و تنها از آن‌ها برای بیان بهتر جملات و ارتباط بین قسمت‌های متن استفاده می‌شود؛ لذا می‌توان ادعا کرد که حذف این عبارات از دامنه عبارات موجود، خدشهای در درک مفهوم اصلی ایجاد نخواهد کرد. همچنین با بررسی‌های دقیق مشخص شد هر عبارتی که با ایست واژه‌ها شروع و یا به ایست واژه‌ها خاتمه یابد، به طور تقریبی در همه موارد فاقد یک معنای مشخص و معین است و از دامنه عبارات می‌تواند حذف شود. برای انجام این کار فهرستی از ایست واژه‌ها در این پژوهش فراهم شده است؛ لذا هر عبارت استخراج شده در مرحله قبل، اگر با ایست واژه شروع شوند یا خاتمه یابند، از دامنه عبارات حذف می‌شود. در این مقاله افعال نیز به عنوان ایست واژه در نظر گرفته شده‌اند. با اعمال این پیش‌پردازش جدول (۱) به جدول (۲) تبدیل خواهد شد.

(جدول-۲): عبارات باقیمانده پس از مرحله پیش‌پردازش

(Table-2): Remaning phrases after preprocessing

زیر رشته	عبارات استخراج شده
این متن	متن
یک پژوهش علمی است	یک-پژوهش-علمی یک پژوهش-پژوهش علمی یک پژوهش علمی
پژوهش علمی	پژوهش علمی پژوهش علمی
نیاز ارزیابی دارد	نیاز-ارزیابی نیاز به ارزیابی دارد

۴-۱-۳ - پردازش‌های آماری عبارات

این بخش به دنبال آن است تا با یکسری پردازش‌های آماری بر روی عبارات استخراج شده از متن که از پایه مرحله قبل عبور کرده‌اند، عبارتی را که به مفهوم متن نزدیک‌تر هستند، به عنوان عبارات نشانه انتخاب کند. علت استفاده از رویکرد آماری آن است که روش پیشنهادی، مستقل از زبان طراحی شده و برای هر متنی در هر زبانی قابل استفاده است. بسیار متداول است که یک فرد تنها به صفحات یک زبان رجوع نمی‌کند؛ بلکه به طور معمول بیش از یک زبان در صفحات وب یک فرد دیده می‌شود. از این‌رو نیاز داریم تا پردازش مستقل



- شوند؛ لذا چند قاعده طراحی شد که با استفاده از آنها دامنه عبارات فعال باز هم محدودتر می‌شود:
۱. اگر عبارتی وجود داشته باشد که شاخصه سوم و چهارم آن به ترتیب از میانگین کل شاخصه‌های سوم و چهارم عبارات متن کمتر باشد، آنگاه آن عبارت حذف خواهد شد.
 ۲. اگر عبارتی وجود داشته باشد که به عنوان مثال تا چهار عبارت قبل یا بعد از آن در دامنه عبارات فعال حضور نداشته باشد، باعث می‌شود که مقادیر Substring_Score و Subphrase_Frequency شاخصه‌های مریبوط به عبارات حذف شده صفر در نظر گرفته شود؛ لذا محدوده اطراف آن عبارت کم‌اهمیت تشخیص داده می‌شود و درنتیجه خود آن عبارت نیز از دامنه عبارات فعال حذف خواهد شد.
 ۳. اگر عبارتی وجود داشته باشد که مقادیر پارامترهای Substring_Score و Subphrase_Frequency چندین عبارت قبل و بعد از آن کمتر از یک حد آستانه باشد، محدوده اطراف آن عبارت کم‌اهمیت تشخیص داده می‌شود و درنتیجه خود آن عبارت نیز از دامنه عبارات فعال حذف خواهد شد.
- در نهایت و با اعمال شروط بالا بر روی دامنه عبارات فعال، عباراتی باقی خواهند ماند که نمایندگان خوبی برای بیان نکات مهم در متن می‌توانند باشند. توجه شود که آنچه در این پژوهش مورد نظر است، با واژگان کلیدی که در مقالات ارائه می‌شود، متفاوت است. واژگان کلیدی در مقالات ناظر بر موضوع کلی مقاله و جهت‌گیری اصلی مقاله است؛ اما در این پژوهش به دنبال آن هستیم تا عبارت‌هایی را پیدا کنیم که نشان می‌دهند در متن به چه موضوعاتی پرداخته شده است. می‌توان فرض کرد که واژگان کلیدی که در مقالات ارائه می‌شوند، زیرمجموعه‌ای از عبارات انتخاب شده می‌توانند باشند. در مرحله بعد عبارتی از دامنه حذف نمی‌شود، بلکه ممکن است دو یا چند عبارت باهم ترکیب شوند و عبارت بزرگ‌تری را تشکیل دهند که به تفصیل به آن می‌پردازیم. شاخصه‌های محاسبه شده برای عبارات جدول (۲) در جدول (۳) ارائه شده است. بر اساس اطلاعات (جدول میانگین پارامتر سوم ۲/۹ و میانگین پارامتر چهارم ۳/۸۷ می‌شود. بنابراین مواردی که به رنگ قرمز مشخص شده‌اند، بر اساس قاعده شماره یک حذف

ظاهر شده‌اند؛ ولی به سبب طول بیشتر دارای بار معنایی بیشتری هستند. اگر یک عبارت طولانی با تعداد تکرار کم، ارزش بالایی از نظر محتوایی در متن داشته باشد، انتظار می‌رود که زیرعبارت‌های آن، تعداد تکرار قابل قبولی را در متن داشته باشند. این پارامتر با درنظر گرفتن این فرضیه، به عبارت طولانی تر کمک می‌کند که در مقابل عبارت کوتاه‌تر اما با تکرار بیشتر، از میدان رقبابت خارج شود. در صورتی که اگر یک عبارت طولانی از نظر محتوایی بار چندانی را نداشته باشد، زیرعبارت‌های آن نیز در متن کمتر ظاهر می‌شوند. در این بخش برای عبارت تک‌کلمه‌ای حد آستانه در نظر گرفته نشده است. عبارت با دو کلمه دست‌کم باید دارای دو زیرعبارت در دامنه عبارات فعال باشد و عبارت با سه کلمه باید دست‌کم دارای چهار زیرعبارت در دامنه عبارات فعال باشد. اگر عبارتی یکی از شرایط بالا را نقض کند، یعنی حد آستانه شاخصه Document_Frequency را ارضا نکند، از دامنه عبارت فعال و سایر پردازش‌ها حذف می‌شود.

شاخصه چهارم با نام Substring_Score به محاسبه یک امتیاز برای هر زیرشته اختصاص دارد که این امتیاز به تک‌تک عبارت‌های موجود در آن زیرشته تشخیص می‌یابد. این امتیاز به صورت زیر محاسبه می‌شود:

(۱)

$$\text{Substring_Scor} = \frac{\sum_{i=1}^n \text{Subphrase_Frequncy}_i}{n}$$

در رابطه (۱)، n تعداد عبارت‌های یک زیرشته و Subphrase_Frequncy_i بیان گر پارامتر Subphrase_Frequncy_i برای عبارت نام در زیرشته است.

یک سؤال اساسی آن است که آیا یک عبارت مهم در یک محدوده کم اهمیت یا بی‌اهمیت در متن می‌تواند قرار بگیرد؟ یا به عبارت دیگر آیا یک زیرشته (جمله یا پاراگراف) با عبارات کم‌اهمیت یا بی‌اهمیت در بردارنده یک عبارت مهم می‌تواند باشد؟ به طور معمول بین عبارات موجود در متن یک ارتباط و همبستگی وجود دارد. برخلاف تصویر که می‌تواند تغییرات ناگهانی و زیادی بین پیکسل‌های مجاور داشته باشد، عبارات متن اغلب چنین رفتاری را نشان نمی‌دهند. هرچند که متن فراز و نشیب‌های زیادی را از نظر مفهومی می‌تواند داشته باشد؛ اما باید دقیق شود که این فراز و نشیب‌ها در بیشتر مواقع نوسان زیادی ندارند؛ به تعبیر دیگر عبارات مهم اغلب به صورت ناگهانی در متن ظاهر نمی‌توانند

پژوهش علمی" باقی مانده‌اند. دو عبارت نخست را بنا به موقعیت مکانی آنها در متن می‌شود ترکیب کرد که عبارت معترض موجود در متن را می‌سازد. به صورت اتفاقی این عبارت ترکیبی همان عبارت سوم موجود در جدول (۳) است. بنابراین از کل متن نمونه مورد نظر تنها یک عبارت که همان "یک پژوهش علمی" است، باقی می‌ماند و تنها همین عبارت به عنوان عبارت نشانه متن نمونه انتخاب می‌شود.

۴-۲ استفاده از زمینه کاربر در بهبود رتبه‌بندی نتایج موتور جستجو

همان‌طور که در قبل بیان شد، یکی از منابعی که در اختیار داشتن آن به شناخت ویژگی‌های یک فرد و کشف زمینه او می‌تواند کمک کند، مشخصات صفحات وبی است که وی به آن‌ها سر می‌زند. در طول زمان و با ثبت اطلاعات تعداد زیادی صفحات وب که کاربر مشاهده می‌کند، تا حد زیادی به ویژگی‌های او می‌توان پی برد. این روش علاوه بر ایجاد قابلیت یادگیری در طول زمان، تغییرات ویژگی‌های کاربر را نیز می‌تواند رصد کند. یک نکته بسیار مهم آن است که این عامل یادگیر یک عامل سمت کاربر^۱ است. یعنی این عامل به گونه‌ای طراحی شده است که اطلاعات زمینه‌ای کاربر را بر روی سیستم خود کاربر ذخیره کند. این نوع رویکرد دو امتیاز مهم دارد که عبارت‌اند از: حفظ محترمانگی اطلاعات کاربر و جلوگیری از بار پردازشی زیاد در سمت سورس میزبان. البته برخی روش‌ها نیز وجود دارند که مایل به استفاده از رفتار کاربر در سمت میزبان هستند. با توجه به محدودیت‌هایی که برای استفاده از زمینه کاربر در سمت میزبان وجود دارد، برخی پژوهش‌ها اطلاعات کاربران را در حد جلسه جستجو محدود کرده‌اند. جلسه جستجو به بازه زمانی پیوسته‌ای گفته می‌شود که کاربر در آن در حال جستجو است. در این شرایط برای جستار اولیه کاربر هیچ اطلاعاتی از رفتار وی در دسترس نیست؛ اما از پردازش جستارهای دوم به بعد می‌توان از رفتار کاربر پس از مشاهده نتایج جستارهای قبلی استفاده کرد. اینکه کاربر به‌ازای هر جستار بر روی چه نتایجی کلیک می‌کند، می‌تواند معنی و مفهوم خاصی داشته باشد که از آن بتوان برای جستجوهای بعدی استفاده کرد. دقت شود که در این حالت اطلاعات فرد پایدار نیست و با اتمام جلسه جستجو اطلاعات مربوط به وی از بین می‌رود [26].

¹ Client side

می‌شوند. قواعد ۲ و ۳ عبارتی را برای این نمونه حذف نمی‌کنند.

(جدول-۳) : پارامترهای محاسبه شده برای عبارات متن نمونه
(Table-3): Parameter values calculated for sample text phrases

Substring score	Subphrase frequency	Subphrase count	Document frequency	عبارت
0.5	1	1	1	متن
5.75	1	1	1	پ
5.75	2	1	2	پژوهش
5.75	1	1	2	علمی
1.25	1	1	1	نیاز
1.25	1	1	1	لرنینگ
5.75	4	3	1	یک پژوهش
5.75	6	3	2	پژوهش علمی
5.75	9	6	1	یک پژوهش علمی
1.25	3	3	1	نیاز به لرنینگ

۴-۱-۴ بازسازی عبارات

برای یافتن عبارات نشانه در متن، تمام عبارت‌هایی که تعداد کلمات کمتر یا مساوی سه دارند، استخراج و سپس با پردازش‌های بیان‌شده تعدادی به عنوان نماینده انتخاب می‌شوند. هر چند برای انتخاب عبارات با طول بیشینه سه کلمه دلایلی بیان شد، اما پر واضح است که امکان وجود عبارت‌های طولانی‌تر که حامل پیام مهمی از متن باشند نیز دور از انتظار نیست؛ به گونه‌ای که وجود عبارت‌های کوتاه‌تر در فهرست عبارات نهایی شاید نتواند پوشش دقیق و کاملی از عبارات طولانی‌تر را به دست دهد. به همین منظور این بخش به عنوان بخش پایانی در استخراج عبارات نشانه افزوده شده است. در این بخش هر جفت از عبارات مهم انتخاب شده در مرحله قبل مورد بررسی قرار می‌گیرند. اگر ترکیب آن‌ها (قرار گرفتن آن‌ها پشت سر هم) باعث تولید عبارتی شود که در متن وجود دارد آن دو عبارت باهم ترکیب می‌شوند. تشکیل یک عبارت جدید با تعداد کلمات بیشتر را می‌دهند. این عمل ترکیب تا آنجایی پیش می‌رود که دیگر هیچ ترکیبی به وجود نیاید. عبارت‌هایی که در پایان این مرحله باقی می‌مانند، به عنوان زمینه کاربر در یک فایل ذخیره می‌شوند.

در جدول (۳) که نتیجه گام قبل را نشان می‌دهد، تنها سه عبارت "یک پژوهش"، "پژوهش علمی" و "یک

متن، پایگاه داده خبری رویترز است. این پایگاه داده با جمع‌آوری بیست هزار خبر طبقه‌بندی شده جزو بزرگ‌ترین و مهم‌ترین پایگاه‌های داده مورد استفاده در پردازش متن است. این پایگاه داده شامل بیست گروه خبری مختلف است که هر کدام دارای هزار خبر مرتبط با آن گروه است [27]. از بین بیست گروه خبری موجود در این پایگاه داده، شش گروه خبری به تصادف انتخاب شدند و برای هر کدام از گروه‌های خبری نیز ۱۱۵ خبر به تصادف برگزیده شدند. این مجموعه که شامل شش گروه خبری و درجمع ۶۹۰ خبر می‌شد، برای ارزیابی این قسمت مد نظر قرار گرفت. شش گروه خبری انتخاب شده عبارت‌اند از:

- Comp.graphics
- Misc.forsale
- Rec.autos
- Sci.crypt
- Soc.religion.christian
- Taik.politics.guns

نحوه ارزیابی و دسته‌بندی متن این گروه‌های خبری بر اساس روش سنجش متقاطع k -دسته‌ای^۱ تعیین شد. در مرحله نخست داده‌ها به ده قسمت تقسیم شدند و برنامه نیز برای ده بار به اجرا گذاشته شد. در هر بار اجرا یک قسمت از ده قسمت به عنوان داده آزمایشی و نه قسمت دیگر به عنوان داده‌های آموزشی فرض می‌شدند. روال انجام ارزیابی نیز به این صورت بود که داده‌های آموزشی به عنوان ورودی به الگوریتم پیشنهادی داده می‌شدند و این الگوریتم، عبارتی را به عنوان نمایندگان این نه قسمت انتخاب می‌کرد. پس از پردازش داده‌های آموزشی تمامی گروه‌ها و تعیین نمایندگان هر گروه خبری، نوبت به دسته‌بندی داده‌های آزمایشی می‌رسید. هر کدام از داده‌های آزمایشی نیز با استفاده از الگوریتم پیشنهادی به تعدادی عبارت که نمایندگان هر داده آزمایشی بودند، تبدیل می‌شدند؛ سپس میزان شباهت عبارات هر داده آزمایشی با هر کدام از دسته‌ها بر اساس معیار مشابهت کسینوسی محاسبه می‌شد. داده آزمایشی متعلق به دسته‌ای قلمداد می‌شد که بیشترین درصد شباهت را با آن داشته باشد.

در مرحله دوم نیز داده‌ها به پنج قسمت تقسیم شدند و دوباره فرآیند بالا به منظور دسته‌بندی متن خبری بر روی این پنج قسمت اجرا شد. درصد صحت دسته‌بندی متن خبری در هر کدام از اجراء‌های مرحله نخست و دوم به ترتیب در شکل‌های (۲ و ۳) نمایش داده شده است.

^۱ K fold cross validation

حال به این سؤال پاسخ می‌دهیم که پردازش‌های روش پیشنهادی که در سمت کاربر انجام می‌شوند، چگونه بر روی نتایج موتور جستجو که در سمت میزبان قرار دارد، تأثیر می‌گذارند؟ روند طراحی شده بدین صورت است که موتور جستجو با توجه به جستاری که کاربر در اختیار وی قرار می‌دهد نتایجی را برای وی بازیابی می‌کند. برنامه پیشنهادی به صورت یک افزونه طراحی شده است که بر روی مرورگرهای مختلف قابل نصب باشد. زمانی که موتور جستجو نتایج را بر روی مرورگر کاربر نمایش می‌دهد به صورت آنی این نتایج به وسیله افزونه مورد پردازش قرار می‌گیرند؛ یعنی میزان مشابهت خلاصه نتایج نمایش داده شده در مرورگر با زمینه کاربر (که در قبل در سمت کاربر استخراج و ذخیره شده است) مورد انطباق و سنجش قرار می‌گیرد. درواقع افزونه، نتایج بازیابی موتور جستجو را به دو دسته نتایج مرتبط و نتایج غیرمرتبط با زمینه تقسیم می‌کند، سپس آن‌هایی را که با زمینه مرتبط تشخیص داده شده‌اند، به صورت مجزایی به عنوان مثال با رنگ خاص یا علامت ستاره نمایش می‌دهد. بدین ترتیب از زمینه کاربر برای خصوصی‌سازی نتایج بازیابی شده توسط موتور جستجو که در سمت میزبان فراهم شده است، استفاده می‌شود. با این رویکرد اگر دو کاربر با زمینه‌های گوناگون یک جستار را جستجو کنند که در حوزه تخصصی هر کدام معنا و مفهوم خاصی دارد، نتایج نشان‌داده شده به آن‌ها متفاوت خواهد بود و هر کدام منطبق با زمینه خود نتایج مرتبط را خواهد دید.

۵- ارزیابی نتایج تجربی

هدف از این بخش بررسی و آزمون روش ارائه شده برای استخراج زمینه و ارزیابی نتایج آن در بهبود عملیات جستجوست. از آنجا که در این پژوهش روش جدیدی برای استخراج عبارات نشانه از متن پیشنهاد شده است، ابتدا نتایج آزمایش جهت ارزیابی دقت الگوریتم استخراج عبارات نشانه ارائه می‌شود و در ادامه هدف اصلی این پژوهش که همان استفاده از اطلاعات زمینه برای بهبود نتایج جستجو است، مورد ارزیابی قرار می‌گیرد.

۱-۵- ارزیابی طبقه‌بندی متن خبری

برای اطمینان از دقت و صحت روش پیشنهادی در استخراج عبارات نشانه، ارزیابی طبقه‌بندی متن خبری نیز مورد توجه قرار گرفت. یکی از منابع بسیار معتبر در طبقه‌بندی اسناد و

87.1%	83.7%	میانگین کلی
-------	-------	-------------

اگر میانگین کلی به دست آمده از این شش دسته خبری را نماینده ای از کل مجموعه بیست گروه خبری پایگاه داده رویترز در نظر بگیریم، می توانیم یک مقایسه نسبی بین روش پیشنهادی با روش های ارائه شده در سایر مقالات مطابق جدول (۵) ارائه دهیم. دقت شود که هدف از ارائه اطلاعات جدول (۵) مقایسه مستقیم روش پیشنهادی با سایر روش ها نیست (چون برای این منظور باید کلیه شرایط از جمله انتخاب داده های آموزشی و ارزشیابی به صورت یکسان انتخاب شود) بلکه هدف این است که نشان دهیم روش پیشنهادی در انتخاب عبارات نشانه از متون دقت خوبی را دارد. در صورتی که در روش نایو بیز تعداد کلمات بسیار بیشتری (به طور تقریبی سه برابر روش پیشنهادی) برای دسته بندی استفاده شده است.

(جدول-۵): درصد صحت دسته بندی الگوریتم های مختلف بر

روی متون ۲۰ گروه خبری پایگاه داده رویترز

(Table-5): Average correctness of classification of 20 news groups of Reuter in other methods

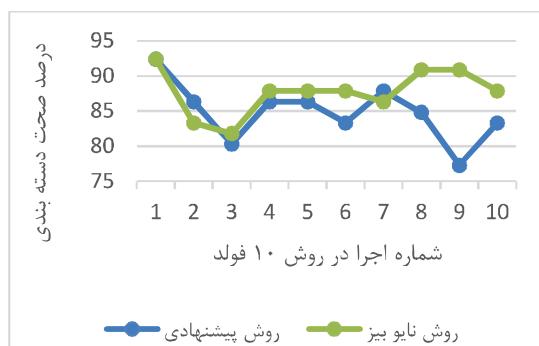
درصد صحت دسته بندی	نام الگوریتم
87.1%	نایو بیز
84.71%	DF+SVM [28]
83.97%	PCA + SVM [28]
88.96%	LDA + SVM [28]
83.7%	روش پیشنهادی (۶ گروه خبری)

۵-۲- ارزیابی بهبود رتبه بندی نتایج موتور جستجو با استفاده از زمینه کاربر

در این ارزیابی به دنبال آن بودیم تا بدانیم روش پیشنهادی چه تأثیری در بهبود عملیات جستجو دارد؛ لذا با توجه به روشی که در بخش ۲-۴ توضیح داده شد، برنامه پیشنهادی در کنار موتور جستجو قرار گرفت تا از بین نتایجی که موتور جستجو بازیابی می کند، آن هایی که به زمینه کاربر نزدیک تر هستند به کاربر پیشنهاد داده شوند. برنامه مذکور به صورت افزونه‌ای^۱ بر روی مرورگر نصب می شود تا علاوه بر جمع آوری محتوای وب کاربر برای استخراج زمینه، در هنگام جستجو و ارائه نتایج به وسیله موتور جستجو اعلام نظر کند. برای انجام این ارزیابی در مرحله نخست نیاز بود تا بر اساس تاریخچه مراجعات کاربر به صفحات وب، زمینه او استخراج شود. برای

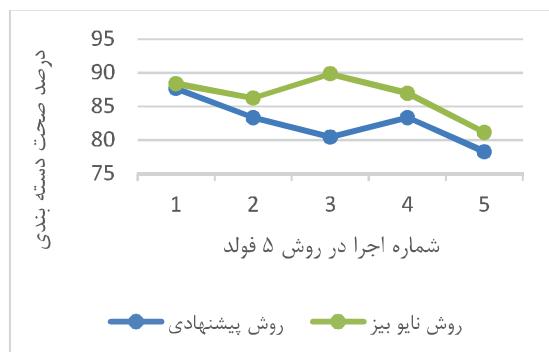
^۱ Add-on

میانگین صحت دسته بندی متون خبری که از مرحله نخست و مرحله دوم به دست آمده اند، در جدول (۴) نیز ارائه شده است. همان طور که در جدول (۴) مشاهده می شود، در صدهای روش پیشنهادی بسیار نزدیک به روش نایو بیز است در صورتی که در روش نایو بیز تعداد کلمات استفاده شده به منظور دسته بندی، بسیار بیشتر از روش پیشنهادی بوده است. درنهایت نیز تفاوت میانگین درصد دسته بندی بین روش پیشنهادی و روش نایو بیز به طور تقریبی سه درصد است. این امر نشان می دهد که الگوریتم در انتخاب عبارت مهم و نشانه دقت بالایی دارد.



(شکل-۲): مقایسه درصد صحت دسته بندی متون خبری در روش پیشنهادی با روش نایو بیز در ارزیابی ده فولد

(Figure-2): 10 fold naive bayes correctness of news texts classification vs proposed method compression



(شکل-۳): مقایسه درصد صحت دسته بندی متون خبری در روش پیشنهادی با روش نایو بیز در ارزیابی پنج فولد

(Figure-3): 5 fold naive bayes correctness of news texts classification vs proposed method compression

(جدول-۴): میانگین درصد صحت دسته بندی متون ۲۰ گروه خبری پایگاه داده رویترز

(Table-4): Average correctness of classification of 20 news groups of Reuter

روش نایو بیز	روش پیشنهادی	
87.7%	84.8%	میانگین ۱۰ فولد
86.5%	82.6%	میانگین ۵ فولد



غالباً در گروههای مختلف قرار می‌گرفت؛ لذا باید روشی پیشنهاد می‌شد که در آن تمام گروههایی که یک جستار به آن‌ها مربوط می‌شود، استخراج شوند [31]. با توجه به اینکه جستارهای مورد استفاده در این مسابقه، دارای مفاهیم چندگانه بودند، ما از آن‌ها برای آزمایش خود استفاده کردیم. نمونه‌ای از جستارهای مبهم بهمراه زمینه مربوطه در جدول (۶) نشان داده شده است. به عنوان مثال نخستین جستار مبهم در جدول (۶)، "روش‌های تشخیص نوافه" است. این جستار مبهم است چون روش‌های تشخیص نوافه در علوم و موضوعات گوناگونی کاربرد دارد؛ اما اگر بدانیم کاربری که آن را جستجو می‌کند در حوزه "پردازش تصویر" پژوهش و کار می‌کند، ابهام جستار برطرف می‌شود. در واقع در این پژوهش از زمینه کاربر برای رفع ابهام جستار استفاده می‌شود؛ اما روش‌های دیگری از جمله استفاده از اصلاح نامه‌ها در رفع ابهام عبارات مطرح هستند که از جمله کارهای صورت‌گرفته را در این رابطه به زبان فارسی را در مرجع [32] می‌توان مطالعه کرد.

به همین منظور سی جستار مبهم (دارای مفاهیم چندگانه) از منبع معرفی شده انتخاب شد. به ازای هر جستار مبهم دویست صفحه از ویکی‌پدیا استخراج شد که این دویست صفحه به عنوان زمینه و برای رفع ابهام از جستار مربوطه، مورد استفاده قرار گرفت. در واقع این دویست صفحه، اطلاعاتی را در برداشتند که ناظر بر یکی از مفاهیم جستار مبهم بود.

(جدول -۶): جستارهای مبهم به همراه زمینه‌هایی برای رفع ابهام
(Table-6): Using context for ambiguous queries

Ambiguous query	Context
Noise detection methods	Image
configure wlan	Linux
Network configuration setting	Ubuntu
New version of operating system	Android

در این سناریو، جستار کاربر بدون هیچ گونه تغییری در اختیار موتور جستجو قرار گرفت. زمانی که موتور جستجو نتایجش را ارائه داد، نوبت به پردازش‌های روشن پیشنهادی می‌رسد تا این بین نتایج، آن‌هایی را که با زمینه کاربر مطابقت بیشتری داشته باشند مشخص کند. در این پژوهش موتور جستجوی گوگل^۱ برای بازیابی نتایج و مقایسه مورد استفاده قرار گرفت. به این صورت که به ازای هر جستاره نتیجه نخست گوگل به عنوان نتایج موتور جستجو در نظر گرفته شد؛ سپس از بین پنجاه نتیجه نخست موتور جستجو، ۵۰

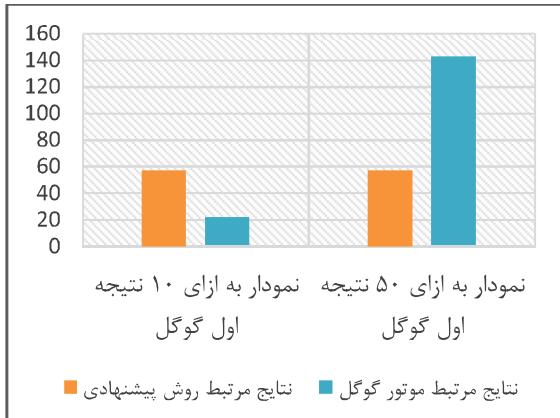
^۱ Google.com

این کار از یک کاربر نمونه خواسته شد که صفحات خاصی را از ویکی‌پدیا که در رده‌بندی مشخصی قرار می‌گیرند، به کار با مرورگر مرور کند. ویکی‌پدیا بزرگ‌ترین مرجع دانشی چندزبانه جهان است که به صورت رایگان بر روی وب قابل دسترسی است. نکته مهمی که ما را به استفاده از ویکی‌پدیا پیشگویی می‌نماید زمینه ترغیب کرد، این بود که هر مقاله در ویکی‌پدیا شامل تعدادی رده است. رده در مقالات ارتباط است. به عنوان مثال مقاله‌ای که در مورد درخت صحبت می‌کند در رده‌های مختلفی قرار می‌گیرد که یکی از آن‌ها رده گیاهان است؛ چون درخت در زمرة گیاهان طبقه‌بندی می‌شود. به همین صورت برای تمامی مقالات موجود در ویکی‌پدیا یک یا چند رده وجود دارد که می‌توان حوزه مفهومی مقاله را با استفاده از رده‌های آن تخمین زد. برای این آزمایش مقالاتی از ویکی‌پدیا توسط کاربر مورد بازدید قرار گرفتند که دارای رده رایانه باشد. به این ترتیب با انتخاب این صفحات رایانه‌ای مجموعه‌ای صفحه و ب داشتیم که در مورد مسائل مربوط به رایانه در آن‌ها بحث شده است. بنابراین عبارات نشانه به عنوان زمینه کاربر با استفاده از روش پیشنهادی از این مقالات استخراج شدند.

در حین استخراج زمینه باید به این سؤال پاسخ می‌دادیم که چه تعداد صفحه برای ساخت زمینه کاربر مناسب است. بر اساس پژوهش‌های به عمل آمده در سال ۲۰۰۴ نشان داده شده که دویست متن برای بیان جنبه‌های مختلف یک عبارت بهینه است [29]. در پژوهش‌های دیگر نیز که برای رفع ابهام از جستار وجود دارد، این عدد به عنوان نتیجه استفاده می‌کنیم و زمینه کاربر را حداقل با دویست صفحه نمایش می‌دهیم.

در مرحله بعد نیاز بود تا جستارهایی با مفاهیم چندگانه تولید شوند که موتور جستجو نتواند نتایج به طور کامل یک‌دستی را برای آن‌ها بازیابی کند. در واقع ما به دنبال یافتن جستارهایی بودیم که موتور جستجو در بازیابی اسناد آن‌ها دچار مشکل است و نمی‌داند که به طور دقیق کدام مفهوم از جستار مدنظر کاربر است. در سال ۲۰۰۵ رقابتی به منظور دسته‌بندی جستار با پشتیبانی ACM برگزار شد. داده‌هایی که سایت مسابقات در اختیار قرار داده بود، شامل هشت‌هزار جستار و ۶۷ گروه بودند. هدف این بود که برای هر جستار، از بین ۶۷ گروه معرفی شده گروههایی که مرتبط با جستار است، تشخیص داده شوند. هر جستار

شده. شبکه کد روش پیشنهادی در این مقاله در شکل (۵) نیز ارائه شده است.



(شکل-۴): نمودار تجمعی تعداد نتایج مرتب در موتور گوگل و روش پیشنهادی

(Figure-4):Google count of context related results vs proposed method

۱. شروع
۲. اگر مرورگر صفحه وبی را بارگزاری کرد:
- ۳.۱. استخراج متن صفحه وب از فرمت HTML
- ۳.۲. استخراج تمامی عبارات از یک تا K کلمه از متن صفحه وب
- ۳.۳. حذف ایست کلمات و عبارات بی معنی از بین عبارات استخراج شده
- ۳.۴. تعیین مقدار هر کدام از پارامترهای زیر برای هر عبارت است (پردازش‌های آماری):

 - ۳.۴.۱ Document_Frequency
 - ۳.۴.۲ Subphrase_Count
 - ۳.۴.۳ Subphrase_Frequency
 - ۳.۴.۴ Substring_Score

- ۳.۵. حذف عبارات کم اهمیت بر اساس قواعد سه گانه‌ای که بر روی ۴ پارامتر فوق اعمال می‌شوند
- ۳.۶. بازسازی عبارات نشانه به عنوان زمینه کاربر در ساختاری مناسب
- ۳.۷. ثبت عبارات نشانه به عنوان زمینه کاربر در شکل (۴) برو به شروع
- ۳.۸. اگر کاربر عبارتی را در موتور جستجوی اینترنتی مورد جستجو قرار داد:
- ۳.۹. تعیین میزان شباهت کسینوسی عنوان و خلاصه ارائه شده به وسیله موتور جستجو برای هر لینک با زمینه کاربر
- ۳.۱۰. رتبه‌بندی مجدد نتایج بر اساس مقدار مشابهت کسینوسی
- ۳.۱۱. پیشنهاد نتایج مرتب به زمینه کاربر از بین نتایج بازیابی شده به وسیله موتور جستجو
- ۳.۱۲. برو به شروع

(شکل-۵): شبکه کد روش پیشنهادی
(Figure-5): Pseudo code of proposed method

نتیجه بر اساس بیشترین میزان شباهت با زمینه کاربر، انتخاب و به عنوان نتایج پیشنهادی ارائه شدند. مشابه نتایج حاصله از موتور جستجو و نتایج ارائه شده توسط روش پیشنهادی با استفاده از معیار مشابهت‌یابی کسینوسی^۱ به صورت زیر به دست می‌آید.

$$\text{similarity} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}} \quad (۲)$$

در رابطه (۲)، n کل عبارات متن نخست و دوم است. همچنین شاخص‌های A_i و B_i به ترتیب بیان‌کننده تعداد تکرار عبارت t_i در متن نخست و متن دوم هستند. در این قسمت متن نخست زمینه کاربر محاسبه می‌شود که در برگیرنده عبارات نشانه و متن دوم خلاصه‌ای است که موتور جستجو به ازای هر نتیجه بازیابی شده ارائه می‌دهد؛ سپس برای نتایج، موتور جستجو و روش پیشنهادی بررسی می‌شود که چه تعداد نتایج مرتب با زمینه بوده‌اند. نتیجه این بررسی نشان می‌دهد که از مجموع سی ارزیابی به عمل آمده، در ۲۱ مورد روش پیشنهادی منجر به بهبود نتایج جستجو شده است. در شش مورد نتایج روش پیشنهادی با نتایج موتور جستجو یکسان است و سه مورد روش پیشنهادی از موتور جستجو ضعیفتر عمل کرده است. نمودار تجمعی نتایج که در شکل (۴) نمایش داده شده است، نشان می‌دهد که در ارائه ده نتیجه نخست مربوط به سی جستار دارای ابهام، به طور میانگین روش پیشنهادی ۴۳٪ و موتور جستجوی گوگل ۱۶٪ از نتایج خود را مرتبط با مفهوم اصلی جستار مورد نظر ارائه کرده‌اند. می‌توان نتیجه گرفت که روش پیشنهادی توانسته است با استفاده از زمینه، به بهبود گویایی منظور جستار کمک کند. همچنین مقایسه تعداد کل نتایج مرتب روش پیشنهادی با کل نتایج مرتب در پنجاه نتیجه نخست موتور جستجو نیز در شکل (۴) نشان داده شده است. مطابق این نتیجه هنوز هم نتایج مرتبی وجود دارند که روش پیشنهادی نتوانسته است آنها را تشخیص دهد. از جمله دلایل این اتفاق آن است که نتایج موتور جستجو در روش پیشنهادی تنها بر اساس خلاصه‌ای که ارائه می‌شوند، اولویت‌بندی می‌شوند و اگر دسترسی به متن صفحات نتایج جستجو ایجاد شود، تعداد بسیار بیشتری از نتایج مرتب به وسیله روش پیشنهادی شناسایی خواهد

^۱ Cosine similarity

- [4] Vaughan, Liwen, and Mike Thelwall, "Search engine coverage bias: evidence and possible causes", *Information processing & management*, vol. 40, no. 4, pp. 693-707, 2004.
- [5] Jansen, Bernard J., et al, "Real life information retrieval: A study of user queries on the web", In ACM SIGIR Forum, vol. 32, no. 1, pp. 5-17, 1998 .
- [6] Jansen, Bernard J., and Danielle Booth, "Classifying web queries by topic and user intent", *CHI'10 Extended Abstracts on Human Factors in Computing Systems*, pp. 4285-4290, ACM, 2010.
- [7] Calderón-Benavides, Liliana, Cristina González-Caro, and Ricardo Baeza-Yates, "Towards a deeper understanding of the user's query intent", *SIGIR 2010 Workshop on Query Representation and Understanding*, pp. 21-24, 2010.
- [8] Abowd, Gregory D., et al, "Towards a Better Understanding of Context and Context-Awareness", *Handheld and ubiquitous computing*. Springer Berlin Heidelberg, pp. 304-307, 1999 .
- [9] Allan, James, and Hema Raghavan, "Using part-of-speech patterns to reduce query ambiguity", In *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*, pp. 307-314, 2002.
- [10] Bäurle, Florian, "A user interface for semantic full text search", Master Thesis, Faculty of Engineerin, University of Freiburg, 2011.
- [11] Bing, Lidong, and Wai Lam, "Investigation of web query refinement via Topic Analysis and Learning with Personalization", 2011.
- [12] Fonseca, Bruno M., et al, "Concept-based interactive query expansion", In *Proceedings of the 14th ACM international conference on Information and knowledge management*, pp. 696-703, 2005 .
- [13] Song, Wei, et al, "An effective query recommendation approach using semantic strategies for intelligent information retrieval", *Expert Systems with Applications*, vol. 41, no. 2, pp. 366-372, 2014 .
- [14] Bordogna, Gloria, et al, "Disambiguated query suggestions and personalized content-similarity and novelty ranking of clustered results to optimize web searches", *Information Processing & Management*, vol. 48, no. 3, pp. 419-437, 2012 .
- [15] Broccolo, Daniele, et al, "Generating suggestions for queries in the long tail with an inverted index", *Information Processing & Management*, vol. 48, no. 2, pp. 326-339, 2012 .
- [16] González-Caro, Cristina, and Ricardo Baeza-Yates, "A multi-faceted approach to query intent classification", *String Processing and Informa-*

۶- نتیجه‌گیری و پیشنهادها

استخراج زمینه کاربر بر اساس صفحات وبی که مشاهده می‌کند، ایده اصلی این پژوهش بوده است، یعنی ویژگی‌های فردی، علاقه، سلیقه و... کاربر را از این داده‌ها می‌توان استخراج کرد؛ سپس از این اطلاعات برای بهبود رتبه‌بندی نتایج موتور جستجو بهره گرفته شده است. ارزیابی‌های به عمل آمده نشان می‌دهند که روش پیشنهادی دقیق و صحی خوبی در انتخاب عبارات مهم از متن و همچنین بهبود رتبه‌بندی نتایج موتور جستجو دارد. استخراج زمینه، نگهداری داده‌ها و کلیه پردازش‌های مربوط به تقویت نتایج جستجوهای موتور جستجو همگی در سمت کاربر اتفاق می‌افتد. با توجه به شناختی که در این پژوهش در حوزه پردازش جستار و به خصوص پردازش جستار به وسیله زمینه کاربر به دست آمده است، پیشنهادهای زیر برای توسعه کارهای آینده مفید خواهد بود. خوشه‌بندی یا دسته‌بندی عبارت استخراج شده به عنوان زمینه، استفاده از هسته‌شناسی‌ها برای یافتن مفاهیم مرتبط با زمینه، استفاده از واژه‌نامه‌ها به منظور ترجمه زمینه کاربر زبان‌های دیگر، به روزرسانی زمینه و تغییر اطلاعات زمینه مطابق با تغییر رفتار کاربر.

تشکر و قدردانی

از جناب آقای مهندس مصلی نژاد که با پیشنهادها، نظرات و همکاری خود در مراحل مختلف نگارش این مقاله به بهبود کیفیت آن کمک کردند، کمال تشکر و قدردانی را داریم.

7-References

۷- مراجع

- [1] Hamdi, Mohamed Salah, "SOMSE: A semantic map based meta-search engine for the purpose of web information customization", *Applied Soft Computing*, vol. 11, no. 1, pp. 1310-1321, 2011.
- [2] Mangold, Christoph, "A survey and classification of semantic search approaches", *International Journal of Metadata, Semantics and Ontologies*, vol. 2, no. 1, pp. 23-34, 2007.
- [3] Kirar, Dilip, and Pranita Jain, "Equirs: Explicitly query understanding information retrieval system based on hmm", *International Journal of Engineering Inventions*, vol. 2, no 1, pp. 31-36, Jan. 2013.

- [28] Luo, Le, and Li Li. "Defining and evaluating classification algorithm for high-dimensional data based on latent topics", PloS one 9, No. 1, 2014.
- [29] Zeng, Hua-Jun, et al, "Learning to cluster web search results", In Proceedings of the 27th annual international ACM SIGIR conference on Research and development in information retrieval, pp. 210-217, 2004 .
- [30] Song, Ruihua, et al, "Identification of ambiguous queries in web search", Information Processing & Management, vol. 45, no. 2, pp. 216-229, 2009 .
- [31] Li, Ying, Zijian Zheng, and Honghua Kathy Dai, "KDD CUP-2005 report: Facing a great challenge", ACM SIGKDD Explorations Newsletter 7, no. 2, pp. 91-99, 2005.
- [32] فرهاد راد، حمید پروین، آتوسا دهباشی و بهروز مینایی. "ارائه روشی جدید برای شاخص گذاری خودکار و استخراج کلمات کلیدی برای بازبایی اطلاعات و خوشه‌بندی متون". فصلنامه علمی-پژوهشی پردازش علائم و داده‌ها، جلد ۱۳، شماره ۱، صفحه ۷۸-۱۰۰، ۱۳۹۵.
- [33] Farhad Rad, Hamid Parvin, Atoosa dahbashi and Behrooz Minaei. "Improved Clustering Persian Text Based on Keyword Using Linguistic and Thesaurus Knowledge", Signal and Data Processing, Vol. 13, No. 1, P.P. 78-100, 2016.



جواد داودي مقدم فارغ التحصيل کارشناسی نرم افزار رایانه از دانشگاه صنعتی بیرجند در سال ۱۳۹۱ و کارشناسی ارشد هوش مصنوعی از دانشگاه صنعتی خواجه نصیرالدین طوسی در سال ۱۳۹۳ است. ایشان از مقطع کارشناسی ارشد فعالیت‌های پژوهشی خود را بر روی پردازش متون فارسی آغاز کردند و با بهره‌گیری از روش‌های هوش مصنوعی و داده‌کاوی ابزارهای مختلفی را برای پردازش متون فارسی به خصوص در حوزه خبر طراحی و پیاده‌سازی کرده‌اند که مورد بهره‌برداری صنعت نیز قرار گرفته است. همچنین تاکنون دو مقاله کاربردی از ایشان در حوزه پردازش متون فارسی در کنفرانس‌های بین‌المللی داخلی ارائه و چاپ شده است. زمینه‌های پژوهشی مورد علاقه ایشان عبارتند از: داده‌کاوی و پردازش متن، طراحی و پیاده‌سازی ابزارهای پردازش زبان فارسی، فهم جستار در موتور جستجو، خصوصی‌سازی نتایج موتور جستجو بر

tion Retrieval, Springer Berlin Heidelb-erg, pp. 368-379, 2011.

- [17] Jiang, Dixin, Jian Pei, and Hang Li, "Mining Search and Browse Logs for Web Search: A Survey", ACM Transactions on Computational Logic, pp. 1-42, Apr. 2013.
- [18] Li, Lin, et al, "A feature-free search query classification approach using semantic distance", Expert Systems with Applications, vol. 39, no. 12, pp. 10739-10748, 2012.
- [19] Bai, Lu, et al, "Exploring the query-flow graph with a mixture model for query recommendation", Proceedings of IGIR Work-shop on Query Representation and Understand-ing, Beijing, China, Jul. 2011.
- [20] Beeferman, Doug, and Adam Berger, "Agglomerative clustering of a search engine query log." In Proceedings of the sixth ACM SIGKDD international conference on Knowledge discov-ery and data mining, pp. 407-416, 2000 .
- [21] Andersen, Casper, and Daniel Christensen, "User Logs for Query Disambiguation", 2013 .
- [22] Sondhi, Parikshit, Raman Chandrasekar, and Robert Rounthwaite. "Using query context mod-els to construct topical search engin-es", In Proceed-ings of the third symposium on Information interaction in context, pp. 75-84, 2010 .
- [23] Wu, Wei, Bin Zhang, and Mari Ostendorf. "Automatic generation of personalized annotation tags for twitter users", In Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics, pp. 689-692, 2010 .
- [24] Biancalana, Claudio, and Alessandro Micarelli. "Social tagging in query expansion: A new way for personalized web search", In Computational Science and Engineering, vol. 4, pp. 1060-1065, 2009 .
- [25] Kramár, Tomáš, Michal Barla, and Mária Bieliková. "Disambiguating search by leveraging a social context based on the stream of user's activity", In User Modeling, Adaptation, and Personalization, pp. 387-392, 2010 .
- [26] Cao, Huanhuan, et al, "Context-aware query classification", In Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval, pp. 3-10, 2009 .
- [27] Joachims, Thorsten. "A Probabilistic Analysis of the Rocchio Algorithm with TFIDF for Text Categorization", Carnegie-mellon univ Pittsburgh pa dept of computer science, No. CMU-CS-96-118, 1996 .

اساس زمینه کاربر، گراف دانشی، سامانه‌های هوشمند و عامل‌های یادگیر.
رایانمه ایشان عبارت است از:
j.davoudi@chmail.ir


علی احمدی دارای مدرک کارشناسی
برق از دانشگاه صنعتی امیرکبیر در
سال ۱۳۶۹ و کارشناسی ارشد و
دکترای هوش مصنوعی از دانشگاه
ایالتی اوزاکای ژاپن در سال‌های ۲۰۰۱

و ۲۰۰۴ میلادی است. ایشان پس از پایان دوره دکترا به مدت سه سال در مرکز پژوهش‌های سامانه‌های نانو در دانشگاه هیروشیما ژاپن مشغول پژوهش در زمینه "طراحی و پیاده‌سازی سخت‌افزاری مدل‌های یادگیر هوشمند" بوده‌اند که منجر به چاپ مقالات علمی در این زمینه شده است. از سال ۱۳۸۶ تاکنون ایشان به عنوان استادیار دانشکده کامپیوتر دانشگاه صنعتی خواجه‌نصیرالدین طوسی و از سال ۱۳۸۹ تاکنون به عنوان رئیس پژوهشکده فناوری اطلاعات این دانشگاه مشغول به فعالیت هستند. زمینه‌های پژوهشی مورد علاقه ایشان عبارتند از: وب‌کاوی و موتورهای جستجوی متنی و تصویری، طراحی محیط‌های واقعیت مجازی و تعاملی، طراحی ترکیبی سخت‌افزاری- نرم‌افزاری مدل‌های یادگیر، محاسبات نرم.

رایانمه ایشان عبارت است از:
ahmadi@eetd.kntu.ac.ir

