

بهبود نتایج موتور جستجوی مبتنی بر مدل بولی و برداری با استفاده از رویکرد معنایی

نرجس راز قندی^(۱)* حسن شاکری^(۲)

(۱) گروه مهندسی کامپیوتر، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران.*

(۲) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

(تاریخ دریافت : ۱۳۹۷/۴/۴) تاریخ پذیرش : ۱۳۹۸/۱۰/۹

چکیده

برای تسهیل جستجو در وب، موتورهای جستجویی طراحی شده‌اند که کاربر را در رسیدن به پاسخ موردنظر یاری می‌دهند. مدل بولی و مدل برداری دو مدل بهینه در موتور جستجو هستند که در تولید نتایج مرتبط با نیازمندی کاربر تأثیر بسزایی دارند. در این مقاله برای بهبود نتایج حاصل از موتور جستجو، در ابتدا برای کشف دقیق‌تر نیاز کاربر، روابط معنایی بین کلمات پرس‌وجوی کاربر در نظر گرفته می‌شود. سپس موتور جستجو، اسناد مرتبط با پرس‌وجوی کاربر را با استفاده از ترکیب مدل بولی و برداری می‌یابد. در مرحله بعد اسناد یافته شده بر اساس میزان ارتباطشان با پرسش با فن TF-IDF رتبه‌بندی می‌شوند و بالاخره لیست بلندی از اسناد مرتبط که بیشترین امتیازها را کسب نموده‌اند به عنوان پاسخ به کاربر بازگردانده می‌شوند. نتایج حاصل از این روش پیشنهادی حاکی از آن است که روش پیشنهادی از نظر دقیقت و کیفیت نتایج جستجو نسبت به تحقیقات قبلی ارائه شده در این زمینه، بهبود قابل ملاحظه‌ای را نشان می‌دهد.

واژه‌های کلیدی: موتور جستجو، مدل بولی، مدل برداری، روابط معنایی

* عهده‌دار مکاتبات:

نشانی: گروه مهندسی کامپیوتر، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران.

تلفن: ۰۹۳۶۶۴۳۴۲۳۰ پست الکترونیکی: narges_razghandi@yahoo.com

۱. مقدمه

حذف کرده و بقیه متن را ریشه‌یابی می‌کنیم و سپس کلمات را وزن دهی کرده و تبدیل به بردار می‌کنیم و با اعمال آستانه، لیست کلمات کلیدی استخراج می‌شود. شاخص‌گذاری یکی از قسمت‌های اساسی و مهم در موتورهای جستجو است به طوری که شاخص‌گذاری مناسب می‌تواند تأثیر قابل توجهی در بالا بردن کارایی موتور جستجو داشته باشد [۵].

یکی از نکات اصلی که برای کاربر اهمیت زیادی دارد نحوه رتبه‌بندی نتایج به دست آمده توسط موتور جستجوگر است. تفاوت در کارایی موتورهای جستجو ناشی از الگوریتم‌ها و مدل‌های مختلفی است که در این قسمت از موتور جستجو پیاده‌سازی شده‌اند. یکی دیگر از نکات این مدل‌ها، رفتار متفاوت آن‌ها در زبان‌های مختلف و مجموعه اسناد مختلف است. به این معنی که مدل‌های بازیابی اطلاعاتی که در موتورهای جستجو به منظور یافتن مشابه‌ترین سند به پرسش کاربر از میان اسناد موجود استفاده می‌شود، برخی از مهم‌ترین آن‌ها مدل فضای برداری و مدل بولی هستند. ما هم مشابه موتور جستجوی علم و فناوری که از دو مدل فضای برداری و مدل بولی استفاده می‌کند و آن‌ها را با یکدیگر ترکیب می‌کند، از ترکیب این دو مدل استفاده می‌کنیم. این مدل‌ها با توجه به مجموعه داده‌های مورداستفاده و زبان مقصود کارایی متفاوتی دارند [۶]. در مدل بولی، نیاز اطلاعاتی کاربر به صورت عبارتی منطقی با عملگرهای and و or، not بیان می‌شود و هر سندی که این عبارت در مورد آن صحیح باشد بازیابی می‌شود [۷/۸]. در مدل برداری، هر سند را به صورت برداری از کلمات در نظر می‌گیریم [۹].

یکی از پرکاربردترین روابط در حوزه بازیابی اطلاعات، پارامتر TF-IDF می‌باشد که از حاصل ضرب فراوانی کلمه در فراوانی معکوس سند به دست می‌آید [۱۰]. دلیل مقبولیت این روش نسبت به سایر روش‌ها را

امروزه موتورهای جستجو از ابزارهای ضروری برای پیدا کردن اطلاعات روی صفحات وب هستند [۱]. در موتور جستجو کاربر کلیدواژه خود را وارد می‌کند، سپس برنامه جستجو با جستجو در بانک اطلاعاتی خود سایت‌های مرتبط با موضوع کاربر را نمایش خواهد داد [۲].

یکی از موتورهای جستجویی که توسط محققان برای مطالعات و آزمایش‌های پژوهشی مورداستفاده قرار می‌گیرد، موتور جستجوی علم و فناوری است. این موتور جستجو ابتدا اطلاعات منتشرشده روی وب سایت‌های دانشگاهی و صفحات شخصی محققان را جمع‌آوری می‌کند، سپس این اطلاعات را پردازش و خلاصه کرده و به کاربران ارائه می‌دهد. موتور جستجو در ابتدا باید منابع اطلاعاتی و مستندات وب را از طریق نرم‌افزاری به نام کاوشنگر وب جمع‌آوری کند. کاوشنگر در مدل کلی صفحات مربوط به سایت‌ها را درخواست می‌کند و در صورت مجاز بودن، صفحات را برای شاخص‌گذاری به واحد مدیریت ذخیره‌سازی می‌دهد تا در مخزن قرار گیرند [۳]. تمام اطلاعات جمع‌آوری شده توسط کاوشنگر وب بعد از طی مراحل ذخیره‌سازی در مخزن در اختیار شاخص‌گذار قرار می‌گیرد [۴].

در این بخش، اطلاعات ارسالی مورد تجزیه و تحلیل قرار می‌گیرد. از آنجاکه حضور همه کلمات متن در شاخص‌گذاری سربار زیادی برای سیستم دارد، به نظر می‌رسد یکی از مشکل‌ترین فعالیت‌ها در روند شاخص‌گذاری انتخاب کلیدواژه‌هایی است که نشان‌دهنده محتویات سند می‌باشد. برای استخراج کلمات کلیدی یک سری پیش‌پردازش‌هایی باید روی متن انجام بگیرد. یکی از این پیش‌پردازش‌ها تعیین کلمات است. پس از تعیین کلمات، کلمات عمومی را

۲. کارهای پیشین انجام شده

در زمینه بهبود دقت و صحت نتایج جستجو توسط موتورهای جستجو کارهای تحقیقاتی متعددی صورت گرفته است. در این بخش، برخی از مهم‌ترین پژوهش‌های ارائه شده در این زمینه را موردنبررسی قرار می‌دهیم.

طبق مرجع [۱] یکی از چالش‌های موجود در موتور جستجو کشف توضیح دقیقی از نیاز کاربر است، زیرا معمولاً کاربران پرس‌وجوهای کوتاه و مبهمی ارسال می‌کنند و به همین دلیل در بسیاری از موارد برای پرسش کاربر پاسخی غیر مرتبط ارائه می‌شود. در این حال همان‌طور که در مرجع [۱] اشاره شده است محققان از فن‌های بازخورد ربط استفاده می‌کنند. در بازخورد ربط، فهرستی از پرسش‌های مرتبط شده با پرسش اولیه کاربر نمایش داده می‌شود که می‌تواند برای کاربر مفید واقع شود. برای مثال اگر کاربر در کلیه موتورهای جستجو عبارت "modonna" را جستجو کند پرس‌وجوهای مرتبطی از "modonnamp3","modonnamusic" قبیل "modonnamusic" به او ارائه خواهد شد. این بازخورد برای اصلاح پرس‌وجوی اولیه و دریافت بهتر نیازهای کاربر به کار می‌رود. در اینجا کاربر می‌تواند به صراحت پرس‌وجوی خود را اصلاح کند، ابهامات احتمالی را از بین ببرد و پرس‌وجوی خود را به یک موضوع دیگر که مربوط به پرس‌وجوی اولیه است هدایت کند. در این فن از قوانین انجمانی استفاده می‌شود که موجب می‌شود نتایج خوبی به کاربر نشان داده شود و دقت موتور جستجو بیشتر شود. ایده این روش این است که الگوی جستجوی قبلی را پیدا می‌کند و با جستجوی فعلی مطابقت می‌دهد تا این اطلاعات برای نشان دادن پیشنهادها مرتبط استفاده کند.

می‌توان با توجه به سهولت در استفاده از این روش محاسبات کم و نتایج قابل قبول دانست [۱۱].

در این مقاله راهکار جدیدی برای بهبود دقت نتایج جستجو در موتورهای جستجو ارائه می‌کنیم که از ایده TF-IDF مبتنی بر رویکرد معنایی استفاده می‌کند. دلیل اینکه رویکرد معنایی را به TF-IDF اضافه می‌کنیم، این است که TF-IDF محدودیتی دارد و آن این است که ارتباط و یکی بودن کلمات مترادف و به طور کلی کلماتی را که با یکدیگر ارتباط معنایی دارند را در نظر نمی‌گیرد. ما سعی می‌کنیم با مشخص کردن سه نوع ارتباط معنایی بین کلمات از قبیل رابطه مترادف بودن، HAS-A و IS-A با استفاده از این رویکرد بر این مشکل غلبه کرده و دقت موتور جستجو را افزایش دهیم. مزیت این روش نسبت به دیگر روش‌های استفاده شده در پژوهش‌های گوناگون این است که نه تنها به محاسبه وزن کلمه مورد جستجو کاربر پرداخته، بلکه وزن و ارزش کلماتی که تشابه معنایی با کلمات مورد جستجوی کاربر دارند هم در نظر گرفته می‌شود. ساختار ادامه این مقاله به شرح زیر است: در بخش ۲ پیشینه تحقیق شامل فن‌های ارائه شده برای بهبود نتایج جستجو، موردنبررسی قرار می‌گیرد. در بخش ۳ راهکار پیشنهادی برای افزایش دقت موتور جستجو ارائه می‌شود. بدین منظور برای بهبود نتایج موتور جستجوی مبتنی بر مدل بولی و برداری آن را با استفاده از رویکرد معنایی بسط و توسعه می‌دهیم. در بخش ۴ روش پیشنهادی مورد ارزیابی قرار می‌گیرد و نتایج حاصل از این ارزیابی‌ها با تحقیقات قبلی ارائه شده در این حوزه مقایسه می‌شود و درنهایت در بخش‌های ۵ و ۶ به ترتیب نتیجه‌گیری مقاله و ایده‌های پیشنهادی برای کارهای آینده مطرح می‌شود.

یکی دیگر از فن‌هایی که محققان در مرجع [۱۲] آبرای رفع چالش فوق ارائه داده‌اند، چارچوبی است که توسط خوشبندی پرس‌وجو به بیبود موتور جستجو کمک می‌کند. در این تحقیق جانسن و همکاران به این نتیجه رسیدند که بیشتر پرس‌وجوها کوتاه هستند.(یعنی در هر پرس‌وجو به صورت میانگین حدوداً دو اصطلاح استفاده شده است). این نتیجه بدست آمده ممکن است ناشی از این باشد که کاربران اطلاعات کمی در مورد موضوع مدنظر خوددارند حتی در بدترین حالت ممکن است آن‌ها ندانند که به دنبال جستجوی چه چیزی هستند. با این حال، کاربران نیاز به آشنایی با اصطلاحات خاصی در حیطه موردنظر خوددارند تا بتوانند پرس‌وجوی مؤثرتری را از موتور جستجو درخواست نمایند. از این فن‌ها برای کشف اطلاعاتی در رابطه با پرسش‌های مرتبط استفاده می‌شود اما موتورهای جستجو برای انجام رتبه‌بندی باکیفیت عالی باید از فن‌های پیشرفته‌تری استفاده کنند. به عبارتی دیگر آن‌ها باید قادر به پردازش ده‌ها هزار پرس‌وجو روی ده‌ها هزار صفحه باشند، بنابراین پرس‌وجو یک مسئله مهم تلقی می‌شود. کار تحقیقاتی ارائه شده در مرجع [۱۳] برای به دست آوردن اسناد مرتبط با پرسش کاربر تنها فن TF-IDF را موردنبررسی قرارداده است. در بخش‌های مختلف مقاله خود، در رابطه با این پارامتر به عنوان قسمتی از راهکار پیشنهادی صحبت خواهیم کرد و نتیجه ارزیابی حاصل از این کار تحقیقاتی صورت گرفته را با رویکرد خود موردقیاس قرار خواهیم داد.

۳. روش پیشنهادی

در این روش ارائه شده با انجام مرحله پیش‌پردازش اصطلاحات مهم و اصلی شناسایی می‌شوند، سپس توسط چند رابطه معنایی کلمات متادف و هم معنی با این اصطلاحات را کشف می‌کنیم. بعد از طی کردن این

مراحل با استفاده از مدل بولی اسنادی را که شامل این اصطلاحات می‌باشد بازیابی کرده و درنهایت با درنظرگرفتن مدل برداری به رتبه‌بندی این اسناد و ارائه نتایج مورد انتظار کاربر می‌پردازیم.

اولین فاز، مرحله پیش‌پردازش است. قبل از فرآیند اصلی جستجو باید عملیات پیش‌پردازشی شامل نشانه‌گذاری، توقف کردن و ریشه‌یابی روی اسناد را انجام دهیم که هر کدام را به شکل خلاصه تعریف می‌کنیم. نشانه‌گذاری روشی است برای جدا کردن کلمات، نمادها و عناصر معنی‌دار دیگر که نشانه نامیده می‌شوند. متوقف شدن فرآیندی است که شامل حذف کلمات پرتکرار می‌باشد. ریشه‌یابی فرآیندی برای به دست آوردن ریشه کلمات است. البته پیش‌پردازش موارد فرعی دیگری را نیز در بر می‌گیرد. نمونه‌های دیگری که برای استخراج کلمات کلیدی بهتر در بک متن استفاده می‌شوند عبارت‌اند از :

نرم‌افزاری

نرم‌افزاری از دو جنبه مطرح می‌شود:

۱. ازلحاظ ظاهری به این معنا که کلمات مشابه که از نظر ظاهر متفاوت‌اند را به ظاهری یکسان تبدیل نماییم. منظور از تفاوت‌های ظاهری، کوچک و بزرگ بودن حروف در زبان انگلیسی است. لذا ابتدا برای نمایش‌های مختلف یک کلمه، کلاس واحدی در نظر گرفته می‌شود. سپس هر زمان که این کلاس در نقاط مختلف متن تکرار شد، یکی از نمایش‌ها که از قبل انتخاب شده است جایگزین کلاس می‌شود. به عنوان مثال، کلمات Friend و friend و FriEnd که همه مشابه یکدیگر ولی در ظاهر متفاوت‌اند. هر کدام از آن‌ها در قسمت از متن که مشاهده شد، با کلمه‌ی friend جایگزین خواهد شد.

متراffد‌ها با استفاده از روابط معنایی و ارتباطات لغوی به یکدیگر پیوند داده شده‌اند. شبکه به دست آمده که شبکه‌ای است از لغات و مفاهیم مرتبط از لحاظ معنایی،

می‌تواند توسط مرورگرها پیمایش شود.

در راهکار پیشنهادی ما مشخصاً سه نوع ارتباط معنایی بین کلمات تعیین می‌شود:

رابطه متراffد بودن: این رابطه اصلی‌ترین رابطه معنایی مورد استفاده است که در واکشی و مرتب‌سازی نتایج جستجو مورد استفاده قرار می‌گیرد. به عنوان مثال دو کلمه «اتومبیل» و «خودرو» به عنوان متراffد یکدیگر در نظر گرفته می‌شوند و جستجو به دنبال هر یک، باید اسناد شامل دیگری را هم ارائه کند.

رابطه IS-A: در علم بازنمایی و شیء‌گرایی، رابطه IS-A عبارت است از یک رابطه‌ای بین دو مفهوم یا کلاس که در آن یک مفهوم زیر کلاس مفهوم دیگر است. به عنوان نمونه کلمه «خودرو» رابطه IS-A با «وسیله نقلیه» دارد چون خودرو زیر کلاسی از کلام وسیله نقلیه است.

رابطه HAS-A: یک رابطه ترکیبی است که یک شیء که جزء نامیده می‌شود، به عنوان یک بخش یا عضو به شیء دیگری که شیء مرکب نامیده می‌شود، تعلق دارد. به عنوان مثال «فرمان» جزئی از اجزای «اتومبیل» است بنابراین بین این دو مفهوم رابطه HAS-A وجود دارد.

در سومین فاز از روش پیشنهادی بر اساس رویکرد بولی، استنادی که کلمات مورد جستجوی کاربر در آن‌ها موجود است پیدا و استخراج می‌شود. این فرآیند با هدف کاهش فضای جستجو و یافتن کلیه اسناد حاوی کلمات مورد نظر صورت می‌گیرد و بدون وزن دهی یا رتبه‌بندی خاصی همه اسنادی را که کلمات کاربر را در بردارند، استخراج می‌کند تا در فاز بعدی پردازش بیشتر جهت انتخاب نهایی و رتبه‌بندی آن‌ها صورت گیرد. بالاخره در فاز چهارم با استفاده از رویکرد برداری نتایج نهایی جستجو به صورت مرتب‌شده استخراج می‌شود. برای این

۲. از لحاظ مفهومی نرم‌افزاری مفهومی شامل عملیات ریشه‌یابی است که در بالا مفهوم ریشه‌یابی را توضیح دادیم.

حذف برخی از عناصر از نظر ظاهری

این مرحله شامل حذف تمام علائم نقطه‌گذاری در متن است. علائم نقطه‌گذاری مانند نقطه، ویرگول و علامت سوال اطلاعات کمی را در اختیار ما قرار می‌دهند و در فرآیند بازیابی، نویز محسوب می‌شوند.

به این ترتیب با حذف آن‌ها، اطلاعات زیادی از دست نخواهیم داد. در عوض آنچه از متن باقی می‌ماند فقط کلمات هستند.

در فاز دوم، روابط معنایی بین کلمات شناسایی و استخراج می‌شود. منظور از روابط معنایی مطالعه و درک ارتباط واژه‌ها با یکدیگر و منطق حاکم بر این ارتباط است. در حقیقت، روابط معنایی می‌خواهد با درک نیت کاربر از طریق معنای کلمات، دقت نتایج جستجو را افزایش دهد و نتایج بهتری را پیش روی کاربر بگذارد. برای این منظور یافتن روابط بین کلمات از اهمیت ویژه‌ای برخوردار است. برای پیدا کردن ارتباط بین کلمات از شبکه واژگان استفاده می‌کنیم. شبکه واژگانیکی از مباحثی است که در چند سال اخیر به شدت مورد توجه قرار گرفته است. وردنت نام عمومی است که بر شبکه‌های واژگانی مختلفی برای بسیاری زبان‌های جهان اطلاق می‌شود. این شبکه‌ها عموماً در نقش واژه ستان شناسی و یا واژگان معنایی محاسباتی در خدمت دستگاه‌های هوشمند دانش‌پایه و معنایگرا قرار دارند.

شبکه واژگان به دلیل دارا بودن یک پایگاه داده غنی از لغات و روابط بین آن‌ها به طور مؤثری استفاده می‌شود. این بانک اطلاعاتی اسم‌ها، فعل‌ها، صفت‌ها و قیدها را به مجموعه‌ای از لغات متراffد دسته‌بندی می‌نماید که هر دسته یک مفهوم مجزا را بیان می‌کند. مجموعه

رتیب‌بندی شده‌ای را در اختیار کاربر قرار می‌دهد. ما برای ارزیابی روش پیشنهادی خود از ۶۰ سند مربوط به حوزه‌های هوش مصنوعی، مهندسی نرمافزار، سرویس وب، کارگزار- هوشمند، منطق و چندین مبحث مرتبط به این عناوین استفاده کرده‌ایم که برای دریافت نتایج مرتبط‌تر، برای هر عنوان مربوطه ده سند در نظر گرفته‌ایم بعد از درنظرگرفتن این داده‌ها فازهای روش پیشنهادی مطرح شده را بر روی آنها اعمال کرده و نتایج حاصل شده از این رویکرد را با نتایج حاصل از مرجع [۱۳و۶] مقایسه می‌کنیم.

۴. ارزیابی روش پیشنهادی

در این بخش تمام فازهای روش پیشنهادی بر روی اسناد جمع‌آوری شده اعمال می‌شود و ثابت می‌شود که روش پیشنهادی نتایج برتری نسبت به روش ارائه شده در مراجع دیگر تولید می‌کند. درنهایت با آنالیز زمان پاسخ و بار اضافی حاصل از افزایش تعداد کلمات مورد جستجو رویکرد پیشنهادی را مورد ارزیابی قرار می‌دهیم.

۱-۴ مقایسه نتایج حاصل از روش پیشنهادی با نتایج حاصل از روش مراجع دیگر
نتایج حاصل شده در این بخش، از اعمال فازهای مختلف روش پیشنهادی بر روی اسناد جمع‌آوری شده به دست آمده است که در شکل ۱-۴ نتایج حاصل از راهکار پیشنهادی ما از نظر دقت در مقایسه با راهکار ارائه شده در مراجع [۱۳و۶] نشان داده شده است.

منظور معیار TF-IDF اسناد حاصل از فاز سوم هم برای کلمات موردنظر کاربر و هم برای کلیه کلماتی که با کلمات مذکور یکی از سه رابطه متادف بودن، IS-A و HAS-A داشته باشند، محاسبه می‌شود و بر اساس آن اسناد مرتب و در خروجی ارائه می‌گردد. وزن کلمات بر اساس رابطه (۱) به دست می‌آید[۱۵و۱۶].

$$(1) \quad \text{TF.IDF} = (\text{TermFrequency} * \text{InverseDocument Frequency})$$

معیار TF به معنای فراوانی تکرار کلمه موردنظر در یک سند است [۱۷]. بدیهی است که هر چه فرکانس تکرار یک کلمه در یک سند بیشتر باشد، آن سند امتیاز بیشتری برای حضور در نتایج جستجو خواهد داشت.

IDF یا فرکانس معکوس سند به معنای فراوانی تکرار کلمه در کل اسناد است. مثلاً کلماتی مانند «و»، «در»، «از» و به‌طورکلی حروف ربط و حروف اضافه با اینکه مکرراً در یک سند تکرار شده‌اند، اما چون در تمام اسناد دیگر هم تکرار شده‌اند، ارزشی ندارند. وزن یک کلمه tk در یک سند zj با درنظرگرفتن یک مؤلفه محلی مربوط به سند و یک مؤلفه سراسری مربوط به کلیه اسناد تعیین می‌گردد[۱۸و۱۹]. فاکتور محلی يا TF متناظر است با فراوانی تکرار کلمه tk در سند zj یعنی تکرار دفعاتی که کلمه مذکور در سند موردنظر وجود دارد. فاکتور سراسری با استفاده از فرکانس معکوس سند يا IDF تخمین زده می‌شود. این معیار به صورت رابطه (۲) تعریف می‌شود:

$$(2) \quad \text{IDF}(tk) = \log(N/nk)$$

که در رابطه فوق، N تعداد کل اسناد شاخص‌گذاری شده و nk تعداد اسنادی است که حداقل یکبار حاوی کلمه tk هستند [۲۰و۲۱].

به‌طورکلی در این فضا هر کلمه‌ای که وزن بیشتری داشته باشد ارزش بیشتری دارد و موتور جستجو را در رساندن کاربر به سند مرتبط یاری می‌دهد. درنهایت موتور جستجو با استفاده از این فن اسناد مرتبط و

شکل ۴-۴ مقایسه بار در صورت اعمال یا عدم اعمال روابط معنایی در روش پیشنهادی


همان‌طور که قابل پیش‌بینی بود، با اعمال رویکرد معنایی بار موتور جستجو کمی افزایش یافته است، که این افزایش بار افزایش زمان پاسخ را هم به همراه دارد، اما این افزایش فقط در حدود ده درصد است و در برابر بهبود دقت حاصل از این رویکرد، قابل چشم‌پوشی است.

۵. نتیجه‌گیری

در این پژوهش روشی برای بهبود نتایج موتور جستجو ارائه شد. در مدل پیشنهادی از رویکرد روابط معنایی استفاده شد که باعث می‌شود که کاربر به سندی که مدنظر دارد نزدیک‌تر شود و آن را بازیابی کند. در این رویکرد کلماتی که با پرس‌وجوی کاربر شباخت معنایی داشتند، استخراج شدند و در جایگاه کلمات ارزشمند قرار گرفتند. درنهایت موتور جستجو را در هدایت کاربر به سمت هدف موردنظر یاری دادند. با ارزیابی و آزمایشی که بر روی روش پیشنهادی اعمال کردیم و مقایسه‌ای که با روش‌های ارائه شده در مراجع [۱۳] و [۶] انجام دادیم به این نتیجه رسیدیم که روابط معنایی درنظر گرفته شده در روش پیشنهادی، سبب بالاتر رفتن دقت موتور جستجو می‌شود. قابل ذکر است که با توجه به ارزیابی به عمل آمده رویکرد معنایی افزایش بار اضافی کلمات و زمان پاسخ را به همراه خواهد داشت. البته این افزایش زمان پاسخ به حدی نیست که ما را از تأثیر مثبت رویکرد معنایی در ارائه اسناد مرتبط با پرس‌وجوی کاربر دور نگه دارد.

۶. کارهای آتی


یکی از ایده‌های پیشنهادی برای ادامه این پژوهش استفاده از روابط معنایی گسترده‌تر برای بهبود دقت



شکل ۴-۱ مقایسه دقت نتایج جستجو در راهکار پیشنهادی در مقایسه با راهکار ارائه شده در مراجع [۶] و [۱۳]

همان‌طور که در شکل ۴-۱ مشاهده می‌شود روش پیشنهادی ما از روش ارائه شده در مراجع [۶] و [۱۳] مناسب‌تر می‌باشد زیرا این روش با درنظر گرفتن روابط معنایی بین کلمات، دقت موتور جستجو را افزایش داده و باعث می‌شود اسناد مرتبط‌تری با پرسش کاربر پیدا شود و برترین نتایج تحت عنوان top1 و top5 و top10 در اختیار کاربر قرار بگیرد.

۴-۲ بار اضافی به وجود آمده از بررسی روابط معنایی



۷. مراجع

- [1] Fonseca, Bruno M., Paulo Braz Golher, Edleno Silva de Moura, and Nivio Ziviani. "Using association rules to discover search engines related queries." In Proceedings of the IEEE/LEOS 3rd International Conference on Numerical Simulation of Semiconductor Optoelectronic Devices (IEEE Cat. No. 03EX726), pp. 66-71. IEEE,(2003).
- [2] Lee, Jihyun, et al. "Effective ranking and search techniques for Web resources considering semantic relationships." Information Processing & Management 50.1 (2014): 132-155.
- [3] Wachsmuth, Henning, et al. "Building an argument search engine for the web." Proceedings of the 4th Workshop on Argument Mining. (2017).
- [4] Martin, Carlstedt. "Using NLP and context for improved search result in specialized search engines." (2017).
- [5] Chauhan, Ekta, and Amit Asthana. "Review of Indexing Techniques in Information Retrieval." International Journal of Engineering Science 13940 (2017).
- [6] Armentano, Marcelo G., Daniela Godoy, Marcelo Campo, and Analia Amandi. "NLP-based faceted search: Experience in the development of a science and technology search engine." Expert Systems with Applications 41, no. 6 (2014): 2886-2896.
- [7] Jayalakshmi, T., and C. Chethana. "A semantic search engine for indexing and retrieval of relevant text documents." Int. J 4, no. 5 (2016): 1-5.
- [8] Hristovski, Dimitar, et al. "Biomedical question answering using semantic relations." BMC bioinformatics 16.1 (2015): 6.

نتایج جستجو می‌باشد. همچنین این امکان وجود دارد که از فن‌های یادگیری ماشین و روش‌های بهینه‌سازی فرا ابتکاری و الهام گرفته از طبیعت استفاده شود، که این فن‌ها باعث بهبود دقت انتخاب اسناد نهایی می‌شود. یک رویکرد دیگر ثبت رفتار کاربر در انتخاب و کلیک روی نتایج جستجوی کاربر در هر پرس‌وجو می‌باشد. نگهداری این اطلاعات در یک بانک اطلاعاتی به منظور شخصی‌سازی جستجو برای کاربران مختلف صورت می‌گیرد.

- [9] Meng, Zeyu, Dong Yu, and Endong Xun. "Chinese microblog entity linking system combining wikipedia and search engine retrieval results." *Natural Language Processing and Chinese Computing*. Springer, Berlin, Heidelberg, (2014). 449-456.
- [10] Nesi, Paolo, Gianni Pantaleo, and Gianmarco Sanesi. "A Distributed Framework for NLP-Based Keyword and Keyphrase Extraction From Web Pages and Documents." *DMS*. (2015).
- [11] Kumari, Madhu, Akshat Jain, and Ankit Bhatia. "Synonyms Based Term Weighting Scheme: An Extension to TF. IDF." *Procedia Computer Science* 89 (2016): 555-561.
- [12] Baeza-Yates, Ricardo, Carlos Hurtado, and Marcelo Mendoza. "Improving search engines by query clustering." *Journal of the Association for Information Science and Technology* 58, no. 12 (2007): 1793-1804.
- [13] Ramos, Juan. "Using tf-idf to determine word relevance in document queries." In *Proceedings of the first instructional conference on machine learning*, vol. 242, pp. 133-142. (2003).
- [14] Zhang, Jiangong, Xiaohui Long, and Torsten Suel. "Performance of compressed inverted list caching in search engines." In *Proceedings of the 17th international conference on World Wide Web*, pp. 387-396. ACM, (2008).
- [15] Boudin, Florian, Hugo Mougard, and Damien Cram. "How Document Pre-processing affects Keyphrase Extraction Performance." *arXiv preprint arXiv:1610.07809* (2016).
- [16] Baquerizo, R., P. Leyva, J. Febles, Hubert Viltres, and Vivian Estrada Sentí Sala. "Algorithm for calculating relevance of documents in information retrieval systems." (2017).
- [17] Khan, Sharifullah, and Jibran Mustafa. "Effective semantic search using thematic similarity." *Journal of King Saud University-Computer and Information Sciences* 26.2 (2014): 161-169.
- [18] Elhadad, Mohamed K., KhaledM Badran, and Gouda I. Salama. "A novel approach for ontology-based dimensionality reduction for web text document classification." In *Computer and Information Science (ICIS), 2017 IEEE/ACIS 16th International Conference on*, pp. 373-378. IEEE, (2017).
- [19] Ram, Naik Ramesh, and C. Namrata Mahender. "Marathi WordNet Development." *International Journal Of Engineering And Computer Science ISSN: 2319-7242* 3, no. 8 (2014): 7622-7624.
- [20] GU, Vasanthakumar, Vanitha Raj KC, Asha Rani BR, P. Deepa Shenoy, and Venugopal KR. "PTMIBSS: PROFILING TOP MOST INFLUENTIAL BLOGGER USING SYNONYM SUBSTITUTION APPROACH." *ICTACT Journal on Soft Computing* 7, no. 2 (2017).
- [21] Markonis, Dimitrios, et al. "The Parallel Distributed Image Search Engine (ParaDISE)." *arXiv preprint arXiv:1701.05596*(2017).