

الله
يُعَزِّزُ
كُلَّ شَيْءٍ

VNFY-Y.2E828



دانشگاه اصفهان

دانشکده فنی و مهندسی

گروه مهندسی کامپیوتر

پایان نامه‌ی کارشناسی ارشد رشته‌ی مهندسی کامپیوتر گرایش نرم افزار

گسترش معنایی پرس‌وجو

استاد راهنما:

دکتر محمد علی نعمت بخش

استاد مشاور:

دکتر ناصر نعمت بخش

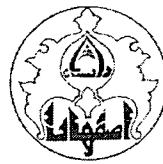
پژوهشگر:

مژگان شیان زاده حبیب آبادی

مهرماه ۱۳۸۹

کلیه حقوق مادی مترقب بر نتایج مطالعات، ابتكارات
و نوآوری های ناشی از تحقیق موضوع این پایان نامه
متعلق به دانشگاه اصفهان است.

شیوه نگارش پایان نامه
رعایت شده است:
تحصیلات تکمیلی دانشگاه اصفهان



دانشگاه اصفهان

دانشکده فنی و مهندسی

گروه مهندسی کامپیووتر

پایان نامه‌ی کارشناسی ارشد رشته‌ی مهندسی کامپیووتر گرایش نرم افزار
خانم مژگان شبان زاده حبیب آبادی تحت عنوان

گسترش معنایی پرس و جو

در تاریخ ۱۴۰۷/۴ توسط هیأت داوران زیر بررسی و با درجه عالی به تصویب نهایی رسید

امضا

۱- استاد راهنمای پایان نامه دکتر محمد علی نعمت بخش با مرتبه‌ی علمی دانشیار

امضا

۲- استاد مشاور پایان نامه دکتر ناصر نعمت بخش با مرتبه‌ی علمی استادیار

امضا

۳- استاد داور داخل گروه دکتر مخدمرضا خیامباشی با مرتبه‌ی علمی استادیار

امضا

۴- استاد داور خارج از گروه دکتر سید رسول موسوی با مرتبه‌ی علمی استادیار



سپاسگزاری

بر خود لازم می‌دانم تا از استاد راهنمای ارجمند جناب آقای دکتر محمدعلی نعمت بخش و همچنین استاد مشاور گرانقدر جناب آقای دکتر ناصر نعمت بخش کمال تشکر و قدردانی را داشته باشم و از خداوند توفيق ایشان را طلب می‌کنم.

از خانواده مهریانم که همواره مشوق و حامی اینجانب در طول زندگی بوده‌اند، سپاسگزاری کرده، سلامتی و موفقیت آنها را از پروردگار مهریان مسئلت دارم. همچنین از تمامی دوستانی که در این راه یاریگر اینجانب بوده‌اند مراتب تشکر و قدر دانی را دارم.

تقدیم به

پروردگار که موفقیت من آرزوی آن ها و سرگردانی آن ها

آرزوی من است.

چکیده

بازیابی اطلاعات یکی از اصلی‌ترین نیازهای کاربران است؛ روزانه کاربران زیادی به جستجو در وب و دیگر منابع به منظور پاسخ‌گویی به نیاز اطلاعاتی خود می‌پردازند. مسائل موجود در زبان طبیعی از جمله عدم تطابق لغوی، کلمات چند معنایی، کوتاه و مبهم بودن پرس‌وجو و داشت ناقص کاربران از موضوع مورد نظر در بازیابی اطلاعات منجر به بازیابی نتایج نامرتب و کاهش رضایت کاربران از نتایج بازیابی شده می‌شود. گسترش پرس‌وجو با بررسی پرس‌وجوهای کاربران و افزودن خودکار کلمات مناسب و با ارزش به آن‌ها کمک می‌کند تا اسناد مرتبط با نیاز و منظور کاربر جستجو و بازیابی گردد. اگر گسترش پرس‌وجو به صورت هوشمندانه‌ای انجام نشود، با انحراف پرس‌وجو و فاصله گرفتن آن از منظور کاربر منجر به بازیابی نتایج نامرتبتری نسبت به نتایج پرس‌وجوی اولیه خواهد شد. مساله‌ی دیگری که در گسترش پرس‌وجو باید به آن توجه کرد این است که در مورد پرس‌وجوهای مشتمل بر بیش از یک کلمه، انتخاب واژگان گسترشی که تنها با یکی از این کلمات مرتبط باشد باعث رخداد مشکل خروج از تعادل پرس‌وجو خواهد شد.

در این رساله، روش جدیدی برای گسترش معنایی پرس‌وجو به منظور تطبیق دادن پرس‌وجو با منظور کاربر ارائه شده‌است. روش پیشنهادی با استفاده از یک الگوریتم رفع ابهام مبتنی بر هستی‌شناسی به رفع ابهام از کلمات پرس‌وجو می‌پردازد. سپس، به منظور در نظر گرفتن روابط بین لغات در پرس‌وجوهای چند کلمه‌ای و اجتناب از مشکل خروج از تعادل پرس‌وجو به گروه‌بندی کلمات آن بر مبنای تشابه معنایی بین آن‌ها می‌پردازد. در ادامه با استفاده از روابط موجود در شبکه واژگان، یک شبکه‌ی معنایی از واژگان هر گروه ایجاد شده از کلمات پرس‌وجو و لغات مرتبط با آن‌ها از نظر معنایی می‌سازد. این روش بر طبق روابط و سلسله مراتب شبکه‌ی ساخته شده، مهمترین کلمات برای گسترش پرس‌وجو را مشخص می‌کند. از بین کلمات انتخاب شده، کلماتی که باعث ایجاد ابهام و نویز در پرس‌وجو نشوند، به عنوان کلمات گسترش انتخاب می‌شوند و وزن مناسبی برای آن‌ها محاسبه می‌شود. به این ترتیب پرس‌وجوی گسترش یافته ساخته می‌شود و عملیات جستجو با این پرس‌وجوی جدید انجام می‌شود. این روش با در نظر گرفتن معیارهای فراخوانی و دقت بر روی مجموعه داده‌ی TIME ارزیابی شده است. نتایج ارزیابی نشان دهنده‌ی افزایش نرخ فراخوانی و دقت بازیابی می‌باشد.

کلمات کلیدی: بازیابی اطلاعات، موتور جستجو، گسترش پرس‌وجو، روابط معنایی.

فهرست مطالب

صفحه	عنوان
	فصل اول: مقدمه
۱	۱-۱ مقدمه
۲	۲-۱ شرح و بیان مساله‌ی پژوهشی
۳	۱-۲-۱ مقایسه‌ی سیستم‌های بازیابی اطلاعات با سیستم‌های بازیابی داده
۴	۲-۲-۱ فرآیند بازیابی اطلاعات
۵	۳-۲-۱ بازیابی اطلاعات کلیدوازه‌ای
۹	۳-۱ هدف تحقیق
۱۰	۴-۱ اهمیت و کاربرد نتایج تحقیق
۱۰	۵-۱ ساختار پایان نامه
	فصل دوم: پیشینه و زمینه‌ی تحقیق
۱۲	۱-۲ مقدمه
۱۲	۲-۱ گسترش پرس‌و‌جو
۱۵	۱-۲-۲ روش‌های محلی گسترش پرس‌و‌جو
۱۶	۲-۲-۲ روش‌های سراسری گسترش پرس‌و‌جو
۱۸	۳-۲ مشکلات موجود در گسترش پرس‌و‌جو
۱۸	۴-۲ پیشینه‌ی تحقیق
۲۷	۵-۲ مدل فضای بردار
۲۸	۶-۲ هستی شناسی
۲۹	۱-۶-۲ شبکه واژگان
۳۱	۷-۲ تشابه معنایی
۳۸	۸-۲ رفع ابهام
۳۸	۱-۸-۲ روش‌های مبتنی بر مجموعه‌ی نوشتار

صفحه	عنوان
۴۰	۲-۸-۲ روش‌های مبتنی بر پایگاه دانش
۴۳	۹-۲ الگوریتم فعال سازی گسترشی
۴۶	۱۰-۲ جمع‌بندی
فصل سوم: طراحی و پیاده سازی یک الگوریتم جدید گسترش معنایی پرس‌وجو	
۴۷	۱-۳ مقدمه
۴۷	۲-۳ تعریف مساله
۴۸	۳-۳ اهداف و انگیزه‌ی طراحی روش جدیدی برای گسترش معنایی پرس‌وجو
۵۰	۴-۳ معماری سیستم
۵۰	۵-۳ مفاهیم اولیه
۵۰	۶-۳ ساختار کلی الگوریتم ارائه شده
۵۲	۱-۶-۳ پیش‌پردازش پرس‌وجو
۵۷	۲-۶-۳ گروه‌بندی کلمات پرس‌وجو
۵۸	۳-۶-۳ ساخت گراف معنایی
۶۰	۴-۶-۳ یافتن کلمات کاندید برای گسترش پرس‌وجو
۶۱	۵-۶-۳ اعمال صافی
۶۲	۶-۶-۳ وزن دهی پرس‌وجوی گسترش یافته
۶۳	۷-۳ جمع‌بندی
فصل چهارم: ارزیابی و تحلیل عملکرد الگوریتم طراحی شده	
۶۵	۱-۴ مقدمه
۶۵	۲-۴ مجموعه داده
۶۸	۳-۴ معیارهای ارزیابی
۶۸	۱-۳-۴ فراخوانی
۶۸	۲-۳-۴ دقیقت

عنوان		صفحه
۴-۴ بستر بازیابی اطلاعات	۶۹	
۴-۵ نتایج آزمایشات	۶۹	
۴-۵-۱ تعیین مقادیر پارامترهای الگوریتم	۶۹	
۴-۵-۲ ارزیابی الگوریتم پیشنهادی	۷۴	
۴-۶ مقایسه الگوریتم پیشنهادی با دیگر الگوریتم‌های گسترش برس و حو و نتیجه گیری	۷۷	
۴-۷ جمع‌بندی	۷۸	
فصل پنجم: نتیجه‌گیری و کارهای آینده		
۱-۵ مقدمه	۷۹	
۲-۵ نتایج	۷۹	
۳-۵ کارهای آینده	۸۰	
واژه‌نامه	۸۳	
منابع و مأخذ	۸۶	

فهرست شکل‌ها

عنوان	صفحه
شکل ۱-۱ فرآیند بازیابی اطلاعات.....	۴
شکل ۲-۱ نتایج پرس‌وجوی "Apple Growing" با موتور جستجوی گوگل	۸
شکل ۳-۱ نتایج پرس‌وجوی "Apple Growing Computers" با موتور جستجوی گوگل	۸
شکل ۱-۲ روش‌های گسترش پرس‌وجو و منابع استخراج واژگان گسترش	۱۴
شکل ۲-۲ فرآیند کلی روش‌های محلی گسترش پرس‌وجو	۱۵
شکل ۳-۲ فرآیند کلی روش‌های سراسری برای گسترش پرس‌وجو	۱۷
شکل ۴-۲ شبیه کد الگوریتم پیشنهادی در مرجع [۲۲]	۲۰
شکل ۵-۲ شبکه‌ی معنایی تولید شده برای اولین معنای bus	۲۵
شکل ۶-۲ الگوهای بین سومین معنای mountain و اولین معنای top	۲۵
شکل ۷-۲ معنای door در شبکه واژگان	۳۰
شکل ۸-۲ روابط زیرمعنایی در شبکه واژگان برای لغت door	۳۱
شکل ۹-۲ ورودی، پارامترها و شبیه کد الگوریتم فعال سازی گسترشی	۴۴
شکل ۱۰-۲ اولین مرحله‌ی الگوریتم فعال سازی گسترشی	۴۵
شکل ۱۱-۲ خروجی مرحله‌ی اول الگوریتم فعال سازی گسترشی	۴۵
شکل ۱۲-۲ خاتمه‌ی الگوریتم فعال سازی گسترشی	۴۵
شکل ۱-۳ فرآیند کلی روش ارائه شده برای گسترش پرس‌وجو	۴۸
شکل ۲-۳ مروری بر روش ارائه شده برای گسترش معنایی پرس‌وجو	۵۱
شکل ۳-۳ تعدادی از کلمات توقف در زبان انگلیسی	۵۶
شکل ۴-۳ روابط بین کلمات در شبکه واژگان	۵۸
شکل ۵-۳ برخی از کلمات پرس‌وجوی نمونه‌ی گسترش یافته	۶۲
شکل ۶-۳ شبیه کد الگوریتم پیشنهادی	۶۴
شکل ۱-۴ محتوای مقاله‌ی شماره‌ی ۲۳ مجموعه داده‌ی TIME	۶۶

عنوان

صفحه

شکل ۲-۴ میانگین دقت بازیابی نسبت به تعداد معانی هر کلمه ۷۴
شکل ۳-۴ نمودار دقت- فراخوانی بازیابی کلید واژه‌ای و گسترش پرس‌وجو ۷۵
شکل ۴-۴ نمودار دقت- فراخوانی بازیابی کلید واژه‌ای و گسترش وزن دار پرس‌وجو ۷۶

فهرست جدول‌ها

عنوان	صفحه
جدول ۱-۱ مقایسه‌ی سیستم‌های بازیابی اطلاعات با سیستم‌های بازیابی داده	۳
جدول ۱-۲ مقادیر بهینه‌ی پارامترهای α , β , γ و δ	۲۱
جدول ۲-۱ دسته بندی مازول‌های تشابه معنایی و نقاط قوت و ضعف آن‌ها	۳۶
جدول ۲-۲ دسته بندی روش‌های رفع ابهام و نقاط ضعف آن‌ها	۴۲
جدول ۱-۳ خروجی نرم افزار WordNet-SenseRelate-AllWords با دریافت پرس‌وجوی نمونه	۵۴
جدول ۲-۳ کلمات غیرتوقف رفع ابهام شده‌ی پرس‌وجوی نمونه	۵۵
جدول ۱-۴ پرس‌وجوهای مجموعه داده‌ی TIME	۶۷
جدول ۲-۴ قسمتی از محتوای فایلی که اسناد مرتبط با هر پرس‌جو را مشخص می‌کند	۶۷
جدول ۳-۴ میانگین دقیق بازیابی نسبت به تشابه معنایی	۷۰
جدول ۴-۴ میانگین دقیق بازیابی نسبت به وزن یال‌ها	۷۱
جدول ۵-۴ میانگین دقیق بازیابی نسبت به عامل کاهنده	۷۲
جدول ۶-۴ میانگین دقیق بازیابی نسبت به حد آستانه‌ی فعل سازی	۷۳

فصل اول

مقدمه

۱-۱ مقدمه

فرآیند تشخیص ارتباط بین استناد و پرس‌وجوی کاربر و بازگرداندن استنادی که احتمالاً نیاز کاربر را تامین می‌کنند، بازیابی اطلاعات نامیده می‌شود. بارزترین کاربرد سیستم‌های بازیابی اطلاعات موتورهای جستجو و کتابخانه‌های دیجیتالی می‌باشد. اگرچه با وجود موتورهای جستجو و کتابخانه‌های دیجیتالی دسترسی به اطلاعات آسان‌تر شده است، اما از آن جایی که حجم اطلاعات وب و کاربران آن روز به روز در حال افزایش می‌باشد، دسترسی به اطلاعات مورد نیاز به چالشی برای کاربران تبدیل شده است. علاوه براین، موتورهای جستجوی کلیدواژه‌ای در پاسخ به نیاز کاربران ضعیف عمل می‌کنند و بسیاری از کاربران نمی‌دانند چگونه پرس‌وجوی مناسب ایجاد کنند. حتی وقتی کاربران با تجربه در حوزه‌ی ناشناخته‌ای به جستجو می‌پردازنند، قادر به ارائه‌ی پرس‌وجوی مناسب و بیان دقیق نیاز اطلاعاتی خویش نمی‌باشند [۱].

گسترش پرس‌وجو با افزودن کلمات به پرس‌وجو نتایج بازیابی اطلاعات را بهبود می‌بخشد. در این پایان نامه با ارائه‌ی روش جدیدی برای گسترش پرس‌وجو سعی می‌شود، بازیابی اطلاعات بهبود بخشد. شود.

در این فصل به معرفی سیستم‌های بازیابی اطلاعات، مشکلاتی که سیستم‌های بازیابی اطلاعات کلید واژه‌ای با آن مواجه می‌باشند و شرح مساله‌ی پژوهشی در این پایان نامه پرداخته می‌شود. سپس اهمیت و کاربرد موضوع بررسی

می شود و همچنین اهداف پایان نامه تبیین خواهد شد.

۱-۲- شرح و بیان مساله‌ی پژوهشی

بازیابی اطلاعات با مسائلی از قبیل نمایش، ذخیره، سازمان دهی و دسترسی اطلاعات مواجه می‌باشد [۲]. نمایش و سازمان دهی اطلاعات باید به گونه‌ای باشد که دسترسی آسان به اطلاعات دلخواه را برای کاربران فراهم کند. بیان دقیق و توصیف صفات اختصاصی نیاز اطلاعاتی^۱ کاربران مساله‌ی ساده‌ای نیست. برای مثال نیاز اطلاعاتی زیر در وب را در نظر بگیرید.

چرا تابع آزادسازی حافظه^۲ در زبان برنامه‌نویسی C++ در محیط ویژوال بر روی سیستم عامل لینوکس با خطای دسترسی مواجه می‌شود؟

بدیهی است که این توضیح کامل از نیاز اطلاعاتی را نمی‌توان مستقیماً برای درخواست اطلاعات با استفاده از واسطه‌های کاربری موتورهای جستجوی امروزی به کار برد. بنابراین کاربر باید در ابتدا نیاز اطلاعاتی خود را به پرس‌وجویی قابل پردازش توسط موتورهای جستجو تبدیل کند.

معمولاً خلاصه‌ای از نیاز اطلاعاتی کاربر توسط پرس‌وجویی مشتمل بر مجموعه‌ای از کلمات کلیدی بیان می‌شود. نیاز اطلاعاتی مطرح شده در مثال بالا برای یک موتور جستجوی انگلیسی زبان ممکن است به صورت یکی از پرس‌وجوهای زیر مطرح شود:

- free error access violation
- error at runtime and break
- "free function" access violation
- "free function" _CrtIsValidHeapPointer(pUserData)
- linux free error
- free function runtime error

با در اختیار داشتن پرس‌وجوی کاربر وظیفه‌ی اصلی سیستم‌های بازیابی اطلاعات، بازیابی اطلاعاتی است که مرتبط با نیاز اطلاعاتی کاربر باشند. ذکر این نکته ضروری است که سیستم‌های بازیابی اطلاعات متفاوت از سیستم‌های بازیابی داده می‌باشند.

¹ Information Need

² Free Function

۱-۲-۱ مقایسه‌ی سیستم‌های بازیابی اطلاعات با سیستم‌های بازیابی داده

در جدول ۱-۱ سیستم‌های بازیابی اطلاعات و سیستم‌های بازیابی داده با هم مقایسه شده‌اند. در سیستم‌های بازیابی داده مانند پایگاه داده‌های رابطه‌ای^۱ داده‌ها ساختار یافته‌اند و از پرس‌وجوهای ساختار یافته برای بازیابی داده استفاده می‌شود. در صورت بازیابی پاسخ غلط در این سیستم‌ها، کل سیستم دچار خطا می‌باشد [۲]. در حالی که در سیستم‌های بازیابی اطلاعات، داده‌ها ساختار یافته می‌باشند به این معنا که داده‌ها متنی می‌باشند و ساختار واضح و آسانی برای کامپیوترها ندارند. علاوه بر این در این سیستم‌ها پرس‌وجوها نیز غیر ساختار یافته و اغلب به زبان طبیعی می‌باشند. در نتیجه ممکن است نتایجی بازیابی شود که با پرس‌وجوی کاربر ارتباطی ندارند و یا ارتباط کمی دارند. چون پرس‌وجوها و داده‌ها به زبان طبیعی می‌باشند، زبان طبیعی ساختار یافته است و ممکن است ابهام داشته باشند [۲].

جدول ۱-۱ مقایسه‌ی سیستم‌های بازیابی اطلاعات با سیستم‌های بازیابی داده

سیستم‌های بازیابی داده	سیستم‌های بازیابی اطلاعات
داده‌های ساختار یافته	داده‌های ساختار یافته
پرس‌وجوهای ساختار یافته	پرس‌وجوها به زبان طبیعی
عدم بازیابی نتایج غلط	امکان بازیابی نتایج نامرتب

برای پاسخگویی به نیاز اطلاعاتی کاربران، سیستم‌های بازیابی اطلاعات باید محتوا اطلاعات را تفسیر و بر طبق میزان مرتبط بودن با پرس‌وجوی کاربر رتبه بندی^۲ کنند. این تفسیر شامل استخراج اطلاعات از اسناد به منظور انطباق آن‌ها با نیاز کاربران است. سختی کار نه تنها دانستن چگونگی استخراج اطلاعات می‌باشد بلکه دانستن چگونگی تصمیم‌گیری در مورد مرتبط بودن اسناد نیز می‌باشد. هدف اصلی بازیابی اطلاعات، بازیابی تمامی اسنادی است که با پرس‌وجوی کاربر مرتبط می‌باشند و امکان بازیابی تعداد کمی اسناد نامرتب نیز وجود دارد.

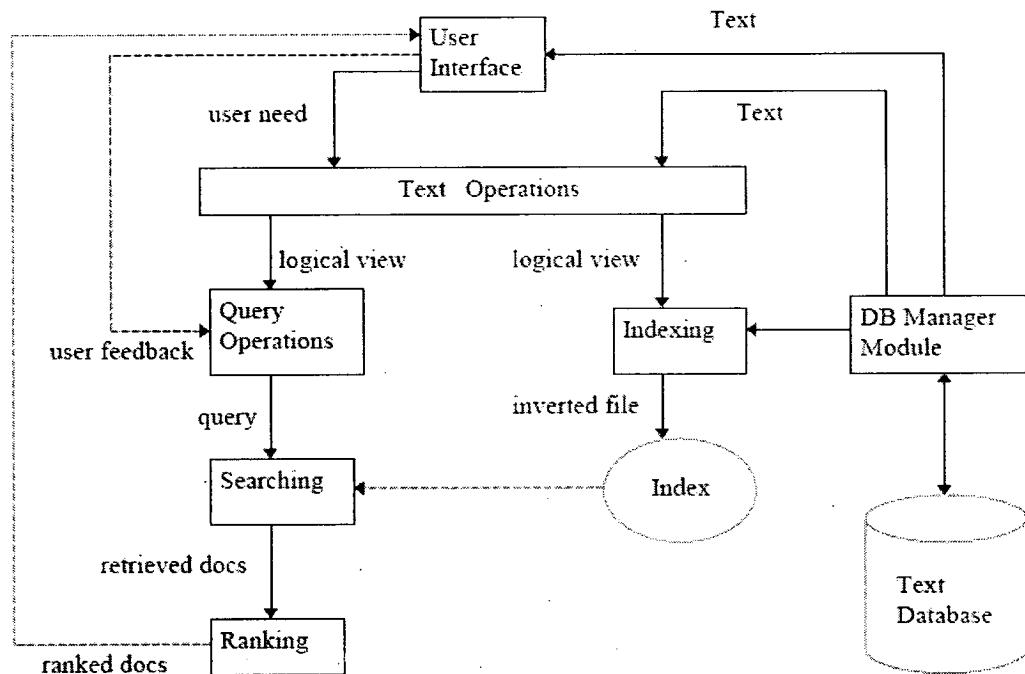
۱-۲-۲ فرآیند بازیابی اطلاعات

در شکل ۱-۱ فرآیند بازیابی اطلاعات نشان داده شده است. به منظور فراهم سازی امکان بازیابی، لازم است که پایگاه متون تعریف شود. این کار با استفاده از مدیر پایگاه داده انجام می‌شود، مدیر پایگاه داده موارد زیر را

¹ Relational Database

² Rank

مشخص می‌کند: الف - استنادی که استفاده می‌شوند. ب - اعمالی که روی متون انجام می‌شود. ج - مدل متن (ساختار متن و عناصری که می‌توانند بازیابی شوند). اعمال متی استناد را تغییر شکل می‌دهند و دیدی منطقی از آن‌ها تولید می‌کنند به این ترتیب که هر سند را با مجموعه‌ای از کلید واژه‌ها نشان می‌دهند. کلید واژه‌ها یا به صورت خود کار از استناد استخراج می‌شوند و یا به صورت دستی برای هر سند مشخص می‌شوند. برای استخراج کلید واژه‌ها، کلمات توقف^۱ از متن حذف می‌شوند. کلمات توقف کلماتی هستند که تقریباً در تمامی استناد رخ می‌دهند و قادر به نفکیک اسناد مرتبط از استناد نامرتبط نمی‌باشند. بقیه واژه‌ها ریشه‌یابی می‌شوند تا تعداد کلیدواژه‌ها کاهش پیدا کند، به این پردازش‌ها اعمال متی گفته می‌شود.



شکل ۱ - فرآیند بازیابی اطلاعات [۲]

با ساخته شدن دید منطقی از استناد، مدیر پایگاه داده، ایندکسی از متون می‌سازد. شاخص ساختار مهمی است و امکان جستجوی سریع روی حجم عظیمی از داده‌ها را فراهم می‌کند. معروف‌ترین ساختار شاخص فایل معکوس است. در فایل معکوس هر واژه به استنادی اشاره می‌کند که این واژه در آن‌ها رخ داده است. اگرچه تولید شاخص

^۱ Stopwords

و پایگاه داده هزینه‌ی زمانی و حافظه‌ای در بر دارد اما چون از سیستم‌های بازیابی اطلاعات بسیار زیاد استفاده می‌شود، این هزینه قابل چشم پوشی است.

پس از ایندکس گذاری استاد پایگاه داده می‌توان عمل جستجو را انجام داد. ابتدا کاربر نیاز اطلاعاتی خود را در قالب یک پرس‌وجو مشخص می‌کند. نیاز اطلاعاتی کاربر توسط همان اعمال متى که به استاد اعمال شده‌اند، مورد پردازش قرار می‌گیرد و تجزیه می‌شود. بعد از آن اعمال پرس‌وجو انجام می‌شود و نیاز کاربر به فرم قابل ارائه به سیستم تبدیل می‌شود. سپس پرس‌وجو برای استخراج استاد پردازش می‌شود. با وجود شاخص، پرس‌وجو به سرعت پردازش می‌شود.

قبل از ارسال نتایج به کاربر استاد بازیابی شده بر اساس میزان مرتبط بودن با نیاز اطلاعاتی کاربر رتبه بندی می‌شوند. سپس کاربر استاد رتبه بندی شده را به منظور پیدا کردن اطلاعات مفید بررسی می‌کند. در این مرحله ممکن است، کاربر زیرمجموعه‌ای از استادی که مشاهده کرده است را به عنوان استاد دلخواه مشخص کند و چرخه‌ی بازخورد کاربر را آغاز کند. در این چرخه، سیستم با استفاده از استادی که کاربر انتخاب کرده است، اطلاعات پرس‌وجو را تغییر می‌دهد و به احتمال زیاد این پرس‌وجوی تغییر یافته نمایش بهتری از نیاز واقعی کاربر فراهم می‌کند.

۱-۲-۳ بازیابی اطلاعات کلیدواژه‌ای^۱

در سیستم‌های بازیابی اطلاعات کلید واژه‌ای معیار میزان مرتبط بودن استاد با پرس‌وجوی کاربر و رتبه بندی استاد، تعداد رخداد واژه‌های پرس‌وجو در آنها می‌باشد. در این سیستم‌ها هر سند و هر پرس‌وجو به عنوان مجموعه‌ای از واژه‌ها در نظر گرفته می‌شود و سندي که بیشترین تعداد رخداد واژه‌های پرس‌وجو را داشته باشد، به عنوان مرتبط‌ترین منبع برای کاربر محسوب می‌شود.

اگرچه موثر بودن بازیابی کلیدواژه‌ای ثابت شده است اما این نوع بازیابی اطلاعات با مشکلاتی نیز مواجه است، این مشکلات را می‌توان به سه دسته‌ی زیر تقسیم‌بندی کرد:

- مشکلاتی که از ذات زبان طبیعی ناشی می‌شوند:

¹ Keyword

- عدم تطابق^۱ واژگان. مشکل عدم تطابق واژگان به این علت رخ می‌دهد که مفاهیم ممکن است با واژگان متفاوتی در پرس‌وجوی کاربر و استاد بیان شوند [۳]. در هر زبانی ممکن است که واژه‌ای یک یا چندین واژه‌ی هم معنا^۲ داشته باشد. بنابراین، این احتمال وجود دارد که کاربران برای توصیف مفاهیم در پرس‌وجوهای خود از واژگانی متفاوت با واژگانی که نویسنده‌گان برای توصیف همان مفهوم به کار می‌برند، استفاده کنند. علاوه بر این نویسنده‌گان متفاوت از واژگان متفاوتی برای بیان مفاهیم یکسان استفاده می‌کنند [۴]. بر طبق [۵] کاربران با نیاز اطلاعاتی یکسان تنها در ۵۲۰ موارد پرس‌وجوی یکسان به کار می‌برند، بنابراین با وجود نیاز یکسان نتایج متفاوتی دریافت می‌کنند. در این موتورهای جستجو مراجعی که هر چند برای کاربر بسیار مفیدند ولی به دلیل عدم وجود واژگان پرس‌وجوی کاربر در آن‌ها و رخداد واژگان هم‌معنا در نتایج جستجو دیده نمی‌شوند. اگر مشکل عدم تطابق در سیستم‌های بازیابی اطلاعات به طور مناسبی حل نشود، کارایی آن‌ها کاهش پیدا خواهد کرد.
- واژگان چندین معنایی^۳. علاوه بر وجود واژگان هم‌معنا، واژگانی نیز وجود دارند که چندین معنا دارند و معنای آن‌ها با توجه به متنی که در آن به کاربرده شده‌اند، مشخص می‌شود. واژگان چند معنایی مشکلاتی را برای موتورهای جستجوی وجود می‌آورند؛ وقتی کاربر در پرس‌وجوی خود واژه‌ای را به کار می‌برد، موتورهای جستجویی که تنها بر اساس انتباط واژگان عمل جستجو را انجام می‌دهند، تنها مراجعی را به کاربر ارائه می‌دهند که واژه‌ی مذکور در مذکور در آن‌ها به کار رفته باشد. پس ممکن است نتایجی ارائه شود که واژه‌ی مذکور در معنایی غیر از معنای مورد نظر کاربر در آن‌ها استفاده شده باشد [۶].

بنابراین با وجود واژگان هم‌معنا و چندمعنا، در بازیابی اطلاعات کلیدواژه‌ای نتایج جستجو بسیار حساس به واژه‌های به کار رفته در پرس‌وجوی کاربر است، به این ترتیب که ممکن است جستجو با واژه‌ای نتیجه‌ای در بر نداشته باشد در حالی که با واژه‌ی متراffد آن به نتیجه برسد. علاوه بر این صحت نتایج جستجو منوط به این است که واژه‌هایی که هم در پرس‌وجوی کاربر و هم در استاد بازیابی شده وجود دارند، به یک معنا باشند.

¹ Mismatch

² Synonym

³ Polysemy

۲ - کاربران

- پرس‌وجوهای کوتاه. کاربران در اغلب موارد اطلاعات مورد نیاز خود را توسط چند واژه بیان می‌کنند، بنابراین معمولاً پرس‌وجوهای کاربران کوتاه می‌باشند. در [۷] بیان شده است که وقتی تعداد کلمات پرس و جو زیاد باشد، گسترش دادن پرس‌وجو کارایی زیادی به دنبال نخواهد داشت ولی پرس‌وجوهای کوتاه معمولاً از گسترش پرس‌وجو سود می‌برند. در واقع علت این مساله ابهام کم‌تر پرس‌وجوهای طولانی و احتمال بیشتر رخداد واژه‌های پرس‌وجوی طولانی در استناد مرتبط با آن‌ها می‌باشد. بنابراین مساله‌ی عدم تطابق در مورد پرس‌وجوهای کوتاه نسبت به پرس‌وجوهای طولانی شدیدتر است. ذکر این نکته ضروری است که معمولاً پرس‌وجوهای کاربران کوتاه می‌باشند، به طوری که متوسط طول پرس‌وجوهای کاربران دو کلمه ذکر شده است [۸].
- دانش ناقص کاربران. کاربران در اغلب موارد، دانش کاملی در مورد موضوع مورد نظر خود ندارند، بنابراین پرس‌وجوهای کاربران معمولاً مبهم‌اند و بیان ضعیفی از نیاز اطلاعاتی کاربر می‌باشند. پرس‌وجوهای ضعیف بازیابی ضعیف اطلاعات را به دنبال حواهند داشت.
- ۳ - سیستم‌های بازیابی اطلاعات. علاوه بر مسائلی که تاکنون مطرح شد، در بازیابی اطلاعات کلیدواژه‌ای تعداد نتایج زیاد است، در بین آن‌ها موارد نامرتبط و تکراری زیاد دیده می‌شود و نتایج مرتبط زیادی نیز بازیابی نمی‌شوند. بنابراین بعد از ارائه‌ی نتایج، کاربر باید آن‌ها را بررسی کند و از بین آن‌ها موارد مرتبط را پیدا کند [۹، ۱۰]. علاوه براین، تعداد زیاد نتایج جستجو از یک طرف باعث سر در گمی کاربران می‌شود و از سوی دیگر باعث می‌شود کاربران تنها چند نتیجه‌ی اولیه‌ی بازیابی را بررسی کنند. در نتیجه ممکن است کاربر به سراغ سند مرتبطی که جزء آخرین نتایج بازیابی است، نرود.

برای روشن‌تر شدن مساله در این جا به ارائه‌ی یک مثال پرداخته می‌شود. پرس‌وجوی "Apple Growing" را در نظر بگیرید، همان طور که در شکل ۲-۱ نیز مشاهده می‌شود، در نتیجه‌ی که با موتور جستجوی گوگل بازیابی شده است، "Apple" به معنای سیب در نظر گرفته شده است. بنابراین اگر نیاز اطلاعاتی کاربر کامپیوترهای اپل باشد با این پرس‌وجو به نتیجه‌ای نمی‌رسد و همانطور که در شکل ۳-۱ نیز مشاهده می‌شود کاربر مجبور است پرس‌وجوی خود را تغییر دهد. با این مثال مشخص می‌شود که نتایج جستجوی کلید واژه‌ای حساس به واژه‌های به کار رفته در پرس‌وجوی کاربر است.