



استناد به این مقاله: هاشم‌زاده، محمد جواد؛ نجعی، زینب؛ مرادی مقدم، حسین (۱۳۹۲). کاربرد و تعدیل قانون زیف و الگوی بازو در بازشناسی واژه‌های بازدارنده زبان فارسی با استفاده از خوش‌بازانی مقالات علمی – پژوهشی رشته کتابداری و اطلاع‌رسانی. پژوهش‌نامه کتابداری و اطلاع‌رسانی، ۳(۲)، ۲۰۸-۱۹۱.

کاربرد و تعدیل قانون زیف و الگوی آماری زو در بازشناسی واژه‌های بازدارنده زبان فارسی با استفاده از خوش‌بازانی مقالات علمی – پژوهشی رشته کتابداری و اطلاع‌رسانی

دکتر محمد جواد هاشم‌زاده^۱، زینب نجعی^۲، حسین مرادی مقدم^۳
دریافت: ۱۳۹۱/۷/۲۹ پذیرش: ۱۳۹۲/۴/۴

چکیده

هدف: شناسایی و استخراج سیاهه‌های نظاممند از واژه‌های بازدارنده به منظور استفاده در نمایه‌سازی خودکار متن‌های فارسی رشته کتابداری و اطلاع‌رسانی

روشن: روش تحلیل محتوا است. جامعه پژوهش، ۵۶ مقاله با روشن نمونه‌گیری تصادفی ساده انتخاب شدند.

یافته‌ها: از مجموع ۱۵۵۷ واژه موجود در متن مقالات، مطابق با الگوی زو، قبل از تعدیل واژه‌ها، ۱۳۶۱ و بعد از تعدیل، ۴۶۱ واژه؛ مطابق قانون زیف نیز قبل از تعدیل، ۲۱۷ و بعد از تعدیل، ۶۰۷ واژه به عنوان واژه بازدارنده شناخته شدند. همچنین از مجموع ۱۹۱۹ واژه موجود در چکیده مقالات، مطابق با الگوی زو قبل از تعدیل واژه‌ها، ۱۶۸ و بعد از تعدیل، ۱۷۳ واژه و بر اساس قانون زیف، قبل از تعدیل، ۶۰ و بعد از تعدیل، ۱۸۶ واژه به عنوان واژه بازدارنده استخراج شدند. در هر دو روش رابطه مستقیمی بین بسامد واژه‌ها و احتمال بازدارنده بودن آن‌ها مشاهده شد. بالاترین درصد واژه‌های بازدارنده (۳۹/۴۴ درصد) بدون احتساب بسامد، در متن مقالات و با کاربرد الگوی آماری زو به دست آمد. نتایج این پژوهش به افزایش کارایی، کاهش حجم فایل درونداد و صرفه‌جویی در زمان و هزینه ذخیره و بازیابی اطلاعات منجر می‌شود.

کلیدواژه‌ها: واژه‌های بازدارنده؛ بسامد؛ واژگانی؛ قانون زیف؛ نمایه‌سازی خودکار؛ الگوی آماری زو.

پژوهشگاه علوم انسانی و مطالعات فرهنگی بریانج حاصل حاصل علوم انسانی

۱. استادیار گروه کتابداری و اطلاع‌رسانی دانشگاه بیرجند؛ hashemzadeh@birjand.ac.ir

۲. کارشناس ارشد کتابداری و اطلاع‌رسانی دانشگاه بیرجند؛ z.nakhaie@yahoo.com

۳. مدرس دانشگاه بیرجند؛ moradymoghadam@gmail.com

مقدمه

در طول چند دهه گذشته و با تلاش‌های متخصصان اطلاع‌رسانی، نمایه‌سازی خودکار توانسته است به عنوان ابزاری برای سازماندهی و در دسترس قرار دادن حجم عظیم اطلاعات موجود یا به عبارتی مقابله با انفجار اطلاعات مطرح گردد که در آن کل فرایند نمایه‌سازی، اعم از استخراج کلیدواژه‌ها، مرتب کردن مدخل‌ها و... توسط رایانه انجام می‌گیرد. در این نوع نمایه‌سازی به روش‌هایی که بر فراوانی نسبی کلمات در متن مبتنی هستند، تکیه می‌شود. تعیین واحدهای متونی و مشخص کردن حد و مرز واژه برای کلمات در مسائل اساسی در گزینش اصطلاحات نمایه‌ای در نمایه‌سازی خودکار است (گیلوری، ۱۳۷۹). ماشین از مسائل اساسی در گزینش اصطلاحات نمایه‌ای در نمایه‌سازی خودکار است (گیلوری، ۱۳۷۹). به علاوه، امکان تشخیص واژه‌های مفهومی از واژه‌های بازدارنده، در فرایند انتخاب اصطلاحات نمایه‌ای تأثیر بسزایی دارد. آنچه مسلم است، ماشین این امکان تشخیص را تها از طریق تطبیق واژه‌های استخراج شده از متن یا منتبش شده به متن با فهرستی که واژه‌های غیرمجاز (بازدارنده)^۱ نامیده می‌شود، به دست می‌آورد (سنجری، ۱۳۸۷). البته تعیین واژه‌های غیرمجاز کار راحتی نیست، زیرا هر واژه ممکن است در نظامی مجاز و در نظامی دیگر غیرمجاز تلقی شود (تیلور^۲، ۱۳۸۱).

در بازیابی اطلاعات عموماً کلماتی را که به صورت مکرر در متن ظاهر می‌شوند اما به تنها بار معنایی ندارند و در ارتباط با واژه‌های دیگر معنا می‌یابند و فقط به دلیل دستوری مورد استفاده قرار می-گیرند، واژه‌های غیرمجاز می‌نامند. شناسایی این گونه از واژه‌ها یکی از مراحل اساسی در امر سازماندهی، ذخیره و بازیابی اطلاعات است که کاربرد آن در رشته‌های علمی و در فرایندهای نمایه‌سازی از قبیل نمایه‌های کوئیک مشخص شده است. به علاوه، سیاهه بازدارنده یک ابزار بنیادی و ضروری برای خوشه-بندی مدارک و تحلیل شباهت مدارک و سایر اموری که با تحلیل مدارک سروکار دارند، می‌باشد که استفاده از آن منجر به کارایی بهتر این امور می‌شود. در صورتی که این واژه‌ها قبل از فرایند نمایه‌سازی مدارک مشخص و فهرست آن‌ها برای کنترل به رایانه داده شود، باعث صرفه‌جویی در زمان و حجم بایگانی‌های نمایه شده و کارایی فرایند نمایه‌سازی را بین ۳۰ تا ۵۰ درصد افزایش می‌دهد؛ هم‌چنین به میزان زیادی از بازیابی مدارک نامرتب و ریزش کاذب در جست‌وجو جلوگیری خواهد کرد (زو^۳ و دیگران، ۲۰۰۶). اما با وجود این، قواعد روشنی برای ایجاد چنین فهرستی وجود ندارد و بیشتر پژوهشگران از روش‌های مختلف برای استخراج واژه‌های بازدارنده استفاده می‌کنند مانند: ۱. بسامد^۴؛ ۲. کارکرد

1. Stop Words

2. Taylor

3. Zou

4. Frequency

نحوی؛ ۳. کاربرد قانون زیف^۱؛ ۴. محاسبه نمره واژه و ۵. محاسبه آنتروپی^۲ واژه. با توجه به این که اغلب شیوه‌های شناسایی و استخراج واژه‌های بازدارنده بر بسامد واژگانی به عنوان بهترین و متداول‌ترین راه تأکید دارند و هم‌چنین بر اساس قانون زیف و الگوی آماری زو و همکاران (۲۰۰۶) که مشخص ساخت واژه‌های دارای بسامد بالا و توزیع ثابت در مدارک مختلف به عنوان واژه‌های بازدارنده در نظر گرفته می‌شوند، پژوهش حاضر بر آن است که قابلیت به کارگیری دو روش مبتنی بر بسامد را در زبان فارسی مورد بررسی قرار دهد و بر این اساس واژه‌های بازدارنده موجود در متن و چکیده مقالات علمی – پژوهشی رشته کتابداری و اطلاع‌رسانی را شناسایی نماید.

پژوهش

۱. واژه‌های بازدارنده موجود در متن مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس الگوی آماری زو، کدام است؟
۲. واژه‌های بازدارنده موجود در چکیده مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس الگوی آماری زو، کدام است؟
۳. واژه‌های بازدارنده موجود در متن مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس قانون زیف، کدام است؟
۴. واژه‌های بازدارنده موجود در چکیده مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس قانون زیف، کدام است؟
۵. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن و چکیده، در الگوی زو هم خوانی وجود دارد؟
۶. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن و چکیده، در روش زیف هم خوانی وجود دارد؟
۷. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن مقاله‌های دو روش زو و زیف هم خوانی وجود دارد؟

1. Zipf law

2. آنتروپی یکی از مقیاس‌های بنیادی در نظریه اطلاعات است که میزان وضعیت تصادفی بودن یک علامت (سیگنال) یا یک اتفاق تصادفی را محاسبه می‌کند و یا میزان اطلاعاتی که توسط یک علامت حمل می‌شود را نشان می‌دهد.

۸. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از چکیده مقاله‌های دو روش زو و زیف هم خوانی وجود دارد؟
۹. واژه‌های بازدارنده چه حجمی از متن و چکیده مقاله‌های حوزه مورد بررسی را تشکیل می‌دهند؟

پیشینه پژوهش

از آنجا که واژه‌های بازدارنده نقش مهمی در بازیابی اطلاعات در پایگاه‌های اطلاعاتی دارند و حذف آنها در نمایه‌سازی خود کار سبب سرعت بخشیدن به پردازش اطلاعات و در نتیجه صرفه‌جویی در زمان و فضای ذخیره‌سازی می‌شود، پژوهش‌های زیادی در سراسر جهان و در زبان‌های مختلف پیرامون این موضوع انجام شده است.

فاکس^۱ (۱۹۹۰) از اولین افرادی بود که فهرست واژه‌های بازدارنده را تهیه کرد. وی از روش بسامد استفاده کرد و پرسامدترين واژه‌های به دست آمده از پیکره زبانی برآون^۲ را با در نظر گرفتن نقطه برش^۳ بسامد، به عنوان واژه‌های بازدارنده عمومی در زبان انگلیسی پیشنهاد کرد. فهرست او شامل ۴۲۱ واژه بازدارنده بود که بعداً این فهرست در سیستم بازیابی اوکاپی^۴ مورد استفاده قرار گرفت.

ویلبور و سیروتکین^۵ (۱۹۹۲) مجموعه‌ای از ۷۱۳۱ مدرک مدلاین در حوزه بیوتکنولوژی را بررسی قرار دادند و دریافتند که با حذف واژه‌های بازدارنده، حجم واژه‌های مدارک حدود ۷۵ درصد کاهش می‌یابد.

لازارینیس^۶ (۲۰۰۷) مراحل ایجاد یک سیاهه بازدارنده برای زبان یونانی و تأثیر حذف آن از پرسش‌های کاربران را مورد بررسی قرار داد و دریافت زمانی که واژه‌های بازدارنده از پرسش کاربران حذف شدند، جست‌وجو سریع‌تر انجام شد و تعداد صفحات مرتبط بیشتری بازیابی شد.

در پژوهشی پاندی و سیدیکوئی^۷ (۲۰۰۷) به ارزیابی تأثیر ریشه‌یابی و حذف کلمات بازدارنده بر بازیابی متون هندی پرداختند و به این نتیجه رسیدند که حذف کلمات بازدارنده به طور معنادار باعث

1.Fox

۲. این پیکره شامل ۵۰۰ مدرک بود که همه آن‌ها برای اولین بار در سال ۱۹۶۱ منتشر شدند. این پیکره تقریباً ۱۰۴۰۰ واژه را از متون جاری ۱۶۷ حوزه نوشتاری در بر داشت.

3 Cutt off Point

4 okapi

5 Wilbur & Sirokin

6 Lazarinis

7 Pandey & Siddiqui

افزایش دقت بازیابی و کاهش حجم فایل نمایه شد.

در پژوهشی دیگر هانو و هانو^۱ (۲۰۰۸) یک رویکرد خودکار برای ایجاد فهرست واژه‌های بازدارنده در رده‌بندی متون چینی ارائه نمودند و هر واژه‌ای که دارای بسامد بالا در مدرک و همبستگی آماری کم با سایر طبقه‌های موجود در طرح رده‌بندی متون چینی بود، به عنوان واژه بازدارنده انتخاب نمودند. آن‌ها به این نتیجه رسیدند که سیاهه آن‌ها که در رده‌بندی نوشتۀ‌های چینی مؤثر است و باعث افزایش دقت و کاهش زمان رده‌بندی می‌شود.

در زبان فارسی سنجی (۱۳۸۷) پس از تعیین بسامد و نوع دستوری واژه‌های موجود در مقالات رشته‌های روانشناسی، علوم تربیتی و کتابداری و اطلاع‌رسانی، تعداد ۹۷۲۸۰ واژه (۱۲۹۱) واژه بدون احتساب بسامد) را به عنوان واژه‌های غیرمفهومی در سه رشته مورد مطالعه شناسایی نمود. هم‌چنین نشان داد که افعال، قیود، ضمایر، حروف، اصوات، اعداد و علائم سجاوندی به عنوان واژه‌های نمایه‌ای ظاهر نمی‌شوند.

در پژوهشی دیگر داورپناه، سنجی و آرمیده (۲۰۰۹) طی دو مرحله به بررسی ۶۳ مقاله در حوزه-های روان‌شناسی، علوم تربیتی و کتابداری و اطلاع‌رسانی و همچنین پیکره ایجاد شده به وسیله روزنامه همشهری پرداختند. در مرحله اول ۷۴۶ واژه و در مرحله دوم ۴۲۲ واژه را به عنوان واژه بازدارنده معرفی کردند. به طور کلی از مرور پیشینه پژوهش می‌توان دریافت که پژوهش‌های بسیاری در مورد واژه‌های بازدارنده (ساووی^۲، ۱۹۹۹؛ ابوالخیر^۳، ۲۰۰۶؛ بسامد (ادموندسون و وایلز^۴، ۱۹۵۹)؛ (برگ^۵، ۱۹۹۷) و قانون زیف (فرانسیس و کوسرا^۶، ۱۹۶۷؛ آрапوو و فیمووا و اشرايدر^۷، ۱۹۷۵) به ویژه در خارج کشور و پژوهش‌های کم‌تری در مورد زبان فارسی صورت گرفته است اما بر اساس بررسی‌های انجام شده پژوهشی مقایسه‌ای در مورد شناسایی واژه‌های بازدارنده مطابق با الگوی آماری زو و همکاران (۲۰۰۶) و قانون زیف یافت نشد. در بیشتر این پژوهش‌ها از روش بسامد واژگانی استفاده شده است و اکثر فهرست‌های بازدارنده به دست آمده، کاربرد عمومی دارند و فقط تعداد انگشت شمار و محدودی از این فهرست‌ها در حوزه‌های خاص موضوعی و به صورت تخصصی تهیه شده‌اند. محققان در پژوهش‌های خود از پیکره‌های گوناگونی استفاده کرده‌اند. تعدادی از آن‌ها پیکره زبانی خود را از میان پایگاه‌های اطلاعاتی یا وب‌سایت-

1. Hao & Hao
2. Savoy
- 3 .Abu-El Khair
- 4 . Edmundson & Wylls
5. Berg
6. Francis & kucera
7. Arapov, Fimova & Shreider

ها انتخاب نموده‌اند و عده‌ای دیگر مجموعه مدارک چاپی (مقاله، روزنامه، چکیده و مانند آن) را مورد سنجش قرار داده‌اند. با توجه به این که تاکنون پژوهشی مقایسه‌ای در مورد شناسایی واژه‌های بازدارنده از یک خوشه واژگانی با استفاده از الگوی تطبیقی مشاهده نشده است، ضرورت پرداختن به این مقوله اهمیت می‌یابد.

روش پژوهش

این پژوهش از نظر هدف کاربردی و به روش تحلیل محتوا انجام گرفته است. جامعه آماری این پژوهش ۵۶ مقاله چاپ شده در آخرین شماره منتشر شده سال ۱۳۸۹ مجلات علمی-پژوهشی کتابداری و اطلاع‌رسانی می‌باشد که از بین آن‌ها ۲۰ مقاله با روش نمونه‌گیری تصادفی ساده انتخاب شدند.

ابزار پژوهش

۱. تهیه خوشه زبانی و متن الکترونیکی مقاله‌ها و چکیده‌های آن‌ها: در این مرحله تنها متن مقاله‌ها بدون در نظر گرفتن پانویس‌ها، ارجاعات، فرمول‌ها، جداول، نمودارها، اعداد ریاضی و منابع و مأخذ در محیط نرم‌افزاری word تایپ شد تا شیوه تایپ آن‌ها یکدست شود (مانند جست‌وجو و جستجو).
۲. تعدل دستوری واژه‌ها (تفکیک واژگان): بخش‌های یک واژه مطابق با معیارهای مطرح شده در پژوهش سنجی (۱۳۸۷) مورد استفاده قرار گرفت. در این معیارها دستورالعمل‌هایی در مورد صیغه‌ها و وجود افعال، افعال مرکب، مصدرهای مرکب، اسمی مرکب، اسمی پیشوندی، میانوندی و پسوندی، گروه‌های حرف اضافه، اسمی، قیدی و هم‌چنین تفکیک واژه‌ها از یکدیگر بر اساس فاصله بین آن‌ها، ارائه گردیده است.

۳. اجرای الگوی زو/قانون زیف:

(الف) الگوی آماری زو: پس از تعیین بسامد تمام واژه‌های موجود در متن و چکیده مقالات مورد

بررسی، مطابق فرمول، $P_{i,j}$ آن‌ها محاسبه شد. به این صورت که بسامد واژه در یک متن/ چکیده بر کل تعداد واژه‌های همان متن/ چکیده تقسیم شد. سپس با استفاده از دو نرم‌افزار SPSS و MINITAB برای هر واژه با توجه به فرمول‌های زیر، «میانگین احتمال»، «واریانس احتمال» و «ارزش آماری واژه یا ضریب

1. Mean of Probability
2. Variance of Probability

تغییرات^۱ در کلیه متن‌ها و چکیده‌های آن‌ها محاسبه شد:

جدول ۱. فرمول‌های مربوط به الگوی زو

ارزش آماری واژه	واریانس احتمال	میانگین احتمال
$SAT(W_j) = \frac{\sqrt{VP(W_j)}}{MP(W_j)}$	$VP(W_j) = \frac{\sum_{1 \leq i \leq N} (P_{i,j} - \bar{P})^2}{N}$ میانگین P های یک واژه.	$MP(W_j) = \frac{\sum_{1 \leq i \leq N} P_{i,j}}{N}$ = تعداد مدارک است که در N این پژوهش ۲۰ مقاله می‌باشد.

با بررسی ارزش آماری واژه‌های به دست آمده از این روش، نقطه برش در متن مقالات ۳۰۰ و در چکیده مقالات ۲۶۲ در نظر گرفته شد تا به این صورت بتوان تعداد واژه‌های غیرمفهومی بیشتری را در فهرست بازدارنده قرار داد. هر واژه‌ای از متن یا چکیده که ارزش آماری آن کمتر از این دو نقطه برش بود، به عنوان واژه بازدارنده انتخاب شد.

ب) قانون زیف: بر این اساس، واژه‌ها به ترتیب بسامد از زیاد به کم مرتب شدند. بالاترین بسامد واژه‌های موجود در هر مقاله تعیین شد و بر اساس این فرمول نقطه عطف آن مقاله مشخص شد: $\frac{-1 + \sqrt{1 + 8F}}{2} = T$ (هویدا ۱۳۷۸).

F_i : بالاترین بسامد واژه‌های موجود در یک مقاله است که در طبقه اول جدول زیف قرار گرفته است به این ترتیب در پژوهش حاضر برای هر متن و چکیده مقاله یک نقطه عطف تعیین شد و کلماتی از آن‌ها که بسامدی بالاتر از این نقاط عطف داشتند، به عنوان بازدارنده استخراج شدند و در یک فهرست قرار گرفتند و واژه‌های بازدارنده تکراری حذف شدند.

۴. تعدیل محتوایی و توجه به معنادار بودن یا غیرمعنادار بودن واژه‌ها: در شیوه اول یا قبل از تعدیل، واژه‌های بازدارنده بر اساس ارزش آستانه‌ای یا نقاط عطف تعیین شده استخراج شدند. اما در شیوه دوم یا بعد از تعدیل، ابتدا فهرست واژه‌های بازدارنده استخراج شده (قبل از تعدیل) مورد بازبینی قرار گرفت و واژه‌های معنادار آن‌ها حذف شد و سپس تعدادی از واژه‌های غیرمفهومی که در فهرست نیامده بودند، به فهرست اضافه شدند. پژوهش بر اساس قواعد ارائه شده آماری که کاربرد غیر قابل انکاری در شناسایی واژگان غیرمفهومی دارند و هم‌چنین بر اساس قاعده و نظریه زیف در مورد اصل کمترین کوشش

1. Statistical Value of word (SAT)

که پژوهش‌های بسیار زیادی پیرامون آن انجام پذیرفته، بنا شده است. همچنین برای غنا بخشیدن به این یافته‌ها در زبان فارسی سعی گردید از معیارهای مطرح شده در پژوهش سنجی به عنوان مبنای برای شناسایی واژه‌های مفهومی و غیرمفهومی و تشخیص و جداسازی واژه‌های بازدارنده از غیر بازدارنده استفاده شود. به این صورت که پس از تعیین نوع دستوری واژه‌های استخراج شده، اگر واژه‌ای جزء یکی از گروه‌های دستوری مورد اشاره در پژوهش ایشان (اعمال، قیود، ضمایر و...) بود، به عنوان بازدارنده و در غیر این صورت به صورت واژه مفهومی در نظر گرفته شد.

یافته‌های پژوهش

در مورد هر فهرست، فقط ۱۰ واژه بازدارنده ابتدای فهرست‌های به دست آمده ارائه شده و فهرست‌های کامل از طریق ارتباط با پژوهشگر قابل دسترس است.^۱ لازم به ذکر است که علائم سجاوندی نیز در این پژوهش مورد پردازش قرار گرفته‌اند اما از جداول حذف گردیده است.

۱. واژه‌های بازدارنده موجود در متن مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس الگوی آماری زو، کدام است؟

جدول ۲. فهرست واژه‌های بازدارنده متن مقاله‌ها بر اساس الگوی زو «قبل و بعد از تعدیل»

ردیف	واژه	قبل از تعدیل	بعد از تعدیل	میانگین احتمال	واریانس احتمال	ارزش آماری
۱	آشکال	✓	-	۰.۰۰۱۰۵	۰.۰۰۰۵۳۱۶	۲۱۹.۵۳
۲	ابتدا	✓	-	۰.۰۰۳	۰.۰۰۰۱۱۷	۱۱۳.۹۴
۳	ابزار	✓	-	۰.۰۰۵۶۵	۰.۰۰۰۳۵۴	۱۰۵.۳
۴	ابعاد	✓	-	۰.۰۰۲۹	۰.۰۰۰۵۰۲	۲۲۴.۳۲
۵	اثر	✓	-	۰.۰۰۶۱۵	۰.۰۰۰۲۲۹	۲۴۶.۷۷
۶	احتمالاً	✓	✓	۰.۰۰۰۵	۰.۰۰۰۱۶۳۱۵۸	۲۵۵.۴۷
۷	ارائه	✓	✓	۰.۰۰۱۲۴۵	۰.۰۰۰۳۴۹	۱۴۹.۹۸
۸	ارائه شده	✓	✓	۰.۰۰۶۳	۰.۰۰۰۵۵۹	۱۱۸.۰۳
۹	ارتباط	✓	-	۰.۰۰۱۱۲۵	۰.۰۰۰۱۳۶	۱۰۳.۷۸
۱۰	اثرگذار	✓	-	۰.۰۰۰۳	۰.۰۰۰۴۳۱۵۷۹	۲۱۸.۹۸
	جمع	۱۳۶۸	۴۶۸			

۱. در صورت لزوم با آدرس ایمیل پژوهشگر مکاتبه شود.

نتایج جدول ۲ نشان می‌دهد که واژه‌های موجود در متن مقالات پس از اعمال الگوی زو تبدیل به ۳۴۶۸ واژه شدند که از بین آن‌ها قبل از تبدیل واژه‌ها، ۱۳۶۸ واژه و بعد از تبدیل آن‌ها، ۴۶۸ واژه به عنوان واژه بازدارنده استخراج شدند که در جدول فقط ۱۰ واژه اول ارائه شده است.

۲. واژه‌های بازدارنده موجود در چکیده مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس الگوی زو، کدام است؟

جدول ۳. فهرست واژه‌های بازدارنده چکیده مقاله‌ها بر اساس الگوی زو «قبل و بعد از تبدیل»

ردیف	واژه	قبل از تبدیل	بعد از تبدیل	میانگین احتمال	واریانس احتمال	ارزش آماری واژه
۱	است	✓	✓	۰,۰۱۰۵۵	۰,۰۰۰۰۳۷	۵۵,۰۴
۲	استفاده	✓	-	۰,۰۰۰۵۷۸	۰,۰۰۰۰۶۱۸	۱۳۶,۱۳
۳	استفاده شد	✓	-	۰,۰۰۱۵۳۵	۰,۰۰۰۰۶۴۱	۱۶۴,۹۲
۴	افرايش	✓	-	۰,۰۰۱۶۰۵	۰,۰۰۰۰۶۷۷	۱۶۲,۱۱
۵	اطلاعاتي	✓	-	۰,۰۰۰۲۸۸	۰,۰۰۰۰۲۴۹	۱۷۱,۵۹
۶	ارائه	✓	✓	۰,۰۰۰۲۲۲	۰,۰۰۰۰۲۳۳	۲۱۷,۹۱
۷	ارائه شده	✓	✓	۰,۰۰۰۲۲۲	۰,۰۰۰۰۲۳۳	۲۱۷,۹۱
۸	از	✓	✓	۰,۰۰۰۲۵۷	۰,۰۰۰۰۱۵۸	۵۳,۳۵
۹	از نظر	✓	✓	۰,۰۰۰۲۰۳	۰,۰۰۰۰۱۵۳	۱۹۲,۷۵
۱۰	این	✓	✓	۰,۰۰۰۱۶۶۴	۰,۰۰۰۰۱۲۲	۶۶,۴۴
	جمع	۱۴۸	۱۷۳			

نتایج جدول ۳ نشان می‌دهد که واژه‌های موجود در چکیده مقالات پس از اعمال الگوی زو تبدیل به ۹۱۳ واژه شدند که از میان آن‌ها قبل از تبدیل، ۱۴۸ واژه و بعد از تبدیل، ۱۷۳ واژه به عنوان بازدارنده استخراج شدند.

۳. واژه‌های بازدارنده موجود در متن مقاله‌ها جهت به کارگیری در نمایه‌سازی خودکار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس قانون زیف، کدام است؟

جدول ۴. فهرست واژه‌های بازدارنده متن مقاله‌ها بر اساس الگوی زیف «قبل و بعد از تبدیل»

بعد از تبدیل			قبل از تبدیل			
تعداد مقالاتی که این واژه را در بر دارند	بسامد	واژه	تعداد مقالاتی که عامل انتخاب واژه بوده‌اند	بسامد	واژه	ردیف
۳	۳	احتمالاً	۱	۲۹	ابرداده	۱
۱	۱	اساساً	۱	۲۹	اتخاذ	۲
۱	۲	ایشان	۱	۲۱	اثر	۳
۵	۸	اینجا	۱	۲۳	اختلاف	۴
۱	۱	اینک	۱	۲۴	ارائه	۵
۱۱	۲۱	غلب	۱	۳۰	ارتباطات	۶
۲۰	۱۵۳۷	✓	۲۰	۱۵۳۷	از	۷
۱	۳	افرون بر این	۱	۱۰۰	استناد	۸
۲۰	۶۵۷	✓	۱۴	۵۷۵	است	۹
۲۰	۲۰	اکثر	۱	۲۶	استاندارد	۱۰

نتایج جدول ۴ نشان‌دهنده آن است که از بین ۱۵۵۵۷ واژه مورد مطالعه، مطابق قانون زیف و قبل از تبدیل، ۲۱۷ واژه و بعد از تبدیل، ۶۰۷ واژه به عنوان واژه بازدارنده شناخته شدند.

۴. واژه‌های بازدارنده موجود در چکیده مقاله‌ها جهت به کارگیری در نمایه‌سازی خود کار مدارک فارسی رشته کتابداری و اطلاع‌رسانی بر اساس قانون زیف، کدام است؟

جدول ۵. فهرست واژه‌های بازدارنده موجود در چکیده‌ها بر اساس قانون زیف «قبل و بعد از تبدیل»

بعد از تبدیل			قبل از تبدیل			
تعداد مقالاتی که این واژه را در بر دارند	بسامد	واژه	تعداد مقالاتی که شامل انتخاب واژه بوده‌اند	بسامد	واژه	ردیف
۴	۶	ازاله	۱	۴	از	۱
۱۸	۸۷	✓	۱۱	۷۳	از	۲
۱	۱	ازآیندرو	۲	۱۲	استناده	۳
۱	۱	ازآشنازی	۱	۸	استناد	۴
۲	۲	از جمله	۱	۷	اختلافات	۵
۲	۴	از لحاظ	۲	۱۴	اعضای	۶
۱۵	۶۰	✓	۶	۲۸	این	۷
۱	۱	این گزنه	۲	۱۲	آن	۸
۲	۲	این که	۱	۵	پند	۹
۱۷	۶۱	✓	۶	۲۵	با	۱۰

همان گونه که در جدول ۵ مشاهده می‌شود از میان ۱۹۸۹ واژه موجود در چکیده‌های مورد مطالعه قبل از تعدیل، ۶۰ واژه و بعد از تعدیل، ۱۸۶ واژه به عنوان واژه بازدارنده شناسایی شدند.

۵. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن و چکیده، در روش زو هم خوانی وجود دارد؟

قبل از تعدیل، از بین ۱۳۷۵ واژه مورد مقایسه، ۱۴۱ واژه (۱۰/۲۵ درصد) و بعد از تعدیل از بین ۴۸۸ واژه مورد مقایسه، ۱۵۳ واژه (۱۳/۳۵ درصد) بین دو فهرست حاصل از متن و چکیده با هم مشترک هستند.

۶. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن و چکیده، در روش زیف هم خوانی وجود دارد؟

از بین ۲۱۸ واژه مورد مقایسه قبل از تعدیل، ۵۹ واژه بازدارنده مشترک (۲۷/۰۶ درصد) بین دو فهرست مورد اشاره یافت شد. از ۶۱۳ واژه مورد مقایسه پس از تعدیل واژه‌ها، ۱۸۰ واژه بازدارنده (۲۹/۳۶ درصد) بین دو فهرست مشترک بودند.

۷. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از متن مقاله‌های دو روش زو و زیف هم خوانی وجود دارد؟

قبل از تعدیل، از مجموع ۱۴۵۶ واژه مورد مقایسه، ۱۲۹ واژه بازدارنده (۰۸/۸۵ درصد) و پس از تعدیل واژه‌ها نیز از میان ۶۶۴ واژه مورد مقایسه، ۱۱ واژه (۶۱/۸۹ درصد) بین دو فهرست مشترک بودند.

۸. تا چه حد بین سیاهه‌های واژه‌های بازدارنده به دست آمده از چکیده مقاله‌های دو روش زو و زیف هم خوانی وجود دارد؟

قبل از تعدیل، ۱۶/۲۰ درصد (یعنی ۲۹ واژه از ۱۷۹ واژه مورد مقایسه) از واژه‌های بازدارنده و پس از تعدیل نیز، ۸۳/۱۶ درصد (یعنی ۱۶۳ واژه از ۱۹۶ واژه مورد مقایسه) بین این دو فهرست مشترک بودند.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی

جدول ۶. فهرست واژه‌های بازدارنده مشترک بین فهرست‌های مورد بررسی به تفکیک قبل و بعد از تغییل

ردیف	قبل از تغییل	بعد از تغییل	قبل از تغییل	بعد از تغییل	قبل از تغییل	بعد از تغییل	قبل از تغییل	بعد از تغییل	قبل از تغییل
۱	از	از	از	از	از	از	از	از	از
۲	استاده	از این رو	از این روز	از این روز	از این روز	از این روز	از این جا که	از	است
۳	اعضای	اعضای انسان	اعضای انسان	اعضای انسان	اعضای انسان	اعضای انسان	اعضای انسان	اعضای انسان	اعضای انسان
۴	آین	از آین	از آین	از آین	از آین	از آین	از آن جا که	از آن جا که	اعضای
۵	آن	از آین دست	از آین دست	از آن طریق	از آن طریق	از آن طریق	از آن جا که	از آن جا که	افزایش
۶	با	از آن روزت که	از آن روزت که	از جمله	از جمله	از جمله	اعضای	اعضای	از
۷	برای	از قبیل	از قبیل	از لحظه	از لحظه	از لحظه	از آین	از آین	است
۸	به	از طریق	از طریق	از نظر	از نظر	از نظر	آن	آن	اطلاعاتی
۹	بین	از نظر	از قبیل	اطلاعات	اطلاعات	اطلاعات	پند	پند	اعضای
۱۰	پژوهش	بازدارنده	از لحظه	اطلاعاتی	اطلاعاتی	اطلاعاتی	با	با	افزایش

۹. واژه‌های بازدارنده چه حجمی از متن و چکیده مقاله‌های حوزه مورد بررسی را تشکیل می‌دهند؟
به منظور پاسخگویی به این سؤال، نسبت تعداد واژه‌های بازدارنده متن یا چکیده به تعداد کل واژه‌های متن / چکیده به تفکیک الگوی زو و قانون زیف مورد محاسبه قرار گرفت. نتایج بررسی در جدول‌های ۷ و ۸ بیان شده است.

جدول ۷. حجم واژه‌های بازدارنده در متن و چکیده مقالات بر اساس الگوی زو

الگوی زو	نمایش	متن بدون اختصار	تعداد کل واژه‌های	تعداد واژه‌های متن بعد	تعداد واژه‌های متن بعد از اهمال	تعداد واژه‌های	درصد واژه‌های	درصد واژه‌های	تعداد کل واژه‌های	تعداد کل واژه‌های بازدارنده	تعداد کل واژه‌های بازدارنده	تعداد کل واژه‌های بازدارنده نسبت به تعداد کل واژه‌های متن بدون اختصار
۰۸/۷۹	قبل از تغییل	۱۵۵۷	۳۶۶۸	۳۶۶۸	۱۱۶۸	۳۶۶۸	۱۱۶۸	۱۱۶۸	۳۶۶۸	۱۳۴۹	۱۳۴۹	۰۸/۷۹
۳	بعد از تغییل	۱۵۵۵۷	۳۶۶۱	۳۶۶۱	۱۶۶	۳۶۶۱	۱۶۶	۱۶۶	۳۶۶۱	۱۳۴۹	۱۳۴۹	
۰۷/۷۶	قبل از تغییل	۱۹۸۹	۹۱۳	۹۱۳	۱۶۲۱	۹۱۳	۱۶۲۱	۱۶۲۱	۹۱۳	۱۶/۲۱	۱۶/۲۱	۰۷/۷۶
۰۸/۷۹	بعد از تغییل	۱۹۸۹	۹۱۳	۹۱۳	۱۸/۹۶	۹۱۳	۱۸/۹۶	۱۸/۹۶	۹۱۳	۱۸/۹۶	۱۸/۹۶	۰۸/۷۹

یافته‌های جدول ۷ نشان‌دهنده این است که در الگوی زو بالاترین نسبت واژه‌های بازدارنده قبل از تعدیل واژه‌ها، مربوط به متن مقالات (۳۹/۴۴ درصد) و پس از تعدیل مربوط به چکیده مقالات (۱۸/۹۶ درصد) می‌باشد.

جدول ۸. حجم واژه‌های بازدارنده در متن و چکیده مقالات بر اساس فرمول زیف

با احتساب بسامد			بدون احتساب بسامد				فرمول زیف
درصد واژه-های بازدارنده با احتساب بسامد	تعداد واژه-های بازدارنده با احتساب بسامد	تعداد کل واژه‌های متن با احتساب بسامد	درصد واژه-های بازدارنده بدون احتساب بسامد	تعداد واژه-های بازدارنده بدون احتساب بسامد	تعداد کل واژه‌های متن بدون احتساب بسامد	نام شیوه	
۴۸/۱۰	۳۵۴۷۷	۷۳۷۵۰	۰/۱۳۹	۲۱۷	۱۵۵۵۷	قبل از تعدیل	متن مقالات
۴۳/۹۷	۳۲۴۲۸	۷۳۷۵۰	۰/۳/۹	۶۰۷	۱۵۵۵۷	بعد از تعدیل	
۲۹/۷۶	۱۱۳۷	۳۸۲۰	۰/۳/۰۱	۶۰	۱۹۸۹	قبل از تعدیل	چکیده مقالات
۴۲/۵۳	۱۶۲۵	۳۸۲۰	۰/۹/۳۵	۱۸۶	۱۹۸۹	بعد از تعدیل	

یافته‌های جدول ۸ نشان می‌دهد که در روش زیف، متن مقالات قبل از تعدیل (۴۸/۱۰ درصد) و پس از تعدیل (۴۳/۹۷ درصد) بالاترین نسبت واژه‌های بازدارنده را دارا است.

نتیجه‌گیری

در متن مقالات مطابق الگوی زو تعداد واژه‌های بازدارنده قبل از تعدیل، ۶۵/۷۹ درصد بیشتر از بعد از تعدیل می‌باشد. به نظر می‌رسد این تفاوت در تعداد واژه‌های بازدارنده ناشی از وجود تعداد قابل توجهی از واژه‌های معنادار در فهرست بازدارنده‌ای باشد که در شیوه قبل از تعدیل ایجاد شده است، به نحوی که با حذف این واژه‌ها در شیوه بعد از تعدیل، تعداد واژه‌ها در دومین فهرست کاهش یافت. نتایج این پژوهش تا اندازه زیادی با یافته‌های پژوهش سنجی (۱۳۸۷)؛ فاکس (۱۹۹۰)؛ هائز و هائز (۲۰۰۸)؛

داورپناه، سنجی و آرمیده (۲۰۰۹) مطابقت دارد. سنجی، ۱۲۹۱ واژه بازدارنده را بر اساس نوع دستوری واژه‌ها و با در نظر گرفتن بسامد آن‌ها شناسایی نمود. فاکس (۱۹۹۰)؛ هانو و هانو (۲۰۰۸) و داورپناه، سنجی و آرمیده (۲۰۰۹) نیز در پژوهش‌های خویش به ترتیب ۴۲۱، ۵۰۰ و ۴۲۲ واژه بازدارنده را استخراج نمودند. به نظر می‌رسد تفاوت بین تعداد واژه‌های بازدارنده این پژوهش و سایر پژوهش‌های مورد بررسی به دلیل تفاوت در روش مورد استفاده جهت استخراج واژه‌های غیرمفهومی، تفاوت در جامعه آماری مورد مطالعه یا اختلاف بین پژوهشگران در تعریف واژه و تعیین مرز کلمات که یک مرحله اجتناب‌ناپذیر قبل از شناسایی واژه‌های بازدارنده است و یا تفاوت در نقطه برش تعیین شده باشد. این نقطه برش بر اساس استنباط فردی پژوهشگر و بررسی پیکره مورد مطالعه مشخص می‌شود. با توجه به این که در الگوی زو بر اساس محاسبات آماری، ارزش بسامد واژه در کل خوشه زبانی مورد توجه قرار می‌گیرد، می‌توان از این الگو به نحو شایسته‌تری در بانک‌های اطلاعاتی تخصصی و مجموعه متون هم‌بند و هم‌سنخ استفاده نمود زیرا بسیاری از واژه‌های عام و بی‌ارزش محتوایی و اطلاعاتی را در مجموعه‌های بزرگ شناسایی نموده و باعث بهینه‌سازی ذخیره و بازیابی اطلاعات تخصصی می‌شود و به نمایه‌سازان، چکیده‌نویسان و طراحان پایگاه‌ها و نرم‌افزارهای اطلاعاتی در کاهش میزان حجم فایل مقلوب نمایه، زمان و هزینه ذخیره‌سازی و بازیابی اطلاعات کمک می‌نماید.

در چکیده مقالات نیز طبق الگوی زو، تعداد واژه‌های بازدارنده بعد از تعدیل، ۱۴/۴۵ درصد افزایش یافت. به نظر می‌رسد این تفاوت در تعداد واژه‌های بازدارنده، می‌تواند مربوط به نقطه برش تعیین شده برای چکیده مقالات باشد که بر اساس آن برخی از واژه‌های غیرمفهومی به دلیل این که ارزش آماری بالایی داشتند، در بخش واژه‌های معنادار قرار گرفتند و با اجرای شیوه بعد از تعدیل و اضافه نمودن آن‌ها به فهرست، تعداد واژه‌های بازدارنده در دومین فهرست افزایش یافت. تنها پژوهشی که به بررسی چکیده مقالات به منظور شناسایی واژه‌های بازدارنده پرداخته بود، پژوهش ساووی (۱۹۹۹) بود که در پژوهش خود، ۲۱۵ واژه بازدارنده را از متن و چکیده مقالات استخراج نمود.

بنا بر قانون زیف نیز در متن مقالات قبل از تعدیل، ۲۱۷ واژه (با احتساب بسامد ۳۵۴۷۷ واژه) و بعد از تعدیل، ۶۰۷ واژه (با احتساب بسامد ۳۲۴۲۸ واژه) به عنوان واژه بازدارنده شناخته شدند. همان گونه که مشاهده می‌شود بدون احتساب بسامد، تعداد واژه‌های بازدارنده در شیوه بعد از تعدیل که به مفهوم معنایی کلمات و تعدیل واژه‌ها توجه شده،^۳ برابر شده است اما با احتساب بسامد، تعداد واژه‌های بازدارنده شیوه قبل از تعدیل بیشتر است. قانون زیف فقط بسامد واژه‌ها را در نظر می‌گیرد و واژه‌هایی که زیاد تکرار

شده باشد را به فهرست اضافه می‌نماید که البته تعدادی از آن‌ها معنادار بوده و به همین دلیل در شیوه بعد از تعديل از فهرست واژه‌های بازدارنده حذف شدند؛ در مقابل واژه‌های غیرمعناداری هم که به فهرست شیوه بعد از تعديل اضافه شدند از بسامد بالایی برخوردار نبودند. یافته‌ها با نتیجه پژوهش داورپناه و بلندیان (۱۳۸۵) مطابقت داشت. آن‌ها به این نتیجه رسیدند که واژه‌های بازدارنده بالاترین بسامد را به خود اختصاص داده‌اند که با حذف آن‌ها از حجم مدارک به میزان قابل توجهی کاسته می‌شود.

در چکیده مقالات نیز مطابق قانون زیف، قبل از تعديل ۶۰ واژه (با احتساب بسامد آن‌ها، ۱۱۳۷ واژه) و بعد از تعديل، ۱۸۶ واژه (با احتساب بسامد آن‌ها، ۱۶۲۵ واژه) به عنوان واژه بازدارنده شناخته شدند که با اجرای شیوه بعد از تعديل، ۷۴/۸۴ درصد افزایش داشته است. تعداد کم واژه‌های بازدارنده استخراج شده از چکیده مقالات نشان می‌دهد که در سال‌های اخیر پژوهشگران در نگارش چکیده‌های خود دقت بیشتری می‌کنند و چکیده‌ها نیز بار اطلاعاتی افزون‌تری را منتقل کرده و بیشتر حاوی واژه‌های مفهومی می‌باشند.

الگوی زو یکی از الگوهای آماری است که برای شناسایی واژه‌های بازدارنده مورد استفاده قرار گرفته است و بر اساس بسامد عمل می‌کند و ارتباط آن با قانون زیف نیز این است که هر دو مبتنی بر بسامد هستند. در این پژوهش این مسئله مدنظر قرار گرفت و سعی شد قابلیت به کارگیری آن‌ها در زبان فارسی و تفاوت آن‌ها در ایجاد فهرست واژه‌های بازدارنده مورد بررسی قرار گیرد که به طور کلی به نظر می‌رسد که می‌توان در زبان فارسی از الگوی آماری زو و همچنین قانون زیف برای شناسایی واژه‌های بازدارنده موجود در متن و چکیده مقالات استفاده نمود که هر کدام از این دو الگو نکات قوت خاص خود را داراست. البته تشخیص کاربردپذیری و میزان کارایی این فهرست‌ها نیازمند به کارگیری آنان در شرایط عملیاتی تجربی و آزمایشی در حیطه ذخیره و بازیابی متون اطلاعاتی در شاخه‌های موضوعی مختلف می‌باشد.

تعداد واژه‌های بازدارنده موجود در متن بیشتر از چکیده می‌باشد زیرا از یک سو، متن از حجم واژگانی بیشتری نسبت به چکیده برخوردار است و از سوی دیگر، چکیده معمولاً غنی‌تر از متن است و بیشتر حاوی واژه‌های مفهومی می‌باشد. لذا استنباط می‌شود که طول متن در حجم واژه‌های بازدارنده تأثیر دارد.

در هر دو روش رابطه مستقیمی بین بسامد واژه‌ها (در متن و چکیده) و احتمال بازدارنده بودن آن‌ها یافت شد. همچنین عامل تعديل که در این پژوهش مورد استفاده قرار گرفت نقش بسزایی در شناسایی

واژه‌های بازدارنده داشت که در آن، حذف بعضی از واژه‌ها و اضافه نمودن برخی دیگر بر اساس قضاوت پژوهشگر انجام گرفته و نیاز به آگاهی و مهارت وی در مسائل زبان مورد مطالعه دارد. اما در مقایسه با شیوه قبل از تعدیل برای استخراج واژه‌های بازدارنده زمان و هزینه‌های بیشتری را می‌طلبد. در کلیه فهرست‌های به دست آمده از پژوهش میزان هم‌خوانی با اجرای شیوه دوم افزایش یافته است. در این شیوه عامل انسانی دخالت داشته و از معیارهای مشابهی برای تمايز واژه‌های معنادار و غیرمعنادار استفاده شده است، در نتیجه تعداد واژه‌های مشترک بین فهرست‌های مورد بررسی بیشتر است. در مجموع به قصد مقایسه و کاربرد این دو روش در استخراج واژه‌های بازدارنده این پژوهش انجام شد و با استفاده از دو روش مذکور،^۸ فهرست از واژه‌های بازدارنده موجود در متن و چکیده مقالات تهیه شد و میزان هم‌خوانی بین آن‌ها به تفکیک دو شیوه، مورد مطالعه قرار گرفت که یافته‌ها نشان داد واژه‌های موجود در این فهرست‌ها تا حد زیادی متشابه نبوده و میزان هم‌خوانی بین این فهرست‌ها در سطح پایینی است. این امر نشان‌دهنده آن است که ایجاد فهرست واژه‌های بازدارنده منسجم و واحد، حتی برای یک حیطه موضوعی خاص کاری بس مشکل و تقریباً ناممکن است و نمی‌توان به سادگی به آن دست یافت و به همین دلیل پژوهشگران از روش‌های گوناگونی در این زمینه استفاده کرده‌اند.

بدون احتساب بسامد متن مقالات در روش زو (۴۴/۳۹ درصد) و با احتساب بسامد، متن مقالات در روش زیف (۱۰/۴۸ درصد) دارای بیشترین نسبت واژه‌های غیرمفهومی می‌باشد. با بررسی فهرست به دست آمده از طریق قانون زیف مشخص شد که استفاده از این قانون به عنوان مبنایی برای تعیین کلمات معنادار در یک مدرک مناسب‌تر باشد و یا برای تهیه فهرست واژه‌های بازدارنده در یک مجموعه و پیکره عمومی کاربرد مناسب‌تری داشته باشد که در نهایت، بررسی‌های بیشتر به منظور روشن‌تر شدن ابعاد مختلف یافته‌های این پژوهش از جنبه‌های مختلف نظری و کاربردی، ضروری به نظر می‌رسد.

با توجه به نتایج به دست آمده، پیشنهادهای اجرایی زیر مؤثر به نظر می‌رسد:

۱. با توجه به شیوه خاص نگارش زبان فارسی (فاصله بین کلمات، املای متفاوت واژه‌ها و غیره) که مشکلاتی را در تفکیک واژه‌ها به وجود می‌آورند، پیشنهاد می‌شود دستنامه واحد و استانداردی برای تایپ فارسی و ورود اطلاعات به رایانه بدون گردد تا کلمات به روشنی قابل تفکیک و تشخیص باشند.
۲. از آن جایی که نشریات علمی و پژوهشی دارای بیشترین میزان کاربرد در عملیات ذخیره و بازیابی اطلاعات می‌باشند، تهیه شیوه‌نامه‌ای استاندارد در طول نگارش این متون می‌تواند برای

درونداد اطلاعات در پایگاه‌های اطلاعاتی و پژوهش‌هایی از این دست که با تحلیل واژگان سروکار دارند، مفید باشد.

۳. پیشنهاد می‌شود که هنگام ورود اطلاعات متنی به رایانه در به کارگیری و استفاده از نیم‌فاصله دقت کافی انجام پذیرد به ویژه در مورد نام کامل نویسنده‌گان، افعال و علائم جمع و تکوازهای صرفی و سایر واژه‌هایی که به لحاظ مفهومی قابل تفکیک نمی‌باشند و در همین راستا با توجه به کاربرد متواتی نیم‌فاصله در تایپ فارسی به طراحان سخت‌افزار پیشنهاد می‌شود صفحه کلید تایپ فارسی را به گونه‌ای باز طراحی نمایند که کلیدی جداگانه و سهل‌الوصول برای نیم‌فاصله به صورت مجزا تعییه گردد.
۴. به طراحان پایگاه‌های اطلاعاتی پیشنهاد می‌شود که با شناسایی واژه‌های بازدارنده و ذخیره آن‌ها در پایگاه خود، میزان کارایی در ذخیره و بازیابی مدارک را افزایش دهند.
۵. پیشنهاد می‌شود در نرم‌افزارهای کتابخانه‌ای و ذخیره و بازیابی اطلاعات، بانک واژه‌های بازدارنده تعییه شود تا ضمن کاهش مدت زمان و هزینه نمایه‌سازی، مدارک مرتبط بیشتری بازیابی شود.
۶. پیشنهاد می‌شود فهرست‌های به دست آمده از این پژوهش در خوش‌های واژگانی مختلف عملاً به کارگرفته شود و میزان تأثیر آن در عملیات ذخیره و بازیابی اطلاعات از جمله ضریب دقت و بازیافت، صرفه‌جویی در زمان، هزینه و مانند آن مورد بررسی قرار گیرد.

کتابنامه:

- بلندیان، صدیقه (۱۳۸۵). تحلیل متن مقالات فارسی کتابداری و اطلاع‌رسانی و امکان نمایه سازی ماشینی آن‌ها بر اساس قانون زیف. پایان‌نامه کارشناسی ارشد، دانشگاه فردوسی مشهد.
- تیلور، آرلین (۱۳۸۱). سازمان‌های اطلاعات. (محمد حسین دیانی، مترجم). مشهد: کتابخانه رایانه‌ای.
- سنجری، مجیده (۱۳۸۷). شناسایی واژه‌های غیرمفهومی رایج در نمایه‌سازی خودکار مدارک فارسی. پایان‌نامه کارشناسی ارشد، دانشگاه فردوسی مشهد.
- گیلوری، عباس (۱۳۷۹). نمایه سازی خودکار: گذشته، حال، آینده. پیام کتابخانه، ۱۰(۴): ۱۷-۲۵.
- هویدا، علیرضا (۱۳۷۸). آمار و روش‌های کمی در کتابداری و اطلاع‌رسانی. تهران: سازمان مطالعه و تدوین کتب علوم انسانی دانشگاه‌ها (سمت).

- Abu-El Khair, I. H. (2003). Effects of Stop Words Elimination for Arabic Information Retrieval. *International Journal of Computing & Information Science*, 4(3), 119-133. Retrieved June 18, 2010, from <http://www.mons.edu.eg/pcvs/13702/13102.asp>
- Berg, C. N. (1997). *Developing Corpus Specific Stop Word List Using Quantitative Comparison*. PhD thesis, Graduate school of Logistics and acquisition management, Retrieved November 20, 2010, from http://www.research.airuniv.edu/papers/ay1997/afit/_berg_cn.pdf
- Davarpanah, M. R., Sanji, M., & Aramideh, M. (2009). Farsi Lexical Analysis and Stop Word List. *Library Hi Tech*, 27(3), 435-449. Retrieved December 14, 2011 from <http://www.emeraldinsight.comType=Article&contentId=1811864/InsightviewContentItem/do?content>
- Edmundson, H. P., & Wyllys, R. E. (1959). *Automatic Indexing and Abstracting of Contents of Documents*. Retrieved June 14 , 2011, from <http://www.washington.edu>
- Fox, C. (1990). *A stop list for general text*. Retrieved November 20, 2010, from <http://www.informatik.uni-trier.de/ley/indice/a-tree.pdf>
- Hao, L., & Hao, Li. (2008). Automatic Identification of Stop Words in Chinese Text Classification. Retrieved October 3, 2011, from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4721858
- Kerner, Y. H., & Blitz, S.Y. (2010). *Experiments With Extraction of Stop words in Hebrew*. Retrieved April 21, 2012, from http://www.cs.tau.ac.ir/~nachum/iscol/HaCohenKerner_ISCOL_10_2.pdf
- Lazarinis, F. (2007). Engineering and Utilizing a Stop Word List in Greek Web. *Journal of the American Society for Information Science and Technology*, 58(11), 1645-1652. Retrieved November 18, 2011, from <http://dl.acm.org/citation.cfm?id=1285331>
- Pandey, A. K., & Siddiqui, T. (2009). *Evaluation Effect of Stemming and Stop-Word Removal on Hindi Text Retrieval*. Retrieved September 17, 2010, from <http://www.springerlink.com/index/j6444068.x213572k.pdf>
- Savoy, J. (1999). A Stemming Procedure and Stop Word List for General French Corpora. *Journal of the American Society for Information Science*, 50(10), 944-952. Retrieved September 17, 2010, from <http://www.members.unine.ch/jacques.savoy/papers/frjasis.pdf>
- Wilbur, j., & Sirotnk, K (1992). The automatic identification of Stop Word. *Journal of Information Science*, 18 (1), 45-55. Retrieved September 3, 2010, from <http://www.jis.sagepub.com/content/18/1/4>
- zou, F., Deng, X., & Han, S. (2006). *Automatic identification of Chinese Stop Words*. Retrieved November 10, 2010 , from <http://www.cycling.org/2006/RCS-18/RCS-18-Page151.pdf>