

گسترش‌پذیری جستجو و بازیابی مدارک در پایگاه‌های اطلاعات علمی فارسی: مورد پژوهشی پیوسته‌نویسی و جدانویسی

ایوب رنجبر^۱، جواد عباس‌پور^۲

چکیده

تاریخ ارسال: ۹۷/۴/۲۲ - تاریخ پذیرش: ۹۷/۵/۲۹

هدف: هدف این مقاله مطالعه میزان توجه سه پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور»، «مرکز اطلاعات علمی جهاد دانشگاهی» و «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» به گسترش‌پذیری جستجو و بازیابی مدارک (مقالات) به صورت پیوسته‌نویسی و جدانویسی است.

روش‌شناسی: پژوهش حاضر از نظر هدف در ریفی پژوهش‌های کاربردی و از نظر طرح پژوهش از نوع تحلیل محتوا بوده است. جامعه آماری شامل مجموعه مدارک موجود در سه پایگاه اطلاعات علمی فارسی بود (۲۹۱۴۲ مدرک) که با استفاده از فرمول کوکران، ۴۳۲ مدرک از آنها با روش نمونه‌گیری طبقه‌ای متناسب (نسبتی) انتخاب شد. ابزار پژوهش یک سیاهه وارسی محقق‌ساخته بود. سیاهه وارسی شامل ده قاعده از مجموعه قاعده‌های پیوسته‌نویسی و جدانویسی کتاب «دستور خط فارسی مصوب فرهنگستان زبان و ادب فارسی» به همراه مصداق‌های «واژگان یا کلیدواژه‌های انتخابی» از هر قاعده بود که امکان رخداد جدانویسی و پیوسته‌نویسی آنها در هنگام نگارش وجود داشت.

۱. دانش‌آموخته علم اطلاعات و دانش‌شناسی، دانشگاه شیراز (نویسنده مسئول).
ayoubranjbar69@gmail.com
۲. عضو هیئت علمی گروه علم اطلاعات و دانش‌شناسی دانشگاه شیراز.
Javad.abbaspour@gmail.com

یافته‌ها: نتایج نشان داد میان پایگاه‌های اطلاعات علمی فارسی از نظر قابلیت بازیابی مدارک با هر یک از شکل‌های نگارشی اعم از پیوسته‌نویسی و جدانویسی تفاوت وجود دارد. علاوه بر این، یافته‌ها نشان داد، تنها $\frac{5}{3}\%$ از مدارک انتخابی در هنگام جستجو در پایگاه‌های اطلاعاتی مورد مطالعه با همه شکل‌های نگارشی قابل بازیابی بود. در مقابل، 74% مدارک انتخابی فقط با همان حالت ثبت شده در پایگاه بازیابی شد. همچنین، مقایسهٔ شکل نگارشی مصادق‌ها در عنوان، چکیده و کلمات کلیدی نسخهٔ پی‌دی‌اف مدارک با اطلاعات نمایه شده از همان مدارک در پایگاه‌های اطلاعات علمی فارسی نشان داد، شکل نگارشی بخش قابل توجهی از مصادق‌های مدارک از حالت نگارشی نزدیک‌نویسی به جدانویسی یا پیوسته‌نویسی تغییر یافته است.

نتیجه‌گیری: با توجه به اینکه در پایگاه‌های مورد مطالعه چالش‌های پیوسته‌نویسی و جدانویسی به طور جامع و به منظور بهبود جامعیت نتایج جستجو مورد توجه قرار نگرفته است، این وضعیت نامطلوب می‌تواند به ازدست دادن مدارکی بینجامد که با دیگر شکل‌های نگارشی در پایگاه‌های اطلاعاتی ذخیره شده‌اند.

کلیدواژه‌ها: بازیابی اطلاعات، پایگاه‌های اطلاعات علمی، پیوسته‌نویسی، جدانویسی، خط فارسی، مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری.

مقدمه

از مهم‌ترین مسائل و چالش‌های نگارشی خط فارسی در محیط‌های الکترونیکی (روند ذخیره‌سازی و پردازش، جستجو و بازیابی اطلاعات) می‌توان به مواردی چون نگارش غیررسمی یا محاوره‌ای، استفاده از واژگان بیگانه، پیچیدگی صرفی، تنوع املایی واژگان، هم‌نگاشت‌ها^۱ و فاصله‌گذاری میان واژگان اشاره کرد (دانش، مینایی و کاشفی^۲). در میان این چالش‌ها، در دهه‌های اخیر مسئله «فاصله‌گذاری» و به طور مشخص پیوسته‌نویسی و جدانویسی^۳ بسیار مورد توجه قرار گرفته است؛ به گونه‌ای که

1. Homographs

2. Danesh, Minaei and Kashefi

3. در عمدۀ کتاب‌های دستور زبان فارسی از جمله کتاب «دستور خط فارسی مصوب فرهنگستان زبان و ادب فارسی» منظور از «جدانویسی» حالت نیم فاصله‌نویسی یا نزدیک‌نویسی است؛ این در حالی است که در این مقاله منظور از جدانویسی استفاده از فاصلهٔ کامل بین اجزای یک واژه واحد است و در جایی نیز که منظور حالت نیم فاصله بوده، از واژه «نزدیک‌نویسی» استفاده شده است.

بیشترین اختلاف نظرها در باب املای فارسی (فرهنگستان زبان و ادب فارسی، ۱۳۸۹) و بیشترین پژوهش‌ها در ارتباط با چالش‌های نگارشی زبان فارسی در محمل‌های الکترونیکی (هنرجویان، ۱۳۹۲) را به خود اختصاص داده است. حتی، در کنار چالش‌های اعراب‌گذاری، از آن به عنوان یکی از مهم‌ترین و تأثیرگذارترین چالش‌ها در قلمرو منابع الکترونیکی یاد می‌شود، به گونه‌ای که صاحب‌نظران مراحل بعدی پردازش متون تولیدی را منوط به حل شدن این دو مسئله دانسته‌اند (کاشفی، نصری و کنعانی، ۱۳۸۹؛ دانش و دیگران، ۲۰۱۱).

به دلیل وجود این چالش در رسم الخط فارسی، اگر شکل‌های مختلف نگارشی یک واژه مرکب اعم از پیوسته‌نویسی یا جدانویسی توسط طراحان و نمایه‌سازان پایگاه‌های اطلاعات علمی فارسی بهنجارسازی^۱ نشود، کاربران با نگارش هریک از شکل‌های نگارشی واژه، تنها به مدارکی^۲ که بدان شکل نگارش یافته است، دسترسی خواهند یافت و سایر مدارک مرتبط نگارش یافته با دیگر شکل‌ها را از دست خواهند داد.

برای تبیین بهتر مسئله و اینکه چه نامه‌منگی‌هایی در ضبط یک واژه واحد در محمل‌های الکترونیکی و به طور اخص پایگاه‌های اطلاعاتی علمی فارسی رخ می‌دهد، نگارنده از بخش «ترکیبات»^۳ دستور خط فارسی مصوب فرهنگستان زبان و ادب فارسی و از قاعده‌ده که مربوط به پیوسته‌نویسی است، واژه «کتابشناسی» را به عنوان نمونه انتخاب و در پایگاه استنادی علوم جهان اسلام^۴ (به عنوان نمونه‌ای از پایگاه‌های اطلاعات علمی فارسی) جستجو کرد. نگارش این واژه به سه شکل «کتابشناسی» (پیوسته‌نویسی)، «کتاب‌شناسی» (نzdیک‌نویسی) و «کتاب شناسی» (جданویسی)

1. Normalization

۲. در این پژوهش منظور از «مدرک / مدارک»، مقاله یا مقالات علمی-پژوهشی و علمی-تربیجی نمایه شده در پایگاه‌های اطلاعات علمی فارسی مورد مطالعه است.

۳. در کتاب دستور خط فارسی مصوب فرهنگستان «ترکیبات» شامل واژگان مرکب و مشتق است.

4. ISC (Islamic World Science Citation Center)

امکان‌پذیر است. در ابتدا جستجو به شکل «کتاب شناسی» (جدانویسی) انجام شد که ۳۶۲ مدرک بازیابی شد؛ ولی با تغییر شکل نگارشی واژه وارد کردن آن به شکل «کتاب شناسی» (نzdیک‌نویسی) و «کتاب‌شناسی» (پیوسته‌نویسی) به ترتیب ۴۰ و ۵۴ مدرک بازیابی شد. توجه نکردن به چنین مسئله‌ای در مراحل ذخیره‌سازی و پردازش، جستجو و بازیابی اطلاعات از پایگاه‌های اطلاعات علمی فارسی، چالش‌ها و موانعی را پیش روی کاربران فارسی‌زبان در دستیابی به اطلاعات مورد نیازشان ایجاد کرده است.

مرور مطالعات انجام شده در سال‌های اخیر نشان می‌دهد میزان توجه سامانه‌های بازیابی اطلاعات به چالش‌های خط فارسی، از جمله مسئله پیوسته‌نویسی و جدانویسی، بعضاً با ذکر تعداد محدودی کلیدواژه (یک یا دو کلیدواژه) آن‌هم از قلمرو موضوعی محدود، به منزله نمونه‌ای از متنون فارسی، بررسی شده است. افزون براین، یکسانی فراوانی تعداد مدارک بازیابی شده در ریخت‌های مختلف یک واژه را نشان از رفع آن چالش در سامانه‌های بازیابی اطلاعات قلداد کرده‌اند. این در حالی است که ممکن است شکل‌های نگارشی یک واژه به طور همزمان در بخش عنوان، چکیده و واژگان کلیدی یک مدرک رخ داده و این مسئله باعث بازیابی دوباره همان مدرک شده باشد.

علاوه بر موارد بالا، در بخش ترکیبات دستور خط فارسی فرهنگستان، ۲۳ قاعده درباره موقعیت‌های رخداد جدانویسی و پیوسته‌نویسی ذکر شده است. این در حالی است که مرور مطالعات پیشین (رمضانی، ۱۳۸۶؛ قدس‌نیا، زارع بیدکی، ویزدانی، ۱۳۸۶؛ عبدالهی و جوکار، ۱۳۸۸؛ گل تاجی و بذرگر، ۱۳۸۹؛ آخشیک و فتاحی، ۱۳۹۱؛ هماوندی، نوروزی و حسینی بهشتی، ۱۳۹۷) نشان می‌دهد پژوهشگران بدون توجه به این قاعده‌ها، گاه با درنظرگرفتن یک یا دو مصداق (کلیدواژه یا واژگان انتخابی) آن‌هم بدون ذکر چگونگی و دلایل انتخاب آنها، چالش‌های پیوسته‌نویسی و جدانویسی و همچنین میزان تأثیر آن بر سامانه‌های بازیابی اطلاعات را بررسی کرده‌اند. در صورتی که به نظر می‌رسد انتخاب مصداق (کلیدواژه) از هر قاعده می‌تواند تأثیرگذاری متفاوتی بر

سامانه‌های جستجو و بازیابی اطلاعات داشته باشد.

با توجه به وجود چنین خلاهایی در پژوهش‌های پیشین، مقاله حاضر در پی آن است که با گسترش قلمروهای موضوعی و با درنظرگرفتن قاعده‌های بخش ترکیبات دستور خط فارسی مصوب فرهنگستان و همچنین، کنترل رخداد شکل‌های نگارشی در بخش عنوان، چکیده و واژگان کلیدی هر مدرک، وضعیت برخی از پایگاه‌های اطلاعات علمی فارسی را از نظر میزان توجه به مسئله پیوسته نویسی و جدانویسی بررسی و بر مبنای نتایج حاصل، پیشنهادها و راهکارهای عملی را ارائه کند. انتظار می‌رود با استفاده از نتایج این پژوهش بتوان از طریق تشخیص دقیق تر نقاط ضعف و قوت پایگاه‌های اطلاعات علمی فارسی در راستای بهبود یا اصلاح الگوریتم‌های جستجو و بازیابی آنها گام برداشت. همچنین، نمایه‌سازی و طراحان سامانه‌های بازیابی اطلاعات می‌توانند با شناسایی قاعده‌های دارای تأثیرگذاری بیشتر بر کمیت نتایج بازیابی شده، امکان به کارگیری و اعمال آنها در الگوریتم‌های نمایه‌سازی یا بازیابی را فراهم کنند. از این‌رو، مقاله حاضر در پی این پاسخ به سؤال‌های زیر نگارش یافته است:

۱. آیا میان پایگاه‌های اطلاعات علمی فارسی از نظر گسترش‌پذیری جستجو و بازیابی

مدارک به صورت پیوسته نویسی و جدانویسی، تفاوت وجود دارد؟

۲. نسبت فراوانی پایگاه‌های اطلاعات علمی فارسی از نظر گسترش‌پذیری جستجو و بازیابی مدارک به صورت پیوسته نویسی و جدانویسی بر حسب قاعده‌های دهگانه فرهنگستان زبان و ادب فارسی چگونه است؟

۳. نسبت فراوانی شکل نگارشی مصدق‌ها در عنوان، چکیده و واژگان کلیدی نسخه پی‌دی‌اف مدارک با اطلاعات ارائه شده از همان مدارک در پایگاه‌های اطلاعاتی علمی فارسی، چگونه است؟

شایان ذکر است، در مقاله حاضر منظور از گسترش‌پذیری جستجو، توانایی پایگاه اطلاعات علمی فارسی در بازیابی مدرک با هردو حالت نگارشی مصدق اعم از

پیوسته‌نویسی و جدانویسی است. بنابراین، سنجش گسترش‌پذیری جستجوبرای هر پایگاه اطلاعات علمی فارسی با مشاهده رویداد یک یا مجموعه‌ای از حالت‌های زیر در زمان جستجوی مصداق‌های مدارک تعیین گردید:

۱. خوانش شکل نگارشی «پیوسته‌نویسی» و گسترش به حالت «جданویسی»؛
۲. خوانش شکل نگارشی «جدانویسی» و گسترش به حالت «پیوسته‌نویسی»؛
۳. خوانش شکل نگارشی «جدانویسی» و گسترش به حالت «نیم فاصله»؛
۴. خوانش شکل نگارشی «پیوسته‌نویسی» و گسترش به حالت «نیم فاصله»؛
۵. خوانش «نیم فاصله» و گسترش به هرسه حالت نگارشی (پیوسته، نیم فاصله و جدای).

مرور پیشینه‌های پژوهش

پیشینه‌های داخلی

تاكنون ويژگی‌ها و مشکلات رسم الخط یا شیوه خط فارسی، از جمله مسئله فاصله‌گذاری و تأثیرگذاری آنها بر روند سامانه‌های ذخیره و بازیابی اطلاعات، موضوع پژوهش‌های متعددی بوده است. «حری» (۱۳۷۲) در مقاله‌ای نظری به تبیین چالش‌های رسم الخط فارسی در مواجهه با رایانه پرداخت. او راه حل‌های طراحی شده برای مقابله با چالش‌های رسم الخط را در پنج دسته کلی، یعنی ۱. هماهنگ‌کردن حروف ۲. استفاده از تکوازها ۳. استفاده از سیاهه آماده ۴. پیوند ساختگی میان واژگان و ۵. هماهنگی رسم الخط جای داد. او همچنین از میان راهکارهای پیشنهادی، مورد پنجم را ارجح و معقول ترداشت. حری دلیل آن را چنین تبیین می‌کند که با به کارگیری این راهکار، به دلیل ضرورت برخورد با رایانه، خط فارسی شیوه‌ای واحد خواهد یافت و آشتفتگی و چندگانگی فعلی رسم الخط از بین خواهد رفت.

«اکبری نژاد» (۱۳۷۶) به واسطه تجربه کار با پایگاه‌های اطلاعاتی، در مقاله‌ای با عنوان «فاصله خالی میان واژه‌ها در ذخیره و بازیابی رایانه‌ای اطلاعات» به بیان مشکلات و

مسائل ایجاد شده به دلیل فاصله میان واژه‌ها و عبارت‌ها در تمام نظام‌های رایانه‌ای ذخیره و بازیابی اطلاعات کتاب شناختی به زبان فارسی پرداخت. نگارنده با اشاره به اینکه ملاک شناسایی واژه‌ها و نمایه‌سازی در نرم‌افزارهای موجود بازار، فضای خالی میان واژه‌است، از مسائل و مشکلات موجود در رسم الخط از جمله فاصله گذاری میان واژه‌ها و عبارت‌ها به صورت فاصله، نیم فاصله یا بی‌فاصله، به عنوان عاملی تأثیرگذار (منفی) بر جامعیت مطلوب یا سرعت جستجو باد کرده است.

«مرتضایی» (۱۳۸۰) نیزبا هدف ارائه نمونه‌هایی از تجربه‌های واژه‌گزینی در ذخیره اطلاعات و به منظور تسریع و تسهیل ذخیره و بازیابی اطلاعات، به بررسی مسائل زبان و خط فارسی در ذخیره‌سازی و بازیابی اطلاعات پرداخت. یافته‌ها نشان داد مسائل زبان و خط فارسی سبب کندی مراحل ذخیره و بازیابی اطلاعات، کاهش نسبت بازیافت اطلاعات و همچنین تأثیر منفی بر جامعیت نتایج یک جستجوی شود.

از جمله پژوهش‌های دیگری که توان به پژوهش «راشی» (۱۳۸۵) اشاره کرد که با استفاده از پرسشنامه و با مطالعه موردی کاربران مرکز اینترنت دانشگاه آزاد اسلامی شبستر، مشکلات جستجو و بازیابی اطلاعات به زبان فارسی در اینترنت را بررسی کرد. پژوهش به روش پیمایشی و با رویکرد توصیفی صورت گرفت. نتایج نشان داد کاربران کمترین استفاده را از «شکل‌های مختلف نوشتاری واژه» دارند و بیشتر کاربران به این نکته توجهی نداشتند. یافته‌های پژوهشگران فرضیه را که «بیشتر از ۵۰٪ موارد عدم بازیابی مطالب موردنظر در جستجوی اطلاعات به زبان فارسی، مربوط به مسائل زبان و خط فارسی است» تأیید کرد.

«قدس‌نیا، زارع بیدکی ویزانی» (۱۳۸۶) در پژوهشی دیگر که با هدف سنجش تأثیرگذاری سیزده چالش از مهم‌ترین مشکلات زبان و خط فارسی بر میزان جامعیت نتایج جستجوی انجام گرفت، با طراحی یک خزنده^۱ یک میلیون و دویست هزار صفحه

وب را بررسی کردند. نتایج پژوهش آنان نشان داد جدی ترین چالش‌ها و مشکلاتی که بر جامعیت نتایج جستجوتأثیرگذار است، به ترتیب شامل استفاده از «ی» فارسی و «ی» عربی نقطه‌دار چسبان به جای «ی» عربی آخر با ۹۴٪/۹۴٪، استفاده از «آ» به جای «ا» با ۹۴٪/۹۴٪ و استفاده از «ی» عربی نقطه‌دار چسبان و «ی» عربی آخر به جای «ی» فارسی با ۷۴٪/۹۸٪ است؛ همچنین استفاده از «فاصله» به جای «نیم فاصله» با ۵۱٪/۷٪ و «نیم فاصله» به جای «فاصله» با ۴۸٪/۳٪ از دیگر موارد قابل توجه است.

«عبداللهی و جوکار» (۱۳۸۸) در مقاله‌ای به بررسی چالش‌های شیوه نگارش زبان فارسی در بازیابی اطلاعات از موتورهای کاوش گوگل، یاهو و آلتا ویستا پرداختند. براین مبنا، پژوهشگران به روش پیمایشی- مقایسه‌ای و اسنادی و با استفاده از یک سیاهه شامل هفده کلیدواژه که هریک نمایانگریک مورد از چالش‌های زبان فارسی در بازیابی اطلاعات بود، این مطالعه را انجام دادند. یافته‌های پژوهش نشان داد موتورهای کاوش وب، شیوه‌های نگارش زبان فارسی را به منظور بهبود کاوش، مورد توجه قرار نداده‌اند و رابطه معناداری بین شکل واژه و نوع ابزار جستجو وجود دارد. در ارتباط با این پژوهش، نکته قابل تأمل اینکه پژوهشگران برای سنجش تأثیرپذیری نویسی و جدانویسی بر بازیابی اطلاعات، تنها به دو مصدق بسته کرده‌اند و از چگونگی و دلایل انتخاب این دو مصدق نیز سخنی به میان نیاورده‌اند. همچنین، پژوهشگران پس از بررسی انجام شده در زمینه این چالش، به یکسان بودن فراوانی مدارک بازیابی شده اشاره کردند و از این طریق درباره عملکرد موتورهای جستجو نسبت به رفع احتمالی چالش‌های رسم الخط فارسی، به نتیجه‌گیری پرداختند. در توضیح این مطلب باید گفت، یکسان بودن فراوانی نتایج بازیابی شده به معنای یکسان بودن رخداد همان مدارک نیست زیرا احتمال دارد شکل‌های مختلف یک واژه در بخش‌های مختلف یک مدرک (عنوان، چکیده و کلیدواژه‌ها) رخ داده و به بازیابی دوباره آن مدارک انجامیده باشد. از سوی دیگر، ممکن است فقط یک حالت نگارشی در مدرک رخ داده باشد و پایگاه اطلاعات علمی فارسی،

امکان بهنجارسازی شکل‌های مختلف واژه را داشته باشد.

«گل‌تاجی و بذرگ» (۱۳۸۹) مسائل ریخت‌شناسی زبان فارسی را در سه پایگاه مقاله‌های فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری»، «مرکز اطلاعات علمی جهاد دانشگاهی» و «پژوهشگاه اطلاعات و مدارک علمی ایران (به اختصار ایراندک)»^۱ با استفاده از روش پیمایشی - مقایسه‌ای بررسی کردند. در این پژوهش، پژوهشگران از یک سیاهه شامل ۱۷ کلید واژه استفاده کردند که به اعتقاد آنها هرکدام نمایانگریک مورد از چالش‌های زبان فارسی در برخورد با فناوری نوین بود. نتایج کلی پژوهش آنان نشان داد هیچ کدام از سه پایگاه فارسی مورد بررسی، به شیوه‌ای جامع چالش‌های زبان شناختی زبان فارسی را در جهت بهبود نتایج جستجو مورد توجه قرار نداده‌اند. همچنین نگارندهای در بعضی موارد تساوی تعداد رکوردهای بازیابی شده در ریخت‌های مختلف یک واژه را نشان از رفع آن چالش خاص در نظر گرفته‌اند. در ارتباط با پژوهش «گل‌تاجی و بذرگ» نیز موارد قابل تأملی که پیش از این درباره پژوهش «جوکار و عبدالله‌ی» اشاره شد، مصدق می‌یابد.

در مقاله «آخشیک و فتاحی» (۱۳۹۱) با عنوان «تحلیل چالش‌های پیوسته نویسی و جدانویسی واژگان فارسی در ذخیره و بازیابی اطلاعات در پایگاه‌های اطلاعاتی»، آنها صد عنوان از پایان‌نامه‌های موجود رشته کتابداری و اطلاع‌رسانی را به منزله نمونه‌ای از متون فارسی در پایگاه‌های اطلاعاتی «پژوهشگاه‌های علوم و فناوری اطلاعات ایران» و «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» انتخاب و تحلیل محتوا کردند. سپس، از هر پایگاه ۵۰ عنوان را به صورت تصادفی انتخاب و عنوان‌های مربوط به هر پایگاه را با «جستجوی عنوانی» به طور عمده در حالت‌های درست و نادرست جستجو کردند. نتایج پژوهش آنان نشان داد، هرچند در پایگاه اطلاعاتی پژوهشگاه علوم و فناوری

۱. نام پیشین این پایگاه مرکز اطلاعات و مدارک علمی ایران بوده است.

۲. علم اطلاعات و دانش‌شناسی

اطلاعات ایران ۵۸٪ عنوان‌ها با تغییرشکل نگارشی مجدد بازیابی می‌شدند؛ اما در پایگاه «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» فقط حالت ثبت شده عنوان‌ها به بازیابی مجدد آن عنوان می‌انجامید. در ارتباط با پژوهش آنان، دونکته قابل تأمل به چشم می‌خورد. نخست، در این پژوهش به وضوح مشخص نشده است که منظور از حالت «جدانویسی»، نگارش با فاصله کامل است یا حالت نیم فاصله‌نویسی؛ یا اینکه این دو حالت نگارشی یکی در نظر گرفته شده است. اگر مبنای پژوهشگران دستور خط مصوب فرهنگستان باشد، در این حالت منظور از جدانویسی حالت نیم فاصله‌نویسی یا نزدیک‌نویسی است. نکته دوم این است که آیا در عنوان‌های انتخاب شده به عنوان حجم نمونه، واژگان شامل حالت «نیم فاصله‌نویسی» هم مشاهده شده است یا خیر و اگر وجود داشته، آیا در زمان جستجو در پایگاه اطلاعات علمی فارسی این حالت نگارشی هم جستجو و بررسی شده است یا خیر.

در نهایت «هماوندی، نوروزی و حسینی بهشتی» (۱۳۹۷) در پژوهشی به روش پیمایشی-تحلیلی و با استفاده از شیوه مشاهده مستقیم، به تشریح مشکلات عمده نوشتاری و معنایی زبان فارسی در استفاده از محیط‌های اطلاعاتی و تعیین میزان انطباق و توجه به این ویژگی‌ها هنگام جستجو و بازیابی در پایگاه‌های اطلاعاتی فارسی پرداختند. یافته‌های آنان نشان داد پایگاه‌های اطلاعاتی فارسی نسبت به ویژگی‌های نوشتاری و معنایی زبان فارسی، همچون پیوسته‌نویسی و جدانویسی، گوناگونی جمع‌ها، واژگان دخیل و معادل آنها توجه کافی ندارند و بسیاری از ویژگی‌های آن را در مراحل ذخیره‌سازی و پردازش اطلاعات نادیده گرفته‌اند. در ارتباط با پژوهش «هماوندی، نوروزی و حسینی بهشتی» موارد قابل تأملی به چشم می‌خورد که پیش از این درباره پژوهش «جوکار و عبدالهی» (۱۳۸۸)، «گل‌تاجی و بذرگر» (۱۳۸۹)، و «آخشیک و فتاحی» (۱۳۹۱) به آن پرداخته شد. مواردی چون انتخاب و اکتفا به چند مصدق برای چالش‌های مورد بررسی، آن هم بدون ذکر دلایل انتخاب آنها.

مرور پژوهش‌های پیشین نشان داد پژوهشگران برای تعیین میزان توجه سامانه‌های بازیابی اطلاعات به چالش‌های خط فارسی، از جمله مسئله پیوسته‌نویسی و جدانویسی، گاه با ذکر تعداد محدودی مصدق (یک یا دو مصدق) آن هم از قلمرو موضوعی محدود، وضعیت سامانه‌های بازیابی اطلاعات را بررسی کرده‌اند؛ درحالی‌که با توجه به پوشش قلمروهای موضوعی متعدد در سامانه‌های بازیابی اطلاعات مورد مطالعه آنها، با درنظرگرفتن این جنبه می‌شد با جامعیت بیشتر و در نتیجه به شکل دقیق‌تر درباره میزان تأثیر چالش‌های نگارشی قضاوت و راهکارهایی را برای اصلاح یا بهبود آنها ارائه کرد. علاوه بر خلاصه فوق، پژوهشگران پس از بازیابی رکوردها در سامانه بازیابی اطلاعات، یکسانی فراوانی تعداد مدارک بازیابی شده در ریخت‌های مختلف یک واژه را نشان از رفع آن چالش در سامانه‌های بازیابی اطلاعات قلمداد کرده‌اند. در توضیح این شیوه پژوهشگران نیز باید گفت کنترل شکل‌های نگارشی یک واژه در بخش‌های یک رکورد (عنوان، چکیده و واژگان کلیدی) امری ضروری است و حتی احتمال دارد فقط یک حالت نگارشی در مدرک رخ داده باشد و سامانه‌های بازیابی به‌گونه‌ای طراحی شده‌اند که قادر به بهنجارسازی شکل‌های نگارشی یک واژه باشند.

در بخش ترکیبات دستور خط فارسی مصوب فرهنگستان، ۲۳ قاعده درباره موقعیت‌های رخداد جدانویسی و پیوسته‌نویسی ذکر شده است؛ در صورتی که مرور پژوهش‌های پیشین نشان می‌دهد پژوهشگران بدون ذکر چگونگی و دلایل انتخاب واژگان بیان‌کننده چالش پیوسته‌نویسی و جدانویسی، بعضًا با درنظرگرفتن یک یا دو مصدق‌ها (کلید واژه‌ها) به بررسی این چالش و همچنین میزان تأثیر آن بر سامانه‌های بازیابی اطلاعات پرداخته‌اند. در صورتی که به نظر می‌رسد انتخاب مصدق‌ها برای هر قاعده می‌تواند تأثیرگذاری متفاوتی بر سامانه‌های بازیابی اطلاعات داشته باشد. تبیین این مسائل به منزله شکاف‌های پژوهشی این قلمروست که سنجش آن می‌تواند سودمند باشد. پس از مرور تحلیلی - انتقادی پیشینه‌های این مقاله، نویسنده‌گان براین باورند که

پژوهش مشابهی با پژوهش حاضر مشاهده نشد و ضرورت انجام این پژوهش، بیش از پیش احساس می‌شود.

پیشینه‌های خارجی

در خارج ایران نیز پیرامون سایر زبان‌ها و مشکلات آنها در مواجهه با محیط‌های الکترونیکی مطالعات مشابه گوناگونی انجام شده است که در ادامه به برخی از آنها اشاره می‌شود.

«ژانگ ولین»^۱ (۲۰۰۷) در پژوهشی پیمایشی - مقایسه‌ای ویژگی‌های پشتیبانی از خارج ایران نیز پیرامون سایر زبان‌ها و مشکلات آنها در مواجهه با محیط‌های الکترونیکی مطالعات مشابه گوناگونی انجام شده است که در ادامه به برخی از آنها اشاره می‌شود.

«لازارینیس»^۲ (۲۰۰۷) در پژوهشی با رویکرد پیمایشی، قابلیت‌های جستجوی وب‌سایت‌های الکترونیکی تجاری را در باره زبان‌های غیر انگلیسی (مطالعه موردی یونانی) بررسی کرد. نتایج او نشان داد موتورهای جستجوی محلی به ریخت‌شناسی سوال‌ها (کلیدواژه‌ها) توجهی نشان نمی‌دهد که نهایت این امر به شکست جستجوی کاربر می‌انجامد.

«لواندوفسکی»^۳ (۲۰۰۸) در پژوهش خود با رویکرد پیمایشی توانایی موتورهای جستجوی پراستفاده و اصلی از جمله گوگل، یاهو، ام اس ان^۴ و اسک^۵ در تشخیص و تمایز میان مدارک به زبان آلمانی از پیشینه‌هایی با زبان انگلیسی را بررسی کرد. نتایج پژوهش او نشان داد در موتورهای کاوش گوگل و ام اس ان، وقتی نتایج به زبان خاصی

-
1. Zhang & Lin
 2. Lazarinis
 3. Lewandowski
 4. MSN
 5. Ask

محدود می‌شود، کاربر با مشکلاتی روبه‌رومی شود، درحالی که هیچ‌یک از موتورهای کاوش در بازیابی نتایج به زبان صفحه رابط کاربر (زبان انتخابی) با مشکل مواجه نمی‌شوند. افزون براین، نتایج اونشن داد استفاده از صفحه میانجی به زبان بومی در جستجو و بازیابی اطلاعات در برخی موقع اثرباری بهتری دارد و همچنین راهبرد محدودیت زبانی، همیشه در بهبود جستجو تأثیرگذار نیست.

در پژوهشی دیگر «همو»^۱ با رویکرد پیمایشی یک قالب کاری برای افزایش کارایی موتورهای کاوش برای متون عربی دار و همچنین فاقد اعراب‌گذاری از طریق روش‌های گسترش سؤال (کلیدواژه) ارائه کرد. نتایج پژوهش اونشن داد گسترش سؤال (کلیدواژه) بر بهبود جستجو و بازیابی متون عربی تأثیرگذار است و کارایی موتورهای کاوش با استفاده از ابزارهای پیشرفته پردازش زبان طبیعی، افزایش می‌یابد.

مرور پژوهش‌های خارجی نیز نشان می‌دهد این پژوهش‌ها اغلب به بررسی توانمندی‌ها و ضعف‌های سامانه‌های جستجو، با هدف شناخت و ارائه راهکارهایی برای اصلاح چالش‌های زبانی پرداخته‌اند. یافته‌های حاصل از آنها نشان می‌دهد ریخت‌شناسی واژه‌ها و عبارت‌های جستجو بر بازیابی مدارک مؤثر است و ابزارهای جستجو در هنگام بازیابی نتایج برشکل کلیدواژه‌های جستجو شده تکیه می‌کنند که این امر در نهایت می‌تواند به شکست جستجوی کاربر منتهی شود.

روش‌شناسی پژوهش

پژوهش حاضراز نظر هدف در ردیف پژوهش‌های کاربردی و از جنبه طرح پژوهش از نوع تحلیل محتواست. جامعه آماری شامل مجموعه مدارک (مقالات‌های علمی - پژوهشی و علمی - ترویجی) ذخیره شده با امکان دسترسی به نسخه تمام‌متن آنها در

پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور»^۱، پایگاه «مرکز اطلاعات علمی جهاد دانشگاهی»^۲ و پایگاه «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری»^۳ است. شایان ذکر است، این سه پایگاه اطلاعات علمی فارسی به دلیل پوشش نسبتاً جامع متون علمی قلمروهای موضوعی مختلف - که در این پژوهش دسته‌بندی قلمروهای موضوعی «سامانه ارزیابی نشریات علمی»^۴ مورد استفاده قرار گرفته است و شامل قلمروهای دام‌پژوهشکی، علوم انسانی، فنی و مهندسی، علوم پایه، منابع طبیعی و کشاورزی، هنر و معماری است - و همچنین، به دلیل دارا بودن بیشترین فراوانی در بین پایگاه‌های اطلاعات علمی مطالعه شده در پژوهش‌های قلمرو بازیابی اطلاعات، به عنوان مهم‌ترین پایگاه‌های اطلاعات علمی فارسی تلقی و محمل انتخاب مدارک شامل مصادق‌های «کلیدواژه‌ها» (واژگان) با قابلیت پیوسته‌نویسی، نزدیک‌نویسی و جدانویسی قرار گرفتند. براین اساس، تعداد کل مدارک بازیابی شده از سه پایگاه اطلاعات علمی فارسی مورد مطالعه ۲۹۱۴۲ مدرک است که به عنوان جامعه آماری انتخاب شد.

حجم نمونه نیز با توجه به وجود سه پایگاه اطلاعات علمی فارسی مورد مطالعه و نیاز به مقایسه شش قلمرو موضوعی و همچنین ده قاعده انتخابی (از مجموع قاعده‌های گزینش شده بخش «ترکیبات» فرهنگستان) با استفاده از روش نمونه‌گیری طبقه‌ای نسبتی و فرمول کوکران برای جامعه معین، با خطای ۰/۰۵ و از طریق فرمول $n = \frac{NZ^2pq}{Nd^2+Z^2pq}$ (دلاور، ۱۳۹۰) تعداد ۳۸۰ مدرک تعیین شد؛ اما با توجه به هدف پژوهش، لازم بود تا این تعداد مدارک به عنوان نمونه در سه سطح، یعنی سه پایگاه اطلاعات علمی فارسی مورد مطالعه، شش قلمرو موضوعی و در هر قلمرو موضوعی نیز بین قاعده‌های دهگانه آنها توزیع شود. بنابراین، پس از توزیع حجم نمونه در سه سطح

1. Magiran; (www.magiran.com)

2. Scientific information Database (SID); (www.sid.ir)

3. Regional information center for science and technology (RICeST); (www.ricest.ac.ir)

4. قابل دسترس در: <http://journals.msrt.ir>

گفته شده، تعداد مدارک در سطح سوم یعنی به ازای هر قاعده، ۱/۷۵ مدرک به دست می‌آمد که این مقدار به عدد ۲ گرد شد. با این عمل، حجم نمونهٔ نهایی به ۴۳۲ مدرک افزایش یافت. بدین‌شکل، با توزیع نمونه در سه سطح گفته شده، به ازای هر پایگاه اطلاعات علمی فارسی مورد مطالعه ۱۴۴ مدرک، به ازای هر قلمرو موضوعی ۲۴ مدرک و به ازای هر قاعده در هر قلمرو موضوعی نیز ۲ مدرک انتخاب شد.

پس از تعیین حجم نمونهٔ مدارک، با مبنا قراردادن بخش ترکیبات دستور خط فارسی مصوب فرهنگستان و با همکاری و نظر استادان رشتۀ‌های علم اطلاعات و دانش‌شناسی وزبان‌شناسی، ۲۳ قاعدهٔ بخش ترکیبات ارزیابی شد. برخی از قاعده‌ها به دلایلی همچون شمی‌بودن و دشواری تشخیص آنها (قاعده‌های ۳، ۵، ۶ و ۷ از مجموعه موارد پیوسته‌نویسی الزامی و قاعده‌های ۱۴، ۱۵ مجموعه موارد جدانویسی الزامی) و همچنین عدم رویداد مصداق‌ها (کلیدواژه‌ها) متناسب با آنها در اصطلاح‌نامه‌ها و فرهنگ‌های تخصصی مورد استفاده یا عدم بازیابی مدرک در زمان جستجوی آنها در پایگاه‌های اطلاعات علمی فارسی مورد مطالعه (قاعده‌های ۴، ۵ و ۸ از موارد الزامی پیوسته‌نویسی و قاعده‌های ۱۳، ۵ و ۷ از موارد جدانویسی الزامی) از مجموع قاعده‌های کنارگذاشته شد. در نهایت، ده قاعده از ۲۳ قاعده دستور خط فارسی مصوب فرهنگستان برای ساخت سیاههٔ وارسی شامل مصداق‌ها (کلیدواژه‌ها) دارای شکل نگارشی پیوسته‌نویسی و جدانویسی انتخاب شد که از این پس، قاعده‌های دهگانه خوانده می‌شود. در بین ده قاعدهٔ انتخابی، مواردی که انتخاب شکل نگارشی به نویسنده واگذار شده بود، بر مبنای کتاب «فرهنگ املایی خط فارسی»^۱ چاپ ۱۳۹۵ عمل شد. لازم به ذکر است، از بین قاعده‌های دهگانه، دو قاعدهٔ ۱ و ۵ به منظور عملیاتی‌سازی سنجش آنها، به دو قاعدهٔ فرعی مجزا تفکیک و با حروف «الف» و «ب» از

۱. صادقی، علی‌اشraf؛ وزندی مقدم، زهرا. (۱۳۹۵). فرهنگ املایی خط فارسی براساس دستور خط فارسی مصوب فرهنگستان زبان و ادب فارسی. تهران: فرهنگستان زبان و ادب فارسی. قابل دسترس در وبگاه

فرهنگستان زبان و ادب فارسی:
<http://persianacademy.ir/fa/X2903952.aspx>

هم متمایز شدند (جدول ۱).

جدول ۱. قاعده‌های دهگانه دستور خط فارسی مصوب فرهنگستان زبان و ادب فارسی

هنگامی که ترکیب پردازه شود، ترکیب جدا [نزدیک‌نویسی] نوشته می‌شود، مثل آب‌شستگی	قاعده ۱ (الف)
هنگامی که ترکیب طولانی شود، ترکیب جدا [نزدیک‌نویسی] نوشته می‌شود، مثل سوراخ‌کاری	قاعده ۱ (ب)
رسیدن حروف مشابه یا بکسان و هم‌خرج به هم موجب جدانویسی [نزدیک‌نویسی] می‌شود، مثل آب‌بند، سیم‌پیچ	قاعده ۲
وقتی جزء دوم با الف آغاز شود، موجب جدانویسی [نزدیک‌نویسی] می‌شود، مانند کم‌احساس، هم‌اسم	قاعده ۳
وقتی جزء دوم با «آ» آغاز شود و تک‌جاجی پاشد، موجب جدانویسی [نزدیک‌نویسی] می‌شود و در صورتی که جزء دوم بیش از یک هجا داشته باشد، از قاعده خاصی پیروی نمی‌کند و گاهی جدا و گاهی پیوسته نوشته می‌شود که در این حالت شکل ارجح واژه بر اساس فرهنگ املایی خط فارسی انتخاب می‌شود، مثل بتن‌آمه، زبان‌آموزی	قاعده ۴
ختم شدن واژه اول در ترکیب به حروف پیوند ناپذیر موجب جدانویسی [نزدیک‌نویسی] می‌شود، مثل کشتارگاه.	قاعده ۵ (الف)
ختم شدن واژه اول در ترکیب به «های» غیرملفوظ موجب جدانویسی [نزدیک‌نویسی] می‌شود، مثل قفسه‌سینه.	قاعده ۵ (ب)
ترکیب‌های اضافی (موصوف و صفت/ مضاف و مضافق‌الیه) جدا نوشته می‌شوند، مثل جسم‌زرد	قاعده ۶
وقتی یک جزء واژه مرکب عدد باشد، موجب جدانویسی [نزدیک‌نویسی] ترکیب می‌شود، مثل هشت‌بهشت	قاعده ۷
واژگان مرکبی که از ترکیب با پیشوند ساخته می‌شود، همیشه جدا [نزدیک‌نویسی] نوشته می‌شود، مگر مرکب‌هایی که با پیشوندهای «به»، «بی» و «هم» با رعایت استثناهایی - صفحات ۲۲-۲۳ دستور خط فارسی - ساخته می‌شود. در این حالت نیز در صورت مواجهه با واژگانی که اختیار به نویسنده واگذار شده باشد، از فرهنگ املایی خط فارسی استفاده می‌شود، مثل همبندی، بی‌حسی موضعی	قاعده ۸
واژگان مرکبی که از ترکیب با پسوند ساخته می‌شود، همیشه پیوسته نوشته می‌شود، مگر هنگامی که مطابق با قاعده ۲، ۴ و ۷ ساخته شوند، مثل نوسانگر، شالیزار	قاعده ۹
یک جزء واژه مرکب صفت فاعلی یا مفعولی باشد، جدا [نزدیک‌نویسی] نوشته می‌شود، مثل اجل‌رسیده، تنظیم‌کننده	قاعده ۱۰

در مرحلهٔ بعد لازم بود به تفکیک قاعده‌های دهگانه، مصداق‌ها (واژگان یا کلیدواژه‌های انتخابی) مورد نیاز هر قاعده انتخاب شود. بدین‌منظور، از اصطلاح‌نامه‌های تخصصی و در صورت نبود اصطلاح‌نامه در هریک از قلمروهای موضوعی (تنها در دام‌پزشکی) از فرهنگ تخصصی آن قلمرو استفاده شد. پس از یافتن هریک از اصطلاحات یا واژگان مورد نظر (به عنوان مصداق موردنظر)، اصطلاح یا واژه در هرسه پایگاه اطلاعات علمی فارسی جستجو شد و در صورت بازیابی بیش از یک مدرک به ازای هر مصداق و همچنین رویداد آن در هرسه پایگاه اطلاعات علمی فارسی، اصطلاح یا لغت برای قاعده مورد نظر انتخاب شد. در نهایت، مصداق‌های انتخابی برای هر قاعده از قاعده‌های دهگانه به تفکیک دریک سیاههٔ وارسی قرار گرفت. لازم به ذکر است، در این مرحله به دلیل حجم بودن اصطلاح‌نامه‌ها و فرهنگ تخصصی، عملاً مرور تمامی صفحات آنها امکان‌پذیر نبود. بدین‌منظور، ابتدا اصطلاح‌نامه‌ها و فرهنگ تخصصی بر حسب حروف الفبا و مقدار حجم لغات هر حرف الفبا، به سه سطح بزرگ، متوسط و کوتاه تقسیم شد. سپس، از هریک از سطوح تعیین شده به روش تصادفی ساده، یک حرف الفبا انتخاب و آنگاه برای هر قلمرو موضوعی، فرایند جستجو برای مصداق‌های موردنظر بر حسب قاعده‌های دهگانه انجام شد.

در گام بعد، با مذکور قراردادن سیاههٔ وارسی تهیه شده در مرحلهٔ قبل، به هریک از پایگاه‌های اطلاعاتی مورد مطالعه مراجعه شد و مصداق‌ها با تمام شکل‌های نگارشی در کادر جستجوی ساده سه پایگاه اطلاعات علمی فارسی مورد مطالعه جستجو گردید.^۱ شایان ذکر است، به دلیل عدم پشتیبانی و شناسایی پایگاه‌های اطلاعاتی مورد مطالعه (به جز پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری») از حالت نیم فاصله در هنگام جستجو در نتیجه عدم بازیابی مدارک دارای شکل نگارشی نزدیک نویسی، این حالت تنها در این بخش از پژوهش از فهرست مجموع حالت‌های

۱. به منظور اجتناب از تغییراتی که ممکن است به علت روزآمدسازی پایگاه‌های اطلاعاتی پیش آید، فرایند جستجو طی یک روز انجام شد.

مورد مطالعه کنار گذاشته شد.

در مرحلهٔ پیشین، از بین مجموع مدارک بازیابی شده، به‌ازای هریک از حالت‌های نگارشی (پیوسته‌نویسی یا جدانویسی)، تعداد یک مدرک و در صورتی که هیچ مدرکی با حالت نگارشی موردنظر در پایگاه اطلاعات علمی فارسی بازیابی نمی‌شد، هردو مدرک از حالت نگارشی دیگر به عنوان نمونه انتخاب می‌شد (در مجموع دو مدرک برای هر قاعده از هر قلمرو موضوعی). چنان‌که می‌دانید، در روش نمونه‌گیری تصادفی ساده، احتمال و شанс انتخاب شدن برای همه اعضای جامعه برابر و مستقل از یکدیگر است. این نوع نمونه‌گیری را به سه شیوه می‌توان انجام داد: (الف) قرعه‌کشی (ب) جدول اعداد تصادفی (ج) استفاده از نرم‌افزارهای آماری (ولیخانی و سرافراز، ۱۳۹۴). از این‌رو، پژوهشگر برای انتخاب دو مدرک از بین مجموع مدارک بازیابی شده برای هر مصدق، از روش نمونه‌گیری تصادفی ساده و از نرم‌افزار تولید اعداد تصادفی^۱ استفاده کرد. شایان ذکر است، بدین شکل فرایند انتخاب و گردآوری ۴۳۲ مدرک موردنیاز به عنوان حجم نمونه صورت پذیرفت.

در گام آخر، به منظور سنجش و ثبت قابلیت پایگاه‌های اطلاعات علمی فارسی از نظر بازیابی مدارک با هریک از شکل‌های نگارشی مصدق‌ها اعم از پیوسته‌نویسی یا جدانویسی، ابتدا به هریک از ۴۳۲ مدرک انتخاب شده به عنوان نمونه در پایگاه‌های اطلاعات علمی فارسی مراجعه شد و فرایند تحلیل محتوا در عنوان، چکیده و واژگان کلیدی هر مدرک انجام و پس از اطمینان از عدم رخداد همزمان چند شکل نگارشی مصدق در بخش چکیده، عنوان و واژگان کلیدی پایگاه اطلاعات علمی فارسی موردنظر، مدارکی که با هردو حالت نگارشی مصدق‌ها اعم از پیوسته‌نویسی (سرهم‌نویسی) و جدانویسی (فاصله کامل) قابل بازیابی بود، این ویژگی به عنوان حالت «گسترش‌پذیری جستجو» برای پایگاه اطلاعات علمی فارسی موردنظر در نظر گرفته می‌شد؛ در غیراین صورت، به عنوان حالت «گسترش‌ناپذیری جستجو» ثبت گردید.

۱. این نرم‌افزار از طریق آدرس <https://www.spss-iran.com> قابل دسترسی است.

یافته‌ها

چنان‌که جدول ۲ نشان می‌دهد، در مجموع پایگاه‌های مورد بررسی تنها ۲۳ مدرک (۰٪/۵) با حالت گسترش‌پذیری جستجو بازیابی شدند. در مقابل، ۴۰۹ مدرک (۹۴٪/۷) با حالت گسترش‌نایپذیری جستجو بازیابی شدند.

جدول ۲. قابلیت پایگاه‌های اطلاعات علمی فارسی از نظر گسترش جستجو و

بازیابی مدارک به صورت پیوسته نویسی و جدانویسی

		گسترش جستجو			
		گسترش	گسترش	پایگاه	
		نایابی	پذیری		
		جستجو	جستجو		
X ²	(df=٤)				
P	P	کل			
۱۴۴	۱۴۴	۰		فراوانی مشاهده شده	
۱۴۴	۱۳۶/۳	۷/۷		فراوانی مورد انتظار	
۱۰۰	۱۰۰	۰		درصد در درون پایگاه اطلاعات علمی فارسی	SID
۱۴۴	۱۳۱	۱۳		فراوانی مشاهده شده	
۱۴۴	۱۳۶/۳	۷/۷		فراوانی مورد انتظار	
۰/۰۰۲	۱۲/۷۶۷**	۰/۰۰۲		درصد در درون پایگاه اطلاعات علمی فارسی	MAGIRAN
۱۴۴	۱۳۴	۱۰		فراوانی مشاهده شده	
۱۴۴	۱۳۶/۳	۷/۷		فراوانی مورد انتظار	
۱۰۰	۹۱	۹		درصد در درون پایگاه اطلاعات علمی فارسی	RICEST
۴۳۲	۴۰۹	۲۳		فراوانی مشاهده شده	
۴۳۲	۴۰۹	۲۳		فراوانی مورد انتظار	
۱۰۰	۹۴/۷	۵/۳		درصد در درون پایگاه‌های اطلاعاتی	کل

* $P < 0.05$ ** $P < 0.01$

چنان‌که می‌دانید، آزمون مجذور خی را می‌توان هم برای رابطه و هم تفاوت بین متغیرهای اسمی یا مقوله‌هایی به کار برد که دو یا بیش از دو ارزش داشته باشند. این نوع آزمون تنها می‌تواند در رابطه با تعداد یا فراوانی‌ها به کار رود (دلاور، ۱۳۹۰). از این‌رو، برای بررسی معناداری تفاوت میان فراوانی‌ها در حالت گسترش‌پذیری جستجو و گسترش‌ناپذیری جستجوی مصدقه‌ها مدارک از آزمون مجذور خی استفاده شد. با توجه به مقدار مجذور خی به دست آمده ($P = ۰/۰۵, X^2 = ۷۶/۱۲$)، تفاوت معناداری میان پایگاه‌های اطلاعات علمی فارسی در دو دسته گسترش‌پذیری جستجو و گسترش‌ناپذیری جستجوی مصدقه‌های فراوانی مدارک وجود داشت. پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی» بیشترین فراوانی را در گسترش‌ناپذیری جستجوی مصدقه‌های مدارک و همچنین کمترین فراوانی را در گسترش‌پذیری جستجوی مصدقه‌های مدارک به خود اختصاص داده بود؛ و در مقابل، پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» بیشترین فراوانی را در گسترش‌پذیری جستجوی مصدقه‌های مدارک و کمترین فراوانی را در گسترش‌ناپذیری جستجوی مصدقه‌های مدارک داشت.

علاوه بریافته بالا، نتایج به دست آمده از توزیع فراوانی قابلیت پایگاه‌های اطلاعات علمی فارسی از نظر گسترش جستجو و بازیابی مدارک به صورت پیوسته‌نویسی و جدانویسی بر حسب قاعده‌های دهگانه فرهنگستان زبان و ادب فارسی نشان داد، پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» در مصدقه‌های مربوط به قاعده‌های ۱، ۲، ۵ و ۹ قادر است با هریک از شکل‌های نگارشی مصدقه‌ها اعم از پیوسته‌نویسی و جدانویسی مدارک مورد نظر را دوباره بازیابی کند؛ بدین شکل که پایگاه اطلاعات علمی فارسی مذکور از کل ۱۳ مدرک به دست آمده با حالت گسترش‌پذیری جستجو، در ۹ مدرک شامل شکل نگارشی جدانویسی مصدقه، قادر به بازیابی مجدد این مدارک حتی با حالت جستجوی پیوسته‌نویسی مصدقه است (گسترش پیوسته‌نویسی به جدانویسی) و در ۴ مدرک دیگر که دارای شکل نگارشی پیوسته‌نویسی

از مصداق‌ها بود، پایگاه اطلاعات علمی فارسی قادر به بازیابی دوباره مورد نظر حتی با حالت جستجوی جدانویسی مصداق‌ها بود (گسترش جدانویسی به پیوسته‌نویسی). در مقابل، پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» در قاعده‌های بیشتری (۱، ۲، ۳، ۸، ۹ و ۱۰)، از نظر توانایی بازیابی مدارک با هریک از شکل‌های نگارشی در دامنه‌ای محدودتر نسبت به پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» جای داشت؛ بدین ترتیب که در کل مدارک به دست آمده با حالت گسترش‌پذیری جستجو (۱۵ مدرک) با بررسی عنوان، چکیده و واژگان کلیدی در هر ده مدرک، فقط شکل نزدیک‌نویسی مصداق‌ها روى داده بود و پایگاه اطلاعات علمی فارسی مذکور در صورت جستجوی مصداق‌ها با حالت جدانویسی، علاوه بر بازیابی مدارک شامل شکل نگارشی جدانویسی، مدارک دارای شکل نگارشی نزدیک‌نویسی را هم بازیابی می‌کرد. شایان ذکر است، پایگاه اطلاعات علمی فارسی «مرکز اطلاعات علمی جهاد دانشگاهی» به دلیل فراوانی صفحه‌برای گسترش‌پذیری جستجو در نتیجه ناتوانی در بازیابی مدارک با هریک از شکل‌های نگارشی مصداق‌ها، در این قسمت گزارش نشده است (جدول ۳).

جدول ۳. قابلیت پایگاه‌های اطلاعات علمی در گسترش‌پذیری جستجو به تفکیک قاعده‌های دهگانه

پایگاه‌های اطلاعاتی		شماره قاعده	قابلیت پایگاه	فرآونی درصد
۱۵/۴	۲	۱ الف	گسترش پیوسته به جدا	
۱۵/۴	۲	۱ ب	گسترش پیوسته به جدا	
۲۳	۳	۲	گسترش پیوسته به جدا	
۱۵/۴	۲	۵ الف	گسترش جدا به پیوسته	
۱۵/۴	۲	۹	گسترش به جدا	
۱۵/۴	۲	کل	گسترش جدا به پیوسته	۱۳
۱۰۰				

فراوانی درصد		قابلیت پایگاه	شماره قاعده	پایگاه‌های اطلاعاتی
۲۰	۲	گسترش جدا به نیم فاصله	الف	RICEST
۱۰	۱	گسترش جدا به نیم فاصله	۲	
۲۰	۲	گسترش جدا به نیم فاصله	۳	
۲۰	۲	گسترش جدا به نیم فاصله	۸	
۲۰	۲	گسترش جدا به نیم فاصله	۹	
۱۰	۱	گسترش جدا به نیم فاصله	۱۰	
۱۰۰			کل	

علاوه بریافته بالا، مقایسه شکل نگارشی مصاداق‌ها در بخش عنوان، چکیده و واژگان کلیدی نسخه پی.دی.اف^۱ هر مدرک با اطلاعات ارائه شده از همان مدرک در پایگاه‌های اطلاعات علمی فارسی نشان داد، شکل نگارشی بخش قابل توجهی از مصاداق‌های مدارک تغییر کرده است (جدول ۴).

جدول ۴. توزیع فراوانی تغییرات شکل نگارشی مصاداق‌ها (کلیدواژه‌های انتخابی) از مدرک به پایگاه‌های اطلاعات علمی فارسی

درصد	فراوانی	تغییرات شکل نگارشی مصاداق (از مدرک به پایگاه اطلاعاتی)	پایگاه
۰/۷	۱	پیوسته به جدا	SIS
۰/۷	۱	نیم فاصله به پیوسته	
۰/۷	۱	پیوسته و جدا به جدا	
۰/۷	۱	پیوسته، نیم فاصله و جدا به پیوسته و جدا	
۱/۴	۲	نیم فاصله به پیوسته، نیم فاصله و جدا	
۱/۴	۲	نیم فاصله به نیم فاصله و جدا	

درصد	فرآنی	تغییرات شکل نگارشی مصدق (از مذکور به پایگاه اطلاعاتی)	پایگاه
۲/۸	۴	پیوسته و جدا به <u>پیوسته</u> و جدا	
۴/۹	۷	نیم فاصله و جدا به جدا	
۲۲/۹	۳۳	پیوسته به <u>پیوسته</u>	
۲۸/۵	۴۱	نیم فاصله به جدا	
۳۵/۴	۵۱	جدا به جدا	
۱۰۰	۱۴۴	کل	
۰/۷	۱	نیم فاصله و جدا به <u>پیوسته</u> و جدا	MAGIRAN
۱/۴	۲	پیوسته به <u>جدا</u>	
۱/۴	۲	نیم فاصله و جدا به <u>جدا</u>	
۲/۸	۴	پیوسته به <u>پیوسته</u> و جدا	
۴/۹	۷	پیوسته و جدا به <u>پیوسته</u> و جدا	
۵/۶	۸	نیم فاصله به <u>پیوسته</u>	
۵/۶	۸	نیم فاصله به <u>پیوسته</u> و جدا	
۲۳/۶	۳۴	پیوسته به <u>پیوسته</u>	
۲۳/۶	۳۴	نیم فاصله به <u>جدا</u>	
۳۰/۶	۴۴	جدا به <u>جدا</u>	
۱۰۰	۱۴۴	کل	
۰/۷	۱	نیم فاصله به نیم فاصله و <u>پیوسته</u>	RICEST
۰/۷	۱	پیوسته و نیم فاصله به <u>جدا</u>	
۰/۷	۱	نیم فاصله به نیم فاصله و جدا	
۲/۸	۴	پیوسته به <u>جدا</u>	
۲/۸	۴	نیم فاصله و جدا به <u>جدا</u>	
۲/۸	۴	نیم فاصله به <u>پیوسته</u> ، نیم فاصله و جدا	
۳/۵	۵	پیوسته و جدا به <u>پیوسته</u> و جدا	
۴/۲	۶	نیم فاصله به <u>پیوسته</u> و جدا	

درصد	فرآینی	تغییرات شکل نگارشی مصداق (از مدرک به پایگاه اطلاعاتی)	پایگاه
۶/۳	۹	نیم فاصله به پیوسته	
۶/۳	۹	نیم فاصله به نیم فاصله	
۱۶/۷	۲۴	نیم فاصله به جدا	
۲۴/۳	۳۵	پیوسته به پیوسته	
۲۸/۵	۴۱	جدا به جدا	
۱۰۰	۱۴۴	کل	

با توجه به جدول ۴ در پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی» از مجموع ۱۴۴ مدرک، در ۸۸ مدرک شکل نگارشی مصداق‌ها تغییری نکرده بود؛ اما در ۵۶ مدرک دیگر، شکل نگارشی مصداق‌ها تغییر داشت. این وضعیت تقریباً با همین نسبت در پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» نیز مشاهده می‌شود؛ بدین ترتیب که در ۸۵ مدرک شکل نگارشی مصداق‌ها بدون تغییر، اما در ۵۹ مدرک دیگر شکل نگارشی مصداق‌ها تغییر یافته بود. پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» متفاوت با دو پایگاه اطلاعات علمی فارسی دیگر بود؛ به‌گونه‌ای که در ۹۰ مدرک، تغییری در شکل نگارشی مصداق‌ها روی نداده بود و تنها در ۵۴ مدرک شکل نگارشی مصداق‌ها بین نسخه‌پی‌دی. اف مدرک با پایگاه اطلاعات علمی فارسی متفاوت بود.

بحث و نتیجه‌گیری

به طور خلاصه، یافته‌های پژوهش حاضر نشان داد پایگاه‌های اطلاعات علمی فارسی در هنگام جستجو از شکل نگارشی نزدیک نویسی و در نتیجه بازیابی مدارک دارای صرفاً شکل نگارشی نزدیک نویسی پشتیبانی نمی‌کنند؛ بدین ترتیب که هنگام جستجو با این حالت نگارشی در پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» همان

مدارک دارای شکل نگارشی جدانویسی بازیابی می‌شوند و مدارک دارای صرفاً شکل نگارشی نزدیک نویسی بازیابی نمی‌شدند. در پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی»، علاوه بر بازیابی مدارک دارای شکل نگارشی جدانویسی، مدارک دارای یکی از اجزای مصدقه‌ها (کلیدواژه‌ها) هم بازیابی می‌شدند و این امر موجب ریزش کاذب^۱ قابل توجه در مدارک بازیابی شده می‌گردید. این یافته با یافته‌های پژوهش «گل‌تاجی و بذرگ» (۱۳۸۹) همسو نیست. در این پژوهش، پژوهشگران یکسان بودن تعداد مدارک بازیابی شده با حالت‌های جدانویسی و نزدیک نویسی را به بهنجارسازی شکل نگارشی از سوی پایگاه‌های اطلاعاتی نسبت داده‌اند؛ درحالی که یافته‌های پژوهش حاضر نشان می‌دهد از دلایل احتمالی یکسان بودن تعداد کل مدارک بازیابی شده، می‌تواند به عدم پشتیبانی پایگاه اطلاعات علمی فارسی از شکل نگارشی نزدیک نویسی و یا به رخداد همزمان چند شکل نگارشی مصدقه در بخش‌های مختلف یک مدرک اعم از عنوان، چکیده و واژگان کلیدی بازگردد.

علاوه بر این، نتایج نشان داد میان قابلیت پایگاه‌های اطلاعات علمی فارسی از نظر بازیابی مدارک با هریک از شکل‌های نگارشی اعم از پیوسته نویسی و جدانویسی تفاوت وجود دارد. بدین ترتیب که پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» با بیشترین فراوانی در گسترش پذیری جستجو نسبت به سایر پایگاه‌های اطلاعات علمی فارسی از عملکرد مطلوب‌تری برخوردار است؛ به‌گونه‌ای که در مدارک به دست آمده با حالت گسترش پذیری جستجو در این پایگاه اطلاعات علمی فارسی، با جستجوی مصدقه‌های آنها با هریک از حالت‌های جدانویسی یا پیوسته نویسی، مدارک مورد نظر دوباره قابل بازیابی است. در مقابل، پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی» با کمترین فراوانی در گسترش پذیری جستجوی مصدقه‌های

۱. خروجی و برونداد غیرمربوطی که در نتیجه اجرای راهبرد کاوش در سیستم بازیابی اطلاعات تولید می‌شود. محاسبه ریزش کاذب از طریق فرمول زیر (یوسفی، ۱۳۷۶): مدارک بازیابی شده مرتبط - تعداد کل مدارک بازیابی شده = ریزش کاذب.

مدارک نسبت به دو پایگاه اطلاعات علمی فارسی دیگر، از وضعیت نامطلوبی برخوردار بود؛ بدین ترتیب که با اعمال هریک از تغییرها در شکل نگارشی به هنگام جستجو، مدارک موردنظر بازیابی نمی‌شد و تنها جستجوی مصدقه‌ها با همان حالت ثبت شده در مدارک به بازیابی دوباره آنها می‌انجامید.

از این‌رو، نتایج کلی به دست آمده این بخش از پژوهش با یافته‌های پژوهش‌های «مرتضایی» (۱۳۸۱)، «عبداللهی و جوکار» (۱۳۸۸)، «گل‌تاجی و بذرگر» (۱۳۸۹)، «آخشیک و فتاحی» (۱۳۹۱)، «هماوندی و دیگران» (۱۳۹۷) هم راستاست؛ بدین شکل که نتایج این بخش از پژوهش مهرتأثییدی است بر یافته‌های «مرتضایی» (۱۳۸۱) مبنی بر اینکه استاندارد نبودن شکل نوشتاری واژگان در عدم مطلوبیت و جامعیت نتایج جستجو تأثیر می‌گذارد. یافته‌های پژوهش «عبداللهی و جوکار» (۱۳۸۸) نیز نشان داد بین شکل نوشتاری واژه و ابزار جستجو رابطه وجود دارد؛ بدین معنا که به کاربردن یک شکل خاص از کلیدواژه و استفاده از یک ابزار جستجوی خاص، بر بازیابی اطلاعات تأثیرگذار خواهد بود. به عنوان مثال، جستجوی شکل پیوسته‌نویسی مصدقه «سوراخکاری» در پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی» می‌تواند به بازیابی مدارکی بینجامد که تنها شکل پیوسته‌نویسی مصدقه در آن روی داده است و در مقابل، در پایگاه‌های اطلاعاتی دیگر همچون «بانک اطلاعات نشریات کشور» جستجو با همان شکل پیوسته مصدقه «سوراخکاری» می‌تواند به بازیابی مدارک دارای دو شکل نگارشی جدا و پیوسته منتهی شود. در کنار یافته‌های این دو پژوهش، یافته‌های «گل‌تاجی و بذرگر» (۱۳۸۹)، «آخشیک و فتاحی» (۱۳۹۱)، «هماوندی و دیگران» (۱۳۹۷) نیز به طور کلی نشان داد پایگاه‌های اطلاعات علمی فارسی به مسائل ریخت‌شناسی زبان فارسی از جمله پیوسته‌نویسی و جدانویسی توجه چندانی نشان نداده‌اند.

افزون بر موارد بالا، نتایج به دست آمده از توزیع فراوانی قابلیت پایگاه‌های اطلاعات علمی فارسی از نظر گسترش جستجو و بازیابی مدارک به صورت پیوسته‌نویسی و

جدانویسی بر حسب قاعده‌های دهگانه فرهنگستان زبان و ادب فارسی نشان داد، پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» قادر است بدخی مصادق‌های انتخابی مربوط به قاعده‌های ۱، ۲، ۵ و ۹ با هریک از شکل‌های نگارشی مصادق‌ها اعم از پیوسته‌نویسی و جدانویسی مدارک مورد نظر را بازیابی کند. به عنوان مثال، در قاعده ۹ که مربوط به ترکیب‌های دارای پسوند است، با جستجوی مصادق‌ها «حسگر» و «نوسانگر»، پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» قادر است با هردو حالت جدانویسی و پیوسته‌نویسی، مدارک موردنظر را بدون توجه به شکل نگارشی دوباره بازیابی کند. از دلایل این امر می‌تواند این نکته باشد که پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» احتمالاً از روش‌های خاصی جهت بهنجارسازی شکل‌های مختلف یک مصادق در بخی قاعده‌های نگارشی استفاده می‌کند.^۱

در مقابل، پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع رسانی علوم و فناوری» در قاعده‌های بیشتری (۱۱، ۲، ۳، ۸، ۹ و ۱۵)، ولی از نظر توانایی بازیابی مدارک با هریک از شکل‌های نگارشی، در دامنه‌ای محدودتر نسبت به پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» جای داشت؛ بدین ترتیب که در صورت جستجوی مصادق‌ها با حالت جدانویسی در پایگاه اطلاعات علمی فارسی مذکور، علاوه بر بازیابی مدارک شامل شکل نگارشی جدانویسی از مصادق به بازیابی مدارک دارای شکل نگارشی نزدیک‌نویسی مصادق نیز می‌انجامید. به عنوان مثال، در قاعده ۱ که مربوط به جدانویسی ترکیب‌های طولانی و پرندانه است، با جستجوی شکل جدانویسی مصادق «آب شستگی»، پایگاه اطلاعات علمی فارسی مذکور قادر بود، علاوه بر بازیابی مدارک دارای آن شکل، مدارک دارای شکل نزدیک‌نویسی مصادق (آب شستگی) را هم بازیابی نماید. این نتایج با یافته‌های به دست آمده از پژوهش «آخشیک و فتاحی» (۱۳۹۱) مغایرت

۱. علی‌رغم مکاتبه‌ای که با تیم پشتیبانی فنی پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» انجام شد، اما تیم مربوطه به دلیل مسائلی رقابتی با سایر پایگاه‌های اطلاعات علمی فارسی حاضر به معرفی روش‌های مورد استفاده نشدنند.

دارد. نتایج پژوهش آنان نشان داد پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع رسانی علوم و فناوری» به ویژگی‌های پیوسته‌نویسی و جدانویسی توجه نشان نداده است و تنها حالت ثبت شده عنوان مدارک به بازیابی دوباره آن می‌انجامد، درحالی که یافته پژوهش حاضر نشان داد پایگاه اطلاعات علمی فارسی مورد نظر در مواردی که مدرک ذخیره شده در پایگاه اطلاعات علمی فارسی دارای شکل نگارشی نزدیک‌نویسی از مصدقاق (واژه یا کلیدواژه انتخابی) باشد، در صورت جستجوی مصدقاق مورد نظر با شکل نگارشی جدانویسی، پایگاه همچنان قادر به بازیابی مدرک مورد نظر است. با وجود این، در ارتباط با رویکرد پایگاه «مرکز منطقه‌ای اطلاع رسانی علوم و فناوری» در بهنجارسازی حالت‌های نگارشی یک مصدقاق می‌توان گفت از آنجاکه یکی از مشکلات مهم خط فارسی در باب واژگان مرکب، مسئله «مشخص نبودن مرز دقیق واژگان مرکب» است (مرتضایی، ۱۳۸۰؛ رمضانی، ۱۳۸۶؛ آخشیک و فتاحی، ۱۳۹۱)، این راهکار پایگاه اطلاعات علمی فارسی بالا ضمن افزایش جامعیت نتایج بازیابی شده می‌تواند سبب همارایی نادرست واژگان شده و در نتیجه به ریزش کاذب در مدارک بازیابی شده منتهی شود. نتایج به دست آمده از مقایسه شکل نگارشی مصدقاق‌ها در عنوان، چکیده و واژگان کلیدی نسخه پی.دی. اف مدارک با اطلاعات ارائه شده از همان مدارک در پایگاه‌های اطلاعات علمی فارسی نیز نشان داد، شکل نگارشی بخش قابل توجهی از مصدقاق‌های مدارک تغییر یافته است؛ بدین ترتیب که در دو پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» و پایگاه اطلاعات علمی «مرکز اطلاعات علمی جهاد دانشگاهی» از مجموع ۱۴۴ مدرک برای هر پایگاه اطلاعات علمی فارسی، به ترتیب شکل نگارشی ۵۶ و ۵۹ مصدقاق تغییر یافته است و بیشترین تغییرات و عدم یکدستی نیز مربوط به مدارک دارای شکل نگارشی نزدیک‌نویسی است که احتمالاً در زمان درون برد^۱ به درون پایگاه اطلاعات علمی فارسی به شکل نگارشی جدا یا پیوسته تغییر یافته است

و در سایر تغییرات نگارشی که از فراوانی کمتری برخوردار است، شکل نگارشی مصدق‌ها از حالت نگارشی «پیوسته به جدا» تغییر یافته است.

در پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» وضعیت کمی متفاوت بود و نسبت به دو پایگاه اطلاعات علمی فارسی دیگر پراکندگی و بی‌نظمی بیشتری در نامه‌سانی شیوه نگارشی مصدق‌ها بین فایل پی‌دی‌اف مدارک و پایگاه اطلاعات علمی فارسی مشاهده شد؛ اما مشابه دو پایگاه اطلاعات علمی فارسی دیگر، بیشتر این تغییرات مربوط به مدارک دارای شکل نگارشی نزدیک‌نویسی بود که در پایگاه اطلاعات علمی فارسی عمده‌تاً به شکل نگارشی جدا یا پیوسته تغییر یافته بود. بنابراین، با توجه به اطلاعات ویافته‌های به دست آمده از این بخش از پژوهش می‌توان گفت آنچه از یک مدرک جهت جستجو و بازیابی مدارک در پایگاه‌های اطلاعات علمی فارسی قرار داده می‌شود، رفتار اولیه نگارنده مدارک نیست. این تغییرها و عدم یکدستی در شکل نگارشی مصدق‌ها بین مدارک (عنوان، چکیده و واژگان کلیدی) و همان اطلاعات در پایگاه اطلاعات علمی فارسی، به چند دلیل احتمالی می‌تواند روی داده باشد که توضیح آن در ادامه می‌آید.

مقاله‌های مجله‌های علمی عمده‌تاً به شکل نسخه ورد^۱ و پی‌دی‌اف در اختیار پایگاه‌های اطلاعات علمی فارسی قرار می‌گیرد و نمایه‌سازان پایگاه‌های اطلاعاتی نیز به شکل متداول (کپی و درج^۲)، بخش عنوان، چکیده و واژگان کلیدی، هر مقاله را به درون نرم افزار مدیریت محتوا پایگاه‌های اطلاعاتی وارد می‌کنند. این شیوه ورود اطلاعات، در صورت عدم پشتیبانی و شناسایی شکل نگارشی نزدیک‌نویسی، می‌تواند از دلایل احتمالی بروز خطا و در نتیجه تبدیل شدن شکل نزدیک‌نویسی عمده مصدق‌ها به حالت جدانویسی باشد. علاوه بر این، از آنجاکه بخش‌های چکیده، عنوان و واژگان کلیدی مقاله‌های فاقد فایل ورد، توسط گروه تایپیست هر پایگاه اطلاعات علمی فارسی

1. Word
2. Paste

تایپ می‌شود، از دیگر دلایل احتمالی تفاوت و عدم یکدستی شکل نگارشی مصادق‌ها، همچون تغییر شکل نگارشی مصادق‌ها از حالت «جدا به پیوسته» یا «پیوسته به جدا» بین نسخه پی.دی. اف مدرک و پایگاه اطلاعات علمی فارسی، می‌تواند ناشی از این مسئله باشد. علاوه بر این، در پایگاه اطلاعات علمی فارسی «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری»، عامل احتمالی دیگری در ایجاد این ناهماهنگی در شکل نگارشی مصادق‌ها دخیل است؛ پایگاه اطلاعات علمی فارسی مذکور برای بخش واژگان کلیدی تعداد معینی کلیدواژه در نظر گرفته است و در صورت نبود کلیدواژه یا کم بودن آن از حد تعیین شده، نمایه‌سازان پایگاه اطلاعات علمی فارسی مذکور، تعدادی کلیدواژه جدید به بخش کلیدواژه‌ها اضافه می‌کنند. این مسئله نیز می‌تواند از دیگر دلایل احتمالی تفاوت و ناهماهنگی شکل نگارشی مصادق‌ها بین نسخه پی.دی. اف مدارک و پایگاه اطلاعات علمی فارسی باشد.

به طور خلاصه، بنا بر افتته‌ها و مطالعه‌های پیشین می‌توان این گونه جمع‌بندی کرد که هرچند دو پایگاه اطلاعات علمی فارسی «بانک اطلاعات نشریات کشور» و «مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری» در برخی مصادق‌ها مربوط به قاعده‌های دهگانه به مسئله پیوسته‌نویسی و جدانویسی توجه نشان داده‌اند و در نتیجه قادر به بازیابی مدارک با دیگر شکل‌های نگارشی مصادق‌هاست؛ اما با توجه به اینکه تنها ۲۳ مدرک معادل ۳٪ از مدارک در هنگام جستجو با هریک از شکل‌های نگارشی قابل بازیابی است و در مقابل ۴۰۹ مدرک دیگر معادل ۷٪، تنها با همان حالت ثبت شده مصادق‌ها مدارک قابل بازیابی است، می‌توان نتیجه گرفت پایگاه‌های اطلاعات علمی فارسی چالش‌های پیوسته‌نویسی و جدانویسی را به منظور بهبود جامعیت نتایج جستجو چندان مورد توجه قرار نداده‌اند. این بی‌توجهی در کنار تغییرهای شکل نگارشی واژگان در زمان ورود اطلاعات مدارک (عنوان، چکیده و واژگان کلیدی) به درون پایگاه‌های اطلاعاتی علمی فارسی، می‌تواند نایکدستی در شکل نگارشی مصادق‌های مدارک را

تشدید کند. در نهایت، کاربران بالقوه این قبیل پایگاه‌های اطلاعاتی در صورت جستجو با یک شکل نگارشی، از دستیابی جامع به مدارک مورد نیازشان بازمی‌مانند.

پیشنهادهای پژوهش

پیشنهادهای کاربردی

با توجه به نتایج به دست آمده از پژوهش حاضر، پیشنهادهای زیر می‌تواند در جهت بهبود یا رفع چالش‌های پیش روی پایگاه‌های اطلاعات علمی فارسی، مؤثر واقع شود.

آگاه‌سازی کاربران نسبت به چالش‌های رسم الخط فارسی و همچنین چگونگی استفاده از پایگاه‌های اطلاعات علمی فارسی. به عنوان نمونه، «اختصاصی سازی صفحه ورود پایگاه اطلاعات علمی فارسی برای هر کاربر، جهت آگاهی از قلمرو موضوعی کاربران و سنجش گرایش نگارشی کاربران هر قلمرو موضوعی و در نتیجه اعمال آنها در فرایندهای بعدی ذخیره، پردازش و بازیابی مدارک مرتبط»، «نمایش یک پیغام یا یک فیلم آموزشی کوتاه، جهت آشنایی کاربران با راهبردهای جستجو و همچنین وجود مسائل و چالش‌های رسم الخط فارسی تأثیرگذار بر بازیابی مدارک در پایگاه اطلاعات علمی فارسی»، «نمایش یک پیام به کاربر در صورت جستجو با یک شکل نگارشی و یا پایین بودن تعداد نتایج بازیابی شده از یک حد معین» و «آگاه‌سازی کاربران نسبت به تکرار جستجو با دیگر شکل‌های نگارشی یک واژه، با قرار دادن متنی پیش‌فرض در درون جعبه جستجو»؛ برگزاری نشست‌هایی از سوی طراحان پایگاه‌های اطلاعات علمی فارسی. پیشنهاد می‌شود طراحان پایگاه‌های اطلاعات علمی فارسی نشست‌هایی را با هدف ارائه تجربه‌ها و بهره‌مندی از دستاوردهای یکدیگر در زمینه رفع یا بهبود چالش‌های خط و زبان فارسی در محمل‌های الکترونیکی برگزار کنند.

رفع خطاها احتمالی و اشتباها انسانی در زمان درون برد مدارک (چکیده، عنوان و واژگان کلیدی) به درون پایگاه‌های اطلاعات علمی فارسی. پیشنهاد می‌شود طراحان و نمایه‌سازان پایگاه‌های اطلاعاتی ضمن توجه به رخداد مسئله بالا، نسبت به رفع آن اقدام

کنند. همچنین، پیشنهاد می‌شود آن دست از مدارکی که بخش عنوان، چکیده و واژگان کلیدی آنها از سوی گروه تایپیست پایگاه‌های اطلاعاتی حروف‌چینی مجدد می‌شود، قبل از انتقال به محیط پایگاه اطلاعات علمی فارسی از نظر غلط‌های املایی و همچنین واژگان دارای چند شکل نگارشی اعم از پیوسته‌نویسی و جدانویسی ویراستاری شوند. به کارگیری روش N -gram در الگوریتم‌های نمایه‌سازی پایگاه‌های اطلاعات علمی فارسی. از آنجاکه این نوع نمایه‌سازی نیازی به اطلاعات قبلی درباره مفاهیم یا زبان متن مورد نظر ندارد (دانش و دیگران، ۲۰۱۱) پیشنهاد می‌شود طراحان پایگاه‌های اطلاعات علمی فارسی برای نمایه‌سازی واژگان مرکب یا دارای چند شکل نگارشی نیاز این شیوه نمایه‌سازی استفاده کنند.

امکان سنجی به کارگیری قاعده‌های دهگانه در الگوریتم‌های نمایه‌سازی یا بازیابی مدارک. با به کارگیری این قاعده‌ها در سامانه‌های بازیابی می‌توان روند نمایه‌سازی خودکار را قاعده‌مند رو به تبع آن روند بازیابی مدارک را بهبود بخشد. به عنوان مثال، با به کارگیری قاعده دودر الگوریتم‌های نمایه‌سازی می‌توان به مدرک شامل واژه «آب بندی» دیگر شکل‌های نگارشی آن، از جمله «آبیندی» و «آب بندی» را هم به طور خودکار اضافه کرد و به این شکل باعث گسترش نمایه در پایگاه اطلاعات علمی فارسی شد.

به کارگیری قابلیت «پیشنهاد واژگان جستجو» در پایگاه‌های اطلاعات علمی فارسی. این راهکار در حال حاضر توسط گوگل و همچنین برخی پایگاه‌های اطلاعاتی فارسی مورد استفاده قرار می‌گیرد و تا اندازه‌ای توانسته است به نزدیک تر کردن رفتار نگارشی کاربران با نگارندگان پایگاه‌های اطلاعاتی و در نتیجه بهبود جامعیت نتایج کمک کند.

پیشنهادهای پژوهشی

- پیشنهاد می‌شود در پژوهشی مشابه با استفاده از روش استفاده شده در این پژوهش، به بررسی موتورهای کاوش (فارسی / غیرفارسی) از نظر میزان توجه به چالش‌های پیوسته‌نویسی و جدانویسی در زبان و خط فارسی انجام گیرد؛

- با توجه به تشابه و نزدیکی خط فارسی و عربی، پیشنهاد می‌شود در پژوهشی به بررسی پایگاه‌های اطلاعاتی عربی پرداخته شود. با انجام این پژوهش می‌توان به مقایسه میزان توجه، استفاده از راهکارهای احتمالی و همچنین الگوبرداری از پایگاه‌های اطلاعاتی عربی پرداخت.

منابع

- آخشیک، سمیه سادات و فتاحی، رحمت الله (۱۳۹۱). «تحلیل چالش‌های پیوسته نویسی و جدا نویسی واژگان فارسی در ذخیره و بازیابی اطلاعات در پایگاه‌های اطلاعاتی»، کتابداری و اطلاع رسانی، (۳)، ۳۵-۹.
- اکبری نژاد، سعید (۱۳۷۶). «فاصله خالی میان واژه‌ها در ذخیره و بازیابی رایانه‌ای اطلاعات». مطالعات ملی کتابداری و سازماندهی اطلاعات، ۱(۸)، ۴۹-۵۶.
- حری، عباس (۱۳۷۲). «کامپیوتوریسم الخط فارسی». تحقیقات اطلاع رسانی و کتابخانه‌های عمومی، ۱(۳)، ۱۱-۶.
- دلاور، علی (۱۳۹۰). احتمالات و آمار کاربردی در روانشناسی و علوم تربیتی. تهران: رشد.
- راثی، محمد صابر (۱۳۸۵). «مشکلات جست و جو و بازیابی اطلاعات به زبان فارسی در اینترنت، مطالعه موردی: کاربران مرکز اینترنت دانشگاه آزاد اسلامی واحد شبستر»، مطالعات ملی کتابداری و سازماندهی اطلاعات، ۱(۱۷)، ۱۷۹-۱۹۶.
- رمضانی، مریم (۱۳۸۶). بررسی مشکلات رسم الخط فارسی در بازیابی منابع از وب از دیدگاه کاربران و رائمه راه حل برای این مشکلات (پایان نامه کارشناسی ارشد)، دانشکده دانشگاه الزهرا، دانشکده علوم تربیتی و روانشناسی، تهران.
- سردم، زهره؛ بازگان، عباس و حجازی، الهه (۱۳۹۵). روش‌های تحقیق در علوم رفتاری، تهران: آگه، ۱۳۹۵.
- عبدالهی، محمد صادق و جوکار، عبدالرسول (۱۳۸۸). «چالش‌های شیوه نگارش زبان فارسی در بازیابی اطلاعات از موتورهای کاوش وب». مطالعات تربیتی و روان شناسی، ۱۰(۲)، ۱۸۰-۲۰۱.
- فرهنگستان زبان و ادب فارسی. (۱۳۸۹). دستور خط فارسی. تهران: فرهنگستان زبان و ادب فارسی، گروه نشر آثار.
- قدس نیا، پدرام؛ زارع بیدکی، علی محمد و یزدانی، ناصر (۱۳۸۶). «بررسی آماری تأثیر برخی از مشکلات زبان فارسی بر جامعیت نتایج جستجو در موتورهای جستجو»، مقاله ارائه شده در سیزدهمین کنفرانس سالانه انجمن کامپیوترا ایران.
- کاشفی، امید؛ نصری، میترا و کنعانی، کامیار (۱۳۸۹). خطایابی املایی خودکار در زبان فارسی، (شورای عالی اطلاع رسانی). تهران: شورای عالی اطلاع رسانی، دبیرخانه.

- گل‌تاجی، مرضیه و بذرگر، سعیده (۱۳۸۹). بررسی مشکلات ریخت شناسی زبان فارسی در سه پایگاه اطلاعاتی مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری پژوهشگاه اطلاعات و مدارک علمی ایران و جهاد دانشگاهی. *کتابداری و اطلاع‌رسانی*، ۵۰، ۱۹۹-۲۲۲.
- مرتضایی، لیلا (۱۳۸۰). مسائل زبان و خط فارسی در ذخیره سازی و بازیابی اطلاعات، پژوهشنامه پردازش و مدیریت اطلاعات، ۲۱-۲، ۲۴-۲۹.
- ولیخانی، احمد و سرافراز؛ مهدی‌رضا (۱۳۹۴). روش تحقیق در روانشناسی. تهران: بینش نو.
- هماوندی، هدی؛ نوروزی، یعقوب و حسینی‌بهشتی، ملوک‌السادات (۱۳۹۷). «بررسی مشکلات جستجو و بازیابی اطلاعات در پایگاه‌های اطلاعاتی از جنبه ویژگی‌های نگارشی زبان فارسی»، پژوهشنامه پردازش و مدیریت اطلاعات، ۳۳، ۹۹-۱۰۹.
- یوسفی، احمد (۱۳۷۶). «ریزش کاذب در ذخیره و بازیابی اطلاعات»، پژوهشنامه پردازش و مدیریت اطلاعات، ۱۲، ۱-۹.

- Danesh, M.; Minaei, B.; & Kashefi, O. (2011). Challenging Massive Information Retrieval in Persian. *International Journal of Information and Education Technology*, 1(3), 212.
- Hammo, B. H. (2009). Towards enhancing retrieval effectiveness of search engines for diacritized Arabic documents. *Information Retrieval*, 12 (3), 300-323.
- Lazarinis, F. (2007). At the sharp END evaluating the searching capabilities of commerce websites in a non-English language A Greek case study. *Online Information Review*, 31 (6), 881-891.
- Lewandowski, D. (2008). Problems with the use of Web search engines to find results in foreign languages. *Online Information Review*, 32 (4), 668-672.
- Zhang, J.; & Lin, S. (2007). Multiple language supports in search engines. *Online Information Review*, 31 (4), 532-516.