

Investigating the Effectiveness of Semantic Tagging in Sense Disambiguation of Specialized Homographs from the Perspective of F-Measure in Retrieving Scientific Texts

Mina Rezaei Dinani

PhD in Knowledge and Information Science; Alzahra University; Tehran, Iran Email: mina.rezaei.d@gmail.com

Iranian Journal of
**Information
Processing and
Management**

Received: 18, Dec. 2021 | Accepted: 13, Apr. 2022

Abstract: The aim of this study was to explain the application of text corpus tagging method in sense disambiguation from specialized homographs and increasing the retrieval F-Measure of scientific texts containing such homographs.

This is an experimental study. Specialized homographs were identified by direct observation and morphological analysis of the word. The research sample consisted of 442 scientific articles of two groups of experimental group and control group. The control group had 221 full-text articles without tags and the experimental group had same the 221 tagged articles, which were tested in the information retrieval system to measure the effectiveness of tagging in word sense disambiguation from specialized homographs.

The level of significance of the Wilcoxon signed-rank test showed that the F-Measure of retrieval results of specialized homographs after using the tagged specialized text corpus in the information retrieval system is significantly different than before. Examination of negative and positive rankings showed that the F-Measure of the results after using the tagged specialized text corpus has increased significantly and has reached its maximum level of 1.

The findings of the present study showed that there is not necessarily an inverse relationship between recall and precision, and the two can reach their maximum level of 1. The better efficiency of the retrieval system using this approach is due to the empowerment of the retrieval system in distinguishing between specialized homographs and identifying their semantic roles by using semantic tags as training data that were considered in the test and training set. Embedding the training set in the structure of the retrieval system provides additional information to serve the retrieval system to distinguish between the various meanings

Iranian Research Institute

for Information Science and Technology
(IranDoc)

ISSN 2251-8223

eISSN 2251-8231

Indexed by SCOPUS, ISC, & LISTA

Vol. 38 | No. 2 | pp. 457-482

Winter 2023

<https://doi.org/10.35050/IJPM010.2022.031>



of specialized homographs. This tool is one of the elements that causes the optimal quality of retrieval and leads the information retrieval system from word-driven retrieval to content-driven retrieval when retrieving texts containing specialized homographs.

Keywords: Specialized Homograph, Information Retrieval, Tagging, Text Corpus, F-Measure



واکاوی تأثیر برچسب گذاری معنایی در ابهام زدایی هم‌نویسه‌های تخصصی از نظر کیفیت بازیابی (معیار F) در بازیابی متون علمی

مینا رضایی دینانی

دکتری علم اطلاعات و دانش‌شناسی؛
گروه علم اطلاعات و دانش‌شناسی؛ دانشگاه الزهراء؛
تهران، ایران | mina.rezaei.d@gmail.com



دریافت: ۱۴۰۰/۰۹/۲۲ پذیرش: ۱۴۰۱/۰۱/۲۴ مقاله برای اصلاح به مدت ۲۸ روز نزد پدیدآوران بوده است.

نشریه علمی | رتبه بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایرانداک)

شاپا (چاپی) ۲۲۵۱-۸۲۲۳

شاپا (الکترونیکی) ۲۲۵۱-۸۲۳۱

نماده در SCOPUS، ISC، LISTA، و

jipm.irandoc.ac.ir

دوره ۳۸ | شماره ۲ | صص ۴۵۷-۴۸۲

زمستان ۱۴۰۱

<https://doi.org/10.35050/JIPM010.2022.031>



چکیده: با توجه به نقش مهم و تعیین‌کننده واژگان تخصصی در مسیریابی دقیق و کامل پژوهش‌های علمی، هدف از پژوهش حاضر تبیین میزان اثربخشی برچسب گذاری معنایی در رفع ابهام هم‌نویسه‌های تخصصی و کیفیت بازیابی حاصل از آن بود. این پژوهش از حیث هدف، کاربردی و از حیث روش‌شناسی، از نوع کاربردشناسی تجربی یا پیکره‌ای است و روشی بانظارت محسوب می‌شود. از جمله فنون پردازش زبان طبیعی که برای دستیابی به هدف پژوهش به کار گرفته شد، تحلیل ریخت‌شناسی و برچسب گذاری معنایی هم‌نویسه‌های تخصصی بود. جامعه پژوهش را ۴۴۲ مقاله علمی در قالب دو گروه کنترل و آزمون تشکیل دادند. گروه کنترل دارای ۲۲۱ متن کامل مقاله بدون برچسب و گروه تجربی دارای همان ۲۲۱ مقاله، اما این بار برچسب گذاری شده بود که در نظام بازیابی اطلاعات برای تبیین اثربخشی برچسب گذاری معنایی در ابهام‌زدایی هم‌نویسه‌های تخصصی و کیفیت بازیابی متون علمی آزموده شدند. سطح معناداری آزمون «ویلکاکسون» نشان داد که میزان کیفیت بازیابی نتایج بعد از به کارگیری پیکره تخصصی برچسب گذاری شده نسبت به قبل از آن، تفاوت معناداری دارد. بررسی رتبه‌های منفی و مثبت نشان داد که این میزان به‌طور معناداری افزایش یافته و به حد بیشینه آن یعنی ۱ رسیده است. به عبارت دیگر، در روش آزموده‌شده این پژوهش، فراخوانی و دقت که هر دو در تعیین میزان کیفیت بازیابی (معیار F) تأثیر دارند، در حد بهینه آن یعنی ۱ به‌دست آمد. از یافته‌های پژوهش حاضر چنین

برمی‌آید که لزوماً بین فراخوانی و دقت، رابطه معکوس وجود ندارد و این دو می‌توانند به موازات یکدیگر به حد بیشینه خود برسند. کارایی بهتر نظام بازیابی با استفاده از این رویکرد به دلیل تجهیز نظام بازیابی به برجسب‌های موضوعی و در نتیجه آن، توانمندسازی این نظام به تمایز موضوعی هم‌نویسه‌های تخصصی است. تعبیه مجموعه آموزش در ساختار نظام بازیابی، اطلاعات افزوده‌ای را فراهم می‌کند تا در خدمت نظام بازیابی برای تمایز بین معانی متعدد هم‌نویسه‌های تخصصی قرار گیرد. این ابزار، یکی از عناصری است که کیفیت بهینه بازیابی را موجب می‌شود و نظام بازیابی اطلاعات را هنگام بازیابی متون دارای هم‌نویسه‌های تخصصی از بازیابی واژه‌محور به سمت بازیابی محتوامحور سوق می‌دهد.

کلیدواژه‌ها: هم‌نویسه تخصصی، بازیابی اطلاعات، برجسب‌گذاری، پیکره متنی، معیار F

۱. مقدمه و طرح مسئله

بی‌تردید هر نظام بازیابی اطلاعات برای استفاده کاربران آن، طراحی و ساخته می‌شود و همواره نیاز کاربران و خشنودی آن‌ها، از اولویت‌های اصلی در طراحی محسوب می‌شوند (منصوریان ۱۳۸۲). اما ماهیت ساختاریافته و حجم روبه‌افزایش اطلاعات قابل دسترس، بازیابی اطلاعات مرتبط را برای کاربران با سختی مضاعف مواجه ساخته و فناوری کنونی در محیط وب قادر نیست فرایندهای جست‌وجوی پیچیده و منسجم را اجرا و پردازش اطلاعات را به گونه‌ای مؤثر تسهیل کند. افزون بر این، تنوع گسترده و پراکندگی بیش از حد اطلاعات، افزایش فراوان محتوای وب و خاصیت گمراه‌کننده پیوندهای موجود در ردیابی حیطه‌های دانشی خاص، مشکلاتی را در زمینه مکان‌یابی اطلاعات یا دانش از طریق فرایند جست‌وجو و تورق به وجود آورده است (کفاشان و فتاحی ۱۳۹۰).

روش مبتنی بر کلیدواژه از روش‌های متداول در بازیابی متون علمی است و پژوهشگران هنگام بازیابی متون علمی به‌طور معمول از اصطلاح‌های تخصصی به‌عنوان کلیدواژه مورد جست‌وجو استفاده می‌کنند، اما چنین روشی برای مفهوم‌سازی نیاز و منظور کاربر کافی نیست. از آنجا که این اصطلاح‌ها برای ارتباط علمی و انتقال صحیح اطلاعات به کار گرفته می‌شوند، چنانچه دچار هرج‌ومرج و نابسامانی شوند، زبان تفهیم و تفاهم و جریان درست اطلاعات مختل می‌شود (مرتضایی ۱۳۸۱). نمونه‌ای از این هرج‌ومرج و نابسامانی در بازیابی مبتنی بر کلیدواژه، هم‌نویسگی اصطلاح‌های تخصصی است. هم‌نویسه‌ها آن

۱. در این پژوهش از بین سه واژه مترادف هم‌نویسه، هم‌نگاره و جناس تام، واژه هم‌نویسه برای پرداختن به موضوع به کار رفته است.

دسته از کلمات چندمعنا هستند که به صورت یکسان نوشته می‌شوند؛ یعنی واژگانی که شکل نوشتاری یکسان، اما معنای متفاوتی از همدیگر دارند (Hearst 1991). معنای این قبیل واژه‌ها، تنها وقتی در متن قرار گیرند، با توجه به بافت موضوعی و زمینه^۱ قابل تشخیص است. شوربختانه، به‌رغم اهمیت این موضوع، تطبیق اصطلاحنامه‌ها نشان می‌دهد که هم‌نویسه‌های تخصصی زیادی در رشته‌های علمی مختلف وجود دارد. این هم‌نویسه‌ها شکل نوشتاری یکسانی دارند، اما از مفهوم و تعریف منحصر به آن رشته برخوردارند. در حالی که یک متخصص ممکن است بتواند به لطف سوابق حرفه‌ای خود معنای صحیح هم‌نویسه را در یک مقاله علمی تعیین کند، برای ماشین، شناسایی معنای یک هم‌نویسه تخصصی به سادگی انسان نیست و روش‌های خودکار بازایی اغلب بدون داشتن چنین دانشی نمی‌توانند اصطلاحات را به درستی از هم تفکیک کنند (Prokofyev et al. 2013). در این صورت، ابهام معنایی که به وجود می‌آید، ناشی از توافق نداشتن عوامل دخیل در یک ارتباط بر سر اصطلاح‌هاست و پیچیدگی فزاینده و کاهش کیفیت بازایی (معیار F) اطلاعات را در پی خواهد داشت. «پرچنر و گوش» معتقدند که حتی اگر تفکیک مدارک مرتبط از غیرمرتبط بیش از یک ثانیه طول نکشد، گردش کار کاربر را به‌طور قابل توجهی مختل می‌کند و این آزاردهنده است (Pretschner & Gauch 1999). واژگان کنترل‌شده یکی از روش‌های غلبه بر بعضی از شدیدترین موانع پرس‌وجوهای کلیدواژه‌ای هستند (کریمی، بابایی و حسینی بهشتی ۱۳۹۸). برگرداندن زبان طبیعی مدارک به زبان کنترل‌شده باعث انطباق نظرات کاربران و تولیدکنندگان اطلاعات می‌شود و حداکثر اطلاعات با کمترین هزینه، نیرو، زمان و بیشترین دقت، ذخیره، سازمان‌دهی و بازایی می‌شوند (حسینی بهشتی، وفایی و نوروزی اقبالی ۱۳۹۳، ۹۶).

در این راستا فنون رفع ابهام معنایی^۲ از هم‌نویسه‌ها، نیاز به منابع ویژه و قابل توجه زبانی دارد و دانش، یک مؤلفه پایه برای رفع ابهام معنایی است. از جمله منابع دانش برای رفع ابهام معنایی، اصطلاحنامه‌ها، سرعنوان‌های موضوعی^۳، وب معنایی^۴ و پیکره‌ها^۵ هستند. برچسب‌زنی موضوعی متون پیکره، امری مهم در حوزه بازایی اطلاعات و نوعی دسته‌بندی یا طبقه‌بندی در زبان طبیعی است که به‌عنوان ابزار کمکی به نظام بازایی

1. context

2. word sense disambiguation (WSD)

3. subject headings

4. semantic web

5. corpus

اطلاعات در ابهام‌زدایی از معنای واژگان کمک می‌کند. از طریق این نوع برچسب‌گذاری، طبقه‌ها یا ویژگی هم‌نویسه‌ها مشخص شده و از همدیگر متمایز می‌شوند. بنابراین، برای کمک به کاربر لازم است نظام بازیابی خودکار اطلاعات به الگوریتم‌ها و فنون خودکار در ذخیره و پردازش اسناد مجهز شود تا در موقع بازیابی اسناد با استفاده از آن‌ها به بازیابی دقیق‌تر بپردازد. چنانچه ابزارهای فناورانه سازماندهی دانش به‌خوبی انتخاب، تأمین و اجرا شوند، مبنایی جامع در راستای دسترسی سریع به دانش، کسب بازخورد و رضایت کاربر تلقی خواهند شد (کفاشان و فتاحی ۱۳۹۰).

برای ارزیابی اثربخشی یک نظام بازیابی اطلاعات، تعیین مجموعه استاندارد آزمون، اصول خود را دارد و تاریخ آن به اوایل دهه ۱۹۵۰ برمی‌گردد. در طول بیش از ۶۰ سال از شروع آن، استفاده از مجموعه‌های آزمون به استاندارد عملی ارزیابی بدل شده است (حریری و همکاران ۱۳۹۳). بیشتر پژوهش‌های منتشرشده در زمینه بازیابی اطلاعات، با استفاده از مجموعه آزمون و معیارهای ارزیابی مرتبط، اثربخشی آن را ارزیابی کردند (Sanderson 2010). معیارهای سنجش ربط در نظام‌های بازیابی اطلاعات رتبه‌بندی‌نشده، دقت، فراخوانی و معیار F^1 است (حریری و همکاران ۱۳۹۳).

معیار F ، نخستین بار در سال ۱۹۷۴ توسط «رایزبرگن» ارائه شد. این ضریب، پارامتر مناسبی برای ارزیابی کیفیت بازیابی است و میانگین متوازن دو کمیت دقت و فراخوانی را محاسبه می‌کند (Sasaki 2007). «شوتز» بر این عقیده است که معیار F ، دقت و فراخوانی را تعدیل می‌کند (Schutze 2014) و «کسلر» آن را ترکیبی از معیارهای دقت و فراخوانی می‌داند (Kessler 2012).

مسئله‌ای که این پژوهش به آن پرداخت، تعیین میزان تأثیری است که استفاده از برچسب‌گذاری بر ابهام‌زدایی معنایی هم‌نویسه‌های تخصصی و کیفیت بازیابی حاصل از آن (معیار F) دارد. به‌عبارت دیگر، پژوهش حاضر به‌منظور پاسخگویی به این سؤال طرح‌ریزی شد که آیا میان میزان کیفیت بازیابی (معیار F) متون علمی، قبل و بعد از برچسب‌گذاری هم‌نویسه‌های تخصصی در نظام بازیابی اطلاعات تفاوت معناداری وجود دارد؟ برای پاسخ به مسئله پژوهش از روش رفع ابهام معنایی نظارتی^۳ استفاده شد. در این روش، معانی به‌عنوان برچسب‌های مجزایی تلقی می‌شوند (Kumar et al. 2019). از ملزومات

1. F-Measure

2. Rijsbergen

3. supervised

روش نظارتی، مجموعه‌ای از هم‌نویسه‌های تخصصی به همراه برجسب‌هایشان است که به‌عنوان مجموعه آموزش استفاده شد. از دیگر تسهیلات برای ابهام‌زدایی معنایی از هم‌نویسه‌های تخصصی، امکان استفاده از انبوه داده‌های متنی در قالب پیکره محقق‌ساخته است که مجموعه آزمون را تشکیل دادند. مجموعه آموزش و آزمون در مسیر پژوهش به کار گرفته شدند تا تأثیر برجسب‌گذاری معنایی بر توانمندی نظام بازایی در تمایز بین هم‌نویسه‌های تخصصی و میزان کیفیت بازایی متون علمی آشکار شود.

۲. پیشینه پژوهش

در جامعه اطلاعاتی ایران با وجود تلاش‌های صورت گرفته، بازایی و استفاده از اطلاعات علمی و فنی با معضل‌ها و کمبودهای جدی روبه‌رو است. بخشی از این مشکلات به آشفتگی‌هایی که در مرحله تولید اطلاعات وجود دارد و بخشی دیگر به نابسامانی‌هایی که در مرحله ذخیره‌سازی اطلاعات به‌وجود می‌آید، مربوط می‌شود (حسینی بهشتی ۱۳۹۳، ۹۶). تاکنون در ایران، پژوهشگران به مطالعه واژگان دانشگاهی فارسی آن‌گونه که لازم است، توجه نکرده‌اند. از چالش‌ها و موانع پیش روی مطالعه در این زمینه می‌توان کمبود پیکره‌های لازم، نبود مشوق‌های پژوهشی، کمبود ادبیات و پیشینه پژوهش و کم توجهی مسئولان ذی‌ربط را برشمرد (غفارثمر، شیرازی‌زاده و کیانی ۱۳۹۴). از جمله معدود آثار واژه‌پژوهی متون دانشگاهی با رویکرد پیکره‌بنیاد، پژوهش «ذوالفقار کندی» و همکاران است که در آن با استفاده از روش بسامدشماری در پیکره متون پزشکی به استخراج خودکار واژگان پایه علوم پزشکی مبادرت نمودند (۱۳۹۹).

«هرست» در پژوهش خود برای پیاده‌سازی الگوریتم مورد نظر، ابتدا مجموعه کوچکی به‌صورت دستی برجسب‌گذاری نمود و از یک فهرست شامل مجموعه‌ای از ویژگی‌های ابهام‌زدایی لغوی، املائی و نحوی موجود در بافت استفاده کرد. یافته‌های پژوهش تأثیر مستقیم این ویژگی‌ها را در رفع ابهام معنایی هم‌نویسه‌ها اثبات کرد (Hearst 1991).

«گیل، چرچ و یاروسکی» در پژوهش خود روشی را برای تفکیک و تمایز معنای اسامی که دارای تعدد معنا هستند، طراحی کردند. این یک روش کمی تفکیک‌پذیر است که میزان دقت آن تا ۹۲ درصد برآورد شده است (Gale, Church & Yarowsky 1992).

«تسپراسیت، چارونپورساوات و سورلر تاموانیچ» از فن یادگیری ماشین به نام «وین‌ناو»^۱ به منظور تعیین مرز کلمات و رفع ابهام هم‌نویسه‌ها استفاده کردند. آن‌ها در این فن از بافتار (واژگان و برجسب‌های) اطراف هم‌نویسه برای رفع ابهام بهره بردند. نتایج نشان داد که رفع ابهام هم‌نویسه‌های تابا استفاده از بافتار به مراتب دقیق‌تر است (Tesprasit, Charoenpornasawat & Sornlertlamvanich 2013).

«کریم‌پور» و همکاران در پژوهش خود دریافتند که برجسب‌زنی اجزای کلام و ریشه‌یابی به‌طور هم‌زمان می‌تواند دقت نتایج بازیابی را به‌طور قابل توجهی افزایش دهد (Karimpour et al. 2005).

«فانژو، کین و تائو» یک الگوریتم هیبرید به نام یادگیری مبتنی بر تبدیل هدایت‌شده^۲ درختی^۳ که ترکیبی از درخت تصمیم و یادگیری مبتنی بر تبدیل^۳ است، برای رفع ابهام معنایی هم‌نویسه‌ها معرفی کرده‌اند. آن‌ها دریافتند که TTBL به‌طور قابل توجهی بهتر از درخت تصمیم عمل می‌کند (Fangzhou, Qin & Tao 2008).

«شن» و همکاران در پژوهش خود الگوریتم‌های نیمه‌نظارتی و یادگیری فعال را معرفی کردند که قادرند رفع ابهام هم‌نویسه‌ها را با استفاده از داده‌های بدون برجسب انجام دهند. نتایج پژوهش نشان داد که این روش، هزینه‌های برجسب‌گذاری دستی را تا حد زیادی کاهش می‌دهد، اما کارایی آن همچنان حفظ می‌شود (Shen et al. 2011). «منای» رویکرد رایانش تکاملی را برای مسئله ابهام معنایی واژگان پیشنهاد می‌کند. وی الگوریتم ژنتیک را برای حل این مسئله در زبان عربی پیشنهاد داده است. نتایج پژوهش، دقت پیش‌بینی نتایج را تا ۷۹ درصد نشان داد (Menai 2014).

«سعید» و همکاران پیکره‌ای شامل ۵۰۴۲ کلمه اردو از پیکره^۴ «اورمونو»^۴ را که دارای ۸۵۶ کلمه مبهم بود، به‌صورت دستی و به کمک فرهنگ لغت «اردو»، برجسب‌گذاری کردند. سپس، تعدادی از مدل‌های ابهام‌زدایی معنایی کلمه بر اساس n-gram بر روی پیکره اعمال شد و دقت ۵۷/۷۱ درصد با استفاده از مدل 4-gram به‌دست آمد (Saeed et al. 2019).

«رحمان و بورا» در پژوهش خود روش جدیدی برای تعیین معنای کلمه در یک جمله ارائه دادند. ایشان در روش خود از فرهنگ لغت نحوی «وردنت» و «ویکی‌پدیا» استفاده

1. Winnow

2. tree-guided transformation-based learning (TTBL)

3. transformation-based learning (TBL)

4. UrMono

کردند. آن‌ها ابتدا، معانی محتمل کلمه را از فرهنگ لغت شناسایی کردند و سپس، با محاسبه امتیاز رخداد باهم‌آیی کلمات با یکدیگر در جمله، امتیاز باهم‌آیی دو کلمه را در «ویکی‌پدیا» محاسبه کردند. این روش بر روی واژه‌های انگلیسی «وردنت» انجام شد. تحلیل تجربی و محاسبه معیار F با استفاده از آزمون «ویلکاکسون»، اهمیت رویکرد پیشنهادی را نسبت به روش‌های پایه و موجود نشان داد (Rahman & Borah 2021).

«سلطانی و فیلی» در پژوهش خود از پیکره متنی بدون برچسب و گراف وابستگی معنایی استفاده کردند و بیان داشتند که این راهکار مناسبی برای افزایش کارایی و دقت بازایی است و با استفاده از وابستگی معنایی می‌توان از کلمات چندمعنا رفع ابهام نمود (۱۳۸۷).

«معروفی و پله‌ور» روش‌های مبتنی بر پیکره و قاموس را بررسی نمودند. نتایج پژوهش آن‌ها نشان داد که الگوریتم پیشنهادی با افزودن فاکتور ارتباطی میان دسته‌بندی موضوعی متن و استفاده از واژگان پیرامونی کلمه، دقت بیشتری نسبت به الگوریتم اولیه در رفع ابهام معنایی ۱۵ کلمه دارد (۱۳۹۰).

«صدقی» در پایان‌نامه خود برای رفع ابهام هم‌نویسه‌ها از پیکره‌ای کوچک استفاده کرد. وی با استفاده از الگوریتم لیست تصمیم بر واژگان پیرامون هم‌نویسه - که هم‌رخداد نامیده می‌شوند- در پیکره آموزشی متمرکز شد و در پژوهش خود دریافت که استفاده از الگوریتم لیست تصمیم، دقت بازایی را ۲ تا ۳ درصد افزایش می‌دهد (۱۳۹۲).

«عرب» در پایان‌نامه خود سعی در بهبود عملکرد الگوریتم ابهام‌زدایی معنایی داشت. وی از یک روش بدون نظارت بر پایه گراف معنایی کلمات استفاده کرد و توانست با استفاده از مدل فضای برداری، تأثیر مثبت غنی‌سازی موضوع را در تعیین معنای نهایی واژه به اثبات رساند (۱۳۹۴).

«مسعودی و راحتی قوچانی» در پژوهش خود مدلی برای رفع ابهام از واژگان مبهم فارسی با استخراج ویژگی‌های جدید ارائه دادند. آن‌ها در مدل پیشنهادی، برای رفع ابهام از روش دسته‌بندی پیشینه بی‌نظمی استفاده کرده و دقت رفع ابهام معنایی واژگان مبهم را ۹۷ درصد تخمین زدند (۱۳۹۴).

«خیرمند پاریزی و نورمندی‌پور» طی پژوهش خود با هدف ارزیابی رویکرد نظارت‌شده الگوریتم‌های IBL در رفع ابهام معنایی واژگان فارسی، آن را برای ابهام‌زدایی معنایی به کار بردند. روش معرفی‌شده ایشان، صحت روش یادگیری نظارتی مبتنی بر نمونه را تا ۸۸/۳۱ درصد نشان دادند (۱۳۹۵).

«مظفری» و همکاران در پژوهش خود سامانه‌ای قاعده‌مند برای رفع ابهام معنایی از حروف اضافه (از، در، با، تا) در زبان فارسی پیشنهاد دادند. نتایج آزمایش داده‌ها دقت بالای عملکرد سامانه ۹۹/۱۶ درصد را در رفع ابهام معنایی این حروف اضافه نشان داد (۱۳۹۶).

«ستوده و هوشیار» در پژوهش خود برای ابهام‌زدایی معنایی هم‌نویسه‌ها به مقایسه پنج بافتار متنی شامل استناد متنی، ارجاع، عنوان ارجاع، عنوان و متن مقاله پرداختند. ایشان دریافتند که بافتار متن و عنوان ارجاع، نقش معناداری در بهبود نتایج بازیابی دارند (۱۳۹۷).

«علایی ابوزر» در پژوهش خود رویکردی ماشینی جهت رفع ابهام از معنای کلمات با استفاده از برجسب‌زنی نحوی و الگوریتم «لسک» معرفی نمود. طبق یافته‌های پژوهش وی، برجسب‌دهی نحوی و رفع ابهام از برجسب نحوی هم‌نویسه‌ها باعث می‌شود که الگوریتم «لسک»، تنها معانی مرتبط با برجسب‌های نحوی را در رفع ابهام معنایی کلمات در نظر گیرد و در نتیجه، عمل رفع ابهام از معنای کلمات با دقت و سهولت بیشتری انجام پذیرد (۱۳۹۷).

«انبایی فریمانی، طباطبایی و کفاشان کاخکی» در مقاله‌ای تأثیر استفاده از پیکره را در شناسایی مفهوم پنهان بررسی نمودند. یافته‌های پژوهش نشان داد که استفاده از الگوریتم نزدیک‌ترین K همسایه و معیار شباهت واگرایی «کولبک لیبلر»، صحت سازماندهی را به مقدار ۸۲/۵ درصد می‌رساند. این روش، پیچیدگی فرایند سازماندهی و بازیابی متون مورد مطالعه پژوهش را تقلیل داده است (۱۳۹۸).

«علی‌پوری حافظی، مولودی و بیات» در پژوهش خود با رویکرد پیکره‌بنیاد رفع ابهام معنایی از واژگان هم‌آوا-هم‌نویسه زبان فارسی را با بهره‌گیری از همایندهای آن‌ها بررسی کردند. آن‌ها با روش تحلیل محتوا، هم‌نویسه «گور» را انتخاب و در پیکره «همشهری»

نسبت به رفع ابهام آن اقدام کردند. یافته این پژوهش نشان داد که امکان رفع ابهام معنایی از واژگان هم‌نویسه با استفاده از همانندهای آن‌ها وجود دارد (۱۳۹۸).

مرور پیشینه‌ها نشان می‌دهد که بیشتر رویکردهای رفع ابهام معنایی بر مفاهیم اسمی تمرکز دارند و کمتر به رفع ابهام معانی سایر واژگان پرداخته‌اند. این مسئله به‌ویژه در زبان‌هایی که فقر داده آموزشی و منابع آموزشی کمتری دارند -مانند زبان فارسی- به مراتب بیشتر است.

در پژوهش‌های مطالعه‌شده از روش‌های مختلف نظارتی، بدون نظارت، و نیمه‌نظارتی شامل الگوریتم‌ها و تکنیک‌های یادگیری ماشینی، رهیافت‌های مبتنی بر آمار، مانند استفاده از پیکره برجسب‌خورده و رهیافت‌های غیرآماری، مانند روش‌های مبتنی بر قانون استفاده شده است. بنابراین، می‌توان گفت اگرچه برخی از این پیشینه‌ها الگوریتم‌های رفع ابهام معنایی از هم‌نویسه‌ها و اسامی را برای بهینه‌سازی نتایج جست‌وجو ارائه داده‌اند، اما تعداد پیشینه‌هایی که با روش رفع ابهام معنایی نظارتی به موضوع هم‌نویسه‌ها پردازند، اندک بوده و در بررسی دقیق‌تر معلوم شد که تاکنون پژوهشی که به موضوع واژگان تخصصی متون علمی و به‌طور ویژه ابهام معنایی هم‌نویسه‌های تخصصی و دانشگاهی و به‌طور مشخص، هم‌نویسه‌های تخصصی فارسی، رویکرد پیکره‌مدار داشته باشد، مشاهده نشد. بنابراین، این پژوهش پیکره‌مدار در زمره معدود مطالعات واژه‌پژوهی دانشگاهی محسوب می‌شود که به دلیل نقش مهم و تعیین‌کننده هم‌نویسه‌های تخصصی در مسیریابی دقیق و کامل پژوهش‌های علمی، به رفع چالش ابهام معنایی هم‌نویسه‌های تخصصی معطوف شده است.

۳. روش پژوهش

ماهیت چندوجهی مسئله، پژوهش حاضر را در زمره پژوهش‌های تجربی قرار می‌دهد. این پژوهش از نظر هدف، کاربردی است و رویکرد پیکره‌مدار به کاررفته در آن، آن را در زمره پژوهش‌های کاربردی پیکره‌ای یا کاربردی تجربی قرار می‌دهد.

مراحل پژوهش به این صورت بود: ابتدا با استفاده از روش کیفی از نوع اسنادی یا کتابخانه‌ای، مشاهده و مطالعه متون انجام و مفاهیم و فرایندها شناسایی و تحلیل شدند. از آنجا که برای انجام پژوهش، یک مجموعه آموزش از هم‌نویسه‌ها و یک مجموعه آزمون از متون علمی مورد نیاز بود، موضوع تحلیل‌های واژگانی مربوط به پردازش زبان

طبیعی مطرح شد. در مراحل ابتدایی به منظور شناسایی هم‌نویسه‌ها و گردآوری مجموعه آموزش، از روش مشاهده مستقیم و تحلیل واژه بهره گرفته شد. تحلیل واژه در این مرحله از پژوهش، از نوع ریخت‌شناسی هم‌نویسه تخصصی بود.

مراحل انجام پژوهش:

۱. در مرحله آموزش، تحلیلگر از مجموعه آموزش استفاده نمود تا معانی را از واژه‌های چند معنا استنتاج کند. در این پژوهش، برای تهیه مجموعه آموزش از شش اصطلاحنامه شیمی، علوم زیستی، جامعه‌شناسی، ریاضیات، علوم زمین، و فیزیک استفاده شد که از سامانه اصطلاحنامه‌های علمی و فنی «پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)»^۱ اخذ شده بودند.

با استفاده از نرم‌افزار «مایکروسافت اکسل»^۱، فایل اصطلاحنامه‌های تخصصی مذکور با همدیگر تطبیق داده شدند و موارد مشترک بین فایل‌ها به‌عنوان هم‌نویسه‌های تخصصی شناسایی و پالایش شد که شامل ۸۹۹ هم‌نویسه تخصصی تک‌واژه‌ای بود. سپس، این هم‌نویسه‌ها به همراه برجسب موضوعی تعیین شده، به‌عنوان مجموعه آموزش سامانه در مسیر^۲ مورد نظر ذخیره شد.

۲. در مرحله آزمون، تحلیلگر یک مجموعه آزمون را فراهم نمود تا با استفاده از فهرست معانی در مرحله آموزش، از معنای واژه مورد نظر رفع ابهام کند. در این پژوهش، به دلیل نوع روش جست‌وجو و برجسب‌گذاری دستی موضوعی و با هدف اطمینان از دقت فرایندها، مجموعه‌ای محدود بررسی شد. این تصمیم همچنین باعث شد که حصول نتیجه، نیازمند صرف وقت و انرژی افزون بر توان پژوهشگر نباشد. به دلیل اینکه پاسخ به پرسش پژوهش با استفاده از پیکره‌های شناخته‌شده موجود فارسی امکان‌پذیر نبود، پژوهشگر ناگزیر به ایجاد پیکره تخصصی به کمک متخصص نرم‌افزار بود. به منظور پاسخ به پرسش پژوهش، از پیکره محقق ساخته در قالب دو گروه آزمودنی شامل گروه تجربی^۳ و کنترل^۴ استفاده شد.

بنا بر آنچه گفته شد، در مرحله عملی این پژوهش با استفاده از روش تجربی دو

گروه وجود داشت:

الف) گروه کنترل، ۲۲۱ مقاله‌ای است که از شش رشته علمی ریاضیات، علوم زمین،

1. Microsoft Excel

2. directory

3. experimental group

4. control group

علوم زیستی، شیمی، فیزیک، و جامعه‌شناسی جمع‌آوری شده و به‌صورت خام در پیکره قرار گرفته و تحت آزمون اولیه برای محاسبه معیار F در وضعیت موجود قرار گرفتند.

ب) گروه تجربی، همان مقاله‌ها، اما این بار با برجسب‌های موضوعی است و برای ارزیابی تأثیر برجسب‌گذاری پیکره متنی به‌عنوان متغیر مستقل بر مقدار معیار F، به‌عنوان متغیر وابسته، تحت آزمون ثانویه برای محاسبه معیار F در روش پیشنهادی قرار گرفتند.

داده‌های زبانی نمونه پژوهش از وبگاه‌های مجله‌های علمی کشور جمع‌آوری و در پیکره گنجانده شد. سرانجام، ارزیابی و مقایسه نتایج حاصل از آزمون دو گروه کنترل و تجربی با استفاده از روش کمی پیمایشی انجام شد و داده‌ها مورد تحلیل و تفسیر قرار گرفته و یافته‌ها به‌دست آمد.

برجسب‌های موضوعی که در این پژوهش استفاده می‌شود، شامل عناوین ۶ رشته علمی است که به هم‌نویسه‌های تخصصی نمونه پژوهش در مجموعه آموزش و آزمون تعلق می‌گیرد و وابستگی علمی آن هم‌نویسه را نسبت به یک رشته خاص نشان می‌دهد؛ مانند تورم (فیزیک) یا تورم (جامعه‌شناسی).

به‌منظور تهیه پیکره، تمام اسناد نوشتاری مقاله‌ها در قالب Microsoft Word، PDF و ... به قالب txt تبدیل شدند و هم‌نویسه‌های آن‌ها شناسایی و برجسب‌گذاری آن‌ها دستی انجام شد و فایل نهایی با کدگذاری یونی‌کد (سازگار با زبان فارسی) به‌عنوان پیکره (مجموعه آزمون) در مسیر داده‌های سامانه مورد استفاده قرار گرفت.

۳. در سومین مرحله از رفع ابهام معنایی هم‌نویسه‌های تخصصی یعنی در مرحله ارزیابی، پاسخ‌های حاصل از مرحله آزمون در یک چارچوب نظارتی یا بدون نظارت ارزیابی شد.

به‌منظور پاسخ به پرسش پژوهش، قضاوت ربط نتایج بازاریابی شده توسط شش متخصص موضوعی از شش رشته علمی مورد نظر به‌صورت دودویی انجام گرفت و سپس، توسط پژوهشگر صحت‌سنجی شد. برای هر رشته علمی حداقل پنج هم‌نویسه تخصصی به‌عنوان کلیدواژه‌های جست‌وجو تعیین شدند. بدیهی

است به دلیل خاصیت گریزناپذیر هم‌نویسی و نوعی تکرار در ظاهر واژه، تعداد هم‌نویسه‌های تخصصی هر رشته از ۵ تا ۱۲ واژه متغیر بود و در مجموع، ۴۶ کلیدواژه جست‌وجو در قالب ۱۶ واژه منحصر به فرد فراهم شد. این تعداد هم‌نویسه از میان ۸۹۹ هم‌نویسه تک‌واژه‌ای گزینش شدند که از مقایسه و تطبیق اصطلاحنامه‌های شش رشته مورد نظر به دست آمد.

جدول ۱، هم‌نویسه‌های مورد نظر پژوهش را به همراه رشته‌های دربردارنده آن نشان می‌دهد.

جدول ۱. هم‌نویسه‌های انتخابی پژوهش

جرم	صفحه	پیش	پروانه	آرایه	چشمه	برگ	حلال
فیزیک	ریاضی	ریاضی	ریاضی	ریاضی	فیزیک	ریاضی	ریاضی
شیمی	شیمی	فیزیک	فیزیک	فیزیک	شیمی	علوم زمین	شیمی
علوم زمین	علوم زمین	علوم زمین	علوم زیستی	علوم زمین	علوم زمین	علوم زیستی	علوم زمین
جامعه‌شناسی	جامعه‌شناسی	علوم زیستی					
درخت	قطر	بازیابی	تورم	تقلب	دوران	یال	پلازما
ریاضی	ریاضی	فیزیک	فیزیک	فیزیک	ریاضی	ریاضی	فیزیک
علوم زمین	علوم زمین	شیمی	جامعه‌شناسی	جامعه‌شناسی	علوم زمین	علوم زمین	علوم زیستی
علوم زیستی	جامعه‌شناسی	علوم زمین					

جدول ۲، تعداد هم‌نویسه‌های تخصصی منتخب پژوهش را به تفکیک رشته‌های علمی نشان می‌دهد.

جدول ۲. تعداد هم‌نویسه‌های تخصصی منتخب پژوهش در شش رشته علمی

رشته‌ها	علوم زمین	ریاضیات	فیزیک	شیمی	علوم زیستی	جامعه‌شناسی	جمع
مقادیر	۱۲	۲۶/۱	۱۰	۲۱/۷	۹	۱۹/۵	۵
فراوانی درصد	۱۰۰	۴۶	۱۰/۹	۵	۱۰/۹	۵	۱۰/۹
فراوانی درصد	۱۰۰	۴۶	۱۰/۹	۵	۱۰/۹	۵	۱۰۰

همان‌طور که جدول ۲، نشان می‌دهد، مجموع واژگان تخصصی انتخاب شده در شش رشته علمی مورد نظر، ۴۶ واژه است، اما به دلیل همپوشانی و به عبارت بهتر هم‌نویسی آن‌ها در دو رشته، سه رشته یا چهار رشته -همچنان که جدول ۱، نشان می‌دهد- ۱۶ واژه منحصر به فرد محسوب می‌شوند.

پس از جست‌وجو توسط متخصص موضوعی در دو وضعیت موجود و پیشنهادی به‌صورت مجزا، با استفاده از فرمول‌های استاندارد زیر ضریب دقت و فراخوانی نتایج محاسبه شد.

فرمول (۱)

$$دقت^1 = \frac{\text{تعداد مدارک بازیابی شده مرتبط}}{\text{کل مدارک بازیابی شده}}$$

فرمول (۲)

$$فراخوانی^2 = \frac{\text{تعداد مدارک بازیابی شده مرتبط}}{\text{کل مدارک موجود مرتبط}}$$

به‌منظور پاسخ به پرسش پژوهش، با استفاده از محاسبات انجام گرفته برای دو معیار دقت و فراخوانی، مقدار کمیت وزن‌دار ضریب F آن نیز طبق فرمول زیر محاسبه شد.

فرمول (۳)

$$F \text{ ضریب} = 2 * \frac{\text{دقت} * \text{فراخوانی}}{\text{دقت} + \text{فراخوانی}}$$

در شرایط ایده‌آل، مقدار معیار F، برابر با ۱ و در بدترین وضعیت برابر با صفر است. مقادیر به‌دست آمده برای تعیین مقدار معیار F در دو وضعیت موجود و پیشنهادی، و بررسی تفاوت معنادار بین این مقادیر مورد استفاده قرار گرفت.

۴. تجزیه و تحلیل یافته‌ها

پاسخ به پرسش پژوهش شامل یک مرحله ارزیابی سه-بخشی بود و توسط پژوهشگر انجام شد.

در بخش اول و دوم ارزیابی، ابتدا ضریب F نتایج بازیابی هم‌نویسه‌های تخصصی رشته‌های مورد نظر در دو گروه کنترل و تجربی به‌صورت مجزا محاسبه شد. جدول‌های ۳ تا ۸ میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر پژوهش را به تفکیک شش رشته علمی در نظام بازیابی اولیه و نظام بازیابی پیشنهادی مورد مقایسه قرار می‌دهد. جدول ۳، میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر رشته زیست‌شناسی را در نظام بازیابی اولیه و نظام بازیابی پیشنهادی نشان می‌دهد.

1. precision (P)

2. recall (R)

جدول ۳. میزان کیفیت (معیار F) نتایج بازیابی شده در نمونه پژوهش رشته زیست‌شناسی در نظام بازیابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازیابی اولیه			نظام بازیابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
پیچش	۰/۲۴	۱	۰/۳۹	۱	۱	۱
پروانه	۰/۳۳	۱	۰/۵	۱	۱	۱
برگ	۰/۳۶	۱	۰/۵۳	۱	۱	۱
درخت	۰/۴	۱	۰/۵۳	۱	۱	۱
پلاσμα	۰/۴۲	۱	۰/۵۹	۱	۱	۱
مجموع	۰/۳۵	۱	۰/۵۲	۱	۱	۱

چنانکه جدول ۳، نشان می‌دهد، میانگین کیفیت (معیار F) بازیابی ۵ هم‌نویسه مورد نظر در متون زیست‌شناسی از ۰/۵۲ در نظام بازیابی اولیه به حد بیشینه آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

جدول ۴، میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر رشته ریاضیات را در نظام بازیابی اولیه و نظام بازیابی پیشنهادی نشان می‌دهد.

جدول ۴. میزان کیفیت (معیار F) نتایج بازیابی شده در نمونه پژوهش رشته ریاضیات در نظام بازیابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازیابی اولیه			نظام بازیابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
صفحه	۰/۲۷	۱	۰/۴۳	۱	۱	۱
پیچش	۰/۲۴	۱	۰/۳۹	۱	۱	۱
پروانه	۰/۳۳	۱	۰/۵۰	۱	۱	۱
آرایه	۰/۳۳	۱	۰/۵۰	۱	۱	۱
برگ	۰/۱۱	۱	۰/۲۰	۱	۱	۱
حلال	۰/۱۷	۱	۰/۲۹	۱	۱	۱
درخت	۰/۳	۱	۰/۴۶	۱	۱	۱
قطر	۰/۱۷	۱	۰/۲۹	۱	۱	۱

نظام هم‌نویسه	نظام بازیابی اولیه			نظام بازیابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
دوران	۰/۴	۱	۰/۵۷	۱	۱	۱
یال	۰/۱۸	۱	۰/۳۱	۱	۱	۱
مجموع	۰/۲۲	۱	۰/۳۶	۱	۱	۱

چنانکه جدول ۴، نشان می‌دهد، میانگین کیفیت (معیار F) بازیابی ۱۰ هم‌نویسه مورد نظر در متون ریاضیات از ۰/۳۶ در نظام بازیابی اولیه به حداکثر مقدار آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

جدول ۵، میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر رشته علوم زمین را در نظام بازیابی اولیه و نظام بازیابی پیشنهادی نشان می‌دهد.

جدول ۵. میزان کیفیت (معیار F) نتایج بازیابی شده در نمونه پژوهش رشته علوم زمین

در نظام بازیابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازیابی اولیه			نظام بازیابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
جرم	۰/۲۱	۱	۰/۳۵	۱	۱	۱
صفحه	۰/۲۳	۱	۰/۳۷	۱	۱	۱
پیچش	۰/۲۴	۱	۰/۳۹	۱	۱	۱
آرایه	۰/۳۳	۱	۰/۵۰	۱	۱	۱
چشمه	۰/۳۹	۱	۰/۵۶	۱	۱	۱
برگ	۰/۱۱	۱	۰/۲۰	۱	۱	۱
حلال	۰/۱۷	۱	۰/۲۹	۱	۱	۱
درخت	۰/۲۵	۱	۰/۴۰	۱	۱	۱
قطر	۰/۱۷	۱	۰/۲۹	۱	۱	۱
بازیابی	۰/۳	۱	۰/۴۶	۱	۱	۱
دوران	۰/۳۳	۱	۰/۵۰	۱	۱	۱
یال	۰/۴۴	۱	۰/۶۱	۱	۱	۱
مجموع	۰/۲۵	۱	۰/۴	۱	۱	۱

جدول ۵، نشان می‌دهد که میانگین کیفیت (معیار F) بازیابی ۱۲ هم‌نویسه مورد نظر در متون علوم زمین از ۰/۴ در نظام بازیابی اولیه به حداکثر مقدار آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

جدول ۶، میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر رشته جامعه‌شناسی را در نظام بازیابی اولیه و نظام بازیابی پیشنهادی نشان می‌دهد.

جدول ۶. میزان کیفیت (معیار F) نتایج بازیابی شده در نمونه پژوهش رشته جامعه‌شناسی در نظام بازیابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازیابی اولیه		نظام بازیابی پیشنهادی		ضرب F
	دقت	فراخوانی	دقت	فراخوانی	
جرم	۰/۳	۱	۱	۰/۴۶	۱
صفحه	۰/۱۹	۱	۱	۰/۳۲	۱
قطر	۰/۱۴	۱	۱	۰/۲۵	۱
تورم	۰/۴۶	۱	۱	۰/۶۳	۱
تقلب	۰/۵	۱	۱	۰/۶۷	۱
مجموع	۰/۲۶	۱	۱	۰/۴۱	۱

همان‌طور که جدول ۶، نشان می‌دهد، میانگین کیفیت (معیار F) بازیابی ۵ هم‌نویسه مورد نظر در متون جامعه‌شناسی از ۰/۴۱ در نظام بازیابی اولیه به حداکثر مقدار آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

جدول ۷، میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر رشته شیمی را در نظام بازیابی اولیه و نظام بازیابی پیشنهادی نشان می‌دهد.

جدول ۷. میزان کیفیت (معیار F) نتایج بازیابی شده در نمونه پژوهش رشته شیمی در نظام بازیابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازیابی اولیه		نظام بازیابی پیشنهادی		ضرب F
	دقت	فراخوانی	دقت	فراخوانی	
جرم	۰/۱۵	۱	۱	۰/۲۶	۱
صفحه	۰/۱۹	۱	۱	۰/۳۲	۱

نظام هم‌نویسه	نظام بازاریابی اولیه			نظام بازاریابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
چشمه	۰/۲۲	۱	۰/۳۶	۱	۱	۱
حلال	۰/۳۸	۱	۰/۵۵	۱	۱	۱
بازیابی	۰/۴	۱	۰/۵۷	۱	۱	۱
مجموع	۰/۲۵	۱	۰/۴	۱	۱	۱

چنانکه از داده‌های جدول ۷، برمی‌آید، میانگین کیفیت (معیار F) بازیابی ۵ هم‌نویسه مورد نظر در متون شیمی از ۰/۴ در نظام بازاریابی اولیه به حداکثر مقدار آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

جدول ۸، میزان کیفیت (معیار F) نتایج بازاریابی هم‌نویسه‌های مورد نظر رشته فیزیک را در نظام بازاریابی اولیه و نظام بازاریابی پیشنهادی نشان می‌دهد.

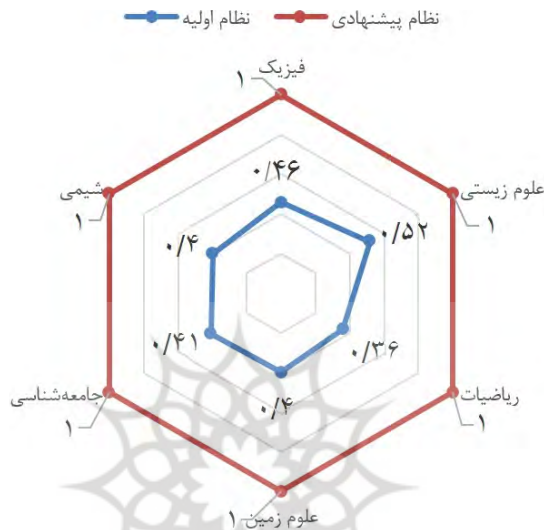
جدول ۸. میزان کیفیت (معیار F) نتایج بازاریابی شده در نمونه پژوهش رشته فیزیک در نظام بازاریابی اولیه و پیشنهادی

نظام هم‌نویسه	نظام بازاریابی اولیه			نظام بازاریابی پیشنهادی		
	دقت	فراخوانی	ضریب F	دقت	فراخوانی	ضریب F
جرم	۰/۲۱	۱	۰/۳۵	۱	۱	۱
پیچش	۰/۲۹	۱	۰/۴۵	۱	۱	۱
پروانه	۰/۳۳	۱	۰/۵۰	۱	۱	۱
آرایه	۰/۳۳	۱	۰/۵۰	۱	۱	۱
چشمه	۰/۲۶	۱	۰/۴۱	۱	۱	۱
بازیابی	۰/۲۵	۱	۰/۴۰	۱	۱	۱
تورم	۰/۳۸	۱	۰/۵۵	۱	۱	۱
تقلب	۰/۵	۱	۰/۶۷	۱	۱	۱
پلاσμα	۰/۵	۱	۰/۶۷	۱	۱	۱
مجموع	۰/۳	۱	۰/۴۶	۱	۱	۱

چنانکه از داده‌های جدول ۸، برمی‌آید، میانگین کیفیت (معیار F) بازیابی ۹ هم‌نویسه

مورد نظر در متون فیزیک از ۰/۴۶ در نظام بازیابی اولیه به حداکثر مقدار آن، یعنی ۱ در نظام پیشنهادی افزایش یافته است.

نمودار ۱، میزان معیار F بازیابی متون ۶ رشته مورد نظر پژوهش را در الگوی اولیه و پیشنهادی نشان داده و امکان این مقایسه را فراهم می‌کند.



نمودار ۱. مقایسه میزان معیار F در دو نظام اولیه و پیشنهادی

به‌طور کلی، بررسی نتایج جدول‌های ۳ تا ۸ و نمودار ۱، در مورد میزان کیفیت (معیار F) نتایج بازیابی هم‌نویسه‌های مورد نظر پژوهش به تفکیک شش رشته علمی نشان می‌دهد که به‌رغم این که در نظام اولیه مقادیر متفاوتی از میانگین معیار F به‌دست آمد، مقدار آن در نظام پیشنهادی برای هم‌نویسه‌های تخصصی متون علمی کلیه رشته‌های مورد نظر پژوهش افزایش یافته و به حد بهینه آن یعنی ۱ رسیده است. این مقدار زمانی به‌دست می‌آید که به‌طور هم‌زمان دقت و فراخوانی نتایج در حد بهینه آن یعنی ۱ حاصل شود و به آن معناست که در نظام پیشنهادی، کلیه متون بازیابی‌شده مرتبط بودند و کلیه متون مرتبط، بازیابی شده‌اند. با توجه به این که پژوهش از نوع تجربی بوده و کلیه متغیرها در کنترل پژوهشگر بودند، می‌توان این‌گونه استنباط کرد که با استفاده از رویکرد پیکره‌مدار در نظام بازیابی اطلاعات و متغیر برچسب‌گذاری معنایی هم‌نویسه‌های تخصصی، حد بهینه کیفیت بازیابی قابل دستیابی است.

در بخش سوم این ارزیابی، نتیجه حاصل از دو بخش قبلی، با استفاده از آزمون ناپارامتری یک رتبه‌های علامت‌دار «ویلکاکسون» مقایسه و به پرسش پژوهش پاسخ داده شد. نتایج آزمون «ویلکاکسون» برای مقایسه میزان کیفیت بازیابی هم‌نویسه‌های تخصصی با به کارگیری دو نظام بازیابی اولیه و پیشنهادی در جدول ۹، ارائه شده است.

جدول ۹. رتبه‌ها: مقایسه میزان کیفیت بازیابی دو نظام بازیابی

جمع رتبه‌ها	میانگین رتبه‌ها	تعداد	
۰/۰۰	۰/۰۰	۰	رتبه‌های منفی *
۱۰۸۱/۰۰	۲۳/۵۰	۴۶	رتبه‌های مثبت **
		۰	گره‌ها ***
		۴۶	جمع

$Z = -5/9.9$ ، سطح معناداری، $P = 0/0001$			

* نظام بازیابی پیشنهادی < نظام بازیابی اولیه

** نظام بازیابی پیشنهادی > نظام بازیابی اولیه

*** نظام بازیابی پیشنهادی = نظام بازیابی اولیه

سطح معناداری آزمون رتبه‌های علامت‌دار «ویلکاکسون» ($Z = -5/9.9$ ، $P = 0/0001$) در جدول ۹، نشان می‌دهد که میزان کیفیت بازیابی (معیار F) هم‌نویسه‌های تخصصی بعد از به کارگیری پیکره تخصصی برجسب‌گذاری شده در نظام بازیابی اطلاعات نسبت به قبل از آن تفاوت معناداری دارد. بررسی رتبه‌های منفی و مثبت نشان می‌دهد که کیفیت بازیابی بعد از به کارگیری پیکره تخصصی برجسب‌گذاری شده به میزان معناداری افزایش یافته است.

۵. نتیجه‌گیری

به‌طور کلی، توجه ویژه به هم‌نویسه‌های تخصصی در متون علمی و لزوم رفع ابهام معنایی از آن‌ها، نظام ذخیره و بازیابی متون علمی را دستخوش فرایندها و پردازش‌های گوناگون و بدیعی می‌سازد.

وجود تفاوت معنادار در معیار F قبل و بعد از برجسب‌گذاری هم‌نویسه‌های تخصصی نشان داد که برای غلبه بر چالش هم‌نویسگی اصطلاح‌های تخصصی، هنگام سازماندهی

اطلاعات، به کارگیری دانش موضوعی که همواره به آن تأکید شده است (Hjørland 2021)، بیش از پیش ضرورت دارد.

چنانکه (Hjørland 2021) در مقاله خود بر نقش پایایی سازماندهی و بازیابی اطلاعات در جهت تحقق یک هدف مشترک یعنی تأمین منابع مورد نیاز کاربر تأکید می‌ورزد، در پژوهش پیش‌رو نیز همسو با تأکیدات «یورلند»، ساختاری برای سازماندهی متون علمی استفاده شد تا در تسهیل و تسریع فرایندهای جست‌وجو و بازیابی هم‌نویسه‌های تخصصی، اثربخش باشد. در این پژوهش برای نیل به این هدف از فرایند برچسب‌گذاری که «یورلند» آن را به‌عنوان یکی از فرایندهای سازماندهی برمی‌شمرد و همچنین، از اصطلاحنامه‌ها که از نظر وی یکی از نظام‌های سازماندهی دانش هستند (همان)، استفاده شد تا هدف غایی KO و IR که همانا تأمین مدارک مرتبط با واژگان تخصصی مورد نظر کاربر است، محقق شود.

پژوهش حاضر با توجه به هدف و ماهیت فناوری آن، در دسته چهارم مباحث چهارگانه‌ای که «یورلند» برای KO برمی‌شمرد، یعنی توسعه پایگاه‌های اطلاعاتی (همان)، جای می‌گیرد.

در روش نظارتی که برای رفع ابهام معنایی هم‌نویسه‌های تخصصی به کار گرفته شد، از منابع دانشی مانند اصطلاحنامه‌ها و پیکره استفاده شد تا با تأمین نوعی نظارت و کنترل، زبان طبیعی را به زبان کنترل‌شده نزدیک نموده و بتوان بر چالش هم‌نویسگی اصطلاح‌های تخصصی و ابهام حاصل از آن فائق آمد.

به‌عنوان یک قانون مشخص در مورد دقت و فراخوانی، افزایش یکی با کاهش دیگری همراه است و این دو با هم رابطه معکوس دارند (Cleverdon 1962)، نقل در Sanderson 2010؛ حریری و همکاران ۱۳۹۳؛ Voorhiees and Harman 2001؛ قدس‌نیا، زارع بیدکی و یزدانی ۱۳۸۶؛ و حسینی‌بهشتی (۱۳۸۲). اما یافته‌های این پژوهش متفاوت از پژوهش‌هایی است که بر معکوس بودن رابطه دقت و فراخوانی تأکید دارند. آزمون نتایج بازیابی شده نشان داد که میزان کیفیت بازیابی (معیار F) هم‌نویسه‌های تخصصی بعد از به کارگیری پیکره تخصصی برچسب‌گذاری شده در نظام بازیابی اطلاعات نسبت به قبل از آن تفاوت معناداری دارد و به میزان معناداری افزایش یافته است. مقدار معیار F در روش استفاده‌شده، برای متون همه رشته‌های علمی مورد نظر پژوهش در حد بهینه آن، یعنی ۱ به دست آمد. به عبارت دیگر، مقدار ضریب F در این پژوهش، قانون رابطه معکوس دقت و فراخوانی

را نقض نموده و به صورت عملیاتی اثبات می‌کند که این دو می‌توانند به موازات هم حرکت کنند و به حد بهینه آن، یعنی ۱ برسند و لزوماً و در هر شرایطی، افزایش یکی با کاهش دیگری همراه نیست.

نتایج این پژوهش همسو با یافته‌های (Hearst (1991)؛ Tesprasit, Charoenpornswat, Sornlertlamvanich & Karimpour et al. (2005)؛ «عرب» (۱۳۹۴) و «ستوده و هوشیار» (۱۳۹۷) نشان داد که غنی‌سازی موضوع از طریق برچسب‌گذاری در تعیین معنای نهایی واژه، تأثیری مثبت دارد و استفاده از روش رفع ابهام معنایی نظارتی می‌تواند عملکرد نظام بازاریابی را در افزایش کیفیت بازاریابی بهبود بخشد. «جلالی» در پژوهش خود بر این عقیده است که در نظر گرفتن روابط معنایی کلیدواژه‌های به کاررفته در فرایند جست‌وجو و ذخیره‌متون در کنار شباهت نحوی آن‌ها به ایجاد نظامی کارا تر منجر می‌شود (۱۳۸۷). نتایج این پژوهش همسو با این مطلب، با ایجاد تطابق مفهومی و نحوی، نوعی روش نظارتی را در رفع ابهام معنایی هم‌نویسه‌های تخصصی متون علمی به کار برده و نتایج ارزیابی از نظر معیار F تفاوت معناداری با وضعیت موجود نشان داد. «کومار» و همکاران در پژوهش خود معتقدند در حالی که نظام‌های مبتنی بر دانش (مانند سامانه مبتنی بر قانون) به طرز مطلوبی به معانی و زبان‌های کم‌منابع می‌پردازند، اما جایگزین‌های تحت نظارت آن‌ها (سامانه‌های پیکره‌مدار) هر زمان که اطلاعات آموزشی کافی در دسترس باشد، به‌طور مداوم از آن‌ها بهتر عمل می‌کنند (Kumar et al. 2019). همچنین، ذکر این نکته ضروری به نظر می‌رسد که اگرچه با توجه به کمبود داده‌های برچسب‌گذاری شده، رویکردهای مبتنی بر دانش انعطاف و امکان‌پذیری بیشتری دارند، اما عملکرد رویکردهای نظارتی به مراتب بهتر است

(Chan & Ng 2007؛ Pilehvar and Navigli 2014 نقل در Rahman و Barba et al. 2020؛ Borah 2021). این روند ناشی از وجود داده‌های آموزشی است که با تأمین سوخت رویکردهای نظارتی، عملکرد بهتری را باعث می‌شوند.

فهرست منابع

اکبری، اسماعیل، ملوک‌السادات حسینی بهشتی، و مهرداد نوروزی اقبالی. ۱۳۸۴. اصطلاح‌نامه علوم زیستی. تهران: مرکز اطلاعات و مدارک علمی ایران.

انبیایی فریمانی، سعیده، حمید طباطبایی، و مجتبی کفاشان کاخکی. ۱۳۹۸. جستاری بر فرایند سازماندهی و بازیابی متون وبی مبتنی بر تجمیع مفاهیم معنایی در راستای سازماندهی دانش. *پژوهشنامه پردازش و مدیریت اطلاعات* ۳۴ (۴): ۱۸۷۹-۱۹۰۴.

ایران نژاد پاریزی، مهدی. ۱۳۹۰. *روش‌های تحقیق در علوم اجتماعی*. تهران: مدیران.

بوث، باربارا، و میشل بلر. ۱۹۹۲. *اصطلاح‌نامه جامعه‌شناسی*. ترجمه مهوش معترف، ۱۳۸۲. تهران: مرکز اطلاعات و مدارک علمی ایران.

جلالی، و حیدر. ۱۳۸۷. بازیابی معنایی اطلاعات با استفاده از بسط مفاهیم حاصل از جست‌وجوی مبتنی بر کلیدواژه. پایان‌نامه کارشناسی ارشد. دانشکده مهندسی کامپیوتر و فناوری اطلاعات. دانشگاه صنعتی امیرکبیر.

حریری، نجلا، فهیمه باب‌الحوائجی، مهرداد فرزندی‌پور، و سمیه نادری راوندی. ۱۳۹۳. معیارهای ارزیابی ربط در نظام‌های بازیابی اطلاعات: دانسته‌ها و ندانسته‌ها. *پردازش و مدیریت اطلاعات* ۳۰ (۱): ۱۹۹-۲۲۱.

حسینی‌بهشتی، ملوک‌السادات. ۱۳۸۲. کاربرد اصطلاح‌شناسی و واژه‌گزینی در نمایه‌سازی ماشینی و بازیابی اطلاعات. *علوم اطلاع‌رسانی* ۱۸ (۳): ۳۱-۴۴.

_____. ۱۳۹۳. *ساختارواژه: اصطلاح‌شناسی و مهندسی دانش*. تهران: پژوهشگاه علوم و فناوری اطلاعات ایران؛ چاپار.

_____, سعیده وفایی، و مهرداد نوروزی اقبالی. ۱۳۹۳. *اصطلاح‌نامه ریاضیات*. تهران: پژوهشگاه علوم و فناوری اطلاعات ایران.

خیرمند پاریزی، منیر، و رضا نورمندی‌پور. ۱۳۹۵. رفع ابهام معنایی کلمات فارسی با استفاده از رویکرد نظارت‌شده الگوریتم‌های IBL. *علوم رایانشی* ۱ (۲): ۶۳.

ذوالفقار کندری، زهره، طیبه میانگاه، بلقیس روشن، و امیررضا و کیلی فرد. ۱۳۹۹. بررسی تکنیک‌های بهبود عملکرد روش‌های بسامدشماری پیکره‌بنیاد در استخراج خودکار واژگان (مورد مطالعه: واژگان پایه علوم پزشکی). *پژوهشنامه پردازش و مدیریت اطلاعات* ۳۵ (۴): ۱۰۳۹-۱۰۶۴.

رجبی، تقی، غریبی، حسین، حسینی بهشتی، ملوک‌السادات، و مهرداد نوروزی اقبالی. ۱۳۸۳. *اصطلاح‌نامه شیمی*. تهران: مرکز اطلاعات و مدارک علمی ایران.

ستوده، هاجر، و مژگان هوشیار. ۱۳۹۷. بررسی نقش انواع بافتار هم‌نویسه‌ها در تعیین شباهت بین مدارک. *پژوهشنامه پردازش و مدیریت اطلاعات* ۳۳ (۳): ۱۱۸۳-۱۲۰۶.

سلطانی، محمود، و هشام فیلی. ۱۳۸۷. استفاده از تکنیک ابهام‌زدایی معنایی واژگان در بازیابی بین‌زبانی اطلاعات. چهاردهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، انجمن کامپیوتر ایران. تهران، دانشگاه صنعتی امیرکبیر.

صدقی، فاطمه. ۱۳۹۲. رفع ابهام از هم‌نویسه‌ها در متون فارسی با روش‌های نیمه نظارتی. پایان‌نامه کارشناسی ارشد. گروه مهندسی کامپیوتر- هوش مصنوعی. دانشکده فنی- مهندسی. دانشگاه الزهرا.

- صدیقی، مه‌ری، حسینی بهشتی، ملوک‌السادات، و مهرداد نوروزی اقبالی. ۱۳۸۴. *اصطلاح‌نامه علوم زمین*. ج ۲. تهران: مرکز اطلاعات و مدارک علمی ایران.
- عرب، میثم. ۱۳۹۴. *استفاده از روابط پنهان بین کلمات در رفع ابهام معنایی کلمات*. پایان‌نامه کارشناسی ارشد. گروه مهندسی کامپیوتر. واحد بین‌الملل دانشکده فنی - مهندسی. دانشگاه شیراز.
- علایی ابوذر، الهام. ۱۳۹۷. معرفی رویکردی ماشینی با استفاده از الگوریتم لسک و برجسب‌دهی نحوی جهت رفع ابهام از معنای کلمات. *پژوهشنامه پردازش و مدیریت اطلاعات* (۳۳): ۳-۱۱۶۵-۱۱۸۲.
- علی‌پوری حافظی، حامد، امیرسعید مولودی، و محمد کریم بیات. ۱۳۹۸. رفع ابهام معنایی از واژگان هم‌آوا - هم‌نویسه فارسی: رویکرد پیکره‌بنیاد. دومین کنفرانس بازاریابی تعاملی اطلاعات. تهران.
- غفارثمر، رضا، محسن شیرازی‌زاده، و غلامرضا کیانی. ۱۳۹۴. بسترها، چشم‌اندازها، کاربردها و چالش‌های مطالعه واژگان در متون دانشگاهی: ضرورت توجه بیشتر به زبان فارسی و زبان‌آموزان فارسی زبان. *جستارهای زبانی* ۶ (۴): ۱۵۳-۱۸۱.
- قدس‌نیا پدرام، زارع‌بیدکی، علی محمد، و ناصر یزدانی. ۱۳۸۶. بررسی آماری تأثیر برخی از مشکلات زبان فارسی بر جامعیت نتایج جست‌وجو در موتورهای جست‌وجو. کنفرانس ملی سالانه انجمن کامپیوتر ایران، انجمن کامپیوتر ایران، دانشگاه صنعتی شریف.
- کریمی، المیرا، محمود بابایی، و ملوک‌السادات حسینی بهشتی. ۱۳۹۸. بررسی ویژگی‌های معنایی و هستی‌شناسانه نظام‌های بازاریابی اطلاعات مبتنی بر اصطلاحنامه و هستی‌شناسی. *پردازش و مدیریت اطلاعات (علوم و فناوری اطلاعات)*، ۳۴ (۴): ۱۵۸۵-۱۶۱۲.
- کفاشان، مجتبی، و رحمت‌الله فتاحی. ۱۳۹۰. نظام‌های نوین سازماندهی دانش: وب معنایی، هستی‌شناسی و ابزارهای سازماندهی دانش عینی. *کتابداری و اطلاع‌رسانی* ۱۴ (۲): ۴۵-۷۰.
- مرتضایی، لیلا. ۱۳۸۱. مسائل زبان و خط فارسی در ذخیره‌سازی و بازاریابی اطلاعات. *فصلنامه اطلاع‌رسانی* ۱۷ (۲-۱): ۷-۱.
- مسعودی، بابک، و سعید راحتی قوچانی. ۱۳۹۴. رفع ابهام معنایی واژگان مبهم فارسی با مدل موضوعی LDA. *پردازش علائم و داده‌ها* ۴ (۲۶): ۱۱۷-۱۲۵.
- مظفری، زهرا، تاکی، گیتی، صباغ‌جعفری، مجتبی، و پاکزاد یوسفیان. ۱۳۹۷. سامانه رفع ابهام معنایی از حروف اضافه در زبان فارسی با استفاده از قالب‌های معنایی. *پژوهش‌های زبانی*، ۹ (۱): ۹۹-۱۱۷.
- معروفی، افسانه، و عبدالحمید پیله‌ور. ۱۳۹۰. رفع ابهام از معنی کلمه مبهم فارسی با استفاده از روش‌ها مبتنی بر پیکره و قاموس. اولین همایش منطقه‌ای رویکردهای نوین در مهندسی کامپیوتر و فناوری اطلاعات. رودسر، دانشگاه آزاد اسلامی.
- منصوریان، یزدان. ۱۳۸۲. مروری بر پژوهش‌های کاربرمدار در مطالعات بازاریابی اطلاعات مبتنی بر وب. *کتابداری و اطلاع‌رسانی* ۳ (۶): ۱-۲۲.

نوروزی اقبالی، مریم، ملوک‌السادات حسینی بهشتی، و مهرداد نوروزی اقبالی. ۱۳۸۵. اصطلاحنامه فیزیک. تهران: پژوهشگاه اطلاعات و مدارک علمی ایران.

References

- Barba, Edoardo, Luigi Procopio, Niccol Campolungo, Tommaso Pasini, & Roberto Navigli. 2020. MuLaN: Multilingual Label propagation for Word Sense Disambiguation. *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence (IJCAI-20)*, Science. Sapienza University of Rome, Italy. 3837-3844.
- Chan, Yee Seng, & Hwee Tou Ng. 2007. Domain Adaptation with Active Learning for Word Sense Disambiguation. *Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics*. Prague, Czech Republic, 49-56.
- Fangzhou Liu., Qin Shi, & Jianhua Tao. 2008. Tree-guided transformation-based homograph disambiguation in Mandarin TTS system. *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*. Las Vegas, NV, USA. 4657-4660.
- Gale, Kenneth W., William A. Church, & David Yarowsky. 1992. A Method for Disambiguating Word Senses in a Large Corpus. *Computer and the Humanities* 26 (5-6): 415-439.
- Hearst, Marti A. 1991. Noun homograph disambiguation using local context in large text corpora. *Proceedings of the 7th Annual conference of the University of Waterloo Centre for the new OED and text research*. Berkeley, Ca. USA. 185-188.
- Hjørland, Birger. 2021. Information Retrieval and Knowledge Organization: A Perspective from the Philosophy of Science. *Information* 12 (3): 135. <https://doi.org/10.3390/info12030135>
- Hjørland, Birger. 2013. Theories of knowledge organization—theories of knowledge: Keynote, 13th Meeting of the German ISKO in Potsdam. *Knowledge Organization* 40 (3): 169-181. DOI: 10.5771/0943-7444-2013-3-169
- Jurafsky, Danial & James H. Martin. 2020. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*. 3rd ed. Prentice Hall Series in Artificial Intelligence). Upper Saddle River, New Jersey: Pearson Education.
- Karimpour, Reza et al. 2008. *Using Part of Speech Tagging in Persian Information Retrieval*. Available at: <http://ceur-ws.org/Vol-1174/CLEF2008wn-adhoc-KarimpourEt2008.pdf> (accessed Dec. 29, 2020)
- Kessler, Wiltrud. 2012. *Evaluation of Text Classification*. Available at: http://www.ims.unistuttgart.de/institut/mitarbeiter/kesslewd/lehre/sentimentanalysis12s/ml_evaluation.pdf. (accessed March 20, 2020)
- Kumar, Sawan, Jat Sharmistha, Saxena Karan, & Partha Talukdar. 2019. Zero-shot word sense disambiguation using sense definition embedding. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL). Florence, Italy. 5670-5681.
- Menai, Mohamed El Bachir. 2014. Word sense disambiguation using an evolutionary approach. *Informatica* 38 (3): 155-169.
- Pretschner, Alexander, & Susan Gauch. 1999. Ontology based personalized search. In Proceedings of the 11th IEEE, International Conference on Tools with Artificial Intelligence. Chicago, IL, USA.
- Prokofyev, Roma., Demartini Gianluc., Boyarsky Alexey, Ruchayskiy, Oleg, & Philippe Cudré-Mauroux. 2013. Ontology-based word sense disambiguation for scientific literature. Advances in information retrieval: 35th European conference on IR research, ECIR. Berlin, Germany: Springer. 594-605.
- Rahman, Nazreena, & Bhogeswar Borah. 2021. An unsupervised method for word sense disambiguation. *Journal of King Saud University, Computer and Information Sciences*. doi:10.1016/j.jksuci.2021.07.022

- Rijsbergen, C. J. Van. 1974. Foundation of Evaluation. *Journal of Documentation* 3 (4): 365-373. Doi. org/10.1108/eb026584
- Saeed, Ali, Nawab Rao Muhammad Adeel, Mark Stevenson, & Paul Rayson. 2019. A Sense Annotated Corpus for All-Words Urdu Word Sense Disambiguation. *ACM Trans. Asian Low-Resour. Lang.* 18 (4): 1-14. <https://doi.org/10.1145/3314940>
- Sanderson, Mark. 2010. Test Collection Based Evaluation of Information Retrieval Systems. *Foundations and Trends @in Information Retrieval* 4 (4): 247-375. Available at: <http://www.nowpublishers.com/articles/foundations-and-trends-in-informationretrieval/> INR-009. (accessed March 20, 2020)
- Sasaki, Yutaka. 2007. *The Truth of the F-measure*. Teach Tutor Mater. Available at: <http://www.cs.odu.edu/~mukka/cs795sum09dm/Lecturenotes/Day3/F-measure-YS-26Oct07.pdf> (accessed March 20, 2020)
- Schutze, Hinrich. 2014. *Introduction to Information Retrieval: Relevance Feedback and Query Expansion*. Retrieved from <http://www.cis.uni-muenchen.de/~hs/teach/13s/ir/pdf/09expand.pdf> (accessed March 20, 2020)
- Shen, Binbin., Zhiyong Wu, Yongxin Wang & Lianhong Cai,. 2011. Combining Active and Semi-Supervised Learning for Homograph Disambiguation in Mandarin Text-to-Speech Synthesis. 12th Annual Conference of the International Speech Communication Association. Florence, Italy, 27-31.
- Tesprasit, Virongrong, Paisarn Charoenpornasawat, & Virach Sornlertlamvanich. 2003. A context-sensitive homograph disambiguation in Thai text-to-speech synthesis. Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology. Pathumthani, Thailand, 2, 103-105. DOI: 10.3115/1073483.1073518
- Voorhiees, Ellen M., and Donna Harman. 2001. Overview of TREC 2001. Paper Presented At 10th Text Retrieval Conference (TREC 2001). Gaithersburg, Maryland NIST Special Publication 15 (1): 500-250. Retrieved from http://trec.nist.gov/pubs/trec10/papers/overview_10.pd (accessed March 20, 2020).

مینا رضایی دینانی

متولد سال ۱۳۶۳، دارای مدرک تحصیلی دکتری علم اطلاعات و دانش‌شناسی از دانشگاه الزهراء است.
ذخیره و بازایی اطلاعات، کاربرد فناوری‌های نوین در کتابخانه‌ها و مراکز اطلاع‌رسانی، شاخص‌های ارزیابی علم، فناوری و نوآوری و نرمال‌سازی در سنجش و ارزیابی از جمله علایق پژوهشی وی است.

