

■ ارزیابی زوج‌های کتابشناختی در خوشبندی

پروانه‌های ثبت اختراع

آناهیتا کرهانی | نرگس نشاط

چکیده ■

هدف: خوشبندی زوج‌های کتابشناختی (اشتراك استنادی) یکی از شکل‌های خوشبندی مدارک است. هدف این پژوهش شناسایی میزان جامعیت و مانعیت این نوع خوشبندی در پروانه‌های ثبت اختراع است.

روش/رویکرد پژوهش: ۷۱۷ پروانه ثبت اختراع یو.اس. مورد استناد در پروانه‌های ثبت اختراع مربوط به ۹۷۶/۷۴۵ از ردیف بندی پروانه‌های ثبت اختراق یو.اس. با استفاده از زوج‌های کتابشناختی و الگوریتم فازی خوشبندی شد. حاصل کار با استفاده از معیارهای ارزیابی مانعیت و جامعیت گسترش یافته‌ی کیوبید موردا رزیابی قرار گرفت. یافته‌ها: خوشبندی پروانه‌های ثبت اختراق با استفاده از اشتراك استنادی عملکرد مطلوبی داشته و از جامعیت گستره‌های برخوردار بوده است.

نتیجه‌گیری: با توجه به عملکرد مطلوب خوشبندی بر مبنای زوج‌های کتابشناختی، استفاده از زوج‌های کتابشناختی در فرآیند سازماندهی و بازیابی پروانه‌های ثبت اختراق نیز می‌تواند عملکرد مطلوب داشته باشد.

کلیدواژه‌ها

پروانه‌های ثبت اختراق، زوج‌های کتابشناختی، خوشبندی فازی، میانگین، خوشبندی، ارزیابی

ارزیابی زوج‌های کتابشناختی در خوشبندی پروانه‌های ثبت اختراع

آناهیتا کرمانی^۱ | نرگس نشاط^۲

دريافت: ۱۳۹۰/۷/۴ | پذيرش: ۱۳۹۱/۱/۳۰

مقدمه

پروانه‌های ثبت اختراع یکی از منابع مهم اطلاعاتی در فناوری به‌شمار می‌رود که اطلاعات موجود در آنها می‌تواند در اهداف گوناگون مورد استفاده قرار گیرد. «تعیین قابلیت ثبت» اختراعات مورد ادعا و یا «رد اعتبار» اختراقات ثبت شده به‌واسطه یافتن اختراعی مشابه و یا «پیمایش‌های فناوری» از جمله کارکردهای اطلاعات موجود در پروانه‌های ثبت اختراع است. در این راستا، ایجاد نظامهای بازیابی مناسب و نیز به‌کارگیری روش‌های مناسب در ایجاد نقشه‌های فناوری نقش بسزایی در استفاده بهینه از اطلاعات موجود این منابع ایفا می‌کند.

گروه‌بندی مدارک مرتبط همواره یکی از دغدغه‌های اصلی در حوزه‌هایی چون سازماندهی و بازیابی اطلاعات بوده است. پروانه‌های ثبت اختراع ممکن است به دلایلی چون بررسی میزان تازگی و غیربدیهی بودن یک اختراق یا رد اعتبار آن، مورد جست‌وجو قرار گیرند. ارزیاب^۳ مأمور به بررسی ماهوی یک اختراق به دلیل بررسی تازگی و غیربدیهی بودن آن، و شخصی که مدعی تجاوز به حق اختراق خود است باید برای رد اعتبار اختراق ثبت شده، به جست‌وجو در منابع و از جمله پروانه‌های ثبت اختراق بپردازد (گراف، و آزوپاردي^۴؛ ۲۰۰۸)؛ اداره ثبت اختراق و علائم تجاری امریکا^۵؛ ۲۰۱۰؛ بونینو، شیاراملا، کورنو^۶، ۲۰۱۰، نقل در هیدئو، آزوپاردي، وندرباووه^۷؛ ۲۰۱۰). همه این موارد فقط گوشاهای از نیازهایی است که ضرورت و اهمیت سازماندهی و

بازیابی مناسب پروانه‌های ثبت اختراع را نشان می‌دهد. در این راستا، پژوهش‌های متفاوتی پیرامون سازماندهی و بازیابی اطلاعات پروانه‌های ثبت اختراع انجام شده که در برخی از آنها (کانگ^۸ و دیگران^۹؛ بشیر، و رابر^{۱۰}، ۲۰۰۹) نیز به روش خوشبندی پرداخته شده است.

خوشبندی روشی است که برای گروه‌بندی موجودیت‌های^{۱۱} (مدارک) مشابه مورد استفاده قرار می‌گیرد. در این روش، مدارک در گروه‌هایی از پیش تعیین نشده به نام خوشه قرار می‌گیرند؛ به طوری که مدارک مشابه در کنار یکدیگر و مدارک نامشابه دور از یکدیگر قرار گیرند (تن، اشتینباخ، و کومار^{۱۲}، ۲۰۰۶).

عوامل گوناگونی در خوشبندی مؤثر است؛ یکی از این عوامل مربوط به نوع خصیصه‌ای^{۱۳} است که به واسطه آن یک مدرک مورد بازنمایی قرار می‌گیرد. نوع خصیصه انتخابی به همراه الگوریتم مناسب، برای خوشبندی از اهمیت بسیار بالایی است (دیلن، کگان و نیکلاس^{۱۴}، ۲۰۰۳). به این دلیل، انتخاب درست خصیصه برای مدارک در نتایج خوشبندی تأثیرگذار خواهد بود.

غالباً خصیصه‌های گوناگونی برای بازنمایی^{۱۵} پروانه‌های ثبت اختراع مورد استفاده قرار می‌گیرد که استناد یکی از پرکاربردترین آنهاست. اهمیت استنادها به این دلیل است که از یک سو توسط افراد متخصصی به نام ارزیاب تعیین می‌شوند و از سوی دیگر، این استنادها مرتبط با ادعاهای موجود در اختراع هستند و اختراعی بودن یک اثر را مورد تأیید قرار می‌دهند.^{۱۶} از این رو، می‌توانند به عنوان خصیصه‌ای مناسب برای بازنمون پروانه‌های ثبت اختراع مورد استفاده قرار گیرند.

در میان منابع فارسی و خارجی اثربخشی که در آن خوشبندی پروانه‌های ثبت اختراع را با استفاده از عناصر استنادی مورد ارزیابی قرار داده باشد یافته نشد، اما می‌توان به آثار لای، وو^{۱۷} (۲۰۰۵)، لی^{۱۸} و دیگران (۲۰۰۷)، فوجی^{۱۹} (۲۰۰۷) اشاره کرد که عنصر استناد را به نوعی در گروه‌بندی پروانه‌های ثبت اختراع مورد توجه قرار داده‌اند.

لای و وو (۲۰۰۵) در مقاله خود با عنوان «استفاده از رویکرد هم استنادی برای ایجاد سیستمی نوین در رده‌بندی پروانه‌های ثبت اختراع»^{۲۰} استفاده از رویکرد هم استنادی را به منظور رده‌بندی پروانه‌های ثبت اختراع پیشنهاد کرده‌اند. نتایج ارزیابی این مدل با استفاده از روش تجربی در مجموعه‌ای آزمایشی شامل پروانه‌های مربوط به نانوتکنولوژی، حاکی از مفید بودن اطلاعات استنادی در سازماندهی پروانه‌های ثبت اختراع بوده است.

کانگ و دیگران (۲۰۰۷) در مقاله‌ای با عنوان «بازیابی خوشه-محور برای پروانه‌های ثبت اختراع»^{۲۱} به مطالعه بازیابی مبتنی بر خوشبندی پروانه‌های ثبت اختراق پرداخته‌اند که

8. Kang

9. Bashir, & Rauber

10. Entity

11. Tan, Steinbach & Kumar

12. Attribute

13. Dhillon , Kogan & Nicholas

14. Representation

15. البته باید توجه داشت که نظام‌های ثبت اختراق در مراکز گوناگون متفاوت است و توصیف یاد شده از استناد در مراکزی صدق می‌کند که در آن ثبت اختراع مستلزم بررسی ماهوی اختراق است.

16. Lai & Wu

17. Li

18. Fujii

19. Using the patent co-citation approach to establish a new patent classification system

20. Cluster-based patent retrieval

در آن هدف از بازیابی، رد اعتبار پروانه‌های ثبت اختراع بوده است. یافته‌ها حاکی از آن بود که مدل زبانی مبتنی بر خوشة می‌تواند مدل زبانی فاقد خوشة را بهبود بخشد. لی و دیگران (۲۰۰۷) در مقاله‌ای با عنوان «رده‌بندی خودکار پروانه‌های ثبت اختراع با استفاده از شبکه استنادی: مطالعه‌ای تجربی در فناوری نانو»^{۲۱}، استفاده از اطلاعات استنادی پروانه‌های ثبت اختراع بهویژه ساختار شبکه استنادی را در اختصاص خودکار رده‌ها به پروانه‌های ثبت اختراع مورد بررسی قرار داده‌اند. نتایج این تحقیق حاکی از آن است که استفاده از ساختارهای شبکه استنادی به طور معنی‌داری عملکردی بهتر نسبت به حالتی ایجاد می‌کند که در آن از استناد استفاده نشده است.

فوچی (۲۰۰۷) در مقاله‌ای با عنوان «تلغیق اطلاعات استنادی و محتوایی در بازیابی ثبت اختراع ان. تی. سی. آی. آر. ۳»^{۲۲} به ارزیابی بازیابی اطلاعات پروانه‌های ثبت اختراع با هدف رد اعتبار پروانه‌های ثبت اختراعات پرداخته است. مدل پیشنهادی او شامل تلغیق اطلاعات استنادی و متنی برای بازیابی پروانه‌های ثبت اختراع بوده است. در این مدل، ابتدا بازیابی مبتنی بر متن و پس از آن، از اطلاعات استنادی استفاده شده است. در بازیابی مبتنی بر متن، متن ادعای(های) موجود در پروانه‌های ثبت اختراع مورد استفاده قرار گرفته است. در نمره‌دهی استنادی مدارک دو شیوه در پیش گرفته شده: حالتی که نمره استنادی در کل مدارک در نظر گرفته می‌شود؛ و حالتی که نمره استنادی در N مدرک برتر حاصل از بازیابی مبتنی بر متن محاسبه می‌شود. در این مدل، به منظور نمره‌دهی ثبت اختراعات از نظر اطلاعات استنادی از روش پیچ رنک^{۲۳} استفاده شده است. نتایج این پژوهش تجربی نشان داده که تلغیق اطلاعات استنادی در حالت اول (محاسبه نمره استنادی بدون در نظر گرفتن N مدرک برتر) اثربخش تراز حالت دوم عمل کرده، اما به طور کلی، تلغیق اطلاعات استنادی و متنی در بازیابی اثربخش بوده است.

تیوانا، و هورویتز^{۲۴} (۲۰۰۹) در «فایندسایت - یافتن خودکار پروانه‌های ثبت اختراع پیشین»^{۲۵} به ارائه الگوریتمی پرداخته‌اند که در آن از استنادها برای یافتن پروانه‌های ثبت اختراع استفاده شده است. این الگوریتم بر روی نتایج بازیابی پیاده‌سازی می‌شود. به این معنی که ابتدا واژه‌ای جست وجو و پس از آن الگوریتم بر روی مجموعه مدارک بازیابی شده، پردازش‌های بعدی را انجام می‌دهد. ابتدا از طریق جست‌وجوی کلیدواژه‌ای، مجموعه از پروانه‌های ثبت اختراع مشخص و سپس پروانه‌های ثبت اختراع مهم از طریق استنادهای پیش‌آیند و پس آیند مشخص می‌شود. استفاده از استناد در الگوریتم پیشنهادی سبب بازیابی تعداد زیادی از منابع نامرتبط در کنار منابع مرتبط بوده است.

زو، و کرافت^{۲۶} (۲۰۰۹) در مقاله خود با عنوان «تبديل پروانه‌های ثبت اختراع به عبارت‌های جستجو برای آثار پیشین»^{۲۷} به شناسایی بهترین ناحیه برای انتخاب خودکار

21. Automatic patent classification using citation network information: An experimental study in nanotechnology

22. Integrating content and citation information for the NTCIR-6 patent retrieval task

23. PageRank

24. Twiana, & Horwitz

25. Findcite: Automatically finding prior art patents

26. Xuo & Croft

27. Transforming patents into prior-art queries

عبارة جستجو پرداخته‌اند و به منظور کاهش مسئولیت کاربران، کل مدرک ثبت اختراع به عنوان عبارت جستجو در نظر گرفته شده است. نتایج حاصل از تحقیق تجربی بر روی مجموعه حاوی پروانه‌های ثبت اختراع اداره یو. اس. پی. تی.^{۲۸} حاکی از آن است که از میان نواحی عنوان، چکیده، خلاصه آثار پیشین، توصیف اشکال، شرح جزئیات، ادعاهای جستجوی آزاد و ادعاهای مقدم، ناحیه خلاصه آثار پیشین^{۲۹} دارای بهترین تأثیر در بازیابی آثار پیشین بوده است. همچنین در میان الگوریتم‌های مورد استفاده برای وزن‌دهی، الگوریتم tf دارای بهترین عملکرد و پس از آن، الگوریتم‌های bool و tf-idf قرار داشته‌اند. و نگیری و آدریانی^{۳۰} (۲۰۱۰) در پژوهش خود با عنوان «بازیابی آثار پیشین با استفاده از محتوای نواحی مختلف در مدارک پروانه ثبت اختراع»^{۳۱} عملکرد بازیابی به منظور رد اعتبار^{۳۲} یک مدرک ثبت اختراع را هنگام استفاده از سه ناحیه «ادعاهای»، ترکیب «عنوان و توصیف» و ترکیب «عنوان، توصیف و ادعاهای» مورد بررسی قرار داده‌اند. نتایج نشان داده که در میان نواحی مورد بررسی، ترکیب «عنوان، توصیف و ادعاهای» دارای بهترین عملکرد از لحاظ معیارهای جامعیت، مانعیت، مانعیت میانگین متوسط (MAP)^{۳۳} و NDCG است. همچنین میزان جامعیت در هر دو مجموعه موضوعات عام^{۳۴} و خاص^{۳۵} بسیار بیشتر از میزان مانعیت آن بوده، و MAP موضوعات عام (۰/۰۵۸۱) بیشتر از موضوعات خاص (۰/۰۵۳۷) است.

چنانچه مشاهده می‌شود استفاده از استناد به عنوان خصیصه می‌تواند به دو شیوه انجام شود: از یک سو، در خوشبندی منابع «استنادکننده» و از سوی دیگر در خوشبندی منابع «استنادشونده». روش نخست که در آن «استنادهای موجود در یک مدرک»، خصیصه‌ای برای بازنمودن مدارک «استنادکننده» محسوب شود «زوج‌های کتابشناختی»^{۳۶}، و روش دوم که «مدارک استنادکننده» به عنوان خصیصه‌ای برای مدارک «استناد شونده» محسوب شود «هم‌استنادی»^{۳۷} نام دارد. از آنجاکه در پژوهش حاضر خوشبندی منابع استنادکننده مورد نظر بوده است، لذا بر آنیم تا عملکرد زوج‌های کتابشناختی را در خوشبندی پروانه‌های ثبت اختراع مورد بررسی قرار داده و برای پرسش‌های زیر پاسخی مناسب بیابیم:

۱. میزان جامعیت در خوشبندی پروانه‌های ثبت اختراع با استفاده از زوج‌های کتابشناختی چقدر است؟
۲. میزان مانعیت در خوشبندی پروانه‌های ثبت اختراع با استفاده از زوج‌های کتابشناختی چقدر است؟

روش پژوهش و جامعه مورد مطالعه

پژوهش حاضر به روش تجربی انجام شده و جامعه آماری شامل ۷۱۷ پروانه ثبت اختراع

28. USPTO

29. Background summary

30. Wangiri & Adriani

31. Prior art retrieval using various patent document fields contents

32. Invalidate

33. Mean Average Precision

34. Large topic set

35. Small topic set

36. Bibliographic coupling

37. Co-citation

یو. اس.^{۳۸} مورد استناد در پروانه‌های ثبت اختراع یو. اس. متعلق به رده ۹۷/۷۷۴ از رده‌بندی یو. اس. پی. سی.^{۳۹} است. رده‌ای اصلی و مربوط به موضوع نانوتکنولوژی (فناوری نانو)؛ رده‌ای فرعی و زیرمجموعه‌ای^{۴۰} از رده فرعی ۹۷/۷۷۳؛ رده ۹۷/۷۷۳ نیز زیرمجموعه‌ای از رده ۹۷/۷۰۰ است. رده فرعی ۹۷/۷۰۰ مربوط به نانوساختارها و رده فرعی ۹۷/۷۷۳ شامل نانوذرات است^{۴۱}.

پس از استخراج و ذخیره اطلاعات در نرم‌افزار اکسل، ابزارهای زیر برای مراحل مختلف مورد استفاده قرار گرفت:

نرم‌افزار کد منبع باز ریل‌داینر^{۴۲} در وزن دهی به استنادها؛ برنامه^{۴۳} خوشه‌بندی فازی^{۴۴} نوشته شده به زبان برنامه‌نویسی پل^{۴۵}؛ و برنامه^{۴۶} محاسباتی جامعیت و مانعیت گسترش یافته بی کیوبید که در گارگاه ویس^{۴۷} معرفی و ارائه شده است. در اجرای پژوهش، فرآیندهایی از جمله ایجاد مجموعه مورد آزمایش^{۴۸}، استخراج استنادها، ایجاد ماتریس‌های استناد-پروانه ثبت اختراع، خوشه‌بندی پروانه‌های ثبت اختراع انجام شده است که در ادامه به آنها می‌پردازیم.

نحوه ایجاد مجموعه آزمایشی و استخراج استنادها

- ارزیابی خوشه‌بندی معمولاً با استفاده از مجموعه‌های آزمایشی انجام می‌شود. مجموعه‌های آزمایشی در برگیرنده مجموعه مدارکی است که نسبت به آنها قضایت‌های ربط صورت گرفته است. در این مجموعه‌ها موضوعاتی تعریف شده که تعدادی از مدارک موجود در مجموعه آزمایشی، به آنها مرتبط است. در این حالت ارزیابی شیوه پیشنهادی برای خوشه‌بندی، با توجه به قابلیت آن در گروه‌بندی مدارک مرتبط، مورد ارزیابی قرار می‌گیرد. یکی از روش‌های ایجاد مجموعه‌های آزمایشی برای پروانه‌های ثبت اختراق، ایجاد مجموعه‌های آزمایشی مبتنی بر استناد است. در این حالت هر پروانه ثبت اختراق مانند موضوعی است که استنادهای موجود در آن، مدارک مرتبط به آن موضوع را مشخص می‌کند. در پژوهش حاضر نیز چنین رویکردی در ایجاد مجموعه‌های آزمایشی مورد استفاده قرار گرفته است. بدین صورت که مجموعه پروانه‌های ثبت اختراق متعلق به رده‌ای خاص به عنوان موضوع و استنادهای موجود در آن به عنوان مدارک مرتبط با آن موضوع در نظر گرفته شده است. بنابراین مجموعه مورد آزمایش در تحقیق حاضر مجموعه مدارکی خواهد بود که پروانه‌های ثبت اختراق رده مفروض آن را مورد استناد قرار داده باشند.
- برای ایجاد مجموعه مورد آزمایش ابتدا تعداد ۱۰۴ پروانه ثبت اختراق مربوط به رده ۹۷/۷۷۴ به عنوان خوشه‌بندی مرجع برگزیده شد. برای به دست آوردن پروانه‌های ثبت اختراق
۲۸. از دلایل پرداختی پروانه‌های ثبت اختراق یو. اس. (US patent)، انتشار مرکز صادرکننده آن (اداره ثبت اختراق و علوم تجارتی امریکا) و حجم گسترهای این مانع به خود اختصاص داده‌اند.
۳۹. USPC (US patent classification)
۴۰. Indented
۴۱. فناوری نانوییکی از فناوری‌های مورد توجه در عرصه ملی و بین‌المللی است. به همین دلیل، در پژوهش حاضر یکی از رده‌های فرعی مربوط به این فناوری (۹۷W/۷۷) مورد بررسی قرار گرفته است.
42. <http://rapid-i.com/content/view/181/190/>
43. <http://cpan.uwinnipeg.ca/htdocs/Algorithm-FuzzyCmeans/Algorithm-FuzzyCmeans.html>
44. Fuzzy c-means clustering
45. Perl
46. http://www.evalita.it/sites/evalita/fblc.eu/files/doc2011/weps2007_scorer_1.1.targz
47. WePS
48. Test collection

رده ۹۷/۷۴، عبارت cd/۹۷/۷۴ در جستجوی پیشرفتہ پایگاه مربوط به پروانه‌های ثبت اختراع اداره یو.اس.پی.تی. آ. به نشانی: <http://patft.uspto.gov/netahmt/PTO/search-adv.htm> مورد جستجو قرار گرفت. از میان ۱۰۴ خوش، تعداد ۱۸ خوش (پروانه‌های مربوط به رده ۹۷/۷۴) به دلیل یکسان بودن با پروانه‌های مورد استناد و تعداد ۱۱ خوش نیز به دلیل عدم استناد به پروانه ثبت اختراع یو.اس. از خوشبندی مرجع حذف شد. درنهایت تعداد ۷۵ پروانه ثبت اختراع (خوش) به دست آمد. تعداد پروانه‌های ثبت اختراع که در این پروانه‌ها مورد استناد قرار گرفته است برابر با ۷۱۷ پروانه ثبت اختراع است که در این تحقیق به عنوان مجموعه آزمایشی مورد استفاده قرار گرفته است.

پس از مشخص شدن مجموعه آزمایشی، براساس شماره پروانه‌های ثبت اختراع (با استفاده از پایگاه‌های اطلاعاتی یو.اس.پی.تی.او. گوگل پتنس^{۴۹}، فری‌پتنس آنلاین^{۵۰})، (حدود ۵۰۰۰۰ استناد) و درج آنها در قالب جداولی در نرم‌افزار اکسل اقدام به استخراج استنادها شده است. درنهایت جدولی تشکیل شد که قسمت‌هایی از آن در زیر قابل مشاهده است.

A	B	C	D	E	F	G	H	I	J	K
20	7431867	2932629	5489449	5690807	5741372	6582763	20050057867	20070054984	20070056465	
21	7422790	6227229	6225198	6251303	6306736	6322901	6326144	6440213	6607829	6617583
22	7417370	4476292	4769292	5247190	5834893	5955837	6091195	6777671	6787796	6920257
23	7405002	3656981	4751194	5549973	5751018	5783263	5788738	5879715	5906670	5965212
24	7402832	3995311	4211467	4332974	4557551	4688882	4693547	4818050	4856859	4894818
25	7399675	4184207	4751558	4785337	4833094	4860070	5196722	5252845	5315142	5411905
26	7399429	20020160195	20020187347	20050129947						5432365
27	7394092	2002019108								
28	7390568	4882609	5021360	5081511	5262357	5293050	5354707	5395791	5412231	5422489
29	7382017	5043940	5434825	5714766	5937295	5959896	6059439	6090666	6139626	6159620
30	7378151	6110308	6306610	7318957	20010023078	20020045045				
31	7361821	3772200	4054343	4683195	4683202	4800159	5401511	5405766	5427930	5451505
32	7361543	6297095	6320784	6444545	6794712	6808992	6958265	6964902	7015090	7091089
33	7358525	3995311	4211467	4332974	4557551	4688882	4693547	4818050	4856859	4894818
34	7357018	5327930	5583443	5730940	6159742	6297063	6465782	6803840	6852673	6919730
35	7346251	2002019190	20030013109	20040131097	20060147169	20060151793				
36	7341914	5408115	5824584	5969383	6816414	6964902	2002019043	20050176202	20060189079	
37	7335345	4751200	5747180	5985353	6251303	6333110	6350515	6426513	6444143	6468808
38	7306963	4118485	4673584	5057313	5142385	5155051	5372675	5427648	5782908	6066204
39	7306823	342301	3580541	3891519	3907566	3966568	4104134	4191794	4192721	4410758
40	7303937	5156336	5306345	6521048	6984842					
41	7274080	5390061	5465185	5549978	5640343	5650958	5729410	5757695	5764567	5841692
42	7259084	5141893	5183776	5238869	5308444	5438951	5473174	5879962	5959308	6107635
43	7256435	5227749	5772905	6256767	6294450	6432740	6504292	6893705	6897098	20020175408
44	7256416	20050064206								20040023162
45	7250653	5714766	6208000	6288943	6444545	6690059	20020076850			
46	7249859	6137523								
47	7238595	5222556	5256550	5879970	5891769	6030894	6093252	6319782	6373112	6537370
48	7214428	4642334	4946778	5034506	5151507	5187085	550928	5558991	5596086	5602240
49	7208793	5328859	5783478	6417085	6432803	6706594	6743681	20020101942	20040178470	5637258
50	7201485	4992699	6318866	6318987	6413615	6447878	6461003	6508558	20020191292	4946778

جدول ۱

جدول ۱ مربوط به استنادهای موجود در هر پروانه ثبت اختراع است که در ستون اول (شماره پروانه ثبت اختراع) و در ستون‌های بعد (شماره پروانه‌ها و درخواست‌نامه‌های ثبت اختراع مورد استناد) درج شده است.

49. <http://www.google.com/patents>
 50. <http://www.freepatentonline.com/search.html>

ایجاد ماتریس استناد-پروانه ثبت اختراع

برای ایجاد ماتریس «استناد-پروانه ثبت اختراع» جدول ۱ به نرم‌افزار ریدماینر وارد شده و وزن‌دهی استنادها براساس روش $tf \cdot idf^5$ انجام گرفت. این روش یکی از متداول‌ترین روش‌های مورد استفاده برای وزن‌دهی خصیصه‌های است که بخش اول آن (tf) از سوی سالتون و بخش دوم آن (idf) از سوی اسپارک جوائز پیشنهاد شده است (تیان، و تنگ،^۶ ۲۰۱۱). tf برابر با سهم حضور یک واژه در یک مدرک است و idf ضریبی است که با توجه به میزان رخداد هر خصیصه در کل مجموعه محاسبه می‌شود. idf برابر با لگاریتم معکوس میزان حضور واژه در کل مجموعه مدارک است و سبب می‌شود که به خصیصه‌های کم رخداد در کل مجموعه وزن بیشتری اختصاص یابد. در این روش وزن هر خصیصه از ضرب «سامد حضور یک خصیصه در یک مدرک» (tf) در «لگاریتم تعداد کلیه مدارک بخش بر تعداد مدارک حاوی هر خصیصه» (idf) به دست می‌آید (تی اف-آی‌دی‌اف^۷، ۲۰۱۱).

نحوه خوشبندی پروانه‌های ثبت اختراع

در تحقیق حاضر، برای بررسی تاثیر خصیصه اشتراک استنادی (زوج‌های کتابشناختی) از خوشبندی سی-مینز (میانگین^۸) استفاده شده است. در این خوشبندی میزان عضویت در یک خوشه مقادیر میان صفر و یک را می‌تواند به خود اختصاص دهد. برای ایجاد خوشبندی فازی سی-مینز مراحل زیر دنبال می‌شود (ودینگ^۹، ۲۰۰۹):

۱. انتخاب تعداد دلخواه k خوشه برای مجموعه‌ای شامل N مدرک^{۱۰}، به طوری که $N < k$ ؛
که در اینجا K برابر است با 75 خوشه و N برابر با 717 پروانه ثبت اختراع است؛

۲. ایجاد یک نقطه مرکزی آغازین به ازای هر یک از K خوشه؛

۳. محاسبه فاصله هر یک از N مدرک تا هر یک از K خوشه؛

۴. تعیین یک عضویت فازی یا کسری در هر یک از K خوشه برای هر یک از N مدرک؛

۵. یافتن نقطه مرکزی جدیدی برای هر یک از k خوشه از طریق یافتن میانگین وزنی رکوردها^{۱۱}؛

۶. تکرار مراحل ۳، ۴، و ۵ تا هنگامی که تغییری در عضویت خوشه‌ای به وجود نیاید (یا تا هنگام رسیدن به معیار همگرایی).

تعیین درجه عضویت مدارک در هر یک از خوشه‌ها

درجه عضویت فازی، از محاسبه فاصله‌های مدارک از مرکز خوشه‌ها به دست می‌آید. هنگامی

۱۱. Term frequency-inverse

document frequency

۵۲. Tian & Tong

۵۳. tf-idf

۵۴. Wedding

۵۵. در توصیف الگوریتم از واژه استفاده data است زیرا کاربر خوشبندی تهابه شده است. مدارک محدود نیست. اما از آنکه خوشبندی مدارک محدود نیست. در اینجا خوشبندی برای مدارک مورد استفاده قرار گرفته است. واژه «مدرک» مورد استفاده قرار گرفته است.

۵۶. Records: در اینجا منظور همان پروانه‌های ثبت اختراع استندکه در صورتی که بخواهیم میانگین وزنی از آنها بگیریم باید از تک مؤلفه‌هایشان میانگین وزنی بگیریم تا بدار خوشه جدید به دست آید.

که مدرکی به مرکز یک خوشه نزدیک‌تر از مرکز دیگر خوشه‌ها باشد، درجه عضویت مدرک در آن خوشه بیشتر و هنگامی که مدرک دورتر باشد درجه عضویت کمتری خواهد داشت. مجموع مقادیر عضویت فازی [یک مدرک] نیز برابر با یک است (ودینگ، ۲۰۰۹). درجه عضویت از طریق فرمول زیر (ودینگ، ۲۰۰۹) محاسبه می‌شود:

$$u_k = \frac{1}{\sum_{i=1}^j \left(\frac{d_k}{d_i} \right)^p}$$

که در آن k یکی از j خوشه، d فاصله و p توان است. توان (p) خود از فرمول زیر (ودینگ، ۲۰۰۹) به دست می‌آید:

$$p=2(m-1)$$

که در آن m یک توان o فازی است به طوری که $m < 100$ است. مقدار m بر درجه فازی بودن خوشه‌ها تأثیرگذار است. هنگامی که $1 \rightarrow m$ نزدیک به ۱ باشد) درجه فازی شدن خوشه‌ها کمتر و هنگامی که $m \rightarrow \infty$ به سمت بینهایت میل کند) خوشه‌ها به طور فزاینده‌ای فازی خواهند شد. برای مقادیر نزدیک به بینهایت، مقدار عضویت‌های فازی یک مدرک در همه خوشه‌ها به برابری می‌گراید. معمولاً برای m مقدار ۲ در نظر گرفته می‌شود (ودینگ، ۲۰۰۹).

پس از به دست آوردن خصیصه‌های وزن داده شده در نرمافزار رییدماینز، از برنامه نوشته شده به زبان پرل برای ایجاد خوشبندی فازی سی-مینز استفاده شده است. از آنجا که خوشبندی مرجع دارای ۷۵ خوشه بود، در تنظیمات خوشبندی، تعداد خوشه برابر با ۷۵ خوشه (طی ۱۰۰ تکرار) تعیین شد.

خروجی این برنامه، جدولی است که در آن میزان درجه عضویت هر پروانه ثبت اختراع را به هر یک از ۷۵ خوشه نشان می‌دهد.

جدول ۲ نشان دهنده عضویت‌های فازی پروانه‌های ثبت اختراع در خوشبندی حاصل از زوج‌های کتابشناختی است. در ستون A شماره پروانه‌های ثبت اختراع قرار گرفته و در ستون‌های بعدی نام هر خوشه قرار دارد.

آمار مربوط به میزان درجه عضویت پروانه‌های ثبت اختراع در هر خوشه نیز در

جدول ۳ آمده است.

57. Exponent

جدول ۲

بخشی از ماتریس مربوط به
عضویت فازی هر مدرک
در هر خوشه براساس
زوج‌های کتابشناختی

1 A	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
2 T***2155656***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
3 T***3203319***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
4 T***3406228***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
5 T***3410880***	0.013	0.013	0.013	0.013	0.013	0.013	0.013	0.013	0.013	0.013
6 T***3450673***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
7 T***3485806***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
8 T***3488327***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
9 T***3488389***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
10 T***3499032***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
11 T***3511894***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
12 T***3527802***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
13 T***3555095***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
14 T***3565868***	0	0	0	0	0	0	0	0	0	0
15 T***3567725***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
16 T***3583950***	0	0	0	1	0	0	0	0	0	0
17 T***3598790***	0.0109	0.0109	0.0109	0.195	0.0109	0.0109	0.0109	0.0109	0.0109	0.0109
18 T***3641145***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
19 T***3664990***	0	0	0	0	0	0	0	0	0	0
20 T***3671473***	0	0	0	0	0	0	0	0	0	0
21 T***3676453***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
22 T***3704128***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
23 T***3705992***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
24 T***3706797***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
25 T***3706800***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
26 T***3715343***	0	0	0	0	0	0	0	0	0	0
27 T***3719933***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
28 T***3728387***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133
29 T***3756994***	0.0132	0.0132	0.0132	0.0132	0.0132	0.0132	0.0132	0.0132	0.0132	0.0132
30 T***3772200***	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133	0.0133

جدول ۳

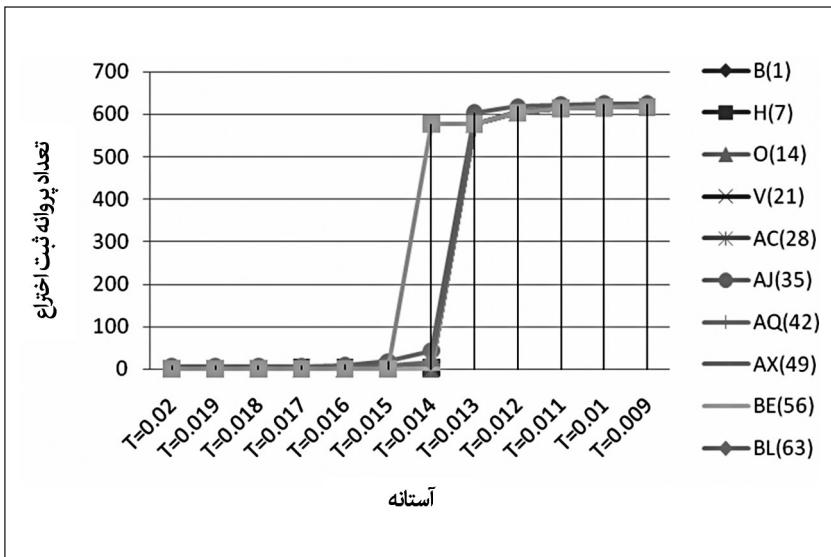
درجه عضویت در هر
خوشه-زوج‌های کتابشناختی

درجه عضویت در خوشه (اشتراک استنادی)	
Min	.
Max	۱
Average	۰/۰۱۳۱۴
Median	۰/۰۱۳۳
Mode	۰/۰۱۳۳
Std	۰/۰۴۰۵۱

یافته‌ها

پس از مشخص شدن درجه‌های عضویت هر پروانه ثبت اختراع در هر ۷۵ خوشه، آستانه‌ای برای ارزیابی مانعیت محور و آستانه‌ای برای ارزیابی جامعیت محور تعیین شده که این آستانه با استفاده از مطالعه بر روی تعدادی از خوشه‌ها تعیین شده است. برای تعیین آستانه مناسب،

آستانه‌های موجود در بازه ۰/۰۲ تا ۰/۰۹ مورد بررسی قرار گرفته‌اند. این بازه با توجه به شاخص‌های مربوط به میانگین و میانه و نیز انحراف معیار جدول ۱ انتخاب شد. نمودارهای مربوط به تغییرات آستانه و تغییرات تعداد اعضای هر خوشه برای تعداد خوشه انتخابی در ادامه ارائه شده است.



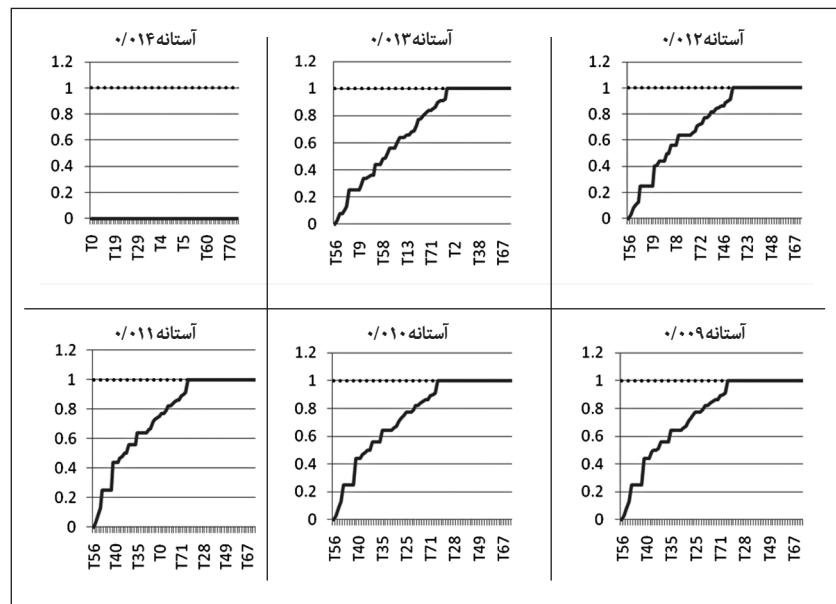
نمودار ۱

زوج‌های کتابشناختی-تغییرات
تعداد اعضای هر خوشه با توجه
به تغییرات آستانه عضویت

طبق نمودار ۱، تغییرات تعداد اعضای اکثر خوشه‌ها از آستانه ۰/۰۱۵ به ۰/۰۱۳ شدت گرفته (شیب منحنی) و پس از آستانه ۰/۰۱۴ تغییر چندانی نکرده است. در پژوهش حاضر آستانه ۰/۰۱۴ (درجه عضویت ۰/۰۱۴ و بیشتر) برای ارزیابی مانعیت محور، و آستانه ۰/۰۰۹ (درجه عضویت ۰/۰۰۹ و بیشتر) برای ارزیابی جامعیت محور، مبنیاً قرار گرفته است، و برای بررسی روند تغییرات از مانعیت محوری به سمت جامعیت محوری، آستانه‌های ۰/۰۱۳، ۰/۰۱۲، ۰/۰۱۱، ۰/۰۱۰ نیز مورد بررسی قرار گرفته است. به ازای اعمال هر درجه‌ای از آستانه برای خوشبندی به وجود آمده، میزان جامعیت و مانعیت گسترش یافته‌ای کیوبد محاسبه شد. نمودار ۲ نشان‌دهنده میزان جامعیت و مانعیت گسترش یافته‌ای کیوبد در آستانه‌های گوناگون است.

نمودار ۲

میزان جامعیت و مانعیت
گسترش‌یافته‌بی‌کیوبید
در آستانه‌های گوناگون



جدول ۴

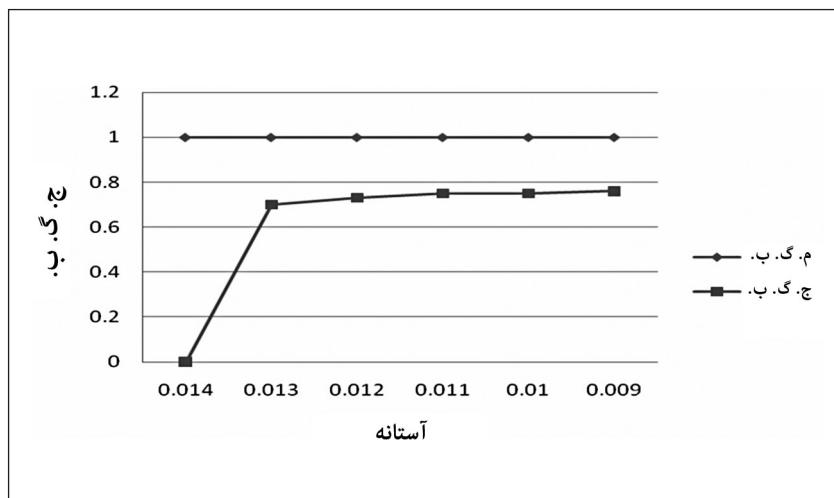
مقدار نهایی جامعیت و مانعیت
گسترش‌یافته‌بی‌کیوبیدر
آستانه‌های اعمال شده

آستانه	.م.گ.ب.	.ج.گ.ب.
۰/۰۱۴	۱	۰
۰/۰۱۳	۱	۰/۷
۰/۰۱۲	۱	۰/۷۳
۰/۰۱۱	۱	۰/۷۵
۰/۰۱۰	۱	۰/۷۵
۰/۰۰۹	۱	۰/۷۶
میانگین	۱	۰/۶۱۵
میانه	۱	۰/۷۴

همان‌طور که جدول ۴ نشان می‌دهد، در آستانه ۰/۰۱۴ مقدار جامعیت گسترش‌یافته صفر است، اما مانعیت آن عدد ۱ را نمایش می‌دهد. همچنین به ترتیب هرچه از آستانه ۰/۰۱۴ به سمت پایین ترسیم می‌شود، یعنی در آستانه‌های ۰/۰۱۳، ۰/۰۱۲، ۰/۰۱۱، ۰/۰۱۰ و ۰/۰۰۹، مقدار جامعیت گسترش‌یافته بی‌کیوبید افزایش می‌یابد.

در آستانه‌های تعیین شده، میانگین میزان مانعیت گسترش یافته بی‌کیوبد برابر با ۱ و میانگین میزان جامعیت آن برابر با 0.615 ± 0 است.

طبق جدول ۴، هرچه از آستانه تعریف شده کاسته می‌شود، مقدار جامعیت گسترش یافته افزایش می‌یابد، اما نرخ رشد و تغییرات آن انداز است. نمودار ۳ نشان‌دهنده تغییرات جامعیت و مانعیت گسترش یافته بی‌کیوبد بر حسب تغییر در آستانه و حرکت از جامعیت محوری در خوشبندی به سمت مانعیت محوری است.



نمودار ۳

تغییرات جامعیت و مانعیت
گسترش یافته بر حسب
تغییرات آستانه

باتوجه به نمودار ۳، هرچه از مانعیت محوری (آستانه 0.014 ± 0) در خوشبندی به سمت جامعیت محوری (آستانه 0.009 ± 0) پیش می‌رویم، میزان جامعیت گسترش یافته افزایش می‌یابد. با این حال، در تمامی آستانه‌های تعیین شده، میزان مانعیت گسترش یافته مقداری ثابت و برابر با ۱ را به خود اختصاص داده است.

همچنین نمودار ۳ حاکی از آن است که خوشبندی با استفاده از زوچ‌های کتابشناختی، در طیف گسترده‌تری از آستانه قابل تعریف است. این بدان معنی است که ساختار خوشبندی در خوشبندی با استفاده از زوچ‌های کتابشناختی از انسجام و عملکرد مطلوبی برخوردار است.

نتیجه‌گیری

جنبه حقوقی در ثبت اختراعات سبب شده است که نیازهای اطلاعاتی در جست‌وجوی پرونده‌های ثبت اختراع نیازمند جامعیت بیشتر در نتایج جست‌وجو باشد تا افرادی که در جهت بررسی قابلیت ثبت اثربه عنوان اختراع هستند بتوانند تمامی منابع مرتبط را مورد

بررسی قرار دهدن. یافته‌های پژوهش حاضر حاکی از آن بود که خوشه‌بندی با استفاده از زوج‌های کتابشناختی، عملکردی مطلوب (بیش از ۵۰ درصد) داشته و این مطلوبیت در طیف گسترده‌ای از آستانه‌های تعیین شده (میزان جامعیت محوری) برقرار است. بنابراین، به نظر می‌رسد استفاده از این خصیصه در بازیابی اطلاعات پروانه‌های ثبت اختراع نتایج مطلوبی دریبی داشته باشد.

عملکرد مطلوب خصیصه استناد در پژوهش فوجی (۲۰۰۷) نیز نشان داده شده است. با این حال بازیابی تعداد زیادی از منابع نامرتبط در کنار منابع مرتبط هنگام استفاده از استناد (تیوانا و هورویتز، ۲۰۰۹) را نمی‌توان تأییدی بر مطلوبیت استفاده از این خصیصه دانست.

یافته‌های پژوهش حاضر همچنین نشان داد که علاوه بر رده‌بندی خودکار (لای و وو، ۲۰۰۵؛ لی و دیگران، ۲۰۰۷) و بازیابی اطلاعات (فوجی، ۲۰۰۷)، استفاده از استناد نیز در خوشه‌بندی پروانه‌های ثبت اختراع نقشی کارآمد دارد. بنابراین شاید بتواند روشی مؤثر در ترسیم نقشه‌های فناوری با استفاده از خوشه‌بندی و نیز بازیابی‌های خوشه‌محور باشد.

البته باید به این مسئله نیز اشاره کرد که با گذشت زمان حجم استنادها افزوده خواهد شد. به طور مثال، در مورد پروانه‌های ثبت اختراع، هر روزه تعدادی اختراع به ثبت می‌رسد و تعدادی از منابع مورد استناد قرار می‌گیرند. این امر سبب افزایش حجم استنادها و درنتیجه خصیصه‌های مورد استفاده در خوشه‌بندی پروانه‌های ثبت اختراع خواهد شد. این امر، پژوهش در باب کاهش حجم مورد نیاز برای نگهداری خصیصه‌ها و شکل‌های مختلف پردازش آنها را ضروری می‌سازد. بنابراین، پیشنهاد می‌شود پژوهش‌هایی در باب کاهش حجم خصیصه‌های استنادی انجام شود تا بهترین راه که با جامعیت بالاتری همراه باشد مورد استفاده قرار گیرد.

شایان ذکر است که پژوهش حاضر به بررسی پروانه‌های ثبت اختراع مربوط به رده نانوتکنولوژی و استفاده از الگوریتم فازی پرداخته است و برای اینکه بتوان نتایج آن را به دیگر حوزه‌های نیز تعمیم داد، شاید لازم باشد تحقیقات مشابه دیگری نیز در سایر حوزه‌ها انجام شود.

منبع

Bashir, S.; Rauber, A. (2009). "Improving retrievability of patents with cluster-based pseudo-relevance feedback documents selection". In: *CIKM '09: Proceeding of the 18th ACM conference on Information and knowledge management*, (pp. 1863–1866), New York, NY, USA. ACM. Retrieved February 19, 2011 from: http://publik.tuwien.ac.at/files/PublicDat_182418.pdf

- Bonino, D.; Ciaramella, A.; Corno. F. (2010). "Review of the state-of-the-art in patent information and forthcoming evolutions in intelligent patent informatics". *World Patent Information*, 32(1):30 – 38.
- Dhillon I.; Kogan J.; Nicholas CH. (2003). "Feature selection and document clustering". In: M. Berry (Ed.), *A Comprehensive Survey of Text Mining* (pp. 73-100). Springer-Verlag. Retreived July 29, 2011, from: <http://www.cs.umbc.edu/csee/research/cadip/2002Symposium/kogan.pdf>
- Fujii, A. (2007). "Integrating content and citation information for the NTCIR-6 patent retrieval task". In: *Proceedings of NTCIR-6 Workshop Meeting on Evaluation of Information Access Technologies: Information Retrieval*, Question Answering and Cross-Lingual Information Access (pp.377-380). Tokyo, Japan.
- Graf, E.; Azzopardi, L. (2008). "A methodology for building a patent test collection for prior art search". In: *Proceedings of the 2nd International Workshop on Evaluating Information Access (EVA), December 16, 2008, Tokyo, Japan* (pp. 60–71). Retrieved January 27, 2010 from: <http://research.nii.ac.jp/ntcir/workshop/OnlineProceedings7/pdf/EVIA2008/11-EVIA2008-GrafE.pdf>
- Hideo, J. ;Azzopardi, L.; Vanderbauwhede, W. (2010)."A survey of patent users". In: *Proceeding of the third symposium on Information interaction in context, August 18-22*, (pp. 13-22). New Brunswick, New Jersey, USA, ACM doi>10.1145/1840784.1840789
- Kang, I.; et al. (2007). "Cluster-based patent retrieval". *Information Processing and Management*, 43 (5): 1173-1182.
- Lai ,K.K. ; Wu, SH.J. (2005)."Using the patent co-citation approach to establish a new patent classification system". *Information Processing and Management*, 41: 313–330.
- Li, X.; et al. (2007). "Automatic patent classification using citation network information: An experimental study in nanotechnology". In: *JCDL'07: Proceedings of the 7th ACM/IEEE-CS joint conference on Digital libraries*, (pp. 419–427): New York, NY, USA. ACM. doi>10.1145/1255175.1255262
- Tan, P.N.; Steinbach, M.; Kumar, V. (2006). "Cluster analysis: Basic concept and algorithm". In: P.N.Tan, M. Steinbach and V. Kumar. *Introduction to Data Mining*, (pp.487-568). Boston, MA: Addison-Wesley Longman Publishing.
- tf-idf (2011, August 30). Retrieved June (?) 01(?), 2011, from Wikipedia, the free encyclopedia: <http://en.wikipedia.org/wiki/Tf%E2%80%93idf>

- Tian , X.; Tong, W. (2011). "An improvement to TF-IDF: Term distribution based term weight algorithm". *Journal of Software*, 6(3): 413-420.
- Tiwana, S.; Horowitz, E. (2009)."FindCite: Automatically finding prior art patents". In:*Proceedings of the 2nd international workshop on Patent information retrieval*, pp. 37-40. Retrieved March 03, 2011 from: http://delivery.acm.org/10.1145/1660000/1651352/p37-tiwana.pdf?ip=217.218.83.9&CFID=39566988&CFTOKEN=46635715&__acm__=1315641819_3628c1ae1982ae3f1f1f9b5747a3f756
- United States Patent and Trademark Office (USPTO) (2010). "Manual of Patent Examining Procedure (MPEP)". (eighth edition). Retrieved January 09, 2011 from: http://www.uspto.gov/web/offices/pac/mpep/pdf_download_search_instructions.doc
- Wanagiri, M. Z.; Adriani, M. (2010). "Prior art retrieval using various patent document fields contents". In: CLEF-2010(Notebook Papers/LABs/Workshops). Retrieved September 03, 2011 from: http://www.clef2010.org/resources/proceedings/clef2010labs_submission_85.pdf
- Wedding, D. K. (2009)."Extending the data mining software packages SAS enterprise miner and SPSS clementine to handle Fuzzy cluster membership: Implementation with Examples".Master of Science Thesis in Data Mining, Central Connecticut State University. Retrieved May 13, 2011 from: <http://web.ccsu.edu/datamining/Data%20Mining%20Theses/Don%20Wedding%20thesis.pdf>
- Xue, X.; Croft W. B. (2009)."Transforming patents into prior-art queries". In: *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval*, (pp. 808-809): Boston, MA, USA. ACM. [doi>10.1145/1571941.1572139]

استناد به این مقاله: کرمانی، آناهیتا؛ نشاط نرگس (۱۳۹۱). «ارزیابی زوج‌های کتابشناختی در خوشه‌بندی پروانه‌های ثبت اختراع». *فصلنامه مطالعات ملی کتابداری و سازماندهی اطلاعات*، ۲۲(۳).