

تحلیل ساختار و الگوریتم ذخیره و بازیابی اطلاعات در پایگاه‌های استنادی وبی

عبدالرسول خسروی*

عضو هیئت علمی،
دانشگاه علوم پزشکی بوشهر

رحمت الله فتاحی

استاد گروه کتابداری و اطلاع‌رسانی،
دانشگاه فردوسی مشهد

دراфт: ۱۳۸۸/۱۰/۱۵ | پذیرش: ۱۳۸۹/۰۱/۲۲

فصلنامه علمی پژوهشی
پژوهشگاه علوم و فناوری اطلاعات ایران
شمال‌آジایی ۵۲۰۶-۱۷۳۵
شایا(الکترونیکی) ۵۵۸۳-۲۰۰۸
نمایه در SCOPUS, LISA و ISC
<http://ijst.irandoc.ac.ir>
دوره ۲۶ | شماره ۲ | ۱۹۹-۲۲۲
زمستان ۱۳۸۹

چکیده: از عمدۀ تلاش‌هایی که طی سالیان اخیر برای پاسخگویی به نیازهای علمی محققان، پژوهشگران و دانشجویان در محیط وب صورت گرفته است، می‌توان به توسعه پایگاه‌های استنادی اشاره داشت که به منزله یک رویکرد جدید در ذخیره و بازیابی اطلاعات به شمار می‌آید. قابلیت‌های درخور توجه این پایگاه‌ها، امکانات بسیاری را در اختیار پژوهشگران چه در زمینه جستجو و بازیابی اطلاعات و چه در عرصه علم سنجی قرار داده است. هدف این مقاله که به روش کتابخانه‌ای و مطالعه موردنی (مشاهده مستقیم پایگاه‌ها) انجام گرفته، بررسی ساختار و قابلیت‌های جستجو و بازیابی اطلاعات در پایگاه‌های استنادی می‌باشد. این امر با تحلیل ساختار نمایه‌سازی پایگاه‌های استنادی و اینکه این پایگاه‌ها از چه سیستم‌ها و الگوریتم‌هایی برای وزن‌دهی، نمایه‌سازی و برقراری پیوند میان استنادها و تحلیل هم استنادی نویسنده استفاده می‌کنند مورد بررسی قرار گرفته است. نتایج این بررسی نشان داد که این نوع پایگاه‌ها از ساختار شبکه‌ای برخوردارند و از دو سیستم نمایه‌سازی استنادی خودگردان و پاب سرج و نیز الگوریتم مورد استفاده آن‌ها بر اساس مدل‌های وزن‌دهی و بردار فضایی و خوشه‌بندی سلسله‌مراتبی انباشتگی است، که در متن مقاله بطور مژوح به آن‌ها اشاره شده است.

کلیدواژه‌ها: نمایه‌سازی استنادی، پایگاه‌های استنادی وبی، بازیابی اطلاعات، نظام نمایه‌سازی استنادی خودگردان، سیستم پاب سرج، الگوریتم‌های ذخیره اطلاعات

* پذیدآور رابط: khosravi2422@gmail.com

1. Autonomous citation index-

2. PubSearch

مقدمه

سال‌ها پژوهشگران و دانشجویان برای یافتن اطلاعات خود از سه راهبرد مهم جستجو استفاده قرار کرده‌اند. راهبرد نخست از طریق دنبال‌کردن دستی و ساده منابعی که در تحقیقات یا موضوعات مشابه توسط دیگران مورد استفاده قرار گرفته است یا به عبارتی استنادها، بوده است. استنادها در آثار علمی جایگاه ویژه‌ای دارند. در واقع یک مقاله علمی زمانی معتبر است که به آثار و متون مرتبط با آن موضوع استناد نماید. این روش، هرچند هنوز توسط برخی از پژوهشگران مورد استفاده قرار می‌گیرد اما به دلیل محدودیت‌های فراوان از قبیل محدودیت زمانی، روزآمد نبودن، عدم دستیابی نویسنده به همه منابع موجود و برخی از موارد دیگر عملاً بطور کامل جوابگوی نیازهای پژوهشگران نیست.

راهبرد دوم مورد توجه، جستجوی کلیدوازه‌ای موضوعی در نمایه‌نامه‌ها و چکیده‌نامه‌ها و پایگاه‌های اطلاعاتی به منظور یافتن منابع مرتبط می‌باشد. این روش نیز بدلیل عدم آشنایی کامل نویسنده‌گان و محققان با راهبردهای جستجو و برخی از کاستی‌های دیگر بطور کامل پاسخگوی نیازهای محققان نبوده است. هرچند که پایگاه‌های اطلاعاتی به دلیل روزآمدی و اطلاعات نو و پویا خدمات ارزنده‌ای به محققان ارائه داده و می‌دهند.

پژوهشگرانی که این دو راهبرد نیاز آن‌ها را برآورده نمی‌ساخت به راهبرد سوم یعنی استفاده از کارشناسان موضوعی روی می‌آورند. این روش بدلیل تسلط موضوعی محقق و روزآمدی اطلاعات، از شیوه‌های موثر مورد استفاده می‌باشد، اما به دلیل محدودیت و کمبود کارشناسان و متخصصان موضوعی، استفاده از این شیوه برای همگان میسر نبوده است.

بدنبال گسترش ابزارها و شیوه‌های بازیابی اطلاعات، امروزه بسیاری از پایگاه‌های اطلاعاتی راهبرد چهارمی را پیش روی پژوهشگران قرار داده‌اند که تحت عنوان نمایه استنادی مورد توجه قرار گرفته است.

استناد بیانگر نوعی استفاده از دانش پیشین است. نوشه علمی فقط بر خود متکی نیست، بلکه بر بسیاری از منابع پیشین استوار است. نمودار شدن منبعی در سیاهه یک اثر بازگوکننده این مطلب است که در ذهن نویسنده ارتباطی میان اثر وی و مقاله‌ای که در فهرست مأخذ خود به آن استناد کرده است وجود دارد. بدین وسیله پایگاه‌های استنادی با مبنای قرار دادن استنادها شروع به نمایه‌سازی و فعالیت‌های مرتبط با آن‌ها نمودند.

می‌توان گفت مهمترین مزیت نمایه‌های استنادی در این پایگاه‌ها، توانایی ردگیری و یافتن مقالات هسته و در حقیقت شناسایی تولیدکنندگان مقاله‌های علمی است. هرچند می‌توان به لحاظ تاریخی، اساس و سابقه طولانی مقوله استناد را در میان مسلمانان نیز یافت که به واسطه علم‌الحدیث

و بحث شناسایی روات و سلسله احادیث از قدیم علماء و بزرگان ما اهمیت زیادی به این مباحث می دادند (حری، ۱۳۸۵)، ولی ضوابطی مدون که بتوان آنها را مبانی نظری چنین امری تلقی کرد، وجود ندارد.

بحث ایجاد پایگاههای استنادی وب پایه برای اولین بار در سال ۱۹۹۵ به عنوان تنها پایگاه جهانی ISI توسط گارفیلد شروع شد (نوروزی، ۲۰۰۵). امروزه پایگاهها و نمایههای استنادی چنان رشدی نموده است که به عنوان یکی از ارکان پژوهش و تولید علم در هر کشوری مورد توجه قرار گرفته است. به رغم جایگاهی که این پایگاهها در بین محققان دارند، آنچه که مورد توجه کتابداران و نمایهسازان است نحوه و ساختار ذخیره و بازیابی اطلاعات موجود در این پایگاههای است و این که چنین پایگاههایی از چه الگوریتمهایی برای ذخیره و بازیابی اطلاعات خود استفاده می کنند، چگونه فیلدهای مختلف به هم ربط پیدا نموده و سبب بر جسته شدن این نوع پایگاهها در ردگیری استنادها گردیده است. از این رو، هدف اصلی این مقاله، بررسی ساختار ذخیره و بازیابی اطلاعات در پایگاههای استنادی است تا ضمن تحلیل ساختار و الگوریتم ذخیره و بازیابی اطلاعات در پایگاههای استنادی و بی به این نکته پردازد که پایگاههای استنادی امروزه از چه الگوریتم ها، راهبردها و شیوههایی برای ذخیره و بازیابی اطلاعات کتابشناختی استفاده می کنند.

بر این اساس، پرسش های زیر مورد توجه پژوهش حاضر می باشد:

۱. پایگاههای استنادی و بی از چه قابلیت هایی برای جستجو و بازیابی اطلاعات برخوردارند؟
۲. پایگاههای استنادی و بی از چه سیستم ها و الگوریتم ها و روش هایی برای ذخیره و بازیابی (ردگیری) اطلاعات استنادی استفاده می کنند؟

روش مورد مطالعه

این پژوهش با استفاده از روش مطالعه موردي، مشاهده مستقيم و تحليل پایگاهها و نيز مطالعه کتابخانه اي انجام گردید. بدین صورت که در روش مطالعه موردي، به مشاهده مستقيم پایگاهها، و تحليل قابلیت های جستجو و بازیابی اطلاعات در زمینه چگونگی نمایهسازی استنادی پرداخته شد. امكانات هر يك از پایگاهها، نحوه نمایش اطلاعات و قابلیت های بازیابی مورد شناسائی قرار گرفت. سپس برای تحليل الگوریتم ها و نظام های نمایهسازی از روش مطالعه کتابخانه اي استفاده گردید. از طریق بررسی متون، نظام های ذخیره و بازیابی و هچنین الگوریتم های مورد استفاده و روش های نمایهسازی مورد شناسائی و بررسی قرار گرفت.

پایگاههای مورد بررسی در این پژوهش شامل سه پایگاه استنادی سایت سیر^۱، آی اس آی^۲ و اسکوپوس^۳ می باشد

1. CiteCeer

2. ISI Web of Knowledge

3. Scopus

پیشینه پژوهش

مطالعات انجام گرفته در داخل کشور نشان می‌دهد که در خصوص الگوریتم‌های ذخیره و بازیابی اطلاعات تحقیقات و نوشهای منسجم و جامعی وجود ندارد. اما به طور کلی در خارج از ایران مطالعات گوناگونی در زمینه الگوریتم‌های پایگاه‌های اطلاعاتی انجام گرفته است.

کامرون^۱ (۱۹۹۷) یک پایگاه استنادی و کتابخانه‌ی جهانی مبتنی بر وب پیشنهاد داد که این پایگاه قادر باشد که به هر اثر علمی نوشته شده و استنادهای آن ارتباط برقرار کند. وی پیشنهاد کرد این پایگاه در سطح جهانی و از طریق اینترنت در دسترس همگان باشد.

گیلز^۲ (۱۹۹۸) نتایج آزمایش خود را که بر روی سایت سیر انجام داده بود، در مقاله‌ای تحت عنوان «سایت سیر: سیستم نمایه‌سازی استنادی خودکار» به تشریح کار این سیستم پرداخته و بطور مفصل الگوریتم‌ها و کارکردهای این سیستم اشاره داشته است. عمدۀ ویژگی‌های این سیستم را صرفه‌جویی در زمان، خودکاربودن و مرور محتوی استنادها می‌داند. همچنین در این مقاله توانائی‌های این سیستم را تشریح می‌کند.

بولاکر^۳ (۱۹۹۸) در مقاله‌ای تحت عنوان «سایت سیر: واسط خودکار برای بازیابی خودکار و تعیین انتشارات مورد علاقه» سایت سیر را به عنوان یک واسط کمکی خودکار در ارتقاء فرآیند یافتن انتشارات علمی بر روی وب سیار سودمند می‌داند.

هی^۴ (۲۰۰۱) نیز در مقاله «باب سرچ: سیستم بازیابی مبتنی بر استناد وبی^۵ به چگونگی کارکرد این سیستم در خصوص جستجوی خوش‌ای مدرک و هم استنادی نویسنده و معماری و نیز سایر کارکردها اشاره کرده است.

هی^۶ (۲۰۰۲) نیز در مقاله «واکاوی یک پایگاه استنادی برای خوشبندی مدرک» یکی از راههای نمایه‌سازی متون در وب را نمایه‌سازی از طریق پایگاه‌های استنادی می‌داند. وی یک فرآیند واکاوی به منظور استخراج دانش خوش‌ای مدرک از پایگاه‌های استنادی به منظور پشتیبانی از بازیابی اطلاعات در وب را پیشنهاد می‌کند. وی تکنیک‌های واکاوی استفاده شده برای ایجاد خوش‌های مدرک مبتنی بر نقشه خود-سازماندهی کوهن^۶ (KSOM) و تئوری رزونانس تطبیقی فازی^۷ می‌داند. وی تکنیک‌های پیشنهادی را که ترکیب شده و یک سیستم به نام PubSerach برای انتشارات علمی و بی‌معرفی می‌کند.

هی (۲۰۰۲ب) همچنین در مقاله‌ای دیگر «واکاوی یک پایگاه استنادی برای تحلیل هم استنادی نویسنده» یک فرآیند واکاوی خودکار برای تحلیل هم استنادی نویسنده (ACA) مبتنی بر پایگاه‌های استنادی پیشنهاد می‌کند. سیستم کارآ برای این منظور PubSearch معرفی می‌کند.

1. Cameron

2. Giles

3. Bollacker

4. He

5. PubSearch: a web citation – based retrieval system

6. Kohonen's self organization Map

7. Fuzzy Adaptive Resonance Theory

بررسی متون نشان می‌دهد که پایگاه‌های استنادی مورد توجه پژوهشگران قرار گرفته است. پایگاه‌های استنادی نیز برای فراهم آوردن زمینه‌های استفاده پژوهشگران از سیستم‌های نمایه‌سازی استنادی خود کار استفاده می‌کنند. همچنین برای بازیابی دقیق‌تر از الگوریتم‌های وزن‌دهی و خوشبندی هم استنادی نویسنده‌گان و مدرک استفاده می‌کنند. بر این اساس، مطالعه حاضر، که نخستین مورد در زبان فارسی است، می‌تواند برای کتابداران و نیز متخصصان علوم رایانه در ایران سودمند باشد.

نمایه استنادی

نمایه استنادی، شامل فهرستی از مقالات و نمایه‌های مرتبط با آن مانند نویسنده‌گان و کلیدواژه‌های موضوعی هریک از مقالات منتشر شده‌ای است که به آن مقالات استناد کرده‌اند. به عبارت دیگر، در مورد یک مقاله خاص، نمایه استنادی مشخص می‌کند که این مقاله به کدام منابع پیش از خود استناد کرده و همچنین بعدها توسط چه مقالات دیگری که پس از آن منتشر شده‌اند، مورد استناد قرار گرفته است. در واقع، از نمایه‌های استنادی بصورت شبکه استنادی و جایگاه هر مقاله به منزله یک گره در این شبکه یاد می‌شود. این نوع نمایه، علاوه بر بازنمون محتوایی، ارتباط یک مدرک را با مدرک دیگر از طریق استنادها مشخص می‌کند. از طریق ردگیری استنادها می‌توان ارزش مقاله‌های علمی را به لحاظ میزان استفاده از آن مشخص کرد (حسن زاده و نوروزی چاکلی، ۱۳۸۷). در این نوع نمایه‌سازی، مقاله استناد شده بوسیله مأخذ استناد مشخص می‌شود (گارفیلد، ۱۹۶۴). نمایه‌های استنادی در اصل برای بازیابی اطلاعات ایجاد شدند (گارفیلد، همان). نمایه استنادی امکان ردیابی گذشته‌نگر (فهرست مقالات استناد شده) و آینده‌نگر (مقالات بعدی که به مقاله‌ای معین استناد کرده‌اند) را فراهم می‌سازد.

از نمایه‌های استنادی به منظورهای مختلفی می‌توان بهره جست؛ مثلاً:

- الف) استنادها به بازیابی به منزله سرنخ‌هایی برای شناسائی مقالات مرتبط استفاده می‌شود؛
- ب) جایگاه استنادها در انتشارات استناد کننده می‌تواند در قضاوت پیرامون سهم عمده یک مقاله استناد شده و مناسب آن با درخواستی معین مفید باشد (گارفیلد، ۱۹۹۴، سالنون ۱۹۷۱)؛
- ج) نمایه استنادی با تعیین جایگاه و تعداد دفعات استناد به مقاله‌ای خاص در متون، به منزله شاخص اهمیت آن مقاله به شمار می‌رود؛
- د) نمایه استنادی تحلیل عمقی تحولات پژوهشی را امکان‌پذیر و حوزه‌های نوپدید علمی را شناسایی می‌کند.

پایگاه‌های استنادی وی

امروزه حجم انبوه اطلاعات، به ویژه اطلاعات موجود در شبکه جهانی وب، موجب ظهور شیوه‌های جدیدی در بازیابی اطلاعات گردیده است. یکی از جنبه‌های مهم ظهور و گسترش وب، ایجاد پایگاه‌های استنادی بود که به دلیل ماهیت پویا و ویژگی‌های منحصر به فرد وب، در ساختار آن‌ها تغییراتی نسبت به نمایه‌های چاپی ایجاد شده است.

نمایه‌های استنادی در پایگاه‌های استنادی وی برای جستجو و بازیابی اطلاعات به عنوان یک منبع ارزشمند تلقی می‌شود. عمدۀ پایگاه‌های شناسائی شده که بیشتر مورد توجه محققان قرار می‌گیرد عبارتند از: سایت سیر^۱، اسکوپوس^۲، آی اس آی^۳. هر چند برخی از پایگاه‌ها و موتورهای جستجوی دیگر هستند که قابلیت‌های پایگاه‌های استنادی را به عنوان امکانات دیگر به قابلیت‌های خود افزوده‌اند مثل: گوگل اسکالر (دانشوران)^۴. بطور کلی پایگاه‌های استنادی وی مجموعه‌ای از داده‌های استنادی را در مخزن خود جمع آوری نموده و برای ذخیره و نمایه‌سازی آن‌ها از تکنیک‌ها و الگوریتم‌های متفاوتی استفاده می‌کنند.

پاسخ به پرسش‌های پژوهش

۱. پایگاه‌های استنادی وی از چه قابلیت‌هایی برای جستجو و بازیابی اطلاعات برخوردارند؟
در بررسی وضعیت جستجو در پایگاه‌های استنادی نظری اسکوپوس، آی اس آی و سایت سیر عمدۀ قابلیت‌های شناسائی شده آن‌ها در دو مقوله جستجو و بازیابی تقسیم گردید، که عمدۀ قابلیت‌ها و امکانات در جدول شماره ۱ و جدول ۲ آمده است. همانگونه که جدول‌های زیر نشان می‌دهند، برخی از امکانات جستجو مورد استفاده همه پایگاه‌های اطلاعاتی است، اما برخی از امکانات به طور خاص تنها در برخی پایگاه‌های استنادی به لحاظ کارکردشان تعییه شده است.

جدول شماره ۱: بررسی امکانات و قابلیت‌های جستجو در پایگاه‌های مورد بررسی

نام پایگاه	ساده	پیشرفته	نویسنده	مراجع	سازمانی	مرور	تاریخچه جستجو	سیستم هشدار	آنالیزور مجلات
اسکوپوس	✓	✓	✓		✓	✓	✓	✓	✓
آی اس آی	✓	✓	✓	✓	✓	✓	✓	✓	✓
سایت سیر				✓	✓	✓			✓

جدول شماره ۲: بررسی امکانات و قابلیت‌های بازبایی و شیوه نمایش در پایگاه‌های مورد بررسی

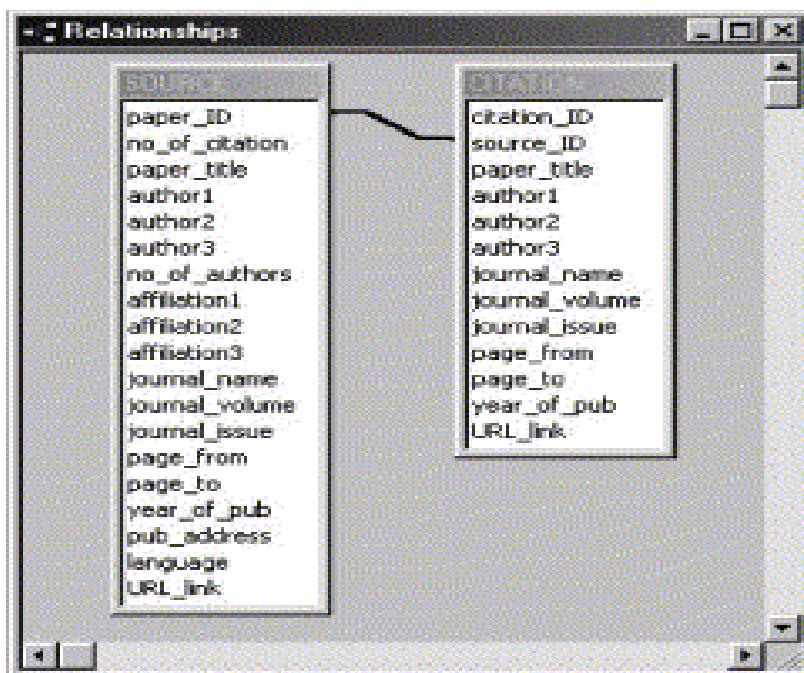
کشور	زبان	ردگیری استناد	ردگیری موسسات	نویسنده‌گان	نوع مدرک	حوزه‌های موضوعی	عنوان منبع	اولین نویسنده	تعداد استناد	دیجیت	تاریخ دیجیت	نام پایگاه
✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	اسکوپوس
		✓		✓	✓	✓	✓	✓	✓	✓	✓	آی اس آی
										✓		سایت سیر

۲- پایگاه‌های استنادی و بی از چه سیستم‌ها و الگوریتم‌ها و روش‌هایی برای ذخیره و بازبایی (ردگیری) اطلاعات استنادی استفاده می‌کنند؟

به طور معمول، سازماندهی فایل در نمایه‌های استنادی نیز همچون پایگاه‌های دیگر بر مبنای اصل فایل مقلوب انجام می‌شود (پائو، ۱۳۷۸). در نمایه‌های استنادی دو فایل اصلی وجود دارد: نمایه مأخذ^۱، نمایه استنادی^۲. نمایه مأخذ در بردارنده توصیف کامل کتابشناختی همه مقاله‌های نمایه‌شده می‌باشد. این نمایه بر اساس نام نویسنده‌گان اصلی الفبایی می‌شود. نمایه استنادی فایلی است که بر اساس آن نام نویسنده‌گان مقاله‌ها (یعنی مقاله‌هایی که توسط مقاله‌های اصلی در نمایه مأخذ مورد استناد قرار گرفته‌اند) تنظیم یافته است. این نمایه به منزله فایل مقلوب نمایه مأخذ عمل می‌کند. ساختار پیشینه‌های مربوط به مدارک مأخذ شامل فیلدهای معمولی یعنی نویسنده، عنوان، مجله و مانند آنهاست. نمایه استنادی فایل را بر اساس عناصر داده‌ای که در مأخذ استناد شده موجود است مقلوب می‌کند. برای جستجوی نمایه استنادی قالبی استنادارد به کار گرفته می‌شود. بطور کلی، ساختار نمایه‌های استنادی از سازماندهی مشخصات کامل انواع اطلاعاتی که باید در فایل‌های جداگانه انباسته شود تشکیل می‌شود که این اطلاعات شامل مقدار داده‌های ذخیره شده در هر پیشینه، ساختار پیشینه، رابطه میان عناصر مختلف داده‌ها، امکان ذخیره فایل، چگونگی ذخیره پیشینه‌ها تشکیل شده است. بسیاری از پایگاه‌های استنادی نظریه ISI برای ذخیره‌سازی استنادها از جدول‌هایی استفاده می‌کنند(هی ۲۰۰۱).

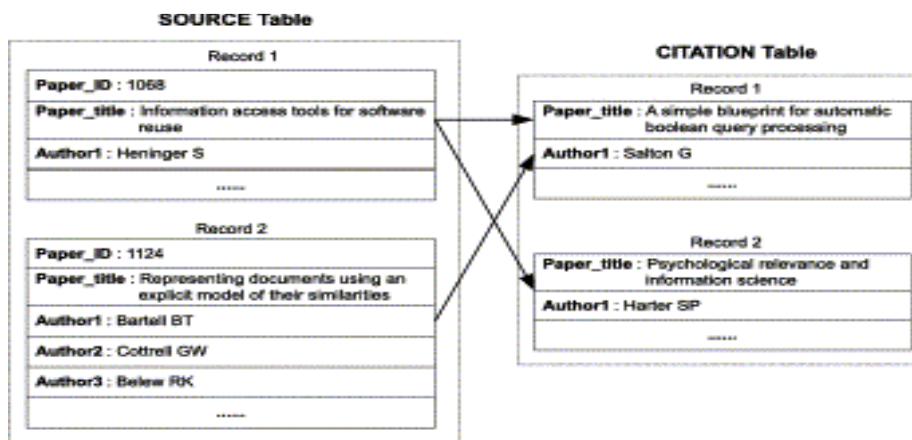
هی (۲۰۰۱) همچنین در مقاله‌ای تحت عنوان «واکاوی پایگاه استنادی برای تحلیل هم استنادی نویسنده» به این نکته اشاره می‌کند که پایگاه استنادی از دو جدول منبع^۳ و جدول استنادها^۴ برای برقراری ارتباط بین استنادهای منابع استفاده می‌کند. جدول منبع، اطلاعات کتابشناختی مقالات و

جدول استناد، استنادهای استخراج شده از منابع مورد استفاده در مقالات شامل می‌شود. عمدۀ خصیصه‌های دو جدول داده‌های تعریف شده مشخصی نظری عنوان مقاله، نام نویسنده، نام مجله، جلد، شماره، صفحه و سال انتشار در بر می‌گیرد. لینک URL نشانی مکان یاب وبی مدرک است که از این طریق امکان دسترسی به متن کامل فراهم می‌کند. ID مقاله در جدول منبع و ID استناد در جدول استناد از کلیدهای اصلی به ترتیب در این دو جدول به شمار می‌روند. ID Source از جدول استناد با Paper ID پیوند می‌خورد، تا نشان دهد که به مقاله خاصی که در جدول استناد ذخیره شده است، استناد کرده است. همانطوریکه در تصویر شماره ۱ نشان داده شده است، اکثر فیلدهای جدول منبع با جدول استناد با هم مشابه هستند. همچنین باید یادآور شد که فقط سه نویسنده اول در پایگاه استنادی ذخیره شده‌اند، زیرا فرض بر این است که نویسنده چهارم دخالت کمتری داشته است.



تصویر ۱. ساختار پایگاه از پایگاه استنادی وبی (منبع: He, 2000)

نمونه‌ای از پیشینه‌های ذخیره شده در جدول منبع و استناد در تصویر شماره ۲ نشان داده شده است. همانطور که می‌بینید ارتباطات در این پیشینه‌ها چند به چند است.



تصویر ۲: نمونه‌ای از پیشنهادهای ذخیره شده در منبع و استناد که مبتنی بر مقالات بازیابی شده در حوزه بازیابی اطلاعات (IR) ایجاد شده است

با توجه به ساختار کلی نمایه‌های استنادی، خط مشی پایگاه‌های استنادی در ارتباط با نمایه‌سازی شامل موارد زیر است که این عملیات بصورت خودکار انجام می‌گیرد. وجود یک یا چند سرور دارای برنامه‌های نرم‌افزاری روبات، نیز شیوه‌ها و راهبردها و تکنیک‌های نمایه‌سازی در پایگاه‌های استنادی و بی به منظور اقدامات زیر مورد نیاز است:

- مرور منابع و استنادها و پیوندهای آنان و تجزیه مقالات برای یافتن استنادها؛
- نمایه‌سازی فیلدها؛
- نمایه‌سازی استنادها و مراجع؛
- مرتبط کردن استنادها به هم؛
- انتخاب کلید واژه‌ها بر اساس الگوریتم خاص؛
- ارسال آن‌ها به پایگاه خاص و مرتب‌سازی آن‌ها؛
- برقراری لینک به مقالات و وزن‌دهی آن‌ها؛
- آماده شدن نمایه برای جستجو.

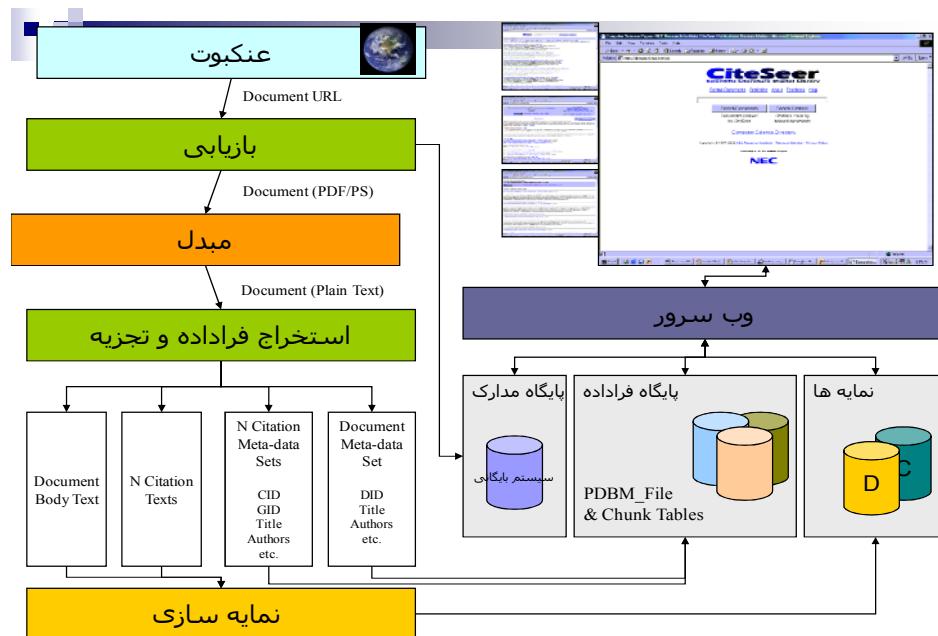
sisteme‌های نمایه‌سازی استنادی خودکار شناسائی شده در پایگاه‌های استنادی

اکثر موئورهای کاوش و پایگاه‌های استنادی به دلیل ماهیت تجاری بودن، الگوریتم‌های نمایه‌سازی خود را به راحتی در اختیار کاربران قرار نمی‌دهند. ما برای شناسائی سیستم‌های نمایه‌سازی خودکار از متون مربوطه استفاده کردیم. آنچه که از مطالعه تحقیقات و بررسی‌های دیگران بدست آمده است (گیلز، ۱۹۹۸، هی، ۲۰۰۲) نشان می‌دهد که تاکنون پایگاه‌های استنادی از

دو سیستم برای نمایه‌سازی استفاده می‌کنند. یکی از این سیستم‌ها ACI یا سیستم نمایه‌سازی خودکار که یکی از عمده‌ترین آن‌ها مورد استفاده Citseer است و دیگری PubSearch است که مورد استفاده قرار گرفته است.

۱. نمایه‌سازی استنادی خودگردان^۱ (ACI)

بررسی‌های انجام گرفته توسط گیلز (۱۹۹۸)، لورنس^۲ (۱۹۹۸) و لورنس (۱۹۹۹) نشان می‌دهد که پایگاه‌های استنادی سایت سیر و آس آی از نظام نمایه‌سازی استنادی خودگردان برای ذخیره و بازیابی اطلاعات استفاده می‌کنند. این نظام قادر است از متونی که الکترونیکی هستند، به صورت خودکار یک نمایه استنادی ایجاد کند. موقفيت این نظام به توانایی آن در انجام درست این فعالیت‌ها بستگی دارد. همانطور که در تصویر ۳ نشان داده شده است، نمایه‌سازی استنادی خودگردان، به همین شیوه مقالات را از وب دانلود کرده و در صورت لزوم به صورت متن برمی‌گرداند. سپس برای استخراج استنادها و زمینه‌ای که این استنادها در مجموعه‌ای از مقالات تحت آن زمینه ایجاد شده‌اند، آن مقالات را تقطیع (تجزیه) می‌نماید و این اطلاعات را در یک پایگاه اطلاعاتی ذخیره می‌کند. البته این نظام کلیدواژه‌ها را بر اساس الگوریتم خاص جدا و به آن‌ها مقدار، یا به عبارتی، وزن داده و سپس در نمایه‌های مربوطه قرار می‌دهد. نمایه‌سازی خودگردان در واقع از یک ساختار شبکه‌ای برخوردار است که همه استنادها را به هم مرتبط و وزن‌دهی می‌کند. نظام مشتمل بر مقاله تمام متن و نمایه‌سازی استنادی است و امکان شناسایی مقالات را از طریق جستجوی کلید واژه‌ای و یا پیوندهای استنادی فراهم می‌کند. این نظام همچنین انواع مقالات مرتبط به یک مقاله خاص را از طریق اطلاعات استنادی مشترک و یا تشابه کلمات جایابی می‌کند. آنچه که در ابتدای این فرآیند اهمیت دارد شناسایی مدارک در سیستم نمایه‌سازی استنادی خودگردان است.



تصویر ۳. نمایش ساختار کلی نمایه‌های استنادی

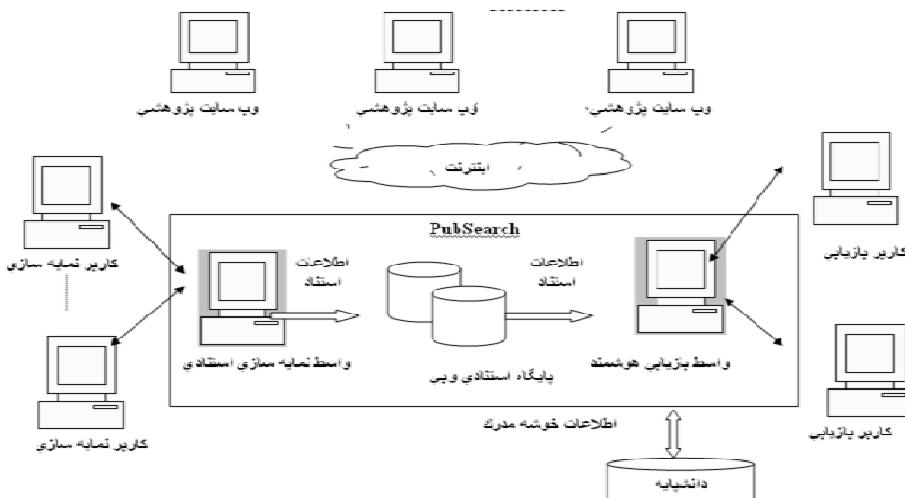
۲. سیستم نمایه‌سازی Pubsearch

این سیستم شامل سه مولفه یعنی واسط نمایه‌سازی استنادی^۱، پایگاه استنادی وبی^۲ و عامل بازبایی هوشمند^۳ می‌باشد. دو شیوه برای ایجاد نمایه‌های استنادی بوسیله واسط نمایه‌سازی استنادی استفاده شده است. اولین شیوه شبیه سایت سیر است که از موتورهای جستجو برای مکان‌یابی کلیدوازه‌های انتشارات علمی در وب سایت‌ها استفاده می‌کند و شیوه دیگر استفاده از وب سایت‌های خاصی که توسط کاربران مورد استفاده قرار گرفته است. واسط نمایه‌سازی از هر شیوه که استفاده نمود ابتدا انتشارات علمی از وب را دانلود کرده و سپس فایل‌های پی‌دی‌اف^۴ و پست اسکریپت^۵ را به داده‌های متنی تبدیل و سپس بخش کتابشناختی را بوسیله جستجوی کلیدوازه‌های «Bibliography» و «References» مشخص می‌کند. در نهایت بخش کتابشناختی را تقطیع نموده و اطلاعات استنادی را استخراج و در پایگاه استنادی ذخیره می‌کند. در پایگاه استنادی دو جدول استناد و منبع ایجاد شده است که در جدول منبع، اطلاعات کتابشناختی استخراج شده توسط

1. Citation indexing database
3. Intelligent retrieval agent
5. Postscript

2. Web citation database
4. PDF

واسط نمایه‌سازی استنادی ذخیره میگردد و در جدول استناد، اطلاعات استنادی استخراج شده در آن ذخیره می‌گردد، که در بخش ساختار پایگاه‌های استنادی بطور مفصل اشاره شد. بخش سوم این سیستم یعنی واسط بازیابی هوشمند به تکنیک‌های خوشه‌بندی پایگاه‌های استنادی برای ایجاد خوشه‌های استناد علاوه بر خوشه‌های نویسنده اشاره دارد (هی، ۲۰۰۱). این سیستم همچنین خوشه‌بندی از مدرک علاوه بر خوشه‌های هم استنادی نویسنده نویسنده را بر اساس کلیدواژه‌های پیدا شده در استنادها ایجاد می‌کند. بدین ترتیب ممکن است کاربری کلیدواژه دقیق را وارد نکند، منتها بتواند با یک کلیدواژه دیگر از طریق خوشه‌بندی به نتایج دیگری که بعضاً با کلیدواژه‌های وی همخوانی داشته باشد، دسترسی پیدا کند. نمایی از سیستم در تصویر شماره ۴ نشان داده شده است.



تصویر شماره ۴: تصویر سیستم (He,2001) PubSearch

شناسایی مدارک در نظام نمایه‌سازی استنادی خودگردان

نظام نمایه‌سازی استنادی خودگردان می‌تواند با جستجوی وب، یا با برقراری پیوند مستقیم با ناشران، مقالات را شناسایی و بازیابی کند. جستجوگران در صورت آشنایی با سیستم‌های نمایه‌سازی استنادی خودگردان می‌توانند مستقیماً از پایگاه‌های مربوطه، به مقالات جدید دسترسی

یابند و این امر با نمایه شدن نسبتاً فوری این مقالات محقق می‌شود. مجلات نوعاً برای دسترسی به مقالات پیوسته (آنلاین) طلب هزینه [اشتراک] می‌کنند و بنابراین، یکی از راه‌های نمایه کردن این مقالات انجام توافقاتی با خود ناشران است. نمایه‌سازی استنادی خودگردان با تورق‌پذیر کردن آسان و سریع بستر استنادها و نیز با نمایه‌سازی گزارش‌های فنی، مقالات کنفرانس‌ها و دیگر متونی که اغلب زودتر از مقالات مجلات در دسترس قرار می‌گیرند، به ارزیابی اهمیت تک تک آثار کمک می‌کند.

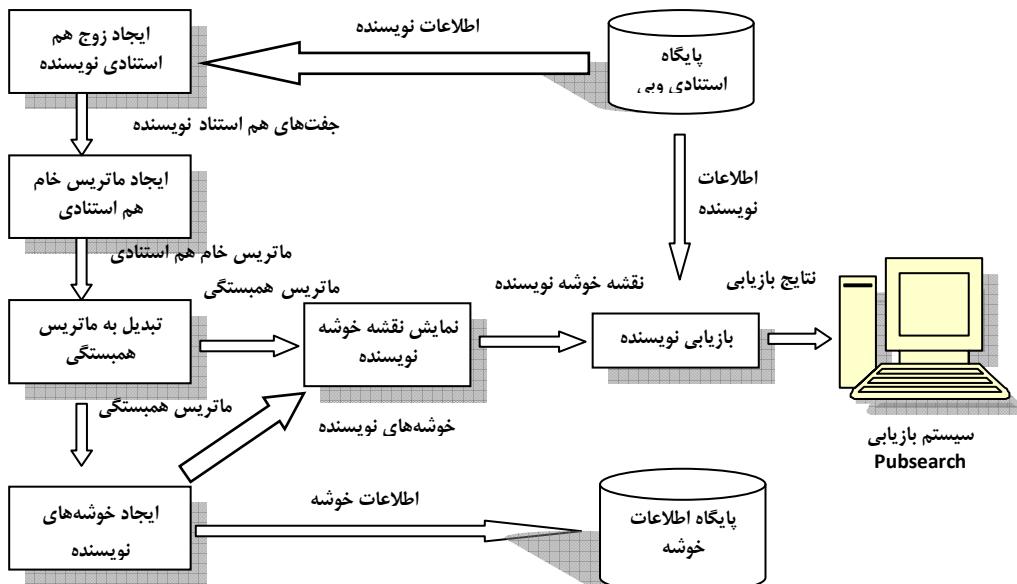
فرآیند واکاوی هم استنادی نویسنده در پایگاه‌های استنادی

تحلیل هم استنادی نویسنده به عنوان یک شیوه تحلیل ساختار فکری مطالعات علمی به طور گسترده مورد استفاده قرار گرفته است. از تحلیل هم استنادی نویسنده می‌توان برای شناسائی نویسنده‌گان هم استناد که تحقیقات موضوعی مشابه و یکسانی دارند، استفاده نمود. تحلیل هم استنادی نویسنده یعنی اینکه دو نفر که از یک مقاله استفاده کنند و در مقالاتشان به آن استناد نمایند. در گذشته از ابزارهای آماری نظری SPSS برای این منظور استفاده می‌شد (لارسون^۱، پری و رایس^۲، ۱۹۹۸، وایت و مک کین^۳، ۱۹۹۸، به نقل از: هی، ۲۰۰۲).

به عنوان مثال، وقتی در یکی از پایگاه‌های استنادی نظری اسکوپوس یا برخی از پایگاه‌های دیگر جستجوی موضوعی انجام می‌دهید، در قسمت نمایش نتایج جستجو لیست شماری از نویسنده‌گان را مشاهده می‌نمایید که به عنوان نویسنده‌گان کلیدی موضوعات می‌باشد. پایگاه‌های استنادی از فرآیند واکاوی هم استنادی نویسنده برای نمایش و رتبه‌بندی در پایگاه‌های خود استفاده می‌کنند. این فرآیند بطور کامل بر اساس پژوهش (He, 2002) در تصویر شماره^۴ نمایش داده شده است. همچنین بر اساس همان پژوهش، الگوریتم خوشبندی سلسله‌مراتبی انباستگی^۵ (AHC) برای ماتریس همبستگی و ایجاد خوشه‌های هم استنادی نویسنده در پایگاه‌های استنادی استفاده می‌شود. در مرحله آخر اطلاعات خوشه‌ای نویسنده هم استنادی برای بازبایی پرسش‌های کاربران مبتنی بر بازبایی نویسنده در سیستم Pubsearch ترکیب شده است. جستجو از کلیدواژه‌های موضوعی و نویسنده‌گان در پایگاه‌های استنادی نظری^۶ و SCOPUS نمونه‌ای از نمایش دسته‌های نویسنده‌گان در یک حوزه خاص قابل مشاهده و استفاده است.

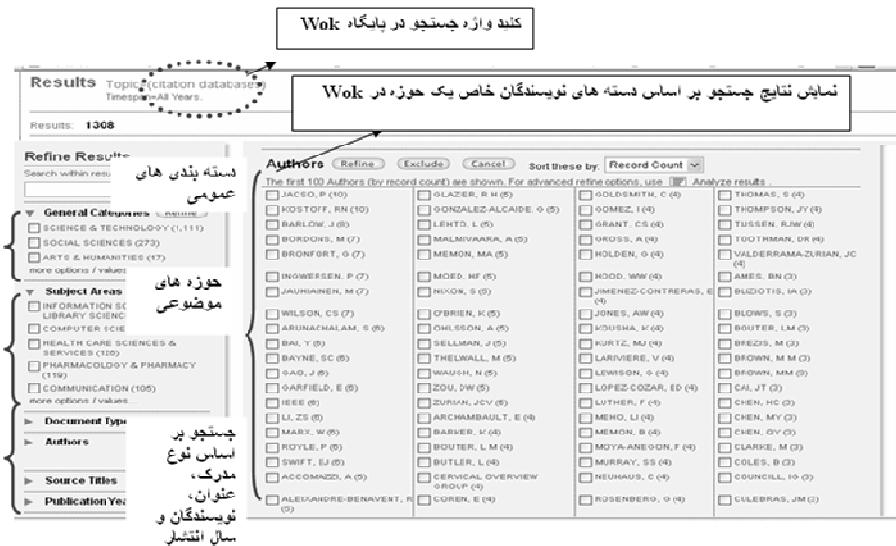
1. Larson
3. White & MacCmin
5. Web of Knowledge

2. Perry & Rice
4. Agglomerative hierarchical clustering (AHC)



تصویر شماره ۵: فرآیند واکاوی هم استنادی نویسنده (He, 2002)

در تصویر شماره ۶، نتایج جستجوی کلیدواژه «Citation Indexing» را در پایگاه Wok نشان می‌دهد. در این جستجو ۱۳۰۸ مدرک به عنوان نتیجه نمایش داده شده است. در سمت چپ صفحه نتایج، امکان استفاده از دسته‌های موضوعی و نویسنده وجود دارد که با کلیک بر روی «Author» امکان نمایش نویسنده‌گان آن موضوع با تعداد استنادها ایجاد می‌شود که نشان می‌دهد نویسنده‌گان این حوزه موضوعی که در این پایگاه مقاله دارند، چه کسانی هستند و شیوه نمایش به ترتیب الفبائی و تعداد استناد می‌باشد که در این تصویر بر اساس تعداد استناد نمایش داده شده است. برای نمونه در جستجویی که در پایگاه استنادی Wok در خصوص کلیدواژه «Citation indexing» انجام گرفت، بدین ترتیب کاربرانی که از طریق نویسنده‌گان، نتایج را دنبال می‌کنند، می‌توانند نویسنده‌گانی را که در آن حوزه کار کرده‌اند، شناسائی و به ردگیری هر یک از آن‌ها اقدام نمایند. نمونه‌ای از این کار کرد را در تصویر شماره ۵ می‌توان مشاهده کرد.



تصویر شماره ۶: نمایش نتیجه جستجو در پایگاه Wok

با بررسی شیوه نمایش نتایج جستجو در برخی از پایگاه‌های استنادی، مشاهده گردید که در رتبه‌بندی نتایج بر اساس تعداد استنادها، نویسنده سازمانی، نویسنده اول، حوزه‌های موضوعی و نوع مدرک در پایگاه‌های استنادی وضعیت مشابهی دارند. با این توصیف بنتظر می‌رسد که پایگاه‌های استنادی از الگوریتم‌ها و روش‌های مشابهی باید استفاده کرده باشند، تا شاهد چنین رتبه‌بندی در نمایش نتایج جستجوی این پایگاه‌ها باشیم. برای این منظور در این پژوهش در مرحله بعدی ما به دنبال بررسی انواع الگوریتم‌های بکار رفته در این پایگاه‌ها بودیم، تا بدانیم که هر یک از پایگاه‌ها برای نمایش انواع رتبه‌بندی نتایج از چه الگوریتم‌هایی برای ذخیره اطلاعات استفاده کرده‌اند.

عمله الگوریتم‌های شناسائی شده مورد استفاده پایگاه‌های استنادی که از بررسی متون بدست آمده است، عبارتند از:

۱- الگوریتم‌های وزن دهندهٔ

برای تشریح الگوریتم‌های پایگاه‌های استنادی، بطور خاص الگوریتم‌های وزن‌دهی از نتایج

۱. بخش عمده‌ای از الگوریتم وزن‌دهی از نتایج مطالعات گیلز استخراج گردیده است.

مطالعات گیلز که بر روی سایت سیر انجام داده است استخراج شد. استفاده از الگوریتم‌های وزن‌دهی برای این است که نتایجی به کاربران ارائه دهد که بتوانند رتبه‌بندی‌هایی را بر اساس بسامد استناد به نویسنده، ردگیری استنادها، ردگیری موضوعات مورد جستجو و ردگیری نویسنده‌گانی که به هم استناد می‌کنند، انجام دهند. عمدۀ مطالب این بخش حاصل نتایج مطالعات گیلز می‌باشد که به روش کتابخانه‌ای گردآوری شده است و بدنبال می‌آید:

گیلز (۱۹۹۸) ^۴ روش را که نرم‌افزار نمایه‌سازی استنادی برای آزمون شناسایی موارد مختلف استنادها به مقالات واحد به کار می‌برند، مطرح می‌کند. هرچند در مقاله خود روش چهارم را بدليل مشکلاتی که دارد یک روش ضعیف قلمداد می‌کند. روش‌های مذکور عبارتند از:

۱. خط مبنای ساده^۱: روش خط مبنای ساده‌ای که در تمامی استنادها قابل استفاده باشد، حداکثر تعداد کلمات هر استناد را که با یک استناد قبلی انتباط داشته و بر حسب طول استناد کوتاه‌تر نرمال‌سازی شده باشد، به دست می‌آورد. اگر این تعداد بیشتر از یک حد آستانه^۲ باشد، استناد جدید همچون استناد قبلی در حکم استناد به مقاله‌ای واحد تلقی می‌گردد و این استناد جدید به همراه استناد قبلی گروه‌بندی می‌شود و گرنۀ برای آن گروه جدیدی در نظر می‌گیریم.

۲. انتباط و اژگانی^۳: الگوریتمی شبیه به الگوریتم خط مبنای ساده است که در ابتدا استنادها را بر طبق طول آنها از بلندترین به کوتاهترین مرتب می‌کند.

۳. انتباط عبارتی و اژگانی^۴: نوعی الگوریتم انتباط و اژگانی است که توالی دو کلمه را در هر فیلد فرعی به عنوان اصطلاحی واحد در فرآیند انتباط در نظر می‌گیرد؛ به عبارت دیگر این الگوریتم نظمی برای کلمات در نظر می‌گیرد که در الگوریتم‌های پیشین به آن توجهی نمی‌شود. حدۀای آستانه‌ای جداگانه‌ای برای انتباط‌های یک کلمه‌ای و دو کلمه‌ای به کار می‌روند.

۴. روش لیکلت^۵: لیکلت نوعی شکل پیچیده فاصله ویرایشی است که در صدد انتباط وزن‌دهی شده بهینه به حروف و مولتی گراف‌هاست (گروهی از حروف). لیکلت بین دو استناد سنجه فاصله را در نظر می‌گیرد. در این روش استناد‌بدست می‌آید. اگر این فاصله کمتر از حد آستانه باشد، آن استناد یکسان و واحد در نظر گرفته شده و به گروه قبلی اضافه می‌شود و گرنۀ، گروه جدیدی ایجاد می‌گردد.

همچنین گیلز (۱۹۹۸) و بولاکر (۱۹۹۸) مطالعه و آزمایشی بر روی سایت سیر انجام داده‌اند که نتایج آن‌ها در مورد الگوریتم‌های مختلف وزن‌دهی در زیر نشان داده شده است:

1. Baseline Simple
3. Word Matching
5. Likelt

2. Threshold
4. Word and Phrase Matching

۱-۱. سنجه‌های فاصله‌ای

نتایج بررسی آن‌ها نشان می‌دهد که نرم‌افزار پایگاه‌های استنادی نظیر سایت سیر از سنجه‌های متفاوتی برای محاسبه فاصله (و برعکس، تشابه) بین یک جفت مدارک (رشته‌های متنی) استفاده می‌کنند. اغلب سنجه‌های معروف فاصله بین مجموعه‌های متنی بر مدل‌های تشابه بین گروه‌های حروف موجود در متن مبتنی هستند. یک نوع از این سنجه‌ها، مبتنی بر فاصله متنی، رشتہ‌ای و ویرایشی است که فاصله را به عنوان میزان تفاوت بین شبکه‌ای از نمادها در نظر می‌گیرد. مثلاً فاصله لونشتاین^۱ (لونشتاین، ۱۹۶۵) به نقل از: گیلز، ۱۹۹۸ اولين فاصله ويرايши بسيار معروف است که در آن تفاوت بین دو رشتة متنی عبارت است از: تعداد موارد ورودی، حذفی و جایگزینی حروف مورد نیاز برای انتقال یک رشتہ به دیگری، نمونه پیچیده و نسبتاً جدید سنجه فاصله‌ای متنی، به سنجه فاصله‌ای لیکلت معروف است.

نوع دیگر فاصله رشتہ‌ای متنی مبتنی است بر آمار کلماتی که در مجموعه‌هایی از مدارک، به ویژه مجموعه‌هایی که در حکم قسمتی از پیکره تعداد زیادی از مدارک هستند، مشترک می‌باشند. نوع متدالول این سنجه که مبتنی بر بسامد واژگان است، به بسامد اصطلاح^x بسامد معکوس مدرک^۲ (TDFIF) معروف است. گاهی به جای کل کلمات فقط ریشه‌شان را در نظر می‌گیرند. روش اکتشافی ریشه‌گیری که Porter مبدع آن بود (پورتر، ۱۹۸۰)، ریشه واحد اشکال مختلف کلمات یکسان را استخراج می‌کند (مثلاً کلمات «رفتن»، «رفت» و «رفته» همگی از کلمه «رفت» مشتق شده‌اند). بسامد هر ریشه کلمه^s در یک مدارک^d عبارت است از f_{ds} و تعداد مدارک^d دارای این ریشه کلمه^s عبارت است از n_s . بیشترین بسامد واژگانی در مدارک^d بسامد F_{dmax} نشان داده می‌شود. در یک چنین طرحی از TFIDF وزن کلمه^s w_{ds} اینگونه محاسبه می‌شود:

$$w_{ds} = \frac{(0/5 + 0/5 \frac{f_{ds}}{fd_{mas}})(\log \frac{No}{ns})}{\sqrt{\sum jed((0/5 + 0/5 \frac{f_{dj}}{fd_{max}})^2 (\log \frac{No}{nj})^2)}}$$

که در آن No تعداد کل مدارک است. به منظور یافتن فاصله بین دو مدارک، حاصل ضرب نقطه‌ای بردارهای دو کلمه برای این مدارک محاسبه می‌شود. یکی از محدودیت‌های این رویکرد، خشة ذاتی^۳ است: کلمات غیر مشترک ممکن است به خاطر برخی مدارک به صورت همسان و مشترک جلوه کنند. بدینگونه مدارک کاذبی دال بر مرتبط بودن آن مدارک به دست آید. یکی

1. Levenshtein
3. inherent noise

2. term frequency inverse document frequency

دیگر از محدودیت‌های این رویکرد وجود ابهام و چندگانگی در کلمات و عبارات است. مثلاً کلمه «شیر» هم ماده غذایی است، هم حیوان وحشی و هم ابزاری در لوله کشی آب. از این‌رو بسامدهای ساده کلمات که جداسازی آن‌ها نیازمند تحلیل بستر آنهاست در این مورد به کار نمی‌آیند.

سومین نوع سنجه فاصله معنایی آن است که از دانش در باب مؤلفه‌ها یا ساختار مدرک استفاده می‌کند. مثلاً در مورد انتشارات پژوهشی می‌توان برای محاسبه تشابه از اطلاعات استنادی بهره جست.

۱-۲. سنجه‌های تشابه

سایت سیر برای محاسبه [میزان] تشابه از سه روش ذیل استفاده می‌کند(گیلز، ۱۹۹۸):

بردارهای واژگانی: برای برآورد ارزش ریشه کلمه در هر مدرک طرح FIDF را به کار گرفته است که در آن بردار همه ارزش‌های ریشه کلمه، «جایگاه» یک مدرک را در فضای بردار واژگانی نشان می‌دهد. سنجه فاصله‌ای به کار رفته عبارت است از پیش نمایی بردار واژگانی یک مدرک روی مدرک دیگری (حاصل ضرب نقطه‌ای بردارها).

فاصله رشته‌ای: سایت سیر برای محاسبه فاصله ویرایشی بین سرآیندهای مدارک در یک پایگاه اطلاعاتی از فاصله رشته‌ای لیکلت بهره می‌برد^۱ (یانیلوس، ۱۹۹۷). به زبان ساده می‌توان گفت که سرآیند هر مدرک تمام اطلاعات مدرک، قبل از چکیده آن (و در صورت نبود چکیده، قبل از مقدمه آن) است. سرآیند یک مدرک حاوی عنوان، نام نویسنده و وابستگی سازمانی وی و احتمالاً محل نشر است. لیکلت بر آن است که رشته‌های فرعی موجود در رشته‌ای بزرگتر را بر هم منطبق سازد. نویسنده‌گان مشترک، مؤسسات یا کلمات در عنوان فاصله لیکلت بین سرآیندها را کاهش می‌دهد. فرض اساسی در حین استفاده از لیکلت آن است که سرآیند مدرک در بردارنده اطلاعات بسیار مهم در باب آن مدرک بوده و حضور کلمات در نظم‌هایی مشابه نشانگر مدارکی با منشاء مشابه است.

استنادهای تک کلمه‌ها (و در حدی کمتر، عبارات تکی) نمی‌توانند موضوع اصلی و یا مفاهیم مطرح در یک مدرک پژوهشی را به قدر کفایت نشان دهند. استنادهای دیگر آثار هم دستچین نویسنده‌گان با فرض مرتبط بودن آنهاست. پس منطقی است که از اطلاعات استنادی برای داوری در مورد ارتباط مدارک استفاده شود. برخی از پایگاه‌های استنادی نظیر سایت سیر از استنادهای مشترک به منظور برآورد این نکته استفاده می‌کند که کدام مدارک موجود در پایگاه اطلاعاتی دانلود شده مدارک پژوهشی ارتباط بیشتری با مدرک دستچین شده^۲ کاربر دارد. برای این منظور

1. Likelt

2. Document picked

از این سنجه، یعنی «استناد مشترک x بسامد معکوس مدرک»^۱ (CCIDF) مشابه با وزن‌های واژگانی کلمه محور TFDIF (سالton به تقلیل از گلیز، ۱۹۸۰) است. الگوریتم لازم برای محاسبه ارتباط CCIDF تمامی مدارک موجود در پایگاه اطلاعاتی با مدرک مورد نظر A و انتخاب بهترین مدرک M عبارت است از:

- ۱- تخصیص وزنی (w_i) به هر استناد i ، برابر با معکوس بسامد استناد در کل پایگاه اطلاعاتی
- ۲- تعیین فهرست استنادها و وزن‌های مربوط به آن‌ها برای مدرک A و درخواست از پایگاه اطلاعاتی برای یافتن مجموعه n مدرک $j: j=1, \dots, n$ که حداقل یک استناد مشترک با مدرک A دارد.
- ۳- تعیین ارتباط مدرک j برای هر $j=1, \dots, n$ به صورت مجموع وزن‌های استنادهای مشترک با استنادهای A

$$R_j = \sum_{i \in A \cap IEB_j}^{w_i}$$

۴- مرتب کردن مقادیر R_j و نشان دادن مدارک j با بیشترین مقادیر R مدارک M
 البته این الگوریتم نیز بولاکر^۲ (2008) نیز به آن اشاره کرده و مورد تائید قرار داده است.
 CCIDF هم مثل TFIDF فرض را بر این می‌گذارد که اگر دو مدرک، یک فقره استناد کاملاً غیر متعارف را هم زمان دارا باشند، وزن این استناد باید بالاتر از وزن استناد موجود در تعداد بیشتری از متون باشد. هرچند کار کرد CCIDF را رسماً برآورد نکرده است ولی کارآمد می‌باشد.
تل斐قی از روش‌ها: با توجه به اینکه که بازبایی مدارک مشابه براساس استناد به صورت ذهنی بهتر از بازبایی براساس بردار واژگانی و یا شیوه لیکلت است، برخی از پایگاه‌های استنادی نظری سایت سیر که عملکرد CCIDF را به صورت کلی ارزیابی کرده و با تکنیک‌های دیگری مثل بردار واژگانی و فاصله ویرایشی که پیشتر ذکر شدند، تلفیق کرده تا بتواند از سنجه فاصله تشابهی که دقیق‌تر از هر روش اعمال شده به صورت مجاز است، استفاده کند. این سنجه تشابه تلفیق شده در واقع برآیند وزن‌دهی شده‌ای از سنجه‌های تشابه پیشگفته که با الگوریتم زیر انجام می‌شود:
 ۱- محاسبه سنجه‌های بردار واژگانی، لیکلت و تشابه استنادی و نرم‌افزاری هر سنجه در قالب یک مقیاس صفر تا یک، که یک نمایانگر مدارک مشابه از نظر معناشناختی و صفر مین مدارک کاملاً متفاوت (فاصله معنایی قطعی) است. سنجه‌های مشابه نرمال شده بین دو مدرک A و B، ترتیب به صورت (WV(A,B)) [در بردار واژگانی] (A,B) LI [در محاسبه سنجه لیکلت] و CI (A,B) [در تشابه استنادی] نشان داده می‌شوند.

1. common citation x inverse document frequency

2. Bollacker

۲- برآورد مشابهت بین یک مدارک مورد نظر A و تمامی n مدارک داوطلب در مجموعه مدارک $B_j: j=1, \dots, n$ به کمک سه سنجه مذکور در بند ۱،

۳- تخصیص وزن های W_{wv} , W_{LI} و W_{CI} بر سنجه های مشابه مربوطه آنها. این ارزش ها (مقادیر) وزنی بین صفر و یک بوده و طوری نرمال سازی می شوند که $W_{wv} + W_{LI} + W_{CI} = 1$ برابر ۱ باشد.

۴- یافتن یک سنجه مشابه تلفیقی S_j بین A و هر کدام از مدارک B_j به صورت حاصل جمع وزن دهی شده:

$$S_j = W_{wv} WV(A, B) + W_{LI} LI(A, B) + W_{CI} CI(A, B)$$

۵- بازیابی مدارکی با بیشترین مقادیر S_j لارم به ذکر است که الگوریتم های که گیلز اشاره کرده در اصل از تحقیقات سالیون اقتباس شده است که نه تنها نتایج گیلز بر آنها صحنه گذاشته است، بلکه مطالعات بولاکر (1998) هم این الگوریتم ها را تایید کرده است. هر جند این الگوریتم ها بطور خاص در سایت سیر مورد مطالعه قرار گرفته است، اما جستجو در دیگر پایگاه های استنادی هم وضعیت مشابه سایت سیر دارد. بدین صورت پس از جستجو در پایگاه های استنادی، نمایش نتایج بر اساس تعداد استنادها، تحلیل استنادی، رد گیری استنادها برای شناسائی نویسنده گان فرمت یکسانی دارند. بدین منظور می توان نتیجه گرفت که احتمالاً الگوریتم های مورد استفاده این پایگاه ها همپوشانی فراوانی دارند. چون با بررسی های نگارندگان الگوریتم های دیگری مورد شناسائی قرار نگرفت و عمدہ الگوریتم ها همان های بود که به آنها اشاره داشت.

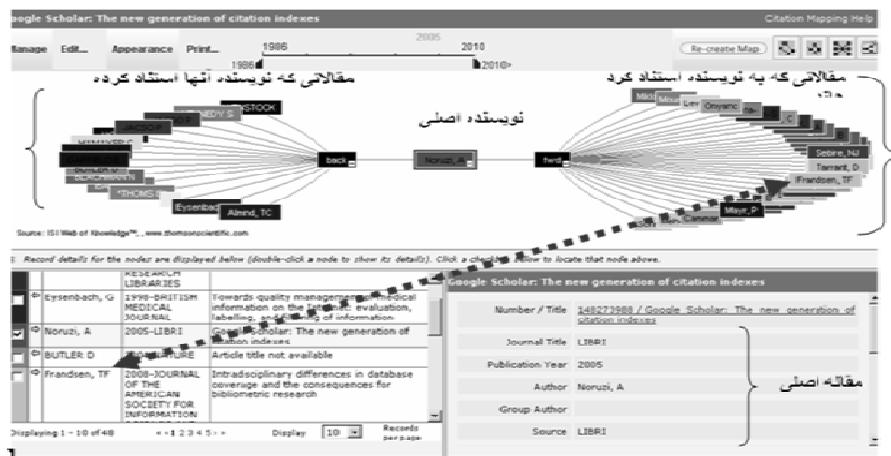
یکی از عده نتایج بازیابی در پایگاه های استنادی نمایش اطلاعات بر اساس تعداد استنادها می باشد. یعنی مقالاتی که بیشترین فراوانی دارند یا بیشتر مورد استناد قرار گرفته اند، به ترتیب تعداد استناد (از زیاد به کم) مورد نمایش قرار می گیرند. در جستجوهایی که در اکثر پایگاه های استنادی انجام شد، شیوه نمایش تعداد و بسامد استنادها یکسان بود. بر این اساس می توان نتیجه گرفت که اکثر پایگاه های استنادی الگوریتم وزن دهی یکسانی به کار می گیرند. اما همانطور که پیشتر هم اشاره شد، پایگاه های اطلاعاتی و موتورهای جستجو به دلیل ماهیت تجاری بودن، الگوریتم های ذخیره اطلاعات خود را بطور آشکار در اختیار عموم قرار نمی دهند. در عین حال، براساس مطالعات و تحقیقات عده الگوریتم های مورد استفاده این نوع پایگاه ها مبتنی بر الگوریتم وزن دهی و مدل بردار فضایی است (گیلز، ۱۹۹۸). یکی از موارد نمایش نتایج بازیابی در پایگاه های استنادی نظری اسکوپوس و سایت سیر و گوگل اسکالر مشخص کردن نویسنده گان کلیدی هر

حوزه هست که باز هم نشان می دهد که این پایگاهها برای تحلیل هم استنادی یک نویسنده از الگوریتم مشابهی استفاده می نمایند

۲- الگوریتم‌های خوشبندی

پایگاه‌های استنادی برای ایجاد شبکه‌های استنادی از نویسنندگان و موضوعات مرتبط رویکردهای متفاوتی اتخاذ نموده‌اند. یکی از این رویکردها تحلیل هم استنادی نویسنده است، که برای تحلیل ساختار فکری مطالعات علمی مورد استفاده قرار گرفته است. برای این منظور از تحلیل هم استنادی نویسنده برای خوشبندی نویسنندگان استفاده کرده است. الگوریتم مورد استفاده خوشبندی سلسله‌مراتبی اباستنگی (AHC) است که به عنوان تکنیک واکاوی برای خوشبندی نویسنده و نمایش و سنجش چند بعدی برای نمایش نقشه خوش نویسنده استفاده شده است (He, 2001, Bollaker, Lawrence & Giles, 1998).

یکی از الگوریتم‌هایی که امروزه برای بازیابی در موتورهای جستجو و برخی پایگاه‌های اطلاعاتی استفاده می‌شود، الگوریتم خوشبندی است. نتایج جستجو در آن پایگاه‌ها و موتورها نشان می‌دهد که هنگام بازیابی نتایج، خوش‌های نویسنندگان و مدارک قابل مشاهده است. بررسی‌ها نشان می‌دهد پایگاه‌های استنادی نیز از الگوریتم‌های خوشبندی استفاده می‌کنند. (He, 2002). هدف نهایی خوشبندی این است که داده‌های موجود را به چند گروه تقسیم کنند و در این تقسیم‌بندی داده‌های گروه‌های مختلف باید حداقل تفاوت ممکن را نسبت به هم داشته باشند و داده‌های موجود در یک گروه باید بسیار به هم شبیه باشند. البته کیفیت نتایج خوشبندی به روش اندازگیری شباهت و توانایی و قدرت الگوریتم در کشف الگوهای مخفی میان داده‌ها بستگی دارد. همچنین از این الگوریتم برای نمایش نقشه هم استنادی نویسنده استفاده گردیده است که در تصویر ۶ شماره نقشه استنادی نویسنندگانی که به گیلز استناد کرده‌اند نمایش داده شده است. به عنوان نمونه در تصویر شماره ۷ وقتی در پایگاه آی اس آی در مورد «Noruzi» در مقاله «Google Scholar: The new generation of citation indexes» در رتبه اول صفحه نمایش ظاهر گردید. برای ردیابی و نمایش نقشه استنادی از گزینه 'Citation Map' استفاده گردید و نقشه مقالاتی که به این عنوان استناد کرده‌اند و مقالاتی که خود نویسنده به آن‌ها استناد کرده بود نمایش داده شد. همانطوریکه هر (۲۰۰۱) هم اشاره کرد، پایگاه‌های استنادی از الگوریتم «AHC» برای نمایش نقشه‌های استنادی نویسنده استفاده می‌کنند.



تصویر شماره ۷: نمایش نقشه استناد یه یک نمونه مقاله بازیابی شده در پایگاه Wok

الگوریتم خوشبندی بطور کلی به دو دسته تقسیم می‌گردد: الگوریتم‌های سلسه‌مراتبی و غیر سلسه‌مراتبی. الگوریتم‌های خوشبندی سلسه‌مراتبی مستلزم یک فرآیند ساختاری شبیه درخت است. از میان انواع الگوریتم‌های خوشبندی الگوریتم خوشبندی سلسه‌مراتبی اباستنگی در پایگاه‌های استنادی بیشتر مورد استفاده قرار گرفته است (He, 2002)

بحث و نتیجه‌گیری

انقلاب ناشی از ظهور وب و تأثیر آن بر ذخیره و دسترسی به اطلاعات صرفاً به جهت دسترسی‌پذیری به اطلاعات نیست بلکه به جهت کارآمدی در دسترسی به اطلاعات است. در این راستا هر چند بسیاری از پایگاه‌های اطلاعاتی متن کامل در دسترس هستند، ولی آنچه که امروزه به طور خاص مورد توجه پژوهشگران و دانشجویان قرار گرفته پایگاه‌های استنادی است که به لحاظ دسترسی‌پذیر ساختن شبکه‌ای از اطلاعات مرتبط توجه بسیاری را به خود جلب نموده است. علت اساسی آن است که این نمایه‌ها ویژگی‌های مهمی دارند که دست به دست هم داده و آن‌ها را برای یک چنین کاربردی بسیار مناسب و منحصر به فرد ساخته‌اند.

بسیاری از پایگاه‌های استنادی که ماهیت مشابهی دارند، از الگوریتم‌های مشابهی استفاده می‌کنند. آنچه که در این مقاله بطور خاص مورد توجه قرار گرفت تحلیل ساختار الگوریتم‌های ذخیره و بازیابی پایگاه‌های استنادی بود که ماهیت تجاری داشتند، نظیر: سایت سیر، اسکوپوس. هر چند، در این پژوهش برخی از پایگاه‌های استنادی نظری گوگل دانشوران به لحاظ تفاوت در ساختار و ماهیت مورد بررسی قرار نگرفتند. بررسی‌های اولیه نشان داد که اصولاً چنین پایگاه‌های

بدلیل ماهیت تجاری الگوریتم‌های ذخیره‌سازی خود را به راحتی در اختیار دیگران قرار نمی‌دهند. اما با بررسی و کنکاش در اینترنت و جستجوی عملی در این پایگاه‌ها و مقایسه نتایج با یکدیگر به این نتیجه رسیدیم که بسیاری از این پایگاه‌ها از دو سیستم نرم‌افزاری برای ذخیره‌سازی و نمایه‌سازی استنادها استفاده می‌کنند. یکی از نرم‌افزارهای که برخی از این پایگاه‌ها نظیر سایت سیر استفاده می‌کنند نرم‌افزار نمایه‌سازی استنادی خودگردان است که بسیاری از این پایگاه‌های برای سازماندهی اطلاعاتی کتابشناختی متون علمی از آن استفاده می‌کنند. نمایه‌سازی استنادی خودکار روند نشر اطلاعات علمی الکترونیکی را تسريع می‌کند. همچنین به واسطه استفاده از آن نرم‌افزار، یک شبکه پیوندی از اطلاعات کتابشناختی متون علمی با دسترس پذیری وسیع نویسنده‌گان مقالات ایجاد می‌کند. سایت سیر به طور خودکار در وب مقالات را شناسائی و استنادهای آن‌ها را تقطیع می‌کند و سپس نمایه‌سازی می‌کند. همچنین از موتور جستجوی آلتا ویستاو هات و اکسایت استفاده می‌نماید. برخی از پایگاه‌های استنادی دیگر سیستم (PubSearch Hui, 2002) مورد استفاده قرار داده‌اند که عمدۀ تفاوت این سیستم با ACI استفاده از الگوریتم خوش‌بندی نویسنده است که این سیستم را از سیستم‌های دیگر متمایز می‌سازد.

نتایج دیگر این بررسی نشان داد که امروزه پایگاه‌های استنادی دو کارکرد عمدۀ دارند که توجه محققان و نویسنده‌گان را به خود جلب نموده است. یکی ردگیری استنادها برای شناسائی نویسنده‌گان هسته در یک موضوع است که پایگاه‌های استنادی هم از تکنیک تحلیل هم-استنادی نویسنده برای نمایش دسته‌بندی نویسنده‌گان استفاده می‌کنند که برای اجرای این تکنیک، الگوریتم خوش‌بندی سلسله‌مراتبی انباشتگی نویسنده را به کار می‌برند. دوم شناسائی مقالات پر استناد است که از طریق نمایش نتایج جستجو در پایگاه‌های بر اساس تعداد استنادها دنبال می‌شود. در این راستا، پایگاه‌های استنادی عمدتاً از مدل‌های وزن‌دهی و مدل‌بردار فضایی برای ذخیره‌سازی استنادها استفاده می‌نمایند. در ایران نیز پایگاه‌های استنادی شروع به فعالیت نموده‌اند که می‌توانند برای بازبایی بهتر و روان‌تر اطلاعات از ترکیبی از این الگوریتم‌ها استفاده نموده و زمینه دسترسی کاربران را در بهره‌گیری از اهداف کاربردی آن‌ها یعنی شناسائی نویسنده‌گان پر استناد، مقالات پر استناد، حوزه‌های فعل و سایر کارکردها فراهم سازند. هر چند به نظر می‌رسد که سایر پایگاه‌های استنادی به ویژه در حوزه‌های تخصصی قابل راه‌اندازی است.

برای بازبایی کارآمدتر اطلاعات، شناسائی نویسنده‌گان هسته و خوش‌های موضوعی استفاده از الگوریتم‌ها و سیستم‌ها، کتابداران می‌توانند به متخصصان نرم‌افزاری در طراحی و راه‌اندازی این پایگاه‌ها کمک کنند. همچنین پیش‌هاد می‌گردد تا پژوهشگران و دانشجویان تحصیلات تکمیلی به بررسی بیشتر و دقیق‌تر این موضوع پرداخته و امکان سنجی ایجاد دیگر پایگاه‌های استنادی فارسی و ارزیابی پایگاه استنادی جهان اسلام مورد توجه قرار دهنند.

فهرست منابع

پائو، میراندا لی. ۱۳۷۸. *مغاهیم بازیابی اطلاعات*. ترجمه رحمت‌الله فتاحی و اسدالله آزاد. مشهد، دانشگاه فردوسی، موسسه چاپ و انتشارات.

حسن زاده، محمد، و عبدالرضا نوروزی چاکلی. ۱۳۸۷. *نمایه‌سازی استنادی و روابط علمی*. رهیافت، شماره ۴۳، پاییز و زمستان.

حری، عباس، و اعظم شاهبداغی. ۱۳۸۵. *شیوه‌های استناد در نگارش‌های علمی*. تهران: انتشارات دانشگاه تهران.
مهرداد، جعفر، محمد حسین دیانی، رحمت‌الله فتاحی، محمدرضا داور پناه، علی گزنه، و رویا مقصودی. ۱۳۸۶. *نمایه استنادی علوم ایران*. شیراز: مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری.

- Bollacker, K., Lawrence, S., & Giles, C. 2000. Discovering relevant scientific literature on the web. *IEEE Intelligent Systems*, 15(2), 42–47.
- Bollacker, K., Lawrence, S., & Giles, C. 1998. Citeseer: An autonomous Web Agent for Automatic Retrieval and Identification of Interesting publication. 2nd International ACM conference on Autonomous Agent. pp. 116-123, ACM Press, May.
- Garfield, E. 1979. *Citation Indexing: Its Theory and Application in Science, Technology, and Humanities*. Wiley, New York.
- Garfield, E. 1994. The concept of citation indexing: A unique and innovative tool for navigating the research literature. *Current Contents*, January 3.
- Garfield, E. 1994. Where was this paper cited? *Current Contents*, January 31, 1994.
- Garfield, E. 1955. Citation indexes for sciences: A new dimension in documentation through association of ideas. *Science* 122 (3159) : 108-111.
- Garfield, E. 1979. *Citation indexing: Its theory and applications in science, technology and the humanities*. New York: Wiley Inter science.
- Garfield, E. 1979. *Citation Indexing: Its Theory and Application in Science, Technology, and Humanities*, John Wiley & Sons, New York.
- Giles, C.L. 1998, "Cite Seer: An Automatic Citation Indexing System," K. Bollacker, and S. Lawrence.Digital Libraries: Third ACM Conf. on Digital Libraries, ACM Press, New York, 1998, pp. 89-98
- He, Y. 2001. Mining a web citation database for the retrieval of scientific publications over the WWW. M. Eng. Thesis, School of Computer Engineering, Nanyang Technological University, Singapore.
- He, Y. 2001b. PubSearch: a web citation – based retrieval system. Siu Cheung Hui. Library Hi Tech. volume 3. pp.274-285
- He, Yulan. Siu Cheung Hui(2002). Mining a web Citation Database for author C0- Citation analysis. *Information processing and Mangemwnt* 38.491-508
- Lawrence, Steve.1998. Digital Libraries and Autonomous Citation Indexing. C. Lee Giles, Kurt Bollacker. IEE computer Available at:
- Lawrence, Steve.1998. Indexing and Retrieval of Scietific Literature. Kurt Bollacker ,C. Lee Giles. ACM
- Nourozi, Alireza. 2005. Google scholar: The new generation of citation indexes. *Libri*, vol55. pp-170-180
- Salton, Gerard and C.S. Yang 1973. On the specification of term values in automatic indexing. *Journal of Documentation*, 29:351–372.
- Salton, Gerard and Chris Buckley 1987. Term weighting approaches in automatic text retrieval. Tech Report 881, Department of Computer Science, Cornell University, 1987.
- Porter, M. F 1980. An algorithm for suffix stripping. *Program*, 14:130–137, 3.
- Salton Gerard. 1971. Automatic indexing using bibliographic citations. *Journal of Documentation*, 27:98–110.
- Yianilos, 1997. *The Likelt Intelligent String Comparison Facility*, Tech. Report 97-93, NEC Research Institute.

Web-based citation databases: An Analysis of the Structures and Algorithms for Information Storage and Retrieval

Abdoulrasoul Khosravi*

Faculty member of Boushehr University

Seyyed Rahmatullah Fattahi

Professor in Ferdowsi University of Mashhad



Abstract: Developing citation databases as a new approach to information storage and retrieval is one of the main activities of information professionals in recent years. The aim of such databases is to satisfy researchers and students' information needs on the Web. The various capacities of these databases provide researchers with different facilities both in information searching and retrieval as well as in scientometrics. Performed using case study (direct observation of these databases) and review of the related literature, this study aims at investigating structures as well as information search and retrieval facilities of Google Scholars and Scopus. This necessitates the analysis of the indexing structure, algorithms of the databases regarding weighting, indexing, connecting citations and author co-citations. Findings revealed that these databases had networked structures and used two citation indexing systems, mainly an automated indexing system. Their algorithm system is based on weighting and spatial vector models and cumulative hierarchy clustering which are discussed in detail. The algorithm allows searchers to trace a network of cited and citing sources.

Keywords: citation indexing; web-based citation databases;
Information retrieval; Autonomous citation index

Iranian Research Institute
For Science and Technology
ISSN 1735-5206
eISSN 2008-5583
Indexed in LISA, SCOPUS & ISC
Vol.26 | No.2 | pp: 199-222
Winter 2011

* Corresponding Author: khosravi2422@gmail.com