

## مروری بر رویکردهای نمایه سازی خودکار وب: محتوا محوری، استناد محوری و معنا محوری

عاطفه شریف

دانشجوی کارشناسی ارشد کتابداری و اطلاع رسانی دانشگاه تهران

### چکیده

وب به واسطه ویژگی چند رسانه‌ای، کاربران فراوانی در اینترنت دارد. شمار وب سایت‌ها روز به روز افزایش می‌یابد و انبوهی از اطلاعات در وب منتشر می‌شود. در چنین وضعیتی مهم‌ترین مسئله، سازماندهی و مدیریت اطلاعات منتشر شده است؛ زیرا کیفیت بازیابی در گرو سازماندهی و ذخیره سازی مناسب است. موتورهای کاوش، با نمایه سازی و ذخیره اطلاعات نمایه شده در پایگاه‌های خود، امکان جست و جو، بازیابی، رتبه‌بندی، و نمایش اطلاعات وب را فراهم می‌آورند. در این مقاله سعی بر آن است تا ضمن معرفی مختصر برخی ابزارهای کاوش، به تشریح رویکردهای موجود- محتوا محوری، استناد محوری، و معنا محوری - در زمینه نمایه سازی خودکار وب در موتورهای کاوش پرداخته شود. در نهایت حرکت به سمت داده‌های ساختار یافته و وب معنایی<sup>۱</sup> با تکنولوژی‌های XML<sup>۲</sup> و RDF<sup>۳</sup> مورد بررسی قرار می‌گیرد.

کلید واژه‌ها: وب، نمایه سازی خودکار، صفحات متنی

1. Semantic Web

2. Extensible Markup Language (زبان نشانه‌گذاری توسعه پذیر)

3. Resource Description Framework (چارچوب توصیف منبع)

## مقدمه

وب به عنوان یکی از جذاب‌ترین بخش‌های اینترنت که کاربران فراوانی دارد، مجموعه‌ای است از صفحات به هم پیوسته که حاوی اطلاعات مفیدی در زمینه‌های موضوعی مختلف است. مطالعه‌ای که [cyveillance.com](http://cyveillance.com) انجام داده است نشان می‌دهد که وب بیش از ۱/۲ بیلیون سند دارد (اکتبر ۲۰۰۴) و نرخ رشد آن نیز ۷ میلیون صفحه در روز است (رویدکی، ۱۳۸۳).

همه دلایل مربوط به چرایی سازماندهی اطلاعات در محیط چاپی با شدت بیشتری در محیط الکترونیکی صادق است. میلیون‌ها نفر در سراسر جهان نیازهای روزمره خود را از طریق وب مرتفع می‌کنند. سرعت رشد وب به حالت انفجارگونه‌ای رسیده است. مسئله اساسی در چنین وضعیتی آن است که چگونه می‌توان بدنه ساختار نیافته<sup>۱</sup> و به سرعت رشد کننده وب را تحت کنترل و مدیریت درآورد. اگرچه در سازماندهی وب از روش‌های پایه و اصول سنتی ذخیره و بازیابی اطلاعات استفاده شده است، روشن است که روش‌های سنتی قابلیت لازم را ندارد. در حال حاضر موتورهای کاوش، به‌ظاهر، وب را تحت ضابطه در آورده‌اند (اسدی و جمالی مهموئی، ۲۰۰۴) و با نمایه سازی صفحات پاسخی برای پرس و جوی<sup>۲</sup> کاربران فراهم می‌آورند.

نحوه سازماندهی اطلاعات، بازتاب مستقیمی در نحوه بازیابی (رتبه‌بندی و نمایش) نتایج دارد. موتورهای کاوش هریک با الگوریتم‌ها و سیاست‌های متفاوتی به مقوله نمایه سازی می‌نگرند. تفاوت در نتایج بازیابی شده در موتورهای کاوش مختلف نشان بارزی از وجود تفاوت در الگوریتم‌های نمایه سازی آنهاست. سازماندهی و سپس ذخیره مناسب اطلاعات به بازیابی نتایج مرتبط و مناسب خواهد انجامید. از این جهت است که آشنایی با این مقوله برای کتابداران و اطلاع رسانان که از دیرباز به انتخاب، گردآوری، سازماندهی، ذخیره، بازیابی، و اشاعه اطلاعات پرداخته‌اند خالی از فایده نیست.

### مسئله و هدف

ابزارهای کاوش که ظاهراً وب را تحت ضابطه درآورده‌اند از روش‌های گوناگونی جهت نمایه سازی اطلاعات بهره می‌برند. بدون شک هریک از روش‌های اتخاذ شده در نمایه سازی مزايا و معایبی دارد که به واسطه انجام پژوهش و آزمون می‌توان به این نقاط ضعف و قوت پی برد و جهت رفع ضعف‌ها کوشید. تلاش‌ها در این زمینه عمدتاً از سوی متخصصان علوم رایانه و هوش مصنوعی انجام پذیرفته است. این در حالی است که همواره کتابداران و اطلاع رسانان مدعی سازماندهی دانش بشر بوده و هستند. حضور پررنگ‌تر در این حوزه نیازمند آشنایی با اصول پایه است. برداشتن گام اول تنها به معنای برداشتن گام اول است و در این مسیر باید گام‌های فراوانی برداشته شود. این از آن جهت اهمیت دارد که متخصصان سایر علوم اگرچه اطلاعات فنی مناسبی جهت طراحی ابزارهای کاوش دارند؛ متخصصان کتابداری و اطلاع رسانی نیز دارای دانش ارزشمندی در زمینه نیازسنگی، رفتارهای اطلاع‌یابی، و روابط حاکم بر پرسش و پاسخ در مرحله پاسخ‌یابی هستند. موفقیت در این زمینه زمانی حاصل خواهد شد که متخصصان اطلاع رسانی همکاری بیشتری با سایر متخصصان داشته باشند. حضور فعال، انجام پژوهش و ارائه راهکار به سایر متخصصان نیازمند دانشی است که کتابداران و اطلاع رسانان باید از واقعیت وب داشته باشند. لذا مطالعه حاضر بر آن است تا ضمن آشکار ساختن چگونگی نمایه سازی خودکار اطلاعات در محیط وب، رویکردهای موجود را تا حد امکان آشکار سازد.

هدف از انجام این پژوهش رسیدن به درکی واقعی از چگونگی نمایه سازی خودکار در وب و رویکردهای موجود در این زمینه است. انجام این پژوهش می‌تواند فواید زیر را در برداشته باشد:

- رسیدن به درکی از واقعیت نمایه سازی در محیط وب؛
- شناخت رویکردهای موجود در نمایه سازی وب و حرکت‌های آتی؛
- بهره‌گیری از دانش کسب شده جهت پاسخگویی کارآمدتر به کاربران و مراجعان کتابخانه‌ها و مراکز اطلاع رسانی؛

- کسب دانشی که در طراحی و مدیریت وب سایت‌ها و پایگاه‌های اطلاعاتی پیوسته به کتابداران یاری رساند؟
- درک اهمیت مشارکت متخصصان حوزه‌های علوم رایانه، کتابداری و اطلاع رسانی و حوزه هوش مصنوعی و کسب دانشی که این همکاری و مشارکت را تا اندازه‌ای عملی تر نماید؟
- کسب آمادگی جهت انجام پژوهش‌های بیشتر در زمینه ارزیابی عملکرد ابزارهای کاوش به خصوص موتورهای کاوش و ارائه راهکارهای عملی.  
روش پژوهش حاضر از نوع کتابخانه‌ای است. و از طریق مروری بر نمایه‌سازی در وب و رویکردهای موجود در متون صورت گرفته است.

### محدودیت‌ها

#### الف. گردآوری اطلاعات

آنچه واقعاً در پشت صحنه جست و جو رخ می‌دهد، به دلایل رقابتی مخفی نگهداشته می‌شود و فقط در اختیار تولید کننده خدمات جست و جو است. بسیاری از اطلاعات فنی ارائه نمی‌شود و یا در صورت ارائه شدن از روزآمدی آنها کاسته شده است. لذا در تحقیق حاضر سعی در اتکا بر متونی شده است که تا اندازه‌ای جنبه‌های فنی نمایه سازی را آشکار ساخته‌اند و در ضمن از روزآمدی نسبی برخوردارند. مقالاتی نیز موجود است که تنها امکان دسترسی به چکیده‌های آنها فراهم است و متن کامل آنها در اختیار نیست. به این ترتیب ادعایی مبنی بر جامعیت مطالب ارائه شده وجود ندارد.

#### ب. درک دقیق اطلاعات بازیابی شده

بحث نمایه سازی وب از یک سوبه اطلاع رسانی و از سویی به علوم رایانه مربوط می‌شود. این در حالی است که اکثر متون مناسب در حوزه علوم رایانه به نگارش درآمده است، این متون حاوی مفاهیم و لغات تخصصی ویژه‌ای هستند و درک دقیق آنها نیازمند مطالعه و تأمل بسیار است.

## پیشینه

### الف. خارج از ایران

بسیاری از مقالات موجود در زمینه فن آوری موتورهای کاوش در حوزه کامپیوتر به نگارش درآمده‌اند. متأسفانه دسترسی به متن کامل تعداد زیادی از این مقالات تحقیقاتی، که اغلب گزارش طراحی موتورهای کاوش و طرح‌های ذخیره و بازیابی است، امکان‌پذیر نیست. طی جست و جوی انجام شده در پایگاه‌های اطلاعاتی دانشگاه تهران و بررسی نتایج حاصل از کاوش پیشرفت‌های گوگل، تحقیقی با این رویکرد بازیابی نشد.

لنکستر (۲۰۰۳) در مقاله‌ای با عنوان "آیا نمایه سازی و چکیده‌نویسی آینده‌ای را پیش رو خواهد داشت؟" به بحث نمایه سازی و چکیده‌نویسی گزینشی در محیط وب می‌پردازد. وی ضمن تأیید توانایی نیروی انسانی متخصص در این زمینه وجود نظام‌های خودکار نمایه سازی بر آینده‌ای روشن تأکید می‌کند که: "احتمالاً سرانجام، رده‌بندی خودکار هم قدرت و هم شهرت متخصصان اطلاع رسانی را ارتقاء خواهد داد."

ونگ و برمان<sup>۱</sup> (۲۰۰۳) ضمن تأکید بر وجود وب نامرئی ساختار موتور کاوش پویایی را شرح می‌دهند که نمایه سازی در آن طبق رویکرد محتوا محور است. در این موتور کاوش پویا از فن آوری XML استفاده شده است

برین و پیج<sup>۲</sup> (۱۹۹۸) با تحلیل دقیق آناتومی گوگل، آن را به کاربران وب معرفی می‌کنند. موتور کاوش گوگل از تحلیل پیوندها بهره می‌گیرد و، علاوه بر نمایه سازی کلید واژه‌ای کلمات متن، بر تحلیل پیوندها نیز تأکید دارد.

برادشاو و هاموند<sup>۳</sup> (۲۰۰۲) نمایه سازی خودکار مدارک را با دو روش محتوا محور و براساس استنادها مورد بررسی قرار داده‌اند. در این مقاله تأکید بر نمایه سازی مدارک مطابق با استنادهاست به گونه‌ای که استنادها اساس نمایه سازی مدارک قرار گیرند. این

1. Wang and Behrmann

2. Brin and Page

3. Bradshaw and Hammond

دو محقق موتور کاوشی بر این مبنای طراحی کرده‌اند که در کتابخانه دیجیتال رزتا<sup>۱</sup> به طور آزمایشی مورد استفاده قرار گرفته است.

دمونتیل و ژاکین (۲۰۰۲) استفاده از هستی‌شناسی را به عنوان مبنای در نمایه‌سازی وب سایت‌ها معرفی کرده‌اند. در فرایند نمایه‌سازی بر مبنای هستی‌شناسی، ارزش گذاری بر طبق نوع نشانه‌ها و سایر مفاهیم مرتبط با صفحه انجام می‌پذیرد و ارزش نهایی در نمایه‌ای ساختار یافته به فرمت XML ذخیره می‌شود.

### ب. داخل ایران

در زمینه مطالعه روش‌ها یا رویکردهای نمایه‌سازی وب در منابع فارسی کار چندانی انجام نپذیرفته است. طبق جست و جوی انجام شده چنین به نظر می‌رسد که هیچ پایان‌نامه یا طرح تحقیقاتی به بررسی نمایه‌سازی در وب پرداخته است.

کمیجانی (۱۳۸۱) در مقاله‌ای با عنوان "ساختار نمایه‌سازی در موتورهای کاوش وب" مدل‌های متمرکز<sup>۲</sup> و توزیعی<sup>۳</sup> نمایه‌سازی را مورد بررسی و مقایسه قرار داده و برتری‌های مدل توزیعی را برشمرده است.

اسدی و جمالی مهموئی (۲۰۰۴) ضمن مطالعه سیر تحول موتورهای کاوش، گرایش‌های مطالعاتی موجود در این زمینه را بیان کرده‌اند. در این تحقیق موتورهای کاوش هوشمند که توانایی استخراج تاییج از داده‌های ساختار یافته را دارند، به عنوان نسل بعدی موتورهای کاوش معرفی شده‌اند.

صفری (۱۳۸۳) با افزودن چهار ابرداده<sup>۴</sup> از مجموعه ابرداده‌های هسته دابلین<sup>۵</sup> - عنوان، موضوع، پدیدآورنده، و همکار - به مطالعه اثربخشی هریک از این ابرداده‌ها پرداخته است. تجزیه و تحلیل آماری در این پایان‌نامه نشان می‌دهد که هیچ‌گونه تفاوت

1. Rosetta Digital Library

2. Centralized model

3. Distributed model

4. Metadata

5. Dublin core

معناداری میان دو گروه آزمودنی و گواه در بهبود بازیابی صفحات وب وجود ندارد و فرضیه های پژوهش مبنی بر اثربخشی هریک از عناصر ابردادهای بر بازیابی صفحات وب تأیید نگردیده است.

سایر اطلاعات منتشر شده در زمینه نمایه سازی وب بسیار کلی و، بیشتر در قالب کتابها و مقالات ترجمه شده در زمینه راهبردهای کاوش و چگونگی ارزیابی نتایج کاوش است. در بیشتر این منابع ساختار اصلی موتورهای کاوش به عنوان پر استفاده‌ترین ابزار کاوش به طور مختصر مورد بررسی قرار گرفته است. به این ترتیب، در زمینه رویکردهای نمایه سازی خودکار در منابع فارسی نه در حوزه کتابداری و نه در حوزه کامپیوتر مطلبی یافت نشد.

### ابزارهای کاوش<sup>۱</sup> در وب

رشد سریع وب سایت‌ها، مراجعه فراوان کاربران به وب جهت رفع نیازهای اطلاعاتی و بسیاری دلایل دیگر متخصصان را بر آن داشته است تا به روش‌های گوناگون، دسترس پذیری به اطلاعات وب را فراهم آورند.

ابزارهای کاوش پایگاه‌های اطلاعاتی قابل جست و جو یا مرور هستند که با استفاده از آنها می‌توان به بخشی از اطلاعات موجود در اینترنت دست یافت. این ابزارها به دو شیوه "جست و جوی کلید واژه‌ای" یا "مرور و انتخاب" پیوندهای فرامتنی، کاربران را به سوی اطلاعات مورد نظر هدایت می‌کنند (کوشان، ۱۳۸۰، ص ۲۶).

ابزارهای کاوش را می‌توان به دو نوع اصلی تقسیم بندی کرد:

### راهنمای موضوعی<sup>۲</sup> و موتورهای کاوش<sup>۳</sup>.

راهنمای موضوعی پایگاه‌هایی هستند که اطلاعات صفحات یا سایت‌های وب

1. Search tools

2. Subject directories

3. Search engines

منتخب را توسط نیروی انسانی در پایگاه خود نمایه می‌کنند. این راهنمایان می‌توانند عمومی یا خاص باشند (کوشان، ۱۳۸۰، ص ۲۶).

موتورهای کاوش پایگاه‌های اطلاعاتی قابل جست و جویی هستند که از طریق برنامه‌های کامپیوتری به شناسایی و نمایه سازی خودکار صفحات وب می‌پردازند. موتورهای کاوش برخلاف راهنمایان موضوعی، برنامه‌های خودکاری هستند که هیچ گونه وابستگی به نیروی انسانی ندارند (کوشان، ۱۳۸۰، ص ۳۱).

علاوه بر دو نوع اصلی ابزارهای کاوش، ابزارهای دیگری نیز برای دسترسی به اطلاعات در محیط وب وجود دارد که عبارتند از:

- ابزارهای کاوش دو وجهی<sup>۱</sup> که ترکیبی از موتور کاوش و راهنمای موضوعی هستند، مانند گوگل و آلتاویستا.

- ابر موتورهای کاوش<sup>۲</sup> که ترکیبی از چندین موتور کاوش و راهنمای موضوعی و فاقد پایگاه مستقلی جهت جمع‌آوری و نمایه سازی هستند.

- نرم‌افزارهای کاوش که هیچ گونه وابستگی به محیط وب ندارند و روی کامپیوتر شخصی نصب می‌شوند. این نرم‌افزارها امکان جست و جوی همزمان در چندین پایگاه اطلاعاتی را در اختیار قرار می‌دهند و از این لحاظ ابر موتور کاوش به شمار می‌آیند (کوشان، ۱۳۸۰، ص ۴۶).

- حلقه‌ها<sup>۳</sup> مجموعه‌ای از سایت‌های هم‌موضوع هستند که توسط نرم‌افزار Web ring به هم متصل شده‌اند. این حلقه‌ها گاه مورد ارزیابی قرار می‌گیرند و با توصیفی همراه می‌شوند.

- درگاه‌ها<sup>۴</sup> سایت‌هایی هستند که خود را سرآغاز و نقطه شروع وب می‌شمارند. این درگاه‌ها می‌توانند موضوعی نیز باشند.

1. Hybrid search tools

2. Meta search engines

3. Web rings

4. Portals or Gateways

- فن آوری فشار<sup>۱</sup> صفحات وب را قبل از درخواست به کاربران ارسال می‌کند.
- کارگزاران هوشمند<sup>۲</sup> نرم افزارهایی هستند که مطابق با نیازهای فردی به جمع آوری اطلاعات می‌پردازند، درست همانند موتور کاوشی که مطابق با نیازهای فردی به جست و جو پرداز (دو شارته، ۲۰۰۲، ص ۶۸-۶۹). تامپسون و دیگران<sup>۳</sup> (۲۰۰۰) کارگزاران هوشمند را نسل چهارم ابزارهای بازیابی می‌نامند که تلاش انسان را در پاسخ‌یابی بسیار کاهش داده است (منصوریان، ۲۰۰۴، ص ۲۱۹).

از میان ابزارهای کاوش معرفی شده، تنها موتورهای کاوش نظام نمایه سازی خودکار خاصی را دنبال می‌کنند؛ لذا در ادامه به بررسی نحوه نمایه سازی در این نوع ابزارهای کاوش پرداخته می‌شود.

## ۱. فن آوری موتورهای کاوش

نمایه سازی با یکی از دو روش دستی یا خودکار انجام می‌پذیرد. در محیط وب به علت حجم وسیع اطلاعات منتشر شده عملاً نمی‌توان به شیوه‌های دستی متولّ شد. به این ترتیب، نمایه سازی در وب به صورت خودکار و توسط موتورهای کاوش انجام می‌شود. موازی با رشد وب، تعداد موتورهای کاوش رو به افزایش است. تفاوت نتایج بازیابی شده در موتورهای کاوش مختلف نشانی از وجود تفاوت در سیاست‌ها و الگوریتم‌های نمایه سازی، ذخیره، رتبه‌بندی و نمایش آنهاست. با وجود تفاوت‌هایی که موتورهای کاوش با یکدیگر دارند سه جزء اصلی در آنها ثابت است:

- عنکبوت<sup>۴</sup> یا روبات خزنده<sup>۵</sup> یا روبات اطلاعاتی<sup>۶</sup>
- نمایه یا پایگاه اطلاعاتی<sup>۷</sup>

1. Push technology

2. Intelligent agent

3. Thompson et al

4. Spider

5. Crawler

6. Info-bot

7. Database

● نرم افزار کاوش (منتظر، ص ۳۴).

به بیانی ساده، عنکبوت به واسطه پیوندهای فرآمتنی، پیوسته در صفحات وب می خزد و اطلاعات لازم را جهت نمایه شدن به پایگاه می فرستد. فرایند نمایه سازی انجام می شود و به وسیله نرم افزار کاوش، که واسطه میان کاربر و پایگاه اطلاعاتی به شمار می آید، به جویش کاربران پاسخ داده می شود.

اولین موتورهای کاوش بر محتوای صفحات وب متمرکز بوده‌اند. آلتاویستا و سایر موتورهای کاوش قدیمی بر مبنای نمایه سازی محتوای صفحات وب طراحی شده‌اند. در واقع، نمایه‌های متمرکز بزرگی می ساختند که امروز نیز بخش مهمی از هر موتور کاوش شناخته شده‌ای است. اگرچه مدل‌های سنتی نمایه سازی در پایگاه‌های داده‌ها مناسب بود، این مدل‌ها برای منابع اطلاعاتی ساختار نیافته وسیعی که در وب وجود دارد مناسب به نظر نمی‌رسید. در مورد وب تنها کامل بودن نمایه‌ها عامل کیفیت نتایج جست و جو نیست. در ۱۹۹۶-۱۹۹۷ گوگل با نوآوری جدیدی ظهر کرد. گوگل بر این اندیشه جدید پایه ریزی شد که ساختار پیوندها در وب، منبع مهمی در بهبود نتایج موتورهای کاوش است. بعداز نمایه سازی بر مبنای محتوا<sup>۱</sup> و تحلیل پیوندها، فضای جدیدی در مطالعات به ظهور رسید. این فضای جدید بر مطالعه صفحه و ساختارهای ترکیب<sup>۲</sup> آن تأکید دارد. در رویکرد جدید، HTML و XML اهمیت می‌یابند. ترکیب صفحه منبع مناسبی جهت بهبود نتایج جست و جو است. به طور مثال، ارزش اطلاعاتی که در نشانه<sup>۳</sup> `<Heading>` می‌آید بیشتر از اطلاعاتی است که در نشانه `<Paragraph>` می‌آید. روند رو به رشد ادامه دارد و چنین انتظار می‌رود که نسل بعدی موتورهای کاوش قادر به استخراج داده‌های ساخت یافته جهت پاسخگویی مناسب و با کیفیت بالا به کاربران باشد (اسدی و جمالی مهموئی، ۲۰۰۴).

1. Content - base Indexing

2. Layout Structure

3. Hypertext Markup Language زبان نشانه گذاری فرآمتن

4. Tag

## رویکردهای نمایه سازی خودکار وب

در بیانی کلی می‌توان گفت که تاکنون در حوزه فن آوری ذخیره و بازیابی اطلاعات در وب شاهد رویکردهای نمایه سازی گوناگونی چون محتوا محوری، استناد محوری (تحلیل پیوندها)، معنامحوری، شامل نمایه سازی معنایی پنهان<sup>۱</sup> (رویکرد ریاضی) و نمایه سازی بر مبنای هستی‌شناسی لغوی<sup>۲</sup> (رویکرد زبان‌شناختی) بوده‌ایم که در ادامه، به آنها پرداخته خواهد شد.

### ۱. محتوا محوری

اغلب موتورهای کاوش حاضر از روش نمایه سازی بر مبنای کلید واژه‌های متن استفاده می‌کنند. در این شکل، فرایند نمایه سازی سه مرحله خواهد داشت:

- شکستن کلمات<sup>۳</sup>
  - تعدیل<sup>۴</sup> و حذف کلمات مزاحم
  - استفاده از الگوریتم ریشه ساز جهت تولید ریشه‌های مفاهیم
- در مرحله شکستن کلمات، داده‌هایی که به صورت رشته‌ای از کاراکترها هستند مورد بررسی قرار گرفته و حدود کلمات و فاصله میان آنها مشخص می‌گردد؛ به نحوی که کلمات از یکدیگر جدا می‌شوند. در مرحله تعدیل طول سند در نظر گرفته می‌شود، کلمات مزاحم، بزرگ نویسی، نقطه‌گذاری، و مواردی از این دست مدیریت شده و حاصل مرحله اول تمیز می‌شود. کلمات مزاحم در نمایه‌سازی کلماتی هستند که بار معنایی خاصی ندارند و تنها برای ایجاد ارتباط و پیوستگی در جمله‌ها به کار می‌روند (ونگ، برمان، ۲۰۰۳) بعداز این مرحله، از الگوریتمی جهت تولید ریشه‌ها و مفاهیم استفاده می‌شود. هریک از اصطلاحات در نمایه دارای وزن یا ارزشی است که از طریق فرمول زیر به دست می‌آید. در این فرمول  $Tz$  نشانی برای اصطلاح زبان مقدار

1. Latent Semantic Indexing

2. Terminology oriented ontology

3. Word breaking

4. Normalization

$D_i = j$  و  $T_j = 1, 2, \dots, n$  نشانی از سند با مقادیر  $i_{f_{ij}} = 1, 2, \dots, n$  است.  $i_{f_{ij}}$  بسامد اصطلاح  $T_j$  در سند  $D_i$  و  $i_{df_j}$  معکوس بسامد سند است که مطابق با فرمول دوم محاسبه می‌شود. معکوس بسامد سند از طریق محاسبه لگاریتم خارج قسمت تقسیم تعداد سندها بر تعداد اسنادی که اصطلاح  $T_j$  در آنها آمده است به دست می‌آید.

$$w_{ij} = i_{f_{ij}} \cdot i_{df_j}$$

$$i_{df_j} = \log \left[ \frac{n}{df_j} \right]$$

جهت تعدیل و اعمال طول سند از سه فرمول زیر استفاده می‌شود به گونه‌ای که در فرمول دوم بسامد اصطلاح  $T_j$  در سند  $D_i$  بر بسامد هر اصطلاحی در سند که دارای بیشترین بسامد باشد تقسیم می‌شود. وزن حاصل، وزن تعدیل شده اصطلاح  $T_j$  در سند  $D_i$  است (ونگ، برمان، ۲۰۰۳).

$$w_{ij} = n i_{f_{ij}} \cdot n i_{df_j},$$

$$n i_{f_{ij}} = \frac{i_{f_{ij}}}{\max_i i_{f_{ij}}},$$

$$i_{df_j} = \log \left[ \frac{n}{df_j} \right]$$

در این رویکرد، سند، تنها با توجه به حضور کلید واژه‌ها نمایه سازی می‌شود؛ و وزن دهنی مطابق با فرمول شناخته شده‌ای که بیان شد محاسبه می‌گردد. در این روش اگر چه واژگان غیرمجاز حذف می‌شود، جامعیت بالا، مانعیت پایین، و معیار رتبه‌بندی مدارک تنها حضور کلید واژه‌ها در سند است.

## ۲. استناد محوری

گوگل دو ویژگی مهم دارد که باعث ایجاد مانعیت در بازیابی اطلاعات می‌شود؛ یکی تعیین رتبه صفحه<sup>۱</sup> و دیگری استفاده از پیوندها جهت بهبود تایج جست و جو، تعداد استنادهایی که به صفحه‌ای خاص در وب می‌شود نموداری از اهمیت و کیفیت آن است. رتبه صفحه مدلی از رفتار کاربران است. فرض طراحان گوگل آن است که جست و جو گر به شیوه آزمون و خطا عمل کند. در این صورت کاوش را از صفحه‌ای آغاز می‌کند، پیوندها را یکی پس از دیگری دنبال می‌کند و در صورت خسته شدن پیوند دیگری را دنبال خواهد کرد. رتبه صفحه میزان احتمالی است که در حالت جست و جوی تصادفی ممکن است آن صفحه خاص توسط جست و جو گر بازیابی و مشاهده شود. لازم به ذکر است که تنها تعداد استنادها در تعیین رتبه صفحه ملاک نیست و استناد از هر سایتی به یک میزان اهمیت ندارد. اطلاعات مربوط به پیوندها نیز به عنوان توصیفی مناسب در نمایه سازی استفاده می‌شود؛ به طور مثال، اگر سند A پیوندی به سند B داشته باشد متن پیوند یا همان متن کد لنگر به سند B مرتبط می‌گردد و جزء کلید واژه‌های سند A قلمداد نمی‌شود. علاوه بر این، جهت تعدیل، تعداد پیوندهای خارج شده از صفحه نیز مورد بررسی قرار می‌گیرد (برین و پیچ، ۱۹۹۸).

فرمول محاسبه رتبه صفحه چنین است:

$$PR(A) = (1-d) + d(PR(T_1)/C(T_1) + \dots + PR(T_n)/C(T_n))$$

در این حالت، d مقدار متغیری بین ۰ و ۱ است که اغلب ۸۵٪ در نظر گرفته می‌شود. استنادها به سند A هستند و C(A) تعداد پیوندهایی هستند که از صفحه خارج شده‌اند. این محاسبه توسط الگوریتمی تکراری محاسبه می‌شود (برین و پیچ، ۱۹۹۸). فرایند ذخیره و بازیابی در موتورهای کاوش شامل خزیدن، نمایه سازی، و جست و

جو رتبه بندی و نمایش است. خزیدن در گوگل توسط چند خزنده توزیع شده انجام می‌پذیرد. خدمت دهنده URL<sup>۱</sup> سیاهه‌ای از URL‌ها را جهت واکشی<sup>۲</sup> به خزنده‌ها می‌فرستد. URL‌ها بعداز واکشی به خدمت دهنده ذخیره<sup>۳</sup> می‌روند. در آنجا صفحات وب فشرده و در مخزن<sup>۴</sup> ذخیره می‌شوند. در این مرحله به هریک از صفحات شماره شناسایی docID اختصاص می‌یابد. فرایند نمایه سازی توسط نمایه ساز<sup>۵</sup> و سورتر<sup>۶</sup> انجام می‌پذیرد. نمایه ساز مخزن را می‌خواند، اسناد را از حالت فشرده خارج می‌سازد و تجزیه می‌کند. هر سند به گروهی از رخداد کلمه یا برخورد<sup>۷</sup> تبدیل می‌شود. برخوردها، کلمه، موقعیت کلمه در سند، اندازه قلم و بزرگ نویسی را ثبت می‌کنند. نمایه ساز این برخوردها را در گروهی از استوانه‌ها<sup>۸</sup> توزیع کرده و نمایه آغازین<sup>۹</sup> را که تقریباً مرتب شده است ایجاد می‌کند. نمایه ساز کار مهم دیگری نیز انجام می‌دهد و آن تجزیه همه پیوندها در هر کجای صفحه است، به طوری که اطلاعات مهم آنها را در فایل لنگرها<sup>۱۰</sup> ذخیره می‌کند. این فایل حاوی اطلاعاتی است که مسیر پیوندها را مشخص می‌سازد. تطبیق‌گر URL<sup>۱۱</sup> فایل لنگرها را خوانده و URL‌ها را تثبیت می‌کند. تطبیق‌گر در نمایه آغازین متن لنگر را به همراه docID مربوط به آن صفحه در وب سایت قرار می‌دهد. همچنین پایگاهی از پیوندها به docID خاص ذخیره می‌شود تا با استفاده از اطلاعات آن رتبه صفحه نیز محاسبه شود. سورتر برای ایجاد فایل مقلوب<sup>۱۲</sup> استوانه‌ها را که مطابق

1. URLserver

بازیابی دستور یا عنصر داده از حافظه و ذخیره آن در ثبات (فرهنگ تشریحی کامپیوتر Fetch)

میکروسافت. ذیل واژه)

3. Store server

4. Repository

5. Indexer

6. Sorter

7. Hit

8. Barrels


9. Forward Index

10. Anchors file

11. URL resolver

12. Inverted file

با docID مرتب شده بودند طبق wordID بازآرایی می‌کند. به علاوه، سورت‌ر فهرستی از wordID‌ها می‌سازد و به فایل مقلوب می‌فرستد. برنامه‌ای به نام Dumplexincon این سیاهه را با سیاهه قبلی که توسط نمایه ساز تولید شده در هم می‌آمیزد و قاموس<sup>۱</sup> جدیدی برای استفاده کاربران می‌سازد. کاوشگر، سرویس دهنده وب را اجرا می‌کند و قاموس ایجاد شده راهنمراه با فایل مقلوب ورتبه صفحات برای یافتن پاسخی بر جویش خود به کار می‌گیرد (برین و پیچ، ۱۹۹۸).



تصویر ۱. معماری موتور کاوش گوگل

در این رویکرد، اگر چه از نمایه سازی کلید واژه‌ای استفاده شده است، به منظور ارتقاء سطح کیفی و افزایش مانعیت، از تحلیل ساختارها به عنوان شاهدی بر اهمیت وب سایت‌ها در رتبه بندی استفاده می‌شود.

### ۳. معنامحوری

محققان دریافت‌های اند که با استفاده از موتورهای جست‌و‌جوگر می‌توانند اطلاعات مرتبه‌های بالاتر را نیز به دست آورند. منظور از اطلاعات مرتبه‌های بالاتر، اطلاعات درباره اموری است که مستقیماً در شبکه موجود نیست، بلکه در تراز بالاتر و به صورت انتزاعی در ساختار شبکه مندرج است و باید از کنار هم قرار دادن اطلاعات مرتبه اول یا اطلاعات مرتبه‌های بعدی آشکار شوند. از جمله محققانی که به این نکته عمیق فلسفی توجه کرده‌اند دو محقق به نام‌های پل ویتانی و رودی سیلیسراستی از مؤسسه ملی ریاضیات و کامپیوتر در آمستردام هلند هستند که در زمینه تولید کامپیوترهای هوشمند فعالیت می‌کنند (موتورهای جست و جو به دنبال معنا، ۱۳۸۳).

این دو محقق برای بهره‌گیری از اطلاعات مرتبه دوم یک مدل آماری طراحی کرده‌اند که نزدیکی و دوری کلمات مختلف را بر حسب شمار مواردی که این کلمات به همراه هم در فهرست‌های موتورهای جست و جوگر ظاهر می‌شوند، اندازه‌گیری می‌کند به طور مثال، با کمک این مدل می‌توان دریافت که ارتباط دو واژه "سر" و "کلاه" که در ۹ میلیون مورد به همراه هم در فهرست‌های گوگل ظاهر می‌شوند از رابطه میان دو واژه "سر" و "مو" که تنها در نیم میلیون مورد باهم ظاهر می‌شوند، به مراتب نزدیک‌تر است. به اعتقاد این دو محقق، با کاربرد این مدل آماری در مورد واژگان مختلفی که در فهرست‌های موتورهای جست و جوگر اینترنتی موجود است می‌توان نرم‌افزارهایی تولید کرد که قادر باشند به صورت خودکار و صرفاً با نظر به درجه همبستگی میان واژگان متفاوت معنای آنها را تشخیص دهند (موتورهای جست و جو به دنبال معنا، ۱۳۸۳)

در حال حاضر اغلب موتورهای کاوش رویکردی مکانیکی دارند و به مفاهیم، الگوهای و کلیدهایی که به فهم مفاهیم می‌انجامد توجهی ندارند. در این ابزارها، جست و جوی واقعی صرفاً بر مبنای کلید واژه‌های است. استفاده از فهرست متراffد‌ها، بهره‌گیری از جست و جوی فازی<sup>۱</sup> و تجربیات گیج کننده‌ای در حوزه هوش مصنوعی از جمله

راهبردهای مطرح شده جهت رفع مشکلات جست و جوی کلید واژه‌ای است. روشی که در اینجا مطرح است بهره‌گیری از نمایه‌سازی معنایی پنهان جهت بهبود مانعیت، جامعیت، و رتبه‌بندی نتایج کاوش است (یو و دیگران،<sup>۱</sup> ۲۰۰۲).

### ۱-۳. LSI نمایه سازی معنایی پنهان

طبق اخبار جدید، گوگل در الگوریتم رتبه‌بندی خود ارزش فراوانی به نمایه سازی معنایی پنهان داده است. نمایه سازی معنایی پنهان به کاربران این اجازه را می‌دهد که جست و جوی خود را به مفاهیم، و نه فقط کلید واژه‌ها، محدود کنند. اگر در ابتدای کلید واژه مورد نظر بدون گذاشتن فاصله، علامت تایپ شود، گوگل به جست و جو در نمایه معنایی خویش پرداخته و نتایج مرتبط با مفهوم را بازیابی می‌کند.<sup>۲</sup>

به همین ترتیب، از این پس گوگل در بازیابی اطلاعات چندان اعتباری برای رتبه صفحه قائل نمی‌شود. به طوری که ممکن است صفحاتی با رتبه صفحه بسیار پایین در ۱۰ نتیجه بازیابی شده در مرتبه بالاتری قرار گیرند.<sup>۳</sup>

LSI ابتدا در دهه ۱۹۸۰ مطرح شد. در جست و جوی کلید واژه‌ای تنها دو حالت مطرح است یا کلید واژه در سند موجود است و یا موجود نیست، بدون اینکه حد میانی مدنظر باشد. اسنادی که حاوی کلید واژه هستند از سایر اسناد جدا شده و طبق الگوی رتبه‌بندی خاصی به نمایش در می‌آیند. اما در LSI علاوه بر در نظر گرفتن کلید واژه‌های سند، مجموعه اسناد به طور کلی مورد بررسی قرار می‌گیرند و به این ترتیب اسناد مرتبط نیز بازیابی می‌شوند.

مشکل اصلی انسان با ماشین آن است که چگونه مفاهیم را به ماشین بیاموزد. در LSI این فرایند تنها با استفاده از محاسبات ریاضی انجام می‌پذیرد، بدون اینکه نیاز به درک

1. Yu et al

2. <http://www.pacificwebsites.com/news-google-sandbox/latent-semantic-indexing.htm>

3. <http://www.pacificwebsites.com/news-google-pagerank/google pagerand-news.htm>

مفهوم از سوی ماشین باشد. به همین سبب است که نمایه سازی با این روش محدودیت زبانی ندارد و می‌تواند همراه با جست و جوی کلید واژه‌ای مورد استفاده قرار گیرد (یو و دیگران، ۲۰۰۲).

LSI به الگوی توزیع کلمات در اسناد به خصوص همایندی کلمات<sup>۱</sup> توجه دارد. آنچه در عمل انجام می‌پذیرد می‌توان چنین برشمرد:

- وجود اسناد الکترونیکی.
- نادیده گرفتن فرمت متن شامل بزرگ نویسی، نظم کلمات، نشانه‌گذاری، و غیره.
- بیرون کشیدن کلمات متن و حذف کلمات زائد از طریق سیاهه بازدارنده<sup>۲</sup>.
- در این مرحله، کلمات متداول که در همه اسناد یافت می‌شوند به علاوه کلماتی که تنها در یک سند از آنها استفاده شده نیز حذف می‌گردد.
- ریشه‌یابی<sup>۳</sup> جهت درآوردن ریشه کلمات، ریشه‌یابی و حذف کلمات زائد، وابسته به زیان است. توسط نرم‌افزارهای خاصی انجام می‌شود؛ به طور مثال، می‌توان از Porter استفاده کرد.
- تنظیم سیاهه کلمات. در مراحل قبلی نشانه‌گذاری‌ها، دستور زبان و سبک از میان می‌رفت. در این مرحله نظم کلمات نیز با انتقال کلمات به سیاهه کلمات، از میان می‌رود.
- تولید ماتریس اصطلاح - سند<sup>۴</sup> به طوری که اسناد به صورت افقی و کلمات متن به صورت عمودی ظاهر می‌شوند.
- وزن دهی<sup>۵</sup> و تعدیل. در این مرحله دو نوع وزن دهی انجام می‌پذیرد. یکی وزن دهی جایگاهی<sup>۶</sup> و دیگری وزن دهی کلی<sup>۷</sup>. در وزن دهی جایگاهی کلماتی که بسامد بالایی

1. Word co-occurrence

2. Stop list

3. Stemming

4. term-document matrix:TDM

5. Weighing

6. Local weighting

7. Global term weighting

دارند وزن جایگاهی بیشتری نسبت به کلماتی که بسامد کمتری دارند خواهند گرفت. برای محاسبه این وزن از فرمول وزندهی جایگاهی لوگاریتمی<sup>۱</sup> استفاده می‌شود. اما وزندهی کلی، سند را در مجموعه اسناد در نظر می‌گیرد. این مقدار به روش‌های مختلفی به دست می‌آید و نمایانگر این مطلب است که در مجموعه اسناد، کلماتی که کمترین میزان حضور را دارند از کلماتی که در اغلب متون توزیع شده و به چشم می‌خورند وزن بیشتری دارند. یکی از طرح‌هایی که وزن کلی را تخمین می‌زند محاسبه معکوس بسامد سند<sup>۲</sup> است. در این مرحله تعدیل نیز انجام می‌پذیرد. در نهایت، وزن عددی واقعی مقادیر ماتریس سند - اصطلاح تخمین زده می‌شود. طبق محاسباتی که انجام می‌شود مقدار ماتریس تغییر می‌کند. مقادیر مثبت و منفی اعداد، بزرگی و شباهت یا تفاوت اسناد را آشکار می‌سازد. به‌طوری که اعداد منفی در ماتریس نشان دهنده رابطه منفی میان اسناد است.


● اجرای الگوریتم تجزیه مقادیر منفرد (SVD)<sup>۳</sup> و شکستن ماتریس اصطلاح - سند. این گام کاملاً مکانیکی است و در هر زبانی مستقل از مفاهیم انجام می‌پذیرد. فرض کنیم می‌خواهیم نوع و پراکندگی سفارش صبحانه در روزی خاص را بررسی کنیم. ترکیبی از سه قلم قابل سفارش را در نظر می‌گیریم، هریک از افراد مجموعه به عنوان سندی در نظر گرفته می‌شود و تقاضای آنها در برداری سه بعدی مشخص می‌شود. آنچه در این فضای مشخص شده است فضای اصطلاح<sup>۴</sup> نامیده می‌شود. نمونه‌ای از فضای اصطلاح در تصویر ۲ آمده است (یو و دیگران، ۲۰۰۲).

1. Logarithmic Local Weighting

2. Inverse document frequency

3. Singular Value Decomposition


4. Term Space



تصویر ۲. بردار سه بعدی سفارش صبحانه

در این مثال، چون سه کلید واژه داریم فضای اصطلاح سه بعدی است اما به تبع اضافه شدن کلید واژه‌ها بر ابعاد فضا افزوده می‌شود. هر سند در این مجموعه، برداری تشکیل می‌دهد. در این فضا اسنادی که کلمات مشابه دارند نزدیک هم و اسنادی که کلمات مشترک اند کی دارند از یکدیگر دور هستند. به این ترتیب، فضای اصطلاح ممکن است ده‌ها بُعد داشته باشد. الگوریتم SVD همزمان با کوچک کردن ابعاد تا جایی که امکان دارد اطلاعات مربوط به فواصل بردارها را حفظ می‌کند. در این فرایند، اطلاعاتی از بین خواهد رفت. از دست دادن اطلاعات نکته‌ای منفی به نظر می‌رسد، اما در این مورد آنچه حذف می‌شود خشنه<sup>۱</sup> است. به گونه‌ای که شباهت‌های پنهان در اسناد مجموعه آشکار می‌شود. اسناد مشابه به هم نزدیک می‌شوند و اسناد غیر مرتبط از هم فاصله می‌گیرند. SVD ماتریس را شکسته و پس از شکستن، ماتریس‌های دیگری را دوباره ترکیب می‌کند و شبکه‌ای معنایی تشکیل می‌دهد. ماتریس به دست آمده تقریبی از ماتریس اولیه است و جست و جو از طریق آن انجام می‌پذیرد (یو و دیگران، ۲۰۰۲). در تصویر ۳ اجرای الگوریتم SVD نمایش داده شده است.

1. noise



تصویر ۳. اجرای الگوریتم SVD (دروسترو و دیگران، ۱۹۶۰)

از طریق الگوریتم SVD سه نوع مقایسه قابل اجراست:

۱. مقایسه دو اصطلاح او زبا یکدیگر

۲. مقایسه دو سند او زبا یکدیگر

۳. بررسی میزان ارتباط و شباهت اصطلاح او با سند (دروسترو و دیگران، ۱۹۹۰)

هنگامی که پرسشی جهت جست و جو وارد سیستم می شود، سیستم به بررسی مقدار وزن های هر ترکیب اصطلاح / سند می پردازد، میزان شباهت ها را محاسبه می کند، و اسناد را مطابق با میزان شباهت محاسبه شده، رتبه بندی کرده نمایش می دهد. در عمل، وزن یا مقداری به عنوان آستانه ارزش<sup>۲</sup> در نظر گرفته می شود که حد میان اسناد مرتبط و غیر مرتبط است (یو و دیگران، ۲۰۰۲).


**۳-۱-۱. مقیاس گذاری چند بعدی (MDS) تکنولوژی ضمیمه LSI**  
تلash الگوریتم SVD کاهش ابعاد ماتریس است، اما در ابعاد بالا نمایش بصری

1. Deerwester et al

2. Threshold Value

3. Deerwester et al

بردارها غیرقابل انجام است. لذا از تکنولوژی دیگری به نام MDS استفاده می‌شود. MDS تکنولوژی ضمیمه LSI است که به خلق تصویری دو یا سه بعدی از داده‌های پیچیده مجموعه می‌پردازد. حاصل الگوریتم MDS الگوی پراکندگی داده‌های است. به طوری که نمایانگر طبقاتی<sup>۱</sup> از استناد است. طبقات به طور خود به خود و به واسطه الگوی همایندی کلمات در مجموعه داده‌ها شکل می‌گیرند، به گونه‌ای که مجموعه ساخت نیافته داده‌ها در طبقه‌هایی که نمایندۀ موضوعی خاص هستند جای می‌گیرند. در واقع، الگوی دو بعدی حاصل، نمونه کوچکی است از آنچه LSI در ابعاد بزرگ‌تر ایجاد می‌کند(یو و دیگران، ۲۰۰۲). همان‌گونه که در تصویر ۴ مشاهده می‌شود هریک از حوزه‌های تجمع استناد نشان دهنده طبقه‌های موضوعی خاص است.



تصویر ۴. نمونه‌آی از نمودار MDS(یو و دیگران، ۲۰۰۲)

LSI مشکل مربوط به کلمات متراffد را به خوبی رفع می‌کند و به استناد اخبار موجود، گوگل از این روش نمایه سازی نیز بهره می‌گیرد.<sup>۲</sup>

1. Clusters

2. <http://www.pacificwebsites.com/news-google-sandbox/latent-semantic-indexing.htm>

### ۲-۳. نمایه سازی بر مبنای هستی‌شناسی لغوی

نمایه سازی بر مبنای کلید واژه‌های صفحات وب بر جامعیت افزوده و مانعیت را کاهش می‌دهد. نمایه سازی بر مبنای هستی‌شناسی، فرایندی است نیمه‌خودکار<sup>۱</sup> و هدف اصلی آن ساخت نمایه‌ای ساخت یافته از صفحات وب است، به گونه‌ای که تنها بر کلید واژه متکی نباشد و بازنمونی از مفاهیم صفحه به شمار آید. در واقع هستی‌شناسی ساختار نمایه را فراهم می‌آورد.

هستی‌شناسی معمولاً متشکل از مجموعه‌ای از رده‌ها(مفاهیم) روابط، عملکردها، اصول بدیهی و نمونه‌ها تصور می‌شود(جمالی مهموئی، ۱۳۸۲، ص ۵۹). هستی‌شناسی اصطلاحات را در مجموعه‌های متراffد سازمان می‌دهد و سپس از روابط برای پیوند مجموعه‌های متراffد استفاده می‌کند. از جمله ارتباطات نشان داده شده در هستی‌شناسی لغوی، متراffد‌ها، اصطلاحات همارا، همارز، اصطلاحات کل به جزء، اصطلاحات مرتبط و متضاد‌هاست(تیلور، ۱۳۸۱، ص ۲۱۳).

### ۲-۱. فرایند نمایه سازی

فرایند نمایه سازی در چندین مرحله انجام می‌پذیرد:

- استخراج اصطلاحات و ساخت نمایه گسترده<sup>۲</sup> از صفحات وب. هر اصطلاح در این نمایه با بسامد وزنی<sup>۳</sup> مربوط به آن اصطلاح مرتبط می‌شود. استخراج اصطلاحات با حذف نشانه‌های HTML از صفحه انجام می‌پذیرد. متن به جملات مستقل تفکیک شده هر کلمه در صفحه با نقش دستوری آن(اسم، اسم+اسم، صفت+اسم) مشخص و تجزیه و تحلیل می‌شود. سپس برای هر اصطلاح بسامد وزنی محاسبه می‌گردد. این وزن دهی

1. Semi-automatic

2. Flat index

فاقد ساختار، فاقد اطلاعات ساختاری که بازیابی مؤثر اطلاعات با ممکن می‌سازد(فرهنگ تشریحی

اصطلاحات کامپیوتر، ذیل واژه(flat) کاربران

3. Weighted frequency

از طریق محاسبه بسامد اصطلاح و اعمال نوع نشانه‌های HTML مربوط به آن رخداد انجام می‌پذیرد. دو فرمول برای محاسبه بسامد وزنی مورد استفاده قرار می‌گیرد. طبق جدولی هریک از نشانه‌های HTML وزنی دارد؛ به طور مثال، نشانگر عنوان وزن ۱۰ و نشانگر خط کلفت<sup>۱</sup> وزن ۲ دارد. در فرمول‌های زیر بسامد وزنی ( $F(T_i)$ ) با محاسبه مجموع بسامد اصطلاحات ضرب در وزن نشانه مربوط به آن و سپس تعدیل از طریق تقسیم مقدار ( $P(T_i)$ ) بر مقدار بسامد وزنی اصطلاح  $K$  ( $P(T_k)$ ) که بیشترین میزان بسامد وزنی را داراست انجام می‌پذیرد. در فرمول نخست ( $M_{i,j}$ ) مربوط به  $j$  بار تکرار اصطلاح  $T_i$  با توجه به وزن نشانه‌های HTML آن است (دسماتیل و جکوئین، ۲۰۰۲).

$$P(T_i) = \sum_{j=1}^p (M_{i,j}) \quad F(T_i) = \frac{P(T_i)}{\max_{k=1..n}(P(T_k))}$$

- تعیین مفاهیم صفحه. پس از آنکه اصطلاحات با بسامد وزنی تعیین گردید، به منظور لحاظ کردن مفاهیم صفحه در فرایند نمایه سازی از اصطلاح‌نامه استفاده می‌شود. از میان مفاهیم استخراج شده در مرحله نخست، مفاهیم کاندید با توجه به اصطلاح‌نامه مشخص می‌گردد. هر مفهوم با سیاهه‌ای از مترادف‌ها همراه است.

- اندازه‌گیری میزان بازنمونی<sup>۲</sup>: برای هریک از مفاهیم کاندید، میزان بازنمونی با توجه به بسامد وزنی و تشابه اباسته<sup>۳</sup> میان مفهوم کاندید با سایر مفاهیم مربوط به صفحه محاسبه می‌شود. میزان تشابه مفاهیم به صورت دو به دو محاسبه می‌گردد و سپس مجموع آن در نظر گرفته می‌شود. میزان تشابه میان مفاهیم به اصطلاح‌نامه مورد استفاده بستگی دارد و، در واقع، در این فرایند فاصله مفهومی میان مفاهیم بررسی می‌شود. در نهایت میزان ضریب بازنمونی، ضریبی از ترکیب خطی بسامد وزنی و<sup>۴</sup> ضریب مربوط به تشابه اباسته مفهوم است. این ضریب عامل مؤثری در بهبود کیفیت پاسخگویی به


1. Bold font

2. representative ness

3. cumulative similarity

پرس و جوی کاربران است.

- تا اینجا از طرفی هستی‌شناسی و از طرفی مفاهیم کاندید به همراه میزان بازنمونی را در اختیار داریم. در این مرحله مفاهیم کاندید با مفاهیم موجود در هستی‌شناسی مطابقت داده می‌شود. اگر مفاهیم کاندید در هستی‌شناسی و همچنین در صفحه نمایه شده موجود باشد، URL صفحه به همراه میزان بازنمونی آن به هستی‌شناسی اضافه می‌شود. نمایه در فرمت XML و به صورت مستقل از صفحه ذخیره می‌شود. در تصویر ۵ فرایند نمایه سازی به تصویر کشیده شده است (دسماتیل و جکوئین، ۲۰۰۲).



تصویر ۵. فرایند نمایه سازی

در بسیاری از موتورهای کاوش از کلید واژه‌ها در نمایه سازی صفحات استفاده می‌شود و بر مبنای فهرستی از واژه‌ها و استفاده از عملکردهای فرایند پاسخگویی به پرسش‌ها صورت می‌پذیرد؛ اما در این روش می‌توان از نمایه ساخت یافته‌ای استفاده کرد؛ به این ترتیب پرس و جوها تنها در سطح اصطلاحی<sup>۱</sup> پردازش نمی‌شود بلکه در

سطح مفهومی<sup>۱</sup> نیز پردازش می‌گردد. بسط پرس و جواز طریق استفاده از هستی‌شناسی امکان‌پذیر است. در این رویکرد اصطلاحاتی که به عنوان پرسش وارد سیستم می‌شوند با مفاهیم مرتبط جا به جا می‌گردند و در ابتدا مفاهیم کاندید در هستی‌شناسی انتخاب می‌شوند. در انتها اگر اصطلاح با مفاهیم کاندید دیگری نیز مرتبط باشد همکاری کاربر ضروری است (دسمانتیل و جکوئین، ۲۰۰۲).

### ۲-۲-۳. ابرداده

اغلب موتورهای کاوش اهمیت فراوانی به ساختار صفحات می‌دهند. به این معنی که نوع نشانه‌ها گویای ارزش اطلاعاتی است که در آن نشانه نمایان شده است. چنانکه بیان شد، در نمایه سازی با تکیه بر هستی‌شناسی، نشانه‌ها ارزش‌های متفاوتی داشتند که در محاسبه وزن اصطلاح لحاظ می‌شد. از طرفی امکان استفاده از ابرداده‌ها در قالب ابرنشانه‌های رایج در زبان HTML فراهم آمده است. تلاش در زمینه تحقق وب معنایی نیز به استانداردسازی ساختارها و تفسیر و پردازش استاندارد موجودیت‌های توصیف شده در آنها تأکید دارد.

همزمان با گسترش وب بسامد واژه ابرداده در متون مربوط به سازماندهی اطلاعات در این محیط پویا و رو به گسترش افزایش یافت. به طوری که می‌توان گفت "در عصر اینترنت، شاید هیچ داده‌ای ارزشمندتر از داده درباره داده نباشد" (السوب<sup>۲</sup>، ۲۰۰۰ نقل در صفری، ۱۳۸۲، ص ۱۷).

در نگاهی تیزبین نمی‌توان ابرداده را تنها به محیط دیجیتالی محدود ساخت. همواره در طول زمان، داده ساختارمند درباره داده از ارزش فراوانی برخوردار بوده است. در مثالی ساده می‌توان فهرستگرهای کتابخانه رامجموعه‌ای ابرداده‌ای دانست که جست و جو، بازیابی و جایابی اقلام اطلاعاتی را تسهیل می‌کند.

برای ابرداده تعاریف متعددی ارائه شده است که ساده‌ترین آنها داده درباره داده

است. این داده باید ساختارمند<sup>۱</sup> و به گونه‌ای ماشین فهم و ماشین خوان باشد(دی،<sup>۲</sup> ۱۳۸۳؛ نقل در صفری، ۱۳۸۳، ص ۱۵). می‌توان گفت ابرداده، داده‌ای است که خصوصیات داده‌های اصلی را بیان می‌کند، روابط آنها را توصیف می‌کند، و کشف و استفاده مؤثر از آنها را میسر می‌سازد(برنت<sup>۳</sup>؛ نقل در صفری، ۱۳۸۳: ۱۶).

ابرداده در تور جهانگستر به منظور یاری رساندن به کاربران برای یافتن اطلاعات مورد نظر مطرح شده است. وجود توصیفی یک دست، دقیق و خوش ساخت از منابع موجود در تور جهانگستر اجازه حصول دقت بیشتر در مجموعه نتایج به دست آمده از کاوش(چه از طریق راهنمایی و چه از طریق موتورهای کاوش) را خواهد داد(نقشینه، ۱۳۷۹، ص ۳۵).

طرح دابلین کور یکی از طرح‌های ابرداده‌ای جهت آشکار ساختن مفاهیم و معانی صفحات وب در قالب ۱۵ ابرنشانه است که کاربرد گستردگی‌های پیدا نکرد؛ اما استفاده از ابرنشانه‌ها از سوی طراحان وب سایت‌ها مورد توجه قرار گرفته است. برخی از موتورهای کاوش این نشانه‌ها را در فرایند نمایه سازی خویش لحاظ کرده و ارزش خاصی برای آنها قائلند. در زبان HTML می‌توان از ابرنشانه‌ها استفاده کرد که مهم‌ترین آنها ابرنشانه توصیفگر و کلید واژه است.

● ابرنشانه از نوع توصیفگر (ابرنشانه توصیفگر): این نوع ابرنشانه‌ها برای آگاهی از محتوای صفحات وب اهمیت خاصی دارند. زیرا از طریق آنها می‌توان توصیف خلاصه‌ای درباره صفحات وب درج کرد و پس از بازیابی صفحات وب در معرض دید کاربران قرار داد(کوشان، ۱۳۸۰، ص ۱۳۸).

● ابرنشانه از نوع کلید واژه (ابرنشانه کلیدواژه): این نوع ابرنشانه‌ها، در واقع، کلمات و واژه‌هایی هستند که به توصیف محتوای یک صفحه وب می‌پردازند(کوشان، ۱۳۸۰، ص ۱۳۹).

1. Structured data

2. Day

3. Burnett

ابرنشانه‌ها در صفحه نمایش داده نمی‌شوند و تنها در فرایند نمایه‌سازی از سوی برخی موتورهای کاوش مورد استفاده قرار می‌گیرند. جای این ابرنشانه‌ها قبل از نشانه متن **<BODY>** در واقع در محدوده نشانه سرصفحه **<HEAD>** و بعد از نشانه عنوان **<TITLE>** است (علیمحمدی، ۲۰۰۳). در حالیکه برخی موتورهای کاوش، به علت عدم اعتماد، ابرنشانه‌ها را نادیده می‌گیرند؛ با این همه، به کارگیری مؤثر این ابرنشانه‌ها معمولاً به طراحان وب سایت‌ها توصیه می‌شود.

### ۳-۲-۳. داده‌های ساختار یافته و وب معنایی

موتورهای کاوش جاری تنها قادرند صفحات محدودی از وب را که مرئی<sup>۱</sup> یا نمایه‌پذیر نامیده می‌شوند مرور کنند. بسیاری از اطلاعات علمی مفید در پشت درهای بسته مانده است. اندازه وب مرئی یا وب سطحی<sup>۲</sup> از وب نامرئی به مراتب کوچک‌تر است. پایگاه‌های گوناگون فهرست کتابخانه‌ها، کتاب‌ها و مجلات دیجیتال، پروانه‌های ثبت اختراع، گزارش‌های مربوط به تحقیقات و آرشیوهای دولتی از جمله نمونه‌های وب نامرئی است. برای رفع این نقص حرکت به سمت وب معنایی با تکنولوژی‌هایی چون XML و RDF است تا منابع وب ساخت یافته‌تری تولید گردد (اسدی و جمالی مهموئی، ۲۰۰۴).

مبتكر وب معنایی آن را چنین تعریف کرده است: "وب متشکل از داده‌ها که به صورت مستقیم یا غیرمستقیم توسط ماشین قابل پردازش هستند" (برنرزلی و فیسکتی، ۱۹۹۹، ص ۱۹۱، نقل در جمالی مهموئی، ۱۳۸۲، ص ۵۱). وب معنایی، داده‌های ساختاربندی شده‌ای به وب کنونی می‌افزاید که پردازش آنها برای رایانه‌ها آسان است (جمالی مهموئی، ۱۳۸۲، ص ۵۱). هم اکنون بازیابی اطلاعات وب، عموماً براساس تطابق لغات و عبارات مورد جست و جو با واژه‌ها و عبارات موجود در متن صفحات وب صورت می‌گیرد. وب معنایی از تطبیق صرف واژه‌ها فراتر است و جست و

جو را براساس موضوع، ارتباط میان داده‌ها، نوع داده‌ها، و کیفیت‌های دیگر انجام می‌دهد (جمالی و مهموئی، ۱۳۸۲، ص ۵۲).

وقتی اطلاعات دیجیتال شد، XML وارد عمل می‌شود. جست و جو و نمایش اطلاعات در صورتی که به روشی معنادار ساختاربندی نشده باشد، ناممکن است. به زبان ساده، تولیدکنندگان اطلاعات باید برای استفاده از منابع اطلاعاتی براساس استاندارد خاصی به برنامه نویسی و کدگذاری اسناد الکترونیکی پردازند (زارع زاده، ۱۳۸۳، ص ۴۱). با استفاده از فرازبان XML می‌توان عناصر ابرداده‌ای را به اسناد افزود، اما هنوز در این حالت، ابرداده‌ها قابلیت پردازش توسط رایانه را ندارند، لذا برای افزودن قابلیت پردازش از RDF و فرانمای<sup>۱</sup> آن استفاده می‌شود.

تا این مرحله رایانه‌ها قادر به تشخیص محتوای صفحات وب شده‌اند و می‌توانند ابرداده‌ها را پردازش کنند؛ اما برای آنکه نظام‌های مختلف رایانه‌ای قادر به تبادل داده‌ها و استفاده از آنها باشند بایستی از سطح قابل قبولی از عمل پذیری درونی<sup>۲</sup> برخوردار باشند. زمینه این ویژگی اگرچه با استفاده از XML و RDF تا حدودی فراهم شده اما کامل نیست. لذا برای تکمیل آن از هستی‌شناسی وب استفاده می‌شود. هستی‌شناسی، درک مشترکی میان رایانه‌ها و نیز میان انسان و رایانه ایجاد می‌کند تا بتوان از داده‌های وب در نرم‌افزارهای مختلف استفاده کرد. مرحله نهایی، تدارک موتورهای استنتاج<sup>۳</sup> است که از قدرت پردازش دانش موجود در وب برخوردارند (جمالی مهموئی، ۱۳۸۲، ص ۶۰).

پیش نیاز کاربرد هستی‌شناسی‌ها در وب معنایی توسعه استانداردی برای تعریف و

---

#### 1. Resource Description Framework Schema

اشارة به مؤلفه‌هایی از سیستم‌های کامپیوتری است که می‌توانند در محیط‌های گوناگون عمل کنند... چنین حالتی در مورد نرم‌افزار زمانی رخ می‌دهد که برنامه‌ها بتوانند داده و منابع را به اشتراک گذارند (فرهنگ تشریحی میکروسافت، ۱۳۷۹، ذیل واژه)

#### 3. Inference engine

مبادله هستی‌شناسی یا به عبارتی، زیان‌های بازنمون هستی‌شناسی است (فنسل و دیگران، ۲۰۰۱؛ نقل در صفری، ۱۳۸۳، ۹۷) زبان‌هایی چون RDF را که در توسعه زبان‌های دیگری چون OIL<sup>۱</sup> و DAML+OIL<sup>۲</sup> نقش داشته است می‌توان به عنوان نمونه‌هایی معروف از این زبان‌ها ذکر کرد (صفری، ۱۳۸۳، ص ۹۷).

در وب معنایی از نمایه سازی معنایی بحث می‌شود. تلاش‌ها جهت تلفیق این نمایه سازی با مدل‌های موجود - نمادین و آماری - در حال انجام است. این نوع نمایه سازی با توجه به هستی‌شناسی و تحلیل ابرداده‌ها انجام می‌پذیرد (کریاکوف و دیگران، ۲۰۰۴). رؤیایی وب معنایی هنوز تحقق نیافته است، اما تحقیقات و تلاش‌ها در این زمینه در حال پی‌گیری است. موتورهای کاوش حاضر جهت ارتقاء عملکرد به بهبود الگوریتم‌های خویش می‌پردازند و در تلاشند تا راهکاری برای رویارویی با وب نامرئی بیابند.

### بحث و نتیجه گیری

در این بررسی، رویکردهای نمایه سازی خودکار در وب نشان داده شد. بدون وجود نظام نمایه سازی مناسب، اطلاعات ارزشمند وب، نامرئی باقی خواهد ماند. هر یک از روش‌های نمایه سازی نقاط ضعف و قوتی دارد که در سایه تحقیقات آشکار خواهد شد. آنچه پشت صحنه موتورهای کاوش به عنوان ابزارهای اصلی کاوش در وب انجام می‌پذیرد بیشتر به نمایه سازی کلید واژه‌ای محدود می‌شود. اگرچه استفاده مناسب از تحلیل پیوندها و به بیانی استناد محوری بر کیفیت نمایه سازی کلید واژه‌ای افزوده است. مدل‌های آماری جدید جهت آشکار ساختن شبکه معنایی مانند آنچه در موتور کاوش گوگل در حال انجام است تا اندازه‌ای امیدوارکننده است. حرکت‌های جاری به سمت بهره‌گیری از داده‌های ساختار یافته و تحقیق وب معنایی است، اما این حرکت‌ها تاکنون

1. Ontology Inference Layer/Language

2. DARPA Agent Mark up Language

3. Kiryakov et al

به طور کامل به سرانجام نرسیده است و هنوز مشکلات حل نشده فراوانی در این مسیر وجود دارد. وب تنها متعلق به متخصصان علوم کامپیوتر نیست. تلاش‌های مشارکتی در دسترس پذیر ساختن اطلاعات وب باید از سوی گروهی از متخصصان و به صورت میان رشته‌ای انجام پذیرد. بی‌گمان کتابداران و اطلاع رسانان به عنوان متولیان سازماندهی دانش بشر، در این مشارکت می‌توانند و باید نقش مؤثری ایفا کنند. تلاش در این زمینه نیازمند مهارت‌ها و دانش پایه‌ای است که لازم است از سوی این متخصصان مورد توجه واقع شود.

به گفته لینچ<sup>۱</sup> (۱۹۹۷) "مهارت‌های کتابدار در طبقه بندی و انتخاب بایستی به وسیله توانایی متخصص رایانه تکمیل شود تا بتوان وظیفه نمایه سازی و ذخیره سازی اطلاعات را خودکار نمود. تنها ترکیبی از دیدگاه‌های مختلف (متخصصان) هر دو حرفه اجازه خواهد داد تا این رسانه جدید پویا باقی بماند (larg، تد، و هارتلی، ۱۳۸۳، ص ۱۵۹).

## مأخذ

- پفامنرگر، برايان (۱۳۷۷). فرهنگ تشریحی اصطلاحات کاربران کامپیوتر، تهران: ناقوس.
- تیلور، آرلین جی (۱۳۸۱). سازماندهی اطلاعات. ترجمه محمدحسین دیانی. مشهد: کتابخانه رایانه‌ای.
- جمالی مهموئی، حمیدرضا (۱۳۸۳). "وب معنایی: شبوهای رو به تکامل برای ذخیره و بازیابی کارآمدتر اطلاعات روی اینترنت". اطلاع‌شناسی، (۳): ۴۹-۶۶.
- رودکی، مهدی (۱۳۸۳). "ما گرسنگان اطلاعات". اینترنت ITNA اخبار فناوری اطلاعات. پیوسته:
- [۳۰] <http://www.itna.ir/archives/article/002041.php>
- زارع زاده، فاطمه (۱۳۸۳). "ایکس. ام. ال چیست و چه کاربردهایی در کتابخانه دارد؟". فصلنامه کتاب. (۱۵) (۳): ۳۷-۴۴.
- صفری، مهدی (۱۳۸۳). "سنجهش میزان اثربخشی عناصر ابردادهای دابلین کور در بازیابی صفحات وب: مطالعه

صفحات وب "Jurnal of Science Iranian International". پایان نامه کارشناسی ارشد کتابداری و اطلاع رسانی. دانشکده علوم تربیتی. دانشگاه تهران.

صفری، مهدی(۱۳۸۳). "مدل سازی مفهومی در بازنمون رسمی دانش: شناختی از هستی‌شناسی در هوش مصنوعی و نظام‌های اطلاعاتی". اطلاع‌شناسی. ۱(۴): ۷۵-۱۰۴.

فرهنگ تشریحی میکروسافت(۱۳۷۹). ترجمه رضا حسنودی و داریوش فرسانی. تهران: نشر دانشیار؛ پیک علوم.

کوشان، کیوان(۱۳۸۰). ابزارهای کاوش اینترنت: اصول، مهارت‌ها و امکانات جست و جو در وب. تهران: نشر کتابدار.

لارج، آندرو؛ تد، لوسی؛ هارتلی، ریچارد(۱۳۸۳). جستجوی اطلاعات در عصر اطلاعات: اصول و مهارت‌ها. ترجمه زاهد بیگدلی؛ ویراسته زهیر حیاتی. تهران: نشر کتابدار.

منتظر، غلامعلی(۱۳۸۱) موتورهای کاوش اینترنت(درآمدی در بازیابی بهینه اطلاعات). تهران: کویر. "مоторهای جست و جو به دنبال معنا" (۱۰ بهمن ماه ۱۳۸۳). اینتا ITNA اخبار فناوری اطلاعات. پیوسته: [۱۳۸۳ ۲۰] <http://www.itna.ir/archivs/news/001950.php>

نقشینه، نادر(۱۳۷۹). "مقدمه‌ای بر فراداد" علوم اطلاع رسانی. ۱۵(۳ و ۴): ۳۱-۳۷.

Alimohammadi,Daryoush(2003)."Meta-tag: a means to control the process of Web indexing. Online Information Review. 27(4): 238-242. Available at:

<http://taddeo.emeraldinsight.com/vl=1364367/cl-158/nw=1/fm=html/rpsv/cw/mcb/14684527/v27n4/s2/p238>

Asadi,S., & Jamali M., H.R.(2004). "Shifts in search engine development: A review of past, present and future trends in research on search engines". *Webology*,1(2),Article 6.Available at:  
<http://www.webology.ir/2004/v1n2/a6.html>

Bradshaw,Shannon; Hommond, Kristian(2002)."Automatically indexing documents: Content vs. Reference". INternational Conference on Intelligent User Interfaces, Proceedings IUI,2002,p 180-181.{compendex database} Available at:

<http://www.engineeringvillage2.org/controller/servlet/Controller?CID=quickSearchAbstractFormat&SEARCHID=18e261d103560e65f5M5b1bcv2100127DOC>

- INDEX=17PAGEINDEX=17database=17format=quickSearchAbstractFormat
- Brin,Sergey,7 Page,Lawrence(1998)."The Anatomy of a Large-Scale Hypertextual Web Search Engine". Available at: <http://www-db.stanford.edu/~backrub/google.html>.
- Deerwester,S.,Dumais,S.T.,Landauer,T.K., Furnas,G.W.and Harshman,R.A.(1990). "Indexing by latent semantic analysis." *Journal of the Society for Information Science*,41(6),391-407.Available at: [lsi.research.telcordia.com/lsi/papers/JASIS90.pdf](http://isi.research.telcordia.com/lsi/papers/JASIS90.pdf)
- Desmontils,E;Jacquin,C.(2002)."Indexing a Website with a Terminology Oriented Ontology". Available at:  
<http://www.semanticweb.org/SWWS/program/full/paper5.pdf>
- Dochartaigh,Niall O.(2002). *The Internet Research Handbook: A Practical for Students and Researchers in the Social Sciences*. London:SAGE Publications.
- "Is PageRank Going Away?" (2004). Available at:  
<http://www.pacificwebsites.com/news-google-pagerank/google pagerand-news.htm>
- Kiryakov et al(2004)."Semantic annotation, indexing, and retrieval". *Web Semantics: Science, Science, Services and Agents on the World Wide Web*.2(1):49-79.available at:  
[http://www.ontotext.com/publications/SemAIR\\_ISWC169.pdf](http://www.ontotext.com/publications/SemAIR_ISWC169.pdf)
- Mansourian,Yazdan(2004)"Intelligent Search Agents and Information Seeking Through the Web"  
*Informology*.1(4):213-231.
- Wang,Shuangbao;Behmann,Michael M.(2003)."A Dynamic Visual Search engine for Database-Driven Web Content". Available at:  
<http://www.actapress.com/proceedings/2003proceedings/TOC>.
- Yu,Clara,Cuadrado,John, Ceglowski,Maciej and Payne,J.Scott.(2002)."Patterns in Unstructured Data: Discovery,Aggregation, and Visualization". Available at:  
[http://javelina.cet.middlebury.edu/lsa/out/cover\\_page.htm](http://javelina.cet.middlebury.edu/lsa/out/cover_page.htm)
- "What is Latent Semantic Indexing Analysis?".(2004). Available at:  
<http://www.pacificwebsites.com/news-google-sandbox/latent-semantic-indexing.htm>