

ساختار نمایه‌سازی در موتورهای کاوش وب

نوشته: احمد کمیجانی*

۱) افزایش ترافیک در وب به علت استخراج تمام اشیا و اجزا صفحات وب و نادیده گرفتن اکثر آن‌ها هنگام نمایه‌سازی؛

۲) جمع‌آوری اطلاعات بدون همکاری و آگاهی سایر خزندۀ‌ها و موتورهای کاوش، مورد توجه قرار گرفته و مرتفع شده است.

مقدمه

از زمان پایه‌گذاری وب جهانی در اوخردهه^۱، ۱۹۸۰ هیچ کس نمی‌توانست پیش‌بینی وضعیت و تأثیرات فعلی آن را بکند. رونق وب و رشد فزاینده آن بر کسی پوشیده نیست، به نحوی که فقط میزان اطلاعات متنی قابل دسترس آن در حدود ۱ ترابایت تخمین زده می‌شود (Baeza-Yates, 1999).

اندازه‌گیری حجم اطلاعات بر روی شبکه اینترنت به ویژه وب کار بسیار دشواری است. بر طبق آمارهایی که گروه Cyveillance عرضه کرده است، بیش از ۲/۱ میلیارد صفحه اطلاعات، بدون تکرار و قابل دسترس تا نیمه دوم سال ۲۰۰۰ بر روی وب موجود بوده و براساس همین مطالعات نرخ رشد انفجاری صفحات وب ۷ میلیون در روز بوده است. (Pasore, 2000)

این بدان معناست که در حال حاضر تعداد صفحات وب، به میزان سه برابر آن افزایش یافته است و این

حجم وسیع اطلاعات بر روی شبکه وب باعث می‌گردد تا پاسخ‌دهی به کاوش‌های ارسالی از سوی کاربرن، بدون دسترسی به تمام متون و فقط با استفاده از فایل‌های نمایه صورت گیرد. بدین منظور در سطح شبکه از روش‌های مختلف نمایه‌سازی استفاده می‌گردد. روش نمایه^۲ انتهای کتاب، استفاده از ابداده‌ها، شاخه‌های موضوعی و ساختار مرکز و پراکنده در فن‌آوری موتورهای کاوش از روش‌های دیگر می‌باشد.

بسیاری از موتورهای کاوش از یک ساختار مرکز خزندۀ‌نمایه‌ساز، سود می‌جونید. خزندۀ‌ها برنامه‌های نرم‌افزاری هستند که عمل پیمایش وب را انجام داده و صفحات جدید و یا به روز در آمده را به سرویس دهنده‌ای که قرار است این صفحات در آنجا نمایه شوند، می‌فرستند. در ساختار پراکنده که بسیار موئتر از نوع مرکز است، مشکلات ناشی از استفاده از ساختار مرکز

چون:

۱) دریافت درخواست صفحات، توسط خزندۀ‌های متفاوت موتورهای کاوش، از سرویس دهنده‌گان وب؛

*دانشجوی کارشناسی ارشد اطلاع‌رسانی

سعی در بالا بردن دسترسی‌پذیری موثر اطلاعات سایت خود نموده است.

سایت دانشگاهی جورج تاون نیز نمایه موضوعی A-Z را در قسمت ابزارهای دسترسی به اطلاعات در صفحه خانگی خود قرار داده است.

ابرداده^(۲) و وب

ابرداده به طور مکرر، داده‌ای برای داده تعریف شده است. این تعریف در عین ضروری بودن ناکافی است. ابرداده، داده‌ای است درباره داده، که برای شرح منابع یا شیء اطلاعاتی پایه‌ریزی شده است و داده‌های منابع و روابط بین آنها را تشریح می‌کند. پدیدآورندگان منابع، ناشران، کتابداران و سایر متخصصان اطلاع‌رسانی می‌توانند ابرداده را تولید کنند. ابرداده می‌تواند در درون منابع اطلاعاتی جاسازی^(۳) و یا در کنار منبع اطلاعاتی و به طور مجزا حفظ شود. (Cleveland, 2001, P.223)

قالب ابردادهای دوبلین کور نمونه‌ای پیشنهادی از ابرداده است که دستاورد نشست متخصصان اطلاع‌رسانی در دوبلین اوهاایو به منظور حل مشکلات موجود در توصیف منابع اطلاعاتی موجود بر روی شبکه‌های کامپیوتری است. این نمونه‌ای از مفهوم پیوند بین ابرداده و وب است.

شخص‌های عنوان، پدیدآور، موضوع، ناشر، توصیف (همچون چکیده)، تاریخ ارائه، نوع مدرک، قالب^(۴) (نیازهای سخت‌افزاری و نرم‌افزاری جهت ارائه مدرک)، برچسب منحصر به فرد شناسایی^(۵)، محل تولید مدرک، زیان اصلی مدرک، چگونگی و محل ارتباط مدرک با سایر منابع، پوشش (بیانگر دامنه، محدوده و عمق مدرک) و مدیری حق مؤلف، در قالب دوبلین کور پیشنهاد گردیده است. (Cleveland, 2001, P.224)

شاخه‌های موضوعی

بعضی از ابزارهای جستجوی وب سعی در مرور سایتها توسط افراد متخصص کرده و پس از تحلیل محتوى سایت، کلیدواژه مناسب را انتخاب و آن را در محل موضوعی، براساس لیست موضوعی ویژه خود قرار می‌دهند

اطلاعات، براساس آمار (2002) NetCraft به وسیله بیش از ۲۷ میلیون سرویس‌دهنده وب در اختیار مشتریان قرار می‌گیرد.

حجم وسیع اطلاعات بر روی شبکه وب باعث می‌گردد تا پاسخ‌دهی به کاوش‌های ارسالی را بدون دسترسی به تمام متون و فقط با استفاده از فایل‌های نمایه صورت دهیم زیرا در غیر این صورت یا باستی نسخه‌ای از اطلاعات درخواستی به صورت محلی ذخیره گردد و یا تمام صفحات از راه دور و از طریق شبکه، در هنگام جستجو دسترسی‌پذیر باشد که این روش‌ها بسیار گران و کند است. تمام این‌ها تأثیر و اهمیت، تلاش برای بهبود روش‌های نمایه‌سازی و الگوریتم‌های جستجو را مشخص می‌سازد.

براساس استاندارد نمایه‌سازی بریتانیا نمایه، ترتیب اصولی از مداخل است که به منظور قادر ساختن استفاده‌کنندگان برای یافتن اطلاعات خود در یک مدرک ایجاد می‌شود. نمایه‌سازی وب کار ساده‌ای نیست و لذا برای کمک به درخواست‌کنندگان اطلاعات در رسیدن به آن در سطح شبکه از روش‌های مختلف نمایه‌سازی استفاده می‌گردد.


روش نمایه انتهای کتاب در وب

بسیاری از سایت‌های وب، برنامه‌ای برای جستجوی سایت خود طراحی کرده‌اند. این برنامه‌ها همچون جستجو در فایل‌های تمام متن می‌تواند در نتایج جستجوی خود دارای مدارک نامرتبط و در اصطلاح همراه با ریزش کاذب باشد.

اگر در چنین سایت‌هایی نمایه‌ای شبیه آنچه در انتهای کتاب‌ها دیده می‌شود به وجود آید، مراجعه‌کننده می‌تواند به سرعت و با استفاده از لیست به مدخل مورد نظر خود وارد شود و با سرعت بالا و از دست دادن زمان کمتری به مدارک مورد نیاز خود و حتی به مدارک مرتبط با آن نیز دسترسی یابد.

سایت وب شرکت نرم‌افزاری Adobe با داشتن نمایه‌ای از نوع کواک^(۶) و نیز موتور کاوش ویژه سایت،

در حقیقت خزنه به درون رایانه نفوذ نمی‌کند، بلکه بر روی یک رایانه محلی اجرا شده و درخواست‌های خود را به رایانه‌های سرویس‌دهنده در نقاط مختلف ارسال می‌کند. عمل نمایه‌سازی در این روش به طور متمرکز صورت می‌گیرد. شکل زیر ساختار نرم‌افزاری متمرکز موتور کاوش AltaVista را نشان می‌دهد.



اصلی‌ترین مشکل در این نوع ساختار، به دلیل طبیعت پویای وب، جمع‌آوری اطلاعات، پیوندهای ارتباطی اشاعر شده به سرویس‌دهنده‌گان وب و سربار شدن^(۸) آن‌هاست. مشکل دیگر حجم اطلاعاتی است که در حقیقت ساختار متمرکز نمایه‌سازی توان مقابله با آن را ندارد. (Baeza-Yates, 1999, P.374)

در واقع به دلیل درخواست‌های سریع ارسالی خزنه‌ها، و اشغال حجم قابل توجهی از پهنهای باند ارتباطی و حتی تمام پهنهای باند در حوزه‌های کوچک^(۹) و برای رفع این مشکل در ۳۰ ژوئن سال ۱۹۹۴ استانداردی را پدیدآورده‌گان برنامه‌های خزنه، برای محدودیت عمل برنامه‌های خودکار خزنه در سراسر وب به وجود آورdenد. براساس این استاندارد، اگر ما می‌خواهیم خزنه‌ها از سرویس‌دهنده ما بازدید نکنند بایستی فایلی متنی با نام robots.txt بر روی ریشه^(۱۰) سرویس‌دهنده، وب خود قرار دهیم و براساس توافقات پدیدآورده‌گان خزنه‌گان یا روبوتها، این برنامه بایستی در اولین مرحله به دنبال این فایل در روی سرویس‌دهنده، وب جستجو کند و در صورت وجود به فرامین قرار داده شده در آن پاسخ داده و سپس به اعمال دیگر بپردازد.

و در واقع یک راهنمای موضوعی را برای استفاده کننده فراهم می‌آورند. این در واقع به آن معناست است که در زمانی که موتور کاوش به طور معمول برای هدایت فرد به سایت، تمام صفحات آن سایت را نمایه کرده است، ولی از سوی دیگر یک راهنمای موضوعی بسیار شبیه یک پیوند (Tyner, 2001) به صفحه خانگی آن سایت تلقی می‌گردد.

Looksmart و Open Directory دو نمونه بارز از این نوع سایتها می‌باشند.

فن آوری موتورهای کاوش ساختار متمرکز

بسیاری از موتورهای کاوش از یک ساختار متمرکز خزنه‌نمایه‌ساز^(۶) سود می‌جوینند. خزنه‌ها برنامه‌های نرم‌افزاری هستند که عمل پیمایش وب را انجام داده و صفحات جدید و یا به روز درآمده را به سرویس‌دهنده‌ای قرار است این صفحات در آنچا نمایه شوند، می‌فرستند. یک خزنه به عنوان نقطه شروع یک URL را دریافت کرده و انتقال صفحات وب را-همچون ایستگاه کاری که صفحات را مرور می‌کند-به سرویس‌دهنده آغاز می‌نماید. پس از انتقال یک مدرک، سازه‌یاب^(۷) شروع به استخراج واژه‌های مرتبط با متن کرده و آن‌ها را به پایگاه داده می‌افزاید. هر رکورد اطلاعاتی در این پایگاه شامل واژه استخراج شده و URL مربوط به آن می‌باشد. قابل ذکر است، تعدادی از خزنه‌ها واژه‌های موجود در بین برچسب‌هایی خاص نظیر، <TITLE>, <H1>, ... و یا واژه‌های با بسامد بالا می‌نمایند.


JumpstationII از این نوع است که علاوه بر آن واژه‌های موجود در عناصر <HEADER>, <BODY> و واژه‌های با بسامد بالا در برچسب <Hi>, 1<=I<=6> را استخراج می‌کند.

خزنه WWW واژه‌های موجود در عنصر <URL>, <TITLE> و <A> (ابر پیوندهای موجود در مدرک) را نمایه می‌کند.

چندین واسطه قابل ارسال می‌باشد. هر واسطه می‌تواند بعد از فیلتر کردن اطلاعات آن را به سایر واسطه‌ها ارسال کند. یکی از اهداف Harvest ایجاد واسطه‌های ویژه موضوعی^(۱۴) و اجتناب از حوزه^{*} وسیع لغات و مشکلات نمایه‌های عمومی است.

ساختار Harvest، تکرارکننده‌ها و حافظه‌های نهانی اشیا^(۱۵) را نیز جهت افزایش سرعت دسترسی به پایگاه داده‌ها فراهم می‌کند. امروزه برنامه‌های کاربردی این شیوه در مراکزی چون ناسا^(۱۶) و آکادمی ملی علوم آمریکا مورد استفاده قرار می‌گیرد و نمونه مورد استفاده در بخش تجاری در وب، سرویس‌دهنده فهرست، شرکت Netscape است.

نمونه‌ای از ساختار Harvest در شکل زیر دیده می‌شود:



نتیجه‌گیری

افزونی افسار گسیخته اطلاعات بر روی شبکه وب، متخصصان رایانه و اطلاع‌رسانی را در جهت بهبودی کارائی نظامهای نمایه‌سازی و به تبع آن بازیابی اطلاعات سوق می‌دهد.

حرکت از سوی نمایه‌های دست‌ساز تا نمایه‌های خودکار و ارائه^{*} شیوه‌های گوناگون آن، به جهت سرعت بخشنیدن برای ارائه^{*} اطلاعات و رفع مشکلات فنی موجود بوده است. با وجود این علیرغم خوش‌بینی در مورد ابزارهای نمایه‌ساز و جستجوگر، هنوز هم بازیابی موضوعی در هر پایگاهی، بر اساس نمایه‌سازی کلیدواژه‌ای صورت می‌گیرد و جستجو براساس منطق بولی بوده و ریزش کاذب در آن قابل توجه است.

البته با استفاده از ابربرچسب^(۱۱) ROBOTS نیز می‌توان از نمایه شدن صفحه^{*} وب توسط روبوت جلوگیری کرد. (Sullivan, 2000)

<HEAD>

<TITLE>Page I Don't Want To Search Engines</TITLE>

<META NAME="ROBOTS" CONTENT = "NOINDEX">

</HEAD>

ساختار پراکنده

این نوع ساختار بسیار موثرتر از نوع متمرکز است و مشکلات ناشی از استفاده از ساختار متمرکز چون:

- ۱) دریافت درخواست صفحات، توسط خزنده‌های گوناگون موتورهای کاوش، از سرویس‌دهنده‌گان وب،
- ۲) افزایش ترافیک در وب به علت استخراج تمام اشیا و اجزا صفحات وب و نادیده گرفتن اکثر آن‌ها هنگام نمایه‌سازی؛

۳) جمع‌آوری اطلاعات بدون همکاری و آگاهی سایر خزنده‌ها و موتورهای کاوش، در این ساختار مورد توجه قرار گرفته و مرتفع شده است.

برای رفع مشکلات ذکر شده، Harvest یکی از مهمترین مدل‌ها در این نوع دو عنصر اصلی را معرفی می‌کند: گرداورنده^(۱۲) و واسطه^(۱۳). (Baeza-Yates, 2000, P.375)

گرداورنده یک نرم‌افزار خودکار است که بر روی سرویس‌دهنده^{*} وب اجرا می‌شود و عمل جمع‌آوری و استخراج اطلاعات لازم برای فایل نمایه را انجام می‌دهد. البته این نرم‌افزار بر روی سایر سرویس‌دهنده‌گان وب نیز می‌توان اجرا شود که این خود با ساختار Haverst در تنافق است.

واسطه به استخراج اطلاعات از گرداورنده‌ها پرداخته و ضمن ایجاد یک نمایه قابل جستجو، واسطه کاربری آن را نیز فراهم می‌کند. همان گونه که دیده می‌شود، یک نرم‌افزار گرداورنده بر روی سرویس‌دهنده^{*} وب، بدون هیچ ترافیک خارجی اجرا شده و اطلاعات جمع‌آوری شده به

بازیاب، با استفاده از تجرب و نتایج امیدوارکننده،
حوزه‌هایی نظیر هوش مصنوعی و نظامهای خبره می‌باشد.

اهداف آتی در این حوزه، مطالعه هر چه بیشتر
پردازش اطلاعات توسط انسان و چگونگی فهم انسان از
اطلاعات و رسیدن به نظامهای هوشمند نمایه‌ساز و

پی‌نوشت‌ها

- | | |
|-----------------------|--------------------|
| 1. KeyWord In Context | 9. Domain |
| 2. Metadata | 10. Root |
| 3. Embedded | 11. Meta Tag |
| 4. Format | 12. Gathere |
| 5. Identifier | 13. Broker |
| 6. Crawler-indexer | 14. Topic-specific |
| 7. Parser | 15. Object Cache |
| 8. High load | 16. NASA |

منابع

1. *American Society of Indexer*. Main Page: <http://www.asindexing.org>
2. Baeza-Yates, Ricardo; Ribeiro-Note, Berthier (1999). *Modern Information Rerieval*. New York: ACM Press
3. Cleveland, Donald B.; Cleveland, Ana D. (2001). *Introduction to Indexing and Abstracting*. Englewood: Libraries Unlimited
4. *Distributed Indexing Systems for Organizing the Web*:
http://eubdl.ugr.es/temp/serbydor/g9/know4_i.htm
5. George Town University website: <http://www.gerogertown.edu>
6. *Netcraft*. Main Page: <http://www.netcraft.com>
7. *Open Directory* Homepage: <http://www.dmoz.org>
8. Pastore, Michael (2000). *The Web: More Than 2 Billion Pages Strong*
http://cyberatlas.internet.com/big_picture/traffic_patterns/article/0,,5931_413691,00.htm
9. Sullivan, Danny (2000). *How to use HTML Meta Tags*.
<http://searchenginewatch.com/webmasters/meta.html>
10. *Toward the automation of a routine task: Using Spidrs to index the Web*:
http://eubdl.ugr.es/temp/serbydor/g9/know2_i.htm
11. Tyner, Ross(2001). *Sink or Swim: Internet Search Tools & Techniques*.
<http://www.ouc.bc.ca/libr/connect96/search.html>