

اینترنت و اطلاعات دولتی

رضا اردلان

گرفته تا ۷۰۰ کیلوبایت. به طور مثال حجم اطلاعات مربوط به نمایندگان کنگره در جلسه صد و سوم در حدود ۳۰۰۰۰ سند است که اندازه هر یک ۶۰۰۰ مگابایت است. اطلاعات مجلسین به صورت روزانه از طرف اداره اطلاعات چایی دولتی با فرمت FTP ارسال می‌گردد. پس از دریافت اطلاعات اولیه، به هر سند برچسب عنوان داده می‌شود. سپس کدهای اداره اطلاعات چایی به کدهای HTML تبدیل می‌شود و برای هر مورد فهرست مندرجات ساخته می‌شود.

علاوه بر این موارد، یک فهرست مندرجات فرامتنی برای پیشینه‌های مجلسین ایجاد می‌گردد. پس از اتمام این مراحل، اطلاعات مورد نظر نمایه سازی می‌شود. لوایح براساس عنوان، شماره لایحه و متن لایحه، نمایه سازی می‌شوند و چون سرعت نمایه سازی بالا است می‌توان اطلاعات را در کمتر از یک‌روز نمایه سازی کرد.

سیستم بازیابی اطلاعات در طرح توماس
موتور جستجوی مورد استفاده در طرح توماس براساس مدل احتمالات بازیابی اطلاعات است. از این سیستم در بسیاری از پروژه‌های پژوهشی استفاده شده و در بازیابی اطلاعات دولتی کاربردی موثر داشته است. از ویژگی‌های این سیستم می‌توان به موارد زیر اشاره کرد:

۱- **سئاده‌های دسته بندی شده**
احتمال ارتباط بین متن و پرسش (Query) از طریق ترکیب مشابهات موجود در متن با کل اطلاعات، کارایی این تکنیک از طریق روش دقت / بازیابی تایید شده است.

۲- **بازیابی براساس متن**
احتمال مرتبط بودن یک سند هم براساس کل مندرجات یک سند و نیز بهترین متن همانند در سندااست. این تکنیک کارایی بازیابی را بالا می‌برد و ابزار بررسی تمام سند را فراهم می‌سازد. از این تکنیک به این دلیل در طرح توماس استفاده شده است که می‌تواند در لوایح پر حجم، ابزاری برای جلوگیری از جستجوی بخش به بخش باشد.

۳- **توانایی انجام پرسش‌های ساده و پیچیده**
زبان بازیابی اطلاعات در این تکنیک می‌تواند عملگرهایی را فعال سازد که تعیین می‌کند چگونه بایستی نشانه‌ها در داخل سند برای رسیدن به ربط احتمالی ترکیب شوند. این بدان معنی است که قالب احتمال گرای بازیابی را می‌توان برای پرسش‌های تک واژه، ترکیبات بول، عبارتی، یا هر ترکیب دیگری به کار برد.

۴- **بازیابی مبتنی بر حیطه (Field)**
جستجوگر می‌تواند براساس فیلد نیز به نمایه سازی و بازیابی اطلاعات بپردازد. به عبارتی گسترش فیلد می‌تواند بخشی از ارزشیابی احتمالی پرسش باشد. بدین معنا که می‌توان جستجو با فیلد را با پرسش‌های پیچیده ترکیب کرد تا به درجه بندی اطلاعات دست یافت. در طرح توماس از این تکنیک می‌توان برای بازیابی برخی از استنادات سند نظیر شماره لایحه و نوع (Type) آن استفاده کرد.

بخش اطلاعات هوشمند دانشگاه ماساچوست آمریکا برنامه نرم‌افزاری این سیستم را تهیه کرد و برای ایجاد تغییرات، قابلیت‌هایی را در این سیستم به وجود آورد. کتابخانه کنگره آمریکا نیز برای ارتباط ساده کاربران با برنامه، صفحات میانجی و امکان انتقال پایگاه‌های اطلاعات به HTML را تهیه کرد.

در کتابخانه کنگره آمریکا اسناد و اطلاعاتی همچون عکس‌های مربوط به جنگ جهانی دوم، تصاویر متحرک قدیمی، کاست‌های صدا، اطلاعات مربوط به جنگ ویتنام، مطالعات کشور مربوط به بخش فدرال وجود دارد. این مواد را بایستی در زمره اطلاعات دیجیتال به حساب آورد. به همین دلیل کارشناسان اعتقاد دارند که طرح توماس طرح اولیه کتابخانه دیجیتال مبتنی بر اطلاعات دولتی است.

از ویژگی‌هایی یک کتابخانه دیجیتال می‌توان به فراهم آوردن امکان دستیابی به بخش گسترده‌ای از اطلاعات ارزشمند در سطح شبکه اشاره کرد که این طرح این قابلیت را داراست. دسترسی رایگان اطلاعات کتابخانه کنگره موجب شده است که طرح توماس از جهانی نیز شبیه به کتابخانه‌های عمومی باشد.

پایگاه اطلاعاتی توماس
این پایگاه اطلاعاتی مختص اطلاعات قانون گذاری است. در زمان حاضر در این پایگاه می‌توان به اطلاعات مجلس ۱۰۳ و ۱۰۴ کنگره و متون مربوط به مذاکرات این دو دوره که در ۱۰ جلد کتاب چاپ شده است، اشاره کرد. مشروح مذاکرات مجلس سنا و مجلس نمایندگان (کنگره آمریکا) به صورت روزانه با تشکیل حداقل یک جلسه به چاپ می‌رسد. هر رکورد در این پایگاه شامل Daily Digest است که شامل خلاصه رویدادها به صورت روزانه و یک بخش از مجلس نمایندگان و یک بخش از مجلس سنا و بخش مشروح مذاکرات است. بخش مشروح مذاکرات شامل اظهارات نمایندگان است که در صحن علنی ایراد نشده است، اما در پایگاه موجود است. اطلاعات بخش‌های سنا و نمایندگان به مباحث یا مذاکراتی که درباره موضوعات خاص ایراد گردیده است، تقسیم می‌شود که هر کدام دارای عناوین خاص است؛ مانند اصلاحیه تنظیم بودجه. این بخش‌ها در مجموع سندهای این پایگاه را تشکیل می‌دهد. هر یک از این لوایح دارای حجم مشخصی است از ۱ کیلو بایت

چکیده
سیستم توماس به گونه‌ای طراحی شده است تا بتوان به کمک آن اطلاعات دولتی را بر روی اینترنت در دسترس عموم قرار داد. این نمونه می‌تواند برای کتابخانه‌های دیجیتالی دولتی به کار رود. طرح توماس پروژه مشترک کتابخانه کنگره آمریکا و دانشگاه ماساچوست است که فرصت مهمی در بازیابی و تکنیک‌های واسط کاربر (User Interface) ایجاد می‌کند که برای دسترسی موثر به اطلاعات پیچیده در محیط‌های اینترنتی ضروری است. تجربیات اولیه در استفاده از توماس نشان داده است که نیاز زیادی به بازیابی این گونه اطلاعات وجود دارد و پرسش‌های کاربر بایستی کوتاه‌تر از نمونه‌های قبلی مانند TREC باشد. تکنیک‌هایی مانند پردازش پرسش، گسترش پرسش و پردازش واژگانی، همگی باید به صورت همکاری‌های چند جانبه پیگیری شود و ارتقا یابد. کلید واژه‌های این بررسی عبارتند از: بازیابی اطلاعات، اینترنت، پردازش پرسش.

مقدمه
در اواسط دسامبر ۱۹۹۴ رییس جدید مجلس نمایندگان کنگره آمریکا از کتابخانه کنگره خواست تا یک سیستم جدید اطلاعاتی برای ارائه اطلاعات بر روی اینترنت ساخته شود. این پایگاه اطلاعاتی جدید می‌بایست کانون توزیع اطلاعات مربوط به کلیه فعالیت‌های کنگره، شامل مشروح مذاکرات مجلس، مصوبات مجلس، کلیه اسناد مجلس نمایندگان و سنا، آدرس‌های پست الکترونیکی و ارتباط (LINK) با سایر منابع الکترونیکی قانونگذاری موجود در اینترنت باشد.

کتابخانه کنگره آمریکا به عنوان سایت مرکزی این گروه از اطلاعات در نظر گرفته شد. البته از قبل، بخشی یا تمام اطلاعات موجود با استفاده از امکانات گوفر و تل نت در کتابخانه سنا، مجلس نمایندگان، اداره امور چایی دولتی، و انواع مختلف خدمات تجاری قابل جستجو بود. رییس جدید مجلس نمایندگان از کتابخانه کنگره خواسته بود تا این سیستم جدید بتواند عموم مردم را به آسانی به WWW مرتبط سازد.

پروژه توماس طرح مشترک کتابخانه کنگره و دانشگاه MIT آمریکا است. در این طرح مشترک علاوه بر کتابخانه و دانشگاه ایالت ماساچوست، شرکایی از بخش‌های دولتی و تجاری حضور دارند.

3. D. Harman. Overview of the Third Text Retrieval Conference (TREC-3). In D. Harman, editor, Proceedings of the Third Text Retrieval Conference (TREC-3), pages 1-120. NIST Special Publication 500-225, 1995.

4. Y. Jing and W.B. Croft. An association thesaurus for information retrieval. In Proceedings of RIAO 94, pages 146-160, 1994.

5. Robert Krovetz. Viewing morphology as an inference process. In Proceedings of the 16th International Conference on Research and Development in Information Retrieval, pages 191-202, 1993.

6. M. Putzel. Room for doubting Thomas. Boston Globe, page 92, January 27, 1995.

7. T.B. Rajashekar and W.B. Croft. Combining automatic and manual index representations in probabilistic retrieval. Journal of the American Society for Information Science, 46 (4): 272-283, 1995.

8. Gerard Salton and Michael J. McGill. Introduction to Modern Information Retrieval. McGraw-Hill, 1983.

9. Karen Sparck Jones, editor. Information Retrieval Experiment. Butterworth, 1981.

10. Howard Turtle. Natural language vs. Boolean query evaluation: A comparison of retrieval performance. In Proceedings ACM SIGIR 94, pages 212-220, 1994.

11. H.R. Turtle and W.B. Croft. Evaluation of an inference network-based retrieval model. ACM Transactions on Information Systems, 9 (3): 187-222, 1991.

12. H.R. Turtle and W.B. Croft. 1992. A comparison of text retrieval models. Computer Journal, 35 (3): 279-290, 1992.

decency	333
immigration	316
balanced	315
health care	305
baseball	303
firearms	300
TOTAL	16/106

مشکلات برنامه توماس

در ژانویه سال ۱۹۹۵ یکی از متخصصان، مقاله‌ای جنجالی درباره توماس نوشت و در مقاله‌اش ادعا کرد که، «تکنیک‌های جستجو در این برنامه کارایی لازم را ندارد». نویسنده این مقاله عبارت «Elderly black Americans» به معنای سیاه پوستان سالمند آمریکا را در سیستم وارد کرده بود و لایحه‌ای درباره «خرس‌های سیاه» دریافت کرده بود در ادامه همین جستجو، دانشگاه‌ها و کالج‌های مربوط به سیاه پوستان نیز ذکر شده بود. علت این اشتباه این گونه بود که چون در سیستم هیچ گونه اطلاعاتی درباره سیاه پوستان سالمند وجود نداشت، ناخواسته واژه‌های سیاه پوستان و آمریکا بازیابی شده بود. در حال حاضر ما سرگرم مطالعه در مورد احتمال افزودن یک تزاروس از پیش آماده شده به سیستم توماس یا احتمال استفاده از یک تزاروس خودکار مانند عبارت «یاب» هستیم.

استفاده از ریشه‌یابی خودکار توماس جنبه‌های مثبت و منفی داشته است. ریشه‌یابی روش خوبی برای بازیابی واژه‌های مختلفی است که یک گروه از مفاهیم مجرد را تشکیل می‌دهند.

نتیجه‌گیری

پردازش اطلاعات که در بالا به آن اشاره شد، چون نمونه قبلی نداشته است، با روش آزمایش و خطابه دست آمده است. تحلیل گران سیستم توماس به طور مستمر در حال تعیین کارایی پرسش‌های کاربران و بررسی تکنیک‌های مورد استفاده هستند. تا به حال بر اساس اطلاعاتی که از استفاده کنندگان به دست آمده است، این سیستم موفق عمل کرده است. اکنون آزمایش‌های بیشتری بر اساس ربط رسمی قضاوت‌ها برای تعیین سطح بهبود کارایی تکنیک‌های جدید به دست آمده است.

REFERENCES

1. J.P. Callan. Passage-level evidence in document retrieval. In Proceedings of ACM SIGIR International Conference on Research and Development in Information Retrieval, pages 302-310, 1994.
2. W.B. Croft and J. Xu. Corpus-specific stemming using word from co-occurrence. In Fourth Annual Symposium on Document Analysis and Information Retrieval, pages 147-159, 1995.

۵- نمایه سازی انعطاف پذیر و موثر
روند نمایه سازی در طرح توماس به گونه‌ای است که می‌تواند برای هر ساختاری اعم از: ... MARC, HTML, تکنیک‌های واژه‌شناسی (تکنیک‌های ریشه‌شناسی) و تشخیص گره‌های مفهومی حوزه (Domain) مانند بسامد اشخاص، شرکت‌ها، مکان‌ها، و تاریخ‌ها به کار رود. در حال حاضر از تشخیص گره‌ها در توماس استفاده نمی‌شود، زیرا نمی‌توانیم پیش بینی کنیم که چه مفاهیمی در این طرح ارزشمند هستند.

۶- ابزارهای پردازش پرسش و گسترش پرسش
پرسش‌های زبان طبیعی می‌تواند به استعمال پرسش‌ها تبدیل شود و از ابزارهایی نظیر برجسب نقش گرامری و تشخیص گره اتمام جمله استفاده کند. پرسش‌ها قابلیت گسترش خودکار دارند و از عبارت‌های مرتبط متن استفاده کنند.

۷- پشتیبانی از ربط بازخورد و مسیریابی
بازخورد کاربر در مورد ربط سندهای بازیابی شده می‌تواند به صورت خودکار نمایانگر پرسشی در یک جلسه یا اطلاعات پرسنلی اشخاص در محیطی باشد که اطلاعات دریافتی با اطلاعات ذخیره شده مقایسه می‌شود.

کارایی سیستم

یکی از راه‌های بررسی کارایی سیستم توماس، توجه به تعداد نتایج جستجو است که این سیستم انجام داده است. در بررسی یک دوره زمانی سه ماهه در سال ۱۹۹۵ تعداد ۲۳۰۲۵۸۹ تراکنش اطلاعاتی وجود داشته است که موجب ۲۹۴۵۷۵ دسترسی به صفحات اینترنتی توماس بوده است. از میزان دسترسی‌ها می‌توان حدت زد که تعداد ۹۴۹۱۱ پرسش وجود داشته است.

نمونه زیر را می‌توان برای آشنایی بیشتر محققان ارائه داد:

Query Count		
balanced budget	2/600	
crime	1/057	
gun(s)	994	
balanced budget amendment		991
s	314	902
telecommunications	888	
welfare	846	
budget	753	
abortion	678	
line item veto	610	
gun control	539	
unfunded mandates	532	
welfare reform	513	
education	441	
tax	415	
term limits	401	
crime bill	375	
contract with America	366	
public broadcasting	333	