

Статистические и аналитические возможности библиотеки будущего

Statistical and Analytical Capabilities of the Library of the Future

Статистичні та аналітичні можливості бібліотеки майбутнього

Рохварг С. Л.

Корпорация «Индустрия Интеллекта», Киев, Украина

Sergey L. Rokhvarg

«Industria Intellecta» Corporation, Kiev, Ukraine

Рохварг С. Л.

Корпорация «Индустрия Интеллекту», Київ, Україна

Рассматриваются вопросы развития информационных систем, требования к ним и их сегодняшние возможности. Формулируются принципы построения информационной библиотечной системы на примере информационной системы «Атлас». Делается попытка спрогнозировать необходимые элементы систем для поиска и обработки информации будущего, и заложить основы для этого развития в разработке системы уже сегодня.

Development of information systems, requirements to these systems and their capabilities are examined. The construction principles of a library information system are formulated based on the example of the information system «Atlas». An attempt is made to forecast the essential elements of information search and retrieval systems of the future and pave the way today for the design of such systems.

Розглядаються питання розвитку інформаційних систем, вимоги до них і їх можливості сьогодні. Формулюються принципи побудови інформаційної бібліотечної системи на прикладі інформаційної системи «Атлас». Робиться спроба спрогнозувати необхідні елементи систем для пошуку й обробки інформації майбутнього і закласти основи для цього розвитку в розробці системи вже сьогодні.

1. Куда мы движемся

Для начала давайте обратим внимание на несколько моментов:

- **количество информации** с каждым днем увеличивается в геометрической прогрессии;
- целевая информация в этом потоке практически теряется и на ее поиск уходит все больше времени (снижается **качество информации**);
- **обработка информации** становится гораздо более важным процессом, чем просто поиск, из-за увеличения количества и снижения качества информации;
- значительную роль в процессе поиска и обработки информации играет **скорость** и **удобство поиска** информации.

Таким образом, библиотека становится не только местом хранения информации, а источником для поиска и обработки информации. Так как значительное количество информации находится в электронной форме, а со временем, это соотношение все больше будет меняться не в пользу печатных изданий, сейчас уже все понимают необходимость создания баз данных для хранения имеющейся и накопления новой информации. Далее мы будем говорить не просто о библиотеках — а о системах для поиска и обработки информации (на примере информационной системы «Атлас»). Попробуем сформулировать принципы такой информационной системы.

2. Принципы построения информационной системы

Мы согласились, что основными требованиями к информационной системе будут не только хранение информации, но ее поиск и обработка. Поэтому важное место в реализации такой системы получают статистические функции системы, функции оперативной аналитической обработки (OLAP) и функции системы добычи данных (data mining).

Список требований, сформулированных нами для информационной системы, выглядит так:

1. **Скорость** — означает, что система должна обеспечивать выдачу большинства ответов пользователям в пределах приблизительно пяти секунд. При этом самые простые запросы обрабатываются в течение одной секунды и очень немногие — более 20-ти секунд. Недавнее исследование в Нидерландах показало, что конечные пользователи воспринимают процесс неудачным, если результаты не получены по истечении 30 секунд. Они способны нажать «Ctrl+Alt+Del», если система не предупредит их, что обработка данных требует больше времени. Даже если система предупредит, что процесс будет длиться существенно дольше, пользователи, могут отвлечься и потерять мысль, при

этом качество анализа страдает. Скорость у нас обеспечивается как разными серверами, так и тематическим разделением базы на физические части.

2. **Доступность** — означает, что система позволяет работать с ней пользователю в любой момент времени. Это обеспечивается распределенной базой данных, несколькими серверами, пользователь получает доступ к тому серверу, который меньше загружен в данный момент, причем при этом учитывается предпочтения по трафику (например, пользователь из России быстрее получит доступ к российскому серверу, аналогично для пользователей Украины), по времени (например, время загрузки серверов для пользователей Северной Америки — ночь для России и Украины) и т. д.
3. **Точность** — возможность поиска, статистического и аналитического модулей выделять необходимую информацию, находить оптимальные пути для ее получения, предоставлять возможности по обработке информации для обеспечения максимально требуемого результата.
4. **Конфиденциальность** — означает, что пользователь получает доступ только к предназначенной ему информации, и к его информации остальные пользователи получают доступ только по его разрешению. Сюда же входит и многопользовательская поддержка, и гибкая система управления правами пользователя.
5. **Информативность** — означает, что в случае отсутствия в базе необходимой информации, в системе должна быть возможность получить (или, по крайней мере, предпринять возможность поиска) из внешних источников — например, из Интернета.
6. **Актуальность** — информация в системе должна своевременно обновляться и дополняться. Время выхода информации в печатном виде не должно быть раньше электронного.
7. **Универсальность** — означает, что система должна быть неприхотлива в установке и использовании, в отсутствии программных конфликтов и остаточных эффектов от ее работы. В частности, у нас это — система не нуждается в установке, может встраиваться в другие системы обмена данными, пользуется стандартными механизмами для работы с базами данных и т. д.

У нас есть возможности работы с базой в 5 вариантах:

1. работа с локальной версией базы — база находится на сервере клиента, локальные версии — на рабочих станциях клиента;
2. работа с локальной версией базы — база находится на сервере клиента, в сервер клиента встраивается интерфейс на RНР для доступа к базе, на рабочих станциях клиента — через Интернет-обозреватель — Explorer;
3. работа с Интернет-версией базы — база находится на нашем ближайшем сервере, локальные версии — на рабочих станциях клиента;
4. работа с Интернет-версией базы — база находится на нашем ближайшем сервере, на рабочих станциях клиента — через Интернет-обозреватель — Explorer;
5. работа с Интернет-версией базы — база находится на нашем ближайшем сервере, в сервер клиента встраивается интерфейс на RНР для удаленного доступа к нашей базе, при этом клиент получает все возможности поиска и обработки информации, пользователи клиента — доступ с его сайта.

Во всех вариантах обновление информации (репликация) идет с ближайшего нашего сервера (по Интернету) или путем получения обновлений в файлах (на дисках, почтой, FTP-доступом и т. д.).

Возможность клиента самому добавлять рубрики и пополнять базу своей информацией (только для локальной версии).

1. **Удобство** — свойства системы, которые позволяют неподготовленному (или плохо подготовленному) пользователю пользоваться системой, максимально приблизить вид получаемой информации к оригиналу (это, например, предоставление полнотекста), приблизить эргономические характеристики системы к естественным человеческим.
2. **Дешевизна** — минимализация затрат на внедрение и использование системы обработки информации. Это в наших условиях достаточно актуально. У нас это означает использование бесплатной версии базы данных (за основу взят Firebird), использование своих механизмов обмена и обработки информацией, своего сервера и локальной версии оболочки.

3. Статистические возможности системы хранения и обработки информации.

Статистические возможности системы хранения и обработки информации можно рассматривать в двух смыслах: как статистику пользования базами данных и как статистическая обработка информации в базе.

Статистическая обработка информации допускает анализ по частоте встречающихся запросов, по структуре запросов к базе данных, по характеру и типам информации, по потребителям и источникам информации, по количеству и качеству тематической информации (это достигается присвоением информации «коэффициента аналитичности»).

К статистической обработке относятся возможности по сортировке и группировке результатов поиска:

- (1) % совпадения результата;
- (2) частоте попадания слов поисковой фразы в поиске;
- (3) величине документа;
- (4) частотности нахождения в поисковых фразах (по статистике поиска);
- (5) по любому из полей поиска.

Статистические возможности по учету пользования информацией делятся у нас на несколько типов:

1. Статистика пользователя информации (за период):
 - 1.1. использованный трафик в базе данных;
 - 1.2. количество статей, к которым получен доступ;
 - 1.3. время работы в базе данных;
 - 1.4. время подписки на доступ к базе данных;
 - 1.5. остаток денег (трафика, статей, времени, входов) на счету (баланс);
 - 1.6. сумма скидок;
 - 1.7. история подписок на доступ к базе данных;
 - 1.8. история оплат доступа к базе данных;
 - 1.9. количество и время входов в базу данных (история пользования).
2. Статистика источника информации (за период):
 - 2.1. использованный трафик в базе данных (по информации этого источника);
 - 2.2. количество статей, к которым получен доступ;
 - 2.3. время работы в базе (с информацией этого источника);
 - 2.4. время подписки на доступ к информации этого источника;
 - 2.5. количество денег (трафика, статей, времени, входов) на счету (баланс) — оплачено пользователями за эту информацию;
 - 2.6. сумма скидок, предоставленных на эту информацию;
 - 2.7. история подписок на доступ к базе данных;
 - 2.8. история оплат доступа к базе данных;
 - 2.9. количество и время входов в базу данных (история пользования).
3. Статистики менеджеров, бухгалтеров, операторов, администраторов — т. е. непосредственно тех людей, которые работают с базой данных изнутри, пополняют ее, следят за ее целостностью и работают с потребителями информации.

4. Аналитические возможности системы хранения и обработки информации

Мы уже говорили, что аналитические возможности информационной системы играют едва ли не самую главную роль для пользователя. Поэтому здесь мы попытались реализовать некоторые принципы OLAP (подробнее о них можно прочитать на сайте www.olap.ru) по модели Кодда:

- 1) многомерное представление данных;
- 2) интуитивное манипулирование данными;
- 3) 4 модели анализа (Категориальный, Толковательный, Умозрительный и Стереотипный);
- 4) прозрачность;
- 5) сохранение результатов;
- 6) гибкость формирования отчетов. Возможность стыковки с другими системами формирования отчетов.

Разрабатываются механизмы добычи данных (так называемое «окно фактов») («data mining»). Собственно поиск, хранение и обработка фактических данных займут в базе свое определенное место.

Огромное значение для скорости и точности получения результата имеет механизм поиска. Анализ структуры текста (например, поиск по рекламным блокам), логический и понятийный поиск, ведение истории поиска (как поисковых запросов, так и результатов поиска), статистики поиска, ведения поиска по всем признакам информации — значительно ускоряют, облегчают и делают поиск целенаправленным. Помогают в этом автоматическое определение гиперссылок, имен и названий.

Облегчает обработку информации автоматическое аннотирование и цитирование текста, автоматическая рубрикация и тематические подборки. Вся информация хранится в системе в двух форматах — HTML и PDF (с сохранением аутентичности расположения элементов документа). Информацию можно просмотреть как в оригинальном виде (полнотекст) так и в оптимизированном для просмотра в Интернете. Используя механизм фильтров (настраиваемый пользователем), Вы всегда будете видеть только ту информацию, которая Вам нужна.

5. Дополнительные (сервисные) возможности системы хранения и обработки информации

К дополнительным сервисным возможностям относятся:

1. Автоматический перевод с и на язык, используемый пользователем.
2. Автоматическая проверка орфографии.
3. Хранение в базе данных информации пользователя, возможность обмена с основной базой, причем на информацию пользователя распространяются все сервисные возможности системы.
4. Возможность экспорта из базы в большом количестве используемых форматов:
 - (1) PDF
 - (2) HTML (только текст)
 - (3) MHTML
 - (4) TXT
 - (5) RTF
 - (6) DOC
 - (7) JPG
5. Автоматическое формирование рассылок с выборками информации.
6. Ведение подборки по какому-либо параметру («своя газета»).
7. Ведение подборки типа «новостная лента».
8. Возможность локальным пользователям удаленно или локально обновлять информацию по какой-либо тематике (механизм репликаций).
9. Настройка автоматических уведомлений о появлении новой информации.
10. Выбор типа обмена информацией: по почте, по электронной почте, Интернет, локально, FTP и т. д.

6. Прогнозы развития информационных систем

Попытаемся продумать пути развития информационных систем.

Поскольку компьютерные системы развиваются в направлении миниатюризации, а тенденции создания переносной техники говорят о глобализации и объединении в одном устройстве наибольшей функциональности (например, производители часов серьезно обеспокоены конкуренцией со стороны производителей мобильных телефонов), видно, что в скором времени большинство функций будут объединены в одном устройстве (карманном компьютере). Это устройство будет выполнять функции как мобильного телефона, компьютера, так и коммуникационного устройства для получения информации из баз данных. Главная роль в процессе обмена информацией будет принадлежать источникам информации — издательствам, библиотекам — онлайнным базам данных. Чтобы дать возможность пользователям работать с такими базами, поставщикам придется удовлетворять требованиям, сейчас еще не настолько актуальным — это, в первую очередь, **удобство**, скорость и доступность. Если сейчас пользователь еще может позволить себе нажать 5 кнопок и подождать 2 минуты, чтобы найти информацию на странице, то при резком увеличении количества пользователей и переноса функций доступа в мобильные устройства, необходимо будет продумать новые эргономичные интерфейсы и механизмы для пользования информационными системами. Для массовых систем необходимо уже сейчас строить распределенные сети для доступа к информации, древовидные серверные структуры. Пользователь не будет работать с «продуктом», прогресс идет по пути упрощения, чтобы предложить что-то на рынок, надо показать то, чем все уже пользуются, но в новом качестве (пример — «электронная книга», но с полным отображением страницы, и с эффектом перелистывания). Успехом будут пользоваться продукты, для которых не является обязательным серьезное обучение, которые можно будет использовать неподготовленному человеку, и делать это будет удобно.

7. Выводы

Подведем итоги.

Мы попытались сделать систему, наиболее приближенную к системам, которые будут использоваться в ближайшем будущем. Естественно, далеко не все еще реализовано, впереди еще много работы, в том числе, вместе с Вами. Только пользователи информационной системы «Атлас» могут указать нам точный путь развития. Но уже сейчас видно, в каком направлении надо двигаться, какие свойства системы развивать. Мы благодарны всем нашим пользователям за тот вклад, который они уже внесли в разработку нашей информационной системы. И надеемся, что они и дальше будут нам в этом помогать.