

УДК 004.55

СИСТЕМА СЕМАНТИЧЕСКОЙ ОПТИМИЗАЦИИ СОДЕРЖИМОГО ВЕБ-САЙТОВ НА ОСНОВЕ ПОЛЬЗОВАТЕЛЬСКИХ ПРЕДПОЧТЕНИЙ

П.И. Банокин, В.Н. Вичугов

Томский политехнический университет

E-mail: pavel805@gmail.com

Выявлена потребность в оптимизации содержимого веб-сайтов в соответствии с индивидуальными предпочтениями пользователей. Предложены способы оптимизации содержимого веб-страниц для различных сценариев использования приложения и способы хранения семантического профиля пользователя. Представлена реализация программной системы в виде набора JavaScript-компонентов и методика интеграции данной системы с существующими веб-приложениями.

Ключевые слова:

Семантическое веб-приложение, оптимизация содержимого веб-страниц, семантический профиль пользователя.

Key words:

Semantic web-application, web-page content optimization, semantic user profile.

Современные интернет-приложения содержат обновляющийся и разнообразный контент в неструктурированном виде. К таким сайтам относятся блоги, социальные сети, интернет-аукционы, фото- и видео-хостинги. В такой ситуации пользователям становится сложно ориентироваться в многообразии информации, представленной как на одной веб-странице, так и на целом веб-сайте.

Несмотря на популярность социальных сетей, поисковые системы являются основным источником новых посетителей для веб-сайтов. Существующие методы продвижения интернет-приложений в большей степени ориентированы на оптимизацию веб-страниц для поисковых систем. Довольно часто такие методы противоречат принципам удобства использования приложения. В результате создаются неестественные и сложные для понимания обычного пользователя заголовки страниц и названия ссылок, а качество интерфейса приложения и релевантность контента поисковому запросу снижаются.

В последнее время алгоритмы работы ведущих поисковых систем интернета изменились: поведение и предпочтения пользователя стали иметь большее значение при поисковом анализе веб-приложения [1]. Алгоритмы ранжирования веб-сайтов стали способны учитывать поведение пользователя на отдельной веб-странице [2]. Обычно выделяют следующие метрики для анализа поведения пользователей на веб-сайте: глубина просмотра, продолжительность визита, источник перехода, тип устройства, географическое положение пользователя. Поэтому возникла необходимость предоставления более качественного и релевантного предпочтениям пользователя контента, а также общее повышение уровня удовлетворенности от пользования приложением.

Задачей разработчиков веб-приложения становится предоставление максимально релевантной предпочтениям пользователя информации, тем самым улучшая метрики его поведения. Индивидуальная настройка внешнего вида и содержимого

отдельной страницы в соответствии с интересами пользователя является одним из эффективных решений для достижения этой цели. Семантический анализатор, исполняемый на стороне клиента, и генератор семантических атрибутов, исполняемый на стороне сервера, могут производить семантический анализ информации и динамически настраивать расположение и оформление контента в соответствии с нуждами конкретного пользователя.

Предполагаемыми сферами применения подобной архитектуры могут быть приложения, работающие по принципу социальных сетей и отличающиеся большой разнородностью интересов пользователей [3].

Для создаваемой архитектуры были определены необходимые качества:

- Гибкость. Процесс интеграции должен требовать минимальной модификации логики приложения. Разработчик должен иметь возможность добавлять новые методы перестроения содержимого веб-страницы и новые алгоритмы ранжирования частей контента.
- Масштабируемость. Количество пользователей веб-приложения должно оказывать минимальное влияние на время выполнения операции семантического анализа и перестроения пользовательского интерфейса.
- Безопасность. Предпочтения пользователя должны храниться в не персонализированной форме.

Все перечисленные выше качества достигаются архитектурой семантического приложения (рис. 1). Все процессы, за исключением процесса генерации семантического HTML-кода, исполняются на стороне клиента.

В соответствии с основными процессами, представленными выше на диаграмме потоков данных (рис. 1), можно выделить четыре основных компонента создаваемой системы семантического анализа:

- 1) генератор семантического HTML-кода;




Рис. 1. Диаграмма потоков данных системы семантической оптимизации веб-сайтов




Рис. 2. Диаграмма клиентских компонентов

- 2) хранилище семантических профилей пользователя;
- 3) семантический анализатор;
- 4) библиотека сервисных функций.

Архитектура рассматриваемой системы является распределенной и состоит из двух физических узлов – веб-сервера (среды исполнения веб-приложения) и клиента. Компоненты программной системы, за исключением генератора семантического HTML-кода, исполняются интернет-браузером пользователя (рис. 2).

Генератор семантического HTML-кода – компонент архитектуры, создающий входные данные для семантического анализатора. Генератор семантического HTML-кода добавляет семантическую

информацию к элементам контента, которые будут в дальнейшем проанализированы семантическим анализатором.

Добавление семантической информации к HTML-содержимому реализуется путем использования специальных атрибутов. При данном способе каждому семантически значимому HTML-тегу присваиваются специальные атрибуты, описывающие контент (рис. 3). Значение атрибута представляет собой строку, состоящую из набора слов (тегов), разделенных пробелом: «тег1 тег2 тег3 тег4». При данном способе форматирования можно задавать произвольное число тегов (строковых констант), характеризующих предпочтения пользователя. Данный подход может использоваться в соче-

```
<div semantic="moscow economics foodmarket">...</div>
```

Рис. 3. Пример семантического атрибута

тании с обычным разделением веб-страницы на семантические области, такие как область навигации и основная функциональность область [4].

В настоящее время большинство веб-приложений используют различные вариации MVC-архитектуры. Логика по форматированию и формированию значений семантических атрибутов должна реализовываться в слое представления веб-приложения.

При анализе HTML-документа компонент «Семантический анализатор» использует данные, созданные генератором семантического HTML-кода. Поэтому генератор семантического HTML-кода не имеет прямых отношений использования или ассоциации с другими компонентами архитектуры.

Семантический профиль пользователя – объект для хранения информации о предпочтениях пользователя приложения. Семантический профиль состоит из набора полей с уникальными названиями. Каждое поле имеет количественное значение, измеряемое в дальнейшем оценкой поля, определяющее его релевантность к предпочтениям пользователя. В хранилище семантический профиль представляется в виде строки, состоящей из пар «поле: значение», разделенных пробелами. Примером такой строки может быть строка «moscow:16 foodmarket:7 aircrafts:10 russia:11».

Операции, которые могут выполняться над семантическим профилем:

- а) Дополнение. К семантическому профилю пользователя добавляются новые поля (предпочтения). Если поле уже присутствует в профиле пользователя, то происходит увеличение оценки поля на требуемое значение.
- б) Вычитание. Оценка полей профиля, перечисленных во входной строке, уменьшается на требуемое значение. В случае, если оценка поля стала отрицательной или равной нулю, такое поле исключается из профиля пользователя.
- в) Удаление. Из профиля удаляются теги (предпочтения), перечисленные во входной строке.

Поставщик семантических профилей ответствен за формирование набора характеристик предпочтений пользователя. Хранилище семантического профиля является децентрализованным. Профиль пользователя хранится в объекте *HTML5 LocalStorage* [5]. Данный подход делает архитектуру приложения менее зависимой от конкретной исполняющей среды и СУБД.

Сценарии, при которых целесообразно использовать клиентское распределенное хранилище:

- Большинство пользователей используют персональные устройства для доступа к веб-приложению, такими как интернет-планшеты или коммуникаторы.

- Страницы веб-приложения просматриваются анонимно без использования регистрационных учетных записей.
- Посетители совершают множество действий во время посещения веб приложения. В результате семантический профиль, если он был утрачен в процессе очистки временных файлов или смены веб-браузера, быстро восстанавливается в процессе самообучения.

Следующие источники могут быть использованы для получения данных о пользователе: социальные сети, опросы (анкетирование) на веб-сайте, статистика поведения пользователя, данные о географическом положении пользователя.

Требования к хранилищу семантических данных:

- а) Производительность. Время, затраченное на процесс получения семантического профиля пользователя из хранилища, может существенно увеличить время выполнения индивидуальной настройки веб-страницы.
 - б) Наличие механизмов разграничения доступа между несколькими веб-приложениями.
- Созданное решение для хранения семантических профилей состоит из двух составных частей (рис. 4):

1. Веб-страница на удаленном сервере (серверная страница). Основное назначение этой страницы перенаправлять запросы к объекту *LocalStorage* после проверки прав доступа клиента на осуществление операции.
2. *JavaScript*-библиотека (клиент), представляющая из себя скрипт с программным интерфейсом для доступа хранилищу. Данная библиотека должна быть включена во все веб-страницы, которые подлежат семантической оптимизации. При первом обращении к программному интерфейсу на странице создается объект *iframe*, который ссылается на серверную веб-страницу. В дальнейшем запросы на получение или запись данных в объект *LocalStorage* направляются через объект *iframe*. В объект *iframe* загружается страница с главного домена. Объект *iframe* выступает в роли сервера. На странице, загруженной в объект *iframe*, содержится набор функций для записи и чтения данных из объекта *LocalStorage*.

Перед выполнением любого запроса происходит сопоставление URL-адреса веб-приложения со списком разрешенных доменов. Список разрешенных доменов хранится в *JavaScript*-библиотеке, размещенной на серверной странице. Список разрешенных доменов представляет собой строковую константу, содержащую список доменов любого уровня, разделенных символом пробела. В случае несоответствия домена клиента выполнение




Рис. 4. Процесс обращения к семантическому хранилищу.

скрипта приостанавливается. Данный процесс выполняется на стороне клиента, но оригинальный *JavaScript*-код, загруженный вместе с серверной страницей, не может быть изменен сторонними объектами. Следовательно, исполнение данного процесса на стороне клиента не может негативно повлиять на безопасность приложения.

Разработанная архитектура предполагает, что группа веб-приложений, имеющих достаточно количество общих посетителей, может использовать общий семантический профиль. Данные о поведении пользователя и его предпочтениях могут стать доступными заранее определенному списку веб-приложений. Идентификатором приложения в таком списке является его доменное имя. Подобный подход позволяет получить более обширный набор данных о предпочтениях пользователя для более точного перестроения содержания страницы.

Компонент «Семантический анализатор» ответственен за процесс выборки всех элементов HTML-контента и дальнейшее выявление частичных или полных совпадений значений их семантических атрибутов с набором атрибутов семантического профиля пользователя. Процесс семантического анализа состоит из следующих процессов: получение набора элементов для анализа, установление рейтинга для каждого элемента и выполнение *callback*-функции для каждого из семантических элементов.

Релевантность того или иного элемента содержимого веб-страницы рассчитывается следующим образом:

- Поля семантического профиля располагаются по убыванию их оценки.
- Каждый тег семантического элемента сопоставляется полям профиля. В случае, если тег соответствует полю семантического профиля, происходит начисление рейтинга в зависимости от расположения поля в отсортированном семантическом профиле пользователя. При настройке семантического анализатора указывается шаг уменьшения рейтинга в зависимости от позиции поля семантического профиля.

Оценки за каждое совпадение суммируются. В случае совпадения оценка начисляется по следующей формуле:

$$ratio_i = ratio_0 \times incr^i,$$

где $ratio_i$ – рейтинг, начисляемый за совпадение поля; i – позиция поля в отсортированном профиле пользователя; $incr$ – коэффициент убывания значимости.

По завершении работы семантического анализатора происходит настройка блоков контента в соответствии с предпочтениями пользователя следующими образами:

- а) Изменение уровня прозрачности блоков контента, которые по результатам семантического анализа могут быть нерелевантными профилю пользователя.
- б) Изменение порядка следования HTML-блоков, находящихся на одном уровне иерархии в DOM. Применение данного подхода более целесообразно для пользователей мобильной версии веб-сайта. Мобильные устройства имеют небольшой размер экрана, содержимое страницы мобильной версии интернет-приложения располагается в одной колонке, и пользователь уделяет большее внимание контенту, находящемуся в начале страницы [6].
- в) Изменение оформления. При данном типе перестроения страницы возможно изменение размера, типа и цвета шрифта, добавление специальных графических символов или изменение цвета блока, содержащего семантические атрибуты.
- г) Полное сокрытие нерелевантных блоков. Данный метод применим к узкому кругу веб-приложений. Наиболее целесообразно применять данный способ перестроения страницы, если пользователь явно отмечает свои предпочтения, а возможности самообучения отключены.

Способы изменения внешнего вида страницы, не меняющие порядок следования частей контента, удобны тем, что они не требуют блокировки интерфейса в процессе анализа. Пользователь может

продолжать работать с содержимым страницы и по прошествии нескольких секунд наблюдать результаты анализа.

Созданное решение предлагает разработчику определять собственные *callback*-функции, выполняющие настройку контента путем изменения CSS-атрибутов HTML-элементов или иным способом. Входными параметрами для этой функции являются отсортированный по убыванию значения атрибута *rating* массив DOM-элементов, находящихся на одном уровне иерархии.

Пользователь веб-сайта с регулярно обновляющимся контентом посещает ресурс с некоторой периодичностью. Пользователь открывает для себя новые области знаний или сферы общественной жизни, что может означать изменение или коррекцию его предпочтений. При обычном сценарии использования веб-приложения пользователь не будет каждый раз редактировать свой профиль вручную в соответствии изменившимися настройками. Оптимальным поведением семантического анализатора является наблюдение за поведением пользователя и внесение изменений в его профиль, основанных на анализе поведения. Семантический анализатор отслеживает переходы пользователя по ссылкам, которые находятся внутри HTML-элементов с семантическими атрибутами.

Разработанная программная система может быть интегрирована с существующими веб-приложениями согласно следующей последовательности действий:

1. Определение сущностей, подлежащих семантическому анализу, и их семантических атрибутов. Примерами таких сущностей является статья, новость. Как правило, для семантического анализа выбираются сущности, которые отображаются на веб-странице в виде списка.

2. Создание логики для вывода семантических атрибутов. Данный этап может в себя включать изменение схемы базы данных. Изменение схемы базы данных не потребуется, если анализируемые сущности имеют иерархические отношения с другими сущностями, которые способны поставлять семантические атрибуты.

3. Подключение *JavaScript*-библиотек. Указание списка доверенных доменов. Задание начальной конфигурации анализатора и хранилища семантических профилей.

Процесс интеграции был подтвержден на примере фотоблога и агрегатора новостей.

Выводы

Разработанная архитектура семантического интернет-приложения может быть применена к широкому кругу существующих веб-приложений. Решение позволит разработчикам одновременно улучшить ранжирование интернет-приложения поисковыми системами и повысить удобство использования для посетителей. Произведенные работы по интеграции на примере двух веб-приложений подтвердили, что процесс интеграции не является трудоемким и не требует глубокой модификации уже существующих приложений.

Созданное решение отличается от существующих использованием интернет-браузера в качестве среды исполнения семантического анализатора и распределенным по конечным пользовательским устройствам хранилищем данных. Помимо этого, решение предлагает разделяемые наборы пользовательских профилей между несколькими веб-приложениями.

Созданный набор *JavaScript*-библиотек был опубликован на хостинге проектов с открытым исходным кодом *github.com* в репозитории *semanticOpt* и доступен широкому кругу разработчиков.

СПИСОК ЛИТЕРАТУРЫ

1. Enge E., Spencer S., Stricchiola J., Fishkin R. The art of SEO. Second edition. – Sebastopol, CA: O'Reily, 2012. – 714 p.
2. Agichtein E., Brill E., Dumais S. Improving Web Search Ranking by Incorporating User Behavior Information // SIGIR '06. The 29th Annual International SIGIR Conference Seattle. – WA, USA, 2006. – P. 19–26.
3. Porter J. Designing for the social web. – Berkeley, CA: New Riders, 2008. – 201 p.
4. Semantic HTML // MSDN. 2012. URL: <http://msdn.microsoft.com/en-us/library/windows/desktop/gg671917.aspx> (дата обращения: 10.03.2011).
5. Web Storage W3C Candidate Recommendation 08 December 2011 – W3C. Дата обновления: 08.12.2011. URL: <http://www.w3.org/TR/webstorage/> (дата обращения: 11.05.2011).
6. Lubbers P., Albers B., Salim F. Pro HTML5 Programming: Powerful APIs for Richer Internet Application Development. – Berkeley, CA: Apress, 2010. – 304 p.

Поступила 13.07.2012 г.