

Семинар Московской секции ACM SIGMOD, 24 мая 2007 года.

Анализ поведения пользователей Интернет: возможность автоматизации

Докладчик: к.ф.-м.н. Щербина А.А.

Структура доклада

- Методы исследования пользователей Интернет
- Системы data mining
- Возможности автоматизации
- Предлагаемая методика


Статистические исследования

- Марковская цепь $V_i = V_{i-1} + \epsilon$
- $P(L) = L^{-3/2}$ (Распределение Гаусса)
- Среднее количество страниц, посещаемых за одну сессию, составляет 3,86

Предпосылки для улучшения

- Рост значения Интернет
- Значительный рост объёма хранимых исторических данных по поведению пользователей
- Рост потребности в анализе пользователей и их предпочтений.
- Отсутствие возможностей для увеличения числа экспертов

Сбор информации



Существующие методы

- Статистический анализ
- Визуализация данных
- Поиск ассоциативных правил
- Существующие методы требуют участия эксперта на различных этапах обработки данных или анализа.
- Кластеризация
 - Существующие методы кластеризации пользовательских сессий не учитывают содержание посещенных страниц;
 - Для проверки результатов кластер-анализа используются эталонные разбиения или статистические параметры.

Ассоциативные правила

- Правила вида:
- $A \Rightarrow p_k$. Где $A = \{p_1, \dots, p_j\}$
- Поддержка – отношение числа сессий где выполняется A к общему числу сессий.
- Достоверность – отношение числа сессий, где выполняется правило к сессиям где выполняется A .

Применение кластеризации

- Уменьшение размерности (выбор представителей)
- Социологическое исследование
- Модификация сайтов
- Персонаификация наполнения

Цель работы

Создание автономного
программного средства,
выполняющего классификацию
поведения пользователей
произвольного Интернет-сайта.

Поставленные задачи

- Разработка метода кластеризации пользовательских сессий.
- Автономное определение оптимального разбиения по кластерам. Все полученные кластеры должны соответствовать типам поведения пользователей.
- Создание системы классификации, включающей все этапы анализа.

Предлагаемый метод

Сбор данных на стороне сервера

- Существуют заранее накопленные данные
- Структура журналов отвечает общему стандарту CLF.
- Основной недостаток: Не всех пользователей можно идентифицировать.

Нечёткий к-центроидов метод

$$\bullet J_m(V; X) = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m r(x_j, v_i)$$

Минимизируется функция J_m , где u_{ij} – характеристическая функция, v_i – центр i -го кластера.

- Только 30 элементов с наибольшей вероятностью используются для пересчёта центров.

Метод Dbscan

- К каждому элементу присоединяются соседние. Кластеры – набор пересекающихся ϵ окрестностей.
- Основной параметр – ϵ .

Расстояние редактирования

Представление сессии: $v_i = \{x_{i1}, x_{i2}, x_{i3}..x_{in}\}$,
где x_{ij} – страница сайта.

Операции замены символа, вставки и
удаления. Веса 2, 1 и 1 соответственно.

Примеры строк: 'cat', 'cash'

CAT -> CAS -> CASH

Общее расстояние 3.

Предлагаемое расстояние

- dir11/dir12/pagename1
- dir21/dir22/pagename2

Если совпадают dir 11 и dir 21 то
уменьшается стоимость замены

Если совпадают dir 21 и dir 22 то
стоимость снижается еще больше

Теорема 1. Предложенное расстояние
является метрикой

Модификации расстояний

- Уменьшение расстояния редактирования на -10% за каждый совпавший символ.
- Все строки дополняются до одинаковой длины.
- Страницы заменяются на каталоги второго уровня.

Расстояние Манхэттена

- Каждая сессия это вектор
 $v_i = \{x_1, \dots, x_N\}$
- $x_j = 1$ если страница j входит в сессию.
- $x_j = 0$ иначе.

$$r(v_1, v_2) = \sum_{i=1}^N |x_{1i} - x_{2i}|$$

Методы верификации

- Индекс Данна $MD(c) = \min(r(j,i)) / \max(D_k)$ $\forall i,j,k: i \neq j$, где D_k – диаметр кластера, $r(j,i)$ – расстояние между кластерами i и j , c – количество кластеров
- Индекс разделения $IR(c) = \max((D_j + D_i) / r(j,i))$ $\forall i,j: i \neq j$, где D_j – диаметр кластера, $r(j,i)$ – расстояние между кластерами i и j , c – количество кластеров
- Энтропия разбиения. $PE(c) = -\frac{1}{N} \sum_{i=1}^c \sum_{j=1}^N u_{ij} \log(u_{ij})$
- Коэффициент разбиения (индекс Беждека).

$$PC(c) = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^N u_{ij}^2$$

где u_{ij} – характеристическая функция

Предлагаемая верификация

- Подсчёт уникальных ассоциативных правил
- $M(P) = \sum_{i=1}^c M_i / N_c$, где N_i количество элементов в i -ом кластере, M_i – количество уникальных правил в i -ом кластере, C – количество кластеров.

Реализация системы


- Сессии представлены как численные векторы
- Расстояние редактирования рассчитывается методом динамического программирования
- Нечёткий C-Medoids метод
- Подсчет уникальных ассоциативных правил
- Хранение представителей в оперативной памяти
- Достигнутая эффективность: 15 минут на обработку данных за 1 день.

Экспериментальные результаты

Данные Citforum.ru


- 70000 посещений в день
- 1300 сессий в день
- 10000 страниц
- Данные за три дня
- Сессии длительностью от 3 до 40 визитов

Уникальные правила




Индекс различности

Индекс $M(P)$ для предлагаемой метрики



Сравнение индексов



Результаты работы

1. Разработан и апробирован метод сравнения сессий пользовательского доступа к веб-сайту. Основные достоинства предложенного метода состоят в следующем:
 - предложенное расстояние обеспечивает корректное сравнение сессий пользовательского доступа за счёт использования данных о последовательности посещения страниц и их размещения на сайте;
 - применение метода не требует предварительной индексации или обработки самих страниц сайта.
2. Разработан и апробирован метод автоматической верификации результатов кластеризации пользовательских сессий. Основные особенности предложенного метода верификации результатов кластеризации:
 - метод определяет качество разбиения сессий по кластерам в зависимости от наличия уникальных ассоциативных правил;
 - метод выявляет семантические отношения, характерные для каждого из кластеров.
3. Создана программная система, обеспечивающая автономную классификацию сессий пользовательского доступа на основании журнала веб-сайта.