

Открытые проблемы по веб-алгоритмам
Лекция N 11 курса
“Алгоритмы для Интернета”

Юрий Лифшиц

ПОМИ РАН - СПбГУ ИТМО

Осень 2006

Не говорите мне, что эта проблема сложна. Будь она проста, не было бы проблемы.

Фердинанд Фош

Вы не можете решить проблему, пока не признаете, что она у вас есть.

Харви Маккей

Старайся создавать такие проблемы, решение которых известно только тебе.

Принцип Берка

План лекции

- ➊ Как поставить хорошую задачу?

План лекции

- ➊ Как поставить хорошую задачу?
- ➋ Задача 1: Крупномасштабная фильтрация

План лекции

- ① Как поставить хорошую задачу?
- ② Задача 1: Крупномасштабная фильтрация
- ③ Задача 2: Распространение меток

План лекции

- ① Как поставить хорошую задачу?
- ② Задача 1: Крупномасштабная фильтрация
- ③ Задача 2: Распространение меток
- ④ Задача 3: Выявление структур

Введение

Какую задачу следует считать хорошей, интересной, важной?

В каком формате мы будем представлять задачи?

Мои критерии

- Непосредственная связь с разработкой новых технологий
- Знакомство с областью приложений
- Взаимосвязь нескольких научных направлений
- Другие задачи сводятся к данной
- Легко проверить, работает ли разрабатываемое решение
- Новизна (часто сопровождается отсутствием хорошей формальной постановки)

Мои критерии

- Непосредственная связь с разработкой новых технологий
- Знакомство с областью приложений
- Взаимосвязь нескольких научных направлений
- Другие задачи сводятся к данной
- Легко проверить, работает ли разрабатываемое решение
- Новизна (часто сопровождается отсутствием хорошей формальной постановки)

Я не использую:

- Техническую сложность
- Известность и возраст задачи
- Известность автора задачи

Мои критерии

- Непосредственная связь с разработкой новых технологий
- Знакомство с областью приложений
- Взаимосвязь нескольких научных направлений
- Другие задачи сводятся к данной
- Легко проверить, работает ли разрабатываемое решение
- Новизна (часто сопровождается отсутствием хорошей формальной постановки)

Я не использую:

- Техническую сложность
- Известность и возраст задачи
- Известность автора задачи

Ваши критерии для выбора темы курсовой/дипломной работы?

Анкета задачи

- ① Область (технология) для использования?
- ② Пример строгой постановки?
- ③ Вовлеченные научные направления?
- ④ Близкий классический результат?
- ⑤ План исследований?
- ⑥ Ваши конструктивные идеи?

Отказ от ответственности

Эта лекция является **экспериментом**:

- ❶ Задачи придуманы после поверхностного знакомства с веб исследованиями
- ❷ В ближайшее время будет проведен поиск по литературе и сопоставление с известными результатами

Отказ от ответственности

Эта лекция является **экспериментом**:

- ❶ Задачи придуманы после поверхностного знакомства с веб исследованиями
- ❷ В ближайшее время будет проведен поиск по литературе и сопоставление с известными результатами

Таким образом, представляемые задачи могут быть уже поставлены и даже решены!

ЗАДАЧА 1:

Крупномасштабная фильтрация

Large-scale filtering

Как построить быстрый алгоритм для персонального
сбора новостей?

1.1. Технологическая задача

Персональный сбор новостей:

У каждого пользователя есть набор предпочтений:
конкретные авторы, ключевые слова, метки (темы),
пороги популярности, ссылки на предпочтения друзей

Каждое новостное сообщение имеет описание:
текст, голоса, рекомендации, метки,
репутацию автора, комментарии

1.1. Технологическая задача

Персональный сбор новостей:

У каждого пользователя есть набор предпочтений:
конкретные авторы, ключевые слова, метки (темы),
пороги популярности, ссылки на предпочтения друзей

Каждое новостное сообщение имеет описание:
текст, голоса, рекомендации, метки,
репутацию автора, комментарии

Задача фильтрации:

Для каждого пользователя определить десять
наиболее интересных ему сообщений

1.1. Технологическая задача

Персональный сбор новостей:

У каждого пользователя есть набор предпочтений:
конкретные авторы, ключевые слова, метки (темы),
пороги популярности, ссылки на предпочтения друзей

Каждое новостное сообщение имеет описание:
текст, голоса, рекомендации, метки,
репутацию автора, комментарии

Задача фильтрации:

Для каждого пользователя определить десять
наиболее интересных ему сообщений

Примеры:

1.1. Технологическая задача

Персональный сбор новостей:

У каждого пользователя есть набор предпочтений:
конкретные авторы, ключевые слова, метки (темы),
пороги популярности, ссылки на предпочтения друзей

Каждое новостное сообщение имеет описание:
текст, голоса, рекомендации, метки,
репутацию автора, комментарии

Задача фильтрации:

Для каждого пользователя определить десять
наиболее интересных ему сообщений

Примеры: Google News, Google Reader, Yandex Lenta, Livejournal Friends, ...

1.2. Формализация

- Опишем систему предпочтений каждого участника **красным** нормализованным вектором (точкой на сфере) в n -мерном пространстве признаков

1.2. Формализация

- Опишем систему предпочтений каждого участника **красным** нормализованным вектором (точкой на сфере) в n -мерном пространстве признаков
- каждое описание новости будет нормализованным **синим** вектором в том же пространстве

1.2. Формализация

- Опишем систему предпочтений каждого участника **красным** нормализованным вектором (точкой на сфере) в *n*-мерном пространстве признаков
- каждое описание новости будет нормализованным **синим** вектором в том же пространстве
- Будем использовать косинусную меру (скалярное произведение) для соответствия новостей пользователям

1.2. Формализация

- Опишем систему предпочтений каждого участника **красным** нормализованным вектором (точкой на сфере) в n -мерном пространстве признаков
- каждое описание новости будет нормализованным **синим** вектором в том же пространстве
- Будем использовать косинусную меру (скалярное произведение) для соответствия новостей пользователям
- Вычислительная задача: провести (пред)вычисления на **синих** векторах так, чтобы для каждого входящего **красного** вектора можно было бы быстро определить десять ближайших **синих** соседей

1.3. Вовлеченные направления

- Классификация текстов, алгоритмы поиска ближайших соседей
- Вычислительная геометрия
- Структуры данных
- Архивирование (редкие векторы)
- Линейная алгебра (сингулярное разложение)
- Модели распределенных вычислений
- Могут ли помочь квантовые алгоритмы?

1.4. Алгоритм Клейнберга (1/2)

- Есть n точек в d -мерном пространстве
- Нужно записать их в структуру данных
- С вероятностью $1 - \varepsilon$ быстро находить ближайшую точку к любой данной

1.4. Алгоритм Клейнberга (2/2)

Алгоритм по шагам:

- ① Выбираем k случайных нормализованных “контрольных” вектора
- ② Составляем скалярные произведения между векторами из коллекции и контрольными
- ③ Запоминаем ближайшую точку для каждой **системы согласованных интервалов**
- ④ Обработка запроса: берем входную точку, определяем соответствующую ей систему интервалов, смотри в структуру данных

1.5. План исследований

- ① Построить быстрый алгоритм фильтрации всех новостей для всех пользователей
- ② Найти наиболее эффективные структуры данных для хранения пользователей/новостей
- ③ Изучить динамические аспекты: описания новостей и пользователей быстро меняются
- ④ Разработать систему предотвращения спама в системе персонального сбора новостей
- ⑤ Как уравнять в правах свежие и старые новости?

1.5. Ваши конструктивные идеи

Какие вопросы необходимо решить в представленной модели?

Как сделать формализацию лучше?

ЗАДАЧА 2

Распространение меток Tag Propagation

Как распространить начальное распределение ключевых слов на весь Веб?

2.1. Технологическая задача

Классификация веба:

Люди используют миллионы меток (ключевых слов)

Веб состоит из миллиардов страниц

Разреженная коллекция пар (вебсайт,метка)

2.1. Технологическая задача

Классификация веба:

Люди используют миллионы меток (ключевых слов)

Веб состоит из миллиардов страниц

Разреженная коллекция пар (вебсайт,метка)

Цель:

Построить быстрый алгоритм подбора меток
для произвольной страницы

2.1. Технологическая задача

Классификация веба:

Люди используют миллионы меток (ключевых слов)

Веб состоит из миллиардов страниц

Разреженная коллекция пар (вебсайт,метка)

Цель:

Построить быстрый алгоритм подбора меток
для произвольной страницы

Приложения:

Настройка рекламных объявлений

Аннотирование результатов поисковых систем

Автоматические каталоги

2.2. Формализация

- Есть граф ссылок

2.2. Формализация

- Есть граф ссылок
- Зафиксируем метку. Пусть для исходно-помеченных страниц $T_0(i) = 1$, для остальных $T_0(i) = 0$

2.2. Формализация

- Есть граф ссылок
- Зафиксируем метку. Пусть для исходно-помеченных страниц $T_0(i) = 1$, для остальных $T_0(i) = 0$
- Возьмем предел по рекурсивным соотношениям:

$$T_k(i) = T_{k-1}(i) + \alpha \sum_{j \text{ links to } i} \frac{T_{k-1}(j) - T_{k-2}(j)}{Out(j)}$$

2.2. Формализация

- Есть граф ссылок
- Зафиксируем метку. Пусть для исходно-помеченных страниц $T_0(i) = 1$, для остальных $T_0(i) = 0$
- Возьмем предел по рекурсивным соотношениям:

$$T_k(i) = T_{k-1}(i) + \alpha \sum_{j \text{ links to } i} \frac{T_{k-1}(j) - T_{k-2}(j)}{Out(j)}$$

- Вычислительная задача: найти алгоритм (пред)вычислений по исходному распределению меток, с помощью которого можно быстро находить десять меток с наибольшим рангом для произвольного запрашиваемого сайта

2.3. Вовлеченные направления

- Структуры данных
- Архивирование (разреженные множества)
- Численные методы (скорость сходимости)
- Алгоритмы для PageRank

2.4. PageRank vs. TagRank

$$PR_k(i) = \varepsilon/N + (1 - \varepsilon) \sum_{i=1}^n \frac{PR_{k-1}(T_i)}{C(T_i)}$$

vs.

$$T_k(i) = T_{k-1}(i) + \alpha \sum_{j \text{ links to } i} \frac{T_{k-1}(j) - T_{k-2}(j)}{Out(j)}$$

2.5. План исследований

- ① Определить формулы распространения меток
- ② Построить алгоритм быстрой предварительной обработки учебной коллекции и on-line аннотирования

1.5. Ваши конструктивные идеи

Какие вопросы необходимо решить в представленной модели?

Как сделать формализацию лучше?

ЗАДАЧА 3

Выявление структур Structure Discovery

Посмотрим на ключевые слова (метки), которые мы используем. Как подобрать наиболее точную систему отношений (иерархию?) между ними?

3.1. Технологическая задача

Можно собрать огромные коллекции данных:
истории покупок и поисковых запросов,
граф звонков и RSS подписок, социальные сети.
КАК ПОЛУЧИТЬ ПОЛЬЗУ ОТ ЭТИХ ДАННЫХ?

3.1. Технологическая задача

Можно собрать огромные коллекции данных:
истории покупок и поисковых запросов,
граф звонков и RSS подписок, социальные сети.
КАК ПОЛУЧИТЬ ПОЛЬЗУ ОТ ЭТИХ ДАННЫХ?

Пример: **обнаружение иерархии**

У нас есть некоторая **фолксономия**

Как вычислить “оптимальную” иерархию меток?

3.1. Технологическая задача

Можно собрать огромные коллекции данных:
истории покупок и поисковых запросов,
граф звонков и RSS подписок, социальные сети.
КАК ПОЛУЧИТЬ ПОЛЬЗУ ОТ ЭТИХ ДАННЫХ?

Пример: **обнаружение иерархии**

У нас есть некоторая **фолксономия**

Как вычислить “оптимальную” иерархию меток?

Приложения:

Улучшение визуализации данных

упрощение навигации

Решение проблемы синонимов

3.2. Формализация

- Каждая метка характеризуется множеством соответствующих ей сайтов

3.2. Формализация

- Каждая метка характеризуется множеством соответствующих ей сайтов
- Мы хотим построить “оптимальное” **AND-OR** дерево меток

3.2. Формализация

- Каждая метка характеризуется множеством соответствующих ей сайтов
- Мы хотим построить “оптимальное” **AND-OR** дерево меток
- Оптимальное = минимальное отклонение от идеала

3.2. Формализация

- Каждая метка характеризуется множеством соответствующих ей сайтов
- Мы хотим построить “оптимальное” **AND-OR** дерево меток
- Оптимальное = минимальное отклонение от идеала
- Идеал: дети OR-вершины не должны пересекаться, множество родителя содержит множества всех детей, и т.д.

3.3. Вовлеченные направления

- Вычислительная биология (алгоритмы филогенетики)
- Приближенные алгоритмы
- Добыча данных (data mining, web mining)

3.4. Алгоритм Фитча (1/2)

- Есть бинарное дерево
- На листьях ДНК
- Нужно найти правдоподобные ДНК внутренних вершин

3.4. Алгоритм Фитча (2/2)

Алгоритм по шагам:

- ① Отдельно работаем для каждой позиции
- ② Для каждой внутренней вершины составим список разумных кандидатов S_v
- ③ Проход снизу вверх: если w — родитель u и v , и $S_u \cap S_v = \emptyset$, то $S_w = S_u \cup S_v$, иначе $S_w = S_u \cap S_v$
- ④ Проход сверху вниз: выбираем символ для корня, дальше берем символ родителя если он входит в множество ребенка, иначе произвольный символ из множества ребенка

3.5. План исследований

- ① Выбрать формат представления метки и определить критерии идеальной иерархии меток
- ② Найти быстрый алгоритм построения оптимальной иерархии
- ③ Изучить взаимосвязи с алгоритмами филогенетики.

3.5. Ваши конструктивные идеи

Какие вопросы необходимо решить в представленной модели?

Как сделать формализацию лучше?

Голосование

Мы обсудили три задачи. Какая из них вам лично кажется наиболее привлекательной?

- ❶ Крупномасштабная фильтрация
- ❷ Распространение меток
- ❸ Выявление структуры

Задача на дом

Пусть $|v| < |u|$, докажите что с вероятностью не менее $\frac{1}{2}$ для случайного вектора r выполнено $r \cdot v < r \cdot u$

Сегодня мы узнали:

- Технологические задачи: персональный сбор новостей, использование больших объемов данных, автоматическое аннотирование

Сегодня мы узнали:

- Технологические задачи: персональный сбор новостей, использование больших объемов данных, автоматическое аннотирование
- Ключевая алгоритмическая проблематика: алгоритмы на миллиардах объектов: эффективные структуры данных и быстрая обработка запросов. Нужно ускорить наивные “каждый-каждый” алгоритмы

Сегодня мы узнали:

- Технологические задачи: персональный сбор новостей, использование больших объемов данных, автоматическое аннотирование
- Ключевая алгоритмическая проблематика: алгоритмы на миллиардах объектов: эффективные структуры данных и быстрая обработка запросов. Нужно ускорить наивные “каждый-каждый” алгоритмы
- Следующий шаг: (1) обзор литературы, (2) формализации и модели, (3) публичное обсуждение

Сегодня мы узнали:

- Технологические задачи: персональный сбор новостей, использование больших объемов данных, автоматическое аннотирование
- Ключевая алгоритмическая проблематика: алгоритмы на миллиардах объектов: эффективные структуры данных и быстрая обработка запросов. Нужно ускорить наивные “каждый-каждый” алгоритмы
- Следующий шаг: (1) обзор литературы, (2) формализации и модели, (3) публичное обсуждение

Сегодня мы узнали:

- Технологические задачи: персональный сбор новостей, использование больших объемов данных, автоматическое аннотирование
- Ключевая алгоритмическая проблематика: алгоритмы на миллиардах объектов: эффективные структуры данных и быстрая обработка запросов. Нужно ускорить наивные “каждый-каждый” алгоритмы
- Следующий шаг: (1) обзор литературы, (2) формализации и модели, (3) публичное обсуждение

Спасибо! Вопросы?

Источники

Страница курса <http://logic.pdmi.ras.ru/~yura/internet.html>

Использованные материалы:

-  Jon Kleinberg
Two algorithms for nearest-neighbor search in high dimensions
<http://citeseer.ist.psu.edu/kleinberg97two.html>
-  Ron Shamir
Phylogenetics
<http://www.cs.tau.ac.il/~rshamir/algmb/01/scribe08/lec08.pdf>
-  AN Langville, CD Meyer
Deeper Inside PageRank
http://meyer.math.ncsu.edu/Meyer/PS_Files/DeeperInsidePR.pdf