

Министерство образования Российской Федерации
Казанский государственный технический университет им. А.Н.Туполева
Кафедра АСОИУ

Интеллектуальные информационные системы

Лекция 7

**Системы обработки естественного языка.
Информационно-поисковые системы**

2011

ОЦЕНКА ПРОЦЕДУР ИНФОРМАЦИОННОГО ПОИСКА

$\{d_i\}$ – множество документов информационного хранилища D

$r(d_i, d_j)$ – оценка смысловой близости двух документов d_i и d_j

d_0 – некоторый воображаемый (виртуальный) документ
определенного содержания.

Задача информационного поиска:

В информационном хранилище требуется отыскать:

некоторый документ d_i такой, что

$$r(d_i, d_0) = 0$$


или множество документов $D_0 = \{d_i\}$, что

$$r(d_i, d_0) \longrightarrow \min \quad \text{для всех } d_i \text{ из множества } D_0.$$

Оценка результатов информационного поиска

Информационная полнота - все ли нужные документы найдены.

Информационный шум - отобраны и ненужные с точки зрения информационного запроса документы.



D_p - множество документов, полученных в результате выполнения поисковых процедур.

k_n - коэффициент полноты

$k_{ш}$ - коэффициент шума

Возможные варианты результатов поиска:

1. $D_p = D_0$, т.е. найдены все адекватные смыслу запроса документы.

$$k_n = 1, \quad k_{ш} = 0.$$

2. $D_p \subset D_0$ Информационный поиск является неполным:

$$0 \leq k_n < 1, \quad k_{ш} = 0.$$

3. $D_0 \subset D_p$, В результате поиска отобраны лишние документы (информационный шум):

$$k_n = 1, \quad 0 \leq k_{ш} < 1.$$

4. Пересечение D_p и D_0 не пустое, при $D_p \neq \emptyset$ и $D_0 \neq \emptyset$,

$$0 \leq k_n < 1, \quad 0 \leq k_{ш} < 1.$$


5. Пересечение D_p и D_0 пустое, при $D_p \neq \emptyset$ и $D_0 \neq \emptyset$,

$$k_n = 0, \quad k_{ш} = 1.$$

- Вычисление k_n и k_w

$$K_n = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \cap D_i^0|}{|D_i|},$$

$$K_w = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \setminus D_i^0|}{|D_i|}$$



- Вычисление k_n и k_w

$$K_n = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \cap D_i^0|}{|D_i|}, \quad K_w = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \setminus D_i^0|}{|D_i|}$$

- Интегральная оценка эффективности поиска

$$E_i = 2 \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \cap D_i^0|}{|D_i| + |D_i^0|}$$

- Вычисление k_n и k_m

$$K_n = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \cap D_i^0|}{|D_i|}, \quad K_m = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \setminus D_i^0|}{|D_i|}$$

- Интегральная оценка эффективности поиска

$$E_i = 2 \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{i=1}^k \frac{|D_i \cap D_i^0|}{|D_i| + |D_i^0|}$$

- Коэффициент точности $K_\tau = 1 - k_m$

$$E_i = \frac{2K_n K_\tau}{K_n + K_m}$$

Факторы, влияющие на процессы обработки информации

- Огромный объем доступной информации
- Взаимосвязи
- Высокий процент временной информации
- Неконтролируемое качество информации
- Разнотипность информации
- Избыточность
- Разнородность пользователей

Фактографические ИПС (ФИПС)

Характерные отличия::

- высокая однородность сообщений,
- фиксированный порядок следования признаков объектов

Способы поиска:

- поиск по совпадению значений для одного или
нескольких признаков;
- поиск по интервалу:
- поиск, по выражению, когда используется некий
логический критерий

$$k_{n \max} = 1 \quad \text{при} \quad k_{\min} = 0$$

Документальные (библиографические) ИПС

Характерные отличия:

- хранение и поиск текстовых документов.

Методы поиска:

- Поиск по метаданным.
- Поиск на основе морфологического разбора.
- Поиск на основе оценок релевантности документа запросу.
- Поиск с использованием языков запросов.
- Поиск на основе семантического анализа.

$$k_{n \max} = 0.5 \text{ при } k_{m \max} = 1$$

Информационный поиск в ДИПС

Дескрипторный поиск


Ввод документа в ДИПС



Информационный поиск в ДИПС

Дескрипторный поиск


Ввод документа в ДИПС



Информационный поиск в ДИПС

Дескрипторный поиск


Ввод документа в ДИПС



1. Формирование ПОД
2. Включение ПОД в массив ПОД.
3. Пополнение словаря дескрипторов

Информационный поиск в ДИПС

Дескрипторный поиск




Релевантность - смысловое соответствие

ГИПЕРТЕКСТОВЫЕ ИПС

Основные идеи гипертекста:

- текст разбит на семантические единицы;
- между сетями устанавливаются связи;
- текст читается по различным траекториям.




Модель ИСС

$$(x_0, x_1, \dots, x_{10}, x_{11})$$

- x_0 - имя ИСС,
- x_1 - заголовок ИСС,
- x_2 - аннотация ИСС,
- x_3 - точка входа в ИСС,
- x_4 - множество текстовых документов ИСС,
- x_5 - множество цифровых объектов ИСС,
- x_6 - множество программных объектов ИСС,
- x_7 - справка по ИСС,
- x_8 - признак ускоренного просмотра ИСС,
- x_9 - признак детального просмотра,
- x_{10} - список гиперссылок внутри ИСС,
- x_{11} - список гиперссылок между ИСС

Структура гипертекста



ГИПС

1. Атрибутивный поиск с помощью *SQL*-запросов, адресуемых на выполнение сопряженной СУБД.
2. Поиск по логической формуле, составленной из ключевых слов.
3. Лексический поиск на основе релевантности, оцениваемой пропорционально количеству терминов из запроса.
4. Ассоциативный поиск, учитывающий вхождение терминов, связанных отношением ассоциативности с терминами запроса.
5. Поиск ассоциаций используется для ассоциативного расширения и уточнения запроса в диалоге с пользователем.
6. Поиск документов по семантическому подобию.
7. Комбинированный поиск.

$$k_{n \max} = 0.9 - 1 \quad \text{при} \quad k_{ш \max} = 0.1 - 0.2$$

Модель поиска

- Способ представления документов
- Способ представления поисковых запросов
- Вид критерия релевантности документов

Релевантность - смысловое соответствие

Формальная релевантность.

Содержательная релевантность

Пертинентность

Простейшие модели поиска

- **Модель дескрипторного поиска**

Дескриптор - совокупность слов или словосочетаний

Дескриптор приписывается документу:

- 1) на основе содержания (индексирование по содержанию),
- 2) на основе названия (индексирование по заголовкам).

Простейшие модели поиска

- **Модель, основанная на Дублинском ядре**

Дублинское ядро – набор метаданных, зафиксированных в спецификации определяющего стандарта.

Образ документа D_k : $D_k = \{ (N_{ik}, V_{ik}) \}$

Представление запроса: $Q = \{ (N_j, V_j) \}$

Критерий релевантности k -го документа: $Q \subseteq \underline{D_k}$

Модели поиска

- **Булевские модели**

Образ документа - совокупность термов.

$T(di)$ - множество термов документа di (словарь документа)

$T = \bigcup_{i=1, \dots, n} T(di)$ - словарь коллекции документов

Представление запроса: булевское выражение.

Критерий релевантности – истинность булевского
выражения.

Модели поиска

- **Векторные модели**

Образ документа $D_k : (w_{1k}, w_{2k}, \dots, w_{nk})$
веса термов

Например: $w_{ik} = n_{ik} / N_k$

количество повторений i -го терма

число термов документа

Представление запроса: (w_1, w_2, \dots, w_n)

Критерий релевантности вычисляется как результат операций над векторами

Модели поиска

- **Вероятностные модели**

(PRP - Probabilistic Ranking Principle)

Для документа D_k определяется оценка вероятности

релевантности запросу.