

# Марковские цепи в задаче ранжирования страниц в Интернете

Т.В. Жуковская, доцент

ТГТУ, кафедра высшей математики

- Марковские цепи

- Марковские цепи
- Задача ранжирования


- Марковские цепи
- Задача ранжирования
- Алгоритм PageRank


- Марковские цепи
- Задача ранжирования
- Алгоритм PageRank
  - Модель случайного блуждания


- Марковские цепи
- Задача ранжирования
- Алгоритм PageRank
  - Модель случайного блуждания
  - Алгоритм вычисления

- Марковские цепи
- Задача ранжирования
- Алгоритм PageRank
  - Модель случайного блуждания
  - Алгоритм вычисления
  - Применение к задаче ранжирования

- Марковские цепи
- Задача ранжирования
- Алгоритм PageRank
  - Модель случайного блуждания
  - Алгоритм вычисления
  - Применение к задаче ранжирования
- Другие модели, основанные на марковских цепях







Цепь Маркова с **дискретным временем** — случайный процесс  $\{X_n\}_{n \geq 0}$ :

$$\mathsf{P}(X_{n+1} = i_{n+1} | X_n = i_n, \dots, X_0 = i_0) =$$

$$\mathsf{P}(X_{n+1} = i_{n+1} | X_n = i_n).$$

**Однородная:**  $\mathsf{P}(X_{n+1} = j | X_n = i) = \mathsf{P}(X_1 = j | X_0 = i)$ .

Цепь Маркова с **дискретным временем** — случайный процесс  $\{X_n\}_{n \geq 0}$ :

$$\begin{aligned} \mathsf{P}(X_{n+1} = i_{n+1} | X_n = i_n, \dots, X_0 = i_0) = \\ \mathsf{P}(X_{n+1} = i_{n+1} | X_n = i_n). \end{aligned}$$

**Однородная:**  $\mathsf{P}(X_{n+1} = j | X_n = i) = \mathsf{P}(X_1 = j | X_0 = i)$ .

Цепь Маркова с **непрерывным временем** — случайный процесс  $\{X_t\}_{t \geq 0}$ :

$$\begin{aligned} \mathsf{P}(X_{t+h} = x_{t+h} | X_s = x_s, \quad 0 < s \leq t) = \\ \mathsf{P}(X_{t+h} = x_{t+h} | X_t = x_t). \end{aligned}$$

**Однородная:**

$$\mathsf{P}(X_{t+h} = x_{t+h} | X_t = x_t) = \mathsf{P}(X_h = x_h | X_0 = x_0).$$

$Q$  — множество запросов,  $D$  — множество документов.

$Q$  — множество запросов,  $D$  — множество документов.

Для некоторого подмножества  $X \subset Q \times D$  известно идеальное ранжирование:

$$q_1 : d_1^1 > d_2^1 > \dots > d_{i_1}^1;$$

$$q_2 : d_1^2 > d_2^2 > \dots > d_{i_2}^2;$$

...

$$q_n : d_1^n > d_2^n > \dots > d_{i_n}^n.$$

$Q$  — множество запросов,  $D$  — множество документов.

Для некоторого подмножества  $X \subset Q \times D$  известно идеальное ранжирование:


$$q_1 : d_1^1 > d_2^1 > \dots > d_{i_1}^1;$$

$$q_2 : d_1^2 > d_2^2 > \dots > d_{i_2}^2;$$

...


$$q_n : d_1^n > d_2^n > \dots > d_{i_n}^n.$$

**Задача:** отранжировать все остальные пары из  $Q \times D$ .




Пусть  $N$  — количество страниц в интернете.

$$\text{PR}(p) = \frac{0.15}{N} + 0.85 \sum_{\tilde{p} \rightarrow p} \frac{1}{\#\{p' : \tilde{p} \rightarrow p'\}} \text{PR}(\tilde{p}).$$




Пусть  $N$  — количество страниц в интернете.

$$\text{PR}(p) = \frac{0.15}{N} + 0.85 \sum_{\tilde{p} \rightarrow p} \frac{1}{\#\{p' : \tilde{p} \rightarrow p'\}} \text{PR}(\tilde{p}).$$



Пусть  $N$  — количество страниц в интернете.

$$\text{PR}(p) = \frac{0.15}{N} + 0.85 \sum_{\tilde{p} \rightarrow p} \frac{1}{\#\{p' : \tilde{p} \rightarrow p'\}} \text{PR}(\tilde{p}).$$



## Степенной метод

$$\pi_{i+1} = A\pi_i,$$

$$A = (a_{i,j}), \quad a_{i,j} = \frac{0.15}{N} + \frac{0.85}{\text{outdegree}(i)};$$

## Степенной метод

$$\pi_{i+1} = A\pi_i,$$

$$A = (a_{i,j}), \quad a_{i,j} = \frac{0.15}{N} + \frac{0.85}{\text{outdegree}(i)};$$

## Метод Немировского–Нестерова

$$\pi_N = \frac{0.15}{1 - 0.85^{N+1}} \sum_{i=0}^N 0.85^i \tilde{A}^i \pi_0,$$

$$\tilde{A} = (\tilde{a}_{i,j}), \quad \tilde{a}_{i,j} = \frac{0.85}{\text{outdegree}(i)},$$

$$\pi_0(i) = \frac{0.15}{N}.$$



Страницы ранжируются (от самой авторитетной) по убыванию PageRank

Страницы рангируются (от самой авторитетной) по убыванию PageRank

### Плюсы

- Зависит от линковой структуры Интернета
- Согласуется с интуицией о блуждании пользователя на вебграфе
- Коррелирует с популярностью сайтов

Страницы рангируются (от самой авторитетной) по убыванию PageRank

### Плюсы

- Зависит от линковой структуры Интернета
- Согласуется с интуицией о блуждании пользователя на вебграфе
- Коррелирует с популярностью сайтов

### Минусы

- Не зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры
- Не зависит от пользовательского поведения



- Personalised PageRank

- Зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры
- Не зависит от пользовательского поведения

- Personalised PageRank

- Зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры
- Не зависит от пользовательского поведения

- BrowseRank

- Зависит от пользовательского поведения
- Неперывное время
- Не зависит от пользовательских запросов
- Не зависит от истории пользовательского поведения
- Не учитывает никаких свойств Интернета кроме линковой структуры и пользовательского поведения

- Personalised PageRank

- Зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры
- Не зависит от пользовательского поведения

- BrowseRank

- Зависит от пользовательского поведения
- Неперывное время
- Не зависит от пользовательских запросов
- Не зависит от истории пользовательского поведения
- Не учитывает никаких свойств Интернета кроме линковой структуры и пользовательского поведения

- High-Order PageRank

- Зависит от истории пользовательского поведения
- Не зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры и пользовательского поведения

- Personalised PageRank

- Зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры
- Не зависит от пользовательского поведения

- BrowseRank

- Зависит от пользовательского поведения
- Неперывное время
- Не зависит от пользовательских запросов
- Не зависит от истории пользовательского поведения
- Не учитывает никаких свойств Интернета кроме линковой структуры и пользовательского поведения

- High-Order PageRank

- Зависит от истории пользовательского поведения
- Не зависит от пользовательских запросов
- Дискретное время
- Не учитывает никаких свойств Интернета кроме линковой структуры и пользовательского поведения

- Supervised PageRank

- Учитывает любые свойства страниц и ссылок в Интернете
- Дискретное время
- Не зависит от пользовательских запросов
- Не зависит от истории пользовательского поведения