

# ПРИМЕНЕНИЕ СТАЦИОНАРНЫХ ЦЕПЕЙ МАРКОВА ДЛЯ ОПТИМИЗАЦИИ ПОИСКОВЫХ СИСТЕМ

Башкевич А. Ю., Жук Е. Е.

Факультет прикладной математики и информатики, кафедра математического моделирования и анализа данных, Белорусский государственный университет

Минск, Республика Беларусь

E-mail: bashkevichay@gmail.com, zhukee@mail.ru

*В данной работе предлагается использовать модель стационарной односвязной цепи Маркова для подсчета значения PageRank при оптимизации поисковой системы Google. PageRank является числом, отображающим важность страницы. При поиске и ранжировании документов поисковая система Google основывается на содержании страницы, ключевых словах в заголовке и описании, после этого на положение страницы влияет ее PageRank.*

## ВВЕДЕНИЕ

Если рассматривать поведение абстрактного пользователя сети, который выбирает ссылки случайным образом и при этом в любой момент может закрыть браузер и прекратить просмотр, то возникает вопрос, с какой вероятностью случайный пользователь попадет на ту или иную страницу и от чего эта вероятность зависит. Именно для расчета вероятности посещения страницы был разработан алгоритм PageRank.

### I. АЛГОРИТМ ССЫЛОЧНОГО РАНЖИРОВАНИЯ

Для расчета PageRank [1] используется формула (1), где  $PR(T_i)$  – PageRank страницы  $T_i$ ,  $T_1, \dots, T_{i-1}, T_{i+1}, \dots, T_n$  – страницы, ссылающиеся на страницу  $T_i$ ,  $C(T_i)$  – количество ссылок страницы  $T_i$ ,  $d$  – коэффициент затухания, находится в пределах от 0 до 1 (обычно равен 0,85), он введен для учета вероятности того, что пользователь закроет страницу. Также на PageRank наложено ограничение [1]:

$$\sum_{i=1}^N PR(T_i) = N, \quad (2)$$

где  $N$  – количество страниц в сети. Данное условие следует из того, что сумма всех вероятностей не может превышать единицу, т.е. вероятность пребывания на данной странице равна отношению значения PageRank к числу всех страниц.

Рассмотрим расчет PageRank для простейшей сети, состоящей из четырех страниц.




Рис. 1 – Пример страниц в сети

Теперь посчитаем значения PageRank на первом шаге, подставив  $PR(B)$  и  $PR(C)$  равные 1 в формулу (1). В результате мы получим новые значения PageRank для всех страниц. Теперь

посчитаем значения PageRank на втором этапе. Здесь подставим  $PR(B)$  и  $PR(C)$ , полученные на предыдущем шаге. Таким образом, мы получим значения PageRank на втором шаге, которые будут использоваться при расчете значений PageRank на третьем шаге.

Смысл заключается в том, что нам придется проделать эту операцию снова и снова, используя каждый раз значения PageRank рассчитанные на предыдущем этапе. И в результате после какого-то шага  $n$  на всех последующих шагах, начиная с  $n + 1$ , значения PageRank будут неизменными. Для нашего примера достаточно проделать 10 шагов, чтобы значения PageRank выглядели следующим образом:  $PR(A) = 1,637; PR(B) = 1,136; PR(C) = 0,614; PR(D) = 0,614$ . Сумма всех  $PR$  равна 4, т.е. условие (2) выполняется.

Также PageRank можно рассчитать матричным методом. Для этого составляется матрица следующего вида:

$$\begin{pmatrix} A & B & C & D \\ 0 & 1/3 & 1/3 & 1/3 \\ 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{pmatrix}$$

Данная матрица соответствует нашей простейшей сети (см. рис. 1), т.е. страница A ссылается на B, C, D. Страница B ссылается на A. Страница C ссылается на A и D ссылается на B. При этом значения каждой строки делятся на количество ссылок данной страницы.

Данную матрицу необходимо умножить на значение  $PR$  с предыдущего шага, полученный вектор умножить на единичный вектор, умноженный на  $d$ , и прибавить к результату единичный вектор, умноженный на  $(1 - d)$ .

После расчета мы видим, что страница A имеет самый высокий  $PR$  в нашей сети, страница B – более низкий. Поэтому если все четыре страницы будут по содержанию соответствовать какому-то запросу поиска, то после учета значений  $PR$  страница A окажется на первом месте, B – на втором, а C и D – на третьем.

## II. ЦЕПИ МАРКОВА

*Определение 1.* Временной ряд  $x_1, \dots, x_T, x_{T+1}, \dots \in S$ , где  $S = \{1, \dots, L\}$ , называется однородной цепью Маркова [2] с пространством состояний  $S$ , образованной из  $L \geq 2$  состояний, если выполняется так называемое марковское свойство (3)  $\forall d_{t+1}, \dots \in S, \forall t = 1, \dots, T, \dots$

Две вероятностные характеристики цепи Маркова [2 3]:

1. начальное распределение вероятностей:

$$\pi_i^{(1)} = P(x_1 = i), \quad i \in S; \quad \sum_{i \in S} \pi_i^{(1)} = 1; \quad (4)$$

2. матрицу вероятностей одношаговых переходов (5).

Цепь Маркова характеризуется своим текущим распределением вероятностей (в момент времени  $t$ ):

$$\pi_i^{(t)} = P\{x_t = i\}, \quad i \in S, \quad t = 1, 2, \dots, T, \dots \quad (6)$$

*Теорема 1.* В условиях модели (3) – (5) текущее распределение вероятностей (6) может быть найдено из соотношения [2]:

$$\pi^{(t)} = (P')^{t-1} \pi^{(1)} = (P^{t-1}) \pi^{(1)}, \quad (7)$$

где  $\pi^{(t)} = (\pi_1^{(t)}, \dots, \pi_L^{(t)})$ ,  $t = 1, 2, \dots, T, \dots$  а  $\pi^{(1)} = \pi^{(1)}|_{t=1}$  – начальное распределение вероятностей.

*Определение 2.* Распределение вероятностей  $\pi = (\pi_1, \dots, \pi_L)$  называется стационарным распределением для однородной цепи Маркова (3) – (5), если выполняется [2]:

$$\begin{cases} P' \pi = \pi; \\ \sum_{i \in S} \pi_i = 1. \end{cases} \quad (8)$$

*Теорема 2.* Пусть для однородной цепи Маркова (3) – (5) начальное распределение вероятностей  $\pi^{(1)}$  совпадает со стационарным из (8):  $\pi^{(1)} = \pi$ , тогда данная цепь Маркова является стационарной, и текущее распределение вероятностей в любой момент времени совпадает со стационарным [2]:

$$\pi^{(1)} = \pi, \quad t = 1, 2, \dots, T, \dots \quad (9)$$

### III. РАСЧЕТ ПОКАЗАТЕЛЯ PAGERANK С ПОМОЩЬЮ ЦЕПЕЙ МАРКОВА

Следуя из определения цепи Маркова можно сказать, что описанный выше процесс поведения абстрактного пользователя сети является марковским. Начальное состояние системы описывается вектором начальных вероятностей цепи Маркова.

Если  $\pi^{(0)}$  это вектор начальных вероятностей, то  $\pi^{(t)}$  – это вероятностный вектор на шаге  $t$ . Значение  $\pi^{(t+1)}$  рассчитываем по формуле (7). Если цепь Маркова стационарная, то при стремящемся к бесконечности, вероятности состояний стремятся к определенным предельным значениям, которые удовлетворяют следующему соотношению:

$$\pi^{(t)} \rightarrow \pi. \quad (10)$$

Из (10) очевидно, что  $\pi$  является единственным и не зависит от вектора начальных вероятностей  $\pi^{(0)}$  и определяется только матрицей вероятностей переходов (5). Матрица вероятностей одношаговых переходов будет выглядеть также как и при расчете PageRank матричным способом.

Для нашей системы вектор начальных вероятностей выглядит следующим образом (поскольку в нашей сети четыре страницы и пользователь может оказаться на любой из них с одинаковой вероятностью):  $\pi^{(0)} = (1/4, 1/4, 1/4, 1/4)$ .

Для расчета вектора  $\pi^{(1)}$  применим формулу (7). Для вектора  $\pi^{(2)}$  формула (7) имеет следующий вид:  $\pi^{(2)} = P' \pi^{(1)}$ . Далее аналогично рассчитывая значения  $\pi^{(t)}$  по формуле (7) мы найдем  $t$ , для которого выполняется равенство (10). Т.е. мы найдем значение вектора  $\pi = (0,429; 0,286; 0,143; 0,143)$ .

Таким образом, после достаточно большого количества переходов со страницы на страницу уже не имеет значения с какой страницы пользователь начал просмотр, поскольку в результате он окажется на странице А с вероятностью 0,429, на странице В с вероятностью 0,286, на страницах С и D с вероятностями 0,143.

Теперь с полученным вектором  $\pi$  произведем вычисления по формуле (1):  $0,85 * 4 * \pi + (1 - 0,85)$ . Получается что, мы получили значения практически равные значениям PR, рассчитанным в первой части статьи.

## IV. СПИСОК ЛИТЕРАТУРЫ

1. Студия дизайна МЕДИАКРАФТ [Электронный ресурс] / Медиакрафт – Москва, 2007. – Режим доступа: <http://www.mediacraft.ru/sections/articles/1/1.html>. – Дата доступа: 08.09.2013.
2. Харин, Ю. С. Математическая и прикладная статистика / Ю. С. Харин, Е. Е. Жук – Минск: БГУ, 2005. – 279 с.
3. Кемени, Дж. Дж. Конечные цепи Маркова / Дж. Дж. Кемени, Дж. Л. Снелл –М.: Наука, 1970. – 272 с.

$$PR(T_i) = (1 - d) + d \left( \frac{PR(T_1)}{C(T_1)} + \dots + \frac{PR(T_{i-1})}{C(T_{i-1})} + \frac{PR(T_{i+1})}{C(T_{i+1})} + \dots + \frac{PR(T_N)}{C(T_N)} \right) \quad (1)$$

$$P\{x_{t+1} = d_{t+1} | x_t = d_t, x_{t-1} = d_{t-1}, \dots, x_1 = d_1\} = P\{x_{t+1} = d_{t+1} | x_t = d_t\} = p_{d_t, d_{t+1}} \quad (3)$$

$$P = (p_{ij})_{i,j \in S}, \quad p_{ij} = P\{x_{t+1} = j | x_t = i\}, \quad \sum_{j \in S} \pi_{ij} = 1, \quad i \in S \quad (5)$$