

# Многоканальные системы обслуживания с марковским нетерпением<sup>1</sup>

Ю.И. Рыжиков

*Институт информатики и автоматизации РАН,  
Военно-космическая академия им. А.Ф. Можайского,  
г. Санкт-Петербург, Россия*

Среди многочисленных применений теории очередей заметную роль играют ситуации с нетерпеливыми заявками, имеющими случайные ограничения на время пребывания заявки в системе. Чисто марковская система указанного вида была рассмотрена в [1, 2]. В данной статье рассматривается гораздо более интересная для практики задача с гиперэкспоненциальным распределением обслуживания и марковским нетерпением. Предлагаемый метод позволяет обобщить задачу применительно к сети обслуживания.

## Итерационный метод для модели $M/H_2/n$

Работа системы  $M/H_2/n$  может быть интерпретирована как процесс обслуживания потока заявок двух типов. Каждая заявка имеет случайное время терпения, подчиненное экспоненциальному закону с параметром  $\gamma$ .

На рис. 1 представлен фрагмент диаграммы переходов между микросостояниями системы  $M/H_2/3-M$  по уходу заявок для 2-го, 3-го и 4-го ярусов. Кодовые комбинации вида (21) указывают типы обслуживаемых заявок, проставленные на концах стрелок дополнительные множители  $\{y_i\}$  – вероятности выбора заявок соответствующего типа из очереди. На ярусах  $j > n$  отличие будет состоять лишь в интенсивности вертикальных переходов вверх:  $\gamma, 2\gamma, 3\gamma \dots$  Заметим, что скорость продвижения в очереди новой (меченой) заявки определяется только судьбой ранее пришедших.

В соответствии с диаграммой переходов для выбранной модели построим матрицы интенсивностей инфинитезимальных переходов:  $A_j$  по прибытию заявки,  $B_j$  – по завершению обслуживания,  $D_j$  – ухода из состояний яруса  $j$ .

---

<sup>1</sup> Работа выполнялась по госзаданию 0073 2018-0003.




Рис. 1. Фрагмент диаграммы переходов

Введем векторы-строки  $g_j = \{g_{j,1}, g_{j,2}, \dots, g_{j,mj}\}$  нахождения системы в состоянии  $(j,i)$ ,  $j=0,1,\dots$ . Теперь можно записать векторно-матричные уравнения баланса переходов между состояниями

$$\begin{aligned} g_0 D_0 &= g_1 B_1, \\ g_j D_j &= g_{j-1} A_{j-1} + g_{j+1} B_{j+1}, \quad j=1,2,\dots \end{aligned} \quad (1)$$

Положим  $t_j = g_j/p_j$ , где  $p_j$  – суммарная вероятность наличия в системе ровно  $j$  заявок, и обозначим

$$x_j = p_{j+1}/p_j, \quad z_j = p_{j-1}/p_j. \quad (2)$$

Тогда систему (1) можно переписать относительно векторов условных вероятностей  $\{t_j\}$ , нормированных к единице в пределах яруса:

$$\begin{aligned} t_0 D_0 &= x_0 t_1 B_1, \\ t_j D_j &= z_j t_{j-1} A_{j-1} + x_j t_{j+1} B_{j+1}, \quad j=1,2,\dots \end{aligned} \quad (3)$$

Алгоритм [3, 4] расчета набора векторов  $\{t_j\}$  и чисел  $\{x_j\}$  и  $\{z_j\}$ , удовлетворяющих соотношениям (1) – (3), в случае разомкнутой системы опирается на существование предельного вектора условных веро-

ятностей  $t_\infty = \lim_{j \rightarrow \infty} t_j$ , которое является следствием стабилизации переходных матриц при  $j > n$ . Для граничного яруса  $N$  в случае прогона сверху вниз последняя из формул (3) записывается в виде

$$t_N D_N = z_N t_{N-1} A_{N-1} + x_N t_{N-1} B_N \quad (4)$$

(отсутствующий ниже лежащий вектор условных вероятностей микросостояний заменяется на только что вычисленный выше лежащий). В случае с нетерпеливыми заявками  $\{B_j\}$  и  $\{D_j\}$  стабилизируются лишь при  $j \rightarrow \infty$ , но вследствие нарастающей при этом интенсивности уходов по нетерпению суммарные вероятности состояний  $\{p_j\}$  при прочих равных условиях будут убывать значительно быстрее, и ошибки от упомянутого допущения будут играть все меньшую роль. Это оправдывает применение для граничного яруса  $N$  условия (4).

После прекращения итераций можно переходить к нахождению кумулянтных вероятностей. Полагая  $p_0 = 1$ , последовательно вычисляем

$$p_{j+1} = p_j x_j, \quad j = \overline{0, N-1}, \quad (5)$$

а затем нормируем их к единице. Имитационный эксперимент показал хорошее согласие расчетных и статистических вероятностей порядка  $10^{-4}$  и больше, для которых число наблюдений превышало 100.

### Распределение времени ожидания

Наибольшие трудности расчета систем с нетерпением связаны с определением их временных характеристик. Здесь общая формула Брюмелля для моментов распределения длительности ожидания

$$w_j = q_{[j]} / \lambda^j, \quad j = 1, 2, \dots, \quad (6)$$

в которой  $\{q_{[j]}\}$  – факториальные моменты распределения длины очереди, как показали имитационные эксперименты, дает неудовлетворительную точность.

Вычислим

- стационарные векторы-строки  $g_k = p_k * t_k$  вероятностей микросостояний,  $k = 0, 1, \dots$ ,
- диагональные матрицы суммарных интенсивностей переходов вверх с элементами  $\{\sigma_{k,i}\}$ ,

- диагональные матрицы  $\{U_k(s)\}$  преобразований Лапласа – Стильеса (ПЛС) распределений длительности переходов вверх по соответствующим суммарным интенсивностям  $\{\sigma_k\}$  с элементами  $\{\sigma_{k,i}/(\sigma_{k,i} + s)\}$ ,

- произведение  $\tilde{U}_n(s)$  матрицы  $U_n(s)$  на единичный вектор-столбец,
- матрицы  $\{T_k\}$  с элементами  $\{b_{k,i,j}/\sigma_{k,i}\}$  вероятностей переходов на вышележащий ярус.

Кроме того, заменим диагональную матрицу  $U_n(s)$  на одноименный вектор-столбец. Полагая  $F_k(s) = U_k(s)T_k$ , можно сразу записать матрицы  $\{F_k\}$  как совокупности элементов вида  $\{b_{k,i,j}/(\sigma_{k,i} + s)\}$ . Суммируя результаты по всем возможным стартовым ярусам, получаем окончательную формулу для ПЛС распределения времени ожидания:

$$\omega(s) = \left[ \sum_{k=0}^{\infty} g_{n+k} \prod_{i=0}^k F_{n+i}(s) \right] \tilde{U}_n(s). \quad (7)$$

В этой формуле перевернутый символ произведения используется для указания на обратный порядок следования сомножителей. Начальное значение  $F_n(s) = I$ .

Многочисленным численным дифференцированием таблицы ПЛС [4] можно получить моменты распределения  $w(t)$  виртуального ожидания начала обслуживания

Осталось учесть возможность «нетерпения» самой меченой заявки. Поскольку для каждой заявки вероятность перетерпеть время  $u$  равна  $e^{-\gamma u}$ , функция распределения длительности успешного ожидания

$$W^+(t) = \int_0^t e^{-\gamma u} w(u) du.$$

Соответственно ПЛС этого распределения

$$\omega^+(s) = \int_0^{\infty} e^{-st} d \left[ \int_0^t e^{-\gamma u} w(u) du \right] dt = \int_0^{\infty} e^{-st} e^{-\gamma t} w(t) dt = \omega(s + \gamma)..$$

Моменты успешного ожидания, полученные таким способом, должны быть разделены на вероятность успешного ожидания, включая нулевое, то есть на

$$\pi_w = \sum_{k=0}^{n-1} P_k + \omega^+(\gamma).$$

Сопоставим численные результаты, полученные по этой методике и посредством имитационного моделирования (2 млн обслуженных заявок). Для трехканальной системы с интенсивностью входящего простейшего потока  $\lambda = 1.5$ , средним временем обслуживания  $b_1 = 4.0$ , коэффициентом вариации обслуживания  $v_b = 2.0$  и интенсивностью нетерпения  $\gamma = 0.2$  результаты сведены в таблицу.

**Моменты распределения успешного ожидания**

Способ	$w_1^+$	$w_2^+$	$w_3^+$
Имитация	0.483	1.048	3.319
Расчет	0.479	1.039	3.287

### Распределение времени пребывания успешной заявки

Сделанное в данной статье предположение о марковском распределении допустимого терпения позволяет при поступлении заявки из очереди на обслуживание отсчитывать ее терпение заново. Нас в конечном счете интересует ожидание «успешных» заявок, дождавшихся завершения обслуживания. Примем распределение последнего двухфазовым гиперэкспоненциальным с параметрами  $\{y_m, \mu_m\}$ . Тогда  $j$ -й момент успешного обслуживания

$$b_j^+ = \int_0^{\infty} \int_0^{\theta} [t^j b(t) dt] \gamma e^{-\gamma\theta} d\theta = \int_0^{\infty} \int_0^t [t^j \sum_{m=1}^2 y_m \mu_m e^{-\mu_m t} dt].$$

Можно показать, что

$$b_j^+ = j! \sum_{m=1}^2 \frac{y_m}{\mu_m^j} \left[ 1 - \frac{\gamma}{\mu_m + \gamma} \sum_{i=0}^j \left( \frac{\mu_m}{\mu_m + \gamma} \right)^i \right]. \quad (8)$$

### Расчет сети с нетерпеливыми заявками

Предположение о марковском распределении допустимого терпения позволяет перенести результаты предыдущего раздела на расчет сетей методом потокоэквивалентной декомпозиции. В нашем случае в общую

схему расчета разомкнутой сети обслуживания [4] приходится внести следующие изменения:

- В сети не должно быть циклических маршрутов.
- Интенсивности выходящих потоков должны рассчитываться умножением интенсивностей входящих на вероятность успеха.
- Нумерация и, соответственно, очередность расчета узлов должны определяться на основе отношений предшествования – например, с помощью известного алгоритма Флойда.

Выделим из матрицы передач сети с  $M$  рабочими узлами:

- вектор-строку  $P = \{r_{0,1}, r_{0,2}, \dots, r_{0,M}\}$  вероятностей перехода из источника в конкретные рабочие узлы;
- вектор-столбец  $T = \{r_{1,M+1}, r_{2,M+1}, \dots, r_{M,M+1}\}^T$  вероятностей перехода из рабочих узлов в сток;
- матрицу  $Q = \{r_{i,j}\}$ ,  $i, j = \overline{1, M}$ , вероятностей переходов между рабочими узлами.

Кроме того, определим диагональную матрицу  $N(s)$  преобразований Лапласа  $\{v_i(s)\}$  распределений времени пребывания в рабочих узлах сети и сформируем матрицу

$$\Phi(s) = N(s)Q.$$

ПЛС распределения длительности  $k$ -шаговых переходов в сток

$$\varphi_k(s) = P\Phi^{k-1}(s)N(s)T.$$

Полное ПЛС распределения времени пребывания заявки в сети получается суммированием переходов кратностей до  $N$  включительно, где  $N$  – максимальное количество посещаемых заявкой узлов:

$$\varphi(s) = \sum_{k=1}^N \varphi_k(s) = P \left[ \sum_{k=0}^{N-1} \Phi^k(s) \right] N(s)T.$$

Моменты  $\{g_i\}$  распределения времени пребывания в сети можно получить численным дифференцированием  $\varphi(s)$  в нуле.

### Заключение

Основные результаты данной работы сводятся к следующему:

1. С учетом экспоненциального нетерпения находящихся в системе заявок. скорректированы правила расчета матриц интенсивностей переходов  $\{B_j\}$  и  $\{D_j\}$ .

2. Обоснована возможность применения метода Такахаси-Таками к рассматриваемой задаче с переменными матрицами интенсивностей переходов.

3. Разработан метод расчета распределения времени ожидания для «успешных» заявок.

4. Предложены формулы для расчета средних потерь на прерванное обслуживание и интенсивности потока обслуженных заявок.

5. Показано применение перечисленных результатов к расчету сетей обслуживания с нетерпеливыми заявками.

Перечисленные результаты применимы к широкому кругу практически важных ситуаций. В технике связи и военном деле это может быть «обслуживание» подвижных объектов с ограниченным временем пребывания в зоне досягаемости, в проблематике МЧС – спасение людей в аварийных ситуациях, в юстиции – затяжные процессы с ограниченным сроком давности, в медицине – «тяжелые» больные, состояние которых быстро ухудшается в ожидании оказания экстренной помощи, и т. п.

#### ЛИТЕРАТУРА

1. Бочаров П.П., Печинкин А.В. Теория массового обслуживания: Учебник. М.: Изд-во РУДН, 1995. 529 с.
2. Takagi H. *Waiting Time in the M/M/m/(m+c) Queue with Impatient Customers* // Int. J. of Pure and Applied Mathematics. 2014. V. 90. No. 4. P. 519–559.
3. Рыжиков Ю.И. Итеративный метод расчета многоканальных систем обслуживания – основы, модификации и предельные возможности // Труды 9-й Российской мультиконференции по проблемам управления. Информационные технологии в управлении. СПб.: ГНЦ РФ «Концерн Электроприбор», 2016. С. 224–233.
4. Рыжиков Ю.И. Алгоритмический подход к задачам массового обслуживания: Монография. СПб.: ВКА им. А.Ф. Можайского, 2013. 496 с.
5. Вишневецкий В.М. Теоретические основы проектирования компьютерных сетей. М.: Техносфера, 2003. 512 с.
6. Takahashi Y., Takami Y. *A Numerical Method for the Steady-State Probabilities of a GI/G/c Queuing System in a General Class* // J. Operat. Res. Soc. of Japan. 1976. V. 19. No. 2. P. 147–157.
7. Маликовский Ю.В. Сети Джонсона с однолинейными узлами и ограниченным временем пребывания и.или ожидания // Автоматика и Телемеханика. 2015. № 4. С. 67–79.

---

Рыжиков Юрий Иванович, д.т.н., профессор; ryzhbox@yandex.ru