

## Сведения об авторе

Людмила Александровна Муравьева-Витковская

— канд. техн. наук; Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики, кафедра вычислительной техники;  
E-mail: muravyeva-vitkovskaya@yandex.ru

Рекомендована кафедрой  
вычислительной техники

Поступила в редакцию  
23.12.13 г.

УДК 004.89: 002.53

В. В. СОСНИН

## ВРЕМЯ ОЖИДАНИЯ В НЕОДНОРОДНЫХ СИСТЕМАХ С ОЧЕРЕДЯМИ ПРИ ОБСЛУЖИВАНИИ ЗАЯВОК В ПОРЯДКЕ ПОСТУПЛЕНИЯ

Для системы массового обслуживания с заявками двух классов с помощью имитационного моделирования рассчитано среднее время ожидания в очереди при использовании бесприоритетной дисциплины обслуживания. Показаны условия, при которых различается среднее время ожидания заявок разных классов.


**Ключевые слова:** неоднородная система массового обслуживания, среднее время ожидания в очереди, бесприоритетная дисциплина обслуживания.

**Введение.** В теории массового обслуживания важное место занимает бесприоритетная дисциплина обслуживания (ДОБП). Традиционно считается [1], что при ДОБП качество обслуживания заявок разных классов одинаково (показателем качества считается среднее время ожидания заявки в очереди). В работе [2] показано, что в системе M/G/1 ДОБП ни один из классов не имеет преимуществ в качестве обслуживания, т.е. если значения времени ожидания в очереди заявок  $k$  классов суть случайные  $W_1, W_2, \dots, W_k$ , то их математические ожидания равны:  $M[W_1] = M[W_2] = \dots = M[W_k]$ . Однако цель настоящей работы — проверить, обладает ли этим свойством весь класс систем GI/GI/1 с ДОБП [3]. Для подтверждения корректности полученных автором результатов были проведены дополнительные исследования.

Поставленная задача решалась с помощью имитационного моделирования. Рассмотрим пример исследования системы массового обслуживания (СМО) GI/GI/1 с заявками двух классов (НК — низконагружающий, ВК — высоконагружающий класс), которые создают загрузки  $\rho_{ВК} = 0,3$  и  $\rho_{НК} = 0,03$ . Время обслуживания заявок ВК и НК — случайная величина  $B_{ВК}$  и  $B_{НК}$  такая, что  $M[B_{ВК}] = M[B_{НК}] = 10$  у.е. Время между приходом заявок ВК и НК — случайная величина  $A_{ВК}$  и  $A_{НК}$ . Для моделирования  $A_{ВК}$ ,  $A_{НК}$ ,  $B_{ВК}$  и  $B_{НК}$  используется гамма-распределение, каждая из этих величин имеет фиксированное значение математического ожидания, а коэффициент вариации  $v$  изменяется от 0 до 3 с шагом 0,1 так, что  $v = v[A_{ВК}] = v[A_{НК}] = v[B_{ВК}] = v[B_{НК}]$ . При проведении имитационных экспериментов измеряются время ожидания в очереди заявок каждого из классов ( $W_{ВК}$  и  $W_{НК}$ ), а также относительное различие их средних значений:

$$\varepsilon = \frac{M[W_{ВК}] - M[W_{НК}]}{M[W_{НК}]} \cdot 100 \%$$

Результаты имитационного моделирования этой системы приведены на рисунке. Высота значков на кривых соответствует величине 99 %-ного доверительного интервала измеренных в соответствующей точке величин (по Стьюденту). На рисунке *a* видно, что средние задержки НК и ВК заметно различаются за пределами доверительного интервала. Относительное значение этого различия представлено на рисунке *б*: видно, что среднее время ожидания заявок ВК может быть на 90 % меньше или на 20 % больше среднего времени ожидания заявок НК.



Аналогичный характер имеет соотношение вариации времени ожидания, отличие состоит в том, что относительная разница их значений несколько меньше. Приведенный пример позволяет однозначно утверждать, что „свойство бесприоритетности“ ДОБП в СМО M/G/1 не может быть распространено на весь класс систем GI/G/1. Анализ экспериментальных данных показал, что заявки НК получают тем лучшее качество обслуживания, чем ближе параметры системы к следующим предельным значениям:  $\nu[A_{HK}] \rightarrow 0$ ,  $\nu[A_{VK}] \rightarrow \infty$ ,  $\nu[B_{VK}] \rightarrow 0$ ,  $\nu[B_{HK}] \rightarrow 0$ ,  $\frac{\rho_{VK}}{\rho_{HK}} \rightarrow \infty$ . Указанное свойство проверялось для  $\nu[A_{VK}] \leq 5$ . При  $\nu[A_{VK}] > 5$  для получения результатов с приемлемым доверительным интервалом требуются существенные вычислительные мощности. Примем, что полученное свойство верно для всей области значений  $0 < \nu[A_{VK}] < \infty$ , тогда с помощью аналитических преобразований (см. подробный вывод в [3]) можно сформулировать следующее неравенство:

$$M[W_{HK}] > \rho M[W_{VK}]. \quad (1)$$

Этот результат подтверждается имитационными экспериментами с различными законами распределения (двухфазное Кокса, гамма, равномерное). Приведем пример возможного применения полученного результата. Рассмотрим процессы, протекающие на выходном порте некоторого маршрутизатора в компьютерной сети. В качестве потока заявок ВК рассматривается сетевой трафик, который проходит через порт. Современные маршрутизаторы позволяют в режиме реального времени получить данные о текущих характеристиках передачи пакетов, поэтому будем считать информацию о средних задержках пакетов потока ВК доступной и достоверной. В качестве потока заявок НК рассматривается сетевой трафик низкой интенсивности, который планируется дополнительно пустить через рассматриваемый порт. Тогда неравенство (1) позволяет оценить максимальное преимущество в качестве обслуживания, которое могут получить заявки НК. Например, пусть заявки ВК создают 60 %-ную нагрузку, а их среднее время ожидания в очереди равно 200 мс. Пусть требуется пустить в эту СМО еще один поток заявок, увеличивающий ее нагрузку на 3 %. Тогда формула (1) позволяет утверждать, что время ожидания в очереди заявок нового потока не может быть менее 123 мс.

Таким образом, в настоящей работе получены следующие результаты:

- 1) с помощью имитационных экспериментов показано, что при беспriorитетной дисциплине обслуживания заявки разных типов могут иметь разные средние значения времени ожидания в очереди, а также разные вариации этого времени;
- 2) получена численная оценка нижней границы для показателей ожидания низконагружающих потоков заявок.

#### СПИСОК ЛИТЕРАТУРЫ

1. Bolch G., Greiner S., Meer H., Triverdi K. Queueing networks and Markov chains: modeling and performance evaluation with computer science applications. NY: John Wiley & Sons, 1998.
2. Клейнрок Л. Вычислительные системы с очередями. М.: Мир, 1979. 600 с.
3. Соснин В. В. Свойства беспriorитетной дисциплины обслуживания в системах вида GI/G/1 // Тр. 5-й Всерос. науч.-практ. конф. „Имитационное моделирование. Теория и практика“ (ИММОД 2011). СПб, 2011. Т. 2. С. 355—360.

#### Сведения об авторе

Владимир Валерьевич Соснин

— канд. техн. наук; Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики, кафедра вычислительной техники; E-mail: vsosnin@mail.ru

Рекомендована кафедрой  
вычислительной техники

Поступила в редакцию  
23.12.13 г.

УДК 681.3

В. А. БОГАТЫРЕВ, А. В. БОГАТЫРЕВ, С. В. БОГАТЫРЕВ

### ОПТИМИЗАЦИЯ ПЕРЕРАСПРЕДЕЛЕНИЯ НАГРУЗКИ В КЛАСТЕРАХ ПРИ ИЗМЕНЯЮЩЕЙСЯ АКТИВНОСТИ ИСТОЧНИКОВ ЗАПРОСОВ

Предложено решение задачи динамической оптимизации перераспределения запросов через сеть в общедоступный кластер, выполняемой с целью минимизации среднего времени пребывания запросов и позволяющей учитывать задержки отображения числа активных узлов, формирующих запросы.

**Ключевые слова:** отказоустойчивость, распределение запросов, кластер, оптимизация, адаптация.

**Введение.** Распределенные вычислительные системы должны характеризоваться минимальными задержками обслуживания при максимальных надежности, отказоустойчивости и производительности системы [1—3]. Эффективность распределенных компьютерных систем достигается при их адаптации к отказам, к изменениям параметров потоков запросов и состояний очередей узлов [3—5], в том числе в результате динамического перераспределения запросов между узлами компьютерной системы [4—9].

Адаптивное перераспределение запросов в реальном времени приводит, с одной стороны, к балансировке загрузки и росту эффективности системы (уменьшению среднего времени пребывания запросов), а с другой — к ее падению из-за дополнительных задержек, связанных с отображением состояний узлов. Это и определяет необходимость оптимизации процесса перераспределения запросов в вычислительных системах, включая объединение через распределенную инфраструктуру множества ресурсов, доступных из любой точки системы.