

СИСТЕМА ОБСЛУЖИВАНИЯ С ГРУППОВЫМ ПОСТУПЛЕНИЕМ ЗАПРОСОВ В СОСТАВЕ СЕССИЙ

С.А. Дудин

Белорусский государственный университет, кафедра ТВиМС

пр. Независимости, д. 4, Минск, Беларусь

телефон: + (37529) 3134834; e-mail: dudin85@mail.ru

Рассматривается однолинейная система массового обслуживания с групповым поступлением запросов в составе сессий. Прибытие сессий в систему описывается марковским входным процессом. Поступление групп запросов в сессии и время обслуживания запросов описывается потоком фазового типа. Число сессий, которые могут быть приняты в систему одновременно, является управляемым параметром. Анализируются совместное распределение числа сессий и числа заявок в системе.

Ключевые слова – марковский входной поток (*MAP*), процесс фазового типа (*PH*), сессионное поступление запросов.

1 ВВЕДЕНИЕ

Математические модели систем массового обслуживания широко используются при исследовании процессов в различных телекоммуникационных сетях. Пользователь сети может генерировать не один запрос, а целое множество, поэтому при анализе систем массового обслуживания часто предполагают групповой приход заявок. Обычно считают, что в момент прихода группы все заявки из нее прибывают в систему одновременно. Однако, типичной особенностью многих современных телекоммуникационных сетей является то, что запросы, принадлежащие одной группе, поступают в систему не одновременно, а в течение некоторого случайного времени. Первый запрос из группы прибывает в систему в момент ее прихода, в то время как остальные проступают по одному через случайные интервалы. Данная ситуация характерна для многих телекоммуникационных сетей, где, например, запросом является пакет видео- или аудиоинформации, а группой является сеанс, фильм, разговор, сессия, поток и т.д. В данной статье группы запросов, приход которых распределен во времени, будем называть *сессиями*.

Системы с сессионным поступлением запросов могут успешно использоваться при описании работы многих телекоммуникационных сетей, например сетей с протоколом HTTP/1.1, в частности, сети Интернет, где предусматривается создание виртуальных каналов, по которым пе-

редаются пакеты информации для каждого пользователя, установившего соединение.

Сценарий с поступлением запросов в сессиях описывался и анализировался с помощью компьютерного моделирования в [1]. В статье [2], а затем и в [3], словесно описанная в [1] модель была сформулирована и проанализирована в терминах теории массового обслуживания. В [2] и [3] предполагалось, что число запросов в сессии имеет геометрическое распределение и что запросы из сессии прибывают по одному через экспоненциально распределенные временные интервалы. Более общей и сложной моделью поступления запросов в сессии является рассмотренная в данной статье модель, в которой приход групп запросов в сессии управляется *PH* (Phase Type) процессом.

2 МАТЕМАТИЧЕСКАЯ МОДЕЛЬ

Структура рассматриваемой системы обслуживания приведена на Рис. 1.




Рис. 1. Структура системы.

Система емкости $R, 1 \leq R < \infty$, состоит из одного сервера и буфера размера $R-1 \geq 0$. Время обслуживания сервером имеет *PH* распределение. Это означает, что время обслуживания запроса сервером определяется как время, за которое цепь Маркова с непрерывным временем $\eta_t, t \geq 0$, имеющая несущественные состояния $\{1, \dots, M\}$ и поглощающее состояние $M+1$, достигнет поглощающего состояния. Начальное состояние цепи Маркова $\eta_t, t \geq 0$, в момент начала обслуживания запроса определяется вероятностным вектором $\beta = (\beta_1, \dots, \beta_M)$. Переходы цепи $\eta_t, t \geq 0$, которые не приводят к окончанию обслуживания, задаются субгенератором S размера $M \times M$. Интенсивности переходов в поглощающее состояние описываются вектором

$S_0 = -Se$. Здесь e – вектор-столбец, состоящий из единиц.

Запросы поступают в систему в сессиях. Сессии прибывают в соответствии с MAP (Markovian Arrival Process)-потоком. Обозначим управляющий процесс MAP -потока как $v_t, t \geq 0$. Этот процесс является неприводимой цепью Маркова с непрерывным временем, имеющей пространство состояний $\{0, 1, \dots, W\}$. Время пребывания цепи в состоянии v экспоненциально распределено с положительным параметром λ_v . Когда время пребывания в состоянии v истекло, с вероятностью $p_{v,v'}^{(k)}$ процесс v_t переходит в состояние v' , при этом генерируются k сессий, $k = 0, 1, v, v' = \overline{0, W}$. Поведение данного MAP -потока сессий полностью характеризуется матрицами $D_k, k = 0, 1$, которые определяются следующим образом: $(D_k)_{v,v'} = \lambda_v p_{v,v'}^{(k)}, k = 1$ и $k = 0, v \neq v'; (D_0)_{v,v} = -\lambda_v, v' = \overline{0, W}$.

Матрица $D(1) = D_0 + D_1$ является инфинитезимальным генератором цепи $v_t, t \geq 0$. Средняя интенсивность поступления сессий λ имеет вид $\lambda = \chi D(1)e$, где χ – вектор стационарного распределения цепи Маркова $v_t, t \geq 0$. Вектор χ является единственным решением системы линейных алгебраических уравнений $\chi D(1) = 0, \chi e = 1$. Здесь 0 – вектор-строка, состоящий из нулей.

Предполагаем, что прием сессий в систему ограничивается с помощью жетонов. Общее число жетонов $K, K \geq 1$. Если в момент прихода сессии нет свободных жетонов или буфер полон, то сессия получает отказ и покидает систему. Иначе, сессия принимается на обслуживание и число свободных жетонов уменьшается на единицу.

Мы предполагаем, что первый запрос сессии прибывает в момент поступления сессии. Процесс поступления остальных запросов в сессии описывается PH входным потоком. То есть приход запросов из принятой сессии (кроме первого запроса) управляется процессом $j_t, t \geq 0$, который является цепью Маркова с непрерывным временем и пространством состояний $\{1, \dots, J\}$. Начальное состояние цепи $j_t, t \geq 0$, в момент прихода сессии определяется вектором $\delta = (\delta_1, \dots, \delta_J)$. Переход цепи Маркова j_t из состояния j в состояние $j', j \neq j', j, j' = \overline{1, J}$, с вероятностью $p_n, n = \overline{1, N}$, сопровождается приходом группы из n запросов, принадлежащих данной сессии. Переход из состояния j в состояние j не допускается. Интенсивности переходов процесса $j_t, t \geq 0$, определяются субгенератором Δ размера $J \times J$. Интенсивности переходов, которые

приводят к окончанию прибытия сессии, задаются с помощью вектора $\Delta_0 = -\Delta e$.

Если в момент прихода группы запросов из принятой сессии число свободных мест в системе превышает размер группы, вся группа принимается в систему. В противном случае, запросы, которым не хватило места в системе, покидают систему навсегда. Если прибытие сессии окончено, жетон, который был у этой сессии, возвращается в пул свободных жетонов. Все запросы из оконченной сессии, находившиеся в буфере в момент возврата жетона, будут обслужены системой.

3 СОВМЕСТНОЕ РАСПРЕДЕЛЕНИЕ ЧИСЛА СЕССИЙ И ЗАПРОСОВ В СИСТЕМЕ

Пусть $k_t = \overline{0, K}$, – число сессий в системе, $i_t = \overline{0, R}$, – число запросов в системе, $v_t = \overline{0, W}$, – состояние управляющего процесса поступления сессий, $j_t^{(l)} = \overline{0, J}$, – состояние управляющего процесса поступления запросов в l -й сессии, $l = \overline{1, K}$, $\eta_t = \overline{0, M}$, – состояние управляющего процесса обслуживания прибором в момент времени $t, t \geq 0$. Тогда очевидно, что процесс $\xi_t = \{k_t, i_t, v_t, j_t^{(1)}, \dots, j_t^{(K)}, \eta_t\}, t \geq 0$, является неприводимой регулярной цепью Маркова с непрерывным временем.

Текущие сессии предполагаются перенумерованными в порядке их открытия: номер 1 имеет наиболее долготекущая к данному моменту времени сессия. При завершении прихода сессии соответствующий ей номер вычеркивается из записи и производится перенумерация.

Когда число i заявок в системе равно 0, состояние процесса η_t не определено. Чтобы избежать отдельного рассмотрения такого случая, мы будем предполагать, что после момента, когда система станет пустой, значение компоненты η_t установится случайно в соответствии с вероятностным вектором β и сохранится до начала следующего обслуживания прибором.

Перенумеруем состояния цепи Маркова ξ_t в лексикографическом порядке и множество состояний, имеющих значение (k, i) двух первых компонент цепи, будем называть макросостоянием.

Пусть Q – генератор цепи Маркова $\xi_t, t \geq 0$, состоящий из блоков $Q_{k,j}$, состоящих из матриц $(Q_{k,j})_{i,i'}$ интенсивностей переходов этой цепи из макросостояния (k, i) в макросостояние $(j, i'), i, i' = \overline{0, R}$.

Введем следующие обозначения:

- $\tilde{\Delta}$ – это диагональная матрица, диагональные элементы которой совпадают с диагональными элементами матрицы Δ ;
- $\hat{\Delta} = \Delta - \tilde{\Delta}$;

- O – нулевая матрица;
- I – единичная матрица;
- $\otimes$ и $\oplus$ – символы кронекеровых произведения и суммы матриц;
- $A^{\oplus i} = \underbrace{A \oplus A \oplus \dots \oplus A}_i, i > 0, A^{\oplus 0} = O_{1 \times 1}$;
- $\bar{W} = W + 1$.

Лемма 1. Генератор Q имеет следующую блочно-трехдиагональную структуру:

$$Q = \begin{pmatrix} Q_{0,0} & Q_{0,1} & O & \dots & O & O \\ Q_{1,0} & Q_{1,1} & Q_{1,2} & \dots & O & O \\ O & Q_{2,1} & Q_{2,2} & \dots & O & O \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ O & O & O & \dots & Q_{K-1,K-1} & Q_{K-1,K} \\ O & O & O & \dots & Q_{K,K-1} & Q_{K,K} \end{pmatrix},$$

где ненулевые блоки $Q_{k,j}$ вычисляются как

$$Q_{k,k} = \begin{pmatrix} A(k,0) & C(k,0,1) & C(k,0,2) & \dots & C(k,0,R) \\ B(k) & A(k,1) & C(k,1,1) & \dots & C(k,1,R-1) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ O & \dots & B(k) & A(k,R-1) & C(k,R-1,1) \\ O & \dots & O & B(k) & \hat{A}(k) \end{pmatrix},$$

$$k = \overline{0, K},$$

$$Q_{k,k+1} = \begin{pmatrix} O & E(k,0) & O & \dots & O \\ O & O & E(k,1) & \dots & O \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ O & O & \dots & O & E(k,R-1) \\ O & O & \dots & O & O \end{pmatrix}, k = \overline{0, K-1},$$

$$Q_{k,k-1} = \text{diag}\{I_{\bar{W}} \otimes \Delta_0^{\oplus k} \otimes I_{M^{\min\{i,1\}}}, i = \overline{0, R}\}, k = \overline{1, K},$$

$$A(k,i) = \begin{cases} D_0 \oplus \bar{\Delta}^{\oplus k} \oplus S^{\oplus \min\{i,1\}}, & k < K, \\ D(1) \oplus \bar{\Delta}^{\oplus k} \oplus S^{\oplus \min\{i,1\}}, & k = K, \end{cases}$$

$$\hat{A}(k) = D(1) \oplus \Delta^{\oplus k} \oplus S,$$

$$C(k,i,n) = p_n^{(i)} I_{\bar{W}} \otimes \hat{\Delta}^{\oplus k} \otimes I_{M^{\min\{i,1\}}},$$

$$B(k) = I_{\bar{W}} \otimes I_{J^k} \otimes (S_0 \beta),$$

$$p_s^{(i)} = \begin{cases} p_s, & s+i < R, s \leq N, \\ \sum_{l=s}^N p_l, & s+i = R, s \leq N, \\ 0, & s > N, \end{cases}$$

$$E(k,i) = D_1 \otimes (I_{J^k} \otimes \delta) \otimes I_{M^{\min\{i,1\}}}.$$

Доказательство Леммы 1 состоит в анализе переходов цепи Маркова $\xi_t, t \geq 0$, за бесконечно малый интервал времени и последующей группировке интенсивностей соответствующих переходов в блочные матрицы.

Так как цепь Маркова $\xi_t = \{k_t, i_t, v_t, j_t^{(1)}, \dots, j_t^{(k)}, \eta_t\}, t \geq 0$, неприводимая, регулярная и имеет конечное пространство состояний, то существует единственное стационарное распределение вероятностей состояний этой цепи, совпадающее с эргодическим (предельным, финальным):

$$\pi(k, i, v, j^{(1)}, \dots, j^{(k)}, \eta) =$$

$$= \lim_{t \rightarrow \infty} P\{i_t = i, k_t = k, v_t = v, j_t^{(1)} = j^{(1)}, \dots, j_t^{(k)} = j^{(k)}, \eta_t = \eta\},$$

$$i = \overline{0, R}, k = \overline{0, K}, v = \overline{0, \bar{W}}, j^{(l)} = \overline{0, J}, l = \overline{1, k}, \eta_t = \overline{0, M}.$$

Перенумеруем стационарные вероятности цепи Маркова ξ_t в лексикографическом порядке и сформируем из них векторы $\pi(k, i)$, состоящие из вероятностей $\pi(k, i, v, j^{(1)}, \dots, j^{(k)}, \eta)$, записанных в лексикографическом порядке по компонентам $(v, j^{(1)}, \dots, j^{(k)}, \eta)$, и векторы

$$\pi_k = (\pi(k, 0), \pi(k, 1), \dots, \pi(k, R)), k = \overline{0, K}.$$

Известно, что вектор $(\pi_0, \dots, \pi_K)$ является единственным решением системы линейных алгебраических уравнений:

$$(\pi_0, \dots, \pi_K)Q = 0, (\pi_0, \dots, \pi_K)e = 1.$$

Для решения данной системы может быть использован устойчивый алгоритм, являющийся модификацией алгоритма, разработанного в [4], для случая генератора блочно-трехдиагональной структуры. Этот алгоритм изложен в следующей теореме.

Теорема 1. Векторы стационарных вероятностей $\pi_k, k = \overline{0, K}$, вычисляются как

$$\pi_k = \pi_0 F_k, k = \overline{1, K},$$

где матрицы F_k вычисляются рекуррентно:

$$F_0 = I, F_k = -F_{k-1}Q_{k-1,k}(Q_{k,k} + Q_{k,k+1}G_k)^{-1}, k = \overline{1, K},$$

матрицы $G_k, k = \overline{0, K-1}$, вычисляются с помощью обратной рекурсии:

$$G_k = -(Q_{k+1,k+1} + Q_{k+1,k+2}G_{k+1})^{-1}Q_{k+1,k},$$

$$k = K-2, K-3, \dots, 0,$$

при начальном условии

$$G_{K-1} = -(Q_{K,K})^{-1}Q_{K,K-1},$$

вектор π_0 вычисляется как единственное решение следующей системы алгебраических уравнений:

$$\pi_0(Q_{0,0} + Q_{0,1}G_0) = 0, \quad \pi_0 \sum_{k=0}^K F_k e = 1.$$

Заметим, что все обратные матрицы в утверждении теоремы существуют, так как субгенераторы обратимы.

Алгоритм вычисления векторов стационарных вероятностей $\pi_k, k = \overline{0, K}$, приведенный в Теореме 1, позволяет легко решить систему на компьютере практически при любых размерностях.

Найдя векторы стационарных вероятностей $\pi_k, k = \overline{0, K}$, можно вычислить различные характеристики производительности системы:

$$\text{Среднее число запросов в системе } L = \sum_{k=0}^K \sum_{i=1}^R i \pi(k, i) e.$$

$$\text{Среднее число сессий в системе } B = \sum_{k=1}^K k \pi_k e.$$

Среднее число запросов, обслуженных в единицу времени, (пропускная способность)

$$T = \sum_{i=1}^R \sum_{k=0}^K \pi(k, i) (e_{\bar{w}} \otimes e_{j^k} \otimes S_0).$$

Вероятность отказа сессии на входе

$$P_s^{(loss)} = \left(\sum_{i=0}^{R-1} \pi(K, i) (D_1 \otimes I_{j^k M^{\min\{i, 1\}}}) + \sum_{k=0}^K \pi(k, R) (D_1 \otimes I_{j^k M}) \right) \frac{1}{\lambda} e.$$

Вероятность потери группы запросов из принятой сессии целиком

$$P_g^{(loss)} = \frac{\sum_{k=1}^K \pi(k, R) e_{\bar{w}} \otimes \hat{\Delta}^{\oplus k} e_{j^k} \otimes e_M}{\sum_{k=1}^K \sum_{i=0}^R \pi(k, i) e_{\bar{w}} \otimes \hat{\Delta}^{\oplus k} e_{j^k} \otimes e_{M^{\min\{i, 1\}}}}.$$

Вероятность потери произвольного запросов из принятой сессии

$$P_c^{(loss)} =$$

$$\sum_{k=1}^K \sum_{m=0}^R \left(\pi(k, R-m) e_{\bar{w}} \otimes \hat{\Delta}^{\oplus k} e_{j^k} \otimes e_M \sum_{n=m+1}^N p_n(n-m) \right) \times \\ \times \left(\sum_{n=1}^N n p_n \left(\sum_{k=1}^K \sum_{i=0}^R \pi(k, i) e_{\bar{w}} \otimes \hat{\Delta}^{\oplus k} e_{j^k} \otimes e_{M^{\min\{i, 1\}}} \right) \right)^{-1}.$$

ЛИТЕРАТУРА

[1] A simple IP flow blocking model / A.A. Kist, B. Lloyd-Smith, R.J. Harris // Performance Challenges Efficient Next Generation Networks. Proceedings of 19 International Telegraphic Congress, 29 August – 2 September 2005, Beijing. – 2005. – P. 355-364.

[2] Queueing Model with Time-Phased Batch Arrivals / M.H. Lee, S. Dudin, V. Klimenok // Lecture Notes in Computer Science. – 2007. – V. 4516. – P. 716-730.

[3] The MAP/PH/1/N queue with time phased arrivals as model for traffic control in telecommunication networks / C.S. Kim, S.A. Dudin, V.I. Klimenok // Performance Evaluation. – 2009. – V. 66. – P. 564-579.

[4] Lack of invariant property of Erlang loss model in case of the MAP input / V. Klimenok, C.S. Kim, D. Orlovsky, A. Dudin // Queueing Systems. – 2005. – V. 49. – P. 187-213.