

ОПТИМИЗАЦИЯ СОСТАВА И СТРУКТУРЫ ВЫСОКОПРОИЗВОДИТЕЛЬНЫХ ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СРЕДНИХ

Фельдман Л. П., Михайлова Т.В.

Кафедра ПМИИ ДонНТУ

feldman@ r5.dgtu.donetsk.ua

Abstract

Feldman L., Michailova T. Structures optimization for high- performance systems of method middle.. Approach for decision of optimization task for computer systems, that use of method middle, is presented. This method is more economical on calculations complication.

Введение

В работе авторов [1] аналитически решена задача оптимизации состава и структуры вычислительной системы (ВС), представленной замкнутой стохастической сетью, обрабатывающих постоянное число задач. В работе [2], являющейся продолжением статьи [1], рассматривается общая постановка задачи оптимизации ВС, представленной замкнутой стохастической сетью, обрабатывающих постоянное число задач, и рассмотрен более эффективный подход для решения таких задач с использованием градиентных методов. В данной работе предлагается еще один подход для решения задачи оптимизации ВС с использованием метода средних, который по сравнению с предыдущими методами более экономичный по сложности вычислений.

1. Марковская модель системы клиент-сервер

Структура системы клиент- сервер приведена на рис. 1. В ней M рабочих станций пользователей и N групп серверов (количество которых k_1, \dots, k_N соответственно). В зависимости от вида ресурса, которым владеет сервер (файловая система, база данных, принтеры, процессоры или прикладные пакеты программ), определяется тип сервера, например файл-сервер, сервер базы данных, принт-сервер, вычислительный сервер, сервер приложений и т.д.[3].

Предполагается, что все рабочие станции заняты пользователями, каждый из которых может послать только один запрос на один из серверов. Пользователь, пославший запрос к одному из серверов, ждет ответа и, только после получения ответа может послать новый запрос.

В системе постоянно находится M запросов, часть из них m_i находится у пользователей, а m_i - на i -ой группе серверов ($m_1+m_2+\dots+m_N=M$).

Функционирование рассматриваемой системы можно представить замкнутой стохастической сетью, содержащей N систем массового обслуживания (СМО), в которой циркулирует M заявок.

Граф передач этой сети изображен на рис. 2, на котором введены следующие обозначения:

$S_1, S_2, \dots, S_k, \dots, S_N$ - СМО, соответствующие клиентам и серверам;

S_0 - фиктивная система, введенная для фиксации событий завершения задач пользователями;

p_{ij} - вероятности поступлений заявок из i -й СМО в j -ю,
 p_{i0} - вероятность завершения задачи пользователем.




Рисунок 1 - Структура системы клиент – сервер

Поскольку в ВС находится постоянное число задач, то предполагается, что после завершения очередной задачи пользователь приступает к следующей. На рис. 2 этому соответствует передача через систему S_0 . По графу передач определяются соотношения интенсивностей потоков заявок λ_i , поступающих в каждую из систем, и среднее число этапов обслуживания задачи пользователем и сервером $\alpha_i = \lambda_i / \lambda_0$ ($i=1, \dots, N$) [2].

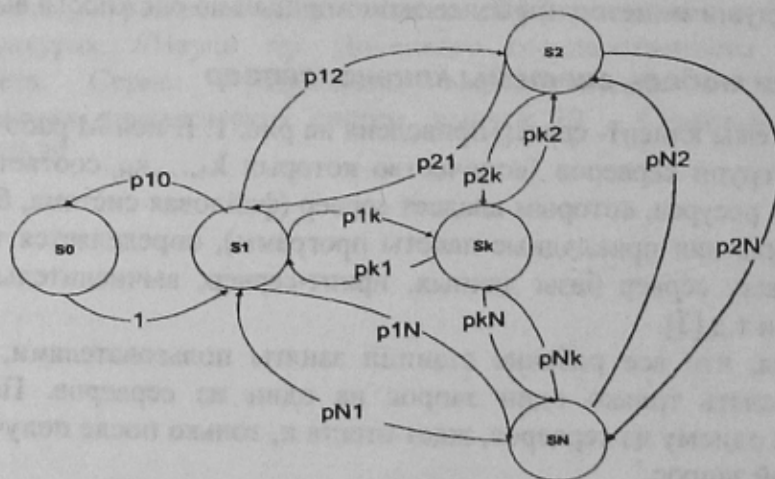


Рисунок 2 - Граф передач сети клиент- сервер

2. Задача оптимизации состава и структуры высокопроизводительных вычислительных систем

Рассматривается решение следующей задачи: определить быстродействие рабочих станций V_1 и серверов V_2, \dots, V_N , обеспечивающих минимальное время решения задачи U так, чтобы стоимость системы с M рабочими станциями не превышала заданного значения S^* . Таким образом, необходимо найти минимум функции U , определяемой формулой (5). При этом надо удовлетворить ограничениям

$$c_1 M V_1 + c_2 V_2 k_2 + \dots + c_N V_N k_N \leq S^*, \quad V_i > 0, i = 1, \dots, N, \quad (1)$$

где c_i - стоимость единицы производительности устройства типа i ,
 k_i - количество серверов i -го вида.

Для решения рассматриваемой задачи можно применить метод множителей Лагранжа, т.е. найти минимум функции

$$G=U+\gamma(c_1MV_1+c_2V_2k_2+\dots+c_NV_Nk_N-S^*), \quad (2)$$

где γ - неопределенный постоянный множитель. В этом случае V_k ($k=1,\dots,N$) и γ определяются как решение системы нелинейных уравнений

$$\frac{\partial G}{\partial V_1}=0,\dots,\frac{\partial G}{\partial V_k}=0,\dots,\frac{\partial G}{\partial V_N}=0, \quad c_1MV_1+c_2V_2k_2+\dots+c_NV_Nk_N \leq S^*. \quad (3)$$

Общее время решения задачи U вычисляется как сумма произведений средних времен пребывания в i -ой СМО ($u_i = \frac{m_i^* v_i}{\rho_i}$) на коэффициент посещения. Основные характеристики сети выражаются через стационарные вероятности [4], некоторые из которых имеют вид:

загрузка сервера $\rho_2 = 1 - \sum_{i=1}^M \pi(i,0,M-i)$; среднее число задач, находящихся на сервере:

$$m_3^* = 1 - \sum_{j=1}^{M-1} j\pi(i, M-j-i, j), \quad i = \overline{1, M}.$$

Стационарная вероятность вычисляется по следующей формуле [4]

$$\pi(m_1, m_2, \dots, m_N) = \frac{\prod_{j=1}^N R_j(m_j)(\alpha_j v_j)^{m_j}}{\sum_{\text{повсем состояниям}} \prod_{j=1}^N R_j(m_j)(\alpha_j v_j)^{m_j}},$$

$$\text{где } R_j(m_j) = \begin{cases} 1/m_j, & \text{если } m_j \leq k_j \\ 1/(k_j! k_j^{m_j-k_j}), & \text{если } m_j > k_j \end{cases}.$$

Выражение для функции U достаточно громоздкое, поэтому для выполнения преобразований, необходимых для получения системы (3), используется пакет *Mathematica*. Программа формирования и решения уравнений (3) подробно описывается в [1].

Полученная таким образом система нелинейных уравнений (3) на современных ПЭВМ решается при ограниченном значении M ($M < 10$), т.к. функция U (5) использует стационарные вероятности (количество которых увеличивается с ростом количества клиентов M). В методе средних [5,6] используются рекуррентные формулы для определения времени решения задачи (5), что позволяет упростить решение поставленной задачи.

3. Метод средних

Основа этого метода - в последовательном вычислении характеристик (4)-(6), начиная с $M=0$ и до заданного значения [6].

Среднее время пребывания в i -й СМО:

$$u_i(M) = v_i [I + n_i(M - I)] + \sum_{j=1}^M j \left[\frac{I}{\mu_i(j)} - v_i \right] P_i(M - I, j - I), \quad (4)$$

$$\text{где } \mu_i(m_i) = \begin{cases} m_i / v_i, & \text{если } m_i \leq k_i, \\ k_i / v_i, & \text{если } m_i > k_i, \end{cases}$$

$$P_i(M, l) = \frac{\lambda_i(M)}{\mu_i(l)} P_i(M - 1, l - 1),$$

$$P_i(0, 0) = 1.$$

Время решения задачи:

$$U(M) = \sum_{i=1}^N \alpha_i u_i(M). \quad (5)$$

Среднее число задач, находящихся в i -й СМО:

$$n_i(M) = \frac{M \alpha_i}{U(M)} u_i(M), \quad (6)$$

$$n_i(0) = 0.$$

Интенсивность входного потока в i -ю СМО:

$$\lambda_i(M) = \lambda_0(M) * \alpha_i. \quad (7)$$

4. Метод оптимизации состава и структуры высокопроизводительных вычислительных систем

Предлагается следующий алгоритм оптимизации состава и структуры высокопроизводительных вычислительных систем.

1. Выбирается исходный вектор производительности устройств V_k ($k=1, \dots, N$) из условия (1). Задаются начальные значения величины шага h , времени отклика $U_{opt} = \infty$, признак определения лучшей точки $flag=0$ ($flag=1$, если определена лучшая точка).

2. Методом средних считаются основные характеристики: средние времена пребывания в i -ой СМО, время отклика задачи $U(M)$, среднее число задач, находящихся в i -ой СМО.

3. Если $U(M) < U_{opt}$, запоминаем новый вектор V_k ($k=1, \dots, N$), новый рекорд по времени отклика $U(M) = U_{opt}$, $flag=1$ (определена лучшая точка на данном шаге).

4. Если нет лучшей точки с шагом h ($flag=0$), уменьшаем его $h=h/2$.

5. Если $h > \epsilon$, переходим к п.5, иначе конец алгоритма.

5. Строим новый вектор V_k ($k=1, \dots, N$) = V_k ($k=1, \dots, N$) + h из условия (1).

Переходим к п.2.

Так как функция U в заданной области монотонна (что показано в [2]), минимум её достигается на границе области допустимых решений [6]. Градиентным методом в силу специфичности функции (2) минимум не всегда достигается. Поэтому методом координатного спуска [5] на границе уточняется результат [2]. Начальным приближением для этого метода используется точка, полученная градиентным методом. Затем на границе с единичным шагом выбирается направление координаты, по которой функция улучшается, и вычисляется новая точка. Если нет лучшей точки, шаг уменьшается. Процесс продолжается, пока не достигнется заданная точность.

5. Пример проектирования вычислительной системы

Спроектировать вычислительную систему клиент-сервер, обеспечивающую обработку потока поступающих запросов так, чтобы стоимость ВС была не больше $S^* = 120$ тыс. грн, а время ответа было минимальным. Вычислительная система состоит из двух серверов и некоторого количества рабочих станций, быстродействие которых необходимо определить. Исходные данные: трудоемкость одного этапа решения задачи в миллионах операций $\theta_1=2$, $\theta_2=1$, $\theta_3=2$ количество этапов обслуживания $\alpha_1=20$, $\alpha_2=17.8$; $\alpha_3=16,6$; коэффициенты стоимости $c1=2$ тыс.грн/ Мфлоп, $c2=5$ тыс.грн /Мфлоп, $c3=2$ тыс.грн/Мфлоп. Результаты, полученные с использованием метода средних совпадают с результатами, полученными методами в [1,2] для $M < 10$ (рис. 1,2), а для значений $M > 10$ – производительности и время отклика вычислены только методом с использованием метода средних.




Рисунок 1 - Производительности рабочих станций и серверов




Рисунок 2 - Время отклика системы

6. Оценка трудоемкости метода

Чтобы вычислить значение времени отклика U (5) по теореме Джексона необходимо рассчитать стационарные вероятности и для каждой СМО среднее время пребывания в ней, загрузку и среднее число задач в этой СМО. Для вычисления нормировочной константы надо выполнить $C \cdot N \cdot M \cdot C_{M+N+1}^{N-1}$ операций сложения и умножения (где C -константа), в том числе $M \cdot C$ операций произведений сомножителей $R_j(m_j)(\alpha_j v_j)^{m_j}$ (так как $\sum_{j=1}^N m_j = M$), N операций сложения этих произведений; для вычисления стационарных вероятностей- C_{M+N+1}^{N-1} операций деления. Чтобы вычислить

необходимые для расчета времени отклика основные характеристики требуется порядка $M*N$ операций сложения. Сложность этого алгоритма – комбинаторная.

Одна итерация с использованием теоремы о среднем требует $L*N*M$ операций сложения и умножения (где L - константа) и еще столько же операций для уточнения на границе. Сложность одной итерации этого алгоритма - полиномиальная.

Выводы

Рассмотрены два подхода к решению задачи синтеза: с использованием теоремы Джексона (аналитическое и численное решение системы (3) методами функций штрафа с уточнением методом покоординатного спуска) и с применением метода средних. Сравнительный анализ аналитического и численного решений системы (3) приведен в [2] в пользу численного решения.

Сравнение аналитического и с использованием теоремы о среднем методов приведен в таблице 1. В целом, алгоритм по теореме Джексона имеет комбинаторный порядок, а алгоритмы с использованием теоремы о среднем – полиномиальный, что позволяет решать задачи, которые вообще не решаются аналитическим методом на современных ЭВМ в течение реального времени.

Рассмотренные выше способы оптимизации состава и структур высокопроизводительных ВС можно использовать для проектирования ВС, причем при больших M – только численным (градиентным) или с использованием метода средних.

Также эти способы можно использовать для расчета основных характеристик (4)-(8) для системы клиент – сервер.

Таблица 1

Метод	Макс. значение M , при котором задача решается на ЭВМ	Время решения задачи при различных M			Кол-во операций сложения и умнож. (в целом)
		1	5	10	
т. Джексона	<10	сек	мин	часы	$N*M * C_{M+N+1}^{N-1}$
т. о среднем	>10	сек	сек	мин	$N*M$

Литература

1. Фельдман Л.П., Михайлова Т.В. Методы оптимизации состава и структуры высокопроизводительных систем //Научные труды Донецкого государственного технического университета. Серия «Информатика, кибернетика и вычислительная техника»(ИКВТ-2000).- Донецк: ДонГТУ. - 2000. – с.90-95.
2. Фельдман Л.П., Михайлова Т.В. Способы оптимизации состава и структуры высокопроизводительных вычислительных систем //Научные труды Донецкого государственного технического университета. Серия «Информатика, кибернетика и вычислительная техника»(ИКВТ-2001).- Донецк: ДонГТУ.- 2000. С. 80-85.
3. Шнитман В. Современные высокопроизводительные компьютеры. Информационно- аналитические материалы центра информационных технологий, 1996: http://hardware/app_kis.
4. Клейнрок Л. Вычислительные системы с очередями. – М.: Мир, 1979, 600с.
5. Фельдман Л.П., Дедищев В.А. Математическое обеспечение САПР. Моделирование вычислительных и управляющих систем. – Киев: УМК ВО, 1992, 256с.
6. Авен О. И. и др. Оценка качества и оптимизация вычислительных систем. – М.: Наука, 1982, 464с.

Поступила в редакційну колегію 1. 11.2001 р.