

УДК 681.3.06:519

МАКРОКОНВЕЙЕРНЫЕ СИСТЕМЫ НЕОДНОРОДНЫХ ПРОЦЕССОВ

Павлов Павел Александрович, к.ф.–м.н., доцент

Полесский государственный университет

Pavlov Pavel, PhD, Polessky State University, pin2535@tut.by

Аннотация: предлагается математическая модель организации вычислений неоднородных конкурирующих процессов в многопроцессорных системах макроконвейерного типа, а также решение задач нахождения числовых характеристик такой организации процессов по времени их реализации.

Ключевые слова: асинхронный режим, диаграмма Ганта, программный ресурс, структурирование, макроконвейерная обработка, канал.

В настоящее время среди наиболее перспективных концепций параллельной обработки является *макроконвейерная* организация вычислений над структурами данных. Интерес к этой концепции постоянно растет в связи с развитием и широким применением локальных и глобальных сетей, созданием вычислительных многопроцессорных систем (МС) и комплексов, сетевого аппаратного и прикладного программного обеспечения. Основная идея концепции *макроконвейерной* организации вычислений заключается в том, что при распараллеливании и распределении вычислений между процессорами (процессорными узлами) “каждому отдельному процессору на очередном шаге вычислений дается такое задание, которое позволяет ему длительное время работать автономно без взаимодействия с другими процессорами” [1]. Уменьшение числа и объемов обмена сообщениями, которыми обмениваются параллельно работающие узлы, как правило, приводит к уменьшению общего времени выполнения заданных объемов вычислений, что является одним из главных критериев качества распараллеливания вычислений.

1. Метод структурирования программных ресурсов и макроконвейерная обработка. *Структурирование (декомпозиция)* – это основной способ уменьшения сложности больших задач, программ, систем и т.д. Основная идея состоит в обеспечении специального способа структурирования программного ресурса на блоки Q_1, Q_2, \dots, Q_s и организации параллельного использования этих блоков множеством конкурирующих процессов [2].

Макроконвейерная технология вычислений предполагает декомпозицию структуры данных на большие информационно–слабозависимые подструктуры, способные занимать процессор длительное время. Работа процессоров при этом организуется таким образом, чтобы обмен данными между ними занимал небольшое время по сравнению с временем вычислений.

Пусть PR – программный ресурс, который могут использовать два и более конкурирующих процессов, причем их число $n \geq 2$; $p \geq 2$ – число процессоров макроконвейерной системы, имеющими как локальную, так и общую для всех процессоров память. Применительно к программным ресурсам, одновременно используемым множеством процессов, при макроконвейерной обработке возможны следующие способы организации вычислений.

1) Каждому i -му процессу, $i = \overline{1, n}$, предоставляется отдельная копия программного ресурса PR. При такой стратегии, в случае $p \geq n$, все n процессов могут выполняться одновременно при условии, что в МС достаточно памяти для размещения n копий программного ресурса (в случае с общей памятью) или память каждого процессора МС вмещает отдельную копию программного ресурса (в случае с распределенной памятью). Если же $p < n$, то возможна организация циклического выполнения n процессов группами по p .

2) Программный ресурс PR может быть структурирован на блоки Q_1, Q_2, \dots, Q_s , а вычисления в этом случае организуются в соответствии с методом структурирования. Эта

стратегия может применяться при организации вычислений в МС всякий раз, если имеются ограничения на оперативную память, как общую, так и память каждого процессора.

Пусть МС характеризуется следующими параметрами: p – число процессоров, каждый из которых имеет собственную локальную память, $p \geq 2$; k – число каналов, через которые каждый из процессоров имеет доступ к внешней памяти, общей для всех процессоров, $k \geq 1$. Предполагается, что в МС выполняется n процессов, $n \geq 2$, каждый из которых состоит из s блоков обмена и s блоков счета, $s \geq 1$. Времена обмена и счета для каждого из процессов представлены в виде матриц $t = [t_{ij}]_{n \times s}$ и $T = [T_{ij}]_{n \times s}$ размерности $n \times s$, в которых i -е строки соответствуют i -му процессу.

Взаимодействие процессов с каналами и процессорами характеризуется следующими условиями: 1) к выполнению одновременно готовы p процессов из n ; 2) в каждый момент времени k процессов из n , одновременно протекающих в МС, выполняются синхронно, остальные в очереди ждут освобождения каналов; 3) во время обмена каждый процесс монополизирует один и тот же канал, во время счета – процессор; 4) очередной j -й блок счета на каждом процессоре выполняется только после завершения соответствующего j -го блока обмена, а каждый $(j+1)$ -й блок обмена выполняется после завершения j -го блока счета; 5) процессы считаются равноприоритетными, а режим работы каналов является циклическим.

Условия 1–5 определяют *асинхронный* режим взаимодействия процессов, каналов и процессоров, который допускает как простои каналов из-за занятости процессоров, так и простои процессоров из-за занятости каналов обмена.

2. Время реализации асинхронных процессов в макроконвейерных системах с одним каналом обмена. Обозначим через $T_n(k)$ общее время выполнения всех n процессов, которые используют k каналов. Заметим, что при $p \geq k \geq n$ в рамках принятой модели макроконвейерных вычислений $T_n(k)$ составит величину

$$T_n(k) = T_n(n) = \max_{1 \leq i \leq n} \sum_{j=1}^s (t_{ij} + T_{ij}).$$

Если окажется, что $p > k > n$, то $k - n$ каналов будут не задействованы, а $p - n$ процессоров будут простаивать.

Пусть имеется один канал, т.е. $k = 1$. Предположим, что $n \leq p$. На рис.1 приведена несовмещенная диаграмма Ганта, отображающая взаимодействие n процессов с одним каналом и p процессорами. Причем каждый процесс состоит из $2s$ блоков, $s \geq 1$, которые периодически повторяются в порядке обмен, счет. При этом осуществляется конвейеризация каждого из блоков счета по всем n процессорам, причем одновременно могут выполняться n блоков счета.




Рисунок 1 – Несовмещенная диаграмма Ганта с одним каналом обмена

Из анализа диаграммы следует, что $T_n(1)$ можно существенно сократить, если воспользоваться совмещением соседних диаграмм Ганта справа налево на максимально возможную величину, не нарушающую условий 1–5. Для этого необходимо составить расписание моментов начала выполнения j -го блока обмена, $j = \overline{1, s}$, для i -го процесса, $i = \overline{1, n}$ [3].

Анализируя две соседние диаграммы Ганта (рис.1), соответствующие j -му и $(j+1)$ -му блокам обмена и счета, с временами t_{ij} , T_{ij} и $t_{i,j+1}$, $T_{i,j+1}$ соответственно, $i = \overline{1, n}$, $j = \overline{1, s-1}$, видно, что моменты начала выполнения *первого* блока обмена для каждого процесса определяются из соотношений:

$$sb_{11} = 0, sb_{21} = sb_{11} + t_{11}, \dots, sb_{i1} = sb_{i-1,1} + t_{i-1,1}, \dots, sb_{n1} = sb_{n-1,1} + t_{n-1,1};$$

для *второго* блока обмена:

$$sb_{12} = \max(sb_{11} + t_{11} + T_{11}, sb_{31} + t_{31}),$$

$$sb_{22} = \max(sb_{21} + t_{21} + T_{21}, sb_{12} + t_{12}), \dots,$$

$$sb_{i2} = \max(sb_{i1} + t_{i1} + T_{i1}, sb_{i-1,2} + t_{i-1,2}), \dots,$$

$$sb_{n2} = \max(sb_{n1} + t_{n1} + T_{n1}, sb_{n-1,2} + t_{n-1,2}); \dots;$$

для s -го блока обмена:

$$sb_{1s} = \max(sb_{1,s-1} + t_{1,s-1} + T_{1,s-1}, sb_{3,s-1} + t_{3,s-1}),$$

$$sb_{2s} = \max(sb_{2,s-1} + t_{2,s-1} + T_{2,s-1}, sb_{1s} + t_{1s}), \dots,$$

$$sb_{i3} = \max(sb_{i,s-1} + t_{i,s-1} + T_{i,s-1}, sb_{i-1,s} + t_{i-1,s}), \dots,$$

$$sb_{ns} = \max(sb_{n,s-1} + t_{n,s-1} + T_{n,s-1}, sb_{n-1,s} + t_{n-1,s}).$$

Теорема 1. Общее время выполнения n ($n \geq 2$) процессов p ($p \geq 2$) процессорами, конкурирующими за использование одного канала, в случае $n \leq p$, определяется по формуле:

$$T_n(1) = \max_{1 \leq i \leq n} (sb_{is} + t_{is} + T_{is}), \quad (1)$$

где sb_{ij} – моменты начала выполнения j -го блока обмена для i -го процесса, определяемые из соотношений:

$$sb_{11} = 0, \quad sb_{i1} = sb_{i-1,1} + t_{i-1,1},$$

$$sb_{1j} = \max(sb_{1,j-1} + t_{1,j-1} + T_{1,j-1}, sb_{n,j-1} + t_{n,j-1}) \quad (2)$$

$$sb_{ij} = \max(sb_{i,j-1} + t_{i,j-1} + T_{i,j-1}, sb_{i-1,j} + t_{i-1,j}), \quad i = \overline{2, n}, \quad j = \overline{2, s}.$$

В результате совмещения диаграмма Ганта будет иметь вид (рис.2):




Рисунок 2 – Совмещенная диаграмма Ганта с одним каналом обмена

3. Макроконвейерные системы с ограниченным числом каналов обмена. Из физических соображений наибольший интерес в рамках концепции макроконвейерных вычислений представляет случай ограниченного числа каналов, т.е. когда $k \ll n$, $n = mk$, $m > 1$, что означает, что процессы конкурируют за использование каналов. Будем считать, что $n \leq p$. Рассмотрим следующие способы взаимодействия процессов с каналами и процессорами.

При первом способе, каждый g -й канал, $g = \overline{1, k}$, обслуживает очередных m процессов, которые выполняются на m процессорах, т.е. 1-й канал обслуживает процессы с номерами $1, 2, \dots, m$, 2-й – с номерами $m+1, m+2, \dots, 2m$, k -й – с номерами $(k-1)m+1, (k-1)m+2, \dots, n$.

Теорема 2. Общее время выполнения p процессорами ($p \geq 2$) $n = mk$ ($m > 1$) процессов, которые конкурируют за использование k каналов ($k \geq 1$), в случае $n \leq p$ определяется из соотношения:

$$T_n(k) = \max_{1 \leq g \leq k} T_m^g(1) = \max_{1 \leq g \leq k} \left(\max_{(g-1)m+1 \leq i \leq gm} (sb_{is} + t_{is} + T_{is}) \right),$$

где sb_{ij} – моменты начала выполнения j -го блока обмена для i -го процесса, определяемые из соотношений:

$$sb_{gm+1,1} = 0, \quad g = \overline{0, k-1}, \quad sb_{i1} = sb_{i-1,1} + t_{i-1,1},$$

$$sb_{(g-1)m+1,j} = \max(sb_{(g-1)m+1,j-1} + t_{(g-1)m+1,j-1} + T_{(g-1)m+1,j-1}, sb_{mg,j-1} + t_{mg,j-1})$$

$$, \quad sb_{ij} = \max(sb_{i,j-1} + t_{i,j-1} + T_{i,j-1}, sb_{i-1,j} + t_{i-1,j}),$$

$$i = \overline{(g-1)m+2, gm}, \quad j = \overline{2, s}, \quad g = \overline{1, k}.$$

Доказательство теоремы приведено в [4].

При втором способе взаимодействия процессов, каналов и процессоров все множество из n процессов разбивается на k групп по m процессов в каждой. Причем каждый g -й канал, $g = \overline{1, k}$, обслуживает группу из m процессов с номерами $(l-1)k + g$, где $l = \overline{1, m}$. В этом случае, согласно формулам (1)–(2) время, затраченное на выполнение каждой группы из m процессов m процессорами каждым g -м каналом, $g = \overline{1, k}$, составит:

$$T_m^1(1) = \max_{1 \leq l \leq m} (sb_{[(l-1)k+1],s} + t_{[(l-1)k+1],s} + T_{[(l-1)k+1],s}),$$

$$\text{где} \quad sb_{11} = 0, \quad sb_{lk+1,1} = sb_{[(l-1)k+1],1} + t_{[(l-1)k+1],1},$$

$$sb_{[(l-1)k+1],j} = \max(sb_{[(l-1)k+1],j-1} + t_{[(l-1)k+1],j-1} + T_{[(l-1)k+1],j-1}, sb_{lk+1,j-1} + t_{lk+1,j-1})$$

$$, \quad sb_{lk+1,j} = \max(sb_{lk+1,j-1} + t_{lk+1,j-1} + T_{lk+1,j-1}, sb_{[(l-1)k+1],j} + t_{[(l-1)k+1],j}),$$

$$l = \overline{1, m-1}, \quad j = \overline{2, s};$$

$$T_m^2(1) = \max_{1 \leq l \leq m} (sb_{[(l-1)k+2],s} + t_{[(l-1)k+2],s} + T_{[(l-1)k+2],s}),$$

$$\text{где} \quad sb_{21} = 0, \quad sb_{lk+2,1} = sb_{[(l-1)k+2],1} + t_{[(l-1)k+2],1},$$

$$sb_{[(l-1)k+2],j} = \max(sb_{[(l-1)k+2],j-1} + t_{[(l-1)k+2],j-1} + T_{[(l-1)k+2],j-1}, sb_{lk+2,j-1} + t_{lk+2,j-1})$$

$$, \quad sb_{lk+2,j} = \max(sb_{lk+2,j-1} + t_{lk+2,j-1} + T_{lk+2,j-1}, sb_{[(l-1)k+2],j} + t_{[(l-1)k+2],j}),$$

$$l = \overline{1, m-1}, \quad j = \overline{2, s}; \dots;$$

$$T_m^k(1) = \max_{1 \leq l \leq m} (sb_{lk,s} + t_{lk,s} + T_{lk,s}),$$

$$\text{где} \quad sb_{k1} = 0, \quad sb_{(l+1)k,1} = sb_{lk,1} + t_{lk,1},$$

$$sb_{lk,j} = \max(sb_{lk,j-1} + t_{lk,j-1} + T_{lk,j-1}, sb_{(l+1)k,j-1} + t_{(l+1)k,j-1}),$$

$$sb_{(l+1)k,j} = \max(sb_{(l+1)k,j-1} + t_{(l+1)k,j-1} + T_{(l+1)k,j-1}, sb_{lk,j} + t_{lk,j}), \quad l = \overline{1, m-1}, \\ j = \overline{2, s}.$$

Теорема 3. *Общее время выполнения p процессорами ($p \geq 2$) $n = mk$ ($m > 1$) процессов, которые конкурируют за использование k каналов ($k \geq 1$), в случае $n \leq p$ определяется из соотношения:*

$$T_m^g(1) = \max_{1 \leq l \leq m} (sb_{[(l-1)k+g],s} + t_{[(l-1)k+g],s} + T_{[(l-1)k+g],s}),$$

где sb_{ij} – моменты начала выполнения j -го блока обмена для i -го процесса, определяемые из соотношений:

$$sb_{g1} = 0, \quad sb_{lk+g,1} = sb_{[(l-1)k+g],1} + t_{[(l-1)k+g],1}, \\ sb_{[(l-1)k+g],j} = \max(sb_{[(l-1)k+g],j-1} + t_{[(l-1)k+g],j-1} + T_{[(l-1)k+g],j-1}, sb_{lk+g,j-1} + t_{lk+g,j-1}), \\ sb_{lk+g,j} = \max(sb_{lk+g,j-1} + t_{lk+g,j-1} + T_{lk+g,j-1}, sb_{[(l-1)k+g],j} + t_{[(l-1)k+g],j}), \\ l = \overline{1, m-1}, \quad j = \overline{2, s}, \quad g = \overline{1, k}.$$

Построенная модель организации макроконвейерных вычислений над структурами данных при ограниченном числе каналов обмена и разработанные аналитические методы расчета общего времени выполнения множества неоднородных конкурирующих процессов являются основой для постановки и решения ряда важных практических задач по расчету оптимальной балансировки числа процессоров и каналов, оптимизации числа блоков счета и обмена, минимизации общего времени выполнения процессов и др.

Список использованных источников:

1. Капитонова, Ю.В., Летичевский, А.А. Математическая теория проектирования вычислительных систем. М., 1988. – 296 с.
2. Павлов, П.А., Коваленко, Н.С. Математическое моделирование параллельных процессов. Lambert Academic Publishing. Germany, 2011. – 246 с.
3. Танаев, В.С., Сотсков, Ю.Н., Струсевич, В.А. Теория расписаний. Многостадийные системы. М., 1989. – 328 с.
4. Коваленко, Н.С., Павлов, П.А. Модель сосредоточенной обработки неоднородных процессов в системах макроконвейерного типа / Н.С. Коваленко, П.А. Павлов // Вестник БГУ. Серия 1: Физика. Математика. Информатика. – 2013. – №3. – С. 93–99.