



ПРОГРАММНО- ТЕХНИЧЕСКИЕ КОМПЛЕКСЫ

П.И. СОБОЛЕВСКИЙ, С.В. БАХАНОВИЧ, А.Н. ГОРБАЧ

УДК 681.3.012+519.6

ОПТИМИЗАЦИЯ ТАЙЛИНГА ПРИ ЧИСЛЕННОМ РЕШЕНИИ МНОГОМЕРНОГО УРАВНЕНИЯ ТЕПЛОПРОВОДНОСТИ НА КОЛЬЦЕ ПРОЦЕССОРОВ¹

Ключевые слова: тайлинг, тайл, вычислительная система с распределенной памятью, оптимизация, уравнение теплопроводности.

Один из важнейших аспектов при разработке и оптимизации параллельных приложений для вычислительных систем с распределенной памятью — эффективная организация коммуникации. На практике коммуникации часто являются узким местом параллельных приложений вследствие высокой латентности каналов связи по сравнению с производительностью узлов. Одно из эффективных средств оптимизации коммуникаций — техника тайлинга, позволяющая уменьшить долю коммуникаций по сравнению с долей вычислений параллельного алгоритма и дополнительного повысить эффективность использования памяти вычислительных узлов.

В данной работе исследуется задача оптимизации тайлинга при решении первой краевой задачи для многомерного уравнения теплопроводности

$$\frac{\partial u}{\partial x_1} = \sum_{m=2}^n \frac{\partial^2 u}{\partial x_m^2}, \quad 0 < x_m < 1, \quad 2 \leq m \leq n, \quad 0 < x_1 < T, \quad (1)$$

на вычислительных системах с распределенной памятью, построены оценки объема коммуникаций и вычислений при заданных вариантах тайлинга. На их основе для случаев $n = 2$ и $n = 3$ получены оценки полного времени реализации алгоритма, представляющие собой функцию от параметров тайлинга и параметров целевого суперкомпьютера: размерности и размеров вычислительной среды, производительности процессоров, времени инициализации и пропускной способности каналов связи. Минимизация этой функции позволяет оптимизировать тайлинг.

1. ТАЙЛИНГ

Предположим, что параллельный алгоритм, как это часто бывает на практике, строится на основе соответствующего последовательного алгоритма. Рассмотрим n -мерные алгоритмы с однородными зависимостями, записанные в виде гнезда тесновложенных циклов:

```
for  $i_1 = 1$  to  $I_1$  do
    .....
    for  $i_n = 1$  to  $I_n$  do
        begin
             $S_1(i_1, i_2, \dots, i_n);$ 
            .....
             $S_k(i_1, i_2, \dots, i_n)$ 
        end
```

(2)

¹ Работа выполнена при финансовой поддержке Белорусского республиканского фонда фундаментальных исследований (проект № Ф08-016).

Алгоритмы такого вида характеризуются областью вычислений V и множеством векторов зависимостей Φ . Область вычислений есть подмножество точек целочисленного пространства \mathbf{Z}^n , которое определяется как $V = \{v(i_1, i_2, \dots, i_n) \in \mathbf{Z}^n | 1 \leq i_m \leq I_m, 1 \leq m \leq n\}$. Каждой точке $v(i_1, i_2, \dots, i_n) \in V$ в соответствии с алгоритмом приписано k операций $S_i(v) = S_i(i_1, i_2, \dots, i_n), 1 \leq i \leq k$. Множество векторов зависимостей отражает информационные зависимости между операциями алгоритма: наличие вектора $\varphi^{(i,j)}$ множества Φ означает, что существуют такие $v \in V$ и $i, j \in N, 1 \leq i, j \leq k$, что операция $S_j(v + \varphi^{(i,j)})$ информационно зависит от операции $S_i(v)$.

Техника тайлинга состоит в разбиении области вычислений алгоритма (и соответственно множества его операций) n семействами параллельных гиперплоскостей на множество n -мерных параллелепипедов-тайлов. Множество операций, принадлежащих одному тайлу, составляют новое (укрупненное) зерно вычислений. Семейства гиперплоскостей задаются множеством из n линейно независимых векторов $\{h_1, h_2, \dots, h_n\}$. Каждому семейству соответствует свой вектор h_m , нормальный для гиперплоскостей этого семейства. Получаемое разбиение области V на тайлы должно удовлетворять следующим условиям:

- 1) тайлы должны быть однотипными, т.е. одинаковыми по форме и размеру (за исключением возможно граничных);
- 2) между тайлами не должно существовать обратных связей.

Введем ряд формальных определений и обозначений.

• $H = (h_1, h_2, \dots, h_n)^T$ — квадратная матрица порядка n , строками которой выступают координаты линейно независимых целочисленных векторов $h_m, 1 \leq m \leq n$, — нормальных векторов гиперплоскостей, осуществляющих разбиение области вычислений на тайлы. Будем считать, что наибольший общий делитель модулей координат каждого из этих векторов равен единице.

• $R = \text{diag}(\eta_1, r_2, \dots, r_n)$ — диагональная матрица. Натуральное число r_m обозначает количество гиперплоскостей с нормальным вектором $h_m, 1 \leq m \leq n$, проходящих через каждый тайл.

$$\bullet v^{\min} = (v_1^{\min}, v_2^{\min}, \dots, v_n^{\min})^T \text{ — вектор, определяемый условиями } h_m \cdot v_m^{\min} = \min_{v \in V} h_m \cdot v, 1 \leq m \leq n.$$

• $1_n = (1, 1, \dots, 1)^T$ — вектор размерности n , составленный из единиц.

• $I = (I_1, I_2, \dots, I_n)^T$ — вектор, построенный из значений $I_m, 1 \leq m \leq n$.

• $\lfloor a \rfloor$ — вектор, составленный из целых частей координат вектора a .

$\{a\}$ — вектор, построенный из дробных частей координат вектора a .

Формально тайлинг можно рассматривать как нелинейное отображение множества V на множество $V' \subset \mathbf{Z}^{2n}$: $v \rightarrow (j, \alpha), v \in V \subset \mathbf{Z}^n, (j, \alpha) \in V' \subset \mathbf{Z}^{2n}$, где

$$\begin{aligned} j &= (j_1, j_2, \dots, j_n)^T = 1_n + \lfloor R^{-1} H(v - v^{\min}) \rfloor, \\ \alpha &= (\alpha_1, \alpha_2, \dots, \alpha_n)^T = R(1_n - \{R^{-1} H(v - v^{\min})\}). \end{aligned} \quad (3)$$

Вектор $j = (j_1, j_2, \dots, j_n)^T, j_m = 1, 2, \dots, J_m, J_m = \left\lceil \frac{1}{r_m} \sum_{k=1}^n |h_{m,k}| (I_k - 1) + 1 \right\rceil$,

$1 \leq m \leq n$, определяет глобальные координаты тайла, вектор $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T, \alpha_m = 1, 2, \dots, r_m, 1 \leq m \leq n$, — локальные (в каждом тайле) координаты точки $v = (i_1, i_2, \dots, i_n) \in V$. Координата α_m обозначает порядковый номер гиперплоскости, проходящей через тайл с нормальным вектором h_m .

Векторы зависимостей для алгоритма вида (2) обладают таким свойством: первая ненулевая координата вектора больше нуля. Отсюда, а также из определения тайлинга и обозначений, приведенных выше, следует, что точка v^{\min} принадлежит тайлу с единичными координатами и является точкой пересечения гиперплоскостей с номерами, определяемыми вектором $\alpha = R\mathbf{1}_n = (r_1, r_2, \dots, r_n)^T$.

Пусть H_+ и H_- — матрицы, полученные из матрицы H заменой соответственно отрицательных и положительных элементов нулями. Тогда имеет место равенство $Hv^{\min} = H_+ \mathbf{1}_n + H_- I$.

Очевидно соотношение

$$H(v - v^{\min}) = Rj - \alpha, \quad (4)$$

из которого при условии целочисленности вектора $v^{\min} + H^{-1}(Rj - \alpha)$ следует $v = v^{\min} + H^{-1}(Rj - \alpha) \in V$ или с учетом приведенных определений

$$v = v^{\min} + \frac{1}{|H|} \begin{pmatrix} \sum_{m=1}^n (r_m j_m - \alpha_m) A_{m1} \\ \sum_{m=1}^n (r_m j_m - \alpha_m) A_{m2} \\ \vdots \\ \sum_{m=1}^n (r_m j_m - \alpha_m) A_{mn} \end{pmatrix}, \quad (5)$$

где A_{mk} — алгебраическое дополнение элемента h_{mk} матрицы H , $|H|$ — определитель матрицы H .

Определение 1. Тайлы j' , j'' называются однотипными, если существует такой вектор $b \in \mathbb{Z}^n$, что тайл j'' может быть получен путем параллельного переноса тайла j' на вектор b .

Утверждение 1. Пусть $I_m \rightarrow \infty$, $1 \leq m \leq n$. Для того чтобы все тайлы были однотипными, необходимо и достаточно, чтобы матрица $H^{-1}R$ была целочисленной, т.е. чтобы все диагональные элементы r_m матрицы r делились соответственно на

$$\Delta_m = \frac{|H|}{\text{НОД}(|H|, A_{m1}, A_{m2}, \dots, A_{mn})}, \quad 1 \leq m \leq n.$$

Действительно, пусть j' , j'' — два тайла, $v' = v^{\min} + H^{-1}(Rj' - \alpha)$, $v'' = v^{\min} + H^{-1}(Rj'' - \alpha)$ — две точки, являющиеся точками пересечения гиперплоскостей с одинаковыми номерами, определяемыми одним и тем же вектором α . Из равенства $v'' - v' = H^{-1}R(j'' - j')$ следует, что тайл j'' можно получить из тайла j' параллельным переносом тайла j' на вектор $H^{-1}R(j'' - j')$. Следовательно, координаты вектора $H^{-1}R(j'' - j')$ должны принимать целочисленные значения. В свою очередь целочисленность координат вектора $H^{-1}R(j'' - j')$ при условии неограниченности областей вычислений эквивалентна целочисленности элементов матрицы $H^{-1}R$.

Утверждение 2[1]. Для того чтобы между тайлами отсутствовали обратные связи, необходимо и достаточно выполнения условия

$$H\varphi \geq 0, \quad \varphi \in \Phi. \quad (6)$$

Условие (6) эквивалентно тому, что проекции векторов зависимостей на прямые с направляющими векторами h_m , $1 \leq m \leq n$, либо нулевые, либо одинаково направлены.

Способ разбиения на супервершины (их форма, размеры) и способ отображения множества супервершин на параллельную архитектуру определяют эффективность реализации алгоритма. Кроме того, на эффективность реализации влияет и то, в каком объеме при разбиении учитываются характеристики суперкомпьютера, такие как производительность процессоров, время инициализации каналов связи и их пропускная способность.

Перспективность тайлинга повлекла за собой ряд исследований в целях разработки методов построения оптимальных разбиений. Результатом этих исследований стал ряд методов оптимизации тайлинга [1–9]. Отличия этих методов состоят в определении критериев оптимальности: в какой степени при разбиении учитываются особенности алгоритма, характеристики вычислительной системы, а также, как решается задача отображения тайлов на множество вычислительных узлов параллельного компьютера. Недостаток методов заключается в том, что они не в полной мере, а некоторые из них вообще не учитывают характеристики целевой вычислительной системы. Исключение составляют методы, представленные в [8, 9]. Однако они пригодны только тогда, когда множество векторов зависит от алгоритма и множество нормальных векторов гиперплоскостей, осуществляющих разбиение на тайлы, состоит только из координатных векторов e_m , $1 \leq m \leq n$ (n -мерные векторы, у которых m -я координата равна единице, а остальные нулевые).

2. АЛГОРИТМ РЕШЕНИЯ ПЕРВОЙ КРАЕВОЙ ЗАДАЧИ ДЛЯ МНОГОМЕРНОГО УРАВНЕНИЯ ТЕПЛОПРОВОДНОСТИ

Последовательный алгоритм вида (2) решения задачи (1), основанный на использовании явной разностной схемы, можно записать в следующем виде:

$$\begin{aligned}
 & \text{for } i_1 = 1 \text{ to } I_1 \text{ do} \\
 & \quad \text{for } i_2 = 1 \text{ to } I_2 \text{ do} \\
 & \quad \quad \dots \\
 & \quad \quad \text{for } i_n = 1 \text{ to } I_n \text{ do} \\
 & \quad \quad \quad y(i_1, i_2, \dots, i_n) = \left(1 - 2 \sum_{m=2}^n \frac{\tau_1}{\tau_m^2} \right) y(i_1 - 1, i_2, \dots, i_n) + \\
 & \quad \quad \quad + \sum_{k=2}^n \frac{\tau_1}{\tau_m^2} (y(i_1 - 1, i_2, \dots, i_{k-1}, i_k - 1, i_{k+1}, \dots, i_n) + \\
 & \quad \quad \quad + y(i_1 - 1, i_2, \dots, i_{k-1}, i_k + 1, i_{k+1}, \dots, i_n)). \tag{7}
 \end{aligned}$$

Областью вычислений V для данного алгоритма есть подмножество точек пространства \mathbf{Z}^n , определяемое как $V = \{v(i_1, i_2, \dots, i_n) \in \mathbf{Z}^n \mid 1 \leq i_m \leq I_m, 1 \leq m \leq n\}$. Множество $\Phi = \{\varphi_1, \varphi_k^+, \varphi_k^- \mid \varphi_1 = e_1, \varphi_k^+ = e_1 + e_k, \varphi_k^- = e_1 - e_k, 2 \leq k \leq n\}$ отражает информационные зависимости между операциями алгоритма.

3. ОЦЕНКА ВЫЧИСЛИТЕЛЬНОГО И КОММУНИКАЦИОННОГО ОБЪЕМОВ ПРИ $n = 2$

Рассмотрим вариант разбиения на тайлы, определяемый матрицей $H_1 = \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix}$.

Очевидно, что для этого варианта тайлинга условие (6) выполняется и имеют место следующие равенства:

$$\begin{aligned}
 v^{\min} &= (1, 1)^T, \quad J = \left(\left[\frac{I_1}{r_1} \right], \left[\frac{I_1 + I_2 - 1}{r_2} \right] \right)^T, \\
 j &= \left(\left[1 + \frac{i_1 - 1}{r_1} \right], \left[1 + \frac{i_1 + i_2 - 2}{r_2} \right] \right)^T, \quad \alpha = \left(r_1 - r_1 \left\{ \frac{i_1 - 1}{r_1} \right\}, r_2 - r_2 \left\{ \frac{i_1 + i_2 - 2}{r_2} \right\} \right)^T.
 \end{aligned}$$

Множество векторов $\alpha = (\alpha_1, \alpha_2)^T$, $\alpha_m = 1, 2, \dots, r_m$, $m = 1, 2$, обозначим $\Lambda(R)$, а количество различных векторов во множестве $\Lambda(R)$ запишем $|\Lambda(R)|$.

Требование однотипности не накладывает никаких ограничений на параметры r_1, r_2 , кроме их целочисленности, так как $\Delta_1 = 1$ и $\Delta_2 = 1$.

Тайлы можно рассматривать как новые укрупненные зерна вычислений (макрооперации), а множество всех тайлов, обозначим его U , — как область вычислений алгоритма (7) на уровне макроопераций.

Информационная зависимость между тайлами $j, j + \beta \in U$ определяется наличием точек $v \in V$ и $v + \varphi \in V$, вектора зависимости $\varphi \in \Phi$, таких что $v \in j$, $v + \varphi \in j + \beta$. Множество всех векторов $\beta = (\beta_1, \beta_2, \dots, \beta_n)$ — это множество векторов зависимостей алгоритма на уровне тайлов, обозначим его B .

Множество всех точек $v \in j$, для каждой из которых существуют точки $v + \varphi \in j + \beta$, обозначим $V_{j, \beta}$. Множество векторов $\varphi \in \Phi$, определяющих информационную зависимость между тайлами j и $j + \beta$, запишем Φ_β .

Пусть $v = v^{\min} + H^{-1}(Rj - \alpha^1)$, $v + \varphi = v^{\min} + H^{-1}(R(j + \beta) - \alpha^2)$, $\alpha^1, \alpha^2 \in \Lambda(R)$. Тогда $\Phi_\beta = \{\varphi \in \Phi \mid H\varphi = R\beta + \alpha^1 - \alpha^2, \alpha^1, \alpha^2 \in \Lambda(R)\}$. Другими словами, вектор $\varphi \in \Phi$ принадлежит множеству Φ_β , если существуют векторы $\alpha^1, \alpha^2 \in \Lambda(R)$, удовлетворяющие равенству $H\varphi = R\beta + \alpha^1 - \alpha^2$. Если для всех $\varphi \in \Phi$ при фиксированном β таких векторов $\alpha^1, \alpha^2 \in \Lambda(R)$ не существует, то множество Φ_β пусто и тайлы j и $j + \beta$ информационно независимы. Заметим, что множество Φ_β будет пустым, если вектор β имеет хотя бы одну отрицательную координату. Действительно, пусть m -я координата β_m вектора β отрицательна. Тогда из определения множества Φ_β следует $h_m \cdot \varphi = \alpha_m^1 - \alpha_m^2 + \beta_m r_m \leq r_m - 1 + \beta_m r_m < 0$, что противоречит условию (6).

Определение 2. Два тайла: $j, j + \beta$ будем называть соседними по направлению ненулевого вектора $\beta \in \mathbb{Z}^n$, если координаты вектора β равны 0 либо 1, а $\max_{\varphi \in \Phi_\beta} h_m \cdot \varphi \leq r_m - 1$, $1 \leq m \leq n$.

Определим коммуникационный объем данных, передаваемых от тайла j к соседнему тайлу $j + \beta$, как $T_{\text{comm}}^\beta = a + b|V_{j, \beta}|$. Здесь a — время инициализации канала связи, b — время, необходимое на непосредственную передачу единицы данных, $|V_{j, \beta}|$ — количество точек $v \in j$ в множестве $V_{j, \beta}$, или, что то же самое, количество различных векторов $\alpha^1 \in \Lambda(R)$, для которых существуют соответствующие векторы $\alpha^2 \in \Lambda(R)$, удовлетворяющие всем равенствам

$$H\varphi = R\beta + \alpha^1 - \alpha^2, \varphi \in \Phi_\beta. \quad (8)$$

Утверждение 3. Пусть $n = 2$, $H = H_1$ и $r_1 \geq 2$, $r_2 \geq 3$. Тогда вычислительный объем тайла равен $T_{\text{comp}} = t_0 |\Lambda(R)| = t_0 r_1 r_2$, множество B имеет вид $B = \{\beta^1 = (0, 1), \beta^2 = (1, 0), \beta^3 = (1, 1)\}$, а коммуникационные объемы тайла равны соответственно $T_{\text{comm}}^{\beta^1} = a + 2b(r_1 - 1)$, $T_{\text{comm}}^{\beta^2} = a + br_2$, $T_{\text{comm}}^{\beta^3} = a + 2b$, где множества векторов, определяющих информационную зависимость между соседними тайлами j и $j + \beta^k$, $k = 1, 2, 3$, имеют вид $\Phi_{\beta^1} = \{\varphi_1, \varphi_2^+\}$, $\Phi_{\beta^2} = \{\varphi_1, \varphi_2^-, \varphi_2^+\}$, $\Phi_{\beta^3} = \{\varphi_1, \varphi_2^+\}$.

Покоординатно равенства (8) запишем $h_m \cdot \varphi = \alpha_m^1 - \alpha_m^2 + \beta_m r_m$, $\varphi \in \Phi_{\beta^k}$, $k = 1, 2, 3$, причем $h_m \cdot \varphi \in \{0, 1, 2\}$, $m = 1, 2$. Но равенство $r_m + \alpha_m^1 - \alpha_m^2 = 0$ невозможно ни при каком выборе векторов $\alpha^1, \alpha^2 \in \Lambda(R)$, равенство $r_m + \alpha_m^1 - \alpha_m^2 = 1$ имеет место, только если $\alpha_m^1 = 1, \alpha_m^2 = r_m$, а равенство $r_m + \alpha_m^1 - \alpha_m^2 = 2$ возможно, только если $\alpha_m^1 = 1, \alpha_m^2 = r_m - 1$, либо $\alpha_m^1 = 2, \alpha_m^2 = r_m$, $m = 1, 2$. Это позволяет определить

множество различных пар векторов $\alpha^1, \alpha^2 \in \Lambda(R)$, удовлетворяющих (покоординатно) всем равенствам (8), и, следовательно, определить значение $|V_{j,\beta}|$.

Поскольку множество векторов $\Lambda(R)$ имеет вид $\Lambda(R) = \{\alpha \in \mathbb{Z}^2 \mid 1 \leq \alpha_m \leq r_m, m=1,2\}$, то $|\Lambda(R)| = r_1 r_2$. Вектор φ_1 принадлежит множеству Φ_{β^1} , так как имеется $r_1 - 1$ пар векторов $\alpha^1, \alpha^2 \in \Lambda(R)$, $\alpha^1 = (k, 1)$, $\alpha^2 = (k-1, r_2)$, $k = 2, 3, \dots, r_1$, удовлетворяющих равенствам $\alpha_1^1 - \alpha_1^2 = 1$, $r_2 + \alpha_2^1 - \alpha_2^2 = 1$. Аналогично $\varphi_1 \in \Phi_{\beta^2}$, так как имеется $r_2 - 1$ пар векторов $\alpha^1, \alpha^2 \in \Lambda(R)$, $\alpha^1 = (1, k)$, $\alpha^2 = (r_1, k-1)$, $k = 2, 3, \dots, r_2$, удовлетворяющих равенствам $\alpha_2^1 - \alpha_2^2 = 1$, $r_1 + \alpha_1^1 - \alpha_1^2 = 1$. Вектор φ_1 принадлежит также множеству Φ_{β^3} , поскольку имеется одна пара векторов $\alpha^1, \alpha^2 \in \Lambda(R)$, $\alpha^1 = (1, 1)$, $\alpha^2 = (r_1, r_2)$, удовлетворяющих равенствам $r_1 + \alpha_1^1 - \alpha_1^2 = 1$, $r_2 + \alpha_2^1 - \alpha_2^2 = 1$.

Аналогично определяется, что вектор φ_2^- принадлежит множеству Φ_{β^2} , а вектор φ_2^+ — всем множествам Φ_{β^k} , $k = 1, 2, 3$.

В приведенном утверждении не учтена особенность граничных тайлов. Это оправдано, если размеры области V достаточно велики и влиянием граничных тайлов можно пренебречь.

4. ОЦЕНКА ВЫЧИСЛИТЕЛЬНОГО И КОММУНИКАЦИОННОГО ОБЪЕМОВ ПРИ $n \geq 3$

Пусть $n = 3$. В качестве матрицы H рассмотрим матрицу $H_2 = \begin{pmatrix} 1 & 1 & 1 \\ 1 & -1 & 1 \\ 1 & -1 & -1 \end{pmatrix}$.

Условие однотипности тайлов эквивалентно требованию четности всех диагональных элементов матрицы R , так как $|H_3| = 4$, $\Delta_m = 2$, $1 \leq m \leq 3$.

Утверждение 4. Пусть I_2 — четное число, а I_3 — нечетное. Тогда вычислительный объем тайла равен $T_{\text{comp}} = t_0 \frac{r_1 r_2 r_3}{4}$; множество B состоит из векторов $\beta^1 = (0, 0, 1)$, $\beta^2 = (0, 1, 0)$, $\beta^3 = (0, 1, 1)$, $\beta^4 = (1, 0, 0)$, $\beta^5 = (1, 1, 0)$; коммуникационный объем тайла равен $T_{\text{comm}}^{\beta} = a + b|V_{j,\beta}|$, где $\beta = \beta^k$, $1 \leq k \leq 5$, $|V_{j,\beta^1}| = r_1 r_2 / 2$, $|V_{j,\beta^2}| = r_1 r_3 / 2 - 2$, $|V_{j,\beta^3}| = r_1$, $|V_{j,\beta^4}| = r_2 r_3 / 2$, $|V_{j,\beta^5}| = r_3$.

Доказательство проводится аналогично предыдущему с учетом того, что если I_2 — четное число, а I_3 — нечетное, то структура множества векторов $\Lambda(R)$ имеет вид $\Lambda(R) = \{(2k_1, 2k_2 - 1, 2k_3 - 1), (2k_1 - 1, 2k_2, 2k_3), 1 \leq k_m \leq r_m / 2, m = 1, 2, 3\}$, а информационная зависимость соседних по направлениям β^k , $1 \leq k \leq 5$, тайлов определяется соответствующими множествами векторов $\Phi_{\beta^1} = \{\varphi_1, \varphi_2^-, \varphi_3^-\}$, $\Phi_{\beta^2} = \{\varphi_1, \varphi_2^-, \varphi_3^+\}$, $\Phi_{\beta^3} = \{\varphi_1, \varphi_2^-\}$, $\Phi_{\beta^4} = \{\varphi_1, \varphi_2^+, \varphi_3^+\}$, $\Phi_{\beta^5} = \{\varphi_3^+\}$.

Пусть $n \geq 3$. В качестве матрицы H рассмотрим матрицу

$$H_3 = \begin{pmatrix} 1 & 1 & \cdots & 1 & 1 \\ 1 & 1 & \cdots & 1 & -1 \\ 1 & 1 & \cdots & -1 & 1 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 1 & -1 & \cdots & 1 & 1 \end{pmatrix}.$$

Тогда $|H_3| = (-1)^{\frac{n(n-1)}{2}} 2^{n-1}$. Условие однотипности тайлов эквивалентно требованию четности всех диагональных элементов матрицы R . Вычислительный объем тайла равен $T_{\text{comp}} = t_0 \frac{1}{2^{n-1}} \prod_{m=1}^n r_m$. При определении коммуникационных объемов тайла учитывается структура множества $\Lambda(R)$, которая зависит также от четности параметров I_m , $2 \leq m \leq n$. В частности, если в алгоритме (2) все параметры I_m , $2 \leq m \leq n$, — нечетные числа, то

$$\Lambda(R) = \{(2k_1, 2k_2, \dots, 2k_n), (2k_1 - 1, 2k_2 - 1, \dots, 2k_n - 1), 1 \leq k_m \leq r_m / 2, 1 \leq m \leq n\},$$

если все параметры I_m , $2 \leq m \leq n$, — четные числа, то

$$\Lambda(R) = \{(2k_1 - 1, 2k_2, \dots, 2k_n), (2k_1, 2k_2 - 1, \dots, 2k_n - 1), 1 \leq k_m \leq r_m / 2, 1 \leq m \leq n\}.$$

Аналогично определяются все допустимые векторы, удовлетворяющие равенствам (8), так как все равенства (8) имеют вид $h_m \cdot \varphi = \alpha_m^1 - \alpha_m^2 + \beta_m^k r_m$, $\varphi \in \Phi_{\beta^k}$, $\beta^k \in B$, причем $h_m \cdot \varphi \in \{0, 1, 2\}$, $1 \leq m \leq n$.

5. АППРОКСИМАЦИЯ МНОЖЕСТВА ТАЙЛОВ

Для построения оценки полного времени реализации алгоритма необходимо явно определить множество тайлов.

Пусть $D = \frac{1}{|H|} \text{diag}(d_1, d_2, \dots, d_n)$, $d_k = \text{НОД}(A_{1k}r_1, A_{2k}r_2, \dots, A_{nk}r_n)$, $1 \leq k \leq n$.

Введем в рассмотрение векторы

$$C^+ = D^{-1} H_+^{-1} R 1_n + \lfloor D^{-1} (H_+^{-1} H_+ (I - 1_n) + H_-^{-1} 1_n) \rfloor$$

и

$$C^- = D^{-1} H_-^{-1} R 1_n - \lfloor D^{-1} (H_-^{-1} H_- (I - 1_n) - H_+^{-1} 1_n) \rfloor.$$

Утверждение 5. Пусть разбиение на тайлы определяется матрицей H . Тогда множество тайлов ограничено n -мерным многогранником

$$\bar{U} = \{j \in Z^n \mid C^- \leq D^{-1} H^{-1} R j \leq C^+, 1_n \leq j \leq J\}. \quad (9)$$

Доказательство следует из оценок

$$\begin{aligned} H^{-1} R j &= H_+^{-1} R j + H_-^{-1} R j = H_+^{-1} R (1_n + \lfloor R^{-1} (H_+ (v - 1_n) + H_- (v - I)) \rfloor) + \\ &\quad + H_-^{-1} R (\lceil R^{-1} (H_+ (v - 1_n) + H_- (v - I) + 1_n) \rceil) \leq \\ &\leq H_+^{-1} R (1_n + R^{-1} (H_+ (v - 1_n) + H_- (v - I))) + \\ &\quad + H_-^{-1} R (R^{-1} (H_+ (v - 1_n) + H_- (v - I) + 1_n)) = \\ &= H_+^{-1} R 1_n + H_-^{-1} 1_n + v - H^{-1} H_+ 1_n - H^{-1} H_- I \leq \\ &\leq H_+^{-1} R 1_n + H_-^{-1} 1_n + H^{-1} H_+ (I - 1_n), \end{aligned}$$

$$\begin{aligned} H^{-1} R j &= H_+^{-1} R j + H_-^{-1} R j = H_+^{-1} R \lceil R^{-1} (H_+ (v - 1_n) + H_- (v - I) + 1_n) \rceil + \\ &\quad + H_-^{-1} R (1_n + \lfloor R^{-1} (H_+ (v - 1_n) + H_- (v - I)) \rfloor) \geq \\ &\geq H_+^{-1} (H_+ (v - 1_n) + H_- (v - I) + 1_n) + H_-^{-1} R 1_n + H_-^{-1} (H_+ (v - 1_n) + H_- (v - I)) = \\ &= H_-^{-1} R 1_n + H_+^{-1} 1_n + v - H^{-1} H_+ 1_n - H^{-1} H_- I \geq \\ &\geq H_1^{-1} R 1_n + H_+^{-1} 1_n - H^{-1} H_- (I - 1_n). \end{aligned}$$

6. ОТОБРАЖЕНИЕ НА КОЛЬЦО ПРОЦЕССОРОВ

Применим LPGS-стратегию пространственно-временного отображения полученного алгоритма на кольцо процессоров, состоящее из заданного числа P вычислительных узлов (процессорных элементов) [8]. Оценим время решения задачи сверху функцией, зависящей явным образом от параметров компьютера, размеров сетки узлов в алгоритме и от чисел r_m , $1 \leq m \leq n$, характеризующих размеры тайла.

Пусть $n = 2$, J_2 кратно P и r_2 кратно η_1 . Применяя LPGS-стратегию отображения в соответствии с методикой, описанной в [8], получаем, что полное время решения задачи не превосходит значения T :

$$T(P, t_0, a, b, I_1, I_2, r_1, r_2) = \\ = t(j^{\max}) = \tau_2(J_2 - 1) + \tau_1 \left(\frac{r_2}{\eta_1} (J_2 - 1) + l - 1 \right) + (\Gamma - 1) \max \left\{ 0, \tau_1 \left(l - \frac{r_2}{\eta_1} P \right) - \tau_2 P \right\},$$

где $\bar{\tau} = (\max(T_{\text{comp}}, T_{\text{comm}}), T_{\text{comp}} + T_{\text{comm}})$, $l = 1 + \frac{r_2}{\eta_1} + \left\lfloor \frac{I_2 - 2}{r_1} \right\rfloor$, $\Gamma = J_2 / P$, $T_{\text{comm}} = T_{\text{comm}}^{\beta^1} + T_{\text{comm}}^{\beta^3}$.

При построении оценки $T(P, t_0, a, b, I_1, I_2, r_1, r_2)$ учтена возможность совмещения процесса передачи с процессом выполнения операций тайлов, отображенных на один и тот же вычислительный узел. Время передачи данных между тайлами, отображенными на один узел, принято равным 0, так как физически данные остаются в памяти процессорного элемента.

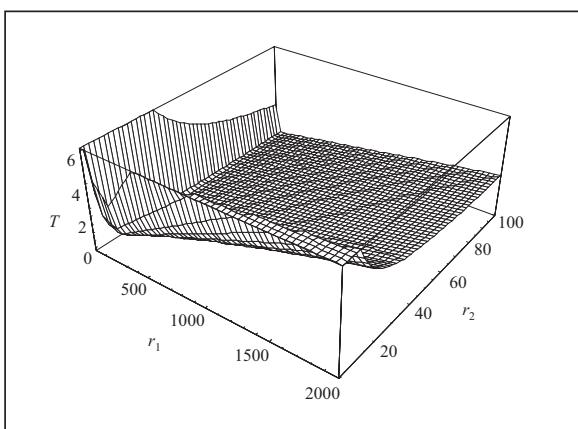


Рис. 1

В случае $n = 3$ применение LPGS-стратегии отображения по методике [8] позволяет оценить время решения задачи функцией

$$T(P, t_0, a, b, I_1, I_2, I_3, r_1, r_2, r_3) = \\ = \tau_2(J_2 - 1) + \tau_3(J_3 - 1) + (\Gamma - 1) \max \left\{ 0, \tau_1 \left(l I_3 + \frac{r_2}{\eta_1} (J_2 - 1) \right) - \tau_2 P \right\},$$

где

$$\tau_1 = \max \left(t_0 \frac{\eta_1 r_2 r_3}{4}, a + b \left(\frac{\eta_1 r_2}{2} - 2 \right) \right), \quad \tau_2 = t_0 \frac{\eta_1 r_2 r_3}{4} + a + b \left(\frac{\eta_1 r_2}{2} - 2 \right), \quad \tau_3 = l \tau_1,$$

$$J_2 = \lceil (I_1 + I_2 + I_3 - 2) / r_2 \rceil, \quad J_3 = \lceil (I_1 + I_2 + I_3 - 2) / r_3 \rceil, \quad \Gamma = J_2 / P,$$

$$l = 2 + \frac{r_2}{\eta_1} + 2 \left\lfloor \frac{I_2 - 2}{r_1} \right\rfloor.$$

Минимизация функции $T(P, t_0, a, b, I_1, I_2, I_3, r_1, r_2, r_3)$ позволяет получить алгоритм с наилучшим временем реализации на заданном кольце процессоров. В частности если принять значения параметров $P = 10$, $t_0 = 10^{-9}$ с, $a = 10^{-6}$ с, $b = 10^{-8}$ с, $I_1 = 2 \cdot 10^6$ и $I_2 = 10^3$, то оптимальные значения функции T достигаются при $r_1 = r_2 = 56$ и равно 0,207 с. На рис. 1 изображена поверхность значений функции T в зависимости от параметров тайла η_1 и r_2 .

СПИСОК ЛИТЕРАТУРЫ

1. Ramanujam J., Sadayappaan P. Tiling of iteration spaces for multicomputers // Proc. of Int. Conf. on Parallel Proces. — 1990. — 2. — P. 179–186.
2. Boulet P., Darte A., Risset T., Robert Y. (Pen)-ultimate tiling? // Integration, The VLSI J. — 1994. — 17. — P. 33–51.
3. Xue J. Communication-minimal tiling of uniform dependence loops // J. of Parallel and Distributed Comput. — 1997. — 1, N 42. — P. 42–59.
4. Schreiber R., Dongarra J. Automatic blocking of nested loops // Tech. rep. 90.38, RIACS. 1997.
5. Ohta H., Saito Y., Kainaga M., Ono H. Optimal tile size adjustment in compiling general DOACROSS loop nests // Proc. of Int. Conf. on Supercomput. ACM Press, 1995. — P. 270–279.
6. Hodzic E., Shang W. On supernode transformation with minimized total running time // IEEE Trans. Parallel and Distributed Systems. — 1998. — 9, N 5. — P. 417–428.
7. Hodzic E., Shang W. On-time optimal supernode shape // IEEE Trans. Parallel and Distributed Systems. — 2002. — 13, N 10. — P. 1220–1223.
8. Баханович С.В., Соболевский П.И. Отображение алгоритмов на вычислительные системы с распределенной памятью: оптимизация тайлинга для одно- и двумерных топологий // Весці НАН Беларусі. Сер. фіз.-мат. науک. — 2006. — № 2. — С. 106–112.
9. Баханович С.В., Соболевский П.И. Оптимизация тайлинга при LSGP стратегии отображения алгоритмов на суперкомпьютеры с распределенной памятью // Там же — 2007. — № 3. — С. 113–118.

Поступила 24.07.2008