

Л. Д. АДАМЕНКО, Є. С. ШОХ

ВАЖЛИВА ОСОБЛИВІСТЬ ВИКОНАННЯ АРИФМЕТИЧНИХ ОПЕРАЦІЙ У РЕЖИМІ ПЛАВАЮЧОЇ КОМИ НА МАШИНАХ ТИПУ «УРАЛ» (З ФІКСОВАНОЮ КОМОЮ)

Машина з фіксованою комою типу «Урал» працюють з числами, абсолютні величини яких менші одиниці. Тому при підготовці задачі для розв'язування на машині всі початкові дані масштабуються так, щоб проміжні і кінцеві результати обчислень були по абсолютній величині меншими одиниці. Але в практиці зустрічаються такі задачі, для яких масштабування є надзвичайно важким завданням, а в деяких випадках і зовсім неможливим.

Для розв'язування таких задач числовий матеріал перетворюють у нормальну форму (нормалізують), тобто приводять до вигляду:

$$a = q_a \cdot 10^{P_a},$$

де $\frac{1}{2} \leq |q_a| < 1$ — мантиса,

P_a — порядок числа a .

Арифметичні операції над числами в нормальній формі виконуються за такими алгоритмами:

1. Множення:

$$c = a \cdot b = q_a \cdot 10^{P_a} \cdot q_b \cdot 10^{P_b} = q_a \cdot q_b \cdot 10^{P_a + P_b} = q_c \cdot 10^{P_c},$$

де $\frac{1}{2} \leq |q_c| < 1$; $P_c = P_a + P_b + \delta$;

δ — поправка до порядку від нормалізації $q_a \cdot q_b$.

2. Додавання (віднімання):

$$\begin{aligned} c = a + b &= q_a \cdot 10^{P_a} + q_b \cdot 10^{P_b} = (q_a \cdot 10^{P_a - P'} + q_b \cdot 10^{P_b - P'}) \cdot 10^{P'} = \\ &= q_c \cdot 10^{P' + \delta} = q_c \cdot 10^{P_c}, \end{aligned}$$

де $P' = \max \{P_a, P_b\}$,

δ — поправка до порядку від нормалізації $q_a \cdot 10^{P_a - P'} + q_b \cdot 10^{P_b - P'}$.

3. Ділення:

$$c = \frac{a}{b} = \frac{q_a \cdot 10^{P_a}}{q_b \cdot 10^{P_b}} = \frac{q_a}{q_b} \cdot 10^{P_a - P_b} = q_c \cdot 10^{P_c},$$

де $P_c = P_a - P_b + \delta$,

δ — поправка до порядку від нормалізації $\frac{q_a}{q_b}$.

Кожне число, приведенне до нормальної форми, записується в оперативній пам'яті (НМБ) в дві ячейки: одна ячейка (повна) — для мантиси числа, друга (неповна) — для порядку. Всі арифметичні операції над такими числами виконуються за вказаними вище алгоритмами окремо з порядками і окремо з мантисами.

Множення найпростіше реалізувати такою послідовністю команд:

$$k + 1 \ 02 < q_a >$$

$$k + 2 \ 06 < q_b >$$

$$k + 3 \ 15 < q_c >$$

$$k + 4 \ 01 < P_a >$$

$$k + 5 \ 01 < P_b >$$

$$k + 6 \ 16 < P_c >$$

але якщо q_a або q_b рівне нулю, то і $q_c = 0$, в той час як P_c може бути, взагалі кажучи, відмінним від нуля.

Через це в обчисленнях, де є багато множень і серед початкових даних є нулі, нулі в кінцевих результатах фактично будуть мати нульові мантиси і, як правило, відмінні від нуля порядки (можуть бути навіть досить великими по модулю).

Те ж буде, якщо при діленні чисельник — нуль.

Якщо ж до такого нуля з порядком додавати якесь інше число, у якого порядок менший, ніж порядок нуля, результат може бути зовсім невірним.

Дійсно, нехай

$$a = 0 \cdot 10^{P_a}, \quad b = q_b \cdot 10^{P_b}$$

і нехай

$$P_a \gg P_b.$$

$$\text{Тоді } a + b = 0 \cdot 10^{P_a} + q_b \cdot 10^{P_b} = (0 + q_b \cdot 10^{P_b - P_a}) \cdot 10^{P_a} = q_c \cdot 10^{P_c}.$$

Якщо $|\Delta P| = |P_a - P_b| < 35$ (35 — кількість розрядів суматора «УРАЛ»-а), то

$$P_c = P_a - \Delta P = P_b,$$

$$q_c = q'_b,$$

де q'_b мантиса, у якої $|\Delta P|$ молодших розрядів будуть нулями, а 35- $|\Delta P|$ старших розрядів співпадатимуть з відповідними розрядами q_b .

Якщо $|\Delta P| = |P_a - P_b| \geq 35$, то $P_c = P_a$, $q_c = 0$.

Коротше кажучи, коли проходить додавання якогось числа до нуля, відбувається непотрібний зсув мантиси з меншим порядком вправо на $|\Delta P|$ розрядів, додавання і потім нормалізація, внаслідок чого втрачається точність або одержується зовсім невірний результат.

Це стає очевидним, якщо прослідкувати роботу рекомендованих програм додавання в режимі плаваючої коми.

Програма наведена в книзі В. Н. Бондаренко і ін. «Программирование для цифровой вычислительной машины „Урал“»:

$$k + 1 \ 02 < P_a > \quad k + 3 \ 21 \ k + 15$$

$$k + 2 \ 03 < P_b > \quad k + 4 \ 10 < - >$$

$k + 5 \ 17 \ <0,5>$	$k + 16 \ 11 \ 0000$
$k + 6 \ 11 \ 0000$	$k + 17 \ 06 \ <q_a>$
$k + 7 \ 06 \ <q_b>$	$k + 20 \ 17 \ <0,5>$
$k + 10 \ 17 \ <0,5>$	$k + 21 \ 05 \ <q_b>$
$k + 11 \ 05 \ <q_a>$	$k + 22 \ 15 \ <q_c>$
$k + 12 \ 15 \ <q_c>$	$k + 23 \ 01 \ <P_b>$
$k + 13 \ 01 \ <P_a>$	$k + 24 \ 01 \ <1 \cdot 2^{-17}>$
$k + 14 \ 22 \ k + 24$	$k + 25 \ 16 \ <P_c>$
$k + 15 \ 17 \ <0,5>$	

Програма з арифметичним зсувом:

$k + 1 \ 02 \ <P_a>$	$k + 11 \ 01 \ <P_a>$
$k + 2 \ 03 \ <P_b>$	$k + 12 \ 22 \ k + 20$
$k + 3 \ 21 \ k + 13$	$k + 13 \ 17 \ <q_a>$
$k + 4 \ 10 \ <->$	$k + 14 \ 11 \ 4000$
$k + 5 \ 17 \ <q_b>$	$k + 15 \ 01 \ <q_b>$
$k + 6 \ 11 \ 4000$	$k + 16 \ 15 \ <q_c>$
$k + 7 \ 01 \ <q_a>$	$k + 17 \ 01 \ <P_b>$
$k + 10 \ 15 \ <q_c>$	$k + 20 \ 16 \ <P_c>$

З метою уникнути такого неприємного явища при додаванні з нулем, що, як правило, матиме якийсь порядок, необхідно обов'язково аналізувати мантиси на нуль, і, якщо один з доданків має нульову мантису, за результат приймати другий доданок з його порядком. Якщо обидва доданки нулі, то, очевидно, за результат можна приймати будь-який з них.

З таким аналізом програма додавання матиме такий вигляд:
без арифметичного зсуву

$k + 1 \ 02 \ <q_a>$	$k + 12 \ 10 \ <->$
$k + 2 \ 15 \ 0000$	$k + 13 \ 17 \ <0,5>$
$k + 3 \ 21 \ k + 26$	$k + 14 \ 11 \ 0000$
$k + 4 \ 02 \ <q_b>$	$k + 15 \ 06 \ <q_b>$
$k + 5 \ 15 \ 0000$	$k + 16 \ 17 \ <0,5>$
$k + 6 \ 21 \ k + 16$	$k + 17 \ 05 \ <q_a>$
$k + 7 \ 02 \ <P_a>$	$k + 20 \ 15 \ <q_c>$
$k + 10 \ 03 \ <P_b>$	$k + 21 \ 01 \ <P_a>$
$k + 11 \ 21 \ k + 23$	$k + 22 \ 22 \ k + 32$

$k + 23 \ 17 \langle 0,5 \rangle$	$k + 30 \ 15 \langle q_c \rangle$
$k + 24 \ 11 \ 0000$	$k + 31 \ 01 \langle P_b \rangle$
$k + 25 \ 06 \langle q_a \rangle$	$k + 32 \ 01 \langle 1 \cdot 2^{-17} \rangle$
$k + 26 \ 17 \langle 0,5 \rangle$	$k + 33 \ 16 \langle P_c \rangle$
$k + 27 \ 05 \langle q_b \rangle$	

з використанням арифметичного зсуву

$k + 1 \ 02 \langle q_a \rangle$	$k + 14 \ 11 \ 4 \ 000$
$k + 2 \ 15 \ 0000$	$k + 15 \ 01 \langle q_a \rangle$
$k + 3 \ 21 \ k + 23$	$k + 16 \ 15 \langle q_c \rangle$
$k + 4 \ 02 \langle q_b \rangle$	$k + 17 \ 01 \langle P_a \rangle$
$k + 5 \ 15 \ 0000$	$k + 20 \ 22 \ k + 26$
$k + 6 \ 21 \ k + 15$	$k + 21 \ 17 \langle q_a \rangle$
$k + 7 \ 02 \langle P_a \rangle$	$k + 22 \ 11 \ 4 \ 000$
$k + 10 \ 03 \langle P_b \rangle$	$k + 23 \ 01 \langle q_b \rangle$
$k + 11 \ 21 \ k + 21$	$k + 24 \ 15 \langle q_c \rangle$
$k + 12 \ 10 \langle - \rangle$	$k + 25 \ 01 \langle P_b \rangle$
$k + 13 \ 17 \langle q_b \rangle$	$k + 26 \ 16 \langle P_c \rangle$

Розглянемо один з випадків, де зустрічається описана особливість додавання чисел в режимі плаваючої коми.

При розв'язуванні багатьох задач фізики і механіки, при розв'язуванні диференціальних і інтегральних рівнянь виникає потреба в знаходженні розв'язків лінійних систем алгебраїчних рівнянь. Нехай

$$AX = B,$$

де A — відома квадратна матриця порядку n ,

B — відома прямокутна матриця розміром $n \times m$,

X — стовбцева матриця невідомих.

Одним з ефективних і точних методів розв'язування систем алгебраїчних рівнянь на ЦАМ є метод перехресного множення. Перетворення будуться за формулами:

$$a_{ik}^t = \frac{a_{11}^{t-1} \cdot a_{i+1, k+1}^{t-1} - a_{1, k+1}^{t-1} \cdot a_{i+1, 1}^{t-1}}{a_{11}^{t-1}}, \quad (1)$$

$$a_{nk}^t = \frac{a_{1, k+1}^{t-1}}{a_{11}^{t-1}}. \quad (2)$$

При $t = n$, $a_{i1}^t = x_i$;

$i = 1, 2, \dots, n-1$

$t = 1, k = 1, 2, \dots, n$;

$t = 2, k = 1, 2, \dots, n-1$;

$\dots$

$t = n, k = 1.$

Вищевказана особливість виконання арифметичних операцій з плаваючою комою з найбільшою силою проявляється саме при розв'язуванні систем алгебраїчних рівнянь цим методом. Прямим наслідком цієї особливості є точність результатів, тобто розв'язків системи.

Матриця A може мати довільний характер, зокрема серед елементів a_{ij} матриці може бути багато нулів. Тоді багато з доданків у чисельнику формули (1) при перетвореннях можуть бути рівними нулю з великим додатним порядком і в результаті додавання результат буде невірний. В деяких випадках програма даного методу дає результати, але з невеликою точністю, якщо ж багато коефіцієнтів системи є нулями, то програма взагалі дає корені з нульовими мантисами і великими додатними порядками.

При використанні програм додавання з попередньою перевіркою мантис на нуль відносна похибка розв'язків не перевищує 0,000 001% (7—9 вірних знаків).

ЛІТЕРАТУРА

1. А. И. Китов и Н. А. Крицкий. Электронные цифровые машины и программирование. М., 1959.
2. Е. Л. Ющенко. Адресное программирование и особенности решения задач на машине «УРАЛ». К., 1960.
3. В. Н. Бондаренко и др. Программирование для цифровой вычислительной машины «УРАЛ». М., 1958.

Стаття надійшла 20. IX 1960.