

IBM 3090 VF に適した数値計算法

日本アイ・ビー・エム(株)

寒川 光 (Hikaru Samukawa)

1. はじめに

IBM 3090 ベクトル機構 (VF: Vector Facility) は 1985 年に発表されたベクトル計算機である¹。3090 VF の命令体系はシステム 370 XA を基礎としたものでベクトル・アーキテクチャーと呼ばれる²。このアーキテクチャーの特長はシステム 370 XA と融和性が高く、31 ビット・アドレスの仮想記憶方式 (VS 方式) を採用している。また、16 個のベクトル・レジスタを定義しているが、その長さはアーキテクチャー上はパラメーター (VSS: Vector Section Size) として扱われる。その他、メモリー上のベクトルを汎用レジスタを介して直接使用する (入力として) 3 オペランド形式のベクトル演算命令や、乗加算や内積のように 2 つの浮動小数点演算を 1 つの命令で行う複合演算命令などに特長がある。

以上はアーキテクチャー上の特長であるが、ハードウェア

のインプリメンテーション上の特長を次に記す。VFは3090の各CPUに付加機構として装備可能であり、ベクトル計算に用いられる命令やデータは緩衝記憶制御機構内のキャッシュ・メモリーを経由して供給される。キャッシュ容量は3090のEモデルでは64KBである。ベクトルレジスター長は128で、ベクトル命令の実行はオーバーラップせず逐次的に行われる。




図1. 3090-200E型 構成要素

ベクトル計算機の性能を十分に引き出すためには、ハードウェアの性格にあわせたプログラミングが要求されるが、これを追求するとプログラムの明解さや

互換性などのプログラムの一般性を損なう場合が少なくない。将来の計算機はさらに複雑なベクトル命令や並列処理の機能を備え、より個性的になることが予想される。したがって性能とプログラムの一般性という相反する要求を満たすための工夫を考察することは重要である。本稿では線型代数演算を

例に階層型プログラミングを紹介する。この手法は行列とベクトルの積を求めるような単純なサブルーチンをローレベルの階層とし、この部分でハードウェアの個性をできるだけ吸収する方法である。ハイレベルのルーチンはこれらを順次コールする形に作っておけば、システム側の多様化をローレベルのサブルーチンを修正したり入れ換えることで対応可能であり、アプリケーション・アルゴリズムへの影響をくい止めることができる。

2. プログラムの文脈と性能

3090 VF はベクトル・レジスタを備えた VS 方式のベクトル計算機であるが、その特長を活かしたプログラミングを紹介する。

2.1 2重ループ

1重ループの例を示す(図2)。ベクトル計算ではループが




図2. ベクトル・スカラー積と内積

ネストすると、ベクトル・ロード/ストア命令を最内側ループから外して性能向上を計ることができる。\$m\$ 行 \$n\$ 列の行列とベクトルの乗算を例にあげる。generic form で記した下線

$$Y = Y + A \cdot x$$


$$\begin{bmatrix} \text{do } \underline{\quad} = 1, \underline{\quad} \\ \quad \text{do } \underline{\quad} = 1, \underline{\quad} \\ \quad \quad Y_i = Y_i + a_{ij} * x_j \end{bmatrix}$$

部のループ添字に \$i, j\$ の順でプログラミングするか、\$j, i\$ の順にするかの2つの方法を考える。図3に両者の処理を示す。

この例の添字 \$j\$ のように右辺に存在して左辺に存在しない添字を本稿ではダミー添字と呼ぶことにする。ベクトル計算でダミー添字が最内側ループの添字に使われるとベクトル演算は内積となり、内側から2番目のループの添字に使われると“2 Vector Operations and 1 Vector-memory Reference”型のベクトル・スカラー積になる。これは図3では VM&A 命令の2つの浮動小数点演算と1回のメモリー参照 (\$a_{ij}\$) を指す。


\$ij\$ 型

$$\begin{bmatrix} \text{do } i = 1, m \\ \quad \text{do } j = 1, n \\ \quad \quad Y_i = Y_i + a_{ij} * x_j \end{bmatrix}$$



\$ji\$ 型

$$\begin{bmatrix} \text{do } j = 1, n \\ \quad \text{do } i = 1, m \\ \quad \quad Y_i = Y_i + a_{ij} * x_j \end{bmatrix}$$



(セグメント・グループ)
 Vload VR, \$Y_i\$
 LD FR, \$x_j\$
 VM&A VR, FR, \$a_{ij}\$
 Branch
 Vstore VR, \$Y_i\$
 Branch

白キ…参照のみ
 黒…書き込み

図3. 行列ベクトル積

スカラー計算ではダミー添字を最内側に選ぶと浮動小数点レジスターへ演算結果を足し込めるため、命令数を節約できるが、ベクトル計算では最内側の添字はベクトル化されるため、内側から2番目に配置することによってベクトルレジスターに足し込みが行える。階層型プログラムを考えると、ベクトル計算とスカラー計算の違いはここに現われる。すなわちスカラー計算では2重ループ演算は1重ループ・サブルーチンをコールするかたちに構成しても大きな性能差は生じないが、ベクトル計算で同じ構成をとると“2 Vect. Op. 1 Vect. Ref”による性能を享受できない。このため2重ループ・サブルーチンを単独のサブルーチンとして用意する必要がある。

2.2 3重ループ

行列の積 $C_{ij} = C_{ij} + \sum_{k=1}^m a_{ik} \cdot b_{kj}$ を generic form で記す³。添字 i, j, k に関する

$\begin{cases} \text{do } _ = 1, _ \\ \quad \begin{cases} \text{do } _ = 1, _ \\ \quad \begin{cases} \text{do } _ = 1, _ \\ \qquad C_{ij} = C_{ij} + a_{ik} * b_{kj} \end{cases} \end{cases} \end{cases}$
 $(A: l \times m, B: m \times n, C: l \times n)$

ループ選択は $3! = 6$ 通り存在する(図4)。この中では行列ベクトル積と同じ

“2 Vect. Op. 1 Vect. Ref.”型で、かつメモリー上のベクトルを連続的に参照する jki 型の性能が最も高い。

IBM 3090 のようにキャッシュを備えた計算機では、メモリー参照されるベクトル・データ (a_{ik}) がキャッシュ内に存在し

た時の方が（メモリーからキャッシュ経由で参照される時よりも）命令実行時間が短い。3重ループの文脈ではこの特徴をも考慮して、2重ループの性能（MFLOPS性能値比較）を浚ぐことができる。具体的には、 jki 型の k のループ回数を、演算に必要なデータがキャッシュに収まりきる範囲でいったん中断し、先に j を進める計算順序をとる（図5）。




図4. 行列積の6つのループ選択





図5. キャッシュ容量を意識した行列積

2.3 メモリー階層と階層型プログラミング

階層型メモリー構造をもったベクトル計算機ではループのネストが深くなるに従って計算性能を高めることができる。


・ 1 重ループ

$$\left[\begin{array}{l} \text{do } i=1, n \\ Y_i = Y_i + \alpha * X_i \end{array} \right. \quad \left[\begin{array}{l} V\text{load} \dots\dots ① \\ VM\&A \dots\dots ② \\ V\text{store} \dots\dots ③ \end{array} \right.$$




・ 2 重ループ

$$\left[\begin{array}{l} \text{do} \\ \text{do } i=1, n \\ Y_i = Y_i + x_j * a_{ij} \end{array} \right. \quad \left[VM\&A \quad VR, FR, a_{ij} \right.$$



・ 3 重ループ

$$\left[\begin{array}{l} \text{do} \\ \text{do} \\ \text{do } i=1, n \\ C_{ij} = C_{ij} + b_{kj} * a_{ik} \end{array} \right. \quad \left[\begin{array}{l} VM\&A \quad VR, FR, a_{ik} \\ \text{in cache} \end{array} \right.$$



最内側ループが FORTRAN ステートメントとしては同じベクトルスカラー積を表現していても、1重ループでは3つのベクトル命令が用いられ、2重ループでは1つに減らせる。3重ループではオペランドをキャッシュにキープすることが可能になる。こうしたシステム側の特性を数値計算アルゴリズムの表面にあらわにすることは、プログラムの一般性の観点からは好ましくない。行列積を例に、システム側の特性を覆い隠したプログラムの例を示す。

Subroutine DMPYAD (A,LDA,B,LDB,C,LDC,L,M,N)
 double precision A(LDA,M), B(LDB,N), C(LDC,N)
 common /SYSTEM/ LVS,NCACHE

【... $C = C + A * B$ 】

$NZ = \text{MIN}(LVS, L)$

$NX = NCACHE / NZ$

$NII = (L-1) / NZ + 1$

$NJJ = (M-1) / NX + 1$

do ii = 1, NII

i = (ii-1)*NZ + 1

NZL = MIN(L-i+1, NZ)

do jj = 1, NJJ

j = (jj-1)*NX + 1


NXM = MIN(M-j+1, NX)

call DMULAD (A(i,j), LDA, B(j,1), LDB,
 C(i,1), LDC, NZL, NXM, N)

enddo 【... $C' = C' + A' * B'$ 】

enddo

return



COMMON/SYSTEM/ にベクトル・レジスタ長 (LVS) と適切なキャッシュ容量 (NCACHE) などのシステム依存パラメータを持つ。また、サブルーチン DMULAD は $C' = C' + A' * B'$ を計算するが、行列 A' のサイズは $NZL \times NXM$ であり、 NZL はベクトル・レジスタ長よりも小さいため、セクショニング・ループを無視した2重ループ・サブルーチンである。^{【注】} ループ選択順序やキャッシュ容量を意識した計算順序は図5に示したようにかなり複雑なものであるが、プログラムを階層化する

ことによって小行列の積和という単純なアルゴリズムにまひめることができる。また、ベクトルレジスター長やキャッシュ容量の異なる機種に対しても、SYSTEM コモンの初期化で対応することができるし、スカラー計算の環境では、ローレベルサブルーチン DMULAD をスカラー用にチューニングしたものに置き換えることで対応することができる。(キャッシュ容量を意識することは、スカラー計算の環境下でも性能向上につながる。) このようにプログラムをよりプリミティブな機能のサブルーチンに分解し、アーキテクチャーやハードウェアに依存する差異をローレベルサブルーチンのなかで解決してしまうことが、性能とプログラムの一般性の両立のためには実用的な方法である。より複雑な演算では、さらにこの行列積を使用するようにプログラムを構築してゆく。

【注】

最もローレベルのサブルーチン DMULAD のループ部分の概略は右のように構成される。キャッシュ容量を意識したこの方法と通常の ikj 型の性能差は、3090 の E モデルでは各行列を次数 1000 の正方形列とした場合約 20% 程度である。

— Vload	VR, c_{ij}
[LD	FR, b_{kj}
VM&A	VR, FR, a_{ik}
Branch	 ($k=1, N \times M$)
Vstore	VR, c_{ij}
Branch	 ($j=1, N$)

(ベクトル命令は
 $i = 1, NZL (\leq VSS)$
 について行う)

3. 連立1次方程式の直接解法

密行列を係数行列とした連立1次方程式を三角分解(LU分解)によって解く問題を考える。行列積の問題と同じように、まずループの構成を考え、次にキャッシュ容量を意識した方法を考える。

三角分解は通常もとの正方行列 A を2つの三角行列の積に変換する。

$$A = LU$$

行列 L は対角項を1にした下三角行列、 U は上三角行列である。一般に L と U を計算するアルゴリズムは始めに A が書かれていた領域に書き込まれてゆく。すなわち、配列 A に正方行列を与えられると、配列 A の上三角行列の部分に U を、下三角行列の対角項を除いた部分に L の対角項よりも下の部分を生成する。

3.1 ループの選択 (6通りのループ選択)

三角分解のアルゴリズムを generic form で記す³。ただし、枢軸(ピボット)選択はここでは省略した。generic form は

$$\left[\begin{array}{l} \text{do } _ = _, _ \\ \quad \text{do } _ = _, _ \\ \quad \quad \text{do } _ = _, _ \\ \quad \quad \quad a_{ij} = a_{ij} - (a_{ik} * a_{kj}) / a_{kk} \end{array} \right. \quad \left(\begin{array}{l} \text{添字の1例} \\ k = 1, n-1 \\ j = k+1, n \\ i = k+1, n \end{array} \right)$$

行列積に類似しているが、ループ添字の動く範囲が外側のループ添字で記されるため、はるかに複雑である。この3重ループに対する6通りの選択を図6に示す。ダミー添字 k をまん中に選んでもベクトル・レジスターに足し込みを行う。“2 Vect.Op. 1 Vect.Ref.”型の命令は生成されない。これは更新されるベクトルが

2重ループの文脈のなかで変化するからである

(最内側ループの添字 i/j の動く範囲がひとつ外側のループ添字 k で記述されている)。


一般にこのような文脈に

ループ・アンローリングを施こして、ベクトル演算に対するメモ


リ参照の回数

k が最外側

i) kji 型



ii) kij 型




$$A^{(k)} \leftarrow P_k \cdot A^{(k-1)}$$


(P_k は基本相似変換行列)

k がまん中

iii) jki 型




iv) ikj 型




k (ダミー添字)がまん中なのでベクトルを更新する。

k が最内側

v) jik 型



vi) ijk 型



k が最内側なので内積ループになる

図6. 三角分解のループ選択

を減らすことができる。

3.2 ループの選択（6通り以外の方法）


6通りのループ選択のなかで、 jki 型の後半（下三角行列の要素を計算する部分）と ijk 型の後半（上三角行列の要素を計算する部分）は、“2 Vect.Op. 1 Vect.Ref.”型でメモリー参照も連続的になっている。両者の利点を合わせてループを構成してみる。図7にこの方法（ $ijk \cdot jki$ 型）の処理を図示

```

do ij = 1, n
  i = ij
  do j = i, n
    do k = 1, i-1
       $a_{ij} = a_{ij} - a_{ik} * a_{kj}$ 
    j = ij
    do i = j+1, n
       $a_{ij} = a_{ij} / a_{jj}$ 
    do k = 1, j-1
      do i = j+1, n
         $a_{ij} = a_{ij} - a_{ik} * a_{kj}$ 

```

ijk 型



jki 型




図7. $ijk \cdot jki$ 型

した。ここでは最内側ループの添字の動く範囲は2つ外側のループ添字で記述されているため、長方形行列を対象に計算を進めることができる。

$ijk \cdot jki$ 型はループ・アンローリングを施した jki 型に匹敵した性能を示す。しかも内側の2重ループは「連続する内

積」(あるいは「転置行列とベクトルの積差」と「行列とベクトルの積差」という単純なアルゴリズムのサブルーチンにより処理することができるので、プログラムの一般性を保ちやすい。これはループ・アンローリング法がプログラムを冗長かつ複雑にすることと比べると大きな利点といえる。

3.3 キャッシュ容量の考慮

$ijk \cdot jki$ 型の処理を r ステップ実行した状態では、配列 A の右下 $(n-r) \times (n-r)$ の小行列は最初の状態のままで残っており、他の小行列は最終結果の三角行列の小行列になっている(右図)。ここで行列の積差

$U_{r,r}$	$U_{r,n-r}$
$L_{r,r}$	
$L_{n-r,r}$	$A_{n-r,n-r}$

$$A'_{n-r,n-r} = A_{n-r,n-r} - L_{n-r,r} * U_{r,n-r}$$

を計算すると、三角分解の問題を次数 $n-r$ の問題に縮小することができる⁴。この処理を繰返して順次問題を縮小し、最終的な三角行列 L と U を求めることができる。(各ブロック・ステップの前半は $ijk \cdot jki$ 型のプログラムを一部修正して利用することができ、また後半では行列積のサブルーチンを利用することができる。)

$$A'_{n-r,n-r} = L_{n-r,n-r} U_{n-r,n-r}$$

Subroutine DIJKIC (A, LDA, N, IPTV)
 double precision A(LDA, N)
 integer IPTV(N) [A $\Rightarrow$ L·U]
 common /SYSTEM/

⋮

MR = r


do M = 1, MSTEP

J1 = (M-1)*MR + 1

J2 = MIN(N, J1+MR-1)


call DIJKIT (A, LDA, N, IPTV, J1, J2)

[J1~J2 行を三角分解する]



call DMPYSB (A(J2+1, J1), LDA, A(J1, J2+1), LDA,
 A(J2+1, J2+1), LDA, N-J2, J2-J1+1,
 N-J2)

[A = A - L·U を計算する]



enddo
 return

(DMPYSBは2.3節のDMPYADに対応するサブルーチン)

図8. キャッシュ容量を意識した三角分解

この方法は行列 A をあらかじめ複数の小行列に分割してファイル上に置き、入出力を伴ないつつ消去を行う分割消去法（ブロック消去法）に類似する。しかしここでは、行列 A をメモリー（仮想記憶域）に置いているため、ファイル上でのフォーマットに制約されない自由なブロッキング・サイズをとることができる。事実、各ブロック・ステップの後半で行なう行列の積差演算（DMPYSB）では、他の部分とは独立に小行列のサイズを選択することができる。

現実のプログラミングでは、性能に大きな影響を与えるためハードウェアを意識せざるをえないルーチンを *machine dependent routines* としてあらかじめインターフェースを定義し、アルゴリズムの表面にまでこうした要素（ベクトル計算かスカラー計算、ベクトル・レジスター長、キャッシュ容量、プロセッサの数など）が顔を出すのを抑えるべきである。3090 VF は VS方式のベクトル計算機 であるため、データ（行列 A ）を単一のアドレス空間に保持できる。したがって、階層化されたプログラムによって性能とプログラムの一般性の両立を実現しやすい計算機である。

3.4 性能の比較

図9に相対的な性能比を示す。行列の次数 1000 までについて、 jki 型, $ijk \cdot jki$ 型, DIJKIC (キャッシュ容量を考慮

した方法)の3者を比較した。 jki 型と $ijk\cdot jki$ 型の差はループ構成の差(“2 Vect. Op. 1 Vect. Ref.”型と“2 Vect. Op. 3 Vect. Ref”型の差)によるものである。DIJKICはキャッシュ容量を考慮した演算部分(行列の積差を計算する部分)の比率が、行列の次数が大きくなるに従って高くなるため、 $ijk\cdot jki$ 型との差が開いてくる。




図9. 相対性能比

4. おわりに

技術計算の計算能力に対する需要増大をサポートするためには、ハードウェアのからくりはベクトル計算、並列計算をとりこんでますます複雑化してゆく傾向にある。FORTRAN はアセンブラーを透視して性能を意識したコーディングをする余地を残した言語である。また、サブルーチン・コールやコモソンの利用による融通性も備えている。本稿ではこれらの特質をうまく使うことにより、アルゴリズムのエレガンスを保ちつつ性能を追求し、さらに将来のハードウェアのインプリメンテーション変化にもわずかな調整で対応する方法を考えてみた。この手法の実現には、システム（アーキテクチャ、ハードウェア）に依存する部分を単純な機能に絞り込み将来の変化による影響をこの部分におしとどめることが、実用的な方法のひとつである。

【参考文献】

1. Gibson, D.H. , Rain, D.W. and Walsh, H.F. , "Engineering and scientific processing on the IBM 3090" , IBM Systems Journal , Vol.25, No.1 , 1986
2. " IBM System/370 Vector Operations" , SA22-7125 , 1986

3. Dongarra, J.J. , Gustavson, F.G. and Karp, A. ,
"Implementing Linear Algebra Algorithms for
Dense Matrices on a Vector Pipeline Machine",
SIAM Review , Vol.26, No.1 , Jan., 1984
4. Wilkinson, J.H. , "The Algebraic Eigenvalue
Problem" , Clarendon Press , Oxford , 1965