Анализ и оптимизация на софтуерни приложения

Александър Пенев

Васил Василев

Векторизация

Съдържание

Какво е векторизация?

- Векторизация (vectorization) е процес на преобразуване на програма изпълняваща една операция за всеки такт от време (в една нишка) към програма изпълняваща няколко операции едновременно в един такт (в една нишка)
- Векторизацията е частен случай на паралелизацията
- Обикновено се използват SIMD инструкциите на съвременните процесори
  (MMX, SSE, AVX, AltiVec, NEON, ...)

Как се прилага

- Ръчно
- Ръчно с използване на intrinsic функции
- Автоматично от компилатора
  Обикновено компилатора трябва да бъде „подпомогнат“ от нас
- Автоматично от процесора
  Като част от скаларните и супер-скаларните архитектури

Пример 1

```
for (i = 0; i < 1024; i++)
  C[i] = A[i] + B[i];
```

Векторизация на цикли

```
for (i = 0; i < 1024; i+=4)
  (C[i], C[i+1], C[i+2], C[i+3]) =
    (A[i], A[i+1], A[i+2], A[i+3]) +
    (B[i], B[i+1], B[i+2], B[i+3]);
```

псевдокод

Частично развиване на цикъл.
Може ли границите на цикъла да не са кратни на 4?

Пример 2

```
for (i = 0; i < MAX; i++)
{
  C[i].x = A[i].x + B[i].x;
  C[i].y = A[i].y + B[i].y;
  C[i].z = A[i].z + B[i].z;
}
```

Векторизация в блок

```
for (i = 0; i < MAX; i++)
{
  (C[i].x, C[i].y, C[i].z) =
      (A[i].x, A[i].y, A[i].z) +
      (B[i].x, B[i].y, B[i].z);
}
```

псевдокод

Ако дължината на вектора е 4, то в примера има проблем с непълното използване на SIMD възможностите

Пример 3

```
for (i = 0; i < 1024; i++)
{
  if (A[i] > 0)
    C[i] = B[i];
  else
    D[i] = D[i-1];
}
```

Векторизация на разклонени алгоритми

```
for (i = 0; i < 1024; i++)
{
  P = A[i] > 0;
  NP = !P;
  C[i] = B[i];    (P)    // изпълнява се само ако P е истина
  D[i] = D[i-1]; (NP)    // изпълнява се само ако NP е истина
}
```

псевдокод

```
for (i = 0; i < 1024; i+=4) {
  vP = (A[i], A[i+1], A[i+2], A[i+3]) > (0, 0, 0, 0);
  vNP = !vP;  // векторно т.е. покомпонентно отрицание
  (C[i], C[i+1], C[i+2], C[i+3]) =
    vsel(vP, (B[i], B[i+1], B[i+2], B[i+3]), (C[i], C[i+1], C[i+2], C[i+3]));
  if (vNP[4]) D[i+3] = D[i+2];  if (vNP[3]) D[i+2] = D[i+1];
  if (vNP[2]) D[i+1] = D[i];    if (vNP[1]) D[i] = D[i-1];
}
```

псевдокод

Пример 3 – Векторна ф-я vsel(P, A, B)

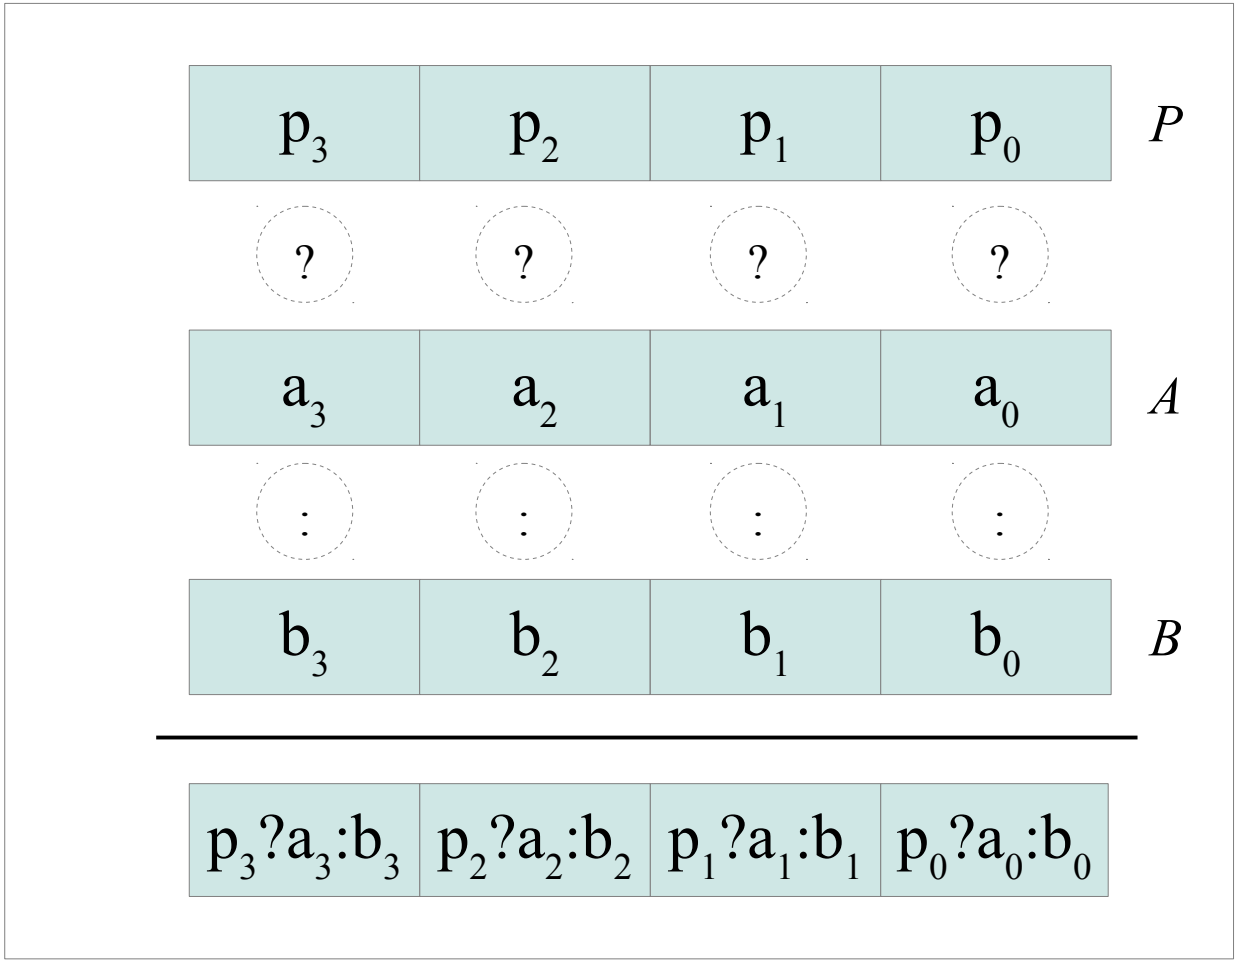

Векторизация на цикли – общ случай

Всеки цикъл се развива до определено ниво (зависи от границите т.е. дали са известни по време на компилация и колко са големи).

Циклите се разделят на 4 части (или по-малко):

- Пред цикъл
  Операции независими от цикъла (инварианти). Обикновено се зареждат (инвариантни) данни във векторни регистри и други
- Цикъл (Цикли)
  Векторизирани вариант(и) на цикъла (циклите)
- След цикъл
  Получаване на резултати и допълнителна инварианта обработка Индукции, редукции и други
- Опашка на цикъл
  Реализация на невекторизиран вариант на цикъла за оставащите итерации, които по някакви причини не са попаднали в основния цикъл (например броя итерации не е кратен на големината на векторите или размера се определя в runtime)

Не всичко може да се векторизира

```
for (i = 0; i < 3; i++)
{
  C[i] = A[i] + B[i];
}
```

OK.
Цикълът може да бъде развит и/или векторизиран напълно

```
for (i = 0; i < 1024; i++)
{
  C[i] = A[i] + B[i];
}
```

OK.
Цикълът може да бъде векторизиран

```
for (i = 0; i < 1024; i++)
{
  D[i] = E[i] - A[i-1];
  A[i] = B[i] + C[i];
}
```

Не може!
Използва се стойност преди да бъде пресметната

Масив от структури или няколко масива?

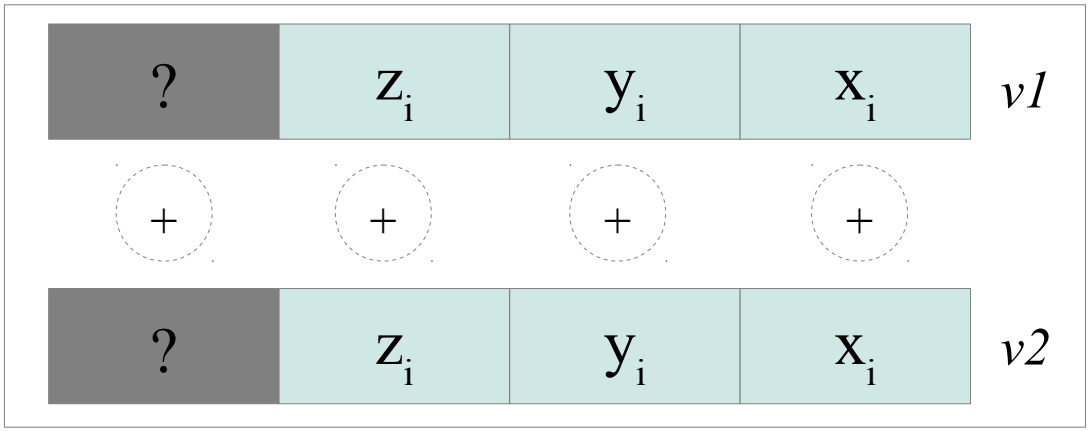


```
struct { float x, y, z; } vec;

vec[100] v1, v2;

for (i = 0; i < 100; i++) {
  v1[i].x += v2[i].x;
  v1[i].y += v2[i].y;
  v1[i].z += v2[i].z;
}
```

ИЛИ

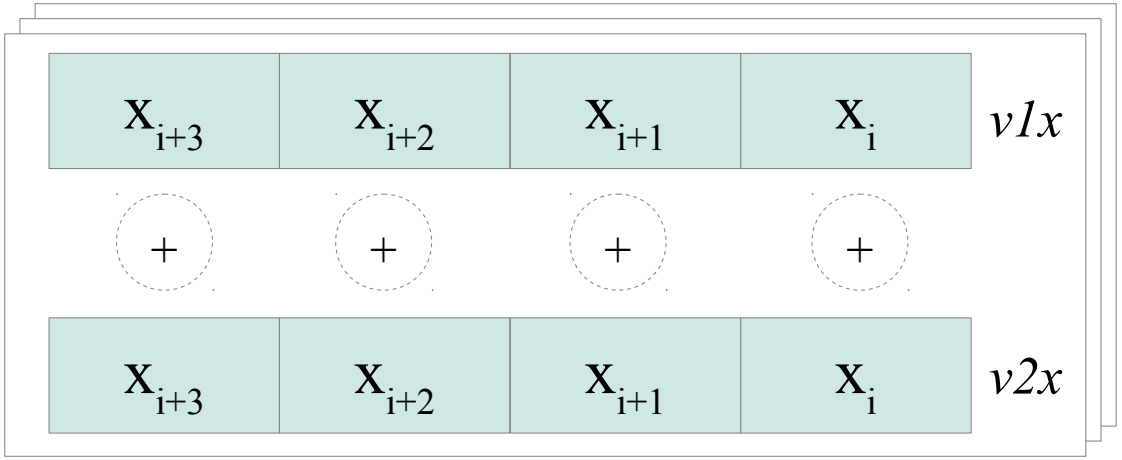


```
float[100] v1x, v2x;
float[100] v1y, v2y;
float[100] v1z, v2z;

for (i = 0; i < 100; i++)
  v1x[i] += v2x[i];
for (i = 0; i < 100; i++)
  v1y[i] += v2y[i];
for (i = 0; i < 100; i++)
  v1z[i] += v2z[i];
```

Типове данни

- Ако типа е еднакъв

  Например 4 float числа се събират точно в един SSE регистър

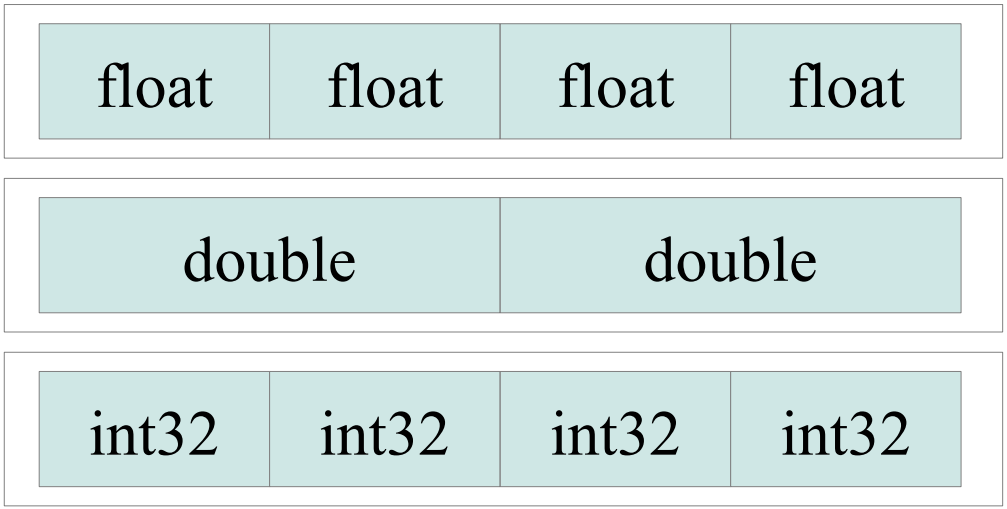

- Ако типовете са различни

  Имаме загуба на производителност. Трябва да се внимава с Align на структурите
  За някои типове може да се налага разширяване до по-голям тип (float->double)