

Examen Novembre 2013 - Architectures Avancées

3H – Tous documents autorisés

OPTIMISATION DE BOUCLES

On utilise le processeur superscalaire défini dans l'annexe 1

Soit la boucle suivante :

<pre>float X[1024], Y[512]; for (i=0 ; i<512 ; i++) Y[i] = X[i+512] - X[i] ;</pre>	<pre>Boucle : LF F1,0(R1) LF F2,2048(R1) FSUB F1,F1,F2 SF F1,0(R1) ADDI R1,R1,4 ADDI R2,R2,4 ADDI R3,R3,-1 BNE R3,Boucle</pre>
---	--

On supposera que l'adresse de X[0] est initialement dans R1, que l'adresse de Y[0] est initialement dans R2. R3 contient initialement le nombre d'itérations de la boucle.

Question 1 : Quel est en nombre de cycles, le temps d'exécution par itération de la boucle originale sans et avec utilisation des instructions SIMD ?

Question 2

Donner par itération de la boucle initiale

- le nombre de cycles sans instructions SIMD avec un déroulage d'ordre 4
- le nombre de cycles avec instructions SIMD avec un déroulage d'ordre 4

Question 3 : Pour la boucle ci-dessous, quelle est la condition pour pouvoir utiliser les instructions SIMD ?

```
float X[2*N], Y[N];
for (i=0 ; i<N ; i++)
    Y[i] = X[i+N] - X[i] ;
```

PREDICTEURS DE BRANCHEMENT

Soit les branchements 1 à 4 qui ont le comportement suivant sur 8 itérations (P pour pris et N pour non pris)

Itération	1	2	3	4	5	6	7	8
Branch 1	N	P	P	N	N	P	P	N
Branch 2	P	P	P	P	P	N	N	N
Branch 3	P	N	N	P	P	P	P	N
Branch 4	P	P	P	P	P	P	P	N

On dispose des prédicteurs suivants :

- statique toujours pris
- dynamique local 1 bit (initialisé à pris)
- dynamique local 2 bits (initialisé à fortement pris)

Question 4) Quel est pour chaque branchement pris individuellement le meilleur prédicteur ? Quel est globalement le meilleur prédicteur pour les 4 branchements ?

CACHES

Un processeur utilise un cache de données de 64 Ko, avec des lignes de 64 octets, à correspondance directe. Le cache utilise la réécriture avec écriture allouée (il y a des défauts de cache en écriture). Le processeur a des adresses sur 32 bits.

On considère l'extrait de programme C suivant, pour lequel les tableaux X et Y sont rangés successivement en mémoire à partir de l'adresse 1000 0000_H (adresse de X[0]).

```
float X[2*N], Y[N];
for (i=0 ; i<N ; i++)
    Y[i] = X[i+N] - X[i] ;
```

Question 5 : Quel est le nombre de défaut de caches par itération quand N = 512

Question 6 : Pour quelle valeur de N (puissance de 2) a-t-on 3 défauts par itérations

PIPELINE LOGICIEL AVEC TMS 320C62

Le code assembleur TMS320C62 ci-dessous donne l'itération du pipeline logiciel pour un programme C.

```
LOOP:
        LDW    .D1    *A4++,A2        ;
||      ADD    .L1    A6,A7,A7        ;
||      ADD    .L2    B6,B7,B7        ;
||[A1]  B      .S2    LOOP            ;
||      MPY    .M1X   A2,A2,A6        ;
||      MPYH   .M2X   A2,A2,B6        ;
||[A1]  SUB    .S1    A1,1,A1        ;   decrement loop counter

        ADD    .L1X   A7,B7,A4        ;
```

Question 7 : Donner le code C correspondant au code assembleur.

Question 8 : Quel est l'intervalle inter-itération (II) ? Justifier la valeur.

SIMD IA-32

Soit le programme P1

```
float X[512], Y[512], A[512];
for (i=0 ; i<512 ; i++)
    A[i] = (X[i] -Y[i])* 0.5f ;
```

Question 9 : En utilisant les intrinsics SIMD fournis en annexe, donner la version SIMD du programme P1. On rappelle que les float sont codés sur 32 bits et que les registres SSE ont une taille de 128 bits.

Question 10 : Donner la suite des instructions pour faire la somme horizontale des 4 floats contenus dans une variable `_m128 X`.

Soit le programme P2

```
float Z[128], X[128], Y[128][128], S;
for (i=0 ; i<128 ; i++){
    S= 0.0f;
    for (j=0; j<128; j++)
        S+= X[j]*Y[i][j] ;
    Z[i]=S ;}
```

Question 11 : En utilisant les intrinsics SIMD fournis en annexe, donner la version SIMD du programme P2.

ACCELERATION PARALLELE

Question 12 : A taille de programme constante, quelle est la fraction séquentielle maximale possible pour obtenir une efficacité parallèle de 60% sur 16 processeurs ?

Annexe 1

Soit un processeur superscalaire à ordonnancement statique qui a les caractéristiques suivantes :

- les instructions sont de longueur fixe (32 bits)
- Il a 32 registres entiers (dont R0=0) de 32 bits et 32 registres flottants (de F0 à F31) de 32 bits.
- Il peut lire et exécuter 4 instructions par cycle.
- L'unité entière contient deux pipelines d'exécution entière sur 32 bits, soit deux additionneurs, deux décaleurs. Tous les bypass possibles sont implantés.
- L'unité flottante contient un pipeline flottant pour l'addition et un pipeline flottant pour la multiplication. - L'unité Load/Store peut exécuter jusqu'à deux chargements par cycle, mais ne peut effectuer qu'un load et un store simultanément. Elle ne peut effectuer qu'un seul store par cycle.
- Il dispose d'un mécanisme de prédiction de branchement qui permet de "brancher" en 1 cycle si la prédiction est correcte. Les sauts et branchements ne sont pas retardés.

La Table 1 donne

- les instructions disponibles
- le pipeline qu'elles utilisent : E0 et E1 sont les deux pipelines entiers, FA est le pipeline flottant de l'addition et FM le pipeline flottant de la multiplication. Les instructions peuvent être exécutées simultanément si elles utilisent chacune un pipeline séparé. L'addition et la multiplication flottante sont pipelinées. La division flottante n'est pas pipelinée (une division ne peut commencer que lorsque la division précédente est terminée).
- L'ordonnancement est statique. Les chargements ne peuvent pas passer devant les rangements en attente.

JEU D'INSTRUCTIONS (extrait)

LF	LF Fi, dép.(Ra)	2	E0 ou E1	$F_i \leftarrow M(Ra + \text{dépl.16 bits avec ES})$
SF	SF Fi, dép.(Ra)		E0	$F_i \rightarrow M(Ra + \text{dépl.16 bits avec ES})$
ADD	ADD Rd,Ra, Rb	1	E0 ou E1	$Rd \leftarrow Ra + Rb$
ADDI	ADDI Rd, Ra, IMM	1	E0 ou E1	$Rd \leftarrow Ra + \text{IMM-16 bits avec ES}$
SUB	SUB Rd,Ra, Rb	1	E0 ou E1	$Rd \leftarrow Ra - Rb$
FADD	FADD Fd, Fa, Fb	3	FA	$Fd \leftarrow Fa + Fb$
FSUB	FSUB Fd, Fa, Fb	3	FA	$Fd \leftarrow Fa - Fb$
FMAX	FMAX Fd, Fa, Fb	3	FA	$Fd \leftarrow \text{Max}(Fa, Fb)$
FMIN	FMIN Fd, Fa, Fb	3	FA	$Fd \leftarrow \text{Min}(Fa, Fb)$
FMUL	FMUL Fd, Fa, Fb	3	FM	$Fd \leftarrow Fa \times Fb$
FDIV	FDIV Fd, Fa, Fb	20	FA	$Fd \leftarrow Fa/Fb$
BEQ	BEQ Ri, dépl	1	E1	si $R_i=0$ alors $CP \leftarrow NCP + \text{depl}$
BNE	BNE Ri, dépl	1	E1	si $R_i \neq 0$ alors $CP \leftarrow NCP + \text{depl}$

Table 1 : instructions disponibles

Le processeur a également 32 registres de 128 bits S0 à S7 pouvant contenir chacun 4 flottants simple précision et les instructions SIMD données dans la Table 2. Cette table donne également les latences des instructions SIMD et le pipeline utilisé dans le cas superscalaire.

PLF	PLF Si, dép.(Ra)	2	E0	Charge quatre flottants simple précision à partir de l'adresse (Ra + dépl.16 bits avec ES).
PSF	PSF Si, dép.(Ra)	2	E0	Range en mémoire à partir de l'adresse (Ra + dépl.16 bits avec ES) quatre flottants simple précision
PFADD	PFADD Sd,Sa, Sb	3	FA	$Sd \leftarrow Sa + Sb$ sur quatre « floats »
PFSUB	PFSUB Sd,Sa, Sb	3	FA	$Sd \leftarrow Sa - Sb$ sur quatre « floats »
PFMUL	PFMUL Sd, Sa, Sb	4	FM	$Sd \leftarrow Sa \times Sb$ sur quatre « floats »
PFMULS	PMULS Sd, Sa, Fb	4	FM	SF $\leftarrow Sa \times Fb$ (chaque élément de Sa est multiplié par Fb et rangé dans l'élément correspondant de SF) sur quatre « floats »
PLB	PLB Si, dép.(Ra)	2	E0	Charge seize octets à partir de l'adresse (Ra + dépl.16 bits avec ES).
PSB	PSB Si, dép.(Ra)	2	E0	Range en mémoire à partir de l'adresse (Ra + dépl.16 bits avec ES) seize octets
PFMAX	PMAX Sd,Sa, Sb	1	FA	$Sd \leftarrow Sa \max Sb$: maximum sur 4 floats
PFMIN	PMIN Sd,Sa, Sb	1	FA	$Sd \leftarrow Sa \min Sb$: minimum sur 4 floats

Table 2 : Instructions SIMD

ANNEXE 2 : Instructions SIMD IA-32 utilisables

ADDPS(a,b)	_mm_add_ps(a,b)	Quatre additions flottantes 32 bits
SUBPS(a,b)	_mm_sub_ps(a,b)	Quatre soustractions flottantes 32 bits
MULPS(a,b)	_mm_mul_ps(a,b)	Quatre multiplications flottantes 32 bits
DIVPS(a,b)	_mm_div_ps(a,b)	Quatre divisions flottantes 32 bits
SET4	_mm_set_ps1(float w)	Quatre fois le flottant 32 bits w dans un mot de 128 bits
HADDPS(a,b)	_mm_hadd_ps(a,b)	$b_3+b_2 b_1+b_0 a_3+a_2 a_1+a_0$
MOVSS(a,b)	_mm_store_ss(*a,b)	$Mem_{32}(a) \leftarrow 32$ bits poids faible de b (sur 128 bits)