

Architettura degli Elaboratori

a.a. 2013/14 - quinto appello, 12 febbraio 2014

Riportare nome, cognome, numero di matricola e corso A/B

Domanda 1

Definire e realizzare una rete sequenziale che calcola il massimo di 256 valori interi non-negativi che costituiscono la sequenza d'ingresso, e valutarne il ciclo di clock. Spiegare come si è ragionato per ottenere la definizione formale della rete.

L'ingresso IN e l'uscita OUT sono sincronizzati con interfacce a transizione di livello. Una volta terminata la sequenza d'ingresso, la rete deve rimanere in uno stato stabile. A parte il valore iniziale, il registro OUT deve contenere solo il risultato finale.

Domanda 2

Un'unità di elaborazione U utilizza una gerarchia di memoria: memoria principale M, cache secondaria C2, cache primaria C1, con C1 e C2 sullo stesso chip di U. La cache a due livelli C1-C2 è su domanda, con blocchi di ampiezza $\sigma_1 = 8$, C1 di capacità 16K e C2 di capacità 1M.

U opera su tre array A, B, C di M interi, con $M = 128 K$:

$$\forall i = 0 .. M - 1: \{ C[i] = 0; \forall j = 0 .. M - 1: C[i] = F(A[i], B[j], C[i]) \}$$

L'array A è allocato staticamente in M all'indirizzo 0. U riceve l'indirizzo di M in cui trovare il nuovo valore dell'array B e l'indirizzo di M in cui scrivere il valore calcolato dell'array C.

Definire l'insieme di lavoro della gerarchia di memoria e valutare la penalità sul tempo di servizio di U dovuta ai fault di cache. I parametri della memoria principale possono essere fissati dallo studente.

Domanda 3

Un'unità di I/O riceve dal dispositivo associato uno stream di parole e le invia, una alla volta, alla CPU usando direttamente il meccanismo delle interruzioni. Il servizio richiesto con l'interruzione è di bufferizzare la parola in una data coda FIFO di 20 posizioni. L'operazione di inserzione in coda è eseguita dallo *handler* dell'interruzione, l'estrazione verrà effettuata da parte di determinati processi.

La coda è una struttura dati con i seguenti campi: indice di inserzione, indice di estrazione, numero di parole attualmente presenti, vettore di 20 posizioni. Handler conosce l'indirizzo logico base di tale struttura, e questo è unico per qualunque processo.

Come di regola, in caso di coda piena la richiesta di servizio di inserzione deve attendere che si svuoti almeno una posizione, ma questo deve avvenire *senza sospendere il processo* che esegue lo handler. Inoltre, nell'operazione di inserzione non deve essere effettuata alcuna azione di scheduling a basso livello nei confronti dei processi estrattori.

- Scrivere il codice del trattamento dell'interruzione, incluso handler.
- Valutare la latenza complessiva dell'operazione di inserzione in coda, a partire dall'istante in cui l'unità di I/O dispone del dato da inviare fino all'istante in cui termina il trattamento dell'interruzione.

La CPU è D-RISC, pipeline, scalare, a singola bufferizzazione, con EU parallela, e cache C1-C2 come nella Domanda 2. Si assume che il PCB del processo in esecuzione e la sua tabella delle interruzioni risiedano in C1, e la struttura dati coda in C2. Qualunque collegamento inter-chip (inclusa la connessione di I/O) va considerato come dedicato con latenza di trasmissione 5τ .

Soluzione

Domanda 1

Definiamo la rete sequenziale $(X, Z, S, \omega, \sigma)$ secondo il modello di Moore, in particolare con lo stato di uscita Z dato dal contenuto del registro OUT (funzione identità delle uscite, ω).

Lo stato interno S è costituito dai contenuti dei registri IN e OUT , del registro MAX destinato a contenere il valore massimo della sequenza, del registro I di 9 bit operante come contatore di passi, e dai quattro indicatori di interfaccia $RDYIN$, $ACKIN$, $RDYOUT$, $ACKOUT$. L'automa ha stato iniziale: MAX , I , OUT e gli indicatori di interfaccia sono inizializzati a zero, e IN è non specificato.

La funzione σ di *transizione dello stato interno* è definita come segue:

- con la sequenza in corso ($I_0 = 0$), il nuovo valore di IN , quando presente ($RDYIN = 1$), viene scritto in MAX a condizione che $segno(MAX - IN) = 1$:

$$in_{MAX} = \text{when clock and } (\bar{I}_0 \text{ RDYIN } segno(MAX - IN)) \text{ do } IN$$

- con la sequenza in corso e un nuovo IN presente, I viene incrementato di uno:

$$in_I = \text{when clock and } (\bar{I}_0 \text{ RDYIN}) \text{ do } I + 1$$

- quando la sequenza è terminata, MAX viene scritto in OUT a condizione che $ACKOUT = 1$:

$$in_{OUT} = \text{when clock and } (I_0 \text{ ACKOUT}) \text{ do } MAX$$

- per gli indicatori di interfaccia:

$$in_{Y_RDYIN} = \text{when clock and } (\bar{I}_0 \text{ RDYIN}) \text{ do } \overline{Y_RDYIN}$$

$$in_{ACKIN} = \text{when clock and } (\bar{I}_0 \text{ RDYIN}) \text{ do } \overline{ACKIN}$$

$$in_{RDYOUT} = \text{when clock and } (I_0 \text{ ACKOUT}) \text{ do } \overline{RDYOUT}$$

$$in_{Y_ACKOUT} = \text{when clock and } (I_0 \text{ ACKOUT}) \text{ do } \overline{Y_ACKOUT}$$

Dalla definizione si ricava immediatamente la realizzazione della rete, facente uso di due ALU e con i valori dei β dei registri ottenuti come uscite di porte AND definite dalla funzione σ di cui sopra. Essendo nullo il ritardo della funzione delle uscite, il ciclo di clock è dato da:

$$\tau = \max(T_\omega, T_\sigma) + \delta = T_\sigma + \delta = T_{ALU} + \delta$$

Esattamente lo stesso risultato si può ottenere progettando la rete sequenziale come unità di elaborazione descritta da un microprogramma di una sola microistruzione:

0. (I_0 , $RDYIN$, $segno(MAX - IN)$, $ACKOUT = 00--$, $1--0$) nop, 0;
 (= 0 1 1 -) reset $RDYIN$, set $ACKIN$, $IN \rightarrow MAX$, $I + 1 \rightarrow I$, 0;
 (= 0 1 0 -) reset $RDYIN$, set $ACKIN$, $I + 1 \rightarrow I$, 0;
 (= 1 -- 1) $MAX \rightarrow OUT$, set $RDYOUT$, reset $ACKOUT$, 0

Con le usuali regole, si deriva la *definizione* delle funzioni ω e σ viste sopra.

Domanda 2

A è allocato staticamente in M ed è in sola lettura: poiché U opera su stream, A è quindi caratterizzato, oltre che da località, da *riuso*. Dati i valori di M , γ_1 e γ_2 , il riuso di A è esplicitabile in $C2$ (dopo l'elaborazione del primo elemento dello stream), ma non in $C1$. Analogamente per il nuovo array B , caratterizzato anche da riuso per la durata dell'elaborazione di un elemento dello stream: dopo la prima

iterazione su i , B viene mantenuto in C2 fino alla ricezione del prossimo elemento dello stream. L'array C è caratterizzato da sola località ed è usato in sola scrittura (non c'è trasferimento di blocchi da M a C2-C1).

L'insieme di lavoro è quindi costituito da tutti i blocchi di A e di B e dal blocco corrente di C.

La penalità sul tempo di servizio dovuta ai fault di cache è data da:

$$T_{fault} = N_{fault-A-C1} T_{trasfC2-C1}(\sigma_1) + N_{fault-B-C2} T_{trasfM-C2}(\sigma_1) + N_{fault-B-C1} T_{trasfC2-C1}(\sigma_1)$$

Si ha:

$$N_{fault-A-C1} = N_{fault-B-C2} = \frac{M}{\sigma_1} \quad N_{fault-B-C1} = \frac{M^2}{\sigma_1}$$

Quindi, grazie gli ordini di grandezza in gioco:

$$T_{fault} \sim \frac{M^2}{\sigma_1} T_{trasfC2-C1}(\sigma_1) = \frac{M^2}{\sigma_1} 2 \sigma_1 \tau = 2 M^2 \tau$$

indipendentemente dalla realizzazione della memoria principale. Il calcolo è sua volta $O(M^2)$.

[L'aspetto dell'eventuale penalità dovuta alle scritture di C in M non è richiesto dall'esercizio. Per completezza:

- se la gerarchia fa uso di write-through, le singole scritture in M sono sovrapposte, almeno parzialmente, al calcolo;
- in caso di write-back, ogni blocco di C viene scritto in M una volta calcolato. Le scritture dei blocchi sono almeno parzialmente sovrapposte al calcolo.

In entrambi i casi, si tratta di valutare l'eventuale penalità partendo dal grado di sovrapposizione.]

Domanda 3

a) Si noti che lo handler è eseguito da qualunque processo che sia in esecuzione all'atto dell'interruzione, non necessariamente il processo che eseguirà anche l'estrazione. Quindi la coda è condivisa: dalle specifiche si deduce come i puntatori condivisi siano gestiti come indirizzi logici coincidenti.

Per rispettare il vincolo sulla corretta bufferizzazione, ogni volta che riempie completamente la coda handler provvede a *disabilitare l'interruzione* corrispondente all'evento in questione (istruzione MASKINT). In altre parole, *questo tipo di interruzione non viene accettata se la coda è piena*. Con l'interruzione disabilitata, l'unità di I/O rimane in attesa di ACKINT, e UNINT conserva il segnale di interruzione; successivamente, quando l'interruzione pendente verrà *riabilitata dall'operazione di estrazione*, il processore (IU) la accetterà e innescherà lo handler per l'inserzione in coda (in questa situazione, è probabile che handler sia eseguito dallo stesso processo che ha effettuato l'estrazione).

Trattamento dell'interruzione, fase assembler:

// la fase firmware ha provveduto a memorizzare il codice-evento (inserzione in coda) in *Revento*, la parola-messaggio in *Rdato*, e l'indirizzo di ritorno in *Rret_int* //

Routine di interfacciamento interruzioni:

1. LOAD Rpcb, Roffset, Rtabella_interruzioni
2. LOAD Rtabella_interruzioni, Revento, Rindirizzo_handler
3. CALL Rindirizzo_handler, Rret_handler
4. GOTO Rret_int

Questa prima parte di codice contiene le dipendenze logiche IU-EU 1-2 e 2-3, entrambe di distanza $k = 1$ con $N_Q = 2$, e due salti ineliminabili (3, 4).

Handler:

// l'indirizzo logico della struttura coda è in *Rbuffer* //

// il test di coda piena viene effettuato dopo l'inserzione //

// codice non ottimizzato //

```

5.  LOAD  Rbuffer, 0, Rins           // indice di inserzione //
6.  ADD   Rbuffer, 3, RQ             // indirizzo base di Q //
7.  STORE RQ, Rins, Rdato           // scrittura in coda //

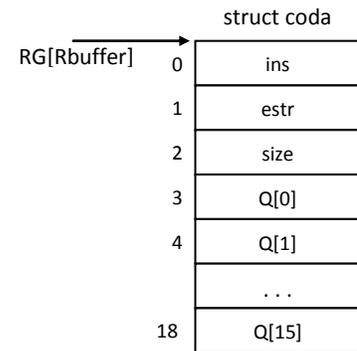
8.  INCR  Rins
9.  MOD   Rins, 20, Rins             // ins = (ins + 1)%20 //
10. STORE Rbuffer, 0, Rins

11. LOAD  Rbuffer, 2, Rsize
12. INCR  Rsize                     // size = size + 1; il valore risultante è sempre ≤ 16 //
13. STORE Rbuffer, 2, Rsize

14. IF <  Rsize, 20, EXIT           // test di coda piena //
15. MASKINT Rmask, Rvalore_maschera // se coda piena, disabilita interruzione //

16. EXIT: GOTO Rret_handler

```



Il codice dello handler contiene le dipendenze logiche IU-EU indicate, tutte con $k = 1$ (6 su 7 con $N_Q = 2$, 9 su 10 con $N_Q = 1$ e $L_{\text{pipe-}k} = 4$, 12 su 13 con $N_Q = 2$) e due salti (14, 16).

b) Nella valutazione supporremo che l'istruzione *MASKINT* non venga eseguita (caso più probabile), per cui, globalmente, si tratta di eseguire 15 istruzioni.

Trattamento dell'interruzione, fase assembler - codice ottimizzato:

```

1.  LOAD  Rpcb, Roffset, Rtabella_interruzioni
2.  LOAD  Rtabella_interruzioni, Revento, Rindirizzo_handler
3.  CALL  Rindirizzo_handler, Rret_handler
4.  GOTO  Rret_int

5.  LOAD  Rbuffer, 0, Rins
6.  ADD   Rbuffer, 2, RQ             // indirizzo_base_vettore_Q - 1 //
7.  INCR  Rins
8.  STORE RQ, Rins, Rdato

```

- 9. MOD Rins, 20, Rins
- 10. LOAD Rbuffer, 2, Rsize
- 11. INCR Rsize
- 12. IF < Rsize, 20, EXIT, delayed_branch
- 13. STORE Rbuffer, 2, Rsize
- 14. MASKINT Rmask, Rvalore_maschera
- 15. EXIT: GOTO Rret_handler, delayed_branch
- 16. STORE Rbuffer, 0, Rins

Non possono essere effettuati spostamenti di codice tra la routine di interfacciamento e lo handler, per cui la cause di degradazione nelle istruzioni 1-4 rimangono.

Nello handler, si è scelto di eliminare la dipendenza logica più pesante (indotta dalla MOD di latenza lunga) e le degradazioni dovute ai due salti. Si può inoltre alleviare la dipendenza indotta sulla STORE RQ. Rimane quella della 11 sulla 12 (la cui bolla contribuisce, comunque, a raggiungere la distanza necessaria per eliminare la dipendenza indotta dalla MOD).

Quindi:

$$\lambda = \frac{2}{15}$$

$$\Delta = \Delta_{1-2}(k=1, N_Q=2) + \Delta_{2-3}(k=1, N_Q=2) + \Delta_{6-8}(k=2, N_Q=2) + \Delta_{11-12}(k=1, N_Q=2)$$

$$= \frac{7}{15} t$$

Il tempo di servizio effettivo per istruzione è:

$$T = (1 + \lambda)t + \Delta = \frac{24}{15} t$$

La latenza della fase assembler del trattamento interruzioni, in assenza di fault di cache, vale dunque:

$$L_{assem-trattint-0} = 15 T = 24 t = 48 \tau$$

La penalità dovuta ai fault si ha a causa del trasferimento da C2 a C1 dei blocchi della struttura dati coda: almeno il primo blocco viene certamente acceduto e, nel caso peggiore (probabile), un altro blocco appartenente al vettore Q.

Quindi valutiamo:

$$N_{fault} = 2$$

$$T_{fault} = N_{fault} 2 \sigma \tau = 32 \tau$$

da cui:

$$L_{assem-trattint} = L_{assem-trattint-0} + T_{fault} = 80 \tau$$

Va poi considerata la latenza della *fase firmware del trattamento interruzioni*:

- da I/O a UNINT: $1\tau + T_{tr}$
- da UNINT a IU e da IU a I/O (ACKINT): $2\tau + T_{tr}$, se l'interruzione è abilitata
- da I/O a DM: $1\tau + T_{tr}$
- da DM a EU (2 parole) e a IU, dove ha luogo la chiamata della routine di interfacciamento: 5τ

Complessivamente:

$$L_{fw-trattint} = 9\tau + 3T_{tr} = 24\tau$$

In conclusione, la latenza di una inserzione in coda vale:

$$L_{inserzione} = L_{fw-trattint} + L_{assem-trattint} = 104\tau$$