

Calcolatori Elettronici B

a.a. 2006/2007

**Pipeline, criticità e prestazioni:
Esercizi**

Massimiliano Giacomini

Influenza delle criticità sulle prestazioni

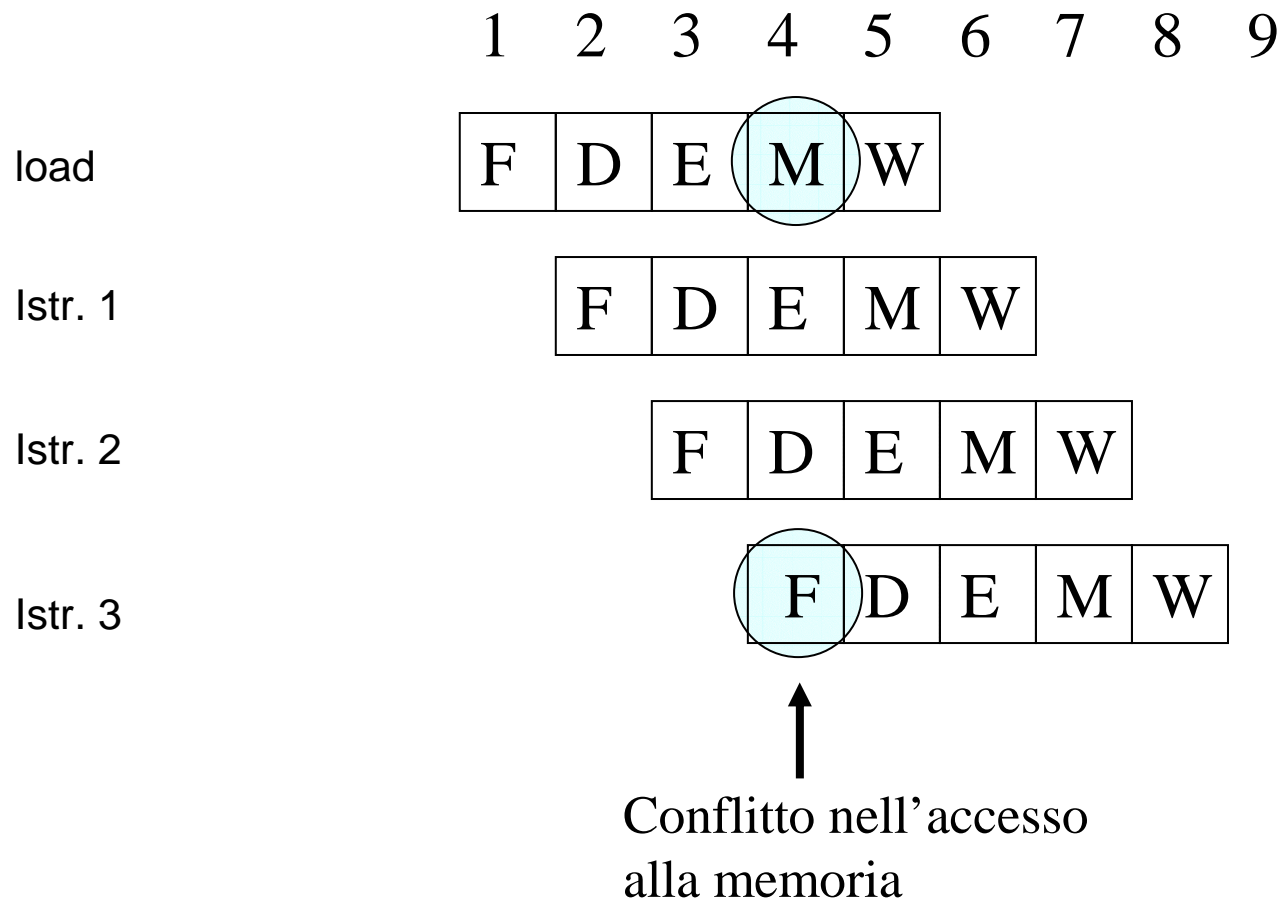
- Tipi di criticità:
 - **criticità strutturale**: ad esempio, viene usata un'unica memoria per i dati e per le istruzioni; oppure caso di fallimento in cache
 - **criticità sui dati**: quando ci sono dipendenze di dati fra istruzioni consecutive o comunque “ravvicinate”
 - **criticità sul controllo**: dovuta ai salti
- Vediamo come questi tipi di criticità influenzano le prestazioni di un processore con pipeline
- Vedremo vari esercizi in cui le precedenti criticità (nell'ordine) influenzano le prestazioni

PRESTAZIONI CON PIPELINE:
CRITICITA' STRUTTURALI


Esercizio – una sola memoria cache per dati e istruzioni

[già svolto nei lucidi; cfr. Es. 4, Tema d'esame 22 settembre '05]

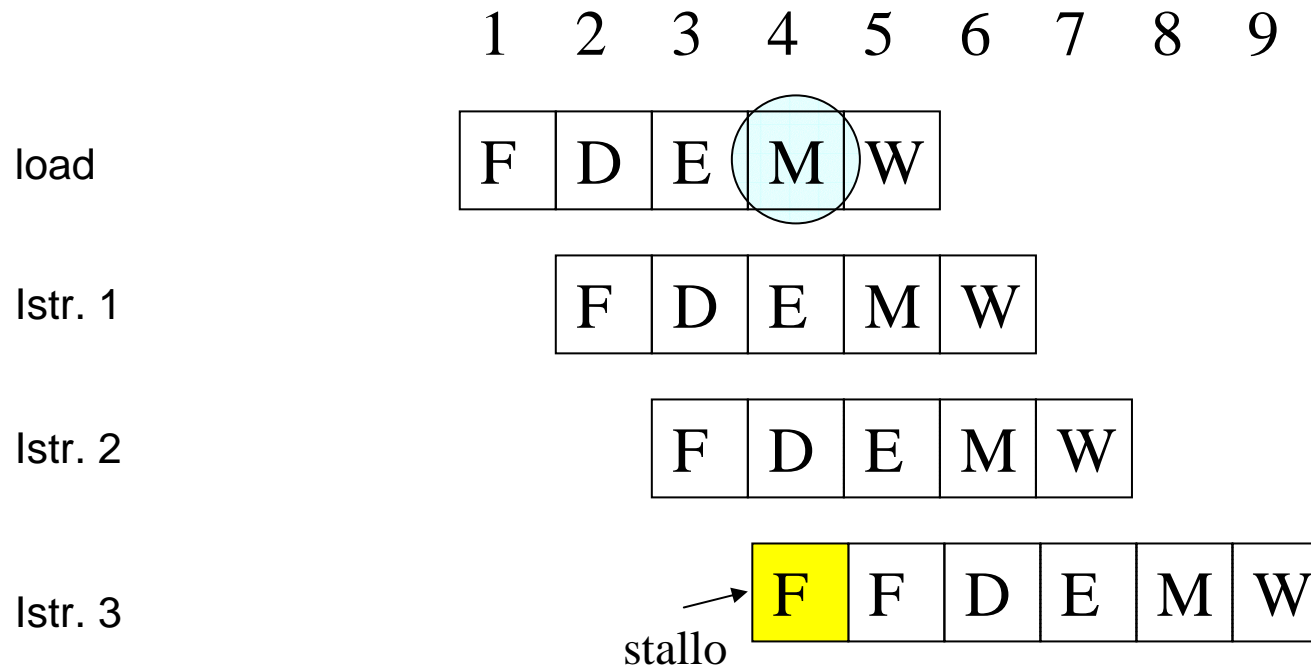
- Si consideri un processore dotato di pipeline (5 stadi) che disponga di una sola memoria cache per i dati e per le istruzioni:
 - 1) Si proponga una soluzione al problema basata sullo stallo della pipeline, descrivendo mediante diagramma temporale ciò che avviene in caso di conflitto sulla memoria.
 - 2) Si supponga che il 40% delle istruzioni eseguite facciano riferimento ai dati e che non esistano altri tipi di stalli: calcolare il CPI medio ed il throughput delle istruzioni.



- Ogni volta che un'istruzione richiede un accesso ai dati, c'è un conflitto con un'istruzione successiva che prevede, nello stadio di fetch, un accesso alla memoria per il prelevamento dell'istruzione.
- Per risolvere il conflitto, la pipeline deve essere messa in stallo per 1 ciclo di clock.



Una possibile soluzione: unità di criticità che pone in stallo la pipeline per un ciclo di clock



L'istruzione 3 viene completata alla fine del ciclo 9, nessuna istruzione viene completata nel ciclo 8

NB: notare che, ovviamente, è l'istruzione I_3 successiva alla load che “stalla”!!!

- Ricordando la formula per il CPI nel caso di stalli:

$$\text{CPI} = \text{CPI ideale} + \text{Cicli di stallo per istruzione}$$

Nel nostro caso: una sola memoria per dati e per istruzioni;
il 40% delle istruzioni eseguite fanno riferimento ai dati
e quindi “subiscono una penalità” ciascuna di un ciclo di clock
(anche se – come visto – in realtà la penalità è
causata dallo stallo di una istruzione successiva)

⇒ Supponendo che non esistano altri tipi di stalli si ha

$$\text{CPI} = 1 + \underbrace{0,40 \times 1}_{\text{Cicli di stallo}} = 1,4$$

Cicli di stallo

$$\text{Throughput} = 1/\text{CPI} = 1/1.4 = 0.71 \text{ istruzioni/ciclo}$$

Esercizio – miss di cache

Si consideri un sistema dotato solamente di **cache primaria** (senza cache secondaria) distinta per i dati e le istruzioni.

Per la cache si suppone:

- una penalità di fallimento di 10 cicli di clock
- una percentuale di successo del 95% per le istruzioni e del 90% per i dati

Si suppone inoltre che il 40% delle istruzioni faccia accesso a dati in memoria.

Si supponga che il carico sia tale che il CPI medio nel caso multiciclo risulti in assenza di miss di cache (come nel precedente esercizio) 4,04

Si calcolino il CPI effettivo ed il throughput per un processore multiciclo e per un processore con pipeline (in tal caso trascurando altre cause di stallo).
Si confrontino le prestazioni delle due soluzioni progettuali.

Consideriamo il processore con pipeline

- Se avviene un fallimento di accesso alla cache (per i dati o le istruzioni) si ha un ritardo dell'istruzione in cui si è verificato il fallimento: si ha un incremento dei cicli di clock pari alla penalità di fallimento di accesso alla cache (10 cicli)
- Dobbiamo considerare l'incremento medio di CPI dovuto ai fallimenti di accesso alla cache, chiamiamo δ_{miss} questo incremento
 - Per le istruzioni (tutte fanno il fetch): 95% percentuale di successo
 - Per i dati: il 40% delle istruzioni faccia accesso a dati in memoria 90% percentuale di successo

$$\delta_{\text{miss}} = \underbrace{0,05 \times 10}_{\text{Cicli di stallo per le istruzioni}} + \underbrace{0,4 \times 0,1 \times 10}_{\text{Cicli di stallo per i dati}} = 0,9 \text{ cicli}$$

⇒ CPI effettivo (in assenza di altre cause di stallo):

$$\text{CPI} = 1 + \delta_{\text{miss}} = 1 + 0,9 = 1,9$$

⇒ $\text{Throughput}_{\text{pipeline}} = 1/\text{CPI} = 1/1,9 = 0,53 \text{ istruzioni/ciclo}$

Consideriamo il processore multiciclo:

In assenza di miss di cache avrei $\text{CPI} = 4,04$

Ma per le istruzioni che danno miss (a causa del fetch o dell'accesso ai dati) si ha una penalità pari a quella del caso con pipeline:

$$\delta_{\text{miss}} = 0,05 \times 10 + 0,4 \times 0,1 \times 10 = 0,9 \text{ cicli}$$

$$\Rightarrow \text{CPI}_{\text{multiciclo}} = 4,04 + 0,9 = 4,94$$

$$\Rightarrow \text{Throughput}_{\text{multiciclo}} = 1/\text{CPI} = 1/4,94 = 0,20 \text{ istruzioni/ciclo}$$

Quindi l'incremento delle prestazioni nel caso con pipeline è

$$\mathbf{0,53/0,20 = 2,65} \quad [\text{Posso confrontare i throughput o, ugualmente, CPI – o, ugualmente, i tempi di esecuzione: il risultato non cambia!}]$$

Esercizio – due livelli di cache

[cfr. Es. 3, Tema d'esame 6 aprile 06]

Supponiamo di avere sia **cache primaria** che **cache secondaria**

- Per la cache primaria, come prima:
 - 95% percentuale di successo per istruzioni, 90% per i dati
 - Si supponga inoltre che per trasferire blocchi dalla cache secondaria alla cache primaria occorranza 4 cicli.
 - Penalità di fallimento: 10 cicli.
- Per la cache secondaria:
 - 94% la percentuale di successo per le istruzioni, 92% per i dati.
- Come prima, supponiamo che il 40% delle istruzioni faccia accesso ai dati in memoria

Calcolare CPI e Throughput per un processore con pipeline (trascurando altri stalli)

Soluzione

$$\begin{aligned} \delta_{\text{miss}} &= \overbrace{0,05 \times (0,94 \times 4 + 0,06 \times 10)}^{\text{Cicli di stallo per le istruzioni}} + \overbrace{0,4 \times 0,1 \times (0,92 \times 4 + 0,08 \times 10)}^{\text{Cicli di stallo per i dati}} = \\ &= 0,4 \text{ cicli} \end{aligned}$$

Da cui, **CPI** = $1 + 0,4 = 1,4$ **Throughput** = $1/1,4 = 0,71$ istruzioni/ciclo

Nota all'esercizio precedente:

si noti che l'esercizio non specifica il tempo di trasferimento di un blocco verso la cache secondaria; quando si verifica un fallimento nella cache secondaria (che necessariamente segue un fallimento nella cache primaria) si considera una penalità di fallimento pari a 10 cicli, ovvero quella della cache primaria: la cache primaria può venire caricata indipendentemente dalla secondaria, con la sua penalità di 10 cicli (è il tempo necessario per portare il blocco mancante nella memoria cache primaria!)
[e la cache secondaria viene caricata indipendentemente]

Per esercizio:

svolgere il calcolo per un processore multicyclo e confrontare le prestazioni in questo secondo caso (cache primaria + cache secondaria)

PRESTAZIONI CON PIPELINE:

**CRITICITA' SUI DATI E
PROPAGAZIONE**

Esercizio di riscaldamento

- Si consideri il seguente codice assembler

```
add $s0, $t0, $t1
```

```
sub $t2, $s0, $t3
```

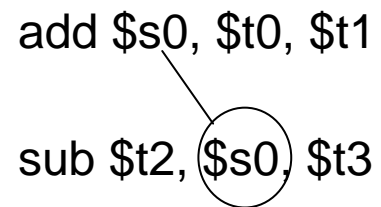
Si consideri la pipeline a 5 stadi del MIPS:

- si individuino le eventuali dipendenze tra i dati
- supponendo di non disporre dell'unità di propagazione, tracciare il diagramma temporale e individuare il numero di stalli necessari
- supponendo di disporre dell'unità di propagazione verso lo stadio E, tracciare il diagramma temporale

Dipendenze

add \$s0, \$t0, \$t1

sub \$t2, \$s0, \$t3



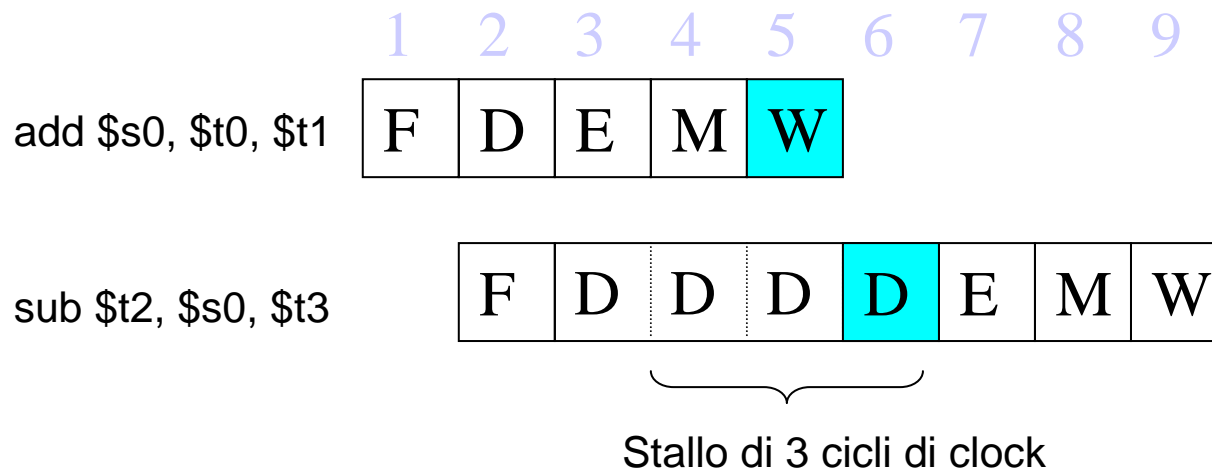
Abbiamo una sola dipendenza su s0

Senza propagazione:

Le istruzioni indipendenti procedono normalmente!

Per ogni dipendenza:

- individuare in quale stadio l'istruzione indipendente scrive il dato
- individuare in quale stadio l'istruzione dipendente legge il dato
- l'istruzione dipendente deve essere posta in stallo in modo che legga il dato dopo che è stato scritto



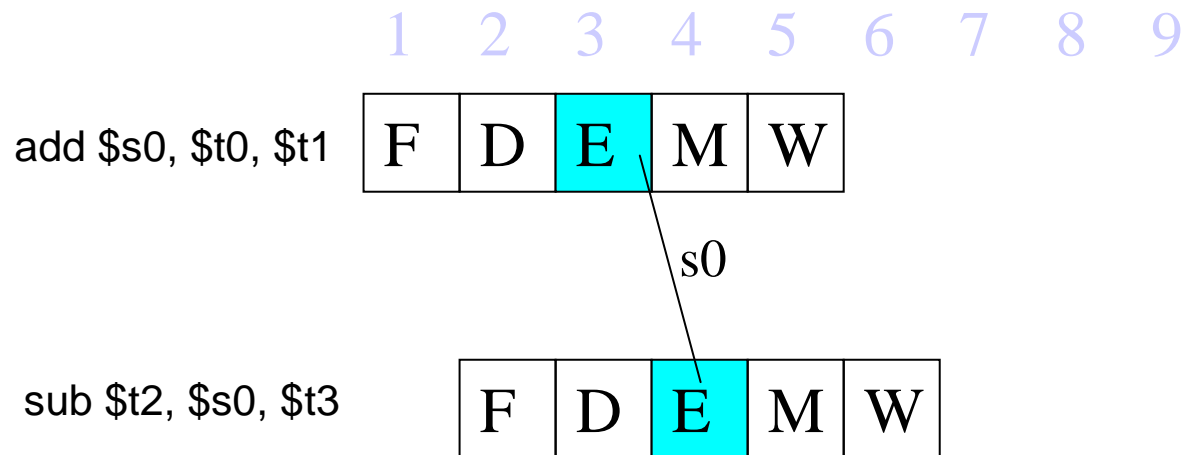
- L'istruzione sub, per prelevare \$s0, deve aspettare che sia disponibile il nuovo valore di \$s0 scritto dall'istruzione add nel suo stadio W.
- Con una pipeline a 5 stadi (prelievo, decodifica, esecuzione, accesso in memoria, scrittura risultato) la add scrive il risultato nel quinto stadio e quindi si creano **tre bolle** nella pipeline (= stallo di 3 cicli di clock).

Con propagazione:

Le istruzioni indipendenti procedono normalmente!

Per ogni dipendenza:

- individuare in quale stadio l'istruzione indipendente produce il dato
- individuare in quale stadio l'istruzione dipendente può propagare il dato (di solito, dove lo utilizza)
- verificare se il dato è disponibile (prodotto in cicli di clock precedenti) quando l'istruzione dipendente arriva nello stadio in cui è disponibile una unità di propagazione:
nel primo caso viene propagato, nel secondo servono cicli di stallo e propagazione



Nessuno stallo in questo caso!

Esercizio – criticità carica-e-usa

- Si consideri il codice assembler:

```
lw      $s0, 10($t1)
```

```
sub     $t2, $s0, $t3
```

Supponendo di disporre dell'unità di propagazione verso lo stadio E, tracciare il diagramma temporale ed individuare il numero di stalli necessari.

- Supponendo che il 30% delle istruzioni eseguite siano delle load e che, nel 50% dei casi, a un'istruzione di load segua un'istruzione che dipende dal risultato della load:

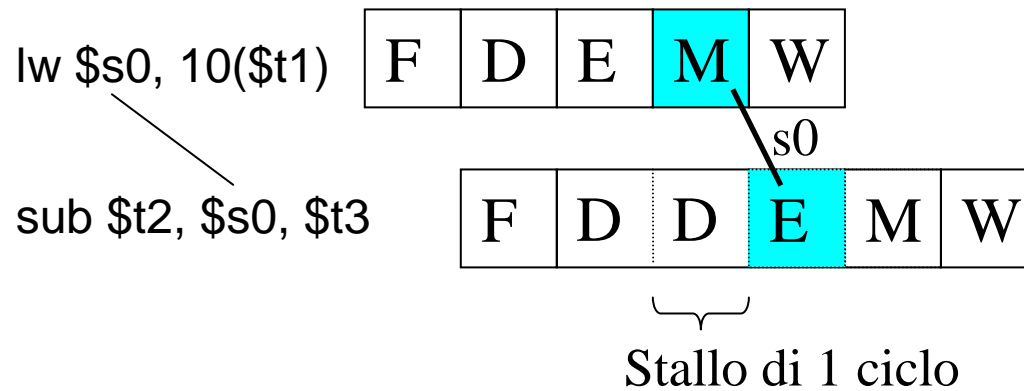
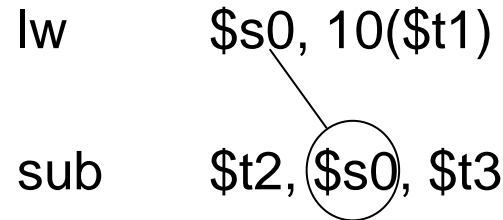
calcolare il CPI effettivo

[senza considerare altri tipi di criticità]

Diagramma temporale:

Dipendenze:

lw \$s0, 10(\$t1)
sub \$t2, \$s0, \$t3



⇒ Ogni volta che una load è seguita da un'istruzione che ne utilizza il dato, ho un ciclo di clock aggiuntivo

- Ricordiamo che:
 - 1) Nel caso ideale il CPI di un processore con pipeline è pari a 1
 - 2) In presenza di stalli:

$$\text{CPI} = \text{CPI ideale} + \text{Cicli di stallo per istruzione}$$

Quindi, supponendo che il 30% delle istruzioni eseguite siano delle load e che nel 50% dei casi a un'istruzione di load segua un'istruzione che dipende dal risultato della load:

- ogni stallo creato da lw seguita da istruzione da essa dipendente è di 1 ciclo di clock (come abbiamo visto nel diagramma precedente)
- supponiamo che non esistano altri tipi di stalli

$$\text{CPI} = 1 + \underbrace{0,30 \times 0,50 \times 1}_{\substack{\text{Penalità dovuta} \\ \text{ai cicli di stallo}}} = 1,15$$

Esercizio – criticità carica-e-usa con sw

- Si consideri il codice assembler:

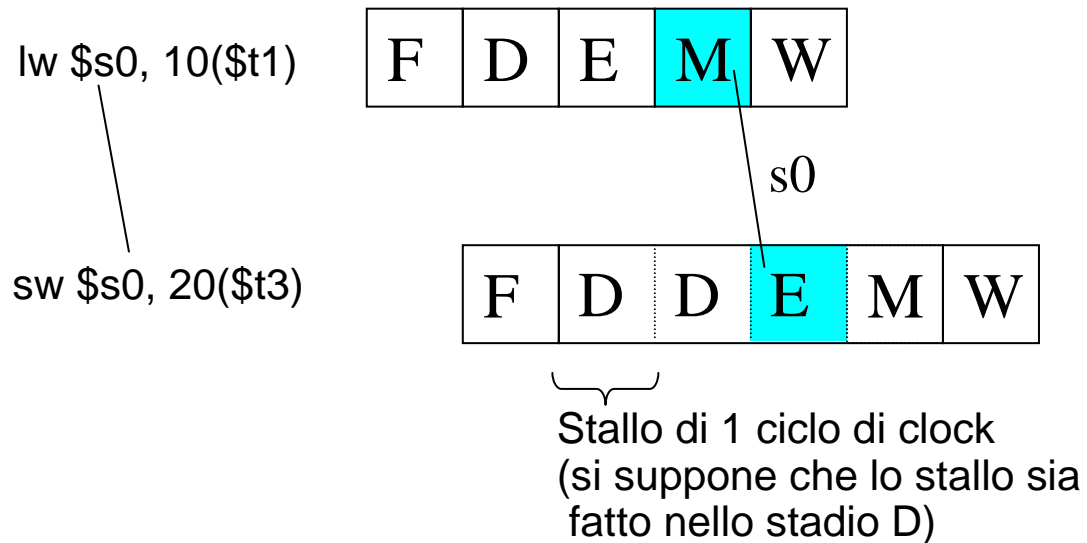
lw \$s0, 10(\$t1)

sw \$s0, 20(\$t3)

Tracciare il diagramma temporale ed individuare il numero di stalli necessari, per ciascuno dei seguenti tre casi:

- non è presente alcuna unità di propagazione
- è presente un unità di propagazione verso lo stadio E
- è presente l'unità di propagazione verso lo stadio E e lo stadio M


Diagramma con propagazione verso E:



NB: `s0` prodotto dalla `lw` nello stadio M [caricato dalla memoria] e propagato verso lo stadio E di `sw`: `sw` deve comunque “aspettare 1 ciclo”

NB2: Il dato propagato in ingresso a EX (istruzione `sw`) viene trasferito in EX/MEM (sarà usato da `sw` nello stadio M)

Propagazione verso E e verso M:



[Nel ciclo di clock 4, lw accede alla memoria per prelevare s0.
Il dato s0 è quindi disponibile (nel registro interstadio M/W)
nel ciclo di clock 5, quando può essere propagato verso
lo stadio M in cui sw lo pone in memoria.]

NB: l'implementazione del MIPS richiede un'estensione per supportare
la propagazione verso M [nella versione base supporta solo propagazione
verso E]

Esercizio: attenzione alla lieve differenza con il precedente...

- Si consideri il codice assembler:

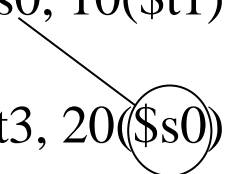
```
lw    $s0, 10($t1)
sw    $t3, 20($s0)
```

Tracciare il diagramma temporale ed individuare il numero di stalli necessari, supponendo di poter fare la propagazione verso qualunque stadio.


Soluzione

Innanzitutto, si individuano le dipendenze

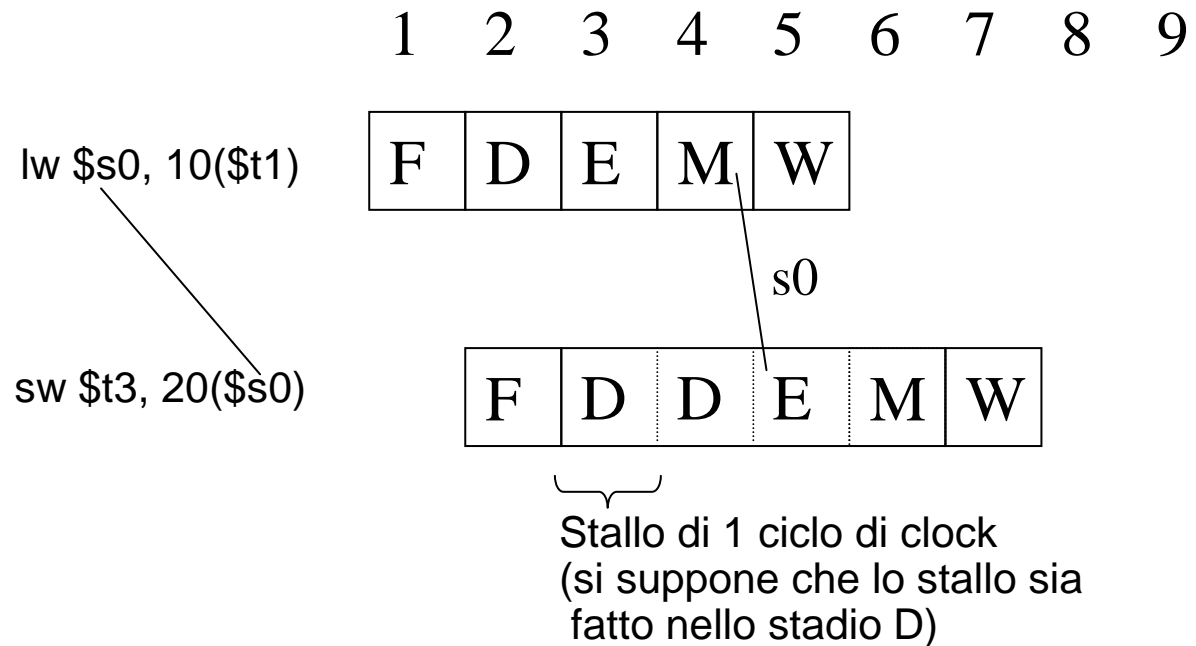
```
lw    $s0, 10($t1)
sw    $t3, 20($s0)
```



Attenzione: occorre sempre analizzare in che stadio è utilizzato (serve) il dato!!!



Quindi in questo caso s0 va propagato necessariamente verso E: 1 stallo



Proposta di esercizi (consideriamo 3 istruzioni):

ES. 1

Si consideri il seguente codice assembler MIPS:

```
lw  $s0, 10($s1)
add $t0, $s0, $s1
add $t1, $t0, $s0
```

Individuare le dipendenze e, supponendo di disporre solo dell'unità di propagazione verso E, disegnare il diagramma temporale.


ES. 2

Si considerino i due seguenti codici assembler MIPS:

```
lw  $s0, 10($s1)      lw  $s0, 10($s1)
add $s0, $t1, $t2     add $s1, $t1, $t2
sub $t3, $s0, $t4     sub $t3, $s0, $t4
```

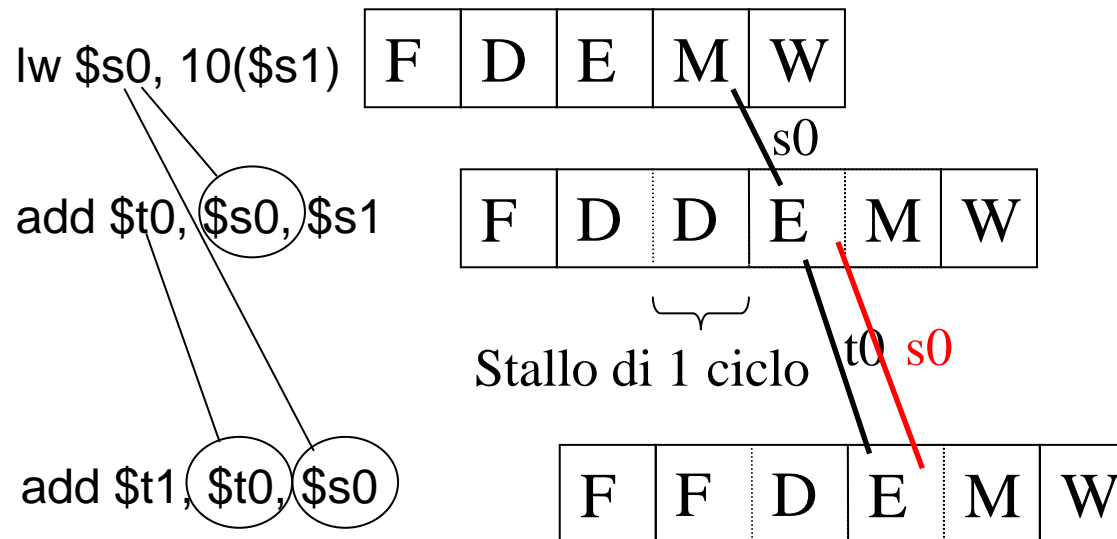
Per ciascuno di essi, individuare le dipendenze e, supponendo di poter propagare i dati verso qualunque stadio, disegnarne il diagramma temporale.

SOLUZIONE ESERCIZIO PROPOSTO N.1



➡ Stallo di un ciclo

ERRORE TIPICO

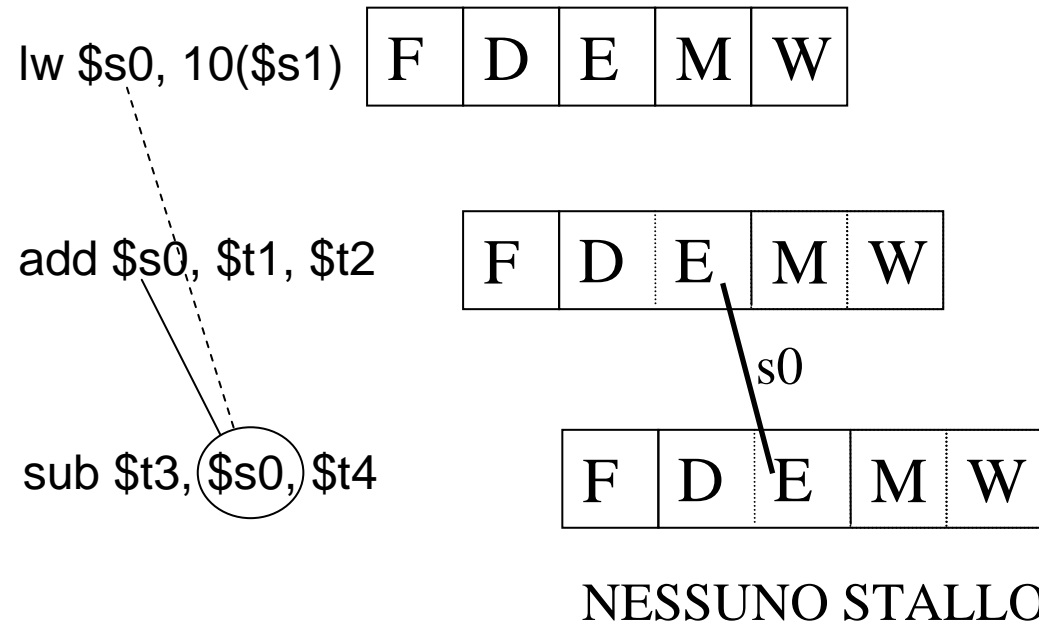


L'istruzione `add` non produce `s0`, anche se utilizza il valore `s0` corretto.
La propagazione avviene sempre dall'istruzione da cui sussiste la dipendenza; per rendersene conto, si pensi al caso in cui la seconda istruzione sia `add $t0, $s6, $s1`:
la propagazione deve avvenire secondo le stesse modalità!

SOLUZIONE ESERCIZIO PROPOSTO N.2

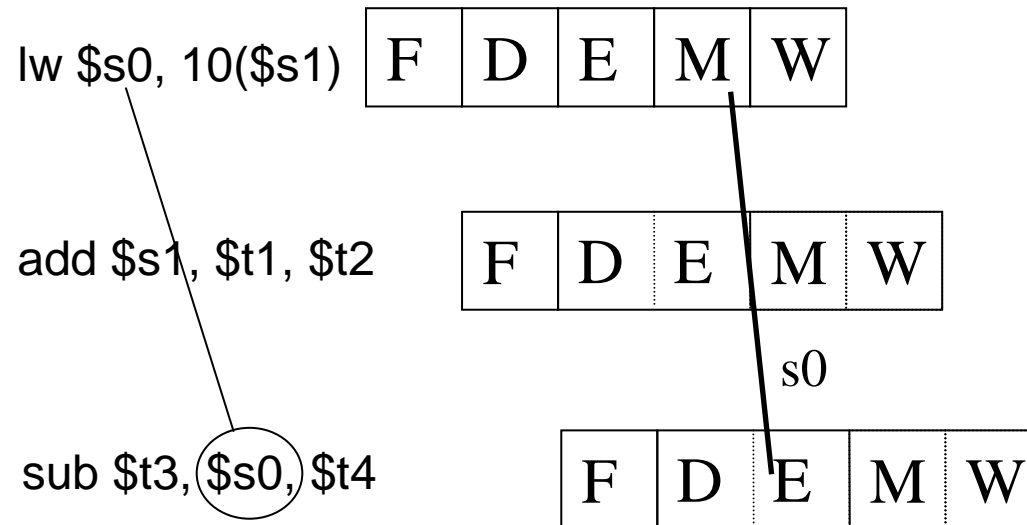
CODICE 1

IMPORTANTE:
INDIVIDUARE
TUTTE LE
DIPENDENZE,
NON SOLO QUELLE
DA PROPAGARE!



Importante: propago dall'istruzione add (la più recente!)

CODICE 2



NESSUNO STALLO

NB: in tal caso ovviamente propago dall'istruzione lw

Esercizio – Criticità sui dati e riordinamento delle operazioni

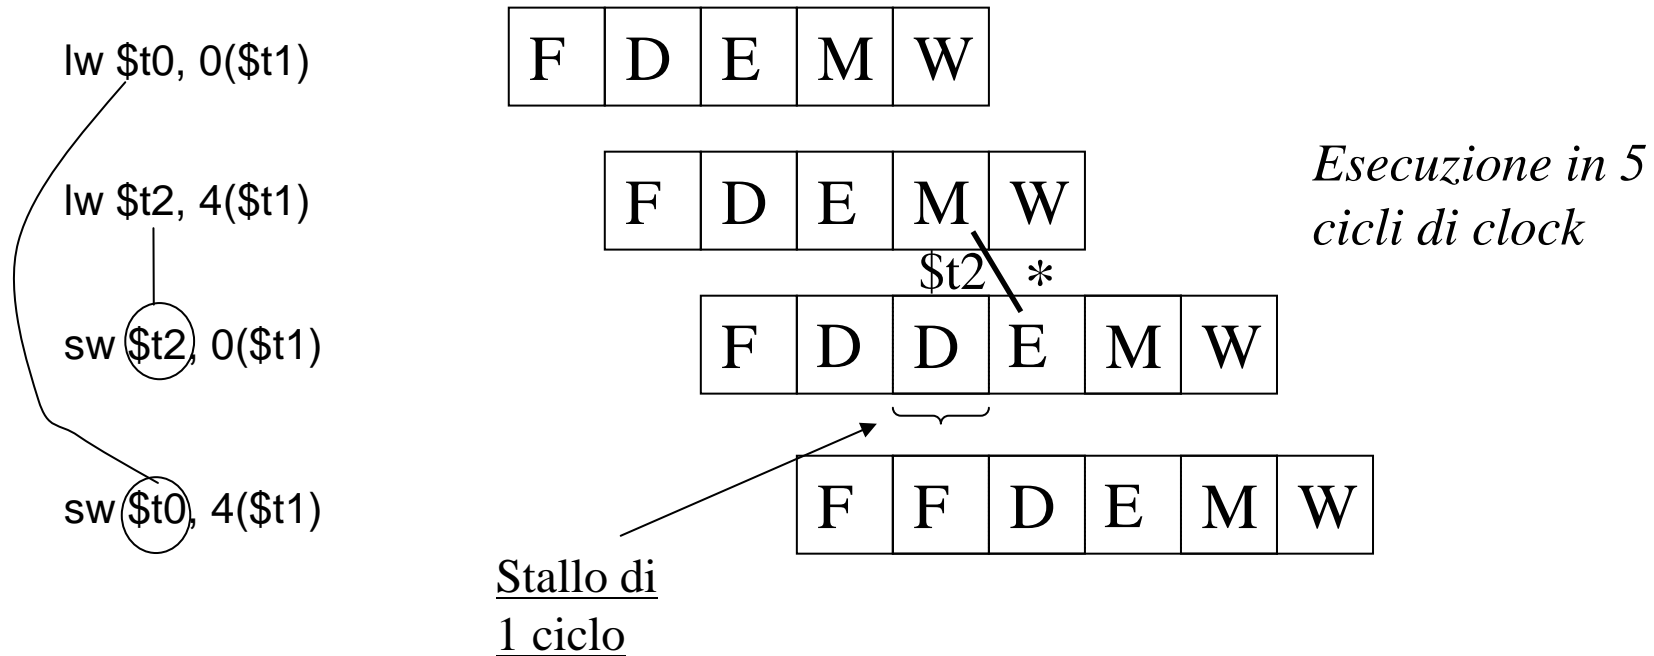
Codice di partenza (NB: è lo scambio $M[\$t1] \leftrightarrow M[\$t1+4]$)

lw	\$t0, 0(\$t1)	} Dipendenza dei dati
lw	\$t2, 4(\$t1)	
sw	\$t2, 0(\$t1)	
sw	\$t0, 4(\$t1)	

Trovare:

- diagramma temporale supponendo propagazione verso E
- supponendo di non disporre di unità di propagazione, riordinamento delle istruzioni per evitare il più possibile stalli della pipeline
- supponendo di disporre di unità di propagazione verso E, riordinamento delle istruzioni per evitare il più possibile stalli della pipeline

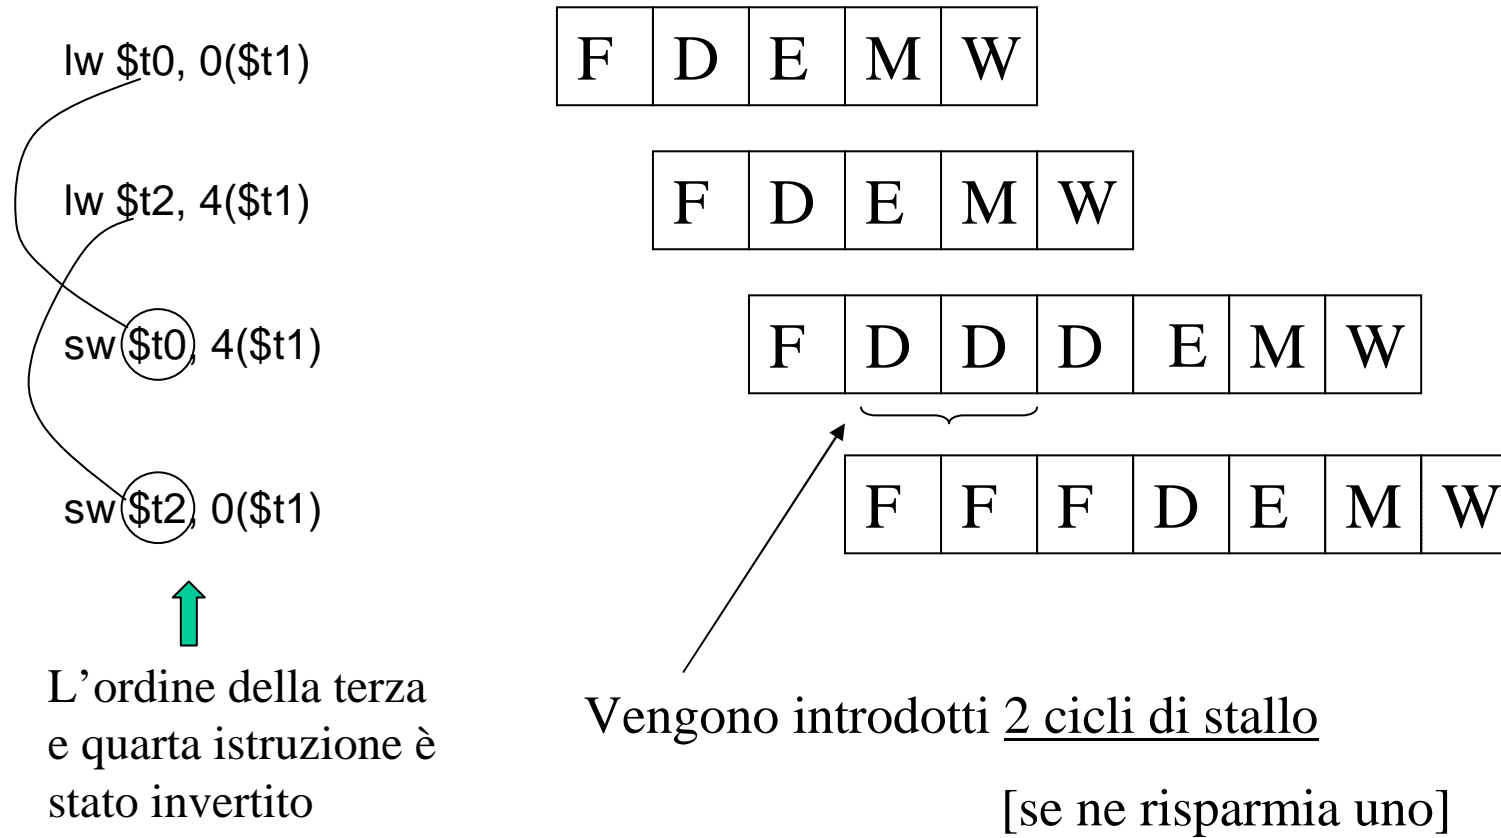
Propagazione verso E




* Il dato letto viene propagato come ingresso di E che lo trasferisce in EX/MEM

NB: è facile constatare che, se non si disponesse dell'unità di propagazione, servirebbe uno stallo di 3 cicli di clock (anziché 1)

Uso del riordino (senza propagazione)



Uso del riordino e della propagazione (verso E)

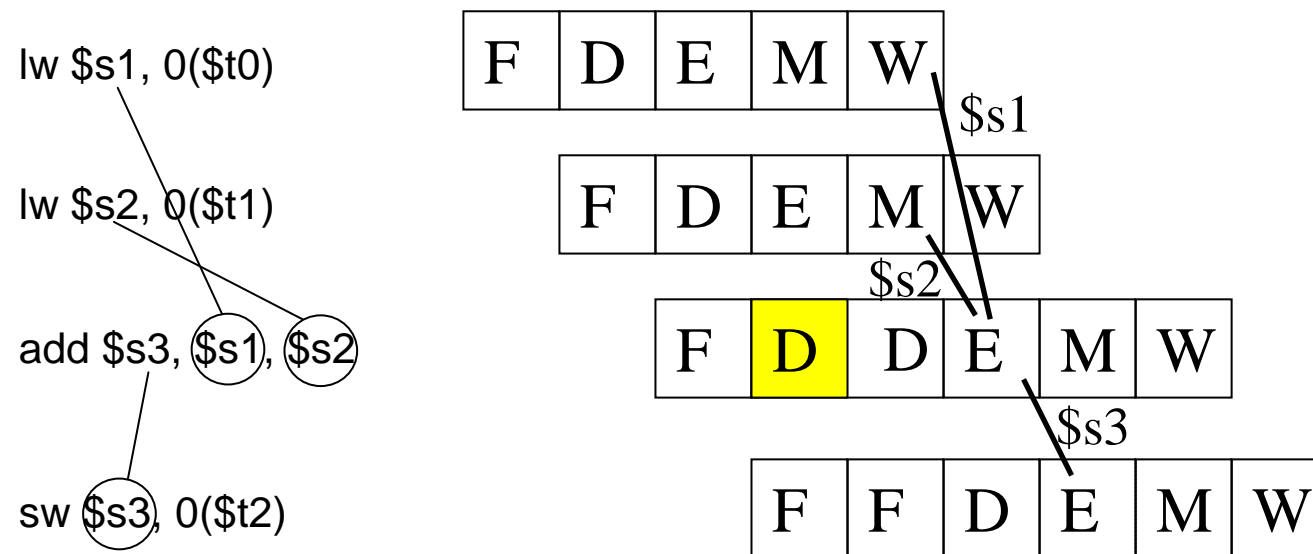


Esercizio/Esempio – Criticità sui dati e riordinamento delle operazioni

La tipica configurazione di codice che deriva da istruzioni del tipo

$$\mathbf{A = B + C}$$

genera **uno stallo** sul valore del secondo dato



Ruolo del compilatore:

- Il compilatore può **modificare la sequenza** di codice per eliminare lo stallo
- Il compilatore cerca di evitare di fare eseguire il **caricamento** e immediatamente dopo **usare il registro destinazione** del caricamento

VEDIAMO COME PARTENDO DA UN ESEMPIO...

- Codice di partenza

$$a = b + c;$$

$$d = e - f;$$

⇒ stallo su c nell'addizione

[se si carica prima b, altrimenti stallo su b]

⇒ stallo su f nella sottrazione

Supponiamo che


- b, c, e ed f siano nelle locazioni di memoria il cui indirizzo è rispettivamente in \$t0, \$t1, \$t3, \$t4
- a e d vadano memorizzati nelle locazioni il cui indirizzo è rispettivamente in \$t2 e \$t5

Esecuzione senza intervento del compilatore

```
lw    $s1, 0($t0)    # carica b
lw    $s2, 0($t1)    # carica c
add   $s3, $s1, $s2  # somma con stallo
sw    $s3, 0($t2)    # memorizza a
lw    $s4, 0($t3)    # carica e
lw    $s5, 0($t4)    # carica f
sub   $s6, $s4, $s5  # sottrazione con stallo
sw    $s6, 0($t5)    # memorizza d
```

...intervento del compilatore...

lw	\$s1, 0(\$t0)	# carica b
lw	\$s2, 0(\$t1)	# carica c
add	\$s3, \$s1, \$s2	# somma con stallo
sw	\$s3, 0(\$t2)	# memorizza a
lw	\$s4, 0(\$t3)	# carica e
lw	\$s5, 0(\$t4)	# carica f
sub	\$s6, \$s4, \$s5	# sottrazione con stallo
sw	\$s6, 0(\$t5)	# memorizza d



Esecuzione con intervento del compilatore

lw	\$s1, 0(\$t0)	# carica b
lw	\$s2, 0(\$t1)	# carica c
lw	\$s4, 0(\$t3)	# carica e
add	\$s3, \$s1, \$s2	# (scambiate lw e add)
lw	\$s5, 0(\$t4)	# carica f
sw	\$s3, 0(\$t2)	# scambiate lw e sw
sub	\$s6, \$s4, \$s5	# sottrazione
sw	\$s6, 0(\$t5)	# memorizza d



Con l'unità di propagazione verso E, non si ha più alcuno stallo!

Dal Tema d'esame 29 giu 2005 [ES. 1]

Si consideri il seguente frammento di codice MIPS:

```
lw $t0, 20($s1)
```

```
sw $t0, 22($s1)
```

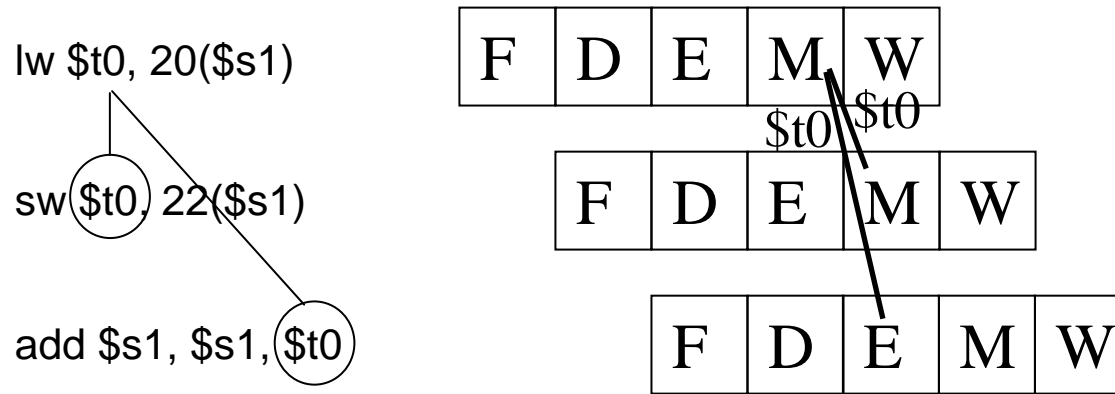
```
add $s1, $s1, $t0
```

Si consideri l'implementazione con pipeline a 5 stadi

(F: Fetch, D: Decode, E: Execute, M: Mem, W: Write-Back). Si chiede di:


- individuare le dipendenze tra i dati
- tracciare il diagramma temporale delle istruzioni nell'ipotesi sia disponibile un'unità di propagazione verso lo stadio E ed un'unità di propagazione verso M
- tracciare il diagramma temporale supponendo sia disponibile soltanto l'unità di propagazione verso lo stadio E. [6]

Caso “Propagazione verso E e verso M”



Nessuno stallo!

Caso “Propagazione solo verso E”



Uno stallo!

Dal Tema d'esame 13 lug 2005 [ES. 3]

Si consideri il seguente frammento di codice in un ipotetico linguaggio assembler:

```
lw $s0, ($s1)
```

```
add $t0, $s0, $s1
```

```
sub $t0, $t0, $s2
```

```
sub $s2, $t0, $s1
```

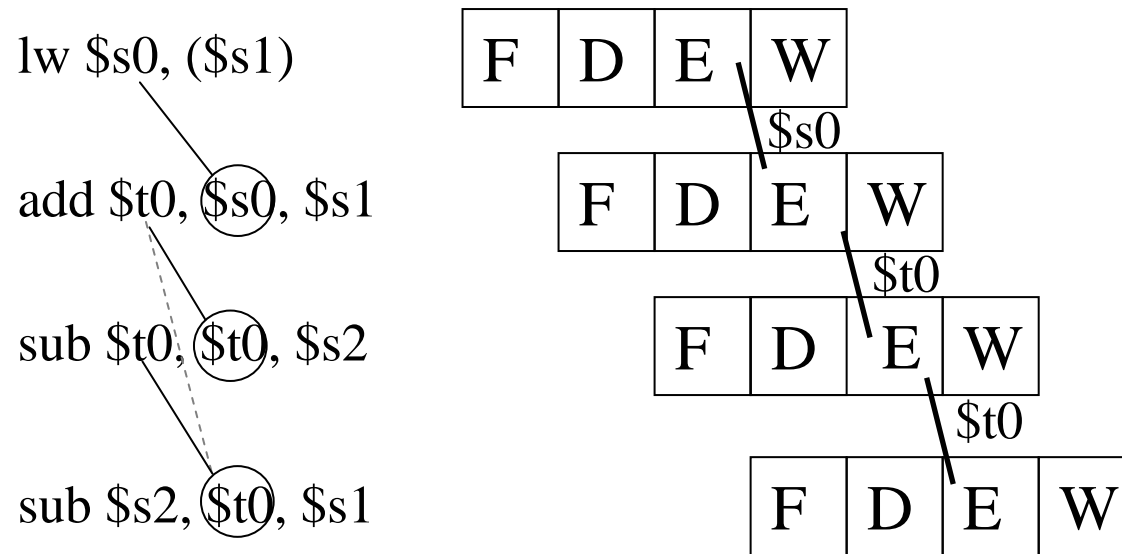
Si consideri l'implementazione con pipeline a 4 stadi
(F: Fetch, D: Decode, E: Execute, W: Write-Back). Si chiede di:

- a) individuare tutte le dipendenze tra i dati
- b) tracciare il diagramma temporale delle istruzioni nell'ipotesi sia disponibile un'unità di propagazione verso lo stadio E.

[4]

Soluzione

NB: si noti che la lettura dalla memoria avviene nello stadio E



NB2: si noti che l'ultima sub propaga t0 dalla sub precedente, non dalla add

Dal Tema d'esame 22 set 2005 [ES. 1]

Si consideri il seguente frammento di codice MIPS:

```
lw $t0, 10($t0)
```

```
add $t0, $t0, $t0
```

```
sw $t0, 10($t0)
```

```
add $t0, $t0, $t0
```

Si consideri l'implementazione con pipeline a 5 stadi

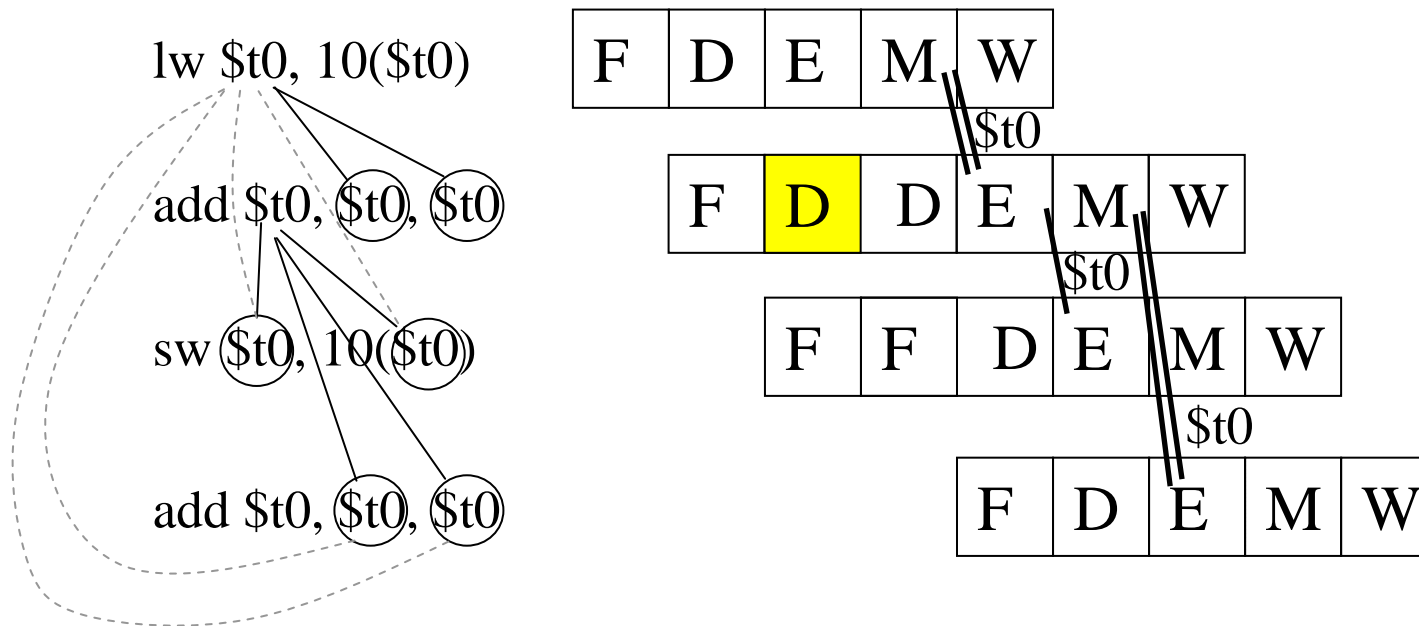
(F: Fetch, D: Decode, E: Execute, M: Mem, W: Write-Back). Si chiede di:

- individuare tutte le dipendenze tra i dati
- tracciare il diagramma temporale delle istruzioni nell'ipotesi sia disponibile un'unità di propagazione verso lo stadio E.

[4]

Soluzione

[le dipendenze a tratteggio sono quelle che non vengono propagate]



Uno stallo!

Dal Tema d'esame 13 dic 2005 [ES. 2]

Si consideri il seguente frammento di codice MIPS:

```
add    $s0, $t1, $t2  
  
sub    $s1, $s0, $t1  
  
add    $s1, $s1, $s0  
  
lw     $t0, 10($s1)  
  
add    $s1, $t0, $t0
```

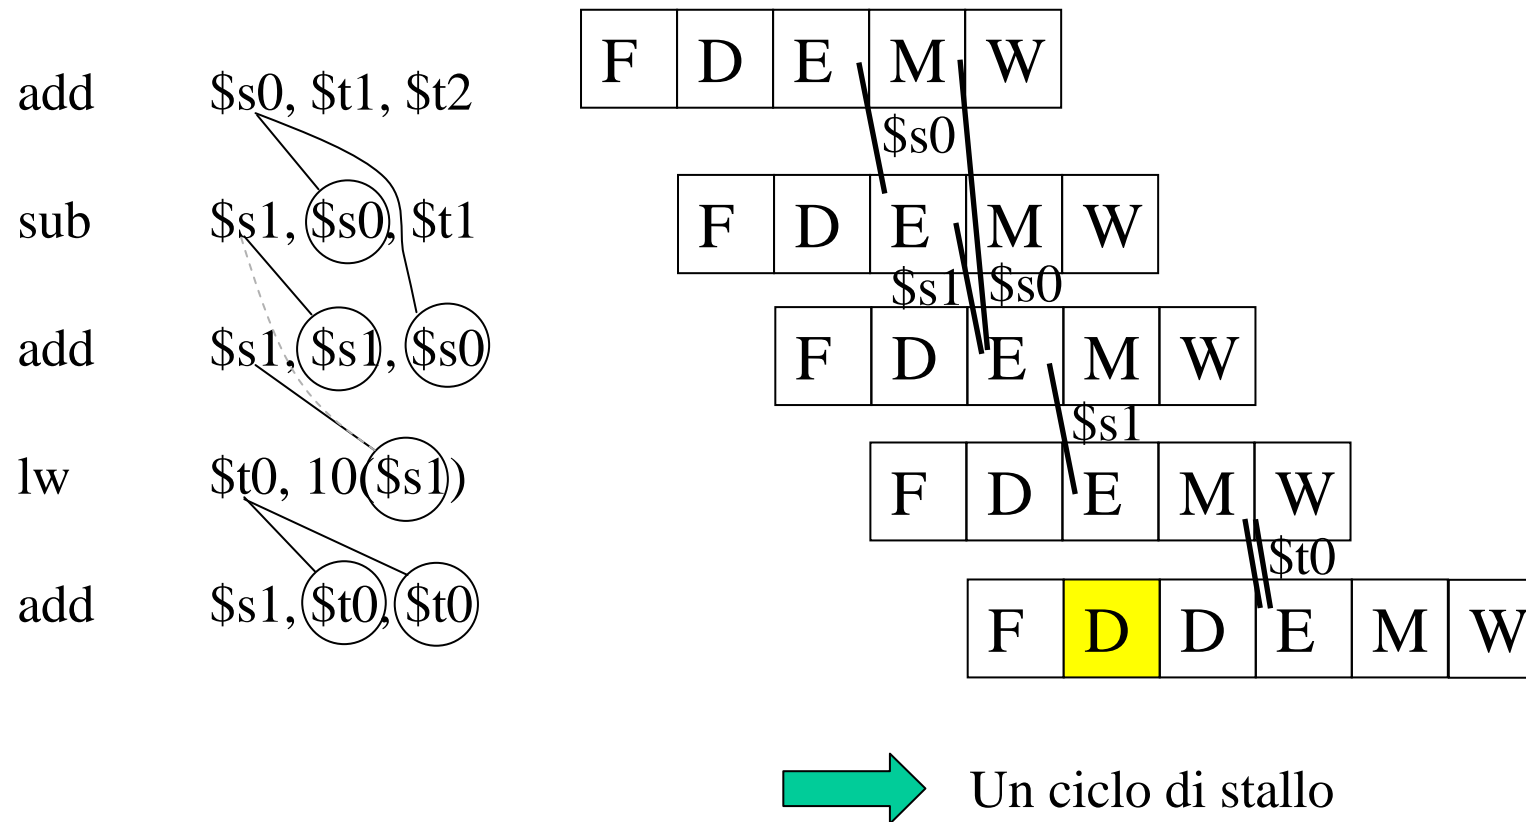
Si consideri l'implementazione con pipeline a 5 stadi

(F: Fetch, D: Decode, E: Execute, M: Mem, W: Write-Back). Si chiede di:

- individuare in modo preciso tutte le dipendenze tra i dati
- tracciare il diagramma temporale delle istruzioni nell'ipotesi sia disponibile un'unità di propagazione verso lo stadio E.
- risolvere il punto precedente supponendo sia disponibile un'unità di propagazione verso lo stadio E ed una verso lo stadio M.

[6]

Soluzione con propagazione verso E



Soluzione con propagazione verso E+M

Si vede che non cambia nulla nel grafico! Infatti per l'ultima istruzione (l'unica che stalla) il dato è utilizzato (ovvero, "serve") nello stadio E, quindi dovrebbe essere necessariamente propagato verso quello stadio anche se si disponesse dell'unità di propagazione verso M!

Dal Tema d'esame 13 dic 2005 [ES. 3]

Si consideri l'implementazione con pipeline a 5 stadi dell'esercizio precedente, per la quale si utilizza un hardware che richiede i seguenti tempi di esecuzione:

- prelievo istruzione e accesso alla memoria dati: 4 ns
- ogni altra operazione critica (ALU, decodifica, lettura e scrittura register file): 2 ns

Si assuma il seguente carico di lavoro:

lw:	20 %
sw:	20 %
formato-R:	40 %
beq:	15 %
j:	5 %

Si supponga che metà delle istruzioni di formato-R, sw e lw siano seguite da istruzioni che ne utilizzano il risultato; in particolare, il 25% delle istruzioni che seguono lw utilizzano il risultato nello stadio E, il rimanente 25% utilizzano il risultato in M.

Si calcoli il tempo medio di esecuzione per istruzione:

- nel caso ideale (trascurando tutte le criticità)

Inoltre, trascurando le criticità strutturali e le criticità sui salti, si calcoli il tempo medio di esecuzione nei due casi seguenti:

- disponendo di un'unità di propagazione solo verso lo stadio E
- disponendo di un'unità di propagazione verso lo stadio E ed una verso lo stadio M.

Soluzione

$$\begin{aligned} T_{\text{es.istruz.}} &= \text{CPI} * T_{\text{clock}} \\ &= (1 + \text{cicli_stallo}) * T_{\text{clock}} \end{aligned}$$

→ $T_{\text{clock}} = 4 \text{ ns}$ (non ci sono due operazioni critiche in serie, la più gravosa è 4 ns)

→ Cicli_stallo (dovuti solo a dipendenza dati):

- Caso ideale: 0

- Prop. Verso E: dovuti a criticità carica-e-usa, ovvero lw seguita immediatamente da istruzione che ne utilizza risultato (in tal caso un ciclo di stallo)

$$0.2 * 0.5 * 1 = 0.1$$

↓ ↓
20% di lw 50% sono seguite da istruzioni che ne utilizzano il risultato (nello stadio E o M)

- Prop. Verso E+M: se lw è seguita da istruzione che ne utilizza il risultato nello stadio M, la criticità è risolta da propagazione verso M.

$$0.2 * 0.25 * 1 = 0.05$$

↓ ↓
20% di lw 25% sono seguite da istruzioni che ne utilizzano il risultato nello stadio E

Svolgendo i conti risulta

$$T_{\text{es.istruz.}} = (1 + \text{cicli_stallo}) * T_{\text{clock}}$$

- Caso ideale (cicli_stallo = 0):

$$T_{\text{es.istruz.}} = 4 \text{ ns}$$

- Prop. E (cicli_stallo = 0.1):

$$T_{\text{es.istruz.}} = 1.1 * 4 \text{ ns} = 4.4 \text{ ns}$$

- Prop. E+M (cicli_stallo = 0.05):

$$T_{\text{es.istruz.}} = 1.05 * 4 \text{ ns} = 4.2 \text{ ns}$$

NB: notare che non abbiamo utilizzato tutti i dati del problema! Il carico di lavoro ci è servito solo per valutare quante lw ci sono (le uniche che generano una criticità!). Inoltre, le dipendenze interessano solo rispetto a lw.

**PRESTAZIONI CON PIPELINE:
CRITICITA' SUL CONTROLLO**

Esercizio – Criticità sui salti e stallo

Si consideri una pipeline a cinque stadi in cui l'esecuzione del salto incondizionato (jump) avviene nel secondo stadio, quella del salto condizionato (beq) nel terzo.

Si supponga che l'hardware risolva le criticità sui salti (condizionati e incondizionati) mediante lo stallo della pipeline.

Si supponga che il carico di lavoro preveda, tra le altre istruzioni:


2 % di istruzioni di salto incondizionato

15 % di istruzioni di salto condizionato


Si calcoli il CPI effettivo trascurando le criticità sui dati e strutturali.


Soluzione

Cicli di stallo per salto incondizionato: 1
(aggiornamento PC nel secondo stadio)



Cicli di stallo per salto condizionato: 2
(aggiornamento PC nel terzo stadio)



 $\delta_{\text{stalli}} = 0,02 \times 1 + 0,15 \times 2 = 0,32$ cicli

$$\text{CPI} = 1 + \delta_{\text{stalli}} = 1,32$$

Esercizio – Criticità sui salti, stallo e propagazione

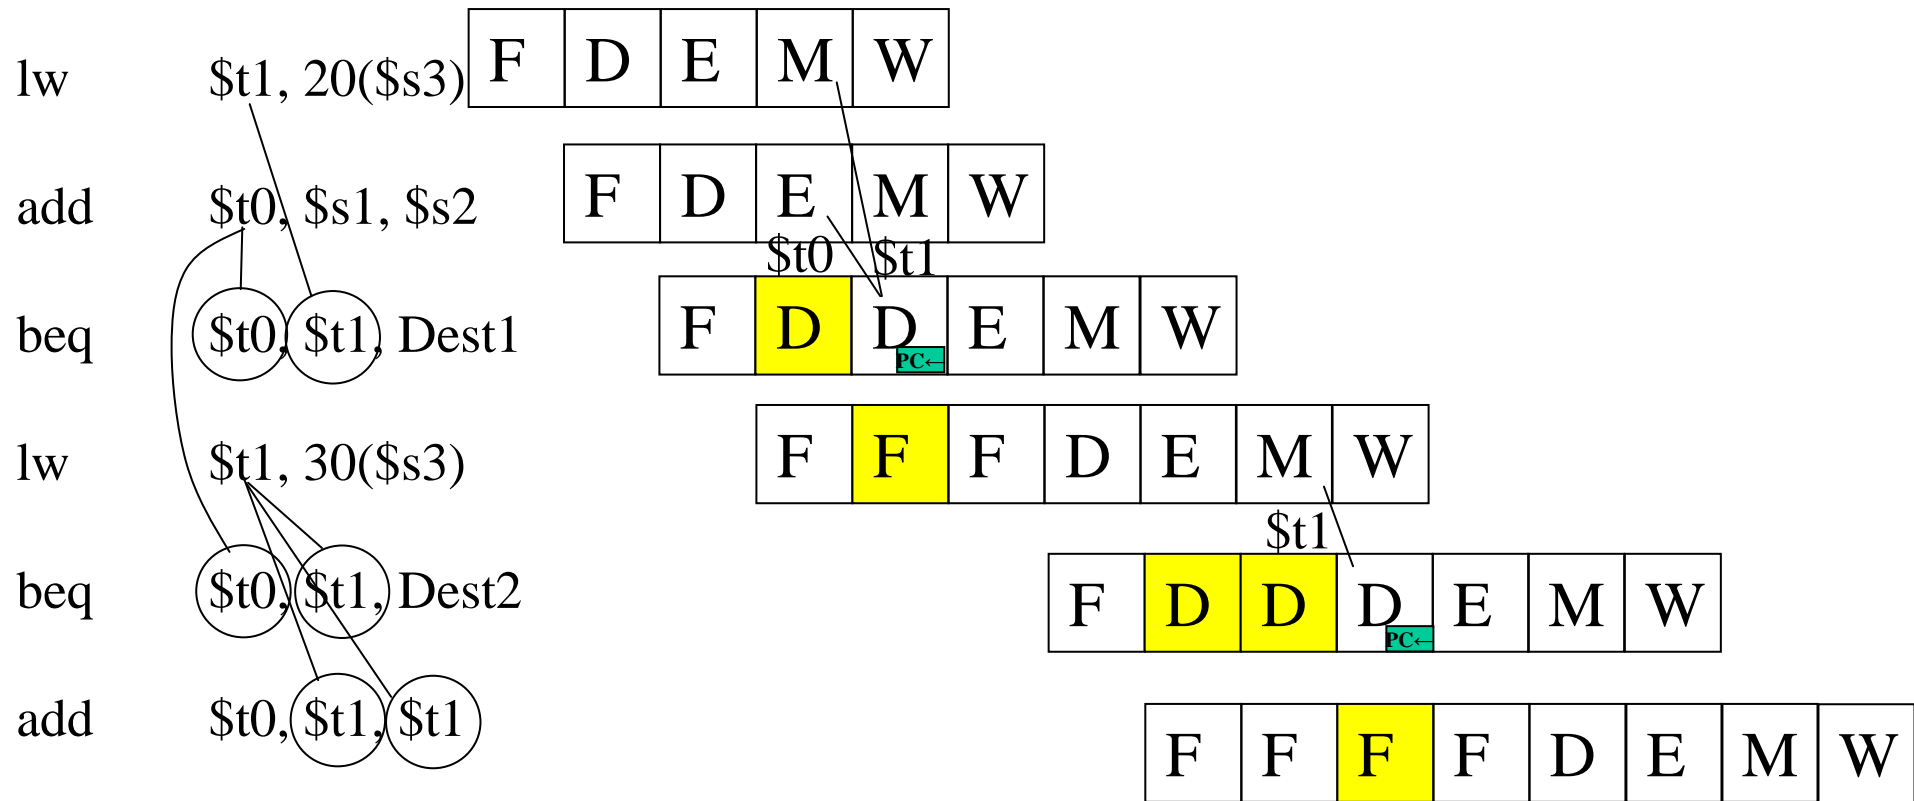
Si consideri il seguente frammento di codice MIPS:

```
lw    $t1, 20($s3)
add   $t0, $s1, $s2
beq   $t0, $t1, Dest1
lw    $t1, 30($s3)
beq   $t0, $t1, Dest2
add   $t0, $t1, $t1
```

Si consideri l'implementazione con pipeline a 5 stadi (F: Fetch, D: Decode, E: Execute, M: Mem, W: Write-Back) in cui le criticità sui salti condizionati sono risolti mediante stallo.

In particolare, sapendo che lo stallo in caso di criticità è di un ciclo di clock, si chiede di tracciare il diagramma temporale delle istruzioni nell'ipotesi che per entrambi i salti condizionati la condizione di salto non si verifichi.

NB: uno stallo nel caso della criticità: da ciò si deduce che il calcolo della condizione e l'aggiornamento del PC avvengono nello stadio D
 ⇒ è necessario propagare in ID se rs e rt dipendono da istruzioni precedenti



➡ In totale 5 cicli di stallo!

Brevi richiami sul salto ritardato

Istruzione di salto

prima istruzione successiva
seconda istruzione successiva
...
n-esima istruzione successiva

Destinazione del salto

**SLOT DI
RITARDO**

*Istruzioni eseguite
indipendentemente dal
successo del salto*

... di solito lo slot di ritardo è limitato a una sola istruzione

Comportamento del salto ritardato

ipotizzando per esempio un solo slot di ritardo:

Caso salto eseguito

Istruzione i di salto eseguito
Istruzione $i+1$ nello slot di ritardo
Destinazione del salto
Destinazione del salto + 1
Destinazione del salto + 2


Caso salto non eseguito

Istruzione i di salto non eseguito
Istruzione $i+1$ nello slot di ritardo
Istruzione $i+2$
Istruzione $i+3$
Istruzione $i+4$

Stadio di esecuzione e slot

- Il numero di slot di ritardo è legato direttamente alla posizione dello stadio in cui il salto viene eseguito (ovvero: PC aggiornato che determina il fetch istruzione destinazione nel ciclo successivo)
- In particolare:
 - stadio D (nr. 2) \Rightarrow 1 slot di ritardo
 - stadio E (nr. 3) \Rightarrow 2 slot di ritardo
 - ecc. ecc.

Infatti



Esercizio – Cicli e riordino delle istruzioni

E' dato il segmento di codice in assembler MIPS [realizza $\$s3=2^{\$s2}$]

```

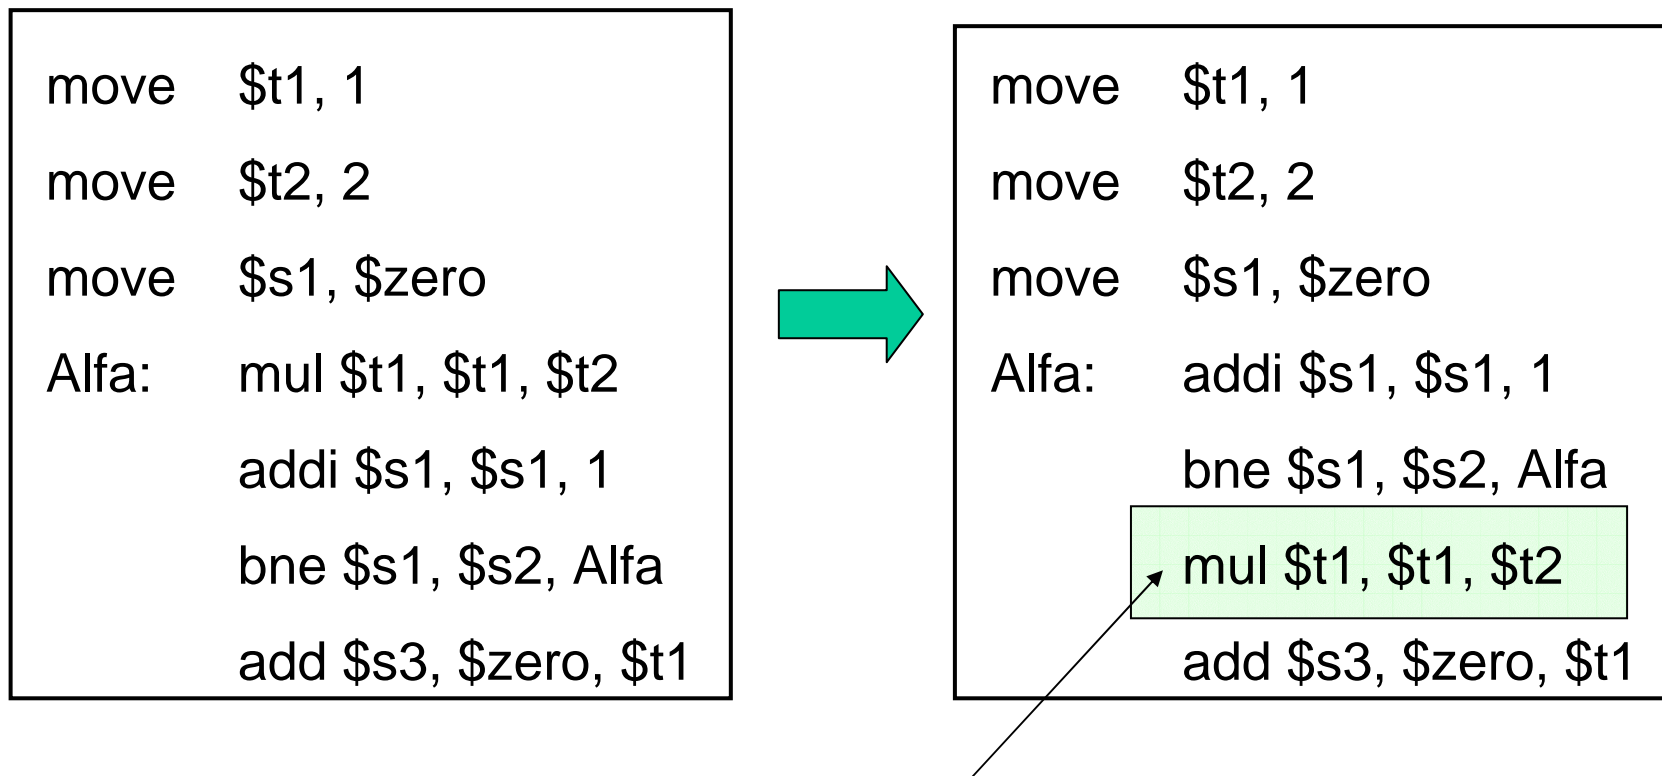
        move      $t1, 1           // prodotto parz.
        move      $t2, 2           // base=2
        move      $s1, $zero       // indice ciclo
Alfa:   mul       $t1, $t1, $t2
        addi      $s1, $s1, 1
        bne      $s1, $s2, Alfa
        add       $s3, $zero, $t1
```

Considerando una pipeline a due soli stadi (F + E) e utilizzando la tecnica del salto ritardato, riordinare il codice in modo da gestire la criticità sul salto bne e riportare i diagrammi temporali nel caso di “salto eseguito” e di “salto non eseguito”.

Pipeline a due stadi

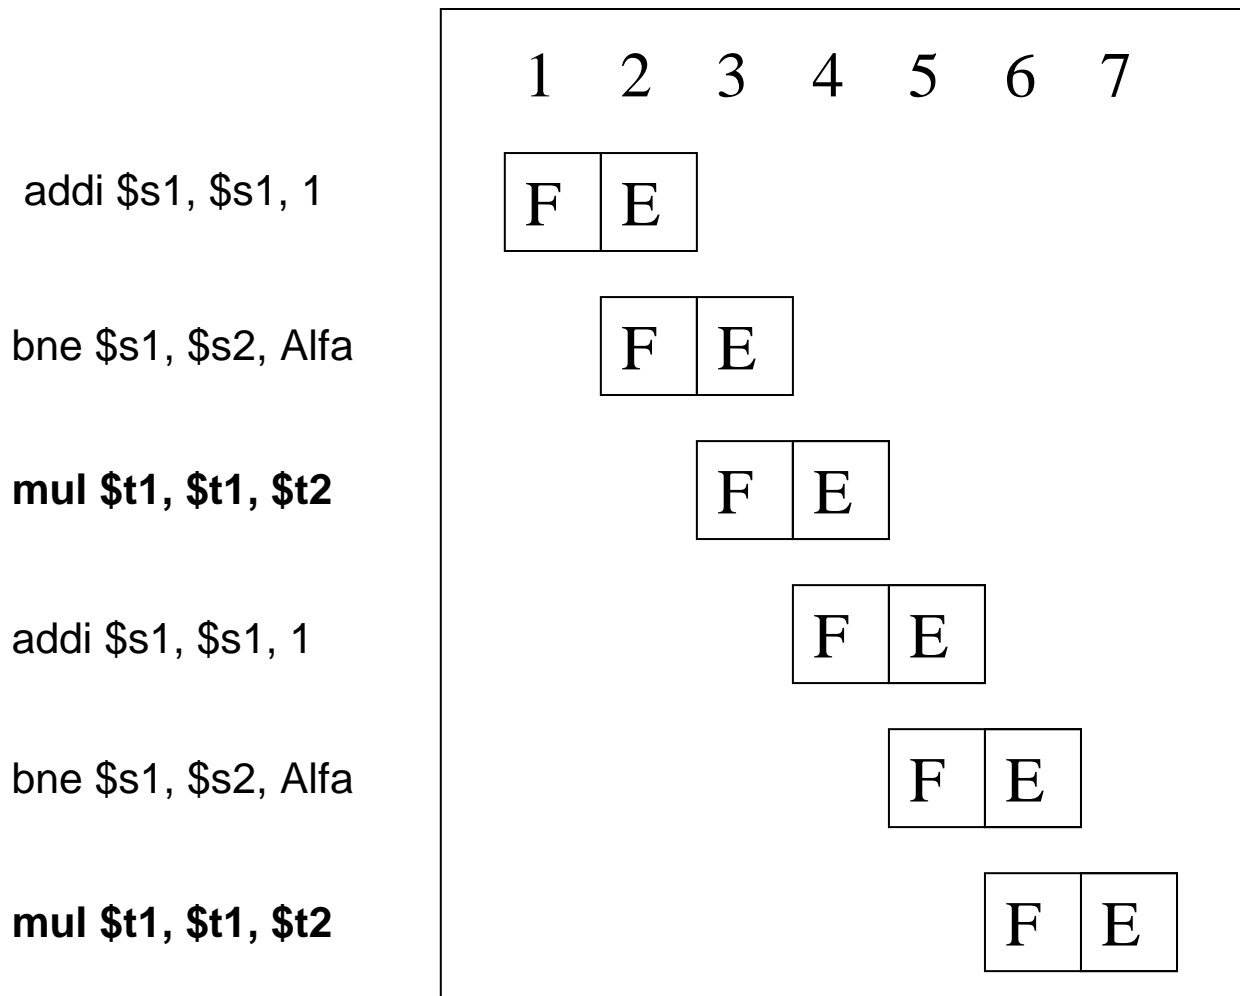
⇒ necessariamente l'aggiornamento del PC nello stadio E
e si ha un solo slot di ritardo!

Riordino delle istruzioni



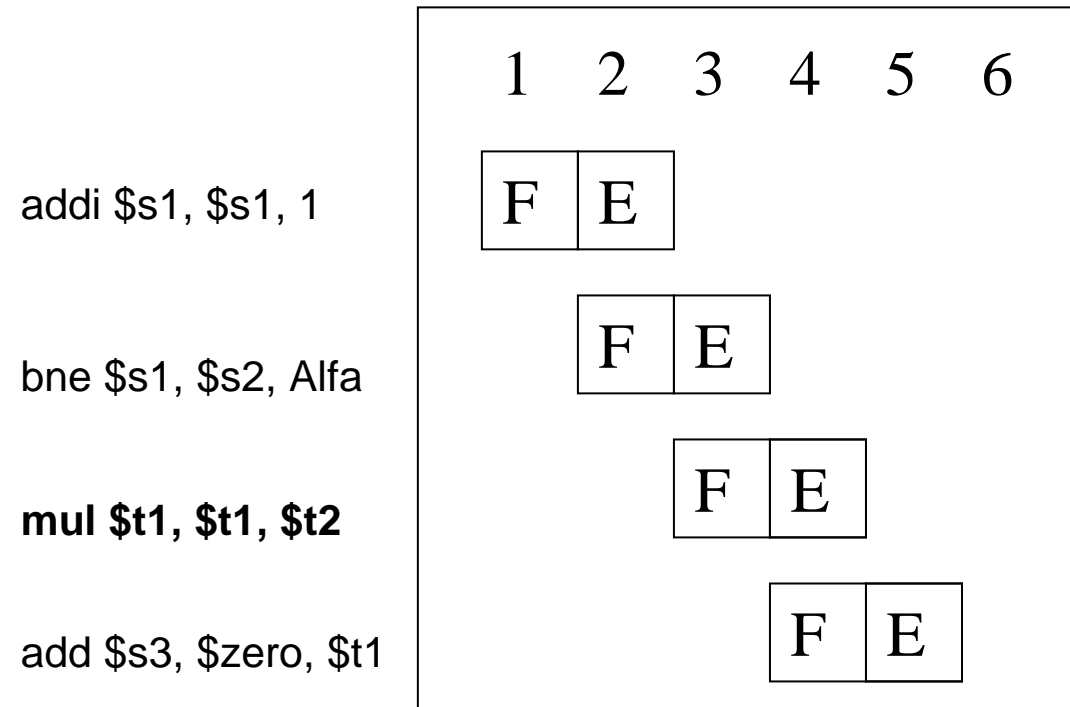
Istruzione inserita nello slot di ritardo

Diagramma temporale nel caso di salto eseguito

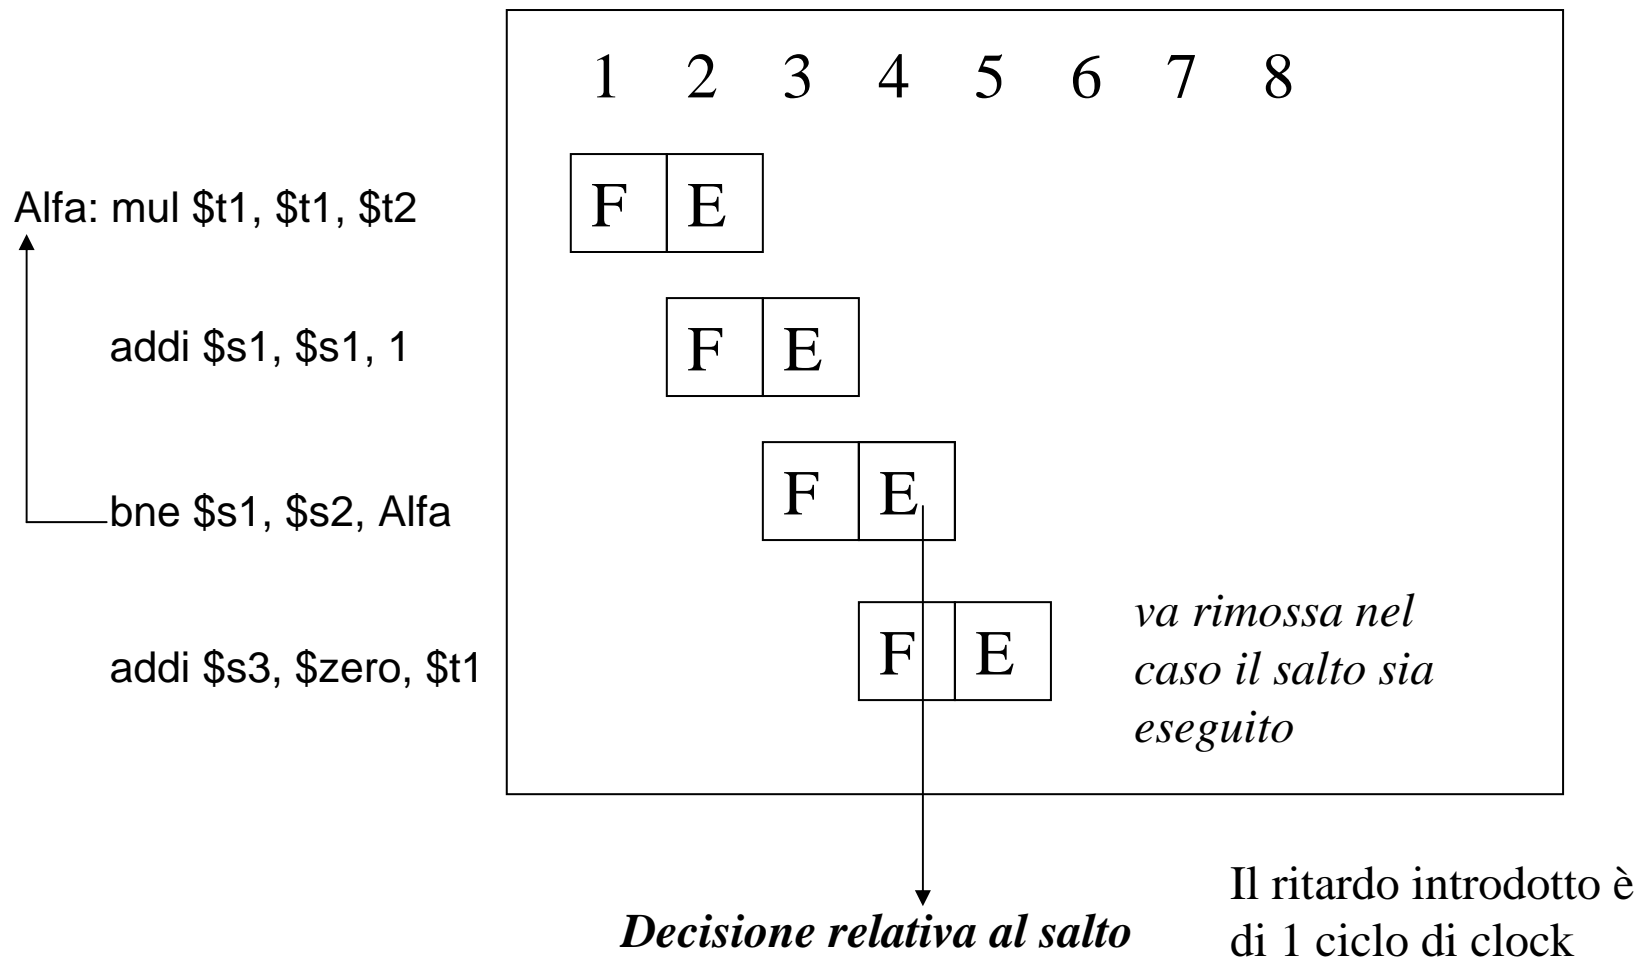


NB: non c'è propagazione di s1 per bne: necessariamente il prelievo degli operandi nelle istruzioni viene fatto in E, sicuramente dopo che l'istruzione precedente ha scritto la destinazione! [ciò perché la pipeline ha solo due stadi!]

Diagramma temporale nel caso di salto non eseguito



**NB: Diagramma temporale dell'esecuzione
senza salto ritardato (pipeline a 2 stadi)
 -prediz. “salto non eseguito”**



Variante dell'esercizio

Consideriamo lo stesso codice ma ipotizzando:

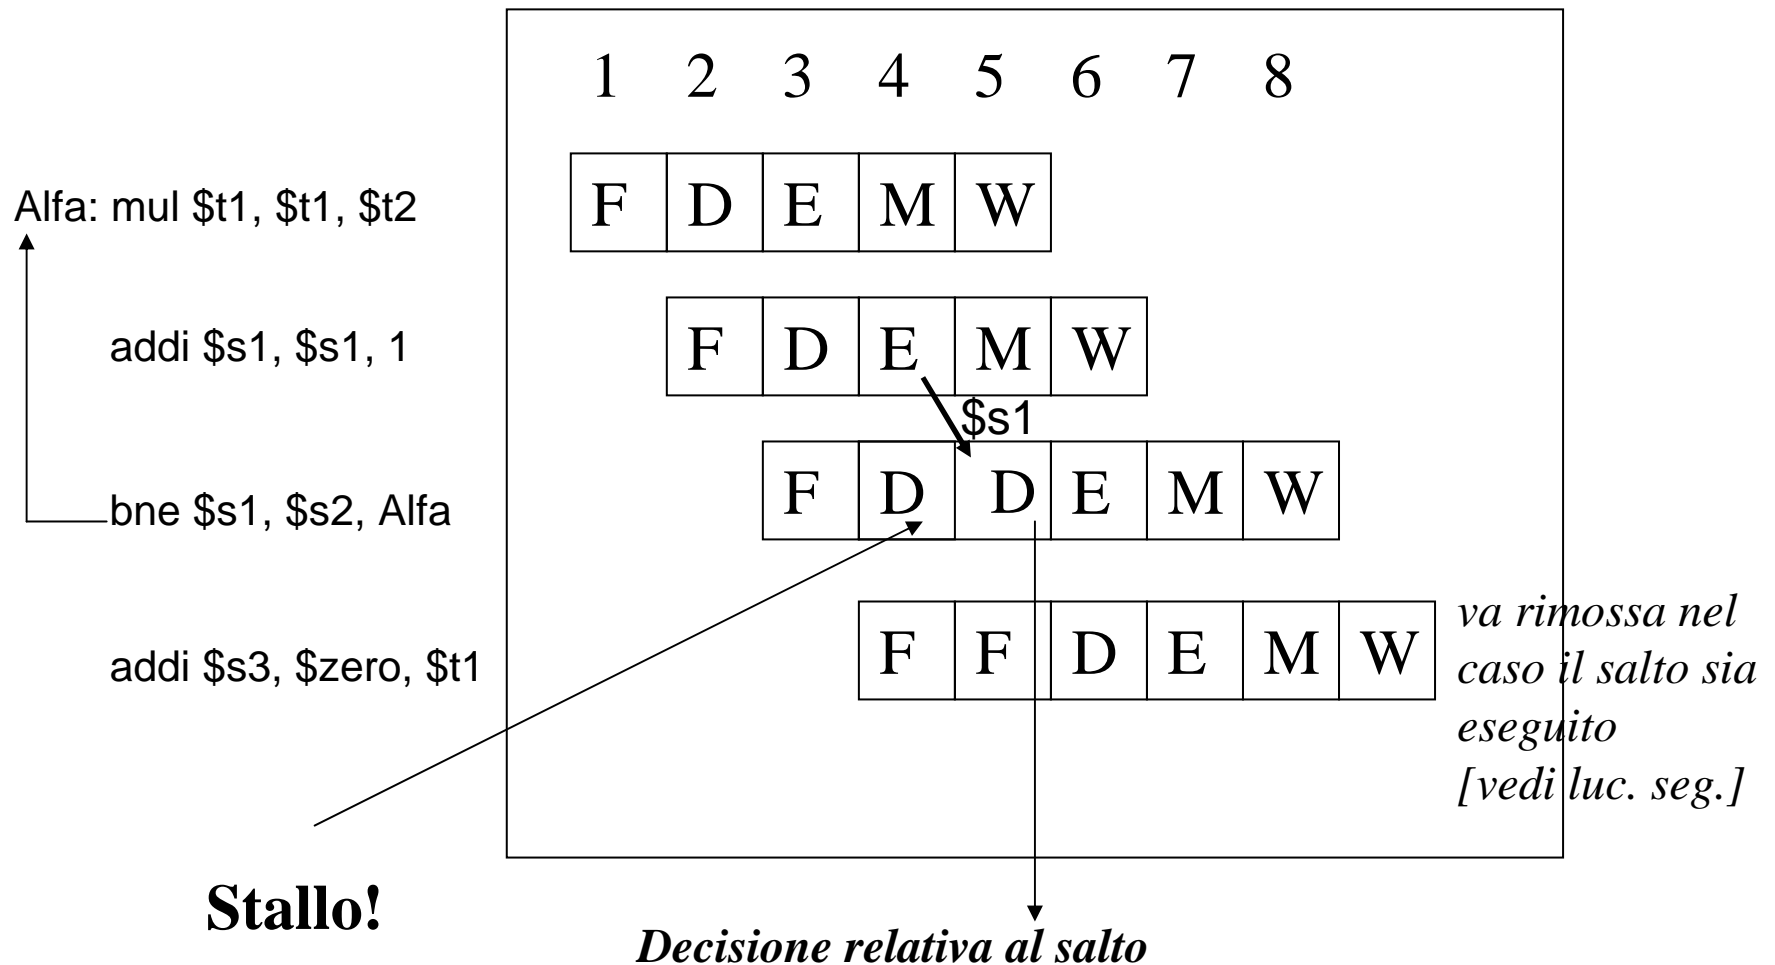
- pipeline a 5 stadi (F-D-E-M-W)
- 1 slot di ritardo

Tracciare il diagramma temporale:

- predizione statica di salto non eseguito
- salto ritardato (caso di salto eseguito)
- salto ritardato (caso di salto non eseguito)

NB: dalle specifiche si capisce che l'esecuzione del salto avviene necessariamente nello stadio D [1 slot di ritardo]

Diagramma temporale dell'esecuzione senza salto ritardato (pipeline a 5 stadi)



CASO SALTO ESEGUITO:

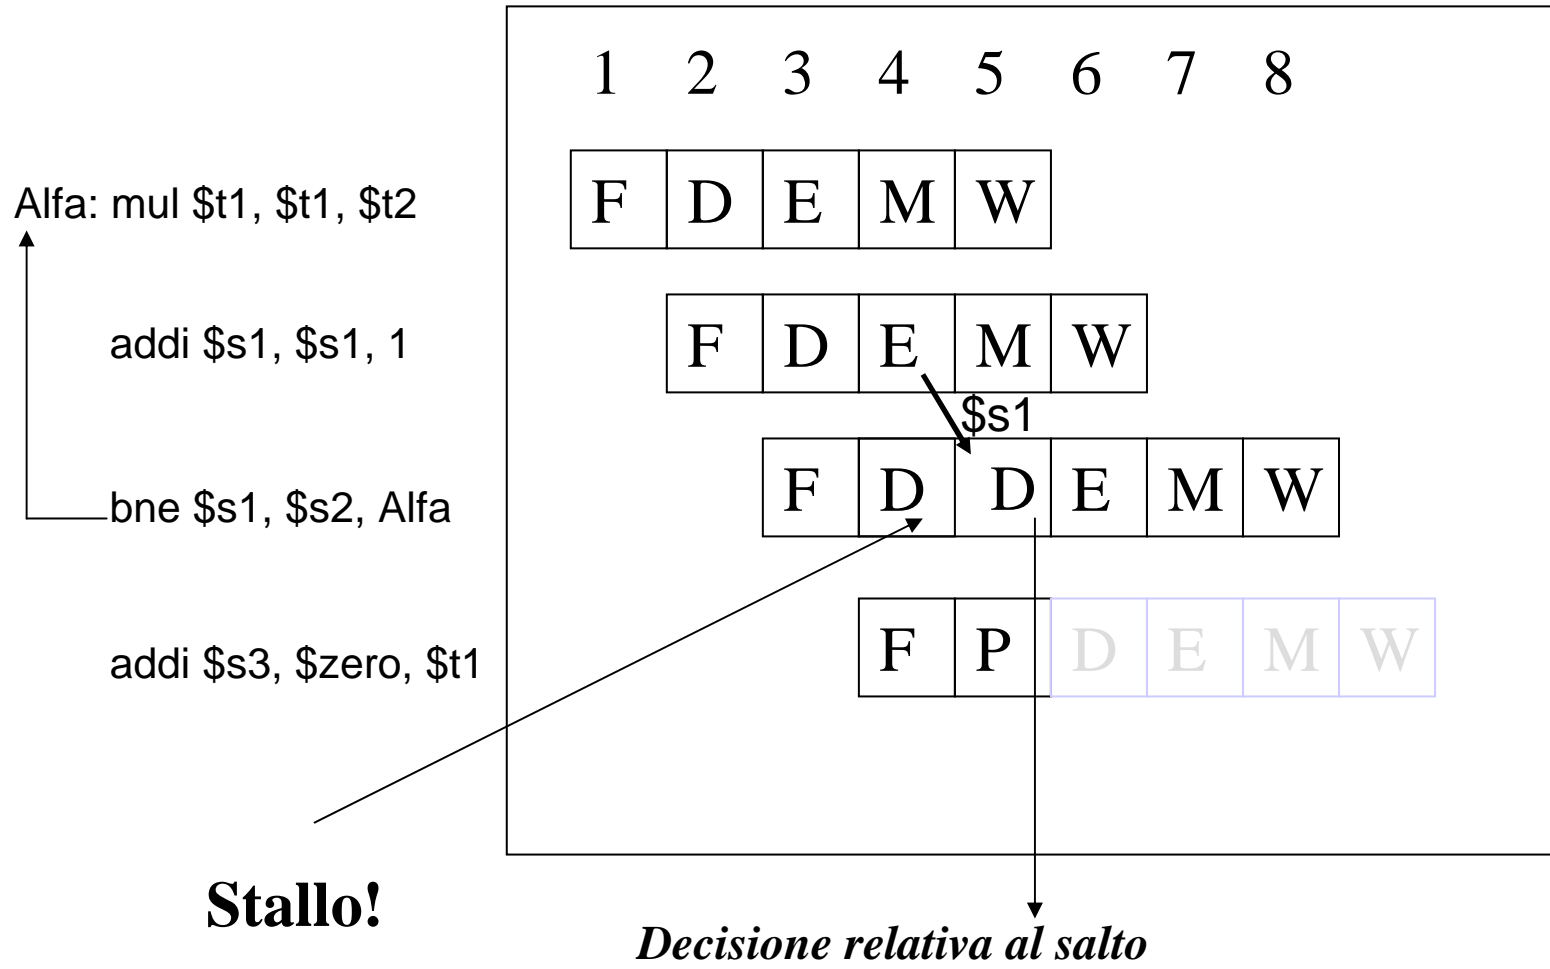


Diagramma temporale dell'esecuzione con salto ritardato: caso 1 (salto eseguito)

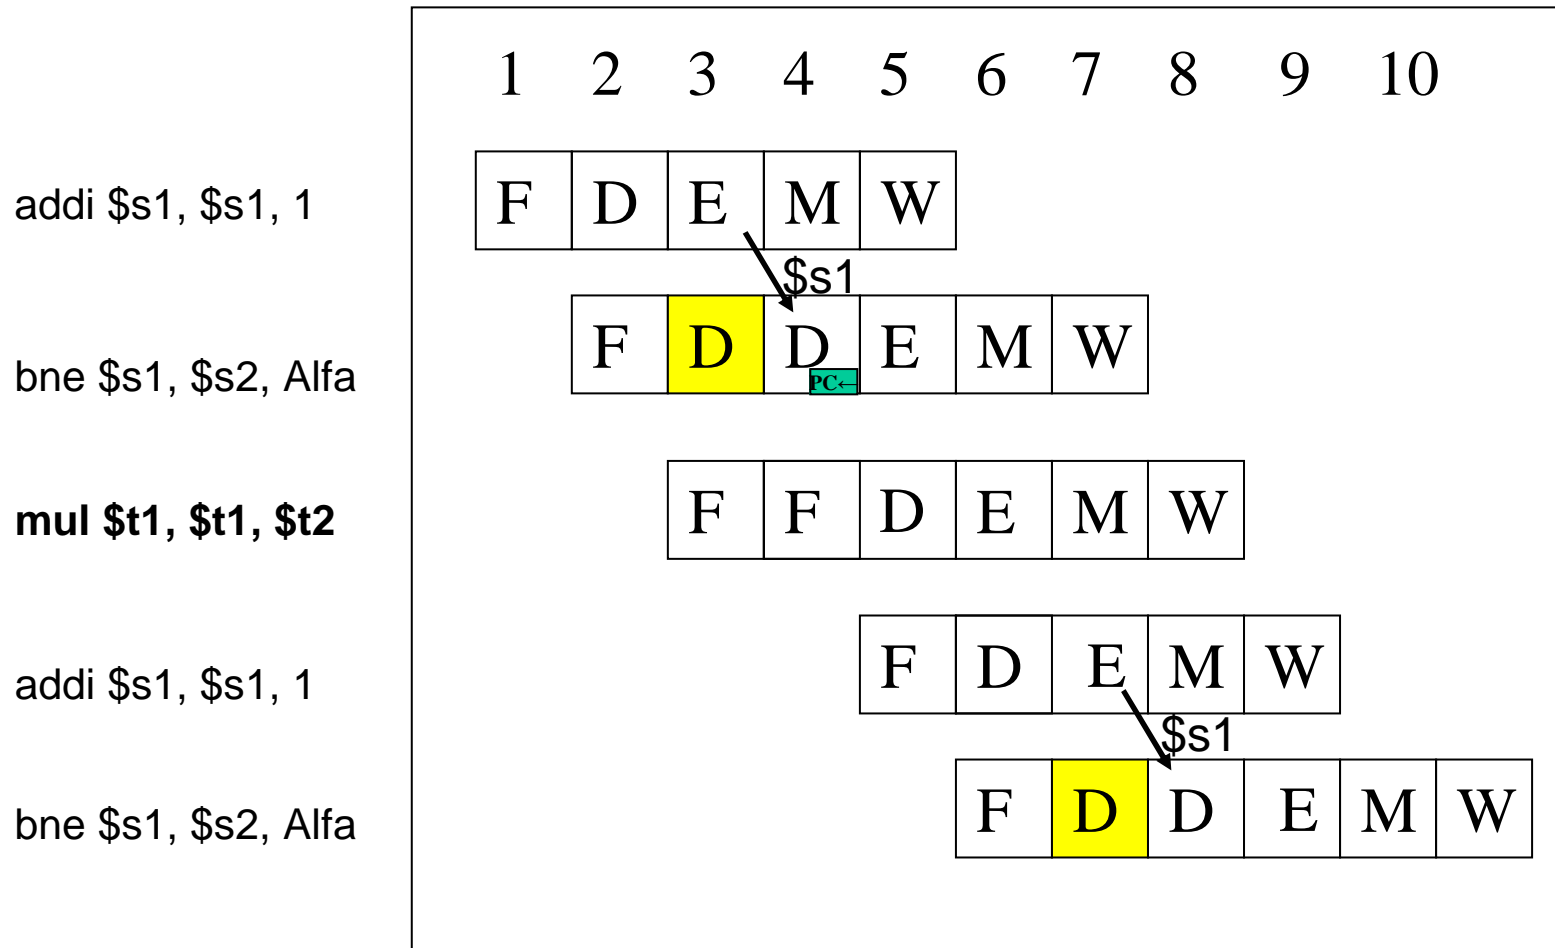
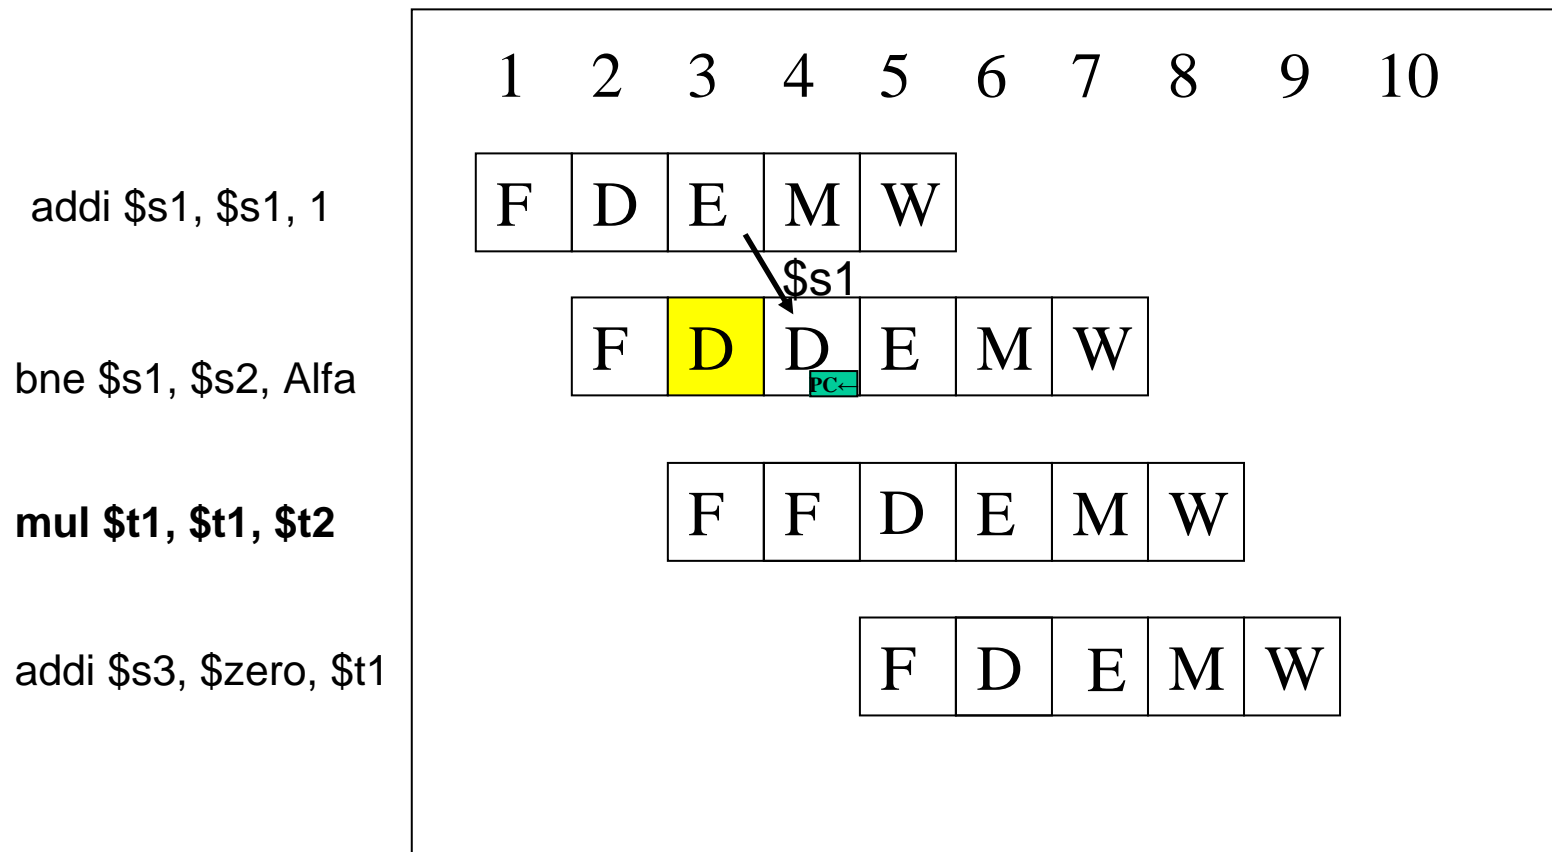


Diagramma temporale dell'esecuzione con salto ritardato: caso 2 (salto non eseguito)



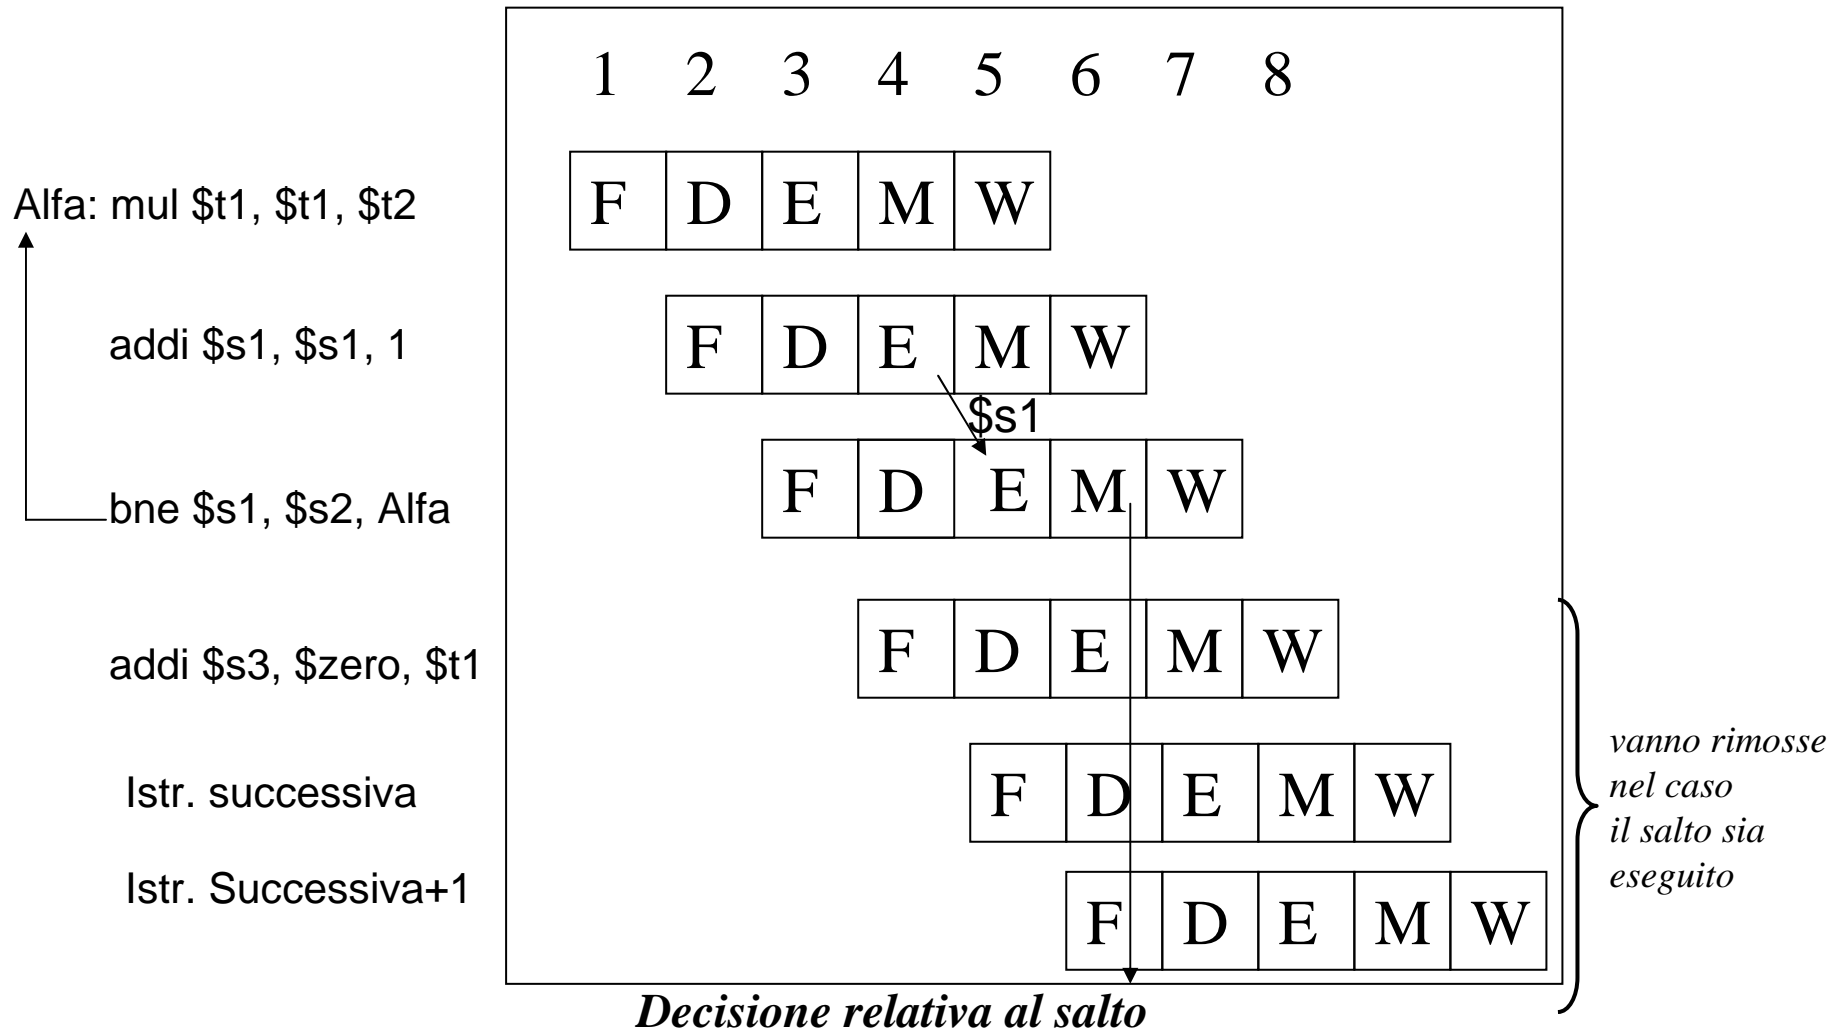
Variante BIS dell'esercizio

Supponiamo che (come nella prima implementazione del MIPS)
l'esecuzione del salto avvenga nello stadio M anziché nello stadio D
e la valutazione della condizione di salto nello stadio E
e ripetiamo l'esercizio (prediz. statica | salto ritardato)

```

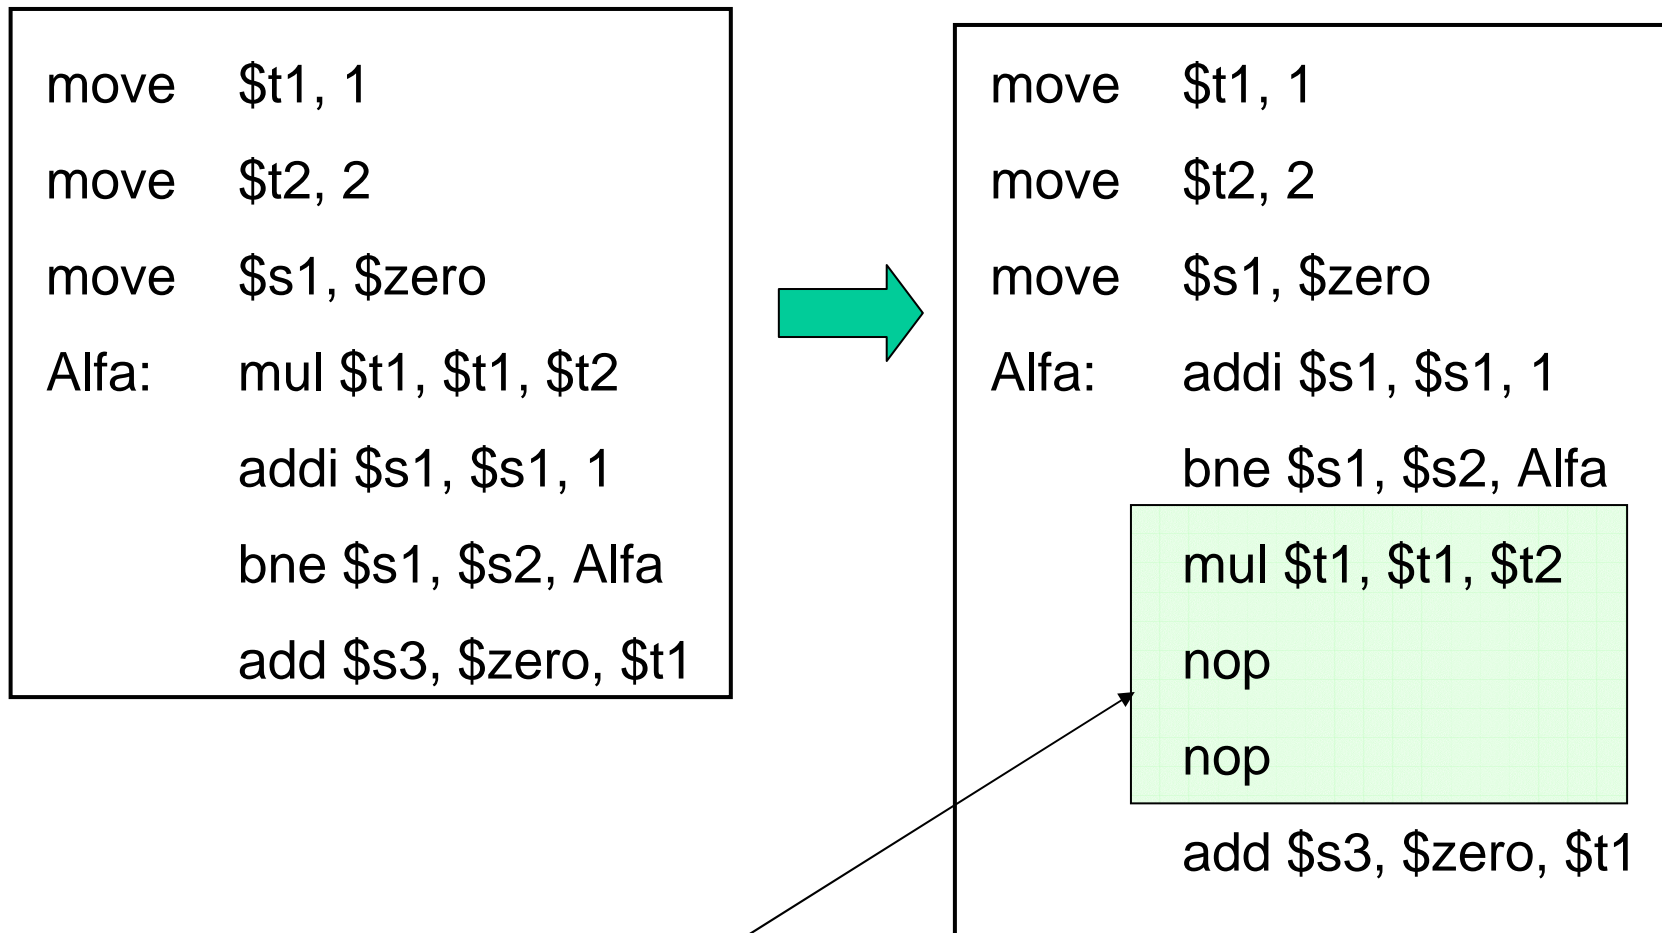
                move      $t1, 1           // prodotto parz.
                move      $t2, 2           // base=2
                move      $s1, $zero       // indice ciclo
Alfa:   mul        $t1, $t1, $t2
                addi      $s1, $s1, 1
                bne       $s1, $s2, Alfa
                add       $s3, $zero, $t1
```

Diagramma temporale dell'esecuzione senza salto ritardato (pipeline a 5 stadi) **Modifica PC relativa al salto nello stadio M**



Riordino delle istruzioni

Adesso gli slot da riempire sono tre! Ma abbiamo solo una istruzione disponibile!



Istruzioni inserite negli slot di ritardo

Diagramma temporale dell'esecuzione con salto ritardato: caso 1 (salto eseguito)

Modifica PC relativa al salto nello stadio M

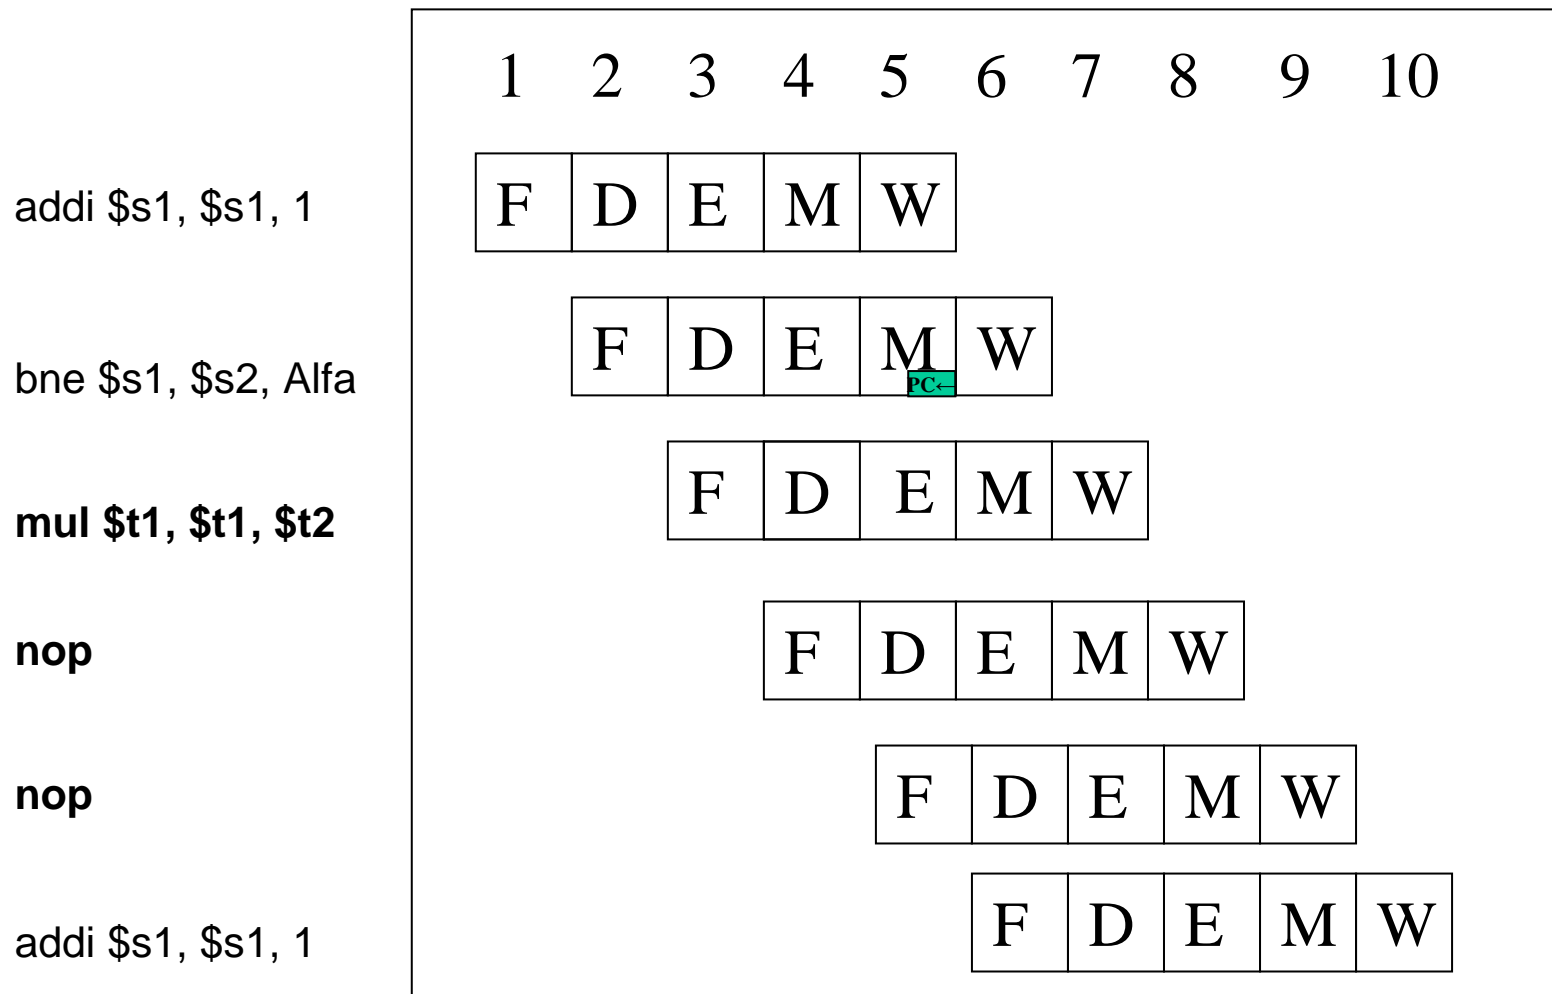
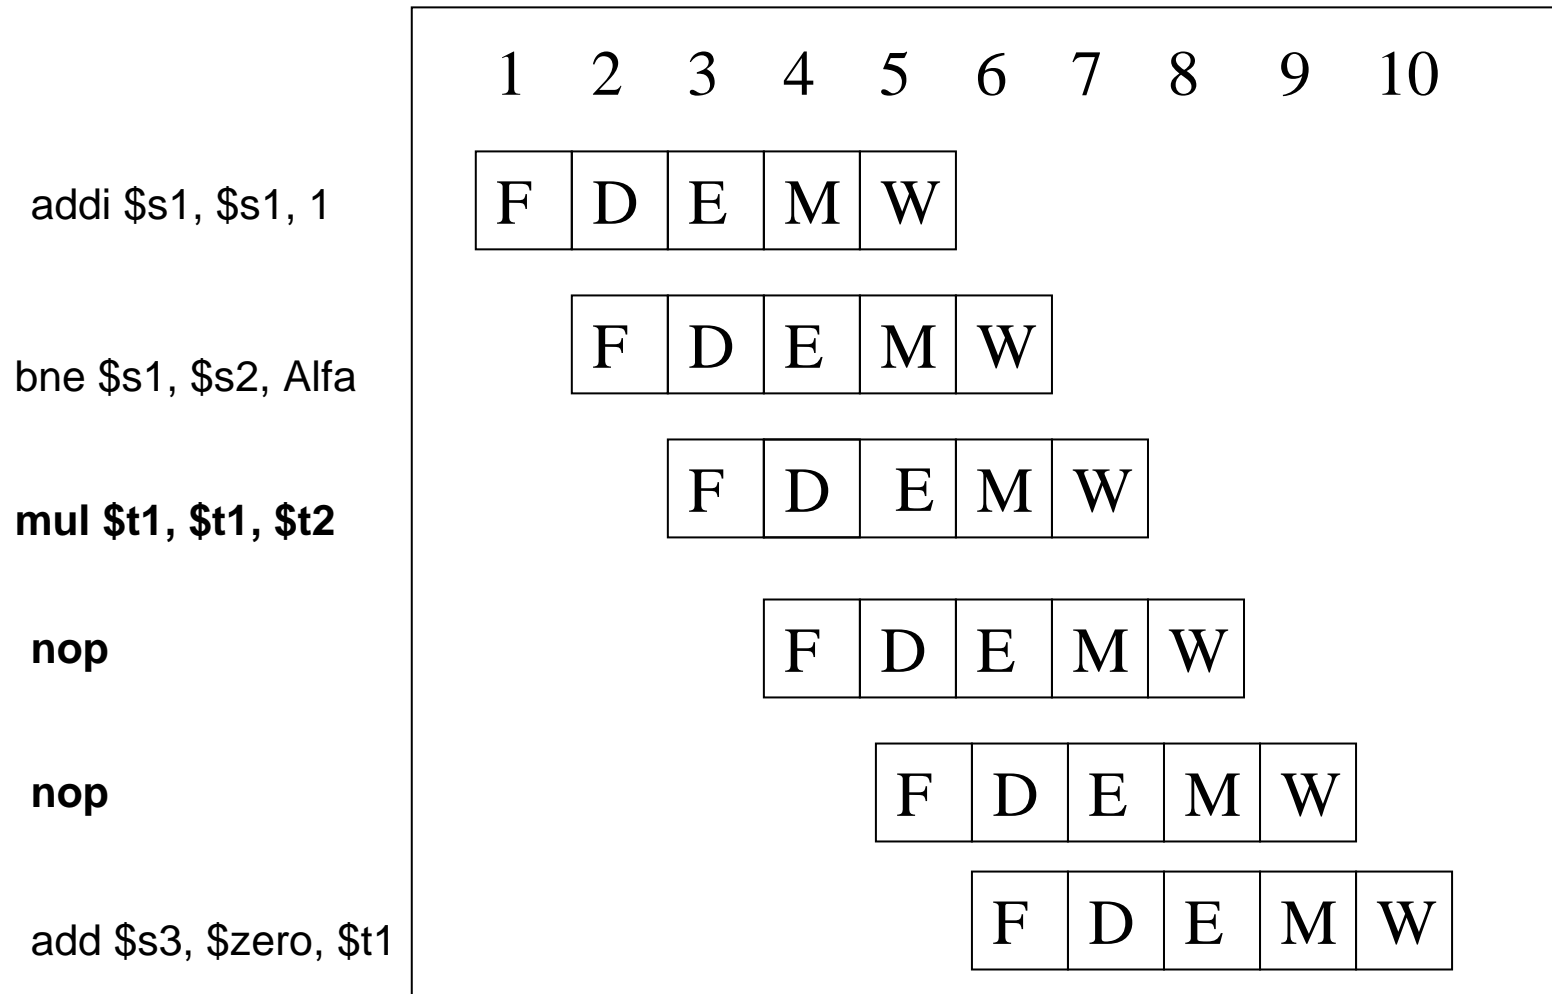


Diagramma temporale dell'esecuzione con salto ritardato: caso 2 (salto non eseguito)




Esercizio – Cicli e riordino delle istruzioni 2

- Segmento di codice in assembler Intel

```
Loop: shl      AX, 1
      dec      BX
      cmp      BX, 0
      jnz      Loop
      add      AX, DX
```

NB: fa lo shift a sinistra di AX per un numero BX volte

SI UTILIZZA IL SALTO RITARDATO E SI HA UN SOLO SLOT DI RITARDO.
SI CHIEDE DI RIORDINARE LE ISTRUZIONI IN MODO OPPORTUNO.



*Istruzione inserita nello slot di ritardo
(viene sempre eseguita)*

Per esercizio: analizzare l'esecuzione del codice su una pipeline a 2 stadi

Esercizio – Condizionale e riordino delle istruzioni

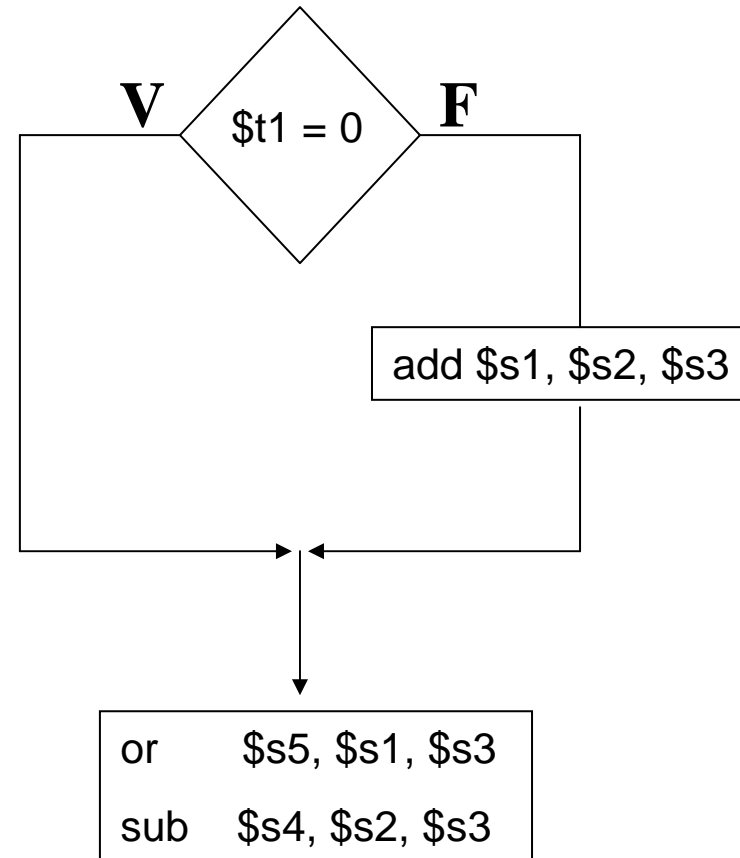
- Segmento di codice in assembler MIPS

```
        beq    $t1, $zero, Alfa
        add    $s1, $s2, $s3
Alfa:   or     $s5, $s1, $s3
        sub    $s4, $s2, $s3
```

Assumendo uno slot di ritardo,
riordinare il codice per gestire la criticità su beq

La logica del codice è:

Alfa: beq \$t1, \$zero, Alfa
 add \$s1, \$s2, \$s3
 or \$s5, \$s1, \$s3
 sub \$s4, \$s2, \$s3



QUINDI:

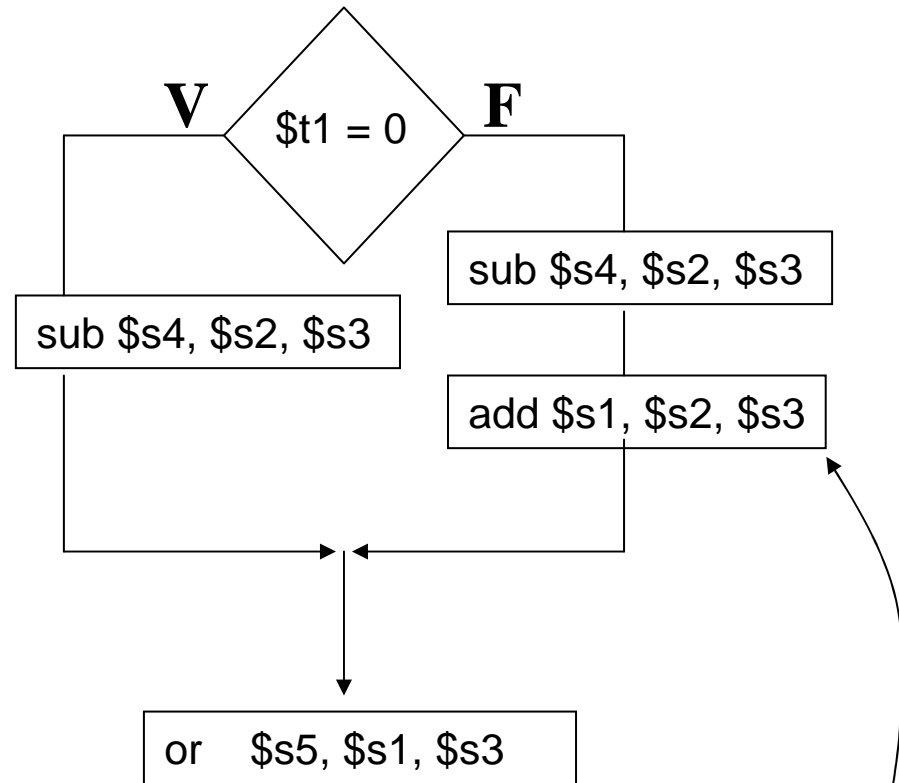
- Segmento di codice in assembler MIPS

```
beq    $t1, $zero, Alfa
```

```
sub    $s4, $s2, $s3
```

```
add    $s1, $s2, $s3
```

```
Alfa:  or    $s5, $s1, $s3
```



NB: notare che la *or* non la potevamo anticipare, perché dipende dal risultato di

Esercizio P.C: analizzare l'esecuzione del codice su una pipeline a 2 stadi e a 5 stadi

Esercizio – Salto ritardato e calcolo prestazioni 1

- Si ipotizzi che il 20% delle istruzioni eseguite da un calcolatore siano istruzioni di salto
- Il calcolatore adotta la tecnica del salto ritardato con 1 intervallo di ritardo
- Determinare il CPI nel caso in cui il compilatore sia in grado di utilizzare l'85% degli intervalli di ritardo (si assuma che non esistano altre cause di stallo oltre ai salti)

Soluzione:

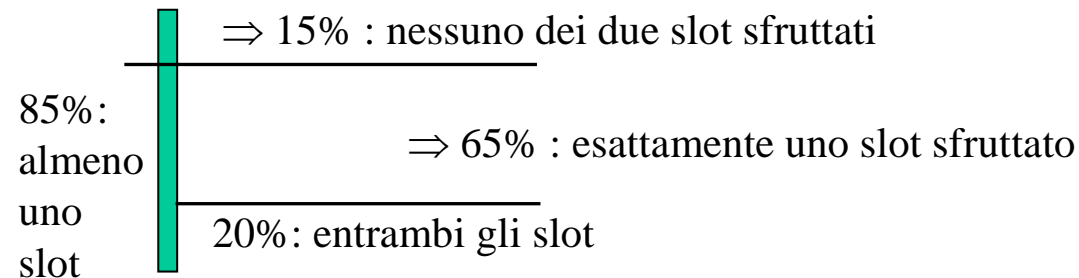
$$\text{CPI} = 1 + \underbrace{0,20 \times 0,15 \times 1}_{\text{Nel 15\% dei salti non viene utilizzato l'intervallo di ritardo, e quindi 1 ciclo viene perso}} = 1,3$$

Nel 15% dei salti non viene utilizzato l'intervallo di ritardo, e quindi 1 ciclo viene perso

Esercizio – Salto ritardato e calcolo prestazioni 2

- Si ipotizzi che il 20% delle istruzioni eseguite da un calcolatore siano istruzioni di salto
- Il calcolatore adotta la tecnica del salto ritardato con 2 intervalli di ritardo
- Determinare il CPI supponendo che il compilatore sia in grado di riempire almeno il primo intervallo nell'85% delle volte, entrambi gli intervalli nel 20% dei casi (si assuma che non esistano altre cause di stallo oltre ai salti)

Soluzione:



$$\Rightarrow \text{CPI} = 1 + 0,20 \times \underbrace{(0,15 \times 2)}_{\substack{\text{nel 15\% dei casi} \\ \text{perde 2 cicli}}} + \underbrace{0,65 \times 1}_{\substack{\text{nel 65\% dei casi} \\ \text{perde 1 ciclo}})} = 1,19$$

Dal Tema d'esame 13 lug 2005 [ES. 4]

Si consideri il seguente frammento di codice MIPS:

```
lw $s0, 20($t1)
```

```
beq $s0, $s1, Ndb
```

```
add $t2, $t2, $t2
```

```
Ndb: add $t2, $t2, $t3
```

```
sub $s2, $s2, $s3
```

Si consideri un'implementazione tramite pipeline a 6 stadi in cui la decisione e l'esecuzione del salto beq avvengono nel secondo stadio della pipeline. Per la gestione delle criticità sui salti, viene adottata la tecnica del salto ritardato. Quanti slot di ritardo sono presenti? Perché?

Si indichi, motivando brevemente la soluzione proposta, come potrebbe essere riordinato il codice per gestire la criticità sul salto beq.

[6]

Secondo stadio \Rightarrow uno slot di ritardo

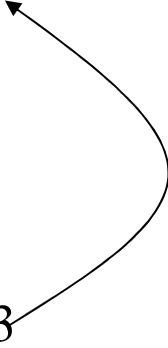
lw \$s0, 20(\$t1)

beq \$s0, \$s1, Ndb

add \$t2, \$t2, \$t2

Ndb: add \$t2, \$t2, \$t3

sub \$s2, \$s2, \$s3



Si vede che la

sub \$s2, \$s2, \$s3

viene eseguita a prescindere dall'esito del salto; possiamo allora anticiparla nello slot, cosicché viene eseguita subito. Ciò è lecito perché non altera i sorgenti delle istruzioni add né queste ultime alterano i sorgenti della sub.

Quindi la soluzione è

```
lw $s0, 20($t1)
```

```
beq $s0, $s1, Ndb
```

```
sub $s2, $s2, $s3
```

```
add $t2, $t2, $t2
```

```
Ndb: add $t2, $t2, $t3
```

Esercizio – predizione statica di “salto non eseguito”

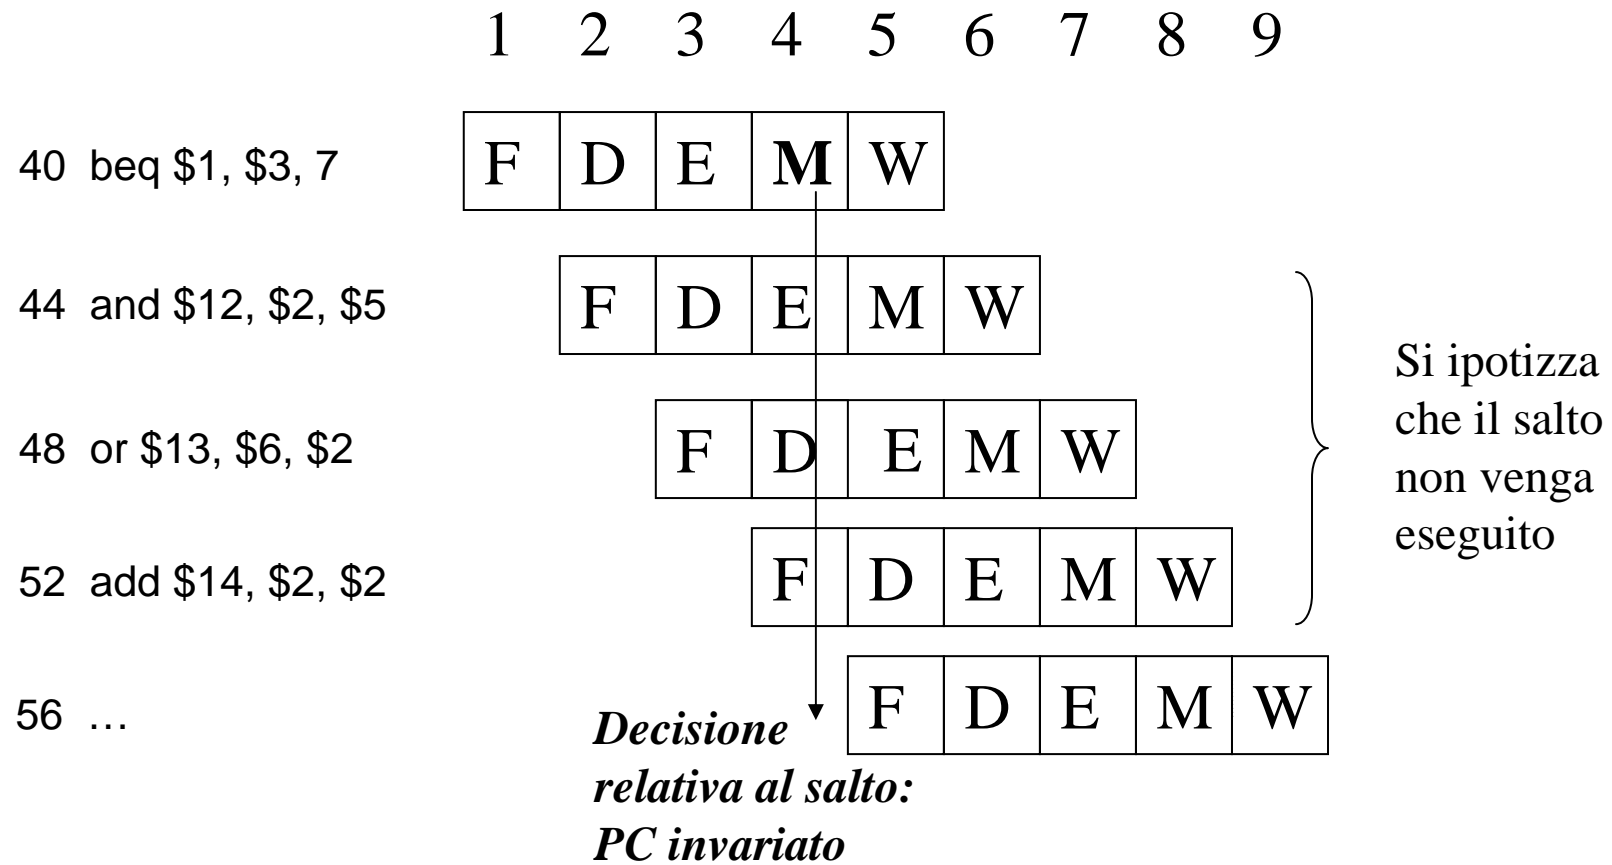
Parte 1

Si consideri il codice assembler:

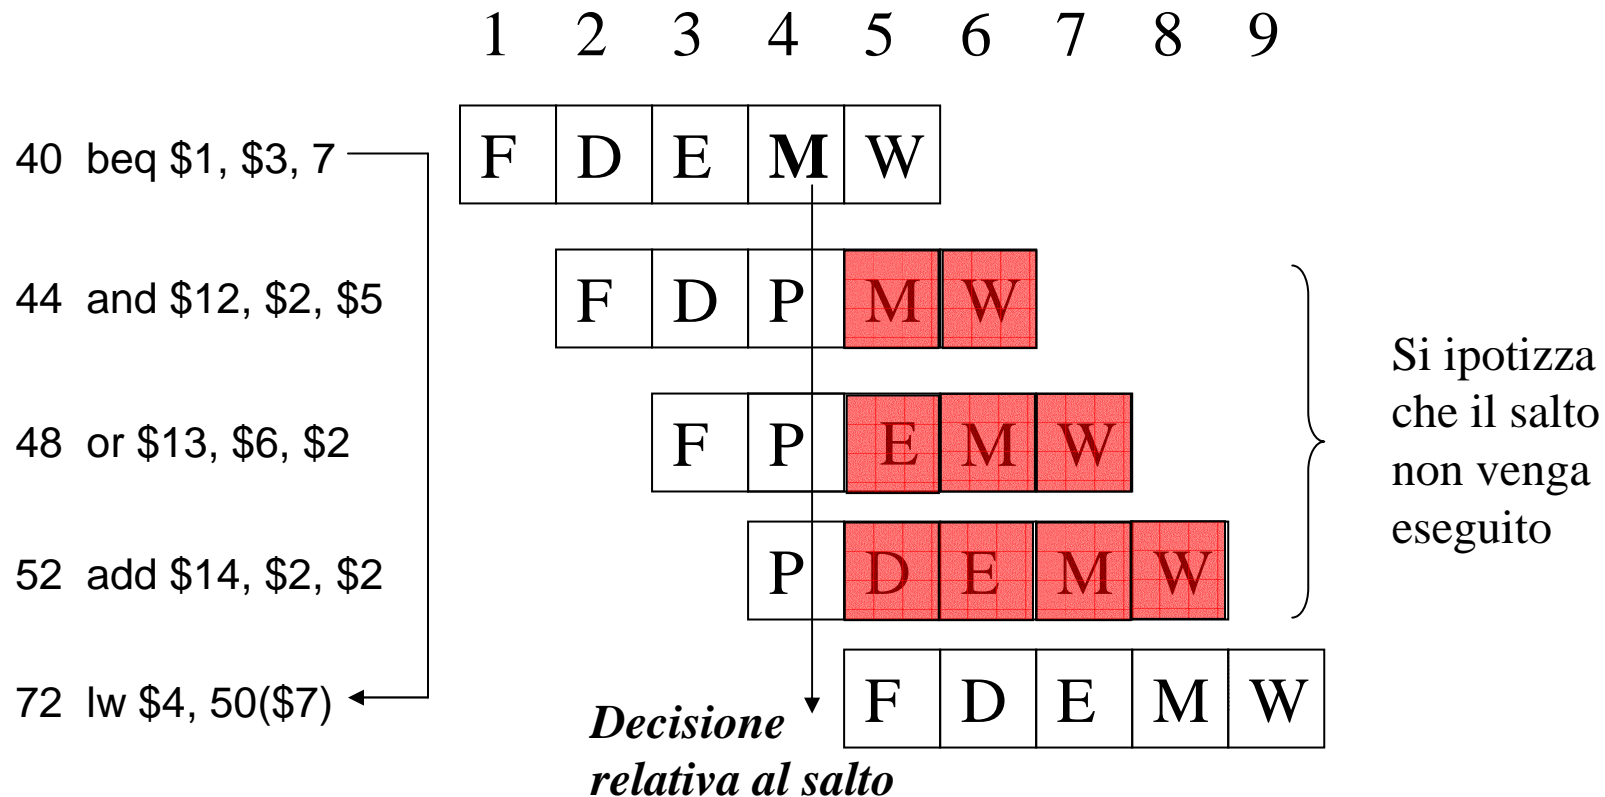
```
40      beq      $1, $3, 7          # salto a: 40 + 4 + 7*4 = 72
44      and      $12, $2, $5
48      or       $13, $2, $6
52      add      $14, $4, $2
...
72      lw       $4, 50($7)
```

- Si consideri la tecnica di previsione statica “ipotesi di salto non eseguito”.
- Si consideri una pipeline a 5 stadi (F, D, E, M, W) in cui la decisione del salto (e l’aggiornamento del PC) si effettuano nello stadio M:
 - ➡ Tracciare il diagramma temporale nell’ipotesi di previsione corretta e nell’ipotesi di previsione errata; indicare in questo caso il numero di cicli di ritardo.
 - ➡ Ripetere esercizio considerando salto in stadio D (al posto di M)

Se il salto non viene effettuato [previsione corretta] tutto procede normalmente:



Se il salto viene effettuato [previsione errata] nel ciclo di clock 4 è aggiornato PC [caricamento nuova istruzione di destinazione al ciclo di clock successivo]

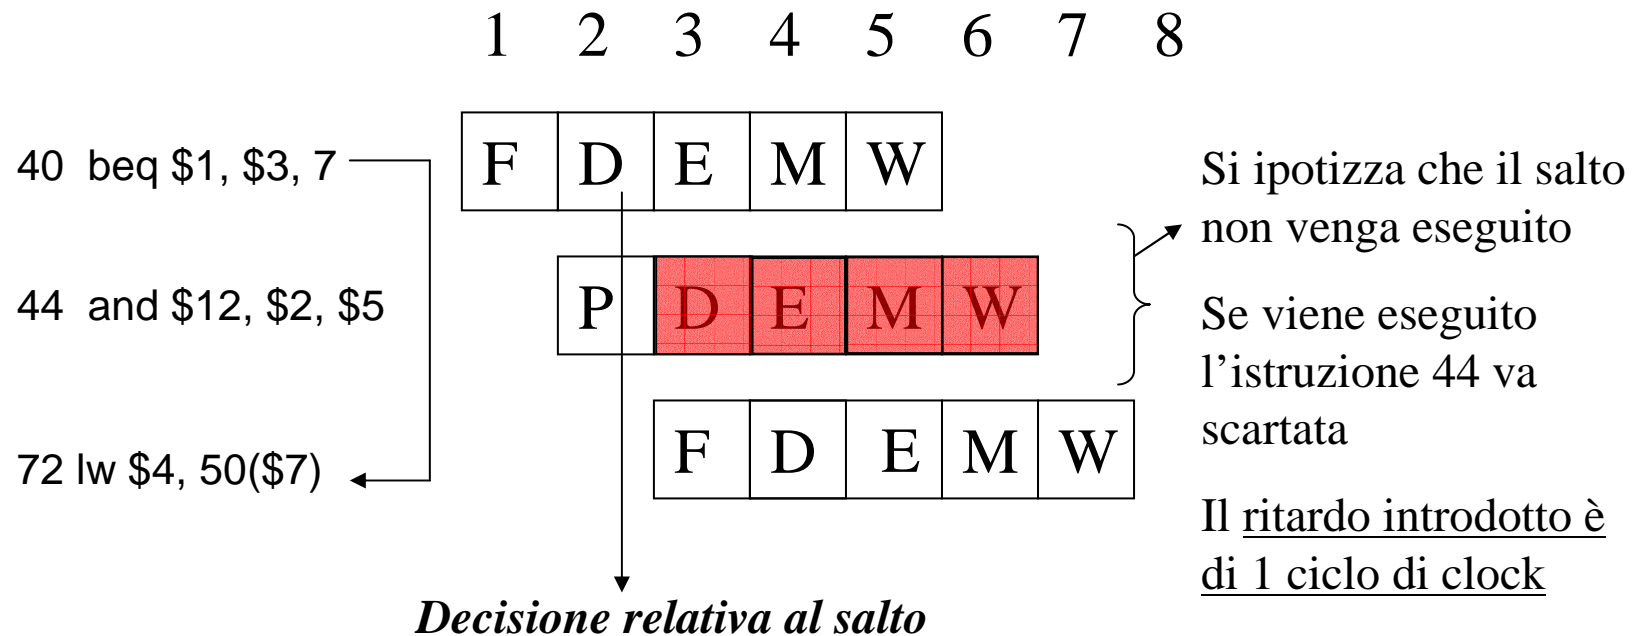


Se il salto viene effettuato [previsione errata], le istruzioni 44, 48, 52 vanno scartate, si introduce un ritardo di 3 cicli di clock.


In rosso sono indicate le bolle create nel ciclo di clock 4

- Spostando l'esecuzione dei salti dallo stadio M allo stadio D si riduce il ritardo a un solo ciclo:

nell'esempio se si verifica il salto, solamente l'istruzione 44 (di cui è stato fatto il fetch) va scartata



Parte 2

- Si consideri la seguente combinazione di istruzioni
 - 22% load, 11% store, 49% formato-R, 16% salti condizionati, 2% salti incondizionati
- Per esecuzione con pipeline [per branch, previsione di “salto non eseguito”]:
 - a) metà delle istruzioni di load seguita da un’istruzione che ne utilizza il risultato
 - b) un quarto dei salti condizionati sono oggetto di previsione errata
 - c) ritardo causato dai salti incondizionati pari a 1 ciclo di clock (in questo caso si suppone che il salto venga effettuato nello stadio di decodifica e che si usi lo stallo)
- Tempo di ciclo: 2 ns (per l’unità funzionale più lenta)
 -  Confrontare le prestazioni relative ad uno schema multiciclo e ad uno schema con pipeline [considerando le due ipotesi di esecuzione dei salti, ovvero in M o D]

Al solito, per il multiciclo:

Numero di cicli per ciascuna classe di istruzioni (fig. 5.42)

Load = 5

Store = 4

Formato-R = 4

Salti cond. = 3

Salti incond. = 3

$$\text{CPI} = 0,22 \times 5 + 0,11 \times 4 + 0,49 \times 4 + 0,16 \times 3 + 0,02 \times 3 = 4,04$$

$$\text{Tempo medio per istruzione} = 4,04 \times 2 \text{ ns} = \mathbf{8,08 \text{ ns}}$$

Per la pipeline (esecuzione salto nello stadio M: ritardo 3 cicli di clock):

Calcoliamo prima il numero di cicli di ritardo per ciascuna classe di istruzioni (nel caso di pipeline a regime):

$$\text{Load} = 0,22 \times 0,50 \times 1 = 0,11 \quad (\text{vedi (a)})$$

$$\text{Salti cond.} = 0,16 \times 0,25 \times n = 0,04 \times n \quad (\text{vedi (b)})$$

$$\text{Salti incond.} = 0,02 \times 1 = 0,02 \quad (\text{vedi (c)})$$

dove $n = 3$ [esecuzione salti cond. in stadio M] o $n=1$ [in stadio D]

$$\delta_M = 0,11 + 0,12 + 0,02 = 0,25$$

$$\delta_D = 0,11 + 0,04 + 0,02 = 0,17$$

Quindi:

$$\text{CPI}_M = 1 + \delta_M = 1,25$$

$$\text{Tempo medio esecuz. } 1,25 \times 2\text{ns} = 2,5\text{ns}$$

$$\text{CPI}_D = 1 + \delta_D = 1,17$$

$$\text{Tempo medio esecuz. } 1,17 \times 2\text{ns} = 2,34\text{ns}$$

Confronto prestazioni pipeline vs. multiciclo: speedup

NB: facciamo riferimento alla soluzione migliore – esecuzione salto in stadio D
[per l'altro caso il calcoli sono analoghi]

L'incremento delle prestazioni (o speedup) del processore con pipeline rispetto al processore multi-ciclo è dato da:

$$\text{Speedup} = \frac{\text{Tempo}_{\text{multiciclo}}}{\text{Tempo}_{\text{pipeline}}} = \frac{8,08}{2,34} = 3,45$$

Il tempo con pipeline ideale sarebbe 2 ns e quindi lo speedup nel caso ideale sarebbe

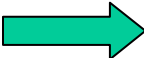
$$\text{Speedup} = \frac{\text{Tempo}_{\text{multiciclo}}}{\text{Tempo}_{\text{pipeline-ideale}}} = \frac{8,08}{2} = 4,04 (> 3,45)$$

Esercizio – predizione statica, stalli e dipendenze

Si consideri il codice assembler MIPS:

```
add    $t1, $s1, $s2
lw     $t0, 20($s4)
beq    $t0, $t1, Dest
sub    $s1, $s2, $s3
...
Dest:  add    $t1, $t0, $t0
```


- Si consideri una pipeline a 5 stadi (F, D, E, M, W) in cui l'indirizzo di destinazione dei salti è calcolato nello stadio D, la valutazione della condizione di salto (e l'aggiornamento di PC) nello stadio E
- Per i salti condizionati, si utilizza la predizione statica demandata al compilatore; in questo caso, il compilatore ha previsto che l'istruzione beq salti effettivamente

 Tracciare il diagramma temporale nell'ipotesi di previsione corretta e nell'ipotesi di previsione errata; indicare in entrambi i casi il numero di cicli di ritardo.

Prima cosa: non dimentichiamoci delle dipendenze sui dati!

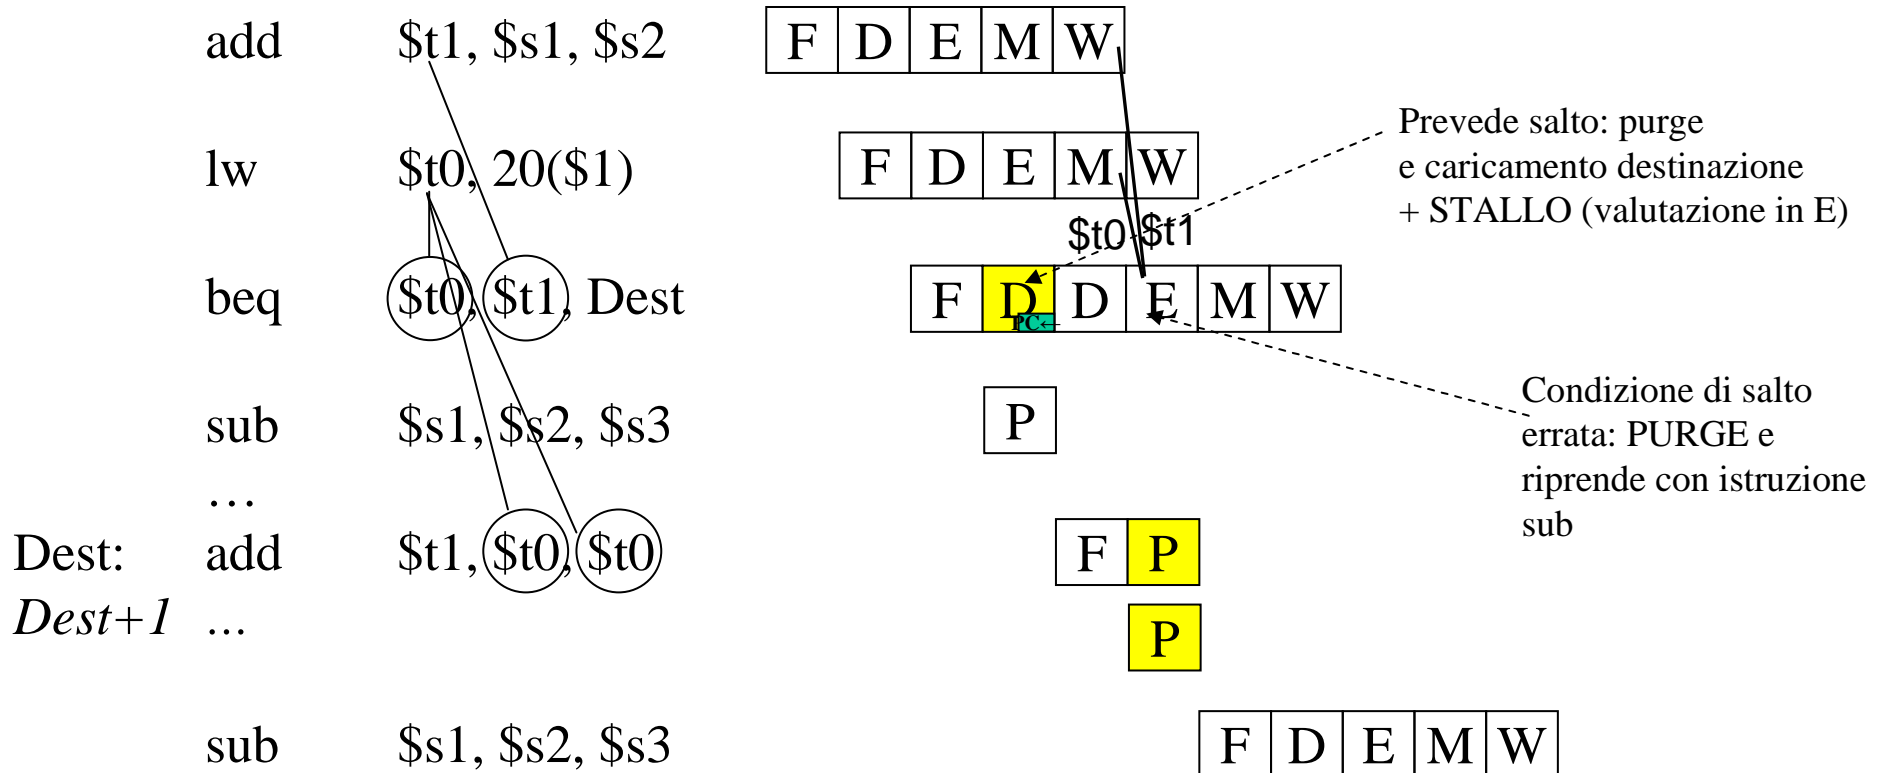
beq: calcola destinazione in D, valuta operandi in E

Caso “predizione di salto” corretta



In totale, ho penalità di un solo ciclo!

Caso “predizione di salto” errata



In totale, ho penalità di tre cicli
 (1 per stallo dipendenza dati e 2 persi per la predizione errata)

Dal Tema d'esame 10 gen 2007 [ES. 4]

Si consideri un processore MIPS implementato tramite pipeline a 5 stadi, per la quale si utilizza un hardware che richiede i seguenti tempi di esecuzione: prelievo istruzione e accesso alla memoria dati 2 ns, lettura e scrittura Register File 1 ns, Operazione ALU, decodifica: 2 ns.

Si assuma un carico di lavoro che prevede la seguente distribuzione delle istruzioni:

lw:	20 %
sw:	20 %
formato-R:	40 %
beq:	15 %
j:	5 %

Si calcoli il tempo medio di esecuzione considerando solo le criticità sui salti, assumendo le seguenti ipotesi:

- i salti incondizionati non comportano mai alcuna penalità
- per i salti condizionati, si utilizza la tecnica di predizione statica demandata al compilatore; l'indirizzo di destinazione è calcolato nello stadio D, mentre la valutazione della condizione di salto e l'aggiornamento del program counter sono effettuati nello stadio E
- ogni salto condizionato beq effettua il salto nell'80% dei casi, non lo effettua il rimanente 20%; in entrambe le situazioni, l'accuratezza della predizione della condizione di salto è pari al 90%.

Soluzione

$$\begin{aligned} T_{\text{es.istruz.}} &= \text{CPI} * T_{\text{clock}} \\ &= (1 + \delta_{\text{salti}}) * T_{\text{clock}} \end{aligned}$$

→ $T_{\text{clock}} = 2 \text{ ns}$ (non ci sono due operazioni critiche in serie, la più gravosa è 4 ns)

→ Cicli_stallo (dovuti solo a criticità sui salti):

- j: penalità nulla (per ipotesi)
- beq: presenti nel 15% dei casi (cfr. carico di lavoro)
 - Predizione corretta (probabilità 90%):
 - Salto non effettuato: penalità 0
 - Salto effettuato (prob. 80%): penalità 1 (aspetto calcolo destinazione in D)
 - Predizione errata:
 - Salto non effettuato: penalità 2 (aspetto calcolo condizione in E)
 - Salto effettuato: penalità 2 (aspetto calcolo condizione in E)

→ $\delta_{\text{salti}} = 0.15 * (0.9 * 0.8 * 1 + 0.1 * 2) = 0.138$

→ $T_{\text{es}} = (1 + 0.138) * 2\text{ns} = 2.476 \text{ ns}$

Esercizio – Prestazioni e predizione dinamica con BTB

Si consideri una pipeline a 5 stadi in cui la valutazione della condizione di salto e l'aggiornamento del Program Counter avvengono nel terzo stadio (EX).

Si valutino le due seguenti soluzioni progettuali per la gestione dei salti condizionati:

- Predizione statica di “salto non effettuato”
- Predizione dinamica che utilizza un BTB in grado di fornire un indirizzo di destinazione sempre corretto ed un'accuratezza nella predizione della condizione di salto pari al 90%

In particolare, detta P la percentuale con cui i salti condizionati in media effettuano il salto, si valuti quale delle due soluzioni è preferibile in funzione di P .

Soluzione 1 “predizione salto non effettuato”

- Salto non effettuato (probabilità $1-P$):
Penalità 0
- Salto effettuato (probabilità P):
Penalità 2 [aggiornamento PC e “purge” al terzo stadio:
elimino due istruzioni]

$$\rightarrow \delta_{\text{miss}}^1 = P*2$$

Soluzione 2 “predizione dinamica”

- Predizione corretta (probabilità 90%):
Penalità 0 [infatti si utilizza direttamente l’indirizzo
di destinazione corretto]
- Predizione errata (probabilità 10%):
Penalità 2 [aggiornamento PC e “purge” al terzo stadio:
elimino due istruzioni]

$$\rightarrow \delta_{\text{miss}}^2 = 0,1*2 = 0,2$$

Confronto

Preferibile la soluzione 1 se $P*2 < 0,2$ ovvero salti eseguiti con frequenza inferiore al 10%

Dal Tema d'esame 20 luglio 2006 [ES. 5]

Si consideri l'implementazione del processore con pipeline a 5 stadi che utilizza la predizione dinamica sui salti mediante BTB (Branch Target Buffer).

Per i salti condizionati, si ipotizzi in particolare che:

- la condizione di salto sia valutata nello stadio D
- il calcolo dell'indirizzo di destinazione effettivo sia effettuato nello stadio E

Si consideri il seguente frammento di codice MIPS:


```
                beq    $s0, $s1, Dest
                add    $t0, $t1, $t2
                ...
Dest:           add    $t0, $t0, $t1
                sub    $t3, $t0, $t0
```

Si chiede di tracciare il diagramma temporale delle istruzioni nell'ipotesi in cui il BTB preveda per l'istruzione beq che il salto venga effettuato ma la predizione sia errata (ovvero il salto in realtà non venga effettuato) e di indicare il numero di cicli di penalità.

[3]

Soluzione

```
        beq    $s0, $s1, Dest
        add    $t0, $t1, $t2
        ...
Dest:    add    $t0, $t0, $t1
        sub    $t3, $t0, $t0
```



 Un ciclo di penalità