

HY425  
Αρχιτεκτονική Υπολογιστών

Static Scheduling

Ιάκωβος Μαυροειδής

# Τεχνικές ελάττωσης stalls.

CPI = Ideal CPI + Structural stalls + RAW stalls + WAR stalls +  
WAW stalls + Control stalls

Θα μελετήσουμε δύο ειδών τεχνικές

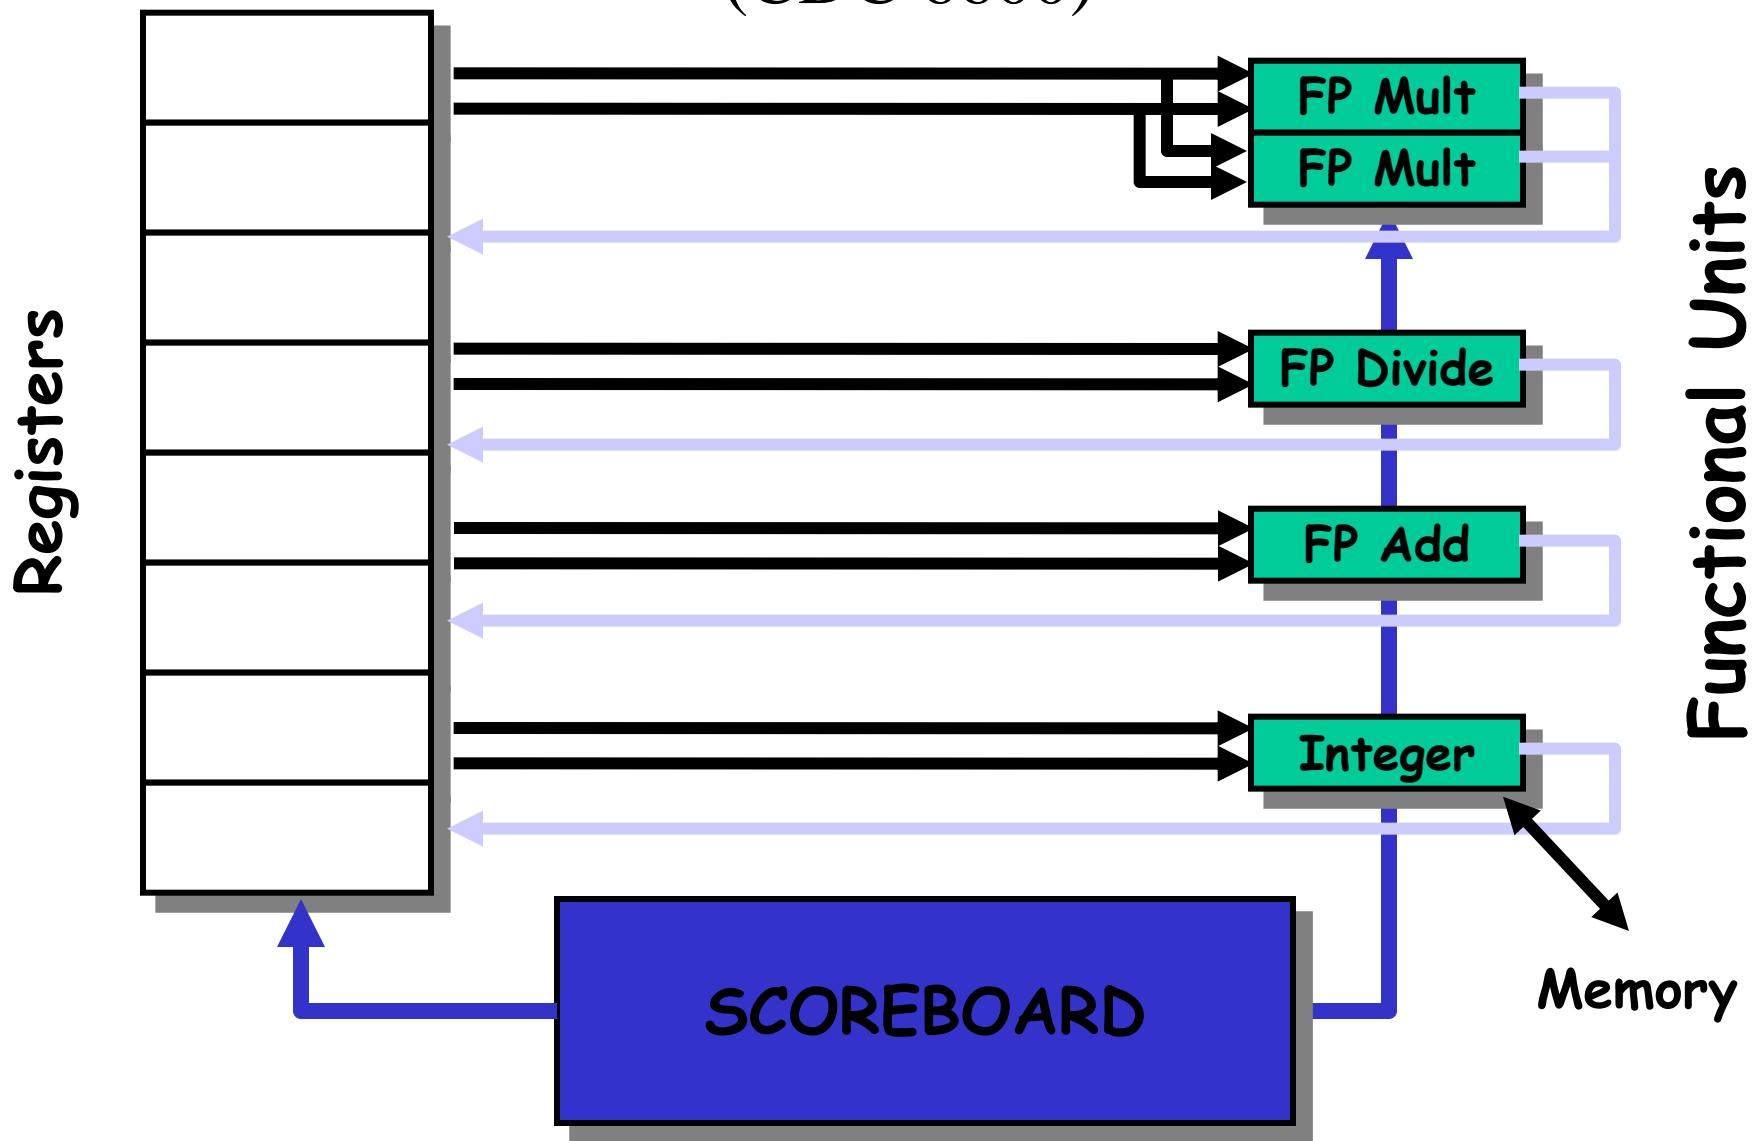
Δυναμικές δρομολόγηση  
εντολών (hardware)

- Scoreboard (ελάττωση RAW stalls)
- Register Renaming
  - a) Tomasulo
  - β) Reorder Buffer  
(ελάττωση WAR και WAW stalls)
- Branch prediction  
(ελάττωση Control stalls)

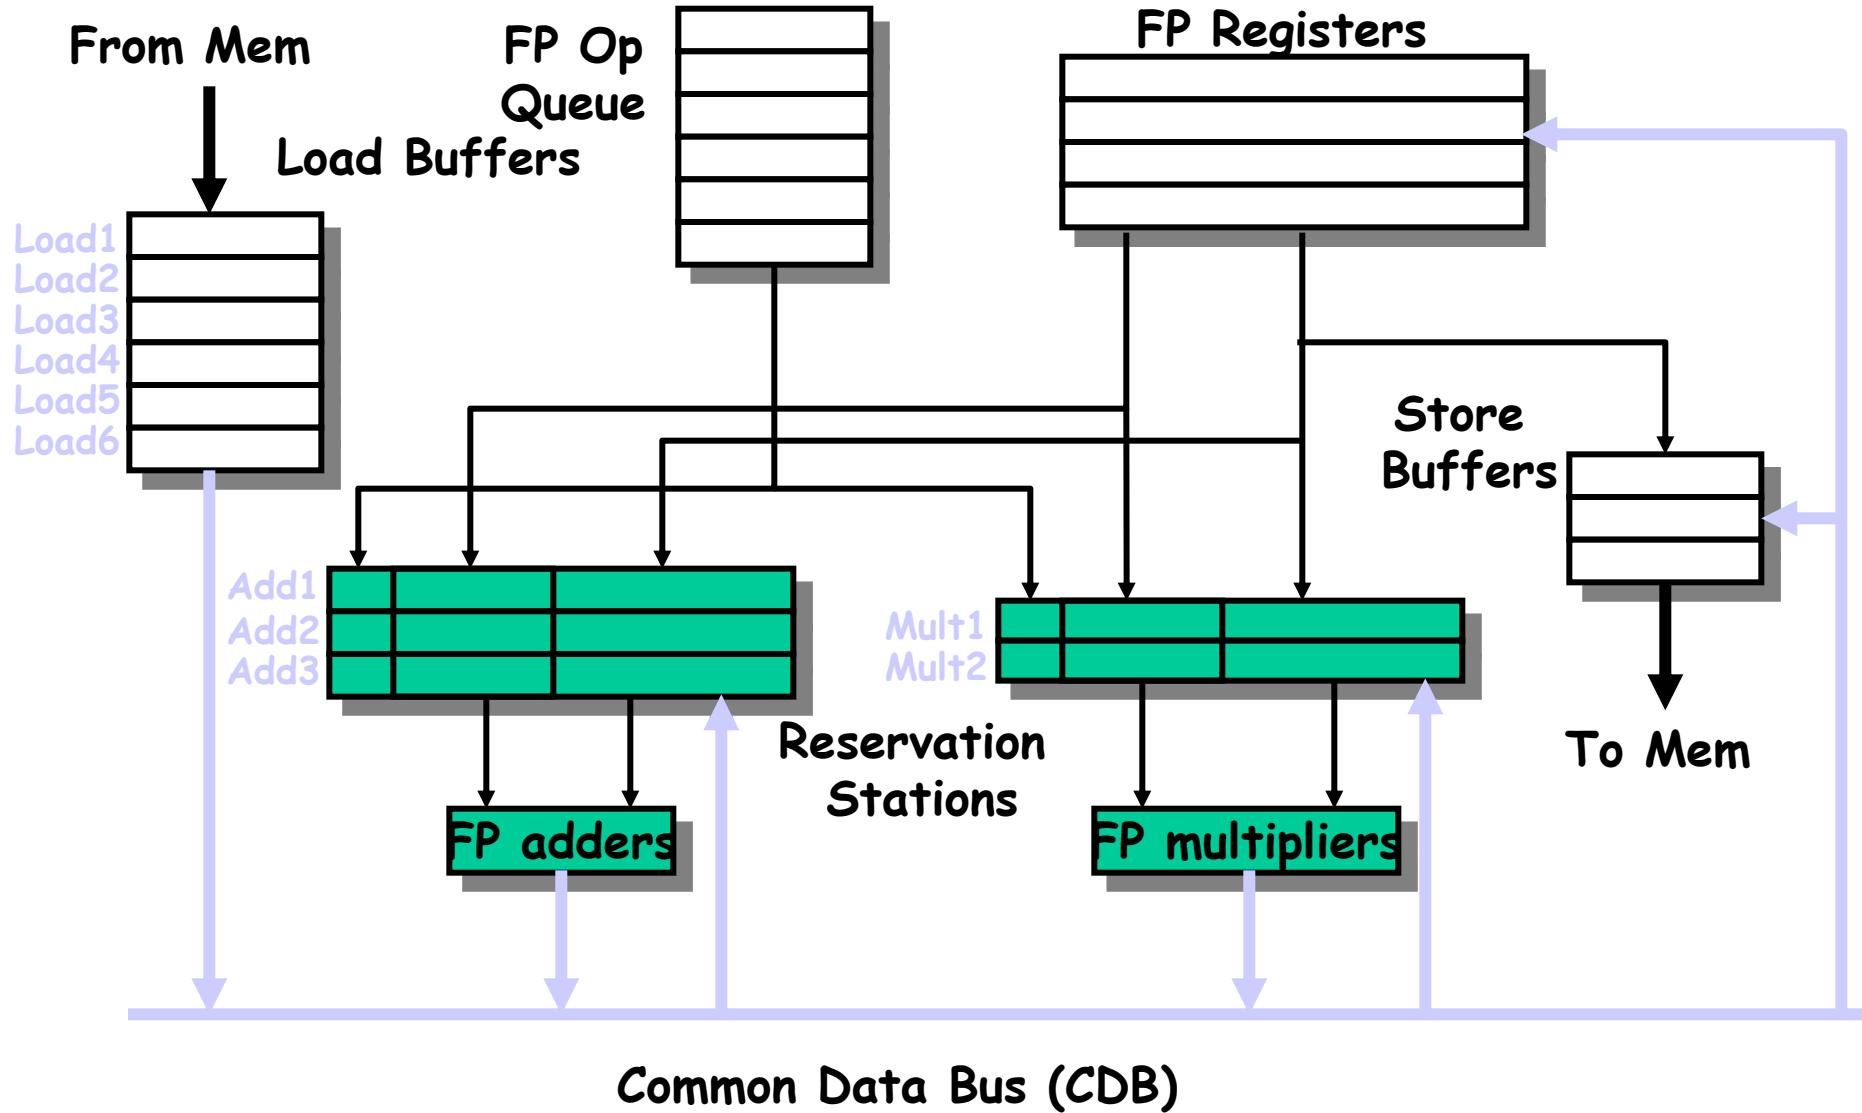
Στατικές (software/compiler)

- Loop Unrolling
- Software Pipelining
- Trace Scheduling

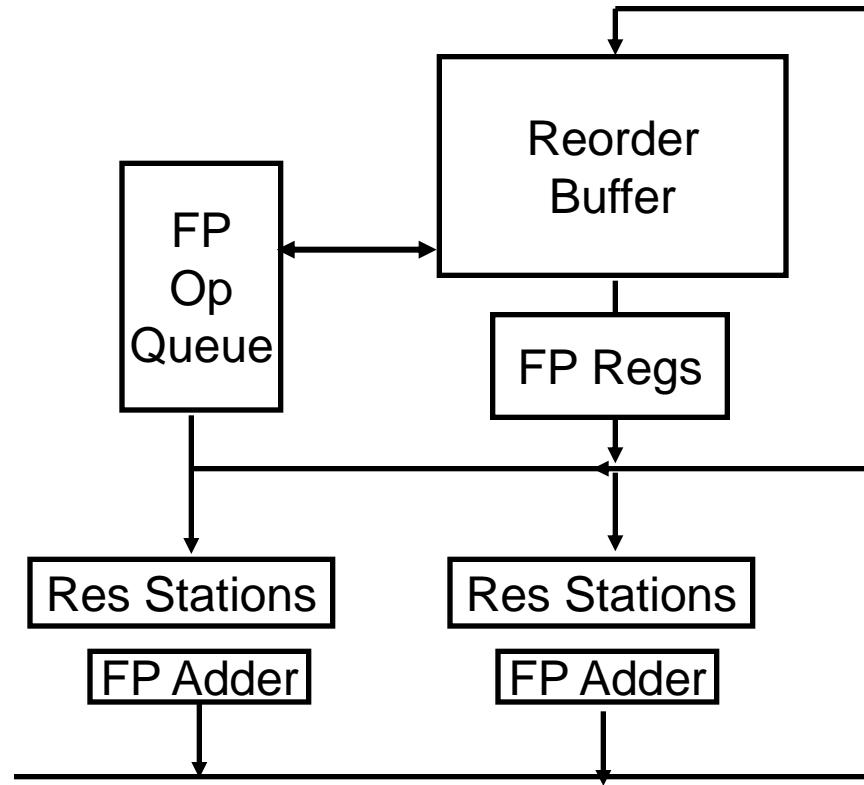
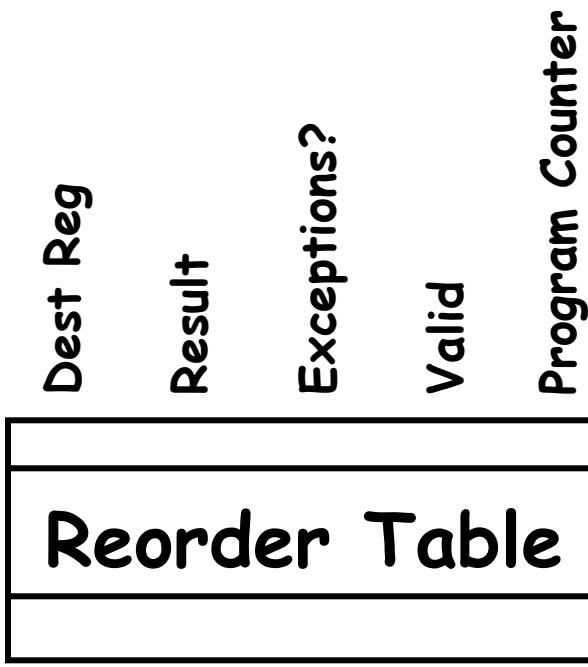
# Αρχιτεκτονική Scoreboard (CDC 6600)



# Tomasulo Organization

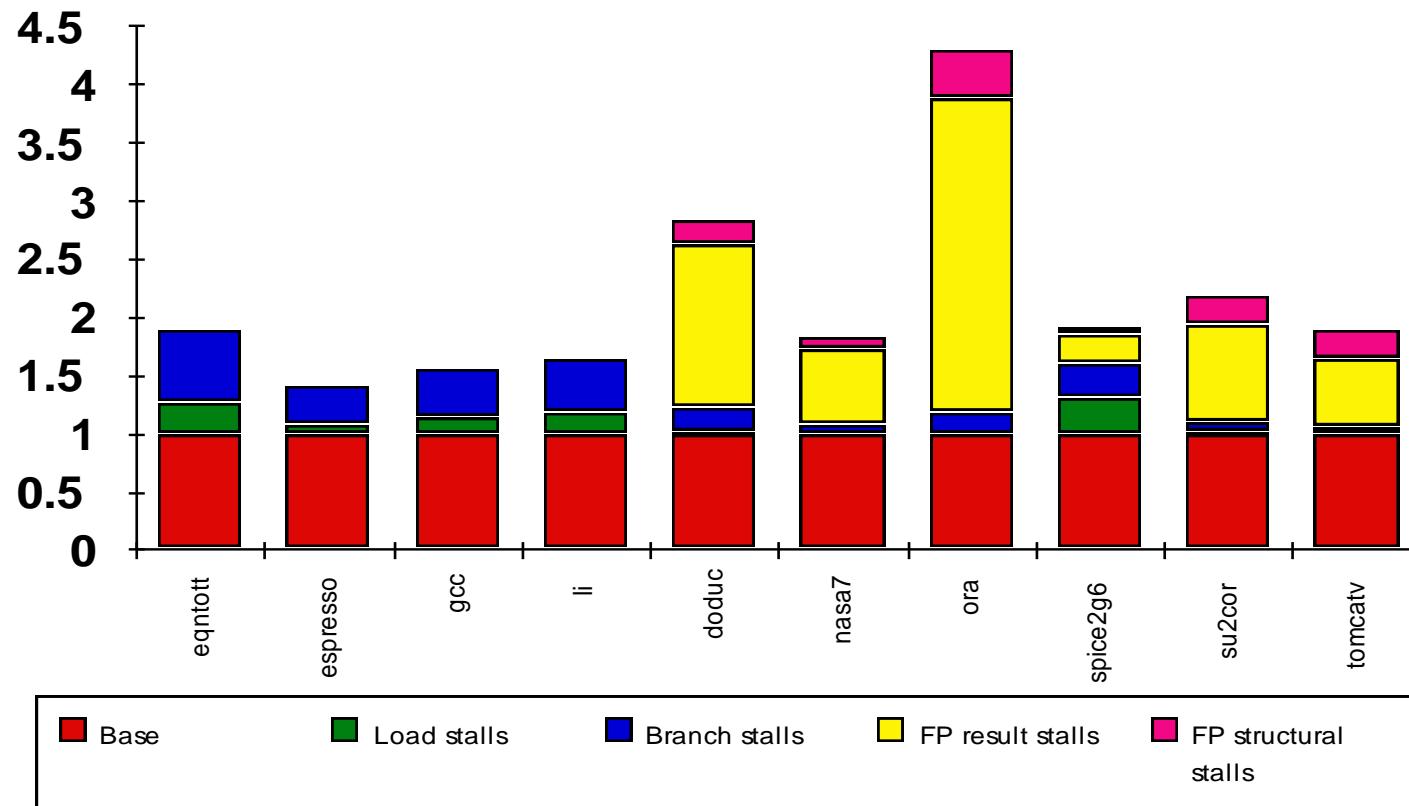


# Reorder buffer (ROB)



# R4000 Performance

- Μη ιδανικό CPI :
  - Load stalls (1 ή 2 clock cycles)
  - Branch stalls (2 cycles + unfilled slots)
  - FP result stalls: RAW data hazard (latency)
  - FP structural stalls: Not enough FP hardware (parallelism)

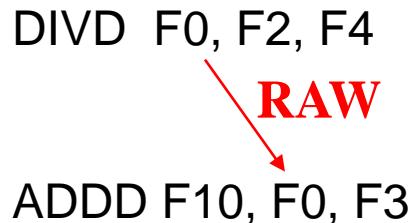


# Instruction Level Parallelism (ILP)

- ILP: Παράλληλη εκτέλεση μη συσχετιζόμενων (μη εξαρτόμενων) εντολών.
- gcc 17% control transfer εντολές
  - 5 εντολές + 1 branch
  - Πέρα από ένα block για να έχουμε περισσότερη instruction level parallelism
- Loop level parallelism one opportunity
  - First SW, then HW approaches

# Εξαρτήσεις Μεταξύ Εντολών (Depedences)

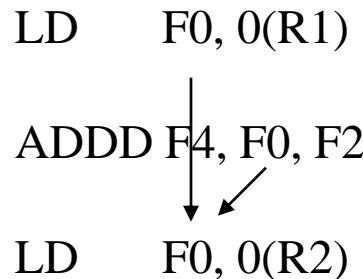
- Ποιές είναι οι πηγές των stall/bubbles; Εντολές που χρησιμοποιούν ίδιους registers.
  - Παράλληλες εντολές μπορούν να εκτελεστούν διαδοχικά χωρίς να δημιουργούν stalls. Π.χ.  
DIVD F0, F2, F4  
ADDD F10, F1, F3
  - Εξαρτήσεις μεταξύ εντολών μπορούν να οδηγήσουν σε stalls. Π.χ.



- Οι εξαρτήσεις μεταξύ εντολών περιορίζουν την σειρά εκτέλεσεις των εντολών (in order execution) π.χ. η ADDD πρέπει να εκτελεστεί μετά την DIVD στο 2o παράδειγμα. Ενώ παράλληλες εντολές μπορούν να εκτελεστούν ανάποδα (out of order execution) π.χ. η ADDD μπορεί να εκτελεστεί πριν την DIVD στο 1o παράδειγμα.

# Εξαρτήσεις Μεταξύ Εντολών

- Data Dependences** : Δύο εντολές είναι data dependent όταν υπάρχει μία αλυσίδα από RAW hazards μεταξύ τους.
- Name Dependences** : Δύο εντολές είναι name dependent όταν υπάρχει ένα WAR ή WAW hazard μεταξύ τους.



- Control Dependences** : Εντολές εξαρτόμενες από branch εντολή.  
if p1 { S1; }

# FP Loop: Πού είναι τα Hazards?

```
while (R1 > 0) { M[R1] = M[R1] + F2; R1 -= 8 }
Loop: L.D      F0,0(R1);F0=vector element
      ADD.D   F4,F0,F2;add scalar from F2
      S.D      0(R1),F4;store result
      SUBI    R1,R1,8;decrement pointer 8B (DW)
      BNEZ    R1,Loop;branch R1!=zero
      NOP          ;delayed branch slot
```

<i>Instruction producing result</i>	<i>Instruction using result</i>	<i>Latency in clock cycles</i>
FP ALU op	Another FP ALU op	3
FP ALU op	Store double	2
Load double	FP ALU op	1
Load double	Store double	1
Integer op	Integer op	0

- Που έχουμε stalls?

# FP Loop Showing Stalls

```
1 Loop: L.D    F0,0(R1) ;F0=vector element
2      stall
3      ADD.D F4,F0,F2 ;add scalar in F2
4      stall
5      stall
6      S.D    0(R1), F4 ;store result
7      SUBI   R1,R1,8  ;decrement pointer 8B (DW)
8      BNEZ   R1,Loop  ;branch R1!=zero
9      stall          ;delayed branch slot
```



<i>Instruction producing result</i>	<i>Instruction using result</i>	<i>Latency in clock cycles</i>
FP ALU op	Another FP ALU op	3
FP ALU op	Store double	2
Load double	FP ALU op	1

- 9 κύκλοι: Ξαναγράψε κώδικα για να ελαχιστοποιήσεις τα stalls?

# Scheduled κώδικας του FP Loop

```
1 Loop: L.D    F0 ,0 (R1)
2          stall
3      ADD.D F4 ,F0 ,F2
4      SUBI   R1 ,R1 ,8
5      BNEZ   R1 ,Loop ;delayed branch
6      S.D    8 (R1) ,F4 ;altered when move past SUBI
```

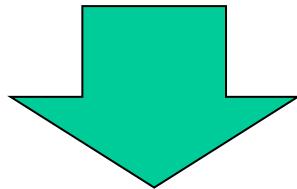
Αλλαγή Θέσεων των BNEZ και SD αλλάζοντας την διεύθυνση του SD

<i>Instruction producing result</i>	<i>Instruction using result</i>	<i>Latency in clock cycles</i>
FP ALU op	Another FP ALU op	3
FP ALU op	Store double	2
Load double	FP ALU op	1

6 clocks: Unroll loop 4 times to make code faster?

# Iδέα : Loop Unrolling

```
while (R1 > 0) { M[R1] = M[R1] + F2; R1 -= 8 }
```



```
while (R1 >= 4*8) {
    M[R1] = M[R1] + F2;
    M[R1-8] = M[R1-8] + F2;
    M[R1-16] = M[R1-16] + F2;
    M[R1-24] = M[R1-24] + F2;
    R1 -= 4*8
}
while (R1 > 0) { M[R1] = M[R1] + F2; R1 -= 8 }
```

Μη εξαρτόμενες εντολές  
μέσα στο Loop. Καλές  
προοπτικές για  
scheduling.

# Unroll Loop 4 φορές: Που έχουμε name dependencies;

```
1 Loop: L.D    F0,0(R1)
2      ADD.D   F4,F0,F2
3      S.D     0(R1),F4      ;drop SUBI & BNEZ
4      L.D     F0,-8(R1)
5      ADD.D   F4,F0,F2
6      S.D     -8(R1),F4    ;drop SUBI & BNEZ
7      L.D     F0,-16(R1)
8      ADD.D   F4,F0,F2
9      S.D     -16(R1),F4    ;drop SUBI & BNEZ
10     L.D     F0,-24(R1)
11     ADD.D   F4,F0,F2
12     S.D     -24(R1),F4
13     SUBI   R1,R1,#32      ;alter to 4*8
14     BNEZ   R1,LOOP
15     NOP
```

# Unroll Loop 4 φορές: Που έχουμε name dependencies;

```
1 Loop: L.D      F0,0(R1)
2          ADD.D   F4,F0,F2
3          S.D      0(R1),F4      ;drop SUBI & BNEZ
4          L.D      F0,-8(R1)
5          ADD.D   F4,F0,F2
6          S.D      -8(R1),F4    ;drop SUBI & BNEZ
7          L.D      F0,-16(R1)
8          ADD.D   F4,F0,F2
9          S.D      -16(R1),F4   ;drop SUBI & BNEZ
10         L.D      F0,-24(R1)
11         ADD.D   F4,F0,F2
12         S.D      -24(R1),F4
13         SUBI    R1,R1,#32    ;alter to 4*8
14         BNEZ    R1,LOOP
15         NOP
```



Πώς εξαφανίζονται;

# Που είναι τώρα;

```
1 Loop: L.D      F0,0(R1)
2      ADD.D    F4,F0,F2
3      S.D      0(R1),F4      ;drop SUBI & BNEZ
4      L.D      F6,-8(R1)
5      ADD.D    F8,F6,F2
6      S.D      -8(R1),F8      ;drop SUBI & BNEZ
7      L.D      F10,-16(R1)
8      ADD.D    F12,F10,F2
9      S.D      -16(R1),F12      ;drop SUBI & BNEZ
10     L.D      F14,-24(R1)
11     ADD.D    F16,F14,F2
12     S.D      -24(R1),F16
13     SUBI    R1,R1,#32      ;alter to 4*8
14     BNEZ    R1,LOOP
15     NOP
```

“register renaming” εξαφάνισε WAR/WAW stalls

# Unroll Loop 4 φορές

1	Loop: LD	F0 , 0 (R1)	1 cycle stall
2	ADDD	F4 , F0 , F2	2 cycles stall
3	SD	0 (R1) , F4	; drop SUBI & BNEZ
4	LD	F6 , -8 (R1)	
5	ADDD	F8 , F6 , F2	
6	SD	-8 (R1) , F8	; drop SUBI & BNEZ
7	LD	F10 , -16 (R1)	
8	ADDD	F12 , F10 , F2	
9	SD	-16 (R1) , F12	; drop SUBI & BNEZ
10	LD	F14 , -24 (R1)	
11	ADDD	F16 , F14 , F2	
12	SD	-24 (R1) , F16	
13	SUBI	R1 , R1 , #32	; alter to 4*8
14	BNEZ	R1 , LOOP	
15	NOP		

Rewrite loop to minimize stalls?

$15 + 4 \times (1+2) = 27$  clock cycles, or 6.8 per iteration  
Assumes R1 is multiple of 4

# Schedule Unrolled Loop

1	Loop:	LD F0, 0 (R1)
2		LD F6, -8 (R1)
3		LD F10, -16 (R1)
4		LD F14, -24 (R1)
5		ADDD F4, F0, F2
6		ADDD F8, F6, F2
7		ADDD F12, F10, F2
8		ADDD F16, F14, F2
9		SD 0 (R1), F4
10		SD -8 (R1), F8
11		SD -16 (R1), F12
12		SUBI R1, R1, #32
13		BNEZ R1, LOOP
14		SD 8 (R1), F16 ; 8-32 = -24

- Τι υποθέσεις έγιναν κατά την μετακίνηση του κώδικά;
  - OK to move store past SUBI even though changes register
  - **OK to move loads before stores/add: get right data?**
  - When is it safe for compiler to do such changes?

*14 clock cycles, or 3.5 per iteration*

# Compiler Perspectives on Code Movement

- Name Dependencies είναι δύσκολο να διαγνωστούν για Memory Accesses
  - Είναι  $100(R4) = 20(R6)$ ?
  - Για διαφορετικές επαναλήψεις του loop, είναι  $20(R6) = 20(R6)$ ?
- Στο παράδειγμά μας ο compiler πρέπει να καταλάβει ότι όταν το R1 δεν αλλάζει τότε:

$$0(R1) \neq -8(R1) \neq -16(R1) \neq -24(R1)$$

There were no dependencies between some loads and stores so they could be moved by each other

# Πότε είναι ασφαλές να κάνουμε Unroll ένα Loop?

- Παράδειγμα: Που είναι οι εξαρτήσεις?

(A,B,C distinct & nonoverlapping)

```
for (i=0; i<100; i=i+1) {  
    A[i+1] = A[i] + C[i]; /* S1 */  
    B[i+1] = B[i] + A[i+1]; /* S2 */  
}
```

1. S2 uses the value, A[i+1], computed by S1 in the same iteration.
2. S1 uses a value computed by S1 in an earlier iteration, since iteration i computes A[i+1] which is read in iteration i+1. The same is true of S2 for B[i] and B[i+1].

Αυτή η εξάρτηση (μεταξύ επαναλήψεων) ονομάζεται **loop-carried dependence**

- For our prior example, each iteration was distinct
- Implies that iterations can't be executed in parallel, Right ??

# loop-carried dependence σημαίνει ότι δεν υπάρχει παραλληλισμός;

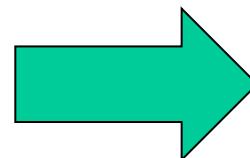
- Παράδειγμα:

```
for (i=0; i<100; i=i+1) {  
    A[i] = A[i] + B[i];      /* S1 */  
    B[i+1] = C[i] + D[i];    /* S2 */  
}
```

S1 χρησιμοποιεί τιμή του B[i] υπολογισμένη σε προηγούμενη επανάληψη (loop-carried dependence).

Όμως δεν υπάρχει άλλη εξάρτηση. Άρα η παραπάνω εξάρτηση δεν είναι κυκλική (circular). Επομένως το loop είναι παράλληλο.

A[0] = A[0] + B[0]  
B[1] = C[0] + D[0]  
A[1] = A[1] + B[1]  
B[2] = C[1] + D[1]  
A[2] = A[2] + B[2]  
B[3] = C[2] + D[2]  
. . .

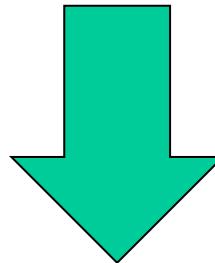


A[0] = A[0] + B[0]  
B[1] = C[0] + D[0]  
A[1] = A[1] + B[1]  
B[2] = C[1] + D[1]  
A[2] = A[2] + B[2]  
B[3] = C[2] + D[2]  
. . .

# loop-carried dependence σημαίνει ότι δεν υπάρχει παραλληλισμός;

- Παράδειγμα:

```
for (i=0; i<100; i=i+1) {  
    A[i] = A[i] + B[i];      /* S1 */  
    B[i+1] = C[i] + D[i];    /* S2 */  
}
```



```
A[0] = A[0] + B[0];                                /* start-up code */  
for (i=0; i<99; i=i+1) {  
    B[i+1] = C[i] + D[i];      /* S1 */  
    A[i+1] = A[i+1] + B[i+1];  /* S2 */  
}  
B[100] = B[99] + D[99];                            /* clean-up code */
```

# Recurrence – Depedence Distance

- Παράδειγμα:

```
for (i=2; i< 100; i=i+1) {  
    Y[i] = Y[i-1] + Y[i];  
}
```

loop-carried εξάρτηση σε μορφή **recurrence**.

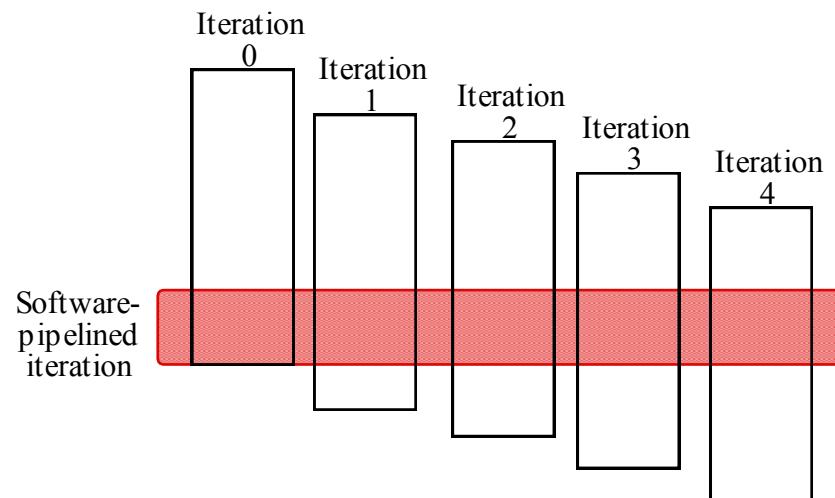
- Παράδειγμα:

```
for (i=2; i< 100; i=i+1) {  
    Y[i] = Y[i-5] + Y[i];  
}
```

Η επανάληψη ι εξαρτιέται από την  $i-5$ , δηλαδή έχει **dependedence distance** 5.  
Όσο μεγαλύτερη η απόσταση τόσο περισσότερο πιθανό παραλληλισμό  
μπορούμε να περύχουμε.

# Άλλη εκδοχή: Software Pipelining

- Παρατήρηση: Αν οι επαναλήψεις του loop είναι ανεξάρτητες, τότε μπορούμε να έχουμε περισσότερο ILP εκτελώντας εντολές από διαφορετικές επαναλήψεις.
- Software pipelining: reorganizes loops so that each iteration is made from instructions chosen from different iterations of the original loop (- Tomasulo in SW)



# Software Pipelining: Παράδειγμα

Iteration 0

LD F0, 0 (R1)

*start-up code*

ADDD F4, F0, F2 LD F0, -8 (R1)

SD 0 (R1), F4 ADDD F4, F0, F2 LD F0, -16 (R1)

SD -8 (R1), F4 ADDD F4, F0, F2 LD F0, -24 (R1)

SD -16 (R1), F4 ADDD F4, F0, F2 LD F0, -32 (R1)

SD -24 (R1), F4 ADDD F4, F0, F2

*finish-up code*

SD -32 (R1), F4



# Software Pipelining: Παράδειγμα

Πριν: Unrolled 3 times

```
1 L.D F0,0(R1)
2 ADD.D F4,F0,F2
3 S.D 0(R1),F4
4 L.D F6,-8(R1)
5 ADD.D F8,F6,F2
6 S.D -8(R1),F8
7 L.D F10,-16(R1)
8 ADD.D F12,F10,F2
9 S.D -16(R1),F12
10 SUBI R1,R1,#24
11 BNEZ R1,LOOP
```

Μετά: Software Pipelined

```
1 S.D 0(R1),F4 ; Stores M[i]
2 ADD.D F4,F0,F2 ; Adds to M[i-1]
3 L.D F0,-16(R1) ; Loads M[i-2]
4 SUBI R1,R1,#8
5 BNEZ R1,LOOP
```

*5 cycles per iteration*

Tα RAW hazards μετατρέπονται σε WAR hazards.

# Software Pipelining

## Symbolic Loop Unrolling

- Maximize result-use distance
- Less code space than unrolling

But..

- Harder to implement
- Execution of SUB & BNEZ in every iteration