Arquitectura de Computadores

TEMA 3
Lanzamiento múltiple, Límites de ILP, Multithreading

DEPARTAMENTO DE ARQUITECTURA DE COMPUTADORES Y AUTOMÁTICA

Curso 2015-2016

Contenidos

- Introducción: CPI < 1
- Lanzamiento múltiple de instrucciones: Superescalar, VLIW
- Superescalar simple
- VLIW
- Superescalar con planificación dinámica
- Límites de ILP
- Ejemplo: Implementaciones X86
- Thread Level Parallelism y Multithreading

- Bibliografía
  - Capítulo 3 y Apéndice H de [HePa12]
  - Capítulos 6 y 7 de [SiFK97]

❑ Introducción

- ¿Por que limitar a una instrucción por ciclo?
- Objetivo: CPI < 1
- Lanzar y ejecutar ***simultáneamente*** múltiples instrucciones por ciclo
- ¿Tenemos recursos?
  - Más área de silicio disponible
  - Técnicas para resolver las dependencias de datos (*planificación*)
  - Técnicas para resolver las dependencias de control (*especulación)*

Más ILP: Lanzamiento múltiple

❑ Alternativas

- **Procesador Superescalar con planificación estática**
- **Procesador Superescalar con planificación dinámica+(especulación)**
- **Procesadores VLIW (very long instruction processor)**

- **Superescalar**
  - Lanza de 1 a 8 instrucciones por ciclo
  - Reglas de ejecución
    - Ejecución en orden-planificación estática
    - Ejecución fuera de orden-planificación dinámica
- **VLIW**
  - Numero fijo de instrucciones por ciclo
  - Planificadas estáticamente por el compilador
  - EPIC (Explicitly Parallel Instruction Computing) Intel/HP

Más ILP: Lanzamiento múltiple

❑ Alternativas

Tipo	Forma del "issue"	Detección de riesgos	Planificación	Ejemplos
Superescalar estático	Dinámico	HW	estática	Embeded MIPS, ARM
Superescalar dinámico	Dinámico	HW	dinámica	ninguno
Superescalar especulativo	Dinámico	HW	Dinámica con especulación	P4, Core2, Power5, 7 SparcVI, VII
VLIW	Estático	Básicamente SW	estática	TI C6x Itanium

Más ILP: Lanzamiento múltiple

❑ SUPERESCALAR

Grado 2
2 Vías

Instruction	1	2	3	4	5	6	7
i	IF	ID	EX	MEM	WB		
i+1	IF	ID	EX	MEM	WB		
i+2		IF	ID	EX	MEM	WB	
i+3		IF	ID	EX	MEM	WB	
i+4			IF	ID	EX	MEM	WB
i+5			IF	ID	EX	MEM	WB

Efecto de riesgo LDE provocado por un Load

- **Duplicar todos los recursos:**
  - Puertas bloque de Registros
  - Fus
  - Puertas de memoria,..
  - Control
- **Ideal CPI= 0.5 se reduce por:**
  - Saltos
  - LOADs
  - Dependencias verdaderas LDE
- **Necesita:**
  - Predicción sofisticada
  - Tratamiento de LOAD; Cargas especulativas, técnicas de prebúsqueda
- **Más presión sobre la memoria**
- **Efecto incremental de los riesgos**
- **Se puede reducir complejidad con limitaciones (Un acceso a memoria por ciclo)**

❑ SUPERESCALAR Simple (estático, en orden)

- Regla de lanzamiento: Una instrucción FP (2ª)+ una instrucción de cualquier otro tipo (1ª)
- Buscar y decodificar dos instrucciones por ciclo (64 bits)
  Ordenamiento y decodificación
  Se analizan en orden. Sólo se lanza la 2ª si se ha lanzado la 1ª (conflictos)
- Unidades funcionales segmentadas (una ope. por ciclo) ó múltiples (división, raíz), más puertas en el bloque de registros
- Lanzamiento simple, recursos no conflictivos (diferentes reg y UF,..), excepto
  Conflictos de recursos; load, store, move FP → más puertas en el bloque de reg.
  Conflictos de datos LDE → más distancia entre instrucciones.

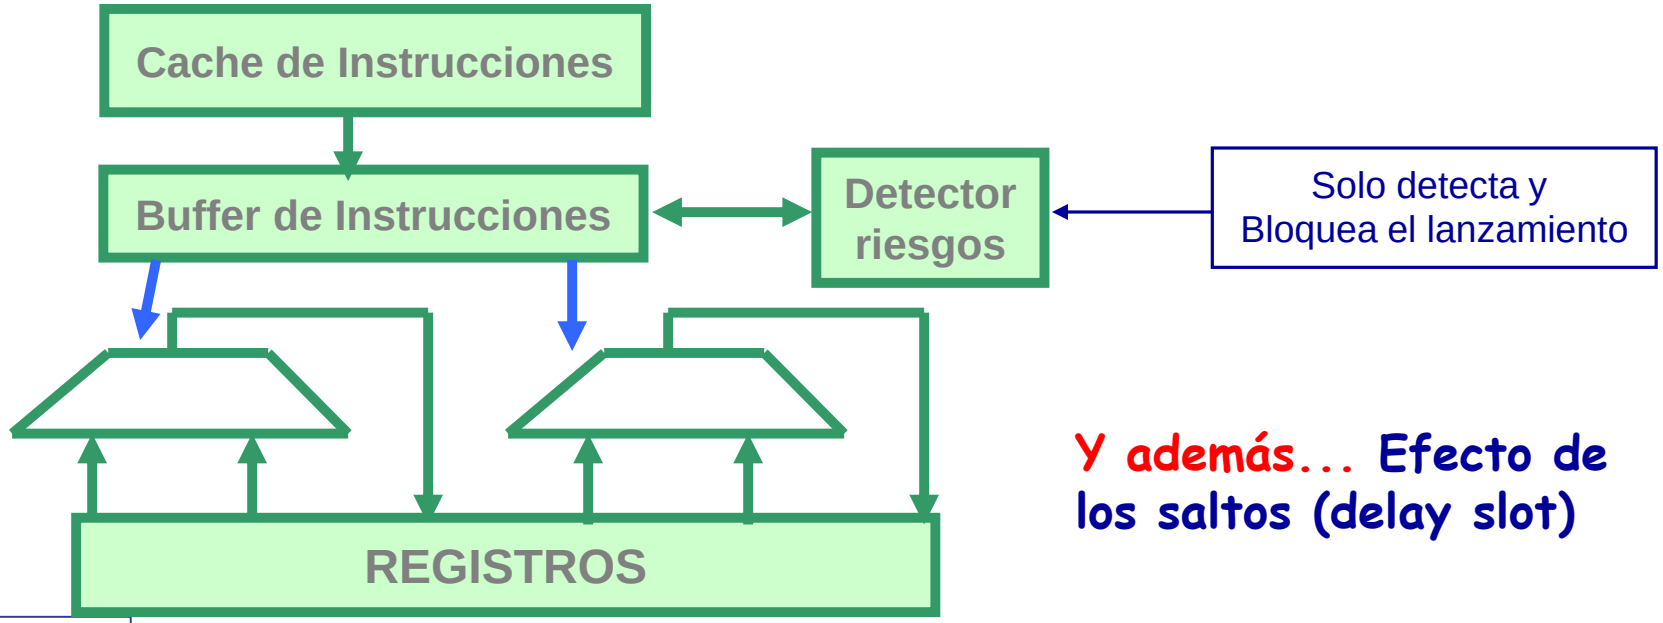

Y además... Efecto de los saltos (delay slot)

❑SUPERESCALAR Simple (estático, en orden)

	Instrucción entera		Instrucción FP		Ciclo
Loop:	LD	F0,0(R1)			1
	LD	F6,-8(R1)			2
	LD	F10,-16(R1)	ADDD	F4,F0,F2	3
	LD	F14,-24(R1)	ADDD	F8,F6,F2	4
	LD	F18,-32(R1)	ADDD	F12,F10,F2	5
	SD	0(R1),F4	ADDD	F16,F14,F2	6
	SD	-8(R1),F8	ADDD	F20,F18,F2	7
	SD	-16(R1),F12			8
	SUBI	R1,R1,#40			9
	SD	16(R1),F16			10
	BNEZ	R1,LOOP			11
	SD	8(R1),F20			12

Separadas por 2 ciclos

- **Desarrollo para ejecución superescalar: se desarrolla una iteración más.**
  12 ciclos, 2.4 ciclos por iteración

- **El código máquina está compacto en la memoria**

Más ILP: Lanzamiento múltiple

❑ SUPERESCALAR Simple (estático, en orden)

➢ *Ventajas*

- No modifica código. Compatibilidad binaria
- No riesgos en ejecución

➢ *Desventajas*

- Mezcla de instrucciones. Solo obtiene CPI de 0.5 en programas con 50 % de FP
- Bloqueos en el lanzamiento
- Planificación fija: No puede adaptarse a cambios en ejecución (Fallos de cache)
- Los códigos deben de ser replanificados para cada nueva implementación (eficiencia)

❑ VLIW

- El análisis de dependencias en tiempo de compilación
- Muchas operaciones por instrucción (IA64 packet, Transmeta molécula)
- Todas las operaciones de una instrucción se ejecutan en paralelo
- Instrucciones con muchos bits
- Muchas operaciones vacías (NOP)

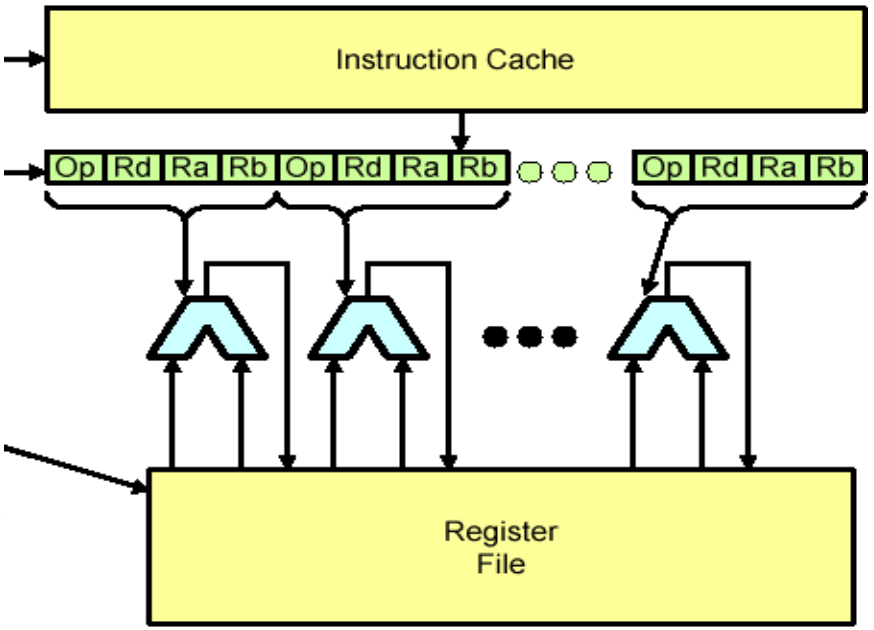

Instrucción: Incluye varias instrucciones convencionales de tres operandos una por ALU

Bloque de registros, 3 puertas por ALU

Más ILP: Lanzamiento múltiple

❑ VLIW Ejemplo Tema 2

```
LOOP    LD      F0,0(R1)
        ADDD    F4,F0,F2
        SD      0(R1),F4
        SUBI    R1,R1,#8
        BNEZ    R1,LOOP
```

- Aplicar técnicas conocidas para minimizar paradas
  - Unrolling
  - Renombrado de registros

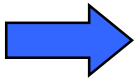

```
LOOP:   LD      F0, 0(R1)
        LD      F6, -8(R1)
        LD      F10, -16(R1)
        LD      F14,-24(R1)
        ADDD    F4, F0, F2
        ADDD    F8, F6, F2
        ADDD    F12, F10, F2
        ADDD    F16, F14, F2
        SD      0(R1), F4
        SD      -8(R1), F8
        SUBI    R1, R1, #32
        SD      16(R1), F12
        BNEZ    R1, LOOP
        SD      8(R1), F16;   8-32 = -24
```

- Latencias de uso: LD a ADD 1 ciclo, ADD a SD 2 ciclos
- Opción: desarrollar 4 iteraciones y planificar: 14 ciclos, 3.5 ciclos por iteración

Más ILP: Lanzamiento múltiple

❑ VLIW

Loop unrolling en VLIW (desarrollo 7 iteraciones)

```
LOOP:   LD F0,0(R1)        ; F0 = array element
        ADDD F4,F0,F2      ; add scalar in F2
        SD 0(R1),F4        ; store result
        SUBI R1,R1,#8      ; decrement pointer
        BNEZ R1, LOOP      ; branch if R1!=0
```

Mem ref 1	Mem ref 2	FP op	FP op	Int op/branch
LD F0,0(R1)	LD F6,-8(R1)			
LD F10,-16(R1)	LD F14,-24(R1)			
LD F18,-32(R1)	LD F22,-40(R1)	ADDD F4,F0,F2	ADDD F8,F6,F2	
LD F26,-48(R1)		ADDD F12,F10,F2	ADDD F16,F14,F2	
		ADDD F20,F18,F2	ADDD F24,F22,F2	
SD 0(R1),F4	SD -8(R1),F8	ADDD F28,F26,F2		
SD -16(R1),F12	SD -24(R1),F16			SUBI R1,R1,#56
SD 24(R1),F20	SD 16(R1),F24			
SD 8(R1),F28				BNEZ R1, LOOP

- ✓ **7 iteraciones en 9 ciclos: 1.3 ciclos por iteración**
- ✓ **23 operaciones en 45 slots (~50% de ocupación)**
- ✓ **Muchos registros necesarios**

Más ILP: Lanzamiento múltiple

❑VLIW

VENTAJAS

- Hardware de control muy simple
  - No detecta dependencias
  - Lógica de lanzamiento simple
- Puede explotar paralelismo a todo lo largo del programa (compilador)

DESVENTAJAS

- Planificación estática; Muy sensible a fallos de cache
- Necesita desenrollado muy agresivo
- Bloque de registros muy complejo en área y tiempo de acceso
- Muchas NOP
  - Poca densidad de código
  - Capacidad y AB de la cache de instrucciones
- Compilador muy complejo
- No binario compatible
- Operación síncrona para todas las operaciones de una instrucción

❑EPIC: Explicitly Parallel Instruction Computing (IA64)

- Instrucciones de 128 bits
  - Operaciones de tres operandos
  - TMP (Template) codifica dependencias entre las operaciones
  - 128 registros enteros (64bits), 128 registros FP (82bits)
  - Ejecución predicada. 64 registros de predicado de 1 bit
  - Cargas especulativas
  - Hw para chequeo de dependencias

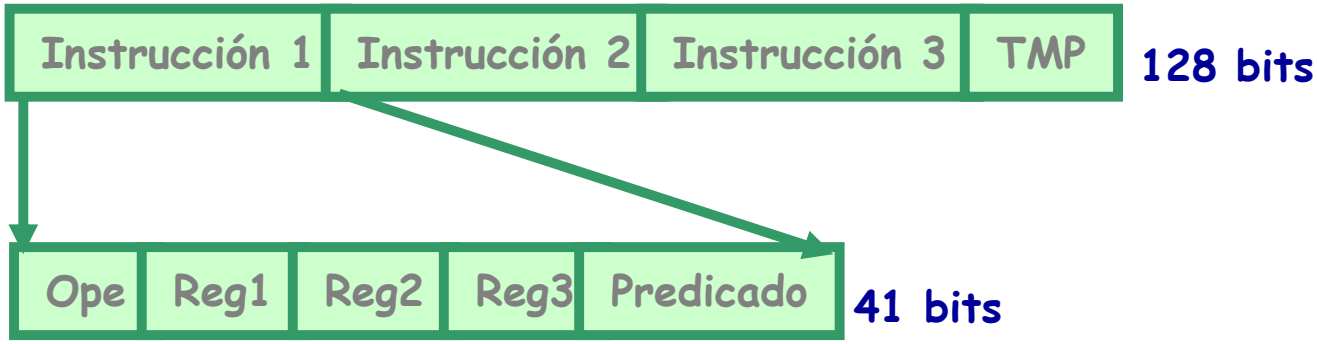

Primera implementación Itanium (2001), 6 operaciones por ciclo, 10 etapas, 800Mhz

Segunda implementación Itanium2 (2005), 6 operaciones por ciclo, 8 etapas, 1,66Ghz

Más ILP: Lanzamiento múltiple

❑SUPERESCALAR con Planificación Dinámica.Fuera de orden

➢ Un Diseño Simple

- Estaciones de reserva separadas para enteros (+reg) y PF (+reg)
- Lanzar dos instrucciones en orden (ciclo de lanzamiento: partir en dos subciclos)
- Solo FP load causan dependencias entre instrucciones enteras y PF
  - Reemplazar buffer de load con cola. Las lecturas se hacen en orden
  - Ejecución Load: "check" dirección en cola de escritura para evitar LDE
  - Ejecución Store: "check" dirección en cola de lecturas para evitar EDL

➢ Rendimiento del procesador

Iteración no.	Instrucción	Lanzada	Comienza Ejecución (número de ciclo)	Escribe resultado	
1	LD F0,0(R1)	1	2	4	
1	ADDD F4,F0,F2	1	5	8	⬅
1	SD 0(R1),F4	2	9		
1	SUBI R1,R1,#8	3	4	5	
1	BNEZ R1,LOOP	4	6		
2	LD F0,0(R1)	5	6	8	⬅
2	ADDD F4,F0,F2	5	9	12	
2	SD 0(R1),F4	6	13		
2	SUBI R1,R1,#8	7	8	9	
2	BNEZ R1,LOOP	8	10		

4 ciclos por iteración

❑ SUPERESCALAR con Planificación Dinámica y Especulación

Ejecución fuera de orden. Finalización en orden

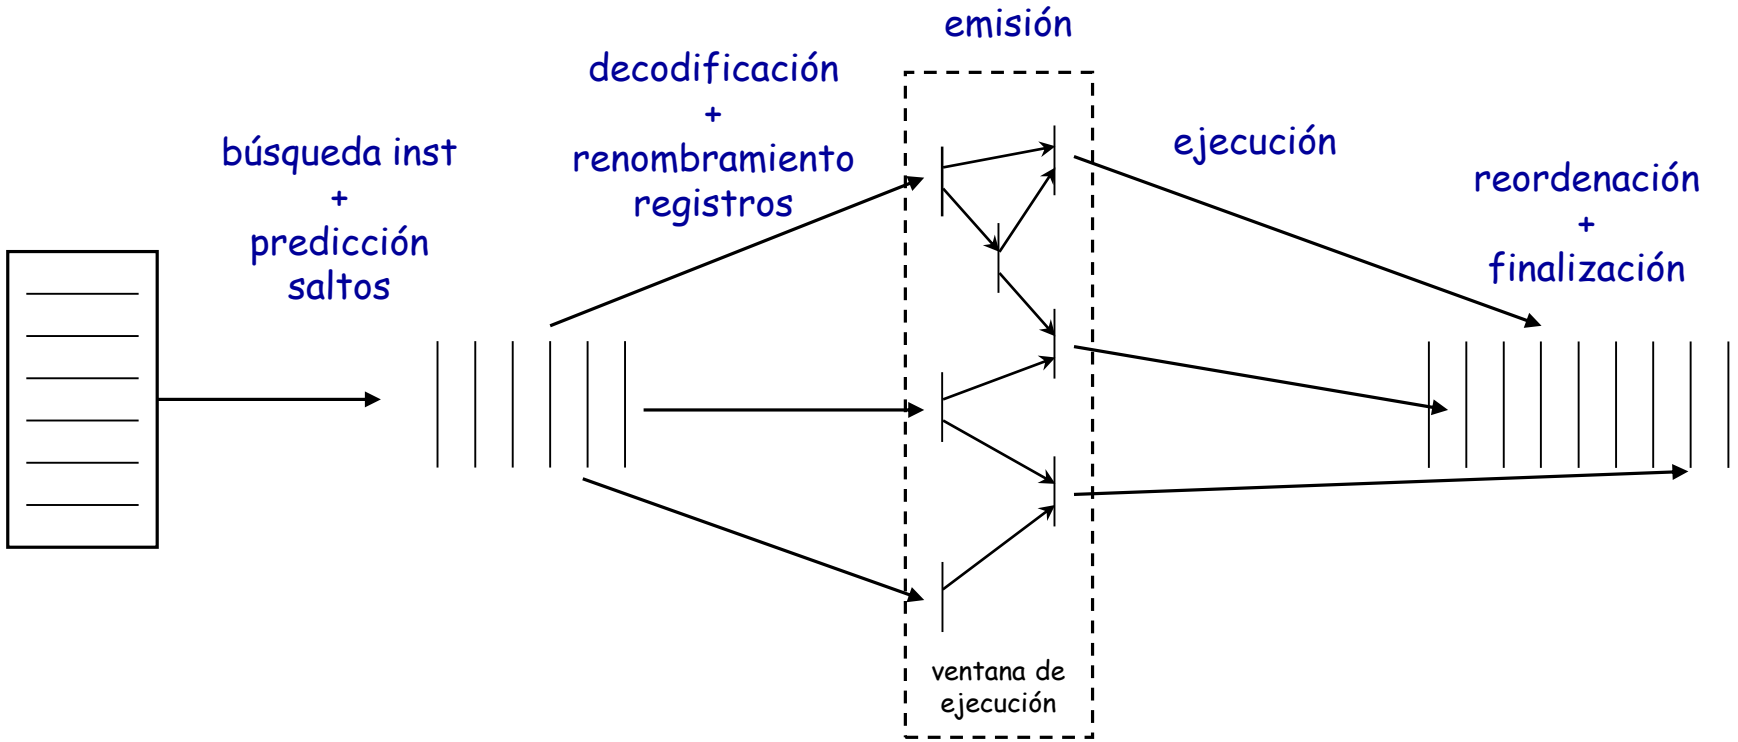

programa estático | **flujo dinámico instrucciones** | **planificación dinámica y ejecución fuera de orden** | **escritura en orden**

❑ EV7 ALPHA 21364 Core (2003)

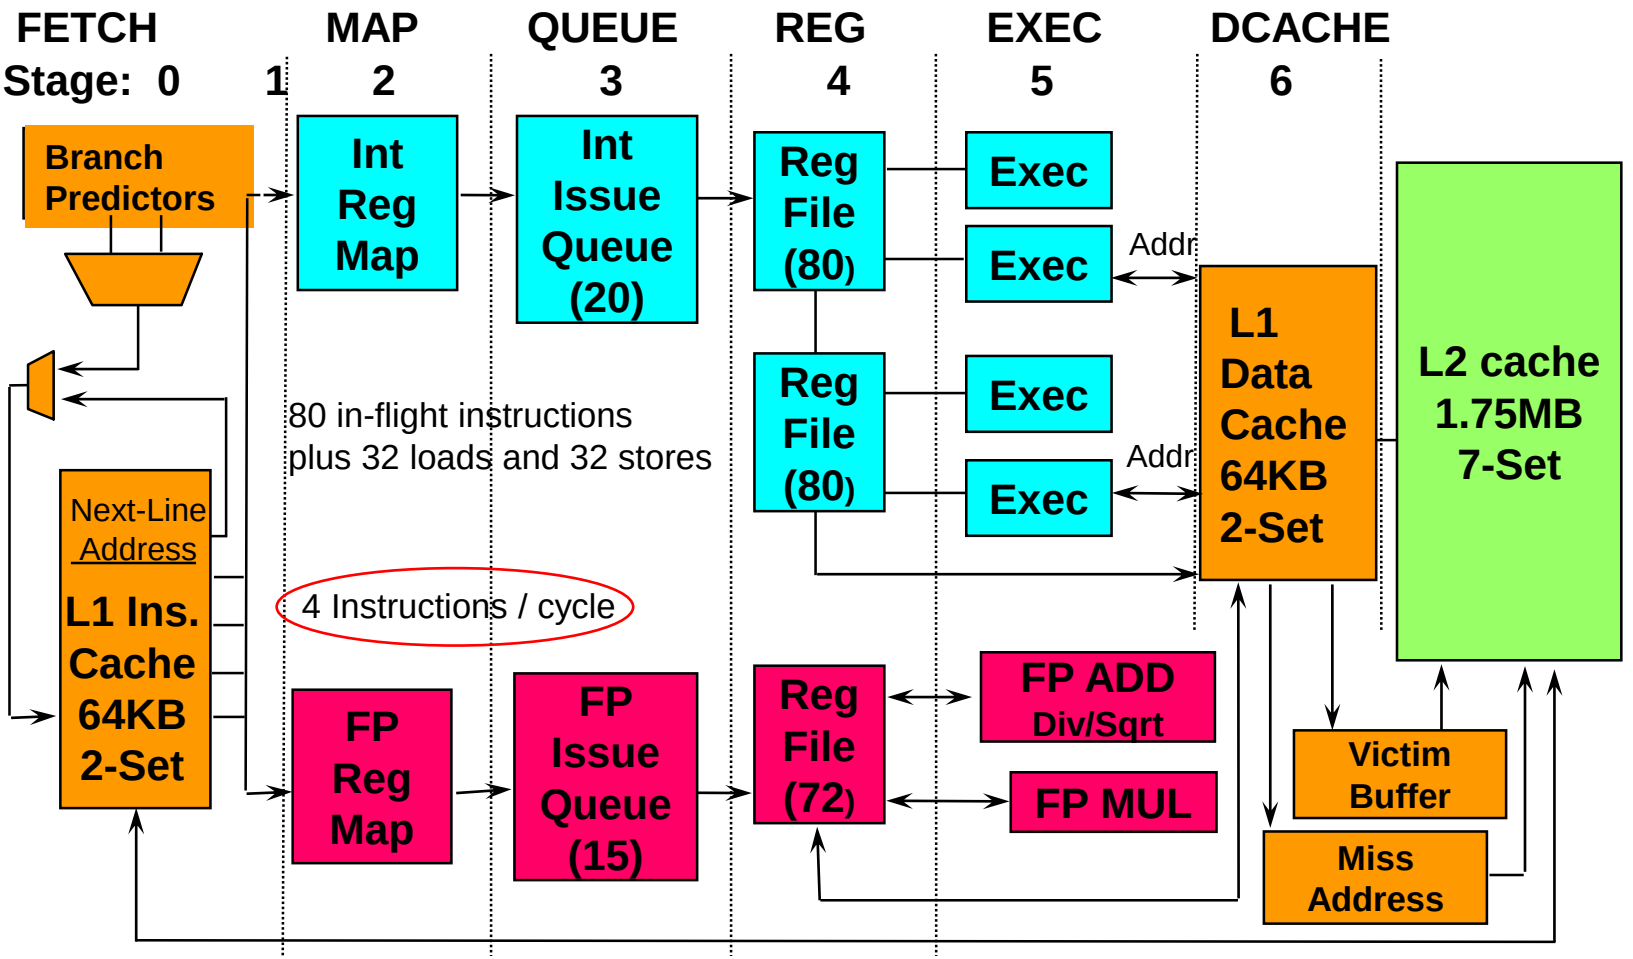

Límites del ILP

- El lanzamiento múltiple permite mejorar el rendimiento sin afectar al modelo de programación
- En los últimos años se ha mantenido el mismo ancho superescalar que tenían los diseños del 1995
- La diferencia entre rendimiento pico y rendimiento obtenido crece

- ¿Cuanto ILP hay en las aplicaciones?

- ¿Necesitamos nuevos mecanismos HW/SW para explotarlo?
  - Extensiones multimedia:
    - Intel MMX,SSE,SSE2,SSE3, SSE4
    - Motorola Altivec, Sparc, SGI, HP

Límites del ILP

- **¿Cuanto ILP hay en las aplicaciones?**

- **Supongamos un procesador superescalar fuera de orden con especulación y con recursos ilimitados**
  - Infinitos registros para renombrado
  - Predicción perfecta de saltos
  - Caches perfectas
  - Lanzamiento no limitado
  - Desambiguación de memoria perfecta
- **Entonces…**
  - En tal sistema la ejecución de instrucciones está solo condicionada por las dependencias LDE.
  - Además si suponemos que la latencia de las UFs es 1 ¿cómo determinar el IPC?

Límites del ILP

- Comparaciones necesarias en lanzamiento
  - Ejemplo: Lanzar 6 instrucciones/ciclo (check LDE)
    - 1-2 1-3 1-4 1-5 1-6 = 5 instr x 2 operandos = 10 comp
    - 2-3 2-4 2-5 2-6 = 4 instr x 2 operandos = 8 comp
    - ....
    - 5-6 = 1 instr x 2 operandos = 2 comp
    - TOTAL = 30 comp
  - En general: lanzar n instrucciones ➔ n^2-n comp

- Comparaciones necesarias para paso de operandos
  - Ejemplo: pueden acabar 6 instr/ciclo, 80 instr en la ventana, 2 operandos/instr.
    - 6 x 80 x 2 = 960 comparaciones/ciclo
  - En general, comparar con los operandos de todas las instrucciones que están esperando a ser ejecutadas.

Límites del ILP

- Modelo versus procesador real

	Modelo	Power 5
Instrucciones lanzadas por ciclo	Infinito	4
Ventana de instrucciones	Infinita	200
Registros para renombrado	Infinitos	48 integer + 40 Fl. Pt.
Predicción de saltos	Perfecta	2% to 6% de fallos de predicción (Tournament Branch Predictor)
Cache	Perfecta	64KI, 32KD, 1.92MB L2, 36 MB L3 (off-chip)
Análisis de Memory Alias	Perfecto	

Límites del ILP

❑ Límite superior: Recursos ilimitados

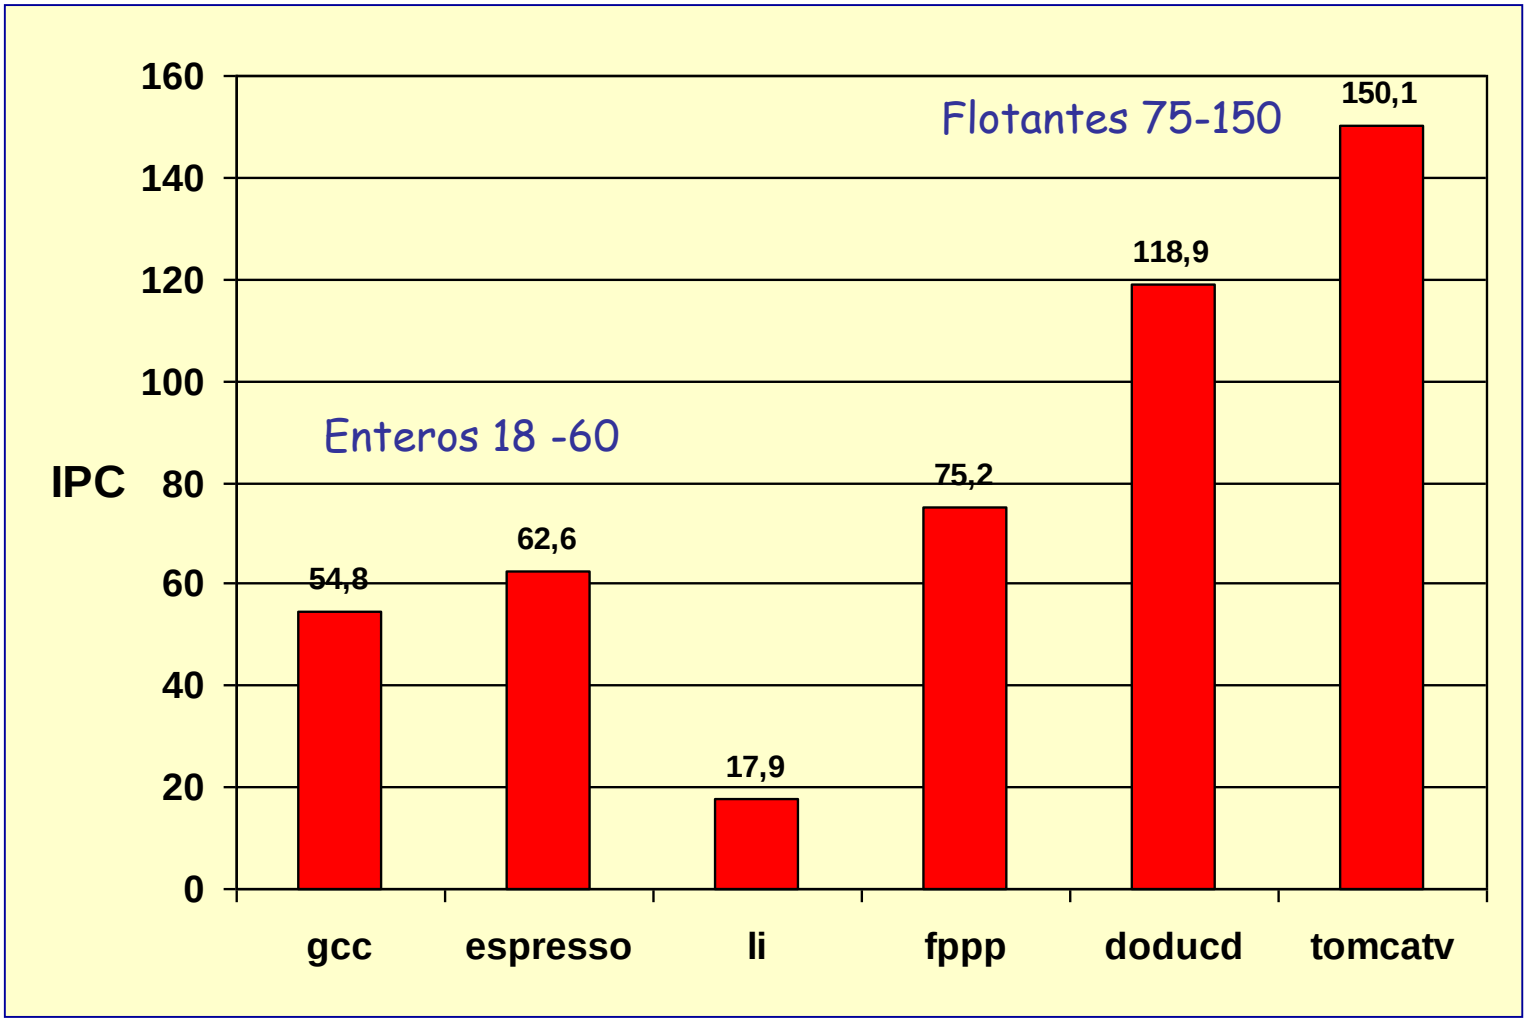

Algunas aplicaciones tienen poco paralelismo (Li)

Límites del ILP

- Modelo versus procesador real

	Nuevo Modelo	Modelo	Power 5
Instrucciones lanzadas por ciclo	Infinitas	Infinitas	4
Ventana de instrucciones	Infinito vs. 2K, 512, 128, 32, 8,4	Infinita	200
Registros para renombrado	Infinitos	Infinitos	48 enteros + 40 Fl. Pt.
Predicción de saltos	Perfecta	Perfecta	Tournament
Cache	Perfecta	Perfecta	64KI, 32KD, 1.92MB L2, 36 MB L3
Análisis de Memory Alias	Perfecto	Perfecto	

Límites del ILP

- HW más real: Impacto del tamaño de la ventana de instrucciones

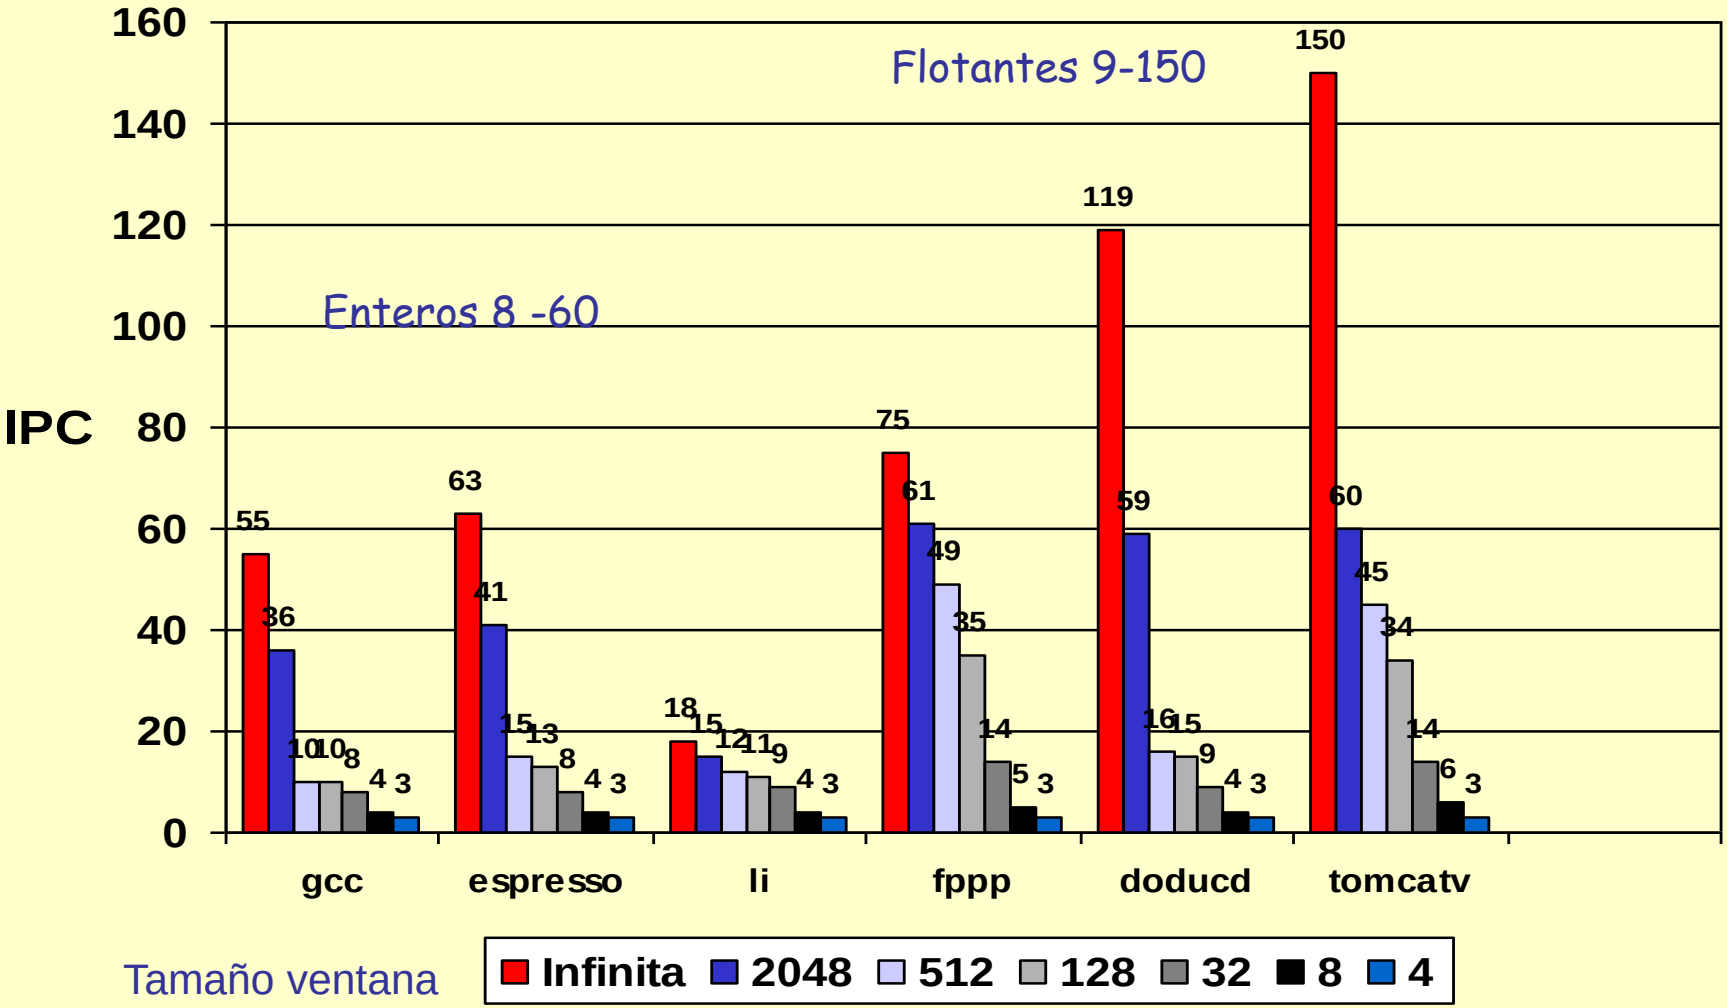

Límites del ILP

- Modelo versus procesador real

	Nuevo Modelo	Modelo	Power 5
Instrucciones lanzadas por ciclo	64 sin restricciones	Infinitas	4
Ventana de instrucciones	2048	Infinita	200
Registros para renombrado	Infinitos	Infinitos	48 enteros + 40 Fl. Pt.
Predicción de saltos	Perfecto vs. 8K Tournament vs. 512 2-bit vs. profile vs. ninguno	Perfecta	Tournament
Cache	Perfecta	Perfecta	64KI, 32KD, 1.92MB L2, 36 MB L3
Análisis de Memory Alias	Perfecto	Perfecto	

❑ HW más real: Impacto de los saltos

Ventana de 2048 y lanza 64 por ciclo

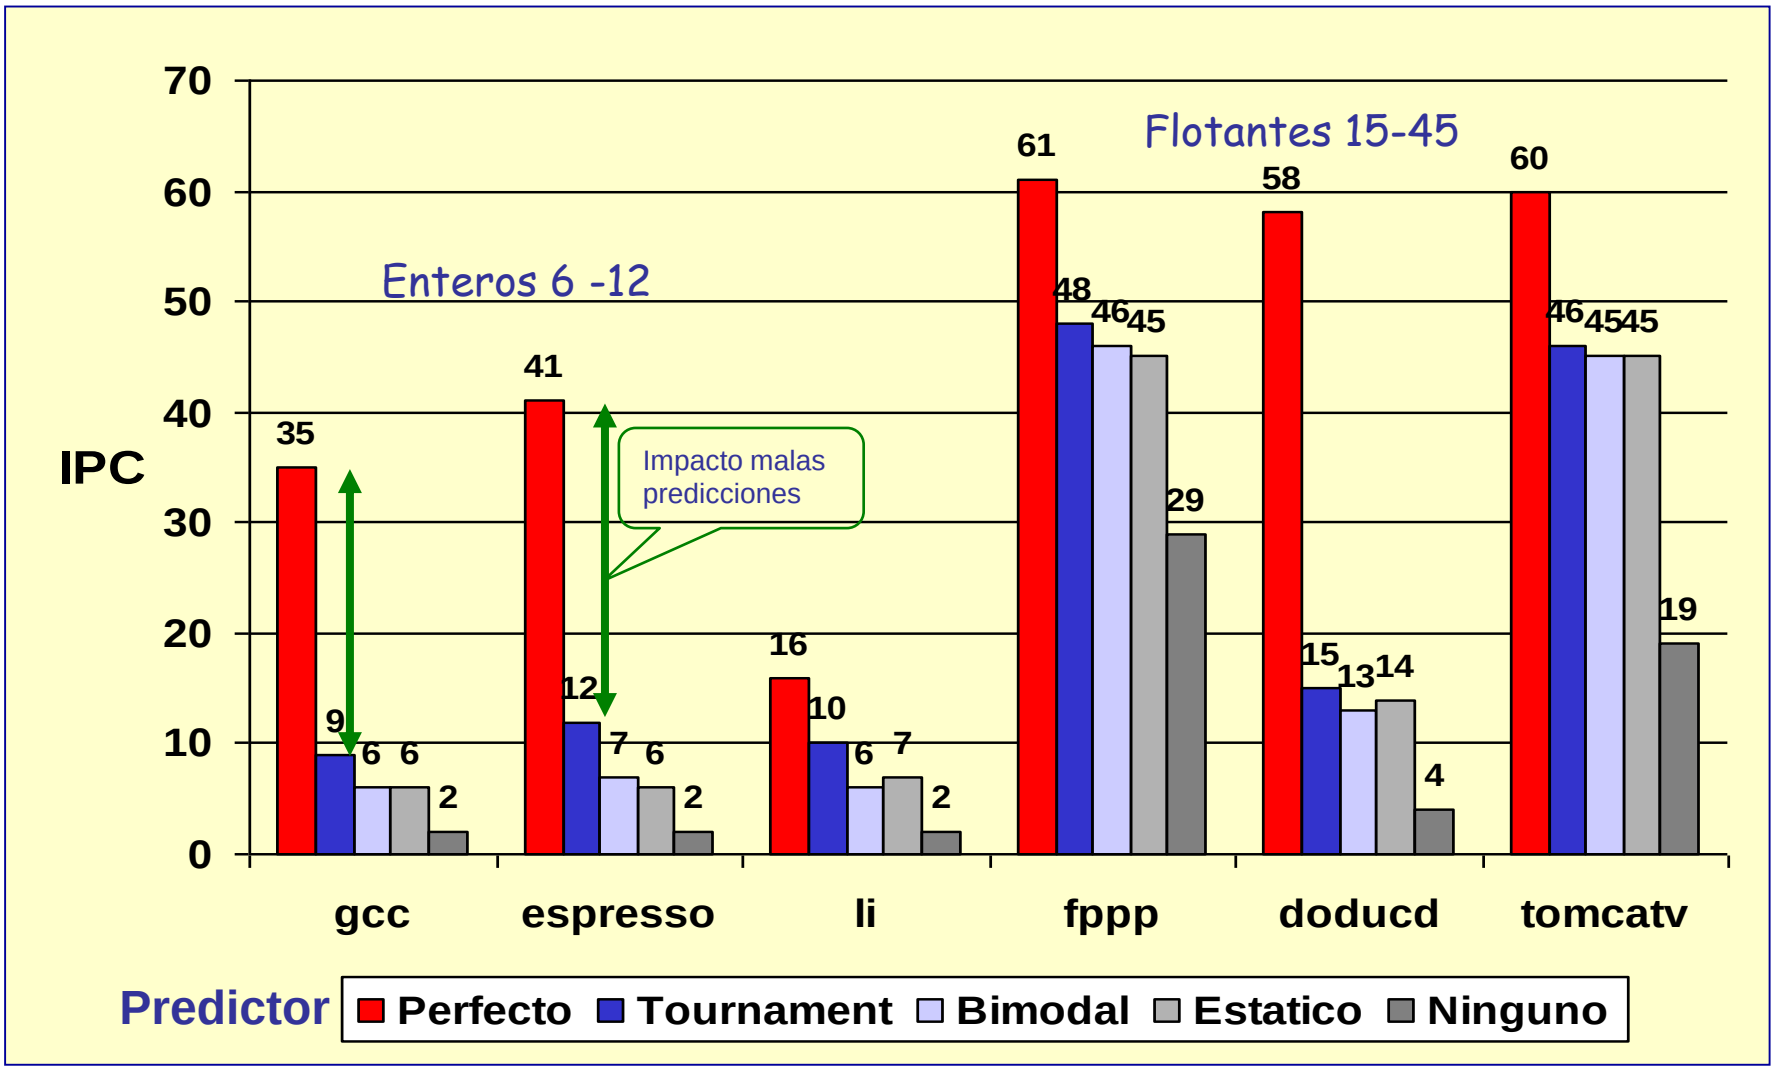

Límites del ILP

- Modelo versus procesador real

	Nuevo Modelo	Modelo	Power 5
Instrucciones lanzadas por ciclo	64 sin restricciones	Infinitas	4
Ventana de instrucciones	2048	Infinita	200
Registros para renombrado	Infinito v. 256, 128, 64, 32, ninguno	Infinitos	48 enteros + 40 Fl. Pt.
Predicción de saltos	8K Tournament (hibrido)	Perfecta	Tournament
Cache	Perfecta	Perfecta	64KI, 32KD, 1.92MB L2, 36 MB L3
Análisis de Memory Alias	Perfecto	Perfecto	

❑ HW más real: Impacto del numero de registros

Ventana de 2048 y lanza 64 por ciclo, predictor híbrido 8K entradas

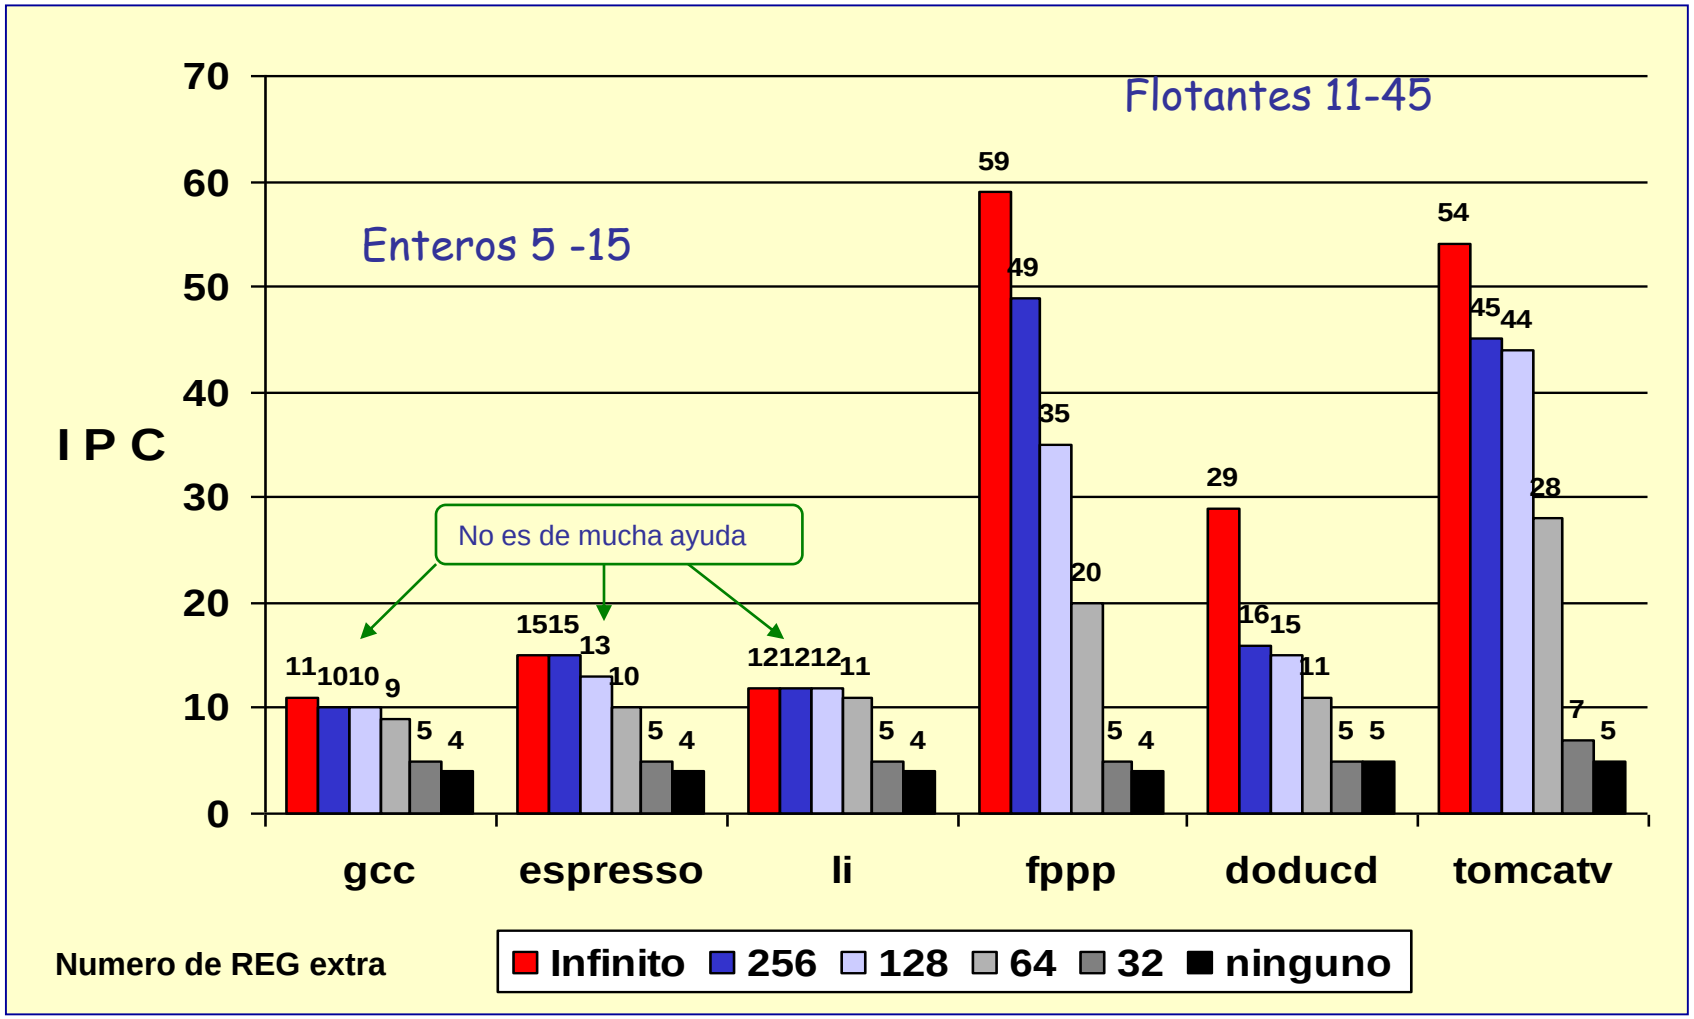

Límites del ILP

- Modelo versus procesador real

	Nuevo Modelo	Modelo	Power 5
Instrucciones lanzadas por ciclo	64 (sin restricciones)	Infinitas	4
Ventana de instrucciones	Infinito vs. 256, 128, 32, 16	Infinita	200
Registros para renombrado	64 Int + 64 FP	Infinitos	48 enteros + 40 Fl. Pt.
Predicción de saltos	1K 2-bit	Perfecta	Tournament
Cache	Perfecto	Perfecta	64KI, 32KD, 1.92MB L2, 36 MB L3
Análisis de Memory Alias	HW disambiguation	Perfecto	

Límites del ILP

HW realizable

64 instrucciones por ciclo sin restricciones, predictor híbrido, predictor de retornos de 16 entradas, Desambiguación perfecta, 64 registros enteros y 64 Fp extra

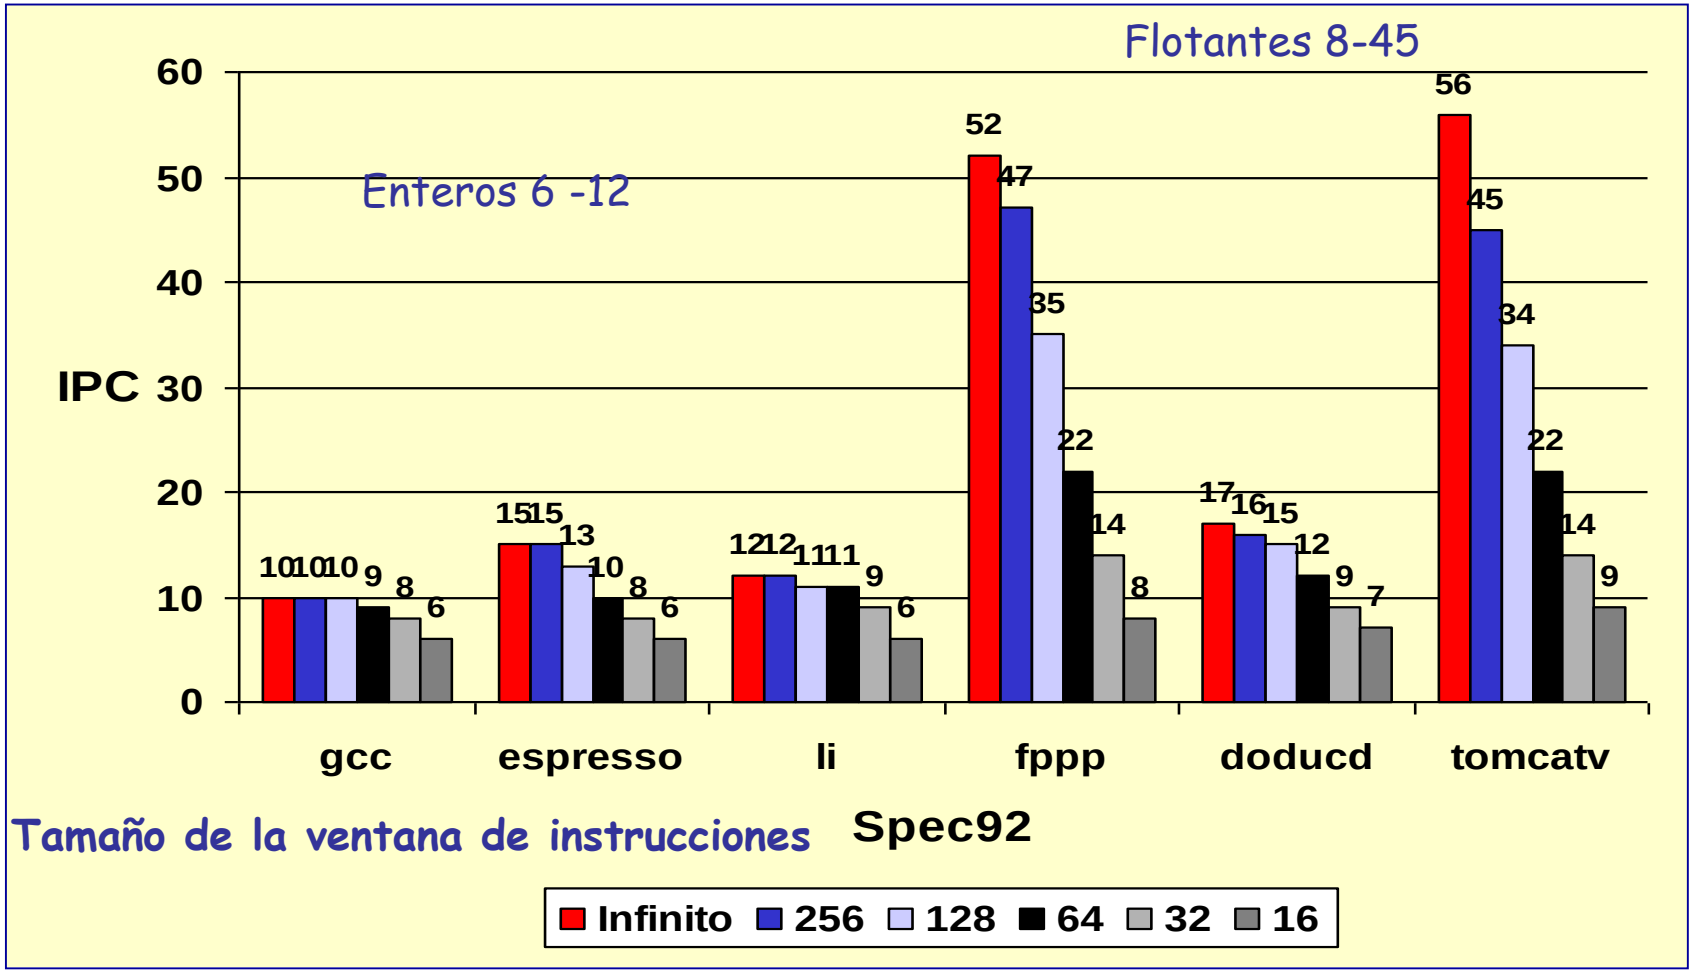

Un ejemplo
Implementaciones X86:
P6, Netburst(Pentium4)...

P6

- P6 (implementacion de la arquitectura IA-32 usada en Pentium Pro, II, III)

Modelo	Año	Clock	L1	L2
Pentium Pro	1995	100-200Mhz	8+8 KB	126-1024KB
Pentium II	1998	233-450Mhz	16+16 KB	256-512KB
Celeron	1999	500-900Mhz	16+16 KB	128KB
Pentium III	1999	450-1100Mhz	16+16 KB	256-512KB
PentiumIII Xeon	1999	700-900Mhz	16+16 KB	1MB-2MB

¿ Como segmentar un ISA con instrucciones entre 1 y 17 bytes?

- El P6 traduce las instrucciones originales IA-32 a "microoperaciones" de 118 bits (Traducción Dinámica)
  - Formato μ-op: cod+3 operandos. Modelo: load/store
  - Muy descodificadas
- Cada instrucción original se traduce a una secuencia de 1 a 4 microoperaciones. Pero ...
  - La instrucciones más complejas son traducidas por una secuencia almacenada en una memoria ROM(8Kx118) (microprograma)
- Tiene un pipeline de 14 etapas
- Ejecución fuera de orden especulativa, con renombrado de registros y ROB

P6 Pipeline (14 etapas)

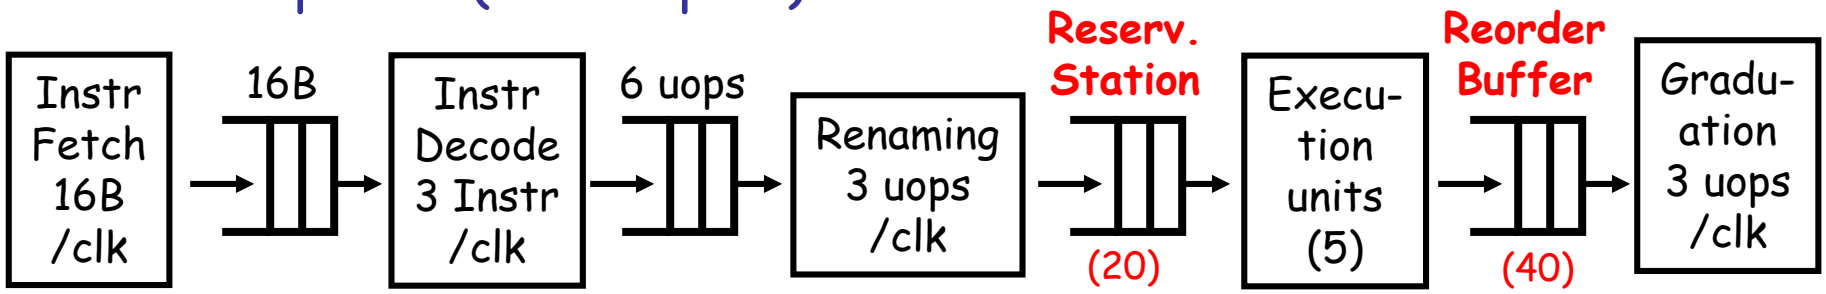

- 8 etapas para fetch, decodificación y issue en orden
  - 1 ciclo para determinar la longitud de la instrucción 80x86 + 2 más para generar las microoperaciones
- 3 etapas para ejecución fuera de orden en una de 5 unidades funcionales
- 3 etapas para la finalización de la instrucción (commit)

Parameter	80x86	microps
Max. instructions issued/clock	3	6
Max. instr. complete exec./clock		5
Max. instr. commited/clock		3
Window (Instrs in reorder buffer)	40	
Number of reservations stations	20	
Number of rename registers	40	
No. integer functional units (FUs)	2	
No. floating point FUs	1	
No. SIMD Fl. Pt. FUs	1	
No. memory Fus	1 load + 1 store	

P6

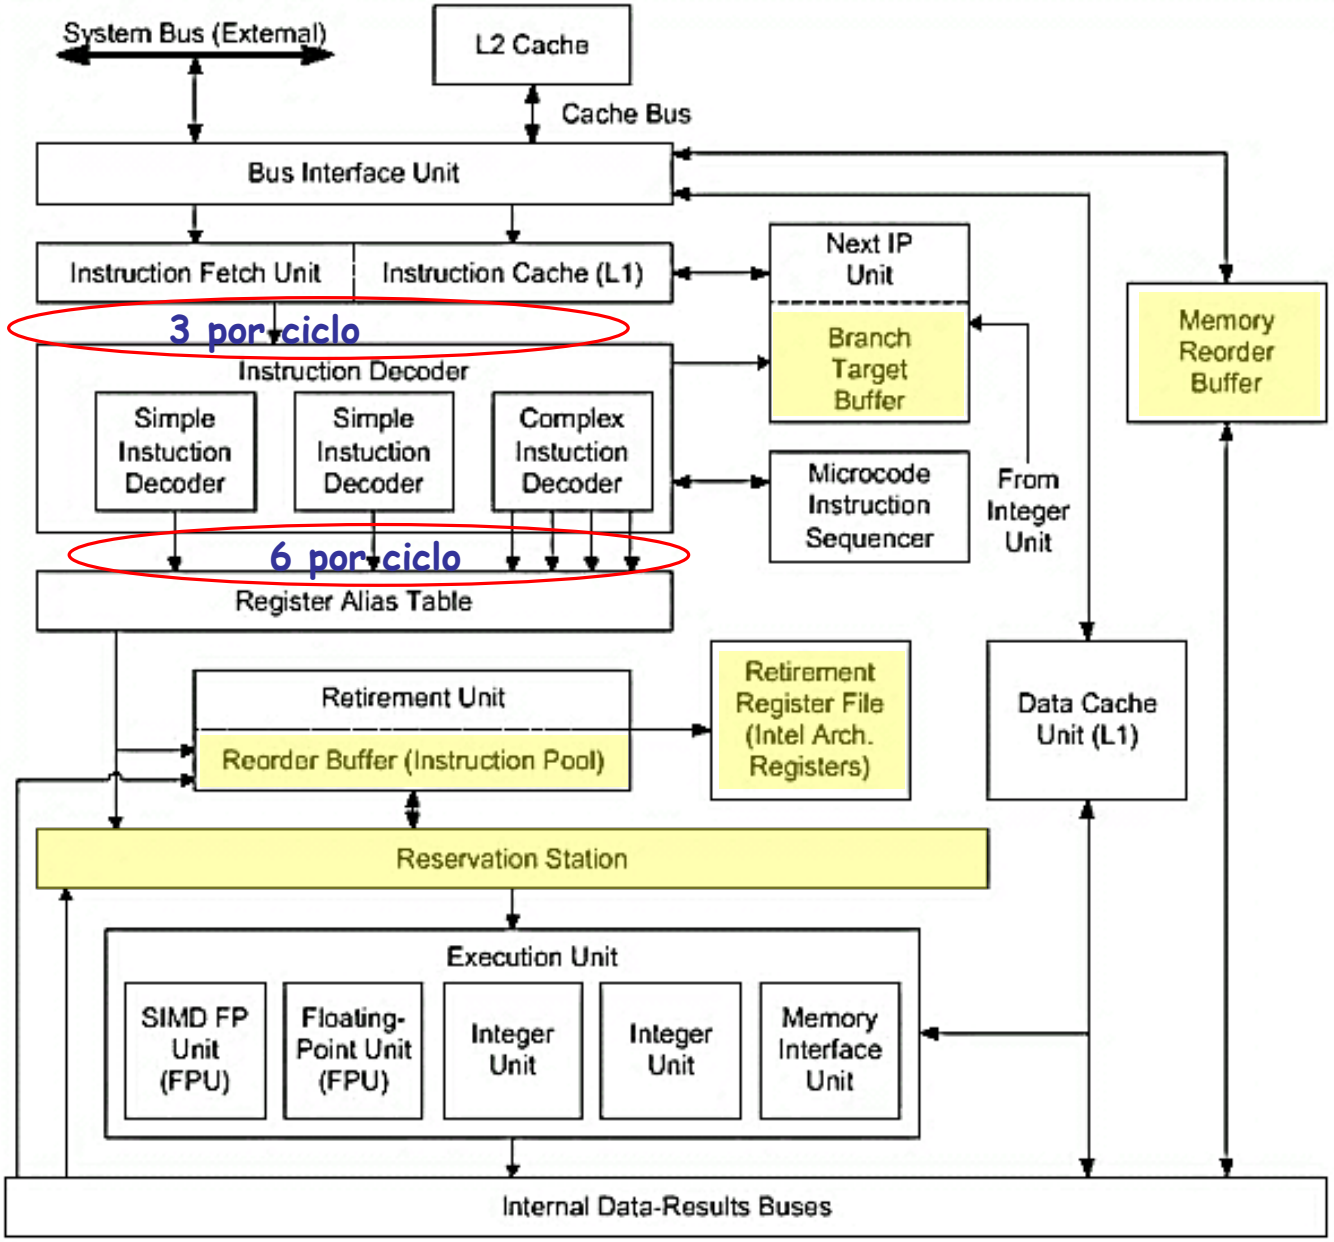
System Bus (External)
L2 Cache
Cache Bus
Bus Interface Unit
Instruction Fetch Unit
Instruction Cache (L1)
Next IP Unit
Branch Target Buffer
Memory Reorder Buffer
3 por ciclo
Instruction Decoder
Simple Instuction Decoder
Simple Instuction Decoder
Complex Instuction Decoder
Microcode Instruction Sequencer
From Integer Unit
6 por ciclo
Register Alias Table
Retirement Unit
Reorder Buffer (Instruction Pool)
Retirement Register File (Intel Arch. Registers)
Data Cache Unit (L1)
Reservation Station
Execution Unit
SIMD FP Unit (FPU)
Floating-Point Unit (FPU)
Integer Unit
Integer Unit
Memory Interface Unit
Internal Data-Results Buses

Pentium 4 (Netburst Microarchitecture)

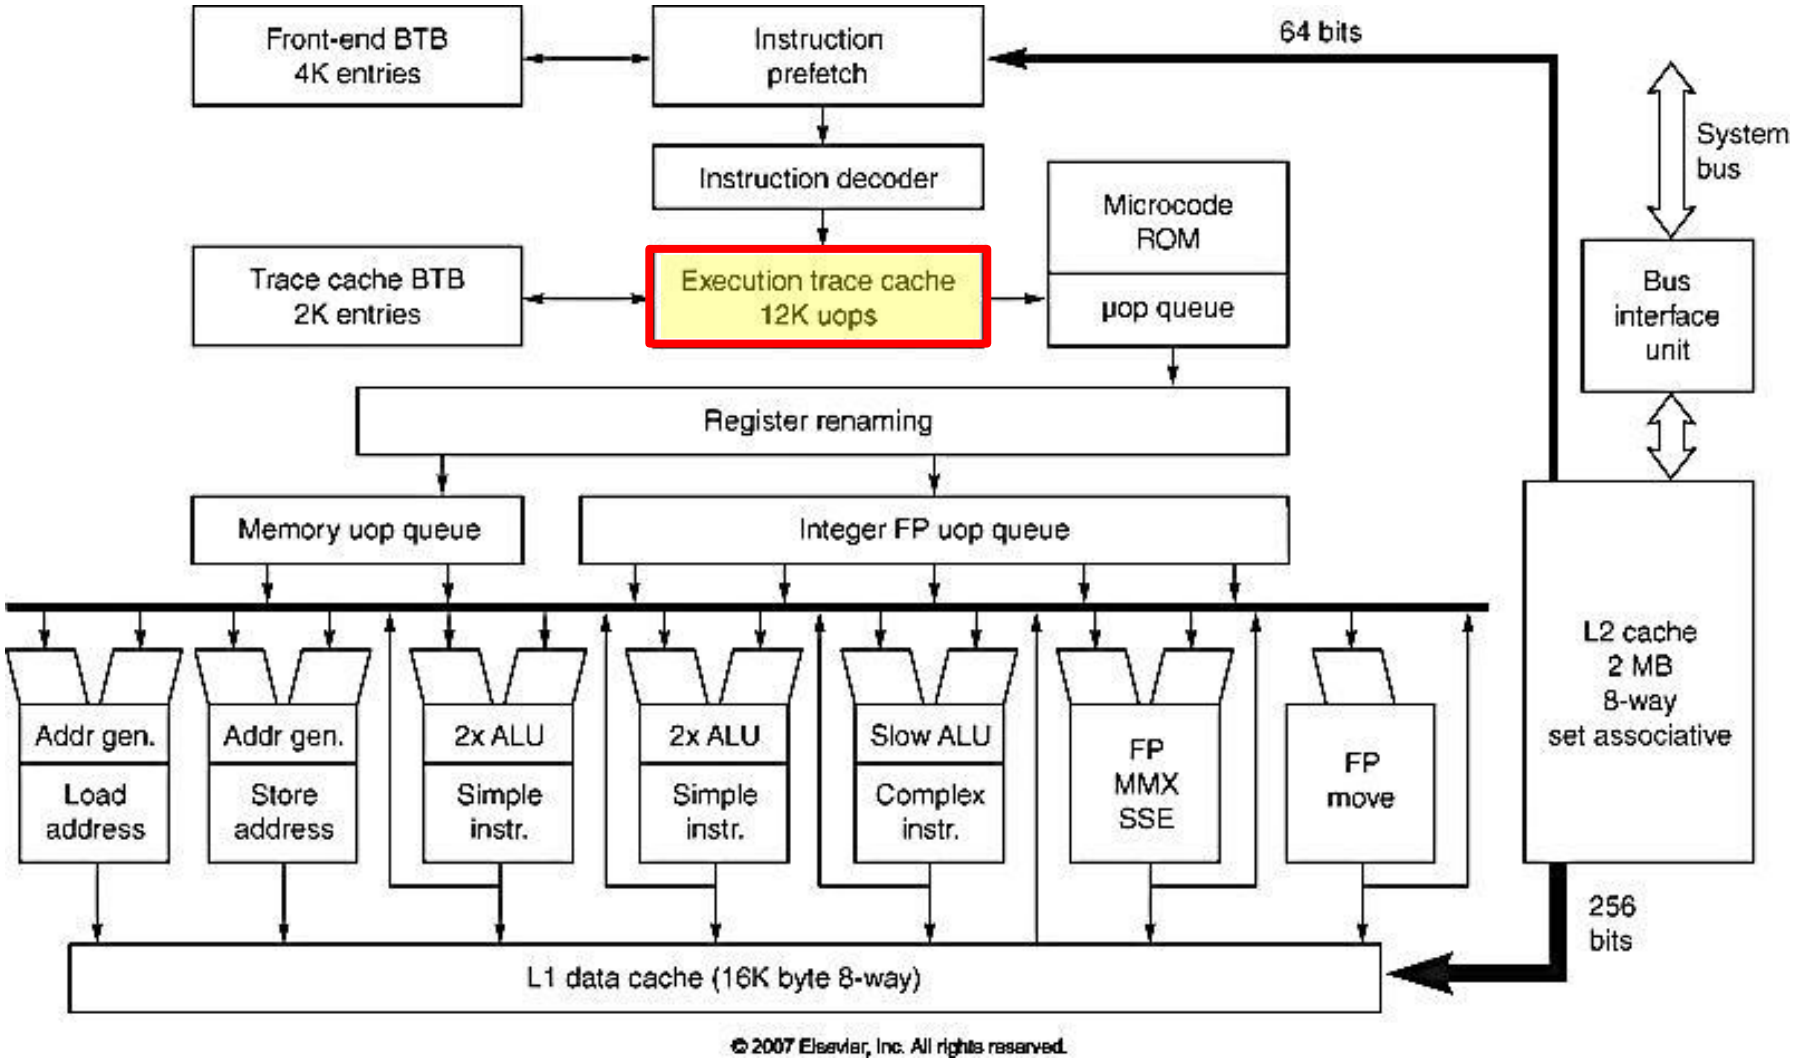

- BTB = Branch Target Buffer (branch predictor)
- I-TLB = Instruction TLB, Trace Cache = Instruction cache
- RF = Register File; AGU = Address Generation Unit
- "Double pumped ALU" means ALU clock rate 2X => 2X ALU F.U.s

Intel Netburst Microarchitecture

- Traduce instrucciones 80x86 a micro-ops (como P6)
- P4 tiene mejor predicción de saltos (x8) y más FU (7 versus 5)
- La Cache de instrucciones almacena micro-operaciones vs. 80x86 instrucciones. "trace cache" (TC), BTB TC 2K entradas
  - En caso de acierto elimina decodificación
- Nuevo bus de memoria: 400(800) MHz vs. 133 MHz (RamBus, DDR, SDRAM) (Bus@1066 Mhz)
- Caches
  - Pentium III: L1I 16KB, L1D 16KB, L2 256 KB
  - Pentium 4: L1I 12K uops, L1D 16 KB 8-way, L2 2MB 8-way
- Clock :
  - Pentium III 1 GHz v. Pentium 4 1.5 GHz (3.8 Ghz)
  - 14 etapas en pipeline vs. 24 etapas en pipeline (31 etapas)
- Instrucciones Multimedia: 128 bits vs. 64 bits => 144 instrucciones nuevas.
- Usa RAMBUS DRAM
  - Más AB y misma latencia que SDRAM. Costo 2X-3X vs. SDRAM
- ALUs operan al doble del clock para operaciones simples
- Registros de renombrado: 40 vs. 128; Ventana: 40 v. 126
- BTB: 512 vs. 4096 entradas. Mejora 30% la tasa de malas predicciones

Netburst(Pentium 4) Rendimiento

Relación μ-operaciones / instrucciones x86

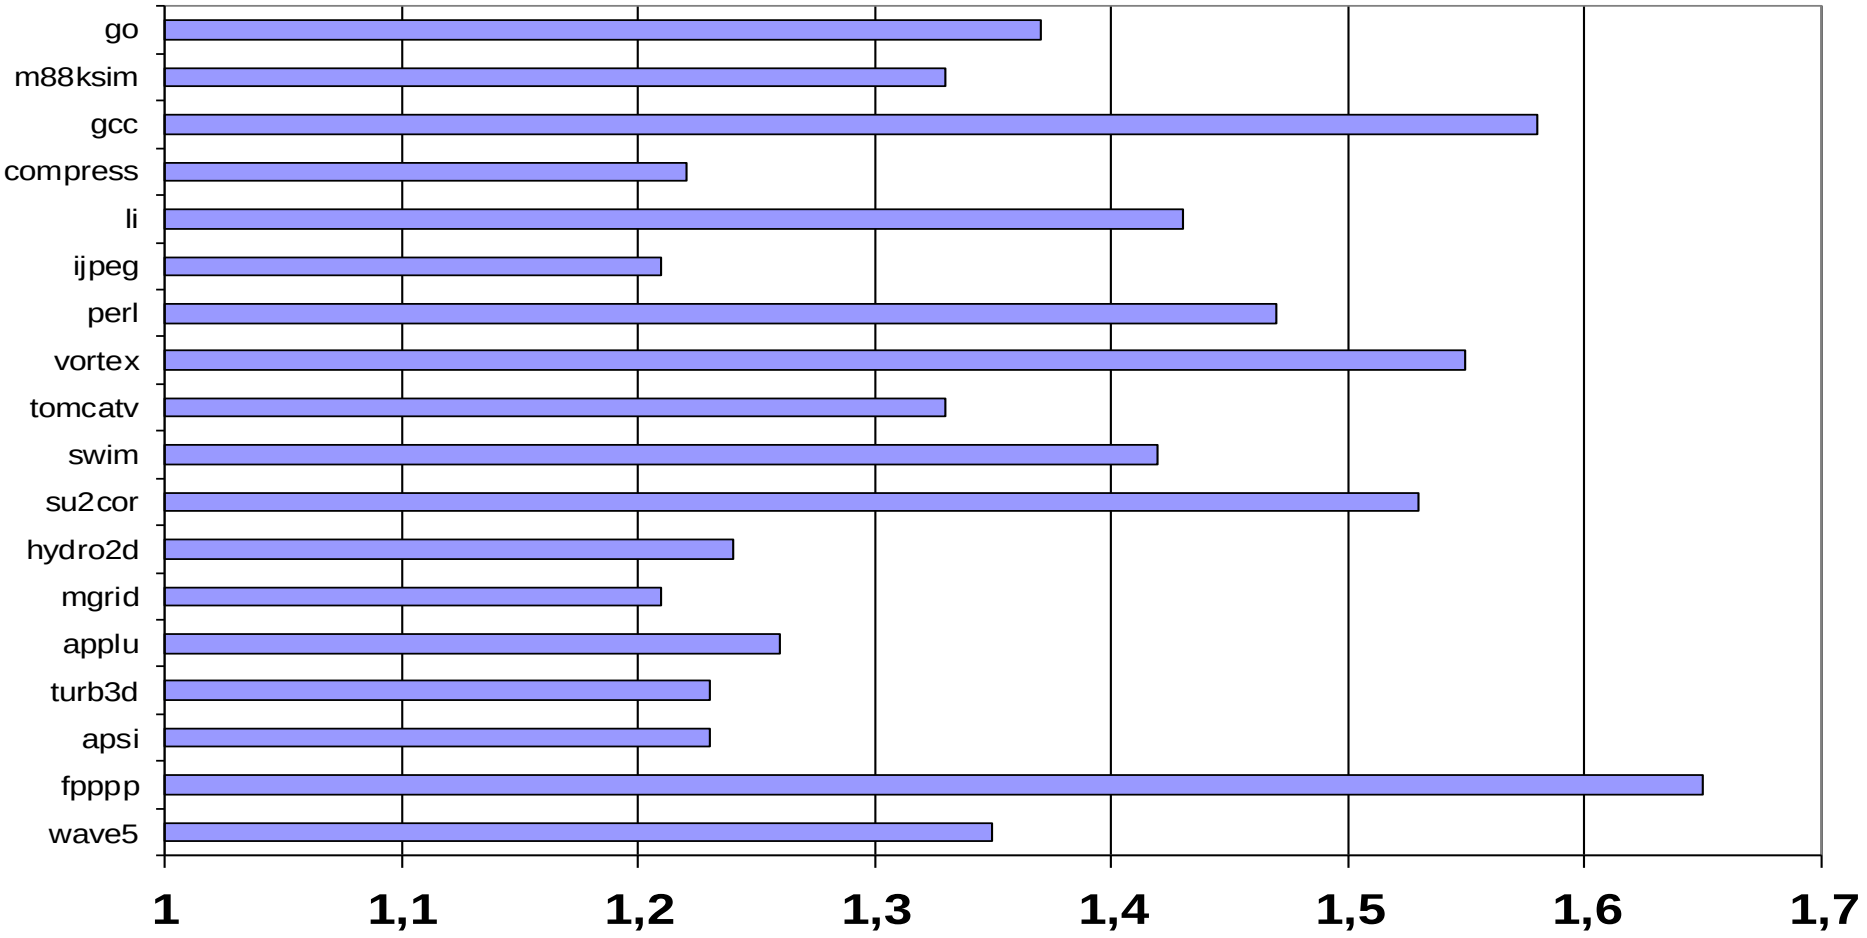

1.2 to 1.6 μops per IA-32 instruction: 1.36 avg. (**1.37 integer**)

Netburst(Pentium4) Rendimiento

Fallos de cache de datos

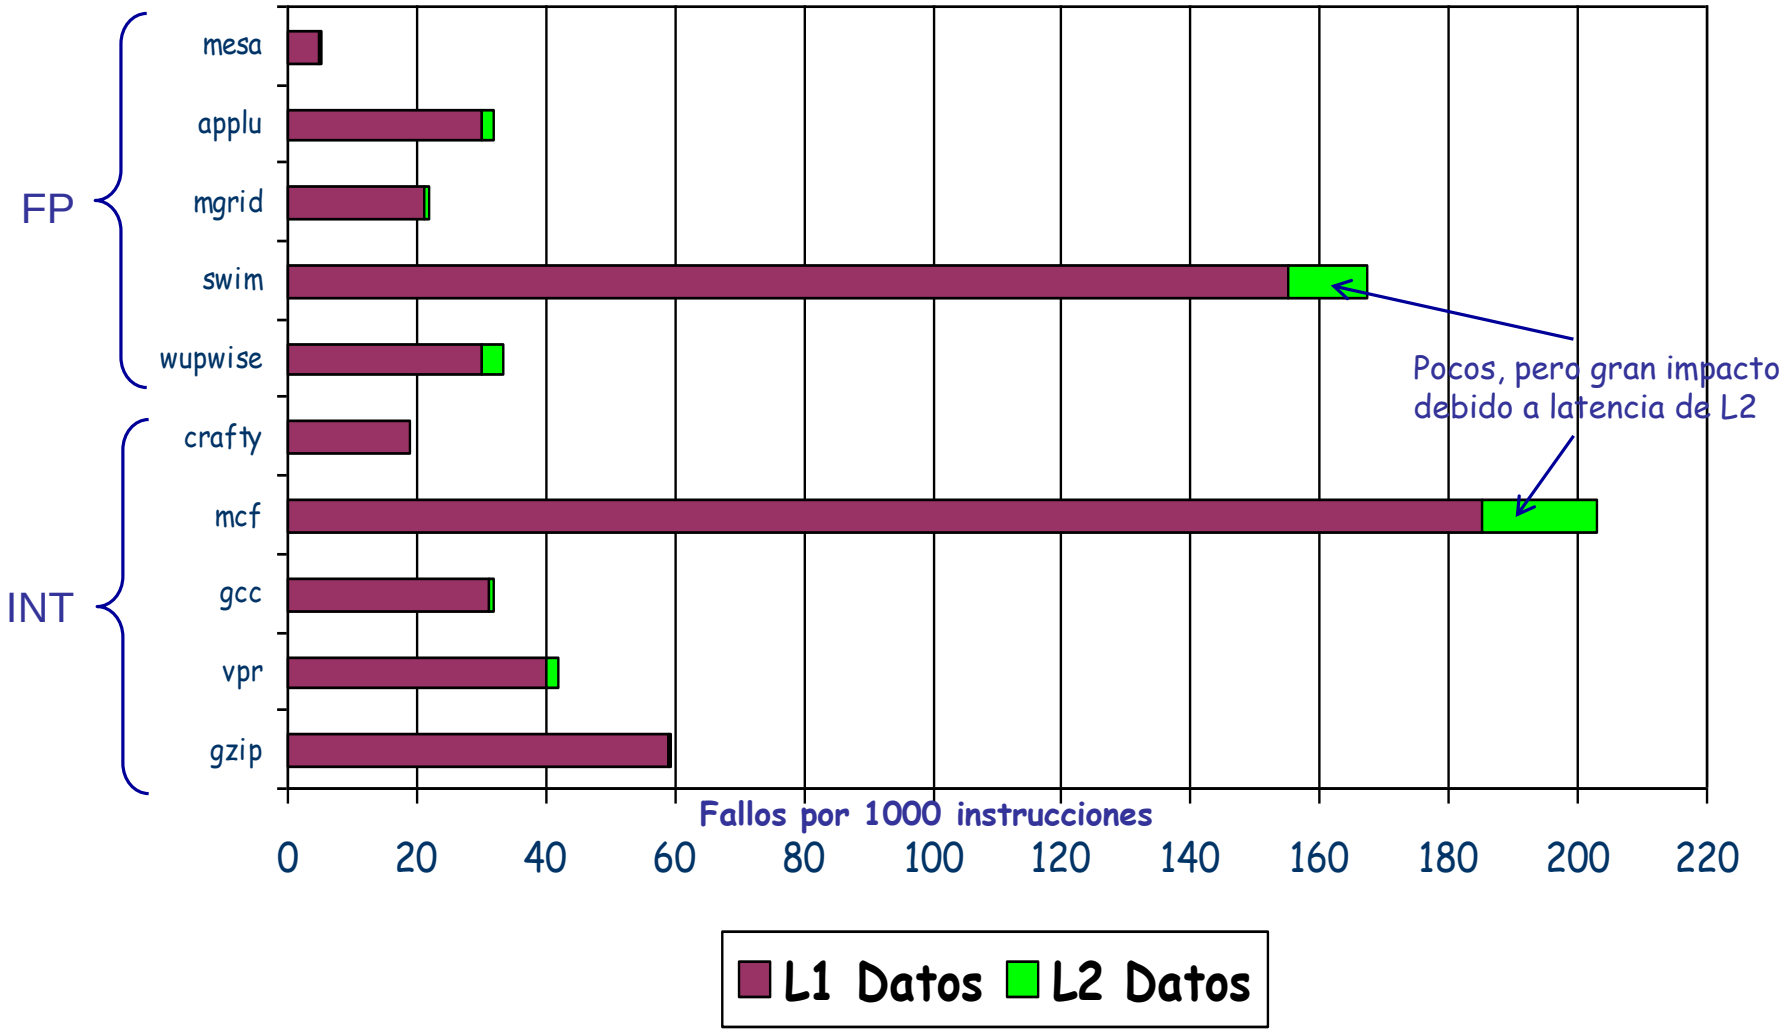

De 10 a 200 fallos por cada mil instrucciones

Netburst(Pentium4) Rendimiento

Comportamiento del predictor: Dos niveles, con información global y local 4K entradas

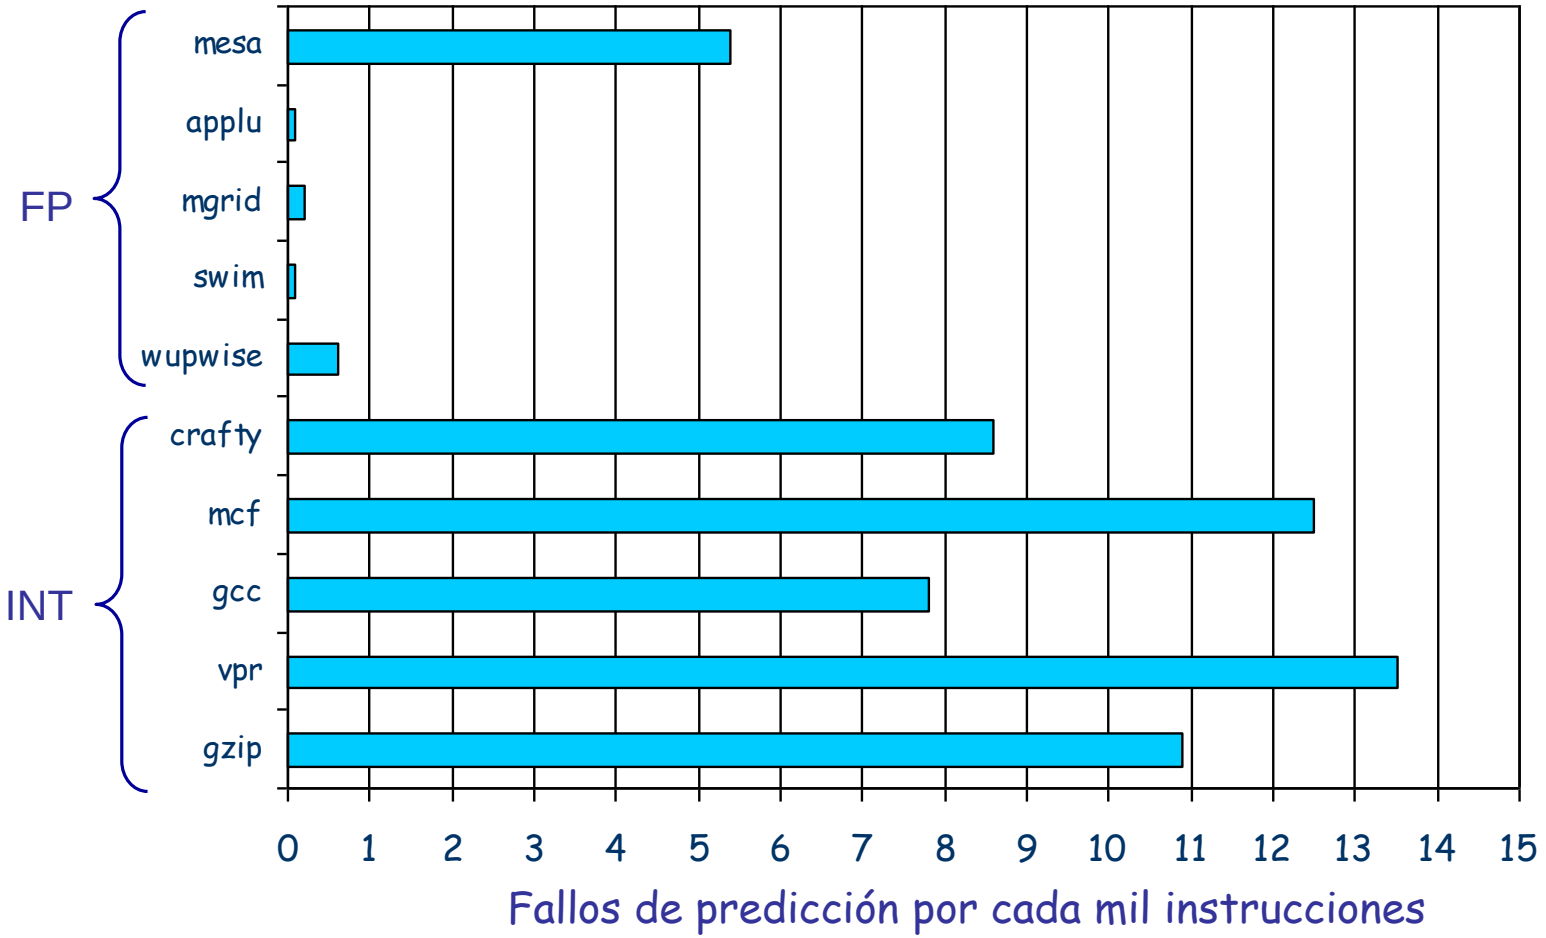

(Tasa de fallos: ≈ 2% en FP, ≈ 6% en INT, según vimos en Tema 2)

Netburst(Pentium4) Rendimiento

Especulación: porcentaje de μ-operaciones que no finalizan (commit)

Muy correlacionada con gráfica anterior

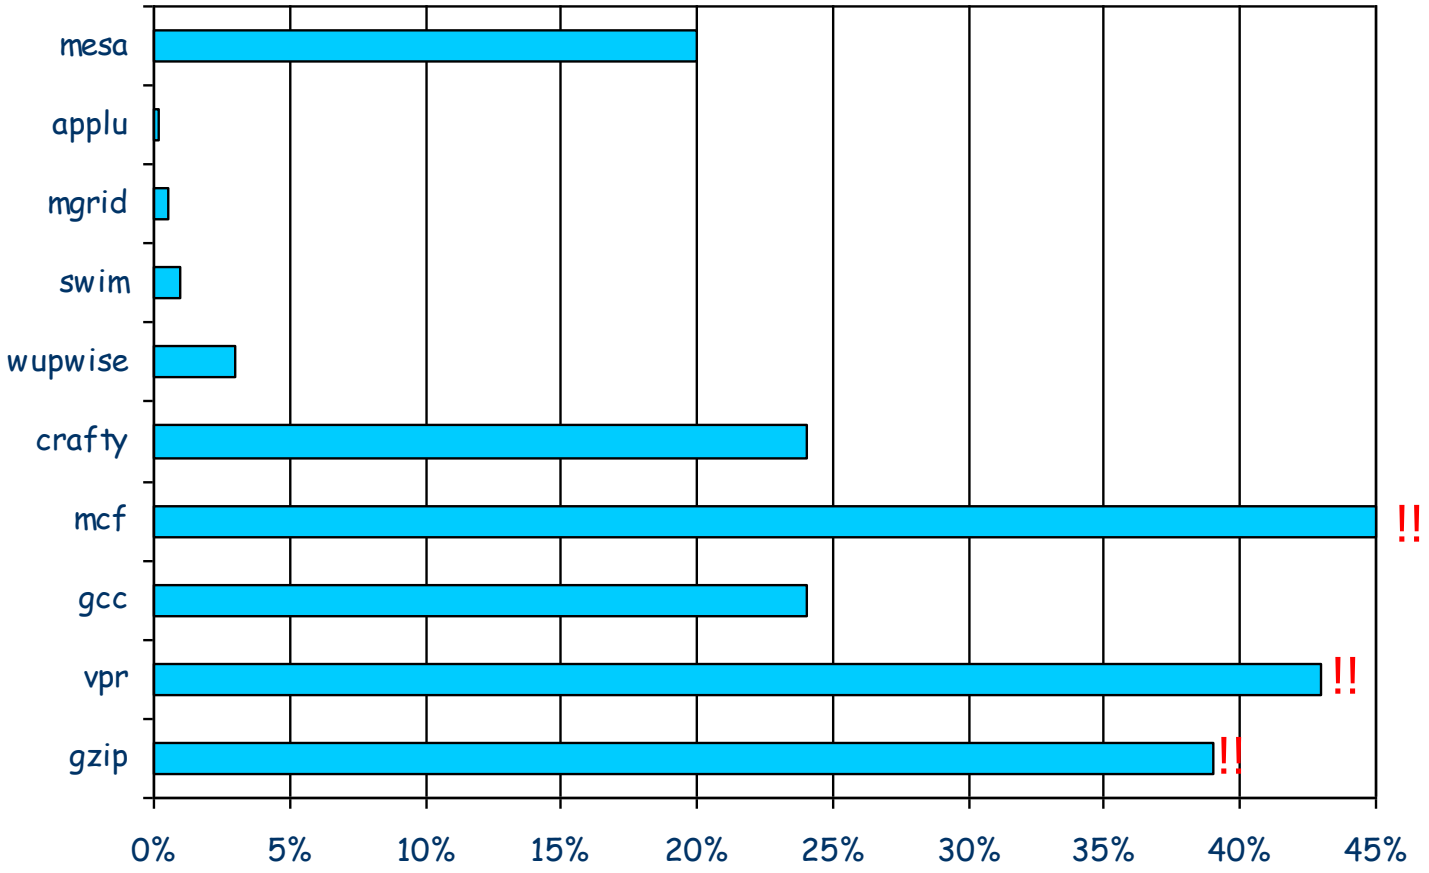

Del 1% al 45 % de las instrucciones no finalizan

Netburst(Pentium4) Rendimiento

CPI real obtenido (ciclos promedio por instr IA-32)

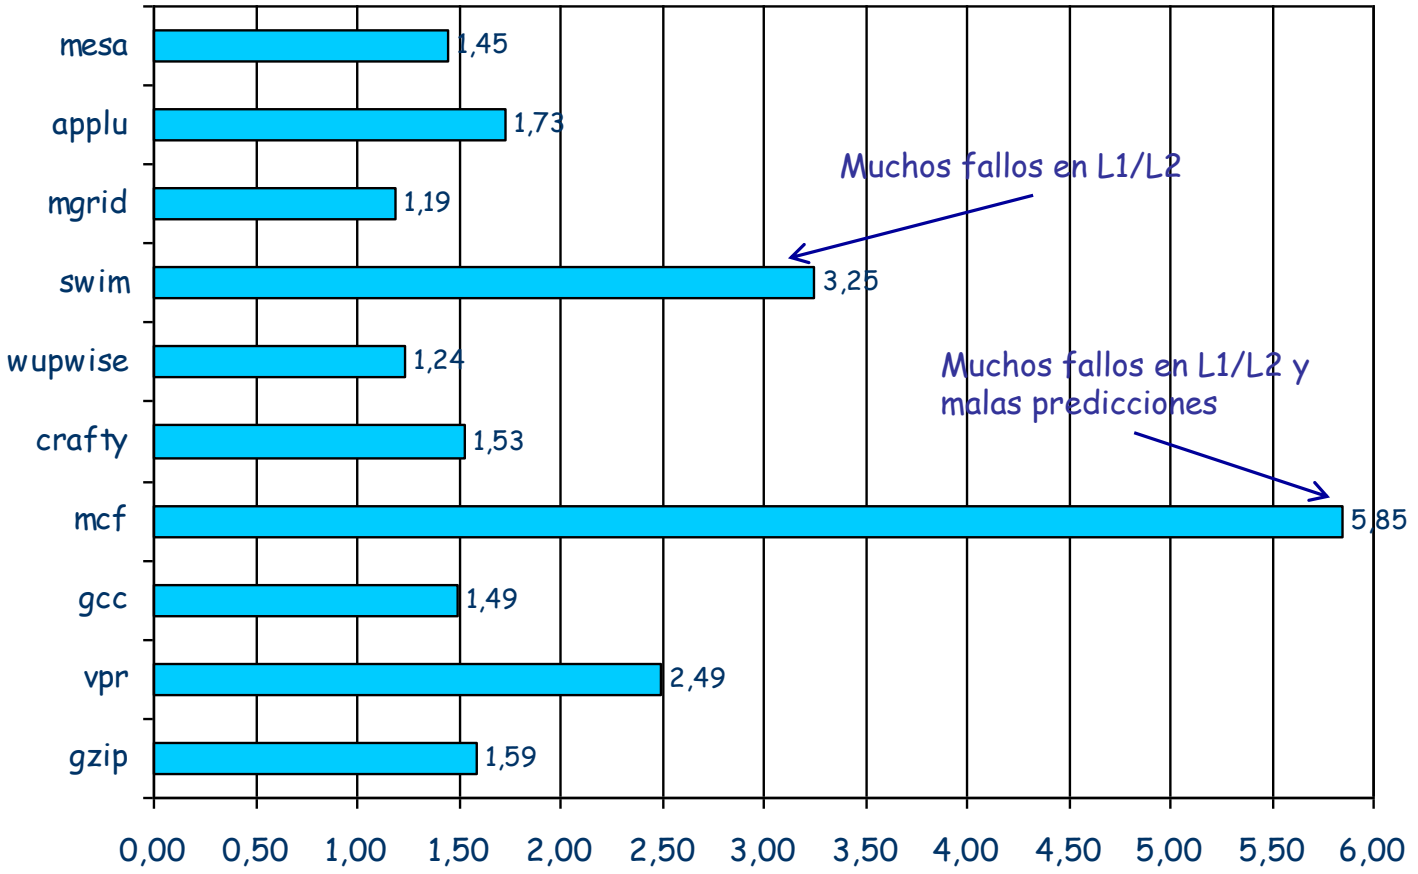

Netburst(Pentium4) versus AMD

Diferencia fundamental; Pentium pipe profundo para soportar alta frecuencia

CPI real obtenido

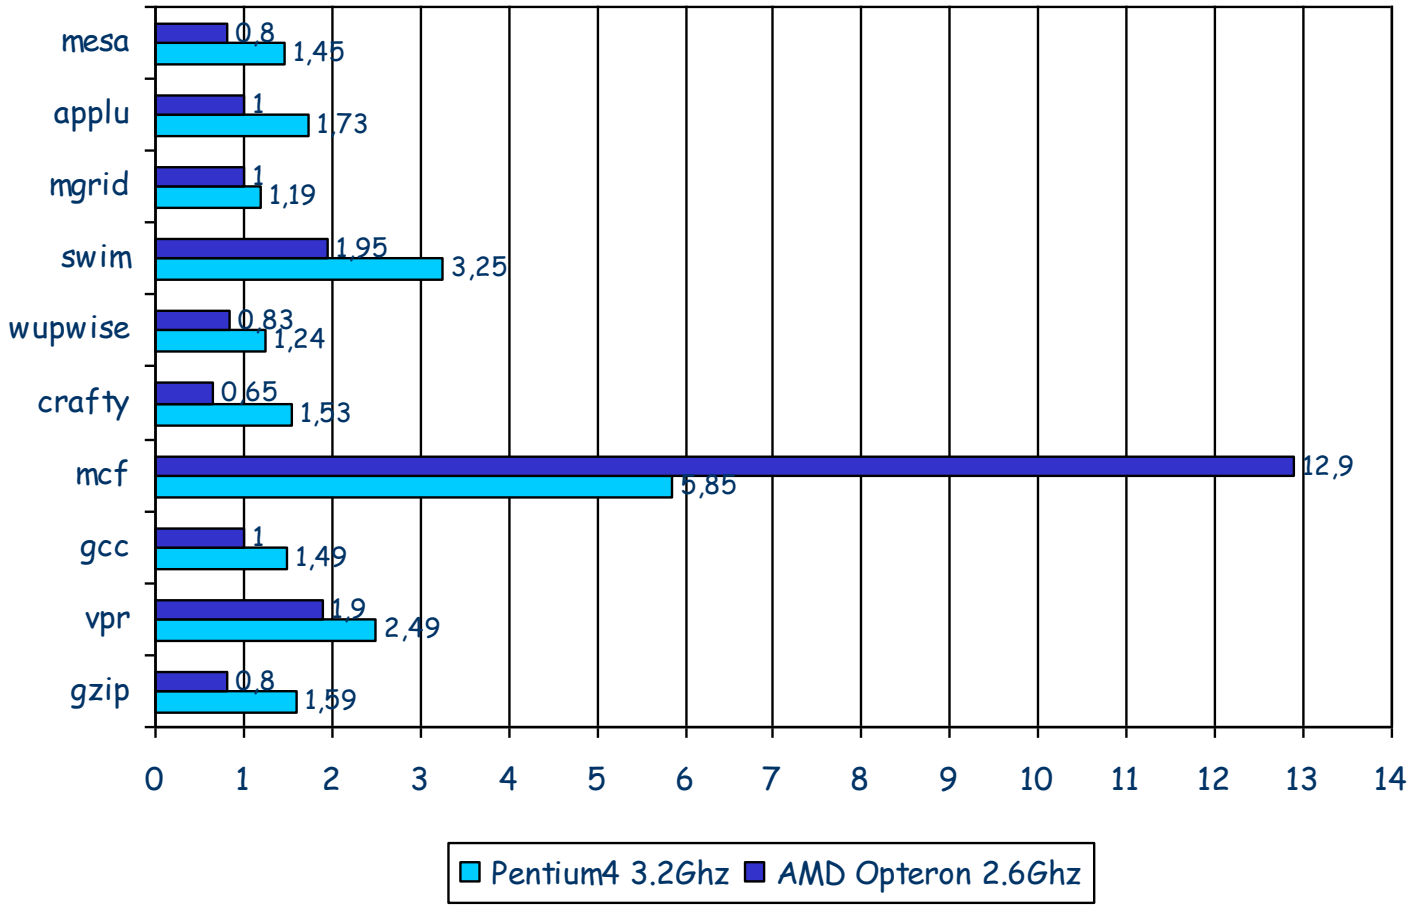

AMD CPI menor en un factor de 1,27. ¿Se puede compensar con la mayor frecuencia?

Netburst(Pentium4) versus AMD

Rendimiento en SPEC2000

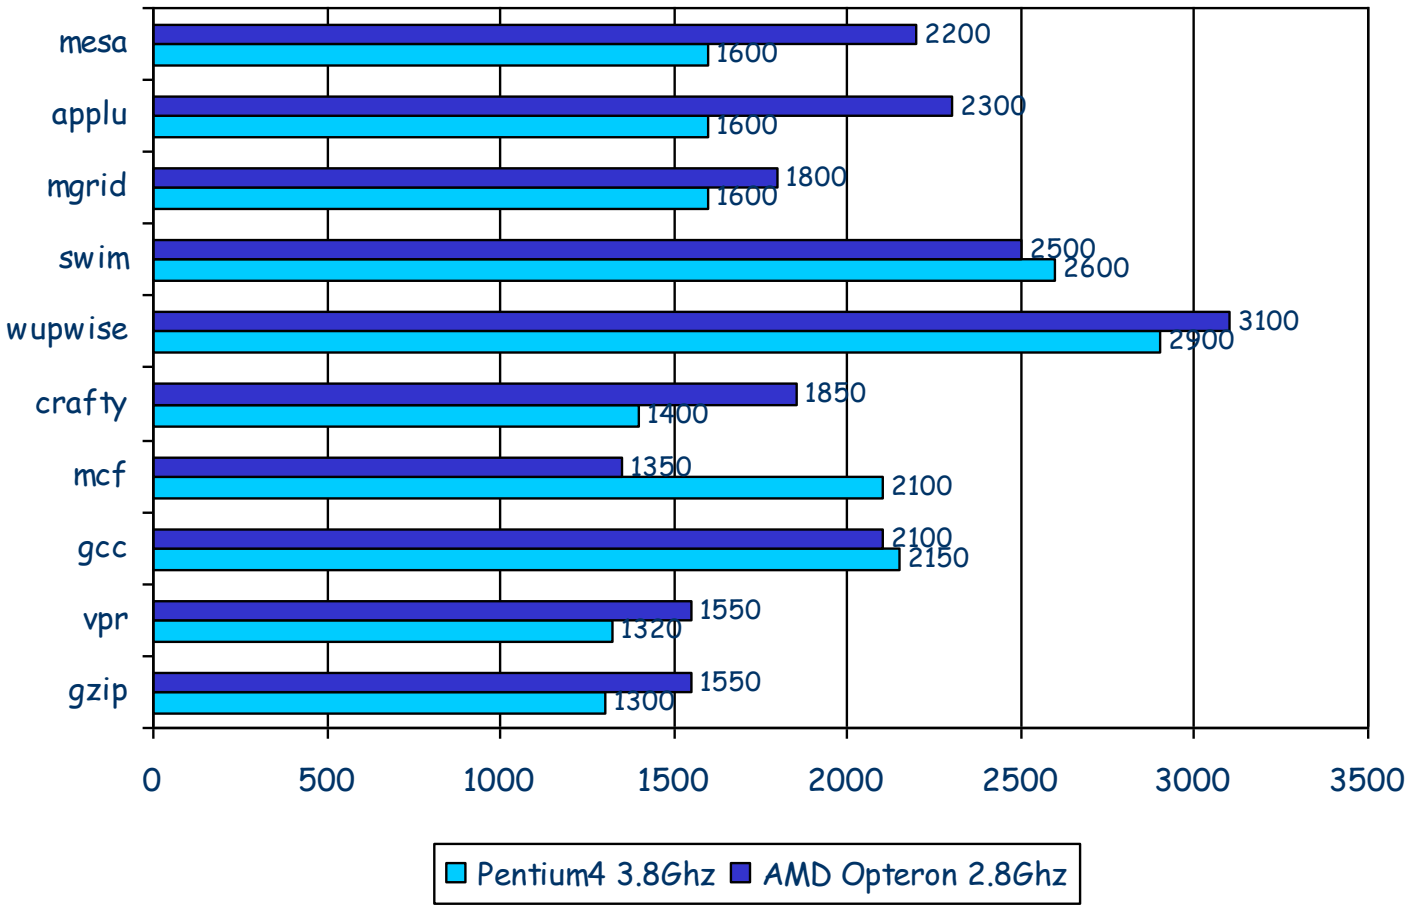

AMD 1,08 más rendimiento. La mayor frecuencia no compensa el mayor CPI

Tick-Tock

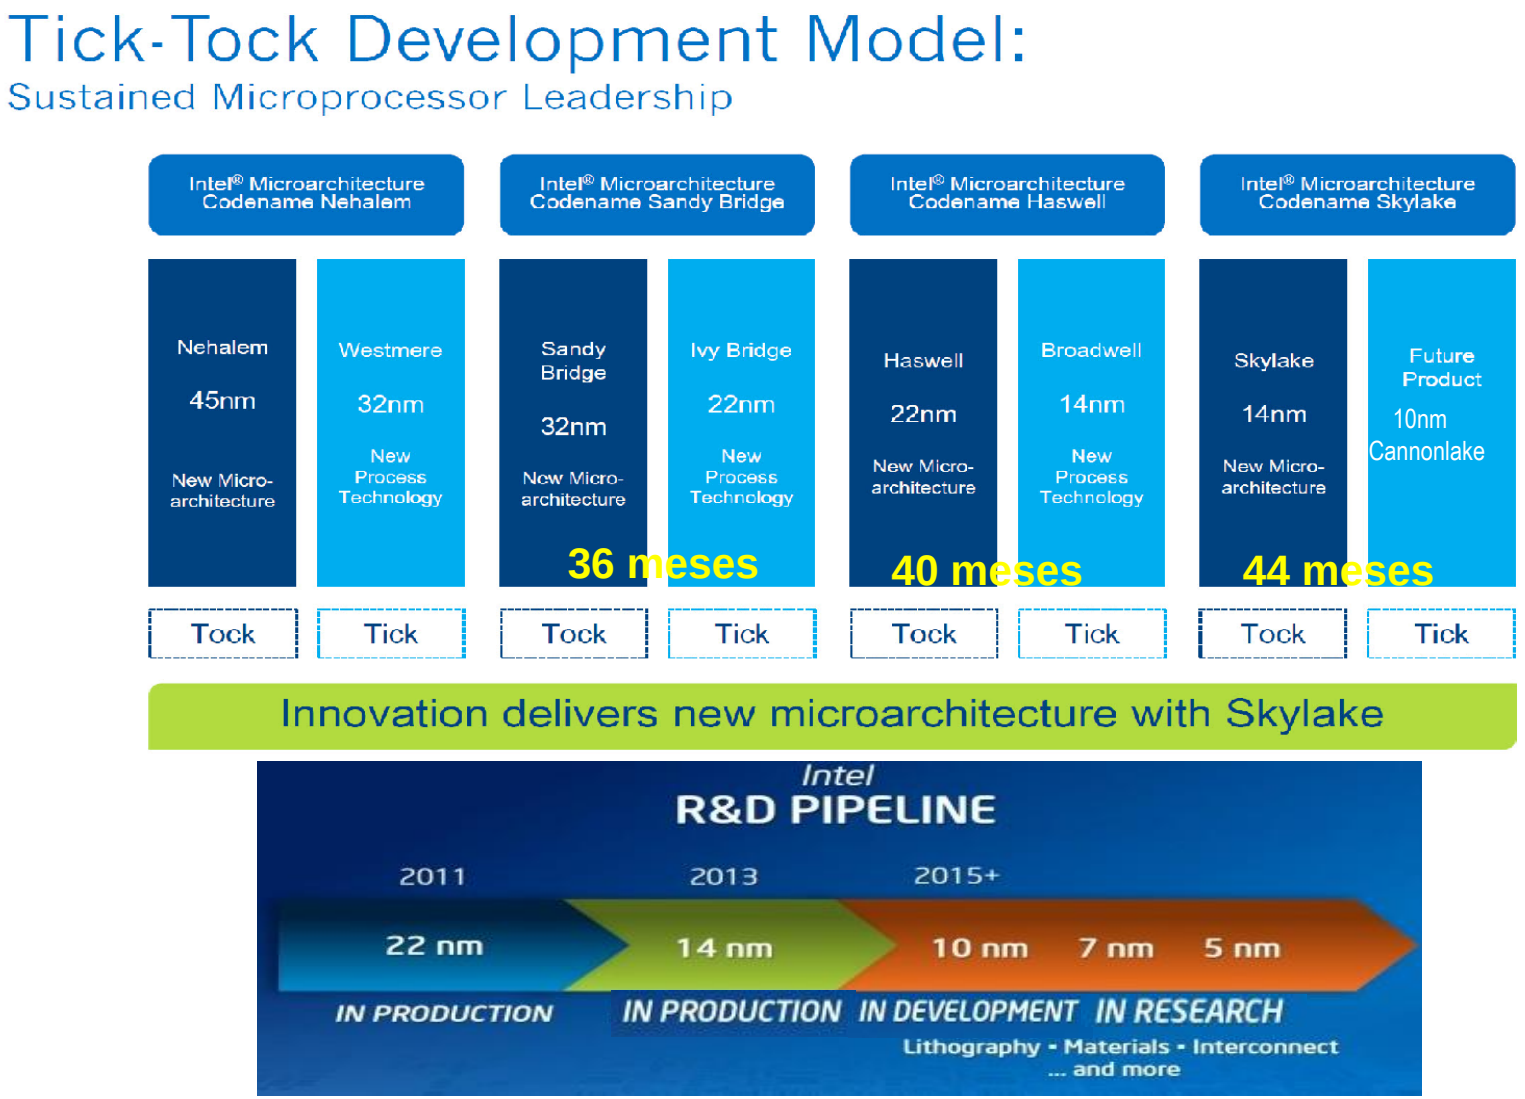
Tick-Tock Development Model:
Sustained Microprocessor Leadership
Intel® Microarchitecture Codename Nehalem
Intel® Microarchitecture Codename Sandy Bridge
Intel® Microarchitecture Codename Haswell
Intel® Microarchitecture Codename Skylake
Nehalem
45nm
New Micro-architecture
Westmere
32nm
New Process Technology
Sandy Bridge
32nm
New Micro-architecture
Ivy Bridge
22nm
New Process Technology
Haswell
22nm
New Micro-architecture
Broadwell
14nm
New Process Technology
Skylake
14nm
New Micro-architecture
Future Product
10nm
Cannonlake
36 meses
40 meses
44 meses
Tock
Tick
Tock
Tick
Tock
Tick
Tock
Tick
Innovation delivers new microarchitecture with Skylake
Intel
R&D PIPELINE
2011
2013
2015+
22 nm
14 nm
10 nm
7 nm
5 nm
IN PRODUCTION
IN PRODUCTION
IN DEVELOPMENT
IN RESEARCH
Lithography • Materials • Interconnect
... and more

Nehalem Microarchitecture

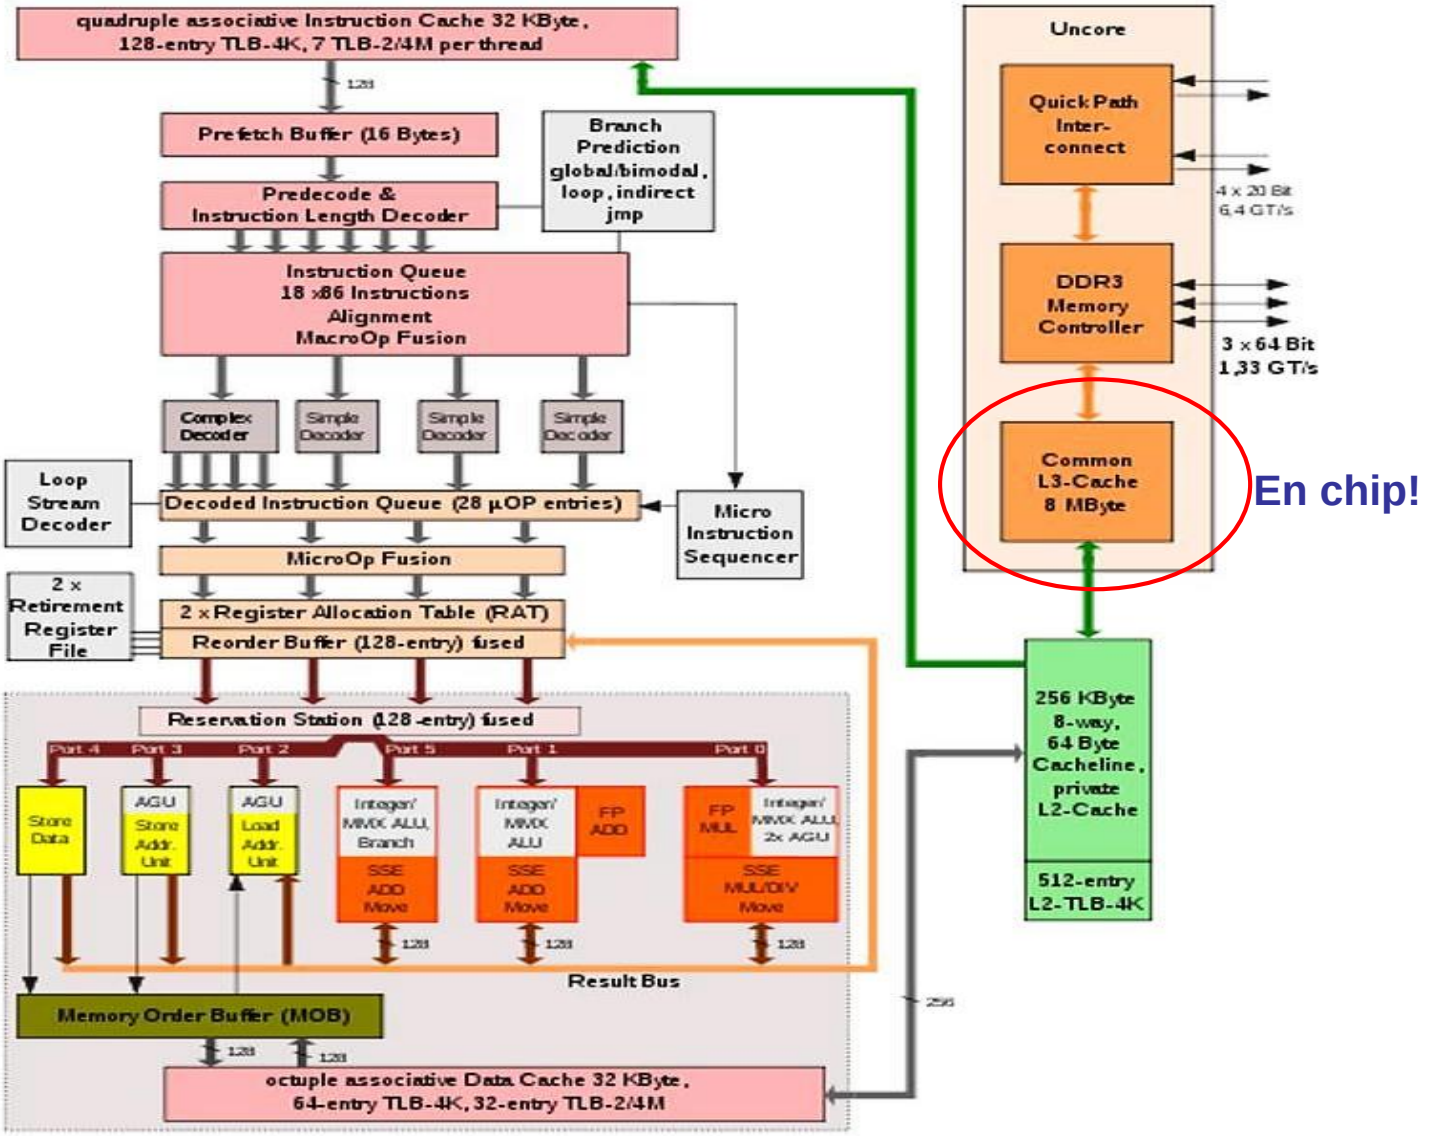

En chip!

Skylake Microarchitecture

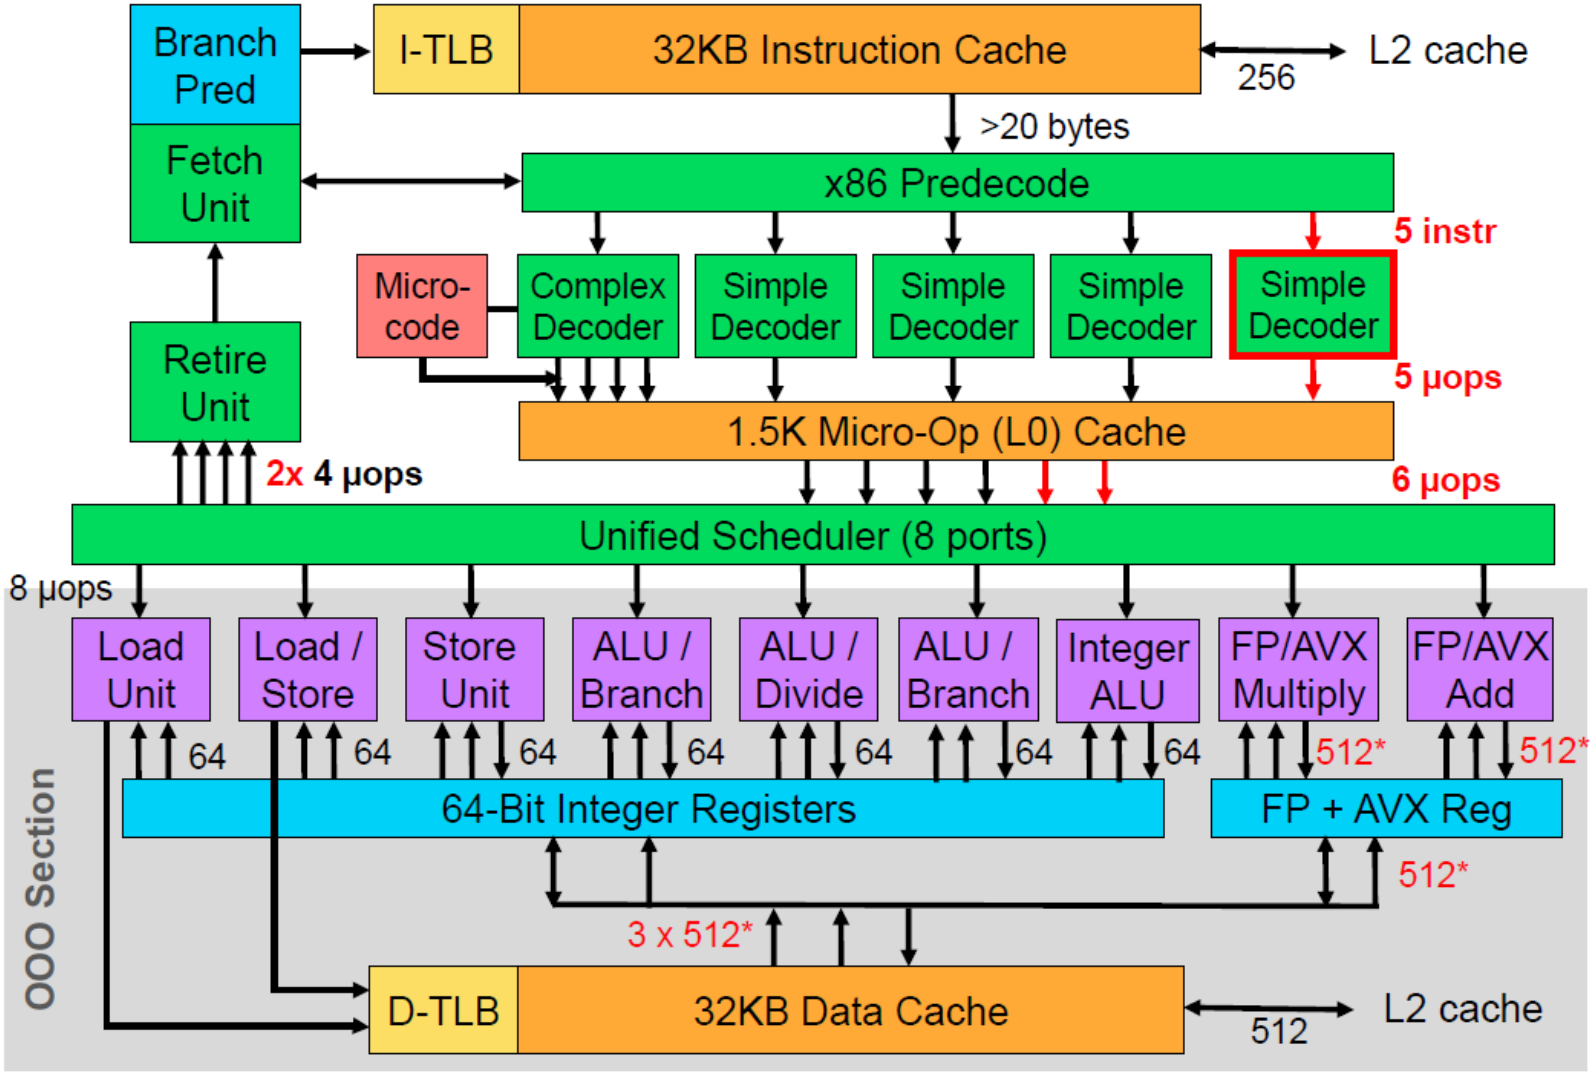

Skylake Microarchitecture

	Nehalem	Sandy Bridge	Haswell	Skylake
x86 Decoders	4 instr	4 instr	4 instr	5 instr
Max Instr/Cycle	4 ops	6 ops	8 ops	8 ops
Reorder Buffer	128 ops	168 ops	192 ops	224 ops
Load Buffer	48 loads	64 loads	72 loads	72 loads
Store Buffer	32 stores	36 stores	42 stores	56 stores
Scheduler	36 entries	54 entries	60 entries	97 entries
Integer Rename	In ROB	160 regs	168 regs	180 regs
FP Rename	In ROB	144 regs	168 regs	168 regs
Allocation Queue	28/thread	28/thread	56 total	64/thread

Límites del ILP

- **¿Como superar los limites de este estudio?**
- Mejoras en los compiladores e ISAs
- Eliminar riesgos EDL y EDE en la memoria
- Eliminar riesgos LDE en registros y memoria. Predicción
- Buscar otros paralelismos (thread)

❑ Buscar paralelismo de más de un thread

- Hay mucho paralelismo en algunas aplicaciones (Bases de datos, códigos científicos)
- Thread Level Parallelism
  - Thread: proceso con sus propias instrucciones y datos
    - Cada thread puede ser parte de un programa paralelo de múltiples procesos, o un programa independiente.
    - Cada thread tiene todo el estado (instrucciones, datos, PC, register state, …) necesario para permitir su ejecución
    - Arquitecturas(multiprocesadores, MultiThreading y multi/many cores)
- Data Level Parallelism: Operaciones idénticas sobre grandes volúmenes de datos (extensiones multimedia y arquitecturas vectoriales)

Thread Level Parallelism (TLP) versus ILP

- ILP explota paralelismo implícito dentro de un segmento de código lineal o un bucle
- TLP representa el uso de múltiples thread que son inherentemente paralelos.
- Objetivo: Usar múltiples streams de instrucciones para mejorar:
  - Throughput de computadores que ejecutan muchos programas diferentes.
  - Reducir el tiempo de ejecución de un programa multi-threaded
- TLP puede ser más eficaz en coste que ILP

¿ Por que multithreading ?

- Procesador superescalar
  (P. ej.: Hasta 3 Fus pueden comenzar una op en cada ciclo)

  Causas de baja utilización de UFs:
  - No hay instrucciones que ejecutar (fallo cache)
  - Hay instr, pero faltan operandos
  - Hay UFs libres, pero no del tipo necesario

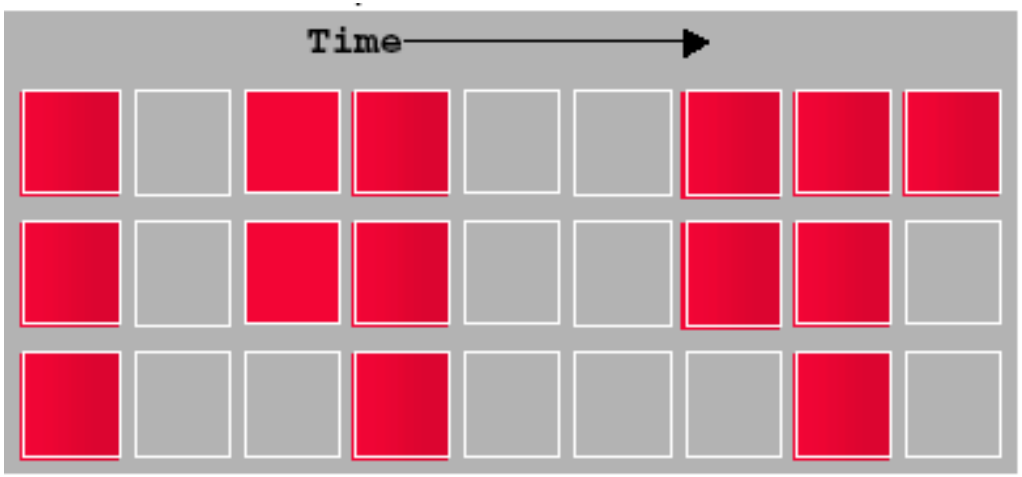

- La latencia de memoria crece.
  ¿Como soportarla?

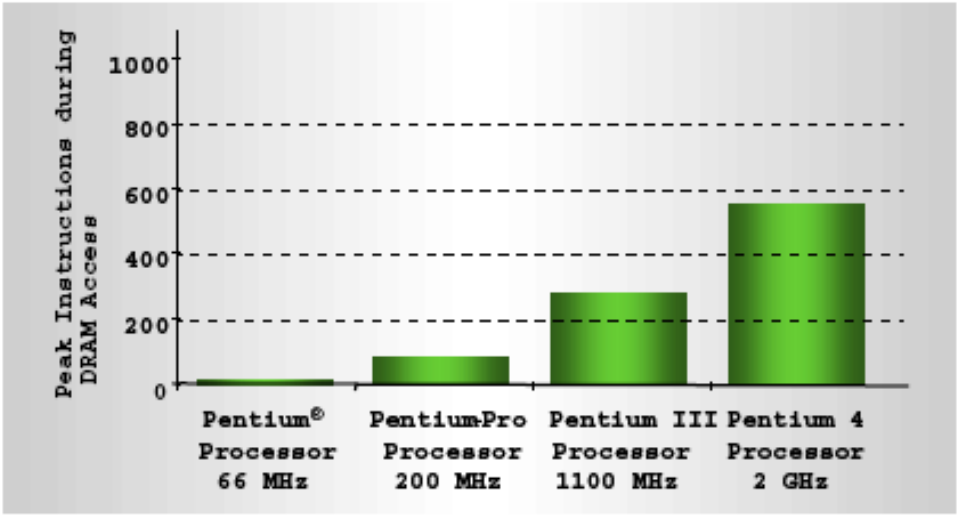

❑ Multithreading

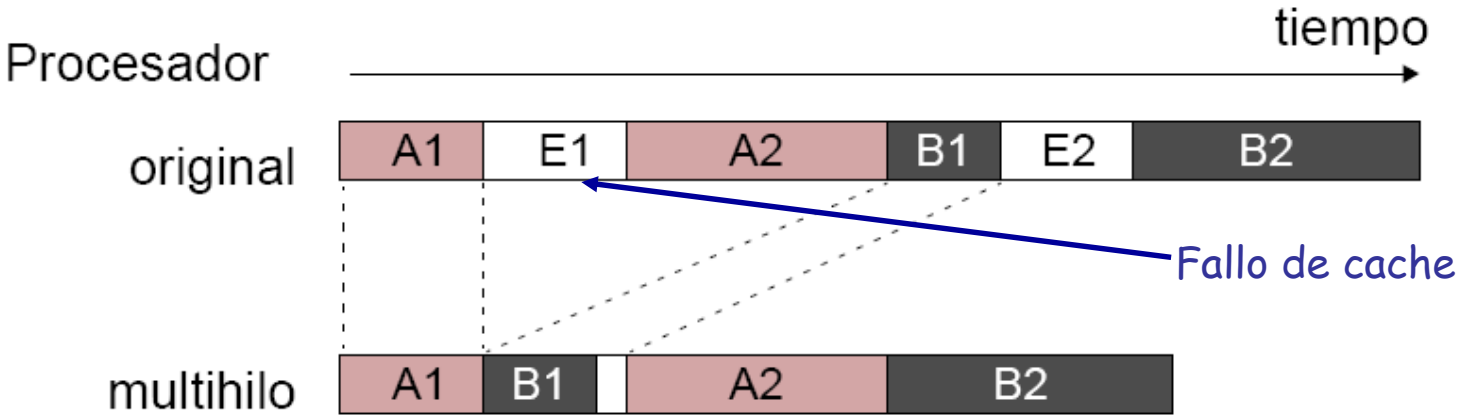

- Incrementar el trabajo procesado por unidad de tiempo
- Si los hilos son del mismo trabajo se reduce el tiempo de ejecución

La técnica multithreading no es ideal y se producen pérdidas de rendimiento.
Por ejemplo, un programa puede ver incrementado su tiempo de ejecución aunque el número de programas ejecutados por unidad de tiempo sea mayor cuando se utiliza multithreading.

❑ Ejecución Mulithreaded

- Multithreading: múltiples threads comparten los recursos del procesador
  - El procesador debe mantener el estado de cada thread e.g., una copia de bloque de registros, un PC separado, tablas de páginas separadas.
  - La memoria compartida ya soporta múltiples procesos.
  - HW para conmutación de thread muy rápido. Mucho mas rápido que entre procesos.

Clave

- ¿Cuándo conmutar?
  - Cada ciclo conmutar de thread (grano fino)
  - Cuando un thread debe parar (por ejemplo fallo de cache)

- HEP (1978), Alewife , M-Machine , Tera-Computer

Multithreading de Grano Fino

- Conmuta entre threads en cada instrucción, entrelazando la ejecución de los diferentes thread.
- Generalmente en modo "round-robin", los threads bloqueados se saltan
- La CPU debe ser capaz de conmutar de thread cada ciclo.
- Ventaja; puede ocultar stalls de alta y baja latencia, cuando un thread esta bloqueado los otros usan los recursos.
- Desventaja; retarda la ejecución de cada thread individual, ya que un thread sin stall es retrasado por reparto de recursos (ciclos) entre threads
- Ejemplo Niagara y Niagara 2 (SUN)

Multithreading Grano Grueso

- Conmuta entre threads solo en caso de largos stalls, como fallos de cache L2
- Ventajas
  - No necesita conmutación entre thread muy rápida.
  - No retarda cada thread, la conmutación solo se produce cuando un thread no puede avanzar.
- Desventajas; no elimina perdidas por stalls cortos. La conmutación es costosa en ciclos.
  - Como CPU lanza instrucciones de un nuevo thread, el pipeline debe ser vaciado.
  - El nuevo thread debe llenar el pipe antes de que las instrucciones empiecen a completarse.
- Ejemplos; IBM AS/400, Montecito (Itanium2 9000), Sparc64 VI

❑ Simultaneous Multithreading

Motivación: Recursos no usados en un procesador superescalar

Un thread, 8 unidades

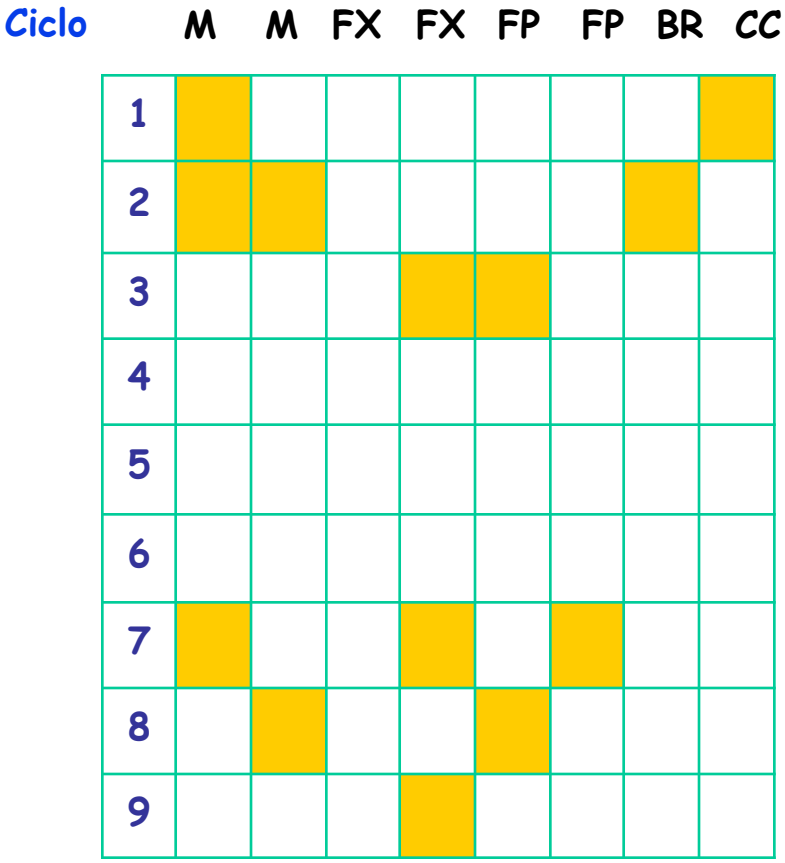

Dos threads, 8 unidades

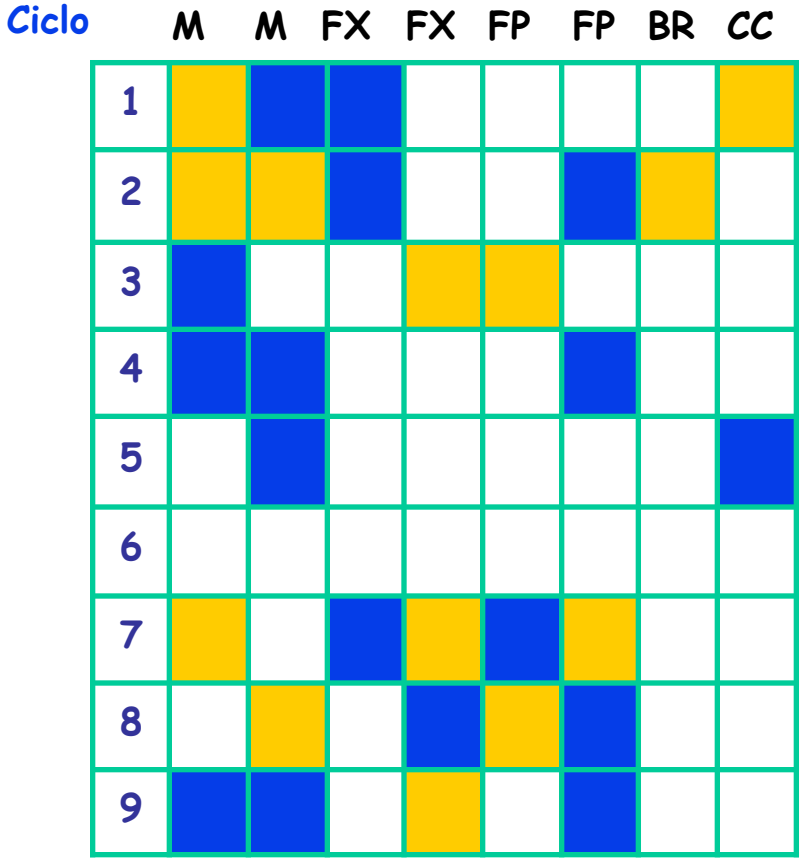

M = Load/Store, FX = Fixed Point, FP = Floating Point, BR = Branch, CC = Condition Codes

Simultaneous Multithreading (SMT)

- Simultaneous multithreading (SMT): dentro de un procesador superescalar fuera de orden ya hay mecanismos Hw para soportar la ejecución de más de un thread
  - Gran numero de registros físicos donde poder mapear los registros arquitectónicos de los diferentes threads
  - El renombrado de registros proporciona un identificador único para los operandos de una instrucción, por tanto instrucciones de diferentes thread se pueden mezclar sin confundir sus operados
  - La ejecución fuera de orden permite una utilización eficaz de los recursos.
- Solo necesitamos sumar una tabla de renombrado por thread y PC separados
  - Commit independiente se soporta con un ROB por thread (Lógico o físico)
- Ojo conflictos en la jerarquía de memoria
- Ejemplos: Pentium4, Power5 y 6, Nehalem (2008)

❑Comparación

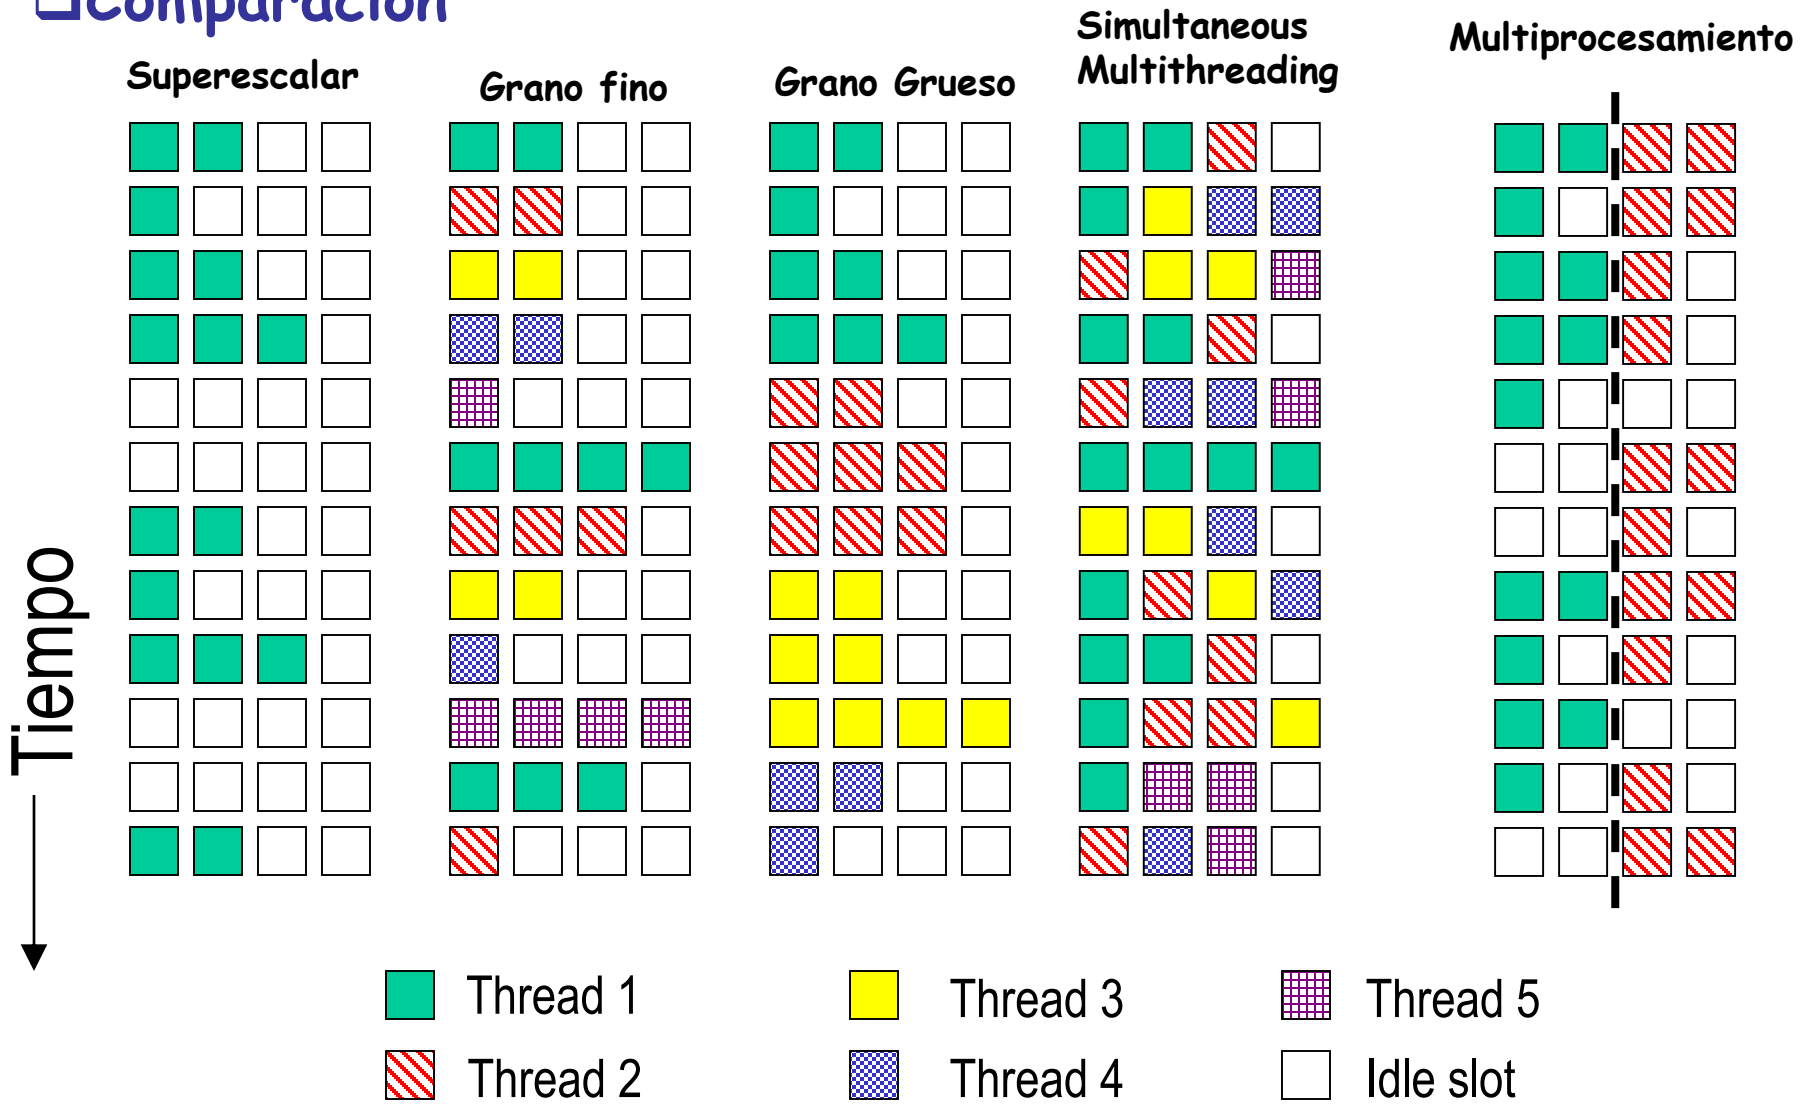

❑ Simultaneous multithreading

❑ Un solo hilo: un flujo de instrucciones

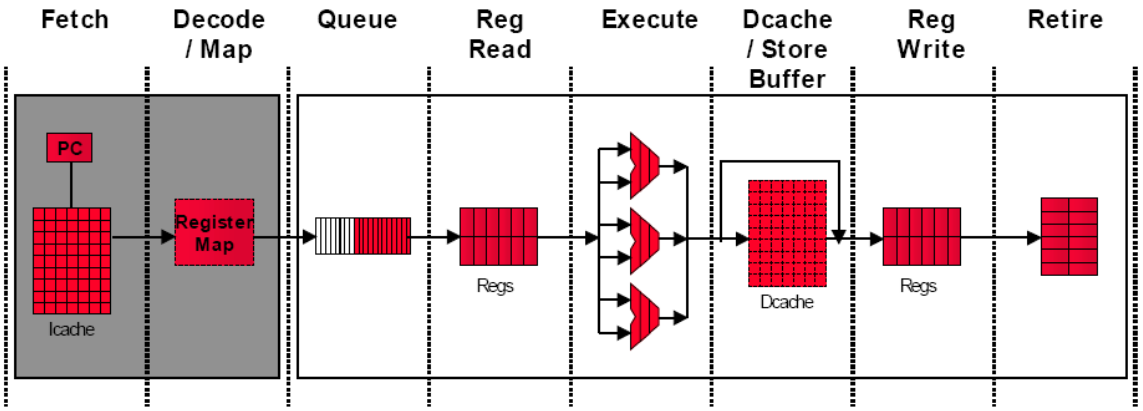

✓ todos los recursos utilizados por un hilo

❑ Multihilo: varios flujos de instrucciones

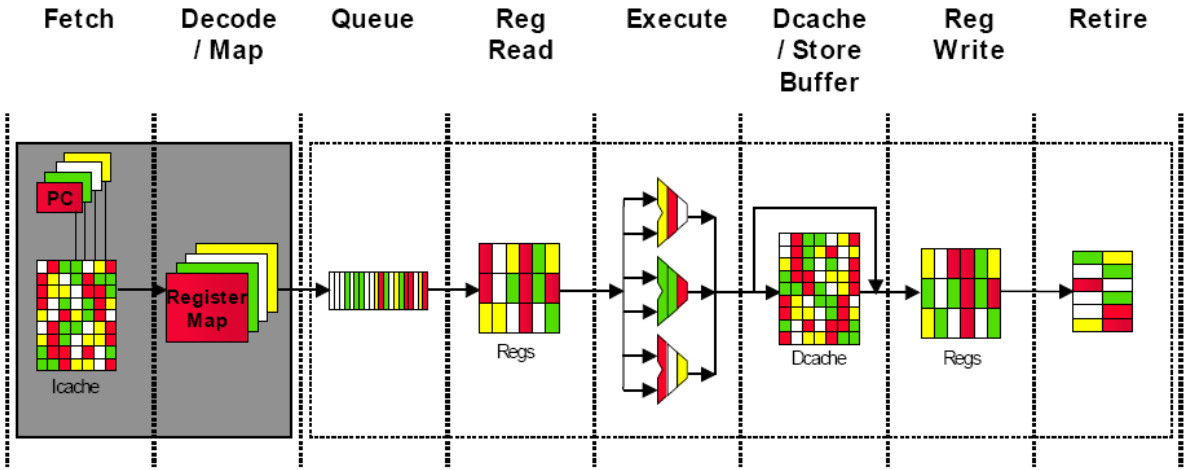

✓ recursos para distinguir el estado de los hilos

✓ los otros recursos se pueden compartir

Pentium-4 Hyperthreading (2002)

- Primer procesador comercial SMT 2 threads
- Los procesadores lógicos comparten casi todos los recursos del procesador físico.
  - Caches, unidades de ejecución, predictor de saltos
- Overhead de área por hyperthreading ~ 5%
- Cuando un procesador lógico (thread) se detiene el otro puede progresar usando los recursos
  - Ningun thread puede usar todos los recursos (colas) cuando hay 2 threads activos.
- Procesadores ejecutando solo un thread se ejecuta a la misma velocidad que sin hyperthreading
- Hyperthreading se elimino de los P6 OoO sucesores del Pentium-4 (Pentium-M, Core Duo, Core 2 Duo), fue de Nuevo incluido con el Nehalem en 2008.

❑ Power 4 (IBM 2000)

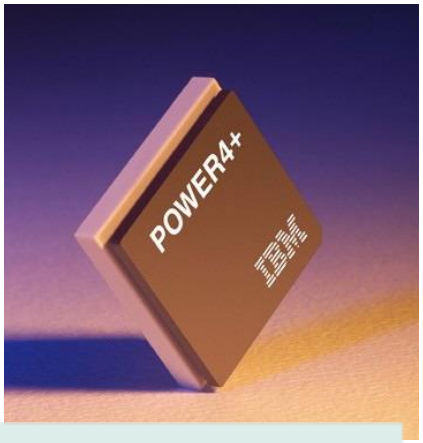

Predecesor Single-threaded del Power 5.
8 unidades de ejecución fuera de orden

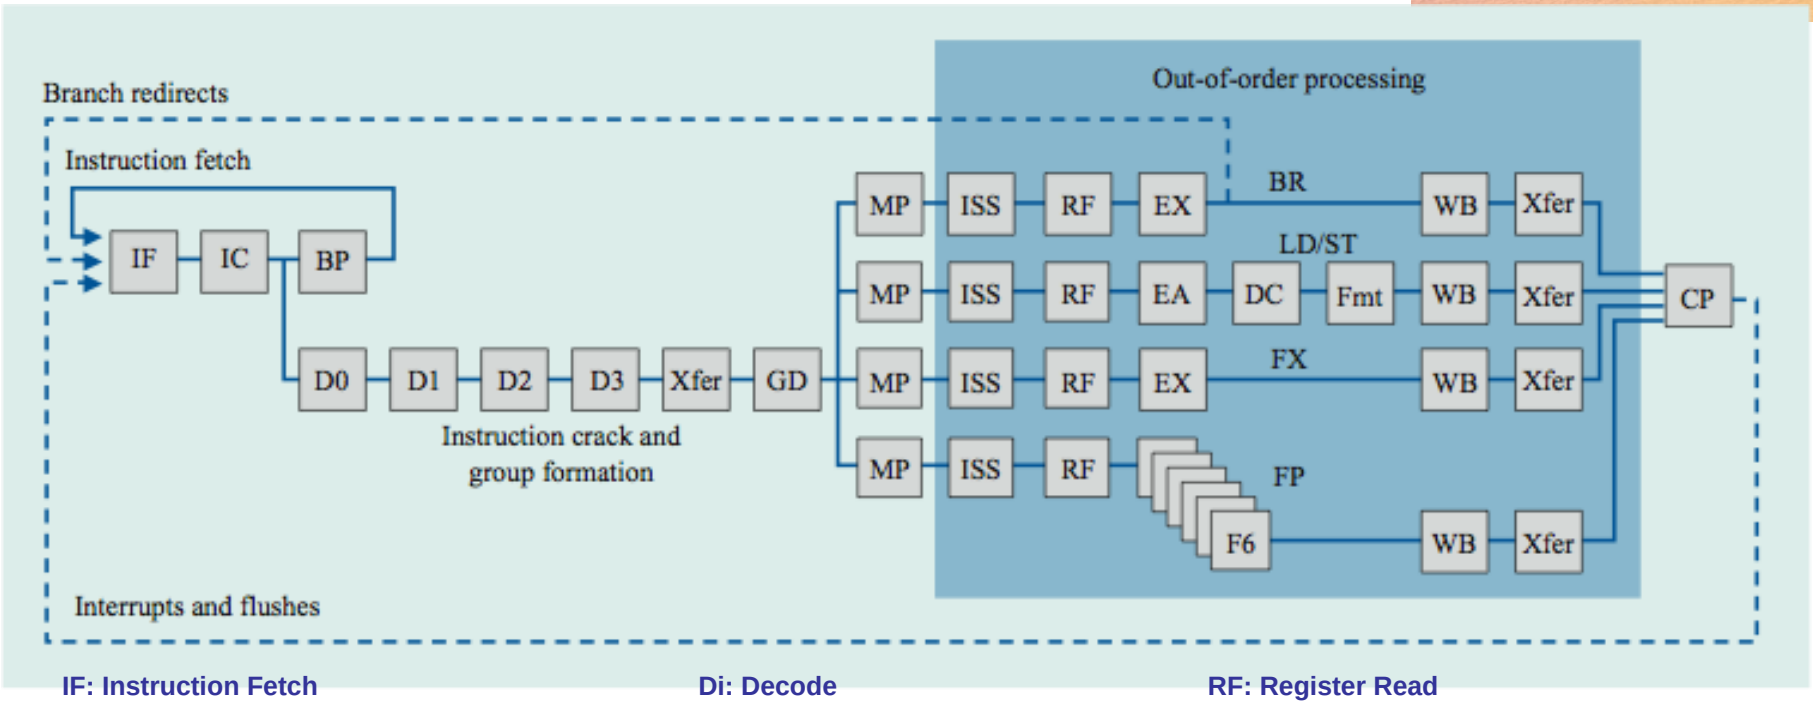

IF: Instruction Fetch
IC: Instruction Cache
BP: Branch Predictor

Di: Decode
MP: Mapping
ISS: Issue

RF: Register Read
DC: Data cache
WB: Write Back

Power 4

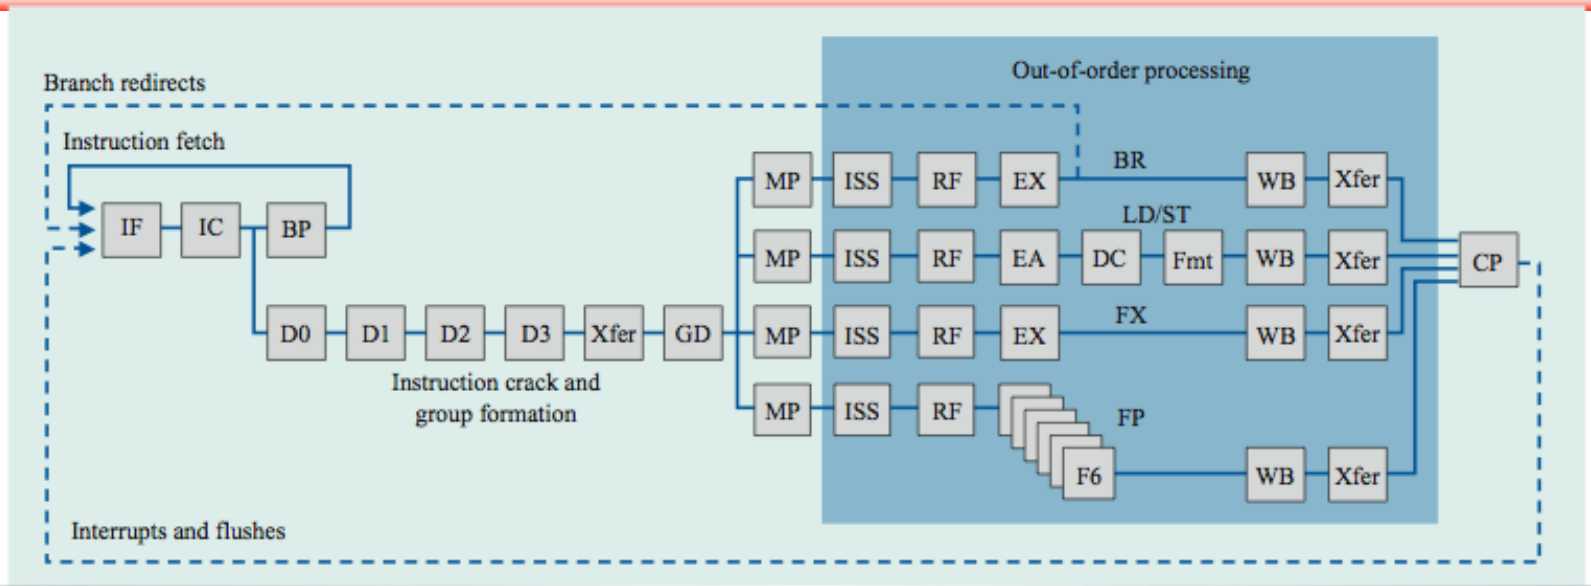

Power 5

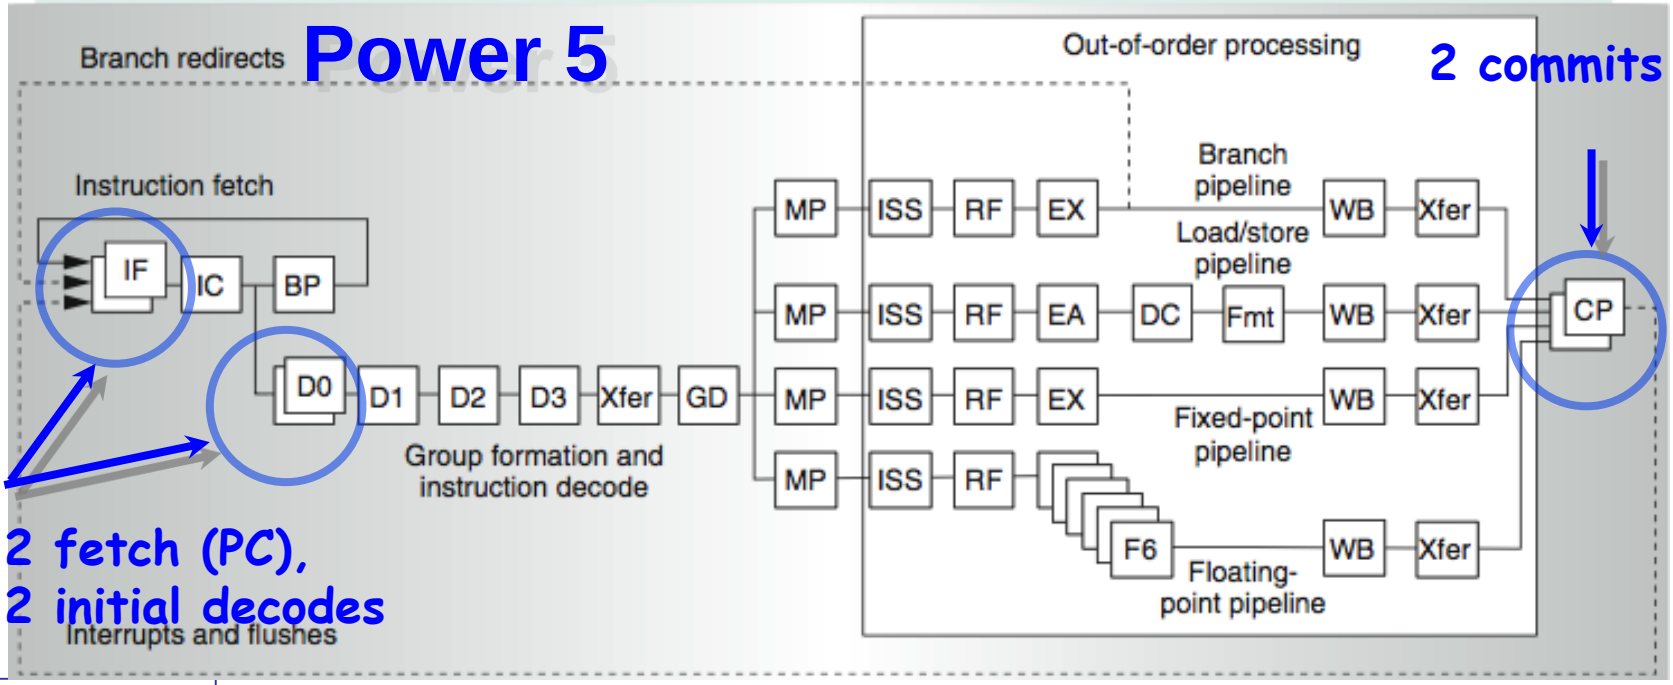

❑ Power 5 (IBM 2005)

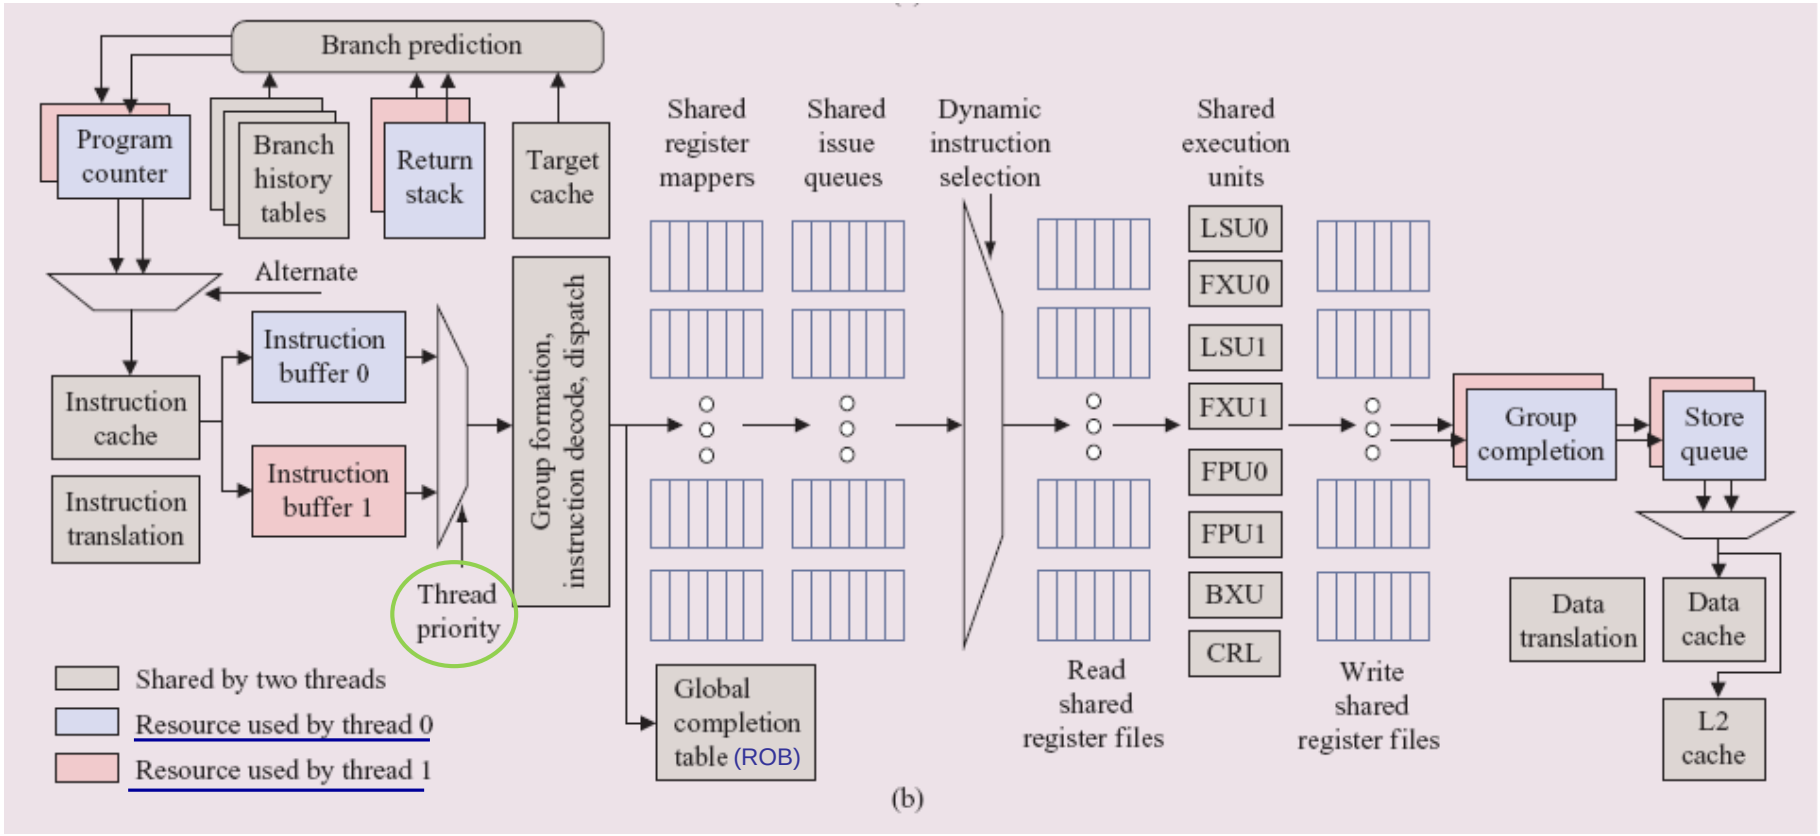

¿Por qué sólo 2 threads? Con 4, los recursos compartidos (registros físicos, cache, AB a memoria) son un cuello de botella.

❑ Power 5

Balanceo de la carga dinámica

1- Monitorizar

cola de fallos (load en L2)

entradas ocupadas en ROB (GCT)

2 – Quitarle recursos;

Reducir prioridad del hilo,

Inhibir decodificación(L2 miss)

Eliminar instrucciones desde emisión y parar decodificación

·3- Ajustar prioridad del hilo (hardware/software)

Baja en espera activa

Alta en tiempo real

8 niveles de prioridad

Da mas ciclos de decodificación al de mas prioridad

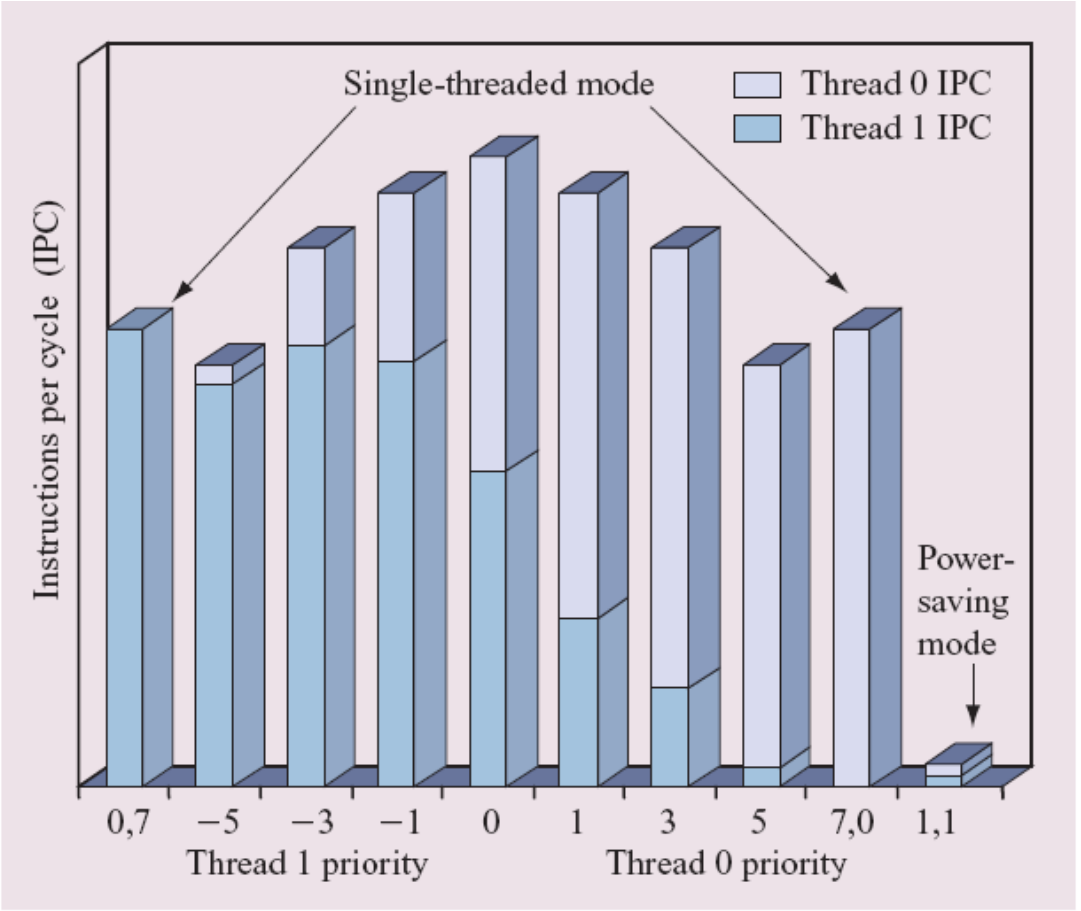

Cambios en Power 5 para soportar SMT

- Incrementar asociatividad de la L1 de instrucciones y del TLB
- Una cola de load/stores por thread
- Incremento de tamaño de la L2 (1.92 vs. 1.44 MB) y L3
- Un buffer de prebúsqueda separado por thread
- Incrementar el numero de registros físicos de 152 a 240
- Incrementar el tamaño de la colas de emisión
- El Power5 core es 24% mayor que el del Power4 para soportar SMT
- Más consumo, pero soportado con DVS

POWER 8

Technology

- 22nm SOI, eDRAM, 15 ML 650mm2

Cores

- 12 cores (SMT8)
- 8 dispatch, 10 issue, 16 exec pipe
- 2X internal data flows/queues
- Enhanced prefetching
- 64K data cache, 32K instruction cache

Accelerators

- Crypto & memory expansion
- Transactional Memory
- VMM assist
- Data Move / VM Mobility

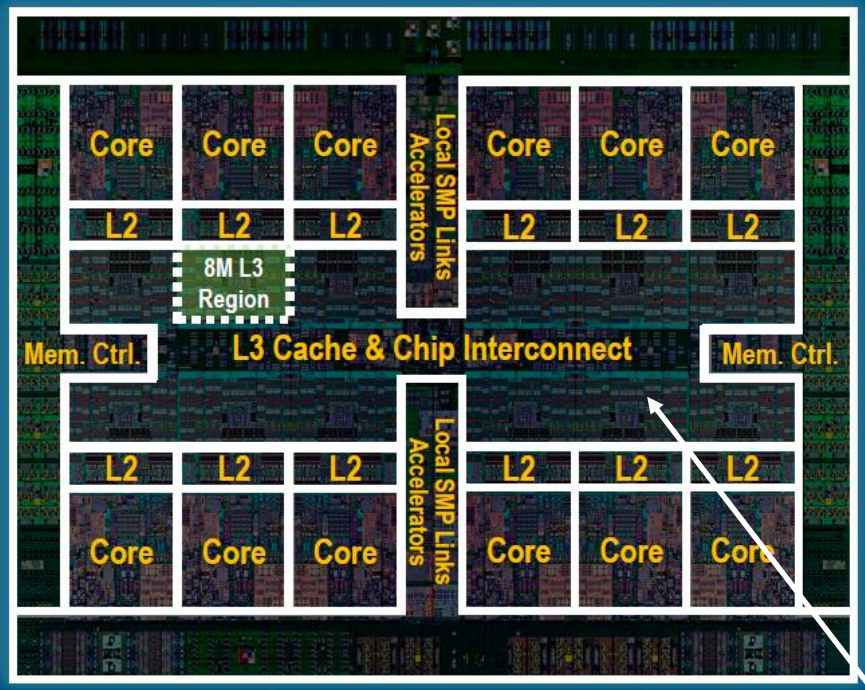

Caches

- 512 KB SRAM L2 / core
- 96 MB eDRAM shared L3
- Up to 128 MB eDRAM L4 (off-chip)

Memory

- Up to 230 GB/s sustained bandwidth

Bus Interfaces

- Durable open memory attach interface
- Integrated PCIe Gen3
- SMP Interconnect
- CAPI (Coherent Accelerator Processor Interface)

Energy Management

- On-chip Power Management Micro-controller
- Integrated Per-core VRM
- Critical Path Monitors

Área de L3 relativamente pequeña: gracias a uso de “embedded DRAM”

❑ Niagara (SUN 2005)

❑ Tolerar (soportar) la latencia de memoria mediante hilos concurrentes

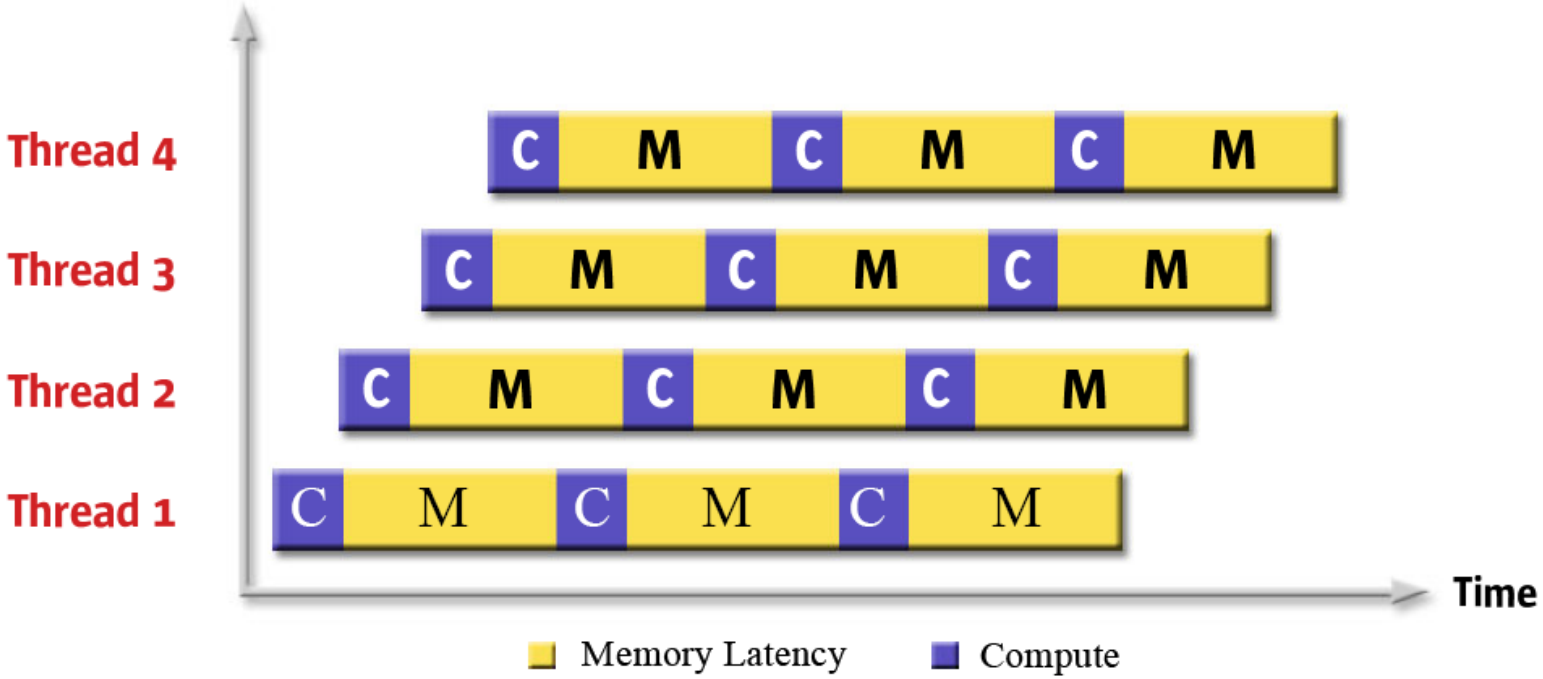

✓ Incrementa la utilización del procesador
✓ Es necesario un gran ancho de banda
- 4 accesos concurrentes a memoria

❑ Niagara: Múltiples cores-múltiples thread

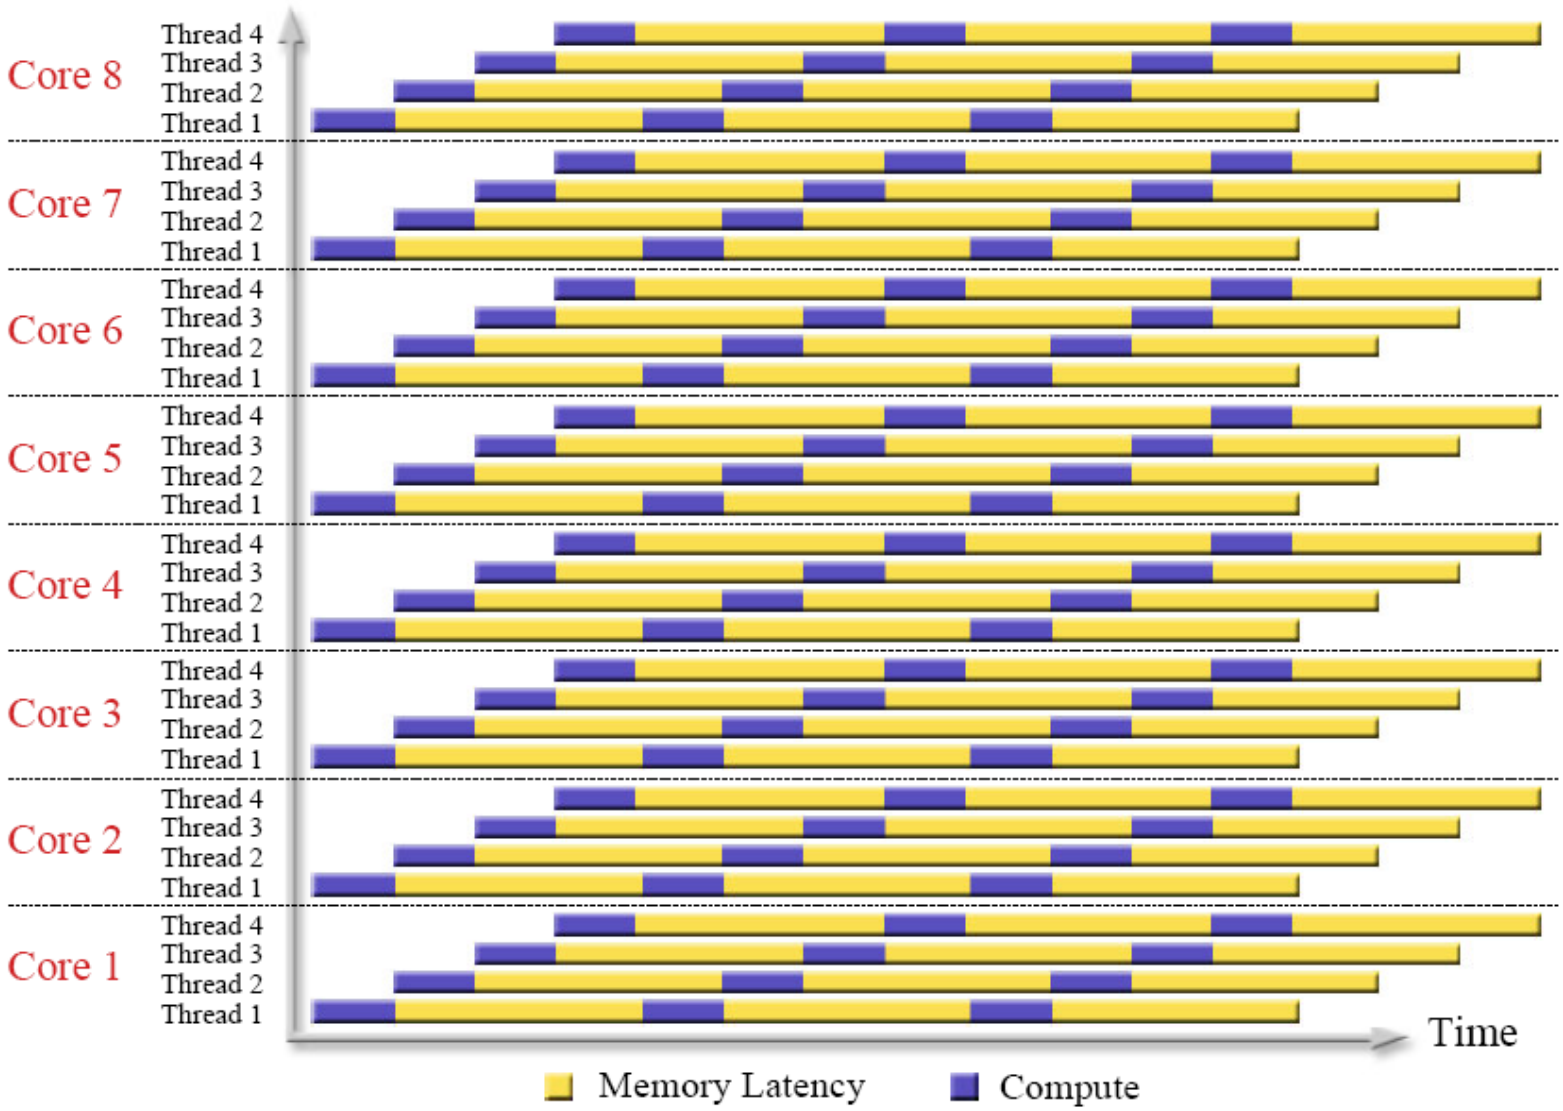

❑ Niagara UltraSparc T1

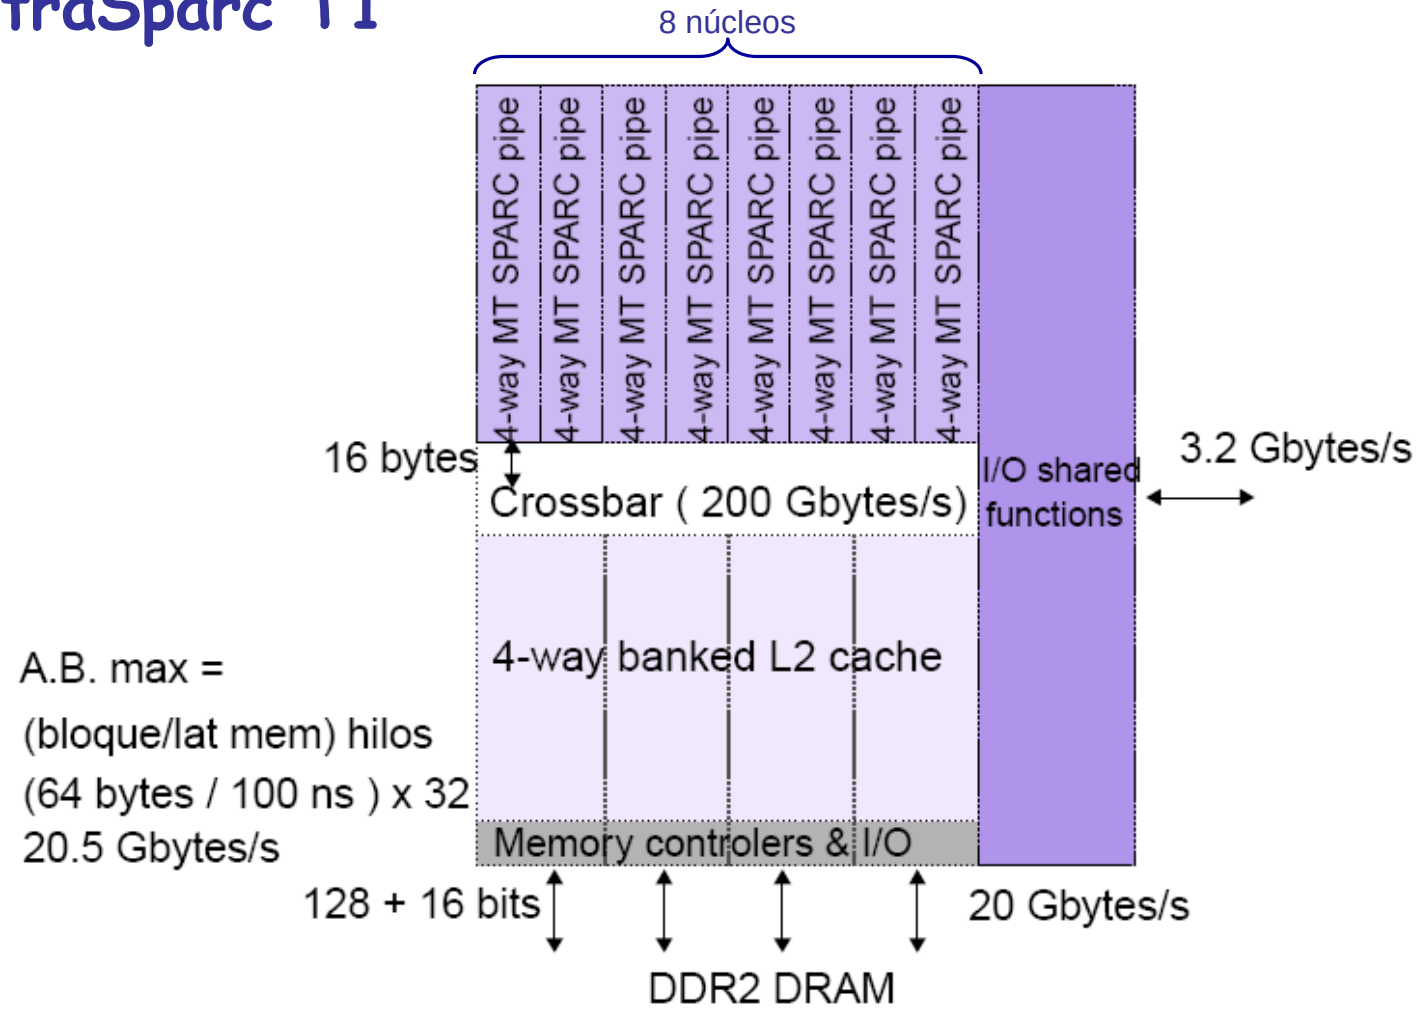

1Ghz, 1 instrucción por ciclo, 4 thread por core, 60 vatios
I-L1 16Kb(4-Way) / D-L1 8Kb (4-Way), escritura directa / L2, 3Mb(12-Way)
Crossbar no bloqueante, No predictor de saltos, no FP (1 por chip)

❑ Niagara UltraSparcT1

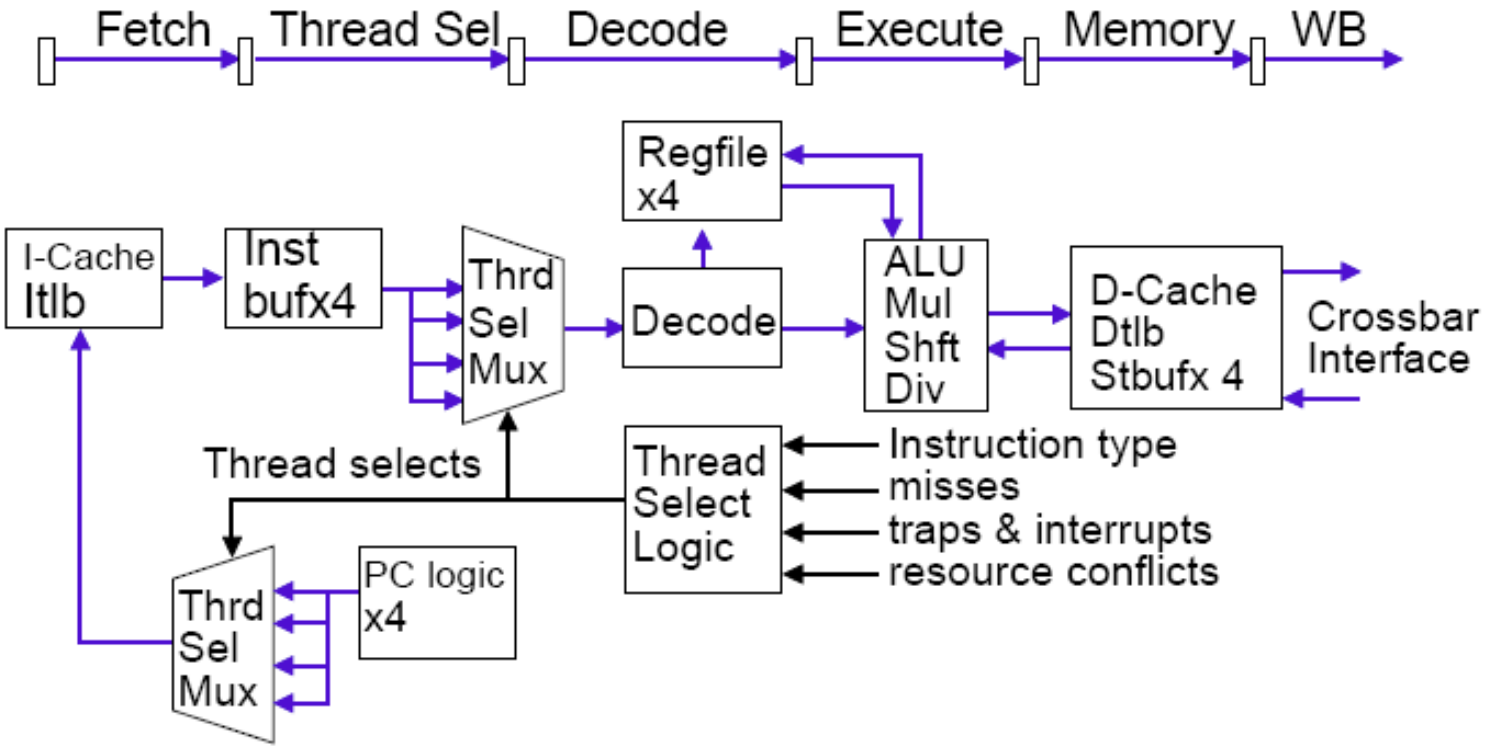

- 6 etapas
- 4 thread independientes
- algunos recursos x4: Banco de registros, contador de programa, store buffer, buffer de instrucciones
- el control de selección de hilo determina el hilo en cada ciclo de reloj
  - ✓cada ciclo elige un hilo

Evolución Sparc

- Oracle Sparc M7
  - 32 cores / 8 threads, 256 threads/chip, 28nm, 10000 Mtrans, 699mm^2, 3.8 Ghz, 70MB L3
  - Hasta 8 socket/nodo: 2048 threads

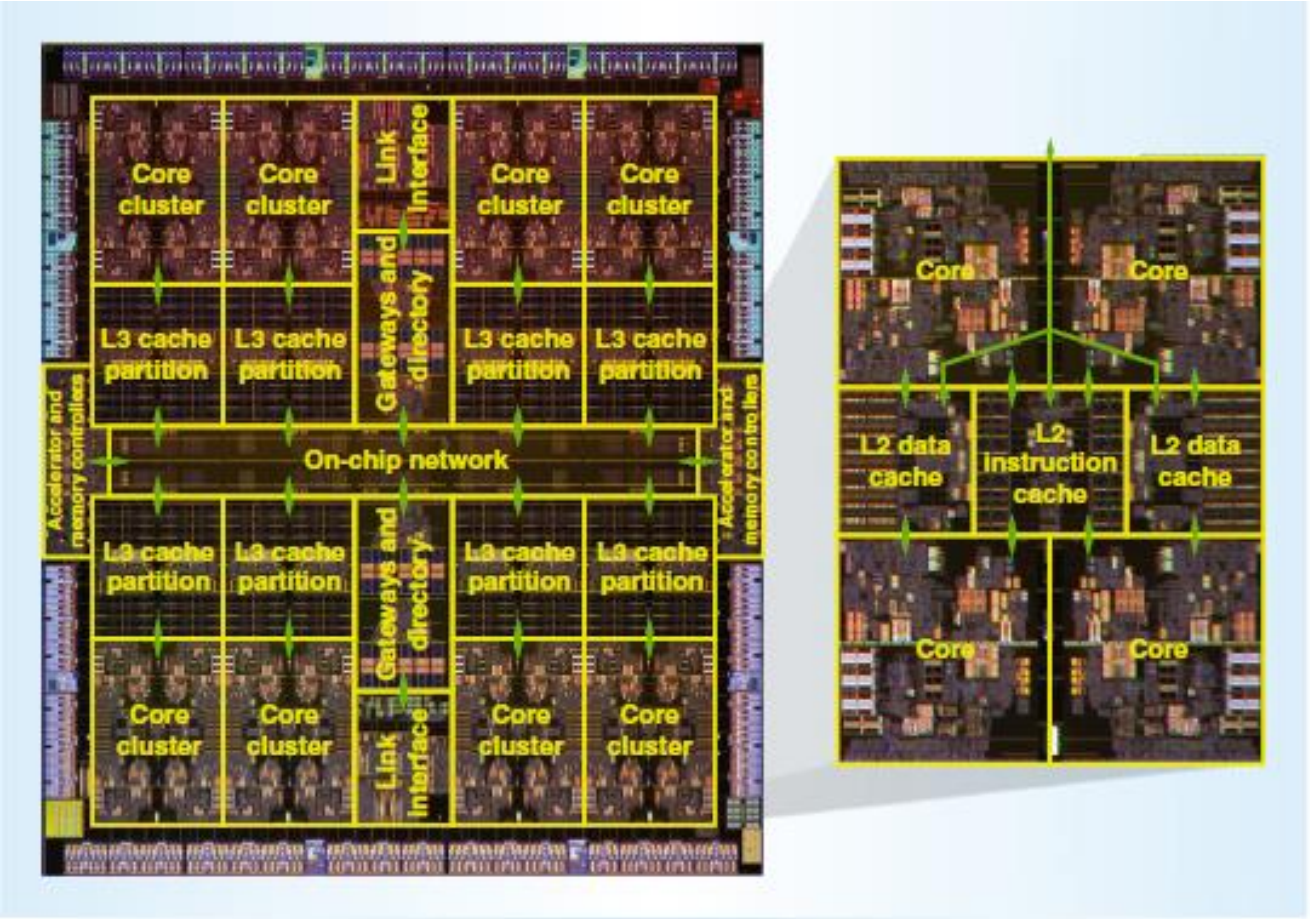

IEEE Micro, Abril 2015

Procesadores Oracle/Sun Niagara

- Orientación datacenters ejecutando servicios web y bases de datos (Oracle), con muchos theads ligeros.
- Muchos cores simples con reducida energía/ operación. Bajo rendimiento por thread

- Niagara-1 [2004], 8 cores, 4 threads/core
- Niagara-2 [2007], 8 cores, 8 threads/core
- Niagara-3 [2009], 16 cores, 8 threads/core
- T4 [2011], 8 cores, 8 threads/core
- T5 [2012], 16 cores, 8 threads/core
- M5 [2012], 6 cores, 8 threads/core
- M6[2013] 12 cores, 8 threads/core
- M7 [2014], 32 cores, 8 threads/core

	Sparc M7	Sparc M6	Sparc M5
CPUs	32 CPUs	12 CPUs	6 CPUs
CPU Type	SPARC V9 S4	SPARC V9 S3	SPARC V9 S3
CPU Freq (max)	3.8GHz*	3.6GHz	3.6GHz
CPU Threads	8 threads per CPU, 256 threads total	8 threads per CPU, 96 threads total	8 threads per CPU, 48 threads total
CPU Cluster	4 CPUs per cluster	CPUs not clustered	CPUs not clustered
Superscalar Issue	Dual issue, out of order		
Pipeline Depth	16 stages		
L1 Cache (I+D)	16KB + 16KB		
L2 Cache	256KB I-cache per cluster, 256KB D-cache per pair, 6MB total	128KB per CPU, 1.5MB total	128KB per CPU, 768KB total
L3 Cache	8MB per cluster, 64MB total	48MB L3	48MB L3
DRAM Interface	16x 64-bit DDR4-2133/2400/2667	8x 64-bit DDR3-1066	8x 64-bit DDR3-1066
DRAM Bandwidth (peak)	341.3GB/s	68.2GB/s	68.2GB/s
DRAM Bandwidth (measured)	170GB/s (DDR4-2133)	57GB/s (DDR3-1066)	57GB/s (DDR3-1066)
DRAM Capacity	2TB per socket	1TB per socket	1TB per socket
Glueless SMP	Up to 8 sockets		
Coherent SMP	Up to 32 sockets	Up to 96 sockets	Up to 32 sockets
PCI Express	4x8 PCIe (Gen3)	2x8 PCIe (Gen3)	2x8 PCIe (Gen3)
Transistors	>10 billion	4.27 billion	3.9 billion
Die Size	700mm2*	643mm2	511mm2
IC Process	TSMC 20nm HKMG	TSMC 28nm HP	TSMC 28nm HP
Availability	Production 1H15*	Production 2013	Production 2012

❑ Itanium2 9000 Poulson 2011

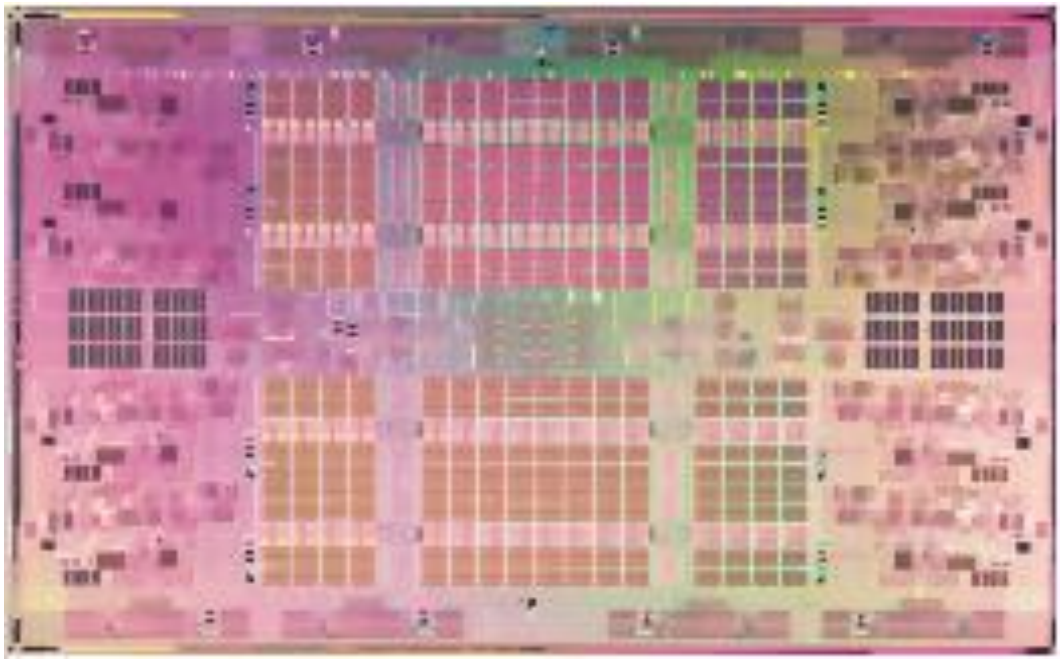

8 cores y 2 threads/core, 544mm^{2,} 3000MTs
Cache L2 separada , 512 KByte L2 Icache, 256KB L2 Dcache
Cache L3 32MB compartida
6 operaciones por ciclo / 2 128-bit bundles
Hasta 12 operaciones por ciclo

¿ Quien es mejor?

Procesador	Microarchitectura	Fetch / Issue / Execute	FU	Clock Rate (GHz)	Transis -tores Die size	Power
Intel Pentium 4 Extreme	Especulativo con planificación dinámica; Pipe profundo; SMT	3/3/4	7 int. 1 FP	3.8	125 M 122 mm^2	115 W
AMD Athlon 64 FX-57	Especulativo con planificación dinámica.	3/3/4	6 int. 3 FP	2.8	114 M 115 mm^2	104 W
IBM Power5 (1 CPU only)	Especulativo con planificación dinámica; SMT 2 CPU cores/chip	8/4/8	6 int. 2 FP	1.9	200 M 300 mm^2 (est.)	80W (est.)
Intel Itanium 2	Planificación estática VLIW-style	6/5/11	9 int. 2 FP	1.6	592 M 423 mm^2	130 W

Rendimiento

❑ SPECint2000

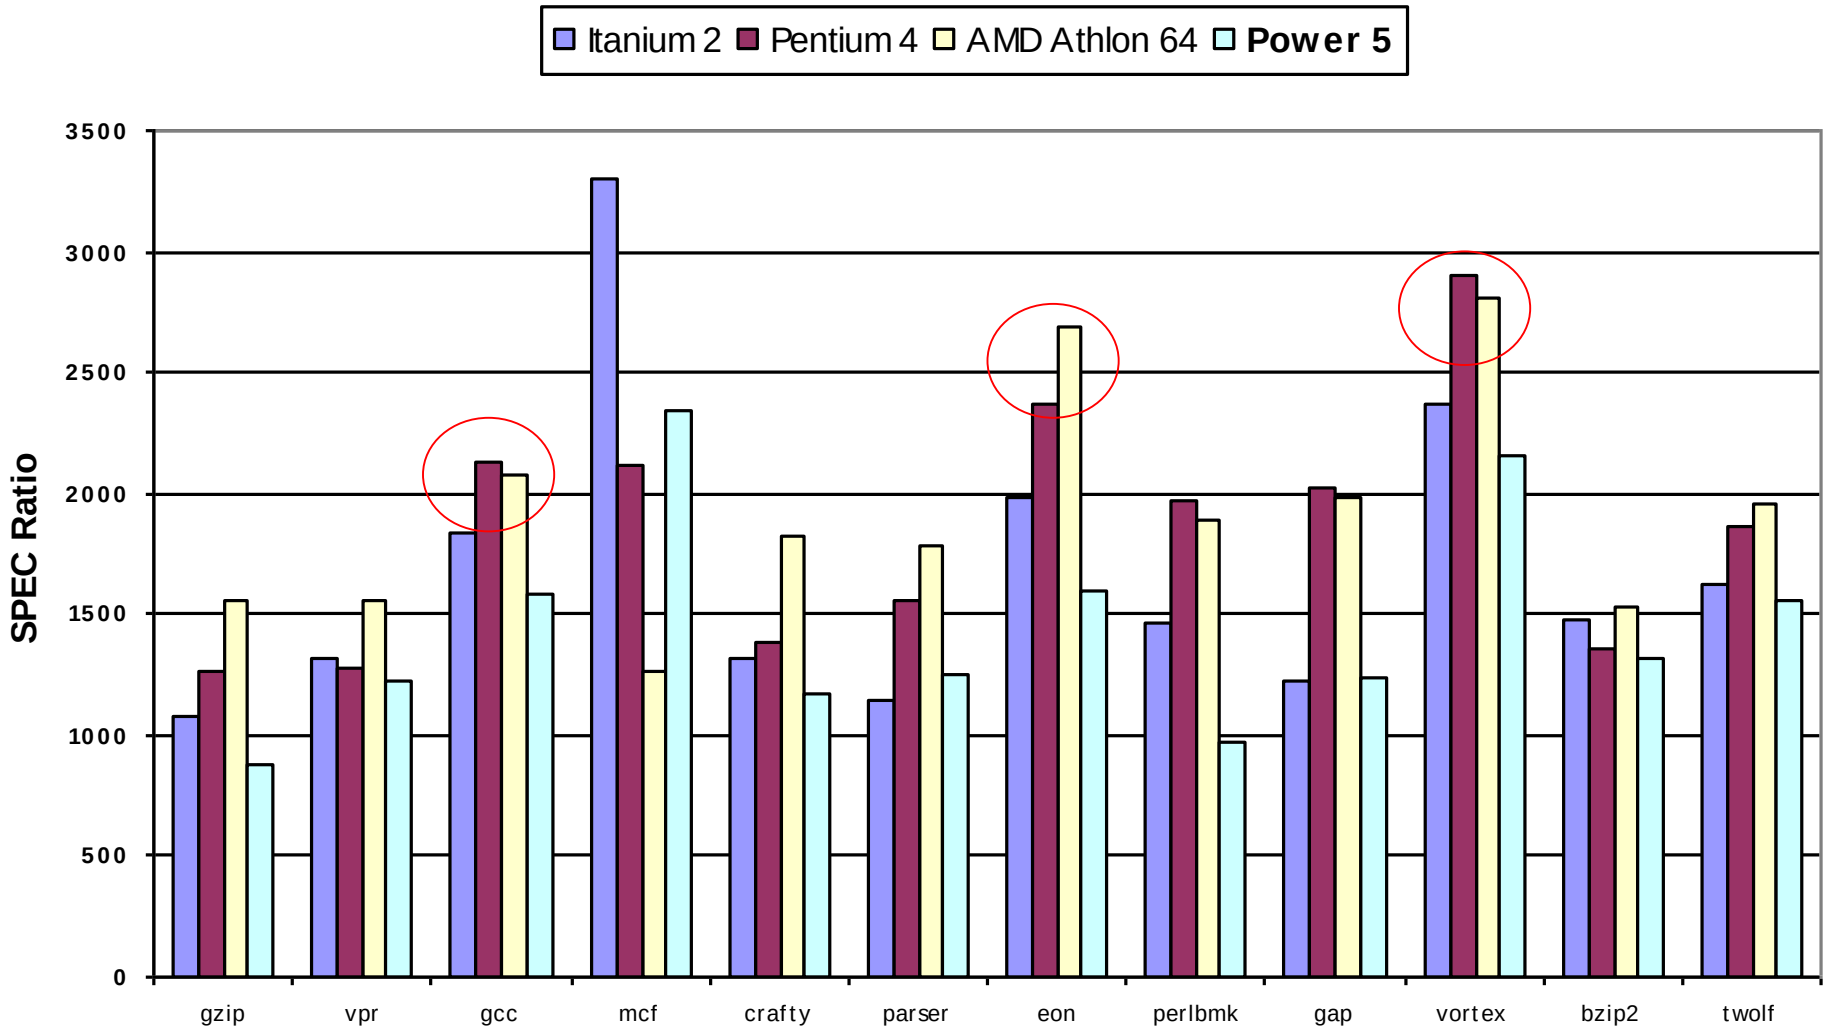

Rendimiento

❑ SPECfp2000

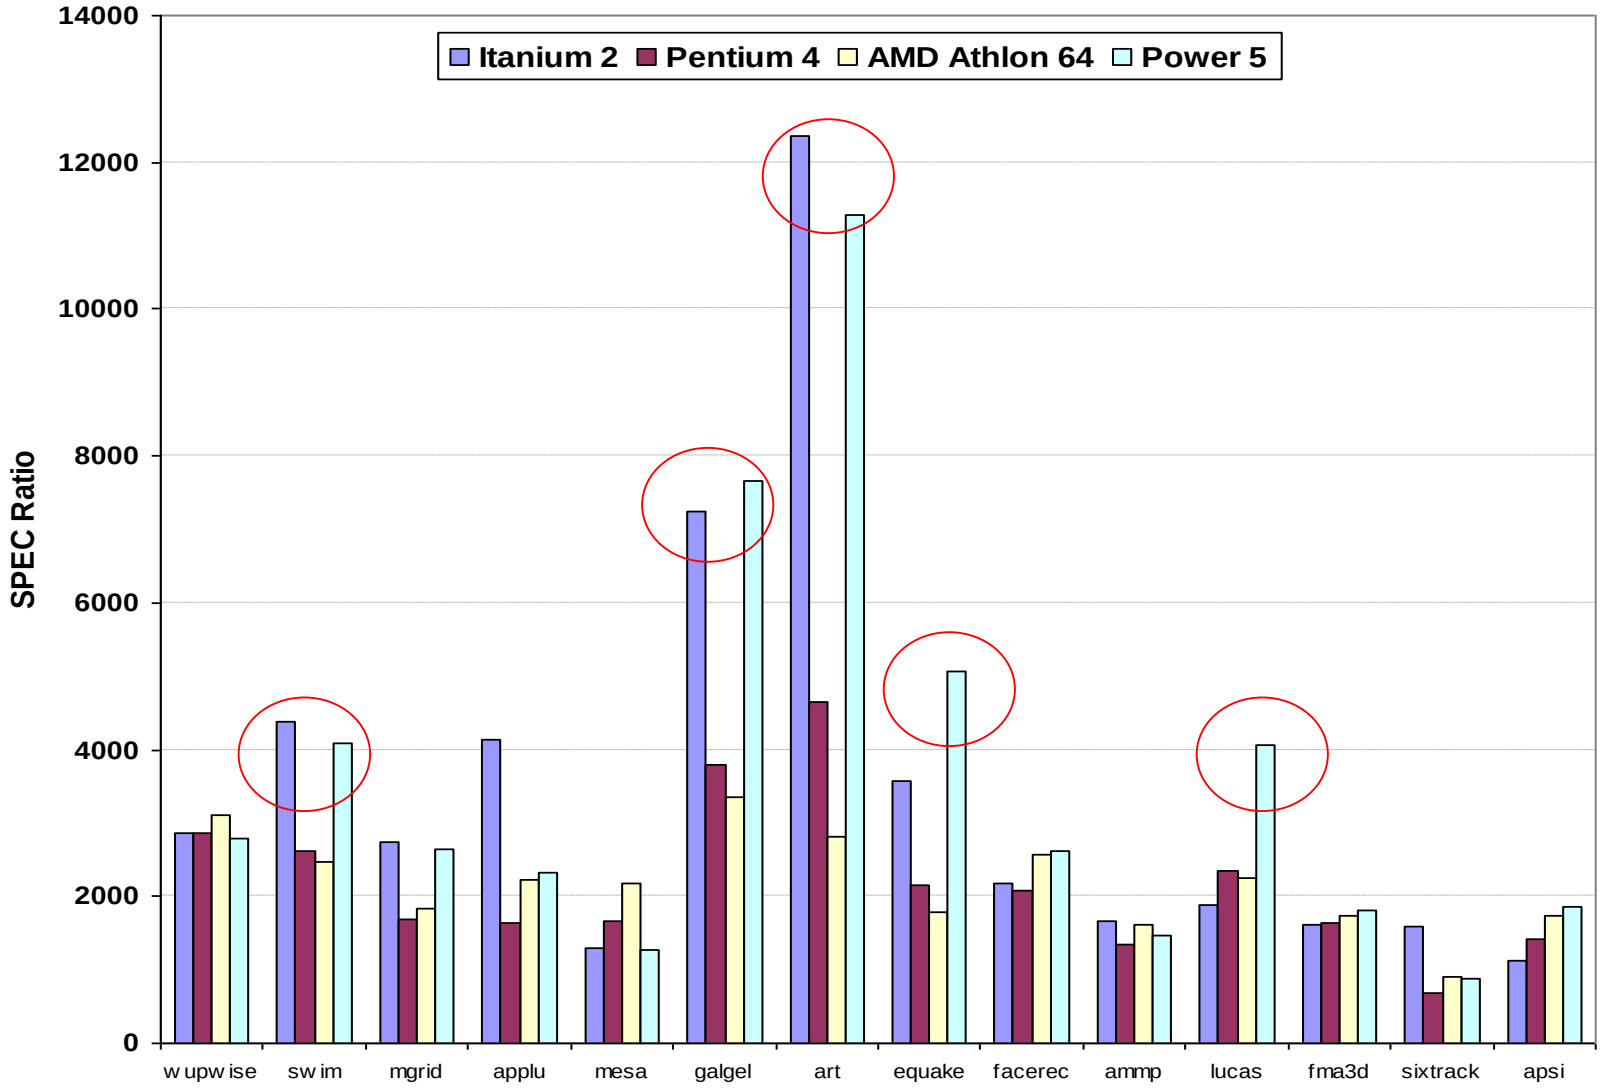

❑ Rendimiento normalizado: Eficiencia

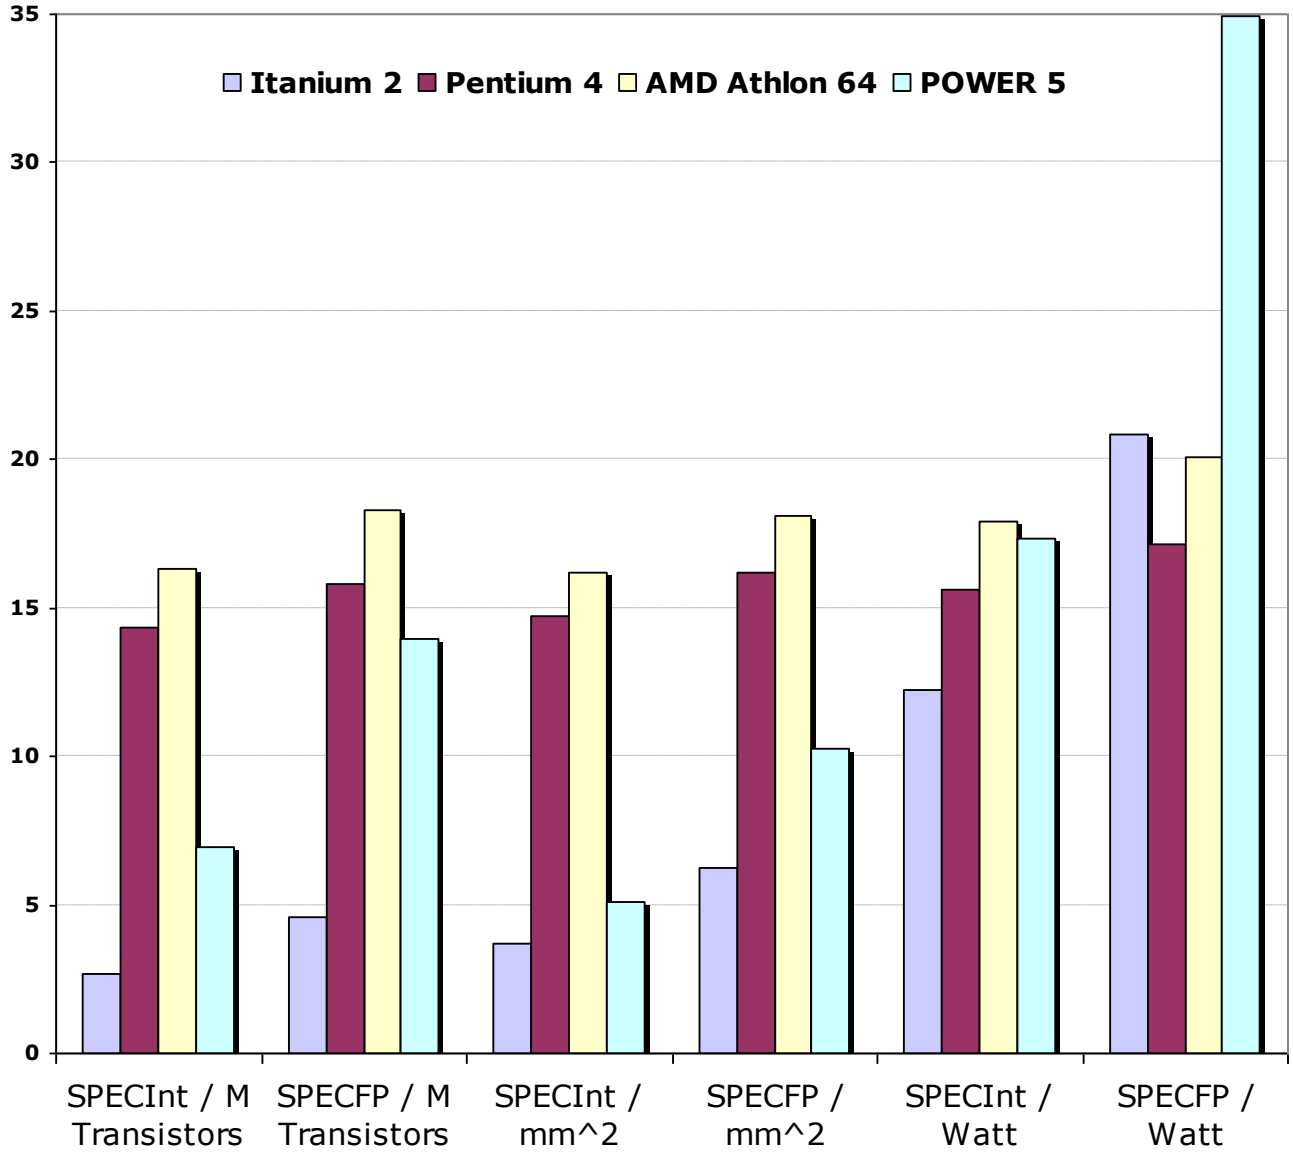

Rank	Itanium 2	Pentium 4	Athlon	Power5
Int/Trans	4	2	1	3
FP/Trans	4	2	1	3
Int/area	4	2	1	3
FP/area	4	2	1	3
Int/Watt	4	3	1	2
FP/Watt	2	4	3	1

Rendimiento Conclusiones

- No hay un claro ganador en todos los aspectos
- El AMD Athlon gana en SPECInt seguido por el Pentium4, Itanium 2, y Power5
- Itanium 2 y Power5, tienen similares rendimientos en SPECFP, dominan claramente al Athlon y Pentium 4
- Itanium 2 es el procesador menos eficiente en todas las medidas menos en SPECFP/Watt.
- Athlon y Pentium 4 usan bien los transistores y el área en términos de eficacia
- IBM Power5 es el mas eficaz en el uso de la energía sobre los SPECFP y algo menos sobre SPECINT

Conclusiones -Limites del ILP

- Doblar en ancho de emisión (issue rates) sobre los valores actuales 3-6 instrucciones por ciclo, a digamos 6 a 12 instrucciones requiere en el procesador
  - de 3 a 4 accesos a cache de datos por ciclo,
  - Predecir-resolver de 2 a 3 saltos por ciclo,
  - Renombrar y acceder a mas de 20 registros por ciclo,
  - Buscar de la cache de instrucciones de 12 a 24 instrucciones por ciclo.
- La complejidad de implementar estas capacidades implica al menos sacrificar la duración del ciclo e incrementa de forma muy importante el consumo.

Conclusiones -Limites del ILP

- La mayoría de la técnicas que incrementan rendimiento incrementan también el consumo.
- Una técnica es *eficiente en energía* si incrementa más el rendimiento que el consumo.
- Todas las técnicas de emisión múltiple son poco eficientes desde el punto de vista de la energía.

Conclusiones -Limites del ILP

- En lugar de seguir explotando el ILP, los diseñadores se han focalizado sobre multiprocesadores en un chip (CMP, multicores,..)
- En el 2000, IBM abrió el campo con el 1º multiprocesador en un chip, el Power4, que contenía 2 procesadores Power3 y una cache L2 compartida. A partir de este punto todos los demás fabricantes han seguido el mismo camino. (Intel, AMD, Sun, Fujitsu,..).
- La explotación del paralelismo existente en las aplicaciones (a nivel de procesos y/o a nivel de datos) se plantea como la vía adecuada para obtener balances satisfactorios entre velocidad de procesamiento y consumo de energía.