

## ***Cache Memory (bagian 2)***



Tim Dosen COA

Fakultas Informatika  
Universitas Telkom



# Rencana Studi

| Rencana Studi  |                                 | Rincian Nilai Kuis     |   |       |   |       |   |       |   | Rincian Nilai Tugas      |   |       |   |     |   | Rincian Nilai Hasil Proyek |   |                    |   |   |   | Bobot Tiap CLO (%) |   |    |    |    |    |
|----------------|---------------------------------|------------------------|---|-------|---|-------|---|-------|---|--------------------------|---|-------|---|-----|---|----------------------------|---|--------------------|---|---|---|--------------------|---|----|----|----|----|
| Perte-muan Ke- | Materi                          | CLO 1                  |   | CLO 2 |   | CLO 3 |   | CLO 4 |   | CLO 1                    |   | CLO 2 |   | CLO |   | CLO 3                      |   | CLO 4              |   |   |   |                    |   |    |    |    |    |
|                |                                 | Kuis (Kognitif) (20 %) |   |       |   |       |   |       |   | Tugas Partisipatif (35%) |   |       |   |     |   |                            |   | Hasil Proyek (45%) |   |   |   |                    |   |    |    |    |    |
| 1              | Sistem komputer                 | 1                      | - | -     | - | -     | - | -     | - | 2                        | - | -     | - | -   | - | -                          | - | -                  | - | - | - | -                  | - | 1  | 2  | 3  | 4  |
| 2              | Input/Output                    | -                      | 2 | -     | - | -     | - | -     | - | -                        | 4 | -     | - | -   | - | -                          | - | -                  | - | - | - | -                  | - | 14 | -- | -- | -- |
| 3              | Sistem Bus                      | -                      | - | 1     | - | -     | - | -     | - | -                        | 4 | -     | - | -   | - | -                          | - | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 4              | Organisasi memori               | -                      | - | -     | 1 | -     | - | -     | - | -                        | - | -     | - | -   | - | -                          | 4 | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 5              | Cara kerja memori utama (RAM)   | -                      | - | -     | - | 1     | - | -     | - | -                        | - | -     | - | -   | - | -                          | 4 | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 6              | Memori sekunder                 | -                      | - | -     | - | -     | 1 | -     | - | -                        | - | -     | - | -   | - | -                          | 4 | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 7              | Cara kerja cache memory (bag-1) | -                      | - | -     | - | -     | 2 | -     | - | -                        | - | -     | - | -   | - | -                          | 4 | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 8              | Cara kerja cache memory (bag-2) | -                      | - | -     | - | -     | - | 1     | - | -                        | - | -     | - | -   | - | -                          | 4 | -                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 9              | Arsitektur SAP-1                | -                      | - | -     | - | -     | - | 1     | - | -                        | - | -     | - | -   | - | -                          | - | 1                  | - | - | - | -                  | - | -  | -  | -  | -  |
| 10             | Arsitektur SAP-2                | -                      | - | -     | - | -     | - | -     | 1 | -                        | - | -     | - | -   | - | -                          | - | 2                  | - | 2 | 1 | -                  | - | -  | -  | -  | 30 |
| 11             | Arsitektur SAP-3                | -                      | - | -     | - | -     | - | -     | 2 | -                        | - | -     | - | -   | - | -                          | - | 3                  | - | 7 | 2 | -                  | - | -  | -  | -  | -  |
| 12             | Instruksi Extended dan Indirect | -                      | - | -     | - | -     | - | -     | 1 | -                        | - | -     | - | -   | - | -                          | - | -                  | - | 7 | - | -                  | - | -  | -  | -  | -  |
| 13             | Arsitektur MIPS                 | -                      | - | -     | - | -     | - | -     | - | 1                        | - | -     | - | -   | - | -                          | - | -                  | - | - | 1 | -                  | - | -  | -  | -  | -  |
| 14             | Instruksi MIPS                  | -                      | - | -     | - | -     | - | -     | - | -                        | 2 | -     | - | -   | - | -                          | - | -                  | - | - | 2 | 1                  | - | -  | -  | -  | -  |
| 15             | Assembly MIPS (bag-1)           | -                      | - | -     | - | -     | - | -     | - | -                        | 1 | -     | - | -   | - | -                          | - | -                  | - | - | 3 | 2                  | - | -  | -  | -  | -  |
| 16             | Assembly MIPS (bag-2)           | -                      | - | -     | - | -     | - | -     | - | -                        | - | 1     | - | -   | - | -                          | - | -                  | - | - | - | 9                  | 7 | -  | -  | -  | -  |

Part 1: Bagaimana cara kerja metode  
*set-associative mapping* pada *cache memory*?

- Cache dibagi menjadi sejumlah set
- Setiap set terdiri dari sejumlah baris
- Setiap blok memori dipasangkan ke nomor set tertentu, tetapi boleh menempati baris mana saja dalam satu set
- Misal: jika tiap set terdiri dari 2 baris, maka:
  - Model pemetaannya disebut: *2-way set associative mapping*
  - Setiap blok memori boleh menempati satu dari dua baris yang tersedia asalkan masih dalam satu set

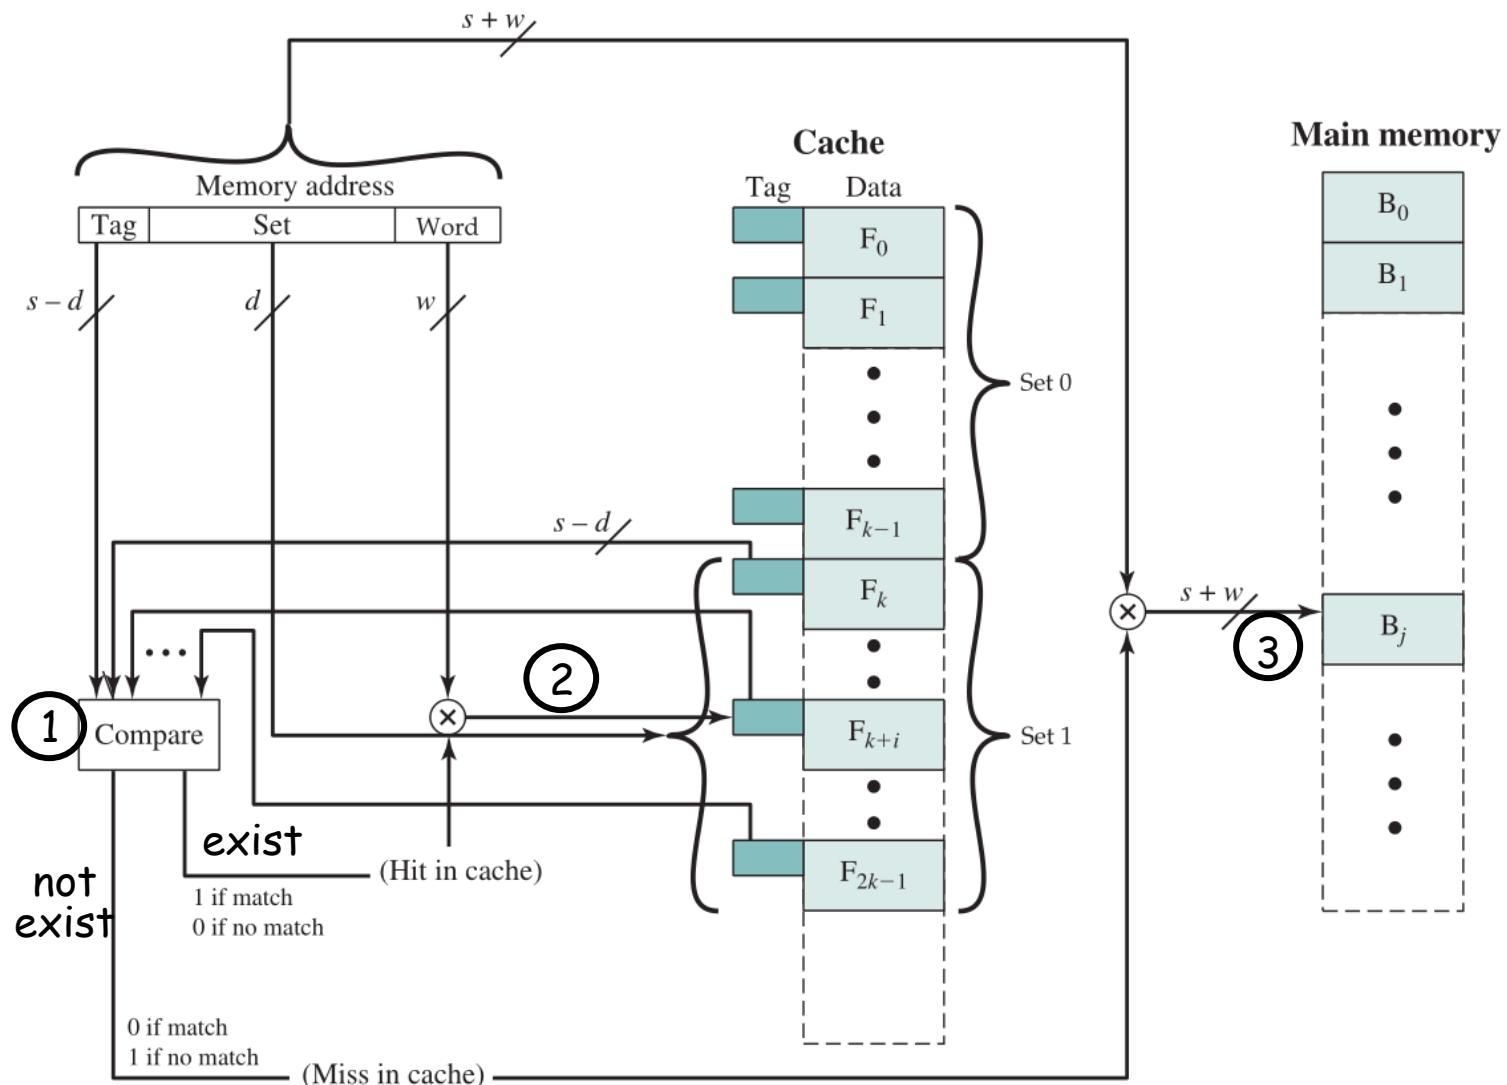
# **Set Associative Mapping (2)**

- Format alamat memori: (dari sisi *cache*)

| Tag (s-v) | Set (v) | Word (w) |
|-----------|---------|----------|
|           |         |          |

- Untuk keperluan akses *cache* → setiap alamat memori dibagi menjadi 2 bagian:
  - word(w) = bit-bit identitas word atau *byte* di dalam blok memori
  - s = bit-bit identitas blok memori
    - set field (v): bit-bit nomor set
    - tag (s-v): bit-bit identitas blok data yang ada di memori

# **Set Associative Mapping - Baca data (1)**



**Figure 4.14** K-Way Set Associative Cache Organization

## ***Set Associative Mapping - Baca data (2)***

- ① CPU membandingkan nomor tag yang akan dibaca dengan semua nomor tag di *cache*. Tag dalam satu set dibandingkan bersama-sama
- ② Bila nomor tag tsb ada di *cache* (*cache hit*) → pilih word yang diinginkan yang terletak pada nomor set yang diinginkan
- ③ Bila nomor tag tsb tidak ada di *cache* (*cache miss*) → ambil (*fetch*) satu blok data di memori sesuai dengan nomor tag dan nomor set yang diinginkan

# **Set Associative Mapping - Contoh (1)**

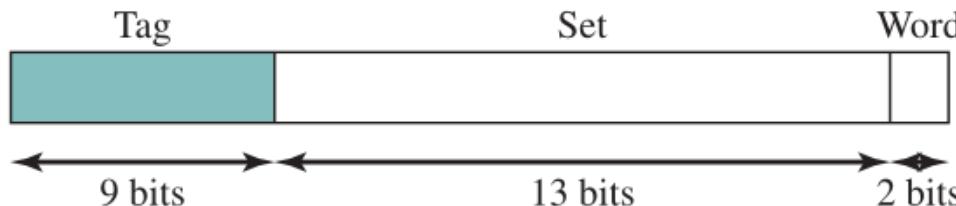
- Diketahui:
  - Main memory berukuran 16 MByte
  - Cache berukuran 64 kByte
  - 1 alamat = 1 byte
  - 1x transfer data = 1 blok memori = 4 byte = 4 alamat
  - Model mapping = 2 way set associative

Sebutkan jumlah bit untuk tag (s-v), set (v), dan word (w) !  
Gambarkan mappingnya !  
Berikan contohnya !
- Maka:
  - Memory 16 Mbyte =  $2^4 \cdot 2^{20} = 2^{24}$  → Jumlah bit alamat yang diperlukan = 24 bit
  - Jumlah bit identitas word (w) = 2 bit (1 blok = 4 byte =  $2^2$ )
  - Jumlah *line cache* = 64 kbyte/4 byte = 16 k line
  - 1 set = 2 line → jumlah set =  $16k/2 = 8k$  set
  - $8k = 2^3 \cdot 2^{10} = 2^{13}$  → Jumlah bit set = 13 bit (0000 - 1FFF)
  - Jumlah bit tag =  $24 - 13 - 2 = 9$  bit (range: 000 – 1FF)
  - Jumlah tag =  $2^9 = 512$  tag

# Set Associative Mapping - Contoh (2)

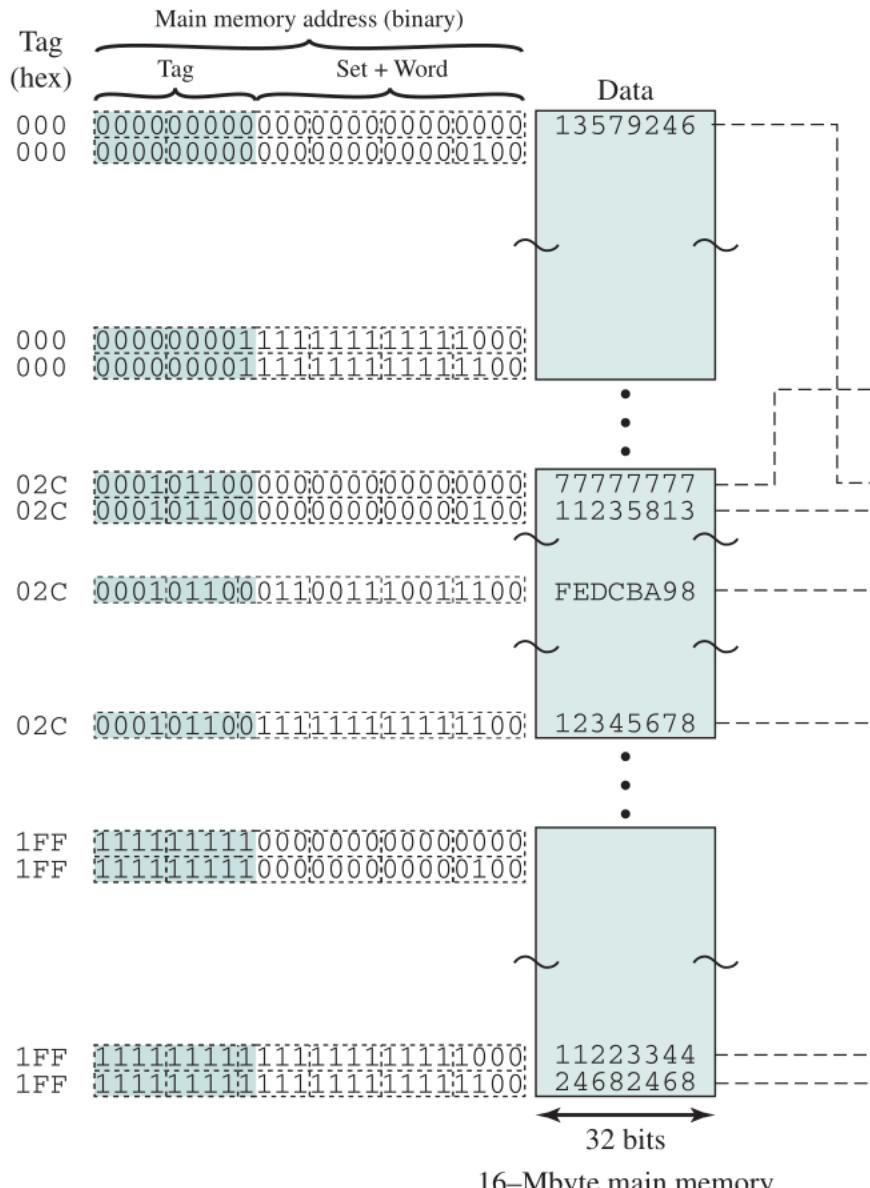
- Format alamat memori: (dari sisi cache)

Main memory address =



- Jumlah alamat memori tiap tag =  $2^{13+2} = 2^5 \cdot 2^{10} = 32$  k alamat
- Range alamat memori tiap tag (dalam format 24 bit) = 000000 – 007FFF, maka alamat memori : 000000, 008000, 010000, ..., FF8000 selalu terletak pada set nomor yang sama (0000)
  - 007FFF = **0000 0000 0111 1111 1111 1111 + 1** → **0000 0000 1**000 0000 0000 0000 = 008000
  - 008000 + 007FFF = 00FFFF = **0000 0000 1111 1111 1111 1111 + 1** → **0000 0001 0**000 0000 0000 = 010000
- Setiap alamat memori di atas bebas menempati salah satu line pada nomor set tersebut
- Setiap satu nomor blok memori hanya dapat menempati satu nomor set
- Satu nomor set dapat dapat ditempati oleh:
  - 512 nomor tag berbeda tetapi nomor blok-nya sama

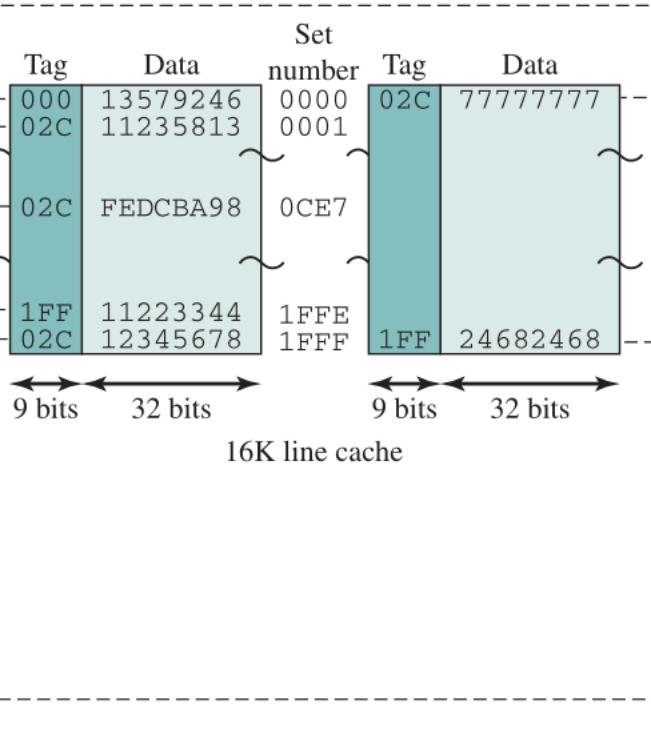
# Set Associative Mapping - Contoh (3)



Cara mapping:

Set+word (15 bit): 3    3    9    C  
                       011 0011 1001 1100

Nomor set (13 bit): 0 1100 1110 0111  
                       0    C    E    7

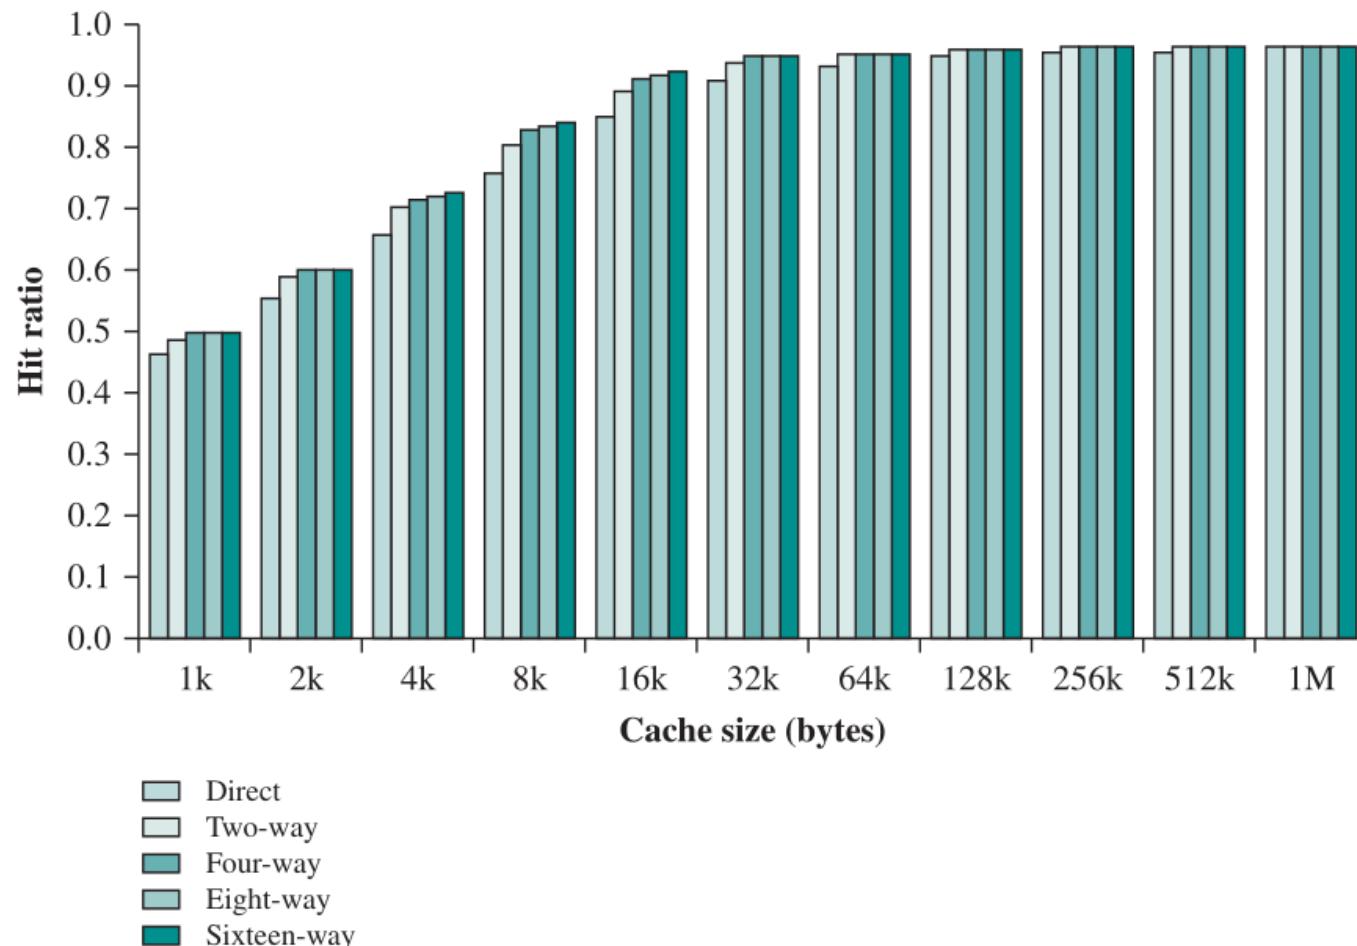


## ***Set Associative Mapping - Kelebihan***

---

- (+) Setiap blok memori dapat menempati lebih dari satu kemungkinan nomor *line* (dapat menggunakan line yang kosong), sehingga *thrashing* dapat diperkecil
- (+) Jumlah tag lebih sedikit (dibanding model *associative*), sehingga jalur untuk melakukan perbandingan tag lebih sederhana

## ***Set Associative Mapping – Hit Ratio***



**Figure 4.16** Varying Associativity over Cache Size

Part 2: Bagaimana cara kerja metode  
*replacement algorithm (LRU, FIFO, LFU,  
random)* pada *cache memory*?

- Ukuran (*Size*) cache
- *Mapping Cache-Main memory*
  - Direct
  - Associative
  - Set associative

## ➤ Algoritma Penggantian (*Replacement*)

- Least Recently Used (*LRU*)
  - First In First Out (*FIFO*)
  - Least Frequency Used (*LFU*)
  - Random
- Cara penulisan (*Write Policy*)
    - Write through
    - Write back
  - Ukuran blok (*Block Size*)
  - Jumlah cache
    - Off-chip, On-chip
    - Single level, Multilevel
    - Unified, Split

- Adalah algoritma yang digunakan untuk memilih blok data mana yang ada di *cache* yang **dapat diganti** dengan blok data baru
- *Direct mapping*
  - Tidak perlu algoritma
  - *Mapping* pasti (tidak ada alternatif lain)
- *Associative & Set Associative*
  - Algoritma diimplementasi dengan H/W (supaya cepat)
  - Jenis algoritma:
    - *Least Recently Used (LRU)*
    - *First In First Out (FIFO)*
    - *Least Frequently Used (LFU)*
    - *Random*

# Replacement Algorithms (2)

## • Least Recently Used (LRU)

- Blok yang diganti adalah blok yang **paling lama** di cache dan **tidak digunakan**
- Kelebihan:
  - Paling efektif
  - Mempunyai hit ratio tinggi → data yang **sering** digunakan saja yang ditaruh di *cache*
  - Paling mudah diimplementasikan pada *two-way set associative mapping* (digunakan sebuah bit tambahan = USE bit, line yang direfer → USE bit = 1)
- Contoh:
  - Kapasitas *cache* hanya 4 baris sedangkan jumlah blok data jauh lebih banyak. Jika urutan pengaksesan data adalah:

a b c d c b a b c kemudian datang data e maka data yang diganti adalah ???

Jawaban: d

Kalau data yang diakses sebelum data e adalah d, maka data yang diganti adalah ???

Jawaban: a (a lebih lama tidak diakses dibanding d)

- *First In First Out (FIFO)*

- Blok yang diganti adalah blok yang **paling awal** berada di *cache*
- Contoh:

- Kapasitas *cache* hanya 4 baris sedangkan jumlah blok data jauh lebih banyak. Jika urutan pengaksesan data adalah:

a b c d c b a b c kemudian datang data e maka data yang diganti adalah .....

Jawaban: a (a paling lama/awal berada di *cache*)

Kalau data yang diakses sebelum data e adalah d, maka data yang diganti adalah .....

Jawaban: a (a paling lama/awal berada di *cache*)

# Replacement Algorithms (4)

- *Least Frequently Used (LFU)*
  - Blok yang **paling jarang** digunakan yang diganti
  - Setiap baris mempunyai *counter*
  - Contoh:
    - Kapasitas *cache* hanya 4 baris sedangkan jumlah blok data jauh lebih banyak. Jika urutan pengaksesan data adalah:  
**a b c d c b a b c a d** kemudian datang data **e** maka data yang diganti adalah .....
    - Jawaban: **d** (**d** paling jarang diakses)
    - Kalau urutan data yang diakses sebelum data **e** adalah **a b c d c b a b c a d**, maka data yang diganti adalah .....
    - Jawaban: **a** (nilai *counter* **a** sama dengan yang lain, tetapi karena **a** datang paling awal maka **a** berada pada baris paling awal) → FIFO  
**b** (paling lama tidak diakses) → LRU
- *Random*
  - Penggantian blok dilakukan secara **acak**

# Part 3: Bagaimana cara menjaga konsistensi data di memori dan *cache memory*?

- Ukuran (*Size*) cache
- *Mapping Cache-Main memory*
  - Direct
  - Associative
  - Set associative
- Algoritma Penggantian (*Replacement*)
  - Least Recently Used (*LRU*)
  - First In First Out (*FIFO*)
  - Least Frequency Used (*LFU*)
  - Random

## ➤ Cara penulisan (*Write Policy*)

- *Write through*
- *Write back*
- Ukuran blok (*Block Size*)
- Jenis cache
  - *Off-chip, On-chip*
  - *Single level, Multilevel*
  - *Unified, Split*

## Write Policy (1)

- Bertujuan untuk memastikan apakah blok di *cache* yang akan diganti telah di-copy di memori
- Problem 1: bagaimana jika *main memory* dapat diakses oleh lebih dari satu *device* tanpa melalui *cache* (misal dengan DMA)
- Solusi:
  - (a) *Write through*
  - (b) *Write back*

# Write Policy (2)

## (a) Write through

- Setiap ada perubahan data di *cache* **selalu di-copy** di memori, demikian pula sebaliknya
- Kelebihan/kekurangan:
  - (+) Teknik paling sederhana
  - (-) Menyebabkan *memory traffic* tinggi (*cache – main memory*)
  - (-) Dapat terjadi *bottleneck* (bus data penuh)

## (b) Write back

- *Update* data **hanya** dilakukan **di cache**
- Jika baris di *cache* akan ditempati data lain → data lama di-copy ke memori **hanya jika** data tsb mengalami perubahan
- Kelebihan/kekurangan:
  - (+) *Memory traffic* berkurang
  - (-) Data di memori tidak valid → akses I/O ke memori harus melalui *cache*
  - (-) *Circuitry* lebih kompleks
  - (-) Dapat terjadi *bottleneck*

## ***Write Policy (3)***

- Problem 2: bagaimana jika terdapat lebih dari satu prosesor dan masing-masing mempunyai *cache* tersendiri?
- Solusi:
  - *Cache* saling berhubungan (*cache coherency*)
    - Macam *cache coherency*:
      - (a) *Bus watching with write through*
      - (b) *H/W transparency*
      - (c) *Non cacheable memory*

# Write Policy (4)

## (a) Bus watching with write through

- Setiap *cache controller* memonitor baris alamat untuk mengetahui apakah ada *device* lain yang menulis ke memori

## (b) H/W transparency

- Digunakan H/W tambahan untuk menjamin perubahan data di memori selalu melalui *cache* dan di-copy-kan ke *cache-cache* yang lain

## (c) Non cacheable memory

- Sebagian dari *main memory* di-sharing oleh beberapa prosesor
- Data pada *shared memory* tidak di-copy-kan ke *cache* → selalu terjadi *cache miss*

Part 4: Mengapa *cache memory* dibuat menjadi beberapa tingkatan/level?

- Ukuran (*Size*) cache
- *Mapping Cache-Main memory*
  - Direct
  - Associative
  - Set associative
- Algoritma Penggantian (*Replacement*)
  - Least Recently Used (LRU)
  - First In First Out (FIFO)
  - Least Frequency Used (LFU)
  - Random
- Cara penulisan (*Write Policy*)
  - Write through
  - Write back

## ➤ Ukuran blok (*Block Size*)

- Jenis cache
  - Off-chip, On-chip
  - Single level, Multilevel
  - Unified, Split

- Ukuran blok memori:
  - Makin besar → *cache hit* makin besar  
(efek *locality*: bila suatu word ada di suatu blok, maka ada kemungkinan word-word lain yang terdapat di dalam blok tersebut juga akan digunakan)
  - Terlalu besar → *cache hit* menurun  
(jumlah blok yang dapat di-copy ke *cache* makin sedikit)
  - Ukuran optimum: 8 – 32 byte

- Ukuran (*Size*) cache
- *Mapping Cache-Main memory*
  - Direct
  - Associative
  - Set associative
- Algoritma Penggantian (*Replacement*)
  - Least Recently Used (*LRU*)
  - First In First Out (*FIFO*)
  - Least Frequency Used (*LFU*)
  - Random
- Cara penulisan (*Write Policy*)
  - Write through
  - Write back
- Ukuran blok (*Block Size*)

## ➤ Jenis cache

- Off-chip, On-chip
- Single level, Multilevel
- Unified, Split

# Jenis cache (1)

- Jenis *cache memory*:
  - Berdasarkan letaknya:
    - *off-chip cache (eksternal)*
    - *on-chip cache (internal)*
  - Berdasarkan levelnya:
    - *one level cache*
    - *multilevel cache (L1, L2, L3)*
  - Berdasarkan jenis data yang disimpan:
    - *unified cache*
    - *split cache*
- (a) *Off-chip cache (eksternal)*
  - Terpisah dari chip prosesor
  - Komunikasi melalui bus eksternal atau bus khusus

## Jenis cache (2)

### (b) *On-chip cache* (internal)

- Menjadi satu dengan chip prosesor
- (+) Waktu eksekusi lebih cepat → performansi sistem meningkat
- (+) Aktifitas bus eksternal berkurang → dapat digunakan untuk keperluan lain

### (c) *One-level cache*

- Hanya ada satu level *cache* (sudah ditinggalkan)

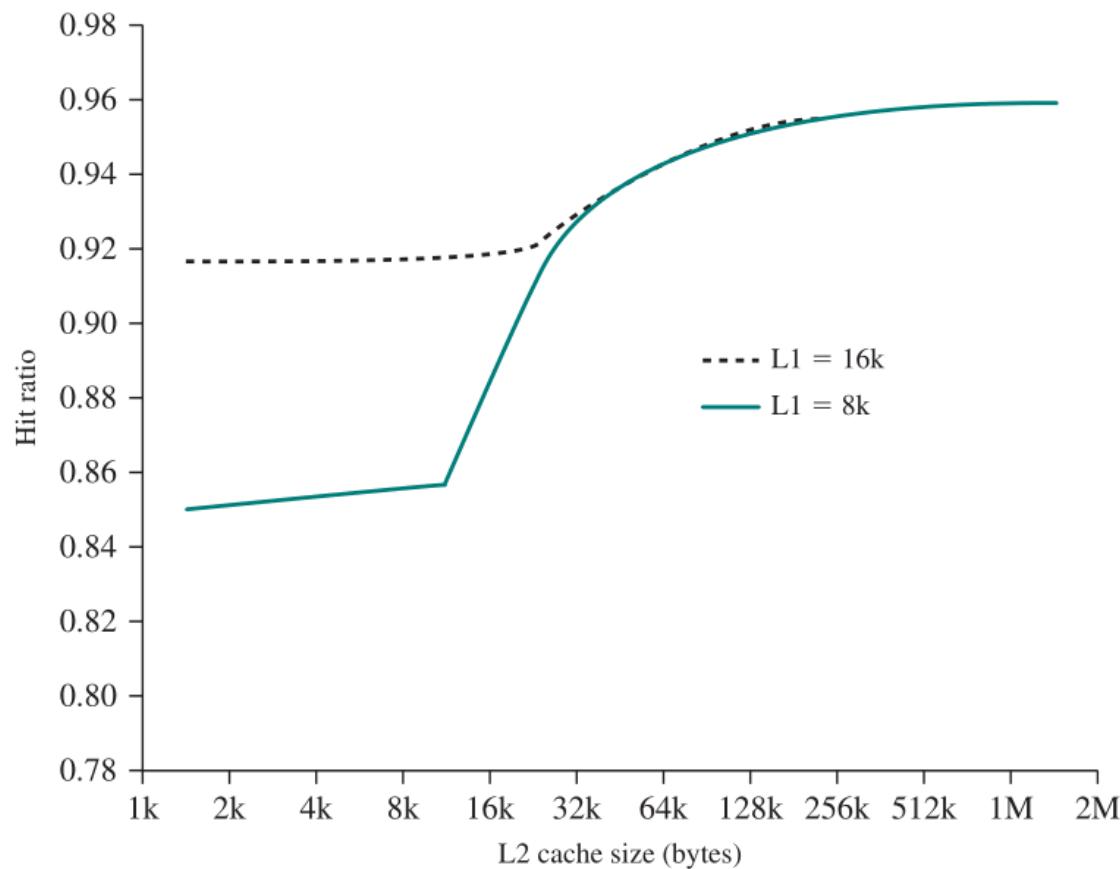
### (d) *Multilevel cache*

- Terdiri dari 2 level *cache* atau lebih

# Jenis cache (3)

- Mengapa perlu 2 level atau lebih??
  - *Cache miss* → CPU akses ke memori, kecepatan memori <<< kecepatan CPU → performansi turun
  - Dengan L2 (SRAM) → mempercepat tersedianya data yang dibutuhkan CPU
- Design L2 *cache*:
  - *Cache* eksternal (dengan bus khusus)
  - *Cache* internal (satu chip dengan prosesor)
- Kelebihan/kekurangan *multilevel cache*:
  - (+) Memperbaiki performansi
  - (-) Perancangan *cache* lebih rumit (ukuran, algoritma, *write policy*, dll)

# Jenis cache (3)



**Figure 4.17** Total Hit Ratio (L1 and L2) for 8-Kbyte and 16-Kbyte L1

## Jenis cache (4)

### (e) *Unified cache*

- Data dan instruksi disimpan pada tempat yang sama (dalam satu *cache*)
- Kelebihan/kekurangan:
  - (+) *Hit rate* lebih tinggi daripada *split cache*
  - (+) Perancangan dan implementasi terfokus pada satu *cache*
  - (-) Tidak mendukung *pipeline*
  - (-) Dapat terjadi *contention* (rebutan) *cache*

## Jenis cache (5)

### (f) *Split cache* (Pentium, Power PC)

- Cache dibagi 2 sehingga data dan instruksi disimpan pada tempat terpisah
- Kelebihan:
  - (+) Mendukung eksekusi instruksi secara paralel
  - (+) Mencegah *contention cache* antara *fetch/decode* instruksi dan eksekusi instruksi → performansi lebih baik

- 80386 – tanpa *cache*
- 80486:
  - *Single on-chip*
  - Ukuran 8 Kbyte
  - Ukuran line 16 byte
  - *Four way set associative*
- Pentium (semua versi) – 2 buah *on chip cache L1*
  - Untuk data dan instruksi
- Pentium 4
  - L1 *caches*:
    - Ukuran 8 Kbyte
    - Ukuran line 64 byte
    - *Four way set associative*
  - L2 *cache*
    - *Feeding both L1 caches*
    - Ukuran 256 Kbyte
    - Ukuran line 128 byte
    - *8 way set associative*

**Table 4.4** Intel Cache Evolution

| Problem   | Solution   | Processor on Which Feature First Appears |
|---|--|--|
| External memory slower than the system bus.   | Add external cache using faster memory technology.   | 386                                      |
| Increased processor speed results in external bus becoming a bottleneck for cache access.   | Move external cache on-chip, operating at the same speed as the processor.   | 486                                      |
| Internal cache is rather small, due to limited space on chip.   | Add external L2 cache using faster technology than main memory.  | 486                                      |
| Contention occurs when both the Instruction Prefetcher and the Execution Unit simultaneously require access to the cache. In that case, the Prefetcher is stalled while the Execution Unit's data access takes place. | Create separate data and instruction caches.   | Pentium                                  |
| Increased processor speed results in external bus becoming a bottleneck for L2 cache access.  | Create separate back-side bus that runs at higher speed than the main (front-side) external bus. The BSB is dedicated to the L2 cache. | Pentium Pro                              |
|   | Move L2 cache on to the processor chip.  | Pentium II                               |
| Some applications deal with massive databases and must have rapid access to large amounts of data. The on-chip caches are too small.  | Add external L3 cache.   | Pentium III                              |
|   | Move L3 cache on-chip.   | Pentium 4                                |

# Blok Diagram Pentium 4 (Simplified)

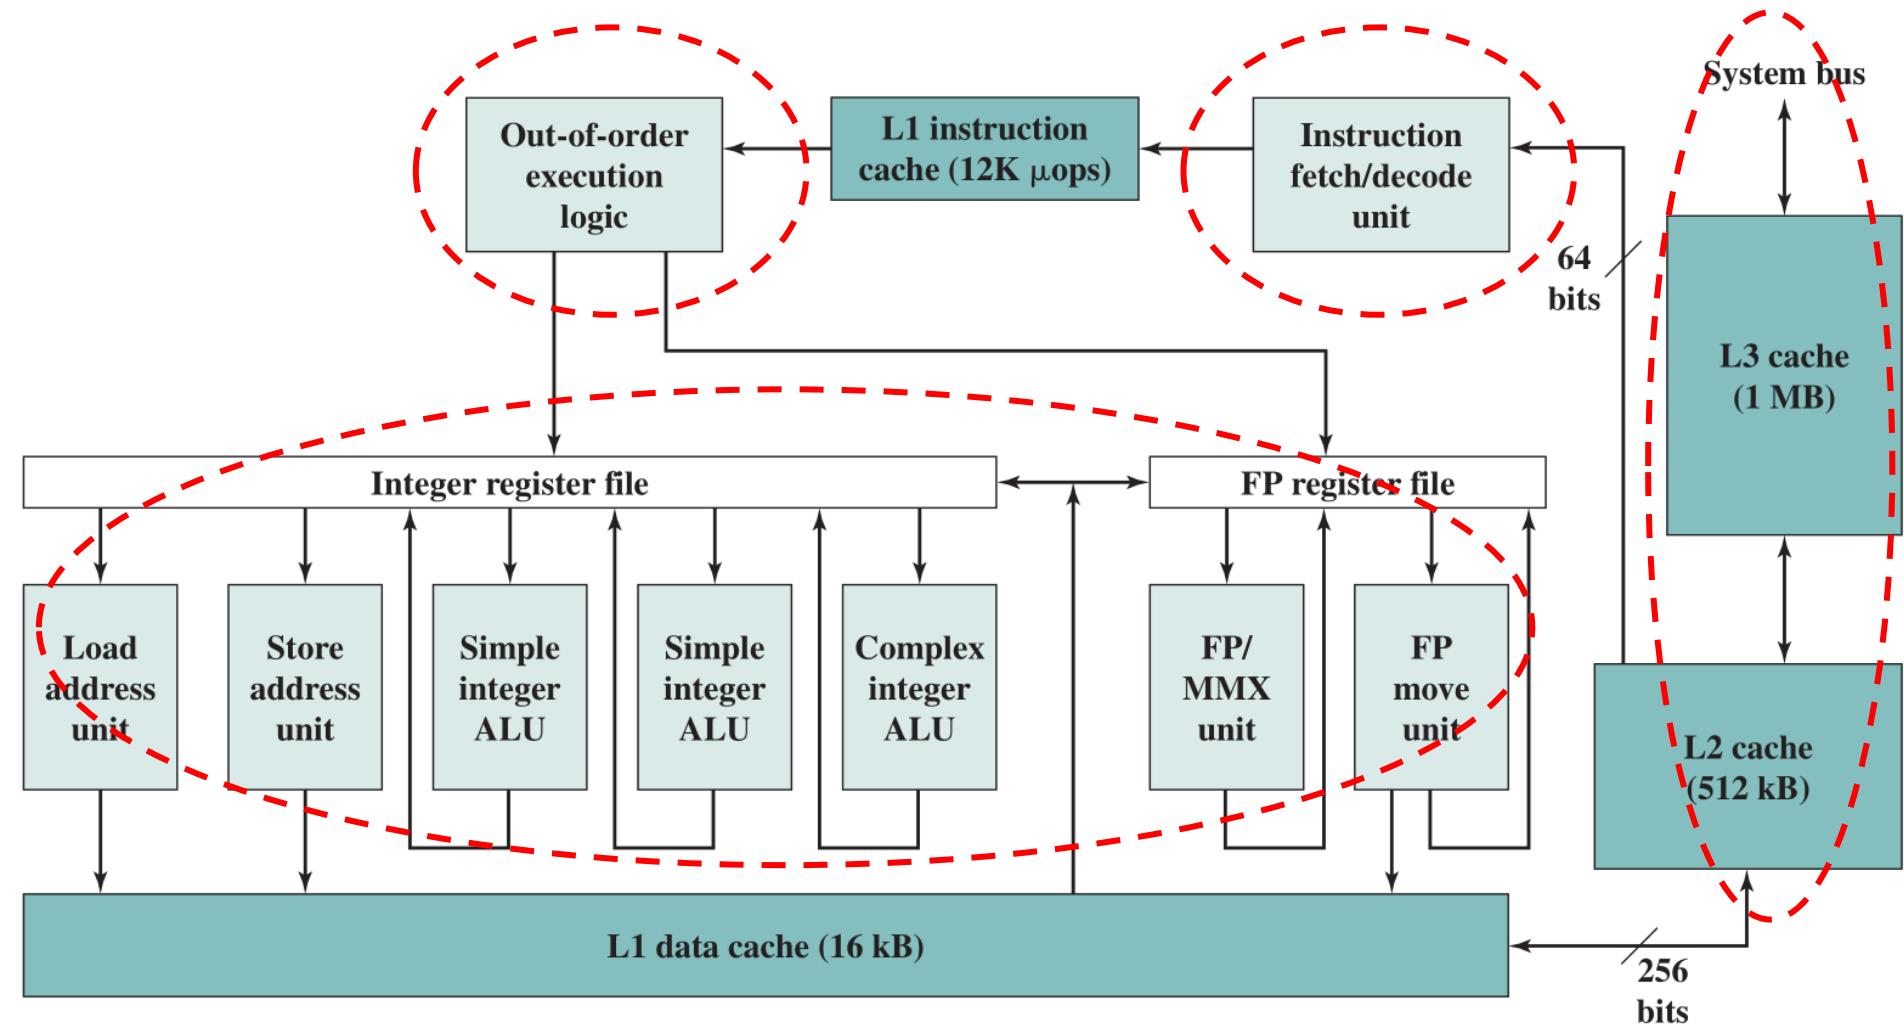


Figure 4.18 Pentium 4 Block Diagram

- *Fetch/Decode Unit*
  - Mengambil instruksi dari *cache L2*
  - Men-decode instruksi menjadi mikro operasi
  - Menyimpan hasilnya (mikro operasi) di *cache instruksi L1*
- *Out of order execution logic*
  - Membuat **jadual** eksekusi mikro operasi sesuai dengan data dan *resource* yang tersedia
  - Membuat jadual eksekusi mikro yang mungkin akan digunakan (**spekulasi**)
- *Execution units*
  - Mengeksekusi mikro operasi
  - Mengambil data yang diperlukan dari *cache L1*
  - Menyimpan hasil pemrosesan ke *register*

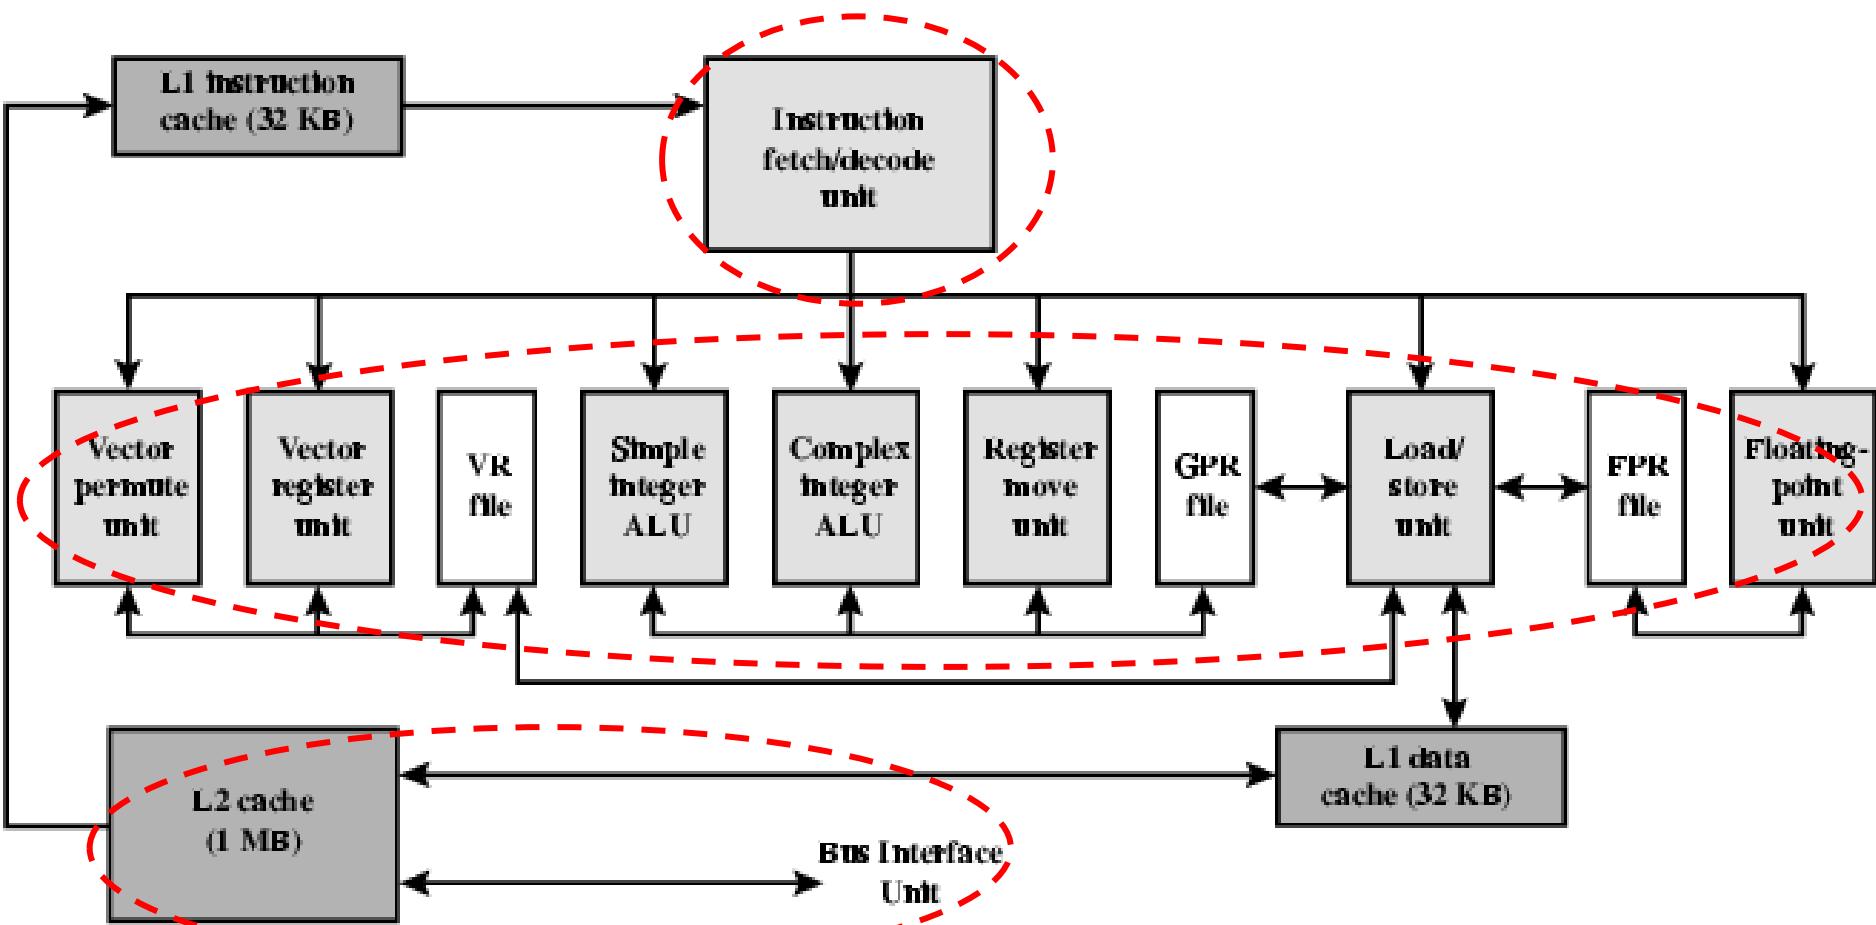
# Bagian Utama Prosesor

## Pentium 4 (2)

- *Memory subsystem*
  - Terdiri dari *cache L2* dan sistem bus
  - Untuk mengakses main memory jika terjadi *cache miss*
  - Untuk mengakses *resource I/O*

- 601 – *single* 32 Kbyte, *8 way set associative*
- 603 – 16 Kb (2 x 8 Kb) *two way set associative*
- 604 – 32 Kbyte
- 610 – 64 Kbyte
- G3 & G4
  - L1 *cache*:
    - 64 Kbyte
    - *8 way set associative*
  - L2 *cache*
    - 256 Kbyte, 512k atau 1M
    - *two way set associative*

# Blok Diagram Power PC G4

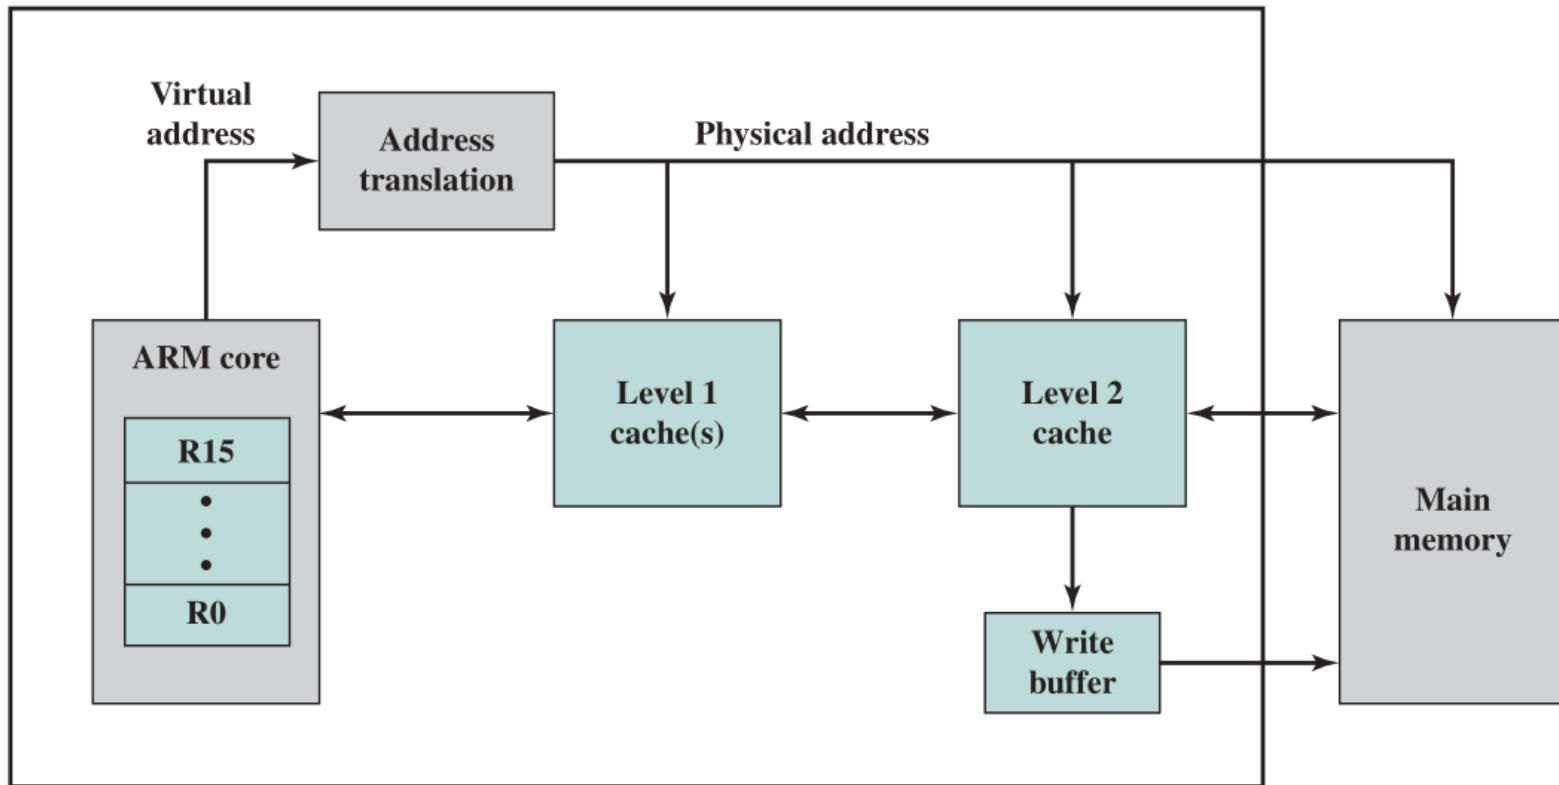


# ARM Cache Features

**Table 4.6** ARM Cache Features

| Core            | Cache Type | Cache Size (kB) | Cache Line Size (words) | Associativity | Location | Write Buffer Size (words) |
|-----------------|------------|-----------------|-------------------------|---------------|----------|---------------------------|
| ARM720T         | Unified    | 8               | 4                       | 4-way         | Logical  | 8                         |
| ARM920T         | Split      | 16/16 D/I       | 8                       | 64-way        | Logical  | 16                        |
| ARM926EJ-S      | Split      | 4-128/4-128 D/I | 8                       | 4-way         | Logical  | 16                        |
| ARM1022E        | Split      | 16/16 D/I       | 8                       | 64-way        | Logical  | 16                        |
| ARM1026EJ-S     | Split      | 4-128/4-128 D/I | 8                       | 4-way         | Logical  | 8                         |
| Intel StrongARM | Split      | 16/16 D/I       | 4                       | 32-way        | Logical  | 32                        |
| Intel Xscale    | Split      | 32/32 D/I       | 8                       | 32-way        | Logical  | 32                        |
| ARM1136-JF-S    | Split      | 4-64/4-64 D/I   | 8                       | 4-way         | Physical | 32                        |

# ARM Cache Features



**Figure 4.19** ARM Cache and Write Buffer Organization

# Perbandingan Ukuran Cache

| Processor               | Type                              | Year of Introduction | L1 Cache <sup>a</sup> | L2 Cache       | L3 Cache              |
|-------------------------|-----------------------------------|----------------------|-----------------------|----------------|-----------------------|
| IBM 360/85              | Mainframe                         | 1968                 | 16–32 kB              | —              | —                     |
| PDP-11/70               | Minicomputer                      | 1975                 | 1 kB                  | —              | —                     |
| VAX 11/780              | Minicomputer                      | 1978                 | 16 kB                 | —              | —                     |
| IBM 3033                | Mainframe                         | 1978                 | 64 kB                 | —              | —                     |
| IBM 3090                | Mainframe                         | 1985                 | 128–256 kB            | —              | —                     |
| Intel 80486             | PC                                | 1989                 | 8 kB                  | —              | —                     |
| Pentium                 | PC                                | 1993                 | 8 kB/8 kB             | 256–512 kB     | —                     |
| PowerPC 601             | PC                                | 1993                 | 32 kB                 | —              | —                     |
| PowerPC 620             | PC                                | 1996                 | 32 kB/32 kB           | —              | —                     |
| PowerPC G4              | PC/server                         | 1999                 | 32 kB/32 kB           | 256 kB to 1 MB | 2 MB                  |
| IBM S/390 G6            | Mainframe                         | 1999                 | 256 kB                | 8 MB           | —                     |
| Pentium 4               | PC/server                         | 2000                 | 8 kB/8 kB             | 256 kB         | —                     |
| IBM SP                  | High-end server/<br>supercomputer | 2000                 | 64 kB/32 kB           | 8 MB           | —                     |
| CRAY MTA <sup>b</sup>   | Supercomputer                     | 2000                 | 8 kB                  | 2 MB           | —                     |
| Itanium                 | PC/server                         | 2001                 | 16 kB/16 kB           | 96 kB          | 4 MB                  |
| Itanium 2               | PC/server                         | 2002                 | 32 kB                 | 256 kB         | 6 MB                  |
| IBM POWER5              | High-end server                   | 2003                 | 64 kB                 | 1.9 MB         | 36 MB                 |
| CRAY XD-1               | Supercomputer                     | 2004                 | 64 kB/64 kB           | 1 MB           | —                     |
| IBM POWER6              | PC/server                         | 2007                 | 64 kB/64 kB           | 4 MB           | 32 MB                 |
| IBM z10                 | Mainframe                         | 2008                 | 64 kB/128 kB          | 3 MB           | 24–48 MB              |
| Intel Core i7<br>EE 990 | Workstation/<br>server            | 2011                 | 6 × 32 kB/<br>32 kB   | 1.5 MB         | 12 MB                 |
| IBM zEnterprise<br>196  | Mainframe/<br>server              | 2011                 | 24 × 64 kB/<br>128 kB | 24 × 1.5 MB    | 24 MB L3<br>192 MB L4 |

- 
- [STA19] Stalling, William. 2019. “*Computer Organization and Architecture: Designing for Performance*”. 11<sup>th</sup> edition. Prentice Hall.