

Bagian 9

Hirarki Memori

Pembahasan

- ✚ Trend teknologi penyimpanan
- ✚ Referensi locality
- ✚ Cache pada hirarki memori

Random Access Memory (RAM)

Karakteristik

- RAM dibungkus dalam paket berbentuk chip
- Satuan penyimpanan dasar adalah sel (1 bit per sel)
- Gabungan beberapa chip RAM membentuk memori

Static RAM (SRAM)

- Setiap sel menyimpan bit dalam rangkaian dgn enam transistor
- Datanya akan bertahan terus, selama diberi daya
- Relatif tahan terhadap gangguan, seperti noise
- Lebih cepat dan mahal dari DRAM

Dynamic RAM (DRAM)


- Setiap sel menyimpan bit dalam kapasitor dan transistor
- Datanya harus di-refresh setiap 10-100 ms
- Sensitif terhadap gangguan
- Lebih lambat dan murah dibandingkan dengan SRAM

Perbandingan SRAM vs DRAM

	Transistor per bit	Waktu akses	Data bertahan	Sensitif	Harga	Aplikasi
SRAM	6	x 1	ya	tidak	x 100	Cache memory
DRAM	1	x 10	tidak	ya	x 1	Main memory


Organisasi DRAM Konvensional

- ✚ Total $d \times w$ bit, disimpan dalam d buah supersel berukuran w bit




Membaca DRAM – Supersel (2,1)

- ✚ Langkah 1(a): Row access strobe (**RAS**) memilih baris ke 2.
- ✚ Langkah 1(b): Baris 2 disalin dari DRAM array ke buffer baris.




Membaca DRAM – Supersel (2,1)

- ✚ Langkah 2(a): Column access strobe (**CAS**) memilih kolom 1.
- ✚ Langkah 2(b): Supercell (2,1) disalin dari buffer ke saluran data & dikirim ke CPU



Modul Memori



Enhanced DRAM


- ✚ Seluruh DRAM yang ada saat ini dibangun berdasarkan DRAM konvensional, yaitu :
 - **Fast Page Mode DRAM (FPM DRAM)**
 - Mengakses isi baris secara [RAS, CAS, CAS, CAS], bukan [(RAS,CAS), (RAS,CAS), (RAS,CAS), (RAS,CAS)]
 - **Extended Data Output DRAM (EDO DRAM)**
 - Peningkatan FPM DRAM, jarak antara sinyal CAS lebih dekat
 - **Synchronous DRAM (SDRAM)**
 - Dikendalikan secara sinkron pada sisi clock naik
 - **Double Data-Rate Synchronous DRAM (DDR SDRAM)**
 - Peningkatan SDRAM, sinyal kontrol menggunakan kedua sisi clock
 - **Video RAM (VRAM)**
 - Seperti FPM DRAM, output diperoleh dengan menggeser buffer baris (shift)
 - Memiliki dua port (dapat melakukan proses baca dan tulis secara bersamaan)

Nonvolatile Memory

- ✚ DRAM dan SRAM termasuk kategori volatile memory
 - Informasi hilang jika daya listrik dimatikan
- ✚ Nonvolatile memory dapat mempertahankan isinya walaupun daya dimatikan
 - Nama generiknya adalah read-only memory (**ROM**)
 - Terjadi salah arti, karena beberapa ROM dapat dimodifikasi
- ✚ Jenis-jenis ROM
 - Programmable ROM (**PROM**)
 - Erasable Programmable ROM (**EPROM**)
 - Electrically Erasable PROM (**EEPROM**)
 - Flash memory
- ✚ Firmware
 - Program yang disimpan di ROM
 - Boot time code, BIOS (basic input/output system)
 - Graphic card, disk controller


Struktur Bus CPU-Memori

- ✚ Bus adalah **kumpulan saluran paralel** yang mengalirkan sinyal alamat, data dan kontrol.
- ✚ Umumnya digunakan bersama oleh beberapa devais.




Proses Membaca Memori (1)

- CPU meletakkan alamat A pada memory bus.




Proses Membaca Memori (2)

- Main memory membaca A dari memory bus, mengambil word x, dan meletakkannya pada bus




Proses Membaca Memori (3)

- ✚ CPU membaca word x dari bus dan menyalinnya ke register %eax




Proses Menulis ke Memori (1)

- CPU meletakkan alamat A pada bus. Main memory membacanya dan menunggu munculnya word data.




Proses Menulis ke Memori (2)

- ✚ CPU meletakkan word data y pada bus




Proses Menulis ke Memori (3)

- Main memory membaca word data *y* dari bus dan menyimpannya di alamat *A*.




Hard Disk

- ✚ Hard disk terdiri dari beberapa **piringan**, masing-masing memiliki **dua permukaan**.
- ✚ Pada setiap permukaan terdapat **lingkaran konsentrik** yang disebut **track**.
- ✚ Setiap track terbagi atas beberapa **sektor** yang dipisahkan oleh jarak tertentu (**gap**).



Geometri Hard Disk

- ✚ Track pada jalur yang sama membentuk silinder



Kapasitas Hard Disk

- ✚ **Kapasitas** : banyaknya bit maksimum yang dapat disimpan
 - Produsen menulis kapasitas dalam satuan gigabyte (GB)
 - $1 \text{ GB} = 10^9$
- ✚ Kapasitas ditentukan oleh faktor teknologi berikut :
 - **Recording density** (bit/inci): banyaknya bit yang dapat ditempatkan dalam segmen track sepanjang 1 inci.
 - **Track density** (track/inci): banyaknya track yang dapat ditempatkan dalam satu segmen radial sepanjang 1 inci.
 - **Areal density** (bit/inci²): perkalian dari recording density dan track density.
- ✚ Hard disk saat ini membagi track menjadi beberapa bagian yang tidak saling berhubungan, disebut **recording zones**
 - Setiap track dalam satu zona memiliki jumlah sektor yang sama, ditentukan oleh panjang track yang paling dalam.
 - Setiap zona memiliki jumlah sektor/track yang berbeda

Menghitung Kapasitas HardDisk

✚ Kapasitas = (# byte/sektor) x (rata2 # sektor/track) x
(# track/permukaan) x (# permukaan/piringan) x
(# piringan/disk)

✚ Contoh :


- 512 byte/sektor
- 300 sektor/track (rata-rata)
- 20,000 track/permukaan
- 2 permukaan/piringan
- 5 piringan/disk

✚ Kapasitas = $512 \times 300 \times 20000 \times 2 \times 5$
= 30,720,000,000
= 30.72 GB

Operasi Hard Disk




Permukaan hard disk berputar dengan kecepatan rotasi tetap



Head baca/tulis diletakkan pada ujung lengan, dan melayang di atas permukaan disk ketika disk berputar

Dengan bergerak secara radial, lengan dapat memposisikan head baca/tulis pada berbagai track

Operasi Hard Disk



Waktu Akses Hard Disk

- + Waktu rata-rata untuk mengakses suatu sektor target dapat dihitung :
 - $T_{\text{access}} = T_{\text{avg seek}} + T_{\text{avg rotasi}} + T_{\text{avg transfer}}$
- + Waktu pencarian ($T_{\text{avg seek}}$)
 - Waktu yang diperlukan untuk meletakkan head di atas silinder yang mengandung sektor target
 - Umumnya $T_{\text{avg seek}} = 9$ mdetik
- + Delay rotasi ($T_{\text{avg rotasi}}$)
 - Waktu untuk menunggu bit pertama sektor target berada di bawah head baca/tulis
 - $T_{\text{avg rotasi}} = \frac{1}{2} \times \frac{1}{\text{RPM}} \times 60 \text{ detik/1 menit}$
- + Waktu transfer ($T_{\text{avg transfer}}$)
 - Waktu untuk membaca bit-bit pada sektor target
 - $T_{\text{avg transfer}} = \frac{1}{\text{RPM}} \times \frac{1}{\text{rata2 \# sektor/track}} \times 60 \text{ detik/1 menit}$

Contoh Waktu Akses HardDisk

+ Diketahui :

- Kecepatan rotasi = 7,200 RPM
- Waktu pencarian rata-rata = 9 ms.
- Rata2 # sektor/track = 400.

+ Diturunkan :

- $T_{avg \text{ rotasi}} = 1/2 \times (60 \text{ det}/7200 \text{ RPM}) \times 1000 \text{ mdetik/detik} = 4 \text{ mdetik}$
- $T_{avg \text{ transfer}} = 60/7200 \text{ RPM} \times 1/400 \text{ sektor/track} \times 1000 \text{ mdetik/detik} = 0.02 \text{ mdetik}$
- $T_{access} = 9 \text{ mdetik} + 4 \text{ mdetik} + 0.02 \text{ mdetik}$


+ Hal penting :

- Waktu akses didominasi oleh waktu pencarian dan delay rotasi
- Bit pertama pada sektor adalah yang paling berpengaruh.
- Waktu akses SRAM sekitar 4 ndetik/doubleword, DRAM 60 ndetik
 - Hard disk sekitar 40.000 kali lebih lambat dari SRAM
 - 2.500 lebih lambat dari DRAM


Blok Logika Hard Disk

- ✚ Pada hard disk modern, sektor geometri yang rumit dapat direpresentasikan dengan sudut pandang yang lebih sederhana
 - Set dari sektor yang tersedia dimodelkan dalam urutan blok logika berukuran b (0, 1, 2, ...)
- ✚ Memetakan blok logika dan sektor fisik sesungguhnya
 - Dikelola oleh suatu device perangkat keras yang disebut harddisk controller.
 - Menerjemahkan permintaan akan blok logika menjadi urutan permukaan-track-sektor
- ✚ Harddisk controller mengatur penggunaan silinder untuk setiap zona
 - Menghitung perbedaan antara “kapasitas setelah diformat” dan “kapasitas maksimum”


Bus I/O




Membaca Sektor Hard Disk (1)



Membaca Sektor Hard Disk (2)



Membaca Sektor Hard Disk (3)



Perkembangan Memori

SRAM

metrik	1980	1985	1990	1995	2000	<i>2000:1980</i>
\$/MB	19,200	2,900	320	256	100	<i>190</i>
akses(ndetik)	300	150	35	15	2	<i>100</i>

DRAM

metrik	1980	1985	1990	1995	2000	<i>2000:1980</i>
\$/MB	8,000	880	100	30	1	<i>8,000</i>
akses (ndetik)	375	200	100	70	60	<i>6</i>
ukuran (MB)	0.064	0.256	4	16	64	<i>1,000</i>

Disk


metrik	1980	1985	1990	1995	2000	<i>2000:1980</i>
\$/MB	500	100	8	0.30	0.05	<i>10,000</i>
akses (mdetik)	87	75	28	10	8	<i>11</i>
ukuran (MB)	1	10	160	1,000	9,000	<i>9,000</i>

Kecepatan Clock CPU

	1980	1985	1990	1995	2000	<i>2000:1980</i>
Prosesor	8080	286	386	Pent	P-III	
clock rate(MHz)	1	6	20	150	750	750
cycle time(ns)	1,000	166	50	6	1.6	750

Gap Kecepatan CPU - Memori

- Perbedaan kecepatan antara DRAM, Hard disk dan CPU terus meningkat



Locality

Prinsip locality :

- Program cenderung untuk memakai ulang data dan instruksi yang letaknya berdekatan dengan yang sebelumnya digunakan, atau yang pernah mereferensikannya.
- **Temporal locality** : sesuatu yang pernah direferensikan cenderung akan direferensikan kembali pada waktu yang tidak lama.
- **Spatial locality** : sesuatu yang letak alamatnya berdekatan cenderung untuk direferensikan secara bersama pada satu waktu

Locality

✚ Contoh locality :

```
sum = 0;
for (i = 0; i < n; i++)
    sum += a[i];
return sum;
```

- Data
 - Mereferensikan elemen array secara berurutan (pola stride-1 reference) : **Spatial locality**
 - Mereferensikan sum pada setiap iterasi : **Temporal locality**
- Instruksi
 - Mereferensikan instruksi secara berurutan : **Spatial locality**
 - Berputar dalam loop secara berulang-ulang : **Temporal locality**

Contoh Locality

- ✚ Kemampuan untuk melihat kode dan mengetahui locality secara kualitatif merupakan kunci yang harus dimiliki oleh seorang programmer profesional.
- ✚ Apakah fungsi di bawah ini memiliki locality yang baik ?

```
int sumarrayrows(int a[M][N])
{
    int i, j, sum = 0;

    for (i = 0; i < M; i++)
        for (j = 0; j < N; j++)
            sum += a[i][j];
    return sum
}
```

Contoh Locality

✚ Apakah fungsi berikut memiliki locality yang baik ?

```
int sumarraycols(int a[M][N])
{
    int i, j, sum = 0;

    for (j = 0; j < N; j++)
        for (i = 0; i < M; i++)
            sum += a[i][j];
    return sum
}
```

Contoh Locality

- ✚ Lakukan permutasi pada loop sehingga fungsi dapat melacak array 3D **a[]** dengan pola stride-1 reference (dan menghasilkan locality spasial yang baik).

```
int sumarray3d(int a[M][N][N])
{
    int i, j, k, sum = 0;


    for (i = 0; i < M; i++)
        for (j = 0; j < N; j++)
            for (k = 0; k < N; k++)
                sum += a[k][i][j];

    return sum
}
```

Hirarki Memori

- ✚ Beberapa perilaku dasar pada hardware dan software :
 - Teknologi penyimpanan yang cepat memiliki biaya per byte lebih tinggi dan kapasitas lebih rendah
 - Perbedaan kecepatan antara CPU dan memori bertambah lebar
 - Program yang dibuat dengan baik cenderung untuk memiliki locality yang baik
- ✚ Setiap perilaku dasar tersebut saling mengisi satu sama lain dengan baik
- ✚ Diusulkan untuk mengelola memori dan sistem penyimpanan yang dikenal dengan **hirarki memori**.


Hirarki Memori




Cache

- ✚ Perangkat penyimpan cepat dan kecil, berfungsi sebagai area antara dengan data yang berada pada penyimpan yang lambat dan besar.
- ✚ Ide dasar dari hirarki memori :
 - Untuk setiap k , devais pada level k yang lebih cepat dan kecil merupakan cache dari devais yang lebih lambat dan besar pada level $k+1$
- ✚ Mengapa hirarki memori digunakan ?
 - Program cenderung untuk mengakses data pada level k lebih sering dari data pada level $k+1$
 - Penyimpan pada level $k+1$ dapat lebih lambat, besar dan harga per bit lebih rendah

Cache Pada Hirarki Memori



Konsep Umum Cache



Program memerlukan obyek d yang disimpan dalam suatu blok b

Cache hit

- Program menemukan b dalam cache level k. Misalnya pada blok 14.

Cache miss

- B tidak terdapat pada level k, sehingga cache level k harus mengambilnya dari level k+1. Misalnya blok 12.
- Jika cache level k penuh, maka suatu blok harus diganti isinya. Blok mana yang menjadi “korban” ?
 - Placement policy** : dimana blok baru diletakkan. Misalnya $b \bmod 4$
 - Replacement policy** : blok mana yang harus terusir ? Misalnya LRU

Konsep Umum Cache

✚ Jenis cache miss :

- **Cold (compulsary) miss**
 - Cold miss terjadi jika cache kosong.
- **Conflict miss**
 - Cache pada level $k+1$ membagi blok menjadi subset berukuran kecil yang dapat diletakkan pada level k .
 - Misalnya, blok i pada level $k+1$ harus diletakkan pada blok $(i \bmod 4)$ pada level $k+1$.
 - Conflict miss terjadi jika cache level k berukuran cukup besar, tetapi suatu kumpulan obyek data dipetakan pada blok yang sama di level k .
 - Misalnya jika mereferensikan blok 0, 8, 0, 8, 0, 8, ... akan terjadi miss secara terus menerus.
- **Capacity miss**
 - Terjadi ketika blok data yang aktif (working set) lebih besar dari kapasitas cache

Cache Dalam Hirarki Memori

Jenis Cache	Obyek Cache	Lokasi Cache	Delay	Pengelola
Registers	4-byte word	CPU registers	0	Compiler
TLB	Address translations	On-Chip TLB	0	Hardware
L1 cache	32-byte block	On-Chip L1	1	Hardware
L2 cache	32-byte block	Off-Chip L2	10	Hardware
Virtual Memory	4-KB page	Main memory	100	Hardware+ OS
Buffer cache	Parts of files	Main memory	100	OS
Network buffer cache	Parts of files	Local disk	10,000,000	AFS/NFS client
Browser cache	Web pages	Local disk	10,000,000	Web browser
Web cache	Web pages	Remote server disks	1,000,000,000	Web proxy server