



Les caches

2MIC

Architecture matérielle

Vincent MIGLIORE



Principes fondamentaux de l'informatique

- **Principe de localité :**


- Il y a une forte probabilité qu'une donnée dont l'adresse est proche d'une donnée récemment accédée le soit à son tour.
- Exemple : Les instructions qui sont situées les unes à la suite des autres en mémoire centrale.

- **Principe de temporalité :**

- Il y a une forte probabilité qu'une donnée récemment utilisée le soit de nouveau.

Le principe du cache


- Le cache est une mémoire rapide, pour combler la différence de vitesse entre le processeur et la mémoire centrale.
- Elle est située entre le processeur et la mémoire centrale.



Le principe du cache


Le cache est une mémoire associative :

- Les informations sont accessibles par leur contenu, et non par une adresse.
- Une ligne de cache est une paire Clé/contenu.
- On demande une clé, en non une adresse.
- Clé = typiquement l'adresse d'une donnée en mémoire centrale.




Le principe du cache

On interroge le cache en demandant s'il possède la **clé** que l'on souhaite, et il renvoie la **donnée** associée.




Le principe du cache

Si la clé est présente, il y a **cache hit** et la donnée est retournée au demandeur.




Le principe du cache

Si la clé **n'est pas** présente, il y a **cache miss**, et donc le cache va demander au cache de niveau supérieur s'il possède la clé.




Le principe du cache

Si le **cache L1 est plein**, il faut alors **invalider une ligne existante** pour placer la ligne demandée par le CPU.




Le principe du cache

Invalider d'une ligne de cache revient à **recopier en mémoire centrale la donnée** présente dans le cache L1. Cela passe par la recopie de la ligne dans tous les caches intermédiaires.




Le principe du cache

Une fois invalidée, la pair (clé, donnée)
peut être recopiée dans la ligne restée
vacante.




Organisation d'un cache

- Un cache est organisé en lignes, qui possèdent en général 8 données de 32 ou 64 bits.
- Pour une mémoire RAM dont les transferts sont sur 64 bits, il faut donc 8 accès mémoires pour remplir 1 ligne de cache.



Organisation d'un cache

- Si on considère un cache de 16 Ko, combien il y a de lignes de cache ?




Organisation d'un cache

- Si on considère un cache de 16 Ko, combien il y a de lignes de cache ?


- Réponse :

$$16 \text{ Ko} / 512 \text{ bits} = 16 \times 2^{10} \text{ o} / 64 \text{ o} = 256$$




Organisation d'un cache

- Question :
 - Comment associe-t-on une ligne de cache à une adresse en mémoire centrale ?




Cas du cache à correspondance pré-établie

- C'est le cas le plus simple :
 - on considère un cache de 4 lignes de 128 bits pour faire simple.
- Cela fonctionne comme un modulo




Cas du cache à correspondance pré-établie

- 0x00 → 0x0F : Ligne 0, 0x10 → 0x1F : ligne 1,
0x20 → 0x2F : Ligne 2, 0x30 → 0x3F : ligne 3.
- 0x40 → 0x4F : Ligne 0, 0x50 → 0x5F : ligne 1,
0x60 → 0x6F : Ligne 2, 0x70 → 0x7F : ligne 3.



Cas du cache à correspondance pré-établie


- 16 octets par ligne → 4 bits pour coder le décalage de l'octet
- 4 lignes → 2 bits pour coder la ligne
- Le reste : C'est le tag



Cas du cache à correspondance pré-établie

Adresse physique ↔ Tag | Ligne | Décalage


0x00 0x00 0x0 0x0



Cas du cache à correspondance pré-établie

Adresse physique ↔ Tag | Ligne | Décalage


0x04 0x00 0x0 0x4



Cas du cache à correspondance pré-établie

Adresse physique ↔ Tag | Ligne | Décalage

0x05 0x00 0x0 0x5





Cas du cache à correspondance pré-établie

Adresse physique ↔ Tag | Ligne | Décalage

0x45 0x01 0x0 0x5

0x00 32 bits
0x04 32 bits
0x08 32 bits
0x0C 32 bits
0x10 32 bits
0x14 32 bits
0x18 32 bits
0x1C 32 bits
0x20 32 bits
0x24 32 bits
0x28 32 bits
0x2C 32 bits
0x30 32 bits
0x34 32 bits
0x38 32 bits
0x3C 32 bits
0x40 32 bits
0x44 32 bits
0x48 32 bits
0x4C 32 bits
0x50 32 bits
0x54 32 bits
0x58 32 bits
0x5C 32 bits
0x60 32 bits
0x64 32 bits
0x68 32 bits
0x6C 32 bits
0x70 32 bits
0x74 32 bits
0x78 32 bits
0x7C 32 bits



0x45



A vous de jouer

Adresse physique ↔ Tag | Ligne | Décalage
0x6F 0x ?? 0x? 0x?

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits




A vous de jouer : Réponse


Adresse physique $\leftrightarrow$ Tag | Ligne | Décalage

0x6F 0x01 0x2 0xF

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits



0x6F





Dernier exemple

Adresse physique $\leftrightarrow$ Tag | Ligne | Décalage

0xA3 0x02 0x2 0x3

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits





0xA3

Exercice de conclusion

- Dans cette configuration, calculez le TAG, la ligne et le décalage des adresses suivantes : 0x28, 0x60



0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits



Exercice de conclusion

- 0x28 → 0b0010 1000 → TAG : 0, LIGNE : 2, DECA. : 8
- 0x60 → 0b0110 0000 → TAG : 1, LIGNE : 2, DECA. : 0

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits






Avantages et inconvénients du cache à correspondance pré-établie

- Avantage :
 - Simplicité : Le cache décode la ligne et le TAG depuis l'adresse, puis est capable en 1 cycle de savoir si la donnée est présente ou non.
- Désavantage :
 - C'est son caractère déterministe (à une adresse correspond une ligne de cache). Cela signifie que la performance est fortement dépendante du programme actuel et du comportement des autres programmes qui tournent en parallèle.


The ultimate cache : Totalement associatif

- Il n'y a aucun lien de correspondance ligne ↔ adresse, chaque adresse peut être associée à n'importe quelle ligne du cache.




The ultimate cache : Totalement associatif

- En contre-partie, le cache doit vérifier le TAG de chaque ligne avant de savoir si la donnée est présente ou non dans sa mémoire.



The ultimate cache : Totalement associatif



Adresse physique demandée : 0x34



The ultimate cache : Totalement associatif


Adresse physique demandée : 0x7C

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits



The ultimate cache : Totalement associatif



Adresse physique demandée : 0x04



The ultimate cache : Totalement associatif

Adresse physique demandée : 0x40




0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits



The ultimate cache : Totalement associatif

Adresse physique demandée : 0x58

Le cache étant rempli, comment choisir la ligne à supprimer ?




Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type Random :

Le remplacement d'une ligne de cache se fait en sélectionnant aléatoirement une ligne

Simple dans sa conception, mais on peut très bien malencontreusement remplacer une ligne qui est fortement utilisée.




Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **FIFO / Round Robin** :

First In First Out → La ligne dont l'ajout dans le cache est la plus ancienne est remplacée.

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits




Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Least Recently Used → Ligne dont l'accès est le plus lointain.

La méthode la plus simple directe est d'ajouter un compteur au niveau du cache et de copier cette valeur lorsque l'on accède à une ligne. Cependant, un compteur demande une activité constante sur le cache, même s'il n'est pas acc

0x00	32 bits
0x04	32 bits
0x08	32 bits
0x0C	32 bits
0x10	32 bits
0x14	32 bits
0x18	32 bits
0x1C	32 bits
0x20	32 bits
0x24	32 bits
0x28	32 bits
0x2C	32 bits
0x30	32 bits
0x34	32 bits
0x38	32 bits
0x3C	32 bits
0x40	32 bits
0x44	32 bits
0x48	32 bits
0x4C	32 bits
0x50	32 bits
0x54	32 bits
0x58	32 bits
0x5C	32 bits
0x60	32 bits
0x64	32 bits
0x68	32 bits
0x6C	32 bits
0x70	32 bits
0x74	32 bits
0x78	32 bits
0x7C	32 bits



Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i, on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i.

Accès à la ligne 2 :

0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0

0x3	32 bits	32 bits	32 bits	32 bits
0x7	32 bits	32 bits	32 bits	32 bits
0x0	32 bits	32 bits	32 bits	32 bits
0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i, on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i.

Accès à la ligne 2 :

0	0	0	0
0	0	0	0
1	1	0	1
0	0	0	0

0x3	32 bits	32 bits	32 bits	32 bits
0x7	32 bits	32 bits	32 bits	32 bits
0x0	32 bits	32 bits	32 bits	32 bits
0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i, on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i.

Accès à la ligne 0 :

0	1	1	1
0	0	0	0
0	1	0	1
0	0	0	0

0x3	32 bits	32 bits	32 bits	32 bits
0x7	32 bits	32 bits	32 bits	32 bits
0x0	32 bits	32 bits	32 bits	32 bits
0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i, on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i.

Accès à la ligne 1 :

0	0	1	1
1	0	1	1
0	0	0	1
0	0	0	0

0x3	32 bits	32 bits	32 bits	32 bits
0x7	32 bits	32 bits	32 bits	32 bits
0x0	32 bits	32 bits	32 bits	32 bits
0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i, on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i.

Accès à la ligne 3 :

0	0	1	0
1	0	1	0
0	0	0	0
1	1	1	0

0x3	32 bits	32 bits	32 bits	32 bits
0x7	32 bits	32 bits	32 bits	32 bits
0x0	32 bits	32 bits	32 bits	32 bits
0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **LRU** :

Méthode matricielle.

Lorsque l'on accède à la ligne de cache i , on positionne à 1 la ligne i de la matrice, et on met à 0 la colonne i .

Remplacement d'une ligne de cache :

0	0	1	0	0x3	32 bits	32 bits	32 bits	32 bits
1	0	1	0	0x7	32 bits	32 bits	32 bits	32 bits
0	0	0	0	0x0	32 bits	32 bits	32 bits	32 bits
1	1	1	0	0x4	32 bits	32 bits	32 bits	32 bits


Défaut : cette méthode demande N^2 bits, N étant le nombre de lignes

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUt** :

Méthode basé sur un arbre binaire.

On associe à chaque nœud de l'arbre un bit, qui sélectionne une branche ou l'autre en fonction de sa valeur. Dans cet exemple, le bit à 0 sélectionne la branche du haut, et un 1 sélectionne la branche du bas. Lorsque l'on accède à une ligne, on va inverser toutes les branches qui pointent vers la ligne.




Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUt** :

Méthode basé sur un arbre binaire.

On associe à chaque nœud de l'arbre un bit, qui sélectionne une branche ou l'autre en fonction de sa valeur. Dans cet exemple, le bit à 0 sélectionne la branche du haut, et un 1 sélectionne la branche du bas. Lorsque l'on accède à une ligne, on va inverser toutes les branches qui pointent vers la ligne.

Accès à la ligne 1 :




Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUt** :

Méthode basé sur un arbre binaire.

On associe à chaque nœud de l'arbre un bit, qui sélectionne une branche ou l'autre en fonction de sa valeur. Dans cet exemple, le bit à 0 sélectionne la branche du haut, et un 1 sélectionne la branche du bas. Lorsque l'on accède à une ligne, on va inverser toutes les branches qui pointent vers la ligne.

Accès à la ligne 3 :



Défaut : L'histoire de chaque nœud est partiellement pris en compte. Le nœud parent par exemple divise en deux groupes les nœuds, gommant une partie de l'histoire de nœuds enfants.

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUm** :

Chaque ligne est associée à un bit. Lorsque la ligne est accédée, on positionne à 1 le bit de la ligne. Lorsque tous les bits sont à 1, on met à 0 tous les bits sauf celui qui vient d'être positionné à 1.

0	0x3	32 bits	32 bits	32 bits	32 bits
1	0x7	32 bits	32 bits	32 bits	32 bits
0	0x0	32 bits	32 bits	32 bits	32 bits
1	0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUm** :

Chaque ligne est associée à un bit. Lorsque la ligne est accédée, on positionne à 1 le bit de la ligne. Lorsque tous les bits sont à 1, on met à 0 tous les bits sauf celui qui vient d'être positionné à 1.

Accès à la ligne 2 :

0	0x3	32 bits	32 bits	32 bits	32 bits
1	0x7	32 bits	32 bits	32 bits	32 bits
1	0x0	32 bits	32 bits	32 bits	32 bits
1	0x4	32 bits	32 bits	32 bits	32 bits

Algorithmes de remplacement

Algorithme de remplacement d'une ligne de type **PLRUm** :

Chaque ligne est associée à un bit. Lorsque la ligne est accédée, en positionne à 1 le bit de la ligne. Lorsque tous les bits sont à 1, on met à 0 tous les bits sauf celui qui vient d'être positionné à 1.

Accès à la ligne 0 :

1	0x3	32 bits	32 bits	32 bits	32 bits
0	0x7	32 bits	32 bits	32 bits	32 bits
0	0x0	32 bits	32 bits	32 bits	32 bits
0	0x4	32 bits	32 bits	32 bits	32 bits

Quand il y a plusieurs lignes à 0, on remplace celle avec l'indice le plus faible. C'est une méthode très populaire.

Benchmark des solutions existantes

Valeur < 1 → Moins de cache miss que LRU

Representative benchmark =

Application usuelle dans le
domaine de l'embarqué :
Automobile /
Télécommunications / Réseau


Policy	Cache size (KB)	Ways	All benchmarks			Representative benchmarks		
			Hit ratio (%)	Miss ratio / LRU	Average Miss ratio / LRU	Hit ratio (%)	Miss ratio / LRU	Average Miss ratio / LRU
1-bit	8	4	96.32	0.987	0.985	97.04	0.984	0.996
	16	4	97.15	0.983		97.90	1.010	
	32	4	98.28	0.999		98.74	0.997	
	64	4	98.56	0.972		99.10	0.991	
LRU	8	4	96.27	1.000	1.000	97.00	1.000	1.000
	16	4	97.10	1.000		97.92	1.000	
	32	4	98.27	1.000		98.74	1.000	
	64	4	98.51	1.000		99.09	1.000	
MPLRU	8	4	96.26	1.002	0.997	97.01	0.994	0.997
	16	4	97.13	0.988		97.94	0.989	
	32	4	98.27	1.001		98.73	1.007	
	64	4	98.52	0.998		99.09	1.000	
PLRU _m	8	4	96.34	0.981	0.981	97.07	0.975	0.976
	16	4	97.17	0.977		97.94	0.988	
	32	4	98.30	0.982		98.78	0.968	
	64	4	98.54	0.985		99.11	0.974	
PLRU _t	8	4	96.26	1.003	0.999	97.01	0.995	0.998
	16	4	97.13	0.989		97.94	0.988	
	32	4	98.27	1.003		98.73	1.010	
	64	4	98.51	1.000		99.09	1.000	
Random	8	4	96.25	1.004	0.999	96.92	1.024	1.021
	16	4	97.15	0.984		97.84	1.037	
	32	4	98.26	1.007		98.71	1.026	
	64	4	98.52	0.999		99.09	0.998	
Round Robin	8	4	96.18	1.023	1.018	96.86	1.045	1.031
	16	4	96.98	1.042		97.79	1.063	
	32	4	98.27	1.000		98.75	0.990	
	64	4	98.50	1.008		99.06	1.026	

Solution classique: Le cache n-associatif

- Solution à mis chemin entre totalement associatif et à correspondance directe.
 - Les lignes sont regroupés en « **sets** » contenant n lignes de cache.
 - Il y a correspondance pré-établie pour sélectionner le **set**.
 - Au sein d'un set, on utilise une associativité totale.
 - Il « suffit » de vérifier seulement les TAG au sein d'un même **set**.
- Ligne 0
Ligne 1
Ligne 2
Ligne 3

Ligne 60
Ligne 61
Ligne 62
Ligne 63

2048 octets = 16384 bits = 16 Kb





Un peu de vocabulaire

- Cache à correspondance pré-établie → Direct mapped
- Cache totalement associatif → Fully associative
- Cache n-associatif → n-associative / n-Way

Politique d'écriture dans la mémoire de niveau supérieure

- Write-through :
 - Dès qu'une donnée en cache est modifiée, elle est remontée à la mémoire centrale. Cette politique est utilisée pour le cache d'instruction.
- Write-back :
 - Remontée à la mémoire centrale lorsque la donnée est invalidée en cache (c'est l'exemple que je vous ai présenté). C'est le cas le plus courant car limite les accès mémoire.

Exemple Intel Core i7 - 3820 CPU

L1 cache :

- instruction cache 32KB
8-way write-through per core
- data cache 32KB
8-way write-back per core
- cache latency : 3 clock cycles

– L2 cache :

- 256KB **8-way write-back**
unified cache **per core**
- Cache latency : 12 clock cycles


– L3 cache :

- 10MB **20-way write-back**
unified cache **shared by all cores**
- Cache latency : 26-31 clock cycles

– TLBs :


- L1 : 4K pages, 64 entries, 4-way
- L2 : 2K pages, 512 entries, 4-way

– Caches + TLBs uses pseudo LRU replacement policy



Temps d'accès selon le niveau de la hiérarchie mémoire

Temps d'accès	Taille
16 μ s	250 Go ~ 2 To
100 ns	1 Go ~ 16 Go
21 ns	10 Mo
7 ns	256 Ko
0.5 ns	32 Ko
0 ns ?	32/64 bits



Application : Multiplication Matrice- vecteur

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

 $\times$

V_0
V_1
V_2
V_3

 $=$

$A_{00} \times V_0 + A_{01} \times V_1 + A_{02} \times V_2 + A_{03} \times V_3$
$A_{10} \times V_0 + A_{11} \times V_1 + A_{12} \times V_2 + A_{13} \times V_3$
$A_{20} \times V_0 + A_{21} \times V_1 + A_{22} \times V_2 + A_{23} \times V_3$
$A_{30} \times V_0 + A_{31} \times V_1 + A_{32} \times V_2 + A_{33} \times V_3$

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 0
- Replacement : 0



0x0 → 0x3	
0x4 → 0x7	
0x8 → 0xB	
0xC → 0xF	

0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 0
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
 V_1
 V_2
 V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 2
- Replacement : 1



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 2
- Replacement : 1



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 2
- Replacement : 1



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 2
- Replacement : 1



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 3
- Replacement : 2



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
 V_1
 V_2
 V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 3
- Replacement : 2



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 3
- Replacement : 2



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 3
- Replacement : 2



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 4
- Replacement : 3



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 4
- Replacement : 3



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 4
- Replacement : 3



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		



Exemple : Multiplication matrice - vecteur

Quelques opérations plus tard ...

Exemple : Multiplication matrice - vecteur

V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Direct mapped

- Cache miss : 32
- Replacement : 31

CPU



$$A_{00} \times V_0 + A_{01} \times V_1 + A_{02} \times V_2 + A_{03} \times V_3$$

$$A_{10} \times V_0 + A_{11} \times V_1 + A_{12} \times V_2 + A_{13} \times V_3$$

$$A_{20} \times V_0 + A_{21} \times V_1 + A_{22} \times V_2 + A_{23} \times V_3$$

$$A_{30} \times V_0 + A_{31} \times V_1 + A_{32} \times V_2 + A_{33} \times V_3$$

0x0 → 0x3	
0x4 → 0x7	
0x8 → 0xB	
0xC → 0xF	

0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 0
- Replacement : 0



0x0 → 0x3	
0x4 → 0x7	
0x8 → 0xB	
0xC → 0xF	

0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 0
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2 / Cache hit : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2 / Cache hit : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2 / Cache hit : 1
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2 / Cache hit : 2
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		

Exemple : Multiplication matrice - vecteur


V_0
V_1
V_2
V_3

A_{00}	A_{01}	A_{02}	A_{03}
A_{10}	A_{11}	A_{12}	A_{13}
A_{20}	A_{21}	A_{22}	A_{23}
A_{30}	A_{31}	A_{32}	A_{33}

X

Fully associative

- Cache miss : 2 / Cache hit : 2
- Replacement : 0



0x00	A_{00}	0x20	A_{20}	0x40	V_0
0x01	A_{01}	0x21	A_{21}	0x41	V_1
0x02	A_{02}	0x22	A_{22}	0x42	V_2
0x03	A_{03}	0x23	A_{23}	0x43	V_3
0x10	A_{10}	0x30	A_{30}		
0x11	A_{11}	0x31	A_{31}		
0x12	A_{12}	0x32	A_{32}		
0x13	A_{13}	0x33	A_{33}		



Exemple : Multiplication matrice - vecteur

Quelques opérations plus tard ...



Conclusion

Direct-mapped :

- Cache hit : 0
- Cache miss : 32
- Remplacement : 31

Fully associative :

- Cache hit : 27
- Cache miss : 5
- Remplacement : 1

Application numérique :

- Cache hit = 0.5 ns / Cache miss : 50 ns / Remplacement : 50 ns



Conclusion

Direct-mapped :

- Cache hit : 0
- Cache miss : 32
- Remplacement : 31

Fully associative :

- Cache hit : 27
- Cache miss : 5
- Remplacement : 1

Application numérique :

- Cache hit = 0.5 ns / Cache miss : 50 ns / Remplacement : 50 ns

Direct-mapped :

3.15 μ s

Fully associative :

313 ns