

معمارية الحاسوب

# Architecture Computer

**ITGS 223**

د. رمزي القانوني

**ITGS 223**

**خريف 2022 - 2023**



## المحاضرة التاسعة:

# Memory & Cache Memory

## الذاكرة وذاكرة السريعة

# Characteristics

## الخصائص

- الموقع (Location)
- السعة (Capacity)
- وحدة النقل (Unit of transfer)
- طريقة الوصول (Access method)
- الاداء (Performance)
- النوع المادي (Physical type)
- الخصائص الفيزيائية (Physical characteristics)
- التنظيم (Organisation)

# Location

## الموقع

- CPU
- Internal
- External

## Cache Memory

عبارة عن ذاكرة صغيرة الحجم, سرعتها عالية جدا, تكون بين CPU وبين RAM الهدف منها هي مجاراة سرعة المعالج التي تكون سرعتها عالية جدا.

لا يمكن مجاراة سرعة CPU من خلال الذاكرة الرئيسية (RAM نضع Cache Memory) بينهم بحيث تكون سرعتها متوسطة بين سرعة CPU وسرعة RAM.

# Capacity

## السعة

السعة التخزينية Cache Memory نحددها من خلال Word size

كل Word size تحتوي على مجموعة من Bits.

$$N = 2^A$$

عدد Word size الموجودة في Cache

$$A = 8 \text{ bit}$$

A عبارة عن عدد Bits لكل موقع تخزيني (عدد المواقع التخزينية)

$$N = 2^8 = 256 \text{ Address}$$

00000000

أول موقع

00000001

ثاني موقع

$$N = 2^{16} = 65535 \quad A = 16 \text{ bit}$$

في حالة :

# Unit of Transfer

## وحدة النقل

➤ وحدة نقل البيانات في الذاكرة الرئيسية (Main Memory) هي عدد bits التي يتم قراءتها أو كتابتها في الذاكرة في وحدة الزمن.

وحدة النقل (Unit of Transfer) مرتبطة بعرض الناقل البيانات Data Bus.  
وحدة العنوان (Addressable unit) بناء على أصغر موقع تخزيني.

# Access Methods (1)

## طرق الوصول

### المتسلسل (Sequential) ➤

المتسلسل يكون من البداية حتي الوصول للبيانات ، يتم التسلسل في عملية البحث عن البيانات حتي نصل إلي البيانات المطلوبة ، Access Time زمن الوصول يعتمد على مكان وجود البيانات مثال عليها الشريط المغناطيسي (tape) وتكون سعة التخزين عالية جدا.

### المباشر (Direct) ➤

تكون الذاكرة مقسمة إلي blocks يتم الوصول إلي أي blocks منها من خلال الوصول إلي منطقة مجاورة من خلال القفز ولها عنوان خاص بها سرعة الوصول تعتمد على الموقع التخزيني للبيانات والموقع السابق, مثال عليها (Hard disk) سرعة الوصول وسعة التخزين كبيرة.

# Access Methods (2)

## طرق الوصول

### العشوائي (Random) ➤

يكون الوصول عشوائي للمواقع وزمن الوصول لا يعتمد على الموقع التخزيني ومثال عليها RAM.

### الترابطي (Associative)

تكون البيانات موجودة من خلال مقارنة جزء من المحتوي مع المخزن ، نقارن البيانات الجديدة بالقديمة فالبيانات تكون مترابطة مع بعضها البعض وزمن الوصول يكون مستقل عن المكان التخزيني أو الوصول السابق ومثال عليها cache إذا تكون البيانات مترابطة مع بعضها البعض.

# Memory Hierarchy

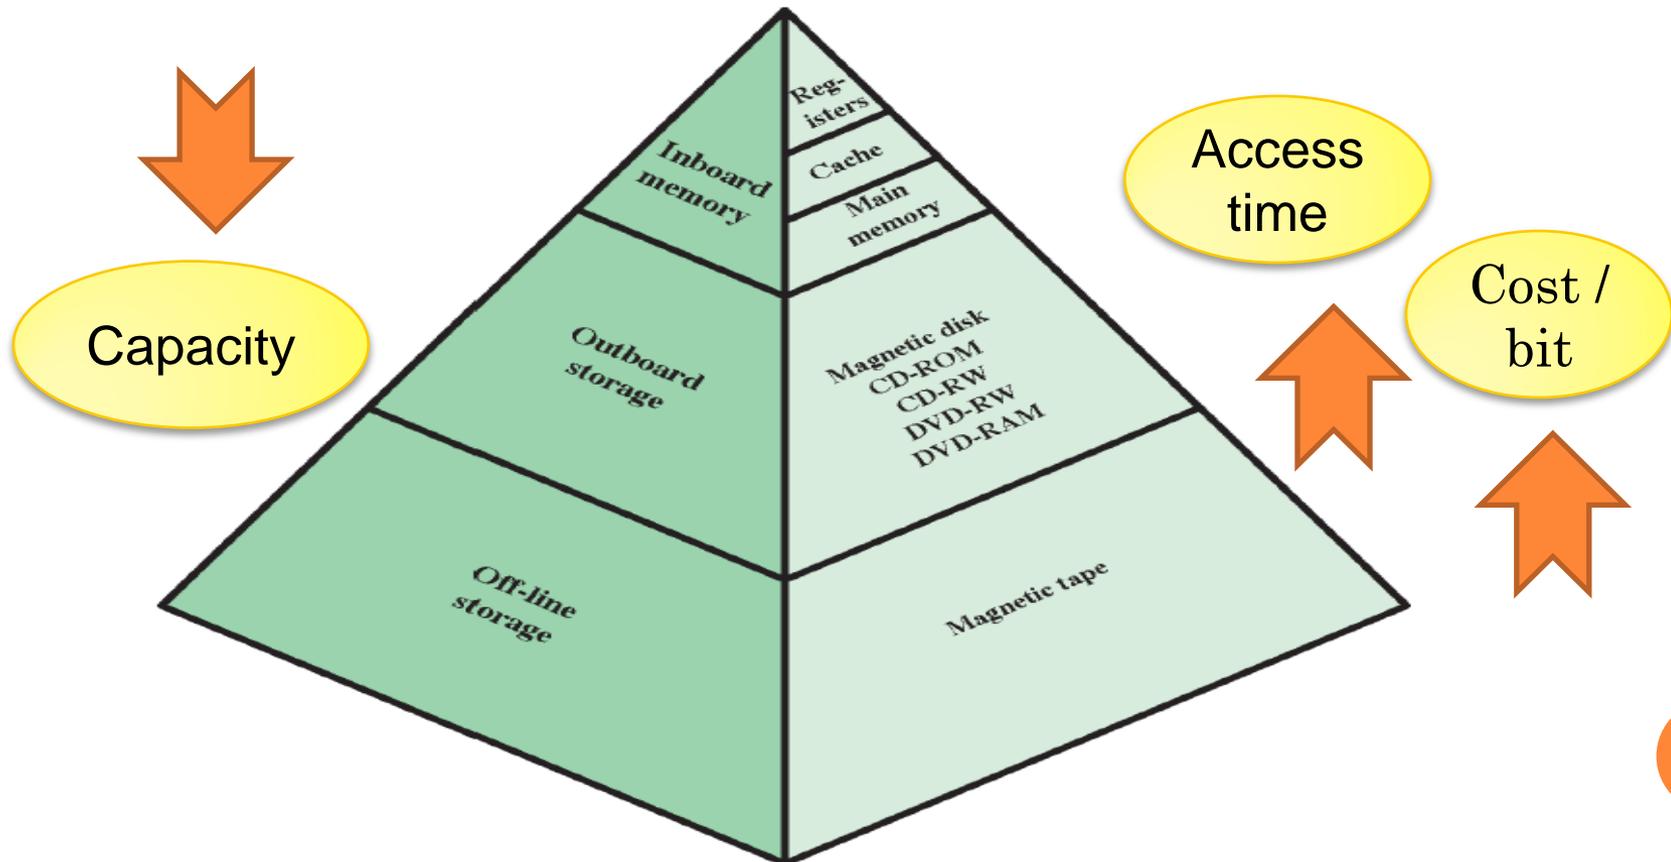
## التسلسل الهرمي للذاكرة

تدرج Memory بناء على الاكثر سرعة :-

- **Registers**
  - In CPU
- **Internal or Main memory**
  - May include one or more levels of cache
  - “RAM”
- **External memory**
  - Hard Disk

# Memory Hierarchy – Diagram

مخطط - التسلسل الهرمي للذاكرة



# Performance

## الاداء

### ➤ زمن الوصول (Access time)

زمن تقديم البيانات والحصول عليها في Registers أعلي من Cache و Cache أعلى من RAM.

### ➤ زمن دورة الذاكرة (Memory Cycle time)

زمن الوصول للبيانات بالإضافة إلي استردادها (أي زمن مطلوب قبل بداية الوصول التالي)

Cycle time access + recovery

### ➤ معدل النقل (Transfer Rate)

نسبة نقل البيانات من مكان إلي مكان , وسرعة هذا النقل.

# Physical Types

## النوع المادي

- Semiconductor
  - RAM
- Magnetic
  - Disk & Tape
- Optical
  - CD & DVD
- Others
  - Bubble
  - Hologram

# Physical Characteristics

## الخصائص الفيزيائية

- ✓ الاضمحلال (Decay) تضائل الاداء أو السعة .
- في الذاكرة المتطايرة المعلومات تضحل بشكل طبيعي أو يتم فقدانها عند غلق / إنهاء الطاقة الكهربائية.
- في الذاكرة الغير متطايرة المعلومات المسجلة لا تفقد أو تضحل حتي يتم تغييرها بشكل معتمد ولا تحتاج إلي الطاقة الكهربائية للحفاظ على المعلومات.
- استهلاك الطاقة (Power consumption).
- تطاير البيانات (Volatility).
- ✓ قابلة للمسح (Erasable) هل البيانات قابلة للمسح أو لا.

الذاكرة المغناطيسية غير متطايرة أما ذاكرة أشباه الموصلات (الالكترونية) قد تكون متطايرة أو غير متطايرة.

# Organisation

## التنظيم

تنظيم الذاكرة يكون للمواقع التخزينية حسب عدد Bits ودائماً لا يكون واضح فمثلاً Hard Disk يكون في فواصل بينية.

# عملية المقارنة بين الذاكر

- How much?
  - Capacity
- How fast?
  - Time is money
- How expensive?

# Hierarchy List

## قائمة التسلسل الهرمي

الترتيب من حيث السرعة :-

- ❖ Registers
- ❖ L1 Cache
- ❖ L2 Cache
- ❖ Main memory
- ❖ Disk cache
- ❖ Disk
- ❖ Optical
- ❖ Tape

# So you want fast?

سؤال:

هل نستطيع حذف (RAM) ونضع مكانها (Cache Memory) ولأدعي أن نحتاج إلي RAM ، يعني مباشرة من Cache Memory التي تكون Static RAM مباشرة إلي CPU تكون السرعة عالية جدا وكذلك التكلفة تكون عالية جدا لذلك نظرا إلي إستخدام RAM لتقليل تكلفة تصنيع الكمبيوتر.

Dr. rami elghannji\_Lecture9

# Locality of Reference

## مرجعية المحل

تعمل Cache Memory بمبدأ مرجعية المحل.

البيانات التي تمت الاشارة إليها مسبقا في الذاكرة الرئيسية تميل إلى إمكانية الاشارة إليها

مرة اخري في وقت لاحق. بمعنى أن البيانات التي نستخدمها في Cache Memory

يمكن أن استخدمها مرة اخري.

**يوجد استراتيجيتين :-**

Temporal Locality ➤

Special Locality ➤

# Locality of Reference

## مرجعية المحل

### Temporal Locality

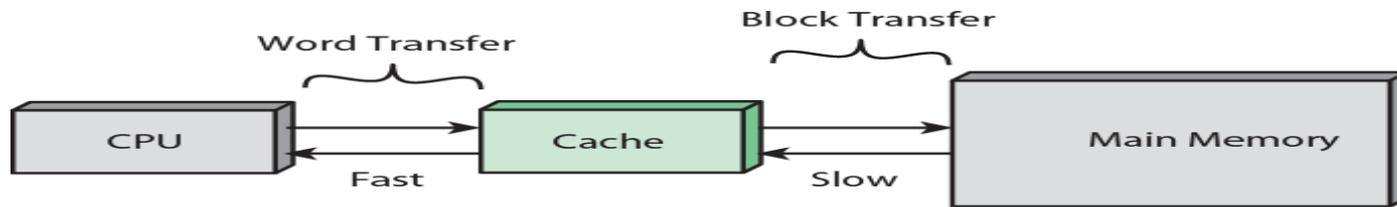
أخر تعليمة تم استدعاها من RAM من المحتمل أن يتم استدعاؤها مرة أخرى فيتم الاحتفاظ بنسخة من هذه التعليمة لوقت معين إذا لم يتم استخدامها يتم التخلص منها.

### Special Locality

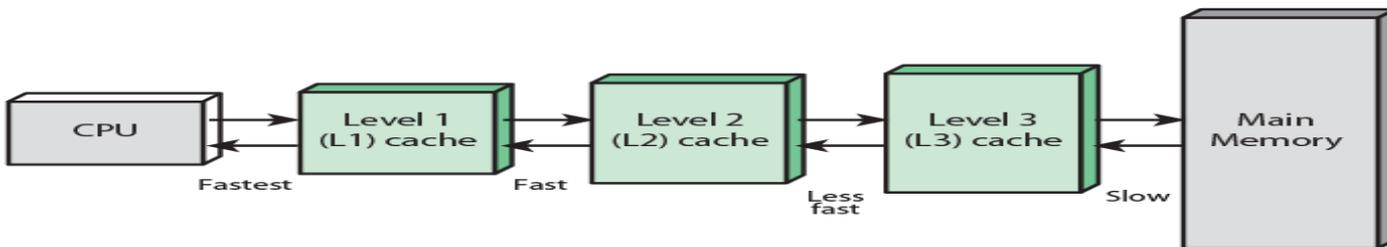
التعليمة الموجودة من القرب من التعليمة التي نريد استدعاها من RAM يمكن أن نستخدمها بدل من جلب تعليمة واحدة فقط فيتم جلب blocks كامل أو جزء كامل من RAM بحيث يمكن أن استخدم التعليمات التي بجانبه.

# Cache and Main Memory

Cache Memory عبارة عن ذاكرة صغيرة الحجم وسريعة جدا توضع بين RAM وبين CPU ويمكن أن توضع على CPU. يتم استخدام النوع الثاني من مرجعية المحل (**Special Locality**) الذي ينقل blocks كامل من Main Memory إلى Cache وينقل Word من Cache إلى CPU على حسب الاستخدام و الطلب.



(a) Single cache



(b) Three-level cache organization

# Cache operation – overview

## العمليات على الذاكرة السريعة – نظرة عامة

CPU يطلب محتويات موقع معين موجود في الذاكرة.

Cache يقوم بفحص إذا كانت هذه البيانات موجوده لديه أو لا.

إذا كانت البيانات موجوده لديه يرسلها مباشرة إلي CPU بهذا يعطينا سرعة عالية.

إذا كانت هذه البيانات غير موجوده في Cache يقوم باستقبال blocks من الذاكرة

يحتوي على المعلومة المطلوبة ثم يقوم بإرسال هذه المعلومة إلي CPU.



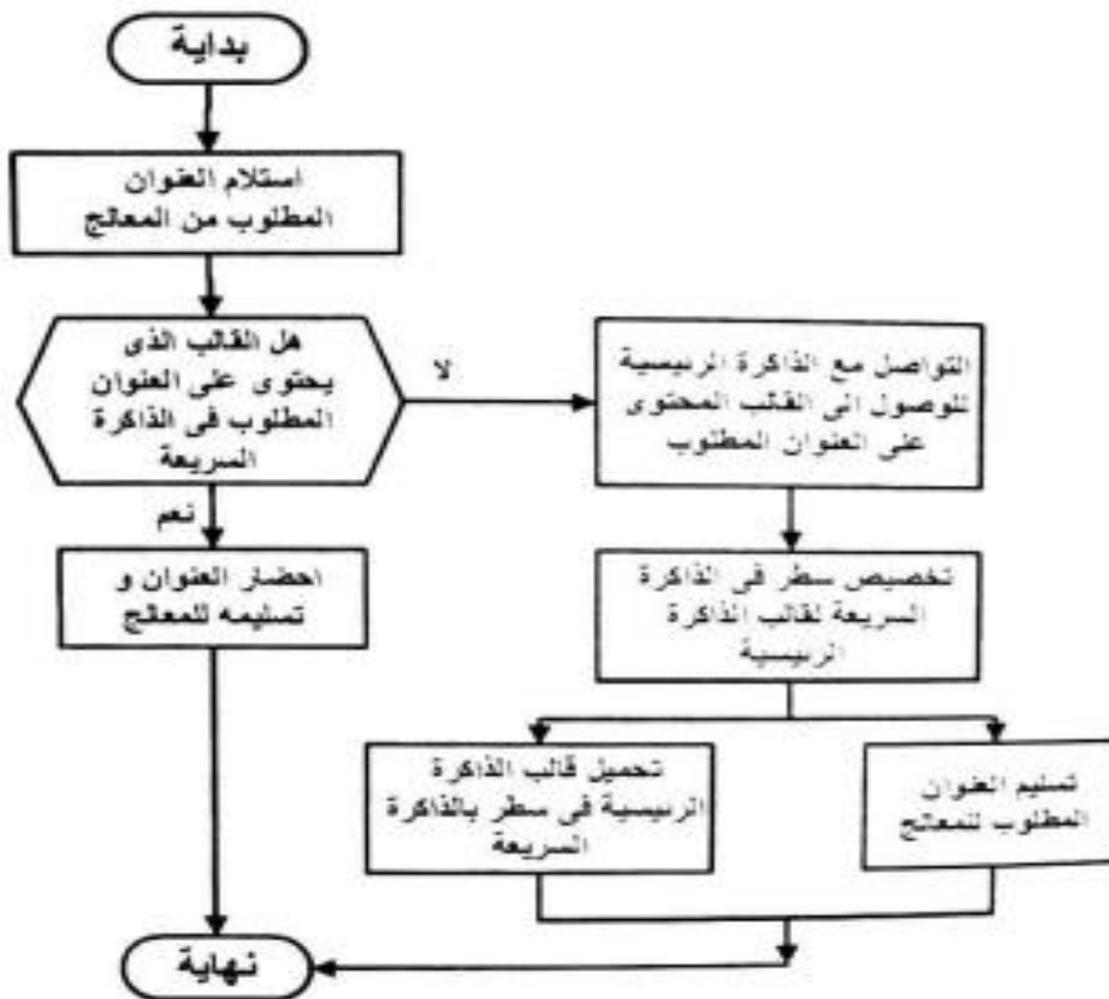
# Cache operation – overview

العمليات على الذاكرة السريعة – نظرة عامة

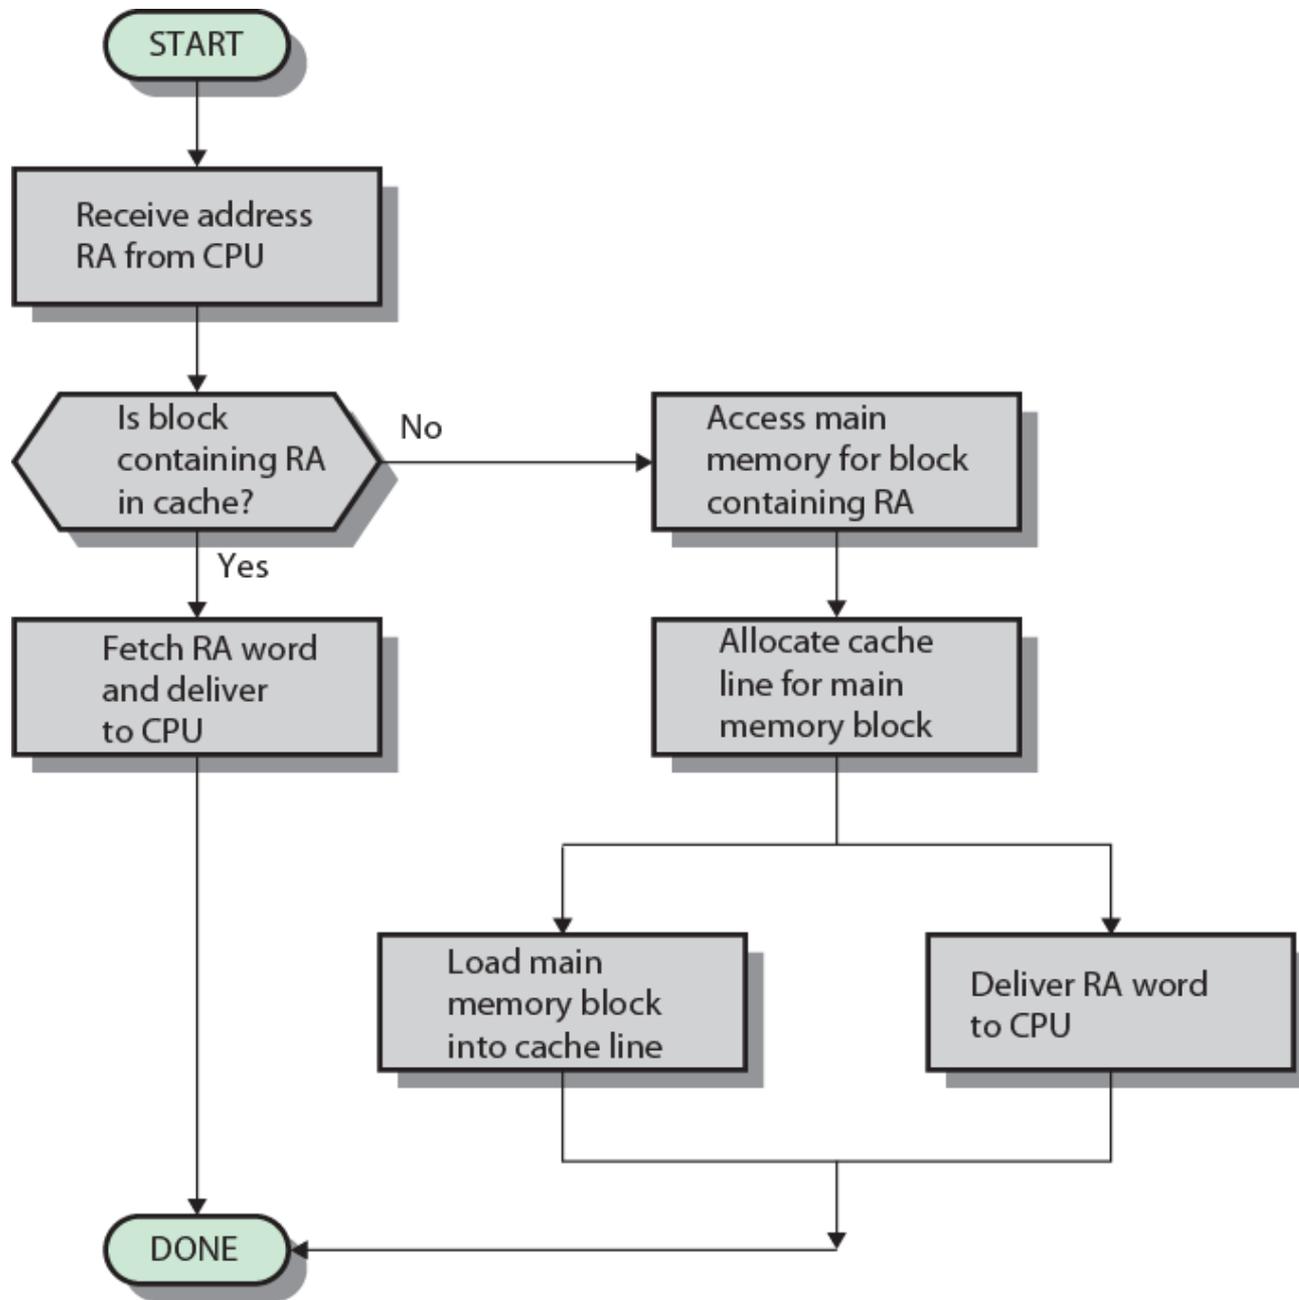
Cache يحتوي على tags.

هذا tags يحتوي على معلومة تدل على اسم blocks الذي تم جلبه من RAM.

كل معلومة موجودة في Cache تحتوي على tags



الشكل (7.5) – عملية القراءة من الذاكرة السريعة



# Cache Design

## تصميم الذاكرة السريعة

- Addressing (logical, physical)
- Size
- Mapping Function
- Replacement Algorithm
- Write Policy
- Block Size
- Number of Caches

كل هذه العناصر تتحكم في أداء الكمبيوتر وسرعته وتكلفته.

# Size does matter

## مسألة الحجم

### Cost

كلما زاد عدد Cache أو حجمها بتزايد التكلفة (Cost).

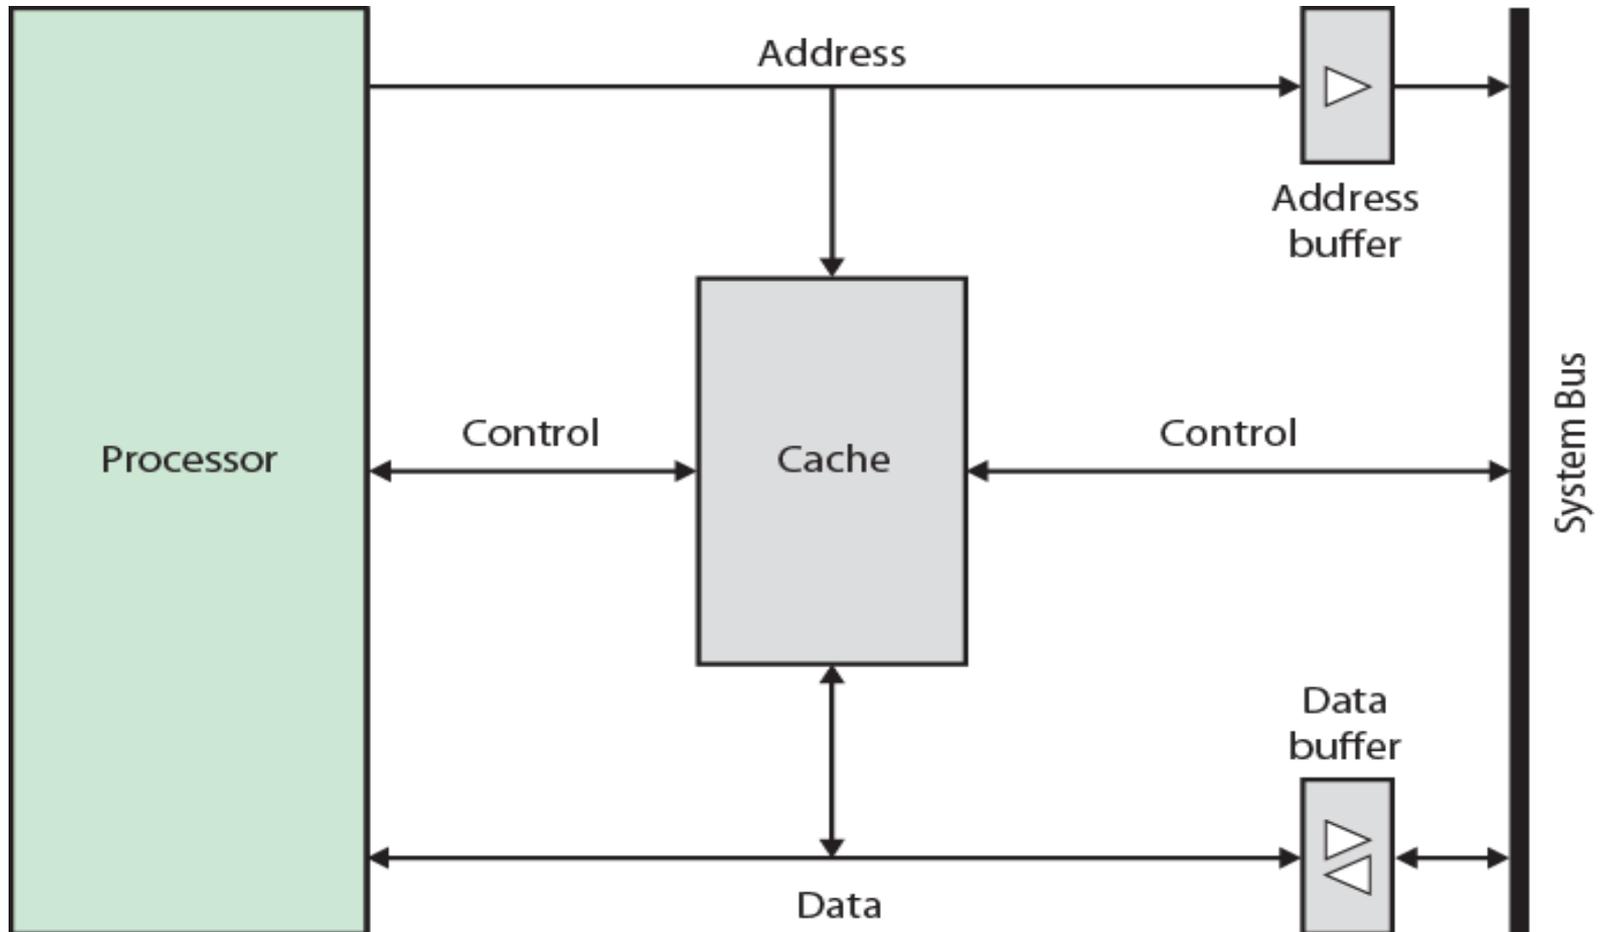
### Speed

كلما زاد عدد Cache أو حجمها بتزايد السرعة (Speed) العملية طرديا.

Dr. Amzi elghanuni - 2019

# Typical Cache Organization

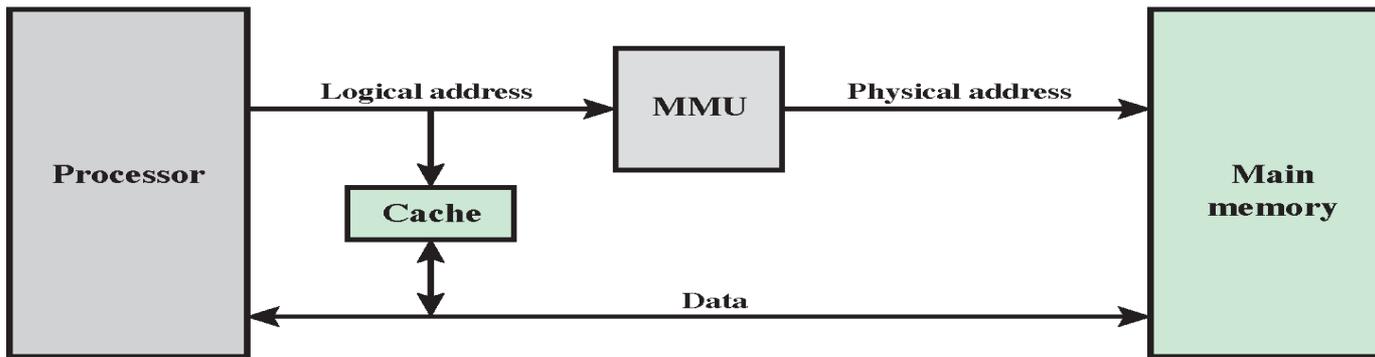
التنظيم النموذجي للذاكرة السريعة



# Addressing cache memory (1)

## عناوين الذاكرة السريعة

عند استخدام عناوين افتراضية يختار المصمم نظام يضع الذاكرة السريعة بين المعالج ووحدة إدارة الذاكرة (MMU) أو بين وحدة إدارة الذاكرة و الذاكرة الرئيسية .  
الذاكرة السريعة الظاهرية تخزن البيانات باستخدام العناوين الافتراضية.  
المعالج يصل إلى الذاكرة السريعة مباشرة دون المرور عبر وحدة إدارة الذاكرة .

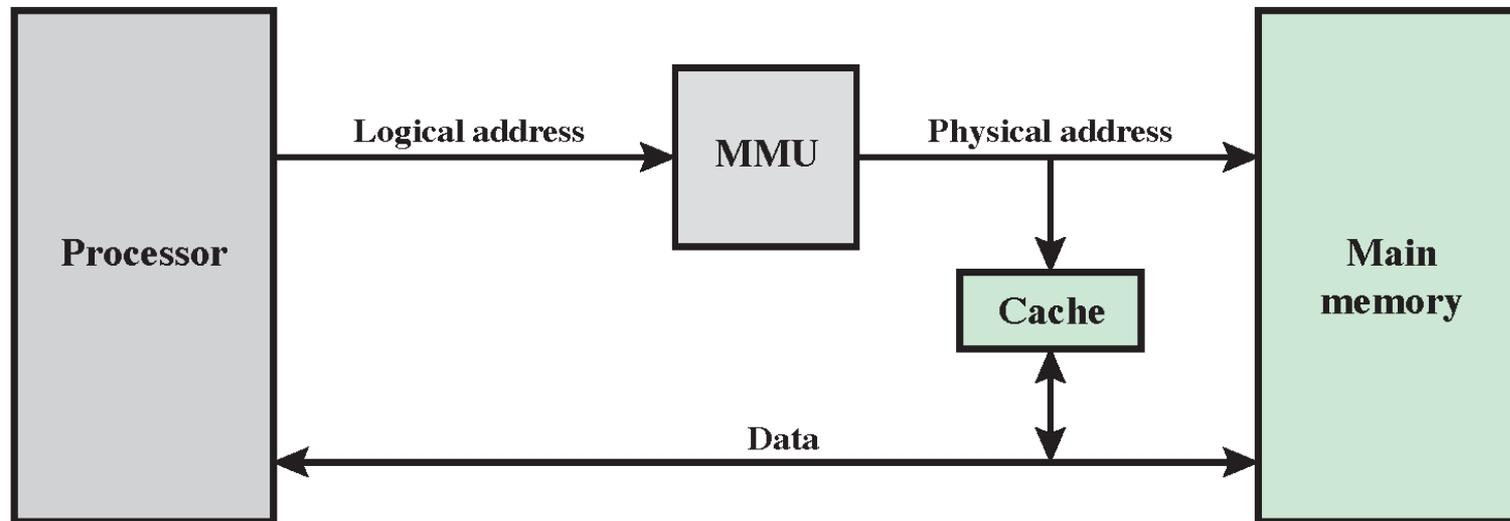


(a) Logical Cache

# Addressing cache memory (2)

## عناوين الذاكرة السريعة

الذاكرة السريعة المادية تخزن البيانات باستخدام عناوين الذاكرة الرئيسية الحقيقية.



(b) Physical Cache

# size cache memory

## حجم الذاكرة السريعة

يجب أن يكون حجم الذاكرة السريعة صغير بما فيه الكفاية بحيث يكون متوسط التكلفة الإجمالية للخانة (البت) هو قريب منه في الذاكرة الرئيسية فقط ، وكبيرة بما فيه الكفاية بحيث يكون إجمالي متوسط زمن الوصول قريبا من الذاكرة السريعة لوحدها .

هناك دوافع أخرى عديدة للتقليل من حجم الذاكرة السريعة منها أن كبر الحجم قد يقلل من السرعة و كذلك المساحة المتاحة على رقاقة المعالج محدودة.

# Mapping Function (1)

## وظيفة الإسقاط

- Blocks in cache called line
- كل مجموعة مواقع تخزينية في Main Memory تسمى Block
- نفس المجموعة في Cache تسمى Line
- بحيث يكون حجم Block يساوي حجم Line
- لو نريد نقل محتويات بيانات Blocks من Main Memory نريد نقلها علي Line يكون نفس الحجم.
- Line هو Blocks لكن التسمية تختلف في Cache Memory

# Mapping Function (2)

## وظيفة الإسقاط

■ **Hit** البيانات موجودة في Cache بمعنى اخر إذا قمنا بعملية بحث عن البيانات في Cache وقمنا بإيجادها.

■ **Miss** إذا كانت البيانات ليست موجودة في Cache نظرًا لجلبها من Memory Main

# Direct Mapping

## الاسقاط المباشر

الاسقاط المباشر طريقة لجلب البيانات من ذاكرة RAM إلى Cache يتم تحميل كل (Block) من الذاكرة الرئيسية في سطر محدد من الذاكرة السريعة.

### مزايا الاسقاط المباشر

أبسط تقنية معروفة.

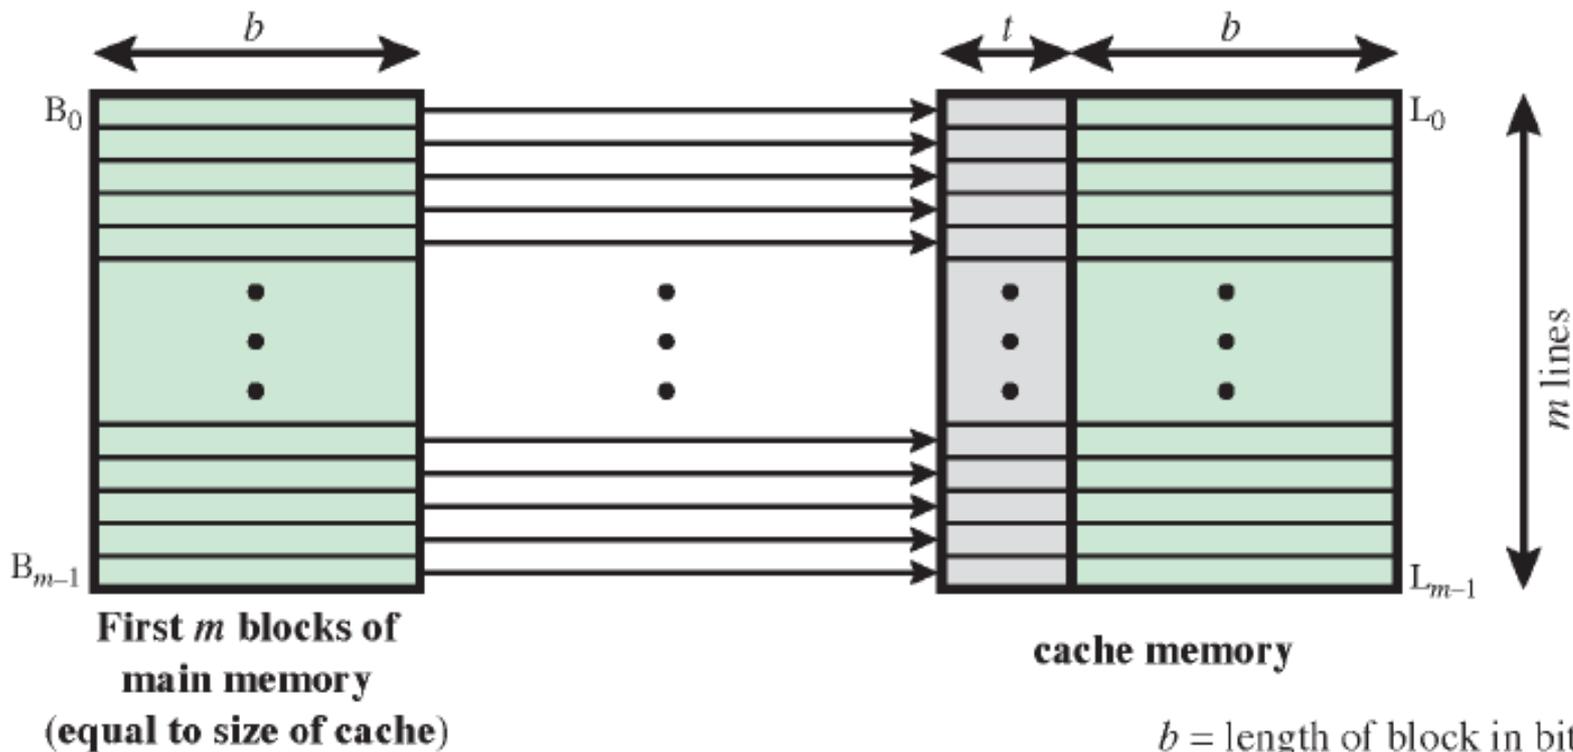
غير مكلفة بالنسبة لقدرات النظام.

### عيوب الاسقاط المباشر

❖ للبيانات مكان واحد فقط في الذاكرة السريعة في حالة جلب بيانات جديدة وتكون متتابعة يلزم جلب كل مرة بيانات واحدة و إزالتها ثم وضع الأخرى وهكذا.

# The mapping of the main memory to the cache memory: Direct

الاسقاط من الذاكرة الرئيسية الى الذاكرة السريعة : المباشر



First  $m$  blocks of main memory (equal to size of cache)

cache memory

$b$  = length of block in bits  
 $t$  = length of tag in bits

(a) Direct mapping

# Associative Mapping

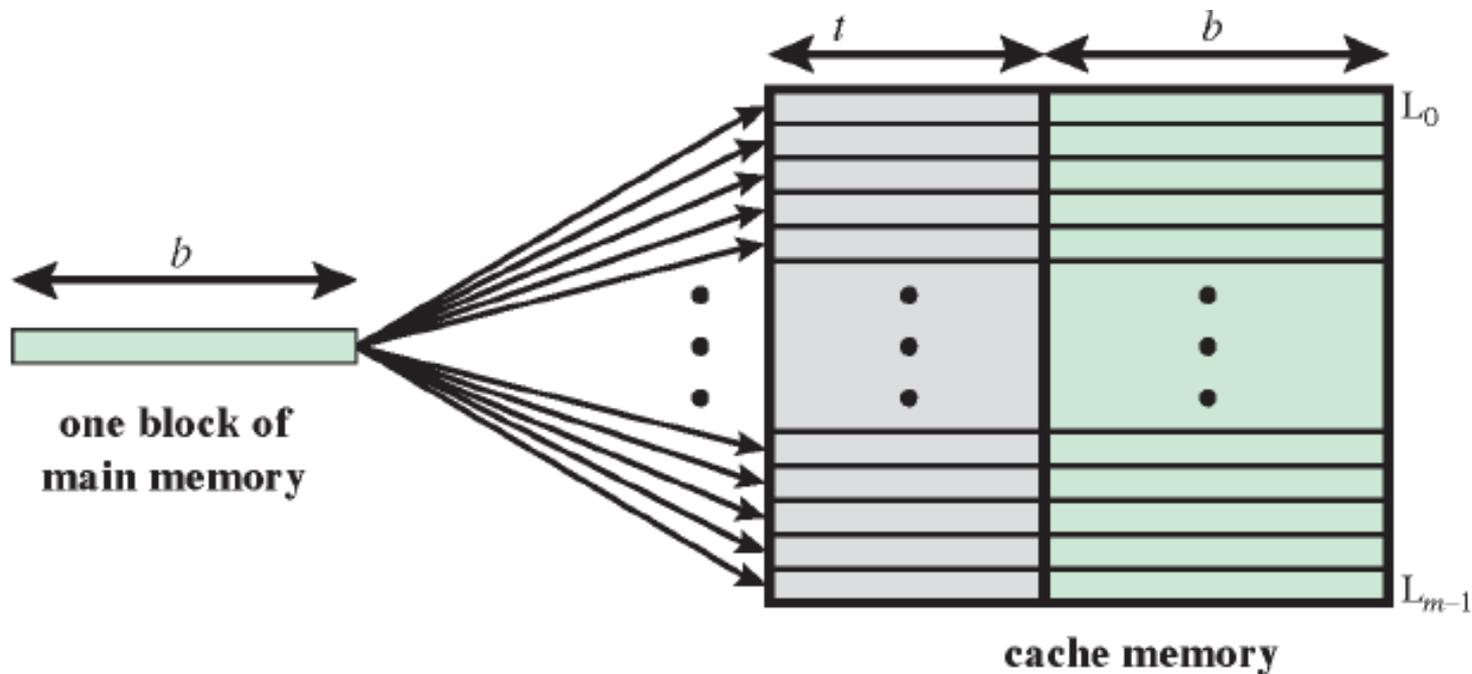
## الاسقاط الترابطي

■ يمكن وضع blocks في إي Line.

■ المشكلة في عملية البحث يجب البحث في جميع Line.

# The mapping of the main memory to the cache memory: Associative

الاسقاط من الذاكرة الرئيسية الى الذاكرة السريعة : الترابطي



(b) Associative mapping

# Replacement Algorithms (1)

## Direct mapping

خوارزميات الاستبدال

الاسقاط المباشر

عملية التبدل بين blocks الموجودة في الذاكرة.

نستخدم خوارزميات التبدل (Replacement Algorithms).

في الاسقاط المباشر (Direct mapping) لا يلزم أن نستخدم هذه الخوارزميات

لأنه يتم استبدال blocks الجديد بـ blocks القديم.

# Replacement Algorithms (2)

## Associative mapping

### خوارزميات الاستبدال الاسقاط الترابطي

نستخدم هذه الخوارزميات لمعرفة أي Line سيتم وضع blocks الجديد فيه وإزالة القديمة.

كل Line موجودة في cache مرشحة للاستبدال توجد عدة طرق :-

**Least Recently used (LRU) ➤**

أقل من أستخدم أخير ، أطول فترة ممكنة ولم يستخدم بعد، يتم استبداله.

**First In First Out (FIFO) ➤**

أول من يدخل هو أول من يخرج.

**Least frequently used ➤**

أقل من تكرر استخدامه، يعني أقل blocks تم اختياره في التنفيذ.

**Random ➤**

وهي الاسواء.

# Write Policy

## سياسة الكتابة

### استراتيجيات أو سياسات الكتابة على Cache

يجب التخزين في Memory و cache في نفس الوقت عند إدخال البيانات من I/O فيتم الكتابة في Memory و يتم الكتابة في cache في نفس الوقت لكي لا يحدث تعقيد ومن المهم أن يتم تحديث البيانات باستمرار في الذاكرة، يجب التأكد قبل الاستبدال أنه لا يوجد تعديلات في الذاكرة بحيث يجب أن يكون عنوان blocks و Line يحمل نفس القيمة أو العنوان.

# Write through

## الكتابة من خلال

الكتابة من خلال (Write through) ▶

يتم كتابة البيانات من I/O إلى cache و RAM وأي تحديث على البيانات في cache يتم بإرسال التحديث إلى RAM لذلك السرعة بطيئة و Traffic عالي.

# Write back

## إعادة الكتابة

### إعادة الكتابة (Write back) >

يتم كتابة البيانات من I/O إلى cache و RAM بعد انتهاء التحديث بشكل كامل في cache يتم إرسال التحديثات مرة واحدة فقط إلى RAM ، لا يسبب أي Traffic عالي.

# Block Size

## حجم الكتلة

عندما يتم استرداد كتلة من البيانات ووضعها في الذاكرة السريعة ، ليس فقط الكلمة المطلوبة يتم استردادها ولكن أيضا بعض الكلمات الملاصقة لها .

كلما زاد حجم الكتلة إلى أحجام أكبر يتم جلب مزيد من البيانات المفيدة في الذاكرة السريعة ولكن احتمال استخدام بيانات مجاورة حديثا يصبح أقل من احتمال إعادة استخدام بيانات التي لا بد من استبدالها .

هناك اعتباران يجب اخذهما في الاعتبار :

- كتل (Block) أكبر يخفض عدد الكتل (Block) التي تدرج في الذاكرة السريعة .
- كلما كبرت الكتلة (Block) أصبحت إي كلمة اضافية بعيدة عن الكلمة المطلوبة .

# Number of Caches

## عدد الذاكرة السريعة

- في البداية كان هناك مستوى واحد.
- مع تطور التقنية أصبح استخدام ذاكرة سريعة بمستويات متعددة.
- الذاكرة السريعة متعددة المستويات
- يمكن أن يكون المستوى الاول ملاصق للمعالج على الشريحة نفسها (ذاكرة سريعة داخلية).
- المستوى الثاني على اللوحة (ذاكرة سريعة خارجية).
- هناك استراتيجيتان في تصميم الذاكرة السريعة هل موحدة أم منفصلة.
- الموحدة تكون للبيانات والتعليمات معا.
- المنفصلة واحدة للتعليمات و اخرى للبيانات.