Programación masivamente paralela en procesadores gráficos (GPUs)

E. Dufrechou, M. Freire, P. Ezzatti y M. Pedemonte

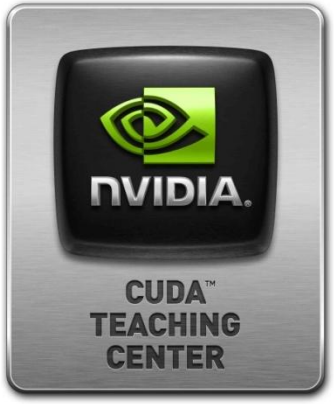

Clase 2
Computación Paralela

Contenido

- Paralelismo en máquinas secuenciales
- Máquinas paralelas
- Modelos y Estrategias para Programación Paralela
- Paralelismo de Memoria Compartida
- Paralelismo de Memoria Distribuida

Paralelismo en máquinas secuenciales

Máquina de Von Neumann

- **La arquitectura de la computadora tradicional de Von Neumann se compone de:**
  - **Una unidad funcional**
  - **Una unidad de control**
  - **Una única memoria.**

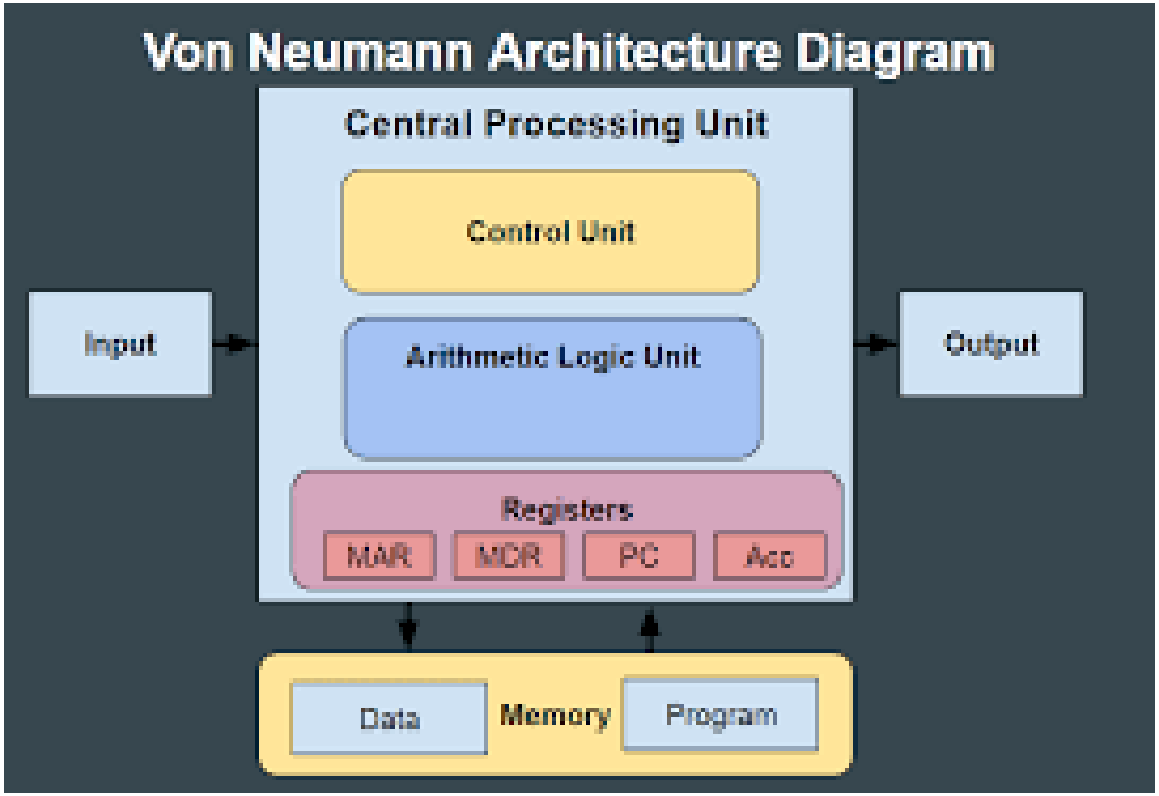

Máquina de Von Neumann

- **Realizar un cómputo implica los siguientes pasos:**
  - **Se trae una instrucción del programa desde la memoria y se decodifica.**
  - **Se calculan las direcciones de memoria de los datos requeridos.**
  - **Se traen los datos requeridos desde la memoria.**
  - **La operación es computada por la unidad funcional.**
  - **Los resultados son almacenados en la memoria.**

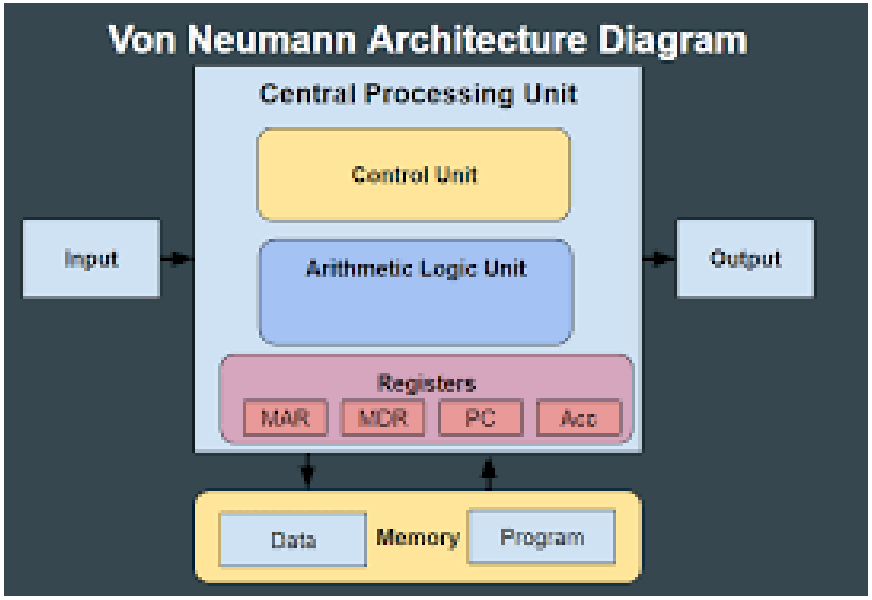

Necesidad de Paralelismo

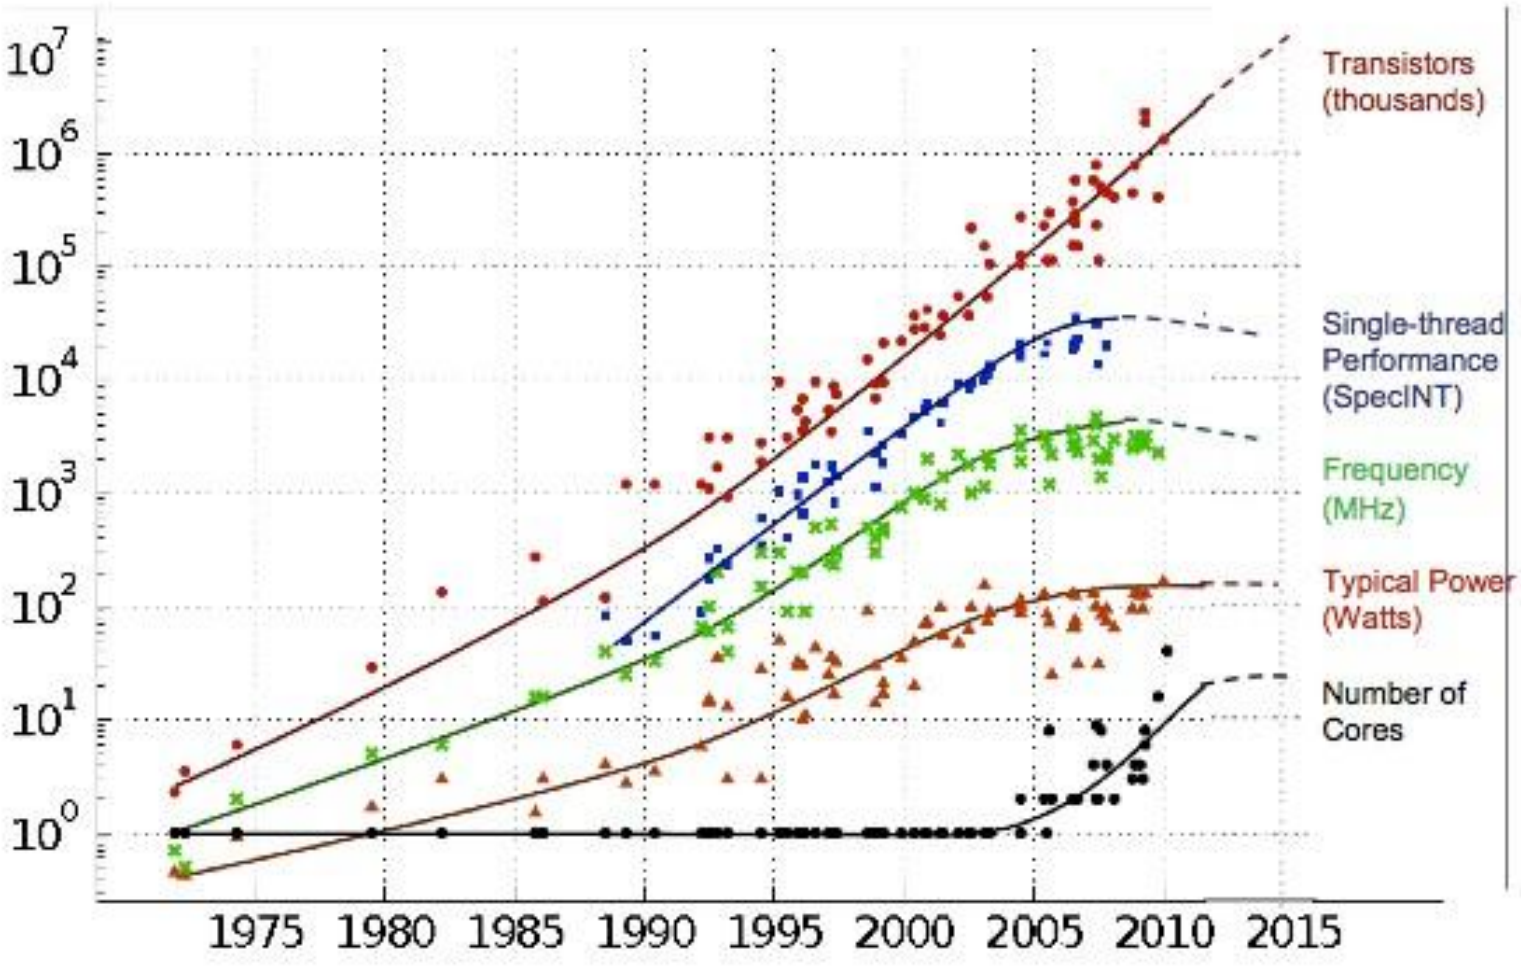

Original data collected and plotted by M. Horowitz, F. Labonte, O. Shacham, K. Olukotun, L. Hammond and C. Batten
Dotted line extrapolations by C. Moore

Necesidad de Paralelismo

- La "Ley de Moore" se sigue cumpliendo ya que el número de transistores por chip se continúa incrementando exponencialmente.
- Sin embargo, las limitaciones térmicas impiden continuar aumentando las velocidades de relojes.
- De lo contrario, los chips comenzarían a fundirse.
- ¿Cómo se puede aumentar más el rendimiento de las aplicaciones ?
  - Aumentar el número de núcleos por chip
  - Explotar el paralelismo

Paralelismo en Máquinas Secuenciales

- **Existen diversas formas de incluir paralelismo en la arquitectura de Von Neumann:**

  1) Incorporar múltiples unidades funcionales:

  - **Multi-core: Una sola unidad de cómputo compuesta por al menos dos procesadores (con sus unidades funcionales y de control independientes)**

Paralelismo en Máquinas Secuenciales

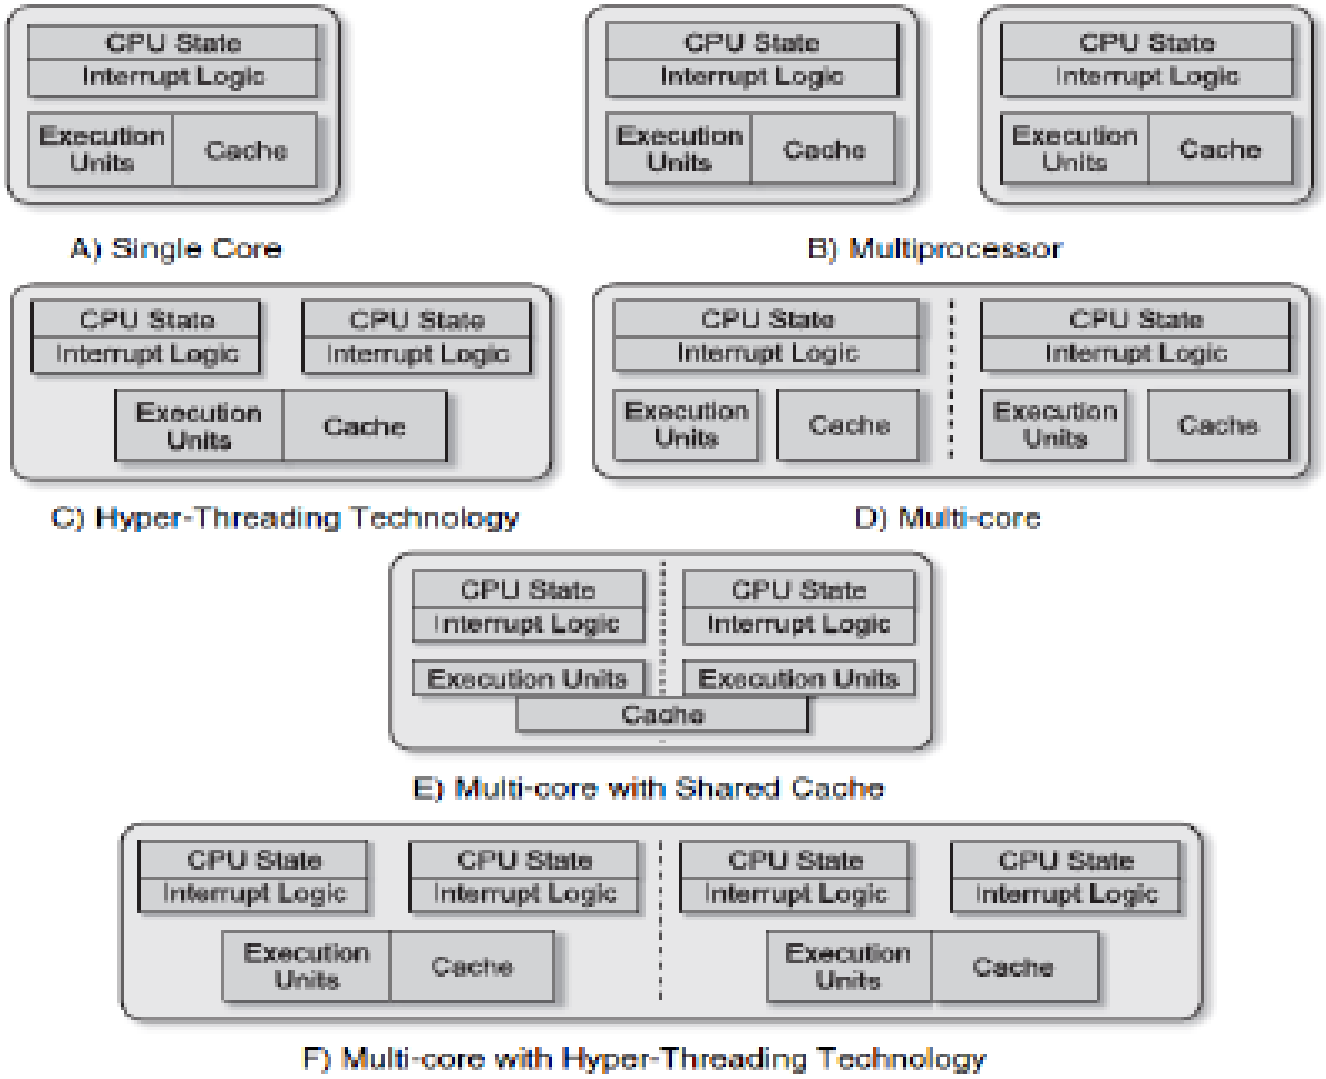

Paralelismo en Máquinas Secuenciales

- **Existen diversas formas de incluir paralelismo en la arquitectura de Von Neumann:**

  2) Pipelining:

  - **Las tareas se pueden dividir en sub-tareas, por lo que se definen sub-segmentos.**
  - **Cada sub-tarea es ejecutada en un ciclo de reloj, pero diferentes sub-tareas son ejecutadas al mismo tiempo por diferentes segmentos.**
  - **De esta forma, cuando se llena el pipeline, en cada ciclo se completa una instrucción.**

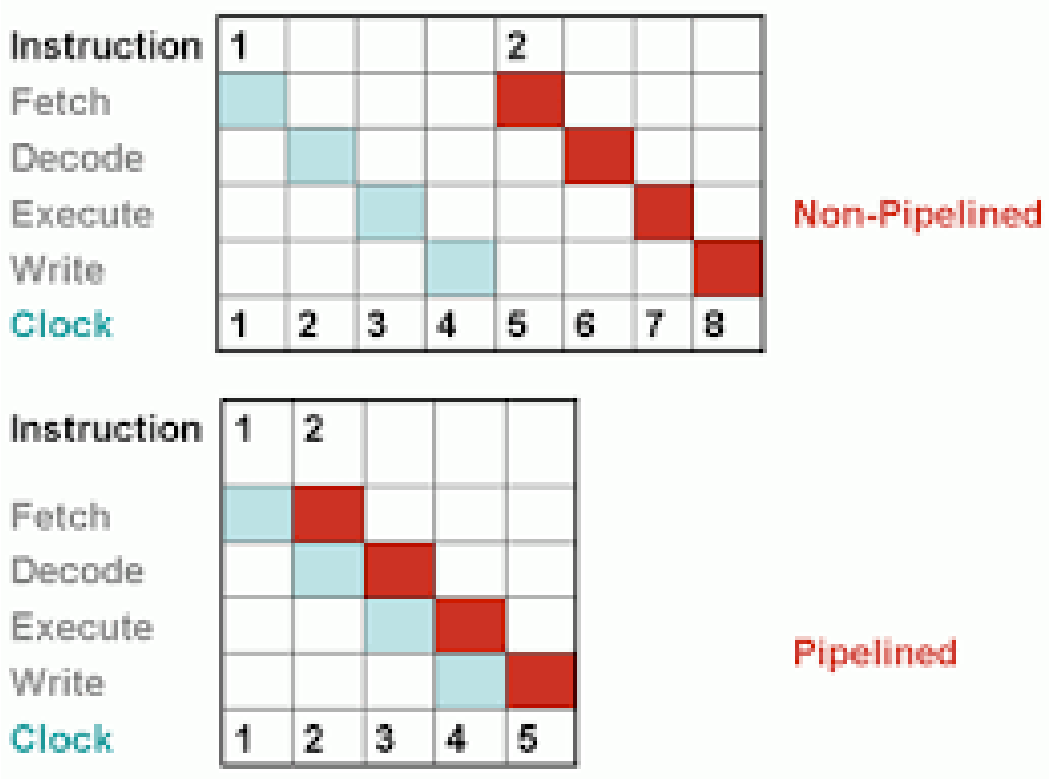

Paralelismo en Máquinas Secuenciales

- **Existen diversas formas de incluir paralelismo en la arquitectura de Von Neumann:**

  3) Instrucciones vectoriales:

  - **Se incorporan al repertorio de instrucciones operaciones que pueden operar sobre un array de datos (registros vectoriales).**
  - **Ejemplos: las operaciones MMX, SSE y AVX de Intel.**

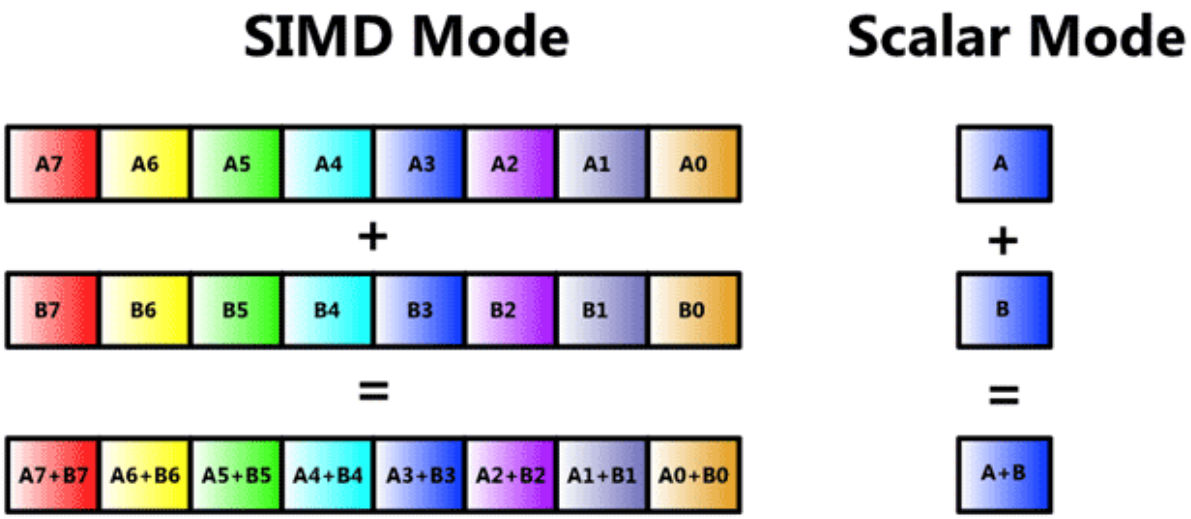

Paralelismo en Máquinas Secuenciales

- **Existen diversas formas de incluir paralelismo en la arquitectura de Von Neumann:**

  4) Paralelismo a nivel de memoria:

  - **Se refiere a la capacidad de tener múltiples operaciones de memoria pendientes al mismo tiempo.**
  - **Es decir que un procesador puede emitir varias solicitudes de memoria al mismo tiempo para cada uno de sus núcleos.**
  - **Es posible realizar múltiples lecturas a la vez, así como operaciones de lectura y escritura a la vez**
  - **La memoria está organizada jerárquicamente.**

Paralelismo en Máquinas Secuenciales

- **Jerarquía de memoria:**

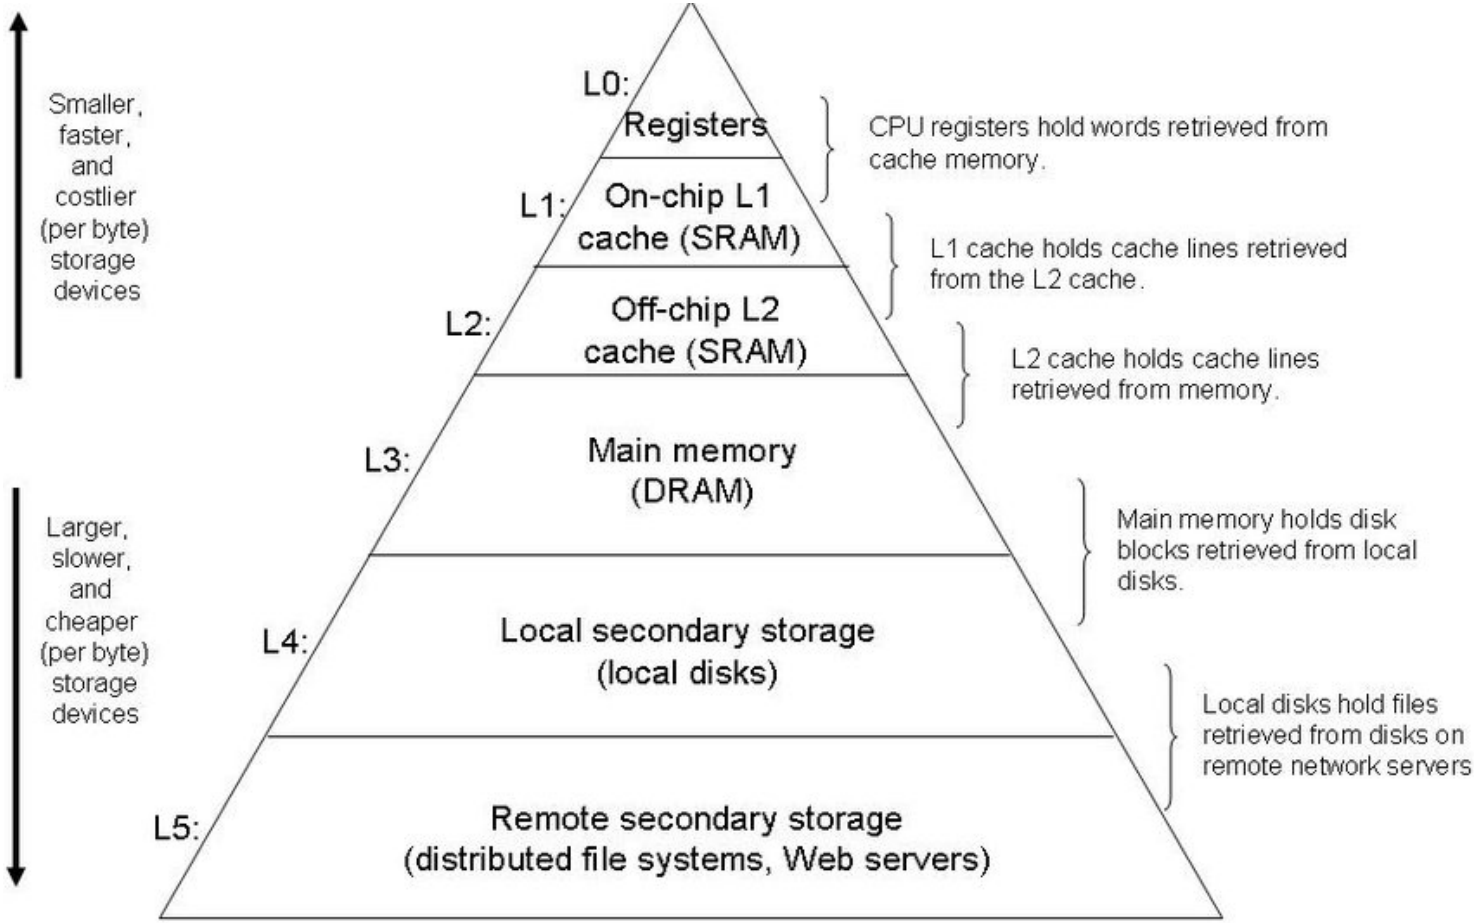

Paralelismo en Máquinas Secuenciales

- **Jerarquía de memoria:**

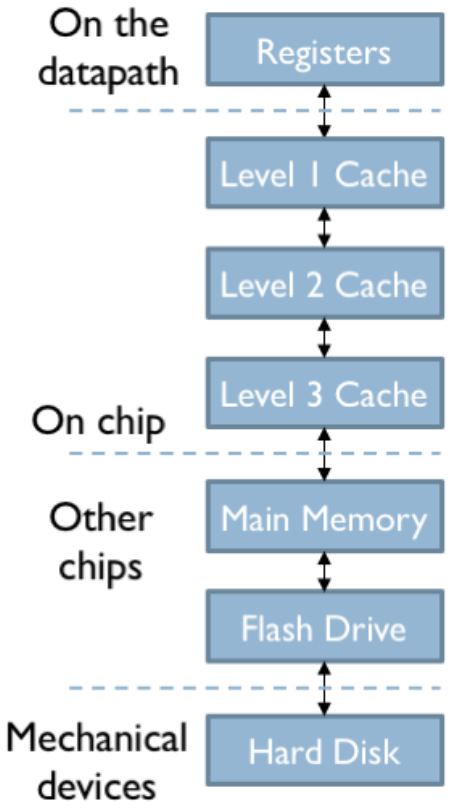

Access time	Capacity	Managed By
1 cycle	1 KB	Software/Compiler
2-4 cycles	32 KB	Hardware
10 cycles	256 KB	Hardware
40 cycles	10 MB	Hardware
200 cycles	10 GB	Software/OS
10-100us	100 GB	Software/OS
10ms	1 TB	Software/OS

Paralelismo en Máquinas Secuenciales

- **Almacenamiento en memoria:**
  - **La memoria es una secuencia de bytes:**

    1 2 3 4 5 6 7 8 9 10 11
  - **Los datos de los arreglos se almacenan en forma contigua.**
  - **Los datos de las matrices dependen del lenguaje de programación:**
    - **C almacena por fila: 1ro los datos de la fila 1, después los datos de la fila 2 y así sucesivamente.**
    - **Fortran almacena por columnas: 1ros los datos de la columna 1, después los datos de la columna 2 y así sucesivamente.**

Paralelismo en Máquinas Secuenciales

- **Almacenamiento en memoria:**

	0	1	2	3
0	8	6	5	4
1	2	1	9	7
2	3	6	4	2

Row-Major (Row Wise Arrangement)

Column-Major (Column Wise Arrangement)

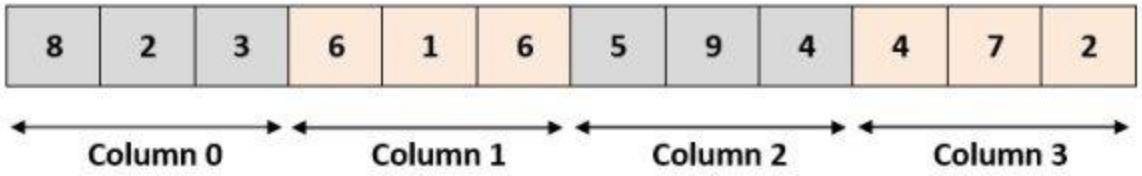

Paralelismo en Máquinas Secuenciales

- **Almacenamiento en memoria:**
  - **Por ejemplo, si se tiene una matriz de m filas y n columnas de reales (es decir que cada dato es de 4 bytes).**
  - **La posición en bytes de la celda (i,j) en la memoria es:**

Por filas – indexado desde 0: `inicio_matriz + ( (i * n) + j ) * 4`

Por filas – indexado desde 1: `inicio_matriz + (((i – 1) * n ) + (j - 1) ) * 4`

Por columnas – indexado desde 0: `inicio_matriz + ( (j * m) + i ) * 4`

Por columnas – indexado desde 1: `inicio_matriz + ((( j – 1) * m ) + (i – 1) ) * 4`

Máquinas Paralelas

Máquinas Paralelas

- La taxonomía más conocida para clasificar las arquitecturas de las computadoras fue propuesta por Flynn (1966).
- Se basa en considerar en forma independiente los flujos de instrucciones y de datos.
- A partir de ello se clasifica a las computadoras en cuatro grupos: SISD, SIMD, MISD and MIMD.

Máquinas Paralelas

- **SISD: Single Instruction flow - Single Data flow**
  - **Corresponde a la arquitectura tradicional (secuencial) de Von Neumann.**

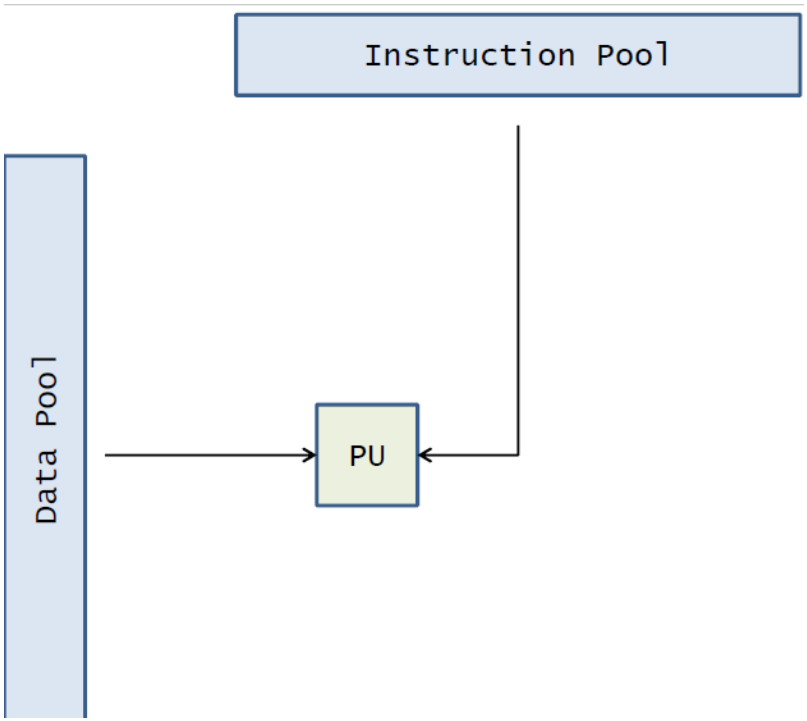

Máquinas Paralelas

- **SIMD: Single Instruction flow - Multiple Data flow**
  - **Se caracterizan por tener múltiples unidades de procesamiento que ejecutan la misma instrucción en diferentes datos en el mismo instante de tiempo.**
  - **Las unidades de procesamiento no tienen autonomía de procesamiento y son controlados centralmente.**

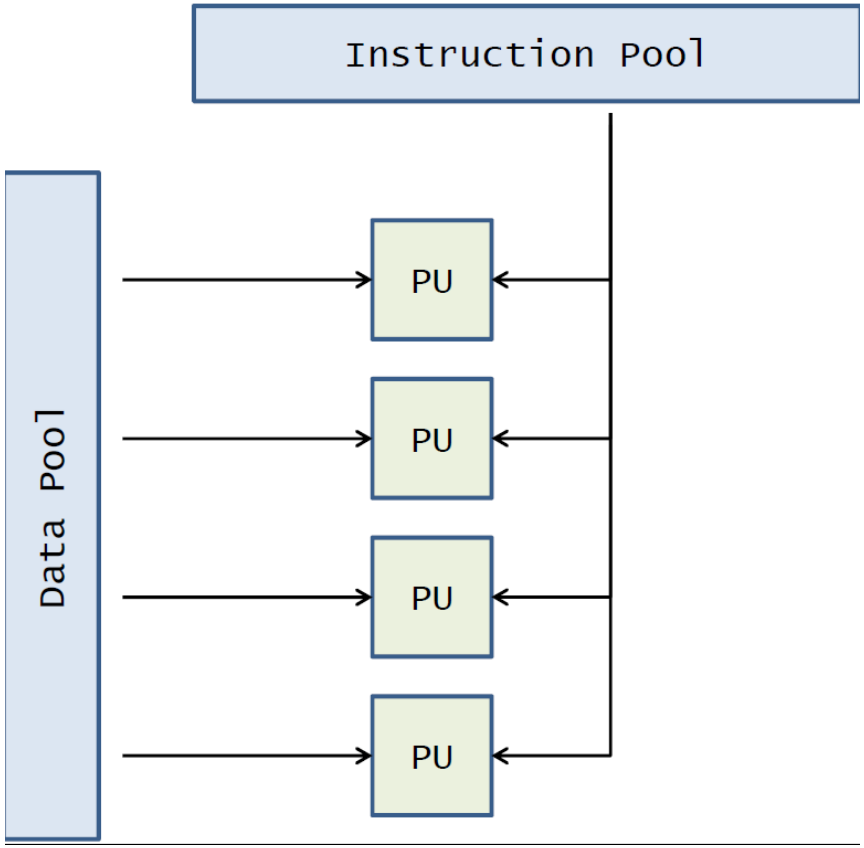

Máquinas Paralelas

- **MISD: Multiple Instruction flow - Single Data flow**

  - **Es una arquitectura muy poco común en la práctica.**
  - **Sistemas a pruebas de fallos: cada unidad de procesamiento opera con los mismos datos y los resultados obtenidos por cada unidad tienen que ser los mismos.**
  - **También los array sistólicos.**

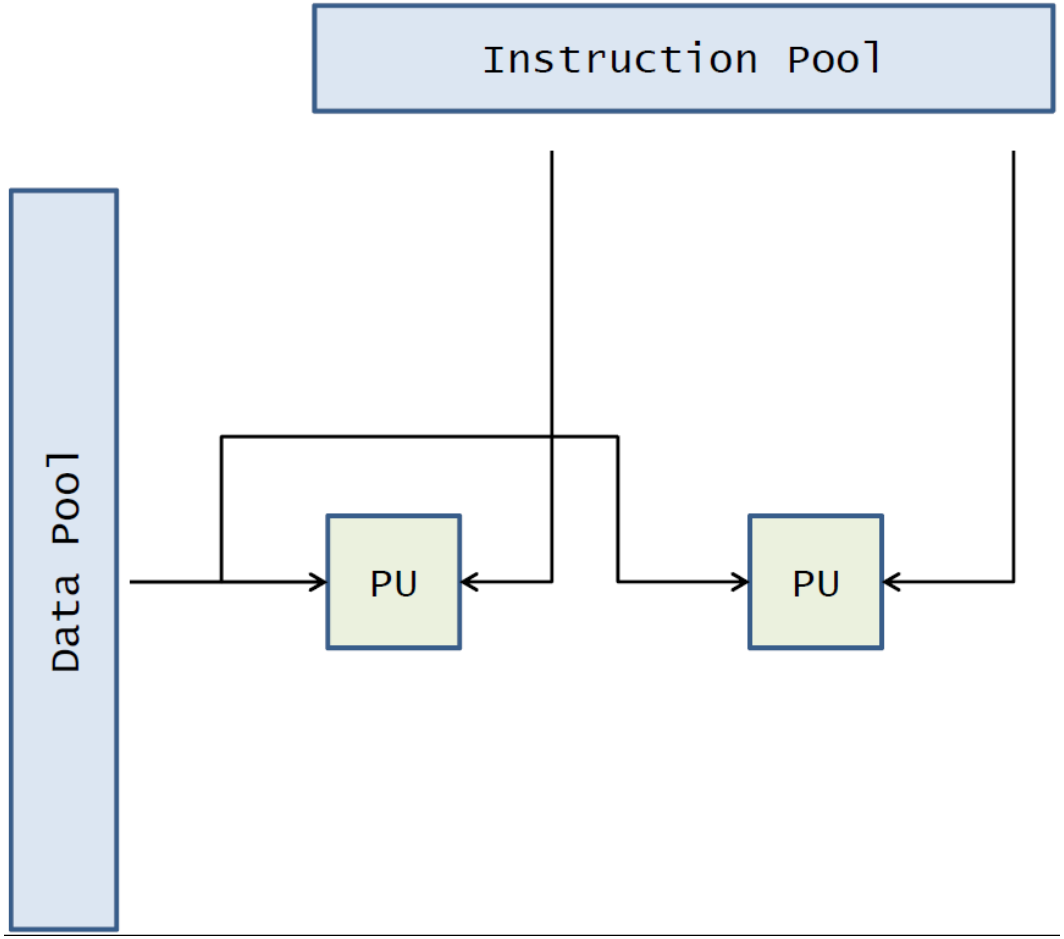

Máquinas Paralelas

- **MIMD: Multiple Instruction flow - Multiple Data flow**

  - **Varias unidades de procesamiento ejecutan diferentes instrucciones en diferentes datos.**
  - **Las unidades de procesamiento son autónomas y el control es completamente descentralizado.**
  - **Las computadoras modernas en general caen en esta categoría.**

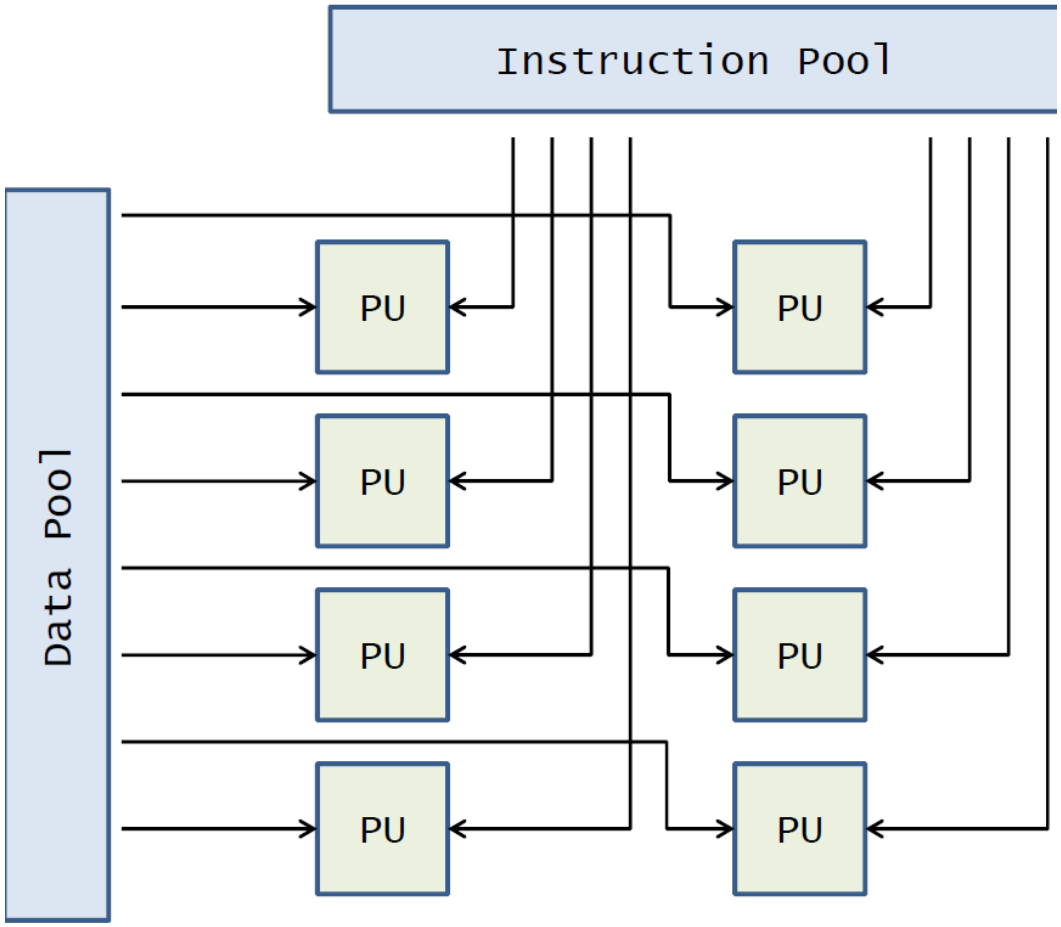

Modelos y Estrategias para Programación Paralela

Niveles de Paralelismo

- **A nivel de trabajo:**
  - **Manejado por el OS. Ej: Multiprogramming, multiprocessing**
- **A nivel de programa:**
  - **Manejado por software. Es el paralelismo a nivel de una aplicación. A su vez se puede dividir en:**
    - **fine grain tasks: por ejemplo a nivel de loops**
    - **coarse grain tasks: ejecución de partes o fracciones del código.**
- **A nivel inter-instrucción:**
  - **Realizado por el compilador.**
  - **Requiere análisis de dependencias entre instrucciones.**
- **A nivel intra-instrucción:**
  - **Realizado por el hardware. Ej: Pipelining, chaining, etc.**

Clasificación de los Programas Paralelos

- **Se puede clasificar de diferentes formas:**
  - **Granularidad:**
    - **Grano fino (fine grain) vs grano grueso (coarse grain)**
  - **Homogéneo – heterogéneo:**
    - **La misma tarea la ejecutan diversos procesadores sobre diferentes datos vs diferentes tareas.**
  - **Estrategia de paralelismo:**
    - **paralelismo de control, paralelismo de flujo, paralelismo de datos**
  - **Grado de programación:**
    - **paralelismo implícito, paralelismo explícito.**

Modelos de Programación Paralela

- **El desarrollo de programas paralelos está fuertemente condicionado por el hardware donde se ejecutará.**
- **En general se divide en dos grandes paradigmas:**
  - **Memoria compartida**
  - **Este modelo requiere memoria de acceso común a todas las unidades de procesamiento y herramientas para sincronización.**
  - **Un ejemplo es la programación multi-hilo.**
  - **Memoria distribuida (pasaje de mensajes)**
  - **Típicamente computadoras con acceso local a memoria (MPP, clusters, sistemas distribuidos, etc).**
  - **En cada procesador ejecuta un programa con sus propios datos y la comunicación y coordinación entre los procesos se realiza mediante mensajes.**

Descomposición de Problemas

- **Para realizar implementaciones paralelas se sigue la estrategia de *divide and conquer* para definir sub-problemas más sencillos**
- **La división puede ser:**
  - **Descomposición funcional**
    - **Si la resolución del problema requiere la aplicación de diferentes funcionales independientes.**
    - **Cada procesador ejecuta una función diferente.**
  - **Descomposición de dominio**
    - **Se aplica cuando el problema implique un domino donde se pueden dividir cómputos independientes.**
    - **Cada procesador ejecuta la misma función sobre un distinto conjunto de datos.**

Aspectos de la Descomposición de Problemas

- **Cuando hay múltiples unidades de cómputo trabajando en forma coordinada se debe tener en cuenta:**
  - **Comunicación**
  - **Sincronización**
- **Para tener un buen desempeño computacional resultan fundamentales:**
  - **El scheduling de las tareas**
  - **La distribución de datos/cálculos**
  - **El control de sincronizaciones**
- **Si bien parece obvio, además de buen desempeño es necesario correctitud.**
- **Sin embargo, este aspecto es más complejo de comprobar que en programas secuenciales.**

Aspectos de la Descomposición de Problemas

- **Existen diversos criterios para optimizar la partición del cómputo:**
  - **Balance de carga: distribuir equitativamente los cómputos.**
  - **Minimizar las comunicaciones/sincronizaciones**
  - **Minimizar el ancho de banda utilizado**
  - **Minimizar la cantidad de nodos con los que me comunico**
  - **Etc.**
- **Mapeo:**
  - **¿Cómo relacionar las unidades de cómputo con los cómputos a realizar?**
  - **Son importantes aspectos como "cercanía" de unidades y localidad de datos (especialmente importante en arquitecturas multi-core).**

Paralelismo de Memoria Compartida

Paralelismo de Memoria Compartida

- Todas las comunicaciones y sincronizaciones se realizan a través del recurso común (memoria).
- Es necesario sincronizar el acceso y garantizar la exclusión mutua de secciones compartidas.
- Paralelismo multithreading
- Bibliotecas estándares (e.g., en lenguaje C).
- Bibliotecas específicas.
- Ejemplos:
  - Hilos
  - OpenMP

Hilos

- **A partir de la existencia de sistemas multiprocesadores (en los años 90), surgieron sistemas operativos que permitían a un proceso del sistema manejar más de un hilo de ejecución (a través del uso de más de un contador de programa).**
- **De esta forma, se permite que un proceso ejecute en más de un procesador en forma simultánea, logrando paralelismo dentro del proceso.**

Hilos

- **Los hilos de un mismo proceso ejecutan sobre un mismo espacio de direccionamiento.**
- **Con el surgimiento de hardware multi-core de los últimos años, la utilización de múltiples hilos de ejecución en un mismo proceso reflotó.**

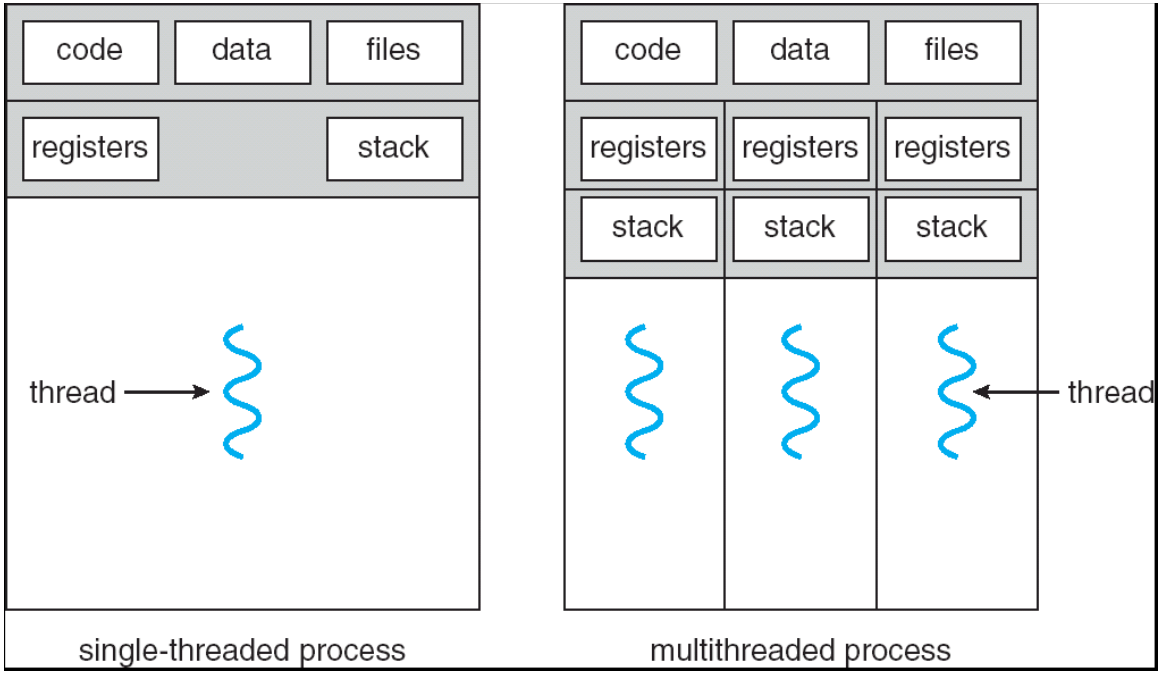

Hilos

- Los sistemas operativos modernos brindan una interfaz de programación que permite la utilización de varios hilos de ejecución dentro de un mismo proceso.
- Brindan herramientas básicas para el manejo de hilos: creación, destrucción y sincronización.
- La programación con hilos permite tener un mayor control sobre el paralelismo, pero requiere que el paralelismo sea implementado (o declarado) por el programador.
- Por lo tanto, requiere de un mayor conocimiento y dedicación que otras herramientas de programación de alto nivel.

Hilos

- **A diferencia de otros paradigmas, la programación con hilos no necesita herramientas de intercambio de información, ya sea a través de mensajes o primitivas a nivel del sistema operativo, ya que los procesos comparten el espacio de direccionamiento.**
- **Esto permite una mayor eficiencia frente a la programación con procesos que no comparten el espacio de direccionamiento.**
- **La gran desventaja del uso exclusivo de esta programación es que no escalan más allá de una máquina. Para esto se deben utilizar otros paradigmas de la programación paralela distribuida.**

OpenMP

- **Es una API que permite aplicar paralelismo sobre memoria compartida utilizando multi-threads.**
- **Portable: C/C++ y Fortran, multiplataforma**
- **Utiliza directivas para el compilador:**
  - **Se pierde en eficiencia y flexibilidad.**
  - **Se gana en portabilidad.**

OpenMP

- **Modelo de Ejecución paralela: fork-join:**
  - **Un programa comienza su ejecución con un proceso único (hilo maestro)**
  - **Cuando se encuentra la primera construcción paralela (directiva) crea un conjunto de hilo**
  - **El trabajo se reparte entre todos los hilos incluido el maestro**
  - **Cuando termina la región paralela solo el hilo maestro continua la ejecución.**

OpenMP

- **Modelo de Ejecución:**
  - **Los hilos se comunican a través de variables compartidas.**
  - **Compartir datos puede llevar a un mal comportamiento del programa debido al acceso simultáneo.**
  - **Para evitarlo se utilizan directivas de sincronización que protegen los datos de conflictos.**
  - **Las sincronizaciones son costosas, por lo que hay que tratar de evitarlas.**
  - **Las directivas se aplican a bloques estructurados**

Paralelismo de Memoria Distribuida

Paralelismo de Memoria Distribuida

- En general se utiliza Message Passing Interface (MPI).
- Utiliza el paradigma de mailbox y se basa en el pasaje de mensajes.
- MPI es un estándar que funciona en una amplia variedad de arquitecturas de computación paralela.
- El estándar define la sintaxis y la semántica de un conjunto de rutinas que permiten escriben programas basados en pasaje de mensajes.
- Se usa un lenguaje secuencial estándar: Fortran, C, (F90, C++)...
- Cada proceso es un programa secuencial por separado.
- Todos los datos son privados a los procesos.
- MPI es SPMD (Single Program Multiple Data).