Sistemas Operativos: Introducción y Conceptos Fundamentales

Este curso analiza los principios, diseño e implementación de los sistemas operativos, esenciales para gestionar el hardware y ejecutar aplicaciones. Los estudiantes comprenderán su arquitectura, componentes y funciones, incluyendo gestión de procesos, memoria, almacenamiento y entrada/salida.

¿Qué es un Sistema Operativo?

Definición Básica

Un sistema operativo (SO) es un **conjunto de programas de software que gestionan los recursos de hardware de una computadora** y proporcionan servicios comunes a las aplicaciones de software.

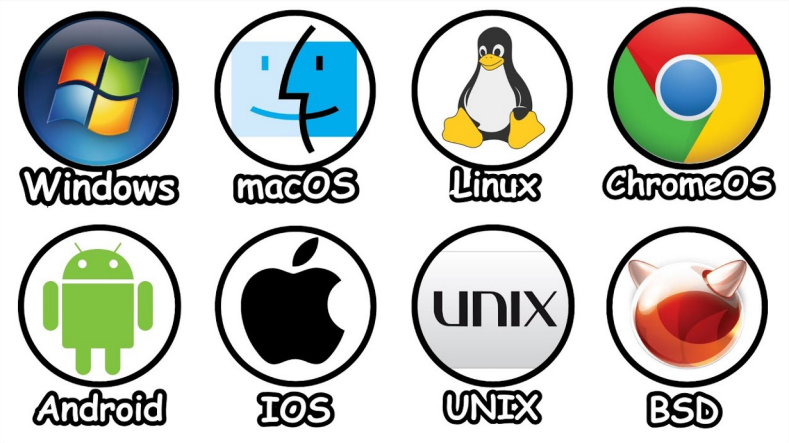

Intermediario

Actúa como **intermediario entre el usuario y el hardware**: El SO crea una **interfaz más conveniente y eficiente** para que los usuarios interactúen con el hardware de la computadora y para que las aplicaciones utilicen estos recursos.

Sin un SO, las aplicaciones tendrían que interactuar directamente con el complejo hardware, lo cual sería una tarea ardua y propensa a errores.

Temario del Curso

Introducción
- Repaso de la arquitectura de computadoras.
- Concepto e historia de los sistemas operativos.
- Objetivos, funciones y evolución de los sistemas operativos.

Procesos
- Procesos: descripción y control.
- Hilos.
- Comunicación entre procesos.
- Sincronización entre procesos.
- Transacciones atómicas.
- *Scheduling* (planificación).

Administración de memoria
- Asignación dinámica de memoria.
- Memoria principal.
- Memoria virtual.
- Memoria de usuario.
- Memoria de kernel.

Almacenamiento masivo
- Servidor de sistema de archivos.
- Servicios del sistema operativo para almacenamiento.
- Sistemas de archivos UNIX y Windows.

Drivers
- Espacio de usuario vs espacio kernel.
- Tipos de drivers: carácter, bloque y red.
- Estructura básica de un módulo del kernel.
- Carga y gestión de drivers (insmod, modprobe).
- Interacción con el hardware: interrupciones y acceso a memoria (MMIO/DMA).
- Interfaces de comunicación con usuario (/dev, sysfs, procfs).
- Depuración básica de drivers (dmesg, registros del kernel).
- Caso práctico: desarrollo de un driver de carácter simple.

Arquitectura de Computadoras: Una Revisión

Importancia para los SO

El diseño y la funcionalidad de un sistema operativo están **íntimamente ligados a la arquitectura de la computadora** que gestiona. Comprender cómo interactúan el procesador, la memoria y los dispositivos de E/S es fundamental para entender las decisiones de diseño y los mecanismos implementados en los SO.

Componentes Básicos

Los componentes fundamentales de una computadora son la **Unidad Central de Procesamiento (CPU) o procesador, la memoria principal y los dispositivos de Entrada/Salida (E/S)**. El sistema operativo es responsable de coordinar y gestionar estos componentes para la ejecución de programas.

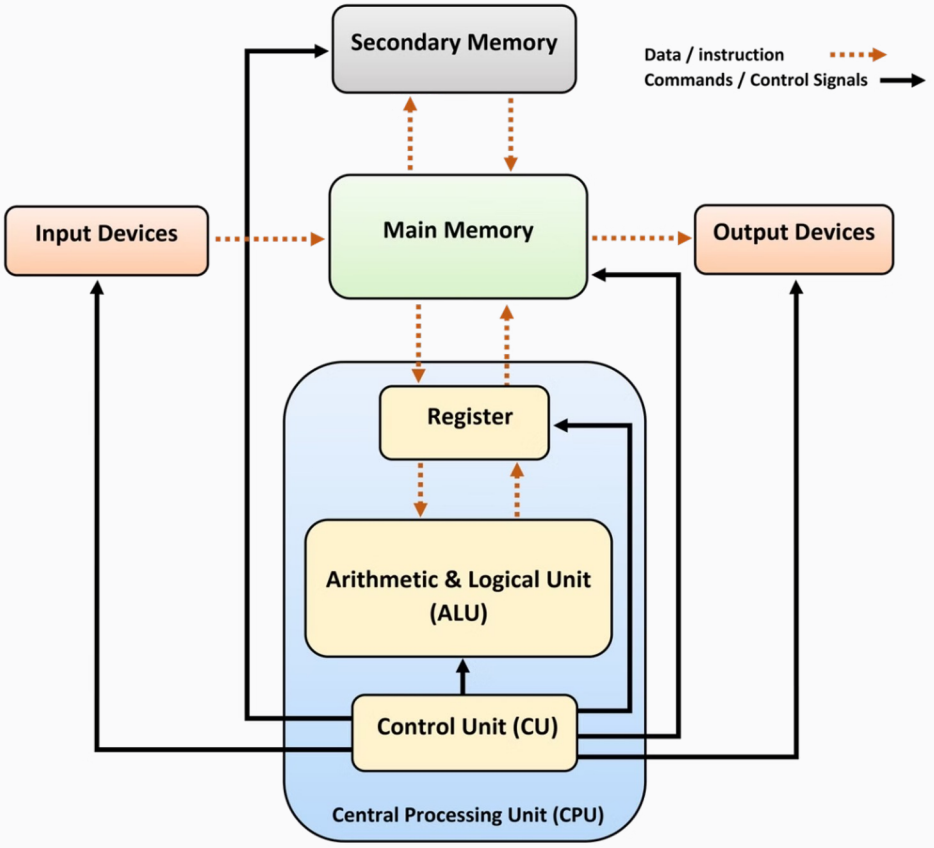

Image By Amila Ruwan 20

Arquitectura de Computadoras - Procesador y Memoria

Procesador (CPU)

La CPU es el **cerebro de la computadora**, responsable de ejecutar las instrucciones de los programas. Está compuesta por la unidad de control, la unidad aritmético-lógica (ALU), registros y caché.

La **unidad de control** dirige la secuencia de operaciones

La **ALU** realiza cálculos

Los **registros** almacenan datos temporales

La **caché** acelera el acceso a la memoria

Memoria Principal

También conocida como **RAM (Random Access Memory)**, es el almacenamiento de acceso rápido donde se cargan los **datos y las instrucciones de los programas que se están ejecutando**.

La RAM permite el acceso directo a cualquier ubicación de memoria, lo que es crucial para la eficiencia en la ejecución de programas. Es importante destacar que la RAM es **volátil**, lo que significa que su contenido se pierde cuando la computadora se apaga.

Evolución del Procesador

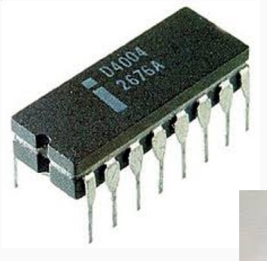

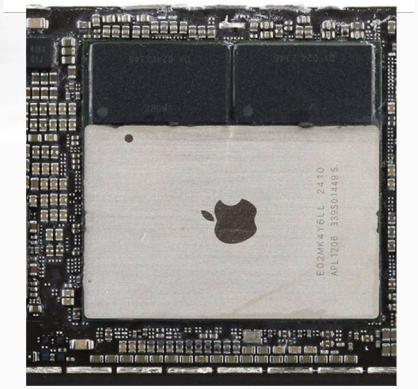

- 1971 - Intel 4004: Primer microprocesador comercial, con 4 bits y 2,300 transistores.
- 1974 - Intel 8080: Base de las primeras computadoras personales, con arquitectura de 8 bits.
- 1978 - Intel 8086: Introducción de la arquitectura x86, base de los procesadores modernos.
- 1985 - Intel 80386: Primer procesador de 32 bits, con capacidad de multitarea avanzada.
- 1993 - Intel Pentium: Mejoras en rendimiento con arquitectura superscalar.
- 2000 - AMD Athlon 64: Primer procesador de 64 bits para consumidores.
- 2006 - Intel Core 2 Duo: Popularización de la arquitectura multinúcleo.
- 2011 - Intel Sandy Bridge: Integración de gráficos en el procesador.
- 2017 - AMD Ryzen: Revolución en el mercado con múltiples núcleos y alta eficiencia.
- 2020 - Apple M1: Transición a arquitectura ARM en computadoras de alto rendimiento.

Capacidades Actuales de los Procesadores

Apple M4:

- Proceso de fabricación: 3 nanómetros de segunda generación
- Núcleos: Hasta 10 (combinación de núcleos de alto rendimiento y eficiencia)
- Memoria unificada: Hasta 16 GB
- Neural Engine: Capaz de realizar hasta 38 billones de operaciones por segundo

Intel Core Ultra 9 285K:

- Proceso de fabricación: 3 nanómetros
- Núcleos: 24 (8 de rendimiento y 16 de eficiencia)
- Frecuencia base: 3.7 GHz
- Frecuencia turbo: Hasta 5.5 GHz
- Memoria soportada: DDR5-6400, hasta 192 GB
- Consumo de energía (TDP): 125 W

AMD Ryzen 9 7950X:

- Proceso de fabricación: 5 nanómetros
- Núcleos: 16
- Frecuencia base: 4.5 GHz
- Frecuencia turbo: Hasta 5.7 GHz
- Memoria soportada: DDR5, hasta 128 GB
- Consumo de energía (TDP): 170 W
- Estas especificaciones reflejan las capacidades avanzadas de cada procesador en sus respectivas plataformas.

Arquitecturas de Computadores

Arquitecturas Mononúcleo vs. Multinúcleo

- Aunque las arquitecturas mononúcleo (con un solo núcleo de procesamiento) todavía existen, la mayoría de los sistemas modernos, desde computadoras personales hasta servidores y dispositivos móviles, utilizan arquitecturas multinúcleo.
- Los procesadores multinúcleo ofrecen un mayor rendimiento para cargas de trabajo paralelas y multitarea.

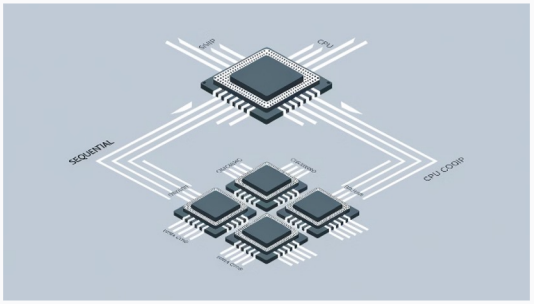

Arquitecturas RISC vs. CISC

- Históricamente, las arquitecturas de procesadores se dividieron en RISC y CISC.
- RISC (Reduced Instruction Set Computing) utiliza un conjunto de instrucciones más pequeño y simple, lo que facilita una ejecución más rápida.
- CISC (Complex Instruction Set Computing), por otro lado, utiliza un conjunto de instrucciones más grande y complejo.
- Si bien la distinción se ha difuminado con el tiempo, muchas arquitecturas modernas incorporan principios de ambas.

Ejecución de Instrucciones - Proceso Básico

Fetch (Obtención)

Obtención de la siguiente instrucción de la memoria

Decode (Decodificación)

Decodificación de la instrucción para determinar qué operación se debe realizar

Execute (Ejecución)

Ejecución de la operación especificada

El procesador contiene una **unidad de control** que coordina las diferentes etapas del ciclo de instrucción, así como una **unidad aritmético-lógica (ALU)** que realiza las operaciones aritméticas y lógicas especificadas por las instrucciones. El procesador utiliza registros internos para almacenar operandos y resultados temporales durante la ejecución.

Ejecución de Instrucciones - Tipos de Instrucciones

Instrucciones de Transferencia de Datos

Estas instrucciones mueven datos entre diferentes ubicaciones de memoria (incluyendo registros, caché y RAM) y entre la memoria y los dispositivos de E/S.
Ejemplos incluyen **LOAD** (cargar un valor de la memoria a un registro)
STORE (almacenar un valor de un registro en la memoria)

Instrucciones Aritmético-Lógicas

Estas instrucciones realizan operaciones aritméticas y lógicas en los datos.
Aritméticas: **ADD**, **SUBTRACT**, **MULTIPLY**, **DIVIDE**
Lógicas: **AND**, **OR**, **NOT**

Instrucciones de Control de Flujo

Estas instrucciones alteran la secuencia normal de ejecución de las instrucciones, permitiendo la implementación de estructuras de control.
Saltos (**JUMP**)
Bifurcaciones condicionales (**BRANCH**)
Llamadas a subrutinas (**CALL**)

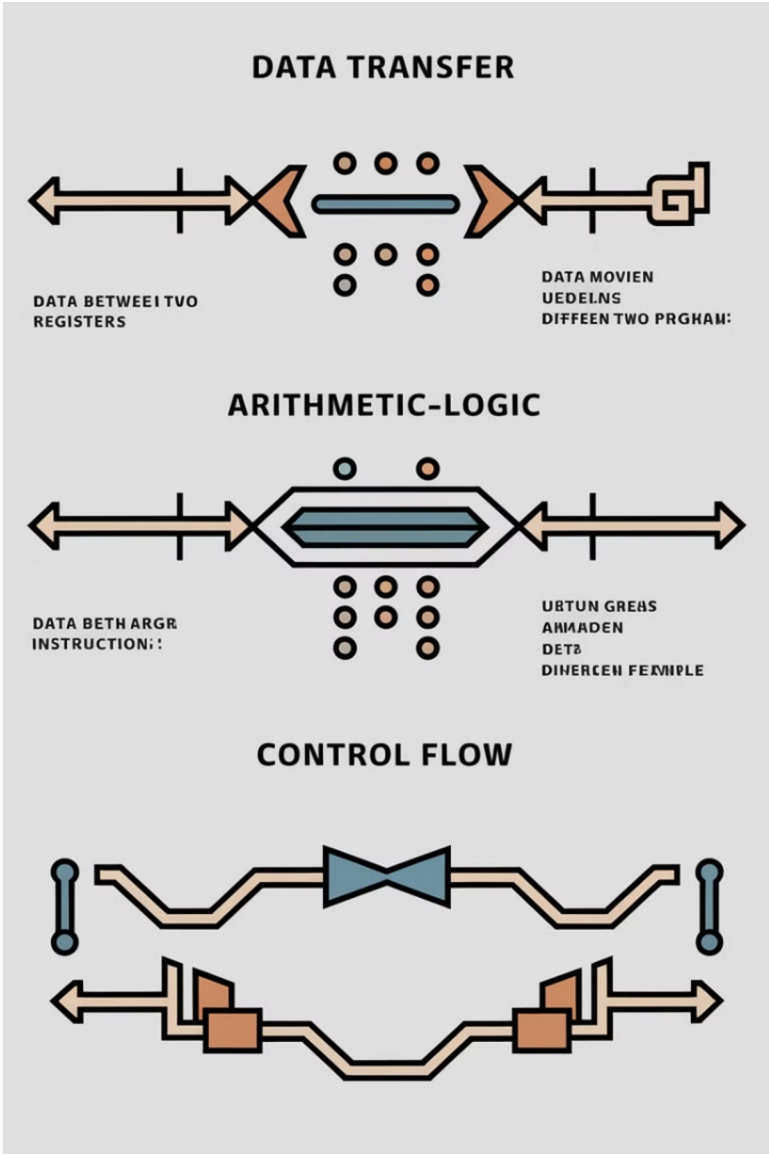

Jerarquía de Memoria - Introducción

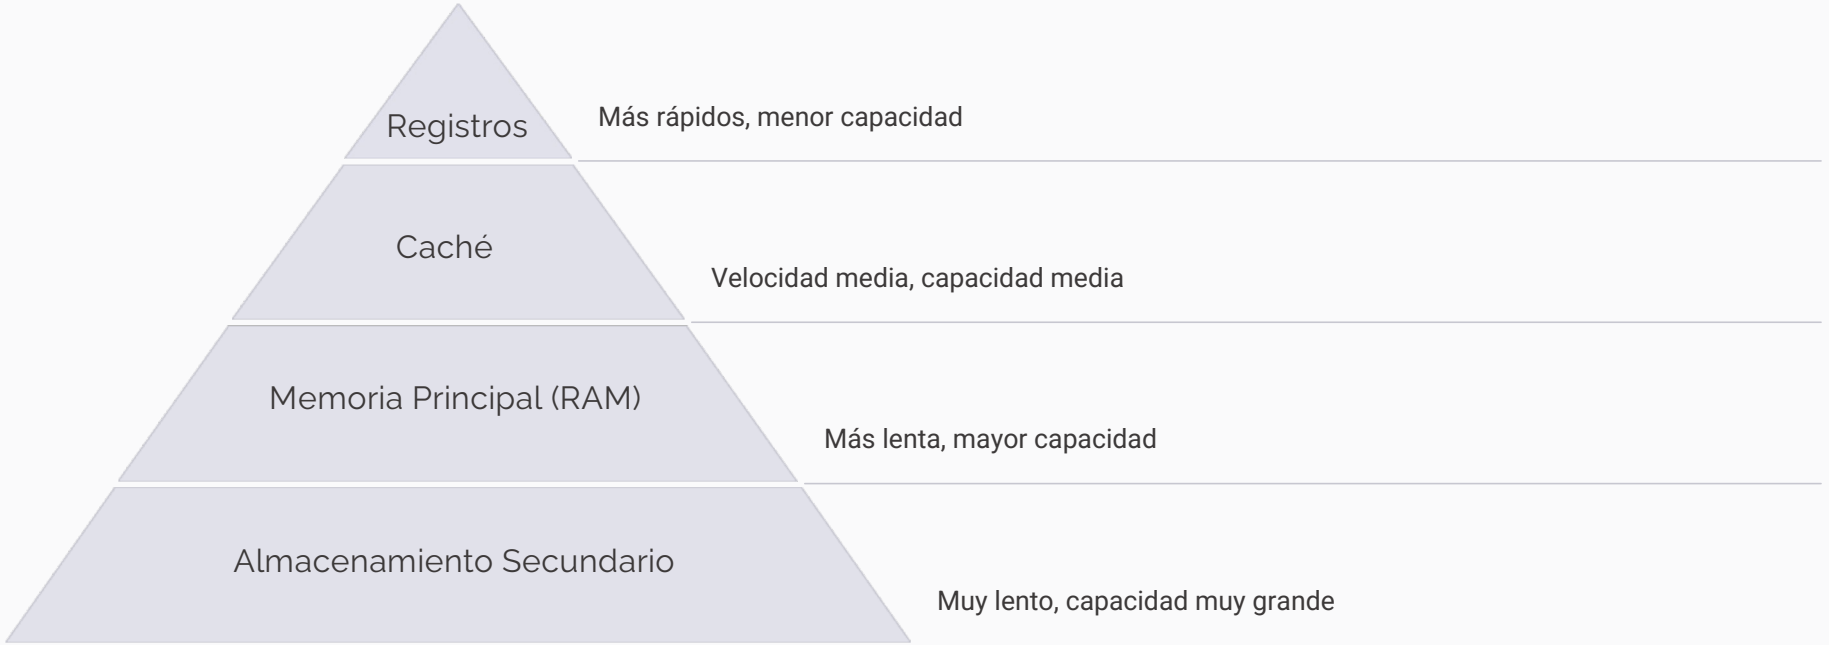

La jerarquía de memoria organiza los diferentes tipos de almacenamiento en niveles según su velocidad, costo por bit y capacidad. Los registros dentro del CPU constituyen el nivel más rápido y pequeño. Le siguen la memoria caché (con múltiples niveles) y la memoria principal (RAM), que ofrecen un equilibrio entre velocidad y capacidad. Finalmente, el almacenamiento secundario, como discos duros o SSDs, proporciona mayor capacidad a menor costo y velocidad. Esta estructura permite a los sistemas optimizar el rendimiento y la eficiencia en la gestión de datos.

Memoria Caché - Concepto

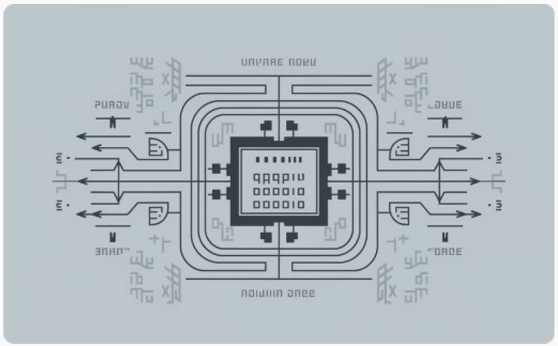

Buffer de Alta Velocidad

La caché actúa como un **buffer de alta velocidad** para la memoria principal, aprovechando el principio de **localidad** (la tendencia de los programas a acceder a un conjunto limitado de ubicaciones de memoria durante un período de tiempo).

Almacenamiento de Copias

Almacena **copias de datos** de la memoria principal que se utilizan con frecuencia. Cuando el CPU necesita acceder a un dato, primero verifica si una **copia del mismo está presente en la caché**.

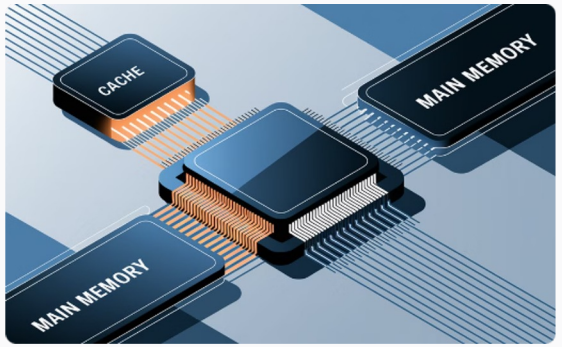

Reducción de Latencia

Objetivo: **reducir la latencia de acceso a la memoria**. Al proporcionar acceso más rápido a los datos utilizados con frecuencia, la caché **disminuye el tiempo promedio que tarda el CPU en acceder a la memoria**, lo que mejora significativamente el rendimiento general del sistema.

Memoria Caché - Funcionamiento Básico

Golpe de Caché (Cache Hit)

Cuando el CPU solicita un dato y lo encuentra en la caché, se produce un **golpe de caché**. El dato se entrega al CPU **rápidamente** desde la caché, sin necesidad de acceder a la memoria principal.
La **tasa de hits** (la proporción de accesos a memoria que son hits de caché) es un factor clave en el rendimiento del sistema.

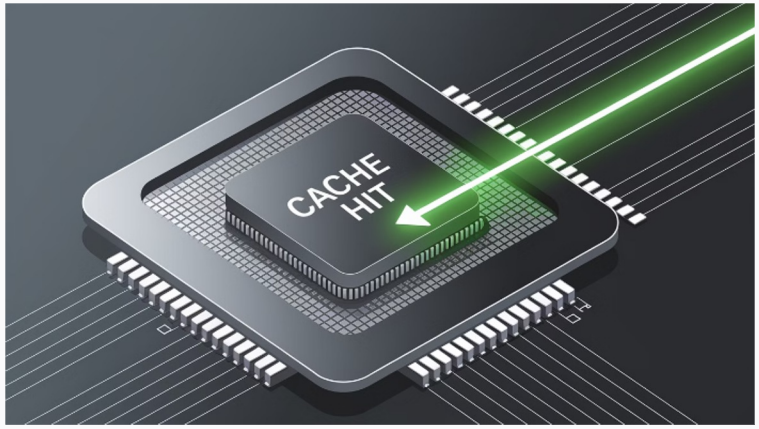

Fallo de Caché (Cache Miss)

Si el dato solicitado por el CPU no se encuentra en la caché, se produce un **fallo de caché**. En este caso, el CPU debe **acceder a la memoria principal** para obtener el dato, lo que implica una **latencia mucho mayor**.
Una vez que el dato se recupera de la RAM, se suele almacenar una copia en la caché para futuros accesos, basándose en las políticas de reemplazo.

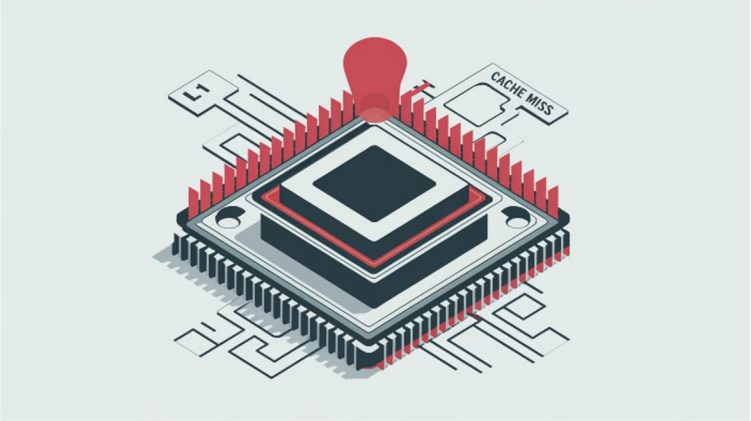

Memoria Caché - Organización (Mapeo)

Mapeo Directo

En el mapeo directo, cada bloque de la memoria principal solo se puede mapear a una **única línea específica de la caché**.

Es la organización más simple pero puede sufrir de **conflictos** si se accede repetidamente a bloques de memoria que se mapean a la misma línea de caché.

Mapeo Asociativo

En el mapeo asociativo, un bloque de la memoria principal se puede mapear a **cualquier línea de la caché**.

Esto ofrece mayor flexibilidad y reduce los conflictos, pero la lógica de búsqueda en la caché es más compleja y costosa.

Mapeo Asociativo por Conjuntos

Este es un enfoque intermedio que divide la caché en un número fijo de **conjuntos**, y cada bloque de la memoria principal solo se puede mapear a una línea dentro de un **conjunto específico**.

Dentro de un conjunto, el mapeo es asociativo, ofreciendo un buen compromiso entre flexibilidad y complejidad. La caché se organiza como un número de conjuntos, cada uno conteniendo un número fijo de líneas. Un bloque de memoria principal se mapea a un conjunto específico basándose en una función de su dirección de memoria. Dentro del conjunto, el bloque se puede colocar en cualquier línea libre.

Memoria Caché - Políticas

Políticas de Reemplazo

Cuando una caché está llena y necesita almacenar un nuevo bloque, es necesario reemplazar uno de los bloques existentes. Las políticas de reemplazo determinan **qué bloque se debe desalojar**.

LRU (Least Recently Used): reemplaza el bloque que no se ha utilizado durante más tiempo

FIFO (First-In, First-Out): reemplaza el bloque que se cargó primero

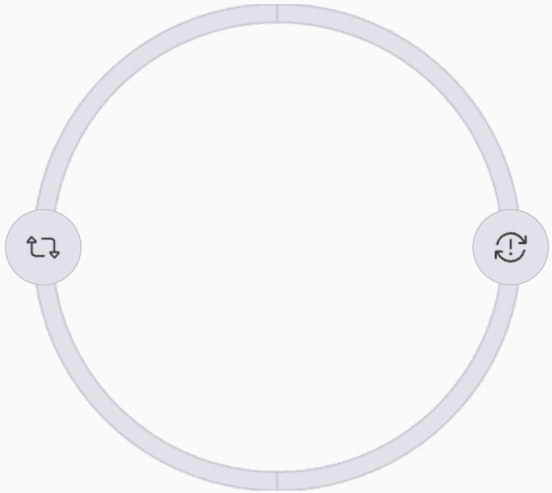

Políticas de Escritura

Cuando el CPU escribe datos en una ubicación de memoria que también está presente en la caché, es necesario mantener la coherencia entre la caché y la memoria principal. La política de escritura determina **cuándo y cómo se actualiza la memoria principal**.

Write-Through: cada escritura a la caché también se escribe inmediatamente en la memoria principal

Write-Back: las escrituras solo se realizan en la caché y la memoria principal se actualiza solo cuando el bloque modificado se reemplaza de la caché

Memoria de Acceso Directo (RAM) - Concepto

Memoria Principal del Computador

La RAM es la **memoria de trabajo** del computador, donde se almacenan temporalmente los datos y las instrucciones que los programas necesitan durante su ejecución. Su tamaño influye directamente en la cantidad de programas y datos que pueden estar activos simultáneamente.

Acceso Aleatorio

Una característica fundamental de la RAM es que permite el **acceso aleatorio** a cualquier ubicación de memoria. Esto significa que el tiempo necesario para acceder a cualquier dato en la RAM es constante, independientemente de su ubicación física.

Volátil

A diferencia del almacenamiento secundario, la RAM es **volátil**. Esto significa que los datos almacenados en la RAM se pierden cuando se interrumpe el suministro de energía a la computadora (es decir, al apagarla). Por lo tanto, es necesario el almacenamiento secundario para guardar los datos de forma permanente.

Memoria de Acceso Directo (RAM) - Tipos

DRAM (Dynamic RAM): La DRAM es el tipo más común de RAM utilizado en las computadoras personales. Almacena cada bit de datos en un condensador dentro de una celda de memoria, que necesita ser **recargado (refrescado)** periódicamente para mantener los datos. Es relativamente barata y ofrece alta densidad de almacenamiento.

SRAM (Static RAM): La SRAM utiliza flip-flops para almacenar cada bit de datos y **no necesita ser refrescada**. Es significativamente **más rápida y costosa** que la DRAM y se utiliza principalmente para la memoria caché debido a su velocidad.

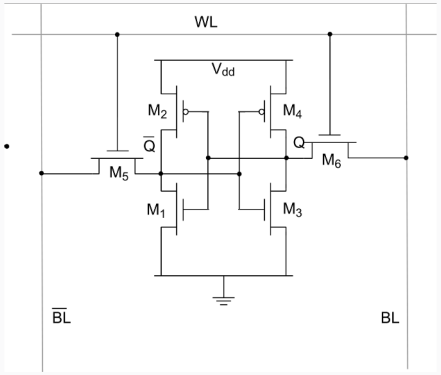

Evolución: A lo largo del tiempo, la tecnología DRAM ha evolucionado significativamente, dando lugar a diferentes generaciones como **DDR (Double Data Rate), DDR2, DDR3, DDR4 y la más reciente DDR5**. Cada nueva generación ofrece mayores velocidades de transferencia de datos y menor consumo de energía.

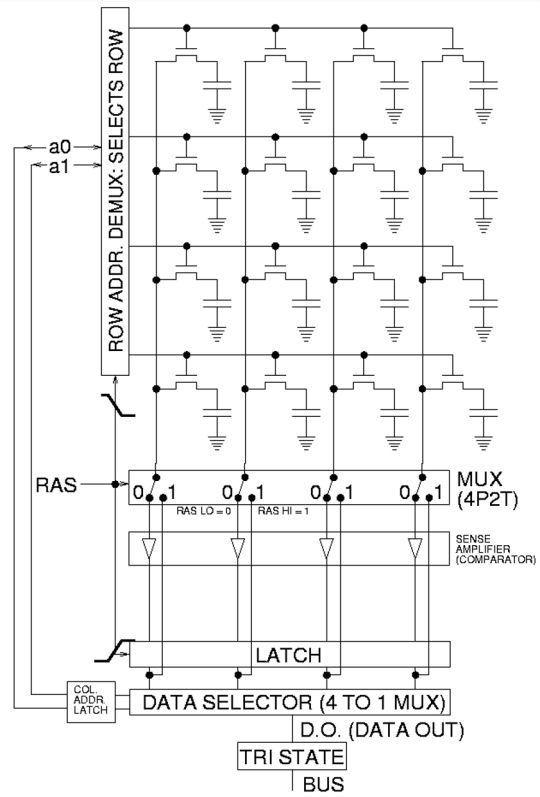

Memoria de Acceso Directo (RAM) - Funcionamiento

Gestión por el SO

El sistema operativo es responsable de **administrar la memoria principal**, asignando bloques de RAM a los procesos que los necesitan y liberándolos cuando los procesos terminan o ya no requieren esa memoria. Esta gestión eficiente de la memoria es crucial para el rendimiento y la estabilidad del sistema.

Carga de Programas

Antes de que un programa pueda ser ejecutado por el CPU, sus **instrucciones y los datos que necesita deben cargarse desde el almacenamiento secundario a la memoria RAM**.

Almacenamiento Temporal

Durante la ejecución de un programa, la RAM sirve como un **almacén temporal para los datos con los que el CPU está trabajando activamente y las instrucciones que está ejecutando**. El CPU accede a la RAM (directamente o a través de la caché) para obtener las instrucciones y los datos necesarios para realizar las operaciones.

Memoria de Acceso Directo (RAM) - Relación con la Jerarquía

2

Nivel en la Jerarquía

En la jerarquía de memoria, la RAM se sitúa **inmediatamente por debajo de la caché**. Es el siguiente nivel de memoria al que el CPU accede cuando un dato no se encuentra en la caché.

10x

Latencia vs. Caché

Cuando se produce un **fallo de caché**, el CPU debe **acceder a la memoria RAM** para recuperar el bloque de datos o la instrucción solicitada. La latencia de acceso a la RAM es significativamente mayor que la latencia de acceso a la caché, por lo que una alta tasa de fallos de caché puede degradar el rendimiento del sistema.

8-32GB

Capacidad Típica

La **cantidad de memoria RAM instalada en un computador** tiene un impacto directo en su rendimiento general. Una cantidad insuficiente de RAM puede llevar a una situación de "**paging**" o "**swapping**", donde el sistema operativo mueve datos entre la RAM y el almacenamiento secundario (que es mucho más lento) para liberar memoria, lo que puede ralentizar significativamente el sistema.

AMD ryzen zen

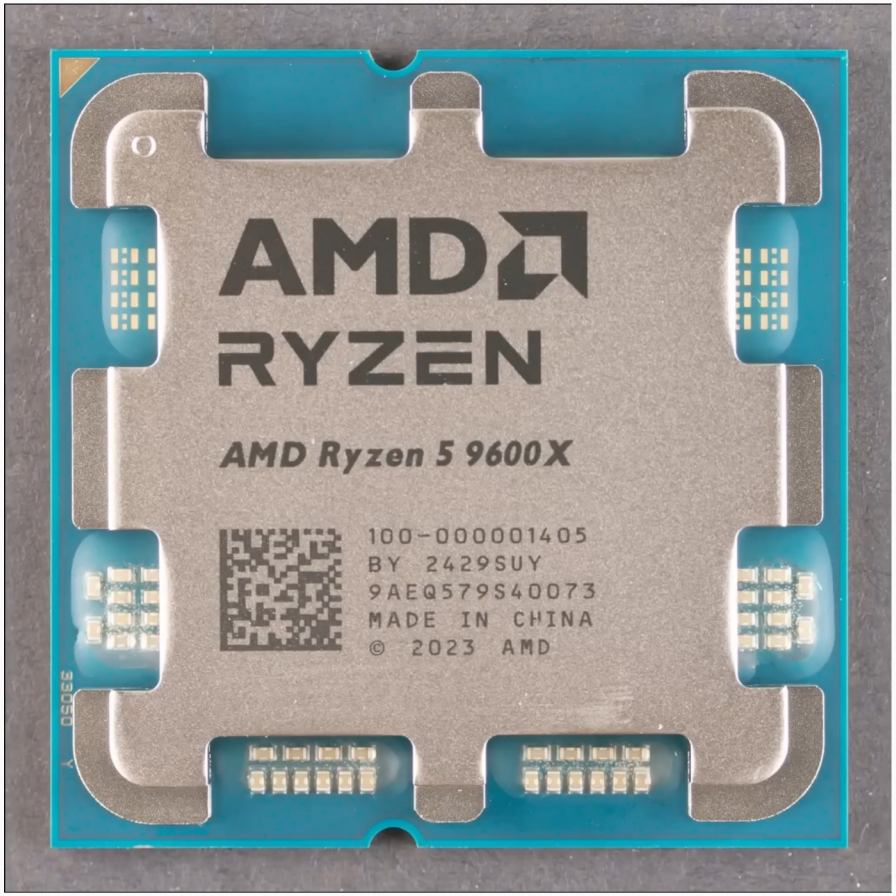

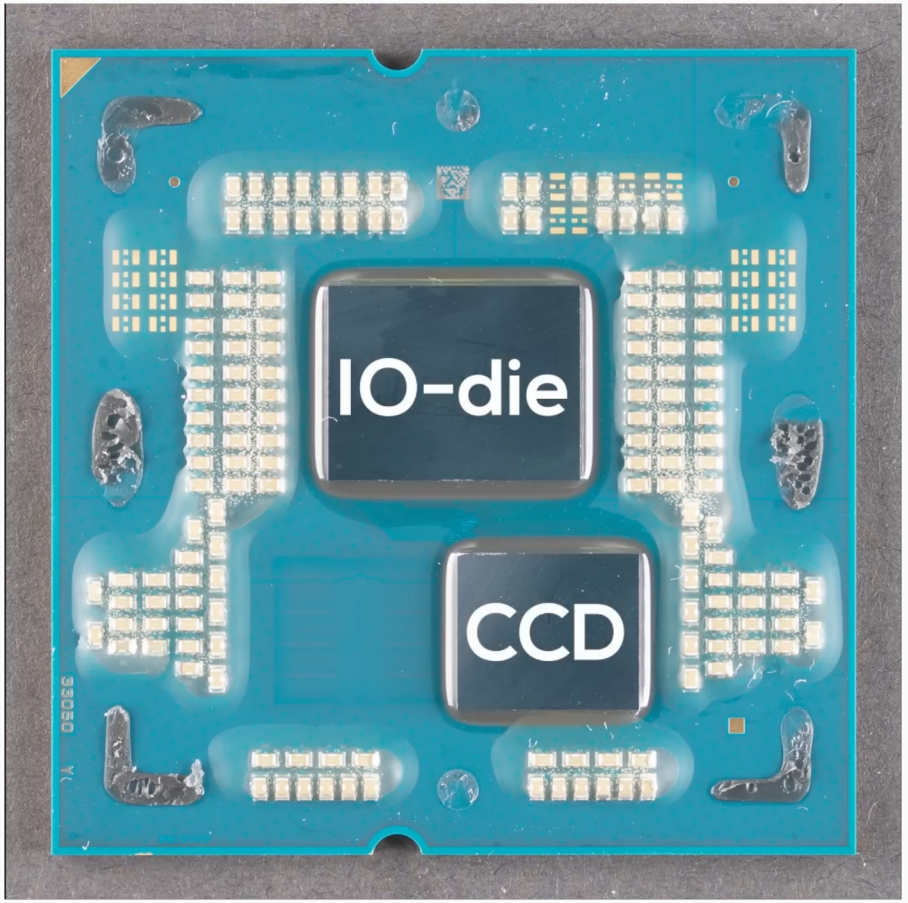

AMD Ryzen

AMD ryzen zen

Arquitectura 5ª Gen AMD EPYC (Serie 9005 “Turin”)

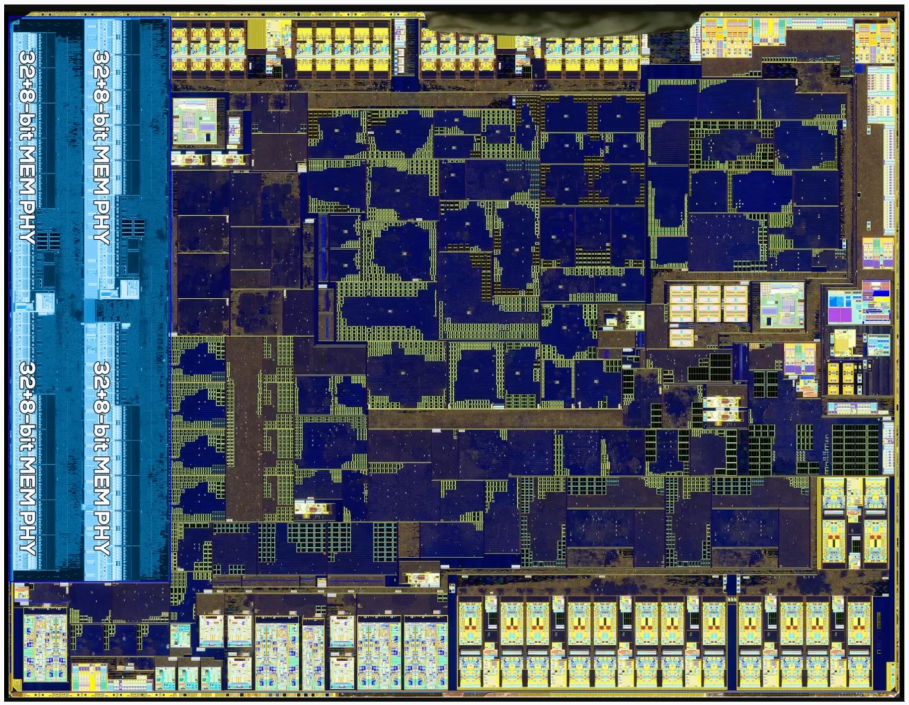

AMD Ryzen IO Die @FritzchensFritz

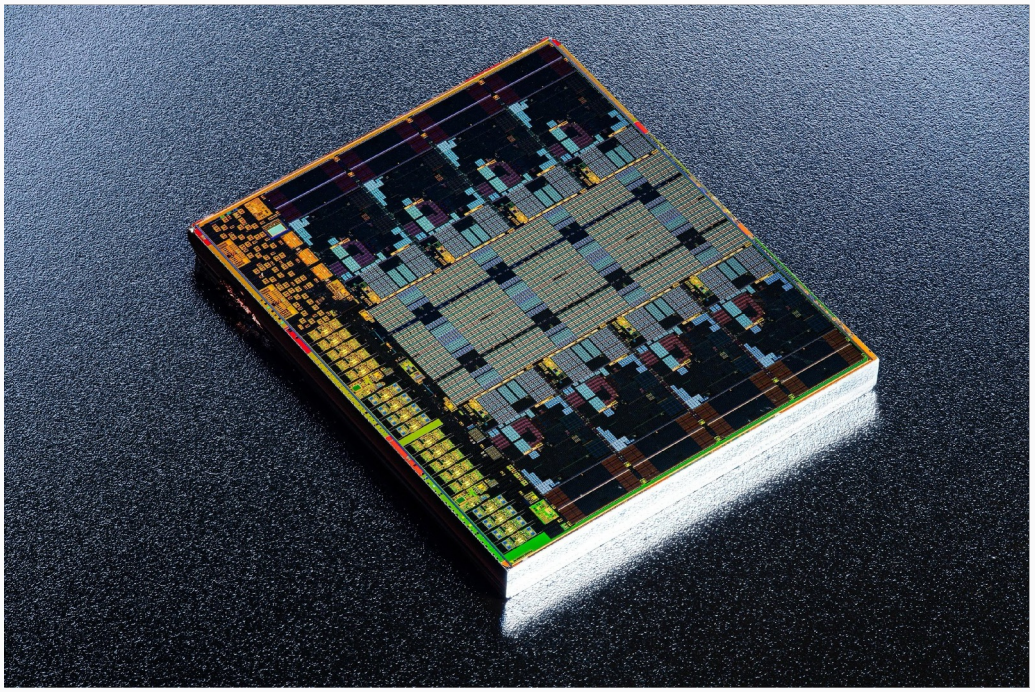

AMD Ryzen CCD ZEN 5 @FritzchensFritz

AMD ryzen zen

Arquitectura 5ª Gen AMD EPYC (Serie 9005 “Turin”)

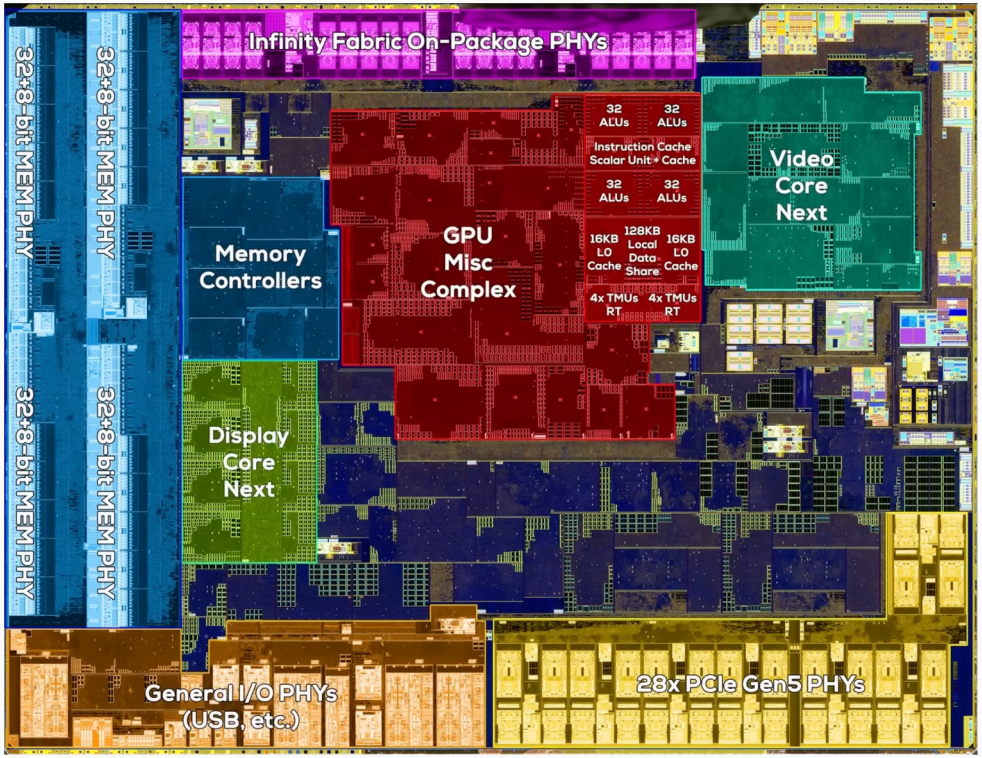

AMD Ryzen IO Die @FritzchensFritz

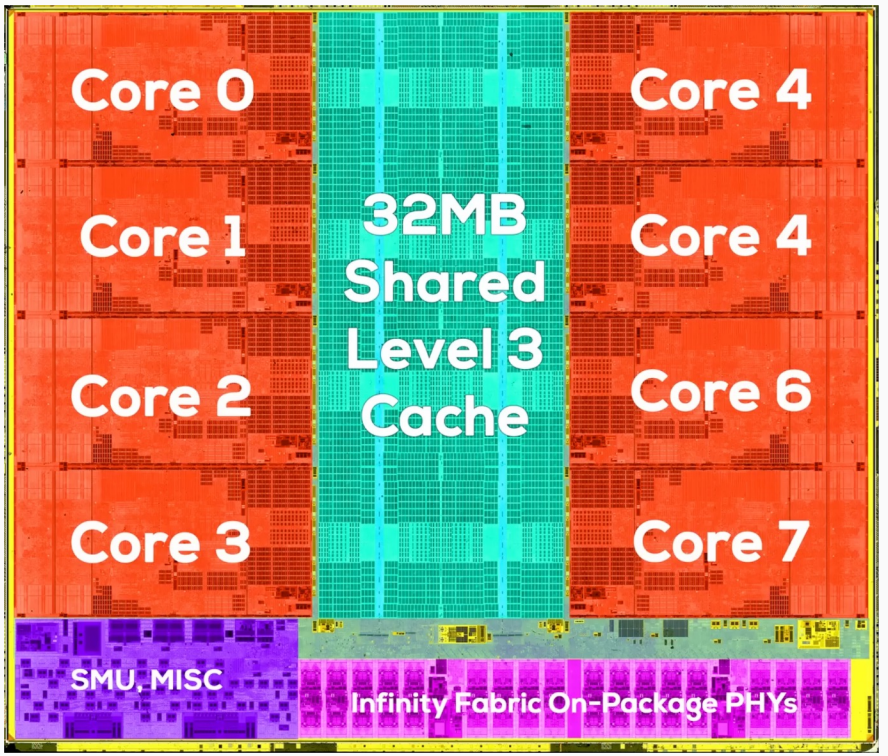

AMD Ryzen CCD ZEN 5 @FritzchensFritz

AMD ryzen zen

Arquitectura 5ª Gen AMD EPYC (Serie 9005 “Turin”)

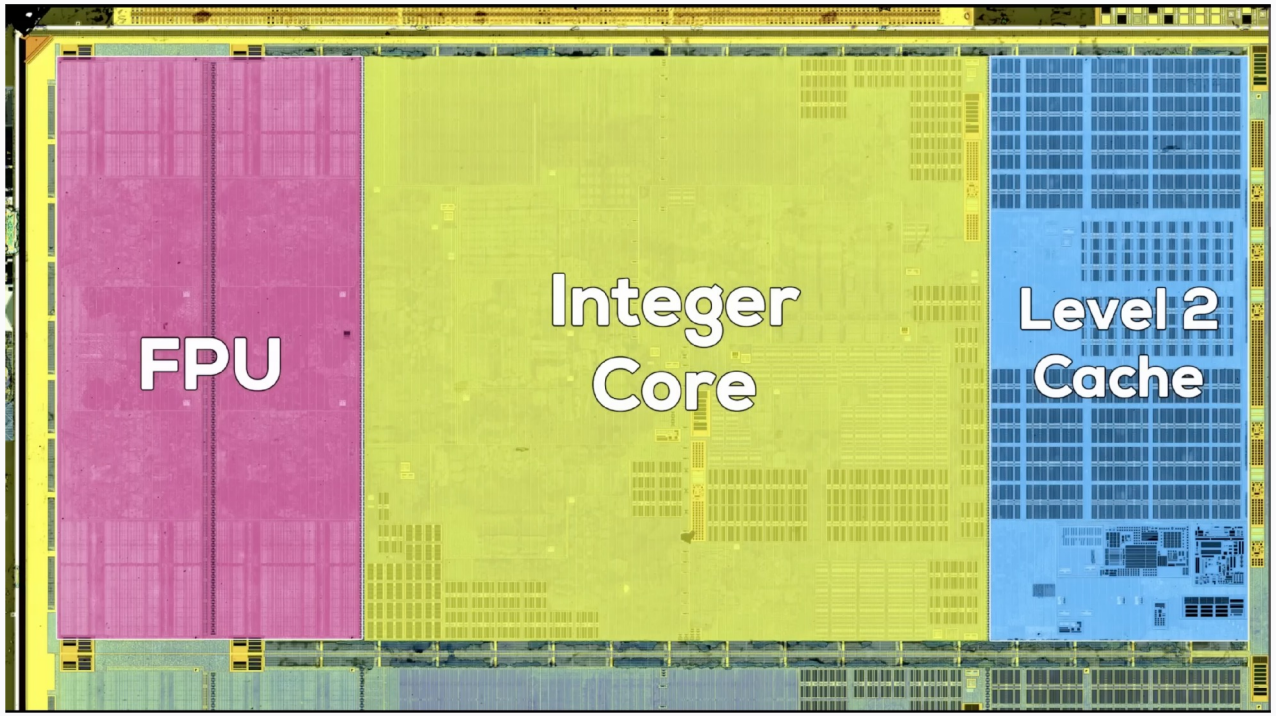

AMD Ryzen CCD ZEN 5 core @FritzchensFritz

AMD ryzen zen

Arquitectura 5ª Gen AMD EPYC (Serie 9005 “Turin”)

•Diseñada para centros de datos con cargas **empresariales tradicionales y de IA**.

•Arquitectura **híbrida multi-die**: separación entre dies de cómputo y die de I/O.

•Desacople de innovación:

- Núcleos CPU en procesos avanzados (Zen 5 en 4 nm, Zen 5c en 3 nm).
- Die de I/O en 6 nm, optimizado para memoria e interconexión.

•Dos tipos de núcleos:

- **Zen 5**: alto rendimiento por núcleo (enterprise, HPC, IA).
- **Zen 5c**: alta densidad y eficiencia energética.

•Escalabilidad extrema: **8 a 192 núcleos por socket**, la mayor densidad en x86.

•Arquitectura modular permite variantes optimizadas para:

- Virtualización
- Cargas licenciadas por núcleo
- IA como CPU host de GPUs
- Cómputo altamente paralelo