

DeliriOS: Exokernel Multicore en 64bits

Silvio Vileriño, Ezequiel Gambaccini

15 de julio de 2014

Delirios: Exokernel 64 bits Multicore

Motivación del trabajo final

- La **idea** directora del proyecto era experimentar con la arquitectura Intel
- Para esto se desarrollo un exokernel de 64 bits **multinúcleo**
- El objetivo inicial fue con **finés didácticos**, posteriormente se implementaron experimentos sobre la plataforma

Delirios: Exokernel 64 bits Multicore

Características

Se desarrollo un exokernel en 64 bits,

- El sistema permite ejecutar una única tarea en varios procesadores
- El *overhead* del OS es mínimo
- No hay soporte de protección, todo corre en nivel 0
- No hay soporte de entrada-salida

Desarrollo

It's working!

- El desarrollo consistió en estudiar todo el proceso de inicio en 64bits e implementarlo
- Además se utilizó grub como bootloader para poder iniciar desde un pendrive y sobre una máquina física
- Por último se implementó sobre dos procesadores un algoritmo para ordenar elementos


Desarrollo

Inicialización de grub

- La revisión de grub no permite ejecutables en 64bits
- Por lo que se utilizo la carga de módulos
- Consiste en cargar partes del sistema sobre el primer megabyte
- Grub permite determinar las posiciones de los módulos

Desarrollo

Mapa de memoria: Memoria baja y módulos en memoria alta



Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP

Grub inicializa la máquina a un estado conocido y otorga el control al loader de nivel 1 del BSP pasándole por parámetros estructuras de grub con información del sistema.

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP

Grub inicializa la máquina a un estado conocido y otorga el control al loader de nivel 1 del BSP pasándole por parámetros estructuras de grub con información del sistema.

- 1 Se realizan **validaciones** requeridas por la especificación multiboot, verificación de firmas, etc.

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP

Grub inicializa la máquina a un estado conocido y otorga el control al loader de nivel 1 del BSP pasándole por parámetros estructuras de grub con información del sistema.

- 1 Se realizan **validaciones** requeridas por la especificación multiboot, verificación de firmas, etc.
- 2 Se obtienen de la metadata provista por grub las posiciones de memoria **donde están cargados** los módulos, ellos son:

`kernel64.bin64:`

segundo nivel de **booteo del BSP**
(binario plano de 64 bits)

`ap_full_code.bin64:`

segundo nivel de **booteo de los Application Processors**
(binario plano de 64 bits)

`ap_startup_code:`

código de inicio del **AP en modo real y el primer stage** de booteo a modo protegido (binario de 32 bits)

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP (cont...)

- 1 Los AP inician en modo real → deben comenzar su ejecución por debajo del primer mega de memoria principal → se copia el módulo `ap_startup_code` a una dirección arbitraria alineada a página `0x2000`. (se superpone código con grub)

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP (cont...)

- 1 Los AP inician en modo real → deben comenzar su ejecución por debajo del primer mega de memoria principal → se copia el módulo `ap_startup_code` a una dirección arbitraria alineada a página `0x2000`. (se superpone código con `grub`)
- 2 Para evitarlo, minimizamos el tamaño del startup de modo real del AP, haciendo lo antes posible un salto a un loader de nivel 2 por encima del mega (`ap_full_code.bin64`)

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP (cont...)

- 1 Los AP inician en modo real → deben comenzar su ejecución por debajo del primer mega de memoria principal → se copia el módulo `ap_startup_code` a una dirección arbitraria alineada a página `0x2000`. (se superpone código con `grub`)
- 2 Para evitarlo, minimizamos el tamaño del startup de modo real del AP, haciendo lo antes posible un salto a un loader de nivel 2 por encima del mega (`ap_full_code.bin64`)
- 3 El AP debe saltar entre los dos niveles de booteo → se le inyecta al primer módulo la dirección donde está cargado el segundo nivel de booteo

Desarrollo

Niveles de booteo del BSP y preparación del entorno de inicio de los AP (cont...)

- 1 Los AP inician en modo real → deben comenzar su ejecución por debajo del primer mega de memoria principal → se copia el módulo `ap_startup_code` a una dirección arbitraria alineada a página `0x2000`. (se superpone código con `grub`)
- 2 Para evitarlo, minimizamos el tamaño del startup de modo real del AP, haciendo lo antes posible un salto a un loader de nivel 2 por encima del mega (`ap_full_code.bin64`)
- 3 El AP debe saltar entre los dos niveles de booteo → se le inyecta al primer módulo la dirección donde está cargado el segundo nivel de booteo
- 4 Finalmente, se realiza un salto en la ejecución a donde comienza el módulo `kernel164.bin64` donde el BSP finaliza la inicialización del contexto hasta modo largo de 64 bits y enciende a los demás núcleos del sistema

Desarrollo

Inicialización por niveles BSP

Grub lleva pc a un estado conocido detallado en la especificación multiboot

nivel 1: Puente entre Grub y DeliriOS

- * Validaciones de especificacion multiboot.
- * Obtención de las posiciones en memoria de los módulos.
- * Copia del módulo `ap_startup_code` a la posición `0x2000`.
- * Inyección de datos entre módulos.
- * Otorgar control al módulo `kernel64`

nivel 2: Puente entre DeliriOS y modo x64

- * Asignar GDT, Paginación, Interrupciones, etc.
- * Reprogramación del PIC.
- * Envío de señal de encendido a los AP's .
- * Limpieza de registros de propósito general.
- * Seteo de la pila.
- * Salto a 64 bits

Inicio completo!

Desarrollo

Inicialización por niveles AP

Ap bootea en 0x2000 en modo real

- * Creación de GDT temporal en código
- * Salto de modo real a modo protegido
- * Salto a loader de nivel 2

nivel 2: Modo protegido a modo x64

- * Asignar GDT, IDT, Paginación
- * Seteo de la pila.
- * Salto a modo x64.

Inicio completo!

Desarrollo: Inicialización del Bootstrap Processor

Modo Legacy x64: Modelo de segmentación

La especificación de *multiboot* de grub asegura que estamos en modo protegido

Pero podemos no tener asignada una GDT válida

Necesitamos las siguientes entradas en la GDT,

Índice	Descriptor
0	Descriptor nulo
1	Código nivel 0 para 32 bits
2	Código nivel 0 para 64 bits
3	Datos nivel 0 para 32 y 64 bits

Desarrollo: Paginación en 64 bits

x64 requiere habilitar PAE

Se realizo un mapeo identity mapping de los primeros 4gb usando paginas de 4kb.

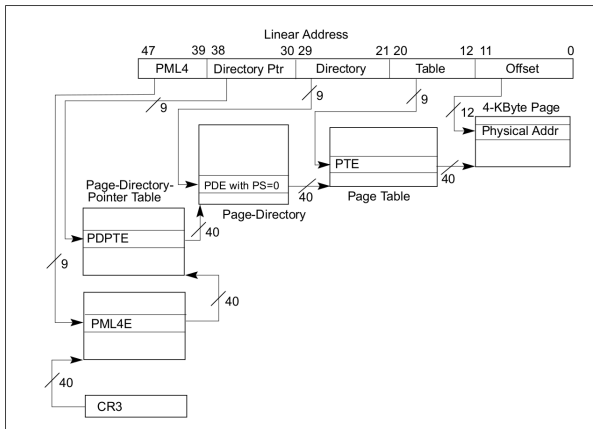


Figure 4-8. Linear-Address Translation to a 4-KByte Page using IA-32e Paging

Desarrollo: Verificación de disponibilidad de x64

Consulta via `cpuid`

Luego de establecer estas estructuras, realizamos una comprobación vía `cpuid` para saber si está disponible modo x64,

de verificarse esta comprobación, encendemos los bits del procesador correspondientes para habilitar dicho modo en el registro CR0.

Desarrollo: Pasaje a modo largo x64 nativo

Para pasar de modo compatibilidad a modo nativo de 64 bits, es necesario realizar un salto largo en la ejecución a un descriptor de la GDT de código de 64 bits.

Luego de realizar el salto al segmento de código de x64 de la GDT establecemos un contexto seguro con los registros en cero, seteamos los selectores correspondientes de la GDT y establecemos los punteros a una pila asignada al BSP.

Desarrollo: Inicialización del PIC

Captura de excepciones e interrupciones

Enviamos señales al PIC para reprogramarlo de forma tal en la que atienda las interrupciones enmascarables.

Luego, asignamos una IDT que captura todas las excepciones e interrupciones y de ser necesario, realiza las acciones correspondientes con su ISR asociada.

Desarrollo: Multicore - encendido de los AP's

Una vez inicializado el bsp, se procede a inicializar el resto de los procesadores del sistema.

Para lograr esto, primero es necesario que encontrar una estructura de datos llamada MP Floating Pointer Structure, que contiene:

- información sobre los demás procesadores
- apic (advanced programmable interrupt controller)
- el I/O apic (análogo al apic, pero se encarga además de rutear interrupciones de input/output a los lapic's)

Desarrollo: Búsqueda de la estructura MP Floating Pointer

Esta estructura puede estar en diferentes lugares de memoria, inicialmente se debe realizar la búsqueda dentro del **primer kilobyte de la ebda** (extended bios data area), de no encontrarse allí, se procede a buscar entre los **639K-640K** de memoria.

- Para encontrar la tabla se busca dentro de esas áreas de memoria la firma de la MP Floating Pointer Structure, la cual es "_MP_"
- Para comprobar la validez de la estructura se realiza un checksum
- Si no se encuentra la tabla, el sistema no soporta multicore

Desarrollo: Inicialización de los AP's

Una vez finalizada la inicialización del `local apic`, se debe pedir a la BIOS que setee el `warm reset vector` a la dirección donde esta localizado el inicio de modo real de los `aps(0x2000)`.

Luego de este paso, se procede a encender los AP's usando la información obtenida por la `MP Configuration Table`.

Desarrollo: Inicialización de los AP's (cont)

Luego de tener listos los `icr`, se procede a mandar las `ipi`'s de `INIT` e `INIT_DASSERT`, luego se espera unos 10 milisegundos, verificando previamente que las `ipis` se hayan enviado correctamente.

Luego de la espera, se procede a enviar la `ipi` de `STARTUP`, se espera 10 ms, se verifica que se haya enviado correctamente, se la vuelve a enviar, se realiza otra espera de 10 ms, y se vuelve a verificar.

Una vez terminado este proceso, se puede asumir que el AP fue encendido, y se continúa el encendido el resto de los AP's encontrados en la `MP Configuration Table`

Desarrollo: Inicialización de modo real a modo nativo x64 de los AP's

booteo por etapas,

- 1 Se inicializa una GDT básica y se salta a modo protegido
- 2 Salto al segundo bootloader (dirección inyectada)
- 3 Pasamos a modo nativo de 64 bits
- 4 Se asignan estructuras comunes, la GDT y la estructura de paginación
- 5 Se inicializa una IDT para los AP y se habilitan los local-apic de cada AP
- 6 Se obtiene el código de identificación del procesador (variable y distinto)

Experimentos: Sorting Paralelo

Combinando *merge sort* con *heap sort* se construyo un algoritmo de ordenamiento en paralelo

El algoritmo tiene 3 subprocessos,

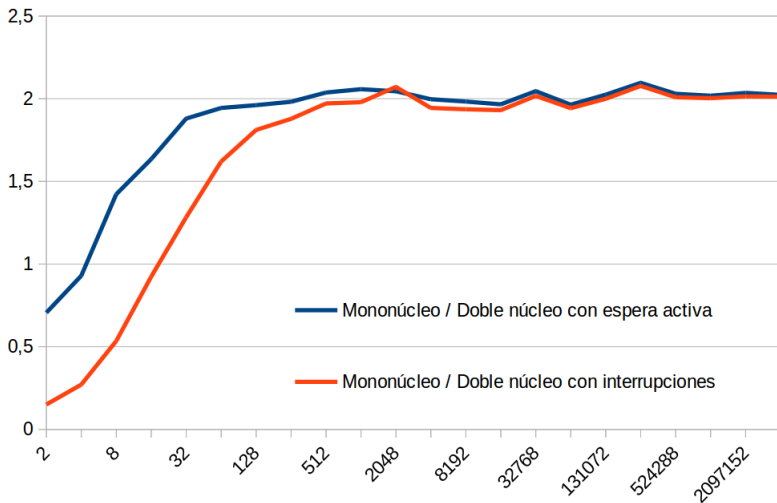
- Sort: Ordenamiento de mitades por cada core
- Merge: Merge paralelizado de las mitades ordenadas
- Copy: Copia del resultado a un buffer de destino

Dos mecanismos de sincronización,

- Memoria: *Polling* sobre memoria
- Ipi: interrupciones entre procesadores

Experimentos: Sorting Paralelo

Resultados en un procesador G2030



GRACIAS