

---

# Kernel: CPU y Memoria

**Diseño y Evaluación de Configuraciones**

**Curso 2012-13**



**Miguel Telleria de Esteban**

telleriam AT unican.es

**Computadores y Tiempo Real**

<http://www.ctr.unican.es>

---

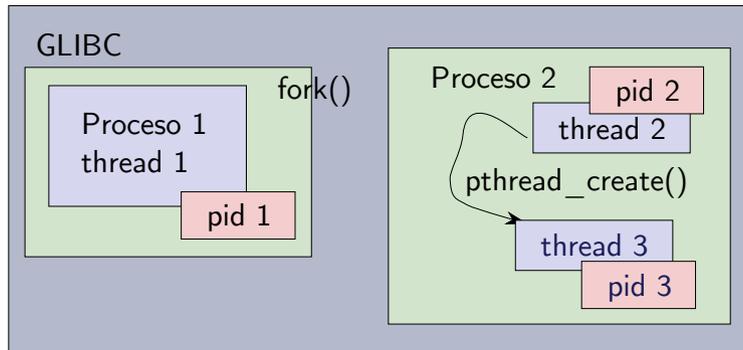
---

# Uso de CPU y planificación

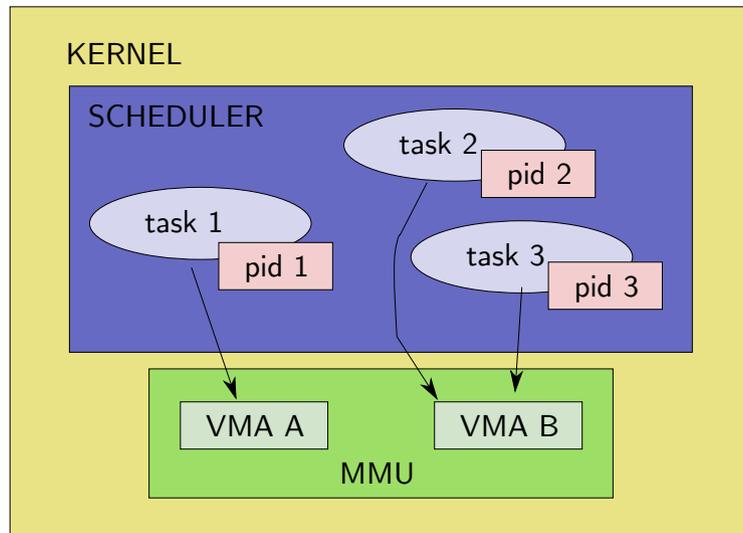
---

# Procesos y Threads

POSIX API: `fork()`, `getpid()`, `pthread_create()`



SYSCALLS: `clone`, `getpid`, `gettid`



- GNU/Linux soporta procesos y threads
  - **Procesos:** Espacio de memoria propio
  - **Threads:** Espacio de memoria compartido
- Para el kernel procesos y threads se planifican indistintamente:
  - PID
  - Política de planificación
  - Prioridad
  - Afinidad
  - Estadísticas
  - Relojes de ejecución

# Planificador de Linux

Desde el 2.6.23 (2007) CFS: Completely Fair Scheduler

## Jerarquia I Real Time:

- Baja latencia (para alta prioridad)
- Bajas prioridades pueden no ejecutar
- SCHED\_RR: Timeslice fija para todos
- SCHED\_FIFO: Hasta que no termine no para

SCHED\_FIFO

SCHED\_RR

---

## Jerarquia II: Timeshare

- Alto throughput “para todos”
- Todas las tareas tiene garantizada la CPU
- SCHED\_OTHER: Round-robin con timeslice inversamente proporcional al nice

SCHED\_OTHER

TASKs  
(rbtree)

Multicores: Balanceo de carga periódico segun afinidad

# Parámetros de planificación de CPU en Linux

- Policy: Política de planificación
  - `SCHED_OTHER` o `SCHED_NORMAL`: Por defecto, round-robin con timeslice variable
  - `SCHED_RR`: POSIX Real-Time: Round robin con timeslice fija
  - `SCHED_FIFO`: POSIX Real Time: prioridades fijas

Las políticas `SCHED_FIFO` y `SCHED_RR` tienen prioridad sobre `SCHED_OTHER`.

- Nice: Avaricia del proceso
  - Sólo se usa en `SCHED_OTHER`, se ignora para real time
  - Oscila entre: (-20 valor más prioritario y 19), por defecto 0
- rt-priority: Nivel de preempción
  - Se usa en `SCHED_RR` y `SCHED_FIFO`, ignorada en `SCHED_OTHER`
- Máscara de afinidad
  - Define en que CPU(s) un proceso admite ser ejecutado

# Nice y nivel de preempcion entremezcladas

- 100 – 139 valor inverso a la prioridad (100 más prioritario)
  - **Donde:** PROCFS: /proc/<pid>/sched (prio).
  - **NOTA:** Cuando se cambia a RT este valor permanece igual (pero es ignorado)
- 0 – 99 creciente en prioridad (sólo en SCHED\_FIFO, SCHED\_RR)
  - **Donde**
    - chrt -p <pid>
    - API's de POSIX (set\_sched\_param)
- -20 a 19 (SCHED\_OTHER) orden inverso a prioridad
  - **Donde:**
    - Htop,
    - chrt -p <pid>
    - Gnome-system-monitor
- 0 – 39 (SCHED\_OTHER) orden inverso a la prioridad
  - **Donde:**
    - top

# Asignación de prioridad y política desde consola

- Comando **chrt**

- **Vemos en que prioridad corre: Usamos -p para el pid**

- `chrt -p 16951`

```
pid 16951's current scheduling policy: SCHED_OTHER
pid 16951's current scheduling priority: 0
```

- **Pasamos a SCHED\_FIFO prioridad alta 80/90 -p para prioridad**

- `chrt -fifo -p 80 169510`

- `chrt -p 16951`

```
pid 16951's current scheduling policy: SCHED_FIFO
pid 16951's current scheduling priority: 80
```

- **Vuelta a SCHED\_OTHER con nice a 0 (valor por defecto)**

- `chrt -other -p 0 16951`

# Afinidad

- La afinidad se representa mediante una máscara binaria
    - CPU 0: 1 CPU 1: 2 CPU 3: 4 CPU 4: 8 ...
    - Valor 3: CPU's 0 y 1
  - Asignación y obtención desde consola (parecido al chrt)
    - Se obtiene con `taskset -p <pid>`
      - `Taskset -p 16951`
- ```
pid 16951's current affinity mask: f
```
- Se asigna con `taskset -p <mascara> <pid>`
    - `taskset -p 1 16951`
    - `Taskset -p 16951`

# Estados de un thread en el tiempo

- En un instante dado un thread puede estar:
  - **R** Running
  - **S** Sleep: Suspendido en un wait() o sleep(). Se le puede interrumpir
  - **D** Uninterruptible sleep (típicamente disk IO). Sólo se le interrumpe con kill -9
  - **T** Traceado en debug
  - **Z** Zombie, difunto:
    - A la espera de que el padre les espere (o muera y sean esperados por init)
- Además puede tener las siguientes añadidos (ej ps):
  - **<** Valor nice negativo, (avaricioso)
  - **N** Valor nice positivo, (generoso)
  - **L** Mantiene páginas en memoria bloqueadas
  - **l** Tiene pthreads asociados
  - **s** Líder de sesión: Proceso que controla el terminal
  - **+** Pertenece al foreground-process-group

# CPU ocupada sin ningún thread de usuario

- Existen situaciones en el que el kernel tiene la CPU ocupada sin ejecutar ningún código o servicio de usuario.
  - **Atendiendo a una interrupción hardware (ej. timer)**
    - Top half (irq ISR)
    - Bottom half (workqueue, tasklet, softirq)
  - **Atendiendo a una interrupción software (ej page-fault + swap)**
  - **Ejecutando tareas de mantenimiento:**
    - Actualizando páginas sucias de la page-cache al disco
    - Balanceando la carga de los multicores
  - **Respondiendo a necesidades de emergencia**
    - Liberando memoria de caches o de procesos
    - Usando la swap del disco
  - **Realizando cambios de contexto**
  - **No realizando nada (idle)**

---

# Funcionamiento de la memoria

---

# Paginación en Linux

- Hardware MMU (Memory management unit) provee:
  - Manejo en bloques de **páginas** (típicamente 4k en i386).
  - Mapeados de direcciones (i386: tablas PGPT, PMD, PTE)
  - Detección de **fallos de página** (acceso a páginas no mapeadas)
  - Permisos de lectura / escritura / ejecución
  - TLB: Cache de traducción de páginas
- El S.O. (linux) ha de programar todo ello:
  - Maneja un **bitmap de todas las páginas de memoria**.
  - Actualiza las tablas en los cambios de contexto: Espacios de memoria
  - Utiliza los fallos de página para
    - Detectar accesos prohibidos
    - Implementar paginación bajo demanda
    - Implementar cache memoria ↔ disco
    - Implementar espacio swap

# Distribución de la memoria física en Linux

- Páginas para el kernel mismo:
  - El fichero `vmlinuz` se carga **permanentemente** en memoria
  - Los módulos se cargan bajo demanda (y se quedan permanentes mientras no se quite el módulo)
  - Losas (**slab**) estructuras pre-allocated (inodos, descriptores de procesos, página...)
    - Cada losa ocupa menos que una página, por lo que el kernel maneja su reuso).
    - Parte de estos objetos se cachean (inode cache, dentry cache)
- Páginas para los procesos (de usuario y de kernel)
  - Código ejecutable (**text**) (compartido con otros procesos)
  - Datos estáticos (**data**)
  - Stack y thread-level-storage (**bss**)
  - Heap
- Páginas de caché de disco (`page_cache`)
  - Caché: Contenido real de disco
  - Buffers: Metadata de los inodos (timestamps, permisos...)
- Pool de páginas libres
  - Para satisfacer rápidamente peticiones urgentes

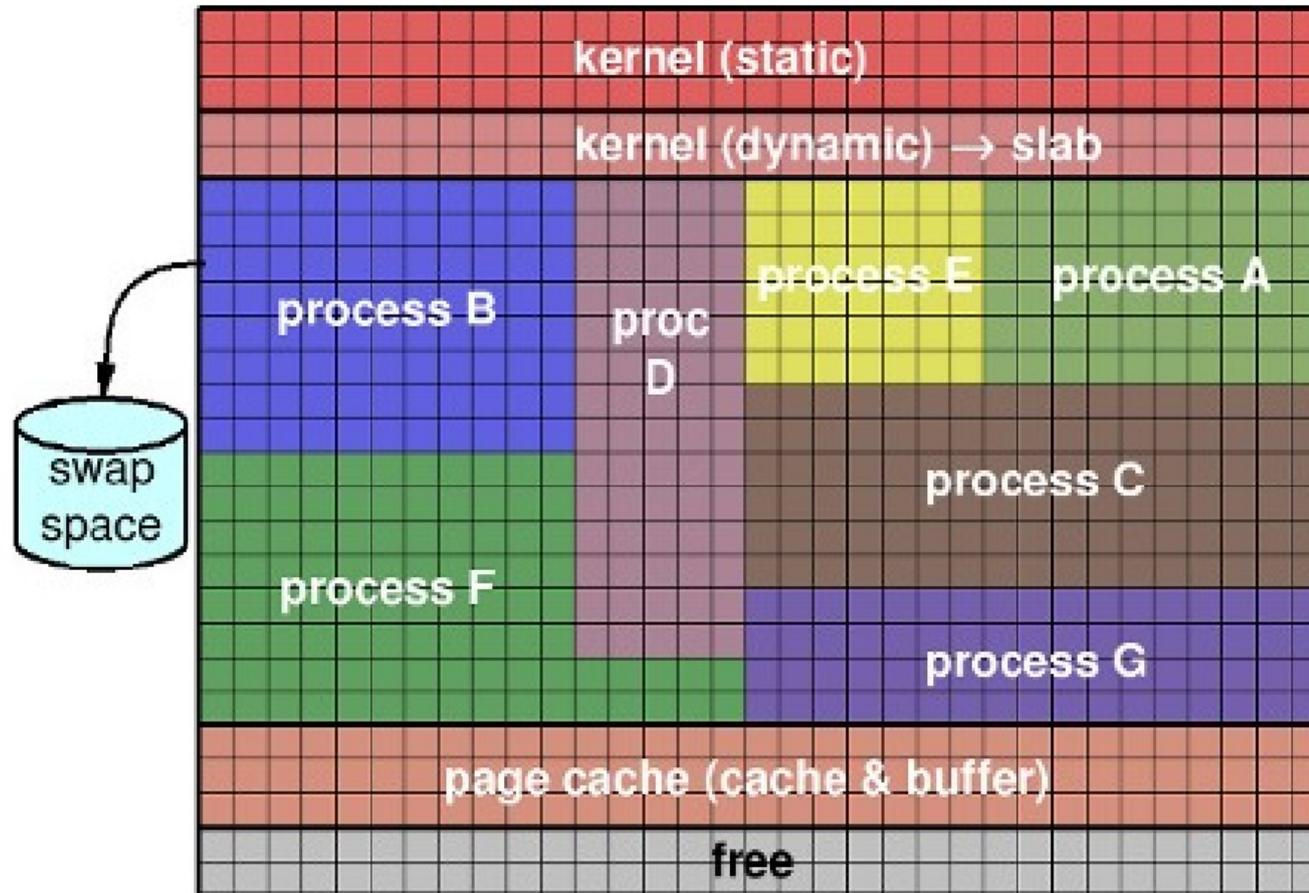
# Memoria asociada a un proceso

- El kernel define zonas de memoria VMA para los procesos
  - Puede estar mapeada a un fichero o ser anónima
  - Tiene asociados permisos de ejecución, lectura y/o escritura
  - Puede estar compartida o no con otros procesos

```
pmap 3070

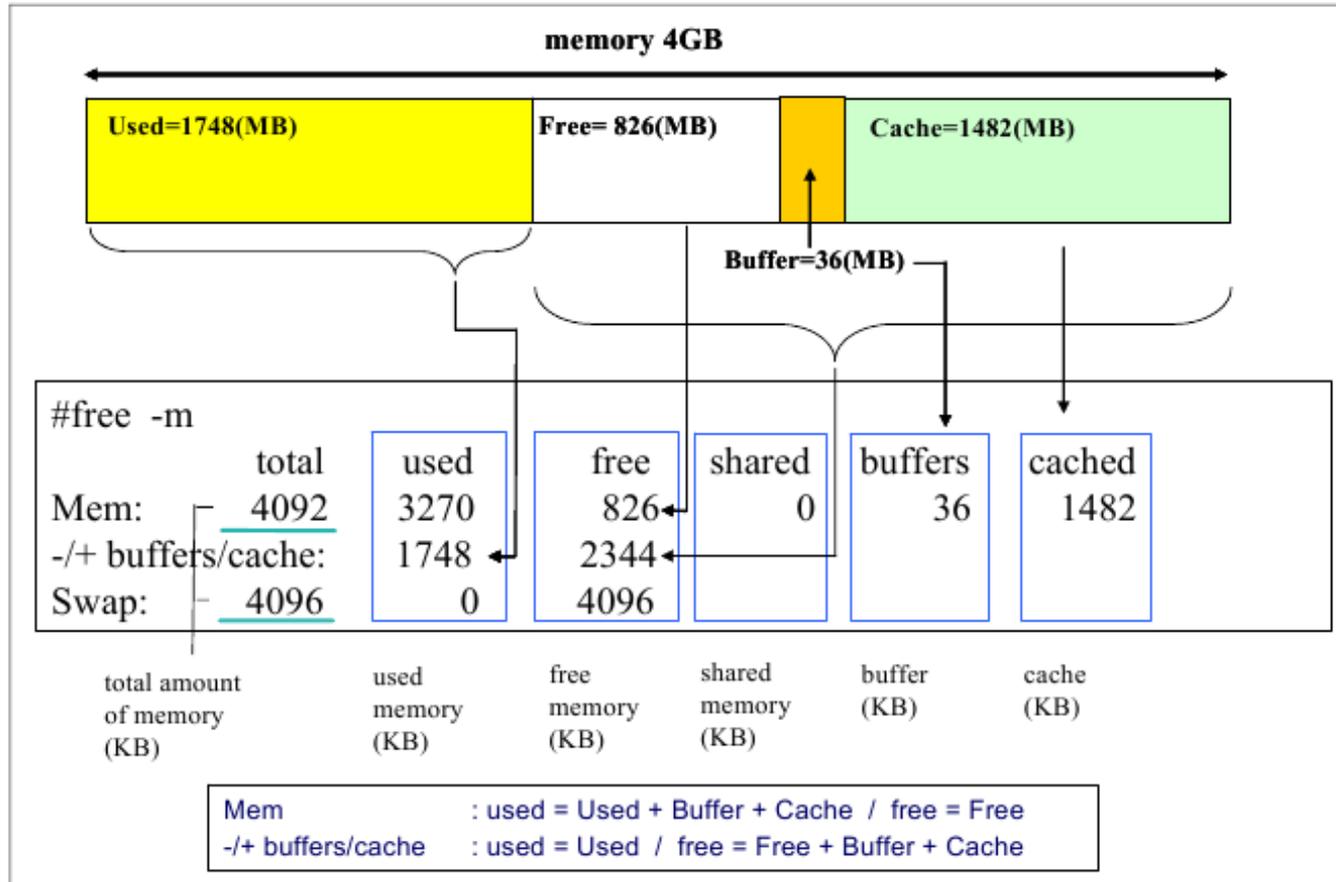
08048000 3152K r-x-- /usr/bin/claws-mail
0835c000 160K rw--- /usr/bin/claws-mail
08384000 80K rw--- [ anon ]
0a372000 42372K rw--- [ anon ]
aad3e000 8620K r---- /usr/share/icons/hicolor/icon-theme.cache
ab5a9000 48536K r---- /usr/share/icons/gnome/icon-theme.cache
ae50f000 4K ----- [ anon ]
afd13000 8192K rw--- [ anon ]
b0513000 112K r--s- /usr/share/mime/mime.cache
b0d9a000 48536K r---- /usr/share/icons/gnome/icon-theme.cache
b3d00000 2048K rw--- [ anon ]
b469b000 8192K rw--- [ anon ]
b4e9b000 484K r-x-- /usr/lib/claws-mail/plugins/vcalendar.so
b4f14000 40K rw--- /usr/lib/claws-mail/plugins/vcalendar.so
```

# Linux intenta usar la máxima memoria



¡¡ Memoria sin usar es memoria desperdiciada !!

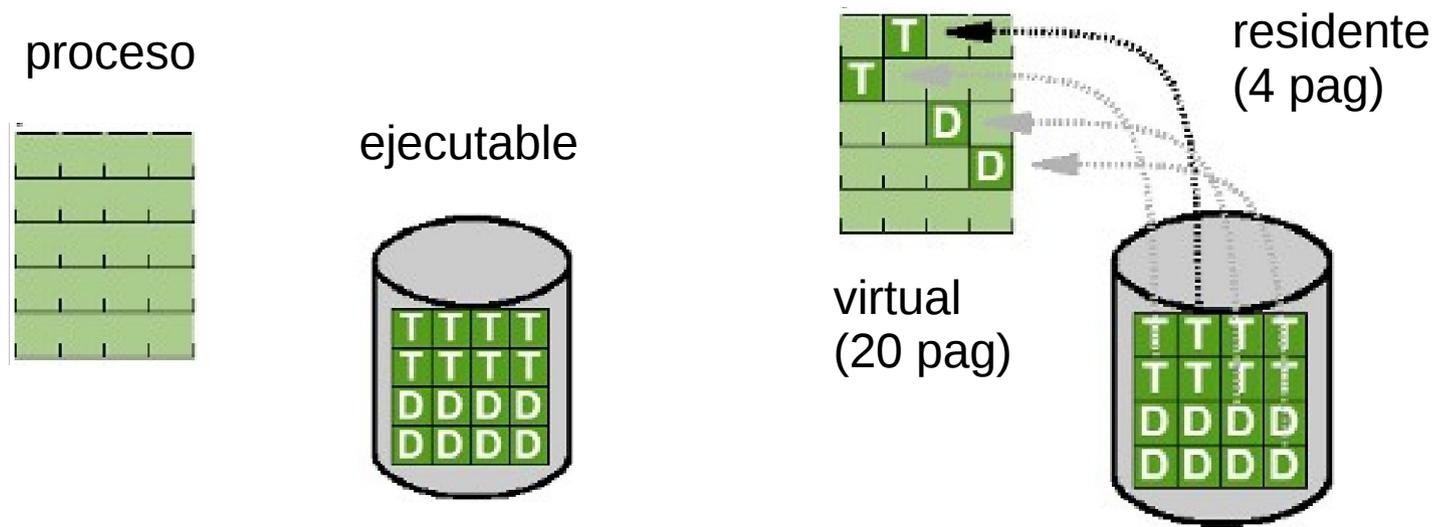
# ¿Cual es entonces la “memoria disponible”?



- Rule of thumb: Libre + page-cache

# Memoria de proceso: virtual vs residente

- Linux utiliza la estrategia de paginación **bajo demanda**
  - malloc, cargar un ejecutable, fork... no ocupan la memoria inmediatamente**



- La memoria se va “rellenando” según se va **referenciando**
  - Cada referencia no mapeada provoca un **page-fault** (excepción software)
  - El kernel trata la excepción relleno la página del proceso (o actualizando el mapeado)

# Memoria swap

- La swap es un mecanismo para **proveer a los procesos** más memoria de la disponible físicamente.
- Es memoria residente de **procesos** mapeada en el disco
- Se usa en 2 contextos:
  - **Caso 1:** Cuando no podemos dar servicio a la demanda de memoria
  - **Caso 2:** Cuando un proceso se queda inactivo durante mucho tiempo (ej init)
- Existe un recurso más fuerte: El **Out-Of-Memory killer**

# Memoria que no crea problemas de performance

- De más a menos favorable
  - Pool libre
  - Memoria residente recién liberada (que pasa al pool)
  - Page cache ya guardada en el disco y poco usada
  - Slabs poco usados
  - inodes, dentries de la cache con LRU bajo (que se traduce en slabs liberados)
- Estas gestiones de memoria se realizan automáticamente por los threads del kernel.

# Memoria que afecta a la performance

- De más a menos favorable
  - Page cache usada recientemente (pero aún limpia en disco)
  - inodes y dentries con LRU alto
  - Page cache sucia (hay que guardarla en disco primero)
  - Memoria residente de procesos limpia en swap
  - Memoria residente de procesos sucia en swap
- Estas acciones sólo se ponen en marcha cuando un proceso pide un **exceso de memoria residente**.

## Ejemplo a seguir

- White Paper de los creadores de atop

---

# Herramientas de monitorización

---

# Gnome-System-Monitor

- Herramienta gráfica de monitorización basada en GTK
- Bueno:
  - Intuitiva
  - Se ve en tiempo real la jerarquía de los procesos
  - Se pueden hacer acciones sobre los procesos con un sólo click
  - Muestra información de ficheros abiertos, zonas de memoria
- Negativo:
  - No exporta ningún dato a texto o a fichero
  - No muestra los pthreads
  - No se puede congelar el resultado
  - No se pueden reorganizar las columnas

Monitor del sistema

Monitor Editar Ver Ayuda

Sistema Procesos Recursos Sistemas de archivos

Carga media para los últimos 1, 5 y 15 minutos: 0,04, 0,03, 0,01

| Nombre del proceso                                  | Usuario | Estado    | Memoria virtual | Memoria residente | Memoria escribible | Memoria compartida | % CPU | Tiempo de CPU |
|-----------------------------------------------------|---------|-----------|-----------------|-------------------|--------------------|--------------------|-------|---------------|
| gam_server                                          | miguel  | Durmiendo | 2,9 MiB         | 1,1 MiB           | 132,0 KiB          | 1016,0 KiB         | 0     | 3             |
| dbus-launch                                         | miguel  | Durmiendo | 3,2 MiB         | 456,0 KiB         | 4,0 KiB            | 452,0 KiB          | 0     | 0:0           |
| dbus-daemon                                         | miguel  | Durmiendo | 3,2 MiB         | 1,6 MiB           | 900,0 KiB          | 752,0 KiB          | 0     | 3             |
| evince                                              | miguel  | Durmiendo | 4,5 MiB         | 1,9 MiB           | 252,0 KiB          | 1,6 MiB            | 0     | 3             |
| gvfs-gphoto2-volume-monitor                         | miguel  | Durmiendo | 8,6 MiB         | 2,1 MiB           | 392,0 KiB          | 1,7 MiB            | 0     | 3             |
| gvfsd-burn                                          | miguel  | Durmiendo | 8,7 MiB         | 2,4 MiB           | 340,0 KiB          | 2,1 MiB            | 0     | 0:0           |
| gvfsd                                               | miguel  | Durmiendo | 8,9 MiB         | 2,4 MiB           | 504,0 KiB          | 2,0 MiB            | 0     | 3             |
| gvfsd-metadata                                      | miguel  | Durmiendo | 9,0 MiB         | 2,6 MiB           | 1,0 MiB            | 1,6 MiB            | 0     | 3             |
| gvfsd-trash                                         | miguel  | Durmiendo | 9,0 MiB         | 2,9 MiB           | 468,0 KiB          | 2,5 MiB            | 0     | 3             |
| gvfs-gdu-volume-monitor                             | miguel  | Durmiendo | 9,5 MiB         | 3,3 MiB           | 568,0 KiB          | 2,7 MiB            | 0     | 3             |
| gconfd-2                                            | miguel  | Durmiendo | 10,4 MiB        | 4,4 MiB           | 2,2 MiB            | 2,2 MiB            | 0     | 3             |
| gvfsd-http                                          | miguel  | Durmiendo | 12,0 MiB        | 3,3 MiB           | 480,0 KiB          | 2,9 MiB            | 0     | 3             |
| gvfs-afc-volume-monitor                             | miguel  | Durmiendo | 18,1 MiB        | 2,1 MiB           | 316,0 KiB          | 1,8 MiB            | 0     | 0:0           |
| gnome-screensaver                                   | miguel  | Durmiendo | 19,4 MiB        | 6,5 MiB           | 1,4 MiB            | 5,0 MiB            | 0     | 3             |
| x-session-manager                                   | miguel  | Durmiendo | 26,7 MiB        | 5,9 MiB           | 592,0 KiB          | 5,3 MiB            | 0     | 3             |
| ssh-agent                                           | miguel  | Durmiendo | 3,2 MiB         | 136,0 KiB         | N/D                | 108,0 KiB          | 0     | 3             |
| kerneloops-applet                                   | miguel  | Durmiendo | 17,5 MiB        | 5,7 MiB           | 944,0 KiB          | 4,8 MiB            | 0     | 3             |
| polkit-gnome-authentication-agent-1                 | miguel  | Durmiendo | 17,9 MiB        | 5,5 MiB           | 920,0 KiB          | 4,6 MiB            | 0     | 3             |
| gdu-notification-daemon                             | miguel  | Durmiendo | 19,4 MiB        | 6,7 MiB           | 1,1 MiB            | 5,5 MiB            | 0     | 3             |
| vino-server                                         | miguel  | Durmiendo | 21,2 MiB        | 6,8 MiB           | 1,2 MiB            | 5,6 MiB            | 0     | 3             |
| evolution-alarm-notify                              | miguel  | Durmiendo | 30,4 MiB        | 7,9 MiB           | 1,5 MiB            | 6,4 MiB            | 0     | 3             |
| gnome-usr/lib/evolution/2.30/evolution-alarm-notify | miguel  | Durmiendo | 76,3 MiB        | 8,0 MiB           | 1,2 MiB            | 6,8 MiB            | 0     | 3             |
| seahorse-agent                                      | miguel  | Durmiendo | 77,2 MiB        | 8,6 MiB           | 1,3 MiB            | 7,3 MiB            | 0     | 3             |
| bluetooth-applet                                    | miguel  | Durmiendo | 84,0 MiB        | 8,3 MiB           | 1,6 MiB            | 6,7 MiB            | 0     | 3             |
| metacity                                            | miguel  | Durmiendo | 125,7 MiB       | 11,6 MiB          | 2,5 MiB            | 9,1 MiB            | 0     | 3             |
| update-notifier                                     | miguel  | Durmiendo | 133,7 MiB       | 11,6 MiB          | 2,3 MiB            | 9,3 MiB            | 0     | 3             |
| alarm-clock-applet                                  | miguel  | Durmiendo | 138,2 MiB       | 15,2 MiB          | 5,6 MiB            | 9,6 MiB            | 0     | 3             |
| gnome-panel                                         | miguel  | Durmiendo | 285,9 MiB       | 24,7 MiB          | 8,7 MiB            | 16,0 MiB           | 0     | 3             |
| nautilus                                            | miguel  | Durmiendo | 335,7 MiB       | 41,6 MiB          | 16,6 MiB           | 25,1 MiB           | 0     | 3             |
| nm-applet                                           | miguel  | Durmiendo | 401,1 MiB       | 15,1 MiB          | 4,1 MiB            | 11,0 MiB           | 0     | 3             |
| gvfs-fuse-daemon                                    | miguel  | Durmiendo | 29,4 MiB        | 2,1 MiB           | 232,0 KiB          | 1,9 MiB            | 0     | 0:0           |

Einalizar proceso

# Trucos de gnome-system-monitor

- Parando el ratón sobre una fila muestra la línea de comandos
- Se pueden ordenar los procesos por consumo:
  - Consumo de CPU: %CPU
  - Consumo de memoria (privada): Memoria
- Se puede observar la jerarquía de los procesos
- Se pueden ordenar los procesos por usuario

## top

- Muestra información sobre memoria y uso de CPU

```

Tasks: 172 total,   3 running, 169 sleeping,   0 stopped,   0 zombie
Cpu(s):  5.3%us,   3.4%sy,   0.0%ni, 91.3%id,   0.0%wa,   0.0%hi,   0.0%si,   0.0%st
Mem:   2065240k total, 1724464k used,   340776k free,   265180k buffers
Swap:  3903752k total,   39888k used,  3863864k free,   788740k cached
  PID USER      PR  NI  VIRT  RES  SHR  S  %CPU  %MEM    TIME+  COMMAND
 7570 miguel    20   0  644m 150m  32m  R   8    7.5 355609:00 firefox-bin
 9292 miguel    20   0  135m  14m  10m  S   3    0.7 355573:07 gnome-terminal
14531 miguel    20   0  424m 176m  80m  S   1    8.7 355584:15 soffice.bin
16574 miguel    20   0 97476  21m  17m  S   1    1.0   0:39.24 gnome-system-mo
16627 root      20   0   2464 1208  896  R   1    0.1   0:00.08 top
 1519 avahi     20   0   3744 2208 1204  S   0    0.1 355573:23 avahi-daemon
 2884 miguel    20   0   138m  15m 9840  S   0    0.8 355573:31 alarm-clock-app
 2890 miguel    20   0 18556 2124 1808  S   0    0.1   0:09.82 gvfs-afc-volume
12524 miguel    20   0   138m  21m  13m  S   0    1.0 355573:18 emacs23
15983 miguel    20   0   138m  20m  13m  S   0    1.0   0:09.05 emacs23
    1 root      20   0   2032  620  592  S   0    0.0 355572:54 init
    2 root      20   0     0     0     0  S   0    0.0 355572:53 kthreadd
    3 root      RT   0     0     0     0  S   0    0.0 355572:53 migration/0
    4 root      20   0     0     0     0  S   0    0.0   0:00.46 ksoftirqd/0
    5 root      RT   0     0     0     0  S   0    0.0   0:00.00 watchdog/0
    6 root      RT   0     0     0     0  S   0    0.0 355572:53 migration/1

```

# Top: Opciones de arranque y uso interactivo

- Opciones interesantes de arranque
  - **-d ss.cc** Periodo de refresco en centésimas de segundo
  - **-p** <pid1>,<pid2> Restringir a los pids en cuestion
  - **-H** Mostrar los pthreads que dependen de cada pid
  - **-b** Modo batch
- Teclas en tiempo de ejecución interactivo
  - **h** Ayuda
  - **f** Permite añadir o quitar campos
  - **O** Cambiar el criterio de ordenamiento
  - **o** Elegir el orden de disposición de los campos mostrados
  - **W** Guardar la configuración para futuras llamadas o modo batch

## Top: Valores mostrados por thread

|              |                                                                                                      |
|--------------|------------------------------------------------------------------------------------------------------|
| <b>PID</b>   | Identificador de proceso (o de thread)                                                               |
| <b>PRI</b>   | prioridad de un proceso                                                                              |
| <b>P</b>     | última CPU usada                                                                                     |
| <b>NI</b>    | prioridad "nice" de un proceso                                                                       |
| <b>WCHAN</b> | a qué función espera un proceso                                                                      |
| <b>STAT</b>  | estado del proceso <b>S</b> leep, <b>R</b> unnable, <b>Z</b> ombie, <b>D</b> :sleep no interrumpible |
| <b>%CPU</b>  | utilización de la CPU                                                                                |
| <b>TIME</b>  | tiempo de CPU total                                                                                  |
| <b>TIME+</b> | tiempo de CPU total, en centésimas de segundo                                                        |

|             |                                                                 |
|-------------|-----------------------------------------------------------------|
| <b>%MEM</b> | utilización de la memoria física                                |
| <b>VIRT</b> | memoria virtual total (kb)                                      |
| <b>RES</b>  | memoria física total (kb)                                       |
| <b>SHR</b>  | memoria compartida (kb)                                         |
| <b>SWAP</b> | espacio de SWAP usado (kb)                                      |
| <b>CODE</b> | espacio que usa el código del proceso (kb)                      |
| <b>DATA</b> | espacio que usan los datos (incluido el stack) del proceso (kb) |
| <b>nFLT</b> | número de páginas que deben ser leídas de disco (page faults)   |
| <b>nDRT</b> | número de páginas que deben ser escritas en disco (dirty pages) |

## Personalización de top

- Conviene personalizar la apariencia de top y guardar las opciones pulsando -W
  - La configuración se guarda en **~/toprc**
  - Se mantiene en modo batch. Es la única forma de asegurar que ciertos campos aparezcan en dicho modo.
- Mis preferencias personales:
  - Activar cmdlines completas: **c**
  - Seleccionar los campos:
    - P (processor): **f j**
    - RES (memoria residente): **f Q**
    - eliminar la prioridad (**f H**) quedándome con el nice.
  - Colocar el campo processor antes del nice: **o J J**
  - Activar sumario de CPU's separadas: **1** (el número 1)

# Top -b Modo batch

- Usando la opción -b genera un output parseable y periódico.
  - Muestra siempre los mismos campos (usando el fichero de opciones)
  - Ignora cualquier input de teclado o stdin.
- Invocación clásica

```
nice <prioridad-nice> top -b -H -d <periodo ss.cc> -p <lista_de_pids>
```

- Parámetros:
  - **Swiches:** **-H** muestra pthreads
  - **Periodo:** Elegir en función de la carga a medir y de la métrica.
    - %CPU y tiempos: Periodos largos ya que los tiempo de ejecución son acumulativos.
    - Memoria: Periodos cortos ya que las muestras son instantáneas
  - **prioridad nice:** Cuanto más prioridad (valor más pequeño) más se forzará la periodicidad de muestreo frente a sobrecarga de CPU

## Salida de top modo batch

```
top - 10:46:12 up 17:15, 6 users, load average: 0.92, 0.53, 0.67
Tasks: 13 total, 1 running, 12 sleeping, 0 stopped, 0 zombie
Cpu0  :  3.7%us,  1.3%sy,  0.0%ni, 94.2%id,  0.8%wa,  0.0%hi,  0.0%si,  0.0%st
Cpu1  :  3.1%us,  1.1%sy,  0.0%ni, 95.7%id,  0.1%wa,  0.0%hi,  0.0%si,  0.0%st
Mem:   2064860k total, 1877996k used, 186864k free, 312388k buffers
Swap:  3903756k total,  0k used, 3903756k free, 924988k cached
```

| PID  | USER   | P | NI | VIRT | RES | SHR | S | %CPU | %MEM | TIME+    | COMMAND |
|------|--------|---|----|------|-----|-----|---|------|------|----------|---------|
| 6375 | miguel | 0 | 0  | 725m | 26m | 13m | R | 100  | 1.3  | 34:28.08 | java    |
| 6307 | miguel | 0 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:00.00  | java    |
| 6312 | miguel | 1 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:04.43  | java    |
| 6313 | miguel | 1 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:00.00  | java    |
| 6314 | miguel | 0 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:00.00  | java    |
| 6315 | miguel | 1 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:00.11  | java    |
| 6316 | miguel | 0 | 0  | 725m | 26m | 13m | S | 0    | 1.3  | 0:00.00  | java    |

- **Consejos para parsear**
  - Cada bloque de muestreo comienza en una línea con la palabra “top”
  - Seguido del top está el timestamp del momento de muestreo
  - Después de la siguiente línea vacía se encuentran las cabeceras de los campos
  - Cada valor de campo de cada thread está separado por espacios salvo el COMMAND al final.

# htop

- Versión “mejorada” de top basada en ncurses
- Ventajas sobre top
  - Es más interactivo y resumido
  - Permite seleccionar thread's para cambiarles la prioridad, afinidad...
  - Permite mostrar la jerárquica de procesos y thread
  - Se puede llamar directamente a strace y ltrace para trazar llamadas del sistema y de librerías
- Desventaja: No se puede exportar directamente el texto
  - Si se redirige la salida a fichero aparecen códigos de escape ANSI
    - Existen formas de filtrarlo (ej: paquete PERL)
  - Se puede copiar-pegar seleccionando con el ratón **mientras se pulsa SHIFT**

# Personalización de htop

- Pulsando **S** (mayúscula) se accede a la pantalla de personalización.
  - La personalización se mantiene entre ejecuciones en **./~htopr**
- Mi personalización personal
  - Métricas: Añadir el hostname a la parte derecha del sumario
  - Display options:
    - Tree view ON
    - Hide kernel threads OFF
    - Display threads in different color ON
    - Show custom thread names ON
    - Highlight program basename ON
    - Detailed CPU time ON
  - Columns: Añadir PROCESSOR, TPGID

# ps: Queries sobre procesos

```
ps [opciones] [PID]
```

- Comando para hacer queries sobre procesos
  - **-A** Todos los procesos
  - **-F** Incluir todos los detalles
  - **-L** Incluir los pthreads
- Todos threads del sistema

```
ps -ALF
```

- Grep is your friend!!

```
ps -ALF | grep `whoami`
```

## ¿Cual usar?

|                        | Ventajas                                                                                                 | Inconvenientes                                                                     | Aplicación                                                           |
|------------------------|----------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------|----------------------------------------------------------------------|
| <b>top</b>             | Modo batch<br>Salida parseable                                                                           | No muestra todos los threads<br>No tiene modo jerárquico<br>No muestra la afinidad | Muestreo periódico de pids conocidos                                 |
| <b>htop</b>            | Muestra todos los threads<br>Buen modo interactivo<br>Fácil de usar<br>Interfaz con strace, lsof, ltrace | No es fácil de parsear                                                             | Vigilancia interactiva<br><br>Toma de comandos (prioridad, afinidad) |
| <b>ps</b>              | Muestra todos los threads<br>Muestra toda la información                                                 | Opciones de comando complicadas<br>No tiene muestreo periódico                     | Queries rápidas de estado                                            |
| <b>gnome sys monit</b> | Gráfico en tiempo real<br>Re-ordenamiento con un click<br>Muestra los mapas de memoria                   | No muestra los pthreads<br>No exporta los datos<br>Poco flexible en visualización  | Gráficos de consumo en tiempo real                                   |

## /usr/bin/time

- Esta herramienta mide tiempos de ejecución asociados a una aplicación distinguiendo tiempo de sistema y de usuario
  - `/usr/bin/time -v <comando> <argumentos>`
    - `-v` : Muestra el significado de cada campo
- **Nota:** No confundir con el comando **time** de la shell **bash**,
  - Ejecutar siempre especificando el path completo
- Información extra obtenida
  - Fallos de página de acceso a memoria
  - Número de “swaps”
  - Cambios de contexto

# Herramientas de información global

- vmstat
  - sar
  - iostat
  - mpstat
- 
- Todas ellas informan de parámetros globales a la plataforma
    - Más orientadas a la configuración del sistema

---

# Referencias

---

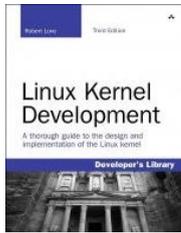
# Libros sobre performance en Linux

- IBM Redbook: Eduardo CLIENDO, Takechica KUNIMASA, *Linux Performance and Tuning Guidelines, 2007* Descargable libremente
  - Explica el funcionamiento del kernel en aspectos como memoria e I/O
  - Detalla herramientas de línea de comando y benchmarks estándares
  - Da consejos de configuración del kernel
- Mark WILDING Dan BEHMAN, *Self service Linux: Mastering the Art of Problem Determination* Prentice Hall 2006. Bruce Perens Open Source series. ISBN 978-0-13-147751-3 Descargable libremente
  - Más orientado a desarrollo y a traceado de bajo nivel
  - Detalla el formato ELF y conceptos de debugueo
  - Al final lista diferentes herramientas de monitorización y da un script para captura de datos.



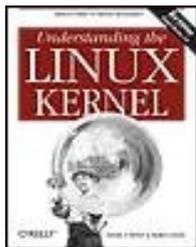
# Libros Genéricos sobre el Kernel

- Robert LOVE, *Linux Kernel Development*, 3<sup>rd</sup> Edition Addison-Wesley 2010, ISBN 978-0-672-32946-8



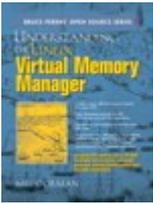
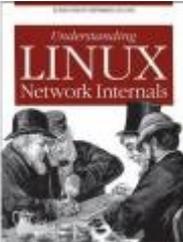
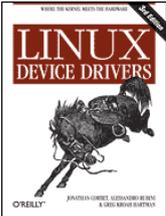
- Abarcable y sencillo de leer.
- Punto de vista: Desarrollador que quiere **añadir código propio** al kernel y utilizar algunos servicios sin interferir en el funcionamiento normal.
- Aunque es una edición reciente, hay muchas novedades del kernel (ftrace, hrtimers, Xen) que no se han añadido.
- Un buen review del libro en LWN.net <https://lwn.net/Articles/419855/>

- Daniel POVET, Marco CESATI, *Understanding the Linux Kernel*, 3<sup>rd</sup> Edition O'Reilly 2005 ISBN 978-0-596-00565-2. Disponible en [google books](#). UTLK3



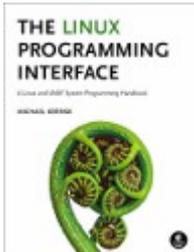
- Muy completo pero denso de leer y digerir
- Punto de vista: Investigador o estudiante que quiere **entender como funciona el kernel por dentro** para diagnosticar problemas o copiar las técnicas en otros ámbitos.
- Aunque tiene ya 6 años, la filosofía del kernel sigue siendo la misma, si bien los procedimientos de funcionamiento que detalla el libro pueden haber evolucionado

# Libros puntuales sobre el kernel

- Mel GORMAN, *Understanding Linux Virtual Memory Manager* Prentice Hall 2004. Bruce Perens Open Source series. ISBN 978-0-13-145348-7  
Descargable libremente  

  - Detalla como el kernel gestiona la memoria. Como siempre las implementaciones evolucionan pero el espíritu se mantiene.
- Christian BENVENUTI, *Understanding Linux Network Internals*, O'Reilly 2006, ISBN 978-0-596-00255-8. Disponible en Google books  

  - Único libro escrito sobre el forrogoso tema del tratamiento de redes y protocolos en Linux. Se concentra en las capas de red y bridges (IP, ruteo, ARP...) pero omite aspectos importantes como TCP o Traffic Control.
  - Critica en LWN.net: <http://lwn.net/Articles/168894/>
- Jonathan CORBET, Alessandro RUBINI, Greg Kroah-Hartman, *Linux Device Drivers* 3<sup>rd</sup> Edition, O'Reilly 2005, ISBN-978-0-596-00590-3 Descargable libremente  

  - Libro pensado directamente para escribir código en el kernel, sin especificar el funcionamiento de algunos mecanismos. En este aspecto se muy bien con UTLK 3<sup>rd</sup>.

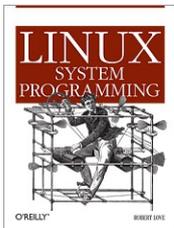
# Libros sobre programación de sistema

- Michael KERRISK, *The Linux Programming Interface* No Starch Press 2010 ISBN 978-1-59327-220-3. Sitio web de soporte



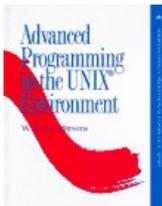
- Cubre un **amplio** espectro de programación en sistema de una manera **precisa** y fácil de leer.
- Cubre el caso de Linux y diferencia otros Unixes y BSD.
- Critica en LWN.net: <http://lwn.net/Articles/423417/>

- Robert LOVE, *Linux System Programming*, O'Reilly 2007, ISBN 978-0-59600-958-8. Sitio web de soporte



- Más sencillo y ligero que el LTPI pero menos riguroso y completo
- Critica en LWN.net: <http://lwn.net/Articles/168894/>

- W. Richard STEVENS, *Advanced programming in the Unix Environment* Addison-Wesley 1992, ISBN 0-201-56317-7. Sitio web de soporte



- Clásico, fácil de leer y se toma aún como referencia
- Anterior al crecimiento de Linux, pero aún válido para la mayoría de los usos