Departament d'Arquitectura de Computadors

UNIVERSITAT POLITÈCNICA DE CATALUNYA

Conceptes Avançats de Sistemes Operatius

FIB, DAC, UPC

Curs 2022/23 Q2

Suport per Temps Real

UNIVERSITAT POLITÈCNICA DE CATALUNYA
BARCELONATECH
Facultat d'Informàtica de Barcelona

Índex

Definició

- Real-time software
  - must deliver computation results
    - under application specific time constraints
  - fails when a result is made available too late
    - (or too early in some systems)
      $\rightarrow$ even if the result is otherwise correct

`http://www.on-time.com/rtos-32-docs/rtkernel-32/programming-manual/tasking/real-time.htm`

Temps Real

- Execució dels processos
  - A temps, complint el deadline
  - Sense ser interromputs per altres processos (menys prioritaris)
- Hard
  - Perdre un deadline significa una fallada total del sistema
- Firm
  - Es poden tolerar algunes pèrdues de deadline
  - La utilitat dels resultats es nul·la si arriben després del deadline
- Soft
  - La utilitat dels resultats decau quan més tard arriben
  - Linux

`http://en.wikipedia.org/wiki/Real-time_computing`

Exemples

- Hard
  - Control del motor d'un cotxe, frens anti-lliscament
  - Sistema de control d'un avió
  - Control d'un marcapassos
- Firm real-time?
  - Video rendering (també soft?)
- Soft real-time
  - Manteniment dels plans de vol de companyies aèries
    - Latència de segons admisible
  - Reproducció d'audio i vídeo (també firm?)
    - Degradació de la qualitat admisible (sala de cinema?)

`http://stackoverflow.com/questions/17308956/differences-between-hard-real-time-soft-real-time-and-firm-real-time`

Conceptes

- Planificació per prioritats
  - Segons la importància de cada tasca
- Deadline
  - Assignat a una tasca, és el temps màxim en el qual la tasca s'ha d'haver executat, per tal que el sistema pugui continuar funcionant
- Deadline miss
  - Pèrdua del deadline en una tasca
  - Les conseqüències poden ser greus hard, firm, soft...

Conceptes

- Tasques periòdiques
  - Són aquelles que es repeteixen indefinidament
  - Seguint un període d'activació
  - Habitualment responen a un event extern

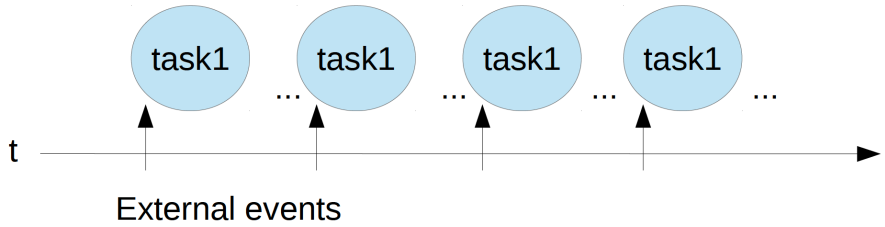

- Tasques aperiòdiques
  - Les tradicionals, que comencen i acaben, sense repetir-se necessàriament

Conceptes

- Jitter: la variació en el temps d'execució d'un procés, deguda a la seva interacció amb
  - Altres processos
  - Interrupcions

Conceptes

- Jitter: la variació en el temps d'execució d'un procés, deguda a la seva interacció amb
  - Altres processos
  - Interrupcions

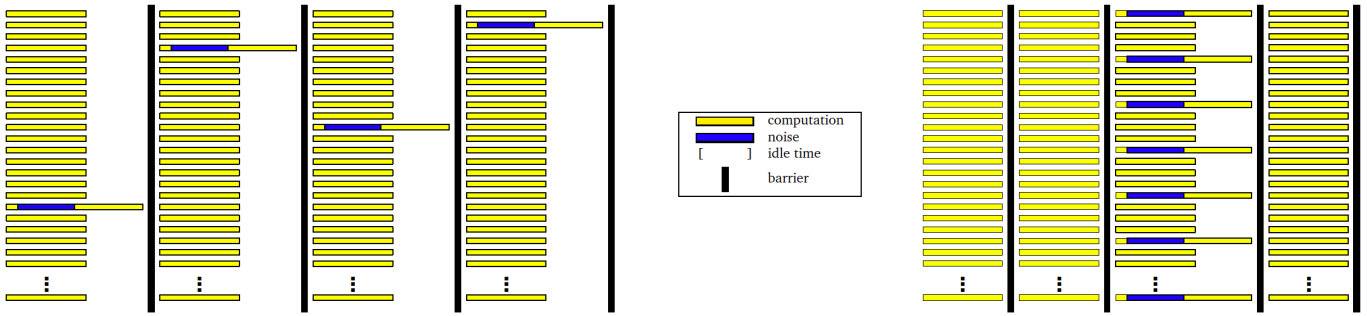

(a) Uncoordinated noise

(b) Coscheduled noise

Petrini, F., Kerbyson, D. J., & Pakin, S. (2003, November). The case of the missing supercomputer performance: Achieving optimal performance on the 8,192 processors of ASCI Q. In *SC'03: Proceedings of the 2003 ACM/IEEE conference on Supercomputing* (pp. 55-55). IEEE.
doi: http://dx.doi.org/10.1145/1048935.1050204

Comparativa OS - RTOS

- Multitasking
  - (GP)OS: per donar igual tractament a tots els usuaris/processos/fluxos (fairness, time sharing)
  - RTOS: usen les prioritats dels processos/fluxos de forma estricta
- Sobrecàrrega del sistema
  - OS: permesa
  - RTOS: no permesa
    - La sobrecàrrega anirà acompanyada de pèrdues de deadlines

Classificació

- Cokernels: al costat del Linux tenim un altre kernel (cokernel, pico-kernel, nano-kernel, o dual kernel)
  - Capa entre el GPOS i el hardware. Fa servir crides al sistema especialitzades.
  - *Interrupt dispatcher* i *scheduler*. Molt associat a una versió de kernel de Linux.
  - Captura les interrupcions i les envia cap a les tasques RT o bé cap al Linux.
  - Exemples: ADEOS (Xenomai, RTAI) i RTLinux.
- Patch al kernel de Linux. Un kernel de sol.
  - Augmenta el grau d'apropiació del codi kernel de Linux actual.
  - Permet als desenvolupadors explotar l'entorn de programació de Linux
  - Exemple: PREEMPT_RT

RTOS Scheduler

- Té en compte la prioritat dels processos i el seu estat
  - *Running* ... en un processador
  - *Ready* ... no s'executen, però estan a punt
  - *Suspended* ... (`task_suspend / task_resume`)
  - *Blocked* ... esperant un event
  - *Timed* ... esperant un event, amb timeout
  - *Delaying* ... esperant que passi un temps (timer)
- Els canvis d'estat són produïts per events externs o per una altra task

`http://www.on-time.com/rtos-32-docs/rtkernel-32/programming-manual/tasking/tasks.htm`

RTOS Scheduler

Regles que implementa

- Els N processos (*ready*) amb més prioritat corren
  - tenint N processadors disponibles
- Si s'ha de triar entre diversos processos que tenen la mateixa prioritat, s'escull aquell que fa més temps que no s'ha activat
- Si diversos processos estan esperant (*blocked*) un event, s'activen quan passa l'event respectiu, en l'ordre fixat per la seva prioritat
- En el moment en que la primera regla no és certa, es fa un canvi de context a un altre procés (més prioritari)

Polítiques de planificació

- Rate-monotonic scheduling (RMS)
  - Per tasques periòdiques
  - La prioritat és estàtica i és la freqüència de la tasca
  - Sempre s'executarà la tasca amb la freqüència més alta

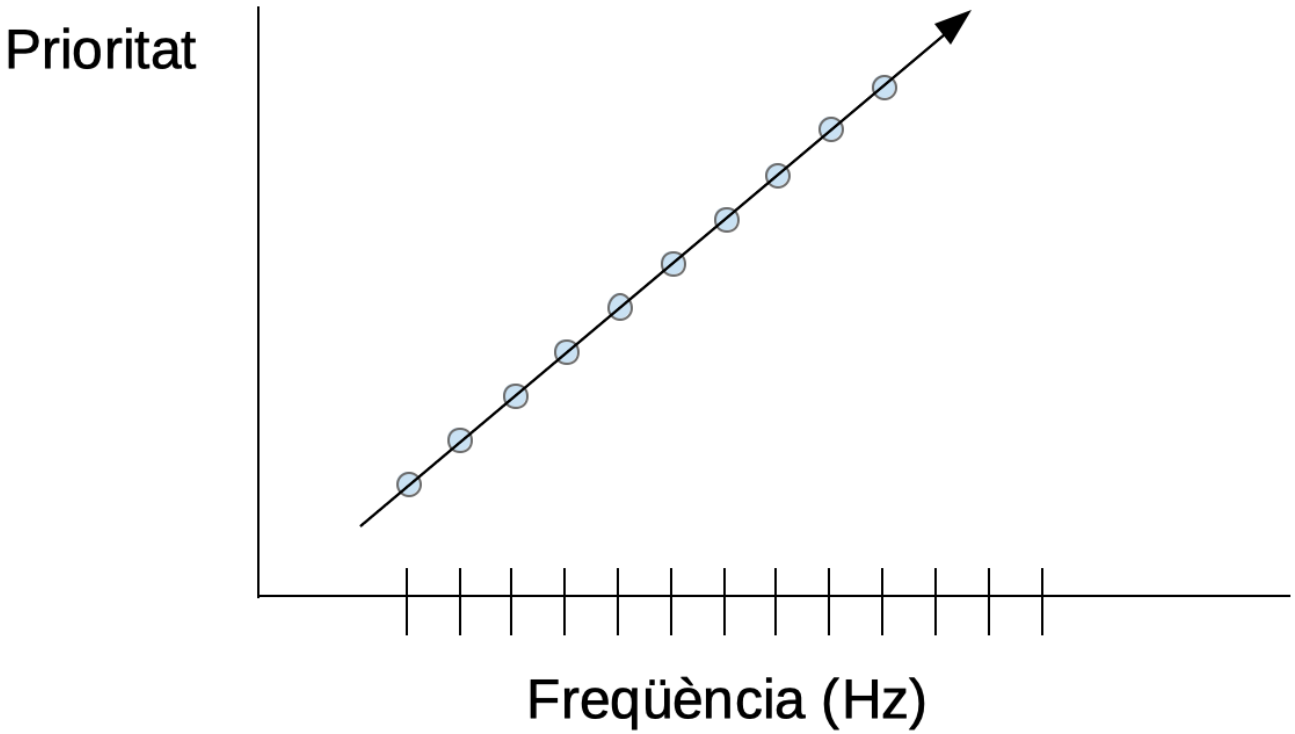

Exemple (prioritats manuals)

- P1: freqüència 2/100, durada: 20, prioritat "low"
- P2: freqüència 1/100, durada: 40, prioritat "high"

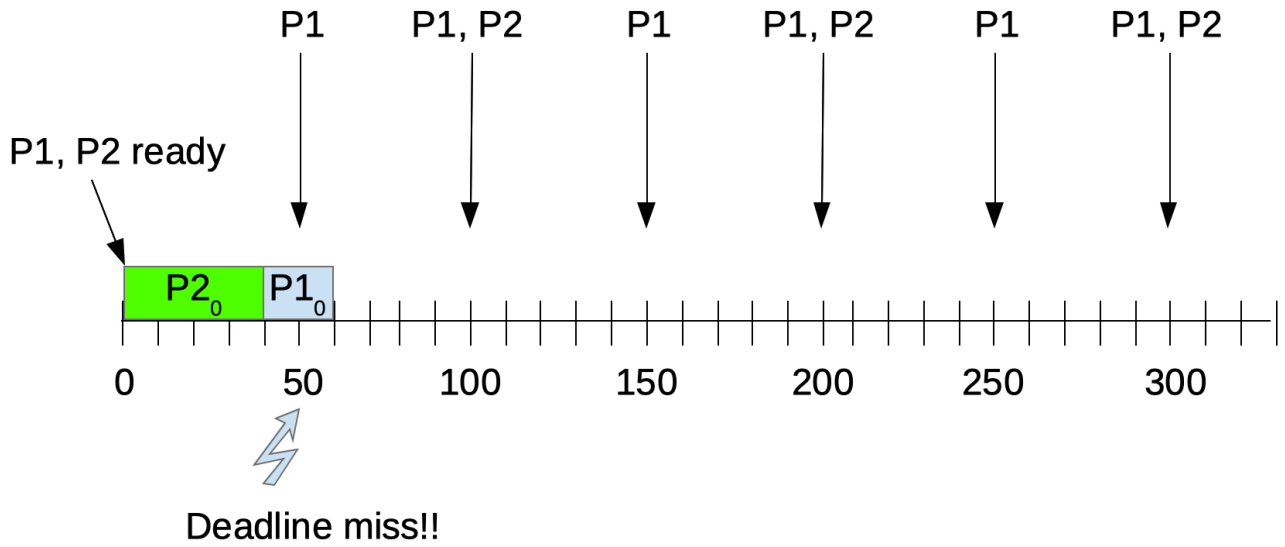

- Lliçó: segons com s'assignen les prioritats, no es compleixen els deadlines

Exemple Rate Monotonic

- P1: freqüència 2/100, durada: 20, prioritat 2
- P2: freqüencia 1/100, durada: 40, prioritat 1

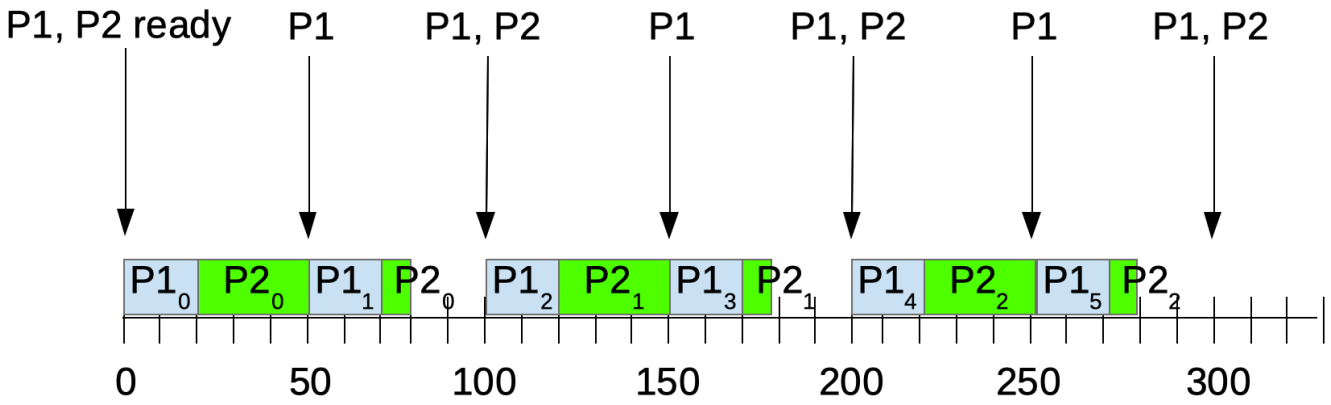

- Lliçó: executar primer la que pot tornar a demanar execució abans

Polítiques de planificació

- Earliest Deadline First
  - Per tasques periòdiques
  - La prioritat és dinàmica
  - Depèn de quan proper és el deadline de la tasca
    $\rightarrow$ Inversament proporcional al temps que falta pel deadline
  - Cada vegada que la tasca es desbloqueja ha d'indicar el seu deadline al sistema
- Exemple:
  P1, prioritat $1/50$
  P2, prioritat $1/100$
  $1/50 > 1/100 \rightarrow$ s'executa primer P1
  - Representació com en el dibuix anterior

Temps real

- Soft, linux amb suport per temps real
  - Arch Linux
    `https://wiki.archlinux.org/index.php/Realtime_process_management`
  - Debian
    `http://www.pengutronix.com/software/linux-rt/debian_en.html`
    `http://www.ptxdist.org/`
  - Suse `https://www.suse.com/products/realtime/`
  - RedHat `https://access.redhat.com/documentation/en-us/red_hat_enterprise_linux_for_real_time/`
  - Ubuntu `https://wiki.ubuntu.com/RealTime`

PAM - pluggable authentication modules

- Permet configurar els límits dels processos
  - `MEMLOCK`, quantitat de memòria virtual que pot fixar-se a memòria física
  - `NICE`, màxim valor per a la prioritat d'usuari $0 \ldots 40$
  - `RTPRIO`, màxim valor de prioritat de temps real que pot tenir el procés
- Defineix classes de prioritats per a l'E/S
  - Realtime: `IOPRIO_CLASS_RT`, preferent per accedir al disc
  - Best effort: `IOPRIO_CLASS_BE`, classe per defecte
- Arch Linux, Gentoo

Problemàtica

- Inversió de prioritats (*priority inversion*)
  - Es dóna quan un flux més prioritari espera per entrar en una regió crítica que té un flux menys prioritari
  - O bé espera per usar un recurs – o dispositiu – que està ocupat per un flux menys prioritari
- Solució: herència de prioritat
  - si es dóna el cas, transferir la prioritat del flux més prioritari, al flux menys prioritari per tal que surti de la regió tan aviat com pugui

Problemàtica

- Inversió ilimitada de prioritats (*unbounded priority inversion*)
  - S'afegeix una tasca (o grup de tasques) intermitja que endarrereix encara més l'execució d'una tasca més prioritària
- Solucions:
  - herència de prioritat
  - sostre de prioritat (*priority ceiling*): cada recurs té una prioritat. Se li assigna un nivell superior (*ceiling*) al de la tasca més prioritària que l'usa. En usar-lo, totes les tasques s'executen en aquest nivell de prioritat

Exemple: Mars Pathfinder

- Inici de la missió: 4 de desembre de 1996
- Arribada a Mart: 4 de juliol de 1997
- Temps previst d'operations: entre 1 setmana i un mes
- Temps final d'operacions: 3 mesos
- Probable fallada: bateria

Font: NASA

Exemple: Mars Pathfinder

- Inversió ilimitada de prioritats

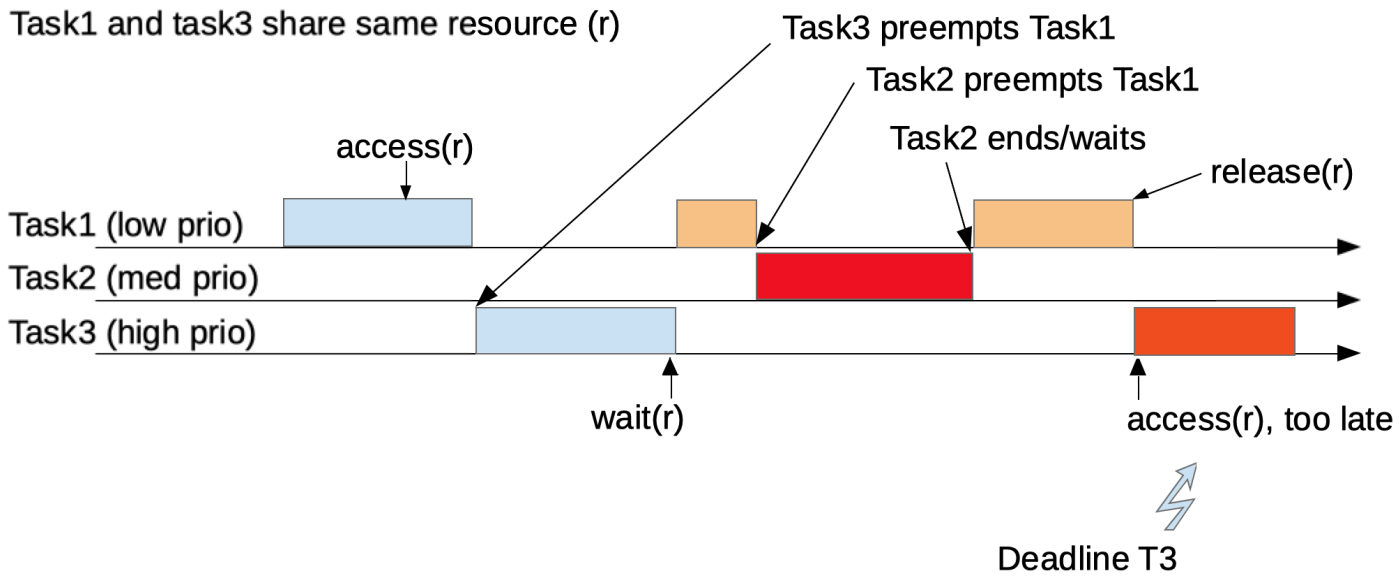

Font: Operating System Concepts, Silberschatz, Galvin, Gagne, Wiley & Sons, 2010

Exemple: Mars Pathfinder

- Tasques en el Mars Pathfinder
  - Information bus management task high priority
    - Bloqueja el bus i posa/treu dades
  - Communications task medium priority
    - Pot trigar una estona ...
    - No necessàriament usa el bus
  - Meteorological data collection task low priority
    - Bloqueja el bus i hi publica les dades recollides
- El mutex que protegeix el bus està inicialitzat sense herència de prioritats

https://sites.fas.harvard.edu/ libe251/fall2019/mars.tx

Exemple: Mars Pathfinder

- La solució va consistir en reinicialitzar el mutex amb herència de prioritats
  - VxWorks tenia l'opció de debug activada
  - Això va permetre canviar la inicialització del mutex

The JPL[1] engineers fortuitously decided to launch the spacecraft with this feature still enabled

`https://sites.fas.harvard.edu/~libe251/fall2019/mars.txt`

[1] Jet Propulsion Laboratory

Exemple: Mars Pathfinder

Font: Operating System Concepts, Silberschatz, Galvin, Gagne, Wiley & Sons, 2010

- Amb herència de prioritats

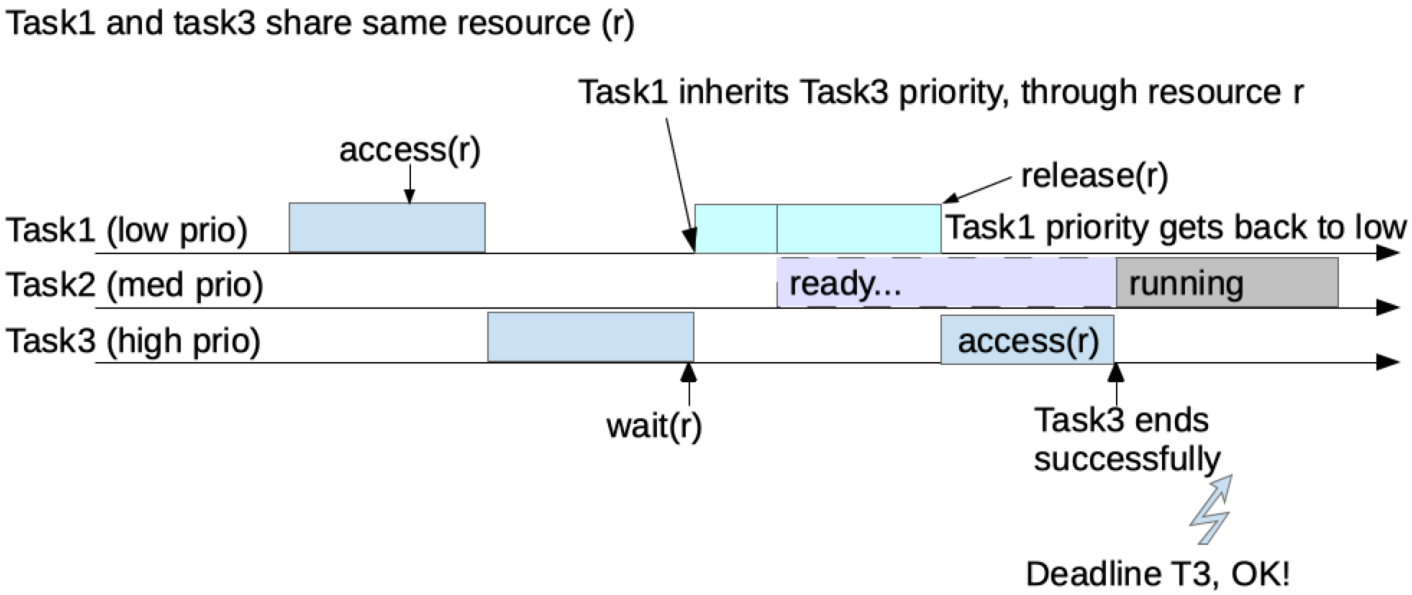

Exemple: Mars Pathfinder

- Solució alternativa
  - Priority ceiling: assignar prioritats més altes també als recursos

r1	200
r2	150
r3	125
r4	100
MAX_TASK_PRIORITY	99
HIGH_PRIORITY	75
MED_PRIORITY	50
LOW_PRIORITY	25
IDLE_PRIORITY	0

  - Les tasques hereden la prioritat del recurs al que accedeixen en exclusió mútua

Font: Operating System Concepts, Silberschatz, Galvin, Gagne, Wiley & Sons, 2010

Exemple: Mars Pathfinder

- Priority ceiling:

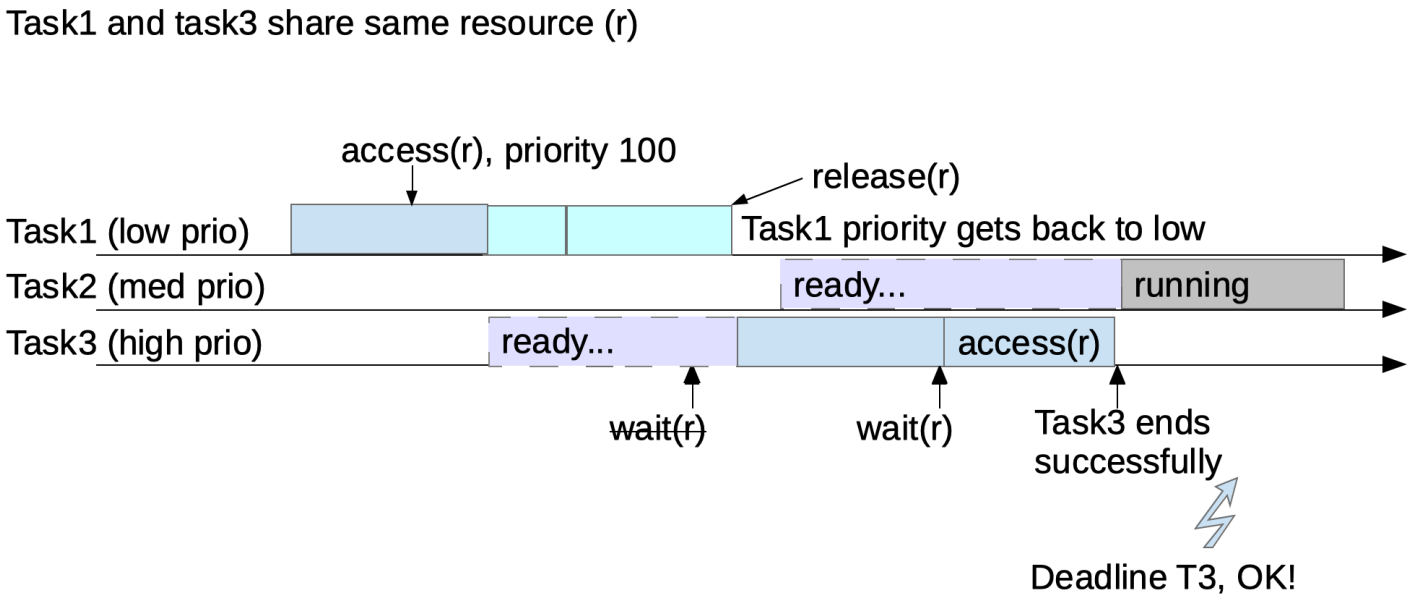

Font: Operating System Concepts, Silberschatz, Galvin, Gagne, Wiley & Sons, 2010

Activitat

- Control 24-4-2015

Task1 and task3 share same resource (r)
Task1 (low prio)
Task2 (med prio)
Task3 (high prio)

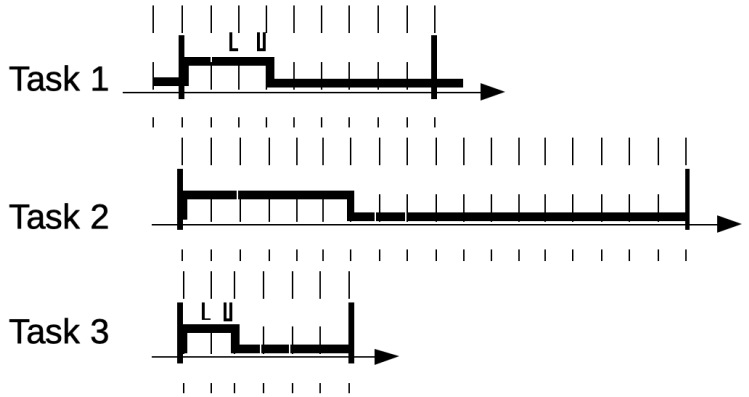

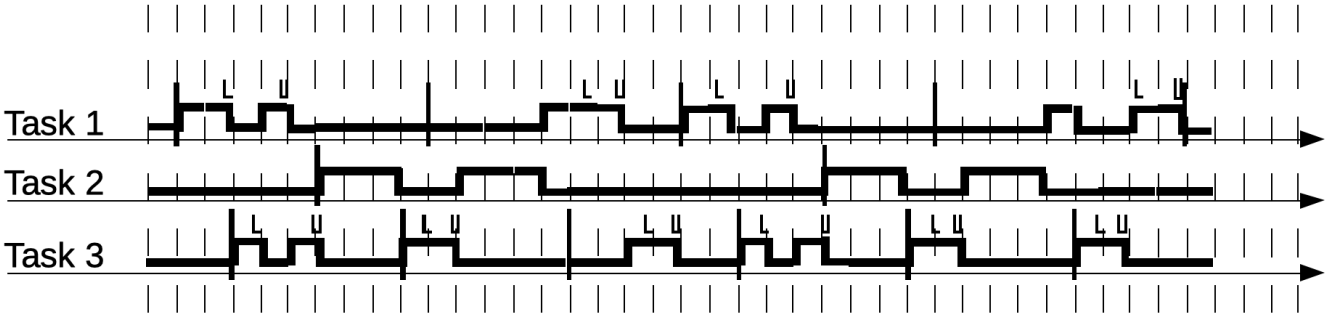

És correcte o hi ha alguna pèrdua de deadline?

Solució

- Control 24-4-2015

Task1 and task3 share same resource (r)
Task1 (low prio)
Task2 (med prio)
Task3 (high prio)

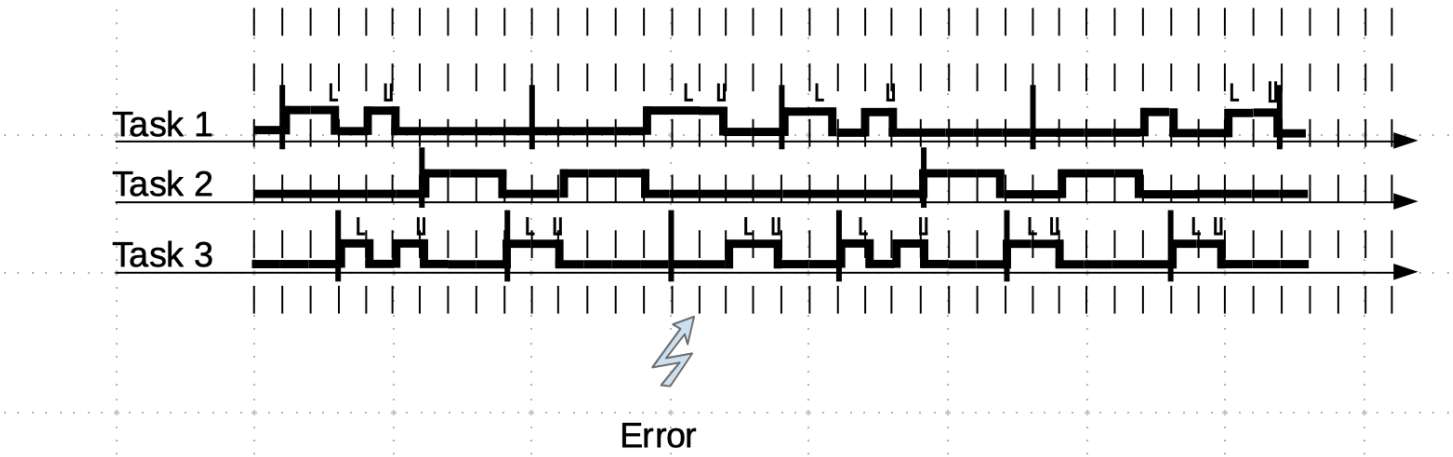

RT-Preempt

- Proporciona característiques de hard real time a Linux
  - Permet que les regions crítiques puguin patir preempcions
    - Manté les que han de ser no-preemptibles
  - Implementa herència de prioritats pel kernel
    - spinlocks
    - semàfors
  - Converteix els gestors d'interrupcions en fluxos
    - Se'ls pot canviar la prioritat
  - Afegeix rellotges d'alta resolució
- Debian, Suse, Ubuntu

Preempt setup (4.4.12)
Preempt application base

RT-Preempt

- Incorpora idees de temps real a Linux
  - Patch al kernel, bastant actualitzat (3.10 $\rightarrow$ 4.4 Apr 2016)
  - Suporta herència de prioritats
    - Soluciona el problema d'inversió de prioritats
- Xenomai pot basar-se en RT-Preempt
  - i proporcionar interfícies diferents
    - VxWorks
    - QNX
    - ...
- `https://www.kernel.org/pub/linux/kernel/projects/rt/`
- `https://wiki.linuxfoundation.org/realtime/documentation/howto/applications/preemptrt_setup`

RT-Preempt

- Herència de prioritats en el `pthread_mutex`
  - Basada en un nou atribut
    - `PTHREAD_PRIO`
      → `NONE` ..... mutex normal
      → `INHERIT` ... el flux executant la regió crítica ha de tenir la més alta entre les prioritats (seva, dels altres fluxos esperant a qualsevol dels mutex amb `PTHREAD_PRIO_INHERIT` que tingui el flux)
      → `PROTECT` ...
  - I la implementació ha d'assegurar que la prioritat es transmet recursivament si el flux que ha heredat la prioritat es bloqueja en un altre mutex

RT-Preempt

- Herència de prioritats
  - `PTHREAD_PRIO_PROTECT`
    - usa la prioritat indicada a l'atribut ceiling del mutex
    - per evitar inversió de prioritats, inicialitzar el ceiling com a més gran o igual a les prioritats dels fluxos que poden agafar aquest mutex
    - i si em bloquejo en un mutex amb ceiling inferior, mantinc la prioritat superior!!!

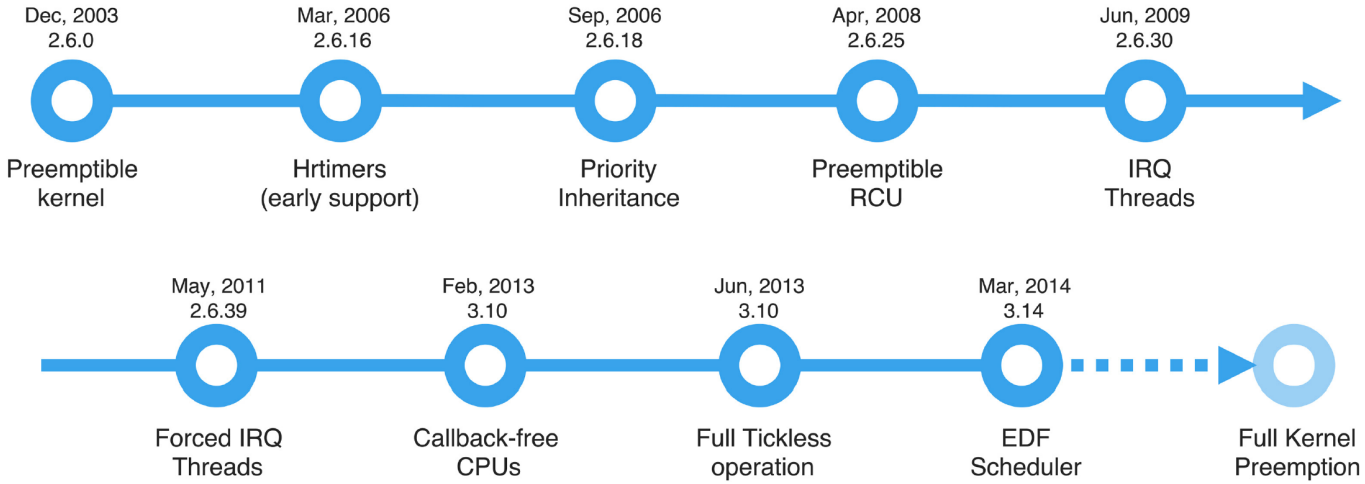

Font:Reghenzani, F., Massari, G., & Fornaciari, W. (2019). The real-time linux kernel: A survey on preempt_rt. *ACM Computing Surveys (CSUR)*, 52(1), 1-36. https://doi.org/10.1145/3297714

Open Source Automation Development Lab

- Realtime-Preempt Kernel Patch
  - Deterministic scheduler
  - Preemption support
  - PI mutexes
  - High-Resolution timer
  - Preemptive Read-Copy update
  - IRQ threads
  - Raw Spinlock annotation
  - Forced IRQ threads
  - R/W semaphore cleanup
  - Full Realtime preemption support

`https://www.osadl.org/Realtime-Linux.projects-realtime-linux.0.html`

Deterministic scheduler

- Gran número d'alternatives:
  - EDF, Earliest Deadline First
    - Schedule the task who's deadline will expire first
    - Runs work as soon as possible
  - LLF, Least Laxity First (nom terriblement dolent)
    - Schedule the task that has least room to still make its deadline
    - Runs work as late as possible

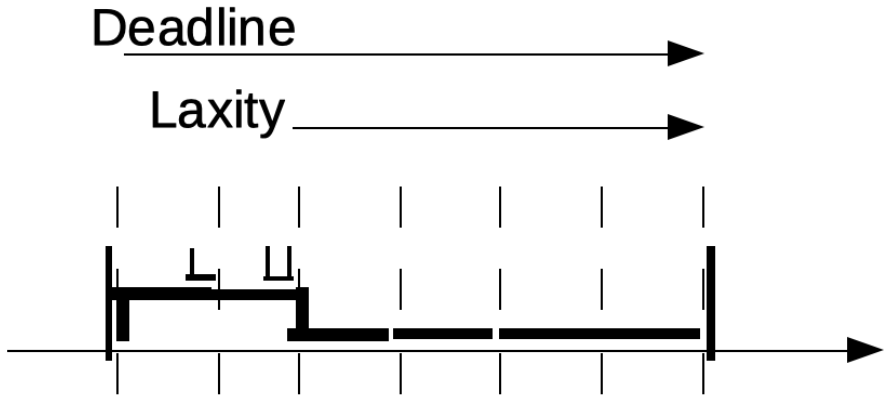

https://www.osadl.org/fileadmin/dam/presentations/RTLWS11/peterz-edf-why-not.pdf
http://class.ece.iastate.edu/cpre458/cpre558.F00/notes/new-rts-lect03.ppt

RT-Preempt

- cyclictest
  - Linux 3.10.17-rt12-smp PREEMPT RT – Atom N455

```
$ cyclictest -a -t -n -p 99

policy: fifo: loadavg: 1.98 1.60 0.99 2/329 1299

T: 0 ( 1144) P:99 I:1000 C: 503964 Min:  4 Act:  26 Avg:  33 Max: 3354
T: 1 ( 1145) P:99 I:1500 C: 335976 Min: 11 Act:  64 Avg:  40 Max: 2535

policy: fifo: loadavg: 0.65 0.78 0.83 2/355 1339

T: 0 ( 1301) P:99 I:1000 C: 816333 Min: 10 Act:  22 Avg: 31 Max: 3803
T: 1 ( 1302) P:99 I:1500 C: 544222 Min:  7 Act:  24 Avg: 33 Max: 2787

policy: fifo: loadavg: 0.58 0.91 1.16 1/387 3784

T: 0 ( 1919) P:99 I:1000 C:2363722 Min: 8 Act: 33 Avg: 30 Max: 4550
T: 1 ( 1920) P:99 I:1500 C:1575814 Min: 7 Act: 35 Avg: 29 Max: 3860
```

RT-Preempt

- cyclictest
  - Linux 3.9.10-smp SMP – Atom N455

```
$ cyclictest -a -t -n -p 99

policy: fifo: loadavg: 0.77 0.58 0.42 2/432 2826

T: 0 ( 2742) P:99 I:1000 C: 232419 Min:  11 Act: 28 Avg: 32 Max: 10589
T: 1 ( 2743) P:99 I:1500 C: 154946 Min:  11 Act: 31 Avg: 37 Max: 19370

policy: fifo: loadavg: 1.68 0.94 0.57 1/377 2871

T: 0 ( 2828) P:99 I:1000 C: 119921 Min:  10 Act: 22 Avg: 40 Max: 15604
T: 1 ( 2829) P:99 I:1500 C:  79947 Min:  11 Act: 28 Avg: 32 Max: 11860

policy: fifo: loadavg: 1.57 1.24 0.77 2/370 2899

T: 0 ( 2873) P:99 I:1000 C: 234043 Min:  10 Act: 28 Avg: 36 Max: 16849
T: 1 ( 2874) P:99 I:1500 C: 156029 Min:  10 Act: 21 Avg: 36 Max: 15801
```

RT-Preempt

- cyclictest
  - Linux 3.10.17-smp SMP – Atom N455

```
$ cyclictest -a -t -n -p 99

policy: fifo: loadavg: 0.08 0.17 0.27 2/308 1235

T: 0 ( 1234) P:99 I:1000 C: 18505 Min: 12 Act: 22 Avg: 49 Max: 16688
T: 1 ( 1235) P:99 I:1500 C: 12335 Min: 12 Act: 40 Avg: 34 Max:  6511

policy: fifo: loadavg: 0.47 0.29 0.30 2/309 1239

T: 0 ( 1238) P:99 I:1000 C: 134952 Min: 11 Act: 26 Avg: 35 Max: 15992
T: 1 ( 1239) P:99 I:1500 C:  89968 Min: 11 Act: 31 Avg: 30 Max:  4339

policy: fifo: loadavg: 0.47 0.38 0.33 4/308 1242

T: 0 ( 1241) P:99 I:1000 C: 258467 Min: 11 Act: 33 Avg: 32 Max: 16334
T: 1 ( 1242) P:99 I:1500 C: 172311 Min: 10 Act: 67 Avg: 38 Max: 16283
```

RT-Preempt

- cyclictest
  - Linux 3.2.23 SMP – Core2 Duo P9400

```
$ cyclictest -a -t -n -p 99

T: 0 (30397) P:99 I:1000 C: 145316 Min:  4 Act:   18 Avg:   18 Max:  15646
T: 1 (30398) P:99 I:1500 C:  96877 Min:  4 Act:   13 Avg:   10 Max:   2670
```

RT-Preempt

- cyclictest
  - Linux 3.2.23 SMP – Core2 Duo P9400

```
$ cyclictest -a -t -n -p 99

T: 0 (30397) P:99 I:1000 C: 145316 Min:  4 Act:   18 Avg:   18 Max:  15646
T: 1 (30398) P:99 I:1500 C:  96877 Min:  4 Act:   13 Avg:   10 Max:   2670
```

RT-Preempt

- cyclictest
  - Linux 3.14.33 #2 SMP i5-4210U CPU @ 1.70GHz

```
bash-4.3$ sudo ./cyclictest -a -t -n -p99
# /dev/cpu_dma_latency set to 0us
policy: fifo: loadavg: 0.16 0.08 0.06 2/437 4336

T: 0 ( 4329) P:99 I:1000 C: 116458 Min:  1 Act:    3 Avg:    2 Max:  184
T: 1 ( 4330) P:99 I:1500 C:  77638 Min:  2 Act:    2 Avg:    2 Max:   52
T: 2 ( 4331) P:99 I:2000 C:  58229 Min:  1 Act:    5 Avg:    2 Max:   16
T: 3 ( 4332) P:99 I:2500 C:  46583 Min:  1 Act:    4 Avg:    2 Max:   54
```

KERNELGIT=git://git.kernel.org/pub/scm/linux/kernel/git
git clone $KERNELGIT/clrkwllms/rt-tests.git

sudo apt install rt-tests

RT-Preempt

- cyclictest
  - Linux 4.4.0-Microsoft i7-8565U CPU @ 1.80GHz

```
WARN: stat /dev/cpu_dma_latency failed: No such file or directory
WARN: High resolution timers not available
policy: fifo: loadavg: 0.52 0.58 0.59 2/16 736
T: 0 (  727) P:99 I:1000 C: 703142 Min: 5 Act:  112 Avg:  310 Max:  18127
T: 0 (  727) P:99 I:1000 C:4581577 Min: 1 Act:  275 Avg:  321 Max:  85857
T: 1 (  728) P:99 I:1500 C:3055512 Min: 2 Act:   76 Avg:  325 Max:  84838
T: 2 (  729) P:99 I:2000 C:2292203 Min: 5 Act:   83 Avg:  323 Max:  85621
T: 3 (  730) P:99 I:2500 C:1833956 Min: 5 Act:  343 Avg:  325 Max:  85105
T: 4 (  731) P:99 I:3000 C:1528420 Min: 5 Act:  740 Avg:  322 Max:  84488
T: 5 (  732) P:99 I:3500 C:1310132 Min: 5 Act:  142 Avg:  326 Max:  83867
T: 6 (  733) P:99 I:4000 C:1146414 Min: 5 Act:  488 Avg:  329 Max:  85207
T: 7 (  734) P:99 I:4500 C:1019048 Min: 7 Act:  836 Avg:  325 Max:  84612
```

RT-Preempt

- cyclictest, with latency threshold
  - Linux 3.14.33 #2 SMP i5-4210U CPU @ 1.70GHz

```
bash-4.3$ sudo ./cyclictest -a -t -n -p99 -f -b100
# /dev/cpu_dma_latency set to 0us
policy: fifo: loadavg: 0.18 0.13 0.08 2/438 4377

T: 0 ( 4374) P:99 I:1000 C:  13476 Min:  10 Act:  16 Avg:  20 Max: 77
T: 1 ( 4375) P:99 I:1500 C:   8984 Min:  11 Act:  15 Avg:  18 Max: 80
T: 2 ( 4376) P:99 I:2000 C:   6738 Min:  10 Act:  19 Avg:  18 Max: 80
T: 3 ( 4377) P:99 I:2500 C:   5390 Min:  10 Act:  20 Avg:  19 Max: 63
# Thread Ids: 04374 04375 04376 04377
# Break thread: 4374
# Break value: 372
bash-4.3$ sudo cat /sys/kernel/debug/tracing/trace

##### CPU 0 buffer started ####
 <idle>-0 3d... 22890493us!: rcu_eqs_enter_common.isra.48 <-rcu_irq_exit
```

RT-Preempt

- cyclictest
  - Linux 3.10.58-android-x86+ SMP PREEMPT i5-4210U CPU @ 1.70GHz

```
[root@localhost rt-tests]# ./cyclictest -a -t -n -p99
policy: fifo: loadavg: 0.79 0.82 0.49 2/610 8051

T: 0 ( 8048) P:99 I:1000 C:  52194 Min:  2 Act:   3 Avg:  2 Max: 20
T: 1 ( 8049) P:99 I:1500 C:  34796 Min:  2 Act:   3 Avg:  3 Max:  7
T: 1 ( 8050) P:99 I:2000 C:  26097 Min:  2 Act:   2 Avg:  2 Max:  6
T: 1 ( 8051) P:99 I:2500 C:  20877 Min:  2 Act:   3 Avg:  3 Max:  7

[root@localhost rt-tests]# ./signaltest
0.12 0.51 0.42 1/607 8056

T: 0 (8055) P: 0 C: 201680 Min:  5 Act:   8 Avg:    9 Max:  280

[root@localhost rt-tests]# ./pip_stress
Successfully used priority inheritance to handle an inversion
```

RT-Preempt

- signaltest
  - Linux 3.10.17-rt12-smp SMP PREEMPT RT – Atom

```
$ signaltest

T: 0 ( 2579) P: 0 C: 851904 Min: 25 Act: 44 Avg: 69 Max: 3537
```

  - Linux 3.10.17-smp SMP – Atom

```
$ signaltest

T: 0 ( 1257) P: 0 C: 744656 Min: 19 Act: 56 Avg: 63 Max: 5329
```

  - Linux 3.14.33 #2 SMP i5-4210U CPU @ 1.70GHz

```
$ signaltest

T: 0 ( 4960) P: 0 C:2140176 Min: 2 Act: 4 Avg: 8 Max: 1969
```

Real-time Ubuntu kernels

- lowlatency
  - soft real-time
  - basat en el kernel per defecte, amb una configuració agressiva per reduir latències
- realtime
  - hard real-time
  - based on PREEMPT-RT

Temps real

- Firm, hard, altres sistemes
  - Linuxworks LynxOS
  - WxWorks (Wind River)
  - QNX Intel, ARM, ... `www.qnx.com`
  - HP-RT
  - Xenomai (Linux)
  - Microsoft Windows Embedded Compact 2013 x86 i ARM
  - IntervalZero RTOS platform Windows, `www.intervalzero.com`
  - OnTime RTOS-32 platform Win32 apps
  - RTXC-Quadros Intel, ARM, PPC, ... `www.quadros.com`

VxWorks

- Recomanacions
  - Usar primitives de sincronització de baix nivell
    - operacions atòmiques (`sync_test_and_set`)
    - spin locks (per 10-20 línies de codi)
    - semàfors / mutex
  - Usar CPU affinity (`sched_setaffinity`)
  - Minimitzar desbalanceig en la feina dels fluxos
    - evitar que hi hagi recursos sobrecarregats

Best Practices: Adoption of Symmetric Multiprocessing Using VxWorks and Intel®Multicore Processors

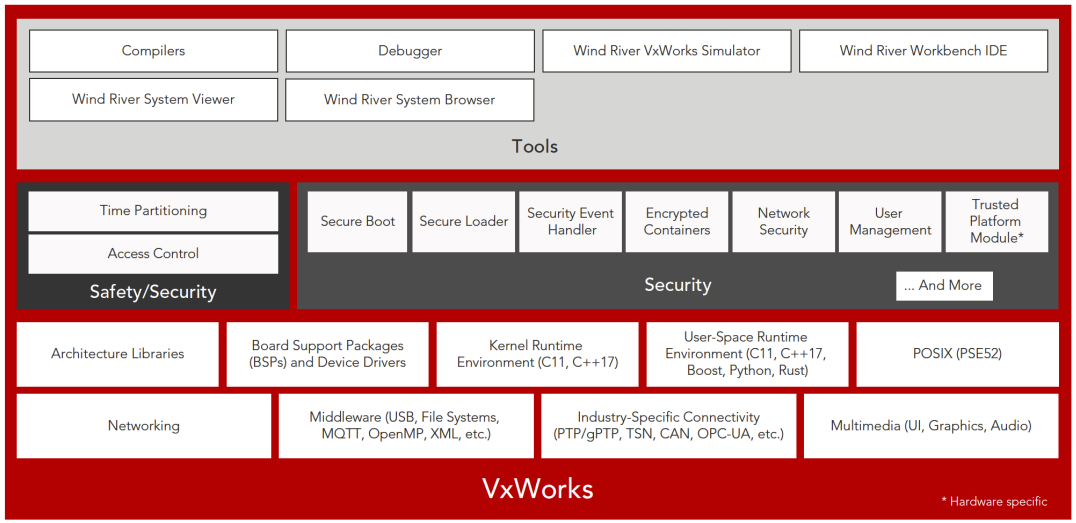

`https://www.windriver.com/products/vxworks`

Xenomai

- Suport per temps real en Linux
  - Patch al kernel
  - Utilitats d'usuari
- Afegeix un conjunt de característiques de temps real a la configuració del kernel
- Permet executar serveis en temps real al costat d'aplicacions que no requereixen temps real

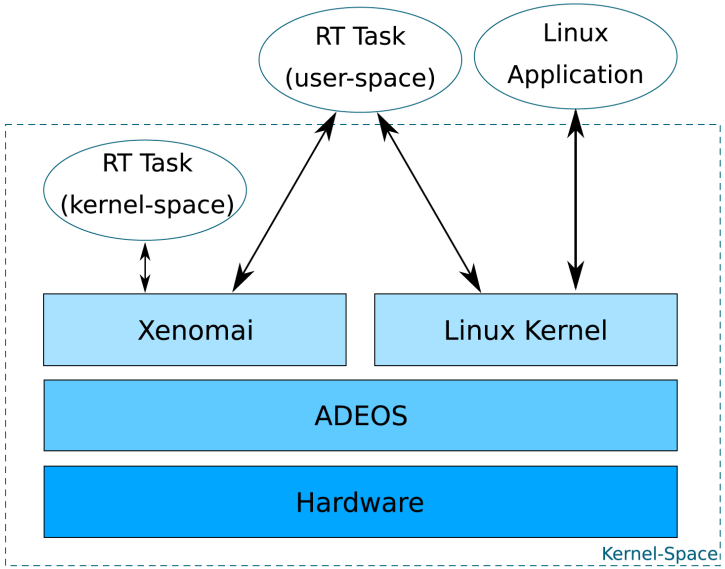

Font: https://doi.org/10.1145/3297714

Xenomai

- Implementa un ordre en la distribució d'events: Adeos
  - Basat en dominis de protecció
    - Cadascun amb una prioritat estàtica
  - Els events es distribueixen primer al domini més prioritari

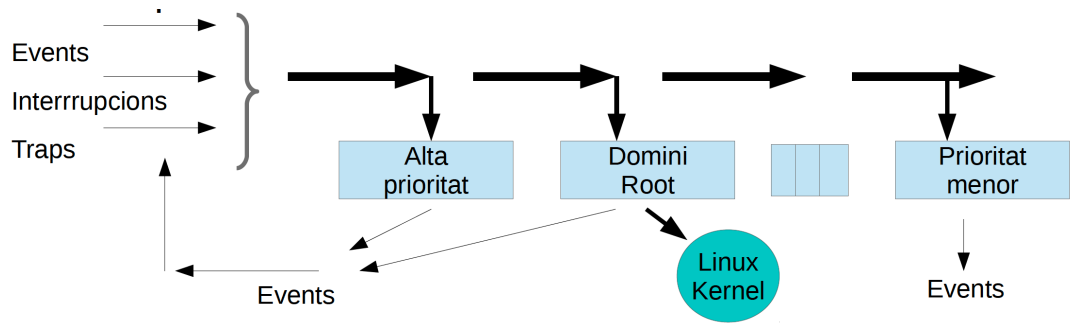

Xenomai

- Disseny dels dominis
  - eficients
  - amb ràfagues curtes d'execució
    - sobretot els més prioritaris
  - poden "inhibir" events i/o interrupcions
    - per exclusió mútua
    - llavors els events no arriben als dominis menys prioritaris fins que han estat processats

Xenomai

- Xenomai threads
  - Poden córrer en mode kernel o en usuari
    - També en el domini Linux
      → Amb latències més llargues
      → Però sense inversió de prioritats
- Entorn d'execució "standard" en Xenomai

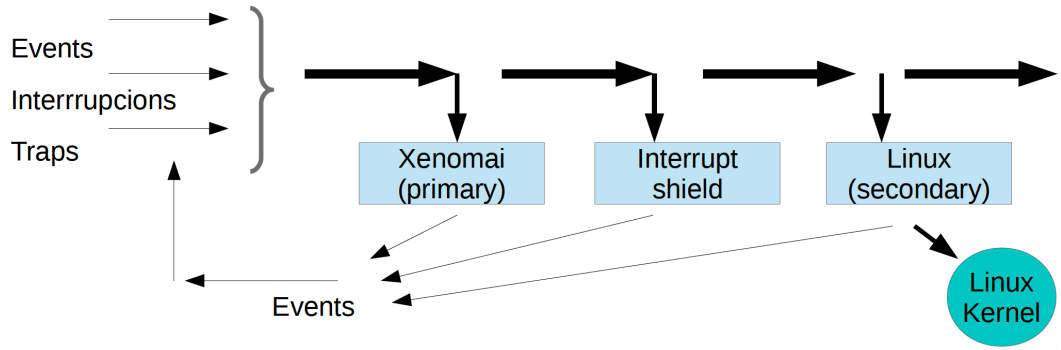

Xenomai

- Implementació
  - aconseguir que Linux cedeixi el control a Adeos
  - per això es fa que el mòdul d'Adeos mogui Linux al ring 1
    - Les instruccions privilegiades causen una excepció

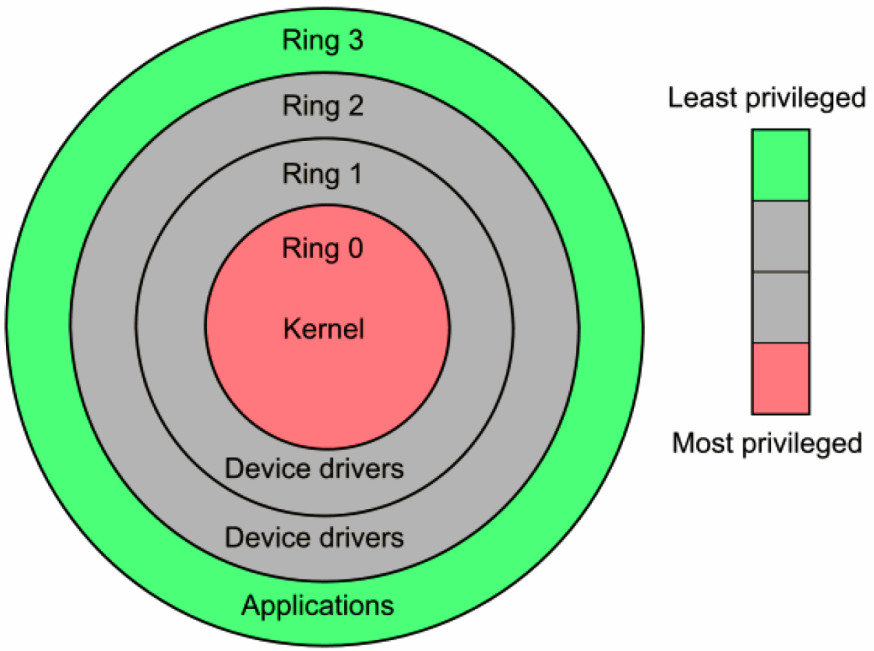

Xenomai

- Les instruccions són:

`clts`, clear task-switched flag

`hlt`, halt processor

`cli`, clear interrupt flag

`sti`, set interrupt flag

`in`, input from port

`out`, output to port

`ins`, input string from port

`outs`, output string from port

`invd`, invalidate cache

`invlpg`, invalidate

`lgdt`, load GDT register

`lidt`, load IDT register

`lldt`, load LDT register

`lmsw`, load machine status register

`ltr`, load task register

`mov to/from CRn`, move to control register n

`mov to/from DRn`, move to debug register n

`wbinvd`, writeback and invalidate cache

`rdmsr`, read model-specific registers

`wrmsr`, write model-specific registers

`rdpmc`, read performance-monitoring counter

`rdtsc`, read time-stamp counter

- Com pot permetre Adeos que Linux les executi?

Xenomai

- Per cada instrucció, es pot executar de diverses maneres:
  - `in, out, ins, outs`: són molt usades pels drivers, cal executar-les eficientment
    - Modificar el descriptor de cada task (procés de Linux) per acomodar el vector de bits que permeti executar-les sobre els ports des del ring 1

Xenomai

- Per la resta d'instruccions
  - emulació
    - l'excepció ha de descodificar la instrucció i modificar l'estat del procés perquè sembli que l'ha executat
  - execució pas a pas
    - activa el bit de single *stepping* i deixa executar la instrucció
    - recupera el control després de la instrucció per desactivar el single *stepping*
  - no es fa un `sti/cli` sinó que Adeos s'apunta que s'ha fet

Xenomai: exemple

```c
#include <stdio.h>
#include <signal.h>
#include <unistd.h>
#include <sys/mman.h>
#include <native/task.h>
#include <native/timer.h>
int main(int argc, char* argv[])
{
        signal(SIGTERM, catch_signal);
        signal(SIGINT, catch_signal);
        /* Avoids memory swapping for this program */
        mlockall(MCL_CURRENT|MCL_FUTURE);
        /*
         * Arguments: &task,
         *            name,
         *            stack size (0=default),
         *            priority,
         *            mode (FPU, start suspended, ...)
         */
        rt_task_create(&demo_task, "trivial", 0, 99, 0);
        /*
         * Arguments: &task,
         *            task function,
         *            function argument
         */
        rt_task_start(&demo_task, &demo, NULL);
        pause();
        rt_task_delete(&demo_task);
        return 0;
}
```

```c
RT_TASK demo_task;
/* NOTE: error handling omitted. */
void demo(void *arg)
{
        RTIME now, previous;
        /*
         * Arguments: &task (NULL=self),
         *            start time,
         *            period (here: 1 s)
         */
        rt_task_set_periodic(NULL, TM_NOW, 1000000000);
        previous = rt_timer_read();
        while (1) {
                rt_task_wait_period(NULL);
                now = rt_timer_read();
                /*
                 * NOTE: printf may have unexpected impact on the timing of
                 *       your program. It is used here in the critical loop
                 *       only for demonstration purposes.
                 */
                printf("Time since last turn: %ld.%06ld ms\n",
                       (long)(now - previous) / 1000000,
                       (long)(now - previous) % 1000000);
                       previous = now;
        }
}
```

`http://www.xenomai.org/index.php/Xenomai_quick_build_quide`
`https://www.rtai.org/` – RealTime Application Interface - 4.0 (2013)

Interfície de Xenomai

```
int rt_task_create (RT_TASK *task, const char *name, int stksize, int prio, int mode)
  Create a new real-time task.
int rt_task_start (RT_TASK *task, void(*entry)(void *cookie), void *cookie)
  Start a real-time task.
int rt_task_suspend (RT_TASK *task)
  Suspend a real-time task.
int rt_task_resume (RT_TASK *task)
  Resume a real-time task.
int rt_task_delete (RT_TASK *task)
  Delete a real-time task.
int rt_task_yield (void)
  Manual round-robin.
int rt_task_set_periodic (RT_TASK *task, RTIME idate, RTIME period)
  Make a real-time task periodic.
int rt_task_wait_period  (unsigned long *overruns_r)
     Wait for the next periodic release point.
...
```

Interfície de Xenomai

- `rt_task_create()`
  - Crea i deixa la tasca en suspens
  - Retorna un handle (`RT_TASK`)
- `rt_task_start()`
  - Engega la tasca
- `rt_task_spawn()`
  - Combina creació i arrancada

Interfície de Xenomai

- `rt_task_set_periodic()`
  - programa el primer dispar de la tasca i el seu període
  - Un cop s'ha executat, la tasca s'aturarà en un `rt_task_wait_period()`

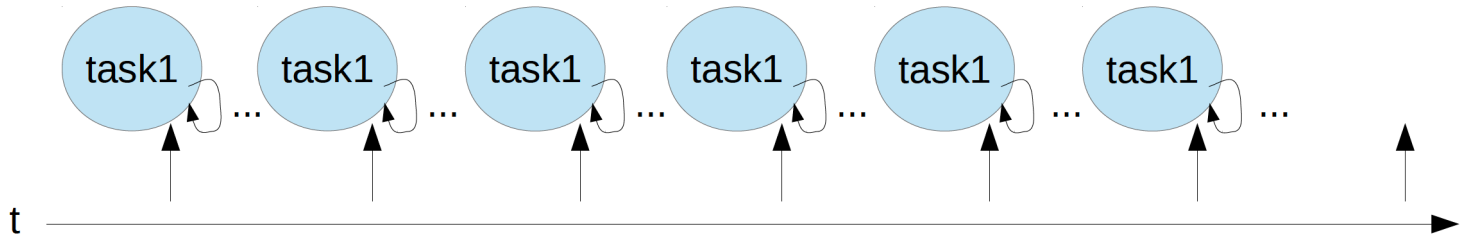

Interfície de Xenomai: resum

- Gestió de tasques
- Gestió del temps
- Sincronització
- Memòria compartida
- Pas de missatges
- Notificacions asíncrones
  - alarmes i interrupcions
- Gestors de dispositius
- Suport a depuració

Pthreads RT

- Barriers
  - `pthread_barrier_init (&barrier, attr, expected_count)`
  - `pthread_barrier_wait (&barrier)`

```
top - 12:36:23 up  3:50,  9 users,  load average: 0.55, 0.41, 0.42
Tasks: 328 total,   3 running, 325 sleeping,   0 stopped,   0 zombie
Cpu0  :  2.2%us, 15.7%sy,  0.0%ni, 82.1%id,  0.0%wa,  0.0%hi,  0.0%si,  0.0%st
Cpu1  :  1.8%us, 15.2%sy,  0.0%ni, 82.5%id,  0.0%wa,  0.4%hi,  0.0%si,  0.0%st
Mem:   1935004k total,  1769548k used,   165456k free,   209924k buffers
Swap:  5119996k total,     4696k used,  5115300k free,   824528k cached

  PID USER      PR  NI  VIRT  RES  SHR S %CPU %MEM    TIME+  WCHAN     COMMAND
 3792 xavim     20   0 22832  380  304 R   42  0.0   0:07.64 -         barrier
 3793 xavim     20   0 22832  380  304 R   41  0.0   0:07.62 futex_wai barrier
 2112 root      20   0  160m  39m  15m S    1  2.1   2:52.81 poll_sche X
 3777 xavim     20   0 19764 1592 1060 R    1  0.1   0:00.79 -         top
    3 root      20   0     0    0    0 S    0  0.0   0:00.26 run_ksoft ksoftirqd
    9 root      20   0     0    0    0 S    0  0.0   0:00.26 run_ksoft ksoftirqd
 2440 xavim     20   0  351m  21m  16m S    0  1.1   0:00.29 poll_sche korgac
```

Pthreads RT

- Barriers
  - Atributs
    - `PTHREAD_PROCESS_PRIVATE`
    - `PTHREAD_PROCESS_SHARED`

Pthreads RT

```
union sparc_pthread_barrier {
  struct pthread_barrier b;
  struct sparc_pthread_barrier_s {
      unsigned int curr_event; // numero de barriers que hem passat
      int lock;  // protegeix left
      unsigned int left; // quants en falten per arribar
      unsigned int init_count; // quants n'han d'arribar
      unsigned char pshared; // compartit entre processos o privat
    } s;
};
```

- Inicialització:

  `init_count = nthreads;`

  `left = nthreads`

Implementació del barrier (I)

```
/* Wait on barrier.  */
int
pthread_barrier_wait (barrier)
     pthread_barrier_t *barrier;
{
  union sparc_pthread_barrier *ibarrier
    = (union sparc_pthread_barrier *) barrier;
  int result = 0;
  int private = ibarrier->s.pshared ? LLL_SHARED : LLL_PRIVATE;

  /* Make sure we are alone.  */
  lll_lock (ibarrier->b.lock, private);

  /* One more arrival.  */
  --ibarrier->b.left;
```

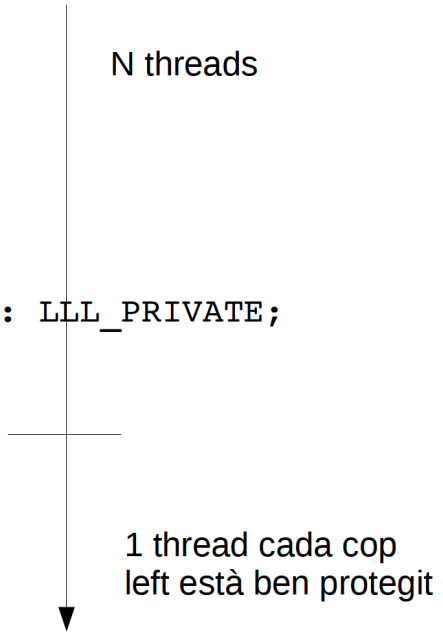

Implementació del barrier (II)

```
/* Are these all?  */
if (ibarrier->b.left == 0)
  {
    /* Yes. Increment the event counter to avoid invalid wake-ups and
       tell the current waiters that it is their turn.  */
    ++ibarrier->b.curr_event;

    /* Wake up everybody.  */
    lll_futex_wake (&ibarrier->b.curr_event, INT_MAX, private);

    /* This is the thread which finished the serialization.  */
    result = PTHREAD_BARRIER_SERIAL_THREAD;
  }
```

L'últim thread en arribar entra aquí...

... i desperta la resta

... aquest tornarà PTHREAD_BARRIER_SERIAL_THREAD

Implementació del barrier (III)

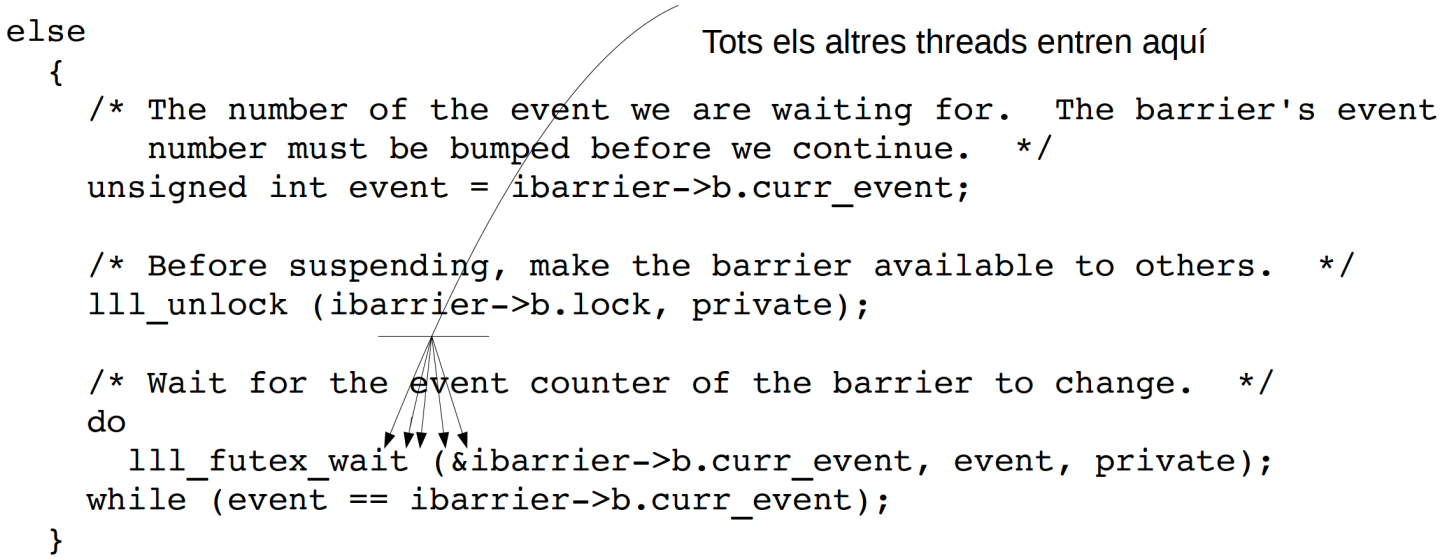

Implementació del barrier (IV)

```
  /* Make sure the init_count is stored locally or in a register.  */
  unsigned int init_count = ibarrier->b.init_count;

  /* If this was the last woken thread, unlock.  */
  if (atomic_increment_val (&ibarrier->b.left) == init_count)
    /* We are done.  */
    lll_unlock (ibarrier->b.lock, private);

  return result;
}
```

L'últim obre el lock per poder tornar-hi

Left està protegit contra decrements pel lock i contra increments per l'operació atòmica

Low level lock

- Implementat amb `lock cmpxchg`
  - Pot comprovar si no hi ha més threads en el procés
    - i llavors estalvar-se el lock

```
#define lll_trylock(futex) \
  ({ int ret;                                                          \
     __asm __volatile (cmpl $0, __libc_multiple_threads(%%rip)\n\t"    \
                       "je 0f\n\t"                                     \
                       "lock; cmpxchgl %2, %1\n\t"                     \
                       "jmp 1f\n\t"                                    \
                       "0:\tcmpxchgl %2, %1\n\t"                       \
                       "1:"                                            \
                     : "=a" (ret), "=m" (futex)                        \
                     : "r" (LLL_LOCK_INITIALIZER_LOCKED), "m" (futex), \
                       "0" (LLL_LOCK_INITIALIZER)                      \
                     : "memory");                                      \
     ret; })
```

%1

%2

Pthreads RT

- `pthread_spin`
  - init
  - lock
  - trylock
  - unlock
- `pthread_getcpuclockid (pthread_t, *clockid)`

Kernel randomization

- Opcions de configuració
  - `CONFIG_HIBERNATION`
    - Permet hivernar en disc (swap area)
  - `CONFIG_RELOCATABLE`
    - Guarda la informació de reubicació, i el kernel es pot carregar a qualsevol posició
  - `CONFIG_RANDOMIZE_BASE`
    - Depends on `RELOCATABLE` and `not(HIBERNATION)`
    - Permet que la càrrega del kernel es faci en una adreça aleatòria
  - `CONFIG_RANDOMIZE_BASE_MAX_OFFSET`
    - 512MB - 1GB