Linux jako real-time systém

Red Hat Czech
Michal Schmidt
mschmidt@redhat.com
Duben 2009

redhat.

Část I

Úvod do real-time

redhat.

Úvod do real-time

Section 1

Real-time úloha

redhat.

Kdy se jedná o real-time problém

- Na zpracování jsou kladena časová omezení
- Výpočet musí být dokončen před časovým limitem (**deadline**)
- Překročení deadline se považuje za chybu

Real-time neznamená dosáhnout co nejvyššího výkonu

redhat.

Užitková funkce

Užitečnost výsledku v čase

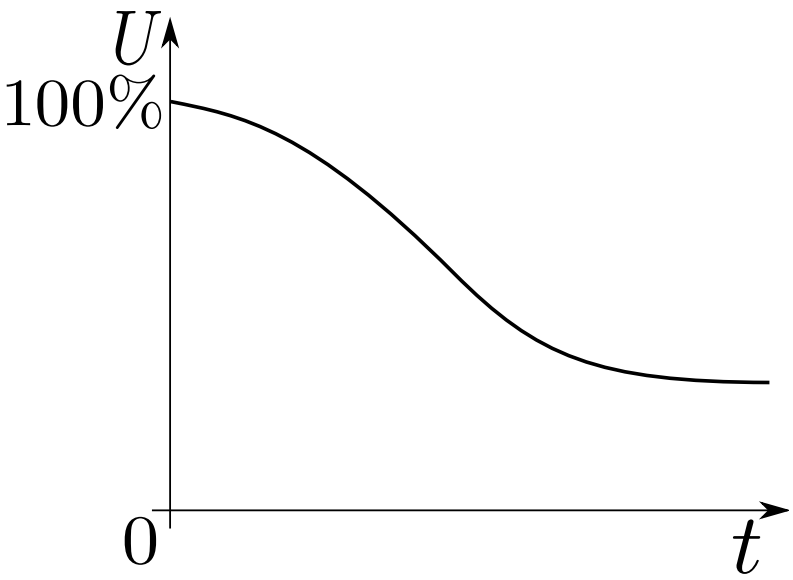

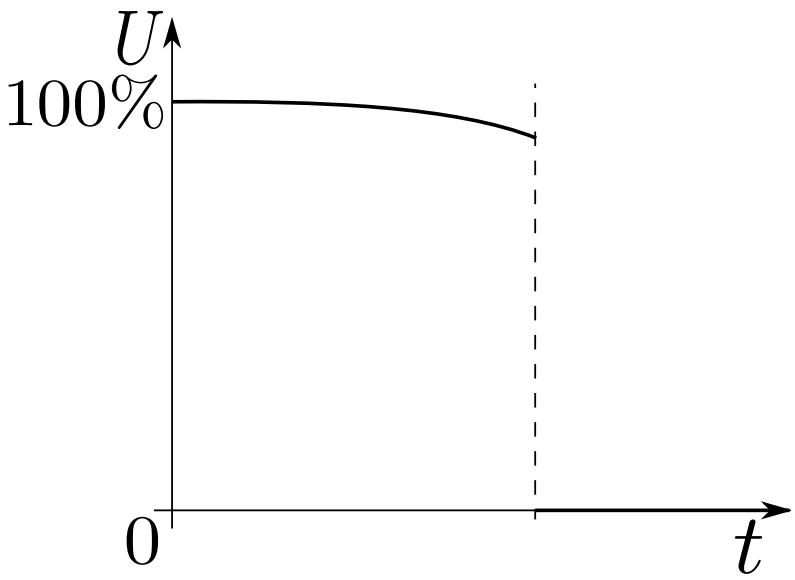

Section 2

Soft vs. hard real-time

redhat.

Rozdíl z hlediska případných následků nedodržení deadline

- Hard RT – při selhání může být ohroženy životy, zdraví, nebo můžou vzniknout velké škody
- Soft RT – nedodržení deadline není fatální, zhoršená kvalita produktu

(Ale jsou i jiné pohledy na rozdíl mezi hard a soft RT.)

redhat.

Co není nutně měřítkem hard RT

Velikost časových konstant nehraje důležitou roli při rozlišení soft a hard RT. Není pravda, že hard RT úlohy mají vždy krátké deadline.

- Hard RT úlohy můžou být i relativně pomalé
  - Stroj se přehřeje, když se chlazení nezapne do 1 minuty
- Soft RT úloha naopak s krátkou deadline
  - Čtení příchozích dat ze síťové karty je vhodné stihnout ve zlomku sekundy

redhat.

Příklady RT úloh

- Zpracování audio/video
- Měření a získávání dat
- Řízení (logické, PID, . . .)
- Průmyslová automatizace
- Robotika
- Lékařské stroje
- Auta
- . . .

Section 3

Real-time operační systémy (RTOS)

redhat.

Úplně nejlepší RTOS

Nejlepší RTOS == obejít se úplně bez OS ;-)

- HW vyhrazený pouze pro danou úlohu
  - specializované obvody
  - mikrokontrolery
- Snadno zaručíme předvídatelnost
- Žádné další běžící procesy
- Velmi vhodné pro jednodušší úlohy
- Ale nemáme pohodlí a výhody OS

redhat.

Operační systémy pro obecné účely

OS pro univerzální účely (jako Linux)

- Většinou optimalizované na vysoký celkový výkon
- Předvídatelnost je až druhořadá
- Mohou poskytovat real-time služby, ale bez záruk (best-effort)
  - funkce POSIX real-time (`SCHED_FIFO`, `SCHED_RR`, ...)
  - Pro mnohé soft RT úlohy stačí

redhat.

Real-time operační systém

OS specializovaný na real-time úlohy

- Při správném použití dokáže poskytnout záruky, že dodržíme deadline
- Předvídatelnost a přesné časování jsou ceněny více než vysoký výkon
- Zajímavé je znát chování v nejnepříznivějším stavu (**worst-case**)
- Používá real-time plánovač procesů (scheduler)
  - Preemptivní plánovač podle priorit
  - Nejbližší deadline nejdříve (EDF)
  - Rate-Monotonic Scheduler

redhat.

Příklady RTOS

- Free software
  - Speciální: eCos, FreeRTOS, TRON, ...
  - založené na Linuxu: RTLinux, RTAI, Xenomai, **Linux + realtime-preempt patch**
- Proprietární
  - LynxOS, QNX, VxWorks, PikeOS, Windows CE, Win+RTX
    ...

redhat.

Měřítka RTOS

Důležité hodnoty jsou

- **interrupt latency** (čekací doba přerušení) – vyvoláno přerušení; za jak dlouho se spustí jeho obslužná rutina?
- **scheduling latency** (čekací doba plánování) – proces s nejvyšší prioritou je připraven k běhu; za jak dlouho dostane přidělen CPU?
- **jitter** (chvění) – nechtěná proměnlivost periody

redhat.

RTLinux

RTLinux (V. Yodaiken, FSMLabs, nyní Wind River)

- První snaha dostat Linux do světa RT
- RTLinux Free, RTLinux Pro
- Malé RT jádro – Linux běží jako proces s nízkou prioritou
- Patentováno – kontroverzní
- Real-time programy jsou vlastně moduly pro RTLinux jádro, používají jeho API
- Ostatní procesy běží pod Linux jádrem.
- Komunikace RT$\leftrightarrow$ne-RT prostřednictvím FIFO nebo sdílené paměti

redhat.

Xenomai

Má za cíl poskytovat API tradičních RTOS, pro snadné portování programů

- Pod Linuxem je nanokernel Adeos/I-pipe
- Různé 'skiny' poskytují různá API pro real-time procesy
  - POSIX, pSOS+, VxWorks, RTAI, ...
- Plánuje se i možnost běhu na Linuxu s realtime-preempt

redhat.

Obojí jsou řešení s duálním kernelem

Vlastnosti řešení se dvěma kernely:

- Výborné nízké latence (desítky μs) pro RT procesy
- Speciální API pro RT programy, nejsou to normální procesy v Linuxu.

Chtěli bychom RT procesy jako normální linuxové programy v userspace.

redhat.

Část II
RT-preempt

RT-preempt

Section 4

Preemptivní jádro

redhat.

Preemptivní jádro

- Linux odjakživa plánoval procesy v userspace **preemptivně**
- Až po Linux 2.4.x – **kooperativní** multitasking pro kód **v jádře**
- Práce na škálovatelnosti v SMP – jemnější zamykání v jádře
- Můžeme preemptnout proces v jádře, pokud zrovna není v kritické sekci!
  - Nelze když: drží spinlock, přistupuje k per-CPU proměnným, ...
- Linux 2.6 – **preemptivní jádro** (volba `CONFIG_PREEMPT`)

redhat.

Vliv preemptivního jádra

- Maličko větší režie – spinlocky nyní zakazují preempci
- Průměrná plánovací latence se snížila
- Stále dlouhé latence v nejhorších případech

redhat.

Odkud se berou latence

- Kritické sekce se spinlocky a rwlocky
- Kritické sekce při čtení v mechanismu RCU
- Kód, kde se výslovně zakazují přerušení nebo preempce
- Vykonávání obsluh přerušení a softIRQ
- Inverze priorit

Section 5

RT-preempt patch

redhat.

RT-preempt patch

- Chce všechny ty zdroje latencí zrušit
- Dělá z Linuxu RTOS
- Normální userspace programy mohou běžet v realtime
- Žádný druhý kernel
- Vývoj: Ingo Molnar, Thomas Gleixner, Steven Rostedt, ...
  - jmenovaní pracují pro Red Hat, umějí spolupracovat s upstreamem, od začátku jasná snaha začleňovat tam postupně části patche

redhat.

SoftIRQs

Nejsnáze se lze vypořádat s latencemi od softIRQ.
Co jsou SoftIRQs v normálním Linuxu

- Jsou to "spodní poloviny" zpracování přerušení (časovače, síť. TX/RX, . . .)
- Běží s povolenými IRQ
- Ale nejsou to procesy – nelze jim sebrat CPU a přidělit ho procesu
- Ochrana proti přetížení od softIRQ
  - `ksoftirqd` – jaderné vlákno pro odložené zpracování softIRQ

redhat.

Preemptivní SoftIRQs

- Už jsme se smířili s tím, že softIRQ mohou být odloženy na později do vlákna
- Můžeme je tam odložit **vždy**
- A když už, tak rovnou samostatné vlákno pro každý typ softIRQ

```
$ ps -eo pid,pri,rtprio,cmd
PID  PRI  RTPRIO  CMD
 4    90      50  [softirq-high/0]
 5    90      50  [softirq-timer/0]
 6    90      50  [softirq-net-tx/]
 7    90      50  [softirq-net-rx/]
 8    90      50  [softirq-block/0]
 9    90      50  [softirq-tasklet]
10    90      50  [softirq-sched/0]
11    90      50  [softirq-hrtimer]
12    90      50  [softirq-rcu/0]
```

redhat.

Obsluha IRQ ve vláknech

- V normálním Linuxu má obsluha každého IRQ přednost před všemi procesy
- To i tehdy, když proces má realtime prioritu
- Spouštějme obsluhy IRQ také ve vláknech (preemptivní)

```
PID PRI RTPRIO CMD
304  90     50 [IRQ-8]
347  90     50 [IRQ-15]
381  90     50 [IRQ-12]
382  90     50 [IRQ-1]
393  90     50 [IRQ-4]
400  90     50 [IRQ-16]
401  90     50 [IRQ-18]
402  90     50 [IRQ-17]
413  90     50 [IRQ-19]
```

redhat.

Klasická obsluha IRQ

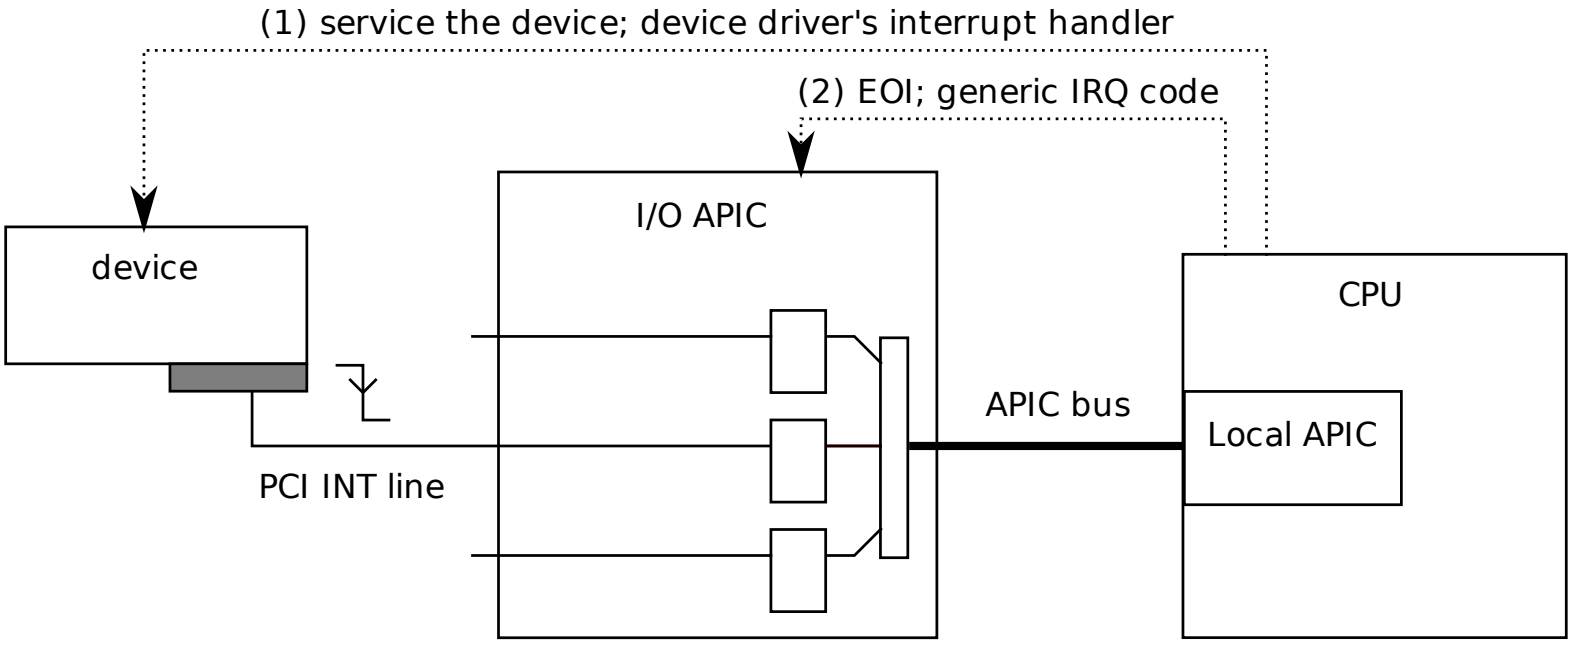

redhat.

Obsluha IRQ z vlákna

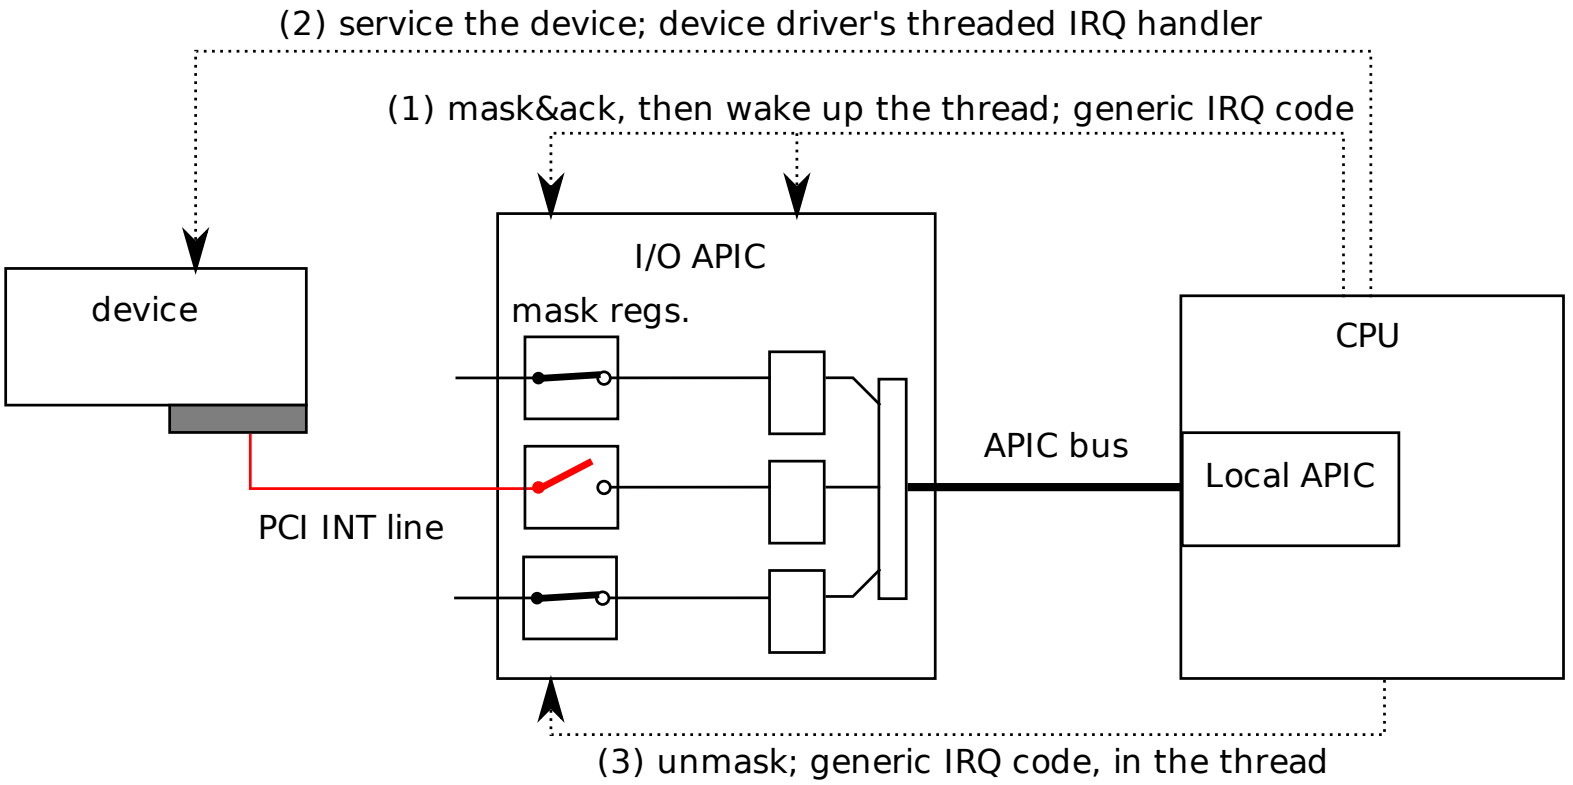

redhat.

Spící spinlocky

Potřebujeme se zbavit dalšího zdroje latencí – sekcí se spinlocky

- Jsou nutné pro přístup ke sdíleným zdrojům na SMP
- Většinou krátké kritické sekce, ale najdou se i dlouhé
- Potřebujeme, aby byly preemptivní
- Náhrada spinlocků spícími zámky – mutexy
  - Aby to fungovalo, IRQ musí být ve vláknech
  - Jen několik vybraných zůstává jako `raw_spinlock_t`

redhat.

Inverze priorit

- . . . je když proces s vysokou prioritou musí čekat na proces s prioritou nižší
  - Nevyhnutelné, pokud oba přistupují ke sdílenému prostředku – musí počkat, až druhý proces uvolní zámek
- Špatná je ale **neohraničená** inverze priorit

redhat.

Neohraničená inverze priorit

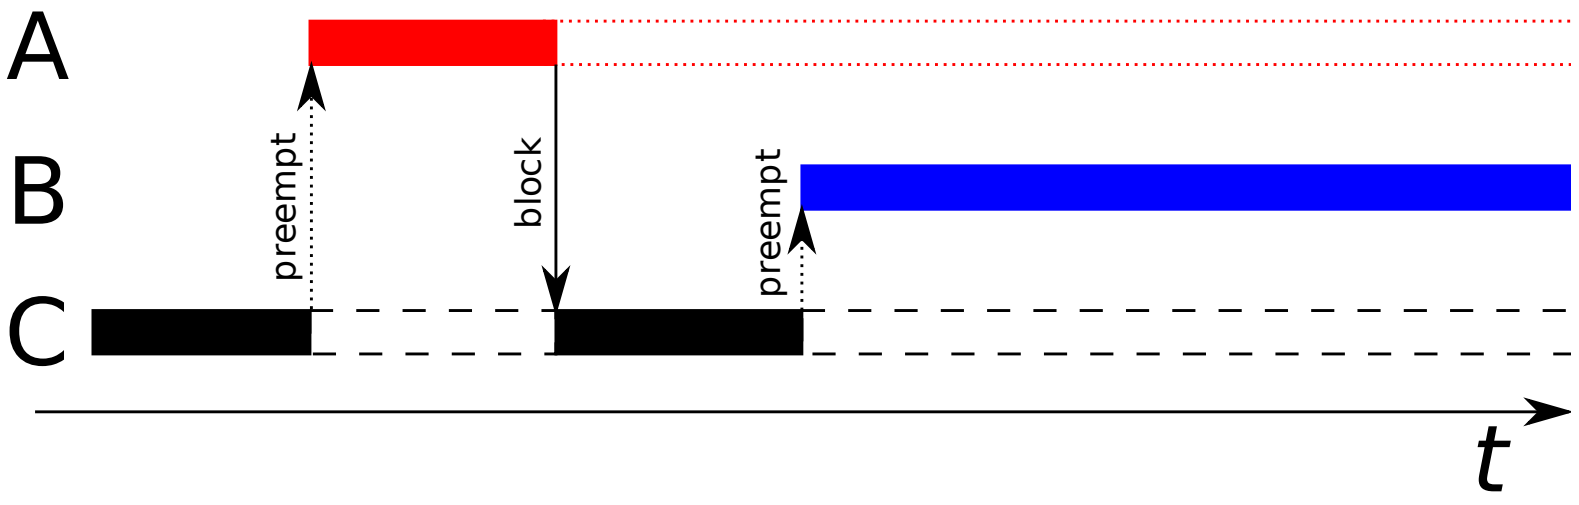

redhat.

Dědičnost priorit

- Řešení prioritní inverze
- Když prioritní proces čeká na uvolnění zdroje drženého nižším procesem, priorita nižšího procesu je dočasně povýšena na úroveň toho čekajícího
- Tento mechanismus využívají rt-mutexy

redhat.

Dědičnost priorit

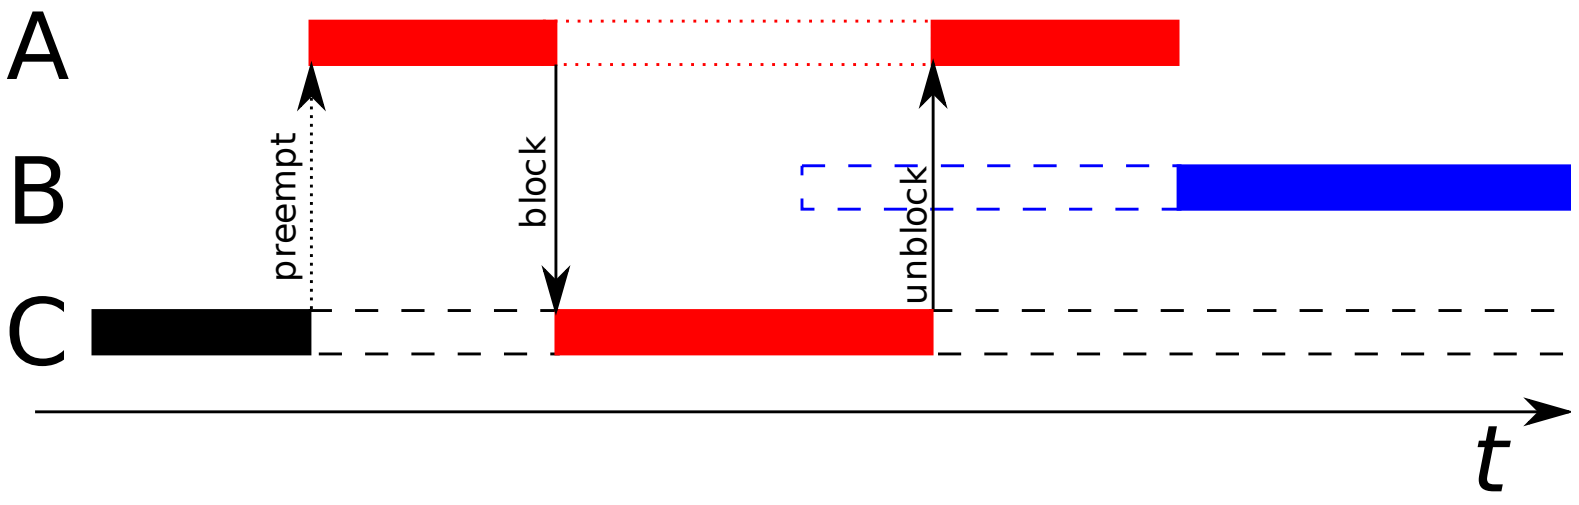

redhat.

Časovače s vysokým rozlišením

- RT aplikace chtějí jemné časování
- clock sources (zdroje hodin)
  - `gettimeofday()`
- clock events (události od hodin)
  - `nanosleep()`, POSIXové časovače
- Padlo omezení na rozlišení periodického tiku (`HZ`)
- API používá nanosekundy – skutečná přesnost a rozlišení je dáno schopnostmi HW

redhat.

Další lahůdky

- Validátor zámků (lockdep)
  - Našel mnoho chyb v zamykání
  - Dokáže detekovat těžko vyvolatelná uváznutí (deadlock), aniž by k nim muselo opravdu dojít
- Sledovač latencí (latency tracer)
  - Také s jeho pomocí bylo nalezeno mnoho chyb
  - Vyvinul se z něj dnešní ftrace (`CONFIG_FTRACE`)
- Detektor SMI
  - System Management Interrupt
  - SMM – režim CPU kde si firmware dělá, co chce, bez ohledu na OS
  - SMI způsobují nečekané prodlevy

redhat.

Výkon

- Latence – desítky μs dosažitelné
- Hrubý výkon o něco snížen, ale ve většině benchmarků jen málo
  - Objeví-li se výraznější propady, řeší se

redhat.

Začleňování do upstreamu

- Vývoj RT-preempt má jasný cíl dostat se do upstream Linuxu
- Mnohé části už tam jsou
  - 2.6.16 – obecné semafory nahrazeny vhodnějšími mutexy
  - 2.6.16 – časovače s vysokým rozlišením
  - 2.6.18 – jednotná instrastruktura pro IRQ: genirq
  - 2.6.18 – robustní futexy a futexy s děděním priorit
  - 2.6.18 – validátor zámků lockdep
  - 2.6.21 – jádro bez tikání (tickless)
  - 2.6.25 – preemptivní RCU
  - 2.6.27 – trasovací nástroj ftrace
  - 2.6.29 – adaptivní čekání mutexů
- Nepřímé příznivé dopady
  - Byly odhaleny četné chyby souběhu, opraveny další chyby
- Výhody z existence RT patche plynou všem

redhat.

Co ještě zbývá začlenit

Stále ještě zbývají dvě nejdůležitější části

- IRQ a softIRQ ve vláknech
  - Podpora přidána v **2.6.30-rc1**
  - Zatím pouze pro vybrané ovladače
  - Umožní zjednodušit kód ovladačů
- Nahrazení spinlocků

Část III

Red Hat Enterprise MRG

Section 6

Messaging + Realtime + Grid

redhat.

Nasazení realtime-preempt Linuxu

RT patch není jen hračka.

Red Hat Enterprise MRG

- Messaging – výkonná implementace otevřeného standardu AMQP (Qpid)
- Realtime – kernel pro předvídatelnou odezvu (v MRG 1.1 založen na 2.6.24-rt), nástroje pro vyladění a monitorování
- Grid – distribuované výpočty (Condor)
- Vrstvený produkt nad Red Hat Enterprise Linux 5
- Zaručena 100 % binární kompatibilita aplikací
- Podporovaná i real-time Java (specifikace RTSJ)

Část IV
Závěr

Zdroje

- Rostedt, S., Hart, D. V.: Internals of the RT Patch. *In Proceedings of The Linux Symposium*, Ottawa, 2007, https://ols2006.108.redhat.com/2007/Reprints/rostedt-Reprint.pdf
- McKenney, P. E., Attempted summary of "RT patch acceptance" thread, take 2, http://lwn.net/Articles/143323/
- McKenney, P. E., A realtime preemption overview, http://lwn.net/Articles/146861/
- Edge, J.: Moving interrupts to threads, http://lwn.net/Articles/302043/
- http://rt.wiki.kernel.org
- http://www.kernel.org/pub/linux/kernel/projects/rt/
- http://www.redhat.com/mrg/