Taskablaufplanung in Linux (Scheduling)

Reinhard Bündgen
buendgen@de.ibm.com

Scheduling: Schlagworte

- Präemptives Multitasking vs. kooperatives Multitasking
  - Präemptiv: Zeitscheiben, preemption
  - Kooperativ: yielding
- Scheduling Policies
  - E/A gebunden (oft aber kurz)
  - Prozess gebunden (lang dafür weniger oft)
- Prioritäten
- Echtzeit

Der Linux Scheduler

- Aufgabe:
  - entscheide welche Task als nächstes (wie lange) läuft
- Anforderung
  - schnell, geringer Overhead,
    - auch bei riesigen Task Listen
    - ab Linux 2.5: O(1) Scheduler
    - Optimiere auf üblichen Fall von 1-2 läuffähigen Tasks
  - Bediene wichtige Tasks bald möglichst
    - Linux ist interaktives OS: E/A gebunden
  - Fairness
    - keine Task darf verhungern
  - SMP Scheduling
    - verteile Arbeit auf mehrere CPUs
      - wenn möglich Auslastung aller CPUs
      - unterstütze CPU Affinität: verhindere Cache Thrashing
    - skalierbar

Prioritäten und Zeitscheiben

- Prioritäten
  - Bestimmen welche Task als nächstes „an die Reihe kommt“
    - Hohe Priorität: bald
    - Niedrige Priorität: später
  - Rein prioritätsgetriebener Scheduler: unfair
- Zeitscheiben
  - Bestimmen wie lange eine Task die CPU (maximal) nutzen darf
  - Nach Blockieren darf Zeitscheibenrest genutzt werden
  - Größe der Zeitscheibe abhängig von Priorität
  - Aufgebrauchte Zeitscheiben werden erst erneuert, wenn Scheduling-fairness garantiert ist
- „an die Reihe kommt“ = seine Zeitscheibe aufbrauchen darf

Linux Task Prioritäten

3 Scheduling Policies (`current->policy`)

- Echtzeit
  - `SCHED_FIFO`
  - `SCHED_RR`
  - Prioritätswerte
    - 1 ... `MAX_RT_PRIO`-1
    - default `MAX_RT_PRIO` = 100
- Normal
  - `SCHED_NORMAL`
  - Prioritätswerte
    - `MAX_RT_PRIO` ... `MAX_RT_PRIO` + 39 (extern -20 ... 19)

Echtzeit-Scheduling

- Weiche Echtzeit gemäss POSIX
- Tasks höherer Priorität (kleinerer Wert) werden
  - vor Echtzeit-Tasks niederer Priorität und
  - vor allen normalen Tasks bearbeitet
- Statische Prioritäten
  - `current->prio == current->static_prio`
- `SCHED_FIFO`
  - unendlich große Zeitscheibe
- `SCHED_RR`
  - endliche Zeitscheibe
  - echtes round robin innerhalb einer Priorität (Task bleibt aktiv)

Normales Scheduling: Priorität

- Policy: `SCHED_NORMAL`
- Dynamische Priorität
  - Initial:
    - `current->static_prio`
    - nice-Wert + `MAX_RT_PRIO` + 20
  - Effektiv:
    - `current->prio`
    - `effective_prio()` berechnet Boni und Mali (-5 ... +5) gemäß Interaktivität der Task
    - `current->sleep_avg` (0 ... `MAX_SLEEP_AVG`)
      - Nach Aufwachen um Schlafdauer erhöht
      - Während Lauf mit jedem Timer Tick dekrementiert

Normales Scheduling: Zeitscheibe

- Zeitscheibengröße: abh. von Priorität

Zeitscheibe	**Dauer**	**Interaktivität**	**Nice Wert**
Initial	½ des Elternteils	N/A	Elternteil
Minimum	`MIN_TIMESLICE` >= 5ms	Niedrig	19
Default	100ms	Durchschnitt	0
Maximum	<= 800ms	Hoch	-20

- Nachdem Task ihre Zeitscheibe verbraucht hat, berechnet `task_timeslice()` neue Zeitscheibe.

Zeitscheibenverfahren

- Alle *aktiven* Tasks in der run-queue verbrauchen ihre Zeitscheibe
  - gemäß Ihrer Priorität
  - Am Stück oder mit Unterbrechungen
- Fairness
  - Sobald Zeitscheibe verbraucht ist, wird Task *inaktiv* („expired“)
  - Alle inaktiven Tasks werden erst wieder reaktiviert, wenn keine aktiven Tasks mehr in der run-queue sind
- Interaktivität
  - Interaktive Tasks dürfen nicht übermäßig lange suspendiert bleiben
  - Können sofort wieder reaktiviert werden, wenn die inaktiven Tasks noch nicht verhungern

Run Queues

- Struktur `struct runqueue` in kernel/sched.c
- Eine pro CPU
  - Die Run Queues enthalten alle Tasks mit Zustand `TASK_RUNNING`
  - Jede Task mit Zustand `TASK_RUNNING` ist in genau einer Run Queue
- Jede Run Queue ist aufgeteilt in 2 SubQueues (`struct prio_array`)
  - aktive SubQueue
  - inaktive (expired) SubQueue
  - Jede SubQueue (aktiv und inaktiv) besteht aus
    - Zähler für die Tasks in der SubQueue
    - ein Array von Queues mit einer Queue für jede mögliche Priorität
    - Einer Bitmap mit einer 1 für jede nicht leere Priorität

Aktive & Expired Tasks in Run Queue

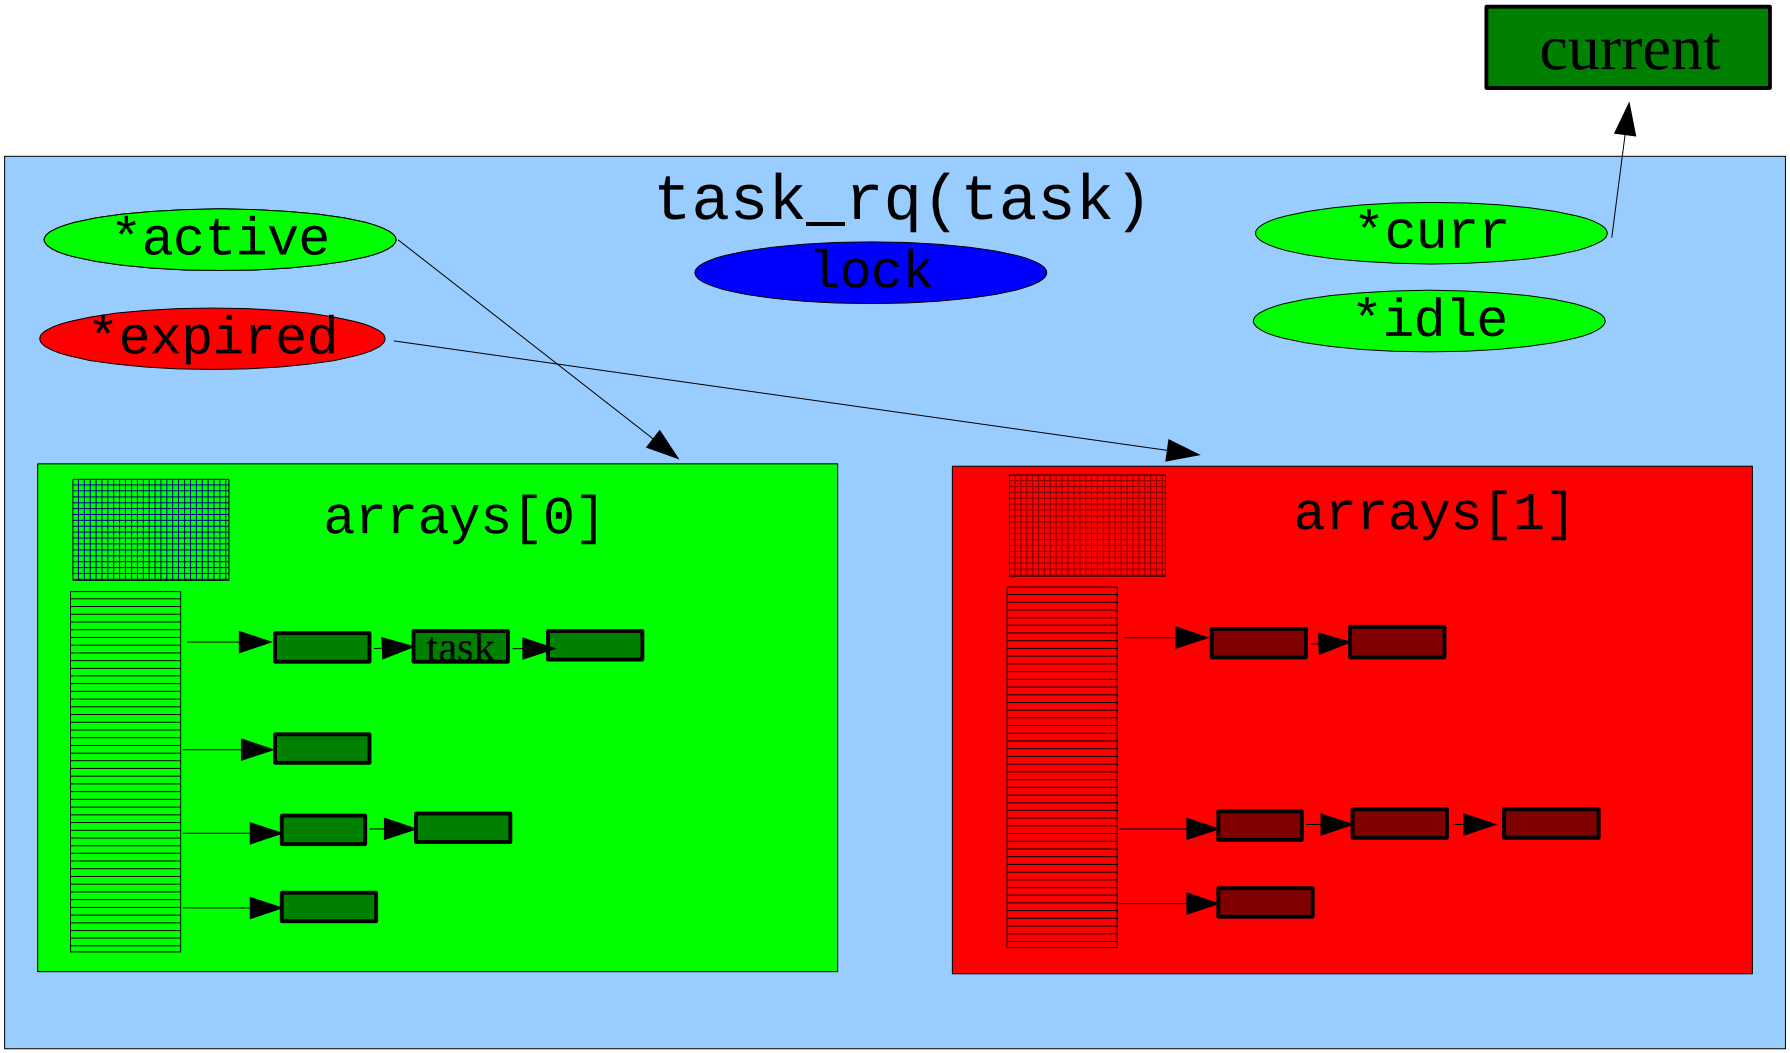

Operationen auf Run Queues

- `cpu_rq(processor)`
- `this_rq()`
- `task_rq(task)`
- `task_rq_lock(task, &flags)`
- `task_rq_unlock(task, &flags)`

Vertauschen von aktiven und inaktiven SubQueues

- In `schedule()` in `kernel/sched.c`:

```
array = rq->active;
if (unlikely(!array->nr_active)) {
        /* Switch the active and expired arrays. */
            schedstat_inc(rq, sched_switch);
            rq->active = rq->expired;
            rq->expired = array;
            array = rq->active;
            rq->expired_timestamp = 0;
            rq->best_expired_prio = MAX_PRIO;
        }
```

Suchen der nächsten Task

- In `schedule()` in `kernel/sched.c`:

```
idx = sched_find_first_bit(array->bitmap);
queue = array->queue + idx;
next = list_entry(queue->next, task_t, run_list);
```

Schlafen und Aufwachen

- Schlafen
  - Eintrag in eine Warteschlange
  - Setzen des Task Status auf `TASK_INTERRUPTIBLE` oder `TASK_UNINTERRUPTIBLE`
  - Aufruf von `schedule()`
    - Ruft `deactivate_task()` auf
      - entfernt Task von Run Queue
- Aufwachen: `wake_up()` weckt alle Tasks einer Warteschlange via `try_to_wake_up()` auf
  - Setzt Task Status auf `TASK_RUNNING`
  - Aufruf von `activate_task()`:
    - trägt Task in Run Queue ein
    - Setzt `need_resched`, falls Tasks Priorität höher als die von `current`

Context Switch & Preemption

- Context Switch (`context_switch()`) am Ende von `schedule()`
  - `switch_mm()`: tausche virtuelle Speicher mappings
  - `switch_to()`: tausche Prozessorzustand (thread_info)
- Wann wird `schedule()` aufgerufen?
  - wenn `need_resched` Flag in `thread_info` gesetzt
  - wenn `scheduler_tick()` oder `try_to_wake_up()`
- Wann kann Präemption passieren?
  - User Space
    - bei Rückkehr von Systemruf in User Space
    - bei Rückkehr von Unterbrechung in User Space
  - Kern (wenn `preempt_count` = 0 und `need_resched` gesetzt)
    - bei Rückkehr von Unterbrechung in Kernel Space
    - wenn der Kern explizit `schedule()` aufruft
    - wenn eine Task im Kern blockiert

SMP Behandlung

- Load Balancing:
  - Wann?
    - wenn Run Queue einer CPU leer
    - jede ms, wenn System idle
    - alle 200ms
  - `load_balance()`
  - Findet vollste Run Queue mit 25% mehr Tasks als `this_rq()`: `find_busiest_queue()`
  - Entscheidet von welchem `prio_array` Tasks zu „stehlen“ (`pull_task()`)
- CPU Affinität
  - `current->cpus_allowed`
  - Bitmaske für zugelassene CPUs (ein bit pro CPU)
  - `sched_setaffinity()` / `sched_getaffinity()` Systemrufe
  - Einschränkung für `load_balance()`

Completely Fair Scheduler (CFS)

- Seit Linux 2.6.23 Ersatz für SCHED_NORMAL
- Ziel: wenn n Tasks lauffähig sind, bekommt jede Task 1/n der CPU-Zeit
  - `rq->fair_clock`
  - Tatsächlich genutzte Zeit: `p->wait_runtime`
- Run-Queue: Red-Black-Tree

  Einordnung der tasks bzgl

  `rq->fair_clock - p->wait_runtime` Schüssels
- Accounting Granularität im ns Bereich
  - einstellbar mit `/proc/sys/kernel/sched_granularity_ns`
  - skaliert mit nice Wert