Taskablaufplanung in Linux (Scheduling)

Reinhard Bündgen
buendgen@de.ibm.com

Scheduling: Schlagworte

- Verdängendes (preemptive) Multitasking vs. kooperatives Multitasking
  - Verdrängend: 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
    - Optimiere auf üblichen Fall von 1-2 lauffähigen Tasks
  - Bediene wichtige Tasks bald möglichst
    - Linux wird meistens als interaktives OS genutzt : 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

Was macht der Scheduler ?

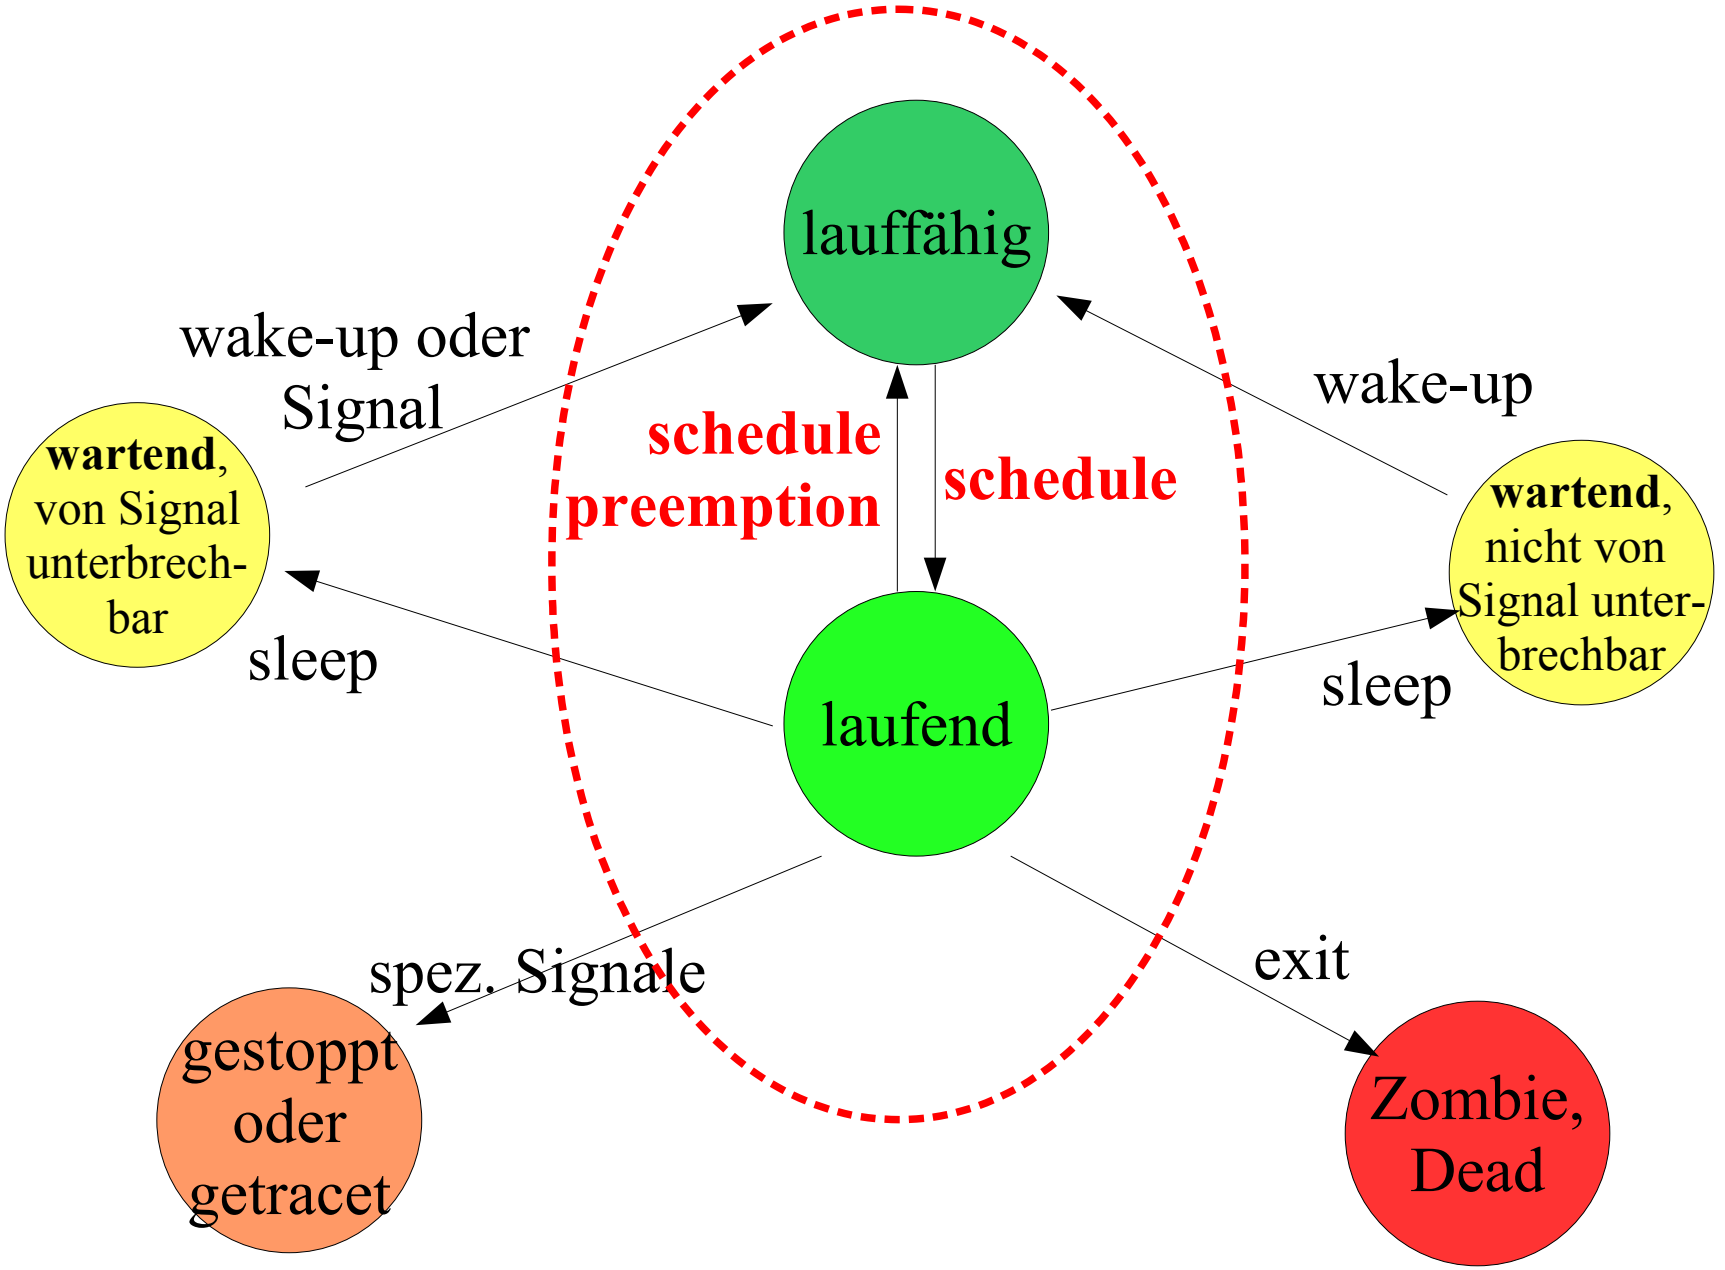

Run Queues

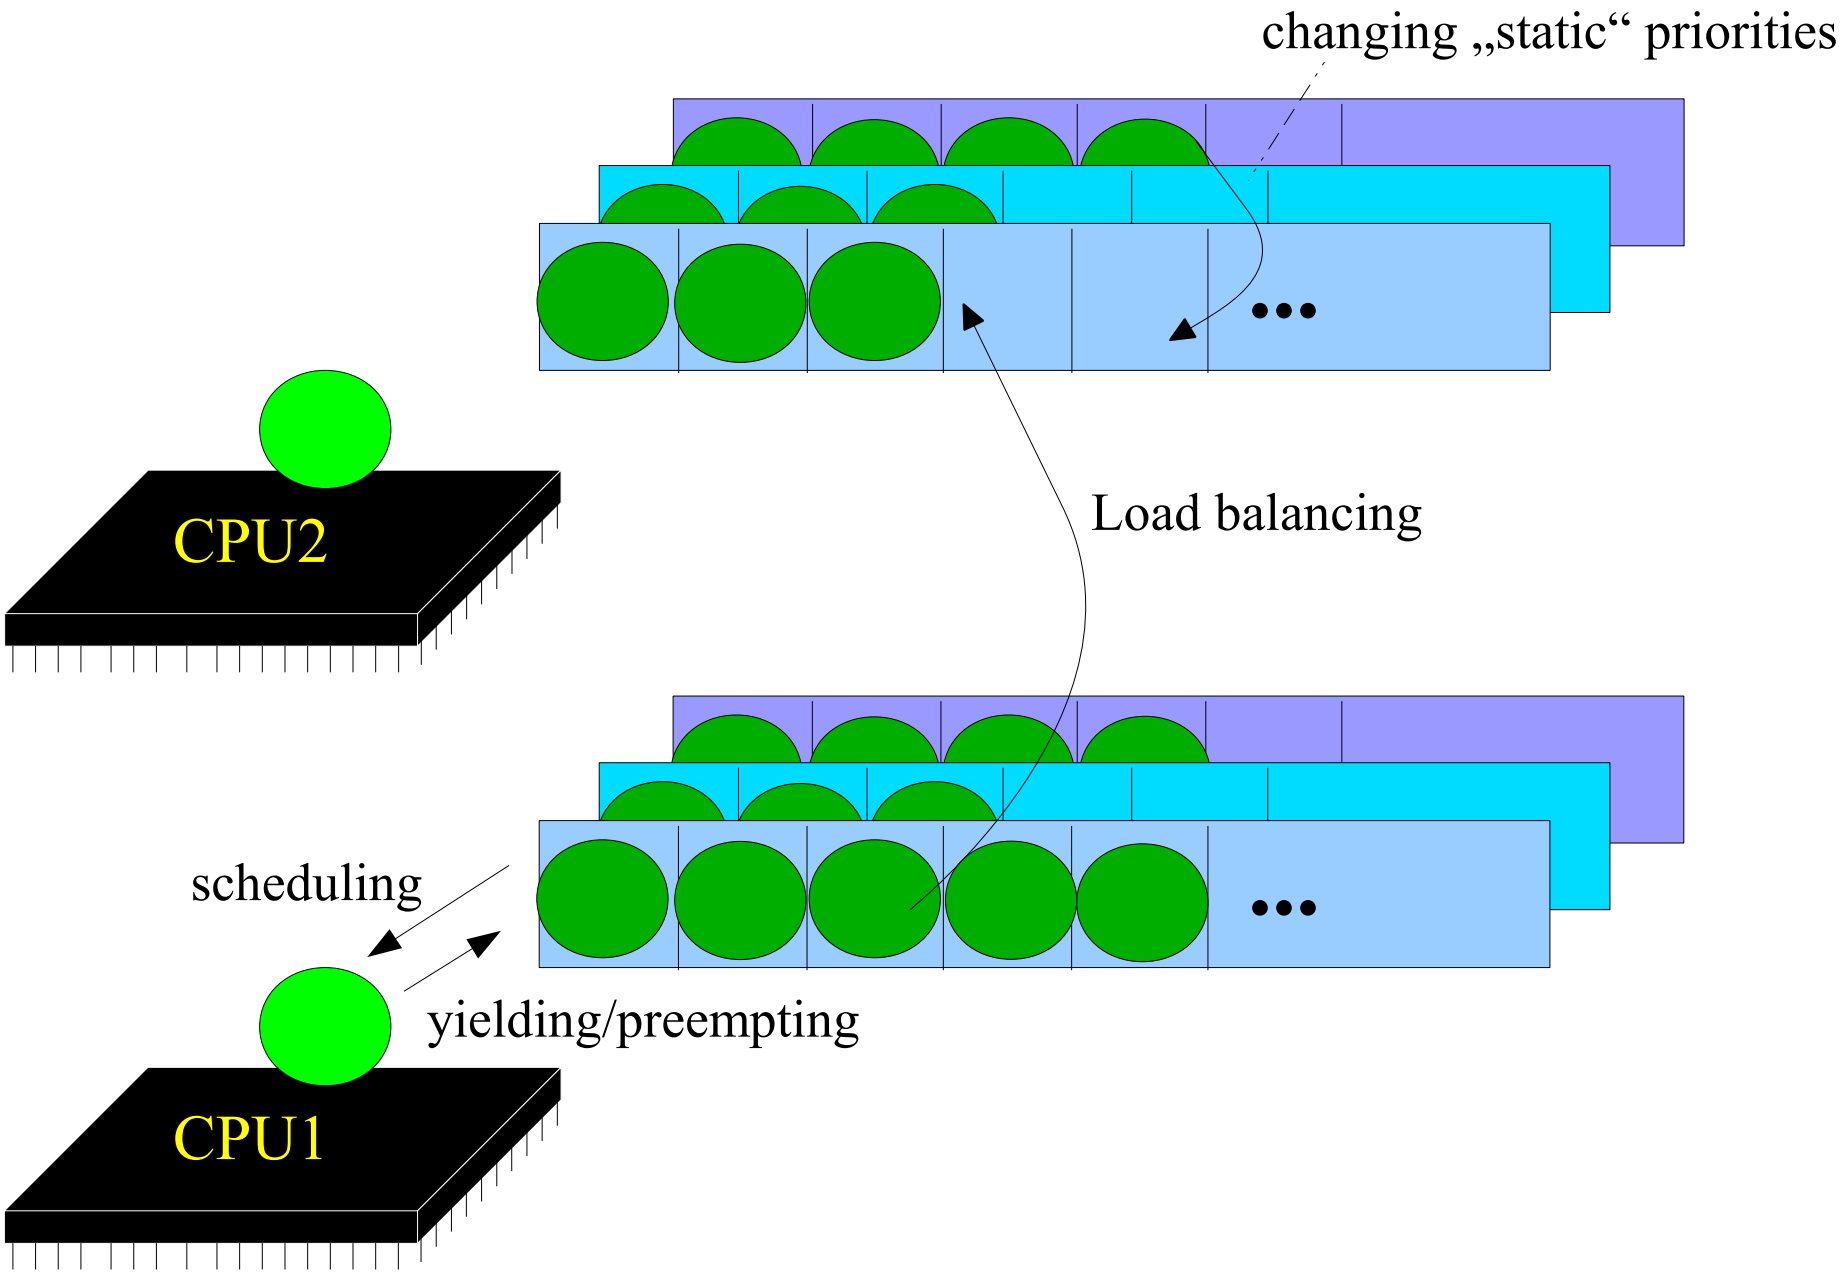
changing „static“ priorities
Load balancing
CPU2
scheduling
yielding/preempting
CPU1

Scheduling-Parameter

- Schedulingverfahren (policies)
- Statische Prioriäten (der Verfahren)
  - pro CPU eine run queue pro statischer Priorität
  - unfair!
- Nice Werte / Gewichte / Anteile (shares)
  - Bestimmen Gewichtung innerhalb einer Priorität
  - Systemruf `setpriority()`

Scheduling Objekte

- Scheduling entities
  - `struct sched_entity` in `linux/sched.h`
  - z.B. `current->se`
  - haben ein Gewicht (weight)
- Atomare Scheduling Objekte
  - Tasks
- Komplexe Scheduling Objekte
  - Bestehen aus einer Liste von Scheduling Objekten, z.B.
    - Prozesse
    - alle Prozesse eine Users
    - beliebige Gruppen von Prozessen
  - Nicht atomare Scheduling Objekte machen rekursive Ablaufplanung innerhalb des Scheduling Objects
  - Realisiert als control groups (cgroups)

Gruppen Scheduling

- Kernbauoptionen `CONFIG_RT_GROUP_SCHED`, `CONFIG_FAIR_GROUP_SCHED`
- Gruppierungsmechanismus
  - `CONFIG_CGROUP_SCHED`
    - Basiert auf control groups (siehe `Documentation/cgroups`)
    - cgroup Pseudodateisystem

```
# mount -t tmpfs cgroup_root /sys/fs/cgroup
# mkdir /sys/fs/cgroup/cpu
# mount -t cgroup -ocpu none /sys/fs/cgroup/cpu
```

    - Verzeichnis in cgroup/cpu Ordner bezeichnet Scheduling Gruppe:
      - `tasks` – liste der PIDs der Mitgliedsprozesse (`task->css_set`)
      - `cpu.shares` – relativer share der Gruppe zur Gewichtsberechnung
      - `release_agent` - Pfad zu Programm (nur in toplevel cgroup)
      - `notify_on_release` - lasse `release_agent` Programm laufen, wenn letzte Task die cgroup verlässt
    - Zuordnung einer Task zu einer cgroup wird bei fork/clone vererbt

Scheduling Verfahren (policy)

- Kann mit `sched_setscheduler()` Systemruf Prozessweise gesetzt werden
- Im Kern als `struct sched_class` implementiert
- Echtzeitverfahren
  - Linux unterstützt nur „weiche“ Realzeit
  - jeweils Priorität 1 - 99
  - implementiert durch `rt_sched_class` (`kernel/sched/rt.c`)
  - Varianten: `SCHED_FIFO, SCHED_RR`
- „vollständig faire“ Verfahren
  - jeweils Priorität 0, Nice Werte -20 – 19
  - Implementiert durch `fair_sched_class` (`kernel/sched/fair.c`)
  - Varianten:
    - `SCHED_OTHER` (Kern: `SCHED_NORMAL`)
    - `SCHED_BATCH`
    - `SCHED_IDLE` (Nice Wert > 19)

Completely fair scheduler (CFS) I

- Jedes top level Scheduling Object t hat Gewicht w(t)
  - `t->se->load.weight`
- T_{rq} = { t | t ist lauffähige Task in run queue rq }
- $W(T_{rq})$ = Summe { w(t) | t in T_{rq} }
  - `cfs_rq->load.weight`
- Schedulingperiode: P (default 20ms)
- Ideale Zeitscheibe für t: slice(t) = P * w(t) / $W(T_{rq})$
- Run queue: implementiert als red black tree
  - Ordungsschüssel: vruntime
  - vruntime: mit Gewicht normalisierte bisherige Laufzeit eines Scheduling Objektes
  - merkt sich min_vruntime

Exkurs: Red Black Trees

- Semi-balancierter binärer Suchbaum
  - längster Pfad im Baum maximal 2 mal so lang wie kürzester Pfad
  - schnelles Einfügen und Löschen (O(log n))
  - siehe Wikipediaeintrag für Red Black Trees
- Benutzung im Linux Kern
  - CFS run queues, diverse I/O Scheduler, hochauflösender Timer, ext3fs, VMA tracking, epoll fds, …
- `linux/rbtree.h`
  - `struct rb_node`
  - `struct rb_root`
  - `rb_entry(ptr,type,member)` analog zu `list_entry()`
  - Funktionen für parent, color, next, prev, first, last, replace, erase
  - Keine(!) Funktionen: für search , insert (siehe Kommentar & Beispiel am Anfang von `rbtree.h`)

Completely Fair Scheduler (CFS) II

- Annäherung an ideale Zeitscheibe für Scheduling Objekt t:
- Wiederhole
  - lasse t eine kurze Zeit auf laufen (ns timer)
  - aktualisiere vrtime von t
  - sei t_0 das erste Scheduling Objekt in der Run Queue
  - wenn vrtime(t) > vrtime(t_0) + delta dann
    - Füge t in run queue ein
    - entnimm t_0 der run queue
    - Setze t = t_0,

RT Scheduler

- Reines prioritätsgesteuertes FIFO (`SCHED_FIFO`) oder Round-Robin (`SCHED_RR`)
- Systemweite Attribute
  - `/proc/sys/kernel/sched_rt_period_us` (default 1s)
  - `/proc/sys/kernel/sched_rt_runtime_us` (default 0,95s, -1 ist unbegrenzt)
  - `(sched_rt_period_us – sched_rt_runtime_us) / sched_rt_period_us` CPU-Anteil ist für CFS reserviert
- `CONFIG_CGROUP_SCHED`
  - .../<cgroup>`/cpu.rt_runtime_us`

Systemrufe zur Prozessablaufplanung

```
int getpriority(int which, int who);

int setpriority(int which, int who, int prio)

int nice(int inc)  // library function in glibc

int sched_setaffinity(pid_t pid, size_t cpusetsize, cpu_set_t *mask);

int sched_getaffinity(pid_t pid, size_t cpusetsize, cpu_set_t *mask);

int sched_setparam(pid_t pid, const struct sched_param *param);

int sched_getparam(pid_t pid, struct sched_param *param);

int sched_get_priority_max(int policy);

int sched_get_priority_min(int policy);

int sched_rr_get_interval(pid_t pid, struct timespec * tp);

int sched_setscheduler(pid_t pid, int policy, const struct
                                                sched_param *param);

int sched_getscheduler(pid_t pid);

int sched_yield(void)
```

Schlafen und Aufwachen

- Schlafen
  - Eintrag in eine Warteschlange
  - Setzen des Task Status auf `TASK_INTERRUPTIBLE` oder `TASK_UNINTERRUPTIBLE`
  - Aufruf von `schedule()`
    - Ruft `deactivate_task()` (`dequeue_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 `enqueue_task()`:
    - trägt Task in Run Queue ein

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?
  - am Ende von Systemrufen oder Unterbrechungen, wenn `TIF_NEED_RESCHED` Flag in `thread_info` gesetzt
  - wenn `sys_yield()` oder `try_to_wake_up()`
- Wann kann eine Task verdrängt werden?
  - User Space
    - bei Rückkehr von Systemruf in User Space
    - bei Rückkehr von Unterbrechung in User Space
  - Kern (wenn `preempt_count` = 0 und `TIF_NEED_RESCHED` gesetzt)
    - bei Rückkehr von Unterbrechung in Kernel Space
    - wenn der Kern explizit `schedule()` aufruft
    - wenn eine Task im Kern blockiert

Anhang:

O(1) Scheduler
seit 2.6.23 durch CFS abgelöst

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

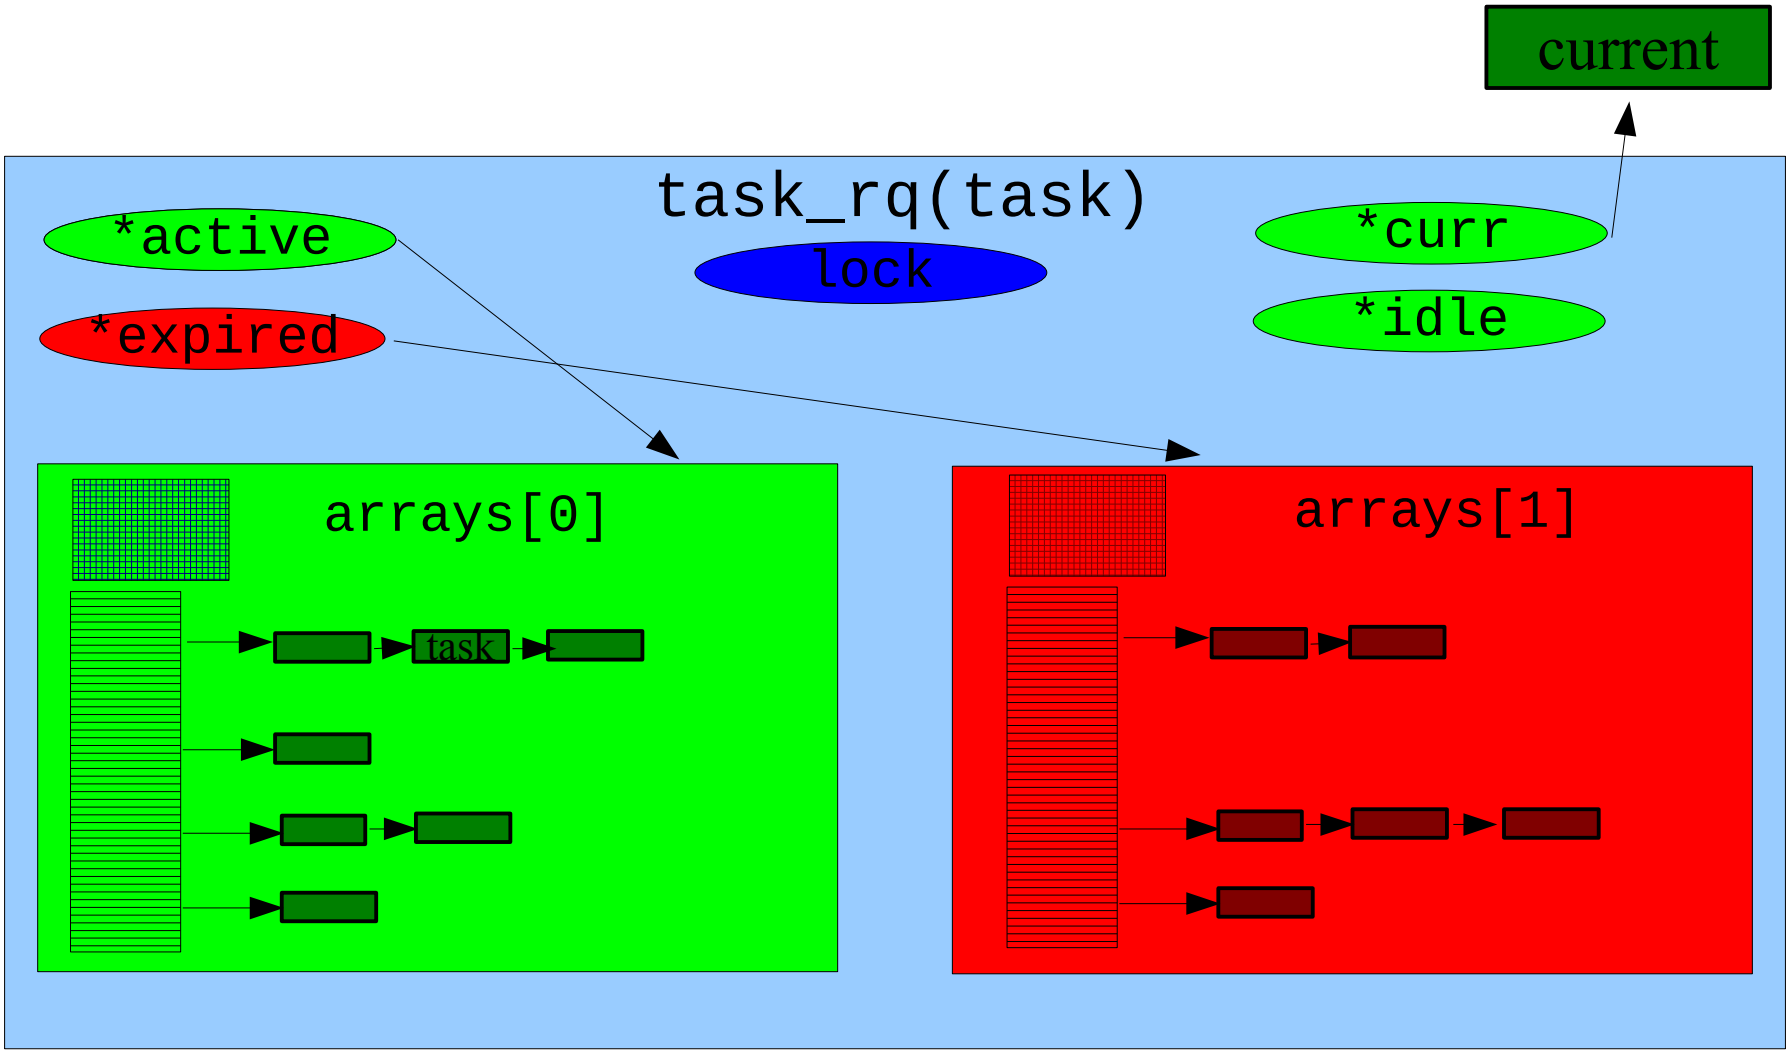

Operationen auf Run Queues

- `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);`
-

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()`

Aussuchen der CPUs

- Kiterien
  - Cache Pollution
  - Energieverbrauch
- CPU Tolologie
  - bzgl. Caches & Speicherzugriff
  - bzgl. Stromzufuhr