Tasks & Prozesse

PD Dr. Reinhard Bündgen
buendgen@de.ibm.com

Was ist eine Task

- Ein sequenzieller Arbeitsauftrag, der Prozessorzeit benötigt
- Beispiele in Unix
  - Prozesse (Instanzen laufender Programme)
  - Threads (light weight processes)
- Linuxkern: kennt nur Tasks, keine Prozesse oder Threads
- In einem multitasking Betriebssystem können mehrere Tasks (quasi) parallel ablaufen

Was gehört zu einer Task?

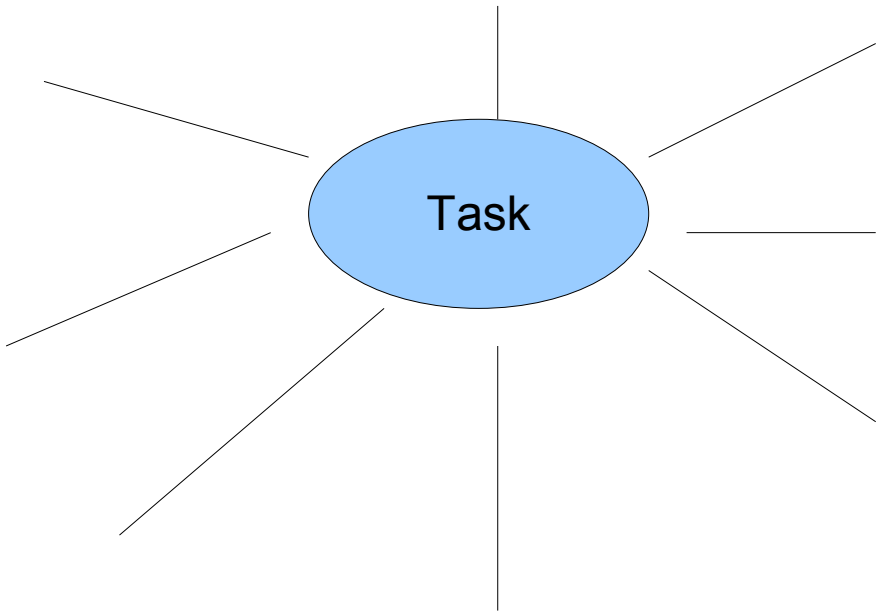

Was gehört zu einer Task?

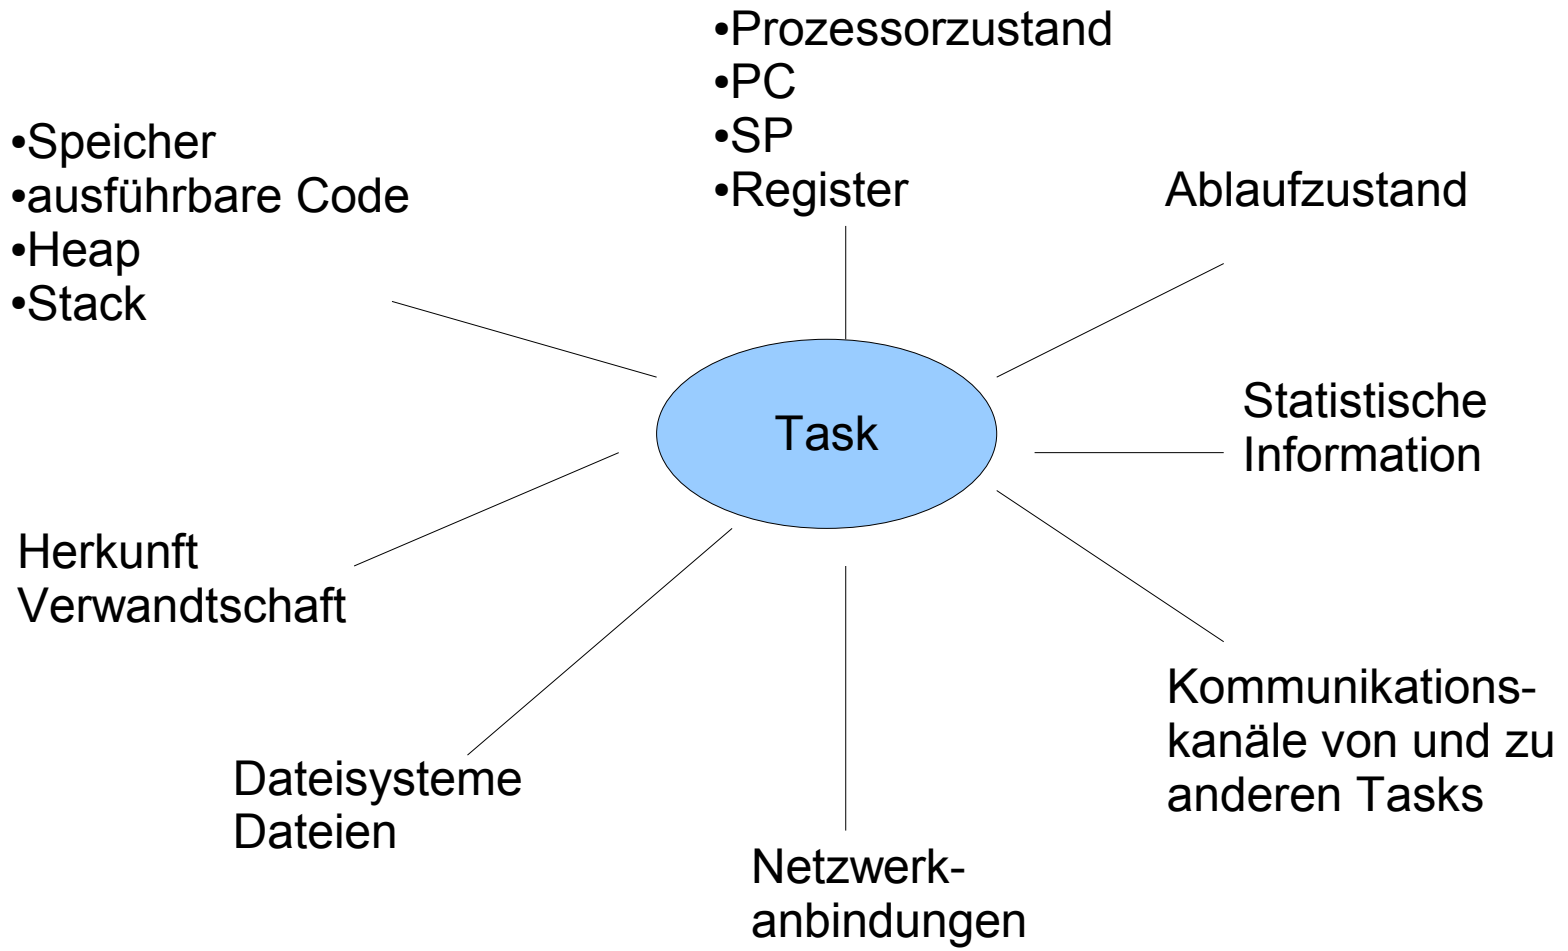

Laufzeiteigenschaften von Tasks

- Können Prozessor abgeben: warten
- Können Kontext wechseln: Nutzer <-> Kern
- sind unterbrechbar
  - Unterbrechung (Interrupt): temporärer Einschub wichtiger Aufgaben
- sind verdrängbar (preemptive, präemptif?)
  - können unterbrochen werden, ohne sofort nach der Unterbrechung wieder die CPU zu erhalten
  - z. B. durch Timerinterrupt & Zeitscheibenende

Befugnisse von Tasks

- Kerneltasks (kernel threads)
  - laufen im Kern Adressraum
  - haben Kernprivilegien
- Prozesse & Threads (Nutzertasks)
  - laufen in eigenem Adressraum (0...$2^{\text{Wortbreite}}$-1 Bytes)
  - haben nur Nutzerprivilegien
  - bei Anforderungen die Befugnisse übersteigen: Systemruf
    - temporärer Kontextwechsel in den Kern
    - eventuell warten
    - anschließend Rückkehr in den Nutzerraum

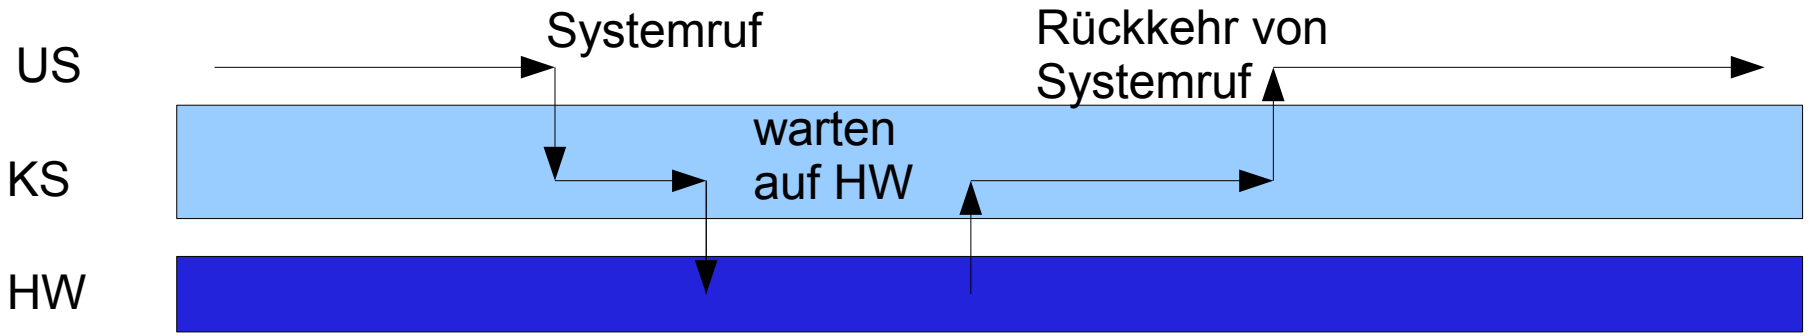

Identifizierung von Tasks im Kern

- Prozessdescriptor vom Typ `struct task_struct`
  - definiert in `include/linux/sched.h`
  - enthält alle wichtigen Daten zu einer Task (~1,7kB für 32bit Architekturen)
  - alloziert via slab/slub allocator
  - aktuelle Task: `current`
- `struct thread_info`
  - definiert in `include/asm/thread_info.h`
  - „zeigt“ auf Stack & `task_struct`
  - aktuelle task: `current_thread_info()`
- Prozessidentifikator (PID) vom Typ `pid_t`:
  - früher max. 32768 pids, jetzt default
  - Erhöhung via `/proc/sys/kernel/pid_max` möglich

Kernstack & Thread_Info

- Stack, der Task im Kern zur Verfügung steht
  - früher 8 bzw 16 kB / Task
  - neu 4 bzw 8 kB / Task
  - enthält am unteren (oder oberen) Ende `struct thread_info`
- `struct thread_info`
  - architekturabhängig
  - zeigt auf `task_struct`
  - `exec_domain`
  - CPU Referenz
  - preempt count

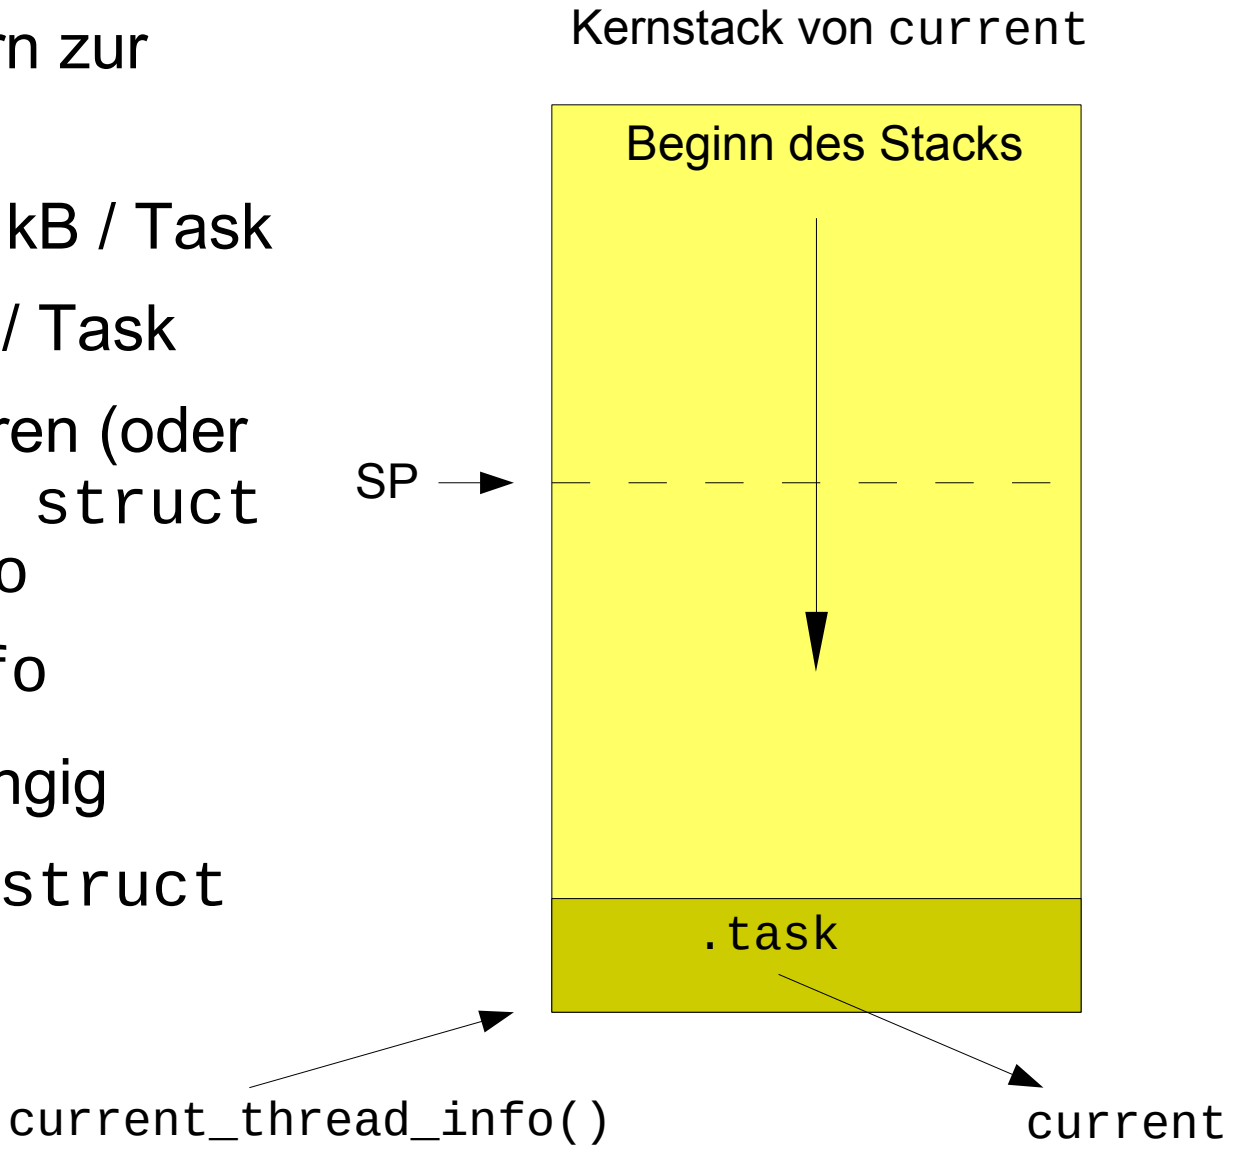

Task Struktur Verkettungen

- doppelt verkettete Listen
  - tasks
  - ptrace_children, ptrace_list
  - children, sibling
  - cpu_timers
- Einzelzeiger
  - real_parent
  - parent
  - group_leader

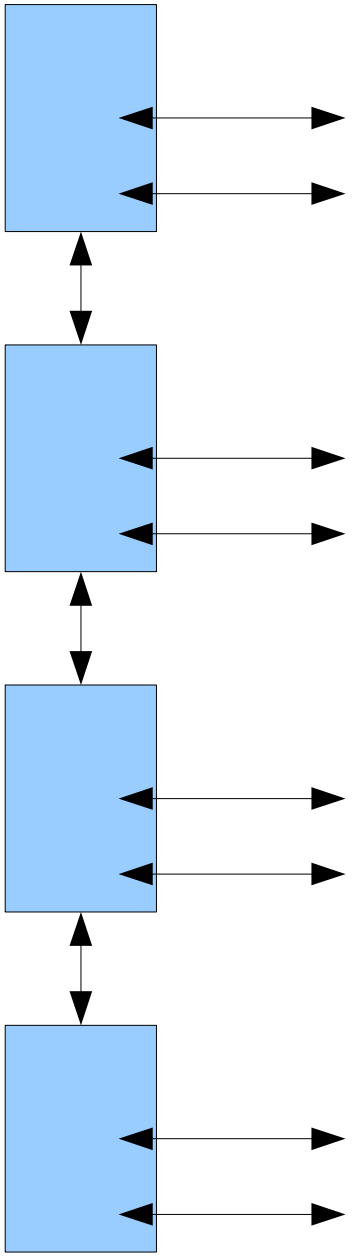

Exkurs: Listen im Kern I

- doppelt verkettete Listen: `<linux/list.h>`
- `struct list_head {`
  - `struct list_head *next, *prev;`
  - `};`

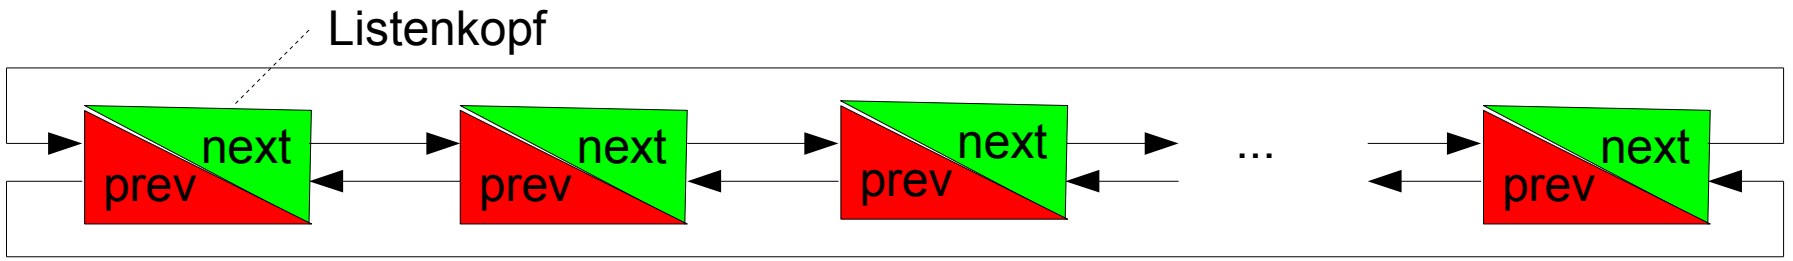

z. B.

```
struct my_struct {
   struct list_head mylist;
   long dog;
   void *cat:
}
```

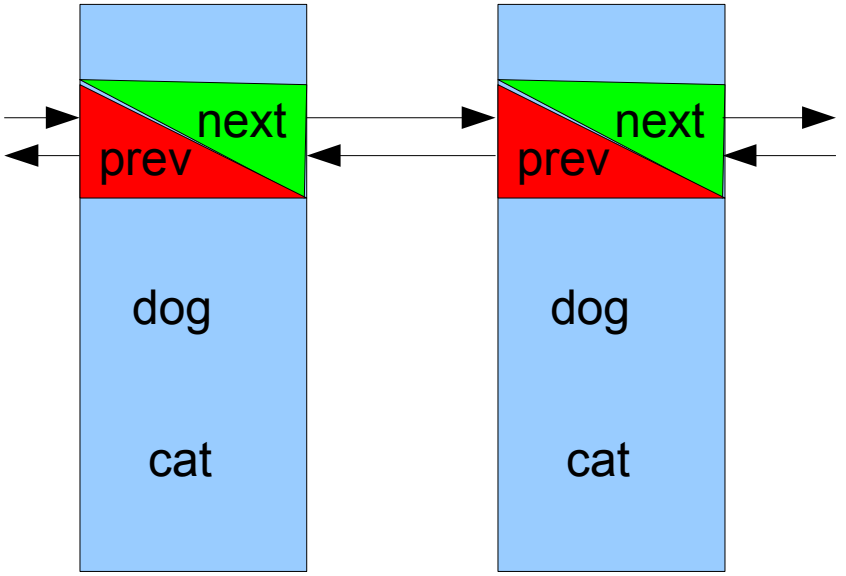

Exkurs Listen im Kern II

- Initialisieren
  - `struct my_struct *p;`
  - `INIT_LIST_HEAD(&p->mylist);` oder
  - `p->mylist=LIST_HEAD_INIT(p->mylist)`
- Operationen (O(1))
  - `list_add(struct list_head *new, struct list_head *head);`
  - `list_add_tail(*new, *head)`
  - `list_add_rcu(*new, *head)`
  - `list_del(*entry)`
  - `list_empty(*head)`
  - ...

Exkurs: Listen im Kern III

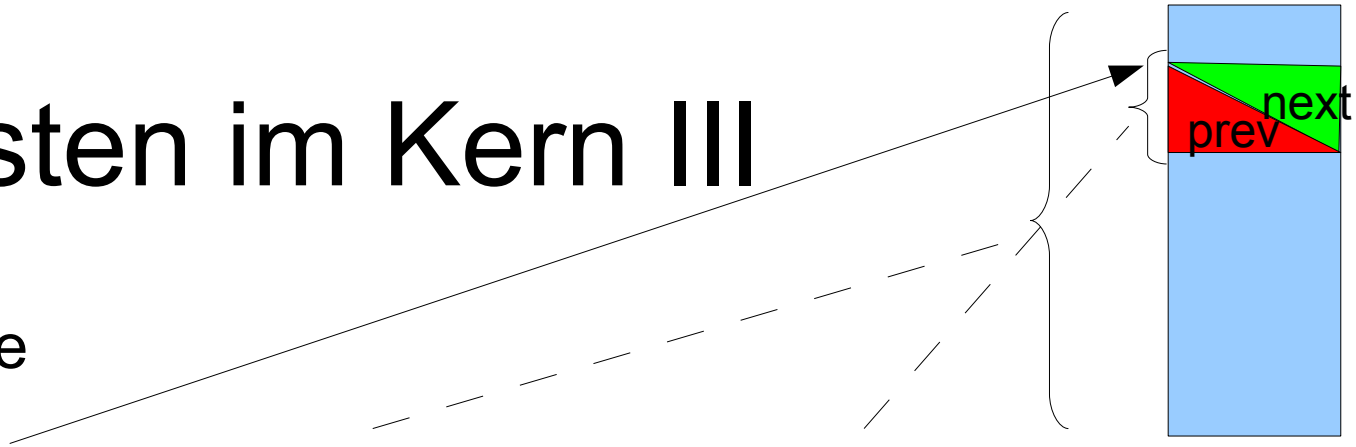

- Element einer Liste
  `list_entry (list_head_ptr, struct_type,member_name)`
- Traversieren von Listen

```
struct list_head *p; struct my_struct *my;
list_for_each(p,mylist) {
        /* p zeigt auf ein Listenelement */
        my=list_entry(p,struct my_struct, mylist)
        /* my zeigt auf die Struktur. die p enthält */
}
```

- ähnlich `list_for_each_prev()`

Traversieren von Tasklisten

- `struct task_struct *task; struct list_head *list;`
- Traversiere alle Kinder einer Task

```
list_for_each(list,&(current->childeren.sibling)){
   task=list_entry(list,struct task_struct,sibling);
   /* task is now one of current's children */
}
```

- Traversiere all Vorfahren einer Task

```
for(task=current; task!=init_task; task=task->parent) ;
```

- Nächste Task

```
list_entry(task->task.next,struct task_struct,tasks)
```

- Traversiere alle Tasks

```
for_each_process(task) {
   printk("%s[%d]\n",task->comm,task->pid);
}
```

Task Zustände

- lauffähig: `TASK_RUNNING`
- wartend
  - & kann Signale empfangen: `TASK_INTERRUPTIBLE`
  - & kann keine Signale empfangen: `TASK_UNINTERRUPTIBLE`
- angehalten: `__TASK_STOPPED`
- ge-trace-t: `__TASK_TRACED`
- beendet durch exit: `EXIT_ZOMBIE`
- fertig zum Aufräumen: `EXIT_DEAD`

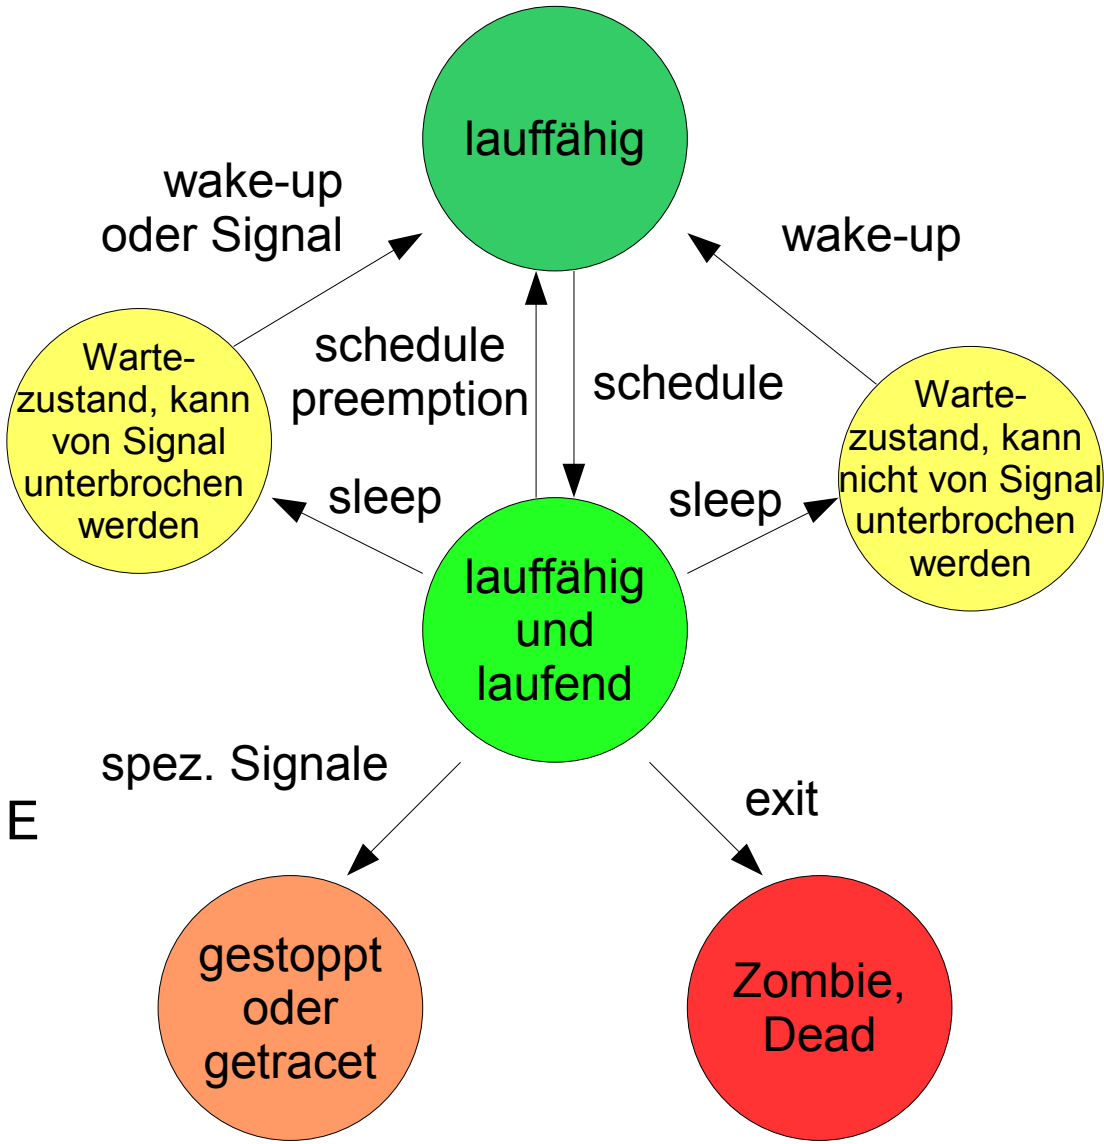

Task-Erzeugung

z. B. Programmstart in Unix

```
pid = fork();
if (pid == 0) {
    /* execute child code */
    /* program start: */
    execv(...);
} else if ( pid > 0 ) {
    /* execute parent code */
} else {
    /* error */
}
```

- `fork()` kopiert Prozess
- `exec[v[e]]()` startet neues Programm in frisch kopierten Prozesskontext
- d.h. bei fork-exec Kombination ist die Kontextkopie durch `fork()` vergeblich!
- moderne Unixe:
  - copy on write (COW)
  - kopiere Seiten erst bei Schreibzugriff

Taskerzeugung im Kern: do_fork()

- `fork()`, `vfork()`, `clone()` werden auf `do_fork()` in `linux/kernel/fork.c` abgebildet
- `do_fork()`
  - Parameter `clone_flags` beschreibt welche Betriebsmittel von Eltern und Kind Task gemeinsam genutzt werden.
  - alloziert neue pid
  - ruft `copy_process()` auf
  - ruft `wake_up_new_task()` auf.

Clone Flags

- `CLONE_VM` set if VM shared between processes
- `CLONE_FS` set if fs info shared between processes
- `CLONE_FILES` set if open files shared between processes
- `CLONE_SIGHAND` set if signal handlers and blocked signals shared
- `CLONE_PTRACE` set if we want to let tracing continue on the child too
- `CLONE_VFORK` set if the parent wants the child to wake it up on mm_release
- `CLONE_PARENT` set if we want to have the same parent as the cloner
- `CLONE_THREAD` Same thread group
- `CLONE_NEWNS` New namespace
- `CLONE_SYSVSEM` share system V SEM_UNDO semantics
- `CLONE_SETTLS` create a new thread local storage (TLS) for the child
- `CLONE_PARENT_SETTID` set the TID in the parent
- `CLONE_CHILD_CLEARTID` clear the TID in the child
- `CLONE_DETACHED` Unused, ignored
- `CLONE_UNTRACED` set if the tracing process can't force CLONE_PTRACE on this clone
- `CLONE_CHILD_SETTID` set the TID in the child
- `CLONE_STOPPED` Start in stopped state

see also `man clone`

Taskerzeugung in Kern: copy_process()

- `copy_process()` in `linux/kernel/fork.c`
  - Plausibilitäts-Checks, Sicherheits-Checks
  - `dup_task_struct()`
  - check resource limits
  - Initialisiere Statistik, Timers
  - kopiere diverse Strukturen
  - `sched_fork()`
    - CPU Zuweisung,
    - `TASK_RUNNING` ohne Einfügen in run-queue
    - (Zeitscheibenallokation)
  - ...
  - return Zeiger auf neue Task

Prozess vs. Threads

- Linux hat keinen expliziten Support für Threads
  - im Gegensatz zu Solaris und Windows
- In Linux werden sowohl Threads als auch Prozesse auf Tasks abgebildet
- Threads werden mit dem Systemruf `clone()` erzeugt
  - Clone hat Parameter, der beschreibt welche Betriebsmittel gemeinsam genutzt werden
  - clone_flags: `CLONE_VM|CLONE_FS|CLONE_FILES|CLONE_SIGHAND`
- Siehe auch „`man clone`“

Task Termination

- Prozesse rufen den `exit()` Systemruf auf
  - evtl implizit ans Ende des Programms einkompiliert/gelinkt
- `do_exit()` aus `kernel/exit.c`:
  - set `PF_EXITING` in `current->flag` in `exit_signals()`
  - lösche Timer: `del_timer_sync()`
  - Accounting
  - Übergabe des Exitcodes
  - Gib AR frei: `exit_mm()`
  - lösche Semaphore: `exit_sem()`
  - räume Taskressourcen auf: `exit_files()`, `exit_fs()`, ...
  - Signalisiere Elternteil in `exit_notify()`:
    - `current->state=EXIT_ZOMBIE`
  - rufe Scheduler auf: `schedule()`

Löschen des Task Descriptors

- nach `do_exit()` existiert die `task_struct` noch
- sie wird evtl. noch vom Elternteil benötigt:
  - die `wait()` Funktionsfamilie gibt pid & Exitcode des abgeschlossenen Kindprozesses zurück
- `sys_wait4()` Systemruf in `kernel/exit.c`
  - see `SYSCALL_DEFINE4(wait4, ...)`
  - `do_wait()` → … → `release_task()`
    - dekrementiere Zahl der Prozesse eines Users
    - `__exit_signal()`,
      - `__unhash_process()`: lösche task aus pidhash
    - evtl: löschen aus ptrace Liste
    - → … → `put_task_struct()`→ `free_task()`
      - gib Kernstack Seiten frei
      - dealloziere `task_struct`

Waisenkinder

- Was passiert mit einem Prozess, dessen Elternprozess aufhört?
- Wird er auf ewig Zombie bleiben?
- Lösung: „Reparenting“
- `do_exit()->exit_notify()->forget_original_parent()`
  - Suche nach neuem Elternprozess:
    - Prozess, der mit prctl (`PR_SET_CHILD_SUBREAPER`) spezifizert wurde (seit kernel 3.4)
    - in gleicher Threadgruppe oder
    - Init Prozess
  - Reparenting aller Kinderprozesse

Kern Threads

- werden benutzt um Kernoperationen im Hintergrund laufen zu lassen
  - Kernprivilegien
  - kein eigener Adressraum
  - keine Kontextwechsel in Nutzerraum
  - schedulable & verdrängbar (preemptive)
- Beispiele: pdflush, ksoftirqd
- Erzeugung von Kern Threads:
  - `int kernel_thread(int (*fn)(void *), void * arg, unsigned long flags);`
    - `do_fork(flags | CLONE_VM | CLONE_UNTRACED, 0, &regs, 0, NULL, NULL);`
  - `CLONE_KERNEL = (CLONE_FS | CLONE_FILES | CLONE_SIGHAND)`

Systemstart: iniziale Prozesse

- Prozess 0 – „swapper process“
  - kernel thread wird in `start_kernel()` (in `init/main.c`) von Grund aufgebaut
  - ...
  - `rest_init()`
    - `kernel_thread(kernel_init, NULL, CLONE_FS | CLONE_SIGHAND);`
    - `schedule();`
    - `cpu_idle();`
- `kernel_init()` in `init/main.c` hat pid=1
  - ...
  - `init_post()` `run_init_process("/sbin/init");`
    - `kernel_execv(...);` `do_execve()`

Ablaufkontexte