Adressräume
und
Speicherverwaltung in Linux

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

Virtueller Speicher und Adressräume

Reale und Virtuelle Adressräume

- Realer Adressraum
  - Menge der im Hauptspeicher physisch vorhandenen Adressen
- Virtueller Adressraum
  - Menge der in einem Programm logisch erreichbaren Adressen (Code, Stack, Heap, ...)
  - beginnt bei Adresse 0, je nach Architektur, 2^{16} , 2^{24} , 2^{31} , $2^{31} + 2^{30}$, 2^{48} Bytes groß (i. A. > realer AR)
  - oft nur lückenhaft genutzt
- Seite
  - zusammenhängender Speicherbereich der Größe 2^k, beginnend auf Adresse $n*2^k$
  - Adressräume werden in Seiten gleicher Größe eingeteilt
  - Typische Seitengrößen: 4 kB, 8 kB

Seiten

- Seite
  - zusammenhängender Speicherbereich der Größe 2^k Bytes, beginnend auf Adresse $j*2^k$
  - Adressräume werden in Seiten gleicher Größe eingeteilt
  - Typische Seitengrößen: 4 kB, 8 kB

Adressraum der Größe 2^n mit Seiten der Größe 2^k:

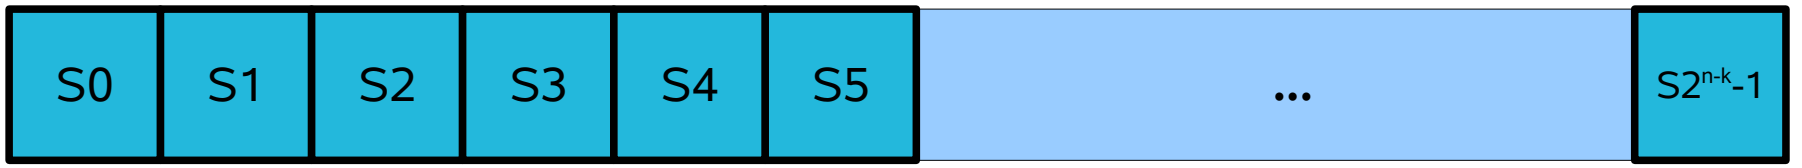

Abbildung von Virtuellen AR auf realen AR

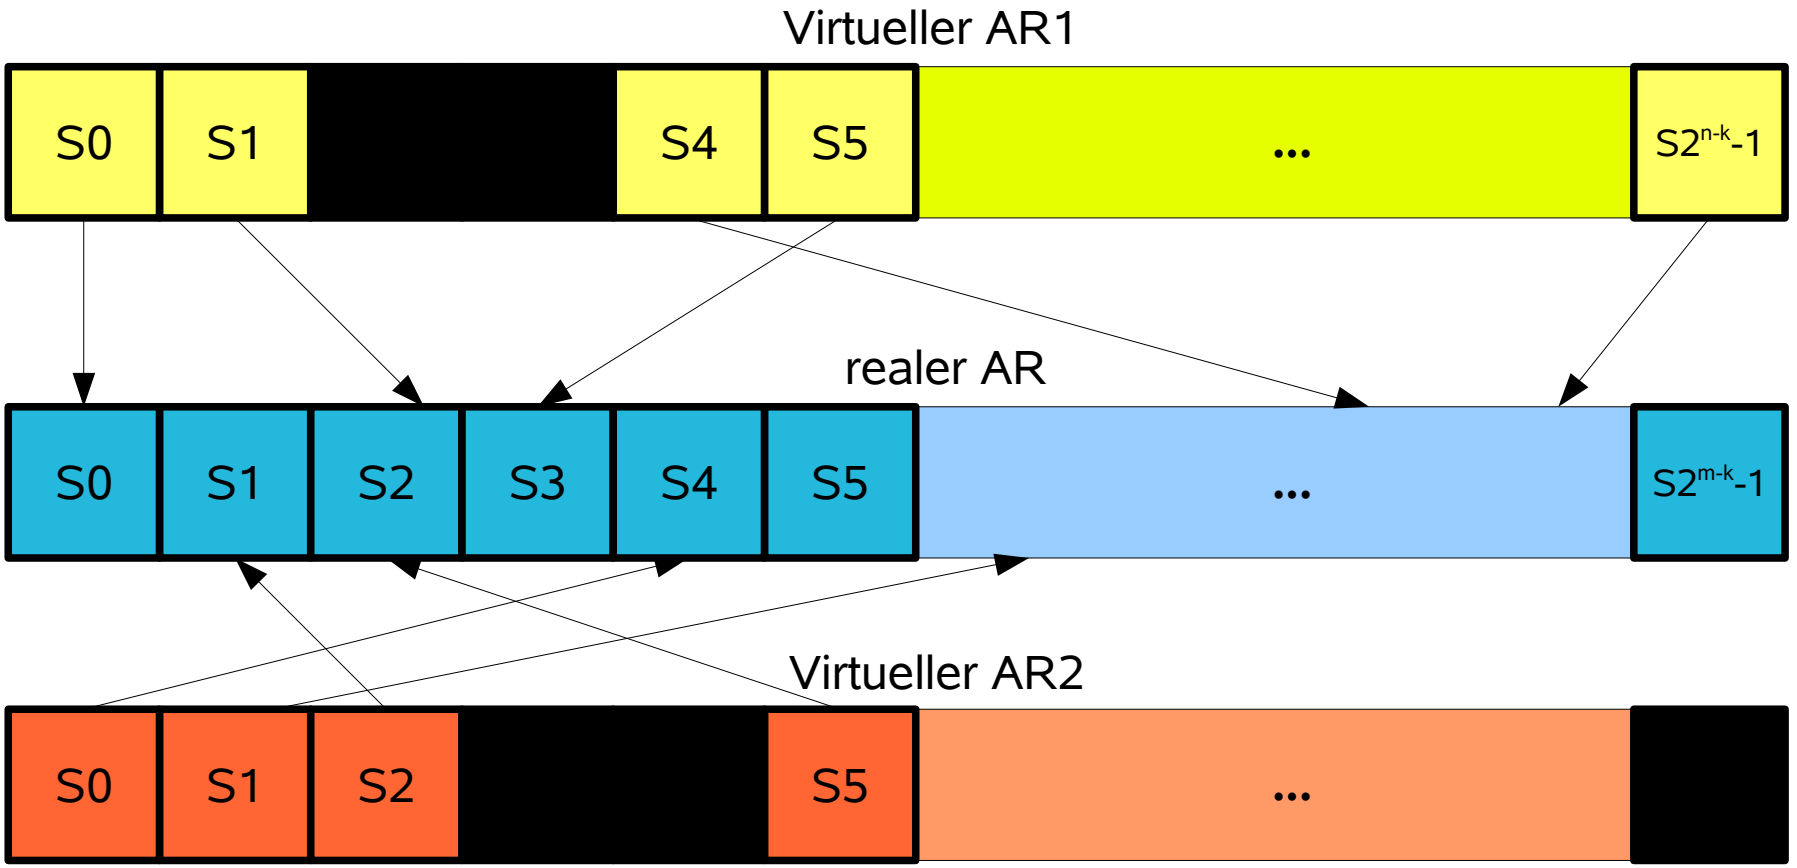

Seitenabbildungsfunktion

- Funktion, die *zum Zeitpunkt t* adressierbare Seiten des virt. AR *einer Task T* auf Seiten des realen AR abbildet
- i. A. ist zu einem beliebig aber festen Zeitpunkt *t* nicht der ganze virt. AR adressierbar!
- Wenn 2 Seiten zweier virt. AR auf die gleiche reale Adresse abgebildet werden, dann
  - gehört die Seite zum „shared memory“ beider zu den AR gehörigen Tasks oder
  - die Seiten sind „read only“

Realisierung der Seitenabbildungsfunktion

- mehrstufige hierarchische Seitentabellen:
  - unterste Hierarchie verweist auf Seiten
  - obere Hierarchien verweisen auf auf Tabellen niederer Hierarchie
- Einträge in jeder Hierarchie dürfen leer sein, wenn keine dazugehörige Seite adressierbar ist.

Linux Seitentabellen: 4 Niveaus

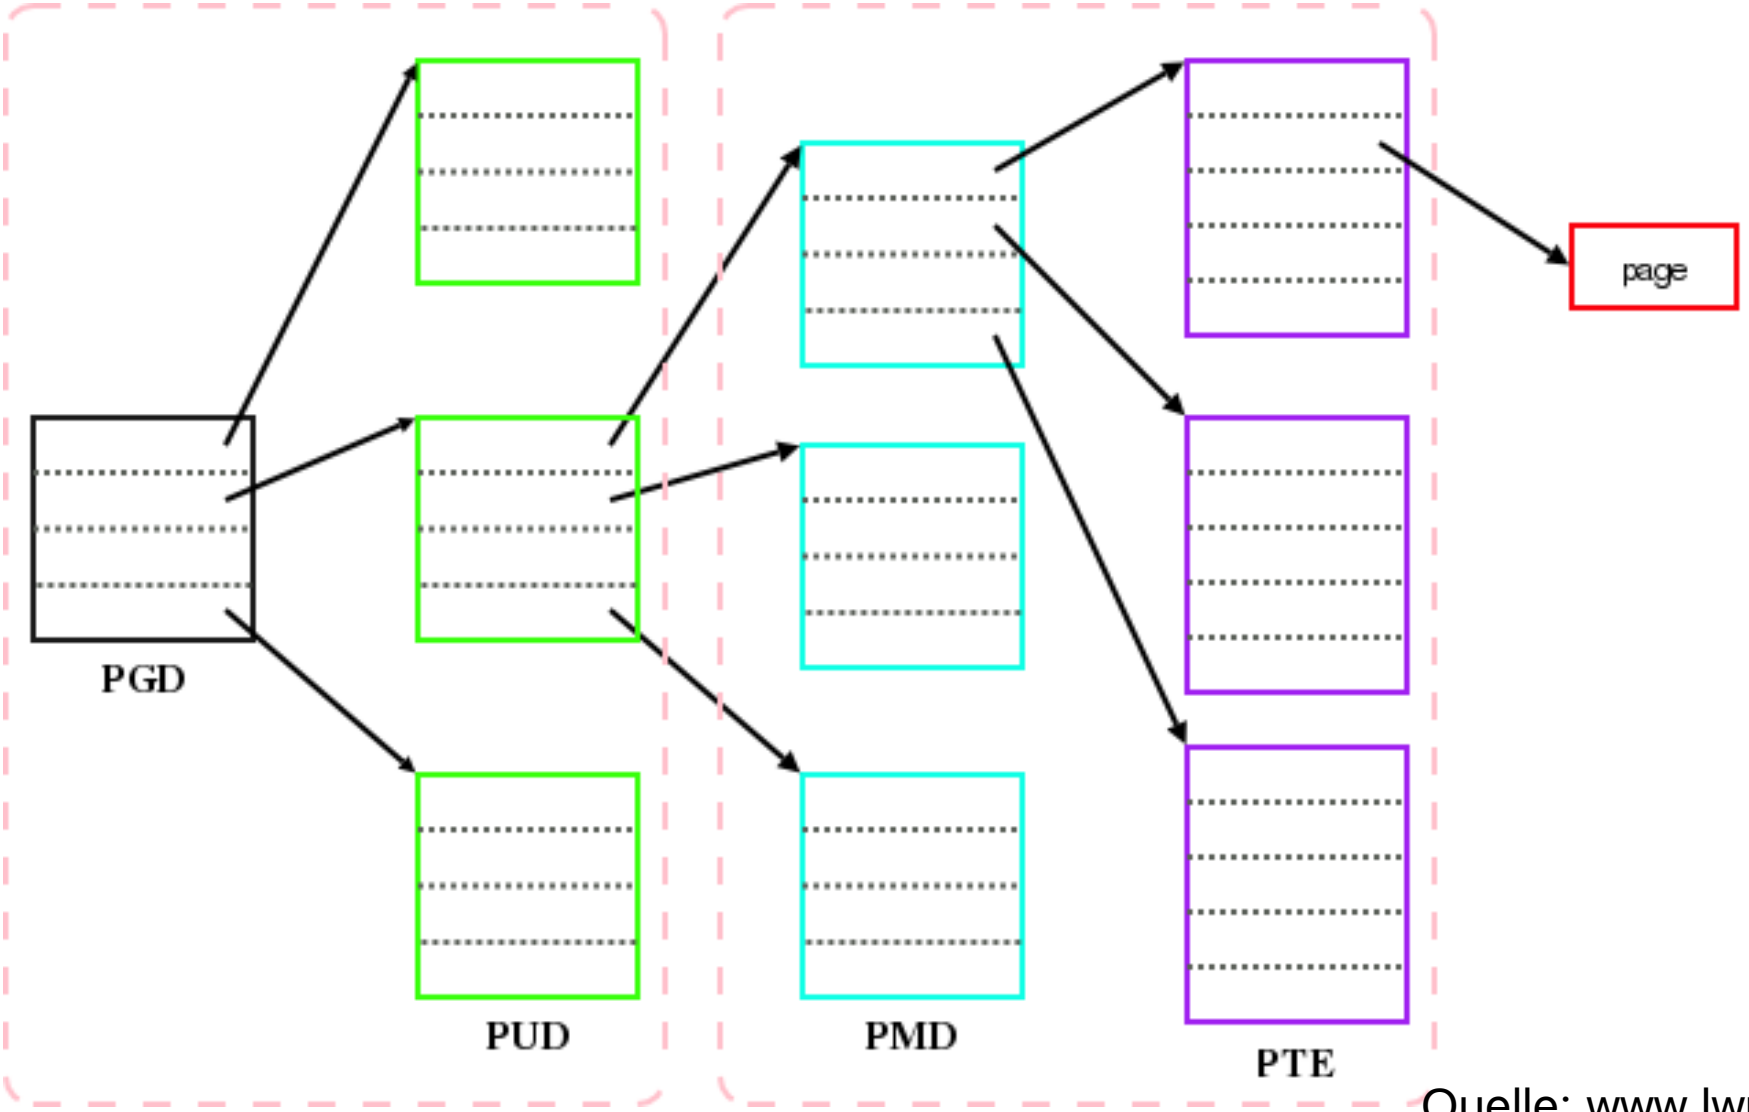

Quelle: www.lwn.net

Adressübersetzung

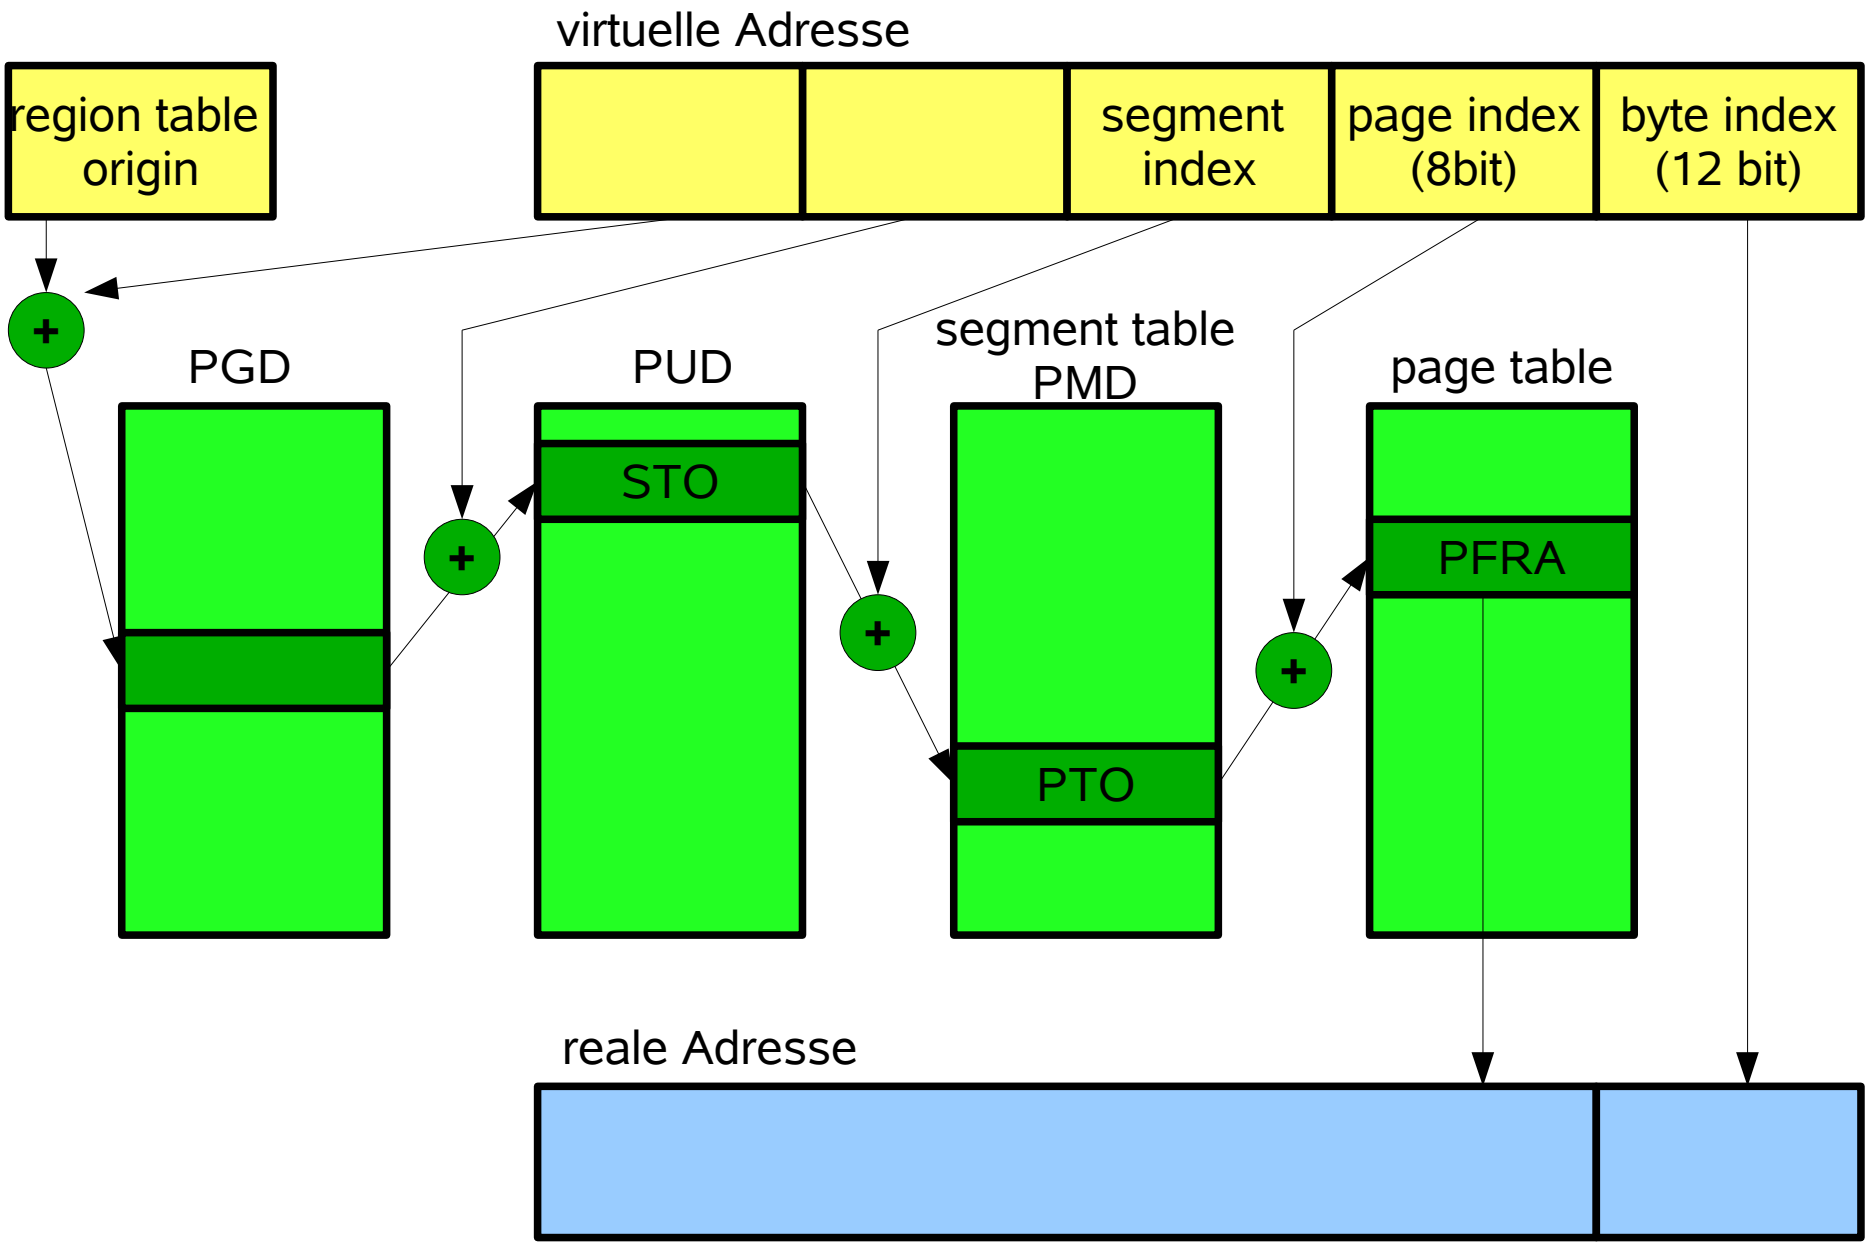

HW Unterstützung für Virtuelle Adressierung

- mehrstufige Seitentabellen
  - z.B. i386: 2-stufig,..., s390x 5-stufig
  - caching der meist benutzen Adressen: TLB
- spezielle Register, die auf Tophierarchie der Seitentabellen zeigen
- page fault exceptions
  - Unterbrechungsmechanismus

Vorteile der Virtuellen Adressierung

- gleichartige lineare Adressräume für alle Programme
- Speicherschutz:
  - verschiedene Adressräume referenzieren i. A. disjunkte Mengen realer Seiten
- es kann mehr virtueller Speicherplatz genutzt werden als real verfügbar ist
  - Lücken in virtuellem AR müssen nicht real vorhanden sein
  - on demand paging:
    - Seiten können von einer Platte eingelesen werden
    - Seiten können auf eine Platte ausgelagert werden

Linux Kernadressraum

- Boot:
  - temporäre Seitentabelle
  - umfasst Kerncode und -datensegmente, Seitentabellen + 128KB für dynamischen Speicher
- Finale Kern Seitentabelle
  - erster Seitenbereich
    - lineares mapping
    - virtuelle Adr = reale Adr + `PAGE_OFFSET`
  - restlicher Speicherbereich
    - freies virtuelles mapping
    - benötigt z.B. für `vmalloc()`

Virtueller Kernel AR für i386

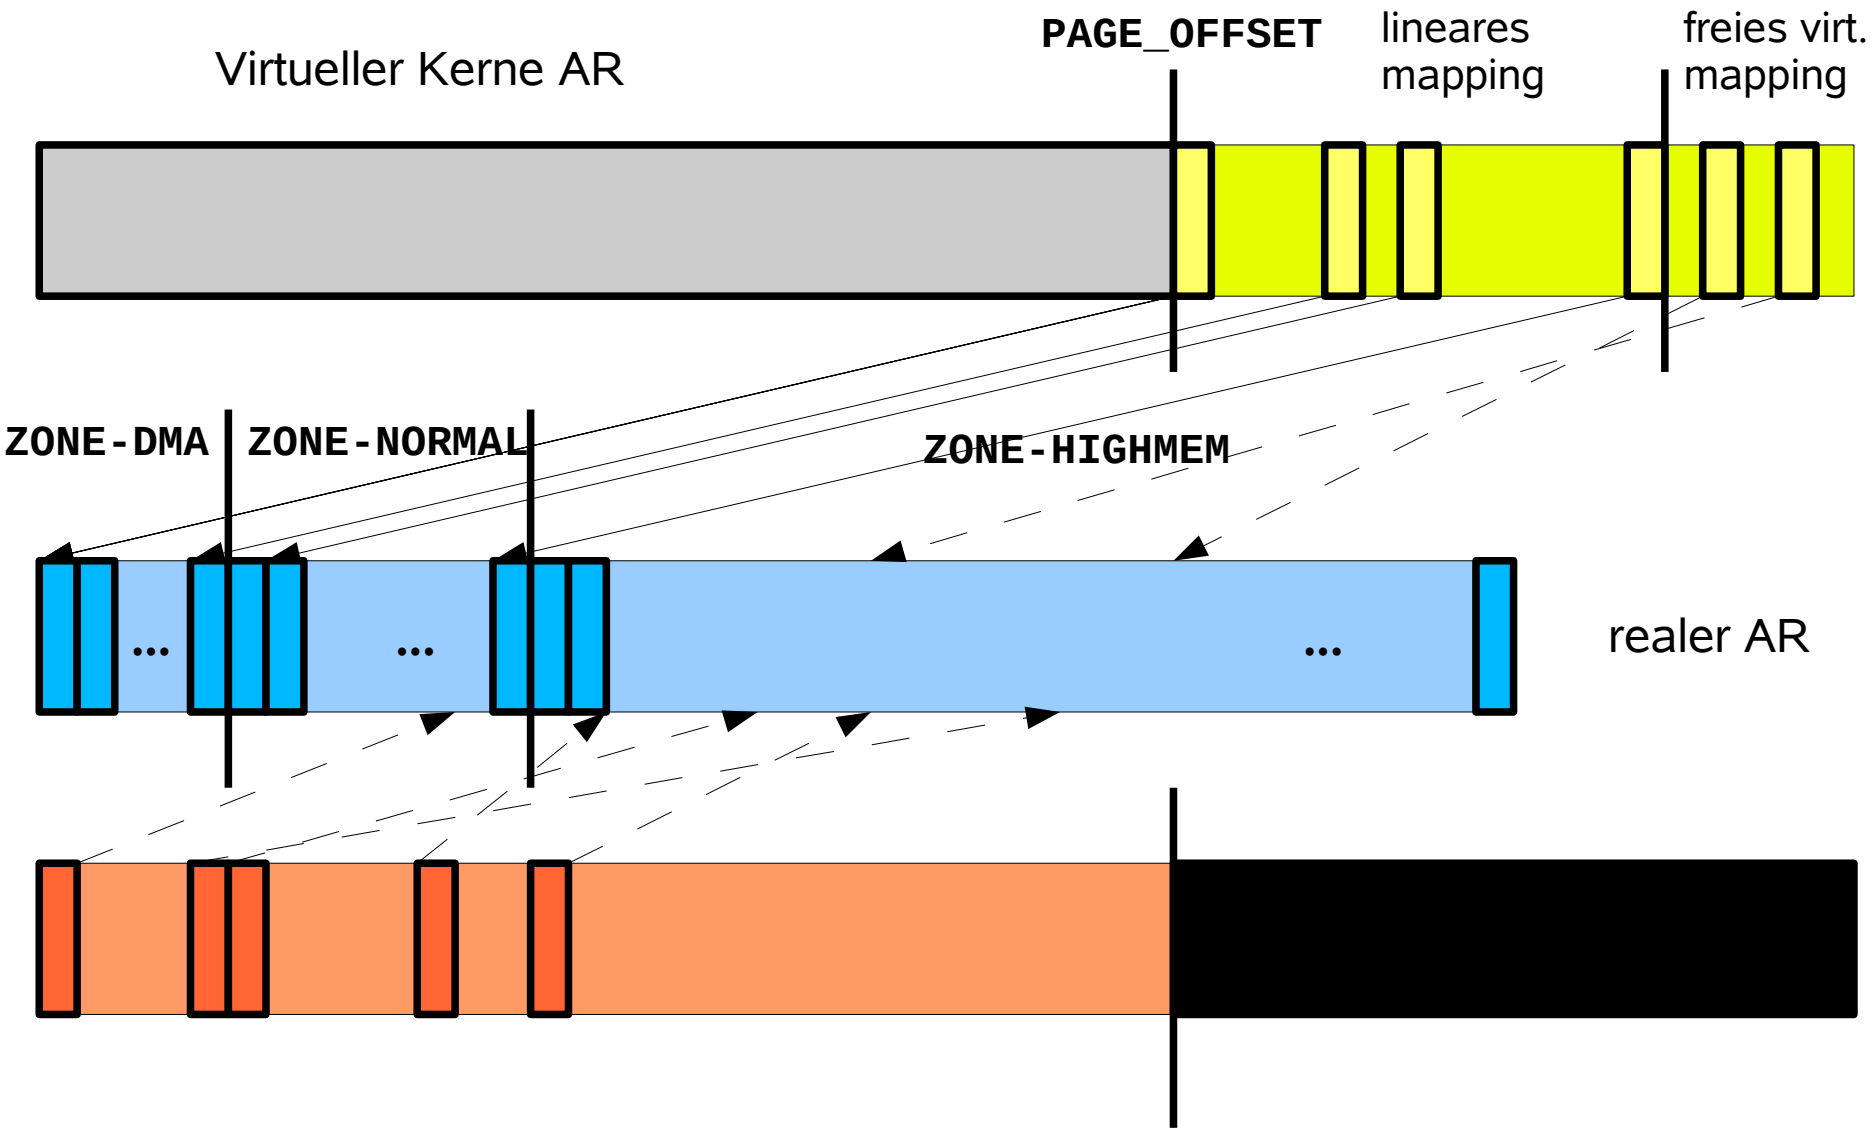

Linux Speicherverwaltung

Repräsentation realer Seiten

- jede reale Seite wird durch ein Objekt vom Typ `struct page` beschrieben
- siehe `<linux/mm.h>`
  - `count`: Referenzzähler,
  - `_mapcount`: Zähler der referenzierenden page tables
  - `lru`: LRU Datenstruktur
  - `flags`: siehe `<linux/page-flags.h>`
    - `PG_dirty, PG_locked, PG_slab, PG_mappedtodisk, ...`
- verbraucht ca 1% des Speichers
- wird hauptsächlich vom Swapper gebraucht

Speicherzonen

- ZONE_DMA
  - DMA fähige Seiten
  - Intel: > 16MB
- ZONE_NORMAL
  - normal adressierbare Seiten
  - Intel 16 MB – 896 MB
- ZONE_HIGHMEM
  - dynamisch gemappte Seiten
  - Intel: > 896 MB

Speicherallokation im Kern

- alloziere ganze Seiten
  - `alloc_pages()`, ...
- alloziere Speicher für bestimmte Datenstrukturen
  - Slab Allokator
- alloziere Speicher byteweise
  - phys. zusammenhängend: `kmalloc()`
  - virtuell zusammenhängend: `vmalloc()`

Allokation von Seiten

- `struct page * alloc_pages( unsigned int gfp_mask, unsigned int order)`
- `unsinged long __get_free_pages( unsigned int gfp_mask, unsigned int order)`
- `void __free_pages( struct page * page, unsigned int order)`
- `void free_pages( unsigned long addr, unsigned int order)`
- `get_zeroed_page()`

- `<linux/gfp.h>`:
- `__GFP_DMA`: Seiten aus DMA Zone
- `__GFP_HIGHMEM`: Seiten aus highmem Zone
- `__GFP_WAIT`: darf schlafen
- `__GFP_HIGH`: greife ggf auf Notfallreserven zu, (darf nicht schlafen)
- `__GFP_IO`: darf E/A auslösen
- `__GFP_FS`: darf Datei E/A auslösen
- `__GFP_COLD`: nutze Cold Page cache
- `__GFP_NOFAIL`: nie aufgeben
- `__GFP_NORETRY`: nur ein Versuch
- ...

Beispiel:

2 Seiten für Interrupt handler: `a = __get_free pages(__GFP_HIGH,1)`

4 Seiten für DMA Treiber: `a = __get_free_pages(__GFP_DMA|GFP_KERNEL,2)`

1 Seite für Nutzer: `p = alloc_free_pages(__GFP_WAIT|_GFP_IO|__GFP_FS,0)`

Zonenbasierter Allokator

- Alloziert Seiten
- ein Suballokator pro Zone
- jeder Suballokator
  - betreibt ein Buddy System
  - hat je CPU einen Per-CPU frame cache
    - hot cache: in HW cache
    - cold cache
- Buddy System
  - alloziere 2^n Seiten
  - Freigabe: verschmelze Buddies

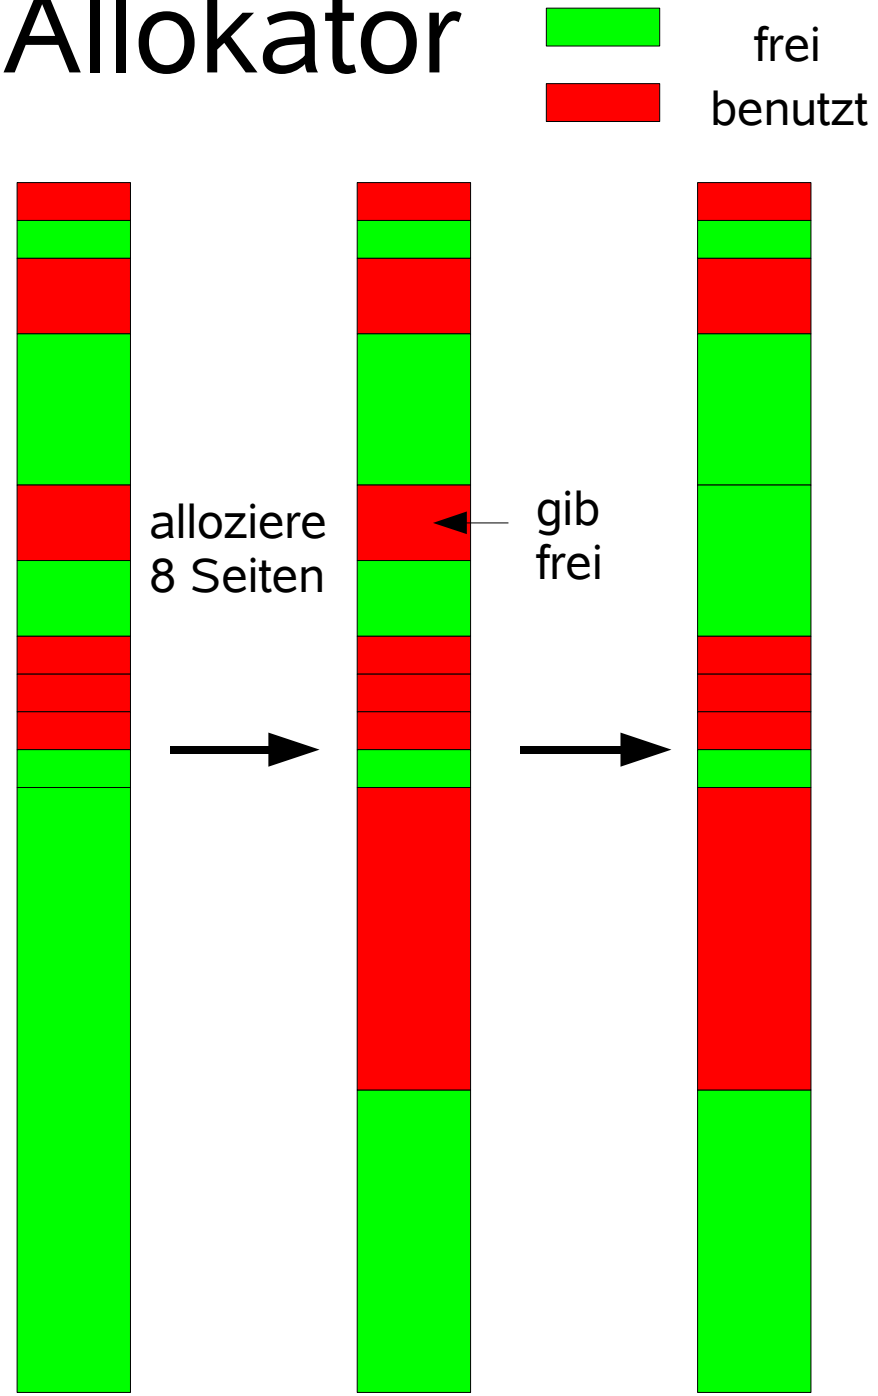

Der Slab Allocator

- Speicherverwaltung für Objekte die oft dynamisch erzeugt und gelöscht werden
- Vorbild Solaris 2.4
- ein Cache je Objekttyp
  - aufgeteilt in Slabs
    - jeder Slab besteht aus einer oder mehren zusammenhängenden Seiten
    - jeder Slab kann maximal 1 oder mehrere Objekte des gleichen Typs enthalten
- Speicher gelöschter Objekte wird aufbewahrt für nächste Allokationen von Objekten dieses Typs
- Schwellenwerte für die Freigabe von Cachespeicher an Kernel
- `/proc/slabinfo`

Struktur des Slab-Allokators

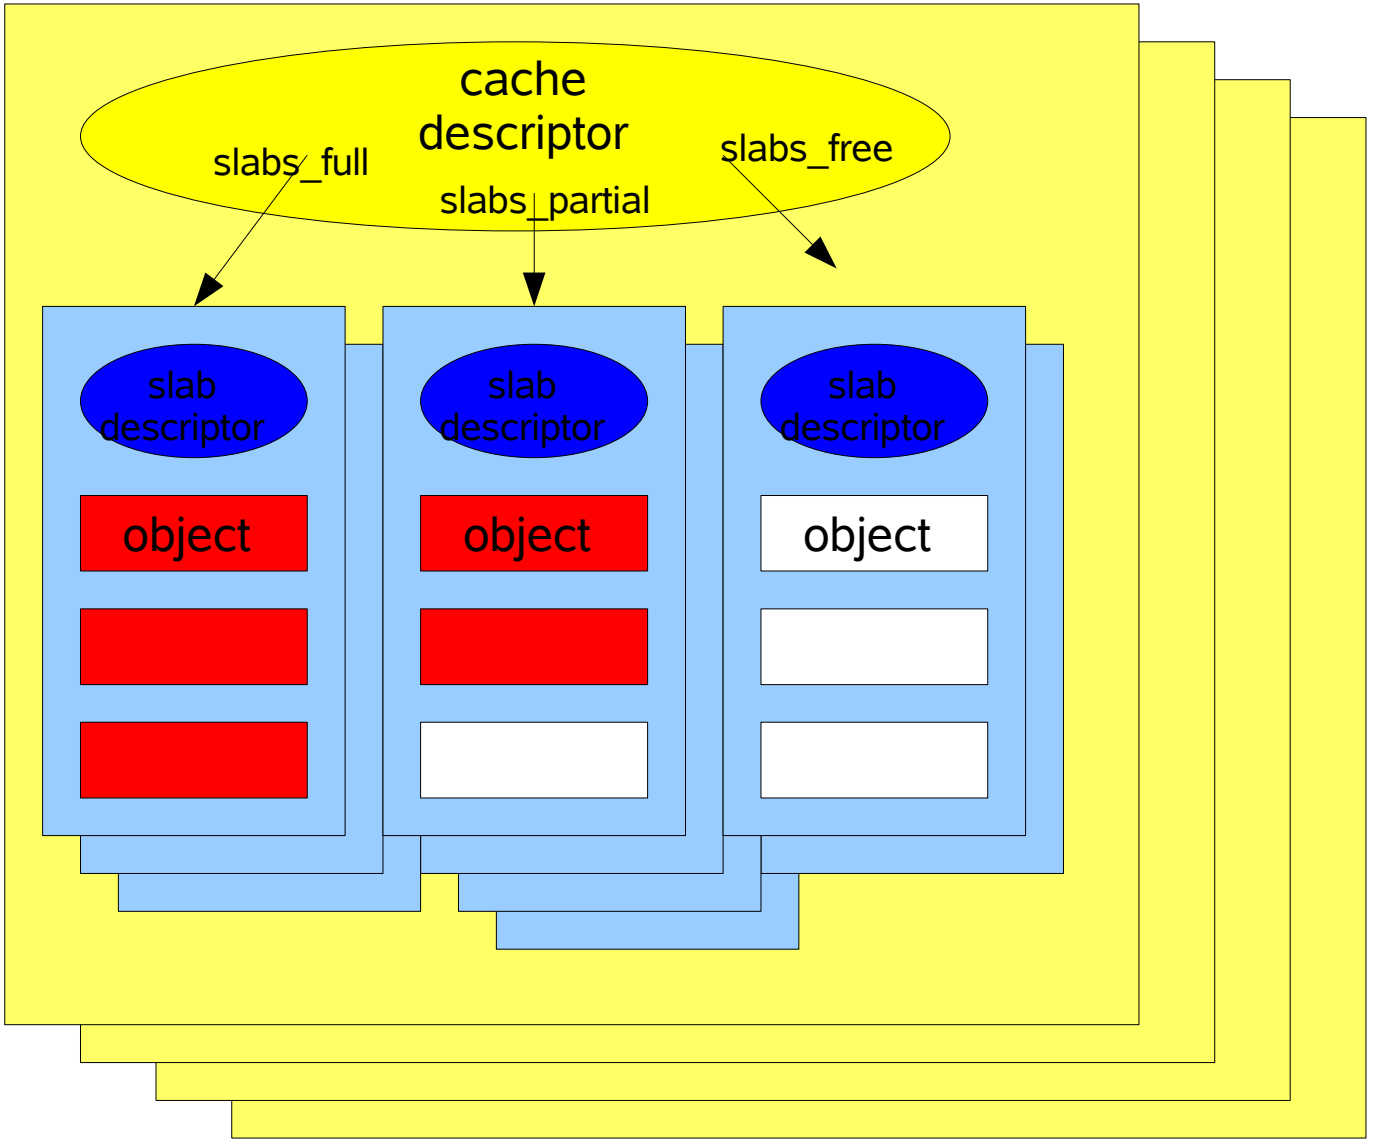

SLAB Kernel API

- Erzeugung eines neuen Caches

```
kmem_cache_create(cont char name, size_t size,
  size_t align, unsigned long flags, void
  (ctor)(void *, kmem_cache_t *, unsigned long),
  (dtor)(void *, kmem_cache_t *, unsigned long))
```

- Allocation neuer Objekte im Cache

```
kmem_cache_alloc(kmem_cache_t *cachep, int flags)

kmem_cache_free(kmem_cache_t *cachep, void *objp)
```

Allokation von Bytesequenzen

- Physikalisch zusammenhängend
  - `include/linux/slab.h & mm/slab.c`
  - `void * kmalloc(size_t size, int flags)`
  - `void kfree(const void *objp)`
  - Standard-Slabs der Größen 2^5 – 2^{17} Bytes
- virtuell zusammenhängend
  - `mm/vmalloc.c`
  - `void * vmalloc(unsigned long size)`
  - `void vfree(void * addr)`