# Betriebssystemtechnik

## Prozesssynchronisation: Wettlauftoleranz

Wolfgang Schröder-Preikschat

Lehrstuhl Informatik 4

26. Juni 2012

# Gliederung

# Synchronisationskonzepte: Befehlssatzebene [8]

**Alleinstellungsmerkmal** dieser Abstraktionsebene sind allgemein die in der **CPU** manifestierten Fähigkeiten eines Rechensystems, hier:

(a) in Bezug auf die Bereitstellung von Spezialbefehlen und

(b) hinsichtlich der Semantik dieser Befehle zur Prozessverarbeitung

Techniken zur Synchronisation gleichzeitiger Prozesse können demzufolge nur auf sehr einfache, elementare Konzepte zurückgreifen

zu (a) die Möglichkeit, externe/interne Prozesse aussperren zu können

- Unterbrechungssperre
- Umlaufsperre (*aktives* Warten) ✓

zu (b) die Möglichkeit, kritische Abschnitt so ausformulieren zu können, dass gleichzeitige Prozesse nicht ausgesperrt werden

- unterbrechungstransparente Synchroniation ✗
- nichtblockierende Synchroniation ✗

# Toleranz gegenüber Wettlaufsituationen

**Wettlaufsituation** bezeichnet einen bestimmten Umstand gleichzeitiger Prozesse eines nichtsequentiellen (verteilten) Programms

- bei dem der zeitliche Ablauf von Elementaroperationen Auswirkung auf das Ergebnis einer Komplexoperation haben kann
- ein **kritischer Wettlauf**, auch (engl.) *race condition* oder *race hazard*
  - neutral/positiv (*condition*) oder negativ (*hazard*) belegt
  - je nachdem, welchen Effekt der Ausgang dieses Wettlaufs bewirkt
- eine Berechnung, die eine ggf. unerwartet **kritische Abhängigkeit** vom relativen Zeitverlauf von Ereignissen zeigt

**Toleranz** gegenüber dieser Situation meint, nichtsequentielle Programme so zu gestalten, dass gleichzeitige Prozesse jederzeit zugelassen sind

- **optimistische Nebenläufigkeitskontrolle** mit/ohne Spezialbefehlen

*Toleranz ist der Verdacht, dass der andere Recht hat.*


Quelle: Gedenktafel, Berlin, Bundesallee 79

# Gliederung

# Unterbrechungstransparente Synchronisation [6]

Koordinierung von unterbrechungsbedingten Aktivitäten, ohne **asynchrone Programmunterbrechungen** abzuwehren

- die Systemsoftware ist *gänzlich* frei von Unterbrechungssperren[1]
- Synchronisation verwendet nur nichtprivilegierte Befehle der ISA
  - mit gewissen **Atomizitätseigenschaften** bezüglich Unterbrechungen
  - wie z.B. atomares lesen/schreiben von Speicherworten ($n > 1$ Bytes)
- nur die Hardware selbst sperrt Unterbrechungen (zeitweilig) aus
  - gleichwohl bestimmt Software, wie *häufig* diese Sperren aktiv sind !!!

Beachte $\hookrightarrow$ Hilfestellung durch andere Konzepte

- um Unterbrechungssynchronisation zur *Ausnahme* werden zu lassen
  - z.B. Fortsetzungssperren, um KA konventionell schützen zu können
- Konzentration auf das Wesentliche: **Nachspannliste** (Kap. II-3, S. 14)

[1] Erneute Abwehr von Unterbrechungen nach Unterbrechungsfreigabe, setzt keine Unterbrechungssperre im eigentlichen Sinn (vgl. Kap. II-3, S. 13).

# Schlange: *first in, first out* (FIFO)

Verwendung z.B. für eine **ankunftszeitorientierte Fadeneinplanung**, die Fäden nach FCFS (Abk. für (engl.) *first come, first served*) verarbeitet

## dos — Abk. für (engl.) *devoid of synchronization*

```
chain_t *dos_fetch(queue_t *this) {
    chain_t *node;
    if ((node = this->head.link) && !(this->head.link = node->link))
        this->tail = &this->head;
    return node;
}
```

```
void dos_aback(queue_t *this, chain_t *item) {
    item->link = 0;
    this->tail->link = item; this->tail = item;
}
```

```
void dos_reset(queue_t *this) {
    this->head.link = 0;
    this->tail = &this->head;
}
```

### Schlangenkopf

```
typedef struct queue {
    chain_t  head;
    chain_t *tail;
} queue_t;
```

*aback* $\models$ Fadenbereitstlg.

*fetch* $\models$ Fadenauswahl

# Schlange: Nachspannliste zur AST-Propagierung

## its — Abk. für (engl.) *interrupt transparent synchronization*

```
extern void     its_reset(queue_t *);             /* clear queue */
extern void     its_aback(queue_t *, chain_t *); /* append chain item */
extern chain_t *its_fetch(queue_t *);             /* remove chain item */
```

```
void its_reset(queue_t *this) {
    dos_reset(this);
}
```

```
void its_aback(queue_t *, chain_t *) {
    ...
}
```

```
chain_t *its_fetch(queue_t *this) {
    chain_t *item = dos_fetch(this);
    ...
    return item;
}
```

## its $\Longleftrightarrow$ dos

*reset* Wiederverwendung
- *chain_t*
- *queue_t*

*aback* Ersetzung

*fetch* Spezialisierung

# Schlange: Wettlauftolerantes *aback*

## Element einfügen: Fußzeiger umsetzen, dann erst Element anhängen

```
void its_aback(queue_t *this, chain_t *item) {
    chain_t *last;

    item->link = 0;          /* make item last chain element */

    last = this->tail;       /* remember item insertion point */
    this->tail = item;       /* advance tail pointer, optimistically */

    while (last->link)       /* overlapping aback: find actual tail */
        last = last->link;

    last->link = item;       /* append item */
}
```

**Atomizität**
- lesen/schreiben von Zeigerwerten ist ELOP

**Überlappungsmuster**
- *aback* überlappt *aback* oder *fetch*

# Schlange: Wettlauftolerantes *fetch*

## Element entfernen

(*dos_fetch* expandiert)

```
chain_t *its_fetch(queue_t *this) {
    chain_t *item;

    if ((item = this->head.link) && !(this->head.link = item->link)) {
        this->tail = &this->head;       /* point of problem! */
        if (item->link) {               /* race condition detected! */
            chain_t *help, *lost = item->link;
            do {                        /* requeue lost elements */
                help = lost->link;
                its_aback(this, lost);
            } while ((lost = help));
        }
    }
    return item;
}
```

**Überlappungsmuster**

- *fetch* wird nur von *aback* überlappt

# Schlange: Plausibilitätskontrolle (Forts.)

*aback*

- überlappt sich selbst immer nur **stapelweise**, wenn überhaupt
- Wettlaufsituation $\iff$ $last = tail$, jedoch $tail \neq item$

  Normalfall $link_{last} = 0 \Rightarrow$ kein *aback*-Wiedereintritt

  Konfliktfall $link_{last} \neq 0 \Rightarrow$ *last* falsch, korrigieren
- Zuweisung an *link* (einfügen von *item*) $\iff$ $last \neq tail$

*fetch*

- überlappt sich **nie selbst**, auch nicht durch Verdrängung
- Wettlaufsituation $\iff$ $head = 0$, jedoch $tail \neq ref(head)$

  Normalfall $link_{item} = 0 \Rightarrow$ *aback* überlappte nicht

  Konfliktfall $link_{item} \neq 0 \Rightarrow item \rightsquigarrow$ *lost & found*
- umtragen der Einträge aus „*lost & found*“-Liste ist atomar

**Beachte $\hookrightarrow$ Parallelverarbeitung**

Nachspannliste

- die **Überlappungsmuster** können beliebig ausfallen

# Gliederung

# Grundsätzliche Idee

Koordinierung sich einander ggf. überlappender Aktivitäten, ohne dabei **gleichzeitige Prozesse**[2] auszuschließen

- toleriert (pseudo-) parallele Programmausführungen
  - parallel: Multiprozessor, wirkliche Parallelität
  - pseudoparallel: Uniprozessor, Parallelität durch Unterbrechungen
- die Verfahren greifen auf **nichtprivilegierte Befehle** der ISA zurück
  - CISC: TAS, FAA, CAS bzw. CMPXCHG
  - RISC: LL/SC
  - sonst: gewöhnliche Befehle zum Lesen/Schreiben von Speicherwörtern
- die Befehle funktionieren im Benutzer- wie auch im Systemmodus

**Beachte**

- kein gegenseitiger Ausschluss ⇒ **Verklemmungsvorbeugung**
- die *benutzten* Befehle sind „echte“ Elementaroperationen der ISA

[2] Prozesse, deren Ausführung sich zeitlich überschneidet.

# Bedingte Wertzuweisung: *Compare and Swap*, CAS

**Elementaroperation** der Befehlssatzebene:

- unteilbar: Unterbrechungs- *und* Zugriffssperre (Datenbus)
- implementiert eine **Transaktion** für Uni- und Multiprozessoren
- gebräuchlich als Einzel- (CAS) und Doppelwortvariante (DCAS)
- eingeführt mit IBM System/370 [3, S. 123]

Ausführung mit einem atomaren „*read-modify-write*“-Zyklus:

1. Lesen eines Datums aus dem Arbeitsspeicher
2. bedingte Modifikation des gelesenen Datums
3. bedingtes Zurückschreiben des Datums in den Arbeitsspeicher

Beachte: CAS lässt sich mittels Sperren nachbilden

| | |
|---|---|
| Uniprozessoren | • Unterbrechungs- oder Verdrängungssperre |
| Multiprozessoren | • Umlaufsperre |

# Bedingte Wertzuweisung: CAS als Maschinenprogramm

## Kritischer Abschnitt

```
int cas(atom_t *ref, word_t exp, word_t val) {
    bool done;

    CS_ENTER(&ref->lock);
    if (done = (ref->data == exp)) ref->data = val;
    CS_LEAVE(&ref->lock);

    return done;
}
```

```
typedef struct {
    word_t data;
    lock_t lock;
} atom_t;
```

- `ref` — die Adresse des atomar, bedingt zu ändernden Speicherworts
- `exp` — der unter der Adresse `ref` erwartete alte Wert
- `val` — der unter der Adresse `ref` zu speichernde neue Wert
  - die Speicherung erfolgt nur, wenn der unter `ref` gespeicherte Wert dem erwarteten Wert `exp` gleicht
  - lag Gleichheit vor, liefert die Funktion *true*, anderenfalls *false*

# Bedingte Wertzuweisung: CAS als Spezialbefehl (x86)

```
ZF = (eax == *ref) ? (*ref = val, true) : (eax = *ref, false)
```

```
int cas(word_t *ref, word_t exp, word_t val) {
    unsigned char aux;

    __asm__ __volatile__(
        "lock\n\t"                      /* prefix next instruction */
        "cmpxchgl %2,%1\n\t"            /* (ref) == exp ? (ref) = val */
        "sete %0"                       /* extend ZF into aux */
        : "=q" (aux), "=m" (*ref)
        : "r" (val), "m" (*ref), "a" (exp)  /* %eax loaded with exp */
        : "memory");

    return aux;
}
```

`lock`
- setzt die Bussperre für den nachfolgenden Befehl
- zwingend für Multi(kern)prozessorsysteme, optional sonst

`cmpxchgl`
- *compare & exchange*: ZF = *true* → Speicherung erfolgt

`sete`
- definiert Variable done mit dem Wert der ZF-Flagge

# Nichtblockierende Synchronisation mit CAS

erledige NBS mit CAS;
  wiederhole
    ziehe *lokale Kopie* des Inhalts der *Adresse* einer globalen Variablen;
    verwende die Kopie, um einen neuen *lokalen Wert* zu berechnen;
    versuche CAS: an *Adresse*, die *lokale Kopie* mit dem *lokalen Wert*;
  solange CAS scheitert;
basta.

pros
- Tolerierung beliebiger Überlappungsmuster
- transparent für die Einplanung: **keine Prioritätsumkehr**
- **Vorbeugung von Verklemmungen**: Bedingung 1 entkräftet [7]
- Robustheit: **keine hängenden Sperren** bei Prozessabbrüchen
- in funktionaler Hinsicht wiederverwendbar und komponierbar

cons
- Gefahr von **Aushungerung** (engl. *starvation*)
- Wiederverwendung sequentieller Altsoftware unmöglich
- **Entwicklung** nebenläufiger Varianten im Regelfall **nicht trivial**

# FAA: *fetch and add* — als Transaktion

Lesen & Aktualisieren einer Zählervariablen durch ein **wettlauftolerantes Maschinenprogramm**

- mit sperrfreier (engl. *lock-free*, Abk. `lf`) Fortschrittsgarantie [2]:
  - garantiert systemweiten Durchsatz
  - riskiert jedoch **Aushungerung** gleichzeitiger, einzelner Prozesse

```
int lf_faa(int *this, int rate) {
    int copy;

    do copy = *this;                          /* fetch contents */
    while (!CAS(this, copy, copy + rate));  /* add value if unvaried */

    return copy;                              /* return (old) contents */
}
```

```
#define CAS(r,e,v)    cas((word_t*)r, (word_t)e, (word_t)v)
```

# FAA: Plausibilitätskontrolle

*copy = *this*
- zieht eine lokale Kopie der zu manipulierenden Zahl

*copy + rate*
- berechnet den neuen Wert auf Basis dieser Kopie

CAS
- versucht, den neuen Wert zu binden (engl. *commit*)
  - *true* $\Longleftrightarrow$ kein Zugriffskonflikt, neuer Wert gültig
  - *false* $\Longleftrightarrow$ **Zugriffskonflikt**, neuer Wert verworfen

*do . . . while*
- terminiert nur, falls der neue Wert gebunden wurde

## Beachte $\hookrightarrow$ ABA-Fall (vgl. S. 26)

- die Festellung des Zugriffskonflikts basiert auf einer Überprüfung des Inhalts einer Speicherstelle, nicht auf der Anwendung ihrer Adresse
- nicht jeder überlappende Schreibzugriff ist daher wirklich erkennbar
  - z.B., wenn zwischenzeitlich eine Änderung um $n$ und $-n$ erfolgt

# FAA: Abbildung auf einen Spezialbefehl

**Fortschrittsgarantie** ist dabei **allein durch die Hardware** gegeben, nicht mehr durch einen als Maschinenprogramm implementierten Algorithmus

```
#define FAA(r,v) faa((int *)r, (int)v)
```

```
int wf_faa(int *this, int rate) {
    return FAA(this, rate);
}
```

gcc -O6 -S

```
wf_faa:
  movl  4(%esp), %edx
  movl  8(%esp), %eax
  lock
  xaddl %eax,(%edx)
  ret
```

```
INLINE int faa(int *ref, int val) {
    int aux = val;

    asm volatile (
        "lock\n\t"
        "xaddl %0,%1"
        : "=g" (aux), "=g" (*ref)
        :  "0" (aux),  "1" (*ref));

    return aux;
}
```

- wartefrei (engl. *wait-free*, Abk. `wf`) [2]:
  - garantiert systemweiten Durchsatz und ist frei von Aushungerung

# Stapel: *last in, first out* (LIFO)

Verwendung z.B. für **stapelorientierte Fadeneinplanung** [1], die Fäden nach LCFS (Abk. für (engl.) *last come, first served*) verarbeitet

```
void dos_push(chain_t *head, chain_t *item) {
    item->link = head->link;
    head->link = item;
}
```

```
chain_t *dos_pull(chain_t *head) {
    chain_t *node

    if ((node = head->link) != 0)
        head->link = node->link;

    return node;
}
```

*push* $\models$ Bereitstellung eines Fadens

*pull* $\models$ Auswahl eines Fadens

```
void dos_zero(chain_t *head) {
    head->link = 0;
}
```

## Listenelement

```
typedef struct chain chain_t;

struct chain {
    chain_t *link;
};
```

# Stapel: LCFS als Transaktion

Element durch ein **wettlauftolerantes Maschinenprogramm** am Kopf der Liste einfügen (*push*) und entnehmen (*pull*)

- mit sperrfreier (engl. *lock-free*) Fortschrittsgarantie [2]

```
void lf_push(chain_t *head, chain_t *item) {
    do item->link = head->link;                    /* is elected head */
    while (!CAS(&head->link, item->link, item));  /* try push item */
}
```

```
chain_t *lf_pull(chain_t *head) {
    chain_t *node;

    do if ((node = head->link) == 0) break;        /* access head */
    while (!CAS(&head->link, node, node->link));  /* try pull node */

    return node;
}
```

# Stapel: Plausibilitätskontrolle

- kritischer Datenbestand ist $link_{head}$, der Listenkopf

*push* # das durch *item* adressierte Element ist noch nicht in der Liste und es wird auch nicht mehrfach in diese Liste eingetragen
- der Listenkopf ist in $link_{item}$ als Kopie vermerkt
- neuer Listenkopf wäre *item*, dessen Bindung CAS versucht
- *do . . . while* terminiert, falls *item* als Kopf gebunden wurde

*pull*
- der Listenkopf ist in *node* als (lokale) Kopie vermerkt
- neuer Listenkopf wäre $node_{link}$, dessen Bindung CAS versucht
- *do . . . while* terminiert, falls $node_{link}$ als Kopf gebunden wurde

**Beachte**
- auch wenn mehrere Fäden auf denselben Kopfzeiger gleichzeitig zugreifen, wird CAS für nur einen Faden die Manipulation zulassen
- je nach Nutzung von *push* und *pull* droht das „ABA-Problem“

# Stapel: Plausibilitätskontrolle (Forts.)

## Datenstrukturentwicklung je nach Überlappungsfall

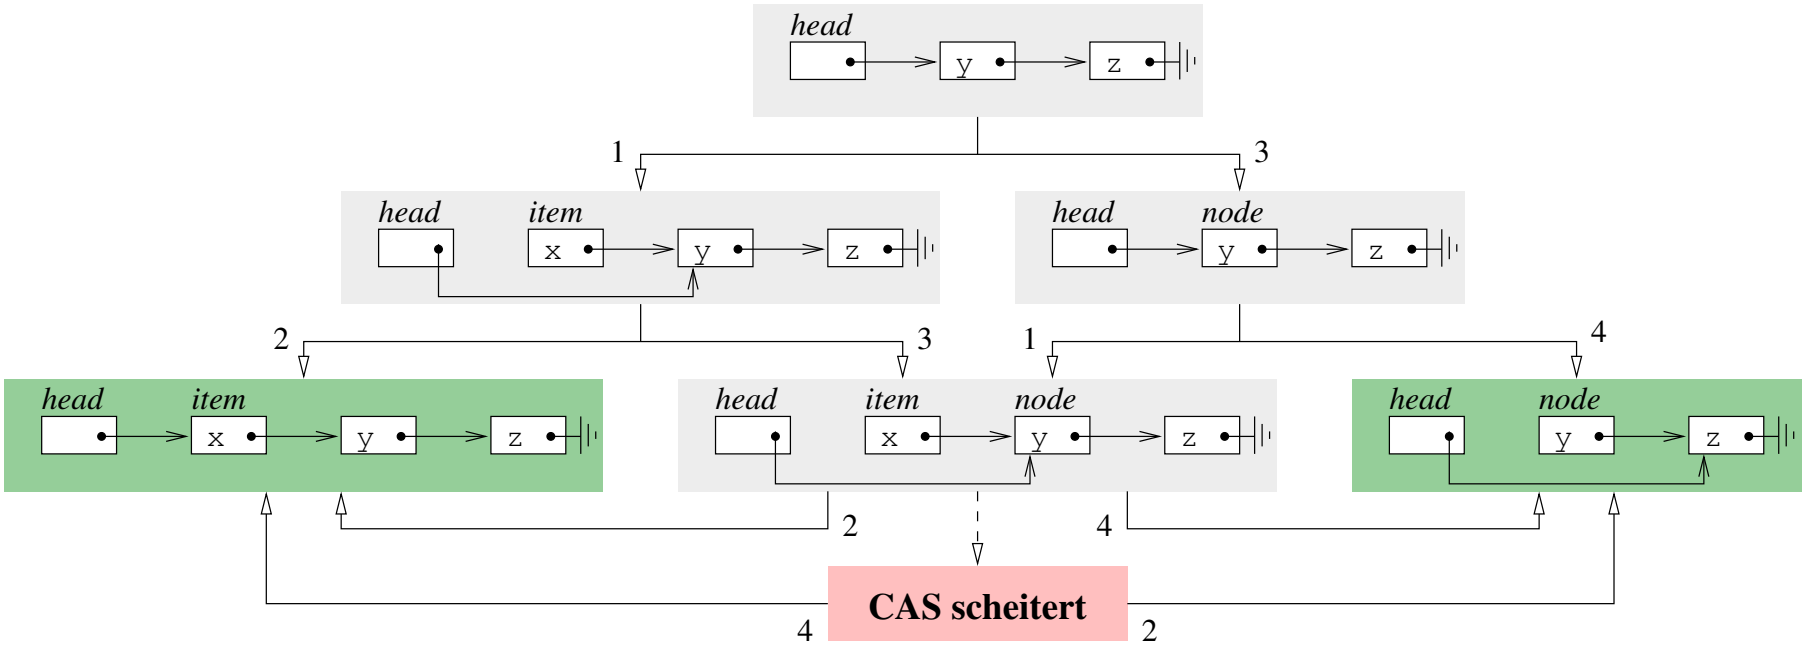


```
void lf_push(chain_t *head, chain_t *item) {
 1   do item->link = head->link;
 2   while (!CAS(&head->link, item->link, item));
}
```

```
chain_t *lf_pull(chain_t *head) {
      chain_t *node;
 3    do if ((node = head->link) == 0) break;
 4    while (!CAS(&head->link, node, node->link));
      return node;
}
```

# Problem ABA

Phänomen der nichtblockierenden Synchronisation auf Basis eines CAS, d.h., einer ELOP, die inhaltsbasiert arbeitet [3, S. 125][3]

- angenommen zwei Fäden, $F_1$ und $F_2$, stehen im Wettstreit um eine gemeinsame Variable $V$
  - $F_1$
    - liest den Wert $A$ von $V$, speichert diesen als Kopie, wird dann allerdings vor dem $\text{CAS}_V$ für unbestimmte Zeit verzögert
  - $F_2$
    - durchläuft dieselbe Sequenz, schafft jedoch mittels $\text{CAS}_V$ den Wert $B$ an $V$ zuzuweisen
    - anschließend wird (in einem weiteren Durchlauf dieser Sequenz) wieder der ursprüngliche Wert $A$ an $V$ zugewiesen
  - $F_1$
    - setzt seine Ausführung mit $\text{CAS}_V$ fort, erkennt, dass $V$ den Wert $A$ seiner Kopie speichert und überschreibt $V$
- im Ergebnis kann dieses Überlappungsmuster dazu führen, dass $F_1$ mittels $\text{CAS}_V$ einen falschen Wert nach $V$ transferiert

[3] Bei *Adressreservierung* wie z.B. mit `LL/SC` besteht dieses Problem nicht.

# Wartestapel mit Wettlaufsituation

Ausgangszustand der (LCFS) Liste: *head* ➪ *A* ➪ *B* ➪ *C*, *head* ist $\texttt{ref}_{CAS}$:

| | | | CAS-Parameter | | | |
|---|---|---|---|---|---|---|
| | $\mathbb{m}$ | Op. | `*ref` | `exp` | `val` | Liste |
| 1. | $F_1$ | *pull* | *A* | *A* | *B* | unverändert |
| 2. | $F_2$ | *pull* | *A* | *A* | *B* | `ref` ➪ *B* ➪ *C* |
| 3. | $F_2$ | *pull* | *B* | *B* | *C* | `ref` ➪ *C* |
| 4. | $F_2$ | *push* | *C* | *C* | *A* | `ref` ➪ *A* ➪ *C* |
| 5. | $F_1$ | *pull* | *A* | *A* | *B* | `ref` ➪ *B* ➪ ☹ |

*A* ➪ *C* verloren

1. $F_1$ wird im *pull* vor CAS unterbrochen, behält lokalen Zustand bei
2.–4. $F_2$ führt die Operationen komplett aus, aktualisiert die Liste
5. $F_1$ beendet *pull* mit dem zum Zeitpunkt 1. gültigen lokalen Zustand

# Kritische Variable mittels „Zeitstempel“ absichern

**Abhilfe** besteht darin, den umstrittenen Zeiger (nämlich *item* bzw. *node*) um einen problemspezifischen **Generationszähler** zu erweitern

Etikettieren

- Zeiger mit einem Anhänger (engl. *tag*) versehen
- Ausrichtung (engl. *alignment*) ausnutzen, z.B.:

$$\begin{aligned} sizeof(chain\_t) &\rightsquigarrow 4 = 2^2 \Rightarrow n = 2 \\ &\Rightarrow chain\_t* \text{ ist Vielfaches von 4} \\ &\Rightarrow chain\_t *_{Bits[0:1]} \text{ immer 0} \end{aligned}$$

- Platzhalter für $n$-Bit Marke/Zähler in jedem Zeiger

DCAS

- Abk. für (engl.) *double compare and swap*
- Marke/Zähler als elementaren Datentyp auslegen
  - *unsigned int* hat Wertebereich von z.B. $[0, 2^{32} - 1]$
- zwei Maschinenworte (Zeiger, Marke/Zähler) ändern

- *push* bzw. *pull* verändern sodann den Zeigerwert um eine Generation

# Generationszähler „*considered harmful*“?

Abhilfe (engl. *workaround*): „umgehen unlösbarer Fehler“ [4]

- die Effektivität des Lösungsansatzes steht und fällt mit dem für den Generationszähler definierten **endlichen Wertebereich**
  - dessen Auslegung letztlich vom jeweiligen Anwendungsfall abhängt
- **Überlappungsmuster** gleichzeitiger Prozesse haben Einfluss auf den für den Generationszähler zur Verfügung zu stellenden Wertebereich
  - bestimmt durch Zusammenspiel *und* Anzahl der wettstreitigen Fäden
  - ein Bit kann reichen, ebenso, wie ein *unsigned int* zu klein sein kann
- diese, dem jeweiligen Anwendungsfall zu entnehmenden Muster zu entdecken, ist zumeist schwer und nicht selten unmöglich

**Vorbeugung** (engl. *prevention*) muss zuerst kommen — sofern machbar:

- beliebige Überlappungsmuster konstruktiv (Entwurf) ausschließen
- oder auf Adressreservierungsverfahren der Hardware zurückgreifen
  - unterstützt nicht jede Hardware, ist nur typisch für RISC
  - z.B. ELOP-Paar *load linked*, *store conditional* (LL/SC) verwenden

# Abhilfe zum ABA-Problem: Etikettierung

## Abstrakter Datentyp *chain_p*: Spezialisierung von *chain_t**

```
typedef chain_t* chain_p;

extern chain_p  aba_wheel(chain_p);  /* rotate pointer tag bit(s) */
extern chain_t *aba_index(chain_p);  /* return pointer value */
```

## Etikett anheften

```
chain_p aba_wheel(chain_p item) {
    return (chain_p)((unsigned)item ^ 1);
}
```

## Etikett entfernen

```
chain_t *aba_index(chain_p item) {
    return (chain_t *)((unsigned)item & ~1);
}
```

## Verwendung

| | |
|---|---|
| *wheel* | • markieren<br>• Zeiger färben |
| *index* | • bereinigen<br>• Zeiger liefern |

# Lebensdauer des Generationszählers bzw. der Etiketten

Abhilfe gegen des Problem der Mehrdeutigkeit (hier: ABA) von Zeigern ist **nicht transparent** für die Programme, die die Zeiger verwenden

- dies trifft insbesondere auch zu auf die Etikettierung von Zeigern
  - damit bleiben lediglich *Einzelwort*-CAS weiterhin möglich
  - Transparenz durch Beibehaltung der Zeigergröße ist nicht das Ziel
- voll ausgeprägte Generationszähler sind offensichtlich intransparent
  - Zeiger und Generationszähler müssen eine Einheit bilden
  - beide zusammen verdoppeln die Zeigergröße $\rightsquigarrow$ *Doppelwort*-CAS

## Zeiger samt Generationszähler/Etikett sind Exemplar eines Typs

- problemspezifische Auslegung, je nach Wertebereich des Zählers

  Einzelwort *chain_t*$*$, falls einfache Etikettierung genügt

  Doppelwort *chain_t*$*$ und *unsigned int*, sonst
- Repräsentation als abstrakter Datentyp [5] $\Rightarrow$ Anpassung notwendig

# Stapel: Etikettierter Zeigertyp *chain_p*

```
void lf_push(chain_t *this, chain_p item) {
    chain_p turn = aba_wheel(item);    /* new pointer generation */

    do aba_index(item)->link = this->link;
    while (!CAS(&this->link, aba_index(item)->link, turn));
}

chain_p lf_pull(chain_t *this) {
    chain_p node;

    do if (aba_index((node = this->link)) == 0) break;
    while (!CAS(&this->link, node, aba_index(node)->link));

    return node;
}
```

Beachte $\hookrightarrow$ abstrakter Datentyp *chain_p* $\mapsto$ *chain_t* $*$

- Exemplare dieses Typs dürfen nur mittels *index* benutzt werden

# Wiederholungsversuche — Aktives Warten?

Scheitern der etwa durch CAS[4] abzuschließenden **Transaktion** zieht die Wiederholung des kompletten Vorbereitungsvorgangs nach sich

- je höher der Grad an Wettstreitigkeit unter gleichzeitigen Prozessen, umso höher die Wahrscheinlichkeit, dass CAS scheitert
- ein zur Umlaufsperre sehr ähnliches Problem ergibt sich, das jedoch durch **sensitive Techniken** gleicher Art lösbar ist (vgl. Kap. VI-1)
  - Häufigkeit von „*read-modify-write*“-Zyklen pro Durchlauf minimieren
  - prozessspezifisches Zurücktreten vom erneuten Transaktionsversuch
  - variable Wartezeiten, um Konflikte bei Wiederholungen zu vermeiden

## Unterschied zur Umlaufsperre

- gleichzeitige Prozesse müssen nicht untätig darauf warten, dass ein kritischer Abschnitt frei ist, d.h., das TAS gelingt
- sie verlassen die Schleife jedoch erst, wenn das CAS gelingt, kommen in der Schleife allerdings mit ihren (lokalen) Berechnungen voran

[4] Für LL/SC-artige Elementaroperationen gilt dies ebenfalls.

# Gliederung

# Resümee

- **Wettlauftoleranz** stellt sich als Merkmal kritischer Abschnitte dar
  - eine durch die Art des Schutzes bedingte nichtfunktionale Eigenschaft
  - gleichzeitige Prozesse nichtsequentieller Programme nie aussperren
- klassischer Ansatz dazu ist die **nichtblockierende Synchronisation**
  - Spezialbefehl: Einzelwort „*compare and swap*“ (CAS)
  - Zähler- und Listenmanipulation (Stapel, Schlange) als Fallstudien
  - Sonderfall: unterbrechungstransparente Synchronisation
    - kommt ohne Spezialbefehl des (realen) Prozessors aus
    - bedingt atomare Lese-/Schreiboperationen auf dem Arbeitsspeicher
- die Verfahren bringen **Eigenarten** mit sich und birgen Gefahren
  - bei CAS-basierten Algorithmen droht das ABA-Problem
    - Abhilfe schafft die Etikettierung der kritischen Variablen $\leadsto$ CAS
    - wo dies nicht möglich ist, können Generationszähler abhelfen $\leadsto$ DCAS
  - aktives Warten bei Fehlversuchen ähnlich zu Umlaufsperren behandeln
- grundsätzlich **anderes Denken** in der Algorithmenentwicklung nötig

# Literaturverzeichnis


[1] Baker, T. P.:
Stack-Based Scheduling of Realtime Processes.
In: *Real-Time Systems* 3 (1991), März, Nr. 1, S. 67–99

[2] Herlihy, M. :
Wait-Free Synchronization.
In: *ACM Transactions on Programming Languages and Systems* 11 (1991), Jan., Nr. 1, S. 124–149

[3] IBM Corporation (Hrsg.):
*IBM System/370 Principles of Operation*.
Fourth.
White Plains, NY, USA: IBM Corporation, Sept. 1 1975. –
GA22-7000-4, File No. S/370-01

[4] LEO GmbH:
*LEO Deutsch-Englisches Wörterbuch*.
Sauerlach, Deutschland : `http://dict.leo.org`,

[5] Liskov, B. J. H. ; Zilles, S. N.:
Programming with Abstract Data Types.
In: Leavenworth, B. (Hrsg.): *Proceedings of the ACM SIGPLAN Symposium on Very High Level Languages* Bd. 9.
New York, NY, USA : ACM, Apr. 1974 (ACM SIGPLAN Notices 4), S. 50–59

[6] Schön, F. ; Schröder-Preikschat, W. ; Spinczyk, O. ; Spinczyk, U. :
On Interrupt-Transparent Synchronization in an Embedded Object-Oriented Operating System.
In: Lee, I. (Hrsg.) ; Kaiser, J. (Hrsg.) ; Kikuno, T. (Hrsg.) ; Selic, B. (Hrsg.): *Proceedings of the 3rd IEEE International Symposium on Object-Oriented Real-Time Distributed Computing (ISORC '00)*.
Washington, DC, USA : IEEE Computer Society, 2000, S. 270–277

# Literaturverzeichnis (Forts.)

[7] Schröder-Preikschat, W. ; Kleinöder, J. :
*Systemprogrammierung*.
http://www4.informatik.uni-erlangen.de/Lehre/WS08/V_SP, 2008 *ff.*

[8] Tanenbaum, A. S.:
Multilevel Machines.
In: *Structured Computer Organization*.
Prentice-Hall, Inc., 1979. –
ISBN 0–130–95990–1, Kapitel 7, S. 344–386

# Gliederung

# Schlange: Szenario 1, *aback* || *aback*

```
void lf_aback(queue_t *this, chain_t *item) {
    chain_t *last;

    item->link = 0;

    do last = this->tail;
    while (!CAS(&this->tail, last, &item->link));

    last->link = item;
}
```

## Plausibilitätskontrolle ↪ kritisch ist *tail*, der Listenfuß

- die Kopie des aktuellen Wertes von *tail* wird in *last* vermerkt
- neuer Wert von *tail* ergibt sich aus $ref(link_{item})$
- CAS gelingt $\iff$ *tail* hält den alten Wert $\Rightarrow tail = ref(link_{item})$
- *do . . . while* terminiert $\iff$ CAS gelingt

# Schlange: Szenario 2, *fetch* || *fetch*

```
chain_t *lf_fetch(queue_t *this) {
    chain_t *node;

    do if ((node = this->head.link) == 0) return 0;
    while (!CAS(&this->head.link, node, node->link));

    if (node->link == 0)
        this->tail = &this->head;

    return node;
}
```

## Plausibilitätskontrolle $\hookrightarrow$ kritisch ist $link_{head}$, der Listenkopf

- analog zu *aback*, jedoch Sonderbehandlung wenn gilt:
  - $link_{head} = node \wedge tail = ref(link_{node}) \Rightarrow$ einziges Element
- im Falle des einzigen Elements gilt nach weiteren Verlauf:
  - $link_{head} = link_{node} = 0 \Rightarrow tail = ref(link_{head})$

# Schlange: Szenario 3, $fetch \parallel (fetch, aback)$

```
chain_t *lf_fetch(queue_t *this) {
    chain_t *node;

    do if ((node = this->head.link) == 0) return 0;
    while (!CAS(&this->head.link, node, node->link));

    if (node->link == 0)
        CAS(&this->tail, &node->link, &this->head);

    return node;
}
```

Beachte $\hookrightarrow$ hier gilt: $link_{node} = 0 \Rightarrow link_{head} = 0$

- überlappendes *aback* hat ggf. *item* angehängt: $tail = ref(link_{item})$
- dann müsste jedoch auch gelten: $link_{head} = item$

$\Rightarrow$ Widerspruch: *fetch* toleriert überlappendes *aback* nicht

# Schlange: Rekapitulation der Szenarien 1 – 3

| | |
|---|---|
| *aback*‖*aback* | • Integrität von *tail* ist sichergestellt |
| *fetch*‖*fetch* | • Integrität von $link_{head}$ ist sichergestellt |
| *fetch*‖*aback* | • Integrität von $link_{head}$ bzw. *tail* ist sichergestellt |
| | • Integrität von beiden zusammen ist nicht sichergestellt |
| *aback*‖*fetch* | • Integrität $\sim$ *fetch*‖*aback* $\Rightarrow$ nicht sichergestellt |

**Neuralgischer Punkt $\hookrightarrow$ Kopfelement wird zum Verkettungsglied**

| | |
|---|---|
| *aback* | • hängt *item* ggf. an ein Kopfelement (*node* = *last*) an, das ggf. schon nicht mehr auf der Liste steht<br>• muss die Aktualisierung von $link_{last}$ in Abhängigkeit vom Ausführungsverlauf von *fetch* vornehmen |
| *fetch* | • setzt *tail* ggf. auf *ref*($link_{head}$), obwohl zwischenzeitlich ggf. ein weiteres (zweites) Element an die Liste angehängt wurde<br>• muss das Zurücksetzen des Fußzeigers (*tail*) in Abhängigkeit vom Ausführungsverlauf von *aback* vornehmen |

# Schlange: *aback* und *fetch* müssen einander helfen

Idee ist es, den Verkettungszeiger (*link*) eines Listenelements auch zur „Signalisierung“ zwischen *aback* und *fetch* zu nutzen

- sei *that* Zeiger (*chain_t*$*$) auf ein Listenelement, dann soll gelten:

$$link_{that} = \begin{cases} that, & that \text{ ist gültiges Verkettungsglied} \\ 0, & \text{Verkettungsglied } that \text{ wurde entfernt} \\ \text{sonst}, & \text{Listenelement } that \text{ mit Nachfolger} \end{cases}$$

- für die beiden Funktionen lässt sich dies dann wie folgt ausnutzen:

  *aback*
  - hängt das neue Element nicht an $\iff link_{that} \neq that$
  - beachte: $that \mapsto last \Rightarrow last$ ist Verkettungsglied

  *fetch*
  - nullt $link_{that} \iff link_{that} = that$, und
  - versucht tail zurückzusetzen $\iff link_{that} = 0$
  - beachte: $that \mapsto node \Rightarrow node$ ist Verkettungsglied

- beachte: $last = node$, beide Funkt. sehen dasselbe Verkettungsglied

# Schlange: Korrektur des Kopfzeigers

Aufmerksamkeit ist noch dem Kopfzeiger ($link_{head}$) zu geben, dessen Integrität im Konfliktfall ($last = node$) wieder herzustellen ist

*fetch*‖*aback*

- *fetch* stellt fest, dass *node* das einzige Element war
- dann gilt $link_{head} = 0 \wedge link_{node} = node$
- zuvor jedoch hängt *aback* noch ein neues Element an
- dann gilt $link_{node} \neq node \Rightarrow$ wird nicht genullt
- $link_{node}$ zeigt auf das soeben angehängte Element

$\Rightarrow$ *fetch*: $link_{head}$ ist auf $link_{node}$ zu korrigieren

*aback*‖*fetch*

- *last* zeigt auf das Verkettungsglied, *tail* ist umgesetzt
- *aback* stellt fest, dass *last* soeben entfernt wurde
- dann gilt $link_{last} = 0 \Rightarrow item$ hängt nicht an
- *fetch* setzt *tail* in der Situation jedoch nicht zurück
- es gilt: $tail = ref(link_{item}) \wedge link_{head} = 0$

$\Rightarrow$ *aback*: $link_{head}$ ist auf *item* zu korrigieren

# Schlange: Wettlauftolerantes *aback* (Forts.)

```
void lf_aback(queue_t *this, chain_t *item) {
    chain_t *last, *self;

    item->link = item;    /* item becomes new tail resp. next last */

    do self = (last = this->tail)->link;  /* draw copies as needed */
    while (!CAS(&this->tail, last, &item->link));

    if (!CAS(&last->link, self, item))    /* last removed by fetch */
        this->head.link = item;           /* item becomes new head */
}
```

## Beachte ↪ Problem ABA: *item*

- zwischenzeitiges wieder einfügen von Elementen, die zuvor in der Schlange standen, kann CAS in *fetch* gelingen lassen
- ggf. muss *aback* weitere Hilfestellung leisten, um *fetch* von diesem Problem zu befreien

# Schlange: Wettlauftolerantes *fetch* (Forts.)

```
chain_t *lf_fetch(queue_t *this) {
    chain_t *node, *next;

    do if ((node = this->head.link) == 0) return 0;
    while (!CAS(&this->head.link, node,
                ((next = node->link) == node ? 0 : next)));

    if (next == node) {    /* last element just removed, be careful */
        if (!CAS(&node->link, next, 0)) this->head.link = node->link;
        else CAS(&this->tail, &node->link, &this->head);
    }

    return node;
}
```

**Beachte $\hookrightarrow$ Problem ABA: $next = link_{node}$ (gepaart)**

- zwischenzeitiges wieder einfügen von *node* kann CAS gelingen lassen, wobei $link_{node}$ aber mittlerweile einen anderen Wert haben könnte

# Schlange: Plausibilitätskontrolle

## Neuralgische Punkte

```
void lf_aback(queue_t *this, chain_t *item) {
    chain_t *last, *self;

    item->link = item;

t   do self = (last = this->tail)->link;
t   while (!CAS(&this->tail, last, &item->link));

1   if (!CAS(&last->link, self, item))
2       this->head.link = item;
}

chain_t *lf_fetch(queue_t *this) {
    chain_t *node, *next;

h   do if ((node = this->head.link) == 0) return 0;
h   while (!CAS(&this->head.link, node,
h            ((next = node->link) == node ? 0 : next)));

3   if (next == node) {
4       if (!CAS(&node->link, next, 0))
5           this->head.link = node->link;
6       else CAS(&this->tail, &node->link, &this->head);
    }

    return node;
}
```

- t
  - *tail* weitersetzen ✓
- h
  - *head* weitersetzen ✓
- 1
  - Verkettungsglied gültig?
  - ja, *item* angehängt
  - *fetch* wurde signalisiert
- 2
  - nein, *fetch* kam vorbei
  - *head* korrigieren
- 3
  - letztes Element raus?
- 4
  - wirklich keins mehr da?
  - ja, *aback* signalisiert: 6
- 5
  - nein, *aback* kam vorbei
  - *head* korrigieren
- 6
  - *tail* ggf. zurücksetzen

# Schlange: Plausibilitätskontrolle (Forts.)

## Datenstrukturentwicklung je nach Überlappungsfall