Betriebssystemtechnik

Adressräume: Trennung, Zugriff, Schutz

X. Mitbenutzung

Wolfgang Schröder-Preikschat

27. Juni 2016

Gliederung

Informationsaustausch und gemeinsame Benutzung

Konsequenz der isolierten Adressräume sowie der physikalischen und logischen Verteilung von Funktionen

- die Prozesse kommunizieren über einen Datenverbund (*data sharing*)
  - alternativ oder ergänzend zum Nachrichtenversenden (*message passing*)
  - geeignet für den Informationsaustausch in homogenen Rechensystemen
    - als explizite Maßnahme in Systemen mit gemeinsamem Speicher *oder*
    - als implizite Optimierungsoption in Systemen mit verteiltem Speicher
- weitere Ergänzung ist ein Textverbund (*code sharing*) von Routinen
  - bspw. um eine Gemeinschaftsbibliothek (*shared library*) zu realisieren
  - aber auch als Optimierungsoption für Methoden der Prozesserzeugung
    - bei Prozessgabelung, ein für Elter- & Kindprozess gemeinsames Textsegment
    - ähnlich bei der Prozessüberlagerung mit einem Programm (insb. SASOS)

Thema sind grundlegende Konzepte zur kontrollierten Benutzung gemeinsamer Speicherbereiche durch Prozesse

- *shared memory segment*, *copy on write*, *copy on reference*

Gliederung

Explizite Text- und Datenverbünde

Mitbenutzung (*sharing*) von Text-/Datenbereichen durch Prozesse, die in voneinander getrennten Adressräumen residieren

- meint die $N:1$-Abbildung auf denselben realen Adressraumbereich
  - N Bereiche ($\Im$) in M logischen Adressräumen, $N \geq M$

    $N = M \Rightarrow$ einfache
    $N > M \Rightarrow$ mehrfache
    } Mitbenutzung pro logischen Adressraum
  - werden abgebildet auf 1 Bereich ($\Re$) des realen Adressraums
- wobei $\Im \subseteq \Re$, d.h., die Bereiche müssen nicht deckungsgleich sein
  - $\Im$ kann kleiner, sollte aber nicht größer als $\Re$ sein
  - $\Im$ verschiedener logischer Adressräume:
    - i müssen denselben logischen Adressbereich abdecken *oder*
    - ii können verschiedenen Ausschnitten dieser Adressbereiche entsprechen
  - verschiedene $\Im$ desselben logischen Adressraums können überlappen
- Ausrichtung (*alignment*) von $\Im$ und $\Re$ gemäß Granulatgröße
  - Segmentierung $\mapsto$ Byte bzw. Block[1], Seitennummerierung $\mapsto$ Seite

[1] Vielfaches (Zweierpotenz) von Bytes, z.B. 16 Bytes für x86.

Positionsabhängige Mitbenutzung

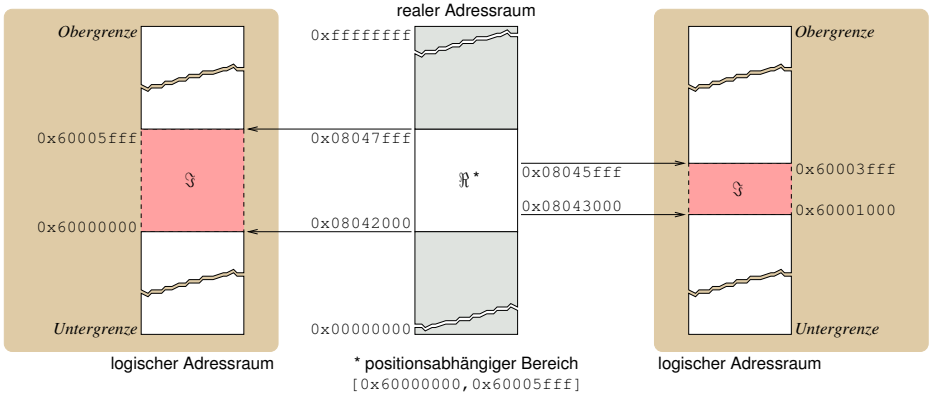

- totale Einblendung eines Bereichs $\Re$ des realen Adressraums (li.)
  - Verwendung von absoluten Adressen bedingen Positionsabhängigkeit
    - Zeiger/Referenzen (Daten) und Sprungziele (Text)
  - Konsequenz entsprechend (vor-) gebundener Programmtexte
- partielle Einblendung desselben Bereichs $\Re$ ist auch möglich (re.)

Positionsunabhängige Mitbenutzung I

einfach

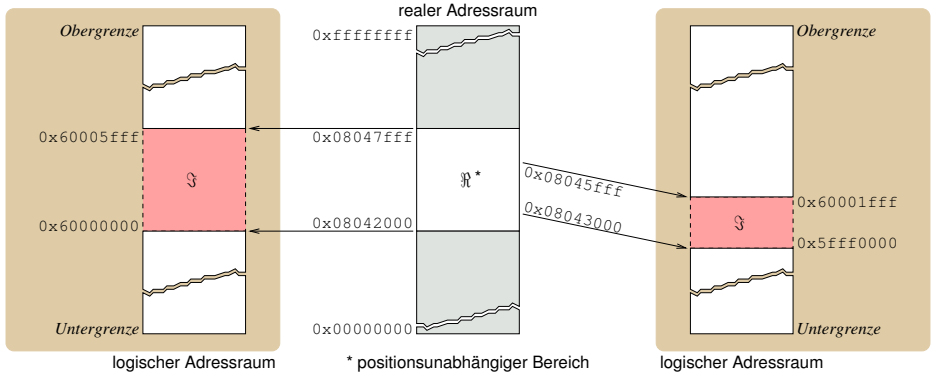

- totale/partielle Einblendung des Bereichs $\Re$ des realen Adressraums
  - Verzicht auf absolute Adressen in $\Re$ bedingt Positionsunabhängigkeit
    - zum Zeitpunkt der Einblendung von $\Re$ in $\Im \rightsquigarrow$ Migrationsintransparenz
  - die Textbereiche in $\Re$ enthalten ausschließlich relative Adressen
- positionsunabhängiger Kode (*position-independent code*, PIC; [2])

Positionsunabhängige Mitbenutzung II

mehrfach

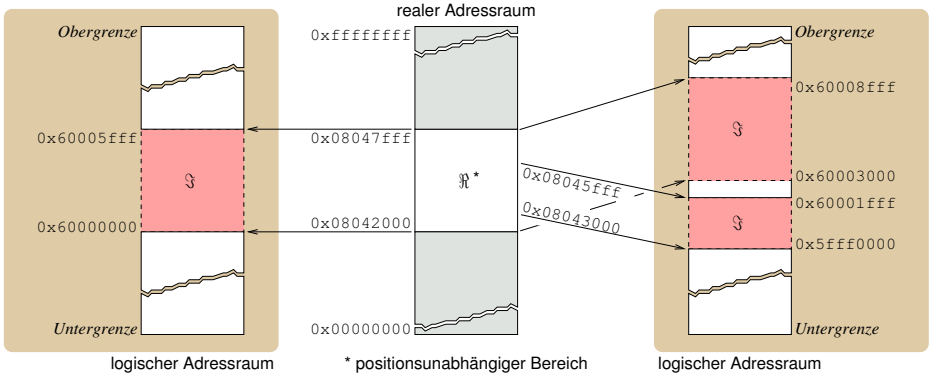

- mehrfache (total/partiell) Einblendung des Bereichs $\Re$ (re.)
  - $\Re$ liegt an verschiedenen Bereichen $\Im$ im selben logischen Adressraum
    - z.B. verschiedene Datenstrukturen, die nacheinander referenziert werden
  - zum Datenzugriff werden auf $\Re$ verschieden breite Fenster gelegt
- die Prozesse entscheiden selbst, wo der Bereich $\Re$ eingeblendet wird

Einflussfaktoren

Mitbenutzung von Adressraumabschnitten bedingt einen passenden Zuschnitt von Text- und Datenbereichen

- Ausrichtung von $\mathfrak{I}$ und $\mathfrak{R}$ gemäß Granulatgröße (vgl. S. 5)
  - die Bereichsadresse ist byte-, block- oder seitenausgerichtet *und*
  - die Bereichslänge ist Vielfaches der Länge einer Ausrichtungseinheit
  - ↪ Adressumsetzungseinheit (*memory management unit*, MMU)
- Systemeigenschaft der Text- bzw. Datenverbünde
  - statisch
    - Symbole werden *vor* Laufzeit an Adressen gebunden
    - zur Programmlaufzeit ist die Bindung fest, unveränderlich
  - dynamisch
    - Symbole werden *zur* Laufzeit an Adressen gebunden
    - *nach* der ersten Laufzeitreferenz ist die Bindung i. A. fest
- Positionierung der Objekt-/Lademodule als Programmeigenschaft
  - Positionsunabhängigkeit innerhalb des logischen Adressraums *oder*
  - feste Zuweisung von Adressbereichen, die das Betriebssystem vorgibt

↪ Betriebssystembelange, die auch in Binder und Lader verankert sind

Gliederung

Implizite Text- und Datenverbünde

Mitbenutzung von Text-/Datenbereichen durch Prozesse während der Durchführung von adressraumbezogenen Systemfunktionen

- automatisch, funktional transparent für die involvierten Prozesse
  - bspw. zum Duplizieren von Prozessinkarnationen (`fork`)
  - Initialisieren („nullen“) neu eingerichteter Adressräume oder
  - Zwischenpuffern oder Übertragen von Nachrichten/-bereichen
- wobei der gleichgestellte Prozess (*peer*) implizites Wissen besitzt
  - und zwar über die Existenz abgebildeter Objekte in seinem Adressraum
  - die ihm nur logisch, nicht aber real als „Eigentum“ überlassen wurden
- Übernahme: kopieren beim Schreiben (COW, *copy on write*, [1, 4, 3])
  - Schreibrechte wurden quellseitig entzogen und zielseitig nicht erteilt
  - Momentaufnahme (*snapshot*) des Zustands zum Schreibzeitpunkt
  - die Prozesse besitzen danach Schreibrechte auf Original und Kopie
- der schreibende Prozess legt eine eigene Version des Objektes an
  - gebunden an der originalen Adresse in seinem logischen Adressraum

Prozessinkarnation I

Szenario & Hauptspeicherabbildung

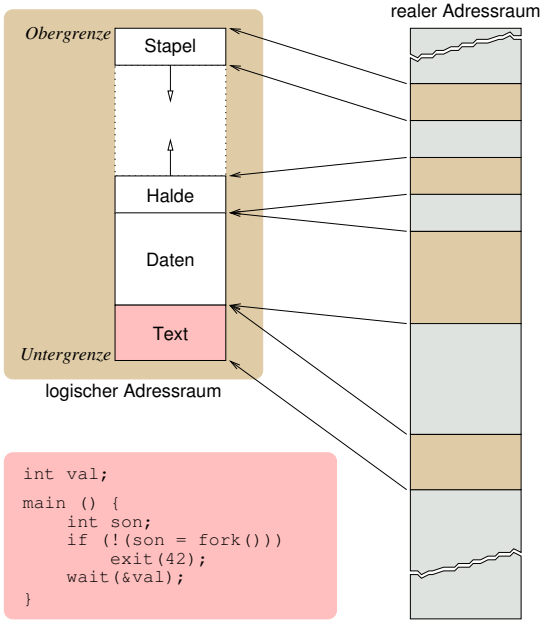

- Klonen (`fork`)
  - hier die Erzeugung eines baulich identischen Individuums von einem Prozess
  - aus einem Elterprozess der Parentalgeneration ein Kindprozess der Filialgeneration erzeugen
- minimalinvasiv
  - hier mit kleinstmöglichem Kopieraufwand in der Erzeugung eingreifend
- aber nur bedingt aufwandsarm...

Prozessinkarnation II

Kindprozessinkarnation

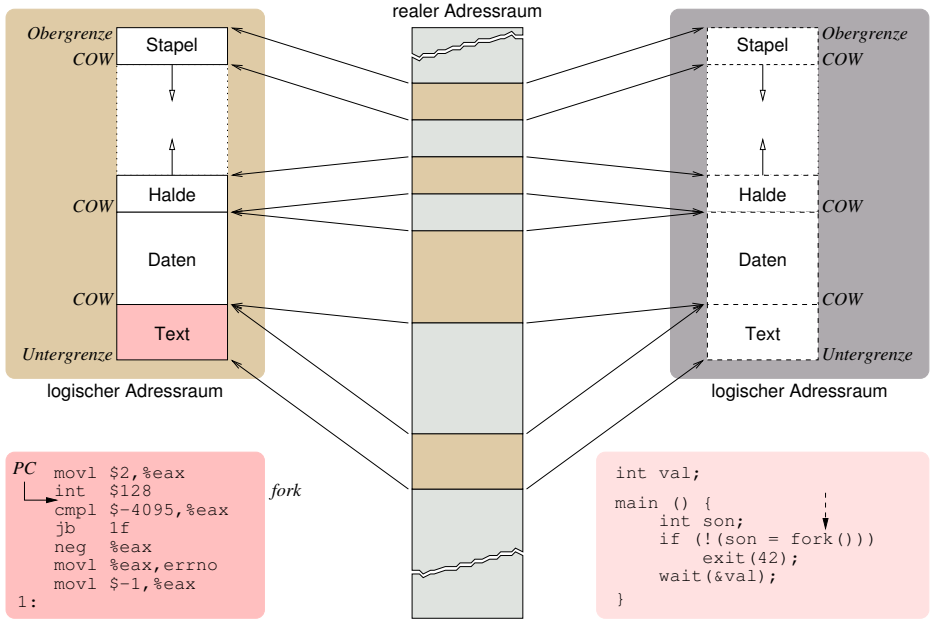

Prozessinkarnation III

Kindhalde & Kindstapel kopiert

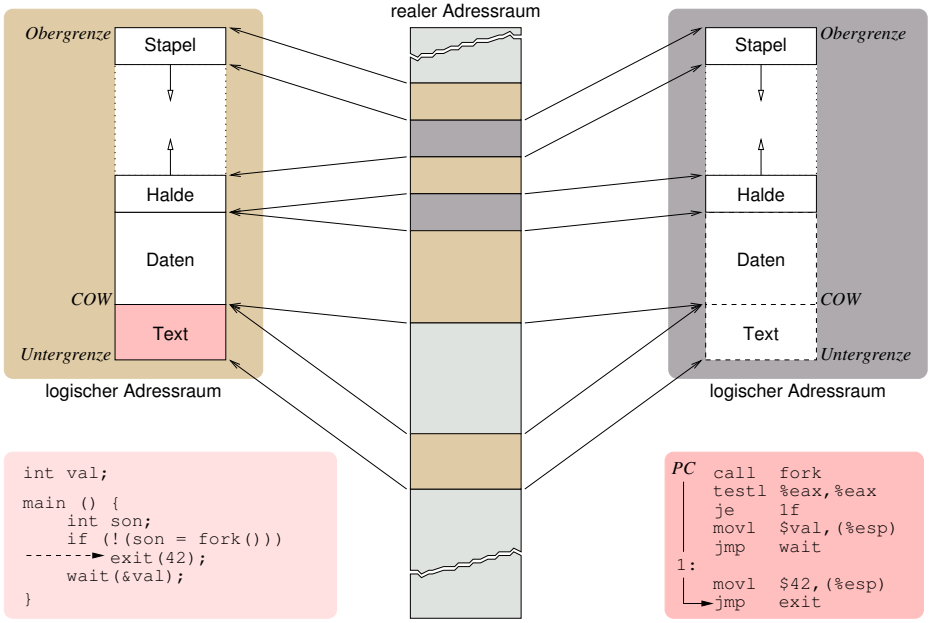

Prozessinkarnation IV

Elterdaten kopiert

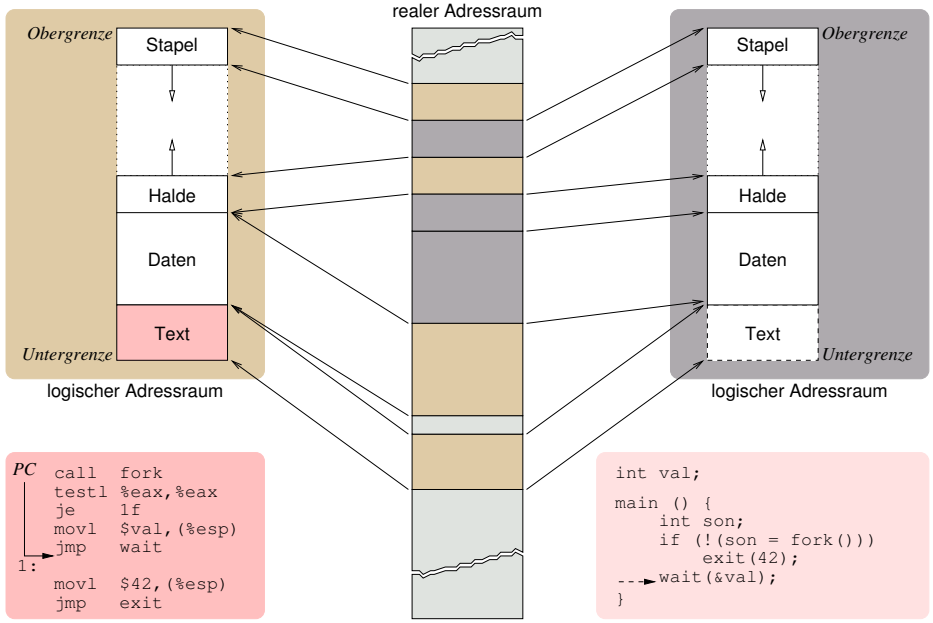

Implizite Datenverbünde

Mitbenutzung von Datenbereichen durch Prozesse nach der logischen Bereitstellung im Rahmen von Weitergabeoperationen

- automatisch, funktional transparent für die involvierten Prozesse
  - bspw. zum Migrieren von Prozessinkarnationen auf ferne Rechner oder
  - Transferieren von Nachrichten bei der Interprozesskommunikation (IPC)
- Empfang: kopieren beim Referenzieren (COR, *copy on reference*, [5])
  - erstellen einer Objektabbildung in den Adressraum des Zugreifers
  - zielseitig mit Lese-, Schreib- oder Ausführungsrechten versehen
  - quellseitig die Schreibrechte entzogen, d.h., auf COW umgestellt
- Kopplung mit IPC zur empfangsseitigen Einblendung der Nachricht
  - *reliable-blocking send*: Annahme im BS, Sender gibt Verortung vor
  - *synchronization send*: `receive`, Empfänger gibt Verortung ggf. vor
  - *remote-invocation send*: `receive`, Empfänger gibt Verortung vor, aber auch explizit, zw. `receive` und `reply`
- bedarfsorienterter (*on-demand*) Datentransfer, auch netzwerkweit

IPC: Deskriptorversand

synchronization send

```
1  site message::send (site afar) {
2    act *peer = stage::being(afar);     // identify receiver
3    if (peer) {                         // is valid
4      act *self = stage::being();       // identify sender
5      peer->serve(self->stock(*this));  // deliver message
6      self->block(&self->depot());      // await receive
7      return peer->label();             // send done
8    }
9    return -1;                          // send failed
10 }
```

- direkte Kommunikation des Nachrichtendeskriptors durch den Sender
  - einlagern (`stock`) und zustellen (`serve`) des Deskriptors
  - Entleerung des Lagers durch den Empfänger abwarten (`block`)
- indirekte Kommunikation der Nachricht durch den Empfänger
  - erst bei Bedarf, durch COW (Sender) oder COR (Empfänger) übertragen
- Sender wird beim Empfang des Nachrichtendeskriptors deblockiert

IPC: Deskriptorversand/-anwendung I

reliable-blocking send

```
1  int message::emit (site afar) {
2    act *peer = stage::being(afar);     // identify receiver
3    if (peer) {                         // is valid
4      act *self = stage::being();       // identify sender
5      area* area = peer->allot(*this, zone::COR, self);
6      if (area)                         // link COR/COW map
7        self->alter(*this, zone::COW, peer);
8      self->exert(self->depot());       // acquire buffer
9      peer->serve(self->stock(*this));  // deliver message
10     return self->depot().range();     // send done
11   }
12   return -1;                          // send failed
13 }
```

- wie send, jedoch speicherabbildend und bedingt synchronisiert
  - Sender reserviert „Platzhalterbereich“ im Adressraum des Empfängers
    - Zieladressbereich zuweisen (`allot`), Quelladressbereich abändern (`alter`)
  - Sendepuffer gebrauchen (`exert`): blockieren, falls dieser noch belegt ist

IPC: Deskriptorversand/-anwendung II

copy on reference

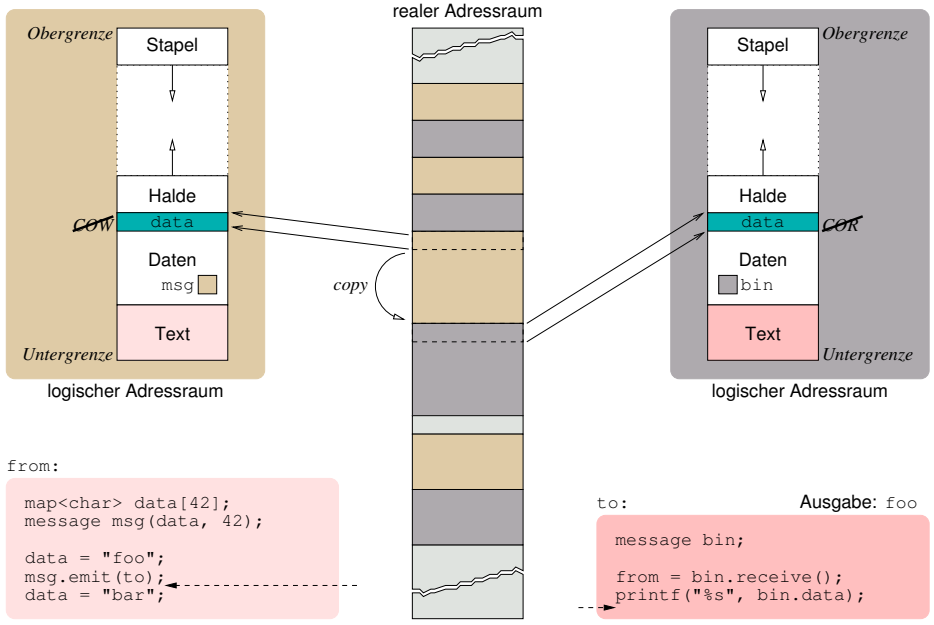

IPC: Deskriptorempfang/-anwendung I

synchronization send

```
1  site message::receive () {
2    act *self = stage::being();         // identify receiver
3    lump* item = self->glean();         // accept message
4    if (item) {                         // message received
5      act *peer = stage::being(item->label());
6      if (peer) {                       // valid sender
7        if (size == 0) *(section*)this = *item;
8        area* area = self->allot(*this, zone::COR, peer);
9        if (area) {                     // message mapped
10         peer->alter(*item, zone::COW, self);
11         peer->quote(peer->depot());   // release buffer
12         return item->label();         // receive done
13       }
14       self->retry(*item);             // keep message
15     }
16   }
17   return 0;                           // receive failed
18 }
```

IPC: Deskriptorempfang/-anwendung II

copy on write

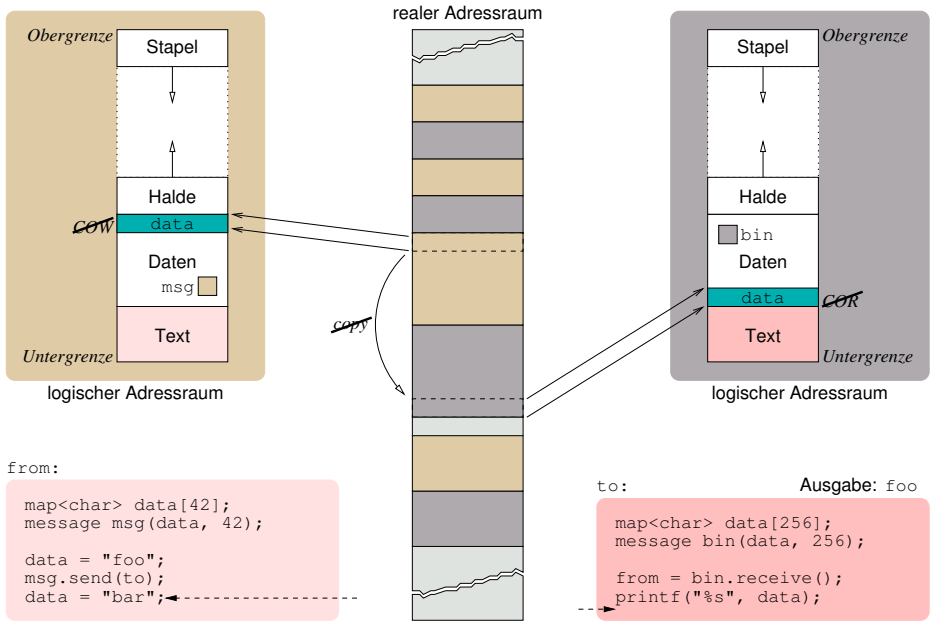

IPC: Deskriptoranwendung I

remote-invocation send

Muster der Empfangs-, Verarbeitungs- und Antwortschleife für eine Diensteinheit (*server*) insb. mikrokernbasierter Betriebssysteme

```
1  void serve () {
2    request msg;
3    for (;;) {
4      site peer = msg.receive(); // blocking acceptance
5      if (peer) {
6        zone area(peer, msg.sort.part[0]);
7        msg.sort.part[0].size = area.apply();
8        msg.reply(peer);          // non-blocking response
9      }
10   }
11 }
```

- Empfang (`receive`) des Auftrags als Nachrichtendeskriptor
- Nachrichtenverarbeitung durch Anwendung (`apply`) des Deskriptors
- Rückantwort (`reply`) und Übermittlung einer Ergebnisnachricht

IPC: Deskriptoranwendung II

```
1  int zone::apply () {
2    act *peer = stage::being(label()); // identify callee
3    if (peer) {                        // is valid
4      act *self = stage::being();      // identify caller
5      area* area = self->allot(*this, zone::COR, peer);
6      if (area) {                      // link COR/COW map
7        peer->alter(*this, zone::COW, self);
8        return range();                // mapping done
9      }
10   }
11   return -1;                         // mapping failed
12 }
```

- analog zu `emit` oder `receive`, jedoch explizit im Anwendungsprozess
  - Reservierung eines „Platzhalterbereichs“ im Adressraum des Aufrufers
    - Zieladressbereich zuweisen (`allot`), Quelladressbereich abändern (`alter`)
  - zuvor das Wesen (`being`, Zeile 2) des Quelladressbereichs validieren
- der Bereich (`zone`) im Quelladressraum wurde geeignet kommuniziert

IPC: Deskriptoranwendung III

copy on reference

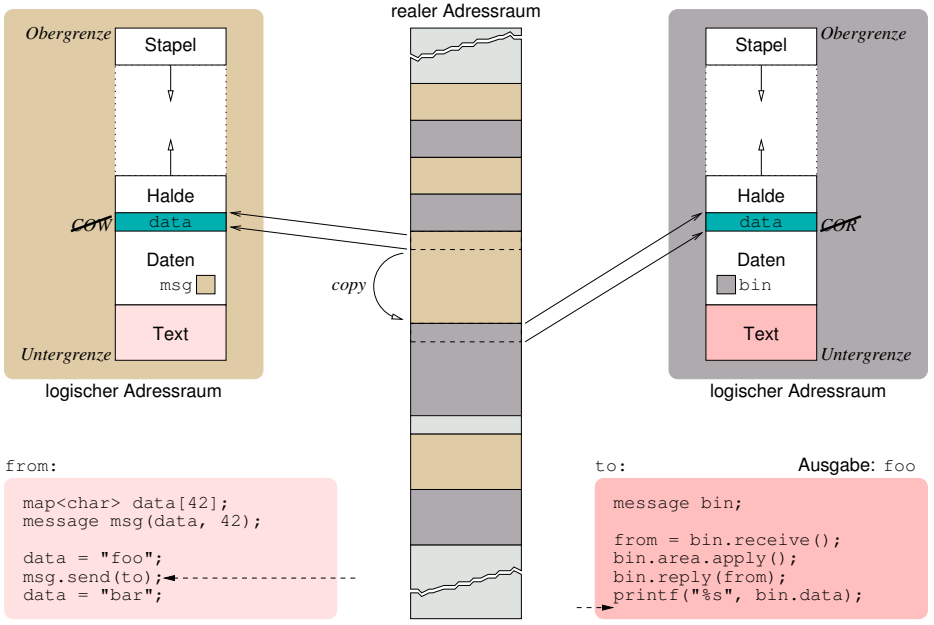

Gliederung

Resümee

- Informationsaustausch und gemeinsame Benutzung
  - Konsequenz der isolierten Adressräume, logische Funktionsverteiltung
  - Interprozesskommunikation über einen Datenverbund (*data sharing*)
  - Gemeinschaftsbibliothek (*shared library*) als Textverbund (*code sharing*)
- Gemeinschaftssegment (*shared memory segment*)
  - explizite Text- und Datenverbünde ursprünglich getrennter Adressräume
    - positionsabhängige/-unabhängige Mitbenutzung
  - Mitbenutzung heißt auch passender Zuschnitt der Text-/Datenbereiche
    - Ausrichtung gemäß Granulatgröße: byte-, block-, seitenausgerichtet
    - Bereichslänge ist Vielfaches der Länge einer Ausrichtungseinheit
  - Text-/Datenverbünde haben statische/dynamische Systemeigenschaften
    - ein Frage der Bindezeit von Symbol und Adresse: vor/zur Laufzeit
- Übertragungstechniken: *copy on write*, *copy on reference*
  - Prozessadressraumerzeugung (`fork`) als ein Beispiel für COW
  - Interprozesskommunikation (IPC) als ein Fall für COW und COR

↪ insb. auch netzwerkweit, d.h., Rechnergrenzen überschreitend

Literaturverzeichnis I

[1] Ball, J. E. ; Feldman, J. ; Low, J. R. ; Rashid, R. ; Rovner, P. :
RIG, Rochester's Intelligent Gateway: System Overview.
In: *IEEE Transactions on Software Engineering* SE-2 (1976), Nov., Nr. 4, S. 321–328

[2] IBM Corporation:
IBM Time-Sharing System/360: Concepts and Facilities.
White Plains, NY, USA, 1967 (Z20-1788-0). –
Sales and Systems Guide

[3] Rashid, R. F.:
From RIG to Accent to Mach: The Evolution of a Network Operating System.
In: Winkler, S. (Hrsg.) ; Stone, H. S. (Hrsg.): *Proceedings of the 1986 ACM Fall Joint Computer Conference*, IEEE Computer Society Press, 1986. –
ISBN 0–8186–4743–4, S. 1128–1137

[4] Rashid, R. F. ; Robertson, G. G.:
Accent: A Communication Oriented Network Operating System Kernel.
In: Howard, J. (Hrsg.) ; Reed, D. P. (Hrsg.): *Proceedings of the Eighth ACM Symposium on Operating System Principles (SOSP '81)*, ACM Press, 1981. –
ISBN 0–89791–062–1, S. 64–75

Literaturverzeichnis II

[5] Zayas, E. R.:
Attaching the Process Migration Bottleneck.
In: Bélády, L. (Hrsg.): *Proceedings of the Eleventh ACM Symposium on Operating System Principles (SOSP '87)*, ACM Press, 1987. –
ISBN 0–89791–242–X, S. 13–24

Ausführungsplattform

Bühne (*stage*)

```
class stage {
    static act* life;        // currently running thread
    static unsigned mask;    // limit of following array
    static act list[];       // thread descriptor table
public:
    static act* being()      { return life; }
    static act* being(site slot) {
        act* item = &list[slot & mask];
        return item->label() == slot ? item : 0;
    }
};
```

- einelementige Menge (*singleton*) zentraler Datenstrukturen
  - *life*
    - wird vom Umschalter (*dispatcher*) aktualisiert
  - *list*
    - Prozesstabelle dynamischer/konfigurierbarer Größe
    - wird zur Systeminitialisierungs oder -laufzeit dimensioniert
  - *mask*
    - zur Maskierung von Prozessnamen bei der Tabellenindizierung
- Abstraktion für prozessor(kern)lokale Systemdaten und -operationen

Prozesskontrollblock

Handlung (*act*)

```
class act : public lockbox, public scope {
    int trim;            // mood, scheduling state
    void* wait;          // blocked-on event
public:
    enum mood {READY, RUNNING, BLOCKED};

    void block ();       // release processor
    void ready ();       // compete for processor

    void apply (void*); // set blocked-on event

    void block (void*); // fall asleep until given event
    void rouse (void*); // awake, if blocked on event

    lump* glean ();      // await inbox message
    int serve (lump&);   // awake inbox-blocked act
    int exert (lump&);   // await outbox message
    int quote (lump&);   // awake outbox-blocked act
};
```

Prozesssteuerung für IPC

```
inline void act::apply (void* link) { wait = link; }

inline void act::block (void* link) {
    apply(link);             // set blocked-on event and
    block();                 // release processor
}

inline void act::rouse (void* link) {
    if (wait == link) {      // the right wakeup event?
        wait = 0;            // yes, cancel and
        ready();             // compete for processor
    }
}

inline lump* act::glean () {
    lump* item = clear();    // remove next message descriptor from inbox
    if (!item) {             // none available, prepare to block
        block(&booth());     // await specified event
        if (!wait)           // no exceptional wakeup
            item = clear(); // there must be a message descriptor
    }
    return item;
}

inline int act::exert (lump& item) {
    if (item.range() != 0)  // outbox available, i.e., not in use?
        block(&item);        // no, await release event (quote)
}

inline int act::quote (lump& item) { range(0); rouse(&item); }
inline int act::serve (lump& item) { aback(item); rouse(&booth()); }
```

Nachrichten und -deskriptoren

- Postfach (*lockbox*) mit Ein- und Ausgang

```
class lockbox : public lump {
    queue inbox;
public:
    lump&  depot () { return *this; }
    queue& booth () { return inbox; }
    lump*  clear () { return (lump*)inbox.clear(); }
    void   aback (lump& item) { inbox.aback(item); }
    void   retry (lump& item) { aback(item); }
};
```

- im Postfach lagerungsfähige Posten (*lump*)

```
class lump : public chain, public zone {
public:
    lump& stock (const section&);     // keep section
    lump& operator= (const section&); // stock it
};
```

- Warteschlange (*queue*) und Verkettung (*chain*) ⇝ VL 9

Adressbereich eines Prozesses

- standortbezogener Bereich (*zone*) im Adressraum

```
1  class zone : public area {
2      site name;              // thread identification
3  public:
4      enum mode {COW, COR};
5
6      site label ()           { return name; }
7      site label (site name) { this->name = name; }
8      int  apply ();          // map zone to address space
9
10     zone (site name, const section& slot) {
11         label(name);
12         *(section*)this = slot;
13     }
14 };
```

- systemweit eindeutige Bezeichnung eines Adressbereiches

Adressraum eines Prozesses

- Geltungsbereich (*scope*) des Adressraums

```
1  class scope {
2  public:
3      area* allot (area&, int, act*); // map address range
4      int   alter (area&, int, act*); // modify mapping
5  };
```

- Bereich (*area*) im Adressraum

```
1  class area : public section {
2  public:
3      int  range ()          { return size; }
4      void range (int size) { this->size = size; }
5      void clear ()          { range(0); }
6  };
```

- Standort (*site*) ⇝ VL 9