

Betriebssystemtechnik

Adressräume: Trennung, Zugriff, Schutz

X. Mitbenutzung

Wolfgang Schröder-Preikschat

23. Juni 2014



Gliederung

Einleitung

Gemeinschaftssegmente

Allgemeines

Übertragungstechniken

Allgemeines

Prozessadressraumerzeugung

Nachrichtenversenden

Zusammenfassung



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

Einleitung

Gemeinschaftssegmente

Allgemeines

Übertragungstechniken

Allgemeines

Prozessadressraumerzeugung

Nachrichtenversenden

Zusammenfassung



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 ($\mathfrak{S}$) in M logischen Adressräumen, $N \geq M$

$N = M \Rightarrow$ einfache
 $N > M \Rightarrow$ mehrfache

} Mitbenutzung pro logischen Adressraum

■ werden abgebildet auf 1 Bereich ($\mathfrak{R}$) des realen Adressraums

■ wobei $\mathfrak{S} \subseteq \mathfrak{R}$, d.h., die Bereiche müssen nicht deckungsgleich sein

■ $\mathfrak{S}$ kann kleiner, sollte aber nicht größer als $\mathfrak{R}$ sein

■ $\mathfrak{S}$ verschiedener logischer Adressräume:

- i müssen denselben logischen Adressbereich abdecken oder
- ii können verschiedenen Ausschnitten dieser Adressbereiche entsprechen


■ verschiedene $\mathfrak{S}$ desselben logischen Adressraums können überlappen

■ Ausrichtung (*alignment*) von $\mathfrak{S}$ und $\mathfrak{R}$ gemäß Granulatgröße

■ Segmentierung $\mapsto$ Byte bzw. Block¹, Seitennummerierung $\mapsto$ Seite

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

Positionsabhängige Mitbenutzung



■ totale Einblendung eines Bereichs $\mathfrak{R}$ 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 $\mathfrak{R}$ ist auch möglich (re.)

Positionsunabhängige Mitbenutzung I

einfach



■ totale/partielle Einblendung des Bereichs $\mathfrak{R}$ des realen Adressraums

■ Verzicht auf absolute Adressen in $\mathfrak{R}$ bedingt Positionsunabhängigkeit


– zum Zeitpunkt der Einblendung von $\mathfrak{R}$ in $\mathfrak{S} \leadsto$ **Migrationsintransparenz**

■ die Textbereiche in $\mathfrak{R}$ enthalten ausschließlich **relative Adressen**

■ **positionsunabhängiger Code** (*position-independent code*, PIC; [2])

Positionsunabhängige Mitbenutzung II

mehrfach



■ mehrfache (total/partiell) Einblendung des Bereichs $\mathfrak{R}$ (re.)

■ $\mathfrak{R}$ liegt an verschiedenen Bereichen $\mathfrak{S}$ im selben logischen Adressraum

– z.B. verschiedene Datenstrukturen, die nacheinander referenziert werden

■ zum Datenzugriff werden auf $\mathfrak{R}$ **verschieden breite Fenster** gelegt

■ die Prozesse entscheiden selbst, wo der Bereich $\mathfrak{R}$ eingeblendet wird

Einflussfaktoren

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

- Ausrichtung von $\mathfrak{S}$ 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 Programmaufzeit 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-/Ladmodule 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

Einleitung

Gemeinschaftssegmente

Allgemeines

Übertragungstechniken

Allgemeines

Prozessadressraumerzeugung

Nachrichtenversenden

Zusammenfassung



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 quelseitig 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...





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
 - zweiseitig 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
- bedarfsorientierter (*on-demand*) Datentransfer, auch netzwerkweit

```

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




```

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




```

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 }

```





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 Ergebnismeldung

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



Einleitung

Gemeinschaftssegmente

Allgemeines

Übertragungstechniken

Allgemeines

Prozessadressraumerzeugung

Nachrichtenversenden

Zusammenfassung



■ Informationsaustausch und gemeinsame Benutzung

- Konsequenz der isolierten Adressräume, logische Funktionsverteilung
- 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




```

1 class stage {
2     static act* life;          // currently running thread
3     static unsigned mask;      // limit of following array
4     static act list[];         // thread descriptor table
5 public:
6     static act* being()        { return life; }
7     static act* being(site slot) {
8         act* item = &list[slot & mask];
9         return item->label() == slot ? item : 0;
10    }
11 };

```

■ 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**



```

1 class act : public lockbox, public scope {
2     int trim;                // mood, scheduling state
3     void* wait;              // blocked-on event
4 public:
5     enum mood {READY, RUNNING, BLOCKED};
6
7     void block ();            // release processor
8     void ready ();           // compete for processor
9
10    void apply (void*);       // set blocked-on event
11
12    void block (void*);       // fall asleep until given event
13    void rouse (void*);       // awake, if blocked on event
14
15    lump* glean ();           // await inbox message
16    int serve (lump&);        // awake inbox-blocked act
17    int exert (lump&);        // await outbox message
18    int quote (lump&);        // awake outbox-blocked act
19 };

```



Prozesssteuerung für IPC

```

1 inline void act::apply (void* link) { wait = link; }
2
3 inline void act::block (void* link) {
4     apply(link);           // set blocked-on event and
5     block();               // release processor
6 }
7
8 inline void act::rouse (void* link) {
9     if (wait == link) {    // the right wakeup event?
10        wait = 0;           // yes, cancel and
11        ready();            // compete for processor
12    }
13 }
14
15 inline lump* act::glean () {
16     lump* item = clear();  // remove next message descriptor from inbox
17     if (!item) {           // none available, prepare to block
18         block(&booth());   // await specified event
19         if (!wait)         // no exceptional wakeup
20             item = clear(); // there must be a message descriptor
21     }
22     return item;
23 }
24
25 inline int act::exert (lump& item) {
26     if (item.range() != 0) // outbox available, i.e., not in use?
27         block(&item);      // no, await release event (quote)
28 }
29
30 inline int act::quote (lump& item) { range(0); rouse(&item); }
31 inline int act::serve (lump& item) { aback(item); rouse(&booth()); }

```



Nachrichten und -deskriptoren

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

```

1 class lockbox : public lump {
2     queue inbox;
3 public:
4     lump& depot () { return *this; }
5     queue& booth () { return inbox; }
6     lump* clear () { return (lump*)inbox.clear(); }
7     void aback (lump& item) { inbox.aback(item); }
8     void retry (lump& item) { aback(item); }
9 };

```

■ im Postfach lagerungsfähige Posten (*lump*)

```

1 class lump : public chain, public zone {
2 public:
3     lump& stock (const section&); // keep section
4     lump& operator= (const section&); // stock it
5 };

```

■ Warteschlange (*queue*) und Verkettung (*chain*)

↪ VL 9



■ 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



■ 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

