Betriebssystemtechnik

Adressräume: Trennung, Zugriff, Schutz

IX. Kommunikationsabstraktionen

Andreas Ziegler

27. Juni 2019

Gliederung

Rekapitulation

- die Prozessblockade synchronisiert auf die Betriebsmittelbereitstellung

  Sender
  - benötigt wiederverwendbare Betriebsmittel

    synchrone IPC $\Rightarrow$ Nachrichtenplatzhalter $\mapsto$ Ziel
    asynchrone IPC $\Rightarrow$ Zwischenpuffer
    $\Rightarrow$ Nachrichten(platzhalter)deskriptor

  Empfänger
  - benötigt konsumier- *und* wiederverwendbare Betriebsmittel

    synchrone IPC $\Rightarrow$ Nachricht $\mapsto$ Quelle
    asynchrone IPC $\Rightarrow$ Zwischenpuffer
    $\Rightarrow$ Nachrichten(platzhalter)deskriptor

- asynchrone IPC bedeutet nicht nichtblockierende Kommunikation **!!!**
  - es meint, Sende- und Empfangsprozess logisch voneinander zu entkoppeln
- „echt nichtblockierend“ bedeutet, `send`/`receive` scheitern zu lassen

Gliederung

Kommunikationsart und Betriebsmittel I

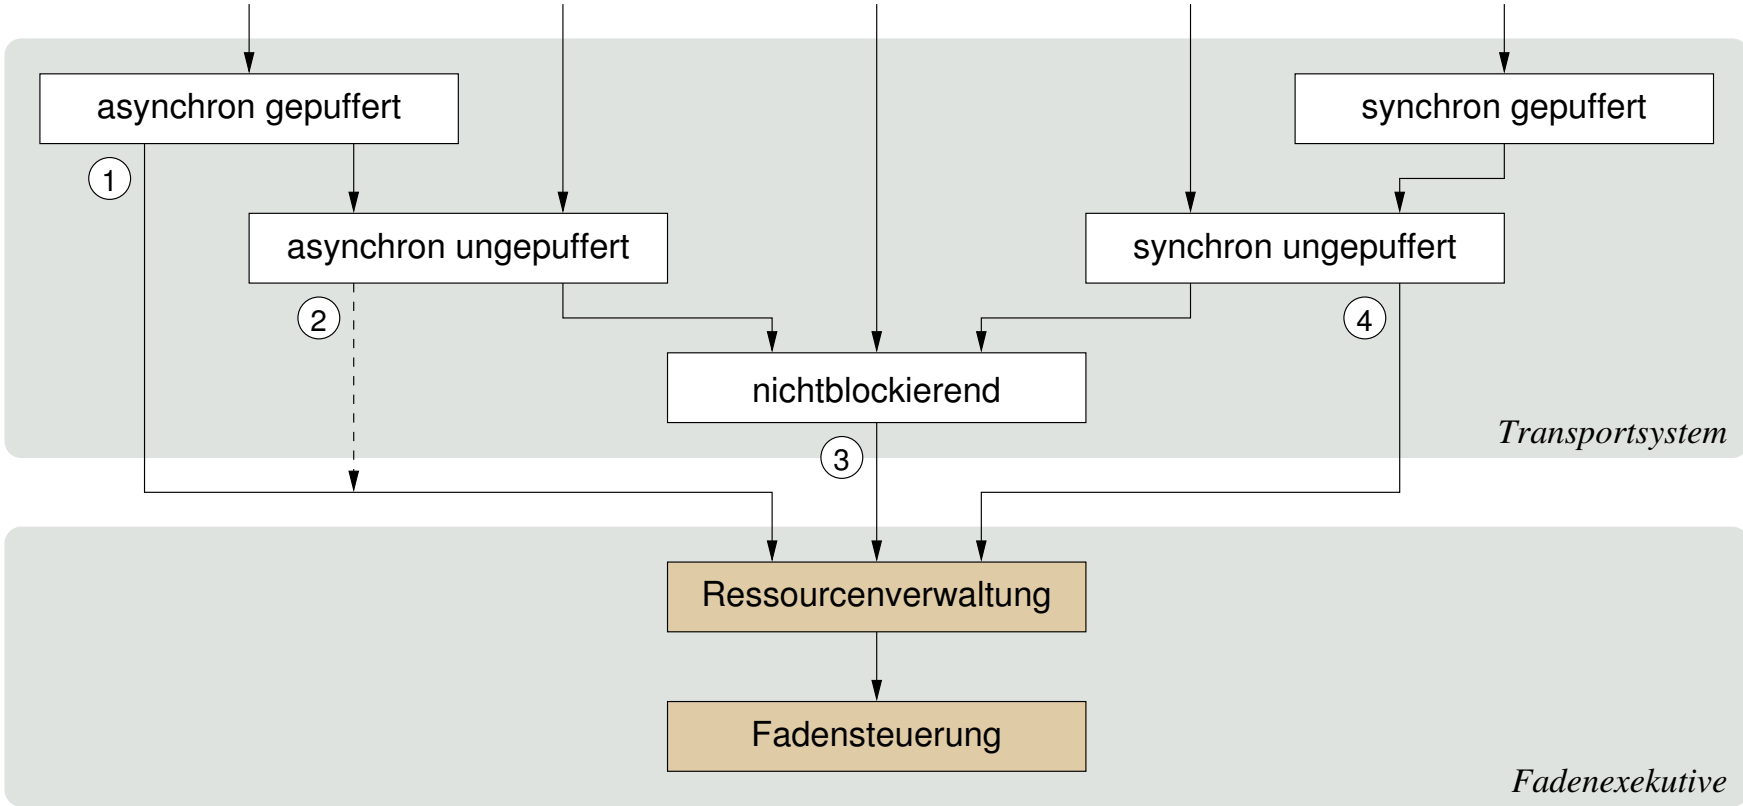

- Schnittstelle zur Fadenexekutive (Ressourcenverwaltung):
  1. Bereitstellung eines Puffers zur Nachrichtenaufnahme abwarten
  2. Bereitstellung eines Pufferdeskriptors zur Nachrichtenerfassung abwarten
  3. Verfügbarkeit eines Puffers/Pufferdeskriptors anzeigen
  4. Übernahme/Empfang einer Nachricht anzeigen

Asynchrone Kommunikation

- braucht Puffer/-deskriptoren als Betriebsmittel im Betriebssystem:
  - gepuffert
    - nach Übergabe an das Transportsystem kann der belegte Speicherbereich sofort wiederverwendet werden
    - durch den Einsatz von Wechselpufferverfahren kann der Kopieraufwand vermieden werden
  - ungepuffert
    - nach Übergabe an das Transportsystem darf der belegte Speicherbereich nur bedingt wiederverwendet werden
    - durch Signalisierung des Sendeprozesses wird die mögliche Wiederverwendung des Speicherbereichs angezeigt
- beide Verfahren wirken blockierend auf den Sendeprozess, wenn:
  i. die Nachrichtenpuffer oder -deskriptoren ausgegangen sind *und*
  ii. die durch Betriebsmittelmangel entstehende Ausnahmesituation nicht zum Scheitern der Operation führen soll

Synchrone Kommunikation

- braucht Puffer als Betriebsmittel im Anwendungssystem:
  - gepuffert
    - nach Übergabe an das Transportsystem kann der belegte Speicherbereich sofort wiederverwendet werden
      - undzwar von einem anderen Faden desselben Programms
    - das Programm kann problemlos ausgelagert werden
  - ungepuffert
    - nach Übergabe an das Transportsystem kann der Transfer der Nachricht End-zu-End stattfinden
      - direkt zwischen Sende- und Empfangsadressraum
    - das Programm kann nur bedingt ausgelagert werden
- beide Verfahren wirken blockierend auf den Sendeprozess:
  - die Operation kann nicht wegen Betriebsmittelmangel scheitern
    - da der Sendeprozess zu einem Zeitpunkt niemals mehr als einen Kommunikationsvorgang auslösen kann
  - sie kann jedoch scheitern, wenn der Empfangsprozess ungültig ist

Nichtblockierende Kommunikation

- alle erforderlichen Betriebsmittel werden „von oben“ geliefert:
  - Puffer
    - von der Anwendungsebene *oder*
    - von der höheren Systemebene
      - die gepufferte Kommunikation implementiert
  - Pufferdeskriptor
    - von der höheren Systemebene
      - die ungepufferte Kommunikation implementiert
- die Kommunikationsbetriebsmittel werden lediglich „delegiert“
  - sie werden Verarbeitungseinheiten (Protokollmaschine, Treiber) zugeführt
  - ihre Freigabe wird den Prozessen signalisiert
- den Prozessen obliegt es, ggf. auf Freigabesignale „oben“ zu warten
  - auf der Anwendungs- oder Systemebene

Kommunikationsart und Betriebsmittel II

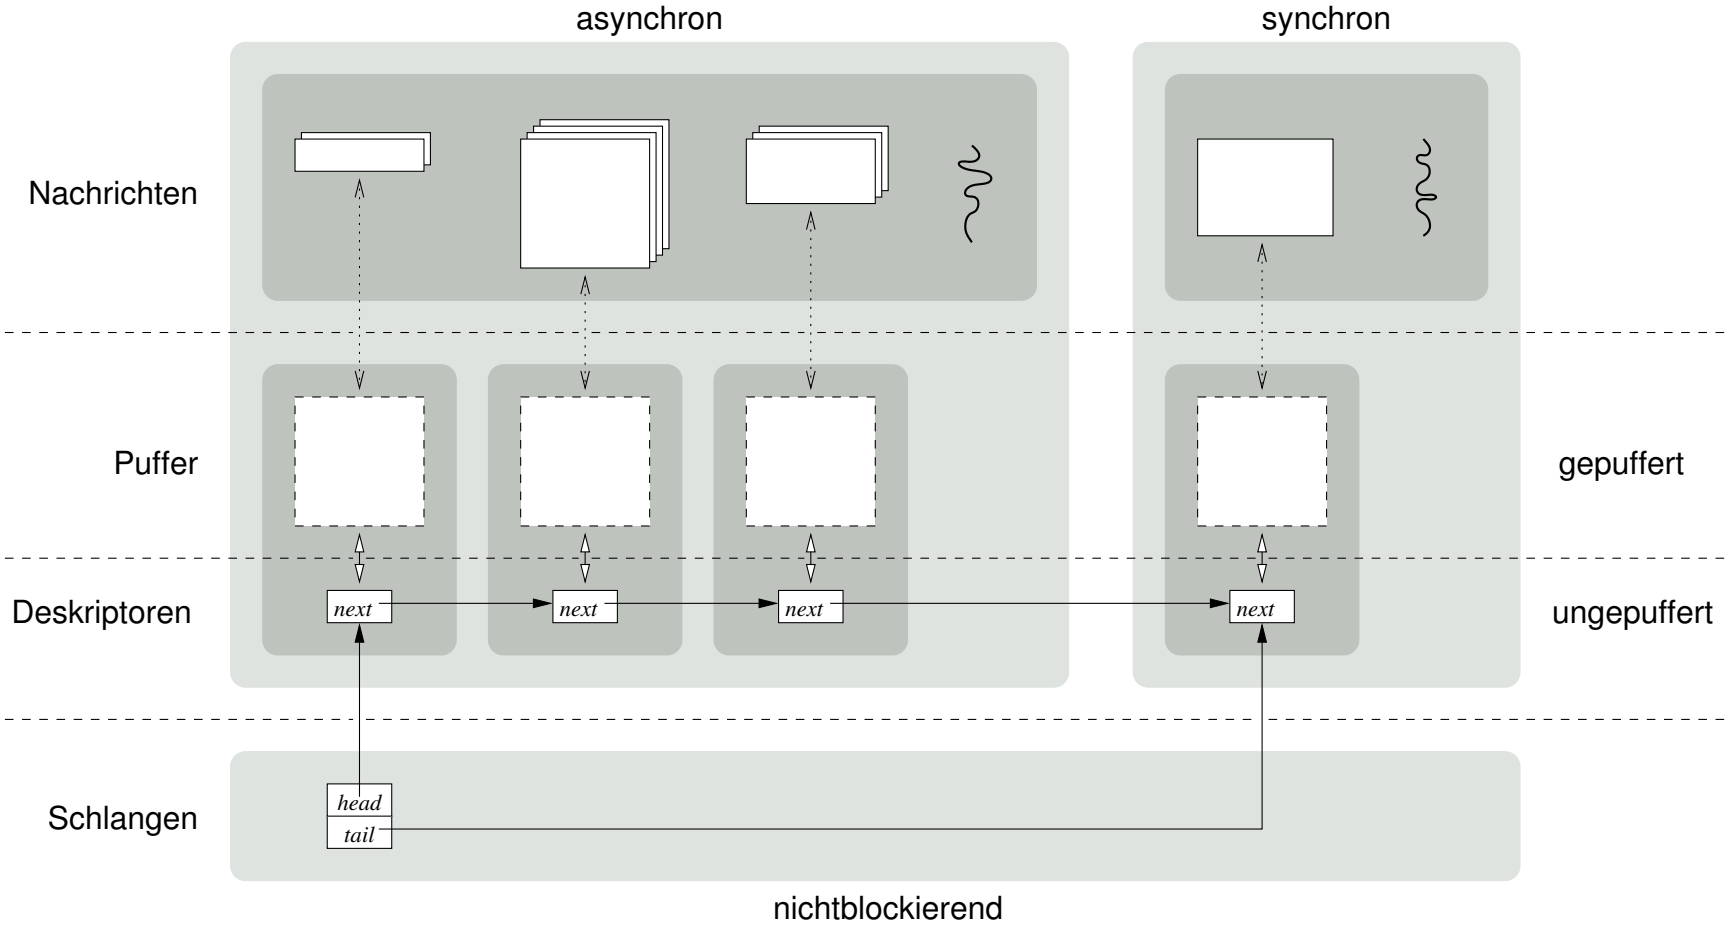

- in Ermangelung von Betriebsmitteln werden Prozesse blockieren
  - hier: Nachrichtenpuffer und -deskriptoren
  - unabhängig von den Synchronität der Kommunikation

Abstraktion von Datenlisten I

- minimale Basis für eine (beliebige) dynamische Datenstruktur

```
1  class chain {
2  protected:
3      chain* link;
4  public:
5      chain        ()              { link = 0; }
6      chain* next  ()              { return link; }
7      void   next  (chain* item)   { link = item; }
8  };
```

- Spezialisierung leicht durch eine Schablone (*template*) möglich

```
1  template<typename T>
2  class entry: public chain {
3      T item;
4  public:
5      entry<T>* next  ()                 { return link; }
6      void      next  (entry<T>* item)   { link = item; }
7  };
```

Abstraktion von Datenlisten II

```
1  class queue : public chain {
2  protected:
3      chain* last;
4  public:
5      queue        () { last = this; }
6      chain* head  () { return link; }
7      chain* tail  () { return last; }
8
9      void aback (chain* item) {
10         last->next(item);
11         last = item;
12     }
13
14     chain* clear () {
15         chain* item = link;
16         if (item && !(link = item->next())) last = this;
17         return item;
18     }
19 };
```

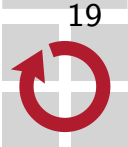

Abstraktion von Kommunikationsendpunkten

- Nachrichtenlokalität im Sender-/Empfängerprozess

```
1 typedef long site; // structured endpoint identifier
```

- problemspezifische Identifizierung von „Kommunikationsentitäten“:

Prozesskontrollblock	■ direkte Adresse des Sende-/Empfangsprozesses ■ Deskriptor einer Prozessinkarnation
Prozessanschluss	■ indirekte Adresse des Sende-/Empfangsprozesses ■ Zugang (*port*, [2]) zu einer Prozessinkarnation
Postkasten	■ Adresse eines Behältnisses für Nachrichten ■ Aus- oder Eingang (*mailbox*)
Prozedur	■ Adresse der Verarbeitungsroutine der Nachricht ■ Nachrichtenextraktion/-integration [13, S. 256]

- das Bezugssystem bestimmt Struktur und Größe des Bezeichners
  - ähnlich, wie eine MMU Struktur in einer logischen Adresse interpretiert
  - in vernetzten Systemen müssen „Ortskoordinaten“ enthalten sein
  - lokal („vor Ort“) muss die Entität unterscheidbar referenziert werden

Abstraktion von Nachrichtenstrukturen I

- Nachrichtendeskriptor einfach (minimale Basis)

```
1  class alert;              // transfer-event signalling
2
3  struct section {
4      union {
5          void* data;   // address as data pointer
6          alert* sign; // address as transfer event
7      } base;
8      unsigned size;    // number of bytes at that address
9  };
```

  - Quell-/Zieladresse im logischen Adressraum ist auch „Ereignisname“
    - bezeichnet eindeutig das Transfereignis für Sender bzw. Empfänger
  - implizite Signalisierung mit Beendigung der Transferoperation (vgl. S. 19)

- Nachrichtendeskriptor verkettbar (minimale Erweiterung)

```
1  class notice: public chain, public section {};
```

Abstraktion von Nachrichtenstrukturen II

- Nachrichtenpaket

```
1  #define PACK_SIZE 64                    // beware of the cache
2  #define PART_COUNT (PACK_SIZE / sizeof(section))
3
4  struct pack {    // beware of the cache: packet alignment
5      union {
6          char data[PACK_SIZE];       // bounded dataset
7          section part[PART_COUNT]; // descriptor set
8      } sort;
9  };
```

  - Platzhalter für einen Datensatz oder mehrere Nachrichtendeskriptoren
  - weitere Varianten ergeben sich ggf. aus dem jeweiligen Anwendungsfall
    - wenn z.B. System(prozess)aufrufe als Fernaufruf [11] laufen sollen

- die Größe ergibt sich auch durch das Programmiermodell der CPU
  - bei Registernutzung zum Botschaftenaustausch zwischen Prozessen *oder*
  - der Ausnutzung der Zwischenspeicherzeile (*cache line*) zum Datentransfer

Abstraktion zum Botschaftenaustausch I

- Versenden und Empfangen von Nachrichtensegmenten

```
1 class message : public section {
2 public:
3     int  send    (site);    // no-wait send, unbuffered
4     site receive ();
5 };
```

- Versenden und Empfangen von Nachrichtenpaketen

```
1 class parcel : public pack {
2 public:
3     site send    (site);    // synchronization send
4     site receive ();
5 };
```

```
1 class datagram : public pack {
2 public:
3     int  send    (site);    // no-wait send
4     site receive ();
5 };
```

Abstraktion zum Botschaftenaustausch II

- Versenden, Empfangen, Beantworten von Anforderungsnachrichten

```
1  class request : public pack {
2  public:
3      site send    (site, pack&); // remote-invocation send
4      site receive ();
5      int  reply   (site);
6
7      site send(site peer) {
8          return send(peer, *this);
9      }
10 };
```

- Verarbeitungsschleife von Anforderungsnachrichten

```
1  for (;;) {
2      request msg;
3      site peer = msg.receive();
4      // carry out order as encoded in the request
5      msg.reply(peer);
6  }
```

Abstraktion zum Datentransfer I

- Auslösung adressraumübergreifender Datentransfers

```
1 class dataset : public section {
2 public:
3     // various dataset constructors come here...
4     int fetch (site, section&); // copy from peer
5     int store (site, section&); // copy to peer
6 };
```

- Verwendungsmuster der Transferoperationen

```
1 dataset from, to;
2
3 from.fetch(peer, to);    // copy data from peer to me
4 to.store(peer, from);    // copy data from me to peer
```

- section-Attribute des dataset sind mittels pack kommunizierbar
  - z.B. über die Verarbeitungsschleife von Anforderungsnachrichten (S. 16)
- ohne Zwischenpufferung wird zwischen den Adressräumen transferiert

Abstraktion zum Datentransfer II „*interruptive*“ Software DMA

- Auslösung adressraumübergreifender, signalisierender Datentransfers

```
1 class capture : public dataset {
2 public:
3     // various capture constructors come here...
4     int fetch (site, section&); // copy from peer & alert
5     int store (site, section&); // copy to peer & alert
6 };
```

- Verwendungsmuster der Transferoperationen

```
1 capture from, to;
2
3 from.fetch(peer, to);    // signal peer when fetched
4 to.store(peer, from);    // signal peer when stored
```

- Ereignis `{from,to}.base.sign` (S. 13) wird im peer-Kontext angezeigt
- ein auf dieses Ereignis wartender Faden im peer-Team wird freigestellt
- das peer-Team erfährt von Lese-/Schreibzugriffen auf seinen Adressraum
  - genauer: von der Beendigung der korrespondierenden Transferoperationen

Abstraktion zum Datentransfer III „zählender Fadensemaphor“

- Signalisierung von Transfereignissen

```
1 class alert {
2 public:
3     int raise (int);       // simulate fetch/store event
4     int await (unsigned); // block on fetch/store event
5 };
```

- ein Faden kann ein `fetch`/`store` auf seinen Adressraumen erfassen
  - signalisiert wird die Basisadresse des zugegriffenen Adressraumabschnitts
  - diese Adresse ist (in dem Fall) auch die Adresse einer `alert`-Inkarnation
  - angezeigt wird Konsumier-/Wiederverwendbarkeit eines Betriebsmittels

    `store` liefert das konsumierbare Betriebsmittel „Nachricht“
    ↪ `await` liefert die Anzahl der transferierten Bytes

    `fetch` macht das wiederverwendbare Betriebsmittel „`capture`“ frei
    ↪ `await` liefert 0
- der Faden wartet eine gegebene Anzahl solcher Ereignisse ab
  - ein zählender Semaphor ist Komponente des Fadenkontrollblocks

Fadensemaphor

Semaphor [5], der fest mit einem Faden verbunden ist und ansonsten die üblichen zählenden Eigenschaften besitzt

- der Semaphor ist Attribut des Fadendeskriptors bzw. -kontrollblocks
  - der Fadendeskriptor enthält, erbt, „benutzt“ einen Semaphordeskriptor
  - über diesen werden fadenspezifische Ereignisse signalisiert und verwaltet
- seine Bedeutung im Zusammenhang mit asynchronen Datentransfers:
  - Anzeige der Konsumier-/Wiederverwendbarkeit eines Betriebsmittels
  - Synchronisierung mit vielen Lesern/Schreibern desselben Speicherbereichs
  - Unterstützung von asynchronen, prozessübergreifenden Prozeduraufrufen
    - mit einem „Versprechen“ (*promise*, [6, 10]) zur Ergebnislieferung
    - die „letztendlich“ (*eventual*, [7]) beim aufrufenden Prozess eintrifft und
    - Erwartungen an eigene Berechnungen in der „Zukunft“ (*future*, [1]) weckt
  - Kommunikation „gleichgetakteter“ Prozesse nach dem SPMD [4] Modell
- in Anlehnung an den PEACE „Segmenttransfer“ [12, S. 370 *ff.*]

Nachrichtenversand und -empfang

- Versenden einer Nachricht ungepuffert im Transportsystem

```
1  int send (site peer, message& msg) {
2      msg.send(peer);                    // pass descriptor
3      return msg.base.sign->await(1);
4  }
```

send versendet den Nachrichtendeskriptor nichtwartend (*no-wait*)
await blockiert den Faden bis zur Beendigung von `fetch`

- Empfangen einer Nachricht gepuffert im Anwendungssystem

```
1  int receive (section& buf) {
2      buf.base.data = 0;                 // nothing received yet
3
4      message msg;
5      site peer = msg.receive();  // fill descriptor
6      if (peer && (buf.base.data = new char[msg.size]))
7          buf.size = capture(msg).fetch(peer, buf);
8  }
```

Prozessorbezug und Anwendungsdomäne

Mikrokerne in Reinform [9] sind in ihrer Leistungsfähigkeit parallelen Systemen eher abträglich $\rightsquigarrow$ „*microkernel considered harmful*“

- hier war und ist schon immer prozessorübergreifende IPC Normalität
  - insb. auf verteilten Speicher (*distributed memory*) basierende Systeme
  - vorrangig ist die minimale Rüstzeit (*setup time*) für die Kommunikation
  - dabei ist lokale IPC die Ausnahme, aber globale IPC ein Muss
- Optimierungsmaßnahmen für lokale Operationen verlieren an Gewicht
  - System- und Anwendungsprozesse residieren eher selten am selben Ort
  - Prozessorregister als Nachrichtenbehälter [3, 8] sind wenig wirkungsvoll

Vielkerner (*many-core processor*) lassen die kooperative Einplanung von Fäden kernlokal immer mehr zur Normalität werden

- das impliziert jedoch nicht die kernlokale IPC zwischen den Fäden
- vielmehr ist auf die Zwischenspeicherzeile (*cache line*) zu achten
  - die nicht nur Größe und Ausrichtung der Nachrichtenpuffer bestimmt
  - sondern überhaupt die Implementierung von IPC querschneidend belangt

Gliederung

Resümee

- Rekapitulation: blockierende vs. nichtblockierende Kommunikation
  - asynchrone IPC bedeutet nicht nichtblockierende Kommunikation
  - „echt nichtblockierend“ bedeutet, `send`/`receive` scheitern zu lassen
- Zusammenhang von Kommunikationsart und Betriebsmittel
  - asynchrone Kommunikation, gepuffert/ungepuffert
  - synchrone Kommunikation, gepuffert/ungepuffert
  - nichtblockierende Kommunikation $\rightsquigarrow$ Betriebsmittel delegieren
- Kommunikationsabstraktionen in Anlehnung an PEACE [12]
  - Datenlisten: Verkettungsglied und -kopf, Spezialisierung
  - Kommunikationsendpunkte: Nachrichtenlokalität (Sender/Empfänger)
  - Nachrichtenstrukturen: Nachrichtendeskriptor und -paket
  - Botschaftenaustausch: *no-wait*, *synchronization*, *remote invocation*
  - Datentransfer: adressraumübergreifend (DMA), signalisierend
  - Fadensemaphor: *promise*, *eventual*, *future*
- Konzepte, die logisch systemweit (kern-/netzübergreifend) greifen

Literaturverzeichnis I

[1] Baker, Jr., H. C. ; Hewitt, C. :
The Incremental Garbage Collection of Processes.
In: Low, J. (Hrsg.): *Proceedings of the 1977 ACM Symposium on Artificial Intelligence and Programming Languages (AIPL '77)*, ACM, 1977, S. 55–59

[2] Balzer, R. M.:
PORTS—A Method for Dynamic Interprogram Communication and Job Control.
In: *Proceedings of the Spring Joint Computer Conference (AFIPS'71)* Bd. 38
American Federation of Information Processing Societies, 1971, S. 485–489

[3] Cheriton, D. R.:
An Experiment Using Registers for Fast Message-Based Interprocess Communication.
In: *SIGOPS Operating Systems Review* 18 (1984), Okt., Nr. 4, S. 12–20

[4] Darema-Rogers, F. ; George, D. A. ; Norton, V. A. ; Pfister, G. F.:
A VM Parallel Environment / IBM.
1985 (RC 11225). –
IBM Research Report

Literaturverzeichnis II

[5] Dijkstra, E. W.:
Cooperating Sequential Processes / Technische Universiteit Eindhoven.
Eindhoven, The Netherlands, 1965 (EWD-123). –
Forschungsbericht. –
(Reprinted in *Great Papers in Computer Science*, P. Laplante, ed., IEEE Press, New York, NY, 1996)

[6] Friedman, D. P. ; Wise, D. S.:
The Impact of Applicative Programming on Multiprocessing.
In: *Proceedings of the 1977 International Conference on Parallel Processing*, IEEE Computer Society, 1977, S. 263–272

[7] Hibbard, P. :
Parallel Processing Facilities.
In: Schuman, S. A. (Hrsg.): *New Directions in Algorithmic Languages*.
Institut de Recherche en Informatique et Automatique (IRIA), 1976, S. 1–7

[8] Liedtke, J. :
Improving IPC by Kernel Design.
In: Black, A. P. (Hrsg.) ; Liskov, B. J. H. (Hrsg.): *Proceedings of the Fourteenth ACM Symposium on Operating System Principles (SOSP '93)*, ACM, 1993. –
ISBN 0–89791–632–8, S. 175–188

Literaturverzeichnis III

[9] Liedtke, J. :
On μ-Kernel Construction.
In: Jones, M. B. (Hrsg.): *Proceedings of the 15th ACM Symposium on Operating System Principles (SOSP '95)*, ACM Press, 1995. –
ISBN 0–89791–715–4, S. 237–250

[10] Liskov, B. J. H. ; Shrira, L. :
Promises: Linguistic Support for Efficient Asynchronous Procedure Calls in Distributed Systems.
In: Wexelblat, R. L. (Hrsg.): *Proceedings of the ACM SIGPLAN'88 Conference on Programming Language Design and Implementation (PLDI)*, ACM Press, 1988. –
ISBN 0–89791–269–1, S. 260–267

[11] Nelson, B. J.:
Remote Procedure Call.
Pittsburg, PA, USA, Department of Comupter Science, Carnegie-Mellon University, Diss., Mai 1981

[12] Schröder-Preikschat, W. :
The Logical Design of Parallel Operating Systems.
Upper Saddle River, NJ, USA : Prentice Hall International, 1994. –
ISBN 0–13–183369–3

Literaturverzeichnis IV

[13] von Eicken, T. ; Culler, D. E. ; Goldstein, S. C. ; Schauser, K. E.:
Active Messages: a Mechanism for Integrated Communication and Computation.
In: Gottlieb, A. (Hrsg.): *Proceedings of the 19th International Symposium on Computer Architecture (ISCA '92)*, ACM, 1992. –
ISBN 0–89791–509–7, S. 256–266