Ludwig-Maximilians-Universität München
Institut für Informatik
Lehrstuhl für Mobile und Verteilte Systeme

mobile and distributed systems group

Betriebssysteme

Skript zur Vorlesung im Wintersemester 2009/2010

Prof. Dr. Claudia Linnhoff-Popien

Unter Mitarbeit von:
Ulrich Bareth, Michael Dürr, Tim Furche, Matthias Hampel, Thomas Höhler, Carmen Jaron, Thomas Schaaf und Diana Weiß

Inhaltsverzeichnis

Abbildungsverzeichnis

Literaturverzeichnis

[1] Greg Gagnei Abraham Silberschatz, Peter Baer Galvin. *Operating System Concepts*. John Wiley & Sons, eight edition, 2008. 992 pages, ISBN-10: 0470128720, ISBN-13: 978-0470128725.

[2] Uwe Baumgarten Hans-Jürgen Siegert. *Betriebssysteme - eine Einführung*. Oldenbourg, sixth edition, 2006. 405 pages, ISBN-10: 3486582119, ISBN-13: 978-3486582116.

[3] Larry L. Wear James R. Pinkert. *Operating Systems - Concepts, Policies and Mechanisms*. Prentice-Hall, 1989. 352 pages, ISBN-10: 0136380735, ISBN-13: 978-0136380733.

[4] Bernd Meyer Otto Spaniol, Claudia Popien. *Dienste und Dienstvermittlung in Client/Server-Systemen*. 1994. ISBN-10: 3929821745, ISBN-13: 978-3929821741.

[5] William Stallings. *Operating Systems - Internals and Design Principles*. Prentice Hall, sixth edition, 2008. 840 pages, ISBN-10: 0136006329, ISBN-13: 978-0136006329.

[6] Andrew S. Tanenbaum. *Betriebssysteme I. Lehrbuch. Entwurf und Realisierung*. Hanser Fachbuchverlag, 1989. 322 pages, ISBN-10: 3446152687, ISBN-13: 978-3446152687.

[7] Andrew S. Tanenbaum. *Betriebssysteme II. MINIX- Leitfaden und kommentierter Programmtext*. Hanser Fachbuchverlag, 1990. 268 pages, ISBN-10: 3446152695, ISBN-13: 978-3446152694.

[8] Andrew S. Tanenbaum. *Verteilte Betriebssysteme*. Prentice-Hall, 1999. 740 pages, ISBN-10: 393043623X, ISBN-13: 978-3930436231.

[9] Andrew S. Tanenbaum. *Moderne Betriebssysteme*. Pearson Studium, second edition, 2002. 1021 pages, ISBN-10: 3827370191, ISBN-13: 978-3827370198.

[10] Uresh Vahalia. *Unix Internals - The New Frontiers*. Prentice Hall, 1995. 601 pages, ISBN-10: 0131019082, ISBN-13: 978-0131019089.

[11] Horst Wettstein. *Architektur von Betriebssystemen*. Hanser Fachbuchverlag, third edition, 1987. 396 pages, ISBN-10: 3446150625, ISBN-13: 978-3446150621.

Teil I

Einführung

1

Das Betriebssystem

- Einordnung der Maschinensprache
- Betriebssysteme und ihre Aufgaben
- Geschichte der Betriebssysteme
- Arten von Betriebssystemen

Inhaltsangabe

1.1 Einordnung der Maschinensprache

In der Vorlesung "Rechnerarchitekturen" wurde die Arbeitsweise der Rechnerhardware betrachtet und darauf aufbauend dargestellt, wie sich Programme auf Maschinenebene schreiben lassen. In dieser Vorlesung legen wir den Schwerpunkt auf das Betriebssystem: Wir betrachten, wie es Programme ausführt und welche Dienste es dem Nutzer zur Verfügung stellt. Dabei werden die eingeführten Konzepte wieder verwendet.
Logisch kann man die Hierarchie der Funktionen eines Rechners wie in Abbildung 1.1 darstellen.

Abbildung 1.1: Logische Hierarchie in einem Rechner

Bislang wurde die Ebene der Maschinensprache betrachtet, die kein Bestandteil der Hardware, sondern abhängig von dem jeweils verwendeten Assembler ist. Darunter liegt eine einfache Softwareschicht (Mikroprogrammierung), die unmittelbar auf physische Komponenten der Hardware einwirkt und eine sehr unkomplizierte Schnittstelle zur Maschinensprache besitzt. Diese Software interpretiert einzelne Maschinenanweisungen wie `ADD`, `MOVE` und `JUMP` in einzelnen Schritten. Um dabei z.B. einen Befehl wie `ADD` auszuführen, benötigt das Mikroprogramm die Adressen der Speicherzellen, aus denen gelesen bzw. in die geschrieben werden soll. Die Menge aller Befehle, die das Mikroprogramm interpretiert, definiert den Befehlsvorrat der Maschinensprache. Um in dieser Schicht beispielsweise Ein- und Ausgabegeräte ansprechen zu können, müssen die Parameter in Geräteregister geladen werden.

Beispiel 1.1 (Diskettenzugriff)**.** *Um eine Datei von Diskette zu laden müssen (unter anderem) folgende Schritte erfolgen:*

1. *Falls nötig Starten des Laufwerksmotors.*
2. *Positionieren des Lesekopfes über der Spur, die das Verzeichnis (Directory) enthält.*
3. *Sektorenweises Einlesen des Verzeichnisses.*
4. *Suchen der Dateiinformationen im Verzeichnis (Dateianfang).*
5. *Positionieren des Lesekopfes über der entsprechenden Spur.*
6. *Teil einlesen, Verknüpfung zum nächsten Teil erkennen und weiter mit 5 solange das Ende der Datei nicht erreicht ist.*

Für jeden Befehl an den Laufwerkscontroller sind hier (neben vielen anderen) die folgenden Werte in die jeweiligen Geräteregister zu laden:

- *Die Adresse der Spur,*
- *die Adresse der Hauptspeicherzelle,*
- *die Anzahl der zu übertragenden Bytes und*
- *der Befehlscode (Lesen oder Schreiben).*

1.2 Aufgaben des Betriebssystems

Das **Betriebssystem** soll diese Komplexität nun mindern, es soll also dem Programmierer einen Befehlssatz bereitstellen, der einfach zu beherrschen ist und die internen Details vor dem Nutzer verbirgt.

Aufgaben des Betriebssystems: Das Betriebssystem hat im Wesentlichen die drei folgenden Aufgaben:

1. Das Betriebssystem ist eine **erweiterte Maschine**, die leichter zu programmieren ist als die darunter liegenden Schichten. Beispielsweise wird die Festplatte nicht mehr durch Sektoren repräsentiert, sondern als Sammlung von Dateien dargestellt, auf die der Benutzer als Einheit zugreifen kann.
2. Das Betriebssystem ist ein **Ressourcenmanager**. Es verwaltet die vorhandenen Systemressourcen wie z.B. Speicher, die CPU oder Ein- und Ausgabegeräte und vermittelt zwischen den sich gegenseitig beeinflussenden Anforderungen der verschiedenen Programme und Nutzer. Für das **Multiplexing**, also das Verteilen von Ressourcen auf zwei oder mehr Programme bzw. Nutzer, gibt es zwei Ansätze:
   - Beim **Time Multiplexing** wird die Ressource zeitlich verzahnt immer vollständig einem Programm zur Verfügung gestellt (z.B. Prozessor).
   - Beim **Space Multiplexing** hingegen teilen sich mehrere Programme die Ressource gleichzeitig (z.B. Hauptspeicher).

   Die Aufgabe des Betriebssystems ist es, beschränkte Ressourcen so zuzuteilen, dass alle Programme ihren Auftrag korrekt ausführen können.
3. Das Betriebssystem dient als **Kontrollinstanz** für jegliche Zugriffe. Unerlaubte Zugriffe auf Hardware oder fremde Daten unterbindet es.

Das Betriebssystem hat die Aufgaben der Komplexitätsreduktion, Ressourcenverwaltung und Zugriffskontrolle und fungiert als Abstraktionsschicht zwischen Hardware und Anwendungsprogrammen.

Bestandteile des Betriebssystems: Zum Betriebssystem zählen Programme, die im sog. Systemmodus (Kernel Mode) laufen und daher privilegiert sind (detaillierte Behandlung später). Dazu zählen unter anderem Gerätetreiber, Prozessmanager, Fenstermanager und viele mehr. Benutzerprogramme, die im nicht-privilegierten Nutzermodus (User Mode) laufen, sind hingegen kein Bestandteil des Betriebssystems (z.B. Editoren, Compiler, HTTP-Server, Web-Browser, Office-Anwendungen).

Systemaufrufe: Die Schnittstelle zwischen Anwendungsprogrammen und Betriebssystem wird durch Systemaufrufe definiert. Ein Anwendungsprogramm, das also (da es im Nutzermodus läuft) nicht direkt auf eine Ressource zugreifen darf, tätigt dazu einen Systemaufruf mit den entsprechenden Parametern.

In ihren konkreten Architekturen unterscheiden sich verschiedene Betriebssysteme z.T. sehr grundlegend. Allerdings gibt es gemeinsame Basiskonzepte, die in nahezu jedem Betriebssystem zu finden sind. Der Schlüsselbegriff in allen modernen Betriebssystemen ist der Prozess.

1.3 Geschichte der Betriebssysteme

Die Geschichte der Betriebssysteme begann viel später als die der Computer: Schon 1832 entwickelte Charles Babbage (1792 bis 1871) seine mechanische “Difference Engine”, nur fünf Jahre später folgte seine “Analytical Engine”. Beide wurden von Ada Lovelace programmiert und besaßen kein Betriebssystem.

Basierend auf diesen frühen Erfindungen entstanden bis heute vier Generationen von Computern, die im Folgenden genauer betrachtet werden sollen.

1.3.1 1. Generation: 1945 bis 1955 (Röhren und Klinkenfelder)

- Etwa gegen Ende des Zweiten Weltkriegs entstanden die ersten Rechner. Größen dieser Zeit sind Konrad Zuse (1910 bis 1995), der 1941 seinen berühmten Z3 vorstellte, oder auch John v. Neumann (1903 bis 1957), nach dem das noch heute übliche Modell der Rechnerarchitektur benannt ist.
- Die Computer dieser Zeit waren riesige Apparate mit zehntausenden von Röhren und dementsprechend vielen Ausfällen. Taktzeiten wurden in Sekunden angegeben.
- Programme wurden über Klinkenfelder gesteckt oder in Maschinencode eingegeben.
- Programmiersprachen, Assemblersprachen und Betriebssysteme waren unbekannt.
- Anfang der 50er Jahre wurde das Stecken der Klinkenfelder durch Lochkarten abgelöst.

1.3.2 2. Generation: 1955 bis 1965 (Transistoren und Stapelsysteme)

- Die Einführung von Transistoren in der Mitte der 50er Jahre erhöhte die Zuverlässigkeit der Systeme um ein Vielfaches, die **Mainframe** genannten Systeme waren aber extrem teuer (eine Anlage kostete mehrere Millionen Dollar).
- Programme wurden in Lochkarten gestanzt und durch Bedienpersonal eingelegt. Erst nach Abschluss der Berechnung (und Ausdruck des Ergebnisses) konnte vom Bedienpersonal das nächste Programm eingelegt werden, was zu großen Leerlaufzeiten führte.
- Dieser Mangel führte zur Entwicklung der **Stapelverarbeitungssysteme (Batchsysteme) (siehe Abbildung 1.2)**:
  Aufträge wurden gesammelt und auf einfachen Rechnern auf ein Magnetband über-

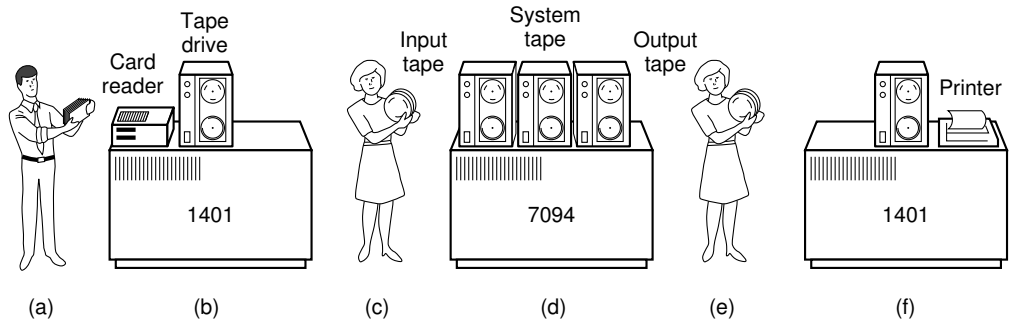

Abbildung 1.2: Erste Stapelverarbeitungssysteme

spielt. Der Mainframe las die einzelnen Jobs (mit Hilfe eines rudimentären Betriebssystems) von diesem Band und speicherte die Ergebnisse auf einem anderen. Das Ausdrucken der Ergebnisse erfolgte wieder an einfachen Rechnern.

– Aufbau eines Programmstapels:
  - Ein Auftrag begann mit einer $JOB-Karte, auf der die maximale Laufzeit in Minuten, die Abrechnungsnummer und der Name des Programmierers codiert waren.
  - Danach folgte eine $FORTRAN-Karte, die das Betriebssystem beauftragte, den FORTRAN-Compiler vom Band zu laden.
  - Darauf folgten das zu übersetzende Programm und eine $LOAD-Karte, die das Betriebssystem veranlasste, das – in übersetzter Form auf ein Hilfsband geschriebene – Programm zu laden.
  - Die folgende $RUN-Karte veranlasste das Betriebssystem, das Programm mit nachfolgenden Daten zu bearbeiten.
  - Den Abschluss bildete eine $END-Karte, die die Programmbearbeitung beendete.

– Erste Betriebssysteme:
  FMS (Fortran Monitor System)
  IBSYS (IBM Betriebssystem für die 7094)

– Das Hauptproblem dieser Betriebssystemgeneration lag in der Interaktion: Jede I/O-Operation unterbrach die CPU.

1.3.3 3. Generation: 1965 bis 1980 (Integrierte Bauelemente und Multiprogramming)

– Anfang der 60er Jahre hatten sich zwei Produktlinien entwickelt:
  - Großrechner für wissenschaftlich/technischen Bereich
  - Rechner für den kommerziellen Bereich

– Da die Inkompatibilität dieser beiden Linien sehr hohe Kosten verursachte, schuf IBM eine Serie von Rechnern, das System /360, das sowohl für den wissenschaftlichen als auch für den kommerziellen Bereich konzipiert wurde.

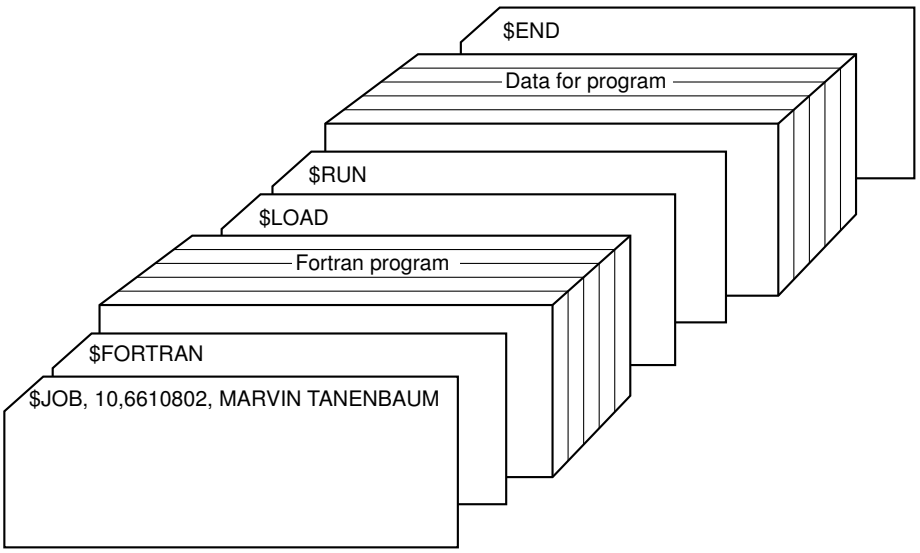

Abbildung 1.3: Erste Betriebssysteme: Kartenstapel zur Ausführung eines Jobs

- Der /360 war die erste größere Computerfamilie, die integrierte Bauelemente (integrated circuits, ICs) verwendete und so ein besseres Preis-/Leistungsverhältnis erreichte.
- Das Betriebssystem des /360 war sehr kompliziert (mehrere Millionen Assembler-Zeilen von tausenden Programmierern), was zu vielen Fehlern führte.
- Fortschritte gegenüber der zweiten Generation:
  1. **Spooling** (Simultaneous Peripheral Operation On Line):
     Jobs wurden auf Vorrat von Karten eingelesen und auf einer Festplatte gespeichert. Terminierte ein Auftrag, so konnte das Betriebssystem einen neuen Auftrag von der Platte in einen jetzt leeren Speicherbereich laden und ihn dort bearbeiten.
  2. **Mehrprogrammbetrieb** (Multiprogramming):
     Bislang: Bei Zugriffen auf Bandgeräte oder E/A-Geräte blieb die CPU untätig, was bei vielen kleinen Jobs die Auslastung der CPU stark verschlechterte.
     Nun: Hauptspeicheraufteilung mit je einem Auftrag in jedem Speicherabschnitt (Space Multiplexing). Wartete der aktive Auftrag auf eine I/O-Operation, so konnte ein anderer Auftrag ausgeführt werden.
- Die ersten Systeme mit Mehrprogrammbetrieb hatten jedoch einen gravierenden Mangel: Ein kleiner Fehler kostete viel Rechenzeit, da der Programmierer während der Ausführung keinen Zugriff auf das Programm hatte uns es insbesondere nicht abbrechen konnte. Ein **Dialogbetrieb** war dringend nötig.
- 1962 wurde am MIT das erste **Timesharing**-System (Compatible Time Sharing System, **CTSS**) entwickelt. Timesharing ist eine Variante des Mehrprogrammbetriebs, bei der jeder Benutzer über ein Terminal direkt auf den Rechner Zugriff hat.
- Die Entwickler von CTSS entwickelten 1965 **MULTICS** (Multiplexed Information and Computing Service), ein Timesharing-System, dessen Grundidee vergleichbar ist mit der

Stromversorgung: bei Bedarf steckt man einen Stecker in die Dose und nimmt sich die Energie/Kapazität, die man braucht. Trotz seiner großen wissenschaftlichen Bedeutung wurde MULTICS kein großer wirtschaftlicher Erfolg, nur in wenigen Firmen wurde es tatsächlich eingesetzt.

– Einer der Programmierer von MULTICS, Ken Thompson, entwickelte eine vereinfachte Einbenutzerversion namens **UNICS** (Uniplexed Information and Computing Service).

– Dennis Ritchie implementierte dieses Einbenutzerbetriebssystem in C neu. **UNIX**, das Ergebnis seiner Arbeit, wurde kostenlos an Universitäten lizenziert und kam so schnell zu großer Verbreitung auf einer Vielzahl von Computersystemen.

1.3.4 4. Generation: seit 1980 (PCs)

– Die Entwicklung von **LSI** (Large Scale Integration) Schaltkreisen (Bauelemente mit Tausenden von Transistoren auf 1 cm^2 Silizium) machte eine hohe Rechenleistung zu vergleichsweise geringen Kosten verfügbar und läutete damit das PC-Zeitalter ein. Als Betriebssystem für PCs setzten sich **MS-DOS** (Microsoft Disk Operating System) und (bei den größeren Systemen) UNIX durch.

– Die Erfindung der **GUI** (Graphical User Interface) schließlich erschloss dem PC (allen voran dem Apple Macintosh) eine völlig neue Käuferschicht: Anwender, die ein benutzerfreundliches System wünschen und von Hardware nichts verstehen (wollen). Beispiele für aktuelle Betriebssysteme dieser "nächsten Generation" sind z.B. Microsoft Windows XP, Mac OS X und Linux mit KDE.

– Mitte der 80er Jahre verbreiteten sich Netzwerke aus PCs immer weiter. Betriebssysteme für diese Rechner lassen sich in zwei Kategorien unterteilen:

  - Bei einem **Netzwerk-Betriebssystem** (Network Operating System) weiß der Benutzer um die Existenz mehrerer Rechner und kann sich gezielt auf fremden Rechnern anmelden (etwa um Daten zu kopieren). Dabei läuft auf jedem Rechner ein eigenes Betriebssystem (meist mit eigener Benutzerverwaltung).
  - Ein **verteiltes Betriebssystem** (Distributed Operating System) hingegen soll dem Benutzer wie ein traditionelles Einprozessorsystem erscheinen, obwohl es auf mehreren (meist räumlich getrennten) Rechnern abläuft. In einem echten verteilten System wissen Nutzer nicht, wo Programme ablaufen und wo Daten liegen – dies wird vom Betriebssystem verwaltet und bleibt dem Nutzer verborgen.

1.4 Arten von Betriebssystemen

Im Laufe der Entwicklung der Betriebssysteme haben sich verschiedene Typen herausgebildet, die hier im Folgenden kurz vorgestellt werden sollen. Auf Besonderheiten einiger der Typen werden wir später noch eingehen.

Mainframe-Betriebssysteme: Sie sind optimiert auf eine Vielzahl gleichzeitig ablaufender Prozesse mit zahlreichen hochperformanten I/O-Operationen auf einem sehr großen Hintergrundspeicher (z.B. große Webserver). Ein Vertreter dieser Betriebssystem-Gattung ist OS/390, ein Nachfolger von OS/360.

Server-Betriebssysteme: Beispiele hierfür sind Unix oder Windows 2000, die für den Bereich zwischen kleinen Webservern und Workstations ausgelegt sind. Sie bieten z.B. Programm- oder Dateifreigaben.

Multiprozessor-Betriebssystem: Einige moderne Computersysteme beinhalten mehr als einen Prozessor und benötigen daher ein Multiprozessor-Betriebssystem, das die Verteilung der Aufgaben auf die Prozessoren vornimmt.

PC-Betriebssysteme: Gängige Vertreter sind Windows XP, Mac OS X oder Linux und laufen auf dem Großteil der heutigen PCs. Sie sind vor allem darauf ausgelegt, eine möglichst generische Plattform für eine Vielzahl von Anwendungen und Anforderungen anzubieten.

Echtzeit-Betriebssysteme: Sie werden z.B. zur Steuerung von Maschinen verwendet. Bei Echtzeit-Betriebssystemen liegt der Schwerpunkt auf geringen Antwortzeiten. Das bedeutet: Die Reaktion des Betriebssystems auf eine Steuerungsanweisung muss "auf den Punkt" erfolgen. Je nachdem, ob hierbei eine gewisse Toleranz erlaubt ist oder nicht, spricht man von weichen bzw. harten Echtzeitsystemen.

Embedded Betriebssysteme: Sie kommen in PDAs und vergleichbaren mobilen Endgeräten zum Einsatz, wobei die geringe Größe der Geräte und die damit verbundene oft geringere Rechenleistung und Speicherausstattung eine besondere Herausforderung darstellen. Effizientes Energiemanagement ist entscheidend, gleichzeitig aber muss eine Vielzahl von Kommunikationsschnittstellen unterstützt werden, wie z.B. der Aufbau oder das Einloggen in ein Ad-Hoc-Piconetz (Bluetooth) oder die Einwahl in ein Mobilfunknetz (GSM, UMTS).

Betriebssysteme für Chipkarten: Diese Mini-Betriebssysteme laufen auf Smart Cards, wie sie z.B. im Zusammenhang mit der RFID-Technologie eingesetzt werden.

Teil II

Prozesse

2

Programme und Unterprogramme

- Maschinenprogramme
- Unterprogramme und Prozeduren
- Programmschema für Unterprogrammaufrufe
- Nested Procedures und rekursive Prozeduraufrufe

Inhaltsangabe

2.1 Vom Programm zum Maschinenprogramm

Ausgangspunkt: Ein in Ausführung befindliches Programm ist eine Folge (Sequenz) von Befehlen. Die Befehle werden nacheinander vom Prozessor ausgeführt.

Wurde ein Programm in einer höheren Programmiersprache (z.B. Java, C, Pascal, SML, Prolog) formuliert, muss es natürlich zunächst in eine Befehlsfolge transformiert werden, die von der CPU auch "verstanden" wird. Dieser Vorgang wird Übersetzung genannt und vom Übersetzer (Compiler) ausgeführt. Das Hochsprachen-Programm dient also als Spezifikation für das gewünschte Maschinenprogramm.

Was bei der Übersetzung genau passiert, hängt von dem Programmierparadigma der Hochsprache (und natürlich vom Befehlssatz der Ziel-Maschine/CPU) ab. Auf die genauen Techniken wird an dieser Stelle nicht im Detail eingegangen. Wenn Sie aber schon erste Erfahrungen in der Assembler-Programmierung gesammelt haben (z.B. durch SPIM), haben Sie dabei intuitiv auch bereits einfache Übersetzungstechniken angewandt, wie beispielsweise die Auflösung von Schleifen oder If-Klauseln. Denn in einer Maschinensprache gibt es solche imperativen Konstrukte nicht. Sie müssen zum Beispiel durch bedingte Sprünge realisiert werden.

Soll das so entstandene Maschinenprogramm nun ausgeführt werden, wird ihm vom Betriebssystem ein zusammenhängender Speicherbereich zugewiesen, der zunächst einmal aus genau so vielen Speicherzellen besteht wie das Programm Befehle enthält. Jeder Befehl wird in eine Speicherzelle kopiert, der Prozessor beginnt bei der ersten Speicherzelle mit der Ausführung des darin kodierten Befehls.

Programme in höheren Programmiersprachen werden in Maschinenprogramme übersetzt. Ein Maschinenprogramm ist eine Folge von Befehlen, die von einer bestimmten Maschine (CPU) direkt verarbeitet werden können.

2.2 Unterprogramme und Prozeduren

Problemstellung: Eine Folge von Befehlen wird mehrmals während der Ausführung eines Programms benötigt.

Offenes Unterprogramm: Der entsprechende Programmtext wird an den erforderlichen Stellen ins Hauptprogramm hineinkopiert. Diese Technik wird auch als Makroaufruf bezeichnet. Sie ist nur bei kleinen Unterprogrammen effizient, wie z.B. bei einfachen arithmetischen Operationen (x^2, $|x|$). Bei langen Unterprogrammen ist sie ungeeignet, da sie Speicherplatz verschwendet und nachträgliche Modifikationen am Unterprogramm an jedem Vorkommen vorgenommen werden müssen. Außerdem ist Vorsicht geboten, wenn das offene Unterprogramm Befehle enthält, die Speicheradressen als Parameter haben (z.B. Sprungbefehle). Diese Adressen können bei jedem Vorkommen des Unterprogramms verschieden sein und müssen beim Kopieren entsprechend angepasst werden.

Geschlossenes Unterprogramm (Prozedur): Das Programmstück wird über seine Anfangsadresse (die Adresse der Speicherzelle, mit der es beginnt) angesprungen. Nach der Aus-

führung des Unterprogramms erfolgt ein Rücksprung zu der Adresse, die unmittelbar vor dem Unterprogrammaufruf als nächstes dran gewesen wäre (Rückkehradresse). Insbesondere werden Prozeduren und Funktionen höherer Programmiersprachen als geschlossene Unterprogramme realisiert. Wir unterscheiden:

- Announcement: Prozedur ohne Ergebnisparameter (in Java z.B. gekennzeichnet durch leeren Rückgabetyp `void`).
- Invocation: Prozedur mit Ergebnisparameter

Unabhängig von obigen Unterscheidungen heißt ein Unterprogramm **rekursiv**, wenn in dem Unterprogramm selbst ein Aufruf dieses Unterprogramms erfolgt (ggf. mit modifizierten Parametern). Beispiel: $n! = n \cdot (n-1)!$ für $n > 0$; $n! = 1$ für $n = 0$.

Wir betrachten Prozeduren, also geschlossene Unterprogramme, näher:

Informationen: Welche Informationen werden zur Realisierung einer Prozedur genau benötigt?

- Anfangsadresse des Unterprogramms: Diese Adresse wird dem Maschinenbefehl `CALL` explizit übergeben. Beispiel: `CALL 0x1802C0D0` bewirkt einen Sprung zum Unterprogramm, das an der Adresse `0x1802C0D0` beginnt.
- Rücksprungadresse zum Hauptprogramm: Der Befehl `RET` bewirkt den Rücksprung zum Aufrufer; hier wird die Rückkehradresse nicht explizit angegeben, sondern entweder aus dem Register `RA` oder aus dem Stack geholt.
- Aufrufparameter: Sie dienen dem Unterprogramm als Eingabe(n).
- Rückgabewert(e): Hat das Unterprogramm ein oder mehrere Berechnungsergebnisse ermittelt, werden diese dem Aufrufer mitgeteilt.

Kommunikation: Wie tauschen Hauptprogramm (Aufrufer, Caller) und Unterprogramm (Callee) Informationen, Parameter und Ergebnisse aus?

- Stack: Eine prinzipiell beliebige Anzahl von Parametern (nur beschränkt durch die Größe des Speichers) lässt sich über den Stack (Kellerspeicher) übermitteln. Im Fall von Aufrufparametern werden diese in umgekehrter Reihenfolge vom Caller auf den Stack geladen (`PUSH`), sodass der Callee diese mit dem `POP`-Befehl in korrekter Reihenfolge erhält. Analog für Rückgabewerte.
- Spezielle Register: Eine schnellere Möglichkeit besteht darin, eine geringe Anzahl von Parametern (zum Beispiel die ersten vier) über bestimmte CPU-Register zu übergeben. Register stehen in der Speicherhierarchie (vgl. “Rechnerarchitekturen”) ganz oben und haben geringste Zugriffszeiten. Es ist daher sinnvoll, diese Möglichkeit auszunutzen.

Haupt- und Unterprogramm tauschen Adressen, Parameter und Rückgabewerte über einen gemeinsam genutzten Kellerspeicher oder über vorher verabredete Register aus.

2.2.1 Die Befehle CALL und RET

Zur Erinnerung: Ein Sprung zu einem Befehl wird technisch so realisiert: Das Statusregister PC (Programm Counter, Programmzähler) der CPU enthält stets die Adresse der Speicherzelle des nächsten auszuführenden Befehls. Ein Sprungbefehl (`JMP addr`) überschreibt diesen Wert durch eine neue Adresse.

Die Definition des Befehls JMP sieht also so aus:

```
COMMAND JMP addr
BEGIN
  PC := addr;
END
```

Der Befehl CALL unterscheidet sich davon durch die zusätzliche Sicherung der Rücksprungadresse. Hier gibt es zwei Möglichkeiten:

1. Die Rückkehradresse wird in einem speziellen Register (RA) gesichert. Als Befehlsdefinition ergibt sich:

   ```
   COMMAND CALL addr
   BEGIN
     RA := PC + 1;
     PC := addr;
   END
   ```

2. Die Rückkehradresse wird auf dem Stack gespeichert. Zwar sind Stack-Zugriffe nicht so schnell wie Registerzugriffe (entsprechend länger dauert die Befehlsausführung), dafür lassen sich rekursive Unterprogrammaufrufe und Nested Procedures (siehe später) leichter realisieren. Die Befehlsdefinition lautet in diesem Fall:

   ```
   COMMAND CALL addr
   BEGIN
     PUSH (PC + 1);
     PC := addr;
   END
   ```

Entsprechend ergeben sich zwei Varianten für die Definition des RET-Befehls:

1. Die Rückkehradresse steht im Register RA:

   ```
   COMMAND RET
   BEGIN
     PC := RA;
   END
   ```

2. Die Rückkehradresse befindet sich auf dem Stack:

   ```
   COMMAND RET
   BEGIN
     PC := POP;
   END
   ```

2.2.2 Schema für Unterprogrammaufrufe

Wir wollen ein Beispiel betrachten, bei dem die Rücksprungadressen auf dem Stack abgelegt werden. Beim Rücksprung ist die aktuelle Rückkehradresse immer das oberste Kellerelement. Ferner betrachten wir hier auch den Fall "genesteter" Unterprogramme.

Nested Procedure: Ein Unterprogramm ruft selbst ein anderes Unterprogramm auf. (Dieses könnte ggf. wiederum ein anderes Unterprogramm aufrufen. So entsteht eine Kette von genesteten Unterprogrammaufrufen.) Unterschied zu rekursiven Aufrufen: Ein rekursives Unterprogramm ruft **sich selbst** auf.

Beispiel 2.1. *Im Beispiel sollen Parameter für den Aufruf des Unterprogramms und ggf. Ergebnisse in Registern – also nicht auf dem Stack – abgelegt werden. Die Sicherung der Registerinhalte wird nicht explizit betrachtet. Die Programmadressen sind im Folgenden für das Beispiel beliebig gewählt.*

Hauptprogramm:

```
4000    ...
 .
 .
4100    CALL 4500
4101    ...
 .
 .
```

Prozedur 1:

```
4500    ...
 .
 .
4600    CALL 4800
4601    ...
 .
 .
4650    CALL 4800
4651    ...
 .
 .
4700    RET
```

Prozedur 2:

```
4800    ...
 .
 .
4890    RET
```

Die Abarbeitung, beginnend mit dem Befehl in der Speicherzelle 4100, lässt sich nun schematisch wie folgt darstellen:

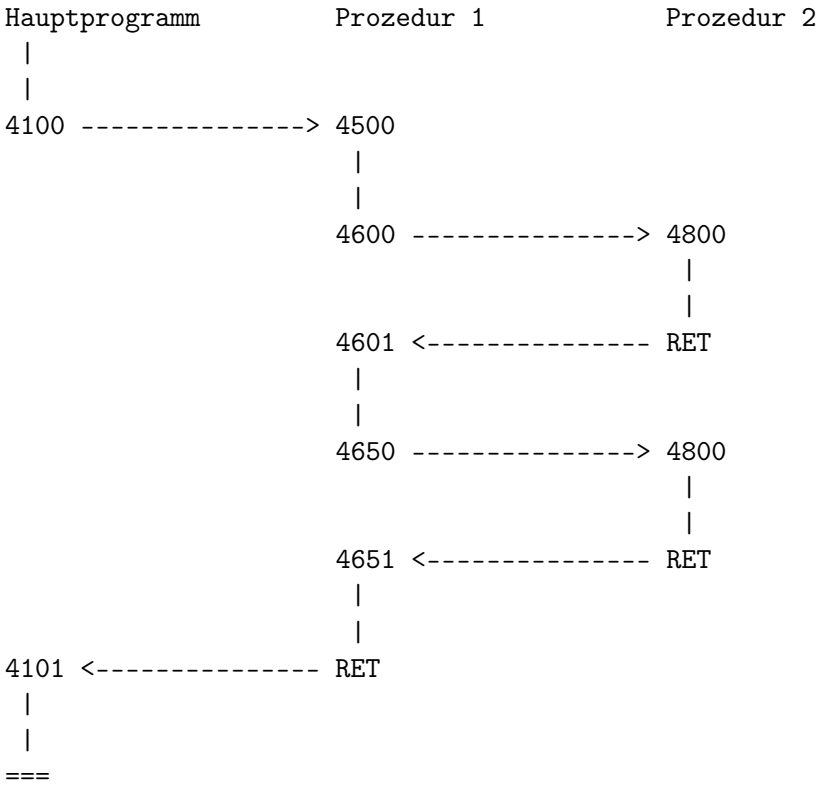

Der Kellerspeicher sieht zu den verschiedenen Zeitpunkten der Abarbeitung so aus:

– Unmittelbar vor der Ausführung des Befehls an der Adresse 4100 ist der Keller entweder leer oder enthält Daten, die für unsere Betrachtungen nicht relevant sind. Der Stack-Pointer (SP) zeigt stets auf die oberste belegte Kellerzelle.

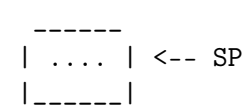

– Unmittelbar nach der Ausführung des CALL-Befehls an der Adresse 4100 enthält der Keller die Rückkehradresse 4101, also die Adresse, an der das Hauptprogramm nach dem Unterprogrammaufruf fortgesetzt wird.

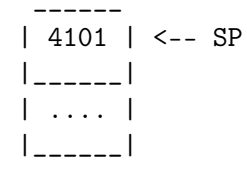

– Entsprechend ergibt sich nach der Ausführung des Befehls an der Adresse 4600:

```
 ______
| 4601 | <-- SP
|______|
| 4101 |
|______|
| .... |
|______|
```

– Nach dem ersten RET:

```
 ______
| 4101 | <-- SP
|______|
| .... |
|______|
```

– Nach 4650:

```
 ______
| 4651 | <-- SP
|______|
| 4101 |
|______|
| .... |
|______|
```

– Nach dem zweiten RET:

```
 ______
| 4101 | <-- SP
|______|
| .... |
|______|
```

– Nach dem dritten RET:

```
 ______
| .... | <-- SP
|______|
```

Nach n `CALL`-Befehlen und n Rücksprüngen (`RET`) hat der Keller die gleiche Belegung wie zu Beginn.

2.2.3 Module

Module: Unter Modulen versteht man allgemeine Komponenten, die anderen Komponenten einen Dienst bereitstellen. Beispiele für Module sind:

- Unterprogramme (Prozeduren, Funktionen)
- Komponenten des Betriebssystems, sowie das Betriebssystem als Ganzes
- Benutzerprogramme
- Prozesse

In der Regel existieren viele Module, die vom Rechensystem auch geeignet verwaltet werden müssen. Dabei kann zu einem Zeitpunkt nur ein Modul dem Rechnerkern zugeordnet sein. Dieses Modul ist aktiv. Alle anderen, nicht zugeordneten Module sind inaktiv. Sie müssen vollständig beschrieben sein, sodass sie jederzeit wieder aktiviert werden können. Das bedeutet, dass die Zustände von Modulen zu speichern und zu verwalten sind.

Ein Zustand ist insb. charakterisiert durch

- den Rechnerkernzustand, d.h. die aktuellen CPU-Registerbelegungen,
- die Speicherabbildungstabellen und
- Programmcode und Daten.

Bezüglich Programm- und Speicherräumen müssen die einzelnen Module von einander isoliert werden (d.h. keine Teilräume gemeinsam nutzen). Eine Aktivierung eines Moduls kann beispielsweise erfolgen durch

- Unterprogramm-/Prozeduraufrufe (in diesem Kapitel betrachtet)
- Systemaufrufe
- Prozesswechsel

Server und Client: In Verteilten Systemen stellen Module auch über Rechnergrenzen hinweg Dienste bereit. Die Komponente, die einen Dienst anbietet, heißt Server (Diensterbringer). Die Komponente, die einen Dienst anfordert und nutzt, wird Client (Dienstnutzer) genannt.

Dienst: Ein Dienst ist eine Funktion, die von einem Objekt (hier: einem Modul) an einer bestimmten Schnittstelle angeboten wird.

Entfernte Prozeduraufrufe: Wird ein Modul auf einem Rechner angeboten und von einem anderen (entfernten) Rechner angefordert, so hilft das Konzept des lokalen Unterprogrammaufrufs nicht weiter. Denn zwei entfernte Computer verfügen nicht über einen einzigen, gemeinsamen Speicher. Man benötigt also Techniken für entfernte Prozeduraufrufe (Remote Procedure Calls). Diese sind in einer Verteilungsplattform (Verteiltes Betriebssystem) enthalten, werden an dieser Stelle aber nicht im Detail behandelt.

2.3 Realisierung eines Unterprogrammaufrufs

In den letzten Abschnitten wurden die Konzepte und Techniken betrachtet, die im Zusammenhang mit einer systemnahen Betrachtung von Unterprogrammaufrufen wichtig sind. Nun wollen wir uns ansehen, wie Unterprogrammaufrufe auf einer Modell-Maschine, der wir den Namen MI geben, realisiert werden. Wir werden das CALL/RET-Schema entsprechend erweitern. Vorher aber müssen wir die Modell-Maschine MI spezifizieren.

Die Modell-Maschine MI: MI verfügt über

- die Register `PC` (Programmzähler), `SP` (Stack-Pointer) und `R0` bis `R14`, wobei `R12` und `R13` nicht frei genutzt werden dürfen, sondern spezielle Bedeutungen haben:
  - `R12` enthält die Ablageadresse des ersten Aufrufparameters (p_1).
  - `R13` enthält die Basisadresse des lokalen Datenraums des Unterprogramms.
- einen Kellerspeicher, von dem angenommen werden kann, dass er für das betrachtete Szenario über ausreichend Speicherplatz verfügt. Wichtig ist allerdings, dass die Adressen der Kellerzellen bei wachsendem Keller kleiner werden.

Die Register und Speicherzellen sind einheitlich 4 Bytes (32 Bits) breit. Das bedeutet, dass alle Maschinenbefehle einschließlich ihrer aktuellen Parameter zu 32-Bit-Wörtern kodiert werden. Zur Größe des Adressraums werden keine Annahmen gemacht. Adressen (von Speicherzellen) werden als dezimale numerische Werte angegeben (z.B. 4100).

Vorbemerkung: Der `CALL`-Befehl übernimmt lediglich die Sicherung der Rücksprungadresse und die Durchführung des eigentlichen Sprungs. Bei einem allgemeinen Unterprogrammaufruf ist aber auch dafür zu sorgen, dass dem Unterprogramm ein **lokaler Datenraum** für Daten innerhalb des Prozedurablaufs zur Verfügung steht. Ferner wird Platz für die "Rettung" der Registerbelegungen der CPU vor dem Unterprogrammaufruf benötigt (da das Unterprogramm diese Register ggf. überschreibt), sowie für die Speicherung der Aufrufparameter (p_1 bis p_n), die an das Unterprogramm übergeben werden.

Bei den folgenden Betrachtungen gehen wir davon aus, dass

- die aktuellen Parameter p_1 bis p_n des Unterprogrammaufrufs in umgekehrter Reihenfolge auf den Keller gelegt werden.
- bei einer Funktion der Rückgabewert als fiktiver Parameter p_{n+1} ebenfalls auf dem Keller liegt bzw. Platz dafür reserviert ist.
- ein Unterprogramm die MI-Register nutzen kann und daher vor ihrer Benutzung sichern und vor dem Rücksprung zum Aufrufer wiederherstellen (mit den alten Werten belegen) muss.

Die Register der Maschine MI sind Callee-saved, d.h. das aufgerufene Unterprogramm trägt die Verantwortung dafür, dass der Kontext des Aufrufers (Caller) nach dem Rücksprung unverändert dem Kontext vor dem Unterprogrammaufruf entspricht.

Der Bereich der lokalen Variablen des Unterprogramms im Keller wird **lokaler Datenraum** des Unterprogramms genannt.

Befehle von MI: Zur Spezifikation einer (Modell-)Maschine gehört auch die Definition der Maschinensprache, die diese Maschine "versteht" – also die Angabe der Befehle. Zur Erinnerung: Die CPU (also der Maschinenkern) erhält die Befehle in Form von Bitcodes über den Befehlsbus. Wir setzen voraus, dass die Umsetzung eines Maschinenbefehls (eigentlich: Assembler-Befehl) wie z.B. `CALL 4100` in eine oder mehrere 32-Bitfolge(n) (z.B. `01101010 10010011 11110000 00000000`) durch den Assembler kein Problem darstellt. Die MI-Befehle sind (ohne formale Definition):

- `PUSH val`: legt den Wert `val` auf den Keller (der Stack-Pointer wird implizit dekrementiert)
- `PUSH reg`: legt den Inhalt des Registers `reg` auf den Keller
- `PUSHR`: sichert den gesamten CPU-Register-Kontext, d.h. die Inhalte der Register R0 bis R14 werden nacheinander auf den Keller gelegt (der dadurch um 15 Plätze = 60 Bytes wächst)
- `POP reg`: legt den Inhalt der obersten Kellerzelle ins Register `reg` (der Stack-Pointer wird implizit inkrementiert)
- `POPR`: stellt den gesamten Register-Kontext wieder her, d.h. die Inhalte der obersten 15 Kellerzellen werden nacheinander in die Register R14 bis R0 (zurück)kopiert
- `MOVE addr, reg`: kopiert die Adresse `addr` ins Register `reg`
- `MOVE reg1, reg2`: kopiert den Inhalt (Wert) von Register `reg1` ins Register `reg2`
- `CALL addr`: Sprung zu `addr` und Sicherung der Rücksprungadresse auf dem Keller (siehe oben)
- `RET`: Rücksprung zum Aufrufer
- weitere grundlegende Befehle, wie (bedingte) Sprungbefehle, logische und arithmetische Operationen (z.B. `JMP`, `ROL`, `ADD` usw.)

Damit sieht die Belegung des Kellerspeichers und der Register R12 und R13 nach dem Aufruf eines Unterprogramms allgemein wie folgt aus:

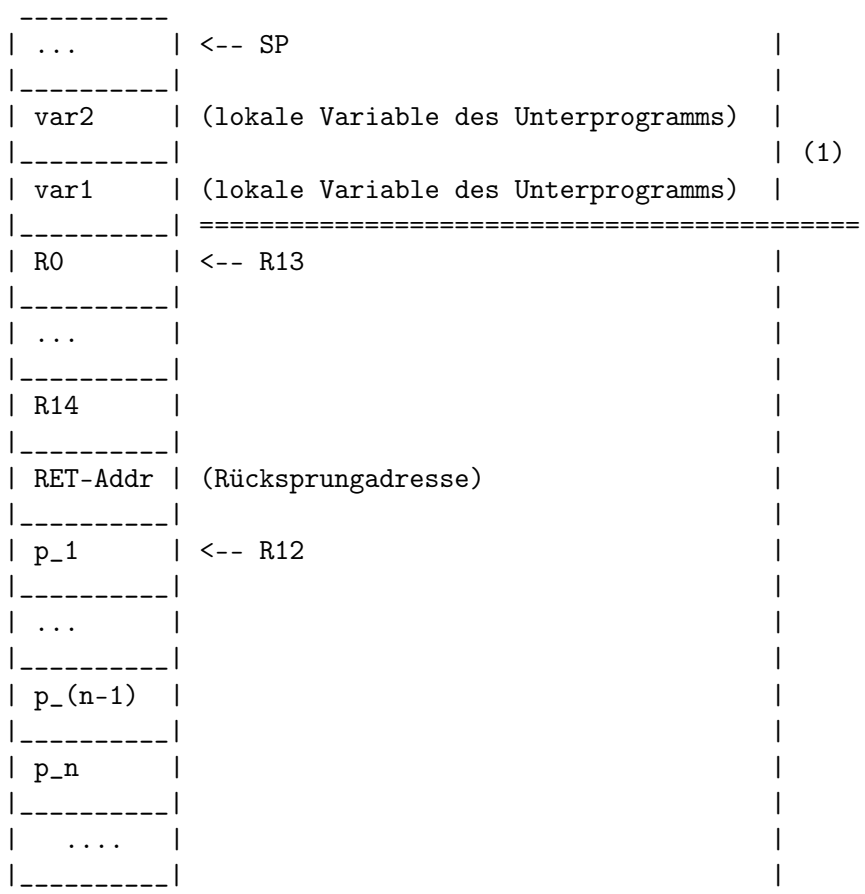

(1): lokaler Datenraum des Unterprogramms

Als erweitertes Unterprogramm-Schema ergibt sich:

Hauptprogramm:

```
4000    ...
 .
 .
40??    PUSH p_n bzw. p_(n+1)
 .
 .
4098    PUSH p_2
4099    PUSH p_1
4100    CALL 4500
4101    POP p_1
4102    POP p_2
 .
 .
```

```
41??    POP p_n bzw. p_(n+1)
 .
 .
```

Prozedur:

```
4500    PUSHR                   # (1)
4501    MOVE 64+SP, R12         # (2)
4502    MOVE SP, R13            # (3)
 .
 .
????    MOVE R13, SP            # (4)
        POPR                    # (5)
        RET                     # (6)
 .
 .
```

Kommentare dazu:

- (1) sichert die Register `R0` bis `R14` auf dem Stack, der dadurch um 15 Speicherzellen wächst (beachte: die Adressen fallen dabei).
- (2) addiert zum Wert des Stack-Pointers 64 Bytes; man erhält die Adresse der Speicherzelle, die 16 (= 64:4 wegen 4 Bytes Wortgröße) Zellen unterhalb der obersten Kellerzelle liegt. Die Zahl 16 setzt sich zusammen aus 15 Zellen für die Register und einer Zelle für die Zelle mit der Rücksprungadresse. Dies ist die **Ablageadresse**, die in `R12` gespeichert wird.
- (3) sichert die **Basisadresse** des lokalen Datenraums in `R13`.
- (4) setzt den Stack-Pointer auf die "alte" Basisadresse zurück. Bei einer "sauberen" Programmierung wurde der Keller vollständig abgeräumt, und der Stack-Pointer enthält bereits vor Ausführung dieses Befehls die korrekte Adresse.
- (5) versetzt alle Register wieder in den Zustand, den sie zum Zeitpunkt der Ausführung des `PUSHR`-Befehls hatten.
- (6) realisiert den Rücksprung.

Prolog und Epilog des Unterprogramms: Die Schritte (1) bis (3) werden als Prolog, die Schritte (4) bis (6) als Epilog des Callees bezeichnet.

Abschließende Bemerkungen:

- Falls es sich um eine Prozedur mit Parametern handelt, so muss das Hauptprogramm dafür sorgen, dass diese Parameter vor dem Unterprogrammaufruf auf den Stack geschrieben werden und nach dem Rücksprung aus dem Unterprogramm ins Hauptprogramm zunächst wieder vom Stack heruntergenommen werden. Zu beachten: Bei einem Invocation-Aufruf ist der Ort des Ergebnisses im Hauptprogramm zu berücksichtigen (zu kennen und zu nutzen).

– Das Unterprogramm muss jedoch auf diese Parameter zugreifen können. Zu diesem Zweck wird die Ablageadresse (Register R12) genutzt, mit deren Hilfe auf p_1 bis p_n zugegriffen werden kann.

Arten der Parameterübergabe: Die Parameterübergabe vom Hauptprogramm an das Unterprogramm und umgekehrt für das Ergebnis vom Unterprogramm ans Hauptprogramm kann auf zwei Arten erfolgen:

– Call by value (Wertübergabe): Übergabe eines konkreten Wertes (z.B. 7)
– Call by reference (Adressübergabe): Übergabe der Adresse der (ersten) Speicherzelle, an der sich der konkrete Parameter befindet (z.B. bei ASCII-Zeichenketten)

2.4 Rekursive Prozeduraufrufe

Wir wollen abschließend untersuchen, wie sich ein Unterprogramm selbst aufrufen kann.

Beispiel 2.2 (Rekursives Unterprogramm)**.** *Als Beispiel betrachten wir die Fakultät-Berechnung.*

```
PROCEDURE fak (k: INTEGER) RETURNS INTEGER
BEGIN
  IF k=0 THEN RETURN 1
  ELSE RETURN k*fak(k-1)
END
```

Die Berechnung von 3! *ergibt folgende Sprünge:*

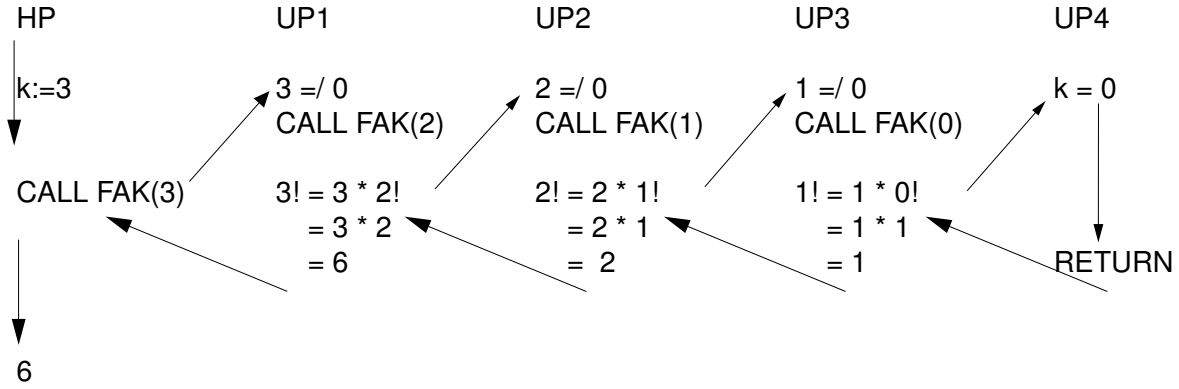

Abbildung 2.1: Sprünge bei rekursiven Unterprogrammaufrufen

Zu beachten: Im i-ten Unterprogramm wird das Ergebnis in den lokalen Datenraum des (i-1)-ten Unterprogramms geschrieben bzw. im ersten Unterprogramm in den lokalen Datenraum des Hauptprogramms. Daher ist es so wichtig, erst Speicherplatz für ein Ergebnis einzurichten und dann zu springen.

3

Prozesse

- Konzept der Prozesse
- Prozessbeschreibung
- Prozesskontrolle
- Unterbrechungen

Inhaltsangabe

3.1 Das Prozess-Konzept

3.1.1 Grundlagen von Prozessen

Moderne Computer können scheinbar mehrere "Dinge" gleichzeitig tun. Aber: Im Vergleich zu Berechnungen durch den Prozessor sind Operationen auf E/A-Geräten oft erheblich langsamer (Vgl. Von-Neumann-Flaschenhals). Es sollte vermieden werden, dass die CPU beim Warten auf das Ende von E/A-Operationen still steht. Das zentrale Konzept eines Betriebssystems in diesem Zusammenhang ist der Prozess.

Prozess: Ein Prozess ist ein in Ausführung befindliches (nicht zwingend aktives) Maschinenprogramm. Mit anderen Worten: Während ein Maschinenprogramm nur eine Folge von Befehlen ist, so wird dieses Programm zum Prozess, indem es in den Speicher geladen wird, einen eigenen Kontext erhält und gestartet wird (Programmzähler auf Anfangsadresse des Maschinenprogramms setzen). Insbesondere beinhaltet der Prozeß:

- den aktuellen Wert des Programmzählers
- aktuelle Werte der Register und der Variablen

(Prozess-)Kontext: Zum Kontext eines Prozesses gehören alle Informationen, die den aktuellen Ausführungszustand eines Prozesses genau beschreiben. Dazu zählen insb. die CPU-Register-Belegungen und alle Prozess-Status-Informationen. Informell könnte man sagen: Zum Prozess-Kontext gehört alles, was man von einem unterbrochenen Prozess benötigt, um ihn auf **dem selben** Computer später fortzusetzen.

(Prozess-)Image: Als Image eines Prozesses bezeichnet man die Gesamtheit der *physischen* Bestandteile eines Prozesses, also insbesondere seine Befehlsfolge (Trace), aber auch seinen Kontext, lokale und globale Variablen und der Ausführungs-Stack. Informell könnte man sagen: Zum Prozess-Image gehört alles, was man von einem unterbrochenen Prozess benötigen würde, um ihn auf **einen anderen** Computer zu transportieren und dort fortzusetzen.

Uniprogramming: Prozesse werden sequenziell nacheinander, vollständig und ohne Unterbrechung ausgeführt.

Beispiel 3.1 (Ressourcennutzung im Einprogrammbetrieb)**.** *Wir betrachten das Modifizieren eines gespeicherten Datensatzes.*

Lesen eines Datensatzes:	*0.0015 sec.*
Ausführen von 100 Befehlen	*0.0001 sec.*
Schreiben des Datensatzes:	*0.0015 sec.*
	0.0031 sec.

CPU-Auslastung: $\frac{0.0001}{0.0031} = 0.03226 \triangleq 3.2\%$

Problem: Mehr als 96% der Zeit verbringt die CPU in diesem Beispiel damit, auf E/A-Vorgänge (Lesen, Schreiben) zu warten.

Multiprogramming: Der Prozessor wird zwischen mehreren Prozessen hin- und hergeschaltet, wobei jeder Prozess für einige 10 bis 100 Millisekunden ausgeführt, dann unterbrochen und zu einem anderen Prozess gewechselt wird. Dabei führt der Prozessor zu jedem

Zeitpunkt nur einen Prozess aus. Aufgrund der kleinen Zeitfenster (Time Slots) und der hohen Rechengeschwindigkeit scheinen die Prozesse gleichzeitig abzulaufen. Man sagt: Die Prozesse werden pseudo-parallel ausgeführt.

Zu beachten: Bei Multiprogramming können a priori keine Annahmen über den zeitlichen Ablauf eines Prozesses gemacht werden. Denn durch das Hin- und Herschalten zwischen mehreren Prozessen kann sich ein ungleichmäßiger und nicht reproduzierbarer Ablauf ergeben.

Multiprocessoring: Stehen mehrere Prozessoren zur Verfügung, dann können Prozesse auch echt-parallel ausgeführt werden. Da es aber auch in einem Mehrprozessor-System in der Regel weit mehr Prozesse als Prozessoren gibt, wird auf den einzelnen Prozessoren wiederum Multiprogramming (und nicht Uniprogramming) realisiert.

Indem Prozesse, die auf E/A-Operationen warten, unterbrochen werden können, blockieren sie nicht länger die CPU. Damit trägt Multiprogramming dazu bei, die CPU-Auslastung und damit den Durchsatz zu erhöhen.

Beispiel 3.2 (Ressourcennutzung im Mehrprogrammbetrieb)**.** *Gegeben ist ein Rechner mit 256 KBytes Speicher, einer angeschlossenen Platte, einem Terminal (Hardware-Schnittstelle zum Benutzer) und einem Drucker. Betrachtet werden drei Prozesse (Jobs).*

Job	*Charakteristik*	*Dauer*	*benötigter Speicher*	*Platte*	*Terminal*	*Drucker*
1	*CPU-intensiv*	*5'*	*50 KBytes*	*-*	*-*	*-*
2	*E/A-intensiv*	*15'*	*100 KBytes*	*-*	*ja*	*-*
3	*E/A-intensiv*	*10'*	*80 KBytes*	*ja*	*-*	*ja*

Dabei wird für Job 2 und 3 angenommen, dass diese nur minimal den Prozessor beanspruchen. Die CPU-Auslastung liegt für Job 1 bei 75%, für Job 2 und 3 jeweils bei 5%. Werden die Programme sequenziell im Einprogrammbetrieb abgearbeitet, so ergibt sich die in Abbildung 3.1 dargestellte Ressourcenausnutzung.
Alternativ dazu führt die Ausführung im Mehrprogrammbetrieb zur verzahnten Ausführung der drei Jobs, wie in Abbildung 3.2 dargestellt. Dabei verbessert sich die Ressourcennutzung deutlich (Vgl. Abbildung 3.3).
Eine detaillierte Berechnung und Gegenüberstellung der Ressourcennutzung zeigt die folgende Tabelle:

	Uniprogramming	*Multiprogramming*
Prozessorauslastung	*17%*	*33%*
Speichernutzung	*30%*	*67%*
Plattenauslastung	*33%*	*67%*
Druckerauslastung	*33%*	*67%*
Gesamtausführungsdauer	*30'*	*15'*
Durchsatz	*6 Jobs/Std.*	*12 Jobs/Std.*
Mittlere Antwortzeit	*18 min*	*10 min*

Die einzelnen Werte dieser Aufstellung ergeben sich wie folgt:

– *Prozessorauslastung:*

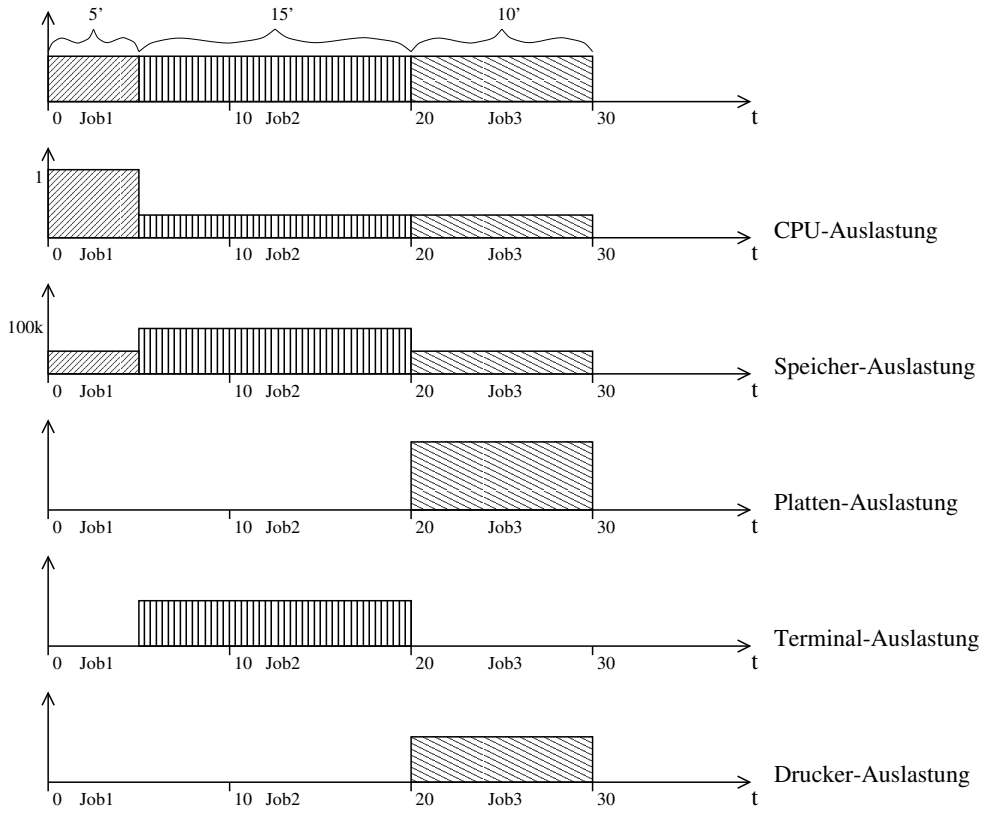

Abbildung 3.1: Ressourcennutzung bei sequenzieller Ausführung von Jobs

	Zeitraum	*Auslastung*	*mittlere Auslastung*
Uniprogramming	*(1–5) 5':*	*75%*	$(5' \cdot 75\% + 25' \cdot 5\%)/30'$
	(6–20) 15':	*5%*	$= (375\% + 125\%)/30$
	(21–30) 10':	*5%*	$= 500\%/30 \approx 17\%$
Multiprogramming	*(1–5) 5':*	$(75 + 5 + 5)\% = 85\%$	$(5' \cdot 85\% + 5' \cdot 10\%$
	(6–10) 5':	$(5 + 5)\% = 10\%$	$+5' \cdot 5\%)/15'$
	(11–15) 5':	5%	$= 500\%/15 \approx 33.5\%$

– *Speichernutzung:*

Uniprogramming $(50\text{kB} \cdot 5' + 100\text{kB} \cdot 15' + 80\text{kB} \cdot 10')/30'$
$= (250\text{kB} + 1500\text{kB} + 800\text{kB})/30$
$= 2550\text{kB}/30 = 85\text{k}$
Bei einer Gesamtgröße des Speichers von 256k ergibt sich eine Ausnutzung von $85/256 \approx 33\%$

Multiprogramming $(230\text{kB} \cdot 5' + 180\text{kB} \cdot 5' + 100\text{kB} \cdot 5')/15'$
$= (1150\text{kB} + 900\text{kB} + 500\text{kB})/15$
$= 2550\text{kB}/15 = 170\text{kB}$
Hier liegt die Ausnutzung bei $170/256 \approx 67\%$

– *Platten- bzw. Druckerauslastung:*

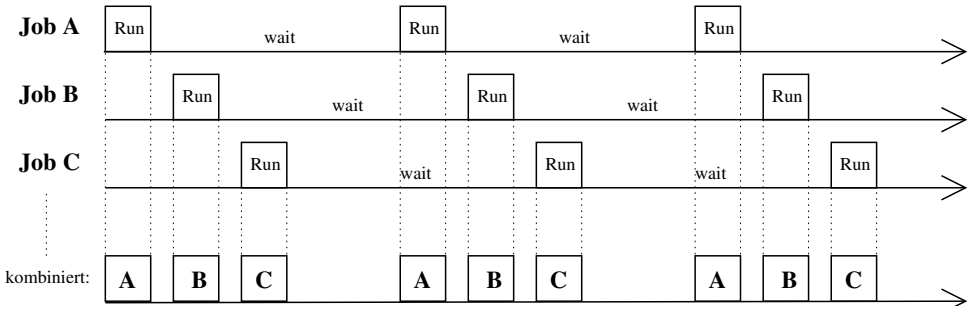

Abbildung 3.2: Pseudo-parallele Ausführung

Uniprogramming $10'/30' = 1/3 \approx 33\%$
Multiprogramming $10'/15' = 2/3 \approx 67\%$

– *Terminalauslastung:*

Uniprogramming $15'/30' = 1/2 = 50\%$
Multiprogramming $15'/15' = 1/1 = 100\%$

– *Durchsatz:*
Anzahl von Einheiten (z.B. Prozessen) in einer bestimmten Zeiteinheit (hier: Stunde).

Uniprogramming *3 Jobs / 1/2 Std.* $\Rightarrow$ *6 Jobs/Std.*
Multiprogramming *3 Jobs / 1/4 Std.* $\Rightarrow$ *12 Jobs/Std.*

– *Mittlere Antwortzeit:*
Man betrachtet für jeden Prozess die Zeit vom Beginn bis zur fertigen Abarbeitung (= Antwortzeit dieses Prozesses). Hiervon bildet man den Durchschnitt (als arithmetisches Mittel).

	Uniprogramming	***Multiprogramming***
Job 1	$5'$	$5'$
Job 2	$20' := 5' + 15'$	$15'$
Job 3	$30' := 20' + 10'$	$10'$
	$55'/3 = 18\mathrm{min}.$	$30'/3 = 10$ *min.*

Obwohl der Prozessor zu jedem Zeitpunkt nur einen Prozeß ausführt, kann er innerhalb einer Sekunde an verschiedenen Prozessen arbeiten.
$\Rightarrow$ Der Nutzer erhält die Illusion von Parallelität.
Dieses Wechseln des Prozessors zwischen mehreren Prozessen wird als Pseudo-Parallelität bezeichnet. Dies unterscheidet sich aber von echter Hardware-Parallelität, bei der der Prozessor Berechnungen ausführt, während ein oder mehrere E/A-Geräte Aufträge bearbeiten.
Um mit Parallelität bei Betriebssystemen leichter umgehen zu können, wurden Modelle entwickelt, wie z. B. das Prozeßmodell. Beim Prozeßmodell wird angenommen, daß jeder Prozeß seinen eigenen virtuellen Prozessor besitzt.

3.1.2 Erzeugung von Prozessen

In den bisherigen Überlegungen wurde von einer bereits existierenden Menge an Prozessen ausgegangen. Betriebssysteme, die ein Prozess-Modell zur Verfügung stellen, müssen natürlich auch eine Möglichkeit bieten, die erforderlichen Prozesse zu erzeugen. Daraus resultiert

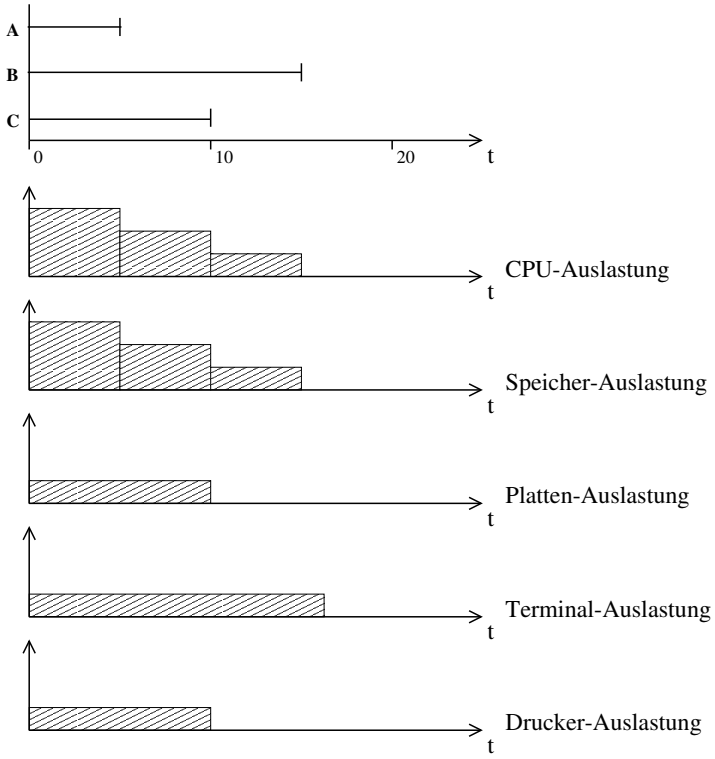

Abbildung 3.3: Ressourcennutzung bei verzahnter Ausführung von Jobs

das Konzept der Prozess-Hierarchie: Ausgehend von einem laufenden initialen Prozess können Prozesse neue Prozesse erzeugen, die dann Kindprozesse (des Elternprozesses) genannt werden.

Prozesserzeugung unter Unix/Linux: Mit dem Systemaufruf `fork` können Prozesse erzeugt werden. Genauer: Es wird eine identische Kopie des aufrufenden Prozesses erzeugt. Mit dem Kommando `execve` kann ein Programm in den Speicherbereich des aufrufenden Prozesses geladen werden (der also dann das neue Programm ausführt).

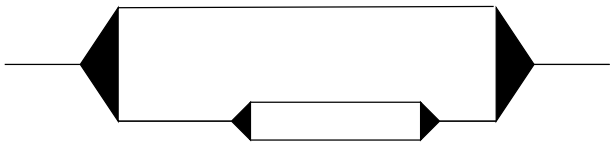

Abbildung 3.4: FORK-Darstellung

- Bei mehrfacher `fork`-Ausführung lassen sich verschiedene Kindprozesse parallel zum Vaterprozess starten.
- Die Kindprozesse können ihrerseits selbst wieder Kindprozesse starten.
- So entsteht ein beliebig tiefer Baum von Prozessen, d.h. eine beliebig tiefe Prozess-Hierarchie.

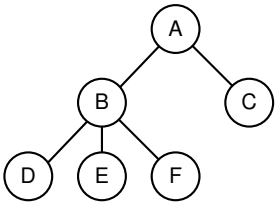

Abbildung 3.5: Beispiel einer Prozesshierarchie: A hat die beiden Kindprozesse B und C erzeugt, B wiederum die drei Kinder D, E und F.

Prozesserzeugung unter MS DOS: Vater- und Kindprozess können nicht parallel ausgeführt werden. Aber es gibt einen Systemaufruf, mit dem ein ausführbares Programm in den Arbeitsspeicher geladen und als Kindprozess ausgeführt werden kann. Im Gegensatz zu Unix suspendiert jedoch dieser Aufruf den Vaterprozess bis der Kindprozess seine Ausführung beendet hat.

Prozesserzeugung unter Microsoft Windows XP: Unter Windows gibt es keine echte Prozesshierarchie. Stattdessen erhält der Elternprozess bei der Erzeugung eines Kindprozesses ein Handle auf diesen. Dieses Handle kann jedoch beliebig weitergegeben werden.

Mehrere Prozesse können quasiparallel ausgeführt werden. Hierfür ist ein ständiger Wechsel zwischen den Prozessen notwendig, welcher durch das Betriebssystem erledigt wird. Z.B. durch **Dispatching** (Zuordnung des Rechnerkerns an einen Prozess). Die Prozessverwaltung erfolgt durch das Betriebssytem auf der Basis der möglichen Prozesszustände. Das Ziel der Realisierung der Prozessverwaltung ist Effizienz, z.B. bei der CPU-Auslastung.

Ursachen für die Erzeugung eines Prozesses: Grundsätzlich gibt es vier mögliche Ursachen, aufgrund derer das Betriebssystem einen neuen Prozess erzeugt:

1. Neuer Stapelauftrag: Das Betriebssystem arbeitet im Batch-Betrieb und liest bei freier Kapazität einen neuen Auftrag von der Platte.
2. Benutzeranmeldung: Meldet sich im interaktiven Betrieb ein Nutzer am System an, so wird für diesen Vorgang ein neuer Prozess erzeugt.
3. Dienstleistungsprozesse: Ein neuer Prozess kann auch im Auftrag eines Anwendungsprogramms erzeugt werden. Fordert ein Anwendungsprogramm z.B. das Drucken eines Dokuments an, so erzeugt das Betriebssystem einen neuen Prozess, der das Drucken im Hintergrund übernimmt.
4. Kindprozesse: Auch ein Anwendungsprozess kann einen neuen Prozess erzeugen, etwa um Programmteile parallel auszuführen. Ein typisches Beispiel dafür ist ein Server-Prozess, der für jede eingehende Anfrage einen neuen Prozess erzeugt, um diese zu bearbeiten. Meistens kommunizieren und kooperieren Eltern- und Kindprozess(e) miteinander. Sie besitzen jedoch getrennte Adressräume.

In Unix sind alle Prozesse Nachkommen des Prozesses `init`, der beim Initialisieren des Systems gestartet wird.

Schritte bei der Prozess-Erzeugung: Im Einzelnen müssen vom Betriebssystem bei der Prozess-Erzeugung die folgenden Schritte durchgeführt werden:

1. Der Prozess bekommt einen eindeutigen Identifikator zugewiesen und wird mit dieser PID in die Prozesstabelle eingetragen.
2. Dem Prozess wird Speicherplatz für das Prozess-Image zugeordnet. Dazu muss dem Betriebssystem mitgeteilt werden, wie viel Speicher für den privaten Adressraum (also Daten und Maschinenprogramme) benötigt wird. Diese Informationen können entweder bei der Anfrage zur Prozessgenerierung übergeben oder aber – in Abhängigkeit vom Prozesstyp – mit Standardwerten belegt werden.
3. Der Prozesskontrollblock (PCB, siehe später) wird initialisiert. Der zugeordnete Prozessidentifikator wird eingetragen und die Prozesszustandsinformationen werden mit Standardwerten belegt. Dem Prozess werden zu Beginn keine Ressourcen (z.B. Drucker) zugeordnet, da diese erst im Laufe der Abarbeitung durch den Prozess über entsprechende Schnittstellen des Betriebssystems angefordert werden.
4. Die erforderlichen Links müssen gesetzt werden. Verwaltet das Betriebssystem beispielsweise jede Scheduling Queue als eine verkettete Liste, so muß der neue Prozeß in die “Ready”- bzw. in die “Ready, Suspend”-Queue eingeordnet werden (siehe später).
5. Gegebenenfalls sind Datenstrukturen zu erweitern oder neu zu schaffen. So könnte es denkbar sein, daß das Betriebssystem für jeden Prozeß eine Datei für Abrechnungszwecke bereitstellt. Diese Datei müßte dann auch für den neuen Prozeß angelegt werden.

Terminierung eines Prozesses: In dem Buch [3] werden 14 typische Gründe für die Prozessterminierung genannt. Darunter befinden sich Instruktionen zum Anhalten eines Prozesses, die jedes Computersystem bereitstellen muß. Dies gilt gleichermaßen für den Stapelauftrag, der einen HALT-Befehl nutzen können muß, als auch für das Betriebssystem, das einen expliziten Befehl zur Terminierung von Prozessen bereitstellen muß. Eine weitere Möglichkeit zur Terminierung bietet “LogOff”, das bewirkt, daß ein eingeloggter Prozeß sich beendet. Die meisten Anwendungen stellen ein “Quit” bereit, um die Beendigung eines Prozesses anzuzeigen. Alle diese Aktionen führen dazu, daß eine Anfrage, d.h. Aufforderung an das Betriebssystem gestellt wird, den entsprechenden Prozeß zu beenden. Hinzu kommen Fehler, die zur Terminierung eines Prozesses führen können (Fehler müssen aber nicht zur Terminierung eines Prozesses führen!). Schließlich kann ein Kindprozeß durch seinen Elternprozeß beendet werden, oder falls der Elternprozeß selbst beendet wird.

3.1.3 Realisierung von Multiprogramming

Wie wird Multiprogramming umgesetzt? Hauptfunktion eines Prozessors ist es, Maschineninstruktionen aus dem Hauptspeicher auszuführen. Diese Instruktionen werden in Form eines Maschinenprogramms bereitgestellt. Um Multiprogramming zu realisieren, muss ein solches Programm, das ausgeführt wird, von Zeit zu Zeit verlassen werden.

Sicht des Prozessors: Die CPU führt definierte Befehle aus, und zwar in der Reihenfolge, wie es ihr durch ihren Programmzähler (Program Counter) diktiert wird. Dass dieser Programmzähler dabei auf Code in unterschiedlichen Programmen verweist, die unter

Umständen Bestandteil verschiedenster Anwendungen sind, spielt für die CPU keine Rolle.

Sicht eines individuellen Programms: Seine Ausführung besteht aus einer Folge von Maschinenbefehlen, die auch Spur (Trace) des assoziierten Prozesses genannt wird. Hierbei ist nur von Bedeutung, dass die Reihenfolge der Abarbeitung seiner Instruktionen nicht verändert wird.

Dispatcher: Der Dispatcher ist ein Prozess, der einen Benutzer-Prozess, der sich in Bearbeitung befindet, unterbrechen und einen anderen Prozess dem Prozessor zuweisen kann.

Beispiel 3.3. *Wir betrachten als einfaches Szenario drei Benutzer-Prozesse, die durch Programme repräsentiert werden, sowie einen (relativ kleinen) Dispatcher-Prozess. Alle Prozesse wurden vollständig in den Hauptspeicher geladen (vgl. Abbildung 3.6).*

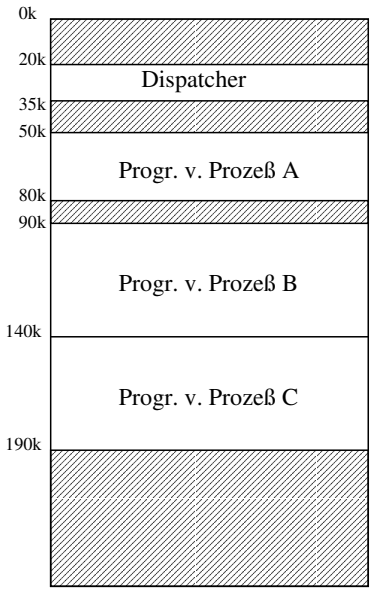

Abbildung 3.6: Speicherbelegung der drei Beispielprozesse

Die Spuren der drei Prozesse sollen wie folgt aussehen (Anfang der Traces):

Trace des Prozesses A	*Trace des Prozesses B*	*Trace des Prozesses C*
$\alpha + 0$	$\beta + 0$	$\gamma + 0$
$\alpha + 1$	$\beta + 1$	$\gamma + 1$
$\alpha + 2$	$\beta + 2$	$\gamma + 2$
$\alpha + 3$	$\beta + 3$	$\gamma + 3$
$\alpha + 4$	*(E/A-Op.)*	$\gamma + 4$
$\alpha + 5$		$\gamma + 5$
$\alpha + 6$		$\gamma + 6$
$\alpha + 7$		$\gamma + 7$
$\alpha + 8$		$\gamma + 8$
$\alpha + 9$		$\gamma + 9$
$\alpha + 10$		$\gamma + 10$
$\alpha + 11$		$\gamma + 11$

Dabei sind α, β und γ die Anfangsadressen der Prozesse A bzw. B und C. Bei Prozess B soll angenommen werden, dass der vierte Befehl (also $\beta + 3$) eine E/A-Operation ist, die ein Warten des Prozesses bedingt. Aus Sicht des Prozessors erhalten wir zur Ausführung dieser $12+4+12 = 28$ Befehle folgende Sequenz abzuarbeitender Befehle:

01. $\alpha + 0$	*16.* $\beta + 3$ *E/A-Anforderung*	*31.* $\delta + 2$	*46.* $\delta + 5$
02. $\alpha + 1$	*17.* $\delta + 0$	*32.* $\delta + 3$	*47.* $\gamma + 6$
03. $\alpha + 2$	*18.* $\delta + 1$	*33.* $\delta + 4$	*48.* $\gamma + 7$
04. $\alpha + 3$	*19.* $\delta + 2$	*34.* $\delta + 5$	*49.* $\gamma + 8$
05. $\alpha + 4$	*20.* $\delta + 3$	*35.* $\alpha + 6$	*50.* $\gamma + 9$
06. $\alpha + 5$ *Timeout*	*21.* $\delta + 4$	*36.* $\alpha + 7$	*51.* $\gamma + 10$
07. $\delta + 0$	*22.* $\delta + 5$	*37.* $\alpha + 8$	*52.* $\gamma + 11$ *Timeout*
08. $\delta + 1$	*23.* $\gamma + 0$	*38.* $\alpha + 9$	*usw.*
09. $\delta + 2$	*24.* $\gamma + 1$	*39.* $\alpha + 10$	
10. $\delta + 3$	*25.* $\gamma + 2$	*40.* $\alpha + 11$ *Timeout*	
11. $\delta + 4$	*26.* $\gamma + 3$	*41.* $\delta + 0$	
12. $\delta + 5$	*27.* $\gamma + 4$	*42.* $\delta + 1$	
13. $\beta + 0$	*28.* $\gamma + 5$ *Timeout*	*43.* $\delta + 2$	
14. $\beta + 1$	*29.* $\delta + 0$	*44.* $\delta + 3$	
15. $\beta + 2$	*30.* $\delta + 1$	*45.* $\delta + 4$	

Dem liegt das Prinzip zu Grunde, dass die Ausführung eines Prozesses nach maximal sechs Befehlszyklen durch ein Timeout unterbrochen wird. Dann übergibt der Dispatcher-Prozess die Kontrolle an den nächsten Benutzer-Prozess.

Fragen: Wie lassen sich dieses und andere Szenarien in Form von Kontrollstrukturen im Betriebssystem abbilden? Wie wird die Suspendierung eines Prozesses genau realisiert? Um diese Fragen beantworten zu können, benötigen wir ein Modell, das den Zustand eines Prozesses charakterisiert.

3.1.4 Das 2-Zustands-Prozessmodell

Prinzipiell kann sich ein Prozess in Ausführung befinden (d.h. Instruktionen aus seiner Trace werden von der CPU ausgeführt) oder aber er wird nicht ausgeführt. Die entsprechenden

Zustände heißen “Running” und “Not running”. Dieses einfachste Prozessmodell sieht wie folgt aus:

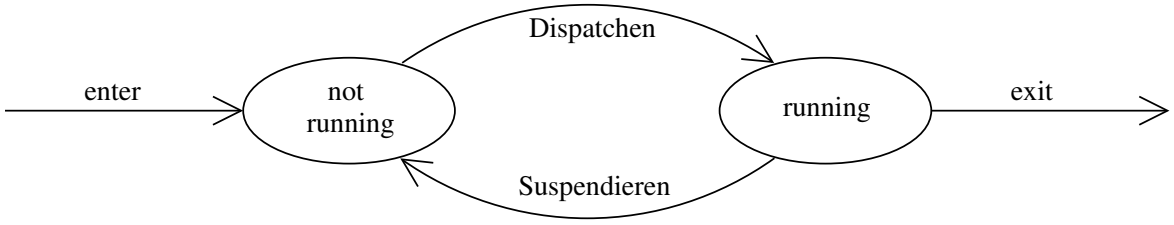

Abbildung 3.7: 2-Zustands-Prozessmodell

Für das Betriebssystem können vorerst zwei Anforderungen an die Informationen über einen Prozess abgeleitet werden:

– der aktuelle Zustand des Prozesses muss beschreibar sein

– die Speicherinformationen bzgl. des Prozesses müssen abrufbar sein (d.h. wo er gespeichert ist)

Aus Modellierungssicht müssen Prozesse im Zustand “Not running” in einer Art Warteschleife zwischengespeichert werden, um auf ihre Ausführung zu warten. Dies ergibt das folgende Warteschlangenmodell:

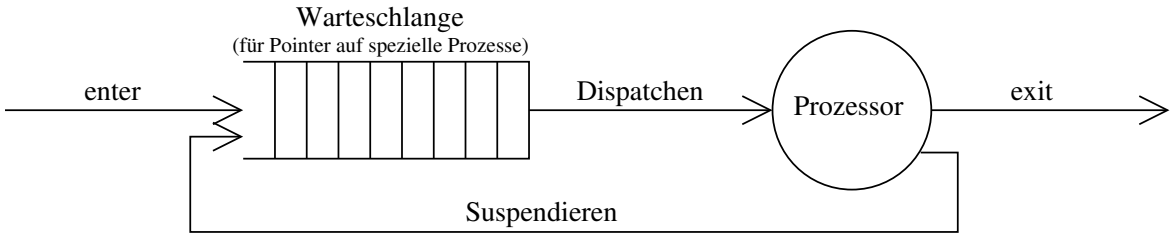

Abbildung 3.8: Warteschlangenmodell des 2-Zustand-Prozessmodells

Dieses Modell beschreibt auch das Verhalten des Dispatchers: Ein Prozess, der unterbrochen wird, kommt in die Warteschlange oder verlässt bei Abbruch bzw. Terminierung das System. Umgekehrt wird bei freiem Prozessor der nächste Prozess aus der Warteschlange zur Ausführung ausgewählt.

Scheduling vs. Dispatching: Die Strategie, nach der entschieden wird, welcher Prozess wann/als nächstes rechnen darf, wird Scheduling-Strategie genannt. Die Komponente, die diese Strategie umsetzt, heißt Scheduler. Das eigentliche Hin- und Herschalten zwischen Prozessen wird Dispatching genannt. Der Dispatcher übernimmt das Suspendieren des “alten” Prozesses und die Zuweisung der CPU an den “neuen” Prozess.

3.1.5 Das 5-Zustands-Prozessmodell

Bislang wurde davon ausgegangen, dass alle Prozesse stets zur Ausführung bereit sind. Das zugehörige 2-Zustands-Prozessmodell mit FIFO-Warteschlange würde dann effektiv arbeiten.

Aber: Prozesse können nicht rechenbereit sein, wenn sie z.B. auf die Beendigung einer E/A-Operation warten. In diesem Fall heißt ein Prozess blockiert. Nicht laufende (bisher: “Not running”) Prozesse werden in zwei Klassen eingeteilt:

– Prozesse, die rechenbereit sind: “Ready”

– Blockierte Prozesse: “Blocked”

Hinzu kommen die Zustände “New” (für neu generierte Prozesse) und “Exit” (für terminierte Prozesse). Dies ergibt folgendes Diagramm:

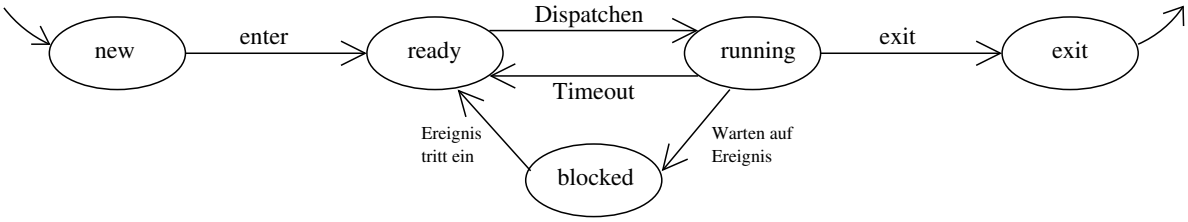

Abbildung 3.9: 5-Zustands-Prozessmodell

Zusammenfassung der Zustände: Zustände und ihre Bedeutung im 5-Zustands-Prozessmodell:

- Running: Der Prozess befindet sich in der Ausführung. Bei Einprozessor-Systemen kann sich zu jedem Zeitpunkt nur ein Prozess in diesem Zustand befinden.
- Ready: Der Prozess ist zur Ausführung bereit.
- Blocked: Der Prozess wartet auf ein Ereignis (z.B. Ende einer E/A-Operation, Benutzereingabe) und kann erst zur Ausführung kommen, nachdem das Ereignis eingetreten ist.
- New: Der Prozess wurde erzeugt, aber noch nicht durch das Betriebssystem zur Menge der ausführbaren Prozesse hinzugefügt.
- Exit: Der Prozess wurde durch das Betriebssystem aus der Menge der ausführbaren Prozesse entfernt.

Die Zustände “New” und “Exit” sind bei der Prozessmodellierung hilfreich für das Prozessmanagement. Beispielsweise kann die Anzahl ausführbarer Prozesse im Betriebssystem limitiert sein. Dann ist der Zustand “new” sinnvoll einsetzbar.

Zulässige Zustandsübergänge: Beispiele für Ursachen aller zulässigen Zustandswechsel:

- Null→New: Ein Prozess wird erzeugt.
- New→Ready: Das Betriebssystem ist in der Lage, einen zusätzlichen Prozess aufzunehmen (genug Speicher vorhanden).
- Ready→Running: Ein rechenbereiter Prozess wird zur Ausführung ausgewählt.
- Running→Exit: Das Betriebssystem beendet den Prozess.

- Running→Ready: Ein anderer Prozess soll zur Ausführung ausgewählt werden (z.B. weil die maximale Zeit für einen Ausführungs-Slot abgelaufen oder ein höher-priorer Prozess ins System gekommen ist).
- Running→Blocked: Der Prozess muss auf ein Ereignis warten.
- Blocked→Ready: Das Ereignis, auf das gewartet wurde, ist eingetroffen.

Beispiel 3.4.

Zeitintervall	*Prozeß A*	*Prozeß B*	*Prozeß C*
1-6	*Running*	*Ready*	*Ready*
7-12	*Ready*	*Ready*	*Ready*
13-16	*Ready*	*Running*	*Ready*
17-22	*Ready*	*Blocked*	*Ready*
23-28	*Ready*	*Blocked*	*Running*
29-34	*Ready*	*Blocked*	*Ready*
35-40	*Running*	*Blocked*	*Ready*
41-46	*Ready*	*Blocked*	*Ready*
47-52	*Ready*	*Blocked*	*Running*
usw.			

Eine Implementierung kann auf zwei Warteschlangen basieren:

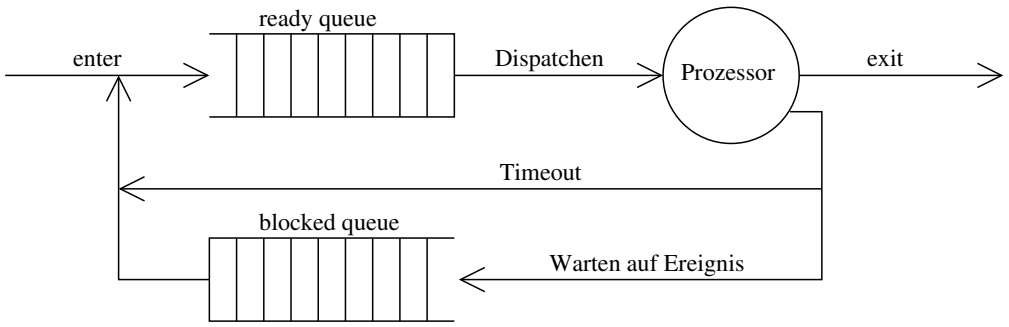

Abbildung 3.10: Warteschlangenmodell des 5-Zustand-Prozessmodells

Zur Realisierung des 5-Zustands-Prozess-Modells werden mindestens zwei Warteschlangen benötigt.

Alternativ können statt einer Blocked Queue auch mehrere Blocked Queues realisiert werden – jeweils eine pro Ereignisart:

Splitting der Ready Queue: Falls es für das Scheduling von Prozessen verschiedene Prioritätsklassen gibt, kann auch die Ready Queue noch einmal in verschiedene Queues unterteilt werden.

3.1.6 Das 7-Zustands-Prozessmodell

Bisher muss jeder Prozess, der vom Prozessor ausgeführt werden soll, komplett in den Hauptspeicher geladen werden. Ein häufiger Grund für das Warten auf ein Ereignis im blockierten

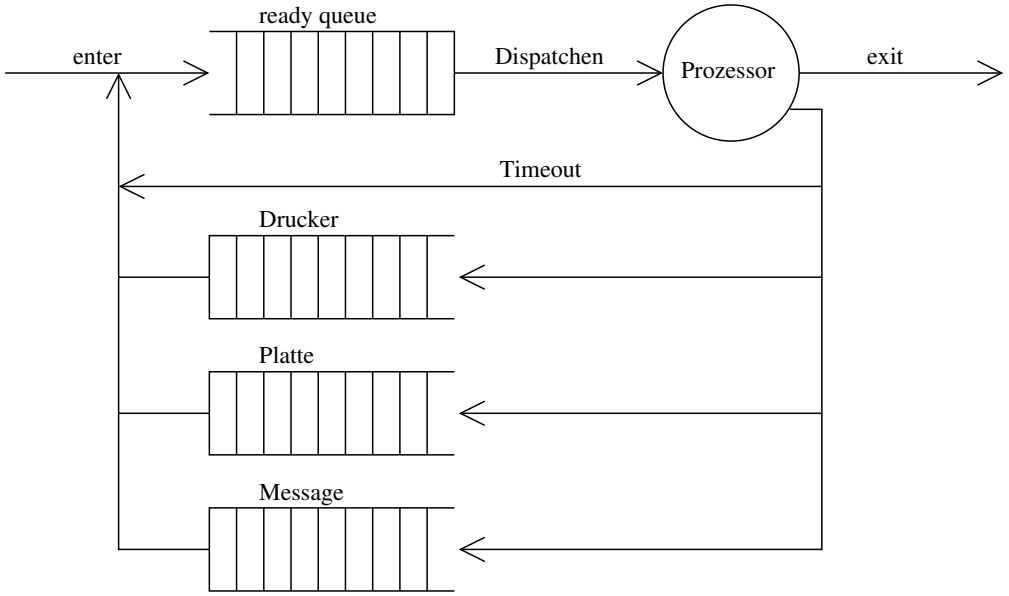

Abbildung 3.11: Implementierung mit mehreren Warteschlangen

Zustand ist eine Ein- oder Ausgabe in Bearbeitung (E/A-Operation). Im Vergleich zu Berechnungen sind E/A-Operationen sehr langsam.

Frage: Was passiert, wenn alle Prozesse im Hauptspeicher auf das Ende einer E/A-Operation warten und kein Speicherplatz für weitere Prozesse mehr frei ist? Dann ist die CPU nicht mehr ausgelastet, potenziell vorhandene Rechenkapazität bleibt ungenutzt.

- Lösung 1: Vergrößerung des Hauptspeichers, sodass dieser mehr Prozesse aufnehmen kann (also Einbau weiterer Speichermodule).
- Lösung 2: Auslagerung (Swapping); ganze Prozesse oder auch nur Teile davon werden in den Hintergrundspeicher (in der Regel eine Platte) ausgelagert. Damit steht dem Betriebssystem praktisch mehr Speicher (virtuell) zur Verfügung als physisch in Form von Speichermodulen vorhanden ist.

Auslagerung von Prozessen (Swapping): Falls sich keiner der Prozesse im Hauptspeicher im Zustand "Ready" befindet, so lagert das Betriebssystem einen der blockierten Prozesse auf die Platte aus, indem es vor allem die speicherintensiven Bestandteile des Prozesses, wie die Instruktions-Spur (Trace) in einen reservierten Bereich des Datenträgers (oft: Swap-Partition) kopiert. Dadurch wird im Hauptspeicher Platz für neue, rechenbereite Prozesse geschaffen. Ausgelagerte Prozesse werden in einer Suspend Queue verwaltet (analog zu Ready Queue und Blocked Queue). Die Suspend Queue selbst und in der Regel auch die Verwaltungsinformationen zum Prozess (Prozesskontrollblock, siehe später) werden allerdings im Hauptspeicher gehalten.

Zu beachten: Swapping ist selbst eine E/A-Operation, da ja Daten zwischen zwei verschiedenen Ebenen der Speicherhierarchie transportiert werden müssen. Aber: Eine Lese- oder Schreiboperation auf einer Platte ist im Allgemeinen die schnellste aller E/A-Operationen

(z.B. verglichen mit einem Druckauftrag oder dem Lesen von einem Wechseldatenträger wie Diskette, CD oder DVD).

Virtueller Speicher: Der virtuelle Speicher ist die Menge an Speicher (in Bytes), die dem Betriebssystems maximal zur Abbildung von Prozessen auf dem Hintergrundspeicher zur Verfügung steht. Dabei gilt allerdings:

- Der Hauptspeicher repräsentiert stets einen Ausschnitt des virtuellen Speichers. Anders formuliert enthält der virtuelle Speicher prinzipiell die gleichen Daten wie der Hauptspeicher, und zusätzlich Daten von suspendierten Prozessen. Dabei können bestimmte Daten im Hauptspeicher "aktueller" sein als die gleichen Daten im Hintergrundspeicher, z.B. wenn Variablen während der Ausführung neue Werte annehmen. Der Hintergrundspeicher kann also temporär "schmutzige" Daten enthalten, was eine Synchronisation von Hauptspeicher und virtuellem Speicher erforderlich macht (detaillierte Behandlung später).
- Die Gesamt-Prozess-Kapazität des Betriebssystems ist damit gleich der Kapazität des virtuellen Speichers (und **nicht (!)** gleich der Summe der Kapazitäten von Haupt- und virtuellem Speicher).
- Demnach muss der virtuelle Speicher immer größer als der tatsächlich vorhandene Hauptspeicher sein (in der Praxis zwei- bis dreimal so groß).

Durch virtuellen Speicher und Swapping wird die CPU-Auslastung zusätzlich erhöht, weil Prozesse, die auf das Ende von E/A-Operationen warten, nicht zwangsläufig den Hauptspeicher blockieren. Swapping verstärkt also die positiven Effekte von Multiprogramming.

Das Swapping bedingt nun zunächst eine Erweiterung des 5-Zustands-Prozessmodells um einen Zustand "Suspend":

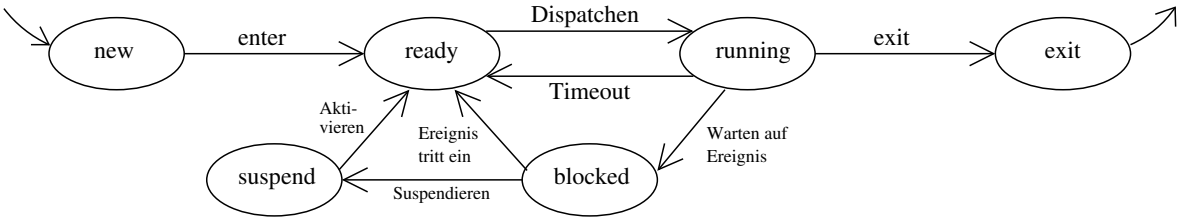

Abbildung 3.12: 5-Zustands-Modell mit Suspend

Problem: Wenn durch das Auslagern eines Prozesses ein weiterer Prozess geladen werden kann, dann ist es oft günstiger, einen der ausgelagerten Prozesse, die inzwischen wieder rechenbereit sind, zu nehmen statt eines neuen. Solche Prozesse sollten sich natürlich nicht mehr im Zustand "blocked" befinden.
Aus diesem Grund macht es Sinn, sowohl bei den im Hauptspeicher enthaltenen als auch bei den ausgelagerten Prozessen zwischen blockierten und nicht blockierten zu unterscheiden:

	Ready	Blocked
Hauptspeicher	Zustand: Ready	Zustand: Blocked
Hintergrundspeicher	Zustand: Ready, Suspend	Zustand: Blocked, Suspend

Dies ergibt noch einmal ein verfeinertes Zustandsübergangsdiagramm:

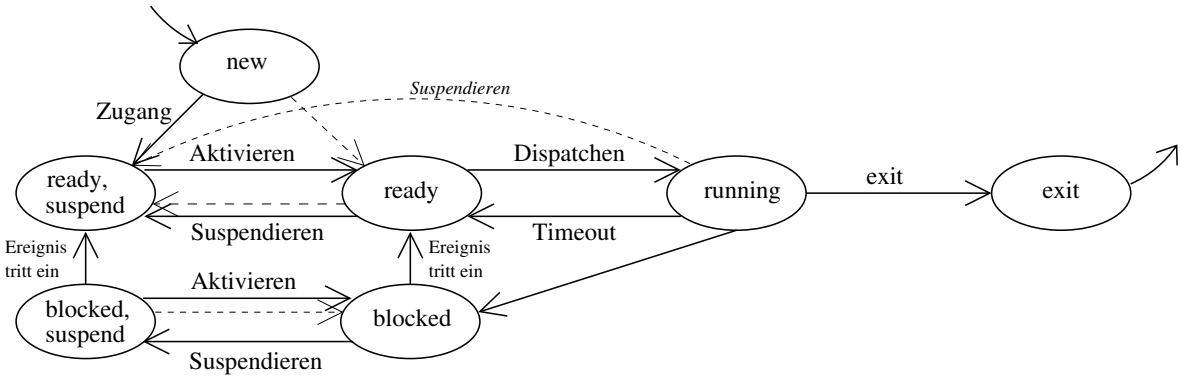

Abbildung 3.13: 7-Zustands-Prozessmodell

Ursachen für die Suspendierung von Prozessen: Für die Suspendierung von Prozessen kann es verschiedene Ursachen geben:

- Ein blockierter Prozess wird in den Hintergrundspeicher ausgelagert (Swapping wie oben beschrieben). Dies entspricht dem Übergang von "blocked" nach "blocked, suspend" (durchgezogener Pfeil) in Abbildung 3.13.
- Ein Prozess wird z.B. über einen langen Zeitraum periodisch, aber nur sehr selten ausgeführt (z.B. Monitoring-Prozesse). Auch wenn der Prozess nach einem Ausführungsintervall nicht blockiert ist (da er nicht auf eine E/A wartet), soll er in der Wartezeit keinen Hauptspeicher belegen, um einen höheren Parallelitätsgrad des Gesamtsystems zu ermöglichen. Daher wird er suspendiert, was dem Übergang von "running" nach "ready, suspend" (gestrichelter Pfeil) in Abbildung 3.13 entspricht. Wird die Entscheidung, den nicht-blockierten Prozess zur Freigabe von Speicher zu suspendieren, erst später (und nicht direkt nach einem Ausführungsintervall) getroffen, so entspricht dies dem Übergang von "ready" nach "ready, suspend" (gestrichelter Pfeil).

3.2 Prozessbeschreibung

Ein Betriebssystem kontrolliert Ereignisse innerhalb des Computersystems, realisiert Scheduling und Dispatching von Prozessen und ordnet Ressourcen (Betriebsmittel) den verschiedenen Prozessen zu.

Bemerkungen zu Abbildung 3.14:

- In einer Multiprogramming-Umgebung existieren n Prozesse P_1, ..., P_n.
- Jeder dieser Prozesse muss auf bestimmte Systemressourcen zugreifen.

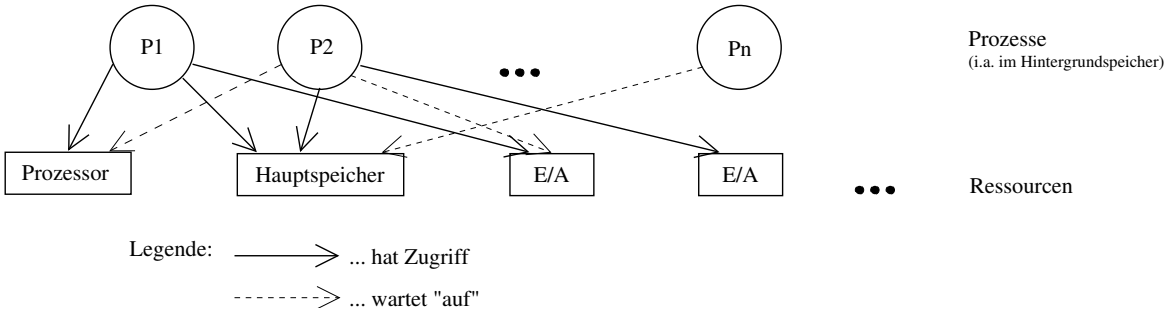

Abbildung 3.14: Verwaltung der Nutzung von Systemressourcen

– Der in Ausführung befindliche Prozess nutzt den Prozessor. Zumindest Teile dieses Prozesses liegen im Hauptspeicher vor. Jeder andere Prozess kann auch vollständig im Hintergrundspeicher abgelegt sein.

Frage: Welche Informationen benötigt das Betriebssystem, um Prozesse zu kontrollieren und Ressourcen für diese Prozesse zu verwalten?

3.2.1 Kontrollstrukturen des Betriebssystems

Das Betriebssystem muss den aktuellen Status jedes Prozesses und jeder Ressource kennen. Zu diesem Zweck erzeugt es für jede zu verwaltende Einheit Tabellen und verwaltet diese. Jedes Betriebssystem unterscheidet dabei 4 Typen von Tabellen und zwar für den Speicher, die E/A-Geräte, die Dateien und die Prozesse (siehe dazu auch Abbildung 3.15). Dabei variieren einzelne Details von Betriebssystem zu Betriebssystem. Im Folgenden sollen diese 4 Kategorien von Tabellen einzeln betrachtet werden. Zuvor noch zwei vorgreifende Begriffserklärungen aus dem Bereich der Speicherverwaltung:

Seitenrahmen (Frames): Jeder Speicher besteht aus Speicherzellen, von denen bekanntermaßen jede eine eindeutige Adresse hat. Aus Sicht des Betriebssystems ist es nicht sinnvoll, diese Speicherzellen einzeln zu verwalten, da es sich nicht für einzelne Instruktionen interessiert, sondern für Prozesse und Teile von Prozessen. Daher wird der Hauptspeicher vom Betriebssystem in gleich große Einheiten partitioniert, die alle eine feste Anzahl von Zellen beinhalten. Diese Einheiten heißen Seitenrahmen und sind in der Praxis zwischen 2 und 16 KBytes groß.

Seiten (Pages): Analog dazu wird die Instruktionsfolge (Trace) eines Prozesses in mehrere Seiten aufgeteilt. Alle Seiten sind gleich groß (auch wenn dadurch einige Seiten nicht ganz gefüllt sind) und haben die gleiche Größe wie die Seitenrahmen (Frames) im Hauptspeicher. Jede Seite “passt” also in jeden beliebigen Seitenrahmen.

1. **Speichertabellen (Seitentabellen)**

   – Speichertabellen dienen dazu, den Überblick sowohl über den Hauptspeicher als auch über den virtuellen Speicher zu behalten.

- Dabei ist stets ein Teil des Hauptspeichers für das Betriebssystem selbst reserviert, der Rest steht für (Benutzer-)Prozesse zur Verfügung.
- Speichertabellen beinhalten vor allem
  - die Zuordnung der Seiten eines Prozesses zu den Frames des Hauptspeichers,
  - die Zuteilung des virtuellen Speichers zu den Prozessen und
  - Schutzattribute von Seiten bzw. Frames, um den Zugriff auf gemeinsam genutzte Regionen zu kontrollieren.

2. **E/A-Tabellen**
   - Sie dienen zur Verwaltung von E/A-Geräten sowie Kanälen des Computersystems.
   - Ein E/A-Gerät ist entweder verfügbar, oder es ist einem bestimmten Prozess zugeordnet.
   - Im zweiten Fall kennt das Betriebssystem den Status der E/A-Operation und den Ort im Hauptspeicher, der als Ziel bzw. Quelle des E/A-Transfers genutzt wird.
3. **Dateitabellen**
   - Sie enthalten Informationen über die Existenz von Dateien, über ihren Ort im Hintergrundspeicher, ihren aktuellen Status und andere Attribute.
   - Falls ein separates Dateisystem existiert (wie heute üblich), so kann ein Großteil dieser Informationen darin enthalten sein; das Betriebssystem besitzt dementsprechend weniger Informationen.
4. **Prozesstabellen**
   - Sie enthalten Informationen zur Verwaltung aller Prozesse im System.
   - Wichtige Fragen sind z.B.: Welcher Prozess wird gerade ausgeführt bzw. welchen Zustand hat ein beliebiger Prozess? Welche Prozesse werden durch welche E/A-Operationen blockiert? Welchem Prozess wird als nächstes die CPU zugeteilt? An welcher Stelle wurde ein suspendierter Prozess zuletzt unterbrochen? Die Prozessverwaltung und die erforderlichen Kontrollstrukturen werden im Folgenden näher untersucht.

Abschließende Bemerkung: Obwohl hier vier verschiedene Klassen von Tabellen beschrieben wurden, können diese untereinander in Beziehung stehen, z.B. gegenseitig referenziert werden. Speicher, E/A und Dateien werden mittels eines (oder mehrerer) Prozesse verwaltet, sodass Referenzen auf diese Ressourcen auch in der entsprechenden Prozesstabelle bestehen müssen. Außerdem muss das Betriebssystem auf alle Tabellen selbst zugreifen können. Daher sind die Tabellen selbst Gegenstand der Speicherverwaltung.

3.2.2 Prozesskontrollstrukturen

Um einen Prozess zu verwalten und zu kontrollieren, muss das Betriebssystem wissen:

I. Wo ist der Prozess gespeichert? (Prozesslokalisierung)

II. Welche Werte haben die für das Prozessmanagement relevanten Attribute? (Prozesskontrollblock)

I. Prozesslokalisierung: Die Lokalisierung eines Prozesses hängt von dem Paradigma der eingesetzten Speicherverwaltung (Segmentierung oder Paging) ab:

Variante 1: Dynamische Partitionierung (→Segmentierung)

- Der Prozess wird als zusammenhängender Block in aufeinanderfolgenden Speicherzellen abgelegt.
- Damit das Betriebssystems diesen Prozess verwalten kann, muss zumindest ein Teil der gespeicherten Daten in den Hauptspeicher geladen werden.
- Um den Prozess ausführen zu können, wird in der Regel der gesamte Prozess in den Hauptspeicher geladen.

Das Betriebssystem muss dabei stets wissen, wo im Hintergrund- bzw. Hauptspeicher das Prozess-Image abgelegt ist.

Variante 2: Feste Partitionierung (→Paging)

- Der Speicher wird in feste (!) Blöcke partitioniert und ein Prozess-Image in aneinander grenzenden Blöcken gespeichert. Sind diese Blöcke alle gleich groß (das ist der Normalfall), so spricht man von Seiten (siehe oben).
- Das gesamte Prozess-Image befindet sich stets im Hintergrundspeicher.
- Wird ein Teil im Hauptspeicher benötigt, so wird dieser Teil in freie Frames kopiert.
- Falls der Teil im Hauptspeicher verändert wird, so ist die Kopie im Hintergrundspeicher so lange unaktuell, bis der Teil des Hauptspeichers zurückgeschrieben wird.

Die Prozesstabelle enthält bei dieser Struktur einen Eintrag für jeden Prozess. Dieser Eintrag enthält dann mindestens einen Zeiger auf das Prozess-Image.

Dieses Prinzip kann von Betriebssystem zu Betriebssystem variieren. Bei mehreren Blöcken für das Prozess-Image sind beispielsweise mehrere Einträge in der Prozesstabelle oder Ketten von Verweisen denkbar.

Weitere Variante: Compatible Time-Sharing System (CTSS)

Die oben aufgeführten Varianten sind nicht die einzigen. Eine weitere Möglichkeit soll hier am Beispiel von CTSS vorgestellt werden. Bisher wurde die Speicherverwaltung nur im Hinblick auf die Bearbeitung von Batch-Prozessen betrachtet. Die Abarbeitung von Batch-Prozessen mittels Multiprogramming ist sehr effizient, erlaubt aber keinerlei Interaktion des Benutzers mit dem System. Gerade im Bereich der Desktop Computer ist die direkte Interaktion mit einer Vielzahl an Anwendungen jedoch unabdingbar. In den 1960er Jahren gab es noch keine PCs oder Workstations und die vorhandenen Rechner waren in der Regel groß und teuer. Um die Idee des Multiprogramming jedoch nicht nur

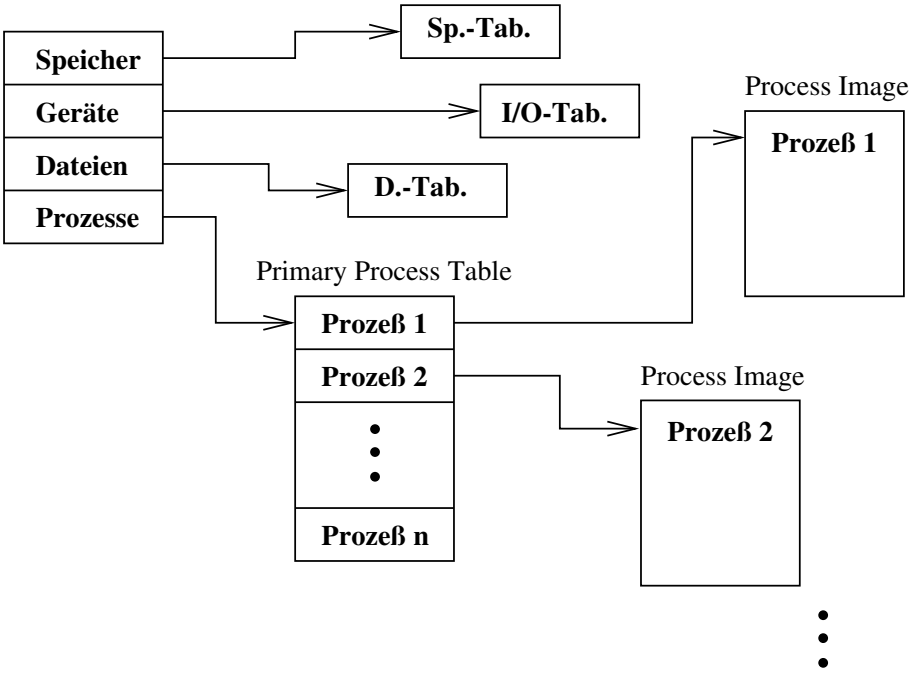

Abbildung 3.15: Struktur der Prozesstabelle

auf Batch-Prozesse sondern auch auf interaktive Jobs anzuwenden, wurde das Konzept des **Time Sharing** entwickelt. Der Begriff Time Sharing rührt daher, dass die Prozessor Zeit unter den verschiedenen (interaktiven) Benutzerprozessen aufgeteilt wird.

Sowohl Batch Processing als auch Time Sharing verwenden das Konzept von Multiprogramming. Die wesentlichen Unterschiede der beiden Verfahren sind in folgender Tabelle dargestellt.

	Batch Multiprogramming	Time Sharing
Ziel	Maximierung der Prozessorauslastung	Minimierung der Antwortzeit
Quelle der Anweisungen für das Betriebssystem	Kontrollkommandos, die dem Job beiliegen	Kommandos, die am Terminal eingegeben werden

Im Folgenden soll nun das Time Sharing am Beispiel des Compatible Time-Sharing System (CTSS) betrachtet werden. Dieses Betriebssystem war extrem einfach und funktionierte für bis zu 32 Nutzer. Wichtig war nur, daß das Betriebssystem auch die Informationen verwaltete, welche Prozeßdaten im Hauptspeicher behalten wurden und welche Daten ausgelagert wurden.

Beispiel: CTSS, MIT 1962, für IBM 709 und später IBM 7094
Wir haben 36k Hauptspeicher (bei IBM 7094), von denen ein Monitorprozeß ständig 5k, und das Betriebssystemprozeß 4k benötigen. Bekommt ein interaktiver Nutzer die

Kontrolle über den Prozessor, so werden die verbleibenden 27k des Hauptspeichers für sein Programm und die Nutzerdaten bereitgestellt.

Von einer Systemuhr werden alle 0.2 Sekunden Interrupts erzeugt, die es dem Betriebssystem erlaubt, den Prozessor einem anderen Nutzerprozess zuzuordnen. Diese Art der Kontrolle wird auch als **Time Slicing** bezeichnet.

Um die Interaktion mit dem Hintergrundspeicher zu minimieren, werden Speicherbereiche des zu unterbrechenden Nutzerprozesses nur dann ausgelagert, wenn der Prozess, der als nächstes die Kontrolle über den Prozessor bekommen soll, diese überschreiben würde. Eine Besonderheit bei IBM 7094 war die Tatsache, dass ein Programm immer an der Adresse 5k (direkt nach dem Monitorjob) geladen wurde. Abhängig von dem Speicherplatzanforderungen des neuen Nutzerprozesses, wurde daher nur ein Teil oder aber der gesamte gerade aktive Job ausgelagert.

Für das folgende Beispiel sollen folgende interaktive Jobs ausgeführt werden:

Job 1:	15k
Job 2:	20k
Job 3:	5k
Job 4:	10k

Die Speicherbelegung erfolgt wie in Abbildung 3.16 dargestellt.

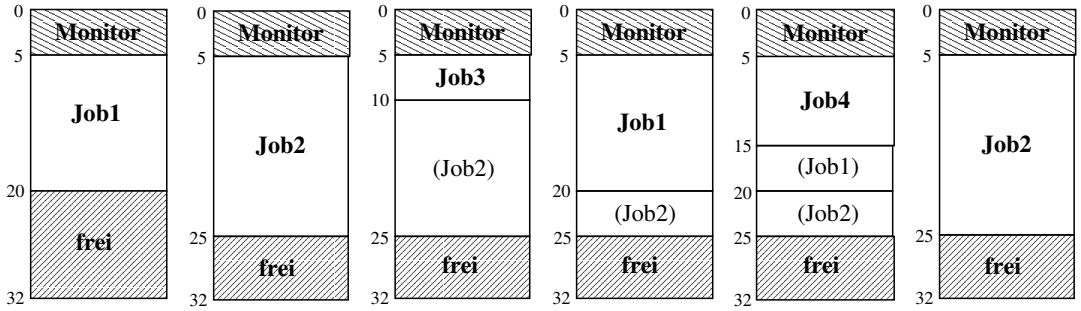

Abbildung 3.16: Beispiel: Speicherbelegung bei CTSS

Zunächst lädt der Monitorprozess Job1 und übergibt ihm die Kontrolle. Später entscheidet der Monitorprozess, dass der Prozessor Job2 zugeordnet werden soll. Da Job2 eine größere Speicheranforderung besitzt als Job1, wird Job1 komplett ausgelagert, bevor Job2 in den Speicher geladen werden kann. Zu einem späteren Zeitpunkt soll Job3 ausgeführt werden. Da dieser Prozess weniger Speicher benötigt als der, der gerade von Job2 belegt wird, reicht es aus, nur einen Teil von Job2 auszulagern. Als nächstes soll wieder Job1 ausgeführt werden, welcher mehr Speicher benötigt als Job3, jedoch weniger als Job2. Dies führt dann zu der vierten Konstellation, usw.

II. Prozessattribute im Prozesskontrollblock: Der Prozesskontrollblock (PCB) ist die bedeutendste Datenstruktur in der Prozessverwaltung des Betriebssystems. Er enthält alle Informationen, die das Betriebssystem zu einem Prozess benötigt. In verschiedenen Betriebssystemen existieren unterschiedliche Realisierungsvarianten. Generell beinhaltet der PCB drei Kategorien von Informationen:

(a) Prozessidentifikation:

- numerischer Identifikator (Prozess-ID, PID)
- Identifikator des Prozesses, der diesen Prozess generiert hat (PID des Elternprozesses); dadurch wird die Prozess-Hierarchie abgebildet.
- ID des Eigentümers/Nutzers des Prozesses

Diese Identifikatoren sind nützlich für Querverweise, z.B. in E/A- oder Speichertabellen. Sie können auch bei der Prozeßkommunikation gebraucht werden.

(b) Prozesszustandsinformationen:

- Inhalt der Prozessorregister (Befindet sich ein Prozeß in der Ausführung, so befinden sich diese Informationen in den Registern.)
- Wird ein Prozeß unterbrochen, so müssen alle Registerinformationen gespeichert werden, so daß dieser Prozeß beim erneuten Laden ordnungsgemäß wieder abgearbeitet werden kann.
  Wiederholung: Anzahl und Art der Register hängt von der verwendeten Hardware ab.
  In der Regel gibt es:
  - Register, die vom Nutzer verwendet werden können,
  - den Stackpointer
  - Kontroll- und Statusregister (d.h. Programmzähler, Condition codes (carryflag, overflowflag, ...))
- Die Menge der Register, die Statusinformationen enthalten, sind in der Regel als sog. Programmstatuswort (PSW) gespeichert.

Beispiel 3.5. *Innerhalb von Pentiumprozessoren wird das PSW als EFLAGS-Register bezeichnet (vgl. Abbildung 3.17. Diese Struktur wird von jedem Betriebssystem genutzt, das auf einem Pentiumprozessor läuft. (Z.B. UNIX oder Windows NT)*

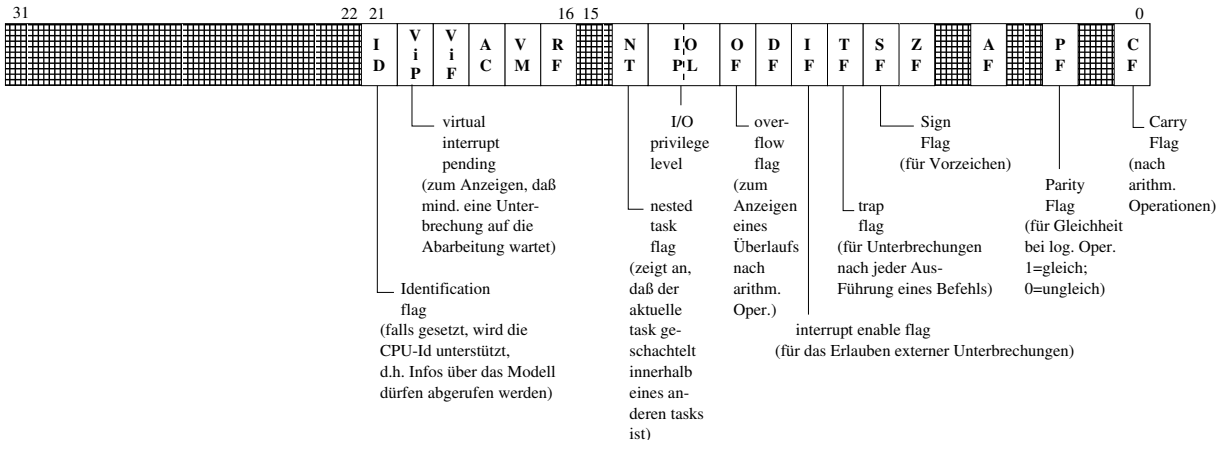

Abbildung 3.17: Struktur des Pentium-EFLAGS-Registers

(c) Prozesskontrollinformationen:

- Scheduling- und Zustandsinformationen, wie

  - Prozesszustand (“Ready”, “Running”, “Blocked”, ...)
  - Priorität
  - Scheduling-Strategie-spezifische Zustandsinformationen, wie z.B. die Zeit, die der Prozess bereits wartet
  - Ereignisse, auf die der Prozess wartet
- Datenstrukturen, z.B. eine Referenz auf den nächsten Prozess, falls alle wartenden Prozesse in einer Queue verwaltet werden
- Signale oder Nachrichten, die zwischen zwei unabhängigen Prozessen ausgetauscht werden (Interprozesskommunikation)
- zusätzliche Informationen über Privilegien des Prozesses, Speichermanagement, Eigentümerverhältnissen von Ressourcen u.a.

Damit können wir die Struktur eines Prozesses im Hintergrundspeicher wie folgt zusammenfassen:

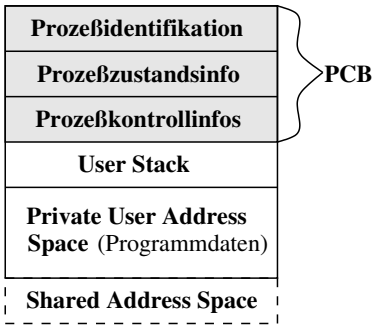

Abbildung 3.18: Struktur eines Prozesses im Hintergrundspeicher

Mit dieser Prozessbeschreibung könnte das 5-Zustands-Prozessmodell wie folgt implementiert werden:

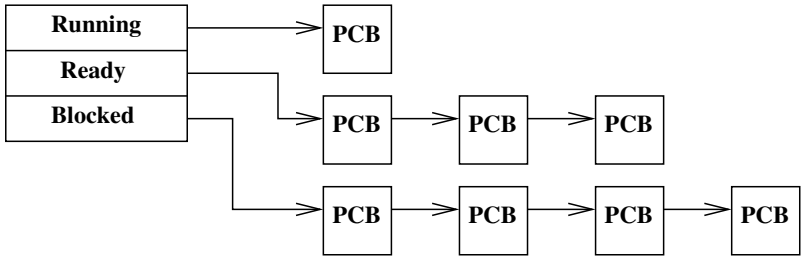

Abbildung 3.19: Implementierung des 5-Zustands-Prozessmodells

Bemerkung zu Abbildung 3.19: Jeder Prozess besitzt eine eindeutige ID, die in einer Tabelle von Zeigern auf Prozesskontrollblöcken als Index genutzt werden kann, d.h. die Queues (Ready- und Blocked-Queue) können als verkettete Listen von PCBs implementiert werden.

3.2.3 Zusammenfassung der Verwaltung und Beschreibung von Prozessen:

Das Betriebssystem entscheidet periodisch, ob ein Prozess angehalten werden und ein anderer aktiviert werden soll (Scheduler). Man sagt, der Prozess wird suspendiert. Wenn ein Prozess suspendiert wird, dann muß die Abarbeitung später genau in dem Zustand wiederaufgenommen werden, in dem er angehalten worden ist. Dazu muß man einen Prozess beschreiben können.

Lösung: Informationen über jeden Prozeß werden in der sogenannten Prozesstabelle gespeichert, die vom Betriebssystem verwaltet wird. Für jeden Prozess gibt es einen Eintrag, der alle Informationen enthält, die diesen Prozess charakterisieren. Der Eintrag wird als Prozessdescriptor festgehalten. Ein suspendierter Prozess wird dann durch folgende Informationen beschrieben:

1. Prozessadressraum (Programmdaten, Nutzerdaten, Nutzerkeller, ...)
2. Eintrag in der Prozesstabelle (PCB)

Realisierung von Prozessen: Der Prozessdescriptor wird meist als Record dargestellt. Im Prozessdescriptor enthalten ist der Prozesskontrollblock (PCB), er enthält die Beschreibung des Prozeßzustands unmittelbar vor dessen Suspendierung. Dabei fällt auf: Um Prozesse in beliebiger Reihenfolge aktivieren und deaktivieren zu können, sollte die Verwaltung nicht kellerartig erfolgen.

Bestandteile eines Prozessdescriptors am Beispiel der MI:

- Ein eindeutiger Name des Prozesses (fortlaufende Nummer, PID in Unix).
- Der Name des Benutzers, dem der Prozess zugeordnet ist.
- zugeordneter Rechnerkern
- Spezifikation des Ereignisses, auf das der Rechnerkern wartet.
- Ablaufpriorität des Prozesses
- Prozesskontrollblock
- Gegebenenfalls die Zuordnung von Ressourcen

Bestandteile des Prozesskontrollblocks:

- Stackpointer
- Inhalte der Register z.B. für die Anfangsadresse und Länge von prozessspezifischen Speicherabbildungstabellen
- Programmstatuswort (PSW)

Achtung, je umfangreicher der Prozesskontrollblock ist, desto “teurer” ist ein Prozesswechsel (siehe unten).

3.3 Prozesskontrolle

Ausgangspunkt: Wir wissen jetzt, warum das Konzept der Prozesse wichtig ist, wie Prozesse erzeugt werden (Kapitel 3.1) und welche Kontrollstrukturen das Betriebssystem verwendet, um Prozesse zu beschreiben (Kapitel 3.2). Nun untersuchen wir, wie auf dieser Grundlage Prozesse kontrolliert und gesteuert werden können.

Zwei Prozessormodi: Bei der Arbeit des Prozessors werden zwei Prozessormodi unterschieden:

1. Im **Systemmodus (Kernel Mode)** ist der Prozessor dem Betriebssystem bzw. einer Funktion des Betriebssystems zugeordnet.
2. Im **Nutzermodus (User Mode)** ist der Prozessor einem Anwendungsprogramm zugeordnet.

Der Systemmodus ist dabei privilegierter, d.h. er erlaubt die Ausführung von Operationen, die im Nutzermodus nicht erlaubt sind. Dazu gehört z.B. das Lesen aus bzw. Schreiben in bestimmte Speicherregionen, aber auch das direkte Ansteuern von Hardware (Drucker, Laufwerke). Im Systemmodus hat die Software die vollständige Kontrolle des Prozessors und den Zugriff auf alle Informationen und Geräte. Prozessen im Nutzermodus können solche Zugriffe verwehrt werden. Damit Nutzerprozesse aber z.B. trotzdem auf angeschlossene Geräte zugreifen können, müssen sie diese über das Betriebssystem anfragen, indem sie eine entsprechende Betriebssystem-Funktion (Support-Funktion) aufrufen. Aus Sicht des Betriebssystems muss dieses also allen Nutzerprozessen Schnittstellen zu seinen Support-Funktionen anbieten.

Frage: Woher weiß der Prozessor, welcher Modus gerade ausgeführt wird? Dazu gibt es im Programm-Statuswort (PSW) ein Bit, das diesen Modus anzeigt (z.B. 0 für Nutzermodus, 1 für Systemmodus).

Funktionen des Betriebssystem-Kerns: Zusammenfassend lassen sich die Haupt-Funktionen des Betriebssystem-Kerns so klassifizieren:

- Support-Funktionen: Dienste, die von Nutzerprozessen in Anspruch genommen werden können (siehe oben).
- Selbstverwaltungs-Funktionen (FCAPS):
  - Fehlermanagement (Fault Management): Erkennung von Fehlerursachen und falls möglich Fehlerbehebung
    Fehler: dauernde oder vorübergehende Veränderung/Verfehlung operationaler Vorgaben
    Ziel ist die Erhöhung der Verfügbarkeit. Dazu müssen Fehlerursachen erkannt und Fehlerquellen behoben werden, wobei die Überwachung entweder permanent ablaufen kann oder alternativ Alarme gemeldet werden können.
  - Konfigurationsmanagement (Configuration Management): Sicherstellung von Verfügbarkeit und Kooperation von Ressourcen (Hard- und Software)
    $\Rightarrow$Überwachung der Geräte/Betriebsmittel und Kontrolle der Einstellungen sind notwendig.

  - Abrechnungsmanagement (Accounting Management): Erfassung und Protokollierung von Nutzerzugriffen zu Abrechnungszwecken
  - Leistungsmanagement (Performance Management): Messung von Leistungsindikatoren (Monitoring), Erkennung und ggf. Auflösung von Engpässen.
  - Sicherheitsmanagement (Security Management): Verschlüsselung von Informationen (z.B. auf Datenträgern), Schutz vor Angriffen, Authentifizierung, Autorisierung
- E/A-Management: Verwaltung von Kanälen und Puffern
- Speichermanagement: Segmentierung, Paging (siehe später)
- Prozessmanagement: Prozesserzeugung und Prozesswechsel

3.3.1 Prozesswechsel (Kontext-Switch)

Ausgangspunkt: Zu gewissen Zeitpunkten wird ein laufender Prozess unterbrochen, und das Betriebssystem ordnet einem anderen Prozess den Zustand "Running" zu. Dafür gibt es im wesentlichen 3 Ursachen:

1. Externe Ereignisse führen die Unterbrechung des aktuell ausgeführten Prozesses herbei, z.B. clock interrupt, I/O interrupt, memory fault
2. Traps, die mit dem aktuell ausgeführten Befehl verbunden sind, rufen eine Unterbrechung hervor. (z.B. zur Behandlung eines Fehlers oder einer Ausnahmebedingung (exception)).
3. Ein Supervisor-Call ruft explizit eine Betriebssystem-Funktion auf, wodurch der aktuelle Befehl unterbrochen wird.

Eine gewöhnliche Unterbrechung übergibt die Kontrolle zunächst einer Unterbrechungsbehandlung. Dann wird eine Betriebssystem-Routine aufgerufen, die speziell auf den Typ der aufgetretenen Unterbrechung zugeschnitten ist.

Kontext-Switch: Bei einem solchen vollständigen Prozesswechsel (Kontext-Switch) sind folgende Schritte erforderlich:

1. Aktualisierung und Sicherung des Prozesskontrollblocks (PCB) des bisherigen Prozesses, also insb. Sicherung der Zustandsinformationen (z.B. CPU-Register, PSW) und Aktualisierung und Sicherung der Kontrollinformationen (z.B. Scheduling-Informationen)
2. Einfügen des Prozesskontrollblocks des bisherigen Prozesses in die Warteschlange des Schedulers
3. Auswahl eines anderen Prozesses zur Ausführung
4. Wiederherstellung und Aktualisierung des Prozesskontrollblocks des neuen Prozesses (einschließlich der Änderung des Ausführungszustands auf "Running")

Beim Kontext-Switch wird der vollständige PCB des alten Prozesses (und damit sein gesamter Kontext) gesichert und der des neuen Prozesses wiederhergestellt. Der Aufwand ist umso größer, je mehr CPU-Register involviert sind.

3.3.2 Unterbrechungen

Motivation: Im Rechnerbetrieb treten häufig zeitlich nicht vorhersehbare Ereignisse ein, die in geeigneter Weise behandelt werden müssen.

Beispiel 3.6. *Angenommen, ein Prozeß* A *kommuniziert mit einem anderen Prozeß* B *auf einem entfernten Computer, indem er eine Nachricht über das Netzwerk sendet.*
Es wird davon ausgegangen, daß der entfernte Prozeß B *innerhalb einer festgelegten Zeit (einem sogenannten* timeout*) die Ankunft der Nachricht mit einer Quittung bestätigt.*
Ist nach einer festgelegten Anzahl von Sekunden, d.h. nach dem timeout, noch keine Quittung eingetroffen, so soll die Nachricht noch einmal gesendet werden.
Diese Anordnung (vgl. Abbildung 3.20) läßt sich auf zwei verschiedene Arten realisieren:

1. *Einerseits kann man den Prozeß* A *solange blockieren, bis die Quittung eingetroffen oder der timeout verstrichen ist. Trifft eine Quittung ein wird normal fortgefahren, andernfalls die Nachricht erneut gesendet. Dadurch entstehen offensichtlich relativ lange Leerlaufzeiten für Prozeß* A*, in denen nur auf die Quittung gewartet wird.*

2. *Daher wählt man meist die zweite Alternative, bei der davon ausgegangen wird, daß die Nachricht im Normalfall ordnungsgemäß übertragen wurde. Falls bis zum timeout jedoch keine Quittung eingetroffen ist, so wird ein Alarm ausgelöst.*

   Tatsächlich sendet das Betriebssystem dem Prozeß – der inzwischen in der Abarbeitung fortgefahren ist – ein Signal, das wiederum den Prozeß suspendiert, seine Register sichert und eine spezielle Prozedur zur Behandlung des Signals startet, die in unserem Beispiel das nochmalige Senden der wahrscheinlich verlorenen Nachricht umfassen könnte. Ist diese Aufgabe beendet, so wird der Prozeß in seinen alten Zustand (vor dem Eintreffen des Signals) zurückversetzt.

Im Falle des Wartens auf ein bestimmtes Ereignis (z.B. Antwort auf Anfrage) würde ein Nutzerprozess im Normalfall in den Zustand "blocked" übergehen, bis das jeweilige Ereignis eingetreten ist. Dabei wird jedoch unter Umständen kostbare Rechenzeit nicht optimal genutzt. Noch extremer wird die Situation, falls mehrere Anfragen nacheinander gestellt werden.
Durch geschicktes Programmieren und ein "nicht-blockierendes" Warten minimiert man die Zeit, die ein Prozess im Zustand "blocked" wartet. Der Prozess geht nicht in den Zustand "blocked" über, sondern bleibt im Zustand "running", falls Befehle vorhanden sind, die ohne Eintreten des Ereignisses, auf das gewartet wird, ausgeführt werden können.

Aber: *Für bestimmte Befehle (Programmteile) benötigt der Prozess das Ereignis, auf das gewartet wird (z.B. Ergebnisse von Anfragen).*

Unterbrechung: Eine Unterbrechung ist das Maschinenkonzept für die Behandlung nicht deterministischer, also unvorhersehbarer Abläufe. Ein gerade aktiver Prozess wird dabei unterbrochen und eine Unterbrechungsbehandlung eingeschoben. Man unterscheidet externe und interne Unterbrechungen. Analog zu Prozeduraufrufen müssen Informationen über den gerade aktiven Prozeß gespeichert werden, um später an dieser Stelle fortfahren zu können. PC und Programmstatuswort PSW müssen, weitere Informationen können, bei der Unterbrechungsbehandlung gesichert werden. Generell ist es notwendig, daß eine Unterbrechung kontrollierbar erfolgt, d.h. der Prozeß muß vollständig in seinem Zustand

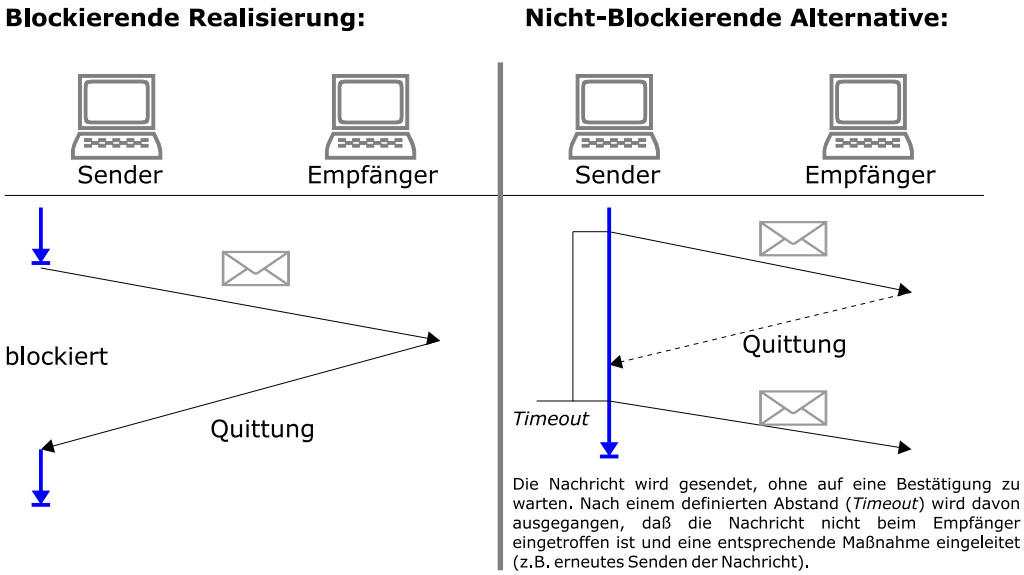

Abbildung 3.20: Blockierende und nicht-blockierende Realisierung von Signalen

beschrieben werden können, so daß eine weitere Abarbeitung später an dieser Stelle möglich ist. Je weniger Informationen zu einem bestimmten Zeitpunkt zur Beschreibung des Zustandes notwendig sind, desto "günstiger" ist eine Unterbrechung. In der Realität ist diese Situation meist nicht gegeben, da wenn z.B. ein katastrophaler Fehler auftritt (Division mit Null, Netz funktioniert nicht o.a.), der laufende Prozeß unterbrochen werden muß.

Externe Unterbrechung (Interrupt): Eine externe Unterbrechung wird durch Ereignisse außerhalb des zu unterbrechenden Prozesses ausgelöst, wie Signale von E/A-Geräten (Tastatur, Maus) oder Zeitgebern. Dies geschieht über einen sogenannten Interrupt Request, der durch eine Signalfolge an die CPU realisiert wird. Der normale Ablauf der CPU wird unterbrochen und eine Unterbrechungsbehandlung im Systemkern aktiviert wie in 3.21.

Interne Unterbrechung (Exception): Sie wird vom ausgeführten Prozess selbst ausgelöst und kann zur Ursache z.B. eine arithmetische Ausnahme haben. Sie bewirkt ebenfalls eine Unterbrechung der CPU und die Aktivierung der Unterbrechungsbehandlung im Systemkern wie in 3.22.

Unterbrechungsroutine (Interrupt Handler): Jede Unterbrechung muss vom Betriebssystem behandelt werden. Die Komponente, die die Unterbrechungsbehandlung durchführt, heißt Unterbrechungsroutine (Interrupt Handler) und gehört zu den Betriebssystem-Funktionen. Sie entscheidet z.B. darüber, ob aufgrund der Unterbrechung der zuletzt ausgeführte Prozess fortgesetzt werden kann oder zu einem anderen Prozess gewechselt werden muss.

Problem: Die Unterbrechungsroutine wird mit den entsprechenden Privilegien im Systemmodus ausgeführt. Muss Interrupt-bedingt ein Nutzerprozess unterbrochen werden, ist daher ein Wechsel vom Nutzer- in den Systemmodus erforderlich. Da die Unterbrechungsroutine

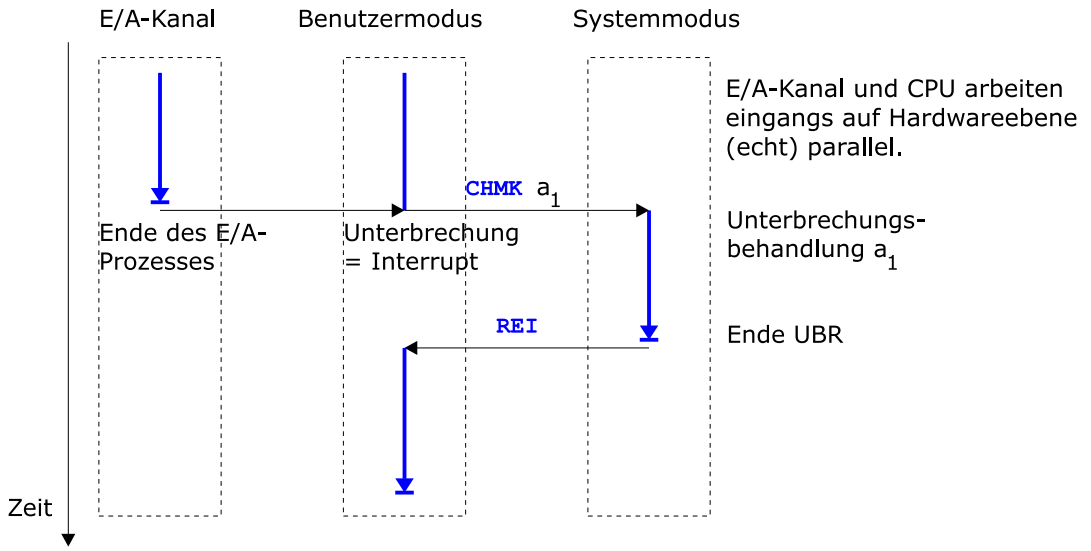

Abbildung 3.21: Prinzip eines Interrupts der CPU durch einen E/A-Kanal

keinen vollständigen Prozesskontext benötigt, soll der Kontext des zuletzt ausgeführten Befehls noch so lange aufrecht erhalten bleiben, wie noch die Möglichkeit besteht, dass dieser Prozess seine Ausführung wiederaufnehmen kann.

3.3.3 Moduswechsel

Moduswechsel: Bei einem Moduswechsel sind folgende Schritte erforderlich:

1. Aktualisierung und Sicherung des Prozesskontrollblocks des gerade aktiven Prozesses (also insb. des Programmstatusworts)
2. Durchführung des eigentlichen Moduswechsels durch Freigabe aller Privilegien
3. Sprung zur Unterbrechungsroutine (Programmzähler wird auf dessen Anfangsadresse gesetzt)

Analog zu Prozeduraufrufen müssen beim Moduswechsel also Informationen über den Status des bisher aktiven Prozesses gespeichert werden, um später an der gleichen Stelle fortfahren zu können. Falls der Interrupt Handler CPU-Register verwendet, so muss er die enthaltenen Daten zuvor selbst auf dem Stack sichern (Callee-saved) und wiederherstellen, bevor er die Kontrolle wieder an den ursprünglichen Prozess zurück gibt (Moduswechsel zurück in den Nutzermodus). Auch wenn nach der Unterbrechungsbehandlung ein anderer als der bisherige Nutzerprozess ausgeführt werden soll, muss die Unterbrechungsroutine die von ihm überschriebenen Register wiederherstellen, da erst dann eine vollständige Kontextsicherung des Prozesses im Rahmen eines Prozesswechsels vorgenommen werden kann (Moduswechsel zurück in den Nutzermodus mit anschließendem Kontext-Switch).

Ein Moduswechsel ist i.d.R. schneller als ein vollständiger Prozesswechsel, da die Zustandsinformationen nicht gesichert werden (vgl. Abbildung 3.23).

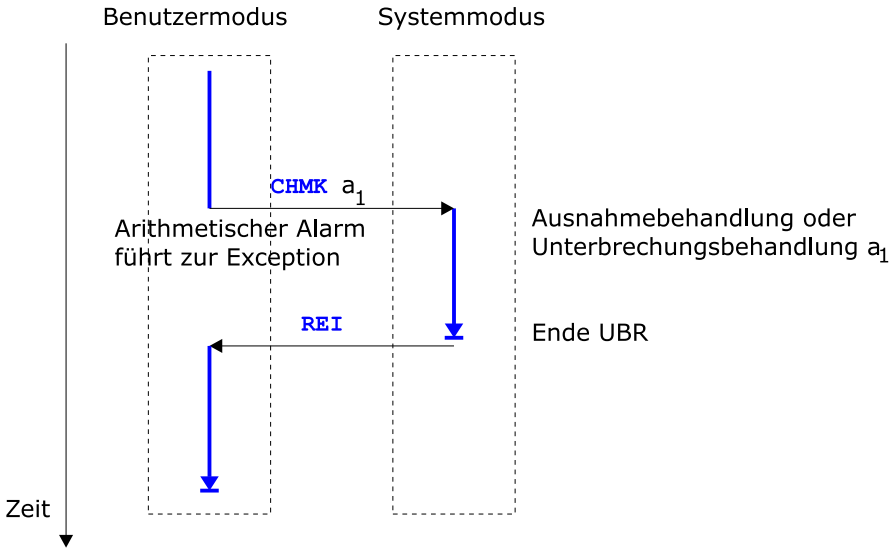

Abbildung 3.22: Prinzip einer Exception

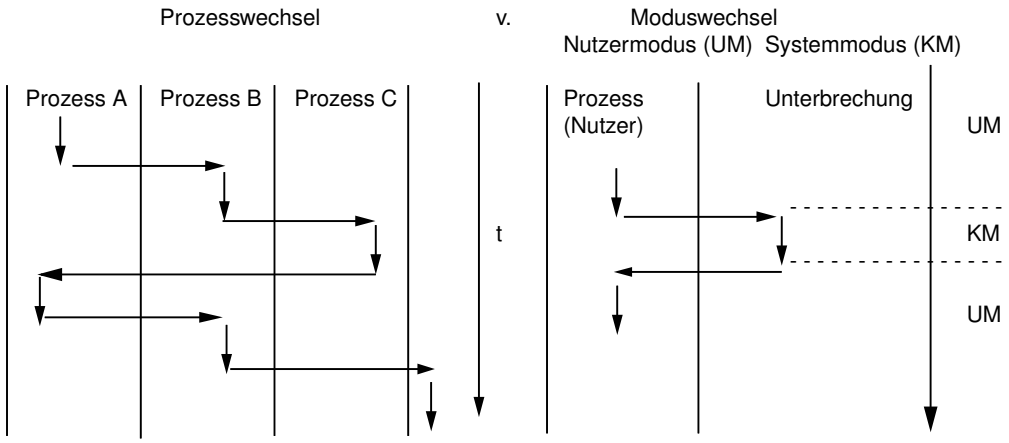

Abbildung 3.23: Prozess- und Moduswechsel

3.3.4 Konflikte bei Unterbrechungen

Ursachen für Konflikte: Bei der Abarbeitung von Unterbrechungen kann es zu Konflikten kommen. Dafür gibt es im Wesentlichen zwei Ursachen:

1. Während der Unterbrechungsbehandlung treten weitere Unterbrechungen auf.
2. Es treffen gleichzeitig (noch vor jeder Unterbrechungsbehandlung) mehrere Unterbrechungswünsche ein.

Beispiel 3.7. *Angenommen, ein Prozeß A habe zwei E/A-Kanäle beauftragt (z.B. Drucker und externes Laufwerk). Während der Unterbrechungsbehandlung von E/A-Kanal 1 beendet der E/A-Kanal seinen Auftrag für Prozeß A und löst damit eine weitere Unterbrechungsbehandlung aus, dies ergibt einen* ***Unterbrechungskonflikt****, wie in 3.24 dargestellt.*

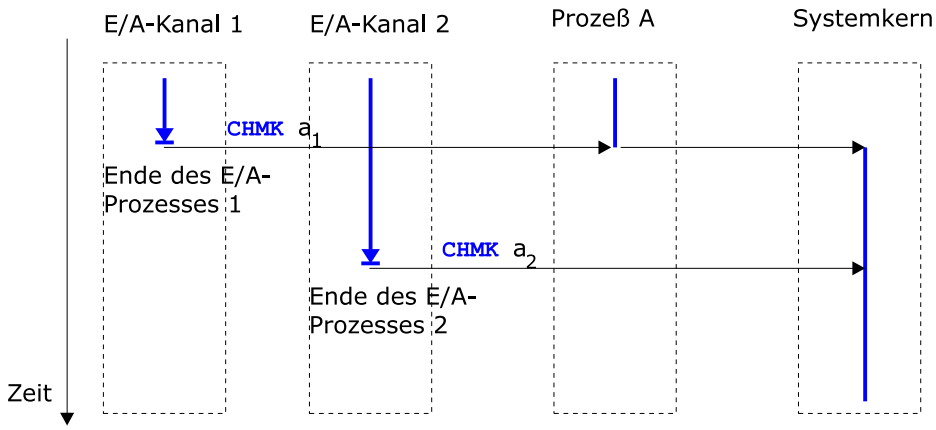

Abbildung 3.24: Beispiel für einen Unterbrechungskonflikt

Lösung von Konflikten: Zur Lösung von Konflikten werden Prioritäten von Unterbrechungen eingeführt. Dabei gilt:

- Benutzerprozesse haben die niedrigste Unterbrechungs-Priorität (0).
- Bei internen Unterbrechungen erhält die zugehörige Unterbrechungsroutine die gleiche Priorität wie der Prozess, der unterbrochen wurde.
- Externen Unterbrechungen sind festgelegte Prioritäten zugeordnet, z.B. von 0 bis 31, wenn 5 Bits für das IPL (siehe unten) zur Verfügung stehen.
- Die Unterbrechung einer Unterbrechungsbehandlung ist möglich, wenn die Priorität der neuen Unterbrechung höher ist, als die der gerade aktiven Unterbrechungsbehandlung. Andernfalls wird der Unterbrechungswunsch zurückgestellt.

Interrupt Priority Level (IPL): Das IPL ist Teil des Programmstatuswortes (PSW) im Prozesskontrollblock. und enthält die Unterbrechungs-Priorität zu einem Nutzer- oder Systemprozess bzw. zu einem Interrupt Handler.

3.3.5 Ausführung des Betriebssystems

Frage: Wie wird eigentlich das Betriebssystem selbst ausgeführt? Um diese Frage zu beantworten, wollen wir von den folgenden beiden Aspekten ausgehen:

1. Das Betriebssystem selbst funktioniert in der gleichen Art und Weise wie jede andere gewöhnliche Computersoftware, d.h. es ist ein Programm, das durch den Prozessor ausgeführt wird.

2. Das Betriebssystem muss oft die Kontrolle abgeben, und es hängt vom Prozessor ab, die Kontrolle wieder zuzuweisen.

Das Betriebssystem als Prozess? Wenn das Betriebssystem eine Sammlung von Programmen/Routinen ist und vom Prozessor auch wie jedes andere Programm ausgeführt wird, ist dann das in Ausführung befindliche Betriebssystem auch ein Prozess? Dazu gibt es eine Vielzahl von Antworten, die unterschiedliche Formen der Kontrolle zur Folge haben.

Konzept des separaten Kerns (Non-Process Kernel): Bei diesem Ansatz, vertreten in älteren Betriebssystemen, wird der Kern des Betriebssystems außerhalb jeden Prozesses ausgeführt. Wird ein in Ausführung befindlicher Prozess unterbrochen, dann muss sein Kontext gespeichert werden und die Kontrolle an den Betriebssystem-Kern übergeben werden. Das Betriebssystem verfügt über eigenen Speicher und seinen eigenen Systemkeller zur Kontrolle von Prozeduraufrufen und entsprechenden Rücksprüngen.

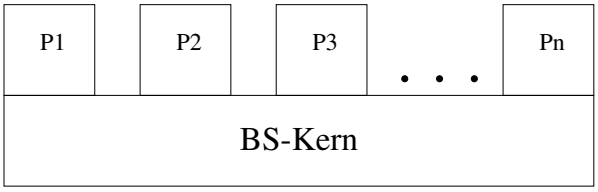

Abbildung 3.25: Ausführung des Betriebssystem-Kerns außerhalb jeden Prozesses

Konzept der Integration in die Nutzerprozesse (Execution within User Process: Ein für kleinere Computer gebräuchlicher Ansatz, bei dem die gesamte Betriebssystem-Software im Kontext jedes Nutzerprozesses ausgeführt wird. Dabei wird angenommen, dass das Betriebssystem eine Sammlung von Routinen ist, die von Nutzerprozessen aufgerufen werden können (Vgl. Support-Funktionen) und auch innerhalb der Umgebung der jeweiligen Nutzerprozesse ausgeführt werden. Lediglich Prozesswechsel-Routinen finden außerhalb dieser Umgebungen statt. Ein Vertreter dieses Ansatzes ist Unix System 5.

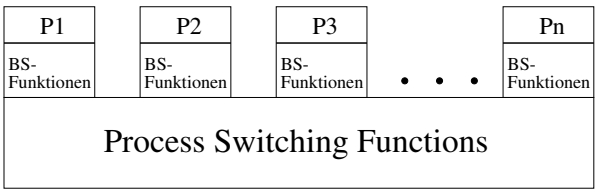

Abbildung 3.26: Ausführung des Betriebssystems durch die Prozesswechselfunktionen und Betriebssystem-Routinen

Konzept des prozessbasierten Betriebssystems (Process-based Operating System): Hier wird das Betriebssystem als eine Sammlung von Systemprozessem implementiert. Jede Funktion ist als separater Prozess organisiert. Nur eine kleine Menge an Code, die zur Realisierung der Prozesswechsel benötigt wird, wird außerhalb jeden Prozesses ausgeführt. Die Struktur des Betriebssystems ist damit vollkommen modular.

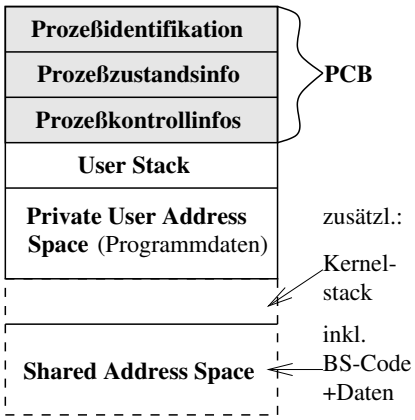

Abbildung 3.27: Prozeß-Image bei Integration der BS-Funktionen

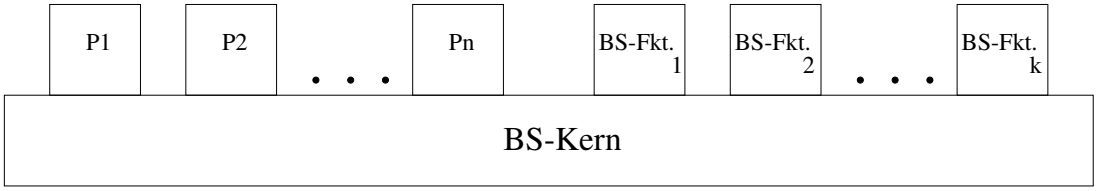

Abbildung 3.28: Implementierung des Betriebssystems als eine Sammlung von Systemprozessen

Beispiel 3.8. *Das Prozeßmanagement in UNIX (System V) verwendet das Konzept der Integration von Betriebssystem-Funktionen in die Nutzerprozesse, das hier vorgestellt wurde. Folglich existiert ein Nutzermodus und ein Systemmodus, und UNIX nutzt zwei Arten von Prozessen: Systemprozesse und Nutzerprozesse:*

– *Systemprozesse laufen im Systemmodus ab und führen Betriebssystem-Code aus um administrative und Verwaltungsfunktionen auszuführen (Literatur: Housekeeping Functions = "Hausmeisterfunktionen"), z.B. Bereitstellung von Speicher, Wechsel von Prozessen.*

– *Nutzerprozesse laufen im Nutzermodus ab, um Programme auszuführen, und im Systemmodus, um Befehle, die zum Kern gehören, auszuführen.*
Der Wechsel vom Nutzer- in den Systemmodus wird dabei durch einen Systemaufruf ausgelöst. Ursache dafür ist eine interne oder externe Unterbrechung.

Bezüglich der Prozeßzustände teilen wir den Zustand "Running" noch einmal in 2 Zustände auf: "User Running" und "Kernel Running".

Als Zustandsübergangsdiagramm ergibt sich ein Modell mit 9 Zuständen:

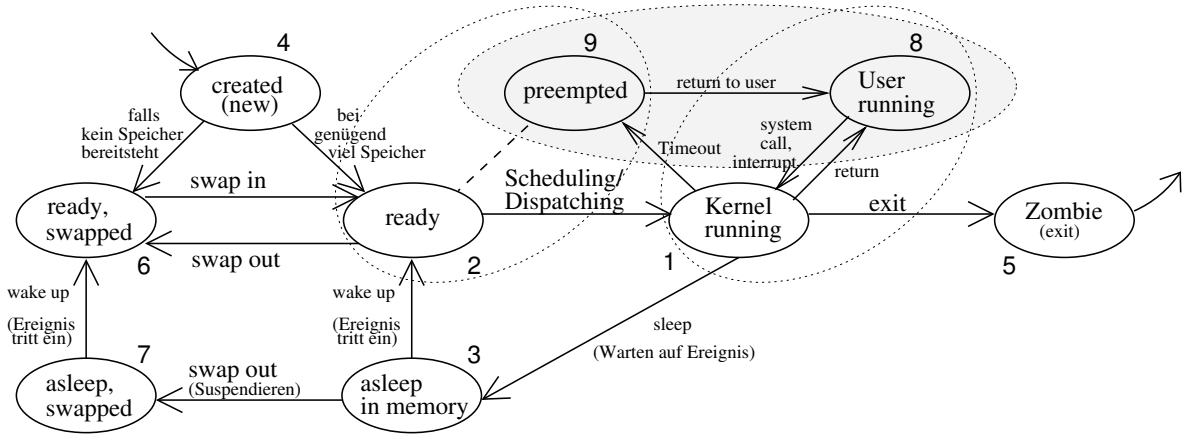

Abbildung 3.29: 9-Zustands-Modell (UNIX)

Dieses Modell ist eine Erweiterung des 7-Zustands-Modells (Abbildung 3.13) dahingehend, daß

1. *der Zustand "Running" in "Kernel Running" und "User Running" aufgeteilt wird und*
2. *der Zustand "Ready" in "Ready" und "Preempted" aufgeteilt wird: "Ready" ist dabei der Folgezustand nach dem Generieren eines neuen Prozesses oder einer Blockierung. "Preempted" ergibt sich durch die Timeout-bedingte Unterbrechung eines in Ausführung befindlichen Prozesses.*

Ferner sind einige Begriffe variiert:

- *Statt dem bekannten "Suspend" wird hier "Swapped" verwendet.*
- *Statt dem bekannten "Blocked" wird hier "Asleep" verwendet.*
- *Statt "New" bzw. "Exit" sind hier "Created" bzw. "Zombie" genannt.*

Die Prozeßbeschreibung wird durch das UNIX Process Image realisiert.
Dieses besteht aus 3 Teilen:

1. *User-Level Context mit Prozeßtext (ausführbare Maschinenbefehle des Programms), Prozeßdaten (Daten, die vom Programm in diesem Prozeß verwendet werden), dem User Stack (Nutzerkeller) und Shared Memory.*
2. *Register Context mit Programmzähler (PC), Prozessorstatusregister, Stackpointer und Hardwareabhängigen Registern für allgemeine Zwecke.*
3. *System-Level Context mit Prozeßtabelleneinträgen, Prozeßkontrollinformationen, Tabellen zur Abbildung von virtuellen auf physikalische Adressen und dem Kernel Stack.*

Die Generierung von Prozessen wird in UNIX im Systemmodus mittels der Operation FORK ausgeführt. Ruft ein Prozeß eine FORK-Operation auf, so führt das Betriebssystem die folgenden Funktionen aus:

1. *Es stellt in der Prozeßtabelle einen Bereich für den neuen Prozeß bereit.*
2. *Es ordnet dem Kindprozeß eine eindeutige ID zu.*
3. *Es macht eine Kopie des Process Images des Elternprozesses - ausgenommen sind dabei jegliche Teile des Shared Memory.*
4. *Das Betriebssystem aktualisiert (d.h. erhöht) die Zähler aller Dateien, die dem Elternprozeß gehören, um anzuzeigen, daß ein neuer Prozeß nun auch Zugriff hat.*
5. *Das Betriebsssystem überführt den neuen Prozeß in den Zustand "Ready".*
6. *Es übergibt dem Elternprozeß die ID des Kindprozesses und dem Kindprozeß den Wert Null.*

Alle diese Schritte werden im Systemmodus des Elternprozesses ausgeführt. Danach kann - als Bestandteil einer Dispatcherroutine - eine der folgenden Alternativen ausgeführt werden:

1. *Die Kontrolle wird an den Nutzermodus des Elternprozesses zurückgegeben - dieser Prozeß kann dann an der Stelle nach dem FORK-Befehl weiter mit der Ausführung fortfahren. D.h. die Kontrolle bleibt im Elternprozeß.*
2. *Die Kontrolle wird an den Kindprozeß gegeben. Dieser Kindprozeß führt die Abarbeitung an der gleichen Stelle wie sein Elternprozeß fort, d.h. nach dem RETURN des FORK-Aufrufs.*
3. *Die Kontrolle wird einem ganz anderen Prozeß gegeben. Dabei bleiben sowohl der Eltern- als auch der Kindprozeß im Zustand "Ready".*

In der Regel ist es schwierig, diese Generierung eines Kindprozesses zu veranschaulichen, weil sowohl Eltern- als auch Kindprozeß den gleichen Code ausführen. Dieser Tatsache kann man dadurch entgegenwirken, daß man den RETURN-Parameter des FORK-Aufrufs testet. Dieser ist beim Elternprozeß eine Zahl ungleich Null, beim Kindprozeß der Wert Null.

4

Threads

- Multithreading
- Threadzustände
- User-level-Threads
- Kernel-level-Threads
- Kombinierte Konzepte
- Andere Formen paralleler Abläufe

Inhaltsangabe

Motivation: Bislang wurden dem Konzept eines Prozesses zwei unterschiedliche Aufgaben zugeordnet:

1. Ein Prozess kann als Eigentümer und Verwalter von Ressourcen betrachtet werden.
   D.h. einem Prozess ist ein virtueller Adreßraum im Hintergrundspeicher zugeordnet, in dem das Prozess Image abgelegt ist. Als Schutzmaßnahme kann ein Prozess nicht auf den virtuellen Adressraum eines anderen zugreifen. Zeitweise können ihm z.B. auch E/A-Geräte, E/A-Kanäle und Dateien zugeordnet werden.

2. Ein Prozess kann als Einheit, die eine gewisse Aufgabe erledigt (Ausführung eines Programms), betrachtet werden.
   D.h. ein Prozess ist ein Ausführungspfad (Trace) durch ein oder mehrere Programme. Diese Ausführung kann unterbrochen werden, weshalb einem Prozess Ausführungszustände ("Running", "Ready", ...) zugeordnet werden, sowie eine Priorität, welche die Dringlichkeit der Ausführung im Betriebssystem steuert.

Diese beiden Aufgaben sind vollkommen unabhängig voneinander!
Deshalb können beide Aufgaben innerhalb eines Betriebssystems auch unabhängig voneinander erfüllt werden.

Zu diesem Zweck wird folgende Begriffswelt eingeführt:

– Die Einheit, die den Eigentümer von Ressourcen bezeichnet, wird weiter Prozess genannt. ABER:

– Eine Einheit, die eine gewisse Aufgabe erledigt, wird Thread (Faden) oder leichtgewichtiger Prozess genannt (lightweight process).

Bislang entsprach einem Prozess auch ein Thread. (Sonderfall Singlethread $\rightarrow$1:1-Relation)
Nun wollen wir einen Prozess durch die Ausführung mehrerer Threads realisieren. Es werden also einem Prozess mehrere Threads ($Thread1, Thread2, \ldots, Threadn$) in einer $1:n$-Relation zugeordnet.
Dieser Sachverhalt wird durch einen neuen Begriff beschrieben, das Multithreading.

4.1 Multithreading

Beim Zusammenspiel von Threads und Prozessen können 4 Fälle unterschieden werden:

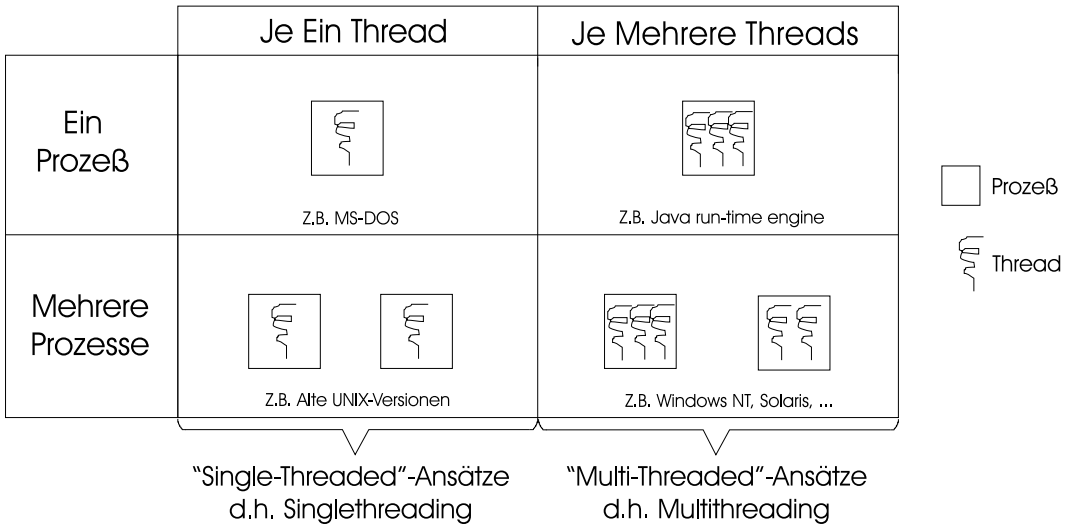

Abbildung 4.1: Die 4 Fälle beim Zusammenspiel von Threads und Prozessen

Ein Einsatzgebiet für den sinnvollen Einsatz von Threads wäre z.B. ein Multicast-Aufruf mit blockierenden Requests.

Wir wollen im Folgenden Multithread-Umgebungen betrachten.

Mit einem Prozess ist dabei assoziiert:

- ein virtueller Adressraum, in dem das Prozessimage abgelegt wird
- ein exclusiver Zugang zum Prozessor, zu anderen Prozessen (bei der Interprozeßkommunikation), zu Dateien und zu E/A-Geräten sowie E/A-Kanälen
- Zugriffsrechte

D.h. der Prozess ist die Einheit, die auf Ressourcen zugreift und Zugriffsrechte klärt.

Innerhalb eines Prozesses werden ein oder mehrere Threads ausgeführt, die dessen virtuellen Adressraum nutzen und im Bedarfsfall gemeinschaftlich auf diesen zugreifen können. Es ist im Gegensatz dazu wichtig zu beachten, dass mehreren Prozessen immer disjunkte virtuelle Adressräume zugeordnet werden.
Jeder der Threads innerhalb eines Prozesses bekommt folgende Bestandteile zugeordnet:

- einen Zustand der Threadausführung ("Running", "Ready", ...)
- falls sich der Thread nicht im Zustand "Running" befindet: Thread-Kontext (Speicherplatz nötig), insbesondere Programmzähler (PC) sichern
- zwei Stacks für die Ausführung (user stack; kernel stack)
- "etwas" Speicherplatz für lokale Variablen
- Zugriff auf Speicher und Ressourcen des zugehörigen Prozesses, die mit allen anderen Threads dieses Prozesses geteilt werden.

Im Folgenden soll der Unterschied zwischen einem Prozess und einem Thread aus der Sicht des Prozessmanagements betrachtet werden.

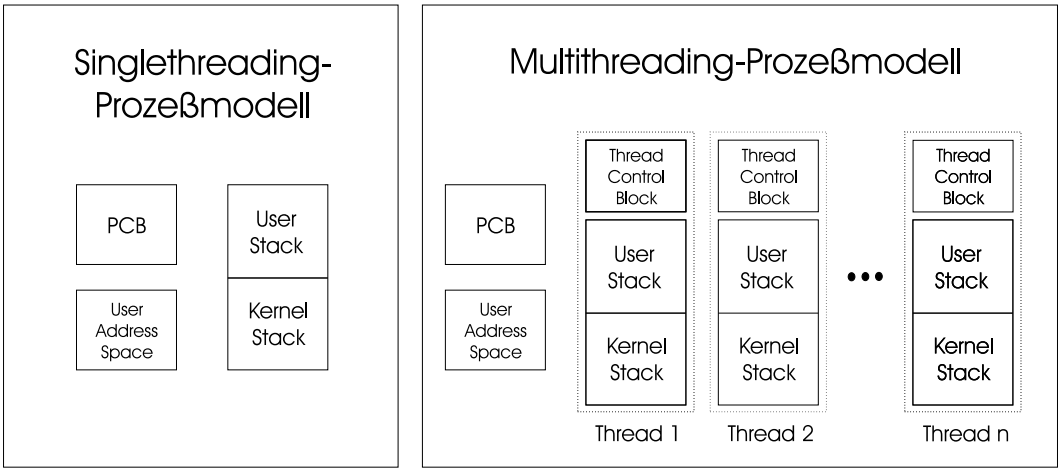

Abbildung 4.2: Singlethreading-Prozessmodell vs. Multithreading-Prozessmodell

Singlethreading: Zur Laufzeit werden die Prozessorregister vom Prozess kontrolliert. Befindet sich der Prozess nicht im Zustand “Running”, so wird der Inhalt der Register abgespeichert.

Multithreading: Zuordnung von PCB und User Adress Space zum Prozess bleibt, aber jeder Thread bekommt zusätzlich einen Kontrollblock, den sog. TCB, der für jeden Thread die Register, den Zustand und andere thread-bezogene Informationen enthält.

Dieses Konzept führt dazu, daß alle Threads eines Prozesses den gleichen Adreßraum nutzen und auf die gleichen Daten zugreifen.
Z.B. wenn ein Thread das Ergebnis einer Rechnung im Adreßraum ablegt, so können alle anderen Threads dieses Prozesses auch darauf zugreifen. ⇒Sicherheitsprobleme!

Vorteil des Threadkonzepts: verschiedene Leistungssteigerungen

– Zur Generierung eines neuen Threads in einem existierenden Prozess ist wesentlich weniger Zeit notwendig, als zur Generierung eines neuen Prozesses, teilweise Faktor 10!

  Beispiel: File-Server eines LANs

  - Für jede Dateianfrage genügt es, anstelle eines neuen Prozesses, einen neuen Thread zu generieren.
  - In kurzen Zeitabständen werden viele Threads generiert und terminiert.

– Threads machen die Kommunikation zwischen verschiedenen ausgeführten Programmen effizienter, da sie untereinander kommunizieren können (z.B.: über abgelegte Daten), ohne den Betriebssystem-Kern zu involvieren.

– Kommt es zu Blockierungen, so entsteht weniger Wartezeit, wenn nur einzelne Threads blockiert sind und andere abgearbeitet werden können.

– Kontextwechsel unter Threads innerhalb eines Prozesses erfordern weniger Zeit als Kontextwechsel von Prozessen.

Besonderheiten des Threadkonzepts:

– Durch den gemeinsamen Adreßraum sind Daten einzelner Threads eines Prozesses bezüglich anderer Threads nicht sicher, da von jedem anderen Thread innerhalb des Prozesses auf diese Daten zugegriffen werden kann.

– Erfolgt ein Swapping des übergeordneten Prozesses, so werden alle Threads gleichzeitig mit ausgelagert. Und analog: Terminiert der übergeordnete Prozess, so terminieren mit ihm alle Threads.

4.2 Threadzustände

Analog zu den Prozessen sind die grundlegenden Zustände eines Threads: “Running”, “Ready” und “Blocked”. Es macht keinen Sinn, Zustände zur Suspendierung den Threads zuzuordnen, da die Auslagerung ein Konzept von Prozessen ist. (Grund: gemeinsamer Adressraum aller Threads eines Prozesses)
Geht der Prozess in einen “suspended”-Zustand über (Auslagerung von Daten in den Hintergrundspeicher), so sind alle Threads betroffen, die mit diesem Prozess in Verbindung stehen. Entsprechendes gilt für den Zustand “exit”.

Als Zustandsübergangsdiagramm ergibt sich für die Threads:

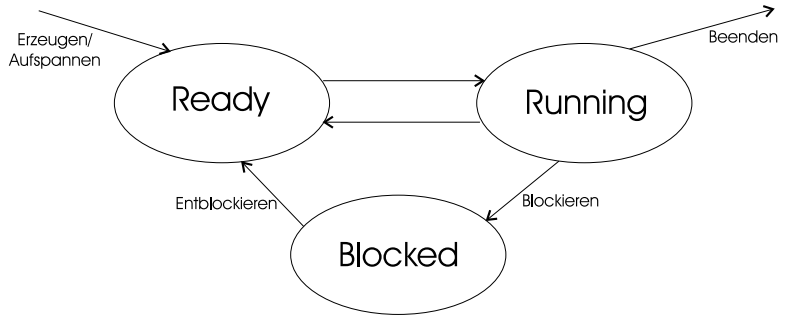

Abbildung 4.3: Thread-Zustandsübergangsdiagramm

Annahme: Der Prozess befindet sich im Zustand “Running”. Bei Ein-Prozessor-Systemen kann zu einem Zeitpunkt nur einem Thread der Prozessor zugeteilt werden. Zu beachten ist dabei, ob die Blockierung eines Threads durch das Blockieren des zugehörigen Prozesses bedingt ist, oder ob alle anderen Threads weiter abgearbeitet werden können. Es können z.B. einzelne Threads auf ein Ereignis (E/A-Geräte,...) warten und blockiert sein, während gleichzeitig andere Threads nicht blockiert sind.
Insgesamt kann man sich also überlegen, Zustände nach den Kriterien global (für einen gesamten Prozess) und lokal (für die einzelnen Threads) zu unterscheiden.

Threadarten
Bei Threads unterscheidet man zwei Arten:

4.3 User-level-Threads (ULT)

– Bei User-level-Threads ist das Threadmanagement Aufgabe der Anwendung, und der Betriebssystem-Kern braucht von der Existenz solcher Threads gar nichts zu wissen.

– Jede Anwendung kann als multithreaded programmiert werden, indem sogenannte Threadbibliotheken genutzt werden.

– Diese Threadbibliotheken sind eine Sammlung von Routinen, die gerade zum Zwecke des User-level-Thread-Managements bereitgestellt werden. Insbesondere enthalten die Threadbibliotheken Code für:

  - die Generierung und Terminierung von Threads,
  - die Nachrichten- und Datenübermittlung zwischen Threads,
  - das Scheduling der Threadausführung, sowie
  - das Sichern und Löschen von Threadkontexten.

– Ausgangssituation: Eine Anwendung beginnt mit einem Thread, und die Ausführung erfolgt auch in diesem Thread.
  Der Prozess befindet sich im Zustand “Running”, er wird vom Betriebssystem-Kern verwaltet.

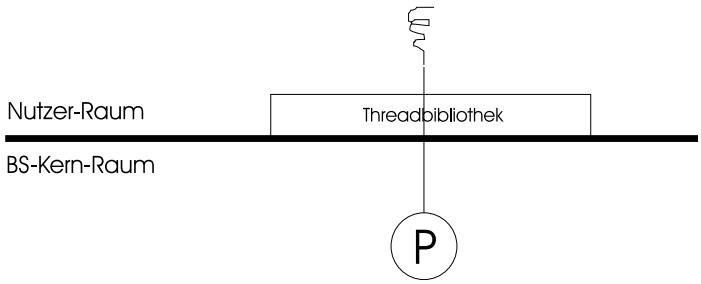

Abbildung 4.4: User-level-Thread-Modell

– Die Anwendung kann nun jederzeit einen neuen Thread generieren, der innerhalb desselben Prozesses läuft. Dies geschieht durch Zugriff auf die entsprechenden Routinen in der Threadbibliothek mittels eines Prozeduraufrufs.
  Die Threadbibliothek generiert eine Datenstruktur für den neuen Thread und übergibt die Kontrolle dann an einen Thread innerhalb des Prozesses, der sich im Zustand “Ready” befindet - die Auswahl dieses Threads erfolgt mittels Schedulingalgorithmen.

Bemerkung: Während bei dieser Ausführung die Kontrolle an die Threadbibliothek übergeben wird, muß der Kontext des aktuellen Threads natürlich gesichert sein und zur Weiterausführung dieses Threads wird der Kontext wieder geladen. (Kontext: Inhalt der Nutzerregister, Programmzähler, Stack-Pointer)

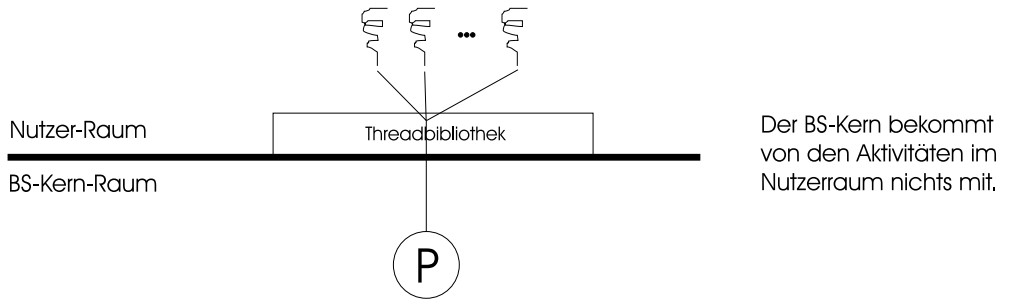

Abbildung 4.5: User-level-Thread-Modell 2

Vorteile solcher User-level-Threads liegen in folgendem begründet:

– Die Threadwechsel + Threaderzeugung/-terminierung benötigen keine Privilegien des Systemmodus, da das Threadmanagement innerhalb des Nutzeradreßraumes eines einzelnen Prozesses stattfindet. Damit wird Zeit für Modiwechsel (System↔Nutzermodus) eingespart.

– Das auf BS-Ebene implementierte Scheduling kann auf Thread-Ebene anwendungsspezifisch realisiert werden.

– Dieser Mechanismus kann in jedem Betriebssystem ablaufen, ohne daß Betriebssystem-Kern-Erweiterungen vorgenommen werden müssen.

Im Prinzip wird durch User Level Threads nur ein Multithreading simuliert. Tatsächlich werden alle Konzepte von Anwendungsprogrammierern implementiert, wodurch Vorteile des Thredkonzepts verlorengehen.
Nachteile bestehen in Folgendem:

1. Wird ein Thread blockiert, so blockiert gleichzeitig der gesamte Prozess, d.h. auch die Menge aller anderen Threads.

2. Reine User-level-Threads können in einer Multiprozessorumgebung nicht parallel ausgeführt werden, da der Betriebssystem-Kern einem Prozess auch nur einen Prozessor zuordnet.

Abhilfe zu 1. Es wird die Technik des "Jacketings" genutzt: ein blockierender Systemaufruf wird dabei in einen nicht blockierenden Systemaufruf transformiert.
Z.B. E/A-Gerät erst antesten, ob es "busy" ist - falls ja, dann zu anderem Thread wechseln und später neu probieren anstatt direkt zu blockieren.

Abhilfe zu 2. Man sollte also überlegen, ob anstelle der User-level-Threads nicht doch vielleicht separate Prozesse verwendet werden sollten, auch wenn dadurch wieder Prozesswechsel nötig werden.

Fazit: User Level Threads sind relativ einfach umsetzbar, realisieren aber wenige Vorteile.

4.4 Kernel-level-Threads (KLT)

– In einer reinen Kernel-level-Thread-Umgebung wird das Threadmanagement vom Betriebssystem-Kern durchgeführt,

– dabei kann jede Anwendung als multithreaded programmiert werden, das Threadmanagement wird vom Betriebssystem-Kern übernommen.

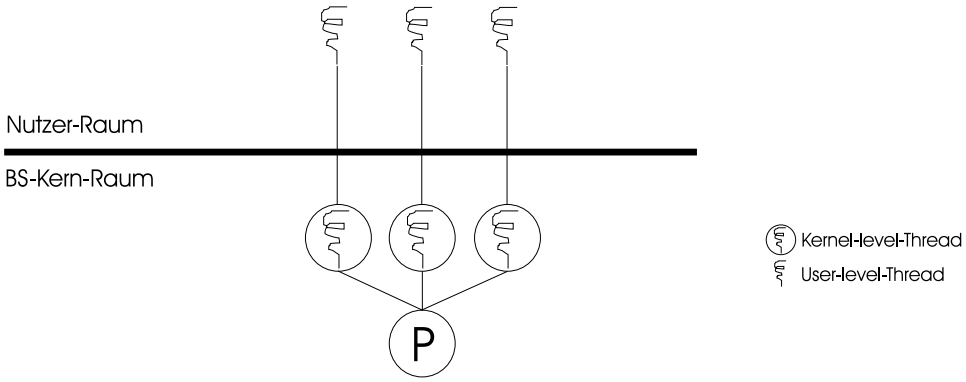

Abbildung 4.6: Kernel-level-Thread-Modell

– Eine Umsetzung ist z.B. in Windows NT gegeben.

Vorteile der KLTs:

– Im Gegensatz zu echten Prozessen können KLTs deutlich schneller erzeugt, gewechselt und terminiert werden.

– Der Betriebssystem-Kern kann mehrere Threads eines Prozesses auf verschiedenen Prozessoren einer Multiprozessorumgebung ausführen.

– Falls ein Thread blockiert ist, so kann die Kontrolle einem anderen Thread desselben Prozesses übergeben werden, der sich im Zustand “ready” befindet.

Nachteile der KLTs:

– Wird die Kontrolle von einem Thread an einen anderen Thread desselben Prozesses übergeben, so ist jedesmal ein Moduswechsel erforderlich, d.h. diese Ausführung führt zu einer Verlangsamung.

4.5 Kombinierte Konzepte

– Einige Betriebssysteme, wie z.B. Solaris, stellen ein kombiniertes Konzept bereit.

– Die Generierung von Threads wird im Nutzerraum durchgeführt, die ULTs werden dann auf eine beliebige, auch kleinere oder größere Anzahl von KLTs abgebildet.

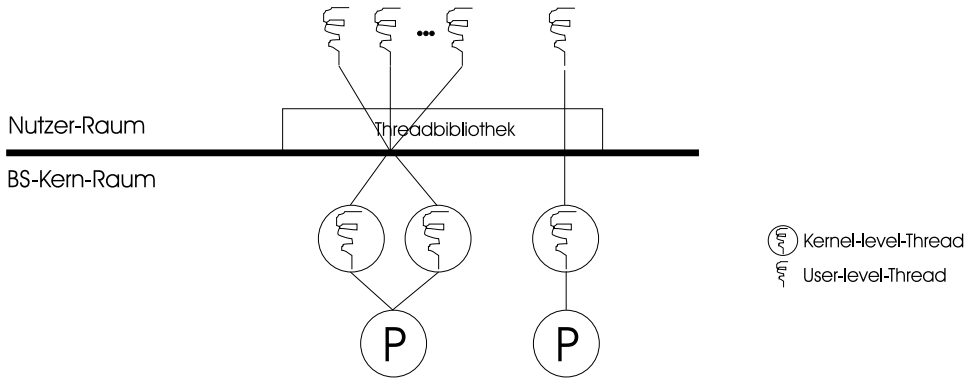

Abbildung 4.7: Thread-Modell für kombinierte Konzepte

– Dabei können mehrere Threads innerhalb desselben Prozesses auf einem Mehrprozessorrechner auch parallel ausgeführt werden und

– ein blockierender Thread blockiert nicht den gesamten Prozess.

– Ziel ist es in jedem Fall, die Vorteile der ULT- und KLT-Ansätze zu kombinieren und die Nachteile zu minimieren.

Abschließend sollen die verschiedenen Relationen zwischen Threads und Prozessen noch einmal zusammengefaßt werden:

#Threads:#Prozesse

1:1 jedem Thread ist ein Prozess mit eigenem Adreßraum und entsprechenden Ressourcen zugeordnet (z.B. ältere UNIX-Versionen)

n:1 einem Prozess ist ein Adreßraum und eine gewisse Menge von Ressourcen zugeordnet; innerhalb dieses Prozesses können verschiedene Threads generiert und ausgeführt werden (z.B. Windows NT, Solaris, ...)

Neben diesen bereits betrachteten Ansätzen ist auch denkbar:

1:n ein Thread kann von einer Prozessumgebung zu einer anderen migrieren (z.B. Clouds Operating System, Emerald System, ...)

n:m kombiniert die n:1 und 1:n-Ansätze (z.B. Operating System TRIX)

4.6 Andere Formen paralleler Abläufe

Motivation:

– Traditionell gesehen wird ein Computer immer als Maschine betrachtet, die Befehle sequentiell abarbeitet.

– In Wirklichkeit werden aber bei jedem Computer auch parallele Abläufe vorkommen, z.B. Signale gleichzeitig generiert oder beim Pipelining Abläufe gleichzeitig ausgeführt.

– Mit den sinkenden Kosten stellen Computer immer mehr Möglichkeiten für Parallelität bereit, wodurch ihre Leistung steigt.

– Es gibt drei verbreitete Ansätze, die Parallelität durch das Replizieren von Prozessoren ermöglichen:

  - Master/Slave Architektur
  - Symmetrisches Multiprocessing (SMP)
  - Cluster

Einordnung

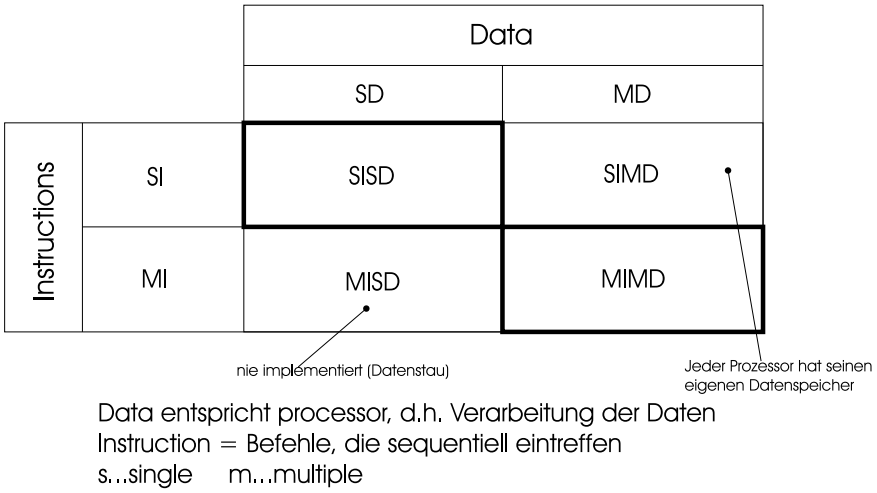

Abbildung 4.8: Einordnung von “Parallele Prozessoren”

SISD: klassischer Rechner mit 1 Prozessor, bei dem über Adress- und Datenbus Befehle nacheinander bereitgestellt werden.
→keine Parallelität in der Ausführung (Pipelining ausgenommen →TGI)
MISD: Situation: Daten/Befehle werden über mehrere Busse bereitgestellt, es ist jedoch nur ein Prozessor vorhanden, der diese Daten verarbeiten kann (Gegenteil des von Neumann'schen Flaschenhalses!) →Diese Architektur wurde nie implementiert. *SIMD, MIMD:* tatsächliche parallele Verarbeitung von Daten auf mehreren Prozessoren.

Resümee: Hier bei parallelen Prozessoren ist nur SIMD und MIMD interessant.

Parallele Prozessoren

Der SMP-Ansatz hat die Vorteile Verteilter Systeme (Fehlertransparenz, keinen Flaschenhals beim Master, ...) Aber er verkompliziert das Betriebssystem: Es muß gewährleistet werden, dass zwei Prozessoren nie denselben Prozess auswählen. Ferner müssen Ressourcen fair zugeordnet werden.
Die SIMD-Komponente (1 Bus, m Prozessoren) kann jedoch kaum Abhilfe bezüglich des von

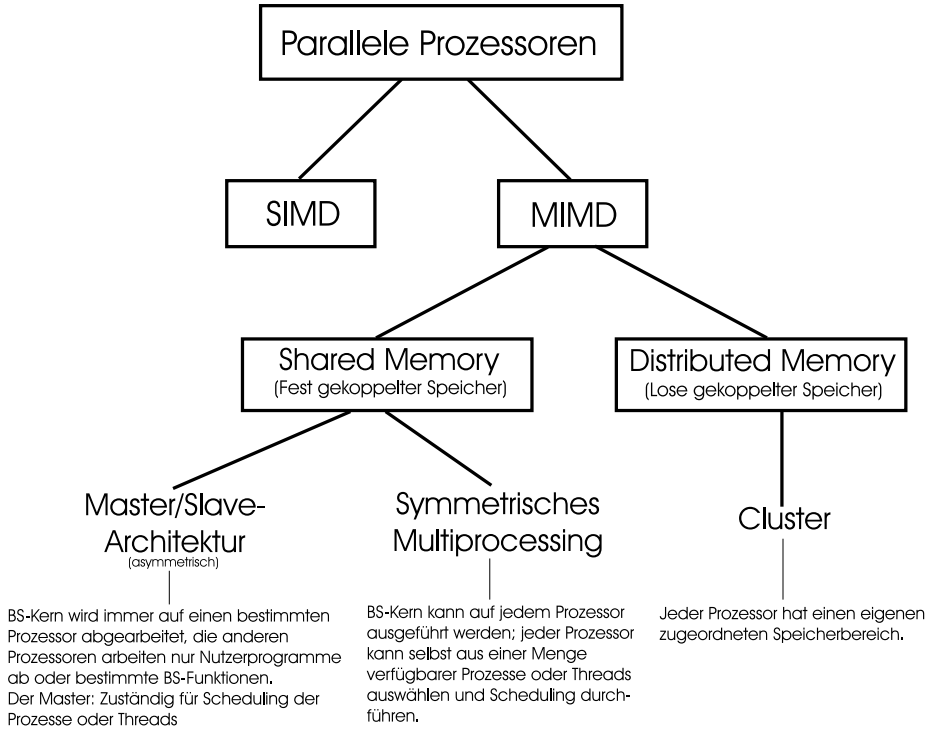

Abbildung 4.9: Parallele Prozessoren

Neumann'schen Flaschenhalses schaffen. Steht für alle Prozessoren nur ein Bus bereit, kann die Problematik eher verschärft werden. Ist dagegen pro Prozessor ein Bus vorhanden, so liegt eine mit SISD vergleichbare Situation vor.

Prinzip der SMP-Organisation

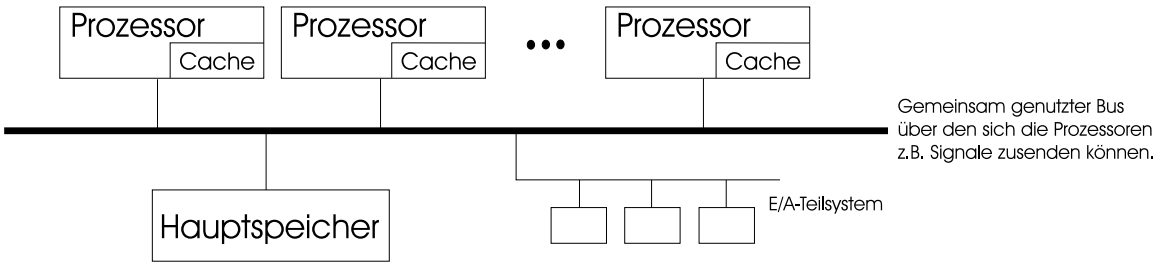

Abbildung 4.10: Prinzip der SMP-Organisation

– Jeder Prozessor besitzt seine eigene Kontrolleinheit, seine eigene ALU und eigene Register.

– Ferner besteht von jedem Prozessor aus Zugriff zum gemeinsamen Hauptspeicher und den E/A-Geräten.

5

Scheduling

- Scheduling und Scheduling-Verfahren als Basis für Multiprogramming
- Zuteilung des Prozessors an mehrere Prozesse

Inhaltsangabe

In den vorhergehenden Abschnitten ist oft die Situation aufgetreten, dass mehrere Prozesse (quasi) gleichzeitig ausgeführt werden können. In solchen Fällen muss das Betriebssystem entscheiden, welcher Prozess als erster ausgeführt werden soll.
Denjenigen Teil des Betriebssystems, der diese Entscheidung übernimmt, bezeichnet man als *Scheduler*.

5.1 Das Prinzip des Schedulings

Scheduling wird notwendig, sobald

1. mindestens ein Prozess *A* im Zustand *running* ist und
2. ein oder mehrere andere Prozesse im Zustand *ready* darauf warten, dass ihnen die CPU zugeteilt wird.

Tritt die Freigabe des Prozesses ein (oder wird sie erzwungen), so stellt sich die Frage, welcher der Prozesse im Zustand *ready* nun dem Prozessor zugewiesen werden sollte.
Dieser Entscheidung sollte offensichtlich eine Strategie (mittels eines Algorithmus) zugrunde liegen.
Die *Aufgabe eines Schedulers* ist es, auf der Basis einer vorgegebenen Strategie die Entscheidung zu treffen, welcher Prozess als nächster dem Prozessor zugewiesen werden soll. Seine Aufgabe ist es jedoch nicht, einen Mechanismus für die eigentliche Zuweisung zur Verfügung zu stellen (dies wird außerhalb des Schedulers, aber auch im Betriebssystem, nämlich in einem *Dispatcher*, realisiert, wie in Kapitel 5.3 erläutert).

5.1.1 Varianten des Schedulings

Beim Scheduling unterscheidet man zwei grundlegende Varianten:

1. **Nicht preemptives Scheduling** oder *Run-to-Completion* wird z.B. beim **Stapelbetrieb** eingesetzt, Aufträge werden ohne Unterbrechung bis zum Ende ausgeführt. Diese Form des Schedulings war im wesentlichen in früheren Systemen gebräuchlich (z.B. bei der Verwendung von Lochkarten).
2. **Preemptives Scheduling:** Bei der Verwendung von preemptivem Scheduling können Prozesse zu jedem Zeitpunkt unterbrochen (suspendiert) werden, so dass ein anderer Prozess zur Ausführung kommen kann. Dieses Scheduling kann jedoch zu kritischen Abläufen oder Bereichen führen, die eine aufwendige Behandlung (z.B. mittels Semaphoren oder Monitoren) notwendig machen (alle heutigen Systeme).

5.1.2 Anforderungen an einen Scheduling-Algorithmus

Die Anforderungen an einen Scheduling-Algorithmus hängen sehr stark vom System ab, in dem Prozesse verwaltet werden sollen. Es gibt keinen optimalen Scheduling-Algorithmus für alle möglichen Systeme. Batch-Systeme erfordern einen hohen Durchsatz wohingegen Dialog-Systeme auf schnelle Antwortzeiten hin optimiert werden müssen. Im Wesentlichen unterscheidet man daher drei Klassen von Systemen:

– Batch-System (Stapelverarbeitungssystem)

– Interaktives System und

– Echtzeitsystem

Die folgenden Anforderungen sind allen Systemen gemein:

Fairness Jeder Prozess sollte einen gerechten Anteil an der Prozessorzeit erhalten (insbesondere sollte ein Prozess nur endliche Zeit warten müssen).

Policy Enforcement Das gewählte Verfahren wird stets durchgesetzt, d.h. es gibt keine Ausnahmen.

Balance Alle Teile des Systems sind (gleichmäßig) ausgelastet.

Datensicherheit Es können keine Daten oder Prozesse verloren gehen.

Skalierbarkeit Die mittlere Leistung wird bei wachsender Last (Anzahl von Prozessen) beibehalten. Es gibt keine Schwelle, ab der das Scheduling nur noch sehr langsam oder gar nicht mehr funktioniert.

Effizienz Der Prozessor sollte möglichst immer vollständig ausgelastet sein.

Zusätzlich hat jedes der oben genannten Systeme seine spezifischen Anforderungen an das optimale Scheduling-Verfahren. Man unterscheidet nutzer- und systemorientierte Kriterien zur Bewertung der Algorithmen. Nutzerorientierte Kriterien spielen in interaktiven Systemen ein Rolle, wohingegen systemorientierte Kriterien in Stapelverarbeitungssystemen bzw. Echtzeitsystemen im Vordergrund stehen. Die Systemen unterscheiden sich in folgenden Anforderungen:

– Batch-Systeme (Stapelverarbeitungssysteme)

  Durchsatz Maximierung der Prozesse pro Zeiteinheit.

  Verweildauer Minimierung der Zeit vom Start bis zur Beendigung eines Stapel-Prozesses.

  Prozessorauslastung Konstante und maximale Auslastung der CPU.

– Interaktive Systeme

  Antwortzeit Die Antwortzeit für die interaktiv arbeitenden Benutzer sollte minimal sein ($\rightarrow$möglichst schnelle Abarbeitung von Nutzerprozessen)

  Verhältnismäßigkeit Der Algorithmus soll auf die Erwartungen des Benutzers eingehen (z.B. darf die Reaktion auf einfaches Klicken eines Icons nicht zu lange dauern).

  Interaktion Die Anzahl interagierender Nutzer sollte maximal sein.

– Echtzeitsysteme

  Sollzeitpunkte Zeitschranken müssen eingehalten werden, d.h. gewisse Berechnungen (Prozesse) müssen zu bestimmten Zeitpunkten beendet sein.

  Vorhersagbarkeit Das Verhalten des Systems muss vorhersagbar sein.

Zu beachten ist, dass im praktischen Betrieb nicht alle Anforderungen gleichzeitig erfüllbar sind. So stehen etwa eine geringe Antwortzeit und maximaler Durchsatz/maximale Auslastung im Widerspruch zueinander. Für jeden Scheduling-Algorithmus muss also entschieden werden, auf welchem System er eingesetzt werden soll, d.h. auf welchen Kriterien der

Schwerpunkt liegt. Es kann sogar gezeigt werden, dass jeder Scheduling-Algorithmus, der eines dieser Kriterien betont, dafür ein anderes vernachlässigt. Schließlich ist die verfügbare Rechenzeit begrenzt.
Bei nutzerorientierten Systemen sind die systemorientierten Kriterien von geringerer Bedeutung.

Ein bedeutendes Hilfsmittel des Prozess-Management ist die Einführung von Prioritäten.
Dabei wird jedem Prozess eine Priorität Q_i zugeordnet, und der Scheduler gibt stets einem Prozess mit jeweils höchster Priorität den Vorrang, d.h. falls $Q_i > Q_j$, so wird PQ_i zuerst abgearbeitet.
Zu diesem Zweck muss eine Erweiterung der Realisierung, d.h. Speicherung von Prozessen im Zustand "ready" vorgenommen werden.
Die Ready-Queue wird nun in $n+1$ Ready-Queues $RQ_0, ..., RQ_n$ aufgesplittet, falls es n Prioritäten und die Priorität 0 gibt (siehe Abbildung 5.1).

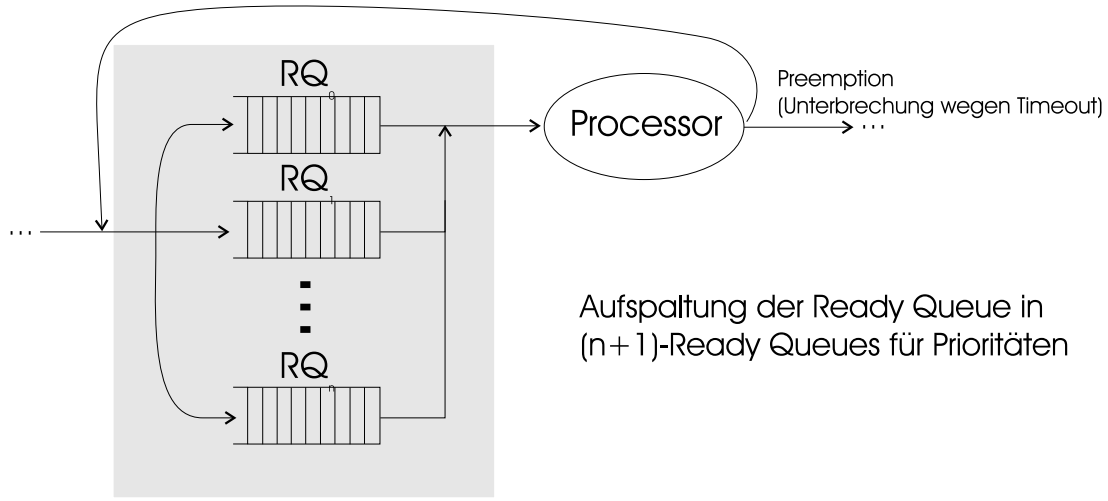

Abbildung 5.1: Aufspaltung in mehrere Ready-Queues für Prioritäten

Muss nun ein neuer Prozess dem Prozessor zugeordnet werden, so wird dieser aus RQ_0 gewählt - befinden sich keine Prozesse in dieser Queue, so wird einer aus RQ_1 genommen und so weiter.

Problem: Prozesse mit niedrigerer Priorität könnten verhungern, falls stets höherpriore Prozesse vorhanden sind.

Lösung: Die Prioritäten der Prozesse können sich mit der Zeit ihrer Abarbeitung ändern.

Unabhängig von den Prioritäten existiert eine sogenannte Auswahlfunktion (Selection Function), die bestimmt, welcher der Prozesse im Zustand "Ready" als nächstes ausgeführt wird.
Den zeitlichen Aspekt charakterisiert dabei ein Entscheidungsmodus (Decision Mode). Dabei unterscheidet man zwei Kategorien:

Nonpreemptive Modi (Nichtunterbrechende Modi): Befindet sich ein Prozess im Zustand

"Running", so wird seine Ausführung fortgesetzt, bis er terminiert oder durch ein Warten auf eine Betriebsmittelanforderung (z.B. E/A) blockiert wird.

Preemptive Modi (Unterbrechende Modi): Eine gerade in Ausführung befindlicher Prozess kann durch das Betriebssystem unterbrochen werden und damit wieder in den Zustand "ready" überführt werden.
Gründe für eine solche Unterbrechung können z.B. in folgenden Dingen gesehen werden:

- wenn ein neuer Prozess ankommt
- wenn eine Unterbrechung auftritt, die einen blockierten Prozess mit höherer Priorität in den Zustand "ready" zurückbringen kann
- oder periodisch durch Uhrenunterbrechungen.

Die Preemptiven Modi verursachen dabei einen größeren Overhead als die Nichtpreemptiven - jedoch lässt sich damit eine bessere Prozessabarbeitung aus Sicht des gesamten Systems erzielen.

5.1.3 Scheduling vs. Dispatching

Hier soll noch einmal kurz der Unterschied zwischen der Bedeutung der Begriffe Scheduling und Dispatching erläutert werden.

Scheduling: Unter Scheduling versteht man die Auswahl eines rechenbereiten Prozesses (Zustand "ready") und die damit gleichzeitige Unterbrechung (bzw. Beendigung) des aktuell abgearbeiteten Prozesses.

Dispatching: Unter Dispatching versteht man die Realisierung des eigentlichen Kontextwechsels. Die Information, welcher Prozess als nächster abgearbeitet werden soll, wird dem Dispatcher vom Scheduler mitgeteilt.

5.2 Scheduling-Algorithmen

5.2.1 Begriffe

Bevor im Detail auf die verschiedenen Scheduling-Algorithmen eingegangen wird, sollen im Folgenden noch einige Begrifflichkeiten geklärt werden.

Ankunftszeit Der Zeitpunkt ab dem ein Prozess existiert.

Startzeit Der Zeitpunkt, an dem der Prozess zum ersten mal dem Prozessor zugewiesen wird.

Verweildauer Die Zeitdifferenz der Ankunftszeit eines Prozesses im System und seiner Terminierung. Dieser Begriff wird vor allem im Hinblick auf Stapelverarbeitungssysteme verwendet.

Antwortzeit Dieser Begriff spielt vor allem in interaktiven Systemen eine große Rolle. Die Antwortzeit bezieht sich auf die Zeitspanne zwischen der Eingabe einer Anfrage und dem Beginn des Empfanges einer Antwort. Ein Prozess kann u.U. also schon mit der Ausgabe einer Antwort auf eine Benutzeranfrage beginnen, während die Anfrage sich aber noch

in Bearbeitung befindet.
Achtung: Der Begriff der Antwortzeit wird in der Literatur sehr oft auch anstelle der Verweilzeit verwendet. In diesem Fall versteht man unter der Antwortzeit ebenfalls die Zeitdifferenz der Ankunftszeit eines Prozesses im System und seiner Terminierung!

Bedienzeit Die Bedienzeit entspricht der Zeitspanne, in der der Prozessor einem Prozess zugeordnet wird, um den Prozess vollständig abzuarbeiten. Die Bedienzeit entspricht also der Zeitspanne, die ein Prozess bis zu seiner Terminierung im Zustand "running" verbringt (Gesamtbedienzeit). Betrachtet man die Bedienzeit eines schon existierenden Prozesses zu einem bestimmten Zeitpunkt, spricht man oft auch von der **Restbedienzeit** eines Prozesses.

Wartezeit Die Wartezeit entspricht der Zeitspanne, die ein Prozess im System verbringt, ohne dass der Prozess ausgeführt wird (nicht im Zustand "running").

Beendigungszeit Der Zeitpunkt an dem der Prozess terminiert ist.

Es gilt

$$Verweildauer = Bedienzeit + Wartezeit$$

Oft findet man im Zusammenhang mit Scheduling-Algorithmen Informationen über das Verhältnis von Verweildauer T_v zur Bedienzeit T_b. Der Quotient $\frac{T_v}{T_b}$ wird auch als *normalisierte Verweildauer* bezeichnet. Diese Kenngröße beinhaltet also die Information über die relative Verzögerung eines Prozesses. Für Prozesse mit langer Bedienzeit kann man in der Regel auch höhere Verzögerungen tolerieren. Natürlich sollen T_v und T_b für sich alleine so klein wie möglich ausfallen. Der Quotient sollte optimalweise einen Wert nahe 1 ergeben. Betrachtet man einen Scheduling-Algorithmus in Bezug auf seine normalisierte Verweildauer, so lässt sich festhalten, dass ein Anwachsen des Quotienten auf ein sinkendes Bedienlevel hindeutet.

5.2.2 Nicht-preemptive Scheduling-Algorithmen

First Come First Served (FCFS)

First Come First Served (FCFS), auch bekannt als *First In First Out (FIFO)*, ist der einfachste nicht-preemptive Scheduling-Algorithmus. Ein rechenbereiter Prozess stellt sich in der Ready-Queue einfach hinten an, und bei frei werdendem Prozessor kann der jeweils älteste Prozess in den Zustand "running" überführt werden. Folgendes Beispiel veranschaulicht den Algorithmus:

Prozess	Ankunftszeit	Verweildauer T_v	Bedienzeit T_b	Quotient $\frac{T_v}{T_b}$
P_1	0	3	3	1
P_2	1	3	1	3
P_3	2	4	2	2
P_4	3	8	5	1.6
P_5	4	8	1	8
		$\emptyset$ 5.2	$\emptyset$ 2.4	$\emptyset$ 3.12

Mittlere Verweildauer: 5.2
Mittlere Normalisierte Verweildauer $\frac{T_v}{T_b}$: 3.12

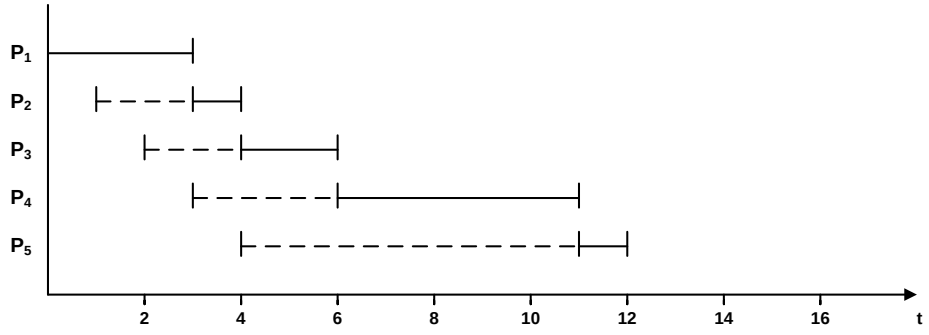

Abbildung 5.2: Beispiel mittlere Verweildauer für FCFS

Problem: Blockierungen von E/A-Geräten werden bei dieser Prozessorzuteilung nur schlecht abgefangen. (Prozesse, die E/A-Zugriffe beanspruchen, warten in der Ready-Queue, während die E/A-Geräte nicht genutzt werden)

Shortest Process Next (SPN) / Shortest Job First (SJF)

Shortest Process Next (SPN), auch bekannt als *Shortest Job First (SJF)*, gehört zu den nonpreemptiven Modi. Dabei wird jeweils der Auftrag ausgewählt, bei dem die kürzeste Abarbeitungszeit erwartet wird.

Die Wirkungsweise von SJF kann an folgendem Beispiel nachvollzogen werden:

Prozess	Ankunftszeit	Verweildauer T_v	Bedienzeit T_b	Quotient $\frac{T_v}{T_b}$
P_1	0	3	3	1
P_2	1	3	1	3
P_3	2	5	2	2.5
P_4	3	9	5	1.8
P_5	4	1	1	1
		$\emptyset$ 4.2	$\emptyset$ 2.4	$\emptyset$ 1.86

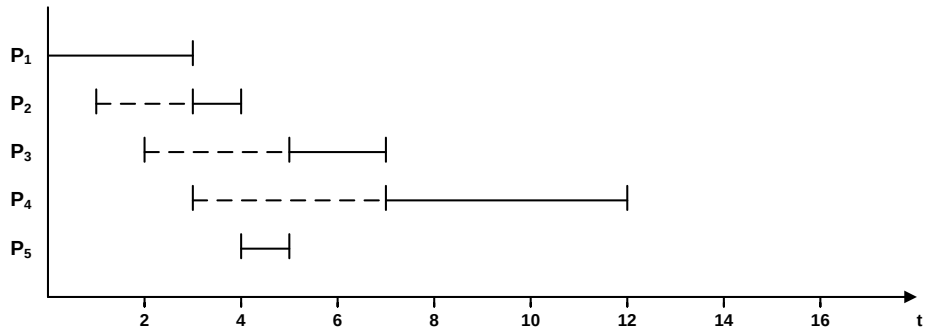

Abbildung 5.3: Beispiel mittlere Verweildauer für SJF

Da das Scheduling (ebenso wie bei FCFS) nicht preemptiv ist, braucht erst nach der Abarbeitung des ersten Prozesses wieder eine Auswahl getroffen zu werden. Im Mittel werden die Prozesse 2,4 Sek. abgearbeitet, verbringen im Mittel aber nur 4,2 Sek. im System. Die Wartezeit eines Prozesses beträgt somit im Mittel 1,8 Sek. (Vgl.: FCFS: 5,2 Sek. mittlere Verweildauer bei 2,4 mittlerer Bearbeitungszeit, also 2,8 Sek. mittlere Wartezeit.)
SJF bringt jedoch einige Probleme mit sich:

Problem 1: Woher soll das Betriebssystem wissen, mit welcher Abarbeitungsdauer es bei dem Auftrag zu rechnen hat?

Mögliche Lösung: Bei gleichartigen Aufträgen den Mittelwert der bereits abgearbeiteten Aufträge betrachten.

Problem 2: Starvation (Verhungern) der längeren Prozesse.

Vergleich der Strategien FCFS und SJF

– **FCFS**

- einfacher zu implementieren
- Fair! (Wer am längsten wartet kommt als nächstes dran, kein Prozessverhungern)

– **SJF**

- Günstiger bzgl. mittlerer Verweildauer, sogar optimal bei nicht-preemptiven Strategien
- Nachteile: Vorteile von FCFS nicht vorhanden; der Implementierer von Scheduling-Algorithmen hat keinen Anhaltspunkt, wie lange die Ausführung eines Prozesses dauern wird.

Optimalität von SJF SJF ist optimal bei nicht-preemptiven Scheduling-Algorithmen bzgl. der mittleren Verweildauer.

Beweis
SJF berechnet zu einer Folge von n Jobs mit Ausführungszeiten $t_1, t_2, \ldots, t_n$ eine Abarbeitungsreihenfolge mit minimaler Verweildauer. Die mittlere Verweildauer bei Abarbeitung der Jobs in der Reihenfolge $t_{i_1}, t_{i_2}, \ldots, t_{i_n}$ ($i_1, \ldots, i_n$ sei eine mögliche Permutation der Indizes $1, \ldots, n$) beträgt

$$\frac{1}{n}\sum_{k=1}^{n}\sum_{j=1}^{k} t_{i_j} = \frac{1}{n}\sum_{k=1}^{n}(n+k-1)t_{i_k} \tag{5.1}$$

Dieser Term soll minimal sein. Dies ist offensichtlich der Fall, wenn gilt

$$nt_{i_1} + (n-1)t_{i_2} + \cdots + 2t_{i_{n-1}} + t_{i_n} = min \tag{5.2}$$

Gleichung 5.2 ist offensichtlich minimal, wenn

$$t_{i_1} < t_{i_2} < \cdots < t_{i_{n-1}} < t_{i_n}$$

gewählt wird. □

5.2.3 Preemptive Scheduling-Algorithmen

Preemptive Scheduling-Algorithmen ermöglichen es Jobs zu unterbrechen, um “wichtigere” Jobs einzuschieben und die mittlere Verweildauer sowie die Antwortzeit noch weiter zu reduzieren. Des Weiteren ermöglichen preemptive Algorithmen mehr Flexibilität z.B. bei der Gewichtung von Fairness in Relation zu günstigeren Antwortzeiten.
ABER:
Diese Algorithmen können zu Inkonsistenzen führen, z.B. “Geld abheben”:
Eine Banktransaktionsfolge in 3 Schritten:

1. lies Kontostand
2. $k' := k - AbzuhebendesGeld$
3. Schreibe Kontostand k'

2 Familien- oder Firmenmitglieder wollen quasi gleichzeitig Geld abheben. Angenommen, es sind 1000 Euro auf dem Konto. Dann müssen folgende Programmbefehle realisiert werden. Sequentielles Ausführen dieser beiden Jobs führt zu einem Kontostand von 500 Euro (Verwendung nicht-preemptiver Scheduling-Algorithmen)

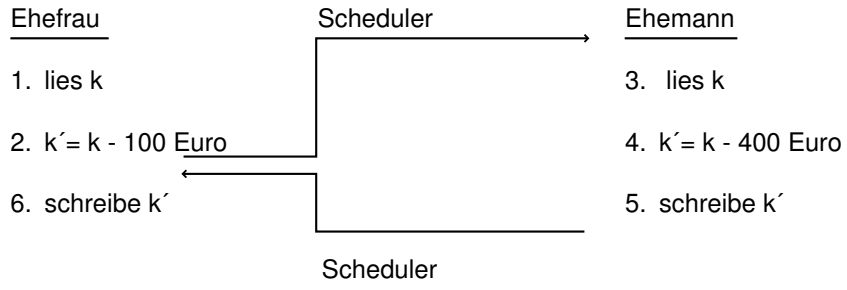

Abbildung 5.4: Programmbefehle

Problem:
Unterbrechungen bei der Ausführung der Jobs sind möglich. Dann sind 900 Euro auf dem Konto, obwohl (s.oben) 500 Euro abgehoben wurden.
⇒Kapitel 7 (Verwendung preemptiver Scheduling-Algorithmen)

Shortest Remaining Processing Time (SRPT)

Diese Strategie wird in mancher Literatur auch nur als SRT bezeichnet und ist die preemptive Variante zu SPN/SJF. Zu jedem beliebigen Zeitpunkt kann der Prozess unterbrochen werden, der aktuell dem Prozessor zugeteilt ist. Dies erfolgt mit dem Ziel, dem Prozessor einen anderen Prozess zuzuweisen, der eine kürzere Restbedienzeit hat. Insbesondere heißt dies: wenn ein neuer Auftrag ankommt, dann muss geprüft werden, ob dieser Auftrag kürzer ist als der gerade in Abarbeitung befindliche.
NEU:
Kommt während der Abarbeitung eines Prozesses ein neuer Prozess an (Zustand “ready”), so wird die Restbedienzeit des aktuellen Prozesses mit der Gesamtbedienzeit des neuen Prozesses verglichen. Ist also der neue Prozess kürzer, so erfolgt ein Kontextwechsel.

Bemerkung: Bei unseren Scheduling-Algorithmen wird nur die reine Bedienzeit der Nutzerprozesse (keine Prozessorzeit für Dispatcher o.ä.) betrachtet.
Die Wirkungsweise von SRPT kann an folgendem Beispiel nachvollzogen werden:

Prozess	Ankunftszeit	Verweildauer T_ν	Bedienzeit T_b	Quotient $\frac{T_\nu}{T_b}$
P_1	0	4	3	1.33
P_2	1	1	1	1
P_3	2	5	2	2.5
P_4	3	9	5	1.8
P_5	4	1	1	1
		$\emptyset$ 4	$\emptyset$ 2.4	$\emptyset \approx 1.53$

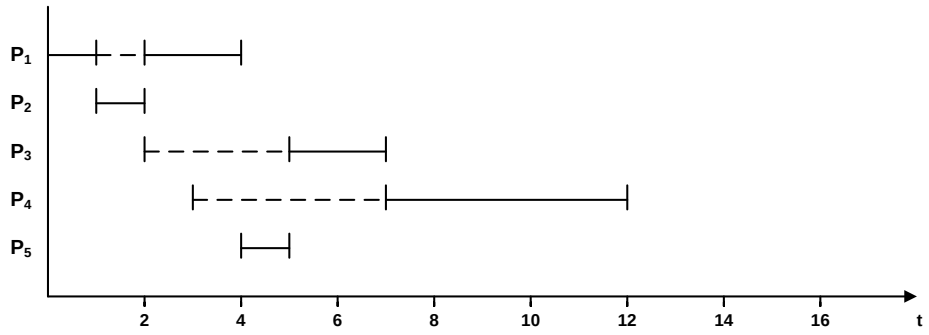

Abbildung 5.5: Beispiel mittlere Verweildauer für SRPT

Der mittleren Verweildauer von 4 Sek. standen 4,2 Sek. beim nicht-preemptiven Scheduling-Algorithmus SJF gegenüber. Unterbrechungen ermöglichen also nur eine nochmalige Verbesserung der mittleren Verweildauer, aber verbessern u.U. nicht die Antwortzeit bei interaktiven Systemen. Dieser Algorithmus ist theoretisch optimal, in der Praxis jedoch nicht realisierbar: Generell stehen keine Angaben über die zu erwartenden Bedienzeiten der Prozesse zur Verfügung. Problem 2 (Starvation) der SPN-Strategie bleibt ebenfalls bestehen. Im Gegensatz zur Round Robin Strategie werden jedoch keine weiteren Unterbrechungen vorgenommen.
Bemerkung:
In dem vorangegangenen Beispiel hätte ein Scheduler zum Zeitpunkt $t = 2$ anstelle des Prozesses P_1 auch den Prozess P_3 dem Prozessor zuweisen können. Dies hätte keinen Einfluss auf die mittlere Verweilzeit, jedoch würde sich die mittlere normalisierte Verweilzeit auf $\approx 1{,}43$ verbessern. Die Entscheidung, in welcher Reihenfolge Prozesse mit gleicher Restbedienzeit ausgeführt werden, wird nicht von SRPT vorgegeben.

Wir wollen nun nach einem praktisch realisierbaren Algorithmus suchen, der *möglichst fair ist* und eine *möglichst geringe mittlere Verweildauer* aufweist.

Round Robin

Round Robin (RR) nutzt Uhren-basierte Unterbrechungen, d.h. in periodischen Intervallen werden Prozesse in ihrer Abarbeitung unterbrochen, bis sie wieder ein Zeitquantum Q für

die Abarbeitung erhalten. Dieses Verfahren wird auch als *Zeitscheibenverfahren* bezeichnet. Als problematisch beim Design des Verfahren erweist sich hierbei die Wahl der Länge einer Zeitscheibe.
Ist die Zeitscheibe zu klein, dann ist der Aufwand für das Dispatching zu groß - ist sie zu groß, kommt FCFS zustande. Dies ist dann der Fall, wenn Q mindestens so groß ist wie der längste Prozess, der abgearbeitet werden soll.
Generell sollten zu kleine Zeitscheiben aber vermieden werden. Wird einem Prozess der Prozessor entzogen, so wird dieser der Ready-Queue hinzugefügt (siehe Abbildung 5.6).

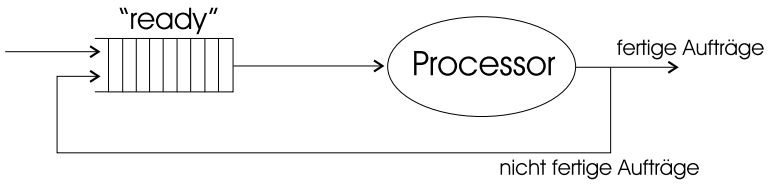

Abbildung 5.6: Realisierung des Round Robin Verfahrens

Die Wirkungsweise von RR kann an folgendem Beispiel mit $Q = 1$ nachvollzogen werden (Abbildung 5.8 zeigt die Belegung der Ready-Queue zu den unterschiedlichen Ausführungszeitpunkten):

Prozess	Ankunftszeit	Verweildauer T_v	Bedienzeit T_b	Quotient $\frac{T_v}{T_b}$
P_1	0	4	3	1.33
P_2	2	16	6	2.67
P_3	4	13	4	3.25
P_4	6	14	5	2.80
P_5	8	7	2	3.50
		$\emptyset$ 10.8	$\emptyset$ 4	$\emptyset$ 2.71

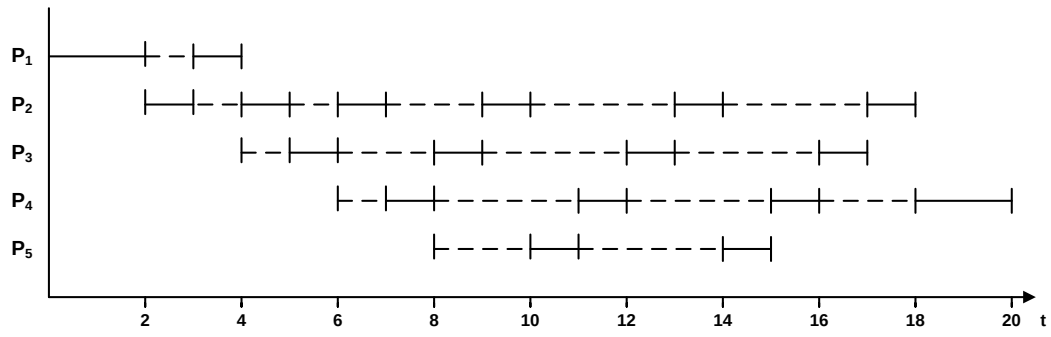

Abbildung 5.7: Beispiel mittlere Verweildauer für RR

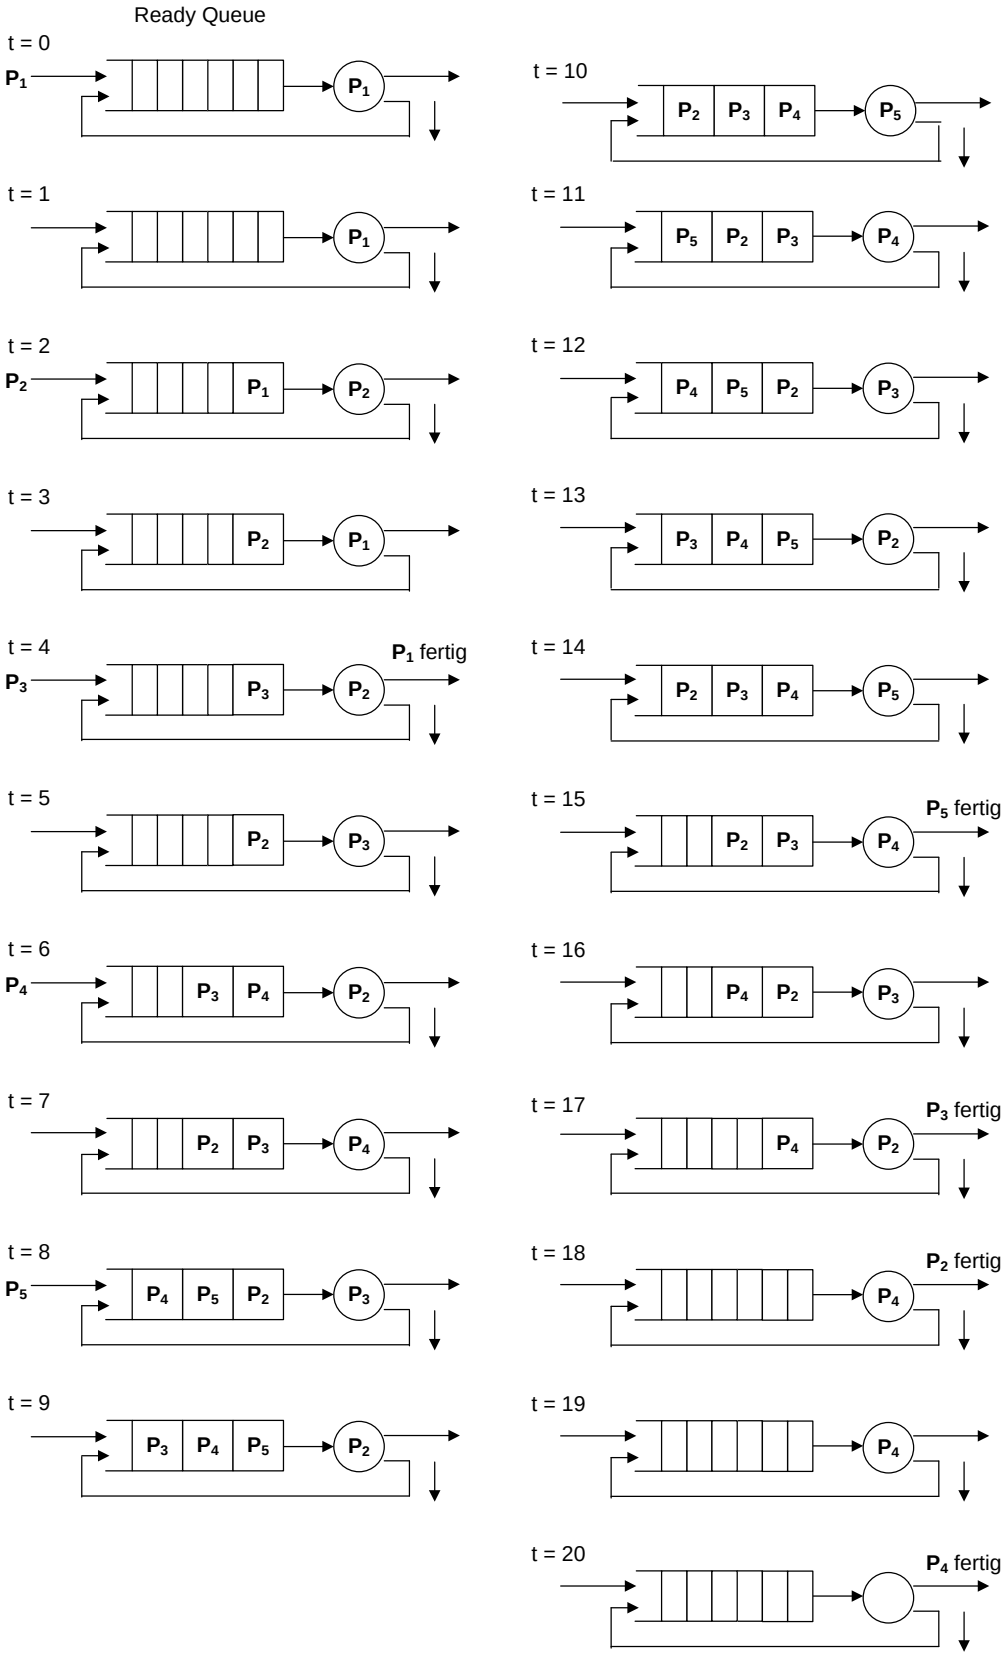

Abbildung 5.8: Belegung der Ready-Queue zu dem Beispiel aus Abbildung 5.7.

Mittlere Verweildauer: 10.8
Mittlere normalisierte Verweildauer $\frac{T_q}{T_s}$: 2.71

Für das schon früher verwendete Beispiel ergibt sich folgendes Bild:

Prozess	Ankunftszeit	Verweildauer T_v	Bedienzeit T_b	Quotient $\frac{T_v}{T_b}$
P_1	0	6	3	2
P_2	1	1	1	1
P_3	2	6	2	3
P_4	3	9	5	1.8
P_5	4	3	1	3
		$\emptyset$ 5	$\emptyset$ 2.4	$\emptyset$ 2.16

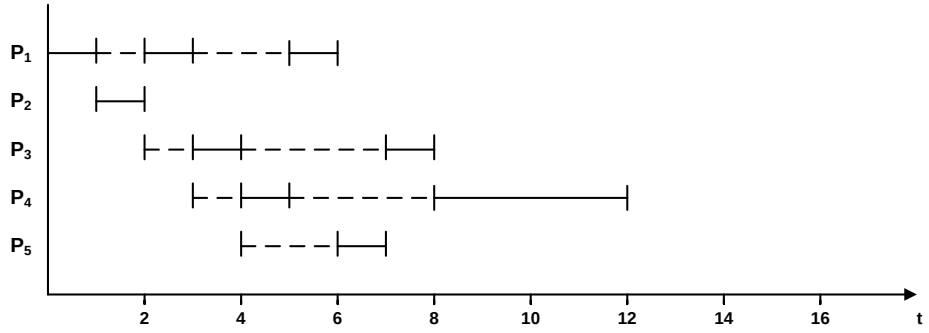

Abbildung 5.9: Beispiel mittlere Verweildauer für RR

Bemerkung:
In den vorangegangenen Beispielen wurde angenommen, dass wenn zu einem bestimmten Zeitpunkt t ein neuer Prozess P_n in die Ready-Queue geschrieben werden soll, der gerade aktive Prozess P_a immer **nach** P_n der Ready-Queue hinzugefügt wird! Diese Vorgehensweise wird jedoch nicht vom jeweiligen Scheduling-Algorithmus vorgeschrieben und muss vorher bekannt sein. Genauso gut hätte man sich auch für die Strategie entscheiden können, stets erst den gerade aktiven Prozess einzureihen. Eine weitere Möglichkeit wäre die Prozesse entsprechend ihrer lexikografischen Ordnung einzureihen.

Vergleich:
RR ist bezüglich der mittleren Verweildauer besser als FCFS, aber schlechter als SJF und als SRPT. Im Gegensatz zu SJF und SRPT ist RR jedoch

- fair in der Hinsicht, dass kein Verhungern vorkommt und
- praktisch implementierbar

Im Verhältnis zu FCFS profitiert RR davon, dass kürzere Jobs schneller abgearbeitet werden. Bei RR hängt die Dauer der Abarbeitung ab von

- der Länge der Jobs ($\rightarrow$linearer Zusammenhang: je kürzer ein Job, desto schneller ist er fertig) und

– der Anzahl vorhandener Jobs.

Man kann nun zwei alternative Fälle betrachten:

1. Das Dispatching wird bei der Zeitberechnung vernachlässigt.

2. Das Dispatching wird bei der Zeitberechnung nicht vernachlässigt.

In Fall 1. hat die Länge des Zeitquantums Q keinen Einfluß auf die mittlere Verweildauer. In Fall 2. hingegen gilt, dass je kleiner Q gewählt wird, desto mehr Overhead entsteht durch den Kontextwechsel, was wiederum zu einer Erhöhung der mittleren Verweildauer führt.
⇒Q ist möglichst optimal zu wählen, so dass zum einen keine Konvergenz gegen FCFS auftritt und zum anderen das Dispatching im Verhältnis zur Prozessabarbeitung nicht zu aufwendig wird. In der Praxis werden z.B. Zeitquanten in der Grössenordnung zwischen 10 und 100 ms verwendet. Prozesse, die weniger als 1 Zeitquantum brauchen, geben die CPU von sich aus frei, andernfalls initiiert der Scheduler eine Unterbrechung.
Fazit: Der Vorteil von RR besteht darin, dass kurze Aufträge nicht so lange warten müssen. Insbesondere ist diese Strategie vorteilhaft für Prozesse, die auf E/A-Geräte zugreifen. Während der Blockierung können andere Prozesse abgearbeitet werden. Lange und rechenintensive Prozesse sind dagegen durch die häufigen Unterbrechungen eher im Nachteil.

5.2.4 Priority Scheduling (PS)

Jedem Auftrag/Prozess wird bei dieser Strategie eine Priorität zugeordnet, die Abarbeitung erfolgt nach dem Prinzip Highest-Priority-First (Scheduler sucht aus).
Bei einem Clustering in Prioritätsklassen würde der älteste aller Aufträge ausgewählt werden, der sich in der höchsten Prioritätsklasse befindet.
Dabei kann das Problem des Verhungerns niederpriorer Aufträge auftreten. →keine Fairness
Vorteile:

– Wichtige Prozesse können bevorzugt werden:
  Bislang haben wir bei “guten” Scheduling-Algorithmen ein Bevorzugen kurzer Prozesse beobachtet ⇒wichtige=kurze Prozesse sollen schnell abgearbeitet werden, d.h. eine hohe Priorität bekommen.

– praktisch implementierbar

Nachteile:

– Verhungern von Prozessen mit niedriger Priorität

– relativ schlechte mittlere Verweildauer

5.2.5 Multilevel Feedback Queueing

Arbeitet sowohl mit Prioritätsklassen (“Multilevel”) als auch mit Zeitscheiben. Das besondere dieses Algorithmus ist - im Gegensatz zu SPN und SRPT - dass man keine Kenntnisse über die voraussichtliche Abarbeitungszeit braucht und trotzdem kurze Aufträge bevorzugen kann.
Das Scheduling wird nun unterbrechend ausgeführt; Prioritäten werden dabei dynamisch vergeben.

Eine Realisierung des Verfahrens kann durch eine Unterteilung der Ready-Queues in $n + 1$ FIFO-Queues erfolgen. Beim Beginn der Ausführung wird einem Prozess die Priorität Q_0 gegeben, d.h ein neuer Prozess wird am Ende der obersten FIFO-Queue eingefügt. Der Scheduler teilt immer dem Prozess am Anfang der obersten nicht leeren Warteschlange den Prozessor zu. Erreicht der Prozess den Anfang der Queue, wird er dem Prozessor zugewiesen. Nun sind drei Fälle zu unterscheiden:

– Der Prozess wird vollständig abgearbeitet
  $Rightarrow$ Der Prozess verlässt das System.

– Der Prozess gibt den Prozessor freiwillig ab
  $Rightarrow$ Der Prozess verlässt die gegenwärtige Queue. Sobald der Prozess wieder in den Zustand "ready" gelangt, wird er wieder in **dieselbe** Queue eingereiht.

– Der Prozess nimmt die gesamte ihm zugewiesene Zeitscheibe in Anspruch
  $Rightarrow$ Der Prozess wird unterbrochen und an das Ende der **nächst niedrigeren** Queue gesetzt.

Dieser Ablauf wird so lange wiederholt, bis der Prozess vollständig abgearbeitet ist bzw. die niedrigste Queue erreicht hat. In der niedrigsten Queue werden die Prozesse im Round-Robin-Verfahren abgearbeitet, bis sie beendet werden und das System verlassen. Kurze Prozesse gelangen dabei relativ schnell zum Ende, lange Prozesse gelangen schließlich in die niedrigstpriore Queue und bleiben dort.

Implementierung und Abarbeitung eines Auftrags:

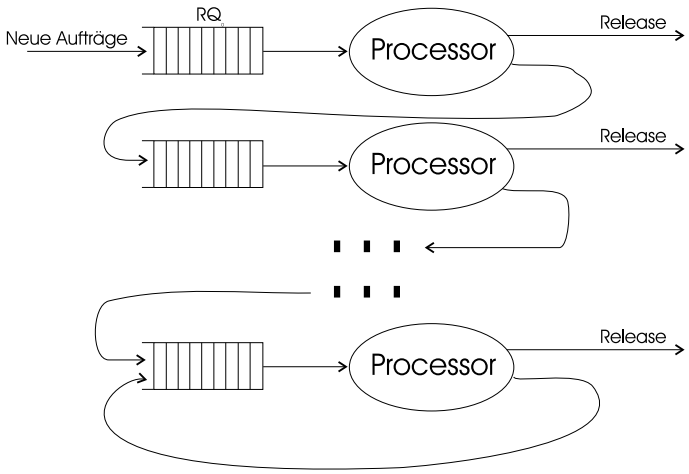

Abbildung 5.10: Implementierung und Abarbeitung eines Auftrags

Bei längeren Abarbeitungszeiten der Prozesse sollten entsprechend auch längere Zeitscheiben verwendet werden.

5.3 Prozesswechsel

In Teilen der Literatur wird der für den Prozesswechsel zuständige Teil des Betriebssystems auch als **Dispatcher** bezeichnet.
Die Aufgabe eines Dispatchers besteht darin, die tatsächliche Zuteilung der Prozesse zur CPU zu realisieren. Diesen Vorgang bezeichnet man auch als *Kontextwechsel des Prozessors*. Aus Prozesssicht bedeutet dies, dass der Dispatcher den Zustandsübergang des Prozesses zwischen rechenwillig und rechnend realisiert.
Beim Übergang von rechnend in rechenwillig (ready) muss der Zustand des Prozesses im PCB gespeichert werden – beim Übergang von rechenwillig in rechnend muss er wieder geladen werden.

5.4 Arten des Schedulings

Beim Scheduling werden verschiedene Arten des Scheduling unterschieden:

Short Term Scheduling

Medium Term Scheduling

Long Term Scheduling

Vgl. auch Abbildungen 5.11 und 5.12.

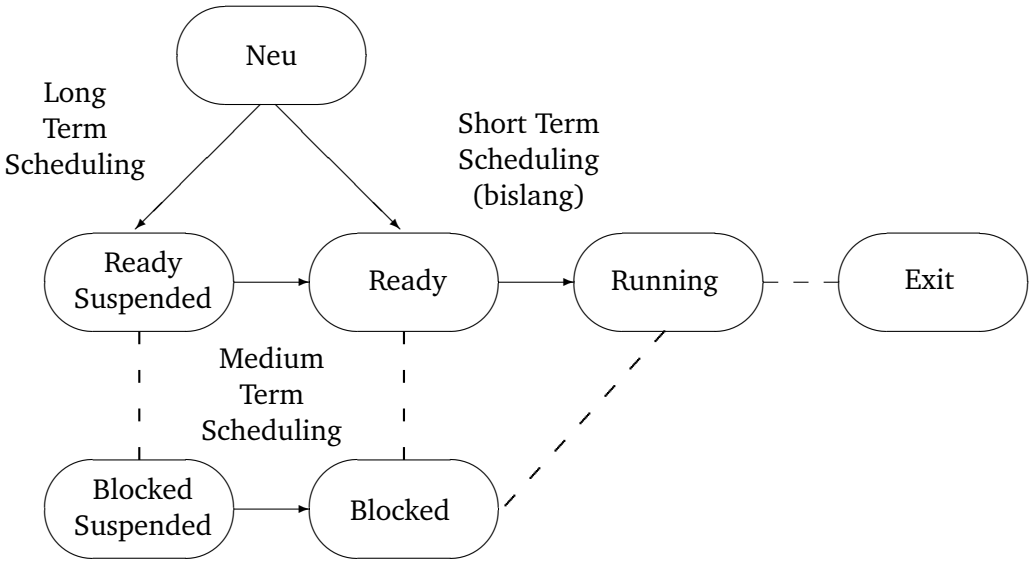

Abbildung 5.11: Zuordnung der Prozesszustände zu den Arten des Scheduling

Genauer: Falls sich keiner der Prozesse im Hauptspeicher im Zustand “ready” befindet, so lagert das Betriebssystem einen der blockierten Prozesse aus und zwar in eine Suspended-Queue auf Platte.

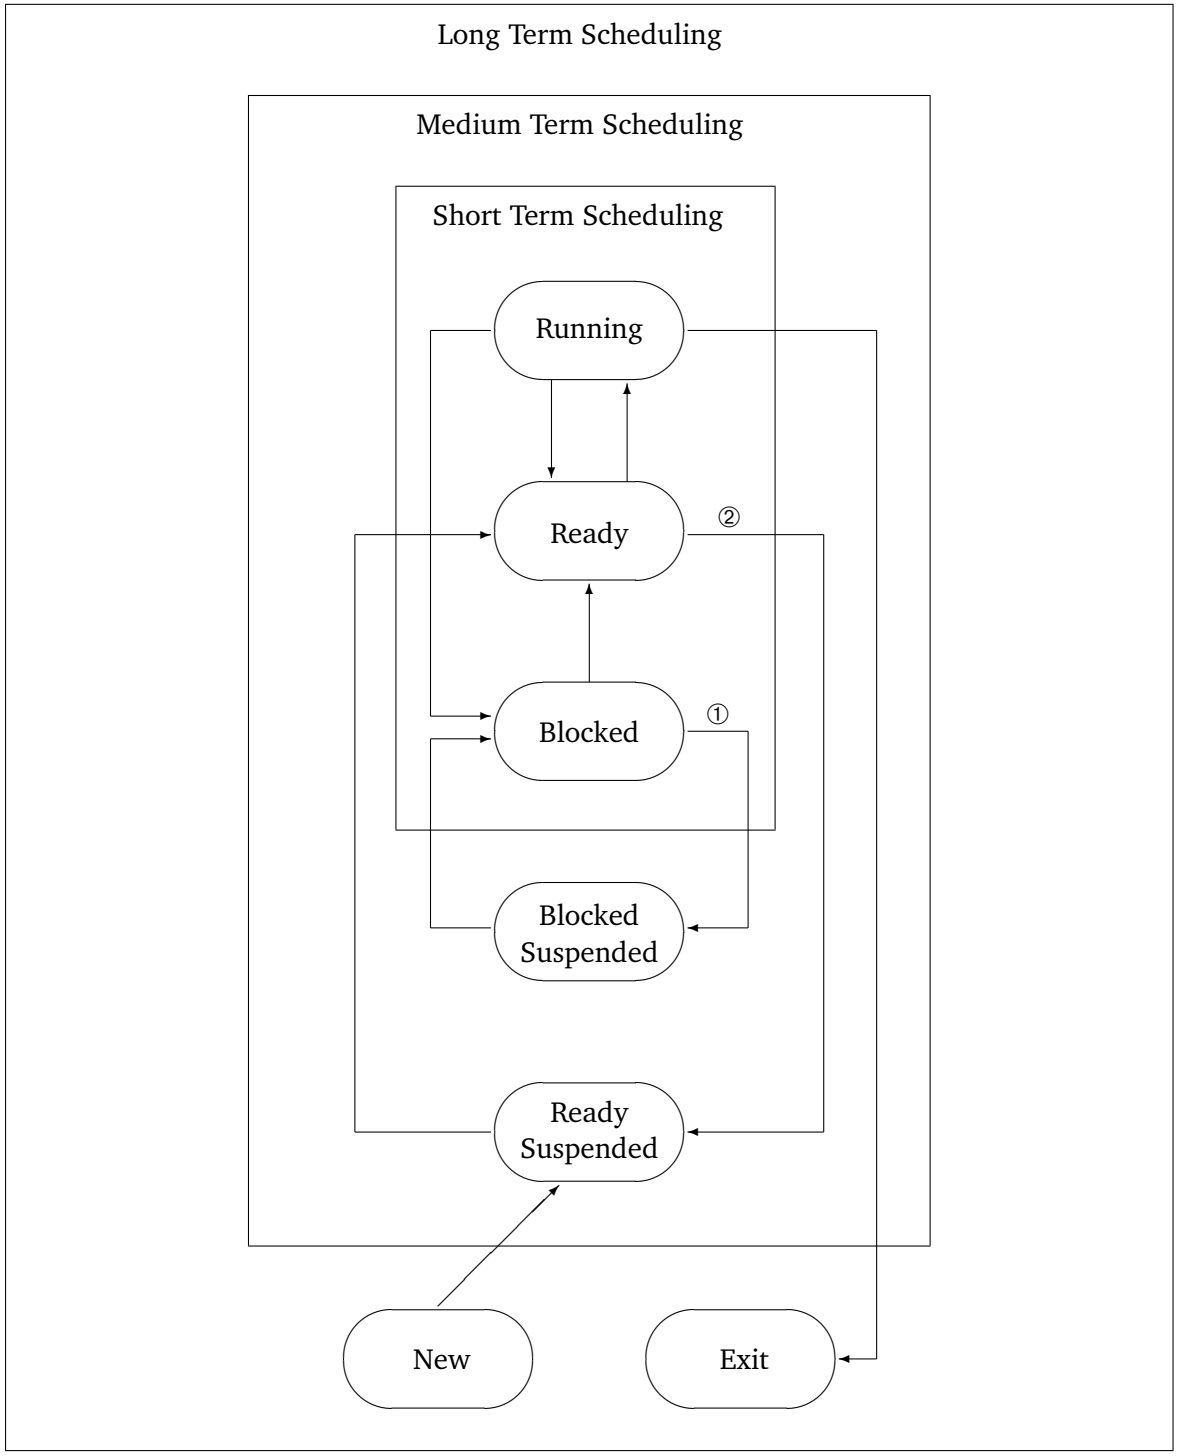

Abbildung 5.12: Visualisierung der hierarchischen Unterteilung der Scheduling-Arten

Dadurch kann ein anderer Prozess dieser Suspended-Queue (der “ready” ist) oder ein ganz neuer Prozess in den Hauptspeicher geladen werden, der dann direkt vom Prozessor ausgeführt werden kann (höhere Priorität: suspendierter Prozess im Zustand ready).

Teil III

Multiprocessing

6

Deadlocks bei Prozessen

- Modellierung von nebenläufigen Prozessen
- Deadlocks und Partial Deadlocks
- Petri-Netze

Inhaltsangabe

In diesem Kapitel soll das Problem des Deadlocks bei kooperierenden Prozessen (vgl. auch Kapitel 7.4.5) diskutiert werden. Um Deadlocks beschreiben und erkennen zu können, wird es nötig sein, Prozesse und ihre Interaktion zu modellieren.

6.1 Motivation der Deadlocks anhand zweier Beispiele

Kreuzung Die Kreuzung in Abbildung 6.1a ist in 4 Quadranten eingeteilt. Auf jeder der einmündenden Straßen befindet sich ein Auto, das die Kreuzung überqueren möchte. Jedes Auto benötigt beim Überqueren der Kreuzung 2 Quadranten, d.h., die Autos befinden sich in einem gegenseitigen Wartezustand: sie belegen einen Quadranten und warten auf das Nutzungsrecht eines anderen Quadranten. Die Blockierung in Abbildung 6.1b kann nur durch Eingreifen einer regelnden Instanz, beispielsweise einer Ampelschaltung oder einen Verkehrspolizisten, verhindert werden. Wir befinden uns in einer Deadlocksituation.

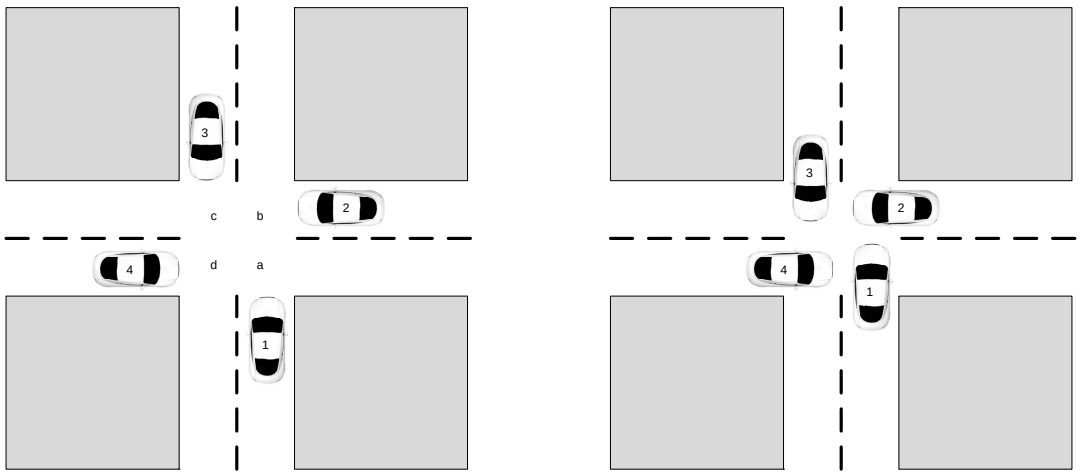

(a) Deadlock möglich (b) Deadlock

Abbildung 6.1: Illustration eines Deadlock

Philosophenproblem Abbildung 6.2 veranschaulicht das 2 Philosophenproblem:
2 Philosophen können wahlweise denken oder essen. Damit wenigstens ein Philosoph essen kann (Reis), werden auf dem Tisch 2 Stäbchen zur Verfügung gestellt. Problem: Wollen beide Philosophen essen und nehmen dazu simultan jeweils das (von ihnen aus) rechte Stäbchen, so bekommt jeder nur eins und keiner kann den Reis essen. ⇒Deadlocksituation

Definition 6.1. Deadlock Ein System befindet sich im Zustand einer Verklemmung (*Deadlock*), wenn mindestens zwei Prozesse sich in einem wechselseitigen Wartezustand befinden und auch durch die Freigabe aller Betriebsmittel möglicher anderer Prozesse dieser Zustand nicht aufgehoben werden kann.

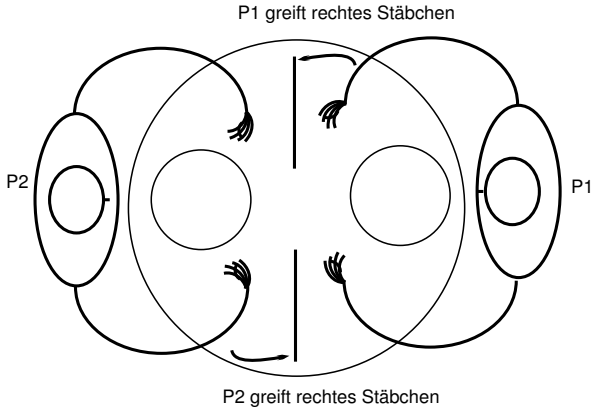

Abbildung 6.2: Beispiel Philosophenproblem

Aufgabe 1 Beispiel für einen Deadlock

Ein Computer habe sechs Bandlaufwerke und *n* Prozesse, von denen jeder zwei Bandlaufwerke gleichzeitig für seine Ausführung benötige. Für welche Werte von *n* ist dieses System frei von Verklemmungen (vgl. Abbildung 6.3)?

Lösung zu Aufgabe 1:

$n = 1$: $\Rightarrow$ kein Deadlock

$n = 2$: Fall 1: Prozesse benötigen ganz bestimmtes Laufwerke $\Rightarrow$ Deadlocks sind möglich
Fall 2: Welche Laufwerke ein Prozess zugeteilt bekommt, ist egal, Hauptsache es sind zwei Stück $\Rightarrow$ kein Deadlock

$n = 3$: $\Rightarrow$ kein Deadlock (wie Fall $n = 2$)

$n = 4$: $\Rightarrow$ kein Deadlock
P_1, P_3 haben 2 Laufwerke. Diese Prozesse werden abgearbeitet und geben dann ihre BM frei. Dann wird entweder P_2 oder P_4 ausgeführt, der wiederum nach der Abarbeitung seine BM freigibt, worauf der letzte Prozess abgearbeitet werden kann.

$n = 5$: $\Rightarrow$ kein Deadlock (ähnlich wie $n = 4$)
Bei 6 Laufwerken und 5 Prozessen gibt es mindestens 1 Prozess, der 2 Laufwerke zugeordnet bekommt und abgearbeitet werden kann.

$n = 6$: $\Rightarrow$ Deadlock kann auftreten! Wenn jeder Prozess ein Laufwerk zugeordnet bekommt und auf ein anderes wartet.

$n \geq 7$: $\Rightarrow$ Deadlocks können auftreten

6.2 Das Prinzip der Deadlocks

Def.: Ein Deadlock ist die dauerhafte Blockierung einer Menge M von Prozessen, die gemeinsame Systemressourcen S nutzen oder miteinander kommunizieren. $(|M|, |S| \geq 2)$

Leider gibt es für dieses Problem keine allgemeingültige Lösung.

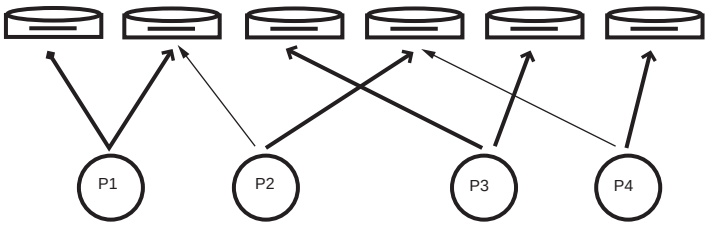

Abbildung 6.3: Beispiel mit 4 Prozessen. Dicke Pfeile deuten an, dass ein Prozess ein Betriebsmittel hält, dünne Pfeile, dass ein Prozess auf ein Betriebsmittel wartet.

Aufgabe 2 Anwendungsbeispiel für das Auftreten von Deadlocks

In einem elektronischen Banksystem gibt es hunderte von identischen Prozessen, die alle mittels der Information über die gutzuschreibende Geldmenge, das Zielkonto und das zu belastende Konto Transaktionen vornehmen. Diese Transaktionen werden vorgenommen, indem beide Konten gesperrt werden und erst wieder freigegeben werden, wenn der Transfer abgeschlossen ist.
Bei vielen parallel ablaufenden Prozessen ist die Wahrscheinlichkeit sehr hoch, daß ein Prozeß *A* ein Konto *x* sperrt und auf Konto *y* wartet, während ein Prozeß *B* das Konto *y* sperrt und nun gerade auf *x* wartet. Finden Sie eine Möglichkeit, Verklemmungen auszuschließen, wobei ein Konto erst dann freigegeben werden kann, wenn die Transaktion abgeschlossen ist, d.h. Lösungen, die ein Konto sperren und es sofort wieder freigeben, wenn das andere gesperrt ist, sind nicht gültig.

Zunächst wollen wir ein Beispiel betrachten, wie Deadlocks zustande kommen. Wir betrachten dazu zwei Prozesse P und Q, die auf je 2 Betriebsmittel A und B zugreifen:

Process P	Process Q
...	...
Get A	Get B
...	...
Get B	Get A
...	...
Release A	Release B
...	...
Release B	Release A

Auch durch geeignetes Scheduling findet man hier keine Möglichkeit, beide Prozesse vollständig abzuarbeiten. Dieser Sachverhalt soll nun in einem sogenannten Prozeßfortschrittsdiagramm dargestellt werden (vgl. Abbildung 6.4):
Dabei verstehen wir unter Fortschritt die Reihenfolge oder Sequenz, in der einzelne Befehle abgearbeitet werden sowie insbesondere der Zugriff und die Freigabe von BM.
Zunächst betrachten wir nicht-preemptives Scheduling am Beispiel des FCFS (1. und 2.):

1. Q wird zunächst vollständig abgearbeitet, dann P.

2. P wird zunächst vollständig abgearbeitet, dann Q.

Nun das preemptive Scheduling:
Betrachten wir folgende Betriebsmittelzuordnung: →a) Q bekommt B,→b) P bekommt A
Es ergibt sich folgendes Szenario:
* P fordert Betriebsmittel B an, das jedoch von Q gehalten wird und nicht frei ist. P geht vom

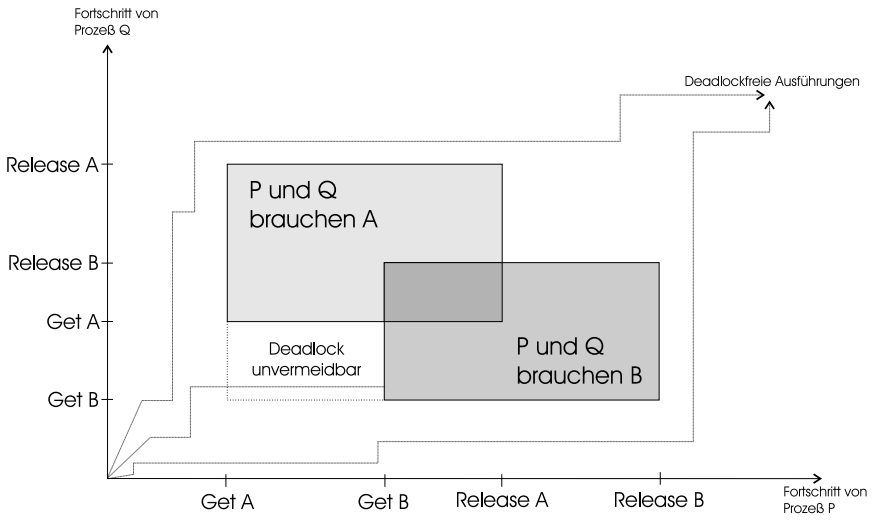

Abbildung 6.4: Prozessfortschrittsdiagramm 1

Zustand *ready* in den Zustand *blocked* über, d.h. P wird unterbrochen, der Scheduler wählt den nächsten Prozess aus, der sich im Zustand *ready* befindet, nämlich Q.
Nun braucht Q das Betriebsmittel A, A wird aber von P belegt ⇒*Deadlock* an der Stelle .
Der Deadlock ist bereits unvermeidbar, wenn der Graph in den unsicheren Bereich kommt, da dieser unweigerlich in den unmöglichen Bereich führt. Die Lösung des Problems ist relativ einfach, wenn die BM-Anforderungen vertauscht werden können, bzw. die Implementierung der Prozesse P und Q so zu gestalten ist, daß jeder der Prozesse die Betriebsmittel A und B nicht gleichzeitig benötigt:

Process P'	Process Q
...	...
Get A	Get B
...	...
Release A	Get A
...	...
Get B	Release B
...	...
Release B	Release A

Dadurch würde das Prozessfortschrittsdiagramm aus Abbildung 6.5 entstehen. Bei diesem Ablauf gibt es keine Kombination, bei der sowohl P als auch Q die Betriebsmittel A und B benötigen und demzufolge auch keinen Zustand, in welchem ein Deadlock unvermeidbar wird (vgl. Abbildung 6.2).

Eine weitere Alternative stellt folgende Lösung dar:

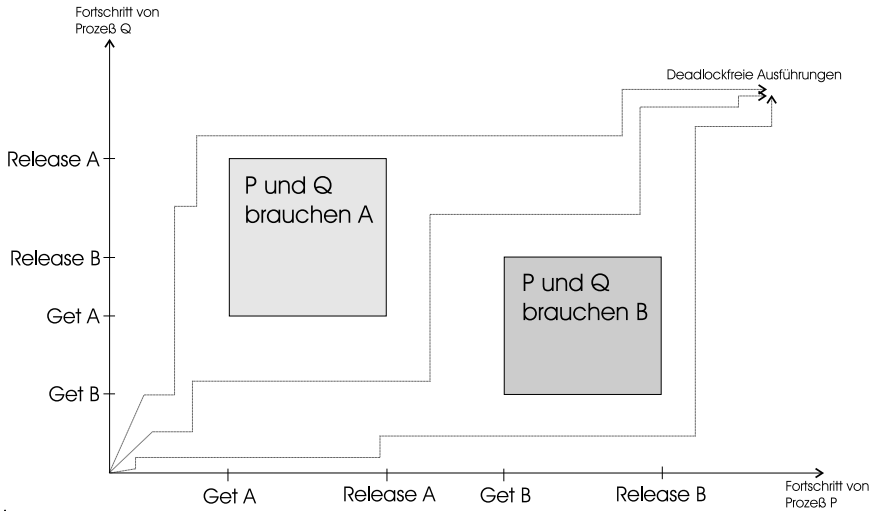

Abbildung 6.5: Prozeßfortschrittsdiagramm 2

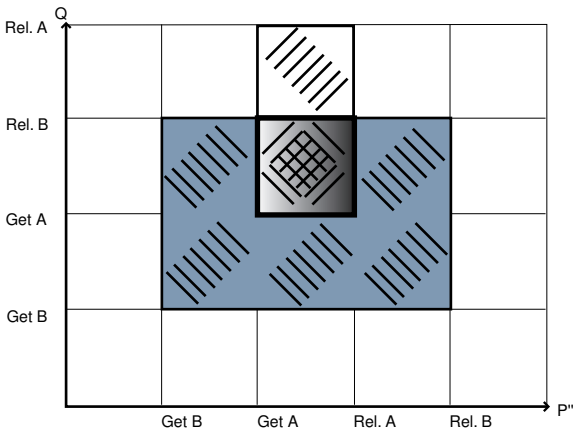

Abbildung 6.6: Bsp. Zustand ohne Deadlock

Process P”	Process Q
...	...
Get B	Get B
...	...
Get A	Get A
...	...
Release A	Release B
...	...
Release B	Release A

Bei den Ressourcen unterscheiden wir 2 Arten:

– **Wiederverwendbare Ressourcen**
sind Ressourcen, die von genau einem Prozeß genutzt werden können und durch diese

Nutzung nicht zerstört werden.
Zu einem späteren Zeitpunkt werden diese Ressourcen wieder freigegeben und können dann von anderen Prozessen genutzt werden. Z.B.: Prozessor, E/A-Kanäle, Hauptspeicher, Sekundärspeicher, Geräte, Dateien, Semaphore
Ein Deadlock könnte hier (zusätzlich zu oben genanntem Beispiel) z.B. durch einen ungünstigen Speicherzugriff entstehen.
Wir nehmen als Beispiel 200 KiloByte Speicher an und folgenden Bedarf von 2 Prozessen:

Process P_1	Process P_2
...	...
80 KByte	70 KByte
...	...
60 KByte	90 KByte
...	...

Gelangen beide Prozesse zwischen die erste und zweite Speicheranforderung, so ensteht ein Deadlock, da nur noch 50 kByte verfügbar sind und 60 bzw. 90 kByte gefordert werden.
Lösung: Virtueller Speicher (→späteres Kapitel)

– **Verbrauchende Ressourcen**
sind Ressourcen, die erzeugt und zerstört werden. Dabei kann ein produzierender Prozeß eine beliebige Anzahl solcher Ressourcen erzeugen. Z.B.: Unterbrechungen, Signale, Nachrichten, Informationen in E/A-Speichern. →kein Deadlock möglich

6.3 Deadlock Prevention

→Verhinderung/Verhütung von Deadlocks

Das Vorgehen zur Deadlockverhütung besteht darin, ein System zu konstruieren, in dem Deadlocks überhaupt nicht vorkommen können. Generell werden die Vorsichtsmaßnahmen, d.h., die Methoden zur Deadlockverhinderung (Deadlock Prevention) in zwei Klassen eingeteilt:

1. Indirekte Methoden

2. Direkte Methoden

Diese beiden Klassen wollen wir nacheinander näher betrachten.

– *Indirekte Methoden* gehen davon aus, dass generell drei Bedingungen erfüllt sein müssen, damit überhaupt ein Deadkock eintreten kann. Diese 3 Bedingungen wollen wir im einzelnen betrachten:

1. Bedingung: Mutual Exclusion (wechselseitiger Ausschluss)
Es gibt mindestens 2 Ressourcen, die nur von einem Prozeß gleichzeitig genutzt werden können. Bei nur einem BM kann kein Deadlock entstehen, da ein wechselseitiger Zugriff nicht stattfinden kann.
Deadlockvoraussetzung: mindestens 2 Prozesse und 2 BM.

2. Bedingung: Hold and Wait
Ein Prozeß muß eine Ressource behalten, während er auf eine weitere Ressource wartet.

3. Bedingung: No Preemption (Keine Unterbrechung)
Eine Ressource kann einem Prozeß, der sie behält, nicht wieder entzogen werden.

Ist mindestens eine dieser Bedingungen verletzt, so kann gar kein Deadlock auftreten.

– *Direkte Methoden* betrachten die genaue Situation, die zu einem Deadlock führen würde. Dieser Umstand wird auch als **Circular Wait** bezeichnet.

4. Umstand: Circular Wait
Es existiert eine geschlossene Kette von Prozessen, so daß jeder Prozeß mindestens eine Ressource hält, die von einem anderen Prozeß der Kette gebraucht wird (vgl. Abbildung 6.7).

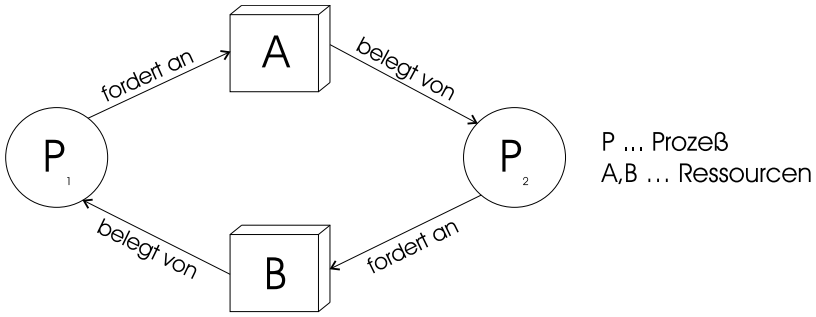

Abbildung 6.7: Circular Wait

6.3.1 Deadlock Avoidance

→Vermeidung von Deadlocks

Bei der Deadlockvermeidung lässt man die 3 Bedingungen außer Acht. Insbesondere werden Unterbrechungen und Nebenläufigkeit zugelassen.
Dafür wird jedoch dynamisch entschieden, ob Ressourcen genutzt werden können, oder ob dies zu einer potentiellen Deadlocksituation führt.
⇒Demzufolge erfordert die Deadlockvermeidung Wissen über die zukünftigen Ressourcenanforderungen der Prozesse.

Genau genommen gibt es zwei Verfahren für die Deadlockvermeidung:

1. Ein Prozeß darf nicht gestartet werden, falls seine Anforderungen zu einem Deadlock führen könnten und

2. Eine Ressourcenanfrage darf nicht befürwortet werden, falls sie zu einem Deadlock führen könnte.

Wir wollen nun eine Methode betrachten, die davon ausgeht, einen Prozess gar nicht erst zu starten, falls ein potentieller Deadlock droht:

I. Process Initiation Denial (Ablehnen einer Prozessinitiierung)
Zunächst brauchen wir einige Vorbemerkungen:
Es werde ein System mit n Prozessen und m verschiedenen Arten von Ressourcen betrachtet.
Durch Einführung von Vektoren und Matrizen werde Folgendes beschrieben:

$Ressourcen = (R_1, R_2, \ldots, R_m)$ bezeichne die Anzahl jedes Ressourcentyps im gesamten System (auch als Max bezeichnet).
$Verfügbarkeit = (V_1, V_2, \ldots, V_m)$ bezeichne die Anzahl verfügbarer Ressourcen, d.h. die Anzahl der Ressoucen pro Typ,die keinem Prozess zugeordnet sind.
Es wird nun davon ausgegangen, dass Prozess P_1 bestimmte Ressoucen jedes Typs belegt, und zwar jeweils von der Ressource R_i c_{1i} Stück. Damit ergibt sich der Vektor:
$Claim_{Prozess_{P1}} = (C_{11}, C_{12}, \ldots, C_{1m})$
Durch Betrachten jedes Prozesses P_i, $i = 1, \ldots, n$ ergibt sich die Matrix der Anforderungen:

claim=

$$\begin{pmatrix} C_{11} & C_{12} & \cdots & C_{1m} \\ C_{21} & C_{22} & \cdots & C_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ C_{n_1} & C_{n_2} & \cdots & C_{nm} \end{pmatrix}$$

Die Informationen dieser Matrix müssen im Voraus durch einen Prozess bereitgestellt werden. Zu einem bestimmten Zeitpunkt belegt jeder Prozess i genau A_{ij} Ressourcen vom Typ R_j, was dargestellt wird als

Allocation=

$$\begin{pmatrix} A_{11} & \cdots & A_{1m} \\ \cdots & \cdots & \cdots \\ A_{n1} & \cdots & A_{nm} \end{pmatrix}$$

Damit ergeben sich folgende Zusammenhänge:

1. $R_i = V_i + \sum_{k=1}^{n} A_{ki} \quad \forall$ Ressourcen i,
   d.h. jede Ressource ist entweder verfügbar oder genau einem Prozess zugeordnet.

2. $C_{ki} \leq R_i \quad \forall$ Prozesse k und Ressourcen i,
   d.h. kein Prozess kann von irgendeiner Ressource mehr belegen als im gesamten System vorhanden ist.

3. $A_{ki} \leq C_{ki} \quad \forall$ Prozesse k und Ressourcen i,
   d.h. kein Prozess kann von irgendeiner Ressource mehr belegen als er ursprünglich durch die Claim-Werte C_{ki} angefordert hat.

Mit diesen Größen kann eine Vorschrift zur Deadlockvermeidung (**Deadlock Avoidance Policy**) wie folgt definiert werden:
Starte keinen neuen Prozess, falls dessen Ressourcenanforderungen zu einem Deadlock führen könnten. D.h. starte einen neuen Prozess P_{n+1} nur, falls $R_i \geq C_{(n+1)_i} + \sum_{k=1}^{n} C_{ki}$ $\forall$ Ressourcen i gilt.
Begründung: In diesem Fall wäre es möglich, dass alle gerade laufenden Prozesse quasi gleichzeitig maximale Anforderungen an die Ressource i stellen würden (Worst Case Abschätzung). Diese Strategie funktioniert zwar, ist aber weit von einem optimalen Systemverhalten entfernt, das die gleichzeitige Verwaltung möglichst vieler Prozesse ermöglicht.

Wir wollen nun einen alternativen Algorithmus betrachten.

II. Ressource Allocation Denial (Ablehnen einer Ressourcenbelegung oder **Bankers Algorithm**)

Der 1965 von Dijkstra vorgeschlagene Algorithmus betrachtet ein System mit fester Anzahl von Prozessen und Ressourcen. Zu jedem Zeitpunkt sind einem Prozess null oder mehr Ressourcen zugeordnet.
$\rightarrow$Zustand des Systems:

– aktuelle Zuordnung von Ressourcen zu einem Prozess

– Zustand wird durch Vektoren und Matrizen beschrieben (Ressourcen, Verfügbarkeit, Claim, Allocation)

Ein **sicherer Zustand** (*safe state*) wird wie folgt definiert: $\exists$ mindestens eine Folge von Prozessabläufen, die nicht zu einem Deadlock führt, sondern bei der alle Prozesse erfolgreich bis zum Ende abgearbeitet werden können.
Ein **unsicherer Zustand** ist ein Zustand, der nicht sicher ist.

Beispiel 6.1. *Es soll ein sicherer Zustand dargestellt werden (vgl. Abbildung 6.1). Dieser Zustand ist sicher, da die Abarbeitungsfolge* P_2, P_1, P_3 *ohne Deadlock möglich ist.* P_2 *wird nach Zuweisung einer Ressource vom Typ* R_3 *abgearbeitet.* $\rightarrow$run-to-completion *und Programmzustand war sicher.*
Deadlock Avoidance Strategie: Das System soll stets in einem sicheren Zustand gehalten werden, d.h., bei einer Ressourcenanfrage wird kontrolliert, ob nach einer evtl. Zuteilung noch ein sicherer Zustand vorliegt. Ist dies nicht der Fall, wird die Anfrage abgelehnt.

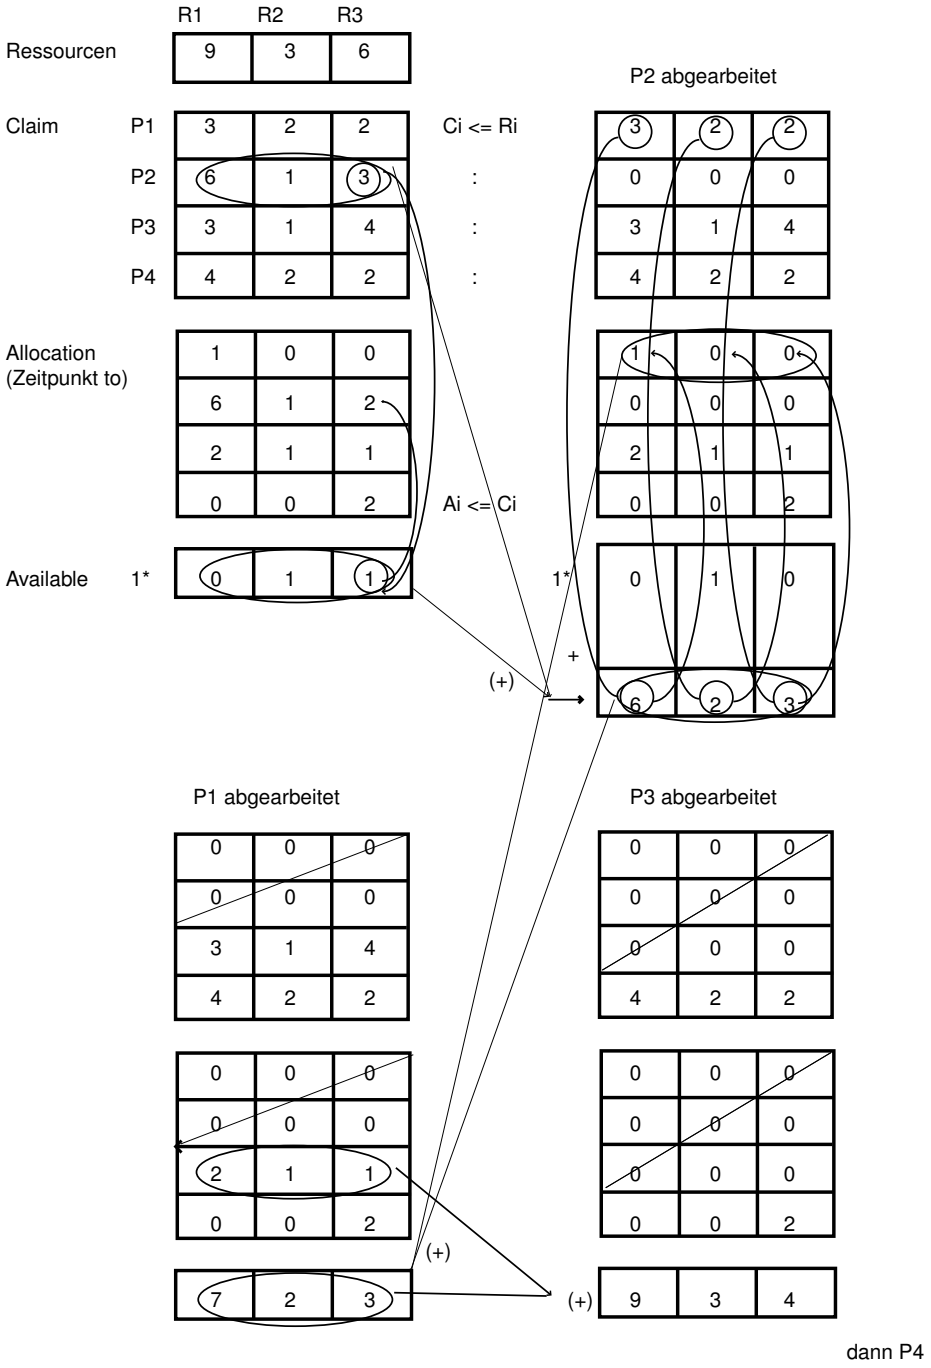

Abbildung 6.8: Beispiel eines sicheren Zustandes

Beispiel 6.2. *Es soll ein unsicherer Zustand dargestellt werden (vgl. Abbildung 6.2).*
R_1 *ist nicht mehr vorhanden, wird aber von jedem Prozess zur vollständigen Abarbeitung benötigt. Ein Deadlock ist an dieser Stelle nicht mehr ausgeschlossen: die Anforderung von* R_1 *und* R_3 *durch* P_1 *würde zu einem unsicheren Zustand führen und muss deshalb abgelehnt werden. Ob tatsächlich ein Deadlock auftritt, hängt jedoch von der konkreten Implementierung und den*

spezifischen Anforderungen (in welcher Reihenfolge wird welche Ressource wieder freigegeben) der anderen Prozesse ab.

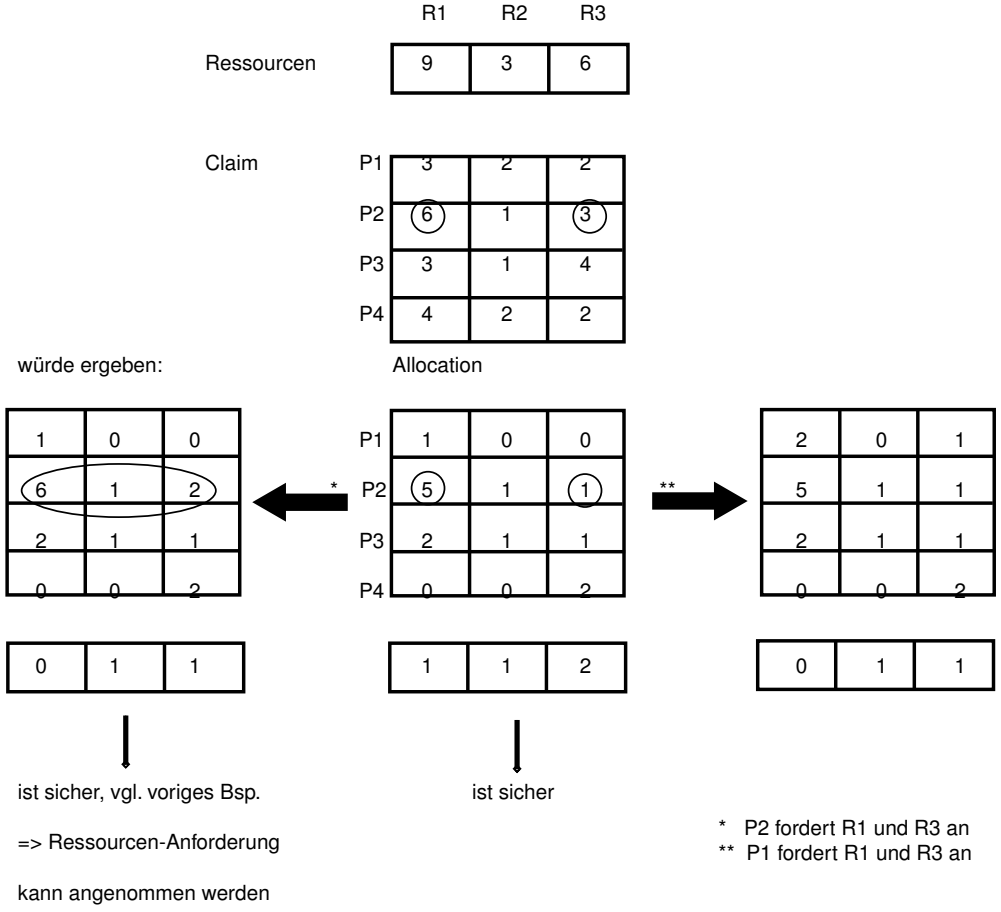

Abbildung 6.9: Beispiel eines unsicheren Zustandes

6.3.2 Petri-Netze zur Prozeßmodellierung

Petri-Netze sind zur Modellierung von nebenläufigen, asynchronen Prozessen geeignet. Sie veranschaulichen Vorgänge und ermöglichen eine Ableitung von Eigenschaften des modellierten Systems.

Definition 6.2 (Netz)**.** Sei $X = (S \cup T, F)$ ein endlicher Graph mit $S \cap T = \emptyset$ (S und T disjunkt). Dann heißt X **Netz** genau dann, wenn

1. S eine endliche Menge $S = \{s_1, \ldots, s_m\}$ von Stellen,
2. T eine endliche Menge $T = \{t_1, \ldots, t_n\}$ von Transitionen und
3. $F \subset (S \times T) \cup (T \times S)$ eine Menge von Kanten ist (X ist also ein gerichteter Graph).

Bemerkung 6.1. *Damit dürfen zwischen je zwei Stellen und zwei Transitionen keine Kanten auftreten. Eine Kante besteht also zwischen genau einer Stelle* s *und einer Transition* t*, entweder von* s *nach* t *oder* t *nach* s*.*

Graphisch werden Stellen als Kreise, Transitionen als (schmale) Rechtecke und Kanten als Pfeile dargestellt, wie in 6.10.

Beispiel für ein Petri-Netz mit $S = \{S_1, S_2, S_3\}$, $T = \{T_1, T_2, T_3\}$ und $F = (S_1, T_1), (S_1, T_2), (S_2, T_1), (S_2, T_2), (T_1, S_3), (T_2, S_3), (S_3, T_3), (T_3, S_1), (T_3, S_2)\}$. Durch die Angabe von S, T und F ist das Netz vollständig beschrieben.

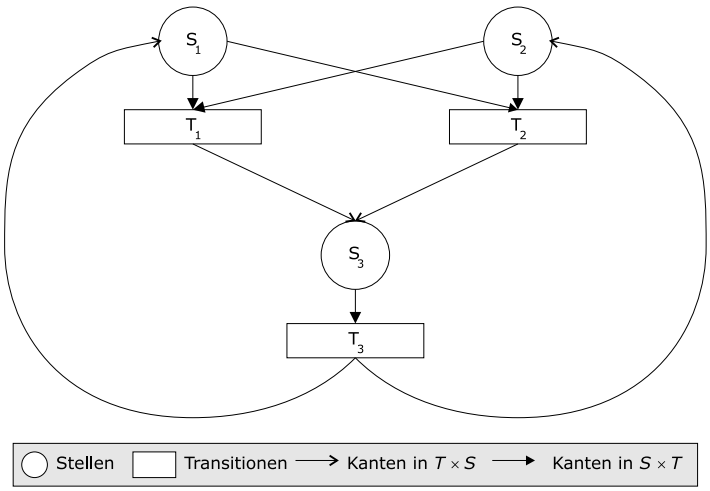

Abbildung 6.10: Beispiel für ein Petri-Netz

Ein sehr gebräuchliches Konzept eines Petri-Netzes ist das sogenannte Stellen/Transitions-System:

Definition 6.3 (Stellen/Transitions-System)**.** Ein **Stellen/Transitions-System** ist ein 6-Tupel $Y = (S, T, F, K, W, M_0)$ bestehend aus einem Netz (S, T, F) sowie den Abbildungen

1. $K : S \longrightarrow \mathbb{N} \cup \{\infty\}$, durch die jeder Stelle eine *Kapazität* zugeordnet wird,

2. $W : F \longrightarrow \mathbb{N}$, durch die jeder Kante ein *Kantengewicht* zugeordnet wird und

3. $M : S \longrightarrow \mathbb{N}$ (Markierung), durch die jeder Stelle eine Anzahl von *Marken* (Token) zugeordnet wird.

Dabei kann eine Stelle nie mehr Marken aufnehmen als ihre Kapazität erlaubt, d.h. für alle $s \in S$ gilt $M(s) \leq K(s)$.
M_0 heißt *Anfangsmarkierung* und stellt die Markierung dar, wie sie zu Beginn des durch das Petri-Netz modellierten Prozesses vorliegt.

Bemerkung 6.2. *Im einfachsten Fall beträgt das Kantengewicht* 1 *und wird nicht weiter angegeben. Analog nimmt man als Kapazität der Stellen* ∞ *an, wenn keine Angabe erfolgt.*

Bemerkung 6.3. *Marken werden graphisch durch schwarze Punkte innerhalb der kreisförmigen Stellen symbolisiert (vgl. Abbildung 6.11).*

1. Bsp

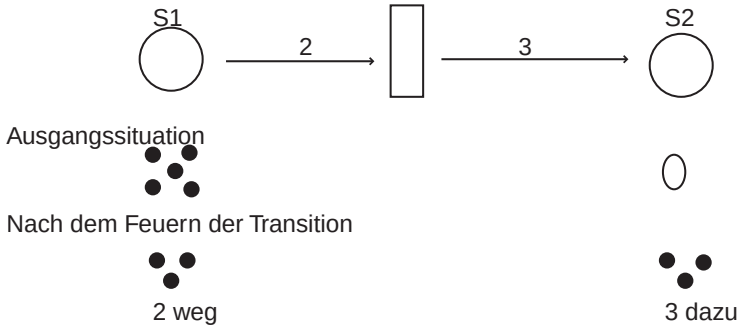

Falls kein Kantengewicht angegeben ist, so ist W = 1

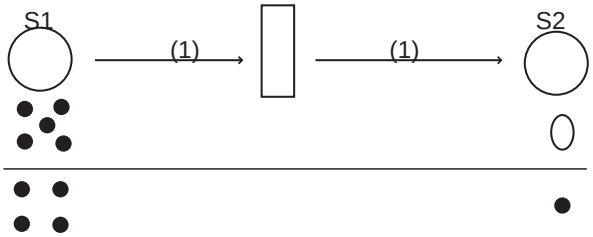

2. Bsp zur Kapazität

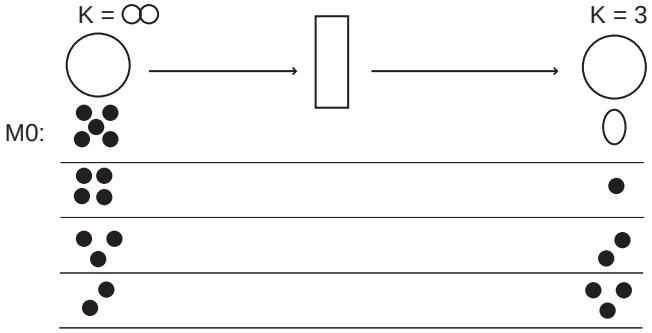

nun ist kein weiteres Feuern möglich, da die Kapazität der rechten Stelle nur 3 Token zulässt.

3. Bsp

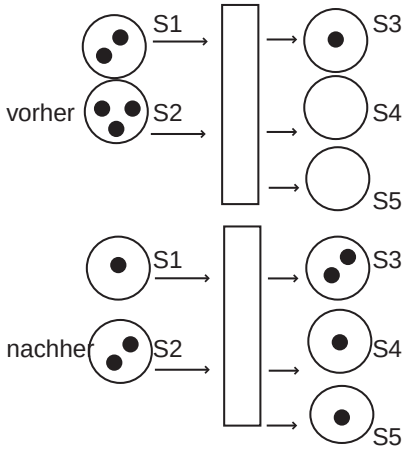

5 Stellen mit Kapazität ○○ , 5 Kanten mit W = 1

M0 = ((S1, 2), (S2, 3), (S3, 1), (S4, 0), (S5, 0))

Folgemarkierung

M1 = ((S1, 1), (S2, 2), (S3, 2), (S4, 1), (S5, 1))

einfacher (1, 2, 2, 1, 1)

Abbildung 6.11: Stellen-Transitionssysteme

Beziehungen zu Prozessen

Die **Stellen eines Petri-Netzes** repräsentieren z.B. Signale, Daten, Speicher eines Objekts, d.h. statische Objekte. Bei Speichern kann die Anzahl der Marken beispielsweise die Anzahl der im Speicher vorhandenen Objekte repräsentieren.
Die **Transitionen eines Petri-Netzes** repräsentieren z.B. Ereignisse, Vorgänge, Berechnungsschritte oder Jobs, d.h. Aktionen.
Die modellierten Systeme sollen dynamisch sein, es stellt sich also die Frage, wie Ereignisse ausgeführt werden. Dies wird durch Schalten der zugehörigen Transition erreicht, d.h. es werden zur Beschreibung der Dynamik eines Systems zusätzlich sogenannte Schaltregeln benötigt.

Definition 6.4. Sei $x \in S \cup T$. Dann definiert man

1. $\cdot x := \{y \in S \cup T : (y, x) \in F\}$ heißt der Vorbereich einer Stelle $s \in S$ bzw. einer Transition $t \in T$.

2. $x\cdot := \{y \in S \cup T : (x, y) \in F\}$ heißt der Nachbereich einer Stelle $s \in S$ bzw. einer Transition $t \in T$.

3. $-x := \{(y, x) \in (S \times T) \cup (T \times S) : (y, x) \in F\}$ heißt die Menge aller **Eingangskanten** von x und

4. $x- := \{(x, y) \in (S \times T) \cup (T \times S) : (x, y) \in F\}$ heißt die Menge aller **Ausgangskanten** von x.

Bemerkung 6.4. *Der Vorbereich einer Stelle besteht nur aus Transitionen, der Vorbereich einer Transition nur aus Stellen.*

Beispiel 6.3. *Wir wollen uns anhand des **Fünf-Philosophen-Problems** ein Petri-Netz modellieren (vgl. Abbildung 6.12).*

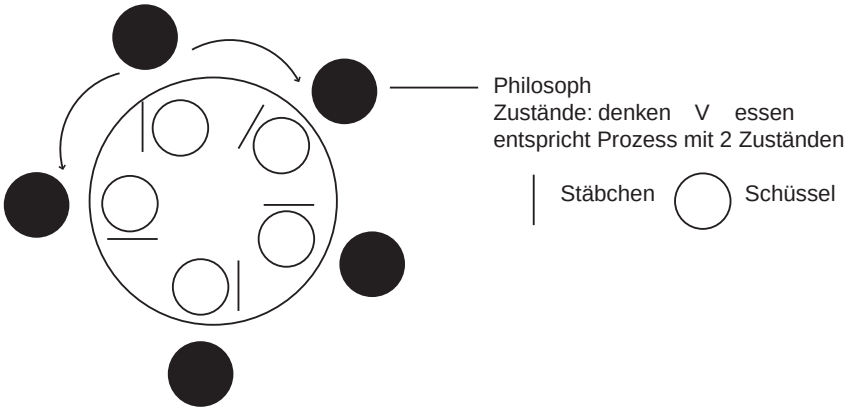

Abbildung 6.12: Philosophenproblem mit 5 Philosophen

Wir stellen einen Prozess durch Stellen dar und zwar pro Prozesszustand eine Stelle (vgl. Abbildung 6.13). Um von einem Prozesszustand in einen anderen überzugehen, muss eine dazwischen liegende Transition feuern. Die BM werden durch Token in bestimmten Stllen dargestellt.

Hier: Stäbchen (=BM) kann frei verfügbar sein (d.h. liegt auf dem Tisch) →Dafür wird eine Stelle benötigt (Denken).
Oder: Stäbchen wird von einem Philosophen genutzt (Essen)

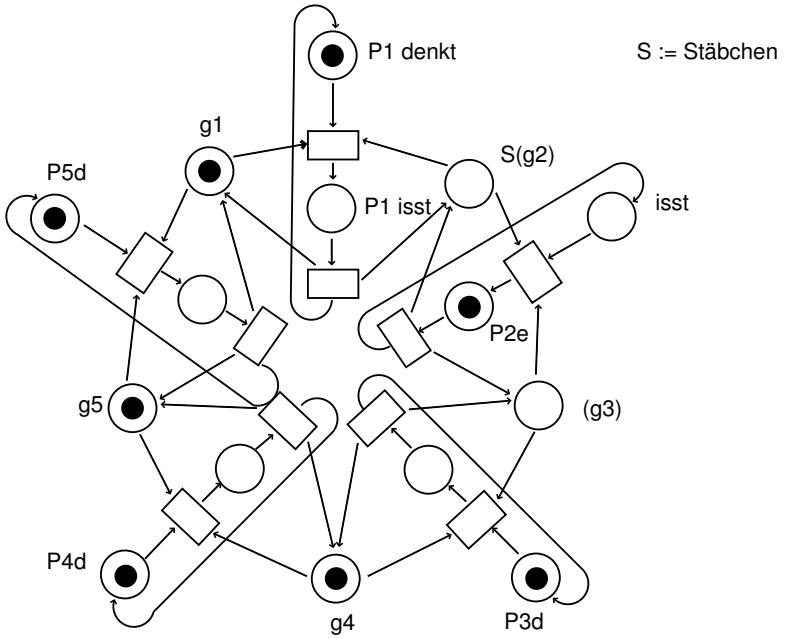

Abbildung 6.13: Petri-Netz zum Philosophenproblem mit 5 Philosophen

6.3.3 Markierungen

Definition 6.5. Sei M ein Markierung. Dann kann M eine Menge $T_{akt}(M)$ zugeordnet werden mit

$$T_{akt}(M) = \{t \in T : (\forall s \in {\cdot}t : M(s) \geq W(s,t)) \wedge (\forall s \in t^{\cdot} : M(s) + W(t,s) \leq K(s))\}.$$

Die in $T_{akt}(M)$ enthaltenen Transitionen heißen **aktiviert** unter der Markierung M. Solche Transitionen können schalten (oder feuern). Abbildung 6.14 zeigt ein Stellen-Transitionssystem mit Markierungen.

Bemerkung 6.5. $(\forall s \in t^{\cdot} : M(s) + W(t,s) \leq K(s))$ *: durch neu hinzukommende Marken wird die Kapazität der Stelle* n *im Nachbereich der Transition nicht überschritten.*

Bemerkung 6.6. *Zu einem Zeitpunkt kann (in der Regel) nur je eine Transition schalten (oder feuern).*

Bemerkung 6.7. *Mehrere Transitionen feuern sequentiell nacheinander (Quasiparallelität)*

Bemerkung 6.8. *Eine Transition* $t \in T$ *ist also genau dann aktiviert, wenn mindestens soviel "Input" zur Verfügung steht wie das Gewicht (die "Bandbreite") der eingehenden Kanten* und *genügend Platz für den "Output" bereit steht.*

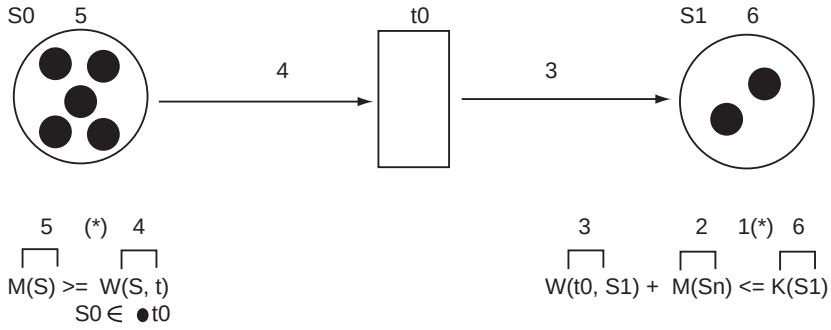

Abbildung 6.14: Stellen-Transitionssystem mit Markierungen

Beispiel 6.4 (Markierte Petri-Netze)**.** *Es soll das Petri-Netz in Abbildung 6.15 betrachtet werden, wobei alle Kanten mit* 1 *gewichtet seien und die Kapazität der Stellen* ∞ *betrage. Als Markierung* M *gegeben:* $\{(S_1, 1), (S_2, 2), (S_3, 0)\}$*, d.h.* S_1 *besitzt eine,* S_2 *zwei und* S_3 *keine Marke.*

Gemäß Definition sind nun die Transitionen T_1 *und* T_2 *aktiviert,* T_3 *ist nicht aktiviert, da z.B. für* T_1 *gilt: Für alle Stellen im Vorbereich von* T_1*, d.h. für* S_1 *und* S_2*, gilt* $M(s) \geq W(s,t) = 1$*, da* $M(S_1) = 1$ *und* $M(S_2) = 2$*. Außerdem ist für alle Stellen* $s \in T_1$*, also für* S_3*,* $M(s) + W(T_1, s) \leq K(s)$*, da die Kapazität aller Stellen* ∞ *ist.*

Feuert nun die Transition T_1*, so ergibt sich die in der 6.15 gezeigte Folgemarkierung. Analog hätte auch* T_2 *feuern können (die Eingangs- und Ausgangskanten von* T_2 *und* T_1 *sind gleich) und zu der gleichen Folgemarkierung geführt.*

Nun ist T_3 *aktiv (kann feuern), nicht aber* T_1 *und* T_2*. Feuert* T_3*, so ist die Belegung der Marken wie vor dem Feuern von* T_1*.*

Durch Schalten oder Feuern einer aktiven Transition ergibt sich aus der Markierung M die unmittelbare Folgemarkierung M' wie folgt:

$$M'(s) = \begin{cases} M(s) - W(s,t) & \text{für } s \in (\cdot t) \setminus (t\cdot) (1.) \\ M(s) + W(t,s) & \text{für } s \in (t\cdot) \setminus (\cdot t) (2.) \\ M(s) - W(s,t) + W(t,s) & \text{für } s \in (t\cdot) \cap (\cdot t) (3.) \\ M(s) & \text{für } s \notin (\cdot t) \cup (t\cdot) (4.) \end{cases}$$

Dabei bedeuten:

1. alle Stellen des Vorbereichs der feuernden Transition

2. alle Stellen des Nachbereichs einer feuernden Transition

3. Stellen des Vor- und Nachbereichs der feuernden Transition

4. alle Stellen, die keine Kante zur feuernden Transition aufweisen

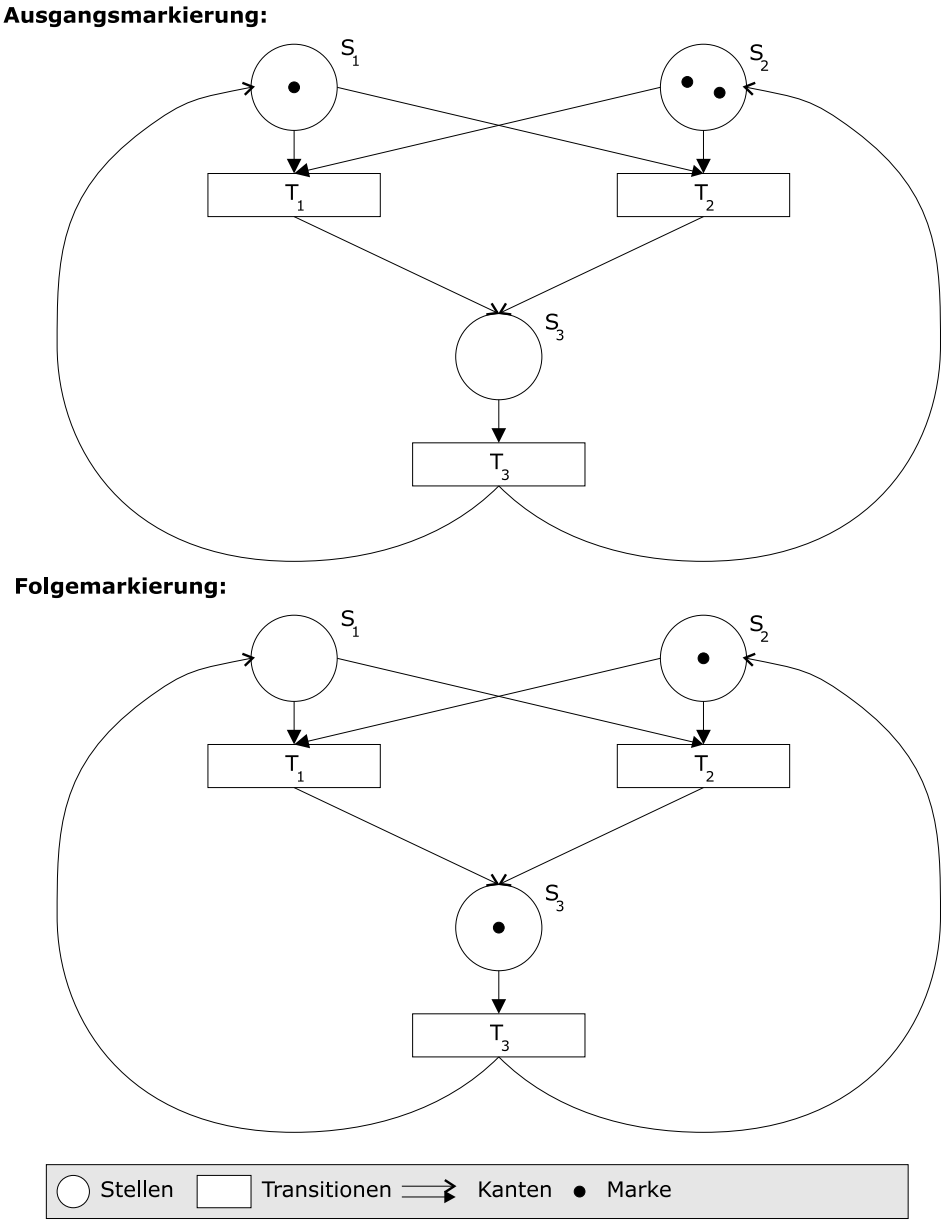

Abbildung 6.15: Petri-Netz mit Markierung und Folgemarkierung

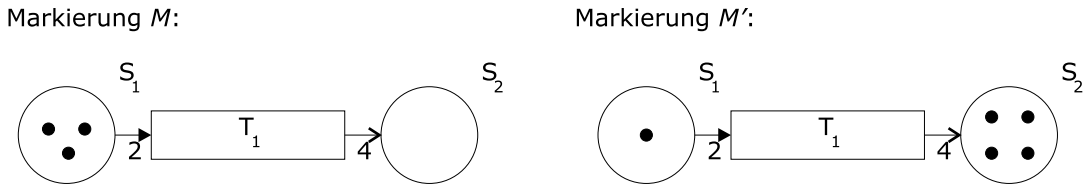

Abbildung 6.16: Petri-Netz mit Markierung und Gewichtung

Beispiel 6.5 (Gewichtete markierte Petri-Netze)**.** *Sei wieder die Kapazität der Stellen ∞, jedoch die Kanten einzeln gewichtet. Dann ergibt sich ein Bild wie in Abbildung 6.16.*

6.3.4 Modellierung von nebenläufigen Prozessen

Petri-Netze können z.B. zur Modellierung von nebenläufigen Prozessen genutzt werden, z.B. im Falle des klassischen Erzeuger/Verbraucher-Problems.
Es handelt sich bei diesem Problem um zwei Prozesse (E=Erzeuger, V=Verbraucher), von denen E Resultate produziert, die V auf dem Drucker ausgeben soll. Zur Synchronisation wird ein endlicher Speicher S der Kapazität MAX eingeführt, der von E gefüllt und von V geleert wird. Es treten bei der Synchronisation 3 Probleme auf:

1. V darf nur auf produzierte Daten von S zugreifen

2. E darf nur bei freien Plätzen ablegen

3. Speicher S darf nicht gleichzeitig von E und V verändert werden

Zur Realisierung des E/V-Problems benötigen wir drei Semaphoren (siehe Kapitel 7) und zwar für die Modellierung des freien Platzes, des Speicherzugriffs und des belegten Platzes. Dann entspricht das Schalten des Petri-Netzes der Zuteilung des Prozessors.
Als Ausgangssituation sei angenommen, daß drei freie Plätze zur Verfügung stehen und noch kein Platz belegt wurde (vgl. Abbildung 6.17).
Dabei bedeuten eine bzw. x Markierungen in

S_1**:** Prozess E hat ein erzeugtes Element

S_2**:** Prozess E greift auf den Speicher S zu

S_3**:** Prozess E hat den Speicher S wieder freigegeben und noch kein Element erzeugt

S_4**:** Es gibt x freie Plätze

S_5**:** Der exklusive Zugriff durch Prozesse E oder V auf Speicher S ist möglich

S_6**:** Es gibt x belegte Plätze

S_7**:** Prozess V möchte ein Element verbrauchen

S_8**:** Prozess V greift auf den Speicher S zu

Bemerkung 6.9. S_5 *ist eine Synchronisationssemaphore (vgl. binäre Semaphore in Kapitel 7).*

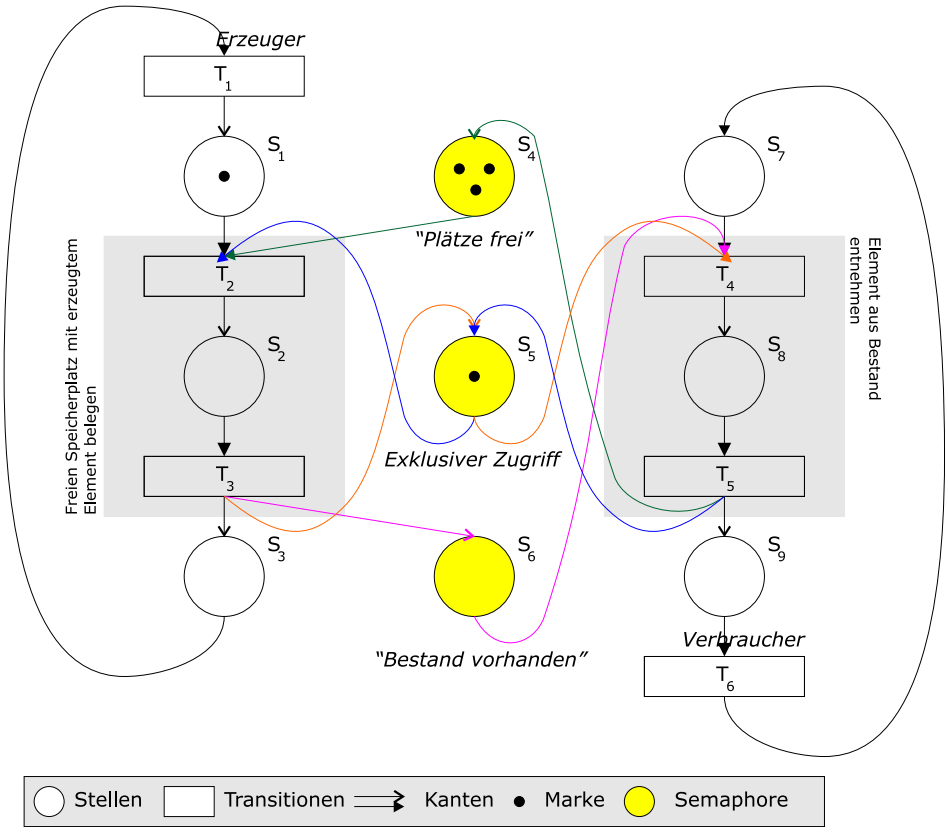

Abbildung 6.17: Petri-Netz zur Modellierung des Erzeuger/Verbraucher-Problems

Beispiel 6.6. *Leser/Schreiber-Problem (Reader/Writer-Problem)*
Das Leser/Schreiber-Problem wird auf verschiedene Arten realisiert:

1. *R/W-Problem →Leser muss (müssen) nur dann warten, wenn ein Schreiber aktiv ist (Schreiber kann verhungern!!)*

2. *R/W-Problem →Wartet der Schreiber, so darf kein neuer Leser mit dem Lesen beginnen.*

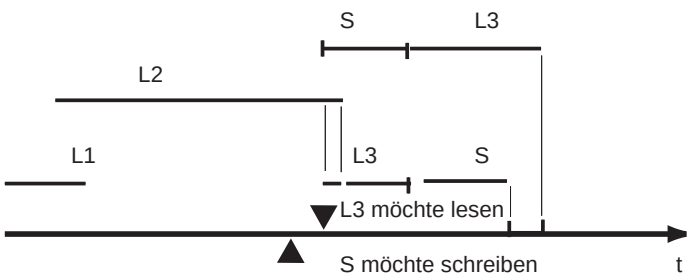

Abbildung 6.18: R/W-Problem

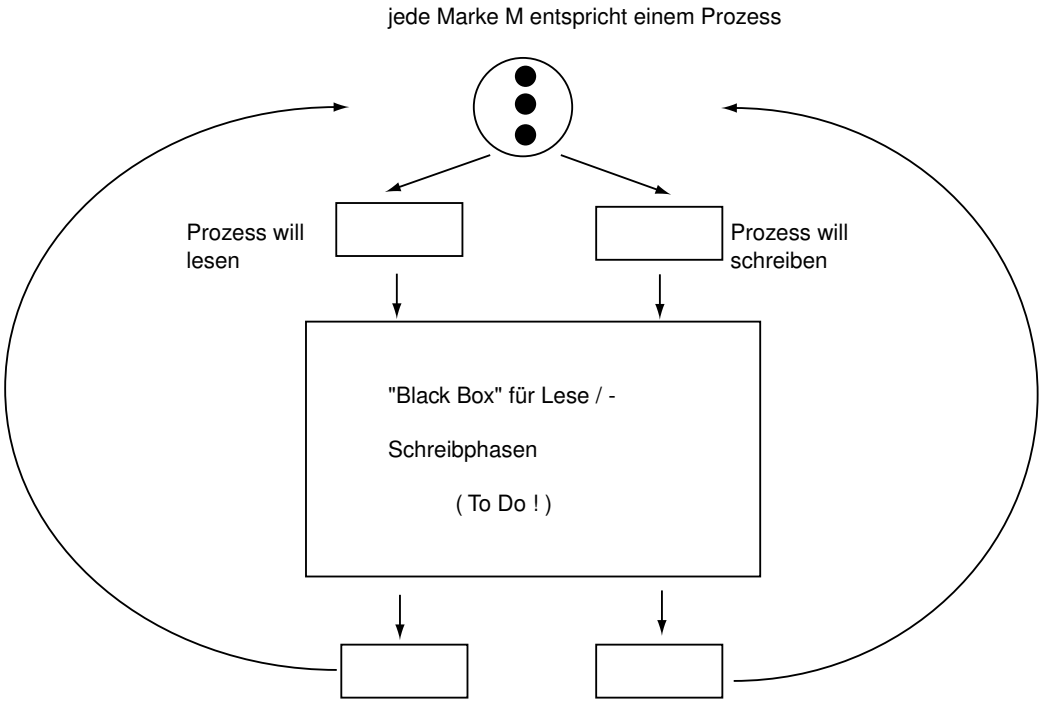

Abbildung 6.19: Einfaches Petri-Netz zum R/W-Problem

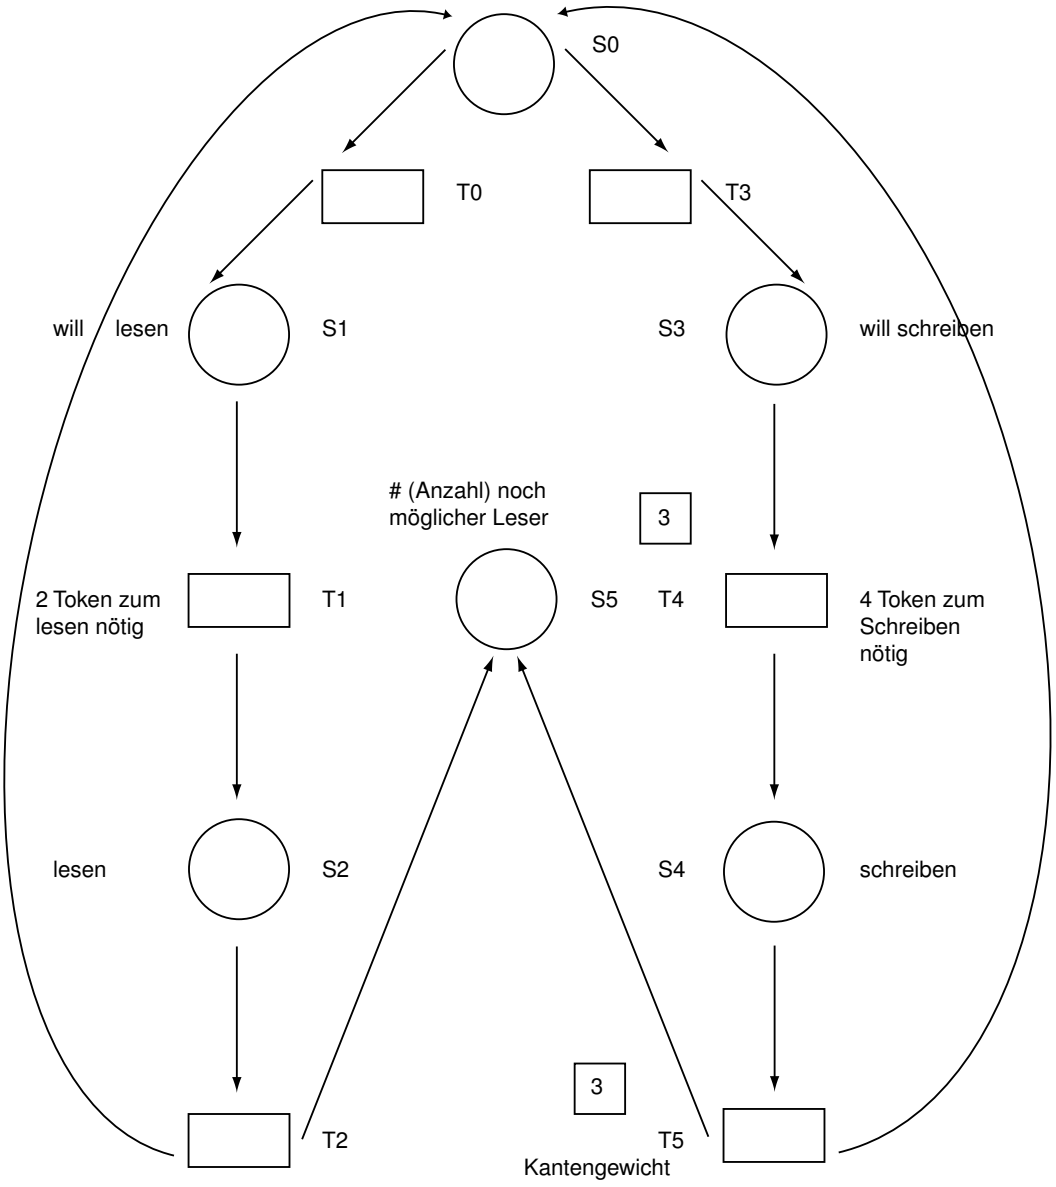

Abbildung 6.20: Fertiges Petri-Netz zum R/W-Problem

z. B. (mögliches Systemverhalten):

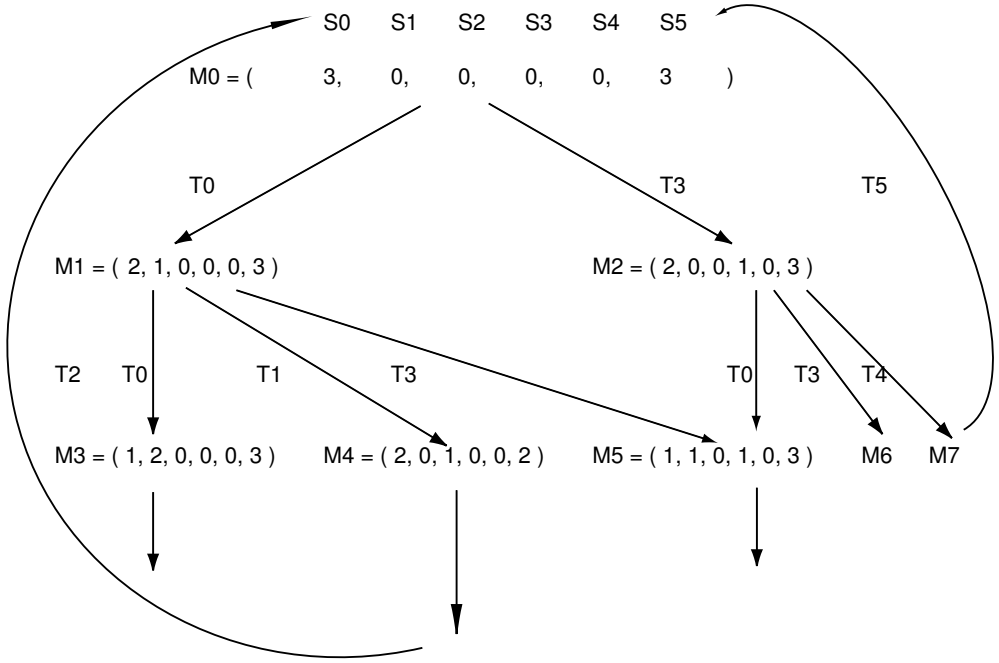

Abbildung 6.21: Erreichbarkeitsgraph zum R/W-Problem

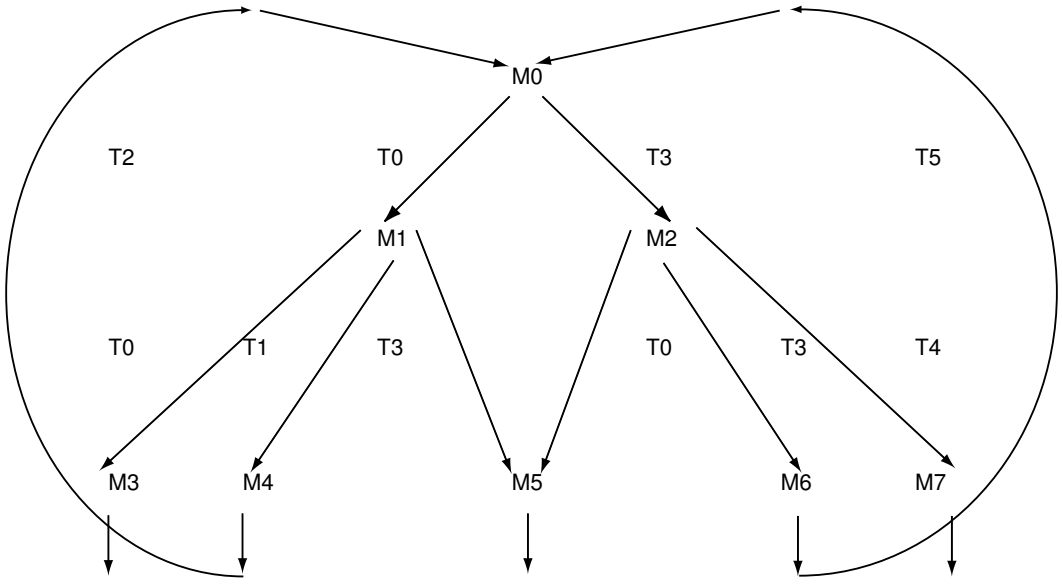

Abbildung 6.22: Vereinfachter Erreichbarkeitsgraph zum R/W-Problem

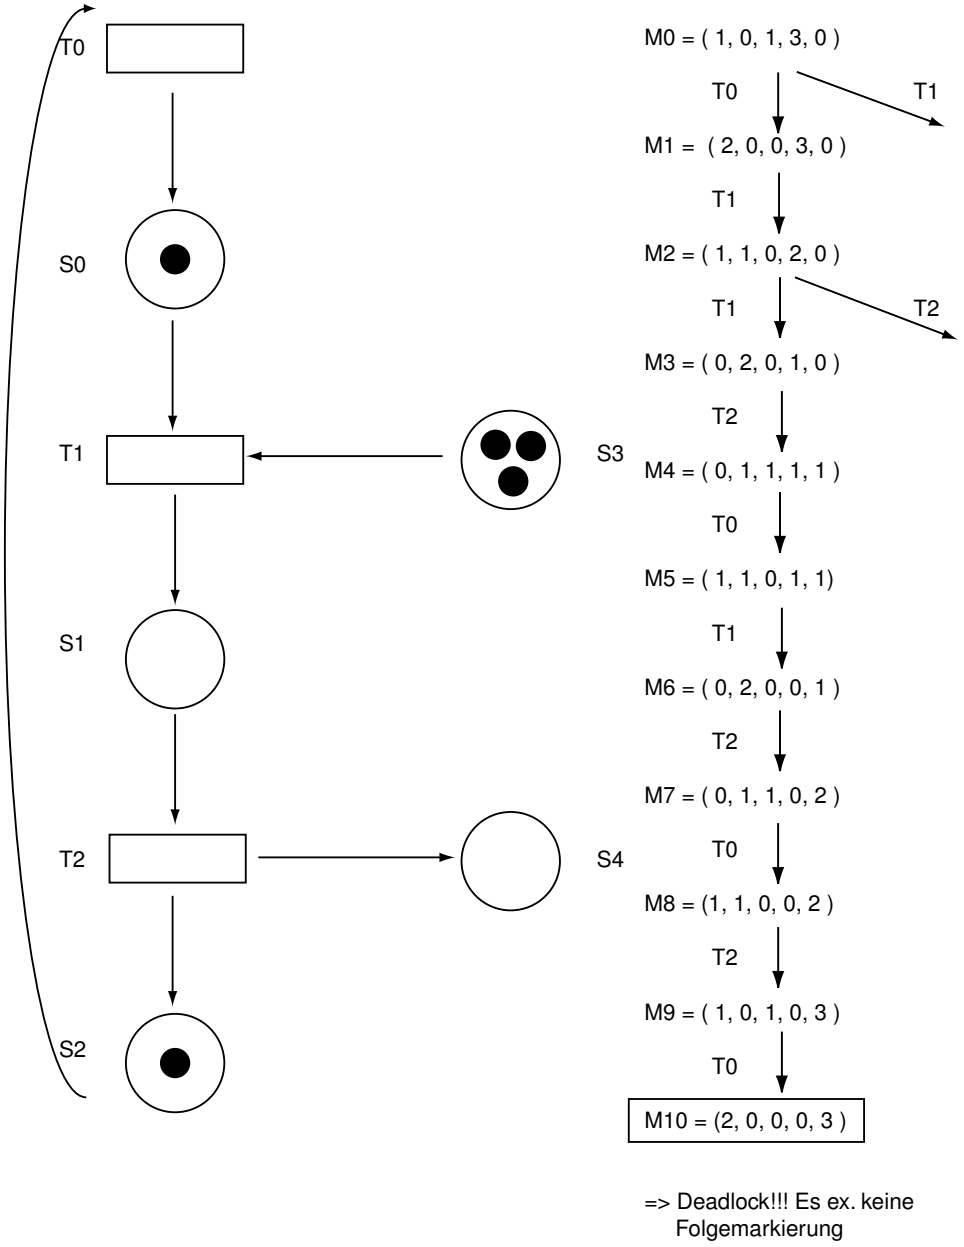

Abbildung 6.23: Beispiel eines Deadlocks

6.3.5 Deadlock Detection (Deadlockerkennung)

Diese Methode betrachtet nicht die zuvor benutzten 3 Bedingungen, sondern prüft in periodischen Zeitabständen, ob ein Circular Wait vorliegt. Ist dies der Fall, werden *Recovering-Strategien* angewandt, die einen Abbruch der verklemmten Prozesse realisieren. Im Folgenden sollen Methoden zur Deadlockerkennung vorgestellt werden.
Teilweise (*partial deadlocks*) und vollständige Verklemmungen (*deadlocks*) kann man durch eine Analyse von Petri-Netzen erkennen und somit vermeiden. Dazu wird das Hilfsmittel des *Erreichbarkeitsgraphen* genutzt:

Definition 6.6 (Erreichbarkeitsgraph)**.** Sei Y ein gegebenes Petri-Netz, $T = \{t_1, t_2, \ldots\}$ die Menge der einfachen und $T^* = \cup_{n=0}^{\infty} T^n$ die Menge der verketteten **Transitionen**.
Dann heißt eine Markierung M' von M aus erreichbar, falls $t_1 t_2 t_3 \ldots t_n \in T^*$ und ein $n \in \mathbb{N}_0$ existieren, so daß

$$M \xrightarrow{t_1} M_1 \xrightarrow{t_2} M_2 \xrightarrow{t_3} \ldots \xrightarrow{t_n} M'.$$

Hierfür schreibt man auch $M \xrightarrow{t_1 t_2 \ldots t_n} M'$. M' wird hierbei als Folgemarkierung von M bezeichnet.
Die **Erreichbarkeitsmenge** E_Y zu dem Petri-Netz Y enthält die Anfangsmarkierung M_0 und alle Markierungen, die von dieser aus erreichbar sind, d.h.

$$E_Y = E_Y(M_0) := \{M' : \exists n \in \mathbb{N}_0, t_1, \ldots, t_n \in T^* : M_0 \xrightarrow{t_1 \ldots t_n} M'\}.$$

Der **Erreichbarkeitsgraph** verbindet über eine Kante alle Markierungen $M, M' \in E_Y$, für die ein $t_i \in T$ existiert, so daß $M \xrightarrow{t_i} M'$. Zwischen M und M' existiert also genau dann eine Kante im Erreichbarkeitsgraphen, wenn M' unmittelbare Folgemarkierung von M ist. t_i wird zur Kantenbeschriftung benutzt. Abbildung 6.24 zeigt den Erreichbarkeitsgraph zu Abbildung 6.17.

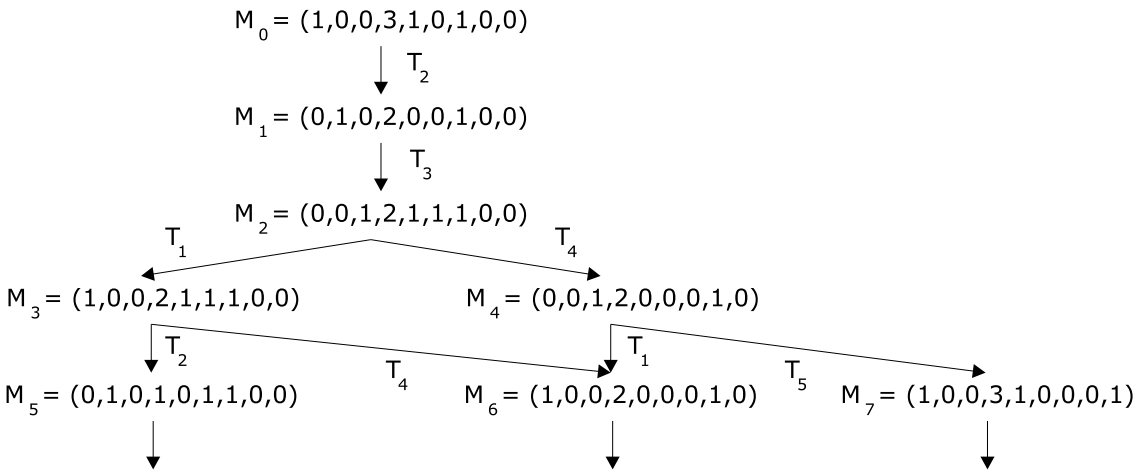

Abbildung 6.24: Erreichbarkeitsgraph zu Abbildung 6.17

In der Regel entsteht als Erreichbarkeitsgraph ein zyklischer, stark zusammenhängender Graph, bei dem jeder Zustand, d.h. jede Markierung von jeder beliebigen anderen aus erreichbar ist. Ein solches System heißt dann *verklemmungsfrei*. Es kann beliebig lange arbeiten, ohne in einen Zustand der Verklemmung zu gelangen.

Definition 6.7 (Verklemmung)**.** Sei wieder Y ein Petri-Netz und E_Y die zugehörige Erreichbarkeitsmenge. Existiere weiterhin eine Markierung $M \in E_Y$, für die es keine Nachfolgemarkierung M' mit $M \rightarrow M'$ gibt. Dann bezeichnet man den zugehörigen Zustand des Systems als **Deadlock** oder Verklemmung .

Definition 6.8 (Teilweise Verklemmung)**.** Sei wieder Y ein Petri-Netz und E_Y die zugehörige Erreichbarkeitsmenge. Existiere weiterhin eine Markierung $M \in E_Y$, die nicht (durch

das Schalten von endlich vielen Transitionen) von jeder anderen Markierung aus erreichbar ist. Dann bezeichnet man den zugehörigen Zustand des Systems als *partial deadlock* oder teilweise Verklemmung.

Befindet sich ein System im Zustand der Verklemmung, so befindet es sich auch im Zustand der teilweisen Verklemmung. Es kann jedoch teilweise Verklemmungen geben, die keine (echten) Verklemmungen sind.

Beispiel 6.7 (Deadlock und Partial Deadlock)**.** *Wir betrachten noch einmal das Petri-Netz aus Abbildung 6.17. Angenommen es stünden beliebig viele Plätze zur Verfügung und man erzeuge, ohne zu verbrauchen. Dann erhält man eine teilweise Verklemmung (vgl. Abbildung 6.25), da* M_1 *nicht mehr von* M_2 *oder* M_4 *erreichbar ist, jedoch keine Verklemmung, da stets eine Folgemarkierung existiert: Da kein Bestand mehr verbraucht wird, entstehen ständig neue Zustände im betrachteten System.*

Einen Deadlock erhält man hingegen, wenn die Synchronisationssemaphore S *nach Verlassen des kritischen Bereichs nicht wieder freigegeben wird (vgl. Abbildung 6.26). Nun kann keine Transition mehr schalten – deshalb gibt es keine Folgemarkierung – und es liegt ein Deadlock vor. Das gleiche Problem würde auch bei dem Petri-Netz aus Abbildung 6.17 vorliegen, wenn es keine Kante zwischen* T_3 *und* S_5 *geben würde.*

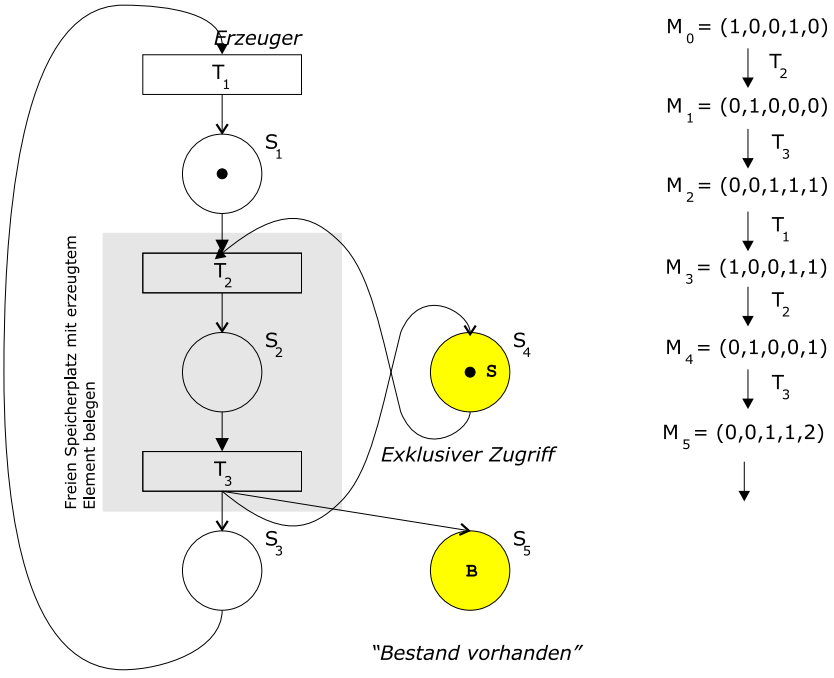

Abbildung 6.25: Entstehen eines Partial Deadlocks

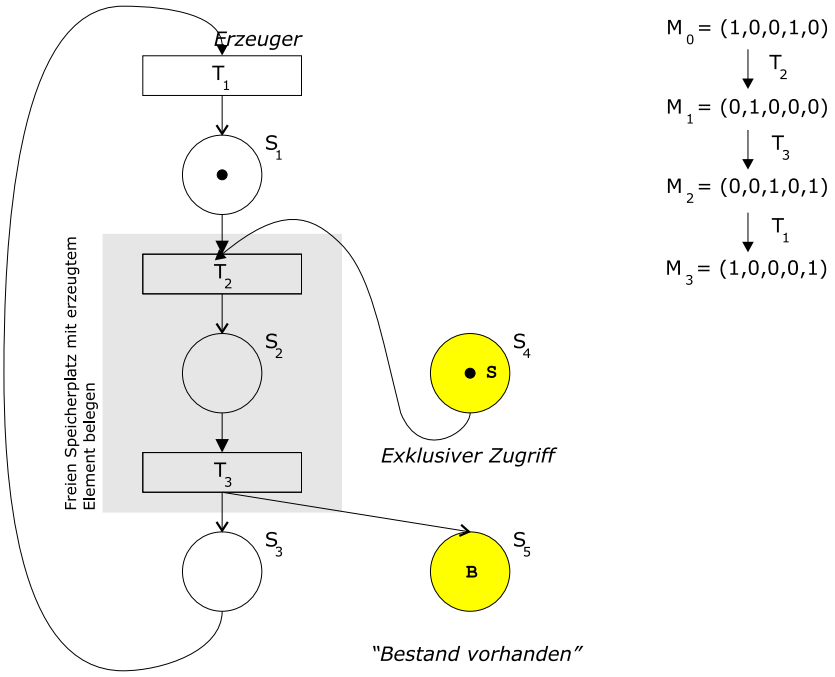

Abbildung 6.26: Entstehen eines Deadlocks

7

Prozesskoordination

- Parallele Prozesse
- Koordinierung von parallelen Prozessen
- Wechselseitiger Ausschluß
- Semaphore und Monitore

Inhaltsangabe

7.1 Nebenläufigkeit von Prozessen

Eine Aufgabe eines Betriebssystems ist das Vermitteln zwischen sich gegenseitig beeinflussenden Anforderungen der verschiedenen Programme bzw. Prozesse.

Definition 7.1 (Abhängige und unabhängige Abläufe)**.** Dabei unterscheidet man zwei Arten von Abläufen:

Unabhängige Abläufe: Gegebenenfalls parallel auszuführende Benutzeraufträge, die sich gegenseitig nicht beeinflussen, d.h. die für ihre Ausführung unterschiedliche Ressourcen des Systems benötigen (Speicher, Peripheriegeräte, etc.).

Abhängige Abläufe: Kooperierende Prozesse, die voneinander abhängig sind, da sie z.B. über gemeinsame Speicherbereiche Daten austauschen oder Betriebsmittel gemeinsam nutzen.

Probleme, die durch parallele Prozesse oder Abläufe entstehen, können gleichermaßen in Verteilten Systemen (z.B. Netzwerken, Parallelrechnern) entstehen, die über mehrere CPUs verfügen, als auch in einem zentralen System mit nur einer CPU.

Definition 7.2 (Parallelität)**.** Man unterscheidet allerdings je nach System die folgenden Formen der Parallelität von Prozessen:

Quasi-Parallelität: Parallele Abläufe sind quasi-parallel, wenn mehrere Prozesse von *einem* Prozessor stückweise bearbeitet werden (preemptive Schedulingstrategien).

Parallelität: Parallele Abläufe sind (echt) parallel, wenn *mehrere* Prozessoren ein oder mehrere Prozesse bearbeiten (Mehrprozessorsysteme).

Definition 7.3 (Nebenläufigkeit)**.** Mehrere Abläufe, die parallel oder quasi-parallel ausgeführt werden, heißen **nebenläufig**, wenn sie inhaltlich zusammenwirken, also voneinander abhängig sind und sich damit gegenseitig beeinflussen können, d.h.

$$\text{Nebenläufigkeit} = \text{Parallelität} + \text{Abhängigkeit}.$$

Die Verwaltung paralleler Prozesse wird erst dann interessant, wenn die einzelnen Prozesse voneinander abhängig sind, d.h. wenn es sich um nebenläufige Prozesse handelt. Solche Prozesse müssen dann koordiniert werden.

Definition 7.4 (Synchrones und asynchrones Ablaufverhalten)**.** Für die Koordination von Prozessen gibt es zwei grundsätzliche Vorgehensweisen:

Synchrones Ablaufverhalten: Alle Abläufe sind streng getaktet, so dass jeder der beteiligten Prozesse zu einem bestimmten Zeitpunkt an einer bestimmten Stelle seiner Ausführung angekommen ist.

Asynchrones Ablaufverhalten: Alle Abläufe erfolgen ungeregelt – eine Koordination wird durch das Eintreffen bestimmter Ereignisse erzielt (z.B. wenn ein bestimmtes Signal kommt, dann wird ein bestimmter Ablauf initiiert).

7.2 Kritische Bereiche

7.2.1 Erzeuger/Verbraucher-Problem

Beispiel 7.1. *Wir betrachten zwei Prozesse* E *und* V. E *berechnet Resultate,* V *soll diese auf einem Drucker ausgeben.*
E *erzeugt also Dinge (meist Daten), die* V *benötigt ("verbraucht").*

Um E und V zu synchronisieren, wird ein endlicher Speicherplatz der Kapazität `MAX` eingeführt, der von E gefüllt und von V geleert werden kann. Das **Synchronisationsproblem** besteht darin, dass

1. der Verbraucher nicht auf Daten zugreifen darf, die noch gar nicht produziert worden sind,
2. der Erzeuger keine Daten mehr ablegen darf, falls der Speicherplatz bereits gefüllt ist,
3. der Speicher nicht gleichzeitig von E und V verändert werden darf.

Einfacher Lösungsansatz

Vorläufig sei angenommen, dass die Bedingung 3 erfüllt sei. Das Erzeuger/Verbraucher-Problem soll mittels zwei Routinen `Erzeuger` und `Verbraucher` gelöst werden, die beide auf eine gemeinsame Variable `s`, den aktuellen "Lagerbestand", zugreifen (vgl. Programm 1).

Programm 1 Routinen für Erzeuger und Verbraucher – einfacher Lösungsansatz

Erzeuger:

```
1 REPEAT
  (* unkrit.Ber. *)
3 <erzeuge Element>;
  WHILE (s = MAX) DO skip;
5 (* Beg.krit.Ber. *)
  <lege Element im Speicher ab>;
7 s := s + 1;
  (* Ende krit.Ber. *)
9 UNTIL FALSE;
```

Verbraucher:

```
1 REPEAT
    WHILE (s = 0) DO skip;
3 (* Beg.krit.Ber. *)
    <entnimm Element aus Speicher>;
5   s := s - 1;
  (* Ende krit.Bereich *)
7 (* unkrit.Ber. *)
    <verbrauche Element>;
9 UNTIL FALSE;
```

Beide Routinen sollen unabhängig voneinander ablaufen. Daher sind bei unkontrolliertem Zugriff auf den Lagerbestand `s` Inkonsistenzen möglich.

Beispiel 7.2. *Sei z.B. angenommen* $s = 17$, $MAX = 20$ *und ein Scheduling, das alle* 3 *Zeittakte die Prozessorzuteilung zwischen Erzeuger und Verbraucher umschaltet.*
Bei der Ausführung entsteht dann u.U. ein Problem wie in 7.1 dargestellt: Obwohl sich die Anzahl der Elemente nicht geändert hat, wurde `s` *inkrementiert.*

Offensichtlich ist also der Zugriff auf gemeinsame Ressourcen (hier die gemeinsam genutzte Variable `s`) der kritische Teil in der vorliegenden Realisierung.

Lösung:

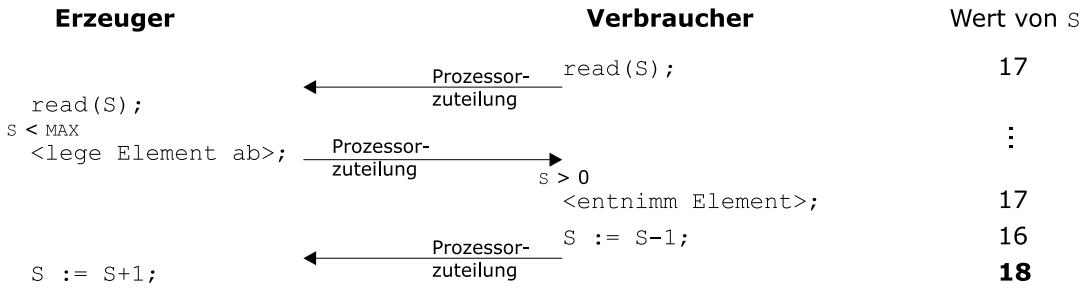

Abbildung 7.1: Ungeschützter Zugriff auf kritische Daten

1. Wir vermeiden Parallelität, d.h. nur nicht-preemptive Schedulingalgorithmen und damit sequentielle Ausführung der Prozesse wird zugelassen.

2. Vermeidung von Abhängigkeit →Ringpuffer

Lösungsansatz mit Ringpuffer

Eine Lösungsmöglichkeit für dieses Problem besteht im Einsatz eines **Ringpuffers**, wie er in 7.2 definiert ist.

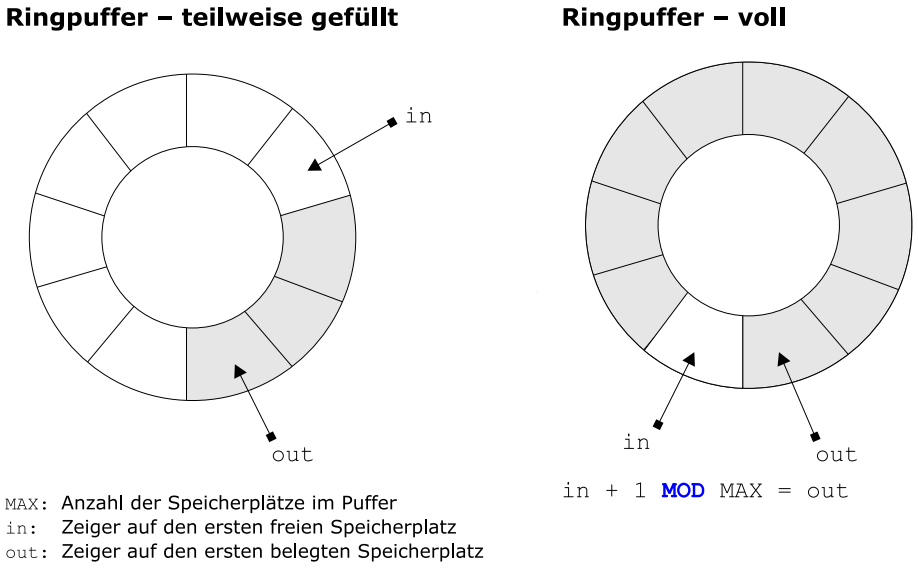

Abbildung 7.2: Darstellung eines einfachen Ringpuffers

Der Ringpuffer wird in Form eines eindimensionalen Arrays mittels einer Modulo-Funktion (`MOD MAX`) realisiert. Damit kann vorläufig nur ein Erzeuger und ein Verbraucher realisiert werden.
Der Erzeuger legt sein Element auf den ersten freien Speicherplatz ab, der Verbraucher entnimmt ein Element aus dem am längsten belegten Speicherplatz. Zur einfachen Erkennung

der Zustände leer und voll dürfen nur höchstens MAX − 1 Komponenten belegt werden. Dann ist der Speicher leer bei in = out und voll bei (in + 1) mod MAX = out (vgl. Programm 2).

Programm 2 Routinen für Erzeuger und Verbraucher – Lösungsansatz mit Ringpuffer

Erzeuger:

```
1 REPEAT
    <erzeuge Element>;
3   WHILE (in+1 MOD MAX = out) DO
      skip;
5   Speicher[in] := <Element>;
    in := in + 1 MOD MAX;
7 UNTIL FALSE;
```

Verbraucher:

```
1 REPEAT
    WHILE (in = out) DO skip;
3   <entnimm Element aus
      Speicher[out]>;
5   out := out + 1 MOD MAX;
    <verbrauche Element>;
7 UNTIL FALSE;
```

Wird das Erzeuger/Verbraucher-Problem auf mehrere Erzeuger oder Verbraucher erweitert, so können beim Schreiben des in- oder des out-Parameters Inkonsistenzen wie beim ursprünglichen Erzeuger/Verbraucher-Problem auftreten.

7.3 Wechselseitiger Ausschluß

Solange sich ein Prozess in einem kritischen Bereich befindet (z.B. ein Programm-Modul auf eine globale Variable zugreift), solange kann kein anderer Prozess in diesen kritischen Bereich eintreten.
Es sollen die n Prozesse $P_0, \ldots, P_{n-1}$. betrachtet werden. Der Programmcode jedes dieser Prozesse läßt sich in kritische und unkritische Bereiche aufteilen.

Definition 7.5 (Kritischer Bereich)**.** Unter einem **kritischen Bereich** versteht man eine Phase, in der dieser Prozess gemeinsam benutzte (globale) Daten oder Betriebsmittel nutzt.
Alle anderen Phasen werden als *unkritische Bereiche* des Prozesses bezeichnet.

Könnten sich zwei oder mehrere Prozesse gleichzeitig im kritischen Bereich befinden, so wäre das Ergebnis ihrer Operation nicht mehr determiniert, sondern von zufälligen Umständen wie z.B. der Prozessorzuteilung für die Prozesse (Scheduling-Strategie) abhängig.
Deshalb darf zu einem Zeitpunkt nur einem Prozess der Zugang zum kritischen Bereich gestattet werden.

Definition 7.6. Das Problem des wechselseitigen Ausschlusses besteht darin, Algorithmen zu finden, die – sobald sich ein Prozess im kritischen Bereich befindet – es keinem anderen Prozess mehr gestatten, den kritischen Bereich zu betreten.

Für eine korrekte Lösung des wechselseitigen Ausschlusses müssen die folgenden drei **Bedingungen** erfüllt sein:

1. *Mutual exclusion:* Zu jedem Zeitpunkt darf sich höchstens ein Prozess im kritischen Bereich befinden.

2. *Progress:* Befindet sich kein Prozess im kritischen Bereich, aber es gibt einen Kandidaten für diesen Bereich, so hängt die Entscheidung, welcher Prozess ihn betreten darf, nur von diesem Kandidaten ab und fällt in endlicher Zeit.

Insbesondere darf es keinen Einfluß haben, wenn ein Prozess in einem unkritischen Bereich terminiert (“stirbt”).

3. *Bounded Waiting:* Zwischen der Anforderung eines Prozesses, in den kritischen Bereich einzutreten und dem tatsächlichen Eintreten in den kritischen Bereich kann eine gewisse Zeitdauer liegen. Es muß jedoch möglich sein, für diese Wartezeit eine endliche obere Schranke anzugeben. Hiermit werden Prioritätsregelungen ausgeschlossen und erzwungen, dass jeder Prozess den kritischen Bereich in endlicher Zeit wieder verläßt, d.h. insbesondere darf ein Prozess *nicht* innerhalb des kritischen Bereiches sterben.

7.3.1 Softwarelösungen für den wechselseitigen Ausschluß

Im folgenden sollen hierfür zwei unterschiedliche Algorithmen hergeleitet werden.

Der Algorithmus von Decker

Erster Ansatz: Hierbei wird eine *geschützte*, aber gemeinsam genutzte globale Variable verwendet, die anzeigt, welcher Prozess in den kritischen Bereich eintreten darf. Man kann sich eine Art Schalter für 2 Prozesse vorstellen, der hin- und herschaltet und damit anzeigt, welcher Prozess den kritischen Bereich betreten darf. Im folgenden soll dies nun anhand des Modells des “,Protokolliglos”, verdeutlicht werden.

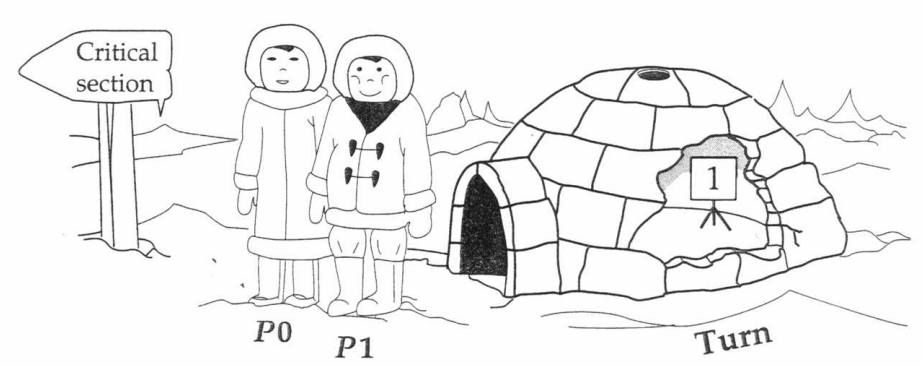

Abbildung 7.3: Gemeinsam genutzte Variable, die anzeigt, welcher Prozess in den kritischen Bereich eintreten darf.

– Durch den Iglo-Eingang und in den Iglo selbst kann zu einem Zeitpunkt nur ein Eskimo.

– Im Iglo befindet sich eine Tafel, auf die ein Wert geschrieben werden kann.

– Möchte nun ein Eskimo (Prozess P_0 oder P_1) in den kritischen Bereich, so muß er zunächst im Iglo nachschauen, ob seine Nummer auf der Tafel steht, siehe Abbildung 7.3; falls ja, darf er den kritischen Bereich betreten, falls nicht, muß er weiter warten, und von Zeit zu Zeit wieder nachsehen.
  $\rightarrow$ Dieses Verfahren wird als “,busy waiting”, bezeichnet, denn das Nachschauen verbraucht Prozessorzeit.

– Kehrt ein Prozess aus dem kritischen Bereich zurück, so muß er in den Iglo gehen und seine eigene Nummer durch eine Nummer eines wartenden Prozesses ersetzen.

Die gemeinsam genutzte Variable (Schalter) soll hier durch *turn* bezeichnet werden.

```
1 VAR turn: 0 ... n-1;
```

Der Algorithmus soll für $n = 2$ Prozesse, d.h. P_0 und P_1 betrachtet werden.

Prozess P_0

```
1 WHILE
  turn <> 0 DO {nothing};
  <kritischer Bereich>;
3 turn:=1;
```

Prozess P_1

```
1 WHILE
  turn <> 1 DO {nothing};
  <kritischer Bereich>;
3 turn:=0;
```

Hierbei können folgende Probleme auftreten:

1. Die Prozesse können den kritischen Bereich nur abwechselnd betreten. ($\rightarrow$ Dies ist absolut unzulässig)

2. Terminiert ein Prozess im unkritischen Bereich, so kann auch der andere höchstens noch einmal den kritischen Bereich betreten und ist dann blockiert. (Verstoß gegen die ",Progress",-Eigenschaft)

3. Turn selbst ist eine kritische Variable.

Prüft man den Algorithmus auf die im vorigen Kapitel beschriebenen 3 Bedingungen, so erhält man folgende Bewertung:

1. Mutual Exclusion $\Rightarrow$erfüllt

2. Progress $\Rightarrow$nicht erfüllt

3. Bounded Waiting $\Rightarrow$erfüllt (kein Prozess kann verhungern)

D.h., der Algorithmus ist nicht geeignet.

Zweiter Ansatz:

– Nun soll nicht mehr die Nummer des Folgeprozesses gespeichert werden, sondern jedem Prozess wird ein Zustand mit Hilfe einer Variablen (flag) zugewiesen.

– "true" steht für Anspruch auf den kritischen Bereich, und "false" für keinen Anspruch, wie in Abbildung 7.4 zu sehen.

– Bei eigenem Bedarf für den kritischen Bereich muß zunächst jede Variable der anderen Prozesse kontrolliert werden, sind diese alle false, darf der entsprechende Prozess seine eigene Variable true setzen.

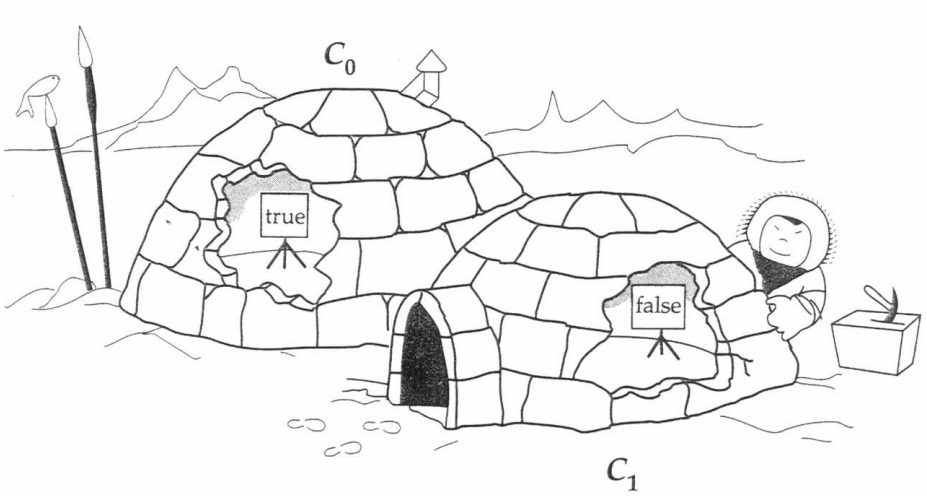

Abbildung 7.4: Jeder Prozess erhält eine Variable “flag”, die den Anspruch auf Eintritt in den kritischen Bereich zeigt.

```
1  VAR flag: array [0..1] of boolean;
```

“flag” wird mit false initialisiert.

Prozess P_0

```
1  WHILE flag[1] DO {nothing};
   flag[0]:=true;
3  <kritischer Bereich>;
   flag[0]:=false;
```

Prozess P_1

```
   WHILE flag[0] DO {nothing};
2  flag[1]:=true;
   <kritischer Bereich>;
4  flag[1]:=false;
```

Fällt nun ein Prozess außerhalb des kritischen Bereichs aus, so wird der andere Prozess trotzdem nicht blockiert. Zusätzlich kann ein Prozess mehrfach hintereinander den kritischen Bereich betreten.

Aber: Fällt ein Prozess zwischen dem “Setzen eines Flags auf true” und dem “Betreten des kritischen Bereichs” aus, so funktioniert dieser Algorithmus nicht mehr. Und zwar auch dann nicht, wenn ein Prozessorwechsel nach der **WHILE** -Überprüfung stattfindet:

1. P_0 untersucht in der **WHILE** Anweisung flag[1], dieses ist false
2. P_1 untersucht in der **WHILE** Anweisung flag[0], dieses ist false
3. P_0 setzt flag[0] auf true und betritt den kritischen Bereich
4. P_1 setzt flag[1] auf true und betritt den kritischen Bereich

Dies führt zu einem Problem!

D.h. der zweite Ansatz ist mindestens so schlecht wie der erste Ansatz, da er die drei Bedingungen für den wechselseitigen Ausschluß nicht garantiert.

Prüft man den Algorithmus wieder auf unsere 3 Bedingungen, so ergibt sich:

1. Mutual Exclusion ⇒nicht erfüllt.

2. Progress ⇒erfüllt.

3. Bounded Waiting ⇒erfüllt

Lösung: Vertauschen der ersten beiden Zeilen?
→Durch ungünstiges Scheduling dürfte in diesem Fall evtl. keiner der Prozesse mehr in den kritischen Bereich eintreten ⇒Deadlocksituation. Gegenbeispiel zum Problem des Mutual Exclusion:

```
flag[1] = flag[0] = false (* kein Prozess will in den kritischen Bereich *)
WHILE NOT flag[1] DO {nothing};
<Scheduler>
WHILE NOT flag[0] DO {nothing};
flag[1] := true;
<kritischer Bereich>;
...
<Scheduler>
flag[0] := true;
<kritischer Bereich>;
...
<Fehler>
```

Dritter Ansatz: Es wird eine größere Vorsicht dadurch erreicht, dass die eigene flag-Variable erst auf true gesetzt wird und dann die andere getestet wird.

Prozess P_0

```
flag[0]:=true;
WHILE flag[1] DO {nothing};
<kritischer Bereich>;
flag[0]:=false;
```

Prozess P_1

```
flag[1]:=true;
WHILE flag[0] DO {nothing};
<kritischer Bereich>;
flag[1]:=false;
```

Nun tritt das Problem auf, dass beide Prozesse ihre flags auf true setzen können und keiner kann den kritischen Bereich betreten.

Eine korrekte Lösung: Es müssen beide Prozesszustände betrachtet **und** eine Ausführungsreihenfolge eingebracht werden. Letzteres kann mit der Variable `turn` aus dem ersten Ansatz erfolgen, so dass wir nun eine Kombination der bisherigen Ideen erhalten:

> Einführung eines Schiedsrichteriglos, wie in Abbildung 7.5 mit einer Tafel/Variable `turn`, die anzeigt, welcher Prozess Vorrang hat.

Algorithmus:

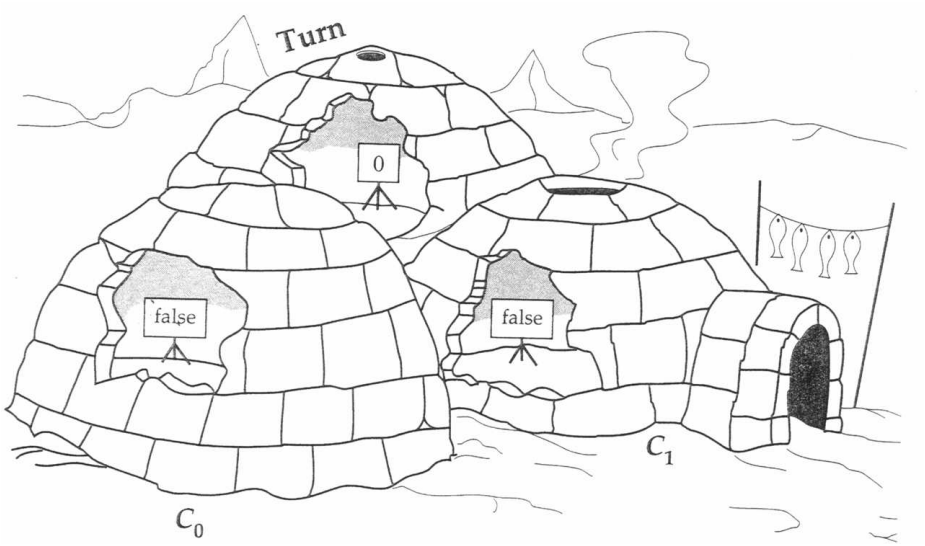

Abbildung 7.5: Die korrekte Lösung: Schiedsrichteriglo mit Variable turn zeigt an, welcher Prozess Vorrang hat.

```
VAR flag: ARRAY [0..1] of boolean;
    turn: 0..1;
BEGIN
   flag[0]:=false;
   flag[1]:=false;
   turn:=1;
   PARBEGIN       (* Dieses PARBEGIN/PAREND-Konstrukt bedeutet *)
     Prozess 0;   (* folgendes: Suspendiere das Hauptprogramm und *)
     Prozess 1;   (* führe Prozess 0 und 1 parallel aus. Wenn alle *)
   PAREND         (* Prozesse terminiert sind, dann gehe zurück ins *)
END               (* Hauptprogramm. *)
```

Prozess P0:

```
PROCEDURE P0;
  BEGIN
    REPEAT
          flag[0]:=true;
          WHILE flag[1] DO IF turn=1 THEN
            BEGIN
                flag[0]:=false;
                 WHILE turn=1 DO {nothing};
                flag[0]:=true
            END;
          <kritischer Bereich>;
          turn:=1
          flag[0]:=false;
          <unkritischer Bereich>;
    FOREVER
  END.
```

Prozess P1:

```
PROCEDURE P1;
  BEGIN
    REPEAT
        flag[1]:=true;
        WHILE flag[0] DO IF turn=0 THEN
          BEGIN
            flag[1]:=false;
             WHILE turn=0 DO {nothing};
            flag[1]:=true
          END;
        <kritischer Bereich>;
        turn:=0
        flag[1]:=false;
        <unkritischer Bereich>;
    FOREVER
  END.
```

Dieser Algorithmus ist nicht intuitiv nachvollziehbar und sehr schwierig zu beweisen. Daher soll im folgenden ein etwas einfacherer Algorithmus betrachtet werden.

Der Algorithmus von Peterson

Um das Prinzip der Implementierung jedes Prozesses zu verdeutlichen, die einen kritischen Bereich betreten wollen, nimmt man nochmals das Modell mit den zwei Eskimos und dem Iglo zu Hilfe.

Schritt 1: Ich zeige an, dass *ich will*.

Schritt 2: Ich räume dem Anderen Vortritt ein, d.h. *du darfst*.

Schritt 3: Falls *du willst und du darfst*, so lasse ich dir den Vortritt. Sonst betrete ich den kritischen Bereich.

Bemerkung 7.1. *Es darf zu einem Zeitpunkt nur einer in den kritischen Bereich* ***und*** *das letzte Wort gilt (z.B. wenn beide nacheinander sagen:* du darfst*)*

Algorithmus:

```
VAR flag: ARRAY [0..1] OF boolean;
    turn: 0..1 ;
PROCEDURE P0;
  BEGIN
    REPEAT
      flag[0]:=true;                          (* ich will   *)
      turn:=1;                                (* du darfst  *)
      WHILE flag[1] AND turn=1 DO {nothing}; (* warte, falls du willst *)
                                              (* und du darfst *)
      <kritischer Bereich>;
      flag[0]:=false;
      <unkritischer Bereich>;
    FOREVER
  END;
```

```
16 PROCEDURE P1;
   BEGIN
18   REPEAT
       flag[1]:=true;
20     turn:=0;
       WHILE flag[0] AND turn=0 DO {nothing};
22     <kritischer Bereich>;
       flag[1]:=false;
24     <unkritischer Bereich>;
     FOREVER
26 END;

28 BEGIN
     flag[0]:=false;
30   flag[1]:=false;
     turn:=1;
32   PARBEGIN
       P0;
34     P1;
     PAREND
36 END;
```

Dieser Algorithmus ist auch recht einfach von zwei auf n Prozesse erweiterbar. Die Prüfung unserer 3 Bedingungen ergibt:

1. Mutual Exclusion ⇒erfüllt.
2. Progress ⇒erfüllt (abhängig vom Scheduling kann bei 2 Anfragen ein Prozess den kritischen Bereich betreten).
3. Bounded Waiting ⇒erfüllt.

7.3.2 Hardwarelösungen für den wechselseitigen Ausschluß

Im folgenden soll ein ganz anderer Ansatz verfolgt werden. Der wechselseitige Ausschluß soll nicht durch eine geeignete Programmierung erreicht werden, sondern mittels Unterstützung durch die Hardware.

Unterbrechungsvermeidung (Interrupt Disabling): In einem Einprozessrechner können sich Prozesse nicht überschneiden, d.h. wirklich parallel ausgeführt werden, sondern sie können nur unterbrochen und wechselseitig ausgeführt werden. Wechselseitiger Ausschluß kann dadurch erreicht werden, dass man Unterbrechungen unmöglich macht und Prozesse sequentiell abgearbeitet werden, d.h. das preemptive Scheduling wird unterbunden. Insbesondere dürfen Prozesse, die sich im kritischen Bereich befinden, nicht unterbrochen werden. Diese Eigenschaft des Unterbrechungsausschlusses kann durch Primitive auf der Systemebene bereitgestellt werden. Ein Prozess würde dan wie folgt auf einen kritischen Bereich zugreifen (Interrupt-Steuerung):

```
   REPEAT
2    <verbiete Unterbrechungen>    (* Disable Interrupt *)
     <kritischer Bereich>;
```

```
4       <ermögliche Unterbrechungen>; (* Enable Interrupt  *)
        <unkritischer Bereich>;
6     FOREVER
```

Bei diesem Ansatz sind aber folgende Nachteile zu beachten:

- Er ist gefährlich und aus Anwendersicht nicht realisierbar
- Er funktioniert in einer Multiprozessorumgebung nicht, da hier echte Parallelität nicht vermieden werden kann. Tritt im kritischen Bereich nun ein Problem auf, so dann nicht durch den Scheduler eine Problembehandlungsroutine eingeschoben werden.

Test and Set - Spezielle Maschinenbefehle: Nun soll ein Mehrprozessorsystem gemäß *SMP*-Ansatz betrachtet werden. Hier müssen die Unterbrechungsvermeidungen nicht auf den Prozessor bezogen werden, sondern auf das eigentliche Betriebsmittel, z.B. den Speicher. Ein solcher Mechanismus kann z.B. in einem Test-and-set-Befehl implementiert werden, der atomar ausgeführt wird.

```
 FUNCTION testset (VAR i: integer): boolean;
2 BEGIN
    IF i=0 THEN
4     BEGIN
        i:=1;
6       testset:=true
      END;
8   ELSE testset:=false
  END.
```

Dieser Befehl testet den Wert eines Argumentes i und leitet einen logischen Ausdruck zurück.

- i=0 bewirkt i:=1 und **true** wird zurückgegeben
- i=1 bewirkt i:=1 und **false** wird zurückgegeben

Ein wechselseitiger Ausschluß wird nun dadurch erreicht, dass ein Programm den test-and-set-Befehl in seine Ausführung integriert und im Fall i=0 den kritischen Bereich betritt. Nach Verlassen des kritischen Bereichs wird i:=1 gesetzt. Das Gesamtprogramm wiürde wie folgt aussehen:

Algorithmus:

```
1 PROGRAM  mutual exclusion;
  CONST      n=...; (* Anzahl der Prozesse *)
3 VAR        i:integer;
  PROCEDURE P(k:integer);
5
  BEGIN
7   REPEAT
      REPEAT {nothing} UNTIL testset(i); (* weiter nur bei i=0 (true) *)
9       <kritischer Bereich>;
        i:=0;
11      <unkritischer Bereich>;
    FOREVER
```

```
13 END;

15 BEGIN (* Hauptprogramm *)
     i:=0;
17   PARBEGIN
       P(1);
19     P(2);
       ...
21     P(n);
     PAREND
23 END;
```

Eine andere Version dieses Algorithmus sieht fogendermassen aus:

```
1 PROCEDURE test_and_set (VAR lock: Boolean):Boolean
  BEGIN
3   test_and_set := lock;
    lock = true;
5 END
```

Diese Prozedur lädt den Wert von lock und belegt ihn mit dem Wert true (initialisiert mit false). Ist ein Betriebsmittel nicht genutzt, so ist lock auf false gesetzt. Wird es benutzt, oder soll es benutzt werden, so wird lock auf true gesetzt.
Es muss sichergestellt werden, dass diese Prozedur atomar benutzt wird, dass heißt, kein Prozess darf auf sie zugreifen, solange sie nicht durch einen anderen Prozess beendet wurde. (Realisierung: Sperren eines Speicherbusses.)
Nutzung:

```
1 WHILE test_and_set(lock) DO {nothing};
    (* Ist das Ergebnis true -> Busy Waiting, BM wird benutzt. *)
3   (* Ist das Ergebnis false -> setze test_and_set auf true *)
    (* und trete in kritischen Bereich ein. *)
5   <kritischer Bereich>;
    lock := FALSE;
7   <unkritischer Bereich>;
UNTIL FALSE;
```

Bewertung nach unseren 3 Bedingungen:

1. Mutual Exclusion ⇒erfüllt.
   Nur ein Prozess kann zu einem Zeitpunkt auf ein BM zugreifen.

2. Progress ⇒erfüllt.

3. Bounded Waiting ⇒nicht erfüllt.
   Ein Prozess kann beliebig oft durch das Scheduling zurückgestellt werden, wenn er lock erst abfragt, nachdem ihm ein anderer Prozess zuvorgekommen ist.
   Lösung: Um dieses unbeschränkte Warten zu vermeiden, müsste ein - recht komplizierter - Algorithmus ergänzt werden, der die “willigen” Prozesse in zyklischer Reihenfolge abarbeitet.

Eine Variante des vorgestellten Prinzips wird mittels eines sog. *Austauschbefehls* realisiert. Dabei ist `i` mit 0 initialisiert, jeder Prozess hat eine Nummer oder ID, die er vor dem Eintritt in den kritischen Bereich mit `i` austauscht, sofern `i=0` gilt. Vorteil ist, dass man sehen kann,

welcher Prozess sich im kritischen Bereich befindet. Diese Ansätze sind einfach und auf eine beliebige Anzahl von Prozessen anwendbar.

Aber: Da ein Prozess im Zustand “busy waiting” auf den Eintritt in den kritischen Bereich wartet, konsumiert er Prozessorzeit.

Und: Bezogen auf unsere drei Kriterien für den wechselseitigen Ausschluß sind *Starvation* und *Deadlock* möglich.

7.4 Semaphore

Die bisher vorgestellten Lösungen für den wechselseitigen Ausschluß basierten auf elementaren atomaren Operationen. Bei komplexeren Aufgabenstellungen wird eine solche Vorgehensweise jedoch schnell unübersichtlich.
Daher sollen nun höhersprachliche Konstrukte entwickelt werden, die leichter nachvollziehbar und weniger fehleranfällig sind. Diese Konstrukte werden jedoch intern ebenfalls auf atomare Operationen zurückgeführt.

Beispiel 7.3. *Ein Parkhaus nutzt einen Zähler zum Modellieren der Anzahl freier Parkplätze. Dieser wird am Morgen eines jeden Tages initialisiert, beim Einfahren eines Autos wird der Zähler um eins verringert, beim Ausfahren um eins erhöht.*
Steht der Zähler auf 0*, so muß ein Auto solange in einer Warteschlange (fair), oder um den Block fahrend (unfair) warten, bis ein anderes Auto das Parkhaus verläßt und dem Zähler signalisiert, dass jetzt wieder ein freier Platz zur Verfügung steht.*
Die Operationen Initialisieren, Inkrementieren und Dekrementieren sind als atomare Operationen realisiert.

Die Abstraktion dieses Mechanismus führt zum Konzept des Semaphors.

7.4.1 Das Prinzip der Semaphore

Ein Semaphor `S` ist eine Integervariable, die nur durch 3 atomare Operationen verändert werden kann. Diese heißen:

1. `init(S, Anfangswert)` setzt `S` auf den Anfangswert. (Initialisierung)
2. `wait(S)` oder auch `P(S)` (nach niederländisch “,proberen”, = probieren) versucht `S` zu verringern. (Dekrementierung)
3. `signal(S)` oder auch `V(S)` (nach niederländisch “,verhogen”, = erhöhen) erhöht `S`. (Inkrementierung)

In den meisten Fällen ist einem Semaphor eine Warteschlange zugeordnet, um auszuschließen, dass Prozesse über eine längere Zeit in einer Wartschleife verweilen und damit unnötig Ressourcen belegen.
Solche assoziierten Warteschlangen verhindern ein *busy waiting*, indem sie Prozessnummern in der Reihenfolge der Anfragen festhalten. Daraufhin können wartende Prozesse suspendiert werden und beanspruchen so keine CPU-Zeit.
Wird der kritische Bereich frei, so wird der in der Warteschlange folgende Prozess rechnend gesetzt und kann den kritischen Bereich betreten.

Bemerkung 7.2. *Eine Implementierung ohne Warteschlange würde dazu führen, dass wenn bereits* $S := 0$ *gilt,* `wait(S)` *nicht ausgeführt werden kann, da keine Ressourcen mehr vorhanden sind. S bliebe dann so lange auf dem Wert 0, bis ein anderer Prozess ein* `signal(S)` *ausgeführt hat. Abhängig vom Scheduling könnten sich hieraus unfaire Abläufe ergeben. Angenommen es existieren drei Prozesse* P_1, P_2 *und* P_3*, die nacheinander folgende Aufrufe tätigen*

P_1: `wait(S)`

P_3: `wait(S)`

P_2: `signal(S)`

dann könnte abhängig vom Scheduling auch erst der Prozess P_3 *den Zugriff auf S erhalten. Zudem impliziert die Implementierung ohne Semaphoren die Anwendung von Busy Waiting, was zu unötigem Verbrauch an Prozessorzeit führt.*

Bei der Implementierung mit einer Warteschlange wird S stets um 1 verringert. Dies ist auch dann der Fall, wenn ein Prozess P `wait(S)` aufruft obwohl bereits $S \leq 0$ gilt. Der aufrufende Prozess wird dann an der $-$S-ter Stelle in der Warteschlange aller wartenden Prozesse einreiht.

Beispiel 7.4. *Der Wert von S ist gerade* -1*. Ein Prozess* P_1 *ruft* `wait(S)` *auf, d.h. die Semaphore wird um 1 dekrementiert (*$S := S-1 = -2$*). Somit reiht sich* P_1 *an der Stelle* $-S := (-(-2)) = 2$ *ein.*

Die drei Operationen werden wie folgt realisiert:

1. `init(S, Anfangswert)`: bewirkt die Zuweisung

   ```
   S := Anfangswert;
   ```

   Sinnvoll ist es, als Anfangswert die Anzahl der Prozesse zu setzen, die sich gleichzeitig im kritischen Bereich aufhalten dürfen.

   Wechselseitiger Ausschluß wird durch `S := 1` erreicht, man spricht dann auch von **binären Semaphoren** im Gegensatz zu sogenannten Zählsemaphoren.

2. `wait(S)` bewirkt

   ```
   1 WHILE (S <= 0) DO skip;
     S := S - 1;
   ```

   oder bei Vorhandensein einer Warteschlange:

   ```
     S := S - 1;
   2 IF (S < 0) THEN
       <ordne Prozess in Warteschlange an Position -S ein>;
   ```

   Beide Realisierungen müssen als atomare Operationen erfolgen.

3. `signal(S)` bewirkt die Zuweisung

   ```
   1 S := S + 1;
   ```

   oder bei Verwendung einer Warteschlange

```
1 S := S + 1;
  IF (S <= 0) THEN
3   BEGIN
      <setze den am längsten wartenden Prozess rechnend>;
5     <erlaube Zugriff auf kritischen Bereich>;
    END;
```

Beide Realisierung müssen wieder als atomare Operationen erfolgen.

Mit diesen drei Operationen kann man das generelle Problem des wechselseitigen Ausschlusses wie folgt lösen:

1. Globale Initialisierung für Prozess P_i: `init(S,1);`.

2. Für jeden Prozess P_i mit $i \in \{0, \ldots, n-1\}$:

```
  REPEAT
2   wait(S);
    <kritischer Bereich>;
4   signal(S);
    <unkritischer Bereich>;
6 UNTIL FALSE;
```

Dieser Algorithmus soll an vier verschiedenen Beispielen verdeutlicht werden.

7.4.2 Ablaufsteuerung mit Hilfe von Semaphoren

Seien zwei Prozesse X und Y gegeben, wobei Y vor X ausgeführt werden soll.
Dazu benötigen wir einen Semaphor `a` mit `init(a,0)`. Dann ergibt sich ein wechselseitiger Ablauf von X und Y (vgl. Abbildung 7.6).
Diese "umgekehrte", Semaphorennutzung bewirkt, dass X solange warten muß, bis Y fertig ist.

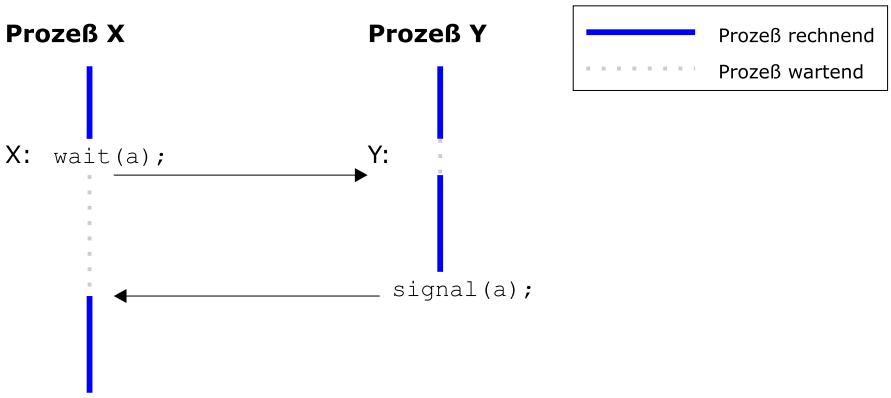

Abbildung 7.6: Ablaufsteuerung von zwei Prozessen mit Hilfe von Semaphoren

7.4.3 Lösung des Erzeuger/Verbraucher-Problems mit Hilfe von Semaphoren

Das aus Abschnitt 7.2 auf Seite 125 bekannte Erzeuger/Verbraucher-Problem soll nun mittels einer Semaphore `S` realisiert werden. Es soll also exklusiver Zugriff auf das Lager, welches `MAX` Speicherplätze aufnehmen kann, garantiert werden, d.h. wir benötigen eine binäre Semaphore zur Realisierung dieses kritischen Bereiches, also

```
init(S, 1);
```

Somit erhalten wir für den Zugriff auf den kritischen Bereich sowohl im Erzeuger als auch im Verbraucher folgende Anweisungen:

```
1 wait(S);
  <Element auf Speicher ablegen oder vom Speicher holen>;
3 signal(S);
```

Um allerdings die Nebenbedingung, dass maximal `MAX` Speicherplätze zur Verfügung stehen, ebenfalls zu garantieren, können zwei *Zählsemaphoren* verwendet werden, und zwar derartig, dass die erste Semaphore `b` die Anzahl der belegten Speicherplätze (den Bestand), die zweite Semaphore `p` die Anzahl der freien Speicherplätze (den verfügbaren Platz) repräsentiert. Ist also $b = 0$, so ist das Lager leer, ist hingegen $p = 0$, so ist das Lager voll.
Die Initialisierung für `b` und `p` geschieht wie folgt:

```
1 init(b, 0);
  init(p, MAX);
```

Während der gesamten Laufzeit des Algorithmus soll also $b + p = MAX$ gelten, d.h. belegte und freie Speicherplätze ergeben zusammen alle Speicherplätze.
Somit ergibt sich der in Programm 3 auf der nächsten Seite gezeigte Algorithmus für Erzeuger und Verbraucher.
Ein Vertauschen der ersten beiden `wait`-Operationen (Zeilen 4 und 5) kann zu Konflikten führen, da in diesem Fall der kritische Bereich durch einen Erzeuger blockiert ist, ohne dass Speicherplatz frei ist. Hätten wir:

```
1 (* Erzeuger *)
  S:=1;  B:=0; P:=Max;
3 <erzeuge>;
  wait(P);
5 wait(S);              (* Deadlock möglich *)
  <lege Element ab>;
7 signal(S);
  signal(B);
9
  (* Verbraucher *)
11 wait(S);
  S:=0; B:=0; P:=Max;
13 wait(B);
  <entnimm Element>;
15 signal(S);
  signal(P);
17 <verbrauche Element>;
```

dann kann in Zeile 5 ein Deadlock entstehen, d.h. `wait(S)` und `wait(P/B)` dürfen nicht vertauscht werden.

Programm 3 Algorithmen für Erzeuger und Verbraucher mit Semaphoren

```
(* Erzeuger: *)
REPEAT
  <erzeuge Element>;
  wait(p);                    (* Warte auf Platz, dann p := p-1   *)
  wait(s);                    (* -- Beginn kritischer Bereich --  *)
  <lege Element im Speicher ab>;
  signal(s);                  (* -- Ende kritischer Bereich   --  *)
  signal(b);                  (* Signal für mehr Bestand b := b+1 *)
                              (* nur Verbraucher reagiert auf     *)
                              (* signal(b).                       *)
UNTIL FALSE;

(* Verbraucher: *)
REPEAT
  wait(b);                    (* Warte auf Bestand b := b-1       *)
  wait(s);                    (* -- Beginn kritischer Bereich --  *)
  <entnimm Element aus Speicher>;
  signal(s);                  (* -- Ende kritischer Bereich   --  *)
  signal(p);                  (* Signal für mehr Platz p := p+1   *)
  <verbrauche Element>;
UNTIL FALSE;
```

signal()-Operationen (=Zählvariable) können beliebig vertauscht werden. Die Reihenfolge der `signal`-Befehle ist jedoch beliebig.

7.4.4 Lösung für das Leser/Schreiber-Problem mit Hilfe von Semaphoren

Das Leser/Schreiber- oder R/W- (Reader/Writer-) Problem ist ein klassisches Problem, insbesondere bei der Verwaltung von Datenbanken. Es seien zwei Arten von Prozessen gegeben:

1. Schreiber, die Daten modifizieren können, und
2. Leser, die Anfragen stellen, d.h. Daten lesen können.

Diese Prozesse sollen Zugriff auf ein gemeinsames Datenobjekt (z.B. eine Datei) besitzen. Dabei sollen Schreibzugriffe exklusiv erfolgen, d.h. wenn Daten geschrieben werden, so darf nur genau ein Prozess aktiv sein, nämlich der Schreiber (weitere Schreiber und Leser müssen ausgeschlossen sein).
Es gibt drei Ansätze, Fairneß für Leser und Schreiber zu garantieren:

1. Ein *Leser* muß nur dann auf Eintrittserlaubnis in den kritischen Bereich warten, wenn ein Schreiber gerade aktiv ist.

   Dabei könnten jedoch Leser einen sogenannten “Verschwörerkreis” bilden (d.h. ein Leser ist immer aktiv), der ewig den Schreiber blockiert. Diese Lösung ist also “Leserfreundlich”.

2. Wartet ein *Schreiber*, so darf ein Leser nicht in den kritischen Bereich eintreten.

Analog jedoch können in diesem Fall die Schreiber die Leser blockieren (“Schreiber-freundlich”).

3. Daher sollen nun Lese- und Schreibphasen alternieren:

   Ist also gerade Lesephase (ein Leser aktiv) und ein Schreiber meldet sich an, so werden keine neuen Leser mehr zugelassen und der Schreiber wird aktiv, sobald alle gerade aktiven Leser beendet wurden. Analog werden alle nachfolgenden Anfragen von Schreibern in der Schreibphase abgewiesen, sobald sich ein Leser angemeldet hat.

Es soll für den einfachen ersten Fall ein Algorithmus angeben werden (vgl. Programm 4), wobei

1. ein binärer Semaphor `S` für Schreibphase mit `init(S,1)`,
2. ein binärer Semaphor `L` für Lesephase mit `init(L,1)` und
3. eine Zählvariable n, die die Anzahl aktiver Leser enthält (zu Anfang 0), benötigt werden.

Programm 4 Lösung des R/W-Problems mit Semaphoren, Leser-freundlich

```
1  (* Writer: *)
   REPEAT
3    wait(S);
     <Schreibvorgang>;
5    signal(S);
   UNTIL FALSE;
7
   (* Reader: *)
9  REPEAT
     wait(l); (* l := l-1, exklusiver Zugriff auf n *)
11   n := n+1;
     IF (n = 1) THEN wait(s);
13   (* Falls kein Leser vorhanden, blockiere Schreibphase *)
     (* (ist Schreiber aktiv, so warte, bis Schreiber fertig, *)
15   (* dann blockiere; sonst blockiere sofort). *)
     signal(l);
17
     <Lesevorgang>; (* nicht wenn n=0 und Schreiber aktiv *)
19
     wait(l); (* exklusiver Zugriff auf n *)
21   n := n -1;
     IF (n = 0) THEN signal(s);
23   (* Freigabe der Schreibphase, wenn keine Leser mehr aktiv *)
     signal(l);
```

7.4.5 Das Philosophenproblem

Auch dieses ist ein klassisches Problem, das die Problematik des exklusiven Zugriffes verdeutlicht, jedoch aus Sicht eines Betriebssystems in der Praxis von eher geringer Relevanz ist.

Philosophen verbringen ihr Leben ausschließlich mit Essen und Denken. Seien fünf Philosophen gegeben, die an einem runden Tisch sitzen (vgl. Abbildung 7.7). Vor jedem Philosophen

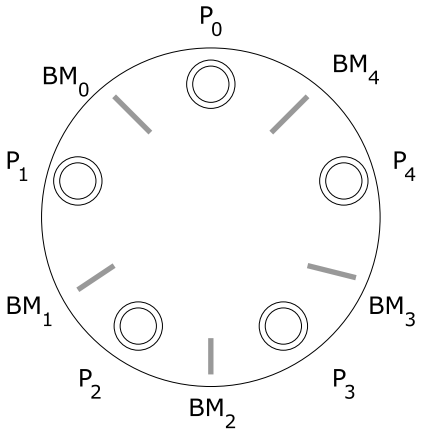

Abbildung 7.7: Das Philosophenproblem

befindet sich ein Teller voller Reis und zwischen je zwei Tellern befindet sich ein Eßstäbchen. Ein Philosoph, der hungrig ist, benötigt sowohl das linke als auch das rechte Stäbchen, um essen zu können. Hat er zwei Stäbchen, so ißt er, bis er satt ist, erst dann legt er die Stäbchen an die ursprünglichen Plätze zurück, so dass seine Nachbarn davon Gebrauch machen können.
Aus Betriebssystemsicht gibt es also fünf Prozesse $P_0, \ldots, P_4$ und fünf Betriebsmittel BM_0, ..., BM_4. Ein Prozess benötigt zwei Betriebsmittel, um aktiv zu werden, und zwar der Prozess P_i die Betriebsmittel BM_i (linkes Stäbchen) und $BM_{(i+1) \bmod 5}$ (rechtes Stäbchen).
Damit ergibt sich für den Prozess P_i der Ablauf:

```
REPEAT
  <unkritischer Bereich>; (* denken *)
  <kritischer Bereich>;   (* essen  *)
UNTIL FALSE;
```

Einfacher Lösungsansatz für das Philosophenproblem

Jedes Betriebsmittel (Stäbchen) wird durch eine Semaphore `BM_0` bis `BM_4` repräsentiert, die mit `init(BM_i, 1)` initialisiert wird.
Damit ergibt sich für P_i folgender Algorithmus:

```
REPEAT
  Denken; (* unkritischer Bereich *)

  wait(BM_i);
  wait(BM_((i+1) MOD 5));

  Essen; (* kritischer Bereich    *)

  signal(BM_i);
  signal(BM_((i+1) MOD 5));
  UNTIL FALSE
```

Bei dieser Realisierung ergibt sich jedoch das Problem, dass in dem Fall, dass alle Philosophen (quasi) gleichzeitig zu essen beginnen, `wait(BM_i)` fünfmal quasi gleichzeitig ausgeführt wird. Jeder Prozess hält also ein Betriebsmittel (das linke Stäbchen), wartet jedoch nun vergeblich auf das zweite Betriebsmittel (das rechte Stäbchen).
Es entsteht ein **Deadlock** (Verklemmung).
Es existieren verschiedene Lösungen dieses Problems, z.B. kann ein Philosoph zum "Rechtshänder" werden, d.h. er wartet zuerst auf das rechte, dann auf das linke Stäbchen, bei diesem Philosophen werden also die Zeilen 3 und 4 in obigem Algorithmus vertauscht.

Lösung des Philosophenproblems unter Vermeidung von Deadlocks

Es wird vorausgesetzt, dass maximal vier Philosophen gleichzeitig zu ihrem ersten Stäbchen Zugriff bekommen. Zu diesem Zweck wird ein weiterer Semaphor `Erlaubte_Esser` eingeführt, der durch `init(Erlaubte_Esser, 4)` auf 4 beschränkt ist.
Damit können höchstens vier Philosophen ihre linken Stäbchen nehmen und immer mindestens ein Philosoph auch das rechte Stäbchen erhalten, mindestens ein Philosoph kann also zu jeder Zeit essen.
Für P_i ergibt sich nun der folgende Algorithmus:

```
1  REPEAT
     Denken;
3
     wait(Erlaubte_Esser);    (* dekrementiere Erlaubte_Esser *)
5    wait(BM_i);
     wait(BM_((i+1) MOD 5));
7
     Essen;
9
     signal(BM_i);
11   signal(BM_((i+1) MOD 5));
     signal(Erlaubte_Esser); (* inkrementiere Erlaubte_Esser *)
13 UNTIL FALSE;
```

7.5 Monitore

7.5.1 Motivation der Monitore

Wir wollen ein - scheinbar korrektes - Beispiel betrachten, das das Erzeuger/Verbraucher-Problem für einen unendlich großen Speicher realisieren soll. Dabei gehen wir von 2 binären Semaphoren S und NOT_EMPTY aus. Kritisch ist - neben dem exklusiven Zugriff - nur, dass der Verbraucher nicht aus einem leeren Speicher entnimmt. Weiterhin sei n eine Zählvariable, die mit $n := 0$ initialisiert ist.

```
1 init(S,1);           (* Zugriff *)
  init(NOT_EMPTY,0); (* Ausgangssituation: empty, d.h. not_empty=false *)
```

Es ergibt sich der Quellcode aus Programm 5: Durch den Scheduler wird nun eine Sequenz von Teilen der Erzeuger- und Verbraucherprozesse dem Prozessor zugewiesen, die folgende Variablenbelegung bedingt:

Programm 5 Routinen für Erzeuger und Verbraucher mit 2 binären Semaphoren und 1 Zählvariable n

Erzeuger E:

```
REPEAT
  <erzeuge Element>;
  wait(S); (* Beg. krit. Ber. *)
  <lege Element im Speicher ab>;
  n: = n + 1
  IF n = 1 THEN signal (NOT_EMPTY);
  signal(S); (* Ende krit. Ber. *)
UNTIL FALSE;
```

Verbraucher V:

```
wait (NOT_EMPTY);
REPEAT
  wait(S); (* Beg. krit. Ber. *)
  <entnimm Element>;
  n: = n − 1;
  signal(S); (* Ende krit. Ber. *)
  <verbrauche Element>;
  IF n=0 THEN wait (NOT_EMPTY);
UNTIL FALSE;
```

			n	NOT_EMPTY	n	NOT_EMPTY	m
1		initial	:=0	0	0	0	
2	E	krit. Bereich	1	1	1	1	
3	V	wait (NOT_EMPTY)	1	0	1	0	
4	V	krit. Bereich	0	0	0	0	0
5	E	krit. Bereich	1	1	1	1	0
6	V	IF $n = 0$ $m = 0$ Then wait(NOT_EMPTY	1	1f	1	0f	0
7	V	krit. Bereich	0	1	0	0	0
8	V	IF $n = 0$ $m = 0$ Then wait(NOT_EMPTY)	0	0	0	wait f*	0
9	V	krit. Bereich	-1f	0			

*= wartet auf $m = 1$

Obwohl die Programmmodule für den Erzeuger und den Verbraucher offensichtlich korrekt programmiert sind, ist im Ablauf ein Fehler aufgetreten. Um diesen zu beseitigen, führen wir eine Hilfsvariable m ein, die innerhalb des kritischen Bereichs beim Verbraucher einen Wert zugewiesen bekommt, der zu einem späteren Zeitpunkt ausgewertet wird. Eine korrekte Lösung ergibt sich damit in folgender Form, wobei der Erzeuger vollständig übernommen wird:

```
n:=0;
init(S,1);
init(NOT_EMPTY,0);
```

Damit ergibt sich der Quellcode aus Programm 6. Die neue Hilfsvariable m kann durch Erzeugerbefehle nicht manipuliert werden! Betrachten wir den obigen Abarbeitungspfad, so sieht man (vgl. auch Tabelle), dass diese Lösung nicht zu dem beschriebenen Konflikt führt.

FAZIT Obwohl Semaphore ein mächtiges und flexibles Tool für die Realisierung des wechselseitigen Ausschlusses sind, ist es in gewissen Situationen doch schwierig, mit ihnen ein korrektes Programm zu erstellen. Diese Schwierigkeit liegt darin begründet, dass Wait- und Signal-Operationen oft so über das Programm verstreut sind, dass es nicht einfach ist, ihre globale Wirkung zu erkennen.

Programm 6 Routinen für Erzeuger und Verbraucher mit Hilfsvariable m

Erzeuger E:

```
1  REPEAT
     <erzeuge Element>;
3    wait(S); (* Beg. krit. Ber. *)
     <lege Element im Speicher ab>;
5    n: = n + 1
     IF n = 1 THEN signal (NOT_EMPTY);
7    signal(S); (* Ende krit. Ber. *)
   UNTIL FALSE;
```

Verbraucher V:

```
   VAR m:INTEGER (* Hilfsvariablen *)
2  wait (NOT_EMPTY);
   REPEAT
4    wait(S); (* Beg. krit. Ber. *)
     <entnimm Element>;
6    n: = n - 1;
     m: = n;     (* NEU! *)
8    signal(S); (* Ende krit. Ber. *)
     <verbrauche Element>;
10   IF m = 0 THEN wait (NOT_EMPTY);
   UNTIL FALSE;
```

Aus diesem Grund wollen wir die Monitore als ein weiteres höherprogrammiersprachliches Konstrukt einführen, das eine äquivalente Funktionalität bezüglich des wechselseitigen Ausschlusses bereitstellt, jedoch einfacher zu kontrollieren ist.

7.5.2 Das Prinzip der Monitore

Das Konzept der Monitore geht auf einen Ansatz C. Hoares (Niederlande) zurück, der im Oktober 1974 unter dem Titel *"Monitors: An Operating System Structering Concept"* in den ACM Transactions of Communication erschien.

Definition 7.7 (Monitor)**.** Ein Monitor ist ein Objekt, das sich im wesentlichen aus einer Menge von Prozeduren auf gegebenenfalls gemeinsam genutzten Daten zusammensetzt. Entscheidend ist, dass der Monitor – zu jedem Zeitpunkt – stets nur von (höchstens) einem Prozess genutzt werden darf. Fordert demzufolge ein Prozess eine Monitorprozedur an und erhält er die Erlaubnis, sie abzuarbeiten, so läuft diese Prozedur atomar ab.

Dieses Konzept wurde dann auch in Programmiersprachen wie Pascal-Plus und Modula 2+3 implementiert.
Einen Monitor wollen wir nun als ein Softwaremodul betrachten, das aus folgenden Bestandteilen besteht:

1. einer oder mehreren Prozeduren
2. lokalen Daten
3. einer Warteschlange für ankommende Prozesse

Der Grundgedanke besteht nun darin, dass auf die lokalen Variablen nur durch Zugang zu den Monitorprozeduren zugegriffen werden darf. Insbesondere ist es ausgeschlossen, dass eine externe Prozedur auf diese lokalen Daten zugreift!
Dies bedeutet insbesondere: ein Prozess betritt den Monitor, indem er auf eine der Monitorprozeduren zugreift.

Ferner darf zu einem Zeitpunkt immer nur ein Prozess im Monitor ausgeführt werden. Alle anderen Prozesse, die Zugriff auf den Monitor erfordern

- haben ihn bereits wieder verlassen oder
- warten in der Warteschlange für ankommende Prozesse auf ihren Eintritt oder
- sind so lange suspendiert, bis der Monitor für sie wieder zur Verfügung steht, also z.B. bis der zur Zeit im Monitor auf eine Prozedur zugreifende Prozess mit der Abarbeitung fertig ist und den Monitor verlässt.

Diese Grundgedanken wollen wir nun in einem Modell (vgl. Abbildung 7.5.2) zusammenfassen, das wie folgt aussehen kann:

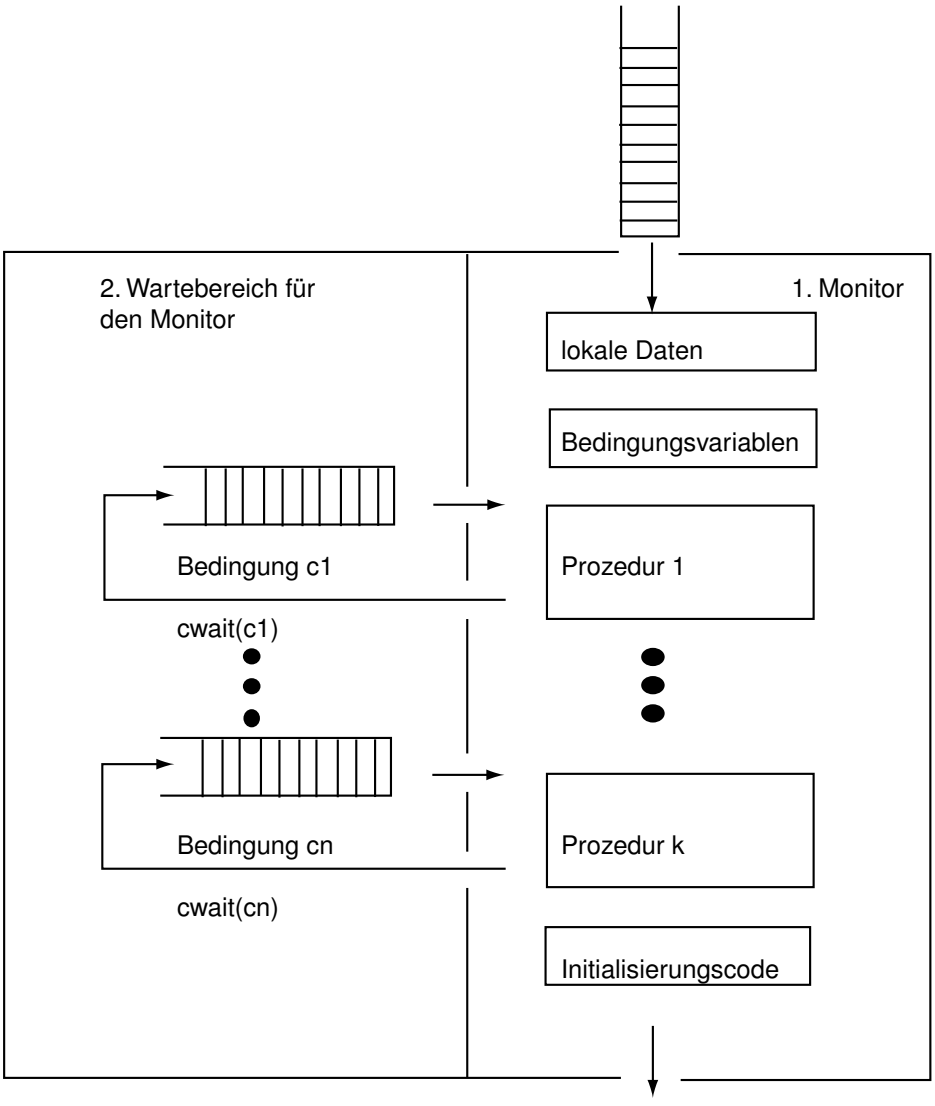

Abbildung 7.8: Monitor

1. Monitor: In diesem Bereich darf sich stets nur 1 Prozess aufhalten. Alle anderen Prozesse müssen außerhalb des Monitors verwaltet werden. Dadurch wird das Prinzip des wechselseitigen Ausschlusses realisiert.

2. Wartebereich: Neben dem eigentlichen wechselseitigen Ausschluss, den wir bislang mittels binärer Semaphore realisiert hatten, bestand bei vielen Problemstellungen noch die Aufgabe der Synchronisation, die über Zählsemaphore gelöst wurde. Diese Synchronisation wird im Monitor über Bedingungen realisiert.

Beispiel 7.5. *Nehmen wir an, bei vollem Speicher würde ein Erzeuger den Monitor betreten. Dann müsste der Erzeugerprozess suspendiert werden, bis die Bedingung erfüllt ist, dass der Speicher nicht mehr voll ist. Während der Suspendierung - die in einem Wartebereich außerhalb des eigentlichen Monitors erfolgt - kann ein anderer Prozess, vielleicht ein Verbraucher, den Monitor betreten und auf eine Prozedur zugreifen, die den kritischen Bereich über die lokalen Variablen anspricht (vgl. auch Programm 7).*
Bemerkung: *Statt `einfügen(x)` bzw. `entnehmen(x)` sind manchmal auch die Schreibweisen `Endlicher_Speicher.einfügen(x)` bzw. `Endlicher_Speicher.entnehmen(x)` gebräuchlich.*

Ein Hauptprogramm zur parallelen Ausführung von Erzeuger und Verbraucher könnte man durch folgende Zeilen ergänzen:

```
1 BEGIN                    (* Hauptprogramm *)
  PAR BEGIN                (* Schlüsselwort für parallele Ausführung *)
3  Erzeuger; Verbraucher;
  PAR END;
5 END;
```

Die korrekte Darstellung z.B. für den Erzeuger und den Verbraucher hätte dann die Syntax aus Programm 8.

Realisierung der Synchronisation in einem Monitor Wir wollen noch einmal den Fall betrachten, dass ein Prozess den Monitor durch Aufruf einer entsprechenden Monitorprozedur (z.B. `einfügen(x)`) betritt, dieser Prozess jedoch noch nicht ausgeführt werden kann, solange eine bestimmte Bedingung (z.B. `not_full`) nicht erfüllt ist. Wir benötigen folglich ein Konzept, bei dem ein Prozess, der auf ein Ereignis wartet, in suspendiertem Zustand den Monitor freigibt, bis dieses Ereignis eingetreten ist. Während dieser Freigabe kann der Monitor von anderen Prozessen betreten werden. Bei Ereigniseintritt kann der suspendierte Prozess den Monitor wieder betreten und seine Abarbeitung an der Stelle fortsetzen, an der er zuvor unterbrochen wurde. Der Monitor unterstützt diese Synchronisation durch die Nutzung von Bedingungsvariablen (condition variables), die nur innerhalb des Monitors verfügbar sind, d.h. aufgerufen werden können (vgl Programm 7). Es gibt 2 Funktionen, die auf diese Bedingungsvariablen ausgeführt werden können:

- `cwait(c)`: suspendiert die Ausführung des Prozesses, der diese Operation aufruft, bis die Bedingung c eingetreten ist. Logisch gesehen reiht sich dieser Prozess in die Warteschlange ein. Der Monitor steht nun anderen Prozessen zur Verfügung.

- `csignal(c)`: Nimmt die Ausführung eines suspendierten Prozesses, der auf die Bedingung c wartet, wieder auf. Falls es mehrere solche wartende Prozesse gibt, wird einer von ihnen ausgewählt (z.B. der am längsten wartende im Fall von FIFO). Falls es keinen Prozess gibt, der auf c wartet, so wird nichts gemacht.

Programm 7 Monitor für den Zugriff auf den endlichen Speicher

```
1  MONITOR Endlicher_Speicher;

3  buffer: ARRAY[0...N] OF char;          (* N Erzeugnisse haben im S *)
                                          (* Platz  *)
5  nextin, nextout: INTEGER;              (* Zeiger für Ringpuffer *)
   count: INTEGER;                        (* akt. Anzahl belegter Pl. in S *)
7  not_full, not_empty: CONDITION;        (* Synchronisationsbedingungen: *)
                                          (* not_full für Verbraucher *)
9                                         (* not_empty für Erzeuger *)
                                          (* (Unterschied zu klassischen *)
11                                        (* Zählsemaphoren wait u. Signal *)
   PROCEDURE einfügen (x:char);
13 BEGIN
     IF count = N THEN cwait(not_full);   (* Speicher ist voll *)
15   buffer [nextin]:= x;                 (* Ablegen des Erzeugnisses auf *)
                                          (* Speicherplatz x *)
17   nextin := nextin + 1 MOD N;          (* inkrementieren von nextin *)
     count := count + 1;                  (* ein zusätzlicher belegter *)
19                                        (* Speicherplatz *)
     csignal(not_empty);                  (* Nachricht an evtl. wartende *)
21                                        (* Verbraucher *)
   END
23
   PROCEDURE entnehmen(x:char);
25 BEGIN
     IF count = 0 THEN cwait(not_empty); (* Speicher ist leer *)
27   x := buffer[nextout];                (* s.o. *)
     nextout := nextout + 1 MOD N;        (* s.o. *)
29   count := count-1;                    (* ein Speicherplatz ist *)
                                          (* weniger belegt *)
31   csignal(not_full);
   END;
33
   (* Initialisierungscode *) *)
35 BEGIN
     nextin := 0; nextout := 0; count := 0; (* Ausgangszust.: leerer S *)
37 END;

39 (* Erzeuger: *)
   REPEAT
41   <erzeuge Element x>;
     einfügen(x);
43 UNTIL FALSE;

45 (* Verbraucher: *)
   REPEAT
47   entnehmen(x);
     <verbrauche Element x>;
49 UNTIL FALSE;
```

Programm 8 Erzeuger-Verbraucher mit endlichem Speicher

Erzeuger E:

```
1 PROCEDURE Erzeuger;
    VAR x:char;
3   BEGIN
      REPEAT
5       <erzeuge Element x>;
        einfügen(x);
7     UNTIL \FALSE;
    END;
```

Verbraucher V:

```
  PROCEDURE Verbraucher;
2   VAR x:char;
      BEGIN
4       REPEAT
          entnehmen(x);
6         <verbrauche Element x>;
        UNTIL FALSE;
8     END;
```

Beachte, dass diese cwait/csignal-Operationen eine völlig andere Arbeitsweise haben als die signal/wait-Operationen der Semaphore. Sie sind weder Zählvariablen noch Operationen auf solche. So kann ein `csignal`-Signal im Falle nicht wartender Prozesse z.B. ohne Bedeutung sein, ein `signal`-Signal hat jedoch immer eine Wirkung.

7.6 Message Passing

Prozesskoordination erfordert Synchronisation und Kommunikation. Diese soll hier mittels Message Passing, d.h. Nachrichtenaustausch realisiert werden.
Für den Nachrichtenaustausch werden zwei Primitive genutzt:

- send(destination, message)
- receive(source, message)

Für die Ausführung dieser Primitive muß zwischen den Prozessen eine Synchronisation stattfinden. Hierbei sind verschiedene Aspekte zu beachten.

7.6.1 Blockierung

Dabei unterscheiden wir 3 Fälle:

1. **Blocking Send, Blocking Receive**
   Der sendende Prozess wird blockiert, bis die Nachricht vollständig abgeschickt und beim Empfänger angekommen ist.
   Beim Empfänger wird nach einem receive-Aufruf auch eine Blockierung vorgenommen, bis eine Nachricht eingetroffen ist.
   →Diese Kombination wird auch als Rendezvous bezeichnet. Sie ermöglicht eine feste Synchronisation zwischen zwei Prozessen.
   Bei den folgenden Fällen gehen wir von einem nichtblockierenden Senden aus.

2. **Nonblocking Send, Blocking Receive**
   Nach dem Abschicken einer Nachricht kann der Sender mit seiner Ausführung fortfahren. Der Empfänger ist bis zum Erhalt einer Nachricht blockiert.
   →Dies ist offensichtlich die sinnvollste Kombination, denn eine oder mehrere Nachrichten können effizient, d.h. unmittelbar nacheinander an verschiedene Empfänger gesendet werden.

3. **Nonblocking-Receive-Ansätze**
   Probleme resultieren daraus, dass eine Nachricht erst geschickt wird, nachdem ein receive aufgerufen wurde. Die Nachricht geht dann verloren.
   Unter Umständen macht der Einsatz eines Puffers Sinn - der Puffer könnte dann von Zeit zu Zeit abgefragt werden.

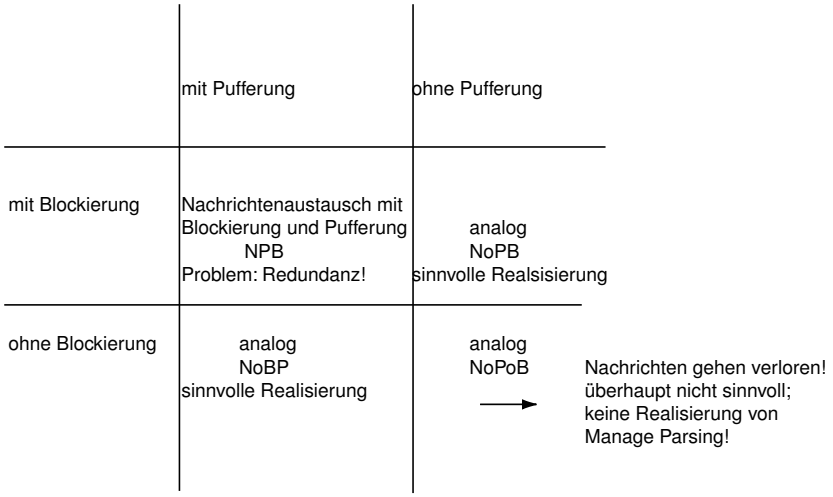

Abbildung 7.9: Realsisierung mit/ohne Blockierung und Pufferung

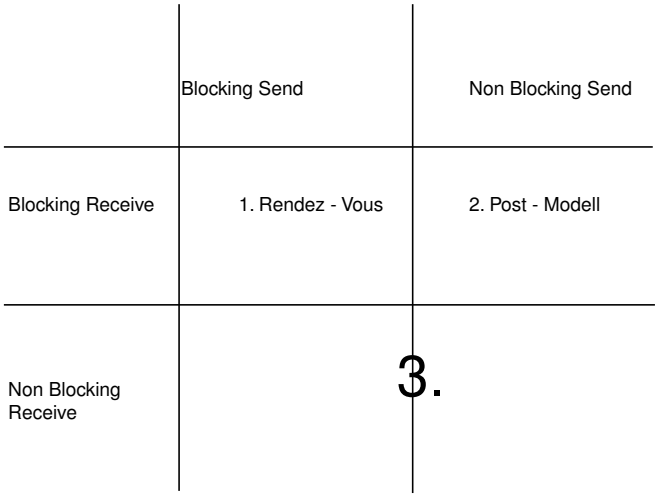

Abbildung 7.10: Realisierung mit/ohne Blockierung

7.6.2 Adressierung

Problem: Wie wird in dem Send-Primitiv angegeben, welcher Prozess die Nachricht erhalten soll, d.h. wie wird die Adressierung vorgenommen?

Und analog: Wie kann ein empfangender Prozess Nachrichten entsprechend deren Absender einschränken?

Dabei werden zwei Ansätze unterschieden:

1. **Direkte Adressierung:**
   Das Send-Primitiv enthält einen speziellen Identifikator des Zielprozesses
   Beim Zielprozeß kann

   (a) genau angegeben werden, von welchem Prozess eine Nachricht erwartet wird (macht z.B. Sinn bei nebenläufigen Prozessen) oder

   (b) jede Nachricht akzeptiert werden. (ist z.B. für einen Drucker geeignet)

   Der Fall b) ließe sich auch sehr gut mit dem folgenden Ansatz realisieren.

2. **Indirekte Adressierung:**
   Nachrichten werden bei diesem Ansatz nicht direkt vom Sender zum Empfänger geschickt, sondern zunächst an eine gemeinsam genutzte Datenstruktur, die im wesentlichen aus einer Warteschlange besteht, die temporär Nachrichten speichern kann.
   Solche Warteschlangen (Queues) werden auch als **Mailboxen** bezeichnet.
   Dabei bestehen folgende Möglichkeiten:

   1:1 (1 Sender →1 Empfänger)
   n:1 - Die Mailbox wird dann auf einen Port zurückgeführt

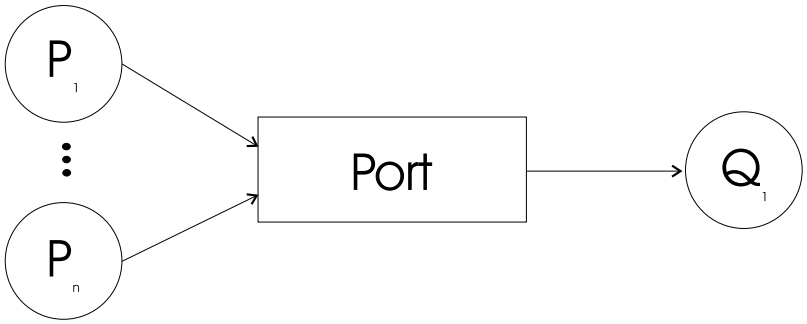

Abbildung 7.11: Indirekte Adressierung n:1

   1:n - Broadcasting
   n:m Mailbox

   Die Zuordnung von Prozessen zu Mailboxen kann dabei statisch oder auch dynamisch sein.
   Ports sind in der Regel statisch den Prozessen zugeordnet.
   Für dynamische Zuordnungen können 2 Primitive verwendet werden: connect und disconnect.

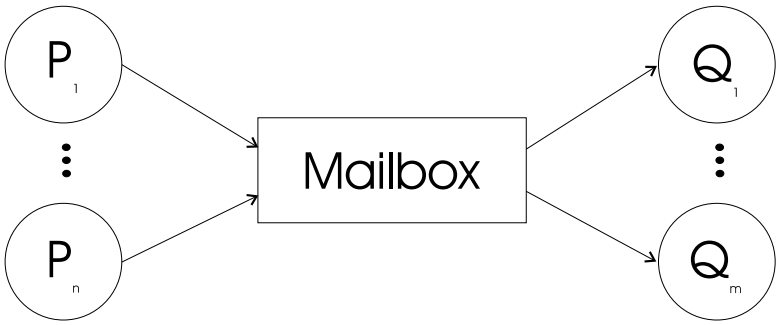

Abbildung 7.12: Indirekte Adressierung n:m

Beispiel (NT, Solaris): Wir realisieren den wechselseitigen Ausschluß nun mittels einer gemeinsam genutzten Mailbox, die wir mit Mutex bezeichnen. (Mutex ... von Mutual Exclusion) Die Mutex-Mailbox kann von allen Prozessen zum Senden und Empfangen genutzt werden, der Initialzustand besteht in einer Message an die Mailbox, diese Nachricht braucht keinen Inhalt zu enthalten.

Ablauf

```
PROGRAM mutualexclusion;
CONST n = ...;                  (* Anzahl der Prozesse *)

PROCEDURE P(i:INTEGER);
VAR msg: message;
BEGIN
  REPEAT
    receive(mutex, msg);        (* Erhalt einer Nachricht ist Bedingung für *)
                                   Eintritt in kritischen Bereich *)
    <critical section>;         (* nun ist die Mailbox leer *)
    send(mutex, msg);           (* Rückgabe der Nachricht an die Mailbox *)
    <remainder>                 (* Damit ist der kritische Bereich *)
                                (* wieder freigegeben *)
  FOREVER
END;

BEGIN                           (* Hauptprogramm *)
  createmailbox(mutex);
  send(mutex, NULL);
  PARBEGIN
    P(1);
    P(2);
    ...
    P(n);
  PAREND;
END.
```

Bei diesem Verfahren muß folgendes beachtet werden:

– Rufen mehrere Prozesse quasi gleichzeitig die receive-Operation auf, so wird die Nachricht an nur einen Prozess ausgeliefert, alle anderen Prozesse werden blockiert, bis sie

eine Nachricht erhalten können.

– Ist die Mailbox leer, so werden alle Prozesse blockiert.

– Wird eine Nachricht in der Mailbox verfügbar, so wird nur ein Prozess aktiviert und ihm die Nachricht übertragen.

Abschließend sollen einige Betriebssysteme und deren Möglichkeiten zur Prozesskoordination und -kommunikation betrachtet werden: (Unterstrichen: Vorwiegend genutzte Möglichkeiten)

– UNIX
  - Pipes (circular buffer to communicate on the E/A-problem basis, d.h. FIFO-Queue, in die ein Prozess schreibt und aus der ein anderer liest.)
  - Messages
  - Shared Memory
  - Semaphore
  - Signale

– Solaris Threads
  - Mutex (Mutual exclusion locks)
  - Semaphore
  - Multiple reader, single writer locks
  - Condition variables (warten, bis Bedingung wahr ist)

– Windows NT
  - File change notification
  - Mutex
  - Semaphore
  - Events
  - Waitable Timer

Teil IV

Ressourcenverwaltung

8

Speicher

- Verwaltung des Speichers
- Aufteilung des Speichers
- Paging und Segmentierung
- Virtueller Speicher

Inhaltsangabe

Vorwissen Rechnerarchitekturen: Der Speicher ist logisch gesehen als linearer Adressraum organisiert. Am Anfang bestimmter Blöcke kann auf Daten zugegriffen werden, wobei die Speicheradresse die Speicherzelle adressiert. z.B. 2^n Speichermedium mit 2^n Speicherzellen benötigt n-Bit große Adressen. Der Speicher wird hierarchisch organisiert.

Nun: Befehle, die vom Prozessor verarbeitet werden, müssen im Hauptspeicher vorliegen. Da dieser jedoch relativ klein ist, können Daten/Programme dort nur temporär vorhanden sein, und Daten müssen zwischen Haupt- und Hintergrundspeicher verschoben werden.

Betriebssystemsicht: Die Speicherverwaltung wird bei der Gestaltung/Entwicklung eines Betriebssystems als eine der schwierigsten Aspekte angesehen.
Speicher wird immer billiger, folglich verfügt jeder Rechner über immer mehr Speicher, aber: es ist nie genug Hauptspeicher verfügbar, um alle Programme und Datenstrukturen aktiver Prozesse und des Betriebssystems anzulegen.
Folglich ist eine zentrale Aufgabe des Betriebssystems, den verfügbaren Speicher zu verwalten.

8.1 Speicherverwaltung

Generell werden fünf Anforderungen an die Speicherverwaltung gestellt:

1. **Relocation:** (Wiederfinden)

   - Der Hauptspeicher eines Multiprogrammingsystems wird von den verschiedenen Prozessen gemeinsam genutzt. Hierfür ist eine Verwaltungsstruktur notwendig, z.B. in Form von Listen.
   - Programme werden zum Teil ausgelagert, und nur das Prozess Image der aktiven Prozesse muß im Hauptspeicher verfügbar sein.

   $\rightarrow$ die Prozessorhardware und die Betriebssystem-Software müssen in der Lage sein, Referenzen im Programmcode in aktuelle physische Adressen umzuwandeln.

2. **Protection:** (Schutz)

   - jeder Prozess muß gegen ungewollte Einmischungen oder Störungen anderer Prozesse geschützt werden, egal ob diese Eingriffe beabsichtigt oder unbeabsichtigt sind.

   $\rightarrow$ fremde Prozesse sollten nicht in der Lage sein, die gespeicherten Informationen eines anderen Prozesses zu lesen oder zu modifizieren, wenn sie dafür keine Erlaubnis haben.

3. **Sharing:** (Teilen/Aufteilen)

   - Die Speicherverwaltung muss verschiedenen Prozessen den Zugriff auf einen gemeinsam genutzten Speicherbereich ermöglichen. Falls mehrere Prozesse das gleiche Programm ausführen, so ist es z.B. vorteilhaft, dass jeder Prozess auf dieselbe Version des Programms zugreift anstatt eine eigene Kopie zu nutzen.

4. **Logical Organization:** (Logische Organisation)

   – Der Hauptspeicher (und in der Regel auch der Sekundärspeicher) ist immer als linearer (1-dimensionaler) Adressraum organisiert, der aus einer Folge von Bits (Bytes oder Wörtern) besteht.

   – Programme werden jedoch modular geschrieben, d.h. diese Darstellung im Speicher entspricht nicht der Art und Weise, in der Programme geschrieben werden.

   → Eine modulare Organisation ist besser zu verwalten und sollte von der Speicherverwaltung unterstützt werden.

5. **Physical Organization:** (Physische Organisation)

   – Umfasst die Einteilung in Hauptspeicher (schneller Zugriff, hohe Kosten) und Hintergrundspeicher (langsamer und billiger).
   Nur der Hintergrundspeicher ist in der Lage, Daten permanent zu speichern. Die Daten werden jedoch vom Prozessor im Hauptspeicher benötigt.

   → Die eigentliche Aufgabe der Speicherverwaltung ist der Transport von Daten zwischen Haupt- und dem Hintergrundspeicher.

8.2 Speicherpartitionierung

Die grundlegende Aufgabe der Speicherverwaltung besteht also darin, Programme zwecks Ausführung durch den Prozessor in den Hauptspeicher zu bringen.
In quasi allen modernen Multiprogrammingsystemen wird dabei das Prinzip des virtuellen Speichers verwendet.
Zunächst sollen jedoch Speichertechniken ohne virtuellen Speicher betrachtet werden.

8.2.1 Feste Partitionierung

– Dabei unterscheidet man gleichgroße und unterschiedlich große Partitionen des Hauptspeichers, wie in Abbildung 8.1 zu sehen.

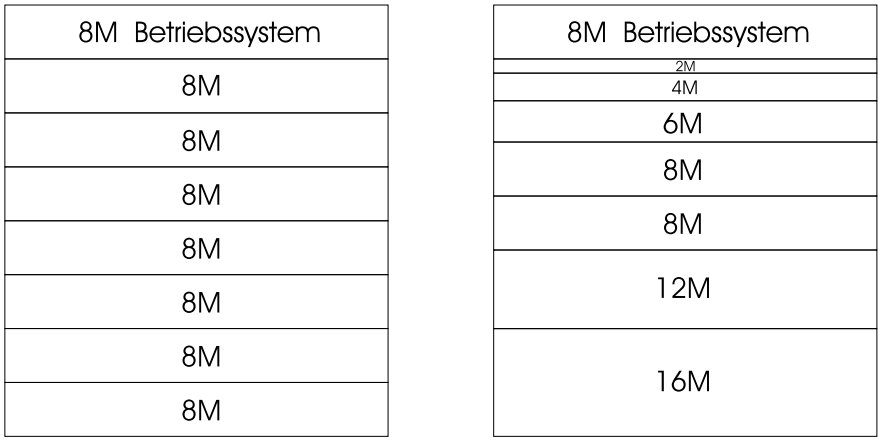

Abbildung 8.1: Beispiel für feste Partitionierung

– In die jeweilige Partition kann jeweils ein Prozess geladen werden, dessen Größe kleiner oder gleich der Partitionsgröße ist.

– Sind alle Partitionen voll und kein Prozess ist im State *Running* oder *Ready*, so kann das Betriebssystem Prozesse auslagern, dadurch Partitionen freibekommen und dann andere Prozesse nachladen.

Mögliche Probleme:

– Ein Programm ist zu groß, um in eine Partition hineinzupassen. Dann ist es die Aufgabe des Programmierers, das Programm in Teilprogramme zu zerlegen (oder sich einen anderen Hauptspeicher zuzulegen: größer oder anders partitioniert).

– Die Partitionierung ist extrem ineffizient, d.h. viele kleine Module belegen die Partitionen, so dass viel Platz verschwendet wird.
→ Diesen Sachverhalt bezeichnet man als **interne Fragmentierung**.

Beide Probleme können mittels unterschiedlich großen Partitionen des Hauptspeichers verringert, jedoch nicht beseitigt werden.

Allerdings ist bei verschieden großen Partitionen zu beachten, dass immer die jeweils kleinste, freie und hinreichend große Partition verwendet wird.

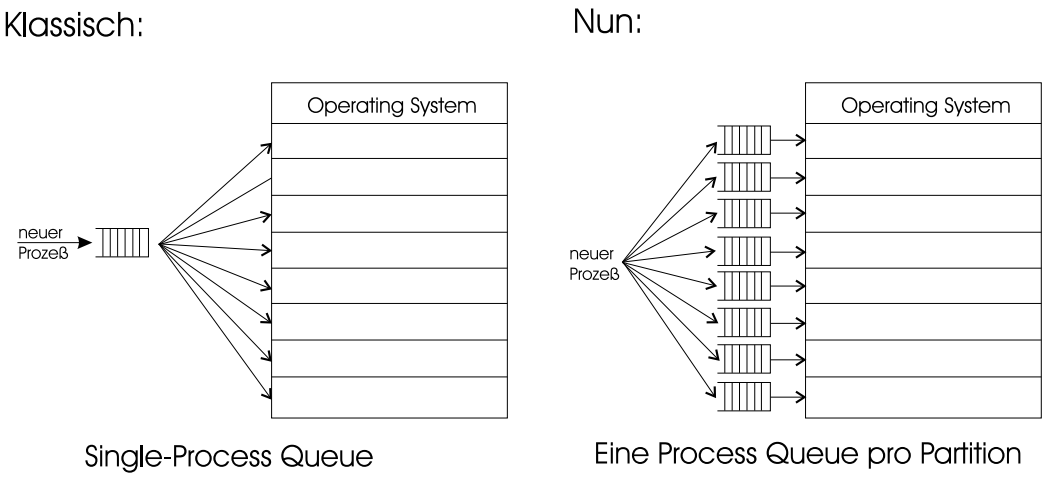

Abbildung 8.2: Technik der fixen Partitionierung

8.2.2 Dynamische Partitionierung

Bei der dynamische Partitionierung ist die Anzahl sowie die Größe der Partitionen variabel. Alle Partitionen werden sequentiell beschrieben.
Soll ein Prozess gespeichert werden, so wird für ihn genau so viel Platz bereitgestellt, wie er benötigt - und nicht mehr. Ein Nachteil dieser Strategie ist die Entstehung von Lücken, falls bestimmte Daten nicht mehr gebraucht werden. Diese Lücken können jedoch von anderen Prozessen genutzt werden.
Abbildung 8.3 veranschaulicht das Prinzip für 1 MByte Hauptspeicher.
Geht man von einem freien Speicher aus, so funktioniert dieser Algorithmus recht gut - der Speicher wird jedoch mit der Zeit zunehmend fragmentiert.

Mögliche Probleme:

– Neue Speicheranforderungen entsprechen in der Regel in ihrer Grösse nicht den bestehenden Lücken, so dass Freiräume zwischen den Segmenten entstehen. → Dieses Phänomen bezeichnet man als **externe Fragmentierung**.

Dagegen hilft die Komprimierung (Compaction): Von Zeit zu Zeit werden die Prozesse zu einem Block zusammengeschoben.
Um innerhalb einer Speicherstruktur, in der einzelne Blöcke abgespeichert sind, ein optimales Füllen der freien Speicherbereiche zu erhalten, gibt es verschiedene Strategien:

Best-Fit: suche die kleinste Lücke, in die der Prozess paßt.

First-Fit: nimm vorne die erste passende Lücke.

Next-Fit: nimm ab letzter Belegung die nächste passende Lücke.

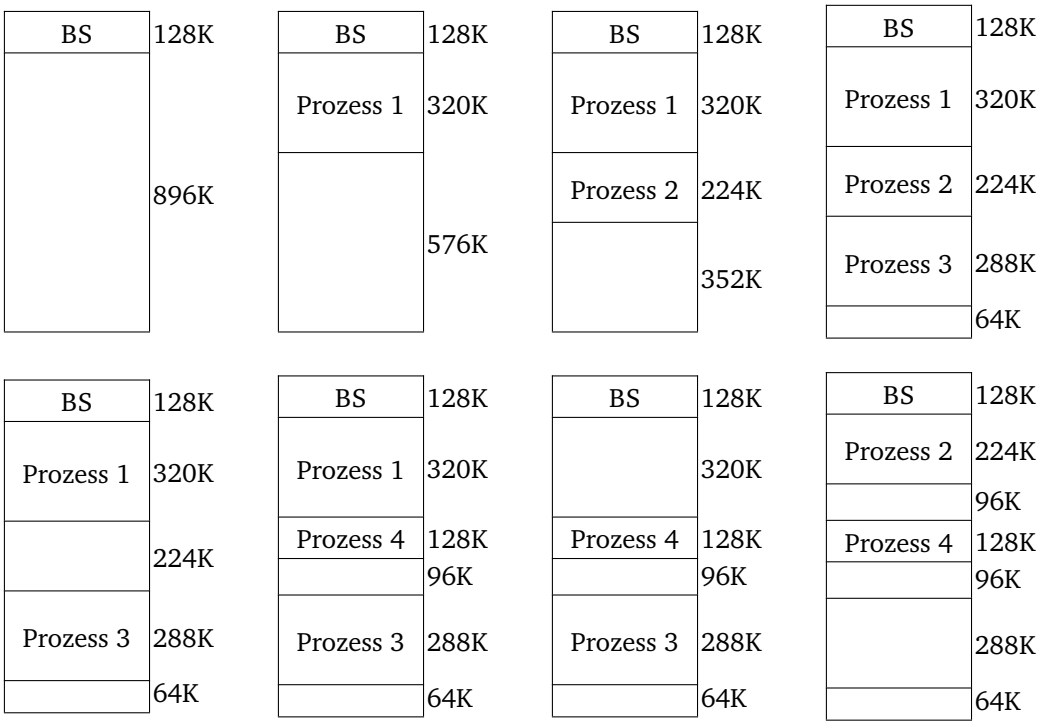

Abbildung 8.3: Dynamische Partitionierung

8.2.3 Buddy-Systeme

Eine feste Partitionierung hat den Nachteil, dass die Anzahl aktiver Prozesse begrenzt ist und der Speicherplatz ineffizient genutzt wird. Eine dynamische Partitionierung ist dagegen komplex zu verwalten und hinterläßt unnutzbare Freiräume.

Ein interessanter Kompromiß sind die sogenannten *Buddy-Systeme*
Ein Speicher der Größe 2^N wird in Blöcke der Größe 2^K eingeteilt. Die kleinste Speichergröße wird auf 2^L, die größte auf 2^U festgelegt. Für unterschiedliche K muss in jedem Fall gelten: $L \leq K \leq U$, Im allgemeinen gilt: $U = N$.
($\rightarrow$L/U = Lower/Upper Bound (Grenze). L ist geeignet zu wählen, so dass hinreichend kleine Buddies möglich sind, deren Verwaltung noch sinnvoll ist.)

Anfangszustand: Der verfügbare Speicherplatz wird als einzelner Block der Größe 2^U betrachtet.

Algorithmus: Kommt nun eine Speicheranforderung S, so wird die Bedingung $2^{U-1} < S \leq 2^U$ geprüft und in diesem Fall der gesamte Speicher der Anforderung zugewiesen.
Ist $S > 2^U$, so kann die Anforderung nicht erfüllt werden.
In der Regel wird jedoch $S \leq 2^{U-1}$ gelten.
$\Rightarrow$Der Speicherblock wird in zwei Buddies der Größe 2^{U-1} aufgespaltet und für den ersten Block die Bedingung $2^{U-2} < S \leq 2^{U-1}$ geprüft. Und so weiter.

Das Buddy-System verwaltet pro Zweierpotenz eine Liste der freien Speicherplätze, d.h. der Lücken der Größen 2^i.

Durch das Splitten wird eine Lücke von der entsprechenden Liste entfernt. Von den beiden (halb so großen) entstehenden Gliedern wird entweder eines besetzt oder weitergesplittet u.s.w.

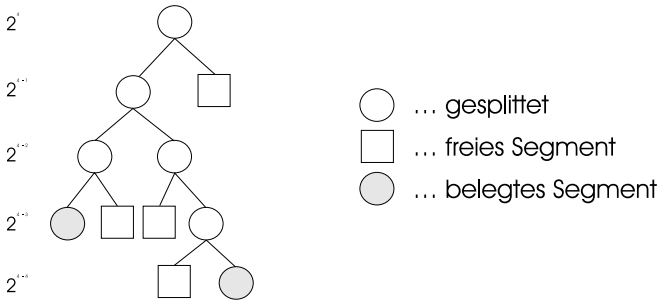

Abbildung 8.4: Beispiel für Buddy-Systeme

Umgekehrt: Ist eine gewünschte Liste leer, so wird die nächsthöhere freie Liste entsprechend gesplittet.
Die Adressierung geschieht dabei auf folgende Art und Weise:
Wir gehen von einem Speicherbereich der Größe 2^U aus, geben ihm die Adresse

$$x\underbrace{000\ldots0}_{\text{U Nullen}}$$

wobei x eine beliebige Dualzahl darstellt (z.B. $x = 0$). Die Blöcke der Größe 2^{U-1} erhalten die Adressen

$$x0\underbrace{000\ldots0}_{\text{U}-1\text{ Nullen}}$$

und

$$x1\underbrace{000\ldots0}_{\text{U}-1\text{ Nullen}}$$

dann ergibt sich für die Blöcke der Größen 2^{U-2} die Adressierung analog (Abbildung 8.5):

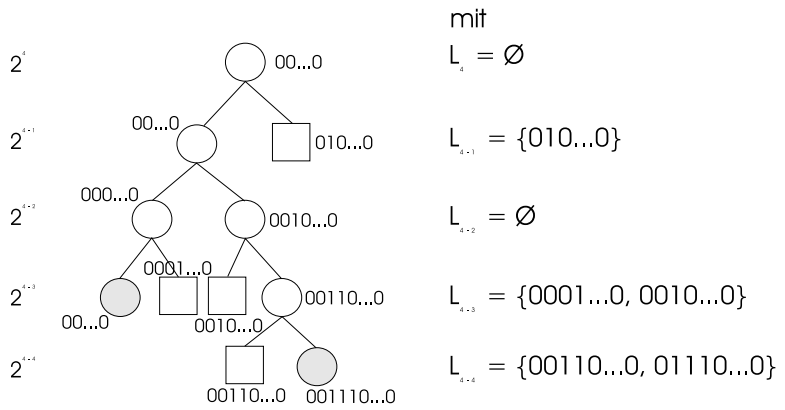

Abbildung 8.5: Adressierung in Buddy-Systemen

In der Praxis könnte für einen Speicher von 1 Megabyte zunächst eine Anforderung von 100k kommen, dann 250k, dann 50k:

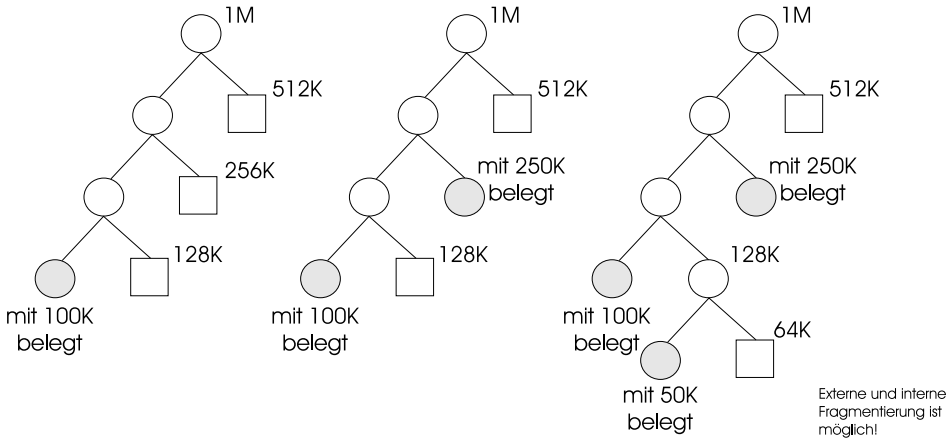

Abbildung 8.6: Fragmentierung bei Buddy-Systemen

Merke: Immer Listen aktualisieren! Bei Freigabe von Buddies muss geprüft werden, ob der benachbarte Buddy auch frei ist. Falls ja, werden beide freien Buddies zu einem nächst grösseren zusammengefasst.
→Eintrag in Liste, erneute Zusammenlegung prüfen etc.

Nachteil: →interne und externe Fragmentierung

Anwendung: Eine Variante dieser Speicherform wird im UNIX Kernel verwendet.

Eine Alternative zu den vorgestellten *Buddy-Systemen* sind die *gewichteten Buddy-Systeme*.

Gewichtete Buddy-Systeme

Um bei Speicherplatzanforderungen ungleich 2^{pot} weniger Platz zu verschenken, d.h. um die interne Fragmentierung möglichst gering zu halten, werden *gewichtete Buddy-Systeme* verwandt.

Prinzip: Ein Block der Größe 2^{n+2} wird im Verhältnis 1:3 geteilt. Das ergibt Blöcke der Größe 2^r und $3 \cdot 2^r$. Der *Buddy* der Größe $3 \cdot 2^r$ wird im Verhältnis 2:1 geteilt, d.h. in Blöcke der Größe 2^{r+1} und 2^r wie man auch in Abbildung 8.7 sehen kann.

Vorteil: Man erhält flexible Buddygrößen und damit weniger Verschwendung von Platz.

Aber: Der Verwaltungsaufwand für die einzelnen Buddies, insbesondere zur Adressberechnung wird deutlich größer.

8.3 Virtueller Speicher

Adressräume stehen in sehr engem Zusammenhang mit der Speicherverwaltung. Wir wollen nun eine statische Partitionierung betrachten und teilen dazu den Hintergrundspeicher und

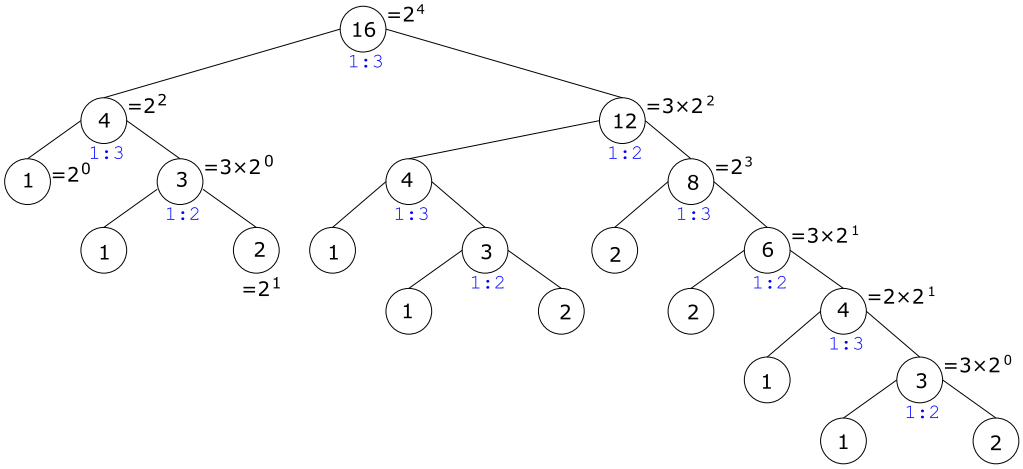

Abbildung 8.7: Veranschaulichung des Prinzips gewichteter Buddy Systeme

den Hauptspeicher in Blöcke gleicher, fester Grösse. Diese feste Grösse soll eine Zweier-Potenz sein, um spätere Adressberechnungen zu vereinfachen. Wenn HGS $>$ HS, dann werden beide Speichermedien in unterschiedliche Anzahlen von Blöcken geteilt. (HGS hat mehr Blöcke als HS).

8.3.1 Prinzip der Speicherverwaltung

Definition 8.1 (Physischer Adressraum)**.** Die Menge der im Arbeitsspeicher physisch vorhandenen Speicherplätze bildet den realen oder *physischen Adressraum* P.

Im physischen Adressraum werden die Speicherzellen, die eine einheitliche Größe besitzen (in der MI 8 Bit), linear angeordnet, d.h. jeder Zelle ist eindeutig eine Adresse zugeordnet, die mit 0 beginnen.

Definition 8.2 (Logischer Adressraum)**.** Dem physischen oder realen Adressraum steht ein virtueller oder *logischer Adressraum* L gegenüber.

Der logische Adressraum wird benötigt, falls die Kapazität des physischen Arbeitsspeichers nicht ausreicht, um alle Daten zu speichern. Der so entstehende Kapazitätsengpaß soll durch die zusätzliche Nutzung des Hintergrundspeichers (in der Regel der Festplatten) beseitigt werden.

Aufgabe der Speicherverwaltung **Die Aufgabe der Speicherverwaltung besteht in der Zuordnung von logischen zu physischen Adressen**, d.h. im Auffinden einer geeigneten Abbildung L $\longrightarrow$ P ("logischer Adressraum" wird abgebildet auf "physischen Adressraum"). Für die Konstruktion einer solchen Abbildung sind die beiden folgenden Fälle zu unterscheiden:

1. Ist $|L| \leq |P|$, also der logische Adressraum kleiner als der physische, so kann der logische Adressraum problemlos in den physischen aufgenommen werden. Bei modernen Rechnern ist diese Situation in der Regel gegeben, wenn nur ein einzelner Benutzer mit einem einzelnen Programm betrachtet wird.

2. Der Fall $|L| > |P|$ ist jedoch der klassische Fall. Dies resultiert u.a. aus der weit verbreiteten Wortlänge von 32 Bit, mit der sich 2^{32} Adressen ansprechen lassen. Nimmt man an, dass jede Adresse ein Speicherwort von 4 Byte adressiert, so lassen sich $2^{32} \cdot 4 = 2^{34}$ Byte $=$ 16 Gigabyte in L ansprechen.

Weiterhin fordern folgende Entwicklungen die Verwendung von virtuellem Speicher: An Rechnern, die Multiprogramming-fähig sind, können mehrere Nutzer gleichzeitig arbeiten und Teile des Speichers durch Systemsoftware belegt werden.

Offensichtlich wird also der Arbeitsspeicher im allgemeinen nicht ausreichen. Gleichzeitig ist ausreichend Hintergrundspeicher vorhanden, um große Datenmengen aufzunehmen.

Aus diesen beiden Beobachtungen heraus wurde die Verwendung von *virtuellem Speicher* notwendig.

Bemerkung 8.1. *In der MI ist* $|L| > |P|$. *Mit einer der* 2^{32} *Adressen läßt sich nur je* 1 *Byte ansprechen, also hat* L *eine Größe von* 4 *Gigabyte. Die MI besitzt allerdings nur einen "realen" Arbeitsspeicher* P *von* 1 *Gigabyte, es muß also eine Methode gefunden werden, den logischen auf den realen Adressraum abzubilden.*

8.3.2 Datentransport zwischen Hintergrund- und Arbeitsspeicher

Im allgemeinen ist der virtuelle Speicher L (deutlich) größer als der reale Speicher P. Daher ist es nötig, zu definieren, wie der Datentransport zwischen Hintergrund- und Arbeitsspeicher vonstatten geht und welche Teile des virtuellen Adressraumes auf Hintergrundspeicher auszulagern sind.

Definition 8.3 (Seite)**.** Zum **Datentransport** werden **Transporteinheiten** fester Länge definiert, die als *pages* oder **Seiten** bezeichnet werden. Der logische Speicher wird also in Seiten aufgeteilt, die einzeln zwischen Hintergrund- und Arbeitsspeicher transferiert werden können.

In der Regel werden für eine Seite Größen zwischen 2 und 8 Kilobyte verwendet, in der MI werden jedoch nur 512 Byte verwendet.

Definition 8.4. Als Gegenstück zu den *pages* des logischen Adressraumes wird der reale Adressraum (d.h. der Hauptspeicher) in *Frames* (Seitenrahmen oder Kacheln) eingeteilt. Frames haben immer die gleiche Größe wie die *pages* (vgl. Abbildung 8.8).

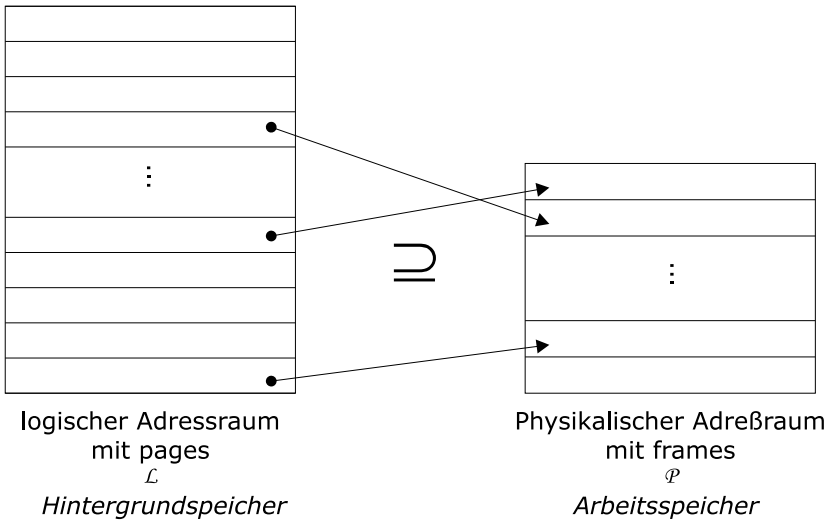

Abbildung 8.8: Abbildung zwischen *frames* und *pages*

Die Größe einer Seite sollte weder “zu klein” (zuviel Transport- und Verwaltungsaufwand) noch “zu groß” (zuviel Speicherverschwendung, interne Fragmentierung) sein.

8.3.3 Abbildung virtueller auf reale Adressen

MI-Maschinenadressen

Die Aufteilung einer MI-Maschinenadresse ergibt sich aus Abbildung 8.9.

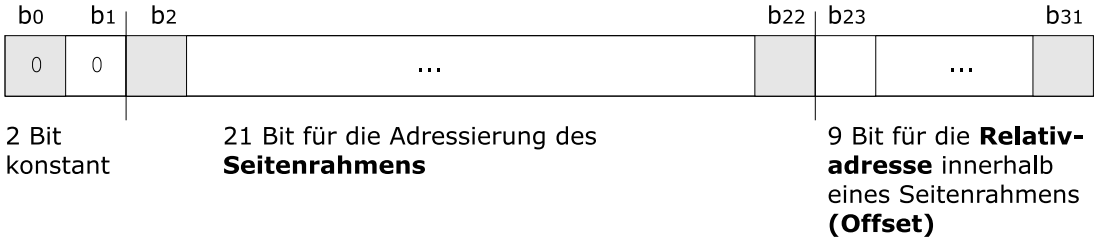

Abbildung 8.9: MI-Maschinenadresse

Eine Maschinenadresse muß folgende Informationen liefern:

1. die Nummer des Seitenrahmens und
2. innerhalb einer Seite muß eine Adresse relativ zum Anfang des Seitenrahmens angegeben werden (**Offset**).

Beispiel 8.1. *Bei der MI hat eine Seite* $2^9 = 512$ *Byte, also benötigen wir gerade 9 Bit für die Adressierung innerhalb einer Seite. Für die Adressierung der Seitenrahmen hingegen benötigen wir* 21 *Bit, da es* 1 *GB* $= 2^{30} : 2^9 = 2^{21}$ *(Größe des Arbeitsspeichers durch Größe einer Seite) Seitenrahmen gibt.*

Beispiel 8.2. *Der HGS hat viermal so viele Speicheradressen wie der HS. Daher sind die virtuellen Adressen um 2 Bit länger als die realen Adressen.*
⇒Mit k zusätzlichen Bits können 2^k mal so viele Speicherzellen adressiert werden.

Virtuelle Adressen (MI-Programmadressen)

Wiederum sind die Adressen von 32 Bit Länge. Die Aufteilung ist ähnlich zu der von MI-Maschinenadressen, jedoch wird folgende Codierung für b_0 und b_1 ergänzt:

b_0	b_1	Bereich
0	0	P0
0	1	P1
1	0	P2
1	1	P3

Damit ergibt sich die Aufteilung in 8.10.

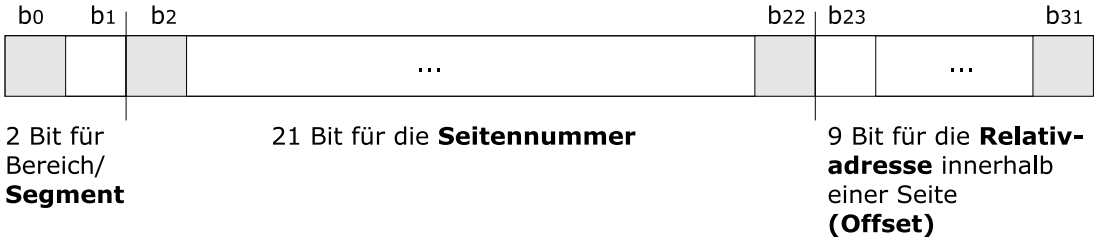

Abbildung 8.10: MI-Programmadresse

Abbildung der virtuellen auf reale Adressen: Die auf diese Weise erhaltenen virtuellen Adressen müssen nun auf reale Adressen abgebildet werden. Dieser Prozess wird auch als *Adress Translation* bezeichnet. Die Abbildung wird mit Hilfe einer **Seitentabelle** (**Seitentafel**, **Speicherabbildungstabelle**) vorgenommen. Darin

- sind die Seiten im Hintergrundspeicher durchnumeriert und
- zu jeder Seite wird angegeben, ob sie im Hauptspeicher verfügbar ist und falls ja, in welchem Seitenrahmen und mit welcher Adresse.

Beispiel 8.3. *Angenommen, wir haben Seiten von 2 Kilobyte Länge. Dann erhalten wir eine Seitentabelle wie in Tabelle 8.1 gezeigt.*

Wird eine virtuelle Adresse angefordert, so werden die Bits für die Seitennummer (MI: b_2 bis b_{22}) in der Tabelle gesucht. Falls die Tabelle sich im Hauptspeicher befindet, so werden diese Bits durch die “realen Bits” ersetzt, d.h. die Seitennummer der virtuellen Adresse wird durch die Seitenrahmennummer der realen Adresse ersetzt.

Speichertabelle mit angenommener Hauptspeicher-Adresse `0A32` für das Frame Nr. 3; alle anderen Hauptspeicheradressen lassen sich automatisch berechnen. Hierbei stehe HGS für Hintergrundspeicher und HS für Hauptspeicher.

Seite	Adr. HGS	S. im HS?	Nr. Frame	Adr. HS
0	AA0000	no	–	–
1	AA0800	yes	5	1A32
2	AA1000	no	–	–
3	AA1800	yes	7	2A32
4	AA2000	yes	3	0A32

Tabelle 8.1: Beispiel für eine Speichertabelle

8.4 Paging

Prinzip: Es werden ausschließlich Speicherblöcke einheitlicher Größe verwendet, diese werden als **Seiten** (*Pages*) bezeichnet. Zu diesem Zweck ist der logische Adressraum von Programmen in Seiten und der physische Adressraum im Hauptspeicher in **Rahmen** (*Frames*) unterteilt worden. Die Seiten werden bei Bedarf in verfügbare Rahmen geladen. Der Vorteil dieser Methode ist, dass es keine Speicherzerstücklung (keine Lücken) gibt (externe Fragmentierung), dafür kommt es jedoch bei der Zuordnung des Seiten zu deutlichem Verschnitt(interne Fragmentierung). Nachdem die feste Partitionierung den Nachteil der internen Fragmentierung hatte und die variable Partitionierung eine externe Fragmentierung bedingte, soll das Paging im Folgenden näher betrachtet werden.

8.4.1 Paging-Strategien

Unter verschiedenen Kriterien sollen drei mögliche Strategien des Pagings betrachtet werden:

1. **Demand Paging:** Fehlt eine Seite im Hauptspeicher (d.h. liegt ein Seitenfehler vor), so wird diese on demand aus dem HGS nachgeladen.

2. **Demand Prepaging:** Fehlt eine Seite im Hauptspeicher, werden gleichzeitig *mehrere* Seiten geladen und verdrängt. Dadurch wird also die Zahl der Zugriffe auf den Hintergrundspeicher geringer gehalten als beim ersten Verfahren.

3. **Look-Ahead-Paging:** Nicht nur bei Seitenfehlern, sondern auch nach anderen (näher zu definierenden) Kriterien können Nachladeoperationen stattfinden.

In der Praxis sollte anhand konkreter Problemstellungen überlegt werden, welche der vorgestellten Paging-Strategien am günstigsten einsetzbar ist. *Demand Paging* ist wahrscheinlich am einfachsten zu implementieren, allerdings kann es effizienter sein, ganze Blöcke von Seiten auf einmal nachzuladen. In diesem Fall sollte darüber nachgedacht werden, *Demand Prepaging* oder auch - z.B. im Falle einer nicht permanent ausgelasteten CPU ohne konkretes Vorliegen eines Seitenfehlers - Look-Ahead-Paging zu verwenden.

8.4.2 Seitenaustauschalgorithmen

Dabei gibt es verschiedene Vorschriften (Policies), die das Betriebssystem für den Virtuellen Speicher macht.
Im Folgenden sollen einige Beispiele solcher Policies betrachtet werden.

Resident Set Management Policy

Macht Vorschriften, ob sich eine feste oder eine variable Anzahl von Seiten eines bestimmten Prozesses während der Abarbeitung ständig im Hauptspeicher befinden sollte. (Zur Wiederholung: Einige Informationen müssen als residente Menge des Prozesses ständig im Hauptspeicher verfügbar sein.)
Weiterhin kann mit dieser Policy die Menge der für einen Austausch infrage kommenden Seiten eingeschränkt werden, diesen Sachverhalt nennt man Replacement Scope.

Fetch Policy

Bestimmt im wesentlichen, ob eine neue Seite nur dann nachgeladen wird, wenn ein Seitenfehler vorliegt (Demand Paging) oder ob Seiten auch dann nachgeladen werden dürfen, wenn kein Seitenfehler vorliegt (Prepaging).
Der letztgenannte Sachverhalt könnte dann sinnvoll sein, wenn - z.B. im Falle eines Seitenfehlers - auch mehrere Seiten auf einmal als Block gut transportiert werden könnten.
Prepaging wird von den meisten Betriebssystemen umgesetzt.

Placement Policy

Bestimmt, wo ein Teil eines Prozesses in den Arbeitsspeicher hingeschrieben wird, z.B. nach best-fit, first-fit, ... Algorithmus.
Beim Paging ist diese Vorschrift irrelevant, da dadurch keine Speichervorteile zustande kommen.

Replacement Policy

Situation: Die einem Prozess zugeordneten Frames sind alle belegt, und es wird eine weitere Page im HS benötigt. Bestimmt die Seite bzw. den Block, der ersetzt werden soll, wenn eine neue Seite geladen werden muß, d.h. wenn ein Seitenfehler auftritt.
In den vergangenen 20 Jahren wurde im Bereich der Betriebssysteme dieses Thema wahrscheinlich am meisten betrachtet.
Es existieren nun verschiedene, grundlegende Ersetzungsstrategien.

1. **OPT (Optimalstrategie):** Lagert jeweils diejenige Seite mit dem größten Vorwärtsabstand aus, also diejenige Seite, die am längsten nicht mehr gebraucht wird. Dieses Verfahren verursacht theoretisch die wenigsten Seitenfehler, man sagt: Die geringsten Kosten. Praktisch ist es jedoch nur in Ausnahmefällen realisierbar.
   Als Approximation kann man den Vorwärtsabstand aufgrund bisheriger Beobachtungen schätzen.
   Wenn man dieses Verfahren im Nachhinein auf eine Abarbeitung von Prozessen anwendet, erhält man ein Maß, um die Güte anderer Verfahren bewerten zu können.

Z.B. bei einer Anforderung der Seiten:

2 3 2 1^* 5 2^* 4 5 3^* 2 5 2

wäre bei einer Kapazität von 3 Seiten im Speicher folgende Belegung denkbar:

FR1				1^r	5	5	5	5	5	5	5
FR2		3	3	3	3	3	3	3	3	3	3
FR3	2	2	2	2	2	2^r	4	4	4	4	2

2 ist die Seite mit dem grössten Vorwärtsabstand, d.h. diese Seite wird am längsten nicht mehr gebraucht →ersetzt. (r steht für raus!)

1^*	5^*	4^*	2
3	3	5	5
2	2	3	3

$*$ bezeichnet dabei das Auftreten eines Seitenfehlers, d.h. bei einer optimalen Strategie treten nur 3 Seitenfehler auf. Streng genommen rechnet man zusätzliche 3 Seitenfehler für die Erstbelegungen und erhält somit 6 Seitenfehler.

FAZIT:

Diese Strategie ist wie ihr Name optimal und sinnvoll v.a. als Benchmarkingstrategie.
Aber: In der Praxis kann der Referencestring erst im Nachhinein aufgestellt werden, da zu einem bestimmten Zeitpunkt immer nur die als nächstes zu bearbeitende Seite sichtbar ist.

2. **First In First Out (FIFO-Strategie):** Ordnet Seiten nach dem Alter, im Bedarfsfall wird die älteste Seite, d.h. die Seite, die sich bereits am längsten im Hauptspeicher befindet, ausgelagert.

Beispiel:

2 3 2 1^* 5^* 2^* 4 5^* 3 2^* 5^* 2

1^*	5^*	2^*	4^*	3^*	5^*	2
3	1	5	2	4	3	5
2	3	1	5	2	4	3

FR1				1	5	2	4	4	3	3	5	2
FR2		3	3	3	1	5	2	2	4	4	3	5
FR3	2	2	2	2^r	3^r	1^r	5	5^r	2	2^r	4^r	3

D.h. es treten mit den Erstbelegungen 9 $(3 + 6)$ Seitenfehler auf. Im Vergleich zur OPT-Strategie ist FIFO also eine relativ schlechte Strategie. Realisiert werden kann dieser Ansatz mit einem zirkulierenden Zeiger. Von der Implementierung her ist dies der einfachste - aber leider nicht der beste - Algorithmus.

3. **Least Recently Used (LRU-Strategie):** Verdrängt Seiten nach dem Alter, d.h. die am längsten nicht mehr benutzte Seite wird aus dem Hauptspeicher ausgelagert.
Die zugrundeliegende Idee besteht in der Lokalität, d.h. die Seite, die gerade gebraucht wurde, wird wahrscheinlich wieder gebraucht.
Diese Strategie kommt der Optimalstrategie relativ nahe.

Beispiel:

2 3 2 1* 5 2* 4 5* 3* 2 5 2												
			1*	5*	4*	3*	2					
			3	1	5	4	3					
			2	2	2	5	5					
			1*	5	2*	4	5*	3*	2	5	2	
oder:		3	2	2	1	5	2	4	5	3	2	5
	2	2	3	3	2	1	5	2	4	5	3	3

D.h. in diesem Fall treten 7 (3+4) Seitenfehler auf.
Aus logischer Sicht kann eine Realisierung so erfolgen, dass die Seiten in FIFO-Reihenfolge im Hauptspeicher abgelegt werden und beim Aufruf einer der bereits im Hauptspeicher bestehenden Seiten diese Seite an die oberste Stelle umgeschrieben wird.
Bei einem Seitenfehler muß die Seite mit maximaler Rückwärtsdistanz, also die am längsten nicht mehr benutzte Seite, ersetzt werden.
Realisierbar ist dieser Ansatz am einfachsten durch eine verkettete Liste und ist insbesondere bei starker Lokalität gut geeignet.

4. **LFU (Least Frequently Used[1]):** Bei diesem Verfahren soll diejenige Seite mit niedrigster Nutzungshäufigkeit ausgetauscht werden, so dass die am häufigsten genutzten Seiten im HS bleiben. Dazu muß jedoch für jeden Frame die Anzahl an Zugriffen verwaltet werden. Dieses Verfahren wird im wesentlichen in drei Varianten verwendet, die sich nach der Dauer der Zählung der Seitenzugriffe unterscheiden:

   Die Seitenzugriffe können gezählt werden
   (a) seit Laden der Seite
   (b) innerhalb der letzten h Zugriffe oder
   (c) seit dem letzten Seitenfehler.
   Diese Variante ist nur bei starker Lokalität geeignet, d.h., wenn zwischen 2 Seitenfehlern ein hinreichend großer Abstand liegt. Dies ist etwa der Fall, wenn mehr Seiten genutzt werden, als Frames in den Hauptspeicher passen.

[1] In der Literatur wird auch häufig der Begriff *Last Frequently Used* verwendet

Bei diesem Verfahren ist jedoch wie auch bei **LRU**, bei jedem Speicherzugriff ein zusätzlicher Verwaltungsaufwand notwendig. Der Aufwand ist in der Praxis so groß, dass das Verfahren kaum genutzt wird.

5. **Climb (Aufstieg bei Bewährung):** Hierbei steigt eine Seite bei jedem Aufruf eine Position höher, wenn sie bereits im Speicher vorhanden ist, d.h. sie tauscht ihre Position mit der vor ihr stehenden Seite. **Beispiel:**

2 3 2 1* 5 2* 4* 5 3 2 5 2										
			2	2	2	2	2	3	2	2
	2	2	3	3	3	3	3	2	3	5
2	3	3	1	5*	5	4*	5*	5	5	3

Ist eine neue Seite nicht im Speicher vorhanden, so wird die unterste Seite ausgelagert und die neue Seite dorthin geladen.
Es treten wie bei der OPT-Strategie 6 (3+3)Seitenfehler auf.

6. **Clock-Strategie:** Im Folgenden soll die Verwaltung von Seiten in einer zyklischen Liste betrachtet werden, die die Form einer Uhr darstellt. Der Zeiger der Uhr zeigt dabei auf die älteste Seite.
Ein zusätzliches Bit pro Seite wird auch als Use Bit bezeichnet. Wird eine Seite das erste mal in ein Frame des Hauptspeichers geladen, so wird dieses Use Bit auf 1 gesetzt. Bei einer nachfolgenden Referenzierung erfolgt ebenfalls ein Setzen auf 1.
Ist es nötig, eine Seite zu ersetzen, so wird der Speicher durchsucht, um ein Frame mit einem Use Bit = 0 zu finden. Trifft er dabei auf ein Frame mit einem Use Bit = 1, so wird dieses auf den Wert 0 zurückgesetzt. Haben alle Frames Use Bits = 0, so wird das erste Frame, auf das der Zeiger zeigt, für die Ersetzung gewählt. Haben andererseits alle Frames ein Use Bit = 1, so durchläuft der Zeiger einen kompletten Zyklus durch den Speicher, setzt alle Use Bits auf 0 und stoppt dann an der ursprünglichen Stelle. Das Frame wird genutzt, um eine Seite zu ersetzen, woraufhin der Zeiger um eins erhöht wird.
Diese Algorithmus ähnelt FIFO, allerdings mit der Ausnahme, dass Frames mit einem Use Bit = 1 durch den Algorithmus übersprungen werden.

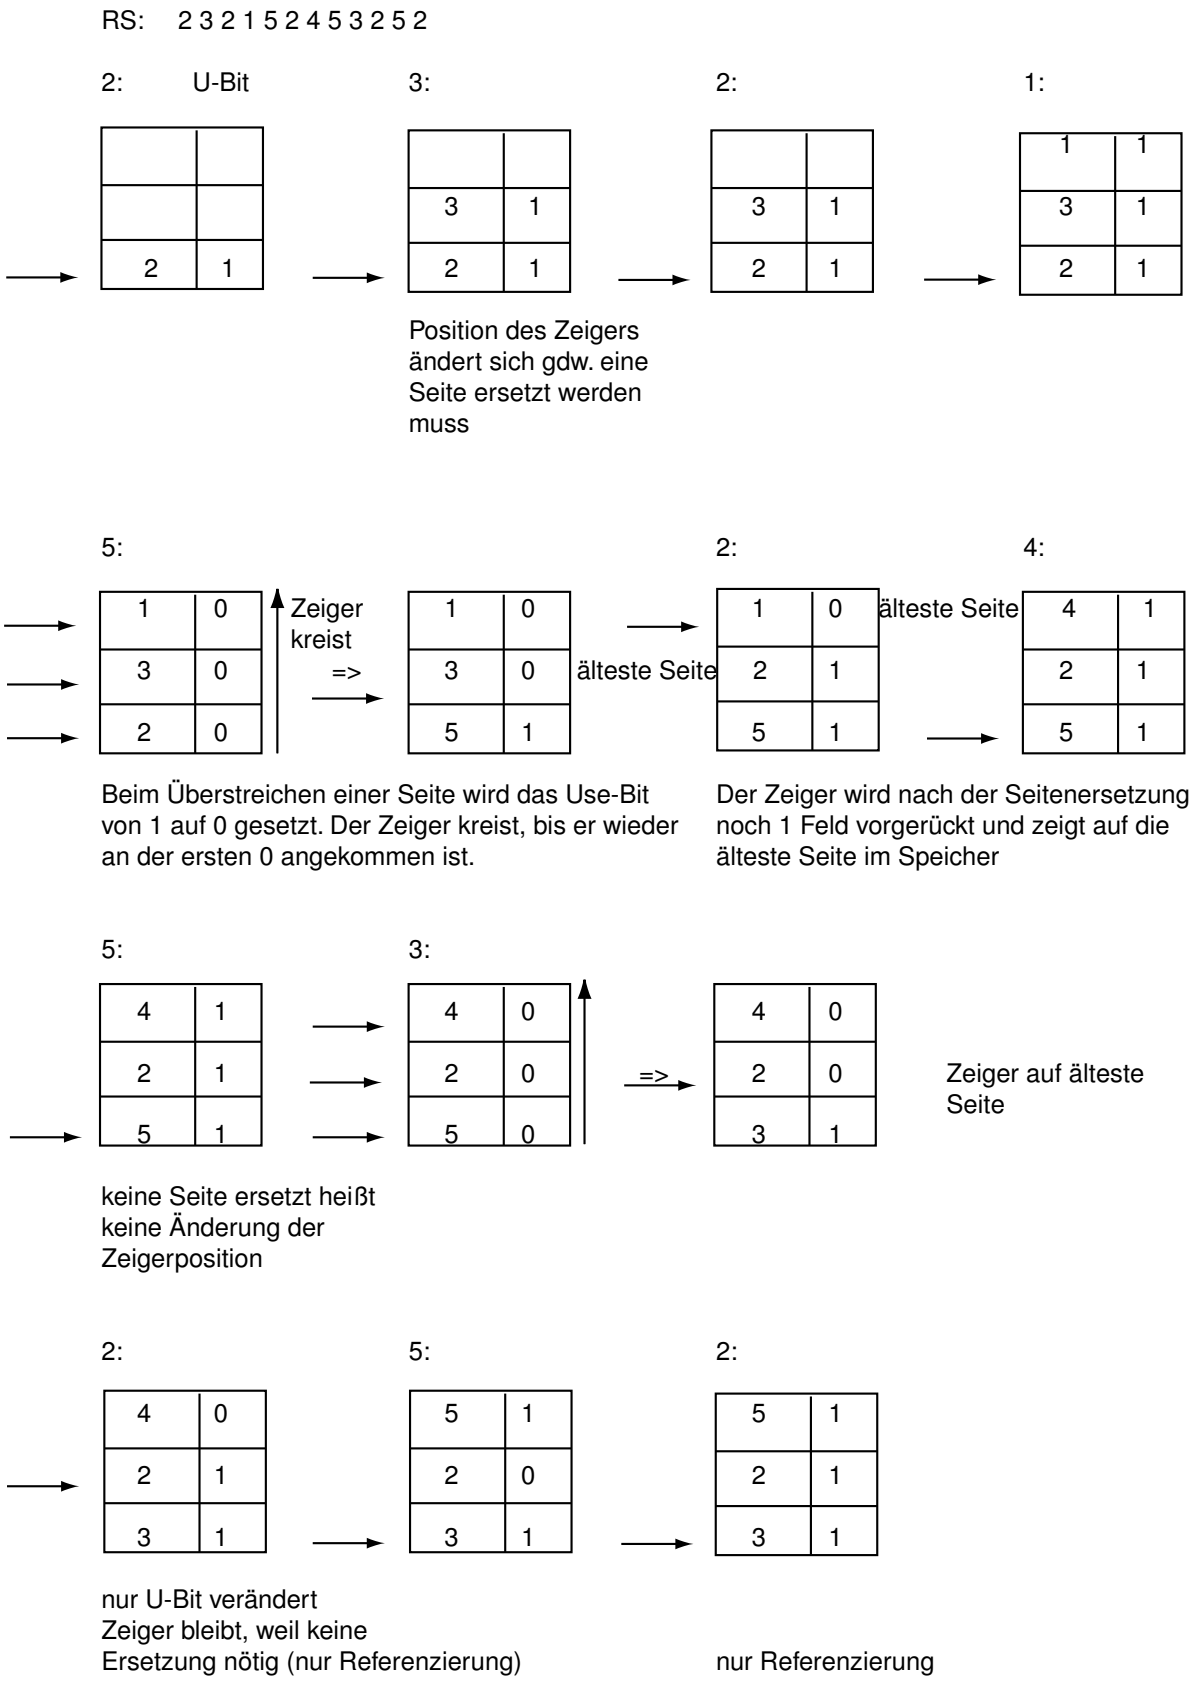

Abbildung 8.11: Beispiel zur Clock-Strategie

Beispiel:

2 3 2 1* 5* 2* 4 5* 3 2* 5 2											
			1*	1	1	4*	4*	4	4	5*	5*
	3*	3*	3*	3	2*	2*	2*	2	2*	2	2*
2*	2*	2*	2*	5*	5*	5*	5*	3*	3*	3*	3*

Diese Strategie führt zu 5 Seitenfehlern (Seitenfehler bis alle Frames belegt sind, werden hier nicht berücksichtigt).

8.4.3 Minimierung von Seitenfehlern

Auf den ersten Blick könnte man annehmen, dass die Anzahl der Seitenfehler sinkt, wenn man die Anzahl der Rahmen im Hauptspeicher bei gleicher Rahmengröße (also den vorhandenen physischen Speicher) erhöht.
Im Jahr 1969 wurde jedoch ein Gegenbeispiel gefunden, das bei der Verwendung von FIFO als Seitenaustauschalgorithmus bei vier Rahmen mehr Seitenfehler verursacht als bei drei (**Belady's Anomalie**).

Belady's Anomalie Tabelle 8.2 veranschaulicht ein Beispiel dieser Anomalie. Bei vier Seitenrahmen treten 10 Seitenfehler auf, bei drei Seitenrahmen nur 9. Im Allgemeinen würde man erwarten, dass bei Hinzunahme von Frames die Anzahl der Seitenfehler abnimmt bzw. konstant bleibt. Alle Algorithmen, die diese Eigenschaft garantieren, werden auch als **Stackalgorithmen** bezeichnet (z.B. LRU). FIFO ist z.B. kein Stack-Algorithmus (Beweis durch Belady's Anomalie).

Reference String	0	1	2	3	0	1	4	0	1	2	3	4
Jüngste Seite	0	1	2	3	0	1	4	4	4	2	3	3
		0	1	2	3	0	1	1	1	4	2	2
Älteste Seite			0	1	2	3	0	0	0	1	4	4
Page Fault	(P)	(P)	(P)	P	P	P	P			P	P	

Reference String	0	1	2	3	0	1	4	0	1	2	3	4
Jüngste Seite	0	1	2	3	3	3	4	0	1	2	3	4
		0	1	2	2	2	3	4	0	1	2	3
			0	1	1	1	2	3	4	0	1	2
Älteste Seite				0	0	0	1	2	3	4	0	1
Page Fault	(P)	(P)	(P)	(P)			P	P	P	P	P	P

Tabelle 8.2: Belady's Anomalie

Diese Beobachtung nötigt zu einer genaueren Betrachtung des Verhaltens von Paging-Systemen.

Definition 8.5 (Reference String)**.** Jeder Prozess erzeugt eine eindeutige Folge von Speicherzugriffen während seiner Ausführung, die in eine eindeutige Folge von Zugriffen auf

bestimmte Speicherseiten umgesetzt werden kann. Diese Folge wird als **Reference String** bezeichnet.

Ein Paging-System kann eindeutig durch die folgenden drei Eigenschaften beschrieben werden:

1. den Reference String des gerade ausgeführten Prozesses,
2. den Seitenaustauschalgorithmus und
3. die Anzahl der Seitenrahmen m, die im Speicher gehalten werden.

Mit Hilfe dieser Definitionen kann man eine abstrakte Maschine wie folgt definieren: Sei M ein Feld (eine Menge), das den Status des Speichers beschreibe, dann ist die Anzahl n der Elemente von M genauso groß wie die Anzahl der virtuellen Seiten des zugeordneten Prozesses. Das Feld M teilt sich in zwei Bereiche, der obere enthält m Einträge, nämlich die Seiten, die sich gerade im Speicher befinden, der untere enthält $n - m$ Seiten, nämlich diejenigen, die bereits einmal angesprochen wurden, jedoch wieder ausgelagert wurden und sich so nicht im Speicher befinden.
Zu Beginn ist M also leer, da noch keine Seiten angesprochen wurden und sich auch keine im Speicher befinden.

Beispiel 8.4 (Operationsweise)**.** *Angenommen als Seitenaustauschalgorithmus wird LRU verwendet und der virtuelle Adressraum hat 8 Seiten, während nur vier Seitenrahmen im physischen Speicher zur Verfügung stehen. Der zugehörige Prozess greift auf die Seiten in der folgenden Reihenfolge zu (Reference String):*

$$0\,2\,1\,3\,5\,4\,6\,3\,7\,4\,7\,3\,3\,5\,5\,3\,1\,1\,7\,2\,3\,4\,1.$$

Dann ergibt sich für die Ausführung der Maschine das Bild in Tabelle 8.3.
Wenn also auf eine Seite zugegriffen wird, wird sie an die Spitze der Einträge von M verschoben. War sie bereits in M (also im Speicher), so werden alle Seiten, die bisher höher standen, um eins nach unten geschoben, war sie bisher nicht im Speicher, so wird die tiefste Seite aus M nach unten bewegt (ausgelagert).

Dieses Beispiel ist dank der Verwendung von LRU als Seitenaustauschalgorithmus zu einer Klasse von besonders interessanten Algorithmen gehörig:
Für alle Seitenaustauschalgorithmen dieser Klasse gilt

$$M(m, r) \subset M(m + 1, r), \forall r \geq m,$$

RS	0	2	1	3	5	4	6	3	7	4	7	3	3	5	5	3	1	1	1	7	2	3	4	1
		0	2	1	3	5	4	6	3	7	4	7	7	3	3	5	3	3	3	1	7	2	3	4
			0	2	1	3	5	4	6	3	3	4	4	7	7	7	5	5	5	3	1	7	2	3
				0	2	1	3	5	4	6	6	6	6	4	4	4	7	7	7	5	3	1	7	2
					0	2	1	1	5	5	5	5	5	6	6	6	4	4	4	4	5	5	1	7
						0	2	2	1	1	1	1	1	1	1	1	6	6	6	6	4	4	5	5
							0	0	2	2	2	2	2	2	2	2	2	2	2	2	6	6	6	6
									0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
PF	P	P	P	P	P	P	P		P					P			P						P	
DS	∞	∞	∞	∞	∞	∞	∞	4	∞	4	2	3	1	5	1	2	6	1	1	4	7	4	6	5

Tabelle 8.3: Beispiel für Reference String

wobei M die eben erklärte abstrakte Maschine, m die Anzahl der Seitenrahmen und r die Indexposition im Reference String bezeichne, d.h. alle Seiten, die sich bei einem Speicher mit m Seitenrahmen nach r Speicherzugriffen im Speicher befinden, befinden sich auch bei einem Speicher mit $m+1$ Seitenrahmen nach r Speicherzugriffen im Speicher. Dadurch ist gewährleistet, dass bei einer Vergrößerung des physischen Speichers (Erhöhung der Anzahl der Seitenrahmen), die Anzahl der Seitenfehler niemals zunehmen kann. Algorithmen in dieser Klasse werden als **Stack-Algorithmen** bezeichnet. FIFO wäre zum Beispiel kein Stack-Algorithmus.

Beispiel 8.5. *Zum Zeitpunkt* t^r *habe unsere Speicherbelegung folgendes Aussehen:*
| *4* | *5* | *3* | *1* | *2* | *0* | | |

Diese Belegung entspricht Spalte 7 in 8.3. Wir definieren $M := 4,5,3,1$. *Sei* $n = 8$*, da der Prozess die Seiten* $0,1,\ldots,7$ *benutzt. Dabei bezeichnet der String* | *4* | *5* | *3* | *1* | *die Frames des gerade belegten Hauptspeichers HS' mit* $m = 4$ *und der String* | *2* | *0* | | | *den belegten Hintergrundspeicher HGS' mit* $n - m$ *Seiten. Wir zählen die Seitenaufrufe durch und nutzen dabei den Index r. Wir erhalten:*

$$\begin{aligned} r = 0 &\qquad M = \emptyset \\ r = 1 &\qquad M = 0 \\ r = 2 &\qquad M = 0,2 \\ &\vdots \\ r = 6 &\quad M = 0,2,1,3,5,4 \end{aligned}$$

Es gilt hier beispielsweise auch $M(4,r) = M(5,r)$ *und insbesondere* $M(4,r) \subset M(5,r)$.
M hängt also von r, m, dem RS und der verwendeten Strategie (z.B. LRU) ab. Eine Erhöhung der Framezahl im HS bedingt, dass zu einem bestimmten Zeitpunkt die gleichen Seiten im HS geladen sind wie bei weniger Frames, und zusätzlich noch weitere Frames.

Bemerkung 8.2. *Für* $r \leq m$ *gilt:* $M(m,r) \subseteq M(m+1,r)$ *und insbesondere* $M(m,r) = M(m+1,r)$. *Dieser Fall wird jedoch hier nicht betrachtet, da der Speicher nicht voll wäre und keine Seiten ausgetauscht werden müssten.*

Im Folgenden sollen nur noch Stack-Algorithmen betrachtet werden.

Distance String

Die Distanz einer Seite bei einem gewissen Aufruf gibt an, wieviele Frames der HS für diesen Prozess bereitstellen muss, damit kein Seitenfehler auftritt.
Bei Stack-Algorithmen ist es möglich und sinnvoll, den Reference String auf eine abstraktere Weise zu repräsentieren als durch die einfachen Seitennummern. Eine Seitenreferenz soll beschrieben werden durch die Entfernung der bisherigen Position der Seite im Stack von dessen Beginn, wobei für Seiten, auf die bisher noch nicht zugegriffen wurde, eine Distanz von ∞ angenommen wird.
Offensichtlich hängt der **Distance String** nicht nur vom Reference String, sondern auch vom Seitenaustauschalgorithmus ab.

Vorhersage der Anzahl von Seitenfehlern

Die voranstehenden Definitionen sind notwendig, um eine genaue Analyse der zu erwartenden Seitenfehler für einen bestimmten Prozess bei Verwendung eines bestimmten Seitenaustauschalgorithmus zu ermöglichen.
Das Ziel des Algorithmus ist es, bei einem Lauf über den Distance String die notwendigen Informationen zu sammeln, um vorhersagen zu können, wie viele Seitenfehler der Prozess bei n Seitenrahmen verursachen würde.
Man erhält – wie man leicht sieht – als Anzahl der Seitenfehler F_m bei einem vorgegebenen Distance String und m Seitenrahmen:

$$F_m = \sum_{k=m+1}^{n} C_k + C_\infty$$

$$F_0 = C_1 + C_2 + \ldots + C_\infty$$

C_k ist die Anzahl der Vorkommen von k im Distance String und C_∞ die Anzahl der Vorkommen von ∞.
Für den Reference String aus Beispiel 8.4 auf Seite 176 ergeben sich dann die Werte aus Tabelle 8.4 bei Verwendung von LRU.

	$C_1 = 4$	$C_2 = 2$	$C_3 = 1$	$C_4 = 4$	$C_5 = 2$	$C_6 = 2$	$C_7 = 1$	$C_\infty = 8$
$F_0 = 24$	$F_1 = 20$	$F_2 = 18$	$F_3 = 17$	$F_4 = 13$	$F_5 = 11$	$F_6 = 9$	$F_7 = 8$	$F_8 = 0$

Tabelle 8.4: Vorhersage von Seitenfehlern aus 8.3

Berechnung: $F_0 = C_1 + C_2 + \ldots + C_n + C_\infty$ $F_0 = 4 + 2 + 1 + 4 + 2 + 2 + 1 + 8 = 24$
$F_1 = C_2 + \ldots + C_n + C_\infty$ $F_1 = 2 + 1 + 4 + 2 + 2 + 1 + 8 = 20$
Oder:
$F_1 = F_0 - C_1 = 24 - 4 = 20$

Das bedeutet, dass man bei einem Frame und vorgegebenen Distance String 20 Seitenfehler erhält.
$F_2 = C_3 + \ldots + C_n + C_\infty$ $F_2 = 1 + 4 + 2 + 2 + 1 + 8 = 18$
Oder:
$F_2 = F_1 - C_2 = F_0 - C_1 - C2 = 24 - 4 - 2 = 18$

Das bedeutet man erhält bei zwei Frames und vorgegebenen Distance String 18 Seitenfehler.

8.4.4 Working Set Strategie

Bisher haben wir Situationen betrachtet, in denen jedem Prozess eine konstante Anzahl von Frames zugeordnet wurde. Jetzt soll die Anzahl von Frames, die ein Prozess über seine Lebenszeit belegen kann, variieren können. Die Working Set Strategie ist im Vergleich zu den anderen Strategien dynamisch und variant - etwa im Gegensatz zur sehr statischen LRU. Wir

betrachten zunächst die sogenannte Lifetime-Funktion $L(m)$. Diese gibt die mittlere Zeit zwischen aufeinanderfolgenden Seitenfehlern in Abhängigkeit von der zugeordneten Rahmenzahl m an.
Gewöhnlich steigt L mit wachsendem m monoton an. Und zwar in folgendem Sinne: Je mehr Frames einem Prozess im Hauptspeicher zur Verfügung stehen, desto seltener werden Seitenfehler, und desto mehr Zeit vergeht daher im Mittel zwischen 2 Seitenfehlern.
$L(M)$ ist natürlich von den jeweiligen Prozessen abhängig, in der Regel hat $L(m)$ aber folgende Form:

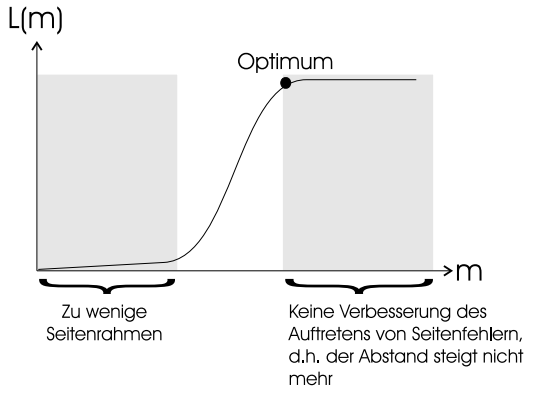

Abbildung 8.12: Lifetime-Function L(m)

Beispiel 8.6. *Bezeichne im Folgenden $\bar{t_i}$ den mittleren Zeitabstand zwischen 2 Seitenfehlern. Es sollen im Sekundentakt Seiten gebraucht werden. Man erhält folgenden Zusammenhang:*

$$
\begin{aligned}
F_0 = 24 \qquad & \bar{t_0} = 1\text{Sek.} \\
F_1 = 20 \qquad & \bar{t_1} = 24\text{Sek.}/20\text{Pagefaults} = 1,25\text{Sek.} \\
F_2 = 18 \qquad & \bar{t_2} = 24\text{Sek.}/18\text{Pagefaults} \approx 1,2551\text{Sek.} \\
& \bar{t_3} \approx 1,5\text{Sek.} \\
& \bar{t_4} \approx 1,8\text{Sek.} \\
& \bar{t_5} \approx 2,2\text{Sek.} \\
& \bar{t_6} \approx 2,6\text{Sek.} \\
& \bar{t_7} \approx 3,0\text{Sek.} \\
& \bar{t_8} \approx 3,0\text{Sek.} \\
& \bar{t_9} \approx \bar{t_1}0 \approx \ldots \approx 3,0\text{Sek.}
\end{aligned}
$$

D.h. bei wenigen zur Verfügung stehenden Frames kommt es quasi ständig zu Seitenfehlern, dann bringt jeder zusätzliche Frame eine deutliche Verbesserung, d.h. eine Verlängerung der Lifetime mit sich, bis irgendwann ein Sättigungsbereich auftritt.
Zur Sättigung der Lifetime-Funktion ist der sogenannte Working Set von Bedeutung. Darunter versteht man die Menge der in unmittelbarer Vergangenheit benötigten Seiten.

Dem Ansatz liegen folgende Annahmen zugrunde:

– Die jüngste Vergangenheit ist eng mit der unmittelbaren Zukunft korreliert.

- Ein Prozess, der bislang viele aktive Seiten hatte, braucht diese mit einer gewissen Wahrscheinlichkeit auch in Zukunft.
- Über weitere Bereiche verhalten sich Prozesse "lokal", d.h. Seiten, die erst vor kurzem referenziert wurden, sind in Zukunft wahrscheinlicher als solche, deren letzter Zugriff schon länger zurückliegt.

Diese Annahmen sind allerdings nicht allgemeingültig - z.B. wenn ein Prozess in einen völlig neuen Abschnitt eintritt, dann sind Ausnahmen durchaus denkbar.

Definition 8.6. Sei $r_1 r_2 ... r_T$ der Referenzstring eines Prozesses, d.h. die zugehörige Folge von Seitenzugriffen.
Dann ist der Working Set $W(t, h)$ dieses Prozesses zur Zeit t unter einem Rückwärtsfenster der Größe h definiert als:

$$W(t, h) := \bigcup_{i=t-h+1}^{t} r_i$$

D.h. $W(t, h)$ ist die Menge der Seiten, die bei den letzten h Zugriffen mindestens einmal referenziert wurden.

Folgendes Beispiel veranschaulicht das Working Set eines Reference String zum Zeitpunkt x bzw t mit einem Rückwärtsfenster $h = 4$

...	r_1	r_2	...	r_{x-3}	r_{x-2}	r_{x-1}	r_x	...	r_{t-3}	r_{t-2}	r_{t-1}	r_t	...	r_T	...
				Fenster zur Zeit x					Fenster zur Zeit t						

Sei $w(t, h)$ die Mächtigkeit von $W(t, h)$. Dann steigt (trivialerweise) $w(t, h)$ mit wachsendem h.
Außerdem haben "lokale" Prozesse einen relativ kleinen Working Set, was bei nicht-lokalen Prozessen nicht der Fall ist.
Entscheidend ist immer das h - ist es zu klein gewählt, dann sind nicht alle aktiven Seiten im Working Set, ist es zu groß, dann befinden sich viele inaktive Seiten darin.

Beispiel 8.7. *Gegeben sei folgender Referenzstring:*

r_1	r_2	r_3	r_4	r_5	r_6	r_7	r_8	r_9	r_{10}	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}	r_{16}	r_{17}	r_{18}	r_{19}	r_{20}
0	*2*	*1*	*3*	*5*	*4*	*6*	*3*	*7*	*4*	*7*	*3*	*3*	*5*	*5*	*3*	*1*	*1*	*1*	*7*

$W(t, h)$ habe $w(t, h)$ Elemente. Die Strategie basiert auf einem fest vorgegebenen h, z.B. $h = 8$. Dann kann zu jedem r_i ein Working Set berechnet werden:
$W(1, 8) = 0$ (negative Indizes sind nicht definiert! Geht man von der Stelle r_1 8 Stellen nach links, so erhält man 0 und 7 mal die leere Menge $\emptyset$ - also eigentlich: $W(1, 8) = \emptyset, \emptyset, \emptyset, \emptyset, \emptyset, \emptyset, \emptyset, 0$.)
Aušerdem ist $w(1, 8) = 1$.
Wir erhalten weiter:

$W(2,8) = 0,2$, $w(2,8) = 2$
$W(3,8) = 0,1,2$, $w(3,8) = 3$
$W(4,8) = 0,1,2,3$, $w(4,8) = 4$
$W(2,8) = 0,2$, $w(2,8) = 2$
...
Die Mächtigkeit von w wächst zunächst und stagniert dann, wenn alle Pages einmal schon erfasst worden sind.
Es ergibt sich für $r = 9$ *folgender Working Set, indem man von der Stelle* r_9 *8 Stellen rückwärts zählt und alle vorkommenden Werte nur einmal berücksichtigt:*
$W(9,8) = 1,2,3,4,5,6,7$ *und somit* $w(9,8) = 7$.
Für $r = 19$ *ergibt sich dagegen:*
$W(19,8) = 1,3,5$ *und somit nur* $w(19,8) = 3$.

Bemerkung 8.3. *Die Working Set Strategie wirft folgende Probleme auf:*

1. *Die Anzahl der Frames variiert pro Prozess und damit auch bezogen auf alle Prozese insgesamt.* $\Rightarrow$*Es kann passieren, dass mehrere Frames gebraucht werden als vorhanden sind, d.h. das System ist überlastet und es müssen Prozesse suspendiert werden.*

2. *Es stellt sich die Frage, wie der Parameter* h *zu wählen ist. Eine Möglichkeit ist die Betrachtung der Lifetime-Funktion* $L(m)$ *und die Ermittlung/Wahl des Wertes* h *in Relation zu* m.

Die Working Set Strategie soll nun wie folgt zusammengefaßt werden:

1. h "gut" einstellen - hierzu gibt es das Knie Kriterium (vgl. Punkt "Optimum" in Abbildung 8.12) oder das 50% Kriterium (bezogen auf Ersetzung von Seiten) als möglichen Algorithmus.

2. Jedem aktiven Prozess so viele Frames zuteilen, wie seinem aktuellen Working Set $W(t,h)$ entsprechen. Wird zusätzlicher Speicherplatz frei, so kann gegebenenfalls ein neuer Prozess aktiviert werden.
   Umgekehrt muß ein Prozess stillgelegt werden, wenn die Summe der Größen aller Working Sets zu einem bestimmten Zeitpunkt zu hoch ist.

3. Bei Seitenfehlern sollten solche Seiten ersetzt werden, die aktuell zu keinem Working Set gehören. Dadurch kann die Anzahl der Frames eines Prozesses variabel sein, d.h. von Zeit zu Zeit bei einem betrachteten Prozess schwanken.
   (Ein Prozess stiehlt sich ein - nicht benutztes - Frame eines anderen Prozesses)

4. Ist keine ersetzbare Seite vorhanden, d.h. jede Seite also im Working Set eines bestimmten Prozesses, so wäre eine Seitenersetzung schädlich, da dadurch weitere Seitenfehler hervorgerufen werden würden. Man kann davon ausgehen, dass das System momentan überlastet ist - der anfordernde Prozess sollte deshalb stillgelegt werden.
   Eine Reaktivierung ist erst sinnvoll, wenn sich die Verhältnisse gebessert haben.

5. Die Working Set Strategie eignet sich vor allem bei starker Lokalität.

8.5 Segmentierungsstrategien

Es gibt auch Seitenaustauschstrategien, die nicht auf einer Einteilung der Speicher in Frames und Pages basieren, sondern eine dynamische Speicherpartitionierung vornehmen. Bei aufeinanderfolgenden Speicherallokationen und -deallokationen können “Löcher” oder Fragmente freien Speichers entstehen, wodurch die Größe, des maximal an einem Stück zu allozierenden Blockes immer mehr abnimmt. Um dies zu vermeiden, wird eine sogenannte **Speicherverdichtung** durchgeführt, wozu allerdings ein relativ großer Zeitaufwand notwendig ist. Daher benötigt man Strategien, wie man in einer vorliegenden, fragmentierten Speicherstruktur mit gewissen Lücken neue Speichersegmente allokieren kann, sog. **Segmentierungsstrategien**.

1. **First Fit(FF):** Plaziere das Segment in die erste passende Lücke.
2. **Best Fit (BF):** Plaziere das Segment in die kleinste passende Lücke.
3. **Rotating First Fit (RFF):** Plazierung wie bei First Fit, jedoch wird von der Position der vorherigen Plazierung, d.h. dem Ende der benutzten Lücke ausgehend, die nächste Lücke gesucht. Dieses Verfahren kann sowohl von vorne als auch von hinten begonnen werden, wie man auch in Abbildung 8.13 sehen kann.

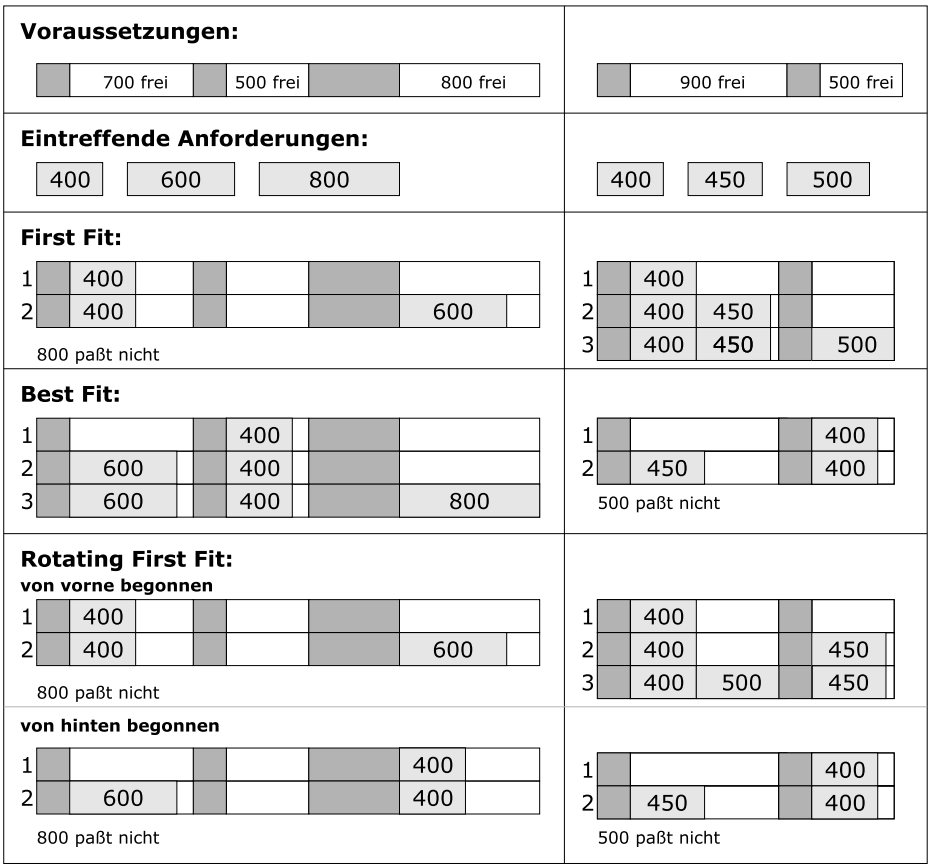

Abbildung 8.13: Beispiele für verschiedene Segmentierungstrategien

Während bei First Fit die Anzahl der Lücken schnell sehr groß wird, so dass ein hoher Speicherverlust entsteht, und bei Best Fit der Fall auftreten kann, dass der verbleibende Rest der Lücken extrem klein wird und später praktisch nicht mehr verwendet werden kann, wurde simulativ gezeigt, dass Rotating First Fit in der Regel am besten abschneidet, wobei der Anfangspunkt unerheblich ist.

9

E/A Verwaltung

- E/A Geräte
- E/A Techniken

Inhaltsangabe

Wegen der Vielfalt der E/A Geräte ist es sehr schwierig eine allgemein gültige und effektive Ein/Ausgabe zu konzipieren.

9.1 Klassifizierung von E/A-Geräten

Externe Geräte für die Ein-/Ausgabe können in prinzipiell 3 Kategorien eingeordnet werden:

Menschen - lesbare Geräte (human-computer interface)
Diese Geräte sind geeignet, mit dem Nutzer zu kommunizieren. In der Forschung beschäftigt man sich mit der Mensch-Maschine-Kommunikation (Oberflächendesign, Bedienungselemente etc.).
(z.B. Monitor, Tastatur, Maus, Drucker, ...)

Maschinen - lesbare Geräte
Sind geeignet, mit elektronischer Ausrüstung zu kommunizieren.
(z.B. Band und Plattenspeicher, Sensoren, ...)

Kommunikationsgeräte
Sind geeignet, mit entfernten Geräten zu kommunizieren.
(z.B. Modems, Netzwerkkarten, ...)

Die einzelnen Geräte können sich dabei noch einmal in verschiedenen Merkmalen unterscheiden:

- Datenrate
- Anwendung
- Komplexität der Kontrolle
- Arten des Datentransfer und Darstellung
- Fehlerbehandlung

9.2 E/A Techniken

Prinzipiell gibt es 3 verschiedene E/A Techniken:

Programmierte E/A
Durch einen Prozess wird im Prozessor ein E/A-Befehl ausgeführt.

Zum Beispiel wartet der Prozess dann im Busy-Waiting-Modus darauf, daß die Operation abgeschlossen ist, bevor er selber seine Abarbeitung weiter ausführen kann.
Dieses veraltete Konzept wurde später verbessert.

Unterbrechungsgesteuerte E/A
Ein Prozess ruft im Prozessor wieder einen E/A-Befehl auf. Der Prozess setzt jedoch die Abarbeitung der nachfolgenden Operationen fort. Ist der E/A-Befehl in seiner Ausführung beendet, so löst das E/A-Modul eine Unterbrechung aus.

Direct Memory Access (DMA)
Ein DMA-Modul kontrolliert den Datenaustausch zwischen dem Hauptspeicher und einem E/A Modul. Dabei sendet der Prozessor eine Anfrage für den Transfer eines Blockes von Daten an das DMA-Modul und wird erst dann unterbrochen, wenn der Block übertragen wird.

Zusammenfassung:

	keine Unterbrechung	mit Unterbrechung
E/A Speichertransfer durch den Prozessor	Programmierte E/A	Unterbrechungs–gesteuerte E/A
Direkter E/A Speichertransfer	—	**DMA**

Historische Entwicklung

1. direkte Kontrolle des Prozesses über die E/A.
2. Hinzufügen von E/A Modulen.
3. Einbeziehung von Unterbrechungen und damit das nicht blockierende Weiterarbeiten des Prozesses.
4. Übergabe der Kontrolle an ein DMA-Modul, welches schließlich ein seperater Prozessor wird.
5. Integration von lokalem Speicher in das DMA-Modul.

D.h. der Prozessor ist im Laufe der Entwicklung immer weniger mit der E/A beschäftigt.

Begriffe in Zusammenhang mit E/A Modulen

E/A Kanal für ein fortgeschrittenes E/A Modul (ab Schritt 4.), welches bereits die Funktionalität eines eigenständigen Prozessors besitzt.

E/A Prozessor ist ein E/A Modul mit zusätzlichem lokalen Speicher

Realisierung des DMA

Zur Realisierung gibt es verschiedene Möglichkeiten:

1. Single Bus Detached DMA

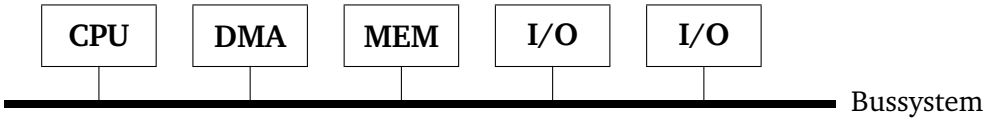

Alle Module nutzen das Bussystem gemeinsam. Das DMA-Modul kann als stellvertretender Prozessor angesehen werden, es erledigt den Datentransport zwischen den E/A-Modulen und dem Speicher.

$\Longrightarrow$ Dieses Prinzip ist einfach und billig, aber nicht besonders effizient, denn jeder Transport benötigt 2 Buszyklen und es besteht die Gefahr eines von Neumannsch'en Flaschenhalses.

2. Single Bus Integrate DMA

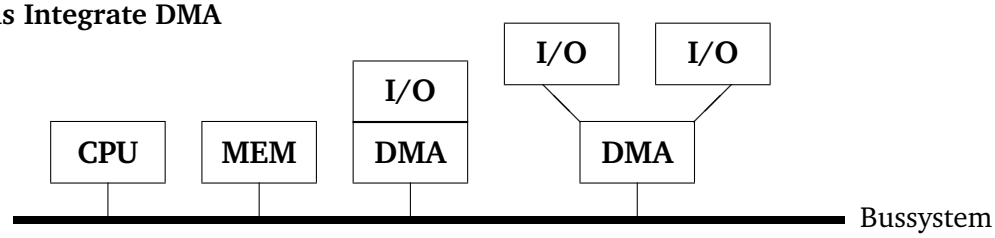

Einige der Buszyklen können eingespart werden. Die DMA-Logik kann dabei entweder ein Bestandteil eines E/A-Modules sein, oder ein getrenntes Modul, welches ein oder mehrere E/A-Module kontrolliert.
Die Last auf dem Systembus wird gegenüber Single Bus Detached-DMA reduziert.

3. E/A Bus

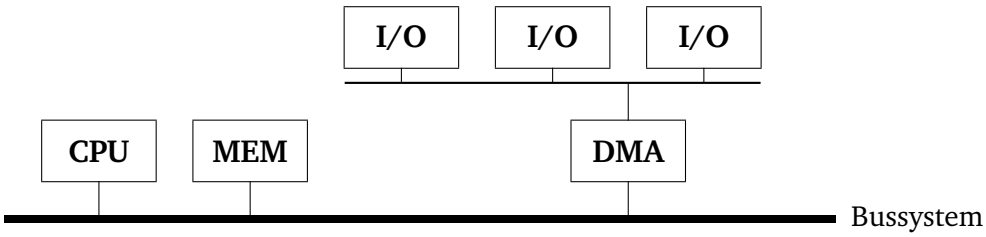

Dieses Konzept ist eine nochmalige Erweiterung. E/A-Module werden durch einen E/A-Bus miteinander verbunden. Dadurch hat das DMA-Modul nur noch eine Eingabeschnittstelle. Die Anzahl der E/A-Komponenten ist leicht erweiterbar.
Die Last auf dem Systembus wird wiederum reduziert.

Teil V

Interprozeßkommunikation

10

Lokale Interprozeßkommunikation

- Grundlagen des Nachrichtenaustauschs
- Pipes
- FIFOs
- Stream Pipes
- Sockets

Inhaltsangabe

Motivation: Um in einem Betriebssystem die Aktionen mehrerer Prozesse zu koordienieren und ein gemeinsames Arbeitsziel zu erreichen, ist es wichtig, daß Prozesse miteinander kommunizieren. Erfolgt diese Kommunikation über Prozessgrenzen hinweg, d.h. zwischen zwei oder mehreren Prozessen, so spricht man von Interprozesskommunikation (interprocess communication – IPC).

Historie: In klassischen Betriebsystemen wurde die Interprozeßkommunikation stark vernachlässigt. Hierzu soll ein herkömmliches Einprozessorsystem mit modernen verteilten Systemen verglichen werden. Eine Interprozesskommunikation setzt die Existenz von *gemeinsam genutztem Speicher* voraus. Ein typisches Beispiel ist das *Erzeuger/Verbraucher-Problem*, wobei ein Prozess in einen gemeinsam genutzten Puffer schreibt und ein anderer Prozess daraus liest. Auch grundlegende Formen der Synchronisation, z.B. mittels Semaphoren, machen es erforderlich, daß Daten, wie Semaphorenvariablen gemeinsam genutzt werden. In verteilten Systemen gibt es per Definition keinen gemeinsam genutzten Speicher. Damit muss die gesamte Interprozesskommunikation neu überdacht werden, um auch durch mehrere Prozesse ein gemeinsames Arbeitsziel erreichen zu können. Das heißt, erst der Zwang auch über Rechnergrenzen hinweg in Netzen die Arbeit zu koordinieren, führte dazu, auch auf einem einzelnen Rechner die Interprozesskommunikation als *Betriebssystemdienst* zu ermöglichen.

10.1 Grundlagen des Nachrichtenaustauschs

Beim Nachrichtenaustausch unterscheidet man drei verschiedene Arten der Verbindung:

- Unicast
- Multicast
- Broadcast

Unicast wird in der Literatur auch als Punkt-zu-Punkt Verbindung bezeichnet, Multicast als Punkt-zu-Mehrpunkt und Broadcast als Rundsendung. Diese Verbindungen können wie in Abbildung 10.1 veranschaulicht werden.

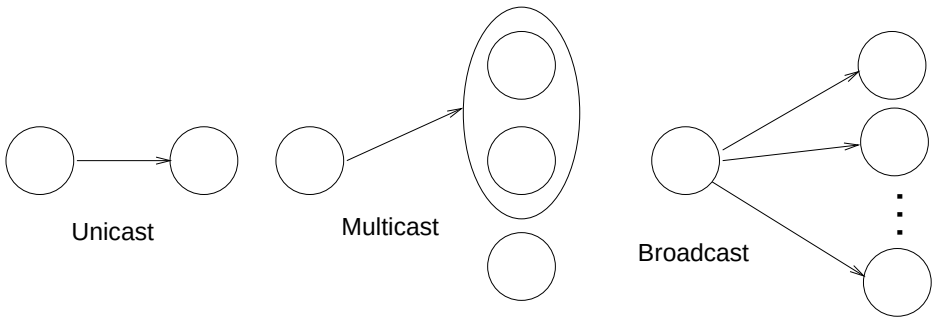

Abbildung 10.1: Grundlegende Verbindungstypen

Dabei lassen sich einzelne Verbindungsarten mittels anderer implementieren, z.B. kann eine Punkt-zu-Mehrpunkt Verbindung auf mehrere Punkt-zu-Punkt Verbindungen zurückgeführt

werden, oder eine Broadcastverbindung mit nur einem Empfänger als Unicastverbindung realisiert werden.
Bei der Implementierung unterscheidet man:

– *verbindungsorientierte Kommunikation*

– *verbindungslose Kommunikation*

Prinzipiell kann man sich unter einer *verbindungslosen Kommunikation* vorstellen, daß ein Prozess Daten an einen anderen Prozess sendet, ohne mit diesem eine Vereinbarung hinsichtlich des Kommunikationsablaufs zu treffen. Dieser Fall ist z.B. beim *IP-Protokoll* des Internets vorhanden.
Bei der *verbindungsorientierten Kommunikation* wird erst eine Vereinbarung mit dem Partner getroffen, d.h. festgestellt, ob der Empfänger existiert und bereit ist, die Verbindung einzugehen. Nach dem Aufbau der Verbindung kann der Nachrichtenaustausch erfolgen. Danach wird die Verbindung wieder abgebaut. Dieser Fall ist z.B. beim Telefonieren oder beim TCP gegeben.
Da der Aufwand für den Aufbau und den Unterhalt einer derartigen Verbindung ziemlich groß ist, wird der moderne Nachrichtenaustausch – bei dem es in der Regel auch nicht so sehr auf Qualität ankommt, sondern der oft einfach nur billig sein soll – über verbindungslose Kommunikation realisiert.

Wie wird eine Kommunikation zwischen zwei Prozessen realisiert? Implementierungstechnisch ist es möglich, Kanäle zwischen zwei Prozessen zu erzeugen, in die der eine Prozess einen Strom von Bytes schreiben kann, die der andere Prozess dann lesen kann. Diese Kanäle werden als **Pipes** bezeichnet, d.h. bei dieser Form der Kommunikation werden Daten aus einem Prozess in den Datenbereich eines anderen Prozesses kopiert. Über den Kanal werden die Daten in den Zieldatenbereich kopiert. Man sagt auch, sie werden über den Kanal transportiert. Zur Realisierung des Transports dienen zwei Operationen:

– `send (Kanal, Quelldaten),`

– `receive (Kanal, Zieldatenbereich)`

Der Prozess, der die `send`-Operation aufruft, nennt man auch sendenden Prozess. Der Prozess, der die `receive`-Operation aufruft, heißt auch empfangender Prozess. Je nachdem, ob bzw. wie sendender und empfangender Prozess zusammenarbeiten, entstehen verschiedene Kommunikationsmuster. Ist für den sendenden Prozess der Zeitpunkt der Abholung der Daten und umgekehrt für den empfangenden Prozess der Zeitpunkt des Empfangs der Daten unerheblich, so spricht man von einer *asynchronen Kommunikation*.
Bei der *asynchronen Kommunikation* kann es z.B. vorkommen, daß der sendende Prozess Daten abschickt und der Zieldatenbereich beim empfangenden Prozß noch gar nicht bekannt ist. Dann werden die Daten oder der Name des Quelldatenbereichs im Kanal zwischengespeichert, bis eine `receive`-Operation aufgerufen wurde, wie man auch in Abbildung 10.2 sehen kann.
Erfolgt umgekehrt ein `receive` ohne vorheriges `send` wie in Abbildung 10.3, so muß im Kanal der Name des Zieldatenbereichs für den späteren Transport zwischengespeichert werden.
Die Alternative dazu besteht in der *synchronen Kommunikation*. Dabei weiß der Sender in der Regel, ob Daten beim Empfänger erwartet werden, und der Empfänger weiß, daß Daten

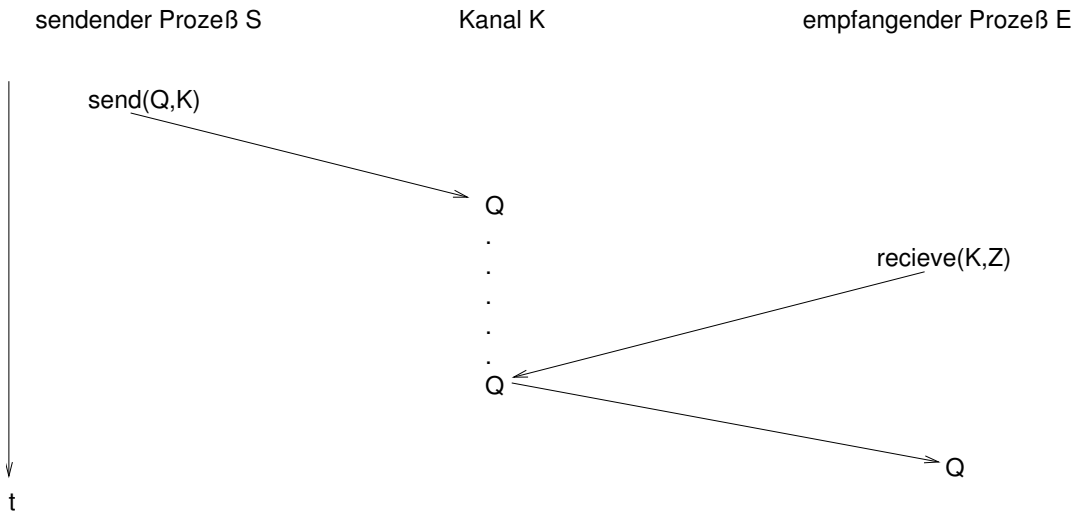

Abbildung 10.2: Send–Receive-Kommunikation (asynchron)

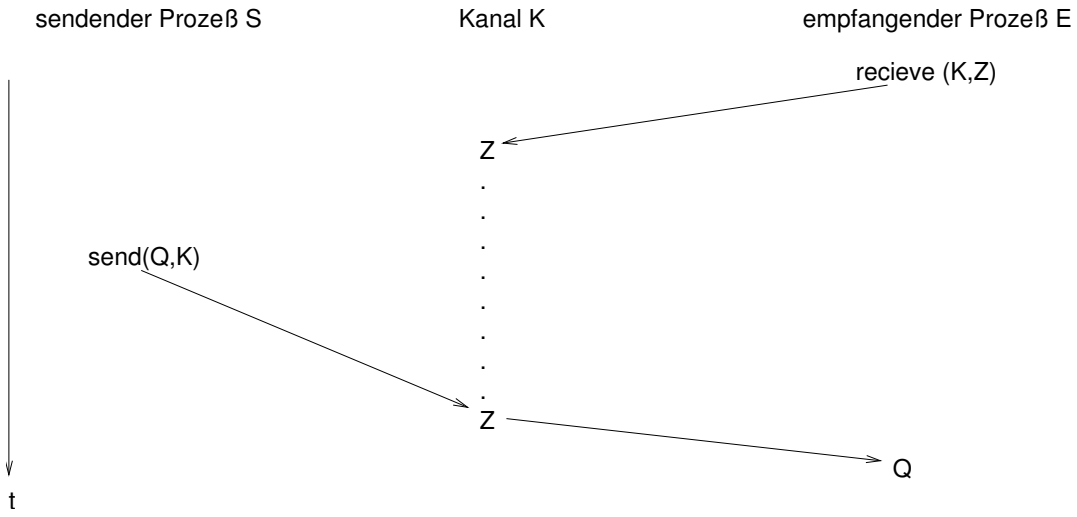

Abbildung 10.3: Receive–Send-Kommunikation (asynchron)

schon für ihn vorliegen, siehe auch Abbildung 10.4. Diese *synchrone Kommunikation* geht also von einer zeitlichen Abstimmung zwischen dem Sender und Empfänger aus. Zum Teil wird diese Kommunikationsbeziehung auch als Rendevouz bezeichnet.

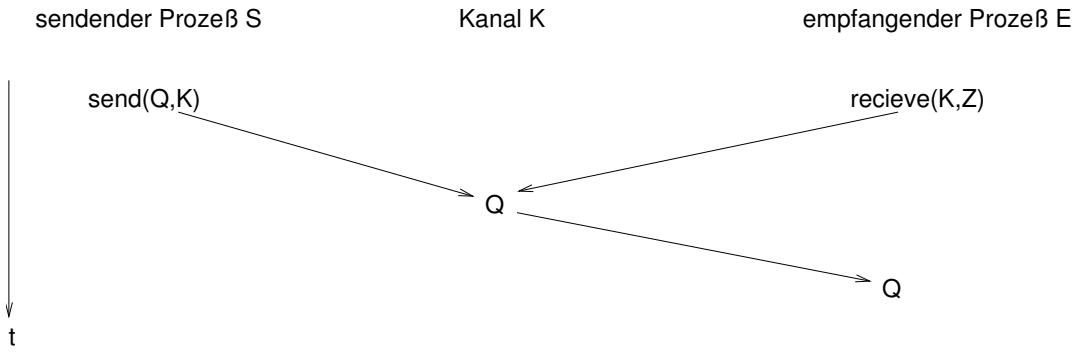

Abbildung 10.4: Synchrone Kommunikation

Eine Vielzahl verschiedener UNIX-Versionen führte in den fünfziger Jahren dazu, daß große Anstrengungen unternommen wurden, um Standards zu schaffen. An diese sollten sich die einzelnen UNIX-Varianten halten. In diesem Zusammenhang sind der **IEEE-POSIX-Standard** und der **X/Open Portability Guide (XPG)** von Bedeutung. Daneben sind heute aber auch die Implementierungen *System V Release 4 (SVR4)*, *Berkley Software Distribution (BSD)-UNIX* und *Linux* sehr weit verbreitet. Im folgenden soll nun betrachtet werden, welche IPC-Arten in den unterschiedlichen Systemen Verwendung finden.

	POSIX.1	XPG3	SVR4	BSD
Pipes (halbduplex)	X	X	X	X
FIFOs (named Pipes)	X	X	X	X
Stream Pipes			X	X
Named Stream Pipes			X	X
Message Queues		X	X	
Semaphore		X	X	
Shared Memory		X	X	
Sockets			X	X
streams			X	

10.2 Pipes

Die Interprozesskommunikation benutzt seit den ältesten Versionen von UNIX einen speziellen gepufferten Kanal – eine Pipe. Dies war die erste Form der Interprozesskommunikation, heute wird sie von allen UNIX-Systemen angeboten. Zunächst soll ein Beispiel betrachtet werden, bei dem es Sinn macht, Daten zwischen Prozessen weiterzureichen.

Beispiel 10.1.

cat: *sei ein Programm, das mehrere Dateien aneinanderhängt,*
pr: *sei ein Programm, das einen Text formatiert,* *Durch* `cat Text1 Text2 | pr | lpr` *werden die Texte Text1 und Text2 aneinandergehängt, formatiert und ausgedruckt. Der Interpreter, dem der Befehl übergeben wird, startet dazu die drei Programme als drei eigene Prozesse, wobei das Zeichen "|" ein Umlenken der Ausgabe des einen Programms in die Eingabe des anderen veranlaßt – und somit die Pipe realisiert. Im Mehrprozessorsystem können die drei Prozesse echt parallel ablaufen, auf einem Einprozessorsystem durch das Scheduling bedingt, quasi parallel.*
lpr: *sei ein Programm, das einen Text ausdruckt.*

Der Übergabemechanismus aus dem Beispiel, der Daten von einem Programm zum nächsten übergibt, wird jeweils durch eine Pipe realisiert. Im folgenden soll betrachtet werden, wie ein Kommunikationskanal funktioniert. Klassische Pipes besitzen grundsätzlich zwei Eigenschaften:

– Pipes können nur zwischen Prozessen eingerichtet werden, die einen gemeinsamen Vorfahren, d.h. Eltern-, Großelternprozeß etc. haben. Demzufolge können sie nicht zwischen Prozessen eingerichtet werden, die unterschiedliche Elternprozesse haben. Das Prinzip basiert darauf, daß eine Pipe von einem Elternprozess eingerichtet wird, der mittels, –Systemaufruf – `fork`, einen Kindprozess kreiert. Dieser Kindprozeß erbt die Pipe, so daß zwischen Eltern- und Kindprozeß eine Kommunikation möglich ist.

– Pipes sind nur halbduplex, d.h. Daten können nur in eine Richtung fließen. Das Prinzip besteht darin, daß ein Prozess, der eine Pipe zum Schreiben eingerichtet hat, in diese nur schreiben darf, während der Prozess auf der anderen Pipe-Seite nur aus der Pipe lesen kann. Soll die Kommunikation auch in umgekehrter Form stattfinden, so muß eine zweite Pipe in inverser Richtung etabliert werden.

Es gibt sogenannte *Stream Pipes*, die diese beiden Einschränkungen nicht besitzen. Im Rahmen dieser Vorlesung sollen jedoch nur die grundlegenden Mechanismen der Pipes betrachtet werden und daher diese beiden Eigenschaften zugrundegelegt werden.

Prinzip einer Pipe: In UNIX wird eine Pipe mit dem gleichnahmigen Systemaufruf `pipe` eingerichtet, d.h. der Prozess richtet eine Pipe im Kern ein. Ist dieser Aufruf erfolgreich so ist:
`fd[0]`: ein geöffneter Filedescriptor zum Lesen aus der Pipe.
`fd[1]`: ein geöffneter Filedescriptor zum Schreiben in die Pipe.

Eine im Kern eingerichtete Pipe könnte man sich wie in Abbildung 10.5 vorstellen.

Diese Pipe ist zunächst für den Prozess nutzlos, da kein weiterer Prozess existiert, mit dem über die Pipe kommuniziert werden kann. Wir gehen nun zu unserer ersten Eigenschaft zurück und das dabei beschriebene Prinzip sieht folgendermaßen aus: Der Prozess, der die Pipe eingerichtet hat ruft nun `fork` auf, um einen Kindprozess zu kreieren, mit dem er kommunizieren möchte. Der Prozess A übernimmt dabei gleichzeitig die Rolle des Elternprozesses. Es ergibt sich, die in Abbildung 10.6 gezeigte Konstellation nach dem `pipe`-und-`fork` Aufruf.
Je nachdem in welche Richtung die Daten fließen sollen, gibt es nun zwei Möglichkeiten.

1. Der Elternprozeß A schreibt und der Kindprozeß B liest. In diesem Fall muß der Elternprozeß die Leseseite der Pipe, d.h. fd[0], und der Kindprozeß die Schreibseite der Pipe, d.h. fd[1], schließen. Damit ergibt sich die Pipe wie in Abbildung 10.7, in der Daten vom Eltern- zum Kindprozeß fließen.

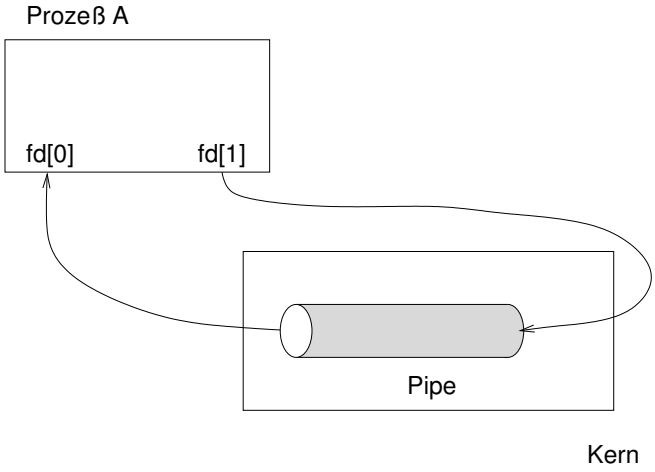

Abbildung 10.5: Einrichtung einer Pipe im Kernel

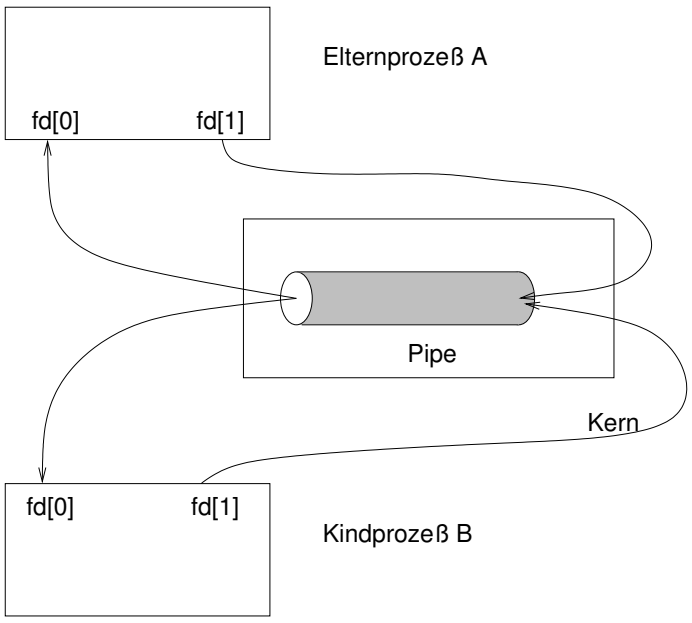

Abbildung 10.6: Grundsätzlicher Aufbau einer Pipekonstellation

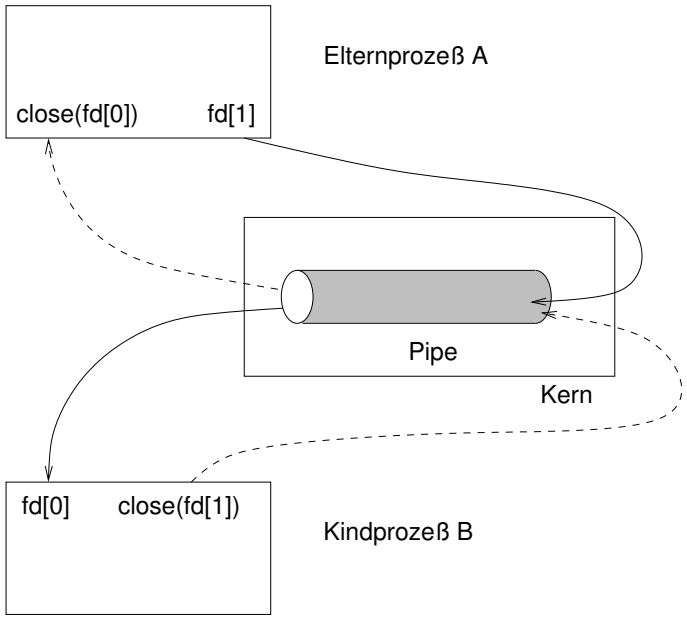

Abbildung 10.7: Daten fließen zum Kindprozeß

2. Der Elternprozeß liest und der Kindprozeß schreibt. Analog schließt der Elternprozeß A die Schreibseite der Pipe und der Kindprozeß die Leseseite der Pipe. Wir haben somit die Situation wie in Abbildung 10.8.

Beim Schreiben in eine Pipe legt die Konstante PIPE_BUF die vom Kern verwendete Buffergröße für die Pipe fest. Werden mit einem oder mehreren `write`-Aufrufen, ohne zwischenzeitliche, den Buffer angemessen leerende, `read`-Aufrufe, mehr als PIPE_BUF Bytes hintereinander geschrieben, so können nicht alle Daten in den Buffer geschrieben werden und gehen verloren. Es ist auch möglich, daß mehrere Prozesse gleichzeitig Daten in dieselbe Pipe schreiben, diese werden dann sequentiell abgelegt.
Nun soll noch die Kommunikation zweier Kindprozesse über eine Pipe betrachtet werden. Dies passiert z.B. in nachstehender Reihenfolge:

– der Elternprozess kreiert das Schreib-Kind,

– der Elternprozess schließt die Schreibseite seiner Pipe,

– das Schreibkind schließt die Leseseite seiner Pipe,

– der Elternprozess kreiert das Lese-Kind,

– der Elternprozess schließt die Leseseite seiner Pipe,

– das Lese-Kind schließt die Schreibseite seiner Pipe,

Damit ergibt sich ein Kommunikationkanal wie in Abbildung 10.9.

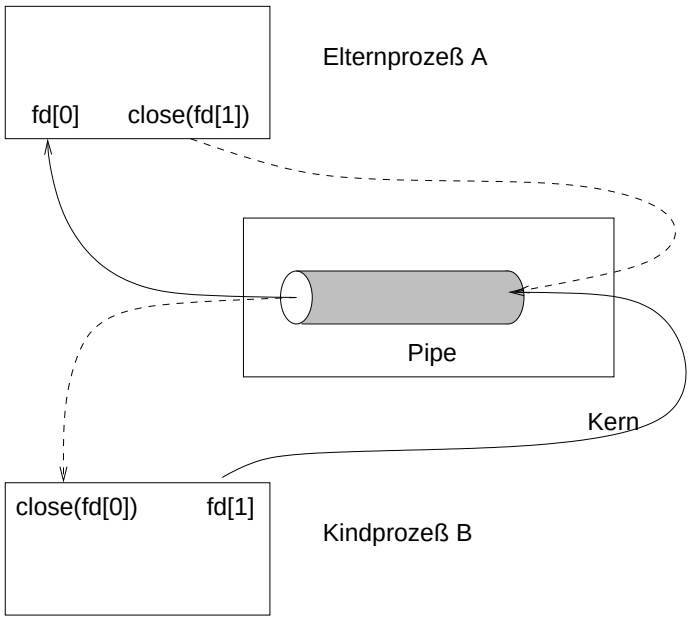

Abbildung 10.8: Daten fließen zum Elternprozeß

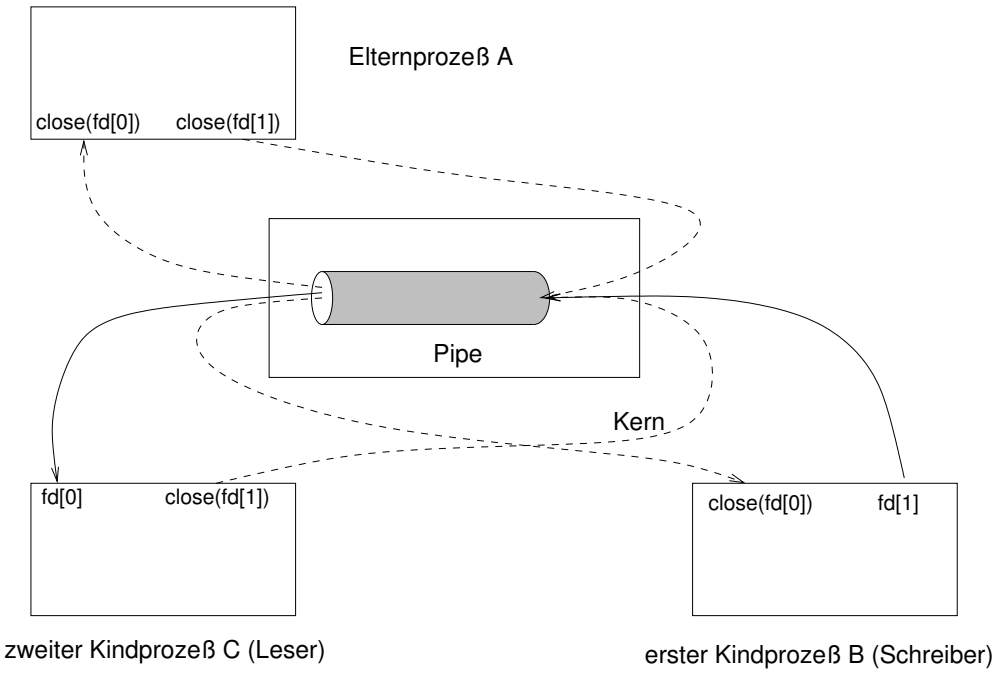

Abbildung 10.9: Kommunikation mit zwei Kindprozessen

10.3 FIFOs

Während die bislang betrachteten Pipes nur zwischen Prozessen verwendet werden können, bei denen ein gemeinsamer Vorfahre die Pipe kreiert hat, werden oft auch Kommunikationsmechanismen benötigt, die zwischen beliebigen Prozessen einen Austausch von Daten ermöglichen. In den gängigen UNIX-Varianten stehen dafür sogenannte *named pipes* (benannte Pipes) zur Verfügung die in der Literatur auch als **FIFOs** bezeichnet werden. Sie sind eine spezielle Dateiart. Solche **FIFOs** können auch für die Realisierung einer Client/Server-Kommunikation wie in Abbildung 10.10 genutzt werden, wenn also Prozesse auf ganz unterschiedlichen Rechnern miteinander kommunizieren sollen. Bei Prozeduraufrufen unter-

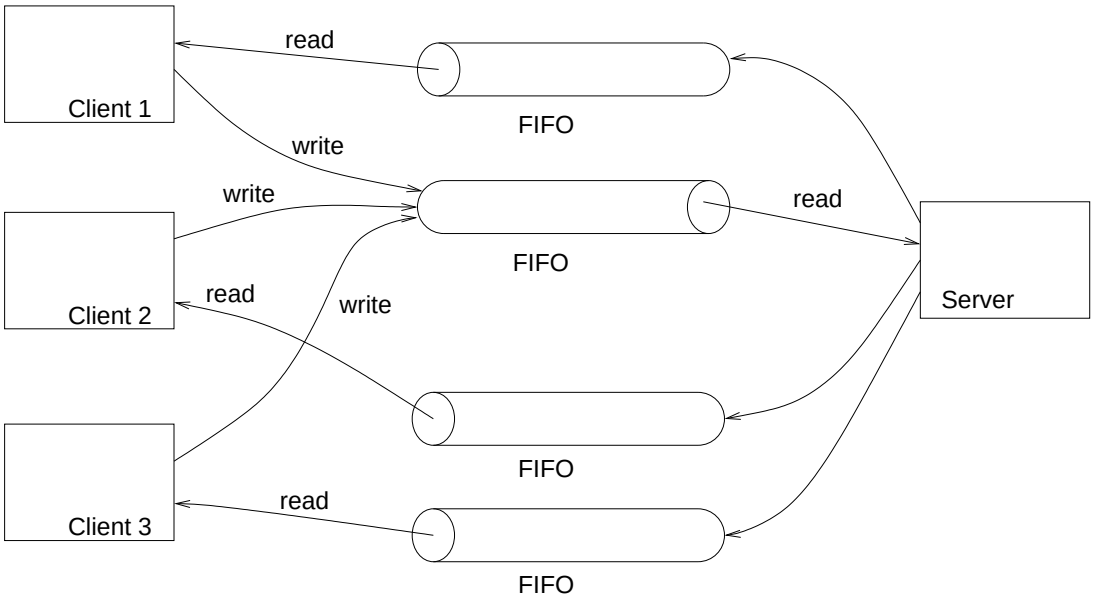

Abbildung 10.10: FIFO-Prinzip für drei Clients und einen Server

scheidet man zwischen Anouncements und Invocations. Bei ersterem wird nur eine Prozedur aufgerufen, ohne eine Antwort zu erwarten. Bei Invocations (z.B. im Sinne der Java-Remote Method Invocations) wird eine Anfrage gestartet, auf die eine Antwort zurückkommt. Die obige Architektur ist für Invocations gedacht, denn bei Anouncements würde die eine **FIFO** ausreichen, mittels der die Clients Daten an den Server schicken können.

10.4 Stream Pipes

Eine Stream Pipe unterscheidet sich von einer normalen Pipe darin, daß sie nicht im Halbduplexbetrieb, sondern im Vollduplexbetrieb arbeitet, d.h. Daten können in beide Richtungen übertragen werden. Dazu wird in UNIX eine Funktion `stream-pipe` verwendet, die ähnlich wie die Funktion `pipe` arbeitet. Das Resultat unterscheidet sich dahingehend, daß die in das Argument fd geschriebenen Filedescriptoren gleichzeitig zum Lesen und zum Schreiben geöffnet sind, siehe auch Abbildung 10.11. Neben der grundlegenden Stream-Pipe die – analog zu einer Pipe – nur zum Datenaustausch zwischen verwandten Prozessen, wie z.B. Eltern- und Kindprozeß genutzt werden kann, gibt es noch die benannten Stream-Pipes. Diese können

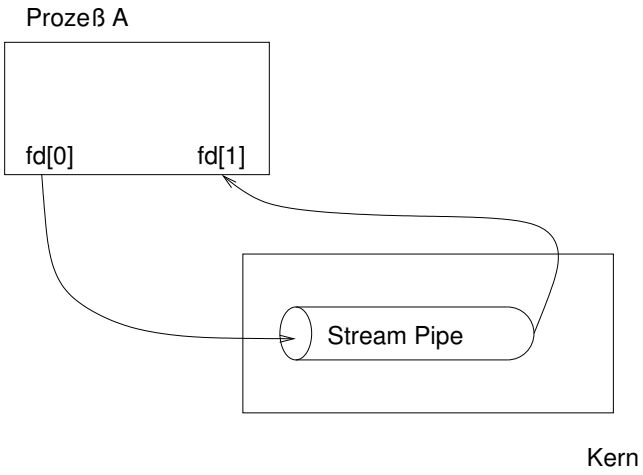

Abbildung 10.11: Stream-Pipe

auch für eine Kommunikation zwischen Prozessen genutzt werden, die in keinem Verwandtschaftsverhältnis stehen.

10.5 Sockets

Sockets dienen zur Kommunikation von Prozessen in einem Netzwerk, können aber auch zur Kommunikation von Prozessen auf einem lokalen Rechner benutzt werden. In letzterem Sinne soll nun ihr Prinzip im Rahmen der Interprozesskommunikation betrachtet werden. Sockets basieren auf verschiedenen Protokollen des *ISO/OSI* Modells, die später Gegenstand von Rechnernetzvorlesungen sind. Sie sollen hier nur insofern betrachtet werden, daß je auf einem Rechner mit der Funktion des Senders und des Empfängers eine *Internetprotokolladresse (IP-Adresse)* und eine Portnummer einen gemeinsamen Kommunikationsendpunkt definieren, der Socket genannt wird. Jedem Socket steht im Rechner ein reservierter Speicherplatz als Kommunikationspuffer zur Verfügung. Darin werden die zu übertragenden und empfangenden Daten jeweils abgelegt. Folgendes Beispiel soll das Socket Prinzip, wie auch in Abbildung 10.12 zu sehen, veranschaulichen.

Beispiel 10.2.

Einer TELNET*-Verbindung wird in Rechner 1 die Portnummer 1080 und in Rechner 2 die Portnummer 23 zugewiesen. Die IP-Adresse von Rechner 1 sei x und die von Rechner 2 sei y. Dann lautet die Socket-Angabe in Recher 1 (Socket:[1080,x]) und die in Rechner 2 (Socket: [23,y]). Die Socket-Nummer bleibt während der ganzen Verbindung unverändert.*

In diesem Sinne ist ein Socket eine Verallgemeinerung eines UNIX Zugangsmechanismus, der einen Kommunikationsendpunkt darstellt. Anwendungsprogramme können dabei das Betriebssystem beauftragen, bei Bedarf, einen Socket zu generieren.

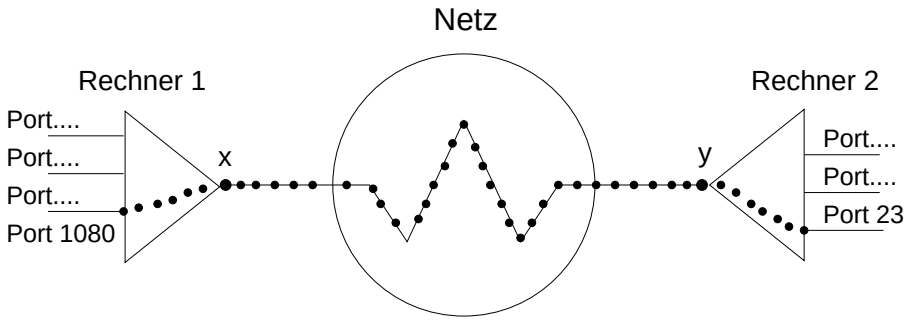

Abbildung 10.12: Das Socket Prinzip

11

Verteilte Systeme

- Einführung in Verteilte Systeme
- Das Client/Server-Modell
- Remote Procedure Call

Inhaltsangabe

11.1 Einführung in Verteilte Systeme

Für den Begriff des Verteilten Systems kann man in der Literatur eine ganze Reihe unterschiedlicher Interpretationen finden. Das Verständnis davon, was man sich unter einem Verteilten System vorzustellen hat, ist historisch gewachsen und unterliegt noch heute einem beständigen Wandel. In [7] findet sich auf Seite 364 der Hinweis, man habe es immer dann mit einem Verteilten System zu tun, falls "multiple interconnected CPUs work together". Demgegenüber ist auf Seite 382 die Rede von einem Verteilten System als "collection of machines that do not have shared memory".
Im folgenden sollen Verteilte Systeme in Ihrer allgemeinsten Form betrachtet werden. Darunter fallen alle Arten von Client-/Server- Systemen sowie Multiprozessorsysteme, d.h. Systeme welche aus Knoten bestehen, die selbst Uni- oder Multiprozessor sein können. [11] entnimmt man folgende Definition(S.86):

> Ein *Verteiltes System* ist ein System mit räumlich verteilten Komponenten, die keinen gemeinsamen Speicher benutzen und einer dezentralen Administration unterliegen. Zur Ausführung gemeinsamer Ziele ist eine Kooperation der Komponenten möglich. Werden von diesen Komponenten Dienste angeboten und angebotene Dienste genutzt, so entsteht ein *Client-/Server-System*, im Falle einer zusätzlichen zentralen Dienstvermittlung ein *Tradingsystem*.

Die Einordnung Verteilter Systeme in den Kontext des OSI-Referenzmodells ist dabei nicht unproblematisch. Generell kann jedoch gesagt werden, daß Verteilte Systeme im wesentlichen Aspekte der oberen Schichten des Referenzmodells betreffen. Im Gegensatz zu einer Grundlagenvorlesung aus dem Bereich "Datenkommunikation", welche sich im wesentlichen mit den unteren OSI-Schichten befasst, werden daher im folgenden verstärkt Konzepte der oberen drei Schichten behandelt.

11.1.1 Historie Verteilter Systeme

Der Beginn der "Modern Computer-Era" ist um das Jahr 1945 herum anzusiedeln. Typisch für die Zeit waren (nach heutigen Maßstäben gerechnet) große und teure Computer, aufgebaut in der klassischen von Neuman-Architektur. In einem Unternehmen waren nur wenige Computer vorhanden, die vollständig unabhängig voneinander arbeiteten (zentraler Ansatz) . Aus dieser Zeit stammt eine Grundregel, welche als Grosch's Gesetz bekannt wurde. Sie besagt, daß sich die Rechenleistung in einer CPU proportional zum Quadrat Ihres Preises verhält. Investiert man also das doppelte in einen Rechner, so kann man nach Grosch's Gesetz das vierfache an Leistung erwarten. Mit der Entwicklung der Mikroprozessortechnologie verlor das Gesetz von Grosch seine Gültigkeit.
Ein genereller Trend zur Abkehr von dem zentralen Ansatz ist seit Mitte der achtziger Jahre zu erkennen. Ausgelöst wurde er im wesentlichen durch vier Entwicklungstendenzen:

1. Im Bereich der Halbleiterchips kam es zu einer Leistungsexplosion. Die Rechenleistung von Mikroprozessoren hat sich im letzten Jahrzehnt ca. alle zwei Jahre verdoppelt, die Kapazität von Halbleiterspeichern alle drei Jahre vervierfacht. Stetig wachsende Leistung bei schrumpfenden Preisen und Abmessungen bildete die Grundlage dafür, dass immer mehr Rechner immer komplexere Software ausführen konnten.

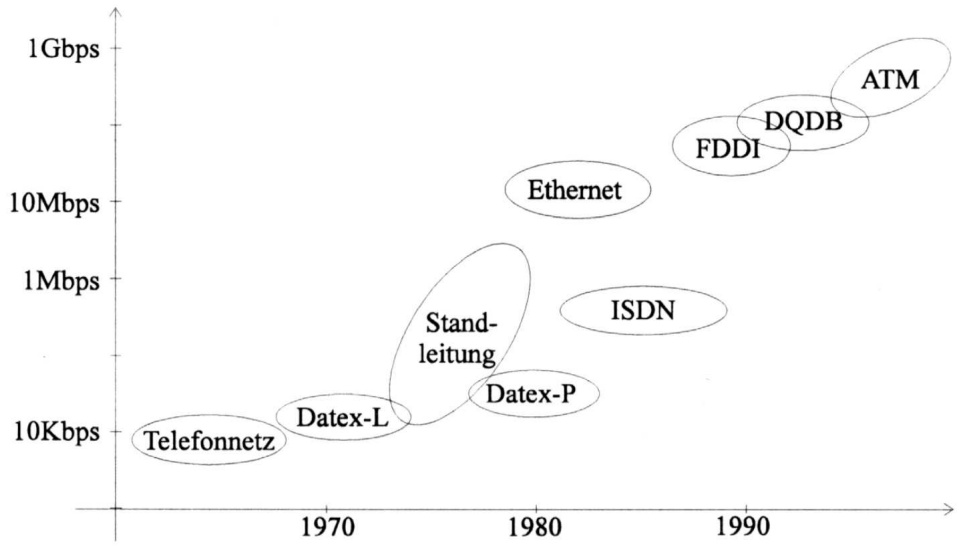

Abbildung 11.1: Leistungsexplosion bei Datennetzen

2. Die Bereitstellung schneller, lokaler Datennetze bildet die ökonomische Voraussetzung dafür, Personal Computer und Workstations zu verbinden. Die Einführung der Ethernet-Technik in den siebziger Jahren kann als Wegbereiter für verteilte Softwaresysteme gesehen werden, siehe auch Abbildung 11.1.

3. In den letzten drei Jahrzehnten sind auch erhebliche Fortschritte im Bereich der Softwaretechnik zu verzeichnen gewesen. Die Akzeptanz von programmiersprachlichen Konzepten wie Prozedur, Modul und Schnittstelle schuf die Voraussetzungen für die grundlegenden Mechanismen Verteilter Systeme. Konsequenzen waren der RPC (Remote Procedure Call) und die objektorientierte Modellierung Verteilter Systeme.

4. Die Abkehr von streng hierarchisch aufgebauten Organisationsformen in Unternehmen führt ganz allgemein zu einer Dezentralisierung und schafft flache Führungsstrukturen.

Diese vier Aspekte ermöglichen nicht nur die Entwicklung Verteilter Systeme, sie provozieren sie geradezu.

11.1.2 Vorteile Verteilter Systeme

Warum nutzt man die oben erwähnten Entwicklungstendenzen, um zentrale Systeme durch verteilte zu ersetzen? Es gibt eine ganze Reihe von Gründen, welche für Verteilte Systeme sprechen:

– Verteilte Systeme ermöglichen die stetige Anpassung der Größe eines Systems. Den neu hinzugekommenen Anforderungen an das Computersystem eines expandierenden Unternehmens kann durch Erweiterung bestehender Komponenten zeitgemäß entsprochen werden.

- Bestehende Lösungen sind integrierbar. Existierende Systeme können von neu hinzukommenden Systemkomponenten genutzt werden, ohne daß ein System gleicher Funktionalität neu entwickelt werden muß.
- Eine sukzessive Systemerweiterung minimiert das Risiko der Überlastung einzelner Systemkomponenten, indem stets auf die gleichmäßige Auslastung sowohl bestehender als auch neu hinzugekommener Module geachtet wird.
- Die überschaubare, organisatorische Verwaltung der Kapazität eines Verteilten Systems bedingt kosteneffektive Realisierungen. Das System ist flexibel und anpassbar.
- Der Eigentümer einer Ressource hat die Möglichkeit, das Management dieser Komponente selbst zu übernehmen. In jedem Fall steht es ihm frei, bei Bedarf einzugreifen, um seine eigenen Interessen wahrzunehmen.
- Die einzelnen Bestandteile eines Verteilten Systems sind weitestgehend autonom. Im Falle eines Fehlers oder sogar Ausfalls einer Systemkomponente können die übrigen Einheiten im Idealfall unbeeinflußt weiterarbeiten und ggf. den Störfall überbrücken.

Neben diesen (und vielen weiteren) Vorteilen eines Verteilten Systems kann man sich auch über Nachteile streiten, die u.a. in folgenden Punkten zum Ausdruck kommen:

- Für den Zeitraum des Übergangs zu Verteilten Systemen droht ein Softwaredefizit. Die Realisierung eines Verteilten Systems erfordert komplexere Softwarelösungen als die eines zentralen Systems. In [7] wird der “radikale Unterschied” in der SW-Bereitstellung für zentrale und Verteilte Systeme betont. Danach ist man bei Verteilten Systemen erst am Anfang der Konzeptentwicklung.
- Die hinzugekommenen Netzwerkkomponenten können vollkommen neuartige Fehler verursachen.
- Aus der Sicht des Datenschutzes sind Verteilte Systeme bedenklich. Vernetzte Daten ermöglichen generell einfacher den Zugriff, als dies bei separater Datenhaltung der Fall ist.

11.1.3 Klassifikation Verteilter Systeme

Die Klassifikation verteilter Systeme erfolgt entsprechend ihrer Hard- und Software. Zunächst zur Hardware. Wichtig ist, wie die einzelnen Komponenten eines Verteilten Systems miteinander verbunden sind und wie sie kommunizieren. Dazu gibt es verschiedene Klassifikationsschemata. Ein bekanntes Beispiel ist sicherlich die Unterscheidung von sequentiellen (“single”) und parallelen (“multiple“) Instruktions- und Datenströmen nach Flynn(1971), welche insgesamt zu vier Rechnerklassen führt: Zum einen sind dies klassische von-Neumann-Rechner, hier bezeichnet mit der Abkürzung SISD (Single Instruction Single Data). Desweiteren benennt man parallele und verteilte Architekturen mit MIMD (Multiple Instruction Multiple Data). Mischformen wie etwa Vektorrechner, gehören einer Klasse der SIMD oder seltener MISD an. Bei MIMD-Architekturen ist es darüber hinaus üblich, zwischen Systemen, bei denen die Prozessoren auf einen gemeinsamen Speicher zugreifen, und solchen, bei denen jedem Prozessor ein eigener privater Speicher zur Verfügung steht, zu unterscheiden. Man trennt also *shared memory*-Systeme von *non shared memory*-Systemen. Betrachtet man

Verteilte Systeme, so liegt dabei im Sinne der Anfangs gemäß [11] gegebenen Definition der Fall des *non shared memory* vor. Um nun Rechnerarchitekturen weiter abzugrenzen, unterscheidet man *lose gekoppelte* und *fest gekoppelte* Systeme. In letzterem Fall ist die Verzögerung bei der Übertragung einer Nachricht von einer CPU zu einer anderen als niedrig einzustufen. Dementsprechend ist die Übertragungsrate hoch. In einem lose gekoppelten System ist das Gegenteil der Fall. Die Übertragungsrate ist niedrig, große Verzögerungszeiten sind möglich . Ein Beispiel für eine lose gekoppeltes System wären zwei über Modem und Telefonnetz gekoppelte Rechner. Fest gekoppelte Rechner sind in der Regel mit *shared memory* ausgestattet . Man bezeichnet sie mithin als Multiprozessorsysteme. Sie eignen sich eher als System zu parallelen Abarbeitung eines einzelnen Problems. Bei der Bearbeitung mehrerer unabhängiger Probleme bietet sich die Verwendung eines Multicomputers mit *non shared memory* an, welcher durch ein echtes Verteiltes System repräsentiert werden kann. Jede dieser Kategorien kann aufgrund des Aufbaus des verwendeten Verbindungsnetzwerks weiter unterteilt werden in busbasiert bzw. switchbasiert. Unter einem Bus versteht man ein einzelnes Netzwerk, ein Kabel oder eine anderes Medium, das alle Rechner verbindet. Switchbasierte Systeme verfügen nicht über ein solches “Rückgrat”. Es bestehen einzelne Verbindungen zwischen den Rechnern. Daher muß in jedem Knoten für eine aufzubauende Verbindung eine Routing-Entscheidung getroffen werden. Für letztere Architektur entscheidet man sich immer dann, wenn abzusehen ist, dass der zu erwartende Datenverkehr das Bussystem schnell überlasten würde. Aber auch switchbasierte Systeme stoßen schnell an ihre Grenzen. Bei einem Kreuzschienenverteiler werden n^2 Switches benötigt, in Omega-Netzwerken aus 2x2-Switches immerhin noch $n \cdot \log_2(n)$ Switches. Neben den dadurch entstehenden hohen Kosten für die große Anzahl Switches tritt als weiteres Problem die hohe Verzögerungszeit bei Durchlaufen der einzelnen Switches auf. Dies betrifft vor allem Multiprozessorsysteme. Bei Multicomputern ist mit deutlich geringerem Verkehrsaufkommen zu rechnen, da der lokale Speicher entlastend wirkt. Um die Kosten niedrig zu halten, werden hier nicht alle Prozessoren über Switche direkt verbunden, sondern können nur mittelbar über andere Prozessoren Nachrichten austauschen. Vielfach verwendete Topologien sind einfache Gitter und Hypercube.

Bisher wurden für die Klassifikation ausschließlich Hardwaremerkmale herangezogen. Unterschieden wurden letztlich vier Varianten: Bus- bzw. switchbasierte, lose oder eng gekoppelte Systeme, wie auch in Abbildung 11.2 zusehen. Bedeutender noch ist jedoch die Software und dabei insbesondere das zum Einsatz kommende Betriebsystem. Analog zur Hardware unterscheidet man lose gekoppelte von fest gekoppelter Software. Lose gekoppelte Software gestattet es Rechnern und Benutzern eines Verteilten Systems, im wesentlichen unabhängig voneinander zu arbeiten und nur in einem begrenzten Umfang - im Bedarfsfall - zu interagieren. Beispiele wären PC-Arbeitsplätze mit jeweils eigener CPU, Speicher und Betriebssystem, aber gemeinsam genutztem Laserdrucker. Fest gekoppelte Software realisiert ein Programm auf verschieden Rechnern gleichzeitig.

Kategorie 2 in Tabelle 11.1 ist die in Unternehmen gebräuchlichste Form der Hardware und Softwarekombination, z.B. realisiert durch eine Anzahl über ein LAN verbundener Workstations. Sie wird auch als Netzbetriebsystem bezeichnet. Jeder Nutzer hat dabei eine eignen Workstation mit einem eigenen Betriebsystem. I.d.R. wird dabei lokales Arbeiten bevorzugt, explizite entfernte Aufrufe (z.B. `rlogin` oder `rcp`) sind jedoch möglich. Die Kommunikation erfolgt in diesem Fall über den Zugriff auf gemeinsame Daten. Kategorie 4 in Tabelle 11.1 das sog. Verteilte Betriebsystem, schafft für den Nutzer die Illusion, dass das gesamte Netzwerk eher ein Time-Sharing-System ist, als daß es eine Ansammlung einzelner Maschinen

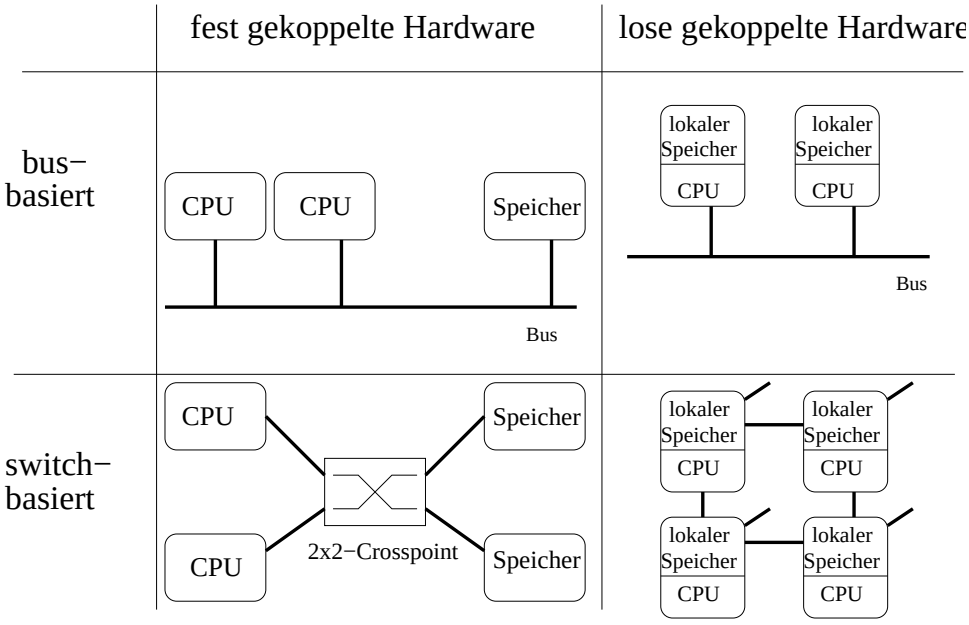

Abbildung 11.2: Bus- und switchbasierte Systeme mit und ohne gemeinsamen Speicher

	lose gekoppelte SW	fest gekoppelte SW
eng gekoppelte HW (Bus- und Switchbasiert)	1	3 (Multiprozessorsystem)
lose gekoppelte HW (Bus- und Switchbasiert)	2 (Netzbetriebsystem)	4 (Verteiltes Betriebsystem)

Tabelle 11.1: Kategorien Verteilter Systeme

darstellt. Die Kommunikation erfolgt bei einem solchen System über Nachrichten. Letztlich ist darüber hinaus nur noch die Kategorie 3 sinnvoll: Die Systeme dieser Kategorie dienen häufig speziellen Zwecken, wie z.B. Datenbanksysteme, charakteristisch ist dabei eine einzelne Prozeß-Queue im gemeinsamen Speicher. Die Kommunikation zwischen den einzelnen Komponenten eines solchen Systems erfolgt über den gemeinsamen Speicher. Diese Kategorie wird auch als Multiprozessorsystem bezeichnet.

11.1.4 Eigenschaften Verteilter Systeme

Nachdem im vorangegangenen Abschnitt geklärt worden ist, auf welche Weise sich verteilte Systeme unterscheiden, soll im folgenden auf die Gemeinsamkeiten der unterschiedlichen Ausprägungen verteilter Systeme eingegangen werden, dabei gibt es folgende Charakteristiken:

1. Ein erster Aspekt ist die Entferntheit. Komponenten eines Verteilten Systems sind immer auch räumlich voneinander getrennt. Wechselwirkungen treten entweder lokal oder entfernt auf.

2. Die Komponenten eines Verteilten Systems können parallel arbeiten, woraus ein Geschwindigkeitszuwachs gegenüber sequentieller Vorgehensweise resultiert. Das System ist in der Lage, Nebenläufigkeit zu realisieren.

3. Es ist nicht praktikabel, ausschließlich globale Systemzustände zu betrachten. Lokale Zustandsbetrachtungen müssen zusätzlich durchgeführt werden.

4. Komponenten arbeiten unabhängig und können auch unabhängig voneinander ausfallen. Verteilte Systeme unterliegen somit dem partiellen Systemausfall.

5. Das System arbeitet asynchron. Kommunikations- und Verarbeitungsprozesse werden nicht durch eine globale Systemuhr gesteuert. Änderungen und Prozesse werden demzufolge nicht notwendigerweise synchronisiert.

6. Im Verteilten System dürfen Management- und Steuerfunktionen auf verschiedene autonome Komponenten, sogenannte Autoritäten, verteilt werden. Dabei darf keine einzelne Autorität eine übergeordnete Gesamtkontrolle ausführen. Dies sichert ein gewisses Maß an Autonomie.

7. Ein Verteiltes System kann durch Zusammenschluß von bereits existierenden Systemen entstehen. Demzufolge ist eine kontextbezogene Namensverwaltung erforderlich, welche die eindeutige Interpretation der Namen über die Grenzen einer administrativen oder technologischen Bereichs hinaus ermöglicht. Man spricht in diesem Zusammenhang von föderativer Namensverwaltung.

8. Um die Leistungsfähigkeit des Verteilten Systems zu erhöhen, können Programme und Daten zwischen verschiedenen Orten bewegt werden, dieses Konzept wird als Migration bezeichnet. Dabei sind zusätzliche Mechanismen einzubeziehen, welche die Lage von Programmen und Daten protokollieren.

9. Ein Verteiltes System muß in der Lage sein, dynamische Umstrukturierungen vorzunehmen. Diese *dynamische Rekonfiguration* ist beispielsweise dann erforderlich, wenn zur Laufzeit neue Bedingungen hinzugefügt werden müssen.

10. Rechnerarchitekturen können unterschiedliche Topologien und Mechanismen benutzen, insbesondere falls es sich um Produkte verschiedener Hersteller handelt. Diese Charakteristik wird als *Heterogenität* bezeichnet.

11. Ein verteiltes System unterliegt der *Evolution*. Es wird in seiner Lebenszeit zahlreiche Änderungen durchlaufen.

12. Quellen von Informationen, Verarbeitungseinheiten und Nutzer können physikalisch mobil sein. Programme und Daten können zwischen Knoten bewegt werden, um die *Mobilität* des Systems zu erhalten oder die Leistungsfähigkeit zu steigern.

Um diese Charakteristiken zu erreichen, müssen bestimmte Anforderungen erfüllt sein, um Verteilte Systeme geeignet modellieren und implementieren zu können:

– Offenheit d.h. Portabilität eines Systems,

– Integrierbarkeit, zur Behandlung der Heterogenität,

– Flexibilität, um die Evolution des Systems zu unterstützen

– Modularität, welche eine wichtige Grundvoraussetzung für die Flexibilität darstellt,

– Föderation, um den Zusammenschluß autonomer Einheiten zu ermöglichen,

– Verwaltbarkeit,

– Sicherstellung von Dienstqualitäten.

– Sicherheit und

– Transparenz.

Transparenz ist eine zentrale Anforderung , die daraus resultiert, den Umgang mit verteilten Anwendungen so weit wie möglich zu erleichtern. Sie umfasst das Verbergen von Implementierungsdetails und die **Verteilungstransparenz**. Letztere verbirgt ihrerseits die Komplexität Verteilter Systeme. Dabei werden interne Vorgänge durch sogenannte Transparenzfunktionen vor dem Betrachter verborgen. Der Nutzer wurde dadurch entlastet.
Es gibt viele Ausprägungen der Verteilungstransparenz. Exemplarisch sollen hier einige genannt werden.

– Die **Zugriffstransparenz** verbirgt die speziellen Zugriffsmechanismen für einen lokalen oder entfernten Dienst- oder Ressourcenaufruf.

– Die **Ortstransparenz** verbirgt die Systemtopologie als solche.

– Dem gegenüber hält die **Migrationtransparenz** Bewegung und Auslagerung von Funktion und Anwendungen transparent.

– Unter **Replikationstransparenz** versteht man Vorkehrungen für das - vom Benutzer unbemerkte - Anlegen redundanter Kopien von Datenbeständen des Netzes. Letztes fördert den sicheren und schnellen Zugriff auf Daten.

– **Abarbeitungstransparenz** verbirgt, ob die Abarbeitung eines Aufrufs parallel oder sequentiell erfolgt.

– Wird bei Ausfall einer angesprochenen Netzkomponente ohne Zutun des Nutzers ein Ersatz gefunden und angesprochen so spricht man von **Ausfalltransparenz**.

– Bleibt auch die Zuordnung von Ressourcen zu Anwendungsprozessen verkapselt, so liegt **Ressourcentransparenz** vor.

– Die **Verbundstransparenz** versteckt Grenzen zwischen administrativen und technischen Bereichen.

– **Gruppentransparenz** verbirgt das Benutzen von Gruppen.

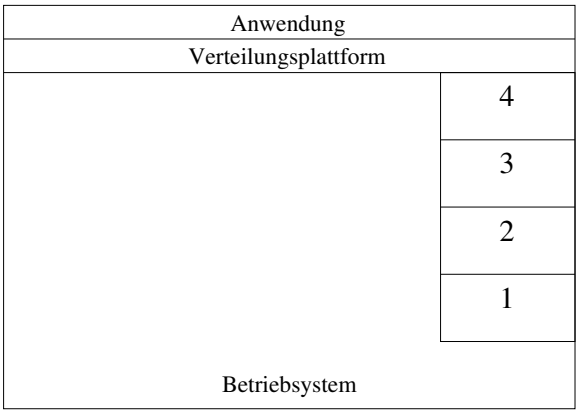

Abbildung 11.3: Einordnung der Verteilungsplattform in die Softwarearchitektur

Zur Überbrückung von Verteilung bedarf es einer geeigneten Softwareinfrastruktur. Diese ist als *Verteilungsplattform* oder auch synonym *Middleware*, *Verteilungsinfrastruktur* bekannt und gemäß der in Abschnitt 11.1.3 eingeführten Klassifikation *Netzbetriebsystem*. Die Verteilungsplattform unterstützt eine Interaktion zwischen den auf potentiell heterogenen Systemen ablaufenden Anwendungskomponenten. Die Verteilungsplattform wird dem lokalen Betriebssystem hinzugefügt oder übernimmt selbst Aufgaben des Betriebssystems. Auf diese Weise wird die Verteilung transparent gehalten. Anwendungen werden von komplexen Details interner Vorgänge abgeschirmt. Einer Verteilungsplattform können viele individuelle Systeme zugrunde liegen, auf denen sie aufsetzt. Gleichzeitig kann eine Vielzahl von Anwendungen auf die Verteilungsplattform zugreifen.

11.2 Kommunikation in Verteilten Systemen

11.2.1 Das Client/Server Modell

Am Anfang unserer Überlegungen soll die These stehen, daß das *OSI-MODELL* nicht zur Modellierung Verteilter Systeme geeignet ist. Warum ist dies der Fall? Der Verwaltungsaufwand der sieben Schichten ist zu hoch, denn bei der Übertragung einer Nachricht wird sieben mal ein Datenkopf angehängt bzw. wieder entfernt. Dies kostet Zeit, bei LANs in Relation zur Übertragung sogar sehr viel Zeit. Die Folge dieser Erkenntnis ist, daß Verteilte Systeme auf ein eigenes Grundmodell zurückgreifen : das *Client/Server-Modell(C/S-Modell)*.

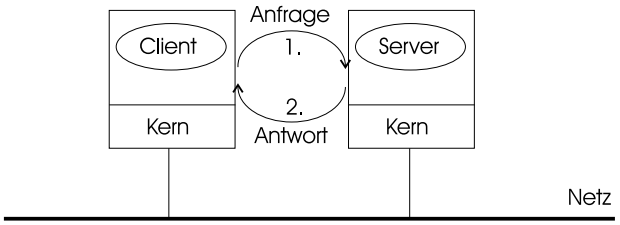

Abbildung 11.4: Das Client/Server-Modell

Die Idee des C/S-Modells besteht darin, ein Betriebsystem als Menge kooperierender Prozesse - sogenannter *Server* - zu strukturieren. Diese stellen den Nutzern - sogenannten *Clients* - Dienste bereit. Auf einem Rechner kann ein Client oder ein Server, eine Menge von Servern oder beides laufen. Das C/S Modell basiert auf einem einfachen, verbindungslosen Anfrage/Antwortprotokoll: der Client sendet eine Anfrage und erhält seine Antwort von dem Server, vgl. Abbildung 11.4. Diese einfache Methode ist sehr effizient. Der Protokollstapel wird klein gehalten. Bei identischen Rechnern besitzt er nur drei Protokollschichten.

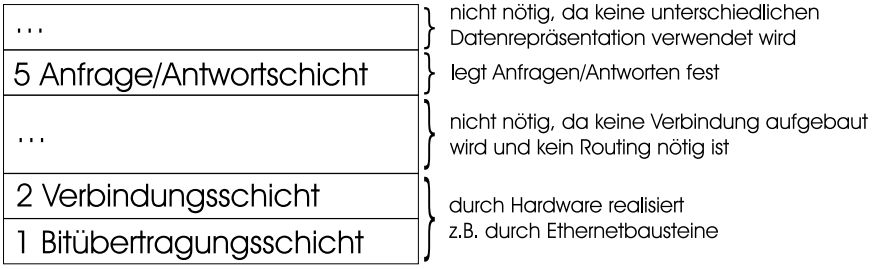

Abbildung 11.5: Der Protokollstapel des Client/Server-Modells

Die Schichten eins und zwei werden immer durch die Hardware realisiert, z.B. durch entsprechende Ethernet- oder Token-Ring-Bausteine. Die Schichten drei und vier werden nicht benötigt, da keine Verbindungen aufgebaut werden und kein Routing notwendig ist. Die Menge der erlaubten Anfragen und Antworten legt das *Anfrage/Antwortprotokoll* in Schicht fünf fest. Da keine unterschiedliche Datenrepräsentation verwendet wird, entfällt die Funktionalität der Schicht sechs. Die Anwendung selbst ist im C/S Modell bzw. in der Verteilungsplattform nicht vorhanden. Legt man diese einfache Struktur zugrunde, so ist es lediglich notwendig, daß die Verteilungsplattform zwei Systemaufrufe anbietet. Ein Aufruf der Art `send(a, &mp)` verschickt die Nachricht, die durch mp referenziert wird, an einen Prozeß der durch a identifiziert wird. Der Aufrufer wird dabei solange blockiert, bis die Nachricht vollständig verschickt ist. Demgegenüber wird der Aufrufer von `receive(a,&mp)` blockiert, bis eine Nachricht von ihm angekommen ist. Die Nachricht wird in den durch mp angegebenen Puffer kopiert. Der Parameter a gibt die Adresse an, die vom Empfänger abgehört wird. Es existieren viele Varianten dieser Routinen. Im folgenden soll eine einfache Implementierung für einen Fileserver gemäß [7] vorgestellt werden. Der Client und der Server haben eine Reihe von Definitionen gemeinsam, die in der Datei header.h aus Abbildung 11.6 zusammengefasst sind. Dabei handelt es sich im wesentlichen um die Definition erlaubter, entfernter Operationen auf den durch den Server verwalteten Dateien, damit in Verbindung stehende Fehlercodes und vor

allem die Definition des Nachrichtenformats. Alle Anfragen von einem Client an einen Server sowie alle Antworten benutzen dieses Format. In einem realen System gibt es i.d.R. kein festes Nachrichtenformat! Die Hauptschleife des ereignisorientierten Serverprogramms ist in Abbildung 11.7 angegeben. Man erkennt, wie einfach die Implementierung vorgenommen werden kann. Zu Beginn des Schleifenkörpers wird die Bibliotheksroutine `receive(·)` aufgerufen, um ankommende Anfragen zu erhalten. Der Prozeß wird blockiert. Erst wenn eine Anfrage eintrifft, veranlasst der Betriebsystemkern die Aufhebung der Blockade. Abhängig vom Inhalt des `opcode`-Feldes wird anschließend eine Prozedur aufgerufen, welche die gewünschte Funktionalität realisiert.

```
#define MAX_PATH    255  /* max. Länge des Dateinamens */
#define BUF_SIZE    1024 /* auf einmal übertragbare Datenmenge */
#define FILE_SERVER 243  /* Netzwerkadresse des Datei-Servers */

/* erlaubte Operationen zur Verwaltung */

#define CREATE      1
#define READ        2
#define WRITE       3
#define DELETE      4

/* Fehlercodes */

#define Ok            0
#define E_BAD_OPCODE  -1 /* unbekannte Operation */

/* Nachrichtenformat */

struct message {
   long source;          /* Identität des Senders */
   long dest;            /* Identität des Empfängers */
   long opcode;          /* Code einer erlaubten Operation */
   long count;           /* Anzahl der übertragenen Bytes */
   long offset;          /* Position des Lesens bzw. Schreibens */
   long extra1;          /* Zusatzfeld */
   long extra2;          /* Zusatzfeld */
   long result;          /* Ergebnisstatus der Operation */
   char name[MAX_PATH];  /* Dateiname */
   char data[BUF_SIZE];  /* Datenpuffer, wird nur benutzt
                            bei READ und WRITE */
};
```

Abbildung 11.6: header.h

Exemplarisch ist in Abbildung 11.8 eine Client-Prozedur angegeben, die mit Hilfe des Servers eine Datei kopiert. Der Funktion `copy` werde dabei Zeiger `src` und `dst` auf die Dateinamen übergeben. Die Bestandteile der Datei werden paketweise vom Server eingelesen und anschließend wieder an diesen zurückgesendet.
Zur Abstraktion des Programms soll überlegt werden, wann der Server blockiert ist. Dies geschieht zunächst beim Aufruf von `receive`. Der Prozeß wartet auf eine Anfrage. Mit dem `send` nach Bearbeitung der Anfrage erfolgt eine weitere Blockierung für die Dauer der Übertragung. Den genauen Ablauf mit den entsprechenden Blockierungsphasen auf Client- und Serverseite entnimmt man Abbildung 11.9

Adressierung: In diesem Beispiel war der Client die Adresse des Servers dadurch bekannt, daß sie als Konstante in der Datei header.h enthalten war. Von einer solchen Voraussetzung kann nicht immer ausgegangen werden. Es ergibt sich ein Adressierungsproblem. Im Sinne

```
#include <header.h>

void main(void)     /* Es handelt sich um einen Prozeduraufruf. Es
                       werden weder Parameter übergeben noch erwartet. */
struct message m1,m2;     /* eintreffende und ausgehende Nachrichten */
int r;                    /* Ergebniscode */

initialize();             /* wird spaeter fuer dyn. Binden gebraucht */
while (true) {            /* permanente Schleife */
   receive (FILE_SERVER,&m1);
                          /* für FILE_SERVER ankommende Nachricht wird
                          in Puffer m1 kopiert. Blockierung, bis
                          Nachricht angekommen und kopiert ist. */
   switch (m1.opcode){    /* Fallunterscheidung für Operation von m1 */
     case CREATE: r=do_create(&m1,&m2);    break;
     case READ:   r=do_read(&m1,&m2);      break;
     case WRITE:  r=do_write(&m1,&m2);     break;
     case DELETE: r=do_delete(&m1,&m2);    break;
     default:     r=E_BAD_OPCODE;
   }
   m2.result=r;           /* Ergebniscode wird der ausgehenden
                             Nachricht zugewiesen */
   send(m1.source,&m2);   /* sende Antwort; Blockierung des Servers,
                                bis die Nachricht verschickt ist */
   }
}
```

Abbildung 11.7: server.c

```
#include <header.h>      /* gleiche Definition wie beim Server */

int copy(char *src, char *dst)
{
   struct message m1;     /* Nachrichtenpuffer */
   long position=0;            /* aktuelle Dateiposition */
   long client=110;            /* Adresse des Client */
   initialize ();              /* bereite Ausführung vor */

   do {
     /* lies einen Datenblock aus der Quelldatei */
     m1.opcode=READ;      /* als Operation wird Lesen definiert */
     m1.offset=position;  /* setzen der aktuellen Dateiposition */
     m1.count=BUF_SIZE;   /* def., wieviele Bytes auf einmal
                          gelesen werden sollen */
     strcpy(m1.name,src);/* kopiere Dateinamen in Nachricht m1 */
     send(FILE_SERVER,&m1);    /* sende Nachricht an Dateiserver */
     receive(client,&m1);/* warte blockiert auf die Antwort */

     /* schreibe die empfangenen Daten in die Zieldatei */
     m1.opcode=READ;      /* Operation ist Lesen */
     m1.offset=position;  /* aktuelle Dateiposition */
     m1.count=BUF_SIZE;   /* wieviele Bytes sollen gelesen werden */
     strcpy(m1.name,src);/* kopiere Dateinamen in Nachricht */
     send(FILE_SERVER,&m1);
     receive(client,&m1);
     position+=m1.result /* m1.result ist Anzahl geschriebener Bytes */
   } while (m1.result>0); /* wiederhole, bis alle Pakete übertragen,
                             oder Fehler aufgetreten sind */
   return (m1.result);    /* gebe OK oder Fehlercode zurück */
}
```

Abbildung 11.8: client.c

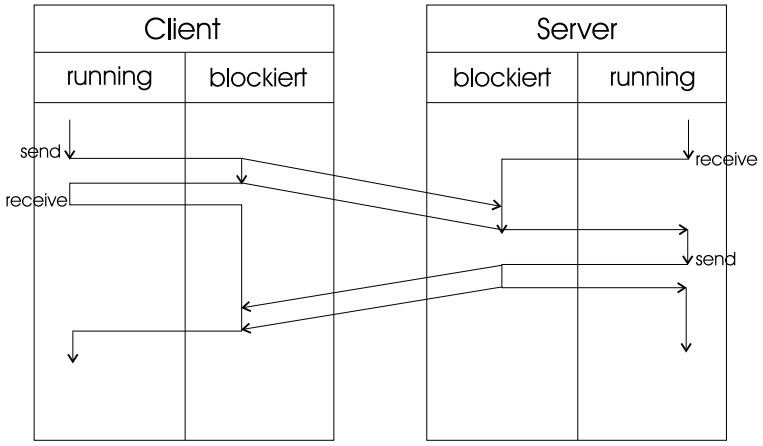

Abbildung 11.9: Blockierende Kommunikationsprimitive

einer föderativen Namensverwaltung sollte bei der Adressierung unterschieden werden zwischen Prozeß und Zielrechner. Als Alternative zu der absoluten Angabe ist es daher sinnvoll den Namen in 2 Teile aufzuspalten. Zum Beispiel stünde 4@243 oder 243,4 für Prozeß 4 auch Rechner Nummer 243. Der Ablauf der Kommunikation ist bei diesem Verfahren besonders einfach. Er besteht nur aus zwei Schritten:

1. Der Anfrage an den Server und

2. dessen Antwort an den Client.

Der Nachteil dieser *machine.process-Adressierung* und ihrer zahlreichen Variationensmöglichkeiten besteht darin, dass der Nutzer wissen muß, auf welchem Rechner der Server platziert ist, d.h. es ist keine Ortstransparenz der Server mehr vorhanden. Damit ist ein wesentliches Ziel bei der Entwicklung Verteilter Systeme verlorengegangen.
Ein anderer Ansatz sieht ein spezielles Lokalisierungspaket vor, das der Sender an alle andern Rechner schickt. Das Lokalisierungspaket enthält die Adresse des Zielprozesses oder eine Bezeichnung des gesuchten Prozesses (Dienstes). Insbesondere für LANs , welche echtes Broadcast bereitstellen, wäre ein *"Lokalisierung-durch-Broadcast"*-Verfahren denkbar. Dieses Vorgehen sichert zwar die Ortstransparenz, verursacht durch den Broadcastaufruf jedoch zusätzliche Netzlast. Der Ablauf wird auf 4 Schritte ausgedehnt:

1. Broadcasten des Lokalisierungspakets,

2. "Ich bin hier "-Antwort des Servers,

3. Anfrage an den Server und

4. Antwort des Servers.

Eine Weiterentwicklung auf diesem Gebiet ist die Einführung eines *Name-Servers* oder *Traders*. Diese Begriffe unterscheiden sich leicht, da ein Trader i.d.R. etwas komfortabler ist. Das Prinzip sieht in beiden Fällen folgenden Ablauf vor:

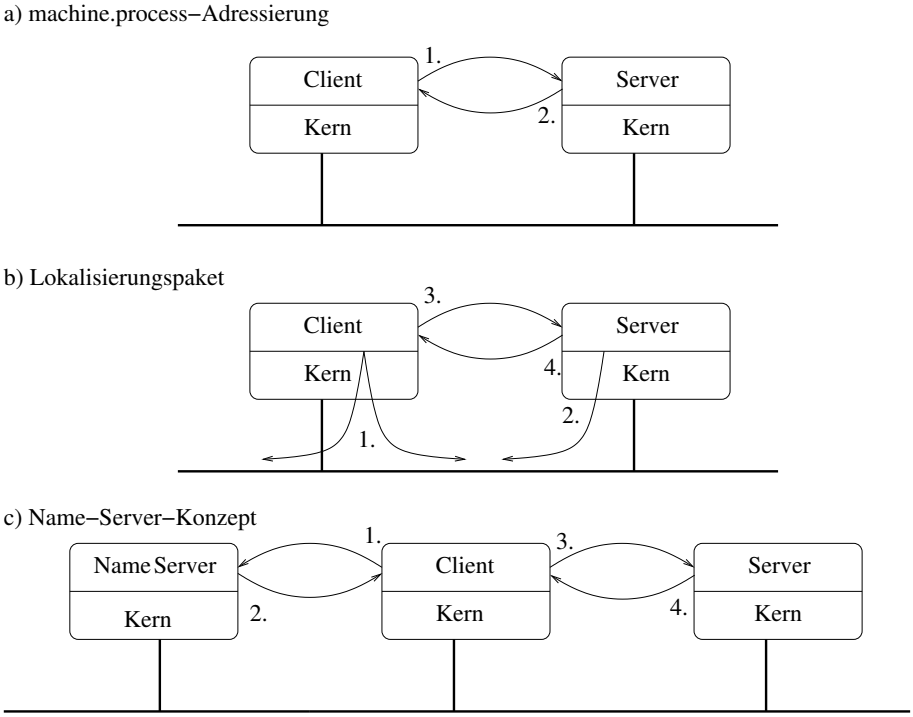

Abbildung 11.10: Varianten der Adressfindung

1. Zunächst erfolgt eine Anfrage des Clients an den Name-Server nach der Adresse des gewünschten Servers. Ein Trader wird alternativ nach einem bestimmten Prozeß oder Dienst gefragt.

2. Der Name-Server (Trader) übermittelt die Adresse an den Client.

3. Mit Hilfe dieser Adresse kann der Client nun die ursprüngliche gewünschte Anfrage stellen.

4. Der adressierte Server antwortet auf die Anfrage.

Bei Vorhandensein eines Traders kann dem Client auch bei unvollständigen Angaben ein Dienst vermittelt werden. Die Dienstvermittlung erfordert jedoch zahlreiche neue Mechanismen, Siehe [SPA94].

Blockierung: Bei Kommunikationsprimitiven unterscheidet man zwischen blockierenden (synchronen) und nichtblockierenden (asynchronen) Primitiven. Der Systementwickler wählt zwischen diesen beiden Arten. Bei blockierenden Primitiven wird der Prozeß während der Sendung einer Nachricht blockiert, d.h. Anweisungen werden erst dann weiter abgearbeitet, wenn die Nachricht vollständig abgesendet ist. Analog endet die Blockierung beim Empfangen erst, nachdem die Nachricht angekommen und kopiert ist. Die in Abbildung 11.6 bis Abbildung 11.8 vorgestellte Implementierung basierte auf der Verwendung von blockierenden Primitiven. Bei *nichtblockierenden Primitiven* wird die zu sendende Nachricht zunächst nur in einen Puffer der Betriebssystems kopiert. Direkt im Anschluß daran, also noch vor

der eigentlichen Sendung, erfolgt die Entblockierung. Der sendende Prozeß kann parallel zur Nachrichtenübertragung mit seiner Ausführung fortfahren. Dieser Geschwindigkeitsvorteil wird jedoch dadurch erkauft, daß der Sender nicht weiß, wann die Übertragung beendet ist und wann er wieder den Puffer nutzen kann. Darüber hinaus kann er den einmal beschriebenen Puffer auch nicht mehr verändern. Die Definition *synchroner* und *asynchroner Primitive* unterscheiden sich je nach Autor. An einigen Stellen wird immer dann von synchronen Primitiven gesprochen, wenn der Sender blockiert ist, bis der Empfänger den Erhalt der Nachricht bestätigt hat.

Pufferung: Auch bezüglich der Pufferung gibt es zwei Möglichkeiten, Primitive zu realisieren. Bisher wurde immer von *ungepuffertern Primitiven* ausgegangen. `receive(addr,&mp)` informiert den Kern seiner Maschine, daß der aufrufende Prozeß die Adresse `addr` abhören will und bereit ist, Nachrichten von dort zu empfangen. Einen Puffer stellt er an der Adresse `&mp` bereit. Wann kann es bei diesem Vorgehen zu Problemen kommen? Schickt der Client erst ein `send` oder der Aufruf von `receive` durch den Server erfolgt zu einem späteren Zeitpunkt, so weiß der Kern bei einer ankommenden Nachricht nicht, ob einer seiner Prozesse die Adresse dieser Nachricht benutzen wird und wohin er ggf. die Nachricht kopieren soll. Der Client kann in diesem Fall einen Verlust des Aufrufes nicht ausschließen. Eine mögliche Implementierung könnte daher ein wiederholtes `send` nach Ablauf eines Timers im Client vorsehen. Nutzen mehrere Clients die gleiche Adresse, so können weitere Probleme auftreten. Nachdem der Server eine Nachricht von einem Client angenommen hat, hört er solange seine Adresse nicht mehr ab, bis er seinen Auftrag erledigt hat und den nächsten `receive`-Aufruf ausführt. Falls die Erledigung eines Auftrags länger Dauert, können andere Clients eine Reihe von Versuchen Unternehmen, an den Server zu senden. Dabei können manche von ihnen bereits aufgegeben haben, je nachdem wie viele Versuche sie unternehmen bzw. wie "ungeduldig" sie sind.

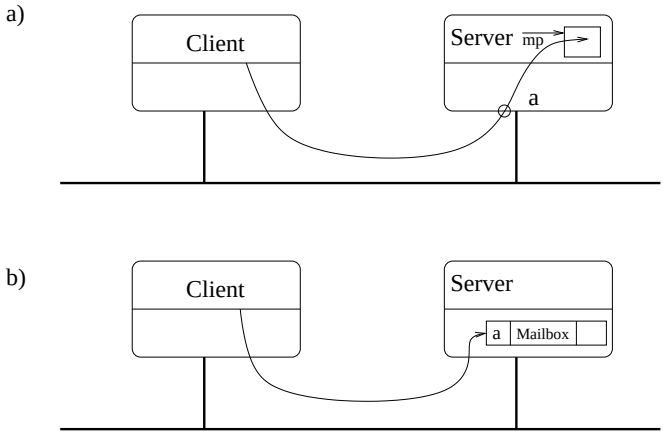

Abbildung 11.11: ungepufferte und gepufferte Primitive

Eine Alternative Implementierung, welche die genannten Probleme zu umgehen versucht, sind die gepufferten Primitive. Ein empfangender Kern speichert die eintreffenden Nachrichten für einen bestimmten Zeitraum zwischen. Wird keine passendes `receive` aufgerufen, so werden Nachrichten nach einem Timeout gelöscht, es müssen Puffer vom Kern bereitgestellt und verwaltet werden. Eine konzeptionell einfache Lösung sieht die Definition einer Daten-

strukturmailbox vor. Ein Prozeß, welcher Nachrichten empfangen will, fordert den Kern auf, eine Mailbox für ihn zu Erzeugen und gibt die Adresse an, mit der in eintreffenden Netzwerkpakten nachgesehen werden soll. Bei einem `receive` wird eine Nachricht aus der Mailbox geholt. Ist die Mailbox leer, so wird der Prozeß blockiert. Probleme treten nur bei volle Mailbox auf. In diesem Fall werden Aufrufe wie im ungepufferten Fall verworfen.

Zuverlässigkeit: Für eine Weiterklassifizierung der Primitive nach dem Grad ihrer Zuverlässigkeit bietet sich eine Einteilung in drei grobe Klassen an.

1. Primitive, welche nach dem "Prinzip der Deutschen Bundespost" vorgehen: Abschicken, der Rest ist egal.

2. Primitive, bei denen der empfangende Kern eine individuelle Bestätigung an den Sender zurückschicken muß.

3. Primitive, welche die Bestätigung per piggy-backing übertragen. Dabei macht man sich das Wissen zunutze, dass der Server i.d.R. auf einen Anfrage in einem eng gesteckten Zeitrahmen antworten wird, siehe auch Abbildung 11.12

Eine Kombination der beiden letztgenannten Möglichkeiten sieht vor, daß vom piggy-backing auf individuelle Bestätigung übergegangen wird, falls der gesteckte Zeitrahmen überschritten wird.

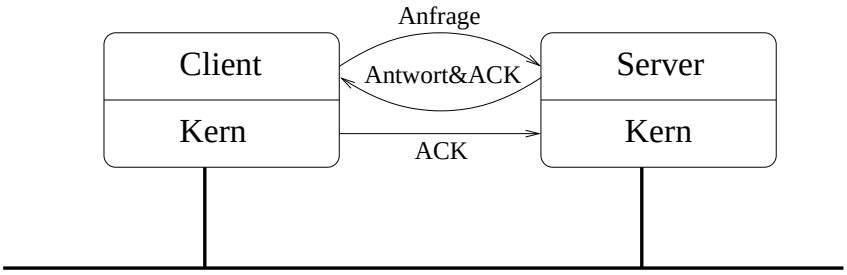

Abbildung 11.12: Bestätigung mittels piggy-backing

Insgesamt ergeben sich vier Entwurfsmöglichkeiten: Adressierung, Blockierung, Pufferung und Zuverlässigkeit. Diese können in ihren verschiedenen Ausprägungen kombiniert werden. Bei der Kombination sollte jedoch beachtet werden, daß es mehr und weniger sinnvolle Möglichkeiten gibt. Die Verwendung von blockierenden und ungepufferten Primitiven ist ebenso sinnvoll wie die Verwendung von nichtblockierenden, gepufferten Primitiven. Es ist jedoch nicht sinnvoll, ungepufferte und nichtblockierende oder gepufferte und blockierende Primitive zu verwenden, da im ersten Fall (ungepuffert, nichtblockierend) das entscheidende Fehlerrisiko zu hoch ist, und im zweiten Fall(gepuffert, blockierend) eine nicht notwendige, zu lange Übertragungszeit entsteht.

11.2.2 Der Remote Procedure Call

Das Client/Server-Modell bietet einen brauchbaren Weg, ein verteiltes Betriebsystem zu strukturieren. Trotzdem hat es eine extreme Schwachstelle: Das Basisparadigma auf dem alle Kom-

munikation aufbaut, ist die Ein- und Ausgabe von Daten; `send` und `receive` organisieren jedoch den Austausch von Daten, um das Ziel, verteilte Berechnungen für den Benutzer genau so aussehen zu lassen wie zentrale Berechnungen, zu erreichen, sind komfortablere Mechanismen notwendig. Ein Vorschlag von Birell und Nelson aus dem Jahr 1984 besteht darin, daß ein Programm ein Unterprogramm aufrufen können soll, welches sich auf einem anderen Rechner befindet. Diese Methode ist als *entfernter Unterprogrammaufruf (remote procedure call, RPC)* bekannt. Ruft ein Prozeß auf Rechner A ein Unterprogramm auf Rechner B auf, so wird der aufrufende Prozeß A ausgesetzt (suspendiert), und die Ausführung des aufgerufenen Unterprogramms findet auf Rechner B statt. Dabei werden Parameter ausgetauscht. Für den Programmierer bleibt dieser Nachrichtenaustausch jedoch unsichtbar. Das Konzept bringt eine Vielzahl an Problemen mit sich, welche einzeln gelöst werden müssen. Um die Komplexität der Konzepte zu reduzieren, soll im folgenden dreistufig vorgegangen werden. Zunächst wird das klassische Konzept des lokalen Unterprogrammaufrufs wiederholt, im zweiten Schritt wird der entfernte Prozeduraufruf in seiner einfachsten, grundlegenden Form vorgestellt und schließlich werden im dritten Schritt Besonderheiten des RPC´s diskutiert und Erweiterungen vorgenommen.

Konventionelle lokale Prozeduraufrufe. Es wird zunächst ein konventioneller Unterprogrammaufruf `count = read(fd, buf, nbytes);` betrachtet: In einem traditionellen System wird `read` aus einer Bibliothek entnommen und durch den Binder in das ausführbare Programm eingebunden. Die Routine `read` ist i.d.R. ein in Assembler geschriebenes Unterprogramm, das nur seine Parameter in Register kopiert und den Systemaufruf READ ausführt, d.h. der Kern wird mit dem Lesen der Daten beauftragt wodurch im Kern eine Ausnahmebehandlung ausgelöst wird. Die Routine *read* kann somit als Schnittstelle zwischen Benutzerprogramm und Betriebsystem verstanden werden. Vor dem Aufruf von `read` im Hauptprogramm enthält der Stack die lokalen Variablen, siehe Abbildung 11.13 a). Für den Aufruf werden die Parameter i.d.R. in umgekehrter Reihenfolge auf dem Stack abgelegt, siehe Abbildung 11.13 b). Zusätzlich findet noch die Rücksprungadresse Platz.

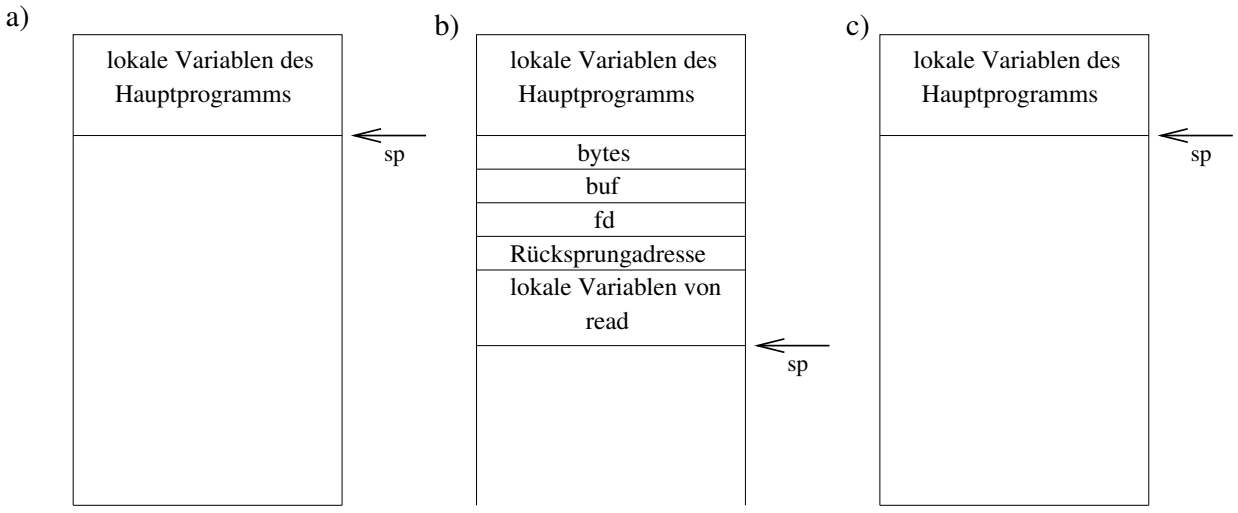

Abbildung 11.13: Stack bei lokalem Prozeduraufruf

Im Anschluß daran wird das Unterprogramm ausgeführt und der Ergebniswert in ein Register übertragen. Die Rücksprungadresse wird vom Stack entfernt und die Kontrolle geht wieder an den Anrufer. Dieser nimmt auch die Parameter vom Stack. Der Stack hat dann wieder den ursprünglichen Zustand, siehe Abbildung 11.13 c). Bei Unterprogrammaufrufen unterscheidet man zwischen Wert- (call-by-value) und Referenzparametern (call-by-reference), je nachdem ob es sich um einen Datenwert oder einen Zeiger auf ein Datum handelt.

Der entfernte Prozeduraufruf. Ist `read` nun ein entferntes Unterprogramm, so ist für diesen Fall eine "andere Version" von `read`, eine sogenannter Client-Stub in der Bibliothek enthalten. Der Aufruf erfolgt analog zum obigen Fall, und es wird wiederum eine Ausnahmebehandlung ausgelöst. Anders als beim Original werden die Parameter nicht in Register kopiert, und der Kern wird nicht damit beauftragt, die gewünschten Daten zu lesen. Statt dessen werden die Parameter in eine Nachricht verpackt und der Kern durch das Send-Primitiv beauftragt, die Nachricht an den Server zu schicken. Im Anschluß daran ruft der Client-Stub ein `receive` auf und blockiert sich solange, bis eine Antwort eintrifft. Trifft die Nachricht beim Server ein, so übergibt der Kern diese an den sogenannten Server-Stub, der an den aktuellen Server gebunden ist. I.a. hat der Server-Stub gerade ein `receive` aufgerufen und wartet auf ankommende Nachrichten. Der Server-Stub packt dann die in der Nachricht enthaltenen Parameter aus und ruft das Unterprogramm lokal auf. Parameter und Rücksprungadresse werden wie gewohnt abgelegt. Es erfolgt die Ausführung und die Rückgabe der Ergebnisse an den Server-Stub. Erhält der Server-Stub die Kontrolle zurück, so verpackt er die Ergebnisse, d.h. den Puffer, erneut in eine Nachricht, die er mittels `send` an den Client schickt. Zum Abschluß ruft er wieder `receive` auf und ist damit bereit, die nächste Nachricht zu empfangen. Erreicht die Antwort des Servers den Client, wird sie in einen entsprechenden Puffer kopiert und der Client-Stub wird entblockiert. Dieser prüft die Nachricht und packt sie aus. Dann schiebt er sie auf den Stack. Wenn der Aufrufer von `read` die Kontrolle zurückerhält, so ist ihm nur bekannt, daß die Daten vorliegen, nicht aber, daß ein Aufruf entfernt ausgeführt wurde. Diese Transparenz zeichnet den RPC aus.
Auf diese Art können entfernte Dienste durch einfache, d.h. lokale UP-Aufrufe ausgeführt werden. Dies erfolgt ohne explizite Anwendung der Kommunikationsprimitive. Alle Details sind durch zwei Bibliotheksroutinen verborgen (den Client- und den Server-Stub), analog zum Verbergen von Ausnahmebehandlungen durch traditionelle Bibliotheken.
Zusammenstellung der einzelnen Schritte:

1. Der Client ruft ein Unterprogramm im Client-Stub auf.
2. Der Client-Stub erzeugt eine Nachricht und übergibt sie an den Kern.
3. Der Kern sendet die Nachricht an den entfernten Kern.
4. Der entfernte Kern übergibt die empfangene Nachricht dem Server-Stub.
5. Der Server-Stub packt die Parameter aus und ruft ein Unterprogramm im Server au.
6. Der Server führt das Unterprogramm aus und übergibt der Server-Stub die Ergebnisse.
7. Der Server-Stub verpackt die Ergebnisse in einer Nachricht und übergibt sie seinem Kern.

8. Der entfernte Kern sendet die Nachricht an den Kern des Client.

9. Der Client -Kern übergibt die Nachricht an den Client-Stub.

10. Der Client-Stub packt die Ergebnisses aus und übergibt sie dem Client.

Hierbei wird der entfernte Prozeduraufruf auf die lokalen Aufrufe 1 und 5 zurückgeführt.

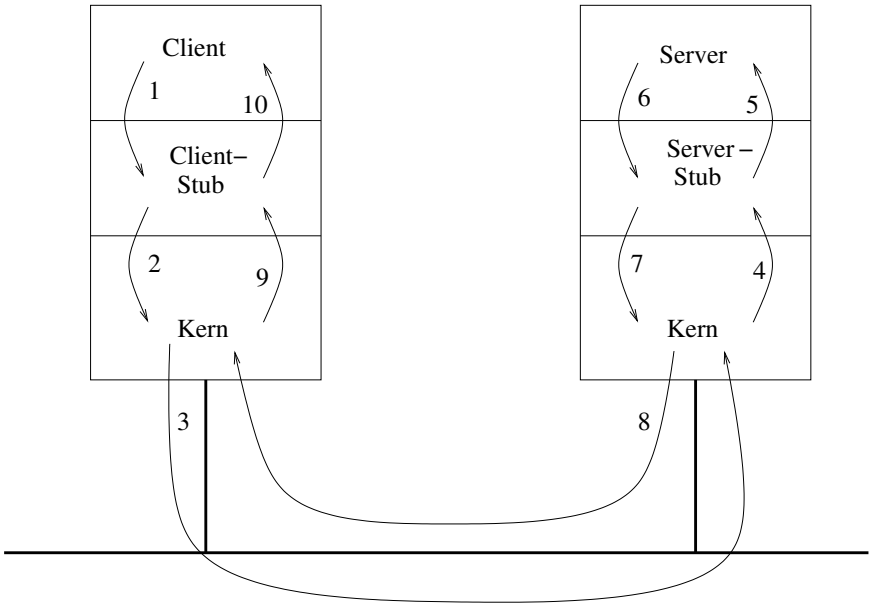

Abbildung 11.14: Ablauf eines RPCs

Erweiterungen des entfernten Prozeduraufrufs: Der Client besitzt die Aufgabe, Parameter entgegenzunehmen, sie in eine Nachricht zu verpacken und diese an den Server-Stub zu senden. Hierbei tritt eine ganze Reihe von Problemen auf, welche im folgenden vorgestellt werden. Für die Parameterübergabe ist zunächst das Verpacken der Nachricht, das sogenannte (parameter)marshalling notwendig. Ein Aufruf der Art n=sum(4,7) wird dabei in eine Nachricht der Form:

sum
4
7

übersetzt. Neben den Parametern 4 und 7 fügt der Client-Stub auch den Namen “sum”(bzw. eine synonyme Nummer) des aufzurufenden Unterprogramms in die Nachricht ein, damit der Server weiß, welches Unterprogramm von ihm ausgeführt werden soll. Solange die C/S-Rechner identisch sind und Parameter skalaren Typs ausgeführt werden, arbeitet dieses Modell gut. Probleme gibt es bei heterogenen Rechnertypen mit unterschiedlichen Zeichencodierungen oder Zahlendarstellungen. Ein störendes Problem ist beispielsweise, daß in anderen Rechnern die umgekehrte Reihenfolge verwendet wird. Die Folge ist, daß z.B. die Bytes zur Darstellung eines großen Integerwertes, in unterschiedlicher Reihenfolge gespeichert werden.

In dem Buch “Gullivers Reisen” ist von zwei Politikern die Rede, welche einen Krieg darüber begannen, an welchem Ende ein Ei aufzuschlagen sei. In Anlehnung an die dort verwendeten Bezeichnungen nennt man das INTEL-Format, bei dem die Bytes von rechts nach links nummeriert werden auch **little endian**. Das SPARC-Format, bei dem umgekehrt verfahren wird, kann demnach mit **big endian** bezeichnet werden.
Da ein Unterprogramm mit n Parametern aus (n+1) Feldern besteht, kann durch die Identifizierung des (n+1)ten Feldes abgeleitet werden, welches Format verwendet wird. Aus den Typinformationen für die Parameter können ggf. notwendige Konvertierungen abgeleitet werden. Um die Darstellung einheitlich zu gestalten, fordert man häufig eine kanonische Darstellung, die von allen Sendern beim Einpacken der Nachrichten eingehalten werden muß. Ein Verfahren, bei dem beispielsweise stets liltle endian verlangt wird kann sich jedoch als störend und ineffizient herausstellen, falls zwei big endian Rechner miteinander kommunizieren. Es muß zweimal konvertiert werden, obwohl dies nicht notwendig wäre. Alternativ benutzt der Client sein internes Format und gibt im ersten Byte an, um welche Darstellung es sich dabei handelt. Der Server kann dann überprüfen, ob eine Übereinstimmung mit seinem internen Format vorliegt und leitet, falls notwendig eine Konvertierung in die Wege.

Dynamisches Binden

In einem Verteilten System ist es möglich, dass sich aufgrund bestimmter Ereignisse die Adresse eines Servers bzw. seiner Schnittstelle ändert. Dies hätte zur Folge, daß zahlreiche Programme neu geschrieben und übersetzt werden müssten. Statt dessen benutzt man den Mechanismus des *dynamischen Bindens*. Ausgangspunkt hierfür ist eine formale Spezifikation des Servers, z.B. in folgender Form:

Programm 9 Formale Spezifikation eines Servers

```
1       #include<header.h>
2         specification of file server, version 3.1;
3         long read (in char name[MAX_PATH],out char buf[BUF Size],
4                        in long Bytes, in Long Position);
5             long write (in char name...);
6             int create(...);
7             int delete(...);
8          end;
```

Diese Spezifiktion enthält:

little endian

Adresse	10	9	8	7	6	5	4	3	2	1
Inhalt	T	N	E	I	L	C	0	0	0	5

big endian

Adresse	1	2	3	4	5	6	7	8	9	10
Inhalt	T	N	E	I	L	C	0	0	0	5

Tabelle 11.2: Der String CLIENT und der Integerwert 5 in INTEL- und SPARC-Format

– den Namen des Servers (im Programm 6 ein file-server)

– die Versionsnummer (3.1)

– eine Liste von Unterprogrammen (read, write,...), die der Server anbietet.

Für alle Unterprogramm werden die Typen der Parameter angegeben. Diese Typen beziehen sich auf den Server, d.h.

– Ein in-Parameter (wie z.B. name) wird vom Client an den Server gesendet. Name teilt dem Server mit, welche Datei gelesen, geschrieben o.ä. werden soll, bytes und position bedeuten, wie viel Bytes von welcher Position an gelesen werden sollen.

– Ein out-Parameter wird vom Server an den Client gesendet, z.B. verweist buf auf die Adresse, an die der Server die Daten ablegt, die der Client angefordert hat.

– Außerdem gibt es in/out Parameter, die vom Client an den Server gesendet werden, dort modifiziert und schließlich an den Client zurückgesendet werden.

Dem Client-Stub ist bekannt, welche Parameter er an den Server senden muß, dem Server-Stub ist bekannt, welche er zurücksenden muß. Die formale Spezifikation wird einem sogenannten *Stub-Generator* eingegegeben, der daraus sowohl Client- als auch Server-Stub erzeugt. Beide Stubs werden anschließend in entsprechenden Bibliotheken abgelegt. Ruft der Client ein Unterprogramm auf, so wird das dazugehörige Client-Stub Unterprogramm dazugebunden. Dies geschieht zur Laufzeit mit der aktuellen Adresse des zuständigen Servers und anderen Parametern; es sind allerdings auch Variationen dieses Verfahrens möglich. Der Server-Stub wird analog bei der Übersetzung des Server-Codes hinzugebunden. Zu Beginn einer Serverausführung erfolgt (beim dynamic-binding) der Aufruf von *initialize()* dieser bewirkt das Exportieren der Schnittstelle des Servers. Der Server sendet hierzu eine Nachricht an ein Programm, das *Binder* genannt wird, und gibt damit sein Existenz bekannt. Man bezeichnet diesen Vorgang als *Registrierung des Servers*, dabei übergibt der Server dem Binder:

– seinen Namen,

– die Versionsnummer sowie ggfs. einen eindeutigen Bezeichner und

– ein sog. *Handle*, das zur Lokalisierung des Servers dient, z.B. Ethernet oder IP-Adresse

Möchte der Server keinen Dienst mehr anbieten, so lässt er sich “entregistrieren”. Mit diesen Voraussetzungen ist Dynamisches Binden möglich, das folgendermaßen geschieht:

– der Client ruft zu ersten mal ein entferntes UP, z.B. read, auf.

– der Client-Stub erkennt daraufhin, dass der Client an noch keinen Server gebunden ist.

– der Client-Stub sendet eine Nachricht an den Binder, um z.B. Version 3.1 der Schnittstelle file-server zu importieren.

Der Binder überprüft, ob (ein oder mehrere) Server eine Schnittstelle mit diesem Namen und der entsprechenden Versionsnummer exportieren. Ist das nicht der Fall, so schlägt die Operation fehl. Falls andererseits ein passender Server existiert, so liefert der Binder das

Handle und den eindeutigen Bezeichner an den Client-Stub zurück. Der Client-Stub benutzt das Handle als Adresse, an die er die Anfragenachricht sendet. Die Nachricht enthält die Parameter und den eindeutigen Bezeichner, mit dem der richtige Server ausgewählt wird, falls mehrere existieren. Der Vorteil *dynamischen Bindens* ist die hohe Flexibilität. Der Binder kann:

- den Server in regelmäßigen Abständen überprüfen und ggfs. entregistrieren,
- bei identischen Servern und Clientanfragen die Auslastung steuern(*load balancing)*
- Authentifikation unterstützen.

Demgegenüber hat das dynamische Binden aber auch Nachteile:

- Es bedeutet zusätzlichen Aufwand für das Im- und Exportieren von Schnittstellen.
- In großen Systemen kann der Binder zum Engpaß werden, so daß mehrere Binder benötigt werden. Dies führt dazu, daß beim Registrieren und Entregistrieren viele Nachrichten verschickt werden müssen.

Solange sowohl Client als auch Server fehlerfrei funktionieren, erfüllt der RPC seine Aufgabe sehr gut. Treten jedoch Fehler auf, so gibt es Unterschiede zwischen lokalem und entfernten Aufruf. Man Unterscheidet fünf Klassen von Fehlerquellen in RPC-Systemen:

1. **Client kann Server nicht lokalisieren.** Z.B. weil kein passender Server ausgeführt wird (Versionsproblem o.ä.). Lösungsmöglichkeiten:
   - Fehlertyp anzeigen lassen und reagieren oder
   - Ausnahmebehandlung auslösen.
2. **Anfragenachricht vom Client an Server geht verloren.** Ist einfach zu lösen: Kern wiederholt Anfrage nach einem Timeout.
3. **Der Server fällt nach Erhalt einer Anfrage aus.** Hierbei müssen wie man in Abbildung 11.15 sehen kann, drei Fehler unterschieden werden:

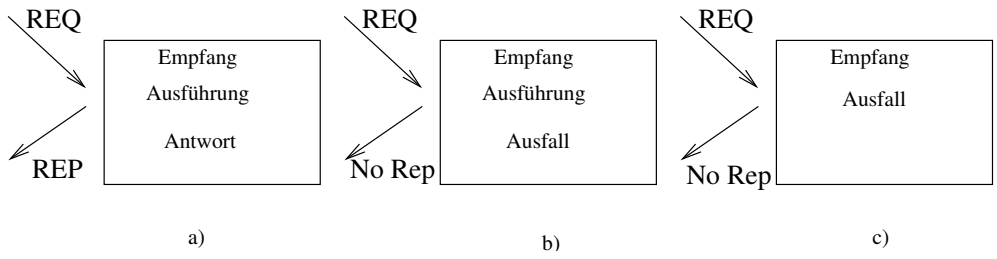

Abbildung 11.15: Serverausfall nach Erhalt einer Anfrage

   (a) ist Normalfall
   (b) ist gleichbedeutend damit, daß die Anfrage nie angekommen ist (→ Wiederholung),

(c) bedingt, dass der Fehler dem Client gemeldet werden muß.

ABER: Wie soll der Client (b) und (c) unterscheiden?

4. **Antwort von Server an Client geht verloren.** Ist schwieriger als Fall 2): man unterscheidet *idempotente* und *nicht idempotente Nachrichten*. Eine *idempotente Nachricht* kann beliebig oft wiederholt werden, ohne daß sich das Ergebnis ändert, etwa das Lesen der ersten 1024 Bytes einer Datei. Das Ergebnis einer *nicht idempotenten Nachricht* ist von der Anzahl des Eintreffens einer Nachricht Abhängig, z.B. das Überweisen von 1000 Euro auf ein Konto. Es dürfen nur *idempotente Nachrichten* wiederholt werden, d.h. man muß eine Sequenznummer beim Senden einfügen oder zwischen Original und Wiederholung unterscheiden.

5. **Der Client fällt aus, nachdem eine Anfrage gestellt wird.** Dann wird die Berechnung ausgeführt, obwohl niemand auf eine Antwort wartet ("verwaiste Berechnung"). Dies verschwendet Rechenzeit und kann zu Konfusionen führen, wenn der Client danach eine neue Anfrage startet und darauf das alte Ergebnis eintrifft. Für dieses Problem gibt es vier Lösungen von Nelson :

   – *Ausrottung:* Eine externe Protokollierungsdatei terminiert Waisen nach Neustart.
   – *Reinkarnation:* Jeder Neustart bestimmt eine neue Epoche (linear aufsteigend).
   – *sanfte Reinkarnation:* In einer neuen Epoche wird versucht, im verteilten System entfernte Besitzer zu finden.
   – *Verfallszeitpunkte:* Feste Zeitdauern T werden vereinbart, in den eine Antwort da sein muß oder erneut angefordert werden muß

Implementierungsaspekte

Zugrundeliegende Konzepte und die Art ihrer Implementierung bestimmen die Leistungsfähigkeit eines Verteilten Systems und dessen Erfolg.

– Soll man verbindungslose oder verbindungsorientierte Protokolle nutzen? Der Vorteil verbindungsorientierter Protokolle liegt in der starken Vereinfachung der Kommunikation, d.h. wenn der Kern eine Nachricht sendet, so braucht er sich nicht darum zu kümmern, ob diese verloren geht und kann den Austausch von Bestätigungen erledigen. Diese Sicherung wird von der Software auf niedriger Ebene erledigt. Durch zusätzliche Software geht auch Leistungsfähigkeit verloren. Man entscheidet sich daher bei einem relativ sicheren Netz für verbindungslose Protokolle.

– Soll man die Protokolle RPC-Spezifisch entwickeln oder allgemeine Standards nutzen? In der Regel benutzen Verteilte Systeme IP (oder UDP, das auf IP aufbaut) als Basisprotokoll. Dabei macht man sich den Vorteil zunutze, dass dieses Protokoll bereits existiert und somit keine Entwicklungsarbeit mehr investiert werden muß. Im übrigen können die Pakete von fast allen UNIX Systemen gesendet, empfangen und über viele Netze übertragen werden.

– Wie soll Bestätigung geregelt werden? Hierfür gibt es verschieden Möglichkeiten:

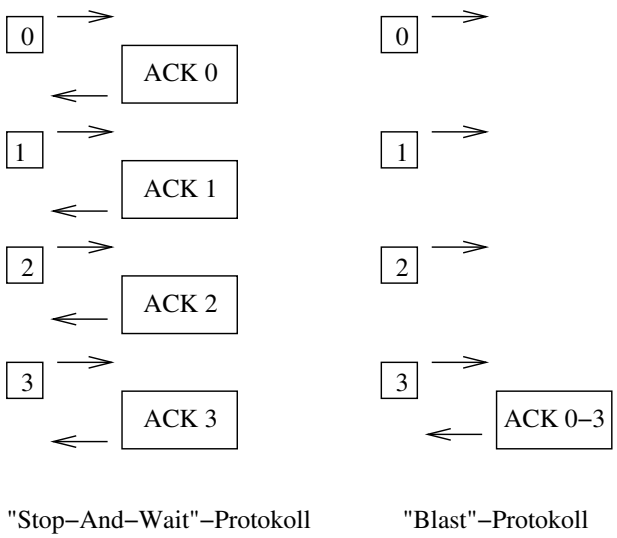

Abbildung 11.16: Möglichkeiten zur Bestätigung

Bei Stop-and-wait braucht das fehlerhafte Protokoll einfach nur wiederholt zu werden, beim Blast- Protokoll muß eine Entscheidung getroffen werden, ob komplett neu übertragen wird, oder ob man zwischenspeichert und das fehlerhafte Paket neu anfordert (*selective repeat*). *Selective repeat* ist nur mit großem Aufwand zu implementieren, senkt aber die Netzbelastung.

– Wie sieht die Flusskontrolle aus? Bei einer begrenzten Pufferkapazität können Pakete verloren gehen, wenn kurz aufeinanderfolgend viele Pakete eintrafen (*overrun error*, Überschreitungsfehler). Beim Stop-and-wait-Protokoll kann (im Gegensatz zum Blast-Protokoll) kein Überschreitungsfehler auftreten.

Kritische Pfade

Ein kritische Pfad (*critical path*) ist die Folge von Instruktionen, die bei jedem RPC ausgeführt werden. Dieser beginnt mit dem Aufruf des Client-Stubs durch den Client, geht dann über zum Kern, beschreibt die Nachrichtenübertragung, die Server-Seite, die Ausführungen des Unterprogramms und die Rückantwort. Genauer:

Client-Seite:

1. Im Client: Rufe Stub-Routine auf $\rightarrow$ Ab sofort Aktionen im Client-Stub.
2. Bereite Nachrichtenpuffer vor, d.h. erzeuge Puffer, um Anfragenachricht zusammenzustellen.
3. Verpacke die Parameter im Puffer. D.h. konvertiere sie in ein geeignetes Format
4. Fülle den Nachrichtenkopf aus.
5. Berechne die Prüfsumme.

6. Führe den Systemaufruf aus. → Ab sofort Aktion im Client-Kern.
   - Der Kern rettet den Inhalt des Prozessorregisters und der Adresstabelle, die er benutzt.
   - Die Nachricht wird in den Kern kopiert, da sie sich zur Verarbeitung in seinem Adressraum befinden muß.
   - Die Zieladresse wird bestimmt.
   - Die Adresse wird in den Nachrichtenkopf eingetragen.
   - Die Netzwerkschnittstelle wird initialisiert.
7. Füge das Paket zur Übertragung in die Warteschlange ein.
8. Übertrage das Paket über den Bus zu Steuerwerk.
9. Übertrage das Pakt über Ethernet.

→ Ende der Client-Seite.

Server-Seite:

1. Im Server-Kern: Hole Paket beim Steuerwerk ab.
2. Unterbrechungsbehandlungsroutine
3. Überprüfe, ob das Paket korrekt übertragen wurde, d.h. berechne die Prüfsumme
   - Entscheide, welcher Stub die Nachricht erhält.
   - Überprüfe, ob Stub wartet. Ansonsten wird die Nachricht abgelehnt oder zwischengespeichert.
   - Kopiere die Nachricht in den Server-Stub.
4. Kontextwechsel in den Server-Stub. → ab sofort Aktionen im Server-Stub.
5. Packe die Parameter aus, lege die Parameter auf dem Stack ab und rufe dann den Server auf.
   - Der Server führt den Auftrag aus.

Die Frage, die sich bei der Implementierung des RPC´s stellt, ist nun, welcher Teil des kritischen Pfades der aufwendigste ist, also am meisten Rechenzeit in Anspruch nimmt(siehe auch Abbildung 11.17. Die Schwachstellen müssen analysiert und dann die Ausführung optimiert werden. 1990 haben Schroeder und Burrows den kritischen Pfad einer Multiprozessorworkstation analysiert und zwar:

1. für einen “leeren RPC”, d.h. den aufruf eines entfernten Unterprogramms ohne Datenübertragung,
2. für einen RPC mit einem 1440 Byte-Feld als Parameter. Dieses Feld muß also verpackt und als Nachricht übertragen werden.

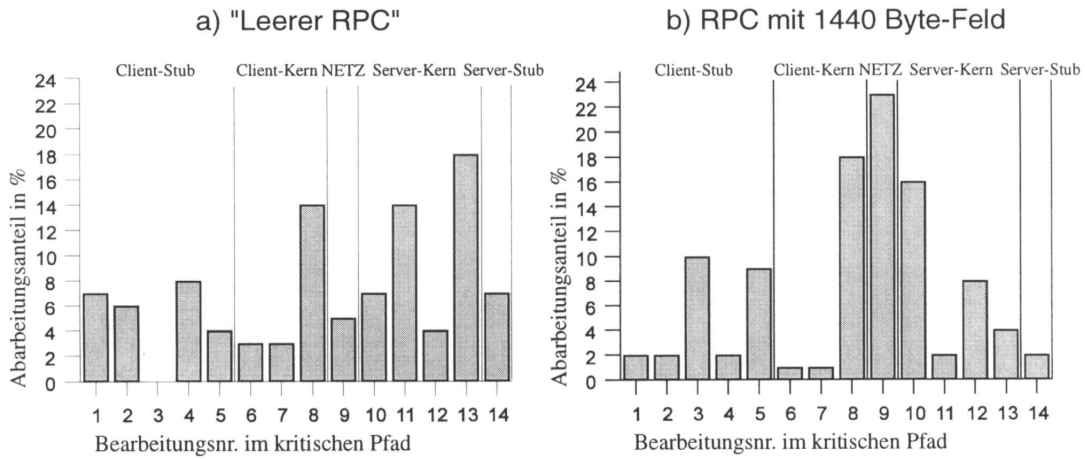

Abbildung 11.17: Analyse eines kritischen Pfades

Interpretation: Beim leeren RPC entstehen die meisten Kosten durch:

- den Kontextwechsel in den Server-Stub, d.h. Retten des Inhaltes von Prozessorregister und Adresstabelle und Laden der Benötigten Adresstabelle (Server-Seite 4.),
- die Unterbrechungsbehandlungroutine im Server-Kern (Server-Seite 2.) und
- das Übergeben des Paketes an die Netzwerkschnittstelle im Client-Kern(8.).

Beim 1440 “Byte-RPC” gibt es andere Engpässe:

- Die Paketübertragung über Ethernet (9.),
- das Übergeben des Paketes an die Netzwerkschnittstelle im Client-Kern (wie oben, 8.),
- Entnehmen des Paketes von der Netzwerkschnittstelle im Server-Kern.

Zu beachten ist allerdings, daß man diese Messergebnisse so nicht ohne weiteres verallgemeinern kann , da sie sich nur auf das zugrundeliegende Multiprozessorsystem beziehen. Die Messwerte basieren auf einer bereits angepassten Implementierung, die aber hinsichtlich gewisser Aspekte noch weiter verbessert werden kann:

- Das *Kopieren* von Daten beeinflusst die Ausführungszeit eines RPC´s ganz wesentlich. Man wird sich also bemühen, einerseits so wenige Kopiervorgänge wie möglich zu benötigen und diese dann andererseits so effizient wie möglich zu gestalten. Im Idealfall wird die Nachricht aus dem Adressraum des Client-Stubs direkt auf das Netzwerk ausgegeben. (Kopiervorgang 1) und in Echtzeit in den Speicher des Server-Kerns abgelegt bzw. umgekehrt (Kopiervorgang 2). Im worst-case benötigt man 8 Kopiervorgänge. Durchschnittlich benötigt das Kopieren eines 32-Bit-Wortes etwas 500 Nanosekunden, d.h. man benötigt etwa 4 Mikrosekunden bei 8 Kopiervorgängen (unabhängig von der Netzschnelligkeit). Bei der Implementierung muß also ein Kompromiß zwischen komplizierten Mechanismen und zeitaufwendigen Kopiervorgängen gefunden werden.

– Ein anderer Aspekt ist die *Verwaltung von Stoppuhren*, wie in Abbildung 11.18. Hierfür muß eine Datenstruktur erzeugt werden, die angibt, wann die Stoppuhr ablaufen soll und was in diesem Fall zu unternehmen ist. Man kann hierfür eine verkettete Liste verwenden, die alle laufenden Uhren enthält und ein Sortieren nach Ablaufzeiten (timeouts) regelt:

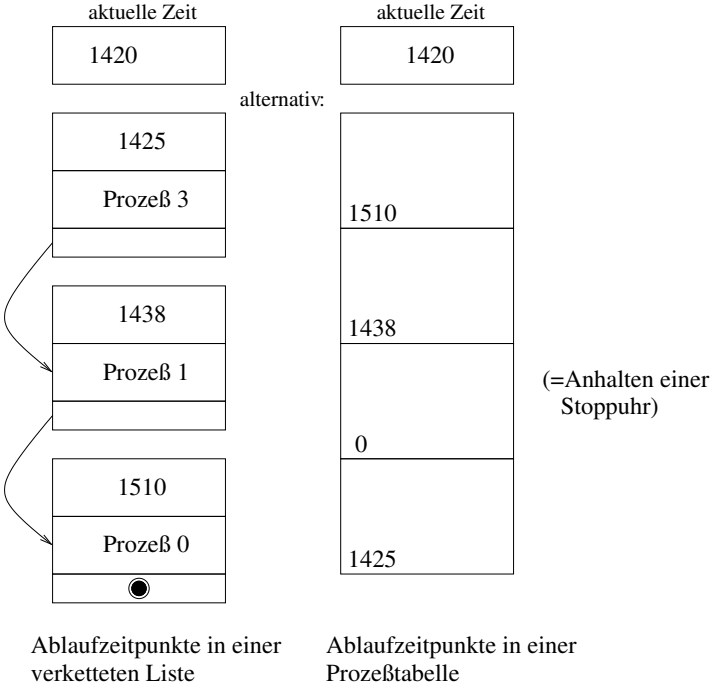

Abbildung 11.18: Verwaltung von Stoppuhren

Trifft eine Antwort oder Bestätigung vor dem Ablaufen einer Stoppuhr ein, so muß der zugehörige Eintrag aus der Liste entfernt werden. In der Praxis werden nur wenige Stoppuhren ablaufen, somit macht das Eintragen/Entfernen die meiste Arbeit.

11.2.3 Kommunikation in Verteilten Systemen

Im folgenden sollen Kommunikationsformen in Verteilten Systemen untersucht werden. Beim RPC wird von einer zwei-Parteien-Kommunikation ausgegangen. Es können sich jedoch auch andere Kommunikationsformen als nötig erweisen. Dies ist zum Beispiel der Fall, wenn eine Gruppe von Datei-Servern miteinander kooperiert, um eine einzelnen(fehlertoleranten) Dateidienst anzubieten. Hier muß der Client eine Nachricht an alle Server senden. Nur so kann man sicherstellen, daß - auch bei Ausfall eines Servers - eine Anfrage ausgeführt wird. Aus diesem Beispielszenario folgt die Notwendigkeit eines zum RPC alternativen Kommunikationsmechanismus, mit dem man eine Nachricht an mehr als einen Empfänger schicken kann.

Grundbegriffe

Def.: Eine *Gruppe* ist eine Menge von Prozessen, die miteinander kooperieren, d.h. auf eine vom Benutzer oder System festgelegte Art und Weise zusammenarbeiten.

Eine Gruppe besitzt folgende Eigenschaften:

– Wird eine Nachricht an eine Gruppe gesendet, so wird die Nachricht von allen Mitgliedern der Gruppe empfangen:

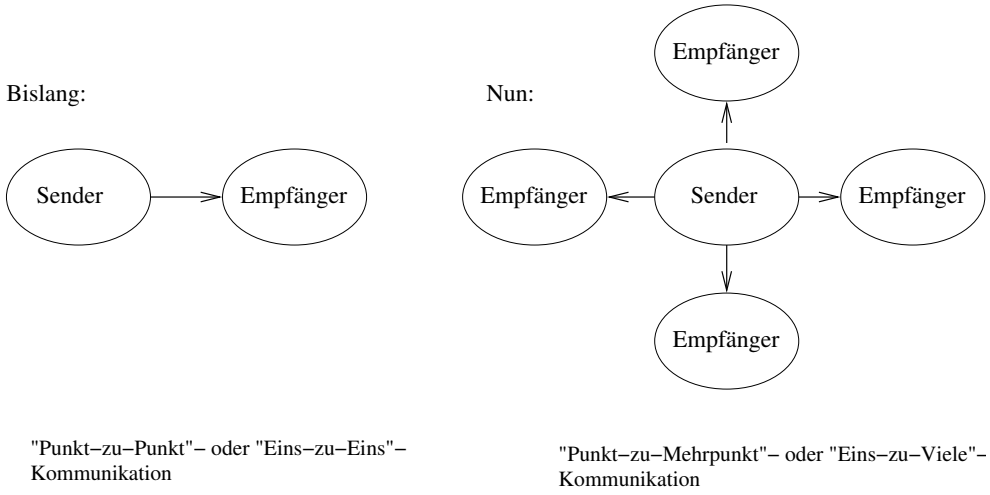

Abbildung 11.19: Punkt-zu-Punkt vs. Punkt-zu-Mehrpunkt-Kommunikation

– Gruppen sind dynamisch, d.h. neue Gruppen können erzeugt und existierende Gruppen aufgelöst werden; Gruppenmitgliedschaften brauchen nicht disjunkt zu sein.

Wird ein Paket an eine Gruppenadresse gesendet, so erfolgt die Übertragung automatisch an alle Rechner, die dieser Adresse angehören. Diesen Prozeß bezeichnet man als *Multicasting*. Multicasting ist die Alternative zum *Broadcasting*, wobei eine Nachricht an alle Rechner übertragen wird und zum *Unicasting*, wobei n-mal vom Sender zu je einem Empfänger übertragen wird. Abbbildung 11.20 veranschaulicht die verschiedenen Übertragungsverfahren.
Die Gruppenkommunikation kann zu Beispiel bei replizierten Dateiservern angewendet werden. Sie wird auch insbesondere bei der sog. *Groupware* verwendet, die die Computerunterstützung von Arbeitsgruppen oder Projektteams bezeichnet. Der Schwerpunkt liegt hier auf der Zusammenarbeit der einzelnen Mitarbeiter. Ein verwandter Ansatz findet sich beim *Computer Supported Cooperative Work* (CSCW). Groupware lässt sich wie folgt kategorisieren: Beim Entwurf von Gruppenkommunikationsdiensten müssen die gleichen Entwurfsentscheidungen getroffen werden, wie beim 2-Parteien-RPC hinsichtlich Adressierung, Blockierung,

	gleichzeitig	zeitlich versetzt
zentral	Group Decission Support System	Projektmanagementsoftware
verteilt	Video Konferenz, Server Sharing	Mail-System, Textsystem für Autorengruppen

Tabelle 11.3: Klassifikation von Gruppenkommunikationssoftware

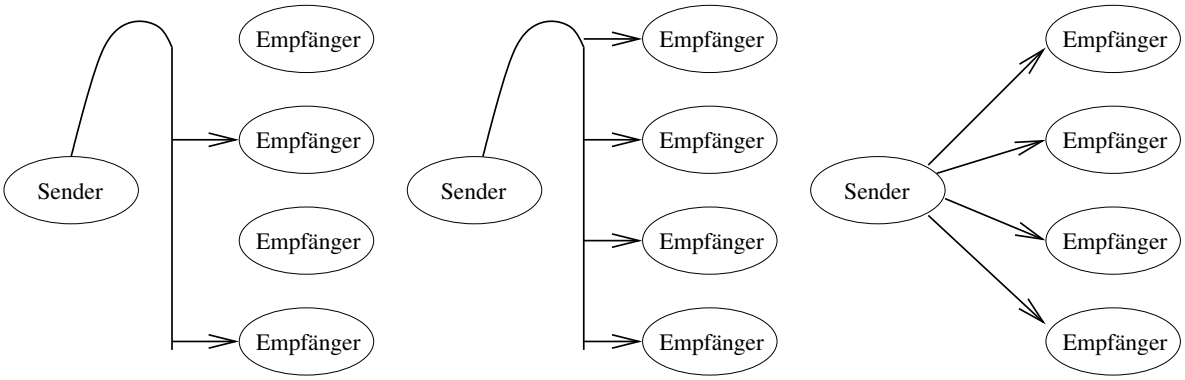

Abbildung 11.20: Verschiedene Übertragungsverfahren

Pufferung und Zuverlässigkeit. Die neue Komplexität der Architektur bedingt jedoch prinzipiell neun weitere Aspekte (von denen auf die wichtigsten im folgenden eingegangen werden soll), die bei Punkt-zu-Punkt-Kommunikation keine Rolle spielen. Die Adressierung an die Gruppe Erfolgt entweder durch :

- Einrichtung einer eigenen Multicastadresse für die Gruppe,
- oder durch Broadcasting und Entscheidung des Kerns, ob er zur Gruppe gehört,
- oder durch Prädikatadressierung, bei der die Nachricht ein Prädikat enthält, das ausgewertet wird und damit die Annahme der Nachricht bestimmt.

Desweiteren Müssen die Sende- und Empfangsprimitive für die Gruppe ab `group send` und `group receive` modifiziert und angepasst werden. Damit die Gruppenkommunikation einfach benutzbar ist, braucht man zwei weitere Eigenschaften:

- *Atomarität*: Ein Multi- oder Broadcast wird immer entweder an alle oder an kein Mitglied der Adressatengruppe geschickt.
- *Nachrichtenreihenfolgeeinhaltung*

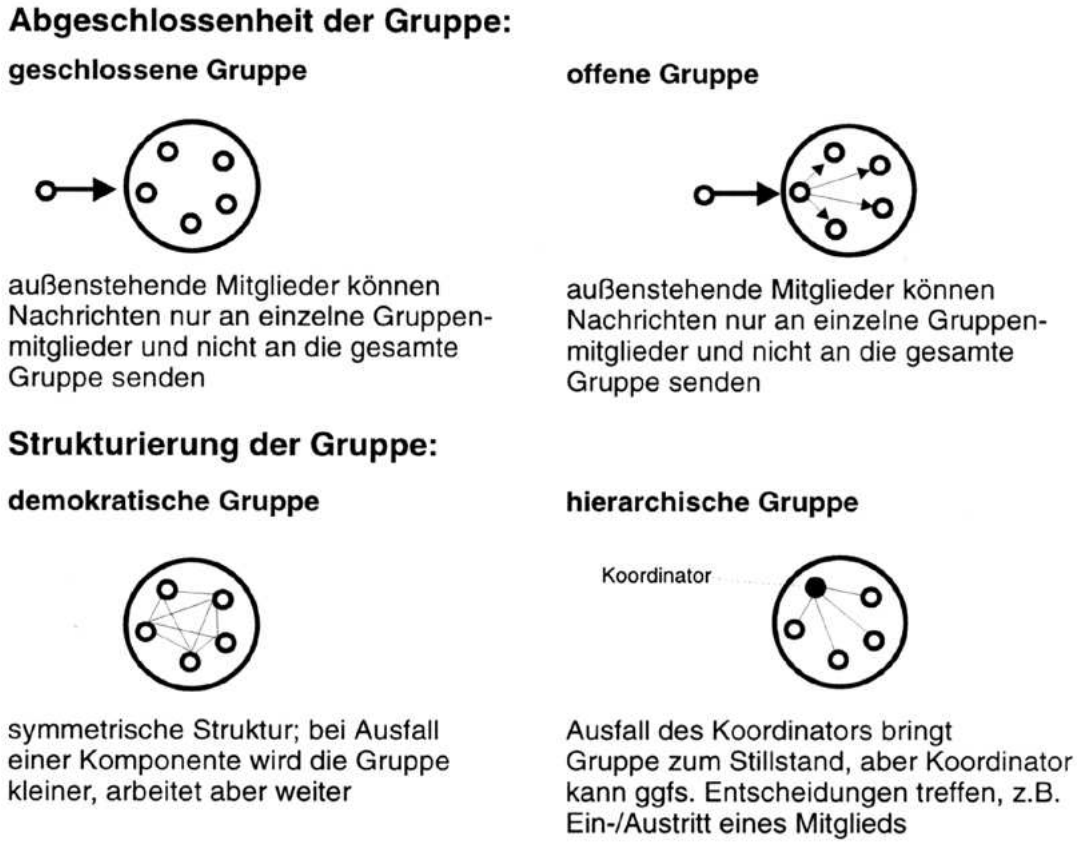

Abbildung 11.21: Aspekte der Gruppenkommunikation