Betriebssystemtechnik

Adressräume: Trennung, Zugriff, Schutz

VIII. Adressraummodelle: Mehradressraumsysteme

Wolfgang Schröder-Preikschat / Volkmar Sieh

7. Juni 2023

Gliederung

Räumliche Isolation

- Mehradressraumkonzept
  - Betriebssystem und Anwendungsprogramme erhalten private Adressräume
    - die gleichsam Schutzdomänen manifestieren
  - Grundlage dafür ist die Mehrfachnutzung desselben realen Adressbereichs
    - für einen N-Bit Rechner gilt für diesen Adressbereich $A = [0, 2^N - 1]$
  - Adressraum als Entität, der eine gewisse Virtualität zugeschrieben wurde
    - d.h., die nicht physisch, aber in ihrer Funktionalität/Wirkung vorhanden ist
  - Technik ist die Individualisierung eines bestimmten Adressbereichs:
    i A komplett *oder*
    ii der obere oder untere Teilbereich von $A \rightsquigarrow \text{StuBS}_{BST}$
- **horizontale Isolation** einerseits, **vertikale Isolation** andererseits

  horizontal
  - innerhalb der Anwendungsprogrammebene
  - Abkapselung des Anwendungsprogramms als Prozessexemplar

  vertikal
  - Anwendungsprogramm- und Betriebssystemebene übergreifend
  - Abkapselung von Prozessexemplar und Betriebssystem
- implizite Mitbenutzung (*sharing*) einer ganzen „Länderei“ (*user land*)
  - zur Beschleunigung von Interaktionen mit dem Betriebssystem

Virtualität von Adressen

Die Eigenschaft einer Sache, nicht in der Form zu existieren, in der sie zu existieren scheint, aber in ihrem Wesen oder ihrer Wirkung einer in dieser Form existierenden Sache zu gleichen.[1]

- Bereiche des (begrenzten) physischen Adressraums individualisieren
  - i **Vervielfachung** von $A = [0, 2^N - 1]$
    - komplett A für Betriebssystem und allen Anwendungsprogrammen, jeweils
  - ii **Partitionierung** von $A_t = [0, 2^N - 1]$, Vervielfachung von $A_p \subset A_t$
    - komplett A_t (total) für das Betriebssystem
    - komplett A_p (partiell) für alle Anwendungsprogramme, jeweils
- Adressen dieser Bereiche sind nicht wirklich (physisch), wohl aber in ihrer Funktionalität vorhanden
  - hinter jeder dieser Adresse steht eine speicherabbildbare Entität
  - sie referenzieren Entitäten der Programmtexte (d.h., Befehle) oder -daten

↪ Segmentierung und/oder Seitennummerierung von Adressräumen

[1] `http://de.wikipedia.org/wiki/Virtualität`

Exklusions-/Inklusionsmodell

Exklusionsmodell:

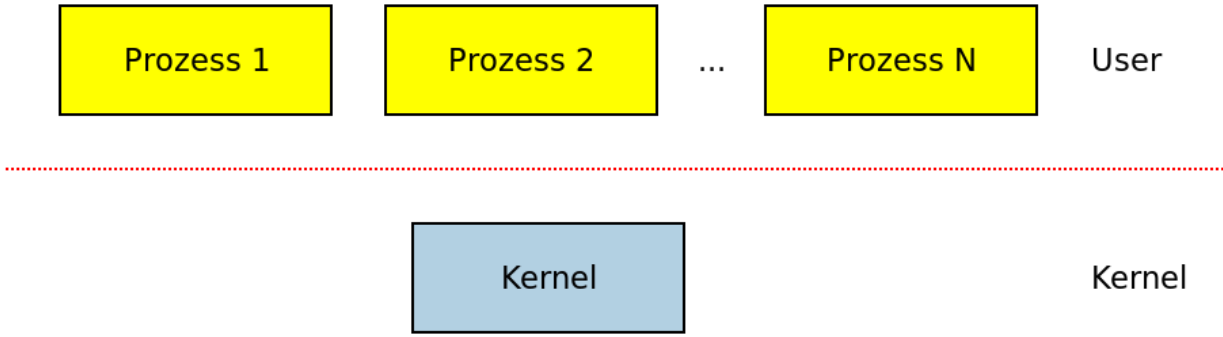

Inklusionsmodell:

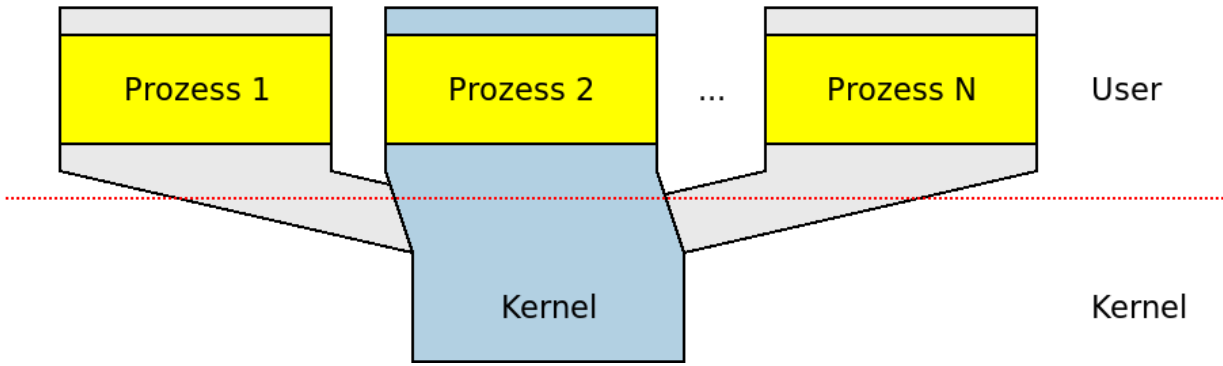

Gliederung

Private Adressräume

Illusion von einem eigenen physischen Adressraum für Betriebssystem und Anwendungsprogramme $\rightsquigarrow$ Exklusion

- Vervielfachung des Adressbereichs $A = [0, 2^N - 1]$
  - wobei N bestimmt ist durch die reale Adressbreite des Prozessors
  - evolutionär betrachtet galt/gilt z.B. für $N = 16, 20, 24, 31, 32, 48, 64$
- die MMU[2] verhindert ein Ausbrechen von Prozessen aus A
  - dies gilt für alle durch das Betriebssystem verwalteten Prozesse, *also*
  - sowohl für Anwendungsprogramme als auch für das Betriebssystem selbst
- Informationstausch zwischen Programmen mittels Maschinenbefehle
  - des Betriebssystems für die Anwendungsprogramme *und* $\mapsto$ Ebene 3
    - Systemaufrufe zur Interprozesskommunikation oder Adressbereichsabbildung
  - der CPU für die Betriebssystemprogramme $\mapsto$ Ebene 2
    - privilegierte Befehle zum Lese-/Schreibzugriff auf den Benutzeradressraum
- im Vordergrund steht die strikte Isolation von ganzen Adressräumen

[2] Ebenso eine MPU (*memory protection unit*).

Fensterbasierter Ansatz I

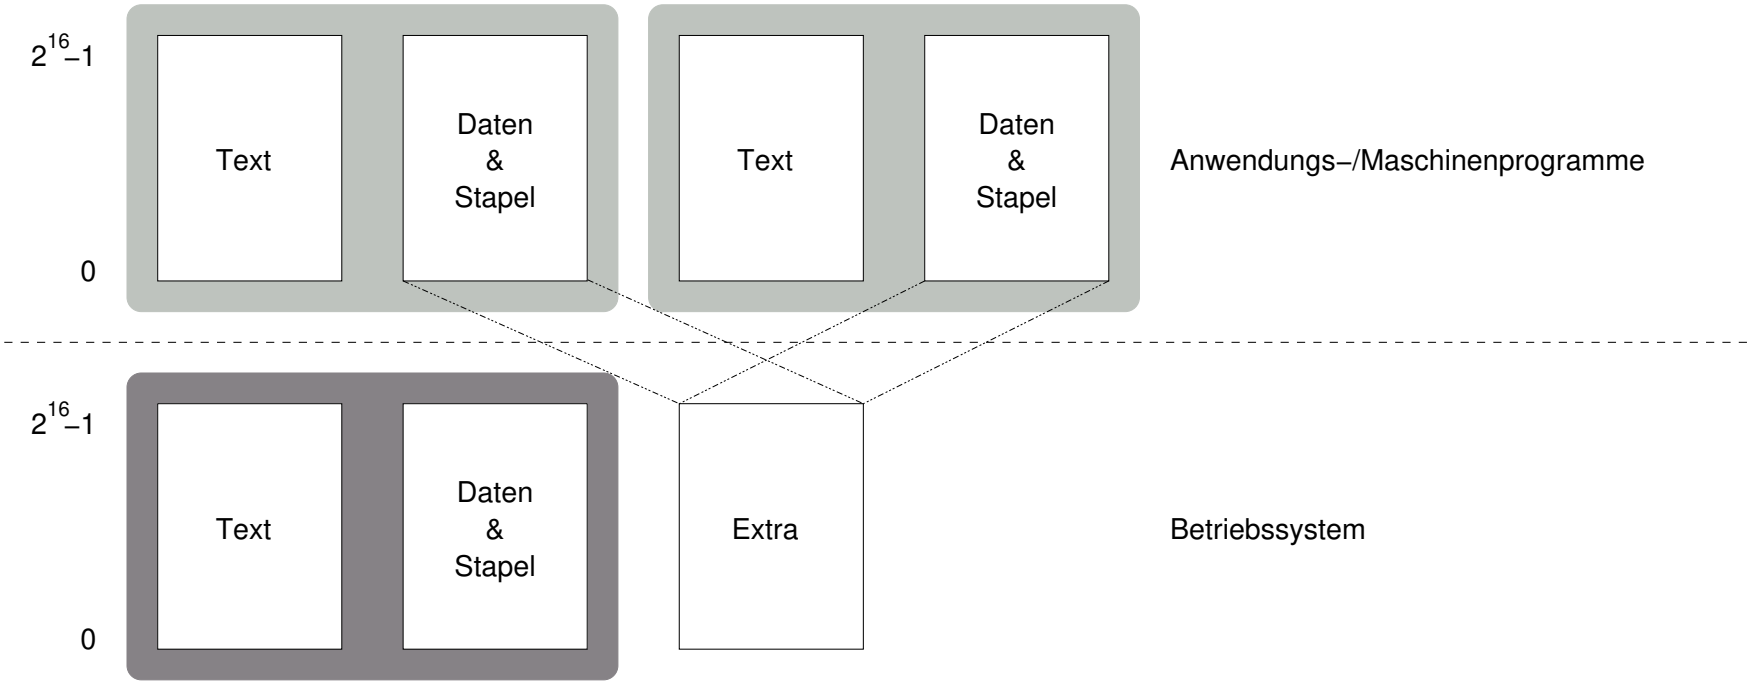

- horizontaler und vertikaler Informationsaustausch
  - horizontal: Interprozesskommunikation (Nachrichtenversenden)
  - vertikal: Zugriffe auf den Benutzeradressraum mittels Extrasegment
- Beispiele von (mikrokernbasierten) Betriebssystemen der Art:
  - QNX: ereignisbasiert, vgl. auch [8, 3]
  - AX: ereignis-/prozedurbasiert, QNX-kompatibel [9]

Fensterbasierter Ansatz II

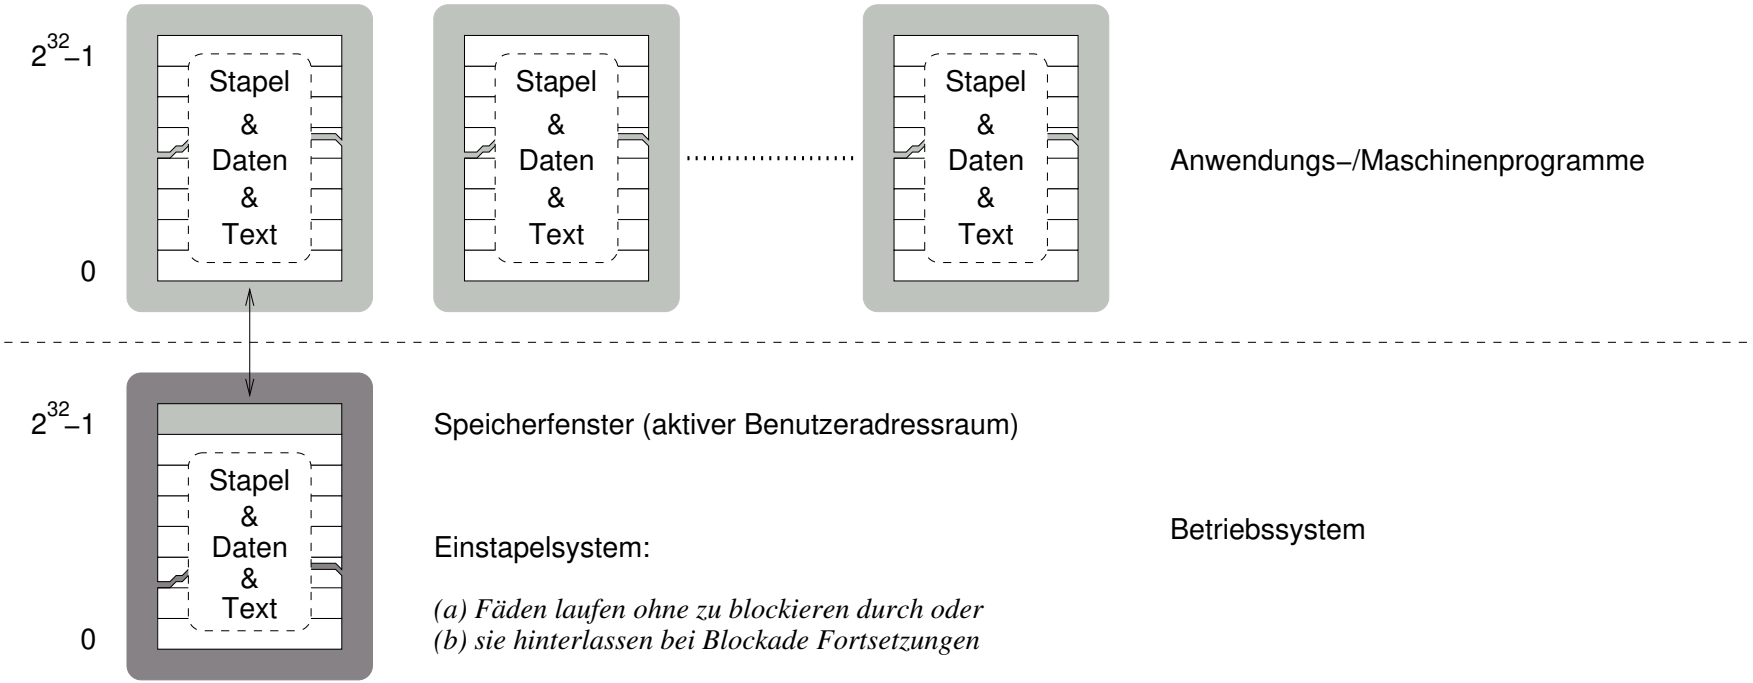

- horizontaler und vertikaler Informationsaustausch
  - horizontal
    - Interprozesskommunikation (Nachrichtenversenden)
    - seitenbasierte Mitbenutzung
  - vertikal
    - Zugriffe auf den Benutzeradressraum mittels Speicherfenster
- prominentes Beispiel eines Betriebssystems der Art:
  - Darwin
    - Hybridkernansatz, ereignis-/prozedurbasiert, 512 MiB Fenster

Spezialbefehlbasierter Ansatz

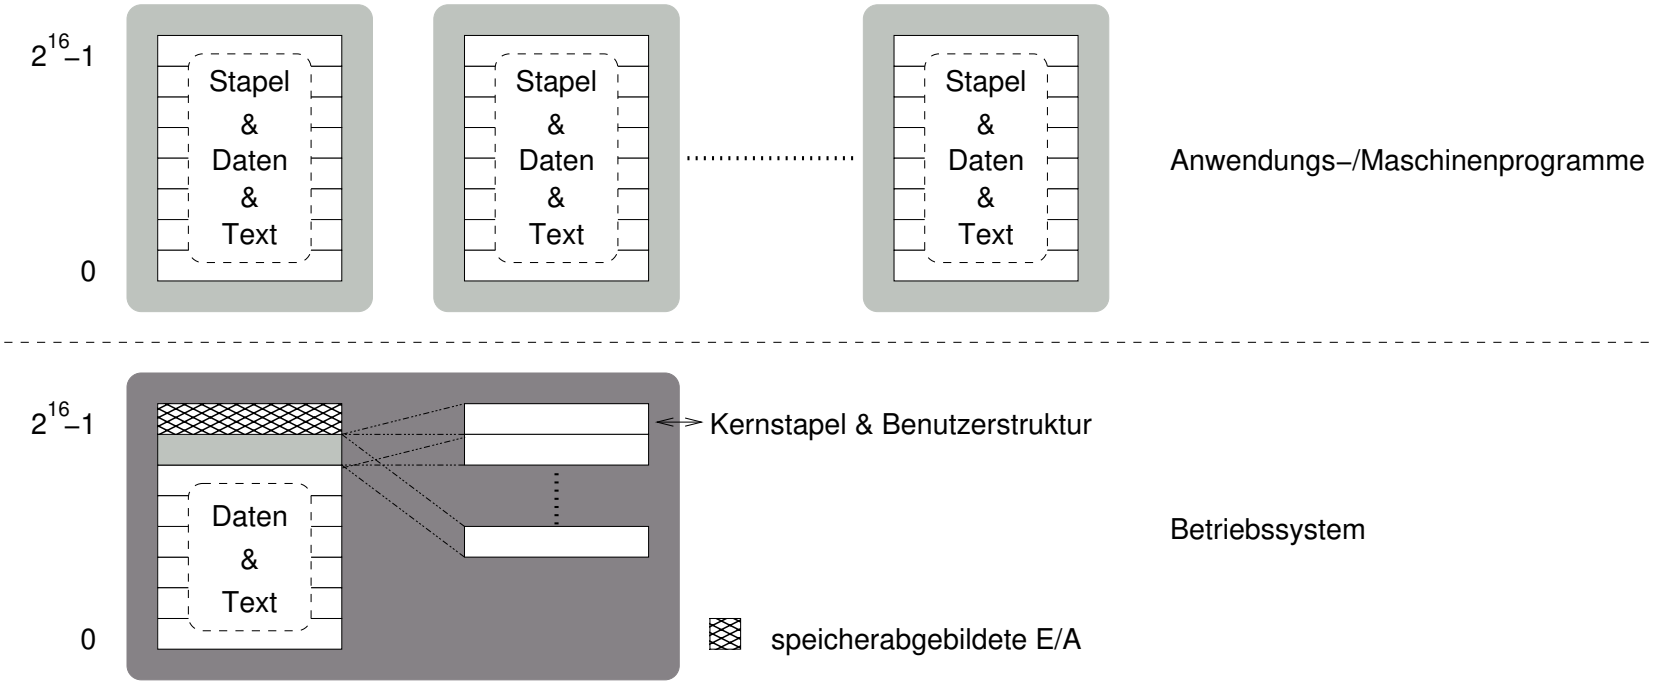

- horizontaler und vertikaler Informationsaustausch
  - horizontal
    - Interprozesskommunikation (Nachrichtenversenden, *pipe*)
    - seitenbasierte Mitbenutzung in Inkrementen von 64 Bytes
  - vertikal
    - Zugriffe auf den Benutzeradressraum mittels Spezialbefehle
- prominentes Beispiel eines (monolithischen) Betriebssystems der Art:
  - UNIX
    - Version 6 [6, 5], prozedurbasiert

Vertikaler Benutzeradressraumzugriff I

- **adressraumübergreifender Zugriff** durch Spezialbefehle der CPU
  - `mfpi` *ea*
    - *move from previous instruction space*
    - das von *ea* gelesene Datum wird auf den Kernstapel abgelegt
  - `mtpi` *ea*
    - *move to previous instruction space*
    - das an *ea* zu schreibende Datum wird vom Kernstapel geholt
    - ↪ *ea* ist *effektive Adresse* im Adressraum vor Kernaktivierung
- ungültige Benutzeradressen können diese Befehle scheitern lassen **!!!**
  - der Kern muss daraufhin seinerseits sein mögliches Scheitern abwenden
- im MMU-Fall wird die Prozessorbetriebsart verfolgt (vgl. [1, S. 2-4]):
  - 00 *kernel mode* ⇝ privilegiert, sicher, vertrauenswürdig
  - 11 *user mode* ⇝ unprivilegiert, unsicher, zweifelhaft
- dafür vorgesehene Bitfelder im Prozessorstatuswort:
  - 15–14 *current mode*
  - 13–12 *previous mode*, vor der letzten Unterbrechung (*trap*, *interrupt*)
- je Betriebsart 8 Seitenadressregister, Umschaltung bei Moduswechsel

Kontrollierte Spezialbefehlausführung

Vorbeugungsmaßnahmen, um ein mögliches Scheitern des Kerns – und damit einen Systemabsturz (*crash*) – abzuwenden

- sind betriebssystemabhängig & gehen optimistisch/pessimistisch vor

  optimistisch
  - Annahme: *ea* ist eine eher gültige Benutzeradresse
  - den Kern auf mögliche Unterbrechung (*trap*) vorbereiten
  - im Ausnahmefall die Ausführung des Kerns fortsetzen

  pessimistisch
  - Annahme: *ea* ist eine eher ungültige Benutzeradresse
  - diese vor Verwendung mit dem Spezialbefehl überprüfen
  - den Ausnahmefall im Kern nicht auftreten lassen

- im Falle eines voll verdrängbaren Kerns oder parallelel Fäden in einer Ablaufumgebung offenbart der pessimistische Ansatz eine Laufgefahr (*race hazard*)
  - angenommen, die Prüfung ergab die Gültigkeit der Benutzeradresse *ea*
  - vor Verwendung von *ea* im Kern wird der Prozess aber verdrängt
  - asynchron dazu verändert sich die Adressraumbelegung des Prozesses
  - so dass Benutzeradresse *ea* bei Prozesswiederaufnahme ungültig ist

  ↪ **beachte**: ein Betriebssystem darf Benutzerprogramme nicht „benutzen“

Optimistisches Vorgehen: Zugriffsoperationen


```
1  gword:                          ; note: r1 holds read address
2    mov   PS, -(sp)               ; save processor status word
3    bis   $340, PS                ; disable interrupts
4    mov   nofault, -(sp)          ; save kernel detour pointer
5    mov   $err, nofault           ; setup detour for trap handler
6    mfpi  (r1)                    ; transfer data onto kernel stack
7    mov   (sp)+, r0               ; receive data just read
8    br    1f                      ; prepare for return...
9  pword:                          ; note: r1 holds write address
10   mov   PS, -(sp)               ; save processor status word
11   bis   $340, PS                ; disable interrupts
12   mov   nofault, -(sp)          ; save kernel detour pointer
13   mov   $err, nofault           ; setup detour for trap handler
14   mov   r0, -(sp)               ; send data to be written
15   mtpi  (r1)                    ; transfer data from kernel stack
16 1:
17   mov   (sp)+, nofault          ; restore kernel detour pointer
18   mov   (sp)+, PS               ; restore processor status word
19   rts   pc
```

Optimistisches Vorgehen: Ausnahme

- Abfangen der Ausnahmesituation (*trap*): `mfpi`/`mtpi` ist gescheitert

```
1  trap:
2    mov   PS, -4(sp)       ; magic: needed for code 1f
3    tst   nofault          ; check for kernel detour
4    beq   1f               ; none, continue
5    mov   $1, SSR0         ; else, reinitialize MMU
6    mov   nofault, (sp)    ; overwrite return address and
7    rtt                    ; return from trap
8  1:                       ; fall into normal trap...
```

- „*escape exception*“ [2] für `gword`/`pword`-rufende Programme

```
1  err:
2    mov   (sp)+, nofault ; restore kernel detour pointer
3    mov   (sp)+, PS      ; restore processor status word
4    tst   (sp)+          ; forget g/pword return address
5    mov   $-1, r0        ; indicate failure of operation
6    rts   pc             ; return from caller of g/pword
```

Vertikaler Benutzeradressraumzugriff II

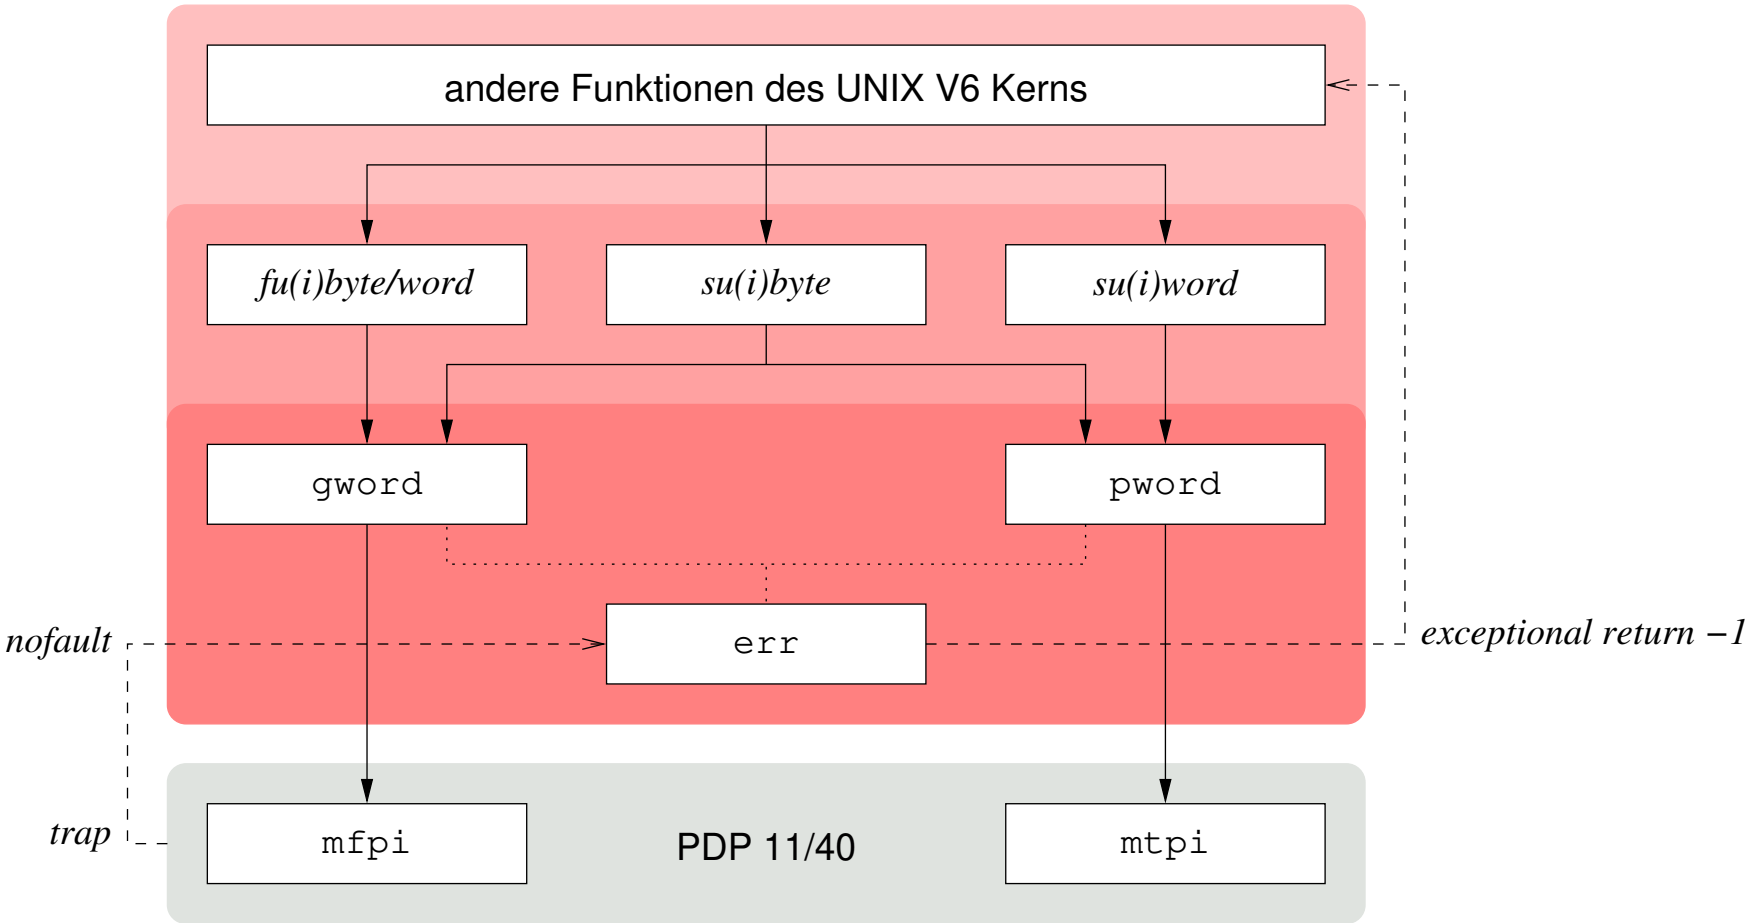

- im Ausnahmefall werden die *fetch*/*store*-Operationen abgebrochen
  - sie bilden zusammen mit `gword`, `pword` und `err` ein Modul [7]
  - denn: alle teilen sich dasselbe Wissen über Stapelaufbau/Ereignisabfolge

Gliederung

Partiell private Adressräume

Illusion von einem eigenen physischen Adressraum bzw. -bereich für die Anwendungsprogramme $\rightsquigarrow$ Inklusion des Betriebssystem(kern)s

- Vervielfachung des Adressbereichs $A_p \subset A_t$
  - A_t ist der dem Betriebssystem *total* zugeordnete Adressbereich
    - existiert einfach, aber mit A_p als integrierten variablen (mehrfachen) Anteil
  - A_p ist der einem Anwendungsprogramm in A_t *partiell* zugeordnete Bereich
    - existiert mehrfach, einmal für jedes Anwendungsprogramm
- der Benutzeradressraum ist ein Teil des Betriebssystemadressraums
  - die MMU verhindert ein Ausbrechen von Prozessen aus A_p und A_t, nicht jedoch deren Eindringen heraus aus $A_t - A_p$ und hinein in A_p
    - bedingter Schreibschutz von A_p für A_t dämmt Betriebssystemfehler ein
  - dabei erstreckt sich A_p über den oberen oder unteren Bereich von A_t
  - nur Prozesswechsel[3] zwischen A_p bedingen das Umschalten der MMU
- im Vordergrund steht **Performanz** (Geschwindigkeit, Rauschen)
  - Systemaufrufe implizieren keinen Adressraumwechsel mehr

[3] Genauer: Der Wechsel zwischen schwergewichtigen Prozessen.

Inklusion des aktiven Benutzeradressraums

gekachelt

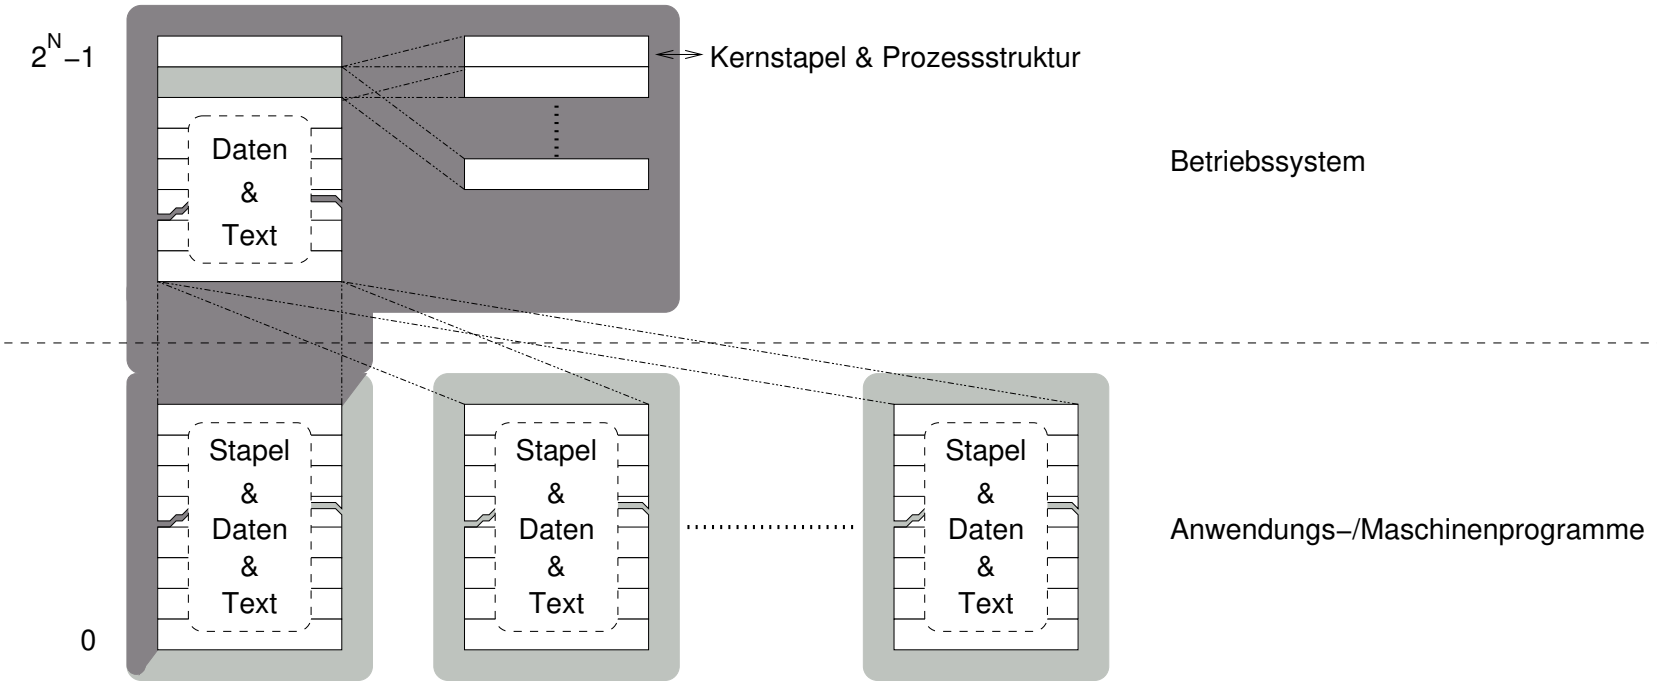

- horizontaler und vertikaler Informationsaustausch
  - horizontal: Interprozesskommunikation, Segment-/Seitenmitbenutzung
  - vertikal: speicherabgebildeter Zugriff auf den Benutzeradressraum
- prominente Beispiele von Betriebssystemen der Art:
  - Linux: monolithisch, prozedurbasiert
  - NT: Hybridkernansatz, prozess-/prozedurbasiert
  - macOS: ab Mac OS X 10.15 (Catalina): 32 $\rightsquigarrow$ 64-Bit Technologie

Teilung des Adressbereichs

in zweierlei Hinsicht

Inklusion des Benutzeradressraums in den Betriebssystemadressraum ist nur bei hinreichend großem N ein sinnvoller Ansatz

- das Modell wurde attraktiv mit Adressbreiten von $N \geq 30$ Bits
  - also für reale Adressbereiche ab 1 GiB Speicherumfang
- typische Aufteilung von $A = [0, 2^{32} - 1] = 4$ GiB:

  gleich
  - 2 GiB jeweils für Benutzer- und Betriebssystemadressraum
  - NT

  ungleich
  - 3 GiB Benutzer- und 1 GiB Betriebssystemadressraum
  - Linux, NT (Enterprise Edition)

  - steht und fällt mit der Größe von Benutzerprogrammen/-prozessen

- die Folge einer solchen Aufteilung ist, dass die Benutzerprozesse dem Betriebssystem ein stärkeres Vertrauen schenken müssen
  - Schreibschutz auf A_p legen und nur bei Bedarf zurücknehmen/lockern
  - sonst sind Zeigerfehler in $A_t - A_p$ verheerend für Programme in A_p

Adressraumschutz durch Abgrenzung

fencing

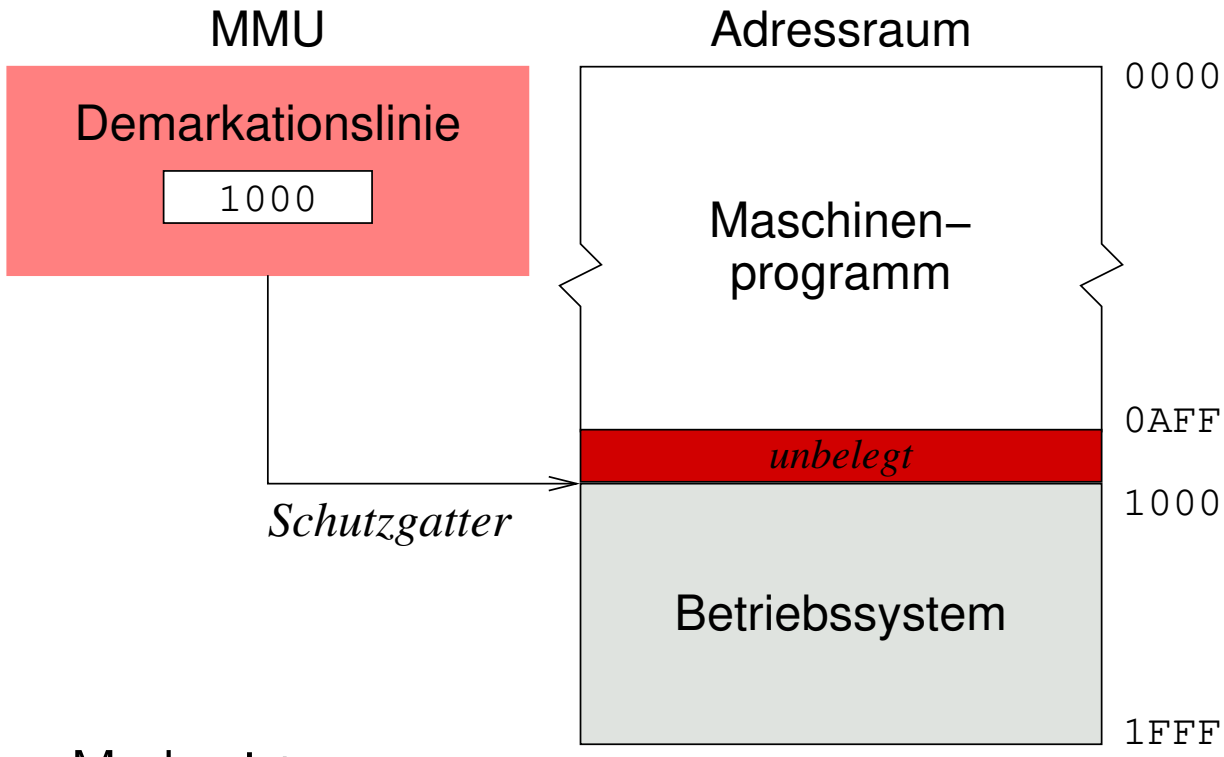

- **Arbeitsmodi**
  - nur im unprivilegierten Modus ist das Schutzgatter aktiv
  - nur im privilegierten Modus sind Zugriffe auf Bereiche jenseits der Demarkationslinie erlaubt

Reminiszenz (vgl. [4, S. 15])

Eine alte, bekannte Technik, die nach wie vor hohe Bedeutung genießt.

Gliederung

Diskussion

- private Adressräume
  - − Systemaufrufe allein rufen bereits Adressraumwechsel hervor
  - − vertikaler Informationsaustausch ist nur indirekt möglich
  - \+ schränken den effektiv zur Verfügung stehenden Adressbereich nicht ein
  - \+ stellen geringere Anforderungen an die Korrektheit des Betriebssystems

- partiell private Adressräume
  - \+ Systemaufrufe gehen ohne Adressraumwechsel einher
  - \+ vertikaler Informationsaustausch ist direkt möglich
  - − verkleinern den effektiv zur Verfügung stehenden Adressbereich
  - − stellen höhere Anforderungen an die Korrektheit des Betriebssystems

↪ **Zielkonflikt** (*tradeoff*)

- keiner der beiden Ansätze ist *per se* ein Vorteil einzuräumen...

Resümee

- Mehradressraumsysteme
  - implementieren (total/partiell) private Adressräume
    - total – sowohl für Anwendungsprogramme als auch Betriebsystem
    - partiell – nur für die Anwendungsprogramme untereinander
  - Informationsaustausch zwischen Betriebssystem- & Benutzeradressraum:
    - fensterbasiert, bedarfsorientierte Einblendung von Adressraumabschnitten
    - spezialbefehlbasiert, selektives Kopieren von Maschinenwörtern
    - adressraumgeteilt, direkter Zugriff von kompletten Benutzeradressraum
- Isolation von Adressräumen in zweierlei Hinsicht
  - horizontale Isolation innerhalb der Anwendungsprogrammebene
    - Abkapselung des Anwendungsprogramms als Prozessexemplar
    - Wechsel zwischen den Prozessexemplaren impliziert Adressraumwechsel
  - vertikale Isolation des Betriebssystems vom Anwendungsprogramm
    - Abkapselung von Prozessexemplar und Betriebssystem
    - Wechsel zwischen den Ebenen impliziert keinen Adressraumwechsel

↪ Aufweichen der Privatsphäre, wenn Performanz vor Schutz gehen soll

Literaturverzeichnis I

[1] Digital Equipment Corporation (Hrsg.):
PDP-11/40 Processor Handbook.
Maynard, MA, USA: Digital Equipment Corporation, 1972.
(D-09-30)

[2] Goodenough, J. B.:
Exception Handling: Issues and a Proposed Notation.
In: *Communications of the ACM* 18 (1975), Nr. 12, S. 683–696

[3] Hildebrand, D. :
An Architectural Overview of QNX.
In: *Proceedings of the USENIX Workshop on Micro-kernels and Other Kernel Architectures (USENIX Microkernels)* USENIX Association, 1992. –
ISBN 1–880446–42–1, S. 113–126

[4] Kleinöder, J. ; Schröder-Preikschat, W. :
Stapelverarbeitung.
In: Lehrstuhl Informatik 4 (Hrsg.): *Systemprogrammierung*.
FAU Erlangen-Nürnberg, 2015 (Vorlesungsfolien), Kapitel 7.1

Literaturverzeichnis II

[5] Lions, J. :
A Commentary on the Sixth Edition UNIX Operating System.
The University of New South Wales, Department of Computer Science, Australia : http://www.lemis.com/grog/Documentation/Lions, 1977

[6] Lions, J. :
UNIX Operating System Source Code, Level Six.
The University of New South Wales, Department of Computer Science, Australia : http://v6.cuzuco.com, Jun. 1977

[7] Parnas, D. L.:
On the Criteria to be used in Decomposing Systems into Modules.
In: *Communications of the ACM* 15 (1972), Dez., Nr. 12, S. 1053–1058

[8] Quantum Software Systems Ltd. (Hrsg.):
QNX Operating System User's Manual.
Version 2.0.
Toronto, Canada: Quantum Software Systems Ltd., 1984

[9] Schröder, W. :
Eine Familie von UNIX-ähnlichen Betriebssystemen – Anwendung von Prozessen und des Nachrichtenübermittlungskonzeptes bem strukturierten Betriebssystementwurf, Technische Universität Berlin, Diss., Dez. 1986