

4 Beispiel: Kerberos (4)

- Unterscheidung zwischen Benutzer (*User*) und Benutzerprogramm (*Client*)
- ◆ Wie kann ein Benutzerprogramm seinen Benutzer identifizieren?
- ◆ Geheimer Schlüssel vom Benutzer (K_X) hängt von einem Paßwort ab
- ◆ mittels einer Einwegfunktion wird aus dem Paßwort der Schlüssel K_X erzeugt
- ◆ Benutzerprogramm braucht also das Paßwort zur Verbindungsaufnahme
- Beispiel: *kinit*, *klogin*
- ◆ Anmeldung beim Authentisierungsdienst mit *kinit* und Paßworteingabe
- ◆ Ticket wird im Benutzerkatalog gespeichert
- ◆ *klogin* erlaubt das Einloggen auf einem entfernten Rechner mit Datenverschlüsselung und ohne Paßwort

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

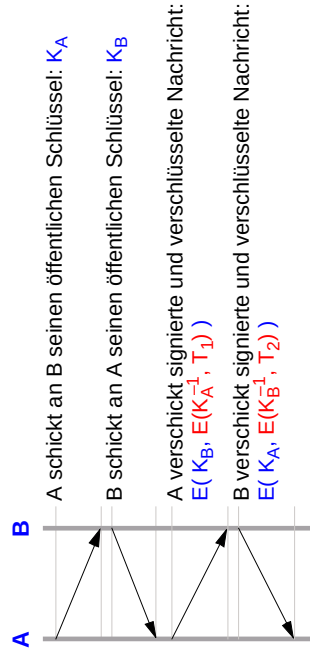
I-Security.doc 1998-02-16 11:27

Reproduzieren oder Verwenden dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

L.109

5 Austausch öffentlicher Schlüssel

- A und B tauschen ihre öffentlichen Schlüssel aus



▲ Problem

- ◆ A und B können nicht sicher sein, daß der öffentliche Schlüssel wirklich vom jeweils anderen stammt

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

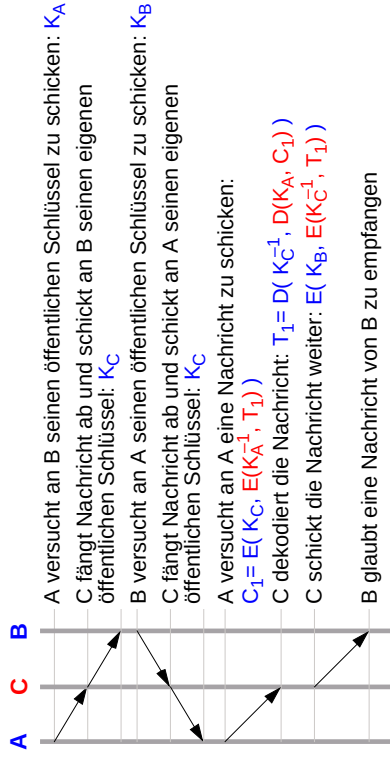
I-Security.doc 1998-02-16 11:27

Reproduzieren oder Verwenden dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

L.110

5 Austausch öffentlicher Schlüssel (2)

- Aktiver Mithörer C fängt Datenverbindungen ab



SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

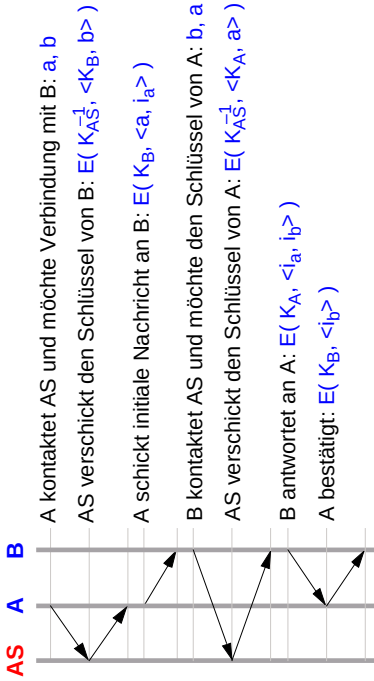
I-Security.doc 1998-02-16 11:27

Reproduzieren oder Verwenden dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

L.111

5 Austausch öffentlicher Schlüssel (3)

- Einsatz eines Authentisierungsdienstes



▲ Replay-Probleme

- ◆ Hinzunahme von Zeitstempel und Lebendauer

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

I-Security.doc 1998-02-16 11:27

Reproduzieren oder Verwenden dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

L.112

I.8 Firewall

- Trennung von vertrauenswürdigen und nicht vertrauenswürdigen Netzwerksegmenten durch spezielle Hardware (*Firewall*)
- ◆ Beispiel: Trennen des firmeninternen Netzwerks (Intranet) vom allgemeinen Internet
- Funktionalität
- ◆ Einschränkung von Diensten
 - von innen nach außen, z.B. nur Standarddienste
 - von außen nach innen, z.B. kein Telnet, nur WWW
- ◆ Paketfilter
 - Filtern „defekter“ Pakete, z.B. SYN-Pakete
- ◆ Inhaltsfilter
 - Filtern von Pornomaterial aus dem WWW oder News
- ◆ Authentisieren von Benutzern vor der Nutzung von Diensten

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


I-Security.doc (1998-02-16 11:27)

L113

Reproduzieren Sie die Abbildung, wenn Sie diese Vorlesung in der Veranstaltung „Systemprogrammierung I“ nutzen.

I.8 Firewall (2)

- Virtual private network
- ◆ Verbinden von Intranet-Inseln durch spezielle Tunnels zwischen Firewalls
- ◆ getunnelter Datenverkehr wird verschlüsselt
- ◆ Benutzer sieht ein „großes Intranet“ (nur virtuell vorhanden)



SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

I-Security.doc (1998-02-16 11:27)

L114

Reproduzieren Sie die Abbildung, wenn Sie diese Vorlesung in der Veranstaltung „Systemprogrammierung I“ nutzen.

J Mach

- Fallbeispiel: *Mach* Betriebssystem
- ◆ Mikrokern
- ◆ Unterstützung für Multiprozessoren
- ◆ neues, hardwareunabhängiges Konzept der virtuellen Speicherverwaltung
- ◆ *Capability*-basierte Interprozesskommunikation – transparent erweiterbar für Netzwerk-Kommunikation
- ◆ Modularer Aufbau, einfache Erweiterbarkeit (nur die wichtigsten Funktionen sind im Mach-Kern realisiert)
- ◆ Betriebssystemumgebung wird durch eine Reihe von *Servern* realisiert
- Geschichte
- ◆ Entwicklung 1985–1994 an der Carnegie Mellon Univ. (CMU)
- ◆ Basis für OSF/1 (Open Software Foundation), NeXT-OS (Next/Apple)
- ◆ Bedeutung heute eher gering

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc (1998-02-18 09:51)

J.1

Reproduzieren Sie die Abbildung, wenn Sie diese Vorlesung in der Veranstaltung „Systemprogrammierung I“ nutzen.

J.1 Motivation

- Entwicklung des UNIX-Systemkerns
- ◆ heute nicht mehr so einfach aufgebaut und leicht modifizierbar wie früher
- ◆ früher auf PDP11 mit 32k HSP lauffähig, heute 1,5–2 MB Speicher (inkl. Puffer etc.) notwendig
- ◆ viele neue Funktionen werden kritisch in den Kern eingebaut, weil dort die notwendigen Informationen leicht zugänglich sind
- ◆ Aufblähung des Kerns, Abstraktionen und Strukturierung werden mehr und mehr zerstört
- ◆ für Einsatz von UNIX auf Multiprozessorsystemen sind aufwendige Modifikationen notwendig
 - Kern-Monitor muß in Teile zerlegt werden oder ganz aufgegeben werden
 - an Stellen, an denen die Monitor-Eigenschaft aufgegeben wird, ist aufwendige Koordinierung erforderlich

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc (1998-02-18 09:51)

J.2

Reproduzieren Sie die Abbildung, wenn Sie diese Vorlesung in der Veranstaltung „Systemprogrammierung I“ nutzen.

J.1 Motivation (2)

- Architektur von Mach
 - ◆ Mikrokern
 - ◆ Betriebssystemumgebung wird durch eine Reihe von *Servern* realisiert, die über die Basis-Mechanismen des Mach-Kerns angesprochen werden können



- ◆ Beispiele:
 - Dateisystem
 - Netzwerk-Kommunikation (z.B. TCP/IP)
 - Scheduling
 - UNIX-Emulation

SP I

Systemprogrammierung I
© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.3

Reproduktion oder Verwertung ohne schriftliche Genehmigung ist strafbar. Alle Rechte vorbehalten.

J.2 Abstraktionen des Mach-Kerns

- **Task:** Ablaufumgebung für *Threads*
 - ◆ virtueller Adressraum
 - ◆ gesicherter Zugriff zu Systemressourcen (Prozessoren, *Port-Capabilities*, Speicher)
- **Thread:** Aktivitätsträger innerhalb einer *Task*
 - ◆ beschreibbar durch
 - einen unabhängigen Programmzähler
 - eigenen Stack-Bereich innerhalb des virt. Adressraums der *Task*
 - ◆ alle *Threads* einer *Task* haben gemeinsamen Zugriff zu allen *Task*-Ressourcen
- **Port:** Kommunikationskanal mit Warteschlange für Nachrichten
 - ◆ wird vom MACH-Kern verwaltet

SP I

Systemprogrammierung I
© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.4

Reproduktion oder Verwertung ohne schriftliche Genehmigung ist strafbar. Alle Rechte vorbehalten.

J.2 Abstraktionen des Mach-Kerns (2)

- **Message:** Menge von Datenobjekten für die Kommunikation zwischen *Threads*
 - ◆ Messages können typisiert werden
 - ◆ können max. den gesamten virt. Adressraum umfassen
 - ◆ können Zeiger und *Capabilities* für *Ports* enthalten
- **Operationen**
 - ◆ Operationen auf einem Objekt (ausgenommen *Messages*) werden durch Versenden von *Messages* an *Ports* ausgeführt, die dieses Objekt repräsentieren.
- ◆ Beispiel:
 - Beim Generieren einer *Task* erhält man die Zugriffsrechte auf einen *Port* dieser *Task*.
 - Durch *Messages* an diesen *Port* kann die *Task* beeinflusst werden.

SP I

Systemprogrammierung I
© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.5

Reproduktion oder Verwertung ohne schriftliche Genehmigung ist strafbar. Alle Rechte vorbehalten.

J.3 Tasks und Threads

- UNIX-Prozesskonzept ist für viele heutige Anwendungen unzureichend
 - ◆ in Multiprozessorsystemen werden häufig parallele Abläufe in einem virtuellen Adressraum benötigt
 - ◆ zur besseren Strukturierung von Problemlösungen sind oft mehrere Aktivitätsträger innerhalb eines Adressraums nützlich
 - ◆ typische UNIX-Server-Implementierungen benutzen die *fork*-Operation, um einen Server für jeden Client zu erzeugen
 - Verbrauch unnötig vieler Systemressourcen (Dateideskriptoren, SKTs, Speicher etc.)

SP I

Systemprogrammierung I
© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

J.6

Reproduktion oder Verwertung ohne schriftliche Genehmigung ist strafbar. Alle Rechte vorbehalten.

J.3 Tasks und Threads (2)

- Lösungsansatz: Gemeinsamer Speicher
- ◆ derzeitige Multiprozessor-Betriebssysteme (z. B. Dynix) ermöglichen gemeinsame Speicherbereiche für mehrere Prozesse



- ▲ Nachteile
- ◆ viele Betriebsmittel zur Verwaltung eines Prozesses notwendig; Prozesseschaltungen aufwendig
- ◆ innerhalb einer solchen Prozeßfamilie wäre häufig ein anwendungsorientiertes Scheduling notwendig, aber schwierig realisierbar

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung der Universität Erlangen-Nürnberg strafbar. Jeder Fall der Zustimmung des Autors.

J.7

J.3 Tasks und Threads (3)

- Lösungsansatz: Koroutine
- ◆ einige Anwendungen lassen sich mit Hilfe von Koroutinen (auf Benutzerebene) innerhalb eines Prozesses gut realisieren



- ▲ Nachteile:
- ◆ Scheduling zwischen den Koroutinen schwierig (Verdrängung meist nicht möglich)
- ◆ in Multiprozessorsystemen keine parallelen Abläufe möglich
- ◆ wird eine Koroutine wegen eines *Page faults* oder in einem Systemaufruf blockiert, ist der gesamte Prozeß blockiert

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung der Universität Erlangen-Nürnberg strafbar. Jeder Fall der Zustimmung des Autors.

J.8

J.3 Tasks und Threads (4)

- Lösungsansatz: Threads, leichtgewichtige Prozesse (*Lightweight processes*)
- ◆ eine Gruppe leichtgewichtiger Prozesse nutzt gemeinsam eine Menge von Betriebsmitteln
- ◆ jeder leichtgewichtige Prozeß ist aber ein eigener Aktivitätsträger
 - eigener Programmzähler
 - eigener Registersatz
 - eigener Stack
- ◆ Umschalten zwischen zwei leichtgewichtigen Prozessen einer Gruppe ist erheblich billiger als eine normale Prozesseschaltung
- es müssen nur die Register und der Programmzähler gewechselt werden (entspricht dem Aufwand für einen Funktionsaufruf)
- Adreßraum muß nicht gewechselt werden
- alle Systemressourcen bleiben verfügbar

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung der Universität Erlangen-Nürnberg strafbar. Jeder Fall der Zustimmung des Autors.

J.9

1 Task

- Betriebsumgebung (System-Ressourcen) für Aktivitätsträger
- ◆ virtueller Adreßraum
- ◆ Zugriffsrechte
- ◆ Betriebsmittel-Informationen
- ◆ kein Programmablauf und keine Register

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung der Universität Erlangen-Nürnberg strafbar. Jeder Fall der Zustimmung des Autors.

J.10

2 Thread

- Aktivitätsträger und seine Ablaufumgebung
 - ◆ Registersatz
 - ◆ Stack
 - ◆ Programmzähler
- Innerhalb einer *Task* können beliebig viele *Threads* existieren
 - ◆ In einer echten Multiprozessorumgebung können verschiedene *Threads* einer *Task* parallel auf mehreren Prozessoren ablaufen
 - ◆ Ein herkömmlicher UNIX-Prozess entspricht einer MACH-*Task* mit einem *Thread*

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung dieser Universität nicht zulässig. Jeder ist zur Einhaltung der Bestimmungen des Autors verpflichtet.

J.11

3 Interprocess Communication – IPC

- nachrichtenorientierte Kommunikation
- Port
 - ◆ geschütztes Objekt des MACH-Kerns
 - ◆ kann Nachrichten (*Messages*) von einem Sender entgegennehmen und an einen Empfänger ausliefern
 - ◆ zu einem *Port* können beliebig viele Sender, aber nur ein Empfänger existieren
 - ◆ Zugriff auf einen *Port* erhält man durch Empfang einer Mitteilung, die ein *Port-Zugriffsrecht (Capability)* enthält

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung dieser Universität nicht zulässig. Jeder ist zur Einhaltung der Bestimmungen des Autors verpflichtet.

J.12

3 Interprocess Communication – IPC (2)

- Message
 - ◆ Ansammlung von Datenobjekten
 - ◆ unstrukturiert oder strukturiert (durch einen Typ näher gekennzeichnet), z.B.:
 - Daten mit Typinformation
 - Zeiger auf Adressräume
 - *Port-Zugriffsrechte (Capabilities)*
- IPC ist in MACH der allgemeine Mechanismus zur Ausführung von Operationen auf Objekten
 - ◆ Objekten (z. B. *Tasks* und *Threads*) sind Ports zugeordnet
 - ◆ Operationen auf Objekten werden durch Nachrichten an diese Ports ausgeführt
 - ◆ zuverlässige Nachrichtenübertragung

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung dieser Universität nicht zulässig. Jeder ist zur Einhaltung der Bestimmungen des Autors verpflichtet.

J.13

3 Interprocess Communication – IPC (3)

- Beispiel
 - ◆ Beim Erzeugen eines *Threads* erhält man Senderechte auf die *Ports* dieses *Threads*. Durch Mitteilungen an diese *Ports* kann der *Thread* manipuliert werden (suspendieren, deblockieren, vernichten, ...)
- Ablauf einer typischen Interaktion
 - ◆ Ein *Thread* von *Task A* schickt eine Nachricht an einen *Port*
 - ◆ *Task B* ist der Empfänger für diesen *Port*

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne Genehmigung dieser Universität nicht zulässig. Jeder ist zur Einhaltung der Bestimmungen des Autors verpflichtet.

J.14

3 Interprocess Communication – IPC (4)

- Capabilities werden ähnlich wie Dateideskriptoren verwaltet



- Jeder Task hat einen privaten Deskriptor für eine Portcapability
- Deskriptor ist mit Rechten verbunden: Senderecht (send), Empfangsrecht (recv)

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne in jeder Hinsicht an die Universität Erlangen-Nürnberg, Institut für Programmierung der Systeme, zu schreiben ist strafbar.

J.15

3 Interprocess Communication – IPC (5)

- Task A erzeugt eine Nachricht und sendet sie



- Adressat ist Port mit Deskriptor 2, Port b

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne in jeder Hinsicht an die Universität Erlangen-Nürnberg, Institut für Programmierung der Systeme, zu schreiben ist strafbar.

J.16

3 Interprocess Communication – IPC (6)

- Einstellen der Nachricht in der Port-Warteschlange



- Nachricht wird in die Warteschlange des Port b eingefügt
- übermittelte Capability wird in Portadresse umgesetzt
- Nachricht steht jetzt zum Empfang bereit
- Task A kann den Nachrichtenspeicher löschen oder wiederverwenden

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne in jeder Hinsicht an die Universität Erlangen-Nürnberg, Institut für Programmierung der Systeme, zu schreiben ist strafbar.

J.17

3 Interprocess Communication – IPC (7)

- Task B möchte eine Nachricht empfangen



- Task B benötigt neuen Deskriptor für die Capability in der Nachricht
- Deskriptor 2 mit dem entsprechenden Recht wird erzeugt

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne in jeder Hinsicht an die Universität Erlangen-Nürnberg, Institut für Programmierung der Systeme, zu schreiben ist strafbar.

J.18

3 Interprocess Communication – IPC (8)

- Task B empfängt Nachricht



- ◆ Task B erhält die Nachricht
- ◆ Portadresse wird in Deskriptor übersetzt
- ◆ Nachricht wird aus der Warteschlange entfernt
- ◆ Task B hat nun Zugriff auf den Port c

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg. Jegliche Vervielfältigung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg.

J.19

4 Übertragen einer „großen“ Nachricht

- Ablauf
- ◆ Task A sendet Message an Port P1
- ◆ der Datenbereich der Message wird temporär in den Adreßraum des Mach-Kerns abgebildet (= Senden an Port)
- ◆ im Adreßraum der Task A wird der Datenbereich als "copy on write" markiert (d. h. für Seiten, auf die nachfolgend Schreibend durch A zugegriffen wird, wird eine Kopie erzeugt und diese wird in den virtuellen Adreßraum von A übernommen)
- ◆ Task B empfängt die Mitteilung, indem der Datenbereich in den virt. Adreßraum von B abgebildet wird
- ◆ Aus dem Adreßraum des Mach-Kerns wird der Datenbereich wieder entfernt
- ◆ Auch bei Task B ist der Datenbereich als "copy on write" markiert

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg. Jegliche Vervielfältigung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg.

J.20

J.4 Virtuelle Speicherverwaltung (VM)

- Eigenschaften
- ◆ portabel
- ◆ hardwareunabhängig
- ◆ unterstützt Multiprozessoren: parallel ablauffähig implementiert
- ◆ unabhängige Pager

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg. Jegliche Vervielfältigung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg.

J.21

1 Motivation

- heute viele unterschiedliche MMUs verbreitet
- weitgehend äquivalente Funktionalität
- ◆ unterschiedliche virtuelle Adreßräume, beschrieben durch Datenstrukturen (z. B. Page table)
- ◆ pro Seite:
 - Zeiger auf physikalische Adresse der Seite
 - Valid bit zeigt an, ob die physikalische Seite gültig ist
 - Protection bits (z. B. read/write, user/kernel)
 - Dirty bit (Seite ist modifiziert)
 - Reference bit (Seite wurde angesprochen)

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc: 1998-02-18 09:51

Reproduzieren oder Abdruck ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg. Jegliche Vervielfältigung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg.

J.22

1 Motivation (2)

- Zwei mögliche Vorgehensweisen zur Unterstützung von virtuellem Speicher
- ◆ Mechanismen, die möglichst gut den Eigenschaften der verwendeten MMU entsprechen
 - System nicht portabel (z. B. VMS für VAX)
 - effizient
- ◆ Beschränkung auf Eigenschaften, die einfach auf jeder Hardware realisierbar sind
 - System weniger leistungsfähig und ineffizient (z. B. UNIX in 4.3bsd)
 - aber portabler

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.23

Reproduction oder andere Verwendung dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

2 Realisierung

- Ziel
 - ◆ möglichst flexible Unterstützung von virtuellem Speicher auf möglichst vielen Architekturen
- Vorgehensweise
 - ◆ Unterteilung der Implementierung
 - architekturabhängiger Teil
 - architekturunabhängiger Teil
 - externe Pager

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.24

Reproduction oder andere Verwendung dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

2 Realisierung (2)

- Architekturabhängiger Teil
 - ◆ Verwaltung der von der Hardware benötigten Adreßabbildungstabellen (*Physical address maps*, *pmaps*)
 - entsprechen den MMU-Tabellen (z. B. VAX *page table* oder eine Menge von Segmentregistern beim IBM PC/RT)
 - ◆ Abbildung von Mach-Seiten in eine oder mehrere Kacheln
 - ◆ konstruiert nur einen Teil der Adreßabbildung
 - ◆ Zugriff auf weitere Adressen kann bei *Page fault* ermöglicht werden
 - ◆ kleine Tabellen trotz großem (dünn besetztem) Adreßraum

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.25

Reproduction oder andere Verwendung dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

2 Realisierung (3)

- Architekturunabhängiger Teil
 - ◆ realisiert Benutzerschnittstelle und Funktionsumfang
 - ◆ Verwaltung der architekturunabhängigen Datenstrukturen
 - ◆ alle notwendigen Abbildungsinformationen für jede Seite des Systems können aus den architekturunabhängigen Datenstrukturen gewonnen werden
- externe Pager
 - ◆ Seitenein- und -auslagerung wird durch die virtuelle Speicherverwaltung (VM) von sogenannten *Pages* über Messages angefordert
 - entscheiden nicht über Ein- und Auslagerungsstrategie
 - entscheiden wohin ausgelagerte Seiten transportiert und woher eingelagerte Seiten bezogen werden (z.B. Platte, Netzwerk etc.)

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.26

Reproduction oder andere Verwendung dieser Vorlesung ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

2 Realisierung (4)

- Lazy evaluation
- ◆ Speicher (Haupt- und Hintergrundspeicher!) wird erst belegt, wenn eine Seite benutzt wird
- ◆ *Map-on-Reference*: Page tables werden nur für aktuell benötigten Speicher bereitgestellt
- ◆ *Copy-on-write*: Seiten werden solange gemeinsam benutzt wie möglich; bei modifizierendem Zugriff werden Nutzer voneinander getrennt

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.27

Reproduktion oder die auch Verwendung dieser Unterlagen oder in Lehrveranstaltungen ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen

- Memory Object
- ◆ repräsentiert einen Speicherbereich, der ganz oder teilweise in einen Adreßraum eingeblendet werden kann
- ◆ Bindeglied zwischen virtuellem Adreßraum und Hintergrundspeicher
- ◆ das *Memory object* kennt oder implementiert einen Pager, der weiß woher die Seiten des Speicherbereichs beschafft werden können und was im Falle eines *Pagout* zu tun ist
- ◆ Pager (intern oder extern) realisiert Ein-/Auslagerung von Seiten
- ◆ *Memory object* hält Liste von Seiten, die momentan im Hauptspeicher vorhanden sind (*cached pages*)

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.28

Reproduktion oder die auch Verwendung dieser Unterlagen oder in Lehrveranstaltungen ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen (2)

- Address Map
- ◆ repräsentiert einen Adreßraum
- ◆ als verkettete Liste von *Address map entries* realisiert
- ◆ jeder Eintrag bildet einen (virtuellen) Speicherbereich mit gleichen Eigenschaften (Schutz, Vererbung) in einen Abschnitt eines *Memory objects* ab
- ◆ *Address map entry* enthält:
 - Vorwärts- und Rückwärts-Verzeigerung
 - Start- und Endadresse des Speicherbereichs im virtuellen Adreßraum
 - aktuelle und maximale Zugriffsrechte
 - Regel für Vererbung des Speicherbereichs an neue Task
 - Zeiger auf *Memory object*
 - Offset dieses Speicherbereichs im entsprechenden *Memory object*

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.29

Reproduktion oder die auch Verwendung dieser Unterlagen oder in Lehrveranstaltungen ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen (3)

- Sharing Maps
- ◆ zur Realisierung von *Shared memory*
- ◆ Zwischenstufe zwischen *Address map* und *Memory object*
- ◆ Änderungen in *Address map*-Eintrag eines Objekts müssen nicht in den *Address maps* mehrerer Tasks nachgetragen werden
- Shadow Object
- ◆ wird wie ein *Memory object* benutzt
- ◆ zur Realisierung von *Copy-on-write*
- ◆ nimmt Seiten auf, die kopiert werden mußten
- ◆ verweist für unveränderte Seiten auf das Originalobjekt

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

J.30

Reproduktion oder die auch Verwendung dieser Unterlagen oder in Lehrveranstaltungen ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen (4)

- Resident Page Table
- Verwaltung des Hauptspeicher-Caches für *Memory object*-Seiten
- Verkettung in Listen



- Abbildung des Codesegments in eine Programmdatei
- Abbildung des Daten- und Stacksegments in einen *Swap space*

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

J.31

Reproduktion oder andere Verwendung dieser Unterlagen, selbst in Lehrzwecken, ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen (5)

- Datenstrukturen der Adreßraumabbildung: *Address map*



Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

J.32

Reproduktion oder andere Verwendung dieser Unterlagen, selbst in Lehrzwecken, ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

3 Datenstrukturen (6)

- Beispielhafter Gesamtüberblick



Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.33

Reproduktion oder andere Verwendung dieser Unterlagen, selbst in Lehrzwecken, ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

4 Benutzerschnittstelle

- MACH-VM stellt folgende Funktionen zur Verfügung:
 - virtuelle Speicherbereiche belegen und freigeben
 - Schutzparameter für einzelne virtuelle Speicherbereiche individuell einstellen (innerhalb vorgegebener Schranken: *current / maximum protection*)
 - Vererbung an neue Task einzeln einstellbar
 - keine Vererbung
 - Copy-on-write (default)
 - Shared
 - Zugriffsmöglichkeit auf Speicherabbildung anderer Tasks (Debugger!)
 - Status- und Statistikabfragen

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.34

Reproduktion oder andere Verwendung dieser Unterlagen, selbst in Lehrzwecken, ist ohne schriftliche Genehmigung der Universität Erlangen-Nürnberg strafbar.

4 Benutzerschnittstelle (2)

- Anwendungsbeispiel
 - ◆ *Memory mapped files* für Benutzer und Kern
 - ◆ Realisierung: Memory object mit entsprechendem Pager
 - ◆ Kern-Anwendungen:
 - Programme laden
 - *Shared libraries*
 - Dateisystem
 - ◆ Benutzeranwendungen:
 - neue *Stdio* mit Dateizugriff über *Mapped file*
 - Dateizugriff über Pointer

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.35

Reproduction of this article for private use without the written permission of the University of Erlangen-Nürnberg is prohibited.

4 Benutzerschnittstelle (3)

- Erfahrungen mit verschiedenen Hardware-Architekturen
 - ◆ Virtuelle Speicherverwaltung von Mach ist
 - portabel
 - stellt wenig Anforderungen an die Hardware-Plattform
 - und wurde auf einer Reihe von Architekturen implementiert
 - ◆ gute Basis für Untersuchungen von VM-Problemen bei verschiedenen Architekturen

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.36

Reproduction of this article for private use without the written permission of the University of Erlangen-Nürnberg is prohibited.

5 VM auf Multiprozessoren

- ★ Problem: *Translation Lookaside Buffer (TLB)* - Inkonsistenz
 - ◆ TLB = Cache für die Adreßdaten der SKT, um eine schnelle Adreßübersetzung ohne zusätzliche Hauptspeicher-Zugriffe durch die MMU zu ermöglichen
 - ◆ bei *Shared memory*-Multiprozessoren werden normalerweise Strategien implementiert, um die Caches der Prozessoren konsistent zu halten
 - ◆ analog ist es notwendig die TLBs der Prozessoren konsistent zu halten, wenn Threads einer Task parallel auf verschiedenen Prozessoren ablaufen
 - wenn sich die architekturabhängigen VM-Datenstrukturen einer Task ändern, müssen die TLBs aller Prozessoren aktualisiert werden, auf denen Threads der Task ablaufen
 - in anderen Betriebssystemen ist dies meist kein Problem, weil in einem Adreßraum nicht mehrere Aktivitätsträger existieren
 - die *Lazy evaluation*-Techniken in Mach führen dazu, daß sehr häufig die pmap-Strukturen angepaßt werden müssen

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.37

Reproduction of this article for private use without the written permission of the University of Erlangen-Nürnberg is prohibited.

5 VM auf Multiprozessoren (2)

- ◆ viele heutige Multiprozessorarchitekturen ignorieren dieses Problem!
- Intuitive Lösungsidee
 - ◆ nach einer Änderung der VM-Abbildung werden durch einen Befehl die TLBs der anderen Prozessoren invalidiert
- ▲ Problem
 - ◆ die meisten MPS-Systeme erlauben es einem Prozessor nur, seinen eigenen TLB, aber nicht die anderer Prozessoren zu invalidieren
- weitergehende Lösungsideen
 - ◆ Hardware-Unterstützung implementieren oder
 - ◆ durch Software-Interrupts die anderen Prozessoren zum Invalidieren ihrer TLBs bewegen

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

J.38

Reproduction of this article for private use without the written permission of the University of Erlangen-Nürnberg is prohibited.

5 VM auf Multiprozessoren (3)

▲ Problem

- ◆ systeminitiierte Aktualisierung der pmap-Strukturen überschneidet sich mit der prozessorinitiierten Aktualisierung (z.B. Setzen des *Reference bit*)
- ◆ inkonsistente Menge von TLB-Einträgen in der MMU möglich
- ◆ Überschreiben der pmap-Strukturen durch die MMU möglich

■ Mögliche Lösungen

- ◆ Prozessoren werden durch Interrupt informiert und führen ein TLB-Konsistenz-Protokoll durch
- ◆ die Nutzung geänderter Abbildungen wird verzögert, bis alle TLBs *flushed* wurden
- ◆ Inkonsistenzen werden in unkritischen Fällen toleriert (z. B. wenn die Zugriffsrechte erweitert werden)
- ◆ Komplexere Algorithmen: z. B. *Shootdown* Algorithmus

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne zu fragen ist ein Verstoß gegen die Urheberrechte der Universität Erlangen-Nürnberg. Jegliche Art der Zerstörung des Dokuments ist strafbar.

J.39

J.5 Mach in verteilten Systemen

1 Netzwerk-Kommunikation

- Mach IPC nur für lokale Kommunikation konzipiert
- ◆ Nachrichten können durch *Network-Server-Tasks* (im User-level!) an andere Knoten weitergeleitet werden
- ◆ Capability-Funktionalität wird über Netzwerk abgebildet
- ◆ Netzwerktransfer wird geschützt
 - DES-Verschlüsselung der Daten
 - Sequenznummern und Checksummen für Pakete
- ◆ Authentisierung anderer Netzwerk-Server für den Capability-Transfer (*Secret Identifier*)

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998


J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne zu fragen ist ein Verstoß gegen die Urheberrechte der Universität Erlangen-Nürnberg. Jegliche Art der Zerstörung des Dokuments ist strafbar.

J.40

1 Netzwerkkommunikation (2)

■ Schaubild einer verteilungstransparenten Taskkommunikation



- ◆ Netzwerkserver fungieren als Vermittler
- ◆ sie stellen jeweils lokale Ports bereit und tunneln Kommunikation durch die Ports über ein Netzwerk

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne zu fragen ist ein Verstoß gegen die Urheberrechte der Universität Erlangen-Nürnberg. Jegliche Art der Zerstörung des Dokuments ist strafbar.

J.41

2 Distributed Shared Memory

- der *Shared memory*-Bereich wird durch ein *Memory Object* repräsentiert
- ◆ jede beteiligte Task bildet den Speicherbereich in ihren Adressraum ab
- ◆ dem *Memory Object* wird ein *External pager* zugeordnet
- ◆ durch die *Lazy evaluation*-Technik werden die Seiten erst auf Anforderung in den Hauptspeicher (Seiten-Cache) geholt
- ◆ im Fall von *Page faults* werden die Seiten von dem *External pager* angefordert
 - diese Anforderungen erfolgen über die regulären Mach Kommunikationsmechanismen, sind also auch auf Netzwerkkommunikation erweiterbar

SP I

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998

J-Mach.doc 1998-02-18 09:51

Reproduzieren oder Verwenden dieser Unterlagen ohne zu fragen ist ein Verstoß gegen die Urheberrechte der Universität Erlangen-Nürnberg. Jegliche Art der Zerstörung des Dokuments ist strafbar.

J.42

2 Distributed Shared Memory (2)

- ◆ als *External pager* wird ein sog. *Shared memory server* benutzt, der Buch über das Caching der Seiten führt
- ◆ *read-only* Seiten können problemlos auf mehreren Knoten gecached werden
- ◆ bei Schreibzugriff wird ein *Page fault* erzeugt; der *Shared memory server* wird informiert, er entzieht den anderen Knoten den Zugriff auf die Seite und erlaubt dann den Schreibzugriff