

7 Heutige asymmetrische Verfahren

■ RSA (Rivest, Shamir und Adleman)

- ◆ Öffentlicher Schlüssel (zum Verschlüsseln) besteht aus (e, N)
- ◆ Ein Block M wird verschlüsselt durch: $C = E(e, N, M) = M^e \bmod N$
- ◆ C wird entschlüsselt durch: $M = D(d, N, C) = C^d \bmod N$
- ◆ Wahl der Schlüssel:
 - Es muß gelten $\forall M: (M^e)^d = M \bmod N$
 - Aus Kenntnis von e und N darf d nur mit hohem Aufwand ermittelbar sein
- ◆ Lösung:
 - $N = pq$ mit p und q zwei hinreichend große Primzahlen
 - zufällige Wahl von d , teilerfremd zu $(p-1)(q-1)$
 - Berechnung von e aus der Bedingung: $ed = 1 \bmod ((p-1)(q-1))$
- ◆ Es ist aufwendig, die Primfaktoren von N zu berechnen (mit diesen wäre es möglich d zu ermitteln)

7 Heutige asymmetrische Verfahren (2)

■ Vorteil asymmetrischer Verfahren (*Public key*-Verfahren)


- ◆ nur ein Schlüsselpaar pro Teilnehmer nötig
(sonst ein Schlüsselpaar pro Kommunikationskanal!)
- ◆ Schlüsselverwaltung erheblich vereinfacht
 - jeder Teilnehmer erzeugt sein Schlüsselpaar und
 - veröffentlicht seinen öffentlichen Schlüssel
- ◆ Authentisierung durch digitale Unterschriften möglich
- ◆ gilt als sicher bei hinreichend großer Schlüssellänge (1024 Bit)

■ Nachteil

- ◆ relativ langsam berechenbar
- ◆ gemischter Betrieb von asymmetrischen und symmetrischen Verfahren zur Geschwindigkeitssteigerung

7 Heutige asymmetrische Verfahren (3)

■ Beispiel: PGP Verschlüsselung



- ◆ Daten werden mit einem individuellen Schlüssel IDEA-verschlüsselt
- ◆ IDEA-Schlüssel wird RSA-verschlüsselt der Nachricht angehängt

★ Nachricht an mehrere Adressaten verschickbar

- ◆ lediglich der IDEA-Schlüssel muß in mehreren Varianten verschickt werden (je eine Version verschlüsselt mit dem öffentl. Schlüssel des Empfängers)

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.103

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

8 Digitale Unterschriften

■ Authentisierung des Absenders

- ◆ Bilden eines Hash-Wertes über die zu übermittelnde Nachricht
 - Hash-Wert ist ein Codewort fester Länge
 - es ist unmöglich oder nur mit hohem Aufwand möglich, für einen gegebenen Hash-Wert eine zugehörige Nachricht zu finden
- ◆ Verschlüsseln des Hash-Wertes mit dem geheimen Schlüssel des Absenders (digitale Unterschrift, digitale Signatur)
- ◆ Anhängen des verschlüsselten Hash-Wertes an die Nachricht
- ◆ Empfänger kann den Hash-Wert mit dem öffentlichen Schlüssel des Absenders dechiffrieren und mit einem selbst berechneten Hash-Wert der Nachricht vergleichen
- ◆ stimmen beide Werte überein muß die Nachricht vom Absender stammen, denn nur der besitzt den geheimen Schlüssel

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.104

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

8 Digitale Unterschriften (2)

- Kombination mit Verschlüsselung
 - ◆ erst signieren
 - ◆ dann mit dem öffentlichen Schlüssel des Adressaten verschlüsseln
- ▲ Reihenfolge wichtig
 - ◆ Man signiere nichts, was man nicht entschlüsseln kann
- Heute gängiges Hash-Verfahren
 - ◆ MD5
 - ◆ 128 Bit langer Hash-Wert

8 Digitale Unterschriften (3)

- Woher weiß ich, daß ein öffentlicher Schlüssel authentisch ist?
 - ◆ Ich bekomme den Schlüssel vom Eigentümer (persönlich, telefonisch).
 - Hash-Wert auf öffentlichen Schlüsseln, die leichter zu überprüfen sind (Finger prints)
 - ◆ Ich vertraue jemandem (Bürge), der zusichert, daß der Schlüssel authentisch ist.
 - Schlüssel werden von dem Bürgen signiert.
 - Bürge kann auch eine ausgezeichnete Zertifizierungsstelle sein.
 - Netzwerk von Zusicherungen auf öffentliche Schlüssel (*Web of Trust*)
 - ◆ Möglichst weite Verbreitung von öffentlichen Schlüsseln erreichen (z.B. PGP: Webserver als Schlüsselservers)

8 Digitale Unterschriften (4)

- ▲ Mögliche Probleme von Public key-Verfahren
 - ◆ Geheimhaltung des geheimen Schlüssels
(Time sharing-System, Backup; Schlüsselpaßwort / Pass phrase)
 - ◆ Vertrauen in die Programme (z.B. PGP)
 - ◆ Ausspähung während des Ver- und Entschlüsselungsvorgangs

I.7 Authentisierung im Netzwerk

- Viele Klienten, die viele Dienste in Anspruch nehmen wollen
 - ◆ Dienste (*Server*) wollen wissen welcher Benutzer (*Principal*), den Dienst in Anspruch nehmen will (z.B. zum Accounting, Zugriffsschutz, etc.)
 - ◆ Im lokalen System reicht die (durch das Betriebssystem) geschützte Benutzererkennung (z.B. UNIX UID) als Ausweis
 - ◆ Im Netzwerk können Pakete abgefangen, verfälscht und gefälscht werden (einfache Übertragung einer Benutzererkennung nicht ausreichend sicher)
- Public key-Verfahren
 - ◆ Authentisierung durch digitale Unterschrift (mit geheimen Schlüssel des Senders) und Verschlüsseln (mit öffentlichem Schlüssel des Empfängers)
 - ◆ Nachteile
 - jeder Dienst benötigt sicheren Zugang zu allen öffentlichen Schlüsseln
 - Verschlüsseln und Signieren mit RSA ist sehr teuer

I.7 Authentisierung im Netzwerk (2)

★ Einsatz von Authentisierungsdiensten

- ◆ zentraler Server, der alle Benutzer kennt
- ◆ Authentisierungsdienst garantiert einem Netzwerkdienst, daß ein Benutzer auch der ist, der er vorgibt zu sein

■ Benutzerausweis

- ◆ der Authentisierungsdienst erkennt den Benutzer anhand eines geheimen Schlüssels oder Paßworts
- ◆ der Schlüssel ist nur dem Authentisierungsdienst und dem Benutzer bekannt

■ Vorgang

- ◆ Benutzer (*Principal*) will mit einem Programm (*Client*) einen Dienst (*Server*) in Anspruch nehmen
- ◆ durch geeignetes Protokoll erhalten Client und Server jeweils einen nur ihnen bekannten Schlüssel, mit dem sie ihre Kommunikation verschlüsseln können (*Session key*)

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

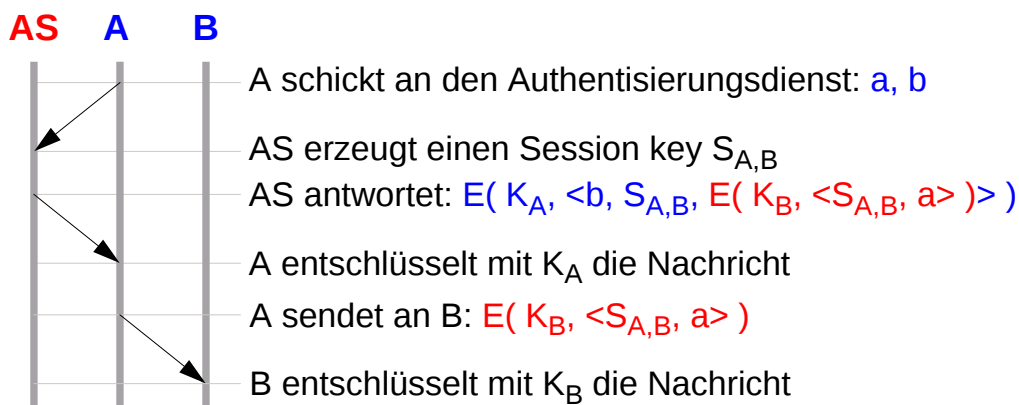
I-Security.fm 1999-02-16 13.38

I.109

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

1 Einfacher Authentisierungsdienst

■ A will den Dienst B in Anspruch nehmen (Nach Needham-Schröder):



- ◆ K_x ist der geheime Schlüssel, den nur Authentisierungsdienst und X kennen
- ◆ nach dem Protokollablauf kennen sowohl A und B den Session key
- ◆ A weiß, daß nur B den Session key kennt
- ◆ B weiß, daß nur A den Session key kennt

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.110

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

1 Einfacher Authentisierungsdienst (2)

▲ Problem

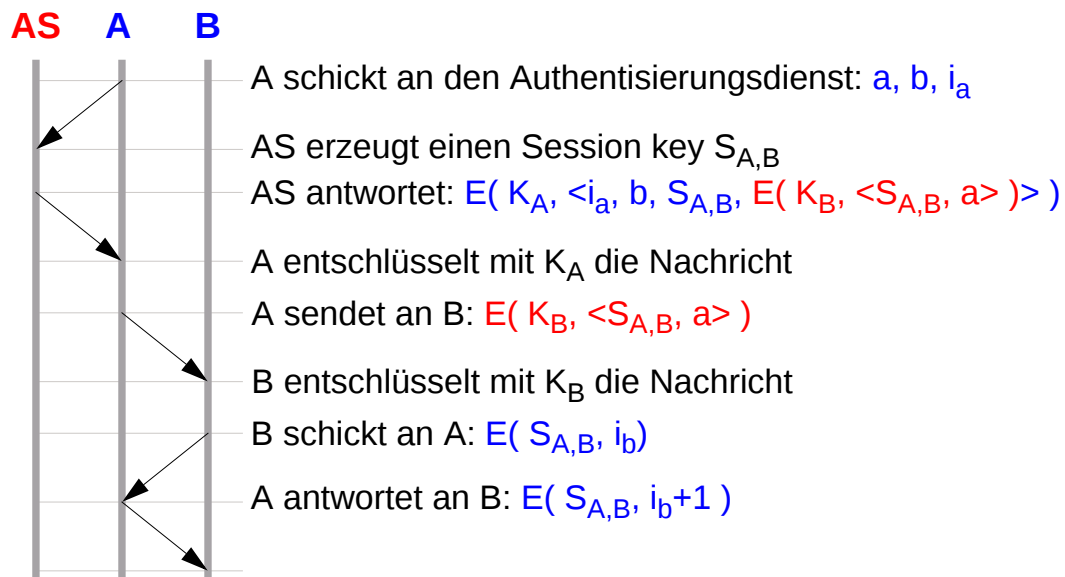
◆ letzte Nachricht von A an B könnte aufgefangen und später erneut ins Netz gegeben werden (*Replay attack*)

◆ Folge: Kommunikation zwischen A und B kann gestört werden

★ Korrektur durch zusätzliches Versenden einer Verbindungsbestätigung durch B und A

2 Authentisierungsdienst mit Bestätigung

■ Bestätigung enthält Einmalinformation (*Nonce*)



◆ ein Wiedereinspielen der Nachricht $E(K_B, \langle S_{A,B}, a \rangle)$ oder $E(S_{A,B}, i_b+1)$ wird erkannt und kann ignoriert werden

2 Authentisierungsdienst mit Bestätigung (2)

▲ Problem

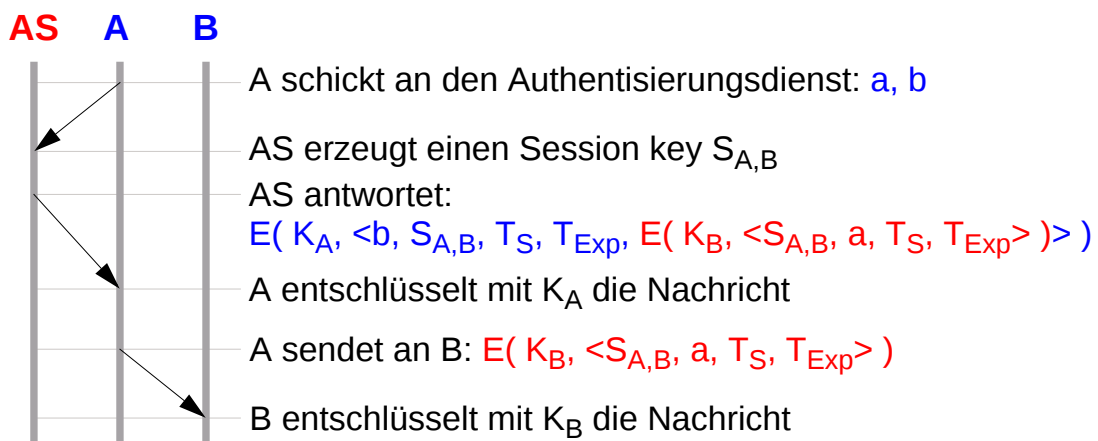
- ◆ Aufzeichnen von $E(K_B, \langle S_{A,B}, a \rangle)$ und
- ◆ Brechen von $S_{A,B}$ erlaubt das Aufbauen einer Verbindung.
- ◆ ein Dritter kann dann die erste Bestätigung abfangen und die zweite Bestätigung verschicken

★ Lösung

- ◆ Einführung von Zeitstempeln (*Time stamp*) und Angaben zur Lebensdauer (*Expiration time*)

3 Authentisierungsdienst mit Zeitstempeln

■ Authentisierungsdienst versieht seine Nachrichten mit Zeitstempeln



- ◆ T_S = Zeitstempel der Nachrichtenerzeugung
- ◆ T_{Exp} = maximale Lebensdauer der Nachricht
- ◆ aufgezeichnete Nachricht kann nach kurzer Zeit (z.B. 5min) nicht noch einmal zum Aufbau einer Verbindung verwendet werden

4 Beispiel: Kerberos

■ Kerberos V5

- ◆ Softwaresystem implementiert Weiterentwicklung des Needham-Schröder-Protokolls
- ◆ entwickelt am MIT seit 1986

■ Ziel

- ◆ Authentisierung und Erzeugung eines gemeinsamen Schlüssels durch den vertrauenswürdigen Kerberos-Server


■ Idee

- ◆ Trennung von Authentisierungsdienst und Schlüsselerzeugung
- ◆ reduziert die nötige Übertragung einer Identifikation oder eines Paßworts zum Kerberos-Server

4 Beispiel: Kerberos (2)

■ Benutzer holt sich zunächst ein Ticket vom Authentisierungsdienst

AS A



A schickt an den Authentisierungsdienst: a , tgs , T_{Exp} , i_a

AS erzeugt ein Ticket für den Ticket Server tgs

AS antwortet:

$E(K_A, \langle S_{A,TGS}, tgs, T_{Exp}, i_a, E(K_{TGS}, \langle S_{A,TGS}, a, T_{Exp} \rangle) \rangle)$

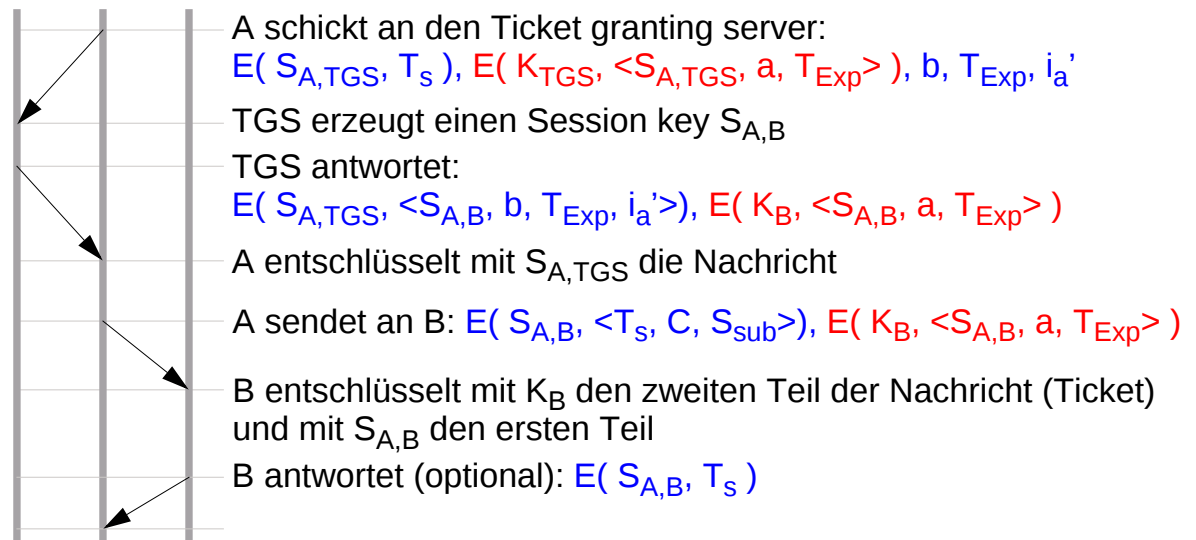
A entschlüsselt mit K_A die Nachricht

- ◆ das Ticket besteht aus $\langle S_{A,TGS}, a, T_{Exp} \rangle$
- ◆ es enthält einen Session key für die Kommunikation mit einem Ticket granting server, der dann die Verbindung zu einem Netzwerkdienst bereitstellen kann

4 Beispiel: Kerberos (3)

- Authentisierungsdienst versieht seine Nachrichten mit Zeitstempeln

TGS A B



- ◆ C = Checksumme zur Überprüfung der richtigen Entschlüsselung
- ◆ A kann mehrere Verbindungen mit seinem Ticket öffnen

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.117

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

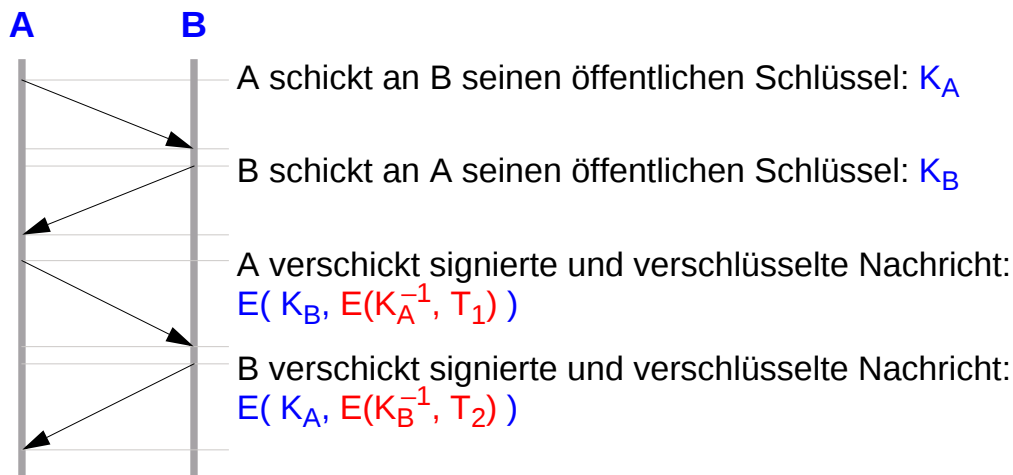
I-Security.fm 1999-02-16 13.38

I.118

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999


I-Security.fm 1999-02-16 13.38

I.119

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

5 Austausch öffentlicher Schlüssel (2)

- Aktiver Mithörer C fängt Datenverbindungen ab (*Man in the middle attack*)



SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

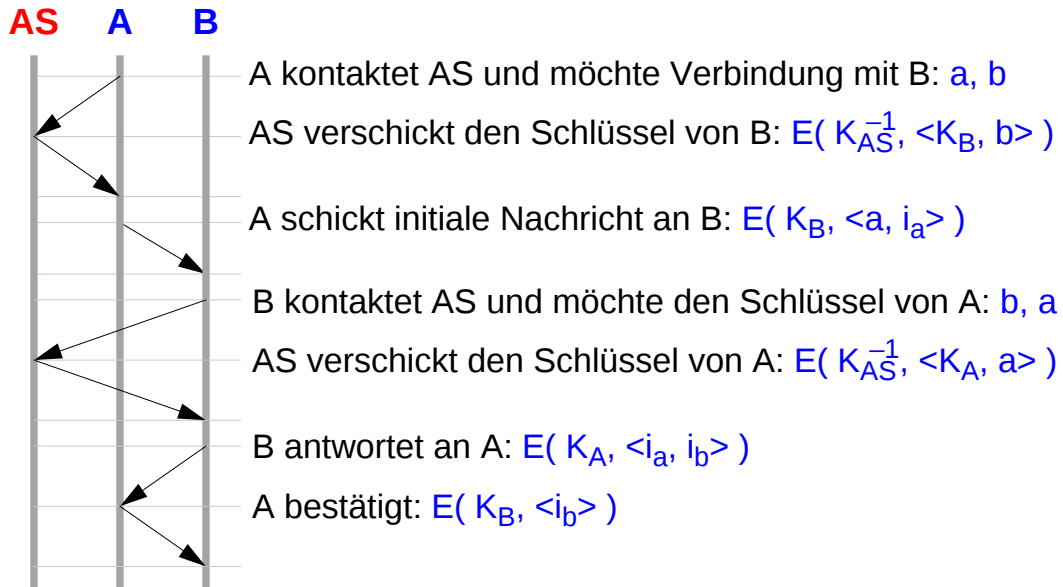
I-Security.fm 1999-02-16 13.38

I.120

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

5 Austausch öffentlicher Schlüssel (3)

■ Einsatz eines Authentisierungsdienstes



▲ Replay-Probleme

◆ Hinzunahme von Zeitstempel und Lebendauer

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.121

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999


I-Security.fm 1999-02-16 13.38

I.122

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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)



I.9 Richtlinien für den Benutzer

1 Paßwörter

- Wahl eines Paßworts
 - ◆ hinreichend komplexe Paßwörter wählen
 - ◆ Schutz vor Wörterbuchangriffen
 - ◆ verschiedene Paßwörter für verschiedene Aufgaben (z.B. PPP Paßwort ungleich Benutzerpaßwort)
- Aufbewahrung
 - ◆ möglichst nirgends aufschreiben
 - ◆ nicht weitergeben
 - ◆ kein Abspeichern auf einem Windows-Rechner (Option immer wegstreichen)

1 Paßwörter

■ Eingabe

- ◆ niemals über eine unsichere Rechnerverbindung eingeben
 - **ftp, telnet, rlogin** Dienste vermeiden
 - nur sichere Dienste verwenden: **ssh, slogin**
 - Datenweg beachten, über den das Paßwort läuft:
ein unsicheres Netzwerk ist bereits genug

■ Änderung

- ◆ Paßwörter regelmäßig wechseln
- ◆ alte Paßwörter nicht wiederverwenden

2 Schlüsselhandhabung

■ Einsatz von PGP oder S/MIME

- ◆ Zugang zu den privaten Schlüsseln für andere verhindern
- ◆ Dateirechte auf der Schlüsseldatei prüfen
- ◆ privater Schlüssel nur auf Diskette
- ◆ Passphrase wie ein Paßwort behandeln
- ◆ privaten Schlüssel nie über unsichere Netze transportieren

3 E-Mail

■ Authentisierung

- ◆ Bei elektronischer Post ist der Absender nicht authentisierbar
- ◆ Digitale Unterschriften einsetzen (z.B. mit PGP oder S/MIME)

■ Abhören

- ◆ Elektronische Post durchläuft viele Zwischenstationen und kann dort jeweils gelesen und verfälscht werden
- ◆ Verschlüsselung einsetzen (z.B. mit PGP oder S/MIME)

4 Programmierung

■ S-Bit Programme vermeiden

- ◆ Oft kann das S-Bit durch geschickte Vergabe von Benutzergruppen an Dateien vermieden werden

■ Verwendung zusätzlicher Rechte (z.B. durch S-Bit) nur in Abschnitten

- ◆ Trusted Computing Base (TCB)

```
seteuid(getuid());/* am Programmanfang Rechte wegnehmen */
...
seteuid(0);      /* setzt root Rechte */
fd = open("/etc/passwd", O_RDWR);
seteuid(getuid());/* nimmt root Rechte wieder weg */
...
```

■ Sorgfältige Programmierung

- ◆ Funktionen wie **strcpy**, **strcat**, **gets**, **sprintf**, **scanf**, **sscanf**, **system**, **popen** vermeiden oder durch **strncpy**, **fgets**, **snprintf** ersetzen

5 World Wide Web

■ Cookies

- ◆ Akzeptieren von Cookies erlaubt einer Web site die angesprochenen Seiten genau einem Benutzer zuzuordnen
- ◆ funktioniert über Sessions hinweg

■ JavaScript

- ◆ schwere Sicherheitslücken erlauben es, alle für den Benutzer lesbare Dateien an einen dritten weiterzugeben
- ◆ Ausschalten!

■ Abhören

- ◆ WWW Verbindungen können abgehört werden
- ◆ keine privaten Daten, wie z.B. Kreditkartennummern übertragen
- ◆ HTTPS mit SSL-Verschlüsselung benutzen; https URLs

SPI

Systemprogrammierung I

© Franz J. Hauck, Universität Erlangen-Nürnberg, IMMD IV, 1998/1999

I-Security.fm 1999-02-16 13.38

I.129

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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

SPI

Systemprogrammierung I

© Franz J. Hauck, Univ. Erlangen-Nürnberg, IMMD IV, 1998/1999

J-Mach.fm 1999-02-09 15.39

J.1

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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 kritiklos in den Kern eingebaut, weil dort die notwendigen Information 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

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

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

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.

1 Task

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

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*

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

3 Interprocess Communication – IPC (2)

■ Message

- ◆ Ansammlung von Datenobjekten
- ◆ unstrukturiert oder strukturiert (durch einen Typ näher gekennzeichnet), z.B.:
 - Daten mit Typinformation
 - Zeiger auf Adreßraumbereiche
 - *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

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

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)

3 Interprocess Communication – IPC (5)


- Task A erzeugt eine Nachricht und sendet sie



- ◆ Adressat ist Port mit Deskriptor 2, Port b

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

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

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

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

J.4 Virtuelle Speicherverwaltung (VM)

■ Eigenschaften

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

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)

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

2 Realisierung

■ Ziel

- ◆ möglichst flexible Unterstützung von virtuellem Speicher auf möglichst vielen Architekturen

■ Vorgehensweise

- ◆ Unterteilung der Implementierung
 - architekturabhängiger Teil
 - architekturunabhängiger Teil
 - externe Pager

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

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 *Pagern* 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.)

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

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*)

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*

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

3 Datenstrukturen (4)

■ Resident Page Table

- ◆ Verwaltung des Hauptspeicher-Caches für *Memory object*-Seiten
- ◆ Verkettung in Listen

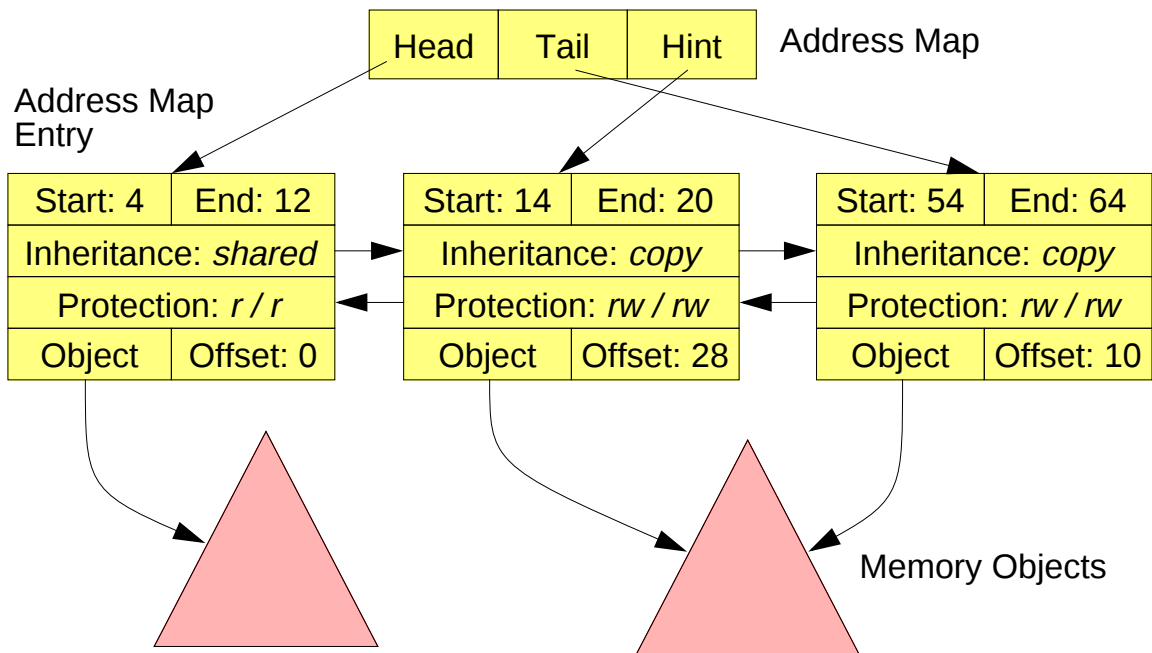
■ Beispiel eines Adreßraums (z.B. einer Task)



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

3 Datenstrukturen (5)

■ Datenstrukturen der Adreßraumabbildung: *Address map*



SPI

Systemprogrammierung I

© Franz J. Hauck, Univ. Erlangen-Nürnberg, IMMD IV, 1998/1999


J-Mach.fm 1999-02-09 15.39

J.28

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

3 Datenstrukturen (6)

■ Beispielhafter Gesamtüberblick



SPI

Systemprogrammierung I

© Franz J. Hauck, Univ. Erlangen-Nürnberg, IMMD IV, 1998/1999

J-Mach.fm 1999-02-09 15.39

J.29

Reproduktion jeder Art oder Verwendung dieser Unterlage, außer zu Lehrzwecken an der Universität Erlangen-Nürnberg, bedarf der Zustimmung des Autors.

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

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

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

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

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

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 *geflushed* wurden
- ◆ Inkonsistenzen werden in unkritischen Fällen toleriert (z. B. wenn die Zugriffsrechte erweitert werden)
- ◆ Komplexere Algorithmen: z. B. *Shootdown* Algorithmus

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*)

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

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

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