

Zusammenfassung

- Funktional: **was** ein (Software)-Produkt tun soll
- Nichtfunktional: **wie** funktionale Eigenschaften realisiert werden
- andere Bezeichnungen NFE: Qualitäten, Quality of Service

Laufzeiteigenschaften zur Laufzeit eines Systems beobachtbar

- Sparsamkeit und Effizienz
- Robustheit, Verfügbarkeit
- Sicherheit (Security)
- Echtzeitfähigkeit, Adaptivität, Performanz

Evolutionseigenschaften (Weiter-) Entwicklung und Betrieb

- Wartbarkeit, Portierbarkeit
- Offenheit, Erweiterbarkeit

Mobile und eingebettete Systeme (kleine Auswahl)

- mobile Rechner-Endgeräte
- Weltraumfahrt und -erkundung
- Automobile
- verteilte Sensornetze (WSN)
- Chipkarten
- Multimedia-und Unterhaltungselektronik

Betriebssysteme

Hardwarebasis

- Einst: Einprozessor-Systeme
 - Heute: Mehrprozessor-/hochparallele Systeme
 - neue Synchronisationsmechanismen erforderlich
- unterschiedliche Hardware und deren Multiplexing

Betriebssystemarchitektur

- Einst: Monolithische und Makrokern-Architekturen
 - Heute: Mikrokern-(basierte) Architekturen
 - Exokernbasierte Architekturen (Library-Betriebssysteme)
 - Virtualisierungsarchitekturen
 - Multikern-Architekturen
- unterschiedliche Architekturen

Ressourcenverwaltung

- Einst: Batch-Betriebssysteme, Stapelverarbeitung (FIFO)
 - Heute: Echtzeitgarantien für Multimedia und Sicherheit
 - echtzeitfähige Scheduler, Hauptspeicherverwaltung, Ereignismanagement, Umgang mit Überlast/Prioritätsumkehr ...
- unterschiedliche Ressourcenverwaltung

Betriebssystemabstraktionen

- Reservierung von Ressourcen (→ eingebettete Systeme)
 - Realisierung von QoS-Anforderungen (→ Multimediasysteme)
 - Erhöhung der Ausfallsicherheit (→ verfügbarkeitskritisch)
 - Schutz vor Angriffen und Missbrauch (→ sicherheitskritisch)
 - flexiblen und modularen Anpassen des BS (→ hochadaptiv)
- höchst diverse Abstraktionen von Hardware

Betriebssysteme als Softwareprodukte

- Betriebssystem: endliche Menge von Quellcode
 - besitzen differenzierte Aufgaben → funktionale Eigenschaften
 - Anforderungen an Nutzung und Pflege → Evolutionseigenschaften
 - können für Betriebssysteme höchst speziell sein
- spezielle Anforderungen an das Softwareprodukt BS

Grundlegende funktionale Eigenschaften von BS: Hardware-

Abstraktion Ablaufumgebung auf Basis der Hardware bereitstellen

Multiplexing Ablaufumgebung zeitlich/logisch getrennt einzelnen Anwendungen zuteilen

Schutz gemeinsame Ablaufumgebung gegen Fehler und Manipulation

Sparsamkeit und Effizienz

- Sparsamkeit: Funktion mit minimalem Ressourcenverbrauch
- Effizienz: Grad der Sparsamkeit
- Die jeweils betrachtete Ressource muss dabei spezifiziert sein
- sinnvolle Möglichkeiten bei BS: Sparsamer Umgang mit Energie, Speicherplatz oder Prozessszeit

1. Hardware-Ebene: Betriebe mit verringertem Energieverbrauch
2. Software-Ebene: neue Komponenten entwickeln, um

- Bedingungen für energiesparen erkennen
- Steuerungs-Algorithmen für Hardwarebetrieb
- Energie-Verwaltungsstrategien
- Bsp: Festplatten-Prefetching, RR-Scheduling

Sparsamkeit mit Speicherplatz

- Maßnahmen Hauptspeicherauslastung
 1. Speicherplatz sparende Algorithmen gleicher Strategien
 2. Speicherverwaltung von Betriebssystemen
 - physische vs. virtuelle Speicherverwaltung
 - speichereffiziente Ressourcenverwaltung
 - Speicherbedarfes Kernels
 - direkte Speicherverwaltungskosten
- Maßnahmen Hintergrundspeicherauslastung
 1. Speicherbedarf des Betriebssystem-Images
 2. dynamische SharedLibraries
 3. VMM-Auslagerungsbereich
 4. Modularität und Adaptivität des Betriebssystem-Images

→ 99% Überschneidung mit NFE Performanz

Robustheit und Verfügbarkeit

- Robustheit: Zuverlässigkeit unter Anwesenheit externer Ausfälle
- *aktiviert, error breitet sich aus, failure*
- Korrektheit: Systemverhalten gemäß seiner Spezifikation
- Verfügbarkeit: Anteil an Laufzeit, in dem Leistung erbracht

Robustheit

- Erhöhung durch Isolation: Verhinderung der Fehlerausbreitung
 1. Adressraumisolation: Mikrokernarchitekturen,
 2. kryptografische HW-Unterstützung (Intel SGX)
 3. Virtualisierungsarchitekturen
- Behandlung von Ausfällen: Micro-Reboots

Vorbedingung für Robustheit: Korrektheit

1. Tests: nur Fehler aufspüren, keine Fehlerfreiheit garantiert
2. Verifizierung: komplex und umfangreich durch Modelle begrenzt

Verfügbarkeit

- angesprochen: Hochverfügbare Systeme
- Maßnahmen: Redundanz, Ausfallmanagement

Sicherheit

- Sicherheit: Schutz gegen Schäden durch zielgerichtete Angriffe, besonders Informationen (speichern, verarbeiten, kommunizieren)
- Sicherheitsziele
 1. Vertraulichkeit (Confidentiality)
 2. Integrität (Integrity)
 3. Verfügbarkeit (Availability)
 4. Authentizität (Authenticity)
 5. Verbindlichkeit (Non-repudiability)

- S.Ziele → Politik → Architektur → Mechanismen

Security Engineering

Politik Regeln zum Erreichen eines Sicherheitsziels

Mechanismen Implementierung der Durchsetzung der Politik

Architektur Platzierung, Struktur und Interaktion von Mechanismen

wesentlich: Referenzmonitorprinzipien

RM1 Unumgebarkeit → vollständiges Finden aller Schnittstellen

RM2 Manipulationssicherheit → Sicherheit einer Sicherheitspolitik

RM3 Verifizierbarkeit → wohlstrukturierte und per Design kleine TCBs

Echtzeitfähigkeit

- Echtzeitfähigkeit: auf eine Eingabe innerhalb spezifizierten Zeitintervalls korrekte Reaktion hervorbringen

1. echtzeitfähige Scheduling-Algorithmen für Prozessoren
2. zentral: garantierte Einhaltung von Fristen
3. Probleme: Prioritätsumkehr, Überlast, kausale Abhängigkeit
4. echtzeitfähige Interrupt-Behandlung
5. zweiteilig: asynchron registrieren, geplant bearbeiten
6. echtzeitfähige Speicherverwaltung
7. Primärspeicherverwaltung, VMM (Pinning)
8. Sekundärspeicherverwaltung, Festplattenscheduling

Adaptivität

- Adaptivität: gegebenes (breites) Spektrum NFEs zu unterstützen
- Adaptivität komplementär und synergetisch zu anderen NFE

Exokernel {Adap.}∪{Performanz, Echtzeit, Wartbar, Sparsam}

Virtualisierung {Adaptiv}∪{Wartbar, Sicherheit, Robust}

Container {Adaptiv}∪{Wartbar, Portabel, Sparsam}

Performanz und Parallelität

- Performanz: für korrekte Funktion benötigte Zeit minimieren
- hier betrachtet: Kurze Antwort-und Reaktionszeiten
- Mechanismen, Architekturen, Grenzen der Parallelisierung

Hardware Multicore-Prozessoren, Superskalarität

Betriebssystem Multithreading, Scheduling, Synchronisation und Kommunikation, Lastangleichung

Anwendung Parallelisierbarkeit, Effizienz, Prozessoreinsatz

Synergetische und konträre Eigenschaften

- eine NFE bei IT-Systemen meist nicht ausreichend
- Zusammenhang nicht immer eindeutig und offensichtlich
- bestimmte Einsatzgebiete brauchen oft mehrere NFE gleichzeitig

Überblick: NFE und Architekturkonzepte

	Makrok.	Mikro.	Exok.	Virt.	Multik.
Energieeff.			(✓)	x	x
Speichereff.	x	(✓)	(✓)		x
Robustheit	x	(✓)	x	(✓)	
Verfügbarkeit	x	(✓)		(x)	(✓)
Korrektheit	x	(✓)	x	(x)	(✓)
Sicherheit	x	(✓)	x	x	
Echtzeitfähig	(✓)	(✓)	x	x	x
Adaptivität	x	(✓)	✓	✓	(✓)
Wartbarkeit	✓		✓	✓	
Performanz	(✓)	x	✓	x	✓

✓Ziel, (✓) synergetisch, xKonträr

Sparsamkeit und Effizienz

Sparsamkeit Funktion mit minimalem Ressourcenverbrauch ausüben
→ Effizienz bei Nutzung der Ressourcen

Effizienz Grad mit welchem System Sparsam ist

- Sparsamkeit mit weiteren Ressourcen, z.B. Speicherplatz
- Betriebssystem (Kernel + User Space): geringer Speicherbedarf
- optimale Speicherverwaltung durch Betriebssystem zur Laufzeit
- Baugrößenoptimierung (Platinen- und Peripheriegerätegröße)

Energieeffizienz

zeitweiliges Abschalten momentan nicht benötigter Ressourcen

- Dateisystem-E/A: energieeffizientes Festplatten-Prefetching
- CPU-Scheduling: energieeffizientes Scheduling
- Speicherverwaltung: Lokalisationsoptimierung
- Netzwerk: energiebewusstes Routing
- Verteiltes Rechnen: temperaturabhängige Lastverteilung

Energieeffiziente Dateizugriffe

- HDD etc. sparen nur bei relativ langer Inaktivität Energie
- CPU: Aufgabe: kurze, intensive Zugriffsmuster → lange Inaktivität
- HDD-Geräten: Zustände mit absteigendem Energieverbrauch

Aktiv einziger Arbeitszustand

Idle Platte rotiert, Elektronik teilweise abgeschaltet

Standby Rotation abgeschaltet

Sleep gesamte restliche Elektronik abgeschaltet

- ähnliche, noch stärker differenzierte Zustände bei DRAM

Prefetching-Mechanismus

- Prefetching („Speichervorgriff“, vorausschauend) & Caching
 - Standard-Praxis bei moderner Datei-E/A
 - Voraussetzung: Vorwissen über benötigte Folge von zukünftigen Datenblockreferenzen
 - Ziel: Performanzverbesserung durch Durchsatzerhöhung und Latenzzeit-Verringerung
 - Idee: Vorziehen möglichst vieler E/A-Anforderungen an Festplatte + zeitlich gleichmäßige Verteilung verbleibender
 - Umsetzung: Caching dieser vorausschauend gelesenen Blöcke in ungenutzten PageCache
- Zugriffs-/Festplattenoperationen

access(x) zugriff auf Inhalt von Block x im PageCache

fetch(x) hole Block x nach einem access(x) von Festplatte

prefetch(x) hole Block x ohne access(x) von Festplatte

- bisher Fetch-on-Demand-Strategie (kein vorausschauendes Lesen)
- Traditionelles Prefetching
 1. Optimales Prefetching: Jedes *prefetch* soll nächsten Block im Referenzstrom in Cache bringen, der noch nicht dort ist
 2. Optimales Ersetzen: ersetzender *prefetch* soll Block überschreiben, der weitesten in der Zukunft benötigt wird
 3. „Richte keinen Schaden an“: Überschreibe niemals Block A um Block B zu holen, wenn A vor B benötigt wird
 4. Erste Möglichkeit: Führe nie ein ersetzendes *prefetch* aus, wenn dieses schon vorher hätte ausgeführt werden können
- Energieeffizientes Prefetching: Länge der Disk-Idle maximieren
 1. Optimales Prefetching
 2. Optimales Ersetzen
 3. „Richte keinen Schaden an“
 4. Maximiere Zugriffsfolgen: Führe immer dann nach einem *fetch/prefetch* ein weiteres *prefetch* aus, wenn Blöcke für eine Ersetzung geeignet sind
 5. Beachte Idle-Zeiten: Unterbruch nur dann eine Inaktivitätsperiode durch ein *prefetch*, falls dieses sofort ausgeführt werden muss, um Cache-Miss zu vermeiden

Allgemeine Schlussfolgerungen

1. HW-Spez. nutzen: Modi, mit wenig Energieverbrauch
2. Entwicklung von Strategien, die langen Aufenthalt in energiesparenden Modi ermöglichen
3. Implementieren dieser Strategien in BS zur Ressourcenverwaltung

Energieeffizientes Prozessormanagement

- CMOS z.Zt. meistgenutzte Halbleitertechnologie für Prozessor
- Energieverbrauch $P = P_{switching} + P_{leakage} + \dots$

Schaltleistung $P_{switching}$

- $P_{switching}$: für Schaltvorgänge notwendige Leistung
 - Energiebedarf kapaz. Lade-/Entladevorgänge während Schaltens
 - Einsparpotenzial: Verringerung von Versorgungsspannung (quadratische Abhängigkeit) und Taktfrequenz
- längere Schaltvorgänge, größere Latenz zwischen Schaltvorgängen
⇒ Energieeinsparung nur mit Qualitätseinbußen

Verlustleistung $P_{leakage}$

- $P_{leakage}$: Verlustleistung durch verschiedene Leckströme
 - Energiebedarf baulich bedingter Leckströme
 - Hardware-Miniaturisierung → zunehmender Anteil $P_{leakage}$ an P
- ⇒ Leckströme kritisch für energiesparenden Hardwareentwurf

Regelspielraum: Nutzererfahrung

- Nutzererwartung bestimmt Nutzererfahrung
- Typ einer Anwendung entscheidet über jeweilige Nutzererwartung
 1. Hintergrund (Compiler): Bearbeitungsdauer, Durchsatz
 2. Echtzeit (Video-Player): Abspielen von Video, Musik
 3. Interaktiv (Webbrowser): Reaktivität, keine Verzögerung
- Insbesondere kritisch: Echtzeit-/interaktive Anwendungen
- Reaktivität: Reaktion von Anwendungen; abhängig z.B. von

Hardware an sich

Energieversorgung der Hardware z.B. Spannungspegel

Software-Gegebenheiten z.B. Scheduling, Management

Energieeffizientes Scheduling

- Probleme mit Energiesparen: Fairness & Prioritätsumkehr

Problem 1 Unfaire Energieverteilung

Problem 2 energieintensive Threads behindern nachfolgende Threads gleicher Priorität

Problem 3 energieintensive Threads niedrigerer Priorität behindern spätere Threads höherer Priorität

- RR Strategie 1: faire Energieverteilung (einheitliche E-Limits)
 - $E_i^{limit} = P_{limit} * T$
 - gewichtete Aufteilung begrenzter Energie
 - Problem: lange, wenig energieintensive Threads verzögern Antwort- und Wartezeiten kurzer, energieintensiver Threads
- RR Strategie 2: maximale Reaktivität (→ klassisches RR)
 - Problem: sparsame Threads werden bestraft durch Verfallen des ungenutzten Energiebudgets
 - Idee: Ansparen von Energiebudgets → mehrfache Ausführung eines Threads innerhalb einer Periode
- RR Strategie 3: Reaktivität, dann faire Energieverteilung

Implementierungsfragen

- Pro
 - Optimierung der Energieverteilung nach Schedulingzielen
 - Berücksichtigung prozessspezifischer Verbrauchsmuster

- Kontra
 - sekundäre Kosten: Energiebedarf des Schedulers, Kontextwechsel, Implementierungskosten
 - Voraussetzung: Monitoring des Energieverbrauchs
- **Alternative:** energieintensive Prozesse verlangsamen → Regelung der CPU-Leistungsparameter

Systemglobale Energieeinsparungsmaßnahmen

- Traditionelle: zu jedem Zeitpunkt Spitzen-Performanz angestrebt
 - viele Anwendungen benötigen keine Spitzen-Performanz
 - viel Hardware-Zeit in Leerlaufsituationen bzw. keine Spitzen-Performanz erforderlich
- Konsequenz (besonders für mobile Systeme)
 - Hardware mit Niedrigenergiezuständen
 - Betriebssystem kann **Energie-Management** realisieren

Hardwaretechnologien

DPM: Dynamic Power Management

- versetzt leerlaufende Hardware selektiv in Zustände mit niedrigem Energieverbrauch
- Zustandsübergänge durch Power-Manager gesteuert, bestimmte DPM-Strategie (Firmware) zugrunde, um gutes Verhältnis zwischen Performanz und Energieeinsparung zu erzielen
- bestimmt, wann & wie lange eine Hardware in Energiesparmodus

Greedy Hardware-Komponente sofort nach Erreichen des Leerlaufs in Energiesparmodus, „Aufwecken“ durch neue Anforderung

Time-out Energiesparmodus erst nachdem ein definiertes Intervall im Leerlauf, „Aufwecken“ wie bei Greedy-Strategien

Vorhersage Energiesparmodus sofort nach Erreichen des Leerlaufs, wenn Heuristik vorhersagt, dass Kosten gerechtfertigt

Stochastisch Energiesparmodus auf Grundlage stochastischen Modells

DVS: Dynamic Voltage Scaling

- effizientes Verfahren zur dynamischen Regulierung von Taktfrequenz gemeinsam mit Versorgungsspannung
- Nutzung quadratischer Abhängigkeit der dynamischen Leistung von Versorgungsspannung
- Steuerung/Strategien: Softwareunterstützung notwendig
- Ziel: Unterstützung von DPM-Strategien durch Maßnahmen auf Ebene von Compiler, Betriebssystem und Applikationen
- **Betriebssystem** (prädictives Energiemanagement)
 - kann Benutzung verschiedener Ressourcen beobachten
 - kann darüber Vorhersagen tätigen
 - kann notwendigen Performanzbereich bestimmen

- **Anwendungen** können Informationen über jeweils für sie notwendige Performanz liefern

→ Kombination mit energieeffizientem Scheduling

Speichereffizienz

- ... heißt: Auslastung des verfügbaren Speichers
- oft implizit: Hauptspeicherauslastung (memory footprint)
- für kleine/mobile Systeme: Hintergrundspeicherauslastung
- Maße zur Konkretisierung:
 - zeitlich: Maximum vs. Summe genutzten Speichers?
 - physischer Speicherverwaltung? → Belegungsanteil pAR
 - virtuelle Speicherverwaltung? → Belegungsanteil vAR
- Konsequenzen für Ressourcenverwaltung durch BS
 - Taskverwaltung (Accounting, Multiplexing, Fairness, ...)
 - Programmiermodell, API (dyna. Speicherreservierung)
 - Strategien virtueller Speicherverwaltung (VMM)
- Konsequenzen für Betriebssystem selbst
 - minimaler Speicherbedarf durch Kernel
 - minimale Speicherverwaltungskosten (oberer Aufgaben)

Hauptspeicherauslastung

Problem: externe Fragmentierung

- Lösungen: First Fit, Best Fit, WorstFit, Buddy, Relokation
- Kompromissloser Weg: kein Multitasking

Problem: interne Fragmentierung

- Lösung: Seitenrahmengröße verringern ABER dichter belegte vAR → größere Datenstrukturen für Seitentabellen
- direkter Einfluss des Betriebssystems auf Hauptspeicherbelegung
 - Speicherbedarf des Kernels
 - statische (min) Größe des Kernels (Anweisungen+Daten)
 - dynamische Speicherreservierung durch Kernel
 - bei Makrokern: Speicherbedarf von Gerätecontrollern

weitere Einflussfaktoren: Speicherverwaltungskosten

- VMM: Seitentabellengröße → Mehrstufigkeit
- Metainformationen über laufende Programme: Größe von Taskkontrollblöcken (Prozess-/Threaddeskriptoren ...)
- dynamische Speicherreservierung durch Tasks

Hintergrundspeicherauslastung

Einflussfaktoren des Betriebssystems

- statische Größe des Kernel-Images, beim Bootstrapping gelesen
- statische Größe von Programm-Images (Standards wie ELF)
- statisches vs. dynamisches Einbinden von Bibliotheken
- VMM: Größe des Auslagerungsbereichs (inkl. Teilen der Seitentabelle) für Anwendungen
- Modularisierung (zur Kompilierzeit) des Kernels: gezielte Anpassung an Einsatzdomäne möglich
- Adaptivität (zur Kompilier- und Laufzeit) des Kernels: gezielte Anpassung an sich ändernde Umgebungsbedingungen möglich

Architekturentscheidungen

- typische Einsatzgebiete sparsamer BS: eingebettete Systeme
 - eingebettetes System
 - Wesentlicher Bestandteil größerer Systems
 - Liefert Ausgaben in Form von Informationen/Daten
 - spezielle, anwendungsspezifische Ausprägung der Aufgaben
 - reduzierter Umfang von HW-Abstraktion, hardwarenah
 - begrenzte Notwendigkeit von HW-Multiplexing & Schutz
 - sparsame Betriebssysteme
 - energieeffizient** geringe Architektur Anforderungen an energieintensive Hardware
 - speichereffizient** Auskommen mit kleinen Datenstrukturen
- ⇒ geringe logische Komplexität des Betriebssystemkerns
- sekundär: Adaptivität des Betriebssystemkerns

Makrokern (monolithischer Kernel)

- User Space
 - Anwendungstasks
 - CPU im unprivilegierten Modus (Unix „Ringe“ 1...3)
 - Isolation von Tasks durch Programmiermodell/VMM
- Kernel Space
 - Kernel und Gerätecontroller (Treiber)
 - CPU im privilegierten Modus (Unix „Ring“ 0)
 - keine Isolation
- Vergleich
 - ✓ vglw. geringe Kosten von Kernelcode (Energie, Speicher)
 - ✓ VMM nicht zwingend erforderlich
 - ✓ Multitasking nicht zwingend erforderlich
 - ✗ Kernel (inkl. Treibern) jederzeit im Speicher
 - ✗ Robustheit, Sicherheit, Adaptivität

Mikrokern

- User Space
 - Anwendungstasks, Kernel- und Treibertasks
 - CPU im unprivilegierten Modus
 - Isolation von Tasks durch VMM
- Kernel Space
 - funktional minimaler Kernel (μ Kernel)
 - CPU im privilegierten Modus
 - keine Isolation (Kernel wird in alle vAR eingeblendet)
- Vergleich
 - ✓ Robustheit, Sicherheit, Adaptivität
 - ✓ Kernelspeicherbedarf gering, Serverprozesse nur wenn benötigt (→ Adaptivität)
 - ✗ hohe IPC-Kosten von Serverprozessen
 - ✗ Kontextwechselkosten von Serverprozessen
 - ✗ VMM, Multitasking i.d.R. erforderlich

BS: TinyOS

- Beispiel für sparsame BS im Bereich eingebetteter Systeme
- verbreitete Anwendung: verteilte Sensornetze (WSN)
- für drahtlose Geräte mit geringem Stromverbrauch
- Architektur: monolithisch (Makrokern) mit Besonderheiten
 - keine klare Trennung zwischen der Implementierung von Anwendungen und BS (aber von funktionalen Aufgaben)
 - zur Laufzeit: 1 Anwendung + Kernel
- Mechanismen
 - kein Multithreading, keine echte Parallelität
 - keine Synchronisation zwischen Tasks
 - keine Kontextwechsel bei Taskwechsel
 - Multitasking realisiert durch Programmiermodell
 - nicht-präemptives FIFO-Scheduling
 - kein Paging → keine Seitentabellen, keine MMU
- in Zahlen
 - Kernelgröße: 400 Byte
 - Kernelimagegröße: 1-4 kByte
 - Anwendungsgröße: typisch ca. 15 kB, DB: 64 kB
- Programmiermodell
 - BS+Anwendung als Ganzes übersetzt: statische Optimierungen durch Compiler (Laufzeit, Speicherbedarf)
 - Nebenläufigkeit durch ereignisbasierte Kommunikation zw. Anwendung und Kernel (command & event)

BS: RIOT

- sparsames BS, optimiert für anspruchsvollere Anwendungen
- Open-Source-Mikrokern-basiertes Betriebssystem für IoT
- Architektur: Mikrokern
 - minimale Algorithmenkomplexität
 - vereinfachtes Threadkonzept → keine Kontextsicherung erforderlich
 - keine dynamische Speicherallokation
 - energiesparende Hardwarezustände vom Scheduler ausgelöst (inaktive CPU)
 - Mikrokerneldesign unterstützt komplementäre NFE: Adaptivität, Erweiterbarkeit
 - Kosten: IPC (hier gering)
- Mechanismen
 - Multithreading-Programmiermodell
 - modulare Implementierung von Dateisystemen, Scheduler, Netzwerkstack
- in Zahlen
 - Kernelgröße: 1,5 kByte
 - Kernelimagegröße: 5 kByte

Robustheit und Verfügbarkeit

- allgemein: verlässlichkeitskritische Anwendungsszenarien
- z.B. Forschung in garstiger Umwelt (Weltraum)
- hochsicherheitskritische Systeme (Finanz, Cloud Dienste)
- hochverfügbare System (öffentliche Infrastruktur, Strom)

Allgemeine Begriffe

- **Verlässlichkeit** Fähigkeit, eine Leistung zu erbringen, der man berechtigterweise vertrauen kann
- Untereigenschaften
 1. Verfügbarkeit (availability)
 2. Robustheit (robustness, reliability)
 3. (Funktions-) Sicherheit (safety)
 4. Vertraulichkeit (confidentiality)
 5. Integrität (integrity)
 6. Wartbarkeit (maintainability)

→ nicht immer sind alle Untereigenschaften erforderlich

Robustheitsbegriff

Ausfall beobachtbare Verminderung der Leistung eines Systems, gegenüber seiner als korrekt spezifizierten Leistung

Robustheit Verlässlichkeit unter Anwesenheit externer Ausfälle (= Ursache außerhalb des betrachteten Systems)

- Fehler → fehlerhafter Zustand → Ausfall

Ausfall (failure) liegt vor, wenn tatsächliche Leistung(en), die ein System erbringt, von als korrekt spezifizierter Leistung abweichen

- Korrektheit testen/beweisen(→ formale Verifikation)

fehlerhafter Zustand (error) notwendige Ursache eines Ausfalls (nicht jeder error muss zu failure führen)

- Maskierung, Redundanz
 - Isolation von Subsystemen
- Isolationsmechanismen

Fehler (fault) Ursache für fehlerhaften Systemzustand (error)

- Ausfallverhalten spezifizieren
 - Ausfälle zur Laufzeit erkennen und Folgen beheben
- Micro-Reboots

Fehlerhafter Zustand

externer Zustand der Teil des Gesamtzustands, der an externer Schnittstelle sichtbar wird

interner Zustand restlicher Teilzustand

erbrachte Leistung zeitliche Folge externer Zustände

- Wirkungskette: Treiber-Programmierfehler (fault) → fehlerhafter interner Zustand des Treibers (error)
 - Ausbreitung dieses Fehlers (failure des Treibers)
 ⇒ fehlerhafter externer Zustand des Treibers
 ⇒ fehlerhafter interner Zustand des Kernels (error)
 ⇒ Kernelausfall (failure)
 - Auswirkung: fehlerhafter Zustand weiterer Kernel-Subsysteme
- Robustheit: Isolationsmechanismen

Isolationsmechanismen

- Isolationsmechanismen für robuste Betriebssysteme
 - durch strukturierte Programmierung
 - durch Adressraumisolation
- noch mehr für sichere Betriebssysteme
 - durch kryptografische Hardwareunterstützung: Enclaves
 - durch streng typisierte Sprachen und managed code
 - durch isolierte Laufzeitumgebungen: Virtualisierung

Strukturierte Programmierung

Monolithisches BS... in historischer Reinform

- Anwendungen, Kernel, gesamte BS-Funktionalität
- programmiert als Sammlung von Prozeduren
- jede darf jede davon aufrufen, keine Modularisierung
- keine definierten internen Schnittstellen

Monolithisches Prinzip

- Ziel: Isolation zwischen Anwendungen und Betriebssystem
- Mechanismus: Prozessor-Privilegierungsebenen (user/kernelspace)
- Konsequenz: fast keine Strukturierung des Kernels

Strukturierte Makrokernarchitektur

- schwach strukturierter (monolithischer) Makrokern
- ⇒ Schichtendifferenzierung (layered operating system)
- Modularisierung

Modularer Makrokern

- Kernelfunktionen in Module unterteilt → Erweiter-/Portierbarkeit
- klar definierte Modulschnittstellen
- Module zur Kernelaufzeit dynamisch einbindbar (Adaptivität)

Fehlerausbreitung beim Makrokern

- ✓ Wartbarkeit
- ✓ Portierbarkeit
- ✓ Erweiterbarkeit
- (begrenzt) Adaptivität
- Schutz gegen statische Programmierfehler nur durch Compiler
- ✗ kein Schutz gegen dynamische Fehler

Adressraumisolation

Private virtuelle Adressräume und Fehlerausbreitung

- private virtuelle Adressräume zweier Tasks ($i \neq j$)
- korrekte private vAR: kollisionsfreie Seitenabbildung
- Magie in Hardware: MMU (BS steuert und verwaltet...)

Robustheit: Vorteil von privaten vAR?

- ✓ nichtvertrauenswürdiger Code kann keine beliebigen physischen Adressen schreiben
- ✓ Kommunikation zwischen nvw. Code muss durch IPC-Mechanismen explizit hergestellt werden → Überwachung und Validierung zur Laufzeit möglich
- ✓ Kontrollfluss begrenzen: Funktionsaufrufe können i.A. keine AR-Grenzen überschreiten
 - BS-Zugriffssteuerung kann nicht durch Taskfehler ausgehebelt werden
 - unabsichtliche Terminierungsfehler(unendliche Rekursion) erschwert ...
- keine Isolation zwischen Fehlern innerhalb des Kernels

Mikrokernelarchitektur

Fortschritt ggü. Makrokern

- Strukturierungskonzept
 - strenger durchgesetzt durch konsequente Isolation voneinander unabhängiger Kernel-Subsysteme
 - zur Laufzeit durchgesetzt → Reaktion auf fehlerhafte Zustände möglich!
- zusätzlich zu vertikaler Strukturierung des Kernels: horizontale Strukturierung eingeführt
 - funktionale Einheiten: vertikal (Schichten)
 - isolierte Einheiten: horizontal (private vAR)

⇒ Kernel (alle BS-Funktionalität) → μ Kernel (minimale BS-Funk.)

- Rest: „gewöhnliche“ Anwendungsprozesse mit AR-isolation
- Kommunikation: botschaftenbasierte IPC (client-server OS)
- Nomenklatur: Mikrokern und Serverprozesse

Modularer Makrokern vs. Mikrokern

- minimale Kernelfunktionalität
- keine Dienste, nur allgemeine Schnittstellen für diese
- keine Strategien, nur grundlegende Mechanismen zur Ressourcenverwaltung
- neues Problem: minimales Mikrokerneldesign

Robustheit von Mikrokernen

- = Gewinn durch Adressraumisolation innerhalb des Kernels
- ✓ kein nichtvertrauenswürdiger Code im Kernelspace, der dort beliebige physische Adressen manipulieren kann
- ✓ Kommunikation zwischen nvw. Code (nicht zur zwischen Anwendungstasks)muss durch IPC explizit hergestellt werden → Überwachung und Validierung zur Laufzeit
- ✓ Kontrollfluss begrenzen: Zugriffssteuerung auch zwischen Serverprozessen, zur Laufzeit unabhängiges Teilmanagement von Code (Kernelcode) möglich (z.B.: Nichtterminierung erkennen)
- Neu:
- ✓ nvw. BS-Code muss nicht mehr im Kernelspace laufen
- ✓ verbleibender Kernel: klein, funktional weniger komplex, leichter zu entwickeln, zu testen, evtl. formal zu verifizieren
- ✓ daneben: Adaptivität durch konsequentere Modularisierung des Kernels gesteigert

Mikrokern: Mach

- 1975: Aleph (BS des „Rochester Intelligent Gateway“)
- 1979/81: Accent (verteiltes BS), CMU
- Mach 3.0 (1989): einer der ersten praktisch nutzbaren μ Kerne
- Ziel: API-Emulation ($\neq$ Virtualisierung) von UNIX und -Derivaten auf unterschiedlichen Prozessorarchitekturen
- mehrere unterschiedliche Emulatoren gleichzeitig lauffähig
 - Emulation außerhalb des Kernels
 - Komponente im Adressraum des Applikationsprogramms
 - 1...n Server, unabhängig von Applikationsprogramm

μ Kernel-Funktionen

1. Prozessverwaltung
2. Speicherverwaltung
3. IPC-und E/A-Dienste, einschließlich Gerätetreiber

unterstützte Abstraktionen (→ API, Systemaufrufe):

1. Prozesse, Threads, Speicherobjekte
2. Ports (generisches, ortstransparentes Adressierungskonzept)
3. Botschaften, ... (sekundäre, von den obigen genutzte Abstraktionen)

Architektur

- Systemaufrufkosten:
 - IPC-Benchmark (1995): i486 Prozessor, 50 MHz
 - Messung mit verschiedenen Botschaftenlängen(x - Werte)
 - ohne Nutzdaten (0 Byte Botschaftenlänge): 115 μ s (Tendenz unfreundlich ...)
- Bewertung aus heutiger Sicht:
 - funktional komplex
 - 153 Systemaufrufe
 - mehrere Schnittstellen, parallele Implementierungen für eine Funktion
 - Adaptivität (Auswahl durch Programmierer)
- Fazit:
 - zukunftsweisender Ansatz
 - langsame und ineffiziente Implementierung

Lessons Learned

- Umsetzung: Designkriterien weitgehend unbekannt
- Folgen für Performanz und Programmierkomfort: [Heis19]
- ✗ „complex“, „inflexible“, „slow“
- wissen etwas über Kosten: IPC-Performanz, Kernelabstraktionen
- wissen nichts über guten μ Kern-Funktionsumfang und gute Schnittstellen


L4

Analyse des Mach-Kernels:

1. falsche Abstraktionen
2. unperformante Kernelimplementierung
3. prozessorunabhängige Implementierung

L3 und L4

- Mikrokerne der 2. Generation
- vollständige Überarbeitung des Mikrokernelkonzepts

First generation Eg Mach	Second Generation Eg L4	Third generation seL4
		
180 syscalls 100 kLOC 100 μ s IPC	~ 7 syscalls ~ 10 kLOC ~ 1 μ s IPC	~ 3 syscalls ~ 9 kLOC 0,2 – 1 μ s IPC

Mikrokernel - Designprinzipien

- Was gehört in einen Mikrokernel?
- Konzeptsicht → Funktionalität
- Implementierungssicht → Performanz
- 1. Generation: durch Performanzentscheidungen aufgeweicht
- Effekt in Praxis gegenteilig: schlechte (IPC-) Performanz

Designprinzipien für Mikrokernel-Konzept

1. System interaktive und nicht vollständig vertrauenswürdige Applikationen unterstützen (→ HW-Schutz,-Multiplexing),
2. Hardware mit virtueller Speicherverwaltung und Paging

Designprinzipien

Autonomie Subsystem muss so implementiert werden, dass es von keinem anderen Subsystem gestört oder korrumpiert werden kann

Integrität Subsystem S_1 muss sich auf Garantien von S_2 verlassen können. D.h. beide Subsysteme müssen miteinander kommunizieren können, ohne dass ein drittes Subsystem diese Kommunikation stören, fälschen oder abhören kann.

L4: Speicherabstraktion

- Adressraum: Abbildung, die jede virtuelle Seite auf einen physischen Seitenrahmen abbildet oder als „nicht zugreifbar“ markiert
- Implementierung über Seitentabellen, unterstützt durch MMU-Hardware
- Aufgabe des Mikrokernelns (Schicht aller Subsysteme): muss Hardware-Konzept des Adressraums verbergen und durch eigenes Adressraum-Konzept überlagern
- Mikrokernel-Konzept des Adressraums:
 - muss Implementierung von beliebigen virtuellen Speicherverwaltungs- und -schutzkonzepten innerhalb des Mikrokernelns (d.h. in den Subsystemen) erlauben
 - sollte einfach und dem Hardware-Konzept ähnlich sein
- Idee: abstrakte Speicherverwaltung
 - rekursive Konstruktion und Verwaltung der Adressräume auf Benutzer-(Server-)Ebene
 - Mikrokernel stellt dafür genau drei Operationen bereit:

grant(x) Server überträgt Seite x seines AR in AR von Empfänger

map(x) Server bildet Seite x seines AR in AR von Empfänger ab

flush(x) Server entfernt Seite x seines AR aus allen fremden AR

Hierarchische Adressräume

- Rekursive Konstruktion der Adressraumhierarchie
- Server und Anwendungen können damit ihren Klienten Seiten des eigenen Adressraumes zur Verfügung stellen
- Realspeicher: Ur-Adressraum vom μ Kernel verwaltet
- Speicherverwaltung, Paging... außerhalb des μ -Kernels realisiert

L4: Threadabstraktion

- Thread
 - innerhalb eines Adressraumes ablaufende Aktivität
 - Adressraumzuordnung essenziell für Threadkonzept
 - Bindung an Adressraum: dynamisch oder fest
 - Änderung einer dynamischen Zuordnung: darf nur unter vertrauenswürdiger Kontrolle erfolgen
- Designentscheidung
 - Autonomieprinzip
 - Konsequenz: Adressraumisolation
 - entscheidender Grund zur Realisierung des Thread-Konzepts innerhalb des Mikrokernelns

IPC

- Interprozess-Kommunikation
 - Kommunikation über Adressraumgrenzen
 - vertrauenswürdigt kontrollierte Aufhebung der Isolation
 - essenziell für (sinnvolles) Multitasking und -threading
- Designentscheidung
 - Integritätsprinzip
 - vertrauenswürdige Adressraumisolation im μ Kernel
 - grundlegendes IPC-Konzepts innerhalb des Mikrokernelns

Identifikatoren

- Thread-und Ressourcenbezeichner
 - müssen vertrauenswürdigt vergeben und verwaltet werden
 - essenziell für (sinnvolles) Multitasking und -threading
 - essenziell für vertrauenswürdige Kernel-/Server-Schnittstellen
- Designentscheidung
 - Integritätsprinzip
 - ID-Konzept innerhalb des Mikrokernelns

Lessons Learned

1. Ein minimaler Mikrokernel
 - stellt Minimalmenge geeigneter Abstraktionen verfügbar
 - flexibel, um Implementierung beliebiger BS zu ermöglichen
 - Nutzung verschiedener Hardware-Plattformen
2. Geeignete, funktional minimale Mechanismen im μ Kern:
 - Adressraum mit map-, flush-, grant-Operation
 - Threadsinklusive IPC
 - eindeutige Identifikatoren
3. Wahl der geeigneten Abstraktionen: kritisch für Verifizierbarkeit, Adaptivität und optimierte Performanz des Mikrokernelns
4. Bisherigen μ -Kernel-Abstraktionskonzepte: ungeeignete, zu viele, zu spezialisierte u. inflexible Abstraktionen
5. Konsequenzen für Mikrokernel-Implementierung
 - müssen für jeden Prozessortyp neu implementiert werden
 - deshalb prinzipiell nicht portierbar → L3-/L4-Prototypen: 99% Assemblercode
6. innerhalb eines Mikrokernelns sind von Prozessorhardware abhängig
 - (a) grundlegende Implementierungsentscheidungen
 - (b) meiste Algorithmen u. Datenstrukturen

7. Fazit: Mikrokernel mit akzeptabler Performanz hardware-spezifische Implementierung minimal erforderlicher vom Prozessortyp unabhängiger Abstraktionen
8. L4 heute: Spezifikation Mikrokernelns (nicht Implementierung)

Zwischenfazit

- Begrenzung von Fehlerausbreitung (→ Folgen von errors)
- konsequent modularisierte Architektur aus Subsystemen
- Isolationsmechanismen zwischen Subsystemen
- statische Isolation auf Quellcodeebene → strukturierte Programmierung
- dynamische Isolation zur Laufzeit → private virtuelle Adressräume
- Architektur, welche diese Mechanismen komponiert: Mikrokernel
- ✓ Adressraumisolation für sämtlichen nichtvertrauenswürdigen Code
- ✓ keine privilegierten Instruktionen in nvw. Code (Serverprozesse)
- ✓ geringe Größe (potenziell: Verifizierbarkeit) des Kernels
- ✓ neben Robustheit: Modularität und Adaptivität des Kernels
- ✗ Behandlung von Ausfällen (→ abstürzende Gerätetreiber ...)

Micro-Reboots

- Kernelfehler potentiell fatal für gesamtes System
- Anwendungsfehler nicht
- kleiner Kernel = geringeres Risiko von Systemausfällen
- BS-Code in Serverprozessen: verbleibendes Risiko unabhängiger Teilausfälle von BS-Funktionalität
- Ergänzung zu Isolationsmechanismen notwendig
- Mechanismen zur Behandlung von Subsystem-Ausfällen
- = Mechanismen zur Behandlung Anwendungs-, Server- und Gerätetreiberfehlern
- Micro-Reboots


Ansatz

- kleinen (als fehlerfrei angenommenen) μ Kernel
- BS-Funktionalität in bedingt vertrauenswürdigen Serverprozessen
- Treiber-/Anwendungen in nicht vertrauenswürdigen Prozessen
- wollen Systemausfälle verhindern durch Vermeidung von errors im Kernel → höchste Priorität
- Treiber- und Serverausfälle minimieren durch Verbergen ihrer Auswirkungen → nachgeordnete Priorität (Best-Effort-Prinzip)
- Idee: Ausfälle → Neustart durch spezialisierten Serverprozess

Beispiel-Betriebssystem: MINIX

- Ziel: robustes Betriebssystem
- Schutz gegen Sichtbarwerden von Fehlern(= Ausfälle) für Nutzer
- Fokus auf Anwendungsdomänen: Einzelplatzrechner und eingebettete Systeme
- Anliegen: Robustheit > Verständlichkeit > geringer HW-Bedarf

Architektur



- Anwendungen (weiß): Systemaufrufe im POSIX-Standard
- Serverprozesse (grau): IPC (botschaftenbasiert), mit Kernel: spezielle MINIX-API (kernel calls), für Anwendungsprozesse gesperrt
- Betriebssystem-Serverprozesse: Dateisystem (FS), Prozessmanagement (PM), Netzwerkmanagement (Net)

- Reincarnation Server (RS) → Micro-Reboots jeglicher Serverprozesse
- Kernelprozesse: systemtask, clocktask

Reincarnation Server

- Implementierungstechnik für Micro-Reboots
- Prozesse zum Systemstart (→ Kernel Image)

system, clock Kernelprogramm

init Bootstrapping (Initialisierung rs), Fork der Login-Shell

rs Fork aller BS-Serverprozesse inkl. Gerätetreiber

Verfügbarkeit

- komplementäre NFE zu Robustheit: Verfügbarkeit (availability)
- Verbesserung von Robustheit → Verbesserung von Verfügbarkeit
- Robustheitsmaßnahmen hinreichend , nicht notwendig
- weitere komplementäre NFE: Robustheit → Sicherheit (security)
- Definition: Grad, zu welchem ein System oder eine Komponente funktionsfähig und zugänglich (erreichbar) ist, wann immer seine Nutzung erforderlich ist (IEEE)
- Anteil an Laufzeit eines Systems, in dem dieses seine spezifizierte Leistung erbringt
- $Availability = \frac{TotalUptime}{TotalLifetime} = \frac{MTTF}{MTTF+MTTR}$
- MTTR: Mean Time to Recovery, MTTF: Mean Time to Failure
- Hochverfügbarkeitsbereich (gefeierte „five nines“ availability)
- Maßnahmen: Robustheit, Redundanz, Ausfallmanagement

einige Verfügbarkeitsklassen:

Verfügbarkeit	Ausfallzeit pro Jahr	Ausfallzeit pro Woche
90%	> 1 Monat	ca. 17 Stunden
99%	ca. 4 Tage	ca. 2 Stunden
99,9%	ca. 9 Stunden	ca. 10 Minuten
99,99%	ca. 1 Stunde	ca. 1 Minute
99,999%	ca. 5 Minuten	ca. 6 Sekunden
99,9999%	ca. 2 Sekunden	<< 1 Sekunde

QNX Neutrino: Hochverfügbares Echtzeit-BS

- Mikrokern-Betriebssystem
- primäres Einsatzfeld: eingebettete Systeme, z.B. Automobilbau
- Mikrokernarchitektur mit Adressraumisolation für Gerätetreiber
- (begrenzt) dynamische Micro-Rebootsmöglich
- → Maximierung der Uptime des Gesamtsystems

High-Avalability-Manager Laufzeit-Monitor der

Systemdienste/Anwendungsprozesse überwacht und neustartet → μ Reboot-Server

High-Avalability-Client-Libraries Funktionen zur transparenten automatischen Reboot für ausgefallene Server-Verbindungen

Sicherheit

Terminologie

Security IT-Sicherheit, Informationssicherheit

- Ziel: Schutz **des** Rechnersystems
- Systemsicherheit, hier besprochen

Safety Funktionale Sicherheit, Betriebssicherheit

- Ziel: Schutz **vor** einem Rechnersystem
- an dieser Stelle nicht besprochen

Sicherheitsziele

- Rechnersystem sicher gegen Schäden durch zielgerichtete Angriffe, insbesondere bzgl Informationen, die im System gespeichert, verarbeitet und übertragen werden
- für Sicherheitsziele gilt: Daten $\neq$ Informationen
- sukzessive Konkretisierungen bzgl anwendungsspezifischer Anforderungen

abstrakte auf konkret definierte Sicherheitsziele

Vertraulichkeit nur für einen autorisierten Nutzerkreis zugänglich

Integrität vor nicht autorisierter Veränderung geschützt

Verfügbarkeit autorisierten Nutzern in angemessener Frist zugänglich

Authentizität Urheber eindeutig erkennen

Verbindlichkeit sowohl integer als auch authentisch

Schadenspotenzial

1. Vandalismus, Terrorismus (reine Zerstörungswut)
2. Systemmissbrauch
 - illegitime Ressourcennutzung, hocheffektive Folgeangriffe
 - Manipulation von Inhalten ($\rightarrow$ Desinformation)
3. (Wirtschafts-) Spionage und Diebstahl
 - Verlust der Kontrolle über kritisches Wissen ($\rightarrow$ Risikotechnologien)
 - immense wirtschaftliche Schäden, z.B. Diebstahl von industriellem Know-How
4. Betrug, persönliche Bereicherung (wirtschaftliche Schäden)
5. Sabotage, Erpressung
 - Außerkraftsetzen lebenswichtiger Infrastruktur
 - Erpressung durch reversible Sabotage

Bedrohungen

1. Eindringlinge (intruders), Hacker
 - Angriff nutzt technische Schwachstelle aus (exploit)
2. Schadsoftware (malicious software, malware)
 - (teil-) automatisierte Angriffe
 - Trojanische Pferde: scheinbar nützliche Software
 - Viren, Würmer: Funktionalität zur eigenen Vervielfältigung und/oder Modifikation
 - Logische Bomben: trojanischen Pferde, deren Aktivierung an System- oder Datumereignisse gebunden
 - Root Kits
3. Bots und Botnets
 - (weit-) verteilt ausgeführte Schadsoftware
 - eigentliches Ziel i.d.R. nicht das jeweils infizierte System

Professionelle Malware: Root Kit

- Programm-Paket, das unbemerkt Betriebssystem modifiziert, um Administratorrechte zu erlangen
- Voraussetzung: eine einzige Schwachstelle...
- ermöglichen Zugriff auf alle Funktionen und Dienste eines Betriebssystems
- Angreifer erlangt vollständige Kontrolle des Systems und kann

- Dateien (Programme) hinzufügen bzw. ändern
 - Prozesse überwachen
 - über die Netzverbindungen senden und empfangen
 - Hintertüren für zukünftiger Angriffe platzieren
- Ziele eines Rootkits
 - seine Existenz verbergen
 - zu verbergen, welche Veränderungen vorgenommen wurden
 - vollständige und irreversible Kontrolle über BS zu erlangen
 - erfolgreicher Root-Kit-Angriff ...
 - jederzeit, unentdeckbar, nicht reversibel
 - systemspezifischem Wissen über Schwachstellen
 - vollautomatisiert, also reaktiv unhinderbar
 - uneingeschränkte Kontrolle über Zielsystem erlangen

Schwachstellen

1. Passwort (erraten, zu einfach, Brute-Force, Abfangen)
2. Programmierfehler (Speicherfehler in Anwenderprogrammen/Gerätmanagern/Betriebssystem)
3. Mangelhafte Robustheit
 - keine Korrektur fehlerhafter Eingaben
 - buffer overrun/underrun („Heartbleed“)
4. Nichttechnische Schwachstellen
 - physisch, organisatorisch, infrastrukturell
 - menschlich ($\rightarrow$ Erpressung, socialengineering)

Zwischenfazit

- Schwachstellen sind unvermeidbar
 - Bedrohungen sind unkontrollierbar
 - ... und nehmen tendenziell zu!
 - führt zu operationellen Risiken beim Betrieb eines IT-Systems
- $\rightarrow$ Aufgabe der BS-Sicherheit: Auswirkungen operationeller Risiken reduzieren

Sicherheitspolitiken

- Herausforderung: korrekte Durchsetzung von Sicherheitspolitiken
- Vorgehensweise: Security Engineering

Sicherheitsziele Welche Sicherheitsanforderungen muss BS erfüllen?

Sicherheitspolitik Durch welche Strategien soll es diese erfüllen?

Sicherheitsmechanismen Wie implementiert BS Sicherheitspolitik?

Sicherheitsarchitektur Wo implementiert BS S.-mechanismen?

Sicherheitspolitiken und -modelle

Kritisch für korrekten Entwurf, Spezifikation, Implementierung

- Sicherheitspolitik (Policy): Menge von Regeln, zum Erreichen eines Sicherheitsziels
- Sicherheitsmodell: formale Darstellung zur
 - Verifikation ihrer Korrektheit
 - Spezifikation ihrer Implementierung

Zugriffssteuerungspolitiken

Zugriffssteuerung (access control) Steuerung, welcher Nutzer oder Prozess mittels welcher Operationen auf welche BS-Ressourcen zugreifen darf

Zugriffssteuerungspolitik konkrete Regeln, welche die Zugriffssteuerung in einem BS beschreiben

IBAC (Identity-based AC) Politik spezifiziert, welcher Nutzer an welchen Ressourcen bestimmte Rechte hat

- Bsp.: „Nutzer Anna darf Brief.docx lesen“

TE (Type-Enforcement) Politik spezifiziert Rechte durch zusätzliche Abstraktion (Typen): welcher Nutzertyp an welchem Ressourcentyp bestimmte Rechte hat

- Bsp.: „Nutzer vom Typ Administrator darf...“

MLS (Multi-Level Security) Politik spezifiziert Rechte, indem aus Nutzern und Ressourcen hierarchische Klassen (Ebenen, „Levels“) gleicher Kritikalität im Hinblick auf Sicherheitsziele gebildet werden

- Bsp.: „Nutzer der Klasse nicht vertrauenswürdig...“

DAC (Discretionary AC): Aktionen der Nutzer setzen die Sicherheitspolitik durch. Typisch: Begriff des Eigentümers von BS-Ressourcen

- Bsp.: „Der Eigentümer einer Datei ändert...“

MAC (Mandatory AC, obligatorische Zugriffssteuerung) Keine Beteiligung der Nutzer an der Durchsetzung einer (zentral administrierten) Sicherheitspolitik

- Bsp.: „Anhand des Dateisystempfads bestimmt BS...“

Traditionell: DAC, IBAC

Auszug aus der Unix-Sicherheitspolitik:

- es gibt Subjekte (Nutzer/Prozesse) und Objekte (Dateien,...)
- jedes Objekt hat einen Eigentümer
- Eigentümer legen Zugriffsrechte an Objekten fest ($\rightarrow$ DAC)
- es gibt drei Zugriffsrechte: read, write, execute
- je Objekt gibt es drei Klassen von Subjekten, mit individuellen Zugriffsrechten: Eigentümer, Gruppe, Rest

In der Praxis

- identitätsbasierte (IBAC), wahlfreie Zugriffssteuerung (DAC)
- hohe individuelle Freiheit der Nutzer bei Durchsetzung der Politik
- hohe Verantwortung

Modellierung: Zugriffsmatrix

- Access Control Matrix (acm): Momentaufnahme der globalen Rechteverteilung zu einem definierten Zeitpunkt t
- Korrektheitskriterium: Wie kann sich dies nach t möglicherweise ändern...?
- Rechteausbreitung (privilege escalation): verursacht z.B. durch Nutzeraktion ($\rightarrow$ DAC)
- Sicherheitseigenschaft: HRU Safety $\rightarrow$ Systemsicherheit

Modern: MAC, MLS

Sicherheitspolitik der Windows UAC (user account control)

- es gibt Subjekte (Prozesse) und Objekte (Dateisystemknoten)
- jedem Subjekt ist eine Integritätsklasse zugewiesen:

Low nicht vertrauenswürdig

Medium reguläre Nutzerprozesse, die Nutzerdaten manipulieren

High Administratorprozesse, die Systemdaten manipulieren

System (Hintergrund-) Prozesse, die ausschließlich Betriebssystemdienste auf Anwenderebene implementieren

- jedem Objekt ist analog eine dieser Integritätsklassen zugewiesen
- sämtliche DAC-Zugriffsrechte müssen mit einer Hierarchie der Integritätsklassen konsistent sein ($\rightarrow$ MAC)
- Nutzer können Konsistenzanforderung selektiv außer Kraft setzen ($\rightarrow$ DAC)

MAC-Modellierung: Klassenhierarchie

Beispiel Relation: $\leq =$

$\{(High, Medium), (High, Low), (Medium, Low), (High, High), (Low, Low)\}$

- repräsentiert Kritikalität hinsichtlich der Integrität
- modelliert legale Informationsflüsse zwischen Subjekten und Objekten $\rightarrow$ Schutz vor illegalem Überschreiben
- leitet Zugriffsrechte aus Informationsflüssen ab: lesen/schreiben

Modellkorrektheit: Konsistenz

- Korrektheitskriterium: Garantiert die Politik, dass acm mit $\leq$ jederzeit konsistent ist? (BLP Security)
- elevation-Mechanismus: verändert nach Nutzeranfrage ($\rightarrow$ DAC) sowohl acm als auch $\leq \rightarrow$ konsistenzerhaltend?
- anders: verändern unmittelbar nur acm $\rightarrow$ konsistenzerhaltend?

Autorisierungsmechanismen

- Sicherheitsmechanismen: Datenstrukturen und Algorithmen, welche Sicherheitseigenschaften eines BS implementieren
- $\rightarrow$ Sicherheitsmechanismen benötigt man zur Herstellung jeglicher Sicherheitseigenschaften
- Auswahl im Folgenden: Autorisierungsmechanismen und -informationen
 - Nutzerauthentisierung (Passwort-Hashing, ...)
 - Autorisierungsinformationen (Metainformationen...)
 - Autorisierungsmechanismen (Rechteprüfung, ...)
 - kryptografische Mechanismen (Hashfunktionen, ...)

Traditionell: ACLs, SUID

Autorisierungsinformationen:

- müssen Subjekte (Nutzer) bzw. Objekte (Dateien, Sockets ...) mit Rechten assoziieren $\rightarrow$ Implementierung der Zugriffsmatrix (acm), diese ist:
 - groß ($\rightarrow$ Dateianzahl auf Fileserver)
 - dünn besetzt
 - in Größe und Inhalt dynamisch veränderlich
- Lösung: verteilte Implementierung der acm als Spaltenvektoren, deren Inhalt in den Objekt-Metadaten repräsentiert wird: Zugriffssteuerungslisten (ACLs)

ACLs: Linux-Implementierung

- objektspezifischer Spaltenvektor = Zugriffssteuerungsliste
- Dateisystem-Metainformationen: implementiert in I-Nodes

Modell einer Unix acm ...	lesen	schreiben	ausführen
Eigentümer (u)	ja	ja	ja
Gruppe (g)	ja	nein	ja
Rest (o)	ja	nein	ja

- 3-elementige Liste, 3-elementige Rechtemenge
- $\rightarrow$ 9 Bits
- Implementierung kodiert in 16-Bit-Wort: 1 1 1 1 0 1 1 0 1

Autorisierungsmechanismen: ACL-Auswertung

Subjekte = Nutzermenge besteht aus Anzahl registrierter Nutzer

- jeder hat eindeutige UID (userID), z.B. integer- Zahl
- Dateien & Prozesse mit UID des Eigentümers versehen
 - bei Dateien: Teil des I-Nodes
 - bei Prozessen: Teil des PCB
 - standardmäßiger Eigentümer: der Ressource erzeugt hat

Nutzergruppen (groups)

- jeder Nutzer durch Eintrag in Systemdatei (/etc/group) einer/mehreren Gruppen zugeordnet ($\rightarrow$ ACL: g Rechte)

Superuser oder root... hat grundsätzlich uneingeschränkte Rechte.

- UID = 0
- darf alle Dateien im System lesen, schreiben, ausführen
- unabhängig von ACL

ACL-Implementierung

Nutzerrechte $\rightarrow$ Prozessrechte

Durchsetzung: basiert auf Prozessrechten

- Annahme: Prozesse laufen mit UID des Nutzers, der sie gestartet hat und repräsentieren Nutzerberechtigungen
- technisch: Nutzer beauftragt anderen Prozess, sich zu dublizieren (fork()) und gewünschte Programm auszuführen (exec*())
- Vererbungsprinzip

Autorisierungsmechanismen: Set-UID

Rechtevererbung

- Nutzer können im Rahmen der DAC-Politik ACLs manipulieren
- Nutzer können (i.A.) jedoch keine Prozess-UIDs manipulieren
- $\rightarrow$ und genau so sollte es gem. Unix-Sicherheitspolitik auch sein!

Hintergrund

- Unix-Philosophie „everything is a file“: BS-Ressourcen wie Sockets, E/A-Gerätehandler als Datei repräsentiert $\rightarrow$ identische Schutzmechanismen zum regulären Dateisystem
- somit: Autorisierungsmechanismen zur Begrenzung des Zugriffs auf solche Geräte nutzbar
 - root bzw. zweckgebundener Nutzer muss Eigentümer sein
 - ACL als `rw- --- ---` gesetzt sein
 - $\rightarrow$ Nutzerprozesse könnten z.B. nicht drucken ...
- Lösung: Mechanismus zur Rechtedelegation
 - durch weiteres Recht in ACL: SUID-Bit (setUID)
 - Programmausführung modifiziert Kindprozess, so dass UID des Programmeigentümers seine Rechte bestimmt
 - Technik: von UID abweichende Prozess-Metainformation ($\rightarrow$ PCB) effektive UID (eUID) wird tatsächlich zur Autorisierung genutzt

Strategie für sicherheitskritische Linux-Programme

- Eigentümer root, SUID-Bit gesetzt
- per eUID delegiert root seine Rechte an genau solche Kindprozesse, die SUID-Programme ausführen
- $\rightarrow$ Nutzerprozesse können Systemprogramme ohne permanente root-Rechte ausführen

Weiteres Beispiel: passwd

- ermöglicht Nutzern Ändern des (eigenen) Anmeldepassworts
- Schreibzugriff auf /etc/shadow (Password-Hashes) erforderlich
- Lösung: `-rws rws r-x 1 root root 1 2005-01-20 10:00 passwd$`
- passwd-Programm wird mit root-Rechten ausgeführt und passwd schreibt nur eigenen Passwort-Hash

Modern: SELinux

- 2000er: sicherheitsfokussiertes Betriebssystemprojekt für NSA
- Implementierung des μ Kernel-Architekturkonzepts Flask
- heute: Open Source, Teil des mainline Linux Kernels
- Klassische UNIXoide: Sicherheitspolitik fest im Kernel
- Idee SELinux: Sicherheitspolitik als eigene BS-Abstraktion
 - zentrale Datenstruktur für Regeln, die erlaubte Zugriffe auf ein SELinux-System definiert
 - erlaubt Modifikation und Anpassung an verschiedene Sicherheitsanforderungen $\rightarrow$ NFE Adaptivität ...

BS-Komponenten

- Auswertung: Security-Server, implementiert als Linux-Kernelmodul $\rightarrow$ entscheidet über alle Zugriffe auf alle Objekte
- Durchsetzung der Sicherheitspolitik: LSM Hooks
- Administration: geschrieben in Textform, muss zur Laufzeit in Security Server installiert werden

Repräsentation der Sicherheitspolitik

- physisch: in spezieller Datei, die alle Regeln enthält, die der Kernel durchsetzen muss
- Datei wird aus Menge von Quelldateien in einer Spezifikationsprache für SELinux-Sicherheitspolitiken kompiliert
- ermöglicht anforderungsspezifische SELinux-Politiken: können sich von SELinux-System zum anderen wesentlich unterscheiden
- Politik wird während des Boot-Vorgangs in Kernel geladen

Semantische Konzepte (Auswahl)

- Type Enforcement (TE): Typisierung von
 - Subjekten: Prozesse
 - Objekten der Klassen: Dateien, Sockets, Geräteschnittstellen, ...
- Rechte delegation durch Retypisierung (vgl. Unix-SUID)

Autorisierungsinformationen

Security Context: Respräsentiert SELinux-Autorisierungsinformationen für jedes Objekt (Semantik: Prozess bash läuft mit Typ `shell_t`)

Autorisierungsregeln

... werden systemweit festgelegt in dessen Sicherheitspolitik ($\rightarrow$ MAC)

Access Vector Rules

- Autorisierungsregeln basierend auf Subjek-/Objektypen
- Zugriffe müssen explizit gewährt werden (default-deny)
- Semantik: Erlaube ("allow") ...
 - jedem Prozess mit Typ `shell_t`
 - ausführenden Zugriff (benötigt die Berechtigung `execute`)
 - auf Dateien (also Objekte der Klassefile)
 - mit Typ `passwd_exec_t`

Autorisierungsmechanismen: passwd Revisited

- Lösung: Retypisierung bei Ausführung
- Prozess wechselt in einen aufgabenspezifischen Typ `passwd_t` $\rightarrow$ massiv verringertes Missbrauchspotenzial!

SELinux: weitere Politiksemantiken

- hier gezeigt: Überblick über TE
- außerdem relevant für SELinux-Politiken (und deren Administration)
 - Einschränkung von erlaubten Typtransitionen (Welches Programm darf mit welchem Typ ausgeführt werden?)
 - weitere Abstraktionsschicht: rollenbasierte Regeln (RBAC) $\rightarrow$ Schutz gegen nicht vertrauenswürdige Nutzer
- ✓ extrem feingranulare, anwendungsspezifische Sicherheitspolitik zur Vermeidung von privilege escalation Angriffen
- ✓ obligatorische Durchsetzung ($\rightarrow$ MAC, zusätzlich zu DAC)
- Softwareentwicklung: Legacy-Linux-Anwendungen ohne Einschränkung
- ✗ Politikentwicklung und -administration komplex
- $\rightarrow$ MAC-Mechanismen ala SELinux sind heutzutage in vielerlei Software bereits zu finden

Isolationsmechanismen

- bekannt: Isolationsmechanismen für robuste Betriebssysteme
 - strukturierte Programmierung
 - Adressraumisolation
- nun: Isolationsmechanismen für sichere Betriebssysteme
 - krypto. Hardwareunterstützung: Intel SGX Enclaves
 - sprachbasiert:
 - * streng typisierte Sprachen und *managed code*: Microsoft Singularity
 - * speichersichere Sprachen (Rust) + Adressraumisolation (μ Kernel): RedoxOS
 - isolierte Laufzeitumgebungen: Virtualisierung

Intel SGX

- SGX: Software Guard Extensions
- Ziel: Schutz von sicherheitskritischen Anwendungen durch vollständige, hardwarebasierte Isolation
- → strenggenommen kein BS-Mechanismus: Anwendungen müssen dem BS nicht mehr vertrauen
- Annahmen/Voraussetzungen

1. sämtliche Software nicht vertrauenswürdig (potenziell durch Angreifer kontrolliert)
2. Kommunikation mit dem angegriffenen System nicht vertrauenswürdig (weder vertraulich noch verbindlich)
3. kryptografische Algorithmen (Verschlüsselung und Signierung) sind vertrauenswürdig, also nicht für den Angreifer zu brechen
4. Ziel: Vertraulichkeit, Integrität und Authentizität von Anwendungen und durch sie verarbeiteten Informationen

Enclaves

- Idee: geschützter Speicherbereich für Teilmenge der Seiten (Code und Daten) einer Task: Enclave Page Cache (EPC)
- Prozessor ver- und entschlüsselt EPC-Seiten


ECREATE App → Syscall → BS-Instruktion an CPU

EADD App → Syscall → BS-Instruktion an CPU

- Metainformationen für jede hinzugefügte Seite als Teil der EPC-Datenstruktur

EINIT App. → Syscall → BS-Instruktion an CPU

- finalisiert gesamten Speicherinhalt für diese Enclave
- CPU erzeugt Hashwert = eindeutige Signatur des Enclave - Speicherinhalts



(Abb. nach [CoDe16])

- Zugriff: App → CPU-Instruk. in User Mode (EENTER, EEXIT)
- CPU erfordert, dass EPC-Seiten in vAR der zugreifenden Task

SGX: Licht und Schatten

- Einführung 2015 in Skylake - Mikroarchitektur
- seither in allen Modellen verbaut, jedoch nicht immer aktiviert
- Konzept hardwarebasierter Isolation ...
- ✓ liefert erstmals die Möglichkeit zur Durchsetzung von Sicherheitspolitiken auf Anwendungsebene
- setzt Vertrauen in korrekte (und nicht böswillige) Hardware voraus
- Dokumentation und Entwicklerunterstützung (im Ausbau ...)
- ✗ schützt durch Enclaves einzelne Anwendungen aber nicht System
- ✗ steckt in praktischer Eigenschaften (Performanz, Speicher) noch in den Anfängen

Sicherheitsarchitekturen

- Voraussetzung zum Verstehen jeder Sicherheitsarchitektur
 - Verstehen des Referenzmonitorprinzips
 - frühe Forschungen durch US-Verteidigungsministerium
 - Schlüsselveröffentlichung: Anderson-Report (1972)
- fundamentalen Eigenschaften zur Charakterisierung von Sicherheitsarchitekturen
- Begriffe des Referenzmonitorprinzips kennen wir schon
 - Abgrenzung passiver Ressourcen (Objekte, z.B. Dateien)
 - von Subjekten (aktiven Elementen, Prozess) durch BS

Referenzmonitorprinzip

- sämtliche Autorisierungsentscheidungen durch zentralen Mechanismus = Referenzmonitor
- Bewertet jeden Zugriffsversuch eines Subjekts auf Objekt durch Anwendung einer Sicherheitspolitik (security policy)
- Architekturbeschreibung, wie Zugriffe auf Ressourcen, die Sicherheitspolitik erlaubt, eingeschränkt werden
- Autorisierungsentscheidungen: basieren auf sicherheitsrelevanten Eigenschaften jedes Subjekts und jedes Objekts

Referenzmonitor ist eine Architekturkomponenten, die

- RM 1** bei sämtlichen Subjekt/Objekt-Interaktionen involviert sind → Unumgebarkeit (total mediation)
- RM 2** geschützt sind vor unautorisierter Manipulation → Manipulationssicherheit (tamperproofness)
- RM 3** hinreichend klein und wohlstrukturiert sind, für formale Analysemethoden → Verifizierbarkeit (verifyability)

Referenzmonitor in Betriebssystemen


Nahezu alle Betriebssysteme implementieren irgendeine Form eines Referenzmonitors

- Subjekte, Objekte
- Regeln einer Sicherheitspolitik charakterisiert
- Unumgebarkeit, Manipulationssicherheit
- Verifizierbarkeit ihrer Sicherheitsarchitektur

Beispiel: Standard-Linux

- Subjekte (Prozesse) → haben reale Nutzer-Identifikatoren (UIDs)
- Objekte (Dateien) → haben ACLs („rwxrwx—“)
- Regeln der Sicherheitspolitik → hart codiert, starr
- Sicherheitsattribute, → Objekten zugeordnet, modifizierbar

Man beurteile die Politikimplementierung in dieser Architektur bzgl. Unumgebarkeit, Manipulationssicherheit und Verifizierbarkeit Referenzmonitorimplementierung: Flask



(Abb. nach [Rosen07] S. 130, Bild 11.1)

SELinux-Architektur: Security Server

- Security Server: Laufzeitumgebung für Politik in Schutzdomäne des Kerns
- Objektmanager: implementiert in allen BS-Diensten mittels „Linux Security Module Framework“
- Objektmanager zur Verwaltung verschiedener Objektklassen
- spiegeln Diversität und Komplexität von Linux BS-Abstraktionen wider: Dateisysteme, Netzwerk, IPC, ...
- jedes Subsystem von SELinux zuständig für
 1. Erzeugung neuer Objekte
 2. Zugriff auf existierende Objekte
- Beispiele: Prozess-Verwaltung, Dateisystem, Networking-System

Dateisystem als Objektmanager

- Durch Analyse von Linux - Dateisystem und zugehöriger API wurden zu überwachenden Objektklassen identifiziert
- ergibt sich unmittelbar aus Linux-API: Dateien, Verzeichnisse, Pipes

- feingranuläre Objektklassen für durch Dateien repräsentierte Objekte (Unix: „everything is a file“)

Permissions (Zugriffsrechte)

- für jede Objektklasse: Menge an Permissions definiert, um Zugriffe auf Objekte dieser Klasse zu kontrollieren
- Permissions: abgeleitet aus Dienstleistungen, die Linux-Dateisystem anbietet
- Objektklassen gruppieren verschiedene Arten von Zugriffsoperationen auf verschiedene Arten von Objekten
- z.B. Permissions für alle „Datei“-Objektklassen (Auswahl ...)

Trusted Computing Base (TCB)

Begriff zur Bewertung von Referenzmonitorarchitekturen

- = notwendige Hard- und Softwarefunktionen eines IT-Systems um alle Sicherheitsregeln durchzusetzen
- besteht üblicherweise aus

1. Laufzeitumgebung der Hardware (nicht E/A-Geräte)
2. verschiedenen Komponenten des Betriebssystem-Kernels
3. Benutzerprogrammen mit sicherheitsrelevanten Rechten

- Betriebssystemfunktionen, die Teil der TCB sein müssen, beinhalten Teile des Prozess-, Speicher-, Datei-, E/A-Managements

Echtzeitfähigkeit

Jedes System, bei dem der Zeitpunkt, zu dem der Output erzeugt wird, von Bedeutung ist. Dies liegt in der Regel daran, dass die Eingabe einer Bewegung in der physischen Welt entspricht und die Ausgabe sich auf dieselbe Bewegung beziehen muss. Die Verzögerung zwischen Eingabe- und Ausgabezeit muss für eine akzeptable Aktualität ausreichend klein sein.
Spektrum von Echtzeitsystemen

1. Regelungssysteme: z.B. eingebettete Systeme, Flugsteuerung
2. Endanwender-Rechnersysteme: z.B. Multimediasysteme
3. Lebewesen: Menschen, Tiere, z.B. Gesundheitsüberwachung

- Murphy's Law: If something can go wrong, it will go wrong
- Murphy's Constant: Damage to an object is proportional to its value
- Johnson's Law: If a system stops working, it will do it at the worst possible time
- Sodd's Law: Sooner or later, the worst possible combination of circumstances will happen
- Realisierung von Echtzeiteigenschaften: komplex und fragil

Antwortzeit Zeitintervall, das ein System braucht, um (irgend)eine Ausgabe als Reaktion auf (irgend)eine Eingabe zu erzeugen

Frist

- bei EZS ist genau dieses Δt kritisch, d.h. je nach Art des Systems darf dieses auf keinen Fall zu groß werden
- Frist (deadline) d_i , die angibt bis zu welchem Zeitpunkt spätestensmöglich die Reaktion erfolgt sein muss, bzw. wie groß das Intervall Δt maximal sein darf

Echtzeitfähigkeit und Korrektheit

- Wird genau dieses maximale Zeitintervall in die Spezifikation eines Systems einbezogen, bedeutet dies, dass ein Echtzeitsystem nur dann korrekt arbeitet, wenn seine Reaktion bis zur spezifizierten Frist erfolgt
- Frist trennt korrektes von inkorrektem Verhalten des Systems

Harte und weiche Echtzeitsysteme

- Praktische Anwendungen erfordern oft Unterscheidung
- hartes EZS: keine Frist jemals überschreiten
- weiches EZS: maßvolles Frist Überschreiten tolerierbar

Charakteristika von Echtzeit-Prozessen

- reale Echtzeitanwendungen beinhalten periodische oder aperiodische Prozesse (oder Mischung aus beiden)
- Periodische Prozesse
 - zeitgesteuert (typisch: periodische Sensorauswertung)
 - oft: kritische Aktivitäten → harte Fristen
- Aperiodische Prozesse
 - ereignisgesteuert
 - Abhängig von Anwendung: harte oder weiche Fristen

Periodische Prozesse (pP)

häufigster Fall bei Echtzeit-Anwendungen

Prozessaktivierung ereignisgesteuert oder zeitgesteuert
Prozesse, die Eingangsdaten verarbeiten: meist ereignisgesteuert
Prozesse, die Ausgangsdaten erzeugen: meist zeitgesteuert

Fristen

- hart oder weich (anwendungsabhängig)
- innerhalb einer Anwendung sind sowohl Prozesse mit harten oder weichen Fristen möglich
- Frist: spätestens am Ende der aktuellen Periode, möglich auch frühere Frist

Modellierung unendliche Folge identischer Aktivierungen: Instanzen, aktiviert mit konstanter Rate (Periode)

Aufgaben des Betriebssystems

- Wenn alle Spezifikationen eingehalten werden, muss Betriebssystem garantieren, dass
- zeitgesteuerte pP: mit ihrer spezifizierten Rate aktiviert werden und ihre Frist einhalten können
- ereignisgesteuerte pP: ihre Frist einhalten können

Aperiodische Prozesse (aP)

typisch für unregelmäßig auftretende Ereignisse, z.B.:


- Überfahren der Spurgrenzen, Unterschreiten des Sicherheitsabstands → Reaktion des Fahrassistentensystems
- Nutzereingaben in Multimediasystemen (→ Spielkonsole)

Prozessaktivierung ereignisgesteuert

Fristen oft weich (aber anwendungsabhängig)

Aufgaben des Betriebssystems unter Einhaltung der Prozessspezifikationen muss BS für Einhaltung der Fristen sorgen
Modellierung bestehen ebenfalls aus (maximal unendlicher) Folge identischer Aktivierungen (Instanzen); aber:
Aktivierungszeitpunkte nicht regelmäßig (möglich: nur genau eine Aktivierung)

Parameter von Echtzeit-Prozessen



Ankunftszeitpunkt a_i Prozess wird ablauffähig

Startzeitpunkt s_i Prozess beginnt mit Ausführung

Beendigungszeitpunkt f_i Prozess beendet Ausführung

Frist (deadline) d_i Prozess sollte Ausführung spätestens beenden

Bearbeitungszeit (computation time) C_i Zeit die Prozessor zur Bearbeitung der Instanz benötigt (ohne Unterbrechungen)

Unpünktlichkeit (lateness) $L_i = f_i - d_i$ Zeit um die Prozess früher/später als Frist beendet

Verspätung (exceeding time) $E_i = \max(0, L_i)$ Zeitbetrag, den ein Prozess noch nach seiner Frist aktiv ist

Spielraum (Laxity) $X_i = d_i - a_i - C_i$ maximale Verzögerungszeit bis Frist beendet werden kann ($f_i = d_i$)

criticality Konsequenzen einer Fristüberschreitung (hart/weich)

Wert V_i Ausdruck relativer Wichtigkeit eines Prozesses

Echtzeitfähige Betriebssysteme

1. Algorithmen, die Rechnersysteme echtzeitfähig machen
 - grundlegende Algorithmen zum Echtzeitscheduling
 - Besonderheiten der Interruptbehandlung
 - Besonderheiten der Speicherverwaltung
2. Probleme, die behandelt werden müssen
 - Prioritätsumkehr
 - Überlast
 - Kommunikation- und Synchronisationsprobleme

Echtzeitscheduling

Scheduling wichtigster Einflussfaktor auf Zeitverhalten des Gesamtsystems

Echtzeit-Scheduling unter Berücksichtigung der Fristen

Fundamentale/wichtigste Strategien

1. Ratenmonotones Scheduling (RM)
2. Earliest Deadline First (EDF)

Annahmen der Scheduling-Strategien

1. Alle Instanzen eines periodischen Prozesses t_i treten regelmäßig und mit konstanter Rate auf. Das Zeitintervall T_i zwischen zwei aufeinanderfolgenden Aktivierungen heißt Periode des Prozesses
2. Alle Instanzen eines periodischen Prozesses t_i haben den gleichen Worst-Case-Rechenzeitbedarf C_i
3. Alle Instanzen eines periodischen Prozesses t_i haben die gleiche relative Frist D_i , welche gleich der Periodendauer T_i ist
4. Alle Prozesse sind kausal unabhängig voneinander (d.h. keine Vorrang- und Betriebsmittel-Restriktionen)

5. Kein Prozess kann sich selbst suspendieren, z.B. E/A-Op
6. Alle Prozesse werden mit ihrer Aktivierung sofort rechenbereit
7. Jeglicher Betriebssystem-Overhead wird vernachlässigt

5-7 sind weitere Annahmen des Scheduling Modells

Ratenmonotones Scheduling (RM)

- Voraussetzung: nur periodische Prozesse/Threads
- Strategie RM
 - Prozess/Thread mit höchster Ankunftsrate bekommt höchste statische Priorität
 - Kriterium: Wie oft pro Zeiteinheit wird Prozess bereit?
 - Scheduling-Zeitpunkt: nur einmal zu Beginn bzw. wenn neuer periodischer Prozess auftritt
 - präemptiv: keine Verdrängung gleicher Prioritäten

- Optimalität: Unter allen Verfahren mit festen Prioritäten optimaler Algorithmus
- Prozessor-Auslastungsfaktor

- Bei Menge von n Prozessen $U = \sum_{i=1}^n \frac{C_i}{T_i}$
- mit $\frac{C_i}{T_i}$ Anteil an Prozessorzeit für jeden Prozess t_i
- und Zeit U zur Ausführung der gesamten Prozessmenge

- Prozessorlast: U ist folglich Maß für die durch Prozessmenge verursachte Last am Prozessor → Auslastungsfaktor
- Planbarkeitsanalyse einer Prozessmenge

- allgemein kann RM Prozessor nicht 100% auslasten
- kleinste obere Grenze des Auslastungsfaktors U_{lub}
- lub: „least upper bound“

- Obere Auslastungsgrenze bei RM

- nach Buttazzo bei n Prozessen: $U_{lub} = n(2^{\frac{1}{n}} - 1)$
- für $n \rightarrow \infty$ konvergiert U_{lub} zu $\ln 2 \approx 0,6931...$
- Wert nicht überschritten → beliebige Prozessmengen

Earliest Deadline First (EDF)


- Voraussetzung: kann periodische/aperiodische Prozesse planen
- Optimalität: EDF in Klasse der Schedulingverfahren mit dynamischen Prioritäten: optimaler Algorithmus
- Strategie EDF

- Prozess mit frühester Frist höchste dynamische Priorität
- Scheduling-Zeitpunkt: Bereitwerden eines Prozesses
- präemptiv: keine Verdrängung gleicher Prioritäten

- Planbarkeitsanalyse

- mit Regeln 1 – 7 max. Prozessorauslastung: $U_{lub} = 1 \rightarrow$ Auslastung bis 100%
- Menge von n Tasks planbar: $U = \sum_{i=1}^n \frac{C_i}{T_i} \leq 1$
- ← $U > 1$ übersteigt die verfügbare Prozessorauslastung; folglich kann niemals eine Prozessmenge mit dieser Gesamtauslastung planbar sein
- Beweis durch Widerspruch. Annahme: $U \leq 1$ und die Prozessmenge ist nicht planbar. Dies führt zu einem Schedule mit Fristverletzung zu einem Zeitpunkt t_2

Vergleich: EDF vs. RM



(Abb. nach [Inf-Handbuch97], Bild 3, S. 740)

- RM
 - Prozessorwechsel: 16
 - im allgemeinen Fall nicht immer korrekte Schedules bei 100% Auslastung
 - statisch Implementiert: jeweils eine Warteschlange pro Priorität
 - Einfügen und Entfernen von Tasks: $O(1)$
- EDF
 - Prozessorwechsel: 12
 - erzeugt auch bei Prozessorauslastung bis 100% (immer) korrekte Schedules
 - dynamisch Implementiert: balancierter Binärbaum zur Sortierung nach Prioritäten
 - Einfügen und Entfernen von Tasks: $O(\log n)$

Prozesstypen in Multimedia-Anwendungen

1. Echte periodische Multimedia-Prozesse (weiche Fristen)
 - (a) pünktliche periodische Prozesse mit konstantem Prozessorzeitbedarf C für jede Instanz (unkomprimierte Audio- und Videodaten)
 - (b) pünktliche periodische Prozesse mit unterschiedlichem C einzelner Instanzen (komprimierte Audio- und Videodaten)
 - (c) unpünktliche periodische Prozesse: verspätet/verfrüht
2. Prozesse nebenläufiger Nicht-Multimedia-Anwendungen
 - interaktiv: keine Fristen, keine zu langen Antwortzeiten Ansatz, maximal tolerierbare Verzögerung
 - Hintergrund: zeitunkritisch, keine Fristen, dürfen nicht verhungern

RC Algorithmus

- Ziel: spezifikationsstreu Prozesse nicht bestrafen durch Fristüberschreitung aufgrund abweichender Prozesse
- Idee
 - grundsätzlich: Scheduling nach frühester Frist aufsteigend
 - für vollständig spezifikationsstreu Prozessmenge wie EDF
 - Frist einer Instanz wird dynamisch angepasst: basierend auf derjenigen Periode, in der sie eigentlich sein sollte
 - Bsp.: $U_i = \frac{20}{40} = \frac{1}{2}$ (spez. Aktivitätsrate 0,5/Periode)
- Variablen
 - a_i : Ankunftszeit der zuletzt bereitgestellten Instanz
 - t_i^{virt} : virtuelle verbrauchte Zeit in aktueller Periode
 - c_i^{virt} : verbrauchte Netto-Rechenzeit
 - d_i : dynamische Frist von t_i für Priorität (EDF)
- Strategie
 - für eine bereite (lauffähige) Instanz von t_i : adaptiere dynamisch d_i basierend auf t_i^{virt}
 - für eine bereit gewordene Instanz von t_i : aktualisiere t_i^{virt} auf akt. Systemzeit (t) → etwaiger „Zeitkredit“ verfällt
- Zeitpunkte, zu denen der Scheduler aktiv wird
 - aktuell laufender Prozess t_i blockiert: $RC(t_i)$
 - Prozesse $t_i \dots j$ werden bereit: $\text{for } x \in [i, j] : RC(t_x)$
 - periodischer „clock tick“ (Scheduling Interrupt) $RC(t_i)$

Umgang mit abweichenden Prozessen unter RC

Auswirkung auf verschiedene Prozesstypen

- pünktlich** Einhaltung der Frist in jeder Periode garantiert
- verspätet** nur aktuelle Periode betrachtet, Nachholen „ausgelassener Perioden“ nicht möglich
- gierig** Prozessorzug, sobald andere lauffähige Prozesse frühere Fristen aufweisen
- nicht-periodische Hintergrundprozesse** pro „Periode“ wird spezifizierte Prozessorrates garantiert

Umgang mit gemischten Prozessmengen



- rechenbereite Prozesse auf 2 Warteschlangen aufgeteilt (einfache Variante eines Mehr-Ebenen-Scheduling)
- Warteschlange 1
 - alle periodischen Prozesse
 - mit höchster Priorität mittels RM oder EDF bedient
- Warteschlange 2
 - alle aperiodischen Prozesse
 - nur bedient, wenn keine wartenden Prozesse in W1

Hintergrund-Scheduling: Vor- und Nachteile

- Hauptvorteil einfache Implementierung
- Nachteile
 - Antwortzeit **aperiodischer Prozesse** kann zu lang werden
 - Verhungern möglich
 - nur für relativ zeitunkritische aperiodische Prozesse

Optimierung: Server-Prozess

- Prinzip: periodisch aktivierter Prozess benutzt zur Ausführung aperiodischer Prozessoranforderungen
- Beschreibung Server-Prozess: durch Parameter äquivalent zu wirklichem periodischen Prozess
- Arbeitsweise Server-Prozess folgend
- geplant mit gleichem S-Algorithmus wie periodische Prozesse
- zum Aktivierungszeitpunkt vorliegende aperiodische Anforderungen bedient bis zur Kapazität des Servers
- keine aperiodischen Anforderungen: Server suspendiert sich bis Beginn der nächsten Periode
- Kapazität in jeder Server-Periode neu „aufgeladen“

Optimierung: Slack-Stealing

- Prinzip: passiver Prozess „slack stealer“ (kein periodischer Server)
- so viel Zeit wie möglich für aperiodische Anforderungen sammeln
- realisiert durch „slackstealing“ bei periodischen Prozessen
- letztere auf Zeit-Achse so weit nach hinten geschoben, dass Frist und Beendigungszeitpunkt zusammenfallen
- Sinnvoll, da Beenden vor Frist keine Vorteile bringt
- Verbesserung der Antwortzeiten für aperiodische Anforderungen


Prioritätsumkehr

Mechanismen zur Synchronisation und Koordination sind häufige Ursachen für kausale Abhängigkeiten zwischen Prozessen

- **kritischer Abschnitt**: Sperrmechanismen stellen wechselseitigen Ausschluss durch nebenläufige Prozesse sicher
- Benutzung von exklusiven, nichtentziehbaren Betriebsmitteln
- Wenn ein Prozess einen kritischen Abschnitt betreten hat, darf er aus diesem nicht verdrängt werden

- Konflikt: kritische Abschnitte vs. Echtzeit-Prioritäten
- Prozess mit höherer Priorität ablauffähig → muss abwarten bis niederpriorisierter Prozess kritischen Abschnitt verlässt
- (zeitweise) Prioritätsumkehr möglich

Ursache der Prioritätsumkehr




(Abb. nach [Buttazzo97], Bild 7.3, S. 183)

- Prioritätsumkehr bei Blockierung an nichtentziehbarem, exklusivem Betriebsmittel
- → unvermeidlich

Folgen der Prioritätsumkehr

- Kritisch bei zusätzlichen Prozessen mittlerer Priorität



- Lösung: Priority Inheritance Protocol (PIP)

Überlast

- Definition: kritische Situation, bei der benötigte Menge an Prozessorzeit die Kapazität des vorhandenen Prozessors übersteigt
- nicht alle Prozesse können Fristen einhalten
- Hauptrisiko: kritische Prozesse können Fristen nicht einhalten → Gefährdung funktionaler und anderer nichtfkt. Eigenschaften (→ harte Fristen!)
- Stichwort: „graceful degradation“ statt unkontrollierbarer Situation → Wahrung von Determinismus

Wichtigkeit eines Prozesses

- Unterscheidung zwischen Zeitbeschränkungen (Fristen) und tatsächlicher Wichtigkeit eines Prozesses für System
- Wichtigkeit eines Prozesses ist unabhängig von seiner Periodendauer und irgendwelchen Fristen
- z.B. kann Prozess trotz späterer Frist wichtiger als anderer mit früherer Frist sein

Umgang mit Überlast: alltägliche Analogien

1. Weglassen weniger wichtiger Aktionen (kein Frühstück...)
2. Verkürzen von Aktivitäten (Katzenwäsche...)
3. Kombinieren (kein Frühstück + Katzenwäsche + ungekämmt)

Wichtung von Prozessen

- Parameter V für jeden Prozess/Thread einer Anwendung
- spezifiziert relative Wichtigkeit eines Prozesses/Thread im Verhältnis zu anderen der gleichen Anwendung
- bei Scheduling: V stellt zusätzliche Randbedingung (primär: Priorität aufgrund von Frist, sekundär: Wichtigkeit)

Obligatorischer und optionaler Prozessanteil

- Aufteilung der Gesamtberechnung eines Prozesses in zwei Phasen

- Möglichkeit der Nutzung des anpassbaren Prozessorzeitbedarfs
- Bearbeitungszeitbedarf eines Prozesses zerlegt in
 1. obligatorischer Teil: unbedingt und immer ausführen → liefert bedingt akzeptables Ergebnis
 2. optionaler Teil: nur bei ausreichender Lapazität ausführen → verbessert erzielt Ergebnis
- Prinzip in unterschiedlicher Weise verfeinerbar

Echtzeit-Interruptbehandlung

- Fristüberschreitung durch ungeeignete Interruptbearbeitung
- Interrupt wird nur registriert (deterministischer Zeitaufwand)
- tatsächliche Bearbeitung der Interruptroutine muss durch Scheduler eingeplant werden → Pop-up Thread

Echtzeit-Speicherverwaltung

- Hauptanliegen: Fristen einhalten
- unkontrollierbare Verzögerungen der Prozessbearbeitung vermeiden
- Ressourcenzuordnung, deswegen:
 1. keine Ressourcen-Zuordnung „on-demand“ sondern „Pre-Allokation“ (=Vorab)
 2. keine dynamische Ressourcenzuordnung, sondern Zuordnung maximal benötigter Menge bei Pre-Allokation

Hauptspeicherverwaltung

- bei Anwendung existierender Paging-Systeme
- durch unkontrolliertes Ein-/Auslagern „zeitkritischer“ Seiten (-inhalte): unkontrollierbare Zeitverzögerungen möglich
- Technik: „Festnageln“ von Seiten im Speicher (Memory Locking)


Sekundärspeicherverwaltung

- Primärziel: Wahrung der Echtzeitgarantien
 - naheliegend: EA-Scheduling nach Fristen → EDF
 - für Zugriffsreihenfolge auf Datenblöcke: lediglich deren Fristen maßgebend (weitere Regeln existieren nicht)
- Resultat bei HDDs
 - ineffiziente Bewegungen der Lese-/Schreibköpfe
 - nichtdeterministische Positionierzeiten
 - geringer Durchsatz
- Fazit: Echtzeit-Festplattenscheduling → Kompromiss zwischen Zeitbeschränkungen und Effizienz
- bekannte Lösungen: Modifikation/Kombination von EDF

→ realisierte Strategien:

1. SCAN-EDF (Kopfbewegung in eine Richtung bis Mitte-/Randzylinder; EDF über alle angefragten Blöcke in dieser Richtung)
2. Group Sweeping (SCAN nach Fristen gruppenweiser Bedienung)
3. Mischstrategien


- Vereinfachung: o.g. Algorithmen i.d.R. zylinderorientiert
- berücksichtigen bei Optimierung nur Positionierzeiten (Positionierzeit meist >> Latenzzeit)



Kommunikation und Synchronisation

- zeitlichen Nichtdeterminismus vermeiden: Interprozess-Kommunikation
 - Minimierung blockierender Kommunikationsoperationen
 - indirekte Kommunikation → Geschwindigkeitsausgleich
 - keine FIFO-Ordnungen (nach Fristen priorisieren)
- Synchronisation: keine FIFO-Ordnungen

Cyclic Asynchronous Buffer (CAB)



Kommunikation zwischen 1 Sender und n Empfängern

- nach erstem Schreibzugriff: garantiert niemals undefinierte Wartezeiten durch Blockierung von Sender/Empfänger
- Lesen/Überschreiben in zyklischer Reihenfolge:
- Most-Recently-Written (MRW) Zeiger auf jüngstes, durch Sender vollständig geschriebenes Element
- Least-Recently-Written (LRW) Zeiger auf ältestes durch Sender geschriebenes Element
- sowohl *MRW* als auch *LRW* können ausschließlich durch Sender manipuliert werden → keine inkonsistenten Zeiger durch konkurrierende Schreibzugriffe
- sowohl *MRW* als auch *LRW* zeigen niemals auf ein Element, das gerade geschrieben wird → keine inkonsistenten Inhalte durch konkurrierende Schreib-/Lesezugriffe
- Regeln für Sender
 - muss **nach** jedem Schreiben *MRW* auf geschriebenes Element setzen
 - muss **bevor** *LRW* geschrieben wird *LRW* inkrementieren
- Regel für Empfänger: muss immer nach Lesen von *MRW* als nächstes *LRW* anstelle des Listennachbarn lesen

Sonderfall 1: Empfänger schneller als Sender

- nach Zugriff auf *MRW* muss auf Lesesequenz bei *LRW* fortgesetzt werden → transparenter Umgang mit nicht-vollem Puffer
- Abschwächung der Ordnungsgarantien: Empfänger weiß nur, dass Aktualität der Daten zwischen *LRW* und *MRW* liegt
- Empfänger niemals durch leeren Puffer blockiert

Sonderfall 2: Sender schneller als Empfänger

- Schreiben in Puffer in Reihenfolge der Elemente → keine blockierenden Puffergrenzen → niemals Blockierung des Senders
 - keine Vollständigkeitsgarantien: Empfänger kann nicht sicher sein, eine temporal stetige Sequenz zu lesen
- Szenarien, in denen Empfänger sowieso nur an aktuellsten Daten interessiert (z.B. Sensorwerte)

Konkurrierende Zugriffe

- ... sind durch Empfänger immer unschädlich (da lesend)
- ... müssen vom Sender nach Inkrementieren von *LRW* nicht-blockierend erkannt werden (Semaphormodell ungeeignet)
- schnellerer Sender überspringt ein gesperrtes Element durch erneutes Inkrementieren von *LRW*, *MRW* muss nachziehen

Architekturen

- müssen Echtzeitmechanismen unterstützen; ermöglicht entsprechende Strategien zur Entwicklungs- oder Laufzeit
- müssen funktional geringe Komplexität aufweisen → theoretische und praktische Beherrschung von Nichtdeterminismus
- Architekturen für komplementäre NFE
 - Sparsamkeit → hardwarespezifische Kernelimplementierung
 - Adaptivität → μ Kernel, Exokernel
- zu vermeiden
 - starke HW-Abstraktion → Virtualisierungsarchitekturen
 - Kommunikation und Synchronisationskosten → verteilte BS
 - Hardwareunabhängigkeit und Portabilität → vgl. Mach

Beispiel-Betriebssysteme

VRTX (Versatile Real-Time Executive)

- Entwickler: Hunter & Ready
- Eckdaten: Makrokern
- war erstes kommerzielles Echtzeitbetriebssystem für eingebettete Systeme
- Nachfolger (1993 bis heute): Nucleus RTOS (Siemens)
- Anwendung: Eingebettete Systeme in Automobilen, Mobiltelefone
- Einsatzgebiete im Hubble-Weltraumteleskop

VxWorks

- Entwickler: Wind River Systems (USA)
- Eckdaten: modularer Makrokern
- Erfolgsfaktor: POSIX-konforme API
- ähnlich QNX: „skalierbarer“ Kernel, zuschneidbar auf Anwendungsdomäne (→ Adaptivitätsansatz)
- Anwendung: eingebettete Systeme, Luft- und Raumfahrt, Unterhaltungselektronik
- Einsatzgebiete: NASA Mars Rover, SpaceX Dragon

DRYOS

- Entwickler: Canon Inc.
- Eckdaten: Mikrokern (Größe: 16 kB)
- Echtzeit-Middleware (Gerätetreiber → Objekte)
- Anwendungen: AE- und AF-Steuerung/-Automatik, GUI, Bildbearbeitung, RAW-Konverter, ...
- POSIX-kompatible Prozessverwaltung

DROPS (Dresden Real-Time Operating System)

- Entwickler: TU Dresden, Lehrstuhl Betriebssysteme
- Eckdaten: Multi-Server-Architektur auf Basis eines L4-Mikrokerns

Adaptivität (Flexibility)

- als unmittelbar geforderte NFE: eingebettete Systeme, Systeme in garstiger Umwelt
- diese Anwendungsdomänen fordern typischerweise auch andere wesentliche NFE
- Adaptivität als komplementäre NFE zur Förderung von

Robustheit funktionale Adaptivität des BS reduziert Kernelkomplexität
Sicherheit TCB-Größe → Verifizierbarkeit, adaptive Reaktion auf Bedrohungen


Echtzeitfähigkeit adaptives Scheduling/Überlast/Interruptbehandlung
Performanz Last- und Hardwareadaptivität
Erweiterbarkeit von Abstraktionen, Schnittstellen, Multiplexing
Wartbarkeit Anpassung des BS an Anwendungen, nicht umgekehrt
Sparsamkeit Lastadaptivität, adaptive Datenstrukturen

- Begriff
 - Fähigkeit eines Systems, sich an breites Spektrum verschiedener Anforderungen anzupassen
 - = so gebaut, dass breites Spektrum verschiedener nicht funktionaler Eigenschaften unterstützt
 - letztere: komplementär zur allgemeinen NFE Adaptivität
- Adaptivität jeweils anhand komplementärer Eigenschaften dargestellt:
 - Exokernel: {Adaptivität} ∪ {Performanz, Echtzeitfähigkeit, Wartbarkeit, Sparsamkeit}
 - Virtualisierung: {Adaptivität} ∪ {Wartbarkeit, Sicherheit, Robustheit}
 - Container: {Adaptivität} ∪ {Wartbarkeit, Portabilität, Sparsamkeit}
- Beispielsysteme
 - Exokernel OS: Aegis/ExOS, Nemesis, MirageOS
 - Virtualisierung: Vmware, VirtualBox, Xen
 - Containersoftware: Docker

Exokernelarchitektur

- Grundfunktion von Betriebssystemen
 - physische Hardware darstellen als abstrahierte Hardware mit komfortableren Schnittstellen
 - Schnittstelle zu Anwendungen (API): Abstraktionen der Hardware
- Problem: Implementierungsspielraum für Anwendungen wird begrenzt
 - Vorteile domänenspezifischer Optimierung der Hardwarebenutzung können nicht ausgeschöpft werden → **Performanz, Sparsamkeit**
 - die Implementierung existierender Abstraktionen kann bei veränderten Anforderungen nicht an Anwendungen angepasst werden → **Wartbarkeit**
 - Hardwarespezifikationen, insbesondere des Zeitverhaltens (E/A, Netzwerk etc.), werden von Effekten des BS-Management überlagert → **Echtzeitfähigkeit**

Exokernelmechanismen



- Trennung von Schutz und Abstraktion der Ressourcen
- Ressourcen-Schutz und -Multiplexing verbleibt beim Kernel
- Ressourcen-Abstraktion Aufgabe der Library-Betriebssysteme

→ autonome Management-Strategien durch in Anwendungen importierte Funktionalität

- systemweit (durch jeweiliges BS vorgegebene) starre Hardware-Abstraktionen vermeiden
- anwendungsdomänenspezifische Abstraktionen sehr einfach
- (Wieder-) Verwendung eigener/fremder Managementfunktionalität wesentlich erleichtert → komplementäre NFE (Performanz, Sparsamkeit, ...)

Funktion des Exokernels

- Prinzip: definiert Low-level-Schnittstelle (so hardwarenah wie möglich)
- Adressierung ermöglichen ohne Informationen über Seiten, Segmente, Paging-Attribute, ...
- Library-Betriebssysteme: implementieren darauf jeweils geeignete anwendungsnahe Abstraktionen
- Anwendungsprogrammierer: wählen geeignete Library-Betriebssysteme bzw. schreiben ihre eigenen Exokernelmechanismen

prinzipielle Exokernelmechanismen am Beispiel Aegis/ExOS

implementiert Multiplexing der Hardware-Ressourcen
exportiert geschützte Hardware-Ressourcen

- minimal: drei Arten von Mechanismen

Secure Binding erlaubt geschützte Verwendung von Hardware-Ressourcen durch Anwendungen, Behandlung von Ereignissen

Visible Resource Revocation beteiligt Anwendungen am Entzug von Ressourcen mittels (kooperativen) Ressourcen-Entzugsprotokolls

Abort-Protokoll erlaubt Exokernel-Beendigung von Ressourcenzuordnungen bei unkooperativen Applikationen

Secure Binding

- Schutzmechanismus, trennt Autorisierung zur Benutzung einer Ressource von tatsächlicher Benutzung
- implementiert für Exokernel erforderliches Zuordnungswissen von (HW-)Ressource zu Management-Code
- "Binding" in Aegis implementiert als Unix-Hardlink auf Metadatenstruktur zu einem Gerät im Kernelspeicher
- Zur Implementierung benötigt
 - Hardware-Unterstützung zur effizienten Rechteprüfung (HW-Caching)
 - Software-Caching von Autorisierungsentscheidungen im Kernel
 - Downloading von Applikationscode in Kernel zur effizienten Durchsetzung
- „Secure Binding“ erlaubt Exokernel Schutz von Ressourcen ohne deren Semantik verstehen zu müssen

Visible Resource Revocation

monolithische BS: entziehen Ressourcen „unsichtbar“, d.h. transparent für Anwendungen

- Vorteil: im allgemeinen geringere Latenzzeiten, einfacheres und komfortableres Programmiermodell
- Nachteil: Anwendungen erhalten keine Kenntnis über Entzug
- erforderliches Wissen für Management-Strategien

Exokernel-BS: entziehen Ressourcen „sichtbar“ → Dialog zwischen Exokernel und Library-BS

- Vorteil: effizientes Management durch Library-BS möglich
- Nachteil: Performanz bei sehr häufigem Entzug, Verwaltungs- und Fehlerbehandlungsstrategien zwischen verschiedenen Library-BS müssen korrekt und untereinander kompatibel sein...
- Abort-Protokoll notwendig, falls dies nicht gegeben ist

Abort-Protokoll

- Ressourcenzugriff bei unkooperativen Library-Betriebssystemen
- notwendig aufgrund von Visible Resource Revocation
- Dialog:
 - Exokernel: „Bitte Seitenrahmen x freigeben.“
 - Library-BS: „...“
 - Exokernel: „Seitenrahmen x innerhalb von 50 μ s freigeben“
 - Library-BS: „...“
 - Exokernel: (führt Abort-Protokoll aus)
 - Library-BS: X („Abort“ hier Prozess terminieren)
- harte Echtzeit-Fristen in wenigsten Anwendungen berücksichtigt
- Abort = nur Widerruf der Secure Bindings, nicht Terminierung
- anschließend: Informieren des entsprechenden Library-BS
- ermöglicht sinnvolle Reaktion des Library-BS
- bei zustandsbehafteten Ressourcen: Exokernel kann Zustand auf Hintergrundspeicher sichern → Management-Informationen zum Aufräumen durch Library-BS

Aegis mit Library-OS ExOS

- sehr effiziente Exokerne, begrenzte Anzahl einfacher Systemaufrufe (10) und Kernel-interne Primitiven
- sicheres Hardware-Multiplexing auf niedriger Abstraktionsebene („low-level“) mit geringem Overhead
- trad. Abstraktionen (VMM, IPC) auf Anwendungsebene effizient implementierbar → einfache Erweiter-/Spezialisierbarkeit
- hochspezialisierte Implementierungen von Abstraktionen generierbar
- geschützte Kontrollflussübergabe: als IPC-Primitive im Aegis-Kernel, 7-mal schneller als zuvor
- Ausnahmebehandlung bei Aegis: 5-mal schneller als bei damals bester Implementierung
- durch Aegis: Flexibilität von ExOS, mit Mikrokern nicht erreichbar
- Aegis erlaubt Anwendungen Konstruktion effizienter IPC-Primitiven ($\Delta\mu$ Kernel: nicht vertrauenswürdige Anwendungen können keinerlei spezialisierte IPC-Primitiven nutzen)

Xok mit Library-OS ExOS

- für x86-Hardware implementiert
- Kernel-Aufgaben: Multiplexing von Festplatte, Speicher, Netzwerk, ...
- Standard Lib-BS (wie Aegis): ExOS „Unix as a Library“
- hochperformant
- Abstraktionen und Operationen auf Exokernel-Basis
- Secure Bindings für Metadaten-Modifikation

Fazit Exokernelarchitektur

- Abstraktionen und Mechanismen des Betriebssystems können den Erfordernissen der Anwendungen angepasst werden
- Ergebnis: beträchtliche Performanzsteigerungen

Performanz, Sparsamkeit ermöglicht direkte HW-Benutzung und Effizienzoptimierung

Wartbarkeit Hardwareabstraktionen flexibel an Anwendungsdomänen anpassbar, ohne BS modifizieren/wechseln

Echtzeitfähigkeit Zeitverhalten des Gesamtsystems durch direkte Steuerung der Hardware weitestgehend kontrollierbar


Idee

- User-Space: anwendungsspezifische Hardwareabstraktionen
- Kernel-Space: nur Multiplexing und Schutz der HW-Schnittstellen
- Praxis: kooperativer Ressourcenzugriff zwischen Kernel, Lib. OS

Ergebnisse

- hochperformante Hardwarebenutzung durch spez. Anwendungen
- funktional kleiner Exokernel (→ Sparsamkeit, Korrektheit)
- flexible Nutzung problemgerechter HW-Abstraktionen
- keine Isolation von Anwendungen → Parallelisierbarkeit: teuer und schwach → keine Robustheit und Sicherheit der Anwendungen

Virtualisierung



→ auf gleicher Hardware mehrere unterschiedliche Betriebssysteme ausführbar machen

Ziele von Virtualisierung

- Adaptivität (ähnlich wie Exokernen)
- Wartbarkeit
- Sicherheit
 - Isolation von Anwendungs- und Kernelcode durch getrennte Adressräume
 - Einschränkung der Fehlerausbreitung → angreifbare Schwachstellen
 - Überwachung der Kommunikation zwischen Teilsystemen
 - Sandboxing (vollständig von logischer Ablaufumgebung isolierte Software)
- Robustheit: siehe Sicherheit

Architekturvarianten - drei unterschiedliche Prinzipien:

- Typ-1-Hypervisor (früher: VMM - „Virtual Machine Monitor“)
- Typ-2-Hypervisor
- Paravirtualisierung

Typ-1-Hypervisor

- Idee des Typ-1-Hypervisors:
 - Multiplexing & Schutz der Hardware (ermöglicht Multiprozess-Betrieb)
 - abstrahierte Maschine mit „angenehmerer“ Schnittstelle als die reine Hardware (z.B. Dateien, Sockets, Prozesse, ...)
- Typ-1-Hypervisor trennt beide Kategorien
 - läuft wie ein Betriebssystem unmittelbar über der Hardware
 - bewirkt Multiplexing der Hardware, liefert aber keine erweiterte Maschine an Anwendungsschicht
 - „Multi-Betriebssystem-Betrieb“
- Bietet mehrmals die unmittelbare Hardware-Schnittstelle an, wobei jede Instanz eine virtuelle Maschine jeweils mit den unveränderten Hardware-Eigenschaften darstellt
- Ursprünge: Time-Sharing an Großrechnern
- heute: Forderungen nach Virtualisierung von Betriebssystemen
 - universeller Einsatz des PC für Einzel- und Serveranwendungen → veränderte Anforderungen an Virtualisierung
 - Wartbarkeit: vor allem ökonomische Gründe
 - Anwendungsentwicklung und -bereitstellung (Lizenzkosten)
 - Administration: einfache Sicherung, Migration virtueller Maschinen
 - Legacy-Software
 - später: Sicherheit, Robustheit → Cloud-Computing
- ideal hierfür: Typ-1-Hypervisor
 - ✓ Gast-BS angenehm wartbar
 - ✓ Softwarekosten beherrschbar
 - ✓ Anwendungen isolierbar

Hardware-Voraussetzungen

- Ziel: Nutzung von Virtualisierung auf PC-Hardware

- systematische Untersuchung der Virtualisierbarkeit von Prozessoren bereits 1974 durch Popek & Goldberg
 - Gast-BS (aus Sicht der CPU im User Mode) muss sicher sein können, dass privilegierte Instruktionen (Maschinencode im Kernel) ausgeführt werden
 - dies geht nur, wenn tatsächlich der HV diese Instruktionen ausführt
 - dies geht nur, wenn CPU bei jeder solchen Instruktion im Nutzermodus Kontextwechsel zum HV ausführen, welcher Instruktion emuliert
- virtualisierbare Prozessoren bis ca. 2006:
 - ✓ IBM-Architekturen (PowerPC, bis 2006 Apple-Standard)
 - ✗ Intel x86-Architekturen (386, Pentium, teilweise Core i)

Privilegierte Instruktionen **ohne** Hypervisor

- User Mode: Anwendung bereitet Befehl und Parameter vor
- User Mode: Privilegierte Instruktion → CPU veranlasst Kontext- und Privilegierungswechsel, Ziel: BS-Kernel
- Kernel Mode: BS-Dispatcher behandelt Befehl und Parameter, ruft weitere privilegierte Instruktionen auf

Privilegierte Instruktionen mit Typ-1-Hypervisor

- User Mode: Anwendung bereitet Befehl und Parameter vor
- User Mode: Trap → Kontext- und Privilegierungswechsel, Ziel: Typ-1-HV
- Kernel Mode: HV-Dispatcher ruft Dispatcher im Gast-BS auf
- User Mode: BS-Dispatcher behandelt Befehl und Parameter, ruft weitere privilegierte Instruktionen auf → Kontext- und Privilegierungswechsel, Ziel: Typ-1-HV
- Kernel Mode: HV führt privilegierte Instruktionen anstelle des Gast-BS aus

Sensible und privilegierte Instruktionen

- Maschinenbefehlen, die nur im Kernel Mode ausgeführt werden dürfen → sensible Instruktionen
- Maschinenbefehlen im User Mode, die Wechsel des Privilegierungsmodus auslösen → privilegierte Instruktionen
- Prozessor virtualisierbar falls sensible Instr. $\subseteq$ privilegierte Instr.
- Befehl im UserM. nicht erlaubt → löst Privilegierungswechsel aus
- kritische Instruktionen = sensible Instr. $\setminus$ privilegierte Instr.
- Beispiele für sensible Instruktionen bei Intel x86: mov auf Steuerregistern


Folgen für Virtualisierung

- privilegierte Instruktionen bei virtualisierbaren Prozessoren
- bei Ausführung einer privilegierten Instruktion in virtueller Maschine: immer Kontrollflussübergabe an im Kernel-Modus laufende Systemsoftware - hier Typ-1-HV
- HV kann (anhand des virtuellen Privilegierungsmodus) feststellen
 - ob sensible Anweisung durch Gast-BS
 - oder durch Nutzerprogramm (Systemaufruf!) ausgelöst
- Folgen
 - privilegierte Instruktionen des Gast-Betriebssystems werden ausgeführt → „trap-and-emulate“
 - Einsprung in Betriebssystem, hier also Einsprung in Gast-Betriebssystem → Upcall durch HV
- privilegierte Instruktionen bei nicht virtualisierbaren Prozessoren typischerweise ignoriert

Intel-Architektur ab 386

- keine Unterstützung für Virtualisierung ...
- kritische Instruktionen im User Mode werden von CPU ignoriert
- Pentium-Familie konnte Kernel-Code explizit feststellen, ob im Kernel- oder Nutzermodus → Gast-BS trifft evtl. fehlerhafte Entscheidungen
- Diese Architekturprobleme (bekannt seit 1974) wurden 20 Jahre lang im Sinne von Rückwärtskompatibilität auf Nachfolgeprozessoren übertragen ...

Typ-2-Hypervisor



Virtualisierung ohne Hardwareunterstützung, keine Möglichkeit...

- trap-and-emulate zu nutzen
- um korrekt den Privilegierungsmodus zu wechseln
- den korrekten Code im HV auszuführen

Übersetzungsstrategie in Software

- vollständige Übersetzung des Maschinencodes, der in VM ausgeführt wird, in Maschinencode, der im HV ausgeführt wird
- praktische Forderung: HV sollte selbst abstrahierte HW-Schnittstelle zur Ausführung des (komplexen!) Übersetzungscodes zur Verfügung haben
- Typ-2-HV als Kompromiss
- korrekte Ausführung von virtualisierter Software auf virtualisierter HW
- beherrschbare Komplexität der Implementierung

aus Nutzersicht

- läuft als gewöhnlicher Nutzer-Prozess auf Host-Betriebssystem
- VMware bedienbar wie physischer Rechner
- persistente Daten des Gast-BS auf virtuellem Speichermedium

Mechanismus: Code-Inspektion

- Bei Ausführung eines Binärprogramms in der virtuellen Maschine: zunächst inspiziert Typ-2-HV den Code nach Basisblöcken
- Basisblock: Befehlsfolge, die mit privilegierten Befehlen oder solchen Befehlen abgeschlossen ist, die den Kontrollfluss ändern
- Basisblöcke werden nach sensiblen Instruktionen abgesucht
- diese werden jeweils durch Aufruf einer HV-Prozedur ersetzt, die jeweilige Instruktion behandelt

Mechanismus: Binary Translation (Binärcodeübersetzung)

- modifizierter Basisblock: wird innerhalb des HV in Cache gespeichert und ausgeführt
- Basisblock ohne sensible Instruktionen: läuft unter Typ-2-HV exakt so schnell wie unmittelbar auf Hardware
- sensible Instruktionen: nach dargestellter Methode abgefangen und emuliert → dabei hilft das Host-BS (z.B. durch eigene Systemaufrufe)

Mechanismus: Caching von Basisblöcken

- HV nutzt zwei parallel arbeitende Module
 - Translator: Code-Inspektion, Binary Translation
 - Dispatcher: Basisblock-Ausführung
- zusätzliche Datenstruktur: Basisblock-Cache
- Dispatcher: sucht Basisblock mit jeweils nächster auszuführender Befehlsadresse im Cache; falls miss → suspendieren (zugunsten Translator)
- Translator: schreibt Basisblöcke in Basisblock-Cache

- Annahme: irgendwann ist Großteil des Programms im Cache, dieses läuft dann mit nahezu Original-Geschwindigkeit (Theorie)

Performanzmessungen

- Typ2-HV keinesfalls so schlecht, wie einst erwartet wurde
- „trap-and-emulate“, erzeugt Vielzahl von Traps → Kontextwechsel zwischen jeweiliger VM und HV
- insbesondere bei Vielzahl an VMs sehr teuer: CPU-Caches, TLBs, Heuristiken zur spekulativen Ausführung werden verschmutzt
- wenn sensible Instruktionen durch VMware-Prozeduren innerhalb des Programms ersetzt: keine Kontextwechsel-Overheads

Studie (von VMware)

- last- und anwendungsabhängig kann Softwarelösung sogar Hardwarelösung übertreffen
- viele moderne Typ1-HV benutzen aus Performanzgründen ebenfalls Binary Translation

Paravirtualisierung

Funktionsprinzip

- ... unterscheidet sich prinzipiell von Typ-1/2-Hypervisor
- wesentlich: Quellcode des Gast-Betriebssystems modifiziert
- sensible Instruktionen: durch Hypervisor-Calls ersetzt
- Gast-Betriebssystem arbeitet vollständig wie Nutzerprogramm, welches Systemaufrufe zum Betriebssystem (hier Hypervisor) ausführt
- Hypervisor: muss geeignetes Interface definieren (HV-Calls)
- Menge von Prozedur-Aufrufen zur Benutzung durch Gast-Betriebssystem
- bilden eine HV-API als Schnittstelle für Gast-Betriebssysteme

Verwandtschaft mit Mikrokern-Architekturen

- entfernt alle sensiblen Instruktionen aus Gast-Betriebssystem...
- ersetzt durch Hypervisor-Aufrufe, um Systemdienste zu nutzen...
- hat man praktisch den Hypervisor in Mikrokern transformiert
- ... das wird schon gemacht: L^4 Linux (TU Dresden)
 - Basis: stringente $L^4\mu$ Kernel-Implementierung
 - Anwendungslaufzeitumgebung: paravirtualisierter Linux-Kernel als Serverprozess
 - Ziele: Isolation, Echtzeitfähigkeit durch direktere HW-Interaktion

Zwischenfazit Virtualisierung

Ziele: Adaptivität komplementär zu

Wartbarkeit ökonomischer Betrieb ohne dedizierte Hardware
Sicherheit von nicht vertrauenswürdigen Anwendungen isoliert
Robustheit Fehler in VMs beeinträchtigen nicht andere VMs


Idee: drei gängige Prinzipien

Typ-1-HV unmittelbares HW-Multiplexing, trap-and-emulate
Typ-2-HV HW-Multiplexing auf Basis eines Host-OS, binarytranslation
Paravirtualisierung Typ-1-HV für angepasstes Gast-OS, kein trap-and-emulate nötig → HV ähnelt μ Kern

Ergebnisse

- ✓ VMs mit individuell anpassbarer Laufzeitumgebung
- ✓ isolierte VMs
- ✓ kontrollierbare VM-Interaktion (untereinander und mit HW)
- ✗ keine hardware-spezifischen Optimierungen aus VM heraus möglich → Performanz, Echtzeitfähigkeit, Sparsamkeit

Container



- Ziel Adaptivität, im Dienste von ...
- ... Wartbarkeit durch Kapselung von
 - Anwendungsprogrammen
 - durch sie benutzte Bibliotheken
 - Instanzen bestimmter BS-Ressourcen
- ... Portabilität: Betrieb von Anwendungen, die lediglich von einem bestimmten BS-Kernel abhängig sind
 - Abhängigkeitskonflikten (Anwendungen und Bibliotheken)
 - fehlenden Abhängigkeiten (Anwendungen und Bibliotheken)
 - Versions- und Namenskonflikten
- ... Sparsamkeit: problemgerechtes „Packen“ von Anwendungen in Container → Reduktion an Overhead: selten (oder gar nicht) genutzter Code, Speicherbedarf, Hardware, ...

Idee

- private Sichten bilden = private User-Space-Instanzen
- Kontrolle dieser Container i.S.v. Multiplexing, Unabhängigkeit und API: BS-Kernel
- keine Form der BS-Virtualisierung, eher: „Userspace-Virtualisierung“

Anwendungsfälle für Container

- Anwendungsentwicklung: konfliktfreies Entwickeln und Testen unterschiedlicher Software, für unterschiedliche Zielkonfigurationen BS-User-Space
- Anwendungsbetrieb und -administration
 - Entschärfung von „dependency hell“
 - einfache Migration, einfaches Backup von Anwendungen ohne den BS-Kernel
 - einfache Verteilung generischer Container für bestimmte Aufgaben
 - = Kombinationen von Anwendungen
- Anwendungsisolation? → Docker

Zwischenfazit: Container

Ziele: Adaptivität komplementär zu...

Wartbarkeit Vermeidung von Administrationskosten
Portabilität Vereinfachung von Abhängigkeitsverwaltung
Sparsamkeit Optimierung der Speicher- und Verwaltungskosten

Idee

- unabhängige User-Space-Instanz für jeden Container
- Aufgaben Kernel: Unterstützung der Containersoftware bei Multiplexing und Herstellung der Unabhängigkeit dieser Instanzen

Ergebnisse

- ✓ vereinfachte Anwendungsentwicklung
- ✓ vereinfachter Anwendungsbetrieb
- ✓ Infrastruktur nötig über (lokale) Containersoftware hinaus, um Containern zweckgerecht bereitzustellen und zu warten
- ✗ keine vollständige Isolation möglich

Beispielsysteme

- Virtualisierung: VMware, VirtualBox
- Paravirtualisierung: Xen
- Exokernel: Nemesis, MirageOS, RustyHermit
- Container: Docker, LupineLinux

Hypervisor - VMware

- stellt verschiedene Virtualisierungs-Softwareprodukte her:
 - VMware Workstation: mehrere unabhängige Instanzen von x86- bzw. x86-64-Betriebssystemen auf einer Hardware betreibbar
 - VMware Fusion: ähnliches Produkt für Intel Mac-Plattformen
 - VMware Player: (eingestellte) Freeware für nichtkommerziellen Gebrauch
 - VMware Server (eingestellte Freeware, ehem. GSX Server)
 - VMware vSphere (ESXi): für Desktop/Server-Systeme, Typ-2-HV
- spezielle vm- Treiber in Host-Betriebssystem eingefügt
- diese ermöglichen: direkten Hardware-Zugriff
- durch Laden der Treiber entsteht „Virtualisierungsschicht“

Hypervisor - VirtualBox

- Virtualisierungs-Software für x86- bzw. x86-64-Betriebssysteme für Industrie und „Hausgebrauch“ (ursprünglich: Innotek, dann Sun, jetzt Oracle)
- frei verfügbare professionelle Lösung, als Open Source Software unter GNU General Public License (GPL) version 2. ...
- lauffähig auf Windows, Linux, Macintosh und Solaris Hosts
- unterstützt große Anzahl von Gast-Betriebssystemen
- reiner Typ-2-Hypervisor

Paravirtualisierung: Xen

- entstanden als Forschungsprojekt der University of Cambridge
- frei verfügbar als Open Source Software unter GNU (GPL)
- lauffähig auf Prozessoren x86, x86-64, PowerPC, ARM, MIPS
- unterstützt große Anzahl von Gast-Betriebssystemen
- bekannt für Paravirtualisierung
- unterstützt heute auch andere Virtualisierungs-Prinzipien

Architektur

- Gast-BSe laufen in Xen Domänen („ dom_i “, analog VM_i)
- genau eine, obligatorische, vertrauenswürdige Domäne: dom_0
 - Bereitstellen und Verwalten der virtualisierten Hardware für andere Domänen
 - Hardwareverwaltung/-kommunikation für paravirtualisierte Gast-BSe (Gerätetreiber)
 - Interaktionskontrolle (Sicherheitspolitiken)
- dom_0 im Detail: ein separates, hochkritisch administriertes, vertrauenswürdiges BS mit eben solchen Anwendungen zur Verwaltung des gesamten virtualisierten Systems

Sicherheit


- Sicherheitsmechanismus in Xen: Xen Security Modules (XSM)
- (Para-)Typ-1-Virtualisierung von BS unterstützt NFE Sicherheit
- PDP: Teil des vertrauenswürdigen BS in dom_0 , PEPs: XSMs im Hypervisor

Exokernel Nemesis

- Betriebssystemaus EU-Verbundprojekt „Pegasus“, zur Realisierung eines verteilten multimediafähigen Systems
- Anwendungen: sollen Freiheit haben, Betriebsmittel in für sie geeignetster Weise zu nutzen (= Exokernel-Prinzip)
- Realisierung als sog. vertikal strukturiertes Betriebssystem
- weitaus meiste Betriebssystem-Funktionalität innerhalb der Anwendungen ausgeführt (= Exokernel-Prinzip)
- Echtzeitanforderungen durch Multimedia → Vermeidung von Client-Server-Kommunikationsmodell wegen schlecht beherrschbarer zeitlicher Verzögerungen

MirageOS + Xen


- Spezialfall: Exokernel als paravirtualisiertes BS auf Xen
- Ziele : Wartbarkeit (Herkunft: Virtualisierungsarchitekturen ...)
- ökonomischer HW-Einsatz
- Unterstützung einfacher Anwendungsentwicklung
- nicht explizit: Unterstützung von Legacy-Anwendungen!
- Idee: „Unikernel“ → eine Anwendung, eine API, ein Kernel
- Unikernel in MirageOS



- Ergebnis: Kombination von Vorteilen zweier Welten
- Virtualisierungsvorteile: Sicherheit, Robustheit (→ Xen-Prinzip genau einer vertrauenswürdigen, isolierten Domäne dom_0)
- Exokernelvorteile: Wartbarkeit, Sparsamkeit
- nicht: Exokernelvorteil der hardwarenahen Anwendungsentwicklung... (→ Performanz und Echtzeitfähigkeit)

Container: Docker

- Idee: Container für einfache Wartbarkeit von Linux-Anwendungsprogrammen entwickeln, testen, portieren → Portabilität
- Besonderheit: Container können wie Software-Repositories benutzt, verwaltet, aktualisiert, verteilt werden
- Management von Containers: Docker Client → leichtgewichtiger Ansatz zur Nutzung der Wartbarkeitsvorteile von Virtualisierung
- Fortsetzung unter der OCI (Open Container Initiative)
- Implementierung der Containertechnik basierend auf Linux-Kernelfunktionen
- Linux Containers (LXC): BS-Unterstützung für Containermanagement
- cgroups: Accounting/Beschränkung der Ressourcenzuordnung
- union mounting: Funktion zur logischen Reorganisation hierarchischer Dateisysteme



Performanz und Parallelität

- Hochleistungsrechnen („high performance computing“)
- „Big Data“: Dienstleistungen für Kunden
- anspruchsvolle Multimedia- Anwendungen (Animationen)

Performanzbegriff

- Minimierung der für korrekte Funktion (= Lösung eines Berechnungsproblems) zur Verfügung stehenden Zeit
- Maximierung der Anzahl pro Zeiteinheit abgeschlossener Berechnungen

Anforderungen hochparallelen Rechnens an ...

- Hardware: Prozessorarchitekturen
- Systemsoftware: Betriebssystemmechanismen
- Anwendungssoftware: Parallelisierbarkeit von Problemen

Hardware-Voraussetzungen

- Entwicklungstendenzen der Rechnerhardware
- Multicore-Prozessoren: seit ca. 2006 (in größerem Umfang)
- bei CPU-Taktfrequenz >> 4GHz z.Zt. physikalische Grenze
- Anzahl der Kerne wächst nicht linear
- Taktfrequenz wächst asymptotisch, nimmt nur noch marginal zu

Performanz durch Parallelisierung ...

1. Performanz-Steigerung von Anwendungen: primär durch Parallelität, Multi-Threaded-Anwendungen
2. erforderlich: Betriebssystem-Unterstützung → Scheduling, Synchronisation
3. weiterhin: Sprachen, Compiler, verteilte Algorithmen ...

... auf Prozessebene

Vorteile von Multicore-Prozessoren

1. möglich wird: **Parallelarbeit auf Chip-Ebene** → Vermeidung der Plagen paralleler verteilter Systeme
2. bei geeigneter Architektur: Erkenntnisse und Software aus Gebiet verteilter Systeme als Grundlage verwendbar
3. durch gemeinsame Caches (architekturabhängig): schnellere Kommunikation (speicherbasiert), billigere Migration von Aktivitäten kann möglich sein
4. höhere Energieeffizienz: mehr Rechenleistung pro Chipfläche, geringere elektrische Leistungsaufnahme → weniger Gesamtabwärme, z.T. einzelne Kerne abschaltbar
5. Baugröße: geringeres physisches Volumen

Nachteile von Multicore-Prozessoren

1. durch gemeinsam genutzte Caches und Busstrukturen: Engpässe (Bottlenecks) möglich
2. zur Vermeidung thermischer Zerstörungen: Lastausgleich zwingend erforderlich! (Ziel: ausgeglichene Lastverteilung auf einzelnen Kernen)

zum optimalen Einsatz zwingend erforderlich

1. Entwicklung Hardwarearchitektur
2. zusätzlich: Entwicklung geeigneter Systemsoftware
3. zusätzlich: Entwicklung geeigneter Anwendungssoftware

Multicore-Prozessoren

MC multicore (processor)

CMP chip-level multiprocessing, hochintegrierte Bauweise für MC

SMC symmetric multicore → SMP ... symm. multi-processing


AMC asymmetric multicore → AMP ... asymmetric multi-processing

UP uni-processing, singlecore (SC) oder uniprocessor

Architekturen von Multicore-Prozessoren

- Netzwerkbasiertes Design
 - Prozessorkerne des Chips u. ihre lokalen Speicher (oder Caches) durch Netzwerkstruktur verbunden
 - größte Ähnlichkeit zu traditionellen verteilten Systemen
 - Verwendung bei Vielzahl von Prozessorkernen (Skalierbar)
- Hierarchisches Design
 - mehrere Prozessor-Kerne teilen sich baumartige Caches
 - jeder Prozessorkern hat eigenen L1-Cache
 - L2-Cache, Zugriff auf Hauptspeicher u. Großteil der Busse
 - Verwendung: typischerweise Serverkonfigurationen
- Pipeline-Design
 - Daten durch Prozessor-Kerne schrittweise verarbeitet
 - durch letzten Prozessor: Ablage im Speichersystem
 - Verwendung: Graphikchips, Netzwerkprozessoren

Netzwerk, Hierarchisch, Pipeline



Symmetrische u. asymmetrische Multicore-Prozessoren

- symmetrische Multicore-Prozessoren (SMC): alle Kerne identisch, d.h. gleiche Architektur und gleiche Fähigkeiten
- asymmetrische MC-Prozessoren (AMC): Multicore-Architektur, jedoch mit Kernen unterschiedlicher Architektur und/oder unterschiedlichen Fähigkeiten

Superskalare Prozessoren

- Bekannt aus Rechnerarchitektur: Pipelining
 - parallele Abarbeitung von Teilen eines Maschinenbefehls in Pipeline-Stufen
 - ermöglicht durch verschiedene Funktionseinheiten eines Prozessors für verschiedene Stufen
 - sowie mehrere Pipeline-Register
- superskalare Prozessoren: solche, bei denen zur Bearbeitung einer Pipelining-Stufe erforderlichen Funktionseinheiten n-fach vorliegen
- Ziel
 - Skalarprozessor (mit Pipelining): 1 Befehl pro Takt (vollständig) bearbeitet
 - Superskalarprozessor: bis zu n Befehle pro Taktbearbeitet
- Vorbereitung heute: universell

Parallelisierung in Betriebssystemen

- Basis für alle Parallelarbeit aus BS-Sicht: Multithreading
 - Kernel-Level-Threads (KLTs): BS implementiert Threads → Scheduler kann mehrere Threads nebenläufig planen → Parallelität möglich
 - User-Level-Threads (ULTs): Anwendung implementiert Threads → keine Parallelität möglich
- grundlegend für echt paralleles Multithreading
 - parallelisierungsfähige Hardware
 - kausal unabhängige Threads

- passendes Programmiermodell, insbesondere Synchronisation!
- Programmierer + Compiler

- BS-Abstraktionen müssen Parallelität unterstützen
- BS muss Synchronisationsmechanismen implementieren

Synchronisations- und Sperrmechanismen

- Synchronisationsmechanismen zur Nutzung
 - durch Anwendungen → Teil der API
 - durch den Kernel
- Verhinderung konkur. Zugriffe auf logische/physische Ressourcen
 - Vermeidung von race conditions
 - Herstellung einer korrekten Ordnung entsprechend Kommunikationssemantik (z.B. „Schreiben vor Lesen“)

Erinnerung: Reader-Writer-Problem

- wechselseitiger Ausschluss (mutual exclusion)
- kritischer Abschnitt (critical section)
- Synchronisationsprobleme
 - write in vollen Puffer
 - read aus leerem Puffer
 - während read durch gleichzeitiges write zugriffen

Sperrmechanismen (Locks)

- Wechselseitiger Ausschluss ...
 - ist in nebenläufigen Systemen zwingend erforderlich
 - ist in echt parallelen Systemen allgegenwärtig
 - skaliert äußerst unfreundlich mit Code-Komplexität → (monolithischer) Kernel-Code
- Mechanismen in Betriebssystemen: Locks

atomic* Lock Operation

- Bausteine der komplexeren Sperrmechanismen
- Granularität: einzelne Integer- (oder sogar Bit-) Operation
- Performanz: mittels Assembler implementiert
- atomic.* Geschmacksrichtungen: read, set, add, sub, inc, dec u. a.
- keine explizite Lock-Datenstruktur → Deadlocks syntaktisch unmöglich
- definierte Länge des kritischen Abschnitts → sehr preiswert

Spinlock

- Locking für längere kritische Abschnitte
- wechselseitiger Ausschluss durch aktives Warten
- Granularität: einfach-exklusive Ausführung von Code, der ...
- ... nicht blockiert
- ... (vorhersehbar) kurze Zeit den kritischen Abschnitt nutzt
- Performanz: keine Scheduler-Aktivierung, keine sperrbedingten Kontextwechsel (alle wartenden Threads bleiben ablaufbereit!)

Semaphor

- Locking für komplexere kritische Abschnitte
- wechselseitiger Ausschluss durch suspendieren von Threads
- Granularität: exklusive Ausführung über längere oder unbekannt lange kritische Abschnitte
- Performanz: nutzt Scheduler, verursacht potenziell Kontextwechsel, implementiert Warteschlange

R/W-Lock

- Reader/Writer Locks: Spezialformen von Spinlocks/Semaphoren
- Steigerung der Granularität → Optimierung des Parallelitätsgrades

- Idee: sperrende Threads nach Zugriffssemantik auf kritischen Abschnitt in zwei Gruppen unterteilt:
- Reader: nur lesende Zugriffe auf Variablen
- Writer: mindestens ein schreibender Zugriff auf Variablen
- R/W-Lock muss explizit als Reader/Writer gesperrt werden
- Performanz: analog Spinlock/Semaphor

Fazit: Locks im Linux-Kernel

- Locking-Overhead: Sperrkosten bei korrekter Benutzung
- Lock-Granularität (ebenfalls bei korrekter Benutzung):
 - mögliche Länge des kritischen Abschnitts
 - Granularität der selektiven Blockierung (z.B. nur Leser, nur Schreiber)
- Locking-Sicherheit: Risiken und Nebenwirkungen hinsichtlich ...
 - fehlerhaften Sperrrens (Auftreten von Synchronisationsfehlern)
 - Deadlocks
 - unnötigen Sperrrens (Parallelität ad absurdum ...)

Lastangleichung und Lastausgleich

Probleme bei ungleicher Auslastung von Multicore-Prozessoren

1. Performanzeinbußen
 - stark belastete Prozessorkerne müssen Multiplexing zwischen mehr Threadausführungen als schwach belastete
 - dadurch: Verlängerung der Gesamtbearbeitungsdauer
2. Akkumulation der Wärmeabgabe
 - bedingt durch bauliche Gegebenheiten (Miniaturisierung)
 - Kontrolle zur Vermeidung thermischer Probleme

Lastangleichung

- statische Verfahren: einmalige Zuordnung von Threads
 - Korrekturen durch geeignete Verteilung neuer Threads
 - Wirksamkeit der Korrekturen: relativ gering
- dynamische Verfahren: Optimierung der Zielfunktion zur Laufzeit
 - Zuordnungsentscheidungen dynamisch anpassbar
 - Korrekturpotential zur Laufzeit durch Zuweisung eines anderen Prozessorkerns an einen Thread (Migration)
 - aber: algorithmisch komplexer, höhere Laufzeitkosten
 - auf Grundlage von a-priori - Informationen über Prozessverhalten
 - durch Messungen tatsächlichen Verhaltens → Übergang von Steuerung zu Regelung
- Kosten von Thread-Migration
 - zusätzliche Thread-bzw. Kontextwechsel
 - kalte Caches
 → Migrationskosten gegen Nutzen aufwiegen

grundlegende Strategien

Lastausgleich loadbalancing oder loadleveling

- Ziel: gleichmäßige Verteilung der Last auf alle Kerne
- verwendet strengere Kriterien, die auch bei nicht leerlaufenden und überlasteten Kernen greifen
- 100%tiger Lastausgleich nicht möglich

Lastverteilung loadsharing

- verwendet schwächere Kriterien
- nur extreme Lastunterschiede zwischen einzelnen Prozessorkernen ausgeglichen

Verteilungsstrategien

load balancing - Strategie

- für jeden Kern nach Zeitscheibenprinzip (z.B. 200 ms) aktiviert
- „Thread-Stehlen“ vom am meisten ausgelasteten Kern
- aber: bestimmte Threads werden (vorerst) nicht migriert
- erzwungene Thread-Migration wenn „loadbalancing“ mehrmals fehlgeschlagen

idle balancing - Strategie

- von jedem Kern aktiviert, bevor er in Leerlauf geht
- Versuch einer „Arbeitsbeschaffung“
- mögliche Realisierung: gleichfalls als „Thread-Stehlen“ vom am meisten ausgelasteten Kern

Heuristische Lastverteilung

- ... für alle Entscheidungen bzgl.
 - loadbalancing („Migrieren oder nicht?“)
 - threadselection („Welchen Threads migrieren?“)
 - time-slicing („Zeitscheibenlänge für loadbalancing?“)
- ... unter Berücksichtigung von
 - Systemlast
 - erwarteter Systemperformanz
 - bisherigem Thread-Verhalten
- Minimum an Informationen zur Realisierung schneller Entscheidungen → Performanz der Lastverteilung
- Tradeoff: höhere Performanz durch teurere Heuristiken


Grenzen der Parallelisierbarkeit

- Jedes Programm aus sequenziellem und parallelisierbaren Anteil
- mit als sequenziellem Anteil $f = \frac{T_s}{T_s + T_p}$ wobei $0 \leq f \leq 1$
- im günstigsten Fall: $T(n) = f * T(1) + (1 - f) \frac{T(1)}{n}$
- Speedup nach Amdahl: $S(n) = \frac{T(1)}{T(n)} = \frac{1}{f + \frac{1-f}{n}}$
- mögliche Beschleunigung bei Parallelisierung einer Anwendung i.A. durch die Eigenschaften der Anwendung selbst begrenzt
- Erhöhung der Prozessorenanzahl über bestimmtes Maß hinaus bringt nur noch minimalen Performanzgewinn
- Für bestimmtes Problem bringt ab einer Maximalzahl jede weitere Erhöhung der Prozessoren-Anzahl keinen weiteren Gewinn, da die Parallelisierbarkeit des Problems begrenzt ist
- Effizienz des Speedups $E(n) = \frac{S(n)}{n}$
- Nutzen($E(n)$)-Kosten($T(n)$)-Quotienten maximieren:

$$\mu(n) = \frac{E(n)}{T(n)} T(1) = S(n) * E(n) = \frac{S(n)^2}{n}$$

Einfluss von Kommunikation und Synchronisation

- Threads eines Prozesses müssen kommunizieren (Daten austauschen), spätestens nach ihrer Beendigung
- hierzu i.A. auch Synchronisation (Koordination) erforderlich
- Prozessoren nicht gesamte Zeit für Berechnungen nutzbar



1. Effizienz maximieren: $n_{opt} = n_E^* = 1$ unsinnig
2. Speedup maximieren = Ausführungszeit minimieren: $n_{opt} = n_S^*$
3. Nutzen-Kosten-Funktion maximieren: $n_{opt} = n_\mu^*$

Beispiel-Betriebssysteme

- durch Abstraktion von Multicore-Architekturen: Multikernel
- durch netzwerkbasierte Multicore-Architekturen: Verteilte BS

Multikernel: Barrelfish

- seit ca. 2009 entwickeltes, experimentelles Betriebssystem
- Untersuchungen zur Struktur künftiger heterogener Multicore-Systeme
- Betriebssystem-Architektur für heterogene Multicore-Rechner
 - Idee: Betriebssystem wird strukturiert ...
 - * als verteiltes System von Kernen,
 - * die über Botschaften kommunizieren (Inter-Core-Kommunikation) und

- * keinen gemeinsamen Speicher besitzen.

– Entwurfsprinzipien:

1. alle Inter-Core-Kommunikation explizit realisiert
2. Betriebssystem-Struktur ist Hardware-neutral
3. Zustandsinformationen als repliziert (nicht verteilt) betrachtet → schwächere Synchronisationsanforderungen

– Ziele dieser Entwurfsprinzipien

1. Verbesserte Performanz auf Grundlage des Entwurfs
2. Natürliche Unterstützung für Hardware-Inhomogenitäten
3. Größere Modularität
4. Wiederverwendbarkeit von Algorithmen, die für verteilte Systeme entwickelt wurden

– Implementierung: auf jedem Prozessorkern BS-Instanz aus CPU-Treiber und Monitor-Prozess

CPU Driver

- Aufgabe: Umsetzung von Strategien zur Ressourcenverwaltung
 - Durchsetzung von Zugriffssteuerungsentscheidungen
 - Zeitscheiben-Multiplexing von Threads
 - Vermittlung von Hardware-Zugriffendes Kernels
 - Ereignisbehandlung
- Implementierung:
 - hardwarespezifisch, ist vergleichsweise klein
 - voll ereignisgesteuert, single-threaded, nicht-präemptiv
 - läuft im privilegierten Modus (Kernel-Modus)
 - ist absolut lokal auf jedem Prozessor-Kern
 → Wartbarkeit, Robustheit, Korrektheit

Monitor

- läuft im Nutzer-Modus
- Quellcode fast vollständig prozessorunabhängig
- auf allen Prozessorkernen: koordinieren gemeinsam systemweite Zustandsinformationen
 - auf allen Prozessor-Kernen replizierte Datenstrukturen
 - implementiert Konsensalgorithmen für verteilte Systeme
- Monitore: enthalten die meisten wesentlichen Mechanismen und Strategien, die in monolithischem Betriebssystem-Kernel (bzw. μ Kernel-Serverprozessen) zu finden sind

Verteilte Betriebssysteme

- Grundidee: Ortstransparenz
- lokaler BS-Kernel kommuniziert mit über Netzwerk verbundenen, physisch verteilten anderen Kernels
- Anwendungssicht auf (verteilte) Hardware-Ressourcen identisch zu Sicht auf lokale Hardware → Ortstransparenz

Amoeba

- verteiltes System aus drei Arten von Knoten
 - Workstation (GUI/Terminalprozess, Benutzerinteraktion)
 - Pool Processor (nicht-interaktive Berechnungen)
 - Servers (File, Directory, Networking, ...)

- BS: μ Kernel (identisch auf allen Knoten) + Serverprozesse (dedizierte Knoten)

→ Vertreter einer verteilten μ Kernel-Implementierung

- Kommunikation: LAN, RPCs (Remote Procedure Calls)

→ realisieren ortstransparenten Zugriff auf BS-Abstraktionen

Plan 9

- verteiltes BS der Bell Labs (heute Open Source)
- Semantik der Zugriffe auf verteilte BS-Abstraktionen

- ortstransparent
- mit ressourcenunabhängig identischen Operationen

- all dies wird logisch organisiert durch private Namensräume
- Konzept hierarchischer Dateisysteme