Betriebssystemtechnik

Adressräume: Trennung, Zugriff, Schutz

XIV. Nachlese

Wolfgang Schröder-Preikschat / Volkmar Sieh

SS 2024

Gliederung

Adressraumverwaltung

Verfeinerung/Vertiefung von Betriebssysteme [1, 2]

Adressräume (von Programmen/Prozessen)

- tren|nen: in eine räumliche Distanz voneinander bringen
  - klassisch, hardwarebasiert, durch MMU *und* Betriebssystem
  - unterstützt durch Dienstprogramme (*utility program*)
    - Kompilierer, Assemblierer, Binder, Lader
  - vertikal (vom Betriebssystem) und horizontal (Anwendungsprogramme)
- zu|grei|fen: nach etwas greifen und es festhalten bzw. an sich nehmen
  - Interprozesskommunikation (VSM) und Mitbenutzung (*sharing*)
  - Mitbenutzung durch Daten- (*data*) und Textverbund (*code sharing*)
  - kopieren beim Schreiben/Referenzieren (*copy on write/reference*)
- schüt|zen: einer Sache Schutz gewähren, einen Schutz [ver]schaffen
  - Angriffssicherheit (*security*) und Betriebssicherheit (*safety*)
  - Immunität einerseits und Isolation andererseits
  - Eindrang bzw. Ausbruch von Prozessen verhindern

↪ ergänzend: softwarebasiert, durch typsichere Programmiersprachen

Gliederung

Forschungsschwerpunkte am Lehrstuhl

- **Komponierbarkeit** und **Konfigurierbarkeit**
  - anwendungsorientierte (variantenreiche, typsichere) Systemsoftware
- **Sparsamkeit**
  - ressourcen-gewahrer Betrieb von Rechensystemen
- **Zuverlässigkeit**
  - Betriebsmittel schonende Fehler- und Einbruchstoleranz
- **Rechtzeitigkeit**
  - Migrationspfade zwischen zeit- und ereignisgesteuerten Echtzeitsystemen
- **Spezialisierbarkeit**
  - dedizierte Betriebssysteme: integriert, adaptiv, parallel
- **Gleichzeitigkeit**
  - Koordination der Kooperation und Konkurrenz zwischen Prozessen

↪ Prozessadressräume sind mehr oder weniger querschneidend dazu

Laufzeitunterstützungssystem für invasives Rechnen

- ***Octo*** — der Bezeichnung eines Wesens entnommen, das:
  - i hoch parallel in seinen Aktionen ist und
  - ii sich sehr gut an seine Umgebung anpassen kann

  ↪ der Krake (Ordnung *Octopoda*)

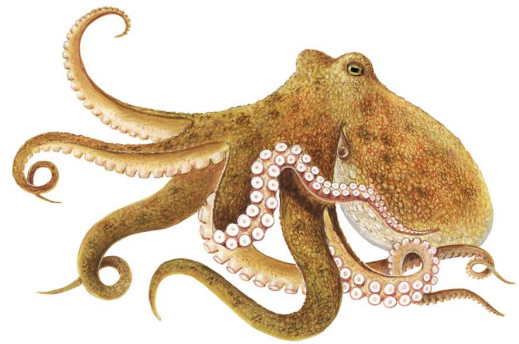

  - kann kraft seiner (acht) Tentakel parallel agieren
  - vermag sich durch Farbänderung anzupassen und
  - verfügt über ein hoch entwickeltes Nevensystem
    - um sich auf dynamische Umgebungsbedingungen und -einflüsse einzustellen
- ***POS*** — Abk. für (engl.) *Parallel Operating System*
  - ein Betriebssystem, das nicht bloß parallele Prozesse unterstützt
  - sondern dabei selbst inhärent parallel arbeitet
  - sowie sich einem wechselnden Anwendungsprofil entsprechend anpasst
    - Adressraumvirtualisierung und -devirtualisierung zur Laufzeit bei Bedarf
    - anwendungsorientierter virtuell gemeinsamer Speicher (VSM)
- DFG: seit 06/2011, 3.5 WM (2.5 FAU, 1 KIT), 1 WHK, 3 SHK
  - `https://sys.cs.fau.de/research/irtss`

Nichtflüchtigkeit energiebewusster Betriebssysteme

Definition (*NVM-pure* Betriebssystem)

Ein Betriebssystem, das NVM nicht nur für die Maschinenprogramme verwaltet, sondern auch für eigene Zwecke nutzt: das selbst komplett im NVM liegt, darin abläuft sowie bis auf Register-/Zwischenspeicher nirgends flüchtigen Speicher benutzt.

- einen auf **Energieeffizienz** und **Rechenleistung** maximierten und **Latenzzeit** minimierten Betrieb eines Rechensystems erreichen
  - Verzicht auf viele, wenn nicht sogar sämtliche, für gewöhnlich sonst zu realisierende Persistenzmaßnahmen
    - Metadatenpersistenz eines Dateisystems (Superblock, *in-core* `inode(7)`)
    - Zwischenspeicherung geschriebener Daten (*delayed write*, *lazy write*)
    - Datensynchronisation (`sync(8)`, `update(8)`)
    - *flush*-Dämon (`bdflush(2)`), ab Version 2.6 der *pdflush*-Faden
  - dadurch **Hintergrundrauschen** (*background noise*) im System verringern
- DFG: seit 08/2021, 2 WM (1 FAU, 1 RUB), 2 SHK
  - `https://sys.cs.fau.de/research/neon`

Stromausfallbewusster virtueller persistenter Speicher

Definition (*NVM-only* Betriebssystem)

Ein *NVM-pure* Betriebssystem, das herkömmlichen DRAM-basierten Hauptspeicher nur noch benutzt, um die höheren Zugriffszeiten oder Latenzen zu kaschieren, die bei NVRAM noch vorhanden sind.

- das Betriebssystem macht den Maschinenprogrammen nichtflüchtigen Hauptspeicher funktional transparent zugänglich
  - **Hochskalieren der Speicherkapazität** auf NVRAM-Basis
  - Tolerierung unvollständiger, aber unterbrochener Schreiboperationen
  - Vorbeugung vollständiger, aber wiederholter Schreiboperationen
  - Gewähr eines Restenergiefensters zum **Fixieren der Übergangszustände**
- Symbiose von NVRAM und virtueller Speicher, **Altsoftware** den Weg ebenen für direkte Ausführung im nichtflüchtigen Hauptspeicher
- DFG: ab 09/2022, 2 WM (1 BTU, 1 FAU), 2 SHK
  - `https://sys.cs.fau.de/research/pave`

Resiliente eingebettete Kommunikationsknoten

- Ausfälle, Überlastung, Angriffe und das Unerwartete meistern
  - byteadressierbaren NVM als primären Hauptspeicher begreifen
  - dem Paradigma der transaktionalen Programmierung folgen
- Kommunikations- und Betriebssystem für mobile IoT-Gerätschaften
  - Sensoren und Aktuatoren
  - heterogene Speicherarchitekturen und Kommunikationsschnittellen
- Widerstandsfähigkeit gegenüber **Betriebsstörungen**
  - **Mikrotransaktionen** im Sinne nichtblockierender Synchronisation
  - durch Ausnahmen ausgelöste **Fixpunkte** des Übergangszustands
- Widerstandsfähigkeit gegenüber **Funktionsstörungen**
  - dynamisches **Vorhersagen** Kapazität des Kommunikationskanals
  - dynamisches **Anpassen** der Reparaturtechnik und des Ablaufplans
  - **Schätzen** des Informationalters und passenden Kommunikationstempos
- DFG: ab 09/2022, 2 WM (1 FAU, 1 UDS), 2 SHK
  - `https://sys.cs.fau.de/research/respect`

Gesamtsystemanalyse beschränkter Anwendungen

- Beschränkung in zweierlei Hinsicht:
  - funktional
    - maßgeschneiderte echtzeitabhängige/-fähige Software
    - Anwendungsfall (*use case*)
  - nichtfunktional
    - Raum, Zeit, Energie
    - ungünstigster Fall (*worst-case*)
- Schwerpunkt sind **energiebeschränkte Echtzeitsysteme**
  - *a priori* Wissen zum möglichen/absehbaren Ablaufverhalten von Prozessen
  - WCRT: *worst-case response time*
  - WCRE: *worst-case response energy consumption*

Ungünstigste Reaktion (*worst-case response*)

Ressourcenverbrauchsbedarf vom Beginn einer Aufgabe bis zu ihrer Beendigung, einschließlich aller möglichen Störungen.

- vorauswissen, nichtfunktionales Verhalten automatisch zu beeinflussen
- dabei aber funktional äquivalente Systemdarstellungen beibehalten

- DFG: voraussichtlich Q3/2022, 1 WM, 1 SHK
  - `https://sys.cs.fau.de/research/watwa`

Migrationsbewusste mehrkernige Echtzeitexekutive

Migrationsentscheidungen anstatt auf globalen Lastparametern systematisch auf Basis von Hinweisen der unter (strikten) Echtzeitbedingungen ablaufenden Maschinenprogramme treffen.

- **Prozessmigration** in mehrkernigen Echtzeitsystemen
  - Hinweise zu zeitlichen und räumlichen Aspekten von Echtzeitprozessen
  - Markierung potentieller Migrationspunkte mehrfädiger Programme

  ↪ das zur Abwanderung bestimmte Prozessexemplar ist der Faden (*thread*)
- das Betriebssystem zu günstigen Entscheidungen befähigen
  - betreffs **Vorhersagbarkeit** und **Leistungsfähigkeit** des Gesamtsystems
  - angestrebte Verbesserung hinsichtlich **Antwortzeit** und **Planbarkeit**
- betrachtet werden Systeme von heterogener Speicherarchitektur
  - die durch Migration verursachten Verwaltungsgemeinkosten
  - die von Speicherort und Umfang der Migrationsdaten abhängen
- Eigenmittel: 2 WM (1 FAU, 1 TUDO), 2 SHK
  - `https://sys.cs.fau.de/research/mare`

Dynamische Betriebssystemspezialisierung

Große Systeme, einmal in Betrieb genommen, unterliegen in der Regel häufigen Änderungen — auch, um die Passgenauigkeit an sich ändernde Anwendungsanforderungen zu verbessern.

- gemeinhin werden **Allzwecksysteme** vorgefertigt und im Binärformat geliefert, ohne auf ein individuelles System zugeschnitten zu sein
  - eingeschränkte zielsystemspezifische Optimierungen zur Herstellungszeit
  - Erweiterungen der konkreten Befehlssatzebene bleiben unausgenutzt

  ↪ **Leistungspotential** der gegebenen Hardware **wird nicht ausgeschöpft**
- **weniger anspruchsvolle Anwendungen** sollten nicht für verbrauchte Ressourcen durch nicht benötigte Funktionen zahlen müssen
  - ideale Betriebssysteme bieten genau das, was eine Anwendung benötigt
  - sie wachsen/schrumpfen mit den jeweiligen Anwendungsanforderungen

  ↪ **bedarfssynchrone** (*just in time*) **Übersetzung** des Betriebssystem(kern)s
- DFG, Projektkampagne: 2 WM (1 FAU, 1 RUB), 2 SHK
  - `https://sys.cs.fau.de/research/doss`

Systeme mehr-/vielkerniger Prozessoren

faui4*	clock	cores per domain		domain		#	
		physical	logical	NUMA	tile		
*8e *8f	2.9 GHz	8	16	2	1	32	Xeon
*9big01	2.5 GHz	6	6	8	1	48	Opteron
*9big02	2.2 GHz	10	20	4	1	80	Xeon
*9big03	2.1 GHz	12	24	4	1	96	Xeon
*9big04	2 GHz[1]	64	128	2	1	256	Epyc
*9big05	2.5 GHz	16	128	2	4	1024	ThunderX2
*9phi01	1.2 GHz	6	12	2	1	24	Xeon
	1.1 GHz	57	228	2	1	456	Xeon Phi
*scc	1.5 GHz	4	8	1	1	8	Xeon
	800 MHz	2	–	–	24	48	Pentium
fastbox	3.5 GHz	4	8	1	1	8	Xeon TSX
InvasIC	50 MHz	5	5	16		80	LEON/SPARC
						2160	

[1] mit *boost* 3.35 GHz

Ab 09/22 neues, altes Gesicht...

Bachelor-, Master- oder Doktorarbeit

Literaturverzeichnis I

[1] Schröder-Preikschat, W. ; Kleinöder, J. :
Systemprogrammierung.
http://www4.informatik.uni-erlangen.de/Lehre/WS08/V_SP, 2008 *ff.*

[2] Sieh, V. :
Betriebssysteme.
http://www4.cs.fau.de/Lehre/WS17/V_BS, 2017 *ff.*