Der Scheduler von Windows 2000

Konzepte und Strategien

Daniel Lohmann

lohmann@informatik.uni-erlangen.de

Gliederung

1. Grundbegriffe
2. Eigenschaften des Schedulers
   - Grundlegende Eigenschaften
   - Prioritätenmodell
   - Dynamische Prioritätenanpassungen
3. Interner Aufbau
   - Interruptverarbeitung
   - Aufruf des Schedulers
4. Fazit

(Einige) Designziele von Windows NT

- Anwendungsportabilität
  - OS/2, Posix, Win16, Win32
- Plattformunabhängigkeit
  - Diverse RISC/CISC Architekturen
  - Ursprünglich MIPS, PowerPC, Alpha, I386
- Unterstützung für SMP

Architektur von Windows NT

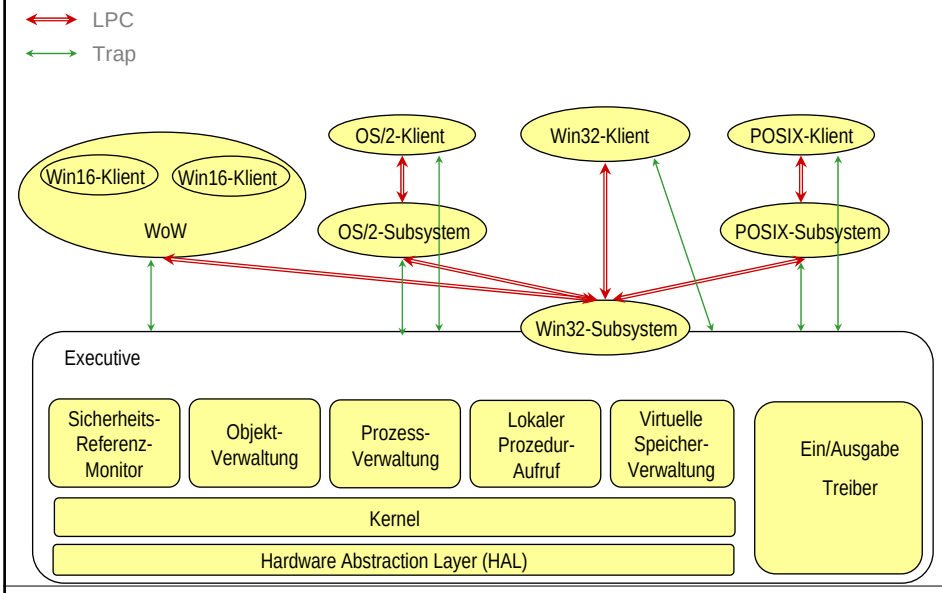

Virtueller Adressraum eines NT-Prozesses

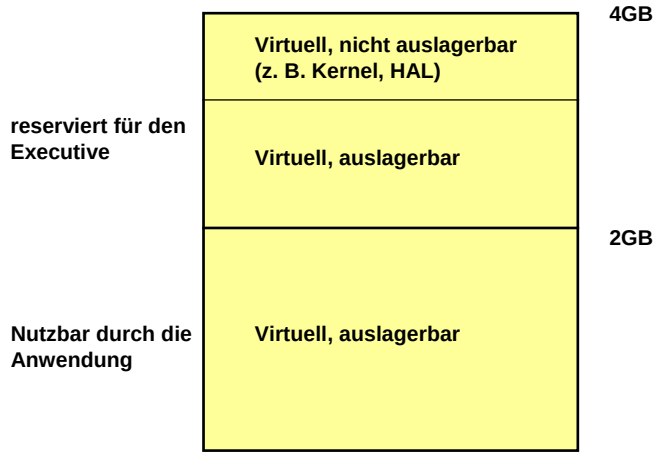

Ausführungspfade (Threads) in einem Prozess

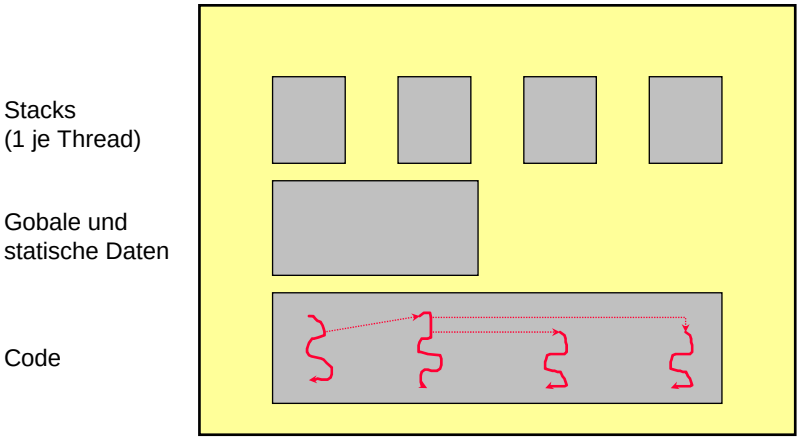

Prozesse und Threads: Zusammenfassung

- Prozess: Umgebung und Adressraum für Threads
  - Ein Win32 Prozess enthält immer mindestens 1 Thread
- Thread: Code ausführende Einheit
  - Jeder Thread verfügt über einen eigenenen Stack, und Registersatz (insbesondere PC)
  - Threads bekommen vom Scheduler Rechenzeit zugeteilt
- Alle Threads sind Kernelmode Threads
  - Usermode-Threads möglich („Fibers“), aber unüblich
- Strategie von NT: Anzahl der Threads gering halten
  - keine blockierenden API-Aufrufe
  - Overlapped (asynchrones) IO
  - Thread-Pooling

Gliederung

1. Grundbegriffe
2. Eigenschaften des Schedulers
   - Grundlegende Eigenschaften
   - Prioritätenmodell
   - Dynamische Prioritätenanpassungen
3. Interner Aufbau
   - Interruptverarbeitung
   - Aufruf des Schedulers
4. Fazit

Grundlegende Eigenschaften des Schedulers

Preemptives, Prioritätengesteuertes Scheduling:

- Thread mit höherer Priorität verdrängt Thread niedrigerer Priorität
  - Egal ob Thread sich im User- oder Kernelmode befindet
  - Die meisten Funktionen der Executive („Kernel“) sind ebenfalls als Threads implementiert
- Round-Robin bei Threads gleicher Priorität
  - Zuteilung erfolgt reihum für eine Zeitscheibe (Quantum)

Thread-Prioritäten

- Derzeit 0 bis 31, aufgeteilt in drei Bereiche
  - Variable Priorities: 1 bis 15
  - Realtime Priorities: 16 bis 31
  - Priorität 0 ist reserviert für den Nullseiten-Thread
- Threads der Executive verwenden maximal Priorität 23

Zeitscheiben (Quantum)

	Kurze Quantumwerte		Lange Quantumwerte	
	Variabel	**Fix**	**Variabel**	**Fix**
Thread in HG-Prozess	6	18	12	36
Thread in VG-Prozess	12	18	24	36
Aktiver Thread in VG-Prozess	18	18	36	36

Quantum wird vermindert

- um den Wert 3 bei jedem Clock-Tick (alle 10 bzw. 15 msec)
- um den Wert 1, falls Thread in den Wartezustand geht

Länge einer Zeitscheibe: 20 – 120 msec

Prioritätsklassen und relative Threadpriorität

Relative Thread Priority		Process Priority Class: Idle 4	Below Normal 6	Normal 8	Above Normal 10	High 13	Realtime 24
Time Critical	=15	15	15	15	15	15	31
Highest	+2	6	8	10	12	15	26
Above Normal	+1	5	7	9	11	14	25
Normal		4	6	8	10	13	24
Below Normal	-1	3	5	7	9	12	23
Lowest	-2	2	4	6	8	11	22
Idle	=1	1	1	1	1	1	16

Prioritäten: Variable Priorities

Variable Priorities (1-15)

- Scheduler verwendet Strategien um „wichtige“ Threads zu bevorzugen
  - Quantum-Stretching (Bevorzugung des aktiven GUI-Threads)
  - dynamische Anhebung (Boost) der Priorität für wenige Zeitscheiben bei Ereignissen
- Fortschrittsgarantie
  - Alle 3 bis 4 Sekunden bekommen bis zu 10 „benachteiligte“ Threads für zwei Zeitscheiben die Priorität 15
- Threadpriorität berechnet sich wie folgt (vereinfacht):

  Prozessesprioritätsklasse + Threadpriorität + Boost

Prioritäten: Realtime Priorities

Realtime Priorities (16-31)

- Reines prioritätengesteuertes Round-Robin
  - Keine Fortschrittsgarantie
  - Keine dynamische Anhebung
  - Betriebssystem kann negativ beeinflusst werden
  - Spezielles Benutzerrecht erforderlich (SeIncreaseBasePriorityPrivilege)
- Threadpriorität berechnet sich wie folgt:
  REALTIME_PRIORITY_CLASS + Threadpriorität

Dynamische Prioritätsanpassung

Dynamic Boosts

- Thread-Prioritäten werden vom System in bestimmten Situationen dynamisch angehoben (nicht bei REALTIME_PRIORITY_CLASS)
  - Platten-Ein- oder Ausgabe abgeschlossen: +1
  - Maus, Tastatureingabe: +6
  - Semaphore, Event, Mutex: +1
  - Andere Ereignisse (Netzwerk, Pipe,...) +2
  - Ereignis in Vordergrundapplikation +2
- Dynamic Boost wird „verbraucht“ (eine Stufe pro Quantum)

Änderung der Priorität nach einem dynamic Boost

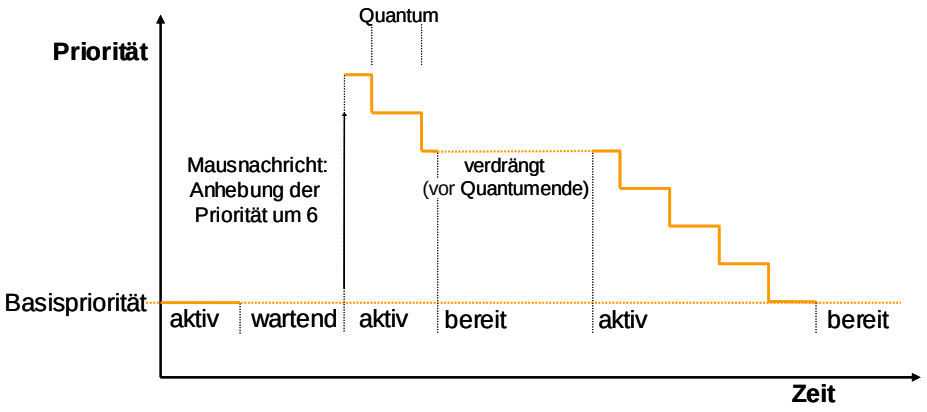

Anhebung der Priorität durch Balance-Set-Manager

Etwa alle 3-4 Sekunden erhalten bis zu 10 „benachteiligte“ Threads für zwei Zeitscheiben die Priorität 15

– Fortschrittsgarantie

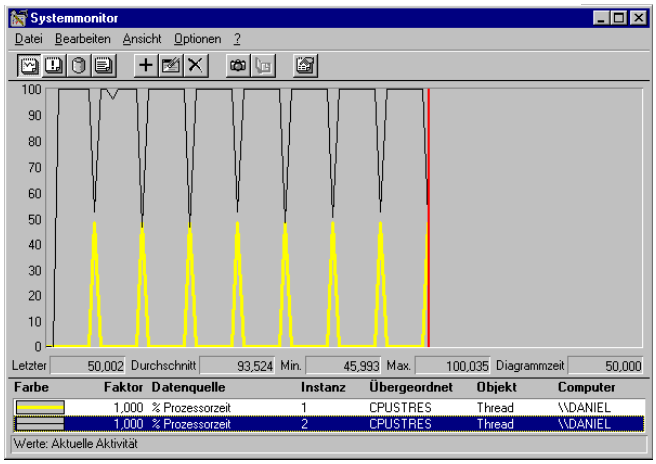

Gliederung

1. Grundbegriffe
2. Eigenschaften des Schedulers
   - Grundlegende Eigenschaften
   - Prioritätenmodell
   - Dynamische Prioritätenanpassungen
3. Interner Aufbau
   - Interruptverarbeitung
   - Aufruf des Schedulers
4. Fazit

Trap / Interruptverarbeitung

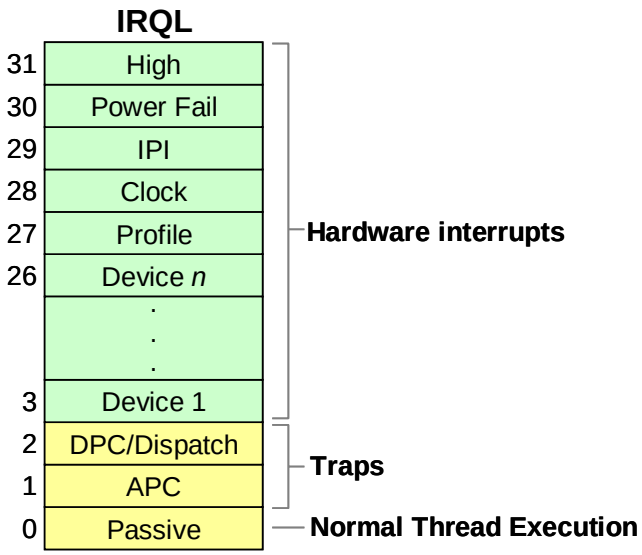

Interruptverarbeitung auf SMP Systemen

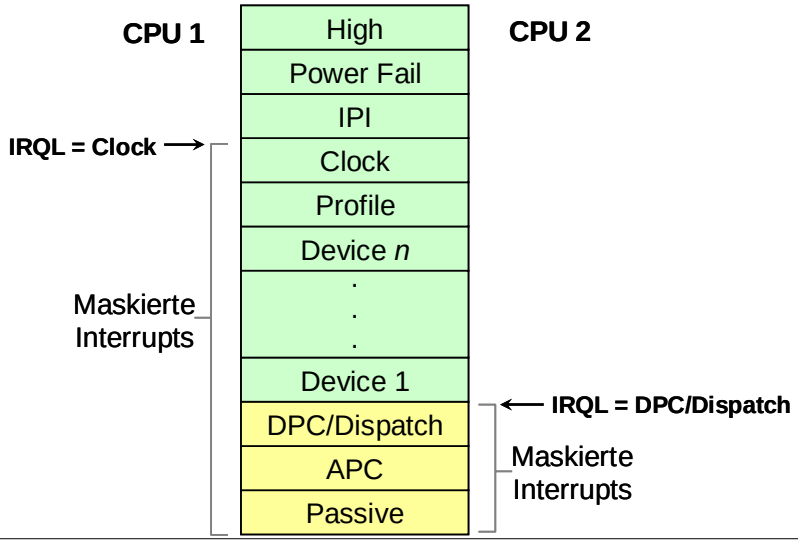

Aufruf des Schedulers

Direkter Aufruf des Schedulers

- Ende eines Threads (ExitThread())
- Freiwilligem Warten (Sleep(), WaitForXXX(), …)

Indirekter Aufruf des Schedulers

- Quantum abgelaufen
- Ein Thread höherer Priorität wird ablaufbereit

Indirekter Aufruf erfolgt durch DPCs und Traps

Aufruf des Schedulers durch Traps

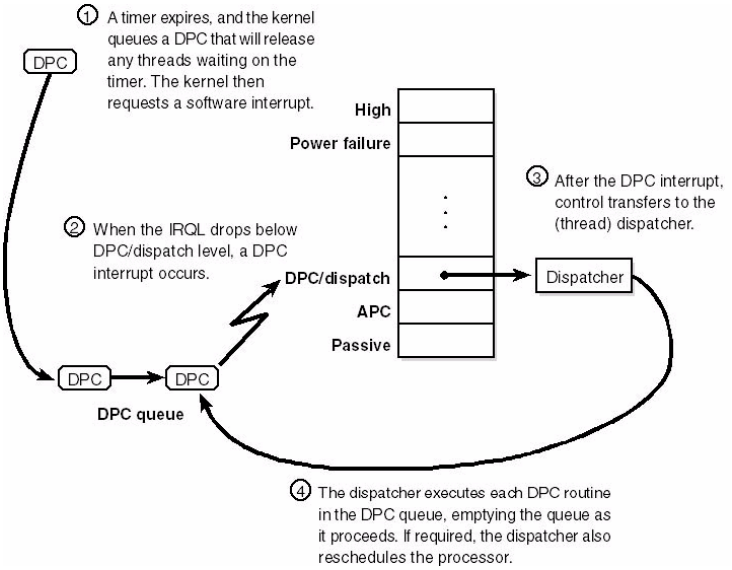

Auswahl des nächsten Threads (SMP)

Ziel: Cacheausnutzung maximieren

Affinität (Zuordnung von CPUs zu Thread):

- **hard affinity:** Feste Zuordnung
  → durch *SetThreadAffinity()*
- **ideal processor:** Gewünschte Zuordnung
  → durch *SetThreadIdealProcessor()*
- **soft affinity:** Letzte CPU, auf welcher der Thread lief
  → intern vom Scheduler verwaltet
- **last run:** Letzte Zuweisung zu einer CPU
  → intern vom Scheduler verwaltet

Auswahl des nächsten Threads (SMP)

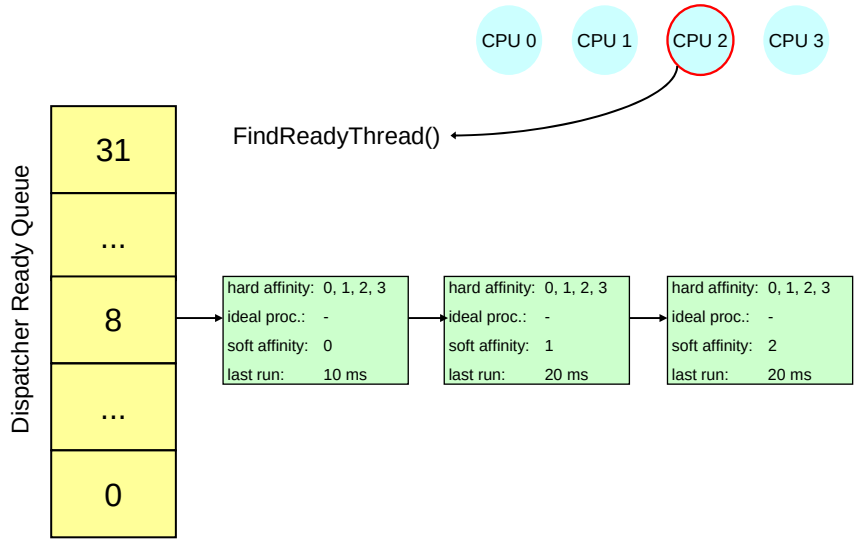

Auswahl des nächsten Threads (SMP)

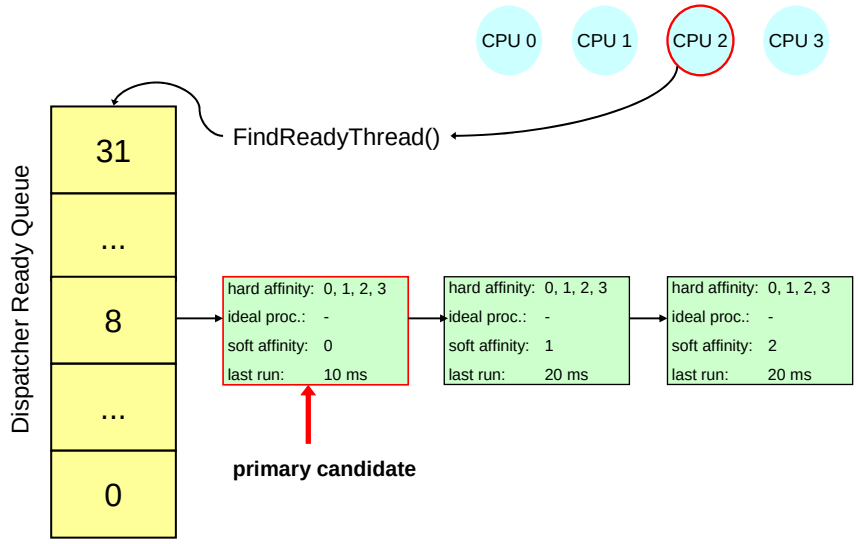

Auswahl des nächsten Threads (SMP)

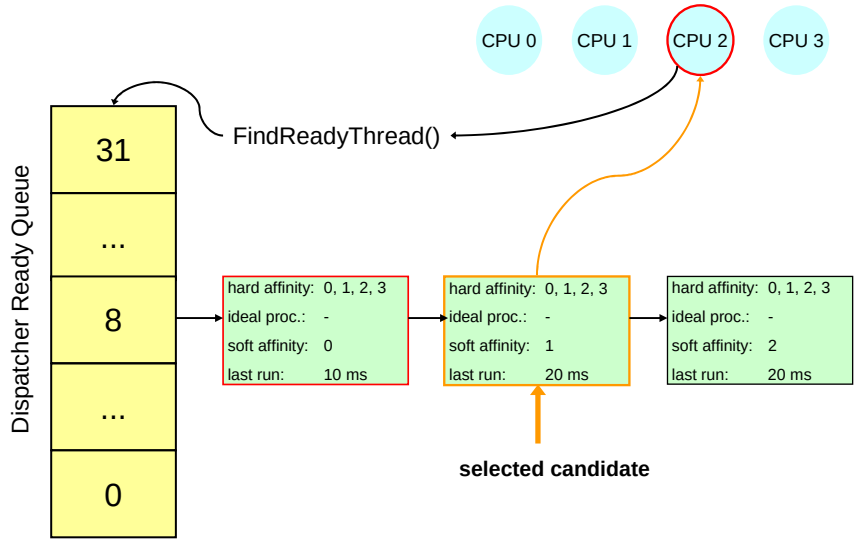

Fazit

Prioritätenmodell erlaubt feine Zuteilung der Prozessorzeit

- Dynamische Anpassungen beachten
- Usermode-Threads mit hohen Echtzeitprioritäten haben Vorrang vor allen System-Threads!
- Executive ist im allgemeinen unterbrechbar

Interruptverarbeitung

- Aufenthaltszeit des Systems in Interrupts bewusst klein gehalten.
  - Epiloge in DPCs ausgelagert
  - Längerfristige Arbeiten werden an Systemarbeitsthreads vergeben
- Gute Skalierbarkeit für SMP Systeme