Systemy operacyjne

Przykłady implementacji planowania przydziału procesora

Wykład prowadzą:
Jerzy Brzeziński
Dariusz Wawrzyniak

Systemy operacyjne

Plan wykładu

- Tradycyjne szeregowanie w systemie UNIX
- Szeregowanie w systemie Linux z jądrem 2.6
- Szeregowanie w systemie Windows 2000/XP

Systemy operacyjne

Szeregowanie w systemie UNIX

Systemy operacyjne

Informacje wstępne

- Stosowany jest algorytm rotacyjny z wywłaszczaniem, oparty na priorytetach dynamicznych.
- Wartość priorytetu jest z zakresu od 0 do 127, mniejsza wartość liczbowa oznacza wyższy priorytet.
- Priorytet (dynamiczny) składa się z części statycznej i części modyfikowanej przez planistę.
- Część statyczna składa się z *bazy* (definiowanej przez system) oraz wartość *nice* (ustalanej przez użytkownika lub nadzorcę).
- Priorytet procesu ustalany jest zawsze, gdy proces ten przechodzi z trybu jądra do trybu użytkownika.
- Okresowo (mniej więcej co 1 sekundę) przeliczane są priorytety wszystkich procesów gotowych.

Przykłady implementacji planowania przydziału procesora (4)

Systemy operacyjne

Struktury danych na potrzeby szeregowania

- Na potrzeby szeregowania procesy zorganizowane są w kolejkę priorytetową — **`qs`**.
- Każda pozycja tablicy kolejek odpowiada czterem wartościom priorytetu.
- Wektor bitowy **`whichqs`** wskazuje pozycje, na których są niepuste kolejki.
- Wyróżnia się 3 zakresy priorytetu:
  - poziom jądra dla procesów nieprzerywalnych,
  - poziom jądra dla procesów przerywalnych,
  - poziom użytkownika.

Przykłady implementacji planowania przydziału procesora (5)

Systemy operacyjne

Kolejka priorytetowa

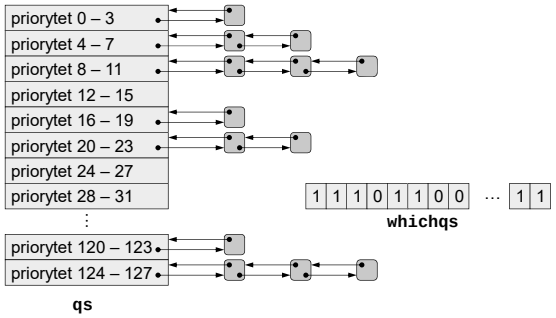

Przykłady implementacji planowania przydziału procesora (6)

Systemy operacyjne

Parametry funkcji priorytetu

- cpu_i — miara dotychczasowego wykorzystania procesora przez *i*-ty proces,
- $baza_i$ — priorytet bazowy procesu *i*-tego,
- $nice_i$ — składowa priorytetu procesu *i*-tego definiowana przez użytkownika,
- pri_i — priorytet procesu *i*-tego (mniejsza wartość oznacza wyższy priorytet),
- $usrpri_i$ — priorytet procesu *i*-tego w trybie użytkownika.

Przykłady implementacji planowania przydziału procesora (7)

Systemy operacyjne

Przeliczanie priorytetu

1) $cpu_i := cpu_i + 1$
2) $cpu_i := \frac{cpu_i}{2}$
3) $usrpri_i := baza_i + \frac{cpu_i}{2} + nice_i$
4) $pri_i := usrpri_i$

Przykłady implementacji planowania przydziału procesora (8)

Systemy operacyjne

Przykład

$usrpri_1$	cpu_1
60	0 1 ... 60
75	30
67	15
63	7 8 ... 67

proces P_1

$usrpri_2$	cpu_2
60	0
60	0 1 ... 60
75	30
67	15

proces P_2

$usrpri_3$	cpu_3
60	0
60	0
60	0 1 ... 60
75	30

proces P_3

Przykłady implementacji planowania przydziału procesora (9)

Systemy operacyjne

Szeregowanie w systemie Linux (jądro 2.6)

Algorytm o stałej złożoności O(1),
zastąpiony wersji 2.6.23 przez CFS

Systemy operacyjne

Informacje wstępne

- Stosowany jest algorytm rotacyjny z wywłaszczaniem, oparty na priorytetach dynamicznych.
- Wyróżnia 140 poziomów priorytetu związanych z 3 klasami (politykami) szeregowania:
  - SCHED_OTHER — polityka szeregowania zwykłych zadań,
  - SCHED_FIFO — polityka szeregowania zadań czasu rzeczywistego zgodnie z zasadą FIFO,
  - SCHED_RR — polityka szeregowania zadań czasu rzeczywistego w sposób rotacyjny.
- Większa wartość oznacza niższy priorytet.

Systemy operacyjne

Priorytety procesów zwykłych

- Priorytet (dynamiczny) składa się z części statycznej i części modyfikowanej przez planistę.
- Część statyczna definiowana jest przez wartość nice z zakresu od -20 do 19.
- Priorytet dynamiczny decyduje zarówno o pierwszeństwie w dostępie do procesora jaki i wielkości kwantu czasu (od 10 ms do 200 ms).
- Preferowane są (nagradzane wyższym priorytetem dynamicznym) zadania ograniczone wejściem-wyjściem.

Systemy operacyjne

Priorytety procesów czasu rzeczywistego

- Priorytety przydzielane są statycznie (nie zmieniają się) z zakresu od 0 do 99.
- Priorytety procesów czasu rzeczywistego są zawsze większe od priorytetów zadań zwykłych.
- Do grupy zadań czasu rzeczywistego mogą być dołączane tylko procesy nadzorcy (użytkownika uprzywilejowanego root).

Przykłady implementacji planowania przydziału procesora (13)

Systemy operacyjne

Odwzorowanie w tablicy priorytetów

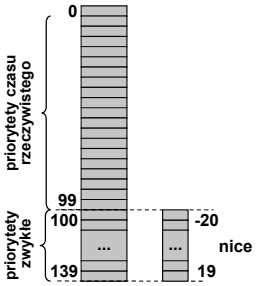

Przykłady implementacji planowania przydziału procesora (14)

Systemy operacyjne

Struktury danych do zarządzania procesami gotowymi

- Tablica priorytetów dla zadań aktywnych — tablica kolejek procesów gotowych, które nie wykorzystały jeszcze kwantu czasu
- Tablica priorytetów dla zadań przeterminowanych — tablica kolejek procesów gotowych, które wykorzystały kwant czasu
- Mapa (maska) bitowa dla każdej z tablic, identyfikująca niepuste kolejki w tablicy priorytetowej

Przykłady implementacji planowania przydziału procesora (15)

Systemy operacyjne

Wywłaszczenie

- Wywłaszczenie procesu w trybie użytkownika może nastąpić przy powrocie z trybu jądra po obsłużeniu przerwania lub zakończeniu wywołania systemowego, gdy znacznik *need_resched* jest ustawiony.
- Znacznik jest ustawiany w następujących przypadkach:
  - po upływie kwantu czasu bieżącego (wykonywanego) zadania,
  - po uzyskaniu gotowości przez zadanie o wyższym niż bieżące priorytecie.

Przykłady implementacji planowania przydziału procesora (16)

Systemy operacyjne

Upłynięcie kwantu czasu

- Po upłynięciu kwantu czasu wykonywanego procesu zwykłego następuje przeliczenie jego priorytetu oraz wyznaczenie następnego kwantu czasu.
- Jeśli proces charakteryzuje się dużym stopniem interaktywności, a w systemie nie ma zadań przeterminowanych jest on umieszczany na odpowiedniej pozycji w tablicy priorytetów dla zadań aktywnych, w przeciwnym przypadku umieszczany jest tablicy priorytetów dla zadań przeterminowanych.

Przykłady implementacji planowania przydziału procesora (17)

Systemy operacyjne

Zmiana epoki

- Jeśli tablica priorytetów dla zadań aktywnych jest pusta (wszystkie procesy gotowe wykorzystały swój kwant czasu), następuje zmiana epoki.
- Zmiana epoki oznacza zamianę tablicy priorytetów: tablica priorytetów dla zadań przeterminowanych staję się tablicą dla zadań aktywnych i odwrotnie.

Przykłady implementacji planowania przydziału procesora (18)

Systemy operacyjne

Zmiana priorytetów dynamicznych

- Początkowy priorytet procesu zwykłego równy jest wartości *nice*.
- Wartość priorytetu może zostać zmieniona następująco:
  - zwiększona o 5 dla zadań ograniczonych procesorem (obniżenia priorytetu),
  - zmniejszona o 5 dla zadań ograniczonych wejściem-wyjściem, rozumianych przez domniemanie jako interaktywne,
  - pozostać bez zmian.
- Proporcjonalnie do priorytetu ustalana jest wielkość kwantu czasu (z zakresu od 10 ms do 200 ms, domyślnie 100 ms).

Przykłady implementacji planowania przydziału procesora (19)

Systemy operacyjne

Ocena interaktywności

- Miarą interaktywności jest względna długość okresów korzystania z procesora oraz przebywania w stanie oczekiwania.
- Implementacją takiej koncepcji w systemie Linux jest atrybut procesu *sleep_avg*, zmniejszany w czasie wykonywania procesu, a zwiększany po wyjściu ze stanu oczekiwania.
- Wartość *sleep_avg* zmienia się od 0 do `MAX_SLEEP_AVG`, a wartością domyślna jest 10 ms.

Przykłady implementacji planowania przydziału procesora (20)

Systemy operacyjne

Planowanie w klasie czasu rzeczywistego

- Na danym poziomie priorytetu najpierw wybierane są procesy klasy SCHED_FIFO.
- Proces klasy SCHED_FIFO wykonuje się tak długa, aż nie odda procesora lub nie pojawi się proces o wyższym priorytecie.
- Proces klasy SCHED_RR wykonuje się podobnie jak proces klasy SCHED_FIFO, ale po upływie kwantu czasu oddaje zasoby innemu procesowi o tym samym priorytecie (jeśli taki proces istnieje).

Przykłady implementacji planowania przydziału procesora (21)

Szeregowanie w systemie Windows 2000/XP

Informacje wstępne

- Szeregowaniu podlegają wątki, stanowiące obiekty w obrębie procesu.
- Stosowany jest algorytm rotacyjny z wywłaszczaniem, oparty na priorytetach dynamicznych.
- Wyróżnia się 32 poziomy priorytetu:
  - 0 — bezczynność (poziom systemowy, niedostępny),
  - 1 do 15 — priorytety dynamiczne (zmienne)
  - 16 do 31 — priorytety czasu rzeczywistego
- Większa wartość (poziom) oznacza wyższy priorytet.

Definiowanie priorytetu

- Zdefiniowanie klasy priorytetu dla procesu: idle (4), below normal (6), normal (8), above normal (10), high (13), realtime (24).
- Zmodyfikowanie priorytetu wątku w ramach klasy priorytetu: idle (-15), lowest (-2), below normal (-1), normal (0), above normal (+1), highest (+2), time critical (+15).
- Priorytet bazowy wątku jest sumą wartości dla klasy oraz modyfikatora (priorytetu wątku).

Priorytet bazowy wątku

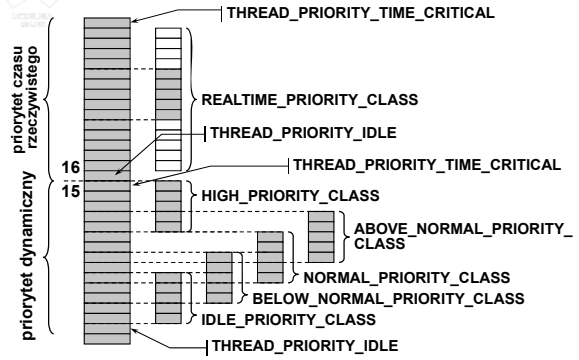

Struktury danych do zarządzania wątkami gotowymi

- *KiDispatcherReadyListHead* — tablica kolejek wątków gotowych.
- *KiReadySummary* — maska bitowa identyfikująca niepuste kolejki w tablicy *KiDispatcherReadyListHead*.

Tablica kolejek wątków gotowych

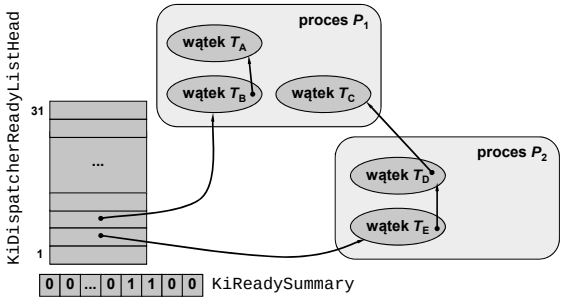

Systemy operacyjne

Przełączanie kontekstu

- Zakończenie działania wątku
- Przejście w stan oczekiwania (samoistnie — w wyniku odwołania do systemu operacyjnego w programie np. wątku w związku z synchronizacją lub operacją wejścia-wyjścia)
- Wywłaszczenie przez wątek o wyższym priorytecie
- Upłynięcie kwantu czasu

Przykłady implementacji planowania przydziału procesora (28)

Systemy operacyjne

Procedury zarządzania wątkami gotowymi

- *FindReadyThread*
  - uruchamiana po zwolnieniu procesora przez wątek wykonywany,
  - szuka wątku gotowego o najwyższym priorytecie i ekspediuje go na procesor.
- *ReadyThread*
  - uruchamiana dla wątku, który przechodzi w stan gotowości lub zwiększa priorytet,
  - porównuje priorytet gotowego wątku z priorytetem wątku wykonywanego i albo wywłaszcza wątek wykonywany albo kolejkuje wątek gotowy.

Przykłady implementacji planowania przydziału procesora (29)

Systemy operacyjne

Przebieg wywłaszczenia przez ReadyThread

Niech T_g oznacza wątek gotowy, T_w wątek wykonywany, a pri(T) priorytet wątku T.

if pri(T_g) ≤ pri(T_w) **then**
  if liczba wykorzystanych kwantów przez $T_g \geq 1$ **then**
    umieść T_g na końcu *KiDispatcherReadyListHead*[pri(T_g)]
  else
    umieść T_g na pocz. *KiDispatcherReadyListHead*[pri(T_g)]
else
    umieść T_w na pocz. *KiDispatcherReadyListHead*[pri(T_w)]

Przykłady implementacji planowania przydziału procesora (30)

Systemy operacyjne

Upłynięcie kwantu czasu

- Kwant wyrażanych jest *jednostkach kwantu czasu*.
- Liczba jednostek do dyspozycji wątku wynosi:
  - 6 — w wersjach dla komputerów osobistych i stacji,
  - 36 — w wersjach dla serwerów.
- Z każdym taktem zegara odejmowane są 3 jednostki.
- Upłynięcie kwantu czasu (zredukowanie liczby jednostek do 0) powoduje wywłaszczenie z procesora pod warunkiem, że jest gotowy inny wątek o takim samym (lub wyższym) priorytecie.
- Jeśli dotychczas działający wątek jest jedynym o tak wysokim priorytecie, przydzielony zostaje mu kolejny kwant.

Przykłady implementacji planowania przydziału procesora (31)

Systemy operacyjne

Regulacja kwantu czasu (1)

- Wątkowi o priorytecie mniejszym niż 16 zabierana jest jedna jednostka kwantu, gdy wchodzi on w stan oczekiwania.
- Jeśli jednak wątek działa na poziomie 14 lub wyższym, przed zredukowaniem jego kwant jest odnawiany.
- Podobne postępowanie jest przeprowadzane w pewnych przypadku wątków pierwszoplanowych, nawet jeśli ich priorytet jest mniejszy niż 14.
- W przypadku wątków o priorytetach powyżej 15 liczba jednostek kwantu jest odnawiana po wyjściu ze stanu oczekiwania.

Przykłady implementacji planowania przydziału procesora (32)

Systemy operacyjne

Regulacja kwantu czasu (2)

- Wątki procesu pierwszoplanowego mogą uzyskać 3-krotnie dłuższy kwant czasu, zależnie od ustawienia rejestru *HKLM\SYSTEM\CurrentControlSet\Control\PriorityControl\Win32PrioritySeparation*
- Wydłużenie kwantu ma na celu zwiększenie preferencji dla wątków związanych z oknem pierwszoplanowym przy jednoczesnym uniknięciu zagłodzenia wątków drugoplanowych.
- W ramach przeciwdziałania głodzeniu wydłużany jest również 2krotnie czas dla wątków oczekujących długo (ponad 300 taktów) na procesor. Celem tego wydłużenia jest przeciwdziałanie inwersji priorytetów.

Przykłady implementacji planowania przydziału procesora (33)

Systemy operacyjne

Zmiana dynamicznych priorytetów wątków

- Podwyższenie priorytetu wątku (maksymalnie do wartości 15) może nastąpić w następujących przypadkach:
  - po zakończeniu operacji wejścia-wyjścia,
  - po oczekiwaniu na zdarzenie lub semafor,
  - po zakończeniu oczekiwania przez wątek pierwszoplanowy,
  - po przebudzeniu wątku GUI,
  - po zbyt długim oczekiwaniu w stanie gotowości.
- Podwyższony priorytet jest obniżany sukcesywnie o 1 po upływie kwantu czasu, aż wróci do wartości bazowej.

Przykłady implementacji planowania przydziału procesora (34)

Systemy operacyjne

Wzrost priorytetu po zakończeniu operacji wejścia-wyjścia

- Operacja związana z dyskiem, CD, portem równoległym lub kartą video — wzrost o 1
- Operacja związana z siecią, portem szeregowym, potokiem, skrytką pocztową — wzrost o 2
- Operacja związana z klawiaturą lub myszą — wzrost o 6
- Operacja związana z kartą dźwiękową — wzrost o 8
- Wartość podwyższenia dodawana jest do **bazowego** priorytetu wątku.

Przykłady implementacji planowania przydziału procesora (35)

Systemy operacyjne

Wzrost priorytetu po oczekiwaniu na zdarzenie lub semafor

- Wartość zwiększenia, 1, dodawana jest do **bazowego** priorytetu wątku.
- Kwant czasu procesora zmniejszany jest o 1 jednostkę.

Przykłady implementacji planowania przydziału procesora (36)

Systemy operacyjne

Wzrost priorytetu po zakończeniu oczekiwania przez wątek pierwszoplanowy

- Priorytet zwiększany jest o wartość zmiennej jądra *PsPrioritySeparation*, dostępnej też jako jedno z pól w rejestrze Windows pod nazwą *HKLM\SYSTEM\CurrentControlSet\Control\PriorityControl\Win32PrioritySeparation*
- Wartość zwiększenia dodawana jest do **bieżącego** priorytetu wątku.
- Zależnie do wartości *Win32PrioritySeparation* może zostać zwiększony kwant czasu dla wszystkich wątków procesu pierwszoplanowego.

Systemy operacyjne

Wzrost priorytetu po przebudzeniu wątku GUI

- Wartość zwiększenia — 2 — dodawana jest do **bieżącego** priorytetu wątku.

Systemy operacyjne

Przeciwdziałanie głodzeniu

- Co sekundę uruchamiany jest wątek *balance set manager*, którego jednym z zadań jest sprawdzanie czasu bieżącego oczekiwania wątków gotowych.
- Jeśli wątek oczekuje dłużej niż 300 taktów zegara (około 3 – 4 sekundy), jego priorytet uzyskuje wartość 15, a kwant czasu zwiększa się dwukrotnie, a w wersjach „serwerowych” czterokrotnie.
- Po upływie przyznanego kwantu, priorytet wątku wraca do poziomu bazowego.