## Operační systémy 1

# Procesy

Petr Krajča

Katedra informatiky
Univerzita Palackého v Olomouci

# Procesy (1/2)

- neformálně: proces = běžící program (vykonává činnost)
- proces charakterizuje:
  - kód programu
  - paměťový prostor
  - data – statická a dynamická (halda)
  - zásobník
  - registry
- operační systém: organizace sekvenčních procesů
- oddělení jednotlivých úloh (abstrakce)
- multiprogramování: (zdánlivě) souběžný běh více procesů
- efektivní využití prostředků CPU (čekání na I/O)
- komunikace mezi procesy, sdílení zdrojů $\Longrightarrow$ synchronizace

# Životní cyklus procesu

**Obecný životní cyklus procesu**

- nový (new) – proces byl vytvořen
- připravený (ready) – proces čeká, až mu bude přidělen CPU
- běžící (running) – CPU byl přidělen procesor a právě provádí činnost
- čekající (waiting/blocked) – proces čeká na vnější událost (např. na vyřízení I/O požadavku, synchronizační primitiva)
- ukončený (terminated) – proces skončil svou činnost (dobrovolně $\times$ nedobrovolně)

**Rozšíření**

- suspend – proces byl odsunut do sekundární paměti (obr. Sta 123)
- ready/suspend + block/suspend – vylepšení předchozího mechanizmu
- fronty pro přechod mezi stavy (obr. Sta 121)

# Informace o procesu

- tabulka procesů $\Longrightarrow$ PCB: process control block – informace o procesu

**Informace identifikující proces**

- identifikátor procesu, uživatele, rodičovského procesu

**Stavové informace**

- stav uživatelských registrů
- stav řídících registrů (IP, PSW)
- vrchol zásobníku(ů)

**Řídící informace**

- informace sloužící k plánování (stav procesu, priorita, odkazy na čekající události)
- informace o přidělené paměti
- informace o používaných I/O zařízeních, otevřených souborech, atd.
- oprávnění, atd.

# Přepínání procesů (context switch)

1. uložení stavu CPU (kontextu, tj. registrů, IP, SP) do PCB aktuálního procesu
2. aktualizace PCB (změna stavu, atd.)
3. zařazení procesu do příslušné fronty
4. volba nového procesu
5. aktualizace datových struktur pro nový proces (nastavení paměti, atd.)
6. načtení kontextu z PCB nového procesu

- $\Longrightarrow$ jde řešit softwarově nebo s podporou HW (různá náročnost na čas CPU)
- kooperativní $\times$ preemptivní přepínání

**Důvody k přepínání**

- vypršení přiděleného časového kvanta (nutná podpora HW)
- přerušení I/O (aktuální proces může pokračovat $\times$ čekající proces může začít běžet)
- výpadek paměťové stránky, vyvolání výjimky (např. dělení nulou)

# Plánování procesů (1/2)

- potřeba efektivně plánovat procesorový čas
- časové kvantum: maximální čas přidělený procesu
- samotné přepnutí procesu má režii (uložení kontextu, vyprázdnění cache) $\Longrightarrow$ latence
- Jak zvolit velikost? $\Longrightarrow$ interaktivita $\times$ odvedená práce
- CPU-I/O Burst cycle: pravidelné střídání požadavků na CPU a I/O
- $\Longrightarrow$ procesy náročné na CPU $\times$ I/O

**Typy plánování**

- dlouhodobé – rozhoduje, zda bude přijat k běhu (změna stavu z new na ready)
- střednědobé – načtení/odložení procesu do sekundární paměti
- krátkodobé – vybírá mezi dostupnými procesy ty, které budou spuštěny na CPU (přechod ze stavu ready do running)
- I/O – rozhoduje jednotlivé požadavky na I/O

# Plánování procesů (2/2)

**Různé typy úloh/systémů**

- interaktivní
- dávkové zpracování
- pracující v reálném čase

**Obecné požadavky na plánování procesů**

- spravedlnost – každému procesu by v rozumné době měl být přidělen CPU
- vyváženost – celý systém běží
- efektivita – maximální využití CPU
- maximalizace odvedené práce (throughput)
- minimalizace doby odezvy
- minimalizace doby průchodu systémem (turnaround)

# Algoritmy pro plánování procesů (1/3)

- vhodné pro dávkové zpracování

**First-Come-First-Served**

- první proces získá procesor
- nové procesy čekají ve frontě
- proces po skončení čekání zařazen na konec fronty
- nepreemptivní
- jednoduchý, neefektivní

**Shortest Job First**

- vybere se takový proces, který poběží nejkratší dobu
- nepreemptivní
- zlepšuje celkovou průchodnost systémem
- je potřeba znát (odhadnout) čas, který proces potřebuje

**Shortest Remaining Time Next**

- pokud nový proces potřebuje k dokončení činnosti méně času než aktuální, je spuštěn
- preemptivní

# Algoritmy pro plánování procesů (2/3)

- vhodné pro interaktivní systémy

**Round robin**

- každý proces má pevně stanovené kvantum
- velikost kvanta? ($\Longrightarrow$ mírně větší než je typicky potřeba)
- připravené procesy jsou řazeny ve frontě a postupně dostavají CPU
- vhodný pro obecné použití (relativně spravedlivý)
- protežuje na CPU náročné procesy ($\Longrightarrow$ přidaná další fronta pro procesy po zpracování I/O, Sta 406)

**Prioritní fronta (obr. Sta 399)**

- každý proces má definovanou prioritu
- statické $\times$ dynamické nastavení priority (např. vyšší priorita po I/O)
- systém eviduje pro každou prioritu frontu (čekající procesy)
- riziko vyhladovění procesů s nízkou prioritou
- rozšíření: nastavení různých velikostí kvant pro jednotlivé priority (přesun mezi prioritami, nižší priorita $\Longrightarrow$ delší kvantum)

# Algoritmy pro plánování procesů (3/3)

**Shortest Process Next**

- vhodný pro interaktivní systémy (krátká doba činnosti + čekání)
- používá se odhad, podle předchozí aktivity procesu

**Guaranteed Scheduling**

- reálně přiděluje stejný čas CPU
- máme-li $n$ procesů, každý proces má získat $\frac{1}{n}$ CPU
- určí se poměr času, kolik získal a kolik má získat ($< 1$ – proces měl méně času)
- volí se proces s nejmenším poměrem

**Lottery Scheduling**

- proces dostane příděl ,,losů"
- procesy voleny náhodně (proporcionální přidělování)
- možnost vzájemné výměny losů mezi procesy

**Fair-share Scheduling**

- plánování podle skupin procesů (např. podle uživatelů)

# Úlohy běžící v reálném čase

- nutné, aby systém zareagoval na požadavek v požadovaném intervalu (důležité pro řídící systémy, např. v průmyslu)
- dva typy úloh:
  - hard real-time – požadavek je potřeba vyřešit do určité přesně dané doby (intervalu)
  - soft real-time – zpoždění vyřešení úlohy je tolerovatelné
- periodické $\times$ neperiodické úkoly
- systém nemusí být schopen všem požadavkům vyhovět

**Varianty plánování**

- statickou tabulkou – obsluha periodických úkolů je dána předem
- statické definice priorit – jednotlivým úlohám jsou nastaveny priority, aby byla splněna zadaná kritéria
- dynamické plánování – proces je spuštěn, pokud je možné splnit jeho požadavky
- dynamicky nejlepší možné – žádná omezení, pokud nebylo možné splnit všechny požadavky v systému, proces je odstraněn

# Vlákna (1/2)

- proces = sekvence vykonávaných instrukcí v jednom paměťovém prostoru
- procesy jsou od sebe izolovány $\Longrightarrow$ nemusí být vždy žádoucí
- obecnější přístup $\Longrightarrow$ proces = správa zdrojů (data, kód), vlákno = vykonávaný kód
- možnost více vláken v rámci jednoho procesu
- každé vlákno má své registry, zásobník, IP, stav (stejně jako proces); jinak jsou zdroje sdílené
- vlákna sdílí stejné globální proměnné (data)$\Longrightarrow$ žádná ochrana (předpokládá se, že není třeba $\Longrightarrow$ potřeba synchronizace)
- využití vláken
  - rozdělení běhu na popředí a na pozadí (CPU $\times$ I/O)
  - asynchronní zpracování dat
  - víceprocesorové stroje
  - modulární architektura

# Vlákna (2/2)

**Vztah proces-vlákno**

- 1:1 – systémy, kde proces = vlákno
- 1:N – systémy, kde proces může mít více vláken (nejčastější řešení)
- N:1/M:N – více procesů pracuje s jedním vláknem (clustery, spíše hypotické řešení)

**Implementace vláken**

- jako knihovna v uživatelském prostoru
- součást jádra operačního systému
- kombinované řešení
- green threads

# Implementace vláken (1/2)

**V uživatelském prostoru**

- proces sám se stará o správu a přepínání vláken
- vlastní tabulka vláken
- nejde použít preempce $\Longrightarrow$ kooperativní přepínání (rychlé – není potřeba systémové volání)
- možnost použít plánovací algoritmus dle potřeby
- problém s plánováním v rámci operačního systému (OS neví nic o vláknech)
- problém s blokujícími systémovými voláními (jsou zablokována všechna vlákna)

# Implementace vláken (2/2)

**V jádře**

- jádro spravuje pro každé vlákno struktury podobně jako pro procesy (registry, stav, ...)
- řeší problém s blokujícími voláními
- vytvoření vlákna pomalejší (recyklace vláken procesu $\Longrightarrow$ pool vláken)
- přepínání mezi vlákny jednoho procesu rychlejší (než mezi procesy; ale pomalejší než u vláken v uživatelském prostoru)
- preemptivita

**Hybridní**

- proces má M vláken v jádře, které má každé $N_i$ vláken uživatelském prostoru
- v OS ústup, renesance v Go

# Implementační aspekty: UNIX (1/2)

- proces – původně základní entita vykonávající činnost
- procesy tvoří hierarchii, každý proces identifikován pomocí PID
- systém při inicializaci spustí první proces (`init`)
- nový proces (potomek) vytvořen voláním `fork()` – vytvoří kopii aktuálního procesu

```
pid_t n_pid = fork();
if (n_pid < 0) { /* chyba */ }
else if (n_pid == 0) { /* kod potomka */ }
else { /* kod rodice */ }
```

- používá se společně s voláním `exec` – nahraje do paměti kód ze souboru a začne jej provádět
- v rámci vztahu rodič-potomek jsou sdílené některé zdroje (např. popisovače souborů)
- sirotci – pokud rodičovský proces skončí dřív, přejde pod `init`
- zombie – proces již skončil, ale existuje v systému
- priorita – nice (40 hodnot)

# Implementační aspekty: UNIX (2/2)

- vlákna přidána do Unixů později (dříve i ve formě knihoven)
- $\Longrightarrow$ není zcela konzistentí s původní koncepcí
- Jak se má zachovat `fork()`?
- oddělené mechanismy pro synchronizaci vláken a procesů
- vlákno – běžná procedura s jedním argumentem vracející jednu hodnotu

```
void *foo(void *arg) {
    /* kod vlakna */
    return (void *)42;
}
pthread_t thr;
void * result;

pthread_create(&thr, NULL, foo, (void *)123);
/* kod provadeny hlavnim vlaknem */
pthread_join(thr, &result);
```

# Plánování procesů v Linuxu

- interně jádro pracuje s vlákny i procesy stejně
- proces/vlákno $\Longrightarrow$ task (účastní se plánování)
- systémové volání `clone` – zobecněný `fork` (umožňuje definovat, které struktury se mají sdílet)
  - paměťový prostor
  - otevřené soubory
  - I/O
  - id rodiče
  - ...
- stavy úloh: běžící, připravené k běhu, uspané-přerušitelné – čeká na nějakou podmínku, uspané-nepřerušitelné (čeká na nějakou kritickou HW operaci), zastavené, skončené (zombie)
- je možné vybrat typ plánovače – obecný, dávkové úlohy, FIFO nebo RR (pro práci v reálném čase)

# Plánování procesů v Linuxu

**Completely Fair Scheduler**

- varianta Guaranteed scheduleru
- tasky organizovány v RB-stromu (podle toho, kolik dostaly času)
- je zvolen ten, který získal nejméně času (tj. nejlevější list)
- priority řešeny pomocí koeficientů
- díky automatickému vyvažování má výběr tasku složitost $O(\log n)$.
- do verze 6.6

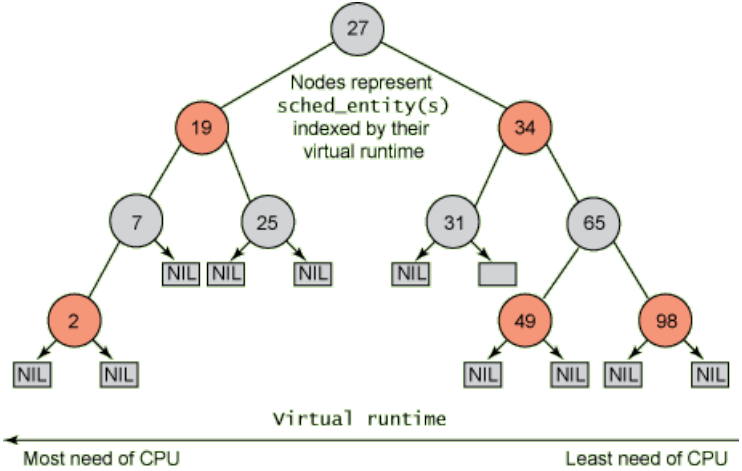
27
Nodes represent
sched_entity(s)
indexed by their
virtual runtime
19
34
7
25
31
65
NIL
NIL
NIL
NIL
NIL
2
49
98
NIL
NIL
NIL
NIL
NIL
NIL
Virtual runtime
Most need of CPU
Least need of CPU

# Earliest eligible virtual deadline first (EEVDF)

- od verze 6.6
- některé tasky nepotřebují moc procesorového času, ale potřebují jej co nejrychleji (vyžadují nízkou latenci); jiné procesy potřebují více času, ale není zase důležité, kdy jej dostanou)
- toto CFS neumí jednoduše podchytit
- EEVDF (poodobně jako CFS) se snaží jednotlivým taskům přiřadit odpovídající podíl procesorového času
- pro každý task je spočítán rozdíl mezi časem, který měl dostat a který dostal, tzv. *lag*
- pouze tasky, které mají nezáporný lag jsou označeny jako způsobilé (*eligible*) k běhu
- doba, kdy task bude způsobilý k běhu se označuje jako *eligible time*
- pro každý task je určena hodnota *virtual deadline* jako součet velikosti časového kvanta a eligible time
- je vybrán task s nejmenší hodnotou *virtual deadline*
- přirozeně řeší požadavky na latencí (jde nastavit pro každý task, jako `latency_nice` pomocí `shed_setattr`) a rovnoměrné dělení procesorového času

# Implementační aspekty: Windows (1/5)

- vlákno – základní jednotka vykonávající činnost (účastní se plánování)
- process – obsahuje jedno a více vláken (společné zdroje a paměť)
- job – slučuje několik procesů dohromady (společné správa, nastavení kvót, atd.)
- fiber – ,,odlehčené vlákna" implementované v kontextu vlákna (kooperativní multitasking)

**Vznik procesu**

- není vyžadován vztah rodič-potomek
- `CreateProcess` – funkce vytvařející nový proces (10+ argumentů); příprava ve spolupráci s daným subsystémem, více verzí jednoho programu v jednom souboru
- `CreateThread` – funkce vytvářející nové vlákno v principu podobná `pthread_create`

```
BOOL WINAPI CreateProcess(
    __in_opt     LPCTSTR lpApplicationName,
    __inout_opt  LPTSTR lpCommandLine,
    __in_opt     LPSECURITY_ATTRIBUTES lpProcessAttributes,
    __in_opt     LPSECURITY_ATTRIBUTES lpThreadAttributes,
    __in         BOOL bInheritHandles,
    __in         DWORD dwCreationFlags,
    __in_opt     LPVOID lpEnvironment,
    __in_opt     LPCTSTR lpCurrentDirectory,
    __in         LPSTARTUPINFO lpStartupInfo,
    __out        LPPROCESS_INFORMATION lpProcessInformation
);
HANDLE WINAPI CreateThread(
    __in_opt   LPSECURITY_ATTRIBUTES lpThreadAttributes,
    __in       SIZE_T dwStackSize,
    __in       LPTHREAD_START_ROUTINE lpStartAddress,
    __in_opt   LPVOID lpParameter,
    __in       DWORD dwCreationFlags,
    __out_opt  LPDWORD lpThreadId
);
```

# Implementační aspekty: Windows (2/5)

- plánování se účastní vlákna

**Stavy vláken**

- initiliazed – během inicializace vlákna
- ready – čekající na běh (z těchto vláken vybírá scheduler další pro běh)
- standby – vlákno připraveno k běhu na konkrétním CPU
  - přechod do running
  - přechod do ready (pokud vlákno s vyšší prioritou přeslo do režimu standby)
- running – vlákno běží; možné přechody
  - vlákno s vyšší prioritou získalo CPU (návrat do standby nebo ready)
  - po vypršení kvanta $\Longrightarrow$ ready
  - čekání na událost $\Longrightarrow$ waiting
  - ukončení vlákna
- waiting – čeká na nějakou událost; přechod do ready, standby či running (v případě úloh s vysokou prioritou)
- transition – zásobník je mimo fyzickou paměť (přechod do ready)
- terminated – vlákno je ukončeno (lze změnit na initialized)

# Implementační aspekty: Windows (3/5)

- pokud se objeví vlákno s vyšší prioritou ve stavu ready než má vlákno ve stavu running, dostane CPU; aktuálně běžící vlákno je přesunuto na začátek příslušné fronty

**Priority**

- priorita – hodnota 0–31 přiřazena vláknu (32 úrovňová fronta)
- třída priority – vlastnost procesu udávající základní prioritu vláken
  - Real-time (24)
  - High (13)
  - Above normal (10)
  - Normal (8)
  - Below normal (6)
- priority vláken – Time critical, highest, above normal, normal, below normal, lowest, idle
- priorita vlákna je dána relativně k prioritě procesu + další úpravy
- kategorie priorit
  - idle (0) – zero page thread
  - dynamické úrovně (1–15) – běžné procesy
  - real-time úrovně (16–31) – systémové procesy (nejedná se o realtime systém)

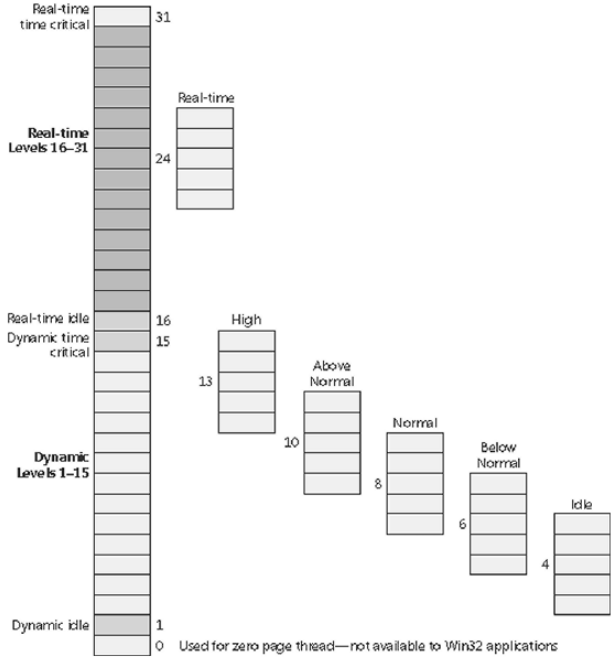
Real-time time critical
31
Real-time
Real-time Levels 16–31
24
Real-time idle
16
High
Dynamic time critical
15
13
Above Normal
10
Normal
Dynamic Levels 1–15
8
Below Normal
6
Idle
4
Dynamic idle
1
0
Used for zero page thread—not available to Win32 applications

# Implementační aspekty: Windows (4/5)

**Velikost kvanta**

- závisí na verzi OS
  - workstation – 6 jednotek (2 tiky přerušení časovače)
  - server – 36 jednotek (12 tiků)
- velikost jde měnit (v nastavení nebo dočasně)
- při čekání, přepnutí, atd. se velikost kvanta mírně snižuje
- proces na popředí – všechna jeho vlákna mají $3\times$ větší kvantum

**Dočasné zvýšení priority (Priority Boost)**

- u procesů s dynamickou úrovní
- po dokončení I/O zvýšena priorita o
  - $+1$ – disk, CD-ROM, grafická karta
  - $+2$ – síťová karta, ser. port
  - $+6$ – klávesnice, myš
  - $+8$ – zvuková karta
- po uplynutí kvanta se priorita snižuje o jedna až na základní hodnotu

# Implementační aspekty: Windows (5/5)

- po čekání na událost nebo synchronizaci s jiným vláknem
  - na dobu jednoho kvanta zvýšena priorita o 1
  - při synchronizaci – vlákno může získat prioritu o jedna vyšší než mělo vlákno, na které se čekalo
- vlákno na popředí po dokončení čekací operace $\Longrightarrow$ priorita $+2$
- aktivita v GUI $\Longrightarrow$ priorita $+4$
- vlákno už dlouho neběželo (řádově sekundy) $\Longrightarrow$ priorita 15 + 2x delší kvantum

# Víceprocesorové systémy

- symmetric multiprocessing (SMP) – dominantní řešení, sdílená paměť
- bootstrap processor – incializace systému
- další procesory aktivovány podle potřeby
- každý procesor vykonává zadaný proces/vlákno odděleně
- úlohy přepínány na základě přerušení
- typické řešení – každé jádro má množinu procesů/vláken, které zpracovává (má vlastní plánovač), v delších intervalech (stovky ms) je provedeno vyvážení úloh mezi procesory
- není žádoucí migrovat úlohy mezi jádry (lepší využití cache)
- možné nastavit affinitu (procesu/vlákna), aby využívalo konkrétní jádra
- situaci komplikují hybridní architektury (různě výkonná a úsporná jadra)