

Operační systémy a sítě

Petr Štěpán, K13133

KN-E-129

stepan@fel.cvut.cz

Téma 3. Procesy a vlákna

# Pojem „Výpočetní proces“

- Výpočetní proces (*job, task*) – spuštěný program
- Proces je identifikovatelný – jednoznačné číslo
  - PID – Process Identification Digit
- Stav procesu lze v každém okamžiku jeho existence jednoznačně určit
  - přidělené zdroje; události, na něž proces čeká; prioritu; ...
- Co tvoří proces:
  - Obsahy registrů procesoru (čítač instrukcí, ukazatel zásobníku, PSW, uživatelské registry, FPU registry)
  - Otevřené soubory
  - Použitá paměť:
    - Zásobník - .stack
    - Data - .data
    - Program - .text
- V systémech podporujících vlákna → bývá proces chápán jako obal či hostitel svých vláken

# Požadavky na OS při práci s procesy

- Umožňovat procesům **vytváření** a spouštění dalších procesů
- Prokládat - „paralelizovat“ vykonávání jednotlivých procesů s cílem maximálního využití procesoru/ů
- Minimalizovat dobu odpovědi procesu prokládáním běhů procesů
- Přidělovat procesům požadované systémové prostředky
  - Soubory, V/V zařízení, synchronizační prostředky
- Podporovat vzájemnou komunikaci mezi procesy
- Poskytovat aplikačním procesům funkčně bohaté, bezpečné a konzistentní rozhraní k systémovým službám
  - Systémová volání – minulá přednáška

# Vznik procesu

- Rodičovský proces vytváří procesy-potomky
  - pomocí služby OS. Potomci mohou vystupovat v roli rodičů a vytvářet další potomky, ...
  - Vzniká tak strom procesů
- Sdílení zdrojů mezi rodiči a potomky:
  - rodič a potomek mohou sdílet všechny zdroje původně vlastněné rodičem (obvyklá situace v POSIXu)
  - potomek může sdílet s rodičem podmnožinu zdrojů rodičem k tomu účelu vyčleněnou
  - potomek a rodič jsou plně samostatné procesy, nesdílí žádný zdroj
- Souběh mezi rodiči a potomky:
  - Možnost 1: rodič čeká na dokončení potomka
  - Možnost 2: rodič a potomek mohou běžet souběžně
- V POSIXu je každý proces potomkem jiného procesu
  - Výjimka: proces *init* vytvořen při spuštění systému
    - Spustí řadu *sh* skriptů (*rc*), ty inicializují celý systém a vytvoří démony (procesy běžící na pozadí bez úplného kontextu) ~ *service* ve Win32
    - *init* spustí pro terminály proces *getty*, který čeká na uživatele => *login* => uživatelův *shell*

# Příklad vytvoření procesu (POSIX)

- Rodič vytváří nový proces – potomka voláním služby **fork()**
- Vznikne identická kopie rodičovského procesu
  - potomek je úplným duplikátem rodiče
  - každý z obou procesů se při vytváření procesu dozvídá, zda je rodičem nebo potomkem
  - do adresního prostoru potomka se automaticky zavádí program shodný rodičem
- Potomek může využít volání služby **exec** pro nahradu programu ve svém adresním prostoru jiným programem
  - Pozn.: Program řídí vykonávání procesu ...

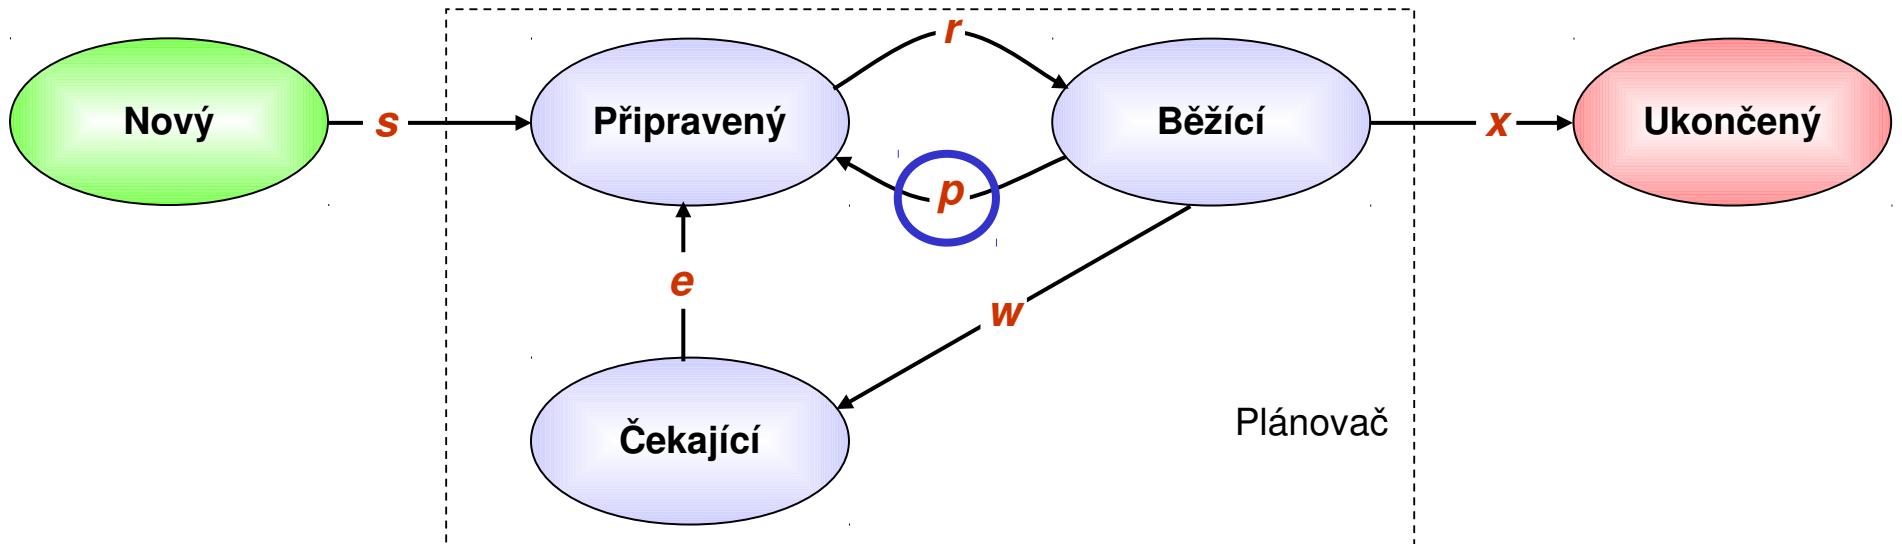
# Ukončení procesu

- Proces provede poslední příkaz programu a žádá OS o ukončení voláním služby **exit(status)**
  - Stavová data procesu-potomka (status) se mohou předat procesu-rodiči, který čeká v provádění služby **wait()**
  - Zdroje končícího procesu jádro uvolní
- Proces může skončit také:
  - přílišným nárokem na paměť (tolik paměti není a nebude nikdy k dispozici)
  - narušením ochrany paměti („zběhnutí“ programu)
  - pokusem o provedení nedovolené (privilegované) operace (zakázaný přístup k systémovému prostředku, r/o soubor)
  - aritmetickou chybou (dělení nulou, arcsin(2), ...) či neopravitelnou chybou V/V
  - žádostí rodičovského procesu (v POSIXu signál)
  - zánikem rodiče
    - Může tak docházet ke kaskádnímu ukončování procesů
    - V POSIXu lze proces „odpojit“ od rodiče – démon
  - a v mnoha dalších chybových situacích

## Stavy procesů

- Proces se za dobu své existence prochází více stavů a nachází se vždy v jednom z následujících stavů:
  - Nový (*new*) – proces je právě vytvářen, ještě není připraven na běh, ale již jsou připraveny některé části
  - Připravený (*ready*) – proces čeká na přidělení procesoru
  - Běžící (*running*) – instrukce procesu je právě vykonávány procesorem, tj. interpretovány některým procesorem
  - Čekající (*waiting, blocked*) – proces čeká na událost
  - Ukončený (*terminated*) – proces ukončil svoji činnost, avšak stále ještě vlastní některé systémové prostředky

# Základní (pětistavový) diagram procesů



## Přechod

**s** Proces vzniká – start

**r** Procesu je přidělen procesor (může pracovat) – run

**w** Proces žádá o službu, na jejíž dokončení musí čekat – wait

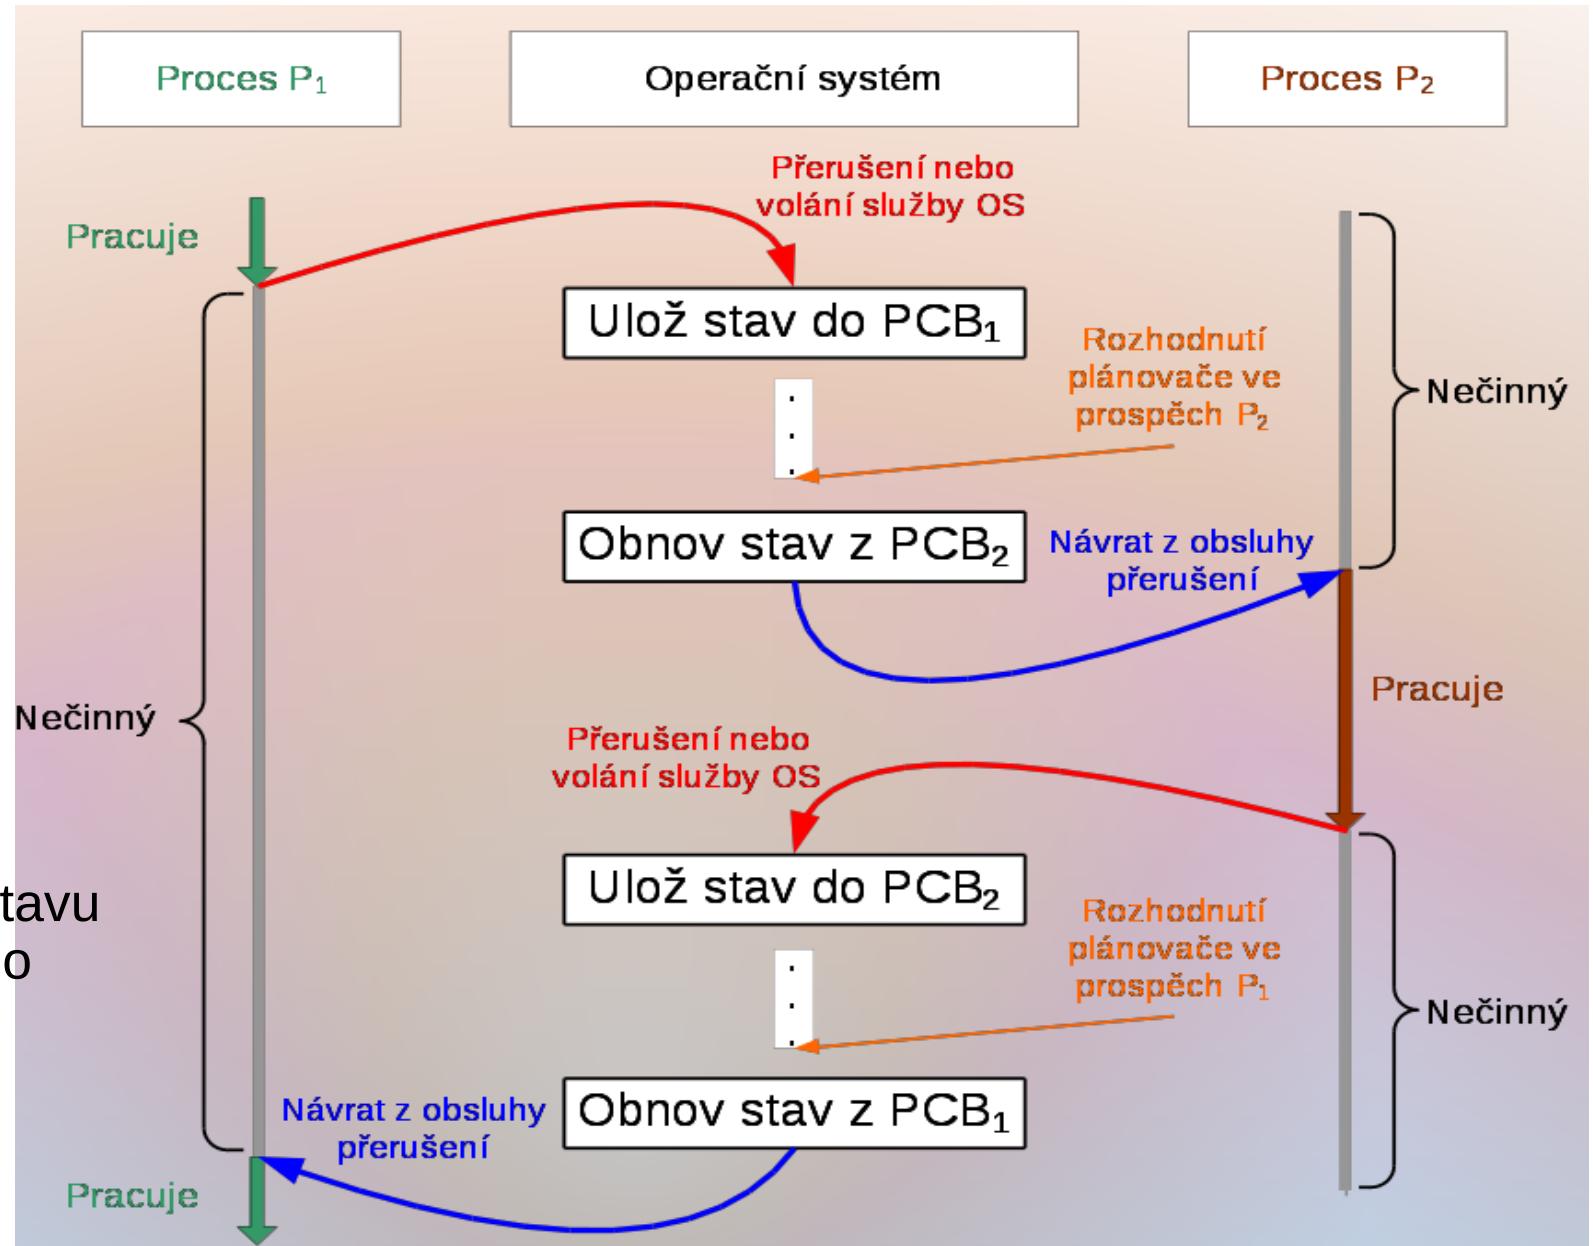
**e** Vznikla událost, která způsobila, že se proces „dočkal“ – event

**x** Skončila existence procesu (na žádost procesu nebo „násilně“) – exit

**p** Procesu byl odňat procesor, přestože je proces dále schopen běhu, tzv. **preempce** (např. vyčerpání časového kvanta) – preemption.

## Význam

# Přepínání mezi procesy – Context switch

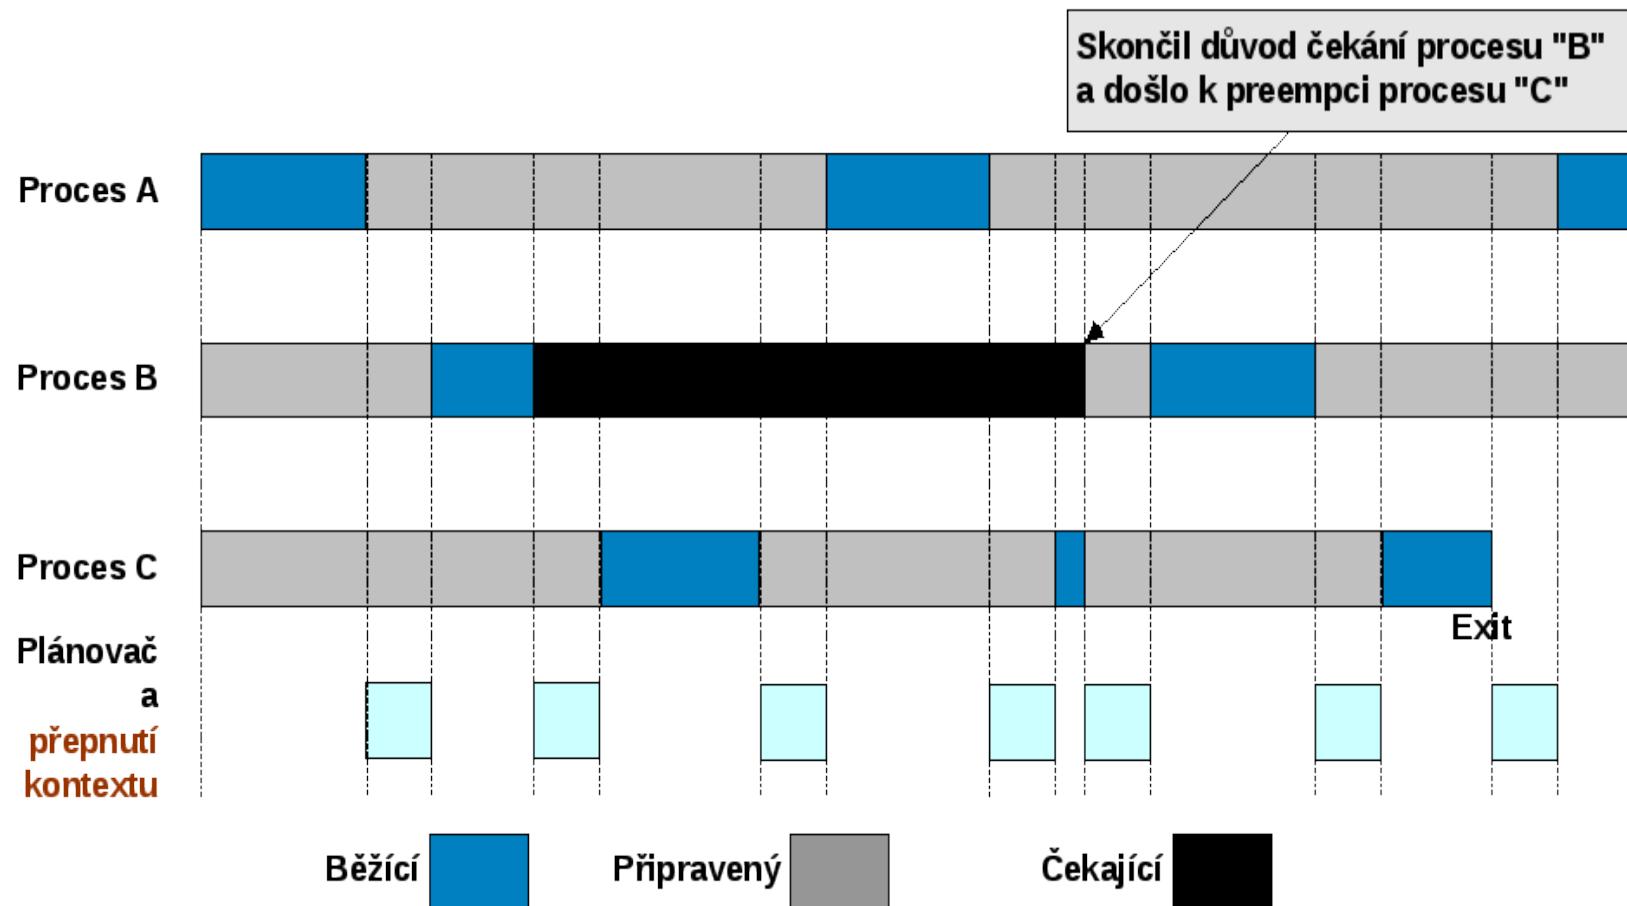


**Nečinný =**  
proces je ve stavu  
„čekající“ nebo  
„připravený“

# Přepnutí kontextu procesu

- Přechod od procesu  $A$  k  $B$  zahrnuje tzv. přepnutí kontextu
  - Přepnutí od jednoho procesu k jinému nastává výhradně v důsledku nějakého přerušení (či výjimky)
  - Proces  $A \rightarrow$  operační systém/přepnutí kontextu  $\rightarrow$  proces  $B$
  - Nejprve OS uchová (zapamatuje v  $PCB_A$ ) stav původně běžícího procesu  $A$
  - Provedou se potřebné akce v jádru OS a dojde k rozhodnutí ve prospěch procesu  $B$
  - Obnoví se stav „nově rozvíhaného“ procesu  $B$  (z  $PCB_B$ )
- Přepnutí kontextu představuje režijní ztrátu (zátěž)
  - během přepínání systém nedělá nic efektivního
  - časově nejnáročnější je správa paměti dotčených procesů
- Doba přepnutí závisí na hardwarové podpoře v procesoru
  - minimální hardwarová podpora při přerušení:
    - uchování čítače instrukcí
    - naplnění čítače instrukcí hodnotou z vektoru přerušení
  - lepší podpora:
    - ukládání a obnova více registrů procesoru jedinou instrukcí

# Stavy procesů v čase – preemptivní případ



Doby běhu plánovače by měly být co nejkratší

- režijní ztráty systému

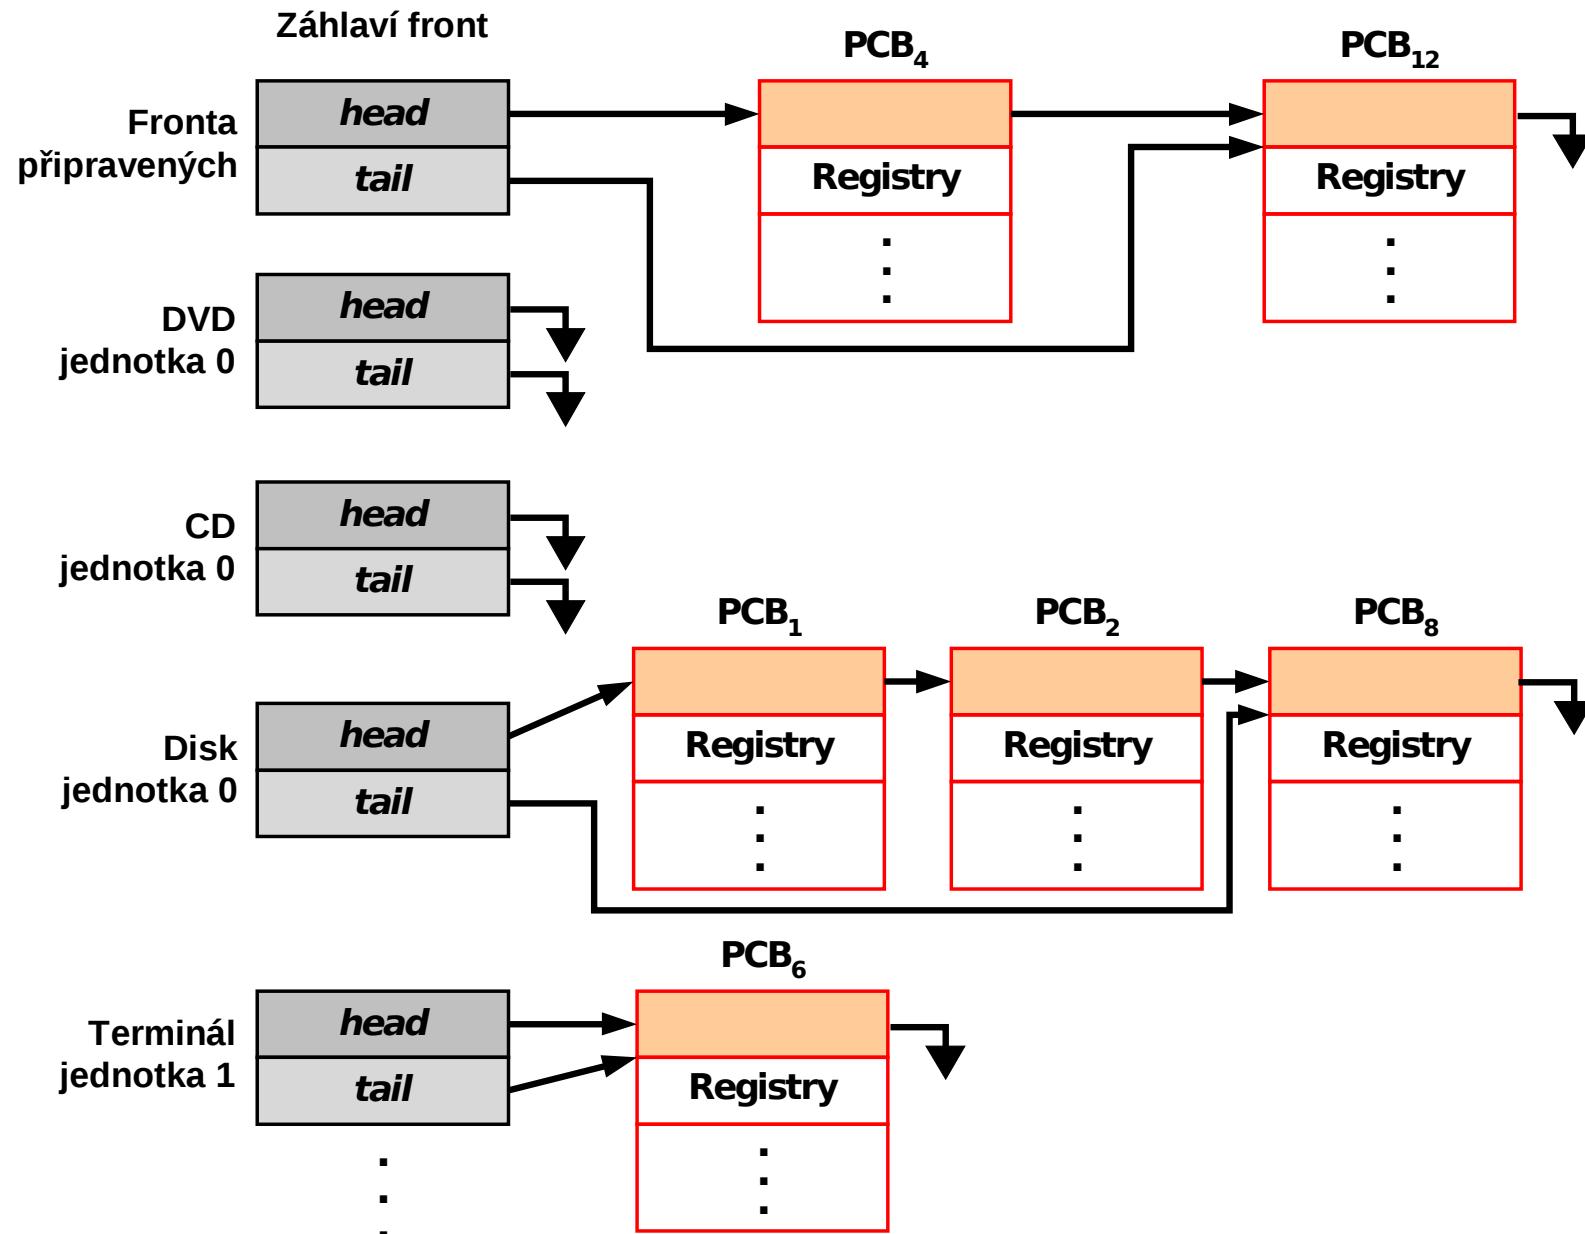
# Popis procesů

- Deskriptor procesu – *Process Control Block (PCB)*
  - Datová struktura obsahující
    - Identifikátor procesu (**pid**) a rodičovského procesu (**ppid**)
    - Globální **stav** (*process state*)
    - Místo pro uložení všech registrů procesoru
    - Informace potřebné pro plánování procesoru/ů
      - Priorita, historie využití CPU, ... →
    - Informace potřebné pro správu paměti
      - Odkazy do paměti (*memory pointers*), popř. registry MMU
    - Účtovací informace (*accounting*)
    - Stavové informace o V/V (*I/O status*)
    - Kontextová data (*context data*)
      - Otevřené soubory
      - Proměnné prostředí (*environment variables*)
    - ...
    - Ukazatelé pro řazení PCB do front a seznamů

# Fronty a seznamy procesů pro plánování

- Fronta připravených procesů
  - množina procesů připravených k běhu čekajících pouze na přidělení procesoru
- Fronta na dokončení I/O operace
  - samostatná fronta pro každé zařízení
- Seznam odložených procesů
  - množina procesů čekajících na přidělení místa v hlavní paměti, FAP
- Fronty související se synchronizací procesů
  - množiny procesů čekajících synchronizační události
- Fronta na přidělení prostoru v paměti
  - množina procesů potřebujících zvětšit svůj adresní prostor
- ...
- Procesy mezi různými frontami migrují

# Fronty a seznamy procesů – příklad



# Program, proces a vlákno

- Program (z pohledu jádra OS):
  - soubor přesně definovaného formátu obsahující
    - instrukce,
    - data
    - údaje potřebné k zavedení do paměti a inicializaci procesu
- Proces:
  - systémový objekt – entita realizující výpočet podle programu charakterizovaná svým paměťovým prostorem a kontextem
  - prostor ve FAP se přiděluje procesům (nikoli programům!)
  - patří mu i případný obraz jeho adresního prostoru (nebo jeho části) na vnější paměti
  - může vlastnit soubory, I/O zařízení a komunikační kanály vedené k jiným procesům
- Vlákno:
  - objekt vytvářený programem v rámci procesu

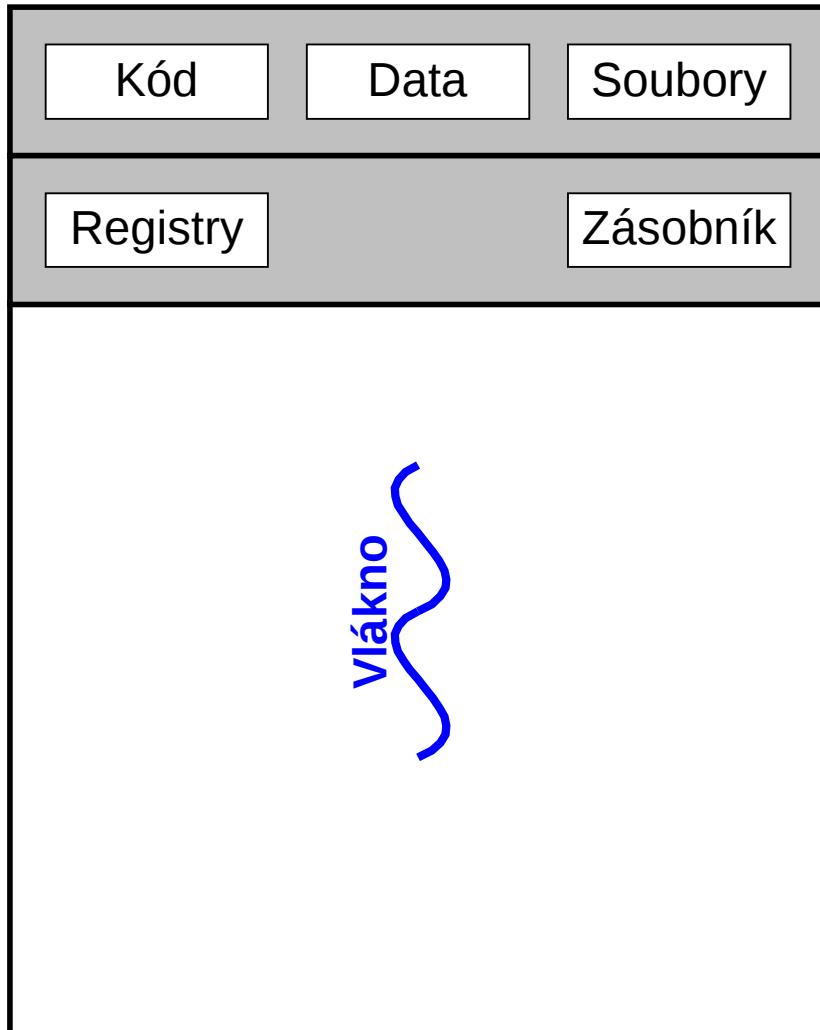
# Vztah procesu a vlákna

- **Vlákno (thread)**
  - Objekt vytvářený v rámci procesu a viditelný uvnitř procesu
  - Tradiční proces je proces tvořený jediným vlákнем
  - **Vlákna podléhají plánování** a přiděluje se jim strojový čas i procesory
  - Vlákno se nachází ve stavech: **běží, připravené, čekající, ...**
    - Podobně jako při přidělování času procesům
  - Když vlákno neběží, je kontext vlákna uložený v **TCB** (*Thread Control Block*):
    - analogie PCB
    - prováděcí zásobník vlákna, obraz PC, obraz registrů, ...
  - Vlákno může přistupovat k LAP a k ostatním zdrojům svého procesu a ty **jsou sdíleny** všemi vlákny tohoto procesu
    - Změnu obsahu některé buňky LAP procesu vidí všechna ostatní vlákna téhož procesu
    - Soubor otevřený jedním vláknom je viditelný pro všechna ostatní vlákna téhož procesu
    - Vlákna patřící k jednomu procesu sdílí proměnné a systémové zdroje přidělené tomuto procesu

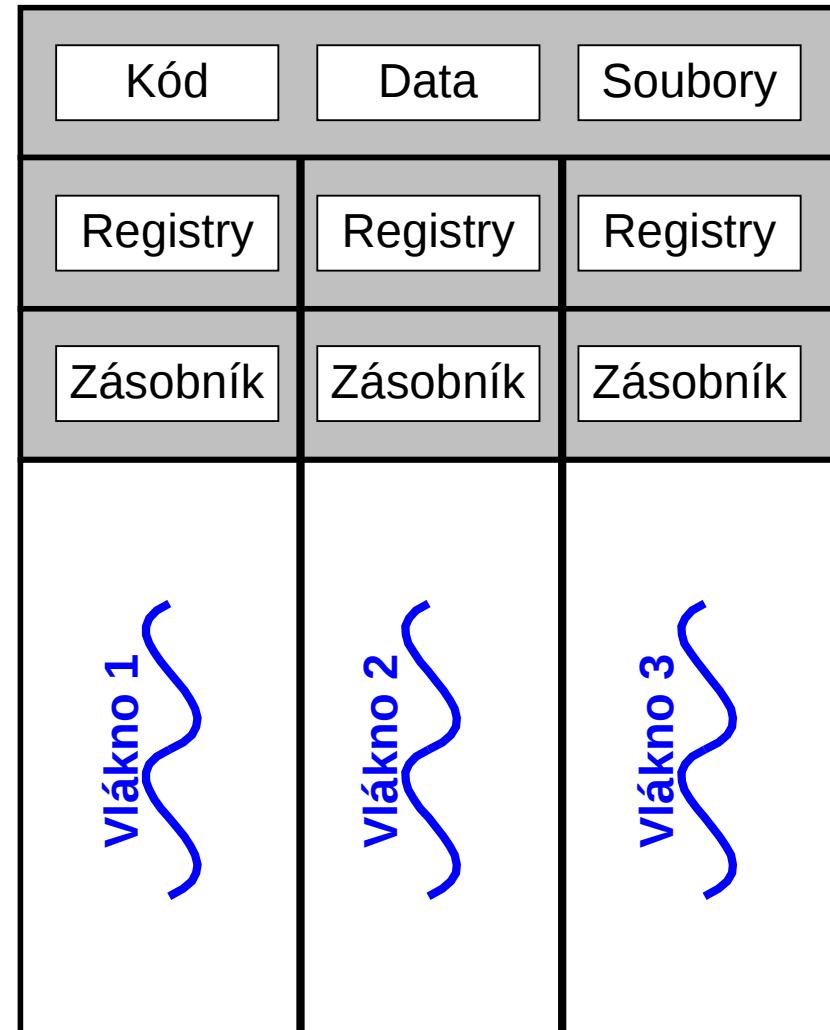
# Proces a jeho vlákna

- Jednovláknové (tradiční) procesy
  - proces: jednotka plánování činnosti a jednotka vlastnící přidělené prostředky
  - každé vlákno je současně procesem s vlastním adresovým prostorem a s vlastními prostředky
  - tradiční UNIXy
    - moderní implementace UNIXů jsou již většinou vláknově orientované
- Procesy a vlákna (Windows, Solaris, ...)
  - proces: jednotka vlastnící prostředky
  - vlákno: jednotka plánování činnosti systému
  - v rámci jednoho procesu lze vytvořit více vláken
  - proces definuje adresový prostor a dynamicky vlastní prostředky

# Procesy a vlákna

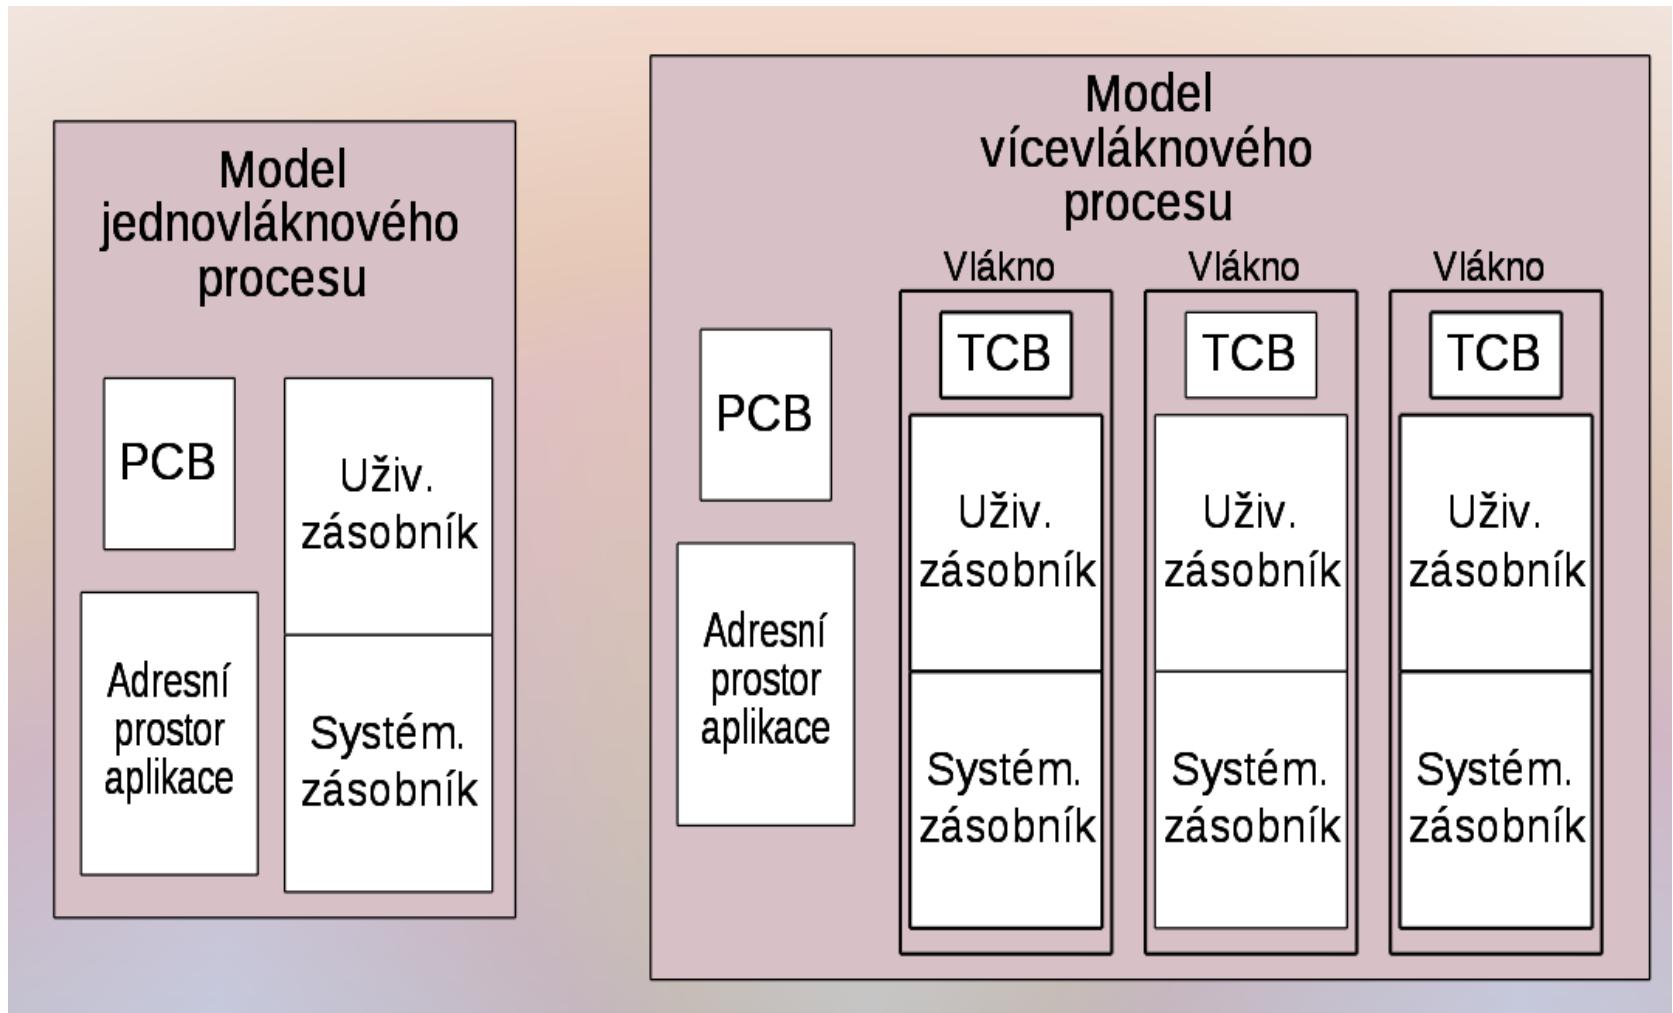


Jednovláknový proces



Vícevláknový proces

# Procesy a vlákna – řídicí struktury



# Procesy, vlákna a jejich komponenty

## Co patří procesu a co vláknu?

kód programu:	počítač
lokální a pracovní data:	vlákno
globální data:	proces
alokované systémové zdroje:	proces
zásobník:	vlákno
data pro správu paměti:	proces
čítač instrukcí:	vlákno
registry procesoru:	vlákno
plánovací stav:	vlákno
uživatelská práva a identifikace:	proces

# Účel vláken

- Přednosti
  - Vlákno se vytvoří i ukončí rychleji než proces
  - Přepínání mezi vlákny je rychlejší než mezi procesy
  - Dosáhne se lepší strukturalizace programu
- Příklady
  - Souborový server v LAN
    - Musí vyřizovat během krátké doby několik požadavků na soubory
    - Pro vyřízení každého požadavku se zřídí samostatné vlákno
  - Symetrický multiprocesor
    - na různých procesorech mohou běžet vlákna souběžně
  - Menu vypisované souběžně se zpracováním prováděným jiným vláknem
  - Překreslování obrazovky souběžně se zpracováním dat
  - Paralelizace algoritmu v multiprocesoru
- Lepší a přehlednější strukturalizace programu

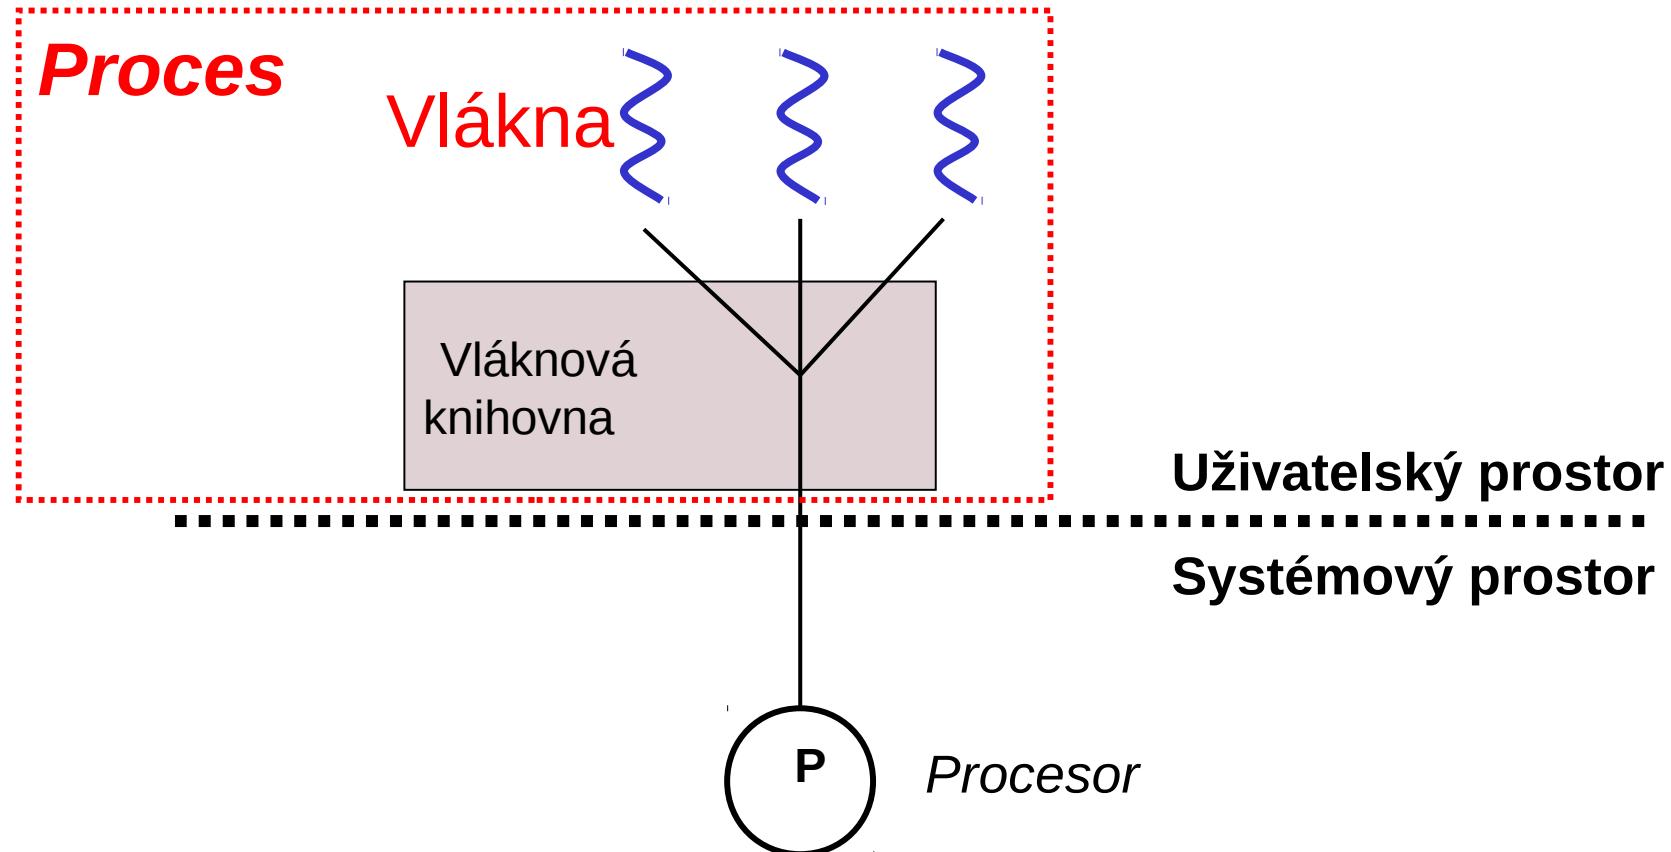
## Stavy a odkládání vláken

- Vlákna podléhají plánování a mají své stavy podobně jako procesy
- Základní stavy
  - běžící
  - připravené
  - čekající
- Všechna vlákna jednoho procesu sdílejí společný adresní prostor
  - => vlákna se samostatně neodkládají, odkládá je jen proces
- Ukončení (havárie) procesu ukončuje všechna vlákna existující v tomto procesu

# Vlákna na uživatelské úrovni, ULT (1)

- *User-Level Threads (ULT)*
- **Vlastnosti**
  - Správu vláken provádí tzv. **vláknová knihovna** (*thread library*) na úrovni aplikačního procesu, JOS o jejich existenci neví
  - Přepojování mezi vlákny nepožaduje provádění funkcí jádra
  - Nepřepíná se ani kontext procesu ani režim procesoru
  - Aplikace má možnost zvolit si nejvhodnější strategii a algoritmus pro plánování vláken
  - Lze používat i v OS, který neobsahuje žádnou podporu vláken v jádře, stačí speciální knihovna (model 1 :  $M$ )
- **Vláknová knihovna obsahuje funkce pro**
  - vytváření a rušení vláken
  - předávání zpráv a dat mezi vlákny
  - plánování běhů vláken
  - uchovávání a obnova kontextů vláken

# Vlákna na uživatelské úrovni, ULT (2)



## Vlákna na uživatelské úrovni, ULT (3)

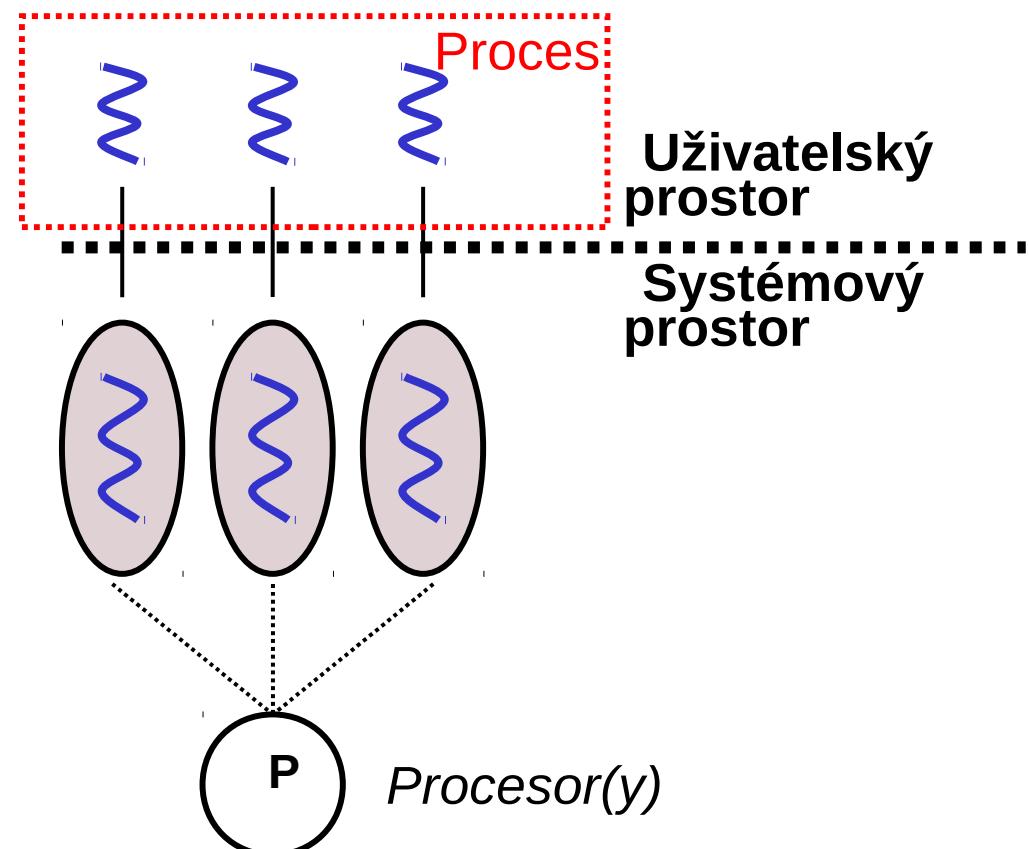
- Problém stavu vláken: Co když se proces nebo vlákno zablokuje?
  - Nechť proces  $A$  má dvě vlákna  $T_1$  a  $T_2$ , přičemž  $T_1$  právě běží
  - Mohou nastat následující situace:
    - $T_1$  požádá JOS o I/O operaci nebo jinou službu:
      - Jádro zablokuje proces  $A$  jako celek.
      - Celý proces čeká, přestože by mohlo běžet vlákno  $T_2$ .
    - Proces  $A$  vyčerpá časové kvantum:
      - JOS přeřadí proces  $A$  mezi připravené
      - TCB<sub>1</sub> však indikuje, že  $T_1$  je stále ve stavu „běžící“ (ve skutečnosti *neběží!*)
    - $T_1$  potřebuje akci realizovanou vláknem  $T_2$ :
      - Vlákno  $T_1$  se zablokuje. Vlákno  $T_2$  se rozběhne
      - Proces  $A$  zůstane ve stavu „běžící“ (což je správně)
  - Závěr
    - V ULT nelze stav vláken věrohodně sledovat

# Výhody a nevýhody uživatelských vláken

- Výhody:
  - Rychlé přepínání mezi vlákny (bez účasti JOS)
  - Rychlá tvorba a zánik vláken
  - Uživatelský proces má plnou kontrolu nad vlákny
    - např. může za běhu zadávat priority či volit plánovací algoritmus
- Nevýhody:
  - Volání systémové služby jedním vláknem zablokuje všechna vlákna procesu
  - Dodatečná práce programátora pro řízení vláken
    - Lze však ponechat knihovnou definovaný implicitní algoritmus plánování vláken
  - Jádro o vláknech „nic neví“, a tudíž přiděluje procesor pouze procesům, Dvě vlákna téhož procesu nemohou běžet současně, i když je k dispozici více procesorů

# Vlákna na úrovni jádra, KLT

- *Kernel-Level Threads (KLT)*
- Veškerá správa vláken je realizována OS
- Každé vlákno v uživatelském prostoru je zobrazeno na vlákno v jádře (model 1:1)
- JOS vytváří, plánuje a ruší vlákna
- Jádro může plánovat vlákna na různé CPU
  - Skutečný multiprocessing
- Příklady
  - Windows NT/2000/XP
  - Linuxy
  - 4.4BSD UNIXy
  - Tru64 UNIX
  - ... všechny moderní OS



# Výhody a nevýhody KLT

- Výhody:
  - Volání systému neblokuje ostatní vlákna téhož procesu
  - **Jeden proces může využít více procesorů**
    - skutečný paralelismus uvnitř jednoho procesu – každé vlákno běží na jiném procesoru
  - Tvorba, rušení a přepínání mezi vlákny je levnější než přepínání mezi procesy
    - netřeba dělat cokoliv s přidělenou pamětí
  - I moduly jádra mohou mít vícevláknový charakter
- Nevýhody:
  - Systémová správa je režijně **nákladnější** než u čistě uživatelských vláken
  - Klasické plánování **není "spravedlivé"**: Dostává-li vlákno své časové kvantum( $\rightarrow$ ), pak procesy s více vlákny dostávají více času

# Knihovna Pthreads

- Pthreads je POSIX-ový standard definující API pro vytváření a synchronizaci vláken a specifikace chování těchto vláken
- Knihovna Pthreads poskytuje unifikované API:
  - Nepodporuje-li JOS vlákna, knihovna Pthreads bude pracovat čistě s ULT
  - Implementuje-li příslušné jádro KLT, pak toho knihovna Pthreads bude využívat
  - Pthreads je tedy systémově závislá knihovna
- **Příklad:** Samostatné vlákno, které počítá součet prvních  $n$  celých čísel

# Příklad volání API Pthreads

**Příklad:** Samostatné vlákno, které počítá součet prvních  $n$  celých čísel;  $n$  se zadává jako parametr programu na příkazové řádce

```
#include <pthread.h>
#include <stdio.h>

int sum;                                /* sdílená data */
void *runner(void *param);                /* rutina realizující vlákno */

main(int argc, char *argv[]) {
    pthread_t tid;                      /* identifikátor vlákna*/
    pthread_attr_t attr;                 /* atributy vlákna */
    pthread_attr_init(&attr);           /* inicializuj implicitní atributy */
    pthread_create(&tid, &attr, runner, argv[1]); /* vytvoř vlákno */
    pthread_join(tid,NULL);             /* čekej až vlákno skončí */
    printf("sum = %d\n",sum);
}

void *runner(void *param) {
    int upper = atoi(param); int i; sum = 0;
    if (upper > 0) {
        for (i = 1; i <= upper; i++)
            sum += i;
    }
    pthread_exit(0);
}
```

# Vlákna ve Windows 2000/XP/7

- Aplikace ve Windows běží jako proces tvořený jedním nebo více vlákny
- Windows implementují mapování 1:1
- Někteří autoři dokonce tvrdí, že *Proces se nemůže vykonávat, neboť je jen kontejnerem pro vlákna a jen ta jsou schopná běhu*
- Každé vlákno má
  - svůj identifikátor vlákna
  - sadu registrů (obsah je ukládán v TCM)
  - samostatný uživatelský a systémový zásobník
  - **privátní datovou oblast**

# Vlákna v Linuxu a Javě

- **Vlákna Linux:**
  - Linux nazývá vlákna *tasks*
  - Lze použít knihovnu *pthreads*
  - Vytváření vláken je realizováno službou OS **clone()**
  - **clone()** umožňuje vláknu (task) sdílet adresní prostor s rodičem
    - **fork()** vytvoří zcela samostatný proces s kopíí prostoru rodičovského procesu
    - **clone()** vytvoří vlákno, které dostane odkaz (pointer) na adresní prostor rodiče
- **Vlákna v Javě:**
  - Java má třídu „Thread“ a instancí je vlákno
    - Samozřejmě lze z třídy Thread odvodit podtřídu a některé metody přepsat
  - Vlákna jsou spravována přímo JVM
    - JVM spolu se základními Java třídami vlastně vytváří virtuální stroj obsahující jak „hardware“ (vlastní JVM) tak i na něm běžící OS podporující vlákna
    - Většinou jsou vlákna JVM mapována 1:1 na vlákna OS

# Vytvoření vlákna v Java API

```
class CounterThread extends Thread {  
  
    public void run() {  
  
        for(int i = 0; i < 10; i++) {  
  
            System.out.println(i);  
  
        }  
  
    }  
  
}  
  
Thread counterThread = new  
CounterThread();  
  
counterThread.start();
```

```
class Counter implements Runnable {  
  
    public void run() {  
  
        for(int i = 0; i < 10; i++) {  
  
            System.out.println(i);  
  
        }  
  
    }  
  
}  
  
Runnable counter = new Counter();  
  
Thread counterThread = new  
Thread(counter);  
  
counterThread.start();
```

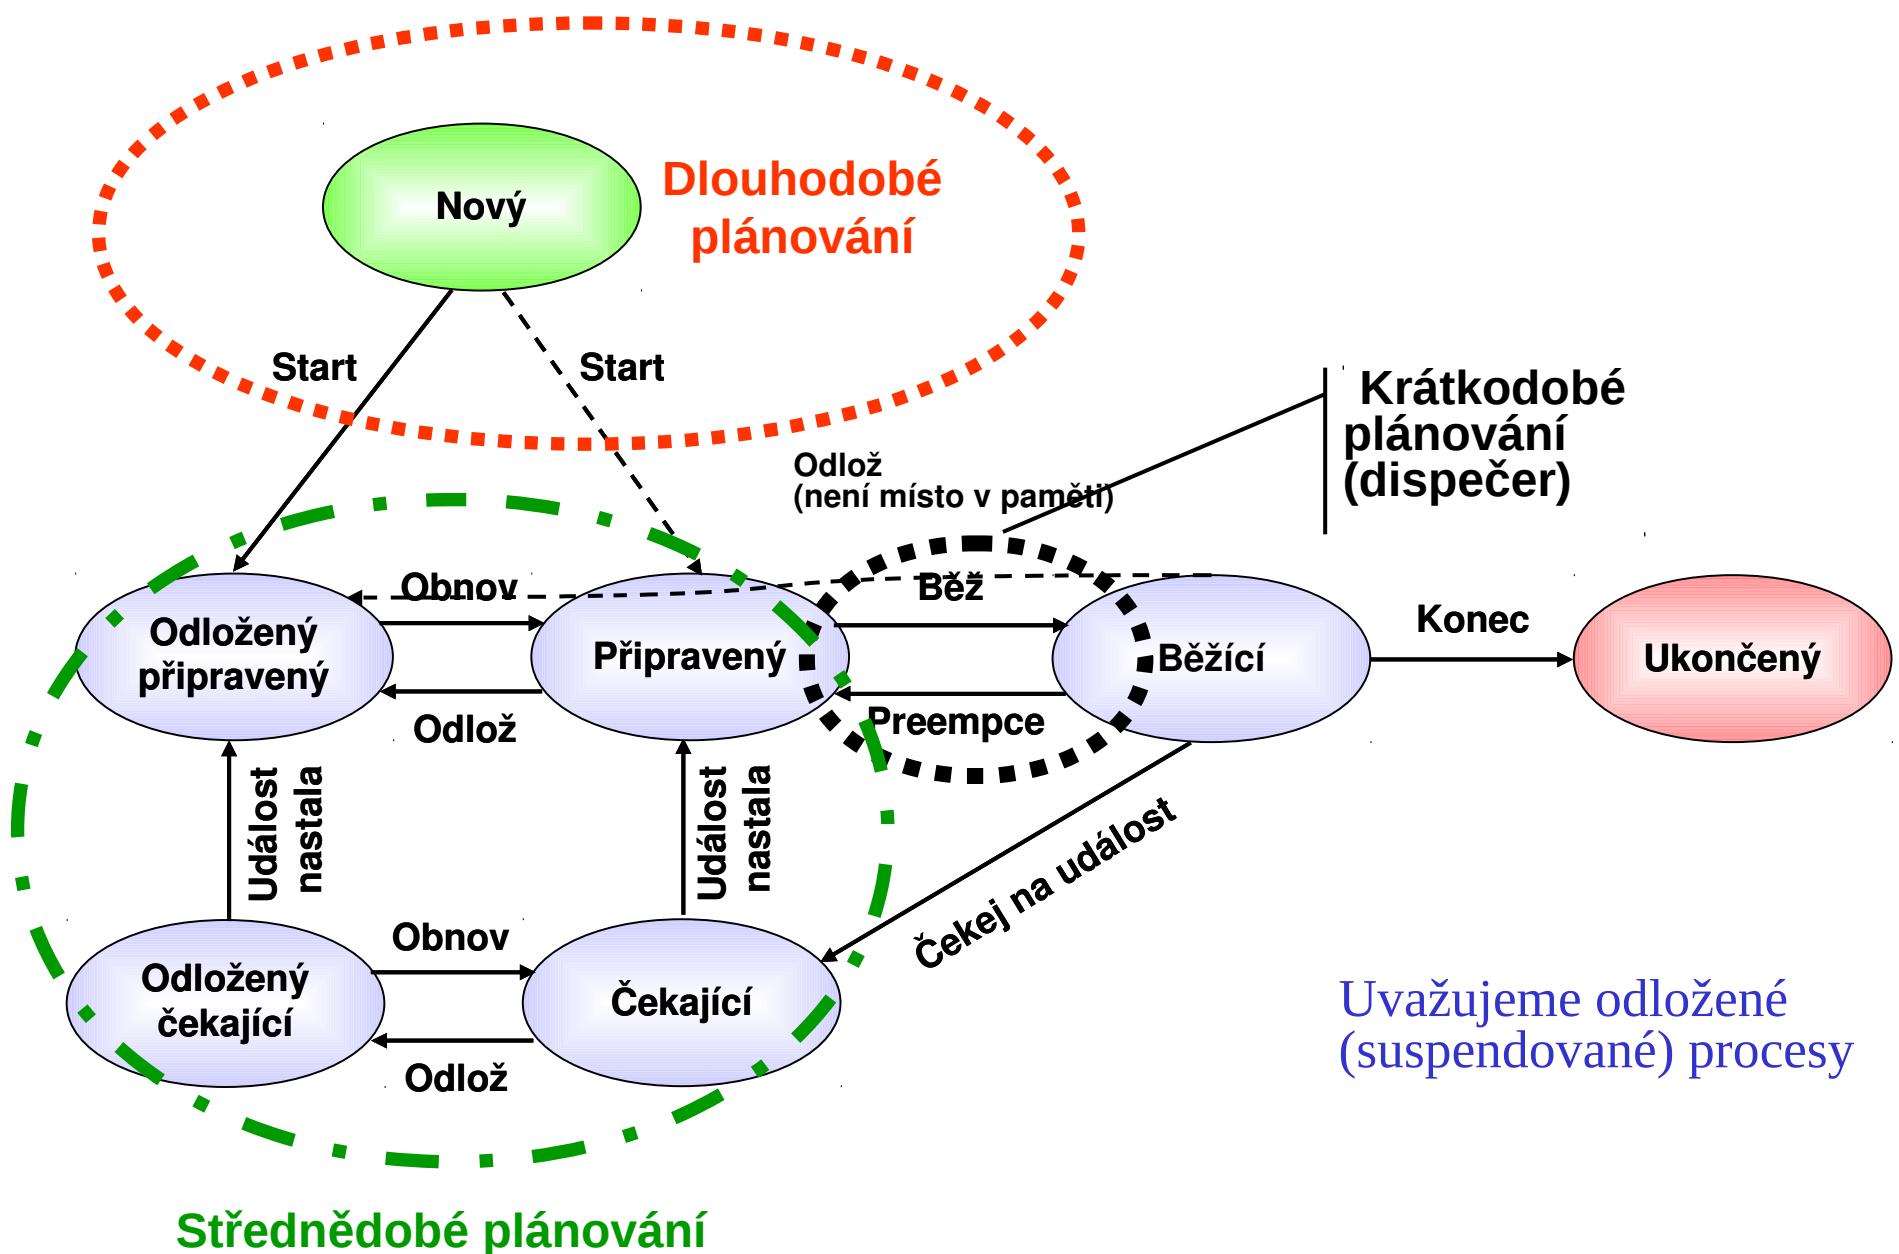
# Plánovače v OS

- Krátkodobý plánovač (operační plánovač, dispečer):
  - Základní správa procesoru/ů
  - Vybírá proces, který poběží na uvolněném procesoru přiděluje procesu procesor (CPU)
  - vyvoláván velmi často, musí být extrémně rychlý
- Střednědobý plánovač (taktický plánovač)
  - Úzce spolupracuje se správou hlavní paměti
  - Taktika využívání omezené kapacity FAP při multitaskingu
  - Vybírá, který proces je možno zařadit mezi odložené procesy →
    - uvolní tím prostor zabíraný procesem ve FAP
  - Vybírá, kterému odloženému procesu lze znova přidělit prostor ve FAP
- Dlouhodobý plánovač (strategický plánovač, *job scheduler*)
  - Vybírá, který požadavek na výpočet lze zařadit mezi procesy, a definuje tak stupeň multiprogramování
  - Je volán zřídka (jednotky až desítky sekund), nemusí být rychlý
    - V interaktivních systémech (typu Windows) se prakticky nepoužívá a degeneruje na přímé předání práce krátkodobému plánovači

# Středně dobý plánovač - *swapping*

- Běžící proces musí mít alespoň pro aktuální části svého LAP přidělen prostor ve FAP
  - jinak by nemohl pracovat
- I když se používá princip virtuální paměti
  - příliš mnoho procesů ve FAP (alespoň částečně) snižuje výkonnost systému
    - jednotlivé procesy obdrží malý prostor ve FAP a aktuální úsek LAP ve FAP se jim vyměňuje příliš často (problém „výprasku“ →)
- OS musí paměťový prostor některých procesů odložit
  - takové procesy nemohou běžet
  - **odložení** – swap-out, okopírování na disk
  - **obnova** – swap-in, zavedení do FAP
- Přibývají tak další dva stavy procesů
  - **odložený čekající** – čeká na nějakou událost a, i kdyby byl v paměti, stejně by nebyl schopen běhu
  - **odložený připravený** – nechybí mu nic kromě místa v paměti

# Sedmistavový diagram procesů



# Plánovač CPU (dispečer) a typy plánování

- Dispečer pracuje s procesy, které jsou v hlavní paměti a jsou schopné běhu, tj. **připravené** (*ready*)
- Existují 2 typy plánování
  - **nepreemptivní plánování** (plánování **bez předbíhání**, někdy také **kooperativní plánování**), kdy procesu schopnému dalšího běhu procesor není „násilně“ odnímán
    - Používá se zpravidla jen v „uzavřených systémech“, kde jsou předem známy všechny procesy a jejich vlastnosti. Navíc musí být naprogramovány tak, aby samy uvolňovaly procesor ve prospěch procesů ostatních
  - **preemptivní plánování** (plánování **s předbíháním**), kdy procesu schopnému dalšího běhu může být procesor odňat i „bez jeho souhlasu“ (tedy kdykoliv)
- Plánovač **rozhoduje** (vstupuje do hry) v okamžiku, kdy některý proces:
  1. přechází ze stavu běžící do stavu čekající nebo končí
  2. přechází ze stavu čekající do stavu připravený
  3. přechází ze stavu běžící do stavu připravený
- První dva případy se vyskytují v obou typech plánování
- Poslední je charakteristický pro plánování preemptivní

# Kriteria krátkodobého plánování

- Uživatelsky orientovaná
  - čas odezvy
    - doba od vzniku požadavku do reakce na něj
  - doba obrátky
    - doba od vzniku procesu do jeho dokončení
  - konečná lhůta (*deadline*)
    - požadavek dodržení stanoveného času dokončení
  - předvídatelnost
    - Úloha by měla být dokončena za zhruba stejnou dobu bez ohledu na celkovou zátěž systému
    - Je-li systém vytížen, prodloužení odezvy by mělo být rovnoměrně rozděleno mezi procesy
- Systémově orientovaná
  - průchodnost
    - počet procesů dokončených za jednotku času
  - využití procesoru
    - relativní čas procesoru věnovaný aplikačním procesům
  - spravedlivost
    - každý proces by měl dostat svůj čas (ne „hladovění“ či „stárnutí“)
  - vyvažování zátěže systémových prostředků
    - systémové prostředky (periferie, hlavní paměť) by měly být zatěžovány v čase rovnoměrně

# Plánovací algoritmy

- Ukážeme plánování:
  - FCFS                            (*First-Come First-Served*)
  - SPN (SJF)                    (*Shortest Process Next*)
  - SRT                            (*Shortest Remaining Time*)
  - cyklické                      (*Round-Robin*)
  - zpětnovazební                (*Feedback*)

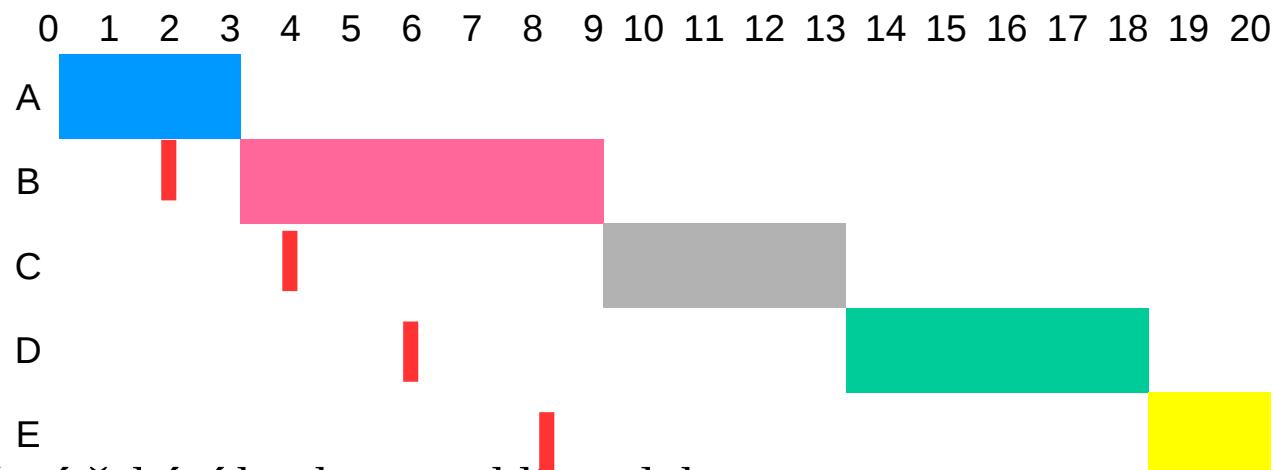
- Příklad
  - používaný v tomto textu pro ilustraci algoritmů

Proces	Čas příchodu	Potřebný čas (délka CPU dávky)
A	0	3
B	2	6
C	4	4
D	6	5
E	8	2

- Chování se ilustruje tzv. Ganttovými diagramy

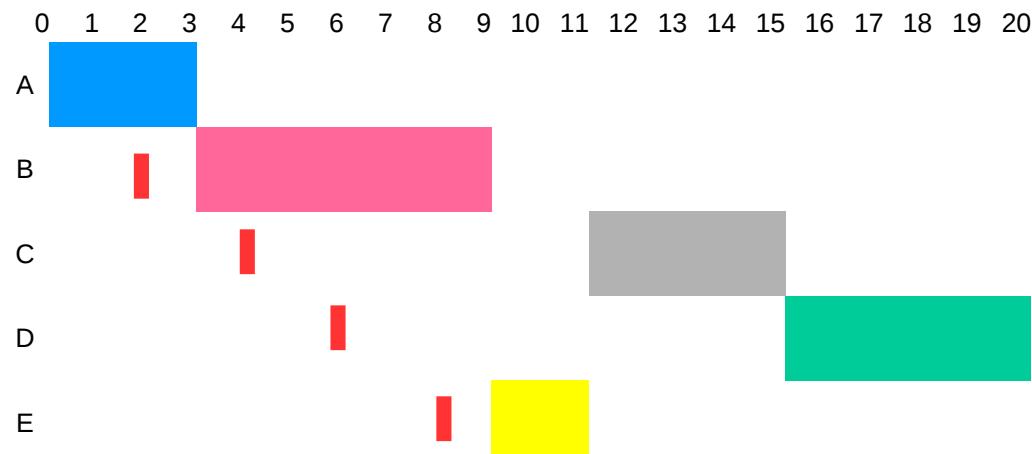
# Plánování FCFS

- FCFS = *First Come First Served* – prostá fronta FIFO
- Nejjednodušší nepreemptivní plánování
- Nově příchozí proces se zařadí na konec fronty
- Průměrné čekání může být velmi dlouhé  ${}^wT_{Avg} = \frac{0+1+5+7+10}{5} = 4,6$
- Příklad:



- Průměrné čekání bychom mohli zredukovat:
  - Např. v čase 9 je procesor volný a máme na výběr procesy C, D a E

$${}^wT_{Avg} = \frac{0+1+7+9+1}{5} = 3,6$$

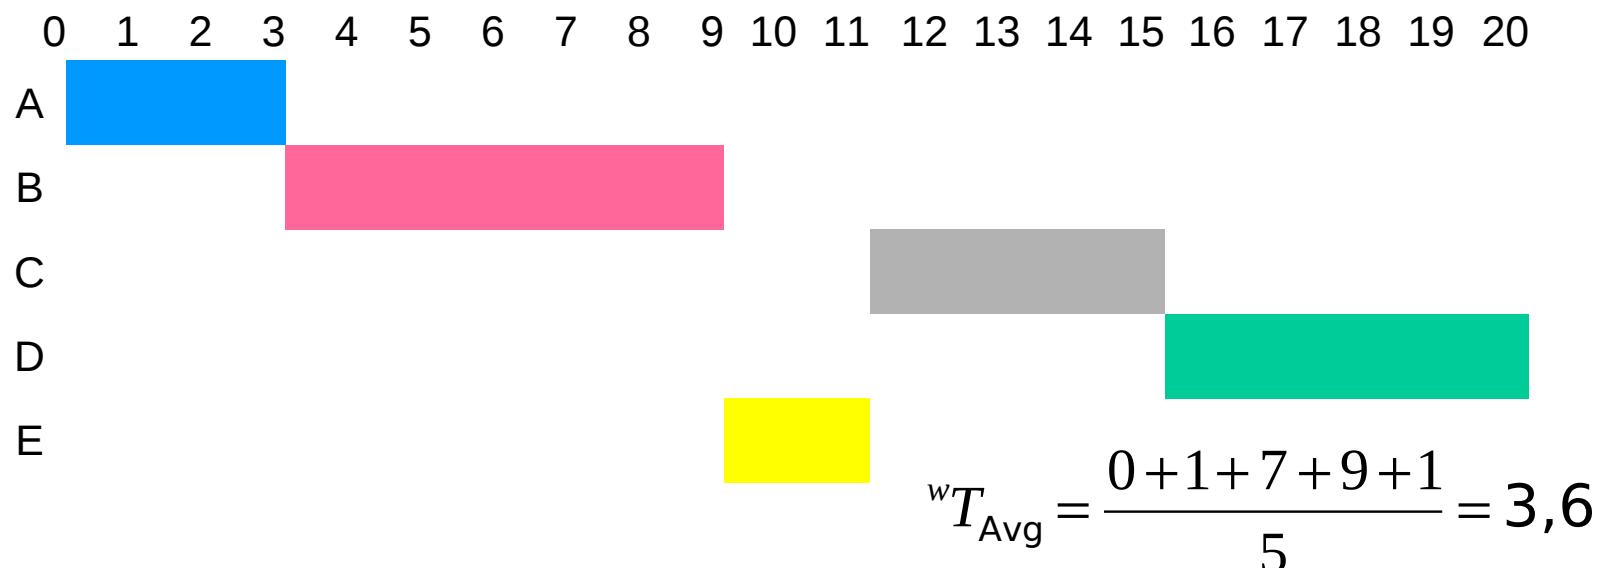


## Vlastnosti FCFS

- FCFS je primitivní nepreemptivní plánovací postup
- Průměrná doba čekání  ${}^W T_{Avg}$  silně závisí na pořadí přicházejících dávek
- Krátké procesy, které se připravily po dlouhém procesu, vytváří tzv. **konvojový efekt**
  - Všechny procesy čekají, až skončí dlouhý proces
- Pro krátkodobé plánování se FCFS samostatně fakticky nepoužívá.
  - Používá se pouze jako složka složitějších plánovacích postupů

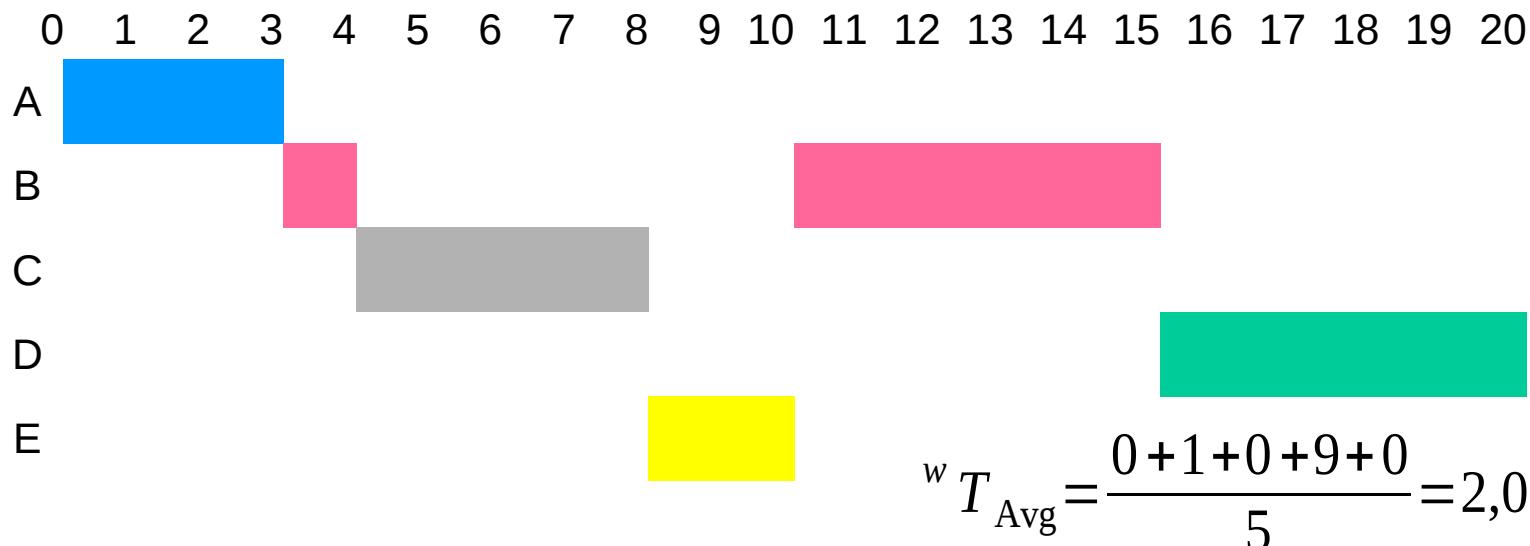
## Plánování SPN

- SPN = *Shortest Process Next* (nejkratší proces jako příští); též nazýváno SJF = *Shortest Job First*
  - Opět nepreemptivní
  - Vybírá se připravený proces s nejkratší příští dávkou CPU
  - Krátké procesy předbíhají delší, nebezpečí stárnutí dlouhých procesů
  - Je-li kritériem kvality plánování **průměrná doba čekání**, je SPN **optimálním** algoritmem, což se dá exaktně dokázat
- Příklad:



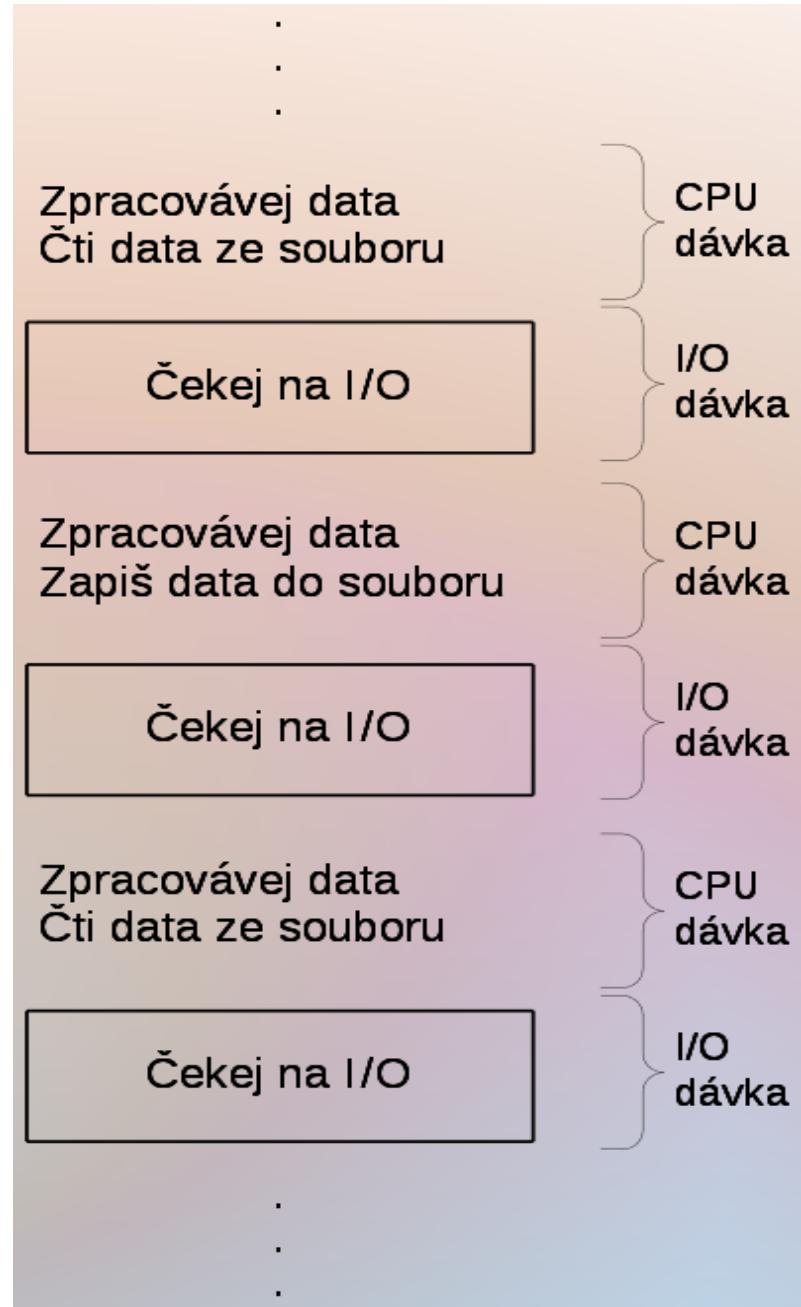
## Plánování SRT

- SRT = *Shortest Remaining Time* (nejkratší zbývající čas)
  - Preemptivní varianta SPN
  - CPU dostane proces, který potřebuje nejméně času do svého ukončení
  - Jestliže existuje proces, kterému zbývá k jeho dokončení čas kratší, než je čas zbývající do skončení procesu běžícího, dojde k preemci
    - Může existovat procesů se stejným zbývajícím časem, a pak je nutno použít jakési „arbitrážní pravidlo“
- Příklad:

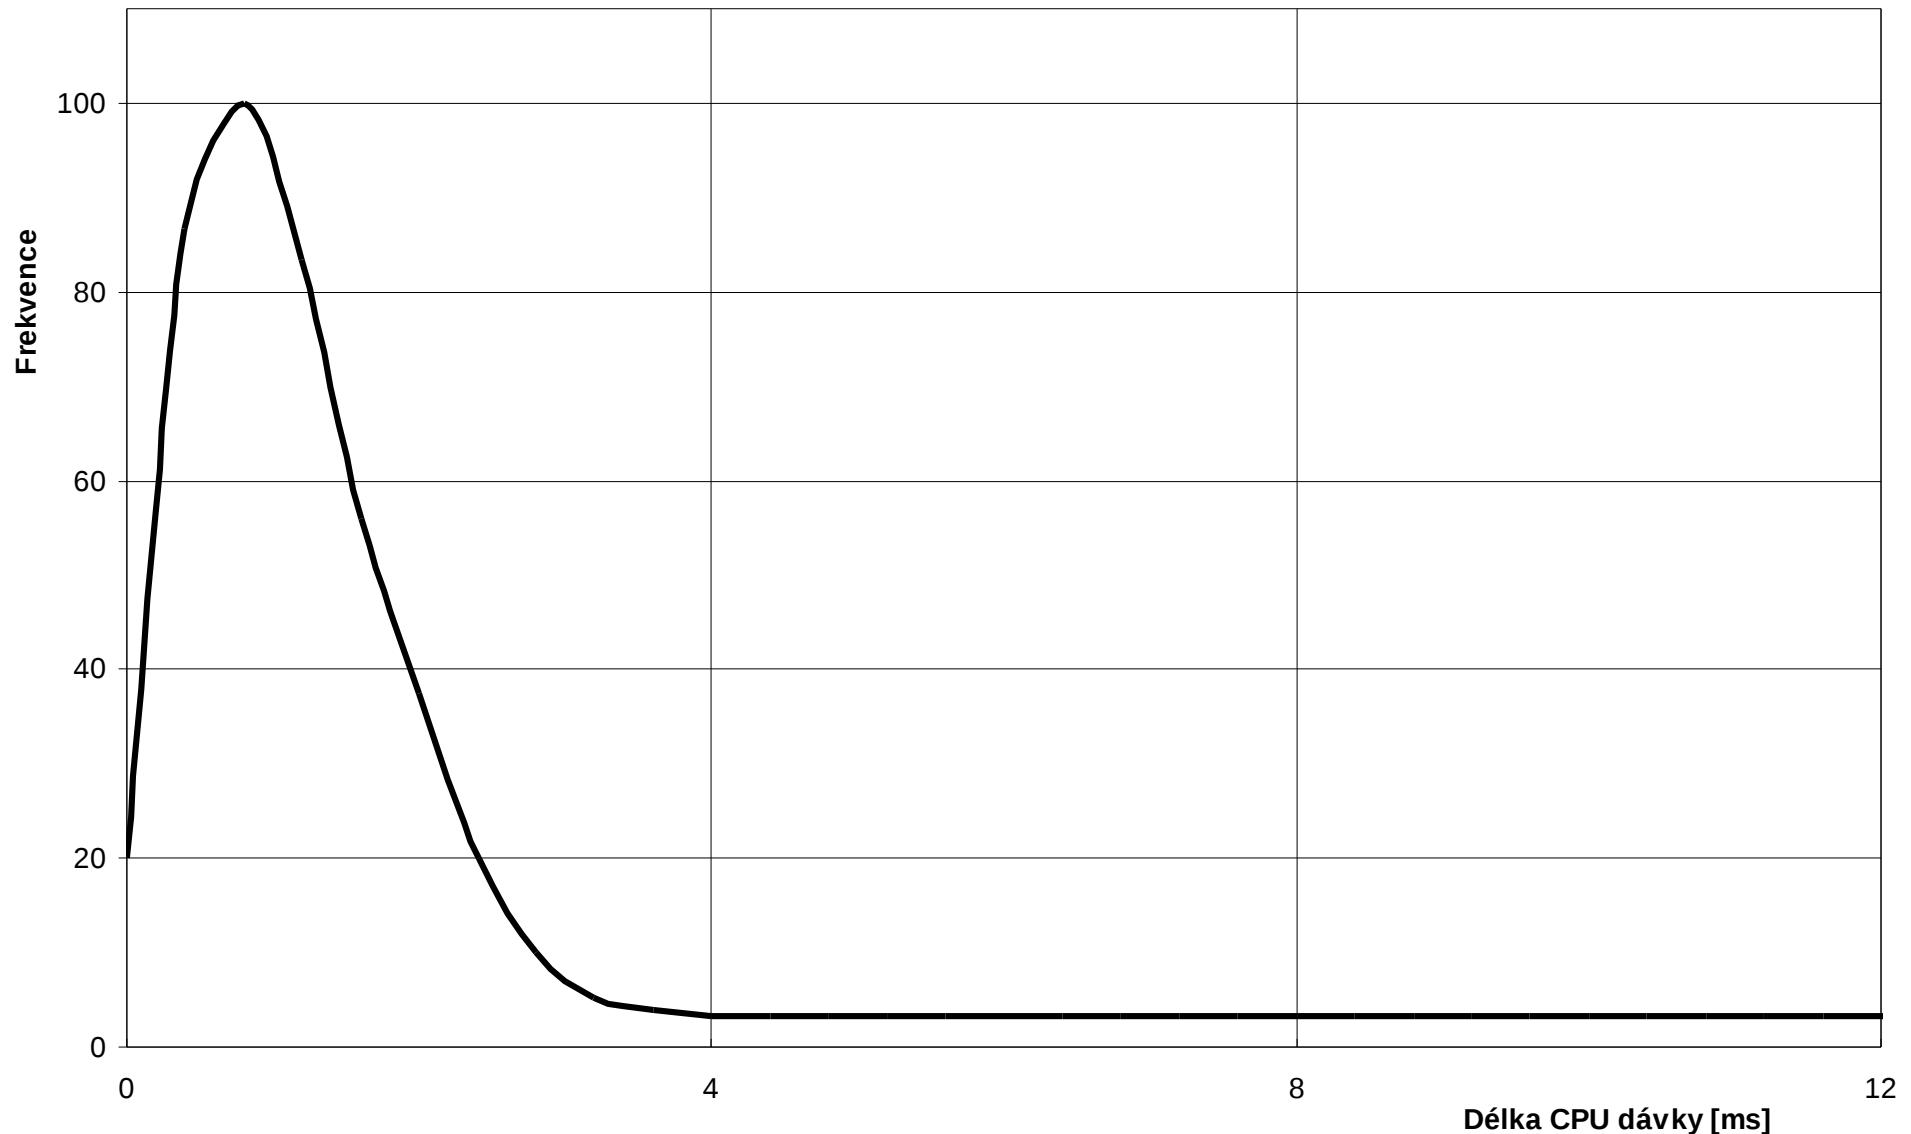


# Motivace plánování CPU

- Maximálního využití CPU se dosáhne uplatněním multiprogramování
- Jak ?
- Běh procesu = cykly alternujících dávek
  - [: CPU dávka, I/O dávka :]
- CPU dávka se může v čase překrývat s I/O dávkami dalších procesů

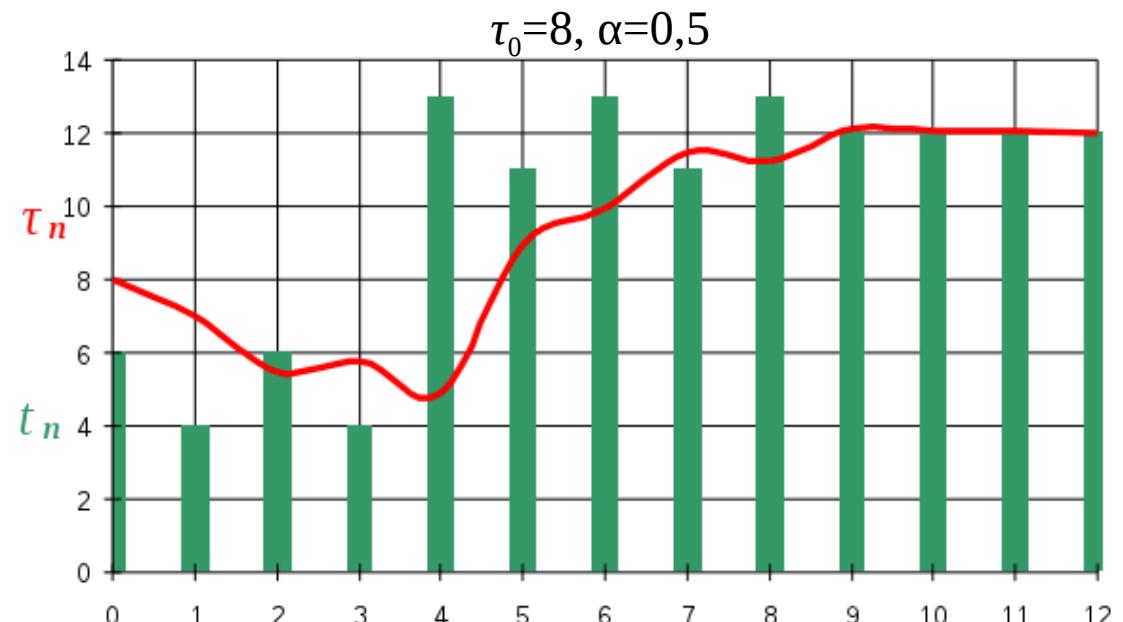


# Typický histogram délek CPU dávek



# Odhad délky příští dávky CPU procesu

- Délka příští dávky CPU skutečného procesu je známa jen ve velmi speciálních případech
  - Délka dávky se odhaduje na základě nedávné historie procesu
  - Nejčastěji se používá tzv. exponenciální průměrování
- Exponenciální průměrování
  - $t_n$  ... skutečná délka  $n$ -té dávky CPU
  - $\tau_{n+1}$  ... odhad délky příští dávky CPU
  - $\alpha, 0 \leq \alpha \leq 1$  ... parametr vlivu historie
  - $\tau_{n+1} = \alpha t_n + (1 - \alpha)\tau_n$
  - Příklad:
    - $\alpha = 0,5$
    - $\tau_{n+1} = 0,5t_n + 0,5\tau_n = 0,5(t_n + \tau_n)$
    - $\tau_0$  se volí jako průměrná délka CPU dávky v systému nebo se odvodí z typu nejčastějších programů



# Prioritní plánování (1)

- Každému procesu je přiřazeno prioritní číslo
  - Prioritní číslo – preference procesu při výběru procesu, kterému má být přiřazena CPU
  - CPU se přiděluje procesu s nejvyšší prioritou
  - Nejvyšší prioritě obvykle odpovídá (obvykle) nejnižší prioritní číslo
    - Ve Windows je to obráceně
- Existují se opět dvě varianty:
  - Nepreemptivní
    - Jakmile se vybranému procesu procesor předá, procesor mu nebude odňat, dokud se jeho CPU dávka nedokončí
  - Preemptivní
    - Jakmile se ve frontě připravených objeví proces s prioritou vyšší, než je priorita právě běžícího procesu, nový proces předběhne právě běžící proces a odejme mu procesor
- SPN i SRT jsou vlastně případy prioritního plánování
  - Prioritou je predikovaná délka příští CPU dávky
  - SPN je nepreemptivní prioritní plánování
  - SRT je preemptivní prioritní plánování

## Prioritní plánování (2)

- Problém stárnutí (*starvation*):
  - Procesy s nízkou prioritou nikdy nepoběží; nikdy na ně nepřijde řada
    - **Údajně:** Když po řadě let vypínali v roce 1973 na M.I.T. svůj IBM 7094 (jeden z největších strojů své doby), našli proces s nízkou prioritou, který čekal od roku 1967. 
- Řešení problému stárnutí: zrání procesů (*aging*)
  - Je nutno dovolit, aby se procesu zvyšovala priorita na základě jeho historie a doby setrvávání ve frontě připravených
    - Během čekání na procesor se priorita procesu zvyšuje

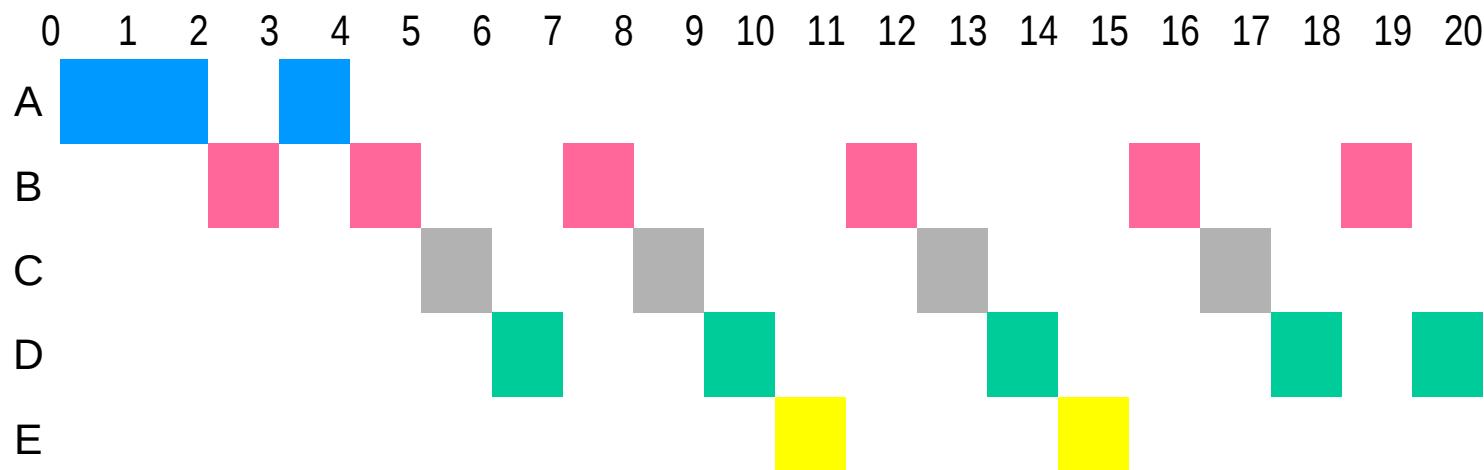
## Cyklické plánování

- Cyklická obsluha (*Round-robin*) – RR
- Z principu preemptivní plánování
- Každý proces dostává CPU periodicky na malý časový úsek, tzv. **časové kvantum, délky  $q$**  ( $\sim$  desítky ms)
  - V „čistém“ RR se uvažuje shodná priorita všech procesů
  - Po vyčerpání kvanta je běžícímu procesu odňato CPU ve prospěch nejstaršího procesu ve frontě připravených a dosud běžící proces se zařazuje na konec této fronty
  - Je-li ve frontě připravených procesů  $n$  procesů, pak každý proces získává  $1/n$ -tinu doby CPU
  - Žádný proces nedostane 2 kvanta za sebou (samozřejmě pokud není jediný připravený)
  - Žádný proces nečeká na přidělení CPU déle než  $(n-1)q$  časových jednotek

# Cyklické plánování (2)

- Efektivita silně závisí na velikosti kvanta
  - Veliké kvantum – blíží se chování FCFS
    - Procesy dokončí svoji CPU dávku dříve, než jim vyprší kvantum.
  - Malé kvantum => časté přepínání kontextu => značná režie
- Typicky
  - Dosahuje se průměrné doby obrátky delší oproti plánování SRT
  - Výrazně lepší je čas odezvy
  - Průměrná doba obrátky se může zlepšit, pokud většina procesů se době  $q$  ukončí
  - Empirické pravidlo pro stanovení  $q$ : cca 80% procesů by nemělo vyčerpat kvantum

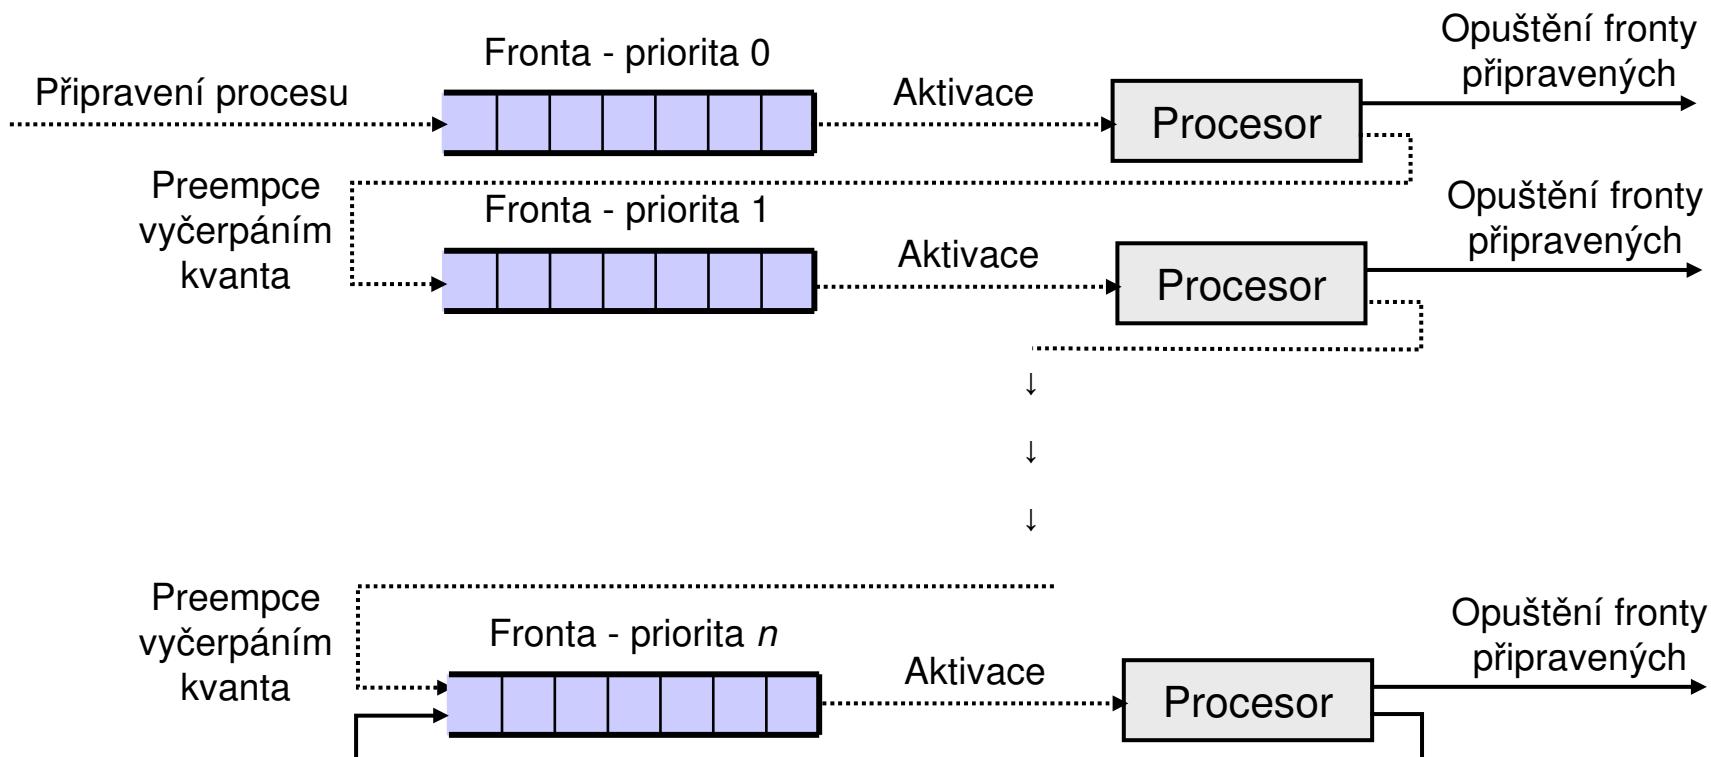
Příklad:



# Zpětnovazební plánování

- Základní problém:
  - Neznáme předem časy, které budou procesy potřebovat
- Východisko:
  - Penalizace procesů, které běžely dlouho
- Řešení:
  - Dojde-li k preemci přečerpáním časového kvanta, procesu se snižuje priorita
  - Implementace pomocí víceúrovňových front
    - pro každou prioritu jedna
  - Nad každou frontou samostatně běží algoritmus určitého typu plánování
    - obvykle RR s různými kvanty a FCFS pro frontu s nejnižší prioritou

## Víceúrovňové fronty - Windows



- Proces opouštějící procesor kvůli vyčerpání časového kvanta je přeřazen do fronty s nižší prioritou
- Fronty s nižší prioritou mohou mít delší kvanta
- Problém **stárnutí** ve frontě s nejnižší prioritou
  - Řeší se pomocí **zrání** (*aging*) – v jistých časových intervalech ( $\sim 10^1$  s) se zvyšuje procesum priority, a tak se přemísťují do „vyšších“ front

# O(1) plánovač – Linux 2.6-2.6.23

- O(1) - rychlosť plánovače nezávisí na počtu běžících procesů – je rychlý a deterministický
- Dvě sady víceúrovňových front
  - Na začátku první sada obsahuje připravené procesy, druhá je prázdná
  - Při vyčerpání časového kvanta je proces přeřazen do druhé sady front do nové úrovně
  - Vzbuzené procesy jsou zařazovány podle toho, zda ještě nevyužily celé svoje časové kvantum do aktivní sady front, nebo do druhé sady front
  - Pokud je první sada prázdná, dojde k prohození první a druhé sady front procesů
- Heuristika pro odhad interaktivních procesů a jejich udržování na nejvyšších prioritách s odpovídajícími časovými kvanty

# Zcela férrový plánovač

- Linux od verze 2.6.23 (Completely Fair Scheduler)  
Nepoužívá fronty, ale jednu strukturu, která udržuje všechny procesy uspořádané podle délky již spotřebovaného času – čím méně proces spotřeboval strojového času, tím větší má nárok na přidělení procesoru
- Pro rychlou implementaci se používá vyvážený binární červeno-černý strom, zaručující složitost úměrnou  $\log(n)$  počtu procesů
- Nepotřebuje složité heuristiky pro detekci interaktivních procesů
- Jediný parametr je časové kvantum:
  - pro uživatelské PC se volí menší pro větší
  - pro serverové počítače větší kvantu omezuje režii s přepínáním procesů a tím zvyšuje propustnost serveru
- Žádný proces nemůže zestárnout, všechny procesy mají stejné podmínky

# Plánování v multiprocesorech

- Přiřazování procesů (vláken) procesorům:
  - Architektura „master/slave“
    - Klíčové funkce jádra běží vždy na jednom konkrétním procesoru
    - Master odpovídá za plánování
    - Slave žádá o služby mastera
    - Nevýhoda: dedikace
      - Přetížený master se stává úzkým místem systému
  - Symetrický multiprocesing (SMP)
    - Všechny procesory jsou si navzájem rovny
    - Funkce jádra mohou běžet na kterémkoliv procesoru
  - SMP vyžaduje podporu vláken v jádře
- Proces musí být dělen na vlákna, aby SMP byl účinný
  - Aplikace je sada vláken pracujících paralelně do společného adresního prostoru
  - Vlákno běží nezávisle na ostatních vláknech svého procesu
  - Vlákna běžící na různých procesorech dramaticky zvyšují účinnost systému

# Symetrický multiprocesing (SMP)

- Dvě řešení:
  - Jedna společná fronta pro všechny procesory
  - Každý procesor svojí frontu a migrace procesů mezi procesory
- Jedna společná (globální) fronta pro všechna vlákna
  - Fronta „napájí“ společnou sadu procesorů
    - Fronta může být víceúrovňová dle priorit
  - Každý procesor si sám vyhledává příští vlákno
    - Přesněji: instance plánovače běžící na procesoru si je sama vyhledává ...
  - Problémy
  - Jedna centrální fronta připravených sledů vyžaduje používání vzájemného vylučování v jádře
    - Kritické místo v okamžiku, kdy si hledá práci více procesorů
    - Předběhnutá (přerušená) vlákna nebudou nutně pokračovat na stejném procesoru – nelze proto plně využívat cache paměti procesorů
- Každý procesor svoji frontu
  - Heuristická pravidla, kdy frontu změnit
- SMP používáno ve
  - Windows, Linux, Mac OS X, Solaris, BSD4.4

# Poznámky k plánování v multiprocesorech

- Používají se různá (heuristická) pravidla (i při globální frontě):
  - Afinita vlákna k CPU – použij procesor, kde vlákno již běželo (možná, že v cache CPU budou ještě údaje z minulého běhu)
  - Použij nejméně využívaný procesor
- Mnohdy značně složité
  - při malém počtu procesorů ( $\leq 4$ ) může přílišná snaha o optimalizaci plánování vést až k poklesu výkonu systému
    - Tedy aspoň v tom smyslu, že výkon systému neporoste lineárně s počtem procesorů
  - při velkém počtu procesorů dojde naopak k „nasycení“, neboť plánovač se musí věnovat rozhodování velmi často (končí CPU dávky na mnoha procesorech)
    - Režie tak neúměrně roste

# Systémy reálného času (RT)

- Obvykle malé systémy se specializovaným použitím
  - Často vestavěné (*embedded*)
- Správná funkce systému závisí nejen na logickém (či numerickém) výsledku ale i na **čase**, kdy bude výsledek získán
  - Správně určený výsledek dodaný pozdě je k ničemu
- Úlohy a procesy reagují na události pocházející zvenčí systému a navenek dodávají své výsledky
  - Nastávají v „reálném čase“ a potřebná reakce musí být **včasná**
- Příklady
  - Řízení laboratorních či průmyslových systémů
  - Robotika
  - Řízení letového provozu
  - Telekomunikační aplikace (digitální ústředny)
  - Vojenské systémy velení a řízení
  - ...

## Charakteristiky OS RT

- Determinismus
  - Operace jsou prováděny ve fixovaných, předem určených časech nebo časových intervalech
  - Reakce na přerušení musí proběhnout tak, aby systém byl schopen obsluhy všech požadavků v požadovaném čase (včetně vnořených přerušení)
- Uživatelské řízení
  - Uživatel (návrhář systému) specifikuje:
    - Priority
    - Práva procesů
    - Co musí vždy zůstat v paměti
- Spolehlivost
  - Degradace chování může mít katastrofální důsledky
- Zabezpečení
  - Schopnost systému zachovat v případě chyby aspoň částečnou funkci a udržet maximální množství dat

# Požadavky na OS RT

- Extrémně rychlé přepínání mezi procesy či vlákny
- OS musí být malý
- Multiprogramování s meziprocesními komunikačními nástroji
  - semafory, signály, události →
- Speciální souborové systémy s velkou rychlostí
  - RAM disky, souvislé soubory
- Plánování založené na prioritách
  - Pozor: preempce je ale časově náročná
- Minimalizace časových úseků, kdy je vypnut přerušovací systém
- Zvláštní hardwarové vybavení
  - hlídací časovače (*watch-dog timers*) a alarmy

# Plánování CPU v RT systémech

- Tabulkou řízené statické plánování
  - Určuje pevně, kdy bude který proces spuštěn tak, aby včas skončil
  - **Nejčastější případ** v uzavřených systémech s předem známými procesy a jejich vlastnostmi
- Preemptivní plánování se statickými prioritami
  - Používá klasický prioritní plánovač s fixními prioritami
    - Může být problematické kvůli velké režii spojené s preempcí
- Dynamické plánování
  - Za běhu určuje proveditelnost (splnitelnost požadavků)
  - V tzv. **přísných RT systémech** (*Hard real-time systems*) téměř nepoužitelné vlivem velké režie
    - *Hard real-time systems* musí přísně zaručovat dokončení časově kritických procesů do předepsaného termínu

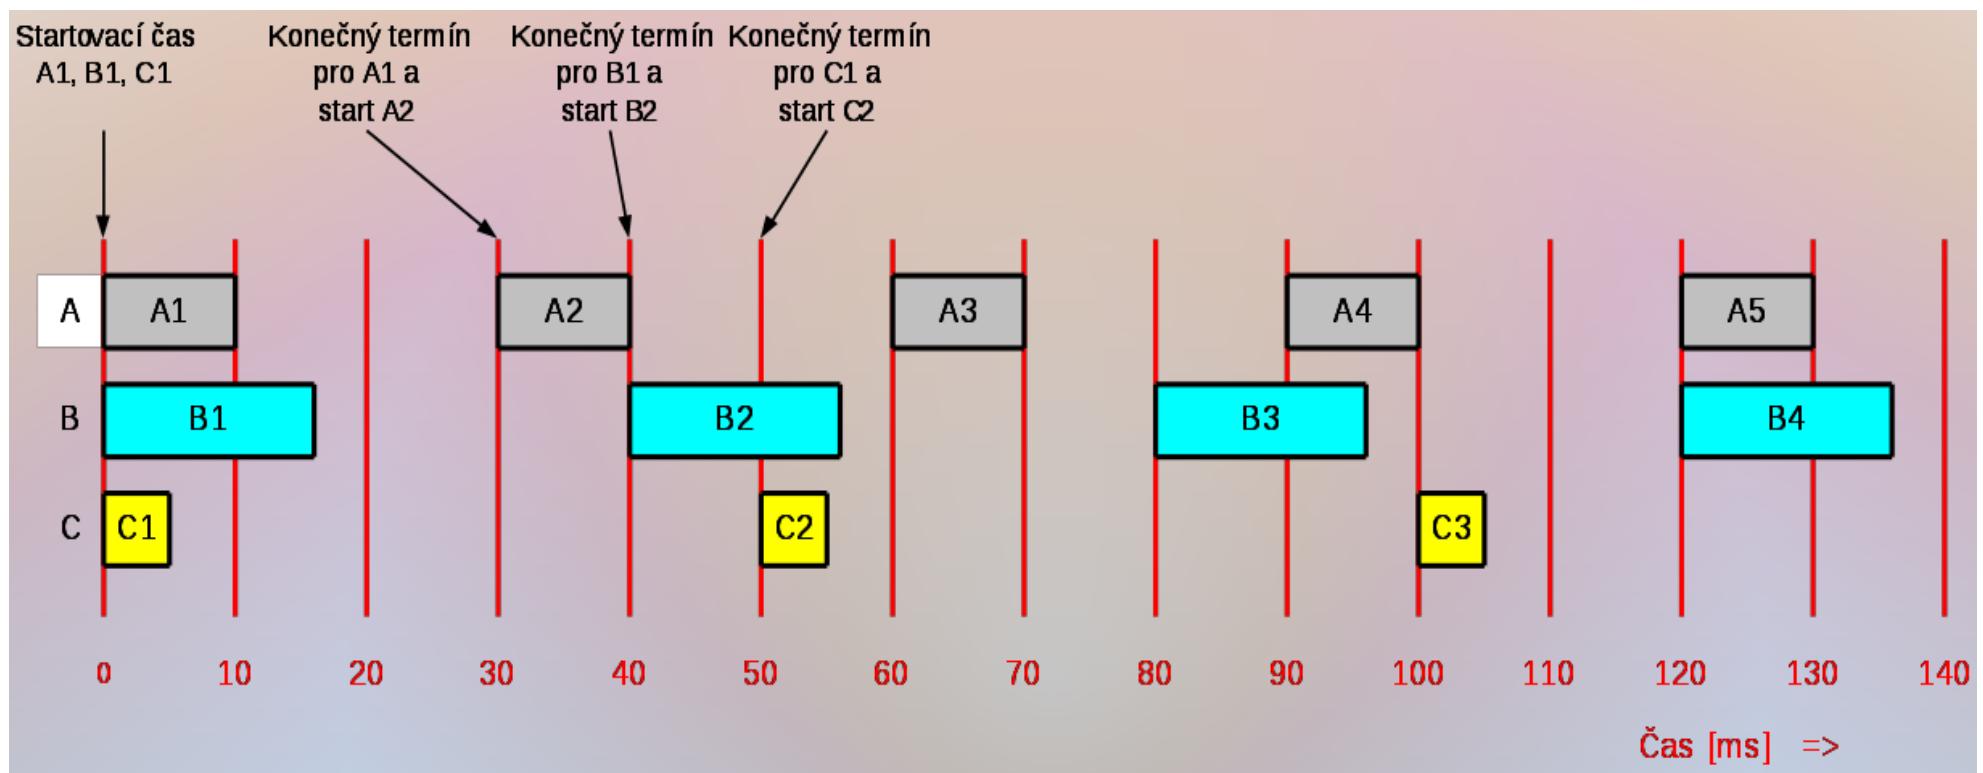
# Periodické plánování dle konečného termínu

- Procesům jde zejména o včasné dokončení v rámci zadané periody běžících procesů
  - Např. v daných intervalech je třeba vzorkovat napětí z čidel
- O každém procesu je znám
  - Potřebný čas (horní hranice délky CPU dávky)
  - Termín začátku a nejzazšího konce každého běhu periodicky spouštěného procesu
- Předpoklady (zjednodušení)
  - Termín dokončení je identický s počátkem následující periody
  - Požadavky na systémové prostředky (či potřebu čekání na jejich přidělení) budeme ignorovat

# Příklad 1

- 3 periodické procesy

Proces	Perioda $p_i$	Procesní čas $T_i$	$T_i / p_i$
A	30	10	0,333
B	40	15	0,375
C	50	5	0,100



# Plánovatelnost v periodických úlohách

- Relativní využití strojového času

- Proces  $i$  využije poměrnou část celkového strojového času, kde  $T_i$  je procesní čas a  $p_i$  je jeho perioda

$$r = \sum_{i=1}^N r_i = \sum_{i=1}^N \frac{T_i}{p_i}$$

$$r = \sum_{i=1}^N \frac{T_i}{p_i} \leq 1$$

- Celkové využití je  $\sum_{i=1}^3 \frac{T_i}{p_i} = \frac{10}{30} + \frac{15}{40} + \frac{5}{50} = 0,808 < 1$

# Plánování RMS

- Algoritmus RMS = *Rate Monotonic Scheduling*
- Statické priority
  - $Prio_i \approx p_i$  (kratší perioda = menší číslo ~ vyšší priorita)
- Používá se pro procesy s následujícími vlastnostmi
  - Periodický proces musí skončit během své periody
  - Procesy jsou vzájemně nezávislé
  - Každý běh procesu (CPU dávka) spotřebuje konstantní čas
  - Předpokládá se, že preempce nastává okamžitě (bez režie)
- Poznatek
  - Plánování je úspěšné, pokud se všechny procesy stihnou v době odpovídající periodě procesu s nejdelší periodou

# Plánování EDF

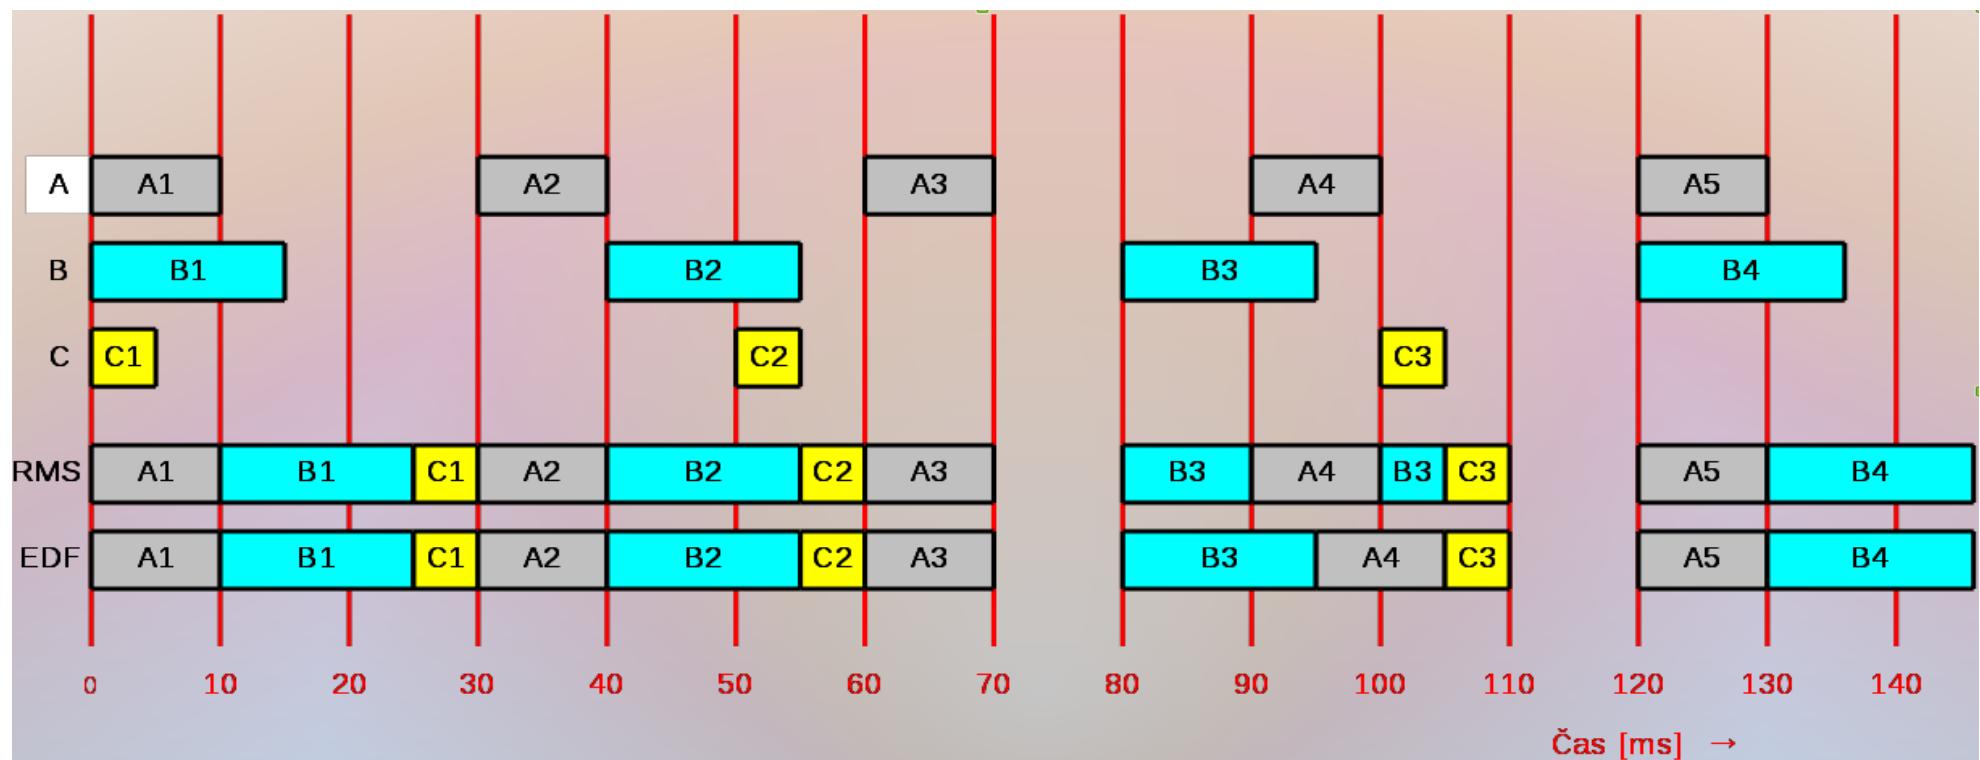
- **EDF = Earliest Deadline First**
  - Upřednostňuje proces s nejbližším termínem dokončení
- **Dynamické priority**
  - Plánovač vede seznam připravených procesů uspořádaný podle požadovaných časů dokončení a spustí vždy ten s nejbližším požadovaným termínem dokončení
- **Použitelné i v následujících situacích**
  - Procesy nemusí být přísně periodické ani nemusí mít konstantní dobu běhu
  - Pokud preempce nastává okamžitě, pak při plánování periodických procesů lze dodržet dokončovací termíny i při vytížení téměř 100%
- **Vlastnosti**
  - Algoritmus není analyticky plně prozkoumán
  - Následky přetížení nejsou známy a nejsou předvídatelné
  - Není známo chování v případech, kdy dokončovací termín a perioda jsou různé

## Příklad 1 (pokračování)

Proces      Perioda  $p_i$       Procesní čas  $T_i$

A	30	10
B	40	15
C	50	5

$$r = 0,808$$

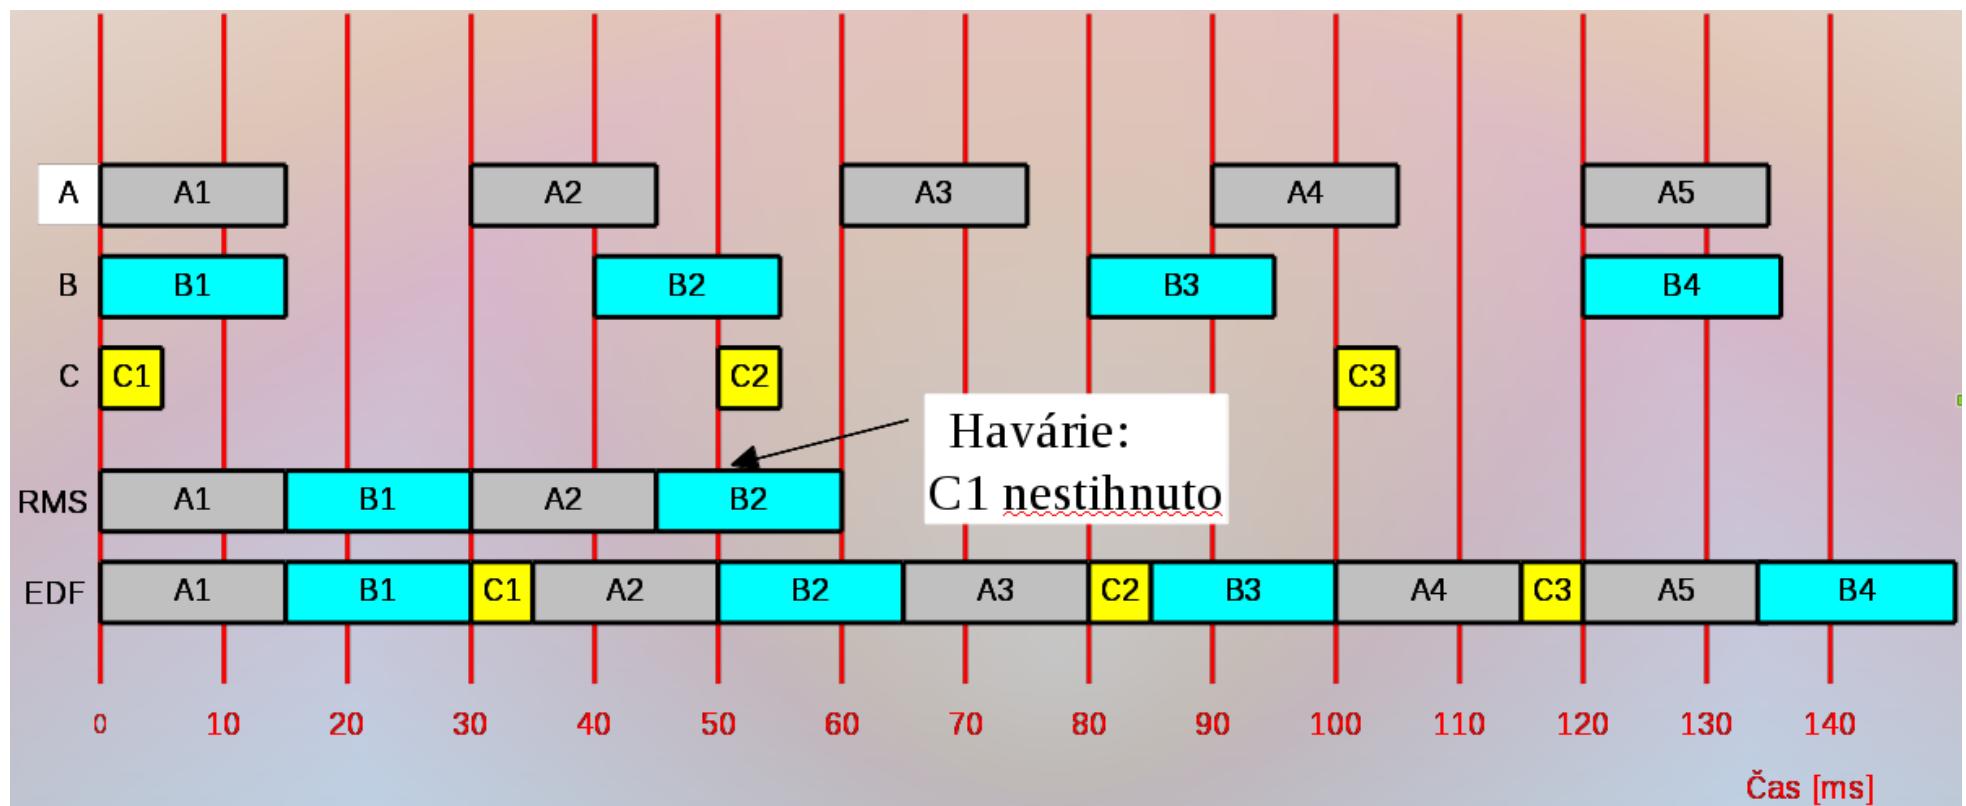


- Oba algoritmy fungují
  - Dokonce chvílemi zbývá volný čas k běhu nějakého procesu „na pozadí“

## Příklad 2

- Opět 3 periodické procesy

Proces	Perioda $p_i$	Procesní čas $T_i$	$T_i / p_i$	Suma	Plánovatelné
A	30	15	0,500		
B	40	15	0,375		
C	50	5	0,100	$R = 0,975 < 1$	



# Plánování RMS podrobněji

- Dobře analyticky zpracovaný algoritmus zaručující dodržení termínů dokončení, pokud při  $N$  procesech platí **(postačující podmínka)** [Liu & Layland 1973]:

$$r = \sum_{i=1}^N \frac{T_i}{p_i} \leq N \left( \sqrt[N]{2} - 1 \right);$$

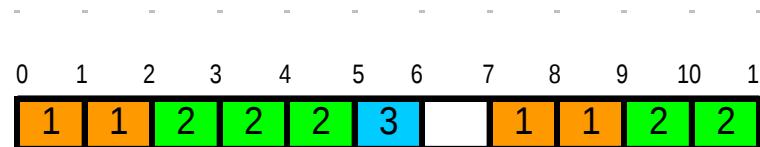
$$\lim_{N \rightarrow \infty} N \left( \sqrt[N]{2} - 1 \right) = \ln 2 \approx 0.693147$$

$N$	$N \left( \sqrt[N]{2} - 1 \right)$
2	0,828427
3	0,779763
4	0,756828
5	0,743491
10	0,717734
20	0,705298

## Plánování RMS podrobněji (2)

- Jak je to s použitelností RMS?

P	i	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
A	1	7	2	0,286	0,286
B	2	8	3	0,375	0,661
C	3	10	1	0,100	<b>0,761</b>



$$3(\sqrt[3]{2} - 1) = 0,7797$$

P	i	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
A	1	6	2	0,333	0,333
B	2	8	3	0,375	0,708
C	3	10	1	0,100	<b>0,808</b>



P	i	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
A	1	4	1	0,250	0,250
B	2	5	1	0,200	0,450
C	3	6	3	0,500	<b>0,950</b>



P	i	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
A	1	4	1	0,250	0,250
B	2	5	2	0,400	0,650
C	3	20	7	0,350	<b>1,000</b>



## Plánování RMS podrobněji (3)

- Lehoczky, Sha & Ding [1989] podrobili RMS analýze znovu.  
Výsledek:

- Mějme procesy  $\{ P_i, i = 1 \dots N \mid p_i \leq p_{i+1}, i = 1 \dots N - 1 \}$
- Soustřeďme se na procesy  $1 \dots i$ , ( $i=1 \dots N$ ) a určeme vždy

$$W_i(t) = \sum_{j=1}^i T_j \lceil t / p_j \rceil, L_i(t) = W_i(t) / t,$$
$$L_i = \min_{\{0 < t \leq T_i\}} L_i(t), \quad L = \max_{\{1 \leq i \leq N\}} L_i$$

$W_i(t)$  reprezentuje kumulativní potřeby procesů  $P_1 \dots P_i$  v časovém úseku  $[0, t]$

$$t \in \{4, 5, 8, 10, 12, 13\}$$

## Plánování RMS podrobněji (4)

- Příklady použití uvedené teorie
  - RMS zhavaruje

$i$	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
1	4	1	0,250	0,250
2	5	1	0,200	0,450
3	6	3	0,500	0,950

$L_i(4)$	$L_i(5)$	$L_i(6)$	$L_i$	$L$
0,250	0,400	0,333	0,250	
0,500	0,600	0,667	0,500	1,167
1,250	1,200	1,167	1,167	

- RMS bude funkční

$i$	$p_i$	$T_i$	$T_i/p_i$	$\Sigma(T_i/p_i)$
1	4	1	0,250	0,250
2	5	2	0,400	0,650
3	20	7	0,350	1,000

$L_i(4)$	$L_i(5)$	$L_i(8)$	$L_i(10)$	$L_i(12)$	$L_i(15)$	$L_i(16)$	$L_i(20)$	$L_i$	$L$
0,250	0,400	0,250	0,300	0,250	0,267	0,250	0,250	0,250	
0,750	0,800	0,750	0,700	0,750	0,667	0,750	0,650	0,650	1,000
2,500	2,200	1,625	1,400	1,333	1,133	1,188	1,000	1,000	

To je dnes vše.

Otázky?