PB153
OPERAČNÍ SYSTÉMY A JEJICH ROZHRANÍ

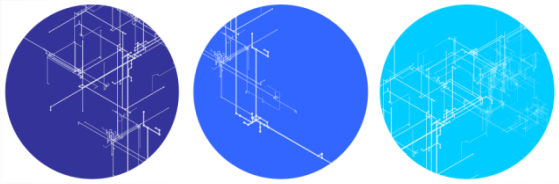

Virtuální paměť

11

ZÁKLADNÍ PRINCIPY

- Virtuální paměť
  - separace LAP a FAP
  - ve FAP se mohou nacházet pouze části programů nutné pro bezprostřední řízení procesů
  - LAP může být větší než FAP
  - adresové prostory lze sdílet mezi jednotlivými procesy
  - lze efektivněji vytvářet procesy
- Techniky implementace
  - Stránkování na žádost, Demand Paging
  - Segmentování na žádost, Demand Segmentation

BĚH PROCESŮ VE VIRTUÁLNÍ PAMĚTI

- Část procesu umístěnou ve FAP nazýváme „rezidentní množinou“ (resident set)
- Odkaz mimo rezidentní množinu způsobuje přerušení výpadek stránky (page fault)
- OS označí proces za „čekající“
- OS spustí I/O operace a provede nutnou správu paměti pro zavedení odkazované části do FAP
- Mezitím běží jiný proces (jiné procesy)
- Po zavedení odkazované části se generuje I/O přerušení
  - OS příslušný proces umístí mezi připravené procesy
- Překlad adresy LAP na adresu FAP se dělá indexováním tabulky PT/ST pomocí hardware CPU

VIRTUÁLNÍ PAMĚŤ – VLASTNOSTI

- Ve FAP lze udržovat více procesů najednou
  - čím více je procesů ve FAP, tím je větší pravděpodobnost, že stále bude alespoň jeden připravený
- Lze realizovat procesy požadující více paměti než umožňuje FAP
  - aniž se o řešení tohoto problému stará programátor / kompilátor
  - jinak bychom museli použít překryvy (overlays)

PŘÍKLAD: LINUX

PID	USER	PR	NI	VIRT	RES	SHR	S	%CPU	%MEM	TIME+	COMMAND
4261	brandejs	17	0	149m	14m	2180	S	4.9	0.0	0:00.15	crond
4268	brandejs	19	0	41164	8072	1836	S	2.9	0.0	0:00.09	execute.pl
4135	zriha	15	0	12560	2160	808	R	2.6	0.0	0:00.58	top
31185	root	16	0	67436	15m	3052	S	2.3	0.0	0:04.82	dovecot-auth
3048	kas	15	0	103m	14m	2184	R	1.9	0.0	0:09.82	vim
9842	root	15	0	0	0	0	S	1.3	0.0	110:03.59	nfsd
6267	root	15	0	14556	532	396	S	1.0	0.0	525:51.34	mcstransd
1	root	15	0	10348	648	548	S	0.6	0.0	79:51.28	init
4236	qruzicka	15	0	47664	2192	1720	S	0.6	0.0	0:00.06	imap
9427	nscd	15	0	486m	179m	3000	S	0.6	0.1	120:59.69	nscd
13943	named	21	0	640m	39m	2212	S	0.6	0.0	929:05.56	named
97	root	10	-5	0	0	0	S	0.3	0.0	0:47.25	events/23
1708	root	15	0	0	0	0	S	0.3	0.0	66:48.99	pdflush
1777	root	15	0	50392	1484	580	S	0.3	0.0	10:44.24	dovecot
2403	root	10	-5	0	0	0	S	0.3	0.0	113:31.64	kjournald
3095	hales	16	0	153m	5408	3832	S	0.3	0.0	0:00.54	vim.Linux

- VIRT - Virtual Image (kb)
  - The total amount of virtual memory used by the task. It includes all code, data and shared libraries plus pages that have been swapped out.
- RES - Resident size (kb)
  - The non-swapped physical memory a task has used.
- SHR - Shared Mem size (kb)
  - The amount of shared memory used by a task. It simply reflects memory that could be potentially shared with other processes.

VIRTUÁLNÍ PAMĚŤ – VLASTNOSTI

- Uložení obrazu LAP (virtuální paměti) v externí paměti
  - nepoužívá se standardní systém souborů OS, používají se speciální metody, optimalizované pro tento účel
  - speciální partition/slice disku
- Stránkování / segmentaci musí podporovat hardware správy paměti
  - stránkování na žádost
  - segmentování na žádost
  - žádost – dynamicky kontextově generovaná indikace nedostatku
- OS musí být schopen organizovat tok stránek / segmentů mezi vnitřní a vnější pamětí

LAP VĚTŠÍ NEŽ FAP

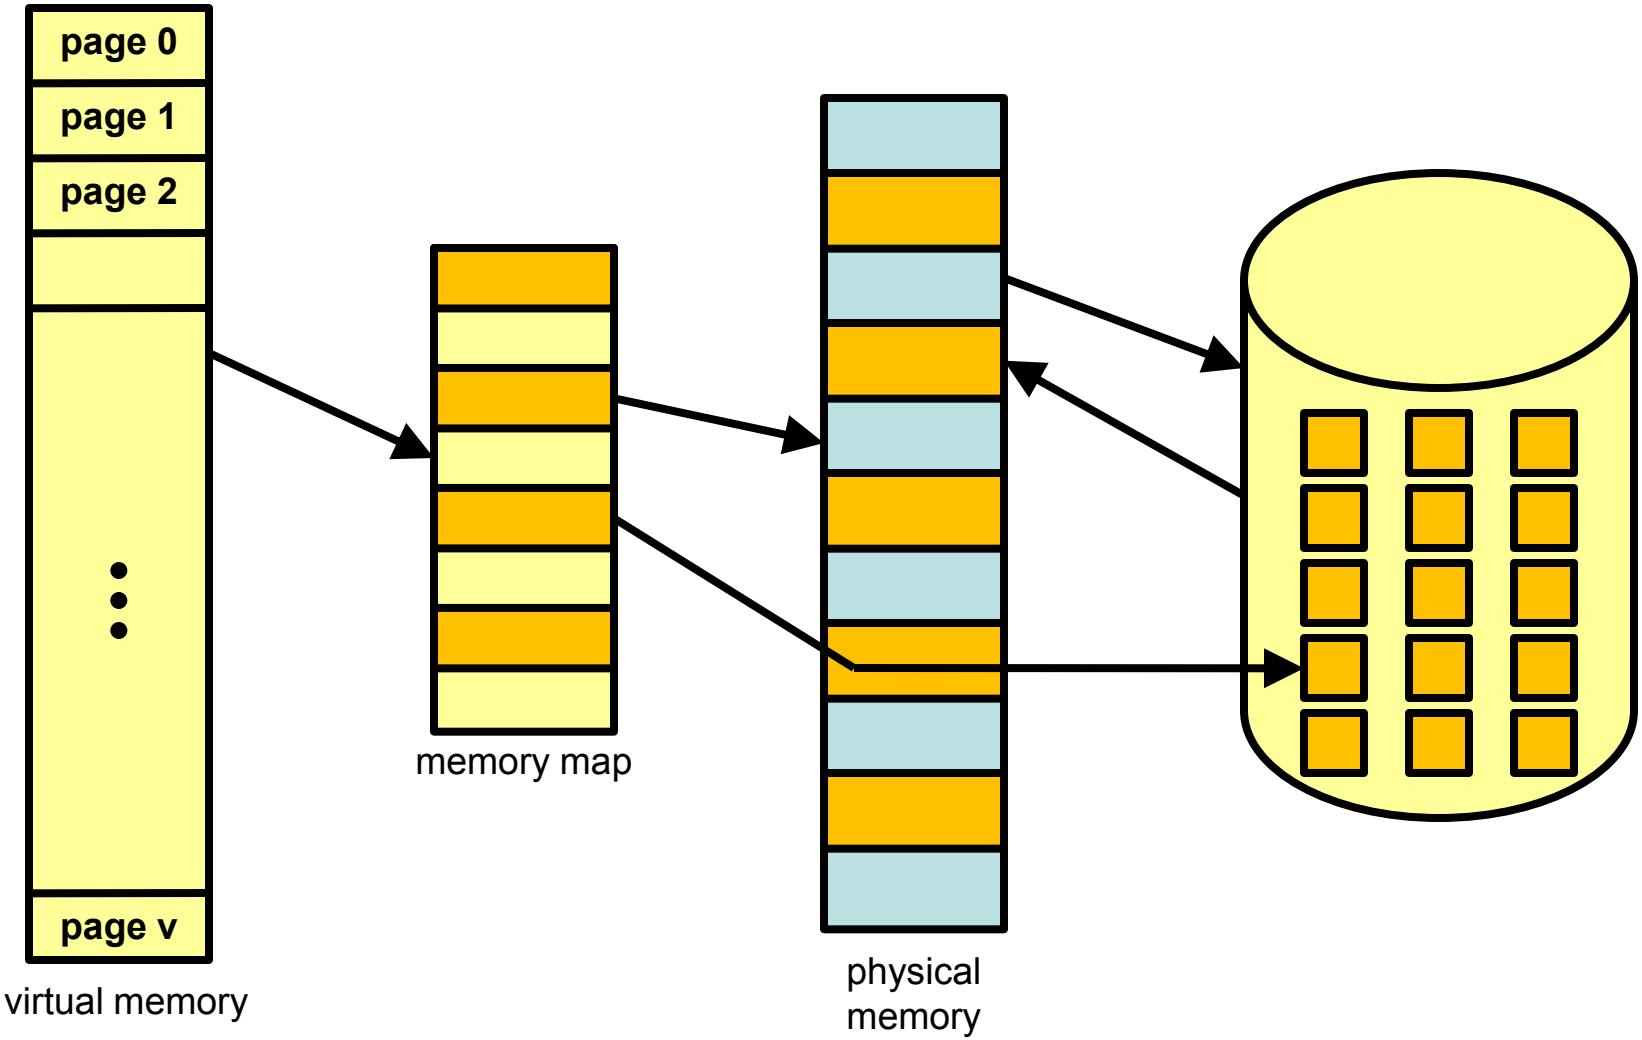

KDY ZAVÁDĚT STRÁNKU

- Stránkování na žádost (Demand paging)
  - stránka se zobrazuje do FAP při odkazu na ni, pokud ve FAP není již zobrazena
  - počáteční shluky výpadků stránek
- Předstránkování (Prepaging)
  - umístění na vnější paměti sousedních stránek v LAP bývá blízké („sousedi“)
  - princip lokality
  - zavádí se více stránek než se žádá
  - vhodné při inicializaci procesu

KAM STRÁNKU ZAVÉST?

- Segmentace
  - best-, first-, worstfit
- Stránkování
  - nemusíme řešit
- Kombinace segmentování + stránkování
  - nemusíme řešit

KTEROU STRÁNKU NAHRADIT?

- Uplatňuje se v okamžiku, kdy je FAP plný
- Typicky v okamžiku zvýšení stupně multitaskingu
- Kterou stránku „obětovat“ a vyhodit z FAP (politika výběru oběti)?
- Politika nahrazování
  - určení oběti
    - politika přidělování místa
      - kolik rámců přidělit procesu?
      - intra/extra (local/global) množina možných obětí
        - oběti lze hledat jen mezi stránkami procesu, který vyvolal výpadek stránky?
        - oběti lze hledat i mezi stránkami ostatních procesů (např. podle priorit procesů)?
  - nelze obětovat kteroukoliv stránku
    - někde rámce jsou „zamčeny“
    - typicky I/O buffery, řídicí struktury OS, …

STRÁNKOVÁNÍ NA ŽÁDOST

- Stránka se zavádí do FAP jen když je potřebná
- Přínosy
  - méně I/O operací
  - menší požadavky na paměť
  - rychlejší reakce
  - může pracovat více uživatelů
- Kdy je stránka potřebná?
  - byla odkazovaná
  - legální reference
    - Nachází se ve FAP, přeloží se logická adresa na fyzickou
  - nelegální reference (porušení ochrany) → abort procesu
  - reference stránky, která není ve FAP → její zavedení do FAP
    - zprostředkovává OS

BIT VALID-INVALID

- S každým řádkem PT je spojen bit V/I (valid/invalid)

  (1 → je ve FAP, 0 → není právě ve FAP)

  - iniciálně jsou všechny V/I bity nastaveny na 0

- Při překladu adresy
  - jestliže je bit valid/invalid roven 0, generuje se přerušení typu „page fault“

Frame #	valid-invalid bit
	1
	1
	1
	1
	0
. . .	
	0
	0

page table

PŘÍKLAD: TABULKA STRÁNEK

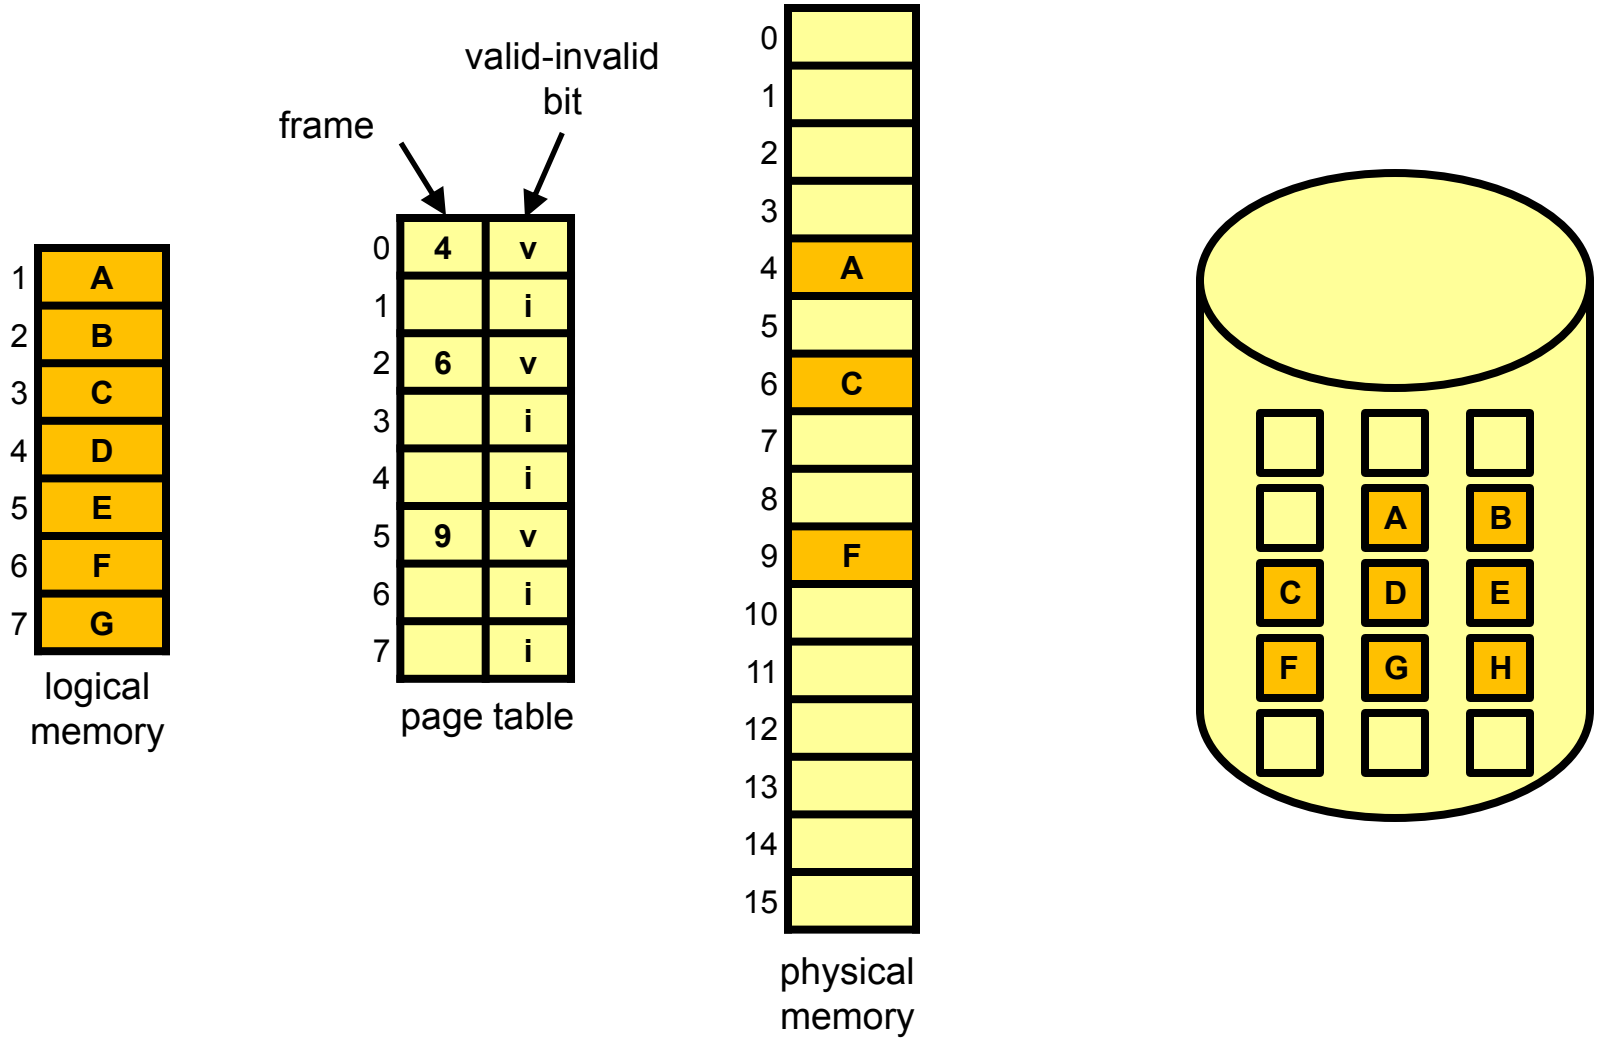

VÝPADEK STRÁNKY

- Pokud se stránka nenachází ve FAP je aktivován OS pomocí přerušení „**page fault**“ (výpadek stránky)
- OS zjistí:
  - nelegální reference → procesu je informován (např. signál SIGSEGV)
  - legální reference, ale stránka chybí v paměti → zavede ji
- Zavedení stránky
  - získání prázdného rámce
  - zavedení stránky do tohoto rámce
  - úprava tabulky, nastaven bit valid/invalid na 1
- Pak se opakuje instrukce, která způsobila „page fault“

ZPRACOVÁNÍ VÝPADKU STRÁNKY

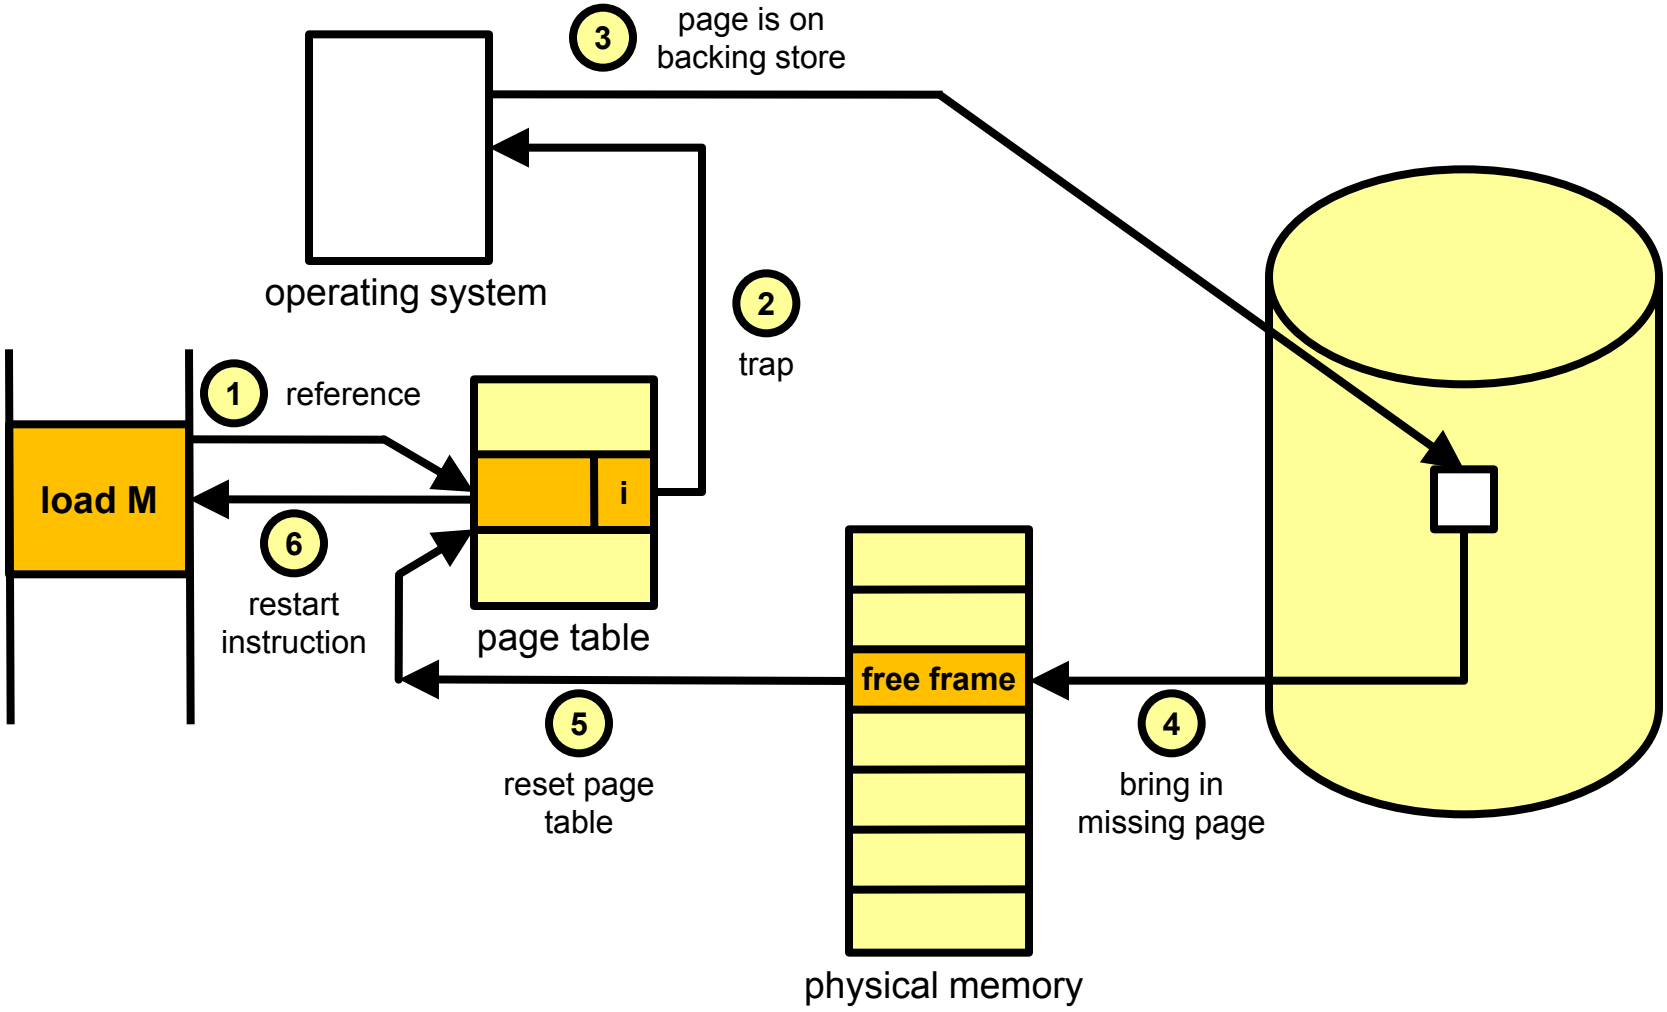

VOLNÝ RÁMEC

- pokud není žádný rámec aktuálně označen jako volný, musíme nějaký uvolnit
  - nalezneme se „oběť“ – nepotřebnou stránku ve FAP (nevíme, co je nepotřebné, můžeme pouze odhadovat)
  - je-li to nutné, před uvolněním stránky ji zapíšeme na disk
    - pokud se do ní nezapsalo, její kopie na disku je aktuální
    - zda se do stránky zapsalo zjistíme v bitu modify (dirty)
    - bit modify nastavuje HW automaticky při zápisu do stránky
- Potřebujeme algoritmus pro hledání „oběti“ a řešení náhrady
  - kritérium optimality algoritmu: nejméně výpadků stránek

PRINCIP LOKALITY

- Odkazy na instrukce programu a na dat mají tendenci tvořit shluky
- Časová lokalita a prostorová lokalita
  - provádění programu je s výjimkou skoků a volání podprogramů sekvenční
  - programy mají tendenci zůstávat po jistou dobu v rámci nejvýše několika procedur (nelze jen něco volat a hned se vracet)
  - většina iterativních konstruktů představuje malý počet často opakovaných instrukcí
  - často zpracovávanou datovou strukturou je pole dat nebo posloupnost záznamů
- → lze dělat rozumné odhady o částech programu/dat potřebných v nejbližší budoucnosti
- vnitřní paměť se může zaplnit
  - něco umístit do FAP pak znamená nejdříve něco odložit z FAP

NÁHRADA STRÁNKY

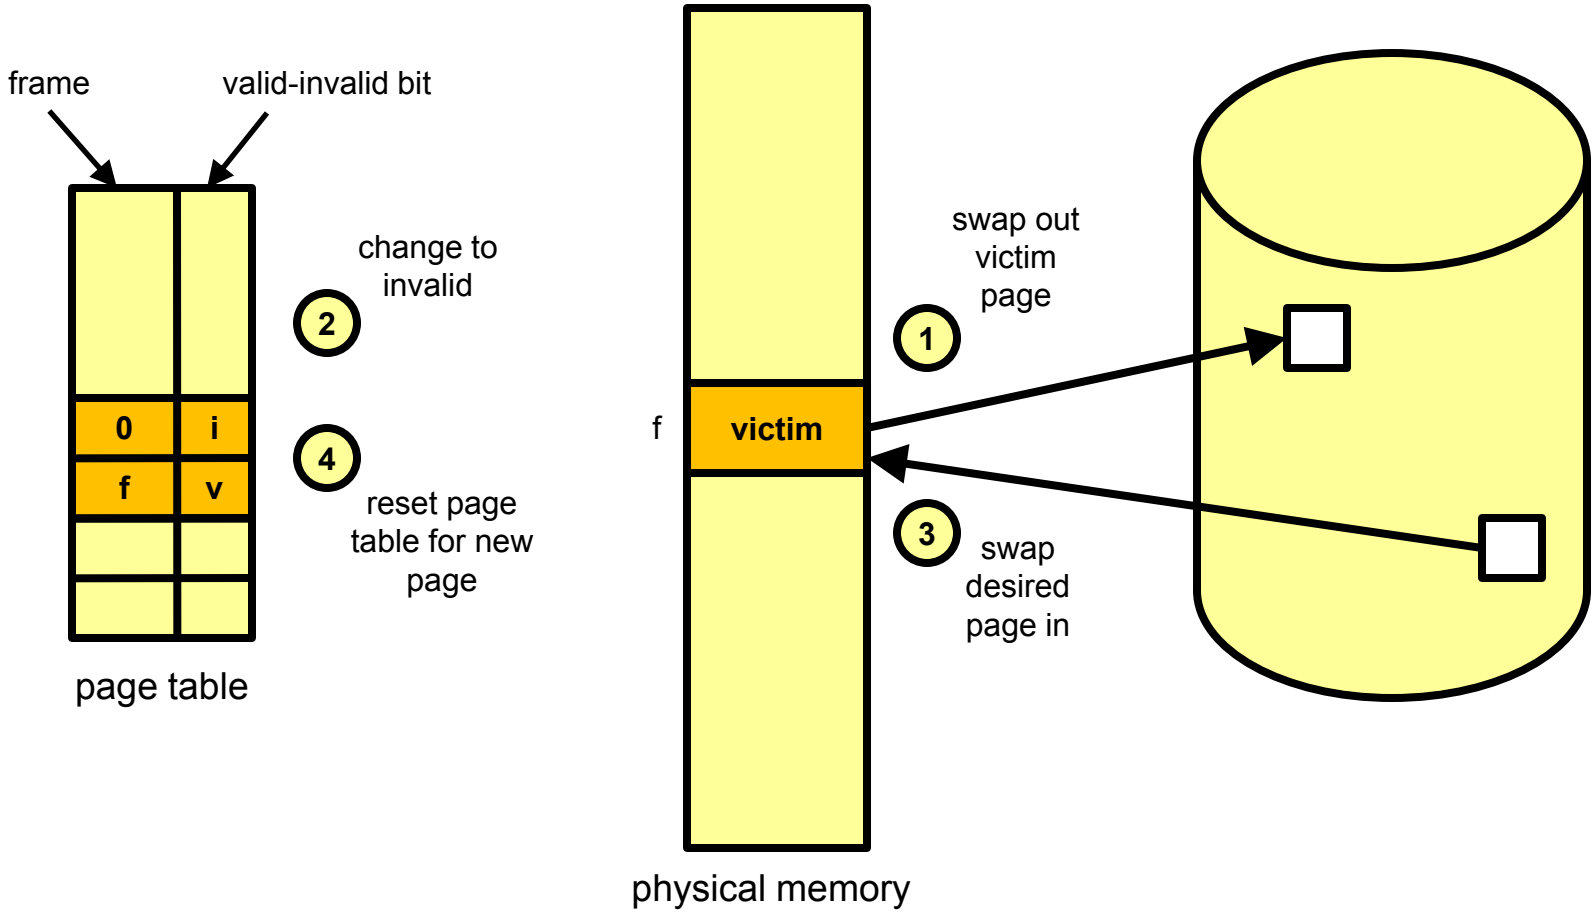

ALGORITMY URČENÍ OBĚTI

- Kritérium optimality
  - nejmenší pravděpodobnost výpadku stránky
- Čím více rámců máme, tím méně často dojde k výpadku stránky

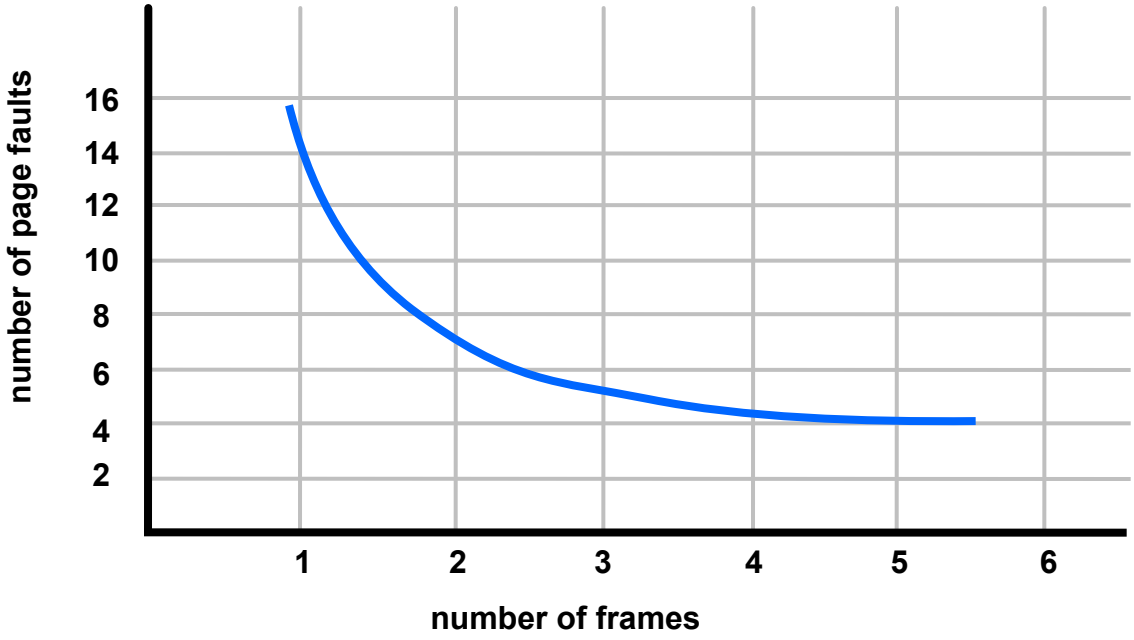

ALGORITMY URČENÍ OBĚTI

- Pouze základní typy
  - existují desítky variant
- Optimální algoritmus
  - příští odkazy na oběť je nejpozdější ze všech následných odkazů na stránky
  - generuje nejmenší počet výpadků stránek
  - neimplementovatelný, neboť neznáme budoucnost
  - používá se jen pro srovnání
- Algoritmus LRU (Least Recently Used)
  - oběť = nejdéle neodkazovaná stránka
- Algoritmus FIFO (First-In-First-Out)
  - oběť = stránka nejdéle zobrazená ve FAP
- Algoritmus poslední šance
  - FIFO + vynechávání z výběru těch stránek, na které od posledního výběru bylo odkázáno

ALGORITMUS FIRST-IN-FIRST-OUT

- Posloupnost odkazů stránek:

  1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5

- 5 stránek
- 3 rámce (3 stránky mohou být ve FAP)
- 4 rámce
  - Beladyho *anomálie*
  - více rámců → více výpadků

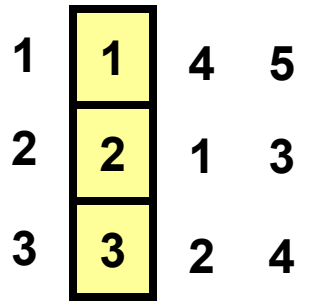

9 výpadků

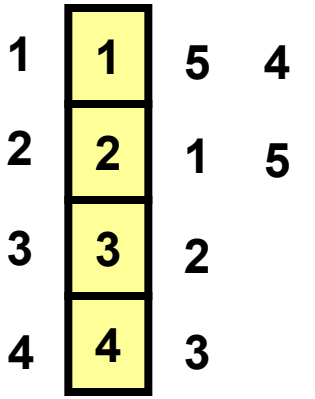

10 výpadků

BELADYHO ANOMÁLIE

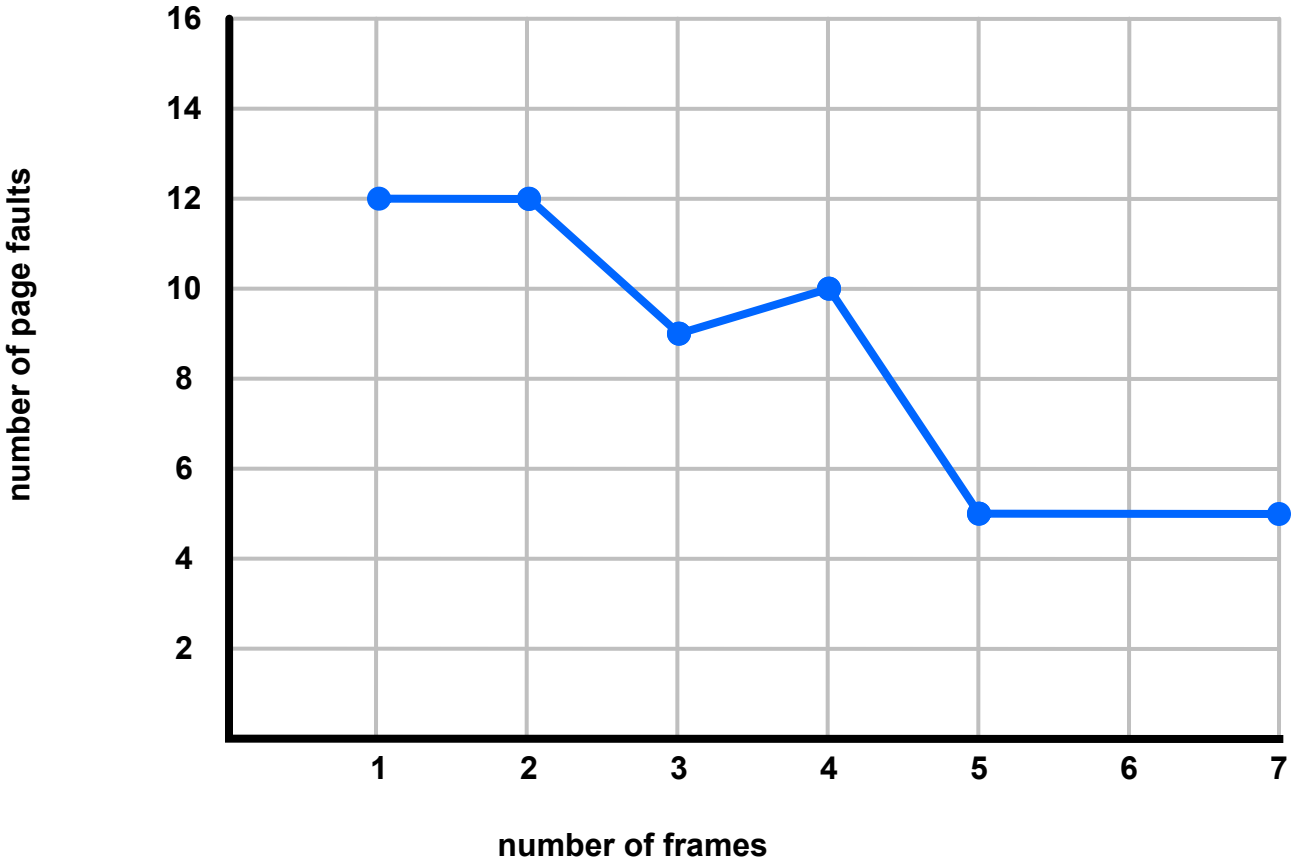

ALGORITMUS FIRST-IN-FIRST-OUT

- Hodnocení FIFO strategie
  - často používané stránky jsou v mnoha případech právě ty nejstarší
    - pravděpodobnost výpadku takové stránky je vysoká
    - tj. algoritmus zbytečně odkládá často používané stránky
  - jednoduchá implementace
    - stačí udržovat ukazatelem vazbu do cyklického pořadí

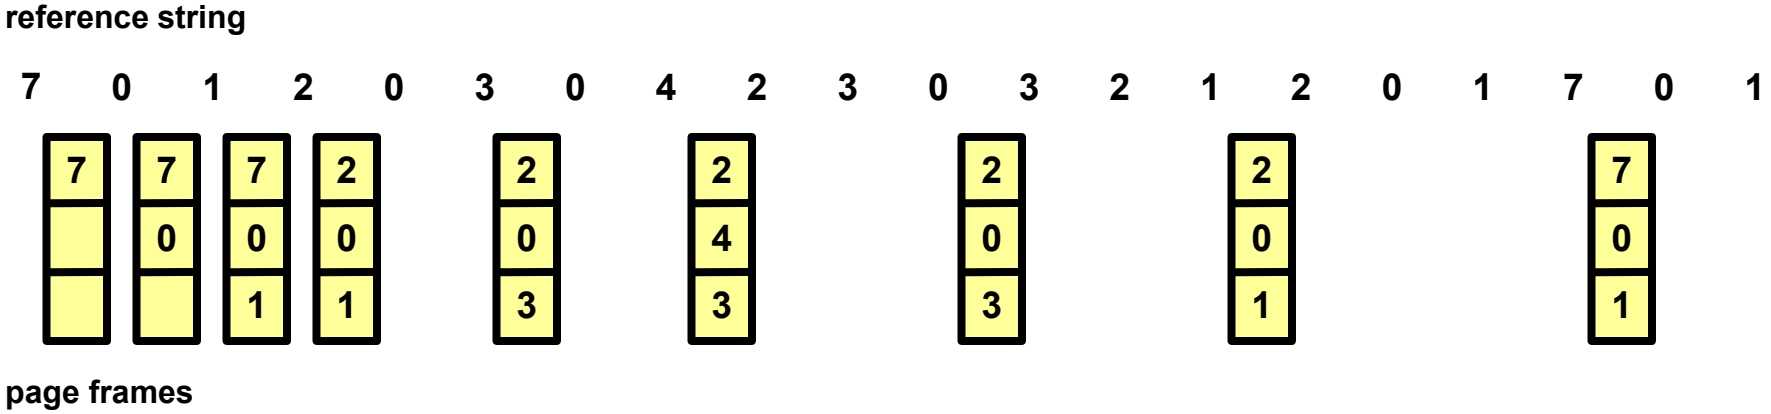

OPTIMÁLNÍ ALGORITMUS

- Obětí je nejpozdější ze všech následných odkazů na stránky
- Potřebuje znát budoucí posloupnost referencí
- Příklad
  - proces s 5 stránkami
  - k dispozici máme 4 rámce
  - Posloupnost přístupů:
    1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5
  - celkem 6 výpadků stránky

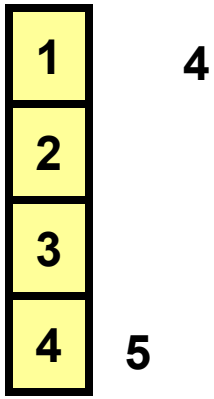

OPTIMÁLNÍ ALGORITMUS

- Další příklad:

reference string

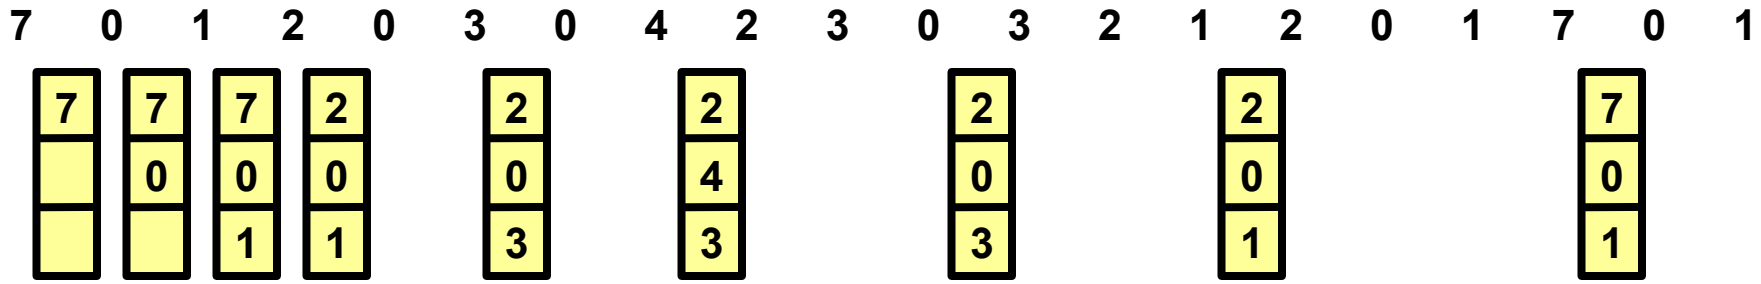

page frames

ALGORITMUS LRU

- Obětí je nejdéle neodkazovaná stránka
  - princip lokality říká, že pravděpodobnost jejího brzkého použití je velmi malá
  - výkon blízký optimální strategii
- Příklad:
  - proces s 5 stránkami, k dispozici 4 rámce
  - 1, 2, 3, 4, 1, 2, **5**, 1, 2, **3**, **4**, **5**

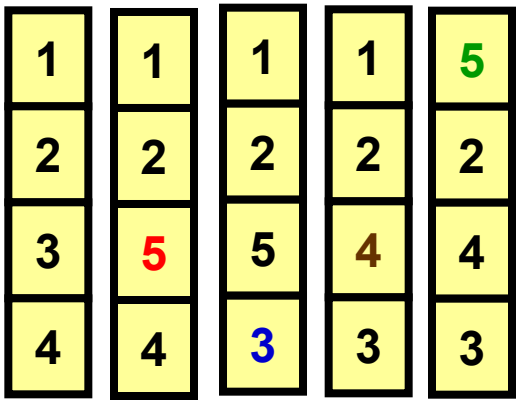

ALGORITMUS LRU

- Další příklad:

reference string

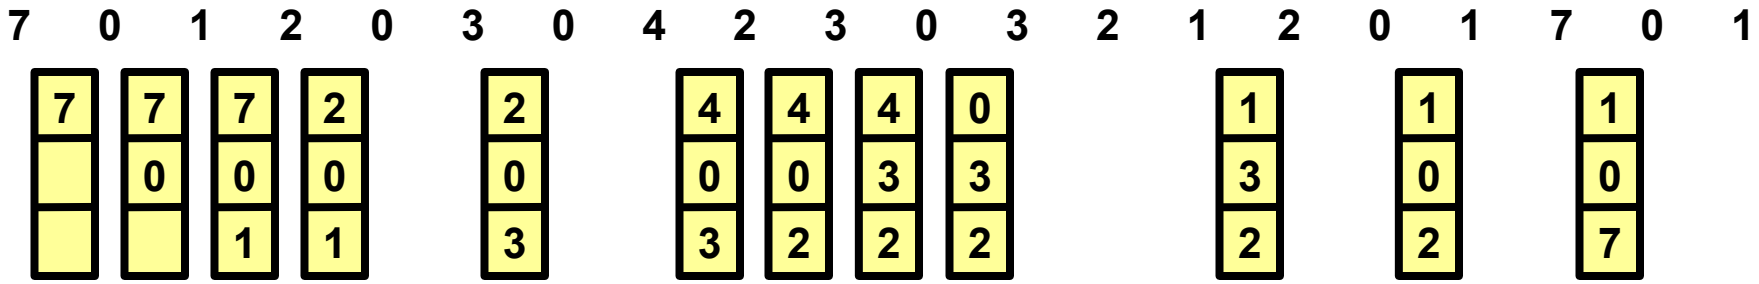

page frames

IMPLEMENTACE POLITIKY LRU

- V položkách PT se udržuje (HW) čítač (sekvenční číslo nebo logický čas) posledního přístupu ke stránce
  - čítač má konečnou kapacitu
  - problém jeho přečtení
- Zásobník
  - zásobník čísel stránek, při přístupu ke stránce je položka odstraněna ze zásobníku a přemístěna na vrchol (na spodu je „oběť“)
- Aproximace: iniciálně je bit nastaven na 0, při každém přístupu je nastaven bit přístupu na 1
  - neznáme pořadí přístupu ke stránkám
  - víme jen které stránky byly použity

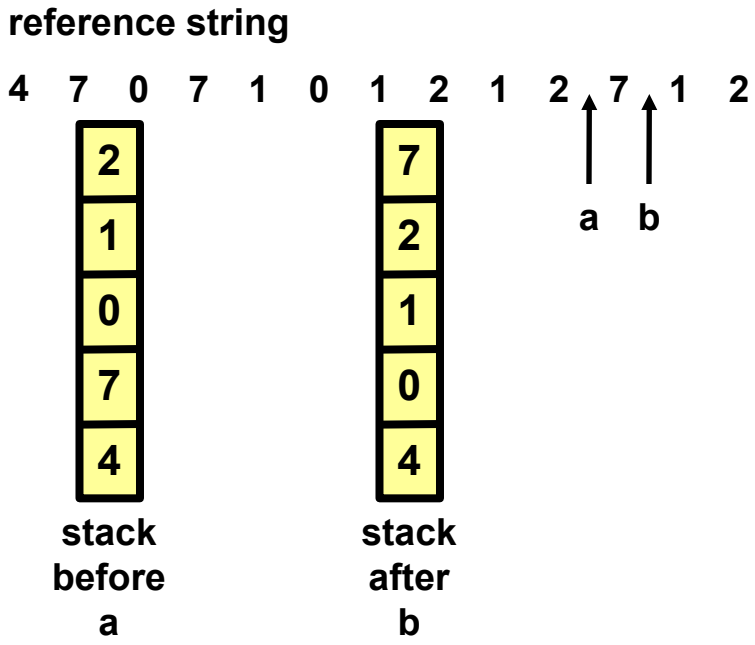

DRUHÁ ŠANCE

- Také nazývané „Máš ještě šanci“
- Výběr oběti – cyklické procházení
  (podobně jako FIFO)
- Odkazem na stránku stránka se nastaví příznak
  - ani násobné odkazy příznak nezvyšují, jen nastavují
- Oběť, která nemá nastaven příznak a je na řadě
  při kruhovém procházení je nahrazovaná
- Experimenty ukazují, že optimalita algoritmu se blíží
  skutečnému LRU

DRUHÁ ŠANCE (2)

- Implementace
  - Množina rámců kandidujících na nahrazení je organizována jako cyklický buffer
  - Když se stránka nahradí, ukazatel se posune na příští rámec v bufferu
  - Pro každý rámec se nastavuje „use bit“ na 1 když
    - se do rámce zavede stránka poprvé
    - kdykoliv se odpovídající stránka referencuje
  - Když se má nalézt oběť, nahradí se stránka v prvním rámci s „use bit“ nastaveným na 0.
    - Při hledání kandidáta na nahrazení se každý „use bit“ nastavený na 1 nastavuje na 0

DRUHÁ ŠANCE (3)

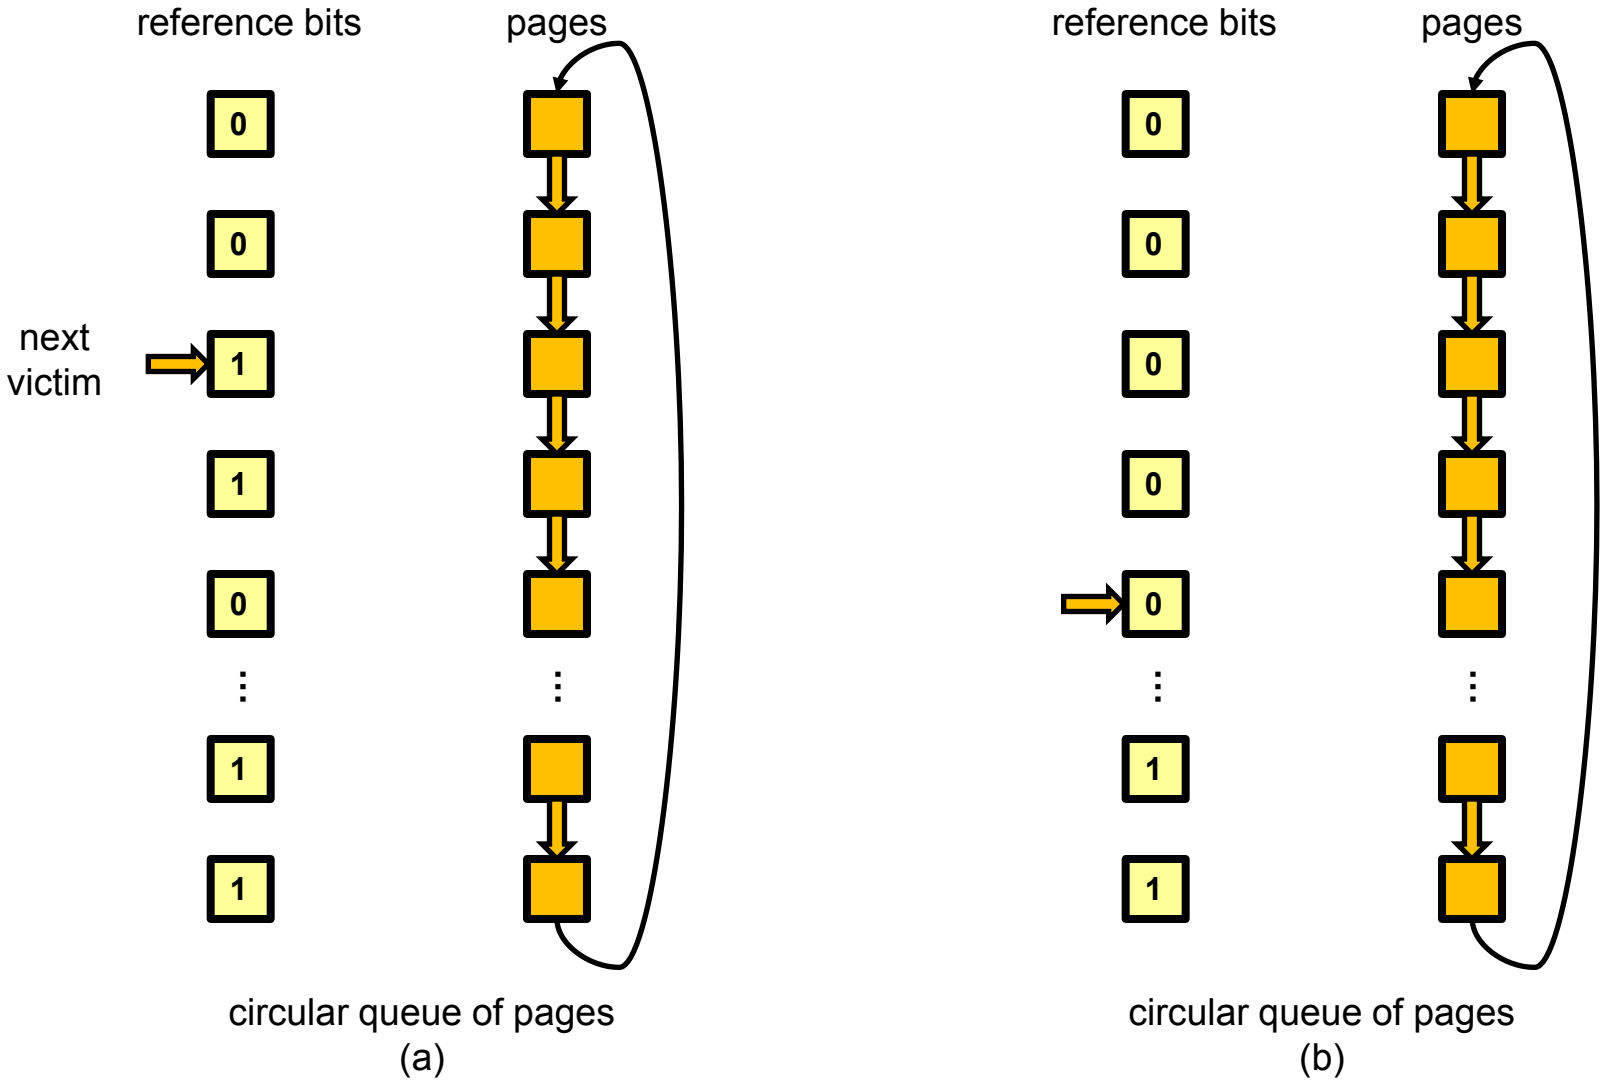

circular queue of pages
(a)

circular queue of pages
(b)

SROVNÁNÍ ALGORITMŮ

- OPT
  - super, ale nutnost znát budoucnost
- LRU
  - časové čítače u rámců, Δt + 1, nulované odkazem
  - oběť = rámec s nejvyšší hodnotou čítače
  - Implementace má vysokou režii
- FIFO
  - snadná implementace, cyklický seznam
  - špatná heuristika
- Druhá šance
  - upravené FIFO
  - z výběru obětí se vynechává alespoň jednou odkázaná stránka od posledního výběru
  - use_bit = (počátečně) 0 / po odkazu 1
  - úprava druhá šance
    - use_bit = 0 / 1, doplněný modified_bit = 0 / 1
    - pořadí výběru: 00, 01, 1x
    - 0x šetří výpis nemodifikované stránky

STRUKTURA PROGRAMU

- `int data[128][128];`
- Jeden řádek odpovídá jedné stránce
- Program 1

```
for (j = 0; j <128; j++)
    for (i = 0; i < 128; i++)
        data[i,j] = 0;
```

  - 128 x 128 = 16,384 výpadků stránky
- Program 2

```
for (i = 0; i < 128; i++)
    for (j = 0; j < 128; j++)
        data[i,j] = 0;
```

  - 128 výpadků stránky

THRASHING

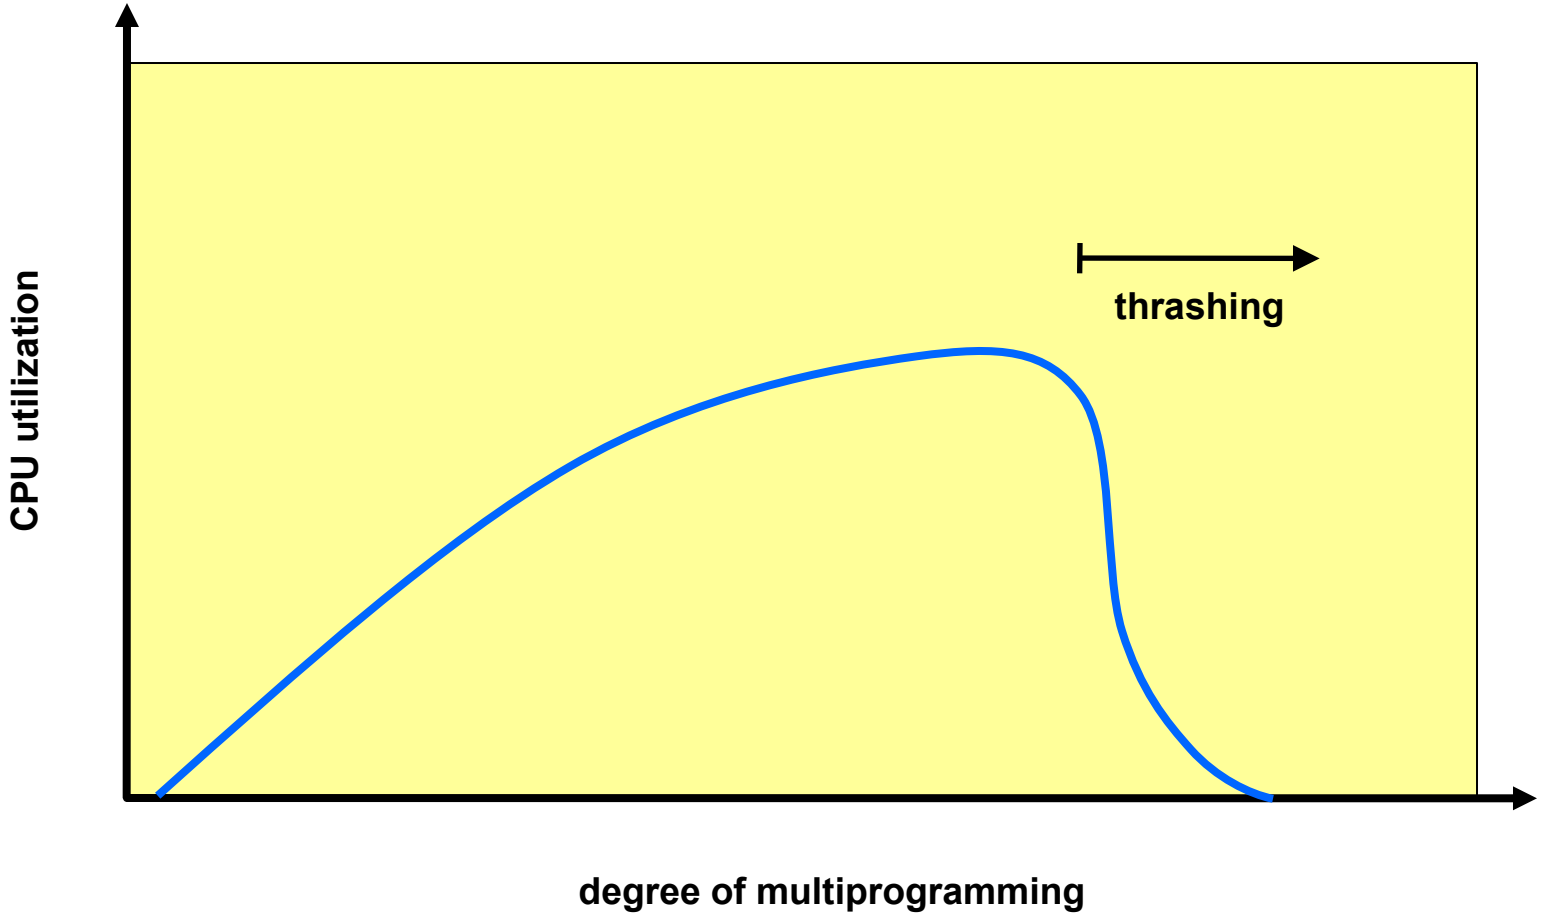

BUDDY ALOKAČNÍ ALGORITMUS

	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K	64K
t = 0	1024K															
t = 1	A-64K	64K	128K		256K				512K							
t = 2	A-64K	64K	B-128K		256K				512K							
t = 3	A-64K	C-64K	B-128K		256K				512K							
t = 4	A-64K	C-64K	B-128K		D-128K		128K		512K							
t = 5	A-64K	64K	B-128K		D-128K		128K		512K							
t = 6	128K		B-128K		D-128K		128K		512K							
t = 7	256K				D-128K		128K		512K							
t = 8	1024K															

1. A alokuje 64K
2. B alokuje 128K
3. C alokuje 64K
4. D alokuje 128K
5. C uvolňuje paměť
6. A uvolňuje paměť
7. B uvolňuje paměť
8. D uvolňuje paměť

PŘÍKLAD: LINUX 2.4

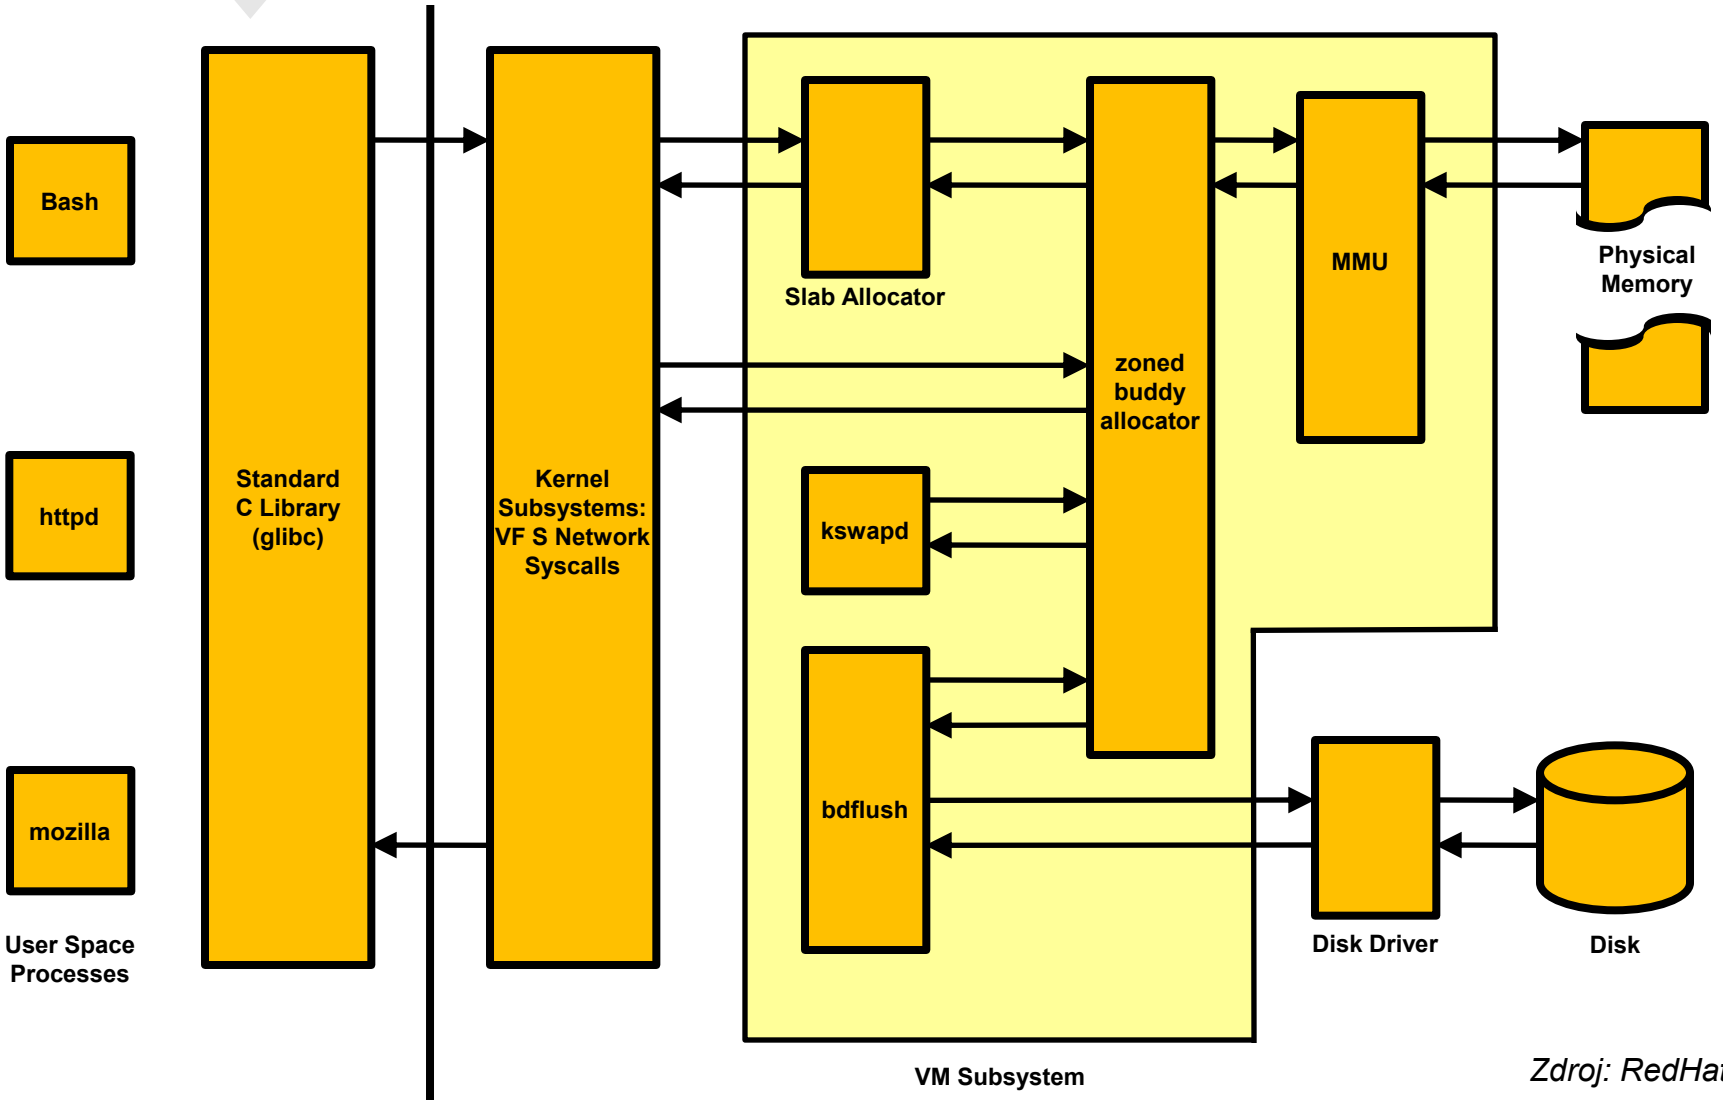

Zdroj: RedHat

PŘÍKLAD: LINUX 2.4

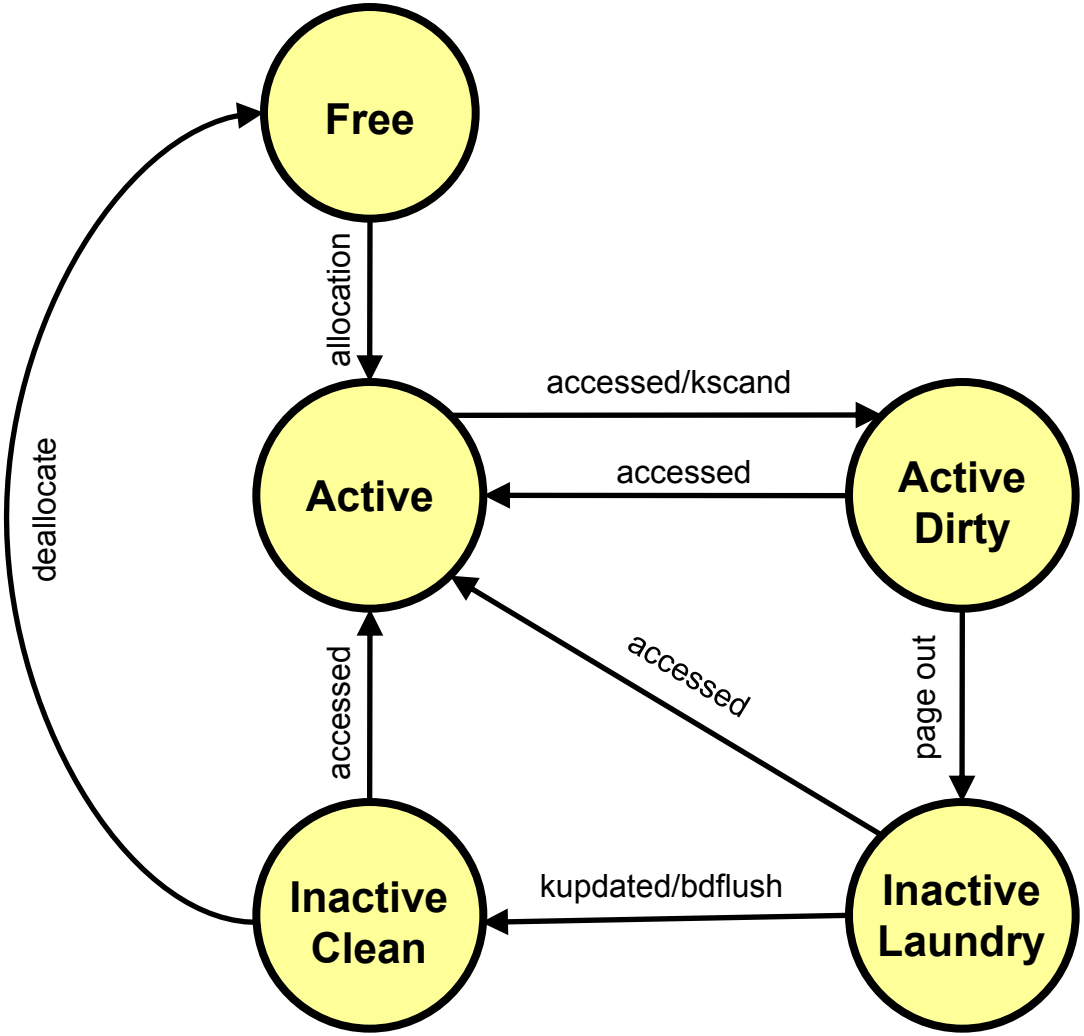

Zdroj: RedHat

PŘÍKLAD: LINUX 2.4

- Kscand
- Kswapd
  - Prochází paměť a hledá stránky k uvolnění pokud dochází paměť
- Kupdated [dirty pages; pravidelně] + Bdflush (2.4) [dirty buffers; v případě potřeby]
- Pdflush (2.6) [dirty pages]
  - Zapisuje na disk

DOCUMENTATION/SYSCTL/VM.TXT

- Currently (2.6.32), these files are in /proc/sys/vm:

- block_dump
- dirty_background_bytes
- dirty_background_ratio
- dirty_bytes
- dirty_expire_centisecs
- dirty_ratio
- dirty_writeback_centisecs
- drop_caches
- hugepages_treat_as_movabl
- hugetlb_shm_group
- laptop_mode
- legacy_va_layout
- lowmem_reserve_ratio
- max_map_count
- memory_failure_early_kill
- memory_failure_recovery
- min_free_kbytes
- min_slab_ratio
- min_unmapped_ratio
- mmap_min_addr
- nr_hugepages
- nr_overcommit_hugepages
- nr_pdflush_threads
- nr_trim_pages
- numa_zonelist_order
- oom_dump_tasks
- oom_kill_allocating_task
- overcommit_memory
- overcommit_ratio
- page-cluster
- panic_on_oom
- percpu_pagelist_fraction
- stat_interval
- swappiness
- vfs_cache_pressure
- zone_reclaim_mode

Výukovou pomůcku zpracovalo

Servisní středisko pro e-learning na MU

CZ.1.07/2.2.00/28.0041
Centrum interaktivních a multimediálních studijních opor pro inovaci výuky a efektivní učení

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ