Laboratório de Pesquisa em Redes e Multimídia

Unix: Processos e o Kernel

Universidade Federal do Espírito Santo
Departamento de Informática

Sistemas Operacionais

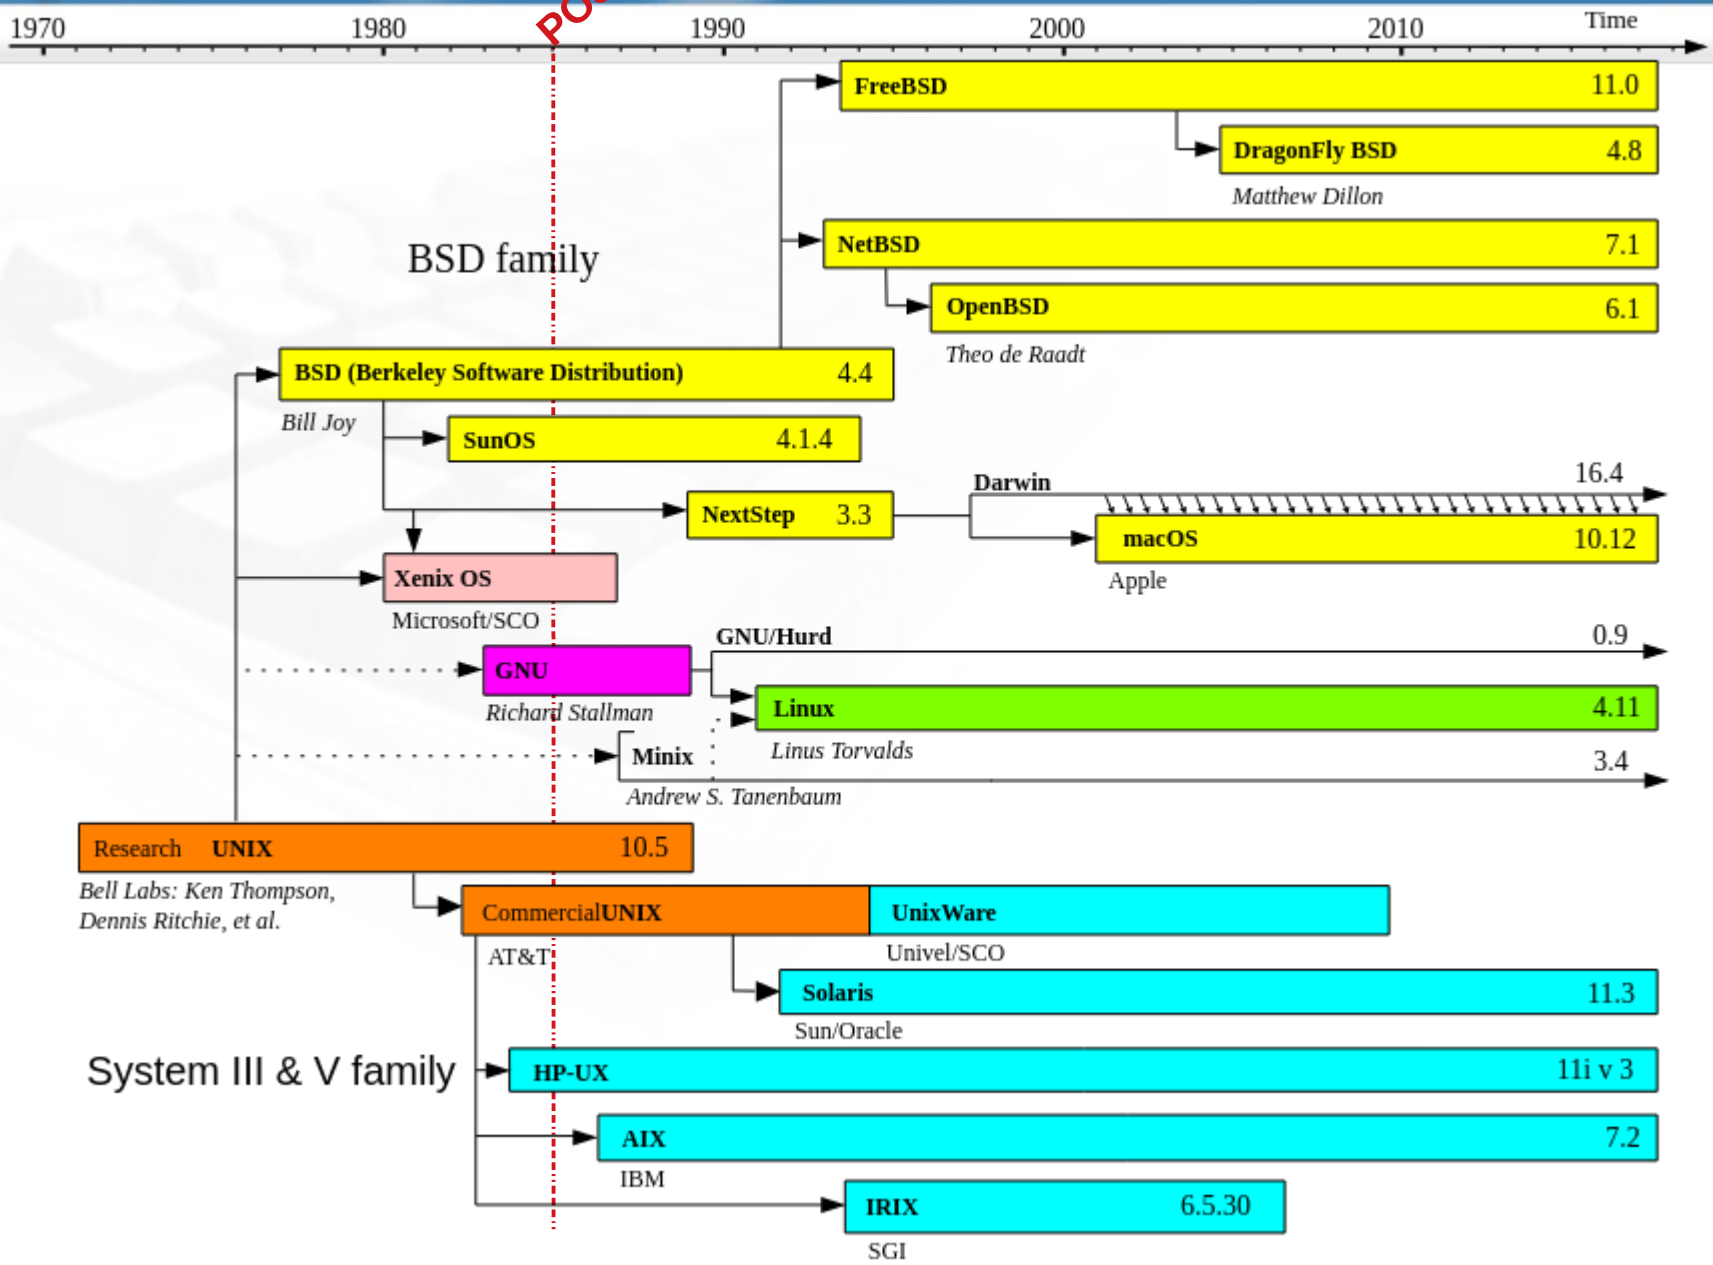
1970
1980
POSIX
1990
2000
2010
Time
BSD family
FreeBSD 11.0
DragonFly BSD 4.8
Matthew Dillon
NetBSD 7.1
OpenBSD 6.1
Theo de Raadt
BSD (Berkeley Software Distribution) 4.4
Bill Joy
SunOS 4.1.4
NextStep 3.3
Darwin 16.4
macOS 10.12
Apple
Xenix OS
Microsoft/SCO
GNU/Hurd 0.9
GNU
Richard Stallman
Linux 4.11
Linus Torvalds
Minix 3.4
Andrew S. Tanenbaum
Research UNIX 10.5
Bell Labs: Ken Thompson, Dennis Ritchie, et al.
CommercialUNIX
UnixWare
Univel/SCO
AT&T
Solaris 11.3
Sun/Oracle
System III & V family
HP-UX 11i v 3
AIX 7.2
IBM
IRIX 6.5.30
SGI

O Kernel

- É um programa especial, uma parte privilegiada do sistema operacional, que roda diretamente sobre o hardware.
  - Ele implementa o modelo de processos do sistema
  - O kernel não é um processo!
- O kernel oferece uma série de serviços
- No Unix, o código do kernel reside em um arquivo em disco
  - *no Ubuntu, /boot/vmlinuz...*
- Programa *bootstrapping* carrega o kernel para a memória na inicialização do sistema.

A Abstração “Processo”

- Processo é uma entidade que **executa** um programa e que provê um **ambiente de execução** para ele
- Processos têm um ciclo de vida:
  - São criados pelas SVCs *fork* ou *vfork* e rodam até que sejam terminados (por meio da primitiva *exit*).
- Durante a sua execução um processo pode rodar um ou mais programas
  - A primitiva ***exec*** é invocada para rodar um novo programa.
- Processos no Unix possuem uma **hierarquia**
  - Cada processo tem um processo pai (*parent process*) e pode ter um ou mais processos filhos (*child processes*).

A Abstração "Processo" (cont.)

- O processo ***init* (PID 1)** localiza-se no topo da hierarquia de processos de usuário do Unix.
  - Primeiro processo de usuário a ser criado, quando o sistema é iniciado.
  - Executa o programa */etc/init* ou */sbin/init*
- Todos os processos descendem do processo *init*, à exceção de alguns poucos, como o *swapper* ou o ***kthreadd*** *(Linux)*
  - Esses também são criados na inicialização do sistema e ajudam o kernel na execução das suas tarefas
  - Diferentemente do *init*, esses processos são implementados dentro do próprio kernel, ou seja, não há um programa binário regular para eles
- **Se, ao terminar, um processo tiver processos filhos ativos, estes tornam-se órfãos e são herdados pelo processo *init*.**

Imagem do Processo (UNIX... não Linux!)

Espaço de endereçamento do usuário

Texto (código), dados, *user stack*, regiões de memória compartilhada, etc.

Informações de controle

Armazenadas em estruturas mantidas pelo kernel

***u area* e *proc* structure**

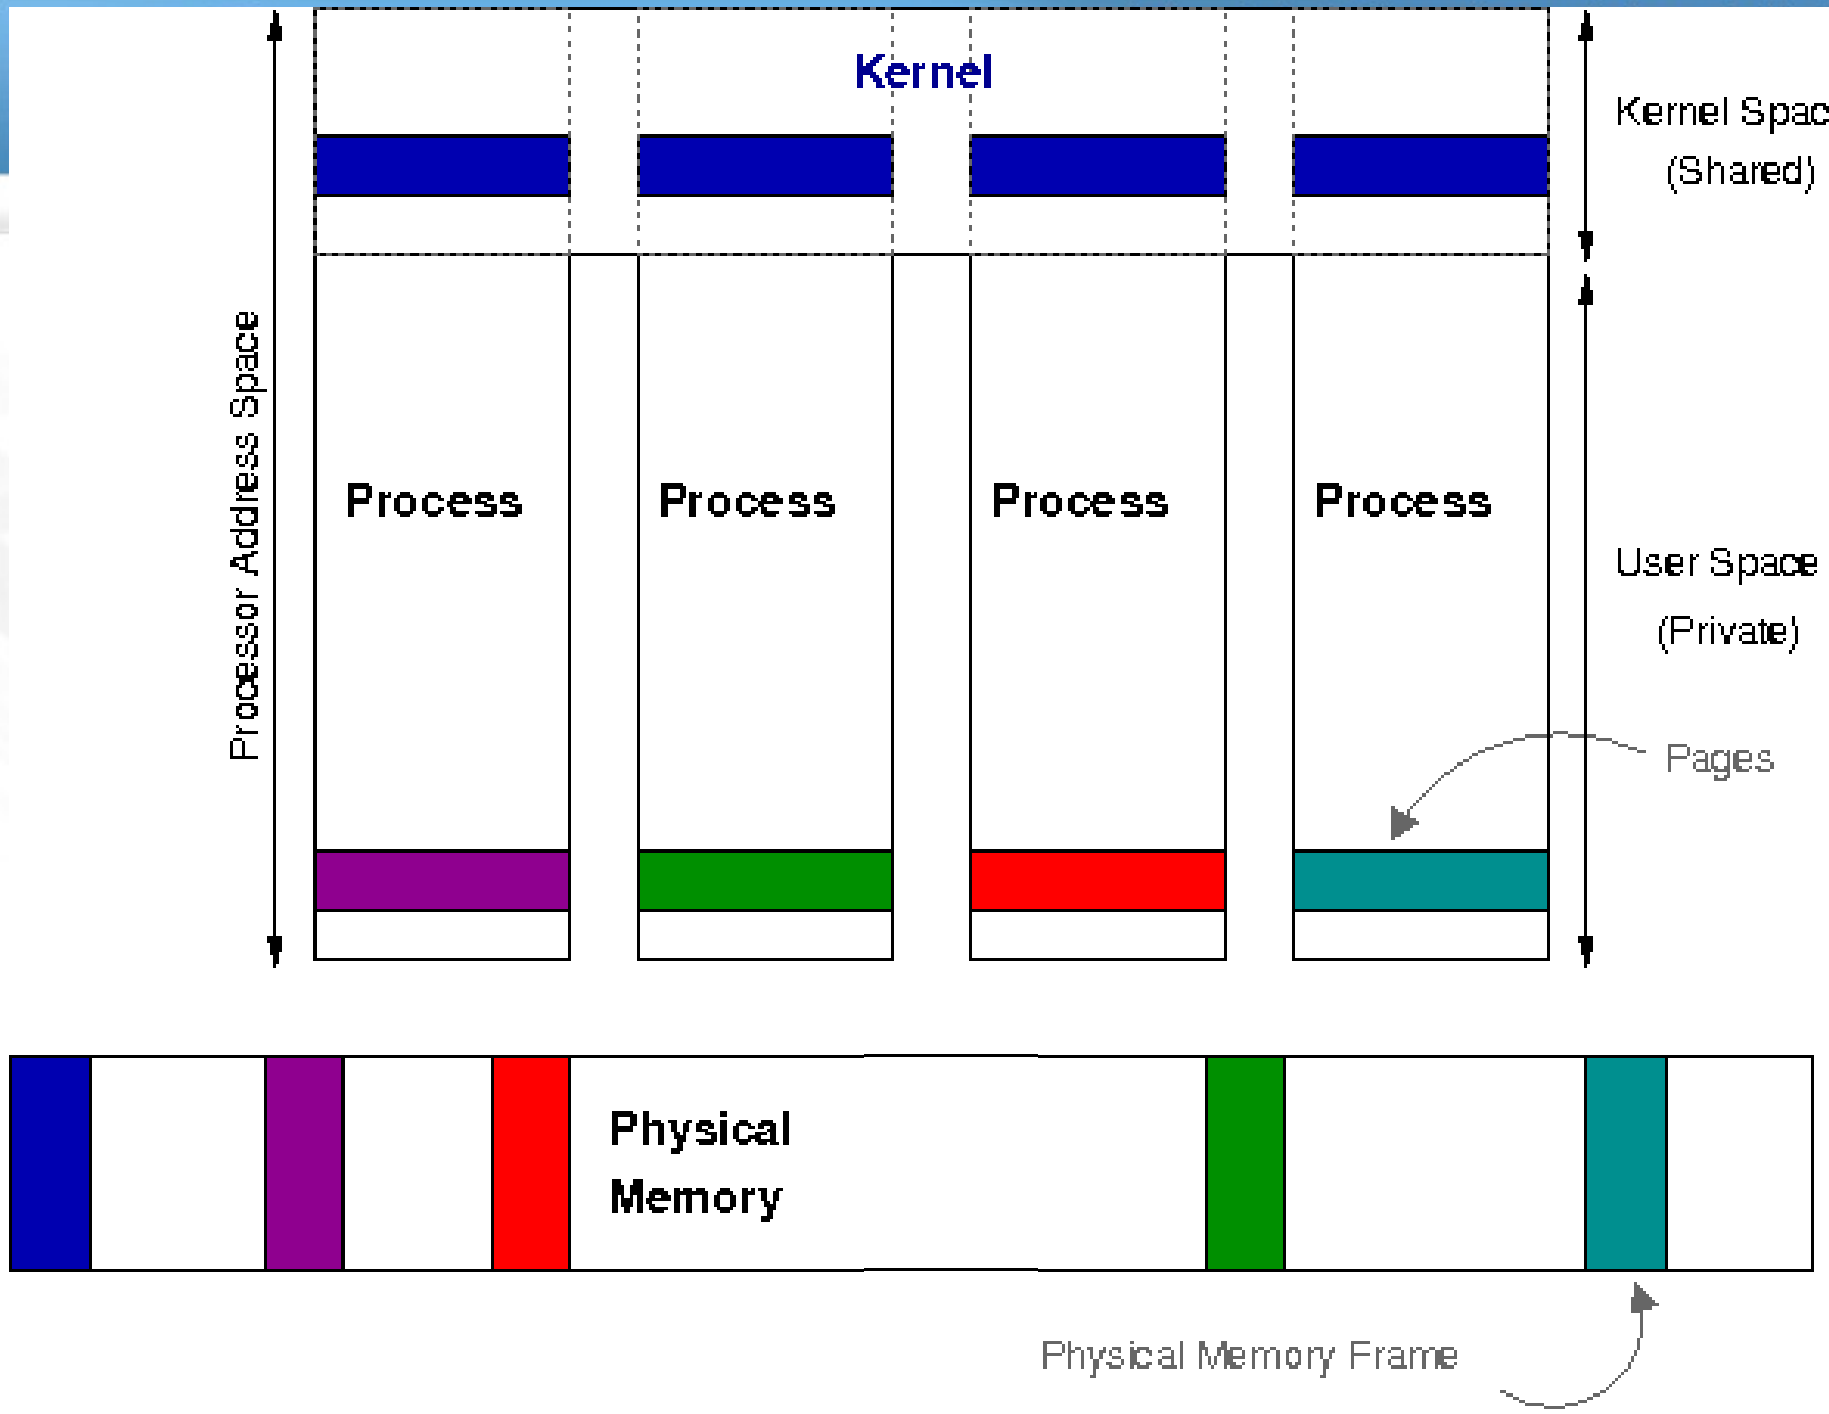
Kernel
Kernel Space
(Shared)
Processor Address Space
Process
Process
Process
Process
User Space
(Private)
Pages
Physical
Memory
Physical Memory Frame

Processo e Memória Virtual

- A maioria das implementações do UNIX usa memória virtual
  - Endereços utilizados no programa não referenciam diretamente memória física
  - Cada processo possui seu **“espaço de endereçamento virtual”**
    - Endereços virtuais são traduzidos para uma localização física na memória principal (e.g. tabela de páginas)
  - Processos só podem acessar endereços dentro deste espaço
- O Espaço de endereçamento é dividido em:
  - ***Process Space***
  - ***System Space*** *ou kernel space*
    - Parte fixa do espaço de endereçamento virtual mapeia o “kernel text” e as estruturas de dados do kernel

System(Kernel) Space x Process Space

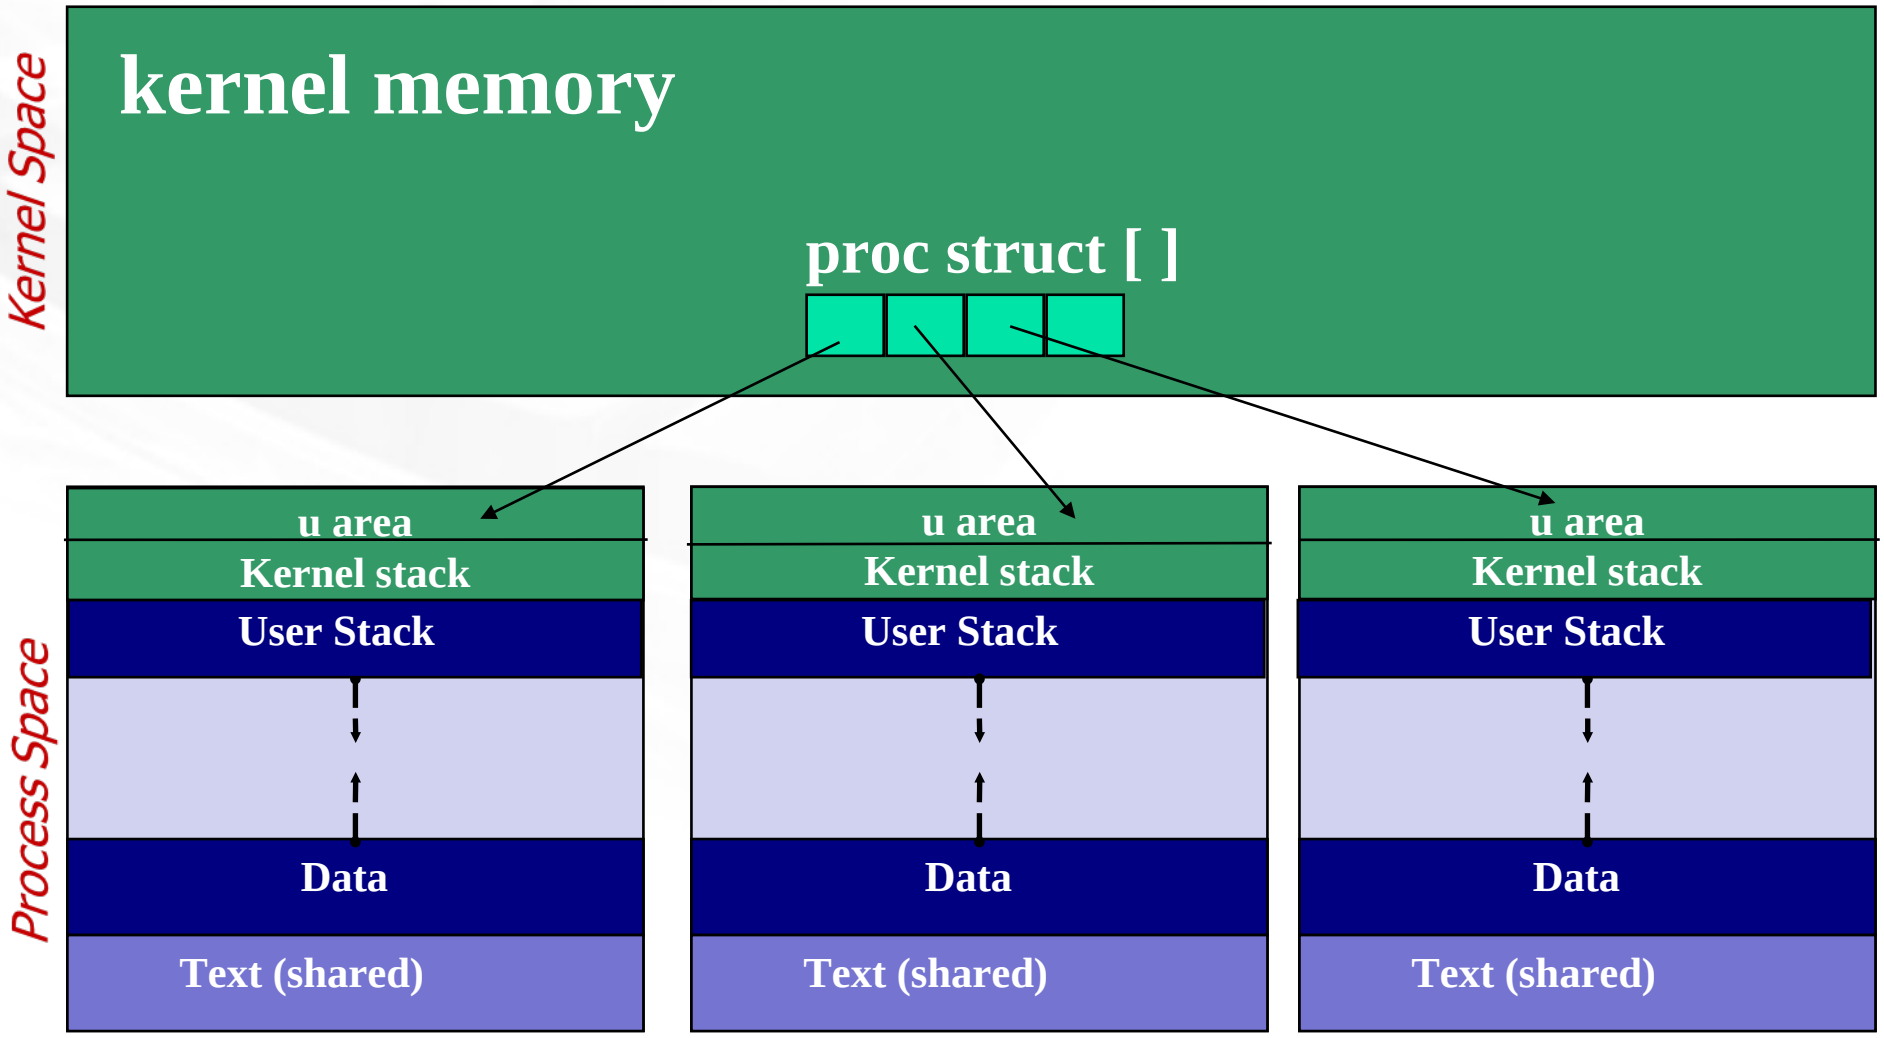

System (Kernel) Space

- Além de código e dados do usuário, parte do espaço de endereçamento virtual de cada processo refere-se a código e dados do kernel (que, afinal, roda em benefício dos processos).
- Esta porção é conhecida como *system space* ou *kernel space*, e só pode ser acessada em *kernel mode*.
- Como existe apenas uma instância do kernel todos os processos são mapeados em um único *kernel address space*.
- O kernel mantém algumas estruturas de dados globais e algumas específicas para cada processo (“per-process objects”).
- Essas últimas contêm informações que permitem ao kernel acessar o espaço de endereçamento de qualquer processo.

Estruturas de Controle

- Proc Structure
  - Contém todas as informações que o kernel posssa precisar quando um processo **NÃO está *running***
  - Encontra-se no *system space*
- u Area
  - Contém informações necessárias apenas quando o processo está *running*, ou vai entrar nesse estado
  - Encontra-se no *process space*

Proc Structure

- Contém todas as informações que o kernel posssa precisar quando um processo NÃO está *running*
- Campos da proc structure
  - Identificadores: PID, *process group*, *process session*, etc.
  - Informações de hierarquia (*p_pid*)
  - Estado corrente do processo
  - Ponteiros para linkar o processo em filas
  - Prioridade de escalonamento
  - Informações para manipulação de sinais (ignorados, bloqueados, postados, etc.)
  - Informações para gerenciamento da memória
  - Localização do mapa de endereços para a *u area* do processo

U area

- Contém informações necessárias apenas quando o processo está *running*
- É normalmente mapeada sempre num local fixo do espaço de endereçamento virtual do processo.
- Campos da u area:
  - *Hardware context* (no UNIX é chamado de “Bloco de controle de processo” !!)
  - *Real* e *effective* UID e GID (credenciais do usuário)
  - Argumentos, valores de retorno e status de erros da SVC corrente
  - *Handlers* de sinais e informações relacionadas
  - Informações do header do processo, como tamanho das áreas de texto, dados e pilha
  - Tabela de descritores de arquivos abertos
  - Estatísticas de uso da CPU
  - Ponteiro para a *proc* structure

E o Linux...

Antes da versão 2.6

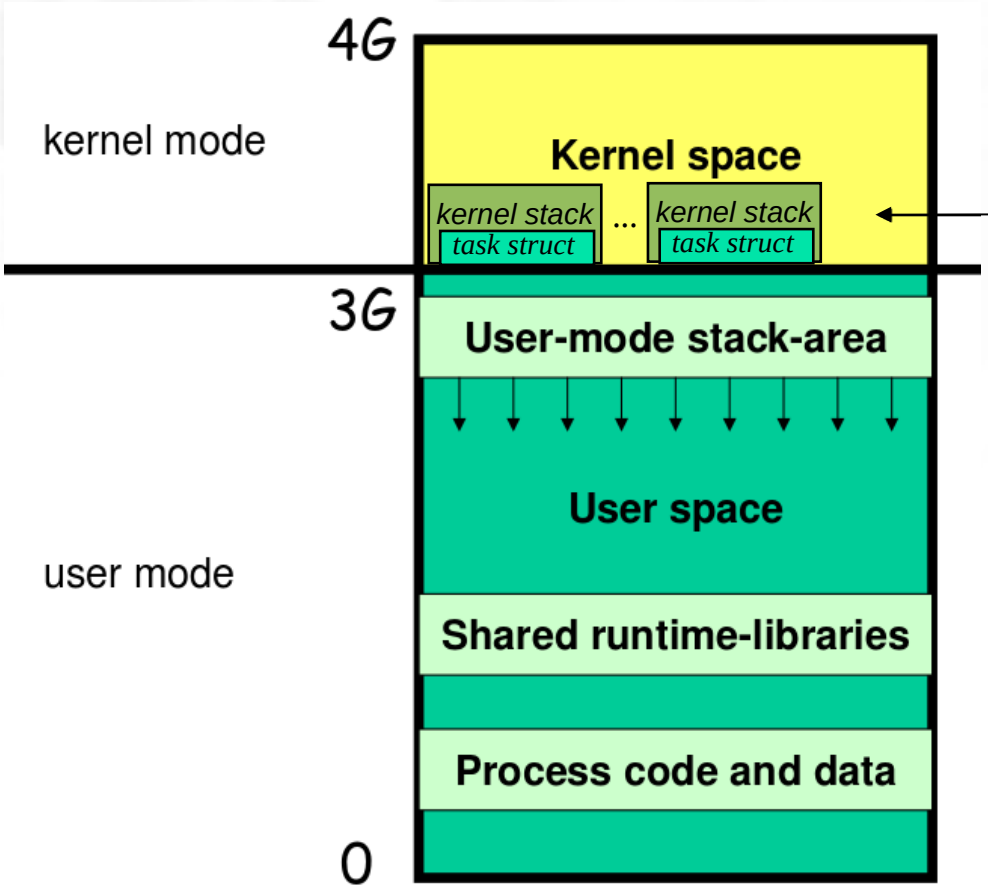

A partir da versão 2.6

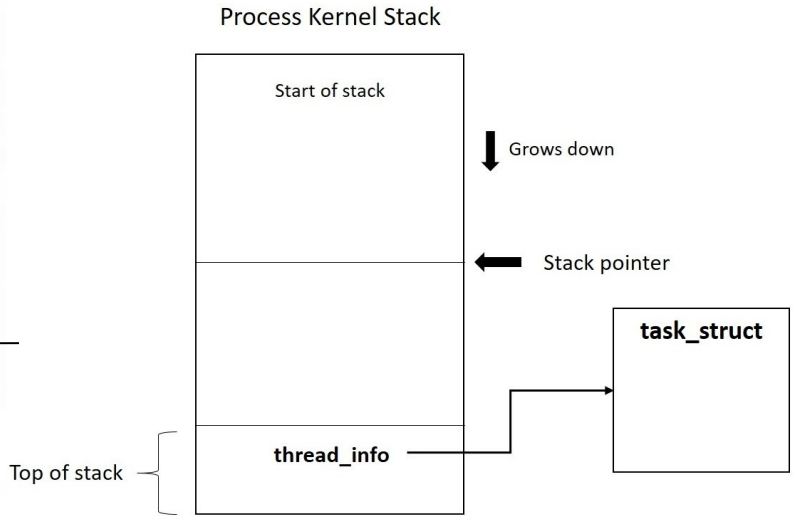

User Mode x Kernel Mode

- Com finalidade principal de proteção, a maioria dos computadores atuais fornece pelo menos dois modos de operação.
- O Unix requer do hardware a implementação de apenas 2 modos de operação:
  - *user mode* (menos privilegiado)
  - *kernel mode* (com mais privilégios).
- Processos de usuário rodam em *user mode*
  - Processos não podem – acidental ou maliciosamente – corromper outro processo ou mesmo o kernel
- Acesso ao *kernel space* só pode ser feito em *kernel mode*
  - O processo só consegue acessar o *kernel space* via SVC (portanto, acesso controlado).

User Mode/Kernel Mode x Máquina de Estados

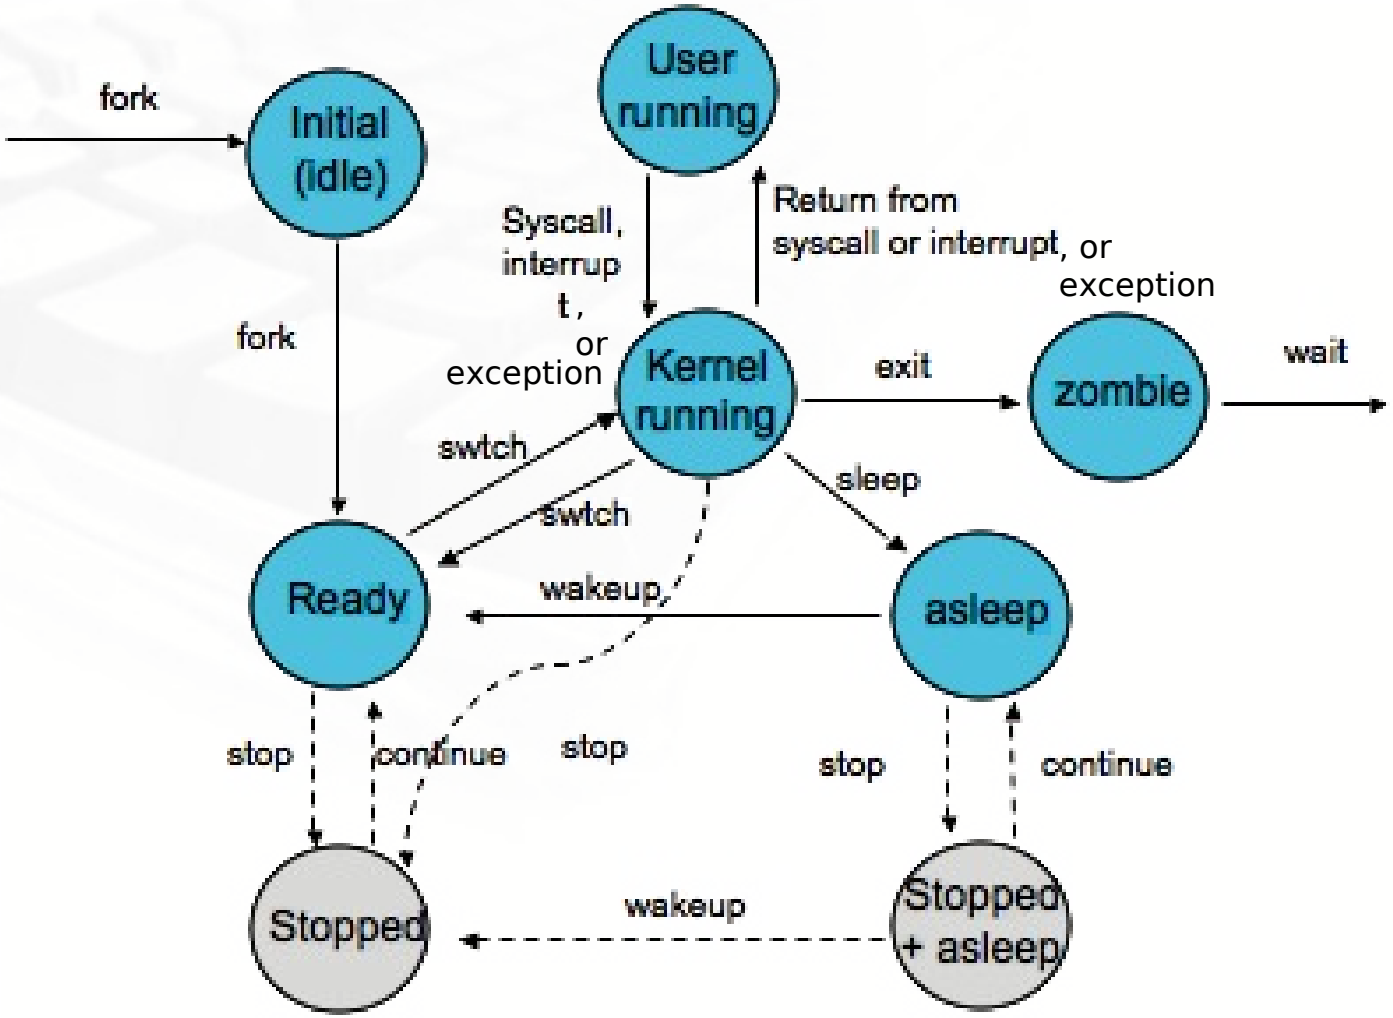

... Quando um processo é criado (**fork()**)....

1. Allocate a slot in the process table for the new process
2. Assign a unique process ID to the child process
3. Make a copy of the process image of the parent, with the exception of any shared memory
4. Increments counters for any files owned by the parent, to reflect that an additional process now also owns those files
5. Assigns the child process to the Ready to Run state
6. Returns the ID number of the child to the parent process, and a 0 value to the child process

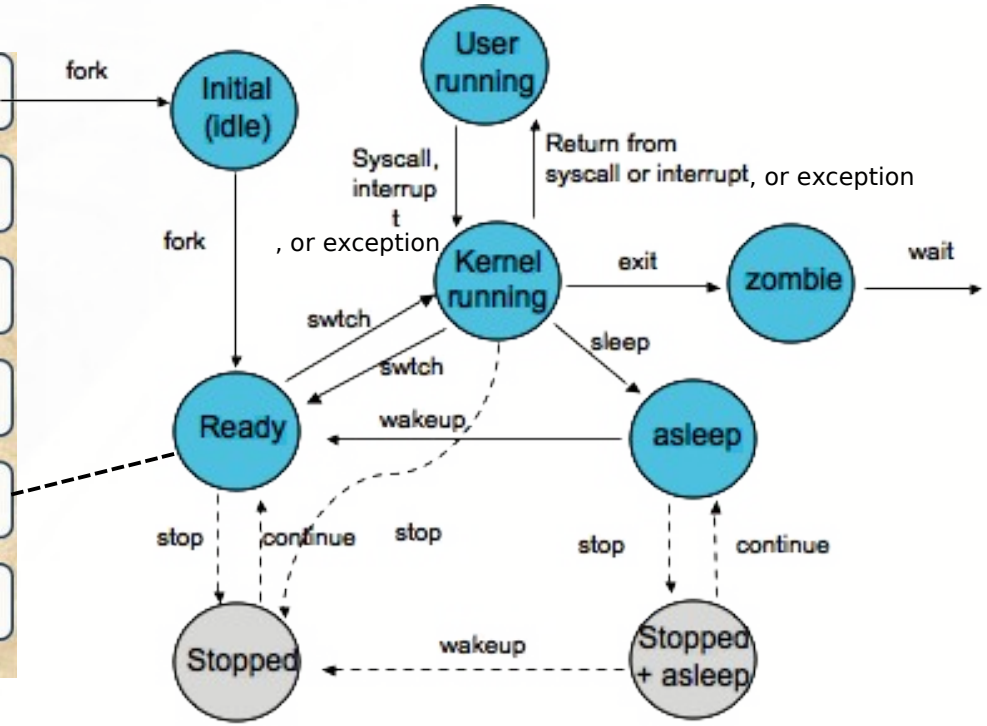

Executando em Kernel Mode

- Existem 3 tipos de eventos que fazem o sistema entrar em *kernel mode*:
  - As chamadas ao sistema (SVCs/traps/interrupções de software)
  - As interrupções provenientes dos dispositivos periféricos
  - As exceções
- Na ocorrência de uma delas, uma sequência especial de instruções é executada para por o sistema em *kernel mode* e passar o controle para o kernel.

HW alterna para kernel mode utilizando a kernel stack do processo:

- HW salva PC e Status (e possivelmente outros "estados" na kernel stack)
- SW (rotina assembly) salva outras informações necessárias para seguir o tratamento do evento

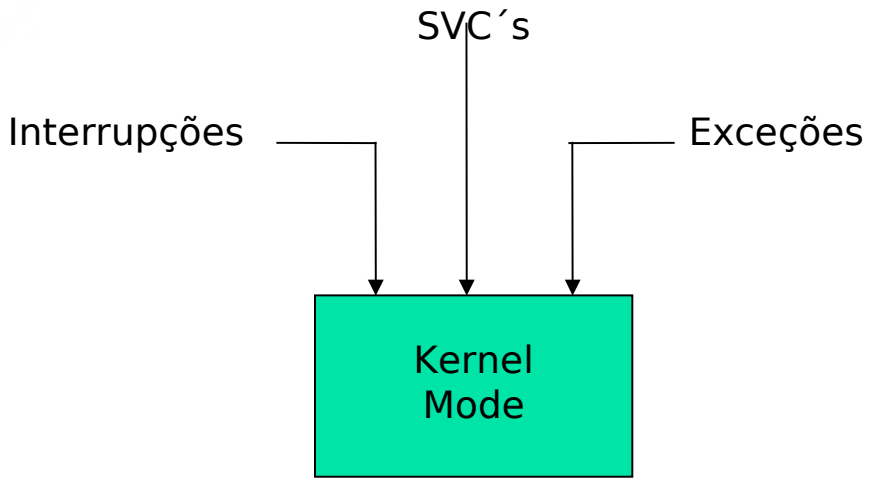

Process Context

- As funções do kernel podem ser executadas em dois contextos:
  - *Process context*
  - *System context*
- Em *process context* o kernel age em benefício do processo corrente (ex: ao executar uma SVC).
- Neste contexto, o kernel pode acessar e modificar o espaço de endereçamento, a *u area* e a *kernel stack* do processo.
- O kernel pode ainda bloquear o processo corrente se este deve esperar por um recurso ou atividade de algum dispositivo.

System Context

- Tarefas como atender a interrupções e re-computar prioridades não são executadas em benefício de um processo em particular.
  - Atividades genéricas como estas (*system-wide tasks*) são ditas executadas em *system context*.
- Quando executando em *system context*, o kernel **não pode acessar o espaço de endereçamento** (incluindo *u area* ou a *kernel stack)* do processo corrente.
- Além disso, o kernel **não pode bloquear o processo** corrente se estiver em *system context* pois poderia estar bloqueando um processo que não tem nada a ver com a tarefa sendo executada.
- Em algumas situações pode até nem ter mesmo um processo para bloquear (todos podem estar esperando por I/O).

Resumindo ...

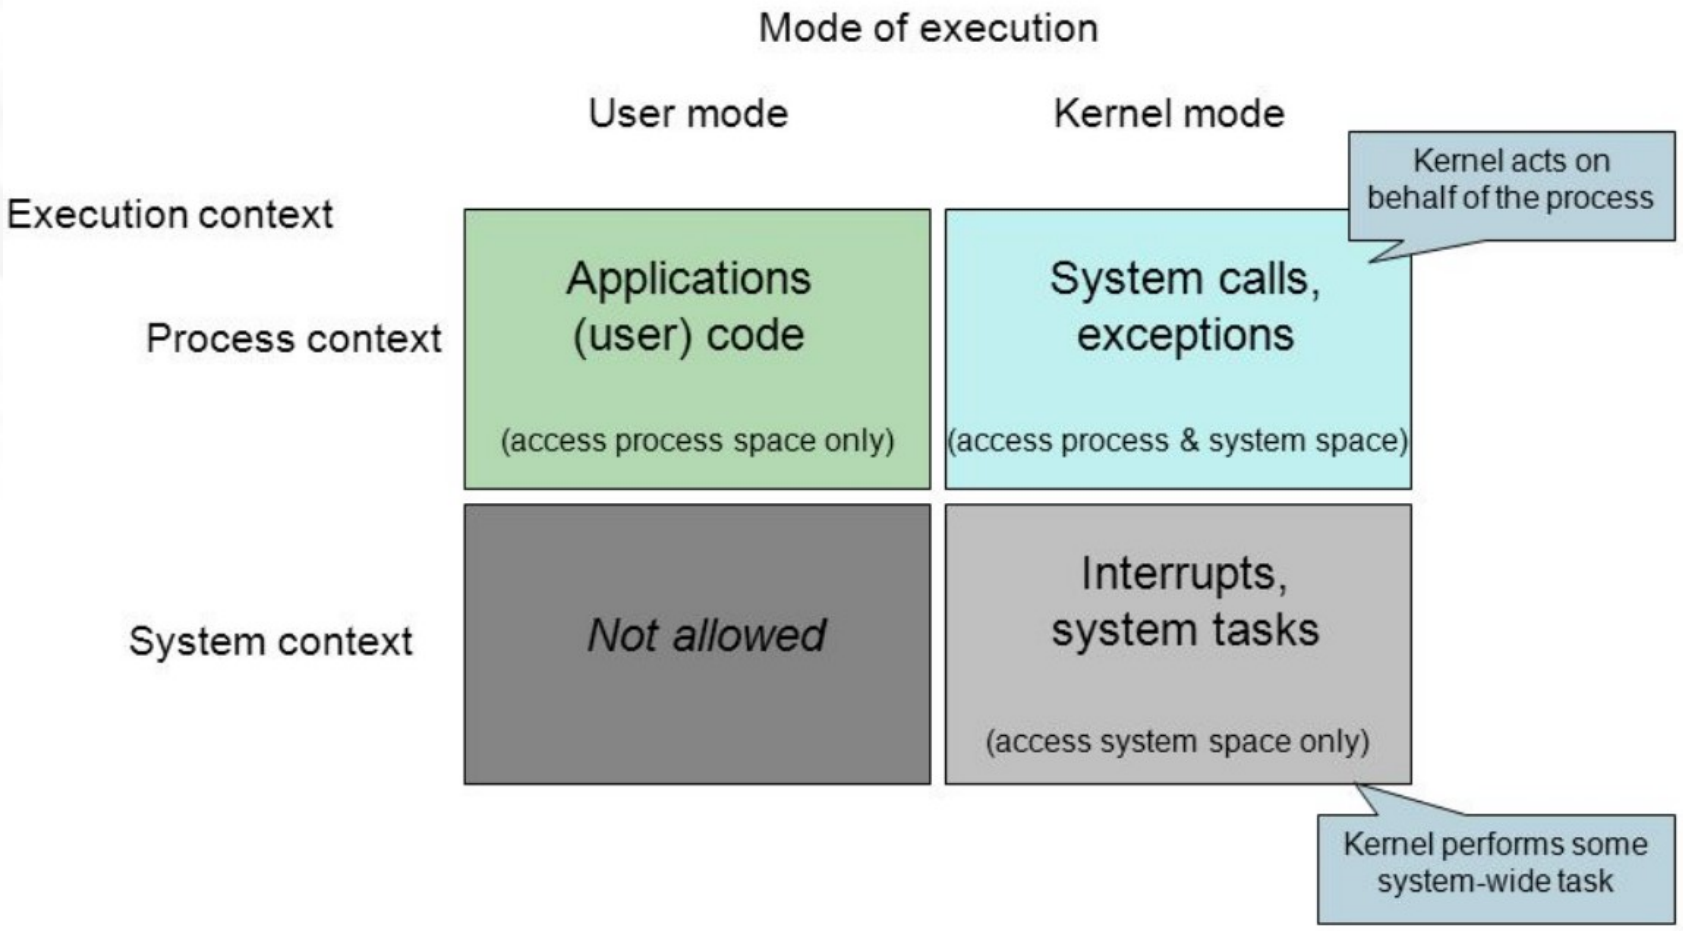
Mode of execution
User mode
Kernel mode
Execution context
Process context
System context
Applications (user) code
(access process space only)
System calls, exceptions
(access process & system space)
Kernel acts on behalf of the process
Not allowed
Interrupts, system tasks
(access system space only)
Kernel performs some system-wide task

Executando em Kernel Mode

- Existem 3 tipos de eventos que fazem o sistema entrar em *kernel mode*:
  - As chamadas ao sistema (SVCs/traps/interrupções de software)
  - As interrupções provenientes dos dispositivos periféricos
  - As exceções
- Na ocorrência de uma delas, uma sequência especial de instruções é executada para por o sistema em *kernel mode* e passar o controle para o kernel.

HW alterna para kernel mode utilizando a kernel stack do processo:

- HW salva PC e Status (e possivelmente outros "estados" na kernel stack)
- SW (rotina assembly) salva outras informações necessárias para seguir o tratamento do evento

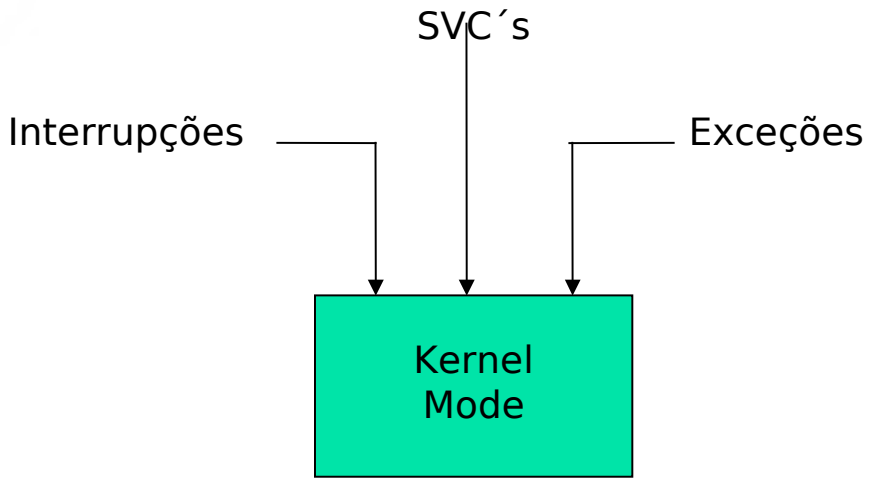

Executando em Kernel Mode (cont.)

- Interrupções
  - Eventos assíncronos causados por dispositivos periféricos (disco, relógio, interface de rede, etc).
  - São tratadas em *system context* pois não são causadas ou provenientes do processo corrente
    - Não pode haver acesso ao *process space*
    - Não pode bloquear (esperar por eventos) pois isso bloquearia um processo arbitrário e inocente

Executando em Kernel Mode (cont.)

- Exceções
  - Eventos síncronos ao processo em execução, causados por eventos relacionados ao próprio processo
    - Divisão por zero, acesso a endereço ilegal, *overflow*, etc.)
  - A rotina de tratamento da exceção (*exception handler*) roda em ***process context***
    - Pode acessar o espaço de endereçamento do processo (incluindo a *uArea*) e bloquear, se necessário.

Executando em Kernel Mode (cont.)

- SVC´s
  - Ocorrem quando o processo executa uma instrução especial do processador (*trap*, syscall)
  - São eventos síncronos ao processo em execução
  - Assim como as exceções, a SVC roda em ***process context***:
    - Pode acessar o espaço de endereçamento do processo (incluindo *U area*), além de poder bloquear o processo, se necessário.

Execução de uma SVC no UNIX

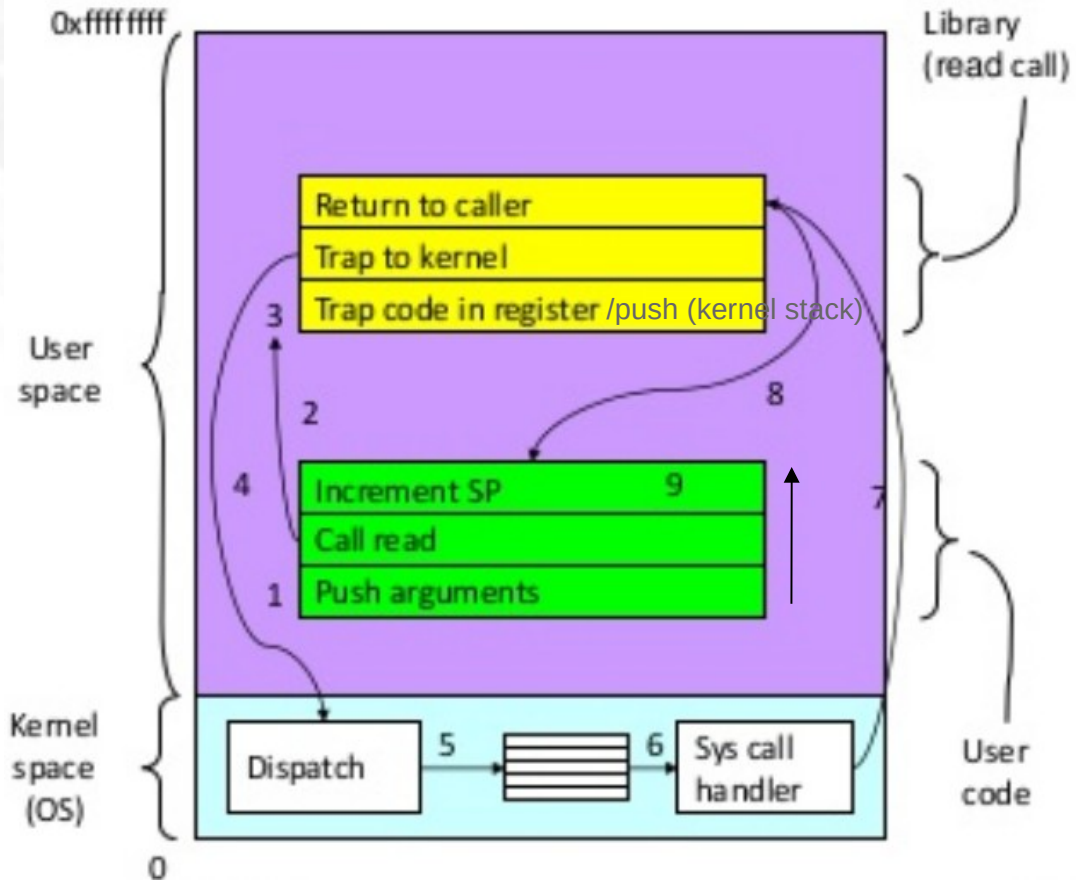

- System call: read(fd,buffer,length)
- Program pushes arguments, calls library
- Library sets up trap, calls OS
- OS handles system call
- Control returns to library
- Library returns to user program

Manipulação de Interrupções

- Interrupções são eventos gerados assincronamente à atividade regular do sistema.
  - O sistema não sabe em que ponto no fluxo de instruções a interrupção ocorrerá.
- *Interrupt Handler* ou *Interrup Service Routine* é o nome dado à rotina de tratamento da interrupção.
- O Interrupt Handler roda em *kernel mode* e *system context.*
  - Logo, o *handler* **não pode** acessar o *process space*, já que ele não tem nada a ver com a interrupção. Idem bloqueá-lo.
  - O tempo de servir a interrupção é descontado do quantum do processo em execução (*time-slice*).

Manipulação de Interrupções (cont.)

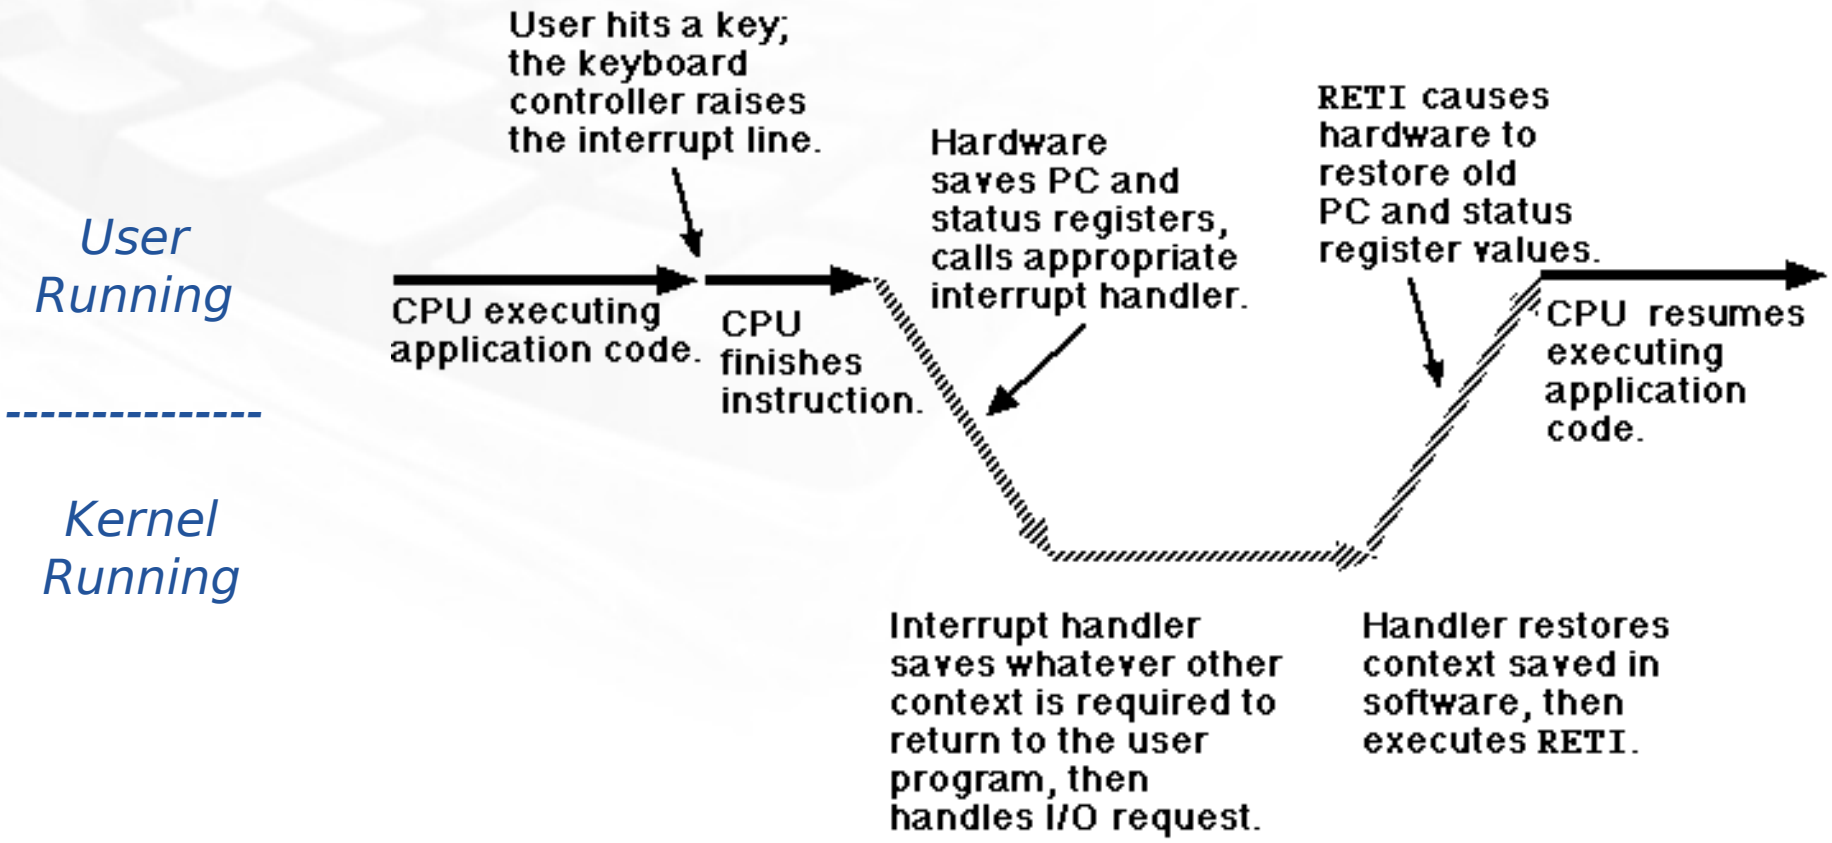

Manipulação de Interrupções - IPL

- Interrupções podem ocorrer enquanto uma outra está sendo atendida
  - Necessidade de se priorizar as interrupções
  - Ex: interrupção de relógio é mais prioritária do que a interrupção de interface de rede (cujo processamento dura vários *ticks* do relógio)
- A cada tipo de interrupção está associado a um ***Interrupt Priority Level - IPL***
  - O número de níveis de interrupção varia de acordo com o padrão Unix e com as arquiteturas de hardware.
  - Ex: Unix BSD – IPL´s variam de 0 a 31.

Manipulação de Interrupções - IPL

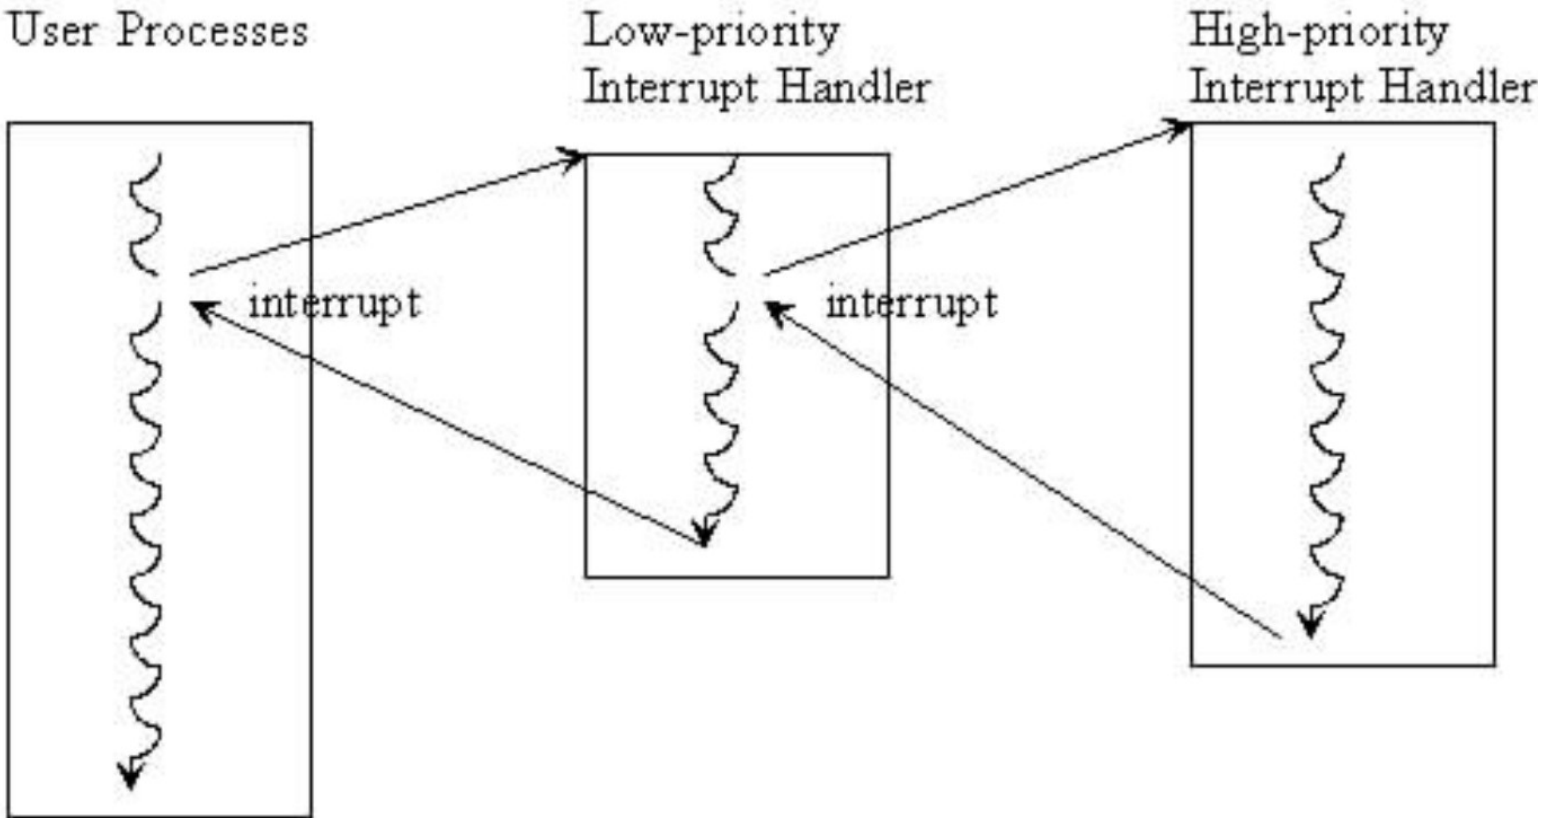

Manipulação de Interrupções - IPL

(cont.)

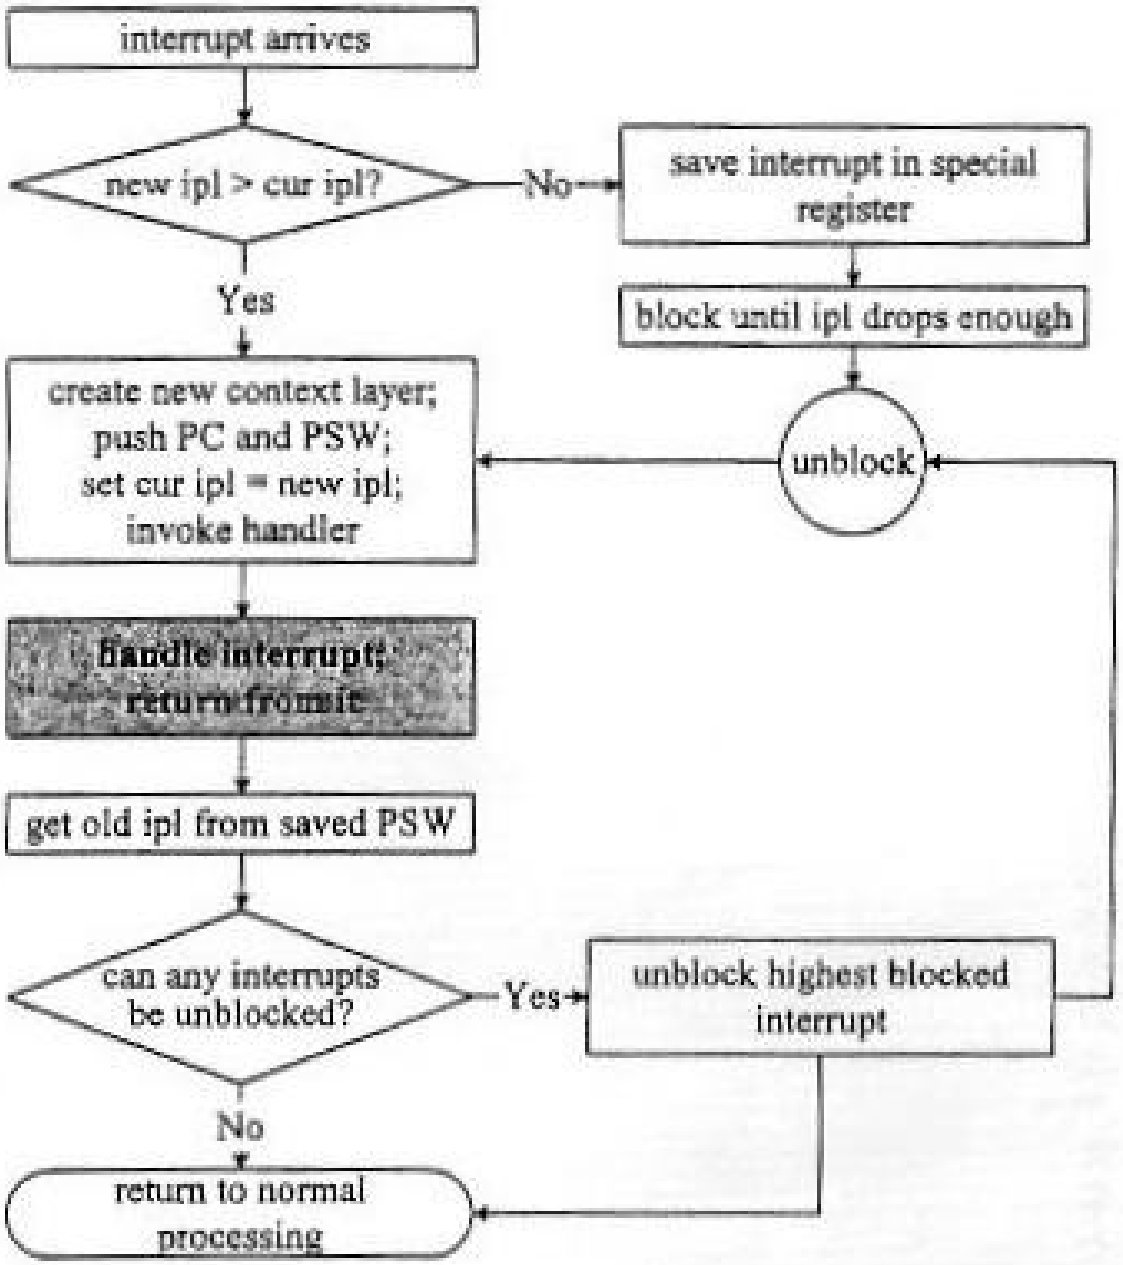

Figure 2-5. Interrupt handling.

Kernel Mode.... Atenção!!!

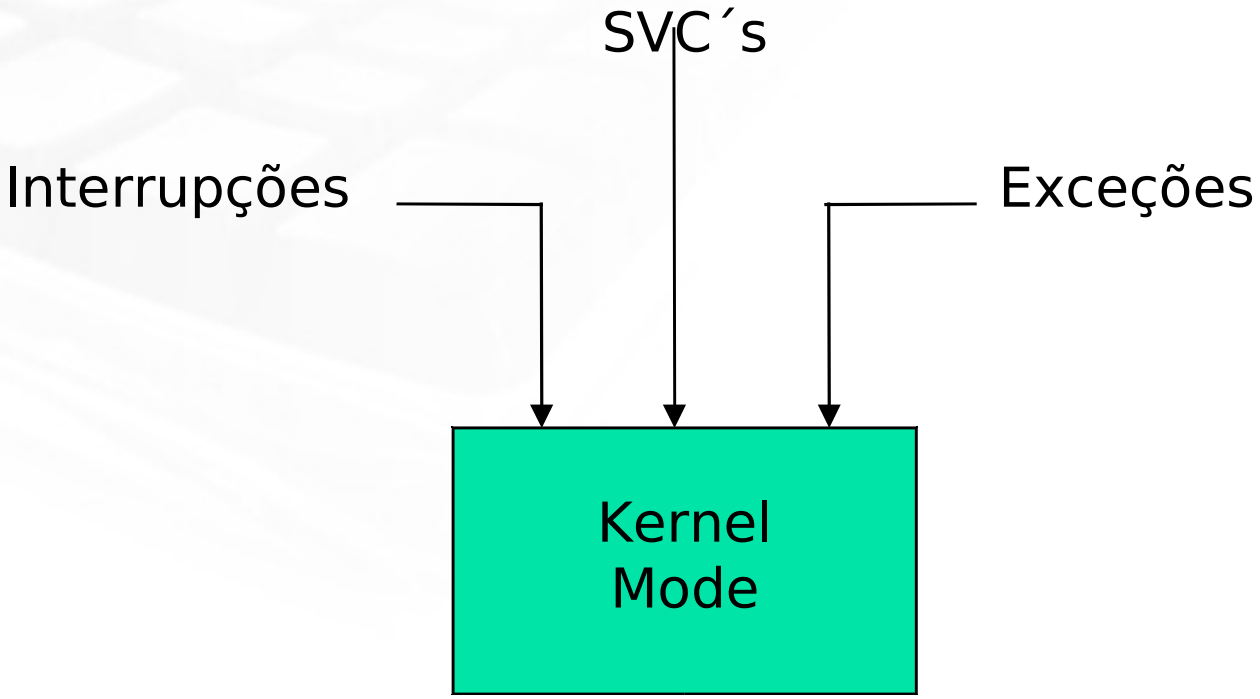

Sincronização

- O kernel do Unix é **reentrante**, o que significa que num dado momento vários processos podem estar ativos no kernel.

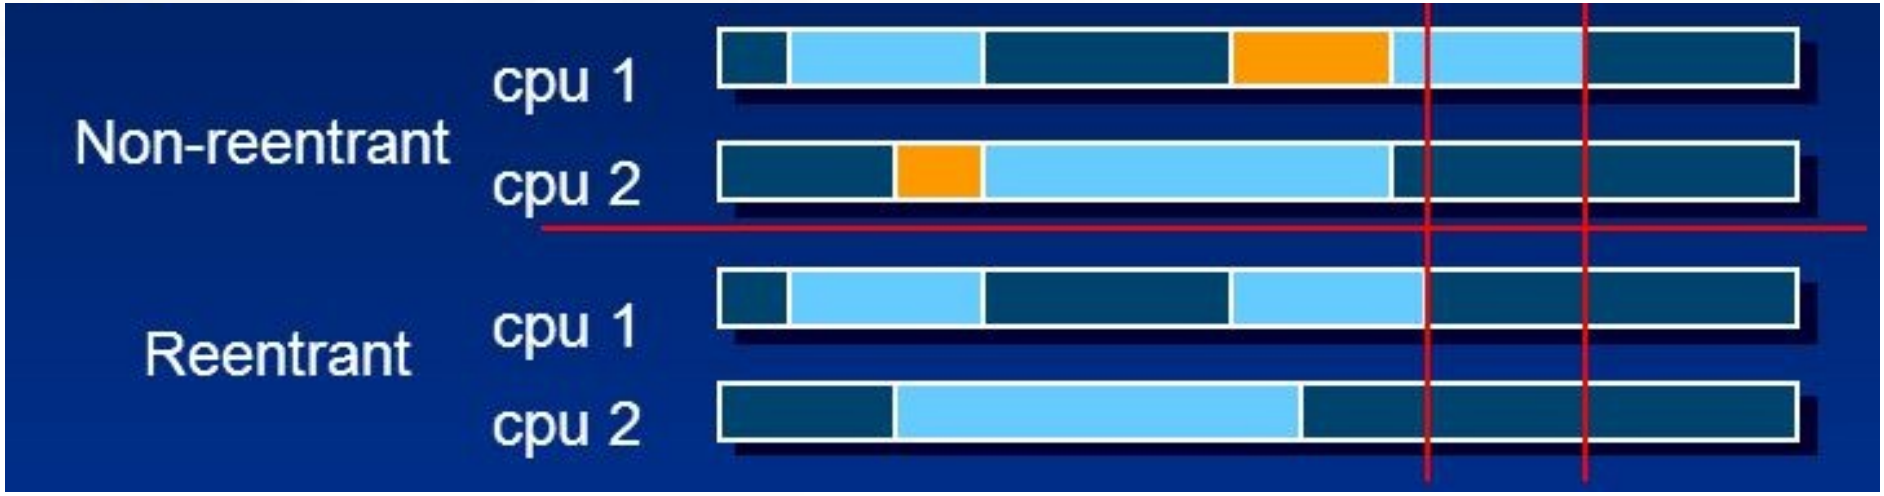

- … **Mesmo com apenas uma CPU, vários processos podem estar "no kernel" !!!**

Sincronização (cont.)

- O kernel do Unix é **reentrante**

Reentrant Kernels

All Unix kernels are *reentrant*. This means that several processes may be executing in Kernel Mode at the same time. Of course, on uniprocessor systems, only one process can progress, but many can be blocked in Kernel Mode when waiting for the CPU or the completion of some I/O operation. For instance, after issuing a read to a disk on behalf of a process, the kernel lets the disk controller handle it and resumes executing other processes. An interrupt notifies the kernel when the device has satisfied the read, so the former process can resume the execution.

Fonte: Bovet, Daniel P., and Marco Cesati. **Understanding the Linux Kernel: from I/O ports to process management.** " O'Reilly Media, Inc.", 2005. Pag.21
https://www.academia.edu/3783747/Understanding_Linux_Kernel

Sincronização (cont.)

- O kernel do Unix é **reentrante**

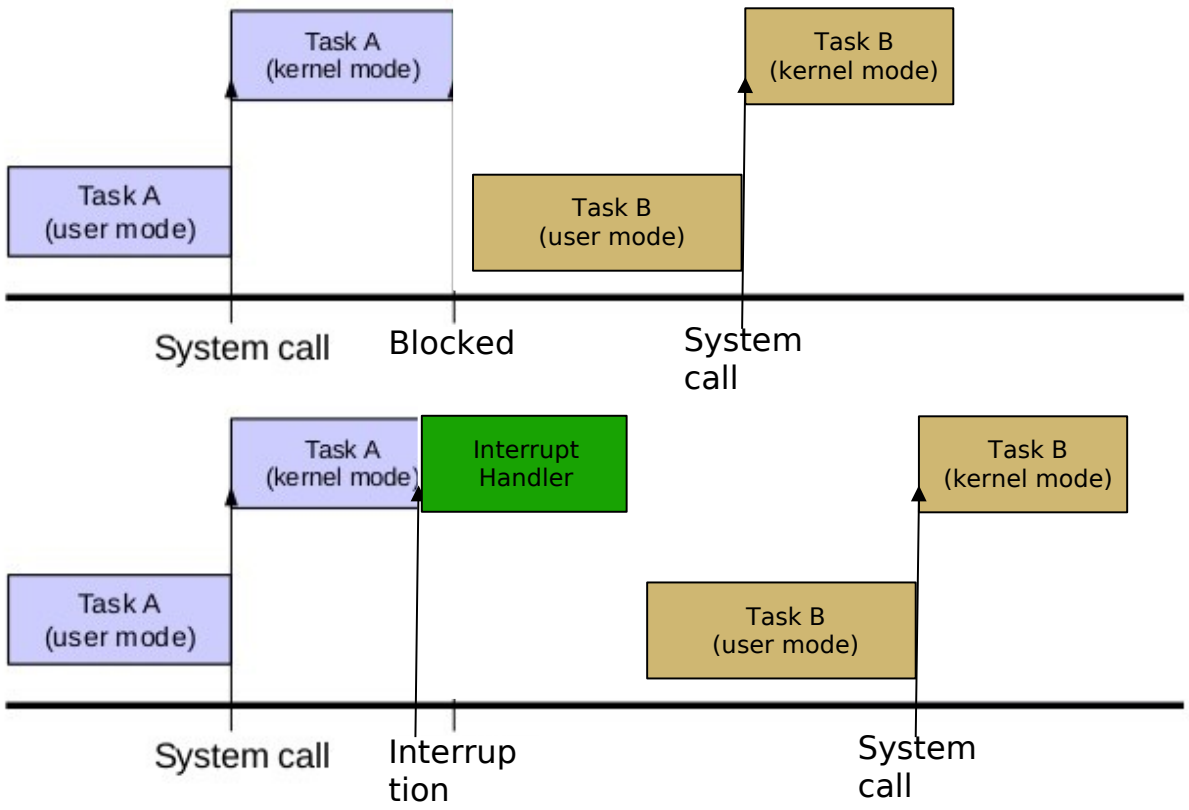

Sincronização (cont.)

- Como todos os processos compartilham uma única cópia das estruturas de dados do kernel, é necessário impor alguma forma de sincronização para prevenir que o kernel não seja corrompido.

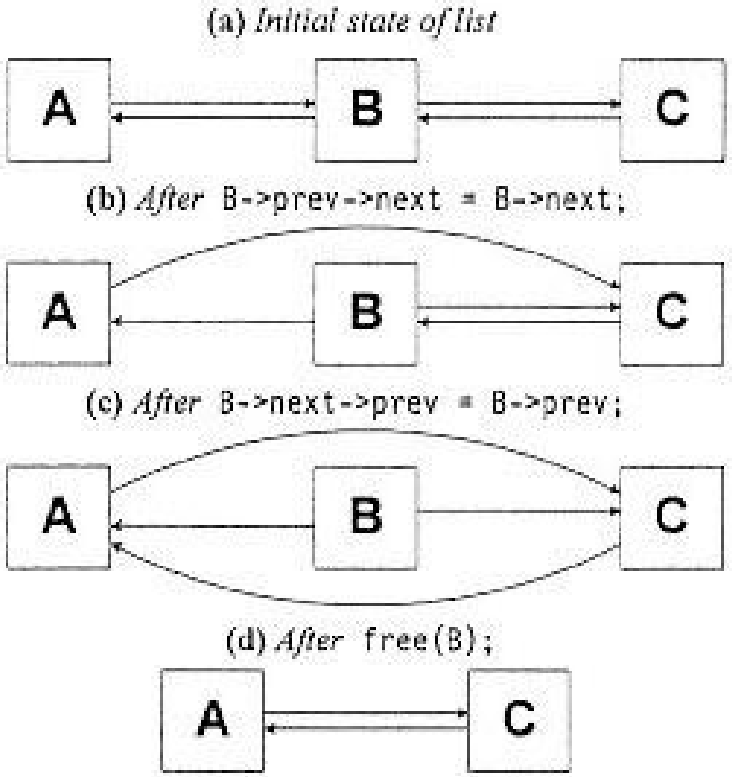

Figure 2-6. Removing an element from a linked list.

Sincronização (cont.)

- O kernel tradicional do Unix é **não-preemptivo**
  - Um processo rodando no estado *kernel running* (*i.e.* CPU em *kernel mode*) não pode ser preemptado (substituído por um outro processo), mesmo que o seu quantum expire ou que haja outro processo mais prioritário esperando

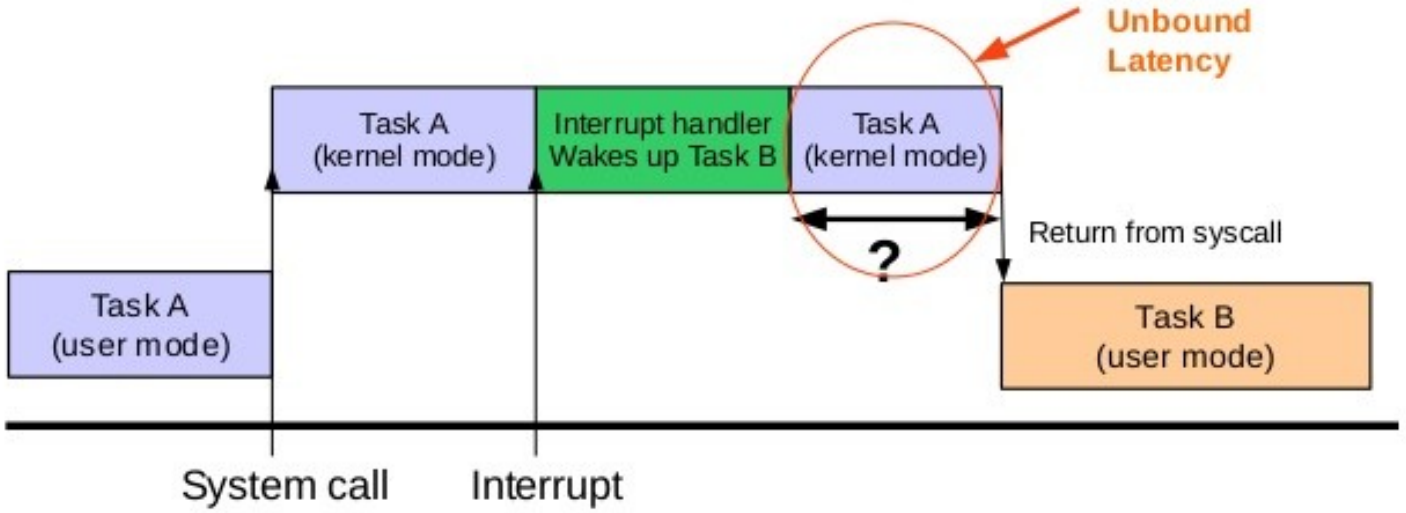

Sincronização (cont.)

- Quando o completar a atividade em kernel mode (ex: acabou o tratamento da interrupção, ou a execução da SVC finalzou), então o processo em execução poderá sofrer preempção
  - Se seu quantum expirou OU um processo mais prioritário tornou-se pronto
- Nesse caso, existe a garantia de que o kernel está num estado consistente.
- Em resumo, um kernel não-preemptivo é uma solução ampla para a maioria dos problemas de sincronização. Porém, três situações ainda persistem:
  - **Operações bloqueantes**
  - **interrupções e**
  - **multiprocessamento.**

Sincronização *x* Operações Bloqueantes

- Uma operação bloqueante é quando, ao fazer uma SVC o processo é bloqueado “no meio”... até que a operação se complete (ex: I/O)
- Quando o evento ocorrer, o processo será desbloqueado e, ao renornar ao estado kernel running, completará a execução da SVC que causou o bloqueio do mesmo
- Alguns objetos (dentro do kernel) podem precisar ser protegidos entre operações bloqueantes, requerendo mecanismos adicionais... Ex:
  - Operação de leitura de um bloco de disco para um buffer do *buffer cache* (outros processos não podem acessar o buffer enquanto o I/O não se completa).
- Solução: uso de *locks* e *wanted flag*

Sincronização *x* Interrupções

- Por ser não-premptivo, o kernel é protegido de preempção por um outro processo. Entretanto, um processo manipulando estruturas de dados do kernel pode ser interrompido por um dispositivo.
- Nessa situação, se o *Interrupt Handler* tentar acessar estruturas do kernel elas podem ficar em estado inconsistente (intencionalmente ou não).
- Solução: bloquear interrupções ao acessar estruturas críticas do kernel.
  - OBS: bloquear uma interrupção significa bloquear todas as interrupções de mesmo nível ou menor.

```
int x = splbio();            /*inibe interrupções de disco */
...modify disk buffer cache;      /* região crítica */
splx(x);                  /* restaura valor prévio do IPL */
```

Sincronização *x* Multiprocessadores

- No caso de mais de um processador os problemas de sincronização são muito mais complexos já que a premissa de não-preempção do kernel deixa de existir.
- Dois processos podem executar em *kernel mode* em diferentes processadores e executarem uma mesma função do kernel concorrentemente.
- Assim, a qualquer hora que o kernel acessar uma estrutura de dados global esta deve ser protegida de acesso por outros processadores (o próprio mecanismo de *locking* deve ser protegido de múltiplos acessos).

Referências

- VAHALIA, U. Unix Internals: the new frontiers. Prentice-Hall, 1996

http://gettem.org/UNIX-Internals-The-New-Frontiers-Vahalia.pdf

  - Capítulo 2 (até seção 2.5)