Laboratório de Pesquisa em Redes e Multimídia

Estudo de Caso
Unix: Processos e o Kernel

Aula 7

Profa. Patrícia Dockhorn Costa

Universidade Federal do Espírito Santo
Departamento de Informática

O Kernel

- É um programa especial, uma parte privilegiada do sistema operacional, que roda diretamente sobre o hardware.
- É ele quem implementa o modelo de processos do sistema.
  - O kernel não é um processo!
- O kernel oferece uma série de serviços aos processos de usuários e aos processos do próprio sistema operacional.
- No Unix, o kernel reside em um arquivo em disco normalmente nomeado como */vmunix ou /unix*.
- Programa *bootstrapping* carrega o kernel para a memória na inicialização do sistema.

A Abstração "Processo"

- Como já visto, 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 primitivas (SVCs) *fork* ou *vfork* e rodam até que sejam terminados através 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*).
- O processo *init* (PID 1) localiza-se no topo da hierarquia de processos de usuário do Unix. É o primeiro processo de usuário a ser criado, quando o sistema é iniciado. Seu nome advém do fato de executar o programa */etc/init*.

A Abstração "Processo" (cont.)

- Todos os processos descendem do processo *init*, à exceção de alguns poucos, como o *swapper* (PID 0) e o *pagedaemon* (PID 2).
- Esses também são criados na inicialização do sistema e ajudam o kernel na execução das suas tarefas (ex: *pagedaemon* previne a ocorrência de *trashing*).
- 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*.

Informações de Contexto do Processo (1)

- São todas as informações que descrevem um processo para o sistema. São seus componentes:
  - *Espaço de endereçamento do usuário*
    - texto (código), dados, pilha do usuário (*user stack*), regiões de memória compartilhada, etc.
  - *Informações de controle*
    - armazenadas em estruturas mantidas pelo kernel (*u area* e a *proc* structure).
  - *Credenciais*
    - identificadores de usuário e de grupo.
  - *Variáveis de ambiente*
  - *Contexto de hardware*
    - Conteúdo dos registradores de propósitos gerais e especiais

Informações de Contexto do Processo (2)

- As variáveis de ambiente são herdados do pai e representam *strings* na forma variavel = valor
  - Normalmente localizam-se na parte de baixo da *user stack*
  - Bibliotecas padrão de usuário fornecem funções para adicionar, deletar ou modificar as variáveis de ambiente.
  - Quando invocando um novo programa (via *exec*) o processo chamador pode pedir para reter o ambiente original ou, ao contrário, prover um novo conjunto de variáveis de ambiente.

Informações de Contexto do Processo (3)

- Exemplos de registradores salvos no contexto de hardware
  - PC (*program counter*): endereço da próxima instrução a executar.
  - SP (*stack pointer*): endereço do elemento no topo da pilha.
  - PSW (*program status word*): contém bits de estado do sistema, como modo de execução corrente e prévio, nível de interrupção corrente e prévio, *overflow*, *carry*, *zero*, etc.
  - MM (*memory management*): relacionados ao mapa de tradução de endereços do processo.

Informações de Contexto do Processo (4)

- A maioria das implementações do UNIX usam 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
- Uma parte fixa do espaço de endereçamento virtual mapeia o "kernel text" e as estruturas de dados do kernel
  - Chamamos de "system space" ou "kernel space"

Use Mode x Kernel Mode

- Com finalidade principal de proteção, a maioria dos computadores atuais fornece pelo menos dois modos de operação.
  - Ex: Intel 80x86 fornece quatro *anéis de execução*.
- O Unix requer do hardware a implementação de apenas 2 modos de operação: *user mode* (menos privilegiado) e *kernel mode* (com mais privilégios).
- Processos de usuário rodam em *user mode*, logo, não podem – acidental ou maliciosamente –, corromper outro processo ou mesmo o kernel.

Máquina de Estados do Unix

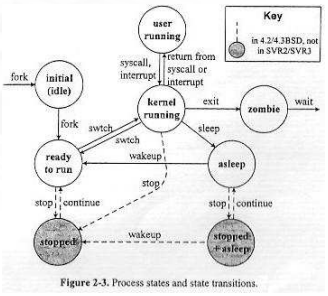

Figure 2-3. Process states and state transitions.

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.

System (Kernel) Space (cont.)

- O kernel é compartilhado por todos os processos mas o *system space* é protegido de acesso em *user mode*, caso contrário processos de usuário acessariam diretamente áreas do kernel.
  - O acesso tem que ser feito via SVC (portanto, acesso controlado).
- Na ocorrência de uma SVC uma seqüência especial de instruções é executada para por o sistema em *kernel mode* e passar o controle para o kernel.
- No término da SVC o kernel executa um outro conjunto de instruções, que retorna o sistema para *user mode* e transfere o controle de volta para o processo chamador.

Process space - U Area

- Existem objetos gerenciados pelo kernel que são implementados como parte do espaço de endereçamento do processo ("per-process objects").
  - Exemplos: *u area* e *kernel stack*.
- A *u area* contém informações sobre o processo que são de interesse para o kernel e necessárias apenas quando o processo está *running*.
  - Número de arquivos abertos, informações de identificação do processo, valores de registradores, etc.
- A *u area* é protegida de acesso em *user mode*.

Process space - Kernel stack

- O kernel do Unix é *reentrante*, significando que vários processos podem estar envolvidos em atividades do kernel concorrentemente (até uma mesma atividade / procedimento).
- Para isso, cada processo necessita da sua própria *kernel stack* para controlar a seqüência de chamadas às funções quando executando no kernel.
- Muitas implementações alocam a *kernel stack* no espaço de endereçamento do processo mas não permitem acesso a ela em *user mode*.
- Conceitualmente, embora a *u area* e a *kernel stack* sejam estruturas "per-process", localizadas no espaço de endereçamento do processo, elas são propriedade do e governadas pelo kernel.

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 ...

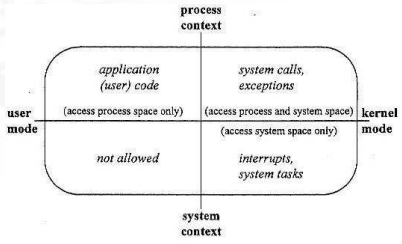

Figure 2-2. Execution mode and context.

U area

- É uma parte do espaço de endereços do processo, visível (necessária) apenas quando o processo está no estado *running*.
- É normalmente mapeada sempre num local fixo do espaço de endereçamento virtual do processo, referenciado pelo kernel através da variável de sistema *u*.
- Na troca de contexto esse mapeamento é resetado de modo que as referências à variável *u* apontem agora para os endereços da *u area* do processo selecionado para execução.

Campos da *U area*

- Bloco de controle de processo (*hardware context*).
- *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

Campos da *U area* - Credenciais do Usuário

- Cada usuário do sistema é identificado por um número único denominado *user ID (UID)*. Cada definição de grupo de usuários é identificada por um *group ID (GID)*.
  - Esses identificadores afetam o *ownership* e permissão de acesso a arquivos, bem como a habilidade de sinalizar outros processos.
- O sistema reconhece um usuário privilegiado, com poderes especiais (o *superuser*, normalmente "logado" como *root*).
  - O *superuser* possui UID = 0 e GID = 1
- Cada processo tem dois pares de IDs: *real* e *effective*.
- Quando o usuário entra no sistema o programa de *login* atribui a ambos os pares de IDs os valores de UID e GID especificados no arquivo */etc/password* (ou em algum outro mecanismo distribuído, como o *NIS - Network Information Service)*.

Campos da *U area* - Credenciais do Usuário (cont.)

- Os atributos *effective UID* e *effective GID* afetam a criação e o acesso a arquivos.
  - Durante a criação de um arquivo, o kernel define o atributo "*owner*" do arquivo como sendo o *effective UID* e *effective GID* do processo criador.
  - No acesso ao arquivo, o kernel usa o *effective UID* e o *effective GID* do processo para verificar se ele pode ou não acessar o arquivo.

Campos da *U area* - Credenciais do Usuário (cont.)

- Os atributos *real UID* e *real GID* identificam o real dono do processo e afetam a permissão de envio de sinais.
  - Um processo sem privilégios de *superuser* só pode sinalizar outros processos se o *real UID* ou o *effective UID* do transmissor for igual ao *real UID* do processo receptor.
- Se um processo invoca *exec* para rodar um programa instalado em *suid mode* o kernel altera o *effective UID* do processo para aquele do dono do arquivo (idem para *sgid mode*). Isso é usado para dar privilégios especiais aos usuários para determinadas tarefas
  - Ex: programa *passwd*, que permite ao usuário ganhar privilégios de superuser (dono do programa *passwd*) modificar a sua própria senha

Campos da *Proc Structure*

- Identificadores: PID, *process group*, *process session*, etc.
- Informações de hierarquia (*p_pid*)
- Estado do processo corrente
- 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

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

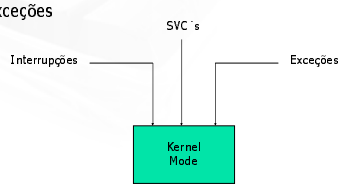

Executando em Kernel Mode (cont.)

- 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 espaço de endereçamento do processo ou a sua *U area*
    - 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, a *U area* e bloquear, se necessário.

Executando em Kernel Mode (cont.)

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

Executando em Kernel Mode (cont.)

- Ações do kernel:
  - Salvar conteúdo de registradores (ex: PC, PSW) na *kernel stack* do processo
  - Consultar uma "*dispatch table*", que contém os endereços das rotinas que manipulam esses eventos
  - Desviar para a rotina apropriada

Executando em Kernel Mode (cont.)

- Ações do kernel após o término da rotina:
  - Restaurar o conteúdo dos registradores do processo
  - Retornar o modo de execução para o valor anterior
    - kernel ⇒ user (SVC)
    - kernel ⇒ kernel (interrupção)

A Interface SVC

- O conjunto formado pelas SVC´s constitui a interface oferecida aos processo de usuário pelo kernel para acesso aos seus serviços

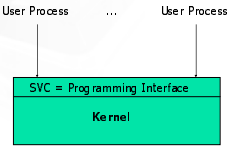

A Interface SVC (cont.)

- A biblioteca C padrão contém uma "*wrapper routine*" para cada SVC.
- Essa rotina empilha na *user stack* do processo o número da SVC e os argumentos, e invoca a instrução especial (ex: *trap()*)
- Essa instrução muda o modo de execução para *kernel mode* e transfere o controle para o "*system call handler*" definido na *dispatch table.*
- Esse *handler*, normalmente chamado syscall(), é o ponto de entrada de todas as SVC´s do kernel.

A Interface SVC (cont.)

- Ações da syscall():
  - Copia os argumentos da *user stack* para a *u area*
  - Salva o contexto do processo na *kernel stack*,
  - Usa o número da SVC para indexar um vetor de despacho de SVC´s (sysent[] - *system call dispatch vector*)
  - Desvia para a SVC apropriada.
  - Ao término da SVC:
    - atribui os valores de retorno ou os códigos de erro nos registradores apropriados,
    - restaura o conteúdo dos registradores (contexto),
    - retorna o modo de execução para *user mode*
    - transfere o controle de volta para a rotina da biblioteca C.

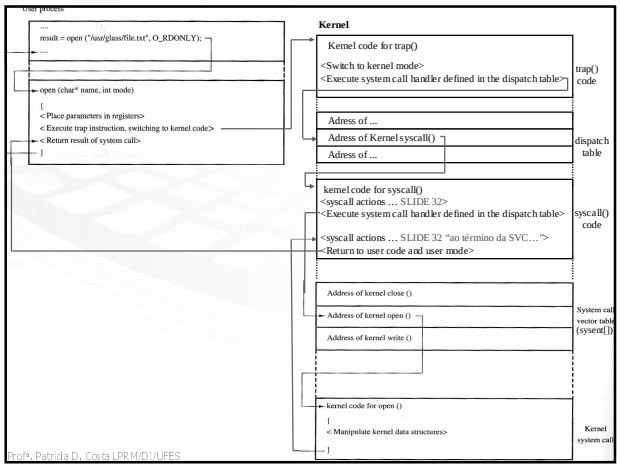

Manipulação de Interrupções

- Como visto, interrupções permitem aos dispositivos periféricos interagir com a CPU, informando o término de tarefas, condições de erro ou outros eventos que requeiram atenção urgente.
- 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* tem que ter o cuidado de não acessar o espaço de endereçamento do processo corrente bem como a sua U area, já que ele não tem nada a ver com a interrupção. Idem bloqueá-lo.

Manipulação de Interrupções (cont.)

- Há, entretanto, um impacto no processo interrompido:
  - O tempo de servir a interrupção é descontado do seu quantum (time-slice)
  - O *Clock Interrupt Handler* precisa acessar a *proc structure* do processo para descontar esse tempo do seu quantum
  - Conclusão: uma programação incorreta do *interrupt handler* pode corromper alguma parte do espaço de endereçamento do processo.

Manipulação de Interrupções (cont.)

- Interrupções podem ocorrer enquanto uma outra está sendo atendida; logo, existe a necessidade de se priorizar as interrupções.
  - Ex: interrupção de relógio é mais prioritária que a interrupção de interface de rede, cujo processamento dura vários *ticks* do relógio
- A cada tipo de interrupção está associado 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 (cont.)

- Unix fornece aos desenvolvedores um conjunto de macros para bloquear e desbloquear interrupções

Table 2-1. Setting the interrupt priority level in 4.3BSD and SVR4

4.3BSD	SVR4	Purpose
spl0	spl0 or splbase	enable all interrupts
splsoftclock	spltimeout	block functions scheduled by timers
splnet		block network protocol processing
	splstr	block STREAMS interrupts
spltty	spltty	block terminal interrupts
splbio	spldisk	block disk interrupts
splimp		block network device interrupts
splclock		block hardware clock interrupt
splhigh	spl7 or splhi	disable all interrupts
splx	splx	restore *ipl* to previously saved value

Manipulação de Interrupções (cont.)

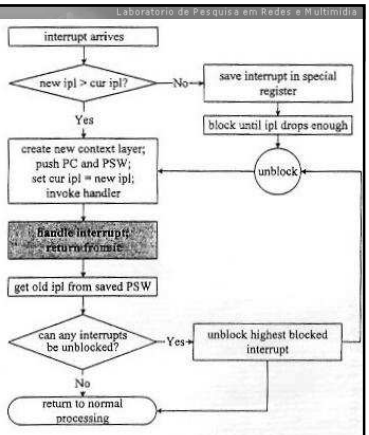

Figure 2-5. Interrupt handling.

Sincronização

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

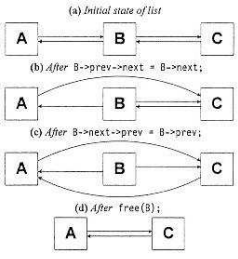

Figure 2-6. Removing an element from a linked list.

Sincronização (cont.)

- Como o kernel tradicional do Unix é não-preemptivo, isso significa dizer que um processo rodando em *kernel mode* não pode ser substituído por um outro processo, mesmo que o seu quantum expire.
- O processo devolve voluntariamente a CPU quando:
  - Bloqueou esperando por um evento, ou
  - Completou a atividade em *kernel mode* e está retornando para *user mode*
- Nesses casos, existe a garantia de que o kernel está num estado consistente.
- Em resumo, adotar 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 aquela que coloca e mantém o processo no estado *asleep* até que a operação se complete.
- A princípio, como o kernel é não-preemptivo, ele pode manipular a maioria dos objetos com a garantia de que o processo não será interrompido.
- Alguns objetos, entretanto, devem ser protegidos inclusive 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* Operações Bloqueantes (cont.)

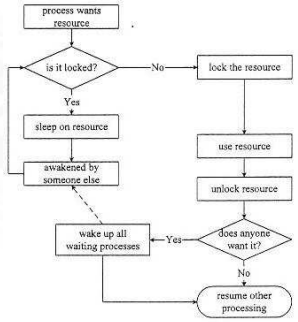

Figure 2-7. Algorithm for resource locking.

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* Interrupções (cont.)

- Interrupções usualmente requerem atendimento rápido; portanto, as regiões críticas devem ser poucas e pequenas.
- As únicas interrupções que devem ser bloqueadas são aquelas que podem manipular os dados da região crítica.
- Observe que dois tipos de interrupções diferentes podem ter o mesmo nível de prioridade
  - Ex: terminal e disco ocorrem com IPL 21.

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).