

Sistemas de Tempo Real: Alocação de Recursos

Rômulo Silva de Oliveira
Departamento de Automação e Sistemas - DAS – UFSC

romulo@das.ufsc.br
<http://www.das.ufsc.br/~romulo>

Introdução

- Processador é o recurso mais importante
 - Mais essencial
- Outros recursos também são usados
 - Canais de comunicação
 - Estruturas de dados
 - Arquivos
- Necessidade de alocar e liberar tais recursos
 - Exigem exclusão mútua no acesso

Introdução

- Existem várias questões a serem tratadas:
- Quando e sob quais condições os pedidos de recursos são atendidos ?
- Como são escalonados os jobs que estão esperando por um dado recurso ?
- Quanto tempo uma dada tarefa precisa esperar até conseguir acessar um dado recurso ?
- Como a existência de recursos outros além do processador afeta a escalonabilidade do sistema ?

Modelo de Recursos

- Sistema monoprocessador
- Podem existir diferentes recursos compartilhados
 - Estruturas de dados independentes
 - Periféricos
 - Etc
- Recursos não podem ser preemptados e requerem exclusão mútua
- Existe apenas uma unidade de cada recurso
 - Mais adiante esta suposição será revista
- Não estamos preocupados com recursos que
 - Podem ser acessados simultaneamente (exemplo: tabela read-only)
 - Existe grande número de unidades (exemplo: bytes na memória)

Modelo de Recursos

- Mecanismo de sincronização é usado pelas tarefas para controlar o acesso aos recursos compartilhados
- Um simples MUTEX será usado para controlar o acesso
- LOCK(X) é usado pela tarefa para indicar que ela requer o uso do recurso X
 - Tarefa fica bloqueada até o acesso ao recurso ser autorizado
 - Enquanto bloqueada, ela sai da fila de aptos e não disputa o processador
- UNLOCK(X) é usado pela tarefa para indicar que ela não mais requer acesso ao recurso X
 - Retorno imediato
 - Poderá liberar outra tarefa que estava esperando para usar o recurso X

Modelo de Recursos

- Seção Crítica
 - Trecho de código onde a tarefa acessa algum recurso compartilhado X
 - Limitado pelas operações LOCK(X) e UNLOCK(X)
- Seções críticas podem ser aninhadas
- É suposto que apenas aninhamentos perfeitos são usados
- Situação mais comum:
 - Chama rotina proc_x que tem LOCK(X) no início e UNLOCK(X) no fim
 - Enquanto da rotina proc_x tem uma chamada para rotina proc_y
 - Rotina proc_y tem LOCK(Y) no início e UNLOCK(Y) no fim

Modelo de Recursos

```


void proc_x() {
  ...
  lock(X);
  usa X;
  proc_y();
  usa X;
  unlock(X);
  ...
}

void proc_y() {
  ...
  lock(Y);
  usa Y;
  unlock(Y);
  ...
}

```


Modelo de Recursos

- Será usada uma notação baseada no livro da Jane Liu (não igual)
- [X,3]
 - Tarefa precisa do recurso X por 3 unidades de tempo
- Recursos aninhados são representados por colchetes aninhados
- [X,3[Y,5]4]
 - Aloca X, usa por 3 unidades de tempo, aloca Y, usa ambos por 5 unidades de tempo, libera Y, usa X por mais 4 unidades de tempo, libera X




Especificação das Demandas de Recursos

- Grafo dirigido acíclico
- Arco da tarefa para o recurso indica que a tarefa requer o recurso
- Anotação no arco indica a duração da seção crítica
- Exemplo
 - T1:[X,3]
 - T2:[X,2]
 - T3:[X,4]




Especificação das Demandas de Recursos

- Exemplo
 - T1:[X,3][Y,1]
 - T2:[X,2]
 - T3:[X,3][Y,5]4]




Modelo de Recursos

- Duas tarefas entram em conflito quando precisam usar o mesmo recurso ao mesmo tempo
- LOCK pode fazer a tarefa ficar bloqueada por algum tempo




Inversão de Prioridade

- Temos em um dado momento a tarefa T1 esperando pela Tarefa T3
- As prioridades estão invertidas
- O tempo de resposta da tarefa T1 será afetado




Anomalia da Inversão de Prioridades

- Se T3 reduzir o tamanho da sua seção crítica
 - O tempo de resposta da tarefa T1 AUMENTA



Inversão de Prioridade Descontrolada

- Pode ser ainda pior
- Agora Tarefa T1 espera por T3 e também por T2
- Tarefa T1 nem sequer compartilha qualquer recurso com T2



Possibilidade de Deadlock

- Deadlock:
 - Um conjunto de tarefas estão bloqueadas a espera de evento que somente pode ser causado por tarefas deste conjunto
- Exemplo:


<u>T1</u>	<u>T2</u>
Lock(X)	Lock(Y)
Lock(Y)	Lock(X)
...	...
Unlock(Y)	Unlock(X)
Unlock(X)	Unlock(Y)
...	...
- Se deadlock é possível, o tempo de resposta no pior caso é infinito

Protocolos de Acesso a Recursos

- Usar protocolos de acesso a recursos específicos
- Podem minimizar a inversão de prioridade
- Podem impedir deadlocks
- Exemplo clássico para impedir deadlocks:
 - Todos os recursos compartilhados são numerados
 - Recursos precisam ser alocados em ordem crescente
 - Tanto T1 como T2
 - Aloca X antes de Y
 - Ou aloca Y antes de X
 - Seja como for, agora é impossível ocorrer um deadlock

(1) Desliga Preempção

- Desliga a preempção antes de acessar qualquer recurso
- Todas as seções críticas executam de forma não preemptiva
- Tempo máximo de bloqueio B_i da tarefa T_i
 - Dado pela duração da maior seção crítica de qualquer tarefa com prioridade mais baixa do que T_i



(1) Desliga Preempção

- Forma mais simples de resolver o problema
- Inversão de prioridade descontrolada não acontece
- Deadlock não acontece
- Qualquer tarefa pode ser bloqueada no máximo uma vez
- Obviamente só funciona em monoprocessador
- Qualquer tarefa pode ser bloqueada por qualquer tarefa de prioridade mais baixa
 - Mesmo que elas não compartilhem recursos entre si
- Solução razoável quando todas as seções críticas forem pequenas
- Corresponde ao “Desabilita Interrupções” de sistemas pequenos

(2) Herança de Prioridade


- Cada tarefa possui uma prioridade nominal fixa
 - Dada por RM, DM, etc
- Cada job possui uma prioridade efetiva
 - A prioridade efetiva varia ao longo do tempo
 - A prioridade efetiva é usada para decidir quem executa a seguir
- Inicialmente, a prioridade efetiva do job é igual à prioridade nominal da sua tarefa
- A prioridade efetiva pode mudar em decorrência da alocação de recursos pelo job em questão

(2) Herança de Prioridade: Regras

- Regra de alocação: Quando um Job J requer (LOCK) um recurso R no instante t:
 - Se R está livre, R é alocado para J até que J libere o recurso (UNLOCK)
 - Se R está ocupado, J bloqueia
- Regra da Herança de Prioridade:
 - Seja Jx o job que detém o recurso R solicitado por J
 - Job Jx herda a prioridade efetiva de J
 - Job Jx executa com a prioridade efetiva de J até liberar R
 - Quando liberar R, Jx retorna para a prioridade efetiva que tinha em t
 - Herança de prioridade é transitiva


(2) Herança de Prioridade: Exemplo

- Inversão de prioridades descontrolada é evitada
- T3 termina a seção crítica mais cedo
- T1 sofre bloqueio direto de T3
- T2 sofre bloqueio por herança de T3




(2) Herança de Prioridade: Exemplo

- Sem herança e com herança de prioridades



(2) Herança de Prioridade: Exemplo

- Bloqueio direto de T2 sobre T1 via Z
- Bloqueio transitivo de T3 sobre T1 via T2(Y)
- Bloqueio transitivo de T4 sobre T1 via T3(X) e T2(Y)
- Suponha T4 executa Lock(Z) em t



(2) Herança de Prioridade

- Impede a inversão de prioridade descontrolada
- Uma tarefa pode ser bloqueada diretamente por outra tarefa de mais baixa prioridade somente uma vez
 - Isto pode acontecer para cada seção crítica usada
- Cada uma das tarefas de mais baixa prioridade é capaz de bloquear a tarefa de mais alta prioridade
 - Por no máximo uma vez
- Tipos de bloqueio
 - Direto
 - Transitivo
 - Por herança de prioridade
- Não impede o deadlock por si só
 - Mecanismo adicional é necessário

(2) Herança de Prioridade

- Não minimiza tempo de bloqueio no pior caso
- Job
 - que requer v recursos
 - e conflita com k jobs de mais baixa prioridade
- Pode ser bloqueado por $\min(v,k)$ vezes
 - A duração do bloqueio será aquela do pior caso
 - Precisa considerar o bloqueio transitivo
- Determinação do B para o pior caso pode ficar complexo
 - se os padrões de uso dos recursos forem complexos

(3) Priority Ceiling

- Estende a herança de prioridade para
 - Eliminar a possibilidade de deadlock
 - Reduzir o tempo de bloqueio no pior caso
- Assume que é sabido antes da execução quais recursos cada tarefa usa
- Priority Ceiling = Teto de prioridade
 - O teto de prioridade de um recurso R_i corresponde a mais alta prioridade entre todas as tarefas que usam R_i
 - Denotado por Π_i
- Uma prioridade imaginária mais baixa que todas as prioridades do sistema será denotada por Ω
- O teto de prioridade do sistema Π corresponde ao maior teto de prioridade entre todos os recursos alocados

(3) Priority Ceiling

- Cada tarefa possui uma prioridade nominal fixa
 - Dada por RM, DM, etc
- Cada job possui uma prioridade efetiva
 - A prioridade efetiva varia ao longo do tempo
 - A prioridade efetiva é usada para decidir quem executa a seguir
- Inicialmente, a prioridade efetiva do job é igual à prioridade nominal da sua tarefa
- A prioridade efetiva pode mudar em decorrência da alocação de recursos pelo job em questão
- As prioridades efetivas dos jobs são usadas para fins de escalonamento
 - Executa o job não bloqueado com a prioridade efetiva mais alta

(3) Priority Ceiling: Regra de Alocação


- Regra de Alocação
- Um job J requer um recurso R no instante t
- Se R está alocado para outro job
 - O pedido é negado e J fica bloqueado
- Se R está livre
 - O pedido será aceito se a prioridade efetiva de J for maior que o teto de prioridade do sistema Π
 - O pedido será aceito se a prioridade efetiva de J for igual ao teto de prioridade do sistema Π , mas for J o job que alocou o recurso R_i cujo teto de prioridade Π_i define Π
 - Caso contrário, o pedido é negado e J fica bloqueado

(3) Priority Ceiling: Regra de Herança

- Regra de herança de prioridade
- Quando o job J tenta alocar o recurso R e fica bloqueado
 - o job J_x que detém o recurso R herda a prioridade efetiva de J
- J_x mantém esta prioridade até o momento que libera o recurso R
 - Neste instante ele retorna para sua prioridade efetiva anterior
- A herança de prioridade é transitiva

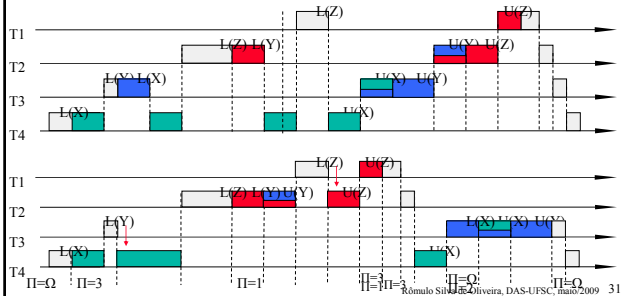
(3) Priority Ceiling: Exemplo

- Tetos de prioridade:
 - $\Pi(X)=3, \Pi(Y)=2, \Pi(Z)=1$



(3) Priority Ceiling: Exemplo


- Herança de prioridade versus Teto de prioridade



(3) Priority Ceiling

- Impossível ocorrer deadlock

- T1:[X,1[Y,1]]
- T2:[Y,1[X,1]]
- $\Pi(X)=1, \Pi(Y)=1$



(3) Priority Ceiling

- Herança de Prioridade
 - Guloso
 - Se recurso estiver livre, o mesmo é alocado
- Teto de Prioridade
 - Conservador
 - Mesmo um recurso livre pode não ser alocado
 - Isto é feito para prevenir um comportamento pior mais adiante
- Semelhante aos protocolos para evitar deadlock
 - Algoritmo do banqueiro

(3) Priority Ceiling: Tipos de Bloqueios


- Bloqueio pode ocorrer de três formas
- Bloqueio direto
 - Recurso está ocupado
- Bloqueio por herança de prioridade
 - Bloqueado por tarefa que herdou prioridade mais alta
- Bloqueio por teto
 - Recurso está livre, mas teto do sistema é mais alto
- Determinação do B é simplificada pois:
 - Um job pode ser bloqueado por no máximo a duração de uma seção crítica

(3) Priority Ceiling

- Uma tarefa T_i pode ser bloqueada apenas uma vez por uma mesma tarefa de prioridade mais baixa T_x
 - Ao liberar o recurso a primeira vez, T_x não executa mais e não aloca novamente
- Não é possível uma tarefa T_i ser bloqueada por T_x e T_y , se T_x e T_y tiverem prioridade mais baixa do que T_i
 - Após o primeiro bloqueio, a regra do teto impede um segundo bloqueio
- Uma tarefa T_i pode ser bloqueada no máximo pela duração de uma única seção crítica
 - Não importa quantas tarefas compartilham recursos com a tarefa T_i
 - Vale a seção crítica mais externa, quando aninhadas


(3) Priority Ceiling

- T1
 - Bloqueio direto de T2 por 2 ut
 - Bloqueio direto de T3 por 5 ut
- T2
 - Bloqueio por teto de T3 por 5 ut
 - Bloqueio por herança de T3 por 5 ut
 - Somente um dos dois é possível
- T3
 - Não sofre bloqueio por definição




(3) Priority Ceiling

- Exemplo mais complexo



(3) Priority Ceiling: Bloqueio Direto


- Para cada tarefa
 - Determina as possibilidades de bloqueio direto
 - Lido direto do grafo de recursos



	por T1	por T2	por T3	por T4	por T5
T1	---	2 (X)	-	-	6 (Z)
T2	---	---	5 (Y)	-	-
T3	---	---	---	-	-
T4	---	---	---	---	-
T5	---	---	---	---	---

(3) Priority Ceiling: Bloqueio por Herança


- Para cada tarefa
 - Determina as possibilidades de bloqueio por herança
 - Máximo da mesma coluna na tabela anterior, em linhas acima



	por T1	por T2	por T3	por T4	por T5
T1	---	-	-	-	-
T2	---	---	-	-	6 (Z)
T3	---	---	---	-	6 (Z)
T4	---	---	---	---	6 (Z)
T5	---	---	---	---	---

(3) Priority Ceiling: Bloqueio por Teto

- Para cada tarefa
 - Determina as possibilidades de bloqueio por teto
 - Mesma tabela anterior, exceto para tarefas que não usam recursos



	por T1	por T2	por T3	por T4	por T5
T1	---	-	-	-	-
T2	---	---	-	-	6 (Z)
T3	---	---	---	-	6 (Z)
T4	---	---	---	---	-
T5	---	---	---	---	---

(3) Priority Ceiling: Cálculo do B

- Tempo de bloqueio máximo de cada tarefa é o máximo da linha
- B1=6, B2=6, B3=6, B4=6, B5=0

	por T1	por T2	por T3	por T4	por T5		por T1	por T2	por T3	por T4	por T5		por T1	por T2	por T3	por T4	por T5
T1	---	2	-	-	6	T1	---	-	-	-	-	T1	---	-	-	-	-
T2	---	---	5	-	-	T2	---	---	-	-	6	T2	---	---	-	-	6
T3	---	---	---	-	-	T3	---	---	---	-	6	T3	---	---	---	-	6
T4	---	---	---	---	-	T4	---	---	---	---	6	T4	---	---	---	---	---
T5	---	---	---	---	---	T5	---	---	---	---	---	T5	---	---	---	---	---

(3) Priority Ceiling

- No pior caso,
 - Priority Ceiling não bloqueia mais do que Herança de Prioridade
- Bloqueio gera mais chaveamento de contexto
 - Precisa incluir no tempo de execução das tarefas
 - Tarefa que não usa recurso acrescenta 2 chaveamentos de contexto
 - Quando inicia e quando termina
 - Tarefa que usa recurso acrescenta 4 chaveamentos de contexto
 - Quando inicia, quando fica bloqueada, quando é liberada, quando termina
 - Cada tarefa tem o seu WCET acrescido de seus chaveamentos de contexto
- Regras são complexas
- É necessário saber quem bloqueia quem, de forma transitiva

(4) Immediate Priority Ceiling


- Cada tarefa possui uma prioridade nominal
 - Atribuída por RM, DM, etc
- Cada recurso tem uma prioridade teto
 - Prioridade mais alta entre as tarefas que usam o recurso
- Cada tarefa tem uma prioridade efetiva
 - Mais alta entre
 - sua própria prioridade nominal
 - e as prioridades teto de quaisquer recursos que a tarefa tenha alocado
- Executa a tarefa apta com a mais alta prioridade efetiva
 - Para a mesma prioridade é usado FIFO

(4) Immediate Priority Ceiling

- Ao alocar um recurso,
 - Tarefa recebe a prioridade teto daquele recurso
 - Se for mais alta do que sua prioridade efetiva corrente
- Como consequência, uma tarefa irá sofrer apenas um bloqueio
 - No início de sua execução
- Uma vez que a tarefa realmente inicia sua execução
 - todos os recursos que ela necessita estarão livres
- Se eles não estivessem,
 - então alguma outra tarefa teria uma prioridade igual ou mais alta
 - e a execução da tarefa em questão seria postergada
- O bloqueio máximo sofrido por qualquer job é o mesmo de quando Priority Ceiling é usado

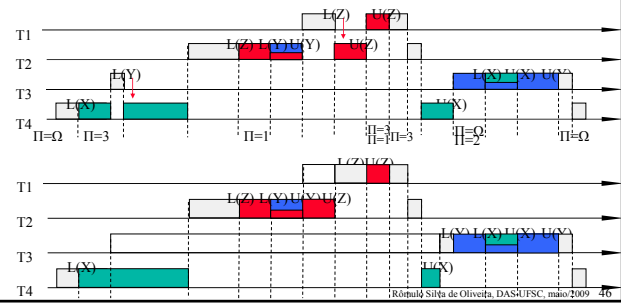
(4) Immediate Priority Ceiling: Exemplo

- Tetos de prioridade:
 - $\Pi(X)=3, \Pi(Y)=2, \Pi(Z)=1$



(4) Immediate Priority Ceiling: Exemplo

- Teto de Prioridade versus Teto de Prioridade Imediado



(4) Immediate Priority Ceiling

- Comportamento de pior caso é o mesmo
 - Priority Ceiling
 - Immediate Priority Ceiling
- Immediate Priority Ceiling
 - É mais fácil de implementar
 - Quem bloqueia quem não precisa ser monitorado
 - Gera menos chaveamentos de contexto pois não ocorre bloqueio após o início da execução
 - Requer mais movimentos de prioridade pois isto acontece a cada uso de recurso
- Immediate Priority Ceiling é chamado de
 - Priority Protect Protocol em POSIX
 - Priority Ceiling Emulation em Real-Time Java

Resumo

- Acesso a recursos compartilhados
 - Gera bloqueio (inversão de prioridades)
 - Pode gerar deadlock
- Mutex simples é ineficaz
- Necessário usar protocolos específicos para tempo real
- Desliga Preempção
- Herança de Prioridade
- Priority Ceiling
- Immediate Priority Ceiling