



Gestion de la mémoire virtuelle dans Linux

Imed Chihi <imed.chihi@gmail.com>
Décembre 2010


Agenda

- Définitions
- Le besoin de bien gérer la mémoire
- Organisation de la mémoire physique
- Organisation de la mémoire virtuelle
- Architecture et vue d'ensemble
- Avantages et exploitation en pratique
- Allocateurs de mémoire
- Quelques détails d'implémentation sous Linux

Définitions

Gestionnaire de la mémoire virtuelle

*Ensemble de programmes et de matériel pour gérer la ressource
“mémoire physique”*



Source: Red Hat Magazine, Novembre 2004


Le besoin de bien gérer la mémoire

Mémoire physique


Éléments de stockage de données “hiérarchisés”


- *ressource cruciale*
- *hiérarchique*
- *pas assez rapide*

Le modèle Von Neumann




*Higher capacity,
lower cost,
and slower memories*





La tendance continue..



Source: Computer Architecture, AQA – Hennessy and Patterson

Organisation de la mémoire physique

- Espace d'adresses contiguës, ou presque
- Le BIOS fournit une carte de la mémoire
 - BIOS 0xe820 system memory map (int 0x15)

“Carte” de la mémoire physique

```
# dmesg
```

```
(..)
```

```
BIOS-provided physical RAM map:
```

```
BIOS-e820: 0000000000000000 - 000000000009bc00 (usable)
BIOS-e820: 000000000009bc00 - 00000000000a0000 (reserved)
BIOS-e820: 00000000000e0000 - 0000000000100000 (reserved)
BIOS-e820: 0000000000100000 - 00000000bfff6000 (usable)
BIOS-e820: 00000000bfff6000 - 00000000bfff6a00 (ACPI data)
BIOS-e820: 00000000bfff6a00 - 00000000bfff8000 (ACPI NVS)
BIOS-e820: 00000000bfff8000 - 00000000c0000000 (reserved)
BIOS-e820: 00000000e0000000 - 00000000f0000000 (reserved)
BIOS-e820: 00000000fec00000 - 00000000fec10000 (reserved)
BIOS-e820: 00000000fee00000 - 00000000fee01000 (reserved)
BIOS-e820: 00000000ff000000 - 0000000100000000 (reserved)
BIOS-e820: 0000000100000000 - 0000000240000000 (usable)
```

```
(..)
```

```
Memory: 8160592k/9437184k available (2112k kernel code, 0k
reserved, 1305k data, 208k init)
```

Zones

- Les adresses mémoires ne sont pas “équivalentes”

→ Rassembler les adresses “similaires” dans des zones

```
# dmesg
```

```
(..)
```

```
Zone PFN ranges:
```

```
DMA          0x000000000 -> 0x000001000
```

```
Normal      0x00001000 -> 0x000377fe
```

```
HighMem     0x000377fe -> 0x000bb800
```

Non-Uniform Memory Access

```
# dmesg
(..)
Scanning NUMA topology in Northbridge 24
Number of nodes 2 (10010)
Node 0 MemBase 000000000000000000 Limit 000000003fffffff
Node 1 MemBase 000000004000000000 Limit 000000007fff0000
(..)
On node 0 totalpages: 262143
  DMA zone: 4096 pages, LIFO batch:1
  Normal zone: 258047 pages, LIFO batch:16
  HighMem zone: 0 pages, LIFO batch:1
On node 1 totalpages: 262128
  DMA zone: 0 pages, LIFO batch:1
  Normal zone: 262128 pages, LIFO batch:16
  HighMem zone: 0 pages, LIFO batch:1
```

Organisation de la mémoire virtuelle (VM)

- Présenter aux applications une vue artificielle de la mémoire physique
- Chaque processus “voit” un espace d'adressage qui lui est propre
- Le gestionnaire de la mémoire virtuelle (VMM) se charge de faire les correspondances

Paging

- Diviser la mémoire (physique et virtuelle) en des morceaux de taille fixe, appelés “**pages**”
- Maintenir des “**page tables**” pour faire l'association entre une page virtuelle et une physique
- Maintenir une “carte de mémoire” avec des informations sur chaque page physique
- Utiliser des composants matériels pour accélérer la conversion virtuel → physique

Espace d'adressage des processus

```
$ pmap -x 8375
```

```
8375:  gcalctool
```

Address	Kbytes	RSS	Anon	Locked	Mode	Mapping
00110000	3892	-	-	-	r-x--	libgtk-x11-2.0.so.0.2000.1
004dd000	16	-	-	-	r----	libgtk-x11-2.0.so.0.2000.1
004e1000	8	-	-	-	rw---	libgtk-x11-2.0.so.0.2000.1
004e3000	8	-	-	-	rw---	[anon]
004e5000	256	-	-	-	r-x--	libpango-1.0.so.0.2800.0
00525000	4	-	-	-	-----	libpango-1.0.so.0.2800.0
00526000	4	-	-	-	r----	libpango-1.0.so.0.2800.0
(..)						
b7785000	4	-	-	-	r----	LC_IDENTIFICATION
b7786000	28	-	-	-	r--s-	gconv-modules.cache
b778d000	4	-	-	-	r----	LC_NUMERIC
b778e000	8	-	-	-	rw---	[anon]
bfe49000	112	-	-	-	rw---	[stack]
-----	-----	-----	-----	-----		
total kB	36232	-	-	-		

Conversion des adresses mémoire

- Les “page tables” contiennent des “**page table entries**” (PTE)
- Chaque PTE contient un numéro de page et des informations sur son état
- Le “Translation Look-aside Buffer” (TLB) est un cache des résultats de la conversion virtuel → physique


La VM, pour quoi faire?

- Les processus ont un espace d'adressage plus large
- La VM peut satisfaire des allocations qui dépasseraient la capacité physique: “**overcommit**”
- Partage de la mémoire entre plusieurs processus
- Prétendre satisfaire des allocations et retarder l'allocation réelle autant que possible: “**Copy-on-Write**” (COW) ou “**Lazy Allocation**”
- Prétendre satisfaire des chargements du disque et retarder l'accès réel autant que possible: “**demand paging**”

La VM, pour quoi faire? – cont.

- Servir de cache des accès disque (**page cache**); pas vraiment VM, mais..
- Permettre de “mapper” des fichiers à l'espace d'adressage d'un processus: assurer un “**zero-copy**”

Vue d'ensemble



Allocation de mémoire physique

- Les allocations utilisent un sous-système qui s'appelle: “**slab**”
- Alloue des objets de même taille de manière optimale

Allocation de mémoire physique

```
# cat /proc/slabinfo
slabinfo - version: 2.1
# name          <active_objs> <num_objs> <objsize> <objperslab> <pagesperslab> :
tunables <limit> <batchcount> <sharedfactor> : slabdata <active_slabs> <num_slabs> <sharedavail>
fat_inode_cache      158      195      416      39      4 : tunables      0      0      0 : slabdata      5      5      0
fat_cache            340      340       24     170      1 : tunables      0      0      0 : slabdata      2      2      0
isofs_inode_cache    43       63      384      21      2 : tunables      0      0      0 : slabdata      3      3      0
nf_contrack_expect    0         0      168      24      1 : tunables      0      0      0 : slabdata      0      0      0
nf_contrack_c08d9a40 63       170      240      34      2 : tunables      0      0      0 : slabdata      5      5      0
kvm_vcpu              0         0     9104       3      8 : tunables      0      0      0 : slabdata      0      0      0
kvm_mmu_page_header   0         0      136      30      1 : tunables      0      0      0 : slabdata      0      0      0
kmalloca_dma-512     32       64      512      32      4 : tunables      0      0      0 : slabdata      2      2      0
RAWv6                 34       46      704      23      4 : tunables      0      0      0 : slabdata      2      2      0
UDPLITEv6             0         0      704      23      4 : tunables      0      0      0 : slabdata      0      0      0
UDpv6                 23       46      704      23      4 : tunables      0      0      0 : slabdata      2      2      0
tw_sock_TCPv6         0         0      256      32      2 : tunables      0      0      0 : slabdata      0      0      0
TCPv6                 25       48     1344      24      8 : tunables      0      0      0 : slabdata      2      2      0
flow_cache            0         0       80      51      1 : tunables      0      0      0 : slabdata      0      0      0
dm_raid1_read_record  0         0     1056      31      8 : tunables      0      0      0 : slabdata      0      0      0
kcopyd_job            0         0      272      30      2 : tunables      0      0      0 : slabdata      0      0      0
dm_uevent             0         0     2464      13      8 : tunables      0      0      0 : slabdata      0      0      0
dm_rq_target_io       0         0      224      36      2 : tunables      0      0      0 : slabdata      0      0      0
(..)
```

Allocation de mémoire physique

- Le système slab utilise un algorithme d'allocation: “**buddy allocator**”
 - Allouer des blocs de taille en puissance de 2. Si indisponible, prendre l'ordre suivant
 - Refusionner les blocs en des blocs aussi gros que possible à la libération
- Différents types d'allocation:
GFP_ATOMIC, GFP_DMA, GFP_NOFAIL,
GFP_KERNEL

Allocation de mémoire physique

```
# echo 1 > /proc/sys/kernel/sysrq
# echo m > /proc/sysrq-trigger
$ dmesg
(..)
DMA: 6*4kB 4*8kB 4*16kB 6*32kB 4*64kB 2*128kB 4*256kB
1*512kB 2*1024kB 2*2048kB 0*4096kB = 8504kB
Normal: 10*4kB 8*8kB 4*16kB 6*32kB 2*64kB 1*128kB 3*256kB
3*512kB 2*1024kB 2*2048kB 126*4096kB = 525160kB
HighMem: 261*4kB 165*8kB 239*16kB 383*32kB 285*64kB
168*128kB 52*256kB 10*512kB 11*1024kB 15*2048kB 233*4096kB
= 1072972kB
```

Swapping et pages anonymes

- Une page peut être: **free**, **active**, **inactive** (**dirty**, **laundry**, **clean**)
- La Memory Management Unit (MMU) peut détourner certains accès à une page virtuelle: **page fault**. Mécanisme servant au demand paging et aux COW.
- Le système de fichiers et le swap sont des “**backing store**” pour les pages de la mémoire physique
- Les pages dont le backing store est le swap sont dites “**anonymous**”
- Les cas de grande demande sur la mémoire par les processus s'appelle: “**memory pressure**”

Swapping et pages anonymes

- En cas de pression mémoire, les pages éligibles sont **évictées** de la mémoire physique vers leurs backing stores respectifs
- Ce processus d'éviction et de re-attribution de mémoire est appelé: **memory reclaiming**
- Les pages “inactive” ne peuvent être évictées qu'une fois devenues “clean”

Quelques détails d'implémentation

- Physical Address Extension (PAE)
- Division espace utilisateur / espace noyau
- 32-bit vs. 64-bit
- Problèmes de la zone Normal dans les systèmes 32-bit
- Le Out Of Memory killer (OOM)
- Désactiver le pagecache avec “**O_DIRECT**” et les montages “**sync**”
- Verrouillage de mémoire avec mlock() et applications temps réel