Bordeaux INP
ENSEIRB
MATMECA

IT201

Système d'exploitation

Brice Goglin

2018-2019

Copyright et Licence

- Copyright © 2007-2019 Brice Goglin.
- Ce support de cours est diffusé sous licence *Creative Commons CC-BY-NC-SA*.
  - http://creativecommons.fr/licences/les-6-licences/

Ceci n'est PAS un polycopié de cours.

Ces « notes » guident simplement le cours.

De nombreuses explications et illustrations manquent, les détails seront donnés au tableau et à l'oral pendant le cours magistral.

Pour me joindre

- Bâtiment Inria, 200 avenue de la vieille tour
- Bureau B425, 05.24.57.40.91

- Envie de découvrir la recherche en système ou HPC ? Stage, thèse, ...

- Brice.Goglin AT inria.fr
- http://people.bordeaux.inria.fr/goglin/

- Facile à trouver dans Google !

Programme du module

- ~~15~~ **11** séances de cours
- ~~10~~ **8** séances de 2h de TD
  - ~~Prévoyez vos laptops pour les deux dernières~~
- Slides du cours et sujets de TD en ligne
  - http://people.bordeaux.inria.fr/goglin/teaching/Systeme.html
  - Beaucoup d'illustrations et explications y manquent
- Examen d'environ 2h
  - Tous documents autorisés
- Projet système (IT202) début février

Sondage

- Qui n'a pas suivi de **prog système** ?
- Qui n'a pas suivi de cours d'**architecture** ?
- Qui n'a jamais **utilisé** Linux ?

- Qui a déjà **compilé** un noyau Linux ?
- Qui a déjà **regardé** les sources de Linux ?
- Qui a déjà **modifié** les sources de Linux ?
- Qui a déjà **écrit** un système d'exploitation ?

Positionnement du cours

- Structure en couche
  - En dessous de la programmation système
  - Au dessus de l'architecture
- Domaine vaste
  - des concepts logiciels...
  - ... aux implémentations matérielles
  - en passant par les algorithmes mis en jeu
- Illustration surtout par le noyau Linux
- Pré-requis : architecture et prog système

Plan du cours

- Introduction
- Concepts généraux
- **Processus et exécution**
- **Gestion mémoire**
- Concurrence et synchronisation
- Gestion du temps
- ~~Systèmes de fichiers~~
- ~~Entrées-sorties~~
- Virtualisation

Bibliographie

- Polycopié de l'ancien prof
- Livres sur les systèmes d'exploitation
- Livres sur Linux
- Ressources en lignes diverses

- Voir la page web du cours !

Introduction

Pourquoi des systèmes d'exploitation?

- OS (*Operating System*)
- Il arrive parfois qu'on n'en utilise pas
  - Quelques systèmes embarqués
  - Mais souvent une bonne idée d'en utiliser un
- Exposer interface virtuelle indépendante du matériel
  - Gérer les différents matériels et leurs limites
    - Rendre les choses simples et uniformes pour l'utilisateur, le programmeur et les applications
- Gérer de multiples tâches et utilisateurs

Pourquoi est-ce intéressant?

- Connaître son fonctionnement permet de mieux exploiter les machines
- Inutile de réinventer la roue, l'OS fait déjà plein de choses pour vous

Probablement le logiciel le plus complexe

- Des aspects très techniques (matériel)
- Du génie logiciel (les interfaces doivent être pratiques, efficaces et fiables)
- De l'optimisation (performances cruciales)
- Des compromis
  - Supporter tout à peu près bien?
  - ... ou supporter certains cas parfaitement?
- De l'algorithmique, des heuristiques
  - Deviner ce que l'utilisateur/application veut
  - S'y adapter, s'y préparer à l'avance, ...

Ceci n'est PAS le système d'exploitation

- Compilateurs
  - et les bibliothèques ?
- Système de fenêtrage (X.org, ...)
  - même si il touche aux périphériques
- Interpréteur de commandes (bash, ...)
- Outils en ligne de commande (cp, mv, ...)
- Le super-utilisateur (root)
- Un processus « homme en noir » qui surveille et contrôle tout depuis le fond

Ceci peut être un système d'exploitation

- Le noyau
  - Le coeur, qui s'exécute en mode privilégié
- Eventuellement des bibliothèques autour
  - La bibliothèque standard (libc sous Linux)
    - Fournit les appels système
  - ex: GNU/Linux vs. Linux
- Eventuellement des outils, services, démons, ...
  - Qui rendent l'OS plus facile à utiliser

root vs. noyau

- Le super-utilisateur n'est pas le noyau
  - Il a juste un accès privilégié au noyau
    - Le noyau le laisse faire plus de choses
- Le noyau contrôle tout
  - Il y accède par les appels-système
  - Il vérifie ce que les utilisateurs veulent faire
- root privilégié **logiciellement** par le noyau
  - Le noyau est privilégié **matériellement**
    - par le processeur

Exemples d'OS

- Linux (sur des dizaines d'architectures)
- Windows (x86 et ARM)
- Solaris (Sparc et x86)
- FreeBSD, NetBSD, OpenBSD, ...
- GNU/Hurd
- MacOS X (x86 et PowerPC)
- PalmOS, Plan9, Symbian, VxWorks, ...

Petite disgression :

Ordre de grandeurs

Exécution

- Processeur
  - Dizaine(s) de coeurs
  - Fréquence
    - ~3 Ghz
  - Instruction (cycle)
    - 1 ns
  - Instruction atomique
    - 100 ns
  - Appel-système
    - 50-1000 ns

Mémoire et I/O

- Mémoire
  - 10 Go, 50-100 ns, 50 Go/s
- Mémoire cache
  - 10 ko – 100 Mo, 1-10 ns
- Bus PCI
  - Go/s, 100+ ns
- Interruption
  - 5 µs

Stockage et réseau

- Disque
  - Mécanique
    - 10 To, 10 ms, 10-100 Mo/s
  - SSD, NVMe, ...
    - 0,1–10 To, 1-100 µs, 0,1–10 Go/s
- Réseau
  - A la maison
    - 10-1000 ms, 1-100 Mo/s
  - Réseaux hautes performances
    - 1 µs, 10 Go/s

Système d'exploitation

Encore une petite disgression :

Que se passe-t-il pendant le boot ?

Boot matériel

- Au démarrage, les processeurs ne savent pas quoi faire
  - Et la mémoire est vide
- Le premier coeur *(Bootstrap Processor*) est configuré pour exécuter le code stocké à une adresse spéciale
  - Le système est configuré pour avoir de code de démarrage à cette adresse
    - Cette adresse pointe vers une mémoire spéciale
      - ROM (*Read Only Memory*), non volatile

BIOS, UEFI, OpenFirmware, ...

- Le processeur exécute le BIOS (*Basic Input Output System)*
  - ou UEFI (*Unified Extensible Platform Interface)* sur machines récentes
  - ou Open Firmware sur les architectures non-x86
  - plus ou moins portable
- C'est l'interface bas-niveau avec le matériel
  - Détecte les composants
    - Autres processeurs, mémoire, périphériques, ...
    - Et les ressources (mémoire embarquée, ports, ...)

BIOS, UEFI, OpenFirmware, ... (2/2)

- Sait faire plus ou moins de choses
  - Configurateur graphique
    - Réglages du processeur, choix du périphérique de démarrage, etc.
  - Exécution de code depuis différents endroits
    - Début du premier disque, CD, USB, réseau (PXE), ...
- Une fois terminé, il charge le code de l'OS
  - Depuis le disque ou le réseau
    - Souvent au début du premier disque dur
      - *Master Boot Record*
  - Puis l'exécute

Boot Loader

- Après le BIOS, on est pas obligé de démarrer un vrai OS
- Le *Boot Loader* (Lilo ou Grub) est un mini-OS conçu pour choisir
  - Quel OS lancer ?
    - Sur quelle partition, avec quel fichier de noyau, ...
      - Impose de savoir lire ce fichier
        - Il peut être stocké de manière discontigue sur le disque
  - Avec quels paramètres, ...

Boot du noyau

- Le *Boot Loader* saute à un autre programme
- Le noyau se lance
  - détection des ressources matérielles via le BIOS
  - création des ressources logicielles de base
    - chargement du code
    - table de page
    - descripteurs de périphériques
    - ...
  - démarrage des autres coeurs
  - quelques démons (threads noyau)
    - travaux système en arrière-plan

Boot du système d'exploitation

- La tâche « chargement du noyau » se transforme en un vrai processus utilisateur : *Init*
  - Le noyau est fonctionnel, l'OS démarre
- *Init* charge les services logiciels configurés par l'administrateur
  - Gestionnaire de périphériques
    - Chargement de modules pilotes
  - Démons utilisateurs
    - Services utilisateur en tâche de fond
    - Gestionnaire de session
    - ...

Concepts généraux

Plan

- Les principaux concepts
- Structure des systèmes
- Exemples de systèmes

Concepts généraux :

Les principaux concepts

Objectifs des systèmes d'exploitation

- Rendre le système plus facile à utiliser
  - Abstraction des périphériques
- Améliorer l'efficacité du système
  - Fournir des ressources efficacement
- Facilité d'évolution
  - Continuer à fournir les mêmes services de la même façon
- Protection des différents programmes
- Sécurité vis-à-vis des autres utilisateurs

Interface entre utilisateur et machine

- Interface uniforme d'accès aux périphériques
  - Détails techniques cachés
- Exécution de programmes
- Accès contrôlé aux données
  - Montrer le contenu structuré des périphériques de stockage et réseau
  - Fournir des fonctions d'édition, développement, communication, ...

Interface entre utilisateur et machine (2/2)

- Gérer les erreurs proprement
  - Signaler aux programmes les erreurs matérielles
  - Réagir en cas d'erreur logicielle
    - Punir ou corriger
- Fournir des statistiques d'utilisation et fonctionnement
  - Permet à l'utilisateur de mieux adapter la configuration du système

Évolution historique

- *Serial Processing* (~1950)
  - Lancement manuel d'un nouveau programme à la terminaison du précédent
- *Simple Batch Systems* (~1960)
  - File d'attente de programmes
- *Multiprogrammed Batch Systems* (~1970)
  - Exploiter le matériel en alternant les processus
- *Time Sharing* (~1980)
  - Alternance automatique entre processus
  - Interactivité

Processus

- Contexte mémoire propre
  - Exécution indépendante des autres processus
- Une file d'exécution (registres + pile)
  - Eventuellement plusieurs si multithreading
    - Permet I/O bloquante sans bloquer tout le processus

- Exécution concurrente pour maximiser l'utilisation des ressources matérielles

Système multi-tâche et préemption

- Système multi-tâches
  - Existence et exécution de plusieurs tâches simultanément
- Système préemptif
  - Ordonnancement non-contraint à la bonne volonté du processus en cours
    - Ordonnancement de force par le système

Gestion mémoire

- Isolation des processus
  - Pas de collision entre leurs mémoires
    - Données et instructions propres
  - Grâce à la mémoire virtuelle et au support matériel
- Allocation et gestion transparente
  - Pas de contraintes sur le programmeur
- Programmation modulaire
  - Bibliothèques réutilisables
- Partage de mémoire avec protection
- Stockage en mémoire persistante

Protection des données et sécurité

- Contrôle des autorisations
  - Accès aux données critiques du système
  - Accès et modification des données des utilisateurs
- Authentification des utilisateurs
- Survie à un problème technique ?

Ordonnancement et gestion des ressources

- Accès aux ressources équitable
  - Pour les travaux de même type
    - Quid des processus multi-threadés
  - En distinguant des classes de travaux
    - Interactif ? I/O ? Calcul pur ?
- Contrôle dynamique
- Efficacité
  - Utilisation du matériel et réactivité

Ordonnancement et gestion des ressources (2/2)

- Ordonnancement de processus et/ou d'entrées-sorties
  - Dans quel ordre envoyer les lectures/écritures sur le disque ?
- Contraintes *Deadline*
  - Événement doit arriver avant...
  - Systèmes temps réel, ...
- Contraintes matérielles
  - Ex: *Elevator*

Les architectures sont parallèles : SMP et NUMA

- Plusieurs processeurs
  - SMP (*Symmetric MultiProcessor*)
  - Accès concurrents
  - Affinité pour un processeur
    - Cache, TLB, ...
  - Affinité des threads d'un même processus
- Contraintes NUMA
  - NUMA (*Non-Uniform Memory Access*)
  - Affinité pour certaines zones mémoire

➔ Nouvelles contraintes d'ordonnancement

Système d'exploitation

Concepts généraux :

Structure des systèmes

Structure du système d'exploitation

- Noyau
  - Coeur
  - Pilotes de périphériques
  - Interface vers l'utilisateur
- Bibliothèques utilisateur de bas niveau
  - Appels système pour parler au noyau
    - Incontournable !
      - Assuré par le matériel
- Et au dessus il y a vos applications

Structure (2/2)

- Gestion mémoire au coeur du système
  - Processus
  - Systèmes de fichiers
  - Réseau
- Systèmes de fichiers et stockage
- Ordonnancement
- Communications entre processus
- Réseau

Noyaux monolithiques

- Ensemble de procédures pouvant toutes s'appeler les unes les autres
  - Très peu d'organisation
- Souvent découpé en
  - Procédures principales
    - Appels-système
  - Procédures de services
    - Traitement effectif
  - Procédures utilitaires
    - Gestion de listes, tables de hachage, ...

Linux monolithique ?

(cf aussi l'*Interactive Map* en lien sur le site du cours)

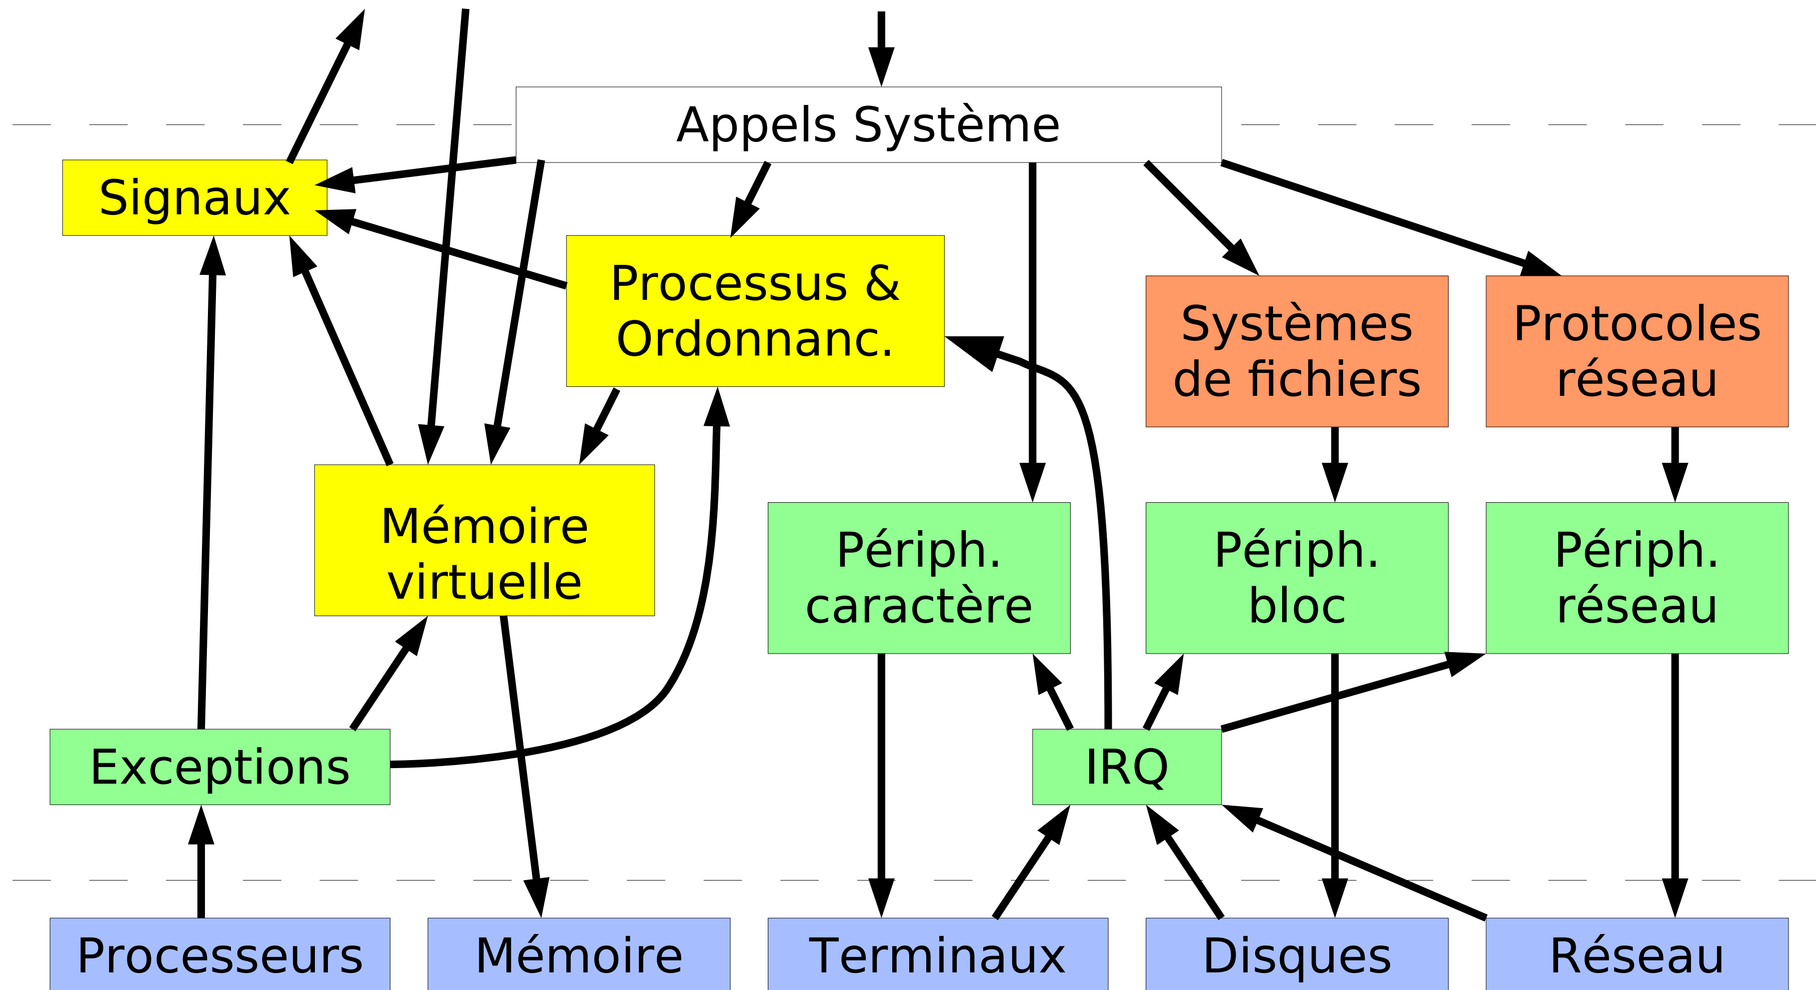

Noyaux en couche

- Tentative d'organisation des monolithiques
- Limites entre couches difficile à définir
  - La gestion mémoire a besoin des I/O pour remplir les pages
  - Les I/O ont besoin de mémoire pour allouer des tampons intermédiaires
- Traversée des couches contraignantes pour les performances

Noyaux modulaires

- Chargement/déchargement dynamique de code optionnel
  - Pilotes de périphériques
  - Fonctionnalités spécifiques
- Réduction du noyau initial
- Possibilité d'évolution dynamique
  - Sans redémarrage

Micronoyaux

- Noyaux monolithiques trop gros ?
  - Pas organisés, même avec des couches
    - Difficile à organiser clairement et efficacement
  - Sécurité difficile à intégrer car trop d'interactions possibles
  - Difficile à maintenir et faire évoluer
- Micronoyaux
  - Uniquement le strict nécessaire
  - Le reste dans des processus serveurs dédiés
- Éternelle dispute entre Torvalds et Tanenbaum

Micronoyau (2/3) : Design

- Un serveur pour chaque tâche
  - Processus, gestion mémoire, ordonnancement, réseau, systèmes de fichiers
    - Dans des espaces mémoire séparés
  - Passage de message entre applications et serveurs
    - Validés par le micronoyau
- Interfaces simples et uniformes
- Extensible, flexible
- Fiable

Micronoyaux (3/3) : Performance

- Passage de message plus lent qu'un appel direct de procédure du noyau ?
- Trop d'interactions critiques entre composants du système d'exploitation ?
  - Mémoire et systèmes de fichiers ?
- Difficile de comparer avec noyaux monolithiques
  - Pas de vrai OS fonctionnel entièrement basé sur un micronoyau
    - GNU/Hurd ?

Concepts généraux :

Exemples de systèmes

Windows

- Très modulaire
  - Ensemble de *Managers (Executive)*
    - *I/O*, *Cache*, *PnP*, *Power*, *Security*, *VM*, *Process*, ...
  - Couche d'abstraction des périphériques
  - Pilotes de périphériques
  - Fenêtrage et graphisme
- Noyau hybride (pseudo micro-noyau)
  - Quasiment tout tourne dans un seul espace noyau
    - Pour des raisons de performance

Windows (2/3)

- *Local Procedure Calls*
  - Échange de message entre applications et managers
    - Modèle *Client-Serveur*
  - Permet communication entre modules, qu'ils soient en mode noyau ou utilisateur
- Design orienté objet (Polymorphisme)
  - Les *Handles* permettent de manipuler tout et n'importe quoi de la même façon

Windows (3/3)

- Support SMP, threads, communications entre processus, ...
- Ordonnanceur de threads préemptif avec priorités
  - Avec affinité pour cache et NUMA
  - Priorité ajustée dynamiquement selon attente passive (GUI) et consommation CPU
- Conçu pour bureautique (initialement)

Unix

- Créé à la fin des années 60
- Design pour serveur et réseau
- Portable car rapidement écrit en C
- Tout est fichier
- Noyau (*kernel*) + Ensemble de bibliothèques et applications (*libc*)
  - Appels système (*System Call Interface*)

Unix (2/3)

- Noyau monolithique
  - Fonctionnalités communes
  - Gestionnaire mémoire
  - Périphériques bloc
  - Périphériques caractère
  - Ordonnanceur
  - Interface Vnode/VFS pour les fichiers

Unix (3/3)

- *System V Release 4*
  - Académique et commercial (AT&T et Sun)
- *Solaris* (*SunOS*)
  - Distribution commerciale (Sun) basé sur SVR4
- *Berkeley Software Distribution* (*BSD)
  - Très répandu dans le monde académique
  - Base de Mac OS X
- *Minix*
  - Clone à but éducatif
- Voir lien vers arbre généalogique

Linux

- Apparu en 1991
- Basé sur *Minix*
  - Pas trop cher pour usage personnel
- Libre (GPL-2)
- Développement collaboratif sur Internet
- Supporte de nombreux architectures et périphériques matériels
- Conçu pour serveurs, stations de travail, bureautique, embarqué, ...

Linux (2/2)

- Chargement dynamique de modules noyau
  - Chargement automatique selon les besoins des applications
  - Hiérarchie basée sur dépendances de symboles
- Structure monolithique particulière
  - Seules certaines fonctions sont accessibles aux autres modules
    - EXPORT_SYMBOL()
  - Pas d'interface fixée

The GNU Hurd

- Le seul vrai OS basé sur un micronoyau ?
  - Unix sur micronoyau *Mach*
  - Pilotes de périphériques limités
- IPC entre composants via le micronoyau
  - Processus serveur et applications
    - L'utilisateur peut lancer ses propres serveurs
      - Réseau, système de fichiers, … sans être root
        - Sans impacter le reste du système
- Notion de *Translator* (voir lien)
  - Fonctionnalité (fichier, répertoire, accès réseau, …) gérée par processus
    - Parcours aisé d'un site web, serveur ftp, archive, …

Processus et exécution

Plan

- Description des processus
- Exécution des processus
- Processus et threads
- Vie et mort des processus
- Ordonnancement
- Algorithmes d'ordonnancement
- Exécution du système

Processus et exécution

Description des processus

Objectifs des processus

- Toutes les applications semblent progresser simultanément
  - Les processeurs physiques les exécutent en alternance
  - Chaque application a l'illusion d'être seule sur la machine
- Partager les ressources disponibles entre de multiples applications
- Le processeur et les périphériques sont utilisés efficacement

Définitions d'un *Processus* ?

- Programme en exécution
- Instance d'un programme s'exécutant sur un ordinateur
- Entité pouvant être assignée et exécutée sur un processeur
- Unité d'activité caractérisée par l'exécution d'une suite d'instructions, un état courant et un ensemble de ressources système

Caractérisation

- A l'initialisation
  - Code du programme
  - Ensemble de données en entrée
- Durant l'exécution
  - Bloc de contrôle
    - Contient un identifiant
      - PID (*Process Identifier*)

Bloc de contrôle d'un processus

- Identifiant
- Adresses mémoire
  - Données utilisateur, programme, pile, ...
- *Program Counter*
- État d'ordonnancement
  - En exécution, prêt, bloqué, mort, ...
  - Priorité
- État des entrées/sorties
- Privilèges
- Statistiques

Généalogie

- Le processus a un père
  - Et peut avoir des fils
  - Le père est notifié de la mort des fils
    - Et peut l'attendre et savoir s'il a réussi
- Cas des orphelins
  - Il leur faut un père
    - Dans Linux, c'est *Init* (PID=1) par défaut
      - Modifiable avec prctl()

Processus et exécution

Exécution des processus

Beaucoup d'architectures différentes

- x86/x86_64
- IA64
- Alpha
- PowerPC
- Sparc
- ARM
- MIPS
- ...
- Quel est le plus vendu ?

Exécution dans les processeurs

- Une instruction par cycle (par pipeline)
  - Durée du cycle fixe, reliée à la fréquence
- Interruption régulière par horloge
  - Permet de donner la main au système régulièrement
    - Environ 1 fois par milliseconde sous Linux
- Différents modes d'exécution avec différents privilèges

État du processeur et contexte d'exécution

- Registres utilisateurs
  - Données
  - Adresses
    - Segment, pile, ...
- Registres de status et contrôle
  - *Program Counter* (PC)
  - Status arithmétique

Modes d'exécution

- Plusieurs niveaux de privilèges
  - Mis en place matériellement
    - Par le processeur
  - Accès aux registres de contrôle
  - Instructions d'entrées/sorties de bas niveau
  - Gestion mémoire
    - Ex: Accès à CR3 pour la table des pages sur x86
  - Accès à certaines zones mémoire
    - Limité par les structures pointées par certains registres

Modes d'exécution (2/3)

- Différents niveaux de privilèges
  - Jeu d'instructions réduit selon les privilèges
- Le noyau peut tout faire
  - *Protection Ring* 0 sur x86 (mode protégé)
  - Sauf en cas de virtualisation matérielle
    - Seul l'hyperviseur peut vraiment tout faire

Modes d'exécution (3/3)

- L'utilisateur est très limité
  - *Protection Ring* 3 sur x86
  - Pas d'accès à la mémoire du noyau
    - Non visible dans la table de pages
      - qui n'est pas modifiable sans privilèges
  - Pas d'accès bas niveau au matériel
    - Sauf si autorisation préalabre (ex: ioperm, iopl)

Exceptions et interruptions

- Evénements inattendus qui interrompent temporairement l'exécution en cours
- Le processeur saute automatiquement et immédiatement à un traitant
  - Fonction dont l'adresse a été définie par le système d'exploitation au démarrage
    - Dépend du type d'exception ou interruption
- Déroutement
  - Suspension du programme en cours
  - Retour au code initial à la fin du traitant

Exceptions

- Interruption par le processeur lui-même
  - En cas d'erreur
    - Erreur arithmétique (division par zéro, ...)
    - Mauvais accès mémoire (segfault, ...)
- Processeur ne sait pas comment continuer !
  - Il demande à l'OS de l'aider
    - Déroutement vers traitant qui va corriger l'erreur
  - Reprise ensuite de l'exécution au même endroit
    - L'instruction fautive est re-exécutée
  - L'application ne se rend compte de rien

Exceptions (2/2)

- Exception uniquement possible quand le processeur travaille
  - Nécessite contexte d'exécution
    - Processus, thread noyau, ...
    - Qu'il soit dans le noyau ou en espace user
- Reprise de l'exécution uniquement si le traitant a réparé l'erreur avec succès
  - Ex: Défaut de page
  - Sinon la tâche est tuée
    - Ex: Segmentation Fault

Interruptions

- IRQ = *Interrupt Request*
- Interruption = Message d'un périphérique
  - Signal électrique sur broche dédiée du processeur
    - ou Ecriture à adresse mémoire spéciale (si matériel récent)
- Evénement asynchrone
  - Le processeur pourrait continuer à tourner en l'ignorant pendant un certain temps
    - Mais OS et/ou applications auraient des problèmes
      - Entrée-sortie non terminée, carte réseau saturée...

Interruptions (2/2)

- Interruption possible n'importe quand
  - Même si le processeur ne fait rien
    - Il suffit qu'un périphérique ait été initialisé
- Déroutement temporaire dans le pilote du périphérique
  - Traitement de la requête
    - Réception paquet réseau, ...
- Pas d'influence directe sur la tâche qui s'exécutait
  - L'application ne se rend compte de rien
  - Mais peut réveiller des tâches qui attendaient la fin d'une entrée/sortie

Exceptions et interruptions (2/2)

- Traitement très similaire
  - Passage temporaire en mode privilégié
    - Un seul cœur (une seule tâche suspendue)
  - Exécution du traitant spécifique
    - Selon exception ou interruption et paramètres
  - Retour à l'exécution initiale
- Exception spéciale pour appels système
  - Changement de mode d'exécution
    - Passage du mode utilisateur au mode noyau
      - Augmentation temporaire des privilèges
    - Instruction spéciale pour revenir

Cas particulier d'exception : Les appels-système

- Exception forcée par l'application
  - Pour effectuer opération privilégiée
    - Changement de mode d'exécution du processeur à la demande
- Se produit uniquement depuis l'espace utilisateur
  - A la demande des applications
- Traité dans le contexte d'un processus
  - En mode privilégié

Cas particulier d'exception : Les appels-système (2/2)

- Déroutement
  - Passage à un mode plus privilégié par instruction spéciale
    - Exception dédiée (int80, ...)
    - *Callgate*
    - Instruction dédiée (sysenter, syscall, ...)
  - Appelé par l'application en mode utilisateur
    - Généralement par des fonctions de la libc
- Passage obligatoire de toute application
  - Impossible de tricher
    - Vérification des paramètres en mode privilégié

Appels-système (1/4)
Comment ca marche ?

- Traitement de l'appel système dans le traitant de l'instruction spéciale
  - Adresse du traitant défini par le noyau au boot
    - Comme pour les traitants d'interruption/exception
      - Le processeur y saute immédiatement lors de l'appel système
  - Exécution temporaire en mode privilégié
    - Le processus n'est pas endormi, son exécution est déroutée
  - Appel d'un sous-traitant dans la table des appels système
    - Table non modifiable depuis l'espace utilisateur

Appels-système (2/4) : L'appel

- Convention de passage des paramètres
  - Numéro dans %eax sur Linux/x86
  - Arguments: %ebx, %ecx, %edx, %esi et %edi
  - Et dans la pile si nécessaire (mmap)
- Sauvegarde des paramètres
- Sauvegarde du contexte utilisateur
- Appel du traitant
  - Après mise des paramètres dans registres
  - Saut à syscall_table[numéro]

Appels-système (3/4) : Le retour

- Restauration des registres utilisateurs
- Convention pour le passage de la valeur de retour de l'appel système
  - Ex: %eax pour Linux/x86
- Possibilité de passer plus de paramètres ou valeurs de retour
  - Pointeurs dans les arguments
    - Le noyau peut lire/écrire en espace utilisateur
- Retour concret en espace utilisateur par instruction spéciale (iret, sysexit, ...)

Appels-système (4/4) : Concrètement dans Linux

- Code assembleur caché dans la glibc
  - On appelle des fonctions « normales »
- 386 appels-système dans Linux 4.21/x86
  - De nombreux sont dépréciés
    - 52 non implémentés sur x86_64
  - La glibc s'adapte à ceux qui sont disponibles dans le noyau utilisé sur la machine
- Voir le code de la glibc et du noyau Linux

Appels-système virtuels

- Appels système chers
  - 100ns sur x86 modernes, parfois plus de 1µs
- Parfois idiot
  - Le retour de getpid() varie « peu »
- Optimiser certains appels en espace utilisateur
  - Mapping de code et données simples du noyau (gettimeofday, getcpu, ...)
    - Voir http://lwn.net/Articles/615809/
  - Se rappeler de certaines valeurs (getpid, getppid, ...)
- Risques de sécurité?
  - Appel-système virtuel pour setuid() ?

Contextes d'exécution

- Processus en mode utilisateur
- Processus en mode noyau pendant un appel-système
- Processus en mode noyau pendant un traitant d'interruption/exception
  - Mode privilégié temporaire
  - Processus suspendu temporairement
    - Reprend la main à la fin du traitant
  - Exécution restreinte car contexte très limité
    - Interruptions désactivées, ...

Ajouter des appels-systèmes?

- Dangereux pour des raisons de sécurité
  - Ex: Ajouter appel-système « je deviens root »
- Table statique
  - Difficile à modifier
  - Souvent la cible des pirates
    - Modification ou remplacement
- Numéros fixés par compatibilité binaire
- Comment faire des commandes à la demande ? Les IOCTL (cours I/O)

Processus et exécution

Vie et mort des processus

Création de processus (Windows)

- CreateProcess(...) crée un processus à partir d'une ligne de commande
  - Nouvel espace d'adressage (et ressources)
  - Nouvelle file d'exécution dans cet espace
- Si on veut modifier des attributs, il faut passer plein d'arguments
  - Ou utiliser CreateProcessAsUser(...)
  - Pas très flexible/extensible

Création de processus (Unix)

- Création du nouveau processus PUIS exécution d'une commande
  - fork() + exec() au lieu de CreateProcess()
  - On peut configurer plein de choses entre les deux
- Fork() pour dupliquer
  - Duplication de l'espace d'adressage
    - Partage de certaines ressources
  - Nouvelle file d'exécution dans cet espace
  - Fils identique au père, sauf le PID
- Exec() pour transformer
  - Ligne de commande remplace le processus

Création de threads

- On rajoute une file d'exécution dans l'espace d'adressage courant
  - pthread_create()
  - clone()
    - Partage de certaines ressources

Lancement d'une tâche

- Le noyau crée un contexte utilisateur
  - Pointant vers la fonction à exécuter
    - main() pour un processus
    - Fonction dédiée pour un thread
  - Avec nouvelle pile
  - Quid de l'ancien contexte ?
    - Détruit en cas d'exec
    - Conservé si en cas de nouvelle tâche
    - Inexistant dans le cas de Init
- Restauration du contexte puis passage en espace utilisateur

Terminaison d'une tâche

- La terminaison se passe dans le noyau
  - Il faut d'abord un moyen d'y entrer
  - Appel système exit ou exception
- La file d'exécution est détruite
  - Elle relâche les ressources qu'elle utilisait
    - Le dernier utilisateur détruit la ressource
  - Identique pour partage entre threads ou processus

Terminaison d'un thread

- pthread_exit() est appelé implicitement ou explicitement
  - Les ressources spécifiques sont détruites
- Le dernier fait l'appel système exit qui détruit le processus
  - Les ressources partagées sont détruites

Terminaison d'un processus

- La tâche qui termine renvoie un code de retour
  - Destiné au père
- Le père peut attendre la terminaison d'un ou n'importe quel fils
  - wait() et waitpid()
  - Récupère le code de retour
- Tâche *Zombie* tant que le père ne s'en occupe pas
  - La plupart des ressources peut être libérée

Vie des processus et états d'ordonnancement

- Lors de l'exécution « normale »
  - Alternance régulière entre *Ready* et *Running* selon décisions de l'ordonnanceur
- Lors d'un appel-système bloquant
  - Sommeil sur file d'attente en attendant événement
  - Retour en *Ready* lors de l'événement
    - Ex: interruption d'un périphérique, action d'un autre processus, ...

La fonction de changement de contexte

- **2** tâches mis en jeu à chaque changement de contexte
- **3** processus du point de vue de la tâche désordonnancée puis réordonnancée
  - La tâche elle-même
  - Un successeur avant changement
  - Un prédécesseur après retour
  - La tâche voit 2 demi-changements différents
- schedule(), switch_mm() et switch_to() dans Linux

Runqueues

- Les processus prêts à s'exécuter sont dans une file d'attente spéciale (*Runqueue*)
  - Soit une seule globale
  - Soit une par processeur
- Uniquement les processus Ready !
  - Les processus non prêts sont dans files spéciales, avec un moyen de les retrouver
  - Ne pas parcourir une liste de 1000 processus pour trouver le seul prêt à s'exécuter !
    - Cf Projet Système IT202 sur les threads

Files d'attente

- Les processus non prêts sont dans files spéciales, avec un moyen de les retrouver
  - File d'attente d'un pilote si attente I/O
  - File dédiée à attente événement logique
    - Ex: Attente de données dans un tube
    - Ex: pthread_join() dans votre projet IT202
  - Aucune uniquement si réveillé par PID
    - Ex: Suspendu par ^Z et réveillé par SIGCONT
    - L'endroit où les signaux arrivent pour chaque PID est une pseudo file d'attente

Attente active d'un événement

- Boucle infinie
  - Tant que l'événement n'arrive pas...
- Monopolise le processeur jusqu'à l'événement
  - Très bonne réactivité
  - Gaspillage de cycles processeur
    - Acceptable pour µs, gaspillage si trop long

Attente semi-active

- Attente active en rendant la main
  - yield() à chaque itération de boucle while
  - Réactivité imprévisible
    - Pas de garantie de reprise de main rapide
  - Peut gaspiller autant de temps CPU
    - Dépend de l'activité des autres tâches
  - A n'utiliser que quand une attente passive est totalement impossible
    - A éviter dans vos join(), sémaphores, ... dans le projet IT202

Attente passive d'un événement

- Mécanisme de réveil lors d'un événement
  - La tâche est placée sur une file d'attente
    - Elle n'est plus dans la runqueue
      - Ignorée par l'ordonnanceur
- Lors de l'événement
  - Celui qui produit l'événement déplace la tâche de la file d'attente vers la runqueue
    - Le premier de la file (ou plusieurs si nécessaire)

Attente passive d'un événement (2/2)

- Endormissement+réveil assez cher
  - Changements de contexte
  - Délai si non prioritaire
    - Ne peut pas préempter immédiatement
- Cela vaut-il le coup de dormir?
  - Pas si le délai d'attente est très court
    - Attente active plus réactive
      - Mais très coûteux si trop long
        - Trouver le bon compromis

Processus et exécution

Ordonnancement

États des processus

- Automate de transition entre les états
  - *Running*
  - *Ready* (Prêt mais pas en train de s'exécuter)
  - *Blocked* (Non-prêt, en attente d'un événement)
  - *New* (En cours de création)
  - *Exit* (En cours de destruction, *Zombie*)
  - *Suspend* (Suspendu par l'utilisateur)

Exécution de l'ordonnanceur

- Le noyau n'existe pas
  - Il n'y a pas d'homme en noir pour ordonnancer les tâches en arrière plan
- Ordonnancement nécessite l'exécution du code de l'ordonnanceur
  - Sur le bon processeur
    - En mode noyau
      - On ignore les threads utilisateur dans le reste du cours
- Invocations explicites ou implicites
  - Ou invocations de force

Ordonnancement coopératif

- Ordonnancement explicite par les applications
  - Processus qui rend la main
    - sched_yield()
  - Processus qui attend
    - sleep()
- Ordonnancement implicite
  - Appel système bloquant
    - read(), poll(), ...
    - Retour de l'appel système nécessite fin de l'I/O

Ordonnancement coopératif (2/2)

- Aucune garantie d'ordonnancement régulier
  - Dépend du bon vouloir des applications
- Problème d'équité et de réactivité
  - Un processus peut conserver le processeur indéfiniment
    - Les tâches doivent coopérer

Exécution de l'ordonnanceur (suite)

- Il faut tâche s'exécutant en mode noyau
  - Sur le bon processeur
  - Et elle doit appeler le code de l'ordonnanceur
- Trouver un moyen d'appeler l'ordonnanceur même si l'application ne fait pas d'ordonnancement explicite ou implicite
  - Ordonnancer depuis code qui n'a rien à voir !
    - À chaque fois que le système prend la main
      - Appels système
      - Interruptions

Préemption

- Désordonnancer une tâche de force
  - Si une tâche s'exécute depuis trop longtemps
    - La mettre sur à la fin de la file *Ready*
    - Remplacer par la première de la file *Ready*
  - Si une autre tâche est prioritaire
    - Mettre la tâche courante sur *Ready*
      - À la fin ou au début ?
    - Remplacer par la première tâche prioritaire
      - Risque de famine ?

Préemption (2/2)

- La préemption a un léger surcoût
  - On doit vérifier de temps en temps s'il faut désordonnancer de force
- Mais gain énorme en équité et réactivité
  - Plus besoin de coopération des processus !

Préemption dans Linux

- L'ordonnanceur vérifie régulièrement s'il faut passer la main à une autre tâche
  - Lors du retour en espace utilisateur
    - Fin d'appel-système
    - Fin d'interruption
      - Utilité des ticks d'horloge périodiques !
- Ici on parlait de préemption uniquement pour le code utilisateur
  - Le code du noyau peut être long et nuire à la réactivité du système
    - Linux préempte aussi le code noyau

Qui préempte qui ?

- Pas de préemption directe en espace utilisateur
  - Il faut être dans le noyau pour exécuter le code de l'ordonnancement
    - Peut se produire n'importe où dans code utilisateur via les interruptions
- Processus préemptés dans le noyau de la même façon
  - Par exemple juste avant leur retour en espace utilisateur
    - Après appels système, exceptions, interruptions
- Les interruptions peuvent préempter n'importe quand
  - Sauf si désactivées

Signaux

- Message (avec numéro) d'un processus à un autre
  - Reçu par exécution d'un traitant
    - Déroutement du programme puis retour
- Délivré quand on revient en espace user
  - Traité par l'ordonnanceur comme préemption
- Délivré uniquement s'il y a des appels-système ou interruptions
  - Heureusement qu'il y a l'horloge de temps en temps

Signaux (2/2)

- Le noyau modifie le contexte d'exécution du processus avant de le laisser retourner en exécution
  - Force l'exécution du traitant
    - Avec segment de pile dédié
  - Force l'exécution d'une fonction « retour de traitant » à la sortie du traitant
    - Modification de l'adresse de retour
- Le « retour du traitant » remet le contexte d'exécution initial en place
  - Reprise de l'exécution à l'endroit initial

Processus et exécution

Processus et threads

Intérêt des threads

- Partage de ressources entre tâches
  - Mémoire partagée triviale
    - Pas d'initialisation complexe
- Meilleure exploitation des processeurs
  - Un seul programme sur plusieurs processeurs
    - Critique depuis l'avénement des multicores
      - Mais pas trivial à utiliser et/ou implémenter...
- Recouvrements des entrées/sorties
  - Exécution d'un thread pendant qu'un autre bloque en attendant un événement

Définition des *threads* ?

- File d'exécution
  - Interne à un processus
- Le processus devient un conteneur
  - Au moins un thread
  - Des ressources partagées

Données partagées ou non

- Contextes d'exécution distincts
  - Piles, registres, ...
- Partage possible de
  - Espace d'adressage mémoire
  - Fichiers ouverts
  - Signaux
  - Identifiant des processus
    - Sous-identifiant par thread
- Définition du partage à la création
  - Voir la manpage de clone()

Modèle *1-on-1*

- Un thread noyau pour chaque thread
- Aussi coûteux que les processus
  - Création, destruction, changement de contexte
- Processus multi-threads avantagés
  - Une *Timeslice* normale pour chaque thread
- Ex: NPTL (Native Posix Thread Library)
  - Création : 6 µs
  - Changement de contexte : 0,5 µs

Threads en espace utilisateur

- Un seul thread noyau propulse plusieurs threads utilisateurs
- Coût d'ordonnancement très réduit
  - On reste en espace utilisateur
- Multiples threads ignorés par le système
  - Une seule *Timeslice* pour tout le processus
  - Si un thread bloque, il bloque tous les autres
- Ex: Marcel
  - Création : 0,21 µs
  - Changement de contexte : 0,22 µs

Modèle *M-on-N*

- Plusieurs threads utilisateurs sur plusieurs threads noyau
- Si un thread bloque une tâche, les autres tâches peuvent continuer à travailler
- Ajout de threads noyau à la volée
  - *Scheduler Activations*
    - Collaboration entre ordonnanceurs noyau et utilisateur pour ajouter tâche noyau si nécessaire
- Ex: Thr (Solaris), NGPT (*Next Generation Posix Threading*), Marcel

Ordonnancement des processus multi-threadés

- Dépend du modèle de thread
  - Le système est-il au courant de l'existence des threads?
  - Avantagé en 1-on-1
  - Désavantagé en threads utilisateur

Changement de contexte en espace utilisateur

- Comment sauver/restaurer le contexte sans casser le contexte qui le fait?
- set/get/make/swapcontext
- setjmp/longjmp

- Projet système IT202 sur les threads

Comportement des programmes multithreadés ?

- Dupliquer tout ou un seul thread lors d'un fork ?
- Et en cas d'exec ?
- Un seul thread a-t-il un sens sans ses copains ?

Processus et exécution

Algorithmes d'ordonnancement

Besoins

- Progression de toutes les tâches
  - Equité
  - Interactivité
- Ne pas dépendre de la bonne volonté des tâches
  - Préemption

Durée d'ordonnancement

- Choix de la durée des *Timeslices*
  - Quantum de temps d'exécution
    - Dépend de la priorité
      - 100 ms par défaut sous Linux
        - Varie entre 5 et 800 ms selon priorité
  - Pas trop court
    - Sinon le coût d'ordonnancement devient prohibitif
  - Pas trop long
    - Sinon les processus n'avancent pas assez régulièrement
      - Problème avec les contraintes temps réel

Mesure du temps d'ordonnancement

- Difficile de savoir précisément si un processus est gourmand en temps processeur
- Ordonnancement essentiellement basé sur les ticks d'horloge
  - Pas très précis
    - 4 ms sous Linux/x86
  - Utilisation du compteur de cycle s'il existe
- Comment comptabiliser le temps passé à traiter les interruptions ?

Critères d'ordonnancement pour l'utilisateur

- Performance
  - Rapidité d'exécution ou de terminaison
  - Réactivité
  - *Deadlines*
- Équité ?
- Prédictabilité ?

Critères d'ordonnancement pour le système

- Performance
  - Quantité de travail
  - Utilisation du processeur
    - et des périphériques
- Équité
- Respect des priorités

Idées pour l’ordonnancement

- FIFO (*First In First Out*)
- *Round-Robin*
  - Exécution tour à tour pendant *Timeslices*
- *Short First* ou *Short Remaining Next*
  - Impose de prévoir la durée d'exécution
- *Feedback*
  - Pénalité pour processus gourmand
    - Ajuster la priorité initiale

Priorités dans Unix

- Priorité de base dynamique
  - *Feedback*
- Facteur ajustable par l'utilisateur (*nice*)
  - Privilège nécessaire pour rendre prioritaire
- *Swapping* très prioritaire
  - En gros, la priorité augmente en allant des applications aux périphériques physiques

Adapter l'ordonnancement aux priorités ?

- Exécuter les tâches prioritaires d'abord ?
  - Peu utile ?
    - Sauf pour processus très courts qui s'exécutent d'un seul coup ?
- Exécuter les prioritaires plus souvent
- Exécuter les prioritaires plus longtemps

Liste triée par priorité

- Liste de tâches triées par priorité ?
  - Complexité linéaire en le nombre de tâches
    - Chaque opération d'ordonnancement coutera cher
      - Yield, Création, Destruction, ...
  - Attention aux famines
    - Les processus non-prioritaires ne doivent pas rester indéfiniment en fin de liste
      - Ajuster priorité selon privilèges précédents ?
        - En temps constant ?

Listes par priorités

- Listes de tâches de même priorité
  - Manipulation en temps constant
- Les listes sont parcourues plus ou moins souvent selon la priorité
  - Limité à un nombre fini de priorités
    - 40 sous Linux
    - Sinon utiliser des *Skip List* ?

Ajuster la timeslice aux priorités

- Définir un quantum de temps d'exécution variable (*Timeslice*) selon la priorités
  - Éventuellement dynamique
    - Privilégié si interactif
      - Entrées/sorties font dormir avant la fin de la timeslice
    - Désavantagé si abuse du processeur
      - Préempté quand la timeslice est terminée
  - Calculable en temps constant

Que change les multicoeurs et multiprocesseurs dans tout ça ?

- Préemption = Concurrence entre tâches sur un seul processeur
  - Evitable en désactivant les interruptions
- Multiprocesseur = Concurrence réelle entre tâches
  - N'importe quand
    - Synchronisation critique
- Sur quel processeur/coeur exécuter quelles tâches ?

Ordonnancement pour multiprocesseurs

- Une seule runqueue (*Load Sharing*)
  - Tous les processeurs y piochent
    - Contention si beaucoup de processeurs
- Une runqueue par processeur
  - Pas de contention
  - Mais il faut les équilibrer (*Load Balancing*)

SMP, NUMA et migration

- Affinité entre processus, threads, processeur et/ ou mémoire
  - Notion de préférences dans l'ordonnanceur
- Impose de garder une trace des affinités
  - Difficile
    - Faire une file par coeur et garder le processus dessus à la fin de sa *Timeslice*?
  - Compromis avec équilibrage de charge
- Quand casser l'affinité ?
  - Si un processeur est libre et un est surchargé
    - Ca dépend...

Ordonnancements spéciaux pour multiprocesseurs

- Dédier un processeur à une tâche
  - Les autres tâches ne peuvent pas venir
    - 100 % de temps CPU
    - Affinité de cache et mémoire garantie
  - A ne pas confondre avec l'assignation d'un processeur
    - Processeur libre, mais tâche contrainte
- Par groupe (*Gang Scheduling*)
  - Intéressant si affinité de cache/mémoire
    - ou si communication inter-tâches

Ordonnancement dans Linux

- Ordonnanceur Unix assez classique
  - mais évolue très vite
    - Le fameux *O(1)-Scheduler* de Linux 2.6 a déjà été remplacé plusieurs fois
- Bonne interactivité et équité
  - Priorité effective avec bonus ou pénalité
    - Crédit d'interactivité si le processus dort
    - Priorités parfois respectées uniquement à l'intérieur des sessions (cf vos TD)

Ordonnancement dans Linux (2/2)

- Support de beaucoup de processus et processeurs
  - Optimisation avancée des structures de données et algorithmes pour passer à l'échelle
  - Masque de processeur accepté pour chaque processus
    - et/ou préféré selon affinité
- Enormément de petites d'optimisations
  - Ex: Le fils de vfork() préempte le père
    - Évite un *Copy-on-Write* inutile

Complexité d'ordonnancement

- Les coûts des opérations ne peut pas dépendre du nombre de tâches
  - Toujours beaucoup de tâches *Blocked*
    - Celles-ci ne doivent pas être sur la Runqueue
  - Potentiellement beaucoup de tâches *Ready*
    - Ne jamais parcourir la Runqueue

Complexité d'ordonnancement (2/2)

- Insertion d'une tâche désordonnancée
  - Ne pas trier la liste
    - Comment gérer les priorités ?
- Retrait d'une tâche ordonnancée
  - Ne pas parcourir la liste
    - Comment choisir rapidement la tâche à exécuter ?
- Calcul des timeslices
  - Ne pas parcourir la liste pour calculer la somme du poids des tâches
    - Maintenir la somme au fur et à mesure des ordonnancements de tâches

Cas des contraintes temps réel

- Réactivité
- Priorité
- *Deadline* (exécution avant une date)
- Utilise un cas spécial d'ordonnancement
  - *Timeslice* pouvant être infinie
    - Nécessite des privilèges
  - SCHED_RR et SCHED_FIFO sous Linux
    - Manpage de sched_setscheduler()

Ordonnanceur temps réel

- Ordonnanceur non-généraliste
  - Conçu pour le temps réel
- Maximiser la réactivité
  - Minimiser la désactivation des interruptions
  - Minimiser les verrous
- Routines dédiées à la gestion des contraintes temps réel
  - Retardement, pause, alarmes (*Timer*), ...

Processus et exécution

Exécution du système

Le noyau n'existe pas

- Pas de processus noyau qui surveille tout le monde
  - Pas d' « homme en noir » qui prend les processus, les fait s'exécuter, vérifie ce qu'ils font, ...
- Le système d'exécute essentiellement dans le contexte des processus lorsqu'ils sont en mode noyau
- Juste éventuellement des démons dédiés à des tâches périodiques

Exécution du noyau dans le dos des processus

- Le noyau s'exécute à travers des *hooks* un peu partout dans le code qui n'a rien à voir
  - Ex: Ordonnancer au retour de getpid()
- Pendant les appels système
  - Traitement des appels système
  - Traitements annexes par la même occasion
- Dans le cas d'interruptions/exceptions
  - Traitement immédiat nécessaire
  - Traitements déferrés si nécessaire
    - Travaux coûteux pourraient nuire à la réactivité

Exécution en mode noyau

- Changement de contexte
  - Changement des privilèges
  - Utilisation d'une pile spéciale
    - Éviter de stocker des informations critiques en espace utilisateur
    - Les espaces mémoire utilisateur et noyau n'ont pas les mêmes contraintes
      - Pas de défaut de page noyau sous Linux
  - Sauvegarde et restauration des registres utilisateurs

Cas des micro-noyaux

- Appels système minimaux
  - Passage de message entre composants en espace utilisateur
- Gestion effective du système d'exploitation en dehors du noyau
  - Dans les processus serveur dédiés

Threads noyau

- Noyaux monolithiques ont besoin de traitements annexes
  - Appels-système imprévisibles
  - Traitants d'interruption dans contexte trop limité
- Utilisation de threads dédiés
  - Toujours en mode noyau
    - Pas d'espace utilisateur
  - Travaux périodiques et/ou programmés

Les threads noyau sont partout

- Tout processus est propulsé par un thread noyau
  - Il passe en mode utilisateur juste après sa création
  - Il revient en mode noyau de temps en temps
    - Appels système
    - Et juste avant sa mort
- Et un processus multithread est propulsé par 1 ou plusieurs threads noyau
  - Selon le modèle 1-on-1, M-on-N, ...

Comment savoir qui je suis ?

- Le noyau doit souvent savoir qui il est
  - Tous les processus peuvent être amenés à exécuter la plupart du code noyau
    - Et aussi les threads noyaux
      - Voire les traitants d'interruption
- Comment savoir quelle tâche s'exécute ?
  - Quels droits a-t-elle ?
    - Utilisateur, permissions, ...
  - Quelles ressources a-t-elle ?
    - Mémoire virtuelle, ...

Comment savoir qui je suis ? (2/2)

- Sacrifier un registre ?
  - On a déjà un registre pour localiser la pile
- Linux utilise un joli hack
  - Le descripteur de tâche est placé sous la pile
    - Tâche = Adresse de la pile tronquée
      - current = StackPointer & ~STACK_SIZE
  - Impose d'aligner et limiter les piles

Gestion mémoire

Objectifs

- Fournir une abstraction aisée pour le programmeur
- Séparer et protéger les différents processus et utilisateurs
  - Mémoire utilisateur et système
- Maximiser l'utilisation du matériel
  - Processeurs, disques, ...
    - La mémoire sert d'intermédiaire

Objectifs (2/2)

- Supporter l'organisation logique des programmes
  - Programmation modulaire
- Supporter l'organisation hiérarchique de la mémoire
  - Caches, RAM, disques, ...
    - Avec les performances adaptées

Hiérarchie mémoire

- Registres du processeur
- Mémoire centrale
  - Stockage volatile (disparaît au reboot)
  - Relativement lent
- Disque, bande, ...
  - Stockage persistant
  - Très lent

Adressage de la mémoire centrale

- Adressage 32 ou 64 bits actuellement
  - Imposé par le processeur
  - La taille des pointeurs en découle
    - 4 ou 8 octets
- Les OS utilisent des adresses de moins de 64bits en pratique
  - Et les processeurs 64bits ne supportent pas vraiment 64 bits en fait

Cache

- Zone de stockage intermédiaire
  - plus petite mais plus rapide
- Conserve zones récemment accédées
- Précharge zones proches qui pourraient être accédées peu après

Exemples de cache

- Cache dans les contrôleurs disques
  - Entièrement géré par le matériel
- Mémoire cache, jusqu'à trois niveaux
  - Très rapide, placé entre processeur et mémoire
  - Essentiellement géré par le matériel
- Cache de pages et espace de *Swap*
  - Entièrement géré par le système d'exploitation

Plan

- Programmation modulaire
- Partitionnement
- Mémoire virtuelle
- Tables de pages
- Pagination à la demande et défauts de page
- Heuristiques de gestion mémoire
- Support matériel
- Mémoire du noyau

Gestion mémoire

Programmation modulaire

Pourquoi de la programmation modulaire ?

- Réutilisation de code
  - Ne pas inclure les mêmes bibliothèques dans tous les programmes
  - Économie d'espace disque
    - Et mémoire
- Changement de bibliothèque sans relinker
  - Il suffit que l'ABI soit la même
- Modification du comportement au chargement
  - LD_PRELOAD, ...

Chargement des programmes

- Assemblage de modules
  - Programme, bibliothèques, ...
- Calcul des adresses mémoire
  - Chargement absolu
    - par le programmeur, le compilateur ou l'assembleur
  - Chargement dynamique
    - Adresses relatives calculées à l'exécution

Édition de liens

- Utilisation de « symboles » pour référencer les adresses inconnues
- Références non-résolues provoquent chargement d'autres modules
  - Mise à jour de modules sans recompiler
    - Fournir la même liste de symboles avec même ABI
  - Partage de code facile

Emplacement d'un programme en mémoire

- A l'origine, pas de mémoire virtuelle
  - Tous les programmes et bibliothèques étaient chargés dans le même espace
- Un programme n’est pas toujours chargé au même endroit
- Les bibliothèques sont rarement chargées au même endroit
  - Liste de bibliothèques variables
  - Chargement multiple possible
  - Même avec de la mémoire virtuelle

Relocalisation

- Comment stocker les adresses si on peut charger à différents endroits ?
  - Adresses absolues simples à gérer
    - Impose emplacement du code en mémoire
    - Impose un seul programme ou mémoire virtuelle
      - Et une seule copie par programme
  - Adresses relatives ajustées plus tard
    - Au chargement ou à l'exécution
      - Edition de liens entre modules
      - Fixer les adresses à l'intérieur des modules

Code indépendant de la position

- Uniquement des adresses relatives
  - Facile à charger
    - Pas besoin de modifier le code
    - Partageable entre plusieurs processus qui le chargent à différents endroits
  - Un peu coûteux en temps, registre et mémoire
- Compilation avec -fPIC (*Position-Independent Code)*
  - Bibliothèques dynamiques sous Unix
- Uniquement pour références internes au module
  - Toujours édition de liens avec autres modules

La pile et le tas

- Intrinsèquement des adresses relatives
  - Augmentations imprévisibles
  - Équivalence entre différents endroits
- Spécificités de la pile
  - Références au cadre précédent (appelant)
  - Un même code peut utiliser différents cadres
    - Appels récursifs, ...
- Spécificités du tas
  - Augmentation imprévisible
    - Pas forcément contigu
      - mmap à partir d'un certain seuil

Sous Linux

- Le compilateur précise l'interpréteur
  - Dans les en-têtes de l'objet
- Quand on lance un programme
  - Interpréteur lancé en premier (ld.so)
- Chargement des modules en mémoire
  - Programme
  - Bibliothèques
  - Création dynamique du tas et de la pile

Sous Linux (2/2)

- Chargement configurable
  - Bibliothèques stockées dans emplacements standard ou non
    - /etc/ld.so.conf, LD_LIBRARY_PATH, ...
  - Bibliothèques de surcharge (LD_PRELOAD)
  - Résolution de symboles à l'exécution ou au chargement (LD_BIND_NOW)
- Voir la manpage de ld.so

Gestion mémoire

Partitionnement

Pourquoi du partitionnement ?

- Une seule mémoire physique
- Plusieurs programmes, bibliothèques, modules
- Comment les répartir ?
  - Découper en segments contigus ?
    - Une partition pour chaque module à allouer
  - Allouer par morceaux ?
    - Pagination
      - Plusieurs pages pour chaque module

Partitionnement fixe

- Division de la mémoire physique en N partitions de même taille
  - Un module par partition
  - N = degré de multiprogrammation maximum
- Inconvénients
  - Fragmentation interne
    - Mémoire inutilisée dans chaque partition
  - Programmes limités en taille
    - Compromis entre multiprogrammation et taille

Partitionnement fixe (2/2)

- Adresses finales du programme décalées
  - La relocalisation peut gérer le décalage mais pas la taille limitée de la partition
  - Le matériel peut gérer le décalage
    - Registre de base pour traduction transparente
      - @phys = @virt + base
    - Base adaptée par l'OS lors du changement de contexte
  - Le matériel peut vérifier qu'on ne déborde pas
    - @virt < taille/N
    - Protection inter-processus

Partitions de tailles différentes

- Découpage fixe en partitions différentes
  - File de partitions libres
    - Prendre la plus petite suffisamment grande pour le programme à charger
    - Algorithmes *First Fit* or *Best Fit*
      - Peu important si peu de partitions
- Support matériel
  - Registre base + limite
    - Traduction en utilisant base
    - Protection en utilisant limite

Partitionnement dynamique

(variable dans le temps)

- Allocation de partitions selon la taille du programme
  - Algorithmes *First Fit* or *Best Fit*
    - Important si beaucoup de programmes ?
- Support matériel
  - Registre base + limite
    - Traduction en utilisant base
    - Protection en utilisant limite

Partitionnement dynamique (2/2)

- Avantages
  - Pas de fragmentation interne
    - On alloue l'espace exactement nécessaire au chargement du programme
- Inconvénients
  - Fragmentation externe
    - Petits résidus inutilisés entre les partitions
      - Dépend de l'algorithme d'allocation
- Solutions
  - Compactage dynamique

Pagination

- Au lieu d'allouer un bloc par programme, on alloue plusieurs pages de même taille par programme
  - Pas de fragmentation externe
  - Un peu de fragmentation interne
  - Taille des pages à bien choisir
- On peut gérer la mémoire à faible granularité
  - Charger, swapper, protection, ...

Pagination (2/2)

- Support matériel beaucoup plus complexe
  - Programmes répartis dans pages physiques discontigues !
  - Relocalisation ne suffit plus
    - Un objet contigu à cheval sur deux pages devient discontigu en mémoire physique
      - *p++ ne fonctionne plus
  - Il faut traduire toutes les adresses à la granularité de la page

➔ Ce qu'on va utiliser plus loin dans le cours

Autres applications du partitionnement

- Utile dès qu'on doit stocker plusieurs choses dans un espace borné
  - Malloc
    - Partitionnement dynamique
      - L'utilisateur veut des buffers contigus
  - Système de fichiers
    - Similaire à la pagination
      - Matériellement découpé en bloc dans les disques
      - Pas directement accédé par l'utilisateur, donc discontiguité invisible
        - Rendu contigu par mmap ou read/write

Gestion mémoire

Mémoire virtuelle

Besoins

- Chaque processus voit un espace linéaire
  - Pas forcément linéaire physiquement
  - Pas forcément utilisé intégralement
    - Utilisation dynamique
- Taille non limitée par la mémoire physique
  - Toute la mémoire virtuelle n'est pas utilisée en même temps
- Protection, partage

Intérêts de la mémoire virtuelle

- Stockée en mémoire physique ou ailleurs
  - Plus de mémoire virtuelle que de mémoire physique disponible
- Code et données non-utilisées peuvent rester sur le disque
  - Chargés par l'OS quand ils deviennent nécessaires
- Cohabitation de nombreux processus
  - même si très gourmands en mémoire
- Isolation des processus
  - Espace virtuel des autres est inaccessible

Différents types d'adresses

- Virtuelle ou Logique (@virt)
  - Sélecteur de segment + Décalage
  - Pointeurs déréférencés par le programme
    - Manipulés par le processeur
- Linéaire (@lin)
  - dans l'espace global du processus
- Physique (@phys)
  - dans la mémoire physique de la machine
- De bus (@bus)
  - Manipulable par les périphériques (DMA)

Adresses vers quoi ?

- Les adresses pointent vers des octets
  - Pas vers des bits particuliers
- Les processeurs manipulent des octets
  - Par paquets de 1/2/4/8/...
  - Avec parfois des contraintes d'alignement
- Accès à certains bits d'un octet ?
  - Instruction arithmétique après avoir chargé octet entier dans registre

Adresses virtuelles

- Indépendant du stockage physique sous-jacent
  - RAM, disque, I/O, ...
    - Géré par l'OS via les défauts de page
- Les instructions processeur manipulent des adresses virtuelles
  - Traduites en adresses physiques au dernier moment
    - Par le matériel (MMU)
- Espace d'adressage d'un processus
  - L'ensemble des @virt valides

Intérêts de la mémoire virtuelle (2/2)

- Pas de contraintes pour le programmeur
  - Abstraction linéaire et uniforme du stockage physique
  - Pas (Peu?) de limite en espace
- Partage facile
  - Plusieurs @virt virtuelles vers même @phys
- Protection
  - Droits d'accès associés à chaque @virt

Inconvénients

- Performance
  - Consommation d'espace mémoire
    - Stockage des tables de pages
  - Consommation en temps
    - Gestion fine donc complexe
- Assistance du matériel très importante

Implémentation

- Traduction des adresses virtuelles
  - Pagination et segmentation
  - Table des pages
- Politiques de gestion
  - Chargement, swap, ...
    - Quand ? Qui ?
- Support matériel et OS conjoint
  - *Memory Management Unit* (MMU)
  - *Translation Lookaside Buffer* (TLB)

Pagination : Le retour

- Permet forte non-contiguité de l'espace virtuel en mémoire physique
- Division de la mémoire physique en blocs de taille fixe
  - *Pages* (typiquement 4ko, dépend de l'archi)
- Division de l'espace virtuel en blocs de taille fixe
  - *Cadres* (*frames*) de la taille des pages
- Chaque cadre virtuel nécessite l'allocation d'une page physique

Pagination (2/8) Implémentation

- Association entre cadres et pages gérée par l'OS
  - Table de pages
- Pas de contrainte sur le choix des pages
  - Espaces virtuels dispersés dans l'espace physique
- Aucune adresse virtuelle ne pointe sur les pages des autres processus
  - Protection intrinsèque

Pagination (3/8)
Traduction des @virt

- @virt = numéro cadre virtuel + décalage
- Numéro = index dans table de page
  - Permet de récupérer numéro de page physique
    - PFN = Page Frame Number
- @phys = PFN + décalage

- Une PTE (*Page Table Entry*) pour chaque cadre virtuel

Pagination (4/8)
Exemple de traduction

- Si @virt 32bits, @phys 24bits, page 4ko
- Décalage dans page 4ko = 12bits
  - Il reste 12bits pour décrire la page physique
- @virt = 20bits de numéro de cadre

  + 12bits de décalage
- Traduction numéro 20bits -> PFN 12bits
  - 2^{20} PTE par processus

Pagination (5/8)
Protection

- Chaque cadre virtuel dispose de bits de protection
  - Stocké dans le PTE
- Bit « valide ou non »
  - Pour les segmentation fault
- Bit « présent ou non »
  - Pour les défauts de page, le swap, ...
- Bits *Read-only*, *Read-write*, *Execute*, ...
  - Selon l'architecture

Pagination (6/8)
Les Page Table Entries (PTE)

- PFN représentant la page physique
- Bits de validité
- Bits de protection
  - R/O, R/W, X, ...
- Bits d'état
  - Modifié (*Dirty*), ...
- Bits de référence
  - Combien d'accès ? Quand ? ...
- Stockage architecture et/ou OS dépendant

Pagination (7/8)
Avantages

- Allocation de pages faciles
  - Listes de pages libres
  - Pas de fragmentation externe
- Swap de morceaux de programmes
  - Tous les cadres virtuels ont la même taille
  - Bit de présence pour savoir si swappé ou non
  - Adapter la taille de pages aux blocs disque
- Partage et protection de pages faciles

Pagination (8/8) Inconvénients

- Un peu de fragmentation interne
  - De l'ordre de la taille d'une page
- Coûteux
  - 2 références par accès mémoire
    - Table de pages puis adresse destination
    - Impose support matériel (TLB)
- Consommation mémoire importante
  - Plusieurs octets par PTE
    - 1/1000 de l'espace mémoire de chaque processus
      - 4Mo par processus en 32bits !
  - Tables hiérarchiques, swappables, ...

Segmentation

- Partitionnement mémoire en unités logiques
  - Code, tas, pile, ...
  - Taille dynamiquement ajustable
- Espace d'adressage = Ensemble de segments indépendants
  - @virt = sélecteur de segment
    + décalage dans ce segment
  - Table associant sélecteur et base+limite

Segmentation (2/3) Avantages

- Protection par segment
  - Bits de validité, protection, …
  - Factorisation de beaucoup d'informations identiques
  - Ex : Code en r-x, tas en rw-, ...
- Partage à forte granularité facile
  - Ex : Bibliothèques

Segmentation (3/3)
Inconvénients

- Allocation difficile
  - Doit être physiquement contigu
    - Problème de partitionnement mémoire (avec partitions de taille variable), compaction, ...
- Swap plus lourd

Approches hybrides : Segments paginés

- Segments pour distinguer unités logiques
  - Code, tas, pile
- Pagination interne à chaque segment
  - Allocation, swap à granularité fine
- Traduction @virt en @phys en 2 temps
  - Décalage d'index dans la table de pages via la table des segments
    - Adresse linéaire
  - Traduction @lin en @phys via la table de pages

Approches hybrides : Multiples tailles de page

- 8-64ko sur Alpha
- 4ko, 2-4Mo sur x86 et 1Go sur Opterons, 16Go sur Power
  - *Huge pages*
- Simultanément plusieurs tailles
- Moins de pression sur la TLB
- Plus difficile à allouer
  - Doit être physiquement contigu et correctement aligné

Partage mémoire

- Plusieurs zones virtuelles peuvent pointer sur les mêmes pages physiques
  - Avec des protections différentes
    - Bibliothèques mappées plusieurs fois
      - r-x pour code exécutable non modifiable
      - rw- pour données globales modifiables non exécutable
- Compteur de références dans les pages
  - La page est libre quand la dernière référence est relâchée
    - On peut la réutiliser
      - Après l'avoir sauvée sur le disque si nécessaire

Gestion mémoire

Tables de pages

Tables de pages

- Ensemble d'associations entre cadres virtuels et validité+localisation+protection
  - Accédé quasiment uniquement par adresse virtuelle
    - Stocké naturellement comme un grand tableau
      - Il faut une case par page virtuelle potentielle
        - On a besoin de savoir si une page est valide ou non
- La table des pages complète prend beaucoup de place en mémoire
  - 4MB pour un espace 32bits avec pages de 4ko
  - La table est forcément entièrement allouée !

Tables de pages (2/3)

- Une grande part de l'espace d'adressage n'est pas utilisé
  - Pas valide du tout
    - Voire valide mais inutilisé actuellement
- Doit-on vraiment décrire toutes ces pages virtuelles inutiles individuellement ?
  - Liste d'intervalles valides ?
    - Parcours de liste mauvais en complexité

Tables de pages (3/3)

- Arbre binaire d'intervalles valides ?
  - Support matériel difficile
  - Modifications pas atomiques ?
- Solutions plus simples ?
  - Tables hiérarchiques à plusieurs niveaux
    - Le matériel aime bien les puissances de 2
    - Mais on gaspille un peu d'espace
  - Tables hachées
    - Le matériel aime bien les choses simples
    - Mais le temps de recherche n'est pas constant

Tables de pages à plusieurs niveaux

- Une table normale = un seul niveau
- Table à plusieurs niveaux = Tableaux d'indirections vers des sous-tableaux
  - Un tableau de niveau 1 avec N pointeurs vers niveau 2
  - N tableaux de niveau 2 avec M pointeurs vers niveau 3... etc.

Tables de pages à plusieurs niveaux (2/5)

- Permet de supprimer les tableaux inutiles
  - Au lieu d'allouer un tableau d'entrées invalides, on marque le pointeur du père comme invalide
    - Ca compense largement l'espace « gaspillé » par les niveaux de pointeurs intermédiaires
  - Contrairement à la table linéaire à 1 seul niveau qui est forcément **entièrement** allouée

Tables de pages à plusieurs niveaux (3/5)

- Si un processus n'utilise qu'un seul cadre virtuel ?
  - On alloue une seule page **par niveau**
    - Très petit par rapport à table linéaire à 1 niveau
- Si un processus utilise toute la mémoire virtuelle ?
  - Le dernier niveau fait exactement la même taille qu'une table linéaire à 1 seul niveau
    - Le surcoût des niveaux supérieurs est négligeable
      - De l'ordre de 1 / nombre de pointeurs par niveau
  - Et ce cas le pire est extrêmement rare !

Tables de pages à plusieurs niveaux (4/5)

- Les processeurs supportent 2 à 4 niveaux (et bientôt 5)
- L'OS les utilise comme il veut
  - Il peut ignorer certains niveaux matériels
  - Il ne peut pas en mettre plus
    - Le matériel ne saurait pas les parcourir
  - 5 niveaux logiciels dans Linux depuis 4.12
    - Certains peuvent être « vides » pour s'adapter au matériel

Tables de pages à plusieurs niveaux (5/5)

- @virt = agrégation d'index pour chaque niveau
  - premiers bits = entrée dans table du premier niveau
  - suivants = entrée dans la sous-table du niveau suivant
  - derniers = décalage dans la page finale
  - Tous les bits pas forcément utilisés!
- Comment l'OS choisit-il le nombre de bits?
  - Simplifier la gestion en faisant tenir la table et chaque sous-table dans une page exactement
- Traduction des @virt en @phys
  - Parcours de la table de haut en bas

Les tables de pages à 4 niveaux dans Linux sur x86_64

- Architecture 64bits
  - 4 niveaux de table de pages matériels
  - pages de 4ko = 12bits de décalage
- 8 octet par PTE
  - Numéro de pages physiques
  - Bits de validité/présence/protection
  - 512 PTE dans une page
    - 9bits de dernier niveau de table
- 8 octet par pointeurs
  - 512 pointeur dans une page
    - 9bits pour les niveaux supérieurs

Les tables de pages à 4 niveaux dans Linux sur x86_64 (2/3)

- @virt = 48bits
  - 9bits de PGD (*Page Global Directory*)
  - 9bits de PUD (*Page Under Directory*)
  - 9bits de PMD (*Page Middle Directory*)
  - 9bits de PTE (*Page Table Entry*)
  - 12bits de décalage dans la page
- 64bits disponibles matériellement mais pas tous utilisés
  - Taille réelle des @virt décidée par le processeur et l'OS
  - Mais forcément stocké dans pointeur 64bits (8 octets)
- 256To de mémoire virtuelle par processus

Les tables de pages à 4 niveaux dans Linux sur x86_64 (3/3)

- 1 tableau de niveau 1 avec 512 pointeurs
- 512 tableaux de niveaux 2 avec 512 ptrs
- 512^2 tableaux de niveaux 3 avec 512 ptrs
- 512^3 tableaux de niveaux 4 avec 512 PTEs
- 512^4 PTEs en tout
  - Couvrent 512^4*4096=256TB de mémoire virtuelle
  - mais n'occupent que 512^4*8=512GB (maximum)
    - Et quelques broutilles pour les tables intermédiaires
- Mais tout ces tableaux ne sont pas forcément alloués

Tables de pages et segments sur processeur Alpha 21064

- Architecture 64bits
  - 3 niveaux de table de pages matériels
  - Pages de 8ko, PTE de 8 octets
- 10 bits par niveau + 13 bits de décalage
  - @virt 43bits (21bits non-utilisés par l'OS)
- 2bits de segments au début de l'@virt
  - 10 = Noyau (protégé)
  - 11 = Pile utilisateur
  - 0x = Code utilisateur

Tentative de résumé

- Si segmentation
  - Sélecteur de segment
    - Dans @virt ou registre spécial
- Puis, si pagination (tout le temps ?)
  - Numéro PGD au début @virt
  - Eventuellement PUD et PMD ensuite
    - Si matériel supporte > 2 niveaux
  - Numéro PTE à la fin @virt

Tables de pages hachées

- Hachage de l'@virt puis parcours d'une liste pour localiser la PTE
  - Ajouter le décalage (comme d'habitude)
- Efficace pour les espaces d'adressage très dispersés
- Lent pour les espaces remplis
  - Liste de hachage très longues
- Disponible matériellement sur IA64, PowerPC, ...

Bilan sur les tables de pages

- Table linéaire originale
  - Très simple, bon temps d'accès, TRES mauvais en espace mémoire
- Table hiérarchique
  - Assez simple, bon temps d'accès, très bon en espace mémoire
- Table hachée
  - Relativement simple, temps d'accès bon en moyenne, très très bon en espace mémoire

Traduction @phys → @virt

- A qui appartient la page que je veux swapper ?
  - Très coûteux avec tables de pages
    - Parcourir toutes les entrées ?
- Table de pages inversée
  - Tableau indexé par numéro de page physique
    - Donne les adresses virtuelles qui la référence
    - Comment stocker les pages partagées?
      - Listes chaînées?
    - Ne permet pas de traduire @virt → @phys !
      - Un complément aux tables hiérarchiques ou hachées
- Implémenté logiciellement dans l'OS

Gestion mémoire

Pagination à la demande et défauts de page

Pagination fainéante

- L'OS peut souvent être fainéant
  - Ne pas charger une page en mémoire tant qu'elle n'est pas accedée
    - Ne pas allouer une page non plus
  - Ne pas dupliquer une page mémoire tant qu'elle n'est pas modifiée
- Défaut de page lors du premier accès
  - Allocation et remplissage
    - Reprise sur erreur

Pagination à la demande

- *Demand Paging*
- La mémoire n'est qu'un cache des données manipulées par le processus
  - Initialement tout est sur le disque
    - A la fin aussi
  - Entre temps, on charge ce qui est accédé quand c'est nécessaire
    - Et on peut évincer quand ca n'est plus nécessaire
  - Mouvement de page entre disque et mémoire
    - Sans que l'application ne s'en rende compte

Défauts de page

- Un défaut de page est un accès qui ne peut être réalisé par le matériel
  - Le processeur ne peut pas faire
  - Il demande l'aide de l'OS
    - Il envoie une exception
- Exemples :
  - Adresse virtuelle invalide
  - Adresse valide mais page absente en mémoire physique
  - Adresse valide mais écriture interdite

Défauts de page (2/2)

- L'OS a défini un traitant pour l'exception « défaut de page »
- Le traitant identifie le problème
  - Peut-il être réparé ?
    - Exemple : Chargement d'une page depuis le disque
  - Si oui, le processus redémarre la même instruction
  - Si non, le processus ne pas continuer
    - Il est tué !

Un défaut de page n'est pas (toujours) une erreur

- C'est une exception pendant la traduction
  - L'accès n'est pas possible avec la table des pages actuelle
    - Ca n'implique pas que l'application a fait une erreur, c'est souvent la faute de l'OS
- Le défaut peut souvent être réparé
  - Page chargée du disque en mémoire, Copy-on-write, malloc pas encore utilisé, ...
- Parfois c'est une erreur
  - Segfault

Allocation de pages

- L'OS dispose d'une liste de pages libres
  - ou une liste par noeud NUMA
    - Les pages ne sont finalement pas si équivalente que ça...
- Si la liste est vide, il faut libérer une page
  - Si on échoue, l'allocation échoue

Libération de pages et swap

- Choisir une page peu utilisée
- Si elle est *Dirty*, il faut la sauver sur le disque
  - Trouver où l'envoyer sur le disque
    - Bloc de swap disponible
    - Ou blocs de fichier correspondant
  - Soumettre l'I/O d'écriture sur disque
    - Libérer la page à la terminaison de l'I/O

Chargement de page lors d'un défaut

- On a récupéré une page libre
- Localiser les données à charger
  - Bloc de swap
  - ou blocs de fichier correspondant
  - Sinon remplir la page de zéros
- Soumettre l'I/O de lecture depuis le disque
- Lorsque l'I/O termine, adapter le statut de la page et reprendre le processus

Intérêts de la pagination à la demande

- Localité temporelle
  - Une page accedée récemment le sera surement à nouveau dans le futur proche
- Localité spatiale
  - Les zones mémoire voisines seront surement accedées dans le futur proche

Intérêts de la pagination à la demande (2/2)

- Une page chargée va être réutilisée plusieurs fois
- En moyenne, on utilise beaucoup les choses déjà chargées
  - En dehors de la période d'initialisation
    - Où tout doit être chargé
- Ne pas charger trop de choses inutilement
  - Surtout si tout ne tient pas en mémoire physique !

Limites de la pagination à la demande

- Certaines applications ne respectent pas vraiment la localité spatiale ou temporelle
  - Mauvaise pratique du programmeur ?
- Les politiques de chargement et remplacement doivent être bonnes
  - Heuristiques d'anticipation

Projection de fichiers

- Tout est fichier
  - Le code du programme et des bibliothèques
  - Leurs variables globales
  - Et même la pile et le tas
    - On pourrait considérer que c'est grosso-modo le *fichier de swap* qui est chargé
- L'OS ne fait que manipuler que des pages de fichiers
  - Une page chargée en mémoire est la projection du fichier sous-jacent
    - *Mapping* mémoire

Projection publique

- Les modifications effectuées en mémoire sont répercutées dans le fichier
  - Visible par les autres processus
- mmap avec MAP_SHARED

Projection privée

- Copie privée du contenu d'un fichier
  - Les modifications sont sauvées dans le swap
    - Pas dans le vrai fichier initial
  - Et sont perdues à la fin du processus
- mmap avec MAP_PRIVATE

Projection anonyme

- Projection sans fichier de support
  - Initialisé à zéro
- mmap avec MAP_ANONYMOUS
- La pile ou le tas
- Utilisé par malloc pour les allocations en dehors du tas
  - Si le tas ne peut plus augmenter
  - Si on doit allouer beaucoup
- Peut être privé ou public

Copy-on-Write

- Les copies mémoire coûtent cher
  - Éviter de dupliquer inutilement
    - Pages partagées et privées mais non modifiées
    - Et ça économise de l'espace mémoire
- Retarder la duplication au maximum
  - Jusqu'à la première modification concurrente
  - Jamais de duplication si jamais de modification
    - Fork puis Exec
    - Tout sauf le bas de la pile juste après Fork
    - Allocation facile de pages remplies de zéros

Copy-on-Write (2/2)

- Page mise en lecture seule dans le matériel
  - Forcer un défaut de page pour détecter une modification concurrente
    - Même si on écrit exactement ce qui est déjà en mémoire !
      - Exception lors de la traduction, avant l'écriture réelle
- Le traitant alloue une page, copie le contenu dedans, la donne au processus
  - Protection ajustée sur l'original et la copie
    - La copie devient privée
    - L'original reste Copy-on-Write s'il reste plusieurs utilisateurs privés

Exemples de Copy-on-Write

- On effectue deux fork() successifs
  - Combien de processus obtient-on ?
  - Zones privées sont marquées CoW avec 4 références
- Chaque processus modifie la même zone privée
  - 1ère modification : récupère une copie RW
    - La page partagée reste CoW avec 3 références
  - 2ème : 1 autre copie RW + CoW à 2 réfs
  - 3ème : 1 autre copie RW
    - Seul le 4ème utilise désormais la page partagée
  - 4ème : La page n'est plus CoW, accès normal

Copy-on-Write peut rester trop cher

- Copy-on-Write est utilisé en permanence mais ne suffit pas
  - Fork doit dupliquer la table de pages et mettre plein de pages en Copy-on-Write
    - Cher si le processus est gros
    - Bête en cas de Fork puis Exec
      - Exec va tout libérer juste après

vfork()

- vfork() ne duplique rien, rajoute simplement une référence sur la table de pages
  - Un appel à Exec ou Exit va libérer la référence rapidement
- Tout est partagé entre père et fils
  - Aucun mécanisme de détection d'accès concurrents
    - Pas de *Copy-on-Write* sur les pages
  - On doit bloquer le père en attendant Exec ou Exit
- Similaire à clone() avec CLONE_VM

Description de l'espace d'adressage

- Pour chaque page virtuelle, il faut savoir
  - Quel fichier et quel décalage dedans
  - Quel type de projection (privé ou publique ?)
    - Utilisé par plusieurs processus ou non
      - Compteur de références pour les pages physique
  - Quelle protection mémoire
  - Présent en mémoire ou non

Description de l'espace d'adressage (2/3)

- Il faut l'état actuel + l'état possible
  - Différence entre
    - Etat voulu par l'application
      - ex : dupliqué par fork
    - Etat utilisé par le système/matériel
      - ex : partagé par Copy-on-Write
  - Permet la gestion retardée
    - Allocation fainéante met page valide et absente au lieu de valide et présente

Description de l'espace d'adressage (3/3)

- Le stockage de l'état des pages est très gourmand en mémoire
  - Regrouper les pages consécutives et similaires en segments
    - Les VMA (Virtual Memory Area) de Linux
    - Cf /proc/<pid>/maps
  - Segments utilisés pour décrire projection, partage, ...
  - Table de pages utilisées pour protection bas-niveau

Gestion des défauts de page

- Protection actuelle des pages stockée dans le matériel
  - Permet de déclencher des défauts « virtuels » pour la gestion fainéante
    - Allocation ou duplication au dernier moment
- Exception déclenchée au premier accès
- Le traitant trouve le descripteur de la zone dans l'OS et la PTE
  - Et en déduit quoi faire

Gestion des défauts de page (2/2)

- Si l'accès est invalide
  - Tuer le processus
    - Segmentation Fault
- Si l'accès est valide et la page absente
  - Charger depuis le disque
    - Le descripteur de page dit depuis où
- Si l'accès est écriture et la page privée
  - Créer une copie et la donner au processus
    - Mapping privé, Copy-on-Write, ...
- Voir handle_mm_fault() et handle_pte_fault() dans mm/memory.c

Défauts inattendus

- Une page valide déjà chargée peut provoquer un défaut
  - Copy on Write après fork()
    - Accès en écriture sur protection matérielle R/O
  - Mapping privé pas encore modifié
    - Accès en écriture sur protection matérielle R/O
  - Page chargée par autre processus, mappée mais pas encore accédée
    - La table des pages ne pointe pas encore dessus

Défauts majeurs et mineurs

- Chargement de page depuis disque ou swap très coûteux
  - Défaut majeur
- Tous les autres coûtent « peu »
  - Défaut mineur

- Cf /usr/bin/time echo toto

Le *Swap*

- Extension de la mémoire physique
  - Plus lent
  - Pas besoin d'être déréférencable par le processeur
- Stocké sur dispositif physique quelconque
  - Disque dur, mémoire distante, ...
  - Grand tableau de bloc de la taille d'une page
- Entièrement géré par l'OS

Le *Swap* (2/4)

- Historiquement on swappait des processus entiers
  - Suspension complète de l'exécution
    - Impose de vérifier qu'aucune I/O n'est en cours, ...
- Pagination permet granularité de la page
  - Un processus gigantesque peut continuer à s'exécuter en résidant essentiellement dans le swap
    - Du moment que le code et les données actuellement utilisés sont en mémoire

Le *Swap* (3/4)

- Les PTE valides mais non-présentes peuvent pointer vers un bloc du swap
  - Un accès provoque un défaut de page et le chargement du bloc en mémoire
- L'OS décide de quelles pages envoyer sur le disque
  - Selon le principe de localité

Le *Swap* (4/4)

- Le *Swap* sert uniquement quand il faut libérer de la mémoire physique
  - Quand on doit allouer d'autres pages virtuelles en mémoire physique
- Seules les pages privées et/ou anonymes vont dans le swap
  - La libération des pages de mappings publics les renvoit sur le disque contenant le fichier correspondant
    - Si pas modifiées, rien à sauver !

Gestion mémoire

Heuristiques de gestion mémoire

Qui et quand charger ?

- *Demand Paging*
- Les pages quand elles sont accédées
  - Lors du défaut de page
    - PTE valides mais non-présentes
- *Prepaging* et *Prefaulting*
  - Chargement à l'avance des pages suivantes
    - Principe de localité

Où charger ?

- Dans n'importe quelle page physique en général
  - La première disponible
- Important sur NUMA
  - Les tâches préfèrent utiliser de la mémoire proche
- Maintenir une liste de pages libres par noeud NUMA
  - Allouer des pages de préférences dans la liste locale

Quand sauver les modifications ?

- Il faut sauver les pages modifiées
  - Dans des fichiers correspondants ou dans le swap
- Pages mappées difficiles à gérer
  - Pas d'appel explicite à l'OS lors des modifs
    - Contrairement à Write()
  - La matériel ajoute un bit *Dirty*
    - L'OS l'enlève quand il sauve la page
- On sauve uniquement les pages *Dirty*
  - Au pire, régulièrement en tâche de fond

Qui swapper ?

- Les pages non-utilisées à l'avenir
  - Optimal = Algorithme de Belady
    - Choisir la page non-utilisée pendant le plus longtemps à l'avenir
  - Comment prédire le futur?
    - Principe de localité?
- Politique LRU (Least Recently Used) ou LFU (Least Frequently Used)
  - Assistance du matériel nécessaire pour maintenir des statistiques d'accès aux pages

Quand swapper ?

- Attendre le dernier moment?
  - Allocation mémoire impossible, impose de libérer une page
    - Bloque l'application pendant longtemps
- A l'avance ?
  - Quand la mémoire disponible passe en dessous d'un seuil
    - Démon *Swapper* qui fait du ménage en tâche de fond de temps en temps

Anomalies du swap

- Assez facile de mettre en défaut LRU
  - « Effet trou »
    - Allouer N+1 pages virtuelles dans N pages physiques et les utiliser en tourniquet
- Ajouter RAM ne réduit pas forcément le nombre de défauts de pages
  - « Anomalie de Belady »
    - Dépend des accès des application

Que conserver en mémoire ?

- La mémoire va plus vite, autant l'utiliser
  - Toujours conserver le plus possible en mémoire
    - Au cas où ca serve plus tard
      - Principe de localité
- Qu'est-ce qui peut servir plus tard?
  - Dans le même processus
    - N'importe quelle page
  - Dans les autres processus
    - Les mappings publics

Que conserver en mémoire ? (2/2)

- Sauvegarde régulière des modifications
  - Sans forcément libérer les pages
    - Uniquement libérer quand on veut allouer
- En régime permanent, un OS utilise tout la mémoire, au cas où
  - Pages publiques gardées en mémoire si un processus les réutilise
    - « cached » dans la sortie de la commande free
  - Pages privées gardées en mémoire jusqu'à la fin du processus courant
    - « used » et « shared » dans la commande free

Gestion des famines

- Si une allocation mémoire échoue?
  - Aucune page swappable, swap plein, ...
- Le système doit survivre
  - Il se garde un peu de mémoire pour lui
- L'utilisateur doit pouvoir continuer à utiliser le système
  - Tuer un processus pour libérer de la mémoire
    - Soit le processus dont l’allocation échoue
    - Soit un autre pour que l’allocation n’échoue pas
  - L'*Out-of-Memory Killer* de Linux

Gestion des famines (2/2)

- Qui tuer?
  - Celui qui essaie d'allouer?
    - Il n'a pas forcément alloué beaucoup avant
  - Celui qui alloue beaucoup?
    - Il n'a pas forcément alloué beaucoup récemment
      - Il y avait peut-être beaucoup de mémoire disponible quand il a alloué ses pages
  - Pas les processus importants ?
    - ex : Serveur X qui gère l'affichage des autres processus

Gestion mémoire

Support matériel

Gestion des adresses virtuelles dans le matériel

- Le code manipule uniquement des @virt
  - Le processeur doit les traduire en @phys
- Il faut que la table des pages soit accessible au matériel
  - Soit directement
    - Par une MMU
  - Soit indirectement
    - Par l'OS via une exception

La MMU

- *Memory Management Unit*
- Circuit dédié du processeur pour traduire les @virt
  - Obtient le numéro de page physique associée au cadre virtuel
  - Ajoute le décalage dans la page

Le TLB

- La traduction des @virt peut être lente
  - Un accès mémoire par niveau de table
    - Plusieurs accès mémoire matériels lors d'un seul accès demandé par le programme !
- Nécessité de *cacher* les traductions
  - *Translation Lookaside Buffer*
    - Cache dans le processeur (dans la MMU)
  - Le TLB contient les dernières traductions
    - Sans le décalage, évidemment
  - Principe de localité

Le TLB (2/2)

- Tableau de numéros de cadres virtuels et de leur PTE associée
- Cache souvent totalement associatif
  - Toutes les entrées sont testées en parallèle
    - Rapide
- Très rapide mais cher donc petit
  - Quelques centaines d'entrées maximum
    - Couvre quelques megaoctets au maximum
    - Il est important de sortir du TLB le moins possible
- Parfois un deuxième cache plus gros mais plus lent

Défauts de TLB

- En cas de TLB miss
  - Il faut récupérer la traduction dans la table de pages
- Géré par la MMU si elle existe
  - par l'OS sinon

Défauts de TLB, par MMU

- Si support matériel pour les défauts de TLB
  - Ex : Processeurs x86
    - PGD stocké dans registre spécial CR3
  - La MMU parcourt la table pour trouve PTE et mettre dans TLB
  - Table de pages stockée en mémoire de manière lisible par le matériel
    - Contraint taille/structure des PTE pour l'OS
      - Limite la quantité d'information stockable dans les PTE

Défauts de TLB, logiciellement

- Si TLB géré logiciellement (*no MMU*)
  - Ex: Processeurs MIPS
  - Le processeur déclenche une exception
  - Le traitant de l'OS parcourt la table de pages, vérifie la protection, ...
  - L'entrée manquante est insérée dans le TLB
    - Le même travail qu'une MMU, mais logiciellement
- Table de pages stockée de manière quelconque par l'OS
- Qui choisit l'entrée à remplacer ?
  - L'OS ou le matériel ? Algorithme LRU ?

Changement de contexte

- Lorsque l'ordonnanceur passe la main à un autre processus
  - L'espace d'adressage change
- Si le matériel sait lire la table de pages
  - Il faut lui donner la nouvelle
    - Changer le pointeur CR3 sur x86
- Il faut vider le TLB

Maintien du TLB à jour

- Vider le TLB lors des changements de contextes
  - Le matériel le fait parfois automatiquement
    - Sur x86, quand CR3 est modifié
- L'OS assure la cohérence entre TLB et tables des pages
  - Invalidation des entrées TLB quand on change des PTE

Traduction d'adresses virtuelles dans le processeur - Résumé

- Le programme passe une adresse virtuelle dans une instruction
- Le TLB est consulté pour traduire rapidement
  - Si TLB cache miss
    - Si MMU, la MMU parcourt la table des pages
    - Si pas de MMU, exception gérée par l'OS
  - Le TLB contient le PTE et valide la protection
- La mémoire physique est enfin accédée

Qui traduit des adresses en pratique ?

- TLB/MMU du processeur dans la plupart des cas
  - Beaucoup d'instructions manipulent des adresses mémoire
    - Il faut les traduire, le processeur le fait à la volée
- Lors d'une I/O, l'application donne une adresse virtuelle, le périphérique veut une adresse physique
  - L'I/O n'est pas une instruction traitée par le processeur, TLB/MMU ne peuvent pas aider

Traduction manuelle par l'OS

- Ca arrive notamment pendant les appels-système faisant des I/O physiques
- L'OS doit traduire avant de passer la requête au périphérique
  - Parcours « manuel » de la table de pages
    - Lecture PGD, puis PUD, … puis PTE
    - Beaucoup plus lent que TLB/MMU
  - Certains processeurs ont instructions dédiées à cette traduction explicite
    - Ex : tpa sur ia64

MMU, TLB et multicoeurs

- Chaque cœur exécute une tâche différente
  - Souvent dans espaces virtuels différents
    - Pouvoir préciser la table de pages de chaque cœur
- Le TLB peut être partagé
  - Bien si tous les cœurs exécutent des threads d'un même processus
  - Sinon il faut marquer l'espace virtuel correspondant à chaque entrée
  - Et ça doit rester rapide !
    - Donc proche des cœurs, et peu de contentions
    - Donc plutôt un TLB par coeur

Quid de la mémoire cache ?

- Petite zone de mémoire rapide entre le processeur et la mémoire centrale
  - Plusieurs niveaux plus ou moins petits et rapides
  - Accès mémoire vérifient d'abord si la donnée est dans le cache
- Essentiellement géré par le matériel
  - En particulier pour la cohérence entre différents caches sur machines multicoeur
  - L’OS doit parfois invalider
    - Changement de contexte ou de mapping

Gestion mémoire

Mémoire du noyau

Espaces d'adressage utilisés par le noyau

- Espace virtuel spécifique au noyau
  - Accessible uniquement en mode privilégié
    - Directement déréférençable depuis le noyau
    - Non modifié lors des changements de contexte
- Espace virtuel utilisateur du processus courant
  - Pendant un appel système ou une interruption
    - Pas toujours déréférençable par le noyau
      - Ca dépend s'il est dans la table de pages noyau
    - Modifié lors des changements de contexte
  - Aucun si thread noyau

A quoi le noyau peut-il accéder ?

- Le noyau est un contexte d'exécution
  - A un espace virtuel courant et une table des pages
    - Aussi vaste que quand en mode utilisateur
- Le noyau a potentiellement le droit accéder à tout
  - Toute la mémoire physique
    - Elle ne tient pas toujours intégralement en mémoire virtuelle
  - La mémoire virtuelle de tous les processus ?
- Comment y accéder ?
  - Le processeur veut une @virt dans table des pages actuelle

De quoi le noyau a-t-il vraiment besoin ?

- Son code
  - Binaire autosuffisant
    - Pas besoin de bibliothèques
    - Les fonctions de bases sont réimplémentées sans dépendre de la libc
      - strlen, strcmp, printk, memcpy, listes, ...
- Ses données propres
  - Structures allouées dynamiquement
    - Descripteurs de périphériques, fichiers, sockets, VMA, tables de pages, ...
- C'est tout petit (10-100 Mo) !

De quoi le noyau a-t-il vraiment besoin ? (2/2)

- La plupart des données en mémoire ne sont jamais déréférencées par le noyau
  - Ex: Code et données utilisateur vont/viennent vers/depuis les périphériques uniquement
    - Jamais besoin de les mapper en espace noyau !
- Le noyau ne mappe rien par défaut à part le strict minimum
  - Le reste peut-être mappé temporairement si nécessaire

Accès temporaire à n'importe quelle partie de la mémoire

- Besoin de mapper des pages quelconques de temps en temps
  - Ex: Copie mémoire pendant I/O logique
- Mapping temporaire
  - Ajout à la table des pages avant accès
  - Retrait après accès
    - Mise à jour du TLB des processeurs impliqués
      - On peut se limiter à un seul cœur dans les cas simples
  - Empêcher le swap de ces pages!

Accès à l'espace utilisateur depuis le noyau

- Certains OS mappent l'espace utilisateur courant dans le noyau, aux mêmes adresses
  - Ex: Linux
  - Accès normal à la mémoire utilisateur, par les mêmes pointeurs
- Certains OS ne mappent pas l'espace utilisateur dans le noyau
  - Ex: MacOS X, Windows, ...
  - Espace utilisateur pas directement déréférençable
    - Impose mapping temporaire dans l'espace noyau
    - Ex: pendant un appel-système

Espace virtuel dans Linux

- Divisé entre espaces virtuels noyau et du processus utilisateur courant
  - Suffisamment pour que les deux travaillent...
  - Espace noyau virtuellement partagé entre tous les processus
    - Une seule fois en mémoire physique
      - Mais dans toutes les tables de pages
        - Partage de portion de tables de pages ?
    - Egalement partagé avec les threads noyau
      - Table de pages avec uniquement l'espace noyau

Espace virtuel dans Linux (2/3)

- Ex: en 32bits
  - Espace utilisateur entre 0 et 3Go
    - La pile commence à 3Go (vers le bas)
    - Un processus ne peut utiliser que 3Go de mémoire virtuelle !
  - Espace spécifique du noyau entre 3 et 4Go
- En 64bits, il y a largement assez de place pour tout le monde...
  - Actuellement 128To chacun sur x86_64

Espace virtuel dans Linux (3/3)

- Le noyau peut déréférencer directement les zones mémoire noyau et utilisateur
  - Du processus courant uniquement
    - Ex: Appels système peuvent accéder à mémoire utilisateur
      - Ex: write dans un tube
- Le processus utilisateur n'a accès qu'à sa mémoire utilisateur
  - Restriction de l'espace accessible via le matériel
    - Même table de pages mais accès restreint
  - Mais la faille Meltdown a changé ça...

Espace virtuel noyau dans Linux

- Large mapping **linéaire** de la mémoire physique dans l'espace virtuel du noyau
  - Evite le mapping temporaire pour les données souvent utilisées par le noyau
    - Le code et les données du noyau
- Un peu d'espace virtuel pour mapping temporaire des autres pages physiques
- Un peu d'espace virtuel réservé pour des zones mémoire spéciales (vmalloc)
  - Ex: Mémoire des périphériques, parfois très gros

Concurrence et synchronisation

Pourquoi de la concurrence ?

- Plusieurs files d'exécution simultanées
  - Machines multi-processeur/coeur
    - Voir intervention des périphériques (interruptions)
- Instructions non-atomiques
  - Modification de structures complexes
    - Listes, ...
- Préemption

➔ Aucune garantie que quelqu'un d'autre n'est pas en train de modifier la même ressource

Concurrence logique ou physique ?

- Accès concurrent physique impose exécution simultanée (matériellement) de différentes tâches
  - Impossible si un seul processeur
  - Un vrai accès concurrent au matériel (la mémoire)

Concurrence logique ou physique ? (2/2)

- La concurrence logique suffit à causer des problèmes
  - Accès interrompu par préemption
    - Autre tâche prend la main et accède à la même ressource alors qu'on n'a pas terminé
  - Ou par une interruption matérielle
    - Le traitant d'interruption modifie une ressources qu'on était en train d'utiliser avant l'interruption
      - Ex : la carte réseau donne un paquet à l'OS pendant que l'application lit le même socket

Compétition vs coopération

- Si on sait parfaitement ce que font les autres, ça peut être facile
  - On peut éviter la concurrence
  - Ils peuvent nous prévenir de leurs accès
- Sinon, il faut imaginer le pire
  - En pratique, tous les cas horribles finissent par arriver
    - Accès pile-poil quand il ne fallait pas, ...
  - S'en prémunir, même si ça peut paraître exagéré

Points communs entre le noyau et l'espace utilisateur

- Mêmes concepts et problèmes
  - Accès concurrents physiques et logiques
  - Exclusion mutuelle
  - Deadlocks
  - Famines

Différences entre le noyau et l'espace utilisateur

- Le noyau maîtrise la préemption et les interruptions
  - Il peut effectivement empêcher concurrence logique
    - En empêchant les autres acteurs ou événements de s'exécuter
- L'espace utilisateur n'a aucune maîtrise

Exclusion mutuelle (Mutex) et verrous

- Verrous à attente active
  - *Spinlocks*
    - Tentative de prise de ressource en boucle
      - Réactif mais consomme du CPU
        - Préféré pour sections critiques courtes
- Verrous à attente passive
  - Sommeil jusqu'à relâchement
    - Réveillé par l'autre tâche via l'ordonnanceur
      - Peu réactif mais consomme peu de CPU
        - Préféré pour sections critiques longues
- Protection contre famine ou deadlock dépendant de l'implémentation

Verrous en espace utilisateur

- L'ordonnanceur noyau n'a pas connaissance des verrous pris
  - Préemption peut rendre section critique très longue
  - Préemption peut passer la main à tâche qui va essayer de prendre le même verrou
    - Deadlock ?
      - Pas infini car tâche bloquée va se faire repréempter
        - Mais pas bien si attente active
- Attente passive très préférable en espace utilisateur

Verrous dans le noyau Linux

- Le coût de synchronisation est critique
  - **Beaucoup** de variantes dans Linux
    - Notamment les variantes à attente active
- Préemption désactivée quand un verrou à attente active est pris
  - Garantie d'avoir section critique courte

Optimisation des verrous actifs

- Si beaucoup de lecteurs et peu d'écrivains
  - *Read/Write Locks*
    - Plusieurs lecteurs en même temps
    - Un seul écrivain, défavorisé
      - Risque de famine ?
  - Le compteur de lecteur peut devenir un goulet d'étranglement...

Instructions atomiques

- Modification atomique simple
  - Entiers, pointeurs, ...
- Maintien de compteur
  - atomic_inc
- Tentative de prise seul d'une ressource
  - test_and_set
  - cmpxchg
  - Utilisé pour les spinlocks
    - Beaucoup plus efficace que modification entre prise et relâchement de verrous

Interruptions

- Le processeur peut être interrompu **n'importe quand**
  - Périphériques, horloge (préemption), ...
  - Y compris au milieu d'une section critique
    - Même s'il tient un verrou
- Si un code manipule une structure modifiable lors d'une interruption ?
  - Désactiver les interruptions avant de le manipuler
    - En plus d'un verrou pour se protéger des accès concurrents hors interruption (autres tâches)

Désactivation des interruptions

- Instructions dédiées pour désactiver les interruptions vers ce processeur
  - Ou vers tous les processeurs si vraiment nécessaire
  - Une seule ou toutes les interruptions à la fois
- Ne pas les désactiver trop longtemps
  - Ca nuit à la réactivité
    - On ne peut plus traiter les autres événements

Sémaphore

- Compteur (atomique) limité de ressources
  - Initialisé au nombre de ressources disponibles
- Equivalent à un verrou si une seule ressource
- Si trop d'accès, on bloque en attendant que quelqu'un relâche une ressource
  - atomic_dec_and_test
  - Sommeil si raté
    - Désordonnancement
  - Possible avec attente active mais peu utile
    - L'attente est souvent longue

Attendre un événement avec un sémaphore

- Sémaphore initialisé à 0
  - Signifie « Événement non arrivé »
- Tentative de prise du sémaphore pour attendre l'événement
  - Bloque tant que personne ne relâche
- Arrivée de l'événement relâche le sémaphore
  - Réveille le processus endormi
- Utilisé pour attendre la fin des I/O
  - Le traitant d'interruption relâche le sémaphore et cela réveille l'application en attente

Variables spécifiques au processeur

- Il y a toujours une seule tâche par processeur
  - Pas de concurrence d'accès aux variables « locales » du processeur
    - Sauf en cas de préemption
      - Désactiver les interruptions
- Utile quand une tâche est assurée de rester sur le même processeur
  - Threads noyau
- Ex: pour des statistiques

Optimisations des verrous : *Read-Copy-Update*

- Certaines modifications peuvent garder la cohérence des objets
  - Lecture possible pendant modification
  - Verrouillage uniquement pour modifications concurrentes
  - Nécessite ordre/cohérence des modifications
- Ne pas désallouer avant que lecteurs ait terminé
  - On ne connaît pas les lecteurs !
    - Assistance de l'ordonnanceur pour savoir quand ils sont garantis d'avoir suffisamment progressé
- Très utile si applicable (ex: pile réseau Linux)

Gestion du temps

Intérêt

- Notion de temps critique pour l'exécution globale du système
  - Système à la fois *event-driven* et *time-driven*
- Nécessité de savoir quand exécuter des tâches
  - Travaux régulier
    - Préempter et équilibrer les listes d'ordonnancement
    - Rafraîchir l'écran
  - Travaux déferrés
    - Entrées-sorties disque

Intérêt (2/2)

- Fournir des indications à l'utilisateur
  - Date courante
  - Dates de modifications/accès aux fichiers
  - Fonctions avec timeout
  - Alarmes
  - Statistiques d'utilisation
    - Aussi utile pour les algorithmes d'ordonnancement
  - Logs d'événements
  - ...

Comment savoir l'heure ?

- Ticks d'horloge
  - *Programmable Interval Timer (PIT)*
  - Les *jiffies* de Linux
  - Léger et régulier, mais grossier
    - 250Hz sous Linux x86 récent
      - 4 ms de précision absolue
    - Délai de traitement d'interruption
  - Augmenter la fréquence pour augmenter la précision ?
    - Coût prohibitif des interruptions

Comment savoir l'heure, plus précisément ?

- Compteur de cycles
  - Dans la plupart des processeurs modernes
    - Instruction rdtsc sur x86
  - Très précis à court terme, pas coûteux
- Difficile à relier à l'heure actuelle
  - Changements de fréquence
  - Desynchronisation entre processeurs
    - Voire entre coeurs d'un même processeur

Comment savoir l'heure absolue ?

- Ticks et TSC = heure relative
- Heure absolue donnée par l'horloge
  - RTC = *Real Time Clock*
  - Fonctionne même si l'ordinateur est éteint
    - Tant que la pile de la carte mère est en vie
  - Granularité élevée (seconde)
  - Cher à programmer et à consulter

Combiner les sources

- RTC lue au démarrage
  - Voire de temps en temps
- Sert de base aux interruptions d'horloge pour garder une heure logicielle
  - Granularité moyenne (ms)
- Autres fonctionnalités spécifiques au matériel pour augmenter la précision
  - TSC (de moins en moins souvent)

Supprimer les ticks d'horloge ?

- Les ticks d'horloge peuvent être inutiles
  - Système *idle*
    - Rien à faire dans le traitant d'interruption
  - Processus unique exécutant des calculs sans faire d'entrées-sorties
- Les OS suppriment des ticks en programmant uniquement un pour le prochain événement si nécessaire
  - Souci d'économie d'énergie

Mesurer la durée d'ordonnancement

- À chaque tick d'horloge, attribuer la durée d'ordonnancement au processus courant
- Pas très précis
  - Autres interruptions intermédiaires mal comptabilisées
  - Préemptions intermédiaires ignorées
- Suffisant pour l'ordonnanceur
  - *Timeslice* souvent au moins de l'ordre de 10ms
  - Et pas très cher

Programmer une alarme

- Enregistrer une fonction à exécuter après un certain délai
  - Pour réveiller un processus (sleep, timeout, …)
  - Ou envoyer un SIGALRM, etc.
- Comment l'exécuter ?
  - Il faut que le noyau ait la main au bon moment pour l'exécuter
    - Même problème que pour la préemption
- Vérifier périodiquement
  - Si le délai est dépassé, exécuter

Programmer une alarme (2/2)

- Attente active jusqu'à l'expiration du délai
  - Gaspillage de temps CPU
- Vérifier si le délai expiré à chaque interruption d'horloge
  - Pas très précis
- Les processeurs modernes peuvent programmer des interruptions plus précisément (ex : HPET sur x86)
  - Ex : ualarm(8100 µs) si tick = 4 ms ?
    - Après 2 ticks d'interruption normale, programmer une alarme HPET dans 0,1 ms

Systèmes de fichiers

Intérêts des systèmes de fichiers

- Structurer et organiser les données sauvées sur le disque
  - Pour y accéder facilement
    - Que ce soit l'OS ou l'utilisateur
  - Pour y accéder après un reboot (voire crash)
    - L'OS et l'utilisateur ont oublié où étaient stockées les données sur le disque
- Séparer les données en entités logiques indépendantes
- Cacher le stockage physique sous-jacent

Les problèmes à gérer

- Intégrité des données
- Performance
- Comment stocker les données?
  - Et les metadonnées?
    - Attributs, taille, droits, répertoires, ...
- Comment réparer après un crash?
- Comment gérer les accès concurrents des différents processus
  - Pas forcément sur la même machine

Et si on utilise pas de système de fichiers ?

- On peut ouvrir et écrire directement dans le disque
  - Ex : manipuler /dev/sda5 comme un seul gros fichier de taille fixe
- Disque/partition réservé à une seule application
  - Ou les applications doivent se mettre d'accord sur qui utilise quelle(s) partie(s)

Systèmes de fichiers

Organisation

Pile d'accès au stockage

- Interface de haut niveau
  - fopen, fread, fwrite, ...
- Appels systèmes
  - open, read, write, unlink, mkdir, stat, ...
- Couche de virtualisation des fichiers
  - *Virtual File System* dans Linux
  - Différents « pilotes » de système de fichiers
    - Ext4, vfat, NTFS, NFS, ZFS, ...

Pile d'accès au stockage (2/2)

- Couche de virtualisation des blocs
  - *Block Device Layer* de Linux
  - Différents types de système de stockage
    - IDE (P-ATA), SCSI (S-ATA), Network Block Device, ...
  - Possibilité d'agrégation RAID, LVM, cryptage, ...
- Drivers de chipsets et périphériques
- Périphériques
  - Stockage linéaire de blocs

Descripteurs de fichiers

- Chemin et *File descriptor* en espace utilisateur
  - Avec un offset
- Numéro d'i-noeud dans le VFS
  - Avec un offset ou un offset dans une page
- Numéro de bloc dans périphérique virtuel
  - Puis dans périphérique physique

Structure des systèmes de fichiers

- Arborescence
  - Lien entre noeuds étiquetés par des noms
  - Feuilles = fichiers de données
  - Le reste = Répertoires
- Lien symbolique ?
  - Fichier contenant un chemin
- Lien physique ?
  - Rupture de la structure d'arbre
    - Deux branches arrivent sur le même noeud

Structure des fichiers

- Fichier de données
  - Suite d'octets sans structure pour l'OS
  - Encodage par l'application
    - Ou par les bibliothèques systèmes pour les sections dans les binaires
- Répertoire
  - Suite de descripteurs de fils
  - Nom et attributs
  - Souvent non-ordonné

Montage

- Disque divisable en partitions
- Chaque partition contient une arboresence de fichiers
- Montage = Insérer une arborescence d'une partition dans l'arborescence d'une autre
  - Un morceau de l'ancienne est masqué pendant la durée du montage

Path Lookup

- Trouver un noeud/fichier à partir d'un chemin (chaîne de caractères)
  - Géré par le VFS selon les montages de partition
- Commencer en haut de la partition racine
  - Si chemin absolu
- Diviser le chemin en entités
  - Séparées par des slashs sous Unix
- Noms spéciaux pour faire référence au père (..) ou à soit même (.)

Path Lookup (2/2)

- A chaque étape, extraire la première entité
  - Trouver le fils correspondant dans le répertoire courant
  - Utiliser en priorité la racine du montage le plus récent s'il existe
  - Vérifier les permissions
  - Recommencer depuis cet endroit

Pourquoi des descripteurs de fichiers ?

- Le *Path Lookup* est très lent
  - Multiple accès mémoire, verrous, accès disques potentiels, ...
- Le système « cache » le résultat et l'application prend une référence dessus par l'appel système open
  - Les appels suivants utilisent directement le descripteur
- « Pointeur » dans le fichier avance selon les read/write

Protection

- Il faut pouvoir définir un ensemble de droits des utilisateurs sur les fichiers
  - Soit une liste de droits par utilisateur
    - *Capability*
    - Facile à transférer ou partager
  - Soit une liste de droits par objet
    - *Access Control List (ACL)*
    - Facile à gérer pour l'OS
      - ACLs de chaque fichier sont stockées avec attributs
    - Lourd si plein d'utilisateurs avec droits différents
      - Définir des groupes d'utilisateurs

Objets dans les systèmes de fichiers

- I-noeuds (*Inode*)
  - Objet de base décrivant un fichier ou répertoire
    - Contenu et droits associés
- Dentry (*Directory entry*)
  - Entrée stockée dans un répertoire
    - Décrire un lien vers un i-noeud fils
      - Contient un nom

Objets dans les systèmes de fichiers Linux (2/2)

- File
  - Descripteur de fichier ouvert
    - Pointe vers un Dentry et décrit la position actuelle
- Superblock
  - Descripteur de système de fichiers
    - Premiers blocs d'une partition
      - Donne le type du FS
    - Pointe vers l'i-noeud racine

Méthodes des fichiers

- Le *Virtual File System* est programmé sur le modèle des objets
  - Objets spécifiques à chaque système de fichiers, hérités des objets génériques du VFS
  - Méthodes génériques au VFS ou spécifiques au système de fichiers
    - Routines de lecture/écriture des données et metadonnées
      - read, write, stat, mkdir, rmdir, link, chmod, ...

Méthodes spécifiques aux systèmes de fichiers

- Fonctions de gestion des blocs où les données sont stockées
  - Allocation, libération, recherche, ...
  - Pour les répertoires et pour les fichiers
  - Lecture, écriture
    - Utilisé explicitement par read/write/...
    - Utilisé implicitement après mmap
- Les méthodes du FS utilisent ces routines pour gérer le stockage réel

Fichiers spéciaux

- Chaque méthode peut avoir un comportement spécial dépendant du fichier
  - /dev/null, /dev/zero, /dev/full, /dev/mem, ...
- On peut créer des fichiers spéciaux avec un comportement quelconque en lecture/écriture/ioctl

Systèmes de fichiers

Stockage

Plusieurs problèmes

- Répartir et lier les différents blocs des fichiers/répertoires au sein du disque
- Trouver et gérer les blocs libres
- Stocker/organiser le contenu des répertoires par dessus ces blocs

Descriptions des fichiers

- Un fichier est une suite de bloc
  - Structuré (répertoire) ou non (fichier)
    - Fichier = Structuré par l'application
  - Taille variable dynamiquement
- Et des metadonnées
  - Eventuellement de taille variable
    - ACLs, ...

Besoins des fichiers

- Trouver le bloc correspondant à un morceau de fichiers
  - Pour le lire ou le réécrire
    - Accès séquentiels ou aléatoires
- Allouer un bloc
  - Pour écrire dans le fichier
    - À la fin ou dans un trou
- Libérer un bloc
  - Pour supprimer ou tronquer un fichier

Besoins des fichiers (2/2)

- Le plus important est la recherche
  - Doit être rapide pour accès aléatoires ou séquentiels
- Allocation/libération moins critiques
- Comment organisers ces blocs?
  - Les blocs contenant un fichier sont stockés dans la structure inode correspondante
    - Avec ou sans indirection

Allocation des blocs des fichiers

- Allocation contigue de tous les blocs?
  - Recherche facile
  - Accès disque minimisé (un seul *seek*)
  - Allocation difficile (comme le partitionnement)
    - First Fit ou Best Fit?
      - Fragmentation externe
    - La taille des fichiers peut varier
      - Souvent imprévisible
      - Agrandissement progressif pendant remplissage
  - Utilisé pour les CD-ROM
    - Précalcul de l'allocation avant gravure

Allocation par liste

- Liste chaînée de blocs pour chaque fichier
  - Éléments de liste stockés dans blocs réservés
    - Pour ne pas réduire l'espace dans les blocs réels
  - Simple, mais peu efficace pour accès non-séquentiels
- FAT (*File Allocation Table*) de DOS et Windows
  - Blocs groupés par « cluster »
    - Moins d'éléments de liste à traverser
  - FAT = Tableau statique de pointeurs vers le cluster suivant (suite du fichier courant)

Allocation par groupe de blocs

- Un nombre fixé contigu est alloué initialement
  - On rajoute d'autres groupes si nécessaire
- Accès disque optimisé
  - si la taille des groupes est grande
- Fragmentation interne
  - si la taille des groupes est grande

Allocation indexée

- Arbre de pointeurs vers les blocs
  - Accès non-séquentiels efficaces
  - Stocké dans un B-tree (arbre trié)
    - Un peu coûteux en gestion mais rapide
      - Recherche, parcours séquentiel, insertion, suppression en temps logarithmique
    - Econome en espace
      - Nombre variable mais faible de blocs d'indirections
    - Incomplet et un peu déséquilibré quand nécessaire
  - Combiner avec groupes contigus pour améliorer accès séquentiels

Occupation disque

- Stocker les données
  - Et les metadonnées décrivant les données
    - ex: Arbre d'indirection vers les blocs
- Écrire dans premier bloc pas équivalent à écrire dans 10^9ème bloc
  - Allocation blocs d'indirection intermédiaires
    - L'occupation disque d'un fichier peut être plus grande que les données réellement contenus !

Fichiers à trous

- Seuls les blocs utiles sont alloués
  - ex: Si on écrit à la fin d'un fichier sans jamais toucher au début
- Taille fichier != Occupation disque
  - L'occupation disque d'un fichier peut être beaucoup plus petite que sa taille !

- Pour s'en rendre compte, jouer avec dd count=...,seek=...

Gestion de l'espace libre

- Comment trouver un ou des blocs pour les allouer à un fichier ?
- Prendre le premier bloc libre ?
  - Facile avec une liste
- Prendre un bloc libre proche d'un autre bloc ?
  - Utile pour performance des accès séquentiels sur un disque dur traditionnel
  - Arbre d'indirection des blocs libres vers les suivants

Gestion des répertoires

- Un répertoire est un fichier a contenu structuré
  - La structure dépend du système de fichier
  - La structure est stockée dans les blocs de l'inoeud
    - Eux-mêmes déjà organisés en arbre dans le stockage physique (cf avant)
- Opérations de gestion de ce contenu
  - Allocation, libération, recherche et parcours des entrées de répertoire
  - Par dessus les opérations de gestion des blocs qui contiennent ces entrées

Gestion des répertoires (2/3)

- Besoin principal = Recherche rapide !
  - Trouver le fils pour un nom donné
    - Pendant le *Path Lookup* pour tous les appels-système qui manipulent un chemin
  - Sans optimisation, on parcourerait la moitié des entrées du répertoire en moyenne
- L'allocation (créer un fichier ou répertoire), la libération (effacer) ou le parcours (ls, readdir) sont beaucoup moins utilisés

Stockage des noms

- Tableau d'entrées de taille fixe ?
  - Embêtant pour les noms de fichiers longs
- Tableau d'indirections vers des noms
  - Allocation d'espace variable pour stocker les noms dans le « contenu » du répertoire
    - Dans les blocs suivants

Gestion des répertoires (3/3)

- Comment rechercher rapidement?
  - C'est l'opération la plus courante sur les répertoires!
  - Table de hashage au lieu du tableau?
    - S'il y a peu d'entrées dans le répertoire
  - En général, un B-tree, à nouveau
    - Un B-tree logique pour les entrées de répertoire, stocké dans un B-tree de blocs physiques de l'inoeud

Systèmes de fichiers

Fonctionnalités diverses

Accès concurrents et consistence

- Quand un processus modifie un fichier, que voient les autres et quand ?
- Sémantique de partage de fichiers UNIX
  - Modifications visibles par les autres immédiatement
- Sémantique NFS « Close-Open »
  - Modifications enregistrées lors de la fermeture et visible aux futurs open
- Partage du pointeur possible par dup/fork
  - Mais certaines fonctions n'utilisent pas ce pointeur (pread/pwrite/...)

Verrouillage des fichiers

- Verrouillage collaboratif
  - Global sur un descripteur de fichier
    - flock()
  - Sur un segment de descripteur de fichier
    - fcntl() avec argument F_SETLK, ...
- Verrouillage réel par le système
  - Vérification des droits lors des accès en lecture ou écriture
    - *System V Mandatory Locks*
  - Activé par les droits g+s-x sur le fichier

Journalisation

- Tester/corriger un FS est très long
  - Vérifier les arbres de blocs
  - Vérifier la structure des répertoires
  - Nécessaire en cas de crash avant démontage
    - Modifications pas forcément toutes déjà sauvées
- Sauver les modifications dans un journal séparé avant de les appliquer
  - Restauration à l'original si crash pendant application de la modification
- Conserver la cohérence du FS

Le *Buffer-Cache*

- Éviter les accès aux disques incessants
  - Regrouper les lectures/écritures
    - Éviter le seek-time des disques et profiter du débit
  - Garder les lectures en mémoire
    - Ne pas relire plusieurs fois depuis le disque
      - Principe de localité
- Ensemble de pages de fichiers gardées en mémoire du système
  - Remplies en mémoire quand c'est nécessaire
  - Sauvées sur le disque de temps en temps si modifiées

Accès explicite ou implicite

- Accès explicites (read, write, ...)
  - Copie entre l'espace utilisateur et le buffer-cache
  - On sait directement quels buffers ont été modifiés
- Accès implicites (mmap+déréférencement)
  - Mapping du buffer-cache dans l'espace du processus
  - Utilisation du bit *Dirty* pour savoir les buffers modifiés

Interaction avec le cache de pages

- Toutes les pages des processus sont considérées comme des pages de fichiers
  - Privé, publique, anonyme, ...
  - Dans Linux, *Buffer-Cache* = *Page-Cache*
- Optimisations génériques du système de gestion mémoire
  - Lecture des fichiers à l'avance (*Read-ahead*)
  - Sauvegarde regroupée, selon bit *Dirty*

Court-circuiter le *Buffer-Cache*

- Buffer-Cache génant dans certains cas
  - Le système doit allouer des pages pour le Buffer-Cache
  - Les écritures ne sont pas synchrones sur le disque
  - Ex : Calcul *Out-of-core*
- On peut demander des accès non-cachés
  - Paramètre O_DIRECT de open()
  - DMA entre le disque et la mémoire utilisateur
    - Tampons mémoire verrouillés, tailles alignées

Entrées-sorties

Objectifs

- Les I/O sont le maillon faible du système
  - Périphériques lents
    - Têtes de lecture des disques
- Maximiser l'utilisation pour ne pas réduire l'utilisation processeur
  - Mais plus de processus pour exploiter les processeurs impose plus I/O pour le swap
- Organiser la vision des périphériques
  - Vision uniforme, même si hiérarchique

Types de périphériques

- Entrées
  - Clavier, souris, scanner, micro, capteurs, ...
- Sorties
  - Ecran, imprimante, ...
- Entrées-sorties
  - Stockage, réseau, ...
- La mémoire n'est pas considérée comme un périphérique
  - Elle est déjà impliquée dans la plupart des instructions...

I/O logiques ou physiques ?

- I/O physiques vers les périphériques
  - Uniquement par l'OS
    - Sauf cas particuliers
- I/O logiques depuis l'application
- Structuration, protection et abstraction assurée par l'OS entre les deux

Entrées-sorties

Entrées-sorties physiques et matérielles

Structure matérielle

- Chipset(s) d'I/O relié(s) au bus mémoire
- Un ou plusieurs bus d'I/O par chipset
  - Des ponts (bridges) entre bus
- Arborescence de bus entre l'hôte et les périphériques
  - Voir la sortie de lspci -vt
  - Les feuilles sont des périphériques

Ressources matérielles

- Ressources exportées par périphériques vers hôte
  - Zones de mémoire ou de registres
  - Exportées par le « protocole » PCI
    - Mappées en mémoire physique par le BIOS et l'OS
  - Voir la sortie de lspci -vvxxx
  - Connu et utilisé par le pilote
- Ressources internes
  - Processeurs, mémoire, registres, ...
- Ressources de l'hôte exportées aux I/O
  - Mémoire accessible par DMA

Caractéristiques des I/O physiques

- Périphériques à caractéristiques variables
  - Débit, latence, protocole, granularité, erreurs, ...
- Gestion des I/O autonome ou non
  - Processeur qui contrôle tout
  - Périphérique qui exécute des commandes
  - Périphérique qui interrompt le processeur
  - Périphérique qui accède à la mémoire centrale
  - Périphérique programmable

Programmed I/O

- Entrées-sorties traitées par le périphérique selon des commandes du processeur
  - Ecriture de requête par le processeur
  - Lecture de réponse par le processeur
  - Accès direct aux registres du périphérique
- Attente de terminaison impose une attente active
  - while (!terminé);
- *Port I/O* ou *Memory Mapped I/O*

Port I/O

- *Programmed I/O* où les registres des périphériques sont accédés par instructions spéciales
  - Ils sont « mappés » dans un espace de ports
    - Voir /proc/ioports
  - Lus et écrits par bloc de 1, 2, 4 ou 8 octets
    - Ex : Instructions inb, outb, ins, outs, inl, outl, ...
- Sert essentiellement pour envoyer des commandes ou lire des réponses

Memory Mapped I/O

- *Programmed I/O* par accès naturel aux ressources des périphériques
  - Comme de la mémoire classique
    - Par déréférencement de pointeur
    - Un peu plus lent
      - Et pas caché en général (effets de bord, ...)
  - Permet d'utiliser la même interface pour les accès à la mémoire centrale et aux périphériques
- Peut servir pour envoyer des commandes, lire des réponses, ou transférer des données

Attente de terminaison

- Comment attendre la fin d'un traitement dans un périphérique ?
  - *Programmed I/O* impose attente active
    - Le processeur teste sans arrêt une valeur statut
      - « Scrutation »
  - Intéressant pour les petites requêtes
    - Réactivité très bonne
  - Mauvais pour les requêtes lentes
    - Monopolisation du processeur qui ne peut rien faire d'autre

Attente de terminaison (2/2)

- Scrutation de temps en temps?
  - Impose changement de contexte entre scrutation et l'application qui essaie de s'exécuter pendant ce temps
    - Mauvais pour performance et pollution du cache
- Il faut notification explicite du périphérique quand il a terminé
  - *Interrupt-driven I/O*
    - Le processeur peut recouvrir le traitement dans le périphérique par l'exécution d'une autre tâche

Interruptions

- *Interrupt Request* (IRQ)
- « Message » d'un périphérique pour prévenir le processeur d'un événement
  - Le processeur stoppe son travail actuel
    - Déroutement, comme appel système ou exception
  - Il traite le message du périphérique
  - Il retourne à son travail précédent
- Nécessite support matériel
  - Et l'OS doit fournir un traitant que le processeur exécutera en cas d'interruption

Qui a envoyé l'interruption ?

- Il y a différentes interruptions
  - Les « Lignes » d'interruption peuvent être partagées entre périphériques
    - Voir /proc/interrupts
- Le numéro d'interruption donne une petite liste de périphériques possibles
  - Leurs drivers savent leur demander si cela vient d'eux
    - Le driver fournit une fonction de traitant
      - PIO ou MMIO dans un registre de statut du périphérique pour savoir si l'interruption vient de lui

Que faire en cas d'interruption ?

- Traitement similaire à exception/appel-système
  - Déroutement de l'OS, traitement puis retour
  - Pas de contexte d'exécution spécifique requis
- Le driver sait quoi faire
  - Le traitant d'interruption s'en charge
  - PIO ou MMIO dans d'autres registres pour savoir les commandes à exécuter
  - Lecture de données en mémoire à traiter
  - L'état est spécifique au driver et matériel

Réactivité vs. Disponibilité

- L'exécution du traitant est immédiate
  - Trop d'interruptions peuvent empêcher tout autre travail
- Le périphérique évite de trop en envoyer
  - Il peut attendre un peu et interrompre une seule fois pour plusieurs événements
    - *Interrupt Coalescing*
  - Moins de charge processeur
  - Moins de réactivité

Traitements lourds dans les traitants d'interruption ?

- Les traitants doivent être courts
  - Ne pas nuire à la réactivité du système
    - Éviter de générer d'autres IRQ, exceptions, ...
      - Ex : Éviter les allocations mémoire
- Comment effectuer un gros traitement interruption ?
  - Ex : réception réseau, copie, CRC, ...
  - Faire le strict minimum dans le vrai traitant
  - Programmer le reste pour plus tard

Direct Memory Access

- Envoyer ou lire des données par PIO est très coûteux
  - Encore plus coûteux en CPU que copie mémoire
    - Et ca interdit le recouvrement
- Les périphériques modernes savent lire ou écrire directement en mémoire centrale
  - DMA (*Direct Memory Access*)
    - Un moteur DMA dans le chipset mémoire et un dans les périphériques
  - Processeur central pas du tout utilisé
    - Recouvrement total par autre exécution

Direct Memory Access (2/2)

- Les périphériques manipulent @bus
  - Equivalent de @phys vu des bus et périphériques d'entrées-sorties
  - Pas de notion de mémoire virtuelle, de défauts de pages, etc.
- L'OS traduit les @virt ou @phys en @bus
  - Puis les donne au périphérique
    - En paramètre de la commande
  - Et il verrouille les pages virtuelles pendant l'I/O
    - La traduction d'adresse doit être valide

Quelles stratégies utiliser ?

- C’est le pilote décide
  - selon les capacités du matériel

- Envoi de la commande
  - ***PIO Write*** par le processeur (en général)
    - Périphérique peut pas deviner quand on va lui envoyer une commande

Quelles stratégies utiliser ? (2/3)

- Notification de terminaison
  - Si traitement potentiellement long, ***Interruption*** par le périphérique
    - Le traitant du pilote est appelé
  - Si traitement court, le pilote peut faire attente active par ***PIO Read*** sur le processeur
    - Le pilote n'avait pas rendu la main après l'envoi de la commande, il traite aussitôt le résultat
- Les tâches qui attendaient cette I/O sont réveillées
  - Quand le pilote a terminé
    - A la fin du traitant d'interruption
    - Ou à la fin des PIO Read

Quelles stratégies utiliser ? (3/3)

- Transfert de données en entrée (hôte vers I/O)
  - Si peu de données, ***PIO Write*** avec la commande
  - Sinon (souvent), ***DMA Read*** par le périphérique

- Transferts de données en sortie (I/O vers hôte)
  - Si peu de données, le pilote fait un ***PIO Read*** par le processeur juste après la notification
  - Sinon ***DMA Write*** par le périphérique juste avant la notification

Exemples

- Liens sur la page du cours
  - Tout sauf MMIO dans le driver 8139too
  - MMIO dans le driver myri10ge

Entrées-sorties

Entrées-sorties logiques

Pourquoi des entrées-sorties logiques ?

- Masquer la complexité du matériel
  - Virtualiser les ressources
- Structurer les ressources
  - Systèmes de fichiers, connexions réseau, ...
- Partager entre plusieurs utilisateurs
  - Avec protection

Exemples

- Pour le stockage
  - I/O logiques = lecture d'un fichier
  - I/O physiques = commandes IDE ou SCSI
- Pour le réseau
  - Logiques = accès aux sockets et protocoles
  - Physiques = envoi/réception de paquets
- Pour le clavier
  - Logique = terminal
  - Physique = lecture de caractères

Exemples avec le stockage

- Accès depuis un processus
  - I/O logique (dans la libc ou le noyau)
    - Conversion chemin d'accès en inoeud
    - Conversion segment de fichier en blocs
  - I/O physique (dans le noyau ou les drivers)
    - Accès aux blocs sur un disque
    - Commandes IDE ou SCSI au controleur

Blocs ou caractères ?

- Certaines I/O sont des flux
  - Entrant et/ou sortant
    - Clavier, souris, cartes réseau
  - Les données sont lues/écrites une seule fois
- Certaines I/O ont une granularité matérielle
  - Stockage par blocs sur les disques
  - Les données sont lues par gros bloc
- On peut aussi mixer les deux
  - Fichier habituel : ni flux, ni blocs
  - Possibilité de flux de blocs, ...

Entrées-sorties

Entrées-sorties logiques en mode caractère (flux)

Entrées-sorties par caractère

- Flux de données entrant
  - Une donnée lue est perdue
  - Entrée à vitesse différente de l'application ?
    - Mettre données supplémentaires dans une file
    - Bloquer l'application si pas assez de données
  - Lecture à l'avance
    - Remplir la file tant que possible
    - Réduire/regrouper les accès au matériel
    - Accélérer les accès logiques suivants
      - Pas besoin d'attendre le matériel

Entrées-sorties par caractère (2/2)

- Flux de données sortant
  - Une donnée écrite ne peut plus être remplacée
  - Sortie à vitesse différente du matériel ?
    - Mettre l'application en attente si elle écrit trop
    - Et les données dans une file pour le matériel
  - Regrouper les accès physiques
    - Réduire le temps apparent d'émission en réduisant les accès au matériel

Entrées-sorties partagées

- Pas de notion de cache en mode caractère
  - Chaque caractère est lu et écrit une seule fois
- Files/anneaux de caractères/paquets partagés
  - Multiplexage entre applications dans même flux logique
    - ex: Plusieurs applications partageant un tube
  - Multiplexage entre flux logiques dans même canal matériel
    - ex: Plusieurs connexions réseau

Entrées-sorties non-bloquantes

- Application bloque indéfiniment si rien à lire ou trop à écrire
  - Attente passive
  - Impossible de travailler en attendant
- Essayer une I/O non-bloquante, et abandonner s'il faudrait attendre
  - Voir O_NONBLOCK pour socket

Entrées-sorties non-bloquantes multiplexées

- Comment attendre sur plusieurs sources d'événements en même temps ?
  - L'attente sur une source empêche de récupérer les événements des autres
  - Attendre un peu sur chaque source ?
    - Couteux et ne passe pas à l'échelle
      - Ex: Serveur www avec 1000 connexions

poll/select

- Le processus devrait se mettre sur plusieurs files d'attente en même temps
  - Le premier événement d'une source le réveille
- Passer un tableau de descripteurs de fichiers au noyau
  - poll() ou select()
    - Attention au passage à l 'échelle
      - Copier des milliers de descripteurs à chaque attente ?
  - Et si la source n'est pas un fichier ?

Entrées-sorties

Entrées-sorties logiques en mode bloc

Entrées-sorties par blocs

- Ensemble de blocs qu'on peut lire/écrire plusieurs fois
  - Pas de notion de flux
    - Accès aléatoire à n'importe quel bloc
      - Pas si simple en pratique...
- Possibilité de regrouper les accès
  - Cacher les données lues dans le système
    - *Page-Cache* pour les fichiers
  - Regrouper les écritures
    - Cachées dans le *Page-Cache* également

Entrées-sorties *bufferisées*

- Lire à l'avance ou retarder les écritures
  - Un seul accès physique pour plusieurs accès logiques répétitifs et/ou consécutifs
- Masquer la granularité matérielle
  - Blocs sur le disque
    - Comment lire un seul caractère ?
  - Pages en mémoire
    - Mémoire virtuelle non consécutive en mémoire physique
- Partage du cache entre applications

Entrées-sorties bloquantes

- I/O physiques souvent *Interrupt-driven*
  - Traitement en arrière plan par le périphérique puis interruption
    - Le processeur peut faire autre chose
- I/O logiques sont souvent bloquantes
  - Application attend terminaison I/O physique
    - Ne peut pas utiliser le processeur
      - Sauf avec des threads
    - Nécessite plus de tâches pour exploiter le processeur
- Sémantique de O_NONBLOCK inapplicable

Ecritures (moins) bloquantes

- Faire croire à l'application que l'I/O physique est terminée
  - Copier les données à écrire dans le cache et retourner un succès
- L'application peut continuer à travailler pendant I/O physique en arrière plan dans le système
- Et en cas d'erreur dans l'I/O physique?
  - L'application a continué à travailler en pensant qu'il n'y avait pas d'erreur?

Lectures (moins) bloquantes

- L'I/O physique doit avoir lieu avant
- Prédire les I/O pour les anticiper
  - Les I/O logiques seront immédiates
- Lecture disque à l'avance
  - Page-Cache des fichiers
    - Selon heuristiques d'accès aux fichiers

Entrées-sorties asynchrones

- Exposer l'asynchronisme matériel aux applications
  - Ne pas bloquer l'application pendant I/O physique
  - Notifier la terminaison de l'I/O plus tard
- Permet recouvrement des I/O
  - Sans rajouter des tâches pour exploiter les processeurs

Entrées-sorties asynchrones (2/2)

- Complexe à utiliser?
  - Impose de prévoir nos I/O à l'avance
    - Les soumettre bien-avant d'avoir besoin du résultat
  - Pas forcément plus complexe que les threads
    - Threads imposent d'exposer du parallélisme
- Voir la manpage de io_submit()
  - Ou aio_read() pour des fausses I/O asynchrones utilisant des threads

Ordonnancement des I/O

- Pas ou peu d'ordonnancement pour I/O en mode caractère
  - Premier arrivé, premier servi
  - Qualité de service réseau?
- Les I/O par blocs n'ont pas besoin d'ordonnancement ?
  - Ca dépend du matériel
    - Tous les accès ne sont pas équivalents en performance

Ordonnancement des accès disques

- Le déplacement de la tête de lecture est très lent (5 ms en moyenne)
  - Minimiser les déplacements
    - Trier par algorithme de l'ascenseur (*Elevator*)
    - Regrouper les requêtes proches, même si les fichiers n'ont rien à voir
- Optimisations
  - *Anticipatory Scheduler*
    - Attendre un peu en cas d'autres accès consécutifs
  - *Deadline*
    - Privilégier la lecture, l'écriture peut attendre

Entrées-sorties

Entrées-sorties configurables ou dédiées

I/O logiques dédiées

- Toutes les I/O logiques ne correspondent pas à une I/O physiques en dessous
  - Tube, Socket locale, ...
    - Appels système dédiés
      - Difficile (et dangereux) d'en ajouter
  - Fichiers caractère spéciaux
    - /dev/null, /dev/zero, /dev/random
      - cf TD5
      - Mode caractère ou bloc selon les besoins
  - Manipulés par appels-système read/write habituels
    - Via méthodes spécifique à chaque fichier

Au delà de read/write

- On peut abuser de read/write
  - On définit le comportement des fichiers comme on le souhaite
  - Ex : fichier spécial pointant vers une webcam
    - Read pour lire la prochaine image
    - Write à offset spécial pour changer la résolution
    - Write à autre offset pour changer le zoom
    - Autant de cas particuliers qu'on veut
  - Quid des opération qui ne ressemblent ni à read ni à write ?
    - Ex : opération avec données en entrée et en sortie

Les IOCTL

- *Input/Output Control*
- ioctl() est un appel système configurable pour chaque fichier
  - Numéros de commandes spécifiques
  - Fonctions spécifiques au fichier pour traiter ces commandes
  - Argument pouvant être un pointeur
    - Peut pointer vers multiples données, entrées et/ou sorties, tableaux, structures, …
      - Il suffit de définir la convention
- man ioctl et cf sock_ioctl() dans net/socket.c

Virtualisation

Intérêts de la virtualisation

- Exécuter plusieurs OS en même temps
  - Jouer sous Windows et travailler sous Linux
- Placer plusieurs serveurs sur une même machine sans risquer que les pannes d'un ne gênent les autres
  - Rebooter les sous-serveurs indépendamment
- Développement et débogage
  - Débugguer ou rebooter un OS depuis un autre

Intérêts de la virtualisation (2/2)

- Facilité de déploiement pour les utilisateurs
  - Création d'image système spéciale pour s'exécuter dans une VM sans casser l'installation existante
- Permettre la gestion transparente de nouveaux périphériques
  - Il suffit qu'un OS d'une VM le supporte et l'exporte aux autres

Terminologie

- OS hôte = OS principal tournant sur machine physique
- VM = *Virtual Machine*
- OS invité = OS tournant dans VM

En pratique

- On lance une nouvelle fenêtre qui affiche la sortie de la machine virtuelle
  - Elle utilise la fenêtre comme écran !
  - Plein de périphériques virtuels
    - Carte graphique, réseau, son
    - Controleur disque = émule disque par un fichier
    - Mémoire = mémoire virtuelle du processus hôte qui exécute la machine virtuelle
    - Processeur = processeur qui exécute le processus hôte de la machine virtuelle
  - Un gestionnaire fait le lien entre ces périphériques virtuels et ceux de l'OS hôte

Différents niveaux de privilèges

- Utilisateur dans VM
  - Mode non-privilégié habituel
- Noyau dans VM
  - Privilèges noyau habituels
    - Gérés matériellement ou non, voir plus loin
  - Ne peut pas sortir de sa VM
    - Pas toucher aux périphériques, en général
- Noyau dans l'hôte
  - Privilèges intégraux
    - Peut manipuler les VM

Virtualisation totale (qemu)

- Exposition de matériel virtuel
  - Processeur, mémoire, disque, réseau, ...
- OS invité = Processus exécuté par l'OS hôte
  - Chaque instruction de la VM est émulée par l'hôte
    - Le processus de gestion de VM s'en charge
      - Très lent
  - Privilèges vérifiés à la volée pendant émulation
- N'importe quel OS invité sur n'importe quel matériel
  - Si l'OS hôte supporte le matériel réel
  - Si l'OS invité supporte le matériel virtuel

Virtualisation totale accélérée (kqemu, VirtualBox, ...)

- Les instructions « normales » n'ont pas besoin d'être émulées !
  - Exécution native beaucoup plus rapide
    - Mais seule l'architecture native est supportée
- Détecter instruction privilégiées ?
  - En mode non-privilégié, elles déclenchent une exception dans le processeur natif
    - Traitée par le pilote du gestionnaire de VM dans OS hôte
    - Instruction privilégiées vérifiées et émulées

Para-Virtualisation (Xen)

- Un *hyperviseur* (OS très simple)
  - Partage le matériel entre plusieurs OS invités
- Le premier OS invité est le maître
  - L'hyperviseur lui confie les périphériques
  - Périphériques virtuels exportés aux autres
    - Pilotes *para-virtualisés* simples, optimisés pour performance
      - Partage de pages avec le maître
- Processeur partagé pour de vrai
  - Ordonnancement simple par l'hyperviseur

Para-Virtualisation (2/2)

- OS invité appelle l'hyperviseur quand nécessaire
  - Ex : Création de VM, accès au matériel, ...
- Tous les OS invités doivent être modifiés pour parler correctement à l'hyperviseur (Hypercall)
  - Utilisation du Ring 1 intermédiaire
    - Sinon tous les appels-système doivent passer par l'hyperviseur
  - C'est pour cela que Windows ne fonctionnait pas sur Xen

Support matériel pour la virtualisation

- Supporter nativement la gestion des VMs
  - Pas d'exception dans l'hôte en cas d'instruction privilégiée invitée
  - Intégrer l'hyperviseur dans le matériel
- Nouvelles instructions de gestion de VM
  - Intel VT-x, AMD-V, ...
    - Registres pour tables de pages hôte et invité, ...
  - Pas besoin de Ring 1
    - Le matériel gère alternance entre mode VM (restreint) et mode normal
- Utilisé par toutes les solutions modernes de virtualisation

Support matériel pour la virtualisation (2/3)

- Lancement de VM sur x86 VT-x
  - L'hôte décrit un OS invité dans structure dédiée en mémoire (VMCS)
  - VMLaunch (ou VMResume) passe la main à OS invité specifié dans VMCS
    - Exécution de l'invité « pendant » VMLaunch ou VMResume
      - En fait, le processeur fait un super-changement de contexte VM en dessous
        - Et il se rappelle dans quel mode il est

Support matériel pour la virtualisation (3/3)

- Gestion des VM sur x86 VT-x
  - En cas d'instruction privilégiée (au sens des VM)
    - Exemple : Accès au VMCS (seul l'hôte peut)
    - Le processeur vérifie si la VM courante a les privilèges nécessaires
    - Si non (OS invité), le processeur sort de l'invité et retourne dans l'hôte (*VM Exit*)
    - L'OS hôte traite la requête puis relance l'invité
      - Equivalent d'un hypercall si l'accès était valide
      - Plus besoin d'hypercalls
        - Plus besoin de modifier l'OS invité !

Virtualisation des périphériques

- Seul le processeur est vraiment partagé entre les OS para-virtualisés
  - L'accès aux périphériques reste assez lent
    - Seul le maître y a un accès direct
- Si le périphérique n'est pas partagé, l'hyperviseur peut le confier directement à un autre OS (*PCI Pass-Through*)
  - Problème de protection
    - Ex: DMA vers la mémoire des autres OS?
  - Solution: support matériel dans le chipset PCI
    - Intel VT-d

Et les containers ?

- LXC, Docker, ...
- Isolation purement logicielle
  - Les processus sont répartis dans différents containers qui disposent de différentes ressources et différents droits
    - chroot, control group, namespaces, ...
- Peu de surcout
- Moins de protection ?
  - Plus facile de s'échapper d'un container que d'une VM ?