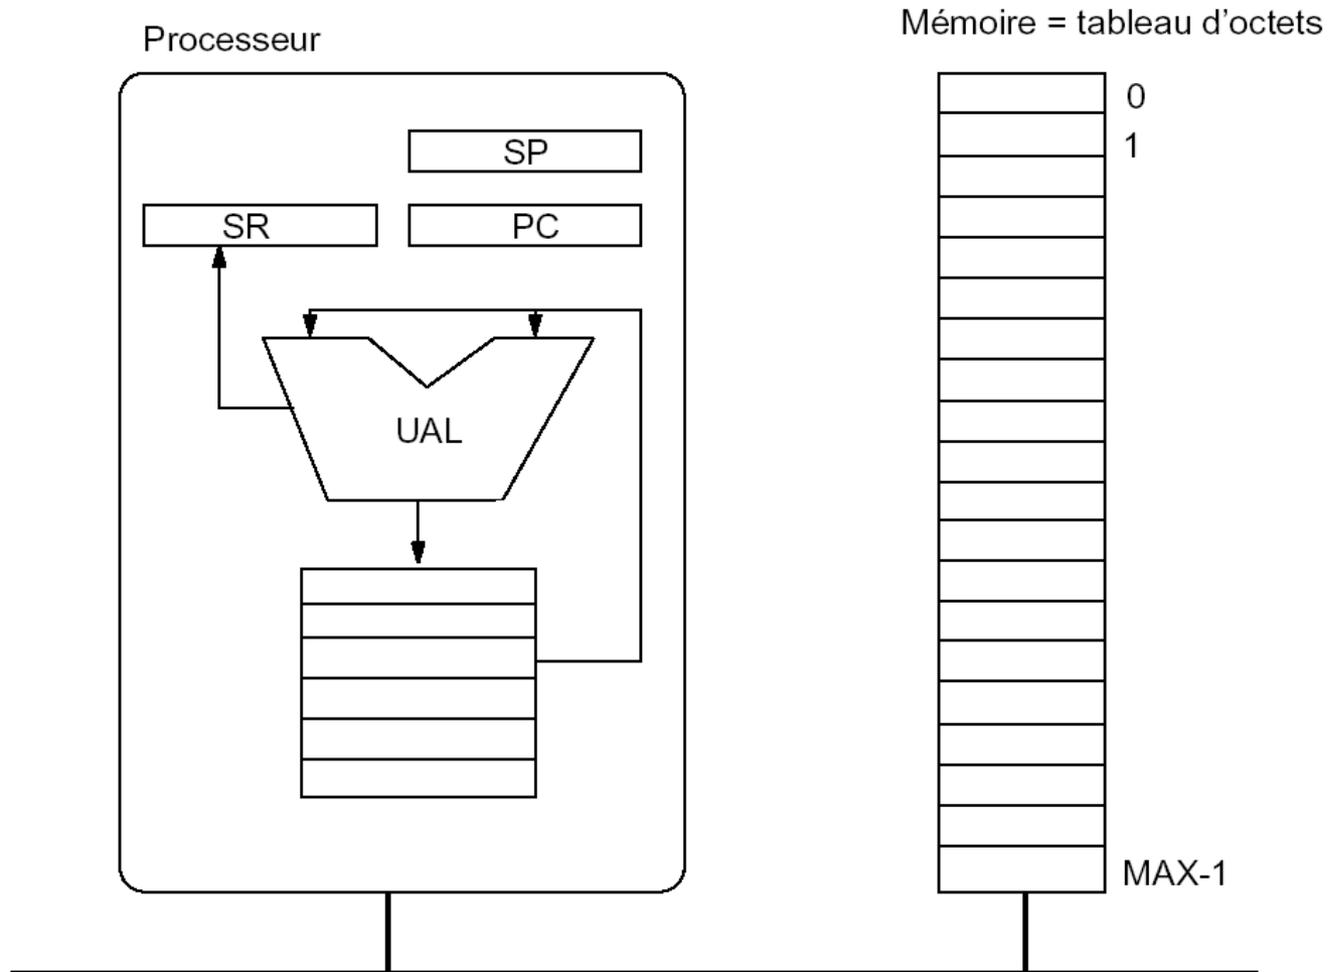


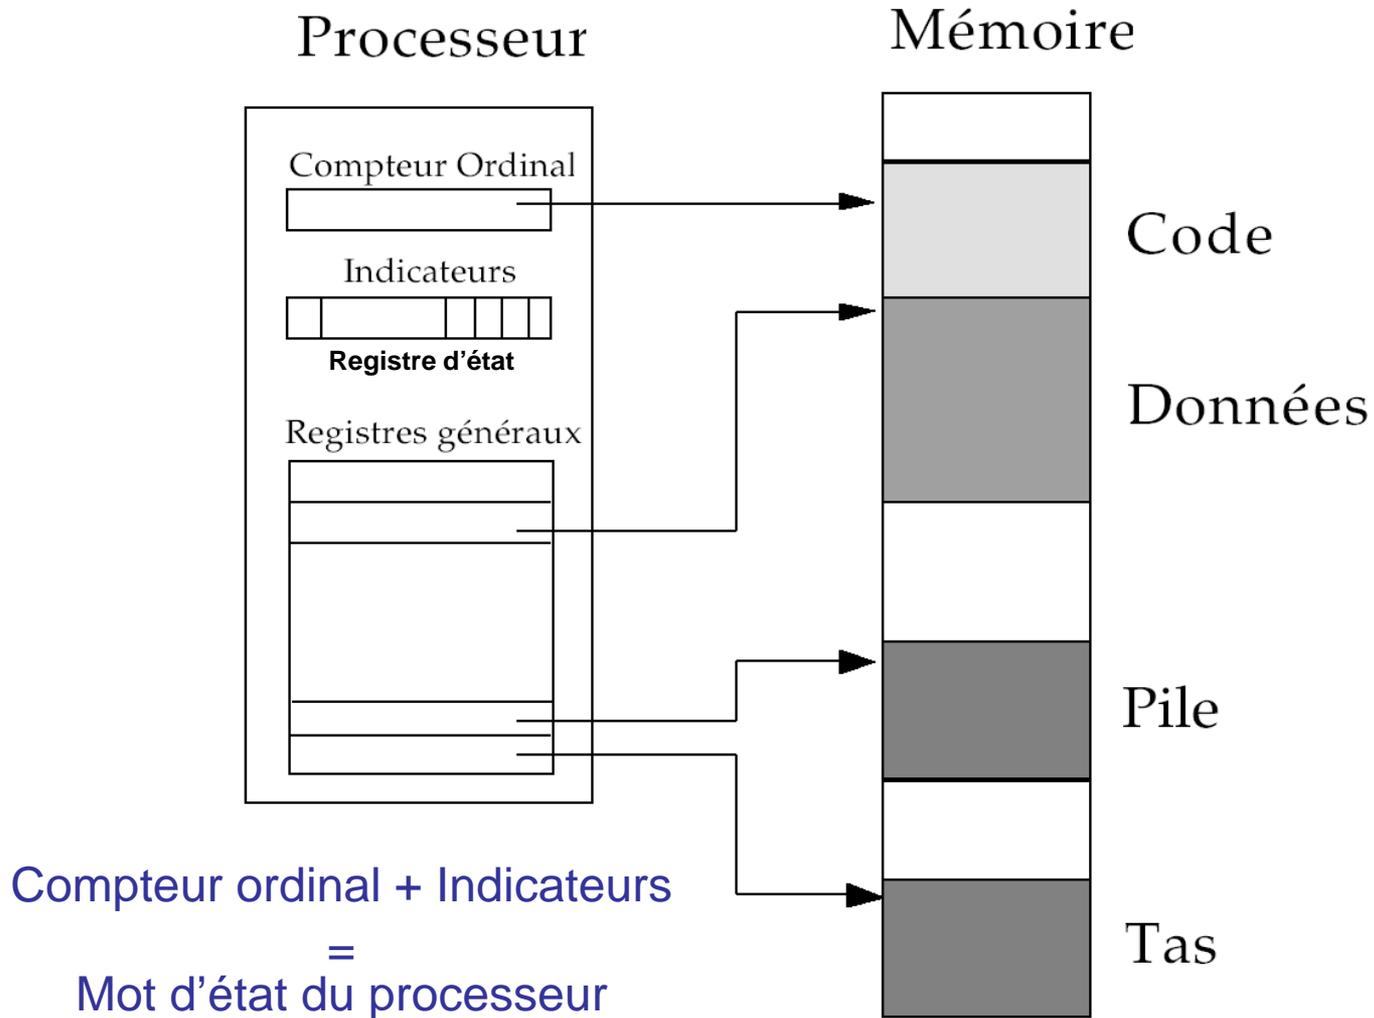
# Mécanismes d'exécution

Gestion de processus

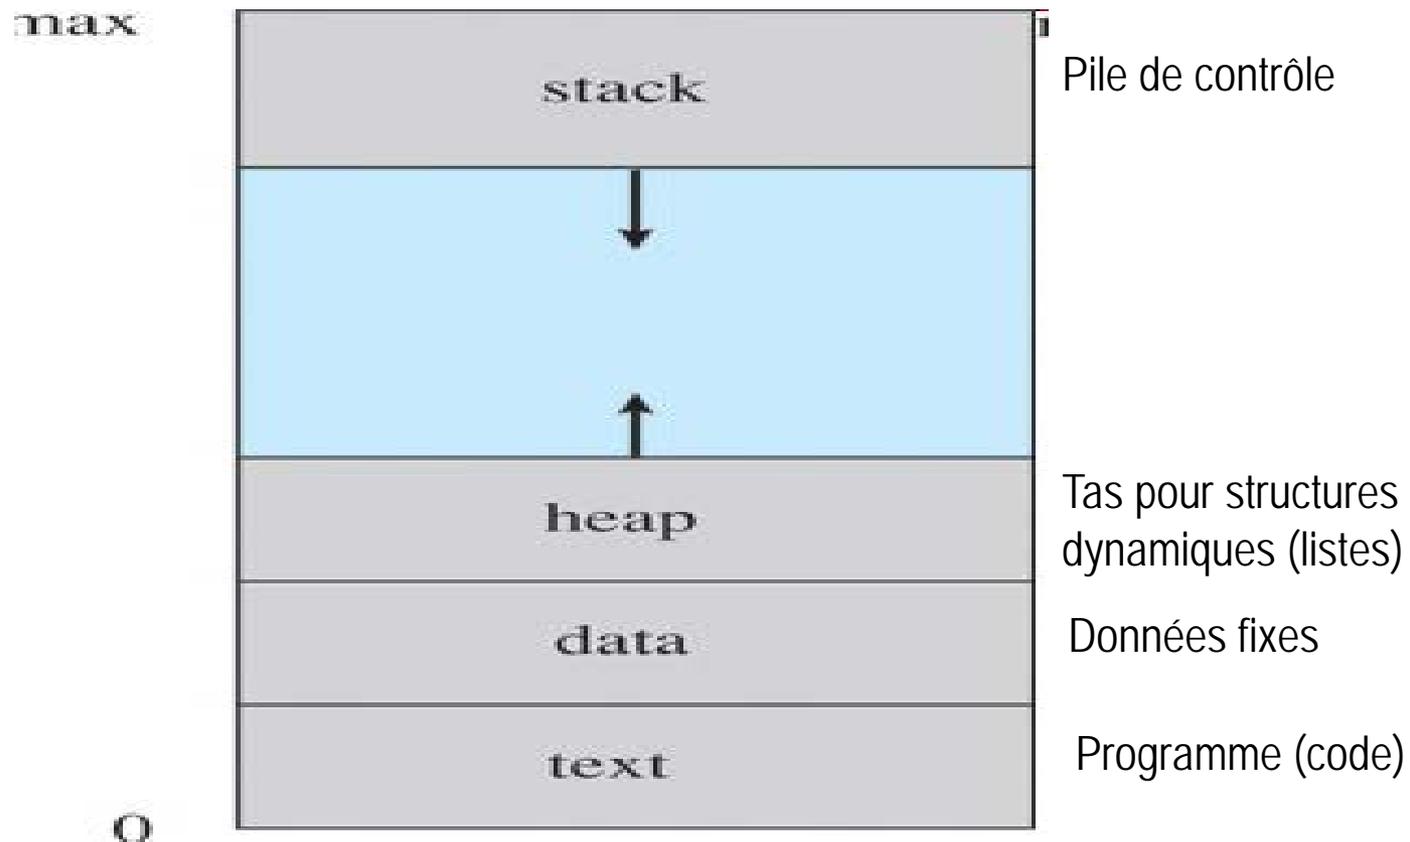
# Mémoire et Processeur



# Modèle d'exécution d'une tâche

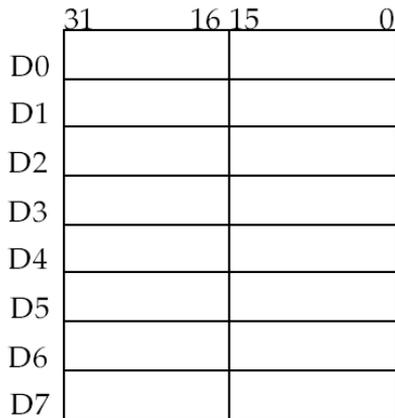


# Configuration typique de mémoire pour une tâche

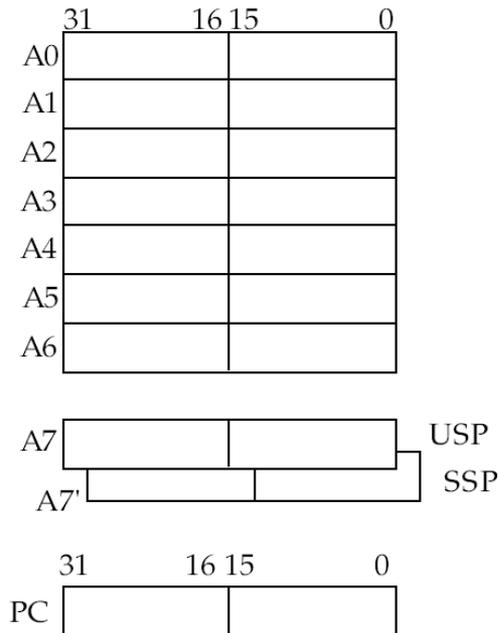


# Exemple : le Motorola 68000

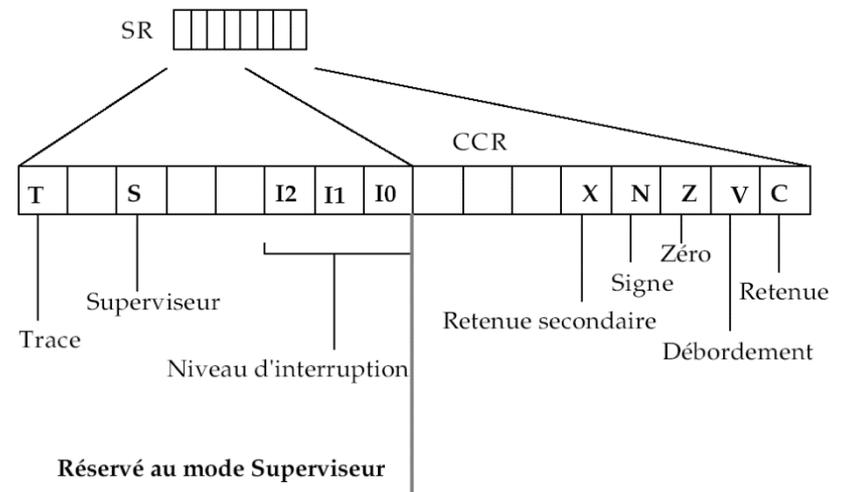
Registres de donnée



Registres d'adresse

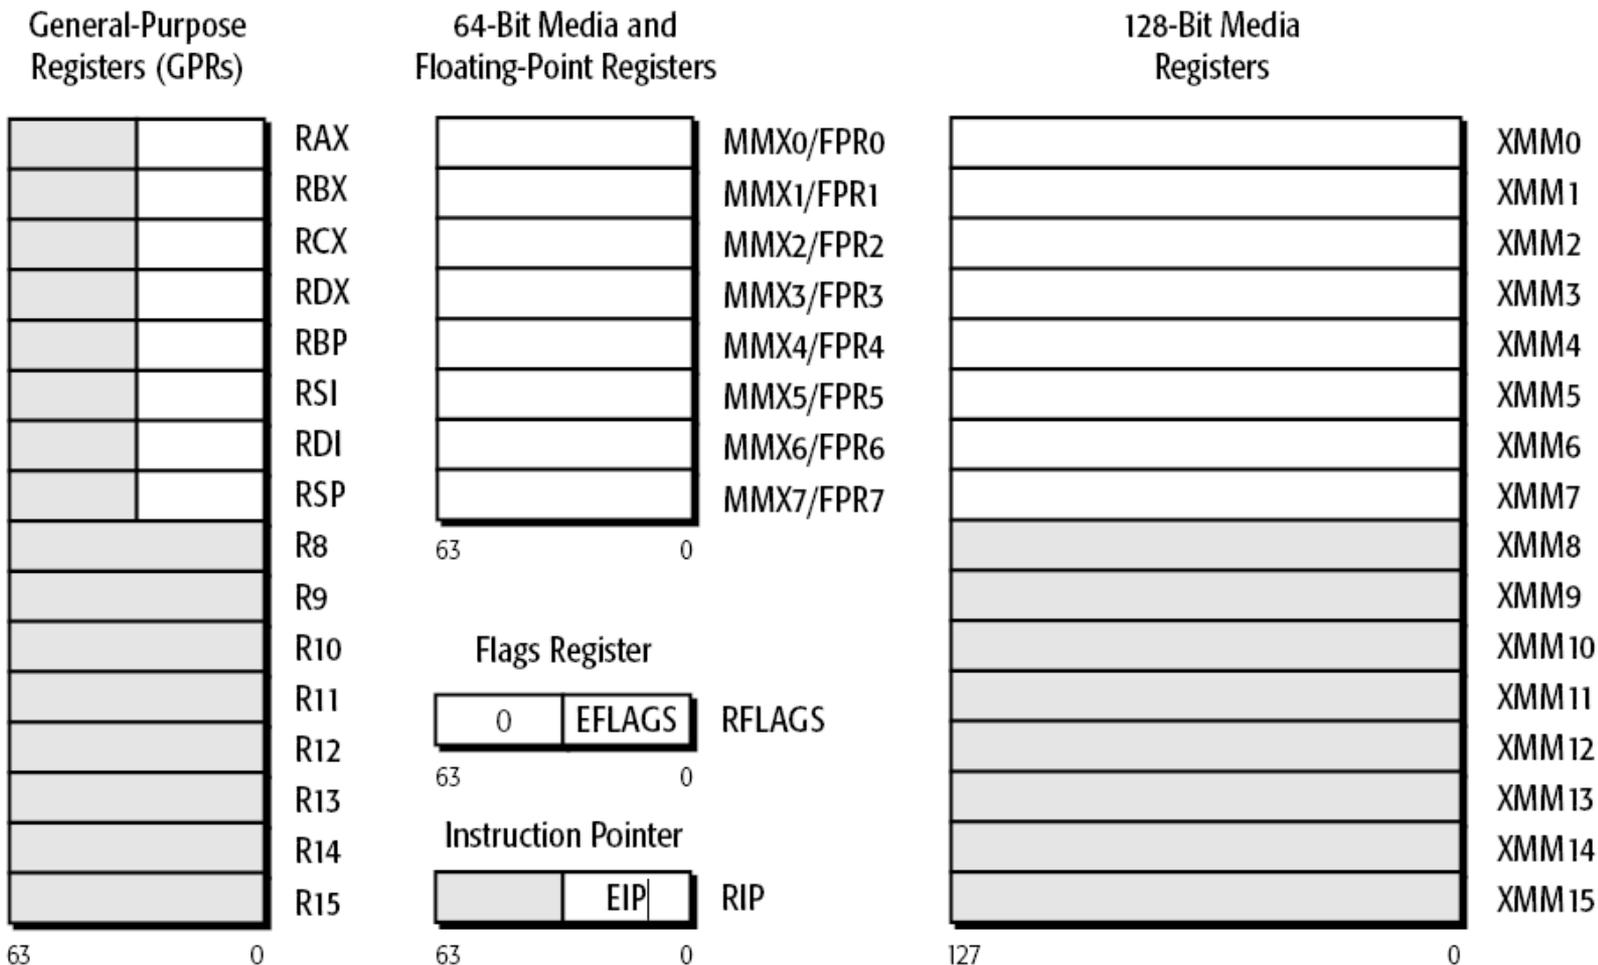


Registre d'état



L'ensemble des valeurs des registres pour un processus donné est appelé le **contexte** du processus.

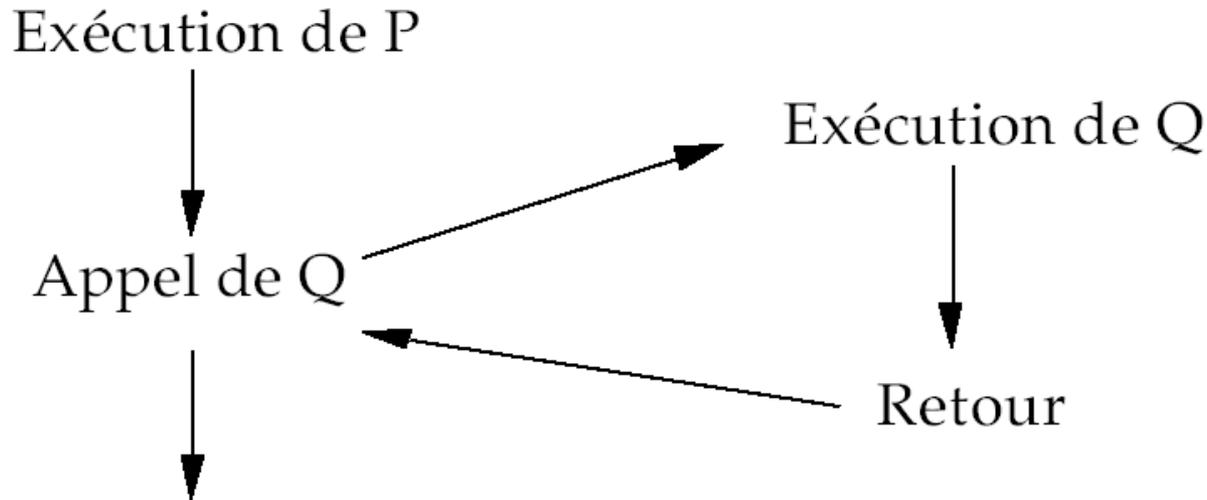
# Exemple de processeur 64 bits



Legacy x86 registers, supported in all modes  
 Register extensions, supported in 64-bit mode

Application-programming registers also include the 128-bit media control-and-status register and the x87 tag-word, control-word, and status-word registers

# Appel et retour de procédure



## Séquence d'appel

Préparation des paramètres transmis à Q

Sauvegarde du contexte de P

Remplacement du contexte de P par le contexte de Q

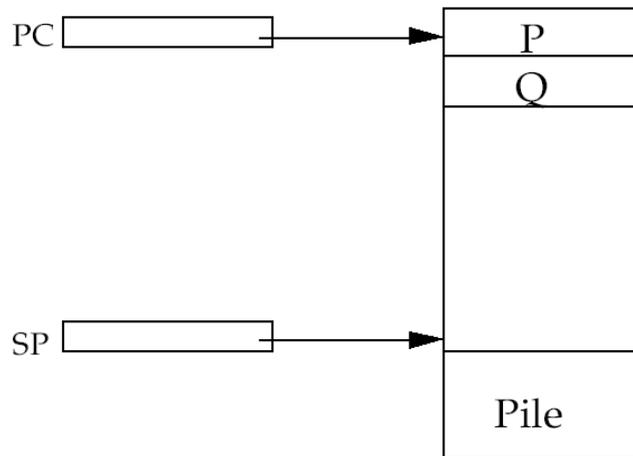
## Retour

Préparation des résultats transmis par Q

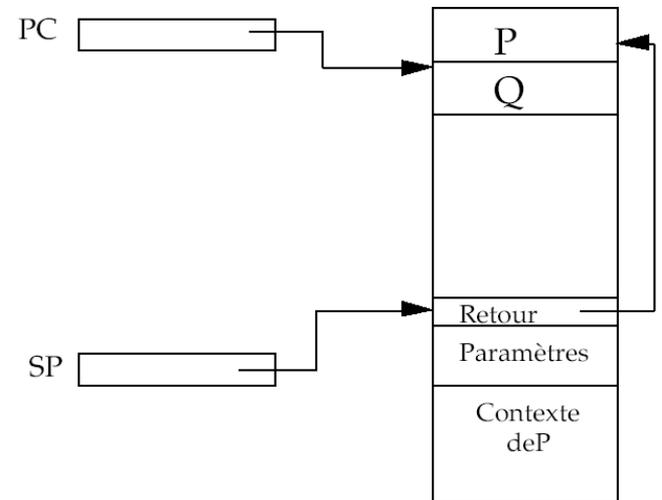
Restauration du contexte de P avant l'appel

# Réalisation avec une pile

État avant l'appel

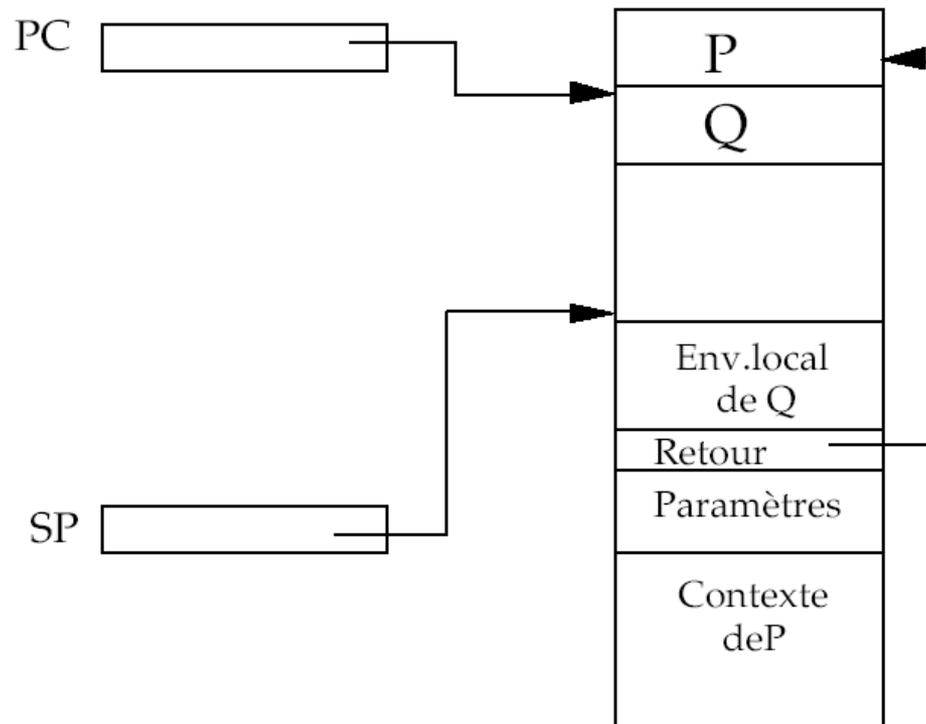


P : Préparation des paramètres et commutation

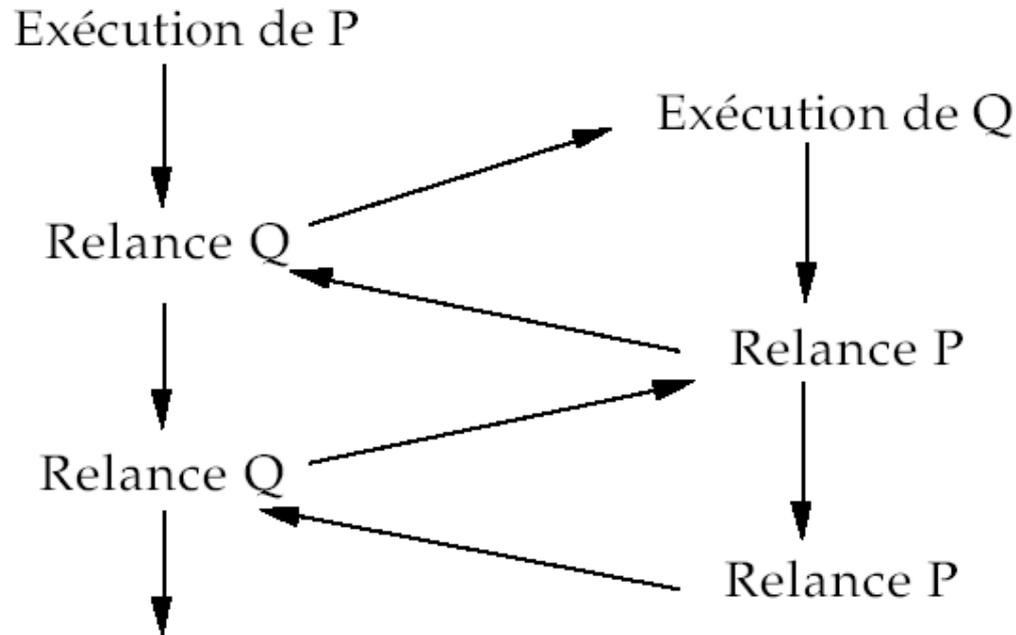


# Réalisation avec une pile

Q : préparation de l'environnement local



# Fonctionnement en co-routines



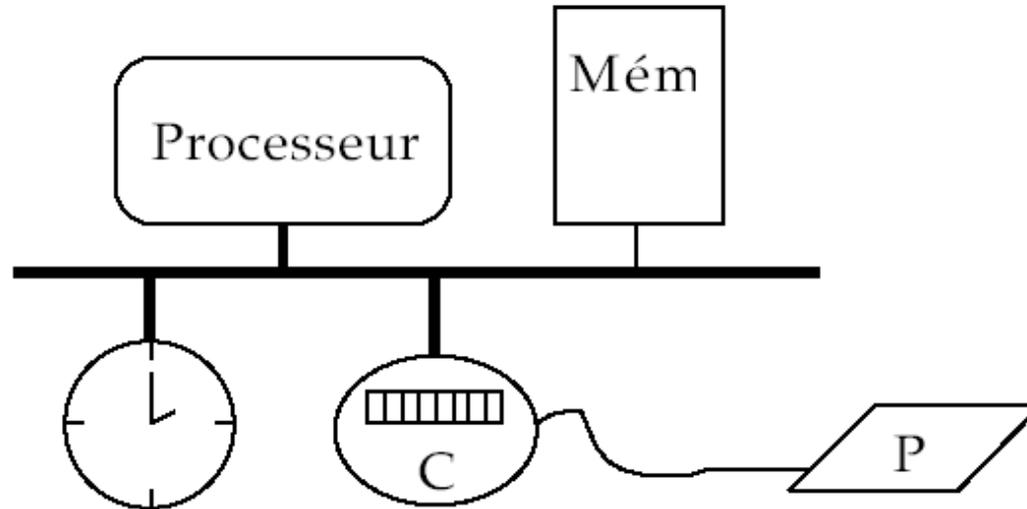
**Relance (Resume) = Séquence d'appel**

- Préparation des paramètres transmis
- Sauvegarde du contexte courant
- Remplacement de l'ancien contexte par le nouveau

**Réalisations**

- Avec une pile ?
- Avec contexte global

# Activités synchrones



Entrées/Sorties par canal, Horloge,  
Intervention externe, Traitement d'erreur

—▶ Nécessité de pouvoir interrompre le processeur

# Activités synchrones

## Mécanismes d'exception

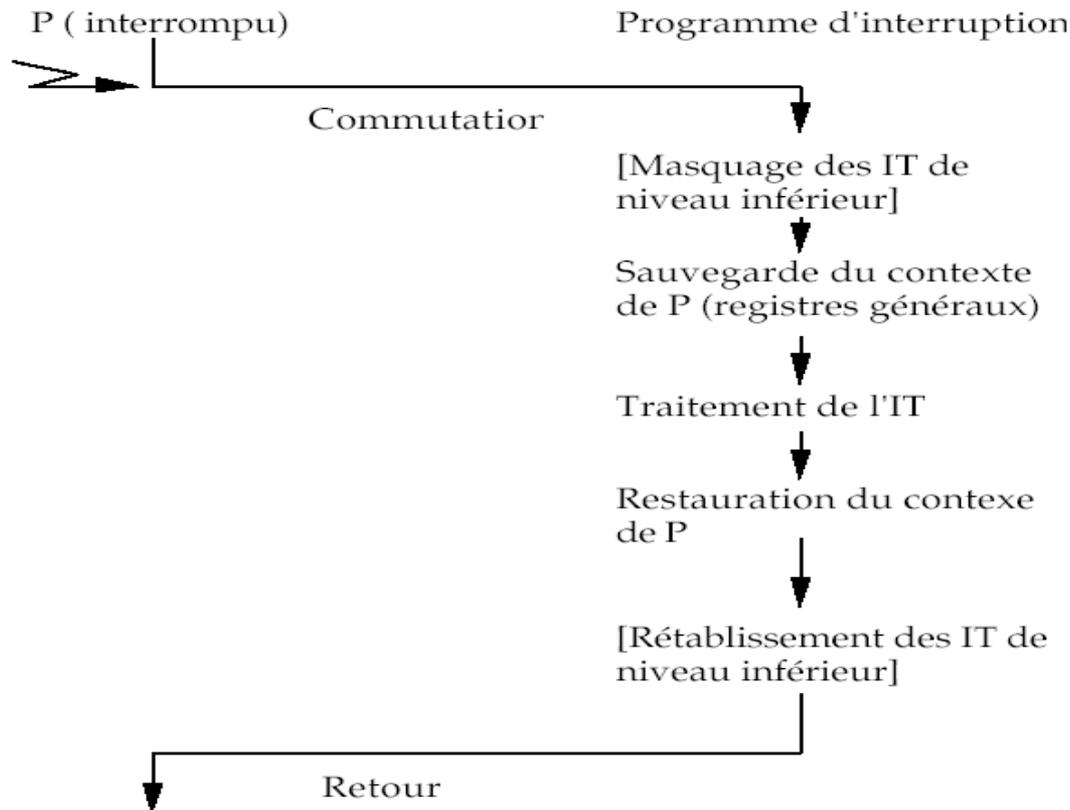
Mécanisme	Cause	Utilisation
Interruption	Extérieure à l'instruction en cours	Réaction à un événement externe (E/S, horloge, sécurité)
Déroutement	Déclenché par l'instruction en cours	Traitement d'erreurs (débordement, division par 0, instruction illégale)
Appel au superviseur	Exception voulue, programmée	Appel d'une fonction du système d'exploitation (passage en mode privilégié)

# Commutation de contexte en cas d'exception

- Principe
  - Sauvegarde du mot d'état du programme et des registres
  - Chargement d'un mot d'état et de registres à partir d'un emplacement spécifié
- 2 méthodes pour la sauvegarde
  - Emplacements fixes
  - Pile

# Interruptions

- En général plusieurs niveaux (priorités)
- Masquables
- Schéma d'un programme d'interruption :



# Déroutements et appels au superviseur

## Déroutements

Données incorrectes (débordement, division par 0)

Violation de protection (de la mémoire, du mode privilégié)

Instruction non-exécutable (code inconnu, erreur d'adresse,...)

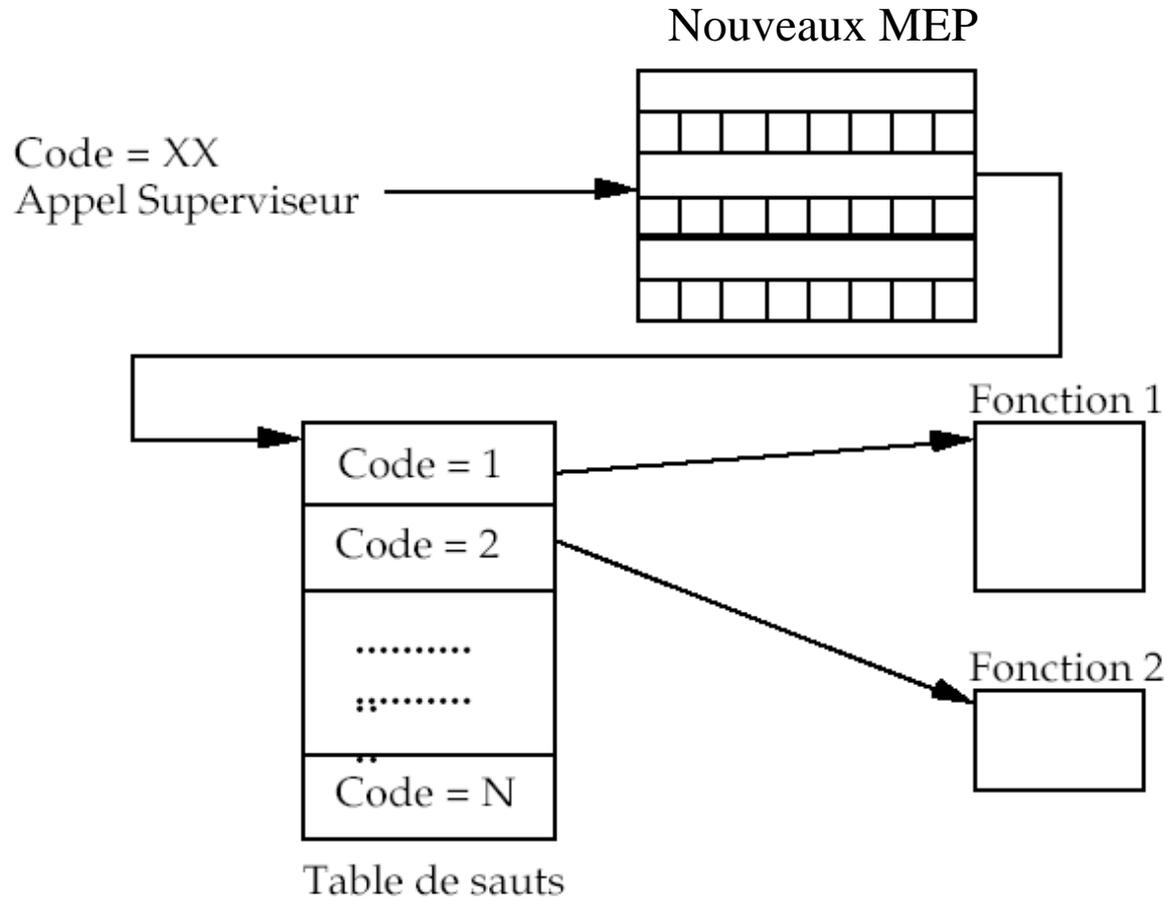
## Appels au superviseur

Comme un appel de procédure mais avec des droits étendus (mode privilégié, IT masquées, droits d'accès)

Appel aux fonctions du système

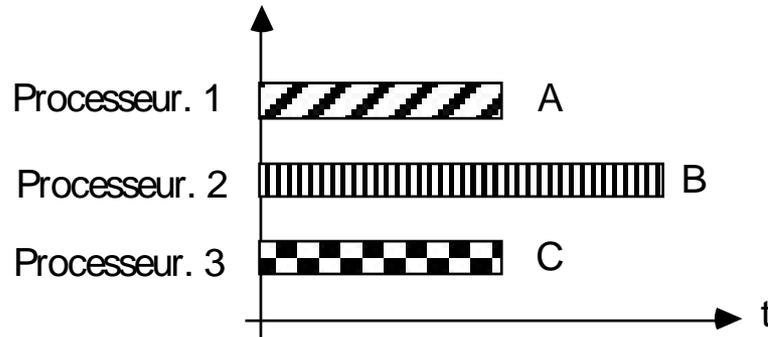
# Déroutements et appels au superviseur

Appel aux fonctions du système

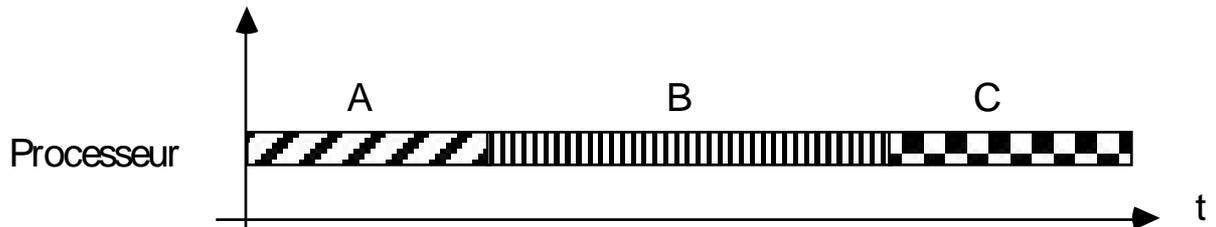


# Le Multitâches

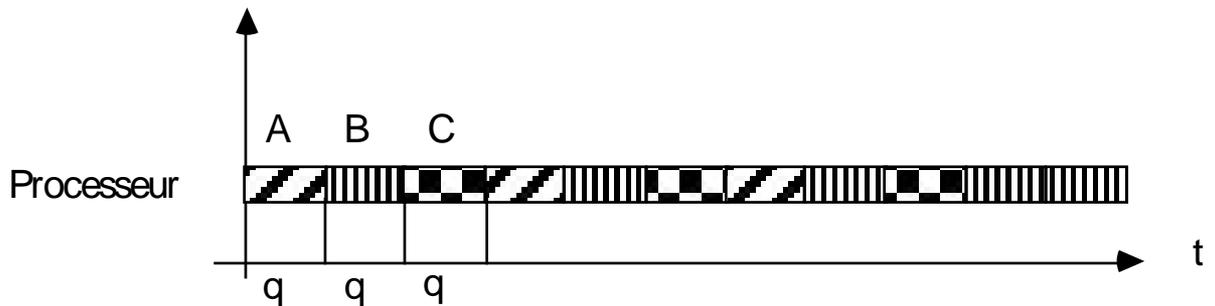
- Système multiprocesseurs



- Système Monoprocesseur, monotâche



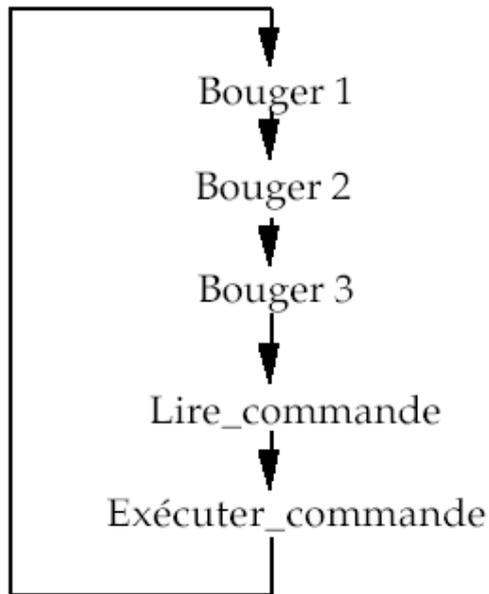
- Système Monoprocesseur, multi-tâches



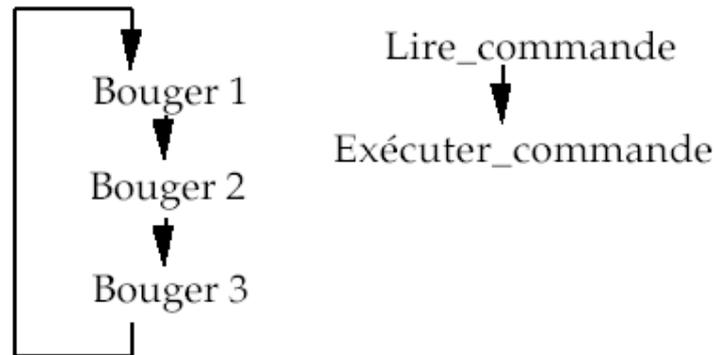
# Exemples : jeux vidéos

Monotâche avec interruptions

Monotâche

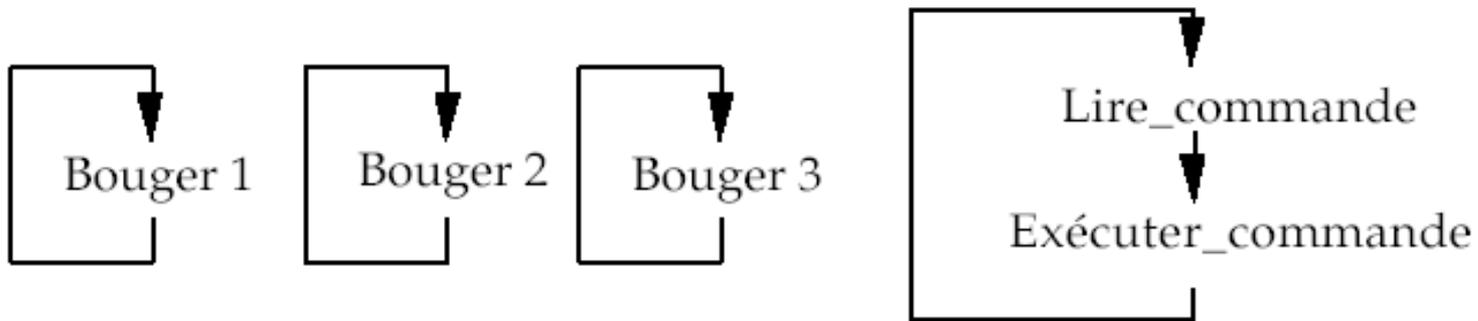


tâche principale/interruptions



# Exemples : jeux vidéos

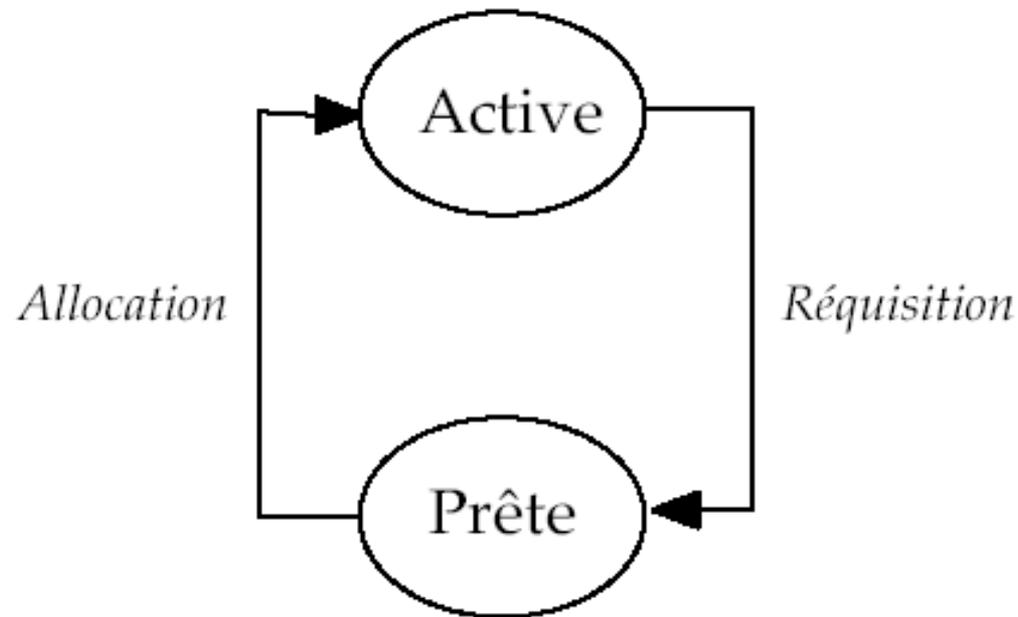
## Multi-tâches



**Souplesse**  
**Partage du code**

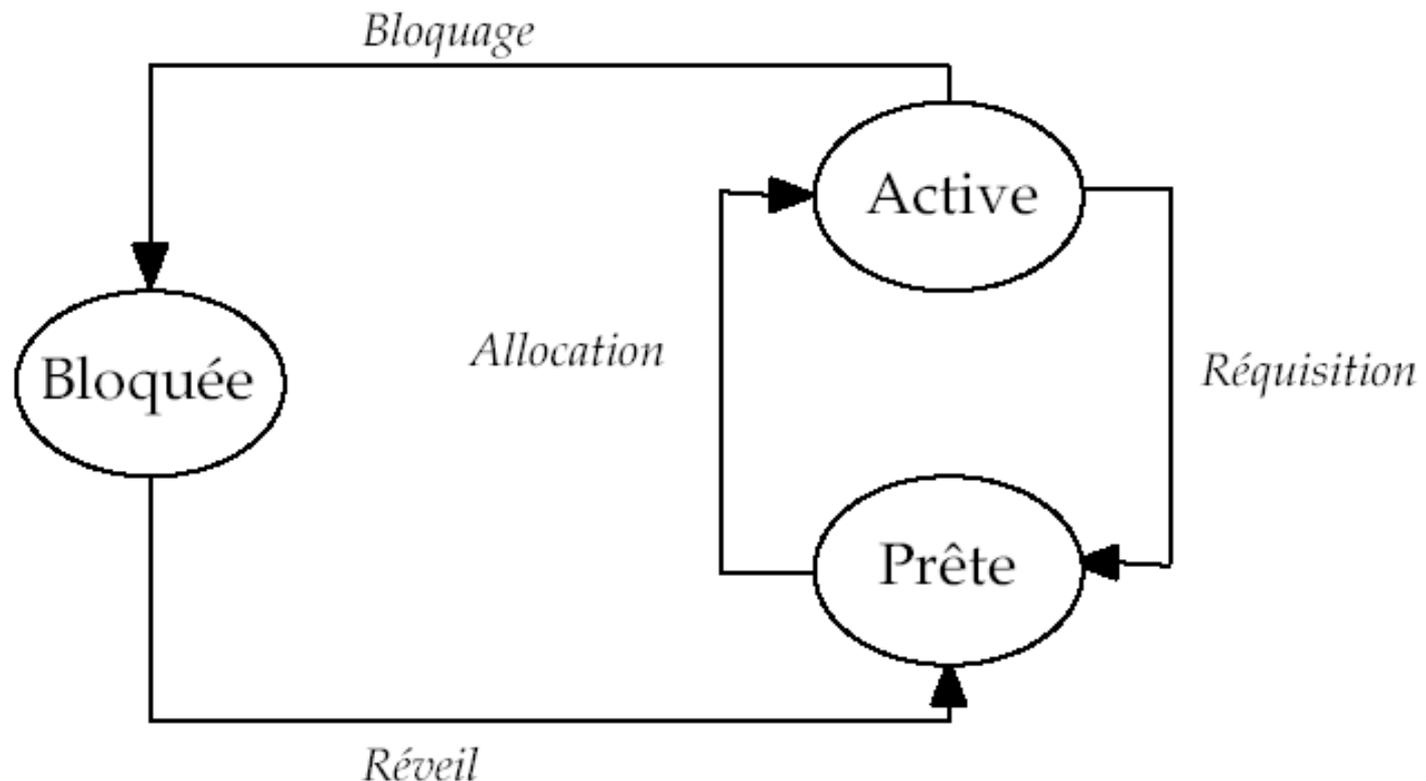
# États d'une tâche

Contexte mono-processeur : une tâche active à la fois



# États d'une tâche

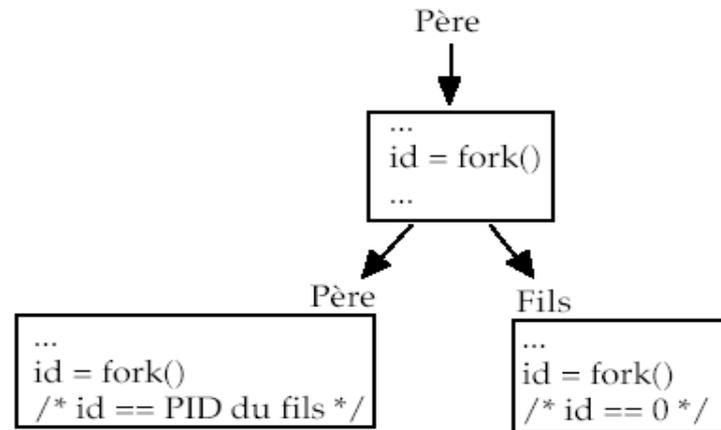
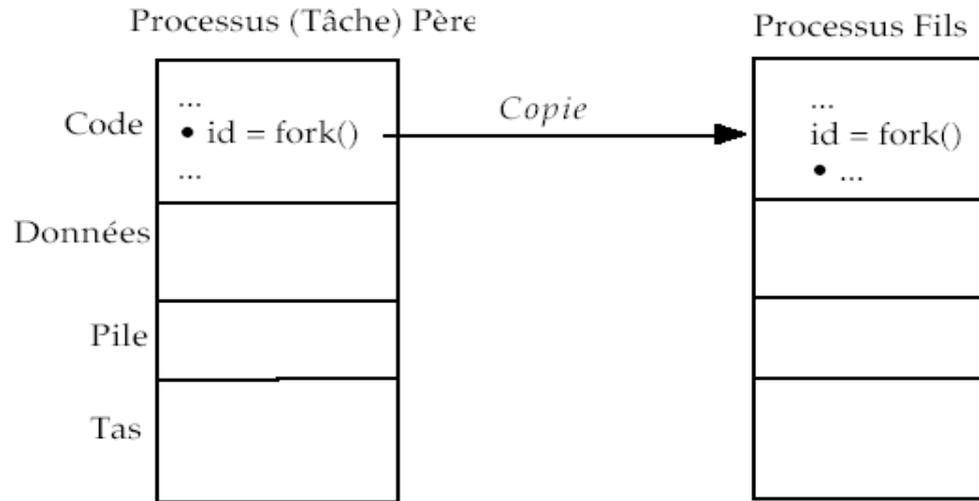
Mais une tâche peut être bloquée en attente d'une E/S



# Tâche = Processus

- **Processus: un programme en cours d'exécution**
  - Possède des ressources de mémoire, périphériques, etc.
- Les processus peuvent créer d'autres processus, formant une hiérarchie
  - Par copie (instruction fork ou équivalente)
  - Par chargement depuis un support
- Sous UNIX chaque commande engendre la création d'un processus

# Création d'une tâche sous UNIX



# Exemple de programme C avec fork

```
/* -----  
 * Schéma de création de processus.  
 * Création d'un processus fils et test pour exécuter un code différent  
 * dans le père et dans le fils.  
 */  
#include <stdio.h>           /* Pour perror */  
#include <stdlib.h>         /* Pour exit */  
#include <unistd.h>         /* Pour fork, getpid, getppid, sleep */  
#include <sys/types.h>      /* Pour pid_t (fork, getpid, getppid) */  
#include <sys/wait.h>       /* Pour wait */  
int main(void)  
{  
    pid_t ident;  
    ident = fork();  
    if (ident == -1) { perror("fork"); return EXIT_FAILURE; } // pb système  
    /* A partir de cette ligne, il y deux processus */  
    printf("Cette ligne sera affichée deux fois\n");  
    if (ident == 0)  
    {  
        /* Code exécuté uniquement par le fils */  
        printf("Je suis le fils\n");  
    }  
    else  
    {  
        /* Code exécuté uniquement par le pere */  
        printf("Je suis le père\n");  
    }  
    return EXIT_SUCCESS;  
}
```

# Exemple de programme C avec fork

```
/* -----  
 * Schéma de création de processus.  
 * Création d'un processus fils et test pour exécuter un code différent  
 * dans le père et dans le fils.  
 */  
#include <stdio.h>           /* Pour perror */  
#include <stdlib.h>          /* Pour exit */  
#include <unistd.h>          /* Pour fork, getpid, getppid, sleep */  
#include <sys/types.h>       /* Pour pid_t (fork, getpid, getppid) */  
#include <sys/wait.h>        /* Pour wait */  
int main(void)  
{  
    pid_t ident;  
    ident = fork();  
    if (ident == -1) { perror("fork"); return EXIT_FAILURE; } // pb système  
    /* A partir de cette ligne, il y deux processus */  
    printf("Cette ligne sera affichée deux fois\n");  
    if (ident == 0)  
    {  
        /* Code exécuté uniquement par le fils */  
        sleep(2); /* le fils dort pendant 2 secondes */  
        printf("Je suis le fils\n");  
    }  
    else  
    {  
        /* Code exécuté uniquement par le pere */  
        printf("Je suis le père\n");  
    }  
    return EXIT_SUCCESS;  
}
```

# Exemple de programme C avec fork

```
/* -----  
 * Schéma de création de processus.  
 * Création d'un processus fils et test pour exécuter un code différent  
 * dans le père et dans le fils.  
 */  
#include <stdio.h> /* Pour perror */  
#include <stdlib.h> /* Pour exit */  
#include <unistd.h> /* Pour fork, getpid, getppid, sleep */  
#include <sys/types.h> /* Pour pid_t (fork, getpid, getppid) */  
#include <sys/wait.h> /* Pour wait */  
int main(void)  
{  
    pid_t ident;  
    ident = fork();  
    if (ident == -1)  
    {  
        perror("fork");  
        return EXIT_FAILURE;  
    }  
    /* A partir de cette ligne, il y deux processus */  
    printf("Cette ligne sera affichée deux fois\n");  
    if (ident == 0)  
    {  
        /* Code exécuté uniquement par le fils */  
        sleep(2); /* le fils dort pendant 2 secondes */  
        printf("Je suis le fils\n");  
    }  
    else  
    {  
        /* Code exécuté uniquement par le pere */  
        ident = wait(NULL); /* le père attend la fin de l'un de ses fils */  
        printf("Je suis le père, mon fils %i est terminé\n" , ident);  
    }  
    return EXIT_SUCCESS;  
}
```

# Terminaison de processus

- Un processus exécute sa dernière instruction
  - pourrait passer des données à son parent
  - ses ressources lui sont enlevées
- Le processus parent termine l'exécution d'un fils pour raisons différentes
  - le fils a dépassé ses ressources disponibles
  - le fils n'est plus requis
- Le parent peut être le Système d'Exploitation

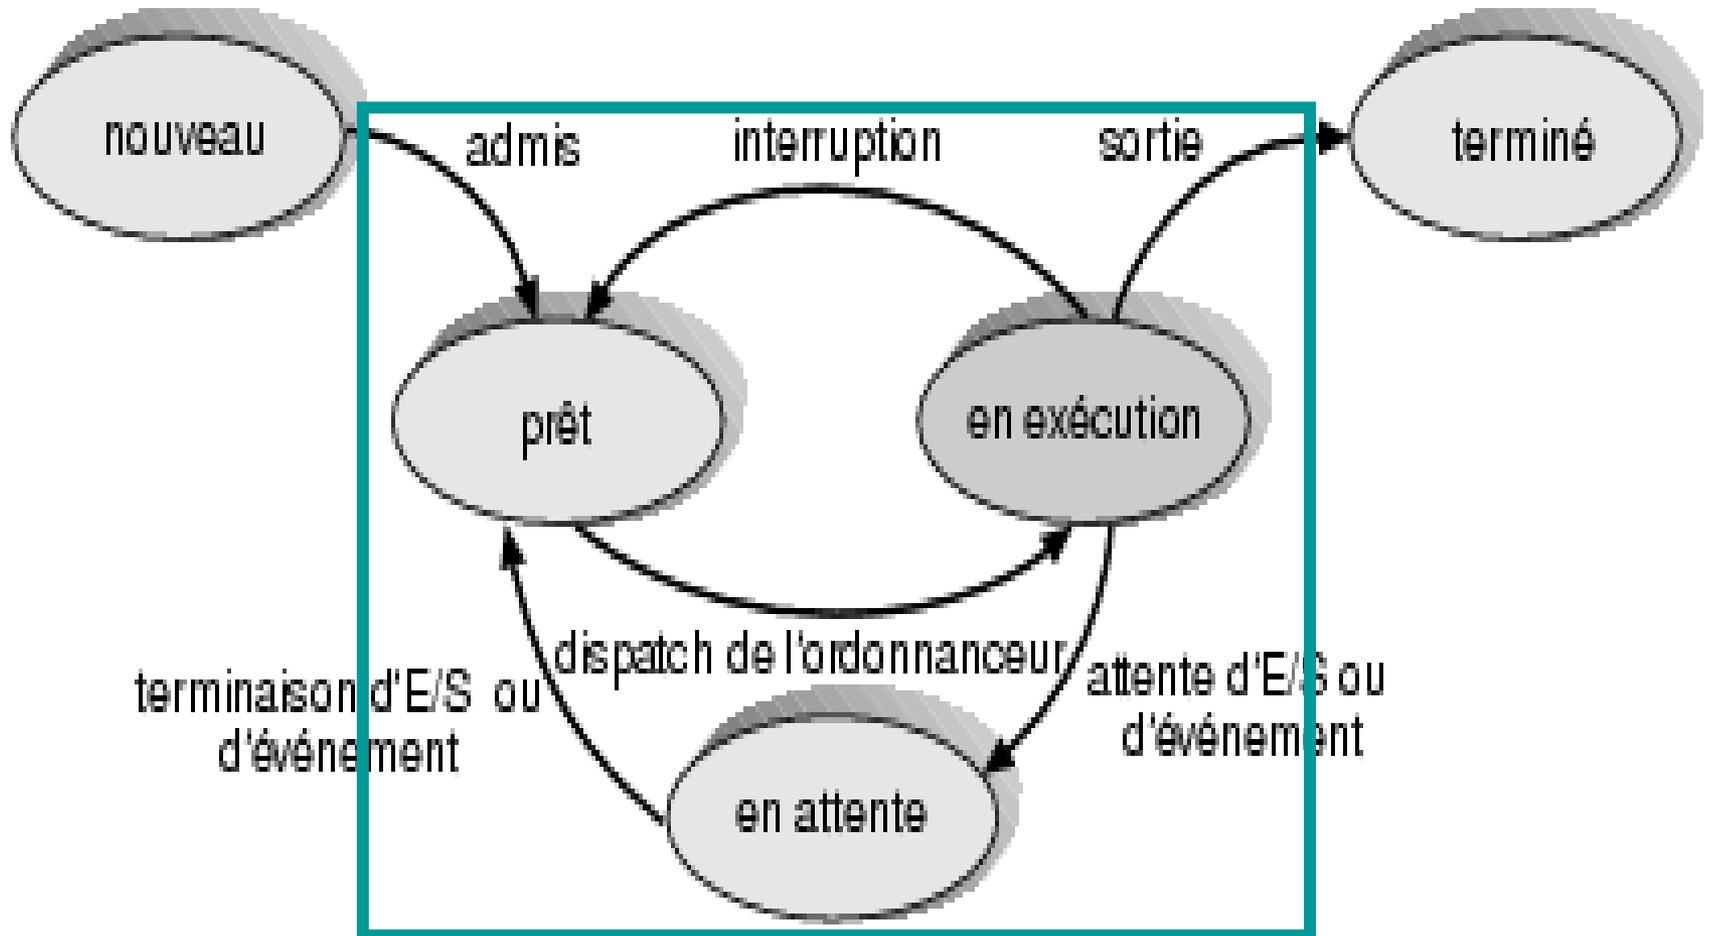
# États d'un processus

- Au fur et à mesure qu'un processus s'exécute, il change d'état :
  - nouveau: le processus vient d'être créé
  - exécutant-running: le processus est en train d'être exécuté par l'UC
  - attente-waiting: le processus est en train d'attendre un événement (p.ex. la fin d'une opération d'E/S)
  - prêt-ready: le processus est en attente d'être exécuté par l'UC
  - terminé: fin d'exécution

# Ordonnanceur de l'UC

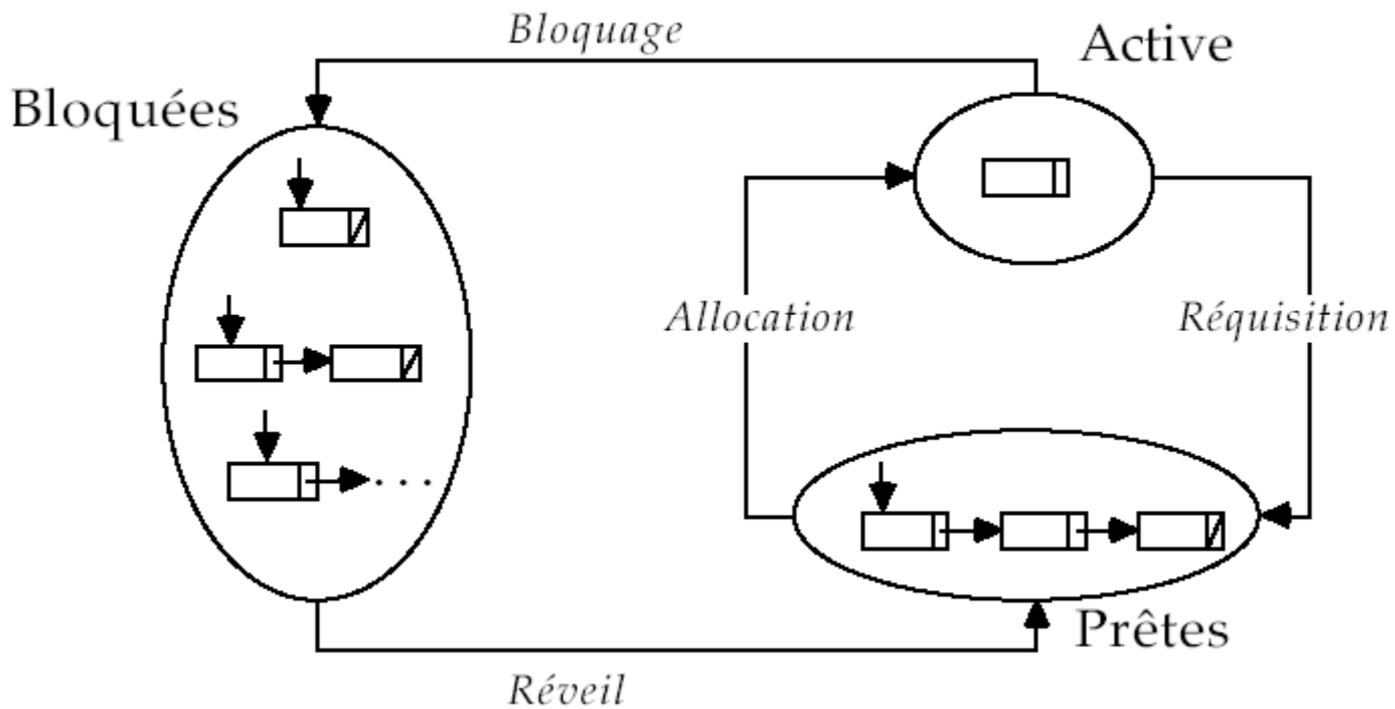
- Une UC est une ressource qui peut être affectée tantôt à un processus, tantôt à un autre
- Quand une UC se libère, un programme est invoqué qui décide quel processus lui sera affecté
- Ce programme est parfois appelé *gestionnaire de tâches*, scheduler en anglais
- Nous l'appellerons l'ordonnanceur

# Diagramme de transition d'états d'un processus



# Gestion du processeur

## États d'une tâche, Files d'attente



# Gestion du processeur

## Ordonnanceur (*scheduler*)

Ensemble des algorithmes utilisés pour faire les transitions entre tâches.

## Distributeur (*dispatcher*)

Plus particulièrement chargé de l'allocation.

## Politique (ou stratégie) d'ordonnancement

Préemptif ou non préemptif

Lié à la gestion des files d'attente

# Stratégies d'ordonnancement

Temps partagé	Temps réel
<p>Rendre le système agréable à utiliser :</p> <ul style="list-style-type: none"> <li>• tâches interactives</li> <li>• algorithmes complexes, avec vieillissement des priorités, régulation de la charge</li> </ul>	<p>Le système doit être efficace et sûr :</p> <ul style="list-style-type: none"> <li>• hiérarchie de tâches (priorités)</li> <li>• souplesse (adaptation à de nombreuses applications, même très contraintes)</li> </ul>

Non préemptif	Préemptif
<p>Exécution de la tâche courante jusqu'à appel du noyau ou interruption externe</p> <p>Le noyau décide ou non de commuter la tâche active</p> <ul style="list-style-type: none"> <li>↗ Facile à réaliser</li> <li>↘ Peu fiable</li> <li>↗ Très bon rendement</li> </ul>	<p>La tâche est de toute façon interrompue en fin de quantum</p> <p>Commutation en fonction des priorités</p> <ul style="list-style-type: none"> <li>↘ Plus difficile à réaliser</li> <li>↗ Plus fiable</li> <li>↗ Meilleure prise en compte des tâches prioritaires</li> <li>↘ Rendement affaibli</li> </ul>

# Temps de latence aux interruptions

Durée maximum pendant laquelle les interruptions sont masquées.  
Critère important des applications temps réel à cause des tâches de sécurité.

Unix : temps de commutation  $\pm 1\text{ms}$ , temps de latence non précisé

Noyau temps réel : temps de commutation 40 à 250  $\mu\text{s}$ , temps de latence inférieur à 100 $\mu\text{s}$

# Critères de qualité de l'ordonnancement

**Efficacité/Rendement** : le maximum de temps doit être consacré à l'application

**Temps de réponse** : le plus faible possible (lié au temps de latence)

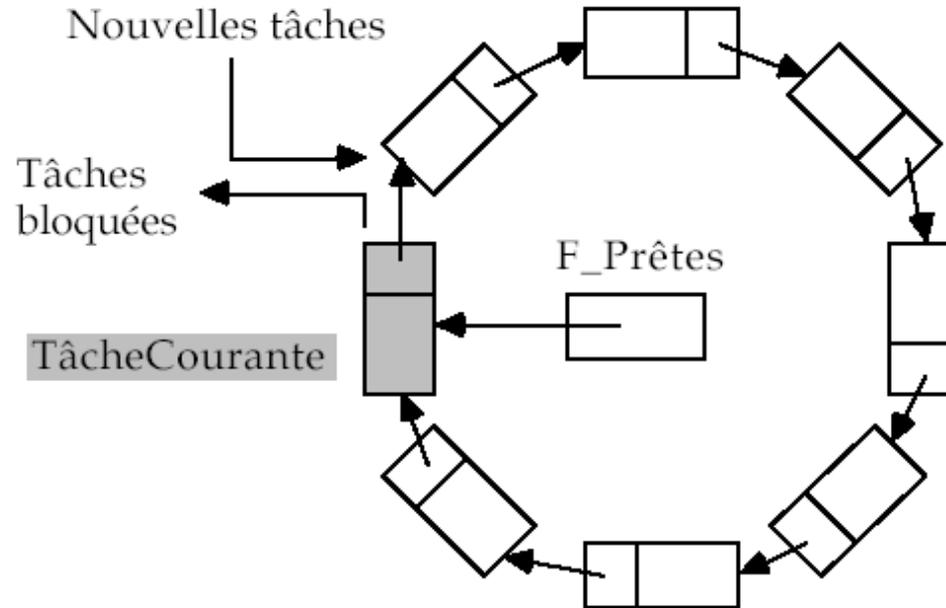
**Impartialité** : partage équitable entre tâches

**Débit** : le plus de tâches possibles dans un temps donné

# Tourniquet :

## ordonnancement circulaire sans priorité

La file des tâches prêtes est circulaire et gérée en FIFO.

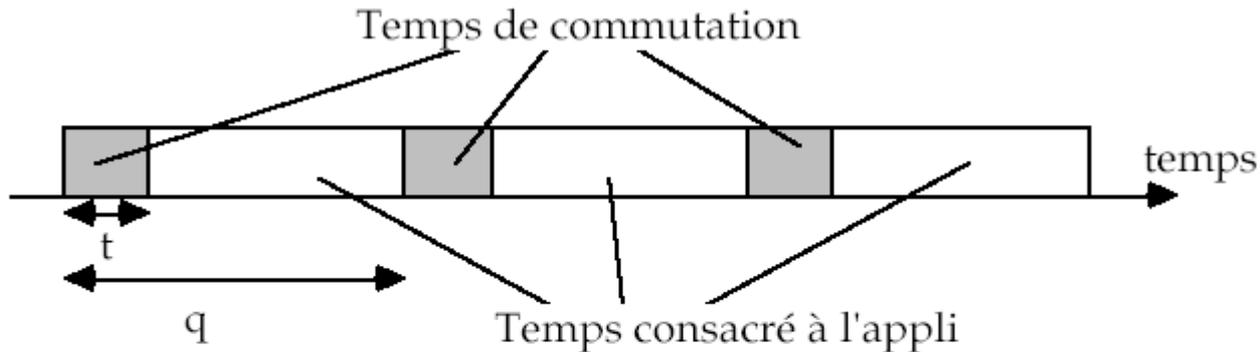


Sans réquisition : très efficace s'il y a peu de tâches qui se bloquent souvent (E/S)

Avec réquisition : c'est une méthode impartiale pour les tâches de même priorité.

# Tourniquet : choix du quantum

Compromis entre débit et efficacité



$$\text{Efficacité } E = \frac{q - t}{q} = \text{rapport } \frac{\text{temps consacré à l'appli}}{\text{temps total}}$$

Exemple :  $t = 1\text{ms}$

$$E = 0.8 \text{ si } q = 5\text{ms}$$

$$E = 0.98 \text{ si } q = 50\text{ms}$$

$$\text{Débit } D = \frac{1}{q} = \text{nombre de tâches traitées par seconde}$$

Exemple :

$$D = 200 \text{ si } q = 5\text{ms}$$

$$D = 20 \text{ si } q = 50\text{ms}$$

Meilleur débit = meilleur temps de réaction

Meilleure efficacité = temps total d'exécution plus court

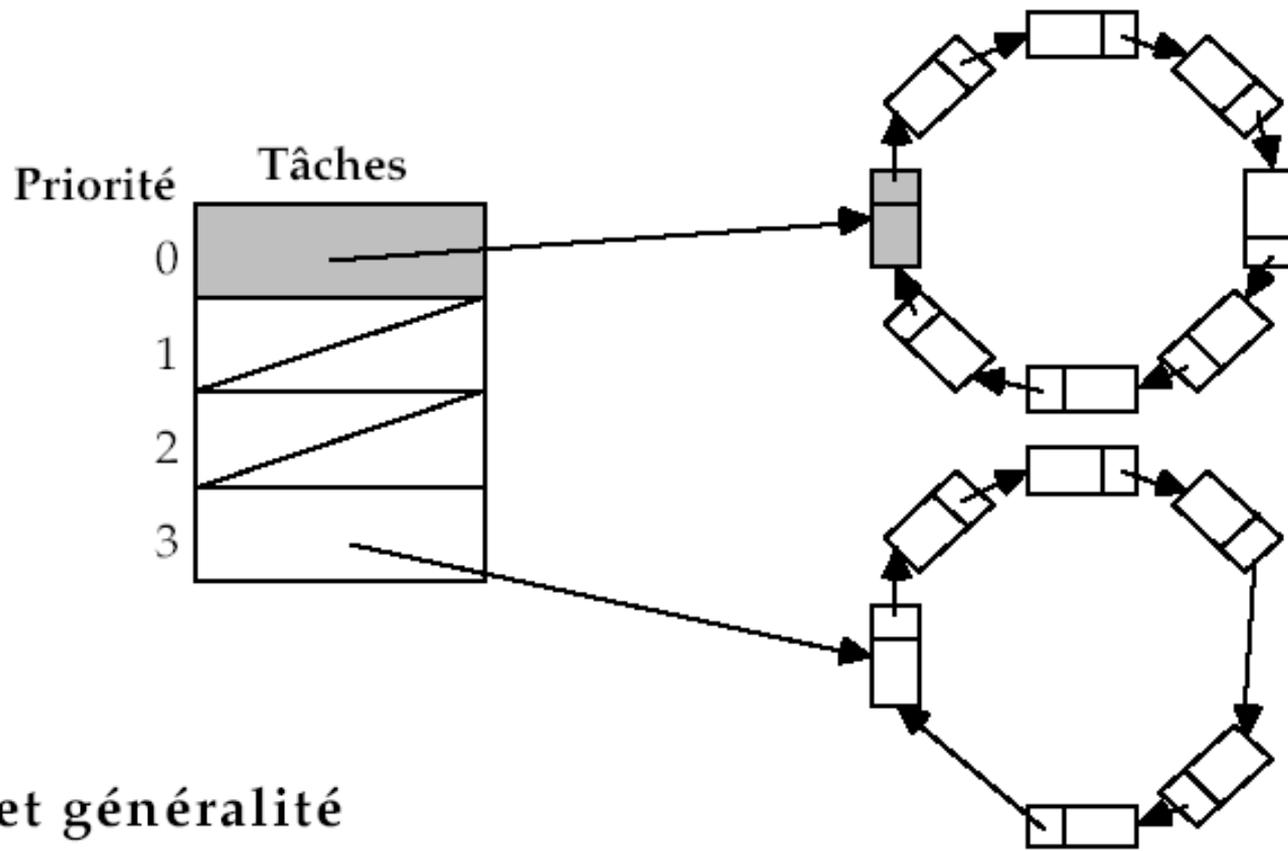
Bien sûr il faut que  $t$  soit le plus petit possible.

# Priorité pure

- Toutes les tâches ont une priorité, et pour une priorité on a au plus une tâche
- La préemption présente peu d'intérêt : la tâche la plus prioritaire s'exécute jusqu'à sa fin ou jusqu'à un blocage.
- L'ordonnancement est donc lié aux interruptions externes

# Méthode mixte : tourniquet multi-niveaux

On a quelques niveaux de priorité mais on peut avoir plusieurs tâches au même niveau de priorité.



## Souplesse et généralité

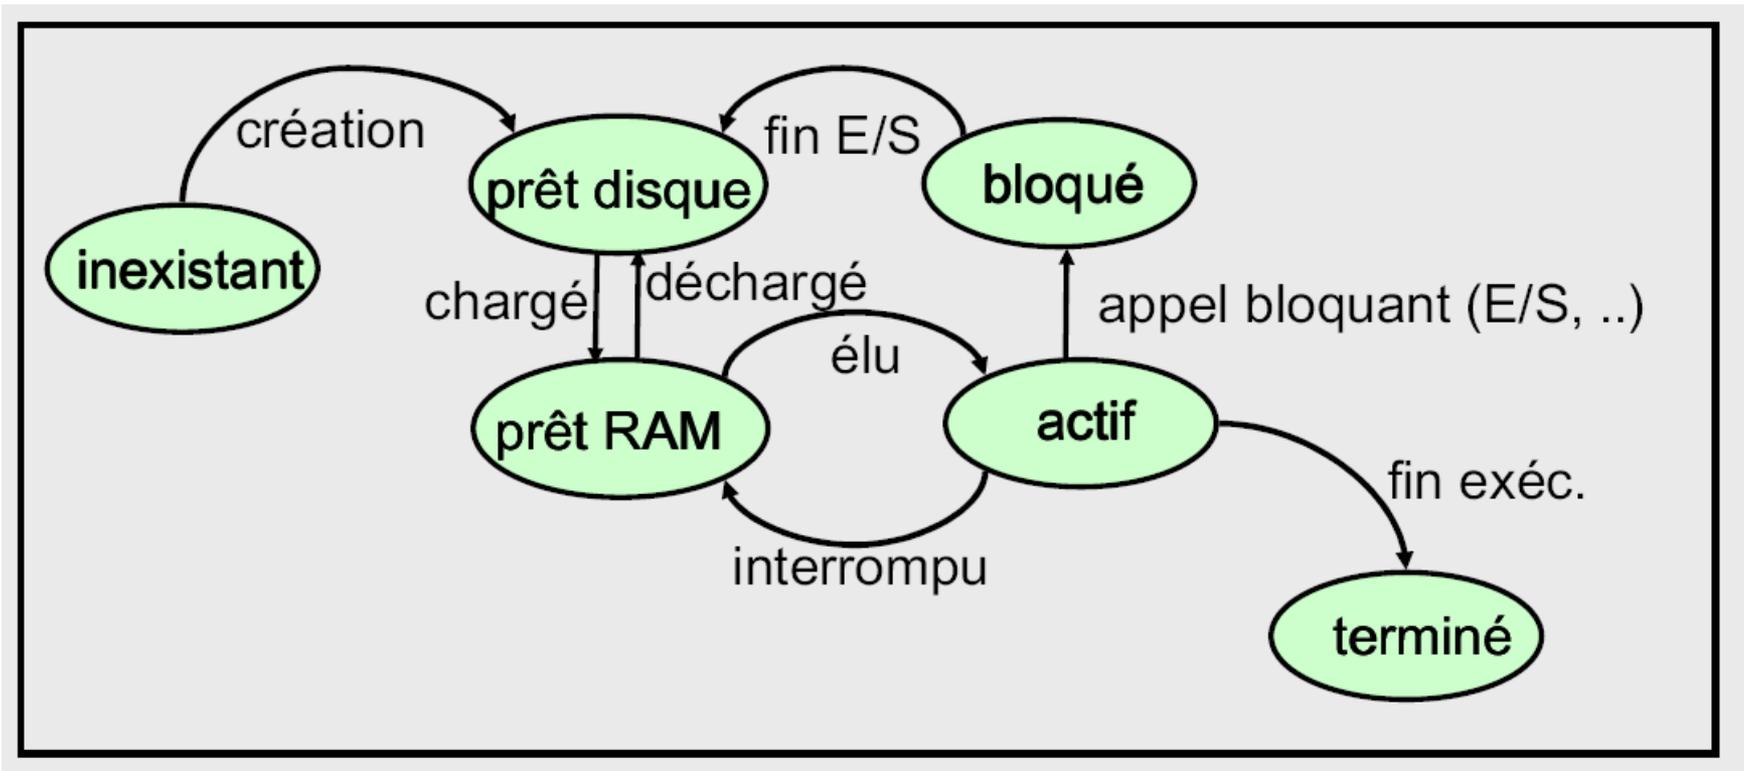
une tâche par niveau = priorité pure

toutes les tâches au même niveau = tourniquet simple

# **Algorithmes d'ordonnancement à plusieurs niveaux**

- **Ensemble des processus prêts trop important pour tenir en mémoire centrale**
- **Certains sont déchargés sur disque, ce qui rend leur activation plus longue**
- **Le processus élu est toujours pris parmi ceux présents en mémoire centrale**
- **En parallèle, on utilise un deuxième algorithme d'ordonnancement pour gérer les déplacements des processus prêts entre le disque et la mémoire centrale**

# Algorithmes d'ordonnancement à plusieurs niveaux



# Autre méthode d'ordonnancement

Systemes à temps partagé de type Unix : l'algorithme d'ordonnancement est plus complexe :

on privilégie les tâches courtes et les tâches interactives

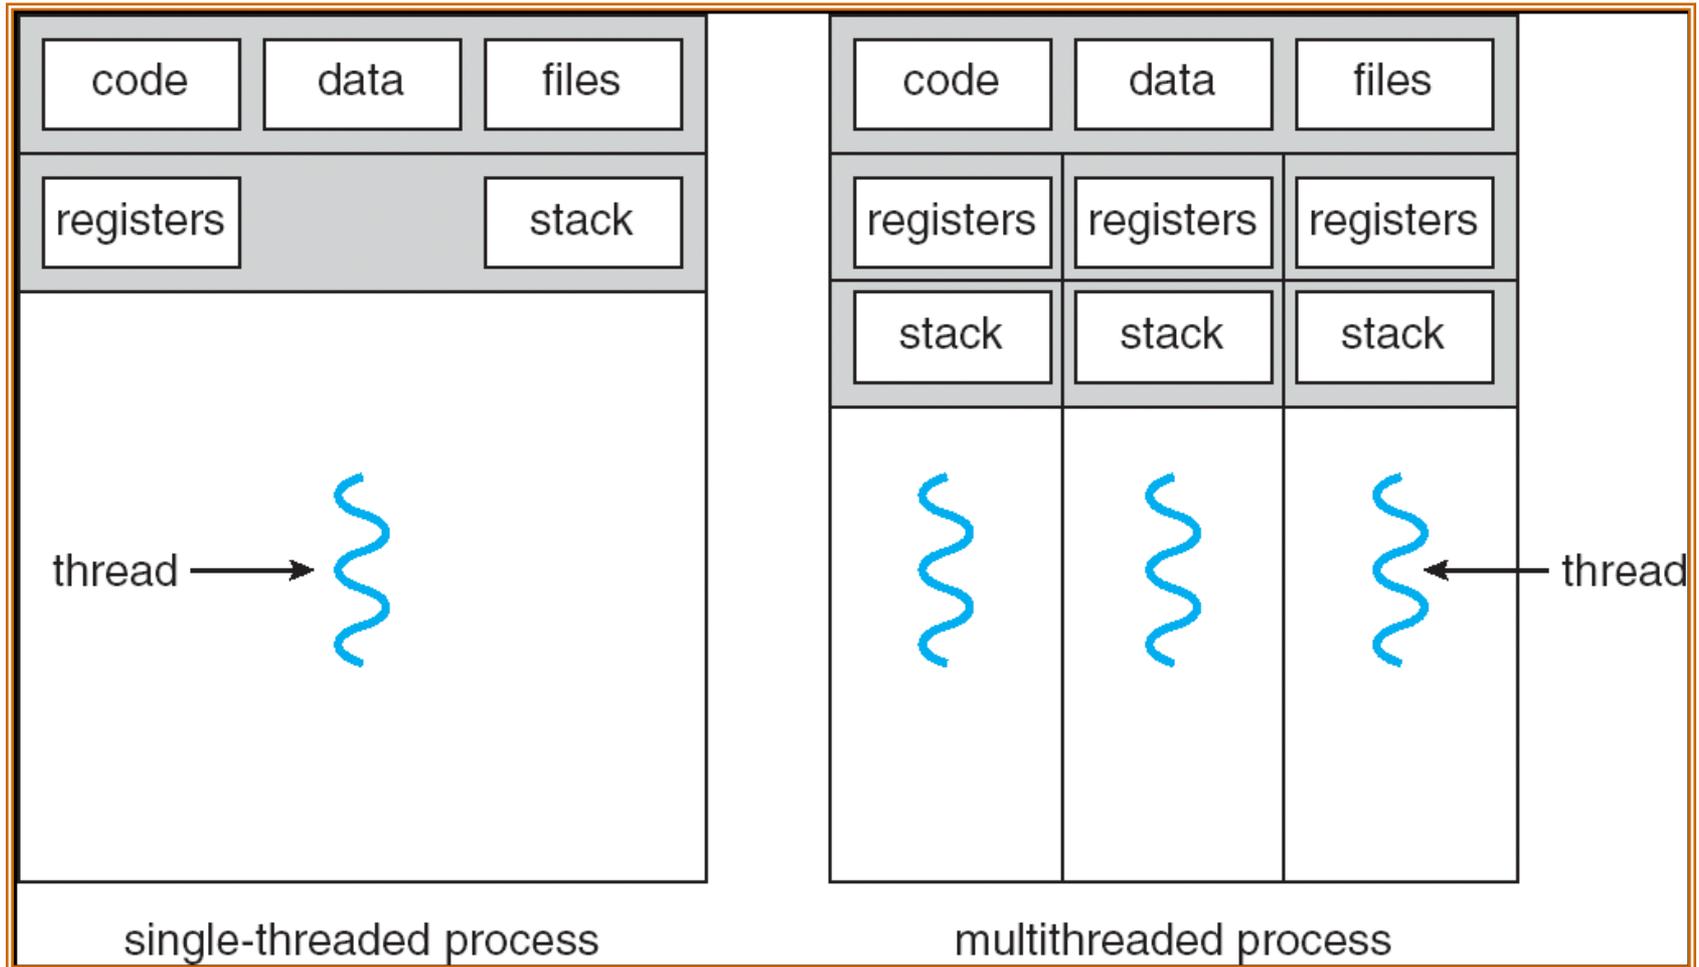
la priorité diminue avec le temps

la durée du quantum alloué peut elle aussi diminuer

# Notion de thread

- Un thread est une subdivision d'un processus
  - Un fil de contrôle dans un processus
- Les différents threads d'un processus **partagent l'espace adressable et les ressources d'un processus**
  - lorsqu'un thread modifie une variable (non locale à lui), tous les autres threads voient la modification
  - un fichier ouvert par un thread est accessible aux autres threads (du même processus)

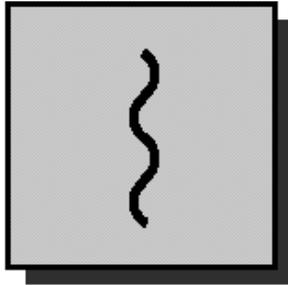
# Processus à un thread et à plusieurs threads



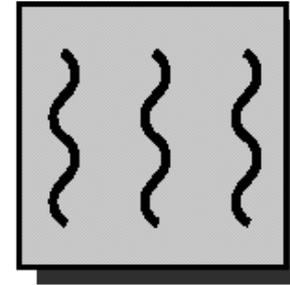
# Exemple

- Le processus MS-Word peut impliquer plusieurs threads:
  - Interaction avec le clavier
  - Rangement de caractères sur la page
  - Sauvegarde régulière du travail fait
  - Contrôle orthographe
  - Etc.
- Ces threads partagent tous le même fichier et données

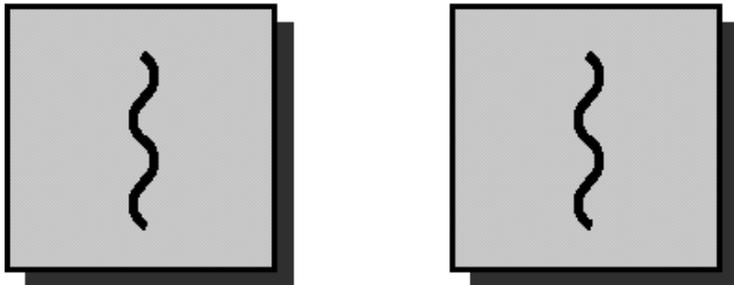
# Treads et Processus



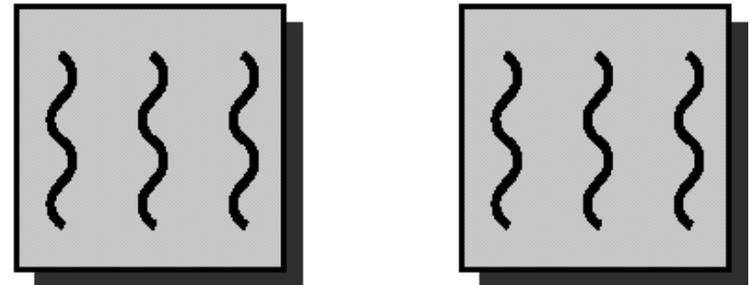
one process  
one thread



one process  
multiple threads



multiple processes  
one thread per process



multiple processes  
multiple threads per process

# Processus

- Possède sa mémoire, ses fichiers, ses ressources, etc.
- Accès protégé à la mémoire, fichiers, ressources d'autres processus

# Thread

- Possède un état d'exécution (prêt, bloqué...)
- Possède sa pile et un espace privé pour les variables locales
- A accès à l'espace adressable, fichiers et ressources du processus auquel il appartient, en commun avec les autres threads du même processus

# Pourquoi les threads

- Réactivité: un processus peut être subdivisé en plusieurs threads, par exemple l'un dédié à l'interaction avec les usagers, l'autre dédié à traiter des données
  - L'un peut s'exécuter pendant que l'autre est bloqué
- Utilisation de machines multiprocesseurs: les threads peuvent s'exécuter en parallèle sur des UC différentes

# La commutation entre threads est moins coûteuse que la commutation entre processus

- Un processus possède mémoire, fichiers, autres ressources
- Passer d'un processus à un autre implique de sauvegarder et rétablir l'état de chacun
- Passer d'un thread à un autre *dans le même processus* est bien plus simple, implique de sauvegarder seulement :
  - les registres de l'UCT,
  - la pile du thread,
  - les variables locales du thread

# Autres intérêts des threads

- La création et terminaison de nouveaux threads dans un processus existant sont aussi moins coûteuses que la création ou terminaison d'un processus
- La communication entre threads est plus simple qu'entre processus : mémoire partagée entre les threads

