Introduction à la programmation concurrente

Introduction

Yann Thoma, Fiorenzo Gamba

Février 2021

Reconfigurable and Embedded Digital Systems Institute
Haute Ecole d'Ingénierie et de Gestion du Canton de Vaud

Introduction

Programmation standard

Définition

- Un processus est une entité active et exécutable
  ou
- Un processus est un programme en cours d'exécution

- Un programme exécute des instructions séquentiellement
- Le développeur maîtrise la suite des opérations
- L'exécution est prévisible
- L'exécution est reproductible

Qu’est-ce que la programmation concurrente?

- La programmation concurrente est un paradigme de programmation tenant compte, dans un programme, de plusieurs contextes d’exécution (threads, processus, tâches) matérialisés par une pile d’exécution (stack) et des données privées
- La concurrence est indispensable lorsque l’on souhaite écrire des programmes interagissant avec le monde réel ou tirant parti de multiples processeurs (multi-coeurs, clusters, cloud, ...)
- Un processus est décomposé en *threads*
- Un thread est une sorte de *processus léger*
- Un thread correspond à une tâche qui s’exécute
    - Plus ou moins indépendamment des autres

Programmation séquentielle vs. concurrente

- Programmation séquentielle (ou **synchrone**): on attend jusqu'à ce que la tâche se termine pour passer à la suivante.
- Programmation concurrente (ou **asynchrone**): on lance la tâche et on passe à la suivante avant qu'elle se termine.

Pourquoi la programmation concurrente?

- Optimiser l'utilisation du/des processeurs
- Eviter de bloquer sur des entrées/sorties (IO)
- Tirer avantage des architectures multi-cores :
  - Aujourd'hui n'importe quel PC possède au moins 2 coeurs
- Augmenter le parallélisme :
  - Tout programme faisant du calcul devrait être développé de manière concurrente
- Attendre des événements de plusieurs entrées
- Simplifier la structure d'un programme
- Satisfaire des contraintes temporelles :
  - Programmation temps réel

Exemple d’applications multi-thread

Exemple d’applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread

Exemple d'applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread
- Serveur haute disponibilité, en cluster (répondre à des milliers de requêtes par seconde)

Exemple d'applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread
- Serveur haute disponibilité, en cluster (répondre à des milliers de requêtes par seconde)
- Browser : un thread gère une connexion, un thread fait le rendu de la page, un thread décode une vidéo, un thread gère l'interaction avec l'interface (tout ceci pour un seul onglet)

Exemple d'applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread
- Serveur haute disponibilité, en cluster (répondre à des milliers de requêtes par seconde)
- Browser : un thread gère une connexion, un thread fait le rendu de la page, un thread décode une vidéo, un thread gère l'interaction avec l'interface (tout ceci pour un seul onglet)
- Jeu vidéo : un thread s'occupe du rendu graphique, un autre de l'IA, un autre du son, *n* threads gèrent *n* joypads, etc.

Exemple d'applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread
- Serveur haute disponibilité, en cluster (répondre à des milliers de requêtes par seconde)
- Browser : un thread gère une connexion, un thread fait le rendu de la page, un thread décode une vidéo, un thread gère l'interaction avec l'interface (tout ceci pour un seul onglet)
- Jeu vidéo : un thread s'occupe du rendu graphique, un autre de l'IA, un autre du son, *n* threads gèrent *n* joypads, etc.
- *Viewer* d'images : un thread affiche l'image courante alors que *n* autres threads chargent les *n* images suivantes

Exemple d'applications multi-thread

- Serveur web ou ftp : chaque client est géré par un thread
- Serveur haute disponibilité, en cluster (répondre à des milliers de requêtes par seconde)
- Browser : un thread gère une connexion, un thread fait le rendu de la page, un thread décode une vidéo, un thread gère l'interaction avec l'interface (tout ceci pour un seul onglet)
- Jeu vidéo : un thread s'occupe du rendu graphique, un autre de l'IA, un autre du son, *n* threads gèrent *n* joypads, etc.
- *Viewer* d'images : un thread affiche l'image courante alors que *n* autres threads chargent les *n* images suivantes
- Programme de traitement de d'image, de vidéo, de rendu: image divisée en *n* blocs, *n* threads faisant le rendu de 1 bloc

Problèmes

- Difficulté à synchroniser des tâches
- Gestion des ressources partagées
- Problème de prédictibilité
- Problème de reproductibilité
- Concrètement:
  - Blackout au Nord-Est des US en 2003
  - Thérapie par radiation: Therac-25, entre 85 et 87

Problèmes - Blackout

- Blackout au Nord-Est des US en 2003 (55 millions de personnes touchées)

https://www.theregister.co.uk/2004/04/08/

Problèmes - Radiations

- Thérapie par radiation: Therac-25, 6 accidents entre 85 et 87, doses massives

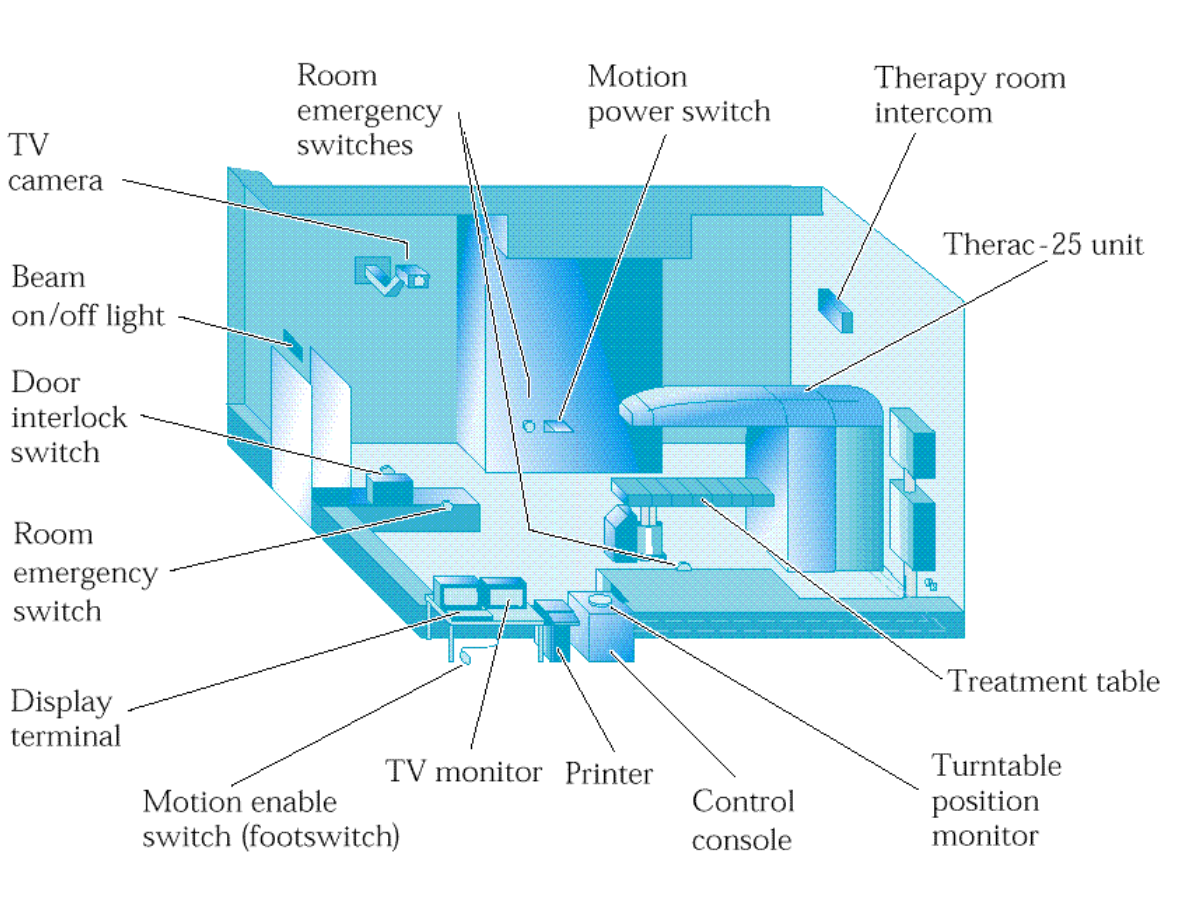

https://en.wikipedia.org/wiki/Therac-25

Programmation parallèle vs. concurrente

- *Programmation parallèle (ou répartie)*
  - Des processus s'exécutent sur plusieurs processeurs
- *Programmation concurrente*
  - Les tâches sont gérées par un même processeur
- Les mécanismes de synchronisation sont différents

Question

- Soient les deux tâches suivantes (s'exécutant en pseudo-parallèle):

Tâche A

```
x = 3;

printf("%d",x);
```

Tâche B

```
x = 5;
```

- Quelle est la sortie du programme dans le terminal ?
- Que vaut x ?

Thread

Thread

- Un thread est un fil d'exécution
- Un processus est composé de plusieurs threads
- Les threads s'exécutent en "*parallèle*"
  - Sur un mono-processeur: chacun son tour
    - Par entrelacement
  - Sur un multi-processeur: peut être réellement parallèle
- Dans tous les cas, l'ordonnanceur est responsable de l'ordre d'exécution
- Problèmes:
  - Accès à des ressources partagées
  - Echange de données
  - Séquentialité de l'exécution

Exemple: avance parallèle

Exemple: demande d’accès à la ressource

Exemple: accès à la ressource partagée

Exemple: relâchement de la ressource

Exemple: accès à la ressource partagée

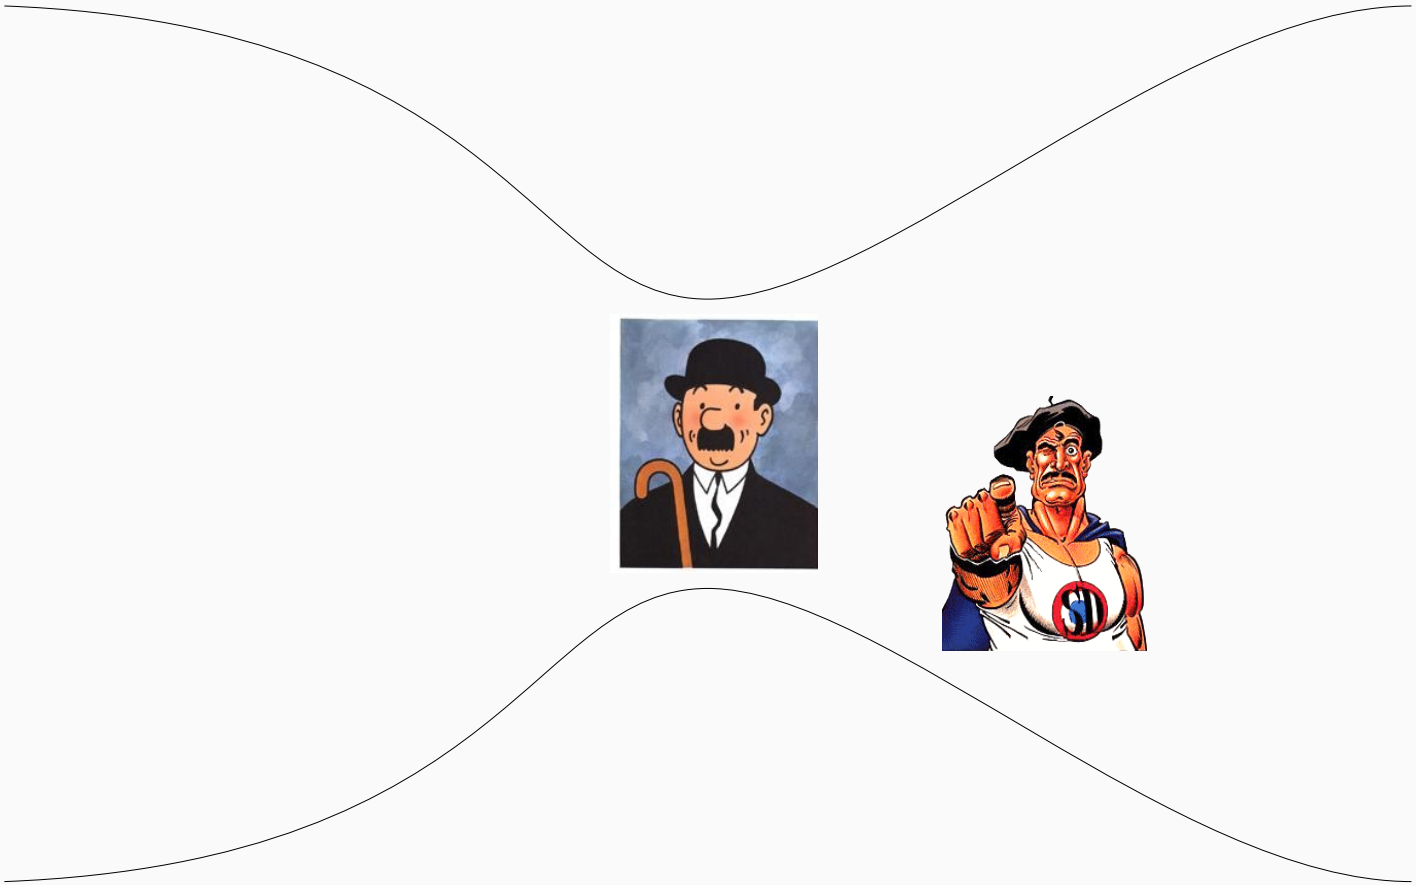

Exemple: avance parallèle

Exemple

Problème des threads: exemple

Classe GiveId

```
class GiveId {
public:
    GiveId(): nb_id(0) {};
    int getUniqueId() {
        return nb_id++;
    }
private:
    int nb_id;
}
```

Problème des threads: exemple

Classe GiveId

```
class GiveId {
public:
    GiveId(): nb_id(0) {};
    int getUniqueId() {
        return nb_id++;
    }
private:
    int nb_id;
}
```

- Que signifie `return nb_id++;` ?

Problème des threads: exemple

Classe GiveId

```
class GiveId {
public:
    GiveId(): nb_id(0) {};
    int getUniqueId() {
        return nb_id++;
    }
private:
    int nb_id;
}
```

- Que signifie `return nb_id++;` ?

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0
.	nb_id++

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0
.	nb_id++
.	return 0

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0
.	nb_id++
.	return 0
nb_id++	.

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0
.	nb_id++
.	return 0
nb_id++	.
return 0	.

Problèmes des threads: exemple

```
int temp = nb_id;
nb_id = nb_id + 1;
return temp;
```

Condition initale:

`nb_id = 0;`

Exemple de déroulement

Thread A	Thread B
	
.	.
temp = 0	.
.	temp = 0
.	nb_id++
.	return 0
nb_id++	.
return 0	.
.	.

Data race, race condition

Définition : Race condition

Une *race condition* est une situation où les résultats d'un programme diffèrent en fonction de l'ordre dans lequel les acteurs du système agissent.

Définition : Data race

Une *data race* est une situation où deux threads accèdent à un emplacement mémoire "en même temps" et qu'un des deux au moins le fait en écriture.

- Nous allons rencontrer des *data races* et verrons comment les éviter
- Nous allons mettre en place des mécanismes permettant de contrôler les *race conditions*

Implémentation

Implémentation

- Comment implémenter la concurrence?

Implémentation

- Comment implémenter la concurrence?
  - Grâce à des mécanismes du langage de programmation

Implémentation

- Comment implémenter la concurrence?
  - Grâce à des mécanismes du langage de programmation
  - Grâce à des bibliothèques

Implémentation

- Comment implémenter la concurrence?
  - Grâce à des mécanismes du langage de programmation
  - Grâce à des bibliothèques
  - Solution intermédiaire

Grâce au langage

- Avantages:
  - Les notions concurrentes de même que les constructions sont données par le langage
  - Détection d'une partie des erreurs à la compilation
  - Méthodologie de programmation imposée par le langage
- Désavantages :
  - Obligation d'utiliser un langage dédié qui est potentiellement peu répandu
  - Contraintes liées au langage choisi (pas forcément souhaitable)
- Exemples : ADA, Java, C++11, Rust, etc.

Grâce à des bibliothèques

- Le système d'exploitation offre une bibliothèque appelée *système multi-tâche*
- Avantage:
  - Un langage quelconque peut profiter de la bibliothèque
- Désavantages:
  - La portabilité (dépendance au système cible)
  - Déboguage délicat
  - Pas de méthodologie de programmation imposée
- Exemple: langage C avec bibliothèque *POSIX Threads* aussi appelée *Pthreads*

Solution intermédiaire

- Un précompilateur gère l'implémentation des outils
- Exemple: C++ avec librairie Qt
    - Code indépendant de la plateforme cible

Exemple de langage: Ada

- Pour
  - Le langage intègre des notions de concurrence
  - Certaines vérifications peuvent être faites à la compilation
  - Robuste
- Contre
  - Moins utilisé que les autres en pratique

Exemple de langage: Java

- Pour
  - Orienté objet
  - Mécanismes de synchronisation natifs
    - Thread
    - synchronized
    - wait, notify, notifyAll
- Contre
  - Langage interprété
  - Donc: légèrement plus lent que C/C++
  - Définition un peu légère du fonctionnement des primitives

Exemple de langage: Rust

- Pour
  - Très robuste
  - Offre tous les mécanismes nécessaires au multi-threading
  - Les *data races* sont interdites
    - Notion de propriété d'une variable
    - Le compilateur génère une erreur en cas de *data race*
- Contre
  - Je ne vois pas

Exemple de langage: C (POSIX)

- Utilisation de la bibliothèque POSIX
- Pour
  - Très utilisé dans le monde (notamment embarqué)
  - Code compilé (rapidité)
- Contre
  - Pas de mécanismes de synchronisation natifs

[1]Parallel and Distributed Programming Using C++, Hughes et Hughes

Exemple de langage: C (POSIX)

- Utilisation de la bibliothèque POSIX
- Pour
  - Très utilisé dans le monde (notamment embarqué)
  - Code compilé (rapidité)
- Contre
  - Pas de mécanismes de synchronisation natifs
  - Stroustrup: "It is possible to design concurrency support libraries that approach built-in concurrency support both in convenience and efficiency. By relying on libraries, you can support a variety of concurrency models, ..."[1]

[1] Parallel and Distributed Programming Using C++, Hughes et Hughes

Exemple de langage: C++11

- C++11 introduit des classes liées à la concurrence:
  - `thread`, `mutex`, `condition_variable`, `atomic`, `future`
  - Et des classes proches
- Pour
  - Contenu dans le langage
  - Lancement des threads facilité
- Contre
  - Pas de sémaphores

Exemple de langage: C++ (Qt)

- Utilisation de l'environnement Qt
- Pour
  - Interopérabilité (Linux, Linux embarqué, Windows, Mac OS, Android, iOS)
  - Tous les objets nécessaires existent
    - `QThread`, `QMutex`, `QSemaphore`, `QWaitCondition`
  - Orienté objet
- Contre
  - Nécessite d'avoir un portage pour la plateforme
    - De plus en plus courant

Pour le cours: C++ et bibliothèque pcosynchro

- Utilisation de la bibliothèque pcosynchro
  - Tous les objets nécessaires existent
    - `PcoThread`, `PcoMutex`, `PcoSemaphore`, `PcoConditionVariable`
- Offre toutes les fonctionnalités nécessaires au cours
  - Et pas plus
- Permet d'instrumentaliser le code (pour des tests)
- Langage connu des étudiants
- Possibilité d'offrir des laboratoires graphiques

Séparation d’un programme en plusieurs threads

Séparation d'un programme en threads

- Comment décomposer un programme en plusieurs threads?
- Il existe plusieurs modèles
  - Le modèle *délégation* (*boss-worker model* ou *delegation model* en anglais)
  - Le modèle *pair* (*peer model* en anglais)
  - Le modèle *pipeline* (*pipeline model* en anglais)

Modèle délégation

- Un thread principal
- Des threads travailleurs

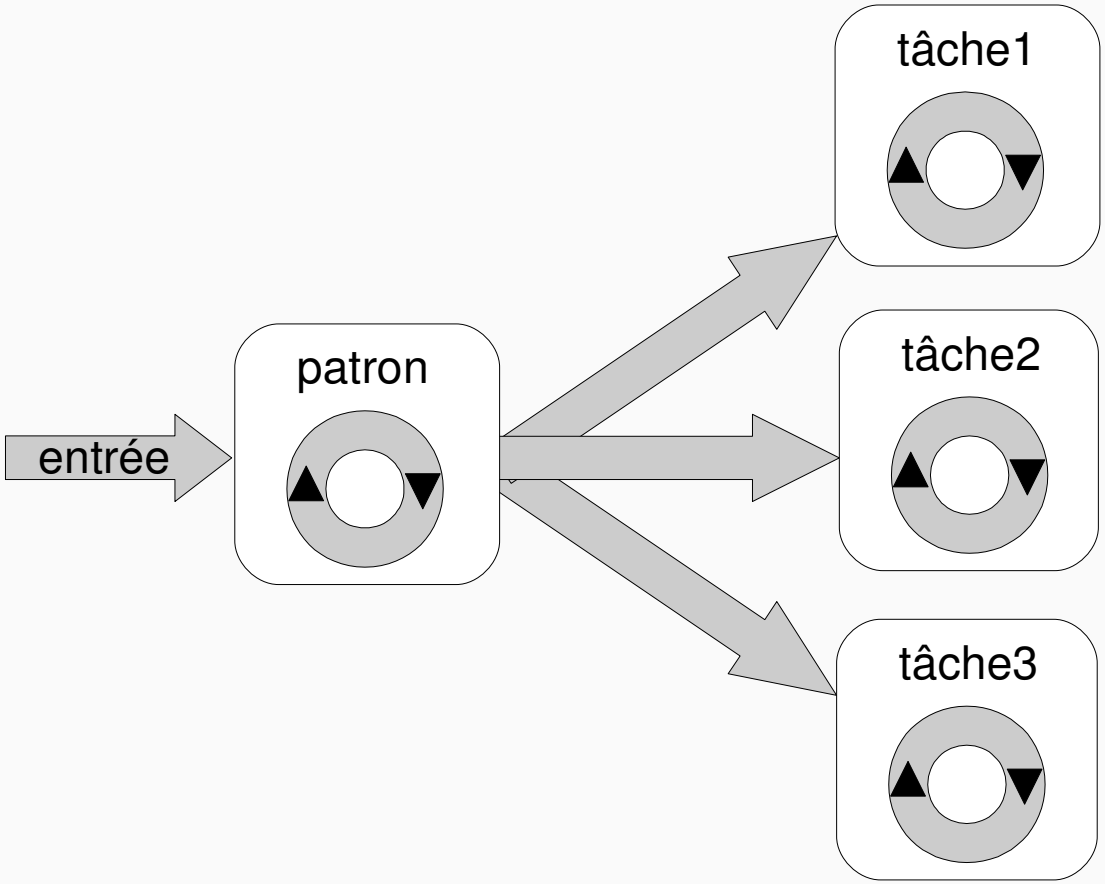

Modèle délégation: exemple 1

```
void tachePatron(void *ptr) {
  boucle infinie {
    attend une requête
    switch (requete) {
      case requeteX: startThread( ... tacheX); break;
      case requeteY: startThread( ... tacheY); break;
      ...
    }
  }
}

void tacheX(void *ptr) {
  exécuter le travail demandé, puis se terminer
}

void tacheY(void *ptr) {
  exécuter le travail demandé, puis se terminer
}
```

Modèle délégation: exemple 2

```
void tachePatron(void *ptr) {
  // crée tous les threads
  startThread(...);
  boucle infinie {
    attend une requête;
    place la requête dans la file d'attente
    signale aux travailleurs qu'une requête est prête
  }
}

void tacheTravailleur(void *) {
  boucle infinie {
    bloque jusqu'à être activé par le patron
    récupère la requête de la file d'attente
    switch(requete){
      case requeteX: fonctionX();
      case requeteY: fonctionY();
      ...
    }
  }
}

void fonctionX() {
  exécuter le travail demandé
}

void fonctionY() {
  exécuter le travail demandé
}
```

Modèle pair

- Pas de thread principal
- Tous égaux
- Chacun s’arrange avec ses entrées/sorties

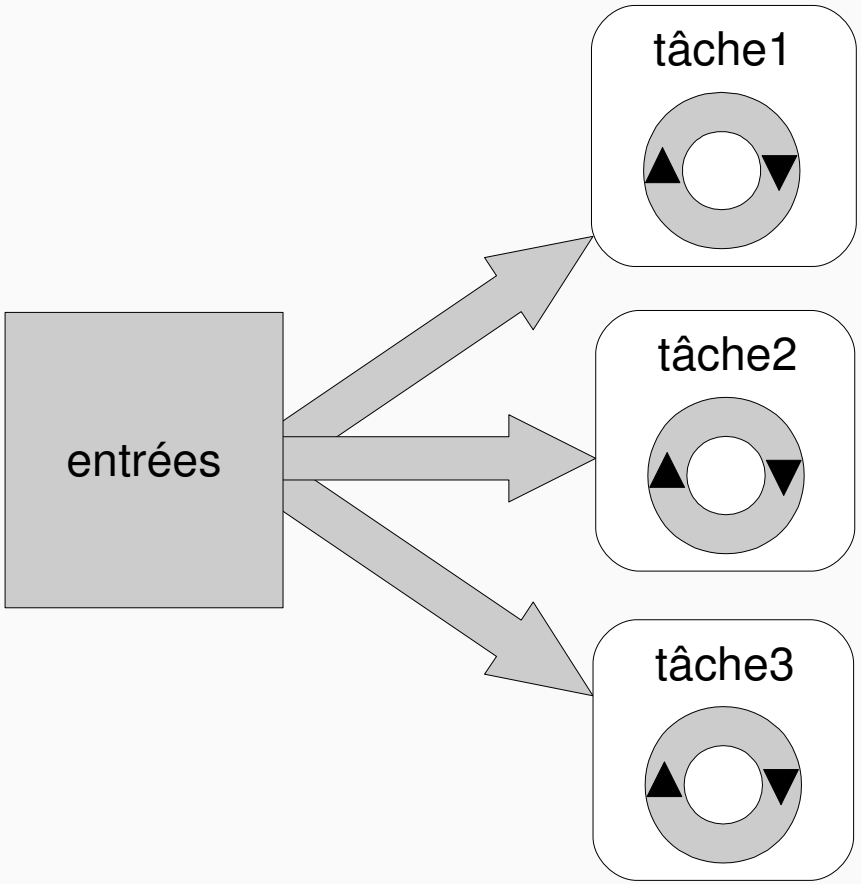

Modèle pair: exemple

```
int main() {
  startThread( ... tache1);
  startThread( ... tache2);
  ...
  signale aux threads qu'ils peuvent commencer à travailler
}

void tache1() {
  attend le signal de commencement
  effectue le traitement, et synchronise avec les autres threads
  si nécessaire
}

void tache2() {
  attend le signal de commencement
  effectue le traitement, et synchronise avec les autres threads
  si nécessaire
}
```

Modèle pipeline

- Appliqué lorsque:
  - L'application traite une longue chaîne d'entrée;
  - Le traitement à effectuer sur ces entrée peut être décomposé en sous-tâches (étages de pipeline) au travers desquelles chaque donnée d'entrée doit passer;
  - Chaque étage peut traiter une donnée différente à chaque instant.
- Un thread attend les données du précédent
- Et les transmet ensuite au suivant

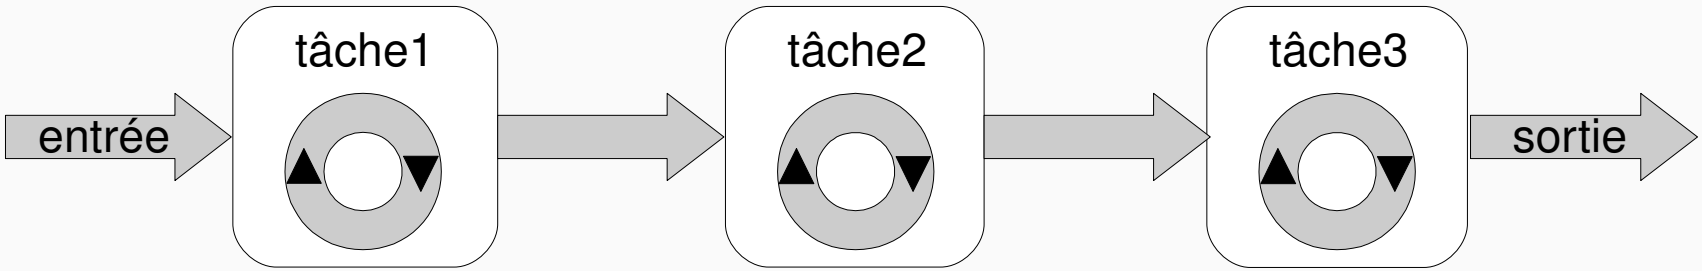

Modèle pipeline: exemple (1)

```
void etage1() {
  boucle infinie {
    récupérer une entrée du programme
    traiter cette donnée
    passer le résultat à l'étage suivant
  }
}
void etage2() {
  boucle infinie {
    récupérer une donnée de l'étage précédent
    traiter cette donnée
    passer le résultat à l'étage suivant
  }
}
void etageN() {
  boucle infinie {
    récupérer une donnée de l'étage précédent
    traiter cette donnée
    passer le résultat en sortie du programme
  }
}
```

Modèle pipeline: exemple (2)

```
main() {
  startThread( ... etage1);
  startThread( ... etage2);
  ...
  startThread( ... etageN);
  ...
}
```

Exemple de Tucuxi

- Logiciel d'aide à l'interprétation de mesures de concentration pour ajustement de posologies (pour pharmacologie clinique)

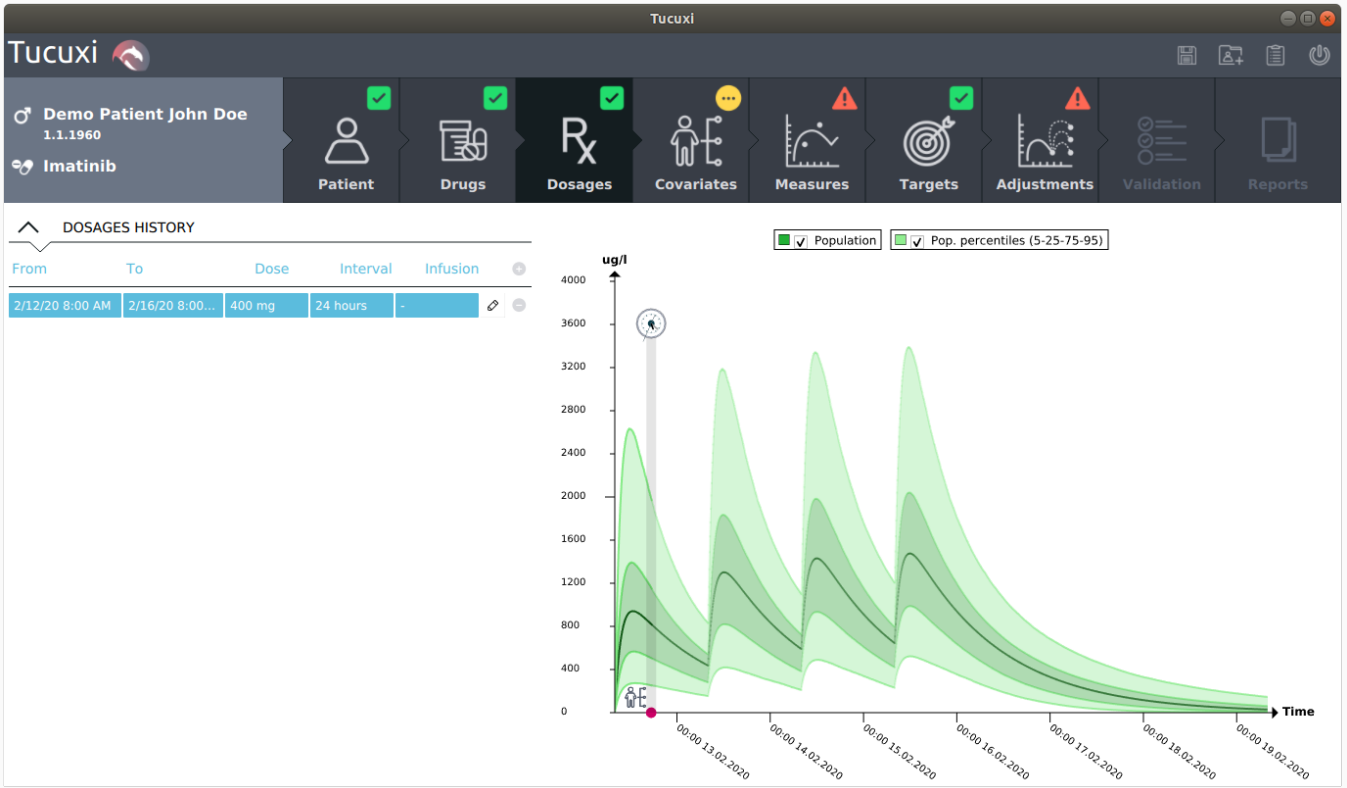

Exemples sur le projet Tucuxi

- Les médicaments sont décrits par des fichiers XML
- Ils doivent être chargés au lancement du programme
  - $\Rightarrow$ Chargement géré par un thread
    - Evite de ralentir le lancement du programme

Exemples sur le projet Tucuxi

- Certains traitements mathématiques nécessaires pour afficher une courbe sont longs (quelques secondes)
  - $\Rightarrow$ Traitement géré par plusieurs threads dédiés au calcul
    - Evite de *freezer* l'application pendant le traitement

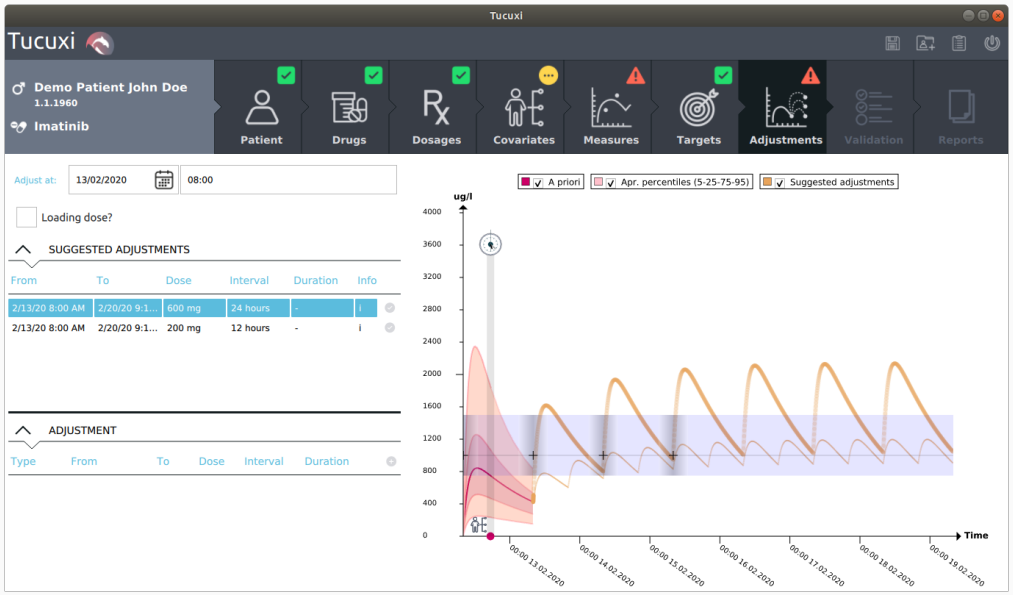

Exemples sur le projet Tucuxi

- Calcul de courbes de percentiles selon Monte Carlo
- Il faut calculer 10'000 courbes
  - $\Rightarrow$ Multithreadé
- Il faut trier ces courbes, à chaque temps
  - $\Rightarrow$ Multithreadé

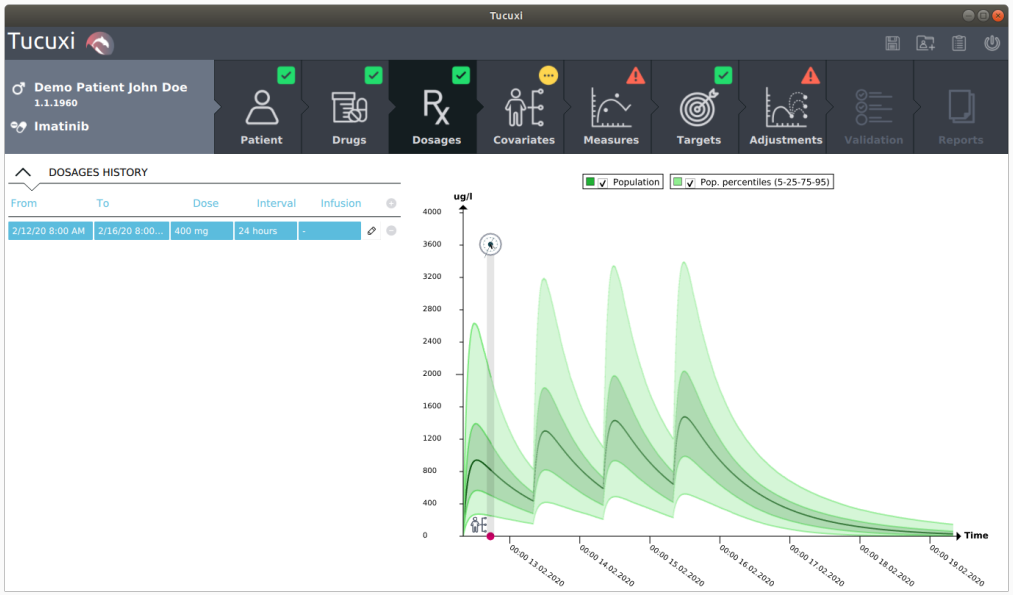

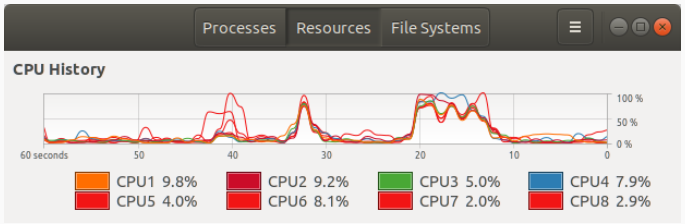

Exemple sur le projet SpikeOnChip

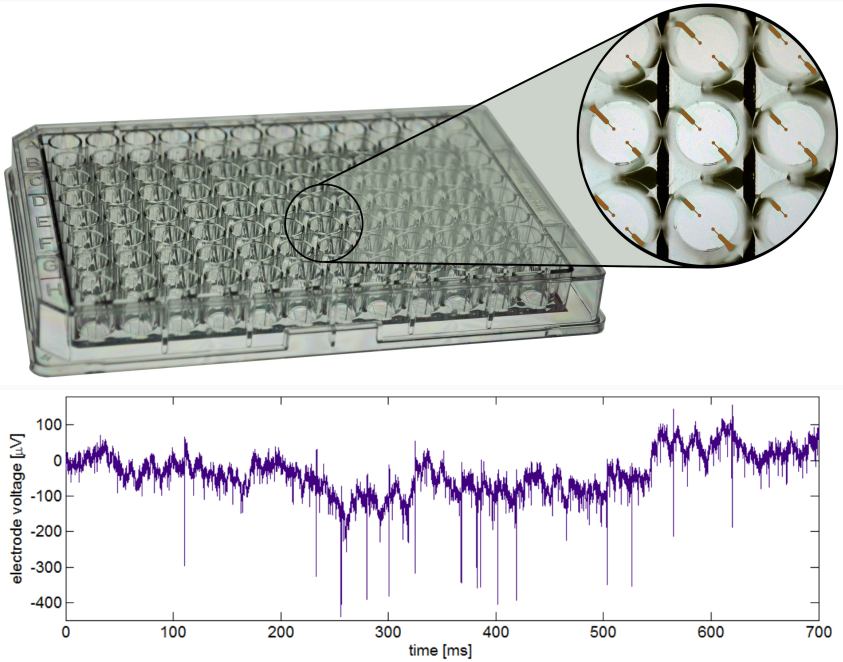

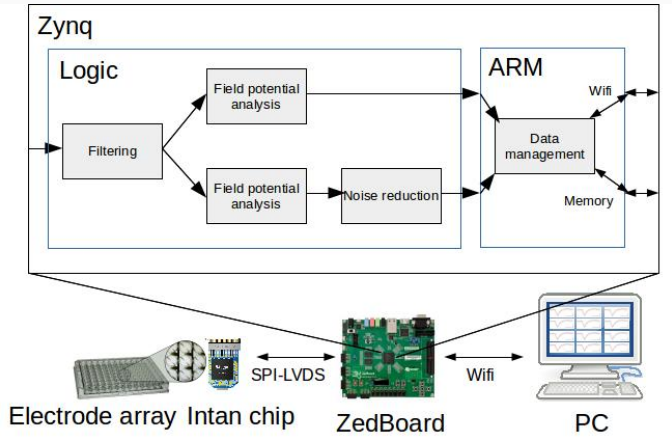

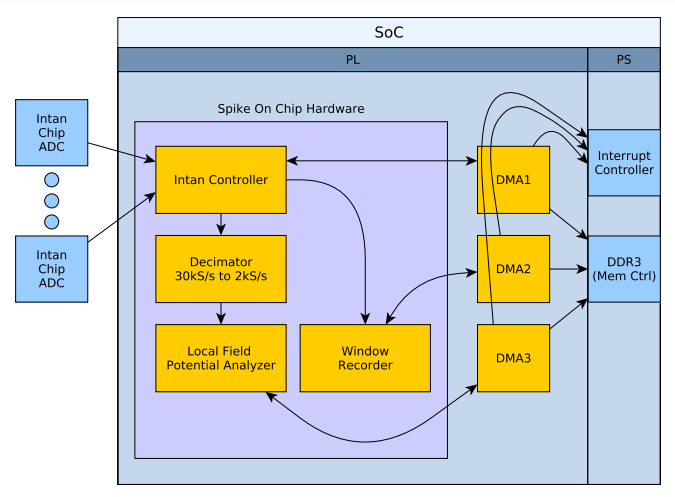

Exemple sur le projet SpikeOnChip

- Analyse de signaux électriques émis par des neurones
- Une tâche pour l'acquisition
- Une tâche pour la transmission (Ethernet ou Wifi)
- Une tâche pour l'écriture sur carte SD