

SDR

Diffusion

Élection naïve

Olivier Lemer

↓ Élections ?

Le problème de l'élection

Étant donné un groupe de processus.

Chacun a une **aptitude**, pas nécessairement statique.

On veut **élire** celui qui a la meilleure aptitude.

Le problème de l'élection

Étant donné un groupe de processus.

Chacun a une **aptitude**, pas nécessairement statique.

On veut **élire** celui qui a la meilleure aptitude.

Par exemple :

- **Algorithme à jeton** : régénérer un jeton après perte
- **Architecture manager/worker** : désigner un nouveau manager
- **Répartition de charge** : sélectionner le serveur le moins chargé

Le problème de l'élection

Étant donné un groupe de processus.

Chacun a une **aptitude**, pas nécessairement statique.

On veut **élire** celui qui a la meilleure aptitude.

Par exemple :

- **Algorithme à jeton** : régénérer un jeton après perte
- **Architecture manager/worker** : désigner un nouveau manager
- **Répartition de charge** : sélectionner le serveur le moins chargé

Propriétés souhaitées

- **Sureté** : un seul processus ne peut être élu
- **Progrès** : il doit y avoir un élu un jour
- **Validité** : l'élu doit être le participant correct à la plus grande aptitude
- **Résilience** :
 - Un processus en panne ne doit pas être élu, même s'il redémarre.
 - Si le réseau est scindé en deux, un élu doit exister par partition.

Différence avec Mutex

Mutex

Essaie d'être équitable
Partage l'accès à une section
Tout demandeur sera accepté
Bloquant si SC est prise

Élection

Choisit la meilleure aptitude
Partage le droit au titre d'élus
Un demandeur peut ne jamais être élu
Non-bloquant si un autre est élu

Là où la Mutex assure que tout le monde aura droit à son moment,
l'élection sert uniquement à décider à qui attribuer un titre spécial d'*élus*.

↓ **Rappel**

Suppositions

Pour l'instant, on supposera

- **Pas de perte** de message
 - **Pas de duplication** de message
 - **Pas de changement d'ordre** de messages
 - **Pas de panne** serveur
-
- **Système synchrone** : délai d'envoi de T maximum

↓ **Algorithme du Bully**

a.k.a. un algorithme naïf

Bully Algorithm

Idée *"tout le monde doit tout savoir"*

J'envoie mon aptitude à tout le monde.

Je reçois l'aptitude de tout le monde.

Le plus fort gagne.

Bully Algorithm

Deux événements

Une élection commence

Réception d'une aptitude

Bully Algorithm

Deux événements

Une élection commence

Je broadcast mon aptitude.

J'attends 2T pour tout recevoir.

Je détermine l' élu.

Réception d'une aptitude

Bully Algorithm

Deux événements

Une élection commence

Je broadcast mon aptitude.

J'attends 2T pour tout recevoir.

Je détermine l'élue.

Réception d'une aptitude

Si je ne suis pas déjà en élection,
j'entre en élection.

Bully Algorithm

Deux événements

Une élection commence

Je broadcast mon aptitude.

J'attends 2T pour tout recevoir.

Je détermine l'élue.


Réception d'une aptitude

Si je ne suis pas déjà en élection,
j'entre en élection.

Si une élection est en cours quand une nouvelle est demandée, elle est différée à la fin de celle en cours.


Bully Algorithm

Exemple




Bully Algorithm

Exemple




Bully Algorithm

Exemple



Bully Algorithm

Exemple




Exemple




Bully Algorithm

Exemple




Bully Algorithm

Exemple




Bully Algorithm

Problème



Bully Algorithm

Problème



Bully Algorithm

Performance

Communication

Durée d'une élection

Bully Algorithm

Performance

Communication

$O(N^2)$ messages par élection

Durée d'une élection

Bully Algorithm

Performance

Communication

$O(N^2)$ messages par élection

Durée d'une élection

Jusqu'à $4T$

($1T$ d'attente, $2T$ de timeout, $1T$ de transit)

↓ Algorithme du Bully

Pseudocode

Pseudocode

Variables

<code>n</code>	<i>entier, constant</i>	nombre de processus
<code>self</code>	<i>entier, constant</i>	mon numéro de processus
<code>apts</code>	<i>tableau d'entiers</i>	aptitudes de tous les processus
<code>apt_self</code>	<i>entier</i>	mon aptitude
<code>T</code>	<i>entier, constant</i>	durée maximale d'une transmission
<code>inElection</code>	<i>booléen, init false</i>	ssi une élection est en cours
<code>isReqPending</code>	<i>booléen, init false</i>	ssi une élection est en attente
<code>élu</code>	<i>entier</i>	id du processus élu

Pseudocode

Initialisation

Écouter infiniment les événements suivants :

- Demande d'élection par la couche applicative

- Demande d'obtention de l'élu par la couche applicative

- Demande de changement d'aptitude à `new_apt`

- Réception de l'aptitude `apt_i` de `i`

- Timeout

Note : les traitements de ces événements sont faits de manière séquentielle.

Pseudocode

Demande d'élection de la couche applicative

Attendre pendant $1T$
Démarrer une élection

Demande d'obtention de l'élue par la couche applicative

Retourner `elu`

Demande de changement d'aptitude à `new_apt`

`apt_self` $\leftarrow$ `new_apt`
Attendre pendant $1T$
Démarrer une élection

Pseudocode

Réception de l'aptitude apt_i de i

Si pas `inElection`

Démarrer une élection

$\text{apts}[i] \leftarrow \text{apt}_i$

Démarrer une élection

Si `inElection`

$\text{isReqPending} \leftarrow \text{true}$

Sinon

$\text{inElection} \leftarrow \text{true}$

$\text{apts}[j] \leftarrow -\text{inf}$ pour tout j

$\text{apts}[\text{self}] \leftarrow \text{apt_self}$

Speaker notes

L'aptitude d'un processus a le droit de changer à tout moment, ce n'est pas une propriété statique (sinon, l'élue pourrait être choisi de manière statique aussi). Il faut donc prendre une "snapshot" de la valeur de l'aptitude du processus au moment où l'élection commence. Ainsi, tout changement d'aptitude durant une élection n'impactera pas l'algorithme.

Pseudocode

Timeout

élu $\leftarrow$ i tel que $\text{apts}[i]$ est le premier maximum de apts .

$\text{inElection} \leftarrow \text{false}$

Si isReqPending

$\text{isReqPending} \leftarrow \text{false}$

 Attendre pendant $1T$

Démarrer une élection

↓ Algorithme du Bully

Pseudocode++ (*avec deux routines*)

Pseudocode à 2 routines

Diffuseur

Responsable de déclencher les élections et communiquer avec l'application.

Collecteur

Responsable de collecter les aptitudes.

Permet de tirer profit de la concurrence.

Pseudocode à 2 routines

Variables partagées

n	<i>entier, constant</i>	nombre de processus
self	<i>entier, constant</i>	mon numéro de processus
T	<i>entier, constant</i>	durée maximale d'une transmission

Pseudocode à 2 routines

Routine 1 - Diffuseur

Variables de la routine 1

élu	<i>entier</i>	id du processus élu
apts	<i>tableau d'entiers</i>	aptitudes de tous les processus
apt_self	<i>entier, constant</i>	mon aptitude

Initialisation

Écouter infiniment les événements suivants :

- Demande d'entrée en élection

- Demande de changement d'aptitude à new_apt

- Demande de l'élu par la couche applicative

Pseudocode à 2 routines

Routine 1 - Diffuseur

Demande d'entrée en élection

Exécuter *entrer en élection*

Demande de changement d'aptitude à `new_apt`

`apt_self` $\leftarrow$ `new_apt`
Exécuter *entrer en élection*

Demande de l'élu par la couche applicative

Retourner `elu`

Pseudocode à 2 routines

Routine 1 - Diffuseur

Entrer en élection

```
Attente bloquante durant  $1T$   
Envoi de apt_self à tous les autres processus  
Envoi de apt_self à la routine Collecteur  
Attente bloquante durant  $2T$   
Obtention de apts de la routine Collecteur  
élu  $\leftarrow i$  tel que apts[i] est le premier maximum de apts
```

Speaker notes

Notez l'absence de booléen `inElection`. Puisque la routine bloque pendant qu'elle est en élection, tous les autres événements ont la garantie qu'aucune élection n'est en cours. Cela simplifie grandement la conceptualisation.

Pseudocode à 2 routines

Routine 2 - Collecteur

Initialisation

Boucle sur l'attente de réception de apt_i de la part de i

$apts \leftarrow$ Tableau de taille n initialisé à $-\infty$

$apts[i] \leftarrow apt_i$

Si $i \neq self$

Demander une élection à *Diffuseur*

Boucle sur l'attente de

Réception de apt_i de i

$apts[i] \leftarrow apt_i$

Demande de $apts$ par *Diffuseur*

Retourner $apts$

Sortir de cette boucle

↓ **Algorithme du Bully**

En cas de panne ?

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Seul danger : Pendant une élection qu'il allait gagner.

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Seul danger : Pendant une élection qu'il allait gagner.

Gestion de telles pannes

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Seul danger : Pendant une élection qu'il allait gagner.

Gestion de telles pannes

On suppose alors un *détecteur de panne* chez les autres, surveillant l'élus :

Si je détecte une panne de l'élus, je demande une nouvelle élection.

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Seul danger : Pendant une élection qu'il allait gagner.

Gestion de telles pannes

On suppose alors un *détecteur de panne* chez les autres, surveillant l'élus :

Si je détecte une panne de l'élus, je demande une nouvelle élection.

Détecteur parfait ou un jour ?

Gestion des pannes

Supposition

Un processus ne tombe jamais en panne *pendant* l'envoi de messages en batch.

Soit il envoie tout, soit il n'envoie rien.

(Il existe des protocoles de communication qui garantissent cela)

Seul danger : Pendant une élection qu'il allait gagner.

Gestion de telles pannes

On suppose alors un *détecteur de panne* chez les autres, surveillant l'élus :

Si je détecte une panne de l'élus, je demande une nouvelle élection.

Détecteur parfait ou un jour ?

Un jour suffit : si suspicion annulée, relancer une élection.

En cas de faux positif, le même élu sera à nouveau choisi.

↓ Exercice

Algorithme du Bully

Exercice

On suppose :

- 2s de transit pour chaque message.
- Si une demande d'élection est rejetée, le processus réessaie une fois l'élection courante terminée.
- Les pannes ne sont pas détectées.

Trois processus

- A, avec aptitude initiale de 15
- B, avec aptitude initiale de 15
- C, avec aptitude initiale de 20

Les événements suivants ont lieu

- T=1 : A demande une élection
- T=2 : l'aptitude de B devient 25
- T=2 : B demande une élection
- T=5 : l'aptitude de C devient 10
- T=5 : C demande une élection
- T=7 : B tombe en panne