Patterns de mobilité

Thèse soutenue par Cédric du Mouza

le 12 octobre 2005

sous la direction de Philippe Rigaux

Equipe VERTIGO - Lab. CEDRIC - CNAM Paris

Contexte

Manipuler *efficacement* des données de nature *complexe* (objets mobiles)

Problématiques classiques:

- indépendance logique/physique: on souhaite exprimer de manière simple des opérateurs puissants
- performances: quelles structures adopter afin d'avoir une évaluation efficace des requêtes

Domaine applicatif choisi: problématique assez récente du suivi et de l'interrogation d'objets mobiles.

Motivations

Convergence de nouvelles technologies:

- Internet
- Communications sans fil
- GPS (et Galileo?)

$\Rightarrow$ nouveaux défis pour la recherche comme:

- interroger des données historisées représentant des trajectoires
- suivre des objets mobiles en temps réel

Contribution

Cette thèse propose:

- un langage de modélisation et d'interrogation de trajectoires: étude de l'expressivité et de la complexité
- un algorithme très efficace pour une partie bien définie du langage
- un modèle de représentation et d'interrogation multi-échelle
- un prototype

Problématique

Hypothèses:

- l'espace de référence est une carte partitionnée en zones
- les trajectoires sont représentées par des séquences de zones traversées

Objectifs:

- définir un modèle de données et un langage de requêtes pour ces trajectoires
- développer des techniques pour une évaluation continue des requêtes

Intuition: utiliser des patterns pour l'interrogation.

Données

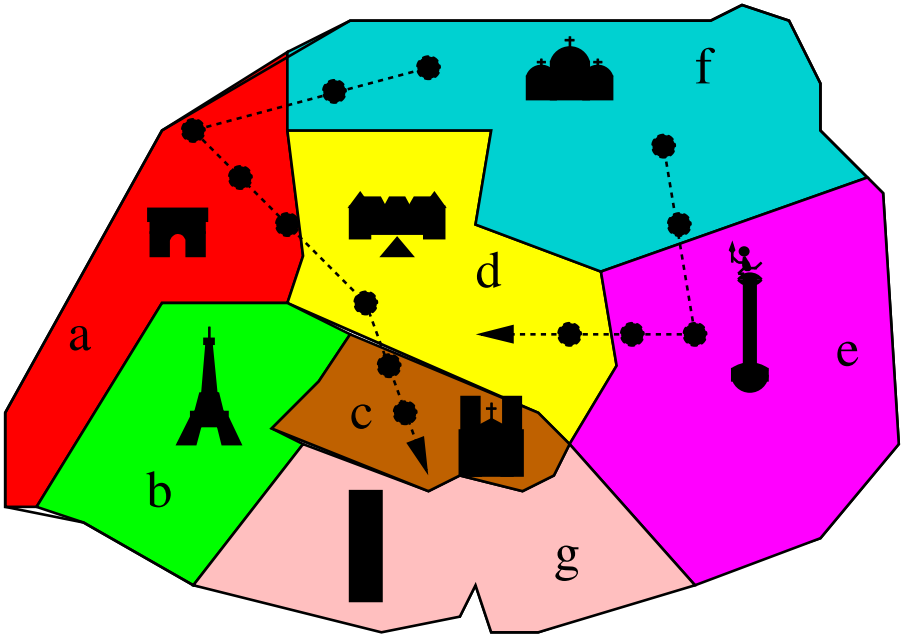

- Une carte partitionnée en 7 zones: `a`, `b`, `c`, `d`, `e`, `f` et `g`
- chaque point représente un nouvel événement GPS, reçu à une fréquence donnée
- 2 trajectoires $f \rightarrow a \rightarrow d \rightarrow c$ et $f \rightarrow e \rightarrow d$

Requêtes

- Q1. Donner tous les objets qui ont voyagé de `a` à `f`, sont restés au moins deux minutes en `f` et ensuite ont voyagé de `f` à `c`.
- Q2. Donner tous les objets qui restent en `a` ou `b` excepté pendant une minute où ils furent dans une autre zone.
- Q3. Donner tous les objets qui sont passés par `f` pour atteindre une autre zone, puis sont allés en `d` ou `c`, et sont revenus en `f` via la *même* zone.

Variables

Une requête correspond donc à une spécification de zones successives traversées avec un certain degré de liberté et des contraintes temporelles.

Comment représenter ces « degrés de liberté »?

Variables

Une requête correspond donc à une spécification de zones successives traversées avec un certain degré de liberté et des contraintes temporelles.

Comment représenter ces « degrés de liberté »?
$\Rightarrow$ utilisation de variables.

Variables

Une requête correspond donc à une spécification de zones successives traversées avec un certain degré de liberté et des contraintes temporelles.

Comment représenter ces « degrés de liberté »?
$\Rightarrow$ utilisation de variables.

Une variable peut être associée à n'importe quel symbole.

Si une variable se répète: toutes les répétitions doivent être liées au même symbole

Variables

Exemple: Donner tous les objets qui restent en `a` ou `b` excepté pendant une minute où ils furent dans une zone `@x` différente de `a` ou `b`.

Exemple: Donner tous les objets qui sont passés par `f` pour atteindre une autre zone `@x`, puis sont allés en `d` ou `c`, et sont revenus en `f` via la *même* zone `@x`.

Exemple: Donner tous les objets partant d'une zone `@x` pour aller en `a`, puis traversant une zone `@y` différente de `@x` avant de revenir en `a`.

Patterns de mobilité

Langage: adaptation des expressions régulières à la sémantique de l'application.

Patterns de mobilité

Langage: adaptation des expressions régulières à la sémantique de l'application.

Pourquoi pas toute E.R.?
$E =$ `b.(a|@x)+.c`, alors la trajectoire `b.a.c` a deux représentants dans $\mathcal{L}(E_1)$:

- `b.a.c`
- `b.@x.c` (avec `@x` instanciée à `a`)

$\Rightarrow$ non déterministe, et parfois n'a aucun sens.

Patterns de mobilité

Langage: adaptation des expressions régulières à la sémantique de l'application.

Pourquoi pas toute E.R.?
$E =$ `b.(a|@x)+.c`, alors la trajectoire `b.a.c` a deux représentants dans $\mathcal{L}(E_1)$:

- `b.a.c`
- `b.@x.c` (avec `@x` instanciée à `a`)

$\Rightarrow$ non déterministe, et parfois n'a aucun sens.

Un pattern de mobilité est une expression régulière sur $\Sigma \cup \mathcal{V}$ où chaque variable joue un rôle dans l'évaluation.

Interrogation

Syntaxe: une *requête* est un pattern accompagné d'un ensemble de contraintes pour les variables.

Sémantique: un objet appartient au résultat d'une requête si les derniers déplacements correspondent au pattern tout en respectant les contraintes.

Exemple: donner tous les objets qui ont traversé une certaine zone différente de `c` pour aller en `d` et après 2 minutes sont allés en `f` en passant par cette *même* zone.

$$q = (\texttt{@x.d[2].@x.f}, \{\texttt{@x} \neq \texttt{c}\})$$

Alors l'objet de trajectoire `d.c[2].a.d[2].a.f` appartient au résultat.

Évaluation

Évaluation de $(a|b)^+.@x.(a|b)^+$

entrée	chaîne possible	instanciation
a	a	@x=⊥
a.**a**	a.a	@x=⊥,
	a.@x	@x=a
a.a.**b**	a.a.b	@x=⊥,
	a.a.@x	@x=b,
	a.@x.b	@x=a
a.a.b.**b**	a.a.b.b	@x=⊥,
	a.a.b.@x	@x=b,
	a.a.@x.b	@x=a,
	a.@x.b.b	@x=b

Expression vs complexité

Dans le pire des cas, le nombre d'états à maintenir est exponentiel dans le nombre de variables.

Expression vs complexité

Dans le pire des cas, le nombre d'états à maintenir est exponentiel dans le nombre de variables.

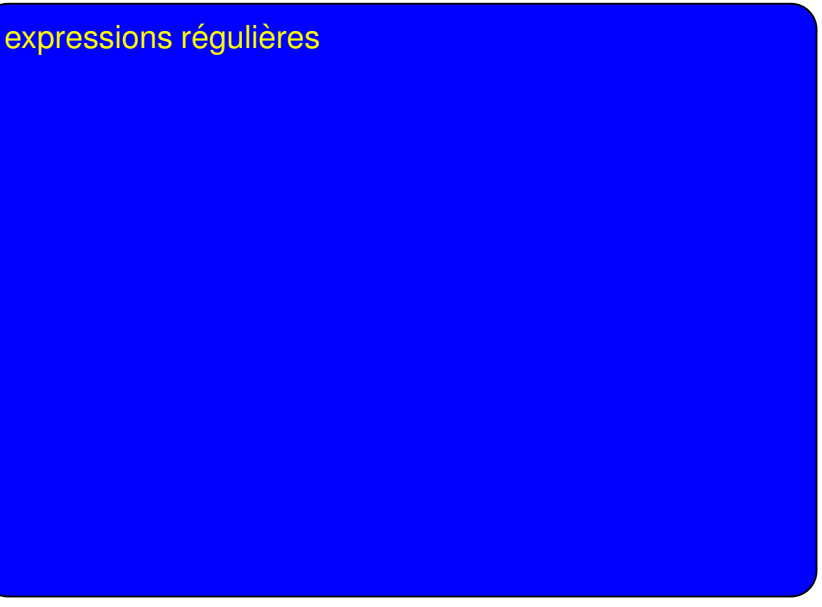

expressions régulières: n'ont pas toujours de sens

Expression vs complexité

Dans le pire des cas, le nombre d'états à maintenir est exponentiel dans le nombre de variables.

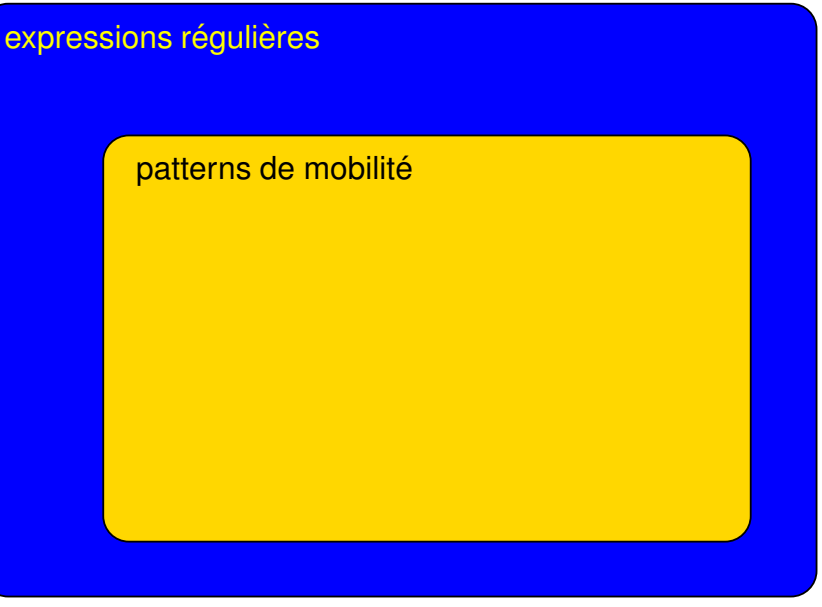

expressions régulières: n'ont pas toujours de sens
patterns de mobilité: ont un sens mais grande complexité

Expression vs complexité

Dans le pire des cas, le nombre d'états à maintenir est exponentiel dans le nombre de variables.

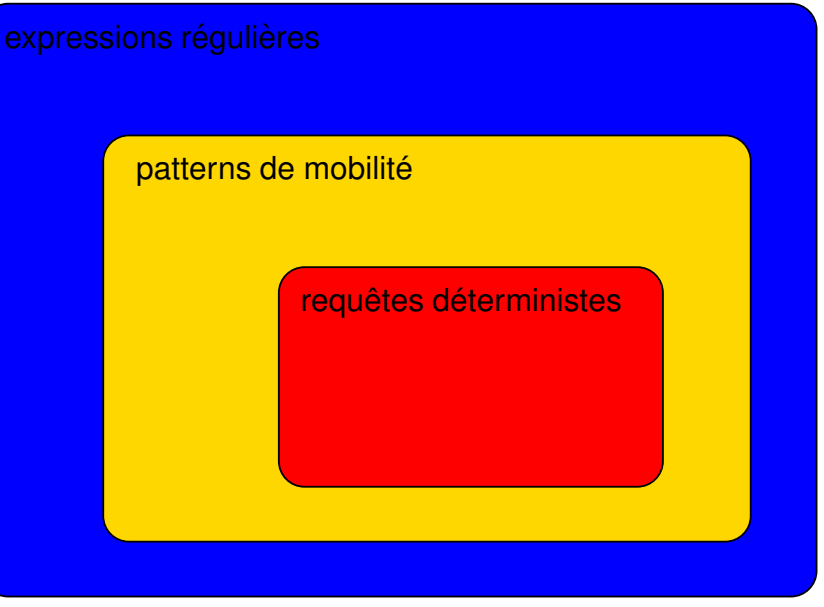

expressions régulières: n'ont pas toujours de sens

patterns de mobilité: ont un sens mais grande complexité

requêtes déterministes: moins expressives mais peu complexes

Expression vs complexité

Dans le pire des cas, le nombre d'états à maintenir est exponentiel dans le nombre de variables.

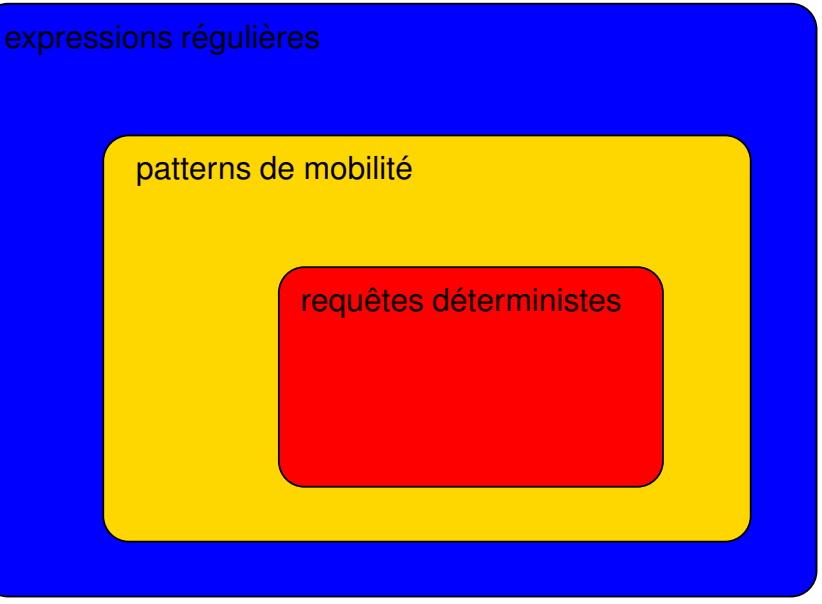

expressions régulières: n'ont pas toujours de sens
patterns de mobilité: ont un sens mais grande complexité
requêtes déterministes: moins expressives mais peu complexes

$\Rightarrow$ en réduisant le pouvoir d'expression en rendant l'instanciation des variables déterministe, le besoin en mémoire devient $|P| + |var(P)|$.

Exemple d'évaluation

Évaluation de $((a|b)^+.@x.(a|b)^+, \{@x \neq a, @x \neq b\})$

entrée	chaîne possible	chaîne impossible
a	a	
a.**a**	a.a	a.@x car a $\notin dom($@x$)$
a.a.**b**	a.a.b	a.@x.b car a $\notin dom($@x$)$ a.a.@x car b $\notin dom($@x$)$
a.a.b.**b**	a.a.b.b	a.@x.b.b car a $\notin dom($@x$)$ a.a.@x.b car b $\notin dom($@x$)$ a.a.b.@x car b $\notin dom($@x$)$
a.a.b.b.**c**	a.a.b.b.@x	

Principaux résultats

- un modèle de représentation des trajectoires sur un espace discrétisé
- un langage d'interrogation, sous-ensemble décidable des expressions régulières avec variables, expressif mais gourmand en mémoire ($|etats(\mathcal{A})| \times |\Sigma^k|$ statuts possibles par objet et par requête)
- un sous-ensemble du langage bien déterminé (décidabilité) garantissant de faibles besoins en mémoire ($|P| + |var(P)|$)

Ces travaux ont été présentés à *STDBM'04* et *GeoInformatica'05*.

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Objectif: évaluation d'une requête en ne testant qu'une fois chaque symbole.

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Objectif: évaluation d'une requête en ne testant qu'une fois chaque symbole.

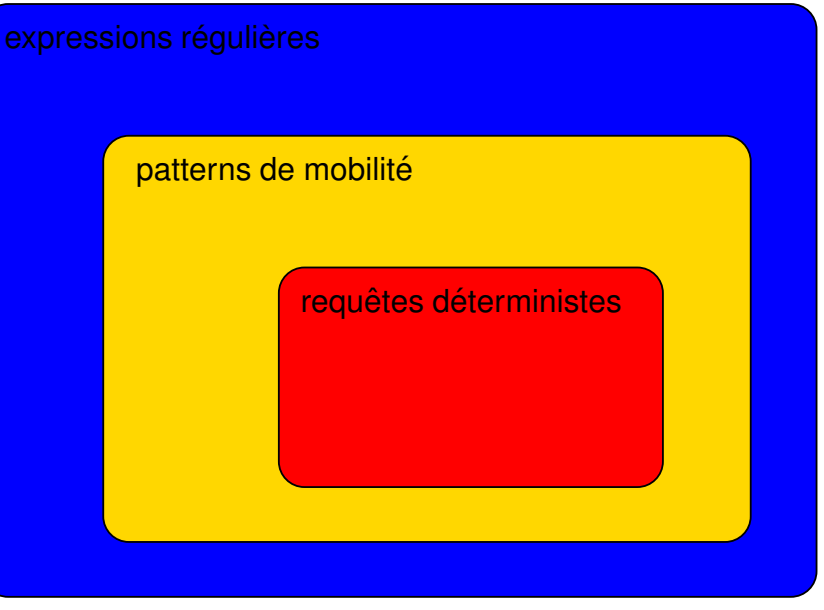

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Objectif: évaluation d'une requête en ne testant qu'une fois chaque symbole.

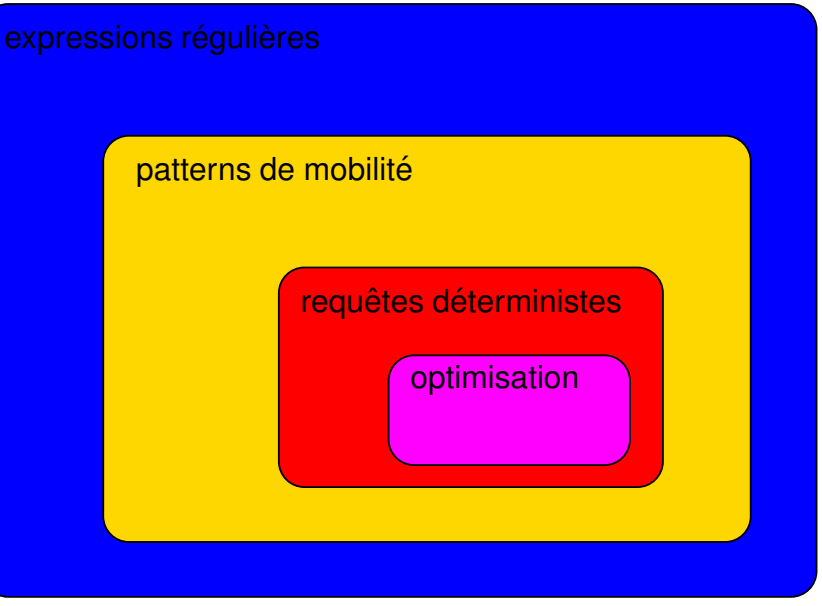

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Objectif: évaluation d'une requête en ne testant qu'une fois chaque symbole.

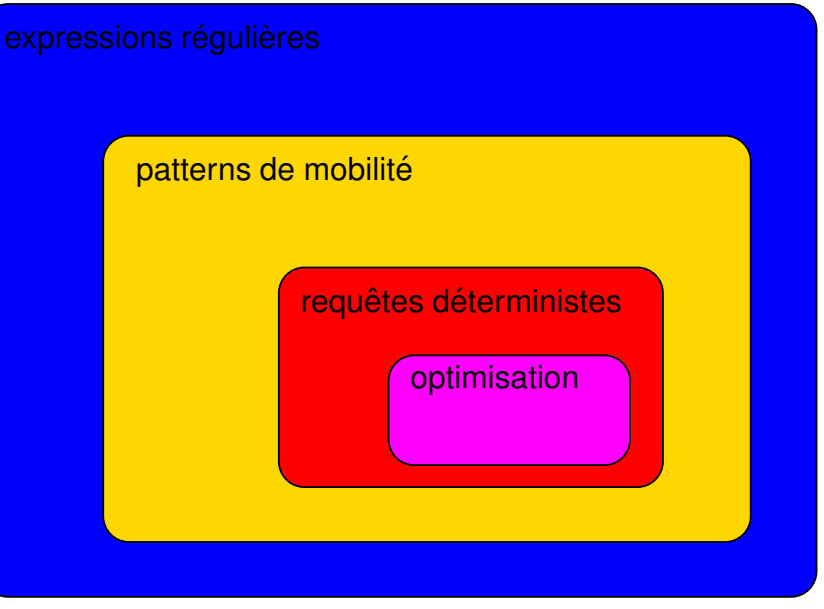

On évalue les patterns de la forme $t_1.t_2 \cdots t_n$ où $t_i \in (\Sigma \cup \mathcal{V})$.

Optimisation

Motivation: réception d'un flux *continu* d'information, pas le temps de re-tester des symboles.

Objectif: évaluation d'une requête en ne testant qu'une fois chaque symbole.

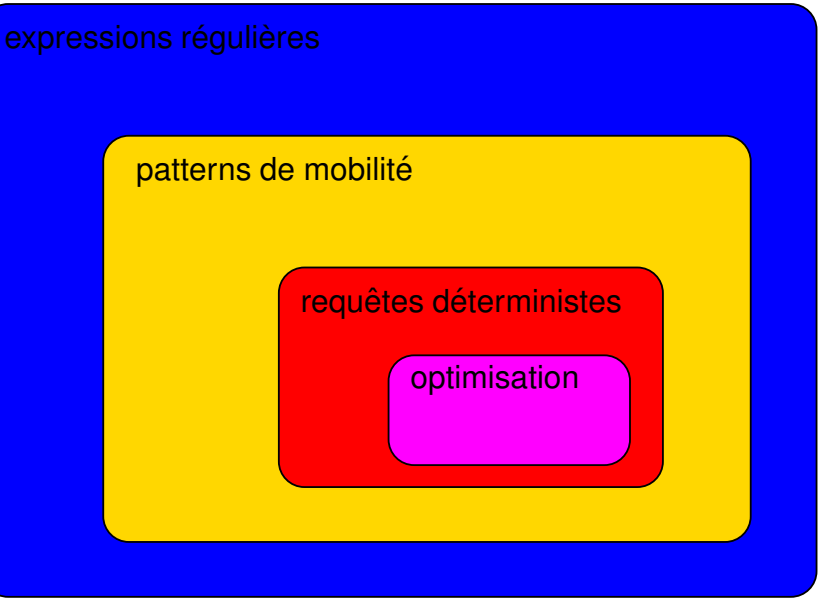

On évalue les patterns de la forme $t_1.t_2 \cdots t_n$ où $t_i \in (\Sigma \cup \mathcal{V})$.

Problème: on sait le faire sans variable (KMP), comment le faire avec des variables?

Évaluation sans variable

Technique naïve sans variable: en cas d'échec on décale de 1 et on recommence.

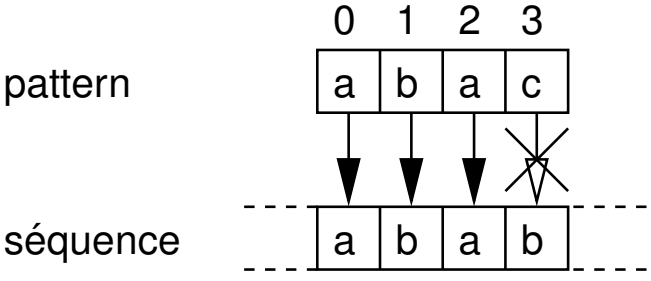

(a) échec à pos. 3

Évaluation sans variable

Technique naïve sans variable: en cas d'échec on décale de 1 et on recommence.

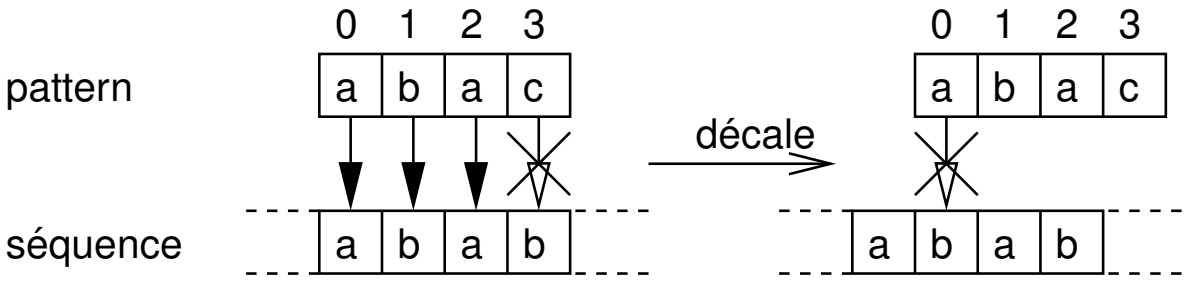

(a) échec à pos. 3 (b) échec à pos. 0

Évaluation sans variable

Technique naïve sans variable: en cas d'échec on décale de 1 et on recommence.

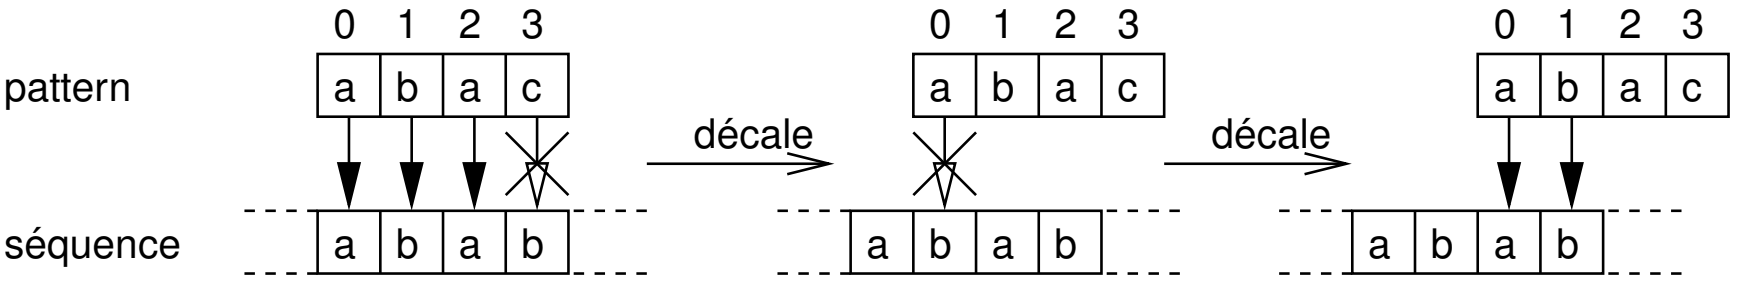

(a) échec à pos. 3 (b) échec à pos. 0 (c) reçoit une nouvelle étiquette

Évaluation avec variables

Technique naïve avec variable: en cas d'échec on décale de 1 et on recommence.

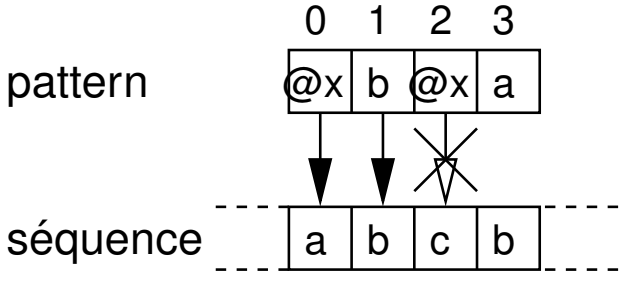

(a) `@x` liée à `a`

échec en pos. 2

Évaluation avec variables

Technique naïve avec variable: en cas d'échec on décale de 1 et on recommence.

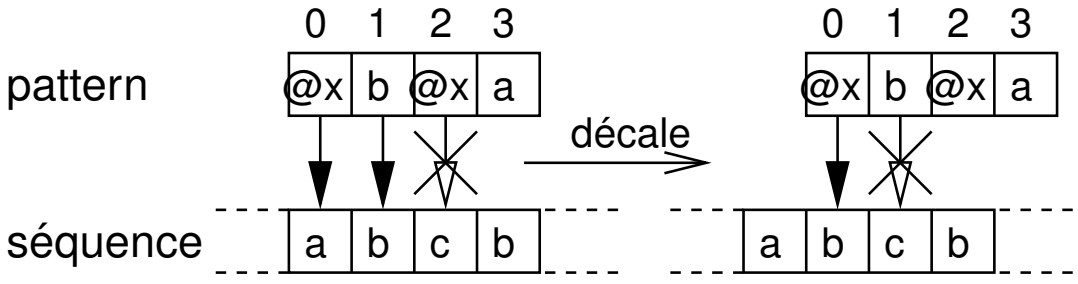

(a) `@x` liée à `a`
échec en pos. 2

(b) `@x` liée à `b`
échec en pos. 1

Évaluation avec variables

Technique naïve avec variable: en cas d'échec on décale de 1 et on recommence.

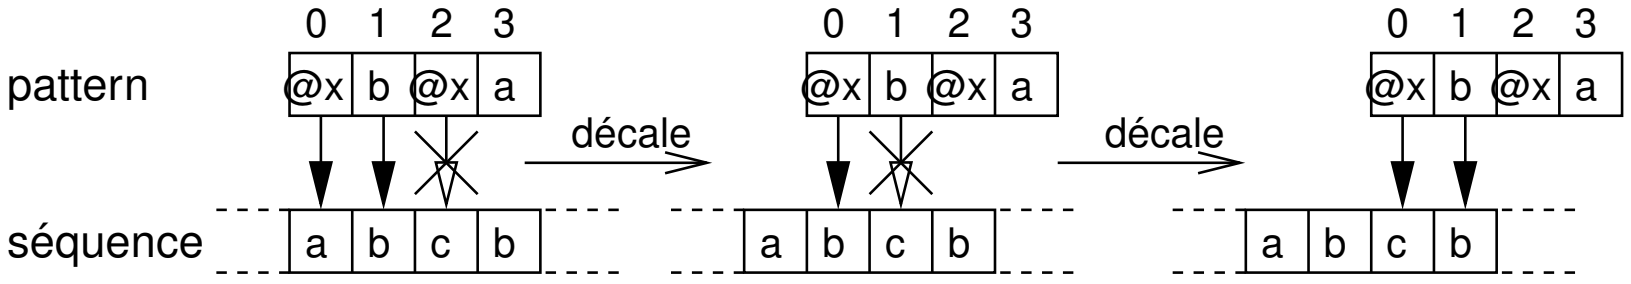

(a) `@x` liée à `a`
échec en pos. 2

(b) `@x` liée à `b`
échec en pos. 1

(c) attend un nouveau symbole

Intuition de l'optimisation

En cas d'échec, certaines comparaisons peuvent être évitées (KMP).

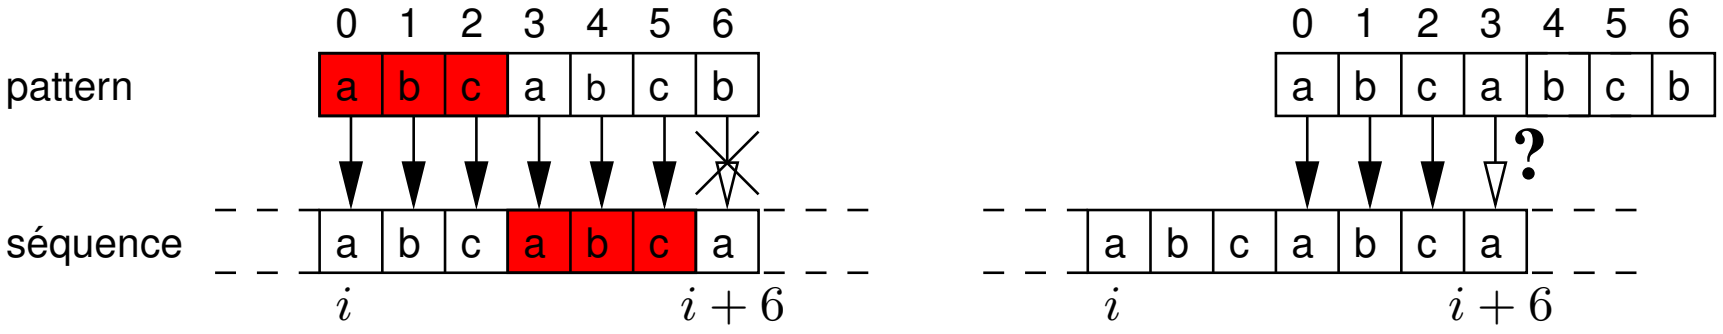

Intuition de l'optimisation

En cas d'échec, certaines comparaisons peuvent être évitées (KMP).

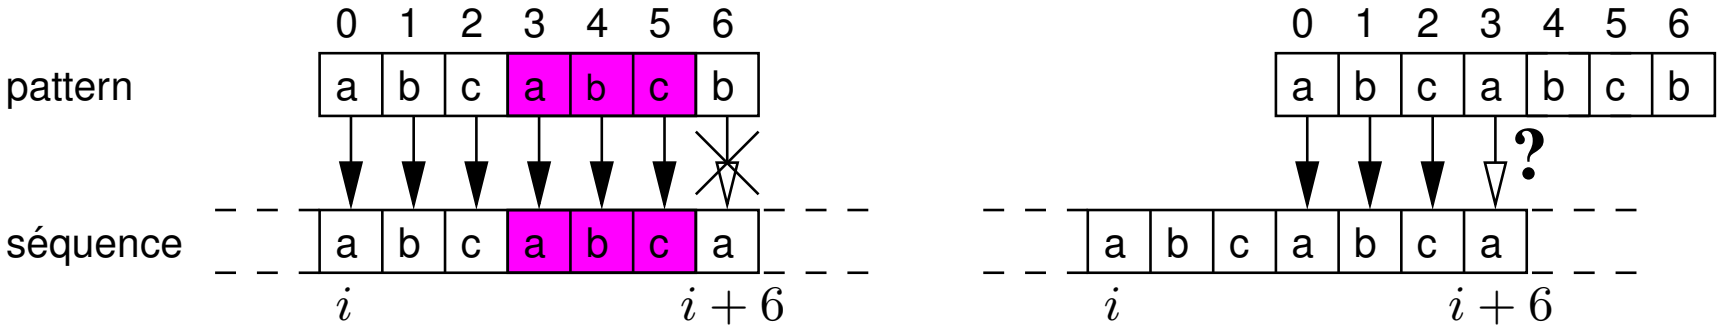

Intuition de l'optimisation

En cas d'échec, certaines comparaisons peuvent être évitées (KMP).

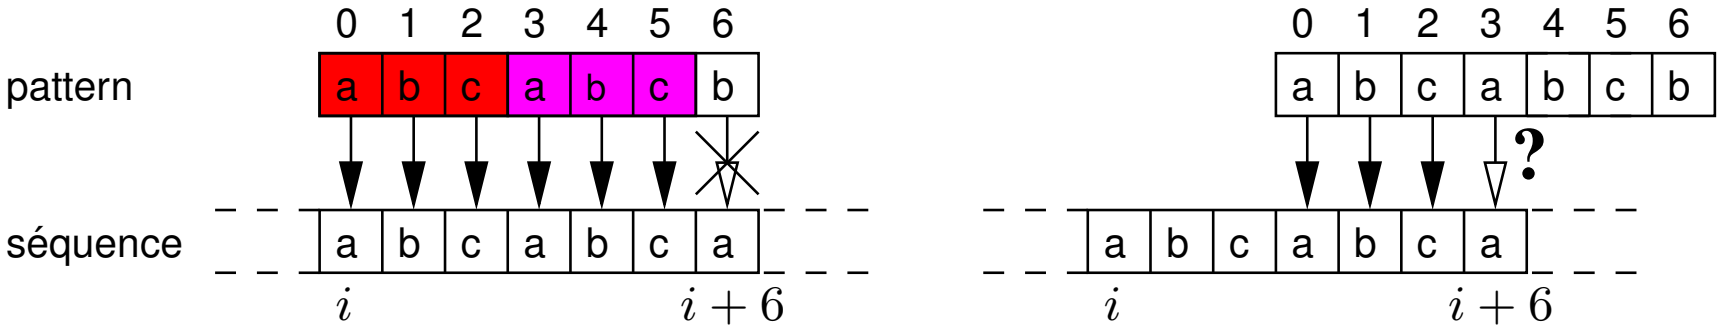

Intuition de l'optimisation

En cas d'échec, certaines comparaisons peuvent être évitées (KMP).

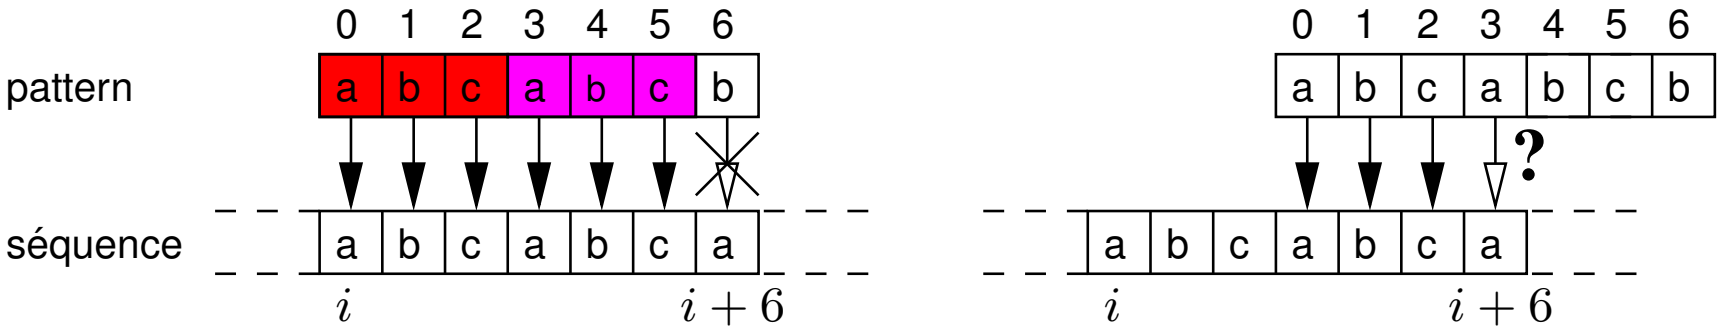

$\Rightarrow$ avant l'exécution il est possible de connaître les décalages à faire en cas d'échec.

KMP étendu

Comment adapter KMP pour nos patterns?

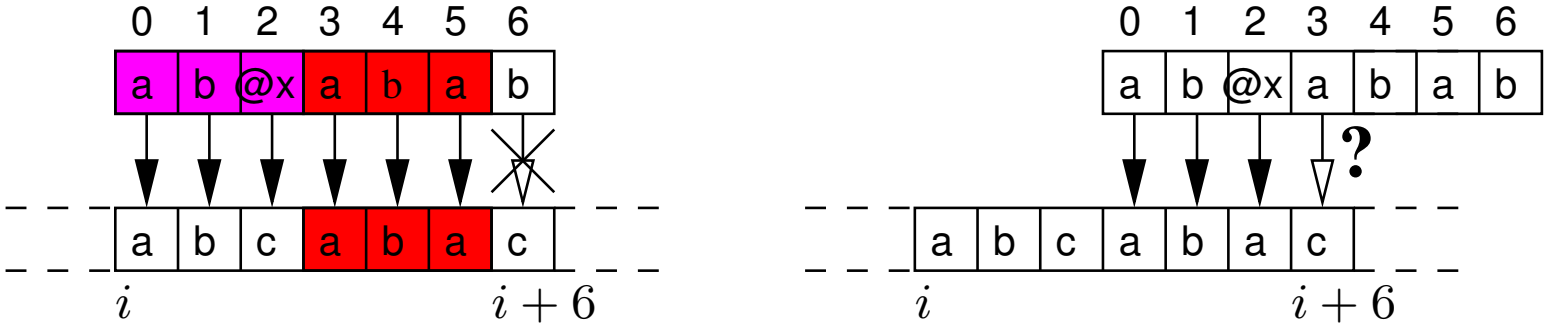

L'instanciation des variables du préfixe peut changer après un décalage.

KMP étendu

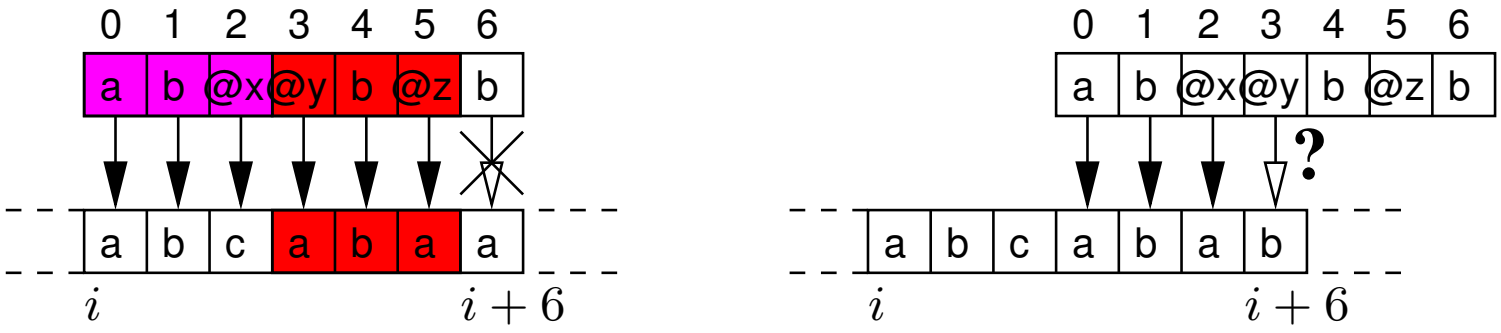

L'instanciation des variables du suffixe à une importance pour trouver le bon décalage.

Bords

Un bord d'un pattern est l'information composée de:

- les conditions sur l'instanciation des variables pour effectuer le décalage
- la longueur du décalage à réaliser
- l'instanciation en sortie des variables du pattern

Bords

Un bord d'un pattern est l'information composée de:

- les conditions sur l'instanciation des variables pour effectuer le décalage
- la longueur du décalage à réaliser
- l'instanciation en sortie des variables du pattern

Exemple: si $(3, \{\texttt{@y} = \texttt{b}\}, \{\texttt{@x} = \texttt{b}\})$ est un bord pour un pattern P de longueur m, alors en cas d'échec, si $\texttt{@y}$ est instanciée à $\texttt{b}$, alors on peut décaler pour reprendre au 4ème symbole et $\texttt{@x}$ devient instanciée à $\texttt{b} \longrightarrow$ bord

Exemples de bords

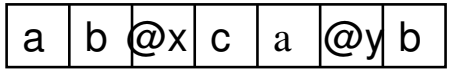

?

- $(0, \emptyset, \emptyset)$ bord par défaut (décalage de tout le pattern);

Exemples de bords

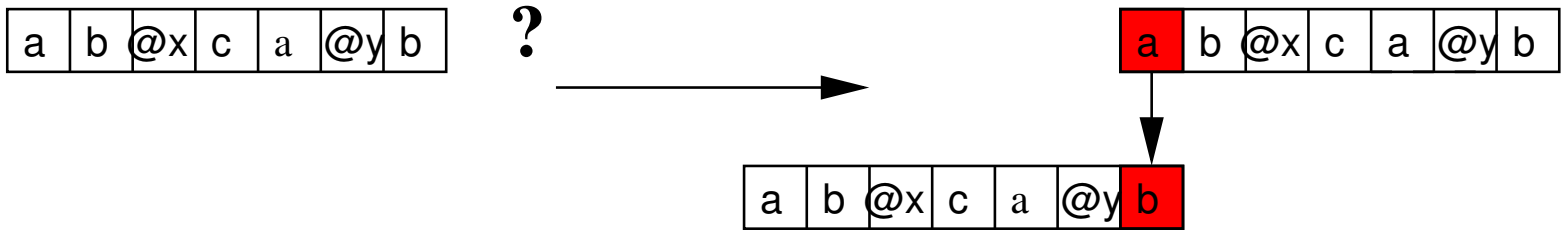

- $(0, \emptyset, \emptyset)$ bord par défaut (décalage de tout le pattern);
- pas de bord de longueur 1 existant car $\mathtt{a} \neq \mathtt{b}$

Exemples de bords

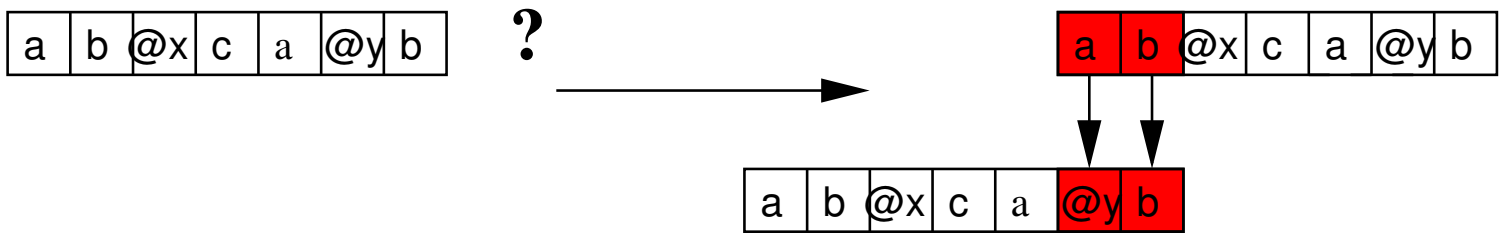

- $(0, \emptyset, \emptyset)$ bord par défaut (décalage de tout le pattern);
- pas de bord de longueur 1 existant car $\mathtt{a} \neq \mathtt{b}$
- $(2, \{\mathtt{@y}/\mathtt{a}\}, \emptyset)$, car si $\mathtt{@y}$ était instanciée à $\mathtt{a}$, alors on peut faire le décalage de 2

Exemples de bords

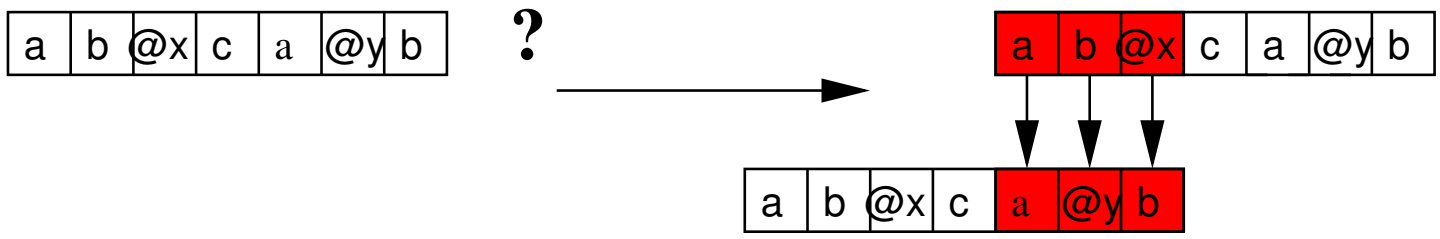

- $(0, \emptyset, \emptyset)$ bord par défaut (décalage de tout le pattern);
- pas de bord de longueur 1 existant car $\texttt{a} \neq \texttt{b}$
- $(2, \{\texttt{@y}/\texttt{a}\}, \emptyset)$, car si $\texttt{@y}$ était instanciée à $\texttt{a}$, alors on peut faire le décalage de 2
- $(3, \{\texttt{@y}/\texttt{b}\}, \{\texttt{@x}/\texttt{b}\})$, car si $\texttt{@y}$ était instanciée à $\texttt{b}$, alors on peut faire le décalage de 3 et $\texttt{@x}$ sera alors instanciée à $\texttt{b}$

Expérimentations

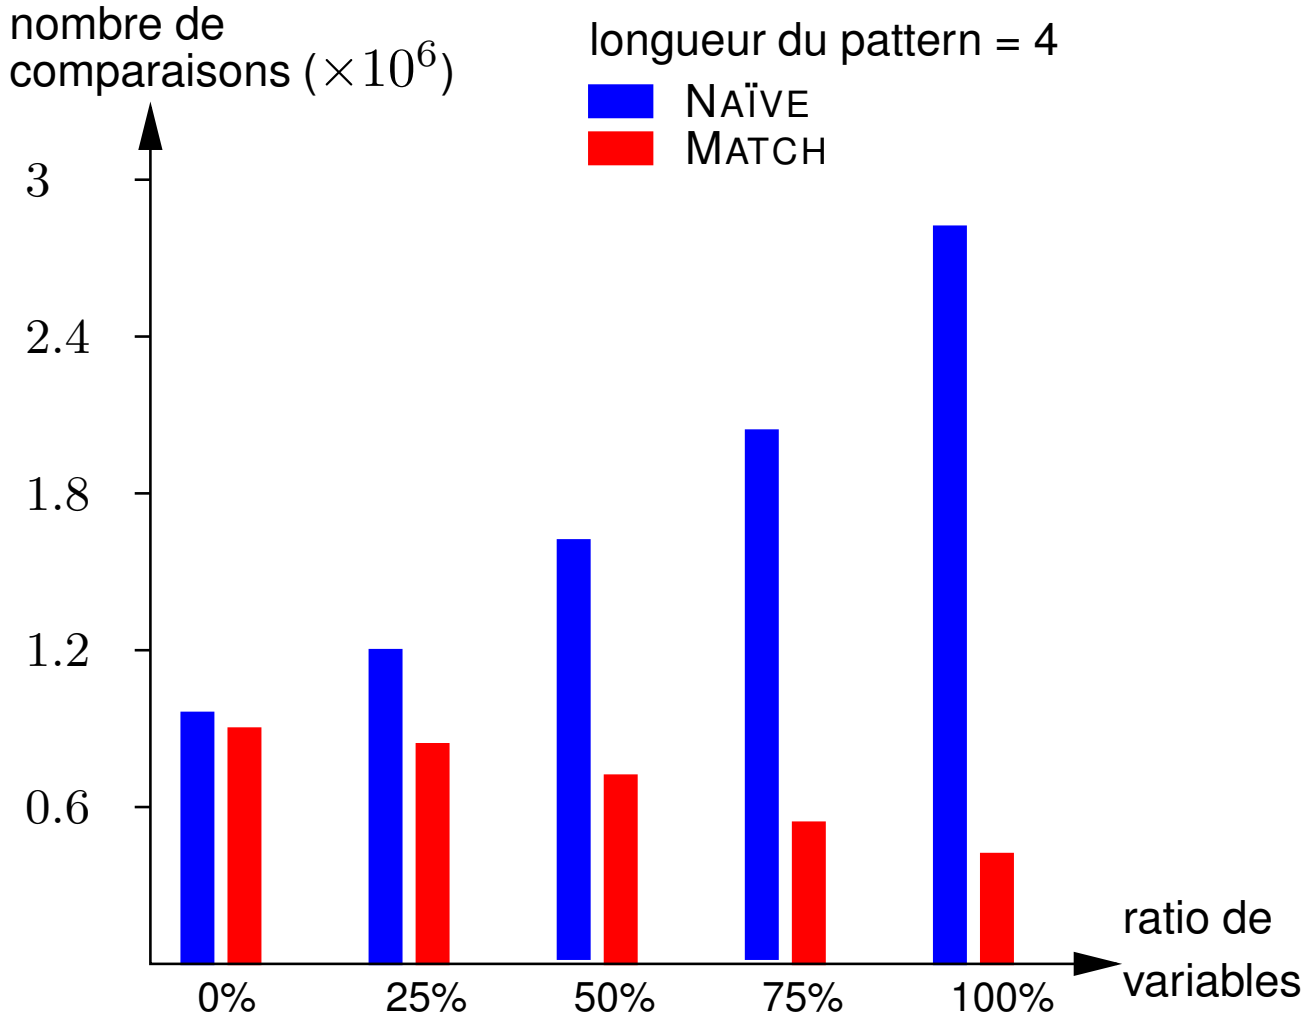

Résumé des contributions

- identification d'un sous-ensemble de patterns de mobilité
- définition d'un bord
- algorithme de construction quadratique de la table des bords
- complexité linéaire de l'évaluation au lieu d'une évaluation naïve quadratique
- expérimentations

Ces résultats ont été présentés à *CIKM'05*.

Autre aspect abordé: multi-échelle

L'espace considéré est partitionné à différent niveaux de granularité $\Rightarrow$ arbre d'inclusion pour les zones.

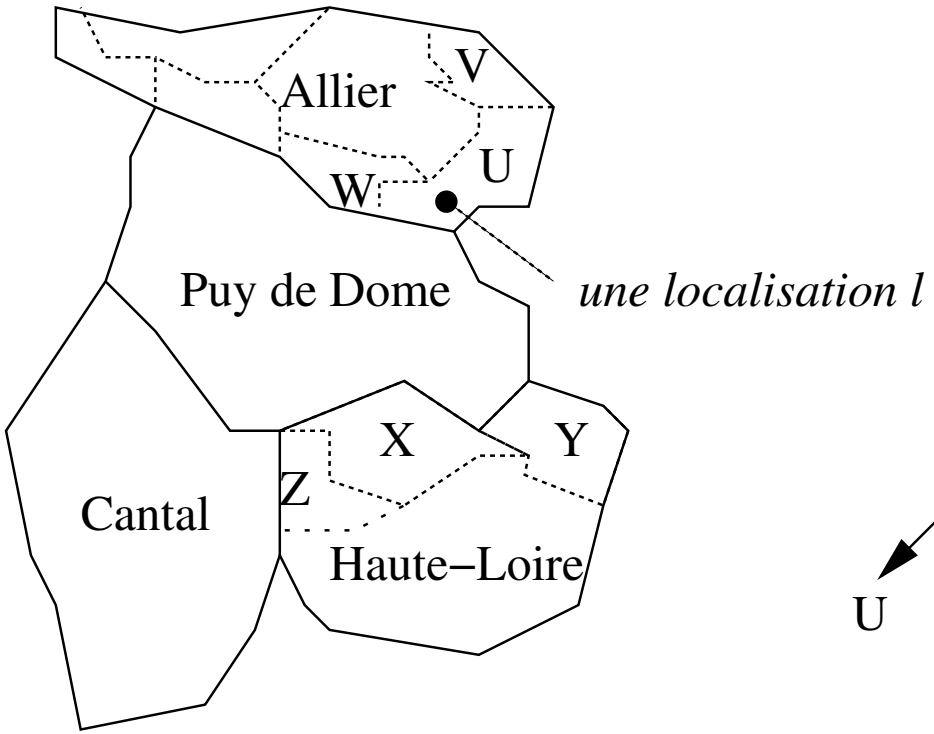

a. l'espace de référence

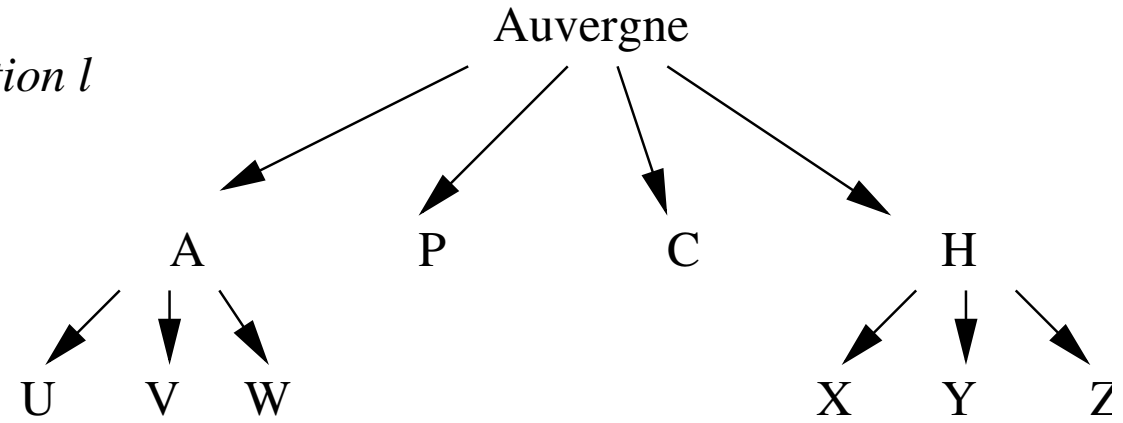

b. sa représentation

Intérêt des niveaux d'échelle

Les niveaux d'échelle permettent:

- d'adapter l'espace considéré aux besoins de l'utilisateur
- en passant à un niveau plus grossier, d'agréger des trajectoires ayant un comportement proche mais distinct à un niveau plus fin
- en passant à un niveau plus fin, de distinguer des trajectoires ayant un comportement semblable à un niveau plus grossier

Exemples

Soit $N1$ le niveau d'échelle des départements et $N3$ celui mixte villes/départements.

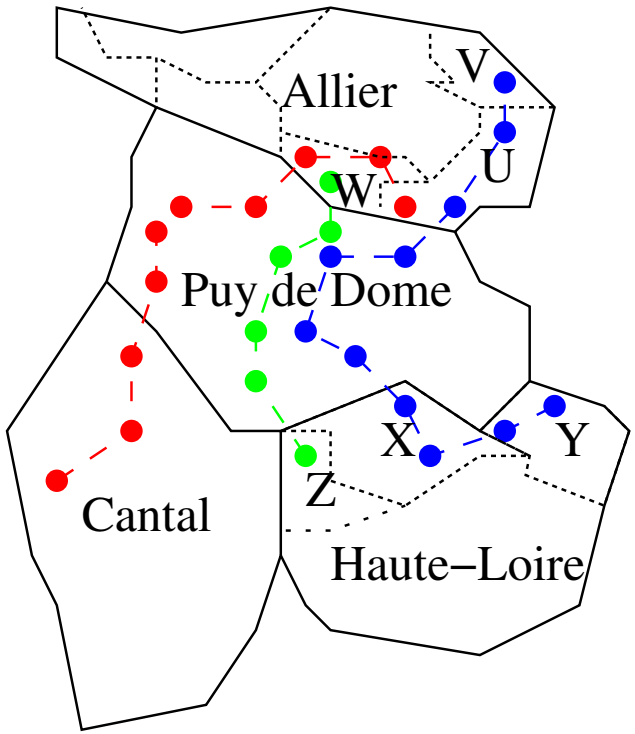

pattern(t1,N1) = A.P.C

pattern (t1,N3) = U.W.P.C

pattern(t2,N1) = H.P.A

pattern(t2,N3) = Y.X.P.U.V

pattern(t3,N1) = H.P.A

pattern(t3,N3) = Z.P.W

Clustering

Objectif: utiliser un pattern plus *générique* pour filtrer les événements à tester sur un ensemble de patterns.

Pourquoi? Si une trajectoire ne satisfait pas le pattern *générique*, aucune chance de satisfaire les patterns plus précis.

Exemple: si une trajectoire ne satisfait pas le pattern $H.P.A$ elle ne peut satisfaire ni *Brioude-Riom-Allier*, ni *Haute-Loire - Puy de Dôme - Vichy*, ni *Haute-Loire - Issoire - Montluçon*

Résumé des contributions

- description d'une carte multi-échelle et définition d'un niveau d'échelle
- relation d'ordre partielle entre patterns et calcul de *lub*
- technique de classification et de clustering de trajectoires s'appuyant sur le multi-échelle

Ces travaux ont été présentés à *SSDBM'04*.

Implantation

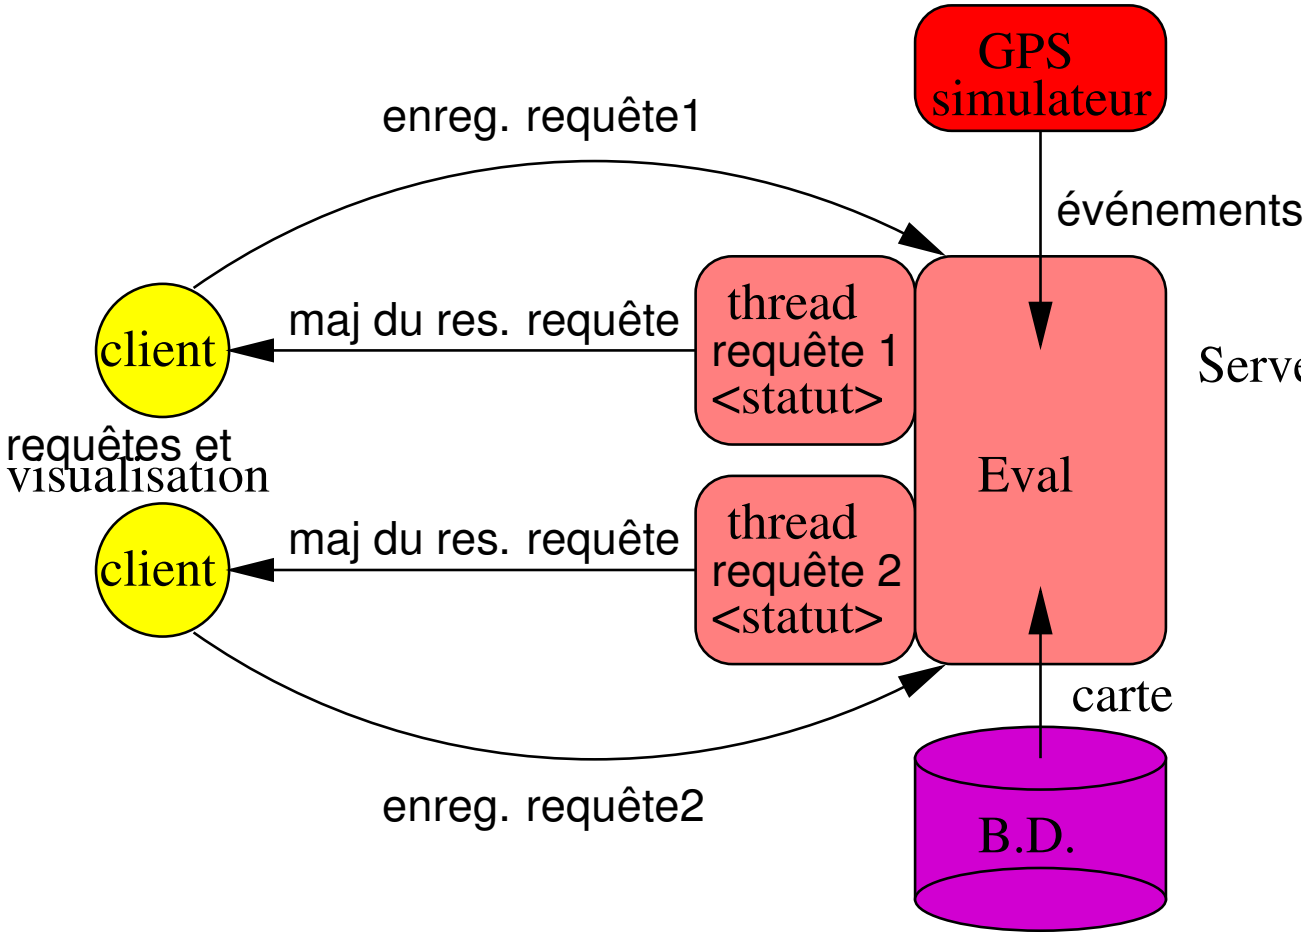

Perspectives

Les trois axes de ma recherche actuelle et future sont:

- le clustering de patterns avec variables
- un nouvel index: le SDR tree
- l'indexation d'images

Perspectives: clustering

Objectif: trouver une structure pour optimiser l'évaluation quand il y a beaucoup de patterns

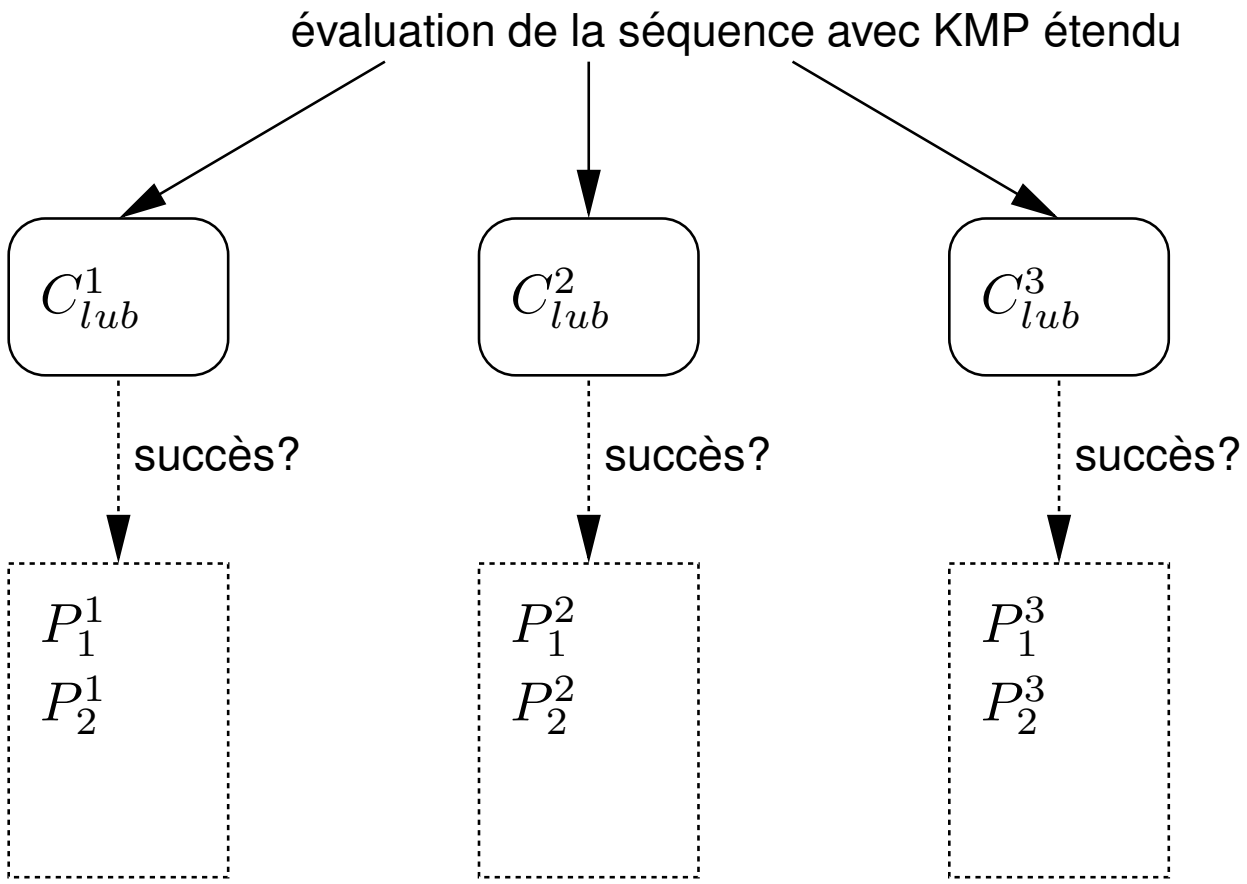

Perspectives: SDRtree

Travail sur un index spatial ayant les propriétés suivantes:

- piloté par les données, avec un algorithme d'éclatement semblable au Rtree
- binaire car chaque nœud interne couvre exactement 2 nœuds
- équilibré
- distribué parce qu'il y a une correspondance un-à-un entre les feuilles et les sites
- problème: minimiser le nombre de messages échangés entre clients/serveurs et serveurs/serveurs pour maintenir et utiliser la structure

Merci

Merci pour votre attention.

Merci...

Nunc est bibendum...