

**9 novembre 2004**

# **Fouille de Données Spatio Temporelles et Optimisation multi-critères**

**Nicolas Tarrisson & Michèle Sebag**

IA – TAO, CNRS – INRIA

Université Paris-Sud Orsay

[Wiki:StagesTao]

# Contexte


## Neuro-imagerie

- Des sujets, une expérience, des mesures



- Une nouvelle technologie : électro-magnéto-encéphalographie.  
pas de temps: .001 seconde

# Les données



## Structure (3D - 2D)

- Courbes  $i = 1..N$
- $i \rightarrow M_i = (x_i, y_i, z_i), X_i[t], t = 1..T$

# Le but

## Trouver des motifs spatio-temporels

- Une aire  $A$  : Boule  $\mathcal{B}(M_A = (x_A, y_A, z_A), d_A, \varepsilon_A)$
- Un intervalle temporel  $I \subset \{1..T\}$

caractérisant

$$\mathcal{V}(A, T) = \{X_k[t], t \in I, k \text{ tq } d_A(M_k, M_A) < \varepsilon_A\}$$

tel que

deviation standard ( $\mathcal{V}(A, T)$ ) faible

## Procédure courante

- à la main  $\rightarrow$  i) ennuyeux; ii) subjectif
- peu de volontaires.

# Grandes lignes

## Propriétés voulues

- Passage à l'échelle
- Flexible  $\Rightarrow$  Paramétrable  $\Rightarrow$  Doit être calibré

$\Rightarrow$  Contrôle des ressources possible - Algorithme anytime

## Discussion

- critères monotones (en  $\varepsilon_A$ , en  $I$ )
- critères antagonistes ( $I \nearrow$ ,  $\varepsilon_A \searrow$ )
- exhaustivité ? Non : le résultat doit être vu par un humain.

# Optimisation multi-critères

## Optimisation classique

Trouver  $ArgMax\{\mathcal{F}(x), \mathcal{F} : \Omega \rightarrow \mathbb{R}\}$

## Optimisation multi-critères

Trouver  $ArgMax\{\mathcal{F}_i, i = 1, 2, \dots, \mathcal{F}_i : \Omega \rightarrow \mathbb{R}\}$

Evidemment,  $\mathcal{F}_i$  antagonistes.

De qualité maximale, de prix minimal...


# Front de Pareto

## Domination de Pareto

- $x < y$  ssi  $\mathcal{F}_i(x) \leq \mathcal{F}_i(y)$  et inégalité stricte pour au moins un  $i$ .

## Front de Pareto

- Ensemble des solutions non dominées.



# Stable Spatio-Temporal Patterns

## Espace de recherche

$X =$

$I_X$  intervalle temporel

$k$   $M_k$  centre de la boule spatiale

$r$  rayon de la boule spatiale

$d_w = (a, b, c)$  distance pondérée

avec

$$d_w(M_k, M_j) = a.(x_k - x_j)^2 + b.(y_k - y_j)^2 + c.(z_k - z_j)^2$$

## Futur

$d_w \rightarrow$  : matrice  $W$ ,  $\|M_k - M_j\|_W = (M_k - M_j)^t . A . (M_k - M_j)$

# Critères de dominance

$$X = (I = [deb, fin], k (M_k \text{ centre}), d_w = (a, b, c), r)$$

- Longueur temporelle  $l(X) = fin - deb$
- Le voisinage spatial  $\mathcal{V}(X) = \{j / d_w(M_k, M_j) < r\}$
- La taille  $|X| = l(X) \cdot |\mathcal{V}(X)|$
- La cohérence spatiale

$$a(X) = \sum_{j \in \mathcal{V}(X)} e^{-d_w(M_k, M_j)}$$

- La cohérence spatio-temporelle

$$\rho(X) = \text{sum}_{j \in \mathcal{V}(X)} \rho_I(X_k, X_j)$$

Où  $\rho_I(X_k, X_j) = \text{covariance}(X_k[t], X_j[t])$  pour  $t$  dans l'intervalle  $I$ .

# EC Multi-critères

## EC classique

Trouver  $ArgMax(\mathcal{F})$

- Initialisation
- Variations (croisement, mutation)
- Sélection

## Problème multi-critères

Trouver  $X = ArgMax\{l(X), a(X), \rho(X)\}$

## Modifications essentielles

But : couvrir le front de Pareto

Archive

Sélection : d'après  $\mathcal{F}'(x)$ , où  $\mathcal{F}'$  mesure :

Le rang de Pareto de  $x$  dans la population courante

Le pourcentage de l'archive dominé par  $x$

...

# Initialisation

## Tirage des intervalles temporels

Tirage  $i$  uniforme in  $[1, ..T]$

Tirage  $\ell \sim \mathcal{N}(L, \sigma)$

$I = [i, i + \ell]$

Paramètres

Nombre  $n_T$

$L, \sigma$

## Commentaires

Intervalles diversifiés de longueur faible, mais admissible

Initialisation de  $d_w = (1, 1, 1)$

pour commencer

Futur : connaissances du domaine

# Initialisation, suite

## Initialisation des motifs

Pour tout  $I$  exhaustif sur les intervalles tirés  
Pour tout  $k = 1..N$  exhaustif sur les capteurs

1. Ordonner  $M_j$  par  $d_w(M_k, M_j)$  croissant
2. Soit  $\mathcal{V}(I, k) = \min\{j / d_w(M_k, M_j) < \text{Seuil}_d\}$
3. Si  $|\mathcal{V}(I, k)| > \text{Seuil}_c$ , alors
  - $r = \max\{d_w(M_k, M_j) / j \in \mathcal{V}(I, k)\}$
  - Population  $\cup = \{X = (I, k, w, r)\}$

# Opérateurs de Variation

$$X = (I = [deb, fin], k (M_k \text{ centre}), d_w = (a, b, c), r)$$

## Mutation

- Muter  $w$  ou  $r$  mutation auto-adaptative
- Incrémenter/Décémenter  $deb$
- Incrémenter/Décémenter  $fin$
- Muter  $k$  (en l'un des capteurs voisins)

# Premiers essais

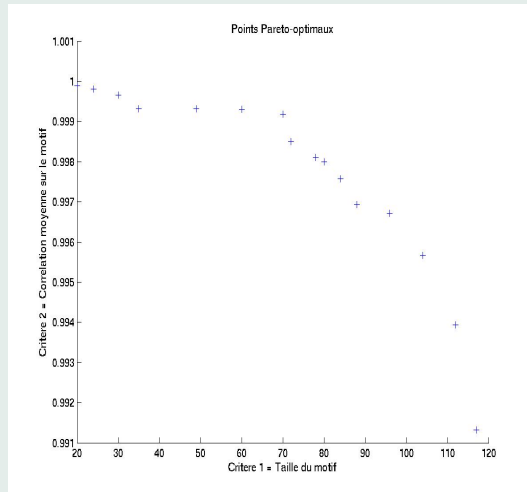
## Problème

Trouver  $X = \text{ArgMax}\{l(X), a(X), \rho(X)\}$

## Echec

déte t  par visualisation

Pas de vari t  : les Pareto dominants sont des variantes de la m me zone.



# Relaxation des critères

## Domination ensembliste

$$A \subset_p B =_{def} |A \cap B| > p|A|$$


**Critère agrégé de dominance**  $X = (I, k, w, r) \prec X' = (I', k', w', r')$   
ssi

- $I \subset_p I'$
- $\mathcal{V}(X) \subset_p \mathcal{V}(X')$
- $a(X') \geq a(X)$  AND  $l(X')^\alpha \rho(X') \geq l(X)l(X)^\alpha \rho(X)$
- $a(X') > a(X)$  OR  $l(X')^\alpha \rho(X') > l(X)l(X)^\alpha \rho(X)$


## Futur

Ajuster  $\alpha$  et  $p$ .


# Avec Pareto dominance ajustée




# Motif 1




# Motif 2



# Motif 3



# Motif 4

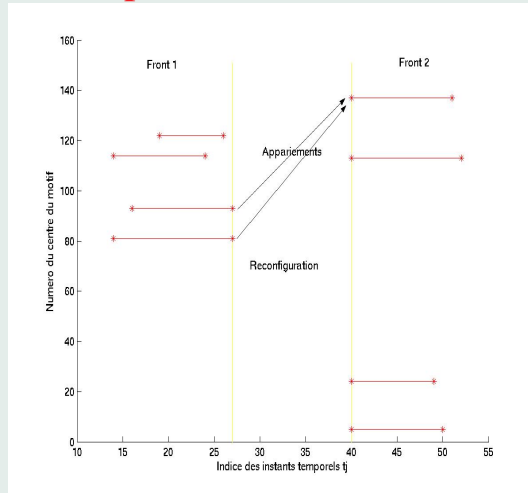


# Du point de vue de l'expert

Construire des scénarios

telle zone “passe le témoin” à telle autre zone.

Appariement temporel simple



# Alternatives

## Independent Component Analysis

- Les aires spatiales se recombinent.
- Disposer des intervalles temporels ?

## FD Spatio-temporelle

- Essentiellement spatio ou temporelle.
- Spatiale :
  - segmentation
  - analyse de dépendances
  - deviations et outliers
  - tendances
  - generalisation, caractérisation