

Conception de métaheuristiques pour l'optimisation dynamique. Application à l'analyse de séquences d'images IRM.

par **Julien Lepagnot**

sous la direction de **Patrick Siarry**

Co-encadré par **Amir Nakib** et **Hamouche Oulhadj**

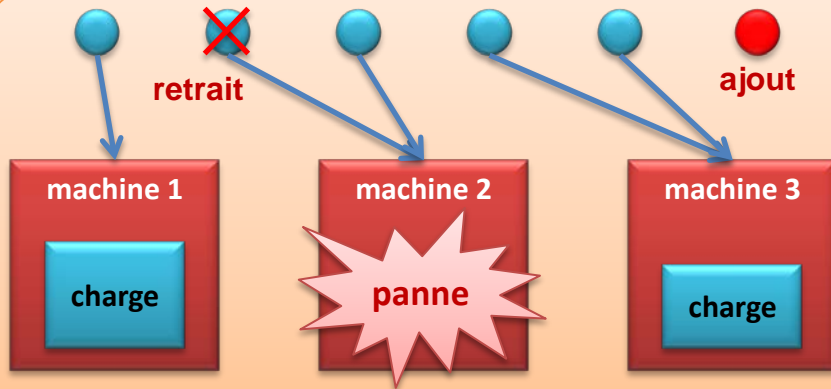
Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives

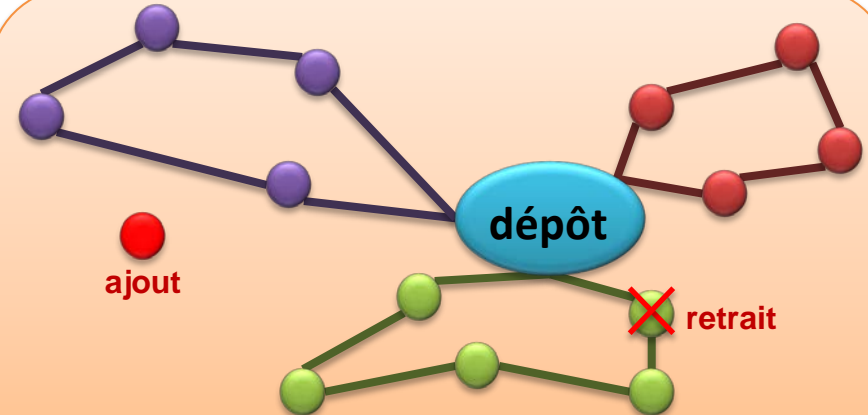
Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADDO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives


1.1. Problèmes d'optimisation dynamique




Le problème d'affectation de tâches



Le problème de tournées de véhicules



Compression du signal



Estimation du mouvement dans une séquence


1.2. Formulation d'un pb. d'optimisation dynamique (mono-objectif)

En optimisation dynamique, la fonction objectif change au cours du temps. Soit :

- un espace de recherche S
- une fonction objectif f
- **le temps t**

Dans le cas d'une minimisation, on cherche $s^*(t)$ telle que :

$$s^*(t) = \arg \min_{s \in S} f(s, t)$$



Jeux de tests :

- *Moving Peaks Benchmark* [Branke, 1999]


Beaucoup d'auteurs l'utilisent.

- *Generalized Dynamic Benchmark Generator* [Li et al., 2008]


Récent et en émergence, utilisé durant la compétition du congrès *IEEE Congress on Evolutionary Computation* (CEC'2009)

1.3.1.

Moving Peaks Benchmark (1 / 2)



(a) Avant un changement



(b) Après un changement

MPB consiste en un ensemble de pics dont la hauteur, la largeur et la position peuvent varier au cours du temps (après un certain nombre d'évaluations de la fonction).

Ce problème est paramétrable, et a été adopté par une majorité d'auteurs.


| Paramètre | Scénario 2 |
|--|------------|
| Nombre de pics | 10 |
| Dimension | 5 |
| Hauteur des pics | [30, 70] |
| Largeur des pics | [1, 12] |
| Nombre d'évaluations d'un <i>time span</i> * | 5000 |
| Sévérité des déplacements des pics | 1 |
| Sévérité des changements de hauteur des pics | 7 |
| Sévérité des changements de largeur des pics | 1 |
| Coefficient d'auto-corrélation des déplacements des pics | 0 |

* **Time span** : Plage d'évaluations de f durant laquelle la fonction objectif ne change pas.
Un changement de la fonction objectif se produit ici toutes les 5000 itérations.


Offline error : Moyenne des écarts entre l'optimum global et la meilleure solution trouvée à chaque évaluation (Une erreur de 0 signifie un suivi parfait de l'optimum).

$$oe = \frac{1}{N_c} \sum_{j=1}^{N_c} \left(\frac{1}{N_e(j)} \sum_{i=1}^{N_e(j)} (f_j^* - f_{ji}^*) \right)$$


1.3.2. Generalized Dynamic Benchmark Generator (1 / 2)



Composition of Ackley's function



Composition of Rastrigin's function



Composition of Griewank's function

- ✓ Le jeu de tests GDBG est constitué de 49 fonctions dynamiques. Il y a un score global, le maximum possible est de 100.
- ✓ L'ensemble de ces fonctions est supposé être représentatif de la plupart des problèmes d'optimisation dynamique réels.
- ✓ Divers types de changements, plus ou moins chaotiques et brutaux, ont lieu après un certain nombre d'évaluations de la fonction (*time span*, comme sur MPB).
- ✓ Ce problème est paramétrable, et a été utilisé lors de la compétition de CEC'2009.

1.3.2. Generalized Dynamic Benchmark Generator (2 / 2)

Chaque fonction dynamique est basée sur une fonction statique.
A chaque *time span*, une opération de changement lui est appliquée.

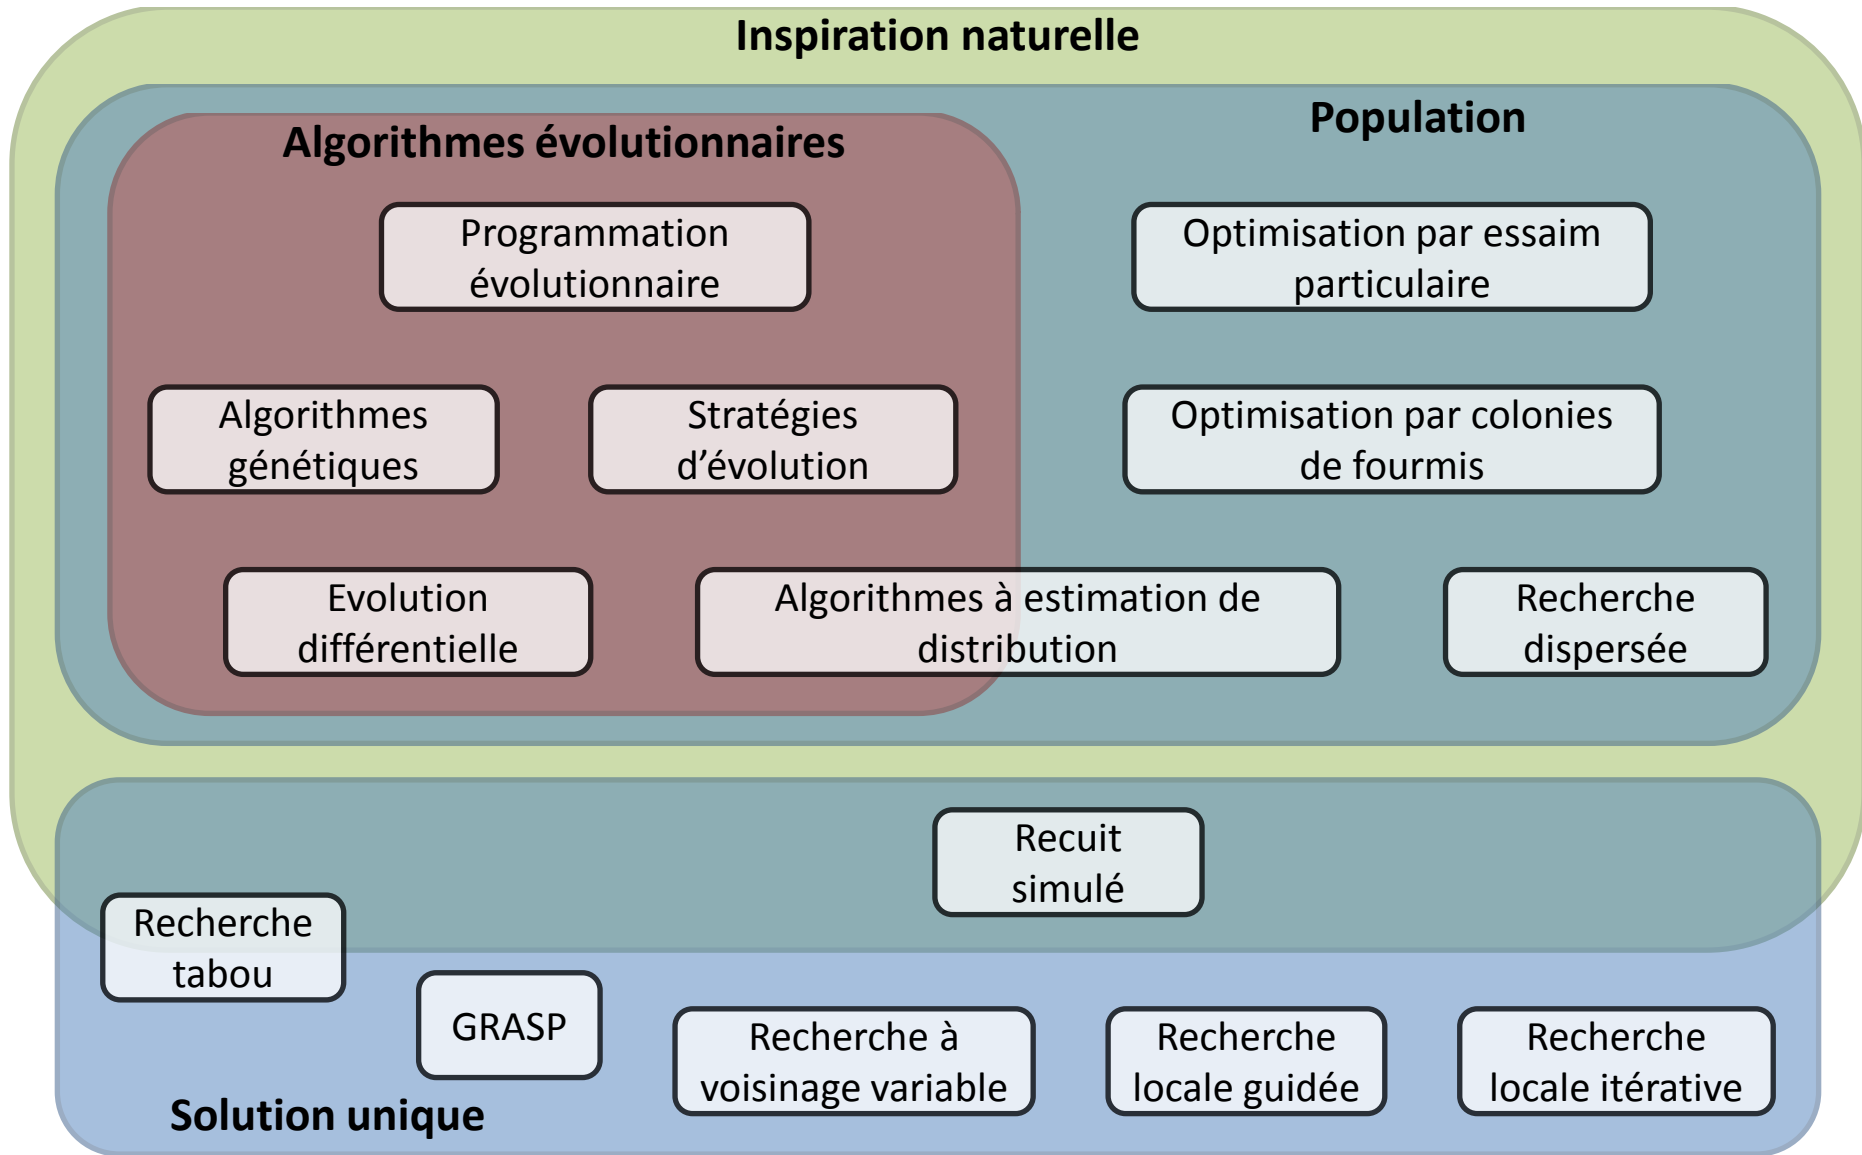
Il existe 6 fonctions statiques :

- F1: *Rotation peak function*
- F2: *Composition of Sphere's function*
- F3: *Composition of Rastrigin's function*
- F4: *Composition of Griewank's function*
- F5: *Composition of Ackley's function*
- F6: *Hybrid Composition function*

Il existe 7 opérations de changement :

- T1: *Small step*
- T2: *Large step*
- T3: *Random*
- T4: *Chaotic*
- T5: *Recurrent*
- T6: *Recurrent change with noise*
- T7: *Random change with changed dimension*

1.4. Les métaheuristiques : classification



1.5. Les métaheuristiques en optimisation dynamique

Inspiration naturelle

Algorithmes évolutionnaires

Programmation
évolutionnaire

Algorithmes
génétiques

Stratégies
d'évolution

Evolution
différentielle

Algorithmes à estimation de
distribution

Population

Optimisation par essaim
particulaire

Optimisation par colonies
de fourmis

Recherche
dispersée

Recuit
simulé

Recherche
tabou

GRASP

Recherche à
voisinage variable

Recherche
locale guidée

Recherche
locale itérative

Solution unique

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

Prédire les futurs changements [Rossi et al., 2008]

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

Prédire les futurs changements [Rossi et al., 2008]

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

Prédire les futurs changements [Rossi et al., 2008]

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

Prédire les futurs changements [Rossi et al., 2008]

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

Prédire les futurs changements [Rossi et al., 2008]

Adaptation des métaheuristiques d'optimisation statique



Introduire de la diversité après un changement [Cobb, 1990]

Maintenir la diversité tout au long de la recherche [Grefenstette, 1992]

Mémoriser des informations sur les « états » passés [Yang & Yao, 2008]

Plusieurs populations de solutions [Branke et al., 2000; Parrott & Li, 2004]

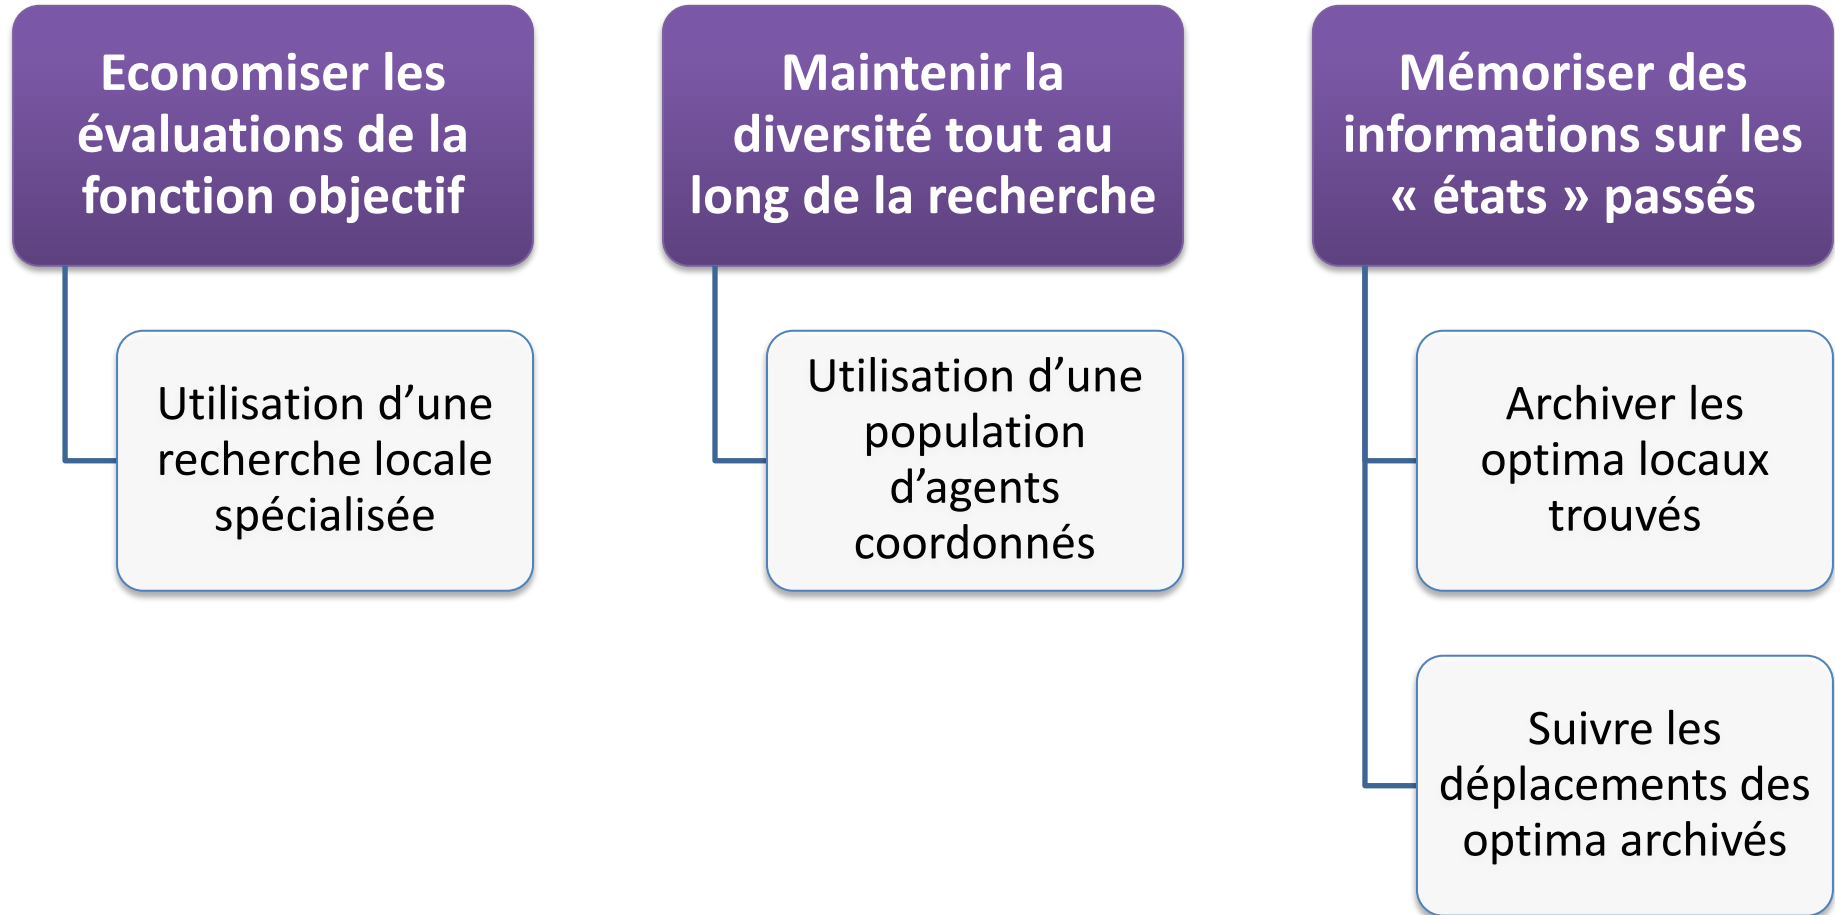
Prédire les futurs changements [Rossi et al., 2008]

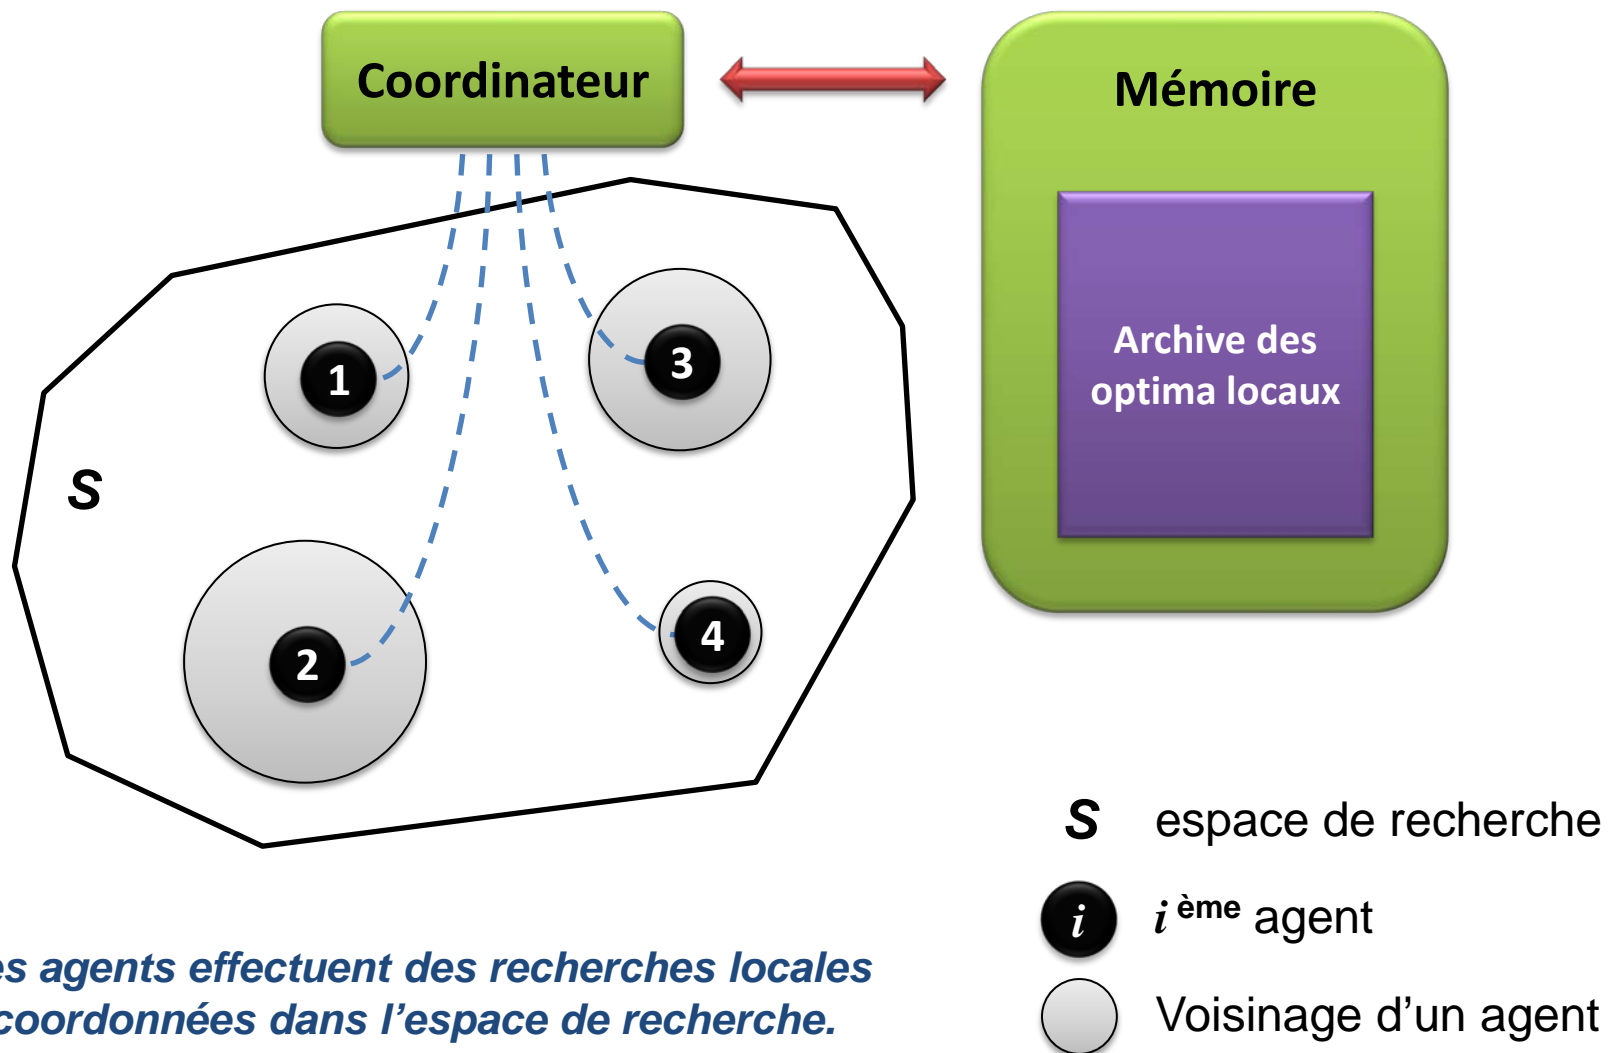
Plan

1. Introduction à l'optimisation dynamique
- 2. L'algorithme MADO**
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives


2.1. Multi-Agent based algorithm for Dynamic Optimization

Objectifs à atteindre via MADO





Les agents effectuent des recherches locales coordonnées dans l'espace de recherche.



● Solution courante (position)

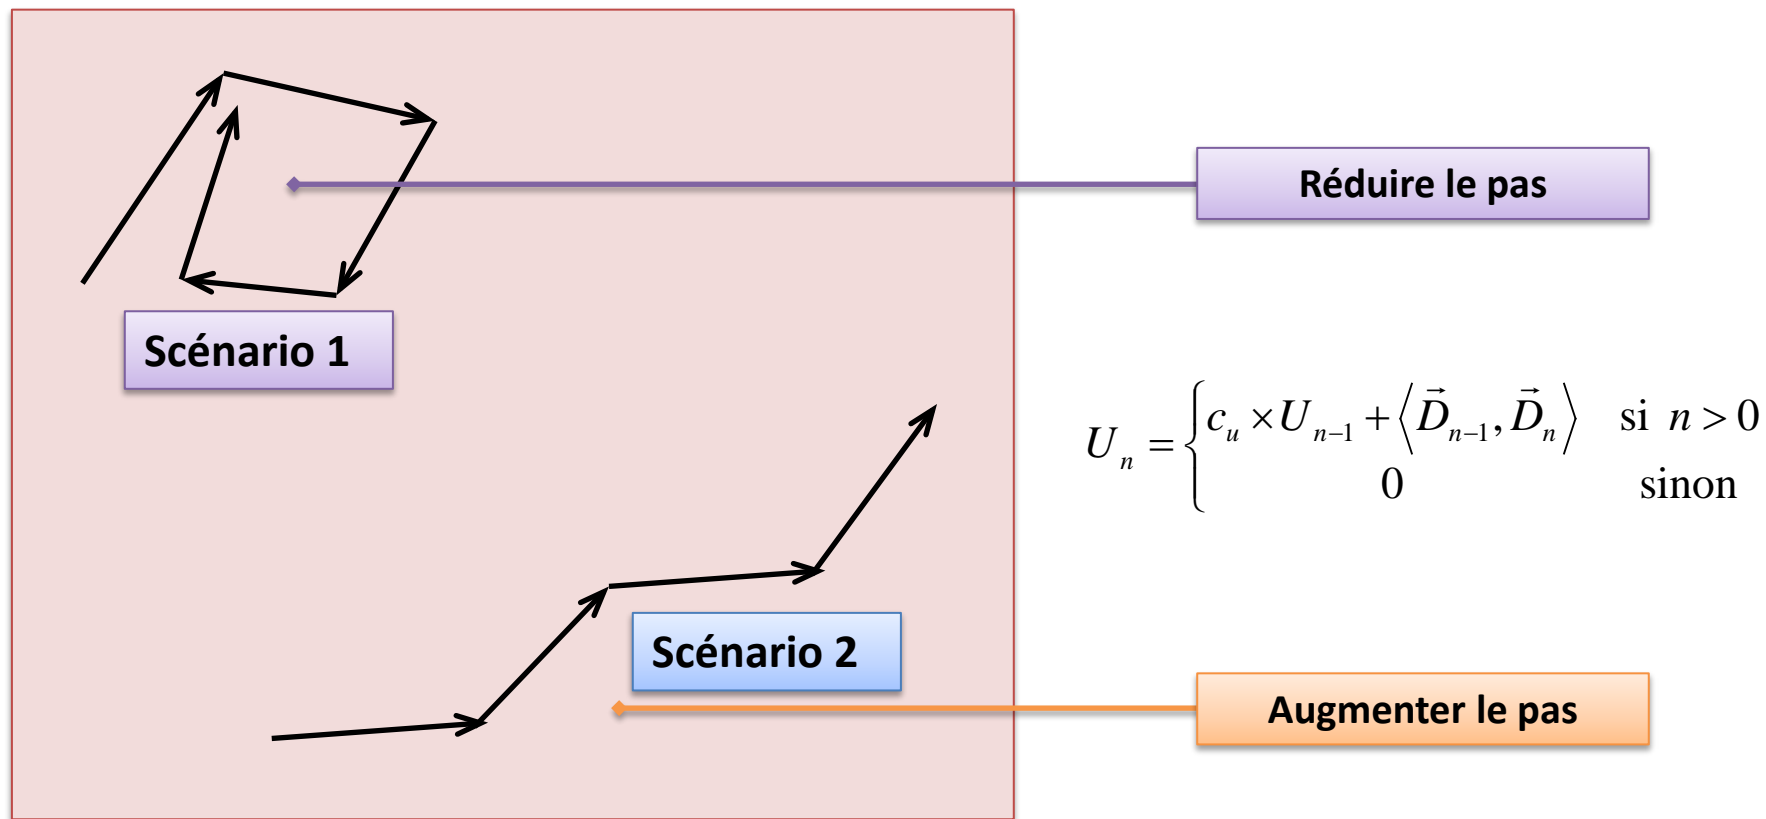
Voisinage d'un agent :

- ▶ solutions candidates régulièrement réparties autour de la solution courante

Une itération de la recherche locale d'un agent :


- ▶ déplacement vers une meilleure solution voisine
- ▶ adaptation du pas de déplacement

2.4. Adaptation du pas d'un agent de MADO

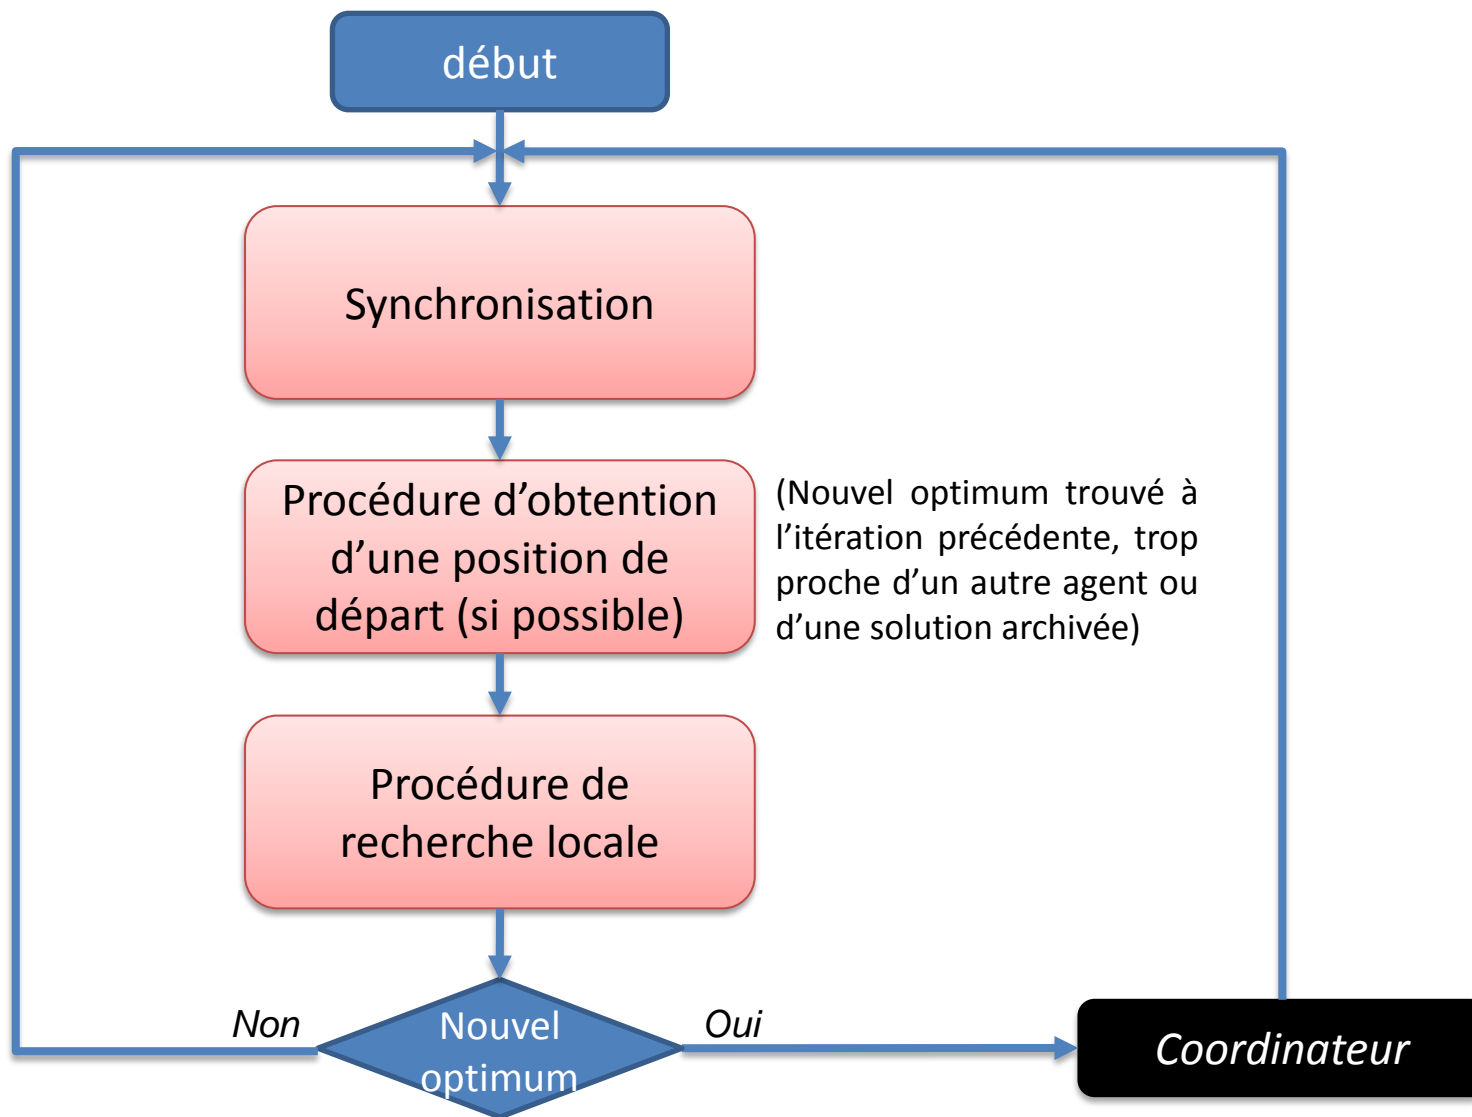


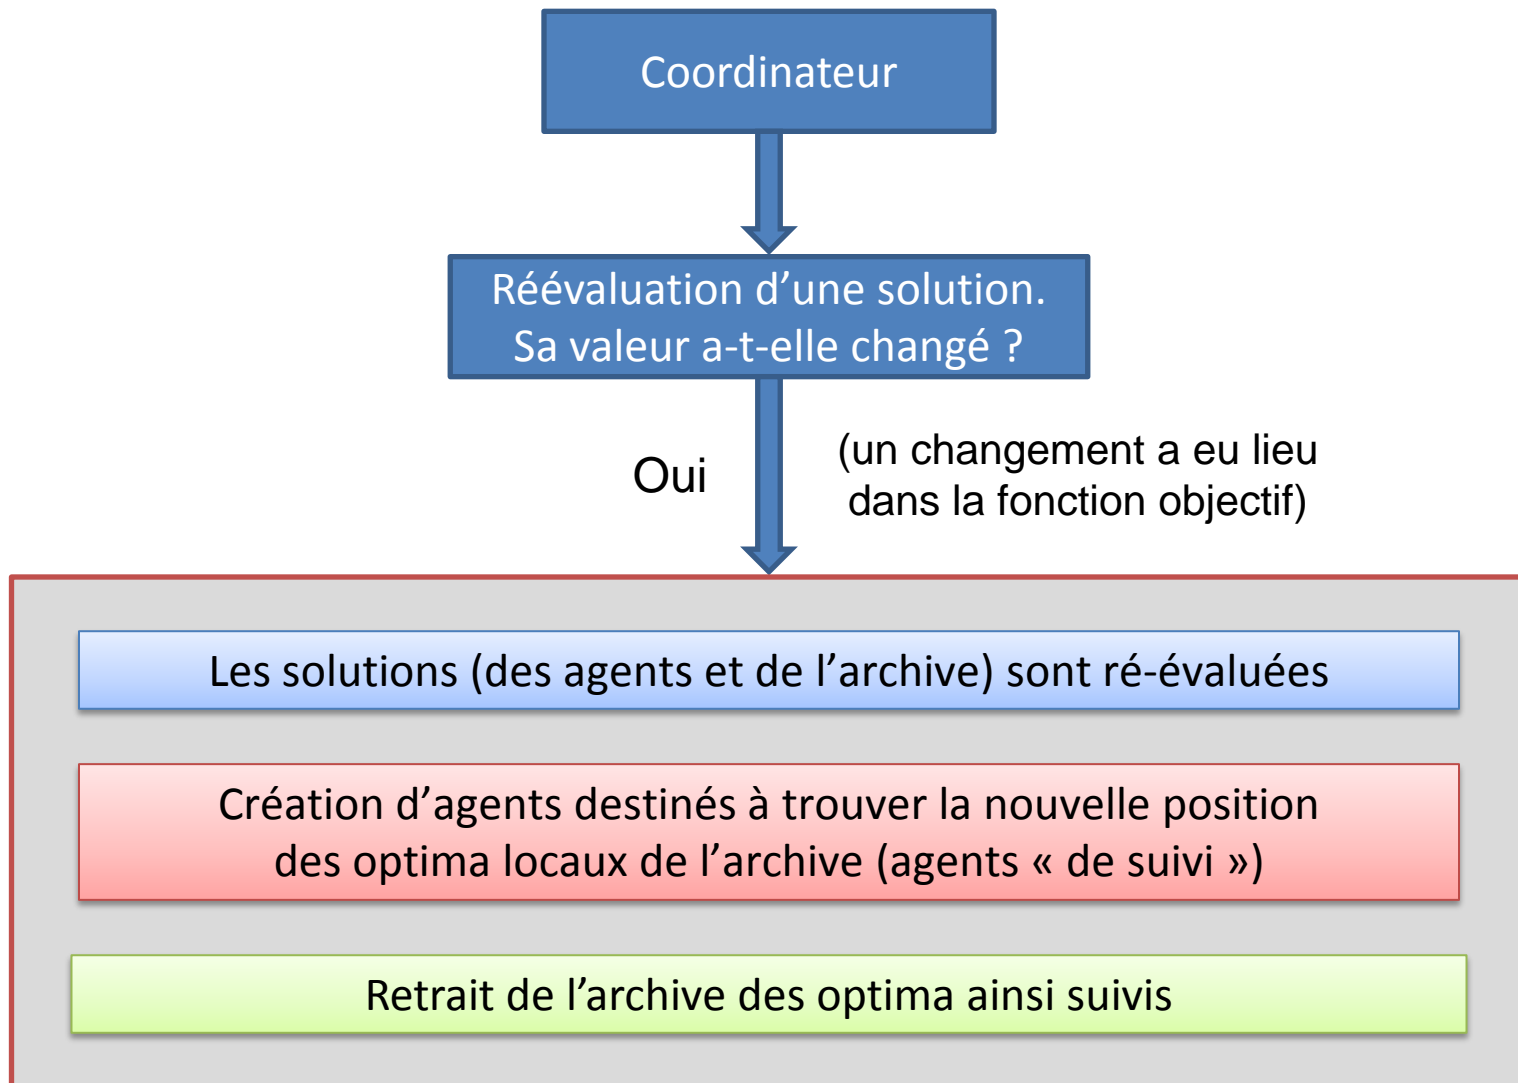
L'adaptation à appliquer au pas est déterminée selon le *produit scalaire cumulé* des déplacements de l'agent.

2.5. La population initiale d'agents de MADO




Maximiser la distance entre les agents dans **T**, comme illustré ici avec 5 agents dans un espace 2D.





| Nom | Type | Intervalle | Courte description |
|------------|--------|-----------------|---|
| n_a | entier | [1, 10] | nombre initial d'agents |
| n_m | entier | [0, $+\infty$ [| capacité de l'archive des optima locaux |
| n_s | entier | [1, $2d$] | nombre de solutions candidates du voisinage d'un agent |
| c_u | réel | [0, 1] | coefficient du produit scalaire cumulé |
| c_r | réel |]0, 1[| coefficient d'adaptation du pas d'un agent |
| r_e | réel |]0, 1] | rayon d'exclusion des agents, et pas initial d'un agent « d'exploration » |
| r_l | réel |]0, r_e [| pas initial d'un agent « de suivi » (créé pour suivre un optimum de l'archive) |
| δ_t | entier | [0, 10] | nombre de déplacements qu'un agent peut faire sans améliorer sa solution courante de plus de δ_p |
| δ_p | réel | [0, $+\infty$ [| la précision du critère de stagnation de la recherche locale d'un agent |

2.9. Convergence sur le *Moving Peaks Benchmark*




Convergence de MADO sur chaque *time span*.

2.10. Performances sur le *Moving Peaks Benchmark*

| Algorithme | Classe | Offline error |
|----------------------------|--------------------|-----------------------------------|
| Moser and Chiong, 2010 | Hybride | $0,25 \pm 0,08$ |
| Novoa et al., 2009 | OEP | $0,40 \pm 0,04$ |
| MADO | Multi-agent | $0,59 \pm 0,10$ |
| Moser and Hendtlass, 2007 | Hybride | $0,66 \pm 0,20$ |
| Yang and Li, 2010 | OEP | $1,06 \pm 0,24$ |
| Liu et al., 2010 | OEP | $1,31 \pm 0,06$ |
| Lung and Dumitrescu, 2007 | Hybride | $1,38 \pm 0,02$ |
| Bird and Li, 2007 | OEP | $1,50 \pm 0,08$ |
| Lung and Dumitrescu, 2008 | Hybride | $1,53 \pm 0,01$ |
| Blackwell and Branke, 2006 | OEP | $1,72 \pm 0,06$ |
| Mendes and Mohais, 2005 | EAs | $1,75 \pm 0,03$ |
| Li et al., 2006 | OEP | $1,93 \pm 0,06$ |
| Blackwell and Branke, 2004 | OEP | $2,16 \pm 0,06$ |
| Parrott and Li, 2006 | OEP | $2,51 \pm 0,09$ |
| Du and Li, 2008 | OEP | $4,02 \pm 0,56$ |

2.11. Performances sur GDBG (jeu de tests de CEC'2009)



**Points positifs**

- ✓ Architecture
- ✓ Adapté aux problèmes dont les changements sont drastiques

**Points négatifs**


- ✗ Nombre de paramètres élevé
- ✗ Algorithme complexe
- ✗ Pas adapté aux problèmes mal conditionnés
- ✗ Convergence trop lente au début de la recherche

Plan


1. Introduction à l'optimisation dynamique
2. L'algorithme MADDO
3. **Les variantes CMADO et PMADO**
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives

Problèmes pour lesquels une « petite » perturbation d'une solution entraîne une « grande » perturbation de la valeur de la fonction objectif de cette solution.


- Compression des lignes d'iso-valeurs de la fonction objectif.



Augmentation
du
conditionnement



3.2. Adaptation aux problèmes mal conditionnés (CMADO)



- Une matrice de covariance est calculée pour chaque agent, à partir de ses déplacements successifs.
- Elle est utilisée pour adapter le voisinage de l'agent au paysage local de la fonction objectif.

$$C' = I \times c_{id} + (C_{n-1} \times c_{cov} + D_n \times D_n^T (1 - c_{cov})) (1 - c_{id})$$
$$C_n = \frac{C'}{eigen'_{max}}$$


Sans adaptation, l'agent pourrait ne pas réussir à sortir de la zone rouge.

⇒ L'adaptation est nécessaire pour trouver l'optimum global.

| Algorithme | Offline error pour MPB | Nombre d'évaluations pour la fonction Rosenbrock 5D |
|------------|------------------------|---|
| CMADO | $0,58 \pm 0,09$ | $15854,5 \pm 13137,8$ |
| MADO | $0,60 \pm 0,11$ | $276789,2 \pm 460376,1$ |

- ❑ Pour MPB (problème bien conditionné)
 - Pas de différence significative des résultats.

- ❑ Pour la fonction Rosenbrock (problème mal conditionné)
 - Nombre d'évaluations (pour trouver l'optimum global avec une précision de 0,01) réduit de 94,3%.



La fonction Rosenbrock


3.4. Prédiction des régions prometteuses (PMADO)

Comment accélérer la convergence vers l'optimum global ?

IDÉE : Réinitialiser les recherches locales des agents dans des zones « prometteuses » de l'espace de recherche.

Procédure parallèle à la recherche effectuée par les agents :

- **Apprentissage** de l'allure de la fonction objectif
 - ❑ par un réseau de neurones
 - ❑ à partir de l'historique des solutions évaluées par les agents
- La *fonction objectif estimée* est au mieux *unimodale* (*lissage* des modes de la fonction objectif réelle par la *généralisation*).
- **Minimisation** par une méthode rapide de la *fonction objectif estimée*.
- Obtention d'une solution dans une région prometteuse.

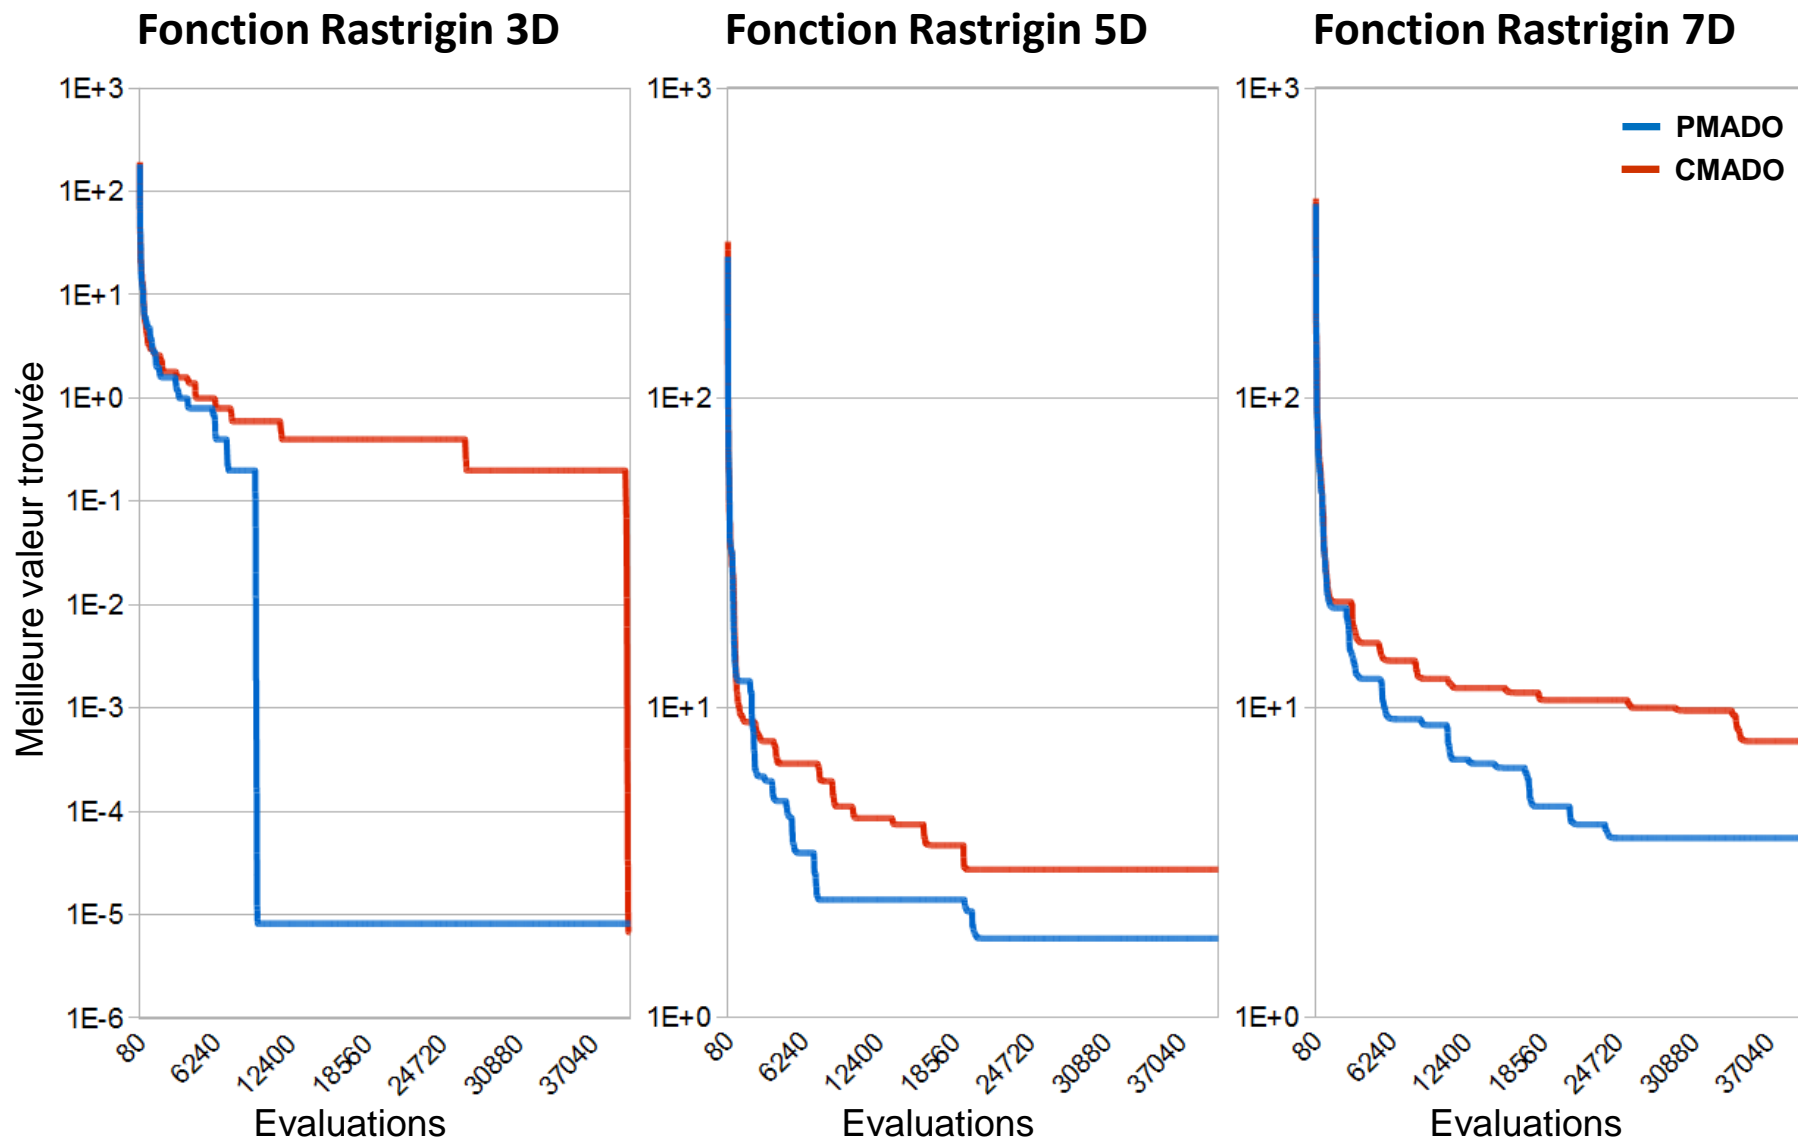


Grand nombre d'optima locaux.

- La convergence vers l'optimum global peut être difficile.

3.6.

Comparaison de CMADO et de PMADO



3.7. Bilan sur les variantes CMADO et PMADO



Points positifs

- ✓ Meilleures performances que MADO sur des problèmes mal conditionnés et fortement multimodaux



Points négatifs

- ✗ Nombre de paramètres élevé
- ✗ Algorithmes plus complexes que MADO


Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADO
3. Les variantes CMADO et PMADO
- 4. L'algorithme MLSDO**
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives

4.1. Multiple Local Search algorithm for Dynamic Optimization

- MLSDO reprend l'architecture de MADO
- **But:** Améliorer et simplifier l'algorithme
- **En particulier:**
 1. *Accélérer la recherche locale des agents*
 2. *Remplacer les stratégies de recherche peu efficaces*
 3. *Réguler le nombre d'agents de suivi créés à la détection d'un changement*
 4. *Réduire le nombre de paramètres de l'algorithme*

4.2. Description d'un agent de MLSDO (1 / 5)



Voisinage d'un agent :


- Solutions candidates réparties le long des axes de l'espace de recherche

Une itération de la recherche locale d'un agent :

- *Déplacement vers une meilleure solution le long du premier axe*
- Itération du déplacement le long de chacun des axes suivants
- Adaptation du pas

● Meilleure solution trouvée à l'itération $n-1$

4.2. Description d'un agent de MLSDO (2 / 5)



Voisinage d'un agent :

- Solutions candidates réparties le long des axes de l'espace de recherche


Une itération de la recherche locale d'un agent :

- *Déplacement vers une meilleure solution le long du premier axe*
- Itération du déplacement le long de chacun des axes suivants
- Adaptation du pas

● Meilleure solution trouvée à l'itération $n-1$

● Meilleure solution trouvée le long du 1^{er} axe

4.2. Description d'un agent de MLSDO (3 / 5)



Voisinage d'un agent :

- Solutions candidates réparties le long des axes de l'espace de recherche

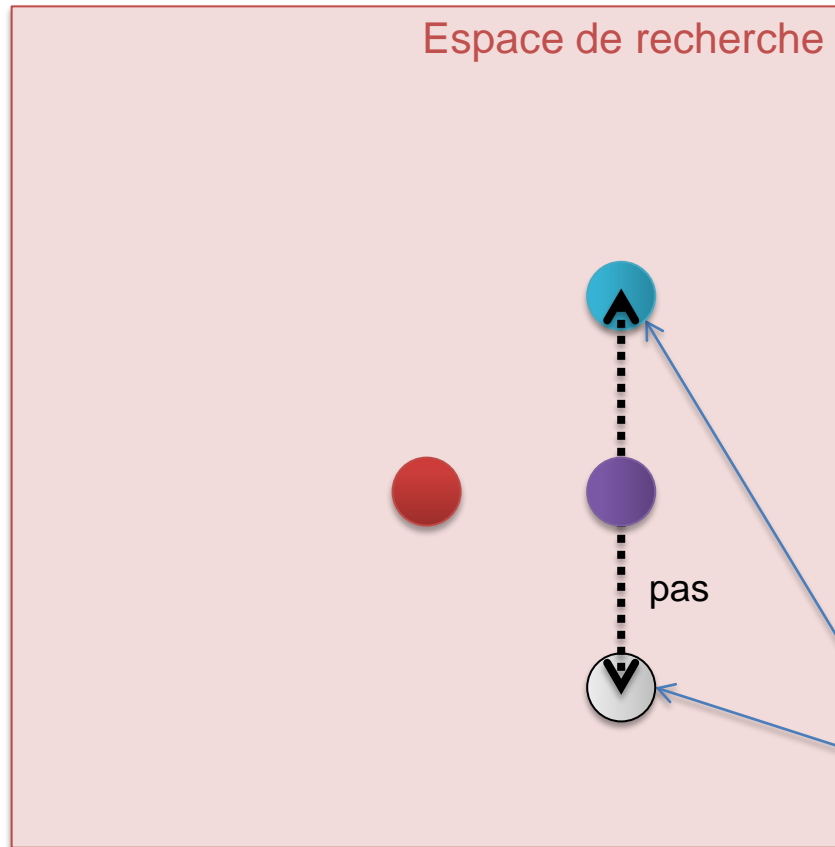
Une itération de la recherche locale d'un agent :

- Déplacement vers une meilleure solution le long du premier axe
- ***Itération du déplacement le long de chacun des axes suivants***
- Adaptation du pas

● Meilleure solution trouvée à l'itération $n-1$

● Meilleure solution trouvée le long du 1^{er} axe

4.2. Description d'un agent de MLSDO (4 / 5)



Voisinage d'un agent :

- Solutions candidates réparties le long des axes de l'espace de recherche

Une itération de la recherche locale d'un agent :

- Déplacement vers une meilleure solution le long du premier axe
- ***Itération du déplacement le long de chacun des axes suivants***
- Adaptation du pas


Solutions voisines

● Meilleure solution trouvée à l'itération $n-1$

● Meilleure solution trouvée le long du 1^{er} axe

● Meilleure solution trouvée le long du 2^{ème} axe

4.2. Description d'un agent de MLSDO (5 / 5)



Voisinage d'un agent :

- ▶ Solutions candidates réparties le long des axes de l'espace de recherche

Une itération de la recherche locale d'un agent :

- ▶ Déplacement vers une meilleure solution le long du premier axe
- ▶ Itération du déplacement le long de chacun des axes suivants
- ▶ **Adaptation du pas selon le produit scalaire cumulé des déplacements consécutifs \vec{D}_n**

● Meilleure solution trouvée à l'itération $n-1$

$$U_n = \begin{cases} \frac{1}{2} \times U_{n-1} + \langle \vec{D}_{n-1}, \vec{D}_n \rangle & \text{si } n > 0 \\ 0 & \text{sinon} \end{cases}$$

● Meilleure solution trouvée à l'itération n

Par rapport à MAD0, le nombre de paramètres est réduit de 9 à 6.

| Nom | Type | Intervalle | Courte description |
|---------------|--------|--------------------------|--|
| r_l | réel | $]0, r_e[$ | pas initial d'un agent de suivi |
| δ_{ph} | réel | $[0, \delta_{pl}]$ | paramètre du critère de stagnation de haute précision de la recherche locale des agents |
| δ_{pl} | réel | $[\delta_{ph}, +\infty[$ | paramètre du critère de stagnation de faible précision de la recherche locale des agents |
| n_a | entier | $[1, 10]$ | nombre maximum d'agents d'exploration |
| n_c | entier | $[0, 20]$ | nombre maximum d'agents de suivi créés à la détection d'un changement dans la fonction objectif |
| r_e | réel | $]0, 1]$ | rayon d'exclusion des agents, et pas initial d'un agent d'exploration |

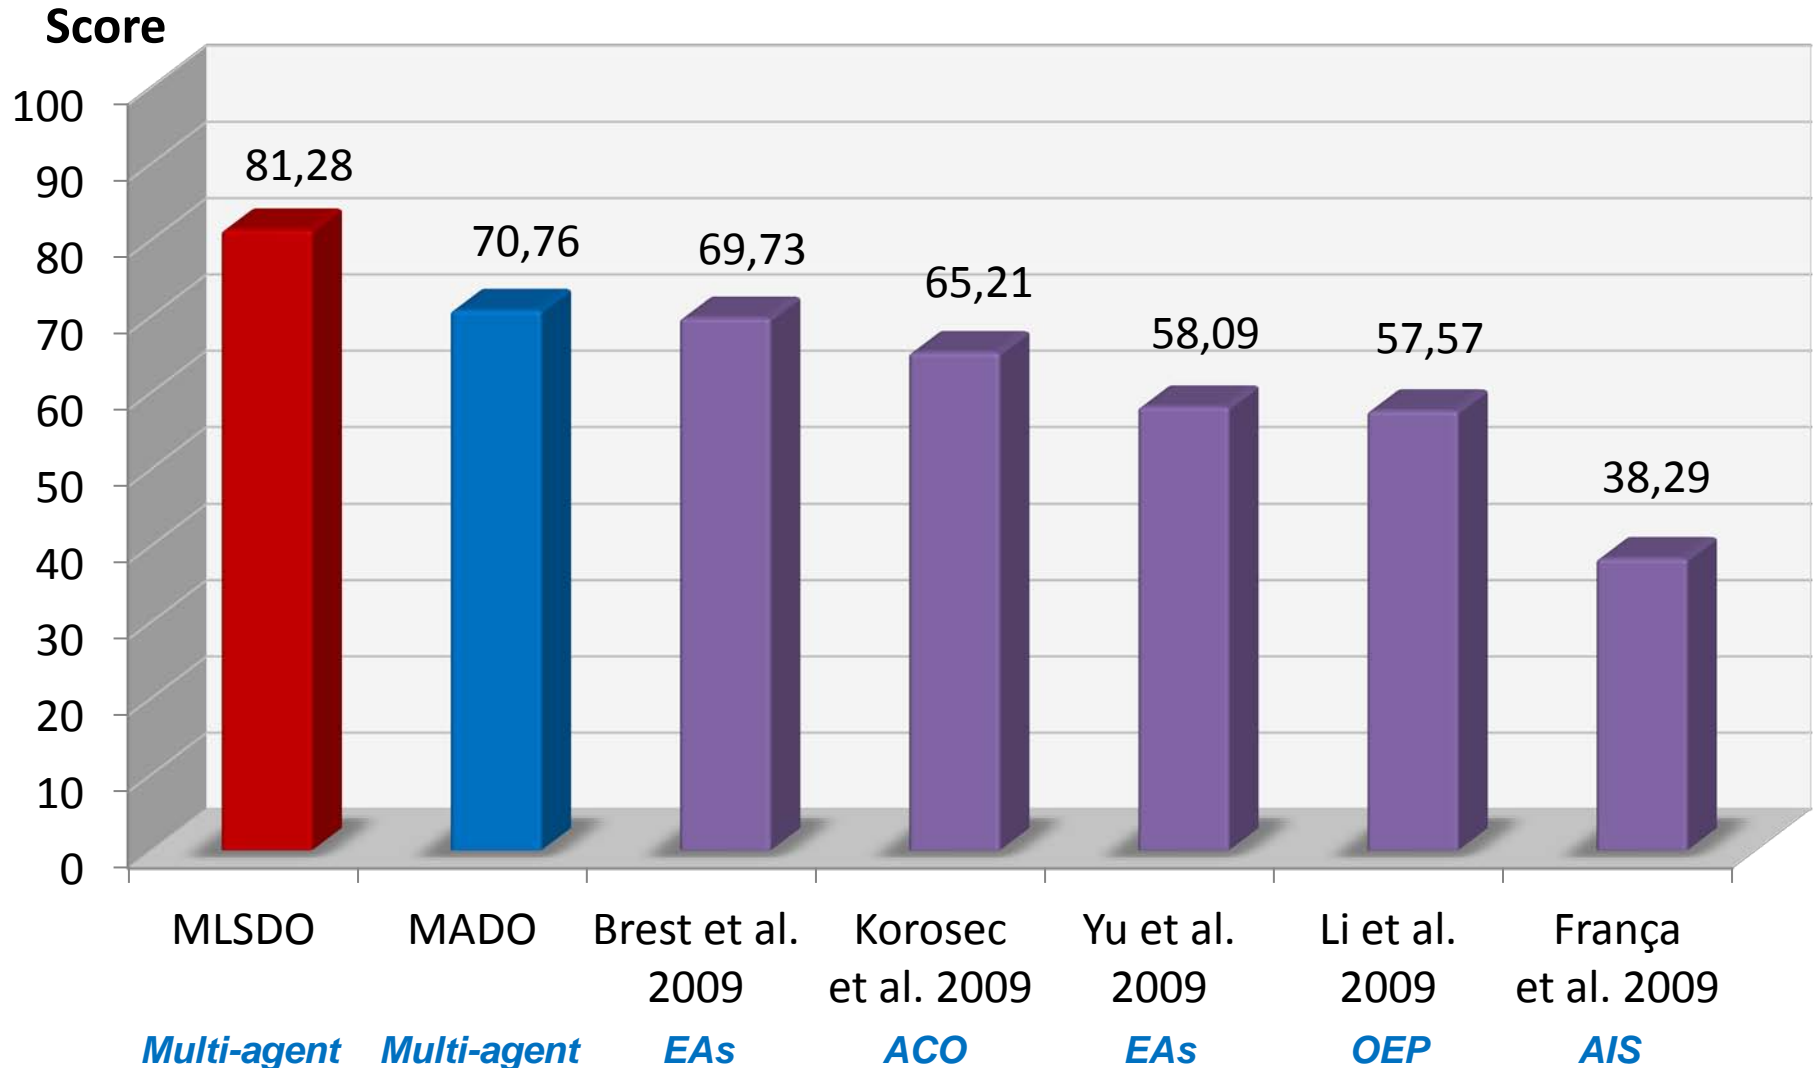
*Critère d'arrêt
à 2 niveaux de
précision*

*Seuls les n_c
meilleurs
optima locaux
sont suivis*

4.4. Performances sur le *Moving Peaks Benchmark*

| Algorithme | Classe | Offline error |
|----------------------------|--------------------|--------------------|
| Moser and Chiong, 2010 | Hybride | 0,25 ± 0,08 |
| MLSDO | Multi-agent | 0,35 ± 0,06 |
| Novoa et al., 2009 | OEP | 0,40 ± 0,04 |
| MADO | Multi-agent | 0,59 ± 0,10 |
| Moser and Hendtlass, 2007 | Hybride | 0,66 ± 0,20 |
| Yang and Li, 2010 | OEP | 1,06 ± 0,24 |
| Liu et al., 2010 | OEP | 1,31 ± 0,06 |
| Lung and Dumitrescu, 2007 | Hybride | 1,38 ± 0,02 |
| Bird and Li, 2007 | OEP | 1,50 ± 0,08 |
| Lung and Dumitrescu, 2008 | Hybride | 1,53 ± 0,01 |
| Blackwell and Branke, 2006 | OEP | 1,72 ± 0,06 |
| Mendes and Mohais, 2005 | EAs | 1,75 ± 0,03 |
| Li et al., 2006 | OEP | 1,93 ± 0,06 |
| Blackwell and Branke, 2004 | OEP | 2,16 ± 0,06 |
| Parrott and Li, 2006 | OEP | 2,51 ± 0,09 |
| Du and Li, 2008 | OEP | 4,02 ± 0,56 |

4.5. Performances sur GDBG (jeu de tests de CEC'2009)




Plan


1. Introduction à l'optimisation dynamique
2. L'algorithme MADDO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
- 5. Application à la segmentation de séquences d'images médicales**
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives

CONTEXTE

- ❑ Méthode d'estimation de l'amplitude des mouvements du 3^{ème} ventricule cérébral à partir de séquences ciné-IRM.
 - Traitement et diagnostic de l'hydrocéphalie.

**OBJECTIF**

- ❑ Améliorer l'étape de segmentation de la méthode.
- ❑ Accélérer cette étape en utilisant l'optimisation dynamique.





*Collaboration avec le CHU Henri Mondor (Créteil),
Service de neurochirurgie*

La segmentation vise à **partitionner une image** en plusieurs régions homogènes, au sens d'un critère fixé a priori (couleur, luminance, ...).

Illustration pour une image de la zone d'intérêt d'une séquence ciné-IRM cérébrale :




Segmentation
en 2 classes
(utilisant 2 labels)




5.3. Méthode de segmentation proposée (1 / 2)




Calculer
l'histogramme
de l'image
(donnant la
probabilité de
chaque niveau
de gris)




Modéliser
l'histogramme
par une somme
de fonctions
Gaussiennes




Partitionner
l'histogramme
modélisé



Fusionner les
classes
qui
correspondent
à un même
objet*



3 fonctions
Gaussiennes
donnent 3
classes de
pixels




* [A. Nakib et al, 2008]


5.3. Méthode de segmentation proposée (2 / 2)



Histogramme
de l'image
 $h(j)$



Histogramme
modélisé
 $p(\Theta, x_j)$



$$h(j) = \frac{g(j)}{\sum_{i=0}^{L-1} g(i)}$$

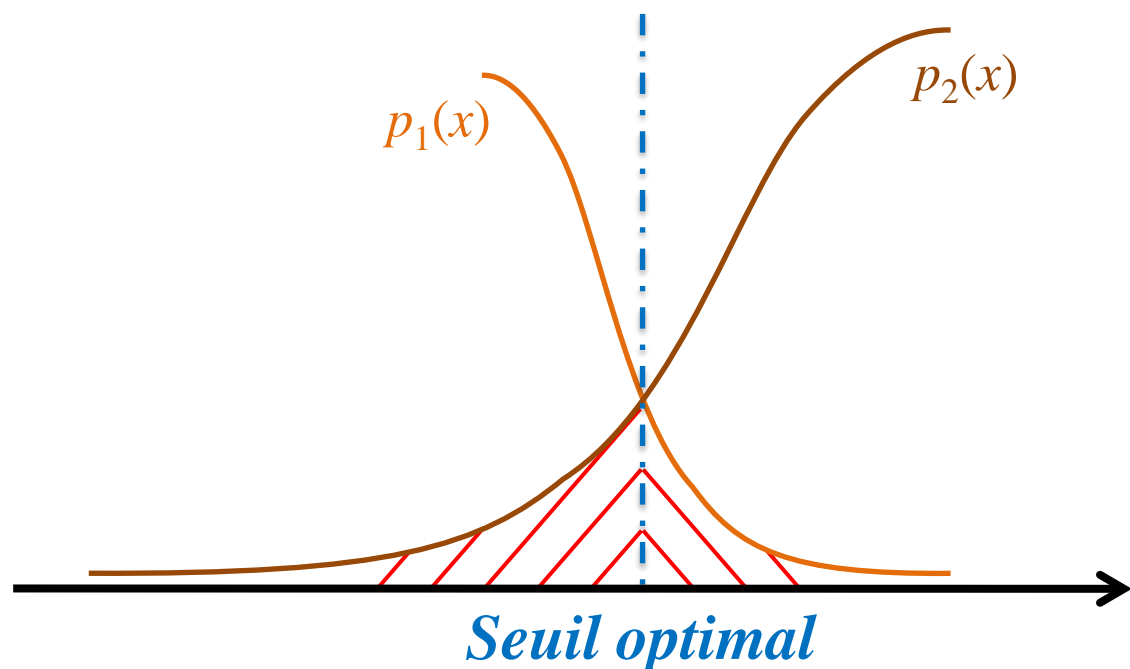
$g(j)$ désigne le nombre d'occurrences
du niveau de gris $j \in \{0, 1, \dots, L-1\}$.

$$p(\Theta, x_j) = \sum_{i=1}^d P_i \exp\left(-\frac{(x_j - \mu_i)^2}{\sigma_i^2}\right)$$


Somme des d Gaussiennes paramétrées
par $\Theta = \{P_i, \mu_i, \sigma_i; i = 1, 2, \dots, d\}$.

BUT : Trouver Θ qui minimise l'erreur de modélisation J :


$$J = \sum_{i=0}^{L-1} |h(i) - p(\Theta, x_i)|^2$$




Minimise
l'erreur de
classification



↓ Partitionner
l'histogramme
modélisé



5.5. Segmentation de séquences d'images : principe



Séquence ciné-IRM cérébrale (*lamina terminalis*)

- Les images d'une séquence sont segmentées l'une après l'autre.
- L'algorithme CMADO est utilisé pour segmenter la séquence.
- CMADO exploite les corrélations entre les images pour accélérer le processus de segmentation (paradigme de l'optimisation dynamique).

□ Optimisation statique :





- La segmentation de chaque image est considérée comme un nouveau problème à optimiser.


$$\Theta^* = \arg \min_{\Theta} \sum_{i=0}^{L-1} |h(i) - p(\Theta, x_i)|^2$$


□ Optimisation dynamique :

- Le passage d'une image à la suivante constitue un changement dans la fonction objectif.


$$\Theta^*(t) = \arg \min_{\Theta(t)} \sum_{i=0}^{L-1} |h(i, t) - p(\Theta(t), x_i)|^2$$

Images
originalesHistogrammes
originauxHistogrammes
modélisésImages
segmentées






Amplitude du déplacement des points des contours de la région d'intérêt.



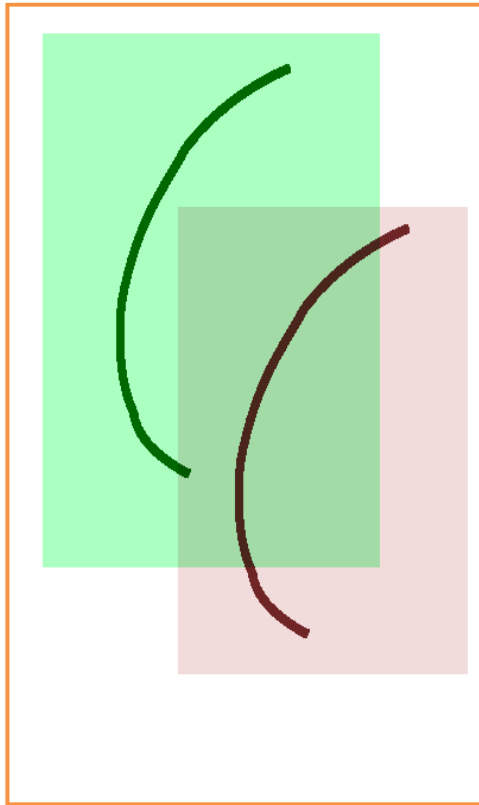
Déplacements des points des contours de la région d'intérêt au cours du temps.





Convergence de CMADO pour le problème traité.

Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
- 6. Application au recalage de séquences d'images médicales segmentées**
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives



Avant recalage

Transformation appliquée
à l'image source (I)
pour la faire correspondre
à l'image cible (J)

Après recalage

$$T^* = \arg \min_{T \in S} f(I \circ T, J)$$

$$T^* = \arg \min_{T \in S} f(I \circ T, J)$$

- Transformations

$$T^* = \arg \min_{T \in S} f(I \circ T, J)$$


- Transformations
- Application d'une transformation

$$T^* = \arg \min_{T \in \mathcal{S}} f(I \circ T, J)$$


- Transformations
- Application d'une transformation
- Mesure de dissimilarité

$$T^* = \arg \min_{T \in S} f(I \circ T, J)$$

- Transformations
- Application d'une transformation
- Mesure de dissimilarité
- Optimisation

$$T^* = \arg \min_{T \in S} f(I \circ T, J)$$

- Transformations
- Application d'une transformation
- Mesure de dissimilarité
- Optimisation

Transformation affine :

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} s_1 \cdot \cos \theta & -s_2 \cdot \sin \theta \\ s_1 \cdot \sin \theta & s_2 \cdot \cos \theta \end{pmatrix} \cdot \begin{pmatrix} x \\ y \end{pmatrix} + \begin{pmatrix} t_x \\ t_y \end{pmatrix}$$

avec :



(x', y') coordonnées (x, y) transformées ;

(s_1, s_2) paramètres d'**échelle** de la transformation ;

(t_x, t_y) paramètres de **translation** de la transformation ;

θ paramètre de **rotation** de la transformation.

6.4. Recalage d'images : mesure de dissimilarité




$I \circ T$

J


1. Les points des contours sont extraits des images ;
2. Une transformation est appliquée aux points de contours de l'image source ($I \circ T$) ;
3. La dissimilarité entre ces points de contours transformés et ceux de l'image cible (J) est mesurée en utilisant l'**Erreur Quadratique Moyenne** (MSE).

6.5. Recalage de séquences d'images : principe



Séquence ciné-IRM cérébrale (*lamina terminalis*)

1. Extraction des points des contours de chaque image.



Séquence des contours extraits (segmentation)

2. Les couples de contours successifs sont recalés séquentiellement.

Dissimilarité mesurée en utilisant l'Erreur Quadratique Moyenne (MSE).

❑ **Optimisation statique :**

- Le recalage de chaque couple de contours est considéré comme un nouveau problème à optimiser.

❑ **Optimisation dynamique :**

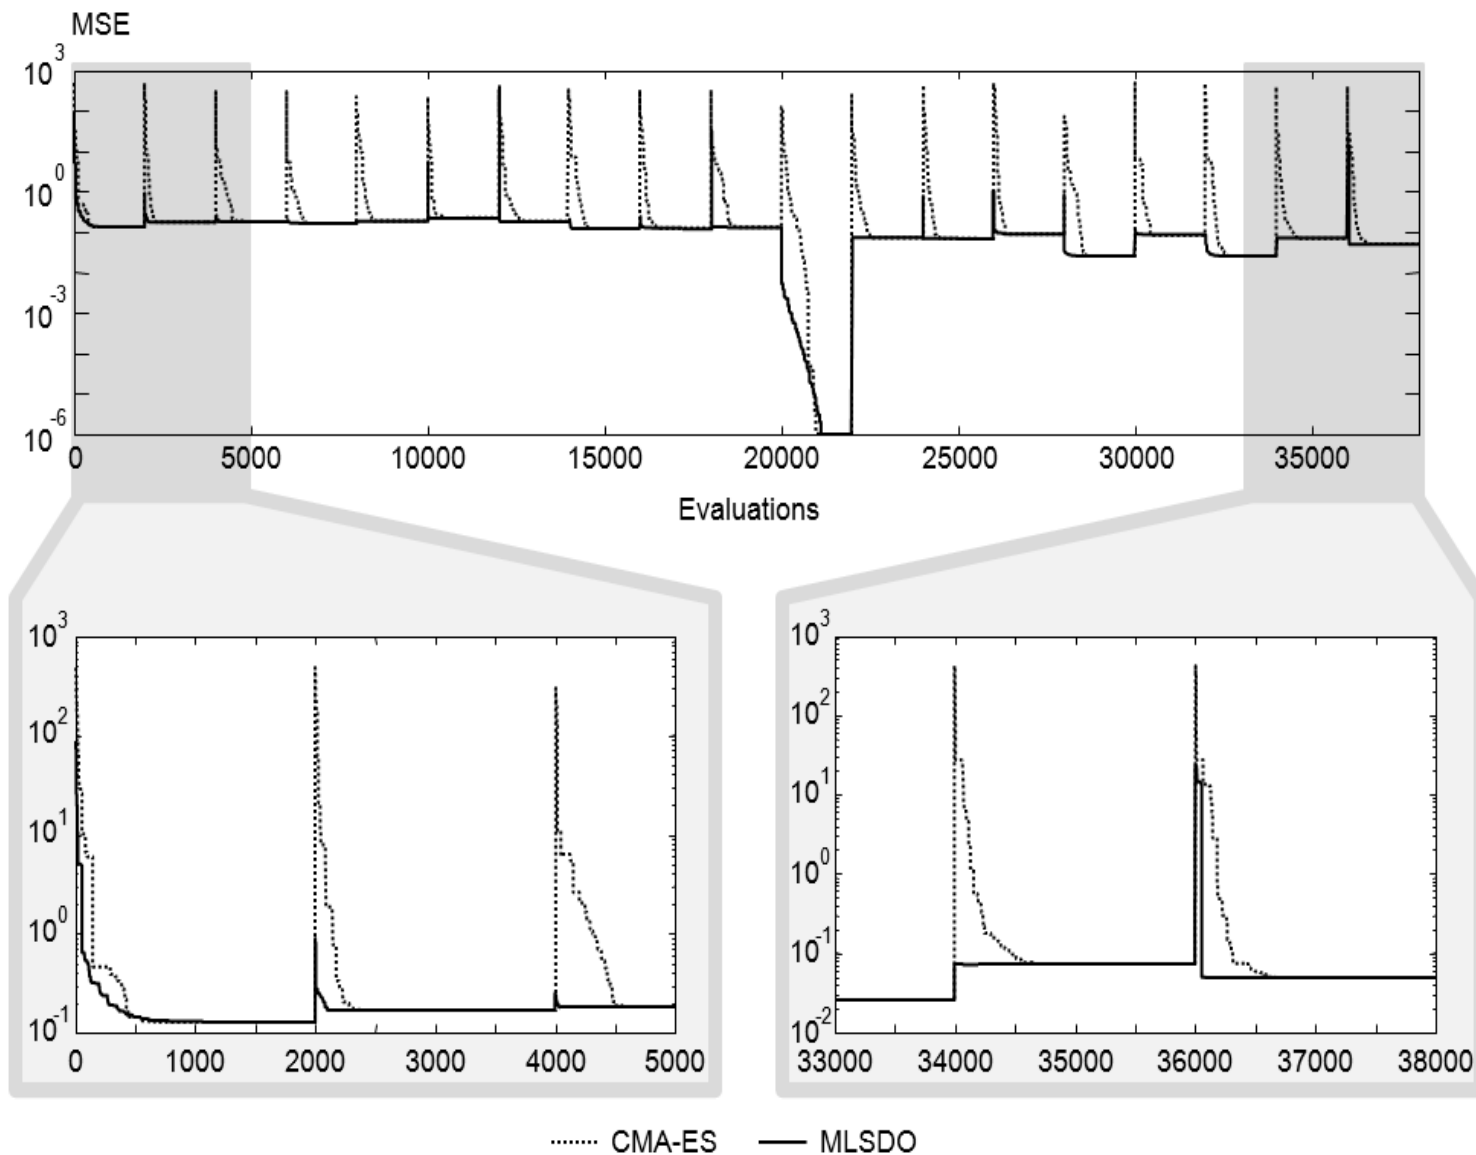
- Le passage d'un couple au suivant constitue un changement dans la fonction objectif.

Performance moyenne du recalage sur 20 exécutions successives :

| | Algorithme | Classe | Evaluations | Temps d'exécution (ms) | MSE cumulée |
|-------------------------------|------------|-------------|-------------------|------------------------|---------------|
| Optimisation dynamique | MLSDO | Multi-agent | 13841,80 ± 386,55 | 13,2 ± 5,7 | 2,05 ± 1,3E-4 |
| Optimisation statique | CMA-ES | EAs | 17651,65 ± 288,10 | 5029,5 ± 212,8 | 2,05 ± 1,6E-2 |
| | SPSO-07 | OEP | 19611,70 ± 994,13 | 49,8 ± 22,5 | 2,05 ± 2,7E-2 |
| | DE | EAs | 21749,60 ± 869,46 | 56,4 ± 23,4 | 2,05 ± 2,8E-5 |
| | MLSDO | Multi-agent | 28891,15 ± 908,88 | 29,8 ± 20,3 | 2,05 ± 1,8E-4 |

Critère d'arrêt : Pas d'amélioration significative (inférieure à 1E-5) pendant 200 évaluations.

6.8. Résultats expérimentaux : convergence



Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. **Application au recalage de séquences d'images médicales non segmentées**
8. Conclusion et perspectives

- **Améliorer la précision et simplifier la méthode:**
 1. *Supprimer l'étape de segmentation*
 2. *Remplacer le recalage géométrique par un recalage « iconique »*
 3. *Remplacer la transformation affine par une transformation élastique*

Transformation élastique (polynomiale d'ordre 2) :

$$x' = c_1 x^2 + c_2 y^2 + c_3 x y + (c_4 |c_4| + 1)x + c_5 |c_5| y + (c_6)^3$$

$$y' = c_7 x^2 + c_8 y^2 + c_9 x y + c_{10} |c_{10}| x + (c_{11} |c_{11}| + 1)y + (c_{12})^3$$

avec :

(x', y') les coordonnées du point (x, y) après transformation ;

c_i les paramètres de la transformation (12 paramètres).

Probabilités des intensités de I' dans la zone C :

$$p_i = \text{Card}((x, y) \in C, I'(x, y) = i) / \text{Card}(C)$$

Probabilités des intensités de J dans la zone C :

$$p_j = \text{Card}((x, y) \in C, J(x, y) = j) / \text{Card}(C)$$

Probabilité jointe :

$$p_{ij} = \text{Card}((x, y) \in C, I'(x, y) = i \wedge J(x, y) = j) / \text{Card}(C)$$

Entropies marginales :


$$H(I') = \sum_i -p_i \times \log(p_i) \quad H(J) = \sum_j -p_j \times \log(p_j)$$


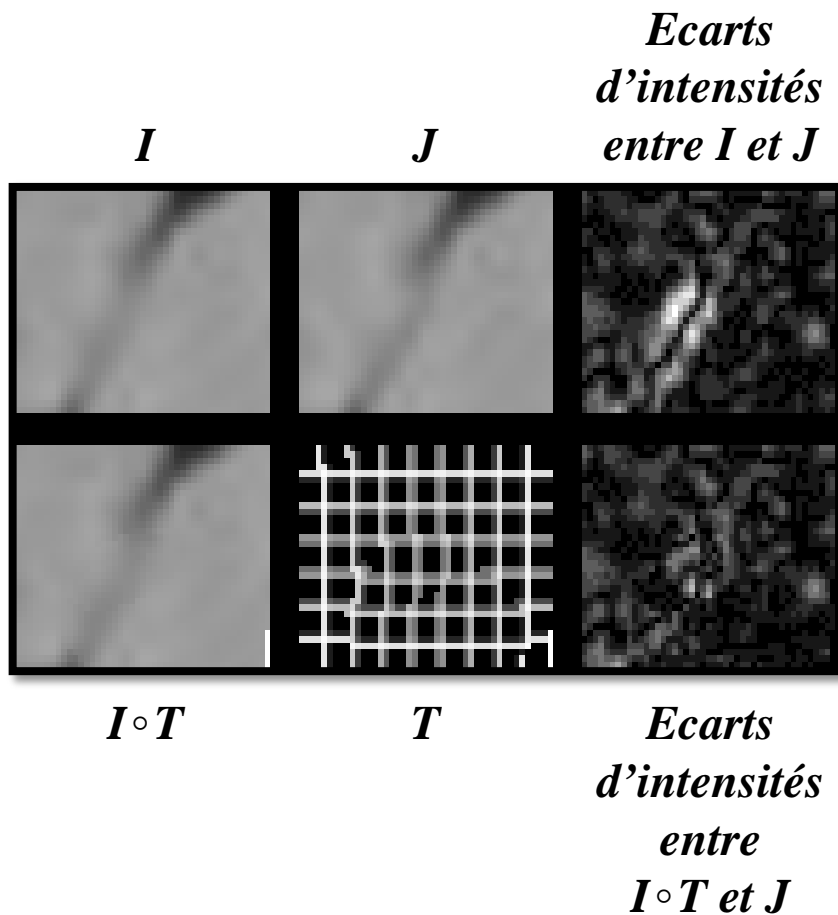
Entropie jointe :

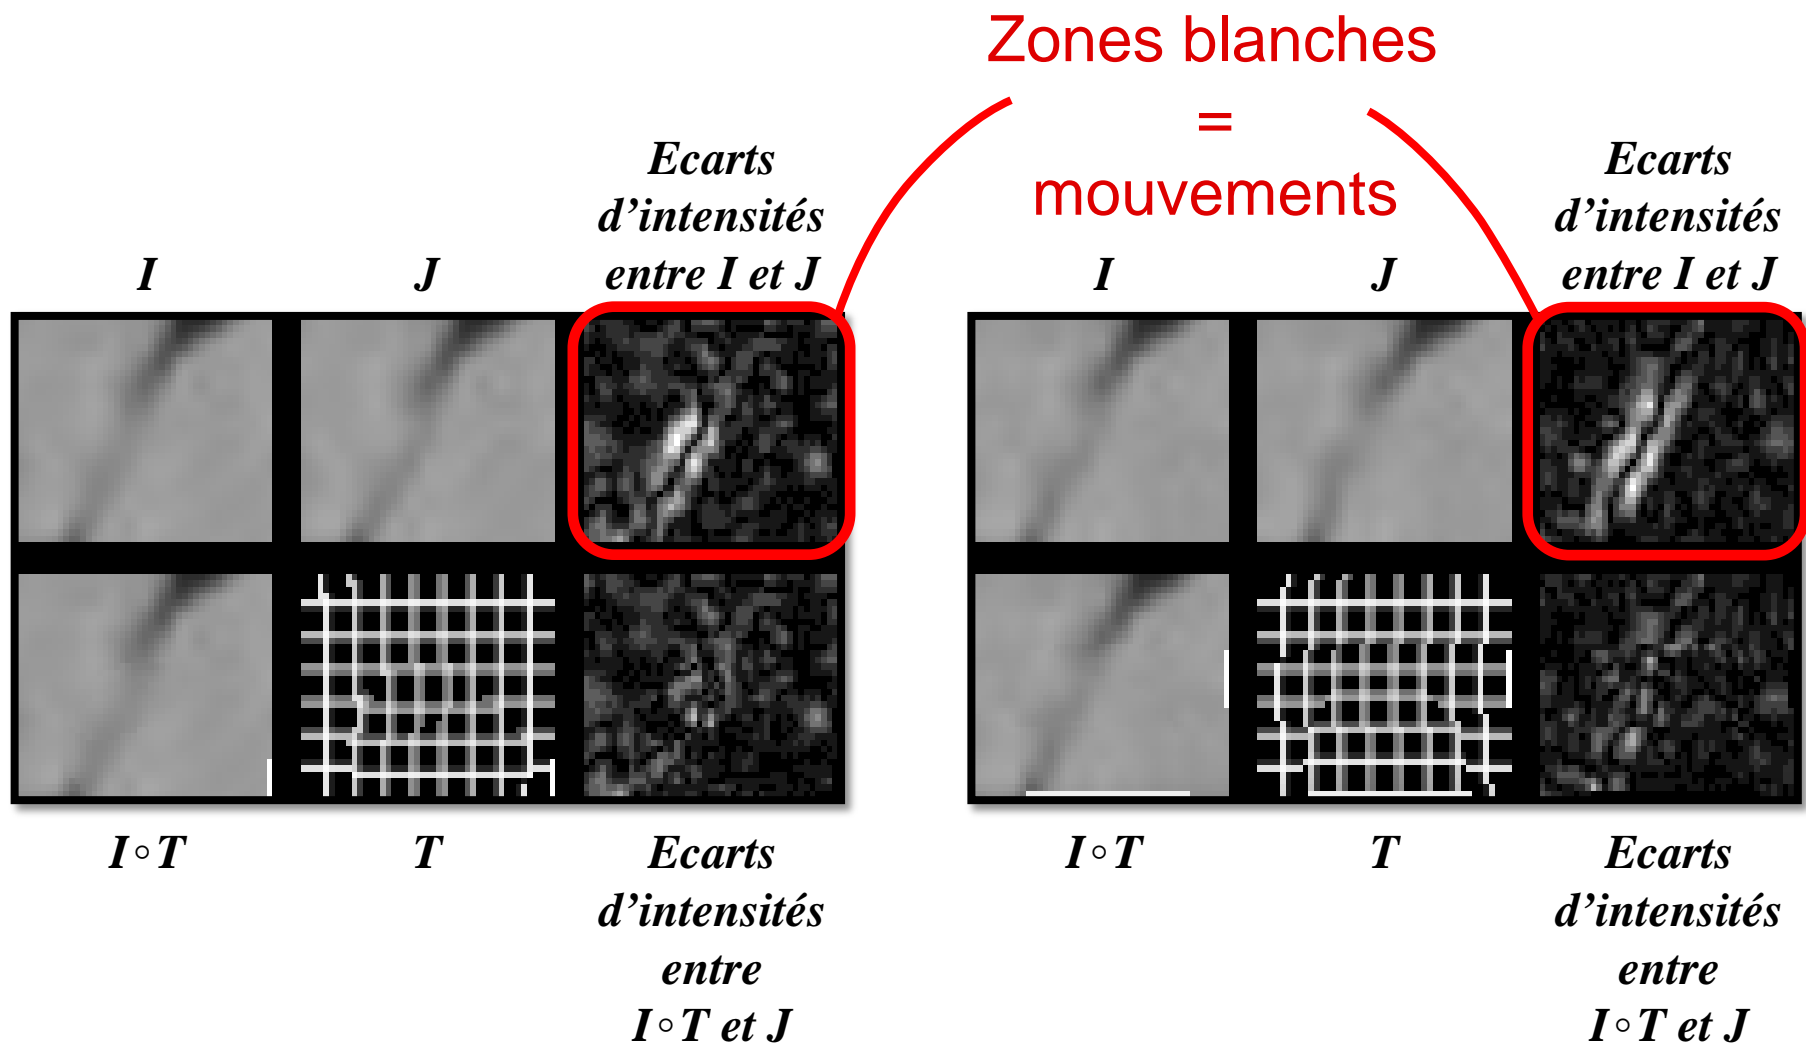
$$H(I', J) = \sum_i \sum_j -p_{ij} \times \log(p_{ij})$$

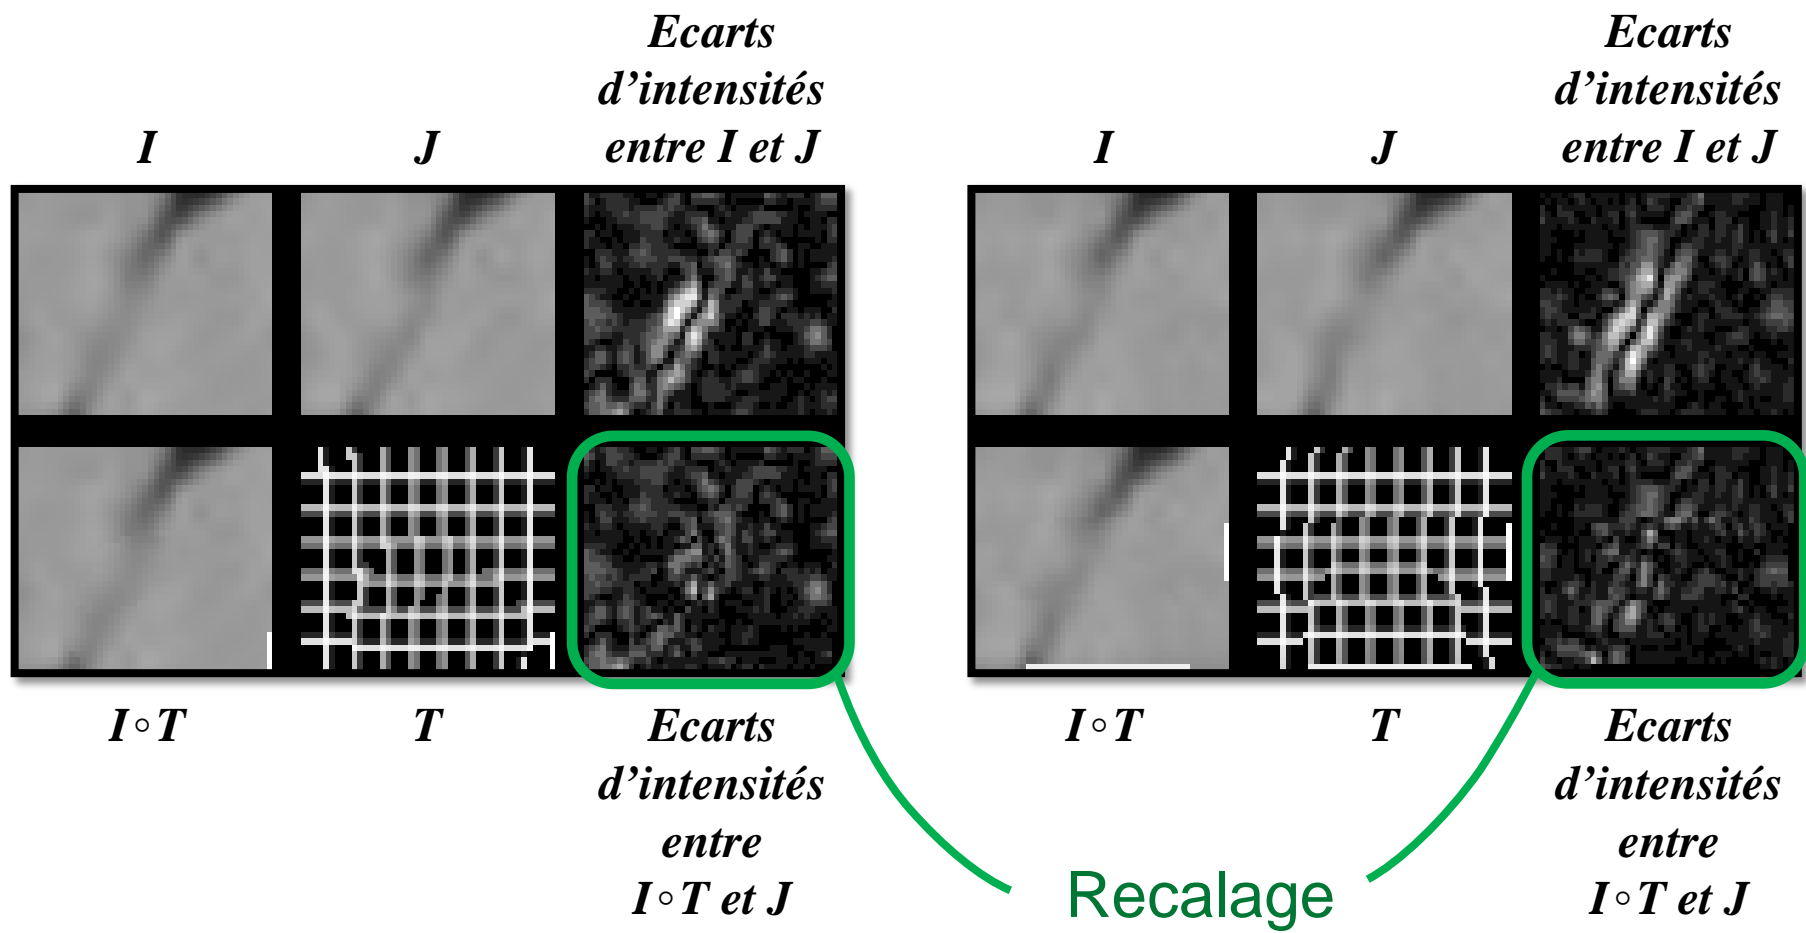
Information mutuelle normalisée (IMN) :

$$IMN(I', J) = \frac{H(I') + H(J)}{H(I', J)}$$

Image cible J Image source transformée I' Zone de recouvrement C








Performances moyennes pour recalibrer un couple d'images de la séquence :

| | Algorithme | Evaluations | Valeur moyenne de la fonction objectif |
|-------------------------------|------------|------------------|--|
| Optimisation dynamique | MLSDO | 6880,68 ± 585,92 | 1,21 ± 7,0E-4 |
| Optimisation statique | CMA-ES | 7709,14 ± 467,75 | 1,21 ± 9,1E-4 |
| | SPSO-07 | 8007,21 ± 364,24 | 1,21 ± 8,8E-4 |
| | DE | 9131,25 ± 279,20 | 1,21 ± 9,3E-4 |
| | MLSDO | 9522,76 ± 648,87 | 1,21 ± 1,7E-3 |

Critère d'arrêt : Pas d'amélioration significative (inférieure à 1E-5) pendant 5000 évaluations.

7.6. Résultats expérimentaux : convergence



Plan

1. Introduction à l'optimisation dynamique
2. L'algorithme MADO
3. Les variantes CMADO et PMADO
4. L'algorithme MLSDO
5. Application à la segmentation de séquences d'images médicales
6. Application au recalage de séquences d'images médicales segmentées
7. Application au recalage de séquences d'images médicales non segmentées
8. Conclusion et perspectives

- ✓ Deux algorithmes à base d'agents, MADO et MLSDO, ainsi que deux variantes de MADO, CMADO et PMADO, ont été proposés pour résoudre des problèmes d'optimisation dynamique.
- ✓ Les résultats obtenus sur les principaux jeux de tests, MPB et GDBG, montrent l'efficacité des stratégies mises en œuvre par ces algorithmes, en particulier :
 - MLSDO est classé premier sur sept algorithmes évalués sur GDBG ;
 - MLSDO est classé deuxième sur seize algorithmes évalués sur MPB.
- ✓ Ces algorithmes ont été appliqués à des problèmes de segmentation et de recalage de séquences ciné-IRM cérébrales.
 - Gains de performance significatifs, montrant l'intérêt de l'optimisation dynamique pour ce type de problèmes.

- ✓ Poursuivre les travaux sur la prédiction des régions prometteuses de l'espace de recherche (PMADO).
- ✓ Rendre les paramètres de MLSDO auto-adaptatifs (adaptés en cours de recherche).
- ✓ Extension à l'optimisation multi-objectif (optimisation de plusieurs fonctions objectives dynamiques d'un même problème simultanément).
- ✓ Accélération par parallélisation sur processeurs graphiques (GPGPU).
- ✓ Amélioration de la précision de la procédure de recalage de séquences d'images, en utilisant un modèle de déformation comportant davantage de degrés de liberté.

PUBLICATIONS

Revue internationale à comité de lecture :

- 1) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "A new multiagent algorithm for dynamic continuous optimization," *International Journal of Applied Metaheuristic Computing*, vol. 1, no. 1, pp. 16–38, 2010.
- 2) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "A Multiple Local Search Algorithm for Continuous Dynamic Optimization," under submission.

Actes de conférences internationales à comité de lecture :

- 1) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Brain cine-MRI registration using MLSDO dynamic optimization algorithm," in *Proc. 9th Metaheuristics International Conference (MIC 2011)*, vol. 1, Udine, Italy, 2011, pp. 241–249.
- 2) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Brain Cine MRI Segmentation Based on a Multiagent Algorithm for Dynamic Continuous Optimization," in *Proc. IEEE Congress on Evolutionary Computation*, vol. 1, New Orleans, USA, 2011, pp. 1695–1702.
- 3) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "A Multi-Agent based Algorithm for Continuous Dynamic Optimization," *EU/MEeting 2010 workshop*, Lorient, France, 2010.
- 4) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Performance analysis of MADO dynamic optimization algorithm," in *Proc. IEEE International Conference on Intelligent Systems Design and Applications*, Pisa, Italy, 2009, pp. 37–42.
- 5) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Brain cine-MRI Sequences Registration using B-spline Free-Form Deformations and MLSDO Dynamic Optimization Algorithm," under submission.

Actes de conférences nationales à comité de lecture :


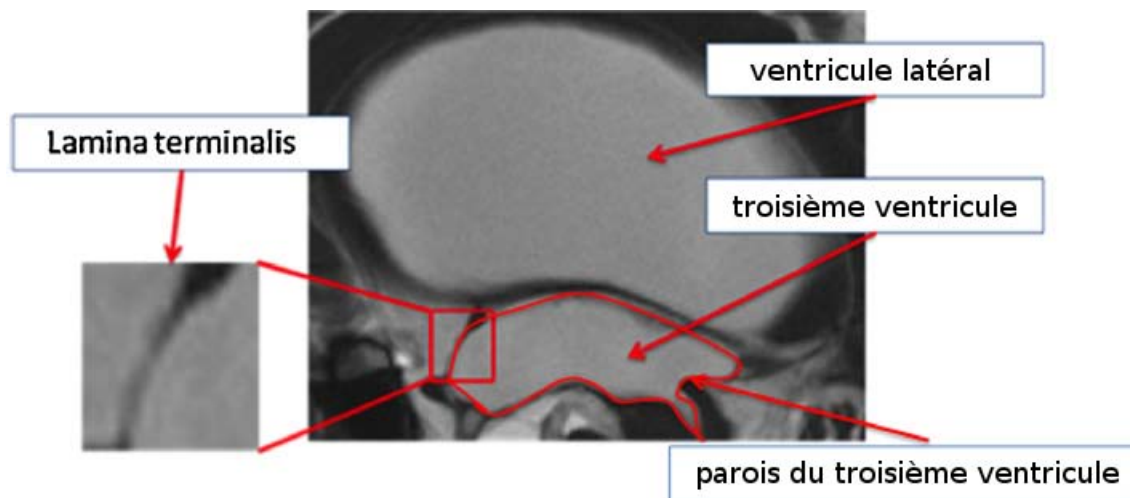
- 1) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Recalage de séquences d'images IRM basé sur un nouvel algorithme d'optimisation dynamique," *Congrès de la Société Française de Recherche Opérationnelle et d'Aide à la Décision (ROADEF 2011)*, vol. 1, Saint-Etienne, France, 2011, pp. 393–394.
- 2) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Réduction du nombre de paramètres de la métaheuristique d'optimisation dynamique MADO," *Congrès de la Société Française de Recherche Opérationnelle et d'Aide à la Décision (ROADEF 2010)*, Toulouse, France, 2010.

Chapitres d'ouvrages :

- 1) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Elastic registration of brain cine-MRI sequences using MLSDO dynamic optimization algorithm," accepted.
- 2) J. Lepagnot, A. Nakib, H. Oulhadj & P. Siarry, "Brain cine-MRI registration using MLSDO dynamic optimization algorithm," under submission.

**Merci de votre
attention!
Des questions?**

A. Segmentation de séquences d'images




B. Segmentation de séquences d'images : comparaison

Images non segmentées Méthode proposée Entropie locale Entropie jointe Entropie globale 2D Otsu K-moyennes




C. Résultats expérimentaux : estimation d'histogramme




D. MLSDO : analyse de la sensibilité des paramètres (1 / 3)

Offline error




Offline error




D. MLSDO : analyse de la sensibilité des paramètres (2 / 3)

Offline error




Offline error




D. MLSDO : analyse de la sensibilité des paramètres (3 / 3)

Offline error



Offline error



E. Calcul du score de GDBG

Cas d'une maximisation :

$$r_i(t) = \frac{f_i^*(t)}{f_i(t)}$$

Cas d'une minimisation :

$$r_i(t) = \frac{f_i(t)}{f_i^*(t)}$$

$$r_{ij} = \frac{r_i(t_j + \alpha)}{1 + \sum_{s=1}^{\frac{\alpha}{s_f}} \frac{1 - r_i(t_j + s_f \times s)}{\frac{\alpha}{s_f}}}$$

$$mark_{pct} = mark_{max} \times \sum_{i=1}^{runs} \sum_{j=1}^{N_c} \frac{r_{ij}}{runs \times N_c}$$