

Polytechnique Montréal
Gerad

PCA-MADS - Réduction de dimension dans MADS

Montréal, 2 avril 2020

Romain Vanden Bulcke


Directeurs : Charles Audet
Sébastien Le Digabel

Superviseur : Miguel Diago Martinez

Introduction

Contexte

- Optimisation sans dérivées / boîtes noires
- Problèmes en grande dimension
- Algorithme séquentiel
- MADS



Introduction

Contexte

- Optimisation sans dérivées / boîtes noires
- Problèmes en grande dimension
- Algorithme séquentiel
- MADS

Idée

- Exploiter les informations connues de la boîte noire → cache
- Identifier les combinaisons de variables les plus influentes
- Suite des projets d'Imen et Nadir

- 1 Introduction
- 2 Réduction de dimension en DFO
- 3 Algorithme
 - Analyse en composante principale
 - Algorithme PCA-MADS
- 4 Tests et résultats
- 5 Conclusion et suite du projet

Plan

- 1 Introduction
- 2 Réduction de dimension en DFO
- 3 Algorithme
 - Analyse en composante principale
 - Algorithme PCA-MADS
- 4 Tests et résultats
- 5 Conclusion et suite du projet

Réduction de dimension en Optimisation Bayésienne I

Optimisation Bayésienne

- Méthode d'optimisation basée sur des modèles aléatoires
- Distribution *a priori* sur F , $p(F)$
- Données D et modèle de vraisemblance $p(D|F)$
- Distribution *a posteriori* $p(F|D) \propto p(D|F)p(F)$
- Construction d'une fonction d'acquisition u , facile à optimiser (probabilité d'amélioration, espérance d'amélioration, ...)
- Mise à jour des distributions et des modèles

Réduction de dimension en Optimisation Bayésienne II

Dimension effective [5]

Une fonction $f : \mathbb{R}^n \mapsto \mathbb{R}$ a une dimension effective $d \leq n$ s'il existe un sous-espace linéaire T de dimension d tel que pour tout $x_T \in T$ et $x_\perp \in T^\perp$,

$$f(x_T + x_\perp) = f(x_T),$$

où d est le plus petit entier satisfaisant cette relation.

Exemple [5]

La fonction $f(x) = \sin^2(x_1 - x_2 - 0.5)$

Sous-espace actif $(x_1, x_2) = (1, -1)^\top y, y \in \mathbb{R}$

Ensemble de ses minima $\{(1, 1)^\top t - (0, 0.5 + \pi k)^\top : t \in \mathbb{R}, k \in \mathbb{Z}\}$.

Réduction de dimension en Optimisation Bayésienne III

Idée

- Problème original :

$$\min_{x \in \mathbb{R}^n} f(x) \quad (1)$$

- Construire un nouveau problème :

$$\min_{y \in \mathcal{Y} \subset \mathbb{R}^p} f(Ay) \quad (2)$$

où $A \in \mathbb{R}^{n \times p}$, $p \ll n$

- A est une matrice aléatoire qui définit un sous-espace actif
- Répéter avec plusieurs matrices aléatoires
- Choix de A et du domaine \mathcal{Y} critiques [3, 4, 5]

Réduction de dimension dans MADS

Algorithme STATS-MADS

- Mémoire d'Imen [1, 6]
- Identifier les variables les plus importantes via une analyse de variance, pour fixer les autres variables
- Alternner entre MADS avec toutes les variables et MADS avec les variables les moins influentes fixées

Analyse de sensibilité dans PSD-MADS


- Mémoire de Nadir [2]
- Version parallèle de MADS
- Utiliser la même analyse de sensibilité pour attribuer des variables aux processeurs

Plan

- 1 Introduction
- 2 Réduction de dimension en DFO
- 3 Algorithme**
 - Analyse en composante principale
 - Algorithme PCA-MADS
- 4 Tests et résultats
- 5 Conclusion et suite du projet

Analyse en composante principale

- Transformation de n variables aléatoires corrélées entre elles X en n variables aléatoires $\alpha_i^\top X$, $i = 1, 2, \dots, n$, variables non corrélées
- Les nouvelles variables $\alpha_i^\top X$ sont les composantes principales
- Les $p \ll n$ premières composantes principales reprennent la majeure partie de l'information



Calcul des composantes principales

- Vecteurs propres de la matrice de covariance Σ (ou corrélation) des variables aléatoires X
- Possibilité de calcul à partir d'un nuage de N points $D \in \mathbb{R}^{N \times (n+1)}$
- Possibilité d'approximer la matrice de covariance Σ par

$$S_{ij} = \frac{1}{N-1} \sum_{l=1}^N (D_{li} - \bar{D}_i)(D_{lj} - \bar{D}_j),$$

où $\bar{D}_j = \frac{1}{N} \sum_{i=1}^N D_{ij}$ est la moyenne des réalisations de la j^{e} variable aléatoire.

Algorithme PCA-MADS I

Contexte

- Problèmes en grandes dimensions
- Pas de parallélisme

Structure et idée

- Structure de MADS normale, avec une étape de recherche et une étape de sonde
- Idée : optimisation d'un problème en petite dimension à l'étape de recherche

Algorithme PCA-MADS II

Etape de recherche

- Reprendre un ensemble de points de la cache
- Appliquer une analyse en composante principale sur ce nuage de points
- Identifier les combinaisons de variables qui semblent influencer fortement l'objectif dans une matrice $P \in \mathbb{R}^{n \times p}$, $p \leq n$
- Lancer une instance de MADS sur le problème

$$\min_{y \in \mathbb{R}^p} f(x_k + Py)$$

- Projeter les points à évaluer sur le treillis

Plan

- 1 Introduction
- 2 Réduction de dimension en DFO
- 3 Algorithme
 - Analyse en composante principale
 - Algorithme PCA-MADS
- 4 Tests et résultats
- 5 Conclusion et suite du projet

Suite de problèmes

Fonctions Rosenbrock



$$f(x) = \sum_{i=1}^{n-1} 100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2$$

- Petites dimensions : 2, 3, ..., 20
- Grandes dimensions : 100, 200, ..., 500

Suite bbob de coco

- Suite de 24 fonctions
- Dimensions : 2, 3, 5, 10, 20, 40
- 16 instances par fonctions, dans chaque dimension

Méthodes

Méthodes

- Pca-Mads : implémentation personnelle de l'algorithme, avec la dimension du sous-problème $p = \lceil \frac{n}{5} \rceil$, en Matlab
- Mads : implémentation personnelle en Matlab, la même que Pca-Mads sans étape de recherche
- Nomad-default : Nomad 3.9.1 avec tous les paramètres mis à leur valeur par défaut
- Nomad-basic : Nomad 3.9.1 avec toutes les options désactivées

Résultats : Rosenbrock en petites dimensions




Figure: Profil de données pour l'ensemble de fonctions Rosenbrock en petites dimensions, avec un budget de $100n$

Résultats : Rosenbrock en grandes dimensions




Figure: Profil de données pour l'ensemble de fonctions Rosenbrock en grandes dimensions, avec un budget de $50n$

Résultats : coco en petites dimensions

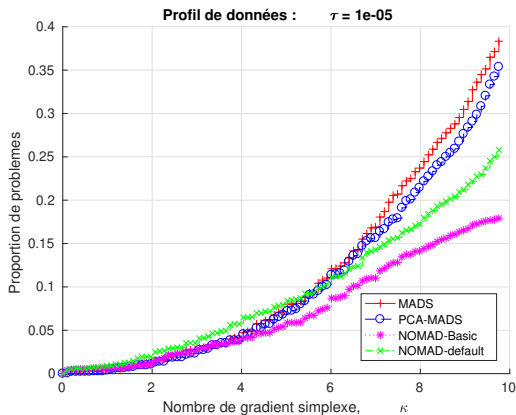


Figure: Profil de données pour l'ensemble de fonctions bbob de coco en petites dimensions, avec un budget de $10n$

Tests sur le paramètre p

Tests sur la dimension réduite

Différentes possibilités pour choisir la dimension du problème réduit p

- $p = n/5$
- $p = n/10$
- $p = n/20$
- Stratégie avec p variable qui divise les composantes principales en deux groupes, à l'aide de l'algorithme *k-means*

Profil pour le paramètre p II

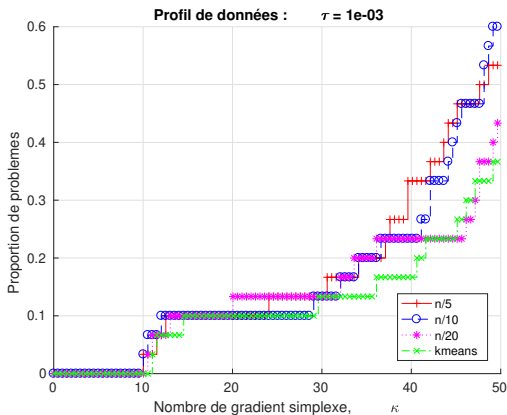


Figure: Comparaison de différentes stratégies de réduction de dimension dans Pca-Mads sur la suite *bbob-largescale* avec un budget de $50n$

Profil pour le paramètre p III

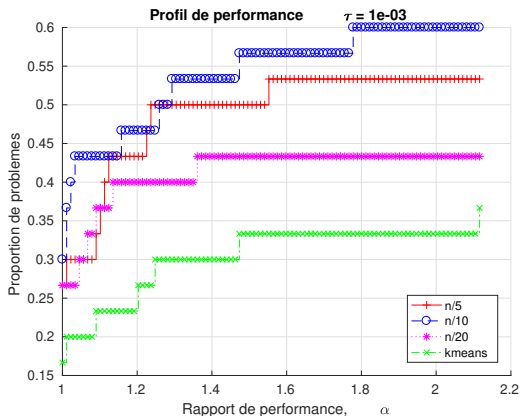


Figure: Comparaison de différentes stratégies de réduction de dimension dans Pca-Mads sur la suite *bbob-largescale* avec un budget de $50n$

Plan

- 1 Introduction
- 2 Réduction de dimension en DFO
- 3 Algorithme
 - Analyse en composante principale
 - Algorithme PCA-MADS
- 4 Tests et résultats
- 5 Conclusion et suite du projet

Conclusion et suite




Conclusion

- PCA-MADS pas efficace pour des problèmes de petites tailles mais semblent intéressants en plus grandes dimensions
- Plusieurs paramètres peuvent influencer les performances de l'algorithme
- Pour l'instant, assez peu de résultats en grandes dimensions




Suite

- Etudier l'influence de chaque paramètre
- Faire plus de tests en grandes dimensions
- Comparer avec d'autres algorithmes en grande dimension
- Tester l'algorithme sur des boîtes noires réelles

Références I

-  L. Adjengue, C. Audet, and I. Ben Yahia B.
A variance-based method to rank input variables of the mesh adaptive direct search algorithm.
Optimization Letters, 8(5):1599–1610, 2014.
-  N. Amaioua.
Modèles quadratiques et décomposition parallèle pour l'optimisation sans dérivées.
PhD thesis, École Polytechnique de Montréal, 2018.
-  M. Binois, D. Ginsbourger, and O. Roustant.
On the choice of the low-dimensional domain for global optimization via random embeddings.
Journal of Global Optimization, 2019.

Références II

-  M. G. B. Blum, M. A. Nunes, D. Prangle, S. A. Sisson, et al.
A comparative review of dimension reduction methods in approximate Bayesian computation.
Statistical Science, 28(2):189–208, 2013.
-  C. Cartis and A. Otemissov.
A dimensionality reduction technique for unconstrained global optimization of functions with low effective dimensionality.
2020.
-  I. Ben Yahia.
Identification statistique de variables importantes pour l'optimisation de boîtes noires.
PhD thesis, École Polytechnique de Montréal, 2012.