

# Conception d'algorithme évolutionnaire à stratégie dynamique basé sur le maximum a posteriori

Asmaa Ghoumari, Amir Nakib, Patrick Siarry

Université Paris-Est Créteil, Laboratoire LISSI, Vitry-sur-Seine, France  
{asmaa.ghoumari, nakib, siarry}@u-pec.fr

**Mots-clés :** *Recherche opérationnelle, optimisation, algorithme évolutionnaire, diversité, apprentissage, maximum a posteriori*

## 1 Introduction

Les algorithmes évolutionnaires (AEs) sont très populaires et largement utilisés mais ils connaissent quelques faiblesses. L'une d'elles concerne le compromis intensification-exploration. En effet, les algorithmes évolutionnaires alternent entre deux principales phases, la première, appelée exploration, permettant une recherche à travers l'espace de recherche de possibles solutions, dont la dispersion est mesurable via la diversité, la seconde, appelée intensification, effectuant une recherche autour d'une de ces solutions. Le compromis intensification-exploration permet de ne pas enfermer l'AE dans un optimum local et d'éviter d'être piégé dans un optimum local. C'est alors que le rôle des opérateurs qui régissent ces phases apparaît crucial ; or, à ce jour, aucune règle n'a encore été trouvée et le choix reste à l'appréciation de l'utilisateur. Dans ce travail, l'objectif est de proposer un algorithme capable d'appliquer la meilleure stratégie respectant le compromis intensification-exploration.

## 2 Algorithme proposé

### 2.1 Maximum a posteriori (MAP)

Nous rappelons la règle de Bayes qui permet d'estimer la probabilité maximum a posteriori :

$$p(X|Y) = \frac{p(Y|X)p(X)}{p(Y)} \quad (1)$$

en désignant par X et Y des évènements ou plus particulièrement X la diversité et Y la stratégie associée. L'objectif du MAP est de maximiser la probabilité a posteriori  $p(X|Y)$  pour  $\hat{Y}$  telle que :

$$\hat{Y} = \operatorname{argmax} p(Y|X) \quad (2)$$

### 2.2 Maximum a posteriori pour le choix d'une stratégie

L'algorithme proposé, appelé MEA, est basé sur une évolution dynamique de la stratégie de recherche de l'optimum. Une stratégie est composée d'une méthode de croisement et d'une méthode

de mutation. En sélectionnant les méthodes les plus couramment utilisées dans la littérature, nous avons cinq méthodes de croisement (BLX- $\alpha$ , discret, *one-point*, linéaire, barycentrique) et quatre de mutation (Levy [1], gaussienne [2], DE/RAND/1/BIN et *scramble*). Ainsi 20 stratégies sont disponibles et peuvent être utilisées par le MEA. L'algorithme va alors employer un mécanisme de remise en question de la stratégie appliquée à des intervalles réguliers de largeur  $\Delta$  générations. A chaque  $\Delta$  l'algorithme va choisir la nouvelle meilleure stratégie à appliquer dans le but de maximiser la diversité future, en calculant le MAP des diversités de chaque stratégie au cours des  $\Delta$  générations passées. La diversité est calculée via la distance euclidienne.

### 3 Analyse et résultats

Afin de tester le MEA nous avons effectué des tests en dimensions 20, 50, 100, 200 sur  $2000 \times \text{dimension}$  générations, avec pour taux de croisement  $CR = 0.7$  et taux de mutation  $MU = 0.3$ , une population  $pop = 50$  et  $\Delta = 50$  générations. Nous avons utilisé six fonctions-test connues dans la littérature : Ackley, Griewank, Rastrigin, Rosenbrock, Schwefel et Sphère.

Les résultats sont calculés sur 100 lancements et montrent le meilleur individu moyen final ainsi que l'écart-type (entre parenthèses) par rapport à l'optimum dans le Tableau 1 :

Dim	Ackley	Griewank	Rastrigin	Rosenbrock	Schwefel	Sphère
20	3.83E-8 (2.03E-7)	5.62E-14 (4.14E-13)	9.10E-12 (5.59E-11)	2.19 (5.43)	-1270.85 (18.37)	0 (0)
50	7.12E-8 (3.60E-7)	2.55E-17 (2.14E-16)	1.52E-13 (1.18E-12)	2.20E-8 (2.03E-7)	-3167.9 (78.75)	0 (0)
100	2.71E-9 (1.79E-8)	2.22E-18 (2.21E-17)	0 (0)	2.44E-11 (1.44E-10)	-6345.03 (129.26)	0 (0)
200	6.70E-9 (6.50E-8)	1.44E-17 (7.31E-17)	0 (0)	1.46E-23 (1.16E-22)	-12727 (7.27E-11)	0 (0)

TAB. 1 – Résultats MEA

Toutes les fonctions-test ont leur optimum global en 0, sauf pour Schwefel pour laquelle il dépend de la dimension comme suit :  $-418.9829 \times \text{dimension}$ . On constate que le MEA obtient des résultats très bons pour les fonctions d'optimisation basiques, car les résultats sont inférieurs à  $10^{-8}$  et de même pour les écarts-type. Cependant le MEA a du mal à atteindre l'optimum pour la fonction Schwefel, laquelle est connue comme particulièrement difficile.

Pour conclure, le MEA est un algorithme génétique se basant sur le principe du maximum a posteriori afin de changer de stratégie en cours d'exécution et de choisir celle qui maximise la diversité à venir. Il s'agit donc d'un modèle fondé sur l'apprentissage. Les premiers résultats obtenus ci-dessus permettent de penser que le MEA est un algorithme prometteur.

### Références

- [1] C-Y Lee, X. Yao, Evolutionary Programming Using Mutations Based on the Levy Probability Distribution. IEEE Transaction on Evolutionary Computation, Vol. 8, No.1, pp. 1-13, 2004.
- [2] R. Hinterding, Gaussian Mutation and Self-Adaptation for Numeric Genetic Algorithms. IEEE International Conference on Evolutionary Computation, Vol. 1, pp. 384, Nov. 1995, Perth, WA, Australia.