

---

# Quoi de neuf dans les algorithmes génétiques ?

Un bilan de 15 ans d'optimisation évolutionnaire


Rodolphe Le Riche, CNRS et Ecole des Mines de St Etienne

leriche@emse.fr

# Le calcul évolutionnaire : définition

Des méthodes numériques basées sur des “populations” de points pour résoudre des problèmes complexes.

- Algos. génétiques (AGs)
- Strat. d'évolutions (ES)
- ...
- Beaucoup d'activité depuis 15 ans.



# Algorithmes évolutionnaires (AE) pour l'optimisation

---

$$\begin{cases} \min_{x \in S} f(x) \\ S \equiv \mathbb{R}^n \text{ ou } \mathcal{D}^n \text{ ou } \{\mathbb{R}^{n1}, \mathcal{D}^{n2}\} \end{cases}$$

- Pas de condition particulière sur  $f$  ou  $S$  (pas rare en optimisation stochastique, cf. le recuit simulé, Monte Carlo ou les recherches taboues).

# AEs : la métaphore Darwinienne

---

Les individus d'une espèce évoluent par reproduction et sélection pour maximiser leur performance dans leur environnement  $\equiv$  résolution d'un pb. d'optimisation.

individu	$x$
chromosome (gènes)	codage de $x$
phénotype (caract. exprimés)	$f(x)$
population	$\{x^1, \dots, x^\mu\}$

Cette métaphore facilite l'explication, mais ne justifie pas les choix algorithmiques !

# Structure d'un AE

---

$t \leftarrow 0$

Initialiser la pop.

Evaluer la pop. ( $f$ )

**Tant que continuer**

$t \leftarrow t + 1$

Sélection.

Reproduction (croisement,  
mutation).

Evaluer les enfants.

Remplacer certains parents  
par les enfants.

**Fin.**

# Plan de la présentation

---

90 - 95	l'essor des AGs, le rêve d'un AE universel
95	NFL et la fin de l'AE universel
95 - auj.	la spécialisation
auj.	quelques tendances



# Période 90-95

---

L'essor des AGs, le rêve d'un AE universel

# I'AE dominant des années 90 :

## I'algorithme génétique

---

J. Holland (1975), D. Goldberg (1989)

Représentation    binaire,  $x$  est écrit  $[0\ 1\ 1\ \dots\ 0]$

Croisement         $\begin{bmatrix} 0|1\ 1\ 1 \\ 1|1\ 0\ 0 \end{bmatrix} \rightarrow [0\ 1\ 0\ 0]$

Mutation            $[0\ 1\ 0\ 0] \rightarrow [0\ 1\ 0\ 1]$

Sélection            $\forall x^i$  et  $x^j$  dans population,  
 $f(x^i) \leq f(x^j) \Rightarrow P_{\text{sél}}(x^i) \geq P_{\text{sél}}(x^j)$



# Théorie des AGs : les schémas

---

Schéma  $\equiv$  sous-ensemble de  $\mathcal{S}$ ,  $\mathcal{H} = \{0 * 1 * 0\}$ .

L'essor des AGs :

- Les schémas courts et performants (BBs) se propagent dans la population par sélection/croisement.
  - Parallélisme implicite : un bon individu favorise tous les schémas auxquels il appartient ( $\Rightarrow$  alphabet binaire).
- $\Rightarrow$  espoirs d'algorithmes performants en moyenne au début des années 90.

Mais :

- Estimation (biaisée) de  $\bar{f}(\mathcal{H})$ .
- Les bons schémas ne contiennent pas nécessairement l'optimum (problèmes difficiles sont non-linéaires).

# Les grands débats des années 90 (I)

---

## ● La représentation

### **codages binaires    contre    codages naturels**

Prc : faire automatiquement émerger les BBs

Codage binaire Gray, évolution du codage (inversion, Holland 75; Messy GAs, Goldberg 91 à 00), ...

Prc : il existe une paramétrisation naturelle (on connaît les BBs, relations d'équivalences).

Vecteurs de nombres réels (Stratégies d'évolution), cellules de Voronoï en optim. topologique (Schoenauer 94 à 00), ...

# Les grands débats des années 90 (II)

---

- Ce qui fait avancer un AE c'est ...

le croisement	vs.	la mutation
le mélange des BBs		les perturbations + la sélection
AGs (Goldberg)		Stratégies d'évolution (Schwefel, Bäck), Programmation évolutionnaire (L. et D. Fogel)

- Le réglage de paramètres : taille de population, pression de sélection, probabilités de mutation et de croisement.

# Vers une spécialisation des AEs

---

- Années 90 : des résultats théoriques et empiriques contradictoires (codages, algos, paramètres).
- Progressivement, généralisation de l'idée de **spécialisation** des AEs au problème ( $\neq$  algo. universel).
- Un résultat théorique vient conforter cette tendance : le théorème du “No Free Lunch”.

# Le théorème du No Free Lunch

---

En moyenne sur tous les problèmes d'optimisation, le comportement de n'importe quel algorithme est le même.  
Wolpert et Macready, 1995

- Interprétation : ce qu'un algorithme gagne sur certains problèmes est perdu sur d'autres.
- En pratique, on ne considère pas tous les problèmes, on exige au moins une certaine régularité de  $f$  sans laquelle le problème de l'optimisation globale ne peut pas être résolu.

## La spécialisation

# Expl. de spécialisation des AEs :

## AEs comme méta-heuristiques

---

- Les AEs gagnent à être couplés à des méthodes d'optimisation locales ou à d'autres heuristiques (“adaptation vs. apprentissage”).
- Couplages en parallèle ou en série :

```
t ← 0, initialiser la pop.
```

```
Evaluer la pop. (f)
```

```
Tant que continuer
```

```
    t ← t + 1
```

```
    Sélection.
```

```
    Reproduction (croisement, mutation, heuristique).
```

```
    Evaluer les enfants.
```


```
    Remplacer certains parents par les enfants.
```

```
Fin tant que .
```

```
heuristique
```

# Expl. de couplage avec une heuristique : mise à l'échelle (1)

(Optimisation de stratifiés composites, R. Le Riche 94)



$$\left\{ \begin{array}{l} \min_{N, \theta_i} N \quad (\text{ou épaisseur } h = Nh_i) \\ \lambda_{\text{flamb}} \geq 1 \quad \text{rupture flambement} \\ \lambda_{\varepsilon} \geq 1 \quad \text{rupture déformations principales} \end{array} \right.$$



## Mise à l'échelle (2)

---

Connaissance RDM pour estimer une nouvelle épaisseur de plaque :

$$\lambda_\varepsilon \approx h \quad , \quad \lambda_{\text{flamb}} \approx h^3.$$

$$\begin{cases} h_{\text{flamb}} = h / \sqrt[3]{\lambda_{\text{flamb}}} \\ h_\varepsilon = h / \lambda_\varepsilon \end{cases} \Rightarrow h = \text{arrondi}_{Nh_i} [\max(h_{\text{flamb}}, h_\varepsilon)] .$$

- Appliqué sur 10% des cas.
- La mutation peut aussi changer l'épaisseur (opt. globale).
- L'algorithme gagne 10% d'efficacité (80% de chances de trouver un optimum pratique en 1310 analyses parmi plus de 10 millions de possibilités).

# Période 00-auj.

---

Deux voies prometteuses

# Tendances récentes (I) :

## algos. à estimation de densités (EDAs)

---

- Les EAs définissent implicitement (à travers le croisement et la mutation) une densité de probabilité d'échantillonner un nouveau point,  $P(x)$ .
- Idée des EDAs (Baluja 94, Mühlenbein 96) : expliciter  $P(x)$  qui remplace les opérateurs génétiques  $\Rightarrow$  meilleure formalisation (Bayes, Markov)

$$P^{t+1}(x) = \frac{P^t_{\text{sélection}}(x) \cdot P^t(x)}{\text{normalisation}}$$


- Difficultés : le choix de  $P$  est un compromis entre sa précision et sa stabilité.

# EDAs : exemple en optimisation de compos- ites

(Grosset et al. 2004)

$$\max f_1(\theta_1, \dots, \theta_{15})$$

$$\text{t.q. } \nu_l \leq \nu_{\text{eff}} \leq \nu_u$$




# Tendances récentes (II) : optimisation multi-critères

(J.F. Aguilar Madeira, 2002)

$$\begin{cases} \min_{x \in S} f_1(x) \\ \dots \\ \min_{x \in S} f_m(x) \end{cases}$$

Ensemble des solutions = ens. des meilleurs compromis = front de Pareto



Les AEs bénéficient de leur population.

# Conclusions

---

- Des méthodes aussi populaires que critiquées depuis 15 ans.
- Les AEs vont (contribuer à) renouveler l'optimisation en déplaçant les centres d'intérêts de l'efficacité vers la représentation, l'extraction de connaissances d'une population, la collaboration entre méthodes ...
- Quel algorithme pour quel problème ? (utilisation de la corrélation  $f$ -distance, ...)

# Backup slides

---

# Calcul évolutionnaire ≡

---

- Les algorithmes génétiques : J. Holland 75 (psychologie, biologie), D. Goldberg 89 (SPI).
- Les stratégies d'évolution : I. Rechenberg 65, H.-P. Schwefel 81, T. Bäck 95 (optimisation).
- La programmation évolutionnaire : L.J. Fogel (62) (prog. d'automates), D.B. Fogel (88).
- La programmation génétique : J. Koza (94) (programmation automatique).
- L'optimisation statistique (EDAs, Bayésienne) : Baluja (94), Mühlenbein (99).

⇒ 30 ans d'histoire, des milliers d'applications dans tous les domaines, > 10 conférences intl. par an, > 3 revues.



# La spécialisation des AEs (I) : l'auto-adaptation

---

Les paramètres de l'AE sont sur le chromosome

[  $x$  *prob\_mutation* *prob\_croisement* ... ]


Ils subissent les opérations génétiques et sont donc adaptés comme  $x$ .

# L'auto-adaptation (exemple)

Auto-adaptation de la mutation dans ES (Schwefel 77, Bäck 91).


Mutation = perturbation Gaussienne,  $x' = x + \mathcal{N}(O, C)$ .

1. Muter la mutation,  
 $C \rightarrow C'$
2. Utiliser  $C'$ ,  
 $x' = x + \mathcal{N}(O, C')$
3. Evaluer  $f(x')$ ,  
sélectionner  $[x' \quad C']$ .



# EAs : estimation de densité implicite


---



population initiale uniforme

# EAs : estimation de densité implicite


---



points gardés par sélection

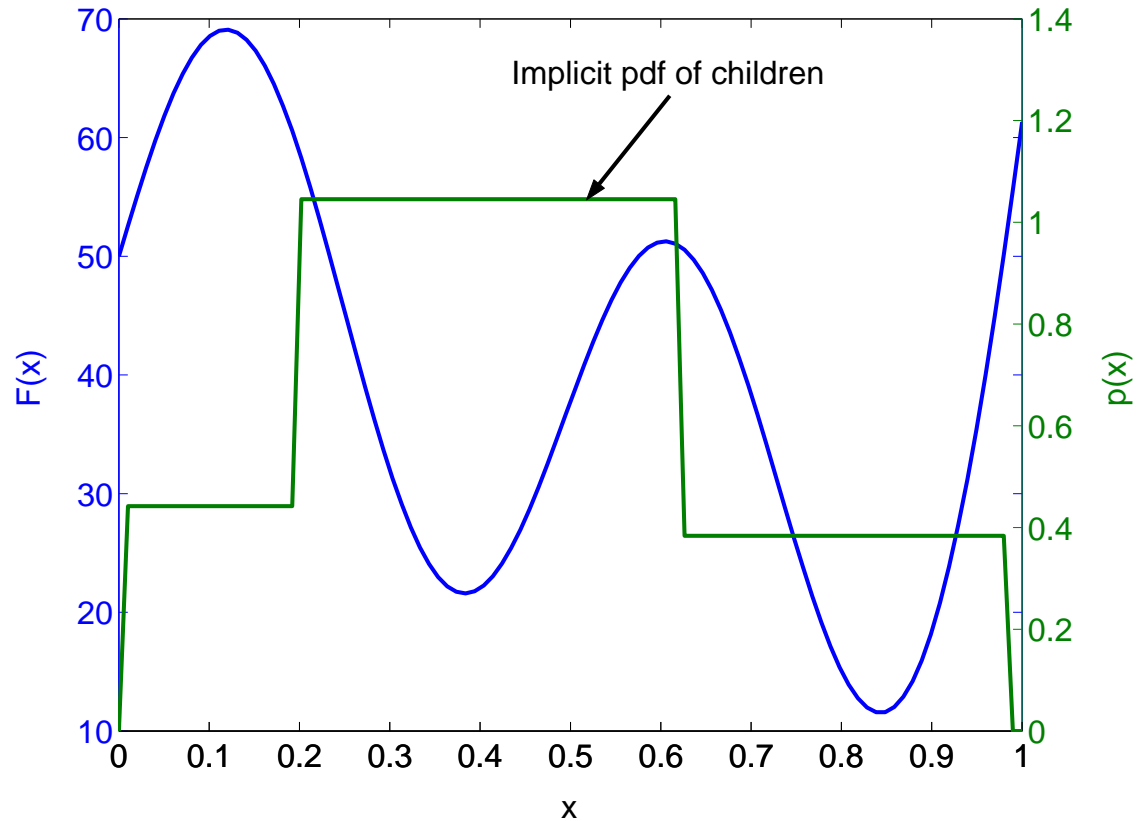
# EAs : estimation de densité implicite

---



création de nouveaux points par croisement  
(weighted average in  $\mathbb{R}^n$ )


# EAs : estimation de densité implicite



création de nouveaux points par croisement

# EAs : estimation de densité implicite

---




nouvelle population

# Tendances récentes (I) :

## fonctionnement schématique d'un EDA

---




population initiale uniforme



# Tendances récentes (I) :

## fonctionnement schématique d'un EDA


---



points gardés par la sélection

# Tendances récentes (I) :

## fonctionnement schématique d'un EDA




estimation de la densité des bons points  $P(x)$

(noyaux,  $P(x) = \text{const}/N \sum_{i=1}^N \exp(-(x - x_i)^2 / (2\sigma^2))$  )

# Tendances récentes (I) :

## fonctionnement schématique d'un EDA




densité des bons points estimée  $P(x)$

# Tendances récentes (I) :

## fonctionnement schématique d'un EDA

---



nouvelle population obtenue par échantillonnage de  $P(x)$

# Tendances récentes (II) : optimisation multi-critères

$$\begin{cases} \min_{x \in S} f_1(x) \\ \dots \\ \min_{x \in S} f_m(x) \end{cases}$$

Ensemble des solutions =  
front de Pareto = ens. des  
points non dominés.


$x$  domine  $y$  ssi,

$\forall i, f_i(x) \leq f_i(y)$  et

$\exists j / f_j(x) < f_j(y)$

## Exemple

$$\begin{cases} \min_{x \in S} \text{masse}(x) \\ \min_{x \in S} \text{coût}(x) \end{cases}$$




solutions introuvables  
par  $\min(\text{masse} + c * \text{coût})$

# Tendances récentes (II) :

## optimisation multi-critères par AEs

(J.D. Schaffer 85, J. Horn et al. 94, K. Deb 98)

- Essentiellement le calcul de la performance est modifié / AE monocritère.
- Calcul de la performance :
  - Utilise la domination de Pareto.
  - Préserve la diversité (dans esp. des  $x$  ou des  $f$ ).

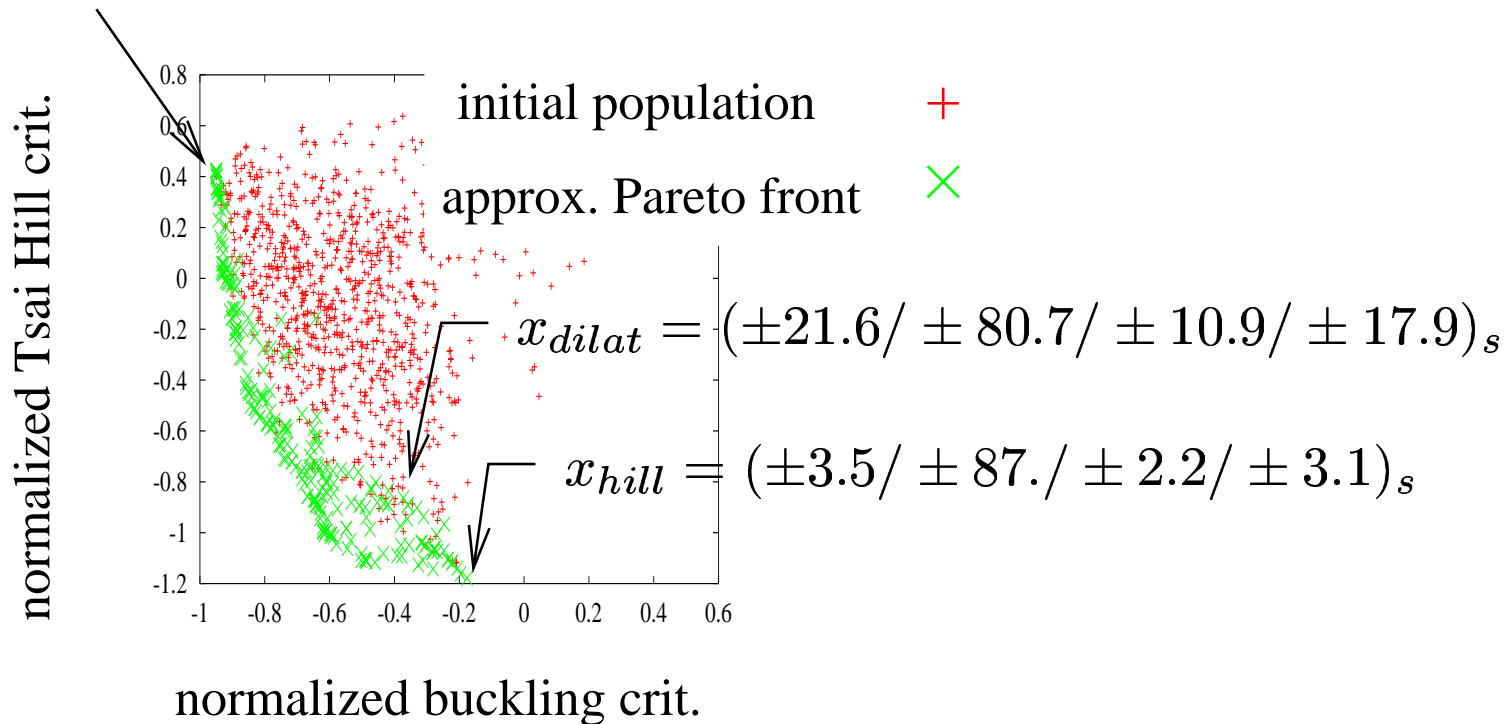


- L'élitisme a besoin d'une archive.

# Optimisation multicritères de composites

(R. Le Riche, 2001)


$$x_{buck} = (\pm 46.3 / \pm 44.8 / \pm 46.6 / \pm 43.)_s$$



Projection du front de Pareto des critères de dilatation thermique longit., flambement, et rupture (Tsai-Hill) dans le plan (Tsai-Hill, flambement). Graphite / epoxy,  $1 \times 1 m$ ,  $N_x = -100000. N$ ,  $N_y = 10000. N$ . Niche Pareto GA.

# Optimisation multicritères de topologies

(J.F. Aguilar Madeira, 2002)



Struct. de volume constant. Non Dominated Sorting GA + sélection avec clustering.