


# THEORIE DES ALGORITHMES ÉVOLUTIONNAIRES



*Evelyne LUTTON*

Equipe APIS - INRIA Saclay - Ile-de-France - [Evelyne.Lutton@inria.fr](mailto:Evelyne.Lutton@inria.fr)

<http://complex.inria.fr/>

# THÉORIE DES AEs

## Questions

- Convergence.
- Fonctions “déceptives.”
- Choix et ajustement des paramètres.
- Représentation/Codage.

2

## Deux grandes approches

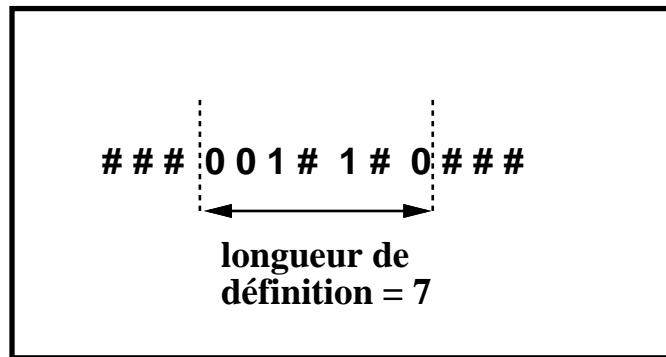
- Théorie des Schémas (*Holland, 1975*)
- Modélisation Markovienne (*depuis 1987*)



## THÉORIE DES SCHÉMAS

**Intuition** : les similarités entre codes guident la recherche.

Notion de schéma : le schéma #001 représente le sous ensemble : {0001, 1001}



– Nombre d'allèles fixés :  $\mathcal{O}(H)$

– Longueur de définition :  $\delta(H)$

**LE THEORÈME DES SCHÉMAS**, pour des populations de taille infinie. : (Holland, 1975)

$$E(m(H, t + 1)) \geq m(H, t) \frac{\overline{f(H)}}{\bar{f}} \left[ 1 - p_c \frac{\delta(H)}{l-1} - \mathcal{O}(H) p_m \right]$$

## NOTION DE DÉCEPTIVITÉ

*Building blocks* = “bons” schémas ayant des  $\mathcal{O}(H)$  et des  $\delta(H)$  faibles.

- *AG-facile* : l’optimum global de  $f$  appartient à l’intersection des building blocks.
- *AG-difficile* : l’intersection des building blocks est toujours un optimum local.
- *Déceptivité statique* (Goldberg 89) : attraction de l’AG vers les optima d’une fonction  $f'$  :

$f'(i) = E(f(i'))$  où  $i'$  peut être atteint à partir de  $i$  par mutation et croisement.

Si l’optimum global de  $f'$  et de  $f$  diffèrent la fonction est déceptive.



## MODÉLISATION MARKOVIENNE

Le passage d'une génération à la suivante peut être considéré comme un processus stochastique dans un espace d'états fini. → **Chaîne de Markov**

– *Goldberg et Segrest, 1987 :*

- Chromosomes de longueur 1
- Population de taille finie
- ==> dérive génétique

– *Horn, 1993 :*

- Niches écologiques

– *Davis et Principe, 1991 :*

- chromosomes de longueur  $> 1$
- ==> décroissance de la probabilité de mutation

– *Nix et Vose, 1992 :*

- la population croît pendant l'évolution

– *Cerf, 1993.*

---

## Les résultats sur la convergence

### Convergence “dans le cas le pire” :

Résultats globaux (simples).

- Théorie des Schémas,
- Modélisations Markoviennes,
- “The genetic algorithm fractal” (Juliany & Vose).

### Fitness contrôlé :

Les résultats sont plus précis grâce à des hypothèses restrictives sur la fonction de fitness :

- NK Landscapes,
- Stratégies d’évolution sur des modèles de sphères,
- Analyse de régularité fractale.

## Paysages irréguliers et fractals

L'irrégularité est une source de difficultés pour les AEs

---

- Existe-t'il un lien entre irrégularité et performance des AEs ?
  - Comment rendre les AEs plus efficaces sur des paysages de fitness irréguliers ?
-

## Caractérisation uniforme de la régularité de la fonction de fitness

Soient  $(X, d_X)$  et  $(Y, d_Y)$  deux espaces métriques.

$F : X \rightarrow Y$  est une fonction **Höldérienne d'exposant  $h \geq 0$**

si  $\forall x, y \in X$  tel que  $d_X(x, y) < 1$

$$d_Y(F(x), F(y)) \leq k \cdot d_X(x, y)^h$$


∞ pour une constante  $k > 0$ .

- Si  $F$  est Höldérienne d'exposant  $h$ , elle est Höldérienne d'exposant  $h'$  pour tout  $h' \in (0, h]$ .
  - Une fonction A Höldérienne est toujours continue, mais non nécessairement différentiable.
-




## Fonctions de Weierstrass

$$W_{b,s}(x) = \sum_{i=1}^{\infty} b^{ih} \sin(b^i x) \quad \text{avec } b > 2 \text{ et } 0 < h < 1$$



Dimension  $s = 1.5$  (Hölder  $h = 0.5$ )



Dimension  $s = 1.7$  (Hölder  $h = 0.3$ )

Fonction + topologie génétique = fitness landscape

La mesure de régularité dépend de la métrique définie sur l'espace de recherche.

Pour les AEs : l'irrégularité apparente dépend de la topologie "génétique."

→ Le design des opérateurs génétiques est extrêmement important.

---


## L'algorithme génétique canonique

Fonction de fitness :  $f : \Omega^l = \{0, 1\}^l \rightarrow \mathbb{R}^+$

– Sélection proportionnelle :

$$P(i) = \frac{f(i)}{\sum_{j=1}^N f(j)}$$

≡ – Crossover à un point avec probabilité  $p_c$  sur un couple d'individus :



– Mutation avec une probabilité fixée faible,  $p_m$ .

---

## Mesure de difficulté pour un paysage de fitness

- *Static deception (Goldberg 89)* : L'AG est attiré vers les optima de  $f'$  :

$$f'(i) = E(f(i'))$$

où  $i'$  est atteint à partir de  $i$  par une mutation ou un crossover.

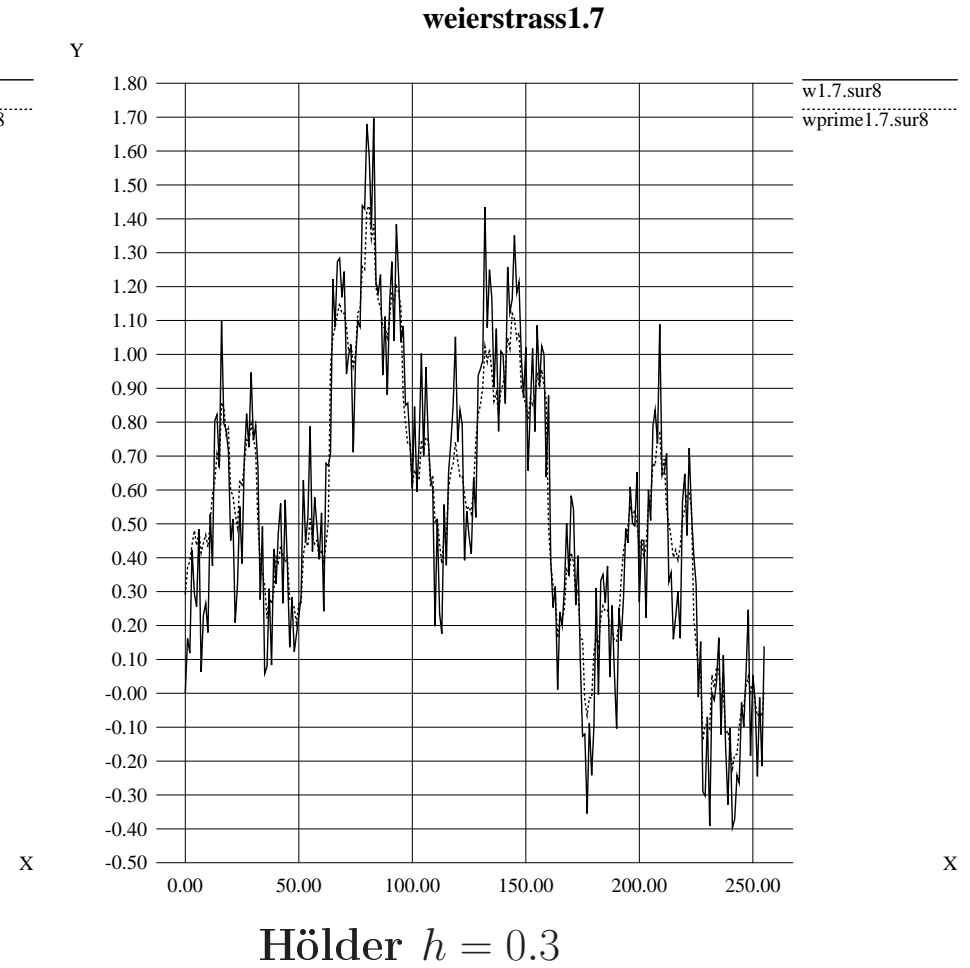
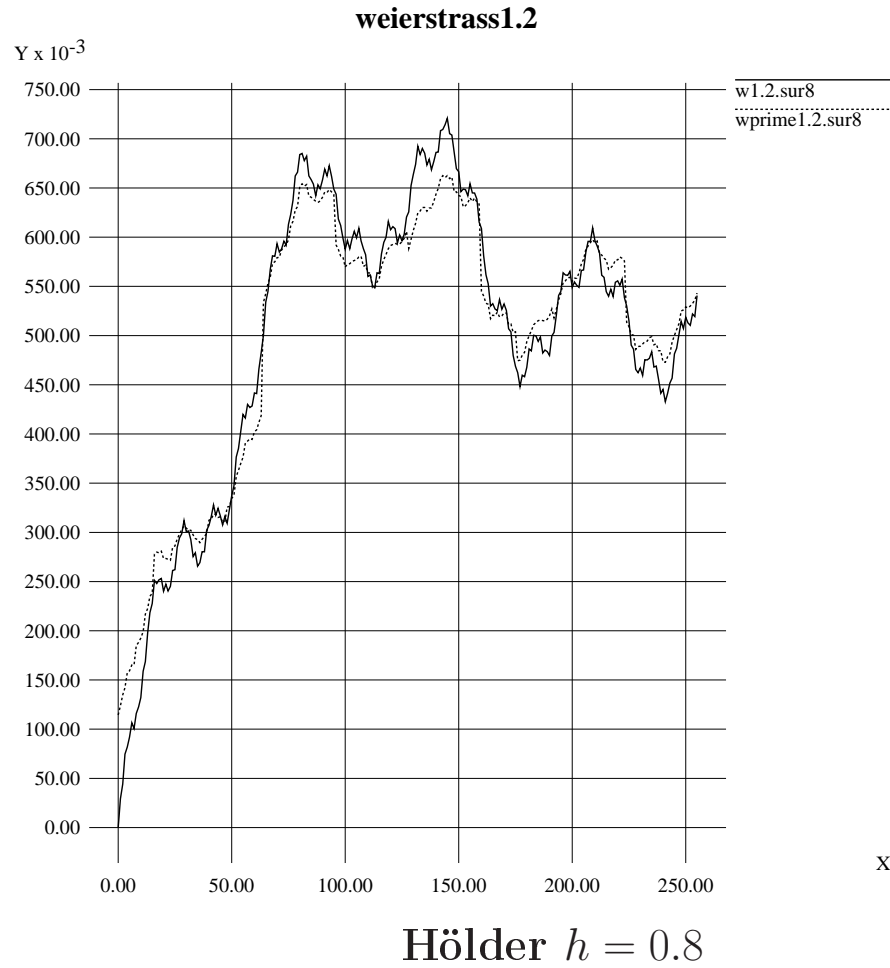
Si l'optimum global de  $f'$  et de  $f$  diffèrent, la fonction est “trompeuse” ( $\simeq$  AG-difficile)

$f'$  peut être calculée à partir de  $f$ ,  $p_m$  et  $p_c$  grâce à une décomposition sur une base de Walsh.

---

# Fitness ajusté pour les fonction de Weierstrass

13



## Fitness ajusté et taux de progrès

$$\Delta f = |f(x) - f'(x)| = |f(x) - E_{\text{Voisins "Genetiques"}}(f(x))|$$

$\Delta f$  est un gain espéré (– ou perte désespérée !) pour la fonction de fitness en une application des opérateurs génétiques.

Pour un (1+1)ES sur un espace de recherche continu,  $\Delta f$  est directement lié au **taux de progrès**.

---

## Fonctions Höldériennes

Si  $f$  est l'échantillonnage d'une fonction Höldérienne  $F$  sur  $[0, 1]$ , d'exposant  $h$  et de constante  $k$  :

$$\forall x \in \{0, 1\}^l, \quad f(x) = F\left(\frac{I(x)}{2^l}\right)$$


$I(x) \in [0, 2^l - 1]$  est l'entier dont la décomposition binaire est  $x$

$$\forall x \in \{0, \dots, 2^l - 1\} \quad |f(x) - f'(x)| \leq k \cdot B(p_m, p_c, l, h)$$

avec

$$B(p_m, p_c, l, h) = \frac{p_c}{l-1} 2^{-h} \left[ \frac{2^{-l(h+1)} - 1}{2^{-(h+1)}} + \frac{(1 - 2^{l-h})(2^{-hl} - 1) - l 2^{-hl}(1 - 2^{-h})}{(2^{-h} - 1)^2} \right] \\ + p_m \frac{2^{-h}}{(2^{-h} - 1)^2} [1 + 2^{-hl}(l 2^{-h} - l - 1)]$$

## Majoration de $\Delta f = |f(x) - f'(x)|$



- $B$  décroît selon  $h$ .
- $B$  croît selon  $p_m$  et  $p_c$ .
- $B$  croît selon  $l$  pour  $l$  petit, atteint un maximum en  $l_{max}$ , puis décroît pour  $l > l_{max}$ .



Coefficients de régularité bit-à-bit : caractérisation fondée sur la distance de Hamming.

Définition : soit  $f$  une fonction définie sur  $\Omega^l$  :

$$\forall q \in \{0, \dots, l-1\}, C_q = \sup_{x \in \Omega^l} \{|f(x) - f(x'_{l-q-1})|\}$$

avec  $x'_{l-q-1}$  et  $x$  différents uniquement selon le bit de position  $(l - q - 1)$

17

Théorème :

Soit  $f$  une fonction définie sur  $\Omega^l$  dont les coefficients de régularité bit-à-bit sont  $(C_q)_{q \in \{0, \dots, l-1\}}$ .

Alors  $\forall x \in \Omega^l$  :

$$|f(x) - f'(x)| \leq \frac{p_c}{l-1} \sum_{q=0}^{l-1} C_q \left( \frac{1 + 2^q(q-1)}{2^q} \right) + p_m \sum_{q=0}^{l-1} C_q (q+1)$$

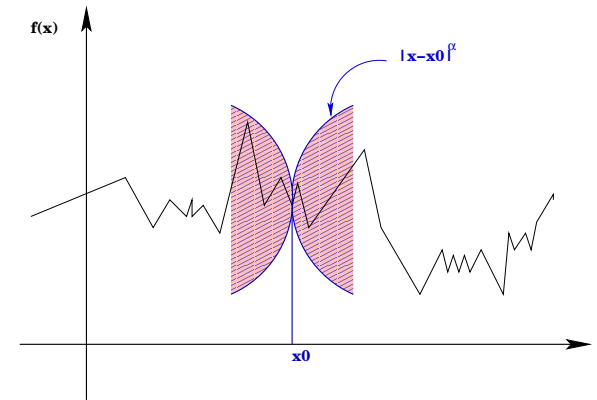
---

## Régularité locale

Soit  $\alpha \in (0, 1)$ ,  $\Omega \subset \mathbf{R}$ .

$f \in C_l^\alpha(\Omega)$  ssi  $\exists k : \forall x, y \in \Omega : |f(x) - f(y)| \leq k|x - y|^\alpha$

$\alpha_l(f, x_0, \rho) = \sup \{ \alpha : f \in C_l^\alpha(B(x_0, \rho)) \}$



*L'exposant de Hölder local* d'une fonction continue  $f$  en  $x_0$  est :

$$\alpha_l(f, x_0) = \lim_{\rho \rightarrow 0} \alpha_l(f, x_0, \rho)$$


## Expérience : influence de la régularité locale

L performance d'un ES est-elle affectée par un changement de régularité locale ?

Fonction de Weierstrass généralisée :

$$GW_{b,h}(x) = \sum_{i=1}^{\infty} b^{-ih(x)} \sin(b^i x)$$

with  $b \geq 2$  and  $0 < h(x) < 1$



Si  $h$  est différentiable, l'exposant de Hölder local de  $GW_{b,h}$  est  $h(x)$  en tout  $x$ .

---

## Fonctions-test

Composante lisse + irrégularité normalisée et contrôlée sur  $[-0.5, 0.5]$  :

$$f(x) = 2 - 4x^2 - |NW_{b,h}(x)|$$

1.  $N(x)$ , cas favorable : les zones irrégulières ont un fitness peu élevé

$$h(x) = 0.9 \quad \text{si} \quad x \in [-0.2, 0.2]$$

$$h(x) = 0.1 \quad \text{sinon}$$


2.  $U(x)$ , cas défavorable : les points les plus irréguliers sont au voisinage de l'optimum global

$$h(x) = 0.1 \quad \text{si} \quad x \in [-0.2, 0.2]$$

$$h(x) = 0.9 \quad \text{sinon}$$


---

## Fonction-test $N$




$N(x)$  : le profil de régularité “n”

## Fonction-test $U$



$U(x)$  : le profil de régularité “u”

Test : (1+1)ES avec mutation uniforme de rayon  $\sigma$



Moyenne des meilleurs fitness au bout de 300 generations d'un (1+1)ES pour  $U$  et  $N$  en fonction de  $\sigma$ .

## Analyse théorique d'un ES à mutation uniforme

Pour une mutation uniforme de rayon  $\sigma$ ,  $f'$  est le fitness espéré sur un disque de rayon  $\sigma$ .

$$f'(x) = \frac{1}{2\sigma} \int_{x-\sigma}^{x+\sigma} f(t) dt$$

Comme  $f$  est localement Hölder, nous avons pour tout  $x : \forall t \in B(x, \sigma) \quad |f(x) - f(t)| \leq C_x |x - t|^{\alpha(x)}$

$|f(x) - f'(x)|$  est donc majoré en fonction de l'exposant de Hölder local  $\alpha(x)$ .

$$|f(x) - f'(x)| \leq \frac{C_x \sigma^{\alpha(x)}}{\alpha(x) + 1}$$

---



## Analyse

$\Delta f(x) = |f(x) - f'(x)|$  est la variation de fitness espérée dans le voisinage de  $x$ .

Pour un  $\sigma < 1$  fixé, elle décroît quand  $\alpha$  croît.

Pour des rayons de mutation suffisamment petits, les fonctions plus lisses sont plus faciles à optimiser.

→ Une mutation dépendant de la localisation  $\sigma = \sigma(x)$  ?

→ Réglée pour obtenir un majorant constant sur  $\Delta f(x)$  tout le long de la trajectoire ?

---

## Une mutation dépendant de la localisation

$\frac{C_x \sigma^{\alpha(x)}}{\alpha(x)+1} = K$ , un paramètre défini par l'utilisateur.

$$\sigma(x) = \left( \frac{K(\alpha(x) + 1)}{C_x} \right)^{\frac{1}{\alpha(x)}}$$

26

Selon la valeur de  $\frac{K}{C_x}$ , le rayon de mutation peut

- croître avec  $\alpha$  (quand  $\frac{K}{C_x} \leq 0.8$ ),
  - ou décroître avec  $\alpha$  (quand  $\frac{K}{C_x} \geq 1$ ).
-

## Expériences avec $N$ et $U$

Deux (1+1)ES ont été comparés :

- avec mutation de rayon fixé : (ES),
- avec rayon de mutation adaptatif : (ESadapt).

$$\sigma(x) = \beta \left( \frac{K(\alpha(x) + 1)}{C_x} \right)^{\frac{1}{\alpha(x)}}$$


$C_x$  et  $K$  sont considérés comme constants sur  $N$  et  $U$ .

$\beta$  varie de façon à avoir un rayon variable de valeur moyenne comparable à la valeur fixée  $\sigma$  de l'ES.

Les statistiques sont faites sur 100 runs pour chaque jeu de paramètres.


---

## Recherche aléatoire pure




Résultats moyens (100 runs) d'un algorithme de recherche aléatoire pure sur  $U(x)$  et  $N(x)$ , le nombre des évaluations est en abscisse.

## Profils adaptifs $\sigma(x)$ pour $N$ et $U$



Pofil Sigma pour  $N(x)$




Pofil Sigma pour  $U(x)$ .

→ Un  $\sigma$  plus large pour les zones les plus irrégulières.


---

## 10 générations d'un (1+1)ES

30




Résultats sur  $N(x)$ .




Résultats sur  $U(x)$ .



## Comparaison de $U(x)$ et $N(x)$ , 10 générations



ES



ESadapt

## Estimation des exposants en ligne

La méthode requiert le calcul de  $\alpha(x)$  et de la norme Höldérienne  $C_x$  en chaque  $x$  :

- $:-$  ( L'échantillonnage d'un voisinage a un coût calculatoire.
- $:-$ ) Les évaluations antérieures peuvent être utilisées.
- $:-$ ) Un AE échantillonne préférentiellement les régions intéressantes (optima).

Un routine d'estimation de  $C_x$  peut être intégrée à un  $(1 + \lambda)ES$  avec très peu de de calculs additionnels.

**Question actuelle :** Design d'une routine efficace d'estimation de  $C_x$  et  $\alpha(x)$  en ligne pour les  $(\mu, \lambda)ES$  et les  $(\mu + \lambda)ES$ .

---



## Estimation de $C_x$ et de $\alpha(x)$

Echantillonnage de  $f$  sur un voisinage de taille  $\varepsilon$  autour de  $x$  :  $f(x_i)$  pour  $x_i = x - i/n, \dots, x + i/n$  (en pratique,  $i \simeq 3$ ).

Oscillation  $\text{osc}_\rho$  de  $f$  sur  $B(x, \rho)$  pour  $\rho = 1/n, \dots, i/n$  :

$$\text{osc}_\rho = \sup_{y \in B(x, \rho)} f(y) - \inf_{y \in B(x, \rho)} f(y).$$

Régression aux moindres carrés du vecteur  $(\log(\text{osc}_\rho))_\rho$  selon  $(\log(\rho))_\rho$  :

- $\alpha(x)$  est la pente,
  - $C_x$  est le point de croisement de la droite avec l'axe des ordonnées.
-

## Juliany & Vose “The genetic algorithm fractal”

Un modèle de système dynamique des AEs fondé sur un théorème des schémas avec égalité : les populations successives peuvent être représentées à l'aide d'une fonction  $\mathcal{G}$ .

A partir d'une population initiale aléatoire  $x$ , l'AE produit des populations successives :  $\mathcal{G}(x), \mathcal{G}^2(x), \dots, \mathcal{G}^n(x)$

⇒ Visualisation des bassins d'attraction  $\mathcal{G}^\infty(x)$  de ce système dynamique produit des images fractales.

---

Juliany & Vose “The genetic algorithm fractal”

