

État de l'art des algorithmes génétiques

Evelyne Lutton

INRIA

28 Mars 1994

[summary by Evelyne Lutton]

Abstract

Les algorithmes génétiques constituent un modèle d'adaptation extrêmement simplifié des systèmes naturels, et sont employés avec succès dans les systèmes artificiels. Ce modèle offre des possibilités non seulement dans le domaine de l'optimisation stochastique, mais aussi dans bien d'autres domaines d'applications, et donne un nouvel éclairage à l'étude des mécanismes de l'évolution naturelle.

Le champ d'application des algorithmes génétiques est très large : il va des applications réelles complexes comme le contrôle du flux de pipelines de gaz, le design de profils d'ailes, ou la planification de trajectoires de robots, à des problèmes plus théoriques de combinatoire, de théorie des jeux, d'économie et d'apprentissage.

1. Introduction

L'idée d'utiliser les principes des processus d'évolution organique en tant que technique d'optimisation globale a émergé indépendamment des deux côtés de l'océan Atlantique il y a une vingtaine d'années. Ces deux approches reposent sur l'imitation du phénomène d'apprentissage collectif d'une population naturelle, basée sur les observations de Darwin et sur la théorie moderne de l'évolution. Ces deux courants ont évolué parallèlement jusqu'à ces dernières années, chacun ayant son champ d'application particulier, tous deux devenant actuellement de plus en plus attirants aussi bien pour les chercheurs que pour les industriels, grâce notamment à la vulgarisation des calculateurs parallèles.

Le courant américain, initialisé par Holland dans les années soixante, a développé ce que l'on appelle les *Algorithmes Génétiques* [6]. Bien qu'ils aient été prévus initialement dans le cadre d'optimisations ou d'adaptations dans le domaine discret, les algorithmes génétiques ont été facilement étendus à l'optimisation sur des domaines continus. En Allemagne, sont apparues à peu près en même temps des méthodes appelées *Stratégies d'Évolution* [5]. Ces méthodes étaient au contraire prévues initialement pour fonctionner sur des domaines continus, et ont été étendues à des applications en optimisation discrète.

Il est relativement malaisé de donner une définition stricte de ce que sont ces approches évolutives (algorithmes génétiques ou stratégie d'évolution) en général. Ce que l'on peut dire, c'est que ces méthodes ont emprunté à la génétique naturelle (et simplifié !) un certain nombre de principes sous-jacents, pour en faire des méthodes algorithmiques, qui s'apparentent dans une certaine mesure aux méthodes d'optimisation combinatoires.

2. Qu'est-ce qu'un algorithme génétique ?

Au premier abord, les algorithmes génétiques peuvent être considérés comme des méthodes d'optimisation stochastique, mais ils ont bien d'autres champs d'applications, comme par exemple en reconnaissance des formes et en intelligence artificielle (systèmes de classeurs ou programmation génétique), en théorie des graphes, en vision et en analyse d'images, en science des matériaux, etc.

L'intérêt d'utiliser un algorithme génétique pour optimiser des fonctions irrégulières est qu'ils savent effectuer une recherche stochastique dans un large espace de recherche, en faisant évoluer un ensemble de solutions (appelée *population*), au lieu d'une seule solution, comme cela est fait classiquement en optimisation stochastique (exemple : un recuit simulé).

Dans l'évolution naturelle, le problème auquel chaque espèce est confrontée est de chercher à s'adapter à un environnement complexe et généralement non statique. Très schématiquement, la "connaissance" acquise par chaque espèce est codée dans les chromosomes de ses membres. Lors des reproductions sexuées, les contenus des chromosomes sont mélangés, modifiés et transmis aux descendants par un certain nombre d'opérateurs génétiques : la mutation, qui se traduit par l'inversion d'une faible partie du matériel génétique, et le croisement (ou recombinaison) qui échange certaines parties des chromosomes des parents. Cette particularité de l'évolution naturelle : la capacité d'une population à explorer son environnement en parallèle et à recombinaison les meilleurs individus entre eux, est copiée et exploitée au sein d'un algorithme génétique.

Un résultat formel important mis en évidence par Holland [6] (largement reconnu comme le fondateur du domaine) a été de prouver que, même dans des espaces de recherche larges et complexes, sous certaines conditions, les algorithmes génétiques convergent vers des solutions qui sont à peu près globalement optimales. C'est-à-dire que la population se concentre autour d'un optimum global (théorie des Schémas [4]).

Dans toutes les approches évolutives, les *individus* représentent des solutions ou des points de l'espace de recherche. Cet espace de recherche est appelé *environnement*, c'est sur cet environnement que l'on cherche à maximiser une fonction (positive) appelée *fitness*.

La principale caractéristique des algorithmes génétiques, par rapport aux autres techniques d'inspiration comportementale, est de travailler sur des codages et non sur des solutions réelles. Ces codes sont appelés *chromosomes* et la plupart du temps, en optimisation, ils sont binaires et de longueur fixe. L'algorithme génétique fait donc évoluer sa population de façon à *adapter* les individus à l'environnement, cela se traduit au sens algorithmique du terme par une *maximisation* de la fonction d'évaluation sur les individus de la population.

3. Structure d'un algorithme génétique

La construction d'un algorithme génétique pour une application particulière impose de définir un certain nombre de composantes [2] :

- (1) une représentation chromosomale des solutions au problème ;
- (2) une méthode de création de la population initiale de solutions ;
- (3) une fonction d'évaluation qui joue le rôle de l'environnement, et qui permet d'évaluer les solutions plus ou moins "adaptées" (on parle de *fitness*) ;
- (4) des opérateurs génétiques qui modifient la composition des chromosomes des enfants au cours de la reproduction ;
- (5) les valeurs des paramètres que l'algorithme génétique emploie (taille de population, probabilités d'application des opérateurs génétiques, etc.).

La structure schématique d'un algorithme génétique est présentée en figure 1. Il existe un grand nombre de variations autour de cette structure.

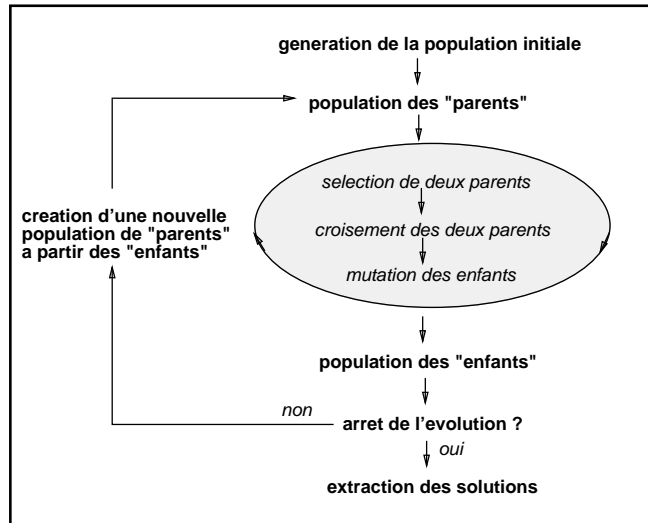


FIGURE 1. Organigramme de l'algorithme génétique simple, cf. [4].

Les solutions (ou *individus*) de la population entrent dans un processus d'évolution. Certaines solutions, meilleures que les autres (leurs fonctions d'évaluations sont meilleures), ont plus de chance de survivre et de transmettre leur patrimoine génétique. La convergence d'un algorithme génétique se traduit par la concentration des individus de la population dans des régions de l'espace de recherche qui présentent un optimum global de la fonction d'évaluation.

La procédure d'initialisation d'un algorithme génétique se fait le plus souvent aléatoirement : les individus de la population initiale sont aléatoirement répartis dans l'espace de recherche. Il est très facile d'introduire des informations *a priori* (sous formes de solutions initiales) dans la population initiale, de façon à accélérer la convergence.

L'évolution de la population se fait par reproduction sexuée. La création d'une nouvelle population (des "enfants") se fait par application de trois opérateurs :

- la *sélection* de deux parents, selon un critère d'adaptation à l'environnement (pour favoriser la reproduction des "bons" individus), c'est là qu'intervient la fonction que l'on cherche à maximiser ;
- le *croisement* des chromosomes des deux parents pour créer les chromosomes de deux enfants (par échange de parties de chromosomes entre les parents) ;
- la *mutation* des chromosomes des enfants (petite perturbation aléatoire sur le chromosome).

La sélection agit comme un opérateur de "concentration", tandis que le croisement a plutôt une action d'exploration. Sélection et croisement favorisent donc la concentration de la population dans des régions de l'espace de recherche où la fonction d'évaluation a des valeurs élevées, avec le risque cependant d'obtenir une convergence prématurée par perte de "diversité génétique" (on dit aussi : par "dérive génétique"). Au contraire la mutation agit comme un opérateur de "dispersion" au sein de la population, et l'on peut démontrer que la mutation permet de maintenir la diversité génétique de la population, et ainsi d'assurer la convergence vers un optimum global. L'efficacité d'un algorithme génétique est donc liée au dosage subtil de ces diverses composantes, afin de converger le plus rapidement possible vers l'optimum global de la fonction à optimiser.

La modélisation et la compréhension des actions de ces trois opérateurs ont été tout d'abord faites au sein de la théorie des Schémas [4, 6]. Plus récemment, les approches par modélisation Markovienne des algorithmes génétiques ont permis de démontrer les effets et l'efficacité de ces

opérateurs [1, 3, 8]. De plus, Davis a proposé il y a peu une démonstration de convergence de l'algorithme génétique simple [3], sur le modèle de la démonstration de la convergence du recuit simulé. Cela lui a permis de proposer une formule de décroissance de la probabilité de mutation (très lente) qui garantit la convergence de l'algorithme vers un optimum global. Le paramètre de probabilité de mutation agit donc de manière similaire à une température dans un recuit simulé.

4. Des applications très nombreuses et très variées

Les algorithmes génétiques classiques, tels que nous venons de les décrire, ont été étendus d'une part par imitation des phénomènes d'évolution naturelle comme la création de niches écologiques (pour l'optimisation de fonctions multimodales) ou la co-évolution de différentes populations (où l'on recherche un état d'équilibre). D'autre part, l'emploi d'autres types de codes que les codes binaires, ont permis des applications orientées Intelligence Artificielle comme les *systèmes de classeurs*, qui manipulent des chromosomes représentant des règles, ou la *programmation génétique*, où les chromosomes représentent directement des programmes arborescents [7].

Les algorithmes génétiques et les algorithmes évolutifs en général intéressent des chercheurs et des ingénieurs de disciplines très diverses, par exemple :

- en optimisation : lorsque les fonctions à optimiser sont complexes, de forte dimensionnalité, irrégulières, mal connues ;
- en intelligence artificielle et sciences cognitives : où l'on exploite plutôt les capacités adaptatives des algorithmes génétiques, et les techniques fondées sur les systèmes de classeurs, (réseaux de neurones, évolution de langages, grammaires) ;
- en robotique : où l'on s'intéresse aux MOBOTS (MOBILE roBOTS) qui doivent pouvoir se mouvoir et agir dans des environnements inconnus, variables (programmation génétique, systèmes de classeurs) ;
- en physique et en ingénierie : en tant que méthode d'optimisation pour les problèmes réels complexes (pour l'optimisation de structures par exemple) ;
- en économie : pour la modélisation de comportements d'agents par exemple ;
- en traitement d'images, du signal, pour détecter des formes caractéristiques, problème que l'on peut soit comprendre comme une optimisation, soit comme une application de règles de décision (SC) ;
- en théorie des graphes et théorie des jeux : le problème du voyageur de commerce, notamment a beaucoup intéressé les chercheurs.

Bibliographie

- [1] Cerf (R.). – Asymptotic convergence of genetic algorithms. – Preprint, 1993.
- [2] Davis (L.). – *Genetic Algorithms and Simulated Annealing*. – Pittman, London, 1987.
- [3] Davis (T. E.) et Principe (J. C.). – A simulated annealing like convergence theory for the simple genetic algorithm. In : *Proceedings of the Fourth International Conference on Genetic Algorithm*, pp. 174–182. – 1991.
- [4] Goldberg (D. A.). – *Genetic Algorithms in Search, Optimization, and Machine Learning*. – Addison-Wesley, janvier 1989.
- [5] Hoffmeister (F.) et Baeck (T.). – Genetic algorithms and evolution strategies : Similarities and differences. In : *Parallel Problem Solving from Nature*, pp. 455–470. – 1990.
- [6] Holland (J. H.). – *Adaptation in Natural and Artificial System*. – University of Michigan Press, Ann Arbor, 1975.
- [7] Koza (J. R.). – *Genetic Programming*. – MIT Press, 1992.
- [8] Nix (A. E.) et Vose (M. D.). – Modeling genetic algorithms with Markov chains. *Annals of Mathematics and Artificial Intelligence*, vol. 5, 1992, pp. 79–88.