

Apport des algorithmes génétiques à la Sûreté de Fonctionnement et à l'optimisation des systèmes

Sébastien Allibe

Université
Joseph Fourier
UFRIMA
Grenoble
sallibe@club.internet.fr

André Cabarbaye

Centre National d'Etudes
Spatiales (CNES)
Laboratoire de Sûreté de
Fonctionnement
18 avenue Edouard Belin
31401 Toulouse Cedex 4
andre.cabarbaye@cnes.fr
Tél. 05 61 28 27 41
Fax. 05 61 28 22 31

Lamine Ngom

Institut National des
Sciences Appliquées
(INSA Toulouse)
Complexe Scientifique
de Rangueil
31077 Toulouse
Cedex 4
ngom@dge.insa-tlse.fr
Tél. 05 61 55 98 09
Fax. 05 61 55 98 00

Linda Tomasini

Centre National d'Etudes
Spatiales (CNES)
Laboratoire de Sûreté de
Fonctionnement
18 avenue Edouard Belin
31401 Toulouse Cedex 4
linda.tomasini@cnes.fr
Tél. (33) 5 61 27 31 73
Fax. 05 61 28 22 31

Résumé : Confronté à certaines difficultés pour dimensionner correctement des systèmes spatiaux de plus en plus complexes, le CNES mène une activité de Recherche et Développement sur l'application à la Sûreté de Fonctionnement et à l'ingénierie des systèmes de différentes techniques d'optimisation issues des domaines de la recherche opérationnelle et de l'intelligence artificielle.

Parmi les pistes explorées, les algorithmes génétiques présentent certains avantages dont notamment ceux de ne pas nécessiter la connaissance analytique de la fonction à optimiser et de ne pas s'arrêter au premier optimum local trouvé. Ils peuvent être couplés à des outils existants d'évaluation de Sûreté de Fonctionnement, considérés comme des boîtes noires, afin de mener l'optimisation suivant divers critères construits à partir du coût du système et de la disponibilité du service rendu à l'utilisateur.

Chaque configuration de paramètres est considérée comme un chromosome dont les gènes sont des paramètres de différents types (binaire, entier, réel). Ces chromosomes subissent, au sein d'une population, des opérations de sélection, croisement, mutation... tenant compte des performances respectives de chacun. Ces opérations sont menées suivant deux objectifs : atteindre les optima locaux et explorer judicieusement l'espace des variables pour rechercher l'ensemble des optima afin de trouver l'optimum global. Cette recherche peut être rendue plus efficace en couplant à ces opérations de base un opérateur de mise à l'échelle, créant un effet de zoom au fur et à mesure de la recherche, ainsi que des techniques d'optimisation plus classiques telles que les méthodes du gradient ou du simplexe.

Cette méthode d'optimisation a notamment été utilisée pour traiter deux types de problèmes :

- l'ajustement des paramètres d'un modèle markovien à une courbe de fiabilité,
- l'optimisation du déploiement d'une constellation de satellites.

Sa mise en oeuvre a nécessité le développement d'un outil générique d'optimisation par algorithmes génétiques pouvant s'adapter à différents outils de Sûreté de Fonctionnement (traitement markovien, simulation de Monte-carlo...) ou d'autres domaines.

Après une présentation approfondie des algorithmes génétiques mis en oeuvre dans cette étude et des premiers résultats obtenus, cette communication en souligne les avantages, difficultés et limites en indiquant les diverses pistes méthodologiques suivies actuellement par le CNES. Parmi celles-ci, les techniques de programmation dynamique et d'apprentissage par renforcement [5] paraissent bien adaptées à la problématique de la maintenance optimale.

Mots-clés : Optimisation - Intelligence artificielle - Algorithmes génétiques - Sûreté de Fonctionnement -

1. Introduction

Diverses évaluations de fiabilité/disponibilité sont menées pour dimensionner correctement l'architecture, la mise en œuvre et la maintenance des systèmes [1]. Ces évaluations sont réalisées au moyen de différentes méthodes et outils de modélisation (bloc diagramme de fiabilité, arbre d'événements, graphe de Markov, réseaux de Pétri) et de traitement (analytique, markovien, simulation de Monte-carlo) suivant la nature et la complexité des systèmes étudiés. Mais les besoins évoluent :

- . L'évaluation doit être menée au niveau du système complet, et non plus de ses seuls constituants, afin de maîtriser la disponibilité du service rendu à l'utilisateur final (abonné d'un service de communication par satellites, usager d'un moyen de transport, téléspectateur d'un événement sportif...).

- . L'évaluation n'est plus considérée comme une étape de vérification contractuelle, mais est utilisée à des fins d'optimisation pour diminuer le coût global d'acquisition des produits (développement, mise en place, opération, maintenance, renouvellement, retrait de service...). Ainsi, l'optimisation de la maintenance, qui a souvent été négligée dans le passé, intéresse de plus en plus les grands donneurs d'ordres (armement, espace, nucléaire...), depuis qu'ils ont pris conscience que le coût du maintien opérationnel d'un produit est généralement supérieur au coût de ce dernier. Suivant la nature des systèmes, l'objectif recherché peut être de minimiser le coût global d'acquisition plus celui induit par les indisponibilités de service, le coût à disponibilité donnée, l'indisponibilité à coût donné ou un ratio entre ces différents paramètres. Cette optimisation rencontre cependant deux écueils :

- . la complexité croissante des systèmes étudiés qui dépendent de nombreux paramètres et présentent généralement plusieurs optima locaux,

- . la durée d'évaluation de ces systèmes, notamment quand celle-ci est réalisée par simulation.

Les analyses de sensibilité menées individuellement sur chacun des paramètres montrent vite leurs limites, et il devient nécessaire de faire appel à des techniques d'optimisation plus sophistiquées issues des domaines de la recherche opérationnelle ou de l'intelligence artificielle.

Confronté à ces difficultés, le laboratoire de Sécurité de Fonctionnement du CNES mène une activité de Recherche et Développement pour traiter des systèmes de plus en plus complexes telles que les constellations de satellites. Parmi les pistes explorées, les algorithmes génétiques [2] présentent certains avantages. Ils ne nécessitent pas la connaissance analytique de la fonction à optimiser et peuvent être couplés à des outils d'évaluation considérés comme des boîtes noires. Ils font alors évoluer les différents paramètres du système en fonction du seul résultat de l'évaluation que l'on cherche à maximiser (ou minimiser).

Après une brève présentation des algorithmes génétiques et de quelques applications dans le domaine spatial, cette communication présente les avantages, difficultés et limites de ces approches quand elle est notamment appliquée à la problématique de la maintenance optimale. Elle propose également d'autres pistes méthodologiques faisant actuellement l'objet d'évaluations.

2. Les algorithmes génétiques

Développés par John Holland et ses collaborateurs à l'université du Michigan, les algorithmes génétiques sont des algorithmes d'optimisation fondés sur les mécanismes de la sélection naturelle et de la génétique. Le premier de ces mécanismes tient aux principes de la survie des espèces les mieux adaptées fondé sur le postulat de Darwin. Le second s'appuie sur la diversité des individus dans la population d'une même espèce, qui évolue au cours du temps par des croisements ou mutation. L'analogie entre la biologie et les algorithmes génétiques est présentée dans la figure 1.

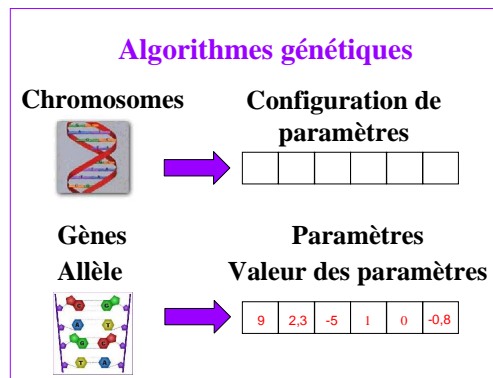


Figure 1 - Analogie entre la biologie et les algorithmes génétiques

Chaque configuration de paramètres correspond à un chromosome dont les gènes sont des paramètres de différents types (binaire, entier, réel, éventuellement borné). Ces chromosomes subissent au sein d'une population des opérations de mutation, croisement, sélection... tenant compte des performances respectives de chacun (figure 2).

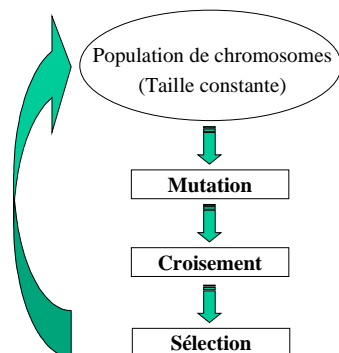


Figure 2 - Principe de base des algorithmes génétiques

A chaque génération, une nouvelle population de même taille est créée, constituée en partie des meilleurs éléments de la génération précédente et d'éléments nouveaux générés par mutation ou croisement. Ces opérations sont menées suivant deux objectifs : atteindre les optima locaux et explorer l'espace des variables pour rechercher l'ensemble des optima afin de trouver par là même l'optimum global.

La **mutation** consiste à introduire un bruit dans la valeur d'un gène d'un chromosome, c'est à dire un écart aléatoire autour de cette valeur. En ce sens la mutation est une opération **d'exploration** de l'espace de recherche. La figure 3 présente un exemple de mutation applicable à différents types de paramètres.




Figure 3 - Exemple de mutation

Dans cet exemple, la mutation d'un chromosome tiré aléatoirement dans la population s'effectue par modification de l'un de ses gènes choisi au hasard. Celui-ci change simplement d'état s'il est binaire ou réalise un saut d'amplitude décroissante au cours du temps s'il est réel ou entier, afin de limiter progressivement l'exploration au fur et à mesure de la recherche.

Le **croisement** est effectué en appariant deux chromosomes de la population qui s'échangent de l'information entre eux pour donner naissance à deux fils. De même que la mutation, le croisement est une opération **d'exploration** de l'espace de recherche dont deux exemples sont proposés à la figure 4.

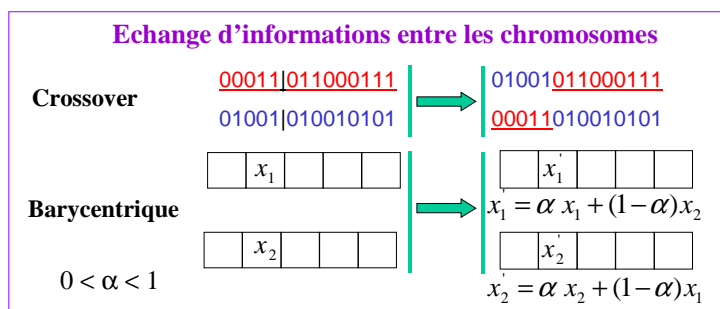


Figure 4 - Exemples de croisement

Dans ces exemples, le croisement de deux chromosomes parents tirés aléatoirement dans la population s'effectue soit par échange de gènes (crossover), chacun des gènes étant reproduit chez l'un ou l'autre des fils, soit en moyennant les valeurs (entiers ou réels) des gènes des parents (barycentrique).

La **sélection** est un procédé par lequel chaque chromosome est copié un certain nombre de fois dans la nouvelle population en fonction de la valeur (ou fitness) de la fonction à optimiser (appelée aussi fonction d'adaptation). Les chromosomes dont la valeur de la fonction d'adaptation est élevée ont une forte probabilité de contribuer à la génération suivante, en créant un ou plusieurs descendants identiques à eux-mêmes. Cet opérateur, dont un exemple est proposé à la figure 5, est bien entendu une version artificielle de la sélection biologique. Dans la nature, l'adaptation d'une espèce est déterminée par sa capacité à survivre aux prédateurs, aux maladies, et aux obstacles à franchir pour atteindre l'âge adulte et la période de reproduction, alors que dans notre environnement artificiel, la fonction à optimiser est l'arbitre final de la vie ou de la mort de chaque chromosome. En ce sens l'opération de sélection est une opération d'**exploitation** de l'espace de recherche.




Figure 5 - Exemple de sélection

Dans cet exemple, la probabilité de sélection p_i de chaque chromosome, calculée à partir du poids relatif du résultat de son évaluation, correspond à un secteur de roue de loterie avec lequel on effectue N tirages pour obtenir la nouvelle population (N étant la taille constante de la population).

Outre les exemples indiqués, les opérations de mutation, croisement et sélection peuvent être réalisées de multiples manières qui se révèlent plus ou moins efficaces suivant les problèmes à traiter. Par ailleurs, la recherche de l'optimum peut être améliorée en couplant à ces opérations de base des techniques de mise à l'échelle, d'élitisme, ou d'optimisation plus classiques. La mise à l'échelle est une transformation agissant sur la valeur de la fonction d'adaptation qui a pour but de créer un effet de zoom sur les résultats au fur et à mesure de la recherche. Au début de la recherche, on veut réduire les écarts entre les fitness afin d'éviter que les bons chromosomes deviennent trop prépondérants. Puis on amplifie les écarts pour accélérer la convergence (figure 6). L'élitisme consiste à conserver à chaque génération un certain nombre des meilleurs chromosomes de la population qui pourraient disparaître par les opérations de mutation, croisement ou sélection. Une méthode de grimpeur, telles que les méthodes du gradient ou du simplexe, peut être également associée à l'algorithme génétique pour constituer ensemble une méthode hybride ayant une meilleure capacité d'exploitation. Toutefois, la méthode du simplexe est généralement préférée à celle du gradient car elle n'impose pas de calcul de dérivée.




Figure 6 – Exemple de mise à l'échelle

2. Mise en œuvre

Divers besoins en Sécurité de Fonctionnement et ingénierie des systèmes nous ont conduits à développer un outil générique d'optimisation par algorithmes génétiques pouvant s'adapter à différents outils d'évaluation (traitement markovien, simulation de Monte-Carlo...). Développer sous Excel™, celui-ci intègre plusieurs opérateurs de mutation, croisement et sélection, que l'on peut choisir et paramétrer suivant les problèmes à traiter, ainsi que diverses techniques d'amélioration (mise à l'échelle, élitisme et simplexe). Son principe est décrit à la figure 5.

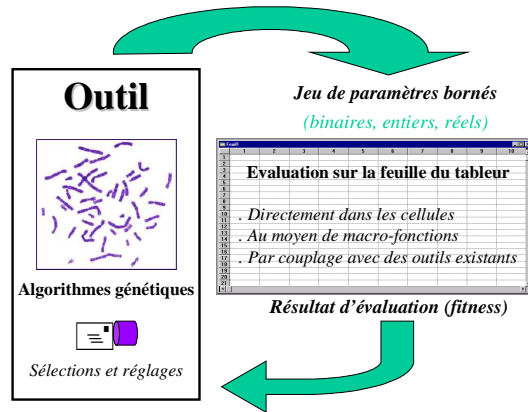


Figure 5 – Outil générique d'optimisation par algorithmes génétiques

En raison de son caractère générique, cet outil suppose que les paramètres à traiter sont indépendants entre eux, ce qui n'est malheureusement pas toujours le cas en optimisation combinatoire. Cependant de telles contraintes peuvent souvent disparaître par de judicieux changements de variables comme le montre l'exemple du voyageur de commerce indiqué en figure 6. Quand cela n'est pas possible, on peut transformer la fonction d'évaluation pour qu'elle produise un mauvais résultat dans le domaine de recherche où s'exercent les contraintes afin d'éliminer celui-ci par l'opérateur de sélection.

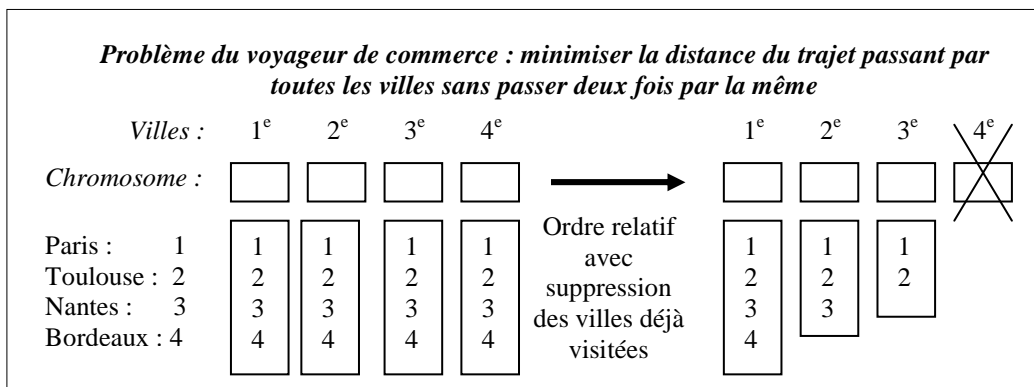


Figure 6 – Suppression de contraintes par changement de variables

Cet outil a été notamment utilisé pour traiter les deux applications présentées ci-après.

2.1 Ajustement des paramètres d'un modèle markovien à une loi de transition quelconque

La méthode des états fictifs consiste à remplacer dans un modèle markovien une transition quelconque entre deux états par un ensemble de transitions à taux constants entre des états fictifs (figure 6).




Figure 6 – méthode des états fictifs (modèle de Cox)

Cette méthode permet de modéliser des durées de transition pseudo-déterministes ou des taux complexes (courbe en baignoire considérant les pannes de jeunesse et les phénomènes d'usure), en se ramenant à un

système markovien homogène (à taux constants) que l'on sait traiter. Elle peut être également utilisée pour pallier l'explosion combinatoire des états d'un système en remplaçant des modèles de sous-ensembles par des modèles simplifiés équivalents limités à quelques états. Mais la principale difficulté de cette méthode réside dans l'ajustement des taux de transition du modèle qui est choisi en fonction de la complexité de la loi de transition (modèle de Cox de degré k ou d'Erlang généralisé si $\lambda_1 = \lambda n$).

Couplé à un logiciel de traitement markovien (SUPERCAB¹ dans nos applications), l'outil d'optimisation par algorithmes génétiques se révèle relativement efficace pour traiter ce type d'ajustement (modèle d'une dizaine de paramètres). L'optimisation est basée sur la méthode des moindres carrés, si l'ajustement est réalisé à partir d'une courbe de fiabilité, ou sur la méthode du maximum de vraisemblance si celui-ci est réalisé à partir d'un échantillon de durées de transition (statistique de durées de réparation par exemple). Les fonctions d'évaluation correspondantes présentent généralement plusieurs optima qui ne peuvent pas être tous atteints par une simple méthode de grimpeur.

2.2 Optimisation du déploiement d'une constellation de satellites

Les algorithmes génétiques ont été utilisés pour minimiser la durée de déploiement d'une constellation de 64 satellites (figure 8) en jouant sur les types de lanceurs, les date de tir, et la répartition des satellites sur les lanceurs. Les contraintes liées à la répartition des satellites ont pu être éliminées par changement de variables, comme dans l'exemple du voyageur de commerce, et l'optimisation a permis de trouver une séquence de tir meilleure que toutes celles qui avaient pu être imaginées (12 mois au lieu de 14).

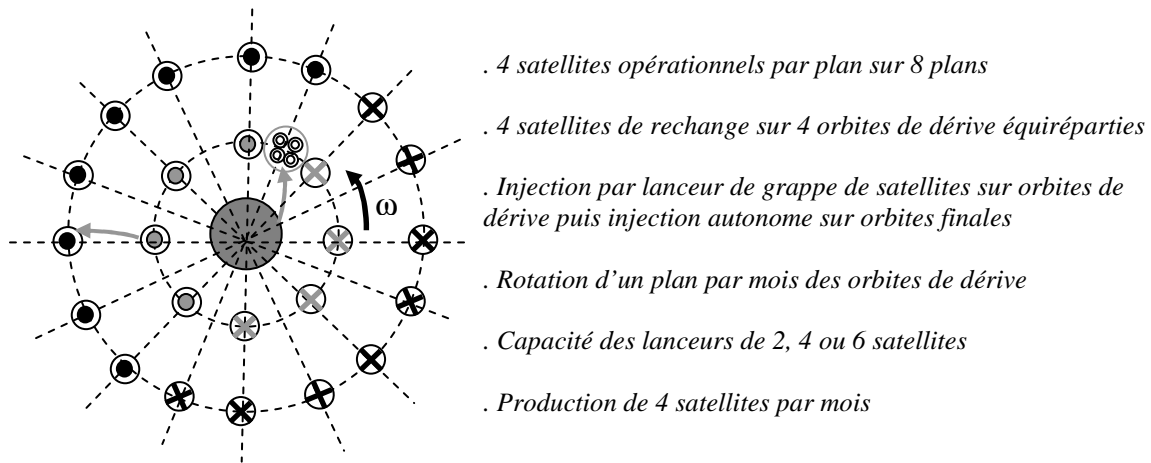


Figure 8 – Constellation de satellite vue de dessus (injection sur orbite de dérives)

2.2 Optimisation de l'entretien et du renouvellement d'une constellation de satellites

L'utilisation des algorithmes génétiques peut être également envisagée pour optimiser le coût de l'entretien et du renouvellement d'une constellation à partir d'un modèle stochastique considérant la fiabilité et le coût des satellites et des lanceurs, la durée de vie des satellites (liée à l'usure et aux ergols) et le coût de la dégradation du service induite par le nombre et la position de satellites indisponibles. Mais elle s'appuie alors sur une stratégie générale de renouvellement, définie a priori dans la modélisation, qui n'est pas forcément optimale. Celle-ci peut considérer par exemple que la décision de renouvellement d'un satellite sera prise en cas de défaillance de celui-ci ou peu avant la date prévue de sa fin de vie. Or il peut être intéressant de remplacer précocement un satellite ayant encore un certain potentiel après la défaillance d'un satellite opérant sur une orbite voisine, afin de bénéficier d'un lancement multiple diminuant sensiblement le coût unitaire d'un satellite à poste.

Ce problème peut être généralisé à celui de la maintenance optimale.

3. Généralisation à la problématique de la maintenance optimale

Les problèmes de maintenance optimale (figure 8) sont des problèmes de décisions séquentielles prises pour répondre à des aléas (actions de maintenance curative) ou pour limiter leur occurrence (maintenance préventive). Deux approches peuvent être envisagées pour résoudre ce type de problème. La première consiste à effectuer une modélisation du système intégrant une stratégie de maintenance définie a priori mais paramétrable. Suivant la complexité du système étudié, on peut utiliser un modèle Markovien, en

¹ Développé par l'un des auteurs de cet article, Supercab+ est diffusé par Microcab (Paris).

faisant éventuellement appel à la méthode des états fictifs pour traiter des transitions complexes ou pseudo-déterministes, ou une méthode de modélisation plus riche faisant appel à la simulation de Monte-carlo comme les réseaux de Petri stochastiques. Les différents paramètres de la stratégie sont alors obtenus par une méthode d'optimisation à partir des résultats du modèle considéré comme une boîte noire. Cette approche n'est évidemment pertinente que si l'on connaît a priori une stratégie de maintenance efficace. La seconde approche consiste à rechercher l'action optimale à prendre dans chacun des états du système. **L'apprentissage par renforcement** [5], ou *neuro-dynamic programming*, apparaît bien adaptée à cette approche. Cette méthode d'optimisation est basée sur une modélisation mathématique sous forme de Processus Décisionnels de Markov (PDM). L'apprentissage par renforcement consiste à rechercher l'action optimale à prendre dans chacun des états du système, en exploitant un modèle de simulation de ce système. Cet apprentissage diffère de la programmation dynamique stochastique par cette utilisation de la simulation, et par l'emploi de fonctions d'approximation qui permettent de traiter des problèmes de décisions séquentielles de taille relativement importante.

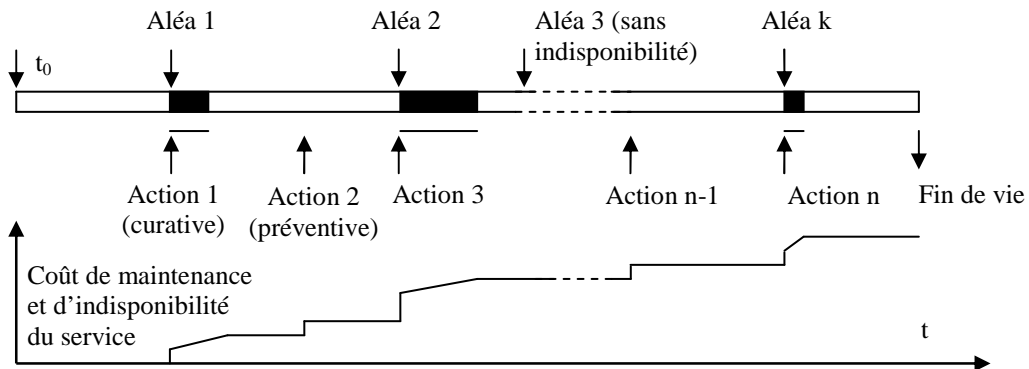


Figure 8 – problématique de la maintenance optimale

Conclusions

Bien que l'apport des algorithmes génétiques à la Sûreté de Fonctionnement et à l'ingénierie des systèmes soit jugé prometteur, leur mise en œuvre a permis de soulever certaines difficultés et limitations.

L'un des premiers obstacles réside dans l'interdépendance des paramètres qui peut être difficilement pris en compte au niveau des algorithmes génétiques quand ceux-ci se veulent génériques. Cette difficulté peut cependant être levée par un changement de variables lors de l'évaluation, ou par élimination du domaine de recherche où s'exercent les contraintes au moyen de l'opérateur de sélection.

La durée de l'évaluation est souvent rédhibitoire, notamment quand celle-ci est réalisée par simulation de Monte-Carlo, même si certains palliatifs peuvent être envisagés. L'optimisation peut s'effectuer en deux temps. Un optimum grossier est d'abord obtenu au moyen d'évaluations peu précises, puis un optimum plus fin est recherché autour du premier au moyen d'évaluations plus fines. Dans certains cas, il est également possible d'effectuer beaucoup plus rapidement l'évaluation grossière au moyen d'un réseau de neurones [3] dont l'apprentissage a été réalisé préalablement à partir d'un certain nombre de résultats d'évaluation.

L'application des algorithmes génétiques à la problématique de la maintenance optimale présente une limitation plus fondamentale. En effet, ceux-ci imposent le choix d'une stratégie de maintenance définie a priori dont on peut optimiser certains paramètres mais qui n'est pas forcément intrinsèquement optimale. Les techniques de programmation dynamique et d'apprentissage par renforcement [5] ne présentent pas cette limitation et peuvent s'avérer intéressantes pour traiter cette problématique. Des développements complémentaires sont actuellement menés au CNES pour tenter de défricher cette voie et pour analyser l'apport éventuel d'autres techniques telles que l'optimisation sous contraintes [4], l'optimisation globale ou des méthodes différentes d'optimisation locale (recuit simulé, méthode tabou...).

Références :

- [1] A. Cabarbaye, *Modélisation et évaluation des systèmes* - Cours de technologies spatiales, Edition Cepadues Toulouse 1998
- [2] David E. Goldberg, *Algorithmes Génétiques, Exploration optimisation et apprentissage automatique*, Addison-Wesley, 1994.
- [3] J-M. Renders, *Algorithmes génétiques et réseaux de neurone*, Hermes, 1995
- [4] T. Schiex, H. Fargier and G. Verfaillie, *Problèmes de satisfaction de contraintes valués*. Revue d'Intelligence Artificielle, 11(3):339-373, 1997.
- [5] R. S. Sutton , A. G. Barto, *Reinforcement Learning : An Introduction*, MIT Press, Cambridge, MA, 1998.