



HAL
open science

Optimisation par algorithme génétique de la maintenance préventive dans un contexte de modélisation par modèles graphiques probabilistes

Ines Ayadi, Laurent Bouillaut, Patrice Aknin, Patrick Siarry

► To cite this version:

Ines Ayadi, Laurent Bouillaut, Patrice Aknin, Patrick Siarry. Optimisation par algorithme génétique de la maintenance préventive dans un contexte de modélisation par modèles graphiques probabilistes. Lambda Mu 17, 17ème Congrès de Maîtrise des Risques et de Sûreté de Fonctionnement, Oct 2010, La Rochelle, France. 10p. hal-00615219

HAL Id: hal-00615219

<https://hal.science/hal-00615219>

Submitted on 18 Aug 2011

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Optimisation par algorithme génétique de la maintenance préventive dans un contexte de modélisation par modèles graphiques probabilistes

Ines Ayadi, Laurent Bouillaut, Patrice Akinin
INRETS-LTN
2 rue de la butte verte,
93166 Noisy-le-Grand Cedex, France
{ayadi, bouillaut, akinin }@inrets.fr

Patrick Siarry
Université Paris-Est
Créteil (LiSSi, E.A. 3956)
61 av. du Général de Gaulle,
94010 Créteil Cedex, France.
siarry@univ-paris12.fr

Résumé:

Les équipements employés dans les milieux industriels, tels que les chaînes de production, l'ingénierie ou le transport, se présentent généralement sous la forme de systèmes complexes multi-composants et multi-états. L'état de ces systèmes est souvent affecté par les conditions d'usage. La compréhension de l'évolution au cours du temps des états de fonctionnement de ce type de système, nécessite l'élaboration de modèles dynamiques adaptés, généralement stochastiques. En complément de ces modèles de dégradation, la politique de maintenance déployée agit directement sur la dynamique d'apparition des états dégradés, selon que l'on choisit d'agir préventivement ou curativement.

L'objectif de ce travail est, d'une part, de proposer, en se basant sur une approche de modélisation par réseaux bayésiens dynamiques, une fonction de coût permettant d'évaluer des politiques de maintenance. D'autre part, de mettre en œuvre un algorithme d'optimisation de type génétique en vue de retenir la politique de maintenance préventive optimale.

Dans cet article, on propose une fonction de coût associée à un cas d'étude (un système de distribution de fluides à 3 vannes) et un algorithme d'optimisation de type algorithme génétique. Le critère d'optimisation proposé utilise une modélisation stochastique de la dégradation du système basée sur une structure particulière des réseaux bayésiens dynamiques nommée Modèle Graphique de Durée (MGD). Ce critère de coût fait intervenir bien sûr les paramètres essentiels de la maintenance, tels que la probabilité d'effectuer une action de maintenance, son coût et sa durée, la disponibilité du système et les utilités associées aux états du système.

Mots-Clés : Maintenance ; Optimisation ; Modèles graphiques de durée ; Algorithme génétique.

Abstract:

Equipments used in industrial environments such as production lines, engineering or transport, are generally complex, multi-components and multi-states systems. These equipments are subject to degradation mechanisms caused by operating conditions such as temperature, vibrations... Accordingly, the understanding of the evolution of the operating states of this type of systems throughout time requires the development of suitable dynamic models, usually stochastic ones. In addition to these degradation models, the deployed maintenance policy directly affects the dynamics of the occurrence of failure states. To overcome these failures, it is possible to perform a corrective maintenance. But this would not prevent the system from suffering the consequences of the occurred failure. A more appropriate solution would be to apply a preventive maintenance in order to limit or even prevent system breakdowns (failures). But if the preventive maintenance is not properly regulated, we risk to face excessive costs and unnecessary system downtime. Given this situation, we should so consider establishing preventive maintenance strategies. These strategies must ensure an adequate compromise between availability of the system and its maintenance costs.

This work has mainly two goals. First, to propose a cost function that evaluates the maintenance policy : this function is based on a dynamic bayesian network modelling approach named Graphical Duration Models (GDMs). Secondly, to implement a

genetic algorithm in order to look for the optimal preventive maintenance policy.

Keywords : Maintenance ; Optimization ; Graphical Duration Model ; genetic algorithm.

Introduction

La gestion de la maintenance des équipements est devenue un enjeu de taille et représente aujourd'hui une préoccupation industrielle majeure. En effet, les systèmes industriels sont de plus en plus complexes, hautement automatisés et robotisés. Ces équipements sont soumis à des mécanismes de dégradation dus aux conditions de fonctionnement et/ou d'environnement : usure, fatigue, vieillissement et altérations physico-chimiques diverses. En conséquence, ces divers dysfonctionnements exigent une maintenance accrue, afin de garantir un niveau de service optimal en termes de fiabilité et de disponibilité. Pour remédier aux défaillances de ces systèmes, il est possible de se contenter de pratiquer une maintenance corrective, mais cela n'empêcherait pas de subir les conséquences des pannes. Une attitude plus "défensive" consiste à mettre en œuvre une maintenance préventive systématique destinée à limiter, voire à empêcher, ces défaillances. On court alors le risque de dépenses excessives et d'indisponibilités inutiles si les périodes d'intervention ne sont pas correctement calibrées. Devant cette situation, l'équipe de maintenance ne doit plus se contenter de surveiller et de réparer les pannes, mais elle doit aussi envisager des stratégies de maintenance préventives. Ces dernières doivent réaliser un compromis acceptable entre la disponibilité du système et les coûts associés à son entretien et à son fonctionnement. C'est dans ce contexte que se situe l'optimisation de la maintenance préventive.

La résolution de cette problématique se compose principalement de deux phases : la première concerne la modélisation de l'évolution du comportement du système, i.e. connaître ses mécanismes de dégradation. En disposant d'un tel modèle, une stratégie de maintenance peut être appliquée au système. La deuxième phase vise, quant à elle, à déterminer les paramètres optimaux de la stratégie de maintenance appliquée et ce afin d'optimiser une fonction de coût donnée du système.

Ces dernières années, l'intérêt des chercheurs travaillant dans le domaine de la maintenance a souvent été axé sur les politiques de l'entretien préventif des systèmes multi-composants. (Cho and Parlar, 1991) définissent un modèle de maintenance multi-unités comme suit : les modèles de maintenance multi-composants sont concernés par les politiques de maintenance optimales pour un système comprenant plusieurs unités de machines ou plusieurs pièces, pouvant éventuellement dépendre les uns des autres (économiquement / stochastiquement / structurellement). Citons également des travaux plus récents effectués par (Dekker et al., 1997), et (Nicolai and Dekker, 2008). Dans le cadre de l'optimisation de la maintenance préventive, nous citons les travaux de (Bris et al., 2003; Lapa et al., 2006; Yeh et al., 2009), qui se sont principalement intéressés à l'optimisation des intervalles de maintenance. Dans la définition des modèles de coût (critère à optimiser), ces derniers se sont essentiellement basés sur les mesures de fiabilité et du coût de la maintenance et ce en supposant que le système possède deux états. Dans le cas des systèmes multi-composants et multi-états, les approches de modélisation par modèles graphiques probabilistes, notamment les modèles graphiques de durée (MGDs), ont fait leur preuve pour représenter fidèlement la dynamique des systèmes complexes. Dans cet article, nous détaillerons d'abord l'approche de modélisation par "Modèle Graphique de Durée" (MGD). Ensuite, nous proposerons un modèle de coût pour l'évaluation des politiques de maintenance. Enfin, nous exposerons notre approche d'optimisation par algorithme génétique dans le but de trouver les paramètres optimaux de la stratégie de maintenance préventive.

Modélisation probabiliste du problème

Récemment, de nouveaux travaux ont révélé que les Modèles Graphiques Probabilistes, i.e. les réseaux bayésiens et réseaux bayésiens dynamiques, sont pertinents pour représenter des systèmes complexes et réaliser des études de fiabilité. Le but dans la plupart des applications est de modéliser la dynamique d'un système à états discrets et finis.

Cette problématique peut être résolue en partie par l'utilisation des réseaux bayésiens (Pearl, 1988). Citons par exemple les travaux de Langseth et al (Langseth and Portinale, 2007) et Boudali et al (Boudali and Dugan, 2005). L'inconvénient de cette approche vient de la contrainte imposée sur les temps de séjour dans les états du système nécessairement exponentiellement distribués. En effet, une modélisation par MGP suppose que le phénomène étudié est markovien. La modélisation des processus de dégradation est donc souvent biaisée par cette hypothèse restrictive. Dans une analyse de fiabilité, une telle erreur peut avoir de graves conséquences, surtout si l'on veut optimiser les paramètres des politiques de maintenance basées sur la fiabilité. Citons dans ce cadre les travaux de Bouillaut et al (2009) (Bouillaut et al., 2009), qui visent à quantifier l'erreur d'estimation de fiabilité due à une approximation exponentielle lorsque le système suit d'autres types de distributions de temps de séjour. Les auteurs montrent que ce problème peut être contourné par l'utilisation de Modèles Graphiques de Durée, qui permettent

de prendre en compte n'importe quelle loi.

Dans les paragraphes suivants, nous proposerons d'employer les Modèles Graphiques de Durée (Donat et al., 2009) pour modéliser la dynamique des systèmes étudiés. Les MGDs se basent sur les modèles à variables de durée introduits par (Murphy, 2002), afin de construire un modèle discret et fini, où chaque loi de probabilité conditionnelle (LPC) est définie sur un domaine discret et fini. Un tel modèle permet de représenter l'évolution du comportement d'un système dynamique au cours du temps. Dans la suite de cette section, nous décrirons la structure graphique du MGD puis ces lois de probabilités conditionnelles. A l'issue de cette modélisation, nous proposons une fonction de coût permettant une évaluation globale des politiques de maintenance.

1 Structure du modèle

Un Modèle Graphique de Durée est un modèle graphique probabiliste markovien discret et fini où chaque loi de probabilité conditionnelle est définie sur un domaine discret et fini, permettant ainsi de représenter l'évolution d'un système dynamique au cours du temps.

La structure graphique d'un MGD est donnée en figure 1. Ce modèle s'articule autour des variables aléatoires X_t, X_t^D et

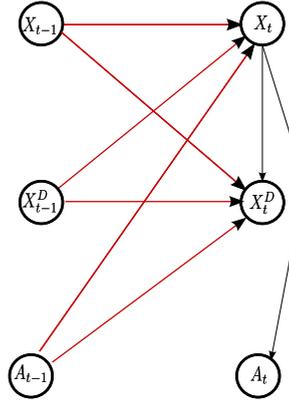


FIG. 1: Structure d'un modèle graphique probabiliste associé à un MGD. Les arcs en gras caractérisent les dépendances temporelles.

A_t à valeurs respectivement dans les ensembles \mathcal{X} , \mathcal{S} et \mathcal{A} . Les variables $(X_t)_{1 \leq t \leq T}$, $(X_t^D)_{1 \leq t \leq T}$ et $(A_t)_{1 \leq t \leq T}$ représentent respectivement l'état du système, le temps de séjour restant dans cet état et l'action sélectionnée sur une séquence de temps de longueur T .

L'examen du graphe associé au MGD montre qu'à une tranche t quelconque, l'état du système X_t dépend à la fois de l'état précédent X_{t-1} , du temps de séjour précédent X_{t-1}^D et de l'action sélectionnée au pas précédent A_{t-1} . Ces relations permettent de contrôler les transitions entre les états par l'intermédiaire des temps de séjour et de l'action sélectionnée. Le temps de séjour courant X_t^D dépend des variables X_{t-1} , X_{t-1}^D , A_{t-1} et de l'état courant X_t .

2 Description des lois de probabilités conditionnelles

Considérons $\mathcal{X} = 1, \dots, k, \dots, K$ l'ensemble des états X_t qu'un composant peut prendre. Nous notons $P(X_1 = k)$, pour tout $k \in \mathcal{X}$, la distribution initiale de l'état d'un composant (ou système). De par la nature discrète et finie du modèle, chaque loi de probabilité conditionnelle (LPC) associée à un nœud du graphe peut se mettre sous la forme d'une matrice stochastique. Alors la LPC caractérisant les transitions d'un état k' à un autre état k pour $t \leq 2$ est définie différemment, selon que la durée restante X_{t-1}^D dans l'état k' est égale ou supérieure strictement à 1, avant le changement de l'état :

$$P(X_t = k | X_{t-1} = k', \underline{X_{t-1}^D} = 1) = E_{k,k'} \quad (1)$$

où E est une matrice carrée de K lignes correspondant à la matrice de transition propre à l'état du composant.

En revanche, tant que la durée restante X_{t-1}^D avant le changement d'état est supérieure à 2, le système reste dans l'état courant. Il s'agit à présent de définir la LPC associée aux temps de séjour dans les différents états du système. On suppose que la v.a. X_t^D est à valeurs dans $\mathcal{S} = 1, \dots, d, \dots, D$. D correspond à la durée maximale autorisée dans chaque état du système.

Notons qu'il n'est pas naturel de définir une v.a. représentant une durée sur un ensemble borné. En effet, il aurait été plus convenable de définir X_t^D sur \mathbb{N} mais, dès lors, le modèle ne serait plus fini. En pratique, il suffit de choisir une borne D

suffisamment grande comparée à la dynamique du système étudié.

Pour tout $k \in \mathcal{X}$ et tout $d \in \mathcal{S}$, la distribution initiale des temps de séjour est $P(X_1^D = d | X_1 = k) = F_{k,d}^1$, où F^1 est une matrice de K lignes et D colonnes. $F_{k,d}^1$ donne la probabilité de rester d unités de temps dans l'état k .

La LPC de X_t^D pour $t \geq 2$ joue un rôle analogue, excepté qu'elle doit également maintenir à jour la durée restante avant la prochaine transition. Deux cas sont à étudier : le premier est le cas où le temps restant dans l'état précédent k' est écoulé. Une transition est alors déclenchée, ayant pour conséquence un changement d'état. La distribution du temps de séjour dans le nouvel état courant est alors donnée pour tout $k \in \mathcal{X}$ et tout $d, d' \in \mathcal{S}$ par :

$$P(X_t^D = d | X_{t-1}^D = d', X_t = k) = F_{d,d'}^{\rightarrow} \quad (2)$$

où F^{\rightarrow} est une matrice de $K \times D$ lignes et D colonnes. Tout comme F^1 , chaque ligne de la matrice F^{\rightarrow} est associée à une loi de temps de séjour dépendant de l'état courant, et également de l'état précédent.

Le deuxième cas correspond au cas où il reste du temps avant un changement d'état, i.e. $X_{t-1}^D \geq 2$, le système reste dans l'état précédent k' et la durée restante est décrétementée de façon déterministe d'une unité.

La LPC associée à la variable A_t permet de décrire la politique d'action agissant sur le système. L'ensemble des actions possibles est noté \mathcal{A} . Une action de maintenance agissant sur un composant déclenche une transition de l'état de ce composant. Pour tout $k \in \mathcal{X}$ et tout $a \in \mathcal{A}$, on a :

$$P(A_t = a | X_t = k) = G_t(k, a). \quad (3)$$

La valeur $G_t(k, a)$ donne la probabilité de sélectionner l'action a , sachant que le système se trouve dans l'état k . Cette LPC est sous la forme d'une matrice stochastique de K lignes et $\text{card}(\mathcal{A})$ colonnes.

Modèle de coût

La disponibilité et le coût constituent de bons éléments pour évaluer la performance d'un système. Leurs valeurs dépendent de la structure du système, ainsi que des états de fonctionnement (fiabilité) des composants. Lorsque le système franchit avec succès la phase de déverminage des défauts de jeunesse, sa fiabilité se stabilise, pour ensuite diminuer avec le vieillissement des composants du système.

Le coût de maintenance dépend généralement de plusieurs facteurs, comme le nombre d'interventions, la nature de l'opération de maintenance (réparation, réglage, graissage, remplacement), ainsi que le temps de maintenance durant lequel le système est indisponible.

1 Fonction de coût au niveau du composant

Une bonne planification de la maintenance doit prendre en compte le coût de l'entretien, ainsi que la disponibilité du composant dans le temps. Comme nous avons l'intention d'examiner l'influence de l'entretien d'un composant sur le fonctionnement entier du système, nous supposons que le composant est inactif au cours de sa période d'entretien. Soit, à l'instant t , l'utilité moyenne associée au fonctionnement d'un composant v :

$$C^v(t) = \sum_{a \in \mathcal{A}} (c^{\text{act}}(a) + c^{\text{pen}}(a)) g_t(a) + \sum_{k \in \mathcal{X}} (c^{\text{state}}(k)) P(X_t = k) \quad (4)$$

$c^{\text{state}}(k)$: utilité associée à l'état k du composant v .

$c^{\text{act}}(a)$: utilité (coût) associée à une action de maintenance a (réparation ou remplacement) appartenant à \mathcal{A} , qui désigne l'ensemble des actions de maintenance.

$c^{\text{pen}}(a)$: utilité associée à la pénalité due à la panne soudaine du système. Nous supposons que $c^{\text{pen}}(a)$ vaut toujours 0 pour une action de maintenance préventive. Par contre, pour une politique de maintenance préventive-curative ¹, cette utilité peut quantifier par exemple la perte en temps de préparation de l'équipe de maintenance (se procurer les pièces de rechange, appeler les techniciens de la logistique..) et ce avant la réparation effective du système.

Les modèles traditionnels supposent que le composant, après les tâches d'entretien préventif, est "comme neuf". Mais, dans certains cas, le système n'est pas réellement remis à neuf, après l'entretien préventif. Cette action préventive est appelée maintenance imparfaite ou peu satisfaisante. Il existe une littérature abondante sur les modèles de la maintenance préventive imparfaite (Osaki, 2002; Nakagawa, 2005). Dans ce travail nous modélisons les effets de la maintenance préventive imparfaite

¹ La maintenance préventive curative : c'est l'application d'une maintenance corrective curative en complément d'une maintenance systématique, pour traiter les défaillances résiduelles du système

par la réduction de l'âge effectif du composant maintenu, en utilisant un facteur d'ajustement.

Supposons que la maintenance préventive est effectuée tous les $k\tau$ temps, tels que $k = 0, 1, 2, 3, \dots$ et $\tau \geq 0$ désigne le pas de temps. Le remplacement total du composant est prévu après une durée de fonctionnement supérieure à $N * \tau$.

La probabilité que le composant soit en état de bon fonctionnement après une action de maintenance préventive est : $P(X_{k\tau}) = (1 - \alpha)P(X_1)$, où α est le facteur d'ajustement.

2 Évaluation des politiques de maintenance au niveau système

Le modèle présenté ci-dessus (4) décrit une estimation d'un modèle de coût pour un seul composant, soumis à une politique de maintenance donnée. Toutefois, le but de ce travail est d'estimer le coût total pour le fonctionnement global du système.

Dans un système Sys composé de \mathcal{V} composants, le coût total pour le fonctionnement de Sys à un instant t donné est la somme des coûts totaux pour chaque composant v et de la valeur de l'utilité moyenne de l'état global du système :

$$C(T) = \sum_{t=1}^N C^v(t) + \sum_{s \in \mathcal{S}} c^{SYS}(s)P(\text{sys}_t = s) \quad (5)$$

où \mathcal{S} et $c^{SYS}(s)$ désignent respectivement l'ensemble des états et l'utilité de l'état s du système Sys , pendant une unité de temps.

Optimisation de la maintenance préventive par algorithme génétique

Les algorithmes génétiques (AG) sont des techniques d'optimisation puissantes, inspirées des principes de l'évolution naturelle. Introduits par Holland en 1975 (Holland, 1992), leur principe général épouse celui des théories darwiniennes : l'algorithme se charge de maintenir un ensemble de solutions candidates du problème (*individus*), constituant une *population*. Celle-ci s'adapte au cours des générations, par le biais d'opérations successives de sélection, de croisement et de mutation. Chaque individu est évalué et l'ensemble tend à favoriser les individus les mieux évalués.

Les individus sont formés par des variables, qui sont les *paramètres* à ajuster dans le problème à traiter (par exemple, une longueur, une distance, un temps ...). La population est conçue aléatoirement à l'intérieur de l'espace de recherche, en respectant les limites prédéfinies (contraintes) par le problème à traiter. Ainsi un individu représente un point de l'espace de décision et devient donc une solution potentielle. Pour mesurer l'adaptabilité de chaque individu au problème, on lui associe une mesure de performance, qui correspond à la valeur du critère à optimiser.

En raison de leur robustesse et de leur personnalisation aisée, les AGs ont été appliqués à un large éventail de problèmes, dont plusieurs problèmes d'optimisation complexes, tels que la conception du cœur du réacteur dans l'ingénierie nucléaire (Pereira, 2003), les problèmes de transfert de chaleur (Gosselin et al., 2009) et notamment les problèmes liés à l'optimisation de la maintenance. Citons par exemple à ce sujet les travaux de Lapa et al (2000)(Lapa, 2000), Marseguerra et Zio (2000) (Marseguerra, 2000), Tsai et al (2001) ou plus récemment Sortrakul et al (2005), Lapa et al(2006) (Lapa et al., 2006).

Généralement la modélisation d'un problème d'optimisation par un algorithme génétique se doit de préciser les points suivants :

- (i) définir un individu dont la structure de données code la solution candidate ;
- (ii) fournir une fonction objectif qui évalue la solution candidate ;
- (iii) fixer les paramètres de réglage : taille de la population, taux de croisement et de mutation, critères d'arrêt.

Dans notre problème d'optimisation de la maintenance préventive, l'objectif est d'optimiser les intervalles d'interventions entre deux actions de maintenance planifiées pour chaque composant du système, et ce afin de minimiser le coût de fonctionnement et de maintenance du système. Selon que les intervalles entre deux actions de maintenance, pour un composant donné, sont réguliers ou flexibles, nous avons élaboré deux algorithmes génétiques (AGs). Ces derniers diffèrent essentiellement par leur approche de codage des solutions candidates.

1 Codage et initialisation de la population

Le premier algorithme élaboré est à codage réel, i.e. les individus sont sous la forme de vecteurs à variables réelles. La longueur de chaque vecteur est égale au nombre des composants du système. Dans ce sens, chaque variable du vecteur correspond à une fréquence de maintenance pour un composant donné du système.

Dans le deuxième algorithme, la solution candidate est binaire, i.e formée d'une suite de 0 et de 1. En génétique, nous appelons "génotype" la suite particulière de 0 et de 1 de l'individu. Le génotype dans cet AG doit encoder le calendrier des actions de maintenance planifiées pour l'ensemble des composants du système. Suivant le paradigme canonique de l'AG, nous fixons la longueur du génotype. Chaque gène (sous-chaîne du génotype) contient N bits, où $N * \tau$ correspond à la durée de fonctionnement

totale du système avant son remplacement. Le décodage du gène est tel qu'un bit égal à 1 signifie qu'une action de maintenance est prévue à cette date. La figure 2 montre le génotype et son décodage pour chaque composant, représenté par un vecteur dont

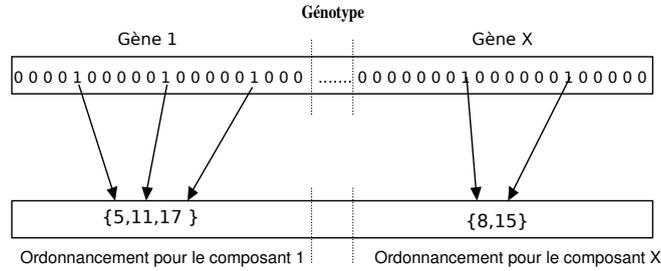


FIG. 2: Exemple de génotype

les éléments sont les dates d'intervention dans une échelle de temps de N pas de temps.

2 Mesure de la qualité d'un individu

L'évaluation de la qualité de chaque individu (solution potentielle) est réalisée à chaque fois par le calcul du coût total du fonctionnement du système avec les nouveaux paramètres de l'individu. Dans ce travail, l'utilité moyenne (*fitness*) de l'état du système exposé en section 2 représente à la fois le critère à optimiser et la fonction d'évaluation des individus.

3 Stratégie de sélection

Dans cette étape et à chaque itération de l'algorithme, des individus sont sélectionnés pour se reproduire, survivre ou disparaître. Généralement, la capacité d'un individu à être sélectionné dépend de sa performance. Cependant, nos premiers essais ont montré que l'emploi d'une stratégie de sélection élitiste², ou bien d'une sélection par roulette, où la probabilité qu'un individu soit sélectionné pour la reproduction est directement proportionnelle à sa qualité, débouchait sur une convergence prématurée de l'algorithme. Nous optons alors pour une méthode offrant une meilleure exploration de l'espace de recherche : une sélection par tournoi.

Cette stratégie permet de favoriser les individus les mieux adaptés, tout en laissant aux individus les plus faibles l'opportunité de participer au processus d'évolution.

Soit une population comportant λ individus. A la suite de l'étape de sélection, les individus sélectionnés ont une probabilité P_{cross} de se reproduire.

Une fois la phase de croisement terminée, l'opérateur de mutation est appliqué aux γ individus issus de la phase de croisement. A chaque itération, la population Pop_{t+1} est composée des $\lambda - \gamma$ meilleurs individus de Pop_t et des γ individus venant d'être générés. La stratégie élitiste, à ce niveau, garantit la convergence de l'algorithme. Il est cependant préférable de ne conserver qu'un nombre réduit d'individus d'une génération à l'autre, afin d'éviter une convergence trop rapide.

4 Croisement

Dans les AGs, le croisement est considéré comme le principal opérateur pour produire de nouveaux individus. Un opérateur de croisement peut utiliser deux individus (parents) pour former un ou deux nouveaux individus (descendants), en leur transférant certains paramètres des individus parents. Le croisement favorise la diversification de la texture de la population, afin de mieux explorer l'espace de recherche, tout en manipulant la structure des individus. De ce fait, les méthodes de croisement diffèrent selon le type de la structure de données des individus à combiner.

- Dans le premier algorithme, nous avons utilisé un croisement BLX- α volumique, qui est une méthode de croisement simple et efficace dans le cas de la représentation réelle de la population. Soient x et y deux individus choisis pour être mutuellement croisés et x_i et y_i leur composante respective, pour $1 \leq i \leq n$, où n est la dimension de l'espace des individus. Un descendant z aura pour composantes :

$$z_i = x_i - \alpha(y_i - x_i) + (1 + 2 * \alpha)(y_i - x_i)\mathcal{U}(0, 1) \quad (6)$$

où $\mathcal{U}(0, 1)$ désigne un nombre aléatoire tiré uniformément dans l'intervalle $[0,1]$.

- Pour l'algorithme à représentation binaire, compte tenu de la longueur du génotype, nous avons opté pour un croisement

² $N/2$ -élitisme : les individus sont triés selon leur mesure de qualité. Seule la moitié supérieure de la population, correspondant aux meilleurs composants, est sélectionnée.

multi-points.

5 Mutation

L'opérateur de mutation modifie aléatoirement un individu pour en former un autre qui le remplacera. La proportion des individus mutés dans la population est égale au taux de mutation. Un individu a une probabilité P_{mut} d'être muté.

- Une des techniques de mutation les plus utilisées en représentation réelle et appliquée dans notre travail est la mutation gaussienne. Elle consiste à ajouter à un individu x une variable gaussienne $\mathcal{N}(0, \eta)$ de moyenne nulle et d'écart-type η .
- Pour la mutation, dans le cas de l'algorithme à représentation binaire, nous procédons à l'inversion d'un seul bit du gène. Ce bit est choisi aléatoirement pour chaque gène du génotype, avec une probabilité égale à $P_{mut} * 2$.

Résultats expérimentaux

Visant à étudier la méthodologie proposée, ainsi qu'à analyser le comportement de la fonction objectif au cours de l'évolution du AG, un cas académique (système de distribution de fluide à trois composants) a été choisi comme objet de cette étude. Cette section est divisée en deux parties : description rapide du système, de sa fonctionnalité et de ses restrictions opérationnelles, puis résultats de la méthodologie.

1 Description du cas d'étude

Considérons un système de distribution de fluide ayant la même architecture que le système de la figure 3. Ce système est composé de trois vannes V_i .

Chaque vanne a quatre modes de fonctionnement : un mode de bon fonctionnement (Ok), deux modes de fonctionnement dégradé (Bloquée Ouverte-BO et Bloquée Fermée-BF) et un mode de réparation (Rep). Le problème est de prédire si l'on peut toujours contrôler le passage du fluide ou non dans le système. Des exemples de défaillance sont les suivants : V_1 et V_3 sont dans un état BF ou BO ou uniquement V_3 est BF. Au contraire si la vanne 3 est OK et si au moins une des deux vannes en parallèle est dans un état OK ou BO, le système reste contrôlable, donc en service. Le système doit fonctionner pendant une séquence de temps de longueur T . Au cours du temps, les vannes vieillissent et passent d'un état de bon fonctionnement à un

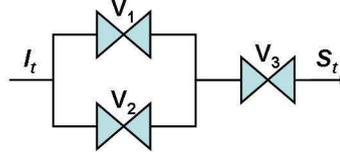


FIG. 3: Exemple de système multi-composants : système de distribution de fluide

état de défaillance. Le comportement défaillant va se répercuter alors sur la performance globale du système dans la mesure où, après une période de temps, il peut devenir impossible de contrôler la distribution du flux.

La période au bout de laquelle le système passe d'un état de marche (OK) à un état hors service (HS) (flux incontrôlable) est sensible aux durées de temps de séjour de chaque vanne dans un état donné. Comme nous le permettent les MGDs, nous utilisons une distribution non exponentielle, loi de Weibull, pour modéliser les temps de séjour. Cette loi repose principalement sur deux paramètres, l'un de forme β et l'autre d'échelle de temps η .

Le temps de séjour de l'état de bon fonctionnement (OK) des vannes suit une loi de Weibull de paramètres : $(\eta, \beta) = (10, 6)$ pour la vanne 1, $(5, 4)$ pour la vanne 2 et $(15, 4)$ pour la vanne 3. Lorsque le temps de séjour dans l'état (OK) est épuisé, le composant se retrouve dans un état dégradé, suivant les taux de défaillance décrits dans le tableau suivant :

	Vanne 1	Vanne 2	Vanne 3
λ_{BO}	0,2	0,6	0,5
λ_{BF}	0,8	0,4	0,5

TAB. 1: Taux de défaillance

Lorsqu'une vanne v est en mode de réparation, cela n'implique pas systématiquement que le système est (HS). Elle est considérée comme si elle était (BF).

2 Analyse des résultats

Pour pouvoir analyser et étudier le comportement de la fonction objectif au cours de l'évolution de l'AG, nous attribuons des utilités aux différentes actions de maintenance. Nous supposons que le coût de réparation est le même pour n'importe quelle vanne. Quant aux utilités U correspondant aux états globaux du système $\{OK, HS\}$, nous considérons deux cas :

1^{er} cas	OK	HS	$2^{ème}$ cas	OK	HS
U	1	-3	U	1	0

Pour des contraintes de temps de calcul de la fonction objectif, nous utilisons des populations d'individus relativement petites pour tester l'AG. Toutefois, nous avons pu valider ce dernier avec une dizaine de *benchmarks* connus. Les figures ci-dessous 4a et 4b illustrent la convergence de la meilleure *fitness* de l'algorithme au cours des générations de l'algorithme d'optimisation. Nous remarquons que la rapidité de la convergence dépend de la taille de la population.

Un autre paramètre qui affecte la vitesse de convergence de l'AG (à représentation binaire) est le nombre de coupures pour

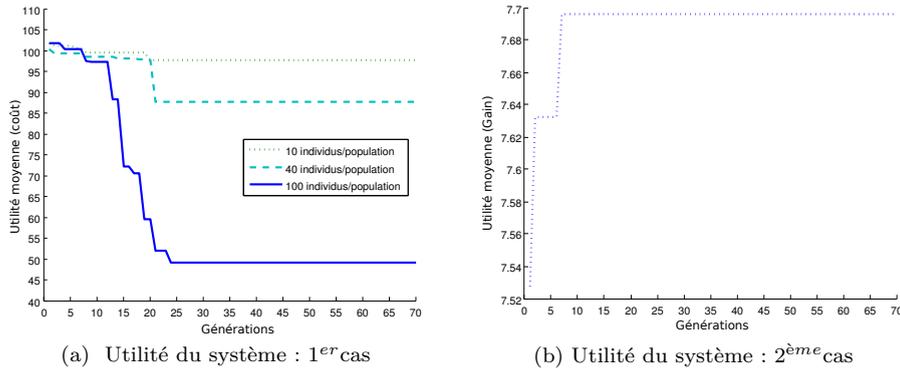


FIG. 4: Convergence de l'AG : optimisation des périodes de maintenance du système de distribution de fluide

chaque gène lors du croisement. Nous avons effectué des tests de l'AG à représentation binaire, utilisé pour l'optimisation des périodes de maintenance d'un seul composant, avec différentes valeurs de coupures. La figure 5, ci-dessous illustre l'allure de

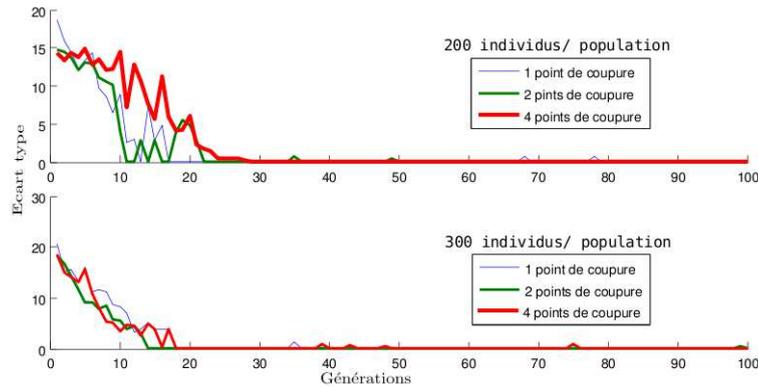


FIG. 5: Allure de l'écart type dans l'AG

l'écart type dans chaque population au cours des générations. Nous remarquons qu'un nombre de coupure supérieur à 2 garantit une convergence plus lente de l'algorithme de ce fait on évite la convergence prématurée. Les tableaux suivants récapitulent les résultats de quelques simulations des deux AGs.

Nombre d'individus	10	20	30	30	30	30	40	50
Nombres de générations	10	10	10	11	20	20	30	20
Coût total	55.64	44.04	48.74	50.33	45.70,9	97,46	87.61	62.04
Périodes d'intervention	[14,37,23]	[52,24,12]	[32,17,10]	[54,16,12]	[44,56,12]	[55,56,35]	[13,56,59]	[13,21,53]

TAB. 2: Résultats de l'AG appliqué au système de distribution de fluide

Nombre d'individus	50	100	500	1000
Nombres de générations	70	100	100	30
Coût total	32.52	31.94	20.93	11.38
Dates d'interventions	[10,19,38,45]	[11,23,32,39]	[9 21 29 35 52]	[10,20,32, 37, 42,53]

TAB. 3: Résultats de l'AG (binaire) appliqué à un seul composant(vanne 1)

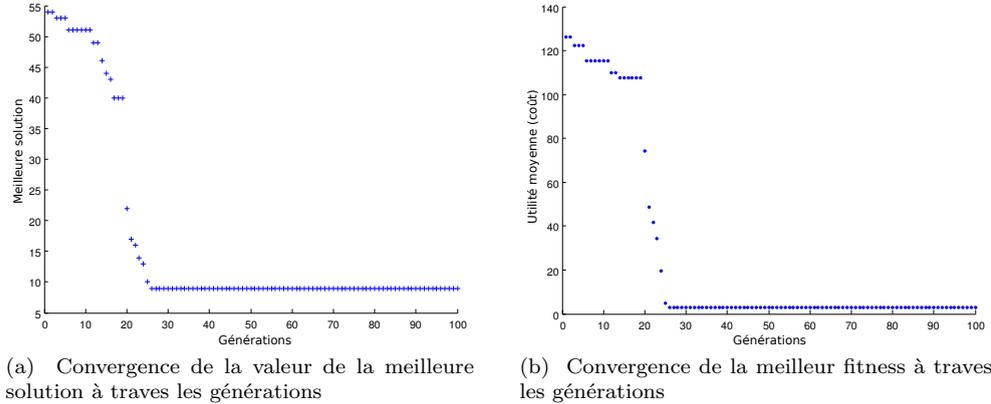


FIG. 6: Convergence de l'AG (à représentation réelle) : optimisation des périodes de maintenance d'un seul composant

Le premier tableau 2 donne des résultats de tests de l'AG (à représentation réelle) pour trouver les périodes d'intervention pour chaque vanne du système. Le meilleur résultat du tableau est celui qui affiche le moindre coût.

Le tableau 3 affiche les résultats de quelques lancements de l'AG (à représentation binaire) appliqué uniquement à la vanne V_1 . Sur cette même vanne V_1 , nous testons aussi l'AG (à représentation réelle). Nous constatons que l'AG converge vers la valeur 9 dans la figure 6a quand la *fitness* (figure 6b) décroît considérablement et tend vers 2. Ce résultat signifie que l'on doit maintenir la vanne V_1 tous les 9 pas de temps, afin de maximiser sa disponibilité et de réduire les coûts de sa maintenance.

Conclusion

Dans cette étude, nous avons présenté une démarche de résolution d'un problème d'optimisation de maintenance. Nous l'avons ensuite expérimenté sur un exemple académique de système mécanique. Cette démarche se compose essentiellement de deux phases : d'abord, une modélisation de la dégradation fondée sur le modèle graphique de durée, ayant l'avantage de s'adapter aux systèmes multi-états et ayant une dynamique d'évolution complexe dépendant d'un contexte particulier. Ensuite, l'intégration des approches de maintenance dans le modèle. Enfin, l'application d'une stratégie d'optimisation, qui sert à ajuster les paramètres de la maintenance préventive déployée pour l'entretien du système étudié, et ce dans le but de réduire les coûts dus aux opérations de maintenance et aux arrêts fortuits du système. Une prochaine étape serait d'aborder le problème d'optimisation d'un côté multi-objectifs. Cela revient à considérer la disponibilité du système comme un critère indépendant à optimiser, en plus de la fonction de coût.

Références

- Boudali, H. and Dugan, J. B. (2005). A discrete-time bayesian network reliability modeling and analysis framework. *Reliability Engineering & System Safety*, 87(3) :337–349.
- Bouillaut, L., Donat, R., Neji, A., and Aknin, P. (2009). Estimation of multi-component systems reliability : comparison of two graphical model approaches. In *proceedings of the 13th IFAC Symposium on Information Control Problems in Manufacturing*.
- Bris, R., Châtelet, E., and Yalaoui, F. (2003). New method to minimize the preventive maintenance cost of seriesparallel systems. *Reliability Engineering & System Safety*, 82(3) :247–255.
- Cho, D. and Parlar, M. (1991). A survey of maintenance models for multi-unit systems. *European Journal of Operational Research*, 51(1) :1–23.

- Dekker, R., Wildeman, R. E., and van der Duyn Schouten, F. A. (1997). A review of multi-component maintenance models with economic dependence. *Mathematical Methods of Operations Research*, 45(3) :411–435.
- Donat, R., Leray, P., Bouillaut, L., and Aknin, P. (2009). A dynamic bayesian network for representing discrete duration models. *Neurocomputing*.
- Goldberg, D. (1989). *Genetic algorithms in search, optimization and machine learning*. Addison-Wesley.
- Gosselin, L., Tye-Gingras, M., and Mathieu-Potvin, F. (2009). Review of utilization of genetic algorithms in heat transfer problems. *International Journal of Heat and Mass Transfer*, 52(9-10) :2169–2188.
- Holland, J. H. (1992). *Adaptation in natural and artificial systems*. MIT Press, Cambridge, MA, USA.
- Langseth, H. and Portinale, L. (2007). Bayesian networks in reliability. *Reliability Engineering & System Safety*, 92(1) :92–108.
- Lapa, C. (2000). Maximization of a nuclear system availability through maintenance scheduling optimization using a genetic algorithm. *Nuclear Engineering and Design*, 196(2) :219–231.
- Lapa, C., Perrira, C., and Debarros, M. (2006). A model for preventive maintenance planning by genetic algorithms based in cost and reliability. *Reliability Engineering & System Safety*, 91(2) :233–240.
- Marseguerra, M. (2000). Optimizing maintenance and repair policies via a combination of genetic algorithms and monte carlo simulation. *Reliability Engineering & System Safety*, 68(1) :69–83.
- Murphy, P. (2002). *Dynamic Bayesian Networks : Representation, Inference and Learning*. PhD thesis, University of California, Berkeley.
- Nakagawa, T. (2005). *Maintenance theory of reliability*. Springer-Verlag, London.
- Nicolai, R. P. and Dekker, R. (2008). Optimal maintenance of multi-component systems : A review. In *Complex System Maintenance Handbook*, pages 263–286.
- Osaki, S. (2002). *Stochastic models in reliability and maintenance*. Springer, Berlin.
- Pearl, J. (1988). *Probabilistic Reasoning in Intelligent Systems : Networks of Plausible Inference*.
- Pereira, C. (2003). Coarse-grained parallel genetic algorithm applied to a nuclear reactor core design optimization problem. *Annals of Nuclear Energy*, 30(5) :555–565.
- Yeh, R. H., Kao, K.-C., and Chang, W. L. (2009). Optimal preventive maintenance policy for leased equipment using failure rate reduction. *Computers & Industrial Engineering*, 57(1) :304–309.