



HAL
open science

Incertitude et flexibilité dans l'optimisation via simulation ; application aux systèmes de production

Ahlem Baccouche

► **To cite this version:**

Ahlem Baccouche. Incertitude et flexibilité dans l'optimisation via simulation ; application aux systèmes de production. Modélisation et simulation. Université Blaise Pascal - Clermont-Ferrand II, 2012. Français. NNT : 2012CLF22281 . tel-01135348

HAL Id: tel-01135348

<https://theses.hal.science/tel-01135348>

Submitted on 25 Mar 2015

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.

N° d'ordre : D.U : 2281

E D S P I C: 578

**Université BLAISE PASCAL-
CLERMONT FERRAND II**

ECOLE DOCTORALE
SCIENCES POUR L'INGENIEUR
DE CLERMONT FERRAND

Université de SFAX

ECOLE DOCTORALE
FACULTE DES SCIENCES
ECONOMIQUES ET DE GESTION
DE SFAX

THÈSE

Présentée par

Ahlem BACCOUCHE

Pour obtenir le grade de

DOCTEUR D'UNIVERSITÉ

SPÉCIALITÉ : INFORMATIQUE

**INCERTITUDE ET FLEXIBILITE DANS L'OPTIMISATION
VIA SIMULATION ;
APPLICATION AUX SYSTEMES DE PRODUCTION**

Soutenue publiquement le 16 Octobre 2012 devant le jury :

M. Pierre CASTAGNA	Professeur, IUT de Nantes, Président et Rapporteur
M. Faiez GARGOURI	Professeur, ISIM Sfax, Rapporteur
M. David Hill	Professeur, ISIMA Clermont Ferrand, Examineur, Invité
Mme Anne Lyse HUYET	Maitre de conférences, IFMA Clermont Ferrand, Examineur, Invitée
M. Mohamed JEMNI	Professeur ESSTT Tunis, Directeur de thèse
M. Henri PIERREVAL	Professeur IFMA Clermont Ferrand, Directeur de thèse

RESUME

La simulation est de plus en plus utilisée dans les études de conception et d'organisation des systèmes complexes. Une étude par optimisation via simulation permet d'optimiser les paramètres d'un système afin d'obtenir les meilleures performances, estimés par la simulation. Toutefois, dans de nombreux systèmes complexes, certaines données sont incertaines (par exemple, les conditions opératoires du système ou le comportement des décideurs). En conséquence, même lorsque l'étude d'optimisation via simulation est réalisée avec le plus grand soin, les solutions obtenues peuvent se révéler inadaptées. Dans ce contexte, notre objectif est d'étudier comment optimiser, via simulation, un système afin qu'il continue d'être performant et robuste.

L'étude bibliographique approfondie que nous avons menée montre que très peu de travaux en optimisation via simulation intègrent l'incertain et qu'ils peuvent être très limités dans leur capacité à fournir des solutions robustes en un temps de calcul raisonnable en particulier lorsque des métaheuristiques sont employées. Par ailleurs, la plupart des travaux existants délivrent une solution unique de conception performante du système et ne sont pas adaptés pour prendre en compte les aspects collaboratifs (groupe de décideurs). C'est pourquoi, nous avons proposé une approche originale connectant une recherche des solutions par optimisation évolutionniste multimodale et une évaluation des performances du système via simulation. Notre approche va permettre de fournir plusieurs alternatives performantes de conception d'un système et assez diversifiées pour acquérir aux décideurs une flexibilité dans le choix de la solution à implanter. De plus, nous avons exploité cette flexibilité pour intégrer, d'une part, les préférences individuelles des membres d'une équipe décisionnelle et, d'autre part, la présence de plusieurs environnements pour étudier la robustesse des solutions en un temps de traitement raisonnable par rapport à d'autres approches utilisant des méta heuristiques.

Les approches proposées sont illustrées par l'optimisation d'une maille de supply chain. Grâce à cette application, nous avons montré qu'en plus de fournir un choix de solutions performantes pour dimensionner le système, nous pouvons proposer des solutions « collectivement acceptable » pour l'équipe décisionnelle et déterminer des solutions de conception robustes du système.

Ces approches fournissent ainsi une flexibilité pour la phase de décision et contribuent à la prise en compte de l'incertitude dans l'optimisation via simulation d'un système.

Mots clés : Simulation en production et logistique, Optimisation via simulation, Optimisation multimodale, Flexibilité décisionnelle, Décision collaborative, Incertitude, Robustesse, Taguchi, Chaîne logistique.

ABSTRACT

Simulation is more and more used in studies of design and organization of complex systems. A simulation optimization study search for the system parameters that yield the best performance. However, in many complex systems, data can be uncertain (e.g., the operating conditions of the system or the behavior of decision makers). Therefore, even when the simulation optimization study is performed with the greatest care, the solutions may be inadequate. In this context, our goal is to study how to optimize, via simulation, a robust system.

The extensive literature review we conducted shows that few simulation optimization approaches incorporate uncertainty and they can be very limited in their ability to provide robust solutions in a reasonable processing time, especially when metaheuristics are used. In addition, most existing approaches provide a single solution to the design problem and are not adapted to take into account the collaborative aspects (decision maker's team). Therefore, we propose a novel approach connecting a search for solutions by evolutionary multimodal optimization and the evaluation of the system performance by simulation. Our approach allows to obtain a diverse set of designs that can be considered as efficient in terms of their performance and to provide decision-makers with flexibility in the choice of the solution to implement. In addition, we use this flexibility to integrate first, the individual preferences of the members of decision maker's team and secondly, the presence of multiple environments for studying the robustness of solutions in a reasonable processing time compared to other approaches based on metaheuristics.

The proposed approaches are illustrated with an example of supply chain. With this application, we have shown that in addition to providing a choice of efficient solutions for sizing the system, we propose "collectively acceptable" solutions to the decision-making team and we identify robust solutions.

Then, these approaches provide flexibility to the decision phase and contribute to the consideration of uncertainty in the simulation optimization of the system.

Keywords: Simulation in production and logistics, Simulation optimization, Multimodal optimization, Decisional flexibility, Collaborative decision, Uncertainty, Robustness, Taguchi, Logistic Chain.

Remerciements

Je souhaite remercier tout d'abord mon directeur de thèse M. Henri PIERREVAL, professeur à l'Institut Français de Mécanique Avancée de Clermont Ferrand pour m'avoir accueillie dans le laboratoire LIMOS et encadrée tout au long de cette période de thèse. Ainsi que mon Directeur M. Mohamed JEMNI, Professeur à l'Ecole Supérieure des Sciences et Techniques de Tunis, pour m'avoir accompagnée et soutenue.

Je remercie plus particulièrement le professeur Pierre CASTAGNA à l'IUT de Nantes de m'avoir fait l'honneur de présider le jury. J'adresse également mes remerciements au professeur Faiez GARGOURI, directeur à l'ISIM Sfax en Tunisie, pour avoir accepté de juger nos travaux en qualité de rapporteur ; et aux autres membres du jury : Professeur David HILL à ISIMA Clermont Ferrand et Mme Anne-Lyse HUYET maître de Conférences à L'IFMA Clermont Ferrand.

Je remercie aussi l'ensemble des personnes aux laboratoires LIMOS en France et LaTice en Tunisie. Je ne peux pas citer tous les doctorants et enseignants chercheurs des deux laboratoires mais ils ont tous participé à la réussite finale de cette thèse. Il ne m'est pas possible d'oublier les soutiens de Mme Besma Feyeche et Mme Anne-Lyse Huyet pour m'avoir occasionnellement aidée dans mon travail durant cette période et pour leurs sympathies.

Je ne saurai jamais assez remercier mes parents qui, loin de moi, participent à la réalisation de mes projets. Je n'oublie évidemment pas ma sœur, Héra et mon frère Amine.

Une pensée particulière va enfin et bien sûr à Sami, pour son amour et sa patience, qui m'a supportée avant d'être docteur et me supportera encore, enfin je l'espère.

Merci encore à tous

TABLE DES MATIÈRES

INTRODUCTION GENERALE.....	1
-----------------------------------	----------

Chapitre I : OPTIMISATION VIA SIMULATION EN CONTEXTE INCERTAIN	5
---	----------

1. Introduction	7
2. La simulation comme outil d'évaluation.....	7
2.1 Principe de la simulation	7
2.2 Classification des types de simulations	10
3. L'optimisation via simulation	11
3.1 Principe.....	11
3.2 Notations et définitions.....	12
3.2.1 Variables de décision.....	12
3.2.2 Mesure de performance	13
3.2.3 Formalisation de l'optimisation via simulation.....	13
2.3 Méthodes de recherche existantes	13
4. Prise en compte de l'incertitude dans les études d'optimisation via simulation	18
4.1 Généralités sur l'incertitude	18
4.2 Modélisation de l'incertitude.....	21
4.2.1 La modélisation stochastique	22
4.2.2 La simulation floue.....	23
4.2.3 La modélisation par des scénarios ou par des environnements	23
4.3 Bilan	25
5. Revue des approches d'optimisation via simulation robustes	26
5.1 Les approches basées sur la méthodologie de Taguchi	26
5.2 Les approches impliquant les décideurs	27
5.3 Les approches basées sur l'analyse du risque.....	28
6. Conclusion.....	29

Chapitre II : INTRODUCTION DE LA FLEXIBILITÉ DÉCISIONNELLE : UNE APPROCHE PAR OPTIMISATION MULTIMODALE VIA SIMULATION	31
--	-----------

1. Introduction	33
2. Définition de flexibilité dans le choix	33

3.	Approche proposée.....	35
3.1	Principes de l'optimisation multimodale.....	35
3.2	Les techniques de l'optimisation multimodale.....	38
3.2.1	Les méthodes de niche	38
3.2.2	Les techniques basées sur l'intelligence des essais particuliers	38
3.2.3	Les systèmes immunitaires artificiels.....	39
4.	Description de l'approche implémentée.....	39
4.1	Algorithme et implémentation.....	42
4.2	Vérification et test de l'algorithme d'optimisation.....	46
4.3	Connexion avec la simulation	49
5.	Conclusion.....	49

Chapitre III : DÉTERMINATION DE SOLUTIONS DANS UNE PRISE DE DÉCISION COLLABORATIVE51

1.	Introduction	53
2.	Principe général.....	54
3.	Approche proposée.....	56
3.1	Première phase	57
3.2	Deuxième phase.....	57
3.3	Troisième phase.....	57
4.	Principes de AHP	58
5.	Algorithme utilisé.....	61
6.	Conclusion.....	62

Chapitre IV: PROPOSITION D'UNE APPROCHE METHODOLOGIQUE POUR LA PRISE EN COMPTE DE L'INCERTAIN EN OPTIMISATION VIA SIMULATION.....65

1.	Introduction	66
2.	Principes Généraux.....	66
3.	Approche proposée.....	71
3.1	Première phase : Optimisation via simulation sur l'environnement attendu.....	71
3.2	Deuxième phase : Simulation en considérant d'autres environnements.....	72
3.3	Troisième phase : Comparaison des solutions prometteuses.....	74
4.	Conclusion.....	76

Chapitre V : APPLICATIONS A UN PROBLEME DE CHAINE LOGISTIQUE.....77

1.	Introduction	79
----	--------------------	----

2.	Description	79
3.	Problème d'optimisation via simulation posé	81
4.	Optimisation multimodale via simulation	82
4.1	Implémentation et connexion	82
4.2	Recherche de solutions efficaces	83
5.	Choix d'une solution dans une prise de décision collaborative.....	85
5.1	Problème de décision posé	85
5.2	Expression des préférences des décideurs par rapport aux solutions retenues	86
5.3	Agrégation des préférences des décideurs.....	90
5.4	Calcul du score de préférence et classement collectif des solutions	91
5.5	Analyse des résultats	92
6.	Détermination des solutions robustes via l'approche de prise en compte de l'incertain.....	92
6.1	Problème d'incertitude posé	92
6.2	Recherche des solutions prometteuses sur l'environnement attendu	95
6.3	Simulation des solutions prometteuses en considérant d'autres environnements	96
6.4	Comparaison des performances des solutions et tests statistiques	98
6.5	Mesure de robustesse.....	100
6.6	Analyse des résultats	101
CONCLUSION GENERALE ET PERSPECTIVES.....		103
BIBLIOGRAPHIE.....		108

TABLE DES ILLUSTRATIONS

Fig.1. 1. Évaluation des performances : Méthodes	8
Fig.1. 2: Optimisation via simulation : les méthodes basées sur les modèles mathématiques. 15	
Fig.1. 3: Convergence prématurée à un optimum local dans une maximisation	16
Fig.1. 4: Optimisation via simulation : couplage entre l'optimisation et la simulation	16
Fig.1. 5: Plan d'expérience factoriel : deux facteurs et deux niveaux.	25
Fig.2. 1. Schéma de l'approche proposée.....	36
Fig.2. 2. Points singuliers d'une fonction unidimensionnelle multimodale.....	37
Fig.2. 3: Principe de l'optimisation multimodale via simulation.....	41
Fig.2. 4: Schéma général de l'approche « Crowding Clustering Genetic Algorithm »	42
Fig.2. 5: Les optima détectés par $f1(x, y)$	47
Fig.2. 6: Les optima détectés par $f2(x, y)$	48
Fig.3. 1 : Schéma général de l'approche proposée.....	56
Fig.3. 2: Evaluation des solutions par paire par le décideur	59
Fig.3. 3. Matrice carrée de comparaison par paire : $A_{p \times p}$	59
Fig 4. 1: Principe de solution prometteuse.....	69
Fig 4. 2: Méthodologie pour la prise en compte de l'incertitude.	71
Fig 5. 1: Maille de Supply Chain	79

LISTE DES TABLES

Tab 2. 1: Analogie entre les espaces mathématiques et la nature	39
Tab 3. 1 Echelle d'évaluations d'après (Saaty, 2009).....	60
Tab 4. 1 Performances moyennes des solutions prometteuses sur d'autres environnements ..	73
Tab 4. 2 Les solutions possédant des différences de performances significatives avec X^* .	75
Tab 5. 1: Les temps des opérations dans la chaîne de production par type de produit	80
Tab 5. 2: Les caractéristiques des solutions de dimensionnement du système	84
Tab 5. 3: Les solutions retenues dans le processus de décision collaboratif.....	85
Tab 5. 4: Evaluation des solutions par paire par le décideur 1.....	87
Tab 5. 5: Evaluation des solutions par paire le décideur 2.....	88
Tab 5. 6: Evaluation des solutions par paire par le décideur 3.....	89
Tab 5. 7: Les scores de préférences collectifs des solutions retenues.....	92
Tab 5. 8: Caractéristiques de l'environnement attendu.....	94
Tab 5. 9: Les niveaux des facteurs d'environnement.....	94
Tab 5. 10: Les caractéristiques des autres environnements pris en compte.....	95
Tab 5. 11: Caractéristiques des solutions prometteuses sur l'environnement attendu.....	96
Tab 5. 12: Performances moyennes des solutions prometteuses sur d'autres environnements	97
Tab 5. 13 Les solutions possédant des différences de performances significatives avec X^* ...	99
Tab 5. 14: Solutions Pareto Optimales.....	101

INTRODUCTION GENERALE

L'environnement très concurrentiel et en perpétuel changement oblige les entreprises à rester compétitives. La compétitivité et la productivité d'une entreprise passe par la maîtrise des systèmes qui régissent son fonctionnement et son développement. Pour la conception et l'organisation de leurs systèmes, par exemple, elles font face à des évolutions technologiques continues et un contexte économique et social incertain qu'il faut savoir intégrer et adapter.

La définition de solutions d'un problème de conception ou d'organisation d'un système de l'industrie manufacturière, de service de la santé ou encore de logistique des transports, passe par une connaissance approfondie des caractéristiques de ce système et de son comportement dynamique. Il s'agit donc de savoir quelles sont les meilleures valeurs des paramètres qui le composent afin d'obtenir un système performant. La performance d'un système de production, par exemple, sera évaluée en fonction de différents critères tels que le makespan, les encours, les délais de satisfaction des commandes,... Cette performance est dépendante d'un ensemble de paramètres qui peuvent être des nombres de machines ou de moyens de transport, des types de ressources, des politiques de gestion, l'existence et la taille de stocks intermédiaires... De tels systèmes étant complexes, il est souvent difficile d'utiliser des approches analytiques pour les modéliser sans formuler d'hypothèses restrictives.

La simulation tient une place prépondérante pour évaluer les performances de systèmes complexes et étudier leur comportement dynamique. Toutefois, la simulation utilisée seule ne permet pas de rechercher la meilleure performance à un problème d'optimisation. Le processus de recherche de la solution présentant la meilleure performance est souvent abordé à l'aide de méthodes d'optimisation, relevant de la recherche opérationnelle. De telles approches, communément désignées par « optimisation via simulation », se révèlent extrêmement utiles pour optimiser les performances de nombreux types de systèmes (Swisher et al, 2004 ; Tekin & Sabuncuoglu, 2004 ; Fu et al, 2005 ; Andradottir, 2007 ; Deng, 2007 ; Li et al 2010). Néanmoins, elles restent limitées. En effet, certaines données sur les systèmes sont incertaines ou souffrent d'un manque de précision par exemple, pour un système de production, le taux de pannes peut ne pas correspondre à ce qui a été anticipé, la fréquence de livraison s'avère inapplicable par rapport à la disponibilité des transporteurs, ... De plus, la plupart des modèles de simulation ne considère le système que dans un contexte donné (e.g., des conditions opératoires fixées) alors qu'il peut se produire une fluctuation de la demande en phase d'exploitation, un changement du marché pendant l'industrialisation, ... A cela s'ajoutent d'autres considérations non quantifiables, comme les difficultés techniques ou les

problèmes reliés au déploiement de la solution, mais aussi ne pouvant être identifiables ou connues à l'avance telles que les préférences individuelles des décideurs du système dans un contexte collaboratif. Par exemple le dimensionnement des ressources de production peut être accepté par un décideur et non par un autre. Pour ce dernier, il serait préférable d'opter pour une solution moins coûteuse à mettre en œuvre ou plus facile à implémenter.

En conséquence, les meilleures performances obtenues par un système peuvent être détériorées si ses conditions opératoires subissent des changements et les conclusions de l'étude par optimisation via simulation pourront devenir obsolètes si la solution s'avère inadaptée. Or, dans le contexte industriel actuel, les entreprises sont spécialement intéressées par des systèmes qui restent performants malgré l'impact de l'incertitude.

Pour aborder ces problèmes et fournir des réponses adaptées, notre recherche s'est attachée à répondre aux interrogations suivantes :

- Comment procurer de la flexibilité aux décideurs dans le choix d'une solution à un problème d'optimisation via simulation d'un système ?
- Comment intégrer les préférences individuelles des membres d'une équipe décisionnelle et déterminer des solutions d'une façon collaborative ?
- Parmi plusieurs solutions quelles sont celles qui restent performantes malgré l'impact de l'incertitude ?

Pour cela, nous verrons dans cette thèse qu'il est souhaitable de disposer :

- De méthodes permettant de déterminer plusieurs solutions de conception performantes et assez diversifiées, à la place d'une seule, pour garantir une meilleure flexibilité dans le choix.
- De méthodes permettant d'intégrer les aspects collaboratifs et incertains dans une étude par optimisation via simulation d'un système.

Par conséquent, dans ce travail de recherche, nous nous proposons d'apporter des éléments méthodologiques qui nous permettent d'introduire de la flexibilité et de l'incertitude dans une étude d'optimisation via simulation.

Le manuscrit est organisé de la façon suivante. Le premier chapitre situe le contexte de cette recherche à savoir la simulation et les méthodes d'optimisation qui lui sont associées. Puis, nous présentons et discutons les approches existantes abordant la prise en compte de l'incertain dans une étude d'optimisation via simulation. Ces méthodes n'étant pas entièrement satisfaisantes pour notre problématique et ne permettant pas de répondre à tous les besoins identifiés, nous proposons, dans le deuxième chapitre, une nouvelle approche basée sur l'optimisation multimodale permettant d'offrir de la flexibilité dans la décision en fournissant un choix de solutions performantes pour un problème de conception d'un système.

Dans le troisième chapitre, nous proposons d'exploiter ce choix de solutions pour intégrer les préférences individuelles des membres d'une équipe de décideurs et ainsi prendre en compte des aspects collaboratifs.

Dans le quatrième chapitre, nous suggérons d'utiliser la flexibilité décisionnelle et proposer une approche originale permettant d'intégrer l'incertain.

Le cinquième chapitre présente une application de gestion d'une maille de supply chain pour laquelle un choix de solutions de conception performantes a pu être déterminé puis exploité pour prendre en compte les aspects collaboratifs et incertains.

La conclusion dresse le bilan de la contribution de cette thèse. De plus, nous dégagons, dans ce dernier chapitre, plusieurs perspectives de recherche.

Chapitre I

**OPTIMISATION VIA SIMULATION EN CONTEXTE
INCERTAIN**

Chapitre I . OPTIMISATION VIA SIMULATION EN CONTEXTE INCERTAIN

1.	Introduction	7
2.	La simulation comme outil d'évaluation.....	7
2.1	Principe de la simulation.....	7
2.2	Classification des types de simulations.....	10
3.	L'optimisation via simulation	11
3.1	Principe	11
3.2	Notations et définitions	12
3.2.1	Variables de décision	12
3.2.2	Mesure de performance	13
3.2.3	Formalisation de l'optimisation via simulation.....	13
2.3	Méthodes de recherche existantes.....	13
4.	Prise en compte de l'incertitude dans les études d'optimisation via simulation.....	18
4.1	Généralités sur l'incertitude	18
4.2	Modélisation de l'incertitude	21
4.2.1	La modélisation stochastique	22
4.2.2	La simulation floue.....	23
4.2.3	La modélisation par des scénarios ou par des environnements.....	23
4.3	Bilan.....	25
5.	Revue des approches d'optimisation via simulation robustes.....	26
5.1	Les approches basées sur la méthodologie de Taguchi.....	26
5.2	Les approches impliquant les décideurs.....	27
5.3	Les approches basées sur l'analyse du risque	28
6.	Conclusion.....	29

1. Introduction

La simulation est nécessaire pour l'étude des comportements dynamiques des systèmes complexes. Cette technique tient une place prépondérante du fait qu'elle permet d'évaluer les performances d'un système relatives à des données qui lui sont proposées en entrée, de tester plusieurs scénarios d'organisation de ce système et d'en tirer les conséquences. Néanmoins, plusieurs problèmes limitent son usage, notamment parce qu'elle ne permet pas de déterminer les composantes critiques du système, ni même de proposer de bonnes solutions à un problème d'optimisation. Par exemple, dans un contexte de dimensionnement d'un système de production, elle ne permet pas de déterminer les nombres optimaux de palettes, de machines et d'opérateurs, de places dans les stocks tampon, ..., etc. La simulation, utilisée en association avec des méthodes d'optimisation, est de plus en plus utilisée pour ce type d'études dans la littérature. Dans la section 3, nous proposons une revue des approches existantes. Toutefois, bien que cette association permette de proposer les solutions de conception présentant les meilleures performances du système, elle ne permet pas d'intégrer les aspects incertains (conditions changeantes, évènements imprévus, ..., etc.) qui peuvent considérablement détériorer les performances obtenues. Or, les décideurs de tels systèmes sont surtout demandeurs de solutions de conception qui ne soient pas uniquement performantes mais aussi robustes ; c'est-à-dire qui doivent être en mesure de bien se comporter malgré l'impact de l'incertitude. C'est pourquoi, nous allons cibler notre étude bibliographique dans la section 4 sur l'intégration de l'incertain dans les études d'optimisation via simulation. Nous présenterons donc les différentes méthodes utilisées dans ce domaine pour caractériser et quantifier l'incertitude. Puis, nous effectuerons une revue des approches publiées.

2. La simulation comme outil d'évaluation

2.1 Principe de la simulation

De nombreux systèmes complexes nécessitent des études approfondies afin de comprendre leur comportement dynamique et adopter les prises de décision nécessaires. Il est souvent difficile d'utiliser une approche analytique pour les modéliser et évoluer leurs performances

sans formuler d'hypothèses trop restrictives. La figure 1.1, (Law et Kelton, 2000), présente les différentes possibilités pour évaluer les performances d'un système.

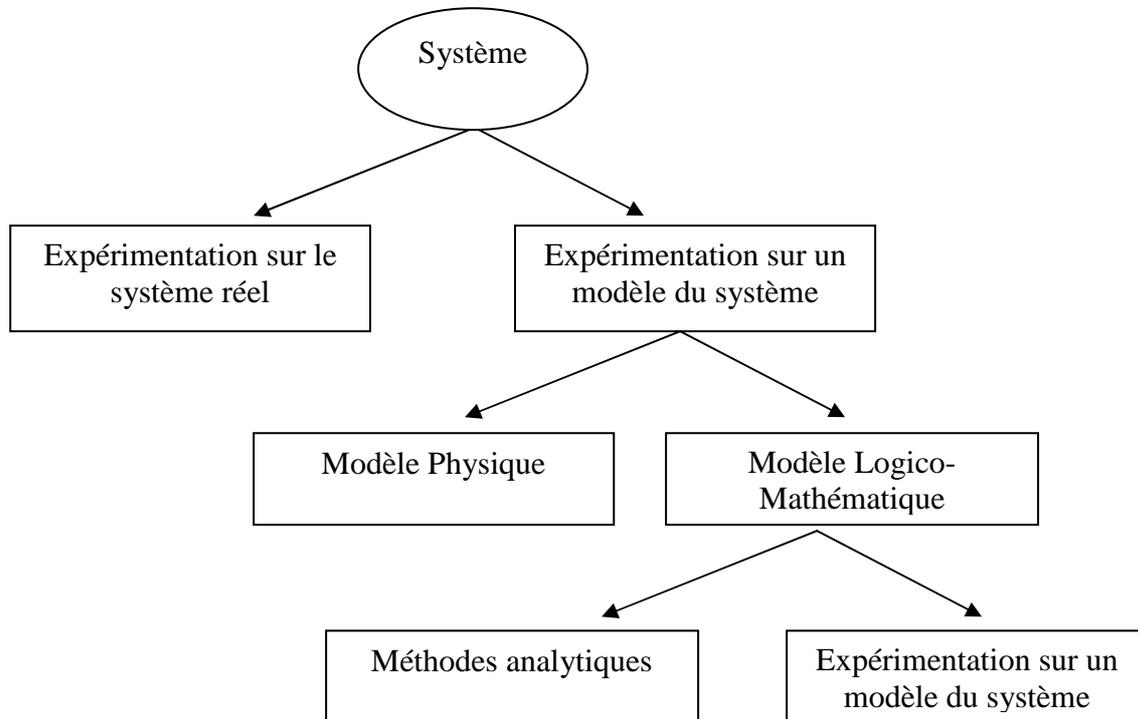


Fig.1. 1. Évaluation des performances : Méthodes

Pour évaluer les performances d'un système suivant un modèle, Law et Kelton (2000) proposent une classification qui distingue les modèles Physiques des modèles Logico-mathématiques :

- Les modèles Physiques sont ceux dans lesquels le système réel est représenté par une réplique ou une maquette, à une échelle différente et éventuellement à l'aide de matériaux différents. Ils sont utilisés à des fins d'entraînement : simulateurs de vol, de conduite, maquettes de véhicules pour des essais aérodynamiques, ..., etc.
- Les modèles Logico-Mathématiques ou symboliques sont définis par des relations logiques et quantitatives qui sont manipulées et changées pour voir comment le modèle du système réel réagit. Ils sont exécutés sur des ordinateurs. Dans cette classe, on différencie les méthodes analytiques (e.g. Réseaux de file

d'attente, Réseaux de pétri, Algèbre des dioïdes) par rapport à l'expérimentation sur un modèle du système : le modèle de simulation.

Dans ce travail de thèse, nous nous intéressons aux modèles de simulation. La simulation sur ordinateur est une technique qui permet, grâce à la réalisation d'un modèle informatique, de reproduire (ou de prédire) certains aspects du fonctionnement dynamique d'un atelier existant ou non afin de répondre à des interrogations sur son fonctionnement (Ziegler et al, 2000 ; Pierreval, 1990). En d'autres termes, cela revient à plonger un modèle dans le temps et observer l'évolution de ce modèle (Hill, 1996).

Un modèle de simulation nous permet d'obtenir typiquement, à partir de variables d'entrées $x_i / i = 1, 2, \dots, n$ comme par exemple le nombre de machines, la politique de gestion de stock ou du réseau de transport, etc ; la variable de sortie y relative à la performance d'un système de production (e.g. nombre des encours, les temps de passage des pièces dans l'atelier, etc.).

Une approche par simulation consiste donc à :

- Concevoir un modèle du système étudié.
- Mener des expérimentations sur ce modèle et non au moyen des calculs. Le modèle de simulation nous permet de tester de façon précise les différentes valeurs possibles pour les entrées du système et délivrer une évaluation de performance relative la plus proche possible de la réalité.
- Interpréter les observations fournies par le déroulement du modèle et formuler des décisions relatives au système.

A l'heure actuelle, le développement des logiciels de simulation permet une meilleure précision des modèles construits. Les domaines d'application sont divers. La liste ci-dessous présente quelques exemples :

- Systèmes de production (équilibre de lignes d'assemblage, dimensionnement des stocks d'un atelier, etc.).

- Flux logistiques et systèmes de transport (conception et dimensionnement d'entrepôts, étude de procédures de contrôle des flux de véhicules en circulation, etc.).
- Production des services (étude de transactions bancaires, ..., etc).
- Systèmes informatiques et télécommunications (évaluation de protocoles de gestion des transactions de bases de données, étude des comportements des utilisateurs, conception et dimensionnement de hubs, etc.).
- Domaine militaire (support logistique, coordination des opérations, ...).
- Gestion d'hôpitaux (personnel, lits, service d'urgence, ...), etc.

2.2 Classification des types de simulations

Law et Kelton (2000) proposent une classification des modèles de simulation qui distingue les modèles statiques des modèles dynamiques :

- Les modèles statiques, pour lesquels le temps n'intervient pas. Exemple : modèle comptable permettant de calculer le bénéfice en fin d'année à l'aide d'un tableur.
- Et les modèles dynamiques, pour lesquels le comportement est une fonction du temps comme par exemple un système de maintenance dans une usine.

Un modèle de simulation diffère aussi selon la logique de changement d'état à adopter :

- Les modèles de simulation continus où les modèles sont décrits par des équations qui régissent les changements d'état par exemple les flux continus des produits dans l'industrie chimique ou l'industrie agro-alimentaire.
- Les modèles à événements discrets où les changements d'état n'ont lieu qu'à certains instants de façon discrète.

- Les modèles de simulation combinés où les variables du modèle peuvent évoluer de façon hybride (discrète/continue).

Enfin, une dernière distinction concerne le comportement des variables dans le modèle :

- Si le système est indépendant de l'influence de variables aléatoires ou imprévisibles, on utilise un modèle déterministe.
- Si des aléas ou des variations aléatoires jouent un rôle significatif dans le comportement du système (exemple typique : les pannes dans les systèmes de production), on utilise un modèle stochastique.
- Si le comportement du modèle est visualisé par animation graphique et l'utilisateur peut modifier des paramètres en cours de simulation, on utilise un modèle de simulation visuelle interactive (VIS).

Dans la suite de ce travail, on traitera principalement les problèmes rencontrés dans la simulation à événements discrets stochastiques. En utilisant un modèle de simulation stochastique, les variables de sortie du modèle sont généralement aléatoires. La simulation, utilisée seule, ne permet pas de déterminer parmi plusieurs scénarios de conception ou d'organisation du système celle qui est la plus performante.

Par ailleurs, la simulation nous donne les moyens d'étudier le comportement d'un système dynamique. C'est une technique couramment utilisée pour répondre aux questions de type « Que se passerait t'il si ? ». Elle aide les analystes à déterminer les performances du système en réponse aux différentes valeurs des variables données en entrée.

Cependant, il nous est difficile d'effectuer des analyses directes notamment pour déterminer le meilleur réglage des variables d'entrées pour obtenir la meilleure performance. Il faut donc associer à la simulation d'autres méthodes afin de rechercher des solutions optimales.

3. L'optimisation via simulation

3.1 Principe

L'optimisation d'un système, par exemple un système de production, consiste souvent à déterminer les meilleures valeurs des variables qui le composent selon divers critères de performance tels que le temps de fabrication, le nombre d'encours, ..., etc. Certaines variables sont numériques comme les capacités de stockage, le nombre de boucles kanban, la taille des lots de transport ou non numériques comme les règles de priorité. Il y a souvent de fortes interactions entre ces variables (par exemple, certaines tailles de lots peuvent engendrer de bons résultats avec une règle de priorité donnée et de mauvais résultats avec une autre). De même que pour les évaluer, il est souvent donc difficile d'utiliser des approches analytiques afin de les optimiser, sans formuler d'hypothèses trop restrictives. La solution la plus adaptée pour permettre leur évaluation est souvent la simulation. L'usage direct de la simulation par une approche « essais-erreurs » peut permettre de tester plusieurs scénarios d'organisation du système au regard d'une fonction objectif. En revanche, lorsque le nombre de possibilités devient trop élevé, il est nécessaire d'optimiser via simulation le système.

De nombreuses approches permettent d'optimiser les variables d'un système simulé (Fu, 2002 ; Tekin and Sabuncuoglu, 2004 ; Andradottir, 2007). Typiquement connues sous le terme optimisation via simulation, ces approches déterminent les meilleures valeurs possibles pour un vecteur d'entrées d'un modèle de simulation de sorte à optimiser une fonction qui représente souvent un ou plusieurs critères d'évaluation de performance.

3.2 Notations et définitions

3.2.1 Variables de décision

Nous appellerons variables de décision, tous les paramètres quantitatifs ou qualitatifs d'un système sur lesquels les décideurs du système peuvent agir (e.g. le nombre de machines, le nombre d'opérateurs, la politique de gestion des stocks, ..., etc.). Chaque variable de décision, notée x_i , sera définie par son domaine de variation (ou son ensemble de définition), noté D_i . Une solution X sera alors représentée par un vecteur de n variables de décision :

$$X = [x_1, x_2, \dots, x_n]^T \in D$$

où le domaine de variation $D = D_1 \times D_2 \times \dots \times D_n$

3.2.2 *Mesure de performance*

La mesure de performance constitue le ou les critères que les décideurs du système cherchent à optimiser tels que le temps de fabrication, les encours, le retard à la livraison, le taux d'utilisation de l'équipement ou du personnel, etc. Estimée par le modèle de simulation, cette mesure représente la variable de sortie y relative à la performance d'un système en réponse à la solution X étudiée.

Nous appellerons M , le modèle de simulation utilisé pour évaluer la performance d'une solution X et la réponse relative sera notée $F(X)$.

Dans notre contexte, la simulation étant stochastique et les variables de sortie du modèle sont aléatoires, plusieurs méthodes peuvent être utilisées pour la dimension aléatoire comme par exemple la méthode des répliques ou la méthode des lots pour une simulation longue (Law et Kelton, 2000).

3.2.3 *Formalisation de l'optimisation via simulation*

Dans la littérature, les auteurs s'intéressent à l'exploration du domaine de recherche défini par l'ensemble D et expriment ceci par un problème de minimisation ou de maximisation de la valeur de la fonction objectif. Le problème est alors de chercher la valeur de la performance optimale z^* décrit de la façon suivante (Tekin and Sabuncuoglu, 2004) :

$$z^* = \min_{x \in D} / \max F(X) \tag{1.1}$$

avec $F(X)$ qui peut être égale à $E[G(X, \omega)]$ où $G(X, \omega)$ typiquement relative à la sortie de simulation y suite à la présence des effets stochastiques, dénotés par ω .

2.3 Méthodes de recherche existantes

De nombreux travaux ont été menés concernant l'optimisation via simulation. Ces travaux diffèrent suivant la méthode d'optimisation employée qui est étroitement liée aux contextes et aux objectifs de l'étude.

Plusieurs revues ont été publiées, par différents auteurs, où différentes classes d'approches ont été distinguées (Swisher et al, 2004; Tekin et Sabuncuoglu, 2004; Fu et al, 2005 ; Andradottir, 2007; Ammeri et al, 2010; Mansourinia et al, 2011). Dans son article, Fu (2002) a identifié quatre grandes catégories de stratégies de recherche pour guider les recherches d'optimisation via simulation. Dans d'autres travaux, certains auteurs les distinguent selon la nature des variables à optimiser : valeurs discrètes ou des valeurs continues (Olafsson and Kim, 2002) ou selon la taille de la région d'exploration des solutions : petit ou grand espace d'exploration (Swisher et al, 2004).

Parmi les différentes classes d'approches distinguées dans la littérature, nous présentons ci-dessous les méthodes de recherche les plus utilisées.

- *Les méthodes basées sur le gradient* ou « *les méthodes d'approximation stochastique* ». Les algorithmes d'approximation stochastique tentent d'imiter la méthode de recherche utilisée dans l'optimisation déterministe : la méthode du gradient. Les procédures basées sur cette méthodologie doivent estimer le gradient de la fonction objectif afin de déterminer une direction de recherche. L'approximation stochastique cible principalement les cas de problèmes avec des variables continues. Elle a été adaptée à des cas de problèmes avec des variables discrètes, notamment dans le travail de (Gerencser et al, 2004).
- *La méthodologie de surface de réponse* (Kleijnen, 2008a) est basée sur le principe de construction d'un (ou plusieurs) modèle mathématique appelé « métamodèle » ou « surrogate model » d'une manière localisée. Le processus de « surface de réponse locale » est répété pour déterminer une stratégie de recherche (par exemple : le passage de direction du gradient estimé). En d'autres termes, les métamodèles ne tentent pas de caractériser la fonction objectif dans l'ensemble de l'espace des solutions, mais plutôt se concentrent à explorer à chaque fois une région de recherche. Les choix les plus populaires des métamodèles sont les métamodèles linéaires et quadratiques. Les métamodèles polynomiaux sont aussi des formes compactes et faciles à évaluer, mais ils ont souvent une capacité limitée à modéliser des fonctions complexes de forme arbitraire (Deng, 2007). Li et al (2010) ont publié, récemment, un

article de référence dans lequel ils établissent une comparaison des techniques basées sur les métamodèles les plus populaires en optimisation via simulation.

Dans cette classe d'approches, les méthodes utilisent des fonctions mathématiques explicites dans le modèle de simulation pour estimer le gradient, la surface de réponse ou les métamodèles de régressions (cf. figure 1.2). Comparée à plusieurs méthodes basées sur le gradient, la méthodologie de surface de réponse est une méthode relativement efficace d'optimisation via simulation en raison du nombre d'évaluations du modèle de simulation requis.

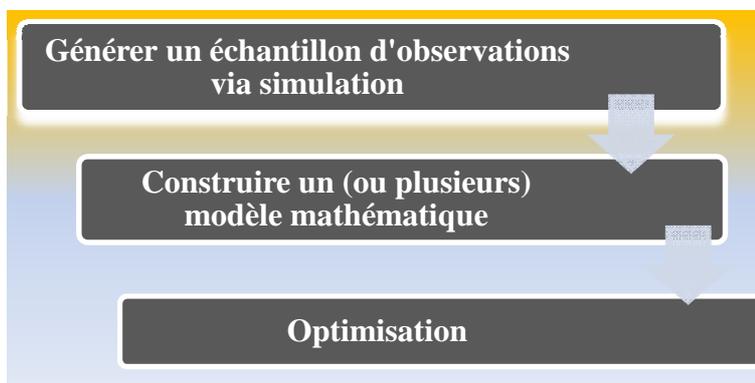


Fig.1. 2: Optimisation via simulation : les méthodes basées sur les modèles mathématiques

Cependant, en raison des caractéristiques d'exploration, la méthodologie de surface de réponse a tendance à être extrêmement sensible aux optima locaux (Yunker et Tew, 1994 ; Kleijnen, 2008) tel qu'il est présenté sur la figure 1.3. De plus, son usage est limité pour les cas où les domaines de définition des variables sont des intervalles réels notamment lors du calcul des gradients, la surface de réponse et les métamodèles de régressions (Olafsson, et al, 2002).

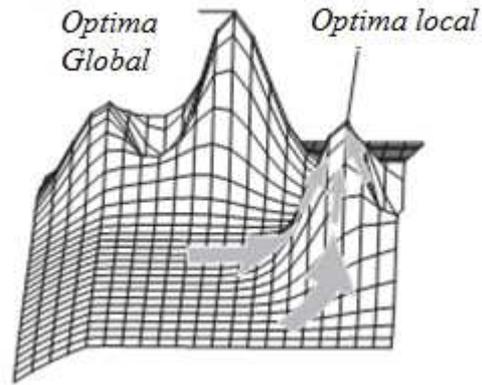


Fig.1. 3: Convergence prématurée à un optimum local dans une maximisation de la fonction objectif

Une autre classe d'approches regroupe les méthodes d'optimisation utilisées conjointement avec la simulation (cf. figure 1.4) où le module d'optimisation propose successivement des solutions que l'on espère de plus en plus performantes, au module de simulation (Ouabiba et al, 2001). Ce dernier les évalue en calculant le comportement du système ainsi paramétré, ceci jusqu'à la satisfaction d'un critère d'arrêt (nombre de générations, valeur de l'optimum atteint, etc...).

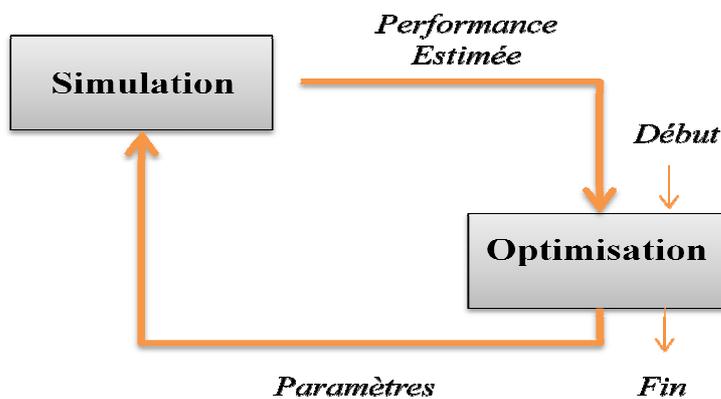


Fig.1. 4: Optimisation via simulation : couplage entre l'optimisation et la simulation

Nous présentons les trois méthodes les plus utilisées ci-dessous.

- *Le recuit simulé* : cette méthode a été introduite par deux équipes indépendantes Kirkpatrick et al, (1983) et Cerny, (1985). Son principe consiste à définir une solution initiale et choisir à partir de celle-ci une solution voisine pour l'évaluer. Si la fonction d'évaluation est améliorée, cette solution devient la solution courante. Sinon elle est considérée comme solution courante mais avec une probabilité qui décroît suivant une certaine loi et en fonction du nombre de solutions déjà étudiées. Contrairement à un algorithme classique, cette méthode accepte une dégradation de la fonction objectif, avec une certaine probabilité, sachant que cette dégradation pourra entraîner une amélioration ultérieurement. Le principal avantage du recuit simulé est donc la capacité d'éviter les pièges des optimums locaux en fonction d'une probabilité d'acceptation liée à une fonction exponentielle, appelée transformation de *Gibbs-Boltzmann*. Cependant, elle présente l'inconvénient de s'intéresser qu'à un seul voisin et de faire intervenir des paramètres intrinsèques au recuit simulé tels la valeur initiale de température et le coefficient de décroissance de la température.
- *La recherche tabou* : c'est une procédure de recherche contrainte, où chaque étape consiste à résoudre un deuxième problème d'optimisation en excluant un sous ensemble de l'espace de solutions. En effet, pour remplacer une solution courante, la méthode tabou nécessite l'exploration exhaustive du voisinage de la solution courante, choisit la meilleure solution et ajoute la solution courante dans la liste des solutions testées dans un passé proche. Cette liste Tabou représente la difficulté majeure du fait qu'elle utilise une loi FIFO : quand la liste est pleine, on supprime la plus ancienne solution et on la remplace par la nouvelle solution à interdire.
- *Les algorithmes évolutionnistes* procèdent suivant une stratégie de recherche qui s'inspire des phénomènes d'évolution naturelle : héritage génétique et principe de survie du plus fort de Darwin (Bäck, 1996). Contrairement aux solutions simples dans les méthodes traditionnelles, ils partent d'un ensemble de solutions potentielles du problème que l'on nomme population d'individus. Les algorithmes évolutionnistes

vont faire évoluer cette population vers une population supposée contenir la meilleure(s) solution(s) en suivant le cycle évaluation-reproduction. De nombreux auteurs ont utilisé les algorithmes évolutionnistes avec succès dans certains domaines, notamment dans les systèmes de production (Pierreval et al, 2003). Cette approche permet de traiter à la fois les facteurs quantitatifs et qualitatifs d'un système (Azadivar et Thompkins, 1999). De plus, il existe des adaptations de ces algorithmes pour l'optimisation multiobjectif notamment dans Alberto et al, (2002) ou encore pour l'optimisation multimodale (Singh et Deb, 2006).

Au travers de notre revue, nous avons remarqué qu'il y a un intérêt important pour les algorithmes évolutionnistes dans le cadre de l'optimisation via simulation notamment parce qu'ils n'exigent pas d'hypothèses restrictives ou de connaissances, *a priori*, sur la forme de la surface de réponse (Bäck et Schwefel, 1993). Ils s'avèrent performants, par rapport à d'autres méthodes tels le recuit simulé ou la recherche tabou mais ils sont reconnus très coûteux en temps de calcul. Toutefois, une approche distribuée peut être mise en place (Pierreval et Paris, 2000).

4. Prise en compte de l'incertitude dans les études d'optimisation via simulation

4.1 Généralités sur l'incertitude

Dans la littérature, les notions de « robustesse » et « incertitude » sont souvent sujettes à discussion. Il n'existe pas de définition unanime de la robustesse et l'incertitude n'a pas un sens précis couramment utilisé par les auteurs. En effet, l'incertitude peut être perçue différemment selon les domaines et les auteurs. En recherche opérationnelle, et notamment dans le domaine de l'aide à la décision, Roy (1997) propose le concept de conclusion robuste qui vise à élaborer des éléments de réponse à un problème auquel est confronté un décideur, éléments de réponse qui sont obtenus en prenant en compte les incertitudes éventuelles sur les paramètres du problème. Dans un autre travail (Roy, 2010), le même auteur définit le terme robuste comme un qualificatif se rapportant à une aptitude à résister à des « à peu près » ou à

des « zones d'ignorance » afin de se protéger d'impacts jugés regrettables. Néanmoins, il est imparfaitement possible de les détecter (Roy, 2010). C'est le cas, par exemple, pour les « à peu près » qui découlent de simplifications, de mauvaises déterminations ou d'options arbitraires et des zones d'ignorances qui proviennent de mauvaises connaissances relatives à la complexité de phénomènes ou de systèmes de valeurs. Dans la théorie de la décision, l'action la plus robuste est celle qui ne conduit pas à une perte importante quelque soit l'évènement qui va se produire (Pomerol, 2001). D'après Davenport et Beck (2000), il n'existe pas de définition d'ordonnancement robuste mais plutôt une compréhension générale informelle de ce qu'est la robustesse (e.g, la capacité d'un ordonnancement prédictif d'être performant malgré des évènements inattendus). Plus récemment, Liefoghe (2010) réfère le concept de robustesse dans le domaine de l'ordonnancement à la capacité du sujet à faire face à des incertitudes.

En ce qui concerne la conception de systèmes, les auteurs parlent de stratégie de conception robuste. Ainsi pour certains auteurs (Tsui, 1992 ; Sanchez, 2000 ; Jichao, 1996), l'environnement d'un système fluctue tout au long de son cycle de vie et des perturbations ou des variations de celui-ci peuvent venir affecter son fonctionnement et donc ses performances. Il s'agit donc d'ajuster les paramètres du système de telle sorte que les performances de celui-ci soient insensibles aux sources incontrôlables de variation présentes dans son environnement. Pour Gaury (2000), il s'agit toujours d'ajuster les paramètres du système afin que son niveau de performance soit acceptable dans de nombreux environnements. D'après Durieux (2004), concevoir un système robuste revient à trouver des solutions robustes à des changements susceptibles de survenir tout au long du cycle de vie de ces systèmes.

La prise en compte de l'incertitude en optimisation, quant à elle, est perçue de différentes manières dans la littérature. L'incertitude est traditionnellement traitée par des approches stochastiques (Prekopa et Ruszczyński, 2002). Ainsi, son traitement est généralement basé sur des estimations déterminées en liaison avec les experts du système. Nous avons vu que l'incertitude peut être aussi traitée à travers une formalisation d'un problème d'optimisation multicritère : la minimisation de l'espérance et l'écart type de la fonction objectif (Doltsinis et Kang, 2004). D'autres types d'approches, dites « d'optimisation robuste » (Bertsimas et al, 2009), traitent la prise en compte de l'incertitude particulièrement pour des fonctions objectifs convexes notamment discrètes linéaires, quadratiques convexes ou coniques (Ben-Tal et

Nemirovski, 1998 ; Bertsimas et Sim, 2004) ou encore récemment pour des fonctions non linéaires (Zhang, 2007). Dans leur revue de l'optimisation évolutionniste en présence d'incertitude, Jin et Branke (2005) classent les types d'incertitude en quatre catégories de la façon suivante :

- *Fonction objectif bruitée* où l'évaluation d'une solution est sujette au bruit (erreurs de mesure, etc.). En conséquence, à chaque appel de la fonction objectif avec les mêmes arguments, celle-ci retourne une valeur différente.
- *Recherche de solutions robustes*. Cette catégorie est divisée par certains auteurs (Chen et al, 1996 ; Beyer and Sendhoff, 2007). Ils distinguent les variations relatives aux variables de décision à celles des facteurs d'environnement en affirmant qu'elles résultent en des sources différentes. Ainsi, la recherche de solutions robustes peut être discutée de deux manières et donc traitée à partir de deux perspectives. D'une part, une solution robuste peut être vue insensible à de petites variations des variables de décision. D'autre part, elle peut être également vue comme insensible à de petites variations des facteurs d'environnements. Pour chacun des cas considérés, de telles solutions sont dites robustes.
- *Fonction objectif approchée*. Lorsque l'évaluation d'une solution est extrêmement coûteuse en temps de calcul, ou qu'une fonction objectif analytique n'est pas disponible, la fonction objectif utilisée est souvent approchée à l'aide de données générées de façon expérimentale ou issues de simulations. Pour ce cas, la fonction objectif souffre d'erreurs d'approximations.
- *Environnement dynamique*. La solution optimale peut changer au cours de l'exécution. La méthode mise en place devrait, en conséquence, être en mesure de pouvoir continuellement suivre le changement de l'optimum plutôt que de nécessiter un redémarrage complet du processus de recherche.

Dans ces travaux de recherche, nous nous intéressons à la prise en compte des données incertaines dans un contexte d'optimisation via simulation. En effet, la présence de données incertaines peut avoir une répercussion directe sur le calcul de la fonction objectif du fait que

les performances sont obtenues par simulation. Il est vrai que la simulation nous permet d'obtenir des évaluations de performance réalistes prenant en compte les phénomènes aléatoires dans le modèle. Toutefois, l'aléatoire ne représente pas tous les différents types d'incertitudes qui sont rencontrés dans les systèmes étudiés. En effet, il est fréquent qu'un modèle de simulation soit construit en faisant un certain nombre d'hypothèses (distribution stochastique, hypothèse simplificatrice, etc). De plus, certaines données avec lesquelles on formalise la fonction objectif sont vagues, souffrent parfois d'imprécision ou sont basées sur des estimations ou des connaissances subjectives. De ce point de vue, l'optimisation via simulation robuste est perçue comme un processus d'optimisation des performances du modèle de simulation, où la meilleure solution n'est pas trop sensible aux manques de précision dans la spécification du modèle de simulation et dans la formalisation de la fonction objectif.

4.2 Modélisation de l'incertitude

Dans certaines études, les entrées de la simulation peuvent être incomplètes au moment de la construction du modèle de simulation ou lors de la formulation des objectifs de l'étude. Si ces informations ne peuvent être connues, aucune hypothèse par exemple ne peut être formulée sur les distributions de probabilité associées au modèle vue qu'une telle distribution est généralement inconnue à l'avance et susceptible de différer pour toute solution. Pour aboutir à des conclusions robustes par la simulation, Durieux et Pierreval (2003) ont présenté les différents types de méthodes publiés dans la littérature. Plus récemment, Beyer et Sendhoff (2007) ont établi une revue détaillée des approches utilisées pour modéliser et mesurer l'incertitude. Ainsi, ils distinguent d'abord l'incertitude objective (aléatoire) et l'incertitude épistémique (subjective) relative notamment aux incertitudes sur le modèle de simulation utilisé pour décrire la réalité: les formes de modélisation erronées, données incertaines relatives aux composantes du modèle comme sa frontière et ses conditions opératoires. Ils rajoutent que les phénomènes aléatoires sont généralement inclus dans le modèle de simulation ; contrairement aux incertitudes épistémiques qui sont peu abordées dans la littérature. Dans le même travail, les auteurs décrivent trois façons pour quantifier mathématiquement l'incertitude :

- *Modélisation déterministe* où on définit les domaines de variation des données incertaines et plus précisément par des ensembles fixés.
- *Modélisation probabiliste* où on définit les distributions de probabilités associées aux données incertaines.
- *Modélisation possibiliste* où on définit des ensembles flous décrivant les possibilités d'occurrence d'un événement.

D'après cette classification, nous avons établi un examen de la littérature qui nous a conduit à distinguer plusieurs types de méthodes. Nous introduisons et discutons ces méthodes dans la suite.

4.2.1 La modélisation stochastique

Certaines variables d'entrée du modèle de simulation, données relatives au système et à son environnement, peuvent comporter des phénomènes aléatoires. De ce fait, le modèle de simulation M et la fonction objectif $F(\cdot)$ sont dits stochastiques. Leur représentation est fréquemment établie moyennant des lois de probabilités. Ainsi, des temps de cycle machine ou opérateur, des approvisionnements en matières premières, des fréquences de commandes, l'apparition de pannes et leurs réparations peuvent être représentées par des processus stochastiques (Law et Kelton, 2000).

Les modèles de simulation, abordés dans ce travail, étant stochastiques nous supposons alors qu'un nombre de répliques, noté r , (ou une seule simulation longue) doit être nécessaire pour chaque solution de manière à prendre en compte les variables aléatoires du modèle. Pour une solution $w \in D$, nous obtenons par exemple un échantillon de r performances (r valeurs de la fonction objectif), notées $\{F_1(w), F_2(w), \dots, F_r(w)\}$. Puis, nous utiliserons comme mesure, la performance moyenne de la solution sur les différentes répliques, notée $\hat{F}(w)$. Les résultats pourront, ensuite, être analysés à l'aide de techniques statistiques.

4.2.2 La simulation floue

Dans les approches classiques d'optimisation via simulation, certaines variables peuvent ne pas être quantifiées par une technique basée sur la théorie des probabilités : des données vagues ou certaines connaissances exprimées avec des règles du langage naturel (Medaglia et al, 2002). Par exemple dans un système de production, la théorie des probabilités nous permet d'estimer « *la probabilité d'obtenir un volume annuel de commandes de N unités pour le produit A qui peut être égale à P* ». Dans certains cas, cette information est vague par exemple « *le volume annuel de commandes de N unités pour le produit A peut être situé entre $N1$ et $N2$* » ou alors « *égale approximativement à N* ». Si le modèle contient des variables floues, le modèle de simulation M et la fonction objectif $F()$ sont flous. En cas d'absence de données statistiques, la théorie des possibilités remplace la théorie des probabilités à travers une représentation des informations vagues par des ensembles ou sous-ensembles flous (Gien et Jacquart, 2005). Certains auteurs ont travaillé sur la construction de modèle flou et se sont intéressés au traitement des données floues au sein d'une simulation discrète. Ainsi, Perrone et al (2001) ont proposé des méthodes pour classer les événements flous dans une simulation à événements discrets.

Les approches basées sur la théorie des ensembles flous ont pu être utilisées notamment dans la conception via simulation des systèmes de production pour formaliser, par exemple, les données relatives à l'environnement du système comme les demandes, les dates de livraison, etc. (Triantis et al, 2003) ; à la présence humaine (Zha, 2003) ; ou encore pour l'agencement des ateliers (Al-Najjar et Alsyouf, 2003).

4.2.3 La modélisation par des scénarios ou par des environnements

D'après Roy (2010), la recherche de robustesse repose sur la définition d'une famille finie ou infinie de scénarios en expliquant que « *Cette famille doit permettre d'internaliser dans les différentes réalités vécues qui méritent d'être considérées : c'est l'incertitude dans laquelle on est d'attribuer une vraie valeur à certaines données ou paramètres qui oblige à considérer ces différentes réalités. Chaque scénario est ainsi défini en attribuant une valeur précise à chacune de ces données et paramètres* ».

En suivant ce principe, nous avons remarqué que la prise en compte de l'incertitude est perçue par certains auteurs par la nécessité de quantifier les données incertaines. Selon les auteurs,

ces données sont appelées « facteurs bruit » ou « facteurs d'environnement ». Leur modélisation est définie via des scénarios ou des environnements testés par la simulation. Pour les identifier plusieurs méthodes existent dans la littérature notamment les méthodes d'échantillonnage ou les plans d'expériences (Kleijnen, 2008).

La méthode introduite par Taguchi dans les années 1950 est plus connue dans le domaine de la qualité auprès des industriels. Cette méthode consiste à ajuster les variables contrôlables de telle sorte que les performances du système soient relativement insensibles aux variations des facteurs bruits (facteurs non maîtrisables ou souffrant d'un manque de précision) (Tsui, 1992; Lim et al, 1996; Jichao, 1996 ; Madu et Madu, 1999; Sanchez, 2000). Taguchi distingue trois types de problème d'optimisation : une minimisation, une maximisation, un ajustement sur une valeur cible. Dans cette optique, un plan d'expériences croisé est proposé pour définir les solutions de conception et les scénarios à tester. Les variables contrôlables varient selon un premier plan d'expériences. Les performances de chaque combinaison de ces variables, représentant une solution de conception, sont estimées sur les différents scénarios définis par un deuxième plan d'expériences. Le but d'un plan d'expériences croisé est alors de trouver les valeurs à retenir pour les variables de conception afin d'obtenir une conception « robuste », c'est-à-dire qui minimise l'influence des facteurs bruit sur la performance tout en assurant un niveau minimum pour la performance moyenne.

Dans l'approche proposée par Taguchi, aucune distinction n'est faite entre les scénarios testés. Dans certaines études, un environnement peut se distinguer des autres (Pierreval et Durieux, 2007 ; Durieux, 2004). En effet, il peut exister un environnement que les experts du système jugent le plus représentatif des conditions dans lesquelles le système évoluera. Dans ces cas d'études, l'environnement escompté est déterminé en liaison avec les experts. Pour quantifier les autres environnements, on associe à tout facteur environnemental incertain, un ensemble de valeurs possibles, par exemple deux niveaux par facteur (voir figure 1.5) en utilisant les plans d'expériences (Kleijnen, 2008).

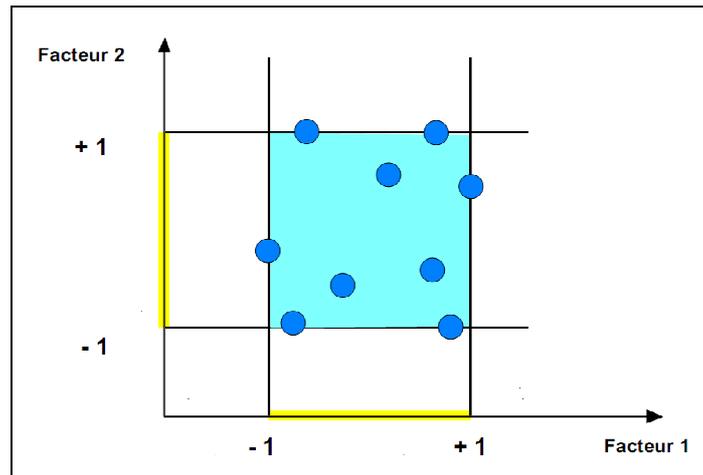


Fig.1. 5:Plan d'expérience factoriel : deux facteurs et deux niveaux.

4.3 Bilan

Au vu de cette présentation de la littérature, nous constatons que la caractérisation de l'incertitude diffère selon la théorie utilisée pour aborder l'incertitude (théorie des probabilités, théorie des possibilités, Etc.) et selon les auteurs. Nous avons remarqué que de nombreuses recherches ont exploré la dimension stochastique dans la simulation et plusieurs articles ou livres répondent aux questions qui lui sont reliées (Law et Kelton, 2000 ; Kleijnen 2008).

La simulation floue est privilégiée par certains auteurs et paraît comme un outil de modélisation rapide par rapport aux approches classiques : une seule simulation suffit pour analyser l'environnement d'un système affecté par une connaissance vague ou imprécise (Durieux et Pierreval, 2003). En ce qui concerne la modélisation par des scénarios ou des environnements, nous avons constaté que les méthodes utilisées (les plans d'expérience ou les méthodes d'échantillonnage) permettent de varier chacun des facteurs incertains (deux niveaux ou plus) et par conséquent plusieurs simulations doivent être établies.

Cependant, représenter l'incertitude ne peut être suffisant pour déterminer des solutions robustes. Il faut pouvoir la valuer par des approches quantitatives ou qualitatives. Nous présentons dans la suite ces différentes approches utilisées pour conduire des études par optimisation via simulation robustes.

5. Revue des approches d'optimisation via simulation robustes

Nous avons effectué une revue des approches publiées dans un contexte d'optimisation via simulation. Ainsi, les différentes méthodes présentées dans le paragraphe précédent ont été associées à des algorithmes d'optimisation ainsi qu'à différentes mesures de robustesse. L'examen de la littérature effectué nous conduit à distinguer différents types d'approches que nous discutons dans les paragraphes suivants.

5.1 Les approches basées sur la méthodologie de Taguchi

Dans ces approches, différentes mesures de robustesse ont été utilisées. Certains auteurs cherchent à minimiser la performance moyenne et sa variance ou (la déviation standard) sur l'ensemble des environnements par l'application de la méthode de surface de réponse (Wild et Pignatello, 1991 ; Sanchez et al, 1996). Toutefois, ces méthodes ont été élaborées dans une optique de conception via simulation de systèmes robustes. Pour des problèmes d'optimisation peu d'approches ont été publiées :

- Benjamen et al (1995) proposent une heuristique basée sur la surface de réponse et qui repose sur la définition de deux mesures de performance concurrentes qui caractérisent le comportement des combinaisons des variables contrôlables testés sur différentes combinaisons de facteurs bruits. Ils proposent donc une optimisation bi-critère selon une stratégie globale qui consiste d'optimiser le second critère tout en maintenant le premier critère à un niveau acceptable.
- Un ensemble d'approches d'optimisation robuste ont été proposées dans les travaux de Dellino et al, (2009 ; 2010). Les auteurs utilisent la modélisation robuste vue par Taguchi mais remplacent les techniques statistiques (e.g. la fonction perte ou le ratio signal / bruit (S/B) proposées par l'application de la méthode de la surface de réponse ou les Kriging métamodèles (Dellino et al, 2008).

Par ailleurs, Al Aomar (2006) a suggéré d'associer les techniques statistiques de Taguchi avec un algorithme génétique classique pour prendre en compte la variabilité de la mesure de performance due uniquement au caractère stochastique du modèle de simulation. Et ainsi, ne plus optimiser en fonction uniquement de la performance moyenne mais en prenant aussi en

compte la variance de la performance de la solution étudiée. L'auteur de cette approche traite la robustesse de chaque solution en l'évaluant au travers d'une fonction perte ou d'un ratio signal / bruit (S/B) proposés par Taguchi. Ce ratio prend en compte à la fois la variabilité de la performance et le rapprochement de la performance moyenne de sa valeur cible.

En revanche, cette méthode est beaucoup plus coûteuse en termes de temps de calcul par rapport aux méthodes utilisant la méthode de surface de réponse.

5.2 Les approches impliquant les décideurs

D'autres auteurs prétendent que la solution robuste doit être définie en liaison directe avec les experts du système notamment Rosen et al (2007) qui soulignent que les approches d'optimisation par simulation supposent implicitement que la solution trouvée est la solution la plus préférable pour le décideur. En conséquence, ils affirment qu'il peut être nécessaire d'intégrer les préférences des décideurs dans la recherche d'optimisation.

Dans leur travail, Pierreval et Durieux (2002) proposent une méthodologie d'optimisation via simulation se voulant plus proche du raisonnement des décideurs. Leur approche est basée sur la distinction d'un environnement attendu par rapport aux autres environnements testés et aussi sur des contraintes fournies par les décideurs, appelées courbes de référence, qui expriment le gain minimal exigé pour chaque environnement. Ainsi, ils conduisent une première optimisation via simulation sur l'environnement attendu afin d'obtenir la meilleure solution. La solution robuste représente le meilleur compromis entre les différences de performances entre la meilleure solution trouvée et une autre solution particulière, obtenue par une deuxième optimisation, sur l'ensemble des environnements testés. La solution robuste retenue est la solution qui répond aux contraintes fixées par les décideurs au travers les courbes de référence et qui procure le gain le plus important. Néanmoins, cette heuristique nécessite des processus d'optimisation multiples et donc un temps de calcul très important.

Suivant la théorie des ensembles flous, Medaglia et al (2002) ont proposé un processus itératif associant une stratégie d'optimisation basée sur la surface de réponse et le contrôle flou avec un module de simulation. Le travail proposé permet d'intégrer les connaissances, exprimées en langage naturel et souvent disponibles chez les analystes et les décideurs des systèmes via leur groupement dans une base de données. Toutefois, tel qu'il a été noté par (Rosen et al, 2007), lorsque le modèle de simulation est stochastique un nombre d'évaluations important

doit être établi pour interagir avec les connaissances des décideurs nécessitant, par conséquent, un temps de calcul très élevé. Ils suggèrent alors une approche alternative, où ils substituent les connaissances des décideurs par un module qui intègre leurs préférences afin que les réponses multiples du modèle de simulation soient converties dans une fonction à optimiser en utilisant la méthodologie de surface de réponse.

Cependant, les décideurs n'ont pas assez de connaissances sur ce qu'ils veulent au moment de la formalisation de l'étude d'optimisation via simulation. De plus, certaines considérations qui vont influencer leurs préférences ne sont pas toutes connues à l'avance ou peuvent être implicites ou qualitatives, ..., etc. Par conséquent, elles peuvent difficilement être regroupées ou paramétrées dans un module ou dans une base de données.

5.3 Les approches basées sur l'analyse du risque

Un système robuste consiste à ajuster les variables contrôlables de telle sorte que le risque d'obtenir une performance non acceptable soit minimisé (Gaury, 2000). Quantifier ce risque nécessite de déterminer la probabilité que l'indicateur de performance soit en dessous (ou au-dessus) d'un certain seuil. Dans Gaury (2000), l'analyse de risque consiste donc à :

- Échantillonner chaque facteur incertain à partir de sa distribution de probabilité,
- Combiner les valeurs sélectionnées en scénarios,
- Conduire une simulation pour chaque scénario,
- Estimer la distribution de probabilité de l'indicateur.

Pour échantillonner les facteurs environnementaux à partir de leurs distributions de probabilités, l'analyse de risque fait appel aux méthodes d'échantillonnage comme la méthode Monte Carlo. Toutefois, des techniques plus évoluées comme le carré latin (Kalagnanam et Diwekar, 1997) peuvent être utilisées dans le but de mieux couvrir l'ensemble des environnements. Enfin, il est nécessaire de définir un seuil pour l'indicateur de performance ainsi qu'une distribution stochastique pour chaque facteur d'environnement sur son domaine de variation. Dans leur travail, Krokhmal et al (2011), les auteurs présentent une étude détaillée sur les techniques de modélisation de l'incertitude à travers l'analyse de risque.

Peu d'approches ont utilisé l'analyse de risque pour un problème d'optimisation via simulation. Gaury (2000) a optimisé les paramètres du système afin que son niveau de performance soit acceptable dans de nombreux environnements en couplant un algorithme génétique avec les tests de dominance stochastique (Wolfstetter, 1996). Néanmoins, comme les méthodes précédentes, utilisant une approche évolutionniste d'optimisation, le temps de calcul peut être très important notamment pour tester le niveau de performance pour chaque environnement. Pour faire face à cette contrainte, plus récemment, Angün (2011) associe l'analyse de risque avec la méthode de surface de réponse pour obtenir des solutions robustes. Toutefois, dans son travail, l'auteur suppose que les distributions de probabilité des facteurs d'environnements sont connues d'après des données historiques.

6. Conclusion

De nos jours, l'optimisation via simulation est de plus en plus utilisée pour étudier le comportement dynamique des systèmes complexes. Toutefois, elle ne permet pas d'intégrer les aspects incertains (conditions changeantes, événements imprévus, ..., etc.) qui peuvent considérablement détériorer les performances obtenues et rendre les conclusions de l'étude l'optimisation via simulation obsolètes.

La plupart des approches d'optimisation via simulation considèrent implicitement que la simulation nous permet d'obtenir des évaluations de performance réalistes prenant en compte les phénomènes aléatoires dans le modèle. Toutefois, l'aléatoire ne représente pas tous les différents types d'incertitudes qui sont rencontrés dans les systèmes étudiés (Beyer et Sendhoff, 2007).

L'étude bibliographique menée montre que peu de travaux portant sur ce thème ont été publiés et qu'ils n'apporteraient pas de réponse entièrement satisfaisante à notre problématique d'introduction de la flexibilité et de l'incertitude dans les études d'optimisation via simulation. En effet, en analysant ces travaux, nous avons constaté que :

- La plupart des approches d'optimisation via simulation utilisées considèrent qu'une solution optimale (ou proche de l'optimal), présentant la meilleure performance du système, sera implicitement suffisante (Rosen et al, 2007). A notre connaissance, il

n'existe pas d'approche capable de générer des solutions alternatives en cas où la solution optimale (ou proche de l'optimal) s'avère inadaptée.

- La conjonction de l'optimisation avec la simulation implique souvent un grand nombre de solutions à évaluer par simulation. Coupler en plus le coût d'évaluation des solutions par simulation pour prendre en compte l'impact de l'incertitude rend le temps de calcul très élevé.
- La présence de plusieurs décideurs et l'intégration de leurs préférences sont récemment abordés dans le domaine de l'optimisation via simulation. Toutefois, les méthodes existantes supposent que les préférences des décideurs peuvent être connues à l'avance et précises de sorte à les paramétrer en interaction avec le processus de recherche.

Toutes ces remarques ouvrent la voie à une contribution personnelle, à savoir l'introduction d'une flexibilité décisionnelle dans les études d'optimisation via simulation. Nous nous intéressons donc dans ce travail de recherche à fournir, à la place d'une seule solution, plusieurs à discuter dans la phase décisionnelle. Ensuite, nous proposons d'exploiter ce choix pour permettre aux membres d'une équipe décisionnelle d'exprimer leurs préférences et déterminer des solutions d'une façon collaborative. Enfin, nous utilisons la flexibilité pour prendre en compte l'impact de l'incertitude à bas coût.

Le chapitre suivant présente une première approche permettant d'introduire de la flexibilité décisionnelle dans l'optimisation via simulation

Chapitre II

INTRODUCTION DE LA FLEXIBILITÉ DÉCISIONNELLE : UNE APPROCHE PAR OPTIMISATION VIA SIMULATION

Chapitre II.

INTRODUCTION DE LA FLEXIBILITE DECISIONNELLE : UNE APPROCHE PAR OPTIMISATION MULTIMODALE VIA SIMULATION

1.	Introduction	33
2.	Définition de flexibilité dans le choix	33
3.	Approche proposée.....	35
3.1	Principes de l'optimisation multimodale	35
3.2	Les techniques de l'optimisation multimodale	38
3.2.1	Les méthodes de niche	38
3.2.2	Les techniques basées sur l'intelligence des essaims particuliers	38
3.2.3	Les systèmes immunitaires artificiels	39
4.	Description de l'approche implémentée.....	39
4.1	Algorithme et implémentation	42
4.2	Vérification et test de l'algorithme d'optimisation	46
4.3	Connexion avec la simulation	49
5.	Conclusion.....	49

1. Introduction

Afin d'obtenir de la souplesse dans le choix de la solution à mettre en œuvre durant la phase de décision, nous proposons une méthode qui permet d'introduire de la flexibilité dans une étude d'optimisation via simulation. Les objectifs seront alors :

- De fournir une possibilité de choix entre plusieurs solutions performantes,
- De procurer une flexibilité intéressante dans le choix.

Typiquement, une étude d'optimisation via simulation permet d'aboutir à une solution unique de conception présentant la meilleure performance du système étudié (ou un front de Pareto dans le cas multiobjectif). Or, dans certains cas, disposer d'une solution unique s'avère non suffisant pour répondre par exemple aux interrogations liées au déploiement de la solution, à sa robustesse ou à sa fiabilité, ... etc. En effet, pour des raisons imprévues une solution performante pourra être difficile à mettre en place. La présence de solutions alternatives, en termes de performance, fournit alors du choix pour la mise en place d'une autre solution qui sera peut être plus facile à implanter et suffisamment performante.

Dans ce chapitre, nous définissons d'abord les principes que nous adoptons pour atteindre les objectifs visés, puis nous présenterons l'approche proposée et l'implémentation que nous avons mise en œuvre. Avant de conclure sur cette approche, nous verrons également comment nous vérifions et testons l'approche implémentée.

2. Définition de flexibilité dans le choix

Le but d'une étude d'optimisation via simulation est de fournir des solutions de conception performantes, évaluées par simulation, répondant à un ou plusieurs critères d'optimisation. Cependant, même s'il existe différentes méthodes efficaces dans ce domaine (cf. Andradottir, 2007), certaines considérations non connues à l'avance ou difficiles à modéliser ne peuvent

pas être prises en compte lors de l'initialisation de la fonction objectif ni incluses dans le modèle de simulation. Par exemple, si la solution ayant la meilleure performance est coûteuse ou non à mettre en œuvre ou alors techniquement réalisable sans difficultés, en phase d'exploitation. De plus, la majorité de ces méthodes ne produit qu'une seule solution et ne permet pas de générer des alternatives de conception performantes en cas où la solution s'avère inadaptée. Ces méthodes permettent alors de disposer d'une solution optimale (ou proche de l'optimal) mais pas de solution alternative de conception pour la remplacer.

Une contribution importante est donc de fournir plus de solutions à discuter durant la phase de décision et ainsi permettre de prendre en compte les considérations ne pouvant être incluses dans l'étude d'optimisation via simulation. De plus, pour garantir une flexibilité intéressante dans le choix, il est important que les solutions soient assez différentes les unes des autres (Gören et Pierreval, 2010) afin d'obtenir des alternatives contrastées (en effet, les solutions similaires sont censées avoir des caractéristiques similaires). Pour faire un bon choix entre les solutions, nous proposons de trouver des solutions avec des caractéristiques suffisamment différentes de telle sorte que chaque alternative soit à la fois acceptable et assez contrastée.

Lorsqu'un tel problème est traité par des techniques d'optimisation classiques l'un des optima sera découvert. Cependant, dans ce travail, nous proposons d'identifier toutes les solutions, c'est-à-dire tous les optima, aussi bien locale que globale. La stratégie la plus simple consiste à exécuter l'algorithme de recherche autant de fois que possible pour localiser toutes les solutions présentant de bonnes performances ; en d'autres termes tous les optima requis. Si tous les optima ont la même probabilité d'être trouvés, le nombre d'exécutions indépendantes est donné approximativement par (Beasley et al, 1993) :

$$op \sum_{j=1}^{op} \frac{1}{J} \approx op (\gamma + \log(op)) \quad (2.1)$$

avec op : le nombre d'optima et γ : constante d'Euler.

Or, dans la pratique, les optima n'ont pas la même chance d'être trouvés, de sorte que le nombre d'exécutions indépendantes est beaucoup plus élevé. D'autre part, dès que le nombre d'optima devient important, cette méthode devient très coûteuse en temps de calcul.

L'optimisation multimodale permet d'identifier plusieurs optima (l'optimum global et les optima locaux). Elle est de plus en plus utilisée dans différents domaines, mais elle est peu

abordée dans la littérature relative à la simulation (Baccouche et al, 2010) ; et d'après notre connaissance elle n'a pas été utilisée dans un tel contexte. Ainsi, pour atteindre les objectifs visés au sein de ce chapitre, nous proposons une approche basée sur l'optimisation multimodale, dont le principe est expliqué dans les sections suivantes.

3. Approche proposée

Nous proposons une nouvelle approche qui permet d'obtenir une possibilité de choix entre plusieurs solutions de conception dans le résultat délivré par une optimisation via simulation d'un système (cf. figure 2.1). Elle repose sur les trois principes suivants :

(i) Nous proposons de remplacer les techniques d'optimisation classiques par un algorithme de recherche multimodal connecté au modèle de simulation pour évaluer les performances du système. Ceci nous permet de trouver tous les optima (optimum global et optima locaux) de notre espace de recherche.

(ii) Nous proposons ensuite d'associer une technique de niche pour garantir la différenciation entre les alternatives. Chaque solution doit présenter des caractéristiques assez différentes des autres solutions pour garantir un bon choix.

(iii) Enfin, nous proposons de restreindre l'ensemble des optima trouvés aux alternatives dont les performances sont voisines à la meilleure performance (l'optimum global).

3.1 Principes de l'optimisation multimodale

Lorsqu'une fonction admet plusieurs optima locaux, elle est dite multimodale (elle est unimodale dans le cas contraire). Le plus petit (respectivement le plus grand) optimum local d'une fonction multimodale, est appelé optimum global. La figure (2.2) présente, à titre d'exemple, une distribution possible des optima d'une fonction unidimensionnelle et multimodale, ainsi que certains points particuliers, tels que les points d'inflexion et de discontinuité, pouvant poser des difficultés aux méthodes de résolution.

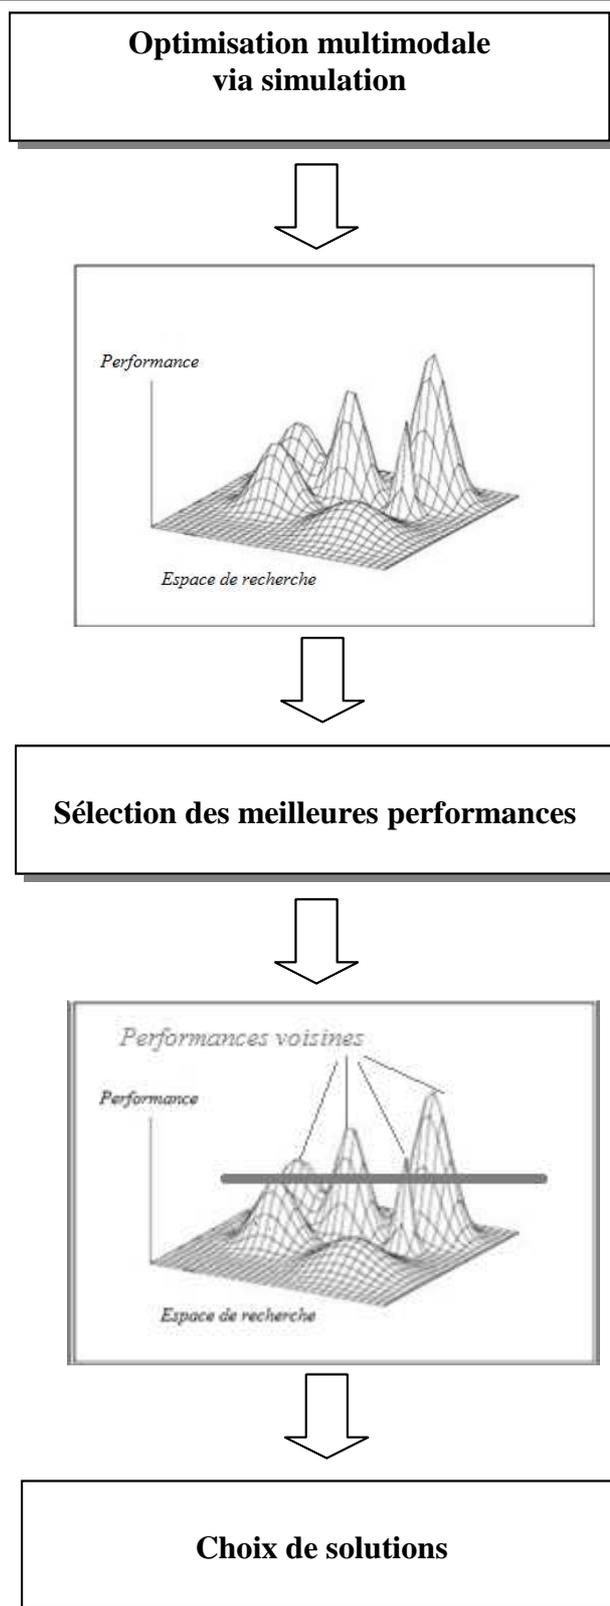


Fig.2. 1. Schéma de l'approche proposée

Dans ce contexte, plusieurs techniques ont été développées, soit pour améliorer les techniques de base en intégrant des procédures de recherche multimodale, soit en concevant de nouvelles heuristiques.

L'adaptation du principe de l'optimisation multimodale nous permet de répondre à la première partie de notre problématique. Ensuite, pour garantir la souplesse dans le choix des solutions nous devons obtenir des solutions ayant des caractéristiques différentes. Ainsi, les méthodes d'optimisation multimodale incluent différentes techniques dont principalement les méthodes de niche (Singh et Deb, 2006 ; Yu et Suganthan, 2010) qui ont été initialement introduites dans les algorithmes génétiques, afin de limiter la dérive génétique due à l'opérateur de sélection et d'explorer en parallèle différentes solutions, locales ou globales, situées dans des régions éloignées de l'espace (Säreni, 1999). Ces caractéristiques permettent d'éviter que l'algorithme de recherche soit piégé dans un optimum local.

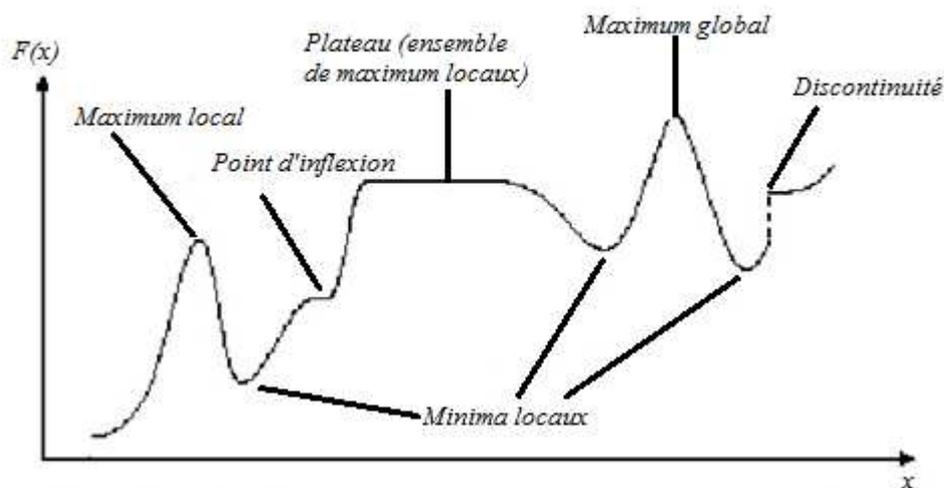


Fig.2. 2. Points singuliers d'une fonction unidimensionnelle multimodale

Il est à noter aussi que d'autres techniques d'optimisation multimodale ont été développées dans la littérature utilisant d'autres concepts associés avec des algorithmes d'optimisation tels que les systèmes immunitaires artificiels (De Castro et Timmis, 2002) et les systèmes basés sur l'intelligence des essaims particulaires (Goldberg et Wang, 1997 ; Benameur et al, 2010). Nous présentons brièvement ci-dessous ces différentes techniques.

3.2 Les techniques de l'optimisation multimodale

3.2.1 Les méthodes de niche

Les méthodes de niche reposent sur une analogie entre les domaines de recherche en optimisation et les écosystèmes naturels. Dans la nature, Chaque espèce évolue de façon à remplir une niche écologique. Une espèce représente un groupe d'organismes identiques de caractéristiques biologiques semblables. Dans chaque niche, les ressources naturelles sont limitées et doivent être partagées entre les représentants des espèces qui l'occupent. Par analogie (Tab 2.1), une niche se réfère typiquement à un optimum de la fonction objectif et la qualité de l'optimum représente les ressources de cette niche (Goldberg et Richardson, 1987). Les espèces sont constituées par des groupes d'individus similaires. La mesure de la similarité entre individus est effectuée à partir d'un critère de distance et d'un seuil de dissimilarité (ou seuil de voisinage).

Les techniques de niche utilisent deux stratégies. La première est basée sur la modification de la structure de certaines régions de l'espace de recherche pour prévenir la convergence de l'algorithme vers ces régions. Cette approche se compose des techniques caractérisées par un voisinage explicite et nécessitant un seuil de dissimilarité fixé pour chaque niche nous permettant d'estimer *a priori* la distance entre deux optima de l'espace. Les seuils sont représentés par des radius (ou compteurs de niches) ou des ratios, calculés ou fixés avant l'exploration de l'espace de recherche. Cette stratégie de niche englobe les techniques de remplissage, de partage et les méthodes hybrides.

La seconde approche est constituée par des procédés de nichage à voisinage implicite. Le seuil de dissimilarité n'est pas explicitement requis. La similarité est définie selon plusieurs critères en comparant les individus. Les membres sont comparés un à un avant de les inclure dans une niche en utilisant généralement les distances phénotypiques notamment pour la technique de surpeuplement. Les techniques des « îlots » et de « populations isolées » utilisent aussi cette seconde stratégie où des contraintes géographiques sont imposées à la population (e.g. species distance dans la technique des « sous-populations ») pour délimiter les similarités entre deux individus d'une même espèce et prévenir la prolifération rapide d'individus très performants.

<i>OPTIMISATION</i>	<i>NATURE</i>
Espace de recherche	Ecosystème
Fonction objectif	Ressources
Optimums	Niches
Groupes de configurations similaires	Espèces
Distance Mathématique	Différence biologique

Tab 2. 1: Analogie entre les espaces mathématiques et la nature

Plusieurs méthodes de niche, exploitant ces deux stratégies, ont été reportées dans la littérature. Nous citons les méthodes les plus utilisées incluant les techniques : de partage (Goldberg et Richardson, 1987 ; El Imrani et al, 1999), de niche séquentielle (Beasley et al, 1993), de niche dynamique (Gan et Warwik, 1999) ou de procédure d'éclaircissement (Petrowski, 1996 ; Singh et Deb, 2006), de surpeuplement (Harik, 1995 ; Mahfoud, 1995 ; Mengsheol et Goldberg, 1999 ; Qing Ling et al, 2008), de surpeuplement associée à un algorithme génétique parallèle, de surpeuplement associée à l'évolution différentielle (Thomsen, 2004), des sous-populations (Li et al, 2002) et enfin les méthodes hybrides notamment Lin et al (1998) qui associent un algorithme génétique standard avec une technique de recherche locale.

3.2.2 Les techniques basées sur l'intelligence des essaims particuliers

L'optimisation par essaim de particules (PSO) repose sur un ensemble d'individus originellement disposés de façon aléatoire et homogène, appelés particules, qui se déplacent dans l'espace de recherche et constituent, chacune, une solution potentielle. Les méthodes de niche ont été étendues récemment pour pallier aux limitations que présente la méthode de base PSO, dans le contexte d'optimisation multimodale. De ce fait, plusieurs techniques ont été proposées dans la littérature. On peut citer : Nbest PSO (Brits et al, 2002) ou Niche PSO, SPSO (Li, 2004) qui améliore la technique proposée par (Kennedy, 2000), et les techniques

basées sur des opérations vectorielles (Schoeman et Engelbrecht, 2005). Une technique basée sur le nichage séquentiel et la technique d'essaims particulaires PSO (ASNPSO), est proposée dans (Zhang et al, 2006). Et enfin, la conception d'un nouveau modèle d'optimisation multimodale intitulé « Multipopulation practical swarms optimization » (MPSO) a été récemment proposée par Benameur (2010).

3.2.3 Les systèmes immunitaires artificiels

Ces systèmes ont été étudiés par la communauté des chercheurs en "vie artificielle" aussi bien pour leur intérêt scientifique intrinsèque, que pour l'application des concepts d'immunologie adaptés aux problèmes de calcul scientifique (Mitchellet Forrest, 1993). Ces systèmes ont été simulés en se basant sur deux populations différentes, qui interagissent, représentées par des chaînes de bits : antigènes et anticorps.

Le principe du modèle proposé par Mitchell et Forrest (1993) est le suivant : tous les individus possèdent initialement un fitness égale à zéro. Un antigène et un ensemble d'individus sont ensuite aléatoirement choisis. L'individu le plus similaire à l'antigène remportera la compétition et son fitness sera incrémenté (Smith et al, 1993). L'effet de cette technique est analogue à celui de la technique de partage dans le sens où les individus les plus similaires devraient souvent partager le coût fourni par les antigènes qui leur sont parfaitement similaires. Ce modèle s'adresse principalement aux problèmes pratiques tels que la détection des intrusions dans les réseaux (Hofmeyr et Forrest, 1999). Pour cela, une version adaptée à la technique de base a été proposée (De Castro et Timmis, 2002), dont le but est de résoudre le problème d'optimisation de fonctions multimodales.

4. Description de l'approche implémentée

Différentes métaheuristiques peuvent être pertinentes pour cette approche (e.g. Hajji et al, 2004 ; Chelouah et Siarry, 2000 ; et ModeFrontier, 2012). L'approche, que nous adoptons, est inspirée de l'analyse effectuée sur les techniques d'optimisation existantes dans la littérature. En effet, les algorithmes évolutionnistes sont souvent utilisés notamment pour résoudre les problèmes reliés aux systèmes de production (Pierreval et al, 2003). Du fait de leur succès dans l'exploration de l'espace de recherche et leur capacité à éviter d'être piégés par un optimum local, nous avons opté pour l'emploi des algorithmes évolutionnistes comme

processus d'optimisation, en couplage avec la simulation. Associé à une technique de nichage, l'algorithme évolutionniste multimodal permet de détecter et maintenir tous les éventuels optima (globaux et locaux) de l'espace de recherche.

La figure 2.3 présente le principe de l'approche couplant un algorithme évolutionniste multimodal, comme module d'optimisation, avec le module d'évaluation des performances c'est à dire le modèle de simulation.

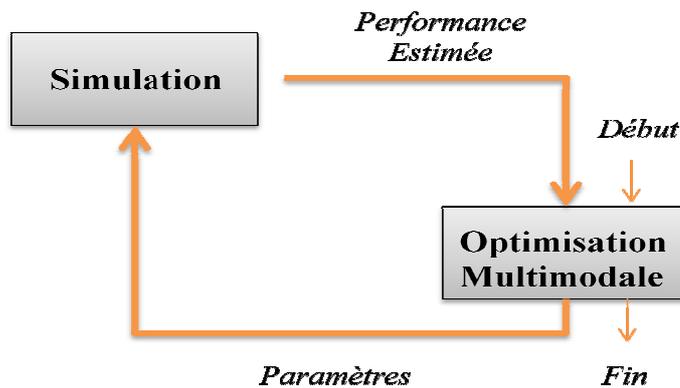


Fig.2. 3: Principe de l'optimisation multimodale via simulation

Supposons $X = [x_1, x_2, \dots, x_n]^T \in D$ le vecteur des variables de décision à optimiser, M le modèle de simulation stochastique utilisé pour évaluer la performance moyenne, notée $\hat{F}(X)$. Nous cherchons à déterminer un ensemble de solutions efficaces en termes de performance et assez contrastées (Baccouche et al, 2010), noté $Q \subset D$ tel que :

$$\forall X \in Q, \hat{F}(X) - z^* \leq \varepsilon, \quad (2.2)$$

avec $\varepsilon > 0$ un nombre réel représentant la perte de performance et z^* la performance de la solution optimale (ou proche de l'optimal).

Une fois ce processus conduit, en liaison avec les décideurs nous pouvons restreindre Q et sélectionner p solutions voisines, en termes de performance, à la solution X^* . Ainsi, nous obtenons l'ensemble $S = \{X^*, X_1, X_2, \dots, X_{p-1}\}$ avec lequel les décideurs du système peuvent fonder leur choix pour l'une ou l'autre des solutions.

4.1 Algorithme et implémentation

La décision sur l'approche que nous avons mise en œuvre repose sur les critères suivants :

- Etablir un processus de recherche rapide des optima,
- Adapter une technique de nichage présentant un taux de détection des sommets (*TDS*), un nombre total de sommets maintenus et un critère de distribution proportionnelle (*TDP*) satisfaisants (Sareni, 1999).

A partir de ces critères, nous avons choisi l'implémentation de l'approche multimodale « Crowding Clustering Genetic Algorithm » (Qing Lin et al, 2008) associant un algorithme évolutionniste à une technique de nichage de surpeuplement. Outre qu'elle soit des plus récentes, cette technique s'avère efficace dans la détection et le maintien des optima d'une fonction multimodale. La figure (2.4) représente la version originale de l'approche. Les auteurs ont mis en place différents moyens leur permettant la qualité, la quantité et la précision des résultats.

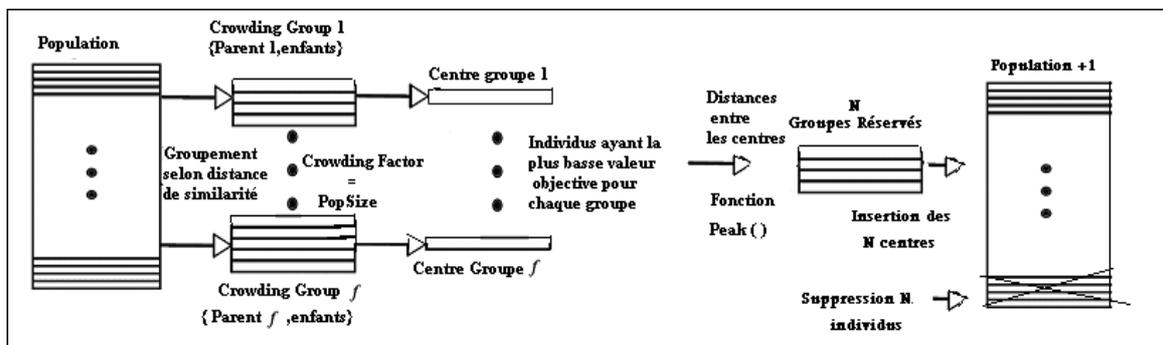


Fig.2. 4: Schéma général de l'approche « Crowding Clustering Genetic Algorithm »

L'approche CCGA a été initialement élaborée pour un codage réel. Nous avons adapté cette approche au cas de variables entières ou qualitatives.

Nous présentons et discutons l'adaptation de l'algorithme « Crowding Clustering Genetic Algorithm » (Qing Lin et al, 2008).

Algorithme 1

Définition de la taille de la population initiale « PopNum » et le critère de terminaison « MaxGen ».

Etape 1 : Initialisation de la population initiale de taille *PopNum*.

Etape 2 : Recombinaison de la population et génération de la population des enfants de taille *PopNum Enfants*.

Etape 3 : Groupement de la population : Pour chaque parent $P_j, j = 1, 2, \dots, PopNum$, construire *PopNum* clusters $\{P_j, CS_j\}$ au moyen du “standard crowding model” avec *CF* (crowding factor) = *PopNum*, selon une distance métrique $D()$. CS_j représente l’ensemble des enfants associé avec le parent P_j . Pour ce faire, regrouper chaque enfant $C_i, i = 1, 2, \dots, CF$ dans le cluster du parent P_j le plus proche.

Etape 4 : Sélection des centres et des radius des clusters : Pour chaque cluster $\{P_j, CS_j\}$ déterminer le centre CC_j du cluster. Pour les autres individus du cluster, calculer leurs distances de CC_j et sélectionner l’individu ayant la distance maximale distance comme radius du cluster, CR_j .

Etape 5 : Tri des clusters : Tri des clusters dans l’ordre croissant selon les fitness. Définir l’ensemble des *clusters réservés* $RC = \emptyset$. Chaque cluster i dans RC a un centre RCC_i , et un radius $RCCR_i$, calculés dans l’étape précédente. Pour chaque $j = 1, 2, \dots, PopNum$, comparer le j th cluster avec les autres clusters RCC_i dans RC , et if Pour chaque $i, D(CC_j, RCC_i) > RCCR_i$ ou $Peak(CC_j, RCC_i) = 1$, placer CC_j dans RC , et fixer le radius du cluster ainsi : $\min(CR_j, D(CC_j, RCC_i))$. La fonction $Peak()$ conditionne la détection des sommets selon la formule suivante :

$$Peak(CC_i, RCC_j) = \begin{cases} 1, & f\left(\frac{CC_i + RCC_j}{2}\right) > \frac{f(CC_i) + f(RCC_j)}{2} \\ 0, & f\left(\frac{CC_i + RCC_j}{2}\right) < \frac{f(CC_i) + f(RCC_j)}{2} \end{cases}$$

Etape 6 : Génération de la nouvelle génération : Soit NRC le nombre d’éléments dans RC . Générer $(PopNum - NRC)$ aléatoirement les nouveaux individus. Ces derniers avec les centres des clusters composent la nouvelle génération.

Etape 7 : Tester le critère de terminaison et s’arrêter ou aller à l’étape 2.

Les différentes étapes de l'algorithme d'optimisation implémenté sont décrites comme suit :

Etape 1 : Les individus parents de taille *PopNum*, sont générés lors de cette première étape. Les chromosomes des individus sont générés aléatoirement selon les domaines de variation que l'on définit pour chaque gène. Chaque individu est ainsi codé via un vecteur.

Etape 2 : Recombinaison des parents

La *sélection* des parents est un mécanisme qui fixe à partir d'une génération donnée, quels individus pourront se reproduire pour former la génération suivante. Cet opérateur oriente l'exploration des individus mais ne fait apparaître aucune configuration nouvelle. La reconnaissance d'autres points de l'espace est assurée par les opérateurs de *croisement* et de *mutation* génétiques. Ils garantissent la diversification des individus dans la population en assurant le brassage des matériaux génétiques au cours des générations.

On utilise un *croisement* classique procédant selon un processus aléatoire appliqué séquentiellement à des couples de parents pris au hasard dans la population. On détermine ensuite aléatoirement un site (un point) de croisement et on croise les chromosomes de chaque couple de parents choisi pour obtenir les chromosomes des deux enfants correspondants. Ce croisement consiste à échanger une partie des gènes des parents pour former les nouveaux individus de la population des enfants de taille *PopNum Enfants*.

L'opérateur de *mutation* permet de transformer au hasard le codage d'un individu afin d'apporter une certaine diversité dans la population et empêcher que celle-ci converge trop vite vers un seul type d'individu, incapable de sortir d'un minimum local. La mutation est réalisée en modifiant un gène d'un individu pris au hasard. L'amplitude de la modification peut elle même être déterminée aléatoirement ou correspondre à une valeur fixée. Cependant, l'utilisation de cet opérateur peut s'avérer secondaire dans certains algorithmes génétiques, du fait que le processus aléatoire établi par l'opérateur de croisement et les nouveaux individus ajoutés à l'*Etape 6*.

Etape 3 : Former les groupes : les clusters

Les parents après croisement peuvent être retirés de la population de reproducteurs (*croisement sans remplacement*) ou bien être gardés pour avoir une nouvelle chance de se reproduire (*croisement avec remplacement*) dans d'autres générations. Partant de ce deuxième principe nous regroupons chaque parent de la population initiale avec tous les individus qui lui sont rattachés dans la population des enfants. Le processus de regroupement est effectué au moyen de la technique de nichage implicite : le *surpeuplement standard*. Cette méthode de surpeuplement aboutit à la formation implicite de niches en restreignant les compétitions entre individus au sein de la population globale. Seuls des individus ayant des caractéristiques génétiques les plus proches possibles sont autorisés à lutter pour leur survie. Ainsi les groupes sont formés selon une distance phénotypique –distance métrique- entre le père et les enfants (distance euclidienne dans notre cas).

L'association du clustering au surpeuplement standard nous permet de remédier à la dérive génétique et les erreurs de remplacement dues au processus de sélection dans les méthodes de surpeuplement existantes. Nous utilisons un facteur de surpeuplement (CF) pour chaque cluster égal à la taille de la population ($CF = PopNum$).

Etape 4 : On sélectionne pour chaque groupe un centre, noté CC_i , déterminé suite à des compétitions entre les individus de chaque groupe selon les valeurs de leurs fonctions objectifs – leurs fitness – L'individu centre représente la meilleure performance du groupe. Le radius, noté CR_i , représente l'individu ayant la plus large distance avec le centre –la moins bonne performance du groupe-.

En effet, les compétitions entre chaque parent avec sa propre progéniture nous permet de déterminer la meilleure performance du groupe (individu centre) et nous permet d'explorer en parallèle les solutions locales situées dans des régions éloignées de l'espace.

Etape 5 : Les groupes sont triés selon la politique d'optimisation de la fonction objectif (minimisation ou maximisation).

La sélection de l'ensemble des groupes réservés, noté RC , est effectuée suite à des compétitions entre les groupes de la population. Cette étape nous permet d'obtenir les meilleures performances de la population. Le processus s'établit selon deux conditions :

- *Condition 1* : Pour chaque groupe à insérer, on calcule la distance, notée D , entre le centre CC_i du groupe i et les centres de tous les groupes réservés, notés RCC_j . Le

groupe est inséré si D est supérieure aux radius des groupes réservés, notés R_{CRj} , de l'ensemble RC . Cette condition vérifie la conformité de la répartition des groupes et l'unicité de chaque performance.

- *Condition 2* : $\text{Peak}(CC_i, RCC_j) = 1$, la fonction $\text{peak}(\)$ vérifie la qualité et la précision de la solution optimale détectée.

Nous vérifions ainsi l'unicité de chaque solution et la conformité de la répartition effectuée lors du groupement afin d'éviter les pièges des optimums locaux et la convergence des régions vers le même optimum (les fonctions $D(\)$ et $\text{Peak}(\)$).

Etape 6 : On compte le nombre de groupes dans l'ensemble RC , noté NRC , on soustrait ce nombre de la population initiale et on insère les centres des groupes réservés et les nouveaux individus en remplacement du processus de mutation.

Etape 7 : Tester le critère de terminaison de l'algorithme, MaxGen , sinon *Etape 2*.

4.2 Vérification et test de l'algorithme d'optimisation

L'algorithme d'optimisation multimodal a été développé en utilisant le langage de programmation C++. La taille de la population a été fixée à 30 et le nombre maximum de générations à 100. Ces valeurs ont été déterminées par une étude de la convergence de l'algorithme initial dans (Qing Lin et al, 2008).

Du fait du coût de l'expérimentation élevé par la simulation, nous effectuons les tests de l'algorithme multimodal sur deux fonctions multimodales de la littérature. L'évaluation des performances est faite par les deux fonctions standards (Qing Lin et al, 2008 ; Thomsen, 2004) :

- « Ackley Function »,
- « Six-Hump Camel Function ».

Expérimentation 1 : « Ackley Function »

La fonction « Ackley » est souvent utilisée dans la littérature pour évaluer les capacités des techniques de nichage pour trouver les optima (Mahfoudh, 1995 ; Harik , 1995 ; Thomsen, 2004 ; Qing Lin et al, 2008). Cette fonction est définie dans la littérature comme une fonction très bruitée du fait qu'elle peut atteindre plus que 40 optima globaux et locaux.

La fonction « Ackley » s'écrit selon l'équation (2.3).

$$\begin{aligned} \min \quad & f1(x, y) = 20 - 20 \exp\left(-0.2 \sqrt{\frac{(x^2 + y^2)}{2}}\right) - \exp\left(\frac{\cos(2\pi x) + \cos(2\pi y)}{2}\right) + e \\ \text{s.t} \quad & -30 \leq x, y \leq 30 \end{aligned} \quad (2.3)$$

Nous avons mis en œuvre l'algorithme d'optimisation multimodal implémenté pour cette fonction. Pour une minimisation de la fonction, l'algorithme identifie et maintient 38 optima (globaux et locaux). La figure 2.5 présente la représentation graphique du résultat trouvé.

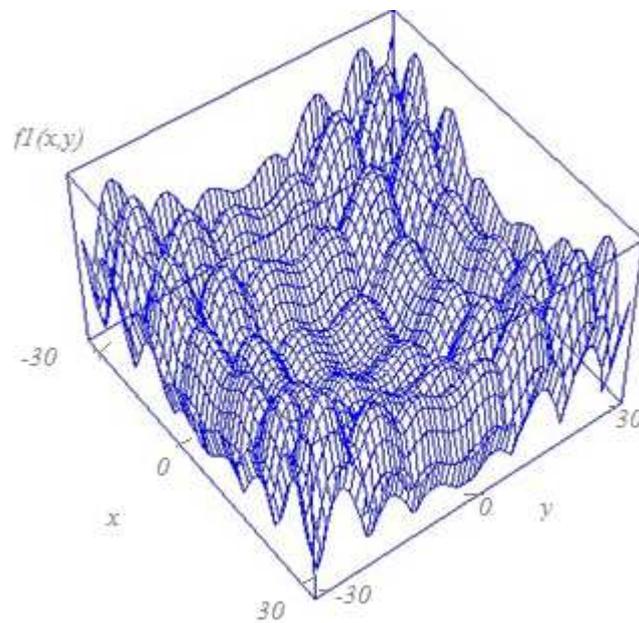


Fig.2. 5: Les optima détectés par $f1(x, y)$

Expérimentation 2 : « Six-Hump Camel Function »

La fonction « *Six-Hump Camel* » est reconnue comme étant difficile à résoudre et certaines techniques de nichage n'ont pas pu détecter ses optima (Thomsen, 2004 ; Qing Lin et al, 2008). La fonction *Six-Hump Camel Function* s'écrit comme suit :

$$\begin{aligned} \min \quad & f_2(x, y) = \left(4 - 2.1x^2 + \frac{x^4}{3} \right) x + xy + (-4 + 4y^2)y^2 \\ \text{s.t} \quad & -1.5 \leq x \leq 1.5, -1 \leq y \leq 1 \end{aligned} \quad (2.4)$$

Pour une minimisation de la fonction, l'algorithme identifie et maintient 9 optima globaux et locaux. Cette fonction est définie dans la littérature comme étant moins bruitée que la fonction « *Ackley* » et elle possède 6 optimums globaux et locaux (2 minimums globaux, 2 minimums locaux stables et deux minimums locaux instables). Dans notre expérimentation nous dépassons ce nombre, en effet nous obtenons 1 minimum global, 4 minimums locaux stables et les solutions restantes sont instables au fil des générations. Ce résultat pourrait être expliqué par les conditions mises en place lors du regroupement des individus dans les niches ou lors des tests mis en place pour conditionner la détection des sommets (cf. *Etape 5* figure 2.4). La figure 2.6 présente la représentation graphique du résultat trouvé.

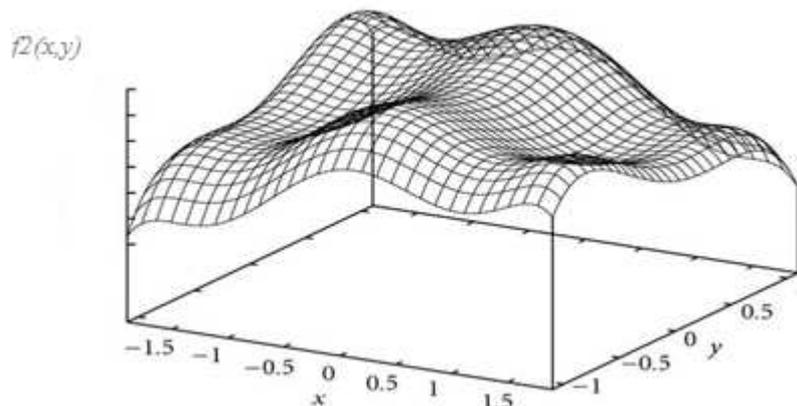


Fig.2. 6: Les optima détectés par $f_2(x, y)$

Nous déduisons que l'utilisation d'autres conditions pour la détection des sommets pourrait améliorer la qualité des résultats de l'optimisation en adoptant par exemple une méthode de graduation (Qing Lin et al, 2008 ; Thomsen, 2004).

Les résultats obtenus par les tests de l'algorithme d'optimisation implémenté sur les fonctions mathématiques sont très similaires à ceux trouvés par l'algorithme initial dans (Qing Lin et al, 2008). Compte tenu de ces résultats, nous connectons l'algorithme implémenté avec le module d'évaluation des performances dans la section suivante.

4.3 Connexion avec la simulation

Nous effectuons le couplage du module d'optimisation multimodale et du module d'évaluation des performances. Nous utilisons pour le module de simulation le logiciel de simulation de flux *ARENA* (www.arenasimulation.com). Ce logiciel permet d'évaluer la performance d'une solution de conception en intégrant toutes les contraintes d'un système. La communication entre les deux modules s'effectue par un échange dynamique des données au niveau des étapes 2 et 5 de l'algorithme (cf. figure 2.4). Pour chaque performance à estimer, le module d'optimisation envoie le vecteur des variables de décision – le chromosome d'un individu – et le module de simulation calcule et renvoie la performance – fitness – correspondante.

Nous présenterons l'application de notre approche d'optimisation multimodale via simulation dans le chapitre 5.

5. Conclusion

Nous avons donc proposé une nouvelle approche qui permet d'introduire de la flexibilité dans une étude d'optimisation via simulation dans le sens où elle peut fournir un ensemble de solutions de conception performantes d'un système. Cette approche est basée sur un module d'optimisation évolutionniste couplé à un module de simulation. Ces deux modules travaillent en interaction afin d'optimiser via simulation le système.

L'originalité de l'approche proposée par rapport aux approches existantes est qu'elle peut fournir plusieurs alternatives de conception contrastées, à la place d'une seule. Ainsi, elle

permet d'acquérir pour les décideurs une souplesse dans le choix de la solution à implanter. Elle va nous permettre, par exemple, de proposer des solutions alternatives performantes qui peuvent être plus facilement implantables que la meilleure solution trouvée. En effet, les coûts associés à la mise en place d'une solution de conception d'un système, même si elle est optimale, peuvent être rédhibitoires alors qu'une solution un peu moins performante peut être facile et peu coûteuse à implanter. Cette approche est illustrée dans le chapitre 5.

Dans le chapitre suivant, nous allons voir comment exploiter cette flexibilité pour aborder la prise en compte des préférences individuelles d'une équipe décisionnelle.

Chapitre III

**DÉTERMINATION DE SOLUTIONS DANS UNE PRISE DE
DÉCISION COLLABORATIVE**

Chapitre III.

**DÉTERMINATION DE SOLUTIONS DANS UNE PRISE DE DÉCISION
COLLABORATIVE**

1. Introduction	53
2. Principe général.....	54
3. Approche proposée.....	56
3.1 Première phase	57
3.2 Deuxième phase	57
3.3 Troisième phase	57
4. Principes de AHP	58
5. Algorithme utilisé.....	61
6. Conclusion.....	62

1. Introduction

Lors de la conception et l'organisation d'un système, des personnes ayant des responsabilités différentes peuvent participer au processus de décision de la solution à implanter. Ces différentes personnes constituent une équipe de décideurs. Chaque décideur possède des préférences concernant la conception du système orientées en fonction de ses responsabilités et son rôle dans l'étude (Kaci, 2011). Néanmoins, ces préférences qui vont influencer leurs choix ne sont pas toutes connues à l'avance ou peuvent être implicites ou qualitatives, Etc. Elles ne peuvent donc pas être incluses dans la fonction objectif ni dans le modèle de simulation. Mais, si elles sont ignorées la solution de conception optimale peut s'avérer inadaptée. En effet, cette solution optimale peut parfois engendrer des difficultés techniques ou même s'avérer coûteuse à implanter.

Intégrer les préférences individuelles des décideurs dans l'optimisation via simulation d'un système est un problème important et peu abordé dans la littérature. En effet, dans la revue de la littérature, nous avons constaté que la plupart des approches d'optimisation via simulation classiques considèrent un contexte mono-décideur et qu'une solution optimale présentant la meilleure performance du système sera implicitement préférée (Rosen et al, 2007). Cependant, des méthodes d'optimisation via simulation interactives ont été publiées comme par exemple (Boyle et Shin, 1996). Toutefois, leur intégration dans un contexte de simulation stochastique s'avère très coûteux (Rosen et al, 2007). Quelques approches alternatives ont été publiées dans la littérature (Baesler et Sepulveda, 2000 ; Medaglia et al, 2002 ; Rosen et al, 2007). Néanmoins, elles ne prennent pas en compte les aspects collaboratifs (groupe de plusieurs décideurs) et elles sont basées sur l'hypothèse que les préférences des décideurs peuvent être identifiables et quantifiables, à l'avance, de manière à les grouper et les formaliser dans un module en association avec l'optimisation.

En pratique, les décideurs peuvent avoir besoin de savoir quelles sont les solutions de conception possibles, afin d'être en mesure d'exprimer leurs préférences. De plus, lorsque les solutions doivent être analysées par plusieurs personnes impliquées dans le processus de décision, nous devons déterminer comment inclure les préférences individuelles de chacun, de manière à sélectionner une solution «collectivement acceptable» c'est-à-dire qui peut satisfaire les différents membres de l'équipe de décision. La prise en compte des aspects collaboratifs

dans la simulation a retenu l'attention des chercheurs (voir par exemple Wang et al, 2010; Xu et al, 2012), mais ils n'ont pas été abordé à notre connaissance dans les études d'optimisation via simulation.

Nous proposons alors, dans ce chapitre, d'aborder ce problème. Nous présentons d'abord le principe général de l'approche proposée puis l'algorithme mis en œuvre.

2. Principe général

La question fondamentale concerne la coopération entre le processus d'optimisation via simulation et les membres de l'équipe des décideurs. Elle s'énonce comme suit :

« *Comment inclure les préférences des décideurs dans le processus d'optimisation via simulation ?* »

Pour intégrer les préférences des décideurs, trois processus de résolution peuvent être distingués dans la littérature (Collette et Siarry, 2002 ; Talbi, 2009):

- La méthode de préférence *a priori* où le décideur est supposé connaître ses préférences et choisir le compromis à réaliser entre elles avant de lancer l'optimisation via simulation.
- La méthode de préférence *a posteriori* où le décideur n'a pas à choisir de faire un compromis. L'étude d'optimisation via simulation calcule toutes les solutions efficaces et le décideur peut ainsi les comparer et en choisir une.
- Interactive où il ya une coopération progressive entre le décideur et le processus d'optimisation via simulation. A partir des connaissances acquises pendant l'optimisation via simulation, le décideur définit des préférences qui sont prises en compte dans l'étude d'optimisation via simulation. Ce processus est réitéré pendant plusieurs étapes.

Lorsque le modèle de simulation est stochastique un nombre d'évaluations important doit être établi pour interagir avec les connaissances des décideurs. Pour réduire le nombre d'évaluations par la simulation, nous proposons d'adopter une méthode de préférence *a*

posteriori. Pour mettre en œuvre cette méthode, nous proposons d'adopter un processus d'optimisation via simulation permettant de délivrer, non pas une solution de conception unique du système, mais un choix de plusieurs solutions.

Pour obtenir un choix de solutions, nous suggérons d'exploiter l'approche basée sur l'optimisation multimodale utilisée au chapitre précédent. Ainsi, nous pourrions obtenir un ensemble de solutions efficaces, en termes de performance, et assez différentes les unes des autres pour garantir la diversité. Une solution efficace signifie que sa performance est en dessus d'un seuil fixé en liaison avec les décideurs. Ce seuil représente le maximum de perte, en termes de performances, que les décideurs peuvent tolérer pour privilégier d'autres considérations. En effet, dans certains cas, les décideurs peuvent accepter une solution avec une performance légèrement inférieure à celle qui présente la meilleure performance ; pour autant que cette solution offre d'autres avantages (Durieux et Pierreval, 2003). Nous citons, par exemple, les difficultés de mise en œuvre de la solution, qui sont, généralement, traitées subjectivement dans une étude par optimisation via simulation. En adoptant cette approche, les décideurs peuvent établir le choix d'une solution à partir de cet ensemble de solutions efficaces du système suivant leurs préférences individuelles.

Néanmoins, lorsqu'il ya plusieurs membres dans l'équipe de décision, ces derniers analysent les solutions fournies et les confrontent de sorte à mettre en évidence les écarts entre elles suivant leurs préférences individuelles. Chaque décideur oriente son choix selon des axes bien définis comme par exemple, la facilité de déploiement de la solution, sa fiabilité, la disponibilité des ressources, ... De ce fait, on aura des solutions de conception qui peuvent être jugées d'une importance différente par les décideurs (Kjellberg et Sohlenius, 1993) comme par exemple le cas où une solution choisie par un décideur peut ne pas être acceptable par un autre décideur. Nous devons donc intégrer la dimension collaborative de notre problématique et déterminer une solution «collectivement acceptable» c'est-à-dire par les différents membres de l'équipe de décision.

Pour cela, nous suggérons d'utiliser la théorie du choix social et intégrer une méthode d'aide à la décision multicritère. Par définition, Vincke (1989), « L'aide multicritère à la décision vise, comme son nom l'indique, à fournir à un décideur des outils lui permettant de progresser dans la résolution d'un problème de décision où plusieurs points de vue, souvent contradictoires, doivent être pris en compte ». En d'autres termes, le recours à cette famille d'approches vise à concilier les différents choix des décideurs au regard des solutions efficaces du système.

Pour mettre en œuvre les principes cités ci-dessus, nous présentons dans la section suivante une nouvelle approche, utilisant le principe des méthodes de préférence *a posteriori*, qui permet d'intégrer les aspects collectifs et déterminer des solutions dans une prise de décision collaborative dans une étude d'optimisation via simulation.

3. Approche proposée

Dans cette section, nous présentons les différentes méthodes utilisées par notre approche (Baccouche et al, 2011). Elle repose, dans un premier temps, sur un processus d'optimisation multimodale via simulation pour déterminer un choix de solutions possibles d'un système et identifier en liaison avec les décideurs les solutions ayant des performances efficaces. Dans un second temps, nous suggérons d'associer une procédure d'agrégation des préférences permettant de collecter et de modéliser les choix des décideurs selon leurs préférences individuelles et de les synthétiser pour déterminer une solution collectivement acceptable. Le schéma général de cette approche est présenté dans la figure 3.1.

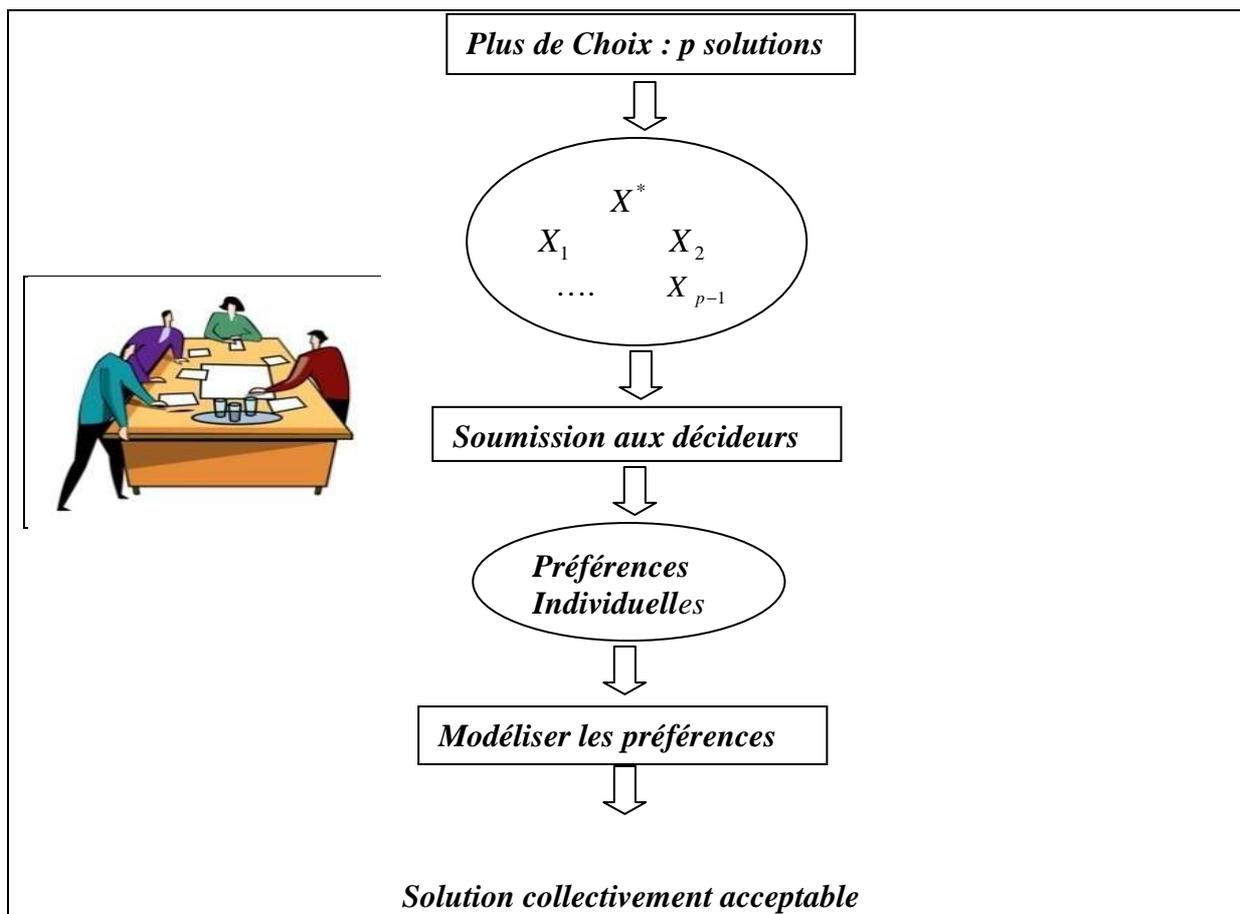


Fig.3. 1 : Schéma général de l'approche proposée

3.1 Première phase

Pour cette première phase, nous devons obtenir la liste des solutions de conception possibles ou envisageables à fournir durant le processus de décision. Chaque solution candidate est dite alternative de conception.

Nous suggérons d'utiliser l'approche d'optimisation multimodale en connexion avec la simulation proposée dans le chapitre 2. Ensuite, nous devons déterminer, en liaison avec les décideurs, les p solutions efficaces sélectionnées suivant le seuil maximum de dégradation de performances α qu'ils tolèrent. Nous obtenons alors la liste des solutions possibles ou envisageables. Cette liste est représentée par l'ensemble : $S = \{X^*, X_1, X_2, \dots, X_{p-1}\}$.

3.2 Deuxième phase

Dans cette deuxième phase, les membres de l'équipe des décideurs doivent examiner les solutions envisageables selon leurs préférences individuelles telles que les coûts d'exécution, la facilité de mise en œuvre, les difficultés techniques, Etc. Ainsi, chaque décideur doit nous fournir son classement des solutions. Du fait que les choix des décideurs sont souvent conflictuels, nous devons établir un modèle global de ces choix et les synthétiser afin d'aboutir à une adéquation convenable.

3.3 Troisième phase

L'objectif de la troisième phase est de déterminer laquelle des p solutions pourrait être collectivement acceptable en prenant en compte le choix de chacun des membres de l'équipe des décideurs, collecté dans la phase précédente.

Les trois phases décrites ci-dessus constituent l'approche que nous proposons. Etant le choix de solutions obtenu lors de la première phase, nous suggérons d'utiliser une méthode d'agrégation des préférences très populaire dans la littérature nommée « the Analytic Hierarchy Process » (AHP). Cette méthode nous permettra d'obtenir une classification collective des solutions de conception envisageables du système. Son principe est présenté dans la section suivante.

4. Principes de AHP

Développée par Saaty en 1980, la méthode AHP a été souvent utilisée dans les 20 dernières années pour modéliser les processus de prise de décisions subjectives sur la base de plusieurs attributs. La maturité de cette méthode a été confirmée à travers plusieurs études. Vaidya et Kumar (2006) ont constaté que 150 articles dans la littérature traitent l'étude de la méthode AHP associée à des applications générales. Dans ses récentes recherches, Ho (2008) a observé que de nombreux outils peuvent être associés avec la méthode AHP, tels que la programmation mathématique, les métaheuristiques, QFD, SWOT analysis, Etc.

Cette méthode propose d'évaluer tous les paramètres d'un problème multicritère par le biais d'une série de comparaisons binaires (paire à paire). Il est donc plus facile pour un décideur d'effectuer des comparaisons binaires que prendre en compte l'ensemble des paramètres du problème. Elle constitue un outil puissant et flexible de prise de décision pour des problèmes multicritères complexes dans lesquels des aspects quantitatifs et qualitatifs doivent être incorporés (Harker, 1989).

D'une manière générale, la méthode AHP aide les décideurs à structurer les composantes importantes d'un problème. Elle permet ensuite de synthétiser les résultats en ramenant les décisions complexes à une série de simples comparaisons et de rangements.

Le processus de la méthode AHP s'énonce comme suit (Harker, 1989) :

- (i) Comparaison par paire des éléments du problème étudié
- (ii) Estimation du vecteur de priorité des solutions pour chaque décideur
- (iii) Agrégation des vecteurs de priorités et calcul des scores de préférence collectifs des solutions

(i) Comparaison par paire des éléments du problème étudié.

Pour déterminer les matrices de comparaison par paire, deux techniques peuvent être utilisées : soit par un vote par consensus soit par agrégation des jugements individuels. Lors de l'utilisation du vote par consensus, les décideurs se mettent d'accord sur une valeur unique pour chaque comparaison par paire. Comme ce processus est long et fastidieux, souvent la technique de combinaison des jugements individuels est utilisée (Harker, 1989).

L'agrégation des jugements nécessite deux étapes :

- *Collecte des différents jugements des décideurs* exprimés par rapport aux solutions. Dans la figure 3.2 chaque décideur évalue les solutions par paire et exprime un jugement relatif à ses préférences. Dans la première colonne il exprime si la solution i est plus importante que la solution j ou non. Dans la deuxième colonne, il affecte une valeur r_{ij} compte tenu de son jugement suivant l'échelle d'évaluation de Saaty (2009) (cf. le tableau 3.1).
- *Et construction des matrices de comparaison par paire* relatives aux jugements des solutions par les décideurs, dites aussi « matrices réciproques » (voir figure 3.3).

Solution		Plus Importante	Degrès d'importance (1-9)
i	j		
X_1	X_2	Solution i / Solution j	r_{ij}
	X_3		
	X_4		
	X_5		

Fig.3. 2: Evaluation des solutions par paire par le décideur

Solution	$j = 1$...	$j = p$
$i = 1$	Si $i=j$, $a_{ij} = 1$		r_{ij} : Valeur attribuée lors du jugement de la solution i par rapport à la solution j	
		1		
			1	
	$1/r_{ij}$: Valeur réciproque.		1	
$i = p$				1

Fig.3. 3. Matrice carrée de comparaison par paire : $A_{p \times p}$

<i>Degrés d'importance</i>	<i>Définitions</i>	<i>Explications</i>
1	Importance égale.	Les deux solutions ont une importance égale pour le décideur.
3	Une solution est un peu plus Importante.	L'expérience et le jugement favorisent légèrement une solution par rapport à une autre
5	Une solution est plus importante que l'autre.	L'expérience et le jugement sont très favorables pour une solution par rapport à une autre
7	Une solution est beaucoup plus importante que l'autre.	L'expérience et le jugement sont fortement favorables pour une solution par rapport à une autre. Son importance est démontrée dans la pratique.
9	Une solution est absolument plus importante que l'autre.	Les preuves favorisant une solution par rapport à un autre sont aussi convaincantes que possible.
2, 4, 6, 8	Valeurs intermédiaires	Lorsqu'un compromis est nécessaire

Tab 3. 1 Echelle d'évaluations d'après (Saaty, 2009)

Après obtention des jugements individuels, on vérifie la cohérence de l'ensemble des jugements dans les matrices. Si les jugements sont calculés à partir de données exactes, ils doivent vérifier la relation de transitivité (Collette and Siarry, 2002). Dans le cas, où les matrices sont construites selon des jugements humains, on doit vérifier si les valeurs de l'échelle (1-9), attribuées par le décideur, sont cohérentes ou non. Pour effectuer ces tests de cohérence, plusieurs méthodes peuvent être utilisées notamment « the Geometric Mean Method (GMM) » ou « the Weighted Arithmetic Mean Method (WAMM) » (Harker, 1989). En final, ce test présente l'avantage de corriger les jugements affectés (non cohérents). Lorsqu'une importance égale est attribuée à tous les membres d'une équipe de décideurs, la méthode « the Geometric Mean Method (GMM) » est considérée la plus appropriée dans la littérature pour construire un choix de groupe à partir de choix individuels (Saaty, 2009). Nous utilisons donc cette méthode dans les étapes suivantes.

(ii) Estimation du vecteur de priorité des solutions pour chaque décideur

Chaque matrice de comparaison par paire relative à un décideur, noté a , permet de déterminer un vecteur de priorité, noté F^a , contenant les scores de préférence des solutions pour ce décideur.

(iii) Agrégation des vecteurs de priorités et calcul des scores de préférence collectifs des solutions

Dans cette dernière étape, on calcule le score de préférence collectif pour chaque solution i , noté R_i . Ensuite, il faut établir un rangement des solutions selon les scores obtenus par ordre croissant. Le plus grand score correspond à la solution qui présente la meilleure adéquation entre les différents choix des décideurs. En cas de non unicité de cette solution, le décideur aura la liberté de choisir celle qui lui convient.

En résumé, la comparaison par paires permet d'obtenir l'importance de chaque solution pour chaque décideur. Le vecteur de priorité (vecteur d'importance) exprime quant à lui les scores de préférence des solutions pour chaque décideur. Enfin, les scores de préférence collectifs des solutions nous permettent d'obtenir leur classement.

5. Algorithme utilisé

L'algorithme implémenté repose sur la « Geometric Mean Method (GMM) (Olson et al, 1995).

Algorithme 2

Soit p le nombre des solutions déterminées dans la première phase de notre approche et d le nombre des membres dans l'équipe des décideurs.

On utilise l'échelle d'évaluations de 1 à 9 suggérée par (Saaty, 2009) pour modéliser les degrés d'importances dans les matrices de comparaisons.

Etape 1 : Pour tout décideur $a \in \{1, 2, \dots, d\}$, construire les matrices de comparaisons $A^a = \{r_{ij}^a / i \in \{1, 2, \dots, p\}, j \in \{1, 2, \dots, p\}\}$, où $\{r_{ij}^a\}$ est le jugement du décideur a pour comparer la solution i à la solution j . Si i est préféré à j , alors r_{ij}^a représente la valeur du jugement ; Sinon si j est préféré à i , alors r_{ij}^a représente la valeur réciproque.

Etape 2 : Estimer le vecteur de priorité F^a pour chaque décideur $a \in \{1, 2, \dots, d\}$. Le vecteur de priorité est calculé par la méthode GMM suivant la formule suivante :

$$F_i^a = \eta \prod_{j=1}^p (r_{ij}^a)^{1/p}, \text{ où } \eta \text{ est une constante de normalisation dont la valeur est calculée}$$

$$\text{de la manière suivante : } \sum_{i=1}^p F_i^a = 1.$$

Etape 3 : Classer la solution i selon son score de préférence R_i . Le score de préférence est calculé par la méthode GMM suivant la formule suivante : $R_i = \prod_{a=1}^d (F_i^a)^{1/d}$.

La mise en œuvre de l'algorithme implémenté nous permettra de modéliser les préférences individuelles des décideurs exprimées par rapport aux solutions alternatives du système et de les synthétiser pour déterminer celle(s) qui est collectivement acceptable(s). Nous présenterons l'application de cet algorithme dans le chapitre 5.

6. Conclusion

Dans ce chapitre, nous avons abordé les études d'optimisation via simulation dans un contexte de prise de décision collaborative par un groupe de décideurs.

Dans notre revue de la littérature, nous avons remarqué que la plupart des approches considèrent un contexte où il n'y a qu'un seul décideur et que la solution ayant la meilleure performance du système est supposée implicitement acceptable. Or, nous avons vu que dans certains cas des personnes ayant des responsabilités différentes peuvent participer au processus de décision de la solution à implanter. De plus, chaque décideur possède des

préférences, concernant la conception du système, orientées en fonction de ses responsabilités et son rôle dans l'étude.

Nous avons donc proposé d'exploiter d'abord la flexibilité décisionnelle obtenue par l'approche d'optimisation multimodale via simulation présentée au chapitre précédent de sorte à fournir plusieurs solutions à discuter. En effet, les décideurs peuvent être prêts à accepter une solution moins performante que la solution ayant la meilleure performance à condition que celle-ci présente un intérêt satisfaisant. Nous avons pu obtenir alors les solutions efficaces, en termes de performance, envisageables pour la conception du système. Ensuite, nous avons utilisé une procédure d'agrégation des préférences basée sur la GMM qui nous a permis de collecter les préférences individuelles des décideurs par rapport aux solutions de conceptions fournies et de les synthétiser pour déterminer celle qui est collectivement acceptable.

Cependant, d'autres procédures d'agrégation des préférences peuvent être utilisées avec la même méthodologie. Nous pouvons notamment choisir des méthodes permettant une démarche plus interactive.

Dans le chapitre suivant, nous proposons une approche qui permet de prendre en compte l'incertain en optimisation via simulation.

Chapitre IV

PROPOSITION D'UNE APPROCHE METHODOLOGIQUE POUR LA PRISE EN COMPTE DE L'INCERTAIN EN OPTIMISATION VIA SIMULATION

Chapitre IV.

PROPOSITION D'UNE APPROCHE METHODOLOGIQUE POUR LA PRISE EN COMPTE DE L'INCERTAIN EN OPTIMISATION VIA SIMULATION

1. Introduction	66
2. Principes Généraux	66
3. Approche proposée.....	71
3.1 Première phase : Optimisation via simulation sur l'environnement attendu	71
3.2 Deuxième phase : Simulation en considérant d'autres environnements	72
3.3 Troisième phase : Comparaison des solutions prometteuses	74
4. Conclusion.....	76

1. Introduction

Dans ce chapitre, nous proposons de fournir des solutions robustes d'un système tout en préservant l'intérêt de l'emploi des métaheuristiques en association avec la simulation qui nous permet d'obtenir des évaluations de performance réalistes prenant en compte les phénomènes aléatoires dans le modèle.

Dans notre étude bibliographique, nous avons constaté que la prise en compte de l'incertitude est peu abordée dans un contexte d'optimisation via simulation. De plus, les travaux utilisant des métaheuristiques nécessitent souvent un temps de calcul très élevé. En effet, l'emploi d'un algorithme d'optimisation évolutionniste implique un grand nombre de solutions à évaluer par simulation. Ajouter à ce nombre les évaluations nécessaires pour l'étude de la robustesse, telle l'approche proposée par Al Aomar (2006), augmente encore plus les coûts de calcul.

Pour cela, nous présentons une approche originale suivant une méthodologie en trois phases permettant de réduire les coûts de calcul.

2. Principes Généraux

Lorsqu'une étude par optimisation via simulation est réalisée, nous obtenons le meilleur vecteur des variables de décision X^* (par exemple un nombre d'opérateurs = 3 ; un nombre de machine = 2 ; taille de stockage = 15 ; etc.) ainsi que la meilleure performance relative $z^* = \hat{F}(X^*)$ (le temps de passage des pièces dans l'atelier ; le taux d'utilisation de l'équipement ou du personnel, ... etc.) selon un environnement donné (par exemple, un certain taux de panne ; un taux de non qualité donné ; une certaine commande, Etc.).

Nous notons les facteurs d'environnement $\phi_m / m = 1..e$, avec e le nombre de facteurs d'environnements. En général, chaque facteur d'environnement est défini par son domaine de variation (ou son ensemble de définition), noté C_m , par exemple le taux de pannes = 10. Dans les plans d'expériences (Kleijnen, 2008), on associe plusieurs niveaux pour chaque facteur (par exemple : $\phi_1^1 = 10$: le niveau de panne le plus bas ; ϕ_1^2 : le niveau de panne moyen ; ϕ_1^3 :

le niveau de panne le plus haut). Un environnement ξ sera alors représenté par un vecteur de dimension e de facteurs d'environnements : $\xi = (\phi_1^v, \phi_2^v, \dots, \phi_e^v)$. Nous notons la performance moyenne d'une solution X sur un environnement ξ : $\hat{F}(X)_{\xi}$.

Cet environnement représente les conditions opératoires mises en place dans le modèle de simulation et qui peuvent être sujet à des changements. Cependant, la meilleure performance obtenue z^* sur cet environnement peut être fortement détériorée sur un autre environnement. C'est pourquoi, nous devons prendre en compte la présence de plusieurs environnements dans une étude par optimisation via simulation et déterminer des solutions qui restent performantes malgré les différents environnements pris en compte, dites solutions robustes.

Dans certains cas, un environnement peut se distinguer des autres (Pierreval et Durieux, 2007). En effet, les décideurs du système peuvent posséder une expertise du domaine (l'expérience du passé, prévisions, des systèmes similaires, ..., etc.) et de ce fait, ils peuvent avoir une idée sur les conditions opératoires attendues du système. Par exemple, dans un atelier d'assemblage :

- le département de production pense qu'un taux de 5% semble un pourcentage raisonnable pour les pièces défectueuses,
- le département commercial prévoit une moyenne de 50 commandes par jour, Etc.

Par définition, l'environnement attendu est, aux yeux des décideurs, le plus représentatif des conditions dans lesquelles le système réel évoluera. Il spécifie les conditions environnementales attendues par les décideurs du système dans le modèle de simulation. En accord avec Pierreval et Durieux (2007), nous adoptons le principe de distinction entre les environnements et nous notons ξ_{EA} l'environnement attendu.

Des scénarios multiples peuvent varier de l'environnement attendu. Nous prenons en compte un ensemble de q autres environnements, notés $\{\xi_k; k = 1, \dots, q\}$ et chaque solution X sera évaluée dans le contexte de chaque environnement.

Néanmoins, dans notre revue, nous avons constaté que les approches exploitant des métaheuristiques et utilisant la modélisation de l'incertitude via des environnements (chapitre

I: paragraphe 5), nécessitent un temps de calcul très important. Par exemple, en couplant un module de robustesse à un algorithme génétique classique, Al Aomar (2006) a pu étudier la variabilité de chaque mesure de performance selon plusieurs environnements mais en utilisant un grand nombre d'évaluations par simulation. Le nombre élevé d'évaluations est dû :

- Au nombre de solutions à prendre en compte,
- au nombre d'environnements,
- et au nombre de réplifications pour estimer la mesure de robustesse.

Nous considérons les notations suivantes pour désigner les paramètres utilisés dans l'algorithme génétique employé par Al Aomar (2006). Soient :

- t_{pop} : la taille de la population,
- N : le nombre de générations,
- P_1 : la probabilité de croisement
- et P_2 : la probabilité de mutation.

Nous désignons r , le nombre de réplifications menés pour prendre en compte l'aspect stochastique du modèle de simulation et enfin, N_{calls} le nombre d'appels au modèle de simulation.

Sans la prise en compte des environnements, le nombre d'appels au modèle de simulation sera calculé :

$$E(N_{calls}) = N * r * t_{pop} * (P_1 + P_2 - P_1 * P_2) \quad (4.1)$$

En supposant q le nombre d'environnements sélectionnés pour l'étude. Le nombre d'appels au modèle de simulation devient alors :

$$E(N_{calls}) = N * r * t_{pop} * (P_1 + P_2 - P_1 * P_2) * q. \quad (4.2)$$

Nous appliquons ce raisonnement sur un exemple simple pour mieux illustrer le principe. Considérons : $t_{pop} = 50$; $N = 100$; $P_1 = 0.4$ et $P_2 = 0.3$. Nous aurons une espérance de 87000

appels au module de simulation. Supposons que nous ayons défini 4 facteurs d'environnements et deux niveaux pour chaque facteur (bas/haut). Le nombre d'environnements q à prendre en compte dans l'étude sera 2^4 environnements (avec un plan factoriel complet). En supposant en plus, que la performance est stochastique et que r est égale à 30, l'espérance du nombre d'appels total au module de simulation sera alors 1 382 000 appels.

Dans ce travail, nous suggérons aussi l'utilisation des métaheuristiques pour optimiser les solutions en fonction de la performance et de la présence de plusieurs environnements tout en ayant un nombre d'évaluations par simulation à bas coût.

Pour cela, il peut être intéressant de privilégier une solution moins performante que la solution optimale (ou proche de l'optimal) X^* sur l'environnement attendu mais qui, en revanche, serait plus performante que celle-ci sur les autres environnements (Pierreval et Durieux, 2007). Nous adoptons ce raisonnement et nous proposons de déterminer en une seule étude par optimisation via simulation sur l'environnement attendu un ensemble de solutions performantes, à la place d'une seule telle dans l'approche proposée par Durieux (2004), dites solutions prometteuses. Une solution prometteuse est définie comme étant une solution présentant un niveau de performance acceptable par les décideurs du système sur l'environnement attendu. Ainsi, par exemple, sur la figure 4.1 les solutions Y et X^* sont considérées prometteuses.

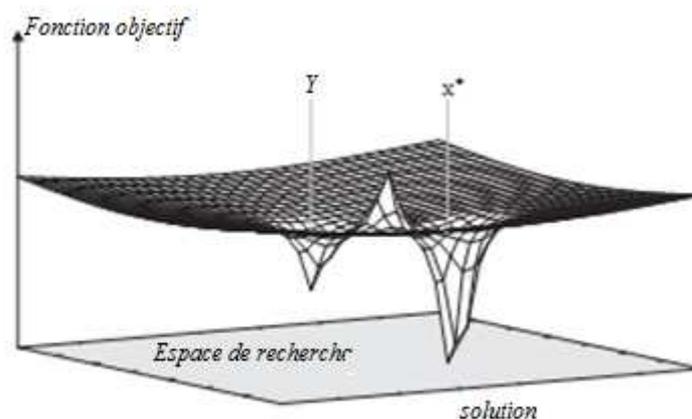


Fig 4. 1: Principe de solution prometteuse

Plus formellement, nous appelons S l'ensemble des p solutions prometteuses trouvées par l'étude d'optimisation via simulation sur l'environnement attendu ξ_{EA} . Nous notons $\hat{F}(X^*)_{/\xi_{EA}}$ la performance moyenne de la meilleure solution X^* et $\hat{F}(X_t)_{/\xi_{EA}}$ ¹ la performance moyenne d'une solution prometteuse $X_t \in S$ autre que X^* . Ensuite, nous proposons d'évaluer toutes les solutions appartenant à l'ensemble S sur les différents environnements définis pour l'étude. En adoptant ce principe, le nombre d'appels au modèle de simulation devient alors :

$$E(N_{calls}) = q * p * r \quad (4.3)$$

Par analogie avec l'exemple numérique et en supposant que l'étude par optimisation via simulation a pu nous fournir 10 solutions prometteuses sur l'environnement attendu, nous aurons seulement 7200 évaluations à conduire. Ainsi, nous pourrions considérablement réduire le coût de calcul par rapport à l'approche proposée par (Al Aomar, 2006) en limitant le nombre d'appels au modèle de simulation uniquement aux meilleures performances du système.

Pour comparer les performances des solutions prometteuses selon les environnements pris en compte et sélectionner celles qui s'avèrent robustes, différentes métriques peuvent être utilisées. Nous citons par exemple :

- Les mesures proposées par Taguchi (ratio S/N ou fonction perte),
- Les courbes de référence (Pierreval et Durieux, 2002),
- L'analyse du risque (Gaury, 2000 ; Angün, 2011),
- L'optimalité de Pareto (Dellino et al, 2010), Etc.

La figure 4.2 présente les principales étapes de la méthodologie proposée (Pierreval et Baccouche, 2012).

¹ *Remarque* : Pour des raisons de simplicité, nous n'avons pas symbolisé les indices relatifs aux solutions et aux environnements dans les chapitres précédents.

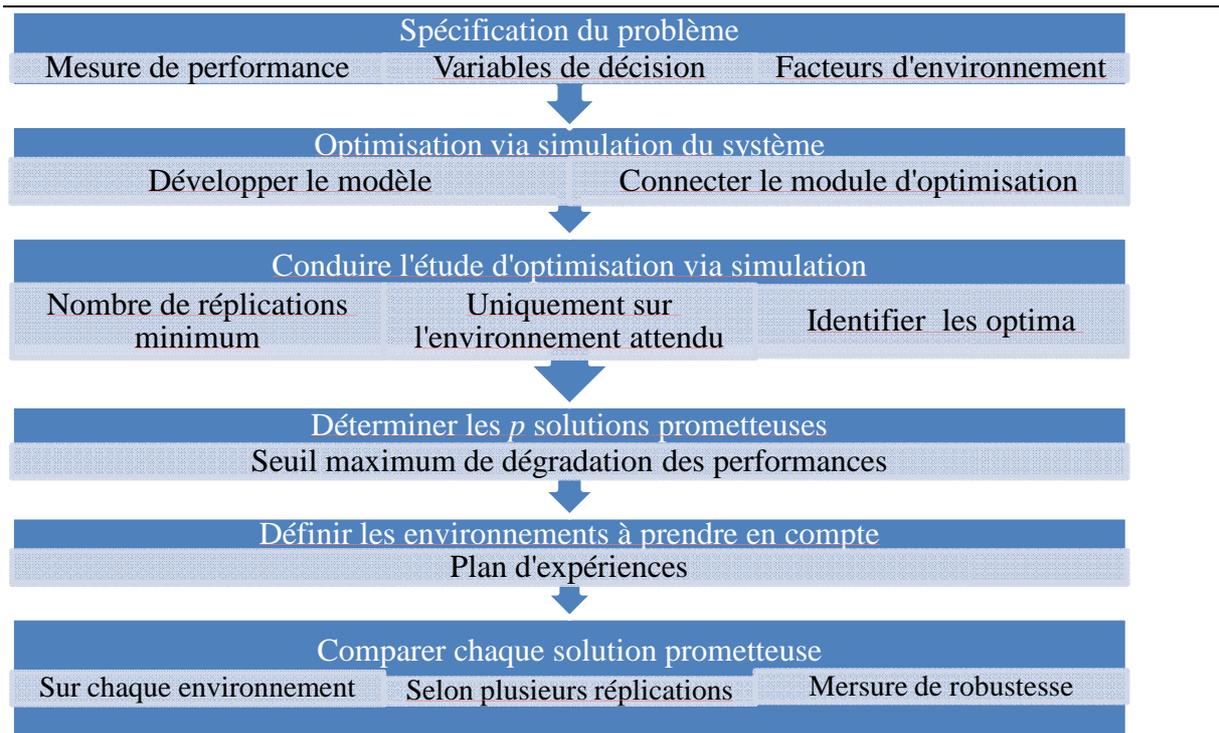


Fig 4. 2: Méthodologie pour la prise en compte de l'incertitude.

3. Approche proposée

Selon les principes décrits précédemment, nous présentons dans cette section une approche en trois phases pour la détermination de solutions robustes d'un système.

3.1 Première phase : Optimisation via simulation sur l'environnement attendu

Dans la première phase, nous devons demander aux analystes du système de fournir le domaine de variation des facteurs d'environnements ainsi que les données attendues de manière à les prendre en compte dans le modèle de simulation. Ainsi, nous définissons l'environnement attendu ξ_{EA} .

Une optimisation via simulation est alors conduite dans le but de déterminer les meilleures solutions sur l'environnement attendu (Baccouche et al, 2009). Nous utiliserons donc comme processus d'optimisation l'approche multimodale via simulation présentée dans le chapitre II

(cf. équation (2.2) du chapitre II). Ensuite nous devons déterminer, en liaison avec les décideurs, les p solutions prometteuses sélectionnées suivant le seuil maximum de dégradation de performances α toléré par les décideurs. Ainsi, nous obtenons l'ensemble des meilleures solutions, acceptables aux yeux des décideurs, sur l'environnement attendu. Cet ensemble est noté $S = \{X^*, X_t; t = 1, \dots, p - 1\}$.

Lorsque le modèle de simulation est stochastique, plusieurs répliques de la simulation peuvent être nécessaires (ou la méthode des lots pour une simulation longue). Nous utilisons comme mesure, la performance moyenne d'une solution W , notée $\hat{F}(W)_{/\xi_{EA}}$ et elle est calculée de la manière suivante :

$$\hat{F}(W)_{/\xi_{EA}} = \frac{1}{r} \sum F_1(W)_{/\xi_{EA}}, F_2(W)_{/\xi_{EA}}, \dots, F_r(W)_{/\xi_{EA}} \quad (4.4)$$

avec r le nombre de répliques.

3.2 Deuxième phase : Simulation en considérant d'autres environnements

Lors de l'exploration du système, les solutions ayant un niveau de performance acceptable sur l'environnement attendu peuvent s'avérer moins performantes sur d'autres environnements.

La mise en œuvre de cette deuxième phase nécessite les étapes suivantes :

Etape 1 : Echantillonnage des environnements

Dans cette étape, nous devons sélectionner les environnements à prendre en compte dans l'étude. En effet, il n'est pas envisageable de tester toutes les combinaisons des facteurs d'environnements. Il est donc nécessaire de déterminer un échantillon d'environnements à prendre en compte dans l'étude. Pour cela, nous utilisons la méthode des plans d'expérience (Kleijnen, 2008).

Etape 2 : Simulation des solutions prometteuses en considérant d'autres environnements.

Nous devons prendre en compte l'ensemble des environnements définis auparavant. Etant $\{\xi_k; k = 1, \dots, q\}$ l'ensemble des q environnements sélectionnés pour l'étude. Cette étape nécessite le processus suivant :

Algorithme 3

Pour chaque environnement ξ_k ,

 Pour toute solution dans S ,

 Exécuter r répliques indépendantes (ou une simulation longue)

 Calculer la performance moyenne de la solution sur l'environnement ξ_k selon l'équation (4.4)

 Fin

Fin

On obtient alors le tableau 4.1 où chaque solution prometteuse dans S (chaque colonne représente une solution) possède une performance moyenne évaluée sur chaque environnement ξ_k (chaque ligne représente un environnement).

	X^*	X_1	X_{p-1}
ξ_1	$\hat{F}(X^*)_{/\xi_1}$	$\hat{F}(X_1)_{/\xi_1}$	$\hat{F}(X_{p-1})_{/\xi_1}$
...		
ξ_q	$\hat{F}(X^*)_{/\xi_q}$	$\hat{F}(X_1)_{/\xi_q}$	$\hat{F}(X_{p-1})_{/\xi_q}$

Tab 4. 1 Performances moyennes des solutions prometteuses sur d'autres environnements

Ce tableau indique si le changement des données de l'environnement attendu, par les experts du système, affecte les performances des solutions obtenues lors de l'étude d'optimisation via simulation. Il nous indique par exemple :

- Si la solution X^* , ayant la meilleure performance sur l'environnement attendu, reste performante sur d'autres environnements.
- Quelles sont les solutions qui s'avèrent potentiellement plus performantes que la solution X^* sur d'autres environnements.

- Si les performances obtenues sur l'environnement attendu sont maintenues sur d'autres environnements.

Cependant, les comportements des solutions indiquent la présence de solutions qui produisent des performances meilleures sur certains environnements et pas sur d'autres. Dans ces cas, un choix doit être fait pour trancher pour l'une ou l'autre des solutions. Dans la section suivante, nous procédons à comparer les résultats obtenus dans le tableau.

3.3 Troisième phase : Comparaison des solutions prometteuses

Selon le tableau obtenu dans la phase précédente (cf. tableau 4.1), nous suggérons de comparer le comportement des solutions prometteuses selon les différents environnements. La comparaison des solutions nécessite deux étapes :

Etape 1 : Comparaison des solutions prometteuses et tests statistiques

Du fait du caractère stochastique de la simulation, plusieurs répliques ont été conduites pour obtenir les performances des solutions sur les environnements (cf. **Algorithme 3**). Sachant que X^* possède la meilleure performance sur l'environnement attendu, nous suggérons de tester si les différences de performances observées par le comportement de la solution X^* et les autres solutions prometteuses sur les différents environnements sont significatives ou non. La fonction *Différence* () conditionne l'obtention des solutions significativement différentes selon la formule suivante :

$$\text{Différence } (\hat{F}(X^*), \hat{F}(X_t))_{/\varepsilon_k} = \begin{cases} \text{Différence significative} \\ \text{Différence non significative.} \end{cases} \quad (4.5)$$

avec $\hat{F}(X^*)$ et $\hat{F}(X_t)$ les performances moyennes de la meilleure solution et une autre solution prometteuse sur l'environnement considéré.

Dans la littérature, différents tests statistiques peuvent être utilisés (voir notamment Giard, 1985). Ainsi, on obtient le tableau 4.2 où la fonction *Différence* () est testée pour chaque couple- solution sur chaque environnement.

	X^*	X_1	X_{p-1}
ξ_1		$\hat{F}(X_1)_{/\xi_1}$		$\hat{F}(X_{p-1})_{/\xi_1}$
...		
ξ_q		$\hat{F}(X_1)_{/\xi_q}$	

Tab 4. 2 Les solutions possédant des différences de performances significatives avec X^*

Ce tableau nous permet d'extraire les solutions ayant des différences de performances significatives. Nous constatons par exemple que :

- Comparée aux performances de X^* sur les environnements ξ_1 et ξ_q (cf. tableau 4.1) la solution X_1 présente des différences de performance significatives.
- Par contre, la solution X_{p-1} présente une différence de performance significative uniquement sur l'environnement ξ_1 .

Etape 2 : Mesure de robustesse.

La comparaison des performances des solutions selon le test statistique nous a permis de distinguer les solutions ayant des différences de performances significatives ou non selon les environnements. Dans cette étape, nous suggérons d'extraire les solutions robustes.

Pour cela, nous proposons d'utiliser le principe de la dominance et la notion d'optimalité Pareto (Talbi, 2009). Pour qu'une solution soit intéressante, il faut qu'il existe une relation de dominance entre les solutions dans le sens suivant :

D'après Collette et Siarry (2002), une solution X_1 domine une solution X_2 si :

- X_1 est au moins aussi performante que X_2 sur tous les environnements,
- X_1 est strictement meilleure que X_2 sur au moins un environnement.

Les solutions qui dominent les autres mais ne se dominant pas entre elles sont appelées solutions optimales au sens de Pareto. Cet ensemble, noté *PO*, constitue l'ensemble des solutions ayant les meilleures performances sur les différents environnements. Ainsi, nous pouvons fournir aux décideurs plusieurs solutions robustes, ayant des caractéristiques différentes leur permettant ainsi une souplesse dans le choix de la solution finale.

Cependant, d'autres approches peuvent être utilisées pour trouver les relations de dominance des solutions selon les différents environnements. Nous citons par exemple les relations de dominance probabilistes où la probabilité qu'une solution domine l'autre est calculée (Teich, 2001 ; Hughes, 2001).

4. Conclusion

Dans ce chapitre, nous avons présenté une nouvelle approche permettant la prise en compte de plusieurs environnements dans une étude d'optimisation en conjonction avec la simulation.

Suivant un raisonnement méthodologique, cette approche originale permet de délivrer les meilleures solutions en distinguant un environnement, jugé attendu par les décideurs, et en un temps meilleur que d'autres approches existantes. En effet, nous avons pu restreindre le nombre de solutions à explorer sur les différents environnements, nécessaires pour l'étude de robustesse, et considérablement réduire les coûts de calcul par rapport à l'approche proposée par Al Aomar (2006).

Ensuite, de manière à mettre en évidence les solutions qui contribuent à la robustesse ou à la non robustesse du système, nous avons suggéré d'utiliser le principe de la dominance pareto pour sélectionner les solutions qui restent meilleures sur plusieurs environnements. Les résultats obtenus nous ont permis de fournir aux décideurs plusieurs solutions robustes et contrastées permettant ainsi une meilleure flexibilité lors du choix de la solution finale.

Dans le chapitre suivant nous allons mettre en application les approches proposées dans ce travail de thèse sur un exemple d'une chaîne logistique.

Chapitre V

**APPLICATIONS A UN PROBLEME DE CHAINE
LOGISTIQUE**

Chapitre V . APPLICATIONS A UN PROBLEME DE CHAINE LOGISTIQUE

1. Introduction	79
2. Description	79
3. Problème d’optimisation via simulation posé	81
4. Optimisation multimodale via simulation	82
4.1 Implémentation et connexion.....	82
4.2 Recherche de solutions efficaces.....	83
5. Choix d’une solution dans une prise de décision collaborative	85
5.1 Problème de décision posé.....	85
5.2 Expression des préférences des décideurs par rapport aux solutions retenues	86
5.3 Agrégation des préférences des décideurs	90
5.4 Calcul du score de préférence et classement collectif des solutions.....	91
5.5 Analyse des résultats.....	92
6. Détermination des solutions robustes via l’approche de prise en compte de l’incertain..	92
6.1 Problème d’incertitude posé	92
6.2 Recherche des solutions prometteuses sur l’environnement attendu.....	95
6.3 Simulation des solutions prometteuses en considérant d’autres environnements	96
6.4 Comparaison des performances des solutions et tests statistiques.....	98
6.5 Mesure de robustesse	100
6.6 Analyse des résultats.....	101
7. Conclusion.....	101

1. Introduction

Nous traitons dans ce chapitre un cas d'application d'une supply chain publié par (Huyet et Paris, 2003). En premier lieu, nous présentons les caractéristiques de ce système. Puis, nous l'utilisons pour illustrer l'approche permettant de fournir de la flexibilité décisionnelle et déterminer plusieurs solutions performantes du système. Nous exploitons, ensuite, cette flexibilité pour prendre en compte un contexte de prise de décision collaborative et intégrer les aspects incertains.

2. Description

Le système étudié est une boucle de supply chain (Huyet et Paris, 2003). Il est constitué d'une centrale de distribution et d'un fournisseur (cf. figure 5.1). Le fournisseur peut produire trois types de produits. Chaque produit est noté, P_m avec $m=1, 2$ ou 3 pour symboliser le type. D'après les experts de notre étude, la centrale de distribution commande fréquemment 65% du produit 1, 25% du produit 2 et 10% du produit 3.

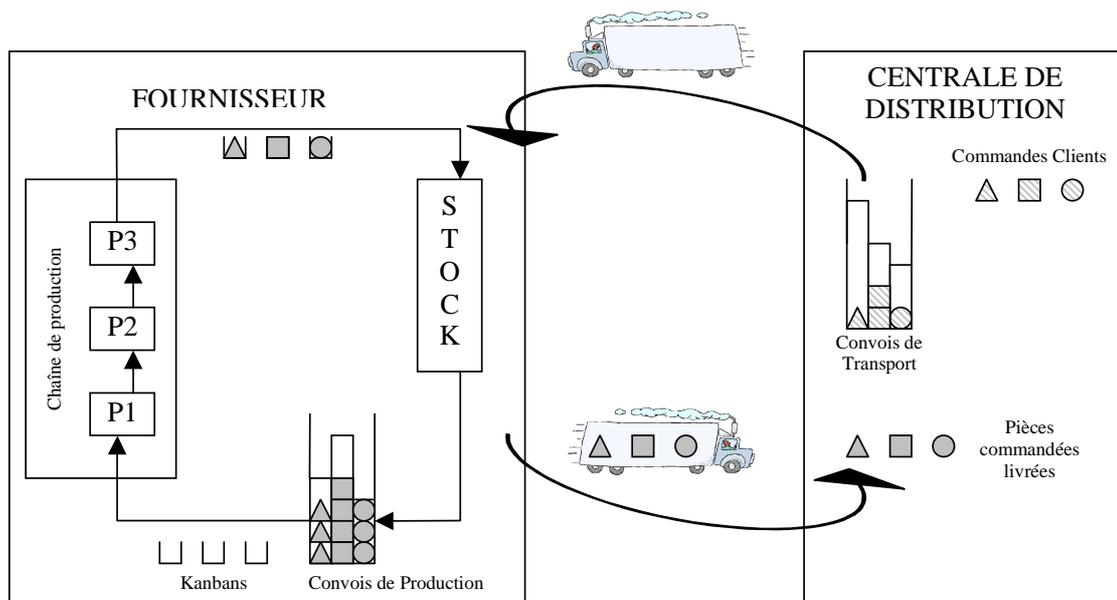


Fig 5. 1: Maille de Supply Chain

Le transport entre les deux sites est assuré par un camion qui apporte les ordres de commande de la centrale de distribution au fournisseur et livre les produits commandés à cette centrale. Le camion effectue un aller retour entre les deux sites toutes les six heures. Une commande client ne peut être retirée de la centrale de distribution que lorsqu'il ya des produits disponibles. Si aucun produit n'est disponible à l'arrivée d'une commande, un ordre de production est envoyé au fournisseur, lors du retour du camion, pour reconstituer le stock dans la centrale de distribution. La production fonctionne selon une politique de juste-à-temps (JIT). Cette technique est souvent mise en application pour améliorer la productivité de la ligne et pour réduire les coûts de fabrication (Golhar et Stamm 1991, Price et al 1994, Yavuz et Satir, 1995 ; Huang et Kusiak, 1996).

Le système de fabrication du fournisseur est constitué d'un atelier de production géré avec des lots de production de tailles constantes pour chaque type de produit. Dans la chaîne de production, différentes boucles de kanbans sont utilisées et un nombre fixe de kanbans est affecté pour chaque type de produit. Les produits subissent trois opérations consécutives P1, P2 et P3 (cf. figure 5.1). Les temps des opérations sont fixés selon le type du produit et se présentent comme suit :

	T e m p s P 1	T e m p s P 2	T e m p s P 3
Produit 1	1 heure	2 heures	3 heures
Produit 2	2 heures	3 heures	4 heures
Produit 3	3 heures	4 heures	5 heures

Tab 5. 1: Les temps des opérations dans la chaîne de production par type de produit

Le nombre de produits commandés pour chaque type de produit est :

- 65% pour le produit 1,
- 25% pour le produit 2,
- Et 10% pour le produit 3.

La boucle de supply chain est gérée aussi selon une politique de transport. Les ordres et les produits commandés sont contrôlés par des lots de transport de tailles constantes pour chaque type de produit qui seront délivrés lors du passage du camion.

Enfin, pour ce système, nous rappelons que la capacité du stock du fournisseur est infinie.

3. Problème d'optimisation via simulation posé

Le recours aux approches d'optimisation via simulation est souvent nécessaire pour résoudre les problèmes liés aux chaînes logistiques (voir par exemple Amodeo, et al (2009) ; Mansouri et al (2012)).

Dans le système que nous étudions, les concepteurs et les décideurs du système pensent que certains paramètres peuvent potentiellement influencer les performances du système. Le problème est de déterminer les valeurs des variables de décision suivantes :

- KB_m : le nombre de kanbans devant la ligne de production pour le produit de type m . Nous considérons que le nombre de kanbans peut varier de 10 à 30,
- TLU_m : la taille de lot de transport du produit de type m . Cette taille peut varier entre 1 et 20.
- PLU_m : la taille de lot de production du produit de type m qui pourra varier de 1 à 10.

En d'autres termes, ces trois types de variables composent la configuration de notre système représentée par le vecteur $X = [KB_m, TLU_m, PLU_m]$ avec $m= 1.. \text{nombre de types de produit}$.

Ainsi, pour des raisons économiques, nous aurons à minimiser le temps de satisfaction d'une commande ainsi que le nombre d'encours dans le système. Ces conditions sont prises en compte dans la fonction objectif suivante que l'on cherche à minimiser :

$$\min_X F(X) = \left[C_{WIP} \cdot \overline{NBE}(X) + \sum_{m=1}^3 C_m \cdot \overline{TpsC}_m(X) \right] \quad (5.1)$$

Avec:

- C_{WIP} : coût d'un encours,
- $\overline{NBE}(X)$: variable de sortie de la simulation représentant le nombre d'encours moyen relatif suite à l'évaluation de la solution X durant la période étudiée,
- C_m : constante représentant le coût d'une unité de temps pour satisfaire une commande de produit m ,
- $\overline{TpsC_m}(X)$: variable de sortie de la simulation représentant le temps de satisfaction moyen d'une commande de produit m relatif suite à l'évaluation de la solution X durant la période étudiée,
- m : type de produit.

Les commandes de chaque type de produit arrivent suivant une loi exponentielle de moyenne λ .

4. Optimisation multimodale via simulation

En étudiant plus particulièrement ce système, nous proposons d'identifier plusieurs possibilités pour dimensionner le système en prenant en compte les critères de performance formulés dans la fonction objectif. Les différentes possibilités procurent aux décideurs une meilleure flexibilité dans le choix de la solution à déployer.

4.1 Implémentation et connexion

Dans le module d'optimisation, nous avons adapté l'approche multimodale *CCGA*, initialement développée pour des systèmes à codage réel, en utilisant le langage de programmation C++. Le vecteur $X = [KB_m, TLU_m, PLU_m]$ avec $m = 1..3$ est considéré

comme un individu codé par un chromosome de 9 gènes. En ce qui concerne les paramètres de l'algorithme évolutionniste multimodal, la recombinaison a été établie au moyen d'un croisement linéaire à un seul point et un processus de sélection aléatoire entre 0 et 1 pour sélectionner les individus à recombinaison. La distance euclidienne est utilisée comme distance de similarité pour former les niches et sélectionner les clusters réservés. La formation des niches est effectuée selon le principe de méthode du « surpeuplement standard » (De Jong, 1975) mais avec un facteur de surpeuplement (CF) égal à la taille de la population (cf. *Etape 3* de l'**Algorithme 1** ; chapitre II section 4.1).

Après plusieurs tests empiriques, les meilleurs résultats de l'algorithme sont obtenus suivant une taille de population fixée à 50 et un nombre maximum de générations à 500.

L'évaluation de la fonction $F()$ est faite par un modèle de simulation. Du fait du caractère stochastique de ce modèle, dans un premier temps nous avons effectué une longue exécution (Law et Kelton, 2000) pour chaque chromosome à évaluer. La durée de la simulation est de 8000 heures soit plus de 15 ans en considérant par an, 47 semaines de travail 7 jours sur 7 et en 2*8 heures par jour. Les résultats sont collectés après un warm-up de 4000 heures soit plus de 35 semaines à 7 jours sur 7 et en 2*8 heures par jour.

4.2 Recherche de solutions efficaces

Après la connexion du module d'optimisation multimodal et du modèle de simulation, *CCGA* a pu détecter et maintenir 27 optima au cours des générations. La solution la plus performante X^* est dite solution optimale (ou proche de l'optimal). Elle représente l'optima global de l'espace de recherche. Les autres solutions sont moins performantes et assez contrastées ; elles sont considérées comme des optima locaux. Chaque optimum trouvé correspond au centre d'une niche réservée de la dernière génération de l'algorithme (cf. Chapitre II section 4.1). Grâce au processus de niching mis en œuvre, nous avons obtenu des solutions suffisamment diversifiées pour offrir une possibilité de choix aux décideurs. Nous obtenons, ainsi, l'ensemble Q des 27 solutions de dimensionnement du système. Le tableau 5.2 nous donne la composition de chaque solution ainsi que sa performance.

Enfin, pour faciliter le processus de décision et selon leurs besoins, les décideurs peuvent restreindre cet ensemble Q aux alternatives dont les performances sont voisines à la performance de la solution optimale X^* et former l'ensemble S des solutions acceptables.

<i>Solution</i>	<i>Performance</i>	<i>KB₁</i>	<i>KB₂</i>	<i>KB₃</i>	<i>TLU₁</i>	<i>TLU₂</i>	<i>TLU₃</i>	<i>PLU₁</i>	<i>PLU₂</i>	<i>PLU₃</i>
X^*	8473,64	16	16	16	14	12	8	4	8	10
X_1	8627,99	24	16	16	14	14	8	10	4	10
X_2	8717,52	16	16	18	14	10	14	2	8	2
X_3	8769,34	20	22	16	12	12	10	10	10	8
X_4	8880,42	16	16	22	8	14	14	8	4	10
X_5	8943,8	16	20	16	10	14	6	4	8	2
X_6	8947,3	24	16	22	14	10	14	10	8	10
X_7	8986,92	16	24	16	14	6	8	2	10	10
X_8	8988	24	22	16	14	14	14	2	10	2
X_9	9004,81	16	22	24	14	12	8	2	10	10
X_{10}	9044,58	18	16	22	14	10	6	6	4	4
X_{11}	9117,02	24	22	16	14	12	8	2	6	10
X_{12}	9121,65	16	22	16	8	12	14	2	2	4
X_{13}	9189,87	16	22	18	8	14	6	8	2	10
X_{14}	9258,72	24	24	24	14	14	14	6	10	10
X_{15}	9276,54	16	16	24	8	10	14	2	2	2
X_{16}	9323,65	22	18	16	8	6	14	10	10	4
X_{17}	9332,42	22	16	16	8	10	8	2	2	2
X_{18}	9384,48	24	16	22	14	6	8	2	10	10
X_{19}	9473,66	16	24	22	8	12	12	8	10	2
X_{20}	9484,38	20	24	24	14	12	12	8	2	2
X_{21}	9503,64	20	20	24	8	12	6	10	8	8
X_{22}	9644,93	16	22	24	8	14	6	2	2	4
X_{23}	9763,9	18	24	22	10	6	14	10	8	10
X_{24}	10104	22	22	20	8	6	8	6	2	8
X_{25}	10154,1	16	20	22	6	6	14	2	6	10
X_{26}	10315,2	18	22	16	6	6	6	10	6	2

Tab 5. 2: Les caractéristiques des solutions de dimensionnement du système

5. Choix d'une solution dans une prise de décision collaborative

5.1 Problème de décision posé

La prise en compte d'un contexte de collaboration de plusieurs décideurs est de plus en plus abordée dans la littérature notamment dans les chaînes logistiques.

Dans ce contexte, différents membres se réunissent pour sélectionner une solution à implanter. A part les critères de performances, chaque décideur possède des préférences concernant le dimensionnement du système non incluses dans la formalisation de la fonction objectif ni dans le modèle de simulation.

L'équipe des décideurs du système que nous étudions est composée de trois membres. En analysant les possibilités de dimensionnement fournies par l'étude d'optimisation multimodale via simulation, les trois décideurs estiment que le taux de dégradation maximum de la performance ne doit pas dépasser 5 %. Une telle proportion de perte de performance est déterminée suite à un accord entre les trois membres. Elle est jugée comme étant le maximum de dégradation qu'ils peuvent tolérer par rapport à la meilleure performance du système trouvée c'est-à-dire la performance de X^* . Ainsi, pour chaque solution de dimensionnement, nous avons calculé la proportion de performance perdue. Parmi les 27 solutions (cf tableau 5.2), cette étude nous conduit à cinq solutions retenues. Ces solutions sont récapitulées dans le tableau 5.3.

<i>Solution</i>	<i>Performance</i>	KB_1	KB_2	KB_3	TLU_1	TLU_2	TLU_3	PLU_1	PLU_2	PLU_3
X^*	8473,64	16	16	16	14	12	8	4	8	10
X_1	8627,99	24	16	16	14	14	8	10	4	10
X_2	8717,52	16	16	18	14	10	14	2	8	2
X_3	8769,34	20	22	16	12	12	10	10	10	8
X_4	8880,42	16	16	22	8	14	14	8	4	10

Tab 5. 3: Les solutions retenues dans le processus de décision collaboratif

Une fois les solutions retenues et sélectionnées, les décideurs peuvent maintenant les analyser et exprimer leurs préférences individuelles. Toutefois, cette analyse nous conduit parfois à des choix différents. Par exemple, pour dimensionner le système, le premier décideur préfère la solution X_3 à la solution X^* (cf. tableau 5.3) car les tailles de lots de production sont plus importantes et selon son jugement, il est souhaitable d'avoir des cycles de production plus longs avec un minimum de réglages et de transitions.

Le second décideur, quant à lui, préfère la solution X_2 où les tailles de lots de production sont plus faibles que les solutions X^* et X_3 . Dans son jugement, la solution X_2 permet d'avoir un processus de production plus flexible, notamment en cas de commandes urgentes ou de pannes imprévues.

Pour remédier à ce problème, nous avons utilisé l'**Algorithme 2** (cf. chapitre III section 5) basé sur le principe de la méthode « AHP » pour modéliser les préférences individuelles des décideurs par rapport aux solutions retenues et la « Geometric Mean Method » pour les agréger et enfin obtenir une solution collectivement acceptable. Nous présentons l'application des étapes de cet algorithme dans la section suivante.

5.2 Expression des préférences des décideurs par rapport aux solutions retenues

Les décideurs à prendre en compte dans cette étude sont trois personnes et ils ont tous une importance égale. Chaque décideur exprime ses préférences par rapport aux solutions retenues (cf. tableau 5.3).

Les tableaux 5.4, 5.5 et 5.6 présentent respectivement les préférences individuelles de chaque décideur. Dans chaque tableau, le processus de comparaison consiste à exprimer si une solution i est préférée à une autre solution j et lui affecter un degrés d'importance r_{ij} selon l'échelle d'évaluation de Saaty (2009) (cf. tableau 3.1 au chapitre III section 4).

- Décideur 1

Solution			Plus Importante	Degrès d'importance r_{ij} (1-9)
i		j		
X^*	Comparée avec	X_1	j	4
		X_2	i	2
		X_3	i	4
		X_4	j	2
X_1	Comparée avec	X_2	i	6
		X_3	i	8
		X_4	i	2
X_2	Comparée avec	X_3	i	2
		X_4	j	4
X_3	Comparée avec	X_4	j	6

Tab 5. 4: Evaluation des solutions par paire par le décideur 1

Dans le tableau 5.4, le décideur 1 compare deux à deux les solutions. Aux yeux du décideur 1, la solution X^* est moins importante que les solutions X_1 et X_4 . Par contre, elle est préférée par rapport aux solutions X_2 et X_3 . La solution X_1 est plus importante que les solutions X_2 , X_3 et X_4 . La solution X_2 est plus importante que la solution X_3 mais aussi moins importante que X_4 .

- Décideur 2

Solution			Plus Importante	Degrès d'importance r_{ij} (1-9)
i		j		
X^*	Comparée avec	X_1	j	2
		X_2	j	6
		X_3	j	4
		X_4	j	8
X_1	Comparée avec	X_2	j	4
		X_3	j	2
		X_4	j	6
X_2	Comparée avec	X_3	i	2
		X_4	j	2
X_3	Comparée avec	X_4	j	4

Tab 5. 5: Evaluation des solutions par paire le décideur 2

Dans le tableau 5.5, le décideur 2 compare deux à deux les solutions. Aux yeux du décideur 2, les solutions X_1 , X_2 , X_3 et X_4 sont plus importantes que la solution X^* . De même X_1 est jugée la moins importante parmi ces quatre solutions. Par contre X_4 est plus importante que les solutions X_2 et X_3 . Enfin pour ces dernières solutions, la solution X_2 est plus importante que X_3 .

- Décideur 3

Solution			Plus Importante	Degrès d'importance r_{ij} (1-9)
i		j		
X^*	Comparée avec	X_1	j	4
		X_2	j	8
		X_3	j	2
		X_4	j	6
X_1	Comparée avec	X_2	j	4
		X_3	j	2
		X_4	j	6
X_2	Comparée avec	X_3	i	6
		X_4	i	2
X_3	Comparée avec	X_4	j	4

Tab 5. 6: Evaluation des solutions par paire par le décideur 3

Dans le tableau 5.6, le décideur 3 compare deux à deux les solutions. De même que le décideur 2, les solutions X_1 , X_2 , X_3 et X_4 sont plus importantes que la solution X^* et la solution X_1 est jugée la moins importante parmi ces quatre solutions. La solution X_2 est plus importante que les solutions X_3 et X_4 . Enfin, la solution X_3 est plus importante que X_4 .

5.3 Agrégation des préférences des décideurs

Les évaluations par paire, exprimées par les décideurs, nous permettent de construire les matrices carrées de comparaison par paire A^a avec a représentant le numéro du décideur. La figure 5.4 présente les trois matrices respectives aux trois décideurs.

$$A^1 = \begin{pmatrix} 1 & 0.25 & 2 & 4 & 0.5 \\ 4 & 1 & 6 & 8 & 2 \\ 0.5 & 0.1667 & 1 & 2 & 0.25 \\ 0.25 & 0.125 & 0.5 & 1 & 0.1667 \\ 2 & 0.5 & 4 & 6 & 1 \end{pmatrix} \quad A^2 = \begin{pmatrix} 1 & 0.5 & 0.1667 & 0.25 & 0.125 \\ 2 & 1 & 0.25 & 0.5 & 0.1667 \\ 6 & 4 & 1 & 2 & 0.5 \\ 4 & 2 & 0.5 & 1 & 0.25 \\ 8 & 6 & 2 & 4 & 1 \end{pmatrix}$$

$$A^3 = \begin{pmatrix} 1 & 0.25 & 0.125 & 0.5 & 0.1667 \\ 4 & 1 & 0.25 & 2 & 0.5 \\ 8 & 4 & 1 & 6 & 2 \\ 2 & 0.5 & 0.1667 & 1 & 0.25 \\ 6 & 2 & 0.5 & 4 & 1 \end{pmatrix}$$

Fig 5.4 : Matrices de comparaison des solutions

Dans la figure 5.4, les colonnes de chaque matrice contiennent les degrés d'importance exprimés lors des évaluations par paire effectuées par les décideurs (cf. tableaux 5.4, 5.5 et 5.6). Le remplissage de chaque colonne s'effectue de la manière suivante :

- Le degré d'importance d'une solution comparée à elle-même est égal à 1,
- Le degré d'importance d'une solution plus importante qu'une autre solution est égal à r_{ij} (cf. tableaux 5.4, 5.5 et 5.6).
- Le degré d'importance d'une solution moins importante qu'une autre solution est égal à $1 / r_{ij}$.

Après la normalisation des matrices, nous estimons le vecteur de priorité F^a , respectif à chaque décideur a . Chaque vecteur exprime le classement des solutions selon les préférences de chaque décideur. Le vecteur est calculé de la manière suivante :

$$F_i^a = \prod_{j=1}^p (r_{ij}^a)^{1/p} \quad (5.3)$$

avec a le numéro du décideur / $a = 1..3$, r_{ij} le degrés d'importance de la solution i par rapport à la solution j pour le décideur a et $p= 1..5$ le nombre de solutions retenues (voir tableau 5.3).

Les vecteurs de priorités relatifs aux décideurs sont présentés comme suit.

- $F^1 = (0.1427 \ 0.4690 \ 0.0756 \ 0.0434 \ 0.2694)^T$,
- $F^2 = (0.0434 \ 0.0756 \ 0.2694 \ 0.1427 \ 0.4690)^T$,
- $F^3 = (0.0434 \ 0.1427 \ 0.4690 \ 0.0756 \ 0.2694)^T$.

Le vecteur F^1 démontre que le classement des solutions pour le décideur 1 est : $(X_1, X_4, X^*, X_2, X_3)$. Le vecteur F^2 démontre que le classement des solutions pour le décideur 2 est : $(X_4, X_2, X_3, X_1, X^*)$. Le vecteur F^3 démontre que le classement des solutions pour le décideur 3 est : $(X_2, X_4, X_1, X_3, X^*)$.

5.4 Calcul du score de préférence et classement collectif des solutions

Etant le vecteur de priorité, estimé pour chaque décideur, nous calculons le score de préférence collectif obtenu pour chaque solution en utilisant la formule suivante :

$$R_i = \prod_{a=1}^3 (F_i^a)^{1/3} \quad (5.4)$$

Avec i indice de la solution et a le numéro du décideur / $a = 1..3$.

Le tableau 5.7 présente les scores de préférences collectifs des solutions retenues.

Solutions	X^*	X_1	X_2	X_3	X_4
Score de préférence R	0.0645	0.1716	0.2121	0.0776	0.3241

Tab 5. 7: Les scores de préférences collectifs des solutions retenues

D'après les scores obtenus, nous déduisons le classement collectif des solutions suivant :
 (X_4, X_2, X_1, X_3, X^*).

5.5 Analyse des résultats

Le choix de la solution collectivement acceptable porte sur la solution X_4 puisqu'elle obtient le score le plus élevé, à savoir « 0.3241 » sur le tableau 5.7, malgré que cette solution ne possède pas la meilleure performance. On déduit alors que les caractéristiques de cette solution représentent une adéquation convenable pour les membres de l'équipe des décideurs. Nous illustrons ainsi tout l'intérêt de notre approche, puisque le choix de la solution X_4 s'effectue en considérant les préférences des décideurs. Dans le cas où les décideurs n'aboutissent pas à un consensus général pour le choix de cette solution, la solution X_2 sera proposée, Etc.

6. Détermination des solutions robustes via l'approche de prise en compte de l'incertain

6.1 Problème d'incertitude posé

S'il y a un changement de la demande sur le marché des biens et de services, comme la diminution ou l'augmentation des quantités commandées des produits, la centrale de distribution doit régir ses quantités de produits commandés selon la demande. De ce fait, le système de fabrication du fournisseur doit aussi réorganiser sa chaîne de production suivant les quantités de produits commandées. Or, les arrivées des commandes des produits sont

incertaines. D'après les experts, les commandes des produits arrivent suivant une loi exponentielle de moyenne λ .

On désigne alors :

- λ_1 : le paramètre de la loi exponentielle pour P_1 ,
- λ_2 : le paramètre de la loi exponentielle pour P_2 ,
- λ_3 : le paramètre de la loi exponentielle pour P_3 .

Nous définissons les arrivées des commandes comme étant les facteurs d'environnement du système. Etant donné que nous avons trois types de produits, nous désignons trois facteurs d'environnement :

- ϕ_1^v : représente λ_1 ,
- ϕ_2^v : représente λ_2 ,
- ϕ_3^v : représente λ_3 .

6.1 Détermination des environnements à prendre en compte

Les arrivées des commandes des produits attendues par les experts sont :

- $\lambda_1 = 10$ minutes pour les commandes de produit P_1
- $\lambda_2 = 12$ minutes pour les commandes de produit P_2
- $\lambda_3 = 38$ minutes pour les commandes de produit P_3

L'environnement attendu est représenté alors par : $\xi_{EA} = \{10,12,38\}$ (cf. tableau 5.8). Cet environnement représente les conditions opératoires incluses dans le modèle de simulation durant le processus d'optimisation via simulation.

	ϕ_1	ϕ_2	ϕ_3
ξ_{EA}	10	12	38

Tab 5. 8: Caractéristiques de l'environnement attendu

Nous proposons de varier les valeurs attendues, exigées par les décideurs, et générer d'autres scénarios à prendre en compte dans le modèle de simulation. Nous avons choisi d'utiliser la technique des plans d'expériences (Kleijnen, 2008) pour échantillonner l'espace des environnements. Plus précisément, nous avons utilisé un plan factoriel complet relatif à trois facteurs. Nous définissons trois niveaux pour chaque facteur (bas, attendu et haut). Le nombre d'environnements q à prendre en compte dans l'étude est de 3^3 environnements.

On considère que l'arrivée d'une commande d'un produit P_m varie selon les niveaux définis dans le tableau 5.9. Par exemple les arrivées d'une commande de produit P_1 peut être :

- $\phi_1^1 = 8$ minutes, désigne le niveau le plus haut d'arrivée d'une commande de produit P_1
- $\phi_1^2 = 10$ minutes, désigne le niveau attendu d'arrivée d'une commande de produit P_1
- $\phi_1^3 = 12$ minutes, désigne le niveau le plus bas d'arrivée d'une commande de produit P_1

Niveau du facteur (v)	Facteur d'environnement		
	ϕ_1	ϕ_2	ϕ_3
1 : Haut	8 min	10 min	36 min
2 : Attendu	10 min	12 min	38 min
3 : Bas	12 min	14 min	40 min

Tab 5. 9: Les niveaux des facteurs d'environnement

De part l'environnement attendu, nous déterminons un échantillon de 26 autres environnements à prendre en compte dans l'étude (voir tableau 5.10).

	ϕ_1	ϕ_2	ϕ_3
ξ_1	8	10	36
ξ_2	8	10	38
ξ_3	8	10	40
ξ_4	8	12	36
ξ_5	8	12	38
ξ_6	8	12	40
ξ_7	8	14	36
ξ_8	8	14	38
ξ_9	8	14	40
ξ_{10}	12	10	36
ξ_{11}	12	10	38
ξ_{12}	12	10	40
ξ_{13}	12	12	36
ξ_{14}	12	12	38
ξ_{15}	12	12	40
ξ_{16}	12	14	36
ξ_{17}	12	14	38
ξ_{18}	12	14	40
ξ_{19}	10	10	36
ξ_{20}	10	10	38
ξ_{21}	10	10	40
ξ_{22}	10	12	36
ξ_{23}	10	12	40
ξ_{24}	10	14	36
ξ_{25}	10	14	38
ξ_{26}	10	14	40

Tab 5. 10: Les caractéristiques des autres environnements pris en compte

6.2 Recherche des solutions prometteuses sur l'environnement attendu

Nous exploitons l'approche multimodale via simulation pour obtenir les solutions prometteuses sur l'environnement attendu par les experts. Nous considérons qu'un taux de

dégradation maximum des performances a été défini par les décideurs. Nous obtenons ainsi, l'ensemble S des solutions prometteuses sur l'environnement attendu. Il constitue les solutions à comparer sur les autres environnements :

- La solution la plus performante, notée X^* ,
- Les solutions voisines à la performance de celle-ci allant de X_1 à X_{14}

Le tableau 5.12 donne les caractéristiques des solutions prometteuses retenues.

<i>Solution</i>	<i>Performance</i>	<i>KB₁</i>	<i>KB₂</i>	<i>KB₃</i>	<i>TLU₁</i>	<i>TLU₂</i>	<i>TLU₃</i>	<i>PLU₁</i>	<i>PLU₂</i>	<i>PLU₃</i>
X^*	8473,64	16	16	16	14	12	8	4	8	10
X_1	8627,99	24	16	16	14	14	8	10	4	10
X_2	8717,52	16	16	18	14	10	14	2	8	2
X_3	8769,34	20	22	16	12	12	10	10	10	8
X_4	8880,42	16	16	22	8	14	14	8	4	10
X_5	8943,8	16	20	16	10	14	6	4	8	2
X_6	8947,3	24	16	22	14	10	14	10	8	10
X_7	8986,92	16	24	16	14	6	8	2	10	10
X_8	8988	24	22	16	14	14	14	2	10	2
X_9	9004,81	16	22	24	14	12	8	2	10	10
X_{10}	9044,58	18	16	22	14	10	6	6	4	4
X_{11}	9117,02	24	22	16	14	12	8	2	6	10
X_{12}	9121,65	16	22	16	8	12	14	2	2	4
X_{13}	9189,87	16	22	18	8	14	6	8	2	10
X_{14}	9258,72	24	24	24	14	14	14	6	10	10

Tab 5. 11: Caractéristiques des solutions prometteuses sur l'environnement attendu

6.3 Simulation des solutions prometteuses en considérant d'autres environnements

En s'appuyant sur le fait que les décideurs acceptent de privilégier une solution moins performante que la solution X^* sur l'environnement attendu à condition que celle-ci présente

un intérêt suffisant sur d'autres environnements, nous simulons les solutions prometteuses sur les autres environnements sélectionnés. Pour cela, nous utilisons l'**Algorithme 3** (cf. chapitre IV section 3.2).

	X^*	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}
ξ_1	13419,7	12545,9	13433,5	14413,15	13468,2	14158,8	13990,5	13060,75	12364,9	13687,3	12587,25	11358	12065,85	12058,7	13605,6
ξ_2	12640,7	11735,45	13299,5	12537,1	12722,9	12626	13998,8	12074,2	11199,55	12429,5	11960,6	10666,15	11191,2	11636,75	12178,45
ξ_3	12130,95	11476,45	12045,2	13123	11983,9	12699,1	12472,45	12198,2	10406,3	12540,55	11067,3	10402,15	11165,9	11877,65	11306,25
ξ_4	8912,7	9221,5	9556,85	9554,55	9959	9989,65	9788,2	9648,65	9382,8	9699,45	9401,9	9280,5	9713,45	9602,85	10030,25
ξ_5	9424,4	9036,05	9788,05	9473,6	9651,85	9896,15	9892,55	9625,7	9377,8	9847,25	9429,8	9298,8	9514,55	9752,45	9888,7
ξ_6	9169,6	9111,15	9293,9	9600,6	9524,6	9745,1	9499,9	9615,85	9280,95	9714	9362,15	9276,75	9549,95	9629,25	9824,15
ξ_7	9066,75	8909,7	9134,1	9702,9	9398,4	9412,2	9245,45	9369,1	9241,05	9693,55	9203,15	9356,9	9605,1	9373,65	9588,9
ξ_8	8881,25	8780,15	9286,2	9282,1	9410,95	9512,65	9468,55	9371,35	9250,55	9357,85	9207,2	9203,65	9544,5	9488,2	9644,2
ξ_9	13419,75	12545,9	13433,5	14413,15	13468,2	14158,8	13990,05	13060,75	12364,9	13687,3	12587,25	11358	12065,85	12058,7	13605,6
ξ_{10}	9499,9	13687,3	9102,84	9377,8	9847,25	9429,8	9647,25	11358	9369,1	9356,9	13433,5	14413,15	13419,75	14158,8	12450,6
ξ_{11}	9245,45	12429,5	9203,15	9356,9	9605,1	9752,45	11983,9	9702,9	8541,22	9203,65	13299,5	12537,1	12640,7	12626	9647,25
ξ_{12}	8522,09	12540,55	9207,2	9203,65	9544,5	12429,5	11960,6	10666,15	9651,85	11358	12045,2	13123	12130,95	12699,1	11983,9
ξ_{13}	8493,73	9699,45	12587,25	11358	12065,85	9115,82	9120,55	13419,75	9275,34	9356,9	9556,85	9554,55	13419,75	9989,65	9377,8
ξ_{14}	9130,94	9847,25	9203,15	9356,9	9605,1	9699,45	9401,9	9280,5	10666,15	9377,8	9788,05	9473,6	12640,7	9896,15	9207,2
ξ_{15}	9544,5	9714	9123,1	11005,23	9693,55	9382,8	12537,1	9401,9	9280,5	9280,5	9382,8	9600,6	9382,8	9745,1	9699,45
ξ_{16}	9429,8	8969,70	13060,75	14413,15	9357,85	9377,8	9847,25	12537,1	9298,8	9298,8	9377,8	9702,9	9377,8	9412,2	9429,8
ξ_{17}	10045,2	13123	11983,9	12699,1	12472,45	12198,2	11629,3	9203,65	9275,34	11735,45	9286,2	9282,1	9280,95	9512,65	13468,2
ξ_{18}	9004,62	13687,3	9377,8	9847,25	9429,8	9298,8	10402,1	9377,8	9847,25	11476,4	13433,5	14413,1	9625,7	14158,8	12722,9
ξ_{19}	9514,55	13687,3	9207,2	9203,65	9544,5	12640,7	11735,45	13299,5	12537,1	9221,5	13433,5	14413,1	9615,85	14158,8	11983,9
ξ_{20}	9549,95	12429,5	9625,7	8912,7	9221,5	9111,15	9693,9	10666,15	9745,1	9036,05	13123	12537,1	9298,8	12626	9959
ξ_{21}	9105,1	9001,01	9615,85	9157,93	9602,85	8909,7	9634,1	9713,45	12537,1	12722,9	9847,25	9429,8	9702,9	9651,85	9651,85
ξ_{22}	8562,89	9479,01	9369,1	9549,95	9752,45	9169,6	9111,15	9514,55	9140,8	8909,7	9280,5	9713,45	9282,1	9524,6	9524,6
ξ_{23}	9112,13	8575,12	9371,35	9605,1	9629,25	9066,75	1009,7	9549,95	9203,65	8780,15	9298,8	9514,55	10250,1	9398,4	9398,4
ξ_{24}	8969,70	9203,65	9600,6	9847,25	9512,65	9468,55	9371,35	9788,05	9473,6	8912,7	13419,75	12545,9	9357,85	9371,35	13060,75
ξ_{25}	9629,25	13433,5	9221,5	9111,15	9293,9	10666,15	9556,85	9554,55	13123	12537,1	9499,9	13687,3	9102,84	9514,55	12537,1
ξ_{26}	9207,72	9667,42	13060,7	9275,34	9373,65	9221,5	13433,5	9605,1	11358	12545,9	12198,2	10406,3	12540,5	9410,95	9410,95

Tab 5. 12: Performances moyennes des solutions prometteuses sur d'autres environnements

Le tableau 5.12 indique la performance moyenne de chaque solution prometteuse, calculée selon l'équation (4.4) du chapitre IV, sur chaque environnement sélectionné pour l'étude. Les paramètres utilisés dans l'**Algorithme 3** sont :

- $r = 30$: la performance moyenne d'une solution prometteuse est estimée selon 30 exécutions du modèle de simulation (Law et Kelton, 2000).
- $q = 27$: le nombre d'environnements pris en compte.

Cependant, du fait du caractère stochastique de la simulation, nous suggérons de tester si les différences de performances observées par le comportement de la solution X^* et les autres solutions sur les différents environnements sont significatives ou non.

6.4 Comparaison des performances des solutions et tests statistiques

Nous avons utilisé un test statistique pour comparer les performances de la solution X^* et les performances des autres solutions pour savoir si les différences de performances observées sur les différents environnements étaient significatives ou non. Ainsi, la fonction *Différence* () (cf. équation (4.5) du chapitre IV) est exprimée selon un test de Student unilatéral avec un risque d'erreur de 5%.

Le tableau 5.13 illustre les résultats obtenus par la fonction *Différence* (). Nous avons coloré les performances moyennes qui sont non significativement différentes.

Ce tableau indique les différences de performances significatives par rapport aux performances de X^* sur les différents environnements. Au vu des résultats, nous constatons, par exemple, que les différences de performances avec les solutions X_1 , X_7 , X_{10} et X_{13} sur l'environnement ξ_1 ne sont pas significatives. Nous remarquons aussi que les performances obtenues sur l'environnement attendu ne sont pas détériorées sur l'environnement ξ_4 et la solution X^* reste la meilleure.

	X^*	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}
ξ_1	13419,7	12545,9	13433,5	14413,15	13468,2	14158,8	13990,5	13060,75	12364,9	13687,3	12587,25	11358	12065,85	12058,7	13605,6
ξ_2	12640,7	11735,45	13299,5	12537,1	12722,9	12626	13998,8	12074,2	11199,55	12429,5	11960,6	10666,15	11191,2	11636,75	12178,45
ξ_3	12130,95	11476,45	12045,2	13123	11983,9	12699,1	12472,45	12198,2	10406,3	12540,55	11067,3	10402,15	11165,9	11877,65	11306,25
ξ_4	8912,7	9221,5	9556,85	9554,55	9959	9989,65	9788,2	9648,65	9382,8	9699,45	9401,9	9280,5	9713,45	9602,85	10030,25
ξ_5	9424,4	9036,05	9788,05	9473,6	9651,85	9896,15	9892,55	9625,7	9377,8	9847,25	9429,8	9298,8	9514,55	9752,45	9888,7
ξ_6	9169,6	9111,15	9293,9	9600,6	9524,6	9745,1	9499,9	9615,85	9280,95	9714	9362,15	9276,75	9549,95	9629,25	9824,15
ξ_7	9066,75	8909,7	9134,1	9702,9	9398,4	9412,2	9245,45	9369,1	9241,05	9693,55	9203,15	9356,9	9605,1	9373,65	9588,9
ξ_8	8881,25	8780,15	9286,2	9282,1	9410,95	9512,65	9468,55	9371,35	9250,55	9357,85	9207,2	9203,65	9544,5	9488,2	9644,2
ξ_9	13419,75	12545,9	13433,5	14413,15	13468,2	14158,8	13990,05	13060,75	12364,9	13687,3	12587,25	11358	12065,85	12058,7	13605,6
ξ_{10}	9499,9	13687,3	9102,84	9377,8	9847,25	9429,8	9647,25	11358	9369,1	9356,9	13433,5	14413,15	13419,75	14158,8	12450,6
ξ_{11}	9245,45	12429,5	9203,15	9356,9	9605,1	9752,45	11983,9	9702,9	8541,22	9203,65	13299,5	12537,1	12640,7	12626	9647,25
ξ_{12}	8522,09	12540,55	9207,2	9203,65	9544,5	12429,5	11960,6	10666,15	9651,85	11358	12045,2	13123	12130,95	12699,1	11983,9
ξ_{13}	8493,73	9699,45	12587,25	11358	12065,85	9115,82	9120,55	13419,75	9275,34	9356,9	9556,85	9554,55	13419,75	9989,65	9377,8
ξ_{14}	9130,94	9847,25	9203,15	9356,9	9605,1	9699,45	9401,9	9280,5	10666,15	9377,8	9788,05	9473,6	12640,7	9896,15	9207,2
ξ_{15}	9544,5	9714	9123,1	11005,23	9693,55	9382,8	12537,1	9401,9	9280,5	9280,5	9382,8	9600,6	9382,8	9745,1	9699,45
ξ_{16}	9429,8	8969,70	13060,75	14413,15	9357,85	9377,8	9847,25	12537,1	9298,8	9298,8	9377,8	9702,9	9377,8	9412,2	9429,8
ξ_{17}	10045,2	13123	11983,9	12699,1	12472,45	12198,2	11629,3	9203,65	9275,34	11735,45	9286,2	9282,1	9280,95	9512,65	13468,2
ξ_{18}	9004,62	13687,3	9377,8	9847,25	9429,8	9298,8	10402,1	9377,8	9847,25	11476,4	13433,5	14413,1	9625,7	14158,8	12722,9
ξ_{19}	9514,55	13687,3	9207,2	9203,65	9544,5	12640,7	11735,45	13299,5	12537,1	9221,5	13433,5	14413,1	9615,85	14158,8	11983,9
ξ_{20}	9549,95	12429,5	9625,7	8912,7	9221,5	9111,15	9693,9	10666,15	9745,1	9036,05	13123	12537,1	9298,8	12626	9959
ξ_{21}	9105,1	9001,01	9615,85	9157,93	9602,85	8909,7	9634,1	9713,45	12537,1	12722,9	9847,25	9429,8	9702,9	9651,85	9651,85
ξ_{22}	8562,89	9479,01	9369,1	9549,95	9752,45	9169,6	9111,15	9514,55	9140,8	8909,7	9280,5	9713,45	9282,1	9524,6	9524,6
ξ_{23}	9112,13	8575,12	9371,35	9605,1	9629,25	9066,75	1009,7	9549,95	9203,65	8780,15	9298,8	9514,55	10250,1	9398,4	9398,4
ξ_{24}	8969,70	9203,65	9600,6	9847,25	9512,65	9468,55	9371,35	9788,05	9473,6	8912,7	13419,75	12545,9	9357,85	9371,35	13060,75
ξ_{25}	9629,25	13433,5	9221,5	9111,15	9293,9	10666,15	9556,85	9554,55	13123	12537,1	9499,9	13687,3	9102,84	9514,55	12537,1
ξ_{26}	9207,72	9667,42	13060,7	9275,34	9373,65	9221,5	13433,5	9605,1	11358	12545,9	12198,2	10406,3	12540,5	9410,95	9410,95

Tab 5. 13 Les solutions possédant des différences de performances significatives avec X^*

Si on considère le tableau des environnements sélectionnés pour l'étude (cf. tableau 5.10), on déduit alors qu'une hausse imprévue uniquement des arrivées des commandes des produits P_1 et P_3 n'affecte pas les performances obtenues sur l'environnement attendu. Mais, lorsqu'une baisse des arrivées des commandes du produit P_2 s'ajoute, la solution X_I est considérée

meilleure que X^* (voir par exemple l'environnement ξ_7). Par contre, s'il se produit une hausse des arrivées des commandes des produits P_1 et P_2 (cf. environnements ξ_1, ξ_2 et ξ_3 dans le tableau 5.10) par rapport aux arrivées attendues par les décideurs du système (cf. l'environnement attendu dans le tableau 5.8), les solutions X_8, X_{11} et X_{12} se comporteront mieux que la solution X^* .

Les résultats obtenus dans le tableau 5.13 permettent donc de comparer les comportements des solutions sur les environnements. Pour exploiter d'avantage ce tableau, nous pouvons associer des méthodes de classification comme les treillis de Galois (Mephu Nguifu, 1993) ou l'analyse de la variance pour déterminer, par exemple, des profils de solutions robustes.

Si l'on cherche à étudier la sensibilité des performances du système à la variation des environnements, des méthodes d'analyse de sensibilité (kleijnen, 2009) peuvent être utilisées.

Cependant, pour déterminer la solution robuste, nous avons constaté qu'il est difficile de trancher pour l'une ou l'autre des solutions. Nous suggérons donc d'utiliser la théorie de la dominance de Pareto pour mesurer la robustesse des solutions.

6.5 Mesure de robustesse

En cohérence avec le chapitre précédent, nous utilisons le principe de la dominance de Pareto pour comparer le comportement des solutions selon les différents environnements. En se basant sur ce principe (cf. *Etape 2* section 3.2 au chapitre IV), nous obtenons les résultats suivants :

- La solution X_6 est moins performante que la solution X^* sur tous les environnements,
- Les solutions dominées par la solution X^* sont : $X_2, X_3, X_4, X_5, X_7, X_9, X_{10}$ et X_{14} .
- Les solutions non dominées sont donc : $PO = \{X^*, X_1, X_8, X_{11}, X_{12}, X_{13}\}$.

Le tableau 5.14 présente les caractéristiques des solutions non dominées.

<i>Solution</i>	<i>Performance</i>	<i>KB₁</i>	<i>KB₂</i>	<i>KB₃</i>	<i>TLU₁</i>	<i>TLU₂</i>	<i>TLU₃</i>	<i>PLU₁</i>	<i>PLU₂</i>	<i>PLU₃</i>
X^*	8473,64	16	16	16	14	12	8	4	8	10
X_1	8627,99	24	16	16	14	14	8	10	4	10
X_8	8988	24	22	16	14	14	14	2	10	2
X_{11}	9117,02	24	22	16	14	12	8	2	6	10
X_{12}	9121,65	16	22	16	8	12	14	2	2	4
X_{13}	9189,87	16	22	18	8	14	6	8	2	10

Tab 5. 14: Solutions Pareto Optimales

6.6 Analyse des résultats

Plusieurs solutions ayant les meilleurs comportements sur les différents environnements ont pu être déterminées par notre approche méthodologique. Nous fournissons ainsi aux décideurs un ensemble de solutions robustes, ayant des caractéristiques différentes, pouvant leur servir d'éléments de discussion lors du choix d'une solution à implanter. En effet, d'autres solutions moins performantes que la solution X^* sur l'environnement attendu peuvent être privilégiées, si nécessaire, par les décideurs du fait qu'elles produisent des comportements satisfaisants sur les autres environnements.

7. Conclusion

Dans ce chapitre, nous avons mis en évidence de façon concrète les apports des approches proposées à la fois d'un point de vue flexibilité dans le choix de solutions performantes d'un système, d'un point de vue détermination de solutions dans une prise de décision collaborative et d'un point de vue prise en compte de l'incertain dans les études d'optimisation via simulation.

Nous avons montré que la mise en œuvre de l'approche d'optimisation multimodale via simulation nous a permis de fournir de la souplesse aux décideurs dans le choix de la solution à mettre en œuvre.

La deuxième approche nous a permis de prendre en compte les préférences individuelles des membres de l'équipe décisionnelle pour obtenir une solution collectivement acceptable à implanter.

Enfin, la troisième approche nous a permis d'étudier la robustesse du système en limitant le nombre de solutions à explorer et en optimisant les temps de calcul. Grâce à cette dernière approche, nous avons pu fournir aux décideurs un choix de solutions robustes.

CONCLUSION GENERALE ET PERSPECTIVES

Dans le contexte économique actuel, il faut que les entreprises soient capables de rester performantes malgré des conditions changeantes et très incertaines. Elles doivent pour cela optimiser la conception et l'organisation de leurs systèmes.

Ces dernières années, l'optimisation via simulation s'est largement développée dans plusieurs domaines notamment dans l'industrie manufacturière, dans les services de la santé et dans la logistique des transports. Elle permet d'optimiser, par exemple, les valeurs des variables qui composent un système de production afin d'obtenir les meilleures performances, évaluées par un modèle de simulation. Néanmoins, la présence de données incertaines ou qui manquent de précision, comme par exemple les pannes, les fréquences de livraison dans un système de production, peut affecter les performances obtenues par une étude d'optimisation par simulation. Leur prise en compte s'avère donc nécessaire pour mener à bien de telles études.

Nous avons effectué une revue des approches d'optimisation via simulation proposées dans la littérature. L'étude bibliographique menée montre que très peu de travaux en optimisation via simulation intègrent l'incertain. Nous avons alors effectué une analyse des approches publiées dans ce contexte. Au vu de notre analyse, nous avons constaté que la plupart des travaux portant sur ce thème n'apportait pas une réponse entièrement satisfaisante et qu'ils sont limités. En effet, l'optimisation par simulation requiert d'évaluer de nombreuses solutions nécessitant des temps de calcul très importants et la prise en compte de l'incertitude nécessite un nombre d'évaluations supplémentaire. Certaines recherches ont essayé d'améliorer les procédures de calcul, toutefois les processus d'optimisation utilisés sont sensibles aux optima locaux. La plupart des travaux existants ne prennent pas en compte les aspects collaboratifs. Ils considèrent implicitement la présence d'un seul décideur et que la solution délivrée par l'étude d'optimisation par simulation sera acceptée par tous les décideurs.

Nous avons alors mis en œuvre une approche permettant de fournir de la flexibilité aux décideurs dans le choix de la solution à implanter et ainsi, déterminer plusieurs alternatives de conception ou d'organisation de leurs systèmes, à la place d'une seule. Pour cela, nous avons remplacé les processus d'optimisation utilisés dans la littérature par une procédure d'optimisation multimodale en connexion avec la simulation. Nous lui avons associé une

technique de nichage parallèle capable de détecter et maintenir, en un seul parcours de l'espace de recherche, une solution optimale (ou proche de l'optimal) et les optima locaux.

La diversité des solutions, en réponse à un problème d'optimisation par simulation d'un système, va permettre d'intégrer d'autres considérations non incluses dans la fonction objectif ni dans le modèle de simulation notamment celles de plusieurs décideurs dans un cas de prise de décision collaborative. Pour cela, nous avons élaboré une approche basée sur la méthode AHP permettant de collecter les préférences des membres d'une équipe de décideurs exprimées par rapport aux alternatives de conception du système et de les agréger, afin d'obtenir celle qui répond au mieux à leurs exigences. Cette deuxième approche nous a permis de déterminer des solutions de conception et d'organisation d'un système d'une façon collective.

Nous avons pu exploiter la flexibilité pour intégrer aussi la prise en compte de l'incertitude des données relatives au fonctionnement d'un système dans une étude d'optimisation via simulation. Pour cela, nous avons suggéré une approche capable de déterminer des systèmes qui ne soient pas uniquement performants mais aussi robustes aux changements de leurs conditions opératoires. Cette troisième proposition nous a permis de mettre en évidence les situations qui contribuent à la robustesse ou à la non robustesse d'un système en gérant mieux la répartition des coûts de calcul par rapport aux approches employant des métaheuristiques. En effet, plutôt que d'évaluer un grand nombre de solutions selon différents environnements, tel que l'approche couplant un module de robustesse avec un algorithme d'optimisation évolutionniste via simulation nous avons largement limité le recours au module d'évaluation.

Afin d'illustrer l'efficacité et le potentiel des approches proposées, nous les avons testées sur un exemple d'application d'une boucle de supply chain, constituée d'une centrale de distribution et d'un fournisseur. Dans cet exemple, nous avons pu fournir diverses alternatives permettant d'optimiser le nombre de kanbans, les tailles de lots de production et de transport utilisés dans l'atelier de production du fournisseur pour répondre aux offres de commandes passées par la centrale de distribution.

Ensuite, nous avons pu prendre en compte de façon concrète les préférences individuelles des responsables, gérant ce système, et établir un classement des alternatives de dimensionnement du système. Ce classement démontre que la solution acceptée par tous les décideurs est autre que celle qui possède la meilleure performance. Pour terminer, nous avons pu déterminer

aussi les alternatives de dimensionnement qui restent performantes malgré l'incertitude des commandes des produits. En résultat, un choix d'alternatives de dimensionnement robustes a pu être fourni aux décideurs du système.

Dans ce mémoire, nous avons proposé de nouvelles approches d'introduction de la flexibilité et de l'incertitude dans l'optimisation via simulation. Cependant, ces travaux induisent des perspectives à plus ou moins long terme.

Ainsi, bien que nous ayons déjà illustré l'efficacité de nos approches sur un exemple de chaîne logistique, nous comptons poursuivre les expérimentations et les applications sur des cas concrets. En effet, l'approche de flexibilité décisionnelle paraît adaptée à un large spectre de problèmes où l'on cherche à avoir de la souplesse dans le choix de la solution à mettre en œuvre. Parmi les possibilités, nous pourrions adapter notre approche à des systèmes de l'industrie manufacturière ou aux services de la santé avec la perspective de déterminer des alternatives d'organisation ou de réorganisation performantes et diversifiées. De même, son application dans des problèmes d'ordonnements dans les systèmes de production pourrait être une perspective intéressante.

Une autre perspective à court terme concerne l'implémentation de l'approche multimodale via simulation. Dans la littérature, d'autres approches multimodales offrent un potentiel qui mérite d'être exploité. Il nous semble intéressant d'utiliser, par exemple, une approche plus adaptée à des problèmes à variables mixtes notamment les techniques basées sur les stratégies d'évolution, l'évolution différentielle ou l'intelligence des essaims particuliers (cf. Zhang et al, 2006).

Pour trouver les relations de dominance des solutions selon les différents environnements, d'autres théories peuvent être utilisées avec l'approche proposée traitant l'impact de l'incertitude. Nous citons par exemple les relations de dominance probabilistes où la probabilité qu'une solution domine l'autre est calculée (Cf. Hughes, 2001 ;Teich, 2001 ;Iskandari et al.,2008).

Par ailleurs, bien que cette dernière approche nous a permis de réduire les temps de calcul, une perspective serait, par exemple, de prévoir la mise en place d'une approche distribuée (cf.

Pierreval et Paris, 2000). Son application dans les études d'optimisation via simulation contribuerait en effet à obtenir des procédures de calculs meilleures.

Une dernière perspective consisterait à traiter le problème d'optimisation via simulation à objectifs multiples et la prise en compte de l'incertitude. En effet, la prise en compte de plusieurs objectifs nécessite l'étude de comparaison de solutions qui présentent des résultats différents sur plusieurs objectifs et sur divers environnements. Leur ajouter un contexte de simulation stochastique (e. g. Pareto domination en contexte aléatoire) augmentera encore plus les comparaisons et donc le nombre d'évaluations par simulation. Ce type de problème est donc très coûteux en temps de calcul. Une perspective serait de proposer des méthodes permettant d'optimiser la répartition des budgets de calcul notamment en gérant au mieux les solutions à comparer selon les objectifs, les environnements et le contexte aléatoire (Cf. Mebarki et Castagna, 2000 ; Chen et al, 2008 ; Lee et al, 2010).

BIBLIOGRAPHIE

- Alberto, I., Azacàrate, C., Mallor, F., Mateo, P.M., 2002, Optimization with simulation and multi-objective analysis in industrial decision-making: A case study. *European Journal of Operational Research*, 140(2), pp 373-383.
- Al-Aomar, R., 2006, Incorporating robustness into genetic algorithm search of stochastic simulation outputs, *Simulation modelling practice and theory*, 14 , pp 201-223.
- Al-Najjar, B., Alsayouf, I., 2003, Selecting the most efficient maintenance approach using fuzzy multiple criteria decision making, *International Journal Of Production Economics*, 84, pp 85-100.
- Ammeri, A., Hachicha, W., Masmoudi, F., Chachoub, H., 2011, A comprehensive literature review of monobjective simulation optimisation methods, *Advances in Production Engineering and Management* 6 (4), pp 291-302.
- Andradottir, S., 2007, *Simulation Optimization*, in: Banks, J. (Ed.), John Wiley & Sons, Inc. Chapter 9 in: *Handbook of Simulation: principles, methodology, advances, applications, and practice*, Hoboken New Jersey, USA, Doi: 10.1002/9780470172445.
- Angün, E., 2011, A risk-averse approach to simulation optimization with multiple responses *Simulation Modelling Practice and Theory*, 19(3), pp 911–923
- Azadivar, F., Tompkins, G., 1999, Simulation optimization with qualitative variables and structural model changes: A genetic algorithm approach. *European journal of Operational Research*, 113, pp 169-182.
- Baccouche, A., Pierreval, H., Huyet, A.-L., 2009, Simulation optimization in uncertain environments : an evolutionary approach, *Proceedings of the 13th IFAC Symposium on Information Control Problems in Manufacturing (INCOM'09)*, Moscou, 13(1), pp 1487-1492.
- Baccouche, A., Huyet, A.-L., Pierreval, H., Feyeche, B., 2010, Multimodal optimization of simulated systems, *Proceedings of the 7th EUROSIM Congress on Modelling and Simulation*, Prague, Czech Republic, 1 -Book of abstracts- , ISBN: 978-90-01-04588-6.
- Baccouche, A., Goren, S., Huyet, A.-L., Pierreval, H., 2011, An approach based on simulation optimization and AHP to support collaborative design with an application to supply chains, *Computational Intelligence In Production And Logistics Systems (CIPLS) IEEE Workshop*, Paris, pp 1-7.
- Bäck, T., 1996. *Evolutionary algorithms in theory and practice*. Oxford University Press.
- Bäck, T., Schwefel H.P., 1993, An overview of Evolutionary Algorithms for Parameter Optimization, *Evolutionary Computation*, 1(1), pp 1-23.
- Beasley, D., Bull, D. R., Martin, R. R., 1993, A sequential niche technique for multimodal function optimization, *Evolutionary computation*, 1(2), pp 101-125.
- Benamer L., Alami J., El Imrani A., 2010, A hybrid discrete particle swarm algorithm for solving the fixed-spectrum frequency assignment problem, *International Journal of Computational Science and Engineering*, 5(1), pp 68-73.

- Benjamin, P., Erraguntla, M., Mayer, R., 1995, Using simulation for robust design, *Simulation*, 65(2), pp 116-127.
- Ben-Tal, A., Nemirovski, 1998, A robust convex optimization. *Mathematics of Operational Research*, 23(4), pp 769-805.
- Bertsimas, D., Sim, M., 2004, The price of robustness, *Operations Research*, 52(1), pp 35-53.
- Bertsimas, D., Nohadani, O., Teo, K., 2009, Non convex robust optimization for problems with constraints. *INFORMS journal on computing*, Articles in advance, pp 1-15.
- Beyer, H. -G., Sendhoff, B., 2007, Robust optimization: A comprehensive survey, *Computer methods in applied Mechanics and Engineering*, 196, pp 3190-3218.
- Boyle, C. R., Shin, W.S., 1996, An interactive multiple-response simulation optimization method, *IIE Transactions*, 28(6), pp 453-462.
- Brits, R., Engelbrecht, A., Van den Bergh F., 2002a, Solving systems of un-constrained equations using particle swarm optimization, *Proceedings of the IEEE Conference on Systems, Man, and Cybernetics*, Tunisia, 3, 6 pages.
- Cerny, V., 1985, Thermodynamical approach to the travelling salesman problem : An efficient simulation algorithm, *Journal of optimization theory applications*, 45, pp 41-51.
- Chelouah, R., Siarry, P., 2000, A Continuous genetic algorithm designed for the global optimization of multimodal functions, *Journal Heuristics*, 6(2), pp 191-213.
- Chen, W., Allen, J.K., Tsui, K-L, Mistree, F., 1996, A procedure for robust design, *ASME Journal of Mechanical Design*, 118 (4), pp 478-485.
- Chen, C. H., He, D., Fu, M., Lee, H., 2008, Efficient Simulation Budget Allocation for Selecting an Optimal Subset, *Inform Journal on Computing*, 20(4), pp 579-595.
- Collette, Y., Siarry, P., 2002, *Optimisation multiobjectif*, Edition EYROLLES.
- Davenport, A.J., Beck, J.C., 2000, A survey for techniques for scheduling with uncertainty, Unpublished, available from <http://www.eil.toronto.ca/profiles/chris/chris.papers.html>.
- De Castro, L.N., Timmis, J., 2002, *Artificial immune systems: a new computational intelligence approach*. Springer-Verlag, London, ISBN 1-85233-594-7
- Dellino, G., 2008, Robust Simulation-Optimization using Kriging Metamodels, *Proceedings of the 2008 Winter Simulation Conference*, pp 570-576
- Dellino, G., Kleijnen, J.P.C., Meloni, C., 2010, Robust Optimization in Simulation: Taguchi and Response Surface Methodology, *International Journal of Production Economics*, 125(1), pp 52-59.

- Dellino, G., Kleijnen, J.P.C., Meloni, C., 2009, Robust Simulation-Optimization using Metamodels, *Proceedings of the 2009 Winter Simulation Conference*, pp 540-550.
- Deng, G., 2007. Simulation-based optimization. Dissertation, University of Wisconsin, USA.
- De Jong, K. A., 1975, *An Analysis of the behavior of a class of genetic adaptive systems*, Dissertation, University of Michigan.
- Doltsinis, I., Kang Z., 2004, Robust design of structures using optimization methods, *Computer Methods in Applied Mechanics and Engineering*, 193, pp 2221-2237.
- Durieux, S., 2004, *Analyse de performance par simulation et conception de systèmes de production robustes*, thèse de l'université Blaise Pascal, Clermont Ferrand II, 204 pages.
- Durieux, S., Pierreval, H., 2003, De la notation de robustesse dans les études de simulation, *Actes de la Conférence francophone en Modélisation et Simulation 2003*, pp 586-591.
- El Imrani, A. A., Bouroumi A., Zine El Abidine H., Limouri M., Essaïd A., 1999, A fuzzy clustering-based niching approach to multimodal function optimization, *Journal Cognitive Systems research*, 1(2), pp 119-133.
- Fu, M. C., 2002. Optimization for simulation : theory vs. practice. *INFORMS Journal on Computing* , 14 (n°3), 192-215.
- Fu, M. C., Glover, F. W., April, J., 2005, Simulation optimization: a review, new developments, and applications, *Proceedings of the 2005 Winter Simulation Conference*, Piscataway, New Jersey, USA, pp 83-95.
- Gan, G., Warwik, K., 1999, A genetic algorithm with dynamic niche clustering for multimodal function optimization, *Proceedings of International Conference on Artificial Neural Network and Genetic Algorithms*, pp 248-255.
- Gaury, E., 2000, *Designing pull production control systems: customization and robustness*, Thèse de l'université Blaise Pascal, Clermont- Ferrand II, 126 pages.
- Gerencser, L., Hill, S. D., Vago, Z., et Vincze, Z., 2004, Discrete optimization, SPSA and markov chain monte carlo methods, *Proceeding of the 2004 American Control Conference*, Boston, pp 3814-3819.
- Giard, V., 1985, *Statistique appliquée à la gestion*, Economica, 479 pages.
- Gien, D., Jacqmart, S., 2005, Design and simulation of manufacturing systems facing imperfectly defined information, *Simulation Modeling Practice and Theory*, 13, pp 465-485.
- Goldberg, D. E., Richardson, J., 1987, Genetic algorithms with sharing for multimodal function optimization, *Proceedings of the 2nd International Conference on Genetic Algorithms*, Cambridge, Massachusetts, USA, pp 41-49.

- Goldberg D. E., Wang L., 1997, Adaptive niching via co-evolutionary sharing, Quagliarella et al (Eds.). *Genetic Algorithms in Engineering and Computer Science* (John Wiley and Sons, Ltd), pp 21-38.
- Golhar, D.Y., Stamm, C.L., 1991, The just-in-time philosophy: a literature review, *International Journal of Production Research*, 29(4), pp 657-676.
- Gören, S., Pierreval, H., 2011, Hybrid flow shop scheduling with several users, *Proceedings of the International Conference on Industrial Engineering and systems management*, Metz, France pp 898 -907.
- Harik, G., 1995, Finding Multimodal Solutions Using Restricted Tournament Selection, *Proceedings on the 6th International Conference on Genetic Algorithms*, Pittsburg, PA, USA, pp. 24-31.
- Harker, P. T., 1989, The art and science of decision making: The analytic hierarchy process, Golder, B. L., Wasil, E. A., Harker, P. T., (Eds.), *The Analytic Hierarchy Process Applications and Studies*, Berlin: Springer, pp 3-36.
- Hajji, O., Brissetts, S., Brochet, P., 2004, A new tabu search method for optimization with continuous parameters, *IEEE Transactions on Magnetics*, 40(2), pp 1184-1187.
- Hill, D. R., 1996, *Object oriented analysis and simulation*. Addison-Wesley Longman. ISBN: 0201877597.
- Ho, W., 2008, Integrated analytic hierarchy process and its applications – a literature review, *European Journal of Operational Research*, 186(1), pp 211-228.
- Hofmeyr, S.A., Forrest S., 1999, Immunity by Design : An Artificial ImmuneSystem, *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO)*, Morgan Kaufmann, San Francisco, CA, pp 1289-1296.
- Huang C.C., Kusiak. A., 1996, Overview of Kanban systems, *International Journal of Computer Integrated Manufacturing*, 9(3), pp 169-189.
- Hughes, E.J., 2001, Evolutionary multi-objective ranking with uncertainty and noise, *Evolutionary multi-criterion optimization EMO 2001*, 1993, pp 329–342.
- Huyet, A-L., Paris, J-L., 2003, Setting and analysis of multiproduct supplier links managed by kanban using a learnig+ evolutionary optimization, *Proceedings of the 2003 Industrial Simulation Conference*, Valencia, Spain, pp 113-117.
- Jichao, X., 1996, Variability detection and robustness design in complex production system, *Computers Industrial Engineering*, 31(3/4), pp 775-778.
- Jin, Y., Branke, J., 2005, Evolutionary optimization in uncertain environments-a survey, *IEEE Transactions on Evolutionary Computation*, 9(3), pp 303 - 317.
- Kaci, S., 2011, *Working with preferences*, New York: Springer. DLC 2011929774.

- Kalagnanam, J.R., U. M. Diwekar., 1997, An efficient sampling technique for off-line quality control, *Technometrics*, 39(3), pp 308-319.
- Kennedy J., 2000, Stereotyping: Improving particle swarm performance with cluster analysis, *Proceedings of the IEEE Congress on Evolutionary Computation*, San Diego, California, U.S.A., pp 1507-1512.
- Kirkpatrick, S., Gelatto, C., et Vecchi, P., 1983. Optimization by simulated annealing. *Science* , 221, 671-680.
- Kjellberg, A., Sohlenius, G., 1993, Principles of multidisciplinary cooperation in research, *Especially Behavioural Science and Manufacturing CIRP Annals - Manufacturing Technology*, 42(1), pp 541-543.
- Kleijnen, J. P., 2008. *Design and analysis of simulation experiments*. Springer.
- Kleijnen, J. P., 2008a, Response surface methodology for constrained simulation optimization: an overview, *Simulation Modelling Practice and Theory* , 16, 50-64.
- Kleijnen, J., 2009. Sensitivity Analysis of Simulation Models. *Center Discussion Paper Series No.2009-11*. Available at SSRN:<http://ssrn.com/abstract=1340449>.
- Kalagnanam, J.R., Diwekar, U.M., 1997, An efficient sampling technique for off-line quality control, *Technometrics*, 39(3), pp 308-319.
- Koulouriotis, D., Xanthopoulos, A., et Tourassis, V., 2010. Simulation optimization of pull control policies for serial manufacturing lines and assembly manufacturing systems using genetic algorithms. *International Journal of Production research*, 48(10) , p.2887-2912.
- Krokhmal, P., Zabarankin, M., Uryasev S., 2011, Modeling and optimization of risk, *Surveys in Operations Research and Management Science*, 16(2), pp 49-66.
- Law, A. M., Kelton, W. D., 2000. *Simulation modeling and analysis* (éd. 3rd Edition). New York, MA : McGraw-Hill.
- Lee, L. H., Chew, E. P., Teng, S. Y., Goldsman, D., 2010, Finding the Pareto set for multi-objective simulation models, to appear in *IIE Transactions*.
- Li, X., 2004, Adaptively choosing neighborhood bests using species in swarm optimizer for multimodal function optimization, *GECCO*, pp 105-116
- Li, Y., Ng, S., Xie, M., et Goh, T., 2010, A systematic comparison of metamodeling techniques for simulation optimization in Decision Support Systems. *applied soft Computing* , pp 1257-1273.
- Li, J. P., Balazs, M. E., Parks G., Clarkson P. J., 2002, A species conserving genetic algorithm for multimodal function optimization, *Evolutionary Computation*, 10(3), pp. 207-234.

- Liefooghe, A., 2010, *Métaheuristiques pour l'optimisation multiobjectif : Approches coopératives, prise en compte de l'incertitude et application en logistique*, Thèse de l'université de Lille 1, Lille, 205 pages.
- Lim, D., Ong, Y.-S., Jin, Y., Sendhoff, B., et Lee, B., 2005. Inverse multiobjective robust evolutionary design optimization in the presence of uncertainty. *GECCO 05*.
- Lim, J. M., Kim, k. S., Yum, B. J., Hwang, H., 1996, Determination of an optimal configuration of operating policies for direct-input-output manufacturing systems using the Taguchi method, *Computers Industrial Engineering*, 31(3/4), pp 555-560.
- Lin, C.Y., Liou, J.Y., Yang, Y.J., 1998, Hybrid multimodal optimization with clustering genetic strategies, *Engineering Optimization*, 30 (3/4), pp 263-280.
- Madu, I.E., Madu, C. N., 1999, Design optimization using signal-to-noise ratio, *Simulation and Practice*, 7, pp 349-372.
- Mahfoudh, S.W., 1995, *Niching methods for genetic algorithms*, Doctoral Dissertation/Technical report No. 95001, University of Illinois at Urbana Champaign, Illinois Genetic Algorithm Laboratory.
- Mansouri, A. S., Gallear, D., Askariazad, M. H., 2012, Decision support for build-to-order supply chain management through multiobjective optimization, *International Journal of Production Economics*, 135(1), pp 24-36.
- Mansourinia, F., Aghaie, A., Haddad, A., 2011. A novel approach of classification in simulation optimization methods, *Proceedings of 5th Symposium on advances in science and technology*, Iran. Accessed on January 25, 2012 [Online], Available: <http://5thsastech.khi.ac.ir/com.aspx>.
- Mebarki, N., Castagna, P., 2000, An approach based on Hotelling's test for multicriteria stochastic simulation-optimization, *Simulation Practice and Theory*, 8(5), pp 341-355.
- Medaglia, A.L., Fang, S.C., Nuttle, H.L.W., 2002, Fuzzy controlled simulation optimization, *Fuzzy Sets and Systems*, 127, pp 65-84.
- Mengsheol, O.J, Goldberg, D.E., 1999, Probabilistic crowding : Deterministic crowding with probabilistic replacement , *Proceedings of The Genetic and Evolutionary Computation conference*, 1, pp 409-416.
- Mephu Nguifo, E., 1993, Une nouvelle approche basée sur le treillis de Galois pour l'apprentissage de concepts, *Mathématique, Informatiques et sciences humaines*, N° 124, pp 19-38.
- Mitchell M., Forrest S., 1993, Genetic Algorithms and Artificial Life, Paper 93-11-072.
- ModeFRONTIER software (accessed on January 20, 2012) [Online], Available: http://www.esteco.com/home/mode_frontier/mode_frontier.html
- Olafsson, S., et Kim, J., 2002, Simulation optimization, in E. YÜCESAN, C.-H. Chen, J. L. Snowdon, & J. M. Charnes (Éd.), *Proceedings of the 2002 winter simulation conférence*, San Diego, 1, pp. 79-84.

- Olson, D. L., Fliedner, G., Currie, K., 1995, Comparison of the REMBRANDT system with analytic hierarchy process, *European Journal of Operational Research*, 82(3), pp 522-539.
- Ouabiba, M., Mébarki, N., Castagna, P., 2001, Couplage entre méthodes d'optimisation itératives et modèles de simulation à événement discrets, *MOSIM'01*, Troyes, 7 pages.
- Perrone, G., Zinno, A., Noto La Diega, S., 2001, Fuzzy discrete event simulation: a new tool for rapid analysis of production systems under vague information, *Journal of Intelligent manufacturing*, 12, pp 309-326.
- Petrowski, A., 1996, A clearing procedure as a niching method for genetic algorithms, *Proceedings of the IEEE International Conference on Evolutionary Computation*, Nagoya, Japan, pp 798-803.
- Pierreval, H., 1990. *Les méthodes d'analyse et de conception des systèmes de production, Technologies de pointe*,. Hermès.
- Pierreval, H., Durieux, S., 2002, A two-stage simulation optimization heuristic for robust design, *Proceedings of IEEE System, Man and Cybernetic 2002*, actes sur CD-rom, 6 pages.
- Pierreval, H., Durieux, S., 2007. Robust simulation with a base environmental scenario. *European Journal OF Operational research*, 182 , p.783-793.
- Pierreval, H., et Paris, J.-L., 2000. Distributed evolutionary algorithms for simulation optimization . *IEEE transaction on systems man and cybernetics*, 30(1) , p.15-24.
- Pierreval, H., Caux, C., Paris, J. L., Viguier, F., 2003, Evolutionary approaches to design and optimization of manufacturing systems, *Computers and Industrial Engineering* , 44, pp 339-364.
- Pierreval, H., Baccouche, A., 2012, On the use of several environmental conditions in an evolutionary simulation optimization search, *International ESF Strategic Workshop on Uncertainty Management In Simulation-Optimization Of Complex Systems: Algorithms And Applications*, Rome.
- Pomerol, J.C., 2001, Scenario development and practical decision making under uncertainty, *Decision Support Systems*, 31, pp 197-2004.
- Prekopa, A., Ruszczynski, A., 2002, Optimization Methods and Software (OMS), *Special Issue on Stochastic Programming*, Taylor & Francis Group, 17(3), pp 25-38.
- Price, W., Gravel, M., Nsakanda, A.L., 1994, A review of Optimisation models of kanban based production systems, *European Journal of Operational Research*, 75, pp 1-12.
- Qing, L., GANG, W., Zaiyue, Y., Qiuping, W., 2008, Crowding clustering genetic algorithm for multimodal function optimization, *Applied Soft Computing*, 8, pp 88-95.

- Rosen, S. L., Harmonosky, C. M., Traband, M. T., 2007, A simulation optimization method that considers uncertainty and multiple performance measures, *European Journal of Operational Research*, 181(1), pp 315- 330.
- Rosenblatt, M., Roll, Y., et Zyse, V., 1993. A combined optimization and simulation approach for designing automated storage/retrieve systems. *IIE Transaction*25(1) , p.40-50.
- Roy, B., 1997, Un chaînon manquant en RO-AD : les conclusions robustes, Cahier du laboratoire d'Analyse et de modélisation de systèmes pour l'Aide à la décision, N°144, Université de Paris Dauphine.
- Roy, B., 2010, Robustness in operational research and decision aiding: A multi-faced issue, *European Journal of Operational Research*, 200 , pp 629-638.
- Saaty, T.L., 2009, Decision making with the analytic hierarchy process, *International Journal Services Sciences*, 1(1), pp 83–98.
- Sanchez, S. M., 2000, Robust design: seeking the best of all possible worlds, *Proceedings of the 2000 Winter Simulation Conference*, pp 69-76.
- Sanchez, S. M., Sanchez, P. J., Ramberg, J. S., Moeeni, F., 1996, Effective engineering design through simulation, *International Transaction in Operational Research*, 3(2), pp 169-185.
- Sareni, B., 1999, *Méthodes d'optimisation multimodales associées à la modélisation numérique en électromagnétisme*. Thèse de l'Ecole Centrale de Lyon, 228 pages.
- Schoeman, I.L., Engelbrecht A., 2005, A parallel vector-based particle swarm optimizer, International Conference on Artificial Neural Networks and Genetic Algorithms (ICANNGA'05), Coimbra, Portugal.
- Singh, G., Deb, K., 2006, Comparison of multi-modal optimization algorithms based on evolutionary algorithms, *Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation*, Seattle, Wachington, USA, pp 1305-1312.
- Smith, R., Forrest S., Perelson A. S., 1993, Searching for diverse, cooperative populations with genetic algorithms, *Evolutionary Computation*, 1(2), pp 127-149.
- Swisher, J. R., Hyden, P. D., Jacobson, S. H., et Schruben, L. W., 2004, A survey of recent advances in discrete input parameter discrete-event simulation optimization, *IIE Transactions* , 36, pp 591-600.
- Talbi, E-G., 2009, *Metaheuristics: from design to implementation*, John Wiley & Sons, Inc., Hoboken, NewJersey, USA. ISBN978-0-470-27858-1(cloth)
- Teich, J., 2001, Pareto-front exploration with uncertain objectives, *Evolutionary Multi-Criterion Optimization, EMO 2001*, 1993, pp 314–328.
- Tekin, E., Sabuncuoglu, I., 2004,Simulation optimization: a comprehensive review on theory and applications, *IIE Transactions* , 36, pp 1067-1081.

- Thomsen, R., 2004, Multimodal optimization using crowding based differential evolution, *Proceedings of IEEE Congress on Evolutionary Computation*, pp 1382-1389.
- Triantis, K., Sarangi, S., Kuchta, D., 2003, Fuzzy pair-wise dominance and fuzzy indices: an evaluation of productive performance, *European Journal of operational research*, 144, pp 412-428.
- Tsui, K. L., 1992 . An overview of Taguchi method and newly developed statistical methods for robust design. *IIE Transaction*, 24(5) , p.44-57.
- Vaidya, O.S., Kumar, S., 2006, Analytic hierarchy process: An overview of applications, *European Journal of Operational Research*, 169(1), pp 1-29.
- Van Den Honert, R. C., Lootsma, F. A., 1996. Group preference aggregation in the multiplicative AHP the model of the group decision process and pareto optimality. *European Journal of Operational Research*, 96(2), 363-370.
- Vincke, P., 1989, *L'aide multicritère de la décision*, Université de Bruxelles.
- Wang, H., Johnson, A., Zhang, H., Liang, S., 2010, Towards a collaborative modeling and simulation platform on the Internet, *Advanced Engineering Informatics*, 24(2), pp 208-218.
- Wild, R., Pingnatello, J., 1991, An experimental design strategy for designing robust systems using discrete event simulation, *Simulation*, 57(6) , pp 358-368.
- Xu, T., Moon, D.H., Baek, S.G., 2012, A simulation study integrated with analytic hierarchy process (AHP) in an automotive manufacturing system, *SIMULATION*, 88(4), pp 450-463.
- Yavuz, I.H., Satir., A., 1995, A kanban-based simulation study of a mixed model just-in-time manufacturing line, *International Journal of Production research*, 33(4), pp 1027-1048.
- Yu, E. L., Suganthan, P. N., 2010. Ensemble of niching algorithms. *Information Sciences*, 180(15), 2815-283.
- Yunker, J., Tew, J., 1994. Simulation optimization by genetic search. *Mathematics and computers in Simulation*, 37(1) , pp 17-28.
- Zha, X.F., 2003, Soft computing framework for intelligent human-machine system design, simulation and optimization, *Soft Computing*, 7, pp 184 -198.
- Zhang, Y., 2007. General robust optimization formulation for nonlinear programming. *Journal of optimization theory and application*, 132(1) , p.111-124.
- Zhang J., Huang D.S., Lok T., Lyu M. R., 2006, A novel adaptive sequential niche technique for multimodal function optimization, *Neuro Computing*, 69, pp 2396-2401.
- Ziegler, B. P., Praehofer, H., Kim, T. G., 2000, *Theory of modeling and simulations* ; second edition.