

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

**MINISTRE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE**

Université des Sciences et de la Technologie
Houari Boumediene (U.S.T.H.B.)

Faculté de Génie Electrique et d'Informatique

Département d'Informatique



Thèse

Présentée à l'U.S.T.H.B.
pour l'obtention du diplôme de Magister
en Informatique

Par: M^{elle} Dalila BOUGHACI

**Méta- heuristiques hybrides pour les problèmes
MAX-W-SAT difficiles**

Soutenue le 02 juin 2001

Devant le jury composé de:

Mme. Boumghar F, Maître de conférences (USTHB).....Présidente
Mme. Drias H, Professeur (USTHB)Directrice de thèse
Mr. Saad R, Maître de conférences (Boumerdès).....Examineur
Mr. Azzoune H, Docteur d'état (USTHB).....Examineur
Mme. Benatchba K, Chargée de cours (INI).Invitée

N° d'ordre : 01/2001-M/IN

Table des matières

Introduction générale	1
Chapitre 1 : Le problème de satisfiabilité SAT	
1.1 INTRODUCTION	5
1.2. NOTATION ET FORMULATION DU PROBLEME	6
1.3. QUELQUES VARIANTES DU PROBLEME SAT	7
1.4. METHODES DE RESOLUTION	9
1.4.1. Méthodes constructives.....	9
1.4.2. Méthodes exactes	12
1.4.3. Méthodes itératives	14
1.5. CONCLUSION.....	17
Chapitre 2 : La recherche tabou, les algorithmes génétiques et le recuit simulé	
2.1. INTRODUCTION.....	18
2.2. LA RECHERCHE TABOU.....	18
2.2.1. DOMAINES D'APPLICATION DE LA RECHERCHE TABOU.....	19
2.2.2. DEFINITION.....	19
2.2.3. NOTATION ET FORMULATION DU PROBLEME.....	20
2.2.4. DESCRIPTION DE LA RECHERCHE TABOU.....	21
2.2.5. PARAMETRES DE CONTROLE DE LA RECHERCHE TABOU.....	22
2.2.6. LA NOTION DE MEMOIRE DANS LA RECHERCHE TABOU.....	25
2.2.7. STRATEGIES DE LA RECHERCHE TABOU.....	25
2.3. LES ALGORITHMES GENETIQUES.....	30
2.3.1. La représentation chromosomique.....	30
2.3.2. La population initiale.....	30
2.3.3. Fonction d'évaluation.....	30
2.3.4. Les opérateurs génétiques.....	30
2.4. LE RECUIT SIMULE.....	32
2.4.1. Algorithme du recuit simulé.....	33
2.4.2. L'organigramme de l'algorithme du recuit simulé.....	34
2.5. CONCLUSION.....	34

Chapitre 3 : La recherche dispersée et la recherche locale guidée

3.1. INTRODUCTION	35
3.2. LA RECHERCHE DISPERSEE.....	36
3.2.1 DESCRIPTION DE LA RECHERCHE DISPERSEE.....	38
3.2.2. LA POPULATION INITIALE.....	38
3.2.3. CONSTRUCTION DES SOLUTIONS DE REFERENCE R.....	38
3.2.4. RENOUVELLEMENT DE LA POPULTAION.....	39
3.3.5. LA COMBINAISON	40
3.2.6. METHODE D'AMELIORATION.....	42
3.2.7. LA DIVERSITE.....	43
3.2.8. L'ALGORITHME DE LA RECHERCHE DISPERSEE.....	44
3.3. LA RECHERCHE LOCALE GUIDEE.....	45
3.3.1. LA RECHERCHE LOCALE.....	45
3.3.2. LA RECHERCHE LOCALE GUIDEE.....	46
3.3.3. L'ALGORITHME DE LA RECHERCHE LOCALE GUIDEE.....	48
3.4. CONCLUSION.....	48

Chapitre 4 : Proposition d'algorithmes de résolution de MAX-W-SAT basés sur la recherche dispersée et la recherche locale guidée

4.1. INTRODUCTION	49
4.2. ADAPTATION DE LA METHODE DE RECHERCHE DISPERSEE AU PROBLEME ETUDIE	50
4.2.1. LA POPULATION INITIALE	50
4.2.2. LA FONCTION OBJECTIVE	52
4.2.3. LA GENERATION DE L'ENSEMBLE R.....	52
4.2.4. LES SOLUTIONS ELITES	54
4.2.5 LA CONSTRUCTION DES SOLUTIONS COMBINEES.....	54
4.2.6. L'AMELIORATION.....	56
4.2.7. LE CRITERE D'ARRET.....	56
4.2.8. L'ALGORITHME DE LA RECHERCHE DISPERSEE	57
4.3. ADAPTATION DE LA METHODE DE RECHERCHE LOCALE GUIDEE AU PROBLEME ETUDIE.....	58
4.3.1. LA SOLUTION INITIALE.....	58
4.3.2. LA RECHERCHE LOCALE	58
4.3.3. LA FONCTION OBJECTIVE AUGMENTEE.....	59
4.3.4 L'ALGORITHME DE LA RECHERCHE LOCALE GUIDEE	61
4.4. CONCLUSION.....	61

Chapitre 5 : Résultats expérimentaux

5.1. INTRODUCTION	62
5.2. RESULTATS	63
5.3. INTERPRETATION DES TESTS EFFECTUES	60

Chapitre 6 : Approches hybrides

6.1. INTRODUCTION	68
6.2. La procédure GSAT avec marche aléatoire.....	68
6.3. La recherche tabou avec bruit aléatoire	69
6.4. La procédure GRASP	71
6.5. Approches hybrides.....	72
6.5.1 La recherche dispersée avec marche aléatoire.....	72
6.5.2 La recherche dispersée avec bruit aléatoire.....	73
6.5.3 La recherche locale guidée avec marche aléatoire.....	73
6.5.4 La recherche locale guidée avec bruit aléatoire.....	74
6.6. CONCLUSION.....	75

Chapitre 7 : Validation des approches développées

7.1. INTRODUCTION	76
7.2. REGLAGE DES PARAMETRES.....	69
7.3. RESULTATS.....	70
7.4. CONCLUSION.....	83

Conclusion générale.....	84
Annexe.....	87
Références	99

Résumé

Cette thèse traite un problème réputé difficile qui est la satisfiabilité maximale pondérée (**MAX-W-SAT** en abrégé). Etant donné un ensemble C de clauses sous forme disjonctive définies sur un ensemble X de variables logiques, à chaque clause C_i un poids W_i est associé. Le problème **MAX-W-SAT** consiste à trouver une assignation aux variables de X qui maximise la somme des poids des clauses satisfaites.

Le problème **MAX-W-SAT** suscite un intérêt particulier car il possède plusieurs applications notamment en raisonnement automatique et en démonstration de théorèmes. De plus, La résolution de ce problème a une très grande importance dans le domaine de l'intelligence artificielle, en particulier, dans l'élimination de l'incohérence des bases de connaissances dans les systèmes experts.

L'accent est mis dans ce travail sur les méta- heuristiques ainsi que les voies qu'ouvrent ces approches dans l'optimisation combinatoire. Il a pour but de clarifier le langage obscur qui entoure les concepts sous-jacents, et d'explicitier l'apport précieux qu'offrent actuellement ces méthodes dans l'intelligence artificielle.

Parmi ces méthodes, on trouve la recherche dispersée et la recherche locale guidée, qui bousculent les méthodes classiques et établissent de nouvelles stratégies de recherche.

La recherche dispersée appelée en anglais «**SCATTER SEARCH**» est une méta-heuristique évolutionniste basée population, elle génère de nouvelles solutions en commençant par un ensemble de solutions appelées solutions références. L'approche fonctionne avec un opérateur de combinaison permettant d'obtenir des solutions admissibles.

La recherche locale guidée est une approche basée pénalité. Elle permet, en principe, d'éviter l'optimum local. C'est une amélioration de la recherche locale, elle modifie la fonction objective dans le but d'approcher l'optimum global.

Dans notre étude, nous avons proposé deux solutions au problème **MAX-W-SAT**. La première est basée sur la recherche dispersée alors que la seconde est basée sur la recherche locale guidée. De plus, nous essaierons pour notre part d'améliorer les performances de ces derniers algorithmes en présentant quelques orientations générales pour une hybridation pertinente de quelques heuristiques connues dans la littérature informatique basées sur la recherche tabou, et la procédure GSAT.

Mots clés :

Méta- Heuristique, Heuristique, Satisfiabilité Maximale Pondérée, Recherche Dispersée, Recherche Locale Guidée, NP- Complet, Intensification, Diversification, Bruit aléatoire, Marche aléatoire.

Introduction générale

Un grand nombre de problèmes d'optimisation sont NP- complets. En conséquence, une énumération exhaustive pour trouver la solution optimale est la plupart du temps impossible. On définit alors des heuristiques qui sont des méthodes qui s'approchent en un temps raisonnable d'une «bonne» solution au problème.

Parmi ces méthodes, on trouve la recherche dispersée et la recherche locale guidée qui constituent une alternative intéressante aux techniques classiques pour la résolution des problèmes d'optimisation [GLM 00][Lag 99], en particulier le problème de satisfiabilité (**SAT** en abrégé).

Le problème SAT de la logique booléenne est le premier problème démontré NP- complet. C'est une satisfiabilité propositionnelle : on donne une formule de calcul propositionnel (une conjonction de clauses, où une clause est une disjonction de littéraux et un littéral est une variable ou sa négation), on décide s'il y a une assignation à ses variables qui rend la formule vraie.

D'autre part, le problème SAT concerne surtout le domaine de l'intelligence artificielle puisqu'il est en relation avec celui du raisonnement déductif. De plus, d'autres formes de raisonnement incluant le raisonnement par défaut, diagnostic, planification et l'interprétation d'images font un appel direct à la satisfiabilité.

Dans notre étude, on s'intéresse à une autre variante du problème SAT, appelée satisfiabilité maximale pondérée «**MAX-W-SAT**» qui associe à chaque clause C_i un poids W_i . Le but consiste à trouver une assignation aux variables qui maximise la somme des poids des clauses satisfaites.

Vu le rôle important que présente le problème SAT, plusieurs méthodes ont été développées pour le résoudre : les méthodes exactes et les méthodes approchées.

La figure1 met en parallèle les méthodes représentatives développées en recherche opérationnelle et en intelligence artificielle, avec à titre indicatif la date approximative d'apparition de chaque méthode.

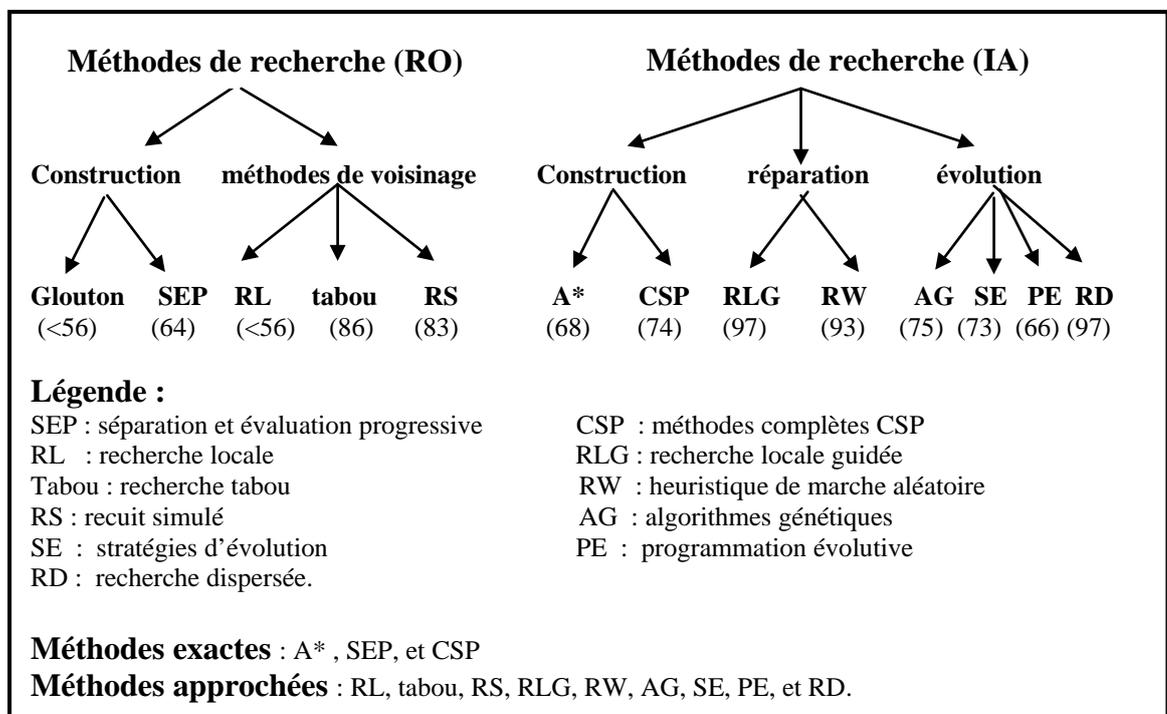


Figure1. Classement des méthodes de résolution.

D'une manière générale, les méthodes de résolution suivent quatre approches différentes pour la recherche d'une solution : l'approche de construction, l'approche de relaxation telle que la relaxation de base en programmation linéaire, l'approche de voisinage et l'approche d'évolution. Ces méthodes font partie de deux groupes de nature différente : le premier groupe comprend les méthodes exactes, et le second groupe comprend les méthodes approchées.

Le principe essentiel d'une méthode exacte consiste généralement à énumérer, souvent de manière implicite, l'ensemble des solutions de l'espace de recherche. Parmi ces méthodes, nous citons les méthodes de séparation et évaluation et la procédure de Davis et Putnam[**BF 97**]. Les méthodes exactes ont permis de trouver des solutions optimales pour des problèmes de taille raisonnable. Cependant, ces méthodes rencontrent généralement des difficultés face aux applications de taille importante.

Les méthodes approchées constituent une alternative très intéressante pour traiter les problèmes d'optimisation de grande taille si l'optimalité n'est pas primordiale. On peut citer les méthodes gloutonnes et l'amélioration itérative : par exemple, la procédure GRASP[**RF 96**], la procédure GSAT[**SHKC 94**], et la recherche locale.

Ces dernières années, des progrès importants ont été réalisés avec l'apparition d'une nouvelle génération de méthodes approchées puissantes et générales, souvent appelées méta- heuristiques.

Les méta- heuristiques sont représentées essentiellement par les *méthodes de voisinage* comme le recuit simulé[**Sia 95**], et la recherche tabou[**Glo 95**], et les *algorithmes évolutifs* comme les algorithmes génétiques[**Hol 92**] et la recherche dispersée[**GLM 00**]. Grâce à ces méta- heuristiques, on peut proposer aujourd'hui des solutions approchées pour des problèmes d'optimisation de plus grande taille.

Notre travail s'intéresse aux méta- heuristiques, en particulier, la recherche dispersée et la recherche locale guidée.

La recherche dispersée appelée en anglais «**SCATTER SEARCH**» est une méta- heuristique basée population, elle génère de nouvelles solutions en commençant par un ensemble de solutions appelées solutions références. L'approche fonctionne avec un opérateur de combinaison permettant d'obtenir des solutions admissibles.

La recherche locale guidée est une approche basée pénalité. Elle permet, en principe, d'échapper à l'optimum local[**Vou 97**]. C'est une amélioration de la recherche locale, elle modifie la fonction objective dans le but d'approcher l'optimum global.

En d'autres termes, la recherche dispersée et la recherche locale guidée procèdent par améliorations successives. La première approche démarre d'une population initiale variée, en explorant des zones *diverses* de l'espace de recherche, et tente de l'*améliorer* tout au long du processus de résolution, alors que la recherche locale guidée est initialisée avec une configuration initiale réalisable qu'elle cherche à améliorer à chaque itération à l'aide d'un algorithme itératif de recherche locale. Pour échapper aux optima – locaux la recherche locale guidée le fait en utilisant une fonction objective augmentée permettant de pénaliser les solutions déjà visitées, la recherche dispersée utilise la diversification et l'amélioration.

L'objet de notre étude consiste à appliquer la recherche dispersée et la recherche locale guidée au problème **MAX-W-SAT**. De plus, nous essaierons pour notre part d'améliorer les performances de ces derniers algorithmes en présentant quelques orientations générales pour une hybridation pertinente de quelques heuristiques connues dans la littérature informatique basées sur la recherche tabou, GSAT et d'autres heuristiques qui vont être exposées dans la suite, et cela dans le cadre de la résolution du problème **MAX-W-SAT**.

Notre document sera organisé comme suit :

Le premier chapitre est consacré aux généralités et aux principaux concepts du problème SAT.

Dans le deuxième chapitre, nous présentons trois méta- heuristiques classiques qui calculent des solutions acceptables : la recherche tabou, le recuit simulé et les algorithmes génétiques.

Nous décrivons au troisième chapitre deux méthodes récentes apparues ces dernières années dans le but de résoudre efficacement les problèmes d'optimisation difficiles : la recherche dispersée et la recherche locale guidée.

Le quatrième chapitre fait un tour d'horizon sur les solutions apportées au problème **MAX-W-SAT** considéré et de manière plus approfondie, deux méta- heuristiques ont été conçues et mises en œuvre à savoir la recherche dispersée et la recherche locale guidée.

Au cinquième chapitre, nous exposons les différents tests numériques réalisés sur plusieurs types de problèmes.

Nous présentons dans le sixième chapitre d'autres algorithmes itératifs : la recherche tabou avec bruit aléatoire, la procédure GRASP, la procédure GSAT avec marche aléatoire, la recherche dispersée hybride, et la recherche locale guidée hybride.

Une étude comparative entre les méta- heuristiques citées ci –dessus est établie au septième chapitre dans le but de tester la performance de la recherche dispersée et de la recherche locale guidée et de prouver leur efficacité, ainsi que leur capacité à résoudre le problème **MAX-W-SAT**.

Enfin, la conclusion générale porte sur les résultats obtenus et dresse quelques perspectives sur la suite de notre travail.

Une annexe est ajoutée à la fin pour élucider les notions non approfondies dans les chapitres.

Chapitre 1 :

Le problème de satisfiabilité SAT

1.1. INTRODUCTION :

Ces dernières années, les méta- heuristiques ont connu un succès grandissant dans les domaines de la recherche opérationnelle et de l'intelligence artificielle. Elles ont prouvé leur efficacité et leur performance dans de nombreux problèmes d'optimisation combinatoire à savoir le problème du voyageur de commerce, les problèmes d'affectation [Vou 97][VT 98], les problèmes d'ordonnancement ainsi que le problème **SAT** [Dri 93].

Le problème de satisfiabilité (**SAT**) est l'ancêtre des problèmes NP- complets. Un problème est dit NP complet si son temps d'exécution s'exprime théoriquement comme une fonction exponentielle de la taille de donnée, ce qui implique l'inexistence des algorithmes polynômiaux pour le résoudre en un temps polynômial.

Beaucoup de problème NP- complets appartiennent à divers domaines, tels que la théorie des graphes (le problème du voyageur de commerce, le problème du circuit hamiltonien et le problème de coloration d'un graphe...), la géométrie, les jeux, la théorie des langages et l'ordonnancement des tâches. Ces problèmes peuvent être formulés comme un problème de satisfiabilité ou une de ses variantes.

D'autre part, le problème **SAT** a un impact sur le domaine de l'intelligence artificielle notamment dans l'élimination de l'incohérence des bases de connaissances dans les systèmes experts, où les implications de la base de connaissance peuvent être transformées sous forme de clauses en utilisant des formules bien connues de l'algèbre de Boole.

Dans ce qui suit, nous allons définir d'une manière formelle le problème de satisfiabilité SAT. Nous citons certaines de ses variantes et nous présentons quelques méthodes de résolution.

1.2. NOTATION ET FORMULATION DU PROBLEME :

Soient :

- X un ensemble de n variables booléennes ;
- C un ensemble de m clauses dont chacune est la disjonction d'un ensemble de littéraux associés aux variables de X, tel que chaque littéral est une variable x_i ou sa négation \bar{x}_i ;

On définit formellement le problème SAT comme une formule logique écrite sous forme normale conjonctive (conjonction de clauses) et on cherche une assignation aux variables de X qui rend cette formule vraie.

$$F = \bigwedge_{1 \leq i \leq m} C_i \quad \text{avec : } C_i = \bigvee_{k \in \{1, \dots, n\}} L_{ik}, \quad L_{ik} \in \{x_j, \bar{x}_j\}, j=1, \dots, n.$$

Une instance de SAT est présentée comme suit :

$$\left\{ \begin{array}{l} C_1 = L_{11} \vee L_{12} \vee \dots \vee L_{1r_1} \\ C_2 = L_{21} \vee L_{22} \vee \dots \vee L_{2r_2} \\ \dots \\ C_m = L_{m1} \vee L_{m2} \vee \dots \vee L_{mr_m} \end{array} \right.$$

Où :

- n est le nombre de variables booléennes x_i ;
- m est le nombre de clauses ;
- r est la longueur d'une clause, c'est -à- dire le nombre de littéraux figurant dans cette clause ;
- L_{ik} est un littéral ;
- r_1, r_2, \dots, r_m sont respectivement les longueurs des clauses C_1, C_2, \dots, C_m .

Une instance est satisfaite quand toutes ces clauses sont vraies, sinon elle sera contradictoire.

Le but est de trouver une assignation aux variables, c'est-à-dire pour chaque variable x_i affecter la valeur vraie =1 ou faux=0, qui satisfasse la conjonction de clauses.

Quand il n'existe pas d'assignation qui rend la formule F vraie, on s'intéresse beaucoup à d'autres variantes du problème SAT.

1.3. QUELQUES VARIANTES DU PROBLEME SAT [Dri 93] [BP 97] [BP 96][MSG 97]:

Le problème SAT peut se trouver sous plusieurs formes. Parmi ces variantes nous citons :

- **Le problème SAT de décision :**

Il permet de répondre par «oui» si la donnée est satisfaite, par «non» si celle-ci est contradictoire.

- **Le problème SAT de recherche des solutions d'une donnée SAT :**

Il consiste en l'exhibition de certaines solutions de la donnée SAT. La résolution de ce problème permet de répondre au problème de décision.

- **Le problème de dénombrement des solutions d'une donnée SAT:**

Il s'agit de déterminer le nombre de solutions de l'instance SAT. La résolution de ce problème permet aussi de répondre au problème de décision associé à SAT.

A ces variantes on peut rajouter les problèmes MAX-SAT, MAX-R-SAT et MAX-W-SAT qui seront présentés comme suit :

✓ **Le problème MAX-SAT :**

Dans le cas où il n'existe pas une assignation qui satisfait toutes les clauses (donnée contradictoire), le problème SAT peut être exprimé en un autre problème appelé **MAX-SAT**. Dans un tel problème on cherche une assignation qui maximise la somme des clauses satisfaites.

✓ **Le problème MAX-R-SAT :**

Dans ce problème toutes les clauses ont une taille inférieure ou égale à R . L'objectif revient aussi à maximiser la somme des clauses satisfaites.

✓ **Le problème MAX-W-SAT :**

Le problème auquel on s'intéresse ici est la satisfiabilité maximale pondérée « **MAX-W-SAT** » qui associe à chaque clause C_i un poids W_i . Le but consiste à trouver une assignation aux variables qui maximise la somme des poids des clauses satisfaites.

On définit formellement le problème MAX-W-SAT comme suit :

Soient :

- $X = \{x_1, x_2, \dots, x_n\}$ un ensemble de n variables booléennes ;
- $C = \{c_1, c_2, \dots, c_m\}$ un ensemble de m clauses formées de littéraux construits à partir de l'ensemble X ;
- A chaque clause c_i un poids positif W_i est associé.
- $c_i = \bigvee_{k \in \{1, \dots, n\}} L_{ik}, \quad L_{ik} \in \{x_j, \bar{x}_j\}, j=1, \dots, n.$
- $F = \sum_{i=1}^m W_i, \quad i \in \{\text{clauses satisfaites}\}.$

⇒ On cherche une assignation aux variables de X qui maximise F .

Le problème MAX-W-SAT consiste à trouver une instanciation qui maximise la somme des poids des clauses satisfaites.

1.4. METHODES DE RESOLUTION :

Les problèmes SAT et MAX-SAT sont NP- complets. Plusieurs méthodes ont été développées pour les résoudre: les méthodes constructives, les méthodes exactes et les méthodes approchées.

1.4.1. Méthodes constructives :

Les méthodes constructives sont basées sur des heuristiques et permettent de construire une solution approchée. Nous citons : les algorithmes de JOHNSON. En 1974, JOHNSON a proposé deux heuristiques de type Glouton john1 et john2. [Joh 74] [JG 79].

• La procédure heuristique John1[Joh 74] :

Cette procédure permet de construire une solution approchée au problème SAT d'une façon progressive. Elle considère à chaque itération le littéral qui apparaît dans le plus de clauses. Ce littéral étant à vrai toutes les clauses où il apparaît sont vraies ; ainsi la solution sera construite à partir des valeurs booléennes pour lesquelles ces littéraux sont vrais.

Algorithme de johnson (john1) :

```
// C : ensemble de clauses.
// U : ensemble des variables booléennes.
// Ens-s : ensemble de clauses satisfaites.
// G : ensemble de clauses – Ens-s.
// Pour chaque littéral l, u(l) est la variable correspondante.
// R est l'assignation aux variables.
```

Début

```
Ens-s =  $\phi$  ;
```

```
G = C ;
```

```
U = { u \ u variable dans C } ;
```

répéter

```
Choisir un littéral l ; // u(l)  $\in$  U et l apparaît dans le maximum
de clauses de G.
```

```
// Soient {Cl1,...,Clk} les clauses dans lesquels l apparaît.
```

```
Ens-s = Ens-s  $\cup$  {Cl1,...,Clk} ;
```

```
G = G - {Cl1,...,Clk} ;
```

```
Si l vrai alors u(l) = vrai Sinon u(l) = faux ;
```

```
U = U - { u(l) } ;
```

```
Jusqu'à ce qu'aucun littéral l,
```

```
avec u(l)  $\in$  U ne soit contenu dans une clause de G.
```

```
Si U  $\neq \phi$  alors pour tout u  $\in$  U faire u = vrai
```

```
Retourner le résultat R
```

Fin

• **La procédure heuristique John2 [JG 79] :**

Cette procédure est une amélioration de la première, elle prend en compte la forme positive ou négative du littéral. Elle considère à chaque itération le littéral qui apparaît dans le plus de clauses. Ce dernier sera vrai si la somme des clauses où il apparaît positif est supérieure à la somme des clauses où il apparaît négatif sinon il sera mis à faux.

Algorithme de johnson (john2) :

// C : ensemble de clauses.
 // U : ensemble des variables booléennes.
 // Ens-s : ensemble de clauses satisfaites.
 // G : ensemble de clauses – Ens-s.
 // Pour chaque littéral l, u(l) est la variable correspondante.
 // R est l'assignation aux variables.

Début

Ens-s = ϕ ;
 G = C ;
 U = { u \ u variable dans C } ;
 Assigner pour chaque clause C_i une masse $W(C_i) = 2^{-|C_i|}$

répéter

Choisir un littéral l ; // u(l) ∈ U et l apparaît dans le maximum de clauses de G.

// Soit CT les clauses de G dans lesquels l apparaît positif .

// Soit CF les clauses de G dans lesquels l apparaît négatif.

Si $\sum_{C_i \in CT} W(C_i) \geq \sum_{C_i \in CF} W(C_i)$

alors

u(l) ← vrai

Ens-s = Ens-s ∪ CT;

G = G - CT;

Pour toute C_i ∈ CT faire

$W(C_i) \leftarrow 2^* W(C_i)$

Sinon

u(l) ← faux

Ens-s = Ens-s ∪ CF;

G = G - CF;

Pour toute C_i ∈ CF faire

$W(C_i) \leftarrow 2^* W(C_i)$

Jusqu'à ce qu'aucun littéral l, avec u(l) ∈ U ne soit contenu dans une clause de G.

Si U ≠ ϕ **alors** pour tout u ∈ U faire u = vrai

Retourner le résultat R

Fin

• **La procédure GRASP [RF 96] [BP 98] :**

C'est une méthode itérative où chaque itération consiste en deux phases, une phase de construction et une phase de recherche locale. Dans la première phase, on construit itérativement une solution qui sera améliorée par la recherche locale dans la deuxième phase.

Plus précisément, dans la phase de construction on utilise une liste candidate contenant toutes les transitions possibles ordonnées selon une certaine fonction Glouton. La solution courante est construite aléatoirement à partir de la liste candidate dans le but d'obtenir une configuration différente à chaque itération.

La fonction Glouton prend en compte l'assignation qui vient d'être faite. Elle est conçue pour maximiser la somme des poids des clauses déjà non satisfaites qui sont devenues satisfaites après une assignation donnée.

Les deux phases de la procédure GRASP sont présentées comme suit :

Phase de construction :

Une solution est construite en exécutant la procédure suivante :

```

procédure construction ()
// n : le nombre des variables booléennes

Pour k=1 → n Faire
- Créer la liste restreinte des assignations candidates;
- Sélectionner aléatoirement une transition ;
- Affecter une valeur de vérité à la variable choisie ;
- Appliquer la fonction Glouton
Fait

```

Phase d'amélioration :

Afin d'améliorer la solution construite par la première procédure, **GRASP** fait appel à une recherche locale. Cette dernière effectue des transformations successives sur la configuration courante dans le but de trouver une solution adjacente. Si le coût de la configuration voisine est meilleur que celui de la solution courante, cette dernière sera remplacée par cette solution voisine, sinon elle sera gardée. Ce processus est réitéré jusqu'à ce qu'aucune amélioration dans la configuration courante ne pourrait être faite

L'algorithme de la recherche locale :

```
// X : la solution construite dans la première phase ;
// Aml = faux, si aucune amélioration ne pourrait être faite dans la configuration courante ;
```

```
Aml := vrai ;
```

Répéter

```
    X' = Meilleur voisin ;
```

```
    Si coût(X') > coût(X) alors X = X' Sinon Aml = faux ;
```

```
Jusqu'à Aml = faux
```

```
Retourner la meilleure solution X ;
```

Par conséquent, on aura l'algorithme GRASP suivant :

Etape 1 : Initialisation

```
- nbiter = 0 ; /* itération courante */
// nbmax : nombre maximum d'itérations
```

Etape 2 : Processus itératif

Tant que (nbiter < nbmax)

Faire

```
- nbiter = nbiter + 1;
- Construction() ;
- Recherche locale() ;
```

Fait**Fin****1.4.2. Méthodes exactes :**

Elles permettent de construire une solution exacte en utilisant soit la programmation linéaire ou bien la programmation dynamique ou les méthodes arborescentes. Pour le problème **SAT**, nous citons la procédure de Davis et Putnam.

- **La procédure de Davis et Putnam[BF 97] :**

Le principe de la procédure de **Davis** et **Putnam** (**DP** en abrégé) revient à réduire l'instance de **SAT** jusqu'à l'obtention d'une sous instance, à partir de laquelle il devient possible de répondre à la satisfiabilité.

L'algorithme de la procédure de **Davis** et **Putnam** est basé sur les deux règles suivantes :

- La règle de la clause unitaire :

Une **clause unitaire** est une clause qui contient un seul littéral. Par convention, une **clause vide** est une clause qui ne contient aucun littéral, et elle est forcément fausse.

La règle de la clause unitaire est appliquée comme suit :

Considérer les clauses unitaires et fixer leur littéral à vrai, puis supprimer toutes les clauses qui contiennent ce littéral **lit**, ainsi que toutes les occurrences négatives de **lit** dans les clauses restantes. Cette règle est appliquée jusqu'à ce que la donnée soit vide (indiquant que la donnée **SAT** est satisfiable), ou qu'elle contient une clause vide (indiquant que la donnée **SAT** est non satisfiable).

- La règle d'éclatement :

Dans le cas où la règle de la clause unitaire n'est pas applicable, l'algorithme de la procédure de **Davis** et **Putnam** s'appuie sur la règle d'éclatement. Cette dernière consiste à choisir une variable **u**, qui n'a pas de valeur de vérité et lui affecter une valeur. Si l'appel de la procédure de Davis et Putnam sur la formule simplifiée retourne non satisfiable, la variable **u** est réinitialisée à la valeur opposée et la procédure **DP** est appliquée de nouveau.

*Après avoir présenté les deux règles utilisées par la méthode de Davis et Putnam , nous donnons dans ce qui suit la procédure **DP** :*

Procédure **DP** :

- Soit un ensemble de clauses **S** défini sur un ensemble de variables **U** ;
- Si **S** est vide alors retourner « satisfiable »
- Si **S** contient une clause vide alors retourner « non satisfiable »

Règle de clause unité :

- Si **S** contient une clause unité **C** alors affecter à la variable mentionnée la valeur de vérité qui satisfait **C**, et retourner le résultat de l'appel de **DP** sur la formule simplifiée.

Règle d'éclatement « Splitting » :

- Sélectionner une variable **u** de **U** qui n'a pas de valeur de vérité ;
- Affecter une valeur de vérité à cette variable, et appliquer **DP** sur la formule simplifiée ;
- Si cet appel retourne «satisfiable» retourner «satisfiable» ;
- Sinon initialiser **u** à la valeur opposée à celle assignée auparavant, et retourner le résultat de l'appel de **DP** sur la formule simplifiée de nouveau.

1.4.3. Méthodes itératives :

Les algorithmes itératifs démarrent d'une configuration initiale et essaient de l'améliorer en effectuant des transformations successives sur la configuration courante. Ce processus est réitéré jusqu'à un certain nombre d'itérations. Parmi ces méthodes nous citons: la procédure **GSAT**, la recherche locale, la technique de recuit simulé, les algorithmes génétiques, et la recherche tabou.

- **La procédure GSAT [SML 92] [SHKC 94]:**

La procédure de base GSAT commence par une solution aléatoire, puis procède de façon répétitive à changer l'affectation de la variable qui mène à la plus grande baisse dans le nombre total des clauses non satisfaites.

Cette procédure se présente de la manière suivante :

```

Soit un ensemble de clauses C
// MAX-ITER : nombre d'itérations ;
// MAX-ESS : nombre d'essais ;
// n : nombre de variables ;
Pour i :=1 à MAX-ESS :
faire
    Soit X une assignation aléatoire
    Pour i := 1 à Max-ITER
    faire
        Si X satisfait C, alors retourner X et arrêter
        Soit  $x_i$  une variable dont le changement de
        l'assignation donne la plus grande baisse dans le
        nombre total de clauses de C qui ne sont pas
        satisfaites par X
        X= X avec la valeur de  $x_i$  inversée.
    fait
fait

```

Les paramètres MAX-ITER et MAX-ESS déterminent respectivement combien de transitions la procédure entreprendra avant d'abandonner et recommencer, et combien de temps cette recherche peut être recommencée avant de quitter.

La procédure GSAT permet de trouver une instanciation pour laquelle on a le maximum de clauses satisfaites. Néanmoins, elle pourrait échouer à trouver une assignation alors qu'elle existe. Pour cet effet, deux extensions de la procédure GSAT ont été introduites : GSAT avec bruit aléatoire et GSAT avec marche aléatoire.

- **GSAT avec marche aléatoire :**

Une stratégie de la «**marche aléatoire**» a été ajoutée à l'algorithme de la procédure **GSAT** pour modifier la règle de choix du voisin, et ça, dans l'algorithme **GSAT avec marche aléatoire**.

Cet algorithme est donné comme suit [BKC 93] :

```

Pour i := 1 à MAX-ESS
  faire
    X := assignation aléatoire
    Pour j := 1 à MAX-ITER
      faire
        Si Randomnbr() < p alors
          Var := variable quelconque ∈ à une clause non satisfaite
        Sinon var := la variable dont Δf est le plus grand
        FLIP(var)
      Fait
    Fait

```

Où :

Randomnbr() : génère un nombre aléatoire entre 0 et 1.

FLIP(var) : inverse la variable var (var := 1- var).

Δf : coût d'une configuration.

MAX-ESS : nombre d'essais.

MAX-ITER : nombre d'itérations.

Principe de résolution :

Vu que l'approche contient certaines étapes avec un choix aléatoire, un certain nombre d'essais est exécuté (MAX-ESS), où Chaque essai consiste en un nombre d'itérations qui égale à MAX-ITER.

A chaque itération une variable est choisie par deux critères différents :

- Avec une probabilité p, choisir une variable d'une clause non satisfaite et inverser sa valeur.
- Avec une probabilité 1-p, appliquer l'algorithme GSAT standard.

- **GSAT avec bruit aléatoire :**

Le principe de cette approche, consiste à faire la sélection aléatoire de la variable à inverser à partir de l'ensemble de toutes les variables et non uniquement celles qui apparaissent dans les clauses non satisfaites. Par conséquent, on aura la procédure suivante :

Procédure **GSAT** avec bruit aléatoire

Pour $i \leftarrow 1$ à **MAX-ESS** **faire**

Pour $l := 1$ to **MAX-ITER** **faire**

- Avec une probabilité p , choisir aléatoirement une variable ;
- Avec une probabilité $1-p$, suivre le schéma de **GSAT** standard ;

Fait

Fait

Où :

MAX-ESS : nombre d'essais.

MAX-ITER : nombre d'itérations.

- **La recherche locale :**

La recherche locale démarre d'une solution initiale possible et essaie de l'améliorer, en cherchant une solution meilleure dans le voisinage courant. Un voisinage d'une solution X correspond à des éléments adjacents à X dont chacun est atteint par un changement dans la configuration courante.

Le processus de recherche est réitéré jusqu'à ce qu'aucune amélioration dans la solution courante ne pourrait être faite.

L'algorithme général de la recherche locale est le suivant:

Soit une solution initiale x ;

Amélior = vrai,

Répéter

$x' = \text{Meilleur Voisin}(x)$;

Si coût(x) < coût(x') **alors** $x = x'$, **Sinon** Amélior = faux **fsi**

Jusqu'à Amélior = faux.

Fin

- **La recherche tabou [Her 95] [Glo 95] :**

La recherche tabou démarre d'une solution initiale aléatoire, puis le meilleur voisin, dans le voisinage courant, est choisi pour être le point courant suivant même s'il est de qualité inférieure au point précédent. Cependant, cette stratégie a tendance à revenir sur des solutions déjà visitées ; c'est pourquoi la recherche tabou utilise une mémoire à court terme; la liste tabou. Cette liste conserve une information sur les dernières itérations de l'algorithme qui permet de se prémunir contre les cycles courts.

- **Les algorithmes génétiques [Gol 89] [Hol 92]:**

C'est un algorithme inspiré de l'évolution naturelle des êtres vivants, il ne considère pas un seul point courant, comme la recherche tabou, mais il fait évoluer toute une population de points. L'algorithme génétique fonctionne avec deux opérateurs : la recombinaison ou croisement et la mutation.

A partir d'une population de points dénommés les parents, cet algorithme construit une nouvelle population (les enfants) en combinant plusieurs parents et en appliquant des modifications aléatoires (mutation).

La phase de sélection produit la population pour l'itération suivante en choisissant les meilleurs points parmi les parents et les enfants.

Habituellement, l'algorithme génétique converge, c'est à dire , la population tend à perdre sa diversité, il perd de son efficacité ; c'est pourquoi la convergence est souvent utilisée comme critère d'arrêt. Toutefois il est fréquent de stopper la recherche après un nombre donné d'itérations (encore dénommées générations).

- **Le recuit simulé [Sia 95] :**

Le recuit simulé est une méthode heuristique inspirée de la thermodynamique ou plus exactement de la physique statique.

Elle est fondée sur une analogie avec le recuit physique des solides, qui consiste à chauffer un matériau à haute température et à le faire refroidir très lentement afin de laisser le système atteindre son énergie minimale.

L'algorithme du recuit simulé génère aléatoirement une nouvelle solution, à partir d'une solution initiale. La nouvelle solution est acceptée ou rejetée, selon un choix effectué par la génération d'un nombre aléatoire, contrôlé par un paramètre T qui est analogue à la température dans le processus physique du recuit.

1.5. CONCLUSION :

Dans ce chapitre, nous avons étudié le problème de la satisfiabilité, certaines de ses variantes, ainsi que quelques méthodes existantes pour sa résolution.

Dans ce qui suit, nous nous intéresserons au problème de la satisfiabilité maximale pondérée MAX-W-SAT. Nous allons contribuer à sa résolution, en utilisant des méthodes basées sur les méta- heuristiques.

Chapitre 2 :

La recherche tabou, les algorithmes génétiques et le recuit simulé

2.1. INTRODUCTION :

La signification exacte d'un problème NP- complet est que jusqu'à présent il n'existe pas d'algorithmes déterministes pour le résoudre en un temps polynomial. Pour contourner cet obstacle, les chercheurs se sont intéressés à une classe d'algorithmes très intéressante permettant de trouver des solutions acceptables aux problèmes NP- complets en un temps raisonnable, ce sont les Méta-heuristiques.

Ces dernières se caractérisent par leur conception et leur philosophie, elles reposent sur des outils mathématiques comme les fonctions à optimiser et de contrôle, qui visent à éviter les solutions de mauvaise qualité.

Ces algorithmes constituent actuellement les algorithmes itératifs produisant les meilleurs résultats. La recherche tabou, les algorithmes génétiques et le recuit simulé font partie intégrante de ces algorithmes.

2.2. LA RECHERCHE TABOU :

Introduite par **Fred Glover** en 1977 [**Glo 89**] et développée plus tard [**Glo 90**], la recherche tabou est considérée comme étant une puissante procédure d'optimisation, capable d'organiser et de diriger les opérations d'une méthode subordonnée. Indépendamment, **Hansen** et **Jaumard** ont développé une méthode très similaire pour résoudre un problème particulier d'optimisation combinatoire qui est le problème de la satisfiabilité maximale [**HJ 89**].

2.2.1. DOMAINES D'APPLICATION DE LA RECHERCHE TABOU :

La méthode de la recherche tabou a remporté un immense succès dans la résolution de nombreux problèmes d'optimisation combinatoire. En effet, cette méthode a été adaptée à des problèmes d'ordonnancement, de productique, de distributive, et d'optimisation dans les graphes.

La table ci-dessous met en relief les différents domaines d'application de la recherche tabou :

SCHEDULING	: Scheduling, job-shop, flow-shop.
CONCEPTION	: Conception assistée par ordinateur, Conception de réseaux de transport.
ALLOCATION	: Affectation quadratique.
INTELLIGENCE ARTIFICIELLE ET LOGIQUE	: <u>Satisfiabilité maximale</u> , Réseau de neurones.
TECHNOLOGIE	: distribution de l'énergie électrique.
TELECOMMUNICATIONS	: Conception de réseaux pour les services.
PRODUCTION	: manufacture flexible.
OPTIMISATION DE GRAPHE	: Partitionnement de graphes, coloration de graphes
DOMAINES D'APPLICATION DE LA RECHERCHE TABOU	

2.2.2. DEFINITION :

La définition littérale du mot tabou est l'interdiction, pour un groupe de gens particulier, de certaines paroles ou actions pour des raisons sociales ou religieuses. Cependant, la méthode de recherche tabou est définie autrement. C'est une procédure suboptimale caractérisée par sa simplicité et sa façon de construire une mémoire dans laquelle se trouvent les solutions réalisables recherchées.

L'information fournie par cette mémoire assure que :

- ❖ La procédure de recherche continue ses investigations et ce dans le but de trouver de nouvelles solutions.
- ❖ La procédure de recherche ne sera pas piégée dans des optima- locaux et ce en les évitant.

C'est une procédure qui opère par améliorations successives, elle est conçue pour converger vers l'optimum global du problème considéré. Elle commence par une solution initiale et tente de l'améliorer au fur et à mesure que la recherche progresse.

En outre, la recherche tabou est caractérisée par sa grande capacité d'échapper aux optima- locaux en utilisant une mémoire à court terme appelée : « liste tabou ». elle permet également le retour à des solutions déjà explorées qui à travers une autre direction peuvent mener à de meilleures solutions. Cette façon de réexploiter ces solutions se fait grâce à une valeur dite : « valeur d'aspiration ».

2.2.3. NOTATION ET FORMULATION DU PROBLEME [Glo 95][LG 93] :

La recherche tabou peut être présentée comme un processus itératif, dans lequel plusieurs acteurs ont contribué en développant des techniques qui permettent de résoudre plusieurs catégories de problèmes d'optimisation combinatoire.

On définit le problème à résoudre comme suit :

X est un ensemble fini de solutions réalisables et f une fonction objective définie dans X à valeurs réelles.

$$\begin{aligned} f : X &\rightarrow \mathbb{R} \\ s &\rightarrow f(s) \end{aligned}$$

Le but est de trouver une solution s^* tel que $f(s^*) = \mathbf{MIN}_{s \in X} f(s)$

Ce problème peut être représenté sous cette forme :

$$(P) \left\{ \begin{array}{l} \mathbf{MIN} f(s) \\ s \in X \end{array} \right.$$

Pour chaque solution s de X , on introduit $V(s)$ comme étant l'ensemble des solutions voisines de s . Le processus tabou démarre d'une solution initiale réalisable quelconque s .

On définit une procédure itérative pour atteindre la solution optimale de (P) comme un processus qui passe d'une solution s à une solution s' dans X , en le répétant autant de fois que nécessaire.

Dans le but de garder la simplicité de la procédure, le passage d'une solution à une autre solution, doit se faire par le biais d'une transformation notée : TR. Soient M l'ensemble de transformations et $M_s \subset M$ l'ensemble des transformations qui donnent une solution $s' = TR(s)$ dans X , donc on définit le voisinage de la solution s par : $V(s) = \{ s' / \exists TR \in M_s : s' = TR(s) \}$.

2.2.4. DESCRIPTION DE LA RECHERCHE TABOU :

L'idée principale de la recherche tabou est d'accepter une solution même si son coût est supérieur à celui de la solution courante. En d'autres termes, si le voisinage $V(s)$ de la solution s ne contient pas de meilleures solutions que s , présenté dans $V(s)$.

En effet, la technique tabou détermine à chaque itération une nouvelle solution parmi l'ensemble des solutions voisines de la solution courante et tel que son coût est le plus faible, ceci permet de choisir le moins mauvais des voisins, c'est à dire celui qui donne un accroissement aussi faible que possible de la fonction objective [Her 95].

L'inconvénient que présente une méthode basée sur cet unique principe est que : si un minimum local est atteint, un mouvement d'une solution s vers une solution s' tel que $f(s) > f(s')$ peut provoquer le mouvement inverse à l'itération suivante, puisque s est voisin de s' et $f(s') < f(s)$. On risque ainsi de cycler autour de ce minimum local. C'est pour cette raison que la méthode tabou s'appuie sur un deuxième principe qui consiste à garder en mémoire les dernières solutions visitées et à interdire le retour vers celles-ci pour un nombre fixé d'itérations, le but étant de donner assez de temps à l'algorithme pour lui permettre de sortir de toute «vallée» contenant un minimum local [Her 95].

Ainsi, la méthode tabou conserve à chaque étape une liste de solutions tabous dite : «liste tabou ». L'espace nécessaire pour sauvegarder un ensemble de solutions tabous peut s'avérer gourmand en place mémoire. Pour cette raison, il est préférable d'interdire uniquement un ensemble de mouvements qui ramènerait à une solution déjà visitée. Ces mouvements interdits sont appelés : «**mouvements tabous**».

2.2.5. PARAMETRES DE CONTROLE DE LA RECHERCHE TABOU [Her 95]:

- **Le voisinage :**

La recherche tabou nécessite que pour toute solution $s \in X$, il existe un sous-ensemble appelé $V(s)$ qui consiste en les solutions réalisables qui peuvent être atteintes par s en un seul mouvement.

Pour certains problèmes, le voisinage $V(s)$ de la solution courante s a une grande taille et le seul moyen de déterminer la solution s' minimisant f sur $V(s)$ est de passer en revue l'ensemble $V(s)$ tout entier, on préfère alors générer un sous-ensemble $V^* \subset V(s)$ ne contenant qu'un échantillon de solutions voisines à s et on choisit la solution $s' \in V^*$ de valeur $f(s')$ minimale.

- **La liste tabou :**

Dans la recherche tabou la meilleure solution s' dans $V(s)$ est acceptée (même si $f(s') > f(s)$, en tenant compte de certaines conditions), par conséquent, on peut facilement retomber sur une solution s déjà explorée, pour éviter de cycler autour de cette dernière, on interdit les modifications qui conduisent vers des solutions déjà visitées, pour cela, on introduit une liste LT appelée : liste tabou dans laquelle toute solution non permise ou interdite est recensée [Glo 95].

En d'autres termes, cette liste de longueur K (fixe ou variable) est utilisée pour conserver les derniers mouvements réalisés sous forme de couple (s, s') c'est à dire quand un mouvement est fait de s vers s' , on introduit le mouvement qui a donné s' à la fin de la liste LT et on rejette le plus ancien, ainsi le retour à s n'est pas autorisé pendant une durée fixe (pendant $|LT| = K$ itérations) dite : tabou tenure. La solution s' est dite «solution tabou» et tout mouvement de s vers s' est un «mouvement tabou».

La meilleure solution s' est gardée dans LT si $s' \notin LT$. Cette condition est appelée «condition tabou» et les solutions gardées dans LT ont un caractère de «statut tabou» [LG 93].

- **Fonction d'aspiration :**

Lors du choix de la meilleure solution $s' \in V(s)$, il est possible que l'on ait à départager plusieurs candidats donnant certes une même valeur à la fonction objective, mais ne nous dirigeant pas tous vers un optimum global. Il est ainsi parfois souhaitable de pouvoir retourner vers une solution visitée s , malgré le fait qu'elle fasse partie de liste LT des solutions taboues, ceci afin d'exploiter une nouvelle région voisine de s .

Pour cette raison, la méthode tabou fait intervenir un nouvel ingrédient appelé **fonction d'aspiration** et définie sur toutes les valeurs de la fonction objective :

Lorsqu'une solution s' voisine de la solution s fait partie de LT et satisfait de plus l'aspiration (c'est à dire $f(s') < A(f(s))$), on lève le statut tabou de cette solution s' et elle devient donc candidate lors de la sélection du meilleur voisin de s . En général, $A(f(s))$ prend la valeur de la meilleure solution s^* rencontrée (on «aspire » donc à déterminer une solution meilleure que s^*).

- **Critère d'arrêt :**

Pour assurer la finitude de la procédure tabou, un critère d'arrêt est introduit comme suit : Si aucune amélioration n'est produite pour s^* pendant un nombre maximum d'itérations, on peut alors stopper la recherche.

En d'autres termes, le processus itératif peut être interrompu quand on est très proche de la solution optimale f^* , pour ce faire, on fixe un nombre maximum $nbmax$ d'itérations entre deux améliorations de la meilleure solution s^* rencontrée. Dès que $nbmax$ itérations sont effectuées sans améliorations, le processus s'arrête.

Dans certaines applications, il est possible de déterminer une borne inférieure f^* de $f(s)$ $s \in X$. $nbmax$ est défini de telle sorte que l'espace des solutions soit parcouru d'une manière exhaustive. De là, un autre critère d'arrêt est retenu, il est présenté comme suit :

On arrête le processus quand $f(s^*)$ atteint f^* où s^* est la meilleure solution trouvée jusqu'ici [Her 95].

L'organigramme illustrant le processus tabou est le suivant :

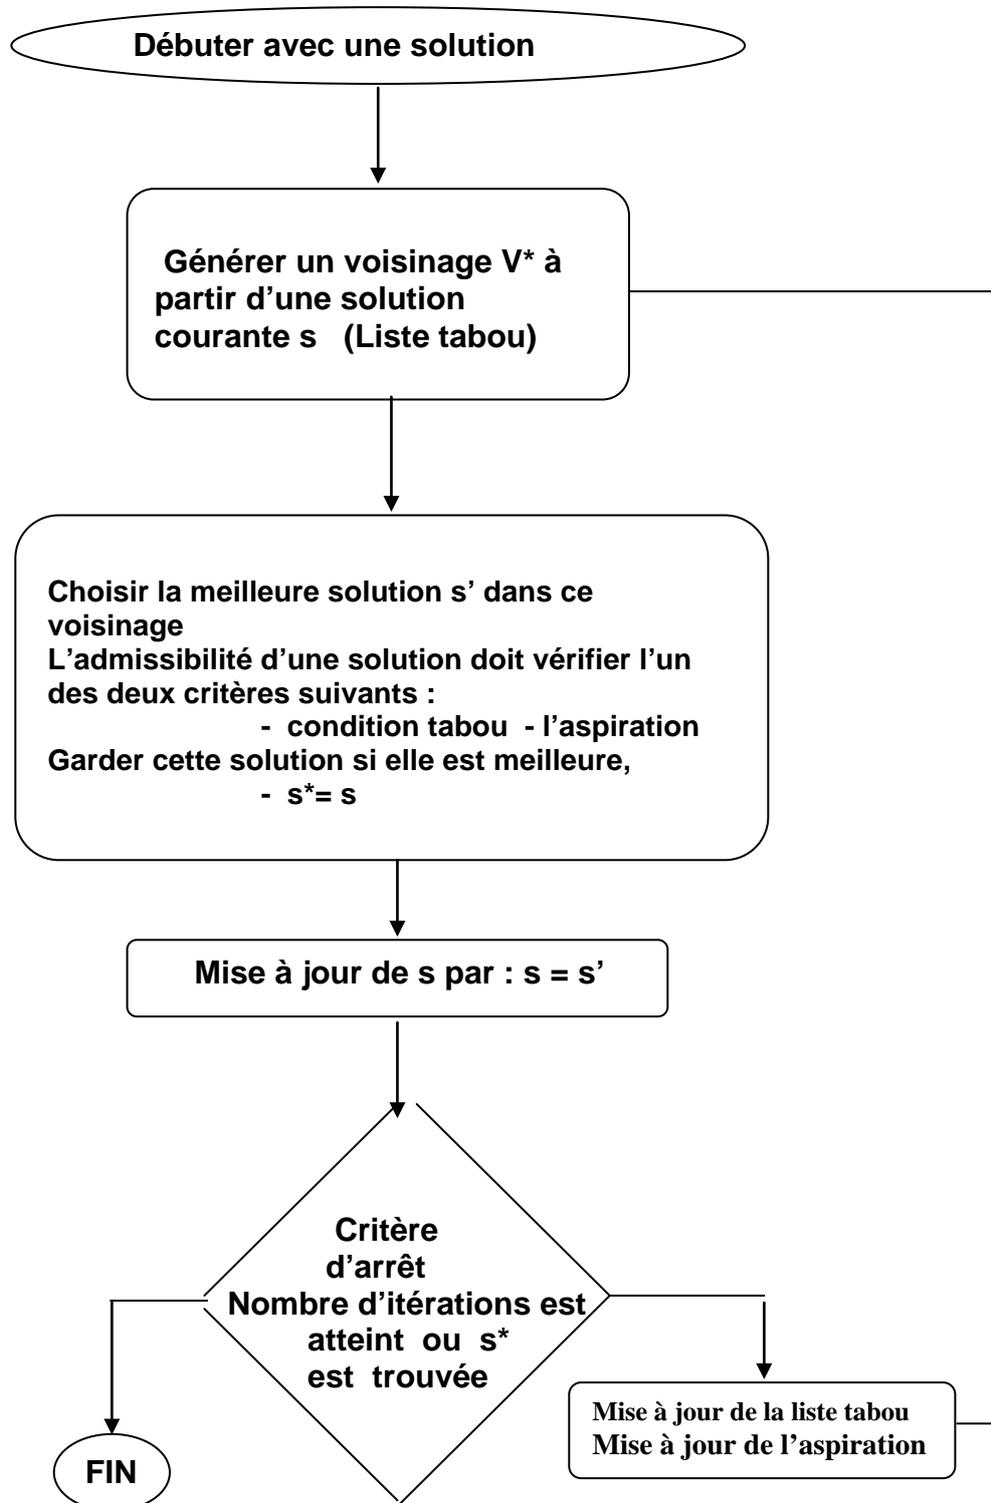


Figure 2.1. Organigramme de la recherche tabou

2.2.6. LA NOTION DE MEMOIRE DANS LA RECHERCHE TABOU [Glo 96] [LG 93] :

Une importante distinction dans la recherche tabou provient en différenciant entre la mémoire à court terme et la mémoire à long terme. Chaque type de mémoire est accompagné de ses propres stratégies. La plus utilisée, la mémoire à court terme. Elle fournit le chemin des solutions qu'elle a échangé durant le passé récent, elle est appelée : mémoire à base récente [Glo 95]. Cette mémoire est exploitée en assignant la désignation tabou aux solutions récemment visitées. Ceci empêche certaines solutions du passé récent d'être revisitée.

Dans quelques applications, les composantes de la mémoire à court terme sont suffisantes pour produire des solutions de haute qualité. Cependant, en général, la recherche tabou devient fermement significative par l'inclusion de mémoire à long terme et ses stratégies. L'utilisation de la mémoire à long terme ne requiert pas de longues exécutions avant que ses bénéfices deviennent visibles. Souvent, ces améliorations se manifestent et permettent la recherche de solution dans un court espace de temps.

La fonction de mémorisation à long terme consiste en une stratégie semblable à la stratégie de mémorisation à court terme, sauf qu'au lieu de centrer la recherche sur des régions contenant des bonnes solutions déjà trouvées, elle guide le processus de recherche à des régions qui ont un aspect différent de ceux déjà examinés.

Le principe de la mémoire à long terme consiste à pénaliser les solutions déjà visitées par le nombre de fois de leur apparition, multiplié par un facteur λ permettant d'augmenter leur fonction objective. Cela est réalisé en utilisant une mémoire dite «**mémoire basée fréquence**». Cette dernière consiste en l'enregistrement des caractéristiques d'un nombre de meilleures solutions sélectionnées et générées durant le processus de recherche.

Les stratégies de la mémoire à long terme prennent avantages de l'histoire de la recherche pour atteindre deux principaux buts : l'intensification régionale et la diversification globale.

2.2.7. STRATEGIES DE LA RECHERCHE TABOU :

- **Stratégies d'intensification :**

Elles sont désignées pour intensifier la recherche dans une région spécifique, elles sont basées sur la modification des règles de choix pour encourager les combinaisons de mouvements et les caractéristiques des solutions trouvées bonnes historiquement.

L'approche opère en enregistrant et en comparant les caractéristiques d'un nombre choisi de meilleures solutions générées durant une période particulière de la recherche.

- **Stratégies de diversification :**

Contrairement à l'intensification, la diversification guide le processus aux régions qui marquent des différences entre celles examinées auparavant.

L'approche diffère des autres méthodes qui cherchent la diversité en générant une recherche heuristique désignée pour produire un nouveau point de départ. Ces stratégies sont basées, généralement, sur la modification des règles de choix pour envoyer les attributs avec une reprise partielle ou totale du processus.

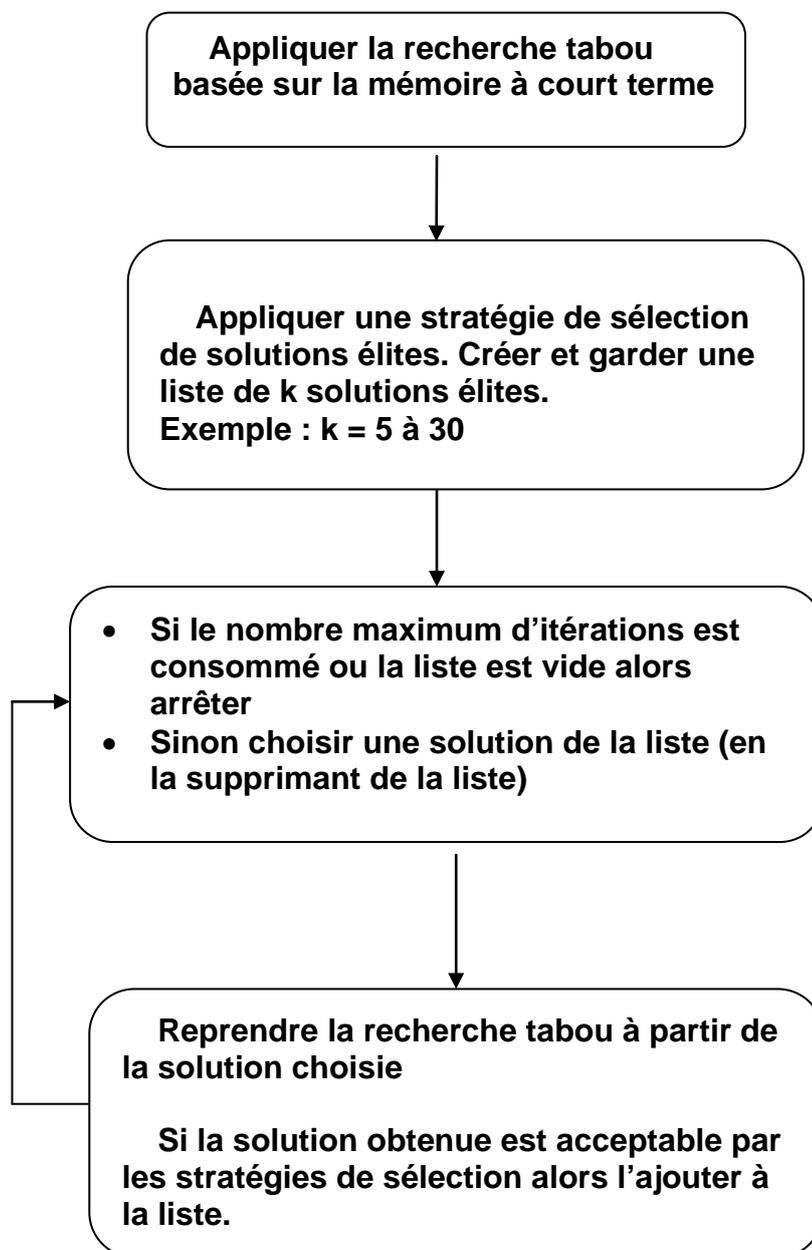


Figure 2.2. Une stratégie d'intensification

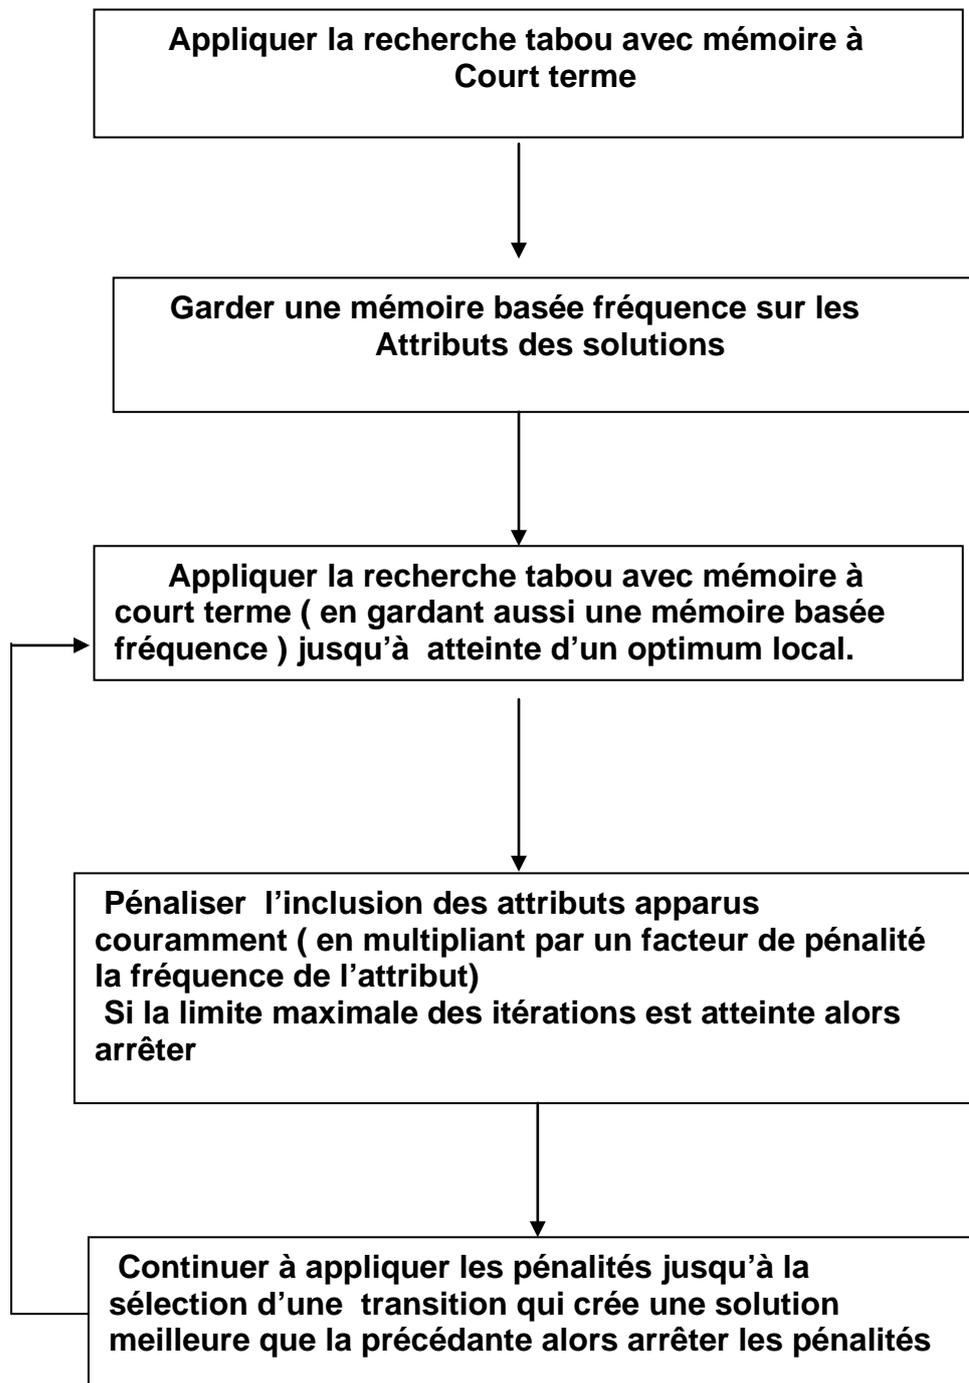


Figure 2.3. Une stratégie de diversification

- **Stratégies d'oscillation :**

La stratégie d'oscillation est étroitement liée aux origines de la recherche tabou, elle fournit un moyen pour réaliser une interaction efficace entre l'intensification et la diversification. Cette approche tend à faire varier la direction de recherche et la région visitée, et cela par le contrôle des évaluations des mouvements dans quelques voisinages de la solution courante.

Dans le cas où l'espace des solutions comporte des sous espaces disjoints, la stratégie d'oscillation fournit un mécanisme pour traverser les régions inadmissibles (ne vérifiant pas les contraintes du problème), elle permet de créer des processus de recherche étendus qui peuvent admettre des solutions inadmissibles durant la recherche, mais elles sont pénalisées. Le composant d'oscillation de la procédure fait varier cette pénalité à chaque fois dans le but d'assurer une diversité efficace en cours de recherche.

- **Le chemin reliant :**

Une intégration utile des stratégies d'intensification et de diversification se produit dans l'approche appelée en anglais «**path relinking** » [Glo 95][LG 93]. Cette approche génère de nouvelles solutions en explorant les trajectoires qui connectent les solutions élites, en commençant par une de ces solutions appelées solution initiale, et en générant un chemin dans l'espace du voisinage qui conduit vers d'autres solutions appelées solutions guides.

Cette approche peut être vue comme une stratégie qui cherche à unir les attributs des solutions de haute qualité, en favorisant ces attributs dans les mouvements choisis. Cependant, au lieu d'encourager seulement l'inclusion de tels attributs, l'approche de chemin reliant subordonne toutes les considérations dans le but de choisir les mouvements qui introduisent les attributs des solutions guides et de créer une bonne composition d'attributs dans la solution courante.

Le chemin reliant

- 1. Identifier la structure de voisinage et associer une solution au chemin reliant .**
- 2. Sélectionner une collection de deux ou plusieurs solutions de références et identifier celle qui va être une solution initiale et celles qui vont être des solutions guides.**
- 3. Déplacer la solution initiale vers les solutions guides, générer une ou plusieurs solutions intermédiaires.**

Figure 2.4. Une stratégie de chemin reliant

- **Stratégies de la liste candidate : [Glo 95]**

La qualité d'une solution peut dépendre de stratégies de la liste candidate appropriées. L'importance de ces approches est souvent négligée, malgré qu'elles soient fondamentales pour la recherche tabou pour effectuer des choix judicieux.

L'examen du voisinage complet avec la recherche tabou fournit généralement une solution de bonne qualité, mais peut être coûteuse en temps de calcul. Pour cette raison, il est souvent important d'appliquer la recherche tabou en conjonction avec une stratégie qui isole les régions de voisinage contenant des mouvements avec de bonnes caractéristiques en les mettant dans une liste de candidats. Ceci est une façon d'accélérer la recherche. Nous citons, dans ce qui suit quelques exemples de ces stratégies qui sont particulièrement utiles.

- **Stratégie de décomposition de voisinage :**

L'approche consiste à décomposer le voisinage en sous-ensembles, à chaque itération. Un seuil d'aspiration est appliqué pour limiter la fréquence de sélection des mouvements les moins attractifs. Généralement, cette stratégie permet de réduire le temps de calcul et de générer une certaine diversité dans la recherche.

- **Stratégie de l'évaluation élite :**

Elle consiste à sauvegarder une collection des meilleurs mouvements dans la liste candidate. A chaque itération, les mouvements appartenant à cette liste sont examinés en premier, suivi d'un sous-ensemble de voisinage. Ensuite, les mouvements de la liste candidate qui ne sont pas attractifs sont remplacés, périodiquement, après un nombre spécifié d'itérations, ou bien quand leurs qualités dans la liste sont détériorées sous un seuil choisi, une large portion du voisinage courant est explorée, afin de reconstruire la liste candidate.

2.3. LES ALGORITHMES GENETIQUES [Gol 89]:

Un algorithme génétique repose sur le principe de l'évolution naturelle d'organismes en respectant les phénomènes d'hérédité et la loi de survie énoncée par Darwin, selon lesquels, dans une population d'individus, ce sont les plus forts, c'est à dire les mieux adaptés à leur environnement qui survivent et pourront donner une descendance.

Le processus d'évolution se fait par deux mécanismes : la sélection naturelle et la reproduction.

2.3.1. La représentation chromosomique :

Le chromosome code une solution au problème, il représente un point de l'espace de recherche. Dans le cas du codage binaire, utilisé dans les premières versions des algorithmes génétiques, un chromosome est représenté par un vecteur dont les éléments appartiennent à $\{0,1\}$. Si la fonction à optimiser possède n variables, le chromosome sera constitué de la concaténation des n codages binaires. Il faut noter qu'il peut parfois être très difficile, de coder des solutions de cette manière. Le choix du codage a un impact sur les performances de l'algorithme génétique. En effet on doit choisir un codage qui n'est pas complexe dans le sens où le temps du décodage est minimal.

2.3.2. La population initiale :

La population initiale d'individus /solutions est l'ensemble des individus qui représentent des solutions d'un problème donné. Cette dernière est générée aléatoirement.

2.3.3. Fonction d'évaluation :

La fonction d'adaptation, décode un individu puis elle lui associe un coût. Un AG tend à maximiser ce coût, en permettant aux chromosomes ayant une grande valeur d'être retenus puis croisés(étape de reproduction).

2.3.4. Les opérateurs génétiques :

Les opérateurs génétiques définissent la manière dont les individus se recombinent et s'agencent pendant la phase de reproduction.

1- La sélection :

La phase de sélection spécifie les individus de la population qui doivent survivre. La méthode de base, appelée roue de loterie, attribue à chaque individu V_i une probabilité de survie P_i proportionnelle à son adaptation dans la population.

Lors de la phase de sélection, les individus sont sélectionnés aléatoirement en respectant les probabilités P_i associées pour former la population de la nouvelle

génération. Ceci s'effectue par le calcul d'une probabilité de sélection cumulée Q_i , telle que :

$$Q_i = \sum_{j=1}^i P_j, \quad P_i = \text{adaptation } V_i / \sum_{j=1}^n \text{adaptation } V_j, \quad \text{où } n \text{ est la taille de la population.}$$

Puis, on génère aléatoirement un réel r sur l'intervalle $[0,1]$.

L'individu V_i est sélectionné lorsque $Q_{i-1} < r \leq Q_i$. De ce fait les individus les mieux adaptés sont sélectionnés plusieurs fois et les plus faibles rarement voire jamais. Ce processus est réitéré n fois.

2- Le Croisement :

Le croisement est défini comme suit (voir Figure 2.5):

Soient deux individus v_1 et v_2 juxtaposées, le croisement les coupe en un point choisi aléatoirement et produit deux nouveaux individus V'_1 et V'_2 après avoir échangé les parties coupées. Les deux individus V_1 et V_2 participant à cette opération sont assimilés aux parents, et les deux chaînes résultantes aux descendants.

3- La mutation :

La mutation est un changement aléatoire d'une ou plusieurs positions d'un individu. L'opérateur de croisement devient moins efficace avec le temps, car les individus deviennent similaires. C'est à ce moment que le phénomène de mutation prend toute son importance. Chaque position de l'ensemble des chaînes de la population a une probabilité P_m de subir une mutation à chaque génération. Cet opérateur permet de sortir des optima locaux.

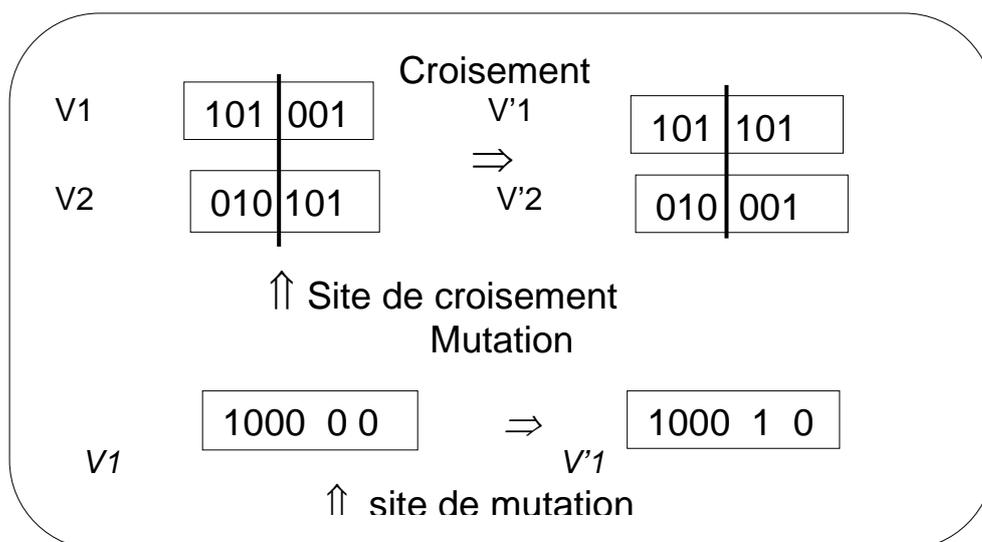


Figure 2.5. Les opérateurs génétiques de croisement et de mutation

Les différentes étapes de l'AG sont les suivantes :

- Générer aléatoirement une population initiale d'individus.
- Evaluation : Affecter à chaque individu son coût.

Répéter

- Sélection : Etablir une liste de paires d'individus susceptibles de se reproduire, le critère de sélection favorise les meilleurs.
- Reproduction : Appliquer les opérateurs génétiques à toutes les paires d'individus sélectionnées.
- Evaluation : Affecter à chaque individu son coût.
- Remplacement : Produire la nouvelle population en remplaçant les individus de manière à favoriser encore les meilleurs.

Jusqu'à un certain critère d'arrêt.**2.4. LE RECUIT SIMULE [Sia 95]:**

Cette méthode est inspirée de la technique du «recuit » qui consiste à chauffer un métal jusqu'à l'état liquide, puis on le refroidit très lentement en marquant des paliers de température de durées suffisantes. La stratégie de la baisse contrôlée de la température conduit à un état solide cristallisé, qui est un état stable, correspondant à un minimum d'énergie.

La méthode de recuit simulé consiste à transposer ce procédé à la résolution d'un problème d'optimisation combinatoire : la fonction de coût du problème, analogue à l'énergie du métal, est alors minimisée, avec l'introduction d'une «température »qui est dans ce cas un simple paramètre de contrôle de l'algorithme jouant le rôle de la température du système physique dans la technique du recuit.

Dans cette méthode, on part d'une configuration initiale représentant une solution réalisable du problème et d'une température T . Ensuite, on fait subir à la configuration une modification élémentaire, si cette transformation a pour effet de diminuer la fonction coût du problème, elle est acceptée. Si au contraire elle provoque une augmentation ΔE de la fonction coût, elle est acceptée tout de même avec la probabilité $\exp(-\Delta E)$ où \exp dénote la fonction mathématique exponentielle. En appliquant itérativement cette règle d'acceptation, on engendre une séquence de configurations. Après qu'un certain nombre d'itérations a été atteint (qui dépend de la taille du problème), on réduit la température T et on effectue une nouvelle série d'itérations à cette nouvelle température. On répète le cycle de refroidissement et des transitions jusqu'à un certain critère d'arrêt qui correspond à une température finale faible(proche de zéro).

2.4.1. Algorithme du recuit simulé :

L'algorithme du recuit simulé est présenté comme suit :

Etape 1 Initialisation :

On part d'une configuration initiale, on calcule son coût E_0 .

$T_0 = T_{\max}$ température initiale

Etape 2 Itération :

Le système se trouve à la température T_i et possède l'énergie E_i .

1- On génère une nouvelle configuration voisine.

Soit E_{i+1} le coût associé à la nouvelle configuration.

$$\Delta E = E_{i+1} - E_i$$

2- On accepte la nouvelle configuration avec la probabilité P :

$$P(T_i, \Delta E) = \text{MIN}(1, \exp(-\Delta E/T))$$

3- On répète cette itération jusqu'à ce que le nombre d'itérations dépasse N_T (aller à 2).

Etape 3 mise à jour et test d'arrêt :

$T_i = a * T_{i-1}$ /* a le taux de décroissance de la température */

Si $T_i \geq T_{\min}$ alors aller à 2 /* T_{\min} est la température minimale */

D'après cet algorithme, on comprend le rôle confié à la température. A haute température, $\exp(-\Delta E/T)$ est voisin de 1, donc la plupart des configurations sont acceptées, l'algorithme équivaut à une simple marche aléatoire dans l'espace de recherche. A basse température, $\exp(-\Delta E/T)$ est voisin de 0, donc la plupart des configurations augmentant la fonction coût (l'énergie) sont refusées. A température intermédiaire, l'algorithme autorise de temps en temps des transformations qui dégradent la fonction coût, il laisse ainsi au système une chance de s'extraire d'un minimum local **[Sia 95]**.

2.4.2. L'organigramme de l'algorithme du recuit simulé :

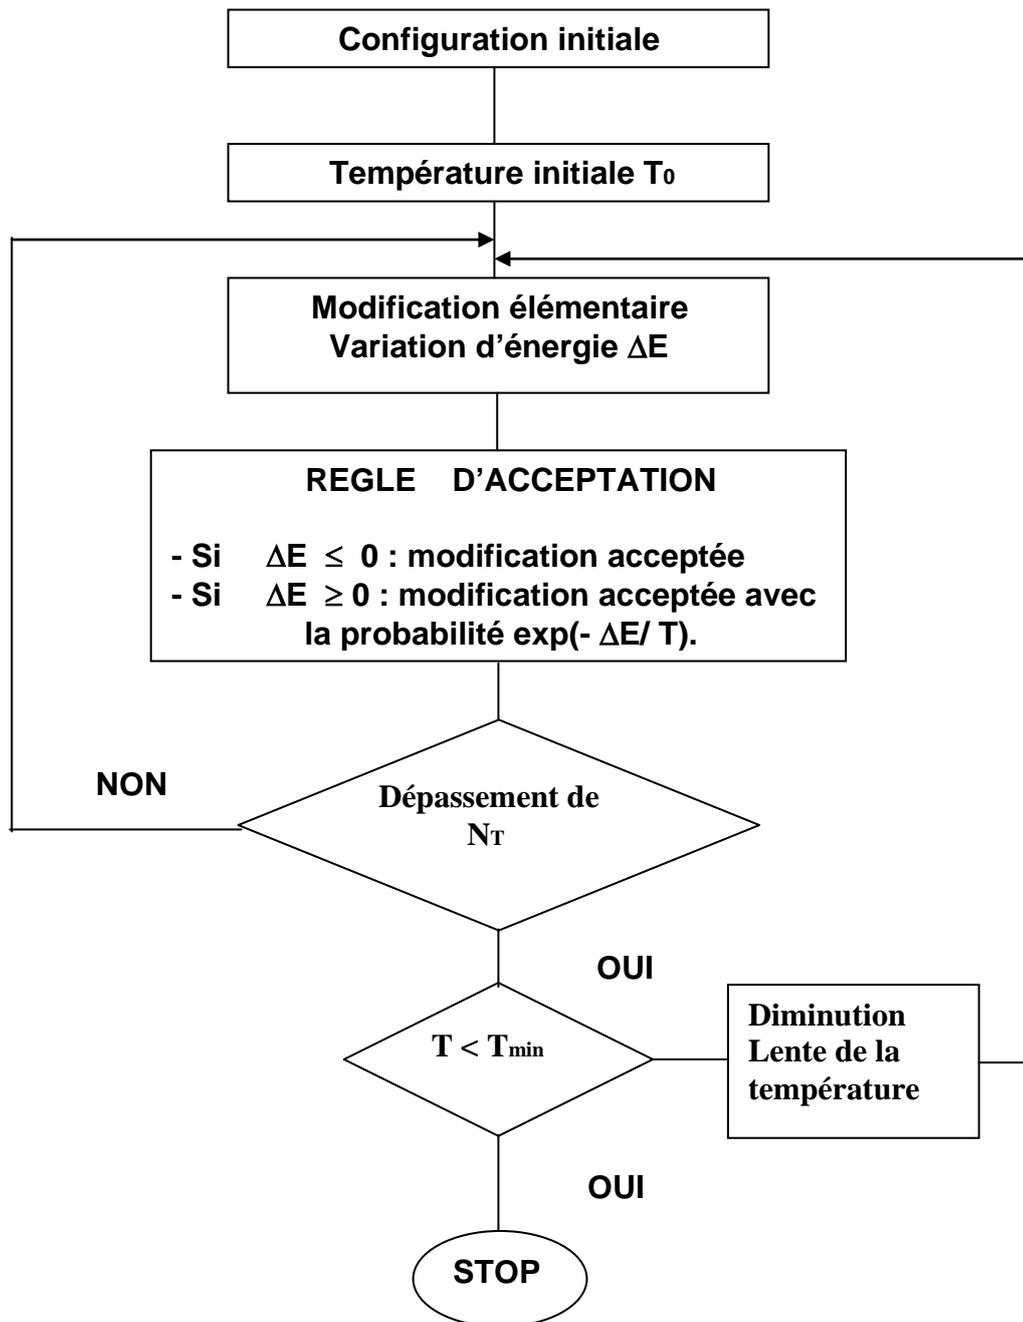


Figure 2.6. Organigramme de l'algorithme de recuit simulé.

2.5. CONCLUSION :

Ce chapitre est consacré aux méta- heuristiques classiques, qui sont des algorithmes itératifs produisant des bons résultats pour les problèmes d'optimisation difficiles. Le chapitre suivant est consacré à examiner deux autres méta- heuristiques récentes : la recherche dispersée et la recherche locale guidée.

Chapitre 3 :

La recherche dispersée et la recherche locale guidée

3.1. INTRODUCTION :

La recherche dispersée et la recherche locale guidée sont des méta-heuristiques apparues ces dernières années avec une ambition commune : résoudre efficacement les problèmes d'optimisation combinatoire en particulier ceux qui sont classés NP- difficiles.

En effet la plupart de ces méthodes sont basées sur le pilotage d'un point courant dans un certain domaine. Les déplacements de ce point sont alors décidés de façon à optimiser une certaine fonction objective. Très souvent, la structure du domaine considéré ne permet pas d'établir un lien fort entre les notions d'optimalité globale et d'optimalité locale. De ce fait, divers artifices de contrôle existent, qui visent à éviter au point courant de s'enfermer sur un optimum local de mauvaise qualité. Ces artifices de contrôle tendent à autoriser des déplacements dégradant temporairement le point courant, moyennant un tirage au sort (le recuit simulé), une mutation (les algorithmes génétiques) ou bien une mémorisation des positions déjà visitées (la recherche tabou).

Dans ce qui suit nous présentons deux autres méthodes récentes et nous donnons d'autres mécanismes utilisés pour échapper à l'optimum local : la recherche dispersée qui s'appuie sur la diversification et l'amélioration et la recherche locale guidée qui utilise une fonction objective augmentée.

3.2. LA RECHERCHE DISPERSÉE [Lag 99][GLM 00] [GLMC 99]:

La recherche dispersée appelée en anglais «**SCATTER SEARCH** » est une méta- heuristique destinée à résoudre au mieux les problèmes dits d'optimisation difficiles : elle fait évoluer une population de points (solutions au problème) générée via un générateur de diversification.

De plus, la recherche éparpillée établit une liste des meilleurs individus «**ensemble référence**» en permettant aux éléments ayant un coût élevé ou une disparité assez importante d'être retenus puis croisés ou combinés (**étape de combinaison**). Le critère de sélection favorise les meilleurs, c'est-à-dire les individus de haute qualité en regardant leur coût ou les solutions diverses de l'espace de recherche.

Autrement dit, la recherche dispersée unit un ensemble préféré de points dits points références pour produire les points élites qui vont devenir la source des nouveaux points références en utilisant un opérateur de combinaison permettant de construire des solutions admissibles. Le processus d'évolution est réitéré jusqu'à ce qu'aucune combinaison n'améliore la qualité ou la diversité de l'ensemble des points références.

3.2.1. DESCRIPTION DE LA RECHERCHE DISPERSÉE [GLM 00] :

La recherche dispersée est une méta-heuristique à stratégies d'évolution. Elle intègre les idées majeures des méthodes évolutionnistes (population de solutions, recombinaison de solutions).

Un algorithme génétique est aussi une approche évolutionniste, il présente plusieurs inconvénients liés à sa structure classique [Tal 95]. Nous citons :

- ❖ L'incapacité du processus de recherche d'exploiter au mieux certaines régions particulières. Ceci est dû au fait que les opérateurs génétiques de mutation et de croisement agissent tous les deux d'une manière aveugle.
- ❖ La convergence prématurée après un certain nombre d'itérations. Ceci est dû au fait que les individus deviennent de plus en plus identiques au fur et à mesure que le nombre de générations augmente. La manière avec laquelle agissent les opérateurs génétiques est une cause principale de cet inconvénient, car comme dans ce cas il faut augmenter le taux de diversification pendant une période suffisante. Chose difficile à réaliser du fait que les opérateurs génétiques classiques restreignent significativement l'effet du contexte, ce sont des opérateurs à effet de contexte neutre [Tal 95].

Dans le but de pallier ces principaux inconvénients, la recherche dispersée s'appuie sur un principe qui consiste à générer la population de départ à l'aide d'une stratégie de diversification. De plus, elle autorise des synergies avec d'autres méthodes itératives, qui peuvent être intégrées dans le processus de recherche.

Dans cette approche, on génère de nouvelles solutions en explorant des trajectoires qui lient plusieurs solutions de départ, appelées solutions de haute qualité, et cela en démarrant par l'une de celles-ci, appelée solution initiale, puis en générant un chemin dans l'espace voisin qui mène vers les autres solutions, dites solutions diverses. Les solutions diverses et de haute qualité sont appelées solutions références.

Le schéma suivant présente une instance de la recherche dispersée :

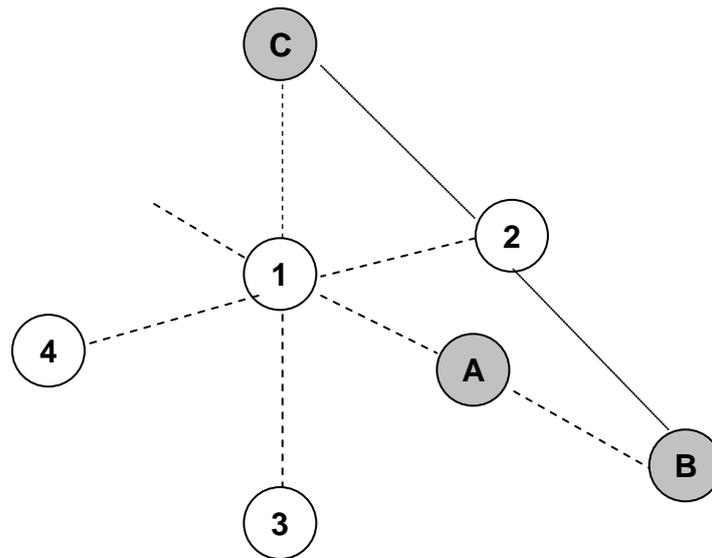


Figure 3.1. Schéma représentant une instance de la recherche dispersée.

On remarque les trois solutions de référence A, B et C. Des solutions intermédiaires sont générées en démarrant par l'une des solutions de référence, puis en générant un chemin dans l'espace voisin qui mène vers les autres solutions. Ceci est effectué en utilisant un opérateur de combinaison. La combinaison joue un rôle presque semblable à celui d'un opérateur de croisement, et cela du fait qu'elle consiste en la construction d'une ou plusieurs solutions combinées en sortie partageant certains attributs avec les solutions références en entrée. Les nouvelles solutions seront améliorées et réintégrées dans l'ensemble des points références. Les points 1, 2, 3, et 4 sont les nouvelles solutions combinées.

La recherche dispersée peut contribuer à bien gérer le compromis entre la diversification et l'intensification. Pour favoriser l'intensification, les solutions références sont choisies de telle sorte qu'elles parviennent d'une région commune «solutions de haute qualité ». Pour favoriser la diversification, les solutions références sont choisies de telle sorte qu'elles parviennent de différentes régions «solutions diverses » [GLM 00]. Cette façon de faire, augmente les chances d'atteindre des solutions optimales.

Les différentes étapes de la recherche dispersée sont les suivantes :

- Générer une population initiale variée ;
- Extraire un ensemble des meilleurs individus qui vont construire les points références ;
- Grouper les points références «combinaison ».

3.2.2. LA POPULATION INITIALE :

La population initiale est l'ensemble des individus qui représentent des solutions d'un problème donné. Contrairement aux algorithmes génétiques où les solutions de départ sont générées aléatoirement, la recherche dispersée utilise une stratégie de diversification, pour avoir une population variée qui permettra d'explorer des zones diverses de l'espace de recherche.

A chaque solution un coût correspondant à la fonction objective est associé. La population de départ est ordonnée suivant la fonction objective en commençant par les meilleurs individus ayant un coût assez élevé.

3.2.3. CONSTRUCTION DES SOLUTIONS DE REFERENCE R :

Dans cette phase on spécifie les individus de la population initiale qui doivent se combiner et produire une nouvelle génération.

En effet le choix d'une solution pour l'ensemble **R** «solutions références » est un point essentiel dans la recherche dispersée, pour lequel une bonne réflexion est nécessaire. Il existe deux stratégies de choix de l'ensemble **R** :

Celle qui consiste à choisir un ensemble de solutions et de les évaluer suivant la fonction objective pour pouvoir déduire les solutions de haute qualité, l'autre consiste à choisir un ensemble de solutions et de les évaluer suivant la disparité pour pouvoir déduire les solutions diverses[**LMC 99**].

Par conséquent, on aura deux sous-ensembles R_1 de taille B_1 et R_2 de taille B_2 , tel que les B_1 solutions sont de haute qualité et les B_2 solutions sont les points les plus éloignés les uns des autres dans l'espace de recherche.

En d'autres termes, l'ensemble **R** est une liste de longueur $B = B_1+B_2$, utilisée pour conserver les meilleures solutions. A chaque évolution on introduit la solution combinée, si elle est meilleure, et on rejette la plus mauvaise.

3.2.4. RENOUELEMENT DE LA POPULATATION :

Le renouvellement de la population, autrement dit la création d'une nouvelle génération, est obtenu par itération de l'algorithme de recherche dispersée qui va créer de nouveaux points et en détruire d'autres. A partir de l'ensemble R, la recherche dispersée génère des sous-ensembles appelés aussi points élites qui vont construire des solutions combinées en utilisant un opérateur de combinaison.

La recombinaison consiste à grouper les éléments de R par paire, par triplet, et ainsi de suite, c'est-à-dire avec un ensemble R de taille B on peut générer **4 types** de solutions définis comme suit :

Type 1 : Il consiste à grouper les éléments de R par paire, puis, pour chaque paire de solutions appliquer l'opérateur de combinaison, améliorer et insérer la solution générée dans R.

Type 2: Les solutions seront combinées trois à trois, en prenant un élément de type1 et on lui rajoute une meilleure solution qui n'apparaît pas dans le couple de solutions courant.

Type 3 : Les solutions seront combinées quatre à quatre. Pour chaque élément de type2, lui rajouter une bonne solution, puis, pour chaque quadruplet obtenu, appliquer l'opérateur de combinaison

Type 4 : Les i meilleurs points de R seront groupés pour donner d'autres Solutions combinées, où $i = 5$ jusqu'à B, c'est -à-dire le type 4 comprend des sous-ensembles de taille 5,...jusqu'à B meilleurs éléments.

Exemple :

Soit l'ensemble R de taille 5 suivant :

X(1) : (0, 0, 0, 0, 0, 0, 0, 0, 0, 0)
 X(2) : (1, 0, 1, 0, 1, 0, 1, 0, 1, 1)
 X(3) : (1, 0, 0, 1, 0, 0, 1, 0, 0, 0)
 X(4) : (1, 0, 0, 0, 1, 0, 0, 0, 0, 1)
 X(5) : (1, 1, 1, 1, 1, 1, 1, 1, 1, 1)

A partir de cet ensemble, 4 types de solutions seront générés et peuvent être présentés comme suit :

TYPE	Sous-ensembles
1	(1,2) (1,3) (1,4) (1,5) (2,3) (2,4) (2,5) (3,4) (3,5) (4,5)
2	(1,2,3) (1,2,4) (1,2,5) (1,3,4) (1,3,5) (1,4,5)
3	(1,2,3,4) (1,2,3,5) (1,2,4,5)
4	(1,2,3,4,5)

Figure 3.2. Les solutions élites

Où 1, 2, 3, 4, 5 sont les solutions de l'ensemble R.

On aura les quatre types suivants :

- **Le type 1** : Contient 10 sous-ensembles, qui vont participer à la combinaison. Chaque élément va construire une troisième solution à l'aide d'un opérateur structuré.
- **Le type 2** : Contient 6 sous-ensembles. Chaque élément dans cet ensemble est formé à partir de l'ensemble de type précédant, en évitant la redondance.
- **Le type 3** : Pour construire un élément de type 3, il suffit de prendre un élément de type 2 et lui rajouter la meilleure solution dans R et qui n'apparaît pas dans le triplet courant.
- **Le type 4** : Afin de créer un élément de type 4, i solutions de R seront groupées, où $i = 5$ jusqu'à B solutions. Dans notre cas, on aura un seul élément de taille 5 puisque le B est égal à 5.

3.2.5. LA COMBINAISON :

L'aveuglance exagérée des opérateurs génétiques classiques est à l'origine de plusieurs problèmes, tels que la convergence prématurée de l'algorithme génétique. Donc, il est intéressant d'utiliser un opérateur plus évolué prenant en considération le contexte du problème.

La combinaison structurée est un opérateur permettant de produire des solutions admissibles, à partir d'un ensemble de solutions appelées solutions élites.

Dans la recherche dispersée, la combinaison dépend de la fonction objective à optimiser «contexte du problème » ainsi que de la représentation utilisée pour modéliser les solutions du problème.

Précisément, sur l'identification d'une collection d'une ou plusieurs solutions élites pour guider le chemin d'une solution donnée, des poids sont assignés aux attributs des solutions guides, comme mobile pour être sélectionnés.

Des gros poids sont assignés aux attributs qui surviennent dans un grand nombre de solutions guides permettant de donner une accentuation des solutions de haute qualité ou bien avec des caractéristiques spéciales.

Quelques conceptions d'attributs peuvent partager des degrés de similarité, et dans ce cas, il peut être utile de garder la solution vectorielle, aussi prévoir «des votes» pour favoriser ou décourager les attributs particuliers.

Exemple : « problème d'ordonnancement »

On entend par ordonnancement, le placement d'un ensemble de tâches qui peuvent être indépendantes ou soumises à des contraintes de précédence, sur un ensemble de processeurs. Ce placement doit minimiser la durée totale de l'exécution.

Soient les deux solutions initiales :

$$X(1) = (1, 2, 3, 4, 5, 6, 7, 8, 9) \quad W(1) = 2/3$$

$$X(2) = (1, 8, 6, 4, 9, 3, 5, 2, 7) \quad W(2) = 1/3$$

Où : $X(i)$ est une solution de référence et $W(i)$ son poids.

A partir de ces deux points de référence, on essaie de trouver une nouvelle solution $X(3)$ de la manière suivante :

- ❖ Soit la relation de précédence (i, j) tel que i est la tâche initiale, trouver le meilleur successeur de i , j à partir de $X(1)$ et $X(2)$.
- ❖ A chaque point de référence $X(i)$, une note «vote $X(i)$ » est associée.

Dans notre cas, le nouveau vecteur $X(3)$ contient au début la valeur 1. Donc le problème revient à chercher un j , le successeur de 1, à partir de $X(1)$ et $X(2)$.

Initialement $X(3) = (1, , , , , , , ,)$, $i = 1, j = ?$.

Cas 1 : d'après $X(1)$, $j = 2$ avec $\text{vote}X(1) = 1$ et $\text{vote}X(2) = 0$
 $X(3) = (1, 2, , , , , , ,)$

Cas 2 : d'après $X(2)$, $j = 8$ avec $\text{vote}X(1) = 0$ et $\text{vote}X(2) = 1$
 $X(3) = (1, 8, , , , , , ,)$

Etape d'évaluation :

Afin de sélectionner un successeur, on doit minimiser la formule donnée par GLOVER comme suit :

$$\text{Minimise } \sum_{q=1}^{\text{Taille de R}} | \text{contribution}(k : q) - W(k) | \quad \text{[Glo 94]}$$

on aura donc :

$$\text{Cas 1} : | 1 - 2/3 | + | 0 - 1/3 | = 2/3.$$

$$\text{Cas 2} : | 0 - 1/2 | + | 1 - 1/3 | = 4/3.$$

⇒ $j = 2$ c'est à dire c'est le premier cas qu'est sélectionné.

⇒ $X(3) = (1, 2, , , , , ,)$

En réitérant le même processus, on aura à la fin la solution $X(3)$ suivante :

(1, 2, 7, 8, 9, 3, 4, 5, 6)

3.2.6. METHODE D'AMELIORATION :

Dans cette méthode, on part d'une configuration représentant une solution réalisable du problème obtenue par la méthode de combinaison. Ensuite, on fait subir à cette solution combinée des modifications élémentaires (série de transformations qui a pour effet d'améliorer le coût de la solution combinée).

Afin d'avoir une solution meilleure, on applique itérativement cette méthode d'amélioration qui engendra une séquence de solutions. On répète le cycle d'amélioration et des transitions jusqu'à un certain critère d'arrêt qui correspond à un certain nombre d'itérations.

Exemple :

Dans l'optimisation combinatoire, la recherche locale est la méthode la plus utilisée pour améliorer une solution donnée. Elle peut être présentée comme suit :

- Soit s une solution à améliorer ;

Répéter

- Générer un ensemble $V^* \subseteq N(s)$ de solutions voisines de s ;
- Choisir la meilleure solution $s' \in V^*$
- **si** $f(s) < f(\text{bestsol})$ **alors** $\text{bestsol} = s'$;

Jusqu'à un certain nombre d'itérations.

3.2.7. LA DIVERSITE:

Afin d'augmenter la probabilité d'atteindre un optimum de haute qualité, les solutions de l'ensemble R sont choisies suivant leur fonction objective «Solutions de haute qualité et suivant leur disparité «Solutions diverses».

En ce qui concerne la diversité, la recherche dispersée est une méthode qui cherche la diversité en générant une recherche heuristique désignée pour produire un nouveau point. La diversification guide le processus aux régions qui marquent des différences entre celles examinées auparavant.

Pour avoir une population variée on utilisera une méthode assurant la diversité à travers le calcul d'une distance «disparité» mesurée entre les solutions de haute qualité et les autres solutions générées dans l'espace de recherche.

Exemple :

Soient deux solutions vectorielles X et Y, la distance entre X et Y sera mesurée comme suit :

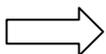
// X solution vectorielle de n variables

// Y solution vectorielle de n variables

Dist = 0 ;

Pour i=1 à n **faire** Si (X[i] <> Y[i]) alors Dist = Dist +1 ;

Distance (X, Y) = Dist



// Distance (x, y) = la différence entre les bits //

3.2.8. L'ALGORITHME DE LA RECHERCHE DISPERSÉE [Lag 99]:

Une version de l'algorithme de la recherche dispersée est présentée comme suit :

INITIALISATION :

- Engendrer une population initiale P en utilisant une stratégie de diversification
- Affecter à chaque solution son coût.
- Ordonner la population suivant la fonction objective
- // Itermax nombre maximum d'itérations

ITERATION :

Pour i=1 à itermax **Faire**

- Etablir une liste de solutions de taille B appelée liste de points références R, le critère de sélection favorise les meilleures.
- L'ensemble R est de taille $B = B1+B2$ où
- // Les B1 solutions sont de haute qualité
- // Les B2 solutions sont diverses

Nouveau = Vrai

Tant que (Nouveau)

Faire

- Calculer la taille de l'ensemble des solutions élites Maxsubset ;
- Nouveau = faux ;

Pour i=1 à Maxsubset **Faire**

- Générer les différents types de solutions
- Appliquer l'opérateur de combinaison pour obtenir une nouvelle solution s
- Améliorer la solution s
- Evaluer la solution améliorée s*.

Si (coût (s*) > coût(B1 ème solution de R) et s* n'apparaît

Pas dans R)

alors

- Insérer s*
- Ecraser la mauvaise
- Nouveau = Vrai ;

Sinon

Si (disparité (s*) > disparité(B2ème solution de R) et s* n'apparaît

Pas dans R)

alors

- Insérer s*
- Ecraser la mauvaise
- Nouveau = Vrai;

Fait

Fait

- Régénérer la population en remplaçant les solutions de manière à favoriser encore les meilleures.

Fait

3.3. LA RECHERCHE LOCALE GUIDÉE [Vou 97] [VT 98]:

La recherche locale guidée est considérée comme étant une puissante procédure d'optimisation, capable d'échapper aux optima- locaux.

La recherche locale guidée a remporté un immense succès dans de nombreux problèmes d'optimisation combinatoire à savoir le problème du voyageur de commerce, les problèmes d'affectation, et les problèmes d'ordonnancement [Vou 97]. Ces problèmes sont caractérisés par un haut degré de complexité dû à la présence d'un nombre assez important d'optima- locaux dans l'espace de recherche. Pour cette raison il n'existe pas d'algorithmes pouvant générer une solution optimale en un temps polynomial.

L'heuristique de recherche locale s'arrête au premier minimum local qui peut être très loin du minimum global recherché. C'est pourquoi la recherche locale guidée a été mise au point.

Pour pouvoir ressortir des optima-locaux une autre variante de la recherche locale a été développée et qui est une amélioration de la première dans le sens où elle modifie la fonction objective dont le but est de pénaliser les solutions de mauvaise qualité et d'approcher le minimum global.

Dans ce qui suit, nous présentons tout d'abord la méthode de base dite «recherche locale». Le point suivant est consacré à la description et la conception d'une approche basée sur la recherche locale afin de trouver des bons résultats pour les problèmes d'optimisation combinatoire : recherche locale guidée.

3.3.1. LA RECHERCHE LOCALE :

Un algorithme itératif de recherche locale part d'une configuration initiale (une solution au problème) et essaie de l'améliorer. L'amélioration consiste à effectuer des transformations successives sur la configuration initiale. Si le coût d'une configuration générée est meilleur que celui de la configuration courante, cette dernière sera remplacée par cette nouvelle configuration, sinon elle sera gardée. Ce processus est réitéré jusqu'à ce qu'aucune transformation ne réduise le coût de la configuration courante.

La recherche locale est une méthode itérative initialisée avec une solution qu'elle cherche à améliorer à chaque itération.

En effet, les algorithmes itératifs de recherche locale conduisent très souvent à des solutions suboptimales. Dans le but d'échapper aux optima- locaux, d'autres techniques ont été développées telles que : la recherche locale guidée qui produit une solution acceptable.

Ci dessous une version de l'algorithme itératif de recherche locale :

```

Début
- Générer une configuration initiale S
- Tant que (coût (S) > 0)
  Faire
  - Générer une configuration voisine S'
  - Si coût (S) < coût (S') alors S= S'
  Fait
- retourner (S)
Fin

```

3.3.2. LA RECHERCHE LOCALE GUIDÉE [VT 98]:

La recherche locale guidée est une méta- heuristique destinée à résoudre efficacement les problèmes d'optimisation combinatoire. Elle permet, en principe, d'éviter le piège des optima- locaux de la fonction objective moyennant une pénalisation de certaines caractéristiques dans la solution.

En effet, la recherche locale guidée est une variante de la recherche locale. Elle modifie la fonction objective dans le but d'approcher le minimum global.

Le principe de la recherche locale guidée revient à pénaliser certaines solutions jugées mauvaises par le nombre de fois de leurs apparitions multiplié par un facteur λ permettant d'augmenter leur fonction objective. Cela est réalisé en utilisant une série de formules présentées dans ce qui suit.

$$\text{Formule 1 : } \text{Ini}(\mathbf{S}) = \begin{cases} 1 & \text{Si, Pour la configuration } \mathbf{S}, \text{ la mauvaise} \\ & \text{caractéristique est présente ;} \\ 0 & \text{Sinon.} \end{cases}$$

$$\text{Formule 2 : } \quad \mathbf{C}(i) = \text{poids de la caractéristique } i$$

$$\text{Formule 3 : } \quad \text{Utilité}(i) = \text{Ini}(\mathbf{S}) * \mathbf{C}(i) / 1+\mathbf{P}(i)$$

Où :

P(i) : Est la pénalité ou encore un compteur de fréquence. Au début P(i) est initialisée à zéro, quand la caractéristique i est mauvaise P(i) est mis à jour.

Ini(S) : Indique si la caractéristique i est mauvaise ou pas.

Utilité(i) : Permet de pénaliser les solutions déjà visitées.

Donc le problème revient à pénaliser les caractéristiques de haute utilité. Cette façon de faire permet de pénaliser les solutions déjà visitées ce qui conduira à une exploration plus diversifiée de l'ensemble de recherche.

Par conséquent, on aura la fonction objective augmentée suivante :

$$H(S) = G(S) + \lambda \sum_{i=1}^m \text{Ini}(S) * P(i)$$

Où :

- H : La fonction objective augmentée ;
- G : Le coût de la solution S
- S : La configuration courante ;
- Ini(S) : L'indicateur ;
- P(i) : La pénalité ;
- m : Le nombre de caractéristiques.
- λ : Le facteur de pénalisation
- $\lambda > 1$: Recherche diversifiée
- $\lambda < 1$: Recherche intensifiée.

3.3.3. L'ALGORITHME DE LA RECHERCHE LOCALE GUIDÉE [VT 98]:

L'algorithme de la recherche locale guidée est présenté comme suit :

INITIALISATION :

- Générer aléatoirement une solution initiale S
- Affecter à la solution générée son coût.
- // G est la fonction objective standard
- // Itermax nombre maximum d'itérations
- // H = la fonction objective augmentée
- // m = nombre de caractéristiques

Pour i=1 à m **Faire** P(i)=0 ;

ITERATION :

Pour i=1 à Itermax **Faire**

- S := recherche locale(S, H)

// appel de l'algorithme de recherche locale avec les paramètres H et S

// la recherche locale retourne une solution S qui est l'optimum local

Pour chaque (mauvaise caractéristique fi)

Faire

- Calculer son utilité

$$\text{Utilité}(fi) = \text{Infi}(S) * C(fi) / 1+P(fi)$$

- Soit utilité- max égale à l'utilité maximale

Si (utilité(fi) = utilité- max) **alors** P(fi) = P(fi)+1 **fini**

Fait

Fait

Retourner la meilleure solution avec le meilleur coût

FIN

3.4. CONCLUSION :

Dans le but de trouver une solution aussi bonne que possible, différentes méta-heuristiques ont été développées. Certains de leurs outils de base sont :

- La randomisation, utilisée pour explorer des zones diverses de l'espace de recherche.
- La mémorisation, pour guider plus efficacement la recherche de la solution.
- L'intensification et la diversification, afin d'augmenter les chances d'avoir une solution de bonne qualité.

Dans le chapitre qui suit, nous proposons deux algorithmes pour la résolution du problème **MAX-W-SAT**. L'un est basé sur la recherche dispersée et l'autre est basé sur la recherche locale guidée.

Chapitre 4 :

Proposition d'algorithmes de résolution de MAX-W-SAT basés sur la recherche dispersée et la recherche locale guidée

4.1. INTRODUCTION :

La recherche dispersée et la recherche locale guidée sont des méta-heuristiques introduites dans le cadre de ce travail dans le but de résoudre efficacement le problème de la satisfiabilité maximale pondérée **MAX-W-SAT** qui est un problème important de l'intelligence artificielle.

En se basant sur la stratégie de diversification, la recherche dispersée génère un ensemble de solutions variées qui seront considérées comme les solutions candidates à améliorer, en utilisant une méthode d'amélioration.

La recherche locale guidée commence à appliquer une recherche locale simple pour obtenir un point de départ, généralement un optimum local. Afin d'échapper à cet optimum, la recherche locale guidée modifie la fonction objective en pénalisant les solutions de mauvaise qualité.

Dans ce qui suit, nous proposons deux solutions au problème MAX-SAT. La première est basée sur la recherche dispersée alors que la seconde est basée sur la recherche locale guidée.

4.2. ADAPTATION DE LA METHODE DE RECHERCHE DISPERSEE AU PROBLEME ETUDIE :

Pour pouvoir appliquer la recherche dispersée on doit passer par les étapes suivantes :

- Générer un ensemble de solutions dispersées «Population variée P» ;
- Avoir une fonction objective qui permet d'évaluer les solutions ;
- Choisir une certaine manière de générer l'ensemble $R \subset P$ afin de choisir Un ensemble de solutions meilleures dites solutions de référence;
- Avoir un opérateur de combinaison qui nous permet de construire d'autres Solutions ;
- Définir le test d'arrêt.

4.2.1. LA POPULATION INITIALE :

Afin d'avoir une population variée, les solutions initiales sont générées à l'aide d'une stratégie de diversification. Cette dernière, permettra d'explorer des zones diverses de l'espace de recherche.

Une solution au problème **MAX-W-SAT** est un vecteur X de taille n , tel que n est le nombre de variables où chaque variable $X[i]$ est une valeur booléenne (0 ou 1).

Exemple :

Soit la donnée SAT suivante :

$$\left\{ \begin{array}{l} C_1 : x_1 + x_2 + x_3 \\ C_2 : x_1 + x_2 + x_3 \\ C_3 : x_2 + x_3 \end{array} \right.$$

Pour :

Un ensemble de clauses $C = \{ c_1, c_2, c_3 \}$,

Un ensemble de variables $X = \{ x_1, x_2, x_3 \}$

Le tableau V , ci-dessous contient respectivement les valeurs 1, 0, 1. Les valeurs attribuées respectivement aux variables x_1, x_2, x_3 représentent une solution de la donnée SAT.

$$V = \begin{array}{|c|c|c|} \hline 1 & 0 & 1 \\ \hline \end{array}$$

$$V[1]= x_1=1, V[2]= x_2= 0, V[3]=x_3=1.$$

- **Méthode de diversification :**

La méthode de diversification utilisée dans la génération de la population initiale considère deux types de solutions :

Type 1 : il consiste à choisir un ensemble de cases repérées par un indice h et leur attribuer une valeur booléenne.

Type 2 : afin de générer des solutions diverses, le type 2 consiste à Complémenter les solutions de type 1, ce qui permettra d'avoir des solutions différentes de celles générées dans le type 1.

Ceci est réalisé en utilisant la méthode de diversification suivante :

```

Pour  $i=1 \rightarrow \text{sizepop}$  Faire // sizepop est la taille de la population P
Pour  $j=1 \rightarrow n$  Faire // n est le nombre de variables de la donnée SAT
P[i][j]=0 // P initialement à zéro

```

```

Tant que  $j \leq \text{sizepop}$  Faire
  Début
     $h=1$ 

    Tant que  $j \leq n$  Faire
      Début
         $P[i][j] = 1 - P[i][j];$  // type 1
         $j = j + h;$ 
      Fait
       $h = h + 1;$ 
       $i = i + 1;$ 

    Si  $i \leq \text{sizepop}$  alors
      Pour  $i=1 \rightarrow n$  Faire
         $P[i][j] = 1 - P[i-1][j];$  // type 2
      Fait
       $i = i + 1;$ 

  Fait

```

Exemple :

Pour $n=10$, $sizepop=10$, on aura la population suivante :

$$P = \left\{ \begin{array}{l} 1, 1, 1, 1, 1, 1, 1, 1, 1, 1 \\ 1, 0, 1, 0, 1, 0, 1, 0, 1, 0 \\ 1, 0, 0, 1, 0, 0, 1, 0, 0, 1 \\ 1, 0, 0, 0, 1, 0, 0, 0, 1, 0 \\ 1, 0, 0, 0, 0, 1, 0, 0, 0, 0 \\ 0, 0, 0, 0, 0, 0, 0, 0, 0, 0 \\ 0, 1, 0, 1, 0, 1, 0, 1, 0, 1 \\ 0, 1, 1, 0, 1, 1, 0, 1, 1, 0 \\ 0, 1, 1, 1, 0, 1, 1, 1, 0, 1 \\ 0, 1, 1, 1, 1, 0, 1, 1, 1, 1 \end{array} \right.$$

4.2.2. LA FONCTION OBJECTIVE :

Une solution est caractérisée par une fonction objective permettant de mesurer sa qualité. Cette dernière est donnée par la somme des poids des clauses satisfaites.

4.2.3. LA GENERATION DE L'ENSEMBLE R :

La recherche dispersée constitue un moyen pour réaliser une interaction efficace entre la diversification et l'amélioration. A chaque étape, une liste de solutions diverses et de haute qualité est conservée pour construire une nouvelle génération.

La qualité d'une solution est mesurée par la fonction objective alors que la diversité est mesurée par la fonction distance suivante :

- **Fonction de dispersion :**

Soient X, Y deux solutions dans l'espace de recherche. La distance entre X et Y est calculée comme suit :

distance = 0 ;

Pour $i=1 \rightarrow n$ **Faire**

Début

Si $X[i] \neq Y[i]$ **alors** distance = distance + 1 ;

Fait

Exemple :

Soient les deux solutions suivantes :

$$X = \{ 1, 1, 1, 1, 1, 1, 1, 1 \} \quad n=8 ;$$

$$Y = \{ 0, 0, 0, 0, 0, 0, 0, 0 \}$$

$$\text{Distance}(X, Y) = 1+1+1+1+1+1+1+1 = 8$$

Après avoir présenté les deux fonctions utilisées pour évaluer les solutions de l'ensemble de recherche (le coût et la disparité), on va décrire dans ce qui suit une construction de l'ensemble R qui comprend les points références.

Les points références sont les points de haute qualité plus les points éloignés dans l'espace de recherche. Ils seront construits comme suit :

- Ordonner la population initiale suivant la fonction objective ;
- Sélectionner les B1 premières solutions de P pour pouvoir déduire les solutions de haute qualité ;
- Sélectionner les B2 solutions diverses en exécutant le processus suivant :

Soient :

- Sizepop la taille de la population P
- B = B1+B2 la taille de l'ensemble R
- Initialement R contient les B1 solutions de haute qualité

Pour chaque solution $X \in (P-R)$,

- Calculer la distance entre X et les Solutions de R
- Sauvegarder la distance minimale

Ordonner les solutions de (P-R) suivant la disparité (distance) en commençant par celles qui possèdent une grande distance ;

Sélectionner les B2 premières solutions de l'ensemble (P-R) qui vont construire les solutions dispersées.

- Rajouter les B2 solutions sélectionnées à l'ensemble R pour le compléter.

4.2.4. LES SOLUTIONS ELITES :

Les points références vont participer à la construction d'un ensemble de solutions dites solutions élites. Avec un ensemble R de taille B on peut générer **4 types** de solutions définis comme suit :

Type 1 : Il consiste à grouper les éléments de R deux à deux, puis, pour chaque paire de solutions appliquer l'opérateur de combinaison.

Type 2: Les solutions seront combinées trois à trois, en prenant un couple de solutions de type1 et on lui rajoute une meilleure solution qui n'apparaît pas dans l'élément courant.

Type 3 : Les solutions seront combinées quatre à quatre. Pour chaque quadruplet obtenu, appliquer l'opérateur de combinaison

Type 4 : Les i meilleurs points de R seront groupés, où i = 5 jusqu'à B éléments

4.2.5. LA CONSTRUCTION DES SOLUTIONS COMBINEES :

Définir un bon opérateur de combinaison est une étape délicate dans l'implémentation de la recherche dispersée. Cet opérateur dépend de la fonction objective utilisée ainsi que de la représentation binaire de la solution.

- **L'opérateur de combinaison :**

Soient X, Y deux solutions dans l'ensemble R «des points références». La solution combinée Z est construite comme suit :

Pour $i=1 \rightarrow n$ **Faire**

Début

Si $X[i] = Y[i]$ **alors** $Z[i] = Y[i]$ // selon la représentation

Sinon

donner une valeur pour $Z[i]$ qui maximise la somme des poids des clauses satisfaites // en regardant la fonction objective

Fait

Exemple :

Soient :

Positif [i] = la somme des poids des clauses où x[i] apparaît positif

Négatif [i] = la somme des poids des clauses où x[i] apparaît négatif

On suppose la donnée SAT suivante :

$$\left\{ \begin{array}{ll} X_1 + \xi_2 + \xi_3 & w_1 = 100 \\ \xi_1 + X_2 + X_3 & w_2 = 200 \\ X_2 + X_3 & w_3 = 50 \end{array} \right.$$

Pour $n=3$, $C = \{ c_1, c_2, c_3 \}$, $X = \{ x_1, x_2, x_3 \}$

On aura les deux tableaux suivants :

Positif = {100, 250, 250}

Négatif = {200, 100, 100}

Soient les deux solutions suivantes :

$$X = \{ 1, 1, 0 \}$$

$$Y = \{ 0, 0, 0 \}$$

La solution combinée Z sera construite comme suit

$$X[1] \neq Y[1] \rightarrow \text{positif}[1] < \text{Négatif}[1] \rightarrow Z[1]=0 ;$$

$$X[2] \neq Y[2] \rightarrow \text{positif}[2] > \text{Négatif}[2] \rightarrow Z[2]=1 ;$$

$$X[3] = Y[3] \rightarrow Z[3]=X[3]=0 ;$$

Par conséquent $Z = \{ 0, 1, 0 \}$

4.2.6. L'AMELIORATION:

Afin d'approcher un optimum de haute qualité, la recherche dispersée s'appuie sur un deuxième principe qui consiste à améliorer la solution combinée en utilisant une méthode itérative. La méthode la plus utilisée est la recherche locale qui converge généralement vers un optimum local.

La méthode proposée est donnée comme suit :

INITIALISATION :

```
// S : la solution combinée
- Affecter à la solution combinée son coût.
// somme des poids des clauses satisfaites
// Itermax nombre maximum d'itérations
```

ITERATION :

Pour i=1 à itermax

Faire

- Générer le voisinage de S
- Inverser une variable dans les clauses non satisfaites
- Evaluer la configuration générée
- Si elle est meilleure remplacer la configuration initiale par cette dernière

Fait

Retourner la meilleure solution avec le meilleur coût

FIN

4.2.7. LE CRITERE D'ARRET:

Il nous faut encore définir une condition d'arrêt.

La recherche dispersée est stoppée après un certain nombre d'itérations ou lorsqu'on atteint la borne supérieure f^* de la fonction objective.

4.2.8. L'ALGORITHME DE LA RECHERCHE DISPERSEE :

L'algorithme de la recherche dispersée est présenté comme suit :

INITIALISATION :

- Engendrer une population initiale P en utilisant une stratégie de diversification
- Affecter à chaque solution son coût.
- Ordonner la population suivant la fonction objective
- // Itermax nombre maximum d'itérations

ITERATION :

Pour i=1 à itermax **Faire**

- Etablir une liste de solutions de taille B.
- // le critère de sélection favorise les meilleures.
- L'ensemble R est de taille B = B1+B2 où
- Les B1 solutions sont de haute qualité
- Les B2 solutions sont diverses

Nouveau = Vrai

Tant que (Nouveau)

Faire

- Calculer la taille de l'ensemble des solutions élites Maxsubset ;
- Nouveau = faux ;

Pour i=1 à Maxsubset **Faire**

- Générer les différents types de solutions
- Appliquer l'opérateur de combinaison pour obtenir une nouvelle solution s
- Améliorer la solution s
- Evaluer la solution améliorée s*.

Si (coût (s*) > coût(B1 ème solution de R)) et s* n'apparaît Pas dans R **alors**

- Insérer s*
- Ecraser la mauvaise
- Nouveau = Vrai ;

Sinon

Si (disparité (s*) > disparité(B2ème solution de R)) et s* n'apparaît Pas dans R **alors**

- Insérer s*
- Ecraser la mauvaise
- Nouveau = Vrai ;

Fait

- régénérer la population, en remplaçant les solutions de manière à favoriser encore les meilleures.

Fait

4.3. ADAPTATION DE LA METHODE DE RECHERCHE LOCALE GUIDEE AU PROBLEME ETUDIE :

Pour pouvoir appliquer la recherche locale guidée on doit passer par les étapes suivantes :

- Générer une solution initiale ;
- Appliquer la recherche locale
- Avoir une fonction objective augmentée qui permet de pénaliser certaines solutions ;
- Définir le test d'arrêt

4.3.1. LA SOLUTION INITIALE:

La recherche locale guidée démarre d'une configuration initiale générée aléatoirement. La représentation binaire est celle utilisée dans l'algorithme de recherche dispersée (vecteur de n variables booléennes).

$$X = \{ x_1, x_2, \dots, x_n \}, x_i \text{ est égal à } 0 \text{ ou } 1.$$

4.3.2. LA RECHERCHE LOCALE:

C'est une méthode itérative où chaque itération consiste à améliorer une configuration courante. L'amélioration consiste à effectuer des transformations successives (inverser un bit) sur la configuration initiale. Si le coût d'une configuration générée est meilleur que celui de la configuration courante, cette dernière sera remplacée par cette nouvelle configuration, sinon elle sera gardée. Ce processus est réitéré jusqu'à ce qu'aucune transformation ne réduise le coût de la configuration courante.

La méthode itérative utilisée est une recherche locale simple présentée comme suit :

INITIALISATION :

// S : la solution initiale
 - Affecter à la solution son coût //nombre de clauses non satisfaites.

// Itermax nombre maximum d'itérations

ITERATION :

Pour i=1 à itermax

Faire

- Générer le voisinage de la solution S
- Inverser une variable dans les clauses non satisfaites
- Evaluer la configuration générée
- Si elle minimise le coût alors remplacer la configuration initiale par la configuration trouvée

Fait

Retourner l'optimum local et son coût

FIN

4.3.3. LA FONCTION OBJECTIVE AUGMENTEE:

La fonction objective permet de mesurer la qualité d'une solution. Pour notre problème MAX-SAT cette fonction est donnée par la somme des clauses non satisfaites. Donc elle consiste à minimiser le nombre de clauses non satisfaites. Afin d'échapper aux optima- locaux, la fonction coût a été modifiée en ajoutant une partie permettant d'augmenter le coût des solutions déjà visitées, ce qui impliquera une exploration plus diversifiée de l'espace de recherche.

La fonction objective augmentée est donnée par la formule suivante :

$$H(S) = G(S) + \lambda * \sum_{i=1}^m I_{ni}(S) * P(i)$$

Où :

H : Fonction objective augmentée ;

G : Coût de la solution S = nombre de clauses non satisfaites;

S : Configuration courante ;

$I_{ni}(S)$: Indicateur ;

P(i) : Pénalité ;

m : Nombre de clauses ;

λ : Facteur de pénalisation ;

$\lambda > 1$: Recherche diversifiée ;

$\lambda < 1$: Recherche intensifiée.

- **Principe de résolution :**

La recherche locale guidée consiste à pénaliser les clauses non satisfaites par le nombre de fois de leurs apparitions dans le but d'augmenter la fonction objective des solutions de mauvaise qualité. Cela est réalisé en utilisant une série de formules présentées dans ce qui suit :

$$\text{Formule 1 : } \quad \text{Ini(S)} = \begin{cases} 1 & \text{Si, pour la configuration S, la clause i} \\ & \text{est non satisfaite ;} \\ 0 & \text{Sinon.} \end{cases}$$

$$\text{Formule 2 : } \quad \text{C(i)} = \text{poids de la clause i}$$

$$\text{Formule 3 : } \quad \text{Utilité(i)} = \text{Ini(S)} * \text{C(i)} / 1 + \text{P(i)}$$

Où :

P(i) : Est la pénalité ou encore un compteur de fréquence. Au début P(i) est initialisée à zéro, quand la clause i est non satisfaite P(i) est mis à jour.

Ini(S) : Indique si la clause i est satisfaite ou pas.

Utilité(i) : Permet de pénaliser les solutions déjà visitées.

Donc le problème revient à pénaliser les clauses non satisfaites ayant une utilité assez grande. Cette façon de faire permet de pénaliser les solutions déjà visitées, ce qui conduira vers une exploration plus diversifiée de l'ensemble de recherche et augmente les chances de trouver un optimum de haute qualité.

4.3.4. L'ALGORITHME DE LA RECHERCHE LOCALE GUIDÉE :

Une version de l'algorithme de la recherche locale guidée est la suivante :

INITIALISATION :

- Générer aléatoirement une solution initiale S
- Affecter à la solution générée son coût // nombre de clause non satisfaite.
- // G est la fonction objective standard
- // Itermax nombre maximum d'itérations
- // H = la fonction objective augmentée
- // m = nombre de clauses

Pour i=1 à m **Faire** P(i)=0 ;

ITERATION :

Pour i=1 à Itermax **Faire**

- S := recherche locale(S, H)

// appel de l'algorithme de recherche locale avec les paramètres H et S
 // la recherche locale retourne une solution S qui est le minimum local

Pour chaque (clause non satisfaite fi)

Faire

- Calculer l'utilité de chaque clause non satisfaite

$$\text{Utilité}(fi) = \text{Infi}(S) * C(fi) / 1 + P(fi)$$

- Soit utilité- max égale à l'utilité maximale

Si (utilité(fi) = utilité- max) **alors** P(fi) = P(fi)+1

Fait

Fait

Retourner la meilleure solution avec le meilleur coût

FIN

4.4. CONCLUSION :

Dans ce chapitre, nous avons proposé deux algorithmes pour la résolution du problème **MAX-W-SAT** basés sur la recherche dispersée et la recherche locale guidée. Dans le prochain chapitre, ces méthodes seront testées à travers des expérimentations numériques pour mesurer leur performance.

Chapitre 5 :

Résultats expérimentaux

5.1. INTRODUCTION :

Afin de mesurer les performances des méta- heuristiques mises en œuvre, des tests ont été effectués sur quelques instances dont on sait apprécier les solutions optimales. Nos algorithmes ont été implémentés sous la plate forme suivante :

- **Machine** : Pentium 300 MMX, 32 MO de RAM.
- **Système d'exploitation** : Windows 95.
- **Langage de programmation** : C++ BUILDER.

Dans nos expériences, nous avons désigné les différentes solutions par :

- **SS_tcpu** : Temps d'exécution de la recherche dispersée.
- **GLS_tcpu** : Temps d'exécution de la recherche locale guidée.
- **SS** : Somme des poids des clauses satisfaites donnée par la recherche dispersée.
- **GLS** : somme des poids des clauses satisfaites donnée par la recherche locale guidée.

La comparaison est basée sur deux paramètres :

- la somme des poids des clauses satisfaites.
- Le temps CPU (temps de calcul).

5.2. RESULTATS :

L'efficacité d'une méta- heuristique dépend largement d'un bon ajustement de ses paramètres. Ceux-ci sont fixés suivant les expérimentations effectuées (Voir annexe) et les valeurs prises sont celles pour lesquelles il existe un compromis entre la qualité de la solution obtenue par la méta- heuristique et le temps d'exécution de l'algorithme.

Pour la recherche dispersée, la taille de la population (sizepop), la taille de l'ensemble R (B), nombre d'itérations de la recherche locale (Aiter), et Maxiter (nombre d'itérations) sont les paramètres à ajuster.

Pour la recherche locale guidée les paramètres de contrôle sont : Maxiter(nombre maximum d'itérations), nombre d'améliorations de la recherche locale (Aiter) et λ le facteur de diversification.

Suite à des tests intensifs, les paramètres de ces deux méta- heuristiques sont fixés comme suit :

- **La recherche dispersée :** Sizepop=100, B1=5, B2= 5, Maxiter=3, et Aiter=100.
- **La recherche locale guidée :** Maxiter= 100, Aiter=1000, et $\lambda=1$.

Instances MAX-SAT :

Dans nos expériences, nous avons considéré deux modèles :

Modèle 1 : le nombre de clauses est égal à 800, le nombre de variables est égal à 100 (Jnh201, Jnh202, Jnh203, Jnh205, Jnh207, Jnh208, Jnh209, Jnh210, Jnh211, Jnh212, Jnh214, Jnh215, Jnh216, Jnh217, jnh218) et la somme des poids des clauses est égale à 394238.

Modèle 2 : le nombre de clauses est égal à 850, le nombre de variables est égal à 100 (Jnh1, Jnh10, Jnh11, Jnh12, Jnh13, Jnh14, Jnh15, Jnh16, jnh17, Jnh18, Jnh19) et la somme des poids des clauses est égale à 420925.

Ces instances sont prises du site Internet «[Http://www.research.att.com/mgcr/data/index.html](http://www.research.att.com/mgcr/data/index.html)» dont les solutions optimales sont connues. Ce sont des problèmes difficiles de la classe Johnson.

Les résultats obtenus par la recherche dispersée et la recherche locale guidée sont les suivants :

Modèle 1 :

Benchmark	Optimale	SS	SS_tcpu	GLS	GLS_tcpu
Jnh201	394238	394238	6.44	394238	21.07
Jnh202	394170	394022	2067.29	393818	3120.00
Jnh203	394199	394135	2379.43	393206	3383.07
Jnh205	394238	394238	1840.49	393903	1916.82
Jnh207	394238	394045	1975.44	393585	1883.44
Jnh208	394159	393934	2219.86	392936	2080.54
Jnh209	394238	393971	1916.71	393812	1824.38
Jnh210	394238	394238	293.56	394238	334.33
Jnh211	393979	393372	2296.44	392921	2189.21
Jnh212	394238	394029	2046.90	393993	1952.04
Jnh214	394163	393377	2079.27	393341	1974.02
Jnh215	394150	393451	2130.24	393872	2042.12
Jnh216	394226	393399	2231.51	393391	2115.18
Jnh217	394238	394238	650.46	394238	1606.38
Jnh218	394238	394238	605.65	394238	914.47

Figure 5.1. Les résultats trouvés par la recherche dispersée et la recherche locale guidée pour le modèle 1 :

La recherche dispersée et la recherche locale guidée donnent de bons résultats mais les solutions trouvées par la recherche dispersée sont nettement meilleures que celles fournies par la recherche locale guidée. L'histogramme suivant le montre avec clarté :

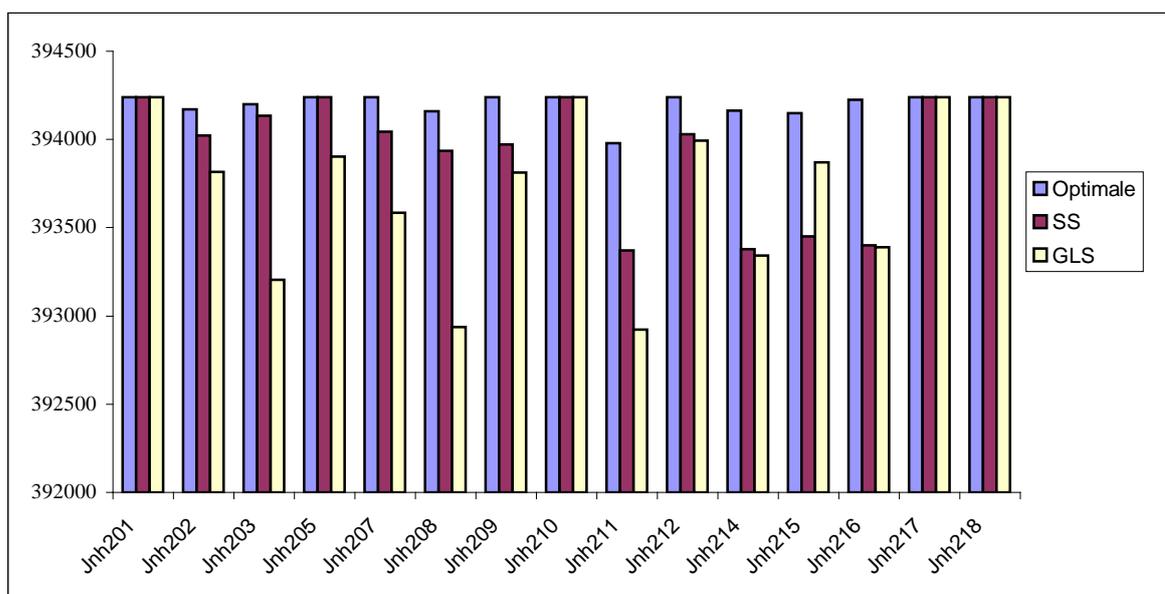


Figure 5.2. Comparaison entre les solutions SS, les solutions GLS et les solutions optimales pour le modèle1.

Modèle 2 :

La table ci-dessous, présente les résultats déterminés par la recherche dispersée et la recherche locale guidée pour le modèle 2 :

Benchmark	Optimale	SS	SS_tcpu	GLS	GLS_tcpu
Jnh1	420925	420925	1159.88	420806	1782.72
Jnh10	420840	420165	1860.38	419420	2432.27
Jnh11	420753	420274	2404.32	420413	2300.99
Jnh12	420925	420706	2407.00	420925	1220.29
Jnh13	420816	420302	2593.60	419491	3249.01
Jnh14	420824	420510	2555.30	420545	2738.84
Jnh15	420719	419671	2680.10	419004	43800.2
Jnh16	420919	420821	2380.91	420063	2294.55
Jnh17	420925	420925	2080.00	420830	2226.41
Jnh18	420795	420692	2576.90	419525	2467.08
Jnh19	420759	420107	2521.19	419468	2428.60

Figure 5.3. Les résultats trouvés par la recherche dispersée et la recherche locale guidée pour le modèle 2 :

On remarque bien que la recherche dispersée et la recherche locale guidée trouvent l'optimum pour certaines instances et pour les autres, l'écart à l'optimum n'est pas très grand. L'histogramme qui suit permet de comparer ces algorithmes en matière de performance :

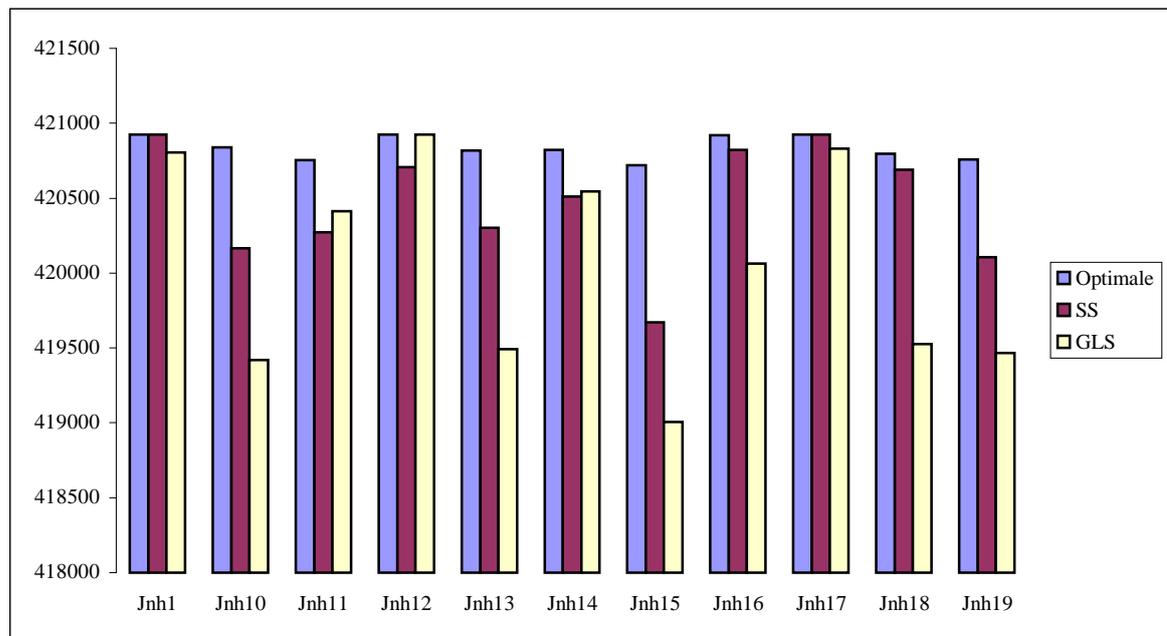


Figure 5.4. Comparaison entre les solutions SS, les solutions GLS et les solutions optimales pour le modèle2.

Commentaire :

Les tableaux ci- dessus montrent les résultats obtenus par la recherche dispersée et la recherche locale guidée ainsi que les solutions optimales.

Il est bien clair dans ces résultats que le degré de difficulté de la résolution du problème varie d'un problème à un autre. Les problèmes Jnh201 et Jnh210 possèdent un degré de difficulté plus petit et les deux algorithmes aboutissent en un temps réduit contrairement aux autres problèmes (Jnh208 et Jnh211) où les deux algorithmes prennent plus du temps pour trouver une solution de bonne qualité. Cela est dû essentiellement à la nature des problèmes, car Jnh201 (par exemple) ne comporte pas des clauses contradictoires contrairement aux problèmes Jnh208 et Jnh211. Ces derniers comportent des clauses qui ont plus de chances d'être contradictoires, c'est -à- dire, qui ne pourront jamais être satisfaites en même temps par la même affectation.

Ce qu'il faut noter aussi en ce qui concerne les solutions trouvées, c'est l'écart entre ces dernières et la solution optimale qui est négligeable dans certaines instances, ce qui prouve la puissance de la recherche dispersée et la recherche locale guidée dans la résolution du problème MAX-W-SAT.

5.3. INTERPRETATION DES TESTS EFFECTUES :

Dans nos tests, nous avons utilisé des données MAX-SAT dont le degré de difficulté est assez important ceci est dû essentiellement à la nature de ces problèmes et le nombre important d'optima-locaux dans l'espace de solutions. Ces instances se caractérisent par un nombre de clauses compris entre 800 et 900 et un nombre de variables égal à 100.

Pour la recherche dispersée, nous remarquons d'après les tests effectués que la taille de la population et la taille de l'ensemble R sont deux paramètres très importants pour la robustesse de la recherche dispersée. Ils fournissent un degré de diversification significatif à la recherche.

En effet, lorsqu'on augmente B et sizepop, la recherche devient efficace mais le temps CPU croit. Pour cela le réglage de ces paramètres est une opération importante dans la recherche et le bon ajustement conduira nécessairement à des résultats satisfaisants.

De même la recherche locale guidée procure généralement une solution de bonne qualité. Toutefois, cette méthode représente quelques inconvénients comme le temps de calcul qui est excessif pour avoir une solution de haute qualité. Le paramètre Maxiter utilisé pour la recherche locale guidée joue un rôle dans la qualité des solutions trouvées. Si celui-ci est important la recherche devient efficace mais perd en rapidité d'exécution, et à l'inverse il diminue l'efficacité mais accélère la recherche.

Nous constatons que la recherche dispersée donne d'excellents résultats. Elle atteint l'optimum plus rapidement que la recherche locale guidée. Les temps sont compris entre 0.50 et 3000 secondes (obtention d'une solution optimale).

En effet, la recherche dispersée tient sa supériorité du fait de l'intégration de plusieurs techniques de diversification et d'amélioration. Ainsi le générateur de la population augmente la probabilité de trouver un optimum de bonne qualité rapidement (Jnh201), alors que la recherche locale guidée utilise sa fonction objective augmentée pour éviter l'optimum local trouvé par la recherche locale et essaie de retomber sur un optimum global après un certain nombre d'itérations.

Chapitre 6 :

Approches hybrides

6.1. INTRODUCTION :

Dans le but de valider les différents algorithmes développés, des tests ont été effectués sur différents problèmes **MAX-W-SAT**.

Afin que la qualité des solutions trouvées soit plus significative, nous utilisons les algorithmes de comparaison suivants:

- La procédure GSAT avec marche aléatoire.
- La recherche tabou avec bruit aléatoire.
- La procédure GRASP.
- La recherche dispersée avec marche aléatoire.
- La recherche dispersée avec bruit aléatoire.
- La recherche locale guidée avec marche aléatoire.
- La recherche locale guidée avec bruit aléatoire.

6.2. La procédure GSAT avec marche aléatoire:

La procédure **GSAT** développée par Selman [SML 92] permet d'obtenir une instanciation en commençant par une assignation aléatoire puis procède à changer l'assignation de la variable qui mène à la plus grande baisse dans le nombre total des clauses non satisfaites. C'est une heuristique très puissante, elle permet d'obtenir des résultats très satisfaisants. Afin d'améliorer ses performances, une stratégie de «**marche aléatoire**» a été ajoutée à l'algorithme pour modifier la règle de choix du voisin, et ça, dans l'algorithme **GSAT avec marche aléatoire**.

Cet algorithme se présente de la manière suivante [BP 96] :

```

Pour i := 1 à MAX-ESS
faire
  X := assignation aléatoire
  Pour j := 1 à MAX-ITER
  faire
    Si Randomnbr() < p alors
      Var := variable quelconque  $\in$  à une clause non satisfaite
    Sinon var := la variable dont  $\Delta f$  est le plus grand
    FLIP(var)
  Fait
Fait

```

Où :

Randomnbr () : est une procédure qui génère un nombre aléatoire entre 0 et 1.
 FLIP(var) : inverse la variable var (var := 1- var).
 Δf : coût d'une configuration.
 MAX-ESS : nombre d'essais.
 MAX-ITER : nombre d'itérations.

A chaque itération une variable est choisie par deux critères différents :

- La variable est choisie aléatoirement d'une clause non satisfaite, avec une probabilité p.
- En se basant sur la fonction objective f, choisir la variable avec le plus grand Δf .

6.3. La recherche tabou avec bruit aléatoire[Dri 99]:

Le choix de la configuration voisine peut avoir un effet considérable aussi bien sur le temps de recherche que sur la qualité de la solution finale. Dans l'algorithme de la recherche tabou, la solution voisine est obtenue en choisissant la meilleure transition non tabou. Une amélioration possible serait de choisir cette solution à partir d'un algorithme de recherche tabou avec bruit aléatoire. Il introduit un bruit représenté par une probabilité p.

Avec une probabilité p, la configuration voisine est choisie aléatoirement. Avec une probabilité 1-p, la solution adjacente est construite en se basant sur la règle de choix du voisin de la recherche tabou.

Ci-dessous une version de l'algorithme itératif de la recherche tabou avec bruit aléatoire :

L'algorithme tabou avec le bruit aléatoire :**Etape 1 : Initialisation**

- Choisir une solution initiale générée aléatoirement $s = s_0$;
- nbiter = 0 /* itération courante */ ;
- bestiter = 0 /* itération ayant donné la meilleure solution */ ;
- bestsol = s_0 /* meilleure solution */ ;
- $LT = \Phi$ /* liste tabou initialisée à vide */ ;
- P /* est le bruit */

Etape 2 : Processus itératif**Tant que** (nbiter- bestiter < nbmax)**Faire**

***Si (RandomNumber () < p) alors /*randomNumber fournit un nombre */
/* aléatoire compris entre 0 et 1 */***

- nbiter = nbiter + 1 ;
- Générer un ensemble $V^* \subseteq N(s)$ de solutions voisines de s ;
- Choisir la meilleure solution $s' \in V^*$ telle que $s' \notin LT$ ou satisfait le critère d'aspiration ;
- Mettre à jour la liste tabou ;

Sinon s= n'importe quel voisin de la solution courante

- $s = s'$;
- ***si*** $f(s) < f(\text{bestsol})$ ***alors*** $\text{bestsol} = s'$; $\text{bestiter} = \text{nbiter}$;

Fait**Fin**

6.4. La procédure GRASP :

La procédure GRASP (Greedy Randomized Adaptive Search Procedure) combine deux phases : une phase de construction aléatoire (Glouton) pour construire une solution initiale et une phase d'amélioration locale. Le processus de construction et d'amélioration est réitéré pour un certain nombre d'itérations.

Dans la phase de construction, les transitions possibles sont ordonnées dans une liste candidate. La solution est construite aléatoirement à partir de la liste candidate, en choisissant pour une variable à assigner une valeur de vérité.

La construction:

Pour $k=1 \rightarrow n$

Faire

- Créer la liste candidate
- Sélectionner aléatoirement une transition
- Affecter une valeur de vérité pour la variable
- Appliquer la fonction Glouton.

Fait

Afin d'améliorer la solution construite par la première procédure, GRASP fait appel à une recherche locale après chaque construction.

La procédure GRASP est présentée comme suit [BP 98] :

Etape 1 : Initialisation

```
nbiter = 0 /* itération courante */ ;
nbmax /* nombre maximum d'itérations */ ;
```

Etape 2 : Processus itératif

Tant que (nbiter < nbmax)

Faire

- nbiter = nbiter + 1;
- Construction() ;
- Amélioration();

Fait

FIN

6.5. Approches hybrides :

Dans cette section, nous proposons quatre hybridations d'algorithmes basées sur l'introduction des stratégies de bruit et de marche aléatoires dans la recherche dispersée et la recherche locale guidée.

L'hybridation des méta- heuristiques en question avec les stratégies de bruit et de marche aléatoires se présente comme suit :

6.5.1. La recherche dispersée avec marche aléatoire :

Dans cette hybridation, le passage à la prochaine solution se fait selon les deux critères suivants :

- La variable est tirée aléatoirement d'une clause non satisfaite, avec une probabilité p .
- La configuration voisine est obtenue en appliquant la recherche dispersée, avec une probabilité $1-p$.

Cet algorithme est donné comme suit :

```

Pour  $i := 1$  à MAX-ESS
Faire
    X := meilleure assignation dans la population
    Pour  $j := 1$  à MAX-ITER
    Faire
        Si Randomnbr() <  $p$  alors
            Var := variable quelconque appartenant à une clause non satisfaite
            FLIP(var)
        Sinon
            Recherche dispersée() ;
    Fait
Fait

```

Où :

Randomnbr() est une procédure qui génère un nombre aléatoire entre 0 et 1.
 MAX-ESS : nombre d'essais.
 MAX-ITER : nombre d'itérations.
 FLIP(var) : inverse la variable var.

6.5.2. La recherche dispersée avec bruit aléatoire :

Une version de l'algorithme de recherche dispersée avec bruit aléatoire est donnée comme suit :

```

Pour i := 1 à MAX-ESS
Faire
    X := meilleure assignation dans la population

    Pour j := 1 à MAX-ITER
    Faire
        Si Randomnbr() < p alors
            Var := variable quelconque
            FLIP(var)

        Sinon
            Recherche dispersée() ;

    Fait
Fait
  
```

Où :

Randomnbr() est une procédure qui génère un nombre aléatoire entre 0 et 1.

MAX-ESS : nombre d'essais.

MAX-ITER : nombre d'itérations.

FLIP(var) : inverse la variable var.

Cette approche possède un paramètre très important qui est le bruit. En augmentant la valeur de p on accélère la recherche mais on diminue de son efficacité, et en diminuant on ralentit la recherche mais on gagne en efficacité. La valeur optimale de p est positionnée empiriquement entre 0.5 et 0.6.

6.5.3. La recherche locale guidée avec marche aléatoire :

Dans sa forme standard, la recherche locale guidée est guidée par une fonction objective augmentée, et le critère de base est d'accepter un voisin s'il satisfait plus de clauses. A quelle ampleur les résultats seront affectés si nous changeons la règle de choix du voisin, en rajoutant des stratégies de bruit ou de marche aléatoires.

L'algorithme de la recherche locale guidée simple, a été modifié dans le but de choisir un voisin suivant des critères différents, et ça, dans les algorithmes suivants :

L'algorithme de recherche locale guidée avec marche aléatoire se présente de la manière suivante :

```

Pour i := 1 à MAX-ESS
Faire
    X := assignation aléatoire

    Pour j := 1 à MAX-ITER
    Faire
        Si Randomnbr() < p alors
            Var := variable quelconque appartenant à une clause non satisfaite
            FLIP(var)

        Sinon
            Recherche locale guidée() ;

    Fait
Fait
  
```

Randomnbr() est une procédure qui génère un nombre aléatoire entre 0 et 1.

MAX-ESS : nombre d'essais.

MAX-ITER : nombre d'itérations.

FLIP(var) : inverse la variable var.

Cette hybridation consiste à choisir la variable à inverser par les deux critères donnés comme suit :

- Avec une probabilité p, la variable est choisie aléatoirement à partir d'une clause non satisfaite.
- Avec une probabilité 1-p, appliquer la recherche locale guidée.

6.5.4. La recherche locale guidée avec bruit aléatoire:

L'introduction de la stratégie de bruit aléatoire dans la recherche locale guidée a donné l'algorithme suivant :

```

Pour i := 1 à MAX-ESS
Faire
    X := assignation aléatoire ;
    Pour j := 1 à MAX-ITER
        Faire
            Si Randomnbr() < p alors
                Var := variable quelconque.
                FLIP(var)

            Sinon Recherche locale guidée().

        Fait
    Fait
Fait
  
```

Où :

Randomnbr() est une procédure qui génère un nombre aléatoire entre 0 et 1.

MAX-ESS : nombre d'essais.

MAX-ITER : nombre d'itérations.

FLIP(var) : inverse la variable var.

Dans la recherche locale guidée avec bruit aléatoire, la solution voisine est obtenue selon les mêmes critères cités dans la recherche dispersée avec bruit aléatoire.

La configuration adjacente est choisie aléatoirement, avec une probabilité p , ou en appliquant la recherche locale guidée, avec une probabilité $1-p$.

6.6. CONCLUSION :

Nous venons de voir qu'ils existent différents modes d'exploration de l'espace de solutions. Les méta- heuristiques se différencient selon la manière dont elles font varier l'intensité de l'exploration au cours de recherche.

Dans la méthode GSAT, par exemple, le mécanisme de base repose sur une règle dite agressive consistant à choisir systématiquement le meilleur voisin. Une manière efficace d'améliorer GSAT de base est l'option de marche aléatoire qui consiste à alterner les mouvements de base et des mouvements totalement aléatoires.

Une autre stratégie pour explorer consiste à mémoriser au cours de la recherche des caractéristiques des régions visitées et à introduire un mécanisme permettant de s'éloigner de ces zones. C'est ce que fait la méthode tabou avec la liste tabou.

Les stratégies de bruit et de marche aléatoires ont été développées pour la recherche dispersée et la recherche locale guidée dans ce chapitre. Seuls les expérimentations intensives peuvent nous renseigner si de telles stratégies augmentent la performance de ces méta- heuristiques. Le chapitre suivant fait l'objet en effet de cette préoccupation.

Chapitre 7 :

Validation des approches développées

7.1. INTRODUCTION :

Comme pour toute méta- heuristique, deux types d'expérimentations doivent être menées : la première catégorie concerne le réglage des paramètres des algorithmes et la seconde teste la performance des approches considérées.

7.2. REGLAGE DES PARAMETRES :

Avant de se lancer dans l'étude comparative entre les différentes approches présentées, le réglage de certains paramètres s'impose. Les résultats empiriques sont montrés dans les tables suivantes :

Symbole	Valeur
Tabou tenure	7
Maxiter	10000
P	0.5

Table 1 : Paramètres de la recherche tabou avec bruit aléatoire

Symbole	Valeur
N_essais	10
Maxiter	1000
P	0.5

Table 2 : Paramètres du GSAT avec marche aléatoire

Symbole	Valeur
Aiter	1000
Maxiter	1000
P	0.5

Table 3 : Paramètres de la recherche locale guidée avec marche aléatoire

Symbole	Valeur
Aiter	1000
Maxiter	1000
P	0.5

Table 4 : Paramètres de la recherche locale guidée avec bruit aléatoire

Symbole	Valeur
Sizepop	100
B1	5
B2	5
Aiter	10
Maxiter	10000
P	0.5

Table 5 : Paramètres de la recherche dispersée avec marche aléatoire

Symbole	Valeur
Sizepop	100
B1	5
B2	5
Aiter	10
Maxiter	1000
P	0.5

Table 6 : Paramètres de la recherche dispersée avec bruit aléatoire

7.3. RESULTATS :

Les expériences numériques sur des instances **MAX-W-SAT** difficiles ont fourni les résultats résumés dans la série des tables montrées sur les figures apparaissant ultérieurement.

- ❖ Les résultats trouvés par la procédure **GSAT** avec marche aléatoire et la recherche tabou avec bruit aléatoire sont exposés dans la table suivante :

Benchmark	Optimale	GsatW	GS_tcpu	TabouW	Tab_tcpu
Jnh201	394238	394238	15.24	394238	143.45
Jnh202	394170	393155	240.36	392837	242.58
Jnh203	394199	392804	274.01	392485	275.26
Jnh205	394238	393959	233.79	393752	235.07
Jnh207	394238	393049	243.71	392708	230.28
Jnh208	394159	392296	255.82	392380	254.41
Jnh209	394238	392933	223.52	392992	225.30
Jnh210	394238	393864	229.41	394238	222.46

Figure 7.1. Les solutions trouvées par la recherche tabou avec bruit aléatoire et GSAT avec marche aléatoire.

La procédure **GSAT** avec marche aléatoire et la recherche tabou avec bruit aléatoire donnent des solutions assez bonnes. Dans ces résultats, on remarque que le problème Jnh201 possède un degré de difficulté plus petit et les deux algorithmes aboutissent en un temps réduit. Les solutions fournies par la recherche dispersée et la recherche locale guidée sont les meilleures.

L'histogramme suivant permet de comparer les algorithmes testés jusqu'à présent en matière de performance.

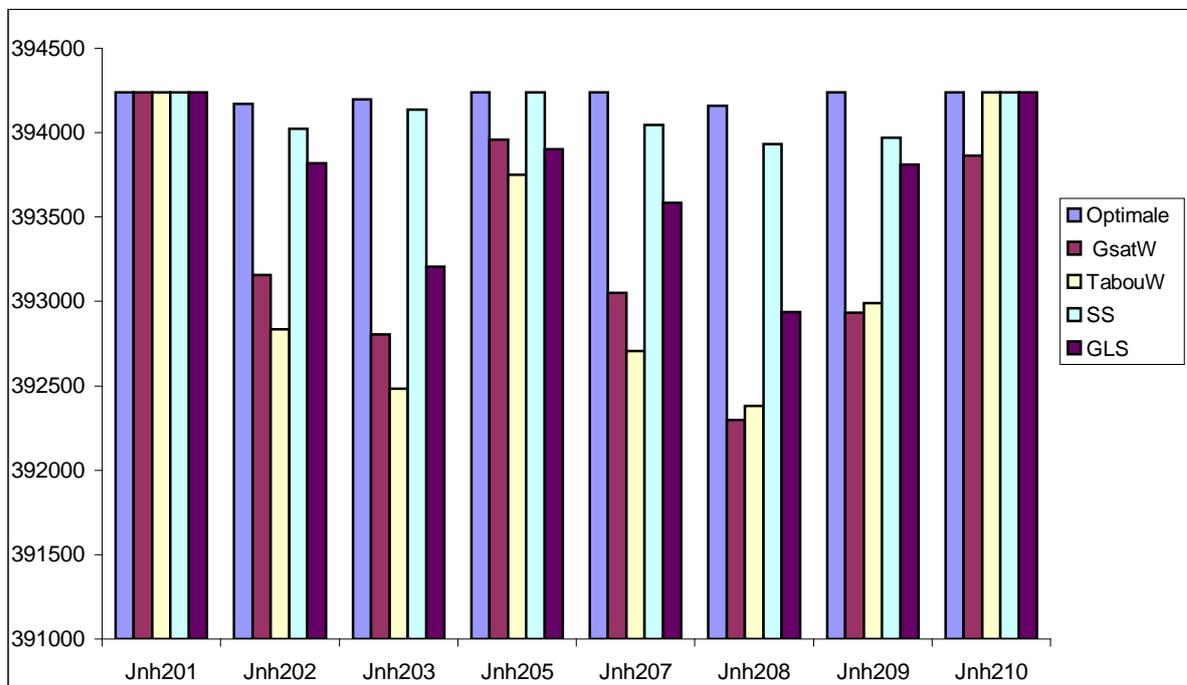


Figure 7.2. Comparaison entre la recherche dispersée, la recherche locale guidée, la recherche tabou avec bruit aléatoire et GSAT avec marche aléatoire.

D'après les tables représentant les tests effectués sur quelques instances **MAX-W-SAT** difficiles, on constate que l'algorithme de recherche dispersée s'est avéré très efficace en qualité de solutions par rapport aux autres méthodes développées.

- ❖ Sur la table suivante, nous reportons les résultats déterminés par la procédure **GRASP** :

Benchmark	Optimale	GRASP	TCPU	SS	SS_tcpu
Jnh201	394238	394154	310.4	394238	6.44
Jnh202	394170	393680	312.2	394022	2067.29
Jnh203	394199	393446	351.2	394135	2379.43
Jnh205	394238	393890	327.8	394238	1840.49
Jnh207	394238	394030	304.7	394045	1975.44
Jnh208	394159	393893	355.2	393934	2219.86
Jnh209	394238	393959	339.0	393971	1916.71
Jnh210	394238	393950	318.5	394238	293.56

Figure 7.3. Les solutions trouvées par GRASP [BP 98].

A partir de la table ci-dessus, on remarque que la recherche dispersée trouve l'optimum global pour certaines instances, et pour les autres l'écart à l'optimum n'est pas très grand. Les résultats respectifs sont meilleurs que ceux fournis par la procédure **GRASP**, concernant la qualité des solutions. L'historique suivant le montre avec clarté.

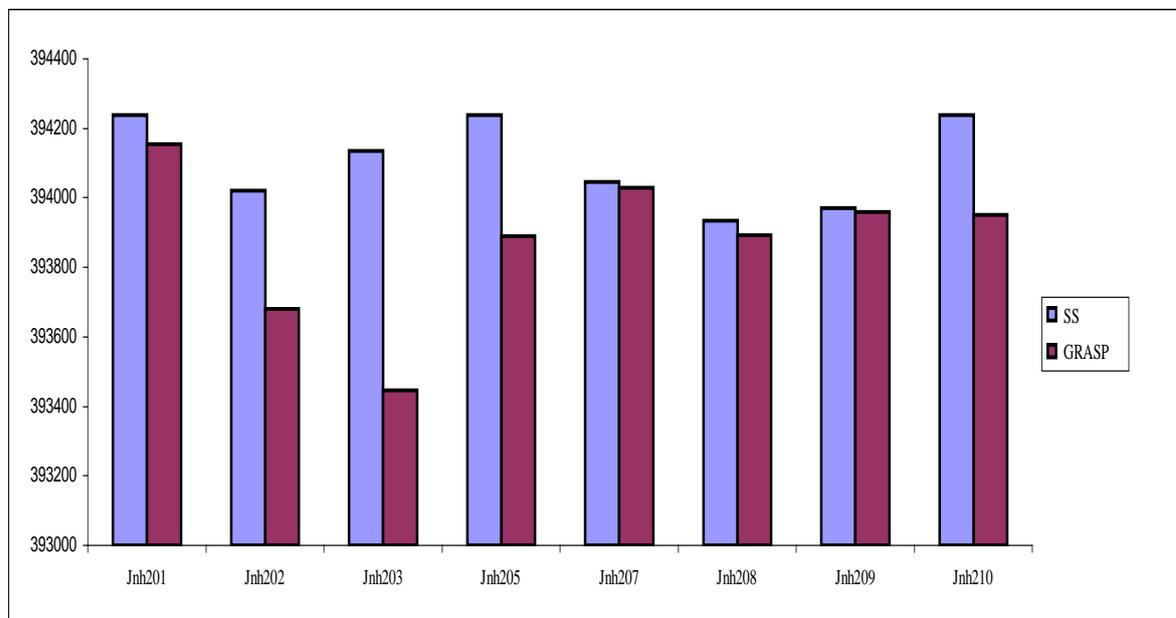


Figure 7.4. Comparaison entre la recherche dispersée et la procédure GRASP.

- ❖ La figure 7.5 montre la comparaison entre la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire. L'histogramme qui suit schématise les résultats de la comparaison :

Benchmark	Optimale	SSW	Swtcpu	SSnoise	SSN_tcpu
Jnh201	394238	394238	28.48	394238	25.12
Jnh202	394170	392788	256.05	394044	1086.39
Jnh203	394199	392795	293.14	393498	1198.62
Jnh205	394238	393300	250.23	393903	338.74
Jnh207	394238	393262	245.67	393745	758.63
Jnh208	394159	392608	272.03	393822	384.74
Jnh209	394238	392819	237.29	393459	919.42
Jnh210	394238	393951	240.91	394238	395.43
Jnh211	393979	391993	284.32	392986	526.55
Jnh212	394238	392710	251.17	394074	610.96
Jnh214	394163	392825	256.98	393077	608.92
Jnh215	394150	393188	264.44	393951	478.22
Jnh216	394226	392661	277.07	393882	860.10
Jnh217	394238	394238	165.42	394197	499.25
Jnh218	394238	393763	251.90	394238	285.55
Jnh1	420925	420609	234	420806	658.16
Jnh10	420840	418550	316.04	419603	674.21
Jnh11	420753	419341	296.49	419658	481.34
Jnh12	420925	418947	307.79	420701	484.94
Jnh13	420816	418447	320.62	418891	598.83
Jnh14	420824	419145	313.44	419358	589.05
Jnh15	420719	419032	322.52	419800	848.66
Jnh16	420919	419501	291.38	420746	914.16
Jnh17	420925	419959	289.65	420925	225.89
Jnh18	420795	418710	317.79	419746	680.99
Jnh19	420759	418765	310.52	419746	567.79

Figure 7.5. Les solutions trouvées par la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire.

Pour la plupart de jeux d'essai :

- Soit la qualité de la solution est dans les deux cas comparable.
- Soit la recherche dispersée avec bruit aléatoire fournit des résultats meilleurs que ceux trouvés par la recherche dispersée avec marche aléatoire.

L'avantage principal de ces méthodes réside dans leur grande simplicité et leur rapidité. Mais les solutions produites sont souvent de qualité médiocre.

Quant à la recherche dispersée, ses performances en qualité des solutions obtenues sont très bonnes.

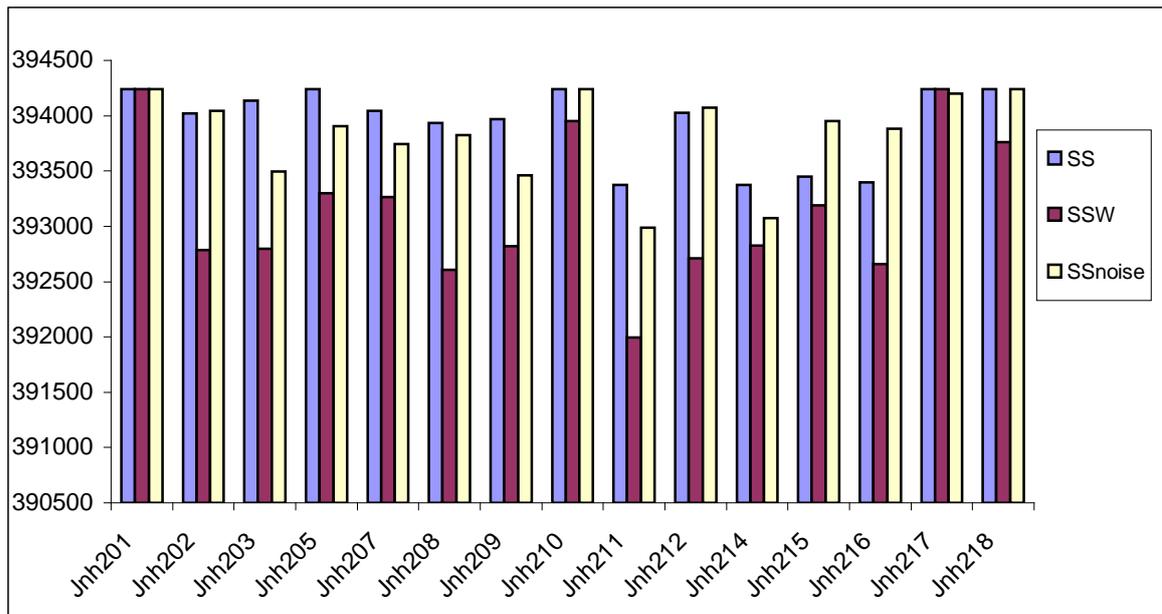


Figure 7.6. Comparaison entre la recherche dispersée, la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire, pour modèle 1.

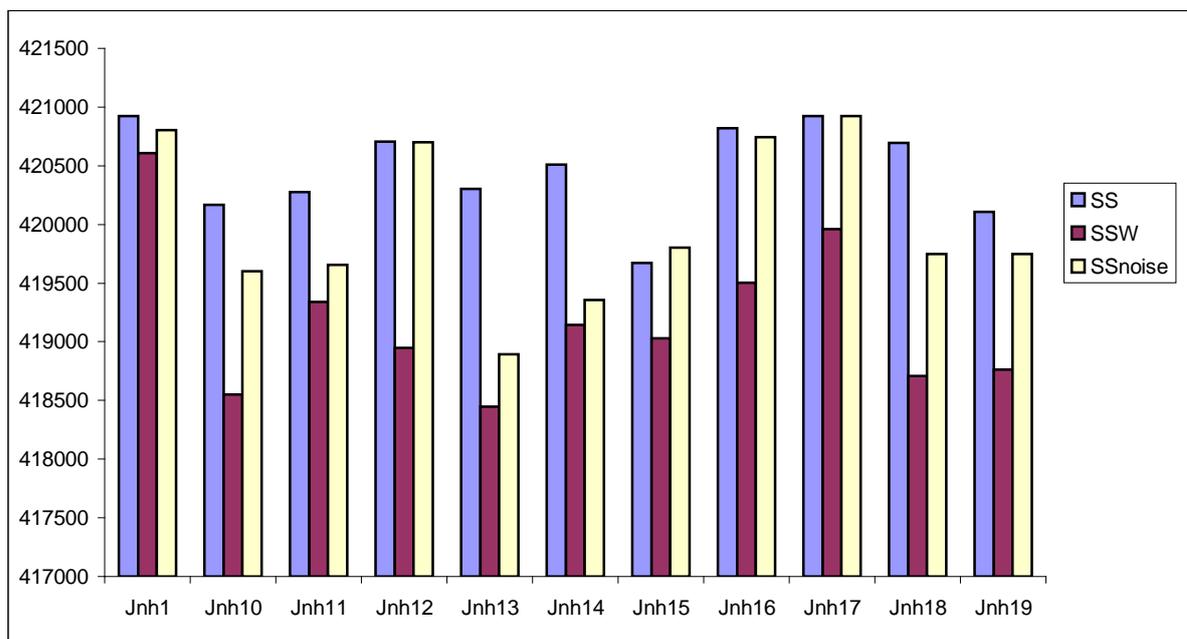


Figure 7.7. Comparaison entre la recherche dispersée, la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire, pour modèle 2.

La recherche dispersée avec bruit aléatoire donne des solutions qui sont en général meilleures que celles trouvées par la recherche dispersée avec marche aléatoire, voire parfois excellentes (l'optimum global). Ceci en ce qui concerne la qualité de la solution obtenue et le temps de calcul qui lui est approprié. La

comparaison entre la recherche dispersée avec marche aléatoire, la recherche dispersée avec bruit aléatoire et la recherche dispersée montre des résultats meilleurs pour la recherche dispersée en ce qui concerne la qualité de solutions.

- ❖ Les algorithmes développés ont été testés sur un certain nombre de problèmes **MAX-W-SAT** difficiles. Les résultats trouvés par la recherche locale guidée avec bruit aléatoire et la recherche locale guidée avec marche aléatoire sont donnés comme suit :

Benchmark	Optimale	GLSW	GW_cpu	GLSN	GN_cpu
Jnh201	394238	394238	78.60	394238	40.14
Jnh202	394170	393157	215.03	393197	175.97
Jnh203	394199	392538	240.03	392463	227.34
Jnh205	394238	393816	135.63	393563	248.27
Jnh207	394238	393593	244.07	393296	301.62
Jnh208	394159	392338	292.66	392706	188.44
Jnh209	394238	393141	145.37	393524	145.82
Jnh210	394238	394238	15.72	394238	86.30

Figure 7.8. Les solutions trouvées par la recherche locale guidée avec bruit aléatoire et la recherche locale guidée avec marche aléatoire.

Les résultats expérimentaux obtenus montrent que la qualité des solutions trouvées par la recherche locale guidée avec bruit aléatoire est comparable à celle des solutions obtenues par la recherche locale guidée avec marche aléatoire.

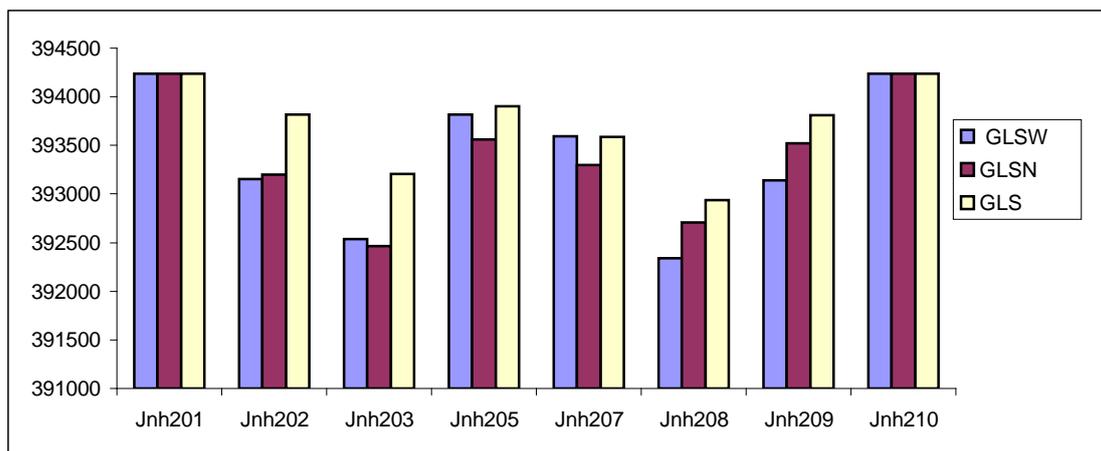


Figure 7.9. Comparaison entre la recherche locale guidée, la recherche Locale guidée avec marche aléatoire et la recherche locale Guidée avec bruit aléatoire.

D'après l'histogramme donné ci-dessus, on voit bien que les stratégies de bruit et de marche aléatoires n'ont pas incité à l'augmentation de la performance de la recherche locale guidée.

7.4. CONCLUSION:

Dans ce chapitre nous avons présenté les différents résultats obtenus des expérimentations numériques des approches développées tout au long de notre projet.

Nous avons vu que parmi les algorithmes développés, la recherche dispersée et la recherche locale guidée ont prouvé leur performance grâce à l'inclusion de plusieurs techniques de diversification et d'amélioration. Les résultats respectifs sont acceptables et meilleurs que ceux de GSAT avec marche, recherche tabou avec bruit et GRASP. De plus, si nous avons à choisir un algorithme parmi ceux développés, nous suggérons la recherche dispersée et la recherche locale guidée sans marche et sans bruit car l'inclusion de ces stratégies n'a pas été sensible à la robustesse de ces méthodes.

Conclusion générale et perspectives

Les problèmes d'optimisation combinatoire auxquels nous nous sommes intéressés sont réputés difficiles : consistant en la recherche d'une solution de meilleure qualité dans un ensemble fini mais de très grande cardinalité donc non énumérable. A leur appartenance à la classe des problèmes NP- Complets, s'ajoute également le fait que souvent n'ont été résolus que des problèmes de petite taille.

Ce travail concerne le problème de la satisfiabilité maximale pondérée (**MAX-W-SAT** en abrégé) qui est le problème central de la NP- Complétude. Il présente un double intérêt : d'une part, il apporte une réponse à de nombreux problèmes de décision se posant souvent, de façon cruciale, dans des domaines très divers. D'autre part, il nous a permis de montrer comment construire des algorithmes performants pour des problèmes très ardues.

En effet, notre démarche a d'abord consisté à appliquer au traitement de ce problème deux méta- heuristiques à savoir la recherche dispersée et la recherche locale guidée.

Nous avons ensuite conçu, étudié et expérimenté des approches hybrides basées sur la recherche tabou, la procédure GSAT, la recherche dispersée, et la recherche locale guidée, dans le but de prouver la performance des méta- heuristiques dans la résolution du problème **MAX-W-SAT**.

Dans la première partie, nous avons proposé deux algorithmes de résolution de **MAX-W-SAT** basés sur la recherche dispersée et la recherche locale guidée.

La recherche dispersée est une méta- heuristique à stratégies d'évolution, elle intègre les idées majeures des méthodes évolutionnistes (population de solutions, recombinaison de solutions), tout en possédant les avantages suivants:

- Elle dispose d'heuristique efficace pour aider à la génération d'une bonne population de départ ;
- Elle autorise des synergies avec d'autres méthodes (algorithmes itératifs), qui peuvent être intégrées dans la phase d'amélioration ;
- Elle se rapproche d'avantage de la formulation du problème (dans la combinaison).

La recherche locale guidée est une méta- heuristique basée pénalité. Elle intègre les idées majeures des algorithmes itératifs de recherche locale (solution initiale, améliorations successives), tout en possédant les avantages suivants :

- Elle augmente la fonction objective, dans le but d'éviter l'optimum local.
- Elle se rapproche d'avantage de la formulation du problème (dans la pénalisation des solutions de mauvaise qualité).

Les expérimentations reportées au chapitre 5, nous ont permis de clarifier ce que l'on peut attendre de ces deux méta- heuristiques, et de confirmer l'existence des méthodes capables de produire d'excellents résultats.

Ce qu'il faut noter aussi en ce qui concerne les solutions trouvées, c'est l'écart entre ces dernières et la solution optimale qui est négligeable dans certaines instances, ce qui prouve la puissance de la recherche dispersée et la recherche locale guidée dans la résolution du problème **MAX-W-SAT**.

Dans la deuxième partie, nous avons fait une étude comparative des approches développées. Elle s'appuie sur l'étude réalisée à propos des performances des algorithmes de recherche dispersée et de recherche locale guidée ; nous avons été amenés à dégager des notions essentielles comme celles de diversification et d'amélioration (Stratégies utilisées pour trouver de bonnes solutions), et à mettre en évidence le rôle joué par la fonction d'évaluation augmentée de la recherche locale guidée (fonction utilisée afin d'échapper à l'optimum local).

Parmi les approches développées, la recherche dispersée et la recherche locale guidée ont prouvé leur performance grâce à l'inclusion de plusieurs techniques de diversification et d'intensification. Les résultats respectifs sont acceptables et meilleurs que ceux de GSAT avec marche aléatoire, recherche tabou avec bruit aléatoire, GRASP, recherche dispersée avec bruit aléatoire, recherche dispersée avec marche aléatoire, recherche locale guidée avec bruit aléatoire, et recherche locale guidée avec marche aléatoire.

Perspectives :

Nos recherches vont naturellement se prolonger, dans les deux voies suivantes :

- Prolonger l'étude des méta -heuristiques proposées. En général, il reste à élaborer des algorithmes parallèles performants pour résoudre les problèmes **MAX-W-SAT** difficiles.
- Appliquer les approches développées à d'autres problèmes d'optimisation combinatoire.

Références :

- [BKC 93] Bart. S & Kautz. A & Cohen. B
Local Search Strategies for Satisfiability Testing
Presented at the Second DIMACS challenge on
Cliques, coloring, and Satisfiability, oct, 1993.
- [BF 97] Borchers. B & Furman. J
A two phase Algorithm for Max-Sat and
Weighted Max-sat Problems (1997)
- [BP 96] Battiti. R & Protasi. M
Reactive Search, a history – based heuristic for
MAX-SAT : theory and applications,
Rutgers University, march 1996.
- [BP 97] Battiti. R & Protasi M
Solving Max-Sat With Non Oblivious Functions and
History based Heuristics. Dimacs series in
discrete mathematics and theoretical computer science.
N°35, AMS and ACM Press, 1997.
- [BP 98] Battititi R & Protasi M
Approximate Algorithms and Heuristics for Max-Sat;
HandBook of Combinatorial Optimization(vol.1) D.-Z Du
and P.M Pardalos(Eds) pp. 77-148 1998
- [BT 95] Battiti R, Tecchiolli. G;
Local Search With Memory. Benchmarking RTS.
Operations Research Spectrum, 1995.
- [Dri 93] Drias. H
Approche probabiliste du dénombrement des solutions
du problème MAX-SAT
Thèse de doctorat,1993
- [Dri98] Drias. H,
New Algorithm For Counting and Checking Satisfiability and a restricted
Unfavorable Region For Polynomial Average Time
IEEE 1998. 0-7803-4547-9/98.

- [Dri 99] Drias. H
Randomness in heuristics : An Experimental investigation for the Maximum Satisfiability Problem in Proc of IWANN-99, lectures notes in artificial intelligence Spain, June 1999.
- [Gol 89] Goldberg. D.E
Genetic algorithms in search optimization and machine learning
The university of Alabama, Edison Wesley, 1989.
- [Glo 86] Glover. F
Future paths for integer programming and links to Artificial intelligence operational search, vol 31, 1986
- [Glo 89] Glover. F
Taboo search : Part I, ORSA, journal on computing, 1989
- [Glo 90] Glover. F
Taboo search : Part II, ORSA, journal on computing, 1990
- [Glo 94] Glover. F
Taboo search for nonlinear and parametric optimization links to genetic algorithms
graduate school of business, University of Colorado, Boulder to appear in discrete applied mathematics, 1994
- [Glo 95] Glover. F
Taboo search fundamentals and uses, journal of heuristic, 1995
- [Glo 96] Glover. F
Taboo search and adaptive memory programming advances, application and challenges, computer science and operation research, 1996
- [GLM 00] Glover..F & Laguna.M & Marti. R
Scatter search
University of Colorado, USA, 2000
- [GLMC 99] Glover.F & Laguna.M & Marti. R & Campos.V
An experimental evaluation of Scatter search for The linear ordering problem, April 23, 1999
- [HJ 89] Hansen P, Jaumard B.
Algorithms For Maximum satisfiability Problem.
- [Her 95] Hertz .A
La méthode tabou appliquée aux problèmes d'ordonnancement, APII, vol 29, n° 4- 5, 1995

- [Hol 92] Holland. J
Les algorithmes génétiques pour la science n°9 1992
- [JG 79] Johnson.S & Garey. R
Computers and Intractability.
Guide to theory of the completeness.(1979).
- [Joh74] Johnson. S,
Approximation algorithms for combinatorial problems, Journal of
Computer and System Sciences 9(1974), 256-278.
- [LG 93] Laguna .M & Glover. F
Taboo search modern heuristic techniques for
Combinatorial problem, C. Reeves, 1993.
- [Lag 99] Laguna. M
SCATTER SEARCH
Graduate school of business, University of
Colorado, Boulder August 16, 1999
- [LMC 99] Laguna.M & Marti. R & Campos. V
Scatter search for the linear ordering problem
University of Colorado, Boulder February 2, 1999
- [MSG97] Mazure. B, Sais L, Gregoire.E;
Taboo Search For Sat, 1997.
- [KS93] Kirkpatrick S, Selman B;
Critical Behavior in The Satisfiability Of Random Boolean
formulae.
- [RF96] Resende.MGC and T.A.Feo;
A grasp for satisfiability; Proc. of the second Dimacs Algorithm
Implementation Challenge on cliques, coloring sansatisfiability ; Dimacs
series on discrete
Mathematics and theoretical Computer science, n°26, 19-96, pp:499-520.
- [SHKC 94] Selman B, Henry A, Kautz Z, Cohen B;
Noise Strategies For Improving Local Search.
Proceeding of AAAI-94, 1994.
- [SML92] Selman B, Mitchell D, Levesque H;
Hard And Easy Distribution Of Sat Problems.
In Proceedings Of The Tenth National Conference On Artificial
Intelligence(AAAJ' 92), 459-465.

- [SML92] Selman B, Mitchell D, Levesque H;
A New Method For Solving Hard Satisfiability
Problems. In Proceeding Of Tenth National Conference On Artificial
Intelligence(AAAI'92),440,446.
- [Sia 95] Siarry .P
La méthode du recuit simulé : théorie et applications.
Automatique productique, informatique industrielle
Vol 29 N° 4/1995.
- [Tal 95] Talbi. EG
Algorithmes génétiques parallèles : techniques et
Applications. Publication université de Lille 1995.
- [Vou 97] Voudouris .C
Guided local search for combinatorial optimization
problems, PHD thesis, department of computer science,
University of Essex, Colchester, July 1997
- [VT 98] Voudouris .C & Tsang. EPK
Guided local search and its application to the traveling
salesman problem, European journal of operational research,
march 1998.

Annexe :

Récapitulatifs des tests

Les tableaux qui suivent donnent les résultats des différents tests effectués afin de déterminer les paramètres des méta- heuristiques mises en œuvre tout au long de notre étude.

Les tests ont été effectués sur différentes instances **MAX-W-SAT** dont les solutions optimales sont connues

Vu que les algorithmes développés contiennent certaines étapes avec un choix aléatoire (bruit, marche, solution initiale), pour chaque jeu d'essai, dix(10) exécutions ont été réalisées. La meilleure solution obtenue pour chaque algorithme ainsi que sa durée d'exécution sont sélectionnés.

Dans ce qui suit, nous avons désigné les différentes solutions par :

- **SS** : Somme des poids des clauses satisfaites donnée par la recherche dispersée.
- **SS_tcpu** : Temps d'exécution de la recherche dispersée.
- **SSW** : Somme des poids des clauses satisfaites donnée par la recherche dispersée avec marche aléatoire.
- **SSW_tcpu** : Temps d'exécution de la recherche dispersée avec marche aléatoire.
- **SSnoise** : Somme des poids des clauses satisfaites donnée par la recherche dispersée avec bruit aléatoire.
- **SSN_tcpu** : Temps d'exécution de la recherche dispersée avec bruit aléatoire.
- **GLS** : Somme des poids des clauses satisfaites donnée par la recherche locale guidée.
- **GLS_tcpu** : Temps d'exécution de la recherche locale guidée.
- **GLSN** : Somme des poids des clauses satisfaites donnée par la recherche locale guidée avec bruit aléatoire.
- **GN_cpu** : Temps d'exécution de la recherche locale guidée avec bruit aléatoire.
- **GLSW** : Somme des poids des clauses satisfaites donnée par la recherche locale guidée avec marche aléatoire.
- **GW_cpu** : Temps d'exécution de la recherche locale guidée avec marche aléatoire.
- **TabouW** : Somme des poids des clauses satisfaites donnée par la recherche tabou avec bruit aléatoire.
- **Tab_tcpu** : Temps d'exécution de la recherche tabou avec bruit aléatoire.
- **GSATW** : Somme des poids des clauses satisfaites donnée par la procédure GSAT avec marche aléatoire.
- **Gsat_tcpu** : Temps d'exécution de la procédure **GSAT** avec bruit

aléatoire.

- **Détermination des Paramètres de la recherche dispersée :**

Le but de cette évaluation est de mesurer l'évolution de la qualité de la solution obtenue par la recherche dispersée, pour des populations de tailles différentes, et de déterminer le nombre maximum d'itérations qui représente le critère d'arrêt de l'algorithme.

Benchmark	SS	SS_cpu	Benchmark	SS	SS_cpu
Jnh201	394238	97.26	Jnh217	394238	1008.06
Jnh202	394044	1226.03	Jnh218	394238	150.94
Jnh203	394135	1441.79	Jnh1	420909	1316.91
Jnh205	394238	364.87	Jnh10	420165	1860.38
Jnh207	394006	1207.59	Jnh11	420274	1772.86
Jnh208	393842	1347.46	Jnh12	420706	1748.86
Jnh209	394057	1201.20	Jnh13	420302	1866.45
Jnh210	394238	123.59	Jnh14	420510	1825.21
Jnh211	393372	1393.20	Jnh15	419285	1907.53
Jnh212	394074	1231.54	Jnh16	420401	1738.11
Jnh214	393205	1289.80	Jnh17	420797	1647.98
Jnh215	393951	1533	Jnh18	419868	1891.74
Jnh216	393462	1620.87	Jnh19	420107	1786.74

Figure 1. Les résultats trouvés par la recherche dispersée pour Maxiter=20, B1=5, B2=5, tpop=100, et Aiter=10.

Benchmark	SS	SS_cpu	Benchmark	SS	SS_cpu
Jnh201	394238	15.30	Jnh217	393817	543.30
Jnh202	392355	606.28	Jnh218	394238	205.57
Jnh203	393462	696.39	Jnh1	420806	547.82
Jnh205	393816	587.76	Jnh10	419812	749.47
Jnh207	393131	580.37	Jnh11	419645	731.75
Jnh208	393064	634.26	Jnh12	420225	718.92
Jnh209	393868	592.92	Jnh13	418574	762.43
Jnh210	394238	261.75	Jnh14	419395	744.16
Jnh211	392035	672.63	Jnh15	419152	770.08
Jnh212	393712	595.42	Jnh16	420412	692.24
Jnh214	392455	612.57	Jnh17	420602	681.35
Jnh215	393453	621.37	Jnh18	419448	755.95
Jnh216	392203	660.44	Jnh19	419144	737.19

Figure 2 . Les résultats trouvés par la recherche dispersée pour Maxiter=3, B1=3, B2=2, tpop=50, et Aiter=100.

Benchmark	SS	SS_cpu	Benchmark	SS	SS_cpu
Jnh201	394238	5.03	Jnh217	394102	954.36
Jnh202	394044	1088.43	Jnh218	394238	304.02
Jnh203	392937	1233.58	Jnh1	420806	954.61

Jnh205	393958	1022.88	Jnh10	419518	1311.70
Jnh207	394171	1141.53	Jnh11	419790	1240.01
Jnh208	392773	994.19	Jnh12	420706	1279.55
Jnh209	393868	267.49	Jnh13	420187	1339.79
Jnh210	394238	1197.92	Jnh14	420160	1303.86
Jnh211	392185	1056.67	Jnh15	419783	1348.46
Jnh212	393970	1056.67	Jnh16	420663	1230.21
Jnh214	393006	1085.44	Jnh17	420231	1193.31
Jnh215	394002	1125.31	Jnh18	419933	1327.09
Jnh216	393224	1146.67	Jnh19	419514	1288

Figure 3. Les résultats trouvés par la recherche dispersée pour Maxiter=3, B1=3, B2=2, tpop=100, et Aiter=100.

Benchmark	SS	SS_cpu	Benchmark	SS	SS_cpu
Jnh201	394238	23.77	Jnh217	394202	1448.75
Jnh202	393961	1605.75	Jnh218	394189	1578.61
Jnh203	392444	1847.99	Jnh1	420744	1447.30
Jnh205	393975	1555.12	Jnh10	419382	1982.26
Jnh207	394229	1554.52	Jnh11	420113	1882.13
Jnh208	393021	1706.86	Jnh12	420645	1904.10
Jnh209	393912	1490.46	Jnh13	420400	2019.51
Jnh210	394238	176.50	Jnh14	420106	1973.51
Jnh211	392380	1787.21	Jnh15	419323	2046.66
Jnh212	394117	1593.59	Jnh16	419982	1839.88
Jnh214	392927	1615.92	Jnh17	42408	1805.30
Jnh215	393593	1654.43	Jnh18	419098	2006.20
Jnh216	393395	1734.13	Jnh19	419240	1944.51

Figure 4 . Les résultats trouvés par la recherche dispersée pour Maxiter=3, B1=5, B2=5, tpop=50, et Aiter=100.

D'après les tables ci-dessus représentant les solutions trouvées par la recherche dispersée, on constate que la taille de la population est grande meilleur est la qualité du résultat.

Benchmark	SS	SS_cpu	Benchmark	SS	SS_cpu
Jnh201	394238	26.31	Jnh217	393937	300.02
Jnh202	392908	334.83	Jnh218	394189	329.58

Jnh203	393475	383.61	Jnh1	420728	301.45
Jnh205	393534	323.99	Jnh10	419015	409.99
Jnh207	393206	321.44	Jnh11	419575	328.50
Jnh208	392568	356.91	Jnh12	420091	398.85
Jnh209	393097	310.10	Jnh13	418810	419.30
Jnh210	394238	24.56	Jnh14	419769	414.84
Jnh211	391587	373.51	Jnh15	419389	422.75
Jnh212	393683	325.89	Jnh16	420029	382.52
Jnh214	392511	368.92	Jnh17	420830	377.76
Jnh215	392927	344.88	Jnh18	419064	418.38
Jnh216	392606	360.02	Jnh19	419047	403.72

Figure 5. Les résultats trouvés par la recherche dispersée pour Maxiter=1, B1=2, B2=2, tpop=40, et Aiter=100.

Benchmark	SS	SS_tcpu	Benchmark	SS	SS_tcpu
Jnh201	394238	6.44	Jnh217	394238	650.46
Jnh202	394022	2067.29	Jnh218	394238	605.65
Jnh203	394135	2379.43	Jnh1	420925	1159.88
Jnh205	394238	1840.49	Jnh10	420165	1860.38
Jnh207	394045	1975.44	Jnh11	420274	2404.32
Jnh208	393934	2219.86	Jnh12	420706	2407.00
Jnh209	393971	1916.71	Jnh13	420302	2593.60
Jnh210	394238	293.56	Jnh14	420510	2555.30
Jnh211	393372	2296.44	Jnh15	419671	2680.10
Jnh212	394029	2046.90	Jnh16	420821	2380.91
Jnh214	393377	2079.27	Jnh17	420925	2080.00
Jnh215	393451	2130.24	Jnh18	420692	2576.90
Jnh216	393399	2231.51	Jnh19	420107	2521.19

Figure 6. Les résultats trouvés par la recherche dispersée pour Maxiter=3, B1=5, B2=5, tpop=100, et Aiter=100.

Benchmark	SS	SS_tcpu	Benchmark	SS	SS_tcpu
Jnh201	394238	8.64	Jnh217	394238	418.33
Jnh202	393912	745.65	Jnh218	394238	175.31
Jnh203	394135	868.05	Jnh1	420661	745.65
Jnh205	393975	694.36	Jnh10	420651	895.07

Jnh207	393862	786.07	Jnh11	420120	933.30
Jnh208	393483	953.77	Jnh12	420549	811.17
Jnh209	394094	687.27	Jnh13	420666	1036.40
Jnh210	394238	12.72	Jnh14	420058	1087.70
Jnh211	393574	1023.97	Jnh15	420314	1084.40
Jnh212	394136	837.84	Jnh16	420871	860.40
Jnh214	393612	828.35	Jnh17	420892	793.85
Jnh215	393942	765.53	Jnh18	419938	1147.65
Jnh216	393805	821.90	Jnh19	419244	980.78

Figure 7. Les résultats trouvés par la recherche dispersée pour Maxiter=6, B1=2, B2=3, tpop=20, et Aiter=100.

Suivant les tables ci-dessus, on remarque que la qualité de la solution s'améliore plus rapidement dans les premières itérations que dans les suivantes. A partir d'un certain seuil, il est inutile d'augmenter le nombre d'itérations, car les variations deviennent très petites. D'après ces tests, on peut fixer ce nombre à trois(3) itérations.

- Détermination des Paramètres de la recherche Locale guidée :

L'objectif de cette évaluation est de déterminer le nombre maximum d'itérations qui représente le critère d'arrêt, le nombre d'améliorations de la recherche locale, ainsi que le facteur de diversification λ .

Benchmark	GLS	GLS_cpu	Benchmark	GLS	GLS_cpu
Jnh201	394238	21.07	Jnh217	394238	1606.38
Jnh202	393818	3383.07	Jnh218	394238	914.47
Jnh203	390206	1916.82	Jnh1	420806	1782.72
Jnh205	393903	1883.44	Jnh10	419420	2432.27
Jnh207	393585	1884.45	Jnh11	420413	2300.99
Jnh208	392936	2080.54	Jnh12	420925	1220.29
Jnh209	393812	1824.38	Jnh13	419491	3249.01
Jnh210	394238	334.33	Jnh14	420545	2738.84
Jnh211	392921	2189.30	Jnh15	419004	43800.2
Jnh212	393993	1952.04	Jnh16	420063	2294.55
Jnh214	393341	1974.02	Jnh17	420830	2226.41
Jnh215	393872	2042.12	Jnh18	419525	2467.08
Jnh216	393391	2115.18	Jnh19	419468	2428.60

Figure 8. Les résultats trouvés par la recherche locale guidée pour Maxiter=100, $\lambda=1$, et Aiter=10000.

Benchmark	GLS	GLS_cpu	Benchmark	GLS	GLS_cpu
Jnh201	394238	21.17	Jnh217	393268	177.05
Jnh202	393815	197.89	Jnh218	393692	194.99
Jnh203	392597	225.55	Jnh1	420806	176.41
Jnh205	393371	189.76	Jnh10	419378	243.02
Jnh207	392660	189.21	Jnh11	418660	245.50

Jnh208	392241	208.24	Jnh12	419776	236.27
Jnh209	393279	181.96	Jnh13	419002	248.71
Jnh210	393791	258.64	Jnh14	419131	244.70
Jnh211	392921	219.77	Jnh15	418323	252.11
Jnh212	393730	194.94	Jnh16	419452	226.46
Jnh214	393341	147.15	Jnh17	420331	221.35
Jnh215	393872	202.24	Jnh18	418960	245.86
Jnh216	392641	210.73	Jnh19	418968	240.44

Figure 9. Les résultats trouvés par la recherche locale guidée pour Maxiter=10, $\lambda=1$, et Aiter=1000.

Benchmark	GLS	GLS_cpu
Jnh201	394238	22.01
Jnh202	393815	493.79
Jnh203	392597	564.23
Jnh205	393379	478.14
Jnh207	393169	472.73
Jnh208	392241	520.90
Jnh209	393568	454.18
Jnh210	394237	334.93

Figure 10. Les résultats trouvés par la recherche locale guidée pour Maxiter=50, $\lambda=1$, et Aiter=500.

Benchmark	GLS	GLS_cpu
Jnh201	394238	22.08
Jnh202	393815	513.61
Jnh203	392597	587.13
Jnh205	393379	495.42
Jnh207	393169	490.18
Jnh208	392241	540.65
Jnh209	393568	471.00
Jnh210	394238	347.51

Figure 11. Les résultats trouvés par la recherche locale guidée pour Maxiter=50, Aiter=500, et $\lambda=2$.

Benchmark	GLS	GLS_cpu
Jnh201	394238	21.96
Jnh202	393815	512.53
Jnh203	392597	587.43
Jnh205	393379	495.42
Jnh207	393169	490.18
Jnh208	392241	540.65
Jnh209	393568	471.00

Jnh210	394238	347.19
--------	--------	--------

Figure 12. Les résultats trouvés par la recherche locale guidée pour Maxiter=50,Aiter=500, et $\lambda=0,5$.

Benchmark	GLS	GLS_cpu
Jnh201	393838	13.81
Jnh202	392086	22.08
Jnh203	391610	23.63
Jnh205	393304	20.04
Jnh207	391960	19.74
Jnh208	392241	22.08
Jnh209	393279	18.42
Jnh210	393101	19.86

Figure 13. Les résultats trouvés par la recherche locale guidée pour Maxiter=10,Aiter=100, et $\lambda=1,5$.

Benchmark	GLS	GLS_cpu
Jnh201	394238	1.62
Jnh202	392086	2.13
Jnh203	391610	2.63
Jnh205	390197	2.40
Jnh207	391817	2.12
Jnh208	391782	2.44
Jnh209	391084	2.06
Jnh210	390281	2.25

Figure 14. Les résultats trouvés par la recherche locale guidée pour Maxiter=10,Aiter=10, et $\lambda=3$.

Benchmark	GLS	GLS_cpu
Jnh201	393838	13.85
Jnh202	392086	28.88
Jnh203	391610	23.69
Jnh205	393304	24.67
Jnh207	391960	19.91
Jnh208	392241	18.54
Jnh209	393579	22.46
Jnh210	393101	20.49

Figure 15. Les résultats trouvés par la recherche locale guidée pour Maxiter=10,Aiter=100, et $\lambda=0.2$.

L'effet du facteur de diversification λ sur la recherche locale guidée est montré sur les figures 8, 9, 10, 11, 12, 13, 14, et 15. On constate qu'une valeur λ plus élevée n'implique pas une solution meilleure. Concernant le nombre d'itérations, on remarque que plus on l'augmente, plus la qualité de la solution est meilleure et plus le temps d'exécution de l'algorithme croît.

- **Détermination des Paramètres de la recherche dispersée avec marche aléatoire et de la recherche dispersée avec bruit aléatoire :**

Un nombre important de paramètres sont utilisés dans la méthode de recherche dispersée hybride (nombre d'itérations maximal, taille de la population, la taille de l'ensemble R, et la probabilité P). Les paramètres choisis sont ceux pour lesquels un compromis a été constaté entre le temps d'exécution de l'algorithme et la qualité de la solution trouvée. Ces paramètres sont fixés comme suit :

- Paramètres de l'algorithme de la recherche dispersée avec bruit aléatoire :
Sizepop=100, B1=5, B2= 5, Maxiter=10, Aiter=1000, et p=0.5.
- Paramètres de l'algorithme de la recherche dispersée avec marche aléatoire:
Sizepop=100, B1=5, B2= 5, Maxiter=10, Aiter=1000, et p=0.5.

Benchmark	Optimale	SSW	Swtcpu	SSnoise	SSN_tcpu
Jnh201	394238	394238	28.48	394238	25.12
Jnh202	394170	392788	256.05	394044	1086.39
Jnh203	394199	392795	293.14	393498	1198.62
Jnh205	394238	393300	250.23	393903	338.74
Jnh207	394238	393262	245.67	393745	758.63
Jnh208	394159	392608	272.03	393822	384.74
Jnh209	394238	392819	237.29	393459	919.42
Jnh210	394238	393951	240.91	394238	395.43
Jnh211	393979	391993	284.32	392986	526.55
Jnh212	394238	392710	251.17	394074	610.96
Jnh214	394163	392825	256.98	393077	608.92
Jnh215	394150	393188	264.44	393951	478.22
Jnh216	394226	392661	277.07	393882	860.10
Jnh217	394238	394238	165.42	394197	499.25
Jnh218	394238	393763	251.90	394238	285.55
Jnh1	420925	420609	234	420806	658.16
Jnh10	420840	418550	316.04	419603	674.21
Jnh11	420753	419341	296.49	419658	481.34
Jnh12	420925	418947	307.79	420701	484.94
Jnh13	420816	418447	320.62	418891	598.83
Jnh14	420824	419145	313.44	419358	589.05
Jnh15	420719	419032	322.52	419800	848.66
Jnh16	420919	419501	291.38	420746	914.16
Jnh17	420925	419959	289.65	420925	225.89
Jnh18	420795	418710	317.79	419746	680.99
Jnh19	420759	418765	310.52	419746	567.79

Figure 16. Les résultats trouvés par la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire pour Maxiter=10000, B1=5, B2=5, tpop=100, Aiter=10, et P=0.5.

Benchmark	Optimale	SSW	Swtcpu	SSnoise	SSN_tcpu
Jnh201	394238	394238	15.38	394019	23.20
Jnh202	394170	392256	30.48	391271	30.43
Jnh203	394199	390147	34.95	391798	33.47
Jnh205	394238	392095	30.04	392365	29.98
Jnh207	394238	392404	29.88	393296	29.24
Jnh208	394159	392575	33.07	390797	32.40
Jnh209	394238	393329	29.55	394187	28.46
Jnh210	394238	393604	30.56	391349	30.04
Jnh211	393979	391941	33.89	390949	33.37
Jnh212	394238	393378	30.91	392364	30.00
Jnh214	394163	391984	31.13	391200	31.01
Jnh215	394150	390910	32.15	392447	31.44
Jnh216	394226	391822	33.01	391949	32.13
Jnh217	394238	392530	28.73	391941	28.54
Jnh218	394238	391541	31.28	393763	29.97
Jnh1	420925	419636	28.81	419408	28.73
Jnh10	420840	416970	36.81	417221	36.95
Jnh11	420753	418944	35.28	417839	35.04
Jnh12	420925	418165	35.57	418419	35.45
Jnh13	420816	417750	35.91	417437	37.19
Jnh14	420824	417813	37.25	418873	37.18
Jnh15	420719	417965	37.28	416643	37.66
Jnh16	420919	418769	35.63	417582	33.75
Jnh17	420925	419104	35.51	418446	34.90
Jnh18	420795	417322	37.81	417570	37.61
Jnh19	420759	417298	36.83	417434	36.51

Figure 17. Les résultats trouvés par la recherche dispersée avec marche aléatoire et la recherche dispersée avec bruit aléatoire pour Maxiter=20, B1=5, B2=5, tpop=100, Aiter=10, et P=0.5.

- **Détermination des Paramètres de la recherche locale guidée avec marche aléatoire et de la recherche locale guidée avec bruit aléatoire :**

Les meilleurs résultats ont été obtenus pour une valeur de Maxiter= 100, une valeur de Aiter=1000, et une valeur de P=0.5.

Benchmark	Optimale	GLSW	GW_cpu	GLSN	GN_cpu
Jnh201	394238	394238	78.60	394238	40.14
Jnh202	394170	393157	215.03	393197	175.97
Jnh203	394199	392538	240.03	392463	227.34
Jnh205	394238	393816	135.63	393563	248.27
Jnh207	394238	393593	244.07	393296	301.62
Jnh208	394159	392338	292.66	392706	188.44
Jnh209	394238	393141	145.37	393524	145.82
Jnh210	394238	394238	15.72	394238	86.30

Figure 18. Les résultats trouvés par la recherche locale guidée avec marche aléatoire et la recherche locale guidée avec bruit aléatoire pour Maxiter = 1000, P=0.5, et Aiter= 1000.

Benchmark	GLSW	GW_cpu	GLSN	GN_cpu
Jnh201	369791	0.77	394238	10.23
Jnh202	374372	0.94	391891	19.77
Jnh203	391833	23.57	392463	11.21
Jnh205	392893	10.60	392738	19.11
Jnh207	366714	1	391545	19.39
Jnh208	391336	11.46	390569	10.43
Jnh209	393141	10	393524	9.06
Jnh210	393135	10.47	393536	9.01

Figure 19. Les résultats trouvés par la recherche locale guidée avec marche aléatoire et la recherche locale guidée avec bruit aléatoire pour Maxiter = 50, P=0.5, et Aiter= 500.

- **Détermination des Paramètres de la recherche tabou avec bruit aléatoire:**

Les paramètres choisis sont ceux pour lesquels un bon compromis a été trouvé entre le coût d'exécution de l'algorithme et la qualité de la solution obtenue.

Benchmark	TabouW	Tab_tcpu
Jnh201	394238	143.45
Jnh202	392837	242.58
Jnh203	392485	275.26
Jnh205	393752	235.07
Jnh207	392708	230.28
Jnh208	392380	254.41
Jnh209	392992	225.30
Jnh210	394238	222.46

Figure 20. Les résultats trouvés par la recherche tabou avec bruit aléatoire pour Maxiter=10000, P=0.5, et tenure=7.

Benchmark	TabouW	Tab_tcpu
Jnh201	394238	11.27
Jnh202	391583	23.97
Jnh203	390908	28.07
Jnh205	391940	24.09
Jnh207	392404	23.34
Jnh208	391383	25.27
Jnh209	392992	21.94
Jnh210	393827	22.11

Figure 21. Les résultats trouvés par la recherche tabou avec bruit aléatoire pour Maxiter=1000, P=0.5 , et tenure=7.

Benchmark	TabouW	Tab_tcpu
Jnh201	394238	11.27
Jnh202	391583	23.98
Jnh203	390908	28.07
Jnh205	391940	24.10
Jnh207	392404	23.34
Jnh208	391383	25.28
Jnh209	392992	21.94
Jnh210	393827	22.10

Figure 22. Les résultats trouvés par la recherche tabou avec bruit aléatoire pour Maxiter=1000, P=0.5, et tenure=3.

- **Détermination des Paramètres du GSAT avec marche aléatoire :**

Les figures 23 et 24, illustrent l'effet du paramètre Maxiter sur la procédure GSAT. On remarque que plus on augmente Maxiter, plus la qualité de la solution est meilleure, et plus le temps de calcul de l'algorithme croît.

Benchmark	GSATW	Gsat_tcpu
Jnh201	394238	15.24
Jnh202	393155	240.36
Jnh203	392804	274.01
Jnh205	393959	233.79
Jnh207	393049	243.71
Jnh208	392296	255.82
Jnh209	392933	223.52
Jnh210	393864	229.41

Figure 23. Les résultats trouvés par GSAT avec marche aléatoire pour Maxiter=1000, P=0.5, et Num-ess=10.

Benchmark	GSATW	Gsat_tcpu
-----------	-------	-----------

Jnh201	394238	140.19
Jnh202	393439	240659
Jnh203	392816	2875.35
Jnh205	393975	2338.34
Jnh207	393649	2301.65
Jnh208	392651	2558.96
Jnh209	393746	2225.98
Jnh210	394238	456.23

Figure 24. Les résultats trouvés par GSAT avec marche aléatoire pour Maxiter=10000,P=0.5, et Num-ess=10.

CONCLUSION:

Après cette expérimentation, les paramètres de chaque méta- heuristiques citées ci-dessus sont fixés aux valeurs suivantes :

- Paramètres de l'algorithme de la recherche tabou avec bruit aléatoire :
Tenure = 7, Maxiter= 10000 et P=0.5.
- Paramètres de l'algorithme du GSAT avec marche aléatoire :
Maxiter=1000, NUM-ess= 10, et P=0.5.
- Paramètres de l'algorithme de la recherche dispersée : Sizepop=100, B1=5, B2= 5,Maxiter=3, et Aiter=100.
- Paramètres de l'algorithme de la recherche locale guidée : Maxiter= 100, Aiter=1000, et $\lambda=1$.
- Paramètres de l'algorithme de la recherche dispersée avec bruit aléatoire :
Sizepop=100, B1=5, B2= 5, Maxiter=10, Aiter=1000, et p=0.5.
- Paramètres de l'algorithme de la recherche dispersée avec marche aléatoire:
Sizepop=100, B1=5, B2= 5,Maxiter=10, Aiter=1000, et p=0.5.
- Paramètres de l'algorithme de la recherche locale guidée avec bruit aléatoire :
Maxiter= 100, Aiter=1000, P=0.5, et $\lambda=1$.
- Paramètres de l'algorithme de la recherche locale guidée avec marche aléatoire: Maxiter= 100, Aiter=1000, P=0.5, et $\lambda=1$.