

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE**

**UNIVERSITE MENTOURI CONSTANTINE
FACULTE DES SCIENCES EXACTES
DEPARTEMENT DE PHYSIQUE**

**N° d'ordre :
Série :**

THESE

**PRESENTEE POUR OBTENIR LE DIPLOME DE DOCTORAT EN SCIENCES EN
PHYSIQUE
SPECIALITE : PHYSIQUE DU SOLIDE
OPTION : METALLURGIE**

THEME

**PREVISION DU COMPORTEMENT MECANIQUE D'ALLIAGES
BIPHASES PAR ALGORITHMES GENETIQUES ET RESEAUX DE
NEURONES. APPLICATION AUX SYSTEMES WC-Co**

Par

Rabah TAOUCHE

SOUTENUE LE : 19/01/2010

Devant le jury :

Président :	A. ROUSTILA	Prof. Univ. Mentouri Constantine
Rapporteur :	N. ROUAG	Prof. Univ. Mentouri Constantine
Examineurs :	B. BOUZABATA	Prof. Univ. Annaba
	M. DJEDOUR	Prof. USTHB. Alger
	L. M. FARES	Prof. Univ. Annaba
	O. KHALFALLAH	Prof. Univ. Mentouri Constantine

Remerciements

Ce travail a été réalisé au Laboratoire de Microstructures et Défauts, Département de Physique, Université Mentouri Constantine.

J'adresse mes vifs remerciements à Mlle. N. ROUAG, Professeur au Département de Physique de l'Université Mentouri Constantine, pour la confiance qu'elle m'a accordé en acceptant de diriger ce travail. Je lui exprime ma sincère reconnaissance pour son aide à la maîtrise du domaine, pour les nombreuses et fructueuses discussions que nous avons eues et pour ses précieux conseils.

Je remercie Mlle. A. ROUSTILA, Professeur au Département de Physique de l'Université Mentouri Constantine, de m'avoir fait l'honneur de présider mon jury de thèse.

Je remercie également Mr. B. BOUZABATA, Professeur au Département de Physique de l'Université d'Annaba, pour l'intérêt qu'il accordé à mon travail en acceptant d'examiner cette thèse.

Je remercie de même Mr. M. DJEDOUR, Professeur au Département de Mathématiques à l'USTHB d'Alger, qui a accepté d'examiner ce travail.

Je tiens à remercier Mr. L. M. FARES, Professeur au Département de Physique de l'Université d'Annaba, qui a accepté de juger ce travail.

Je tiens à remercier également Mr. O. KHALFALLAH, Professeur au Département de Physique de l'Université Mentouri Constantine, pour l'intérêt particulier qu'il a accordé à mon travail et en acceptant d'examiner ce travail.

Je remercie particulièrement mon frère Chérif, Maître Assistant au Département d'Informatique du Centre Universitaire d'Oum El Bouaghi et son ami Mohamed CHEMACHEMA, Maître de Conférences au Département d'Electronique de l'Université de M'sila pour leur aide en matière informatique et programmation et pour leur soutien moral et encouragements durant les moments difficiles.

Je remercie Mr. N. MAAZI, Maître de Conférences au Département des Sciences Fondamentales de l'Université de Skikda, pour l'aide et le soutien moral que j'ai trouvé auprès de lui.

Je remercie enfin tous mes camarades du laboratoire pour leur aide amicale et pour l'ambiance agréable créée pendant la réalisation de ce travail.

Subject**PREDICTION OF MECHANICAL BEHAVIOUR OF TWO-PHASE ALLOYS
BY GENETIC ALGORITHMS AND NEURAL NETWORKS.
APPLICATION TO WC-Co SYSTEMS****Abstract**

This work is a further contribution to the study of mechanical behaviour of two-phase materials. We are concerned in the prediction and optimization of stress-strain curves of WC-Co two-phase alloys as a function of Co volume fraction. We suggest a Genetic Algorithms optimization method of the mechanical parameters of a model based on the homogeneous continuum mechanics notions. It is based on an iso-strain condition, and the stress distribution is supposed to follow the rule of mixtures. The present optimization method allows to determinate the optimal values of the four parameters of the model that represent the mechanical impact of each phase on the mechanical behaviour of the two-phase material. The stress-strain curves, calculated by means of the proposed method, are compared with the experimental ones, a good agreement is found. The resistance of phases increases with the rise of the hard phase volume fraction. The influence of the mechanical properties of each phase on the two-phase alloy behaviour is not intrinsic, hence the rule of mixtures is only a first approximation. A linear law of variation of the phases resistance allows to interpolate and extrapolate the model, a good agreement is found with the evolution of the experimental behaviour. In a second part, we suggest a Neural Networks model for the prediction of the evolution of stress-strain curves digitalized and optimized by Genetic Algorithms as a function of the Co volume fraction of WC-Co two-phase materials deformed by compression and tensile tests. The Genetic Algorithms optimization of the experimental data ameliorates considerably the Neural Networks performance. The present model allows to obtain a good approximation of the experimental behaviour evolution. The agreement with the experimental behaviour is very satisfactory as long as the experimental curves used as input data present a good behaviour similarity.

Keywords

Genetic Algorithms ; Neural Networks ; Two-phase materials ; Second phase ; Volume fraction ; WC-Co ; Strain ; Stress ; Rule of mixtures ; Resistance.

Sommaire

Introduction	1
 Chapitre I : Rappels sur les méthodes numériques appliquées en Sciences des Matériaux. 	
I.1. Introduction.....	3
I.2. Les algorithmes génétiques (AG).....	3
I.2.1. Définition d'un algorithme génétique.....	4
I.2.2. Principe de base d'un AG standard.....	5
I.2.2.1. La sélection.....	7
I.2.2.2. Le croisement.....	8
I.2.2.3. La mutation.....	9
I.2.3. Le codage.....	9
I.2.4. Paramètres d'un AG.....	10
I.2.5. Processus d'évolution des générations : générationnel, stationnaire et élitiste.....	11
I.2.6. Opérateurs de croisement.....	11
I.3. Les réseaux de neurones.....	13
I.3.1. Les réseaux de neurones formels.....	14
I.3.2. Architecture des réseaux de neurones.....	15
I.3.2.1. Les réseaux de neurones non bouclés.....	15
I.3.2.2. Les réseaux de neurones bouclés.....	17
I.3.3. L'apprentissage des réseaux de neurones.....	18
I.3.3.1. Apprentissage supervisé.....	18
I.3.3.2. Apprentissage non supervisé.....	19
I.3.3.3. Apprentissage hybride.....	19
I.3.4. Les différents types de réseaux de neurones.....	19
I.3.4.1. Les réseaux 'feed-forward'.....	19
I.3.4.1.1. Le perceptron.....	19
I.3.4.1.2. Le perceptron multicouches (PMC).....	20
I.3.4.1.3. Les réseaux à fonction radiale.....	20
I.3.4.2. Les réseaux 'feedback'.....	20
I.3.4.2.1. Les cartes auto-organisatrices de Kohonen.....	20
I.3.4.2.2. Les réseaux de Hopfield.....	21

I.3.4.2.3. Les réseaux ART.....	21
I.3.5. Propriété fondamentale des réseaux de neurones: l'approximation parcimonieuse.....	21
I.3.6. Réseaux de neurones et régression non linéaire.....	22
I.3.7. Mise en œuvre des réseaux de neurones et domaines d'application.....	24

Chapitre II : Modèles et méthodes numériques de prévision et d'optimisation du comportement mécanique des alliages biphasés.

Application au comportement mécanique des alliages biphasés de WC-Co.

II.1. Introduction.....	27
II.2. Modèles de déformation.....	27
II.2.1. Loi des mélanges.....	28
II.2.1.1. Modèles d'iso-déformation.....	30
II.2.1.2. Modèles d'iso-contrainte (ou distribution de la déformation).....	30
II.2.2. Modèles micromécaniques.....	31
II.2.3. Modèles auto-cohérents.....	31
II.3. Méthodes numériques d'optimisation du comportement mécanique des alliages biphasés.....	32
II.3.1. Méthode des éléments finis.....	32
II.3.2. Méthode des algorithmes génétiques.....	33
II.3.3. Méthodes des réseaux de neurones.....	34
II.4. Comportement mécanique des alliages biphasés WC-Co.....	34
II.5. Structure et microstructure des alliages WC-Co.....	35
II.6. Caractéristiques mécaniques des alliages WC-Co.....	35
II.7. Comportement mécanique des alliages biphasés WC-Co.....	36
II.7.1. Effet de la taille des grains de la phase WC.....	36
II.7.2. Effet de la fraction volumique de Co.....	37
II.8. Déformation plastique des alliages WC-Co.....	38
II.8.1. Courbes contrainte-déformation des alliages WC-Co.....	38
II.8.1.1. WC-Co en traction.....	38
II.8.1.2. WC-Co en compression.....	39

Chapitre III : Optimisation du comportement mécanique des alliages biphasés de WC-Co par la méthode des algorithmes génétiques.

III.1. Introduction.....	40
III.2. Modèle avec la forme de Voce.....	40
III.3. Présentation mathématique du modèle.....	41
III.3.1. Condition d'iso-déformation.....	41
III.3.2. Relation contrainte-déformation de chaque phase.....	41
III.3.3. Relation contrainte-déformation dans l'alliage biphasé.....	42
III.4. Procédure d'optimisation.....	42
III.5. Résultats.....	44
III.5.1. WC-Co en traction.....	45
III.5.2. WC-Co en compression.....	47
III.6. Extension du modèle.....	48
III.7. Discussion.....	50
III.8. Conclusions.....	50

Chapitre IV : Prévion du comportement mécanique d'alliages biphasés de WC-Co par un modèle de réseaux de neurones.

IV.1. Introduction.....	52
IV.2. Le réseau de neurones.....	52
IV.3. Architecture du réseau.....	54
IV.4. Application des réseaux de neurones en comportement mécanique.....	54
IV.5. Résultats.....	55
IV.5.1. WC-Co en compression.....	55
IV.5.2. WC-Co en traction.....	57
IV.6. Discussion.....	59
IV.7. Conclusions.....	60

Conclusions et perspectives.....	62
---	-----------

Annexe A

Annexe B

Bibliographie

Introduction

Les études théoriques du comportement mécanique des matériaux biphasés sont peu nombreuses, des modèles fondés sur les notions de la mécanique des milieux continus homogènes ont été développés en vue de fournir une description globale du comportement mécanique des matériaux biphasés. Récemment, avec l'apparition des nouvelles méthodes numériques tels que les Algorithmes Génétiques et les Réseaux de Neurones, la prévision et l'optimisation du comportement mécanique des matériaux biphasés sont devenues très accessibles. Ces méthodes sont devenues en quelques années des outils précieux dans les différents domaines de la science des matériaux, du fait de leur intérêt pratique qui est dû essentiellement à leurs propriétés mathématiques spécifiques et leurs mises en œuvre très simples.

Dans ce travail, nous nous sommes intéressés à la prévision théorique de l'évolution des courbes contrainte-déformation en fonction de la fraction volumique de la seconde phase des matériaux biphasés WC-Co, déformés en traction et en compression. Nous avons utilisé les deux méthodes pour le suivi de l'évolution du comportement mécanique de ces matériaux, en premier lieu la méthode des Algorithmes Génétiques, en second lieu la méthode des Réseaux de Neurones.

Les alliages métalliques industriels sont le plus souvent des alliages biphasés. Ces alliages ont un grand intérêt pratique, du fait qu'ils allient une bonne aptitude à la mise en forme à une résistance élevée. Bien que les métallurgistes n'aient pas attendu les études fondamentales pour déformer et transformer les alliages biphasés sans disposition particulière, ces derniers ont été très peu étudiés d'un point de vue fondamental.

Les matériaux biphasés WC-Co qui appartiennent à la famille des carbures cémentés sont parmi les matériaux biphasés les plus importants à cause de leur haute température de fusion et leur dureté élevée ; ils sont généralement utilisés comme outils de coupe, de forage et d'autres applications. La caractéristique la plus importante de ces matériaux est la combinaison entre une dureté élevée désirable et une contrainte de rupture élevée, ceci est dû aux contributions respectives des phases de carbure WC (phase dure) et de la phase métallique Co (phase molle), d'où l'intérêt pratique de ce type de matériaux. Ils représentent donc un matériau type pour l'étude théorique de prévision et d'optimisation du comportement mécanique des matériaux biphasés.

Dans la première partie de ce travail, nous présentons une méthode d'optimisation par Algorithmes Génétiques que nous avons mis au point sur la base d'un modèle de la mécanique des milieux continus homogènes, avec l'hypothèse d'iso-déformation, la contrainte étant distribuée suivant la loi des mélanges. Nous avons employé une forme exponentielle à la place de la forme pseudo-linéaire pour décrire la relation contrainte-déformation, elle nous apparaît plus appropriée que la forme pseudo-linéaire dans le cas des matériaux biphasés à matrice molle destinés à la mise en forme, qui présentent expérimentalement une allure avec palier.

Dans la deuxième partie de ce travail, nous avons mis au point un modèle de Réseaux de Neurones pour prévoir le comportement contrainte-déformation en fonction de la fraction volumique de la seconde phase des matériaux biphasés WC-Co déformés en compression et en traction. Nous avons optimisés toutes les données expérimentales numérisées utilisées en entrée par Algorithmes Génétiques.

La présente étude est divisée en quatre chapitres :

- Dans le chapitre I, nous rappelons les méthodes numériques appliquées en Sciences des Matériaux, avec un accent particulier sur les Algorithmes Génétiques et les Réseaux de Neurones, qui connaissent actuellement un essor considérable dans le domaine de l'optimisation en Sciences des Matériaux.
- Dans la première partie du chapitre II, nous rappelons les différents modèles de déformation ainsi que les méthodes d'optimisation du comportement mécanique des matériaux biphasés ; dans une deuxième partie, nous résumons quelques caractéristiques et propriétés mécaniques des matériaux WC-Co, objet des tests et validation de notre étude de prévision et d'optimisation des propriétés mécaniques des matériaux biphasés.
- Le chapitre III est réservé à la mise au point d'une méthode d'optimisation par Algorithmes Génétiques du comportement mécanique des matériaux WC-Co ainsi que les résultats obtenus sur les alliages WC-Co déformés en traction et en compression.
- Le chapitre IV est consacré à la mise au point d'un modèle de Réseaux de Neurones pour la prévision du comportement mécanique des matériaux biphasés de WC-Co, en comparant les prévisions issues de ce modèle avec les résultats expérimentaux, nous présentons également une extension de ce modèle.
- Enfin, nous terminons cette étude par des conclusions et des perspectives

Chapitre I

Rappels sur les méthodes numériques appliquées en Science des Matériaux.

I.1. Introduction

La simulation numérique dans les différents domaines de la science des matériaux, en particulier pour le calcul des structures métalliques, a connu de nombreuses évolutions durant ces dernières années grâce au progrès du calcul scientifique, au développement des ordinateurs, tant dans leur vitesse de traitement que dans la qualité des informations gérées. Les chercheurs disposent d'un large éventail de méthodes, supportées par des outils informatiques, notamment les méthodes d'optimisation qui constituent des alliés précieux pour la conception optimale des structures, dans le respect de certaines règles ou normes.

Les méthodes d'optimisation ont pour objectif de guider les chercheurs pendant la phase de conception et de les aider à choisir la structure qui répondra, au mieux, à tous les critères et contraintes liés notamment aux études d'exécution, à la fabrication et au montage et ce, avec un coût ou un poids minimum.

Parmi les méthodes d'optimisation, on distingue les algorithmes génétiques et les réseaux de neurones, qui s'inspirent fortement des mécanismes de l'évolution biologique, liés aux principes de sélection et d'évolution naturelle, pour les transposer à la recherche de solutions adaptées au problème structural à résoudre. Ces algorithmes connaissent actuellement un essor considérable dans le domaine de l'optimisation discrète des structures grâce à leur universalité, fiabilité et robustesse.

I.2. Les algorithmes génétiques (AG) [1,2]

Les premiers travaux sur les algorithmes génétiques (AG) ont été initialement développés en 1975 par John Holland [3] qui a mis en lumière les principes fondamentaux des AG dans le cadre de l'optimisation mathématique. Par la suite Goldberg, en 1989, a permis de mieux faire connaître les AG par son ouvrage qui décrit leur utilisation dans le cadre de la résolution de problèmes concrets [1].

Les AG ont été utilisés dans une large gamme d'applications en science des matériaux pendant ces dernières années. Les premières applications ont été fortement focalisées sur l'optimisation des paramètres mécaniques. Plusieurs travaux [4,5] ont été publiés par la suite et ont confirmé l'utilité de cette approche évolutive.

I.2.1. Définition d'un algorithme génétique

Les algorithmes génétiques (AG) sont des méthodes utilisées dans les problèmes d'optimisation. Les AG tirent leur nom de l'évolution biologique des êtres vivants dans le monde réel. Ces algorithmes cherchent à simuler le processus de la sélection naturelle dans un environnement défavorable en s'inspirant de la théorie de l'évolution proposée par C. Darwin. Dans un environnement, les individus les mieux adaptés tendent à vivre assez longtemps pour se reproduire, alors que les plus faibles ont tendance à disparaître (the survival of the fittest); Michalewicz et al [6].

Par analogie avec l'évolution naturelle, les AG font évoluer un ensemble de solutions candidates, appelé une population d'individus. Un individu n'est autre qu'une solution possible du problème à résoudre. Chaque individu de cette population se voit attribuer une fonction appelée fonction d'adaptation (fitness) qui permet de mesurer sa qualité ou son poids; cette fonction d'adaptation peut représenter la fonction 'objectif à optimiser'. Ensuite, les meilleurs individus de cette population sont sélectionnés, subissent des croisements et des mutations et une nouvelle population de solutions est produite pour la génération suivante. Ce processus se poursuit, génération après génération, jusqu'à ce que le critère d'arrêt soit atteint, comme par exemple le nombre maximal de générations.

Les techniques de recherche et d'optimisation sont en général classées en trois catégories (Coello et al [7]) : énumératives, déterministes et stochastiques. Les AG font partie de la troisième catégorie et quatre caractéristiques les distinguent des autres techniques d'optimisation (Goldberg [1]) :

- ils utilisent un codage des paramètres et non les paramètres eux-mêmes;
- ils travaillent sur une population d'individus (ou de solutions);
- ils n'utilisent que les valeurs de la fonction à optimiser, pas sa dérivée, ou une autre connaissance auxiliaire;

- ils utilisent des règles de transition probabilistes et non déterministes.

Dans la littérature, il existe plusieurs versions d'algorithmes génétiques. Dans le cadre de cette étude, on ne considère que les principaux éléments qui caractérisent un AG standard.

I.2.2. Principe de base d'un AG standard

Un AG standard nécessite en premier le codage de l'ensemble des paramètres du problème d'optimisation en une chaîne de longueur finie. Le principe d'un AG est simple, il s'agit de simuler l'évolution d'une population d'individus jusqu'à un critère d'arrêt. On commence par générer une population initiale d'individus (solutions) de façon aléatoire. Puis, à chaque génération, des individus sont sélectionnés, cette sélection est effectuée à partir d'une fonction 'objectif' appelée fonction d'adaptation. Puis, les opérateurs de croisement et de mutation sont appliqués et une nouvelle population est créée. Ce processus est réitéré jusqu'à un critère d'arrêt. Le critère le plus couramment utilisé est le nombre maximal de générations que l'on désire effectuer.

La figure I-1 présente le principe d'un AG standard. L'AG débute par la génération d'une population initiale et l'évaluation de la fonction d'adaptation de tous les individus qui composent cette première population. Puis, des individus sont sélectionnés aléatoirement pour la reproduction, selon le principe de la survie du plus adapté. Ensuite, des individus 'enfants' (ou les descendants) sont générés en appliquant les deux opérateurs génétiques suivants : le croisement et la mutation. Ces enfants sont placés dans une nouvelle population $P(t)$ et vont se substituer, en totalité ou en partie, à la population de la génération précédente. De nouvelles populations d'individus vont ensuite se succéder, d'une génération (t) à la génération $(t+1)$, chaque génération représentant une itération jusqu'à l'atteinte du critère d'arrêt. L'AG présenté ci-dessous est dit générationnel car tous les individus enfants générés sont placés dans une population et vont remplacer entièrement la population des individus parents. L'AG est basé sur trois éléments principaux : la sélection, le croisement et la mutation.

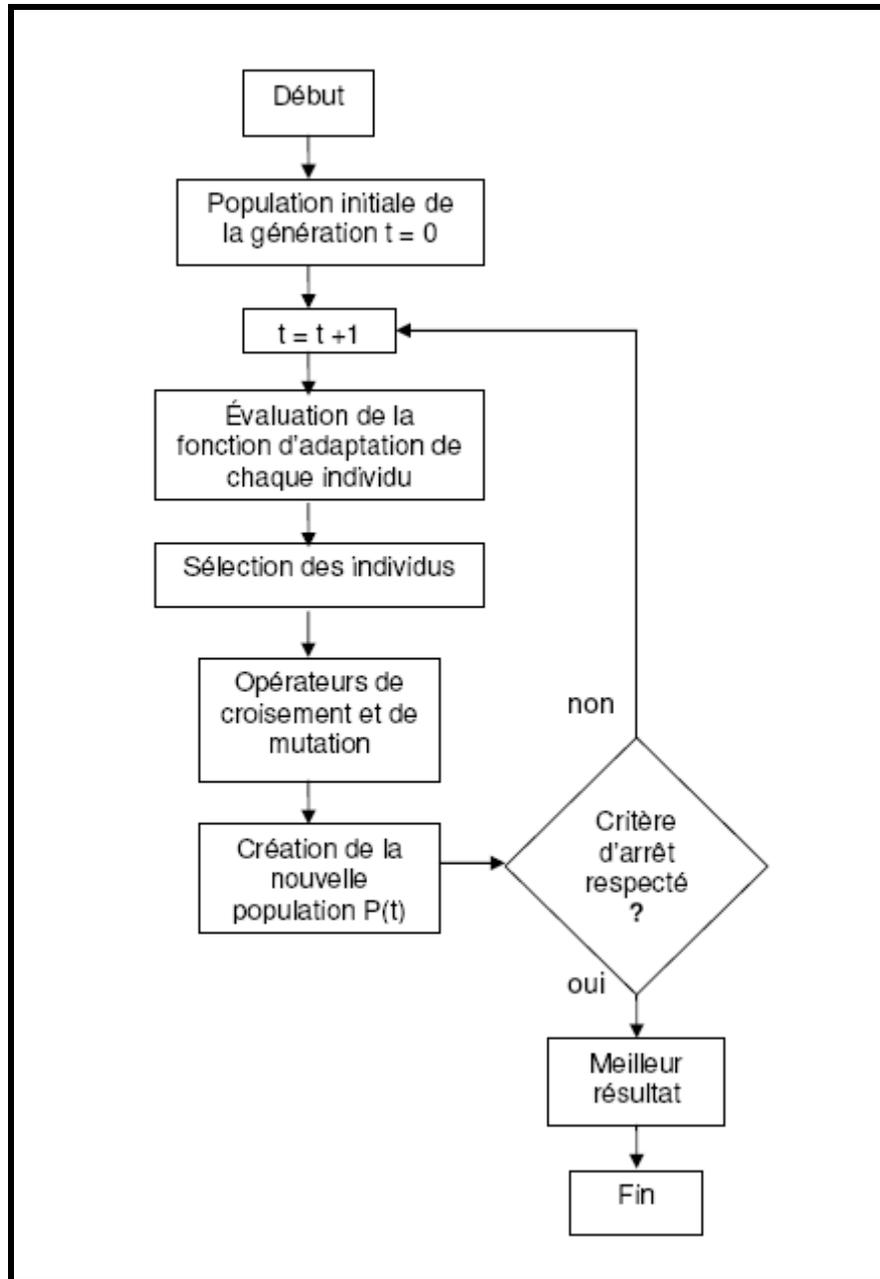


Figure.I-1 : Organigramme d'un AG standard.

I.2.2.1. La sélection

La sélection a pour objectif d'identifier les individus qui doivent se reproduire. Cet opérateur ne crée pas de nouveaux individus, mais identifie les individus sur la base de leur fonction d'adaptation, les individus les mieux adaptés sont sélectionnés alors que les moins bien adaptés sont écartés [8]. La sélection doit favoriser les meilleurs éléments selon le critère à optimiser (minimiser ou maximiser). Ceci permet de donner aux individus dont la valeur est plus grande une probabilité plus élevée de contribuer à la génération suivante (Fig.I-2). Il existe plusieurs méthodes de sélection, les plus connues sont la 'roue de la fortune' et la 'sélection par tournoi'.

- La '*roue de la fortune*' est la plus ancienne ; chaque individu, de la population de taille maximale J_{max} , occupe une section de la roue proportionnellement à sa fonction d'adaptation $Fitness(j)$, la probabilité de sélection d'un individu (j) s'écrit :

$$Prob(j) = \frac{Fitness(j)}{\sum_{j=1}^{J_{max}} Fitness(j)} \quad (I.1)$$

Chaque fois qu'un individu doit être sélectionné, un tirage à la loterie s'effectue et propose un candidat, les individus possédant une plus grande fonction d'adaptation ayant plus de chance d'être sélectionnés.

- La '*sélection par tournoi*' consiste, chaque fois qu'il faut sélectionner un individu, à tirer aléatoirement k individus de la population, sans tenir compte de la valeur de leur fonction d'adaptation ; le choix du meilleur individu est fait parmi les k individus sélectionnés. Le nombre k a une influence sur la pression de sélection : lorsque $k = 2$, la sélection est dite par 'tournoi binaire'.

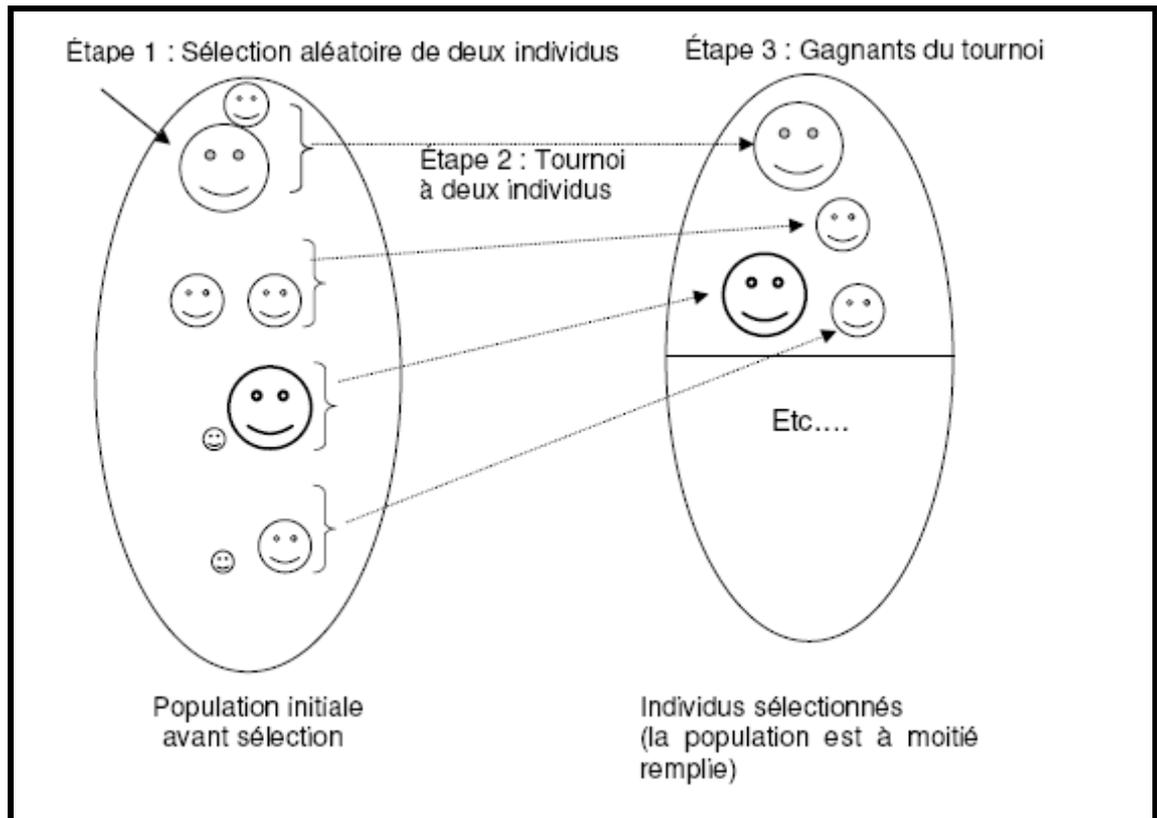


Figure.I-2 : Représentation d'une sélection par tournoi d'individus pour un critère de maximisation. Chaque individu représente une solution possible.

I.2.2.2. Le croisement

Le croisement permet de créer de nouvelles chaînes en échangeant de l'information entre deux chaînes (Fig.I-3). Le croisement s'effectue en deux étapes. Les nouveaux éléments produits par la reproduction sont appariés, ensuite chaque paire de chaînes subit un croisement comme suit : un entier k représentant une position sur la chaîne est choisi aléatoirement entre 1 et la longueur de chaîne moins un ($l-1$). Deux nouvelles chaînes sont créées en échangeant tous les caractères compris entre les positions $k+1$ et l inclusivement. L'exemple suivant (Fig.I-3) montre deux chaînes (A1 et A2) de longueur $l=5$ appartenant à la population initiale. Les deux nouvelles chaînes (A3 et A4) appartenant à la nouvelle population sont obtenues par croisement à la position $k=4$.

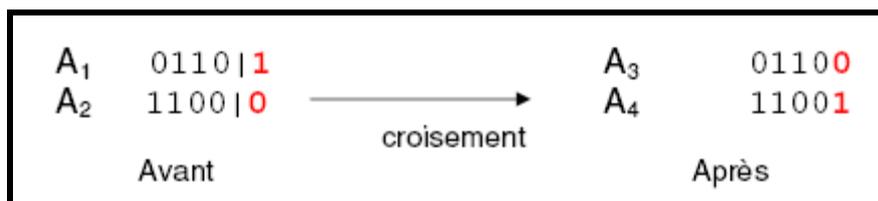


Figure.I-3 : Représentation d'un croisement en un point de deux chaînes.

1.2.2.3. La mutation

La mutation est exécutée seulement sur une seule chaîne. Elle représente la modification aléatoire et occasionnelle de faible probabilité de la valeur d'un caractère de la chaîne ; pour un codage binaire, cela revient à changer un 1 en 0 et vice versa (Fig.I-4). Cet opérateur introduit de la diversité dans le processus de recherche des solutions et peut aider l'AG à ne pas stagner dans un optimum local.

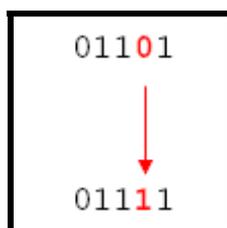


Figure.I-4 : Représentation d'une mutation de bits dans une chaîne.

La mise en œuvre d'un AG nécessite deux étapes. La première est le codage de l'individu représenté par un chromosome. La seconde est la définition des paramètres de l'AG.

1.2.3. Le codage

Le codage utilisé par un AG est représenté sous forme d'une chaîne de bits qui contient toute l'information nécessaire pour représenter un point de l'espace de recherche. Le codage binaire est le code le plus utilisé [1], l'inconvénient majeur du code binaire étant que deux points proches dans l'espace des variables (voir la colonne 1 du Tableau I-1) ne sont pas nécessairement codés par deux chaînes de bits voisines (colonne 2 du Tableau I-1). On remédie en général à ce problème en utilisant le codage de Gray qui conserve une distance de Hamming de '1' entre deux chaînes (colonne 3 du Tableau I-1). La distance de Hamming entre deux chaînes de bits est le nombre de bits qui diffère de l'une à l'autre. Pour les deux chaînes suivantes : 111 et 100, la distance est de 2.

Le Tableau I-1 montre un exemple du code binaire et le code Gray pour des variables entières allant de 0 à 7. On voit que la distance de Hamming est de 1 pour chaque entier dans le code Gray, alors que pour les nombres binaires, pour passer de 3 à 4, la distance de Hamming est de 3.

Variables entières	Code binaire	Code Gray
0	000	000
1	001	001
2	010	011
3	011	010
4	100	110
5	101	111
6	110	101
7	111	100

Tableau.I-1 : Code de Gray et code binaire pour une chaîne à trois bits.

I.2.4. Paramètres d'un AG

Pour appliquer un AG à un problème réel, on doit posséder les éléments suivants :

- un codage des éléments appartenant à la population, le codage des solutions du problème à résoudre doit être choisi avec soin;
- une fonction d'évaluation, d'adéquation ou d'adaptation de l'individu qui mesure la qualité de l'individu;
- un processus d'évolution des générations;
- des opérateurs pour modifier les individus d'une population de la génération (t) à la génération (t+1) comme le croisement et la mutation;
- des paramètres de l'AG : les opérateurs précédents dépendent de plusieurs paramètres qui sont fixés à l'avance et dont dépend fortement la convergence de l'algorithme :

1. la taille de la population : c'est-à-dire le nombre d'individus dans la population. Si la taille est trop petite, l'AG peut ne pas converger, par contre si elle est trop grande, l'évaluation des individus peut être très longue;

2. une probabilité de croisement et de mutation : les valeurs de ces probabilités

peuvent varier d'une application à l'autre. Par exemple, dans l'étude des AGs pour l'optimisation de cinq fonctions mathématiques, De Jong [9] a suggéré de choisir une probabilité de croisement élevée, une probabilité de mutation faible (inversement proportionnelle à la taille de la population), et une population de taille modérée (Goldberg [1]). La probabilité de mutation est en général très faible, inférieure à 0,1 ; une probabilité trop grande, peut modifier les meilleurs individus;

3. un critère d'arrêt : c'est-à-dire le nombre maximal de générations à effectuer.

I.2.5. Processus d'évolution des générations : générationnel, stationnaire et élitiste

Traditionnellement, les AG sont générationnels. Les individus de chaque génération sont testés et une nouvelle population en entier est générée, le nombre de descendants produits est donc égal au nombre d'individus parents. Les deux populations ne se chevauchent pas (Langdon [10]). La nouvelle population d'individus enfants est formée à chaque génération. Cependant, certains individus enfants peuvent être une copie conforme des parents qui n'ont pas été perturbés ni par un croisement ni par une mutation.

La stratégie de remplacement stationnaire (steady-state) diffère de l'AG générationnel. Dans cette approche, il y a seulement un ou deux individus qui sont générés à la fois (Ryan [11]). Il peut y avoir différentes façons de sélectionner 'l'individu victime' à supprimer de la population. Par exemple, on peut sélectionner un individu aléatoirement ou sélectionner celui qui a la plus petite fonction d'adaptation. Dans ce type d'AG, les nouveaux individus générés sont ajoutés à la population et peuvent immédiatement être sélectionnés comme parents de nouveaux individus (Langdon [10]).

Dans l'approche élitiste, les opérateurs de croisement et de mutation peuvent affecter le meilleur individu d'une génération. Le modèle élitiste a pour avantage d'écartier la possibilité de perdre cet individu. Ce modèle copie le meilleur individu de chaque génération dans la population de la génération suivante. Ce modèle peut accélérer la vitesse de domination exercée par ce super individu sur la population (Cerroloza et Annicchiarico [12]).

I.2.6. Opérateurs de croisement

Il existe d'autres opérateurs de croisement :

1. **Croisement en deux points** : on choisit au hasard deux points de croisement et on échange les parties de la chaîne situées entre ces deux points (Fig.I-5).

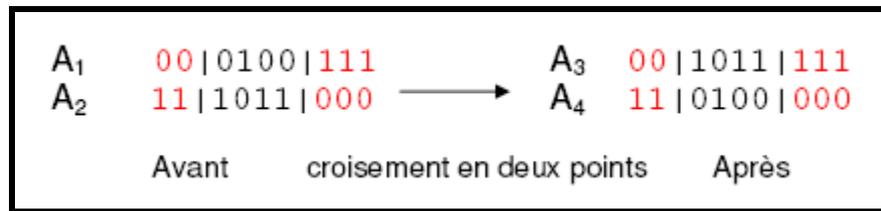


Figure.I-5 : Représentation d'un croisement en deux points.

2. **Croisement uniforme** : dans ce type de croisement, on utilise un masque de croisement; il consiste en un vecteur généré aléatoirement, de longueur identique aux chaînes parents, et est composé de 0 et 1. Lorsque le bit du masque vaut 0, l'enfant hérite le bit du premier parent, sinon il hérite celui du second parent. Le second enfant est le complémentaire du premier. Ce croisement peut être considéré comme une généralisation du croisement multipoint, sans connaissance préalable du point de croisement (Fig.I-6).

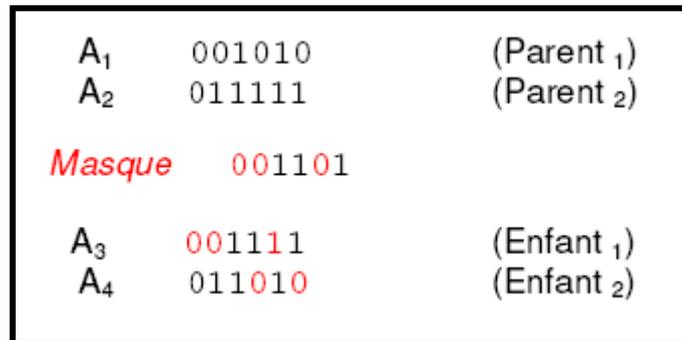


Figure.I-6 : Représentation d'un croisement uniforme.

En conclusion, les AG sont intéressants pour la résolution de certains problèmes pour lesquels les méthodes classiques d'optimisation, basées sur le calcul des gradients, s'avèrent inopérantes, c'est-à-dire lorsque la fonction objectif et les contraintes sont discontinues ou que leurs dérivées sont difficilement quantifiables.

Cependant, les AG ne sont pas confortées par des théories permettant de démontrer l'exactitude de la solution optimale. On se contente de la recherche d'une solution très proche de l'optimum ou presque optimale, mais non rigoureusement optimale. Une telle solution peut être interprétée comme un compromis entre faisabilité et performance par le chercheur,

quand il s'attache davantage à quantifier l'efficacité du choix des variables de conception sur son projet plutôt que l'optimum lui-même.

I.3. Les réseaux de neurones [13,14]

Les réseaux de neurones artificiels sont devenus en quelques années des outils précieux dans des domaines très divers de l'industrie et des services. Néanmoins, ils n'ont pas encore atteint leur plein développement, pour des raisons plus psychologiques que techniques, liées aux connotations biologiques du terme et au fait qu'ils sont considérés, à tort, comme des outils d'Intelligence Artificielle. Or l'intérêt des réseaux de neurones, dans le domaine des Sciences de l'Ingénieur, ne doit rien à la métaphore biologique : il est uniquement dû aux propriétés mathématiques spécifiques de ces réseaux. Nous expliquons dans ce qui suit, à partir de principes simples, ce que sont réellement les réseaux de neurones, et nous délimitons leurs domaines d'excellence.

De façon générale, on situe le début des réseaux de neurones artificiels en 1943, avec les travaux de McCulloch et Pitts [15] qui montrent qu'un réseau de neurones discret, sans contrainte de topologie, peut représenter n'importe quelle fonction booléenne et donc émuler un ordinateur. En 1958, Rosenblatt [16] propose le premier algorithme d'apprentissage, qui permet d'ajuster les paramètres d'un neurone. En 1969, Minsky et Papert [17] publient le livre 'Perceptrons', dans lequel ils utilisent une solide argumentation mathématique pour démontrer les limitations des réseaux de neurones à une seule couche. Ce livre aura une influence négative telle que la plupart des chercheurs quitteront le champ de recherche sur les réseaux de neurones. En 1982, Hopfield [18] propose des réseaux de neurones associatifs et l'intérêt pour les réseaux de neurones renaît chez les scientifiques. En 1986, Rumelhart, Hinton et Williams [19] publient l'algorithme de la 'rétropropagation de l'erreur' qui permet d'optimiser les paramètres d'un réseau de neurones à plusieurs couches. À partir de ce moment, la recherche sur les réseaux de neurones connaît un essor fulgurant et, au cours des années 90, les applications commerciales de ce succès académique suivent.

Aujourd'hui, on retrouve les réseaux de neurones solidement implantés dans diverses industries, entre autres : dans les milieux financiers, pour la prédiction des fluctuations de marché ; en pharmaceutique, pour analyser le 'QSAR' (Quantitative Structure-Activity Relationship) de diverses molécules organiques ; dans le domaine bancaire, pour la détection de fraudes sur les cartes de crédit et le calcul de cotes de crédit ; dans les départements de marketing de compagnies de diverses industries, pour prévoir le comportement des consommateurs ; en aéronautique, pour la programmation de pilotes automatiques.

Les applications sont nombreuses et partagent toutes un point commun essentiel à l'utilité des réseaux de neurones : les processus pour lesquels on désire émettre des prédictions comportent de nombreuses variables explicatives et, surtout, il existe éventuellement des dépendances non linéaires de haut niveau entre ces variables qui, si elles sont découvertes et exploitées, peuvent servir à l'amélioration de la prédiction du processus. L'avantage fondamental des réseaux de neurones, par rapport aux modèles statistiques traditionnels, réside dans le fait qu'ils permettent d'automatiser la découverte des dépendances les plus importantes du point de vue de la prédiction du processus.

I.3.1. Les réseaux de neurones formels

Un 'neurone formel' ou 'artificiel' (ou simplement 'neurone') est une fonction algébrique non linéaire et bornée, dont la valeur dépend de paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées 'entrées' du neurone, et la valeur de la fonction est appelée sa 'sortie'.

Un neurone est donc avant tout un opérateur mathématique, dont on peut calculer la valeur numérique par quelques lignes de logiciel. On a pris l'habitude de représenter graphiquement un neurone comme indiqué sur la figure I-7.

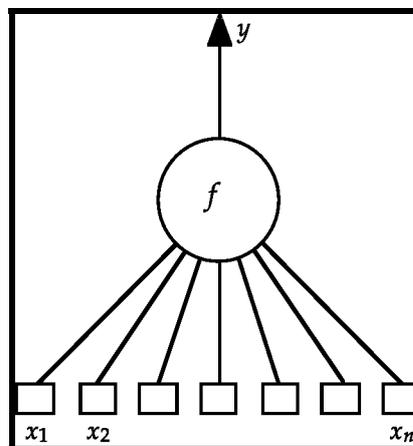


Figure.I-7 : Représentation graphique d'un neurone formel.

Un neurone réalise donc une fonction non linéaire bornée $y = f(x_1, x_2, \dots, x_n; c_1, c_2, \dots, c_p)$ où les $\{x_i\}$ sont les variables (ou entrées) et les $\{c_j\}$ sont des paramètres (ou poids). En règle générale, le calcul de la valeur de cette fonction peut se décomposer en deux étapes :

- Une combinaison linéaire des entrées :

$$v = c_0 + \sum_{i=1}^n c_i x_i \quad (\text{I.2})$$

Les c_i sont appelés poids synaptiques ou simplement poids, c_0 est appelé biais. Le biais peut être considéré comme la pondération de l'entrée 0 fixée à 1. v est appelé potentiel du neurone.

- La sortie du neurone est :

$$y = f(v) = f\left(\sum_{i=0}^n c_i x_i\right) \quad (\text{I.3})$$

La fonction f est appelée fonction d'activation ou de transfert, la figure I-8 montre les différentes fonctions d'activation utilisées dans les réseaux de neurones.

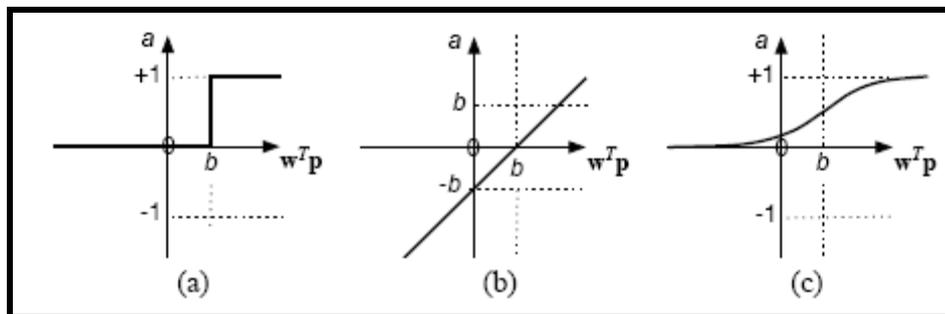


Figure.I-8 : Fonctions d'activation : (a) à seuil, (b) linéaire et (c) sigmoïde.

Un neurone formel ne réalise donc rien d'autre qu'une somme pondérée suivie d'une non linéarité. C'est l'association de tels éléments simples sous la forme de réseaux qui permet de réaliser des fonctions utiles pour des applications industrielles.

I.3.2. Architecture des réseaux de neurones

On distingue deux grands types d'architectures de réseaux de neurones : les réseaux de neurones 'non bouclés' et les réseaux de neurones 'bouclés'.

I.3.2.1. Les réseaux de neurones non bouclés [20]

Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones 'connectés' entre eux, l'information circule des entrées vers les sorties, sans 'retour en arrière'. Si on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les 'connexions' entre eux, le graphe d'un réseau non bouclé est acyclique. Le terme de 'connexions' est une métaphore : dans la très grande majorité des applications, les réseaux de neurones sont des formules algébriques dont les valeurs numériques sont calculées par des

programmes d'ordinateurs, non des objets physiques (circuits électroniques spécialisés) ; néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage, car il est commode quoique trompeur. Il a même donné naissance au terme de connexionnisme.

La figure I-9 représente un réseau de neurones non bouclé qui a une structure particulière, très fréquemment utilisée : il comprend des entrées, une couche de neurones 'cachés' et des neurones de sortie. Les neurones de la couche cachée ne sont pas connectés entre eux. Cette structure est appelée 'Perceptron multicouche'.

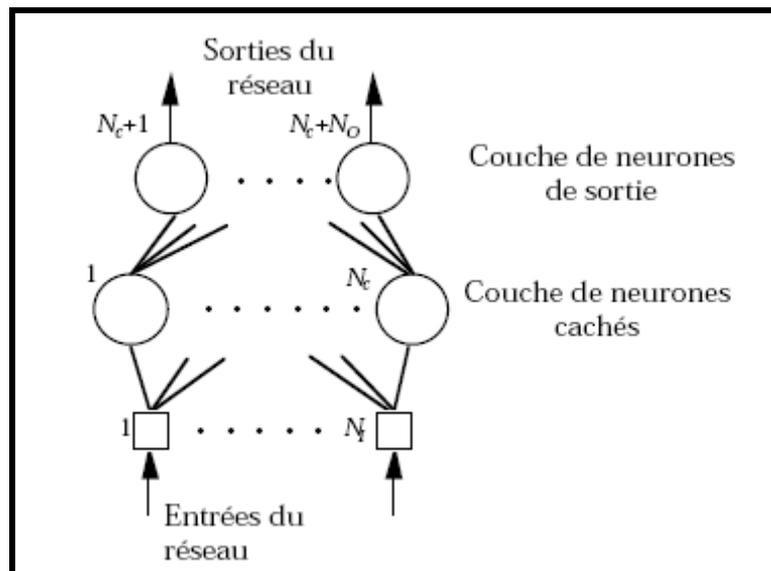


Figure.I-9 : Réseau de neurones non bouclé 'Perceptron multicouche'.

Les réseaux de neurones non bouclés sont des objets statiques : si les entrées sont indépendantes du temps, les sorties le sont également. Ils sont utilisés principalement pour effectuer des tâches d'approximation de fonction non linéaire, de classification ou de modélisation de processus statiques non linéaires.

Un réseau de neurones non bouclé est constitué par plusieurs opérateurs algébriques élémentaires appelés neurones et réalise une fonction paramétrée, non linéaire par rapport aux entrées et aux paramètres.

La famille des réseaux de neurones à une couche de neurones cachés possède la propriété d'approximation parcimonieuse. Cela signifie qu'elle est capable d'approcher n'importe quelle fonction bornée et suffisamment régulière, en utilisant moins de paramètres ajustables que les familles de fonctions usuelles telles que les polynômes.

Dans l'optique d'une modélisation statistique, on utilise les réseaux de neurones pour approcher la fonction de régression du processus. L'intérêt de la parcimonie est alors de

limiter le nombre d'exemples nécessaires pour obtenir une bonne estimation de la fonction de régression.

Par opposition aux modèles linéaires par rapport aux paramètres, pour lesquels la solution des moindres carrés s'obtient en résolvant un système d'équations, l'ajustement des paramètres d'un réseau de neurones (appelé aussi 'apprentissage') nécessite la mise en oeuvre d'algorithmes itératifs. À cet égard, il convient de bien distinguer l'étape de calcul du gradient de la fonction de coût par rapport aux paramètres (par exemple par 'la rétropropagation du gradient'), de l'étape de modification des paramètres (méthodes du gradient simple, de quasi-Newton, de Levenberg-Marquardt, etc.).

I.3.2.2. Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés, dont le graphe de connexions est acyclique, les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties. Pour qu'un tel système soit causal, il faut évidemment qu'à toute boucle soit associé un retard : un réseau de neurones bouclé est donc un système dynamique, régi par des équations différentielles ; comme l'immense majorité des applications sont réalisées par des programmes d'ordinateurs, on se place dans le cadre des systèmes à temps discret, où les équations différentielles sont remplacées par des équations aux différences.

Un réseau de neurones bouclé à temps discret est donc régi par une (ou plusieurs) équations aux différences non linéaires, résultant de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions.

La figure I-10 représente un réseau de neurones bouclé.

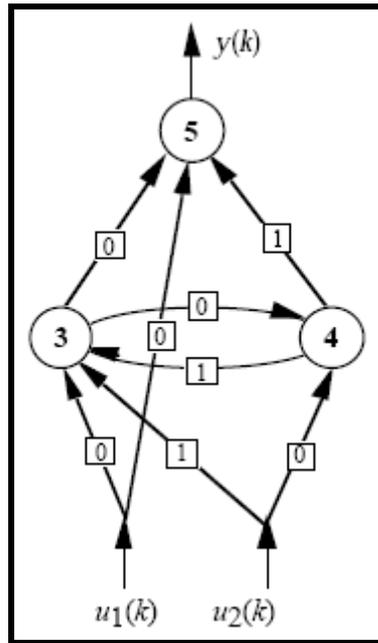


Figure.I-10 : Réseau de neurones bouclé.

Les réseaux de neurones bouclés sont utilisés pour effectuer des tâches de modélisation de systèmes dynamiques, de commande de processus, ou de filtrage.

I.3.3. L'apprentissage des réseaux de neurones

L'objectif de l'apprentissage est de fournir une méthode au réseau, afin qu'il puisse ajuster ses paramètres lorsqu'on lui présente des exemples à traiter. On distingue habituellement trois types d'apprentissage : supervisé, non supervisé et hybride.

I.3.3.1. Apprentissage supervisé

Dans ce type d'apprentissage, on fournit au réseau de neurones la donnée à traiter mais aussi la sortie attendue. Le réseau effectue une évaluation de la donnée, puis compare la valeur obtenue avec la valeur désirée, il va ensuite modifier ses paramètres internes afin de minimiser l'erreur constatée. L'apprentissage 'supervisé' consiste donc à calculer les coefficients de telle manière que les sorties du réseau de neurones soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties 'désirées', qui peuvent être : la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander.

La plupart des algorithmes d'apprentissage des réseaux de neurones sont des algorithmes d'optimisation : ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût, qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses

réponses désirées. Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût : le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite méthode de rétropropagation, puis il est utilisé par l'algorithme d'optimisation proprement dit. Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement, jusqu'à obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de validation, distinct du précédent. Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent : il existe des algorithmes d'optimisation non linéaire extrêmement rapides [21] qui permettent de faire des développements industriels sur de simples PC. L'apprentissage des réseaux de neurones bouclés (pour réaliser des modèles dynamiques) est très semblable à celui des réseaux non bouclés [22].

I.3.3.2. Apprentissage non supervisé

Dans ce type d'apprentissage, aucune information n'est fournie au réseau en plus des données à apprendre. Celui-ci est amené à découvrir la structure sous-jacente des données afin de les organiser en clusters.

I.3.3.3. Apprentissage hybride

Ce type d'apprentissage est plus rare et est encore mal exploré, cette approche combine des méthodes numériques (réseaux de neurones, algorithmes génétiques) et des méthodes symboliques [23,24]. Certains auteurs utilisent le terme d'apprentissage hybride pour parler d'un couplage 'supervisé non supervisé' ; dans ce cas, il s'agit d'un réseau qui met en parallèle ou en série un réseau entraîné en mode supervisé et un autre en mode non supervisé.

I.3.4. Les différents types de réseaux de neurones [25]

On peut distinguer deux groupes de réseaux de neurones : les réseaux 'feed-forward' et les réseaux 'feedback'.

I.3.4.1. Les réseaux 'feed-forward'

I.3.4.1.1. Le perceptron

C'est historiquement le premier réseau de neurones, c'est le perceptron de Rosenblatt. C'est un réseau simple, puisqu'il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il est calqué, à la base, sur le système visuel et, de ce fait, est connu en premier dans la reconnaissance des formes. Cependant, il peut aussi être utilisé pour faire de la classification et pour résoudre des opérations logiques simples (telle 'ET' ou 'OU'). Sa principale limite

est qu'il ne peut résoudre que des problèmes linéairement séparables. Il suit généralement un apprentissage supervisé selon la règle de correction de l'erreur (ou selon la règle de Hebb).

I.3.4.1.2. Le perceptron multicouches (PMC)

C'est une extension du précédent, avec une ou plusieurs couches cachées entre l'entrée et la sortie. Excepté pour les couches d'entrée et de sortie, chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante, et il n'y a pas de connections entre les cellules d'une même couche (figure I-9). Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïde. Il peut résoudre des problèmes non-linéairement séparables et des problèmes logiques plus compliqués (notamment le fameux problème du XOR), qui ne peuvent pas être résolus par un perceptron simple. Il suit aussi un apprentissage supervisé selon la règle de correction de l'erreur.

I.3.4.1.3. Les réseaux à fonction radiale

Ce sont des réseaux que l'on nomme aussi RBF (Radial Basic Functions). L'architecture est la même que pour les PMC, cependant les fonctions de base utilisées ici sont des fonctions gaussiennes. Les RBF seront donc employés dans les mêmes types de problèmes que les PMC, en classification et en approximation de fonctions, particulièrement. L'apprentissage le plus utilisé pour les RBF est le mode hybride et les règles sont : soit la règle de correction de l'erreur, soit la règle d'apprentissage par compétition.

I.3.4.2. Les réseaux 'feedback'

I.3.4.2.1. Les cartes auto-organisatrices de Kohonen

Ce type de réseau, appelé aussi SOM (Self Organised Maps) est un réseau à apprentissage non supervisé qui établit une carte discrète, ordonnée topologiquement en fonction de patterns d'entrée. Le réseau forme ainsi une sortie de treillis, où chaque nœud du treillis est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins vont être modifiés afin d'augmenter encore cette corrélation.

Les LVQ (Learning Vector Quantization) sont un cas particulier des SOM, où seul le nœud ayant la meilleure corrélation est adapté. On parle pour ce type de réseau, où seul le 'vainqueur' est sélectionné, de réseaux à compétition.

I.3.4.2.2. Les réseaux de Hopfield

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés. Dans ce type de réseaux, chaque neurone est connecté à chaque autre neurone, il n'y a aucune différenciation entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. L'application principale des réseaux de Hopfield est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation. Le mode d'apprentissage utilisé ici est le mode non supervisé.

I.3.4.2.3. Les réseaux ART

Les réseaux ART (Adaptative Resonance Theory) sont des réseaux à apprentissage par compétition. Le problème majeur qui se pose dans ce type de réseaux est le dilemme 'stabilité/plasticité'. En effet, dans un apprentissage par compétition, rien ne garantit que les catégories formées vont rester stables. La seule possibilité pour assurer la stabilité serait que le coefficient d'apprentissage tend vers zéro, mais le réseau perdrait alors sa plasticité. Les ART sont connus spécifiquement pour contourner ce problème. Dans ce genre de réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche d'un prototype déjà connu par le réseau. On parlera alors de résonance. A l'inverse, si l'entrée s'éloigne trop des prototypes existants, une nouvelle catégorie va alors se créer, avec pour prototype l'entrée qui a engendré sa création. Le mode d'apprentissage des ART peut être supervisé ou non. Il est à noter qu'il existe deux principaux types de réseaux ART : les ART-1 pour des entrées binaires et les ART-2 pour des entrées continues.

I.3.5. Propriété fondamentale des réseaux de neurones : l'approximation parcimonieuse

Les réseaux de neurones, tels que nous les avons définis précédemment, possèdent une propriété remarquable, qui est à l'origine de leur intérêt pratique dans des domaines très divers : ce sont des 'approximateurs' universels parcimonieux.

Sans entrer dans les détails mathématiques, la propriété d'approximation peut être énoncée de la manière suivante : toute fonction bornée suffisamment régulière peut être approchée avec une précision arbitraire, dans un domaine fini de l'espace de ses variables, par un réseau de neurones comportant une couche avec un nombre fini de neurones cachés, possédant tous la même fonction d'activation, et un neurone de sortie linéaire [26]. Cette propriété n'est pas

spécifique aux réseaux de neurones : il existe bien d'autres familles de fonctions paramétrées possédant cette propriété ; c'est le cas notamment des ondelettes, des fonctions radiales, des fonctions splines, par exemple.

La spécificité des réseaux de neurones réside dans le caractère parcimonieux de l'approximation : à précision égale, les réseaux de neurones nécessitent moins de paramètres ajustables (les poids des connexions) que les approximateurs universels couramment utilisés ; plus précisément, le nombre de poids varie linéairement avec le nombre de variables de la fonction à approcher, alors qu'il varie exponentiellement pour la plupart des autres approximateurs [27]. C'est cette remarquable parcimonie qui justifie l'intérêt industriel des réseaux de neurones. En pratique, dès qu'un problème fait intervenir plus de deux variables, les réseaux de neurones sont, en général, préférables aux autres méthodes.

Qualitativement, la propriété de parcimonie peut se comprendre de la manière suivante : lorsque l'approximation est une combinaison linéaire de fonctions élémentaires fixées (des monômes par exemple, où des gaussiennes à centres et écarts-types fixes), on ne peut ajuster que les coefficients de la combinaison ; en revanche, lorsque l'approximation est une combinaison linéaire de fonctions non linéaires à paramètres ajustables (un Perceptron multicouche par exemple), on ajuste à la fois les coefficients de la combinaison et la forme des fonctions que l'on combine. Ainsi, dans un Perceptron multicouche, les poids de la première couche déterminent la forme de chacune des sigmoïdes réalisées par les neurones cachés, et les poids de la seconde couche déterminent une combinaison linéaire de ces fonctions. On conçoit facilement que cette souplesse supplémentaire, conférée par le fait que l'on ajuste la forme des fonctions que l'on superpose, permet d'utiliser un plus petit nombre de fonctions élémentaires, donc un plus petit nombre de paramètres ajustables. Nous allons voir dans le paragraphe suivant pourquoi cette propriété de parcimonie est précieuse dans les applications industrielles.

I.3.6. Réseaux de neurones et régression non linéaire

Dans la pratique, on n'utilise pas les réseaux de neurones pour réaliser des approximations de fonctions connues. Le plus souvent, le problème qui se pose à l'ingénieur est le suivant : il dispose d'un ensemble de mesures de variables d'un processus de nature quelconque (physique, chimique, économique, financier, ...), et du résultat de ce processus ; il suppose qu'il existe une relation déterministe entre ces variables et ce résultat, et il cherche une forme mathématique de cette relation, valable dans le domaine où les mesures ont été effectuées, sachant que : les mesures sont en nombre fini, elles sont certainement entachées de bruit et

toutes les variables qui déterminent le résultat du processus ne sont pas forcément mesurées. En d'autres termes, l'ingénieur cherche un modèle du processus qu'il étudie, à partir des mesures dont il dispose, et d'elles seules : on parle de modélisation 'boîte noire'. Dans le jargon des réseaux de neurones, les données à partir desquelles on cherche à construire le modèle s'appellent des exemples.

En quoi la propriété d'approximation parcimonieuse peut-elle être utile pour résoudre ce genre de problèmes ? Ce que l'ingénieur cherche à obtenir à l'aide de son modèle, c'est la 'vraie' fonction qui relie la grandeur y_p que l'on veut modéliser aux variables $\{x\}$ qui la déterminent, c'est-à-dire la fonction que l'on obtiendrait en faisant une infinité de mesures de y_p pour chaque valeur possible de $\{x\}$: en termes de statistiques, on cherche la fonction de régression de la grandeur à modéliser. Cette fonction est inconnue, mais on peut chercher une approximation à partir des mesures disponibles : les réseaux de neurones sont donc de bons candidats pour cela, si la fonction de régression cherchée est non linéaire. Cette approximation est obtenue en estimant les paramètres d'un réseau de neurones au cours d'une phase dite d'apprentissage. C'est ici que la propriété d'approximation parcimonieuse des réseaux de neurones est précieuse : en effet, le nombre de mesures nécessaires pour estimer les paramètres de manière significative est d'autant plus grand que le nombre de paramètres est grand. Ainsi, pour modéliser une grandeur avec une précision donnée à l'aide d'un réseau de neurones, il faut moins de données que pour la modéliser, avec une précision comparable, à l'aide d'une régression linéaire multiple ; de manière équivalente, un réseau de neurones permet, avec les mêmes données disponibles, de réaliser une approximation plus précise qu'une régression linéaire multiple.

De manière générale, un réseau de neurones permet donc de faire un meilleur usage des mesures disponibles que les méthodes de régression non linéaires conventionnelles. Ce gain peut être considérable, lorsque le processus à modéliser dépend de plusieurs variables : rappelons en effet que le nombre de paramètres (donc de mesures) varie exponentiellement pour les méthodes conventionnelles de régression non linéaire, alors qu'elle varie linéairement pour les réseaux de neurones.

Ainsi, à la lumière de cette propriété fondamentale, la technique des réseaux de neurones apparaît comme une puissante méthode de régression non linéaire : ce n'est donc rien d'autre qu'une extension des méthodes de régression linéaire ou multilinéaires proposées par tous les logiciels qui permettent de faire de la modélisation de données. Contrairement à une croyance répandue, elle ne relève donc pas de l'Intelligence Artificielle au sens classique du terme, mais

elle constitue une branche des statistiques appliquées. Il ne faut donc pas être victime du vocabulaire anthropomorphique utilisé (neurones, apprentissage, etc.) ; le tableau I-2 résume les équivalences entre le vocabulaire des statistiques et celui des réseaux de neurones.

RÉSEAUX DE NEURONES	STATISTIQUES
Choix de l'architecture	Choix de la famille de fonctions destinées à approcher la fonction de régression
Ensemble d'apprentissage	Observations
Apprentissage	Estimation des paramètres de l'approximation de la fonction de régression
Généralisation	Interpolation, extrapolation

Tableau.I-2 : Réseaux de neurones et statistiques.

I.3.7. Mise en œuvre des réseaux de neurones et domaines d'application

Pour réaliser l'approximation de la fonction de régression cherchée, à partir d'échantillons généralement bruités, à l'aide d'un réseau de neurones, trois étapes successives sont nécessaires :

- Il faut tout d'abord choisir l'architecture du réseau, c'est-à-dire les entrées externes, le nombre de neurones cachés, et l'agencement des neurones entre eux, de telle manière que le réseau soit en mesure de reproduire ce qui est déterministe dans les données ; le nombre de poids ajustables est un des facteurs fondamentaux de la réussite d'une application : si le réseau possède un trop grand nombre de poids, c'est-à-dire si le réseau est trop 'souple', il risque de s'ajuster au bruit qui est présent dans les données de l'ensemble d'apprentissage, et, même en l'absence de bruit, il risque de présenter des oscillations non significatives entre les points d'apprentissage, donc de posséder de mauvaises propriétés d'interpolation (ou, dans le jargon des réseaux de neurones, de 'généralisation') ; si par contre ce nombre est trop petit, le réseau est trop 'rigide' et ne peut reproduire la partie déterministe de la fonction. Le problème de la détermination de l'architecture optimale est resté pendant longtemps un problème ouvert, mais il existe actuellement diverses méthodes, mettant notamment en jeu des tests statistiques, qui permettent de déterminer cette architecture pour une vaste classe de réseaux [28] ; la figure I-11 illustre l'influence du nombre de paramètres sur la qualité de l'approximation : le réseau le plus parcimonieux (4 neurones cachés, soit 13 coefficients) produit un bien meilleur ajustement qu'un réseau trop riche en coefficients (8 neurones cachés, soit 25 coefficients).

- Il faut calculer ensuite les poids du réseau ou, en d'autres termes, 'estimer les paramètres de la régression non linéaire' à partir des exemples, en minimisant l'erreur d'approximation sur les points de l'ensemble d'apprentissage, de telle manière que le réseau réalise la tâche désirée. Ce calcul des coefficients synaptiques constitue l'apprentissage supervisé pour le réseau de neurones.
- Il faut estimer enfin la qualité du réseau obtenu, en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage.

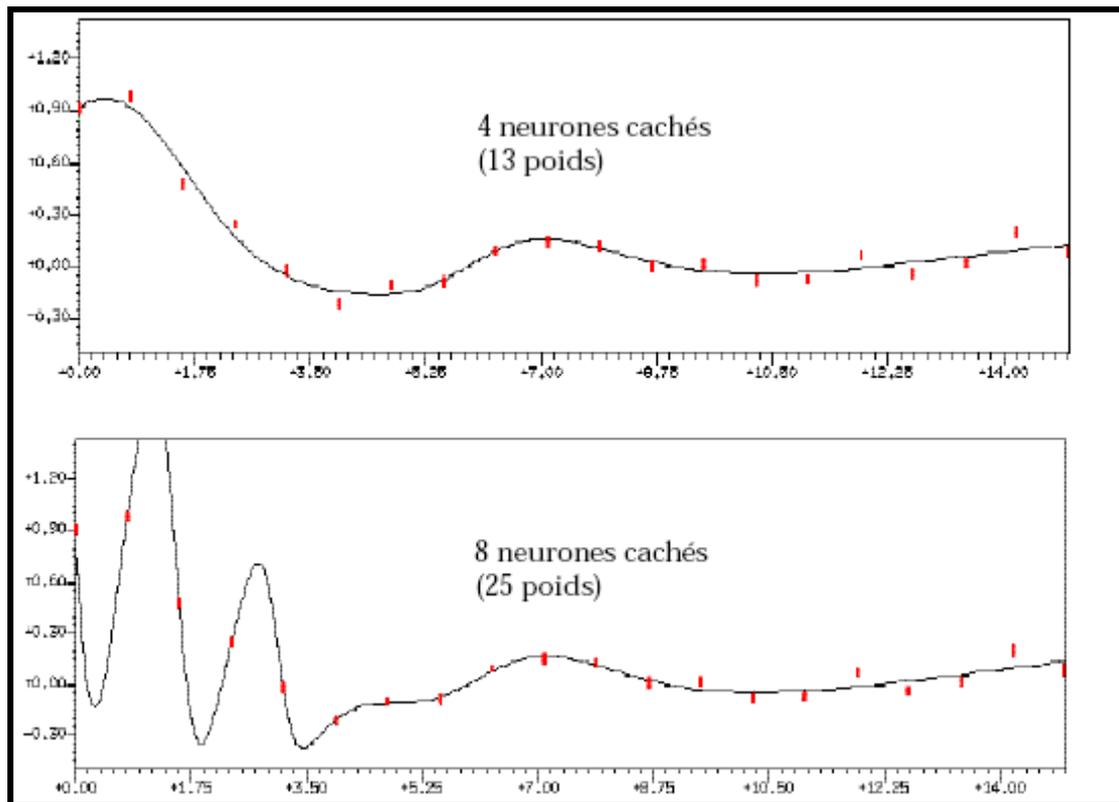


Figure.I-11 : Influence du nombre de paramètres sur la qualité de l'approximation.

Les grands domaines d'application des réseaux de neurones découlent naturellement de leurs propriétés fondamentales :

- **La régression non linéaire, ou modélisation de données statiques** : il existe une immense variété de phénomènes statiques qui peuvent être caractérisés par une relation déterministe entre des causes et des effets ; les réseaux de neurones sont de bons candidats pour modéliser de telles relations à partir d'observations expérimentales, sous réserve que celles-ci soient suffisamment nombreuses et représentatives.
- **La modélisation de processus dynamiques non linéaires** : modéliser un processus, c'est trouver un ensemble d'équations mathématiques qui décrivent le comportement

dynamique du processus, c'est-à-dire l'évolution de ses sorties en fonction de celle de ses entrées ; c'est donc typiquement un problème qui peut être avantageusement résolu par un réseau de neurones, si le phénomène qu'on veut modéliser est non-linéaire. La prévision de séries chronologiques (prévisions financières, prévision de consommation, etc.) entre dans ce cadre.

- **La commande de processus** : commander un processus, c'est imposer à celui-ci un comportement défini à l'avance en fonction des signaux de commande ; l'ensemble (commande + processus) peut donc être considéré comme un système qui réalise une fonction non-linéaire qu'un réseau de neurones peut approcher.

- **La classification** : supposons que l'on désire classer des formes en deux catégories, A ou B, en fonction de certaines caractéristiques de ces formes ; on peut définir une fonction φ qui vaut (+1) pour toutes les formes de la classe A et (-1) pour toutes les formes de la classe B. Les réseaux de neurones sont de bons candidats pour réaliser une approximation de cette fonction φ , et on peut démontrer que cette approximation constitue une estimation de la probabilité d'appartenance de la forme inconnue à la classe A. Les réseaux de neurones fournissent donc une information très riche, qui est loin d'être une simple réponse binaire. Cette propriété remarquable, que les réseaux de neurones partagent avec d'autres classifieurs, n'est malheureusement pas mise à profit dans la plupart des applications.

En conclusion, les points fondamentaux qu'il convient de toujours garder à l'esprit lorsqu'on cherche à mettre en œuvre des réseaux de neurones sont donc les suivants :

- Les réseaux de neurones sont des outils statistiques, qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points ; comme toute méthode statistique, l'utilisation de réseaux de neurones nécessite que l'on dispose de données suffisamment nombreuses et représentatives.

- Les réseaux de neurones sont des approximateurs parcimonieux.

- Les réseaux de neurones permettent de modéliser des phénomènes statiques (réseaux non bouclés) et dynamiques (réseaux bouclés).

- Il est toujours souhaitable, et souvent possible, pour la conception du réseau, d'utiliser les connaissances mathématiques dont on dispose sur le phénomène à modéliser : les réseaux de neurones ne sont pas nécessairement des 'boîtes noires'.

Chapitre II

Modèles et méthodes numériques de prévision et d'optimisation du comportement mécanique des alliages biphasés.

Application au comportement mécanique des alliages biphasés de WC-Co.

II.1. Introduction

Ce chapitre comprend deux parties. La première est consacrée à la présentation des différents modèles et méthodes d'optimisation, utilisés pour le calcul et la prévision des courbes contrainte-déformation théoriques des alliages biphasés à partir de celles de leurs constituants. On cite parmi ces modèles la loi des mélanges, les modèles de la mécanique des milieux continus, les modèles micromécaniques et les modèles auto-cohérents. Pour les méthodes numériques, la méthode la plus utilisée est la méthode des éléments finis mais, récemment, d'autres méthodes telles que la méthode des algorithmes génétiques et les réseaux de neurones ont connu une large application pour la prévision et l'optimisation du comportement mécanique des matériaux. Nous discutons essentiellement dans ce travail leur aptitude à la prévision et l'évolution des courbes contrainte-déformation des alliages biphasés en fonction de la fraction volumique de la seconde phase. Dans la deuxième partie du chapitre, nous essayons de donner quelques caractéristiques et propriétés mécaniques des matériaux de WC-Co, objet de test et de validation de notre étude de prévision et d'optimisation des propriétés mécaniques des alliages biphasés.

II.2. Modèles de déformation

Tous les traitements théoriques du comportement en déformation des alliages biphasés supposent que la microstructure peut être modélisée comme un matériau composite constitué d'une phase dure et d'une phase molle. La différence entre les différentes approches résulte, d'une part, de la distribution de la déformation entre les deux phases et, d'autre part, de la manière dont une phase affecte les caractéristiques d'écoulement de l'autre phase. Dans ce qui suit, nous décrivons brièvement les différents types de modèles pour la prévision du comportement contrainte-déformation des alliages biphasés, en insistant particulièrement sur les principales différences qui existent entre eux.

II.2.1. Loi des mélanges

La loi des mélanges a été utilisée dans plusieurs modèles de la mécanique des milieux continus comme moyen de distribution de la contrainte et/ou la déformation entre les deux phases. C'est une expression qui prévoit une variation linéaire de la contrainte ou de la déformation en fonction de la fraction volumique de la seconde phase.

Pour une déformation donnée ε , la contrainte σ est exprimée par l'équation II.1.

$$\sigma = f_{\alpha}\sigma_{\alpha} + f_{\beta}\sigma_{\beta} \quad (\text{II.1})$$

Avec:
$$f_{\alpha} + f_{\beta} = 1 \quad (\text{II.2})$$

Où f_{α} et f_{β} expriment respectivement les fractions volumiques de la phase α et de la phase β . σ , σ_{α} et σ_{β} expriment respectivement les contraintes pour une déformation donnée ε dans l'alliage biphasé et dans les phases α et β , comme le montre la figure II.1.

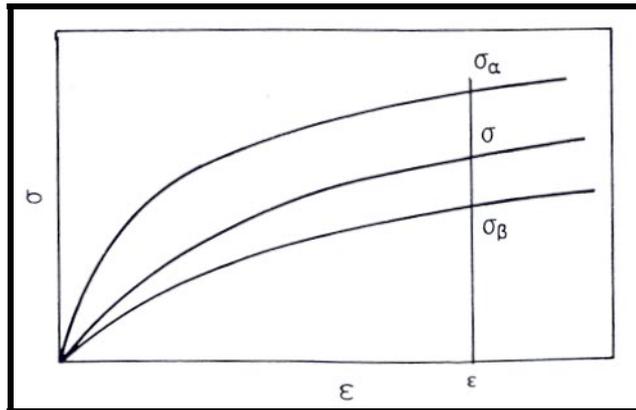


Figure.II-1 : Loi des mélanges avec une déformation constante [29].

Pour une contrainte donnée σ , la déformation ε est exprimée par l'équation II.3.

$$\varepsilon = f_{\alpha}\varepsilon_{\alpha} + f_{\beta}\varepsilon_{\beta} \quad (\text{II.3})$$

Où ε , ε_{α} et ε_{β} expriment respectivement les déformations pour une contrainte donnée σ dans l'alliage biphasé et dans les phases α et β , comme le montre la figure II.2.

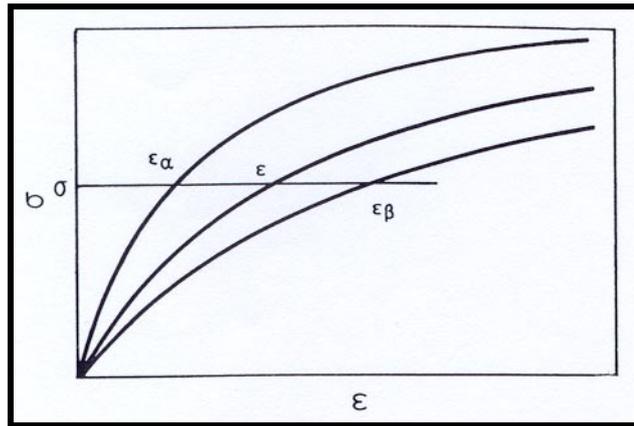


Figure.II-2 : Loi des mélanges avec une contrainte constante [29].

Les figures II.3-a et II.3-b montrent les géométries correspondant aux deux cas cités ci-dessus.

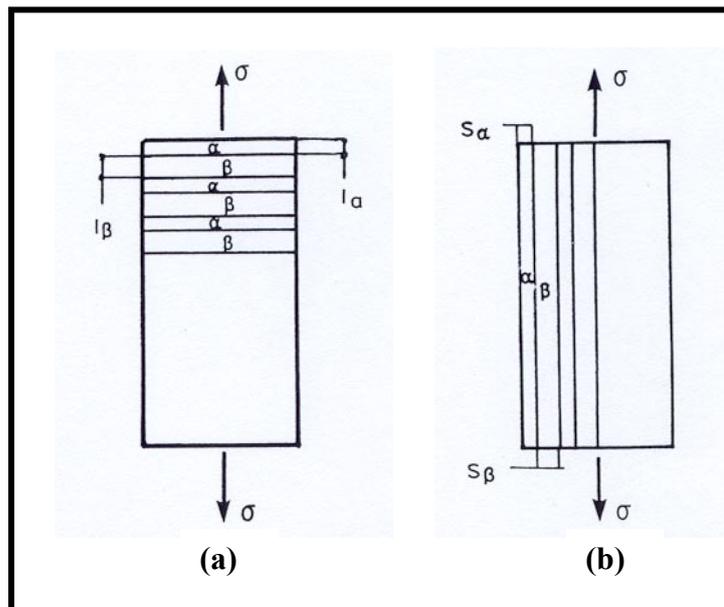


Figure.II-3 : Géométrie correspondant à la loi des mélanges :
a) avec une déformation constante, b) avec une contrainte constante [29].

Pour une contrainte constante σ , la géométrie appliquée pour l'alliage biphasé est celle montrée sur la figure II.3-a, généralement nous avons :

$$f_{\alpha} = \frac{l_{\alpha}}{l_{\alpha} + l_{\beta}}, f_{\beta} = \frac{l_{\beta}}{l_{\alpha} + l_{\beta}}, \frac{f_{\alpha}}{l_{\alpha}} = \frac{f_{\beta}}{l_{\beta}}. \quad (\text{II.4})$$

Pour une déformation constante ε , la géométrie appliquée pour l'alliage biphasé est celle montrée sur la figure II.3-b, généralement nous avons :

$$\frac{f_{\alpha}}{s_{\alpha}} = \frac{f_{\beta}}{s_{\beta}} \quad (\text{II.5})$$

Il faut noter qu'il existe d'autres géométries dérivées de ces deux cas.

La loi des mélanges peut être appliquée pour une condition d'iso-déformation comme pour une condition d'iso-contrainte dans les modèles de la mécanique des milieux continus.

II.2.1.1. Modèles d'iso-déformation

Dans ce type de modèles, on peut citer les modèles développés par Mileiko [30] et Garmon et Thompson [31], qui permettent de prévoir des variations uniformes de déformations et de contraintes des matériaux composites à fibres ductiles. Ces modèles ont été appliqués aux aciers à deux phases (dual-phase steels) (structure ferrite-martensite) [32,33]. Les deux approches supposent une condition d'iso-déformation et utilisent la loi des mélanges pour la distribution des contraintes. Ils supposent également que le matériau composite et les phases qui le constituent suivent l'équation de Hollomon [34] :

$$\sigma = k\varepsilon^n \quad (\text{II.6})$$

Où k et n sont des constantes qui caractérisent l'état du matériau.

La condition d'iso-déformation dans le modèle de Mileiko exige les hypothèses suivantes :

1. isotropie élastique et plastique.
2. application parfaite de la mécanique des milieux continus aux interfaces.
3. absence de contraintes résiduelles.
4. absence de déformation aux interfaces.
5. connaissance des propriétés *in-situ* des déformations considérées.

II.2.1.2. Modèles d'iso-contrainte (ou distribution de la déformation)

Plusieurs auteurs [35,36] ont proposé des modèles de la mécanique des milieux continus avec des déformations différentes dans les deux phases (cas ferrite et martensite). Araki et al [35] utilisent un modèle, également en mécanique des milieux continus, qui permet d'évaluer l'énergie emmagasinée dans les deux phases et dans le matériau composite. Les déformations

sont distribuées suivant la loi des mélanges et il est supposé que l'équation de Hollomon (eq. II.6) décrit les courbes contrainte-déformation du matériau composite et celles de ses phases. Une équation générale de la courbe contrainte-déformation en fonction de la fraction volumique de la phase dure a été développée à partir de cette analyse.

II.2.2. Modèles micromécaniques

D'autres auteurs [37,38] ont développé des modèles où l'état de contrainte n'est pas supposé constant, comme dans les modèles de la mécanique des milieux continus décrits ci-dessus. Dans le modèle micromécanique développé par Ashby [38] et appliqué aux aciers à deux phases (dual-phase steels) par Ramos et al [39], la martensite est supposée non déformable et les dislocations s'accumulent pour accommoder les gradients de la déformation plastique qui résulte de la déformation non homogène. L'effet de durcissement de ces dislocations dans la ferrite dépend de leurs libre parcours moyen, qui est fonction de la fraction volumique et de la taille des grains de la martensite.

II.2.2. Modèles auto-cohérents

En utilisant les modèles auto-cohérents, un comportement plastique non homogène du matériau biphasé peut également être déduit à partir de celui de ses composants. Ces modèles sont basés sur l'hypothèse suivante : les interactions mécaniques, entre chaque élément d'un agrégat non homogène et tous les autres éléments de l'agrégat, sont remplacées par l'interaction de cet élément avec un milieu homogène équivalent, de comportement inconnu, qui représente l'agrégat. On se ramène ainsi au problème d'une inclusion dans une matrice infinie, cette solution est appliquée à chaque élément de l'agrégat. En utilisant les résultats d'Eshelby [40] sur les inclusions, et en appliquant la loi des mélanges pour les contraintes et les déformations, Berveiller et Zaoui [41] ont établi les lois d'interaction suivantes pour un matériau biphasé :

$$\varepsilon_{\alpha} = \frac{5\mu}{3\mu + 2\mu_{\alpha}} \quad (\text{II.7})$$

$$\varepsilon_{\beta} = \frac{5\mu}{3\mu + 2\mu_{\beta}} \quad (\text{II.8})$$

Où : ε_{α} et ε_{β} sont les déformations de la phase α et de la phase β .

μ_α , μ_β et μ sont les modules de cisaillement de la phase α , de la phase β et du matériau biphasé.

Chaque phase est supposée avoir un comportement élasto-plastique isotrope, représenté par la relation de Hencky, sans changement de volume et les inclusions sont considérées comme sphériques.

En utilisant ces méthodes auto-cohérentes, d'autres auteurs [29,42] ont traité le problème de la déformation en traction uniaxiale de biphasés, ayant été filés ou tréfilés préalablement dans la direction de traction. Ils ont donné les modélisations obtenues de la courbe de traction du biphasé à partir de celles des monophasés correspondantes, pour le modèle de Berveiller et Zaoui à inclusions sphériques et pour leurs modèles à inclusions ellipsoïdales et à matrice isotrope et orthotrope.

La mise en oeuvre du modèle présenté est simple. La comparaison avec le modèle de Berveiller et Zaoui a donné des indications intéressantes sur l'effet de la forme des grains de chaque phase, mais ce n'est manifestement pas un paramètre important par rapport aux autres paramètres, tels que l'anisotropie structurale et l'anisotropie de la matière. Leur modélisation permet de prendre en compte uniquement l'effet de l'anisotropie de forme.

II.3. Méthodes numériques d'optimisation du comportement mécanique des alliages biphasés

Les modèles cités ci-dessus présentent un grand nombre de limitations pour modéliser correctement le comportement mécanique des matériaux biphasés. Parmi les limites, on peut citer la qualité des données d'entrée. La qualité des modèles est généralement influencée par un paramètre plus que les autres, paramètre qu'il est donc important de définir parmi l'ensemble des paramètres intervenant dans le comportement mécanique. De ce fait, les méthodes numériques d'optimisation ont connu un développement important pour optimiser les paramètres des modèles qui seront utilisés pour la prévision globale du comportement mécanique, à partir d'un ensemble de données expérimentales non déterminé,.

II.3.1. Méthode des éléments finis

La méthode des éléments finis est actuellement largement utilisée pour modéliser le comportement mécanique des alliages biphasés. La simulation par cette méthode repose sur l'hypothèse de substitution du matériau réel soumis à une sollicitation donnée, par un matériau périodique formé de mailles de forme géométrique bien connue, correspondant à la

géométrie de la sollicitation considérée. Les mailles représentatives du matériau de remplacement doivent respecter certaines conditions : elles doivent avoir une symétrie compatible avec celle du matériau réel, lorsqu'il est soumis à la sollicitation considérée, elles doivent posséder une structure interne respectant ces symétries et elles doivent présenter les caractéristiques essentielles de la microstructure réelle, telles que les fractions volumiques de chaque phase, les tailles relatives et les formes de leurs domaines [43]. La figure II.4 montre un exemple de représentation du matériau réel de WC-Co par un réseau des éléments finis [44].

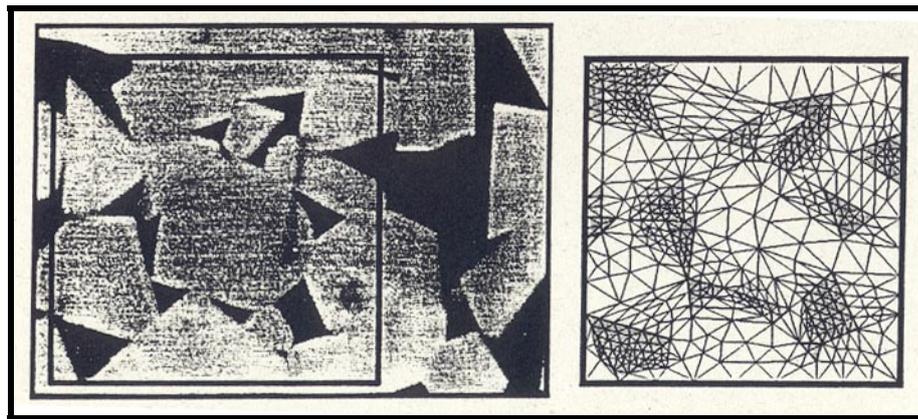


Figure.II-4 : Microstructure et réseau des éléments finis d'un alliage de WC-Co (la longueur du carré est de $8.4 \mu\text{m}$) [44].

II.3.2. Méthode des algorithmes génétiques

La méthode des algorithmes génétiques (AG) de nature récursive permet de construire des modèles adéquats avec un minimum d'expérimentation ; une fois que le modèle est suffisamment optimisé, il peut être utilisé par la suite dans une procédure de prévision de comportement. La méthode des AGs est très souhaitable pour résoudre ce type de problèmes cités ci-dessus et pour éviter les inconvénients que présentent les méthodes classiques conventionnelles. D'une part, dans cette méthode chaque donnée individuelle est traitée en tant qu'entité séparée, pour laquelle les paramètres du modèle doivent être optimisés, et les courbes expérimentales n'ont donc pas besoin d'être ajustées. D'autre part, il n'existe pas une limite du nombre d'entités à considérer ou des paramètres qui peuvent être traités en même temps. Finalement, elle détermine les paramètres optimaux qui permettent d'intégrer l'erreur expérimentale.

II.3.3. Méthode des réseaux de neurones

Les réseaux de neurones sont devenus en quelques années des outils précieux dans le domaine des sciences des matériaux à l'instar d'autres domaines très divers. L'intérêt pratique des réseaux de neurones en science des matériaux est dû essentiellement à leurs propriétés mathématiques spécifiques et leur mise en œuvre très simple. La méthode des réseaux de neurones se situe dans la perspective des méthodes classiques de traitement statistique de données (comme la régression par exemple) et elle se considère comme une extension puissante de ces dernières.

Les réseaux de neurones sont généralement utilisés pour résoudre un problème où on dispose d'un ensemble de mesures de variables d'un processus de nature quelconque (physique ou autre) et d'un résultat de ce processus. Il est supposé qu'il existe une relation déterministe entre ces variables et ce résultat et on cherche une forme mathématique de cette relation, valable dans le domaine où les mesures ont été effectuées, sachant que les mesures sont en nombre fini et que les variables qui déterminent le résultat du processus ne sont pas forcément mesurées. En d'autres termes, on cherche un modèle du processus qu'on étudie à partir des mesures dont on dispose et on dit qu'on a effectué une modélisation 'boîte noire'.

II.4. Comportement mécanique des alliages biphasés WC-Co.

La plupart des matériaux structuraux importants sont constitués de deux ou plusieurs phases, avec des propriétés mécaniques largement différentes. Parmi ces matériaux, on peut citer les carbures cémentés, les cermets, les aciers à outils, les aciers à deux phases (dual-phase steels), la plupart des alliages destinés aux outils de coupe et les céramiques. Les matériaux de WC-Co sont classés dans la catégorie des carbures cémentés et ils sont considérés comme les matériaux les plus importants dans cette catégorie à cause de leur température de fusion très élevée (2785°C) et leurs importantes duretés (16-22 GPa Vickers à une charge de 500g) [45]; ils sont généralement utilisés comme outils de coupe, de forage et d'autres applications. La caractéristique la plus importante de ces matériaux est la combinaison entre une dureté élevée désirable et une contrainte de rupture élevée, ceci est dû aux contributions respectives des phases de carbure WC (phase dure) et de la phase métallique Co (phase molle), d'où l'intérêt pratique de ce type de matériaux, il représente donc un matériau type pour l'étude théorique de prévision et d'optimisation du comportement mécanique de ces matériaux.

II.5. Structure et microstructure des alliages WC-Co

Les matériaux biphasés WC-Co sont morphologiquement constitués d'une phase dure de carbure de tungstène WC de structure hexagonale et d'une phase molle métallique liante de Co de structure cfc (le Co a une structure hexagonale compacte à température ambiante et passe à la structure cfc à 405°C) (Fig.II-5) [46].

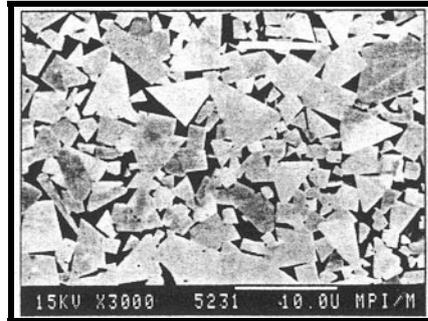


Figure.II-5 : Microstructure du matériau WC-9%wt Co [47].

II.6. Caractéristiques mécaniques des alliages WC-Co

Les propriétés mécaniques des matériaux WC-Co dépendent essentiellement de leurs composition (fraction volumique de Co) et microstructure (plus particulièrement de la taille des grains de la phase WC). En général, la diminution de la taille des grains de la phase WC augmente les propriétés mécaniques de ces matériaux telles que la dureté, la résistance, la rupture transverse et le durcissement. L'augmentation de la fraction volumique du Co augmente la contrainte de rupture au détriment de la dureté et de la résistance [48]. Le WC a une limite élastique de 970 MPa et un module de Young de 703 GPa, le Co a une limite élastique de 270 MPa et un module de Young de 207 GPa [47]. La limite élastique et le module de Young du matériau biphasé WC-Co dépendent de la taille des grains de la phase WC et de la fraction volumique de Co [49] (Fig.II-6 et II-7).

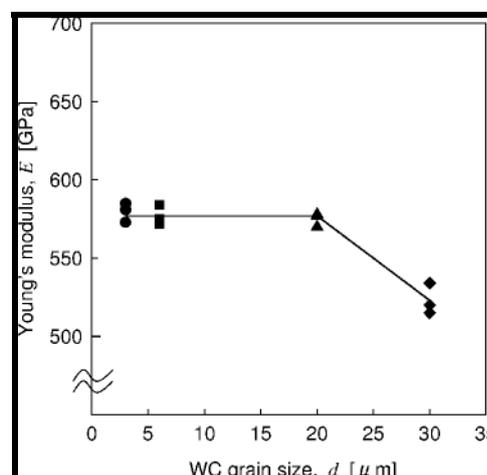


Figure.II-6 : Variation du module de Young en fonction de la taille des grains de WC
(Alliage WC-10%wt Co) [49].

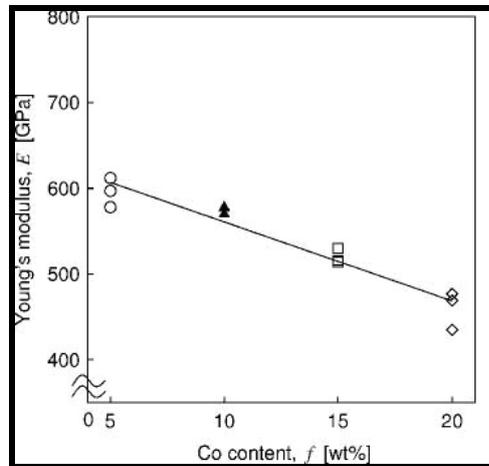


Figure.II-7 : Variation du module de Young en fonction de la teneur en Co (20 μm de taille de grains de WC) [49].

II.7. Comportement mécanique des alliages biphasés WC-Co

Le comportement mécanique des alliages biphasés WC-Co est régi essentiellement par l'effet de la taille des grains de la phase dure WC et de la fraction volumique de la phase molle Co.

II.7.1. Effet de la taille des grains de la phase WC

Les propriétés mécaniques des matériaux WC-Co sont fortement liées à la taille des grains de la phase WC, elles augmentent avec sa diminution. Les résultats expérimentaux indiquent que les matériaux avec des tailles de grains de WC petites (e.g., 3-6 μm) sont fragiles, ceux avec des tailles de grains plus grandes (20-30 μm) sont ductiles [49]. La figure II-8 montre la variation des propriétés mécaniques (contrainte-déformation) en fonction de la taille des grains de WC [49].

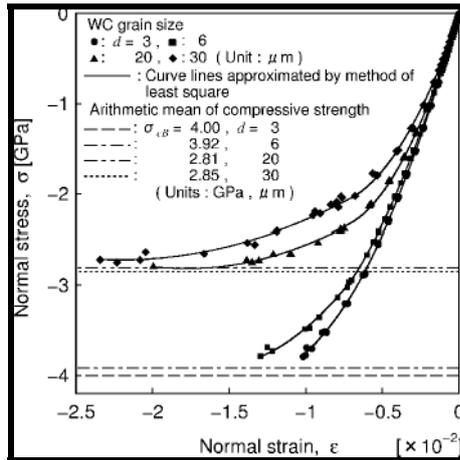


Figure.II-8 : Variation des courbes contrainte-déformation de WC-10%wt Co déformé en compression en fonction de la taille des grains de WC [49].

II.7.2. Effet de la fraction volumique de Co

L'effet de la fraction volumique de Co apparaît essentiellement dans la diminution de la contrainte d'écoulement plastique avec l'augmentation de la fraction volumique de Co. La déformation du matériau biphasé de WC-Co est contrôlée en grande partie par la matrice de la phase molle de Co. C'est cette dernière qui détermine le module et la limite élastiques ainsi que la contrainte de rupture. La figure II-9 montre la variation des propriétés mécaniques (contrainte-déformation) en fonction de la fraction volumique de Co [49].

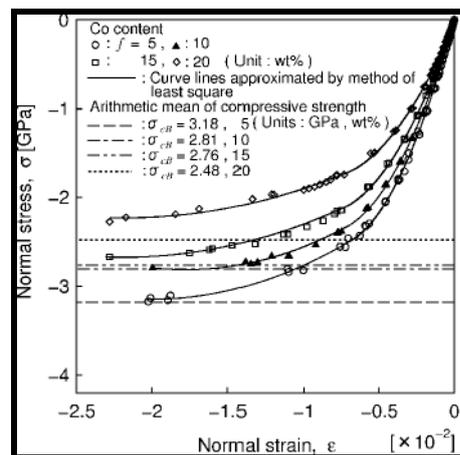


Figure.II-9 : Variation des courbes contrainte-déformation de WC-Co déformé en compression en fonction de la teneur en Co (taille des grains de WC $20 \mu\text{m}$) [49].

II.8. Déformation plastique des alliages WC-Co

Pour l'étude de la déformation plastique des matériaux biphasés WC-Co, des essais de déformation à vitesse constante et des courbes de contrainte-déformation sont nécessaires pour avoir accès aux paramètres physiques comme la limite élastique, le module élastique et le taux de durcissement ; ils permettent également de reconnaître les différents stades de déformation. Ils sont importants comme mesures comparatives de la résistance à la déformation des différents alliages WC-Co, dont les paramètres critiques comme la taille des grains WC et la fraction volumique de la phase Co sont différents. Ces essais montrent que la phase Co est responsable de la déformation plastique du matériau biphasé.

II.8.1. Courbes contrainte-déformation des alliages WC-Co

Dans toute notre étude nous avons choisi d'étudier le système WC-Co, ce choix trouve sa justification d'une part parce qu'on dispose d'une évolution complète du comportement mécanique de ce système en fonction de la fraction volumique de Co, en traction et en compression, d'autre part il est constitué de deux phases mécaniquement largement différentes, une dure (WC) et l'autre molle (Co).

II.8.1.1. WC-Co en traction

La figure II-10 montre l'évolution expérimentale des courbes contrainte-déformation de WC-Co déformé en traction, ces essais ont été effectués par Nishimatsu et Gurland [50].

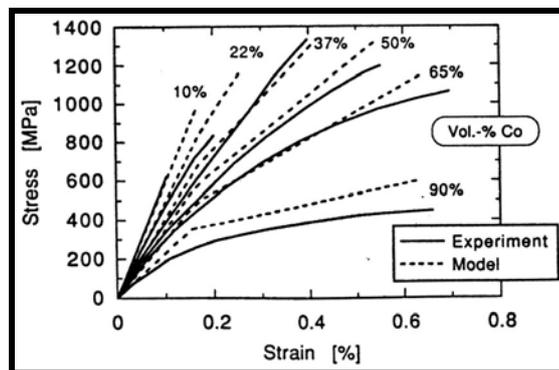


Figure.II-10: Courbes contrainte-déformation de WC-Co déformé en traction [50].

II.8.1.2. WC-Co en compression

La figure II-11 montre l'évolution expérimentale des courbes contrainte-déformation de WC-Co déformé en compression, ces essais ont été effectués par Doi et al [51].

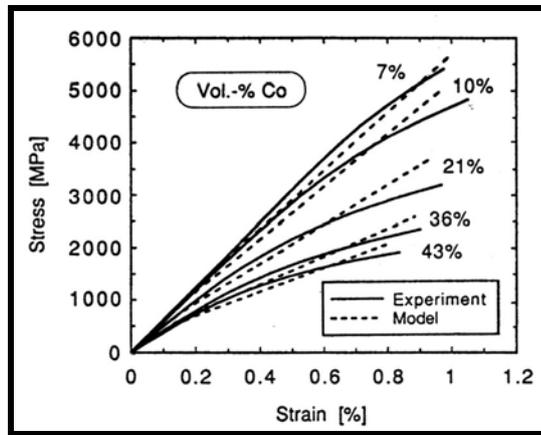


Figure.II-11 : Courbes contrainte-déformation de WC-Co déformé en compression [51].

Ces résultats ont été obtenus à température ambiante et à vitesse de déformation constante.

Les matériaux WC-Co se comportent différemment en compression et en traction, le meilleur comportement mécanique de ces matériaux est observé en compression: c'est dans ce dernier cas qu'on a un domaine élastique-plastique suivi par la rupture ; c'est ce que nous avons également remarqué (cf. chapitre 4).

Chapitre III

Optimisation du comportement mécanique des alliages biphasés de WC-Co par la méthode des algorithmes génétiques.

III.1. Introduction

Ce chapitre est consacré à la présentation de la méthode d'optimisation du comportement mécanique des alliages biphasés de WC-Co par les Algorithmes Génétiques et aux résultats obtenus en appliquant cette dernière sur les alliages de WC-Co déformés en traction et en compression.

III.2. Modèle avec la forme de Voce [52]

Le comportement plastique des alliages biphasés est gouverné par les propriétés mécaniques de chaque phase, ainsi que par la fraction volumique et la distribution morphologique de la seconde phase ; ces différents paramètres doivent être introduits dans une procédure de modélisation de la déformation.

Le présent modèle est basé sur les notions de la mécanique des milieux continus. Une hypothèse d'iso-déformation est utilisée et la distribution de la contrainte suit la loi des mélanges. La structure du matériau, à part la différence mécanique entre les deux phases, n'est pas prise en compte et la distribution des phases est supposée homogène. Il est nécessaire de noter que la dominance des phases est une dominance mécanique, qui ne coïncide pas généralement avec la dominance morphologique.

Il est bien connu que les approches de la mécanique des milieux continus supposent que la relation contrainte-déformation de chaque phase respecte la forme pseudo-linéaire suivante :

$$\sigma = k\varepsilon^n \quad (\text{III.1})$$

Cette forme ne permet pas de donner une bonne prévision du comportement des alliages biphasés à matrice molle, qui présentent expérimentalement une allure avec plateau de contrainte (Fig.III-1). Pour obtenir cette allure, nous avons considéré dans ce travail une loi exponentielle sous la forme suivante :

$$\sigma = k(1 - \exp(-\frac{\varepsilon}{n})) \quad (\text{III.2})$$

Où k et n expriment respectivement la résistance à la déformation et l'ajustement vers le comportement avec palier de contrainte.

L'utilisation de la forme exponentielle donne un meilleur ajustement que la forme pseudo-linéaire du comportement des alliages biphasés à matrice molle comme, généralement, les alliages métalliques.

III.3. Présentation mathématique du modèle [53]

III.3.1. Condition d'iso-déformation

La déformation est supposée égale dans les deux phases (hypothèse d'iso-déformation) :

$$\varepsilon = \varepsilon_\alpha = \varepsilon_\beta \quad (\text{III.3})$$

Où ε , ε_α et ε_β sont les déformations de l'alliage, de la phase α et de la phase β respectivement.

III.3.2. Relation contrainte-déformation de chaque phase

Pour les alliages biphasés à matrice molle, qui présentent expérimentalement une allure avec palier, nous avons employé pour chaque phase la forme exponentielle :

$$\sigma_\alpha = k_\alpha \left(1 - \exp\left(-\frac{\varepsilon}{n_\alpha}\right)\right) \quad (\text{III.4})$$

$$\sigma_\beta = k_\beta \left(1 - \exp\left(-\frac{\varepsilon}{n_\beta}\right)\right) \quad (\text{III.5})$$

σ_α et σ_β sont les contraintes dans la phase α et dans la phase β respectivement.

Les coefficients k_α et k_β expriment respectivement la résistance des phases α et β dans le matériau biphasé. Ils sont obligatoirement différents des valeurs intrinsèques de chaque phase. Ils dépendent de la fraction volumique de la seconde phase, de la répartition morphologique de la seconde phase et de l'interaction mutuelle phase dure – phase molle.

Les coefficients n_α et n_β expriment respectivement l'ajustement des phases α et β vers le comportement en palier, caractéristique des phases molles. Ils sont d'autant plus élevés que les phases présentent une bonne aptitude à la déformation, ils prennent des valeurs comprises entre 0.1 et 1.

III.3.3. Relation contrainte-déformation dans l'alliage biphasé

Nous avons utilisé, comme dans les modèles cités dans le chapitre 2, la loi des mélanges pour la distribution de la contrainte σ dans l'alliage biphasé :

$$\sigma = f_{\alpha}\sigma_{\alpha} + f_{\beta}\sigma_{\beta} \quad (\text{III.6})$$

f_{α} et f_{β} sont les fractions volumiques des phases α et β respectivement.

σ_{α} et σ_{β} sont les contraintes dans les phases α et β , elles ont les formes (III.4) et (III.5) respectivement.

III.4. Procédure d'optimisation [54]

Les paramètres k_{α} , k_{β} , n_{α} et n_{β} (Eqs III.4 et III.5) sont déterminés dans chaque cas par optimisation en utilisant un *Algorithme Génétique (AG)*. Cette procédure a été utilisée par Reardon et Bingert [5] pour optimiser les paramètres micromécaniques de modélisation de la densification des poudres. A partir des courbes expérimentales numérisées, la première étape de l'optimisation par AG est de définir les intervalles de recherche pour chaque paramètre. Pour k_{α} et k_{β} , les intervalles sont autour de la limite élastique de chaque phase, ils varient avec la variation de la fraction volumique. Pour n_{α} et n_{β} les intervalles sont de 0.1 à 1. La deuxième étape est de définir les fonctions à optimiser.

Dans ce travail, l'objectif est de minimiser la différence entre les courbes contrainte-déformation calculées et expérimentales. Dans le cas où l'AG trouve une valeur non souhaitable d'un paramètre à la fin d'un intervalle, ceci indique une insuffisance dans l'intervalle du paramètre. Lorsque cela arrive, l'intervalle du paramètre sera élargi. Lorsque l'AG trouve une valeur non souhaitable d'un paramètre à l'intérieur d'un intervalle, ceci indique une insuffisance dans le modèle lui même. Dans le cas des alliages biphasés à matrice molle, qui présentent une forme avec plateau de contrainte, l'insuffisance réside dans les modèles qui supposent une forme pseudo-linéaire, cette forme ne peut pas donner une telle allure. L'utilisation d'une forme exponentielle est plus appropriée pour ce type d'alliages biphasés (Fig.III-1). Il faut noter que l'AG calcule uniquement les valeurs des paramètres des fonctions et non pas la courbe contrainte-déformation entière. Pour chaque fraction volumique et à partir des valeurs des paramètres (k_{α} , k_{β} , n_{α} , n_{β}) obtenus par optimisation, la courbe contrainte-déformation est calculée en utilisant la loi des mélanges (Eq III.6) et la condition

d'iso-déformation à partir des courbes de chaque phase (Eq III.3). La troisième étape est la définition des paramètres génétiques de l'AG lui-même (Tab.III-1).

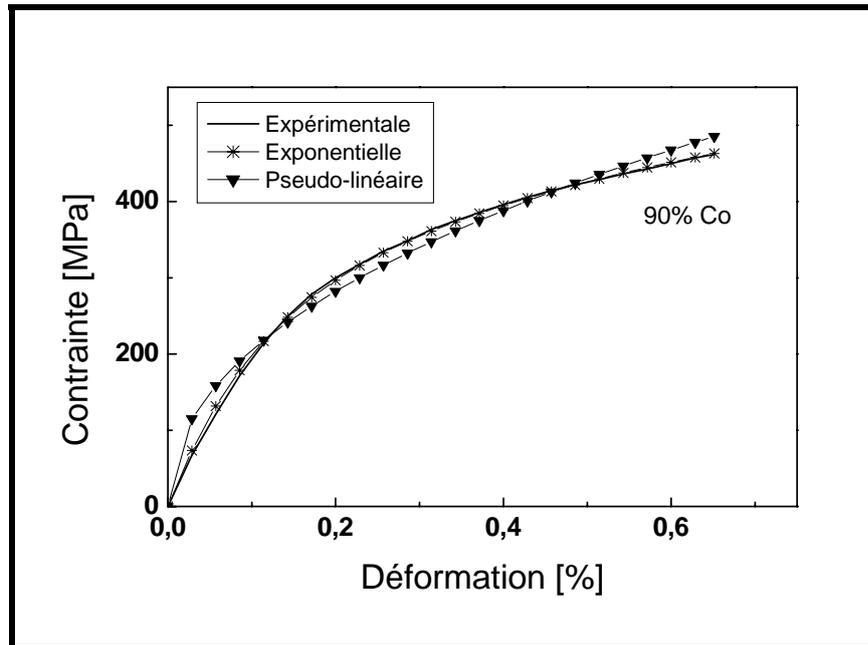


Figure.III-1 : Comparaison entre les comportements calculés par AG par la forme pseudo-linéaire et exponentielle. Alliage WC-90% Co en traction (données expérimentales [50]).

Paramètre	Valeur
Nombre des individus	200
Nombre de générations	60
Longueur du chromosome	29
Probabilité de croisement	0.85
Probabilité de mutation	0.02

Tableau.III-1 : Paramètres génétiques de l'AG.

Le fonctionnement de l'AG (partant de la dernière étape) se fait de la manière suivante : Initialement une première génération sera multipliée d'une manière aléatoire, cette génération contient N individus qui représentent les paramètres de la fonction $(k_{\alpha}, k_{\beta}, n_{\alpha}, n_{\beta})$. Chaque individu est codé selon un code binaire, ensuite un décodage a lieu pour la détermination des paramètres de la fonction, les trois opérateurs de la génétique tels que la reproduction, le croisement et la mutation vont intervenir pour la création de la nouvelle génération. Lorsque cette opération est achevée (reproduction, croisement et mutation), la population finale

contient le double de la population initiale, ce qui induit l'intervention de la sélection finale pour avoir le même nombre d'individus, cette sélection est faite par compétition entre parents et enfants. C'est cette compétition entre parents et enfants qui va donner la population la plus performante et la mieux adaptée des paramètres de la fonction $(k_\alpha, k_\beta, n_\alpha, n_\beta)$. Après 30 à 40 générations, l'AG commence à donner des valeurs raisonnables des paramètres. Un exemple de convergence de la méthode des AGs est donnée sur la figure III-2, qui montre la variation des paramètres k_α et k_β en fonction du nombre de générations pour l'alliage WC-90% Co en traction.

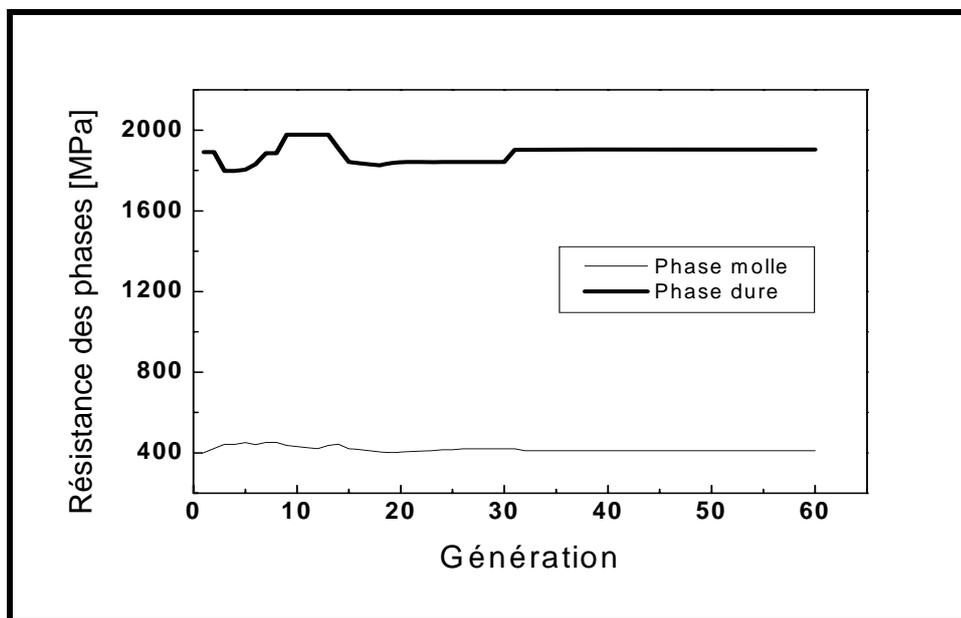


Figure.III-2 : Exemple de convergence de la méthode des AGs : résistance des phases en fonction du nombre de générations, pour le cas de l'alliage WC-90% Co en traction.

III.5. Résultats

Cette méthode a été appliquée pour calculer les courbes contrainte-déformation du système : WC-Co déformé en traction pour les fractions de 90%, 65%, 50% et 37% de Co (les valeurs des paramètres optimisés sont reportées sur le tableau III-2) et WC-Co déformé en compression pour les fractions de 43%, 36%, 21% et 10% de Co (les valeurs des paramètres optimisés sont reportées sur le tableau III-3). Le système WC-Co est de type connecté, WC est la phase dure et Co est la phase molle. Ce système a été étudié par Poech et Fishmeister [47]. Les auteurs ont appliqué leur modèle, basé sur une compatibilité de déformation, à ce système. Leur modèle permet de prévoir uniquement le cas des alliages biphasés à matrice dure.

Fraction volumique de Co (%)	k_{α} (MPa)	k_{β} (MPa)	n_{α}	n_{β}
90	410.0196	1904.4689	0.16	1.00
65	534.0294	2724.3297	0.40	0.40
50	564.7260	3088.5397	0.40	0.52
37	814.7065	6214.4066	0.94	1.00

Tableau.III-2 : Valeurs des paramètres obtenus par optimisation par AG. Système WC-Co en traction.

Fraction volumique de Co (%)	k_{α} (MPa)	k_{β} (MPa)	n_{α}	n_{β}
43	412.6614	4287.1868	0.82	0.58
36	1012.7221	4599.9004	0.52	0.70
21	2445.7945	5284.9817	0.76	0.82
10	2513.1037	8217.5519	0.94	1.00

Tableau.III-3 : Valeurs des paramètres obtenus par optimisation par AG. Système WC-Co en compression.

III.5.1. WC-Co en traction

Les courbes contraintes-déformations calculées sont en bon accord avec le comportement expérimental pour les fractions 90%, 65% et 50% de Co (Fig.III-3). La variation de la résistance des phases est linéaire tant que la phase molle est dominante (Fig.III-4).

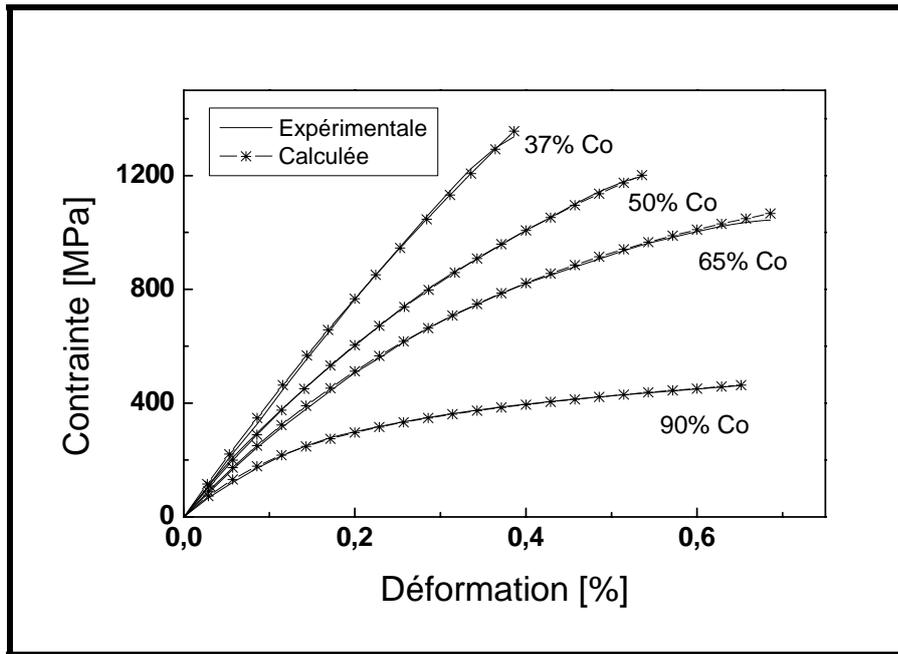


Figure.III-3 : Courbes contrainte-déformation calculées par AG. Système WC-Co en traction (données expérimentales [50]).

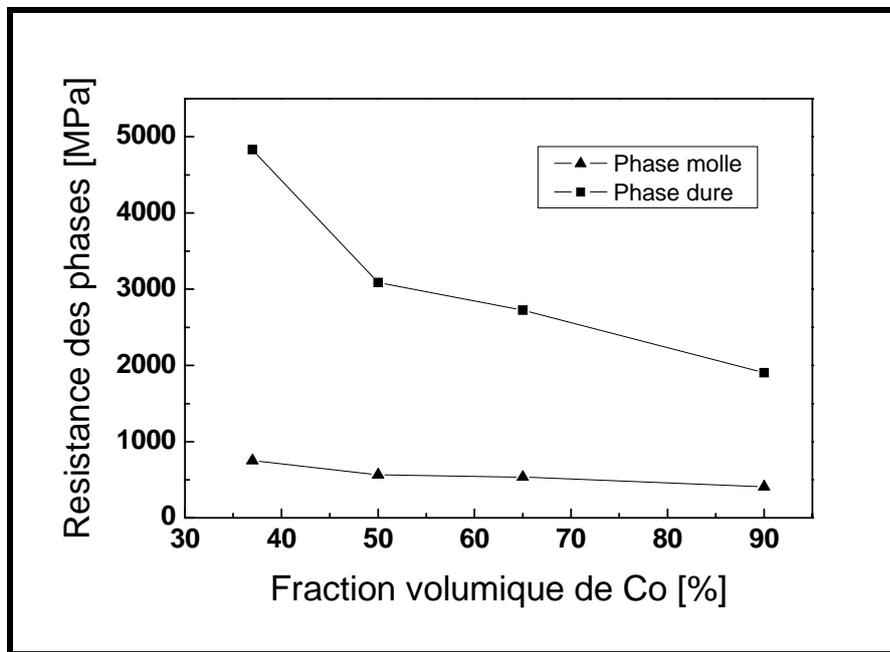


Figure.III-4 : Evolution de la résistance des phases calculée par AG en fonction de la fraction volumique de la phase molle (Co) pour le système WC-Co en traction.

III.5.2. WC-Co en compression

La figure III-5 montre la comparaison entre les courbes contraintes-déformations calculées et expérimentales, elle montre un bon accord pour les fractions 43%, 36% et 21% de Co. La variation de la résistance des phases est visualisée sur la figure III-6.

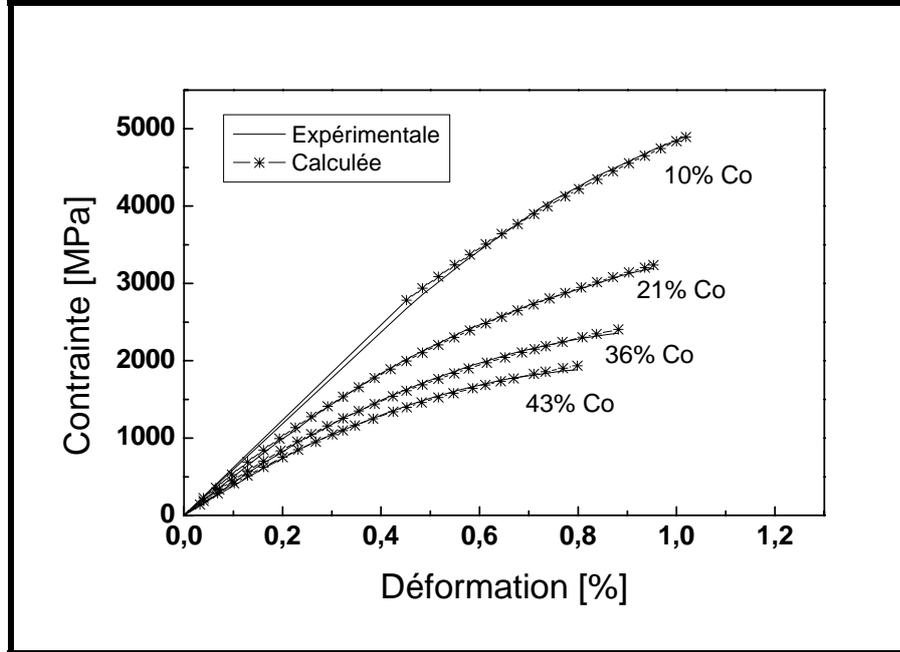


Figure.III-5 : Courbes contrainte-déformation calculées par AG. Système WC-Co en compression (données expérimentales [51]).

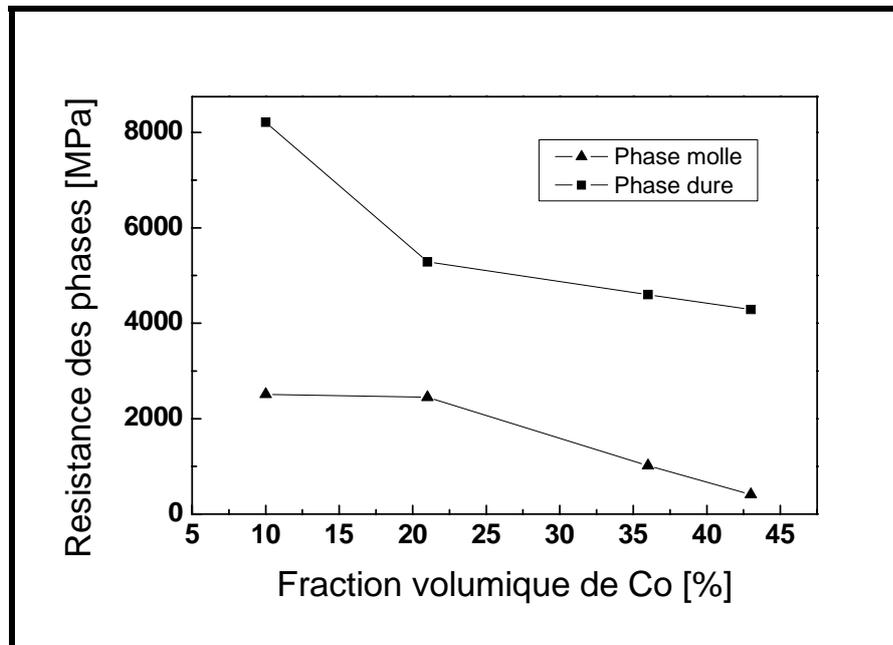


Figure.III-6 : Evolution de la résistance des phases calculée par AG en fonction de la fraction volumique de la phase molle (Co) pour le système WC-Co en compression.

III.6. Extension du modèle

Dans cette partie, nous présentons une extension du modèle dans le cas du système WC-Co en traction. Nous avons procédé à une interpolation et extrapolation du modèle, basées sur la variation de la résistance des phases.

Nous pouvons admettre, à partir de la figure III-4, que l'évolution de la résistance est linéaire sur le domaine [90% - 50%] Co. Nous avons donc essayé de trouver une loi de variation linéaire de la résistance des phases en fonction de la fraction volumique de la phase dure. Les trois points 90%, 65% et 50% de Co ne sont pas strictement sur une même droite, une correction de l'un de ces points est nécessaire. Nous avons procédé à cette correction en retraçant les courbes $[\sigma, \varepsilon]$ (Fig.III-7) :

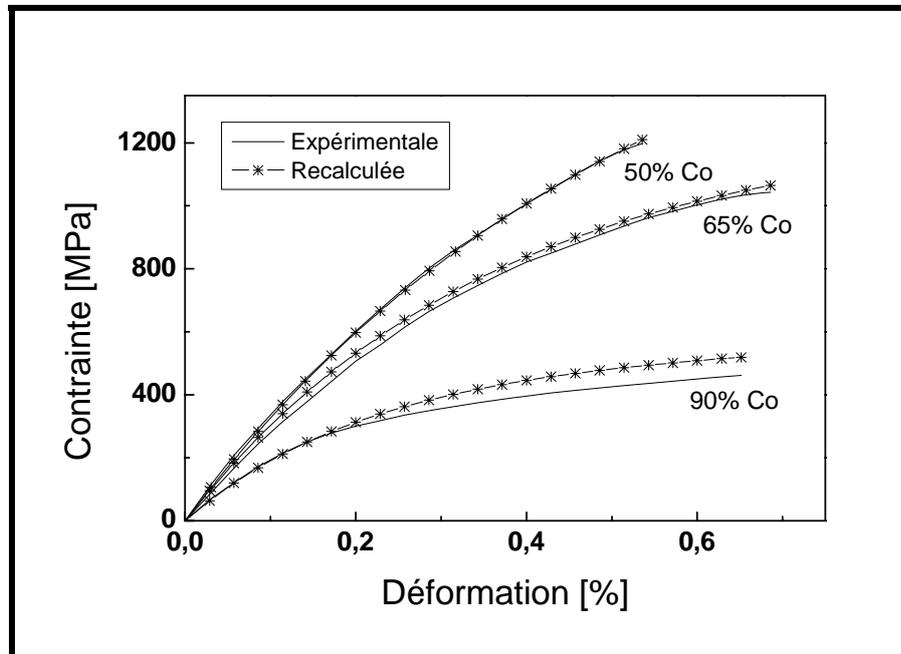


Figure.III-7 : Courbes contrainte-déformation recalculées par AG et expérimentales. Système WC-Co en traction.

- En partant des deux premiers points 90% et 65% Co, nous traçons la courbe correspondant à 50% Co, nous pouvons voir sur la figure III-7 qu'elle est en bon accord avec la courbe expérimentale.
- Si on considère les deux points 90% et 50% Co, on peut voir sur la figure III-7 que la courbe théorique correspondant à la fraction 65% Co est éloignée de la courbe expérimentale.

– De même, si on considère les deux points 65% et 50% Co, on peut voir sur la figure III-7 que la courbe théorique correspondant à la fraction 90% Co s'éloigne encore plus de la courbe expérimentale.

La loi de variation de la résistance des phases n'est donc bien vérifiée que dans le premier cas. Pour procéder à une extension du modèle, ce sont donc les deux points 90% et 65% Co qui doivent être retenus, le point 50% Co doit être corrigé. Ce résultat est significatif du point de vue physique, car la forme exponentielle est d'autant plus appropriée que l'alliage présente une grande tendance vers un palier.

En retenant les points 90% et 65% et la valeur corrigée correspondant à 50%, la loi de variation de la résistance des phases est donnée par les deux équations suivantes :

$$r(\text{MPa})=4.9604 * f(\%) + 360.4157 \quad \text{pour la phase molle,}$$

$$R(\text{MPa})=32.7944 * f(\%) + 1576.5 \quad \text{pour la phase dure.}$$

f est la fraction volumique de la phase dure.

Cette loi permet d'interpoler et d'extrapoler le modèle. La figure III-8 montre la position des courbes interpolées et extrapolées par rapport aux courbes expérimentales. On remarque que ces courbes s'accordent bien avec l'évolution du comportement expérimental.

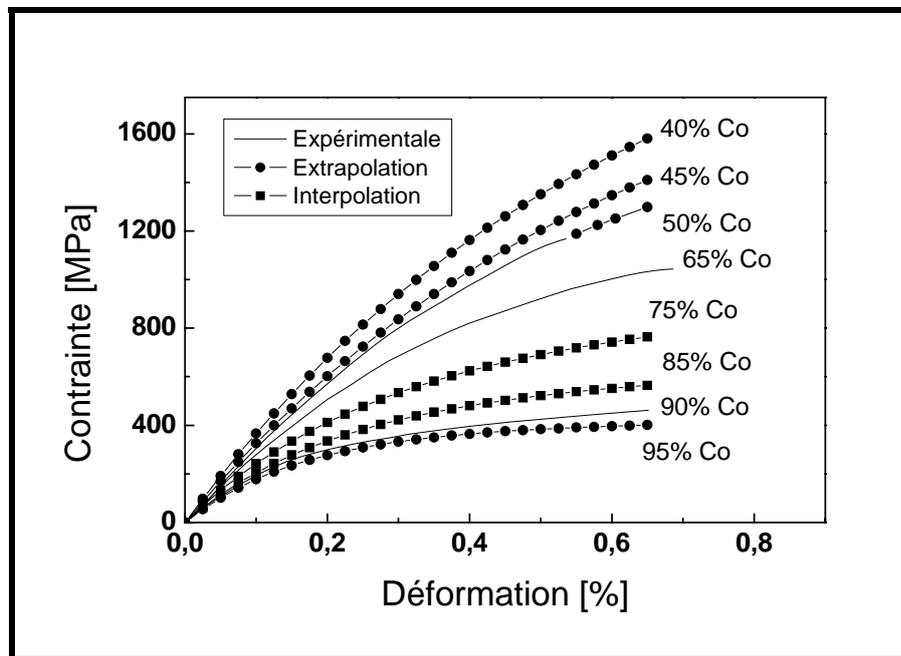


Figure.III-8 : Position des courbes interpolées et extrapolées calculées par AG dans l'évolution du comportement expérimental du système WC-Co en traction.

III.7. Discussion

La méthode d'optimisation par algorithmes génétiques a permis de construire un modèle mécanique adéquat avec un minimum d'expérimentation, à partir de quelques courbes contraintes-déformations expérimentales. Le modèle a été suffisamment optimisé et il peut être utilisé pour déterminer les courbes contraintes-déformations en fonction de la fraction volumique de la seconde phase.

La résistance des phases (optimisée) augmente avec l'augmentation de la fraction volumique de la phase dure, ce qui indique que l'impact mécanique des phases n'est pas intrinsèque, les phases constituant le matériau biphasé n'ont pas le même impact que celui qu'elles possèdent dans leurs matériaux monophasés correspondants. Cette augmentation est due à l'effet durcissement des phases, effet qui peut avoir deux origines :

- Durcissement par volume de la seconde phase, il dépend du volume occupé par cette dernière et de sa nature mécanique, il existe uniquement pour une seconde phase dure.
- Durcissement par les joints interphases entre les deux phases, il augmente avec l'augmentation de l'interface entre les deux phases, il atteint son maximum pour les fractions volumiques comparables des phases ; ce type de durcissement existe quelle que soit la nature mécanique de la seconde phase (dure ou molle).

La loi des mélanges ne peut donc être considérée que comme une première approximation, car elle ne prend en compte que l'effet volume des phases.

Quand les paramètres n_α et n_β sont optimisés à des valeurs très différentes, ceci indique qu'il y a une grande différence entre les propriétés mécaniques des phases constituantes ; i.e. une grande variation de la déformation entre les deux phases (molle et dure) et l'hypothèse d'iso-déformation a besoin d'être modifiée pour une meilleure prise en compte des caractéristiques mécaniques des phases constituantes ; on peut utiliser par exemple l'hypothèse de distribution des déformations ou une phase dure non déformable.

III.8. Conclusions

Dans cette étude, nous avons utilisé un algorithme génétique pour optimiser les paramètres du modèle à partir des courbes contraintes-déformations expérimentales numérisées. Le modèle utilisé dans cette étude (avec la forme exponentielle pour décrire la relation contraintes-déformations de chaque phase) a permis d'approximer l'évolution du comportement contrainte-déformation des alliages biphasés à matrice molle en fonction de la fraction volumique de la phase dure. La procédure des AGs a déterminé les valeurs optimales des

quatre paramètres qui représentent l'impact mécanique de chaque phase sur le comportement mécanique du matériau biphasé. L'agrément avec le comportement expérimental est très satisfaisant tant que la phase molle est dominante. Il permet également d'apprécier l'évolution de la résistance des phases en fonction de la fraction volumique de la phase dure, cette évolution est due à l'effet durcissement par volume de phase, avec l'intervention de l'effet des interfaces, qui ne peut pas être négligé devant l'effet volume. La traduction de la résistance des phases sous forme d'une loi, permet de donner une extension du modèle, qui permet de calculer les courbes contraintes-déformations pour des fractions volumiques qui n'ont pas des courbes expérimentales correspondantes.

Chapitre IV :

Prévision du comportement mécanique d'alliages biphasés de WC-Co par un modèle de réseaux de neurones.

IV.1. Introduction

Dans ce chapitre, nous décrivons le modèle de réseaux de neurones que nous avons utilisé pour prévoir le comportement contrainte-déformation en fonction de la fraction volumique de la seconde phase, des alliages biphasés de WC-Co déformés en compression et en traction, utilisés précédemment. Les données expérimentales ont été optimisées par AG, pour être utilisables comme entrées pour entraîner le réseau de neurones.

Pour faire entraîner le réseau de neurones, plusieurs fractions volumiques en Co, donnant différents comportements contrainte-déformation de l'alliage WC-Co, ont été utilisées. Les résultats de cette étude montrent qu'il existe un bon accord entre les résultats expérimentaux et les prévisions et que le réseau de neurones a une grande potentialité dans la modélisation du comportement contrainte-déformation d'alliages biphasés.

IV.2. Le réseau de neurones

Le réseau de neurones est un réseau avec des nœuds ou neurones analogues aux neurones biologiques. Les nœuds sont interconnectés à des liens de pondération [55-57]. Les poids sont ajustables et peuvent être entraînés par un processus et des exemples d'apprentissage. Il y a différentes couches interconnectées dans un réseau complexe. La figure IV-1 montre la structure d'un réseau de neurones avec plusieurs couches.

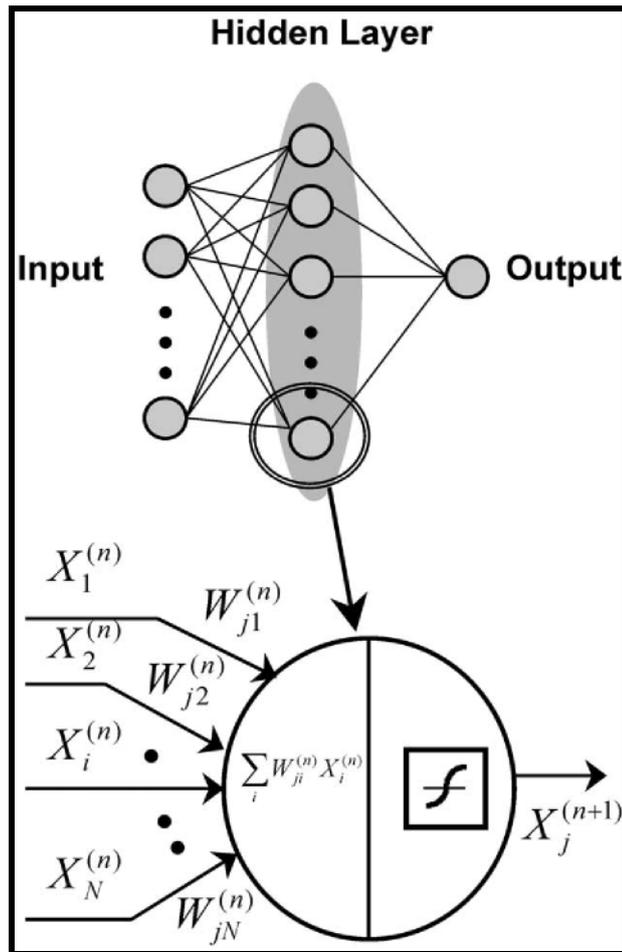


Figure.IV-1 : Description schématique d'un réseau de neurones [55].

Nous avons utilisé un réseau de neurones de type perceptron multicouches (MLP) avec un algorithme d'apprentissage de type rétro propagation. La déformation et la fraction volumique ont été utilisées comme entrées du réseau, la contrainte correspond à la sortie du réseau.

Toutes les variables utilisées ont été normalisées [58] entre 0 et 1 comme suit :

Pour la contrainte :

$$x_N = \frac{x}{x_{\max}},$$

Pour la déformation et la fraction volumique, exprimées en pourcentage (%) :

$$x_N = \frac{x}{100}.$$

Toutes les données expérimentales contrainte-déformation utilisées dans la phase apprentissage comme entrées et sorties ont été optimisées par algorithmes génétiques (cf. chapitre 3) pour avoir un pas régulier de variation du comportement expérimental, qui est nécessaire pour faire entraîner le réseau de neurones.

Dans le processus d'apprentissage, un ensemble de données, regroupant les entrées et les sorties correspondantes ; a été utilisé pour entraîner le réseau. Un algorithme itératif 'algorithme de Levenberg-Marquardt' ajuste les poids, de telle sorte que les sorties du réseau (Eq IV.1) soient les plus proches possibles des sorties désirées. Cet objectif est atteint en minimisant l'erreur d'apprentissage, définie par l'erreur quadratique moyenne (Eq IV.2).

$$y_i = f\left(\sum_{j=1}^n w_{ij}x_j + b_i\right) \quad (\text{IV.1})$$

Où :

- y_i est la sortie, x_j est l'entrée,
- f est la fonction d'activation, c'est une fonction non linéaire d'une combinaison des entrées x_j pondérées par les paramètres w_{ij} .
- w_{ij} sont les poids, ce sont des paramètres de pondération ajustables de la fonction d'activation.
- b_i est le biais, c'est un paramètre constant de correction.

$$MSE = \frac{1}{QN} \sum_{m=1}^Q \sum_{n=1}^N (d_n(m) - y_n(m))^2 \quad (\text{IV.2})$$

Où :

d est la sortie désirée, y est la sortie du réseau, Q est le nombre d'ensembles d'apprentissage et N est le nombre de sorties.

IV.3. Architecture du réseau

Le réseau que nous avons utilisé présente les caractéristiques suivantes :

- une couche d'entrée (ensemble de vecteurs de déformation et fraction volumique) ;
- une couche de sortie (contrainte) ;
- une seule couche cachée (16 neurones) ;
- la fonction d'activation est une logarithmique sigmoïde pour la couche cachée, linéaire pour la couche de sortie.

IV.4. Application des réseaux de neurones en comportement mécanique

Dans le domaine de la mécanique, un certain nombre de résultats expérimentaux est nécessaire pour développer un réseau de neurones performant, incluant son architecture, les fonctions d'apprentissage, l'algorithme d'apprentissage et les autres paramètres du réseau. Un

processus d'apprentissage et une méthode d'évaluation sont ensuite utilisés. Après avoir entraîné le réseau pour résoudre le problème basé sur ces données, de nouvelles données du même problème peuvent être introduites dans le réseau entraîné pour sortir des solutions réelles. Le processus de mise au point du réseau de neurones comporte les quatre étapes suivantes :

1. Collection de données : analyse et traitement de données.
2. Apprentissage du réseau : ceci inclut le choix de son architecture, les fonctions d'apprentissage, l'algorithme d'apprentissage et les paramètres du réseau.
3. Test du réseau entraîné, pour évaluer la performance du réseau.
4. Utilisation du réseau entraîné pour la simulation et la prévision.

IV.5. Résultats

IV.5.1. WC-Co en compression

Pour l'apprentissage du comportement contrainte-déformation de l'alliage WC-Co déformé en compression, nous avons utilisé les courbes contraintes-déformations expérimentales optimisées, des fractions volumiques en Co suivantes : 43%, 36%, 21% et 10%. Les prévisions obtenues par le réseau de neurones sont en bon accord avec les résultats expérimentaux (Fig.IV-2). Afin de tester la validité du réseau, nous avons interpolé l'application du réseau entraîné à d'autres fractions volumiques comprises entre 43% et 10% en Co. Nous avons procédé de la manière suivante : nous avons entraîné un autre réseau de neurones de la même architecture afin de déterminer le maximum de la contrainte en fonction de la fraction volumique (Fig.IV-3). Après avoir déterminé le maximum de la contrainte correspondant à chaque fraction volumique, nous avons interpolé le réseau aux fractions 40%, 30%, 25% et 15% en Co. La figure IV-4 montre la position des courbes interpolées par rapport aux courbes expérimentales, elles s'accordent bien avec l'évolution du comportement expérimental.

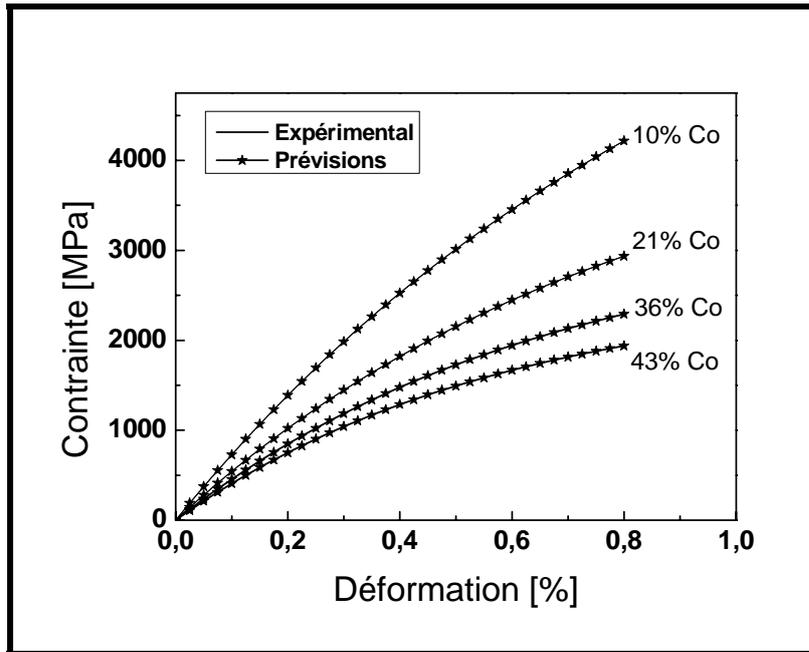


Figure.IV-2 : Prédiction par RN des courbes contrainte-déformation. Système WC-Co en compression (courbes expérimentales [51]).

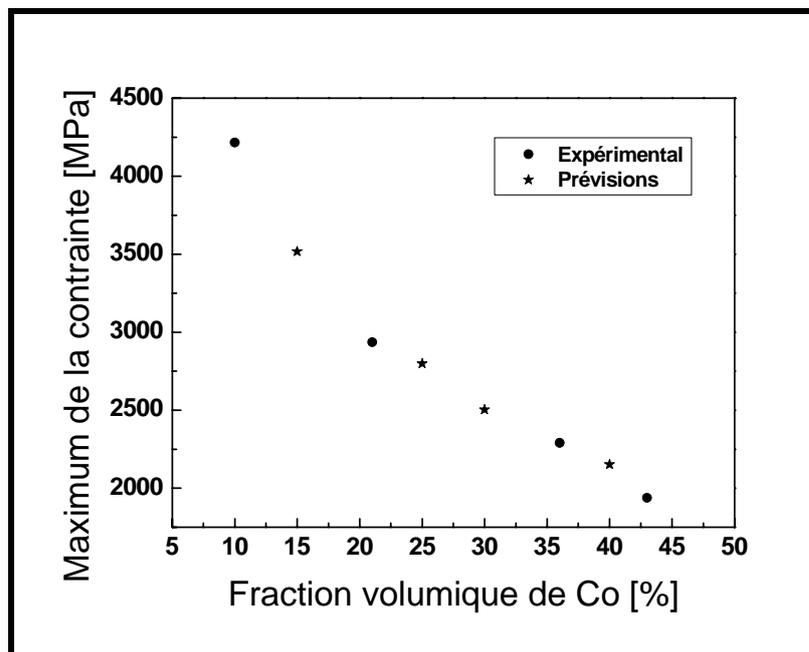


Figure.IV-3 : Prédiction par RN du maximum de contrainte en fonction de la fraction volumique de Co pour le système WC-Co en compression.

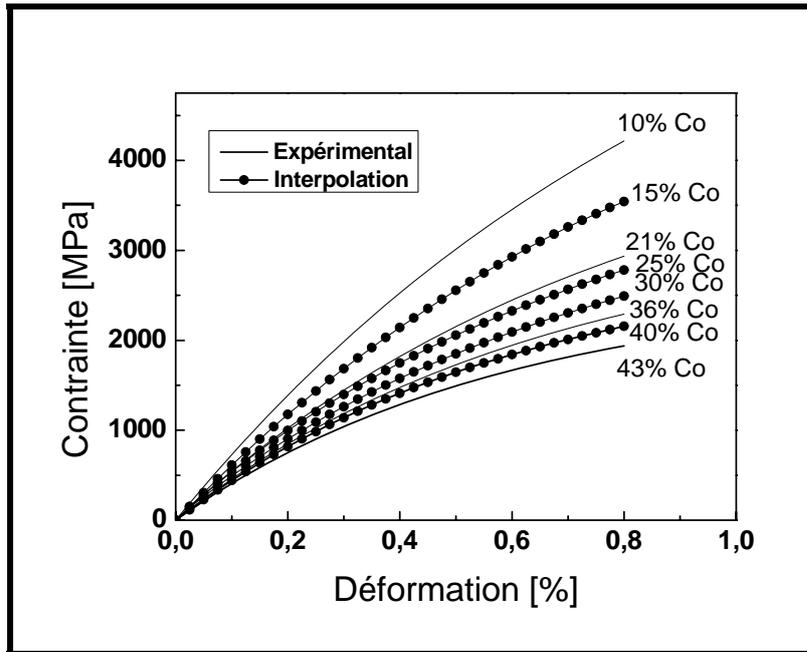


Figure.IV-4 : Position des courbes interpolées calculées par RN dans l'évolution du comportement expérimental du système WC-Co en compression (courbes expérimentales [51]).

IV.5.2. WC-Co en traction

Pour l'apprentissage du comportement contrainte-déformation de l'alliage WC-Co déformé en traction, nous avons utilisé les courbes contrainte-déformation expérimentales des fractions volumiques en Co suivantes : 90%, 85%, 75% et 65%. Les prévisions obtenues par le réseau de neurones sont en bon accord avec les résultats expérimentaux (Fig.IV-5). Afin de tester la validité du réseau, nous avons interpolé l'application du réseau entraîné à d'autres fractions volumiques comprises entre 90% et 65% en Co ; comme pour le cas en compression, nous avons entraîné un autre réseau de neurones de la même architecture afin de déterminer le maximum de la contrainte en fonction de la fraction volumique (Fig.IV-6). Après avoir déterminé le maximum de la contrainte correspondant à chaque fraction volumique, nous avons interpolé le réseau aux fractions 88%, 80%, 72% et 70% en Co. La figure IV-7 montre la position des courbes interpolées par rapport aux courbes expérimentales. Comme pour le cas en compression, elles s'accordent bien avec l'évolution du comportement expérimental.

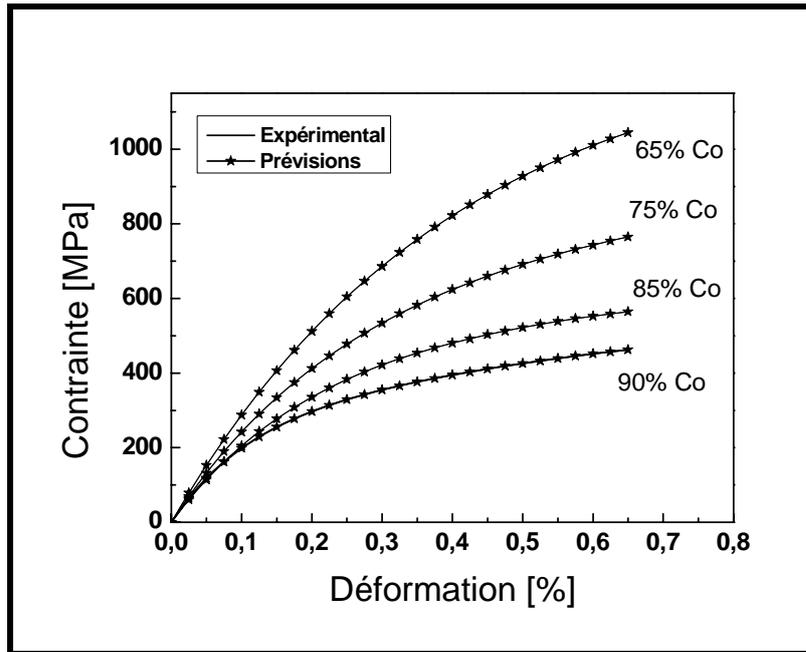


Figure.IV-5 : Prédiction par RN des courbes contrainte-déformation. Système WC-Co en traction (données expérimentales [50]).

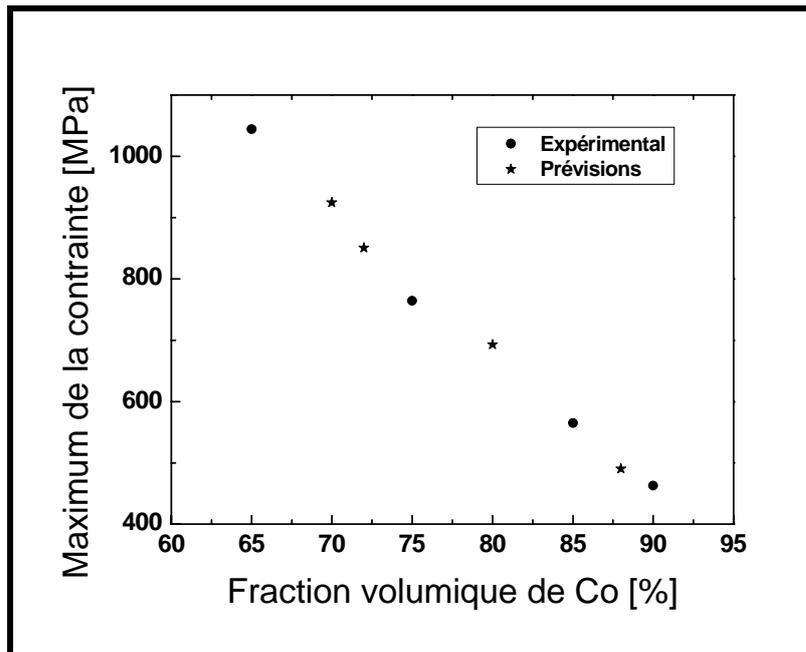


Figure.IV-6 : Prédiction par RN du maximum de contrainte en fonction de la fraction volumique de Co pour le système WC-Co en traction.

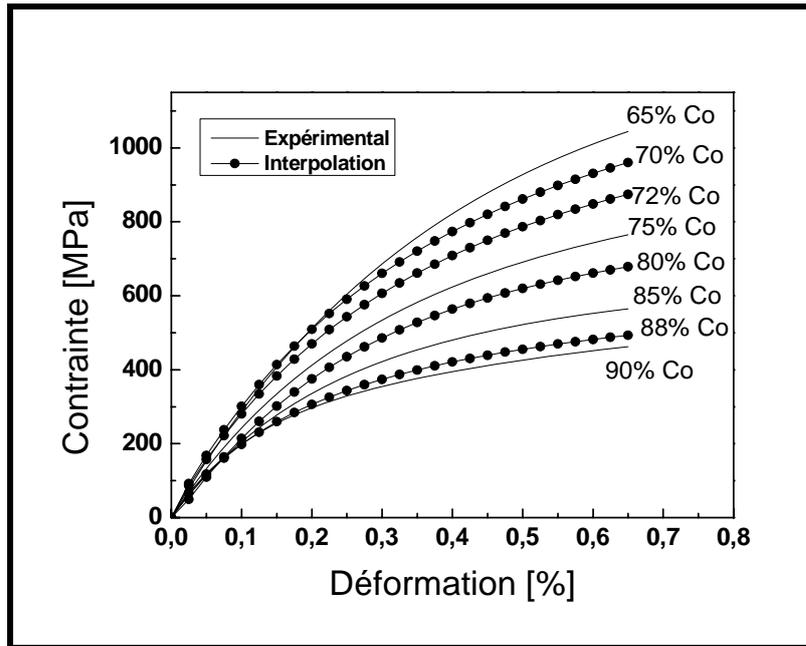


Figure.IV-4 : Position des courbes interpolées calculées par RN dans l'évolution du comportement du système WC-Co en traction (courbes expérimentales [50]).

IV.6. Discussion

- L'apprentissage est d'autant plus performant que le nombre de données expérimentales est plus grand ; après des tests, nous avons remarqué que le minimum requis pour ces deux exemples est quatre (04) fractions volumiques (c-à-d quatre courbes expérimentales).
- La similitude de l'évolution des données expérimentales utilisées dans l'apprentissage a une grande influence sur les résultats obtenus, ces derniers sont d'autant plus performants que les courbes expérimentales sont similaires.
- Pour l'alliage WC-Co en traction, nous avons utilisé les fractions 85% et 75% en Co obtenues théoriquement [54], parce que nous n'avons pas de données expérimentales pour ces deux fractions; nous n'avons pas utilisé les fractions 50% et 37% en Co à cause du manque de similarité du comportement avec les fractions 90% et 65% en Co. Nous avons retenu ces deux dernières fractions et non les deux premières, parce que nous nous intéressons au comportement mécanique d'alliages biphasés à matrice molle, c-à-d un comportement avec plateau de contrainte, ce qui justifie le choix d'une fonction non linéaire (logarithmique sigmoïde) pour la fonction d'activation de la couche cachée.

- La méthode des réseaux de neurones est limitée à l'ensemble des exemples utilisés dans la phase apprentissage, elle sert uniquement dans l'interpolation à des courbes ou des fractions limitées entre les deux bornes des exemples d'apprentissage. Le réseau entraîné peut prévoir uniquement des comportements similaires à ceux utilisés en apprentissage.
- Les résultats obtenus par la méthode des réseaux de neurones et par la méthode des algorithmes génétiques (cf. chapitre 3) sont comparables. Les deux méthodes appartiennent à la même famille des algorithmes évolutionnaires mais sont différentes dans la mise au point ; toutes deux donnent de bons résultats en prévision et en interpolation.
- Il est important de remarquer que les AG permettent d'élargir considérablement le champ d'application des réseaux de neurones. En effet, l'utilisation des réseaux de neurones nécessite d'avoir des données à variation régulière comme entrées pour la phase d'apprentissage. Les AG peuvent servir de base pour l'optimisation des données expérimentales brutes, pour avoir des données d'entrée à variation régulière. Une étape d'optimisation par les AG permet donc l'utilisation des réseaux de neurones, même si la chaîne des données expérimentales n'est pas à pas fixe. L'application des réseaux de neurones peut ainsi être envisagée dans beaucoup de domaines, sans restriction sur les données expérimentales. On peut également noter que les AG peuvent être utilisés pour optimiser les poids des réseaux de neurones eux-mêmes ; l'erreur d'apprentissage (définie par l'erreur quadratique moyenne (Eq IV.2)) de la rétro propagation de la couche cachée peut être utilisée comme fonction 'objective' d'optimisation des poids. Dans ce sens, le problème revient à trouver un ensemble de poids les mieux ajustés pour minimiser la fonction 'objective'. L'AG pourrait seulement évoluer vers l'orientation croissante de la fonction d'adaptation (fitness), par conséquent cette dernière peut être configurée avec l'inverse de la fonction 'objective' [59].

IV.7. Conclusions

Nous avons utilisé un réseau de neurones pour prévoir le comportement mécanique des matériaux biphasés du système WC-Co à partir de données expérimentales de contrainte-déformation. La méthode utilisée a permis d'obtenir une bonne approximation de l'évolution du comportement contrainte-déformation des matériaux biphasés WC-Co en fonction de la fraction volumique de Co. L'accord avec le comportement expérimental est très satisfaisant

quand les courbes expérimentales utilisées comme données d'entrée présentent une bonne similarité de comportement. L'utilisation des AG pour optimiser les données expérimentales numérisées utilisées en entrée du réseau de neurones a considérablement amélioré la performance de ce dernier. Cette étude du comportement mécanique d'alliages biphasés optimisé par AG a montré la capacité des réseaux de neurones pour prévoir le comportement contrainte-déformation d'alliages biphasés de WC-Co en fonction de la fraction volumique de Co.

Conclusions et Perspectives

Cette étude est une contribution dans la prévision et l'optimisation du comportement mécanique d'alliages biphasés de WC-Co. Nous avons considéré l'évolution des courbes contrainte-déformation d'alliages biphasés de WC-Co en fonction de la fraction volumique de la seconde phase.

Dans une première partie, nous présentons une méthode d'optimisation par Algorithmes Génétiques du comportement mécanique d'alliages biphasés à matrice molle de WC-Co. Nous avons optimisé les paramètres mécaniques du modèle à partir des courbes contrainte-déformation expérimentales numérisées. Le modèle mis au point dans cette étude est fondé sur des notions de la mécanique des milieux continus, la répartition des phases est supposée homogène. Le modèle est basé sur une hypothèse d'iso-déformation, la contrainte est supposée distribuée suivant la loi des mélanges. La relation contrainte-déformation de chaque phase est exprimée sous une forme exponentielle, avec deux paramètres pour chaque phase, le premier exprime la résistance de chaque phase, le second exprime l'ajustement des phases vers un comportement en palier.

Nous avons employé la forme exponentielle car elle est plus appropriée que la forme pseudo-linéaire pour la description du comportement d'alliages biphasés à matrice molle, qui présentent expérimentalement une allure avec palier.

La méthode d'optimisation par Algorithmes Génétiques a permis de déterminer les valeurs optimales des quatre paramètres du modèle qui représentent l'impact mécanique de chaque phase sur le comportement mécanique du matériau biphasé. Les prévisions théoriques issues de cette méthode sont en bon accord avec les résultats expérimentaux.

Dans une deuxième partie, nous présentons un modèle de Réseaux de Neurones pour la prévision de l'évolution des courbes contrainte-déformation. Nous utilisons comme entrées les courbes numérisées et optimisées par Algorithmes Génétiques d'alliages biphasés de WC-Co déformés en compression et en traction. Pour faire entraîner le Réseau de Neurones, plusieurs fractions volumiques en Co, donnant différents comportements similaires en contrainte-déformation de l'alliage WC-Co, ont été utilisées.

Le modèle de Réseaux de Neurones a permis d'obtenir une bonne approximation de l'évolution du comportement contrainte-déformation des matériaux biphasés WC-Co en fonction de la fraction volumique de Co. L'accord avec le comportement expérimental est très

satisfaisant quand les courbes expérimentales utilisées comme données d'entrée présentent une bonne similarité de comportement.

A partir du tracé de courbes de résistance obtenues par optimisation en utilisant les Algorithmes Génétiques, nous avons montré que l'influence des propriétés mécaniques de chaque phase sur le comportement de l'alliage biphasé n'est pas intrinsèque, elle évolue avec l'évolution de la fraction volumique et la répartition morphologique de la seconde phase.

Pour apprécier l'influence des propriétés mécaniques de chaque phase sur le comportement de l'alliage biphasé, nous avons utilisé la loi des mélanges. Cette approche doit être considérée comme une première approximation, car elle ne tient compte que de l'effet volume. L'effet interface est important et doit être pris en considération dans une étude approfondie.

Par ailleurs, les deux phases, dure ou molle, se durcissent dans un alliage biphasé, ce durcissement augmente avec l'augmentation de la fraction volumique de la phase dure, ce qui se traduit par l'augmentation de la résistance des phases avec l'augmentation de la fraction volumique de la phase dure.

A partir de la variation de la résistance des phases obtenue par la méthode proposée, nous avons déterminé une loi de variation de la résistance dans chaque phase, cette dernière varie linéairement avec la fraction volumique de la phase dure. En se basant sur cette loi, nous avons interpolé et extrapolé le modèle à différentes fractions volumiques, les résultats obtenus s'accordent bien avec l'évolution du comportement expérimental.

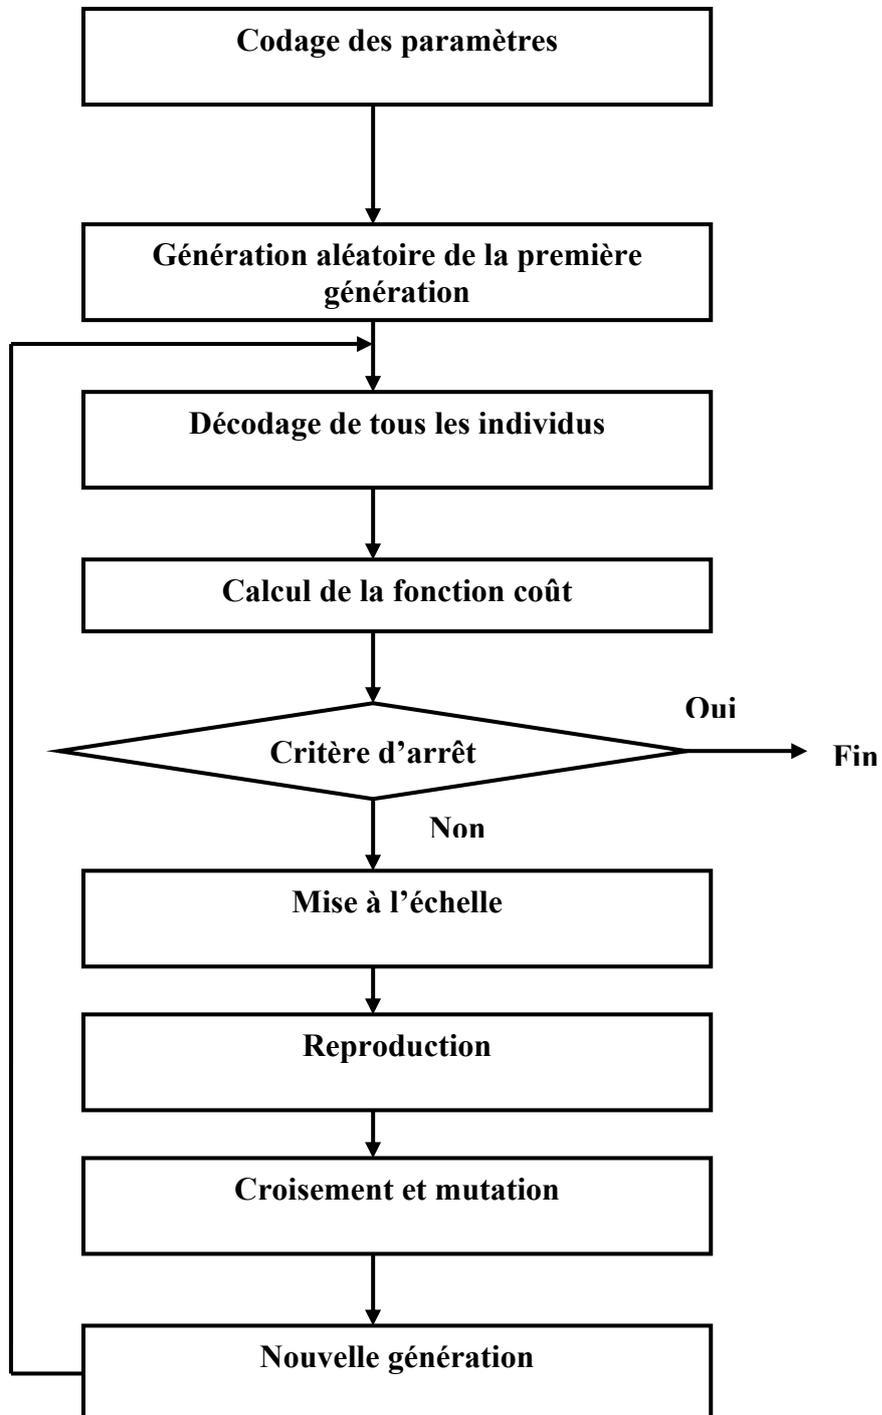
Cette étude de prévision du comportement mécanique par les Algorithmes Génétiques et les Réseaux de Neurones ouvre la voie à de nombreuses perspectives, comme suite à notre étude sur le comportement des matériaux biphasés. Nous proposons une combinaison des deux méthodes, l'utilisation des Algorithmes Génétiques pour l'optimisation des poids des Réseaux de Neurones permet d'élargir le champ des données expérimentales exploitables. On peut ainsi obtenir une meilleure prévision du comportement mécanique [59].

Les Algorithmes Génétiques et les Réseaux de Neurones constituent des outils d'investigation puissants pour différents domaines d'application en Sciences des Matériaux, ces méthodes connaissent actuellement un essor considérable dans le domaine de l'optimisation et la prévision de comportement grâce à leur universalité, fiabilité et robustesse.

Annexe A

Application des Algorithmes Génétiques

A.1. Organigramme de l'AG



Organigramme de l'AG

A.2. Utilisation de l'AG pour l'obtention des courbes $\sigma - \varepsilon$

Pour l'obtention des courbes $\sigma - \varepsilon$ à l'aide de l'AG, nous avons procédé comme suit :

1. Entrée des points expérimentaux des courbes $\sigma - \varepsilon$.
2. Analyse de l'allure expérimentale des courbes pour le choix de la fonction appropriée : dans notre cas, nous avons retenu la fonction exponentielle parce que l'allure de la courbe présente un palier.
3. Définition des intervalles de recherche des constantes de la fonction $(n_\alpha, n_\beta, k_\alpha, k_\beta)$ (cf.III.3.2).
4. Traitement des populations générées à partir de la population initiale (aléatoire), en restant dans les intervalles de recherche.

Le fonctionnement de l'AG (partant de la dernière étape) se fait de la manière suivante :

Initialement une première génération sera multipliée d'une manière aléatoire, cette génération contient N individus qui représentent les paramètres de la fonction $(n_\alpha, n_\beta, k_\alpha, k_\beta)$. Chaque individu est codé selon un code binaire, ensuite un décodage aura lieu pour la détermination des paramètres de la fonction, les trois opérateurs de la génétique tels que la reproduction, le croisement et la mutation vont intervenir pour la création de la nouvelle génération. Lorsque cette opération est achevée (reproduction, croisement et mutation), la population finale contient le double de la population initiale, ce qui induit l'intervention de la sélection finale pour avoir le même nombre d'individus, cette sélection est faite par compétition entre parents et enfants. C'est cette compétition entre parents et enfants qui va donner la population la plus performante et la mieux adaptée des paramètres de la fonction $(n_\alpha, n_\beta, k_\alpha, k_\beta)$.

Les paramètres de fonctionnement de l'AG sont :

1. Les intervalles de recherche

Pour les paramètres n_α et n_β les intervalles sont de 0.1 à 1.

Les paramètres k_α et k_β sont des intervalles autour de la limite élastique de chaque phase α et β , ces derniers varient avec la variation de la fraction volumique de la seconde phase.

2. Les paramètres génétiques

Après adaptation des différentes fonctions, nous avons retenu les paramètres cités dans le tableau III.1 (cf.III.4).

3. Le critère d'arrêt

Le critère d'arrêt que nous avons choisi est de type générationnel, c'est-à-dire qu'on fixe un nombre maximal de générations ; dans notre cas, nous avons fixé ce nombre à 60 générations, la convergence de l'algorithme a lieu entre 30 à 40 générations (cf.Fig.III-2).

Annexe B

Application des Réseaux de Neurones

B.1. Choix de l'architecture du réseau

Le réseau de neurones que nous avons choisi présente les caractéristiques suivantes :

- Une couche d'entrée, dans laquelle nous présentons les entrées, qui sont les déformations et les fractions volumiques, sous forme de vecteurs de taille 33 pour le cas de la compression et de taille 27 pour le cas de la traction.
- Une couche de sortie, dans laquelle nous présentons les sorties, qui sont les contraintes, sous forme de vecteurs de même taille que les déformations.
- Apprentissage du réseau : pour faire entraîner le réseau, nous avons utilisé un algorithme itératif de rétro-propagation ; nous avons utilisé quatre fractions volumiques comme exemples d'apprentissage, c'est-à-dire quatre vecteurs de déformations et de contraintes.
- Une seule couche cachée, constituée de 16 neurones.
- La fonction d'activation pour la couche cachée est une logarithmique sigmoïde, elle a la forme suivante :

$$f(x) = \frac{1}{1 + e^{-x}}$$

- La fonction d'activation pour la couche de sortie est linéaire, elle a la forme suivante :

$$f(x) = x$$

B.2. Choix du nombre de neurones dans la couche cachée Le tableau B-1 montre que le minimum de l'erreur quadratique moyenne (MSE) correspond au nombre de 16 neurones, ce qui justifie notre choix du nombre 16 dans la couche cachée.

Nombre de neurones	Erreur quadratique moyenne (MSE)
2	202.7287
4	0.2261
6	0.0013
8	0.0082
10	2.9047E-5
12	3.1902E-5
14	3.3057E-6
16	2.8471E-6
18	1.8146E-4
20	9.2306E-5
22	9.7610E-6

Tableau.B-1 : Erreur quadratique moyenne (MSE) en fonction du nombre de neurones dans la couche cachée.

B.3. Critère d'arrêt

Le critère d'arrêt que nous avons choisi est le nombre maximum d'époques (itérations), nous avons retenu un nombre égal à 2000.

B.4. Estimation de l'erreur

La figure ci-dessous (Fig. B-1) montre la variation de l'erreur quadratique moyenne normalisée en fonction du nombre d'époques pour le cas du système WC-Co en compression. On remarque qu'à partir de 1400 époques, l'erreur commence à se stabiliser, ce qui justifie que le choix du nombre de 2000 époques est largement suffisant pour l'apprentissage du réseau.

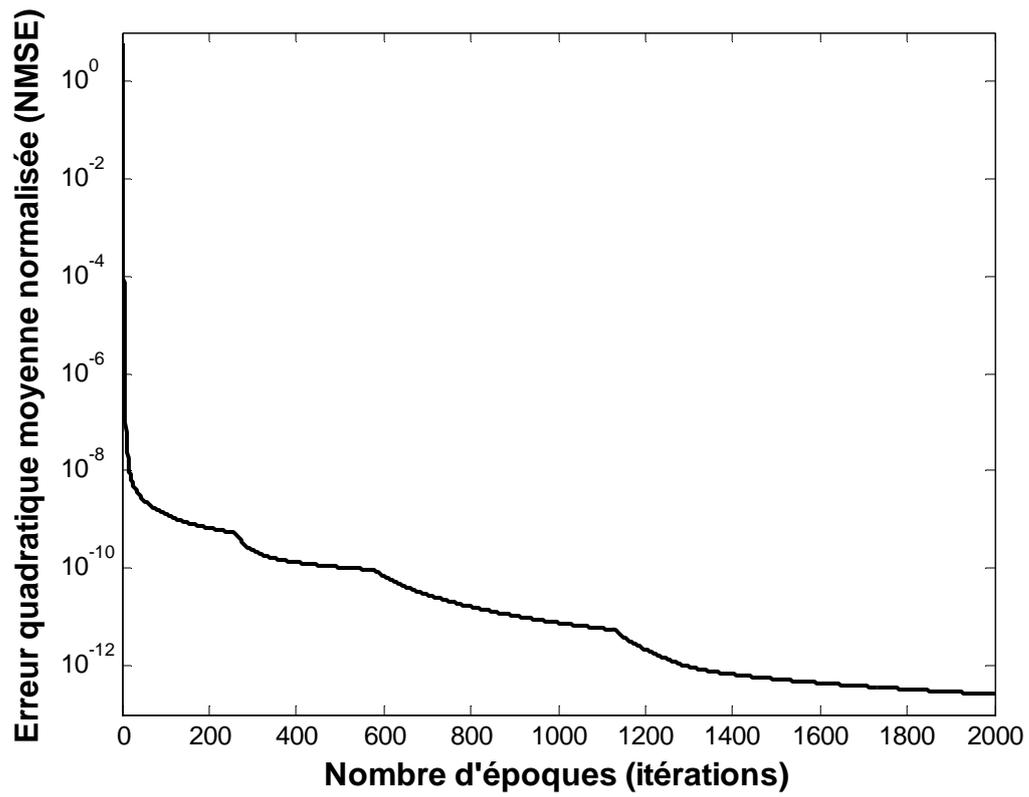


Figure.B-1 : Erreur quadratique moyenne normalisée en fonction du nombre d'époques (itérations) pour le cas du système WC-Co en compression.

Bibliographie

- [1]. D. E. Goldberg, 'Algorithmes Génétiques : exploration, optimisation et apprentissage automatique', Traduction de l'anglais (américain) par Vincent Corruble, Addison-Wesley France, 1994.
- [2]. L. Dridi, 'Développement et validation d'une approche de remplacement des conduites pour les réseaux d'eau potable', Thèse de doctorat, INRS-Eau, Terre et Environnement, Québec, Canada, 2005.
- [3]. J. Holland, 'Adaptation in Natural and Artificial Systems', Ann Arbor, University of Michigan Press, 1975.
- [4]. B. J. Reardon, 'Optimization of micromechanical densification modeling parameters for copper powder using a fuzzy logic based multiobjective genetic algorithm', Los Alamos National Laboratory Unclassified Report, LA-UR-98-0419, 1998.
- [5]. B. J. Reardon, S. R. Bingert, 'Inversion of tantalum micromechanical powder consolidation and sintering models using Bayesian inference and genetic algorithms', Acta Mater. 48: 647-658, 2000.
- [6]. Z. Michalewicz, K. Deb, M. Schmidt, T. H. Stidsen, 'Evolutionary algorithms for engineering applications', pp.73-94. Dans: 'Evolutionary algorithms in engineering and computer science: recent advances in genetic algorithms, evolution strategies, evolutionary programming, genetic programming and industrial applications'. Edité par: M. Makela, K. Miettinen, P. Neittaanmaki, J. Periaux, Chichester, New York, Wiley, 1999.
- [7]. C. Coello, A. Carlos, D. A. Van Veldhuizen, G. B. Lamont, 'Evolutionary Algorithms for Solving Multi-Objective Problems', Kluwer Academic Publishers, New York, 2002.
- [8]. K. Deb, 'Introduction to selection'. Dans: 'Evolutionary computation 1: advanced algorithms and operators'. Édité par: T. Bäck, D. B. Fogel, Z. Michalewicz, Institute of Physics Publishing, Bristol and Philadelphia, 2000.
- [9]. K. De Jong, 'An analysis of the behaviour of a class of genetic adaptive systems', PhD thesis, University of Michigan, 1975.
- [10]. W. B. Langdon, 'Genetic programming and data structures: genetic programming + data structures = automatic programming!', Boston, Kluwer Academic Publishers, 1998.
- [11]. C. Ryan, 'Automatic Re-Engineering of Software using Genetic Programming', Kluwer Academic Publishers, 2000.
- [12]. M. Cerrolaza, W. Annicchiarico, 'Genetic algorithms in shape optimization: finite and boundary element applications', pp.283-323. Dans: 'Evolutionary algorithms in engineering

- and computer science: recent advances in genetic algorithms, evolution strategies, evolutionary programming, genetic programming and industrial applications'. Édité par: M. Makela, K. Miettinen, P. Neittaanmaki, J. Periaux, Chichester, New York, Wiley, 1999.
- [13]. G. Dreyfus, J. M. Martinez, M. Samuelides, M. B. Gordon, F. Badran, S. Thiria, L. Héroult, 'Réseaux de neurones: méthodologie et applications', Eyrolles, France, 2004.
- [14]. G. Dreyfus, 'Les réseaux de neurones', Mécanique Industrielle et Matériaux, N° 5, Septembre, 1998.
- [15]. W. McCulloch and W. Pitts, 'A logical calculus of the ideas immanent in nervous activity', Bulletin of Mathematical Biophysics, 5: 115-133, 1943.
- [16]. F. Rosenblatt, 'The Perceptron: a probabilistic model for information storage and organization in the brain', Psychological Review, 65: 386-408, 1958.
- [17]. M. Minsky, S. Papert, 'Perceptrons', Expanded Edition. MIT Press, 1988.
- [18]. J. J. Hopfield, 'Neural networks and physical systems with emergent collective computational abilities', Proceedings of the National Academy of Sciences, 79: 2554-2558, 1982.
- [19]. D. Rumelhart, G. Hinton, R. Williams, 'Learning internal representations by error propagation', Parallel Distributed Processing, Vol. 1, D. Rumelhart and J. McClelland Eds, Cambridge: MIT Press, pp. 318-362, 1986.
- [20]. C. Bishop, 'Neural Networks for Pattern Recognition', Oxford University Press, 1995.
- [21]. W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery, 'Numerical Recipes in C: the Art of Computing', Cambridge University Press, 1992.
- [22]. O. Nerrand, P. Roussel-Ragot, L. Personnaz, G. Dreyfus, 'Neural networks and nonlinear adaptive filtering: unifying concepts and new algorithms', Neural Computation, Vol.5, pp. 165-199, 1993.
- [23]. W. Chen, P. Garder, 'Word level discriminative training for handwritten word recognition', Proc. 7th IWFHR, pp. 393-402, Amsterdam, 2000.
- [24]. H. Bunke, M. Roth, E. G. Schukat-Talamazzini, 'Off-line cursive handwriting recognition using hidden markov models', Pattern Recognition, Vol. 28, N° 9, pp. 1399-1413, 1995.
- [25]. H. A. Beghdadi, M. Senouci, 'Réseaux de neurones : théorie et pratique', Office des Publications Universitaires, Algérie, 2005.
- [26]. K. Hornik, M. Stinchcombe, H. White, 'Multilayer Feedforward Networks are Universal Approximators', Neural Networks, Vol. 2, pp. 359-366, 1989

- [27]. K. Hornik, M. Stinchcombe, H. White, P. Auer, 'Degree of approximation results for feedforward networks approximating unknown mappings and their derivatives', *Neural Computation*, Vol. 6, pp. 1262-1275, 1994.
- [28]. D. Urbani, P. Roussel-Ragot, L. Personnaz, G. Dreyfus, 'The selection of neural models of nonlinear dynamical systems by statistical tests', *Neural Networks for Signal Processing I*, pp. 229-237, IEEE Press, 1994.
- [29]. L. Durand, 'Models of tensile behaviour of two-phase alloys from their components', *Materials Science and Technology*, Vol. 3, pp. 105-109, February, 1987.
- [30]. S. T. Mileiko, 'The tensile strength and ductility of continuous fiber composites', *J. Mater. Sci* 4: 974-977, 1969.
- [31]. G. Garmond, R. B. Thompson, 'A theory for the mechanical properties of metal-matrix composites at ultimate loading', *Met. Trans* 4: 863-873, 1973.
- [32]. P. R. Rios, J. R. C. Guimarães, K. K. Chawla, 'Modelling the stress-strain curves of dual phase steels', *Scripta. Met*, Vol. 15, pp. 899-904, 1981.
- [33]. D. A. Korzekwa, R. D. Lawson, D. K. Matlock, G. Krauss, 'A consideration of models describing the strength and ductility of dual-phase steels', *Scripta. Met*, Vol. 14, pp. 1023-1028, 1980.
- [34]. J. H. Hollomon, 'Tensile deformation', *Trans. AIME* 162: 268, 1945.
- [35]. K. Araki, Y. Takada, K. Nakoka, 'Work hardening of continuously annealed dual phase steels', *Trans. ISIJ* 17: 710-717, 1977.
- [36]. G. R. Speich, R. L. Miller, 'Structures and Properties of Dual-Phase Steels', (R. A. Kot, J. W. Morris, Ed.), TMS-AIME, New York, pp. 145-182, 1979.
- [37]. L. M. Brown, W. M. Stobbs, 'Work Hardening of Copper Silica: The Role of Plastic Relaxation', *Phil. Mag*, Vol. 23, pp. 1201-1233, 1971.
- [38]. M. F. Ashby, 'Strengthening Methods in Crystals', (A. Kelly, R. B. Nicholson, Eds), Elsevier Publishing Co, p. 137, 1971.
- [39]. L. F. Ramos, D. K. Matlock, G. Krauss, 'On the deformation behavior of dual-phase steels', *Met. Trans*, Vol. 10A, pp. 259-261, 1979.
- [40]. J. D. Eshelby, 'The determination of the elastic field of an ellipsoidal inclusion, and related problems', *Proc. Roy. Soc*, A241, pp. 376-396, 1957.
- [41]. M. Berveiller, A. Zaoui, 'Comportements rhéologiques et structure des matériaux', 175, Paris, Groupe Français de Rhéologie, 1980.

- [42]. L. Durand, 'Méthode Autocohérente Adaptée à la Traction de Matériaux Biphasés à Grains Allongés: Modèle à Matrice Orthotrope', *Mém. Et. Sci. Rev. Mét.*, 85, N° 3, pp. 167-174, 1988.
- [43]. C. Thomas de Montpreville, 'Modèles tridimensionnels pour le calcul des comportements mécaniques des alliages polyphasés', *Res. Mechanica* 7 : 211-230, 1983.
- [44]. M. H. Poech, H. Fischmeister, R. Spiegler, 'Deformation and fracture of two-phase materials', Max-Planck-Inst Fuer Metallforschung, Stuttgart (Germany F R), 1998.
- [45]. H. C. Kim, D. Y. Oh, I. J. Shon, 'Synthesis of WC and dense WC-xvol%Co hard materials by high-frequency heated combustion method', *Int. J. Refractory Metals and Hard Materials*, 22, pp. 41-49, 2004.
- [46]. D. Mari, 'Déformation à haute température des composites WC-Co', Thèse de doctorat en sciences, Lausanne, EPFL, 1991.
- [47]. M. H. Poech, H. F. Fischmeister, 'Deformation of two-phase materials: a model based on strain compatibility', *Acta metall. mater*, Vol. 40, N° 3, pp. 487-494, 1992.
- [48]. H. C. Kim, I. K. Jeong, I. J. Shon, I. Y. Ko, J. M. Doh, 'Fabrication of WC-8% wt.%Co hard materials by two rapid sintering processes', *Int. J. Refractory Metals and Hard Materials*, 25, pp. 336-340, 2007.
- [49]. S. Okamoto, Y. Nakazono, K. Ostuka, Y. Shimoitani, J. Takada, 'Mechanical properties of WC/Co cemented carbide with larger WC grain size', *Materials Characterization*, 55, pp. 281-287, 2005.
- [50]. C. Nishimatsu, J. Gurland, 'Experimental survey of the deformation of the hard-ductile two-phase alloy system WC-Co', *Trans. Am. Soc. Metals* 52: 469, 1960.
- [51]. H. Doi, Y. Fujiwara, K. Miyake, 'Mechanism of plastic deformation and dislocation damping of cemented carbides', *Trans. Metall. Soc. A. I. M. E* 245: 1457, 1969.
- [52]. E. Voce, 'The relationship between stress and strain for homogeneous deformation', *J. Inst. Metals* 74: 537, 1948.
- [53]. R. Taouche, 'Modélisation de la déformation d'alliages biphasés à matrice molle', Mémoire de Magister, Université Mentouri Constantine, Algérie, 2001.
- [54]. R. Taouche, N. Rouag, 'Optimization of stress-strain behavior parameters by genetic algorithms method: Application to soft-matrix two-phase alloys', *Computational Mechanics*, 30, pp. 297-302, 2003.
- [55]. Z. Zhang, K. Friedrich, 'Artificial neural networks applied to polymer composites: a review', *Composites Science and Technology*, 63, pp. 2029-2044, 2003.

- [56]. A. Bahrami, S. H. Mousavi Anijdan, A. Ekrami, 'Prediction of mechanical properties of DP steels using neural network model', *Journal of Alloys and Compounds*, 392, pp. 177-182, 2005.
- [57]. R. Koker, N. Altinkok, A. Demir, 'Neural network based prediction of mechanical properties of particulate reinforced metal matrix composites using various training algorithms', *Materials and Design*, 28, pp. 616-627, 2007.
- [58]. M. A. Yescas, H. K. D. H. Bhadeshia, D. J. Mackay, 'Estimation of the amount of retained austenite in austempered ductile irons using neural networks', *Materials Science and Engineering A*, 311, 162-173, 2001.
- [59]. W. Liu, Q. Liu, F. Ruan, Z. Liang, H. Qiu, 'Springback prediction for sheet metal forming based on GA-ANN technology', *J. Mater. Process. Tech*, Vols. 187-188, pp. 227-231, 2007.

التنبؤ بالسلوك الميكانيكي لسبائك ثنائية الطور بواسطة الخوارزميات الوراثة والشبكات العصبية. تطبيق على الجمل WC-Co

ملخص

هذا العمل هو مساهمة في دراسة السلوك الميكانيكي للمواد ثنائية الطور. نهتم بالتنبؤ و بتحسين منحنيات إجهاد-تشوه لسبائك ثنائية الطور WC-Co بدلالة النسبة الحجمية Co. نقترح طريقة تحسين بواسطة الخوارزميات الوراثة للوسائط الميكانيكية لنموذج مبني على مفاهيم ميكانيك الأوساط المستمرة المتجانسة. و هو قائم على شرط تساوي التشوه، بفرض أن الإجهاد موزع حسب قانون الخلائط. سمحت طريقة التحسين هذه بتحديد القيم الأكثر تحسينا للأربعة وسائط للنموذج التي تمثل التأثير الميكانيكي لكل طور على السلوك الميكانيكي للمادة ثنائية الطور. قورنت منحنيات الإجهاد-التشوه، المحسوبة باستعمال هذه الطريقة المقترحة مع المنحنيات التجريبية و وجد إتفاق جيد بينهما. ترتفع مقاومة الأطوار مع إرتفاع النسبة الحجمية للطور القاسي. يكون تأثير الخصائص الميكانيكية لكل طور على السلوك الميكانيكي لسبيكة ثنائية الطور غير ذاتي، وبالتالي فقانون الخلائط ما هو إلا تقريب أولي. سمح قانون خطي لتغير مقاومة الأطوار باستكمال داخلي و خارجي للنموذج، و لقد وجد إتفاق جيد مع تطور السلوك التجريبي. من جهة ثانية، نقترح نمودجا للشبكات العصبية للتنبؤ بتطور منحنيات إجهاد-تشوه مرقمنة و محسنة بواسطة الخوارزميات الوراثة بدلالة النسبة الحجمية Co للمواد ثنائية الطور WC-Co مشوهة بالإنضغاط و بالشد. عملية تحسين المعطيات التجريبية بواسطة الخوارزميات الوراثة تحسن بصفة معتبرة جودة الشبكات العصبية. سمح هذا النموذج بالحصول على تقريب جيد للسلوك التجريبي. يكون الإتفاق مع السلوك التجريبي جد مرض متى كانت المنحنيات التجريبية المستعملة كمعطيات في المدخل تتميز بتشابه كبير في السلوك.

الكلمات الدلالية

الخوارزميات الوراثة ؛ الشبكات العصبية ؛ المواد ثنائية الطور ؛ الطور الثاني ؛ النسبة الحجمية ؛ WC-Co ؛ التشوه ؛ الإجهاد ؛ قانون الخلائط ؛ مقاومة.

Sujet

PREVISION DU COMPORTEMENT MECANIQUE D'ALLIAGES BIPHASES PAR ALGORITHMES GENETIQUES ET RESEAUX DE NEURONES.

APPLICATION AUX SYSTEMES WC-Co

Résumé

Ce travail est une contribution à l'étude du comportement mécanique des matériaux biphasés. Nous nous intéressons à la prévision et à l'optimisation des courbes contrainte-déformation d'alliages biphasés de WC-Co en fonction de la fraction volumique de Co. Nous proposons une méthode d'optimisation par Algorithmes Génétiques des paramètres mécaniques d'un modèle fondé sur les notions de la mécanique des milieux continus homogènes. Il est basé sur une condition d'iso-déformation, la contrainte est supposée distribuée suivant la loi des mélanges. Cette méthode d'optimisation a permis de déterminer les valeurs optimales des quatre paramètres du modèle qui représentent l'impact mécanique de chaque phase sur le comportement mécanique du matériau biphasé. Les courbes contrainte-déformation calculées à l'aide de la méthode proposée sont comparées aux courbes expérimentales, un bon accord a été trouvé. La résistance des phases augmente avec l'augmentation de la fraction volumique de la phase dure. L'influence des propriétés mécaniques de chaque phase sur le comportement de l'alliage biphasé n'est pas intrinsèque, la loi des mélanges n'est donc qu'une première approximation. Une loi linéaire de la variation de la résistance des phases a permis d'interpoler et d'extrapoler le modèle, un bon accord a été trouvé avec l'évolution du comportement expérimental. Dans une deuxième partie, nous proposons un modèle de Réseaux de Neurones pour la prévision de l'évolution des courbes contrainte-déformation numérisées et optimisées par Algorithmes Génétiques en fonction de la fraction volumique de Co des matériaux biphasés de WC-Co déformés en compression et en traction. L'optimisation des données expérimentales par Algorithmes Génétiques améliore considérablement la performance des Réseaux de Neurones. Ce modèle a permis d'obtenir une bonne approximation de l'évolution du comportement expérimental. L'accord avec le comportement expérimental est très satisfaisant quand les courbes expérimentales utilisées comme données d'entrée présentent une bonne similarité de comportement.

Mots-clés

Algorithmes Génétiques ; Réseaux de Neurones ; Matériaux biphasés ; Seconde phase ; Fraction volumique ; WC-Co ; Déformation ; Contrainte ; Loi des mélanges ; Résistance.