



**MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR
ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITÉ « Abbès LAGHROUR » DE KHENCHELA
FACULTÉ DES SCIENCES ET DE TECHNOLOGIE**



Département de Génie Mécanique

Mémoire de fin d'études

Pour l'obtention du diplôme de Master (L.M.D)

Spécialité : Génie Mécanique

Option : Génie des Matériaux

**PREDICTION DES CONTRAINES
D'ÉCOULEMENT D'UN ACIER MICROALLIÉ
PAR APPROCHE NEURONALE**

Réalisé par :

- ***AZZEB Aymen***
- ***ABDERREZAK Bachir***

Membres de jury :

<i>Dr. ABBOUDI Abdelaziz</i>	<i>M.C.A.</i>	<i>Président</i>
<i>Mr. BERKIA Abdelhak</i>	<i>M.A.A.</i>	<i>Examineur</i>
<i>Dr. ALLAOUI Abdelhalim</i>	<i>M.C.B.</i>	<i>Rapporteur</i>

ANNEE UNIVERSITAIRE 2019 -2020



Résumé



ملخص

بعد تحديد منحنيات الإجهاد كدالة تشوه لمعدلات تشوه مختلفة ودرجات حرارة مختلفة ، فإن الهدف الأول هو دراسة سلوك السبيكة $CMn(Nb-Ti-V)$ وتحديد المعلمات الريولوجية المختلفة باستخدام نموذج $Arrhenius$ معدل، والتي من شأنها تحديد قانون سلوك السبيكة المدروسة.

الهدف الثاني من هذه الدراسة هو التنبؤ بالإجهاد للسبيكة $CMn(Nb-Ti-V)$ باستخدام نهج الشبكة العصبية. تم تطوير نموذج قائم على الشبكات العصبية الاصطناعية (RAN) للتنبؤ باستجابة التشوه للسبيكة المعرضة للضغط على الساخن. البيانات التجريبية مجمعة لمنحنيات الإجهاد تشوه في نطاق درجة حرارة (700 إلى 1050 درجة مئوية) لقيم معدل التشوه من S^{-1} 0.0029، $0.0146S^{-1}$ و $0.000734 S^{-1}$. متغير الإخراج من نموذج RAN هو الإجهاد ومتغيرات المدخلات هي درجة الحرارة ومعدل التشوه والتشوه. تم استخدام خوارزمية $Levenberg-Marquardt$ لتنفيذ النموذج باستخدام $MATLAB$.

قد أثبتت الدراسة أن النموذج RAN له أداء أفضل في التنبؤ بالإجهاد. يمكن استخدام النتائج بشكل أحسن في المحاكاة الرياضية لعمليات تشكيل المعدن على الساخن.

الكلمات المفتاحية: لإجهاد؛ السبيكة $CMn(Nb-Ti-V)$ ؛ شبكة اعصاب صناعية RAN ؛ نموذج $Arrhenius$ ؛ معدل اختبارات ضغط على الساخن.

Résumé

Après avoir déterminé les courbes de variation de la contrainte en fonction de la déformation pour différentes vitesses de déformation et différentes températures le premier objectif est l'étude du comportement de l'acier microallié CMn (Nb-Ti-V) et la détermination des différents paramètres rhéologiques par un modèle amélioré de type Arrhenius avec une série de coefficients variables en fonction de la déformation, qui permettraient de déterminer la loi de comportement de l'alliage étudié.

Le deuxième objectif de cette étude est de prédire la contrainte d'écoulement de l'acier microallié CMn (Nb-Ti-V) en utilisant une approche de réseau neuronal. Un modèle basé sur des réseaux de neurones artificiels (RNA) a été développé afin de prédire la réponse à la déformation de l'acier microallié soumis à une compression à chaud. Les données expérimentales regroupées des courbes Contrainte-déformation dans une plage de température (700 à 1050 °C) pour des valeurs de vitesse de déformation de 0,0029 S⁻¹, 0,0146 S⁻¹ et 0,000734 S⁻¹. La variable de sortie du modèle de RNA est la contrainte d'écoulement par compression et les variables d'entrée sont la température, la vitesse de déformation et la déformation. L'algorithme de Levenberg-Marquardt a été utilisé pour entraîner le modèle sous MATLAB.

Il a été démontré que le modèle RAN offre de meilleures performances pour prédire la contrainte d'écoulement. Les résultats peuvent également être utilisés dans la simulation mathématique de processus de déformation à chaud.

Mots clés : Contrainte d'écoulement; Acier micro allié; modèle amélioré de type Arrhenius ; Réseaux de neurones artificiels; Tests de compression à chaud.

Abstract

After having determined the curves of variation of the stress as a function of the deformation for different strain rates and different temperatures, the first objective is the study of the behavior of microalloyed steel CMn (Nb-Ti-V) and the determination of the different rheological parameters by an improved Arrhenius model with a series of variable coefficients as a function of the deformation, which would make it possible to determine the behavior law of the alloy studied.

The second objective of this study is to predict the flow stress of microalloyed steel CMn (Nb-Ti-V) using a neural network approach. A model based on Artificial Neural Networks (ANN) has been developed to predict the deformation response of microalloyed steel subjected to hot compression. The combined experimental data of Stress-strain curves in a temperature range (700 to 1050 °C) for strain rate values of 0.0029 S⁻¹, 0.0146 S⁻¹ and 0.000734 S⁻¹. The output variable of the RNA model is the compression flow stress and the input variables are temperature, strain rate and strain. The Levenberg-Marquardt algorithm was used to train the model under MATLAB.

It is demonstrated that the neural network model has better performance in predicting the flow stress. The results can be further used in mathematical simulation of hot metal forming processes.

Keywords: Flow Stress; Micro Alloyed Steel; improved Arrhenius type model; Artificial Neural Network; Hot Compression Tests.



Table des Matières



Table des Matières

Introduction générale.....	1
-----------------------------------	----------

CHAPITRE I

Évolutions microstructurales au cours de la déformation à chaud

I.1. Introduction.....	4
I.2. Catégories et spécification des aciers HSLA.....	4
I.2.1. Aciers résistants à la corrosion.....	5
I.2.2. Aciers micro-alliés ferrito-perlitique.....	5
I.2.2.1. Aciers Micro-alliés au Vanadium.....	5
I.2.2.2. Aciers Micro-alliés au Niobium.....	5
I.2.2.3. Aciers Micro-alliés au Vanadium-Niobium.....	6
I.2.2.4. Aciers Micro-alliés au Niobium-Molybdène.....	6
I.2.2.5. Aciers Micro-alliés au Vanadium-azote.....	6
I.2.2.6. Aciers Micro-alliés au Titane.....	6
I.2.2.7. Aciers Micro-alliés au Titane-Niobium.....	7
I.2.3. Aciers Laminés à Structure Perlitique.....	7
I.2.4. Aciers à Ferrite Aciculaire (bainite à bas carbone).....	7
I.2.5. Aciers dual-phase.....	7
I.2.6. Aciers à Forme d'inclusion Contrôlés.....	7
I.3. Contrôle des propriétés des aciers HSLA.....	8
I.4. Comportement à chaud des aciers micro-alliés.....	9
I.4.1. Transformations structurales.....	10
I.4.2. Diagramme d'équilibre fer-carbone.....	10
I.5. Déformation à chaud.....	11
I.5.1. Etapes de restauration dynamique et de recristallisation dynamique.....	12
I.5.1.1. Restauration dynamique.....	12
I.5.1.2. Recristallisation dynamique.....	12
I.5.1.3. Germination.....	14
I.6. Conclusion.....	16

CHAPITRE II

Généralités sur la régression neuronale généralisée

II.1. Introduction	28
II.2. Généralités sur les réseaux des neurones	29
II.2.1. Définition.....	31
II.2.2. Historique.....	32
II.2.3. Neurophysiologie.....	32
▪ Le Neurone	32
II.2.4. Neurone formel.....	32
II.2.5. Représentation mathématique.....	33
II.2.5.1. Architectures de réseaux de neurones.....	35
II.2.5.2. Fonctionnement du réseau.....	36
▪ Le Perceptron.....	36
II.2.5.3. Apprentissage des réseaux de neurones.....	37
▪ Apprentissage non supervisé.....	38
▪ Apprentissage supervisé.....	41
II.2.5.4. La convergence du perceptron.....	42
II.2.6. Réseau multicouches.....	42
II.2.7. Mise en œuvre des réseaux de neurones.....	42
II.3. Application des réseaux de neurones en métallurgie	43
II.3.1. Prédiction de défauts en moulage sable.....	43
II.3.2. Prédiction de micro-retassures dans une fonderie en Espagne.....	44
II.3.3. Prédiction des propriétés mécaniques de pièces en fonte.....	44
II.3.4. Prédiction de comportement d'un alliage de magnésium en fonction de sa composition et de la vitesse de refroidissement.....	45
II.3.5. Composite à matrice métallique en métallurgie des poudres.....	45
II.3.1. Prédiction de la modification du silicium pour un alliage Al-Si-Cu.....	46
II.4. Conclusion	46

CHAPITRE III
**modélisation par un modèle de régression
neuronale généralisée et par des lois de
régression rhéologiques**

III.1. Introduction	47
III.2. Détermination expérimentale de la contrainte d'écoulement	48
IV.2.1. Procédures matérielles et expérimentales.....	48
IV.2.2. Résultats expérimentaux.....	52
III.3. Comportement rhéologique	54
IV.3.1. Equations constitutives du comportement rhéologique.....	54
IV.3.1.1. Calcul des constantes de matériau n , α et β	55
IV.3.1.2. Calcul de l'énergie d'activation apparente Q	55
IV.3.1.3. Construction de l'équation constitutive à la déformation 0.1.....	56
IV.3.1.4. Construction de l'équation constitutive de déformation de 0 ~ 0,8.....	57
IV.3.2. Résultats du modèle développé.....	59
III.4. Modèle RNA	63
IV.4.1. Développement du modèle RNA.....	63
IV.4.2. Description générale de l'algorithme de calcul (Levenberg-Marquardt).....	66
IV.4.3. Méthode rétro propagation	72
IV.4.4. Modèle RNA.....	75
IV.4.4. Résultats du réseau de neurones développé.....	76
III.5. Comparaisons entre les résultats des modèles développés	83
III.6. Conclusion	86
Conclusion générale	88
Références Bibliographiques	90
Annexe	99



Liste des Figures et Tableaux

Liste des Figures

Chapitre I

Figure I.1	Compromis résistance-ductilité des différentes familles d'aciers HLE	8
Figure I.2	Diagramme métastable Fe ₃ C	10
Figure I.3	Diagramme d'équilibre binaire Fer – Carbone	10
Figure I.4	Courbe contrainte- déformation obtenue par déformation à chaud	11
	a) lorsque le seul processus d'adoucissement est la restauration dynamique	
	b) lorsque le seul processus d'adoucissement est la recristallisation dynamique	
Figure I.5	Les processus de restauration dynamique et recristallisation dynamique	13
Figure I.6	Représentation schématique de	13
	a) état déformé, b) état restauré, c) état partiellement recristallisé, d) état complètement recristallisé, e) croissance normale des grains et f) croissance anormale des grains	
Figure I.7	Recristallisation dynamique	14
	a) structure déformée restaurée et non recristallisée; b) germination de nouveaux grains;	
	c) grains à des niveaux différents d'écrouissage; d) exemple d'une microstructure d'un alliage de cuivre présentant des grains écrouis et recristallisés	
Figure I.8	a) Modèle de migration induite par la déformation ($E_1 > E_2$),	15
	b) Schéma de la SIBM impliquant le développement coopératif de plusieurs sous-grains.	

Chapitre II

Figure II.1	Courbes contrainte-déformation pour différentes vitesses de déformation à T=300°K	19
Figure II.2	Schéma illustrant la variation de la contrainte d'écoulement des métaux avec la température, Rosenfield et Hahn	20
Figure II.3	Effets de la vitesse de déformation avec un modèle de comportement parfaitement plastique	23
Figure II.4	Comparaison des modèles d'écrouissage	24
Figure II.5	Effets de la viscosité avec un modèle de NORTON	26

Chapitre III

Figure III.1	Hypothèse biologique de génération d'un comportement intelligent	30
Figure III.2	Schéma d'un neurone biologique	33
Figure III.3	Structure d'un Neurone formel	33
Figure III.4	Structure d'un neurone artificiel	34

Figure III.5	Notation de la structure d'un neurone artificiel	34
Figure III.6	Différents types de fonctions de transfert pour le neurone artificiel, a : fonction à seuil (S, la valeur du seuil), b : linéaire par morceaux, c : sigmoïde.	35
Figure III.7	Réseau multicouche	35
Figure III.8	Réseau à connexions locales	36
Figure III.9	Réseau à connexions récurrentes	36
Figure III.10	Réseau à connexions complète	36
Figure III.11	Le Perceptron	37
Figure III.12	Fonction d'activation ou fonction de transfert	38
Figure III.13	Apprentissage non supervisé	38
Figure III.14	Apprentissage supervisé	41
Figure III.15	Algorithme d'apprentissage supervisé	41
Figure III.16	Réseau multicouches	42

Chapitre IV

Figure V.1	Dispositif de compression à chaud	49
Figure IV.2	Procédures expérimentales pour les essais de compression de l'acier micro allié CMn (Nb-Ti-V)	50
Figure IV.3	Microstructure initiale des échantillons	51
Figure IV.4	Echantillon refroidi après austénitisation à 1300 ° C	51
Figure IV.5	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,0146 S-1	52
Figure IV.6	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,0029 S-1	53
Figure IV.7	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,000734 S-1	53
Figure IV.8	Les relations entre $[\dot{\epsilon}]$ et $[\ln \sigma]$ & $[\ln \dot{\epsilon}]$ et σ].	57
Figure IV.9	Les relations entre $[\ln \dot{\epsilon}]$ et $[\ln \sinh(\alpha \sigma)]$ & $[T-1]$ et $[\ln \sinh(\alpha \sigma)]$	57
Figure IV.10	Les paramètres Q, ln A, n, α évalués par compensation polynômiale en fonction de la déformation ϵ .	58
Figure IV.11	Valeurs de prédiction faces aux valeurs mesurées de la contrainte d'écoulement	59
Figure IV.12	Evaluation de l'erreur relative absolue et l'erreur relative absolue moyenne pour l'ensemble des points de mesure	60
Figure IV.13	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à T = 700 ° C	61
Figure IV.14	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à T = 750 ° C	61
Figure IV.15	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à T = 850 ° C	62
Figure IV.16	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à	62

	T = 950 ° C	
Figure IV.17	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à T = 1050 ° C	63
Figure IV.18	L'erreur quadratique (SE) et l'erreur quadratique moyenne (MSE) de l'ensemble des données	77
Figure IV.19	L'architecture optimale du réseau de neurones artificiels	77
Figure IV.20.a	Contrainte d'écoulement mesurée face au prédite pour l'ensemble d'entraînement	78
Figure IV.20.b	Contrainte d'écoulement mesurée face au prédite pour l'ensemble de test	79
Figure IV.20.c	Contrainte d'écoulement mesurée face au prédite pour l'ensemble de validation	79
Figure IV.20.d	Contrainte d'écoulement mesurée face au prédite pour l'ensemble des données.	80
Figure IV.21	L'erreur relative absolue (ARE) et l'erreur relative absolue moyenne (AAR) de l'ensemble des données	80
Figure IV.22	Valeurs expérimentales et prévues de la contrainte d'écoulement pour la vitesse de déformation $\dot{\epsilon} = 0,0029 \text{ S}^{-1}$ et T = 700 ° C	81
Figure IV.23	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes valeurs de vitesses de déformation à T = 750 ° C	81
Figure IV.24	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 900 ° C	82
Figure IV.25	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 950 ° C	82
Figure IV.26	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 1050 ° C	83
Figure IV.27	Valeurs maximales expérimentales et prévues des contraintes pour différentes températures et vitesses de déformation	83
Figure IV.28	Valeurs expérimentales et prévues de la contrainte d'écoulement pour une vitesse de déformation de 0,0029 S-1 à T = 700 ° C	84
Figure IV.29	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 700 ° C	85
Figure IV.30	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 750 ° C	85
Figure IV.31	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 850 ° C	86
Figure IV.32	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 950 ° C	86
Figure IV.33	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 1050 ° C	87

Liste des Tableaux

Tableau IV.1	Compositions chimiques détaillées	50
Tableau IV.2	Résultats de l'ajustement polynomial de Q , n , $\ln A$ et α	58



Introduction générale

Afin d'estimer divers paramètres tels que la charge, l'énergie et les contraintes dans une opération de formation de métal, connaissance des relations constitutives reliant les variables de processus telles que la déformation, la vitesse de déformation et la température à la contrainte d'écoulement du matériau déformant est nécessaire. La prédiction précise de la contrainte d'écoulement pour la déformation d'un matériau devient de plus en plus importante avec l'utilisation parallèle d'éléments finis méthode dans le développement de modèles de processus de déformation pour caractériser le comportement de la pièce dans différentes conditions de traitement. La prédiction précise de la contrainte d'écoulement nécessite le développement des équations constitutives capables de modéliser l'influence des paramètres dépendants dans différentes conditions de fonctionnement. Les approches de modélisation constitutive existantes peuvent être distinguées par l'échelle de taille qu'elles représentent et le degré auquel ils sont dérivés des théories physiques [1]. À un extrême de l'échelle sont des modèles analytiques qui relient étroitement les relations constitutives avec les théories physiques alors que les modèles empiriques sont à l'autre extrême, généralement basés sur des mesures extensives des propriétés macroscopiques pour assurer leur validité et n'ayant aucune relation avec les théories physiques. Les relations analytiques, qui sont étroitement liées aux théories physiques, exigent une compréhension très claire de la physique.

Les processus contrôlant la déformation du matériau, et sont difficilement applicables en pratique. Certains chercheurs ont eu recours à des approches de modélisation entre ces deux extrêmes, tels que les modèles phénoménologiques et les variables internes d'état [2-7] qui sont formulés en termes d'un petit nombre de variables qui représentent les effets de la microstructure sur la déformation. Alors que les modèles phénoménologiques sont moins rigoureusement liés aux théories physiques, une connaissance substantielle de la physique et les fondamentaux de la déformation non élastique sont encore nécessaires pour développer un modèle constitutif réussi. Une approche plus largement adoptée consiste à obtenir des équations constitutives à partir de courbes d'écoulement déterminées expérimentalement. Ainsi, plusieurs chercheurs [8-17] ont eu recours à des modèles empiriques et semi-empiriques qui corrélerent la contrainte d'écoulement avec les paramètres du processus. Des études récentes [18-26] sur l'application des réseaux neuronaux dans plusieurs domaines de l'ingénierie manufacturière tels que la planification des processus, la reconnaissance des caractéristiques, la conception des outils ont montré la possibilité de résolution des problèmes qui sont lourdes et intraitables avec les méthodes traditionnelles.

Les réseaux de neurones artificiels représentent une famille d'algorithmes informatiques inspirés des mécanismes de fonctionnement du cerveau. Ce sont des exemples typiques de systèmes parallèles distribués car ils suggèrent qu'en l'absence d'une représentation explicite des symboles, l'intelligence peut apparaître comme le résultat de l'interaction d'un grand nombre de composants simples grâce aux résultats obtenus au cours de la dernière décennie. Les réseaux de neurones connaissent un succès croissant et ont prouvé leur efficacité dans plusieurs domaines : comme le traitement de signal, l'identification des paramètres, la commande des procédés, l'estimation et la détection des défauts Ils demeurent toutefois un sujet d'un grand intérêt pour les chercheurs qui désirent améliorer les performances de ces réseaux et étendre leur champ d'applications. [27]

Le développement des nouvelles techniques et méthodologies expérimentales donne la possibilité d'aller toujours plus loin dans l'étude de l'architecture neuronale. Ainsi, des modèles toujours plus élaborés sont proposés pour comprendre les mécanismes fondamentaux de la dynamique neuronale d'une part, et pour proposer de nouvelles expériences ou applications d'autre part. En parallèle avec cette évolution il y a un besoin de développer des méthodes mathématiques d'analyse ou d'améliorer les méthodes existantes, tel que les problèmes théoriques qui posent la dynamique des réseaux de neurones [28].

De plus, si l'identification des systèmes linéaires est relativement bien maîtrisée, l'identification des systèmes non-linéaires reste un enjeu majeur. Actuellement, de nombreuses méthodes ont été proposées afin d'utiliser les réseaux de neurones dans le cadre de l'identification des systèmes dynamiques. Toutefois, ces méthodes reposent essentiellement sur une modélisation de type "boîte noire", qui font l'hypothèse que le processus à modéliser peut être décrit par des modèles entrée-sortie ; ce qui leur vaut d'avoir une complexité de calcul et de mise en œuvre.

Des études récentes ont montré que la méthodologie des réseaux de neurones peut être adoptée pour résoudre des problèmes difficiles à résoudre à l'aide de méthodes traditionnelles, et ont démontré que les techniques RNA peuvent modéliser les courbes de flux de déformation à chaud de différents matériaux.

L'objectif de cette étude est de prédire la contrainte d'écoulement de l'acier microallié CMn (Nb-Ti-V) en utilisant un modèle semi empirique en utilisant l'équation d'Arrhenius amélioré avec une série de coefficients variables en fonction de la déformation et un modèle RNA basé sur une approche de régression neuronale.

Les travaux et résultats de recherche sont résumés dans ce modeste travail présenté. Celle-ci comprend quatre chapitres. Les deux premiers chapitres rappellent les résultats bibliographiques sur l'évolution microstructurales au cours de la déformation à chaud. Le deuxième chapitre porte sur la régression neuronale généralisée.

L'objectif du troisième chapitre est de prédire la contrainte d'écoulement de l'acier microallié CMn (Nb-Ti-V) en utilisant deux modèles qui seront confrontés aux résultats expérimentaux. Chacun de ces chapitres est terminé par une conclusion partielle, dont le bilan est effectué en conclusion générale, et qui permet d'envisager des perspectives aux travaux présentés.



CHAPITRE I

*Evolutions microstructurales au cours
de la déformation a chaud*

I.1. Introduction

Les aciers HSLA sont un groupe d'aciers à bas carbone qui utilise de petites quantités d'éléments d'alliages pour atteindre une limite d'élasticité supérieure après normalisation ou laminage. **[Figure I.1]** Ces aciers ont de meilleures propriétés mécaniques et une meilleure résistance à la corrosion par rapport aux aciers au carbone laminé. De plus, pour une faible quantité de carbone, on peut obtenir une haute résistance et la soudabilité de beaucoup de ces aciers sont comparables ou même meilleure à celle des aciers doux. **[29,30]** Les aciers HSLA sont essentiellement laminés à chauds en forme de produit forgé (tôle, bande, barre, plaque, et sections structurales).

Les méthodes de traitement de ces aciers incluent :

- Un laminage contrôlé des aciers HSLA durcis par précipitation donne des grains austénitiques très fins et/ou très déformés, se transformant en grains de ferrite fins pendant le refroidissement. Ces transformations améliorent la ténacité et augmentent la limite élastique.
- Pour produire des grains de ferrite fins pendant la transformation d'austénite, les aciers HSLA doivent subir un refroidissement accéléré.
- Une trempe ou un refroidissement accéléré à l'eau ou à l'air des aciers à bas carbone (0.08% C) possédant une trempabilité adéquate pour se transformer en bainite à bas carbone (ferrite aciculaire). Cette microstructure offre une excellente combinaison de haute limite d'élasticité, de soudabilité, de formabilité et haute ténacité. **[31]**
- Un recuit inter-critique d'aciers HSLA pour obtenir une microstructure dual phase (des îlots de martensite dispersés dans une matrice ferritique). Cette microstructure expose une limite d'élasticité inférieure mais, à cause d'un durcissement par écrouissage, fournit une meilleure combinaison de ductilité et de résistance à la traction que les aciers HSLA conventionnels et une formabilité amélioré.

I.2. Catégories et spécification des aciers HSLA

Les aciers HSLA incluent un grand nombre de nuances standards et sont conçus pour fournir des combinaisons spécifiques de propriétés telles que la résistance, la ténacité, la formabilité, la soudabilité et la résistance à la corrosion atmosphérique. Ces aciers ne sont pas considérés comme des aciers alliés, bien que leurs propriétés désirées soient accomplies par l'usage de petites additions d'alliages. Au lieu de cela, ils sont classés comme une catégorie d'acier séparée, qui est semblable à l'acier au carbone doux laminé, avec des propriétés

mécaniques rehaussées obtenues par de judicieuses (petites) additions d'alliages et des techniques de traitement spéciales tel que le laminage contrôlé. [32]

Les aciers HSLA peuvent être divisés en six catégories :

I.2.1. Aciers résistants à la corrosion

Ils étaient les premiers aciers HSLA développés. Ils contiennent du cuivre et autres éléments qui augmentent la résistance à la corrosion, le durcissement par solution solide et l'affinement du grain ferritique.

I.2.2. Aciers micro-alliés ferrito-perlitique

Ils utilisent des additions d'éléments tels que le niobium et le vanadium pour augmenter la résistance de l'acier laminé à chaud sans augmenter la quantité du carbone et/ou du manganèse. Des études faites sur le niobium et le vanadium ont révélé que de petites quantités de ces éléments (moins de 0.10%) suffisent pour durcir les aciers au carbone-manganèse. Donc, la quantité de carbone pourrait être réduite pour améliorer la soudabilité et la ténacité, les effets durcissant de niobium et de vanadium ayant compensé la décroissance de la résistance due à la réduction du carbone. [33]

Ces aciers peuvent contenir d'autres éléments pour améliorer la résistance à la corrosion et le durcissement par solution solide ou augmenter la trempabilité (si on veut obtenir une microstructure autre que la microstructure ferrito-perlitique).

Les différents types d'aciers micro-alliés ferrito-perlitique incluent :

I.2.2.1. Aciers Micro-alliés au Vanadium

Le développement des aciers contenant du vanadium s'est produit peu après le développement de ceux résistants aux effets atmosphériques. Le vanadium contribue au durcissement en formant des fines particules (5 à 100 nm) de V(C, N) dans la ferrite pendant le refroidissement après une déformation à chaud. Ces précipités sont en solution à toutes les températures de laminage ou forgeage. Donc, leur formation dépend des vitesses de refroidissement. La quantité du manganèse et la taille du grain ferritique affectent aussi le durcissement des aciers micro-alliés au vanadium. Le durcissement par précipitation du vanadium peut être augmenté par le fait que le manganèse abaisse la température de transformation austénite-ferrite. Cela donne une dispersion plus fine.

I.2.2.2. Aciers Micro-alliés au Niobium

Comme le vanadium, le niobium augmente la limite élastique par un durcissement par précipitation. La magnitude de l'augmentation dépend de la taille et de la quantité des carbures du niobium précipités. Cependant, le niobium est aussi un affineur de grain très efficace.

Les aciers au niobium sont produits par laminage contrôlé, recristallisation contrôlée et refroidissement accéléré. [34]

I.2.2.3. Aciers Micro-alliés au Vanadium-Niobium

Ces aciers fournissent une plus grande limite élastique que celle réalisable avec l'un des deux. Si l'acier subit un laminage contrôlé, l'addition du niobium et du vanadium est particulièrement avantageuse pour augmenter la limite d'élasticité et abaisser la température de transition ductile-fragile par affinage du grain. Habituellement les aciers au niobium-vanadium contiennent une petite quantité de carbone (moins que 0.10%C). Cela réduit la quantité de perlite et améliore la ténacité, la ductilité et la soudabilité. Ces aciers sont fréquemment connus sous le nom d'aciers à perlite réduite.

I.2.2.4. Aciers Micro-alliés au Niobium-Molybdène

Ils peuvent avoir soit une microstructure ferrito-perlitique soit une microstructure de ferrite aciculaire. Dans les aciers ferrito-perlitique au niobium, l'addition du molybdène augmente respectivement la limite d'élasticité et la résistance à la traction. L'effet principal du molybdène sur la microstructure est de changer la morphologie de la perlite et d'introduire la bainite supérieure comme un remplacement partiel de la perlite.

I.2.2.5. Aciers Micro-alliés au Vanadium-azote

L'Azote se combine plus au Vanadium qu'au niobium et forme des précipités VN. L'addition de l'azote aux aciers à haute résistance qui contiennent du vanadium est devenue commercialement importante parce qu'elle augmente le durcissement par précipitation. Ce durcissement peut être accompagné par une chute de résilience, mais cela peut souvent être évité en diminuant la quantité de carbone. Le nitrure de vanadium agit aussi comme un affineur du grain. Cependant, la fissuration est un problème majeur dans ces aciers et l'usage d'azote n'est pas recommandé pour les aciers qui seront soudés à cause de son effet nuisible sur la résilience dans la Z.A.T. [35]

I.2.2.6. Aciers Micro-alliés au Titane

Le titane dans les aciers à bas carbone forme plusieurs composés qui fournissent un affinage du grain, un durcissement par précipitation et contrôle la forme des sulfures. Cependant, comme le titane est un bon désoxydant, il doit être utilisé dans des aciers calmés (désoxydé par l'aluminium) afin qu'il soit disponible pour former d'autres composés que l'oxyde du titane. Comme les aciers au niobium et/ou au vanadium, les aciers micro-alliés au titane sont durcis par des mécanismes qui impliquent une combinaison d'affinage de grain et un durcissement par précipitation. La combinaison dépend de la quantité d'addition de l'alliage et des méthodes de traitement.

I.2.2.7. Aciers Micro-alliés au Titane-Niobium

Bien que les aciers au titane durcis par précipitation aient des limitations en ténacité et une variation des propriétés mécaniques, la recherche a montré qu'une addition de Titane aux aciers au Niobium à bas carbone améliore leurs propriétés. Le Titane augmente l'efficacité du Niobium parce qu'il forme des TiN, donc empêche la formation des nitrures de Niobium. Cela permet d'augmenter la solubilité du Niobium dans l'austénite qui résulte en une augmentation subséquente de précipitation des particules de Nb(C, N) dans la ferrite.

I.2.3. Aciers Laminés à Structure Perlitique

Ils sont un groupe spécial d'aciers dont l'augmentation des propriétés mécaniques (et dans quelques cas, la résistance à la corrosion atmosphérique) est obtenue par l'addition de quantités modérées d'un ou de plusieurs éléments autres que le carbone. D'autres aciers perlitique contiennent de petites quantités d'éléments alliés pour améliorer la soudabilité, la formabilité, la ténacité et la dureté.

I.2.4. Aciers à Ferrite Aciculaire (bainite à bas carbone)

Une autre approche au développement des aciers HSLA est d'obtenir une microstructure de ferrite aciculaire très fine et plus résistante, au lieu d'une microstructure de ferrite polygonale habituelle pendant la transformation des aciers à très bas carbone (moins que 0.08%C) avec une trempabilité suffisante (par additions de Molybdène et/ou de bore). A la différence de la structure polygonale, la structure aciculaire (qui est aussi appelé bainite à bas carbone) est caractérisée par une haute densité de dislocation et des grains fins très déformés. Les aciers à ferrite aciculaire peuvent être obtenus par trempe ou, de préférence, par refroidissement à l'air avec l'addition d'éléments convenables pour la trempabilité. L'avantage principal de ce type d'acier est la combinaison exceptionnelle de hautes limites d'élasticité, haute ténacité et d'une bonne soudabilité. [36, 37]

I.2.5. Aciers dual-phase

Ils ont une microstructure composée de 80 à 90% de ferrite polygonale et 10 à 20% d'îlots de martensite dispersées dans la matrice ferritique. Ces aciers ont une faible limite d'élasticité, donc ils forment un acier à faible résistance, mais ils peuvent aussi fournir une haute résistance pour un composant fini à cause de leur durcissement par un travail à froid. [38]

I.2.6. Aciers à Forme d'inclusion Contrôlés

Un développement important dans les aciers micro-alliés a été permis par le contrôle de la forme des inclusions. Les inclusions des sulfures qui sont plastiques durant le laminage à chaud et donc allongées, ont un effet nuisible sur la ductilité dans le sens travers-court (suivant l'épaisseur).

L'objectif principal du contrôle de la forme des inclusions est de produire des inclusions sulfureuses avec une plasticité négligeable même pour les plus hautes températures de déformation. Ce contrôle est exécuté avec de petites additions d'éléments de terre rare (Pr, Ce), de Zr, de Ca ou du Ti qui changent la forme des inclusions allongées en petites globules dispersés presque sphériques. Ce changement dans la forme des inclusions augmente la résilience et améliore la formabilité. [39,40]

Ces catégories ne sont pas des groupes nécessairement distincts. Par exemple, la forme d'inclusion de tous les types précités d'aciers peuvent être contrôlés. L'acier micro-allié ferrito-perlitique peut avoir aussi des alliages supplémentaires pour la résistance à la corrosion et le durcissement par solution solide.

I.3. Contrôle des propriétés des aciers HSLA

Les propriétés mécaniques des aciers HSLA ne résultent pas uniquement d'une simple présence des éléments dispersives. L'austénite conditionnée, qui dépend des effets complexes du design de l'alliage et des techniques des traitements thermomécaniques, est aussi un facteur important dans l'affinage du grain de ces aciers. Le développement des processus de laminage contrôlé, associé au design de l'alliage, a conduit à des niveaux de limite d'élasticité croissants, accompagnés d'un abaissement graduel en quantités de carbone. Beaucoup d'aciers HSLA ont une quantité de carbone aussi basse que 0.06%, ou même plus basse encore. Cependant, ils sont encore capables de développer une haute limite d'élasticité. Cette dernière est obtenue par les effets combinés de la taille du grain développée pendant le laminage contrôlé et le durcissement par précipitation dû à la présence de vanadium, de niobium et de titane.

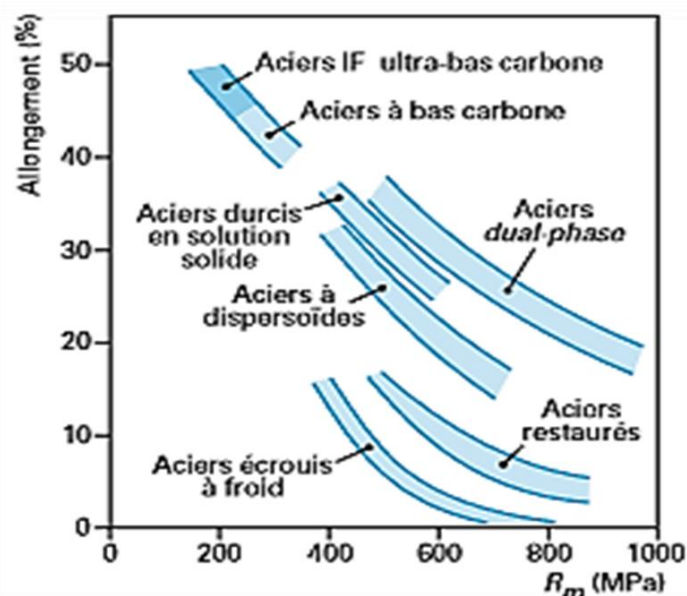


Figure I.1 : Compromis résistance-ductilité des différentes familles d'aciers HLE [30]

I.4. Comportement à chaud des aciers micro-alliés

Lorsqu'un métal est soumis à une opération de formage, il oppose une certaine résistance à la déformation plastique qui se traduit par des sollicitations mécaniques sur les outils, mais cette notion de résistance à la déformation ne caractérise pas le métal de manière intrinsèque car elle fait intervenir le mode de déformation. Il est nécessaire de définir une grandeur physique caractérisant de manière intrinsèque le métal de point de vue de son comportement mécanique en cours de la déformation et qui dépend de l'état dans lequel il se trouve. Ainsi la valeur que prend à un instant donné la contrainte de déformation généralisée est un paramètre qui caractérise de façon intrinsèque le comportement du métal en cours de déformation plastique. C'est ce paramètre que l'on appellera plus simplement contrainte de déformation et qui d'une façon générale dépend de la déformation, de la vitesse de déformation, de la température et aussi de la microstructure du matériau, L'allure des courbes contrainte-déformation reflète de manière très représentative la compétition entre les mécanismes d'écrouissage et les mécanismes d'adoucissement.

Au cours du recuit, le passage des matériaux d'un état instable vers un état de plus grande stabilité, donc de moindre énergie, se fait en deux étapes :

- Lors de la première étape dite de germination, les germes des futurs cristaux se forment et se développent lorsqu'ils ont une taille critique se développent.
- Dans la deuxième étape dite de croissance, on obtient un grossissement des germes qui confèrent au matériau sa nouvelle configuration.

On peut obtenir, plusieurs évolutions possibles de la structure au cours de la croissance, qui est directement influencée par les traitements mécaniques et thermiques subis par le matériau de départ. Nous verrons pour commencer, les différents mécanismes de transformation qui interviennent pendant la déformation à chaud.

Les propriétés mécaniques des aciers HSLA ne résultent pas uniquement d'une simple présence des éléments dispersoïdes. L'austénite conditionnée, qui dépend des effets complexes du design de l'alliage et des techniques des traitements thermomécaniques, est aussi un facteur important dans l'affinage du grain de ces aciers. Le développement des processus de laminage contrôlé, associé au design de l'alliage, a conduit à des niveaux de limite d'élasticité croissants, accompagnés d'un abaissement graduel en quantités de carbone. Beaucoup d'aciers HSLA ont une quantité de carbone aussi basse que 0.06%, ou même plus basse encore. Cependant, ils sont encore capables de développer une haute limite d'élasticité. Cette dernière est obtenue par les effets combinés de la taille du grain développée pendant le laminage contrôlé et le durcissement.

I.4.1. Transformations structurales

La structure du fer change avec la température. A 20°C, la structure est cubique centrée CC (fer α) A partir de 912°C apparaît la forme cubique à faces centrées CFC (fer γ). Cette forme est stable jusqu'à 1394°C où le fer redevient cubique centré (fer δ) jusqu'à la fusion à 1538°C. Les atomes de carbone peuvent entrer dans les espaces libres entre les atomes du fer CFC. La solubilité varie avec la température.

I.4.2. Diagramme d'équilibre fer-carbone

Le diagramme d'équilibre Fer-carbone est très utile pour comprendre les aciers, les fontes et les traitements thermiques. Il est limité à droite par la cémentite Fe_3C (6.67% C) est fait apparaître les deux grandes familles de métaux ferreux : les aciers (entre 0.008% C et 2% C) et les fontes (de 2% C à 6.67% C). [Figure (I.2), (I.3)]

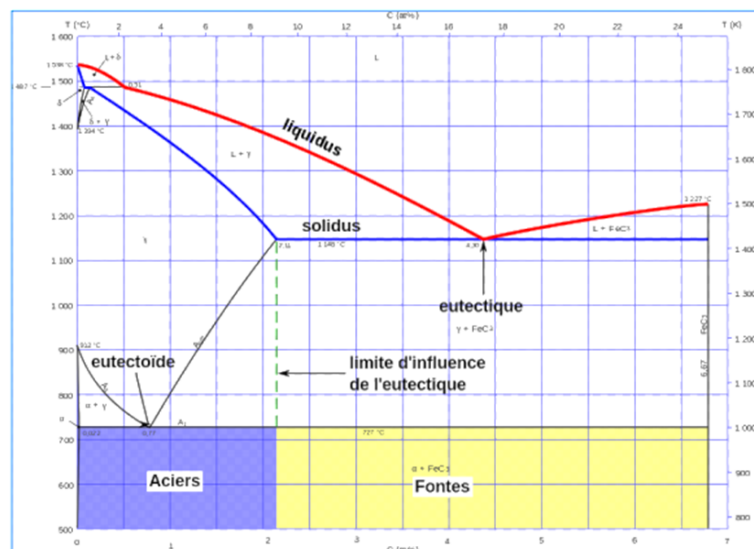


Figure I.2 : Diagramme métastable Fe₃C

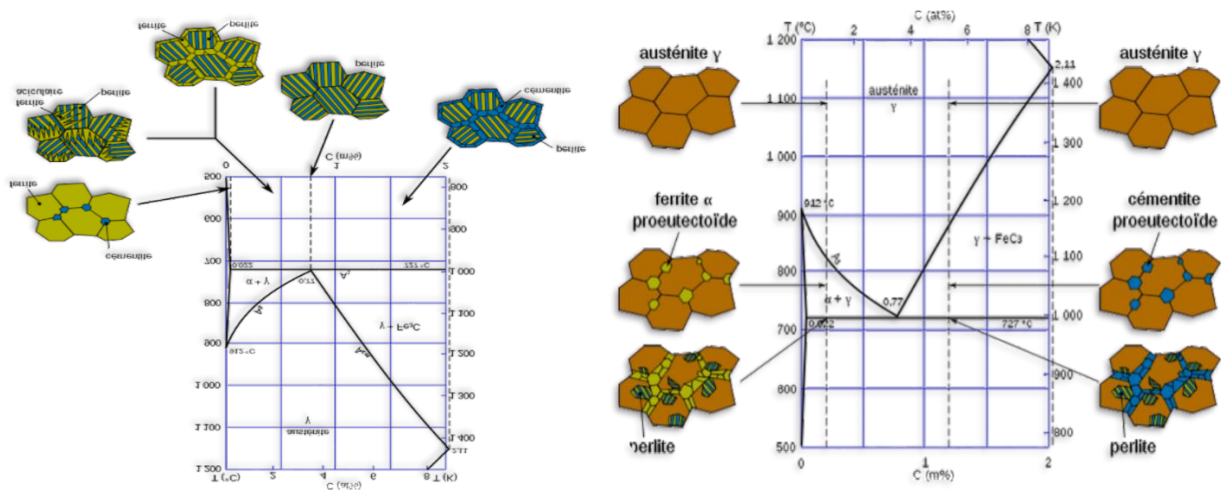


Figure I.3 : Diagramme d'équilibre binaire Fer – Carbone

I.5. Déformation à chaud

En général, la déformation à haute température ($T > 0.5 \text{ TF}$) d'un métal ou d'un alliage se caractérise par la coexistence de l'écrouissage et de l'adoucissement pendant la déformation. L'écrouissage est dû à l'augmentation de la densité des dislocations sous l'effet de la déformation plastique. Quant à l'adoucissement il est dû à l'activation des processus de restauration par annihilation des dislocations. Suivant les conditions de température et de vitesse de déformation, une compétition se crée entre l'écrouissage et les phénomènes d'adoucissement. Dans de nombreux cas, lorsque la déformation à chaud est poursuivie ($\epsilon \geq 0.5$) cette compétition conduit souvent à l'établissement d'un régime d'écoulement stationnaire. Ce régime stationnaire correspond un état d'équilibre dynamique, dans lequel la structure du métal est adaptée aux conditions imposées (vitesse et température de déformation).

Dans les matériaux à forte énergie de défaut d'empilement de l'ordre de 10^1 J/m^2 (exemple l'Aluminium et certains de ses alliages, le fer α et les aciers ferritique...) l'adoucissement activé pendant la déformation à chaud correspond à la restauration dynamique. Le processus se caractérise par le réarrangement continu et l'annihilation individuelle des dislocations. Lorsque le régime d'écoulement stationnaire est atteint, il y a équilibre entre les vitesses d'émission et d'annihilation des dislocations [Figure I.4.a].

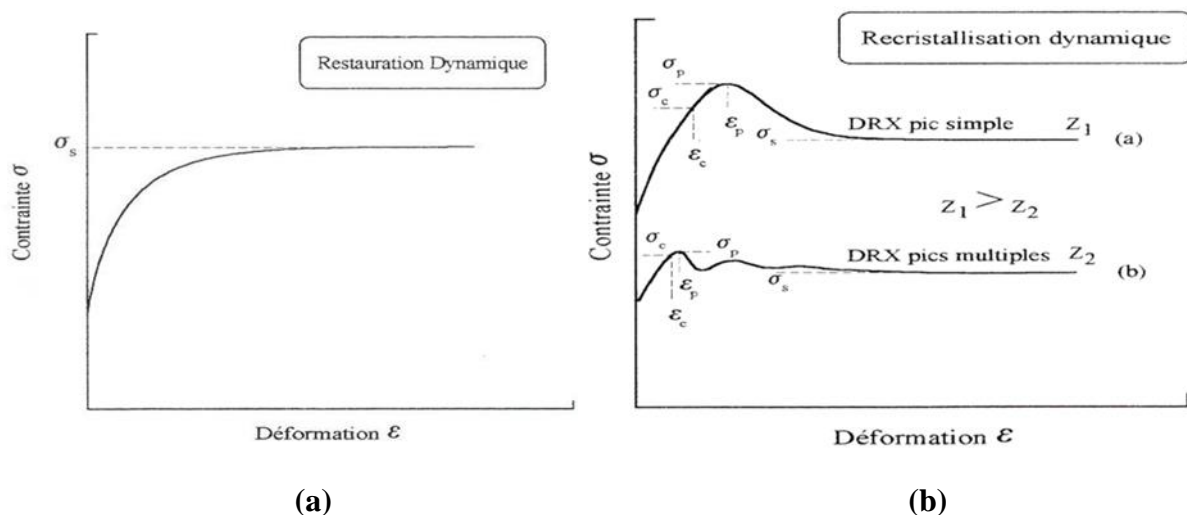


Figure I.4 : Courbe contrainte- déformation obtenue par déformation à chaud

- a) lorsque le seul processus d'adoucissement est la restauration dynamique**
- b) lorsque le seul processus d'adoucissement est la recristallisation dynamique**

Dans les matériaux à faible énergie de défaut d'empilement de l'ordre de 10^{-2} J/m^2 (exemple le Cuivre, le Laiton, le Fer γ et les aciers Austénitique) la restauration dynamique activée en début de déformation se produit relativement plus lentement et conduit à

l'accumulation d'une quantité plus importante de dislocations. Le régime stationnaire défini ci-dessus ne peut pas être atteint tout de suite. Lorsque la densité de dislocations atteint une valeur critique, et sous certaines conditions de température et de vitesse de déformation, le mode d'adoucissement par recristallisation dynamique se caractérise par la germination et la croissance de nouveaux grains au cours de la déformation. L'écoulement conduit donc à l'établissement d'un régime stationnaire [Figure I.4.b], différent de celui de la restauration dynamique.

I.5.1. Etapes de restauration dynamique et de recristallisation dynamique

I.5.1.1. Restauration dynamique

La restauration se fait en plusieurs étapes. Dans un premier temps, on assiste à une réorganisation des sous-structure de dislocations. En favorisant la montée des dislocations par élévation température, on diminue la densité totale de dislocations par annihilation. Les dislocations et les parois se structurent pour former des sous-joints, c'est l'étape de polygonisation [41]. Puis, les sous-grains évoluent par mouvements des sous-joints pour atteindre une structure minimisant l'énergie stockée.

Chaque grain présente donc une sous-structure constituée de cellules ou de sous-grains désorientés de quelques degrés par rapport à l'orientation initiale du grain. Cette restauration peut être influencée par le taux de déformation, la température de recuit et les caractéristiques du matériau (énergie de faute d'empilement, éléments en solution solide et précipités). La restauration est d'autant plus rapide et se fait à température d'autant plus basse que l'énergie stockée est plus élevée. Cette énergie augmente avec la déformation et dépend de l'orientation du grain considéré. La texture développée pendant la déformation ne change pas de manière appréciable pendant la restauration.

I.5.1.2. Recristallisation dynamique

La recristallisation correspond à la formation de nouveaux grains dans un matériau déformé et à la migration de joints de grains de forte désorientation dont la force motrice est principalement l'énergie de déformation stockée [42,43]. La recristallisation primaire est habituellement divisée en deux stades :

La germination et la croissance des germes dans la matrice écrouie. La vitesse de recristallisation (volume recristallisé par unité de temps) s'écrit : $V=N.G$ Où N est le nombre de nouveaux germes par unité de temps et G leur vitesse de croissance volumique. Comme ces deux quantités dépendent du temps, la cinétique de recristallisation n'est pas une fonction simple du temps. Expérimentalement, le problème consiste à mesurer séparément N et G.

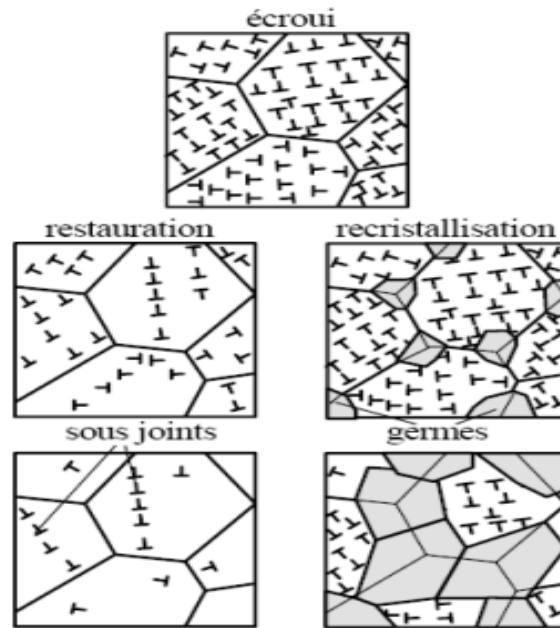


Figure I.5 : Les processus de restauration dynamique et recristallisation dynamique [44]




Figure I.6 : Représentation schématique de

- a) état déformé, b) état restauré, c) état partiellement recristallisé, d) état complètement recristallisé, e) croissance normale des grains et f) croissance anormale des grains





Figure I.7 : Recristallisation dynamique

- a) structure déformée restaurée et non recristallisée; b) germination de nouveaux grains;**
c) grains à des niveaux différents d'écroutissage; d) exemple d'une microstructure d'un alliage de cuivre présentant des grains écrouis et recristallisés [45]

I.5.1.3. Germination

La germination coïncide avec la formation de régions de faible taille exemptes de défauts, susceptibles de croître rapidement dans la matrice écrouie. La croissance des germes est d'autant plus rapide que la désorientation avec la matrice environnante est importante. De plus, un germe potentiel ne peut croître que si sa taille est supérieure à celle des cellules voisines. Dans une zone cellulaire, par exemple, un germe potentiel peut atteindre la taille critique nécessaire à son développement au détriment des autres voisins soit par croissance des cellules, soit par coalescence. L'orientation des germes est un élément important, puisqu'elle détermine en partie la texture de recristallisation. Chaque germe conserve le plus souvent l'orientation de la cellule dont il est issu. La distribution des orientations des germes est donc comprise dans la distribution des orientations dans l'état déformé. La recristallisation à partir de ces sites de germination a été observée dans divers métaux C.F.C. tels que le cuivre [46-48] et l'aluminium [49]. Les zones proches des joints de grains sont également des sites privilégiés de germination. La germination peut dans ce cas être définie par le mécanisme de SIBM (Strain Induced Boundary Migration) schématisé sur la [Figure I.8], souvent observé pour les faibles taux de déformation dans divers métaux tels que l'aluminium [49,50] ou le cuivre [51].



(a) (b)
Figure I.8 : a) Modèle de migration induite par la déformation ($E_1 > E_2$) [52], b) Schéma de la SIBM impliquant le développement coopératif de plusieurs sous-grains [53].

I.5.1.4. Croissance

Lorsqu'un germe atteint la taille critique et qu'il est suffisamment désorienté par rapport à son environnement, il peut croître dans la matrice sous l'action de l'énergie de déformation stockée. La vitesse de migration du joint qui sépare le germe potentiel en cours de croissance de la matrice écrouie dépend fortement :

- De la température,
- De la désorientation du grain en croissance avec la matrice,
- De la pureté du métal.

Dans l'aluminium par exemple, Liebmann et al. [54] ont observé une croissance préférentielle de germes présentant une désorientation de 38° autour d'un axe $\langle 111 \rangle$ commun au germe et à la matrice. Aust et Rutter [55] ont montré que l'on pouvait distinguer deux types de joints qui réagissent différemment en présence d'impuretés : les joints d'orientation quelconques et les joints "spéciaux". Ces derniers correspondraient à des désorientations remarquables dans le modèle du réseau de coïncidence ou à des orientations voisines de celles-ci (dans le cas des matériaux C.F.C, elles correspondent à une rotation voisine de 38° autour d'un axe $\langle 111 \rangle$ et 28° autour d'un axe $\langle 001 \rangle$). Les impuretés agissent à de très faibles concentrations (dizaines de ppm), et cette action est beaucoup plus forte sur les joints de désorientation quelconque que sur les joints "spéciaux". Ces derniers, par suite de leur structure moins désordonnée, seraient moins sensibles aux impuretés, qui y ségrégeraient.

I.6. Conclusion

Le comportement mécanique de ces aciers, mesure expérimentalement pour chaque nuance et chaque type de microstructure, ne fait encore l'objet que de modélisations simples et toujours a posteriori. Le développement de l'utilisation de ces aciers pour de nouvelles pièces et de nouvelles applications requiert des efforts importants.

La modélisation du comportement mécanique à partir de la seule connaissance de la microstructure. Ces modélisations posent encore de nombreux problèmes tels que la prise en compte correcte de la morphologie des phases durcissantes et de leur répartition

Enfin, les caractéristiques mécaniques doivent s'entendre au sens large, c'est à dire prendre en compte la description du comportement en sollicitation multiaxiale.



CHAPITRE II

*Généralités sur la régression
neuronale généralisée*

II.1. Introduction

Le comportement d'écoulement des matériaux est un facteur important qui doit être pris en compte dans la production réelle car il est étroitement lié à la microstructure et propriétés des produits [56,57]. Les propriétés mécaniques du produit [58-60]. Cependant, dans le processus de production actuel de compression, la structure interne et les propriétés du métal vont évidemment changer, entraînant comportement mécanique différent lors de la déformation ultérieure. Elle reflète la relation non linéaire entre la contrainte d'écoulement et les paramètres de contrôle, y compris la déformation, la vitesse de déformation et la température, qui est souvent déterminé par le modèle constitutif [61-63]. Le modèle constitutif peut être utilisé pour découvrir le mécanisme de déformation des matériaux et à développer le modèle dynamique de recristallisation.

Dans la présente étude, de nombreux modèles constitutifs, notamment l'analyse physique, les réseaux de neurones artificiels (RNA), et des modèles phénoménologiques pour différents matériaux ont été développés sur la base des tests de déformation à chaud [64-68]. Les modèles d'analyse physique doivent régresser de nombreux coefficients matériels, ce qui impose inévitablement de sérieuses contraintes sur leurs applications pratiques [69]. En raison de l'évitement effectif du contact avec le mécanisme physique et de la précision accrue, Les modèles constitutifs phénoménologiques, tels que le modèle Arrhenius à compensation de contrainte, nécessitent moins de constantes matérielles, et sont donc largement adoptées dans la pratique [70-74]. Afin d'améliorer la précision prédictive, de nombreux chercheurs ont modifié les modèles constitutifs phénoménologiques [75,76]. Cependant, s'agissant de données expérimentales et de matériaux différents ayant des états de traitement différents, les constantes de régression de l'analyse physique et des modèles phénoménologiques utilisant la régression méthode doivent être recalculées [77,78].

La méthode de modélisation RAN, sans calculs mathématiques spécifiques, fournit une nouvelle idée pour l'étude du comportement constitutif des matériaux. Cela sans calculs de régression répétés, et des prévisions de haute précision peuvent être obtenues par le RNA modèle [79-81]. Il a le grand avantage de pouvoir traiter des problèmes compliqués et non linéaires. Des relations, Ainsi le RNA a été largement utilisée pour prédire le comportement des matériaux métalliques en écoulement [82-84]. Néanmoins, l'incertitude et l'instabilité du RNA dans la prévision du comportement de l'écoulement limitent son utilisation. L'introduction d'un algorithme génétique (AG) peut supprimer cette limitation, améliorer sa stabilité et précision, et recherchez le poids et le seuil optimaux pour RNA en même temps.

II.2. Généralités sur les réseaux des neurones

L'informatique est la science du traitement automatique de l'information. Son développement est souvent confondu avec celui des machines de traitement : les ordinateurs. Depuis les débuts (ENIAC 1946) jusqu'à aujourd'hui, les ordinateurs sont devenus de plus en plus puissants. Cependant, cette augmentation de puissance ne permet pas de toujours résoudre les problèmes d'une application informatique dans un domaine particulier. L'idée s'est donc installée que ce n'était peut-être pas tant le matériel que le logiciel qui pêchait par manque de puissance. La construction de logiciels s'appuie sur plusieurs approches. Deux parmi les plus utilisées sont l'approche algorithmique et l'approche basée sur la connaissance. Une approche algorithmique nécessite l'écriture (avant la transcription dans un quelconque langage de programmation) du processus à suivre pour résoudre le problème. Lorsque le problème est complexe, ce peut être une étape coûteuse ou impossible. D'autre part, les ordinateurs sont des machines complètement logiques (et même binaires) qui suivent à la lettre chacune des instructions du programme. C'est un avantage lorsque tous les cas ont été prévus à l'avance par l'algorithmicien. La seconde approche possible est celle de l'intelligence artificielle (appelée IA par commodité), avec pour applications les plus connues les systèmes experts. Ici, la résolution du problème est confiée à un ensemble de règles données par l'expert humain du domaine. Il n'en demeure pas moins que toutes les règles doivent avoir été exprimées préalablement au traitement, et que le programme demeure binaire dans son exécution. Les cas qui n'ont pas été prévus par l'expert ne seront pas correctement traités. L'introduction de la logique floue ne change pas la nature des limitations d'emploi du programme : l'exécution reste totalement déterministe. En fait, l'approche basée sur la connaissance se limite à des domaines d'application où la modélisation de la connaissance, par exemple sous forme de règles, est possible. Ces domaines sont souvent ceux des sciences dites "exactes" comme l'électronique, la mécanique, la physique, etc., par opposition aux sciences dites "humaines" comme la médecine, la psychologie, la philosophie, etc., où la connaissance est plus empirique. L'IA se révèle donc être principalement un moyen commode de stocker de la connaissance sous forme explicite. Une troisième approche au traitement automatique de l'information semble donc s'offrir à nous, où l'on cherche à s'inspirer du traitement de l'information effectué par le cerveau. L'hypothèse principale, à la base de l'essor des réseaux de neurones artificiels, est que le comportement intelligent est sous-tendu par un ensemble de mécanismes mentaux. Ces mécanismes étant basés sur des processus neurophysiologiques, nous supposons donc que la structure du système nerveux central est à la base du développement d'un comportement intelligent. Remarquons que cette hypothèse n'a pas toujours eu cours. Ainsi, depuis l'antiquité, le siège des émotions a lentement migré depuis les pieds, vers l'estomac (qui se noue

face au danger), puis le cœur (qui s'accélère lors des passions) pour finir dans la boîte crânienne. [85,86]. La [Figure. II.1] reprend l'hypothèse proposée par de nombreux biologistes : pour recréer le comportement intelligent du cerveau, il faut s'appuyer sur son architecture, en fait, tenté de l'imiter.

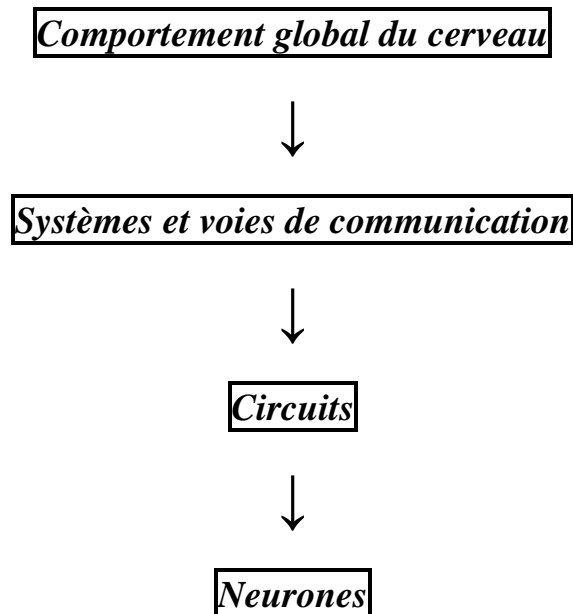


Figure II.1 : Hypothèse biologique de génération d'un comportement intelligent [86]

Les réseaux de neurones artificiels représentent une famille d'algorithmes informatiques inspirés des mécanismes de fonctionnement du cerveau. Ce sont des exemples typiques de systèmes parallèles distribués (SPD) car ils suggèrent qu'en l'absence d'une représentation explicite des symboles, l'intelligence peut apparaître comme le résultat de l'interaction d'un grand nombre de composants simples. Aujourd'hui de nombreux termes sont utilisés dans la littérature pour désigner le domaine des réseaux de neurones artificiels, comme connexionnisme ou neuro-mimétique. Pour notre part, il nous semble qu'il faut associer à chacun de ces noms une sémantique précise. Ainsi, les réseaux de neurones artificiels ne désignent que les modèles manipulés ; ce n'est ni un domaine de recherche, ni une discipline scientifique. Connexionnisme et neuro-mimétique sont tous deux des domaines de recherche à part entière, qui manipulent chacun des modèles de réseaux de neurones artificiels, mais avec des objectifs différents. L'intérêt des réseaux de neurones artificiels, dans le domaine des Sciences ne doit rien à la métaphore biologique, il est uniquement dû aux propriétés mathématiques spécifiques de ces réseaux. Les réseaux de neurones ont été développés pour résoudre les problèmes de reconnaissance de formes ou de mots, de décision, de mémorisation comme une alternative à l'intelligence artificielle, et comme on peut les utiliser pour la modélisation des systèmes et

processus. Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit.

II.2.1. Définition

Les réseaux de neurones artificiels sont devenus en quelques années des outils précieux dans des domaines très divers de l'industrie et divers services, des techniques d'analyse en provenance de l'apprentissage automatique (intelligence artificielle) et des bases de données. 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 ne doit rien à la métaphore biologique, il est uniquement dû aux propriétés mathématiques spécifiques de ces réseaux. Les réseaux de neurones ont d'abord été développés pour résoudre des problèmes de contrôle, de reconnaissance de formes ou de mots, de décision, de mémorisation comme une alternative à l'intelligence artificielle, et en relation plus ou moins étroite avec la modélisation de processus cognitifs (capable de connaître ou faire connaître) réels et des réseaux de neurones biologiques. [87].

Les réseaux de neurones artificiels s'inspirent du fonctionnement du cerveau et du système nerveux. Ils sont composés de simples éléments opérant en parallèle. Ces éléments s'inspirent des systèmes nerveux biologiques. Comme dans la nature, les fonctions neuronales sont largement déterminées par les connections entre ces éléments (ces connections sont appelées poids). Dans un réseau, les neurones sont disposés en couches : la couche d'entrée, la couche de sortie et un nombre variable de couches intermédiaires appelées couches cachées....Chaque neurone fonctionne indépendamment des autres de telle sorte que l'ensemble forme un système massivement parallèle. L'information est stockée de manière distribuée dans le réseau sous forme de coefficients synaptiques ou de fonctions d'activation, il n'y a donc pas de zone de mémoire et de zone de calcul, l'une et l'autre sont intimement liés. Un réseau ne se programme pas, il est entraîné grâce à un mécanisme d'apprentissage. Les tâches particulièrement adaptées au traitement par réseau de neurones sont: l'association, la classification, la discrimination, la prévision ou l'estimation, et la commande de processus complexes. [88] Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau.

II.2.2. Historique

- 1890 : W. James, célèbre psychologue américain introduit le concept de mémoire associative, et propose ce qui deviendra une loi de fonctionnement pour l'apprentissage sur les réseaux de neurones connue plus tard sous le nom de loi de Hebb.
- 1943 : J. Mc Culloch et W. Pitts laissent leurs noms à une modélisation du neurone biologique (un neurone au comportement binaire). Ceux sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique).
- 1949 : D. Hebb, physiologiste américain explique le conditionnement chez l'animal par les propriétés des neurones eux-mêmes. Ainsi, un conditionnement de type pavlovien tel que, nourrir tous les jours à la même heure un chien, entraîne chez cet animal la sécrétion de salive à cette heure précise même en l'absence de nourriture. La loi de modification des propriétés des connexions entre neurones qu'il propose explique en partie ce type de résultats expérimentaux.

II.2.3. Neurophysiologie

Le cerveau se compose d'environ 10^{12} neurones (mille milliards), avec 1000 à 10000 synapses (connexions) par neurone. Nous allons décrire succinctement l'élément de base du système nerveux central : le neurone.

L'étape suivante nous conduit à l'étude de petits réseaux de neurones, tels ceux impliqués dans les arcs réflexes. L'étude du mécanisme de la vision chez l'animal (et l'homme) permet d'appréhender les notions de messages somato-sensoriels, de réduction d'information, d'étages de traitement et de complexification de l'information [89].

▪ Le Neurone

Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former les dendrites. C'est par ces derniers que l'information est acheminée de l'extérieur vers le soma, corps du neurone. L'information traitée par le neurone chemine ensuite le long de l'axone (unique) pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms (10^{-9} m) entre l'axone du neurone afférent et les dendrites du Neurone efférent. La jonction entre deux neurones est appelée la synapse [Figure. II.2].

II.2.4. Neurone formel

Par définition un réseau neuro-mimétique est constitué de neurones formels et ceux-ci sont reliés entre eux via des flèches ce qui donne un graphe orienté. En comparaison avec son homologue biologique, le neurone formel est constitué de synapses qui sont représentées par des

flèches pondérées, d'un centre qui est l'équivalent du noyau cellulaire où se déroulent les activités mathématiques telles que la sommation des entrées ainsi que la fonction d'activation ($f(a)$) qui s'applique à la sommation des entrées pour être comparée au seuil d'activité "S", et d'une sortie qui est l'équivalent de l'axone. Chaque neurone formel est un automate complètement indépendant, dont l'état, une valeur scalaire, définit son activité ou activation a .




Figure II.2 : Schéma d'un neurone biologique [89]

II.2.5. Représentation mathématique

Un neurone est donc avant tout un opérateur mathématique, dont on peut calculer la valeur numérique par quelques lignes de logiciel. D'un point de vue mathématique, un neurone formel réalise donc une fonction linéaire. [Figure III.3].

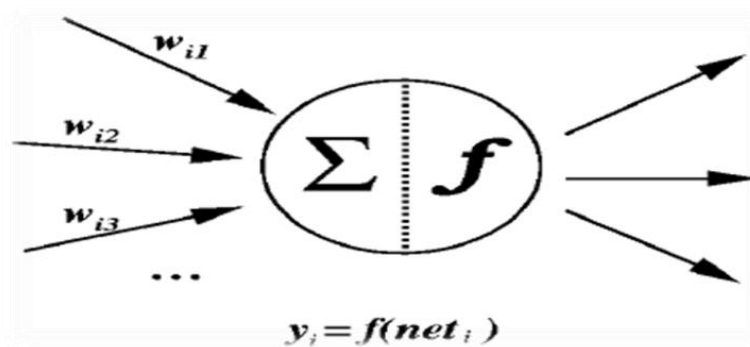


Figure II.3 : Structure d'un Neurone formel [90]

La [Figure. II.4] montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit des entrées en provenance de neurones amont. A chacune de ces entrées est associé un poids w abréviation (weight) représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones aval. A chaque connexion est associé un poids.

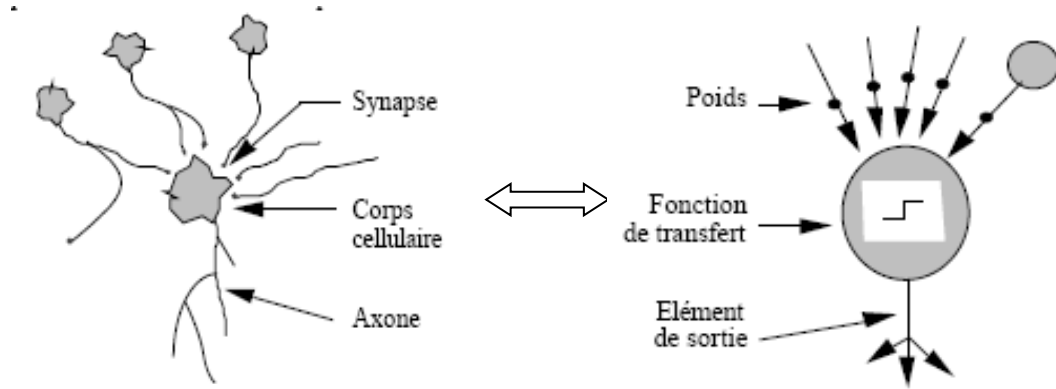


Figure II.4 : Structure d'un neurone artificiel.

La structure de la [Figure. II.4] peut être notée par la [Figure. II.5]. Pour le neurone d'indice i , les entrées sur celui-ci sont de poids W_{ij} alors que les connexions avals sont de poids W_{ki} .




Figure III.5 : Notation de la structure d'un neurone artificiel.

Le comportement de la cellule montrée sur la [Figure. II.5], consiste à calculer la somme pondérée des entrées (x_i) selon l'expression suivante :

$$f(a) = b + \sum_{i=1}^n (W_i \cdot x_i) \quad (1)$$

A partir de cette valeur, une fonction de transfert permet d'avoir l'état du neurone. C'est cette état ou valeur qui sera transmise aux neurones de sortie (**voir équation (2)**). Il existe plusieurs formes de fonctions de transfert comme le montre la [Figure. II.6].

La plupart de ces fonctions de transfert sont continués, offrant une infinité de valeurs possibles sur l'intervalle $[0, +1]$ (ou $[-1, +1]$)

$$y = \begin{cases} 1 & \text{si } f(s) \geq 0 \\ -1 & \text{si non} \end{cases} \quad (2)$$




Figure II.6 : Différents types de fonctions de transfert pour le neurone artificiel, a : fonction à seuil (S, la valeur du seuil), b : linéaire par morceaux, c : sigmoïde.

II.2.5.1. Architectures de réseaux de neurones

L'architecture des réseaux de neurones dépend des connexions entre les neurones qui composent le réseau, on distingue :

- a) Réseau multicouche (au singulier) : les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches avals **[Figure. II.7]**.

Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie.

Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées.




Figure II.7 : Réseau multicouche.

- b) Réseau à connexions locales : Il s'agit d'une structure multicouche, dont chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche aval **[Figure. II.8]**. Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique.




Figure II.8 : Réseau à connexions locales

- c) Réseau à connexions récurrentes : les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales [Figure. III.9].




Figure II.9 : Réseau à connexions récurrentes.

- d) Réseau à connexion complète : c'est la structure d'interconnexion la plus générale [Figure. II.10]. Chaque neurone est connecté à tous les neurones du réseau (et à lui-même).




Figure II.10 : Réseau à connexions complète

II.2.5.2. Fonctionnement du réseau

- **Le Perceptron**

Nous allons présenter le Perceptron (réseau simple formé par un seul neurone) comme le monte la [Figure. II.11]. Ce perceptron réalise une simple somme pondérée de ses entrées,

compare une valeur de seuil, et fourni une réponse binaire en sortie. Par exemple, on peut interpréter sa décision comme classe 1 si la valeur de x est +1 et classe 2 si la valeur de x est -1.




Figure II.11 : Le Perceptron.

Les connexions des deux entrées e_1 et e_2 au neurone sont pondérées par les poids w_1 et w_2 . La valeur de sortie du neurone est notée x . Elle est obtenue par la somme pondérée des entrées (a) et comparée à une valeur de seuil S . Pour mieux comprendre le comportement du perceptron, on considère un exemple simple qui traite des entrées logiques, Sachant que les poids du Perceptron à deux entrées sont : $w_1 = 0.5$, $w_2 = 0.2$ et que la valeur de seuil est $S = 0.0$, déterminons son comportement, sachant que les comportements du ET logique, OU logique et OU exclusif sont donnés par le tableau suivant:

<i>ET</i>			<i>OU</i>			<i>OU exclusif</i>		
e_1	e_2	x	e_1	e_2	x	e_1	e_2	x
1	1	1	1	1	1	1	1	1
1	-1	-1	1	-1	1	1	-1	-1
-1	1	-1	-1	1	1	-1	1	-1
-1	-1	-1	-1	-1	-1	-1	-1	1

Dans ces conditions, la sortie y sera : OU

En générale, le fonctionnement du réseau de neurone dépend de :

- La nature de ses entrées : elles peuvent être binaires ou réelles
- Prétraitement des entrées.
- Fonction d'activation (seuil) : elle représente la limite à partir de laquelle le neurone s'activera, la sortie de neurone dépend d'une fonction de transfert dont les principales sont représentées sur la [Figure. II.12].
- Fonction de sortie : Cette fonction calcule la sortie du neurone en fonction de son état d'activation.

II.2.5.3. Apprentissage des réseaux de neurones

L'apprentissage est un processus d'acquisition de connaissance sur l'environnement, la phase d'apprentissage est l'étape la plus importante dans les réseaux de neurones, elle est suivie

d'une mémorisation qui consiste à modifier les poids des connexions jusqu'à ce que ces derniers ne se modifient plus que d'une façon infime autrement dit jusqu'à l'obtention du comportement désiré [91]. Les procédures d'apprentissage sont conçues à partir de plusieurs lois comme la loi de Hebb, la loi de Widrow-Hoff et la loi de Grossber. Ces procédures peuvent se subdiviser, en deux grandes catégories : apprentissage supervisé et apprentissage non supervisé.

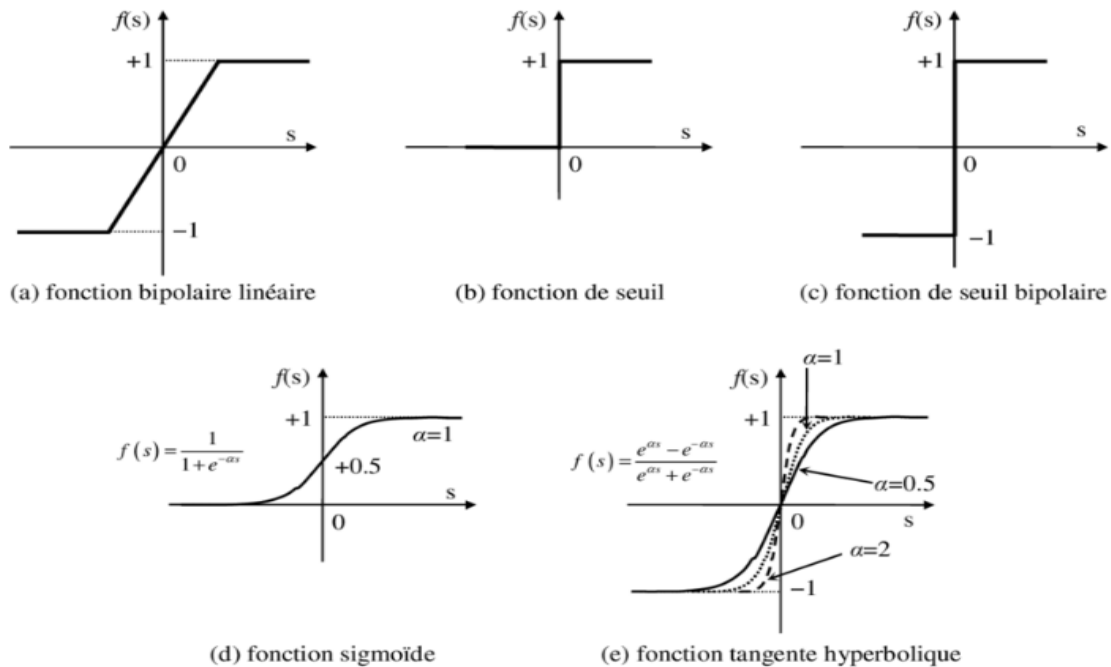


Figure II.12 : Fonction d'activation ou fonction de transfert.

▪ Apprentissage non supervisé

La [Figure. II.13] illustre la configuration d'un apprentissage non supervisé. La loi de Hebb (1949) s'applique aux connexions entre neurones. "Si 2 cellules sont activées en même temps alors la force de la connexion augmente".

La modification de poids dépend de la co-activation des neurones pré synaptique et post synaptique, comme le montre la table.1 de vérité, x_i et x_j sont respectivement les valeurs d'activation des neurones i, j et ∂W_{ij} (dérivée partielle du poids) correspond à la modification de poids réalisée.




Figure II.13 : Apprentissage non supervisé.

x_i	x_j	∂W_{ij}
0	0	0
0	1	0
1	0	0
1	1	+

Table.1

La loi de Hebb peut être modélisée par les équations suivantes ($w(t+1)$ est le nouveau poids, $w_{ij}(t)$ l'ancien) :


$$w_{ij}(t+1) = w_{ij}(t) + \partial w_{ij}(t) \quad (3)$$

$\partial W_{ij} = x_i \cdot x_j$ (La Co-activité est modélisée comme le produit des deux valeurs d'activation)

L'algorithme d'apprentissage modifie de façon itérative (petit à petit) les poids pour adapter la réponse obtenue à la réponse désirée. Il s'agit en fait de modifier les poids lorsqu'il y a erreur seulement :

Exemple d'application de l'algorithme d'apprentissage :

Choisissons pour les neurones un comportement binaire. Les entrées e_1 et e_2 sont considérées comme des neurones.



L'apprentissage est basé sur la base d'apprentissage décrite par la table suivante :

e_1	e_2	x	
1	1	1	(1)
1	-1	1	(2)
-1	1	-1	(3)
-1	-1	-1	(4)

1- Conditions initiale $s : \mu = +1$, les poids et le seuil sont nuls.

2- Calculons la valeur de x pour l'étape (1) :

3- $a = w_1 \cdot e_1 + w_2 \cdot e_2 - S = 0.0 \cdot 1 + 0.0 \cdot 1 - 0.0 = 0$ $a \leq 0 \Rightarrow x = -1$

4- La sortie est fautive, il faut donc modifier les poids en appliquant :

$$w_1 = w_1 + e_1 \cdot x = 0.0 + 1 \cdot 1 = 1$$

$$w_2 = w_2 + e_2 \cdot x = 0.0 + 1 \cdot 1 = 1$$

On passe à l'étape suivante (2) :

1- $a = 1 \cdot 1 + 1 \cdot -1 - 0.0 = 0$ $a \leq 0 \Rightarrow x = -1$

2- La sortie est fautive, il faut donc modifier les poids en appliquant :

$$w_1 = 1 + 1 \cdot 1 = 2$$

$$w_2 = 1 + 1 \cdot -1 = 0$$

L'étape (3) est correctement traité : $a = -2$ et $x = -1$ (la sortie est bonne). On passe directement, sans modification des poids à l'étape (4). Celui-ci est correctement traité. On revient alors au

début de la base d'apprentissage : l'étape (1). Il est correctement traité, ainsi que le second (2). L'algorithme d'apprentissage est alors terminé : toute la base d'apprentissage a été passée en revue sans modification des poids.

▪ **Apprentissage supervisé :**

La [Figure. II.14] illustre la configuration d'un apprentissage supervisé. La règle de Hebb ne s'applique pas dans certain cas, bien qu'une solution existe. Un autre algorithme d'apprentissage a donc été proposé, qui tient compte de l'erreur observée en sortie. L'algorithme d'apprentissage du Perceptron est semblable à celui utilisé par la loi de Hebb comme le montre la figure(16). La différence se situe au niveau de la modification des poids.

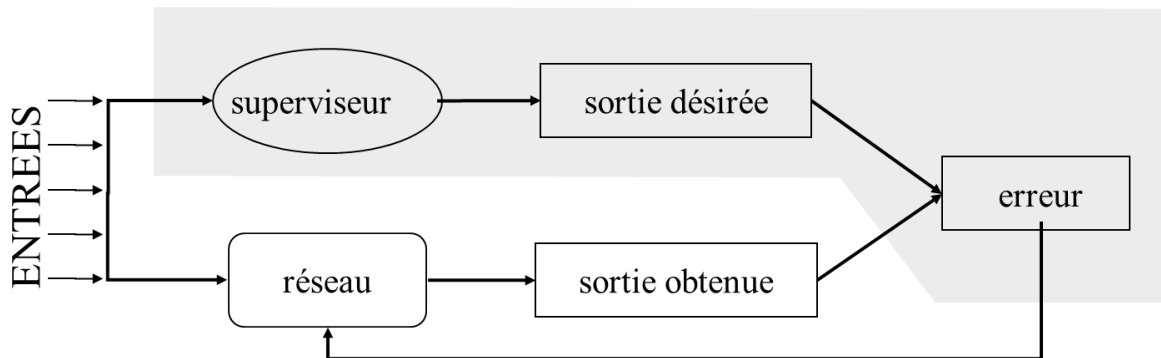


Figure II.14 : Apprentissage supervisé.

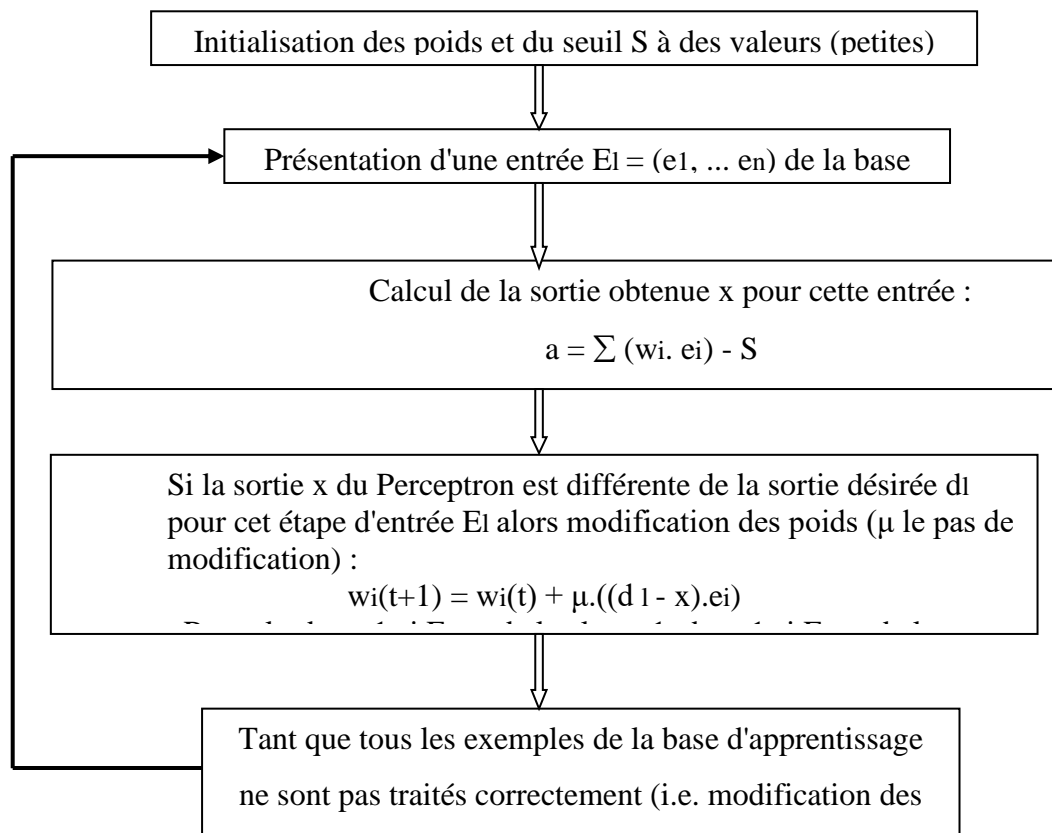


Figure II.15 : Algorithme d'apprentissage supervisé.

II.2.5.4. La convergence du perceptron

Au début de la convergence du Perceptron consiste à initialiser les petites valeurs aléatoires non nulle du poids synaptique W_i et le seuil S si l'erreur est minimale alors on dit que le réseau converge et la sortie est acceptable, si non il faut varier le vecteur d'entrée. La sortie est donnée par :

$$Y = f\left(\sum_{i=0}^{n-1} W_i X_i - S\right) \quad (4)$$

Avec S : représente le seuil

f : la fonction d'activation ou fonction de transfert, la convergence du perceptron vers la solution désirée dépend du bon choix de la fonction de transfert.

II.2.6. Réseaux multicouches

Le perceptron multicouche est un réseau comportant (L) couches comme le montre la [Figure. II.16], chaque neurone d'une couche étant totalement connecté aux neurones de la couche suivante. Chaque neurone (k) est un automate linéaire généralisé dont la fonction de transfert est bien choisie selon le domaine d'application et principalement selon une certaine expertise. L'algorithme d'apprentissage se fait par la méthode de rétro-propagation du gradient de l'erreur cette méthode consiste à trouver le poids des connexions minimisant l'erreur quadratique moyenne commise par le réseau sur l'ensemble d'apprentissage. L'efficacité de cette méthode d'apprentissage dépend, d'un grand nombre de paramètres que doit fixer l'utilisateur : le pas du gradient, les paramètres des fonctions de transferts, l'architecture du réseau ; nombre de couches, nombre de neurones par couche..., l'initialisation des poids... [92].

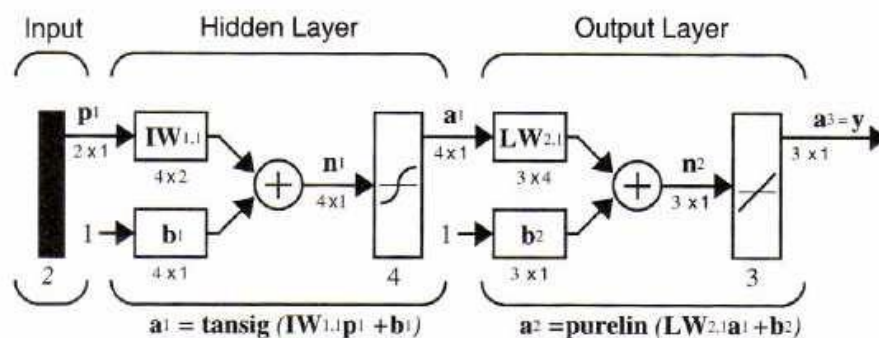


Figure II.16 : Réseau multicouches

II.2.7. Mise en œuvre des réseaux de neurones

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

1. 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. 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.
2. 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.
3. Il faut estimer enfin la qualité du réseau obtenu, en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage.

II.3. Application des réseaux de neurones en métallurgie

Les applications des réseaux de neurones en métallurgie commencent à apparaître depuis quelques années. L'analyse de la littérature scientifique sur ce sujet (Manjunath Patel et Prasad Krishna) montre en effet de nombreuses études sur la prédiction des paramètres de production optimum, sur la prédiction des propriétés mécaniques à différents stades du processus, la prédiction de la présence (ou l'absence de défauts) lors du contrôle des pièces, l'identification et la classification de défauts ou encore la planification de la production de pièces. On note aussi des études touchant au calcul du prix des pièces à l'étape du devis, la prédiction des microstructures ou la diminution des défauts à la solidification, on peut citer quelques exemples : [\[93-95\]](#)

- **Prédiction de défauts en moulage sable**

Dans une fonderie de fonte en sable à vert (Inde), un réseau de neurones (avec une couche de neurones cachés comprenant 23 neurones) a été généré (MATLAB Software) pour prédire l'apparition de défauts sur pièces à partir de 11 paramètres d'entrée (4 liés

au sable et 7 liés à la composition chimique et conditions de coulée). Le paramètre de sortie pour l'entraînement est la présence (1) ou l'absence de défauts (0) mais le résultat ensuite est une probabilité d'apparition de défaut entre 0 et 1. Il a été utilisé 65 jeux de données d'entrée et 19 jeux de données de tests (issues de 4 types de pièces différentes) pour valider les résultats. La prédiction est globalement bonne en particulier pour l'apparition de criques et de malvenues. Cependant, les auteurs (Ganesh G. Patil, Dr K.H. Inamdar) mentionnent que la prédiction des porosités gazeuses est moins bonne, sans doute liée à un trop faible nombre de données d'entrée.

- **Prédiction de micro-retassures dans une fonderie en Espagne**

Des travaux de (Igor Santos, Javier Nieves) menés dans une fonderie espagnole ont permis de bâtir un modèle de prédiction des micro-retassures sur des supports de disque de frein en fonte FGS pour l'industrie automobile (45 000 t/an). Ce modèle, développé sur 2 types de pièce, tient compte de 24 paramètres de production et intègre 4 niveaux de risques d'apparition de défauts internes (de 0 « aucun risque de défauts » à 3 « très fort risque de défauts »). Le réseau de neurones artificiels à 3 couches ; 24 neurones dans la couche d'entrée, 15 neurones en couche intermédiaire et 4 neurones en couche de sortie. La phase d'apprentissage a nécessité d'entrer les paramètres de production de 951 pièces (support de disques de frein) et le niveau de qualité (radiographie et contrôle ultra-sons). Les données d'entrée, au nombre de 24, comprennent des variables métal (composition, inoculant, température), des variables moule (type de sable, paramètres de moulage) et enfin des variables liées aux dimensions et à la géométrie des pièces. Les résultats semblent assez concluants (85 % de fiabilité), même s'ils ne sont pas parfaits car le modèle prédictif n'atteint pas les 100 % de fiabilité. Les auteurs du papier vont investiguer d'autres types de défauts de pièce.

- **Prédiction des propriétés mécaniques de pièces en fonte**

Dans la même fonderie que précédemment, un réseau de neurones a été testé pour prédire les propriétés mécaniques (R_m) à partir de 25 variables de production (composition chimique, vitesse de refroidissement, traitement thermique) et 11 références de pièces différentes totalisant 889 données d'entrée possibles. Différentes tailles (100, 200, ..., 800) de lots d'apprentissage ont été testés avec à chaque fois 66 % des pièces utilisés en apprentissage et 33 % utilisés en phase de test des performances de prédiction. Les meilleurs résultats en termes de réduction d'erreur de prédiction ont été obtenus avec un grand nombre de données (entre 700 et 800), mais pas avec la totalité de la base d'apprentissage.

- **Prédiction de comportement d'un alliage de magnésium en fonction de sa composition et de la vitesse de refroidissement**

Un réseau de neurone a été développé (L.A. Dobrzanski et M. Król) pour prédire les caractéristiques ($R_{p0.2}$, dureté et taille de grain) d'alliages de magnésium (Mg-Al-Zn) en fonction de la composition chimique et de la vitesse de refroidissement (0.6, 1.2 et 2.4 °C/s). Les auteurs ont utilisé 75 % des données expérimentales pour la base d'apprentissage et 25 % pour la base de tests avec 8 neurones d'entrée, 6 neurones cachés et 3 neurones de sortie. Il est noté que les résultats de prédiction sont très bons pour la résistance mécanique et la dureté et acceptable pour la taille de grain. Les propriétés mécaniques dépendent ainsi fortement de la vitesse de refroidissement et de la teneur en aluminium. La dureté, quant à elle, augmente avec la teneur en aluminium et décroît légèrement avec la vitesse de refroidissement.

- **Composite à matrice métallique en métallurgie des poudres**

Des composites à matrice métallique AlCuMg / B4Cp avec un renforcement allant jusqu'à 20% en poids et produits par la métallurgie des poudres ont fait l'objet d'un modèle de réseau neuronal artificiel (TemelVarol et AykutCanakci) pour prédire les effets des paramètres de fabrication (durée du broyage, pression de compactage, ...) sur la densité et la porosité des composites AlCuMg / B4Cp. L'erreur en pourcentage absolu moyen n'excède pas 1,6 %.

- **Prédiction de la modification du silicium pour un alliage Al-Si-Cu**

Les points de transformation du diagramme d'analyse thermique d'un alliage AlSi7Cu3 avec différentes teneurs en strontium (de 8 à 96 ppm) ont été utilisés (R. Francis et J Sokolowski) pour prédire le niveau de modification au strontium (SiML pour Silicon Modification Level selon l'ASM) qui varie de 1 à 6. Les résultats sont relativement bons avec une base d'apprentissage limité à 47 échantillons.

II.4. Conclusion

Dans ce chapitre, les notions principales aux réseaux de neurones et leur apprentissage ont été présentées. A cet effet, il est à rappeler qu'un réseau de neurones n'est rien d'autre qu'un outil informatique et mathématique intelligent d'approximation de fonctions basé sur l'interconnexion de plusieurs entités élémentaires appelées neurones. Dans ce contexte, et En raison du grand nombre de paramètres d'entrée, du caractère souvent non linéaire de ces paramètres et des surfaces de réponses souvent complexes, la métallurgie offre un vaste champ d'application aux réseaux de neurones. Le plus délicat est sans doute de pouvoir extraire une base de données pertinente pour la phase d'apprentissage. En effet, il suffit bien souvent qu'un paramètre très influent (la température, l'épaisseur de pièce, la teneur en carbone, différentes contraintes soit oublié pour que la qualité des réponses fournies soit médiocre ou ne puisse pas se généraliser à d'autres cas. De ce point de vue, la simulation numérique du processus permet de générer off line une base d'apprentissage importante et semble être une solution intéressante pour la modélisation du comportement mécanique d'un acier allié, dont le chapitre IV fait objet.



CHAPITRE III

*Modélisation par un modèle de
régression neuronale généralisée*

III.1. Introduction

Pour optimiser la technologie d'une opération de formation de métal, il est nécessaire d'expérimenter les relations constitutives reliant des variables de processus telles que la température, le taux de déformation et la déformation à la contrainte d'écoulement du matériau déformant [96]. Une modélisation appropriée des courbes de déformation à chaud constitue la première étape d'une simulation mathématique des processus de déformation à chaud, tels que le forgeage à chaud et le laminage à chaud. Une approche plus largement adoptée consiste à obtenir des équations constitutives à partir de courbes de flux déterminées expérimentalement [97]. Par conséquent, de nombreux chercheurs ont optés pour des méthodes empiriques permettant de relier les variables de processus à la contrainte d'écoulement [98-100].

Plusieurs groupes de recherche ont essayé de développer des équations constitutives de matériaux et ont suggéré leurs propres formulations en regroupant les données mesurées expérimentalement dans une seule équation. Ont développé une équation constitutive qui suppose que la dépendance de la contrainte sur la déformation, la vitesse de déformation et la température peut être décomposée de manière multiplicative en trois fonctions distinctes comprenant cinq constantes à déterminer par les données expérimentales obtenues pour un matériau spécifique. Le modèle traditionnel de type Arrhenius est en faveur de la prédiction de la contrainte d'écoulement à une contrainte fixe. En raison de l'absence d'effet de la déformation sur la contrainte d'écoulement, il ne peut pas satisfaire le besoin de simulations numériques de divers processus de formage à chaud. Ce modèle constitutif amélioré était remarquable pour sa précision supérieure et appliqué avec succès à l'acier. L'objet de cette étude est de construire le comportement constitutif équation de description qui représente les relations de contrainte, de température, le taux de contrainte et la contrainte d'écoulement.

Afin de réaliser les simulations numériques de la réponse aux déformations et d'établir les paramètres de traitement à chaud d'un acier HSLA. Le comportement en déformation par compression de l'acier HSLA a été étudié aux températures de 700 °C à 1050 °C avec un pas de 50 °C et les vitesses de contrainte de $7,34 \cdot 10^{-4} \text{ s}^{-1}$, $2,9 \cdot 10^{-3} \text{ s}^{-1}$ et $1,46 \cdot 10^{-2} \text{ s}^{-1}$ sur une machine de compression. Sur la base de l'analyse de l'effet de la déformation, de la température et de la vitesse de déformation sur la contrainte d'écoulement, des caractéristiques d'adoucissement de type recristallisation dynamique de la courbe contrainte-déformation à pic unique ont été identifiées.

Le modèle traditionnel de type Arrhenius est favorable à la prédiction de la contrainte d'écoulement pour une contrainte fixe et ne peut pas satisfaire le besoin de simulations

numériques de divers processus de déformation à chaud en raison de l'absence d'effet de la déformation sur la contrainte d'écoulement. Un modèle de type Arrhenius amélioré avec une série de coefficients variables en fonction de la déformation (les constantes de matériau n et α et le facteur de structure A , et l'énergie d'activation de la déformation Q) permettant de prédire la contrainte d'écoulement lors de la compression à chaud. L'application a été démontrée dans ce travail pour un acier HSLA.

Des études récentes [101–103] ont montré que la méthodologie des réseaux de neurones peut être adoptée pour résoudre des problèmes difficiles à résoudre à l'aide de méthodes traditionnelles, et ont démontré que les techniques RNA peuvent modéliser les courbes de flux de déformation à chaud de différents matériaux. Après avoir déterminé les courbes de variation de la contrainte en fonction de la déformation pour différentes vitesses de déformation et différentes températures le premier objectif est l'étude du comportement de l'acier microallié CMn (Nb-Ti-V) et la détermination des différents paramètres rhéologiques, qui permettraient de déterminer la loi de comportement de l'alliage étudié.

Le deuxième objectif de cette étude est de prédire la contrainte d'écoulement de l'acier microallié CMn (Nb-Ti-V) en utilisant une approche de réseau neuronal.

III.2. Détermination expérimentale de la contrainte d'écoulement

III.2.1. Procédures matérielles et expérimentales

Le test de la compression à chaud est le plus approprié de tous les tests de déformation pour l'étude des paramètres rhéologiques, car il permet d'obtenir une déformation homogène dans l'échantillon à partir d'une amélioration des conditions de lubrification jusqu'à l'interface échantillon-tas de la machine.

Le test de la compression permet également d'obtenir des déformations de l'ordre de l'unité. Le dispositif de compression à chaud est illustré à la [Figure III.1] Il permet également l'extinction de l'échantillon à la fin du test. Le chauffage se fait par rayonnement dans un tube de quartz, ce qui garantit le meilleur compromis entre flexibilité d'utilisation et vitesse de montée en température grâce à six lampes infrarouges placées au centre d'une antenne parabolique. La zone de chauffage est plus grande avec une température homogène.

Le test de la compression est contrôlé par ordinateur et assure le réglage de la position de croisement lors de la montée en température, de telle sorte que la couche supérieure reste toujours en contact avec l'échantillon. Un programmeur géré par microprocesseur permet de

réaliser des cycles thermomécaniques complexes. Les températures maximales admissibles dans ce modèle sont de l'ordre de 1300 ° C. La force est mesurée en continu. Lorsque cela dépasse un certain seuil, le croisement est automatiquement levé pour annuler la force. De cette façon, l'effet de dilatation est compensé. Les échantillons utilisés sont cylindriques avec un diamètre de 7,8 mm et une hauteur de 11,3 mm. Avant la déformation, nos échantillons sont chauffés à l'intérieur du dispositif de compression jusqu'à la température de test, à une vitesse de 100° C par minute.



Figure III.1 : Dispositif de compression à chaud.

La température est contrôlée par deux thermocouples placés l'un au-dessus et l'autre au-dessous de l'échantillon. Dès que le test est terminé, la partie supérieure de la machine se soulève automatiquement pour nous permettre de faire tremper nos échantillons très rapidement à l'aide d'un doigt actionné de l'extérieur.

Les essais de compression ont été effectués à des températures comprises entre 700 °C et 1050 °C, pour des vitesses de déformation allant de (0,000734, 0,0029 et 0,0146 S⁻¹), en fonction du cycle illustré à la [Figure III.2]. Ce cycle a pour but de: une précipitation progressive des éléments additifs.

Après homogénéisation de la structure par chauffage à 1300 ° C suivi d'une trempe à l'eau, les éprouvettes sont fixées dans le dispositif de compression où elles subissent un traitement de mise en solution à 1050 °C. Ensuite, ils sont refroidis à la température de déformation, comprise entre 700 °C et 1050 °C. [Tableau III.1] Afficher les compositions chimiques détaillées et les

[Figures (III.3), (III.4)] présentent la microstructure initiale. La taille moyenne des grains est d'environ 40 μm .

Tableau III.1 : Compositions chimiques détaillées

% C	% S	% P	% Al	% Si	% Mn	% V	% Nb	% Ti
0.044	0.012	0.012	0.017	0.22	1.45	0.053	0.080	0.041




Figure III.2 : Procédures expérimentales pour les essais de compression de l'acier micro allié CMn (Nb-Ti-V)




Figure III.3 : Microstructure initiale des échantillons.




Figure III.4 : Echantillon refroidi après austénitisation à 1300 ° C.

III.2.2. Résultats expérimentaux

Les courbes contrainte-déformation obtenues par compression à chaud sont montrées dans les [Figures (III.5), (III.6) et (III.7)] à différentes températures (de 700°C à 1050°C) et vitesses de déformation ($0,0029 \text{ S}^{-1}$, $0,0146 \text{ S}^{-1}$ et $0,000734 \text{ S}^{-1}$). Leurs allures nous suggère de les classer en trois types a, b et c, en fonction des différentes gammes de température :

- La contrainte augmente rapidement et décroît avec une pente importante (700 et 750°C) (type a)
- La contrainte augmente rapidement jusqu'à atteindre un palier (800 et 850°C) (type b)
- La contrainte augmente jusqu'à un maximum puis décroît plus ou moins rapidement pour atteindre un état stationnaire (Domaine austénitique) (type c)




Figure III.5 : Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation $0,0146 \text{ S}^{-1}$

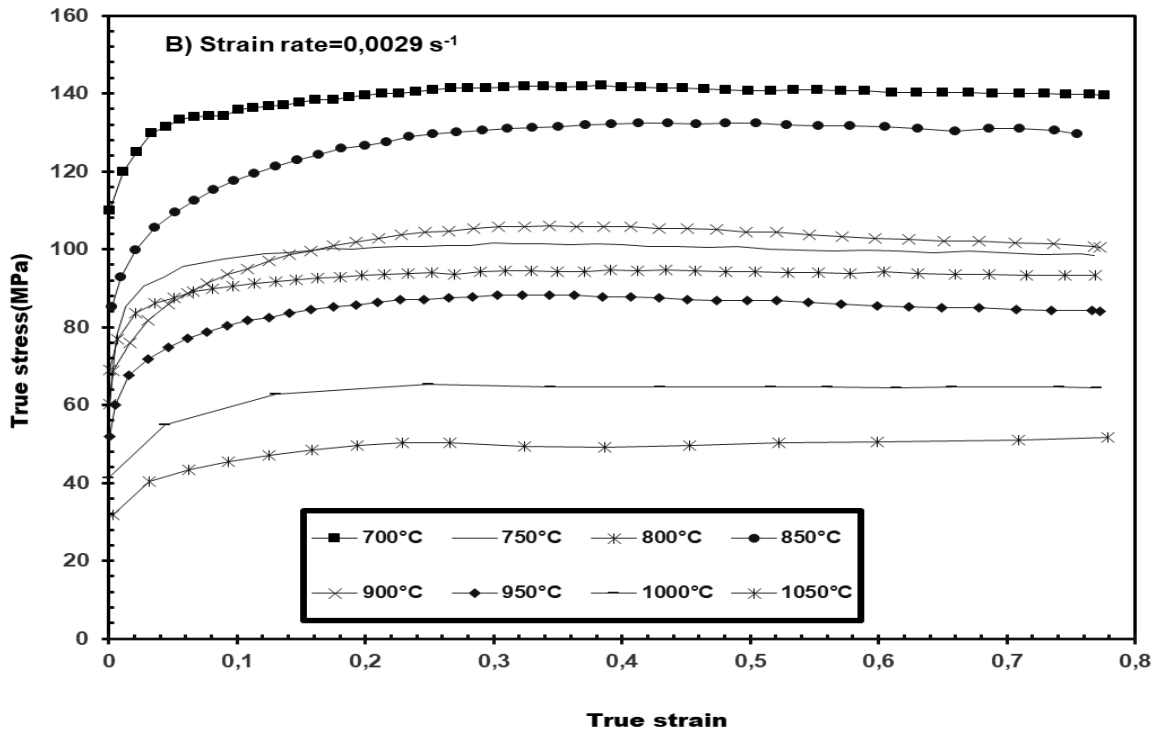


Figure III.6 : Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,0029 S⁻¹

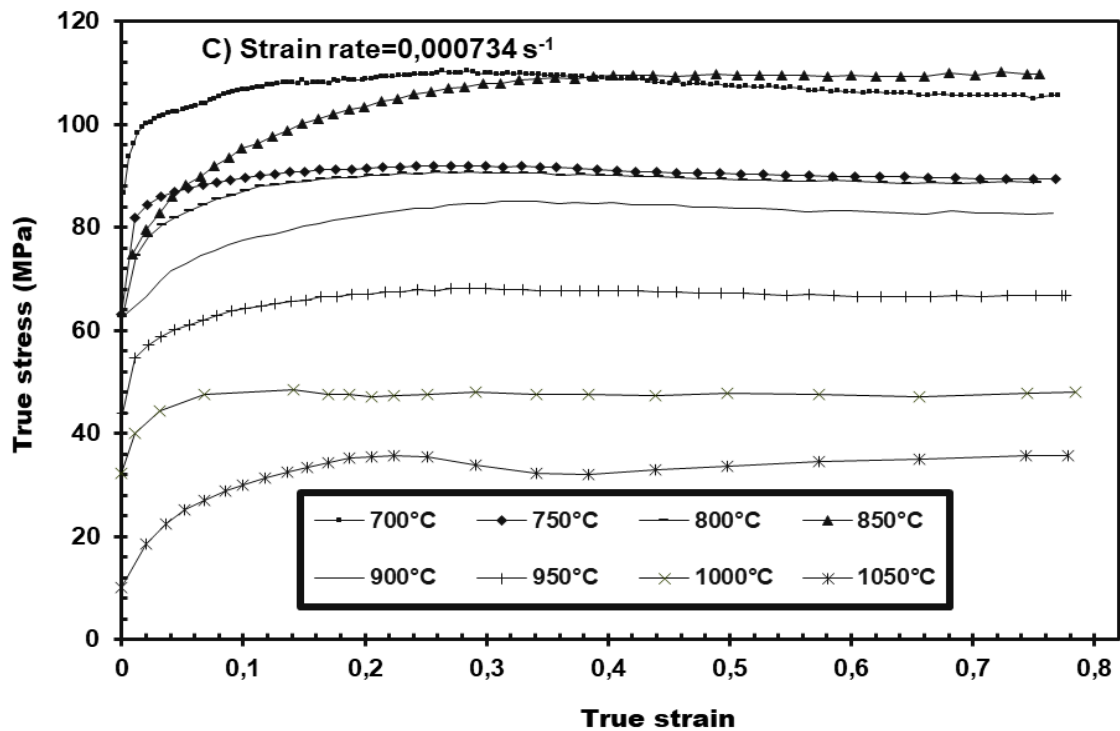


Figure III.7 : Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,000734 S⁻¹

III.3. Modèle RNA

III.3.1. Développement du modèle RNA

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.

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 de neurones cachés en nombre fini, possédant tous la même fonction d'activation et un neurone de sortie linéaire

En plus, les réseaux de neurones nécessitent moins de paramètres ajustables (les poids des connexions) que d'autres outils mathématiques couramment utilisés. 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 est de trouver une relation entre un ensemble de sorties dans un processus donné, et l'ensemble des entrées correspondant à travers les mesures effectuées. On suppose que cette relation existe malgré que :

- Les mesures sont en nombre fini,
- Elles sont certainement entachées de bruit,
- Toutes les variables qui déterminent le résultat du processus ne sont pas forcément mesurées.

De manière générale, un réseau de neurones permet de faire un meilleur usage des mesures disponibles que les méthodes d'approximation non linéaires conventionnelles [104]. Ce gain peut être considérable lorsque le processus à modéliser dépend de plusieurs variables tels que dans le cas des procédés de mise en forme là où il intervient plusieurs types de non-linéarités et plusieurs paramètres matériels et technologiques.

Les étapes de la conception d'un réseau de neurone

1. Choix et préparation des échantillons

Comme dans les cas d'analyse de données, cette étape est cruciale et va aider le concepteur à déterminer le type de réseau le plus approprié pour résoudre son problème. La façon dont se présente l'échantillon conditionne : le type de réseau, le nombre de cellules d'entrée, le nombre de cellules de sortie et la façon dont il faudra mener l'apprentissage, les tests et la validation.

2. Elaboration de la structure du réseau

La structure du réseau dépend étroitement du type des échantillons. Il faut d'abord choisir le type de réseau : un perceptron standard, un réseau de Hopfield, un réseau à décalage temporel (TDNN), un réseau de Kohonen, un ARTMAP etc... Dans le cas du perceptron par exemple, il faudra aussi choisir le nombre de neurones dans la couche cachée.

3. Apprentissage

L'apprentissage consiste tout d'abord à calculer les pondérations optimales des différentes liaisons, en utilisant un échantillon. La méthode la plus utilisée est la rétropropagation : on entre des valeurs des cellules d'entrée et en fonction de l'erreur obtenue en sortie (le delta), on corrige les poids accordés aux pondérations. C'est un cycle qui est répété jusqu'à ce que la courbe d'erreurs du réseau ne soit croissante (il faut bien prendre garde ne pas sur-entraîner un réseau de neurones qui deviendra alors moins performant). Il existe d'autres méthodes d'apprentissage telles que le quickprop par exemple.

4. Validation et Tests

Alors que les tests concernent la vérification des performances d'un réseau de neurones hors échantillon et sa capacité de généralisation, la validation est parfois utilisée lors de l'apprentissage. Une fois le réseau calculé, il faut toujours procéder à des tests afin de vérifier que notre réseau réagit correctement.

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 [105].
- 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.

Dans le domaine de génie des matériaux, 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.

III.3.2. Description générale de l'algorithme de calcul (Levenberg-Marquardt)

Dans ce travail, un modèle RNA pour les comportements d'écoulement de compression de l'acier microallié CMn (Nb-Ti-V) a été développé. Les variables d'entrée sont la température (T), la vitesse de déformation ($\dot{\epsilon}$), la déformation (ϵ). La contrainte d'écoulement (σ_f) est la variable de sortie, cette dernière (σ_f) dépend des variables indépendantes (ϵ , $\dot{\epsilon}$, T) pendant le processus de travail à chaud. Par conséquent, la couche d'entrée est composée de trois neurones représentant ces variables. La contrainte d'écoulement est représentée par le neurone dans la couche de sortie. MATLAB a été utilisé pour former le réseau de neurones.

Il utilise l'algorithme de Levenberg-Marquardt pour l'entraînement du réseau, cet algorithme est connu pour être très efficace dans la résolution de problèmes d'optimisation non linéaire.

Communément appelé LM, Levenberg-Marquardt fait référence à une implémentation particulière de l'algorithme de propagation inverse qui utilise une variation de la méthode de Newton. Lorsque l'algorithme de descente raide est basé sur une expansion de série Taylor de premier ordre, la méthode de Newton utilise une série Taylor de second ordre:

$$F(x_{k+1}) \approx F(x_k + \Delta x) \approx F(x_k) + g_k^T \Delta x_k + \frac{1}{2} \Delta x_k^T A_k \Delta x_k \quad (14)$$

En prenant le gradient de l'équation (14) par rapport à Δx_k et en le fixant à zéro donne:

$$g_k + A_k \Delta x_k = 0 \quad (15)$$

Puis résoudre pour Δx_k

$$\Delta x_k = -A_k^{-1} g_k \quad (16)$$

Donc, définissant maintenant la méthode de Newton comme:

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (17)$$

Où le gradient et la toile de jute sont définis comme **EQ (18)** et **EQ (19)**, respectivement:

$$g_k \equiv \nabla F(s) \Big|_{x = x_k} \quad (18)$$

$$A_k \equiv \nabla^2 F(s) \Big|_{x = x_k} \quad (19)$$

En supposant que $F(x)$ est la somme des fonctions des carrés:

$$F(x) = \sum_{i=1}^{IV} v_i^2(x) = v^T(x) v(x) \quad (20)$$

Le jième élément du gradient étant

$$[\nabla F(x)]_j = \frac{\partial}{\partial x_j} F(x) = 2 \sum_{i=1}^{IV} v_i(x) \frac{\partial}{\partial x_j} v_i(x) \quad (21)$$

Et écrire le gradient sous forme matricielle:

$$\nabla F(x) = 2J^T(x)v(x) \quad (22)$$

Avec :

$$J(x) = \begin{bmatrix} \frac{\partial}{\partial x_1} v_1(x) & \frac{\partial}{\partial x_2} v_1(x) & \dots & \frac{\partial}{\partial x_n} v_1(x) \\ \frac{\partial}{\partial x_1} v_2(x) & \frac{\partial}{\partial x_2} v_2(x) & \dots & \frac{\partial}{\partial x_n} v_2(x) \\ \dots & \dots & \dots & \dots \\ \frac{\partial}{\partial x_1} v_N(x) & \frac{\partial}{\partial x_2} v_N(x) & \dots & \frac{\partial}{\partial x_n} v_N(x) \end{bmatrix}$$

La méthode de Newton est de second ordre et donc exige également la matrice hessienne.

L'élément k, j de la Hessian:

$$[\nabla^2 F(x)]_{k,j} = \frac{\partial^2}{\partial x_k \partial x_j} F(x) = 2 \sum_{i=1}^N \left\{ \frac{\partial}{\partial x_k} v_i(x) \frac{\partial}{\partial x_j} v_i(x) + v_i(x) \frac{\partial^2}{\partial x_k \partial x_j} v_i(x) \right\} \quad (23)$$

Ou sous forme de matrice

$$\nabla^2 F(x) = 2J^T(x)J(x) + 2S(x) \quad (24)$$

Avec :

$$S(x) = \sum_{i=1}^{IV} v_i(x) \nabla^2 v_i(x) \quad (25)$$

Si $S(x)$ est supposé petit, alors le Hessien devient :

$$\nabla^2 F(x) = 2J^T(x)J(x) \quad (26)$$

On utilise la méthode de Gauss-Newton, la substitution des EQ 26 et EQ 22 en EQ 17 donne :

$$x_{k+1} = x_k - [2J^T(x_k)J(x_k)]^{-1} 2J^T(x_k)v(x_k) = x_k - [J^T(x_k)J(x_k)]^{-1} J^T(x_k)v(x_k) \quad (27)$$

Comme on peut le voir sur **l'EQ 27**, seul le Jacobien reste dans la méthode de Gauss-Newton comme le Hessien a été éliminé et l'efficacité de calcul a été améliorée maintenant que les dérivées secondes ne sont pas calculées. Un problème peut se poser en ce qui concerne la matrice approximative de Hesse, $H = J^T J$ peut ne pas être réversible. On utilise la représentation suivante :

$$G = H + \mu I \quad (28)$$

Les valeurs propres, λ_i et les vecteurs propres de G sont les mêmes que H . Si μ est augmenté de telle sorte que $(\lambda_i + \mu) > 0$ pour tout i , alors G sera défini positif et donc inversible. C'est cette dernière modification qui aboutit à l'algorithme de Levenberg-Marquardt **[108]** donné par équation(29) ou l'équation (30).

$$x_{k+1} = x_k - [J^T(x_k)J(x_k) + \mu_k]^{-1} J^T(x_k)v(x_k) \quad (29)$$

$$\Delta x_k = -[J^T(x_k)J(x_k) + \mu_k]^{-1} J^T(x_k)v(x_k) \quad (30)$$

Lorsque $\mu\kappa$ augmente, l'algorithme se rapproche de la méthode de descente brutale et si μ if est réduit à zéro, l'algorithme devient Gauss-Newton. L'algorithme LM est donc similaire à l'algorithme de rétro-propagation standard, sauf que le Jacobien est maintenant déterminé en calculant les dérivées des erreurs par rapport aux poids et biais par opposition à trouver les dérivées des erreurs quadratiques. Donc le Jacobéen pour un Levenberg-Marquardt multicouche devient:

$$\mathbf{J}(\mathbf{x}) = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_{1,1}^1} & \frac{\partial e_{1,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{1,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{1,1}}{\partial b_1^1} & \dots \\ \frac{\partial e_{2,1}}{\partial w_{1,1}^1} & \frac{\partial e_{2,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{2,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{2,1}}{\partial b_1^1} & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{S^M,1}}{\partial w_{1,1}^1} & \frac{\partial e_{S^M,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{S^M,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{S^M,1}}{\partial b_1^1} & \dots \\ \frac{\partial e_{1,2}}{\partial w_{1,1}^1} & \frac{\partial e_{1,2}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{1,2}}{\partial w_{S^1,R}^1} & \frac{\partial e_{1,2}}{\partial b_1^1} & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix} \quad (31)$$

De plus, les différentes sensibilités de l'algorithme LM sont données par :

$$S_{i,h}^{\sim m} = \frac{\partial v_h}{\partial n_{i,q}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \quad (32)$$

Avec :

$$h = (q - 1)S^M + k \quad (33)$$

Les éléments du Jacobéen pour les poids sont donnés maintenant par

$$[\mathbf{J}]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \times \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = S_{i,h}^{\sim m} \times \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = S_{i,h}^{\sim m} \times a_{j,q}^{m-1} \quad (34)$$

Or pour

$$[\mathbf{J}]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial b_l^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \times \frac{\partial n_{i,q}^m}{\partial b_l^m} = S_{i,h}^{\sim m} \times \frac{\partial n_{i,q}^m}{\partial b_l^m} = S_{i,h}^{\sim m} \quad (35)$$

Comme précédemment, la sensibilité Marquardt pour la couche finale a également trouver

$$\tilde{S}_{i,h}^M \equiv \frac{\partial v_h}{\partial n_{i,q}^M} = \frac{\partial e_{k,q}}{\partial n_{i,q}^M} = \frac{\partial}{\partial n_{i,q}^M} (t_{k,q} - a_{k,q}^M) = \frac{\partial a_{k,q}^M}{\partial n_{i,q}^M} = (-f^m(n_{i,q}^m) \text{ pour } i = k ; 0 \text{ pour } i \neq k) \quad (36)$$

Maintenant, le réseau peut être initialisé avec

$$\tilde{S}_q^M = -\dot{F}^M(n_q^M) \quad (37)$$

Où le côté droit est défini précédemment par l'égaliseur (48). Les colonnes de la matrice sont rétropropagées à travers le réseau en utilisant EQ (49) pour produire une ligne de Jacobine. Les colonnes peuvent également être rétropropagées ensemble en utilisant

$$\tilde{S}_q^M = -\dot{F}^M(n_q^M)(W^{m+1})\tilde{S}_q^{m+1} \quad (38)$$

Les matrices de sensibilité totale Marquardt pour chaque couche sont formées en augmentant les matrices de chaque entrée

$$\tilde{S}_q^M = [\tilde{S}_1^M | \tilde{S}_2^M | \dots | \tilde{S}_Q^M] \quad (39)$$

En résumé, Levenberg-Marquardt est réalisé de manière itérative comme suit:

- Attribuer des poids et des biais initiaux (généralement de petits nombres aléatoires)
- L'entrée est transmise par le biais du réseau
- Calculer la somme des erreurs quadratiques à l'aide de l'égaliseur (20)
- Calculer le jacobéen, EQ (32), et les sensibilités en utilisant EQ (38) puis EQ (33)
- Trouver les éléments du jacobéen en utilisant EQ (35) et EQ (36) (c.-à-d. Modifier les poids et les biais)
- Résoudre pour Δx_k en utilisant EQ (31)
- Trouver les nouvelles erreurs quadratiques, si elles sont plus petites, calculer $\mu\nu$ et laissez $x_{k+1} = x_k + \Delta x_k$, si non calculez $\mu\nu$ et retrouver Δx_k .

▪ Autres améliorations

Bien que le Levenberg-Marquardt augmente de manière significative le taux de formation, il ne traite pas à lui seul plusieurs des difficultés évoquées précédemment. La vitesse d'entraînement et la performance globale peuvent être améliorées par plusieurs autres moyens.

- **Variables impliquées**

S'il existe une connaissance préalable des relations possibles entre des variables d'entrée particulières et la sortie attendue, est plusieurs fois bénéfique d'inclure ces relations par la modification des entrées. En cas contraintes d'écoulement, il est connu que le log de la contrainte peut être lié linéairement au log de la vitesse de déformation. Donc, cela peut faire sens de fournir au réseau des souches logarithmiques ou des taux de déformation en plus ou à la place des souches et des souches les taux.

- **Normalisation**

Échelle ou normalisation supplémentaire, EQ (40), les variables d'entrée et / ou les valeurs d'apprentissage pour aller de 0 à 1 ou -1 à 1 peut permettre aux fonctions de transfert de mieux gérer les données, mais avec la complication supplémentaire du retraitement la sortie du réseau formé. Bien sûr, les requêtes ultérieures du réseau nécessitent une normalisation entrées et sorties démoralisantes.

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} - \frac{1}{2} \quad (40)$$

- **Arrêt anticipé**

La technique d'arrêt précoce divise les données en tiers; cible, validation et test. Les cibles sont utilisées comme avant avec l'erreur étant déterminée. De plus, l'erreur sur l'ensemble de validation est également trouvée. Pendant l'entraînement, l'erreur sur les cibles diminuera toujours, mais une fois que le sur-ajustement commence à se produire, l'erreur sur la validation ensemble augmentera. La formation sera arrêtée après un certain nombre d'époques qui continuent à produire cette divergence. L'ensemble de test peut en outre être utilisé pour comparer un modèle à un autre (c'est-à-dire un nombre varié de neurones, couches, etc.).

Le sur-ajustement se produit généralement en raison du plus grand nombre de paramètres, de poids et biais, que nécessaire pour ajuster les données. Un arrêt précoce ne permet pas de réduire le nombre de paramètres

III.3.3. Méthode rétropropagation

Les réseaux de rétropropagation à rebours (RRP) sont couramment utilisés pour l'approximation des fonctions. La présentation ci-dessus décrit la partie du réseau en aval. La rétropropagation fait référence à la méthode d'ajustement ou de correction des poids et des biais

pour produire une sortie de réseau conforme à l'entraînement. Il convient de souligner que la performance du réseau dépend intrinsèquement de la qualité de l'entraînement. L'ensemble de formation doit représenter de manière adéquate le système ou les courbes à modéliser. Un autre La caractéristique de FBP est due à l'algorithme de formation lui-même, les fonctions de transfert utilisées doivent être différentiables.

- **Algorithme de rétropropagation**

Une itération de l'algorithme de base peut être représentée par EQ(41) :

$$x_{k+1} = x_k - \alpha_k g_k \quad (41)$$

Où x_k est un vecteur des poids et des biais actuels, g_k est le gradient actuel et α_k est le taux d'apprentissage. Le site exige un indice de performance pour déterminer dans quelle mesure la sortie du réseau se rapproche de l'entraînement. Comme indiqué précédemment, l'idée générale est de diminuer l'erreur avec l'erreur quadratique moyenne (EQM) utilisé dans ce cas. Si le réseau est fourni avec un ensemble de formation représenté par :

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (42)$$

Où P_Q est une entrée vectorielle dans le réseau et t_Q est une sortie cible correspondante. L'erreur quadratique moyenne peut être calculée en comparant la sortie du réseau avec la cible et est donnée par :

$$F(x) = E(e^2) = E[(t - a)^2] \quad (43)$$

Les sensibilités doivent maintenant être calculées. La relation récurrente qui existe entre une couche et la couche précédente l'une est l'idée derrière la rétropropagation. Pour calculer la relation récurrente, on utilise la matrice jacobéenne :

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \dots & \dots & \dots & \dots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (44)$$

Une expression pour la matrice est requise, donc en considérant l'élément i,j de la matrice :

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = \frac{\partial}{\partial n_j^m} \left(\sum_{l=1}^{s^m} w_{i,l}^{m+1} a_l^m + b_i^{m+1} \right) = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial}{\partial n_j^m} f^m(n_j^m) \quad (45)$$

Et

$$\left. \frac{\partial f^m(n_j^m)}{\partial n_j^m} \right| = \frac{\partial}{\partial n_j^m} f^m(n_j^m) \quad (46)$$

et en remplaçant l'EQ 46 par l'EQ 45, on obtient :

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = w_{i,j}^{m+1} f^m(n_j^m) \quad (47)$$

Ce qui permet d'écrire le Jacobéen comme :

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \mathbf{W}^{m+1} \dot{\mathbf{F}}^m(\mathbf{n}^m) \quad (48)$$

où

$$\dot{\mathbf{F}}^m(\mathbf{n}^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \dots & 0 \\ 0 & f^m(n_2^m) & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & f^m(n_{s^m}^m) \end{bmatrix} \quad (49)$$

La relation de récurrence pour les sensibilités peut maintenant être rédigée sous la forme suivante :

$$s^m = \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \left(\frac{d\mathbf{n}^{m+1}}{d\mathbf{n}^m} \right)^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \dot{F}^m(\mathbf{n}^m)(W^{m+1})^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} \quad (50)$$

ou

$$s^m = \dot{F}^m(\mathbf{n}^m)(W^{m+1})^T s^{m+1} \quad (51)$$

À ce stade, on peut facilement reconnaître que les sensibilités se retrouvent par rétropropagation de chacune des dernières couches à la première. Le point de départ, s^m , doit également être trouvé en utilisant la dernière couche.

$$s_i^M = \frac{\partial \hat{F}}{\partial n_i^M} = \frac{\partial}{\partial n_i^M} (t - a)^T (t - a) = \frac{\partial}{\partial n_i^M} \sum_{j=1}^n (t_j - a_j)^2 = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (52)$$

Maintenant, en utilisant la relation :

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial}{\partial n_i^M} f^M(n_i^M) = \dot{f}^M(n_i^M) \quad (53)$$

En remplaçant :

$$s_i^M = -2(t_i - a_i) \dot{f}^M(n_i^M) \quad (54)$$

Ou sous forme de matrice :

$$s^M = -2 \dot{F}^M(\mathbf{n}^M)(t - a) \quad (55)$$

Enfin, toutes les équations nécessaires à la réalisation de la rétropropagation ont été développées.

L'entraînement lui-même est le processus d'applications répétées de l'algorithme de rétropropagation jusqu'à ce que l'erreur devienne acceptable ou que d'autres critères sont remplis.

Chaque itération d'entraînement est appelée une époque. En résumé,

La rétropropagation s'effectue par les moyens suivants :

Attribuer des poids et des biais initiaux (généralement de petits nombres aléatoires)

- L'entrée est transmise à travers le réseau
- Sur la base de l'erreur produite, la sensibilité est calculée à la dernière couche en utilisant l'EQ 55
- La sensibilité de chaque couche antérieure est calculée en utilisant le QE 52
- Les poids sont mis à jour en utilisant le QE 44
- Les biais sont mis à jour en utilisant le QE 45

III.3.4. Modèle RNA

Les données totales du modèle RNA, qui consistent en 1168 ensembles de données entrée-sortie, sont dérivées des 24 courbes de contrainte-déformation. Ces données ont été subdivisées en trois groupes. Le premier groupe comprend 590 ensembles de données et est utilisé pour former le réseau. Le deuxième groupe est composé de 287 et est utilisé pour évaluer la généralisation. Enfin, le dernier groupe, constitué de 291 ensembles de données, est utilisé pour valider le modèle RNA.

Dans la recherche du meilleur modèle RNA, il faut déterminer le nombre approprié de couches cachées et le nombre de neurones dans chacune. Cela se fait par la formation et le test de différentes structures de réseau et de celle qui convient, à déterminer en évaluant la tolérance entre les données prévues et les données expérimentales. L'erreur quadratique moyenne, MSE, ainsi que la montre l'équation (11) a été introduite pour évaluer les performances de formation et de généralisation de RNA [106].

Les exercices d'entraînement et de test, comme indiqué dans le paragraphe précédent, ont abouti à un réseau de deux couches cachées de dix neurones chacune. Ce réseau a produit une valeur MSE de 0,15, comme indiqué sur la [Figure III.18]. Le réseau résultant est présenté sur la [Figure III.19].

Le modèle RNA résultant des sections précédentes est utilisé ci-après pour prédire les conditions de déformation, ce qui correspond aux points de test et aux points d'entraînement précédents. Les [Figure III.10.a, b, c et d] montrent les valeurs prédites et expérimentales des contraintes d'écoulement, ainsi que leurs relations de corrélation. La ligne la mieux ajustée correspond à la ligne à 45 degrés. Les chiffres montrent que toutes les erreurs entre les valeurs de contrainte d'écoulement prévues et observées sont inférieures à 5%. De même, le coefficient de corrélation résultant entre les valeurs observées et prédites est 0,9999 et 0,9998 pour les ensembles de données d'apprentissage et de test, respectivement [108].

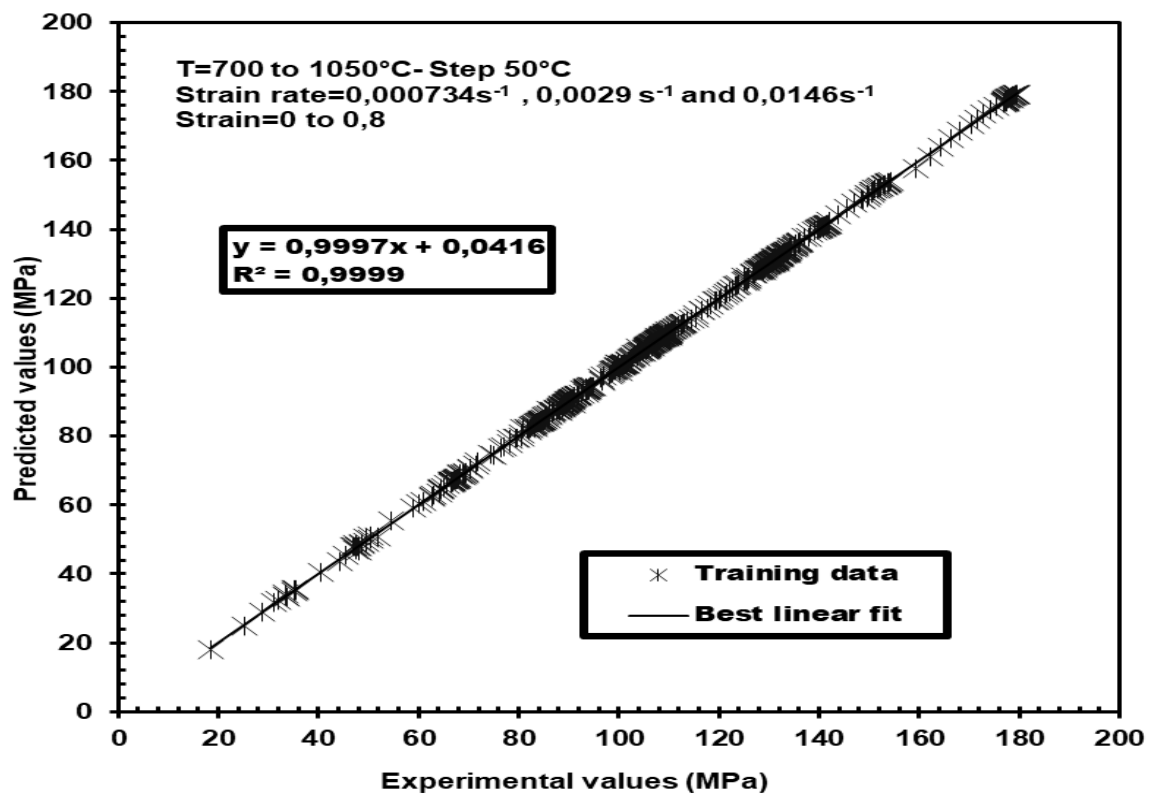


Figure III.10.a : Contrainte d'écoulement mesurée face au prédite pour l'ensemble d'entraînement




Figure III.10.b : Contrainte d'écoulement mesurée face au prédite pour l'ensemble de test




Figure III.10.c : Contrainte d'écoulement mesurée face au prédite pour l'ensemble de validation

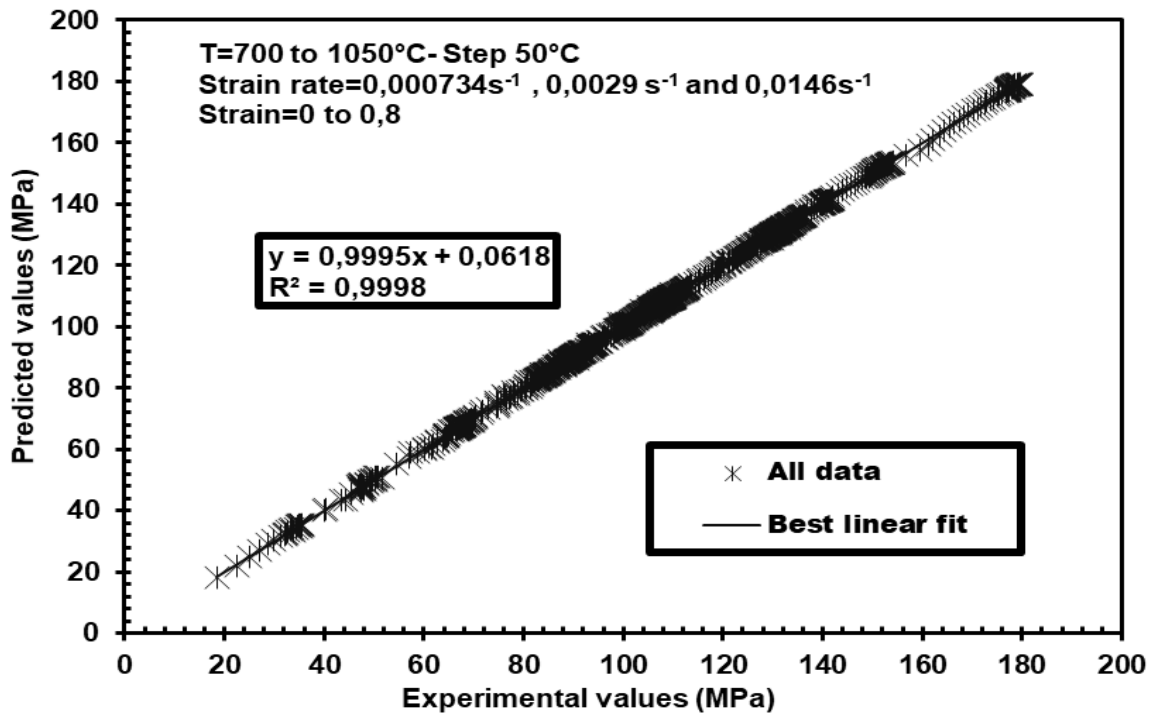


Figure III.10.d: Contrainte d'écoulement mesurée face au prédite pour l'ensemble des données.

Comme indiqué ci-dessus, un coefficient de corrélation élevé indiquerait une bonne capacité de prédiction du modèle. De la même façon, AAR est utilisé comme autre test d'ajustement de qualité, comme illustré à la [Figure III.11]. La valeur AAR s'est environ à 0,31% pour tous les ensembles de données. Cette faible erreur indiquerait la grande précision du modèle RNA pour les ensembles de données de test et de formation.




Figure III.11: L'erreur relative absolue (ARE) et l'erreur relative absolue moyenne (AAR) de l'ensemble des données

Les [Figures (III.12), (III.13)] présentent les résultats de l'entraînement, des tests et de validation de quatre courbes de déformation sous contrainte avec une erreur relative maximale de 3,1% pour les conditions expérimentales présentées dans les figures correspondantes. Ces résultats confirment et donc valident la capacité d'apprentissage et de la généralisation du modèle RNA.




Figure III.12: Valeurs expérimentales et prévues de la contrainte d'écoulement pour la vitesse de déformation $\dot{\epsilon} = 0,0029 \text{ S}^{-1}$ et $T = 700 \text{ }^{\circ}\text{C}$




Figure III.13: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes valeurs de vitesses de déformation à $T = 750 \text{ }^{\circ}\text{C}$

Une comparaison entre les courbes expérimentales initiales et les valeurs de contrainte-déformation prédites par RNA est présentée aux [Figures (III.14), (III.15) et (III.16)]. Les données prédites montrent que le modèle RNA est capable de reproduire avec précision les règles d'évolution qui régissent les relations contrainte-déformation.

Lorsque la température augmente, la contrainte diminue. Par conséquent, le modèle RNA obtenu était capable de suivre les régions de ramollissement dynamique et le travail de durcissement de l'acier microallié CMn (Nb-Ti-V).




Figure III.14: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 900^{\circ}\text{C}$




Figure III.15: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 950^{\circ}\text{C}$




Figure III.16: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 1050^{\circ}\text{C}$

La [Figure III.27] montre l'évolution de la contrainte maximale en fonction de la vitesse de déformation et de la température. Ces courbes sont caractérisées par une diminution de la contrainte entre 700°C et 750°C , suivie d'une augmentation entre 750°C et 850°C . Enfin, au-delà de 850°C , la contrainte maximale diminue rapidement. En effet, la contrainte maximale diminue au début du domaine biphasé, puis augmente avec l'augmentation de la fraction volumique de la phase austénitique pour atteindre un maximum au point AC3. Des mesures de dilatomètre ont été effectuées sur notre matériau pour déterminer les points de transformation allotropique $\text{AC1} = 710^{\circ}\text{C}$ et $\text{AC3} = 850^{\circ}\text{C}$.




Figure III.17: Valeurs maximales expérimentales et prévues des contraintes pour différentes températures et vitesses de déformation

III.4. Comparaisons entre les résultats des modèles développés

Les contraintes d'écoulement ont été calculées à l'aide d'une équation semi-empirique pour différentes déformations, vitesses de déformation et températures. Les valeurs calculées de la contrainte d'écoulement ont été comparées aux valeurs mesurées correspondantes de cette dernière en utilisant un paramètre statistique: carré du coefficient de corrélation (R-carré). On constate que la valeur du carré r entre les valeurs de contrainte d'écoulement calculées et mesurées était de 0,9917.

La valeur R^2 du modèle RNA s'est avérée être de 0,9998 après un grand nombre d'entraînements et de simulations du modèle RNA avec différents nœuds, de couche cachée et des taux d'apprentissage variables. Nous avons utilisé une structure de réseau **3-10-10-1** pour obtenir une grande précision.

Les valeurs de la contrainte d'écoulement calculées par le modèle d'Arrhenius amélioré, le modèle RNA et mesurées sont montrées respectivement sur les [Figures (III.18) – (III.13)]. On peut voir sur ces figures qu'il existe une proximité entre les valeurs prévues et mesurées de la contrainte d'écoulement aux températures 700°C à 1050°C.

Le modèle RNA est plus précis que le modèle semi-empirique car la non-linéarité des données expérimentales est bien prise en compte dans le modèle RNA.




Figure III.18: Valeurs expérimentales et prévues de la contrainte d'écoulement pour une vitesse de déformation de $0,0029\text{ S}^{-1}$ à $T = 700\text{ °C}$




Figure III.19: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 700\text{ °C}$




Figure III.20: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 750\text{ °C}$




Figure III.21: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 850\text{ °C}$




Figure III.22: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 950\text{ °C}$




Figure III.23: Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à T = 1050 ° C

III.5. Conclusion

Dans la présente étude, le comportement à l'écoulement d'un acier microallié a été étudié en utilisant des tests de compression à chaud la plage de température de 700 ~ 1050 °C et une vitesse de déformation plage de 0,0029 S⁻¹, 0,0146 S⁻¹ et 0,000734 S⁻¹. Le travail principal est de construire deux modèles rhéologiques qui représentent les relations entre déformation, température, vitesse de déformation et contrainte d'écoulement.

L'application d'un modèle amélioré de type Arrhenius (énergie d'activation de la déformation Q , constantes matérielles a , et n , et le facteur de structure A) avec une série de coefficients variables en fonction de la déformation pour prédire la contrainte d'écoulement lors de la compression à chaud de notre acier a été démontré dans ce travail. Les comparaisons entre les résultats prévus et expérimentaux montrent que, dans le pire des cas, l'erreur relative dans l'estimation de la contrainte d'écoulement est 6%, et l'erreur relative moyenne pour un taux de déformation fixe est 2,34%.

Un modèle basé sur des réseaux de neurones artificiels a été développé afin de prédire la réponse à la déformation de l'acier microallié soumis à une compression à chaud dans les mêmes conditions citées en ci-dessus.

La variable de sortie du modèle RNA est la contrainte d'écoulement par compression et les variables d'entrée sont la température, la vitesse de déformation et la déformation. L'algorithme de Levenberg-Marquardt a été utilisé pour entraîner le modèle. L'architecture de réseau résultante est composée de trois neurones dans la couche d'entrée, suivis de deux couches cachées composées de dix neurones et se terminant par une couche de sortie d'un neurone.

La valeur R^2 du modèle RNA s'est avérée être de 0,9998 après un grand nombre d'entraînements et de simulations du modèle RNA avec différents nœuds, deux couches cachées et des taux d'apprentissage variables. Nous avons utilisé une structure de réseau **3-10-10-1**(voir annexe).

Le modèle du RNA prédit bien le comportement de la contrainte d'écoulement et suit avec précision le ramollissement dynamique, la localisation des régions de l'écoulement et le durcissement dû au travail de déformation du matériau. Nous pouvons conclure avec certitude que le modèle proposé peut prédire de manière fiable la réponse à la déformation de l'acier microallié CMn (Nb-Ti-V) sous compression à chaud mieux que le modèle d'Arrhenius amélioré.



Conclusion générale



Le comportement à chaud d'un acier microallié a été étudié en utilisant des essais de compression à chaud dans une plage de température de 700 ~ 1050 °C avec un pas de 50°C et des vitesses de déformation 0,0029 S⁻¹, 0,0146 S⁻¹ et 0,000734 S⁻¹. L'objectif principal est de construire deux modèles rhéologiques qui représentent les relations entre déformation, température, vitesse de déformation et contrainte d'écoulement.

Initialement un modèle amélioré de type Arrhenius avec une série de coefficients variables en fonction de la déformation pour prédire la contrainte d'écoulement lors de la compression à chaud de notre acier a été détaillé dans ce travail.

Dans une deuxième étape une nouvelle méthodologie pour la prédiction de la contrainte d'écoulement a été proposée qui utilise des réseaux neuronaux artificiels. Cette approche aide non seulement à réduire l'expérimentation nécessaire pour caractériser le comportement d'écoulement d'un matériau, mais réduit également les problèmes associés aux modèles constitutifs empiriques et semi-empiriques qui impliquent l'évaluation d'un grand nombre de constantes. Le réseau de neurones formés est capable de prédire très précisément la contrainte d'écoulement, la précision étant comparable à celle des prédictions des approches analytiques et semi-empiriques existantes. Les prédictions ont également indiqué une déformation à haute température clairement pertinente sur les caractéristiques, telles que l'écroutissage, et la recristallisation, sous l'influence de divers paramètres de procédé.

Un modèle basé sur des réseaux de neurones artificiels (RNA) a été développé afin de prédire la réponse à la déformation de l'acier microallié soumis à une compression à chaud. Les données expérimentales regroupées des courbes Contrainte-déformation dans une plage de température (700 à 1050°C) pour des valeurs de vitesse de déformation de 0,0029 S⁻¹, 0,0146 S⁻¹ et 0,000734 S⁻¹. La variable de sortie du modèle de RNA est la contrainte d'écoulement par compression et les variables d'entrée sont la température, la vitesse de déformation et la déformation. L'algorithme de Levenberg-Marquardt a été utilisé pour entraîner le modèle sous MATLAB.

L'architecture de réseau résultante est composée de trois neurones dans la couche d'entrée, suivis de deux couches cachées composées de dix neurones et se terminant par une couche de sortie d'un neurone.

Le modèle de RNA prédit bien le comportement de contrainte dû à l'écoulement et suit avec précision le ramollissement dynamique, les régions de localisation d'écoulement et le

durcissement au travail du matériau déformant. Nous pouvons conclure avec certitude que le modèle proposé peut prédire de manière fiable la réponse à la déformation de l'acier microallié CMn (Nb-Ti-V) sous compression à chaud.

Les comparaisons entre les résultats prévus et expérimentaux montrent que, dans le pire des cas, l'erreur relative dans l'estimation de la contrainte d'écoulement, l'erreur relative moyenne pour un taux de déformation fixe et la valeur R^2 des deux modèles sont regroupées dans le tableau suivant :

<i>Modèle</i>	<i>Erreur relative maximale</i>	<i>Erreur relative moyenne</i>	<i>R²</i>
<i>RNA</i>	3%	0,31%	0,9998

Comme conclusion, le modèle de régression neuronale généralisée a été développé pour prévoir la courbe contrainte-déformation pour l'acier microallié étudié, sachant les conditions de son procédé de production. Le modèle de prévision a présenté une bonne approximation entre les données expérimentales et les valeurs de sorties prévues par le réseau de neurones, mieux que le modèle d'Arrhenius amélioré. Par conséquent, ce modèle peut être employé avec un degré satisfaisant d'exactitude et de fiabilité des aciers HSLA produits dans des conditions similaires.

Une fois notre modèle est établi, on peut l'utiliser selon différents points de vue, selon le domaine d'utilisation :

- Fournir des bibliothèques de modèles exécutables pour des utilisateurs.
- Analyse de sensibilité afin d'étudier le comportement du modèle en faisant varier les entrées.
- Exécution du modèle en mode inverse pour retrouver des entrées en fixant les sorties attendues.



Références bibliographiques

- [1] T.C. Lowe, Computer simulation of deforming processing, *J. Metals*, 40 (1988) 6 11.
- [2] L. Anand, Constitutive equations for the rate-dependent deformation of metals at elevated temperatures, *ASME J. Eng. Mats. Techn.*, 104 (1982) 1 12 17.
- [3] A.K. Ghosh, A physically-based constitutive model for metal deformation, *Acta metall.*, 28 (1980) 1443 1465.
- [4] A.K. Miller and O.D. Sherby, A simplified phenomenological model for non-elastic deformation prediction of pure aluminum behavior and incorporation of solute strengthening effects, *Acta metall.*, 26 (1978) 289 304
- [5] G.A. Henshall and A.K. Miller, The influence of solutes on flow stress plateaus, with emphasis on back stresses and the development of unified constitutive equations, *Acta metall.*, 37 (1989) 12693 2704,
- [6] P.S. Follansbee and U.F. Kocks, A constitutive description of the deformation of copper based on the use of the mechanical threshold stress as an internal state variable, *Acta metall.*, 36 (1988) 81- 93.
- [7] R.O. Adebajo and A.K. Miller, Modelling effects of recrystallization on the flow behaviour during hot deformation by modifying an existing constitutive model Part 1. Conceptual development of the MATMOD-ReX equations, *Mats. Sci. Eng.*, A119 (1989) 87 94.
- [8] J.G. Lenard, F. Wang and G. Nadkarni, The role of constitutive formulation in the analysis of hot rolling, *Trans. ASME, J. Eng. Mats. Tech.*, 109 (1987) 343 349.
- [9] C.S. Hartley and R. Srinivasan, Constitutive equations for large plastic deformation of metals, *ASME J. Eng. Mats. Tech.*, 105 (1983) 162 167.
- [10] C. Ouchi, T. Okita, T. Ichihara and Y. Ueno, Hot deformation strength of austenite during controlled rolling in a plate mill, *Trans. ISIJ*, 20 (1980) 833 841.
- [11] P.J. Wray, Modelling of roll force behaviour in the finishing train of a hot strip mill, *Proc. 28th Mechanical Working and Steel Processing Conf- Proc. AIME Conf, Chicago*, (1986), pp. 155 160.
- [12] P.J. Wray, Onset of recrystallization during the tensile deformation of austenite iron at intermediate strain rates, *Met. Trans.*, 6A (1975) 1197 1203.
- [13] Y. Saito, T. Enami and T. Tanaka, The mathematical model of hot deformation resistance with reference to microstructural changes during rolling in plate mill, *Trans. ISIJ*, 25 (1985) 1146 1155.
- [14] J.R. Klepaczko, A practical stress strain strain rate-temperature constitutive relation of the power form, *J Mech. Work Tech.* 15 (1987) 143 165.

- [15] P. Dadras and J.F. Thomas, Jr., Characterization and modelling for forging deformation of Ti 6Al 2Sn 4Zr 2Mo 0.1Si, *Met. Trans.*, 12A (1981) 1867-1876.
- [16] A. Darsouni, B. Bouzabata, F. Montheillet, rhéologie des alliages biphasés, Réunion. Group. MECAMAT, p. 36. école centrale de paris, 28-29 mai (1998).
- [17] C.M. Sellars and W.J. McG. Tegart, Hot Workability, *Int. Met. Rev.*, 17 (1972) 1-24.
- [18] K. Osakada and G.B. Yang, Neural networks for process planning of cold forging, *Ann. CIRP*, 40 (1991) 243-246.
- [19] A.Y.C., Nee, X.H. Shah and A.N. Poo, An AI/neural network based solution for cutting tool selection. 7th Int. Conf. on Computer Aided Production Eng., Edinburgh, (1991), Elsevier, Amsterdam, pp. 251-260.
- [20] G.H. James, P.C. Michael, W.H. James, Y. Sudhakar, Allen Herman, S. Ruofei, Ranjithan and W. James, Engineering applications of neural networks, *J. Intelligent Manufacturing*, 4 (1993) 1-21.
- [21] M.J. Willis, G.A. Montague and A.J. Morris, Modelling of industrial processes using artificial neural networks, *Comput. Control Eng. J.*, 3 (1992) 113-117.
- [22] G. David Garson, Interpreting neural network connection weights, *AI Expert* (April 1991) 47-51.
- [23] D. Bailey and D. Thompson, How to develop neural network applications, *AI Expert* (June 1990) 38-47.
- [24] D. Philip Wasserman, *Neural Computing Theory and Practice*, Van Nostrand Reinhold, New York, (1989).
- [25] Jim Howell, Inside a Neural Network, *AI Expert* (Nov. 1990) 28-33.
- [26] Using NWorks, *NeuralWorks Professional II/Plus User Manual*, Neural Ware Inc., USA.
- [27] LeCun, Y. (1985). Une procédure d'apprentissage pour réseau à seuil asymétrique. In *Proceedings of Cognitive*.
- [28] Rumelhart, D., Hinton, G., and Williams, R. (1986). Learning internal representation by error propagation, volume 1, chapter Parallel distributed processing: explorations in the microstructure of cognition. MIT Press.
- [29] D.J. NAYLOR "Review of international activity on microalloyed engineering steels", *Ironmaking and Steel Making* 1989, vol 16, N° 4
- [30] MARK GRUMBACH "Aciers d'usage général", *techniques de l'ingénieur*, 1991
- [31] PIERO BUFALINI and all "Accelerated cooling after control rolling of line-pipe plates influence of process conditions on microstructure and mechanical properties", *Proceeding*

- of International Conférence on Technology and Application of HSLA Steels, october **1983**
- [32] PHILIPPE CHARLIER "Aciers à Dispersoïdes", techniques de l'ingénieur, **1991**
- [33] G. MURRY "Aciers micro-alliés, aciers à dispersoïdes pour pièces forgées" revue de traitement thermique, **1990**
- [34] L.J. CUDDY "Grain Refinement of Nb Steels by Control of Recrystallization during Hot Rolling", Metallurgical Transactions A, vol 15A, January **1984**
- [35] S. LIU "Weldability of Steels", Metals Handbook
- [36] F.B. PICKERING "The Spectrum of Microalloyed, High Strength Low Alloy Steels", Proceeding of International Conférence on Technology and Application of HSLA Steels, october **1983**
- [37] TADAAKI TAIRA and all "Development of Super Tough Acicular Ferrite Steel for Line-pipe – Optimization of Carbon and Niobium Content in Low-Carbon Steel, Proceeding of International Conférence on Technology and Application of HSLA Steels, october **1983**
- [38] T.R. Thomson, R.M Hobbs "Dual Phase Steels Production and Formability", Mémoires Scientifiques. Revue de métallurgie, avril **1980**
- [39] J. Malcolm Gray and all "Property Improvements in Bars and Forgings Through Microalloying and Inclusion Engineering", Proceeding of International Conférence on Technology and Application of HSLA Steels, october **1983**
- [40] Alexander D. Wilson "Characterizing Inclusion Shape Control in Low Sulfur CMn- Cb Steels", Proceeding of International Conférence on Technology and Application of HSLA Steels, october **1983**
- [41] F.Haessner, Recrystallization of Metallic materials, editor F.Haessner, second edition, Riederer Verlag, Stuttgart, p. 1 (**1978**).
- [42] P. Paillard, Thèse de doctorat, Université de Paris-Sud, (**1994**).
- [43] H.Hu, International Symposium, Edited by N. Hansen, D. Juul Jensen, T. Leffers, B. Ralph, Roskilde, Denmark, p. 75 (**1986**).
- [44] R.D. Doherty, D.A. Hughes, F.J. Humphreys et al. Current issues in recrystallization: a review. Materials Science and Engineering A, Vol. A238 p. 219 (**1997**).
- [45] J.M. Haudin et F. Montheillet, Notions fondamentales sur les matériaux - Déformation plastique et essais mécaniques, SNPMD Editeur, Paris, **1989**
- [46] J. Grewen, T. Noda, D. Sauer, Zeitschrift für Metallkunde, Vol. 67, p. 260 (**1977**).

- [47] A.A. Riddha, W.B. Hutchinson, Acta Metallurgica and Materialia, Vol. 30, p. 1929 (1982).
- [48] C. Donadille, R. Valle, P. Dervin, R. Penelle, Acta Metallurgica, Overview n° 82, Vol. 37, N°6, p. 1547 (1989).
- [49] P.A. Beck, P.R. Sperry, Journal of Applied Physics, Vol. 21, p. 150 (1950).
- [50] R.D. Doherty, D.A. Hughes, F.J. Humphreys et al. Current issues in recrystallization: a review. Materials Science and Engineering A, Vol. A238 p. 219 (1997)
- [51] D. Hughes, N. Hansen, Acta Materialia, Vol. 45, N°9, p. 3871 (1997).
- [52] J.E. Bailey, P.B. Hirsch, Proceedings of Royal Society of London A, Vol. 267, p. 11 (1962).
- [53] H.J. Shin, H.T. Joeng and D.N. Lee, Mater Sci. Eng., Vol. A279 p. 244 (2000)
- [54] Ph. Gerber, J. Tarasiuk, T. Chauveau, B. Bacroix, Acta Mat. Vol. 51, p. 6359 (2003).
- [55] M. Ly, Rapport de stage de DEA Métallurgie et Matériaux, INSTN, CEN Saclay, 91191 Gif sur Yvette Cedex, (1996).
- [56] Adda Y., Dupouy J.M., Philibert J. et Quéré Y., Eléments de métallurgie physique, tome 5, Déformation plastique, (1991).
- [57] Becker R., Elastische Nachwirkung und Plastizität, Zeitschrift für Physik, A26 (1925), p185.
- [58] Eyring H., Viscosity, plasticity, and diffusion as examples of absolute reaction theory, J. Chem. Phys. 4 (1936), p 283.
- [59] McGregor C. W., Fisher J. C., A velocity-modified temperature for plastic flow of metals, Trans. ASME, J. Appl. Mech., 13 (1946), A11.
- [60] Rhayour M., Modélisation de l'influence de la vitesse de déformation sur l'écoulement plastique d'un acier industriel ; application pour l'étude de traction dynamique des tôles. Thèse université de Metz, (1998).
- [61] Klepaczko J.R., Introduction to experimental techniques for materials testing at high strain rates, Institute of Aviation, Al. Krakowska 110/114, 02-256 Warsaw, Poland (2007).
- [62] Juanicotena A., Etude théorique et expérimentale du comportement viscoplastique des matériaux aux grandes déformations et grandes vitesses de déformation. Application à l'acier mars 190 et au tantale, thèse université de Metz, (1998).
- [63] Bay F., Etude expérimentale et modélisation du comportement plastique d'un tantale. Prise en compte de la vitesse de déformation et de l'histoire de chargement, thèse université de Metz, (1996).

- [64] Klahn D, Mukherjee A.K., Dorn J.F., Strain rate effects, 2nd international conference on the strength of metals and alloys, Asilomar, Vol. 3, (1970) p.951.
- [65] Rosenfield A.R., Hahn G.T., Numerical description of the ambient low temperature and high strain rate flow and fracture behaviour of plain carbon steel, Trans. Am.Soc.Metals, Vol. 59, (1966), p.967.
- [66] J.P. Ansart, « Lois de comportement », DYMAT, ETCA, Arcueil, France (1994)
- [67] S.R. Bodner and Y. Partom, « Constitutive equations for elastic-viscoplastic strain hardening materials », J. of Applied Mechanics Trans. of ASME (1975) 385-389
- [68] D. Bois et D. Grave, « Simulation numérique d'essais d'impact et comparaison des lois de comportement », J. de Physique, Colloque C5, supplément au n°8. Tome 46, pp 101-112; Août 1985.
- [69] A. Cosculluela, N. Goubot et G. Naulin, « Comportement mécanique des matériaux sous grandes vitesses de sollicitations », Revue Scientifique et Technique de la Direction des Applications Militaires (1994) 11 53-64.
- [70] M .Bornert, Th Bretheau, P. Gilormini, Homogénéisation en mécanique des matériaux, Vol.1 and 2, HERMES, SCIENCE, Paris 2001.
- [71] F. Montheillet et P. Gilormini – Préviation du comportement mécanique d'un mélange de deux phases viscoplastiques linéaires à l'aide d'un modèle du type automate cellulaire. C. R. Acad. Sci. Paris, série II 319, p. 483-490 (1994).
- [72] P. Gilormini et F. Montheillet – Deformation of an inclusion in a viscous matrix and induced stress concentrations. J. Mech. Phys. Solids 34, p. 97-123 (1986).
- [73] M.Berveiller, A. Zaoui, 1979 An extension of the self-consistent scheme to plastically-flowing polycrystals. J. Mech. Phys. Solids. 26, 325- 344.
- [74] Changizian, P.; Zarei-Hanzaki, A.; Roostaei, A.A. The high temperature flow behavior modeling of AZ81 magnesium alloy considering strain effects. Mater. Des. 2012, 39, 384–389.
- [75] Taleghani, M.A.J.; Navas, E.M.R.; Salehi, M.; Torralba, J.M. Hot deformation behaviour and flow stress prediction of 7075 aluminium alloy powder compacts during compression at elevated temperatures. Mater. Sci. Eng. A 2012, 534, 624–631.
- [76] Sellars, C.M.;Mctegart,W.J. On the mechanism of hot deformation. ActaMetall. 1966, 14, 1136–1138.
- [77] Abbasi, S.M.; Shokuhfar, A. Prediction of hot deformation behaviour of 10Cr–10Ni–5Mo–2Cu steel. Mater. Lett. 2007, 61, 2523–2526.

- [78] Krishnan, S.A.; Phaniraj, C.; Ravishankar, C.; Bhaduri, A.K.; Sivaprasad, P.V. Prediction of high temperature flow stress in 9Cr–1Mo ferritic steel during hot compression. *Int. J. Press. Vessels Pip.* **2011**, *88*, 501–506.
- [79] Phaniraj, C.; Samantaray, D.; Mandal, S.; Bhaduri, A.K. A new relationship between the stress multipliers of Garofalo equation for constitutive analysis of hot deformation in modified 9Cr–1Mo (P91) steel. *Mater. Sci.Eng. A* **2011**, *528*, 6066–6071.
- [80] Yang, X.; Li, W. Flow Behavior and Processing Maps of a Low-Carbon Steel During Hot Deformation. *Metall. Mater. Trans. A* **2015**, *46*, 6052–6064.
- [81] Asgharzadeh, A.; Aval, H.J.; Serajzadeh, S. A Study on Flow Behavior of AA5086 over a Wide Range of Temperatures. *J. Mater. Eng. Perform.* **2016**, *25*, 1076–1084.
- [82] Lin, Y.C.; Nong, F.Q.; Chen, X.M.; Chen, D.D.; Chen, M.S. Microstructural evolution and constitutive models to predict hot deformation behaviors of a nickel-based superalloy. *Vacuum* **2017**, *137*, 104–114.
- [83] Cai, J.; Zhang, X.; Wang, K.; Miao, C. Physics-Based Constitutive Model to Predict Dynamic Recovery Behavior of BFe10-1-2 Cupronickel Alloy during Hot Working. *High Temp. Mater. Process.* **2016**, *35*, 1037–1045.
- [84] Xiao, G.; Yang, Q.W.; Luo-Xing, L.I. Modeling constitutive relationship of 6013 aluminum alloy during hot plane strain compression based on Kriging method. *Trans. Nonferrous Met. Soc. China* **2016**, *26*, 1096–1104.
- [85] Lin, Y.C.; Li, Q.F.; Xia, Y.C.; Li, L.T. A phenomenological constitutive model for high temperature flow stress prediction of Al–Cu–Mg alloy. *Mater. Sci. Eng. A* **2012**, *534*, 654–662.
- [86] Quan, G.Z.; Wang, T.; Li, Y.L.; Zhan, Z.Y.; Xia, Y.F. Artificial Neural Network Modeling to Evaluate the Dynamic Flow Stress of 7050 Aluminum Alloy. *J. Mater. Eng. Perform.* **2016**, *25*, 1–12.
- [87] Han, Y.; Qiao, G.; Sun, J.P.; Zou, D. A comparative study on constitutive relationship of as-cast 904L austenitic stainless steel during hot deformation based on Arrhenius-type and artificial neural network models. *Comput. Mater. Sci.* **2013**, *67*, 93–103.
- [88] Lin, Y.C.; Xia, Y.C.; Chen, X.M.; Chen, M.S. Constitutive descriptions for hot compressed 2124-T851 aluminum alloy over a wide range of temperature and strain rate. *Comput. Mater. Sci.* **2010**, *50*, 227–233.
- [89] Jia, W.; Zeng, W.; Zhou, Y.; Liu, J.; Wang, Q. High-temperature deformation behavior of Ti60 titanium alloy. *Mater. Sci. Eng. A* **2011**, *528*, 4068–4074.

- [90] Zhu, Y.C.; Zeng, W.D.; Feng, F.; Sun, Y.; Han, Y.F.; Zhou, Y.G. Characterization of hot deformation behavior of as-cast TC21 titanium alloy using processing map. *Mater. Sci. Eng. A Struct. Mater. Prop. Microstruct. Process.* **2011**, *528*, 1757–1763.
- [91] Guo-Fu, X.U.; Peng, X.Y.; Liang, X.P.; Xu, L.I.; Yin, Z.M. Constitutive relationship for high temperature deformation of Al-3Cu-0.5Sc alloy. *Trans. Nonferrous Met. Soc. China* **2013**, *23*, 1549–1555.
- [92] Li, J.; Li, F.; Cai, J.; Wang, R.; Yuan, Z.; Xue, F. Flow behavior modeling of the 7050 aluminum alloy at elevated temperatures considering the compensation of strain. *Mater. Des.* **2012**, *42*, 369–377.
- [93] Mandal, S.; Sivaprasad, P.V.; Dube, R.K. Modeling Microstructural Evolution during Dynamic Recrystallization of Alloy D9 Using Artificial Neural Network. *J. Mater. Eng. Perform.* **2007**, *16*, 672–679.
- [94] Ramesh, R.; Gnanamoorthy, R. Artificial Neural Network Prediction of Fretting Wear Behavior of Structural Steel, En 24 Against Bearing Steel, En 31. *J. Mater. Eng. Perform.* **2007**, *16*, 703–709.
- [95] Ashtiani, H.R.R.; Shahsavari, P. A comparative study on the phenomenological and artificial neural network models to predict hot deformation behavior of AlCuMgPb alloy. *J. Alloys Compd.* **2016**, *687*, 263–273.
- [96] Devadas, C.; Baragar, D.; Ruddle, G.; Samarasekera, I.V.; Hawbolt, E.B. The thermal and metallurgical state of steel strip during hot rolling: Part II. Factors influencing rolling loads. *Metall. Trans. A* **1991**, *22*, 321.
- [97] Mosleh, A.; Mikhaylovskaya, A.; Kotov, A.; Pourcelot, T.; Aksenov, S.; Kwame, J.; Portnoy, V. Modelling of the Superplastic Deformation of the Near-alpha Titanium Alloy (Ti-2.5Al-1.8Mn) Using Arrhenius-Type Constitutive Model and Artificial Neural Network. *Metals* **2017**, *7*, 568.
- [98] Wang, F.; Zhao, J.; Zhu, N. Constitutive Equations and ANN Approach to Predict the Flow Stress of Ti-6Al-4V Alloy Based on ABI Tests. *J. Mater. Eng. Perform.* **2016**, *25*, 4875–4884.
- [99] Mandal, S.; Sivaprasad, P.V.; Venugopal, S. Capability of a feed-forward artificial neural network to predict the constitutive flow behavior of as cast 304 stainless steel under hot deformation. *J. Eng. Mater. Technol.* **2007**, *129*, 242–247.
- [100] R. Forestier, E. Massoni, Y. Chastel, Estimation of constitutive parameters using an inverse method coupled to a 3D finite element software, *Journal of Materials Processing Technology*, Vol. 125, p. 594–601, **2002**.

- [101] W. Chen, P. Garder, 'Word level discriminative training for handwritten word recognition', Proc. 7th IWFHR, pp. 393-402, Amsterdam, **2000**.
- [102] H. A. Beghdadi, M. Senouci, 'Réseaux de neurones : théorie et pratique', Office des Publications Universitaires, Algérie, **2005**.
- [103] Dreyfus G., Martinez J-M., Samuelides M., Gordon M.B., Badran F., Thiria SS., Hérault L, Réseaux de neurones : Méthodologie et Applications, Eyrolles, **2002**.
- [104] Zhan MY, Chen Z, Zhang H, Xia W (**2006**) Flow stress behavior of porous FVS0812 aluminum alloy during hot-compression. Mech Res Commun 33:508–514
- [105] Rakhshkhorshid M, Hashemi SH (**2013**) Experimental study of hot deformation behavior in API X65 steel. Mater Sci Eng 573:37–44
- [106] Peng K, Zhong H, Zhao L, Xue K, Ji Y (**2014**) Strip shape modeling and its setup strategy in hot strip mill process. The International Journal of Advanced Manufacturing Technology 72:589–605
- [107] Mirzadeh H, Najafizadeh A (**2010**) Flow stress prediction at hot working conditions. Mater Sci Eng A 527:1160–1164
- [108] Lin YC, Chen XM (**2011**) A critical review of experimental results and constitutive descriptions for metals and alloys in hot working. Mater Des 32:1733–1759



Annexe

Programme du RNA

```

clearall
clc
closeall
[num, txt, tab] = xlsread('C_B_C_1.xls');
% fonction c'est Contrainte= f(T (°C), ?(S-1), Déformation)
formatlong, num, single(num);
sigma =num(:,2);%? (S-1)

Deform=num(:,3);%Déformation
T =num(:,1);%T (°C)

Contr=num(:,4);%Contrainte

p =[T';Deform';sigma'];% vecteur des entrées

t =Contr';% vecteur de sortie

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
[pn,minp,maxp,tn,mint,maxt] = premmx(p,t);
[R,Q] = size(pn);
iitst = 2:4:Q;
iival = 4:4:Q;
iitr = [1:4:Q 3:4:Q];
val.P = pn(:,iival); val.T = tn(:,iival);
test.P = pn(:,iitst); test.T = tn(:,iitst);
ptr = pn(:,iitr); ttr = tn(:,iitr);
%pause
net = newff(minmax(ptr), [10 10 1], {'tansig' 'tansig' 'tansig'}, 'trainlm' );
net.trainParam.epochs = 1000;
net.trainParam.goal = 0;
[net,tr]=train(net,ptr,ttr,[],[],val,test);
figure(2)
plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
grid
legend('Training','Validation','Test',-1);
ylabel('Squared Error'); xlabel('Epoch')
an = sim(net,pn);
a = postmnmx(an,mint,maxt);
fori=1:1
figure(i)
[m(i),b(i),r(i)] = postreg(a(i,:),t(i,:));
end

figure (5)
plot(a, 'or')
holdon
plot(t, 'b')
hold off

clearall
clc
closeall
[num, txt, tab] = xlsread('C_B_C_2.xls');
% fonction c'est Contrainte= f( T (°C), Déformation, Log ? (S-1) )
formatlong, num, single(num);
sigma =num(:,3);%? (S-1)

```

```

Deform=num(:,2);%Déformation
T =num (:,1);%T (°C)

Contr=num(:,4);%Contrainte

p =[T';Deform';sigma'];% vecteur des entrées

t =Contr';% vecteur de sortie
%t1=exp(t)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
[pn,minp,maxp,tn,mint,maxt] = premmx(p,t);
[R,Q] = size(pn);
iitst = 2:4:Q;
iival = 4:4:Q;
iitr = [1:4:Q 3:4:Q];
val.P = pn(:,iival); val.T = tn(:,iival);
test.P = pn(:,iitst); test.T = tn(:,iitst);
ptr = pn(:,iitr); ttr = tn(:,iitr);
%pause
net = newff(minmax(ptr),[5 10 1],{'tansig''tansig''tansig'},'trainlm' );
net.trainParam.epochs = 1000;
net.trainParam.goal = 0;
[net,tr]=train(net,ptr,ttr,[],[],val,test);
figure(2)
plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
grid
legend('Training','Validation','Test',-1);
ylabel('Squared Error'); xlabel('Epoch')
an = sim(net,pn);
a = postmnmx(an,mint,maxt);
fori=1:1
figure(i)
[m(i),b(i),r(i)] = postreg(a(i,:),t(i,:));
end

figure (5)
plot(a, 'or')
holdon
plot(t, 'b')
holdoff

clearall
clc
closeall
[num, txt, tab] = xlsread('C_B_C_3.xls');
% fonction c'est (Contrainte, Log (Contrainte))=f( T (°C ),? (S-1),
Déformation, Log (?), Log ? (S-1), 1/T (°C))
formatlong, num, single(num);
sigma_1 =num(:,2);% ? (S-1)

Deform=num(:,3);% Déformation
T =num (:,1);% T (°C )
log_segma =num(:,4);% Log (?)
inv_T =num(:,6)% 1/T (°C);

log_segma_1=num(:,5);% Log ? (S-1)
Contr =num(:,7); % Contrainte
Log_Contr=num(:,8); % Log (Contrainte)
p =[T';sigma_1';Deform'; log_segma';log_segma_1'; inv_T'] % Vecteur des
entrées

t =[Contr'; Log_Contr'];% vecteur des sorties

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
[pn,minp,maxp,tn,mint,maxt] = premnmx(p,t);
[R,Q] = size(pn);
iitst = 2:4:Q;
iival = 4:4:Q;
iitr = [1:4:Q 3:4:Q];
val.P = pn(:,iival); val.T = tn(:,iival);
test.P = pn(:,iitst); test.T = tn(:,iitst);
ptr = pn(:,iitr); ttr = tn(:,iitr);
%pause
net = newff(minmax(ptr),[5 10 2],{'tansig' 'tansig' 'tansig'}, 'trainlm' );
net.trainParam.epochs = 1000;
net.trainParam.goal = 0;
[net,tr]=train(net,ptr,ttr,[],[],val,test);
figure(2)
plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
grid
legend('Training','Validation','Test',-1);
ylabel('Squared Error'); xlabel('Epoch')
an = sim(net,pn);
a = postmnmx(an,mint,maxt);
fori=1:2
figure(i)
[m(i),b(i),r(i)] = postreg(a(i,:),t(i,:));
end

figure (5)

plot(a(1,:), 'or')
holdon
plot(t(1,:)','b')
grid
holdoff
figure (6)
grid
plot(a(2,:), 'or')
holdon
plot(t(2,:)','b')
grid
holdoff

```