



**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 CONTRAINTES
D'ÉCOULEMENTS D'UN ACIER MICRO-
ALLIÉS EN UTILISANT DEUX MODÈLES
DIFFÉRENTS***

Réalisé par :

- ***MEZDAOUET Amal***
- ***BOULEBIAR Biya***

Membres de jury :

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

ANNEE UNIVERSITAIRE 2020 -2021



**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 CONTRAINTES
D'ÉCOULEMENTS D'UN ACIER MICRO-
ALLIÉS EN UTILISANT DEUX MODÈLES
DIFFÉRENTS***

Réalisé par :

- ***MEZDAOUET Amal***
- ***BOULEBIAR Biya***

Membres de jury :

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

ANNEE UNIVERSITAIRE 2020 -2021

Remerciement :

Nous remercions tout d'abord é remercie Dieu le tout puissant et miséricordieux, qui nous à donner la force et la patience durant ces longues années d'étude.

Nous tenons à saisir cette occasion et adresser nos profonds remerciements et nos profondes reconnaissances à :

- ♥ Notre encadreur Dr : ABDELHALIM ALLAOUI qui a consacré son temps à nous aider et nous accompagner et donner de son meilleur pour la réussite de ce travail*
- ♥ Toute l'équipe pédagogique de l'université Abbes laghrour, département génie mécanique exceptionnelle.*
- ♥ Nos familles qui par leurs prières et leurs encouragements nous avons pu surmonter tous les obstacles.*
- ♥ Nos collègues de promotion 2020/2021 avec qui nous avons partagé nos doutes, nos craintes et nos connaissances.*
- ♥ Et enfin, à tous ceux qui ont participé de près ou loin à la réalisation de ce travail.*

Dédicaces

A l'aide de dieu tout puissant, qui m'a tracé le chemin de ma vie, j'ai pu réaliser ce travail que Je dédie :

A mes très chers parents,

Tout d'abord et spécialement à ma chère mère qui aurais été fière de ma réussite. Tous les mots du monde ne sauraient exprimer l'immense amour que je vous porte maman, ni la profonde gratitude que je vous témoigne pour tous les efforts et les sacrifices que vous n'avez jamais cessé de consentir pour mon instruction et mon bien-être. Je vous rends hommage par ce modeste travail en guise de ma reconnaissance éternelle et de mon infini

Amour. Que le Dieu l'accueille dans son vaste paradis.

A mon très agréable père, qui s'est tant sacrifié pour moi et pour assurer mon bien être.

J'espère que je suis à la hauteur de ce qu'il attend de moi.

Puisse Dieu, le Très Haut, vous accorder santé, bonheur et longue Vie.

Mon frère et Mes sœurs

Aucune dédicace ne saurait exprimer tout l'amour que j'ai pour vous, Votre joie me comble de bonheur. Puisse Dieu vous garder, éclairer votre route et vous aider à réaliser vos vœux les plus chers.

Amel





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 $0.0029S^{-1}$ ، $0.0146S^{-1}$ 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: إجهاد 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

Evolutions 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

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 a) lorsque le seul processus d'adoucissement est la restauration dynamique b) lorsque le seul processus d'adoucissement est la recristallisation dynamique	11
Figure I.5	Les processus de restauration dynamique et recristallisation dynamique	13
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	13
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	14
Figure I.8	a) Modèle de migration induite par la déformation ($E_1 > E_2$), b) Schéma de la SIBM impliquant le développement coopératif de plusieurs sous-grains.	15

Chapitre II

Figure II.1	Hypothèse biologique de génération d'un comportement intelligent	30
Figure II.2	Schéma d'un neurone biologique	33
Figure II.3	Structure d'un Neurone formel	33
Figure II.4	Structure d'un neurone artificiel	34
Figure II.5	Notation de la structure d'un neurone artificiel	34
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.	35
Figure II.7	Réseau multicouche	35
Figure II.8	Réseau à connexions locales	36
Figure II.9	Réseau à connexions récurrentes	36
Figure II.10	Réseau à connexions complète	36
Figure II.11	Le Perceptron	37
Figure II.12	Fonction d'activation ou fonction de transfert	38
Figure II.13	Apprentissage non supervisé	38
Figure II.14	Apprentissage supervisé	41

Liste des figures et tableaux

Figure II.15	Algorithme d'apprentissage supervisé	41
Figure II.16	Réseau multicouches	42
Chapitre III		
Figure III.1	Dispositif de compression à chaud	49
Figure III.2	Procédures expérimentales pour les essais de compression de l'acier micro allié CMn (Nb-Ti-V)	50
Figure III.3	Microstructure initiale des échantillons	51
Figure III.4	Echantillon refroidi après austénitisation à 1300 ° C	51
Figure III.5	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,0146 S-1	52
Figure III.6	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,0029 S-1	53
Figure III.7	Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation 0,000734 S-1	53
Figure III.8	Les relations entre $[\ln \epsilon \text{ et } \ln \sigma]$ & $[\ln \epsilon \text{ et } \sigma]$.	57
Figure III.9	Les relations entre $[\ln \epsilon \text{ et } \ln[\sinh(\alpha \sigma)]]$ & $[T-1 \text{ et } \ln[\sinh(\alpha \sigma)]]$	57
Figure III.10	Les paramètres Q, ln A, n, α évalués par compensation polynômiale en fonction de la déformation ϵ .	58
Figure III.11	Valeurs de prédiction faces aux valeurs mesurées de la contrainte d'écoulement	59
Figure III.12	Evaluation de l'erreur relative absolue et l'erreur relative absolue moyenne pour l'ensemble des points de mesure	60
Figure III.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 III.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 III.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 III.16	Valeurs expérimentales et prévues de la contrainte d'écoulement par le modèle d'Arrhenius amélioré pour différentes vitesses de déformation et à T = 950 ° C	62
Figure III.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 III.18	L'erreur quadratique (SE) et l'erreur quadratique moyenne (MSE) de l'ensemble des données	77
Figure III.19	L'architecture optimale du réseau de neurones artificiels	77
Figure III.20.a	Contrainte d'écoulement mesurée face au prédite pour l'ensemble d'entraînement	78
Figure III.20.b	Contrainte d'écoulement mesurée face au prédite pour l'ensemble de test	79

Liste des figures et tableaux

Figure III.20.c	Contrainte d'écoulement mesurée face au prédite pour l'ensemble de validation	79
Figure III.20.d	Contrainte d'écoulement mesurée face au prédite pour l'ensemble des données.	80
Figure III.21	L'erreur relative absolue (ARE) et l'erreur relative absolue moyenne (AAR) de l'ensemble des données	80
Figure III.22	Valeurs expérimentales et prévues de la contrainte d'écoulement pour la vitesse de déformation $\dot{\epsilon} = 0,0029 \text{ S}^{-1}$ et $T = 700 \text{ }^\circ\text{C}$	81
Figure III.23	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes valeurs de vitesses de déformation à $T = 750 \text{ }^\circ\text{C}$	81
Figure III.24	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 900 \text{ }^\circ\text{C}$	82
Figure III.25	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 950 \text{ }^\circ\text{C}$	82
Figure III.26	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 1050 \text{ }^\circ\text{C}$	83
Figure III.27	Valeurs maximales expérimentales et prévues des contraintes pour différentes températures et vitesses de déformation	83
Figure III.28	Valeurs expérimentales et prévues de la contrainte d'écoulement pour une vitesse de déformation de $0,0029 \text{ S}^{-1}$ à $T = 700 \text{ }^\circ\text{C}$	84
Figure III.29	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 700 \text{ }^\circ\text{C}$	85
Figure III.30	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 750 \text{ }^\circ\text{C}$	85
Figure III.31	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 850 \text{ }^\circ\text{C}$	86
Figure III.32	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 950 \text{ }^\circ\text{C}$	86
Figure III.33	Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 1050 \text{ }^\circ\text{C}$	87

Liste des Tableaux

Tableau III.1	Compositions chimiques détaillées	50
Tableau III.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 corrélient 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 RNA basé sur une approche de régression neuronale. Les travaux et résultats de recherche sont résumés dans ce modeste travail présenté. Celle-ci comprend trois chapitres. Les deux premiers chapitres rappellent les résultats

Introduction générale

bibliographiques sur l'évolution microstructurales au cours de la déformation à chaud et 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 un modèle qui confronté 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



*Revue bibliographique sur la
métallurgie des aciers micro-alliés*

I.1. Introduction

Il n'est pas facile de donner une définition parfaite des aciers micro-alliés car s'il est indéniable qu'il s'agit d'aciers où l'on a introduit volontairement certains éléments en très faible quantité, l'expression ne s'applique pas obligatoirement à toutes les nuances micro-alliées, mais plutôt à des familles d'aciers à hautes caractéristiques et surtout dans le domaine des aciers de construction (métallique et mécanique). [29]

Dans notre travail nous donnerons, chaque fois que cela n'entraîne pas de trop longs développements, une vue d'ensemble du rôle des éléments de micro-alliage quelle que soit la famille concernée, tout en considérant en priorité les aciers de construction à hautes performances. [30]

Les familles d'acier concernées sont les suivantes :

- Les aciers soudables à haute limite d'élasticité ou à haute résistance (HLE, en anglais HSLA) sous forme de plaques, de tôles à tubes, de tôles minces, de barres, de profilés, de laminés marchands (aciers de construction, aciers pour appareils à pression...);
- les tôles minces pour formage et emboutissage à haute limite d'élasticité ou sans élément interstitiel libre, c'est-à-dire avec fixation des éléments C et N sous forme de carbures et de nitrures ;
- Les aciers de construction mécanique au carbone pour lesquels le micro-alliage permet d'éviter des traitements thermiques ou le développement de traitements combinés dans la chaude du forgeage (traitements thermomécaniques) ;
- Des familles particulières, comme les aciers à rails, les ronds à béton, des aciers pour boulonnerie, etc.
- Des aciers dits à dispersion d'oxydes, qui sont les plus récents et sont de vrais aciers à dispersoïdes.

I.1.1. Catégories et spécification des aciers HSLA

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. [31]

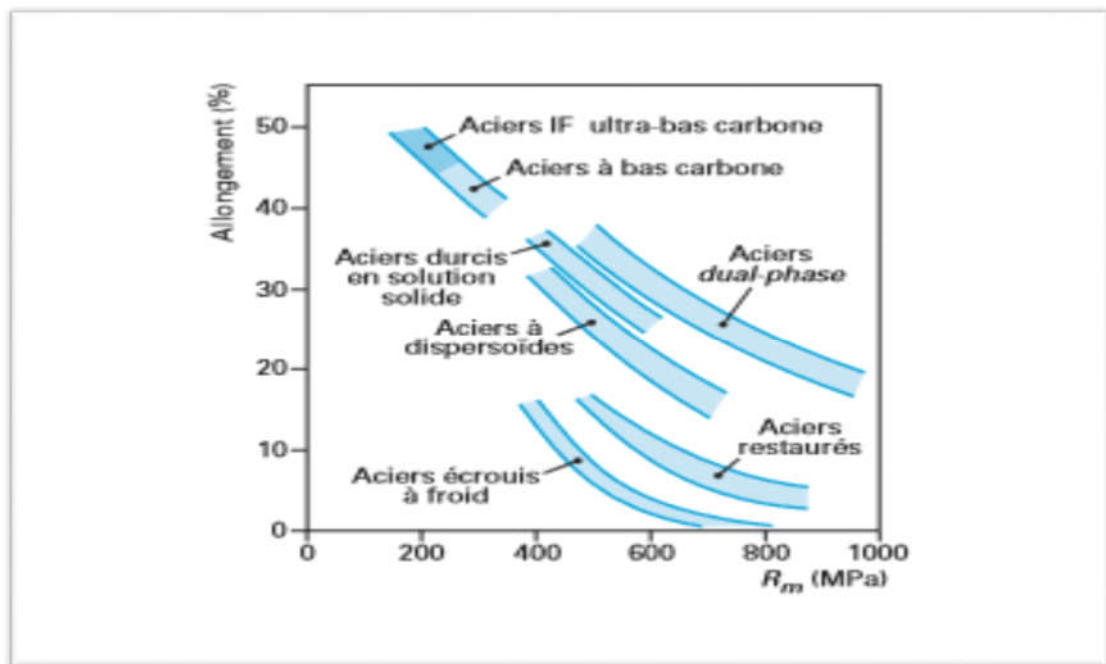


Figure I.1 : Compromis résistance-ductilité des différentes familles d'aciers HLE

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.
- 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 améliorée.

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.

Les aciers HSLA peuvent être divisés en six catégories : [32]

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.

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.

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

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.

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.

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.

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.

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.

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.

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.

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 perlitiques contiennent de petites quantités d'éléments alliés pour améliorer la soudabilité, la formabilité, la ténacité et la dureté.

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. Les applications principales de ces aciers sont les pipelines dans les conditions de l'arctique.

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.

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 transversal-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.

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.1.2. Composition chimique

La composition de l'alliage confère à l'acier son niveau de résistance mécanique. La fonte, première étape de fabrication de l'acier, est uniforme pour tous les produits. C'est au stade suivant, à l'aciérie, que seront ajoutés ou supprimés les éléments d'alliage, déterminant ainsi les grandes familles d'acier, des plus résistants aux plus emboutissables. La proportion de carbone joue un rôle primordial dans cette répartition car le carbone est le principal élément durcissant du fer. D'autres éléments tels que le manganèse, le silicium ou le phosphore participent aussi à l'ajustement du niveau de résistance de l'acier. De façon plus sélective, on peut aussi ajouter d'autres éléments d'alliage comme le titane, le niobium ou le vanadium qui confèrent des propriétés spécifiques de dureté. On parle dans ce cas d'aciers micro-alliés car l'effet de ces éléments se manifeste même quand ils sont ajoutés en très petite quantité par rapport aux autres éléments d'alliage. L'azote et le carbone sont des éléments chimiques de faible taille atomique par rapport à celle du fer. Ils sont appelés éléments interstitiels car ils se positionnent aisément à l'intérieur de la matrice cristalline du fer. Placés aux interstices du réseau cristallin, ils durcissent ainsi l'ensemble du cristal par un verrouillage des possibilités de glissement des plans atomiques entre eux. Leur quantité dans l'alliage d'acier est déterminante pour définir ses propriétés mécaniques ultérieures. La teneur en carbone est ajustée principalement par soufflage d'oxygène dans la fonte liquide et peut être complétée par une opération sous vide.

Deux voies sont possibles pour procéder à la décarburation et la dénitruration, c'est-à-dire pour provoquer la précipitation des atomes de carbone et d'azote résiduels en composés

trop volumineux pour occuper des positions interstitielles. Soit l'adjonction d'aluminium (on parle d'aciers "calmes" à l'aluminium) qui est la voie choisie pour les aciers courants et a résistance élevée, soit l'adjonction de titane (on parle d'aciers "calmes" au titane).

Cette deuxième voie est la plus efficace pour réduire au minimum la présence d'azote et de carbone interstitiels. L'influence de la composition chimique sur l'aptitude à la déformation est très importante. L'étude de cet effet doit se faire en fonction de la répartition des éléments dans la matrice, cette population pouvant être éventuellement répartie de façon hétérogène. La répartition des éléments dépend essentiellement des solubilités différentes, des réactions d'échange et des traitements thermiques antérieurs. [33]

Ces facteurs ne sont pas indépendants. Des changements de structure, souvent importants, peuvent se produire. Ils entraînent des variations sur les caractéristiques mécaniques de résistance.

I.2. Ductilité

I.2.1. Introduction

En résistance des matériaux, la ductilité désigne la capacité d'un matériau à se déformer plastiquement sans se rompre. La rupture se fait lorsqu'un défaut (fissure ou cavité), induit par la déformation plastique, devient critique et se propage. La ductilité est donc l'aptitude d'un matériau à résister à cette propagation. S'il y résiste bien, il est dit ductile, sinon il est dit fragile. L'origine de la ductilité d'un matériau est la mise en mouvement des dislocations dont il est le siège. Cependant, cette mise en mouvement génère d'autres dislocations, ce qui durcit le matériau mais néanmoins le rend plus fragile : c'est le phénomène d'écrouissage. Ainsi, un diamant (qui comporte énormément de dislocations) sera très dur mais très fragile, contrairement à un métal qui sera plus ductile et moins fragile.

La ductilité est une propriété conditionnée par la malléabilité. « La malléabilité est le premier indice de la ductilité ; La ductilité désigne surtout la capacité d'une matière à résister à l'étirement. Par exemple, l'or est le matériau le plus ductile car le fil que l'on obtient par son étirement extrême, sans rupture, est le plus fin de tous les matériaux connus.




Figure I.2 : Comportement à la rupture en essai de traction

(a) Fragile ; (b) ductile ; (c) complètement ductile

I.2.2. Mode de mesures

Deux principales mesures sont effectuées :

- Les essais de traction mesurant l'allongement à la rupture et la striction (réduction du diamètre de l'éprouvette au niveau où elle se rompt) ;
- L'essai mouton de Charpy mesurant l'énergie dépensée pour casser une éprouvette.

Un matériau est ductile si :

Son allongement et sa striction à la rupture sont importants ;

- ✚ L'énergie dépensée pour le casser est importante.

Inversement un matériau est fragile si :

- ✚ Son allongement et sa striction à la rupture sont faibles ;
- ✚ L'énergie dépensée pour le casser est faible

I.2.3. Conditions de la ductilité

La ductilité dépend de la température, de la pression et de la vitesse de déformation :

- ✚ Quand la température augmente, le seuil de plasticité diminue ;
- ✚ Quand la pression augmente, le seuil de rupture augmente ;
- ✚ Quand la vitesse de déformation augmente, le seuil de rupture diminue.

En effet les mécanismes impliqués lors des essais dépendent de ces paramètres :

- ✚ La mobilité des dislocations ;
- ✚ La restauration et la recristallisation dynamique ;
- ✚ La diffusion et le fluage.

I.2.4. Particularités

Pour les matériaux cristallins, la ductilité intrinsèque (c'est-à-dire liée au matériau et non pas aux conditions de déformation) est déterminée par :

- le nombre de systèmes de glissement disponibles : en effet, la déformation plastique se fait par glissement de plans cristallographiques denses selon des directions denses, certaines structures en possèdent plus que d'autres ; cela explique la ductilité des cristaux ayant une symétrie cubique à faces centrées (CFC) comme l'or, le plomb ou l'aluminium ; par ailleurs, dans le cas des alliages ordonnés (oxydes, intermétalliques...), certains modes de déformation sont bloqués (nécessité de respecter l'alternance chimique à tout moment) ;
- la pureté : les atomes étrangers (interstitiels ou en substitution) viennent épingler les dislocations et gênent leur mouvement ;
- l'unicité de la phase : s'il y a des précipités, on a un durcissement structural (les précipités bloquent les dislocations) ; [34]
- la taille des cristallites : les joints de grain bloquent les dislocations, plus les cristallites sont petits, plus il y a de joints de grain (cf. loi de Hall-Petch, la limite élastique est proportionnelle à l'inverse de la racine carrée du diamètre moyen des cristallites).

I.3. Classification des aciers

Les aciers ont été classés en fonction de deux critères ; la composition chimique et le niveau de qualité. Ainsi on distingue les aciers : [35]

- non alliés (<1% d'alliage)
- peu alliés (teneur de chaque élément d'alliage < 5%)
- très alliés

Et, en fonction de la garantie donnée aux propriétés d'usage, les aciers

- de base
- de qualité
- les aciers spéciaux.

Ces derniers sont placés dans trois familles

- les aciers de construction mécanique (peu ou non alliés)
- les aciers à outils (peu ou très alliés)
- les aciers inoxydables.

I.4. Influence des éléments d'addition sur la ductilité

I.4.1. Introduction

De nombreuses études ont permis de préciser l'influence des éléments d'addition sur la ductilité à chaud et sur l'évolution microstructurale, facteurs qui conditionnent les propriétés des structures ferrito-perlitique.

On note notamment :

- 1) L'influence des éléments en solution solide, soit d'insertion telle que le carbone et l'azote, soit de substitution telle que le manganèse et le silicium.
- 2) L'influence des éléments sur la microstructure, notamment la teneur en carbone sur la proportion de ferrite et de perlite.
- 3) L'influence de précipités fins ayant une grande affinité pour le carbone ou pour l'azote.

4) L'influence de la taille du grain.

Comme notre étude porte sur les aciers micro-alliés de type industriel, où les éléments d'addition (C, S, Mn, P, Al, V, Nb et Ti) sont prépondérants, l'influence de ceux-ci sur la ductilité à chaud sera revue en fonction des résultats bibliographiques.

I.4.2. Les éléments d'addition

▪ Influence du carbone

Le carbone donne avec le fer des solutions solides d'insertion. L'évaluation des vides laissés dans la structure par les réseaux cubiques à faces centrées et cubiques centrés donne respectivement 25 % et 32 %. C'est cependant la structure à face centrée qui dissout le plus de carbone et cela à cause de la répartition différente des vides. L'addition du carbone dans le fer modifie les positions des points de transformation. Le carbone réduit, d'une part, le domaine du fer(α) (domaine ferritique) à haute température et à partir de 0.18 % de carbone, le fer se solidifie directement en fer(γ). D'autre part, il agrandit le domaine du fer(γ) (domaine austénitique), élevant ainsi la température du point A₄ tout en abaissant la température du point A₃.

Comme le fer cristallise dans un système cubique, il possède alors un nombre élevé de plans de translation, ce qui le rend relativement plastique. L'ajout du carbone dans les aciers a pour effet de rendre plus difficiles les translations qui conditionnent la déformation plastique. L'ajout d'éléments d'addition dans un acier diminuent la solubilité du carbone dans l'austénite et en même temps élèvent corrélativement la proportion de carbure et cela pour une teneur donnée de carbone. Les additions en proportion acceptable ont pour effet d'abaisser la teneur en carbone de la perlite. D'un point de vue mécanique, le carbone durcit le fer et rend possible le phénomène de trempe (formation de martensite). Il augmente la dureté, la résistance à la traction et la limite élastique. Le durcissement s'accompagne d'une fragilisation de l'alliage ; l'allongement et la résilience diminuent avec l'augmentation de la quantité de carbone.



Figure I.3 : Schéma de l'élément "Carbone « C »"

▪ Influence du soufre

Le soufre présent dans l'acier provient le plus souvent des combustibles. Pour des teneurs élevées en soufre, on remarque un point eutectique à 988°C. Cet eutectique a tendance à former autour des grains de fer, un réseau avec un point de fusion assez bas qui rend le métal fragile à chaud. Pour éviter cette situation, on additionne du manganèse pour piéger le soufre, en formant un sulfure de manganèse beaucoup moins fusible. Le chrome, le zirconium et le titane agissent de la même manière que le manganèse alors que le nickel, le cobalt et le molybdène facilitent au contraire la fusibilité des sulfures et leurs répartitions en réseau.



Figure I.3 : Schéma de l'élément " Soufre « S »"

▪ Influence du phosphore

Le phosphore, présent sous forme de phosphate dans la gangue de certains minerais, passe en solution solide dans l'acier après avoir été libéré sous l'action combinée de la silice et du carbone. L'augmentation de la quantité de phosphore à plus de 1.7% élimine la transformation α - γ et tend à réduire l'étendue du domaine d'existence de l'austénite, permettant d'obtenir aux basses températures la structure ferritique de solidification.

Le phosphore a une grande tendance à ségréger. Sur un acier riche en phosphate, on constate que sa structure est formée d'une juxtaposition d'une ferrite riche en phosphate et donc d'une perlite moins chargée, suggère un traitement d'homogénéisation à 1200°C pendant 70h pour supprimer la ségrégation du phosphore.



Figure I.4 : Schéma de l'élément " Phosphore « P »"

▪ Influence de l'aluminium

L'aluminium de structure CFC fond à 660.2°C et bout vers 2060°C. Un acier est considéré comme allié lorsque sa teneur en aluminium dépasse 0.3%. L'aluminium est un élément alphagène, la transformation α - γ disparaît à partir de 1% d'aluminium environ. En étudiant l'influence de l'aluminium sur des nuances de fer pur dopé uniquement en aluminium, a constaté que ce dernier n'affecte pas la ductilité lors d'une déformation à chaud. A montré que la présence de l'aluminium (300 $\mu\text{g/g}$), accentue la baisse de ductilité due au soufre (30 $\mu\text{g/g}$) dans le domaine biphasé alors que dans le domaine austénitique il n'a aucune influence. Malgré une très bonne ductilité entre 850°C et 1200°C.

Dans le cas des aciers contenant du nitrure d'aluminium et du soufre, la ductilité se restaure pour une teneur en soufre donnée à des températures supérieures à celles observées dans le cas des aciers contenant du soufre seulement. Dans ce cas la ductilité est contrôlée par la dissolution et la coalescence des précipités de nitrures d'aluminium. Ce processus permet d'une part d'atteindre les conditions critiques telles que la taille et le nombre de précipités nécessaires pour débloquer la recristallisation dynamique, et d'autre part, de diminuer le nombre des sites potentiels d'amorçage des cavités.



Figure I.5 : Schéma de l'élément "Aluminium « AL »"

▪ Influence du silicium

Beaucoup de revêtements réfractaires utilisés lors de l'élaboration de l'acier contiennent de la silice, qui, après sa réduction par le carbone, s'incorpore dans l'acier sous forme de silicium. Le silicium est un élément alphagène. Le domaine austénitique forme une boucle fermée. A partir de 1.7% de silicium environ, la transformation α - γ disparaît et donc ces alliages conservent à l'ambiante la structure ferritique de solidification.

Le silicium tend à relever la limite élastique ; il est de ce fait important dans les aciers de construction ou de production de tubes soudés destinées au transport du gaz et du pétrole. Les aciers au silicium 1.5%, utilisés pour leur haute résistance à l'usure. En effet les alliages fer-silicium ne sont plus forgeables à partir de 10% de Si. La perte de ductilité commence à 7% de Si. Dans notre étude, il ne jouera pas de rôle important sur la ductilité.



Figure I.6 : Schéma de l'élément " Silicium « Si »"

▪ Influence du manganèse

Le manganèse est un élément gamagène, abaisse la température de transformation de l'austénite en ferrite et par le même réduit la teneur en carbone nécessaire à la formation de l'eutectoïde. Il évite aussi la précipitation de la cémentite aux joints de grains. Il joue un rôle d'agent désulfurant et désoxydant de l'acier, et intervient comme nettoyeur chimique de l'acier en le débarrassant des impuretés tel que le soufre et l'oxygène. On le trouve également comme élément d'alliage. En effet, à proximité de la ligne solidus il donne avec le fer une série de solutions solides. Le manganèse a tendance à ségréger à l'échelle dendritique, en provoquant une hétérogénéité en éléments d'addition. Ainsi, pendant un traitement mécanique par traction, les zones hétérogènes formées sont étirées en fils allongés formant une structure fibreuse, processus appelé fibrage de l'acier. Le manganèse peut également provoquer la formation d'inclusions plus ou moins arrondies devenant plastiques et s'étirant, elles aussi en fils lors de la déformation à chaud.



Figure I.7 : Schéma de l'élément " Manganèse « Mn »"

▪ Influence du vanadium

Le vanadium ne peut se trouver ni dans la gangue, ni dans le combustible. Il est introduit volontairement dans l'acier sous forme de Ferro vanadium. Le vanadium est un élément alphasé, la transformation α - γ est incomplète (alliages semi-ferritiques) pour des teneurs en vanadium comprises entre 1.0 et 1.1%, alors que pour des teneurs supérieures à 1.1% de vanadium, la transformation disparaît (alliages ferritiques). Le vanadium élargit la poche de ductilité vers les hautes températures. Le durcissement provoqué par la précipitation des carbonitrides de vanadium est moins important dans les aciers calmés à l'aluminium normalisés que dans les aciers semi-calmés ou calmés au silicium. Sachant que la présence de fins précipités freine le grossissement du grain austénitique, ont étudié le phénomène de grossissement du grain austénitique en fonction de la température d'austénisation. Ils ont constaté que le grain austénitique croît d'abord lentement avec la température. Puis au-delà d'une certaine température critique, il augmente rapidement avec l'augmentation de la température, lorsque les particules présentes dans la matrice ont coalescé au-delà d'une certaine taille. Ceci permet alors de situer la température de mise en solution au-dessus de seuil critique permettant une croissance rapide de la taille du grain austénitique.

Ont constaté sur des coulées normalisées, que la précipitation durcissant du vanadium a lieu au refroidissement, au niveau de l'interface entre les grains de ferrite en croissance et l'austénite. Les précipités sont des nitrures ou des carbonitrides riches en azote. Cette précipitation interphase pourrait modifier la cinétique de croissance des grains ferritiques et donc leurs tailles.



Figure I.8 : Schéma de l'élément " Vanadium « V »"

▪ Influence du niobium

Le niobium est un élément alphasé il est ajouté à l'acier sous forme de ferro -niobium. Il est recommandé de désulfurer avec soin les aciers destinés à subir une addition de niobium. Le niobium cristallise en cubique centré. L'affinité du niobium pour le carbone et l'azote favorise un durcissement et un affinement du grain par la formation de précipités de carbures et de nitrures finement dispersées. Le développement du laminage contrôlé sur des nuances micro-alliées au niobium a imposé une série d'études sur la forgeabilité et entre autres sur l'apparition d'une série de défauts sur les brames. L'effet inhibiteur du niobium sur la recristallisation est le principal phénomène mis en cause.

Il faut aussi souligner le rôle particulier du niobium dans les aciers déjà traités à l'aluminium ainsi que l'effet de son comportement inhibiteur de la recristallisation de l'austénite et l'influence de la déformation sur l'intensification de sa précipitation. Le durcissement de la matrice par la précipitation intergranulaire fine contribue lui aussi de manière significative à la perte de ductilité.



Figure I.9 : Schéma de l'élément "Niobium « Nb»"

▪ Influence du titane

Le titane n'est pas présent dans le combustible, il peut se trouver dans certains minerais, mais sa présence dans les aciers est le résultat d'une addition volontaire. A de faibles teneurs il est utilisé dans l'élaboration de l'acier comme désoxydant.

Il est également utilisé comme dénitrurant, malgré le fait qu'il ne se porte sur l'azote que lorsque tout l'oxygène est fixé. Il peut avoir aussi une action désulfurante, il remplace avantageusement le manganèse ; 1% de titane peut remplacer, pour cela 3.6 % de manganèse, mais seulement après avoir neutralisé l'oxygène et l'azote présents. Le titane est un élément alphagène, la transformation est incomplète pour les teneurs en titane supérieures à 0.66 at. % (alliages semi-ferritiques) alors que pour 0.8 at. % elle disparaît complètement. Le titane abaisse le pouvoir trempant des aciers en se combinant à une partie du carbone pour former du carbure de titane TiC que l'on rencontre dans les aciers pour des teneurs en carbone supérieures à 0.1 ou 0.2 % et des teneurs en titane supérieures à 0.2 %. Le titane joue donc, à ce point de vue le même rôle que le vanadium. Notons que les carbures de titane sont en outre moins solubles que les carbures de vanadium.

L'augmentation de la quantité de titane dans un acier provoque une perte de ductilité on a montré que le titane a un effet fragilisant certain, mais toutefois moins intense que celui du niobium. Cette fragilisation est attribuée à la présence des nitrures de titane par probablement les mêmes mécanismes que ceux invoqués pour le niobium. Par contre, on a observé une amélioration de la ductilité dans l'acier calmé à l'aluminium lorsqu'il y a présence de titane. Il explique cela par le fait que la présence du titane favorise la formation de nitrures de titane stables, empêchant l'aluminium de se combiner avec l'azote pour former des AlN plus fragilisant. Ce comportement est observé pour des aciers ayant environ 300 à 400 µg/g d'Al. On indique que le nitrure de titane fragilise l'acier seulement lorsque celui-ci subit un traitement thermique favorisant la formation de précipités de taille très fines. Ils considèrent que le carbure de titane participe à la perte de ductilité par son rôle de retardateur de la recristallisation dynamique.



Figure I.10 : Schéma de l'élément " Titane « Ti »"

Tableau. I.1 : Propriétés les éléments d'addition [36]

	Résistance à la traction	Re	Résistance à l'usure	Résistance à la fatigue	Résilience	Dureté à froid	Dureté à chaud	A%
<i>Aluminium</i>					↗			
<i>Carbone</i>	↗		↗		↘	↗		
<i>Cobalt</i>		↗					↗	
<i>Chrome</i>	↗	↗	↗		↘	↗		↘
<i>Manganèse</i>	↗	↗	↗			↗		↘
<i>Molybdène</i>	↗	↗					↗	
<i>Nickel</i>	↗	↗	↗		↘			↘
<i>Silicium</i>	↗	↗	↗			↗		
<i>Titane</i>	↗	↗	↗		↘	↗	↗	
<i>Tungstène</i>	↗	↗	↗			↗	↗	
<i>Vanadium</i>	↗	↗		↗	↘	↗		



CHAPITRE II

*Généralités sur les réseaux de neurones
et leur utilisation.*

II.1. Généralités

Aujourd'hui de nombreux termes sont utilisés dans la littérature pour désigner le domaine des réseaux de neurones artificiels, comme connexionnisme ou neuromimétique. 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 neuromimétique 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'objectif poursuivi par les chercheurs connexionnistes est d'améliorer les capacités de l'informatique en utilisant des modèles aux composants fortement connectés. Pour leur part, les neuromiméticiens manipulent des modèles de réseaux de neurones artificiels dans l'unique but de vérifier leurs théories biologiques du fonctionnement du système nerveux central.

II.1.1. Définition

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.....

➤ Le cerveau humain




Figure II.1 : Le cerveau humain [37]

Le cerveau humain est constitué d'environ 1010 Neurones connectés chacun à 104 neurones. Ce système organique permet une bonne adaptation aux tâches complexes, est robuste aux pannes (continue de fonctionner même en cas de lésion quelquefois importante) et possède des capacités d'apprentissage, de généralisation et d'auto organisation.

➤ **La science du gouvernement et neurones**

La science du gouvernement étudie les propriétés et les lois du comportement de différent système de contrôle, indépendamment de la nature physique de ces systèmes. C'est L'étude des systèmes de traitement de l'information. Ses fondateurs principaux sont: Wiener, Shannon, Turing, Von Neumann, Ashby, Grey Walter, Culloch, Pitts, Rosenblatt, Kolmogorov

➤ **Les réseaux de neurones**

Les réseaux de neurones constituent une nouvelle race de machines qui par conception se rapproche du cerveau humain.

II.1.2. Historique

1943 Mc Culloch&Pitts : Définition du neurone formel

1948 Von Neumann : Définition de l'automate cellulaire

1949 Hebb : Définition de la "Synapticplasticity"

1960 Rosenblatt : Premiers travaux sur le Perceptron

1969 Minsky&Papert : Limites du Perceptron

1970 Conway : Turing et jeu de la vie

1982 Hopfield : Modélisation "Spin glasses"

1985 Hopfield : Résolution du problème du voyageur de commerce avec un réseau de neurones

1985 Rumelhart : Définition et expérimentation de l'algorithme de rétro-propagation du gradient
1986 Sejnowski : Définition et réalisation du réseau "NetTalk" d'apprentissage à la lecture.

II.1.3. Approche classique et neuronale de la mémoire

L'approche classique de la mémoire fait que chaque donnée élémentaire est à tout moment stockée en un seul endroit de la machine.

L'approche neuronale de la mémoire fait que chaque donnée élémentaire est à tout moment répartie sur l'ensemble de la machine.

Tableau II.1 : Comparaisons de ces deux approches

<i>Données Localisées</i>	<i>Données Délocalisées</i>
<i>Programmation décomposée en étapes</i>	<i>Programmation non décomposable</i>
<i>Tolérance aux fautes à gérer explicitement</i>	<i>Tolérance aux fautes intrinsèque</i>
<i>Réalisation numérique (en générale)</i>	<i>Réalisation numérique analogique ou mixte</i>
<i>Le temps de traitement croît très vite avec la Taille et la complexité</i>	<i>Le temps de traitement est indépendant de la taille et de la complexité</i>

II.1.4. Axiomes de définition d'un réseau de neurone

Ce type de machine repose sur un certain nombre d'axiomes dont voici les principaux :

- 1) Le neurone répond par tout ou rien.
- 2) Pour exciter le neurone à un moment quelconque, un nombre fixé de synapses y arrivant doivent être excitées au cours d'une période où leurs effets puissent se sommer.
- 3) Le seul délai significatif dans le système nerveux est le délai synaptique.
- 4) L'excitation d'une synapse inhibitrice empêche toute réponse du neurone.
- 5) La structure du réseau neuronique ne change pas au cours du temps.
(Axiomes 1 à 5 : Mc Culloch et Pitts en 1943).
- 6) Les synapses sont pondérées, et la réponse du neurone se fait en tout ou rien après un certain seuil.(Axiome 2 modifié par Von Neumann en 1958).
- 7) L'excitation du neurone dépend également des groupes de neurones avoisinant, qui sont stimulés en même temps que lui.(Axiome de Jan Geysel en 1963)

D'autre jeux d'axiomes peuvent être utilisés, par exemple en considérant que la réponse d'un neurone n'est pas binaire mais continue dans le domaine]-1, +1[.

II.2. Modélisation par réseau de neurones

L'Analyse de régression est la technique de modélisation la plus courante dans l'exploration statistique de données, laquelle décrit la relation entre les variables en construisant des équations de régression.

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. [38]

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.

II.2.1. Neurone biologique

Dans le cerveau humain, un neurone typique recueille les signaux des autres à travers une multitude de structures fines appelées dendrites. Le neurone envoie des pics d'activité électrique à travers un long, un support mince connu sous le nom d'un axone, qui se divise en des milliers de branches.

A la fin de chaque branche, une structure appelée synapse convertit l'activité de l'axone en compte les effets électriques qui inhibent ou excitent l'activité de l'axone en compte les effets électriques qui inhibent ou excitent l'activité dans les neurones connectés. Quand un neurone reçoit une entrée excitatrice qui est suffisamment grande par rapport à son entrée inhibitrice, il envoie un pic d'activité électrique vers le bas de son axone [Figure. II.2].




Figure. II.2 : Schéma d'un neurone biologique [39]

II.2.2. Neurone formel

Le neurone artificiel (ou cellule) est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones appartenant à un niveau situé en amont (on parlera de neurones "amont").

A chacune des entrées est associé un poids w 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 appartenant à un niveau situé en aval (on parlera de neurones "avals"). A chaque connexion est associé un poids [Figure. II.3]. Les réseaux de neurones formels sont à l'origine d'une tentative de modélisation mathématiques du cerveau humain. La modélisation consiste à mettre en œuvre un système de réseaux neuronal sous un aspect non pas biologique mais artificiel.

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. II.4].




Figure. II.3 : Structure d'un neurone artificiel




Figure. II.4 : Structure d'un Neurone formel

▪ Fonctions d'activation

Dans sa première version, le neurone formel était donc implémenté avec une fonction à seuil, mais de nombreuses versions existent. Ainsi le neurone de McCulloch et Pitts a été généralisé de différentes manières, en choisissant d'autres fonctions d'activations. La sortie du neurone dépend d'une fonction de transfert, dont les principales sont : [40]

a) fonction binaire à seuil

$$h(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases} \quad \text{sgn}(x) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{sinon} \end{cases}$$

Le seuil introduit une non-linéarité dans le comportement du neurone, cependant il limite la gamme des réponses possibles à deux valeurs.




Figure. II.5 : Fonctions binaires à seuil

b) Fonction linéaire

C'est l'une des fonctions d'activations les plus simples, sa fonction est définie par : $F(x)=x$

c) Fonction linéaire à seuil ou multi seuil

Cette fonction représente un compromis entre la fonction linéaire et la fonction seuil, entre ses deux barres de saturation, elle confère au neurone une gamme de réponses possibles. En modulant la pente de la linéarité, on affecte la plage de réponse du neurone.

$$F(x) = \begin{cases} x & \text{si } x \in [u, v] \\ v & \text{si } x > v \\ u & \text{si } x < u \end{cases}$$




Figure. II.6 : Fonction linéaire

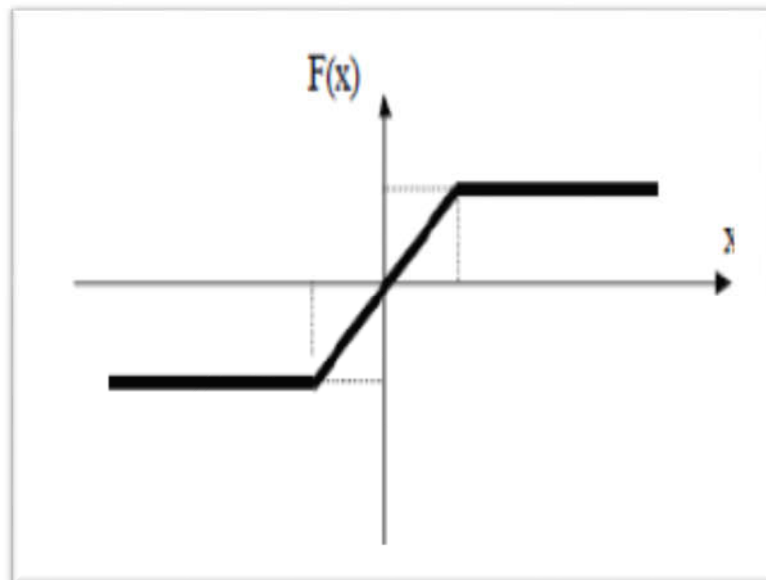


Figure. II.7 : Fonction linéaire a seuil

d) La fonction sigmoïde

Elle est l'équivalent continu de la fonction linéaire. Etant continu, elle est dérivable, d'autant plus que sa dérivée est simple à calculer, elle est définie par :

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




Figure. II.8 : Fonction sigmoïde

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

Les fonctions réalisées par un neurone formel sont représentées sur les *figures (II.9), (II.10) et (II.11)*.

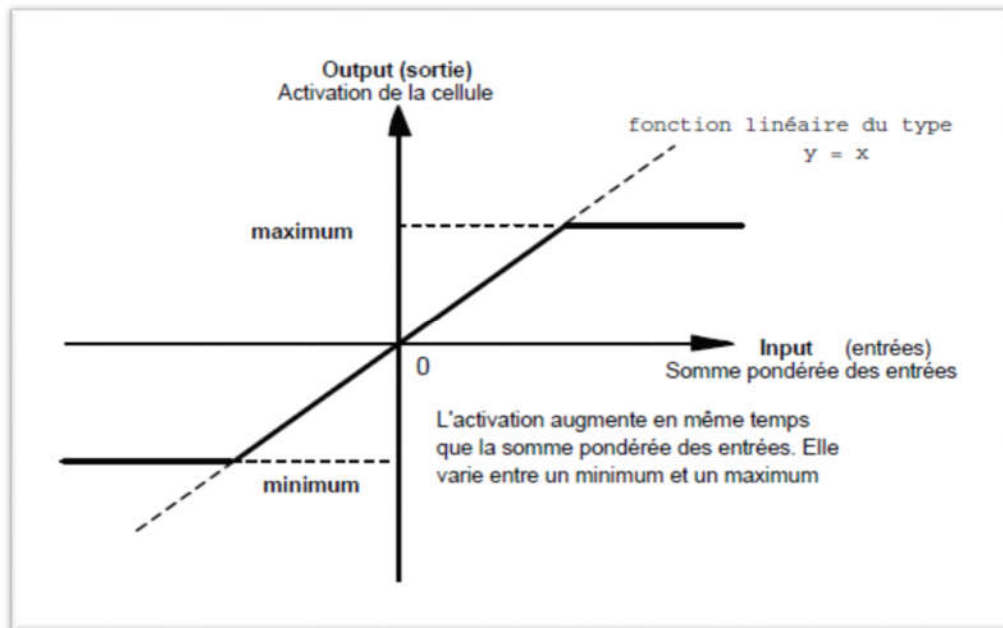


Figure. II.9 : Fonction linéaire

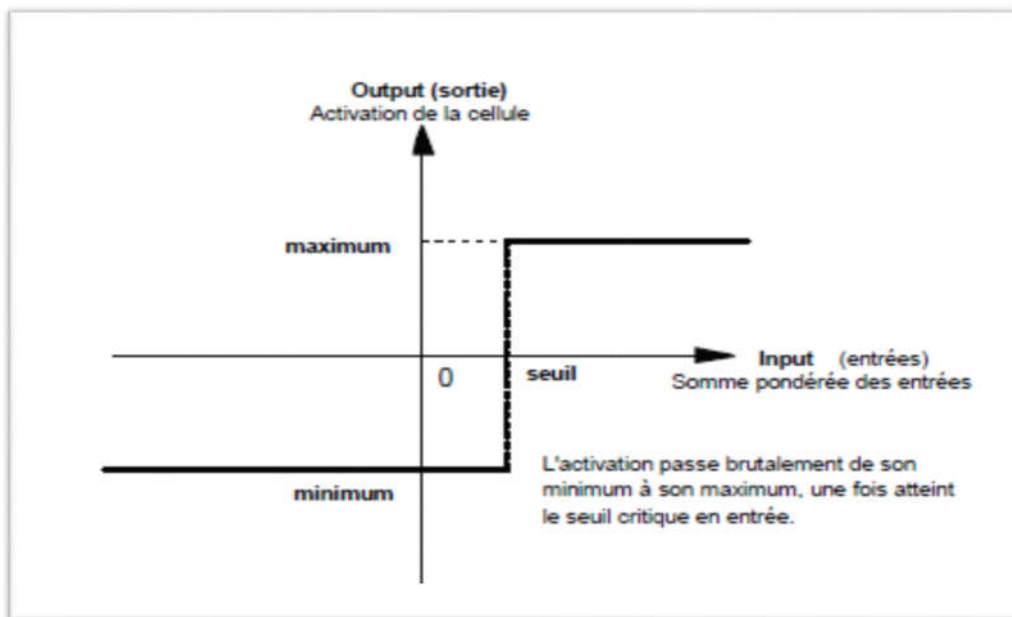


Figure. II.10 : Fonction à seuil




Figure. II.11 : Fonction sigmoïde

II.2.3. Réseau de neurones artificiel (RNN)

II.2.3.1. Définition

Un ANN (Réseau de Neurones Artificiels) est un ensemble de neurones formels (d'unités de calcul simples, de nœuds processeurs) associés en couches (ou sous-groupes) et fonctionnant en parallèle. Dans un réseau, chaque sous-groupe fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit par aucune, soit par plusieurs couches intermédiaires (dites couches cachées).

Habituellement (excepté pour les couches d'entrée et de sortie), chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante. Les RNA ont la capacité de stocker de la connaissance empirique et de la rendre disponible à l'usage. Les habiletés de traitement (et donc la connaissance) du réseau vont être stockées dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage.

II.2.3.2. Architecture d'un réseau de neurones artificiel

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité (réseau à connexion complète). [41]

1) Réseaux monocouche

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soient entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids.




Figure. II.12 : Réseau de neurones monocouche Réseaux multicouche

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 de couches avales. 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 d'entrée, couche de sortie

l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.




Figure. II.13 : Réseau de neurones multicouche

II.2.4. L'apprentissage des réseaux de neurones

L'objectif de l'apprentissage est de fournir une méthode au réseau, afin qu'il puisse ajuster ses paramètres lorsqu'on lui présente des exemples à traiter. En effet les réseaux de neurones ont été appliqués avec succès à l'apprentissage de tâches de classification et d'approximation de fonctions.

Est le processus d'adaptation des paramètres d'un système pour donner une réponse désirée à une entrée ou stimulation quelconque.

II.2.4.1. Choix de l'algorithme d'apprentissage

Un réseau de neurones passe par une phase d'apprentissage. Celle-ci s'effectue grâce à le choix de l'algorithme d'apprentissage relatif au problème à traiter. Une des méthodes d'apprentissage des réseaux de neurones est la rétro-propagation du gradient de l'erreur est plus connu sous son nom anglais « back propagation ». Cet algorithme est utilisé dans les réseaux de type feedforward, ce sont des réseaux de neurones à couches, ayant une couche d'entrée, une couche de sortie, et au moins une couche cachée. Il n'y a pas de récursivité dans les connexions, et pas de connexions entre neurones de la même couche. Le principe de la rétro-propagation consiste à présenter au réseau un vecteur d'entrées, de procéder au calcul de la sortie par propagation à travers les couches, de la couche d'entrée vers la couche de sortie en passant par les couches cachées. Cette sortie obtenue est comparée à la sortie désirée, une erreur est alors obtenue. A partir de cette erreur, est calculé le gradient de l'erreur qui est à son tour propagé de la couche de sortie vers la couche d'entrée, d'où le terme de rétro-propagation. Cela permet la modification des poids du réseau et donc l'apprentissage. L'opération est répétée pour chaque vecteur d'entrée et cela jusqu'à ce que le critère d'arrêt soit vérifié.

II.2.4.2. Critères d'arrêt

Plusieurs critères d'arrêts peuvent être utilisés avec l'algorithme de rétro propagation des erreurs. Le plus commun consiste à fixer un nombre maximum de périodes d'entraînement, Ce qui fixe effectivement une limite supérieure sur la durée de l'apprentissage. Ce critère est important car la rétro propagation des erreurs n'offre aucune garantie quant à la convergence de l'algorithme. Il peut arriver, par exemple, que le processus d'optimisation reste pris dans un minimum local. Sans un tel critère, l'algorithme pourrait ne jamais se terminer. Un deuxième critère commun consiste à fixer une borne inférieure sur l'erreur quadratique moyenne, ou encore sur la racine carrée de cette erreur. Dépendant de l'application, il est parfois possible de fixer a priori un objectif à atteindre. Lorsque l'indice de performance choisi diminue en dessous de cet objectif, on considère simplement que le **PMC** a suffisamment bien appris ses données et on arrête l'apprentissage.

Les deux critères précédents sont utiles mais ils comportent aussi des limitations. Le critère relatif au nombre maximum de périodes d'entraînement n'est aucunement lié à la performance du réseau.

Le critère relatif à l'erreur minimale obtenue mesure quant à lui un indice de performance mais ce dernier peut engendrer un phénomène dit de sur-apprentissage qui n'est pas désirable dans la pratique, surtout si l'on ne possède pas une grande quantité de données d'apprentissage, ou si ces dernières ne sont pas de bonne qualité.

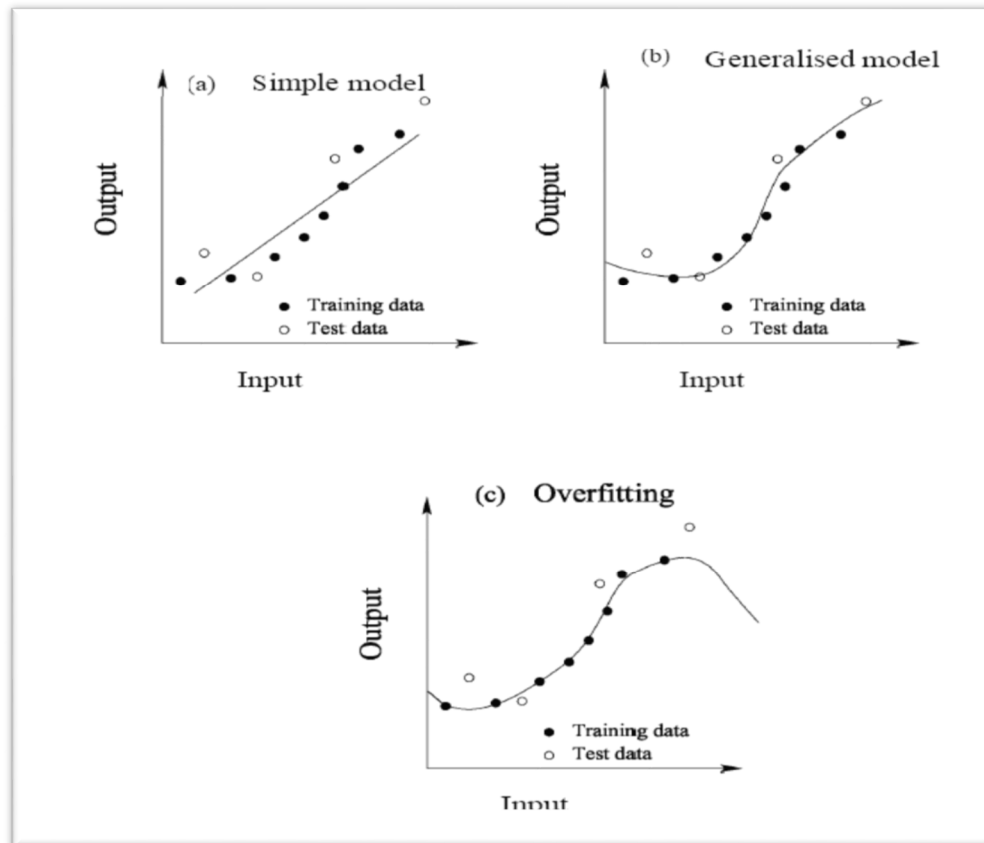


Figure. II.14 : Illustration du degré de la complexité d'un réseau

Un processus d'apprentissage par correction des erreurs, comme celui de la rétro propagation, vise à réduire autant que possible l'erreur que commet le réseau. Mais cette erreur est mesurée sur un ensemble de données d'apprentissage. Si les données sont bonnes, c'est-à-dire qu'elles représentent bien le processus physique sous-jacent que l'on tente d'apprendre ou de modéliser, et que l'algorithme a convergé sur un optimum global, alors il devrait bien performer sur d'autres données issues du même processus physique.

Cependant, si les données d'apprentissage sont partiellement corrompues par du bruit ou par des erreurs de mesure, alors il n'est pas évident que la performance optimale du réseau sera atteinte en minimisant l'erreur, lorsqu'on la testera sur un jeu de données différent de

celui qui a servi à l'entraînement. On parle alors de la capacité du réseau à généraliser, c'est-à-dire de bien performer avec des données qu'il n'a jamais vu auparavant [Figure. II.14].

Par exemple, la [Figure. II.15] illustre le problème du sur-apprentissage dans le contexte d'une tâche d'approximation de fonction. La droite en pointillés montre une fonction linéaire que l'on voudrait approximer en ne connaissant que les points noirs. La courbe en trait plein montre ce qu'un réseau hypothétique pourrait apprendre. On constate que la courbe passe par tous les points d'entraînement et donc que l'erreur est nulle. De toute évidence, ce réseau ne généralisera pas bien si l'on échantillonne d'autres points sur la droite.




Figure. II.15 : Illustration du phénomène de sur-apprentissage pour le cas simple d'une approximation de fonction

Une solution à ce problème consiste à utiliser un autre critère d'arrêt basé sur une technique dite de validation croisée (en anglais «*cross-validation*»). Cette technique consiste à utiliser deux ensembles indépendants de données pour entraîner notre réseau : un pour l'apprentissage (l'ajustement des poids) et l'autre pour la validation, c'est-à-dire le calcul d'un indice de performance (une erreur, un taux de reconnaissance ou tout autre mesure pertinente à l'application). Le critère d'arrêt consiste alors à stopper l'apprentissage lorsque l'indice de performance calculé sur les données de validation cesse de s'améliorer pendant

plusieurs périodes d'entraînement. La [Figure. II.16] illustre le critère de la validation croisée dans le cas d'un indice de performance que l'on cherche à minimiser.

La courbe en pointillés de ce graphique représente l'indice de performance d'un réseau hypothétique calculé sur les données d'apprentissage, alors que la courbe en trait plein montre le même indice mais calculé sur les données de validation. On voit qu'il peut exister un moment au cours de l'apprentissage où l'indice en validation se détériore alors que le même indice continue à s'améliorer pour les données d'entraînement. C'est alors le début du «sur-apprentissage».




Figure. II.16 : Illustration de la validation croisée

II.3.Conclusion

Nous avons présenté dans ce chapitre des notions sur les réseaux de neurones formels. Nous tenons à rappeler que pour l'analyse des données les méthodes statistiques demeurent très importantes et elles sont largement utilisées. Le réseau de neurone est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement de vrais neurones. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissages. Ces notions sont nécessaires pour mieux mener l'étude dans le chapitre **III**.



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 [42]. 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 [43]. Par conséquent, de nombreux chercheurs ont optés pour des méthodes empiriques permettant de relier les variables de processus à la contrainte d'écoulement [44].

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 [45] 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)

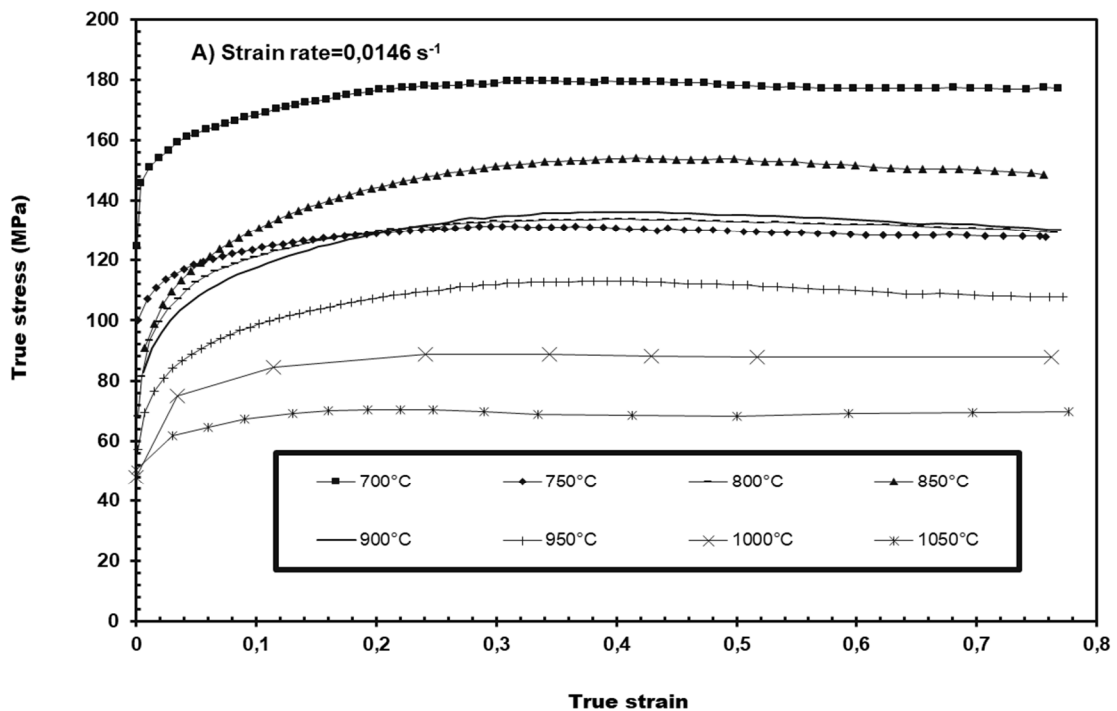


Figure III.5 : Courbes contrainte-déformation sous différentes températures avec une valeur de vitesse de déformation $0,0146 \text{ S}^{-1}$




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 [46]. 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 [47].
- 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 :

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

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

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

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 :

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

La méthode de Newton est de second ordre et donc exige également la matrice hessienne. L'élément k, j de la Hessian:

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

Ou sous forme de matrice

$$\nabla^2 F(x) = 2J^T(x)J(x) + 2S(x) \tag{24}$$

Avec :

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

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

$$\nabla^2 F(x) = 2J^T(x)J(x) \tag{26}$$

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

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

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 :

$$G = H + \mu I \tag{28}$$

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 donné par l'équation (29) ou l'équation (30).

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

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

Lorsque μ_k augmente, l'algorithme se rapproche de la méthode de descente brutale et si μ 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 Jacobien pour un Levenberg-Marquardt multicouche devient:

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

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

$$S_{i,h}^{-m} = \frac{\partial v_h}{\partial n_{i,q}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \tag{32}$$

Avec :

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

Les éléments du Jacobéen pour les poids sont donnés maintenant par

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

Or pour

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

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

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

Maintenant, le réseau peut être initialisé avec

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

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

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

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.

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

- **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. Une autre 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

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

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 :

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

où

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

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

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

ou

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

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 :

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

En remplaçant :

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

Ou sous forme de matrice :

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

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.

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].

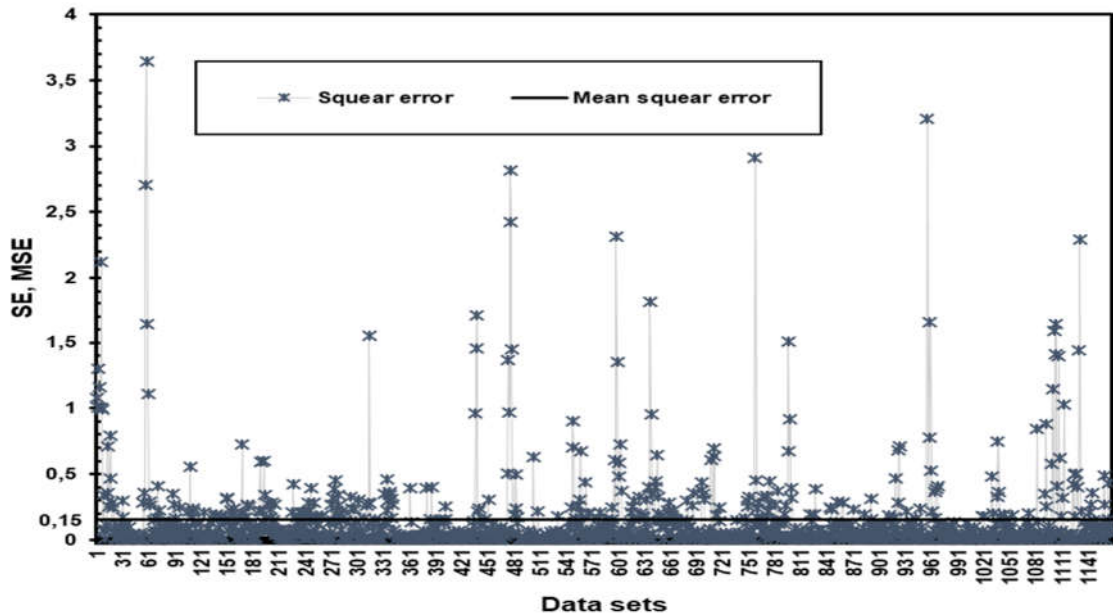


Figure III. 8 : L'erreur quadratique (SE) et l'erreur quadratique moyenne (MSE) de l'ensemble des données




Figure III. 9 : L'architecture optimale du réseau de neurones artificiels

III.3.4. Résultats du réseau de neurones développé

La prévisibilité du modèle RNA est vérifiée dans cette étude en utilisant deux indicateurs statistiques : l'erreur relative absolue (AAR) et le coefficient de corrélation (R). Ces indicateurs sont donnés dans les équations (12) et (13).

La valeur plus élevée de R proche de 1 indique que les valeurs prédites sont bien conformes aux valeurs expérimentales ; pendant ce temps, une valeur AARE basse proche de zéro indique que la somme des erreurs entre les valeurs prédites et les valeurs expérimentales tend à être nulle. Ainsi, de tels R et AARE sont attendus.

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.




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

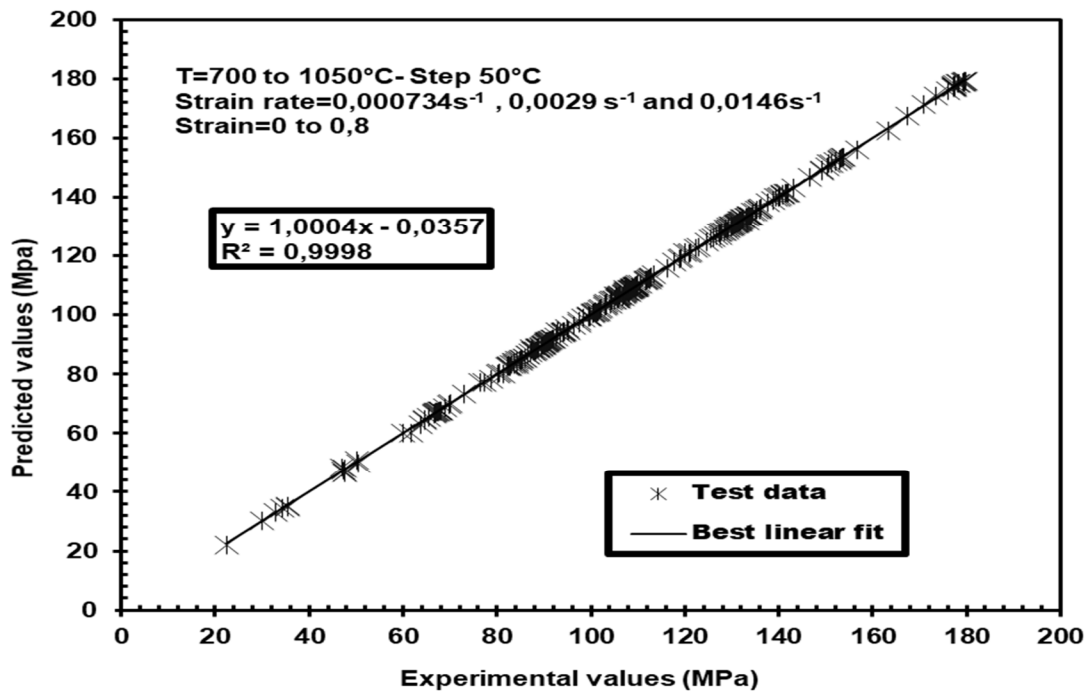


Figure III.10.b : Contrainte d'écoulement mesurée face au prédite pour l'ensemble de test




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

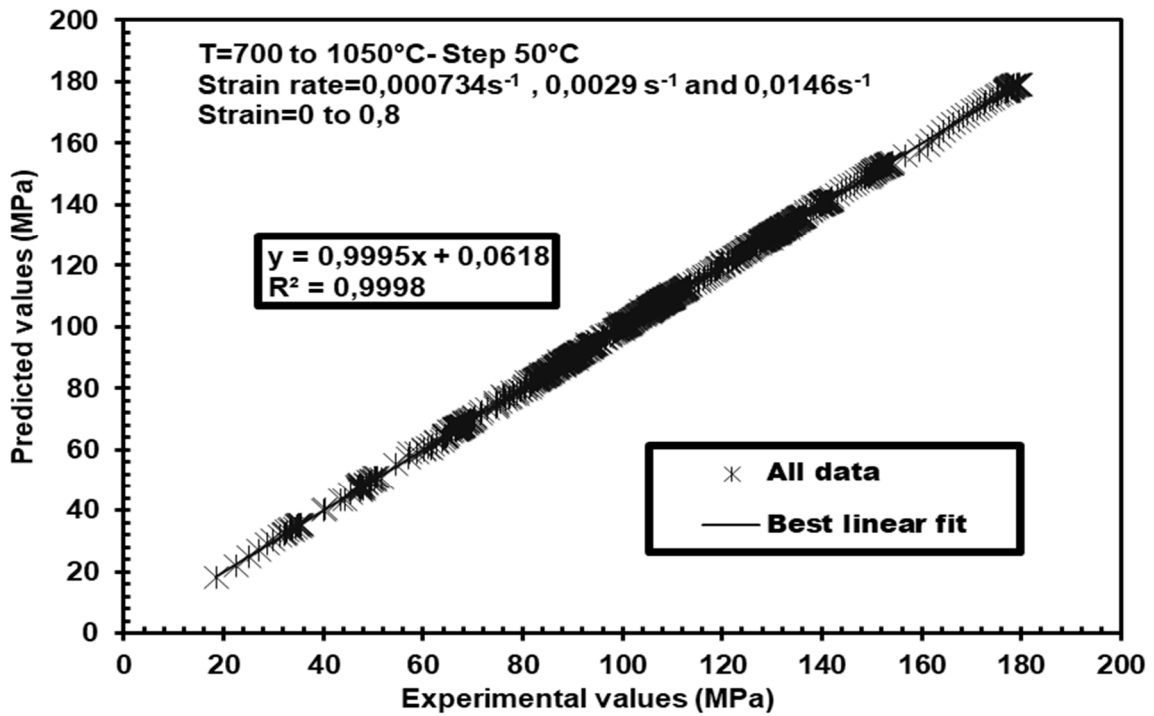


Figure III.10.d : Contrainte d'écoulement mesurée face au prédite pour l'ensemble des données.

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.

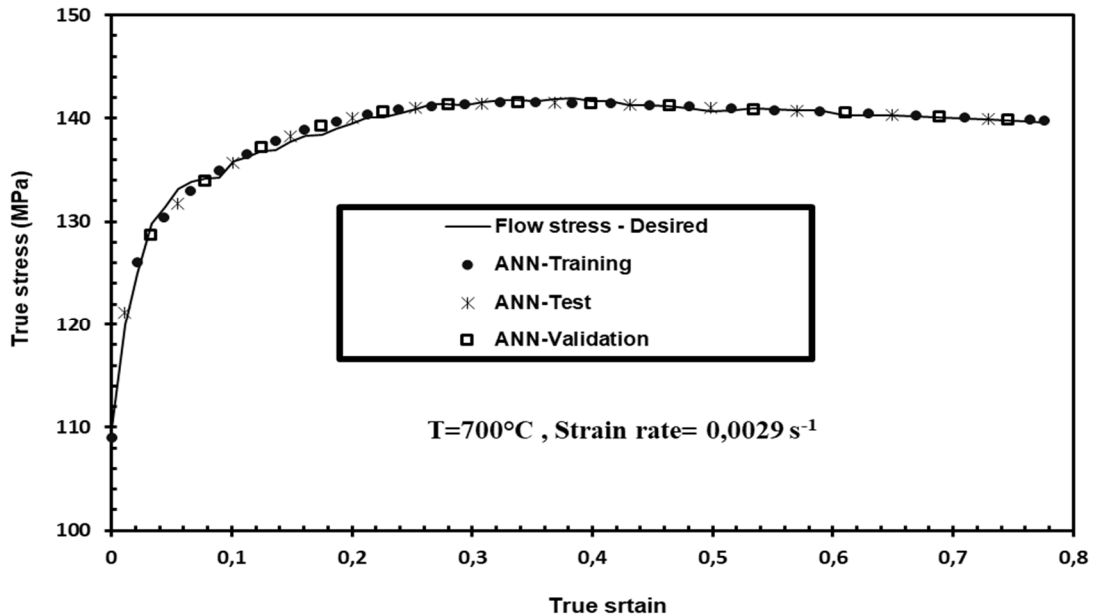


Figure III.12 : Valeurs expérimentales et prévues de la contrainte d'écoulement pour la vitesse de déformation $\dot{\epsilon} = 0,0029 \text{ S}^{-1}$ et $T = 700 \text{ }^\circ\text{C}$




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 $T = 1050 \text{ } ^\circ\text{C}$

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 $700 \text{ } ^\circ\text{C}$ et $750 \text{ } ^\circ\text{C}$, suivie d'une augmentation entre $750 \text{ } ^\circ\text{C}$ et $850 \text{ } ^\circ\text{C}$. Enfin, au-delà de $850 \text{ } ^\circ\text{C}$, 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 $AC1 = 710 \text{ } ^\circ\text{C}$ et $AC3 = 850 \text{ } ^\circ\text{C}$.




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 S⁻¹ à T = 700 °C




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

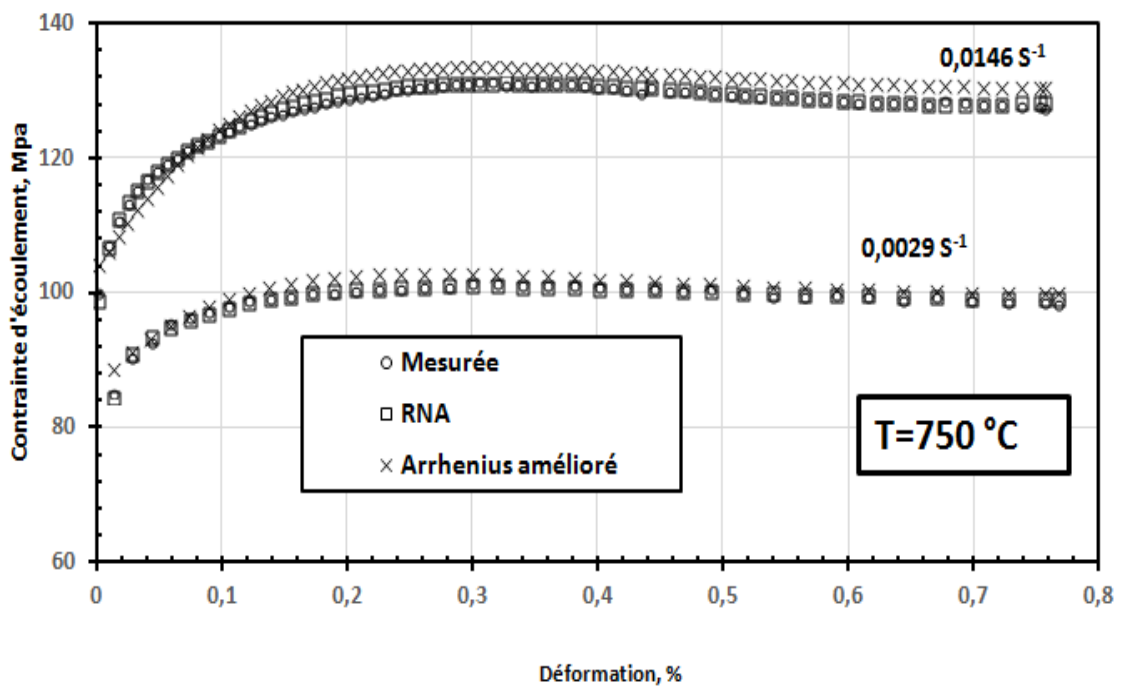


Figure III.20 : Valeurs expérimentales et prévues de la contrainte d'écoulement pour différentes vitesses de déformation à $T = 750\text{ °C}$




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




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




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

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 $700 \sim 1050 \text{ °C}$ et une vitesse de déformation plage de $0,0029 \text{ S}^{-1}$, $0,0146 \text{ S}^{-1}$ et $0,000734 \text{ S}^{-1}$. 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



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

Conclusion générale

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 powerform, *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 En, 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] 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.
- [33] 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.
- [34] 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.
- [35] 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.
- [36] 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.
- [37] 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.
- [38] 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. NonferrousMet. Soc. China* **2016**, *26*, 1096–1104.
- [39] 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.
- [40] 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.
- [41] 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.
- [42] 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.

- [43] 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.
- [44] 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.
- [45] 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.
- [46] 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.
- [47] 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.
- [48] 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.
- [49] 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.
- [50] 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.
- [51] 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.
- [52] 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.
- [53] 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.

- [54] 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**.
- [55] W. Chen, P. Garder, 'Word level discriminative training for handwritten word recognition', *Proc. 7th IWFHR*, pp. 393-402, Amsterdam, **2000**.
- [56] H. A. Beghdadi, M. Senouci, 'Réseaux de neurones : théorie et pratique', Office des Publications Universitaires, Algérie, **2005**.
- [57] Dreyfus G., Martinez J-M., Samuelides M., Gordon M.B., Badran F., Thiria SS., Hérault L, *Réseaux de neurones : Méthodologie et Applications*, Eyrolles, **2002**.
- [58] 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
- [59] Rakhshkhorshid M, Hashemi SH (**2013**) Experimental study of hot deformation behavior in API X65 steel. *Mater Sci Eng* 573:37–44
- [60] 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
- [61] Mirzadeh H, Najafizadeh A (**2010**) Flow stress prediction at hot working conditions. *Mater Sci Eng A* 527:1160–1164
- [62] 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] = premmmx(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] = premmmx(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

```