

Prédiction des contraintes résiduelles en tournage dur de l'acier 100Cr6 par la méthode des réseaux de neurones

S. MAKHFI^{a,b}, M. HABAK^b, R. VELASCO^b, K. HADDOUCHE^a, P. VANTOMME^b

a. Laboratoire des Technologies Industrielles, Université Ibn Khaldoun de Tiaret, B.P.78, Tiaret 14000, Algérie.

b. Laboratoire des Technologies Innovantes E.A. 3899, Université de Picardie Jules Verne, avenue des Facultés, Le Bailly, 80025 Amiens Cedex1, France.

Résumé:

Le procédé de coupe génère des contraintes résiduelles qui peuvent influencer le comportement mécanique des pièces usinées. Dans le but de prédire l'intégrité de surface de ces pièces, une méthode de calcul basée sur les réseaux de neurones artificiels (RNA) a été développée. Le réseau étudié est un feed-forward de type perceptron multicouches avec rétro-propagation de gradient d'erreur. Une architecture comprenant 6 entrées (V_c , f , a_p , A , B et n) et 2 sorties (contraintes résiduelles axiales et circonférentielles) a été utilisée. Les résultats ont mis en évidence les performances de la configuration étudiée et ont montré que le choix des paramètres a une influence sur la convergence de l'algorithme.

Abstract:

The cutting process generates residual stresses which may influence the mechanical behavior of machined parts, In order to predict the surface integrity of these pieces. A calculation method based on artificial neural networks (ANNs) was developed. The studied network is a feed-forward type multilayer perceptron with back-propagation of error gradient. An architecture comprising 6 inputs (V_c , f , a_p , A , B and n) and 2 outputs (axial and circumferential residual stresses) was used. The results showed the performance of the studied configuration and showed that the choice of parameters has an influence on the convergence of the algorithm.

Mots clefs : usinage, contraintes résiduelles, réseaux de neurones artificiels, prédiction.

1 Introduction

L'usinage est un procédé de génération de surfaces. Il consiste à créer une nouvelle surface par enlèvement de matière en utilisant un outil coupant. Les caractéristiques de cette surface dépendent du matériau usiné, de l'outil de coupe et des paramètres misent en jeu pendant la coupe (vitesse de coupe, vitesse d'avance, profondeur de passe, lubrification ...).

Le procédé de coupe engendre en surface de la pièce des contraintes résiduelles qui résultent le plus souvent d'un couplage entre des effets thermiques (montée de température générée par la coupe), mécaniques (déformation plastique qui accompagne la génération de copeau) et métallurgiques (transformation de phase) intervenant dans la zone de coupe lors de la génération du copeau. Ces contraintes résiduelles influent sur la durée de vie des composants mécaniques en accélérant ou en retardant la propagation de fissures. Ainsi, la maîtrise de ces contraintes est essentielle afin d'optimiser les gammes de fabrication et de garantir une durée de vie compatible avec les exigences applicatives.

Dans le but de prédire les résultats issues du processus de coupe, les industriels et chercheurs ont recours de plus en plus à l'application des réseaux de neurones artificiels (RNA). Ces modèles peuvent servir de base de développement de logiciels de prédiction, par exemple, des états de contraintes résiduelles après une opération de coupe en limitant le nombre d'études expérimentales.

Toparli et al. [1] ont utilisé deux méthodes pour le calcul des contraintes résiduelles dans des barres d'acier trempé dans l'eau à partir de 600 °C: la méthode des éléments finis (FEM) et celle des RNA. Pour ce dernier un réseau feed-forward multicouches avec rétro-propagation du gradient d'erreur a été utilisé. Les

résultats obtenus par la méthode RNA sont comparable à ceux obtenus par la FEM. Umbrello et al. [2,4] et Ambrogio et al. [3] ont développé des modèles théoriques permettant de prédire les conditions de coupe requises pour aboutir à un état de contrainte résiduelle donné en utilisant les RNA. Kafkas et al. [5] ont présenté une approche basée sur les RNA de type feed-forward avec une couche cachée pour déterminer les contraintes résiduelles dans un acier PM base Nickel (FLN2-4405) avec différents traitements thermiques. Ils ont utilisé l'algorithme de rétro-propagation du gradient d'erreur dans l'apprentissage et les fonctions d'entraînement de Levenberg-Marquart (LM) et Scaled Conjugate Gradient (SCG). Karataş et al. [6] ont opté pour un RNA avec l'algorithme de rétro-propagation de gradient d'erreur dans l'apprentissage. Ils ont exploité les résultats de mesures expérimentales comme données d'entraînement et de test pour déterminer les contraintes résiduelles en fonction des conditions de grenailage. Les résultats de la modélisation mathématique ont été approuvés.

Dans ce contexte, nous proposons une approche méthodologique pour l'optimisation d'une configuration d'un RNA, adaptée à prédire les contraintes résiduelles. Le réseau est alimenté à partir des résultats expérimentaux de plusieurs campagnes d'essais en tournage dur (chariotage) d'un acier 100Cr6 durci (avec et sans carbure) en utilisant un outil avec une coupe négative (-20°) type cBN (BNX10 de Sumitomo) [7].

Le réseau de neurones étudié est un réseau feed-forward de type perceptron multicouche MLP (Multi Layer Perceptron) avec rétro-propagation de gradient d'erreur, comportant une couche d'entrée, une couche cachée et une couche de sortie. L'emploi de la couche cachée permet de donner une forme non-linéaire entre les unités d'entrées et de sorties [8]. Le réseau de neurones MLP avec rétro-propagation de gradient d'erreur a été choisi pour sa simplicité, son utilisation très vaste dans le domaine des génies des procédés [9] et pour les résultats satisfaisants déjà obtenus avec ce modèle.

2 Présentation des contraintes résiduelles

La détermination des contraintes résiduelles est effectuée par la technique de la diffraction des rayons X. Les contraintes sont mesurées selon deux directions (figure 1) : celle de la vitesse de coupe (contraintes longitudinales, nommées contraintes axiales σ_{xx} [MPa]) et celle de la vitesse d'avance (contraintes transversales, nommées contraintes circonférentielles σ_{yy} [MPa]) [7].




FIG. 1 - Directions d'analyses des contraintes résiduelles [7].

3 Méthodologie des réseaux de neurones artificiels (RNA)

Un RNA est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. En général, il est composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Les RNA sont généralement optimisés par des méthodes d'apprentissage. Des exemples d'apprentissage (jeux de valeurs d'entrées et sorties) sont fournis au réseau. L'apprentissage consiste à calculer les poids et les biais (le seuil d'activation d'un neurone) des connexions entre les différentes couches de telle manière que les sorties du réseau soient, pour les exemples utilisés, aussi proches que possible des sorties désirées. Pour ce faire, on utilise des algorithmes d'optimisation qui minimisent une fonction de coût constituée d'une mesure de l'écart entre la réponse réelle du réseau et la réponse désirée. Cette optimisation se fait de manière itérative, en modifiant les poids et les biais en fonction du gradient de la fonction du coût : le gradient est estimé par une méthode spécifique au réseau de neurones, dite méthode de rétro-propagation de l'erreur. Les poids et les biais sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement jusqu'à ce que l'erreur entre la sortie du réseau (résultats calculés) et les résultats désirés soient minimisés sur l'ensemble des données d'apprentissage.

Le neurone formel est conçu comme un automate doté d'une fonction de transfert qui transforme ses entrées en sorties selon des règles précises. Il est souvent représenté sous la forme donnée en figure 2 où f est la

fonction d'activation et a la sortie du neurone (modèle de Mc Culloch et Pitts, 1943). Les informations détaillées sur RNA peuvent être trouvée dans [10].

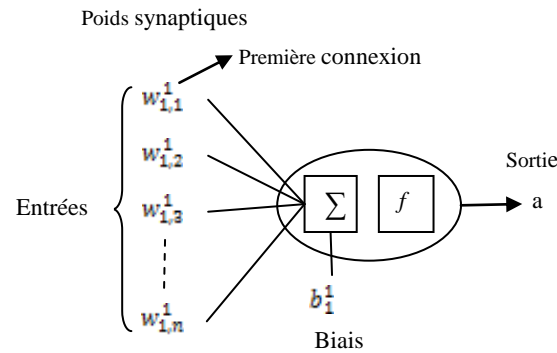


FIG. 2 - Modèle mathématique d'un neurone formel.

L'équation qui décrit la sortie du neurone i de la couche $k+1$ est donnée par l'équation (1) [11]:

$$a_i^{k+1} = f\left(\sum_{j=1}^{s^k} w_{i,j}^{k+1} a_j^k + b_i^{k+1}\right) \quad (1)$$

Afin de quantifier la qualité des prédictions, la somme de l'erreur quadratique SSE (performance du réseau), de l'erreur entre la valeur mesurée a et la valeur prédite t (sortie du réseau) et le rapport R de la régression linéaire ont été utilisés comme indicateurs de performance lors de l'entraînement du réseau en test.

L'objectif est de minimiser SSE et d'avoir un R proche de l'unité (équation 2).

$$R = \frac{\sum_{k=1}^Q (t(k) - \bar{t})(a(k) - \bar{a})}{\sqrt{\sum_{k=1}^Q (t(k) - \bar{t})^2} * \sqrt{\sum_{k=1}^Q (a(k) - \bar{a})^2}} \quad (2)$$

Où Q est le nombre d'exemples utilisés

\bar{a} et \bar{t} sont les valeurs moyennes des valeurs mesurés et prédites respectivement.

4 Modèle du RNA proposé

Le réseau de neurones artificiels étudié est:

1- De type feed-forward, il se compose d'une couche d'entrée, une couche de sortie et une couche cachée avec un nombre de neurones étant variable (figure 3). L'information est propagée à travers les couches, de la couche d'entrée vers la couche de sortie.

Les entrées sont les coefficients A [MPa], B [MPa], n de la loi de comportement du matériau 100Cr6 durci (terme écrouissage) identifiées par des essais de cisaillement sur éprouvettes type chapeau [7] et les conditions de coupe, à savoir : vitesse de coupe V_c (m/min), vitesse d'avance f (mm/tr) et profondeur de passe a_p (mm). Les sorties sont les contraintes résiduelles axiales σ_{xx} et circonférentielles σ_{yy} .

2- Le perceptron multicouches MLP dont la propagation d'activation de l'entrée vers les couches cachées puis vers la sortie (correspondant à l'état de neurones de la couche de sortie) permet de déterminer la réponse du réseau. Il est alors possible de déduire par comparaison avec la réponse souhaitée, l'erreur commise par le réseau.

3- La rétro-propagation du gradient d'erreur est utilisée pour ajuster les poids et les biais du réseau afin de minimiser l'erreur entre la sortie du réseau et la sortie réelle. Une méthode basée sur la technique de régularisation bayésienne par modération des poids et les biais a été utilisée. Elle consiste à pénaliser les valeurs élevées des poids et les biais en modifiant la fonction de coût (erreur quadratique moyenne entre la valeur mesurée a et la valeur prédite t du réseau) définie par l'équation 3 [11].

$$F = \frac{1}{Q} \sum_{k=1}^Q [t(k) - a(k)]^2 \quad (3)$$

4- Les deux fonctions d'activation (fonction de seuillage, ou fonction de transfert) permettant d'introduire une non-linéarité dans le fonctionnement du neurone utilisées, sont: une fonction type sigmoïde dans la couche cachée et une fonction linéaire dans la couche de sortie.

Avant les phases d'apprentissage et du test du réseau, les valeurs du vecteur d'entrée ont été normalisées dans l'intervalle [-1 1] afin de permettre un traitement efficace par le réseau [12].

L'architecture générale du réseau MLP étudiée est "6-x-2", illustrée dans figure 3 avec x allant de 1 à 20 (nombre de neurones dans la couche cachée).

Pour la phase d'apprentissage 31 exemples d'entrée/sortie ont été utilisés (tableau 2) et pour la phase test 5 exemples d'entrée/sortie autres que ceux utilisés dans la première phase ont été utilisés.




FIG. 3 - Architecture du RNA utilisée.

La figure 4 représente l'évolution de la somme de l'erreur quadratique SSE en fonction du nombre de neurones dans la couche cachée et les régressions linéaires des sorties du réseau par rapport aux valeurs désirées sont données dans le tableau 1. Ces résultats montrent que le nombre de neurones dans la couche cachée influe fortement sur l'efficacité du réseau.

La courbe de la figure 4, montre que la valeur de SSE diminue avec l'augmentation du nombre de neurones x de la couche cachée et se stabilise au delà d'un x = 4.

Dans la suite, le rapport de régression linéaire du test (R-Test) sera utilisé comme indicateur de performance lors de l'entraînement du réseau, il est prépondérant dans la structure 6-9-2 par rapport aux autres structures testées. Nous noterons qu'un réseau de neurones est jugé "bon", lorsqu'il a un pouvoir de généralisation élevé, c'est-à-dire avoir une erreur test acceptable. Donc le choix s'est porté sur un réseau avec l'architecture 6-9-2. Les résultats obtenus sont donnés dans le tableau 1.

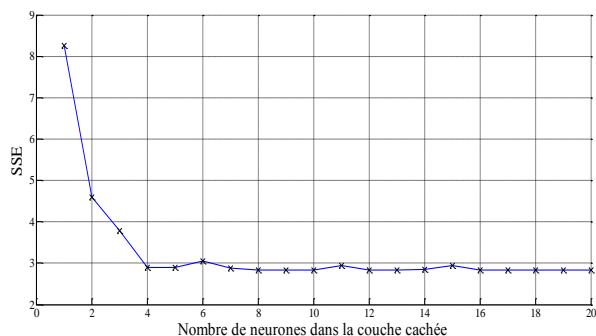


FIG. 4 - Evolution de SSE en fonction du nombre de neurones dans la couche cachée.

Tableau 1 - Résultats obtenus pour différentes architectures.

Structure	R-Apprentissage	R-Test
6-1-2	0.63	0.65
6-4-2	0.89	0.85
6-6-2	0.88	0.87
6-9-2	0.89	0.90
6-11-2	0.89	0.88
6-15-2	0.89	0.88
6-16-2	0.89	0.90
6-17-2	0.89	0.90
6-20-2	0.89	0.90

Tableau 2 - Résultats des valeurs prédites et les erreurs de la structure 6-9-2 par rapport aux données expérimentales dans la phase d'apprentissage.

Essai N°	A [MPa]	B [MPa]	n	V _c (tr/min)	f (mm/tr)	a _p (mm)	Mesurés [MPa]		Prédites [MPa]		Erreur [MPa]	
							σ _{xx}	σ _{yy}	σ _{xx}	σ _{yy}	σ _{xx}	σ _{yy}
1	1492	357	0,21	150	0,1	0,2	106	94	78	97	28	-3
2	2179	1891	0,52	150	0,1	0,2	-24	-116	-117	-156	93	40
3	2179	1891	0,52	300	0,1	0,2	-29	207	-15	268	-14	-61
4	2179	1891	0,52	250	0,1	0,2	-127	48	-117	-5	-10	53
5	2179	1891	0,52	50	0,1	0,2	54	-98	18	-5	36	-93
6	2179	1891	0,52	150	0,05	0,2	-205	-205	-179	-185	-26	-20
7	2179	1891	0,52	200	0,1	0,2	-114	-20	-156	-157	42	137
8	2144	1566	0,51	250	0,1	0,2	-324	-346	-268	-46	-56	-300
9	2144	1566	0,51	150	0,1	0,2	-479	-523	-329	-308	-150	-215
10	2144	1566	0,51	200	0,1	0,2	-280	-297	-341	-260	61	-37
11	2144	1566	0,51	100	0,1	0,2	-240	-331	-261	-243	21	-88
12	1515	565	0,29	200	0,1	0,2	10	2	37	64	-27	-62
13	1515	565	0,29	100	0,1	0,25	-78	-60	28	14	-106	-74
14	1515	565	0,29	150	0,05	0,2	20	43	26	123	-6	-80
15	1515	565	0,29	150	0,1	0,3	119	226	59	228	60	-2
16	1515	565	0,29	150	0,1	0,1	57	97	44	-39	13	136
17	2144	1566	0,51	50	0,1	0,2	-204	33	-183	-149	-21	182
18	2144	1566	0,51	300	0,1	0,2	-116	473	-149	250	33	223
19	1938	1258	0,46	200	0,1	0,2	-173	109	-194	-8	21	117
20	1938	1258	0,46	150	0,1	0,2	-188	-28	-244	-194	56	166
21	1938	1258	0,46	100	0,1	0,2	-154	-186	-232	-249	78	63
22	1938	1258	0,46	150	0,05	0,2	-232	-131	-254	-95	22	-36
23	1938	1258	0,46	150	0,2	0,2	-218	-309	-208	-385	-10	76
24	1938	1258	0,46	150	0,15	0,2	-330	-523	-227	-290	-103	-233
25	1938	1258	0,46	150	0,1	0,3	-379	108	-280	-22	-99	130
26	1938	1258	0,46	150	0,1	0,4	-286	103	-305	131	19	-28
27	1634	797	0,39	100	0,1	0,2	-138	-329	-144	-256	6	-73
28	1515	565	0,29	100	0,1	0,2	21	103	44	-18	-23	121
29	1515	565	0,29	150	0,12	0,1	8	-172	70	-46	-62	-126
30	1515	565	0,29	150	0,2	0,2	200	-52	166	21	34	-73
31	1515	565	0,29	150	0,15	0,2	218	224	127	64	91	160

La figure 5 montre que l'évolution des contraintes prédites suit celle des résultats expérimentaux. Les erreurs entre les contraintes résiduelles mesurés et prédites sont données dans le tableau 2.




FIG. 5 - Résultats des valeurs prédites de la structure 6-9-2 par rapport aux données expérimentales des contraintes résiduelles au cours de l'entraînement. (a). Contraintes axiales. (b). Contraintes circonférentielles.

Afin de vérifier la performance de l'architecture choisie, 5 exemples d'entrée/sortie différents de ceux exploités pour l'apprentissage ont été utilisés. Les résultats obtenus sont données dans le tableau 3, ils montrent que les erreurs sont acceptables.

Comme pour les courbes d'apprentissage, les courbes testes prédites des contraintes résiduelles suivent la même évolution que les courbes expérimentales.




FIG. 6 - Résultats des valeurs prédites de la structure 6-9-2 par rapport aux données expérimentales des contraintes résiduelles au cours du test. (a). Contraintes axiales. (b). Contraintes circonférentielles.

Tableau 3 - Comparaison entre les valeurs des contraintes prédites et expérimentales.

Essai N°	A [MPa]	B [MPa]	n	V _c (tr/min)	f (mm/tr)	a _p (mm)	Mesurés [MPa]		Prédites [MPa]		Erreur [MPa]	
							σ_{xx}	σ_{yy}	σ_{xx}	σ_{yy}	σ_{xx}	σ_{yy}
1	2179	1891	0,5224	200	0,1	0,1	-68	-244	-110	-294	42	50
2	2179	1891	0,5224	150	0,15	0,2	-17	-99	-54	-118	37	19
3	1515	565	0,2893	150	0,1	0,2	0	32	78	95	-78	-63
4	1515	565	0,2893	150	0,08	0,2	96	131	57	106	39	25
5	1634	797	0,3874	150	0,1	0,2	-83	113	-74	-41	-9	154

Les résultats de simulations avec une architecture 6-9-2 obtenus mettent bien en évidence les performances de la configuration du réseau de neurones proposée.

Conclusions

Une méthode de calcul basée sur les réseaux de neurones a été développée dans le but de prédire les contraintes résiduelles superficielles générées par une opération d'enlèvement de matière à l'outil coupant. Le réseau étudié est un feed-forward de type perceptron multicouches à trois couches avec rétro-propagation de gradient d'erreur basée sur la technique de régularisation bayésienne. Une architecture comprenant 6 entrées (V_c , f , a_p , A , B et n) et 2 sorties (contraintes axiales et circonférentielles) a été utilisée.

L'utilisation des fonctions d'activation de type sigmoïde dans les couches cachées et celle de type linéaire dans la couche de sortie est fortement souhaitée.

L'augmentation du nombre de neurones dans la couche cachée n'implique pas obligatoirement l'obtention d'une meilleure performance. Par conséquent, un choix adapté et judicieux d'une architecture optimale doit nécessairement être opéré, Ceci nous a permis de faire un choix d'une architecture pour continuer l'étude, à faible coefficient de régression en test. L'analyse des différentes architectures en se basant sur SSE en fonction de nombres de neurones dans la couche cachée et sur l'indicateur de performance R-Test du réseau mettent bien en évidence l'architecture 6-9-2 du réseau choisi.

References

- [1] Toparli M., Sahin S., Ozkaya E., Sasaki S., A residual thermal stress analysis in cylindrical steel bars using finite element method and artificial neural networks, *Computers and Structures*, 80, 1763–1770, 2002.
- [2] Umbrello D., Analysis of machining processes: Innovative experimental techniques for results assessing, These PhD, Université de Calabria, Italie, 2004.
- [3] Ambrogio G., Filice L., Shivpuri R., Umbrello D., Application of NN technique for predicting the residual stress profiles during hard turning of AISI 52100 steel, The 9th International Conference on Material Forming, ESAFORM 2006, Glasgow, United Kingdom, 595- 598, 2006.
- [4] Umbrello D., Ambrogio G., Filice L., Shivpuri R., A hybrid finite element method-artificial neural network approach for predicting residual stresses and the optimal cutting conditions during hard turning of AISI 52100 bearing steel, *Materials and Design*, 29, 873-883, 2008.
- [5] Kafkas F., Karataş C. Sozen A, Arcaklioğlu E. Saritaş S., Determination of residual stresses based on heat treatment conditions and densities on a hybrid (FLN2-4405) powder metallurgy steel using artificial neural network, *Materials and Design*, 28, 2431-2442, 2007.
- [6] Karataş C. Sozen A, Dulek E., Modelling of residual stresses in the shot panned material C-1020 by artificial neural network, *Expert Systems with application*, 36, 3514-3521, 2009.
- [7] Habak M., Etude de l'Influence de la Microstructure et des Paramètres de coupe sur le comportement en Tournage Dur de l'Acier à Roulement 100Cr6, Thèse ENSAM, CER d'Angers, 2006.
- [8] Yao Y. L., Fang X., Assessment of chip forming patterns with tool wear progression in machining via neural networks, *International Journal of Machine Tools and Manufacture*, 33, 89-102, 1993.
- [9] Morris A.J., Montague G.A., Willis M.J., Artificial neural networks: studies in process modelling and control, *Trans, IChem*, 72, 3-19, 1994.
- [10] Maunayri H., Novel Artificial Neural Networks Force Model for end Milling, *International Journal of Advanced Manufacturing Technology*, 18, 693-700, 2001.
- [11] Özel T., Karpaz Y., Predictive Modeling of Surface Roughness and Tools Wear in Hard Turning Regression and Neural Networks, *International Journal of Machine Tools & Manufacture* 45, 467-479, 2005.
- [12] Özel T., Nadgir A., Prediction of flank wear by using back propagation neural network modeling when cutting hardened H-13 steel with chamfered and honed cBN tools, *International Journal of Machine Tools & Manufacture*, 42, 287–297, 2002.