

Configuration optimale d'un réseau de neurones adapté à la surveillance en ligne de l'usure des outils de tournage

Idir Belaidi, Raouf Tahmi & Kamal Mohammedi

Laboratoire LMMC, Groupe Modélisation Mécanique et Productique
Université M'Hamed BOUGARA, Boumerdès 35000, Algérie, idirbelaidi@yahoo.fr

Résumé :

Nous présentons dans cette étude une approche efficace pour la configuration optimale d'un réseau de neurones multicouches avec rétro-propagation du gradient, spécifiquement adaptée à la surveillance en ligne de l'usure des outils de tournage. Il s'agit de déterminer précisément un nombre approprié de neurones dans la couche cachée pour assurer une fiabilité maximale du système, en exploitant des signaux issus de mesure des efforts de coupe et de l'usure en dépouille. A cet effet, nous avons développé un algorithme, basé sur le modèle de rétro-propagation du gradient d'erreurs, et présentant le double avantage d'éviter l'apparition des phénomènes de surapprentissage et de minimums locaux.

Mots Clés :

Surveillance ; Usure d'outil ; Tournage ; Réseau de neurones ; Algorithme de rétro-propagation de gradient.

Abstract:

We present an approach for the optimal configuration of a 'Multi Layer Perceptron' neuronal network, specially adapted to the on line monitoring of the cutting tools wear. Our aim is to determine precisely an appropriate number of neurones in the hidden layer to insure maximal system efficiency, by exploiting measured signals (cutting efforts and tool wear). For that purpose, we introduce an algorithm presenting the double advantage to avoid the appearance of local minimums and learning by excess.

Key words:

Monitoring; Tool wear; Turning; Neural network; Back-propagation algorithm.

1. Introduction

Les réseaux de neurones, de par leur caractère particulièrement bien adapté au traitement de processus fortement non linéaires, leur facilité de mise en œuvre et leur grande fiabilité : Abou Mahfouz (2003), sont très souvent utilisés dans les systèmes de surveillance en ligne de l'usure des outils de coupe, à l'exemple des réseaux multicouches avec rétro-propagation du gradient et les réseaux à fonctions de base radiale : Balazinski (2002), Heynes (2001), Obikawa (2004), Zawada (2001).

Nous présentons dans cette étude une approche efficace pour la configuration optimale d'un réseau de neurones multicouches avec rétro-propagation du gradient, spécifiquement adaptée à la surveillance en ligne de l'usure des outils de tournage. Il s'agit de déterminer précisément un

nombre approprié de neurones dans la couche cachée pour assurer une fiabilité maximale du système, en exploitant des signaux issus de mesure des efforts de coupe et de l'usure en dépouille. A cet effet, nous avons développé un algorithme, basé sur le modèle de rétro-propagation du gradient d'erreurs avec "momentum" : Theodorakis (2003), et présentant le double avantage d'éviter l'apparition des phénomènes de surapprentissage et de minimums locaux.

2. Système de surveillance en ligne de l'usure des outils de coupe

Le système est constitué d'une phase d'acquisition des données d'usinage (signaux mesurés des composantes des efforts de coupe et de l'usure), et d'une phase de décision, basée sur un réseau de neurones multicouches avec rétro-propagation du gradient (Fig. 1).




Fig. 1 — Système général de surveillance en ligne de l'usure de l'outil.

2.1. Phase I : Acquisition de données d'entrée/sortie du réseau

Cette étude est basée sur l'exploitation des données expérimentales relatives aux trois composantes de l'effort de coupe et l'usure en dépouille, issues des travaux de Dimla (2000), et qui sont les données d'entrée pour l'apprentissage et le test du réseau de neurones. La sortie désirée est la valeur de l'usure en dépouille cible.

2.2. Phase II : Caractérisation de l'état d'usure de l'outil

Cette phase de décision caractérise, après traitement des données d'entrées par le réseau, l'usure de l'outil, selon deux états:

- Outil à l'état neuf, correspondant à un fonctionnement normal de l'outil, et
- Outil à l'état usé, correspondant à un fonctionnement anormal qui déclenchera une alarme.

3. Mise en œuvre du réseau de neurones Perceptron Multicouche

3.1 Stratégie exploratoire

Le modèle initial implémenté est de type Perceptron Multicouche à rétro-propagation du gradient « 6-i-1 », comportant une couche d'entrée, une couche cachée, dont la détermination du nombre de neurones appropriée fera l'objet d'une optimisation, et une couche de sortie.

A cet effet, différentes architectures seront simulées et optimisées en variant le nombre de neurones dans la couche cachée de $i = (1 \text{ à } 30)$, en fonction d'une erreur de test dans une première étape, et du taux d'apprentissage et du momentum (valeurs fixés aléatoirement : $\eta=0.5$ et $\alpha=0.7$) dans une deuxième étape.

3.2 Apprentissage du réseau

Lors de l'apprentissage, basé sur l'algorithme de rétro-propagation du gradient d'erreurs: Theodoridis (2004), le "vecteur entrées" (composantes de l'effort de coupe et l'usure en dépouille) associé au "vecteur sortie" (état d'usure) sont présentés au réseau de neurones pour apprentissage et mémorisation de leurs allures respectives.

L'exécution de l'algorithme se poursuit jusqu'à l'obtention d'une erreur jugée acceptable, synonyme d'une grande fiabilité du système, ce qui nécessite un nombre important d'itérations, et une réévaluation des sorties du réseau en relation avec le calcul des quantités de mise à jour des poids et des biais.

3.3 Paramétrage du réseau

Pour obtenir une convergence rapide du réseau et une estimation précise du critère d'usure, un paramétrage adéquat du réseau nécessite l'initialisation des poids (intervalle : 1,-1) et l'utilisation d'une fonction coût (erreur moyenne quadratique *MSE*) pour les différentes architectures considérées. Pour ce faire, nous avons opté pour une erreur de test *MSET* égale à $1.5 \text{ E-}003$ et un nombre d'itérations $NB = 2000$. Les fonctions d'activation retenues sont : de type sigmoïde

logistique $f(x) = \frac{1}{1 + \exp(-x)}$, dans la couche cachée, afin de limiter l'amplitude des sorties entre 0

et 1, et de type linéaire $f(x) = x$ dans la couche de sortie.

La taille du vecteur "Entrée/Sortie" est dimensionné en fonction de deux différentes combinaisons « Apprentissage/Test », fournissant (30/27) et (45/12) exemples, dont la dernière a produit des erreurs *MSET* nettement inférieures pour différents nombres de neurones cachés.

3.4 Phénomènes de surapprentissage et de minimums locaux

L'apprentissage du réseau de neurones MLP avec une faible erreur d'apprentissage *MSEA* génère un nombre important d'itérations qui provoque l'apparition du phénomène de surapprentissage, se traduisant par une erreur de test *MSET* élevé (Fig. 2). Cette dernière est affectée de minimums locaux, dont les plus significatifs se situent dès les premières itérations (Fig. 3).




Fig. 2 — Phénomène de surapprentissage sur un réseau « 6-10-1 »
($lr = 0.5$; $Mc = 0.7$)




Fig.3 — Phénomène du minimum local sur un réseau « 6-10-1 »
($lr = 0.5$; $Mc = 0.7$ et $NB = 20000$ itérations)

4. Détermination d'un nombre approprié de neurones dans la couche cachée

4.1. Algorithme de rétro-propagation du gradient étendu

Pour déterminer un nombre de neurones appropriés dans la couche cachée, tout en remédiant aux phénomènes de surapprentissage et de minimums locaux, nous avons développé un algorithme basé sur le modèle de Theodorakis (2003), fonctionnant en trois étapes (Fig.4) :

- Apprentissage du réseau en associant les 45 exemples d'entrée/sortie,
- Test du réseau, en utilisant des exemples différents de ceux employés pour l'apprentissage,
- Traitement des problèmes de surapprentissage et de minimums locaux : aussi, afin d'éviter l'apparition de ces derniers, la plage de test de surapprentissage a été élargie à $NB = 5000$ itérations. Lorsque les 10 dernières valeurs des MSET augmentent, le processus s'arrête et les résultats sont stockés automatiquement. Un réseau est alors jugé performant, lorsque son pouvoir de généralisation est élevé, autrement dit lorsque l'erreur de test permet d'obtenir un taux de réussite satisfaisant pour des valeurs de test différentes de celles utilisées lors de l'apprentissage.

4.2. Résultats

Les trente différentes architectures ont été entraînées par simulation plusieurs fois chacune, en variant le nombre de neurones dans la couche cachée, et avec des poids et des biais aléatoires: les poids obtenus après la phase d'apprentissage ont été ensuite utilisés pour tester la fiabilité du réseau, caractérisée par l'obtention d'une erreur MSET minimale après 20000 itérations, correspondant à l'architecture retenue de type « 6-7-1 » (Fig. 5 et 6).

5. Conclusion

La mise en oeuvre de l'algorithme de rétro-propagation du gradient étendu, a permis de configurer précisément un nombre approprié de neurones dans la couche cachée, en évitant l'apparition des phénomènes de surapprentissage et de minimums locaux, propres aux réseaux de neurones de type perceptron multicouches. Une simulation effectuée, à partir de données d'entrées issues des travaux de Dimla (2003), a montré l'efficacité du réseau dans la prédiction d'un état d'usure en dépouille avec un taux de réussite de 92.83%. Ce résultat reste perfectible en procédant notamment à une optimisation plus affinée des paramètres de performance de ce réseau (taux d'apprentissage, momentum, poids initiaux et fonctions d'activation) : Tahmi (2006).

Références

- Abu-Mahfouz I., « Drilling wear detection and classification using vibration signals and artificial neural network », *International Journal of Machine Tools & Manufacture*, vol.43, 2003, p. 707–720.
- Abu-Zahra N.H., Yu G., « Gradual wear monitoring of turning inserts using wavelet analysis of ultrasound waves », *International Journal of Machine Tools & Manufacture*, vol. 43, 2003, p. 337–343.
- Balazinski M., Czogalab E., Jemielniak K., Leski J., « Tool condition monitoring using artificial intelligence methods », *Engineering Applications of Artificial Intelligence*, vol.15, 2002, pp. 73–80.
- Dimla Sr D.E., Lister P.M., « On-line metal cutting tool condition monitoring. I: force and vibration analyses », *International Journal of Machine Tools & Manufacture*, vol.40 2000, p.739–768.
- Heyns P.S., Scheffer C., « Wear monitoring in turning operations using vibration and strain measurements », *Mechanical Systems and Signal Processing* vol.15(6), 2001, 1185-1202.
- Obikawa T, Shinozuka J., « Monitoring of flank wear of coated tools in high speed machining with a neural network ART2 », *International Journal of Machine Tools & Manufacture* vol.44 , 2004 , p. 1311–1318
- Tahmi R., Système de surveillance en ligne de l'usure des outils de tournage basé sur un réseau de neurones de type MLP, thèse de Magister, Université de Boumerdes, (Algérie), 2006.
- Theodoridis S., Koutroumbas K., Pattern Recognition- second edition, Elsevier (USA), 2003.
- Zawada-Tomkiewicz A., « Classifying the wear of turning tools with neural networks », *Journal of Materials Processing Technology*, vol.109, 2001, p. 300-304.