

## LA COMMANDE NEURONALE DE LA MACHINE À RÉLUCTANCE VARIABLE

AHMED TAHOUR <sup>1</sup>, HAMZA ABID <sup>1</sup>, ABDEL GHANI AISSAOUI <sup>2</sup>

**Mots clé : Moteur à réluctance variable, PI, Commande neuronale, Commande de vitesse.**

Cet article présente une application de la commande neuronale pour le réglage de la vitesse de la machine à réluctance variable (MRV). Un contrôleur neuronal de la vitesse du moteur est alors conçu et simulé. La simulation numérique montre que le contrôleur conçu réalise un bon comportement dynamique du moteur, une vitesse sans dépassement et un bon rejet des perturbations de la charge. L'application du contrôleur neuronal à une MRV donne d'excellentes performances et de robustesse élevée que ceux obtenus par un contrôleur classique (PI).

### 1. INTRODUCTION

Les moteurs à réluctance variable (MRV) peuvent être utilisés dans les applications industrielles dues à leurs avantages de coût. Le moteur à réluctance variable est simple dans sa construction. C'est non seulement des dispositifs de stator à pôles saillants mais comporte également un rotor qui n'a aucun conducteur ou aimant et est ainsi le plus simple de tous les rotors des machines électriques. La simplicité rend le MRV peu coûteux et fiable, et ainsi que son capacité à grande vitesse et couple élevé par rapport à l'inertie.

Cependant, le moteur est fortement non-linéaire et fonctionne dans la saturation pour maximiser le couple. D'ailleurs, le couple du moteur est une fonction non-linéaire de la position du rotor et de courant. La structure complexe du MRV rend la conception du contrôleur difficile. En effet, l'application de neuronale dans la commande de la vitesse du moteur à réluctance variable est décrite dans cet article [1–3].

L'article est organisé comme suivant: dans la section 2, on présente le principe de la commande du moteur à réluctance variable; dans la section 3, le contrôleur proposé est décrit et employé pour commander la vitesse du moteur à

---

<sup>1</sup> Laboratoire AML, Département d'électronique, Faculté d'ingénieur, Université de Sidi Bel Abbes, Sidi Bel Abbes 22000 Algérie, tahourahmed@yahoo.fr.

<sup>2</sup> Laboratoire IRECOM, Département d'électrotechnique, Faculté d'ingénieur, Université de Sidi Bel Abbes, Sidi Bel Abbes 22000 Algérie.

réductance variable. Des résultats de simulation sont donnés pour montrer l'efficacité de ce contrôleur. Des conclusions sont récapitulées dans la dernière section.

## 2. MODÈLE DE MRV

### 2.1. DESCRIPTION DU SYSTÈME

Dans une machine à réductance variable, seulement le stator présente des enroulements, alors que le rotor est fait en acier sans conducteurs ou aimants permanents. Cette structure très simple réduit considérablement son coût. Motivé par cette simplicité mécanique ainsi que les récentes avances dans les composants de l'électronique de puissance, beaucoup de recherches ont été développées dans la dernière décennie. La MRV, en comparaison avec les machines à courant alternatif et les machines à courant continu, présente deux avantages principaux :

- c'est une machine très fiable puisque chaque phase est en grande partie indépendante physiquement, magnétiquement et électriquement des autres phases.
- elle peut réaliser de hautes vitesses (1000–50000 tr/min) en raison du manque de conducteurs ou d'aimants sur le rotor.

Quand un enroulement de stator est alimenté, produisant un champ magnétique simple, le couple est produit par la tendance de déplacer le rotor à sa position alignée [4]. Une vue en coupe est présentée sur la Fig. 1.




Fig. 1 – Moteur à réductance variable 6/4.

Le diagramme schématique du système de commande de vitesse est montré sur la Fig. 2. Le circuit de puissance est un convertisseur asymétrique à demi pont. Chaque phase à deux IGBTs et deux diodes [5, 6]. Les paramètres du moteur à réductance variable sont donnés dans l'annexe.

Les entrées de la commande sont l'erreur entre la vitesse de la machine et la vitesse de référence, alors que la sortie de la commande est utilisée pour produire le courant de référence.




Fig. 2 – Commande de MRV.

## 2.2. ÉQUATIONS DE LA MACHINE

Le moteur à réluctance variable a une construction simple, mais le modèle mathématique est relativement difficile due à son comportement non-linéaire. Le flux est une fonction de deux variables, du courant  $i$  et de la position du rotor (angle  $\theta$ ). Le modèle mathématique du circuit équivalent est :

$$v_j = R i_j + \frac{d\Psi_j(\mathbf{i}, \theta)}{dt}, \quad j=1, 2, 3, \quad (1)$$

On peut écrire :

$$v_j = Ri_j + \frac{d\Psi_j(\mathbf{i}, \theta)}{di} \frac{di}{dt} + \frac{d\Psi_j(\mathbf{i}, \theta)}{d\theta} \omega, \quad j=1, 2, 3. \quad (2)$$

avec :  $\omega = \frac{d\theta}{dt}$ .

L'équation de mouvement est :

$$J \frac{d\omega}{dt} = T_e - T_l - f\omega. \quad (3)$$

Le couple total est la somme des couples des phases :

$$T_e = \sum_{phase=1}^n T_{phase}, \quad (4)$$

avec :  $v$  – tension d'alimentation,  $i_j$  – le courant de phase,  $R$  – résistance d'une phase,  $\Psi$  – flux,  $J$  – moment d'inertie,  $f$  – le coefficient de frottement,  $L(\theta, i)$  – inductance,  $T_{phase}$  – le couple de phase,  $T_e$  – le couple total,  $T_l$  – couple résistant,  $\omega$  – vitesse angulaire du rotor,  $\theta$  – angle de position électrique.

### 3. COMMANDE NEURONALE ADAPTATIVE DE LA VITESSE

#### 3.1. PRINCIPE DE NEURONALE

Les réseaux de neurones artificiels ou réseaux connexionnistes sont fondés sur des modèles qui tentent d'expliquer comment les cellules du cerveau et leurs interconnexions parviennent, d'un point de vue globale, à exécuter des calculs complexes. Ces systèmes qui stockent et retrouvent l'information de manière "similaire" au cerveau sont particulièrement adaptés aux traitements en parallèle de problèmes complexes comme la reconnaissance automatique de la parole, la reconnaissance de visages ou bien la simulation de fonctions de transfert. Ils offrent donc un nouveau moyen de traitement de l'information utilisé en reconnaissance de formes. La Fig. 3 montre un schéma comportant les organes principaux d'un neurone artificiel.




Fig. 3 – Représentation d'un neurone formel.

Un neurone formel pour un réseau (Fig. 3) est caractérisé par

$$x_i = f(A_i), \quad (5)$$

$$A_i = \sum_{j=1}^{N_i} w_{ij} x_j + b_i, \quad (6)$$

où :  $x_i$  – l'état d'un neurone  $i$ ,  $A_i$  – l'activité du neurone  $i$ ,  $w_{ij}$  – le poids de la connexion entre les neurones  $j$  et  $i$ ,  $b_i$  – est le biais.

Le perceptron multicouches est un réseau comportant  $L$  couches, chaque neurone d'une couche étant totalement connecté aux neurones de la couche suivante. Chaque neurone  $k$  est un automate linéaire généralisé dont la fonction d'activation est  $f_k$ .




Fig. 4 – Réseaux de neurone avec architecture multicouches.

La mise à jour des poids synaptiques se fait au niveau des algorithmes de l'apprentissage en utilisant la rétro-propagation du gradient. Le terme rétro-propagation du gradient provient du fait que l'erreur calculée en sortie est transmise en sens inverse vers l'entrée. L'erreur commise sur le  $k^{\text{ème}}$  noeud de sortie est :

$$\delta_{p,k} = O_{p,k} - x_{p,l,k}, \quad (7)$$

où :

$O_{p,k}$  – vecteur des sorties désiré,  $x_{p,l,k}$  – vecteur des sorties réel du réseau,  $p, j$  et  $k$  – neurone  $k$  et l'échantillon  $p$  de la couche  $j$ .

Par conséquent l'erreur totale (pour tous les noeuds) est :

$$E_p = \frac{1}{2} \sum_{k=1}^m \delta_{p,k}^2 = \frac{1}{2} \sum_{k=1}^m (O_{p,k} - x_{p,l,k})^2. \quad (8)$$

La modification des poids est fonction du calcul du gradient. Ainsi, les poids sur la couche de sortie sont mis à jour de la façon suivante :

$$\begin{aligned} w_{l,k,j}(t+1) &= w_{l,k,j}(t) + \Delta_p w_{l,k,j}(t), \\ \Delta_p w_{l,k,j}(t) &= \mu (O_{p,k} - x_{p,l,k}) f'(y_{p,l,k}) x_{p,l-1,j}, \end{aligned} \quad (9)$$

où  $\mu$  – pas d'apprentissage  $0 < \mu < 1$ .

### 3.2. CONTROLEUR NEURONAL

Le modèle proposé a été employé pour calculer le courant référentiel à partir de l'erreur de la vitesse ( $e$ ) et la dérivé de l'erreur ( $de$ ) en suivant la procédure :

- fixer le nombre de couches cachées : mis à part les couches d'entrée et de sortie. L'analyste doit décider du nombre de couches intermédiaires ou cachées.

- déterminer le nombre de neurones par couches cachées : chaque neurone supplémentaire permet de prendre en compte des profils spécifiques des neurones d'entrée.
- choisir la fonction d'activation : le passage de cette dernière à la couche de sortie sera soit linéaire, soit sigmoïde (logistique) selon les types de variables.
- choisir l'apprentissage : l'apprentissage nécessite la détermination du paramètre d'ajustement des poids synaptiques à chaque itération en utilisant la rétro-propagation du gradient.

Le modèle neuronal est identifié pour remplacer le PI (Fig. 5). Le contrôleur utilise l'erreur de la vitesse ( $e$ ) et sa dérivé ( $de$ ) et la sortie de contrôleur calcul le courant référentiel.

$$f(\text{net}_i) = \frac{1}{1 + \exp(-\lambda \text{net}_i)}, \quad (10)$$

$$\text{net}_i = \sum_j W_{ij} y_j, \quad (11)$$

$$y_j = I_{ref}, \quad (12)$$

$$o_k = f(\text{net}_k). \quad (13)$$




Fig. 5 – Diagramme d'identification de PI par réseaux de neurone.

L'erreur est calculée par la fonction suivante:

$$E = \frac{1}{2} \sum_{k=1} (y_k - o_k)^2. \quad (14)$$

Et on calcule l'erreur de poids par :

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}}. \quad (15)$$

La mise à jour de poids est calculée par le façon suivante:

$$W_{kj}(k+1) = W_{kj}(k) + \eta \delta_{ok} y_j \quad (16)$$

et :

$$\delta_{ok} = -\frac{\partial E}{\partial \text{net}_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial \text{net}_k}, \quad (17)$$

$$\delta_{ok} = \frac{1}{2} (y_k - o_k)(1 - o_k^2).$$

La formation a été exécutée avec 10 couches cachés, avec une erreur finale moyenne environ de 0,00012 entre la fonction de cible et la sortie d'ANN.

#### 4. RÉSULTAT DE SIMULATION

La Fig. 6 montre le diagramme schématique de la commande de vitesse du moteur a réluctance variable en utilisant d'abord le PI et par suite le contrôleur neuronal équivalent.




Fig. 6 – Configuration de système de la commande de vitesse.

Pour montrer les performances du contrôleur neuronal, nous avons simulé le système décrit sur la Fig. 1. L'essai présente un changement de vitesse de 100 rad/s–50 rad/s–200 rad/s et sous une charge de 1,5 N·m à 1,3 s et son élimination à  $t = 1,8$  s. La simulation est réalisée en utilisant le logiciel de SIMULINK dans l'environnement de MATLAB. La Fig. 5 montre les performances du contrôleur neuronal.

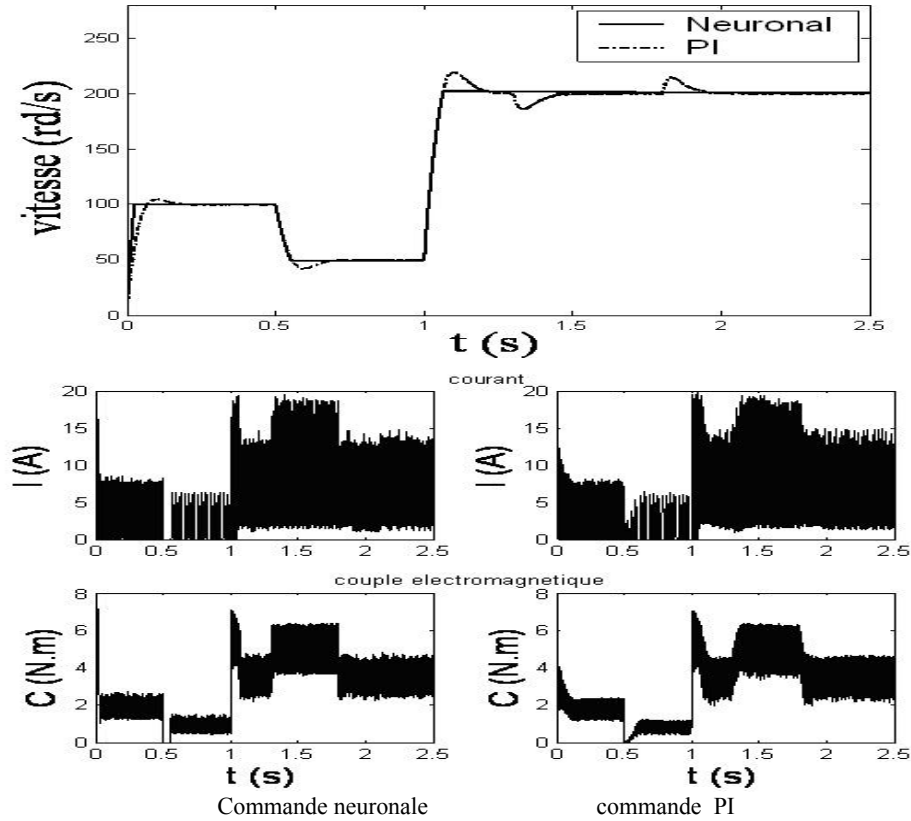


Fig. 7 – Résultats de simulation de la commande de vitesse.

La Fig. 7 montre que le réglage présente de meilleures performances vis-à-vis la poursuite de la référence et le rejet de la perturbation. La simulation atteint des performances très bonne avec le contrôleur neuronal. En effet, on voit que le dépassement est important dans le cas du régulateur PI.

Le cheminement de la vitesse est satisfaisant, et l'ondulation de couple est basse. Ces résultats démontrent la robustesse de la commande dans des conditions de charge imprévisibles. Les oscillations décroissantes de vitesse avec le contrôleur PI sont dues à une réaction plus lente du courant, comme représenté sur la Fig. 7.

## 5. ROBUSTESSE

Afin d'examiner la robustesse de la commande proposée, nous avons étudié les variations des paramètres sur le réglage de la vitesse. Deux cas sont considérés :

1. variation d'inertie,

## 2. variation de résistance de stator.

La Fig. 7 montre les essais de la robustesse : a) la robustesse examine au sujet de la variation des résistances, b) la robustesse examine la variation du moment d'inertie.




Fig. 8 – Essai de la robustesse.

Les essais effectués montrent que l'augmentation ou la diminution des paramètres de la résistance et de moment d'inertie de la machine n'affecte pas les performances de la commande proposée (Fig. 8).

## 6. CONCLUSION

Cet article présente une nouvelle approche de la commande robuste de vitesse pour le moteur à réluctance variable. Les résultats de simulation prouvent que le contrôleur proposé est supérieur au contrôleur classique dans la robustesse et dans la précision de cheminement. L'étude de simulation indique clairement les performances supérieures de la commande neuronale. Il s'avère plus efficace parce qu'il a un rendement élevé dans la présence des paramètres incertains et des perturbations de la charge. D'autre part, la poursuite en vitesse est sans dépassement et sans erreur.

## APPENDIX

Paramètres de la MRV:

- nombre de phases 3, nombre de pôles du stator 6, arc du pôle  $30^\circ$  ;
- nombre de pôles du rotor 4, arc du pôle  $30^\circ$  ;

- inductance maximum 60 mH, inductance minimum 8 mH, résistance d'une phase  $R = 1,3 \Omega$ ,
- moment d'inertie  $J = 0,0013 \text{ kg.m}^2$ , frottement  $f = 0,0183 \text{ Nm/s}$ , tension d'alimentation  $v = 150 \text{ V}$ .

Reçu le 13 novembre 2007

## REFERENCES

1. J. S. R. Jang. *Adaptive-network-based fuzzy inference system*, IEEE Trans Syst Man Cybernet, **23**, 3, pp. 665–685 (1993).
2. R. Krishnan, *Switched reluctance motor drives modelling, simulation, analysis, design and applications*, CRC Press, London, 2001.
3. R. Krishnan, *Switched reluctance motor drives modeling, simulation, analysis, design and applications*, London, CRC Press, 2001.
4. F. Soares, P.J. Costa Branco, *Simulation of a 6/4 Switched Reluctance Motor Based on Matlab/Simulink Environment*, Aerospace and electronic system. IEEE transactions, Vol. 37 pp. 989–1009, July 2001.
5. T. H. E. Miller, *Switched reluctance motors and their control*, Oxford University Press, 1993.
6. M. Brown, C. Haris, *Neuro-fuzzy adaptive modeling and control*, Englewood Cliffs, Prentice-Hall, 1994.
7. E. Mese, D.A. Torrey *sensorless position estimation for variable reluctance machine by using artificial neural networks*, IEEE IAS 97, pp. 540–547, New Orleans, Oct. 97.
8. C. T. Lin, C. S. G Lee. *Neural fuzzy systems: a neuro-fuzzy synergism to intelligent systems*, Upper Saddle River, Prentice-Hall, 1996.
9. M. T. Wishart, R. G. *Harley identification and control of induction machines using artificial neural networks*, IAS, 1993, pp. 703–709.
10. \* \* \*, *Matlab Neural Networks Toolbox*, The mathworks Inc.
11. A. Bellini, F. Filippetti, G. Franceschini, P. Vas, *Sensorless SRM drives using ANN-based estimators*, ICEM 98, Istanbul, Turkey, September 1998.
12. A. F. Stronach, P. Vas, *Application of artificial intelligence based speed estimators in high performance electromechanical drives*, Proc of intelligent motion, June 1997.

## NEURAL CONTROLLER FOR A SWITCHED RELUCTANCE MACHINE

AHMED TAHOUR, HAMZA ABID, ABDEL GHANI AISSAOUI

**Key words:** Switched reluctance motor, PI, Neuronal control, Speed control.

This paper presents an application artificial neural network (ANN) to control the switched reluctance motor (SRM) speed. A neuronal controller of the motor speed is then designed and simulated. Digital simulation shows that the designed ANN speed controller realises a good dynamic behaviour of the motor, a perfect speed tracking with no overshoot and a good rejection of impact loads disturbance. The applying of the neuronal controller to a SRM gives best performances and high robustness than those obtained by the application of a conventional controller (PI).