

L'application des réseaux de neurones de type « feed forward » dans le diagnostic statique

MSAAF Mohammed

Laboratoire des techniques industriel
Faculté des sciences et techniques
Université Sidi Mohammed Ben Abdellah
Fès, Maroc
mohamed.msaaf@usmba.ac.ma

Belmajdoub Fouad

Laboratoire des techniques industriel
Faculté des sciences et techniques
Université Sidi Mohammed Ben Abdellah
Fès, Maroc
fbelmajdoub@yahoo.fr

Résumé—Les réseaux de neurones constituent un outil de l'intelligence artificielle. Ils offrent des solutions très performantes pour le diagnostic des procédés industriels. Ces réseaux se manifestent sous forme de plusieurs architectures. L'application de chacune de ces architectures présente des points forts et des points faibles.

Ce document constitue un état de l'art concernant le diagnostic statique avec les réseaux de neurones. Nous présentons, dans ce document, une comparaison entre les différentes architectures des réseaux de neurones les plus utilisées en diagnostic statique : à savoir les perceptrons multicouches, le réseau de neurones à base de fonction radiale, la carte de Kohonen et le réseau Random Vector Functional Link.

Keywords— Réseau de neurones, le réseau RBF, perceptron, perceptron multicouche, carte de Kohonen, le réseau RVLNN.

I. INTRODUCTION

Les réseaux de neurones (RdN) représentent une méthode utilisée en intelligence artificielle, notamment en reconnaissance des formes qui a été largement appliquée dans divers domaines d'ingénierie. Vu sa capacité d'auto-apprentissage, cette méthode est utilisée pour résoudre les problèmes les plus complexes.

Les RdN, selon leurs types, ont plusieurs applications en industrie. On peut citer le diagnostic statique [1, 2], le diagnostic dynamique [3], le pronostic [4, 5], le contrôle [6, 7] et la surveillance des systèmes industriels.

L'application des RdN dans le diagnostic est une sorte de reconnaissance de forme, où on associe à chaque panne la cause la plus probable. À partir d'un vecteur d'entrée contenant les paramètres de système à diagnostiquer ainsi que les signaux provenant des capteurs, on peut avoir une sortie qui indique l'état de système. Dans ce papier on va essayer de donner une étude comparative entre les différentes architectures des réseaux de neurones les plus utilisées en diagnostic statique.

Ce papier sera organisé comme suit : Une première partie représente les différentes architectures des RdN étudiés, la deuxième partie donne une étude comparative entre ses architectures et propose une procédure de sélection du réseau de neurones le plus adéquat à une

application donnée et finalement on termine par une conclusion.


II. LES RÉSEAUX DE NEURONES

A. Neurone simple

Le neurone simple ou le neurone formel (Fig. 1) est une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation pondérée des entrées. Cette sommation appelée activation se calcule comme suit :


$$y = \vec{w} \cdot \vec{x} = \sum_{i=1}^n w_i x_i \quad (1)$$

Fig. 1. Neurone formel



La fonction d'activation est la fonction de transfert qui relie la sommation pondérée au signal de sortie. Il y a plusieurs types de fonction d'activation. La figure 2 illustre les fonctions d'activation les plus utilisées.

Fig. 2. Fonctions de sortie les plus utilisées, a) fonction linéaire b) fonction à seuil c) fonction linéaire par morceaux d) fonction sigmoïde e) fonction tangente hyperbolique f) fonction gaussienne.



B. Réseaux de neurones de type « feed forward »

Les RdN de types « feed forward » ou a propagation directe sont les réseaux de neurones où l'information passe de la couche i à la couche j avec $i < j$.

C. Le perceptron simple

Un perceptron simple ou perceptron monocouche est un réseau de neurones développé par Rosenblatt [8]. Ce réseau est constitué d'un seul neurone agit par la fonction d'activation :

$$A = \begin{cases} 1 & \text{si } y > 0 \\ 0 & \text{(ou } -1) \text{ si } y \leq 0 \end{cases}$$

Avec y est défini en (1).


D. Le perceptron multicouche

Le perceptron multicouche (PMC) [9] est un ensemble de perceptrons répartis dans des couches successives (Fig. 3), à savoir : une couche d'entrée, un nombre des couches cachées et une couche de sortie. La fonction d'activation O de chaque neurone est la fonction sigmoïde (Fig. 2) :

$$o(\vec{x}) = \frac{1}{1 + e^{-y}}$$

Avec y est défini par l'équation (1).


Fig. 3. L'architecture d'un PMC



E. Le réseau « Random Vector Functional Link »

Random Vector Functional Link Neural Network (RVFLNN) est un modèle du perceptron développé par Pao et al [10]. Ce réseau a l'architecture d'un réseau PMC avec des connexions supplémentaires entre la couche d'entrée et la couche de sortie (Fig. 4). Les connexions qui relient la couche cachée et la couche de sortie, selon Pao [10], représentent des entrées optimisées et ne font pas l'objet de l'apprentissage. La fonction d'activation utilisée pour les neurones cachés et de sortie est une sigmoïde (Fig. 2).

Fig. 4. L'architecture d'un RVFLNN




F. Les RdN à base de fonction radiales

Le RdN à base de fonction radiale (RBF) [11, 12] est un réseau de neurones (Fig. 5) à trois couches une couche d'entrée, une cachée et une couche de sortie. La particularité de ce réseau réside dans sa couche cachée (deuxième couche) réagit par des fonctions de sortie H_i à base radiale (II). Ce réseau est capable de fournir une représentation locale de l'espace. Il y'a différentes formes des fonctions à base radiales, la plus utilisée est la fonction gaussienne.

$$H_i = \exp\left(\frac{\|x_i - \mu_i\|^2}{2\sigma_i}\right)$$

Où $\| \cdot \|$ représente la norme euclidienne, x_i , μ_i et σ_i sont respectivement le vecteur d'entrée, le centre et le rayon d'influence de neurone i de la couche cachée

Fig. 5. L'architecture d'un RBF




La couche cachée représente une mémoire statique, elle mémorise les informations (μ_i et σ_i) qui concernent les différentes classes du problème.

G. La carte de Kohonen

La carte de Kohonen [13] est une carte auto-organisatrice en deux couches (Fig. 6), une couche d'entrée et une autre de sortie. La couche de sortie appelée aussi couche compétitive est en deux dimensions. Chaque neurone d'entrée est connecté à l'ensemble des neurones de sortie par des poids W_{ij} . La carte

de Kohonen est une carte à apprentissage non supervisé, à partir d'une base d'apprentissage constitué seulement des éléments d'entrées, elle permet de regrouper ces entrées en classes.

Fig. 6. L'architecture d'une carte de Kohonen



III. ETUDE COMPARATIVE ET SYNTHESE

A. Étude comparative

Plusieurs travaux ont été élaboré par des auteurs qui ont pour objectif de comparer les différents types des réseaux de neurones [1, 14, 15]. En se basant sur ces travaux, cette partie résume les avantages est les inconvénients de chaque architecture des réseaux de neurones les plus utilisés.

TABLEAU I LES AVANTAGES ET LES INCONVENIENTS DE QUELQUES ARCHITECTURES DES RESEAUX DE NEURONES

RN	Description	Apprentissage	Avantages	Inconvénients
Perceptron simple	<ul style="list-style-type: none"> Un seul neurone 	Supervisé	- Architecture simple	N'accepte pas les données bruitées et la classification non linéaire
PMC	<ul style="list-style-type: none"> Plusieurs neurones organisés en couches Sorties des neurones : sigmoïde 	Supervisé	<ul style="list-style-type: none"> Accepte les données bruitées et la classification non-linéaire Représentation globale de l'espace Architecture simple 	<ul style="list-style-type: none"> Classe les éléments qui n'appartiennent à aucune classe à la classe la plus proche Le nombre de couches caché et des neurones dans les couches caches est indéfini
RVFLNN	<ul style="list-style-type: none"> Réseau en trois couches Couche d'entrée reliée à la couche de sortie 	Supervisé (seulement les poids reliant la couche d'entrée avec celle de la sortie)	<ul style="list-style-type: none"> Accepte les données bruitées et la classification non-linéaire Représentation globale de l'espace Des entrées optimisées 	- Architecture plus complexe que le PMC Moins de précision que le PMC
RBF	<ul style="list-style-type: none"> Plusieurs neurones organisés en 3 couches Couche cachée : gaussienne 	Non supervisé (μ, σ) + Supervisé	<ul style="list-style-type: none"> Accepte les données bruitées et la classification non-linéaire Capable de dire « je ne sais pas » Représentation locale de l'espace Une grande précision. Apprentissage rapide. 	<ul style="list-style-type: none"> Apprentissage complexe Nécessite une grande capacité de calcul
Carte de Kohonen	<ul style="list-style-type: none"> Couche de sortie sous forme d'une carte (2D) 	Non supervisé	<ul style="list-style-type: none"> Classifier les données sans connaissance préalable de procédé. regroupement automatique des données 	- Parfois les résultats ne correspondent pas à celle souhaitée

B. Synthèse

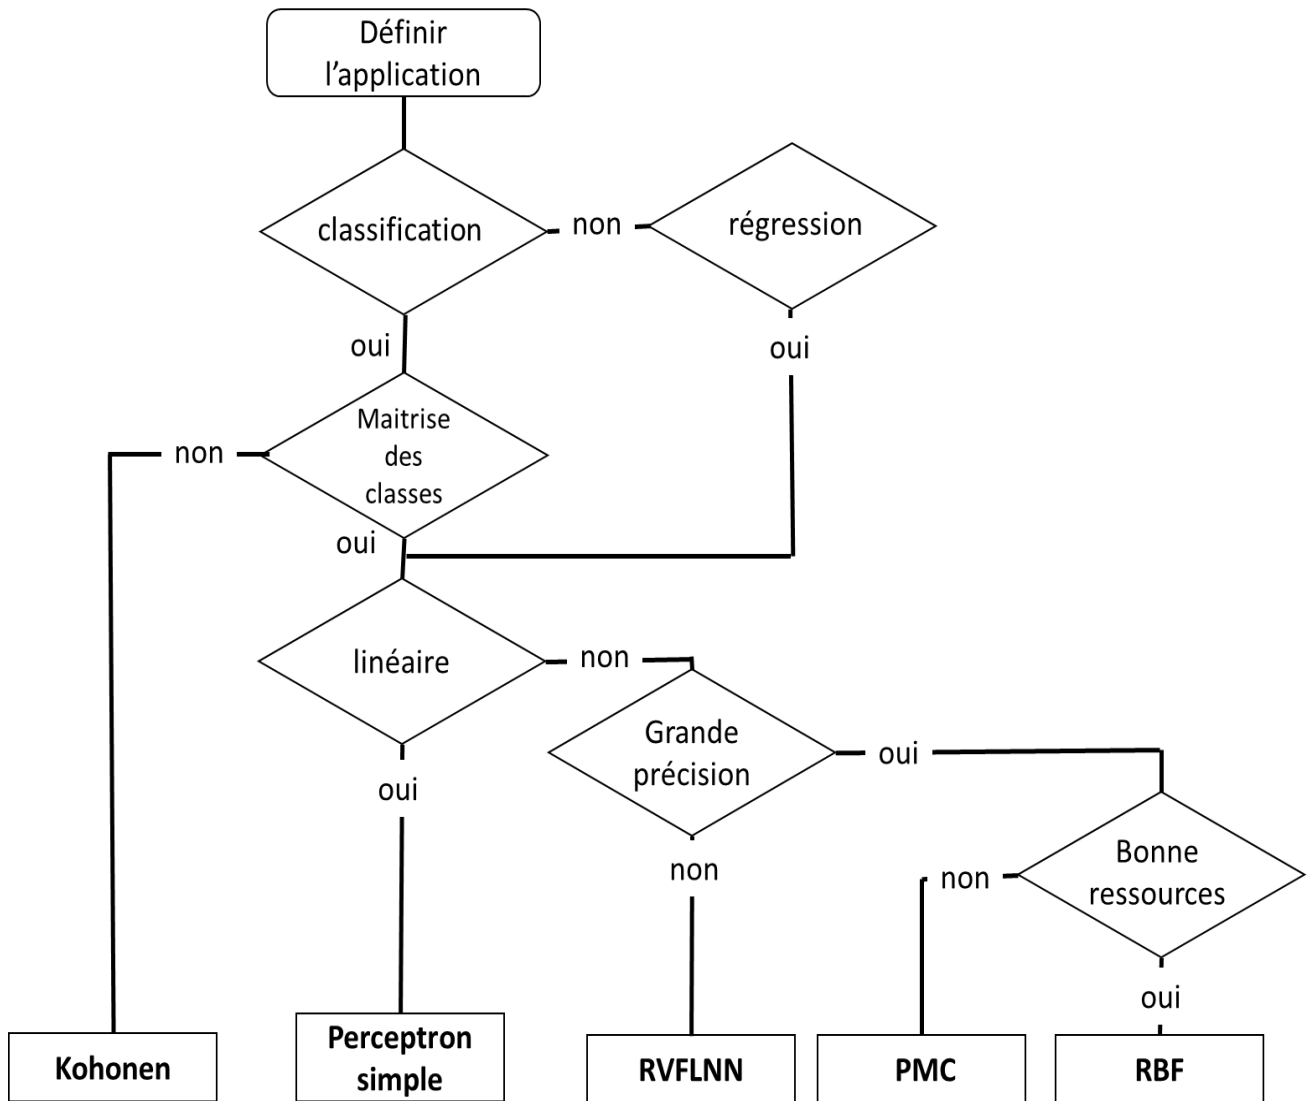
Le choix de la RdN dépend principalement de quatre critères qui sont :

- la fonction à remplir : régression ou classification
- la performance des ressources sur lesquelles on va implémenter notre réseau de neurones (ordinateur, carte électronique...)

- La précision voulue : Ceci s'exprime par le taux d'erreur commis lors de la phase de test.
- le degré de maîtrise de système traité : l'existence d'une base de données contenant les variables d'entrées et toutes les classes correspondante.

La figure résume la procédure à suivre pour choisir une architecture des réseaux de neurones selon les quatre critères déjà cités ci-dessus.

Fig. 7. procédure de sélection d'une architecture de réseau de neurones



IV. CONCLUSION

Ce document présente une comparaison entre cinq architectures des réseaux de neurones. Cette étude a montré que la carte de Kohonen est le réseau de neurones le plus approprié lorsqu'on n'a pas suffisamment d'information sur le système traité. Cette carte peut permettre la définition des classes et donc la préparation des données pour

l'apprentissage des autres types des réseaux de neurones. Les réseaux RBF (radial basic function) donnent la meilleure précision par rapport à la précision donnée par les autres architectures, mais l'implémentation de ce réseau nécessite une grande capacité calculatoire.

RÉFÉRENCES

Society Winter Meeting, 2002. IEEE, 2002, pp. 274-279.

- [1] H. Koivo, "Artificial neural networks in fault diagnosis and control," *Control engineering practice*, vol. 2, pp. 89-101, 1994.
- [2] H. Wang and P. Chen, "Intelligent diagnosis method for rolling element bearing faults using possibility theory and neural network," *Computers & Industrial Engineering*, vol. 60, pp. 511-518, 2011.
- [3] R. Patton, J. Chen, and T. Siew, "Fault diagnosis in nonlinear dynamic systems via neural networks," in *Control, 1994. Control'94. International Conference on*, 1994, pp. 1346-1351.
- [4] H. R. DePold and F. D. Gass, "The application of expert systems and neural networks to gas turbine prognostics and diagnostics," in *ASME 1998 International Gas Turbine and Aeroengine Congress and Exhibition*, 1998, pp. V005T15A009-V005T15A009.
- [5] D. Tobon-Mejia, K. Medjaher, and N. Zerhouni, "CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks," *Mechanical Systems and Signal Processing*, vol. 28, pp. 167-182, 2012.
- [6] D. H. Nguyen and B. Widrow, "Neural networks for self-learning control systems," *Control Systems Magazine, IEEE*, vol. 10, pp. 18-23, 1990.
- [7] J. Na, X. Ren, C. Shang, and Y. Guo, "Adaptive neural network predictive control for nonlinear pure feedback systems with input delay," *Journal of Process Control*, vol. 22, pp. 194-206, 2012.
- [8] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, p. 386, 1958.
- [9] J. L. McClelland, D. E. Rumelhart, and P. R. Group, "Parallel distributed processing," *Explorations in the microstructure of cognition*, vol. 2, 1986.
- [10] Y. Pao, "Adaptive pattern recognition and neural networks," 1989.
- [11] D. S. Broomhead and D. Lowe, "Radial basis functions, multi-variable functional interpolation and adaptive networks," DTIC Document 1988.
- [12] J. Moody and C. J. Darken, "Fast learning in networks of locally-tuned processing units," *Neural computation*, vol. 1, pp. 281-294, 1989.
- [13] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological cybernetics*, vol. 43, pp. 59-69, 1982.
- [14] M. Fatima and S. Hamid, "Comparaison de méthodes de classification réseau RBF, MLP et RVFLNN1," *Damascus University Journal Vol,(25)-No.(2)*, 2009.
- [15] J.-W. Park, R. Harley, and G. Venayagamoorthy, "Comparison of MLP and RBF neural networks using deviation signals for on-line identification of a synchronous generator," in *Power Engineering*