

Contribution à la surveillance de vibrations d'une turbine à gaz à l'aide Des réseaux de neurones dynamiques NARX

Youcef Mahroug⁽¹⁾, Mouloud Guemana⁽¹⁾, Ahmed Hafaifa⁽¹⁾

⁽¹⁾ Faculté de Technologie, Université de Médéa, ⁽¹⁾ Faculté de Technologie, Université de Médéa 26000, Algérie.

⁽¹⁾ Laboratoire d'Automatique Appliquée et Diagnostic Industriel LAADI, Université de Djelfa 17000, Algérie.

Emails: mahroug.youcef@gmail.com, guemana_m@yahoo.fr, hafaifa.ahmed.dz@ieee.org

RÉSUMÉ : Les turbines à gaz sont devenues très efficaces dans les applications industrielles pour la production d'énergie électrique et thermique dans plusieurs industries. Cependant, ces systèmes de machines tournantes sont complexes et ils sont composés de plusieurs éléments sensibles soumis à certains défauts et risques opérationnels. En effet, le but de ce travail est de proposer un modèle de surveillance et diagnostic des vibrations d'une turbine à gaz GE MS5002B utilisant une approche basée sur les réseaux de neurones Non linéaire Autorégressif avec entrée eXogène NARX basée sur des données expérimentales, ce qui nous garantira la disponibilité optimale de ce système. Les résultats obtenus montrent clairement que le modèle NARX proposé est fiable et peut être utilisé pour la surveillance et le diagnostic des turbines à gaz.

MOTS-CLÉS : Turbine à Gaz, Surveillance des Vibrations, Réseau de Neurones, NARX.

1. INTRODUCTION

Le mouvement vibratoire est un phénomène inhérent à tous les types de machines tournantes, quelles que soient leur condition matérielle ou leur état de fonctionnement, et se mesure généralement en fonction de la réponse physique de la machine ou du son produit par le mouvement vibratoire induit. Ainsi, les vibrations, en général, peuvent être divisées, respectivement, en deux catégories ; vibrations mécaniques et vibrations acoustiques [1]. Le diagnostic des machines implique la mesure et l'analyse de divers phénomènes associés au fonctionnement des machines et vise spécifiquement à détecter et à identifier les défauts des machines [1,2]. Le comportement vibratoire est un indicateur essentiel de l'état des machines et joue donc un rôle clé dans le diagnostic des machines et la surveillance de la santé. Les mesures de vibrations mécaniques sont privilégiées comme mesures du mérite dans l'évaluation de l'état et des performances des machines. Jusqu'à présent, plusieurs modèles basés sur les techniques d'identification du système ont été développés pour identifier le comportement dynamique des turbines à gaz. Les plus courantes de ces méthodes comprennent les modèles polynomiaux comme ARMAX, modèles NARMAX [3,4], modèles de réseaux neuronaux (NN) [5,6] et modèles ANFIS [7,8].

Dans ce travail nous proposons une technique d'identification du comportement vibratoire basée sur le model **NARX** (Non linéaire Autorégressif avec entrée eXogène) en utilisant l'algorithme de **Levenberg-Marquardt** comme méthode de recherche pour une turbine à gaz à deux arbres. Cet article est organisé comme suit : La section II décrit la technique d'identification du comportement vibratoire basée sur le model NARX. Dans la section III, comprend la représentation de la turbine à gaz. Dans la section IV, les résultats d'identification sont présentés et discutés. La dernière partie mentionne la conclusion de l'article.

2. Identification de systèmes par réseaux de neurones dynamiques NARX

Le réseau NARX est une architecture neuronale dynamique couramment utilisée pour la modélisation entrée-sortie de systèmes dynamiques non linéaires [5,9]. Appliqué à la prédiction de séries temporelles. Comme on peut le voir sur la figure1, il existe deux architectures différentes du modèle de réseau neuronal NARX ; architecture série-parallèle (nommée aussi open-loop) et architecture parallèle (nommée aussi close-loop) donnée par les équations (1) et (2), respectivement :

$$\hat{y}(t+1) = F \left[y(t), y(t-1), \dots, y(t-n_y), x(t), x(t-1), \dots, x(t-n_x) \right]$$

$$(1) \hat{y}(t+1) = F \left[\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y), x(t), x(t-1), \dots, x(t-n_x) \right] \quad (2)$$

Où, La fonction F est un estimateur non linéaire qui associe les régresseurs d'entrée et de sortie à la sortie du modèle. $\hat{y}(t+1)$ Est la sortie du NARX à l'instant t + 1. $\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y)$ Sont les sorties précédentes du NARX. $y(t), y(t-1), \dots, y(t-n_y)$ sont les valeurs précédentes réelles de la série temporelle, appelées aussi valeurs de sortie désirées. $x(t), x(t-1), \dots, x(t-n_x)$ sont les entrées du NARX, et n_y et n_x désignent le nombre des variables de regressions de sortie et d'entrée respectivement




Figure 1 : Architectures du réseau de neurones NARX.

Dans l'architecture série-parallèle, la valeur future de la série temporelle $\hat{y}(t+1)$ est prédite à partir des valeurs actuelles et précédentes de $x(t)$ et des valeurs précédentes réelles des séries temporelles $y(t)$. Dans l'architecture parallèle, la prédiction est effectuée à partir des valeurs actuelles et précédentes de $x(t)$ et des valeurs précédemment prédites de la série temporelle $\hat{y}(t)$ [6,9]. Dans cette étude, au cours de la phase de formation, l'architecture série-parallèle est utilisée en raison de la disponibilité des valeurs précédentes réelles des séries temporelles.

L'utilisation de l'architecture série-parallèle présente deux avantages :

- 1) La première est que l'utilisation des valeurs réelles comme entrée du réseau d'anticipation est plus précise.
- 2) Le deuxième avantage consiste en une architecture du réseau résultant qui est purement directe, les algorithmes d'apprentissage habituels pour les réseaux multicouches Perceptron (MLP) peuvent être utilisés.

Après la phase d'apprentissage, le réseau neuronal NARX est converti en architecture parallèle, ce qui est bénéfique pour la prédiction à plusieurs étapes [9,10]

Comme le montre la figure 2, un MLP classique se compose de trois couches : la couche d'entrée, la couche cachée et la couche de sortie. Les autres éléments se composent de neurones, de fonctions d'activation et de poids. La direction du flux d'informations dans les couches va de l'entrée à la couche de sortie. Dans chaque couche, chaque neurone multiplie le vecteur d'entrée x_j donné par la couche précédente par le vecteur de poids w_{ij} pour donner le produit scalaire $x_j \times w_{ij}$. Une fonction d'activation f donnée par le tableau 1, est ensuite réalisée pour obtenir la sortie neuronale suivante :

$$y_i = f \left(\sum_{j=1}^n x_j \cdot w_{ij} \right) \quad (3)$$

Où i est l'indice de la couche d'entrée. j est l'indice de la couche cachée.




Figure 2 : Détails d'un réseau neuronal (a) et MLP (b).

Tableau 1 : Exemples de fonctions d'activation

Fonction f	Définition
Linéaire	x
Sigmoïde	$\frac{1}{1 + e^{-x}}$

3. Description du processus

La turbine à gaz étudiée dans ce travail est installée à la station de compression de gaz CS2 SONATRACH TFT, en Algérie. Le MS5002B est une turbine à gaz spécialement conçue pour les applications d'entraînement mécanique telles que le Recyclage de gaz sous haute pression, les usines de GNL et le stockage de gaz. La turbine MS5002B est composée de deux rotors indépendants du point de vue mécanique (Vitesse nominale du 1^{er} arbre 5100 tr / min, vitesse nominale du 2^{ème} arbre 4900 tr / min). Le premier rotor comprend le compresseur axial (à 16 étages de compression) et la turbine HP (haute pression). Le compresseur axial comprime l'air qui doit être transmis à la chambre de combustion et la turbine HP. Sur le second rotor LP (basse pression) il y a l'arbre de commande qui mène le compresseur centrifuge à travers un accouplement mécanique.




Figure 3 : schéma du système de turbine à gaz MS5002B

Lors de la supervision de la turbine à gaz, les acquisitions des signaux de vibrations sismique ont été enregistrées aux niveaux des deux paliers «1 » et «4 », à partir de notre vélocimètre.

4. Résultats et discussion

Les données d'exploitation réelles de la turbine à gaz MS5002B examinée dans cette étude ont été explorées pour identifier les paramètres du modèle NARX de notre turbine à gaz, avec 466 échantillons prélevés à un temps d'échantillonnage $T_s = 0.639901s$.

La structure du modèle proposé est mentionnée dans la figure 4.

Les capteurs d'entrée sont ceux utilisés pour la mesure des variables suivantes :

TNH : vitesse de l'arbre haute pression (HP). TNL : vitesse de l'arbre basse pression (LP)

Les capteurs de sortie sont ceux utilisés pour la mesure des variables suivantes

(BB1) : vibration sismique du palier «1 ». (BB4) : vibration sismique du palier «4 »




Figure 4 : Structure du modèle NARX MISO

Les variables d'entrée choisies pour cette identification sont présentées respectivement Dans les Figures 5 et 6




Figure 5 : variation de vitesse TNH




Figure 6 : variation de vitesse TNL

Le processus d'identification de différentes variables de sortie et ainsi que leurs erreurs d'identification sont présentées respectivement dans les Figures 7 et 10.

Les figures 9 et 12 montrent les graphes de régression qui indique la relation entre les sorties du réseau et les sorties du système (cibles).

La valeur R est une indication de la relation entre les sorties et les cibles comme sont montrés dans les figures 9 et 12, les valeurs de R pour tous les graphes sont très proches de un (1).

Par conséquent, les résultats de chaque ensemble de données d'apprentissage, de validation et de test indiquent un très bon ajustement.

Les figures 8 et 11 illustrent les détails du meilleur réseau obtenu en fonction des performances moyennes de toutes les structures formées.

Les performances du modèle NARX pour l'apprentissage, la validation et le test sont illustrées dans ces figures. Comme on peut constater, les itérations dans lesquelles l'erreur de performance de validation atteint le minimum sont quatre (4) pour la première sortie (BB1) et six (6) pour la deuxième sortie (BB4). L'erreur quadratique moyenne (MSE) de la performance à ce stade est assez faible.

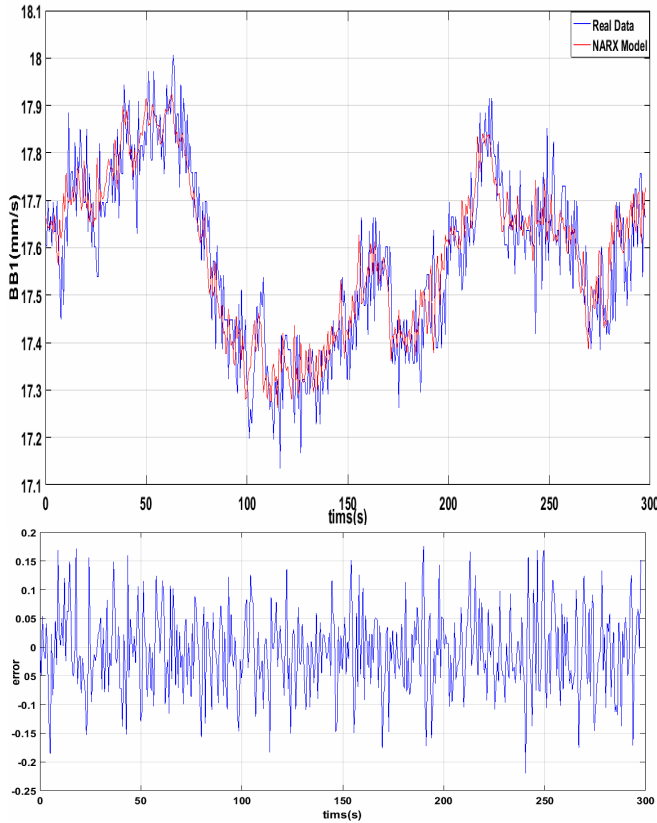


Figure 7 : variation de BB1 (Réel et modèle)




Figure 8 : Performances du modèle
 NARX de BB1

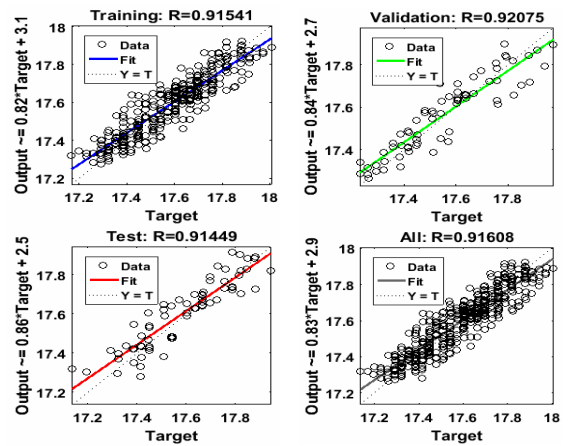


Figure 9 : Régression du modèle NARX de BB1

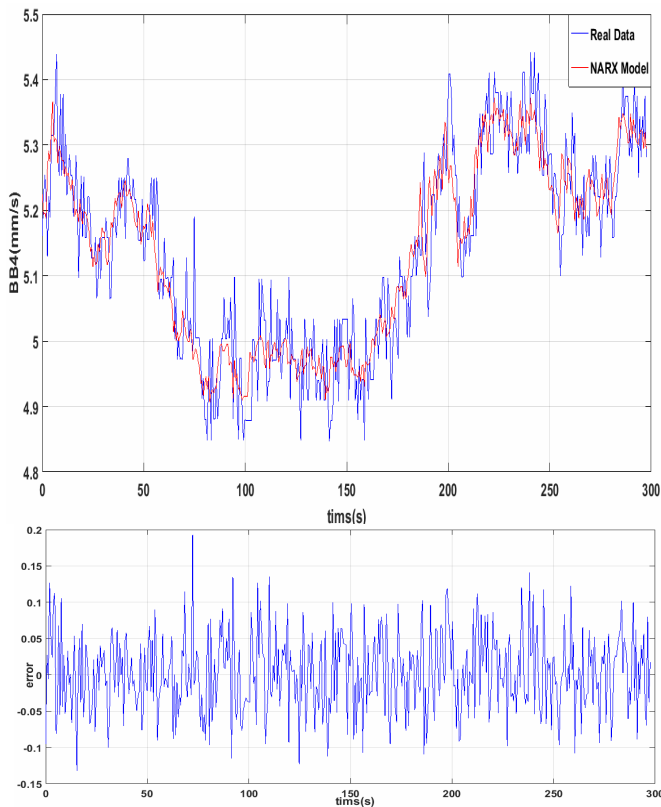


Figure 10 : variation de BB4 (Réel et modèle)

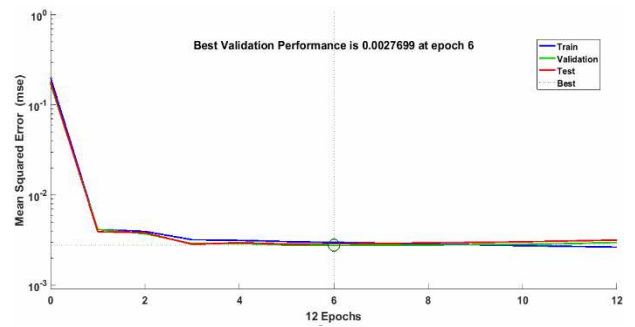


Figure 11 : Performances du modèle
 NARX de BB4

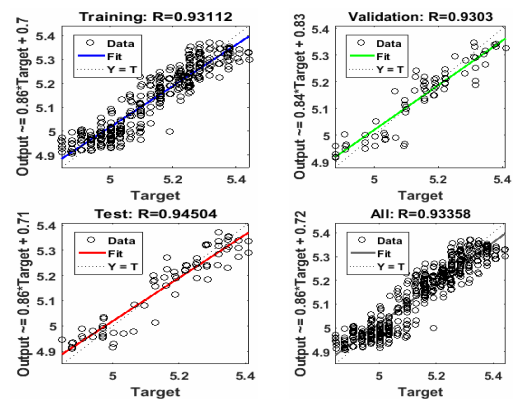


Figure 12 : Régression du modèle

NARX de BB4

Le tableau ci-dessous montre l'architecture de modélisation de la turbine à gaz.

Tableau 2 : Estimation du modèle et résultat de validation

NARX Model	Nombre de neurones		Fonction de transfert		Algorithme d'apprentissage	MSE
	couche cachée	couche de sortie	couche cachée	couche de sortie		
BB1	20	1	logsid	Linear	Levenberg-Marquardt	0.0085
BB4	20	1	logsid	Linear	Levenberg-Marquardt	0.0034

Conclusion

Dans ce travail, le modèle NARX a été utilisé comme une technique fiable pour l'identification du comportement vibratoire à dynamique non linéaire de la turbine à gaz.

Les résultats du modèle développé NARX permettent de mettre en place un outil de simulation puissant et facile à construire, pouvant être utilisé pour le contrôle et le diagnostic en temps réel de différents types de turbines à gaz.

En outre, les résultats ont révélé que le modèle NARX a une capacité suffisante pour découvrir les relations complexes entre les paramètres d'entrée et de sortie essentiels des turbines à gaz, donc il peut être étendu aux autres types de turbines à gaz.

Références

- [1]. JA. Stamm, Machinery diagnostics via mechanical vibration analysis using spectral Analysis techniques. Dissertation, the Naval Postgraduate School, USA (1988).
- [2]. A. Hafaifa, M. Guemana and A. Daoudi, Vibration supervision in gas turbine based on parity space approach to increasing efficiency. Journal of Vibration and Control, (2013).
- [3]. H. Asgari and al, Modeling and Simulation of the Transient Behavior of an Industrial Power Plant Gas Turbine, ASME J. Eng. Gas Turbines Power, 136(6), p. 061601, (2014).
- [4]. M. Yari, M. Aliyari, V94.2 Gas Turbine Identification Using Neural Network, RSI/ISM International Conference on Robotics and Mechatronics, Iran, (2013).
- [5]. M. Ben Rahmoune, A. Hafaifa, M. Guemana, Control and diagnostic of vibration in gas turbine System using neural network approach, 8th International Conference on Modelling, Identification and Control (ICMIC-2016), Algeria, (2016).
- [6]. F. Jurado, J. Carpio, Modeling Micro-Turbines on the Distribution System Using NARX Structures, Latin Am. Trans, IEEE, 1(1), pp. 34–39, (2003).
- [7]. A. Benyounes, A. Hafaifa, M. Guemana, Gas turbine parameters modelling based on fuzzy logic and artificial neural networks: Solar TITAN 130N investigation, Conference Paper, (2016).
- [8]. A. Benyounes, A. Hafaifa, K. Abdallah, M. Guemana, Fuzzy neural network approach based on measured data classification, Mathematics-in-Industry, Case Studies, DOI 10.1186/s40929-016-0006-3, (2016).
- [9]. Z. Boussaada, O. Curea and al, A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation, Journal of energies, doi.org/10.3390/en11030620, (2018).
- [10]. A. Ferreira, T. Ludermit, R. Aquino, Comparing recurrent networks for time-series forecasting, International Joint Conference on Neural Networks (IJCNN), Australia, (2012).