

GENERATION DU PROFIL VERTICAL DE LA VITESSE DU VENT PAR RESEAUX DE NEURONES.

N.Cheggaga * et F.Youcef Ettoumi

Laboratoire de Traitement d'Images et Rayonnement, Université des Sciences et de la
Technologie .BP 32 El Alia, 16111 Bab Ezzouar, Alger, Algérie.

Tél/Fax: +213 21 24 78 94 Mob: +213 61 68 29 18

cheggaga@yahoo.fr , youcefettoumi@yahoo.fr

RESUME

Le vent partage avec l'eau la première source d'énergie mécanique d'origine naturelle et la plus ancienne à avoir été exploitée par l'homme. Aujourd'hui, l'énergie d'origine éolienne est souvent considérée comme la plus prometteuse des énergies renouvelables à développer pour remplacer le charbon, le pétrole, le gaz et même le nucléaire.

Il est clair que pour l'optimisation des systèmes éoliens en un site donné, il est nécessaire de connaître les potentialités énergétique du site d'installation .Les données vents fournies par les stations météorologiques sont mesurées à la hauteur standard de 10 m du sol, les chercheurs se sont orientés vers l'extrapolation des paramètres vents à la hauteur de l'axe de l'éolienne (60 m ou plus).

Le présent travail vise à améliorer les fondements d'une prédiction de qualité à courts et longs termes de la puissance électrique générée par les installations d'énergie éolienne en adoptant l'approche par les réseaux de neurones. En utilisant en premier lieu des réseaux de neurones à couches non-récurrentes ; puis en incluant d'autres paramètres dans notre modèle de réseaux de neurones, tels que la température.

1. INTRODUCTION

L'objectif d'une estimation de potentiel éolien est de donner avec la plus grande précision possible l'énergie éolienne récupérable sur le site d'installation a la hauteur du mat de l'éolienne .Les données vents fournies par les stations météorologiques sont mesurées à la hauteur standard de 10 m du sol, les chercheurs se sont orientés vers l'extrapolation des paramètres vents à la hauteur de l'axe de l'éolienne (60 m ou plus).

Le choix des turbines et de leur emplacement précis nécessite ensuite une détermination plus précise des conditions de vent et de turbulence prenant en compte les facteurs locaux. Le productible théorique est alors estimé, assorti d'un calcul d'incertitude.

Or, le retour d'expérience des parcs en exploitation montre fréquemment une production réalisée inférieure à la production estimée, avec des écarts pouvant atteindre 20%. La principale contribution à ces écarts provient probablement de l'incertitude sur la détermination des grandeurs météorologiques. C'est notamment le cas pour les sites en terrain complexe, pour lesquels les méthodes et outils actuellement utilisés sont souvent mis en défaut. Par ailleurs, la tendance prévue pour les prochaines années est plutôt à la construction de parcs éoliens de grande taille, ce qui va rendre de plus en plus importante la prise en compte du calcul d'incertitude.

2. MODELISATION

La modélisation statique et dynamique est l'une des principaux domaines d'utilisation des réseaux de neurones RNs. Ces derniers sont des fonctions non linéaires modulaires capable d'approximer n'importe quelle fonction bornée dans un intervalle fermé de ses entrées.

En premier lieu notre système est considéré comme un système non linéaire mono variable qui peut être modélisés par la relation suivante:

$$y(k) = g(\Phi(k)),$$

Avec :

$$\Phi(k) = [y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-m)]$$

Et g est une fonction non linéaire supposée inconnue. Les paramètres m et n représentent, respectivement, l'ordre de la régression sur l'entrée $u(k)$ et l'ordre de la régression sur la sortie $y(k)$. Donc la sortie du réseau de neurone sera :

$$y_{\text{net}} = W_{2a}[W_{1a}U] + W_{2b}F[W_{1b}U]$$

$W_1, W_2, W_{1a}, W_{1b}, W_{2a}$ et W_{2b} Présentent les poids des réseaux linéaire, non linéaire et hybride.

Notre choix c'est porté sur un réseau multicouche non récurrent. Le réseau est constitué par trois couches de neurones, nommées couche d'entrée, couche de sortie et couche cachée.

Un grand nombre des processus d'apprentissage sont disponibles. Dans notre cas, on utilise la règle d'apprentissage nommé apprentissage par rétro propagation. Le but de l'algorithme d'apprentissage est de minimiser l'erreur globale E définit par :

$$E = \frac{1}{2} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

y_t est la sortie obtenue par le réseau et \hat{y}_t est la cible (la sortie désirée).

3. RESULTATS

Nous avons commencé par l'extrapolation de la vitesse de vent d'un niveau $Z_1=10\text{m}$ à $Z_2=50\text{m}$. À l'aide du logiciel MatLab et des données météorologiques relevées grâce à des pylônes installés dans différentes régions (Algérie, Canada et USA). Les données sont relevées toutes les heures à des hauteurs allant de 10 à 103m du sol.

Nous avons procédé à des simulations pour tester l'efficacité des réseaux de neurones particulièrement dans le domaine de l'extrapolation. Notre choix justifié par le critère d'Akaike c'est porté sur le feed-forward à une entrée Z_1 , deux couches cachées et une sortie Z_2 .

Le critère d'Akaike consiste à choisir le modèle pour lequel la quantité AIC est minimale :

$$AIC = N \log(EQM) + 2(q+1)$$

Ou N est le nombre d'exemple, q le nombre de descripteur du modèle, et ou EQM est l'erreur quadratique moyenne sur un ensemble de données. Ainsi, pour une même performances estimé les modèles ayant le plus petit nombre de paramètre sont favorisés.




Figure 1 Variation journalière de la vitesse moyenne du vent a deux hauteurs (10m et 50m).

Afin de mieux approcher les modèles classiques, une étude comparative du profil vertical du vent, basée sur les vitesses moyennes brutes et la moyenne estimée à une hauteur de 50m, a été établie En figures 2. Qui représente la dépendance structural de la variation mensuelle de la vitesse moyenne du vent entre deux hauteurs (10m et 50m). Ainsi que les résultats de l'extrapolation par les méthodes suivantes :

- Loi logarithmique
- Loi de puissance 1/7
- Loi de puissance
- Modèle d'extrapolation de Justus
- Modèle d'extrapolation de Mikhail et al

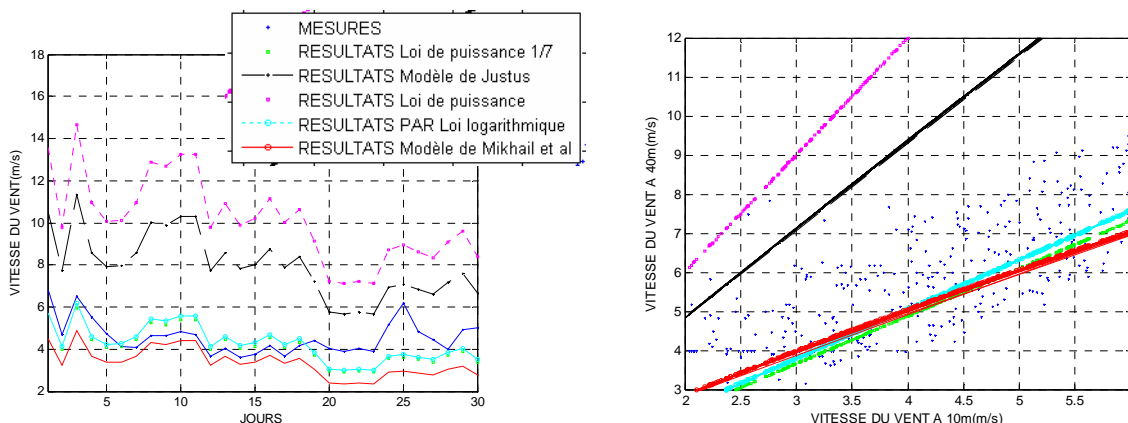


Figure 2 Comparaison entre la sortie réelle et la sorties obtenues par différentes méthodes ou modèles classiques

Le calcul de l'erreur RMS (Root-mean-square error) et de l'incertitude, lors de la comparaison, a permis de dresser le tableau suivant :

Tableau 1 Tableau comparatif

Méthodes d'extrapolation	Estimation journalière	Estimation mensuelle	Estimation annuelle
Loi de puissance 1/7	0.8700 (14.67%)	7.0118 (16.98%)	50.6295 (149.08%)
Modèle d'extrapolation de Justus	3.4969 (73.62%)	33.2508 (92.86%)	90.8401 (307.25%)
Loi de puissance	5.6284 (120.54%)	64.4730 (172.56%)	141.6425 (491.31%)
Loi logarithmique	0.8066 (13.59%)	8.4068 (19.91%)	52.7176 (156.86%)
Modèle d'extrapolation de Mikhail et al	0.7398 (12.73%)	9.0998 (21.75%)	29.9348 (96.25%)

On examine la performance des réseaux de neurones pour l'extrapolation de la vitesse du vent d'une altitude vers une autre. Une paire de valeurs (d'entrée et de sortie) constitue l'échantillon d'apprentissage. L'entrée c est la vitesse du vent à 10m et la sortie c' est la vitesse du vent à 50m. Les figures suivantes visualisent respectivement l'apprentissage et la validation du réseau de neurones. Le nombre d'échantillons équivaut à une journée. La validation est sur une année




Figure 3 apprentissages du RN et Comparaison entre la sortie réelle et la sortie obtenue par le modèle RN

Le calcul de l'erreur RMS et de l'incertitude, pour une variété de temps d'apprentissage (un jour, un mois, une année) et une variété de périodes de validation, a permis de dresser le tableau 2. On peut toujours faire une comparaison entre le tableau 1 et le tableau 2. Afin de mettre en évidence l'amélioration.

Tableau 2 Performance du réseau de neurones.

d'échantillons d'apprentissage	Période de validation un jour	Période de validation un mois	Période de validation un an
Une journée	0.4649 3.76	1.0802 9.83	19.6531 44.10
Un mois	0.5259 4.13	19.6406 44.07	19.7026 42.94
Une année	- -	- -	0.9965 6.10

On remarque que le réseau de neurones trace une fonction d'approximation ou modèle linéaire au bout d'une journée d'observation. Donc la réponse du modèle est linéaire. Elle se bien approximer mais ne couvre pas tous le champs. Le problème peut être résolu par l'introduction d'autres entrées (paramètres). L'étude du phénomène vent nous mène à adopter le paramètre température.

Les figures suivantes visualisent respectivement l'apprentissage et la validation du réseau de neurones. Le nombre d'échantillons équivaut à une journée. La validation est également sur une journée.

Une paire de valeurs (2 entrées et une sortie) constitue l'échantillon d'apprentissage. Les entrées sont la vitesse du vent et la température à 10m et la sortie c'est la vitesse du vent à 50m

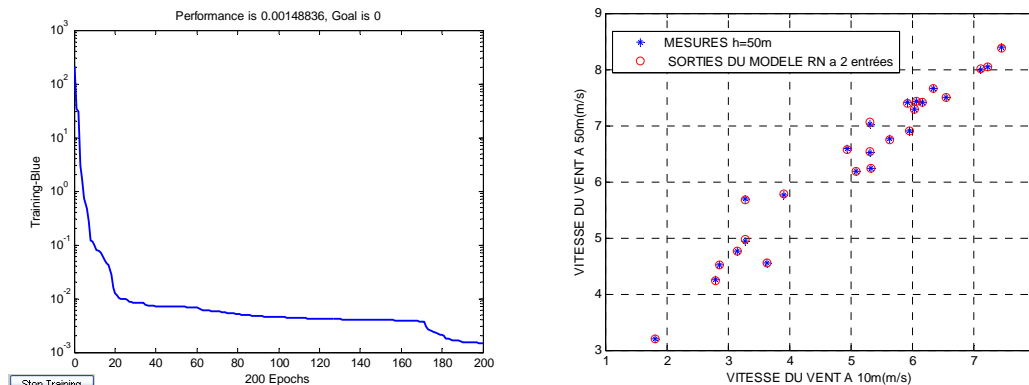


Figure 4 apprentissages du RN et Comparaison entre la sortie réelle et la sortie obtenue par le modèle RN à deux entrées

Le passage d'un site à un autre ne nécessite qu'une adaptation du nombre de neurones dans les couches, en particulier la première couche.

Pour générer le Profil vertical de la vitesse du vent, on utilise un réseau qui comprend, deux entrées (vitesse et altitude). La figure 6, illustre les évolutions des sorties (système et modèles).

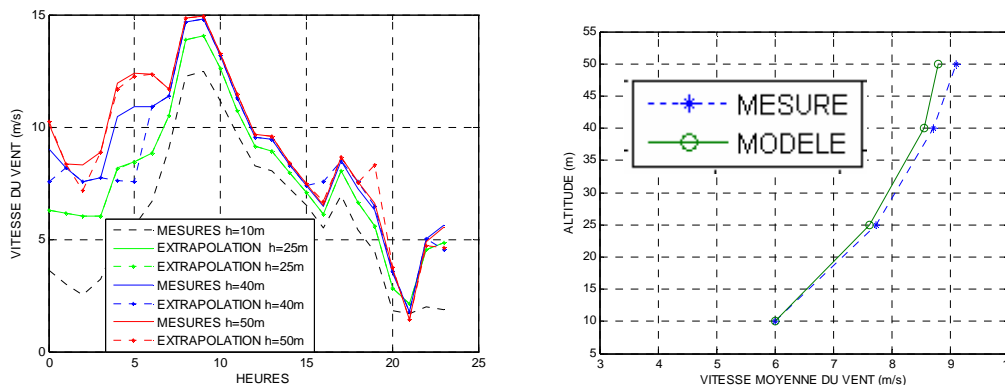


Figure 5 : évolutions des sorties (système et modèles).

4. CONCLUSION:

Lors de notre étude comparative entre les vitesses mesurées et les résultats de l'extrapolation par les méthodes classiques, on a remarqué que certaines méthodes se rapprochent des mesures alors que d'autres s'éloignent des mesures. Ces méthodes sont plus au moins valident d'après les régions. Car ces des méthodes empiriques, élaborées suite a des années de mesures régionales. Donc un réseau de neurones aussi simple que le notre, peut en une journée d'observation, dégager l'équivalent des ces méthodes.

Les réseaux de neurones offrent une approche prometteuse pour différents problèmes scientifiques comme l'identification des systèmes non linéaire. Dans ce travail nous avons montré la possibilité de l'utilisation des réseaux de neurones à couches non-récurrentes pour l'extrapolation de la vitesse de vent, d'un niveau $Z_1=10m$ a des niveaux plus haut, à court et long terme. Les résultats obtenus permettent de dégager des décisions économiques pour des projets d'aménagement industriel au bout d'un moi d'observation.

Dans ce travail nous avons montré la possibilité de l'introduction du paramètre température lors de l'extrapolation de la vitesse du vent d'une altitude à une autre, ainsi que les amélioration des résultats apportés par la prise en compte de ce paramètre très décisif. On peut nettement remarquer que l'introduction de l'approche réseaux de neurones avec le paramètre température ou différence de température permet d'obtenir un résultat qui couvre fidèlement le nuage de mesure.

REFERENCES BIBLIOGRAPHIQUES

1. Dr. Gary & L. Johnson, 2001, "Wind Energy Systems", Available: 2001www.rpc.com.au/products/windturbines/wind-book/WindTOC.html
2. "Le spectaculaire développement de l'énergie éolienne en Espagne »Congress EWEC 2003 Available : www.clean-auto.com/spip.php?article1334
3. J.F.Manwell, J.G. McGowan & A.L. Rogers,2002, "wind energy explained", John Wiley & Sons Ltd : ch 2.
- 4 .William David Lubitz, 2006, "Accuracy of Vertically Extrapolating Meteorological Tower Wind Speed Measurements", Canadian Wind Energy Association Annual Conference Winnipeg, MB, Canada. October 22-25,. www.soe.uoguelph.ca/webfiles/wlubitz/Lubitz_CanWEA_2006.pdf
5. S.S.MIKHAIL & C.G. JUSTUS, 1981, "Comparison of Height Extrapolation Models and Sensitivity Analysis", Journal of Wind engineering, vol. 5/2.
6. J.D Pneumatikos. , 1991, " An Experimental Test of the Empirical Formula Commonly Used to Represent Wind Speed Profiles near Ground" Renewable energy, vol1, N°5/6, pp 423-428.
7. S. Poje and B. Cividini, 1988, "Assessment of wind Energy Potential in Croatia" SolarEnergy, vol.41 N°6 pp 543 554.
8. J.P,Norton,1986, "an introduction to identification".Academic press.
9. L. Personnaz & I. Rivals, 2003, « Réseaux de neurones formels pour la modélisation, la commande et la classification »CNRS édition 2003 ,387p.
10. D.T.Pham and X.Liu,1999, "Neural networks for identification prediction and control": Springer 1999.238p
11. The Neural Network Toolbox for use with MATLAB provides tools for design, Available: www.mathworks.com/products/neuralnet/