



**HAL**  
open science

## Modélisation neuro-flou du bilan hydrique d'une serre horticole

Fateh Bounaama, Belkacem Draoui, Abdelhafid Hasni

► **To cite this version:**

Fateh Bounaama, Belkacem Draoui, Abdelhafid Hasni. Modélisation neuro-flou du bilan hydrique d'une serre horticole. JITH 2007, Aug 2007, Albi, France. 5p. hal-00167219

**HAL Id: hal-00167219**

**<https://hal.science/hal-00167219>**

Submitted on 29 Aug 2007

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# MODELISATION NEURO-FLOUE DU BILAN HYDRIQUE D'UNE SERRE HORTICOLE

Fateh BOUNAAMA, Belkacem DRAOUI, Abdelhafid HASNI

Institut de Génie Mécanique, Centre Universitaire de Béchar, B.P 417, 08000 Béchar

*fbounaama2002@yahoo.fr*

**Résumé :** Les systèmes de production "serres" deviennent considérablement sophistiqués et alors démesurément coûteux. C'est pourquoi, les serristes qui veulent demeurer compétitifs, doivent optimiser leur investissement par une grande maîtrise des conditions de production [1]. De nouvelles techniques de conduite climatique ont émergé, par lesquelles l'utilisation d'intelligence artificielle, sont des méthodes d'actualité servant à l'élaboration de modèles mathématiques destinés à la gestion climatique [1]. A partir de ce constat nous avons entrepris cette étude dont l'objectif principal est d'étudier la modélisation Neuro-Floue d'un système non linéaire. Les tests sont faits sur une séquence du mois de Mai, des données expérimentales collectées sur le site de l'INRA, Bioclimatologie Avignon (France). Le modèle obtenu représente fidèlement la serre et apte à être utilisé dans le cadre d'une régulation on-line [2].

**Mots clés :** Climat – Identification – Modèle Neuro-Flou – Serre – Pression.

## 1. INTRODUCTION

A la suite des travaux effectués ses vingt dernières années, beaucoup de progrès ont été faits dans l'étude et la modélisation et comportement hydrique des serres horticoles. Les problèmes liés au contrôle : de la déshumidification par aération et chauffage, l'humidification et ombrage estivale, contrôle simultané et l'humidité et de la température doivent être abordé à partir des bilans de vapeur d'eau. Nous avons été amené à développer un modèle Neuro-Flou de bilan de vapeur d'eau de la serre. Ce dernier caractérise le fonctionnement du système complexe que constitue la serre. L'identification qui est au centre de cette démarche est un processus de recherche d'une représentation mathématique qui minimise les écarts du système réel par rapport au système modélisé. Le développement de la plante est influencé principalement par les variables climatiques environnementales. La serre, qui est un milieu fermé dans lequel les variables climatiques peuvent être contrôlées, constitue le milieu idéal pour la maîtrise de la croissance des plantes. La serre doit non seulement créer les conditions favorables à la croissance des plantes, mais elle doit en plus être en mesure d'assurer une certaine flexibilité dans le calendrier de production : précocité et étalement du calendrier. Pour réaliser cet objectif un bon modèle représentant fidèlement le comportement de la serre est plus que nécessaire [2].

## 2. BILAN HYDRIQUE D'UNE SERRE HORTICOLE

### 2.1. Modèle de connaissance

Les serres sont des systèmes dynamique complexe qui dépendent des conditions environnementales extérieures, de la structure de la serre, de l'effet des variables de commande (surface d'ouvrant et le chauffage), dont le comportement peut être décrit en termes de système d'équations non linéaires qui après intégration et mise sous forme récurrente entre les pas de temps  $n$  et  $n+1$ , on obtient un modèle de connaissance décrit par les équations d'état suivantes [2] :

*Pression de vapeur d'eau interne de la serre :*

$$P_i(n+1) = P_i(n) \exp(-\zeta \Delta t) + (1 - \exp(-\zeta \Delta t)) \cdot \left( \frac{rsB}{\xi} \frac{\gamma\tau}{\xi} \frac{\chi}{\xi} \frac{\gamma sB}{\xi} \frac{\gamma s}{\xi} \right) (R_g P_e T_i \varphi_i)^T \quad (1)$$

*Température de la masse virtuelle (le sol) de la serre :*

$$T_m(n+1) = T_m(n) \exp\left(-\frac{\Delta}{\tau} t\right) + \left(1 - \exp\left(-\frac{\Delta}{\tau} t\right)\right) \cdot \left(\frac{\alpha h + B\gamma}{h(K + K_s)}, \frac{\nu}{h(K + K_s)}, 1, \frac{l}{(K + K_s)}, \frac{K_l}{(K + K_s)}, -\frac{K_l}{(K + K_l)}\right) \theta \quad (2)$$

avec  $\theta = (T_e R_g Q_{sol} Q_{air} P_e P_i)^T$

et température de l'air interne de la serre :

$$T_i(n+1) = \frac{h}{\gamma} T_m(n+1) + \left(\frac{\nu - h}{\nu} \frac{\alpha}{\nu} 0 \frac{l}{\nu} \frac{K_l}{\nu} - \frac{K_l}{\nu}\right) \theta \quad (3)$$

### 3. METHODES NEURONALES DANS LES SYSTEMES FLOUS

#### 3.1. Modèle de comportement

Malheureusement le modèle de connaissance obtenu est difficilement contrôlable car il est à temps variant et non linéaire [3]. L'utilisation des méthodes neuro-flou devenues très populaires dans la résolution des problèmes complexes [5], peuvent appréhender la serre dans toute sa complexité en intégrant des concepts qualitatifs empiriques et expertes [4], et génèrent un modèle de comportement apte pour le contrôle. Si on a une base de connaissance exprimée sous forme de règles linguistique, nous pouvons formuler un système d'inférence flou, et si on dispose de données expérimentales nous utiliserons les neurones artificiels. Pour construire un système d'inférence flou, il faut spécifier les ensembles flous, les opérateurs flous et la base de connaissance, et pour construire un réseau de neurones artificiel, l'utilisateur a besoin de spécifier l'architecture et l'algorithme d'apprentissage. L'analyse montre que ces deux approches semblent complémentaires, et la construction d'un système complet doit combiner les deux concepts. Dans la littérature il y a une panoplie de systèmes neuro-flou comme : les systèmes neuro-flou coopératives, concurrents, et les systèmes dit hybrides ou neuro-flou adaptatif. Dans ces derniers les systèmes flous sont représentés sous forme d'une structure réseaux imitant ainsi les réseaux neuronaux artificiel (Ann) [1].

#### 3.2. Systèmes d'inférence neuro-flou adaptatifs

Les systèmes d'inférence neuro-flou adaptative (anfis), sont des systèmes hybrides utilisant l'inférence floue de Takagi Sugeno. La structure anfis est constituée de cinq couches comme montrées par les figures (3 - 1,2). La première couche cachée 'fuzzifie' les variables d'entrées et les opérateurs type T-norm calculent la partie prémisse des règles dans la deuxième couche cachée. La troisième couche cachée normalise les poids des règles suivit par la quatrième couche cachée où les paramètres des parties conclusion des règles sont déterminés. La couche de sortie calcule la somme de tous les signaux venant de la quatrième couche [6]. Les paramètres adaptables dans les systèmes anfis sont:

- ❖ Les paramètres de la fonction d'appartenance des parties prémisses [a,b,c,d].
- ❖ Et les paramètres polynomiaux [p,q,r], appelées paramètres de la partie conclusion.

Sont entraînés par l'algorithme du gradient descente (rétro propagation) pour l'optimisation des paramètres des parties prémisses, et l'algorithme des moindres carrés pour la résolution des paramètres des parties conclusion. Afin de réduire l'erreur E [4].

$$E = \frac{1}{2} (y - y')^2 \quad (4)$$

La i<sup>em</sup> règle du système flou type Sugeno constituées de m entré et n règles (i = 1, ..., n), est représentée aux figures (3 - 1,2).




Figure 3.1 : Système Sugeno d'ordre Zéro avec n=2 règles, et m=2 entrées




Figure 3.2 : Système Sugeno d'ordre 1 avec n=2 règles, et m=2 entrées

Un système Sugeno d'ordre zéro est représenté par les équations suivantes :

$$w_i = \prod_{j=1}^m \mu_{A_j}(x_j) \quad \text{et} \quad \bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i} \quad (5) \quad y = \sum_{i=1}^n \bar{w}_i f_i = \sum_{i=1}^n y_i \quad (6)$$

où  $f_i$  est une constante définie par :  $f_i = r_i$  (7)

En présence des sorties cibles ( $y^r$ ), le réseau peut être ajusté pour réduire la mesure d'erreur. Les paramètres ajustables sont les fonctions d'appartenance d'entrée, et la sortie de type singleton  $r_i$ .

$$r_i(t' + 1) = r_i(t') - lr \frac{\partial E}{\partial r_i} \quad (8) \quad \Leftrightarrow \quad r_i(t' + 1) = r_i(t') - lr \frac{\mu'}{\sum_{i=1}^n \mu_i^p} (y^p - y^{rp}) \quad (9)$$

Pour un système Sugeno de premier ordre les paramètres de conclusions ( $p, q$ , et  $r$ ) de la  $n^{\text{ième}}$  règle sont reliés linéairement par un polynôme de premier ordre de forme :

$$f_n = p_n x_1 + q_n x_2 + r_n \quad (10)$$

Si la sortie des nœuds dans chacune des couches respectives est représentée par :  $O_i^l$ , où  $i$  est le  $i^{\text{ième}}$  nœud de la couche  $l$ , alors la description couche par couche d'un système Sugeno de premier ordre de 2 entrées et de 2 règles est la suivante [4]:

**Couche 1** Génération du degré d'appartenance :  $O_i^1 = \mu_{A_i}(x)$  (11)

**Couche 2** Génération du poids de la règle  $i$  :  $O_i^2 = w_i = \prod_{j=1}^m \mu_{A_j}(x)$  (12)

**Couche 3** Normalisation des poids de la règle  $i$  :  $O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}$  (13)

**Couche 4** Calcule de la sortie des règles en fonction des paramètres conclusions :

$$O_i^4 = y_i = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (14)$$

**Couche 5** Faire la somme toutes les entrées à partir de la couche 4 :

$$O_i^5 = \sum_i y_i = \sum_i \bar{w}_i f_i = (\bar{w}_1 x_1) p_1 + (\bar{w}_1 x_2) q_1 + \bar{w}_1 r_1 + (\bar{w}_2 x_1) p_2 + (\bar{w}_2 x_2) q_2 + \bar{w}_2 r_2 \quad (15)$$

C'est dans cette dernière couche que les paramètres des parties conclusions peuvent être optimisées par l'utilisation de l'algorithme des moindres carrés. L'équation ci dessus devient alors sous la forme suivante :


$$O_i^5 = y = (w_1 x_1) p_1 + (w_1 x_2) q_1 + w_1 r_1 + (w_2 x_1) p_2 + (w_2 x_2) q_2 + w_2 r_2 \quad (16)$$

$$y = [w_1 x_1 \ w_1 x_2 \ w_1 \ w_2 x_1 \ w_2 x_2 \ w_2] [p_1 \ q_1 \ r_1 \ q_2 \ r_2]^T = XW \quad (17)$$

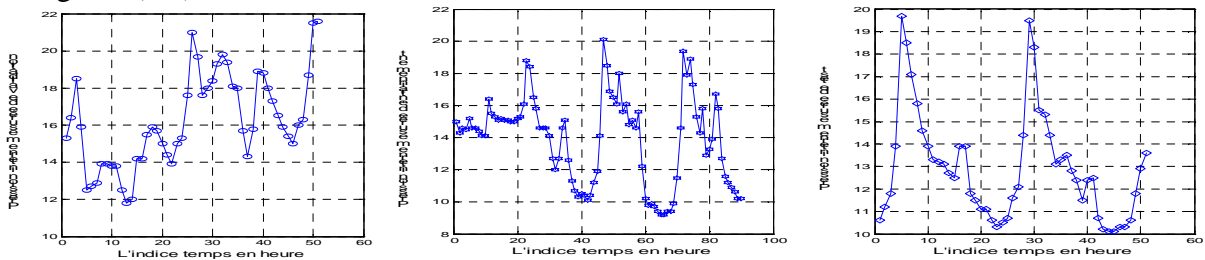
## 4. LES RESULTATS

### 4.1. Les fichiers de mesure

Les enregistrements ont été réalisés durant la période du mois de Mai à L'INRA d'Avignon, France [2]. La serre dans laquelle toutes les enregistrements expérimentaux ont été réalisés est une serre en plastique double chapelle, double paroi gonflable, de 1700 m<sup>3</sup> de volume. Elle occupe une surface au sol de 416 m<sup>2</sup>. Son grand axe est parallèle à la direction nord-sud. Le toit et les parois latérales sont en polythène. Cette serre avec ses vecteurs climatiques d'entrées-sorties est identifiée sous forme d'un modèle hydrique représenté dans la figure (4.1.b) :



Pour mener à bien notre travail, nous avons divisé les fichier de données de sept jours du mois de Mai en trois parties, la première comprends quatre jours (90 heures), la seconde et la troisième sont représentées de deux jours chacune (50 heures) ce qui est rapporté sur les figures (4.2).

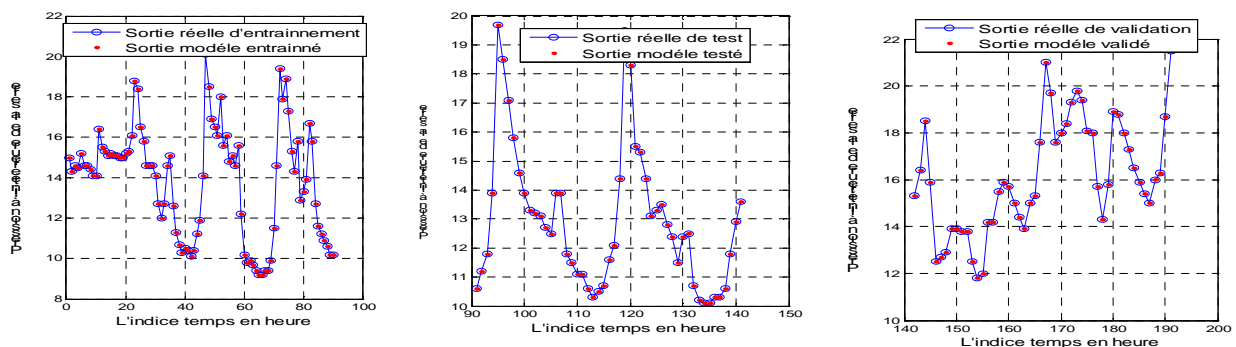


#### 4.2. Validation de modèle par l'ensemble des données de test et de validation

La validation de modèle est le processus dans lequel les vecteurs d'entrées des données d'entrées-sorties mesurées et sur lequel le modèle FIS n'est pas entraîné sont appliquées. Ceci est accompli par un ensemble de données appelées données de test, et de validation. Cette démarche est utilisée pour contrôler le potentiel de généralisation du modèle FIS, et pour éviter le sur ajustage de celui-ci sur les données d'entraînement [5].

#### 4.3. Discussion des résultats

Les figures (4.3, 4.4) montrent une parfaite concordance entre la sortie des données mesurées et la sortie modèle.



#### 4.4. Erreur d'entraînement, de validation et de test

Dans notre travail l'erreur à chaque itération est la racine carrée moyenne (*RMS*). Les figures (4.5) représentent cet écart quadratique moyen pour chaque type de données mesurées et calculées sachant que les températures sont mesurées à l'aide de sondes cuivre d'une précision de  $0,5\text{ }^{\circ}\text{C}$ .

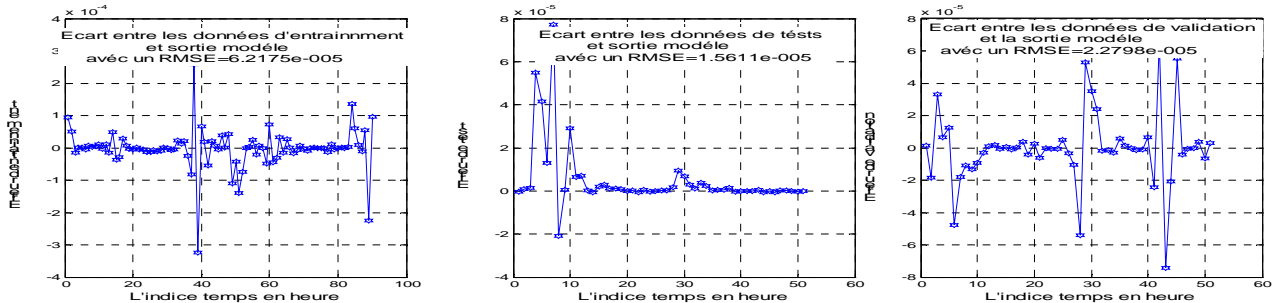


Figure 4.5 : les écarts des pressions interne réelle et calculées d'entraînement, de test, et de validation

Les erreurs d'entraînement, de test, et de validation obtenues sont très faibles avec une erreur quadratique moyenne respectivement de  $6,2175\text{ e-}005$ ,  $1,5611\text{ e-}005$ , et  $2,2798\text{ e-}005$ . Donc d'après ces erreurs notre modèle n'est pas sur ajustée et généralise assez bien ces sorties.

## 5. CONCLUSION

La modélisation des serres par les méthodes hybrides neuronale et floue nécessite un maximum d'informations selon différentes situations pour son apprentissage [7]. Malgré l'utilisation d'une base de données relativement réduite (90 entrées-sorties pour la phase d'apprentissage et  $2 \times 50$  entrées-sorties pour la phase de test et de validation pour un système MIMO 7-entrées, 1 sortie), les résultats obtenus sont comparables avec ceux publiés dans la littérature [4]. Les résultats obtenus dans la phase de test et de validation montrent qu'en présence de nouvelles situations, le modèle reproduit fidèlement le comportement de la serre, et est donc apte à être utilisé pour l'élaboration d'une loi de commande appropriée.

## Références

- [1] F. Bounaama, Modélisation neuronale et polynomiale d'une serre horticole et commande par réseau neuronale et logique floue, mémoire de Magister en physique énergétique, centre universitaire de Béchar, 2001.
- [2] B. Draoui. Caractérisation et analyse du bilan thermo hydrique d'une serre horticole. Identification in situ des paramètres d'un modèle dynamique, Thèse de Doctorat de l'université de Nice Sophia Antipolis, France, 1994.
- [3] B. Kosko, Fuzzy systems as universal approximators, IEEE Trans. Computers 43, 1329–1333, 1994.
- [4] J.S.R. Jang, ANFIS: Adaptive-network-based fuzzy inference systems. IEEE Transactionson Systems, Man & Cybernetics 23(3), 665–685, 1993.
- [5] R. Babuřska, H.J.L. van Can and H.B. Verbruggen, Fuzzy modeling of enzymatic Penicillin–G conversion, In Preprints 13th IFAC World Congress, Volume N, San Francisco, USA, pp. 479–484, 1996.
- [6] J.S.R. Jang, and C.-T. Sun, Functional equivalence between radial basis function networks and fuzzy inference systems, IEEE Transactions on Neural Networks 4(1), 156–159, 1993.
- [7] Fuzzy logic Toolbox, For Use with MATLAB, User's Guide Version2.