

MODELES DE PREVISION NEURONAUX VS ANFIS**FORECAST MODELS NEURONAL VS ANFIS****Bourioune Tahar**

Maitre de conférences classe A .Université de Sétif, wbourioune@yahoo.fr

Received: 27/04/2019

Accepted: 13-05/2019

Published:01/06/2019

Résumé :

Cet article tente de prévoir le taux d'inflation en Algérie durant la période 2017 :01 -2018 :06 par le modèle neuro-flou ANFIS. Les résultats de ce modèle sont comparés à ceux des modèles SARIMA et ANN. Les critères retenus pour la performance des prévisions sont le RMSE, le MAE et R². Ce travail a conclu à la supériorité relative du modèle ANFIS (RMSE= 7.8 e-02) et a révélé que le modèle a-théorique ANN est non moins compétitif.

Mots clés : INFLATION, ANN, FL, ANFIS

Jel classification : E31, C45, C63

Abstract :

This article attempts to predict inflation rate in Algeria during the period 2017: 01 -2018: 06 by the neuro-fuzzy ANFIS model. The results of this model were compared with those of the SARIMA and ANN models. The criteria used for forecast performance are RMSE, MAE and R². This work has found the relative superiority of the ANFIS model (RMSE = 7.8 e-02) and revealed that the a-theoretical ANN model is no less competitive.

Key words : INFLATION, ANN, FL, ANFIS

Jel classification : E31, C45, C63

1. INTRODUCTION

L'inflation est de retour en Algérie. Selon l'ONS, Le rythme d'inflation annuel en 2017 s'élèverait à plus de 6, 5% (ONS, 2017). Une prévision des IPC permettrait de se prémunir des effets néfastes de paupérisation et de déstructuration sociale de celle-là en élaborant des politiques anti-inflationnistes convenables. Comme les conséquences de mauvaises prévisions peuvent être tragiques, il ne suffit plus de prévoir encore faut-il que nos prévisions soient efficaces.

En vue de réaliser des prévisions congrues, les techniques de prévision se sont ingénierées au fil de l'histoire à « mimer » les chroniques économiques et financières réelles. A ce jour, ni les modèles statistiques SARIMA (Moshiri,2000 ; Nakamura,2004, Neves,2007 ; Hu,2007 ; Duzgun,2010), ni les modèles neuronaux ANN (Sztandera, 2003 ; Malek, 2010 ; Xi,2013), ni les modèles flous FL (Otlia, 2008 ; Keskin, 2010 ; Tektas, 2010 ; Lotfi, 2014) n'ont donné entièrement satisfaction.

L'hypothèse fondamentale de linéarité des modèles paramétriques traditionnels serait à l'origine de la faible performance des modèles SARIMA, VARIMA, ... dans le traitement des séries économiques de nature souvent non linéaire (Refenes, 1994).

La caractéristique de modèle à « boîte noire », le manque d'un fondement théorique, l'incapacité à traiter les variables qualitatives,...constitueraient parmi les principaux désavantages des modèles neuronaux ANN (Zadeh, 1965 ; Mahabir, 2003).

Les modèles de logique floue FL basés sur la théorie des ensembles flous et la théorie des possibilités du Professeur L. Zadeh n'ont pu surmonter les limites des

modèles ANN. En prenant en considération les données linguistiques (assez fort, fort, très fort), ils se sont rapprochés du langage humain et permis d'exprimer les connaissances qu'on a à priori sur un système sous forme de règles explicites. Malheureusement les problèmes de détermination des règles (rules) et des index des fonctions d'appartenance MF demeurent parmi leurs points faibles (Jang, 1993).

Pour pallier à ces relatives insuffisances, trois types de modèles mixtes ANN/FL sont proposés aujourd'hui en littérature : les modèles neuronaux-flous NFS, les modèles flous-neuronaux FNS et les systèmes hybrides. Les modèles NFS sont des modèles neuronaux dans lesquels on a implanté un système Flou de type Takagi Sugeno TS. Le modèle ANFIS est le modèle le plus représentatif de ces derniers, il fera l'objet de notre travail.

2. MATERIEL ET METHODES

21. Les Modèles ANN

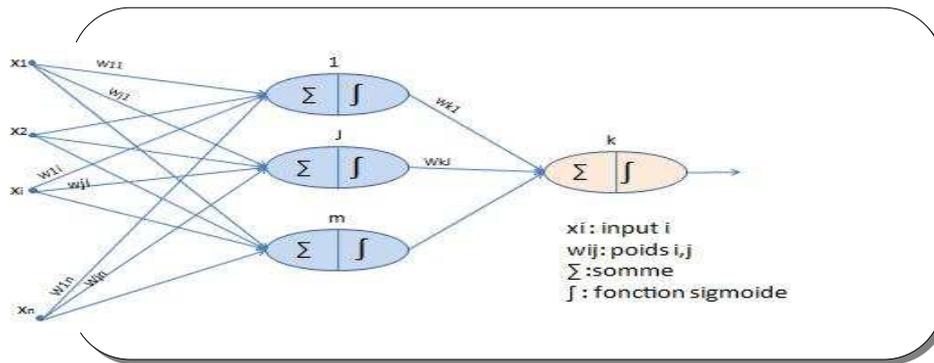
Les modèles ANN peuvent être classés en modèles statiques (FFNN, GRNN, RBFN, ...) et dynamiques (TDNN, NOE, NNARMAX ...). Nous nous limiterons dans cet article au modèle statique FFNN.

2.1.1 Structure du modèle FFNN

Le modèle *FFNN* est le modèle neuronaux type (Mehrotra, 1997). Statique, supervisé, il est originellement entraîné par l'algorithme « Back Propagation » BP. Il est souvent constitué de 3 couches : couche input, couche cachée (une ou plusieurs) et couche output. Le nombre d'unités de la couche input dépend de la dimension du vecteur input X ; le nombre d'unités de la couche cachée est déterminé par l'erreur de prévision minimale. Son prédicteur et sa structure sont les suivants :

$$\hat{y}(t) = \Phi_2 \left\{ \sum_{j=0} w_{kj} \left[\Phi_1 \left(\sum_{i=0} w_{ji} x_i + w_{j0} \right) \right] + w_{k0} \right\} \quad (1)$$

fig.1 structure FFNN [n : m :1]



Source : l'auteur

2.1.2 Architecture du réseau

Le vecteur input X^k a été formé par l'ensemble des variables explicatives $\{\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-k}\}$. Le nombre de décalage 'k' a été déterminé par l'erreur minimale de prévision. L'output $\hat{\pi}_t$ a constitué la valeur prédite de la valeur actuelle ' π_t ' de l'IPC. Nous avons opté pour une seule couche cachée, son nombre d'unités a été choisi par la méthode 'trial and error'. sa fonction de transfert a été 'tanh'. La couche de sortie a compris un seul neurone et sa fonction a été, selon les modèles, «purelin» ou «tanh».

2.1.3 Méthodologie de prédiction / prévision

Les prédictions ont été réalisées par simulation, au plus à 8-step-ahead. Les prévisions ont été effectuées selon la méthode réursive RMSNN. Les critères d'appréciation des prévisions ont été le RMSE, MAE et R^2 . Les données, couvrant la période 2002-2016, ont été subdivisées en 3 groupes : training set (70%), validation set (15%) et testing set (15%) soient respectueusement 126, 27 puis 27 observations. La période de prévision s'est étalée de 2017 :01 à 2018 :06.

2.2 Le Modèle SARIMA

2.2.1 Structure

Un processus stochastique P.S. $\{X_t\}_{t \in \mathbb{Z}}$ non stationnaire est I(d) « intégré d'ordre d » si $(1-L)^d X_t$ est stationnaire. Le modèle ARIMA (p, d, q) (Hurlin, 2004) est un processus non stationnaire I(d) qui vérifie :

$$\Phi(L) (1-L)^d X_t = \delta + \theta(L) \varepsilon_t$$

$$\text{où } \varepsilon_t \square iid(0, \sigma^2)$$

$$\Phi(L) = \sum_{i=0}^p \phi_i L^i$$

$$\theta(L) = \sum_{i=0}^q \theta_i L^i$$

(1.3)

$$L^p (X_t) = X_{t-p}$$

p : ordre du AR

d : ordre de différenciation

q : ordre du MA

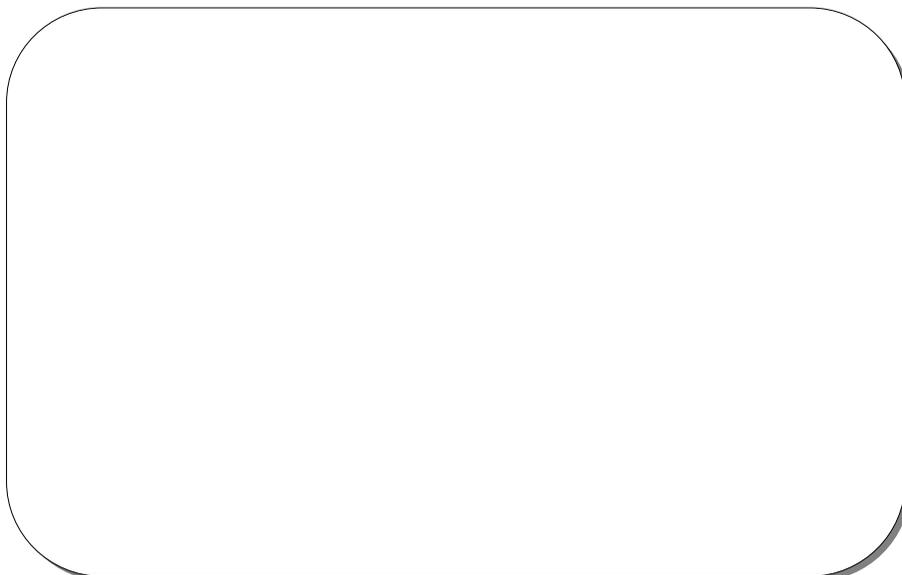
$$\Phi_0 = \theta_0 = 1$$

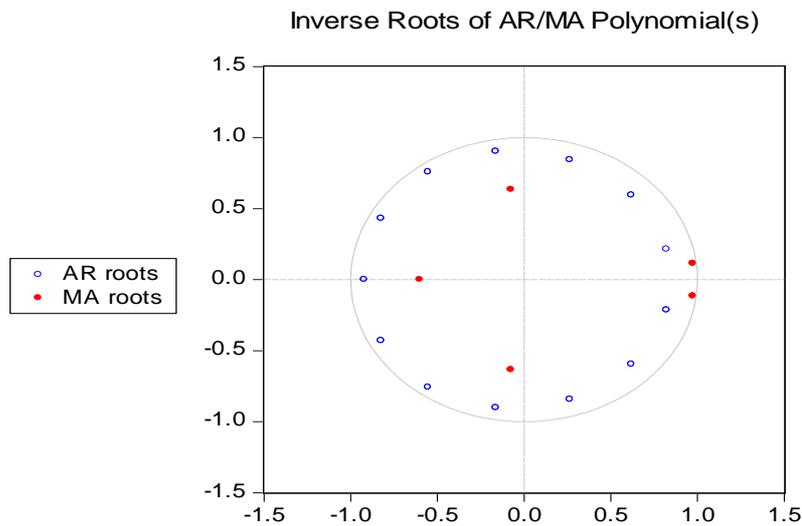
Le modèle SARIMA *multiplicatif* (p, d, q) (s, P, D, Q) est un prolongement du modèle ARIMA (p, d, q) contenant des parties saisonnières $\Phi_s(L)$ et $\theta_s(L)$.

2.2.2 Architecture du modèle

Après avoir stationnarisé la série brute 'yt', nous avons entamé sa spécification. Les tests informels (l'analyse du graphe, de la variance et du correlogramme) ont affirmé l'existence d'une saisonnalité. La stationnarisation de la série brute des IPC 'yt' a abouti à la série 'ytsa1' désaisonnalisée de forme additive. les tests formels DF et ADF ont conclu au fait que la série 'ytsa1' est I(0) donc stationnaire. Le modèle ARMA(13,5) est le modèle qui ajusterait le mieux la série désaisonnalisée 'ytsa1'. Ce modèle est stationnaire et inversible (fig. 2).

Fig. 2 l'inverse des racines d'ARMA (13,5)





Source : l'auteur

2.2.3 Méthodologie de prédiction / prévision

Les prédictions, dans ce cadre, se sont effectuées après identification, estimation et validation du meilleur modèle conformément à la méthodologie de Box-Jenkins. Récursivement, le prédicteur du processus ARMA(p,q) à l'horizon h, est :

$$\hat{Y}_{t+h} = \hat{Y}_t(h) = E(Y_{t+h} / Y_t, Y_{t-1}, \dots) = \sum_{k=1}^{h-1} \phi_k \hat{Y}_{t+h-k} + \sum_h^{t+h} \phi_k Y_{t+h-k} \quad (1.5)$$

Les prévisions ont été effectuées, sous eviews7, selon la procédure 'dynamique'.

2.3 MODELE ANFIS

Ce modèle a pour but d'améliorer la performance du modèle flou FL par l'ajustement des MF et des règles d'inférence au moyen de l'algorithme d'apprentissage hybride BP-LMS.

2.3.1 STRUCTURE

Ce modèle est dû à J-S. R. Jang (1993) à qui on emprunte l'exemple illustratif suivant :

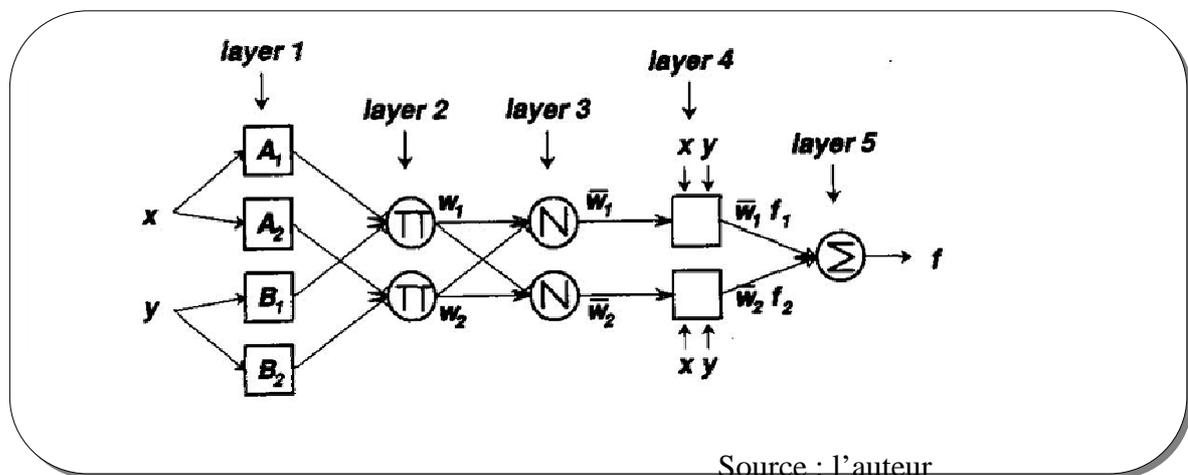
Si l'on suppose 2 inputs 'x' et 'y'; 2 fonctions d'appartenance de type 'gbellmf' (pour chaque input) à savoir 'A1', 'A2' et 'B1', 'B2' ; 1'output 'f' et 2 règles d'inférence de type TS à savoir :

Si 'x est A₁' et 'y est B₁' ALORS 'f₁=p₁x+q₁y+r₁'

Si 'x est A₂' et 'y est B₂' ALORS 'f₂=p₂x+q₂y+r₂'

Ce modèle, de structure comparable à celle du modèle FFNN, est composé de 5 couches.

fig.3 structure ANFIS



La couche 1 est le lieu de la fuzzification des inputs (x_i,y_i), l'output d'un nœud i est l'index de la fonction d'appartenance MF.

$$O_i^1 = \mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad a_i, b_i, c_i : \text{paramètres 'premisses' variables}$$

Les paramètres variables a_i , b_i et c_i , sont ajustés lors de la phase 'backward' de la procédure d'entraînement.

La couche 2 comprend des nœuds dénommés ' Π ' qui combinent les divers index obtenus en ' 1 ' au moyen d'opérateurs logiques pour obtenir les poids des règles d'inférence (rules) :

$$O_i^2 = W_i = \mu_{A_i}(x) + \mu_{B_i}(x) \quad i=1,2$$

La couche 3 comprend des nœuds dénommés 'N' qui procèdent à la normalisation des poids obtenus en ' 2 ' :

$$O_i^3 = \bar{W}_i = \frac{W_i}{W_1 + W_2} \quad i=1,2$$

La couche 4 est le lieu de calcul des 'conséquences' des règles d'inférence de type TS :

$$O_i^4 = f_i = \bar{W}_i (p_i x + q_i y + r_i) \quad i=1,2$$

Les paramètres variables p_i , q_i et r_i sont ajustés lors de la phase 'forward' de la procédure d'entraînement.

La couche 5 calcule, enfin, l'output final ' f ' ,

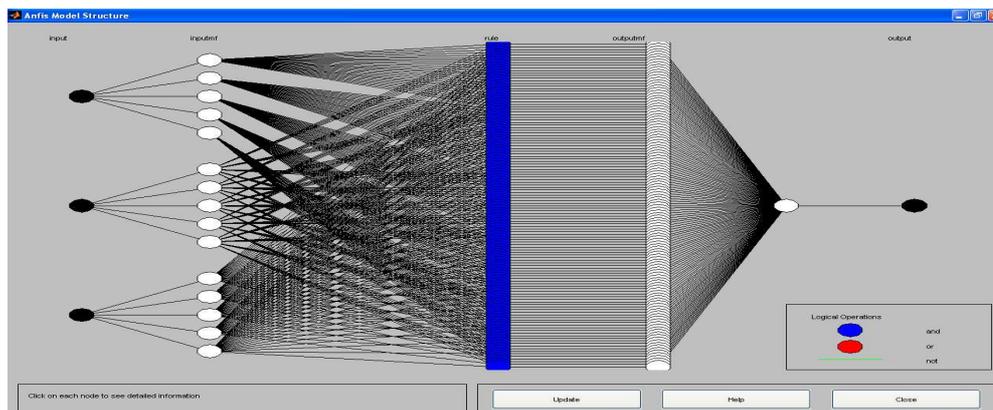
$$O_i^5 = f = \sum_i \bar{W}_i \quad i=1,2$$

2.3.2 ARCHITECTURE

Le vecteur input X^k est formé par l'ensemble des valeurs explicatives $\{\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-k}\}$. Le nombre de décalage ' k ' a été déterminé par l'erreur

minimale de prévision. L'output $\hat{\pi}_t$ a constitué la valeur prédite de la valeur actuelle de l'IPC π_t . Les MF des inputs ont été choisies tous de type 'trimf' ou 'gaussmf', celle de l'output 'f' est de type 'linear'. Le nombre de SEF est fixé à cinq : dm, df, itf, if et im. Les règles d'inférence sont choisies de type TS. L'algorithme d'apprentissage est la règle hybride 'BP-LMS'. L'architecture du système est présentée dans la figure suivante (fig. 4).

Fig. 4 Architecture du modèle (13,5)



Source : l'auteur

2.3.3 METHODOLOGIE DE PREDICTION /PREVISION

Les prédictions ont été effectuées par la méthode d'inférence de Takagi-Sugeno TS, au plus à 8-step-ahead. Les prévisions ont été effectuées selon la méthode récursive RMSNN. Les critères d'appréciation des prévisions sont le RMSE, MAE et R². La période de prévision s'étale de 2017 :01 à 2018 :06.

2.3 DONNEES

Les données sont tirées des séries « collections statistiques : IPC » publiées par l'ONS. La période s'étale sur 180 mois, de 2002 :01 à 2016:12 ; la période de prévision couvre 18 mois : 2017 :01- 2018 :06. Parce que nous considérons un horizon à court terme, nous nous contenterons des valeurs historiques des IPC $\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-k}$; $k \in \mathbb{N}$ comme variables explicatives. Le prétraitement des données

s'est restreint à leur agencement en $\pi_t^p = f(\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-p})$; $p = \overline{1,8}$ et à leur dessaisonnalisation en π_{tsa} (ou y_{tsa}).

3. SPECIFICATION ET RESULTATS

31. Modèle FFNN

FFNN1, FFNN2 et FFNN3 désignent respectivement le modèle à fonction d'output linéaire, le modèle à fonction d'output non linéaire et le modèle non linéaire. Le modèle FFNN2, relativement plus performant, a représenté le modèle FFNN [tab. 1].

Tableau 1 Performance comparée du modèle ffnn

Variante	RMSE	MAE	R
FFFN1	0.37	0.52	0.54
FFNN2*	0.40	0.45	0.63
FFNN3	0.48	0.56	0.66

Source : l'auteur

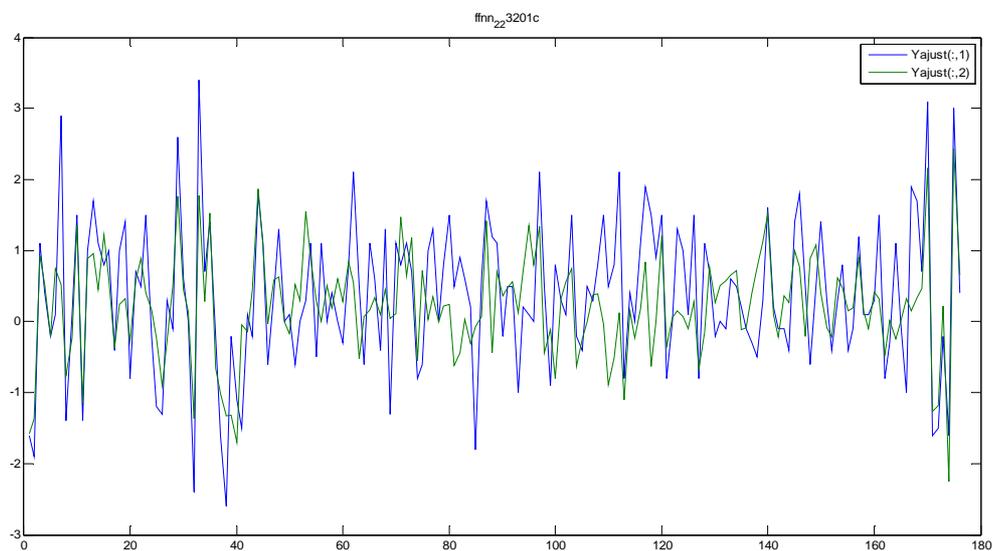
La variante optimale a été déterminée comme suit : Nous avons choisi d'abord le modèle représentatif de chacune des huit variantes au moyen du nombre optimal de neurones de sa couche cachée. Nous avons sélectionné, ensuite, la meilleure variante du modèle FFNN sur la base de l'erreur de prévisibilité minimale. Elle a représenté notre modèle FFNN qui a été entraîné par l'algorithme LM sous le logiciel MATLAB 2011.

Sur la base des résultats obtenus par simulation dans MATLAB 2011, la variante π_t^{4*} [4 :20:1] a matérialisé le modèle FFNN.

3.1.1 Prédiction par le modèle FFNN

Le graphe suivant (fig.5) illustre la moins bonne qualité d'ajustement du modèle à la série YTSA1 ($R^2=0.63$).

Figure 5 Ajustement de YTSA par FFNN2



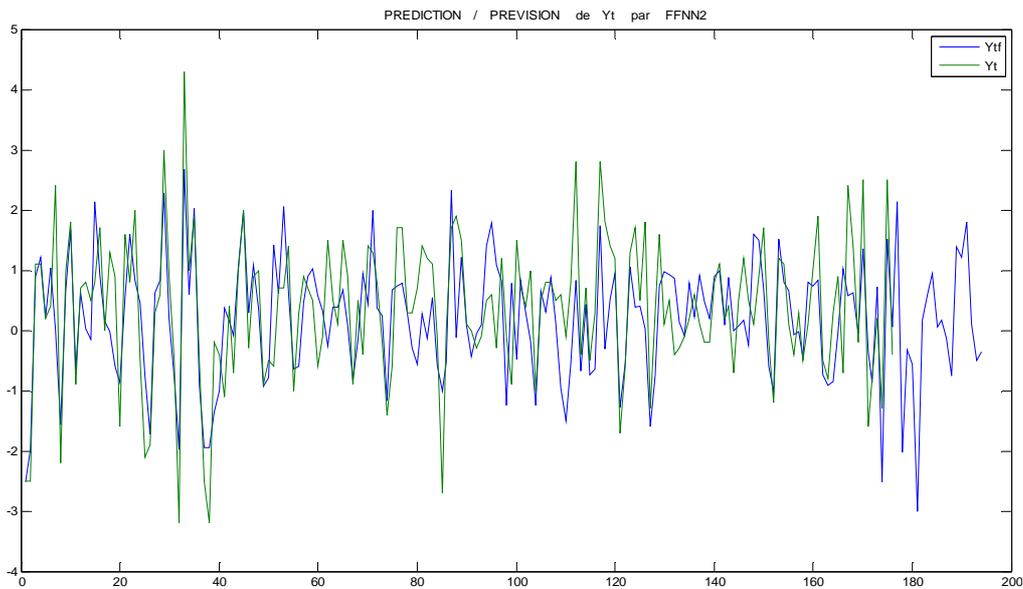
Source :

l'auteur

3.1.2 Prédiction par le modèle FFNN

Les IPC prévisionnels janvier 2017–juin 2018 générés par ce modèle sont représentés par le graphe ci-dessous [fig 6].

Figure 6 Prédiction de Y_t par FFNN2



Source : l'auteur

3.2 LE MODELE SARIMA

ARMA(13,5) et ARMA(13,7) sont les modèles retenus par notre étude statistique. Selon les critères du pouvoir prédictif, le meilleur modèle a été le modèle ARMA(13,5).

Tableau 2 Critères du pouvoir prédictif d'YTSA1

	RMSE	R ²	AIC	SC
modèle (13,5)*	1.03	0.82	2.92	3.02
modèle (13,7)	1.09	0.79	3.06	3.16

Source : l'auteur

Pour ce modèle, les tests statistiques de validation ont confirmé que : $\varepsilon_i \sim N(0, \sigma)$,

ε_i sont *iid* $(0, \sigma)$, ε_i sont homoscédastiques, le processus AR est stationnaire et MA est inver

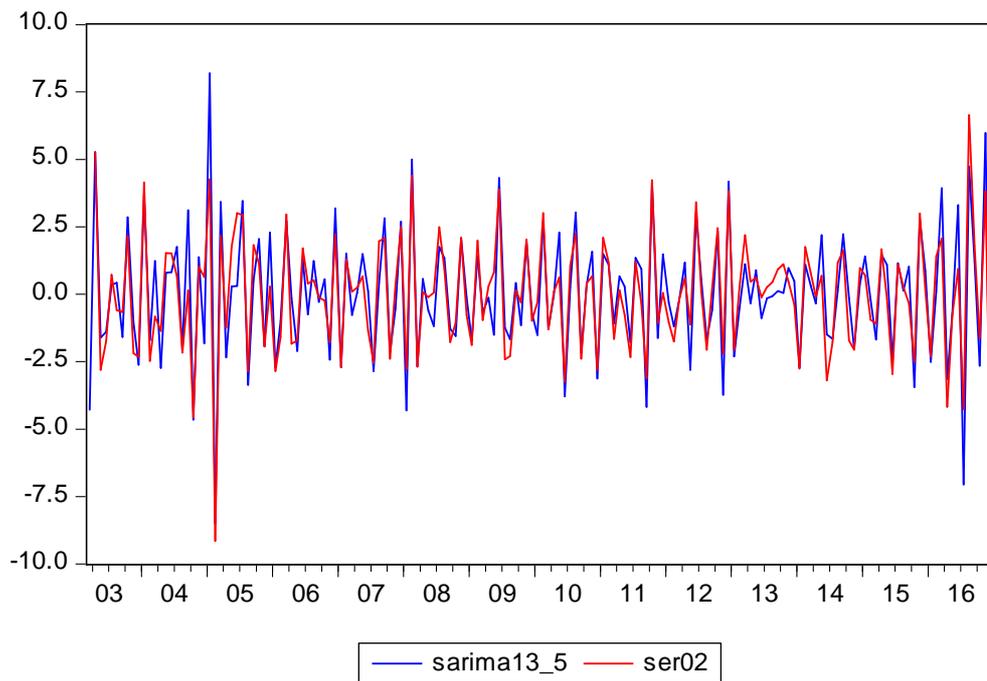
Aussi, le meilleur modèle statistique ajustant la série YTSA1 est :

$$\hat{ytsa1} = 1.42 ytsa1_{t-1} - 1.29 ytsa1_{t-2} - 0.2 ytsa1_{t-13} - 1.2 \varepsilon_{t-1} + 0.23 \varepsilon_{t-5} \text{ (fig.7).}$$

3.2.1 Prédiction par le modèle SARIMA

Le graphe suivant illustre la bonne qualité d'ajustement du modèle à la série YTSA1 ($R^2=0.82$).

Fig.7 Ajustement d'YTSA1 par le modèle SARIMA

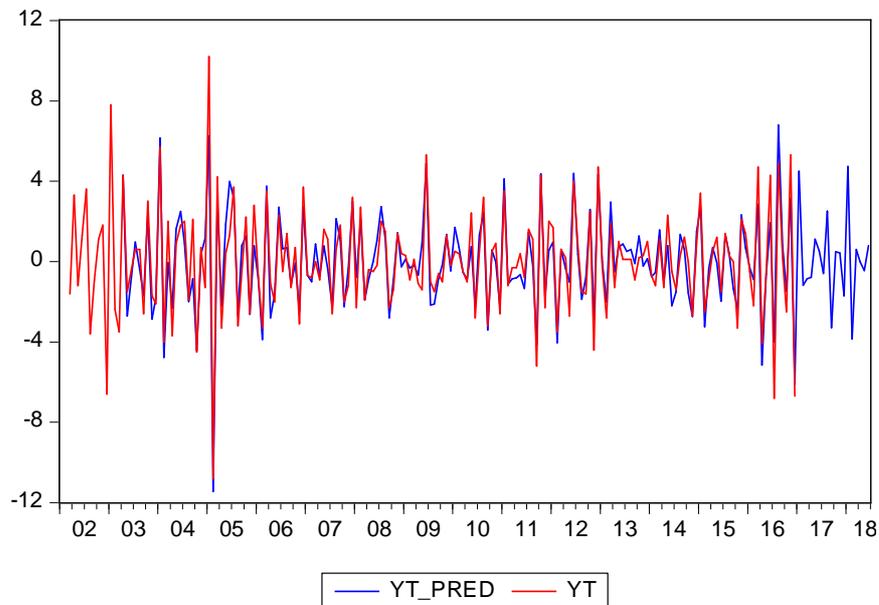


Source : l'auteur

3.2.2 Prédiction par le modèle SARIMA

Les IPC prévisionnels janvier 2017–juin 2018 générés par ce modèle sont représentés par le graphe ci-dessous [fig 8]. Les valeurs de performance de ce modèle sont : RMSE=1.03 MAE=0.77 et $R^2=0.82$.

Fig.8 Prédiction de YT par le modèle SARIMA



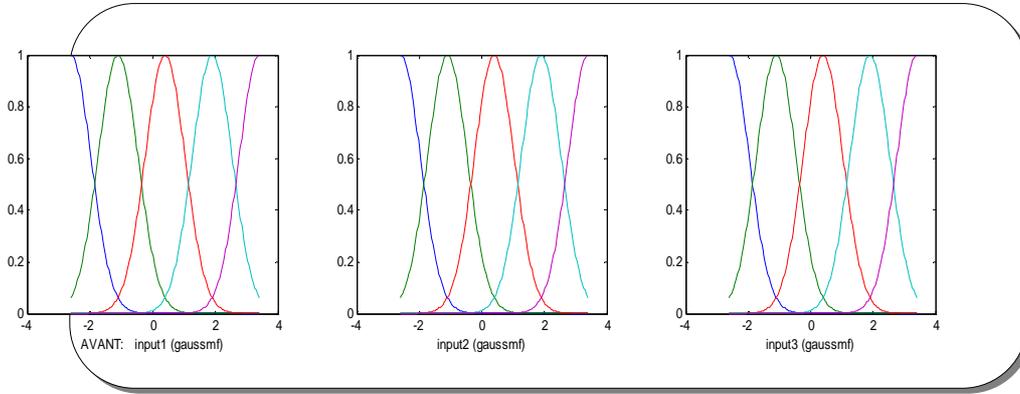
Source : l'auteur

3.3 LE MODELE ANFIS

La partition de l'univers des données $U [-2.6 \ 3.4]$ a été effectuée au départ par la méthode heuristique. On en a fixé cinq classes u_i d'amplitudes identiques. La fonction d'appartenance choisie a été la fonction triangulaire « trimf » ou la fonction gaussienne « gaussmf ». Il en a résulté 5 SEF.

Après avoir fixé l'ordre 'k' de la relation entre les variables par l'erreur minimale de prédiction à 2. Les triplets de données X^k , ont constitué les inputs du modèle ANFIS. Les MF des inputs avant ajustement sont illustrés dans le graphe ci-dessus (fig . 9).

Fig . 9 MF des inputs avant ajustement



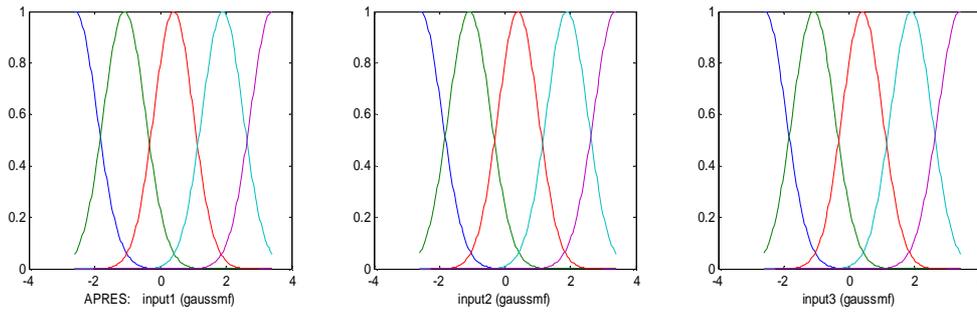
Source : l'auteur

Après la fuzzification des inputs à travers les MF, on a procédé à la multiplication des index obtenus dans la couche ' π ' pour obtenir les poids des règles d'inférence ; une fois la normalisation des poids effectués, on a procédé au calcul de la somme des moyennes pondérées des règles d'inférence qui a constitué l'output final prédit $\hat{\pi}_i$. Durant la procédure d'entraînement aussi bien les paramètres « prémisses » des MF que les paramètres « conséquents » des règles d'inférence ont été ajustés par l'algorithme BP-LMS afin de minimiser l'erreur de prédiction.

Les MF des inputs après ajustement sont présentées ci-dessous.

fig.10 MF des inputs après ajustement





Les paramètres de notre modèle ANFIS 3 sont résumés dans le tableau ci-dessus:

Tab.3. Paramètres du modèle ANFIS 3

PARAMETRES	Anfis 3	
	trim	gauss
# MF	5	5
# paramètres linéaires	500	500
# paramètres non linéaires	45	30
# total des paramètres	545	530
# règles	125	125
# nodes	286	286
training data pairs	177	177
checking data pairs	0	0
# epochs	10	10
error tolerance	0	0

Source : l'auteur

Après entraînement des données par l'algorithme 'BP-LMS' dans le cadre du système flou de type TS, les prédictions des outputs ont été déterminées. Le

tableau ci-après résume les performances du modèle ANFIS 3 selon que les MF sont de type 'trimf' ou 'gaussmf'

Tab.4. Performance des 2 versions du modèle ANFIS 3

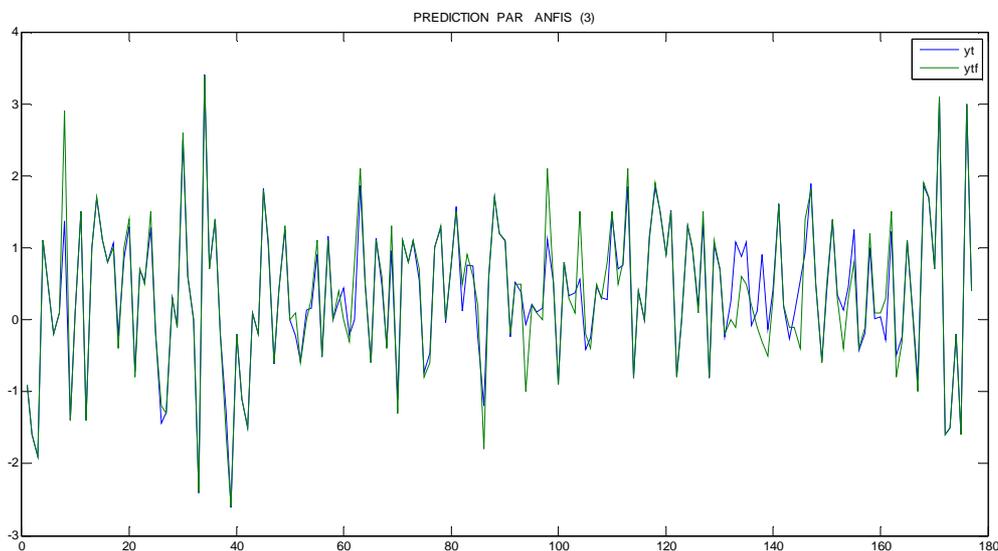
critères de performance	Anfis 3	
	trimf	Gaussmf*
MAE	0.1917	0.1365
RMSE	0.0866	0.0787
R ²	0.95	0.96

Source : l'auteur

3.3.1 Prédiction par le modèle ANFIS

Le graphe ci-dessous illustre la bonne qualité d'ajustement des données par le modèle ANFIS.

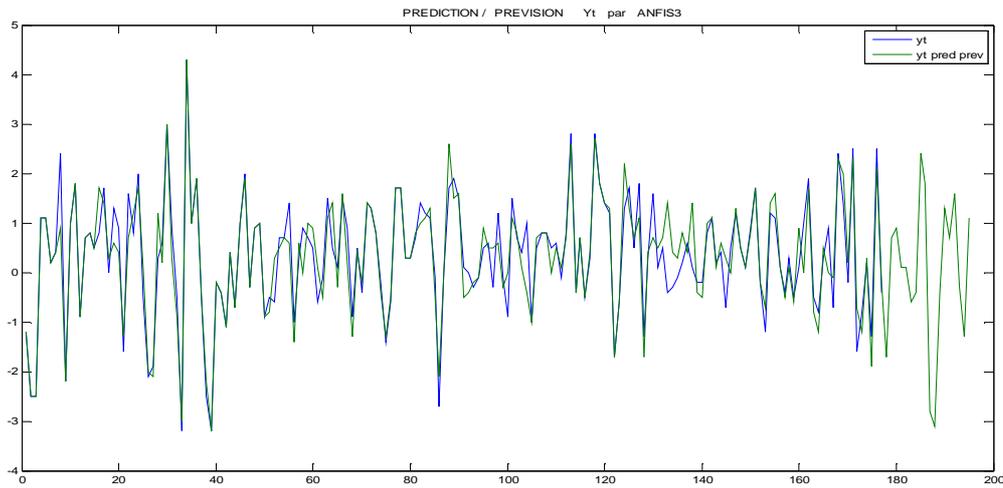
fig.11 Prédiction du modèle par ANFIS



3.3.2 Prévission par le modèle ANFIS

Le graphe ci-dessous illustre les prévisions des IPC durant la période 2016 :01 - 2018 :06.

fig.12 Prévission du modèle par ANFIS



Source :

l'auteur

4. DISCUSSION

Dans le cadre de notre étude et d'après les résultats des critères de performance retenus, le modèle

ANFIS est plus performant que les modèles SARIMA et ANN (tab. 5). Les modèle SARIMA

s'avère le moins compétitif.

Tableau 5 Performance comparée du modèle FFNN

Variante	RMSE	MAE	R ²
SARIMA	1.03	0.78	0.82

FFFN1	0.37	0.52	0.54
FFFN2	0.40	0.45	0.63
FFFN3	0.48	0.56	0.66
ANFIS*	0.07	0.13	0.96

Source :

l'auteur

5. CONCLUSION

Dans le cadre de notre tentative de modélisation des IPC en Algérie, le modèle mixte ANFIS s'est révélé plus compétitif que les modèles statistiques SARIMA et ANN.

La faiblesse des modèles SARIMA serait liée à leur hypothèse fondamentale de linéarité incompatible avec la nature non linéaire des séries économique-financières. La moindre performance des modèles ANN serait due à leur caractéristique de modèles purement numériques dépourvues de toute assise théorique contrairement aux modèles de logique flou FL.

La combinaison des modèles numériques ANN au modèle théorique FL dans le cadre du modèle ANFIS a abouti, dans le cas de notre étude, à une meilleure performance et semble prometteuse. Aussi, nous nous orienterons prochainement vers l'étude de nouvelles mixtures à l'instar des modèles flous -neuronaux 'FNS' (Lin & Lee, 1996) et des modèles 'mixtes' SANFIS (Lee, 2000),...

6. BIBLIOGRAPHIE

Office National des STATISTIQUES (2017), Collection statistique n° 259, Juillet 2017, Algérie.

- Moshiri S. and Cameron N. (2000). NN versus econometrics models in forecasting inflation, *Journal of forecasting*, 19,201-207.
- Nakamura E. (2004). Inflation forecast using neural network, *Economics Letters*, 373-378.
- Neves L.D. (2007). Forecasts inflation and NARMAX models, VII encontro brasileiro de finanças.
- Hu T.F., Luja U.G., SU H.C. and Chang C.C. (2007). Forecasting inflation under globalization with ann-based thin and thick models, *Wcecs*.
- Duzgun R. (2010). GRNN for inflation forecasting, *International journal of research of finance and economics*, 51.
- Sztandera L. M., Celia Frank C., Vemulapalli B. & Raheja A. (2003). A Fuzzy Forecasting Model for Apparel Sales, United State department of commerce/ National Textile Center, USA.
- Malek, S. A. (2010). Comparison between Neural Network Based and Fuzzy Logic Models for Chlorophyll-a Estimation. [2010 Second International Conference on Computer Engineering and Applications](#), Indonesia
- Xi C.** (2013). *Artificial Neural Network and Fuzzy Logic in forecasting short-term Temperature*, Erihe, Telemark university college, faculty of technology.
- Vasile O. E. (2008). contribution au pronostic des défaillances par réseau neuro-flou : maîtrise de l'art de prédiction, thèse de doctorat en automatique, UFR des sciences et techniques de l'université de Franche-Comté.
- Keskin M. E. Taylan D & Terzi O. (2010). Adaptive neural based fuzzy inference system (ANFIS): approach for modeling hydrogical time series, *hydrogical sciences journal*, 51:4, 588-598.

Tektas M. (2010). Weather forecasting using ANFIS and ARIMA models, environment research, engineering and management,1(51), 5-10.

Lotfi E. & Karimi M. R. (2014). OPEC oil price prediction using Anfis, journal of mathematics and computer science, 10, 286-296.

Refenes A. N., Zapranis A. & Francis G. (1994). Stock performance and neural network a comparative study with regression models. Neural Networks, 7(2), pp.375-388.

Zadeh L. A. (1965). Fuzzy sets, information and control. Vol 8, pp. 338-353.

Mahabir C. (2003). Application of Fuzzy Logic to forecast seasonal runoff. Hydrological Process. Vol. 17(1), pp. 3749-3762.

Mehrotra K., Mohan C. K. & Ranka S. (1997). Elements of artificial neural networks, MIT Press, Vol. 71.

Hurlin C. (2014). *Cours d'économétrie appliquée: séries temporelles*, université Paris Dauphine, chap. 2, p.78.

Jang J-S R. (1991). Rule extraction using Generalized neural network. Proc. of 4th IFSA world congress, volume of artificial intelligence, 82-86.

Jang J-S R. (1993). Adaptative Neural Fuzzy Inference System, IEEE Journal, vol.23(3), pp.665-685.

Jang J-S R. (1993). Functionnal equivalence between RBFN and FLS, IEE Trans Neural Networks, vol.4(1), pp. 156-159.

Lin C. T. & Lee G. (1996). Neural Fuzzy Systems : a neuro-fuzzy synergism to intelligent systems. Editions Prentice Hall.

Lee G. & Wang J-S. (2000). SANFIS : structure and learning. IEE/RSJ, International Conference on intelligent robots and system.