

MODELES DE PREVISIONS NEURONAUX VS STATISTIQUES

Bourioune T
Université de Sétif
wbourioune@yahoo.fr

Résumé:

Le but de l'article est de comparer le modèle de prévision statistique SARIMA aux modèles RNA. L'objet porte sur les taux d'inflation de l'Algérie durant la période 1997:01–2009:04. Les résultats révèlent que les modèles RNA sont plus compétitifs et paradoxalement, parmi ces derniers, les modèles statiques élémentaires sont plus performants.

Mots clés : RNA, Taux d'inflation, SARIMA, FFNN, GRNN, RBFN, TDNN, NNARMAX

Abstract ;

The purpose of this article is to compare the statistical forecast model SARIMA to the neuronal models (ANN). The subject deals with the inflation rate of Algeria during the period 1997:01 – 2009:04. The results reveal that the models ANN are more competitive and paradoxaly among these, basic static models are more efficient.

Key words: ANN, Inflation Rate, SARIMA, FFNN, GRNN, RBFN, TDNN, NNARMAX

1. Introduction

L'inflation est de retour en Algérie. Elle serait, au premier trimestre 2009, la plus élevée du Maghreb (6,1% selon l'ONS)¹. Une prévision efficace des IPC permettrait de se prémunir des effets néfastes de celle-ci en élaborant des politiques anti-inflationnistes convenables.

L'hypothèse fondamentale de linéarité des modèles paramétriques traditionnels serait à l'origine de leur faible performance dans le traitement des séries économiques de nature souvent non linéaire².

De récents modèles, basés sur les réseaux de neurones artificiels (RNA), semblent prometteurs. Ce sont des modèles adaptatifs, exploratoires, non paramétriques, non linéaires, capables d'approximer n'importe quelle fonction continue et de prévoir un futur output. Les résultats encourageants obtenus par l'application des modèles RNA dans certains travaux de prévision financière (actions en bourse, taux de change,...)³ ont incité dernièrement à leur expérimentation en macro économie.

S'inscrivant dans ce cadre, notre travail consiste à prédire le taux d'inflation en Algérie en utilisant des modèles RNA : d'abord statiques (FFNN, RBFN, GRNN,...) puis dynamiques (TDNN, NNARMAX,..) ; ensuite, à comparer la performance en prévisibilité de ces modèles avec celle des modèles traditionnels notamment SARIMA(p, d, q)(s, P, D, Q). Les critères retenus pour la performance des prévisions sont le RMSE, le MAE et R.

Les modèles RNA ont été introduits tardivement en macroéconomie, notamment dans la prévision de l'inflation.

En 1999, **Stock et Watson**⁴(USA) s'interrogèrent sur la relative performance des modèles non linéaires; ils mirent en confrontation des modèles univariés linéaires (AR, EX) avec des modèles non linéaires (LSTAR, RNA). Leurs résultats furent malheureusement non concluants. A la même date, **Moshiri et al**⁵ (Canada), en comparant divers modèles RNA (BPN, RBF, RNN) avec une panoplie de modèles statistiques (ARIMA, VAR, BVAR), conclurent à une supériorité limitée des modèles RNA.

En 2005, **Nakamura**⁶ (USA), quant à elle, aboutit à une supériorité conditionnée des modèles RNA (FFNN) relativement à AR(1) : l'horizon prévisionnel devrait, dit-elle, être de 2 trimestres au plus, la spécification simple et les procédures d'estimation spécialisées. En 2006, **Binner et al**⁷ (USA) présentèrent un nouveau modèle non linéaire hybride, le "MS-AR" (Markov Switching AutoRegressive). Il le mirent en compétition avec des modèles RNA (FFNN,...) et AR(p) et confirmèrent sa relative supériorité.

En 2008, **Neves**⁹ [Brazil], dans la classe des modèles NNARMAX, mit en rivalité le modèle neuronal NNAR contre le modèle AR et aboutit à la supériorité du premier.

En 2010, **Düzgün**¹⁰ [TURQUIE] testa le modèle neuronal GRNN qui selon lui n'a fait l'objet d'aucune publication et le mit en challenge avec le modèle ARIMA et le modèle neuronal FFNN. Les calculs plaidèrent en faveur du modèle GRNN relativement aux modèles FFNN et ARIMA.

Nos techniques de prévision se limiteront à un modèle statistique et cinq modèles neuronaux.

2. Matériels et Méthodes

2.1 Les modèles de prévision

2.1.1 Le modèle SARIMA (p, d, q) (s, P, D, Q).

Le modèle SARIMA multiplicatif (p, d, q) (s, P, D, Q) est un prolongement du modèle ARIMA (p, d, q) contenant des parties saisonnières. La représentation SARIMA¹¹ (p, d, q) (s, P, D, Q) est un processus non stationnaire qui vérifie :

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

où $\varepsilon_t \square iid(0, \sigma^2)$ (1)

$$\Phi(L) = \sum_{i=0}^p \phi_i L^i ; \quad \theta(L) = \sum_{i=0}^q \theta_i L^i$$

$$\Phi_s(L) = \sum_{i=0}^P \phi_{s,i} L^{si} \quad \theta_s(L) = \sum_{j=0}^Q \theta_{s,j} L^{sj}$$

$$L^p(X_t) = X_{t-p} \quad (1-L)X_t = X_t - X_{t-1}$$

(1-L^s)X_t = X_t - X_{t-s} p : ordre du polynome AR
 d : ordre de différenciation q : ordre du polynome MA

La prévision, dans ce cadre, ne s'effectue qu'après identification, estimation et validation du meilleur modèle¹².

2.1.2 Le modèle neuronal FFNN¹³

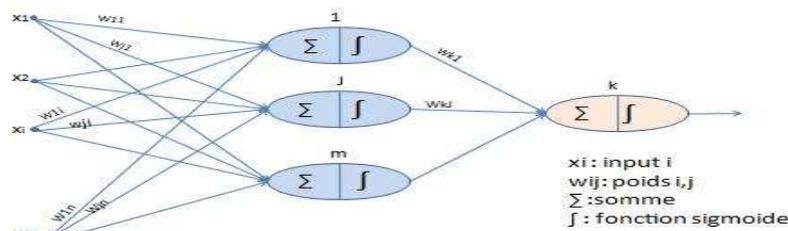
Les réseaux de neurones peuvent être classés en modèles statiques (FFNN, GRNN, RBFN, ...) et dynamiques (TDNN, NOE, NNARMAX ...). Le modèle FFNN est le modèle neuronale type. Statique, supervisé, il est originellement entraîné par l'algorithme BP. Il est souvent constitué de 3 couches : couche input, 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 est :

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

(2)

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

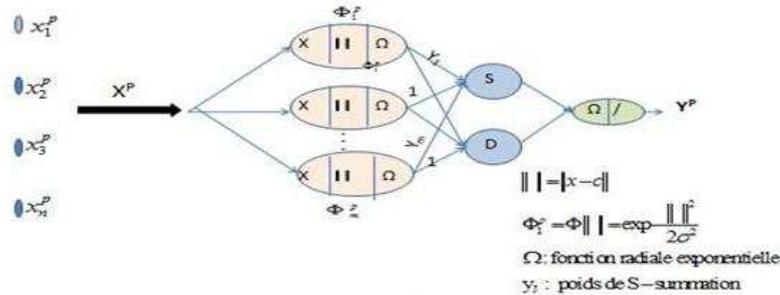


2.1.3 Le modèle neuronal GRNN¹⁴

C'est un réseau à base radiale qui ne requiert pas d'entraînement itératif. Il ne présuppose aucune forme fonctionnelle de celle-ci mais plutôt l'exprime comme un fonction de densité de probabilité (fdp) qui sera déterminée empiriquement à partir des données (X^i, Y^i) par l'estimateur non paramétrique de Parzen-Rosenblatt :

$$\hat{y}(x) = \frac{\sum_i y^i \exp\left(-\frac{D^2}{\sigma^2}\right)}{\sum_i \exp\left(-\frac{D^2}{\sigma^2}\right)} \quad \text{représentant la valeur estimée de } y \text{ sachant un vecteur } x. \quad (3)$$

fig.2 structure GRNN [n : m : 2 : 1]



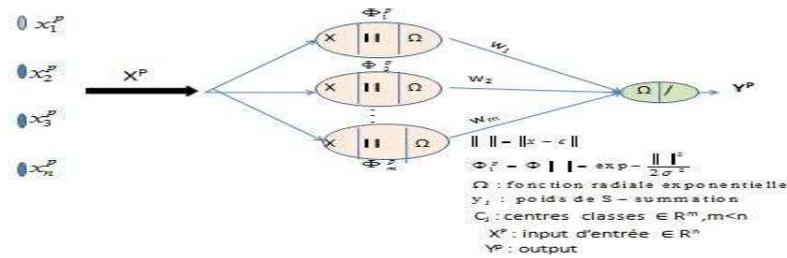
2.1.4 Le modèle neuronal RBFN¹⁵

De structure comparable à celle du FFNN, le modèle RBFN est un approximateur universel, statique, 'feedforward', mais contrairement au FFNN, il ne comporte qu'une seule couche cachée ; son processus d'apprentissage se limite aux neurones (poids) de la couche d'output ; ceci lui confère une rapidité plus grande [fig.3]. Son prédicteur est :

$$\hat{y}(t) = \Phi_2 \left[\sum_j w_{kj} \exp\left(-\frac{k}{d^2} \|x - c_i\|^2\right) \right] \quad (4)$$

Trois stratégies de learning sont utilisées dans ce modèle: la 'pseudo inverse technique', le 'gradient descent learning' et l'hybrid learning

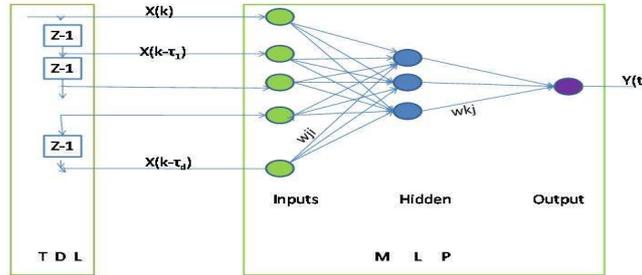
Fig.3 structure RBFN gaussien [n : m : 1]



2.1.5 Le modèle neuronal TDNN¹⁶

Le modèle TDNN est un modèle FFNN à qui est rajouté un filtre temporel TDL en input. Dans ce modèle, on se limite, contrairement aux modèles NNFIR et NNAR, à la présentation de la chronique X(t) et au choix de la dimension de la TDL qui s'occupe de l'agencement de la chronique en vecteurs retardés X(t), X(t-τ₁), X(t-τ_N).

fig.4 Structure TDNN



$$\text{Son prédicteur est } Y_j(t) = \Psi_1 \left(\sum_{i=0}^N w_{ij} \cdot x(t - \tau_i) \pm \theta_j \right) \quad (5).$$

Ce modèle, caractérisé par un filtre TDL localisé seulement en input, ne requiert pas pour son entraînement de rétro propagation dynamique (BPTT, RNTL). Il est entraîné, généralement, par l'algorithme BP.

2.1.6 Le modèle neuronal NNARMA¹⁷

En utilisant en input, seulement les outputs retardés Y_{t-i}, Les modèles FFNN et TDNN ne prennent pas en considération les erreurs retardées ε_{t-i}. Le modèle RNN avec un feedback en output à partir de (Y - Ŷ_t) s'identifie alors à un NNARMA (p,q).

Le modèle NNARMAX est un modèle ARMAX implanté dans un RNA à fonction d'activation non linéaire. Son prédicteur est :

$$\hat{y} = g[\phi(t, \theta), \theta] \quad (6)$$

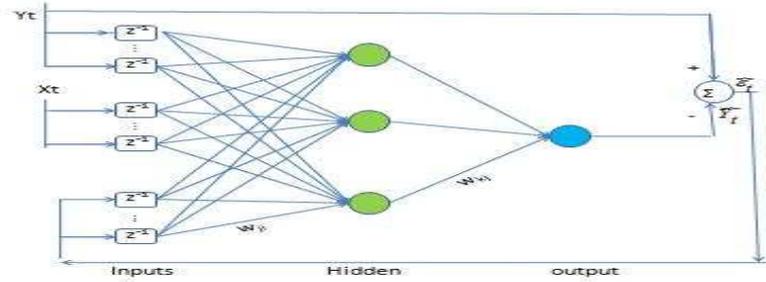
$$\phi(t, \theta) = [y(t-1), y(t-n), u(t-1), u(t-d-m), \varepsilon(t, \theta), \varepsilon(t-k, \theta)] : \text{vecteur regression ARMAX}$$

$$\theta = [-a_1, \dots, -a_n, b_1, \dots, b_m, \dots, c_1, \dots, c_k] : \text{vecteur poids}$$

g non linéaire

Les principaux algorithmes d'entraînement des réseaux récurrents sont le BPTT et le RTRL.

fig.5 le modèle NNARMAX [n :m :k :1].



2.2 Données et méthodologie

Les données sont tirées des séries «collections statistiques: IPC» publiées par l’ONS. La période totale s’étale sur 148 mois, de 1997 :01 à 2009:4; la période de prévision couvre 18 mois et s’étale de 2009 :5 à 2010 :10. Pour les modèles neuronaux, les données sont subdivisées en 3 groupes : training set (70%), validation set (15%) et testing set (15%) soient respectueusement 96, 20 puis 20 observations. Le prétraitement des données se restreint à leur désaisonnalisation.

Parce que nous considérons un horizon de court terme, nous nous contenterons des valeurs historiques du taux d’inflation $\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-k}$; $k \leq 8$ comme variables explicatives.

Les prédictions se feront à 3 horizons temporels: 1-period-ahead, 2-period-ahead et 12-period-ahead.

Les prévisions s’effectueront selon la méthode récursive, les procédures statique et dynamique. Les critères d’appréciation des prévisions sont le RMSE, MAE et R.

3. Spécifications et résultats

3.1 Le modèle SARIMA (p, d, q) (s, P, D, Q)

SARIMA(2,0,0) (12,1,0, 2); SARIMA(0,0,13) (12,3,0,3) et SARIMA(0,0,13) (12,3,0,1) sont les modèles candidats retenus par l’étude. Selon les critères de pouvoir prédictif, le meilleur modèle choisi est le modèle 2.

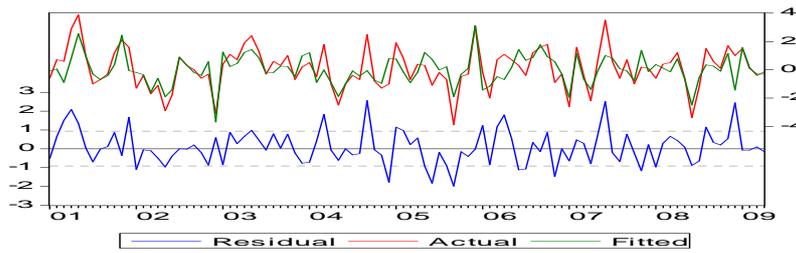
Tab.1 Performance des modèles candidats

	σ	R ²	AIC	SC
modèle 2*	0.924	0.591	-0.117	-0.013
modèle 3	0.959	0.556	-0.052	0.025

Les tests statistiques de validation confirment que : $\varepsilon_i \sim N(0, \sigma)$, ε_i iid $(0, \sigma)$, le processus AR est stationnaire et

MA est inversible. Aussi, le meilleur modèle statistique ajustant la série YTSA est SARIMA (0,0,13) X(12,3,0,3) [fig 6].

Fig.6 Ajustement de YTSA par le modèle SARIMA



Les valeurs de performance de ce modèle sont : RMSE=0.9, MAE=0.68 et R=0.769.

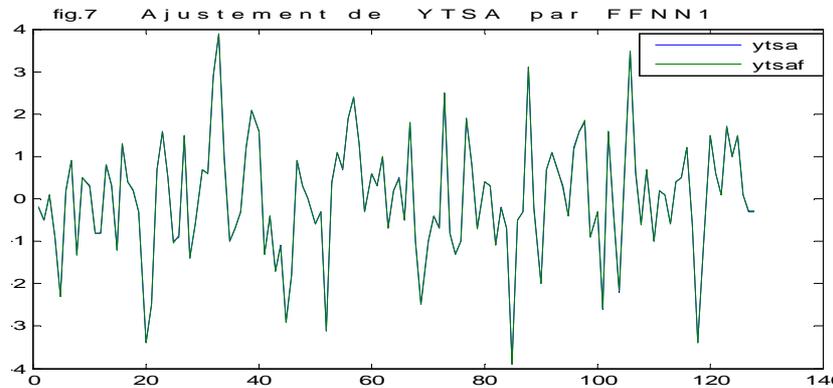
3.2 Le modèle FFNN

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. Sur la base des critères de performance retenus, le modèle FFNN1 s'avère le plus performant. Il représentera le modèle FFNN.

La figure 7 montre la qualité d'ajustement de la série YTSA par ce modèle.

Tab.2 performance des variantes FFNN

Variante	RMSE	R
FFN1	0.04	0.995
FFN2	0.19	0.994
FFN3	0.89	0.515



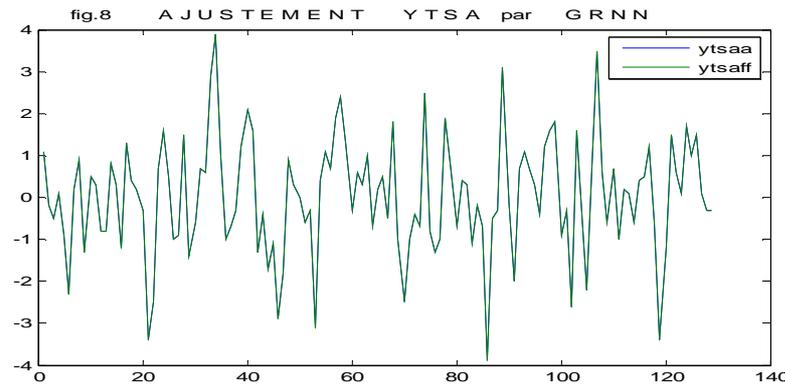
3.3 Le modèle GRNN

Sur la base des résultats obtenus et consignés dans le tableau 3, la variante π_t^{7*} [7 :7 :2:1] représentera le modèle GRNN.

Tab.3 Performance des variantes du modèle GRNN

VARIANTE	spread	RMSE	MAE	R
I_t^1	0.1	1.17	1.38	0.50
I_t^2	0.1	0.43	0.20	0.94
I_t^3	0.1	0.18	0.009	0.997
I_t^4	0.1	7.51e-4	1.4e-4	1.00
I_t^5	0.1	1.05e-7	1.31e-8	1.00
I_t^6	0.1	8.12e-16	1.03e-16	1.00
I_t^7	0.1	0	5.46e-216	1.00

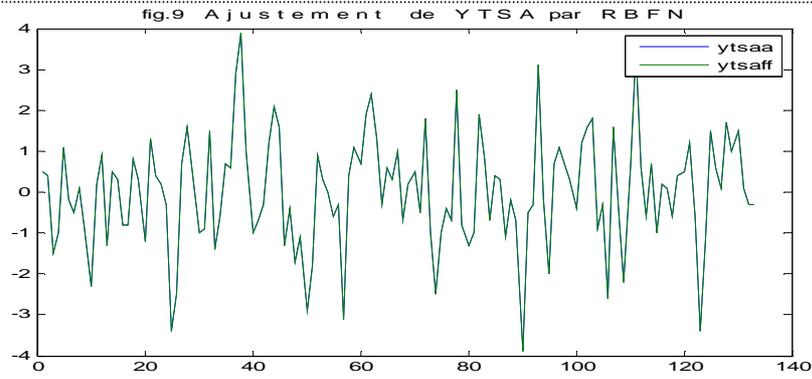
La qualité d'ajustement de la série YTSA par ce modèle est appréciée à travers le graphe de la figure 8.



3.4 Le modèle RBFN

Sur la base des résultats obtenus dans le tableau 4, la variante π_t^{3*} [133 :133 :1] représentera le modèle RBFN.

La figure 9 illustre la qualité d'ajustement de la série YTSA par ce modèle



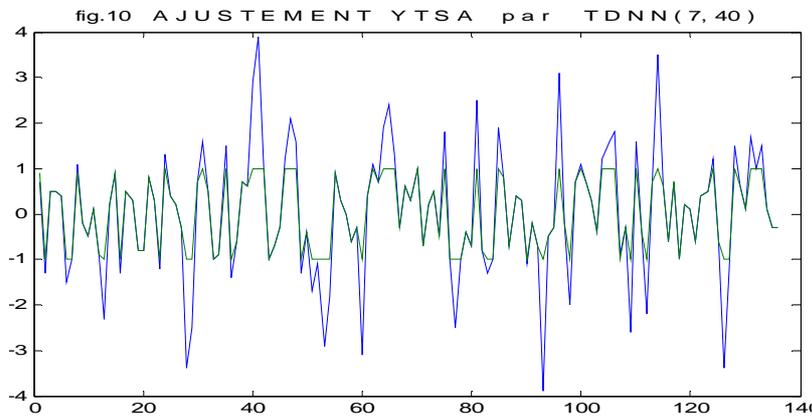
Tab.4 Performance des variantes du modèle RBFN

VARIANT TE	Nbre unités dans couche cachée	sprea d λ	RM SE	MAE	R
π_t^1	133	0.1- 0.3	1.1 1	0.79	0. 57
π_t^2	133	01-08	0.1 6	0.02	0. 99
π_t^3	133	0.3	8e- 30	2.48e- 15	1. 00

3.5 Le modèle TDNN

Sur la base des résultats obtenus et consignés dans le tableau 5, la variante π_t^{7*} [7 :40:1] représentera le modèle TDNN

La figure 10 montre la qualité d'ajustement de la série YTSA par ce modèle.

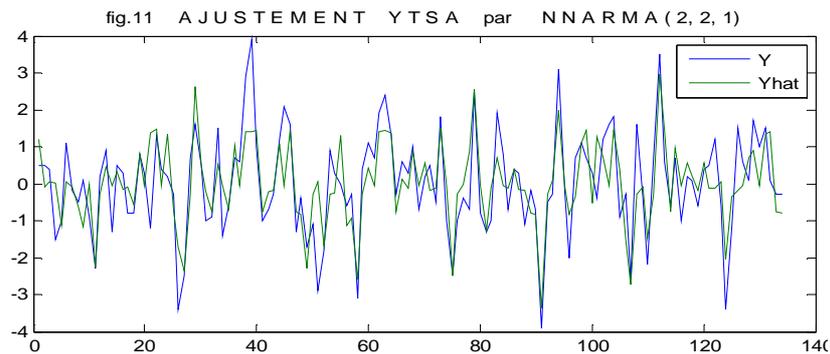


tab.5 performance des variantes du modèle TDNN

VARIANT TE	Nbre unités dans couche cachée	RMSE	R
π_t^1	35	1.174	0.213
π_t^2	40	0.818	0.464
π_t^3	35	0.774	0.498
π_t^4	40	0.752	0.515
π_t^5	35	0.756	0.509
π_t^6	40	0.751	0.509
π_t^7	40	0.744	0.514
π_t^8	40	0.745	0.513

3.6 Le modèle NNARMA

La performance de ce modèle est donnée par $MSE = 0.3858$ et $MAE=0.686$. La qualité d'ajustement de la série Y TSA par ce modèle est appréciée par la figure 11.



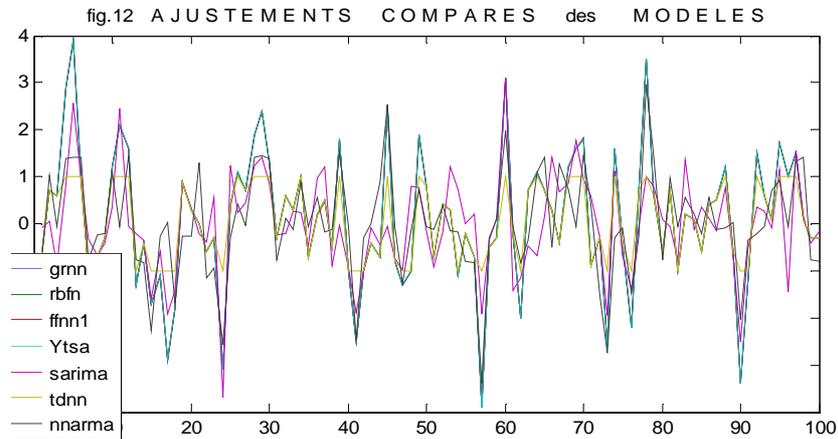
4. Discussion

Au vu des critères de performance retenus, les modèles RNA sont plus performants que le modèle statistique SARIMA (0,0,13)(12,3,0,3) et , parmi les modèles RNA, les modèles GRNN et RBFN sont les plus compétitifs [tab 6].

Tab.6 Performances comparées de tous les modèles de prévision

Variante	RMSE	MAE	R
Sarima()	0.91	0.68	0.769
FFNN1	0.04	0.01	0.995
FFNN2	0.19	0.05	0.994
FFNN3	0.89	0.99	0.515
GRNN	0	5.46e-216	1.00
RBFN	8.0e-30	2.48e-15	1.00
TDNN	0.744	0.34	0.514
NNARMA	0.621	0.34	0.97

Le graphe ci-dessous, regroupant les ajustements effectués par l'ensemble des modèles de prévision, confirme la supériorité des modèles RNA suscités.



5. Conclusion

Les modèles de prévision RNA s'avèrent être supérieurs aux modèles statistiques et paradoxalement parmi les modèles RNA, les modèles statiques et élémentaires (GRNN, RBFN, FFNN) semblent être les plus performants. Le nombre de retard encore modeste du modèle récurrent NNARMA (2, 2, 1) paraît être la raison de son déclassement.

REFERENCES :

[1] Chabane (M.), L'Algérie sous tension, les prémices d'une crise, l'urgence d'un changement, revue Averroès, n° 4-5, 2011

- [2] **Refenes (A.N.), Zapranis (A.) & Francis (G.)**, Stock performance using neural network a comparative study with regression models, *Neural Network*, vol7, n°2, 375-388, 1994
- [3] **Moshiri (S.)**, Forecasting inflation using econometrics and ann models, thesis, Manitoba university, Canada, Nov.1997
- [4] **Stock(J.H.) & Watson(M.W.)**, forecasting inflation, *Journal of monetary economics*, 44, 293-335, 1999.
- [5] **Moshiri (S.) and Cameron (N.)**, nn versus econometrics models in forecasting inflation, *Journal of forecasting* , 19,201-207, 2000
- [6] **Nakamura (E.)**, Inflation forecast using neural network, *Economics Letters*, 373-378, 2004
- [7] **Binner (J.M.) and al.**, Forecasting Euro inflation, *applied economics* ,665-680, 2005
- [8] **Hu (T.F.), Luja (U.G.), SU (H.C.) and Chang (C.C.)**, Forecasting inflation under globalization with ann-based thin and thick models, *Wcecs*, Oct 2007
- [9] **Neves (L.D.)**, Forecasts inflation and NARMAX models, VII encontro brasileiro de finanças, 2007
- [10] **Duzgun (R.)**, GRNN for inflation forecasting, *International journal of research of finance and economics*, 51, 2010
- [11] **Poo (J. R.)**, Computer-aided introduction to econometrics, Springer, p.225, 2003
- [12] **BOX (G.E.P.) & Jenkins (G.M.)**,Time Series analysis, forecast y and control, Prentice Hall, Englewood Cliffs, 1976.
- [13] **Norgaard (M.)**,Neural Network modeling and control of dynamic system: a practitioner, Springer, 2003
- [14] **Specht (D.F.)**, A general Regression Neural Network, *IEEE transactions on neural network* , Vol.2, N° 6, Nov 1991.
- [15] **Howlet (R.J.), Jain (L.C.)**, Radial Basis Function Networks 2: new advances in design, Physica- Verlag, 2001
- [16] **Fa-Long (L.)**, Digital Front-End in wirless communications and broadcasting :circuits and signal processing, Cambridge University Press, 2011
- [17] **Ljung (L.)**,System Identification:theory for user,Prentice Hall, Englewood Cliffs,1987