

Evolution de l'indice des Prix à la Consommation (IPC) en Algérie
Evolution of Consumer Price Index (CPI) in Algeria

Bourioune Tahar

Université de Sétif(Algérie) wbourioune@yahoo.fr

Reçu le:20/03/2022

Accepté le:14/06/2022

Publié le:15/07/2022

.....
Résumé :

L'objet porte sur les taux d'inflation prévus en Algérie durant la période 2021 :01-2022 :06 by différents modèles : statistiques and neuronaux. Le but de l'article est de comparer le modèle de prévision statistique SARIMA (p, d, q) aux modèles RNA. Les résultats révèlent que les modèles RNA sont plus compétitifs et paradoxalement, parmi ces derniers, les modèles statiques statistiques sont plus performants.

Abstract:

The subject deals with the inflation rate forecast in Algeria during the period 2021:01-2022:06 by different models: statistical and neuronal. The purpose of this article is to Compare the statistical forecast model SARIMA (p, d, q) to the neuronal ones. The results Reveal that the models ANN are more competitive and paradoxaly among these, the static statistical models are more efficient.

Keywords: Inflation Rate, SARIMA, FFNN, NNARMAX

1.Introduction

L'inflation revient avec force en Algérie. Elle était, en octobre 2021, la plus élevée du Maghreb (9,1% selon les données de l'ONS)¹. Une prévision efficace de celle-ci permettrait alors de se prémunir de ses effets de déstructuration socio-économique du pays en élaborant des politiques monétaires adéquates.

L'hypothèse fondamentale de linéarité des modèles paramétriques traditionnels de prévision serait à l'origine de leur faible performance dans les prévisions des séries économiques de nature souvent non linéaire (Refenes A.N., 1994)

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,...) ont incité dernièrement à leur expérimentation en macro économie. (Moshiri S. , 1997)

S'inscrivant dans ce cadre, notre travail consiste à prévoir le taux d'inflation en Algérie à fin juin 2022 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 R².

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

En 2000, Moshiri et al (*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 (Moshiri S. &., 2000).

En 2004, McNelis(USA), construisit une structure composite de modèles non linéaires appelée « trimmed ANN-based thick model » et conclut à sa supériorité relativement au modèle AR(p) (McNelis, 2004).

En 2005, Nakamura (USA), 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 (Nakamura, 2005).

En 2006, Binner et al (*USA*) présentèrent un nouveau modèle non linéaire hybride, le *'MS-AR'* (Markov Switching AutoRegressive). Ils le mirent en compétition avec des modèles RNA (FFNN,...) et AR(p) et confirmèrent sa relative supériorité (BINNER, 2006).

En 2007, Henri (Thailand) compara les modèles ANN, ES et ARIMA du point de vue performance dans la prévision des exportations du riz de Thaïlande. Les résultats révélèrent la précellence des modèles ANN dans la poursuite de la dynamique non linéaire du trend, de la saisonnalité et de leurs interactions (Henri, 2007).

En 2008, Neves (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 (Neves, 2008).

¹ Calculé par l'auteur à partir de la collection « IPC » de l'ONS, nr 331, octobre 2021.

En 2009, Binner (USA) eut l'idée de mettre au point un modèle dynamique mixte de type NNARX basé sur la méthode Kernel «the kernel recursive least square regression (KRLSR)» qu'il mit en compétition avec le modèle RNN ; les résultats montrèrent que le modèle KRLSR est plus performant en prévisibilité que le modèle RNN (Binner, Tino, Tepper, & Anderson, 2009).

En 2010, Düzgün (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 (Duzgun, 2010).

En 2013, Mehri (Iran) compara, dans la prédiction de l'éclosion chez les poules pondeuses, les modèles ANN, FL et MLR. Il conclut à la suprématie du modèle ANN (Mehri, 2013).

En 2015, Cuauhtémoc (Mexique) compara les modèles neuronaux FFNN, RBFN, GRNN au modèle de régression statistique SLR, du point de vue précision prédictive, dans le développement des projets de logiciels. Les résultats affirmèrent la supériorité des modèles ANN notamment RBFN (Cuauhtémoc, 2015).

2. Matériels et Méthodes

2.1 Les modèles de prévision

Nos techniques de prévision traiteront un modèle statistique (SARIMA) et cinq modèles neuronaux à savoir FFNN, GRNN, RBFN, TDNN et NNARMA.

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. SARIMA (p, d, q) (s, P, D, Q) est un processus non stationnaire qui vérifie : (Poo, 2003)

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

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

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

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

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

$(1-L^s)X_t = X_t - X_{t-s}$ 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 modèle selon la méthode Box-Jenkins (Box, 1976).


2.1.2 Le modèle neuronal FFNN

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 (figure 1). 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 (Norgaard, 2003).

Son prédicteur est :

$$y(t) = \Phi_2 \left\{ \sum_{j=0} w_{kj} \left[\Phi_1 \left(\sum_{i=0} w_{ji} x_i + w_{j0} \right) \right] + w_{k0} \right\} \quad (2)$$

Graphique N°1 : structure FFNN [n :m :1]

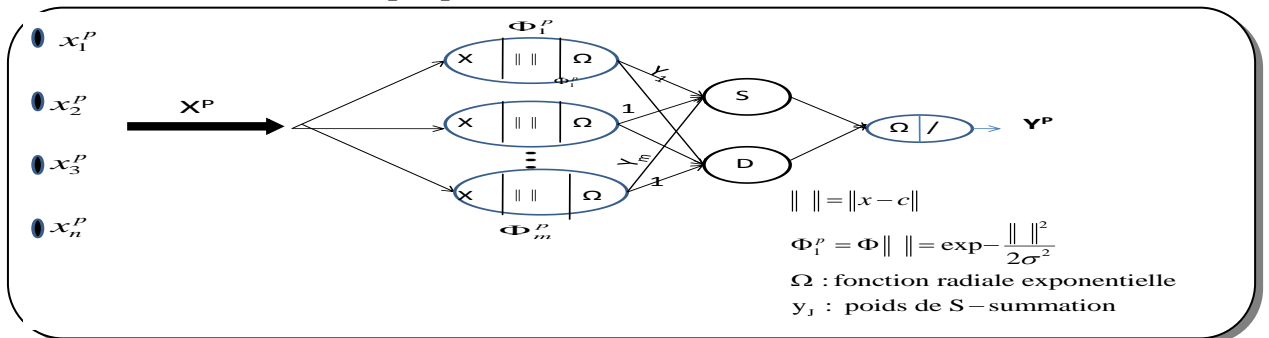


Source : fait par l'auteur

2.1.3 Le modèle neuronal GRNN

C'est un réseau à base radiale qui ne requiert pas d'entraînement itératif [figure2]. 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 (Specht, 1991):

Graphique N°2 : structure GRNN [n :m :2 :1]



Source : fait par l'auteur


2.1.4 Le modèle neuronal RBFN

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 [figure 3]. Son prédictor est (Howlet, 2001):

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

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

Graphique N°3 : structure RBFN gaussien [n : m :1]

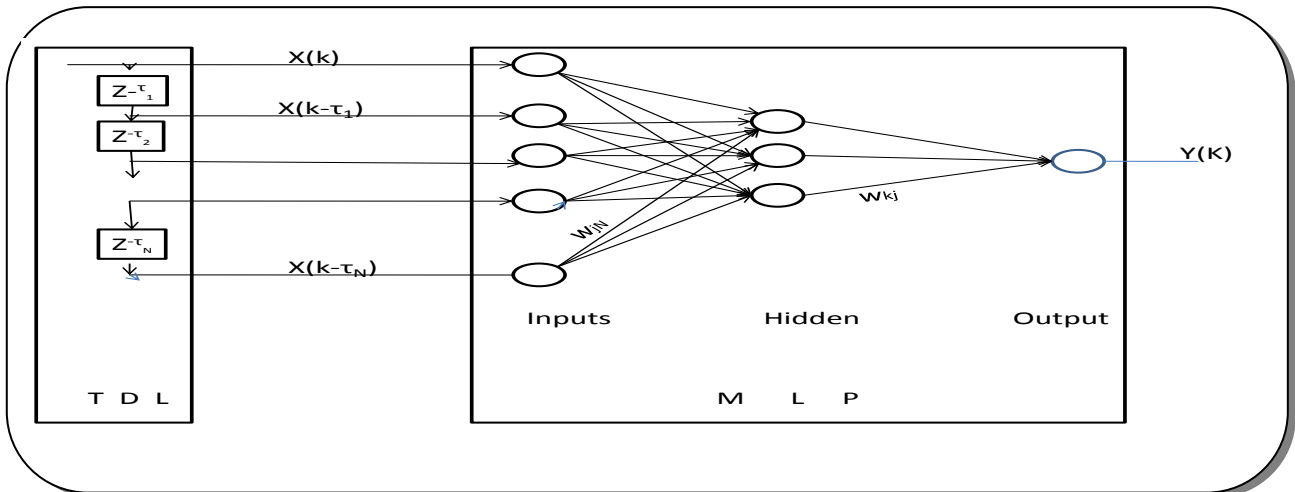


Source : fait par l'auteur

2.1.5 Le modèle neuronal TDNN

Le modèle TDNN est un modèle FFNN à qui est rajouté un filtre temporel TDL en input [figure 4]. 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 $X(t)$, $X(t-\tau_1)$, $X(t-\tau_N)$ (Fa Long, 2011).

Graphique N°4 : Structure TDNN



Source : fait par l'auteur

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

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 NNARMA

En utilisant en input, seulement les outputs retardés Y_{t-i} , Les modèles FFNN et TDNN ne prennent pas en considération les erreurs retardées e_{t-i} . Le modèle RNN avec un feedback en output à partir de $(Y - \hat{y}_t)$ 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 [figure 5]. Son prédicteur est : (Ljung, 1987)

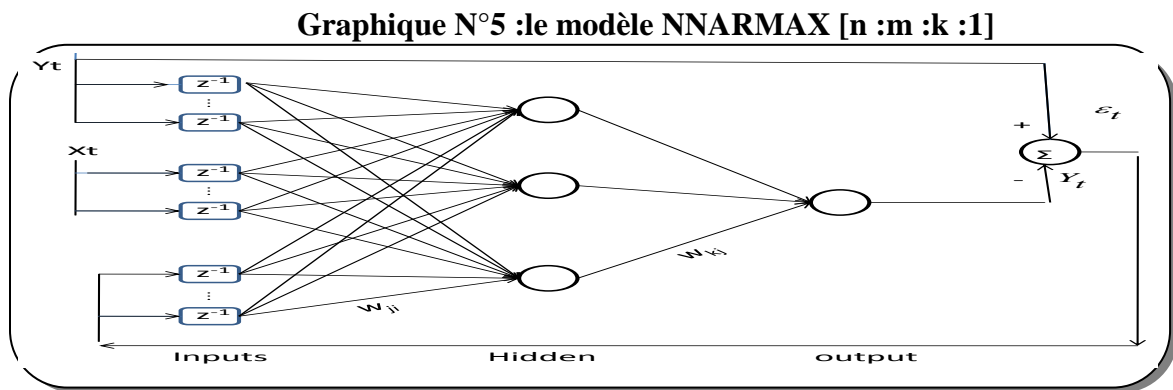
$$y = g[\varphi(t, \theta), \theta] \quad (6)$$

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

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

g : non linéaire

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



Source : fait par l'auteur

2.2 Données et méthodologie

Les données sont tirées des séries «collections statistiques: IPC» publiées par l'ONS. (ONS, 2020) La période totale s'étale sur 228 mois, de 2002 :01 à 2020:12; la période de prévision couvre 18 mois et s'étale de 2021 :01 à 2022 :06. Pour les modèles neuronaux, les données sont *subdivisées* en 3 groupes : training set (70%), validation set (15%) et testing set (15%) soient respectueusement 160, 34 puis 34 observations. Le prétraitement des données se restreint à leur dessaisonnalisation.

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^2 .

Les logiciels utilisés sont Matlab 2011a et Eviews 9. Nous déterminons maintenant les meilleures variantes représentatives des six modèles.

3. Spécifications et résultats

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


Sarima(22,0,4)(12,2,0,2); Sarima(11,0,27)(12,0,0,0) et Sarima(47,0,4) (12,2,0,2) sont les modèles candidats retenus par l'étude. Selon les critères de pouvoir prédictif, le meilleur modèle choisi est le modèle 3.

Tableau (1) Performance des modèles candidats

	σ	R^2_{adj}	AIC	SC
Modèle 1	0.69	0.27	2.27	2.46
Modèle 2	0.73	0.17	2.32	2.47
Modèle 3*	0.68	0.29	2.25	2.48

Source : à partir des résultats d'evIEWS 9

Les tests statistiques de validation confirment que les résidus e_i sont iid $N(0,\sigma)$; le processus AR est stationnaire et MA est inversible [annexe 1,2 et 3]. Aussi, le meilleur modèle statistique ajustant la série YTSA est SARIMA (47,0,4) (12,2,0,2). La figure 6 ci-dessous illustre la prédiction d' Y_t par ce modèle.

Graphique N°6 :Prédiction de Y_t par le modèle SARIMA

Source : graphique evIEWS 9

Les valeurs de performance de ce modèle sont : RMSE=0.81, MAE=0.65 et $R^2=0.29$.

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 [tableau 2], le modèle FFNN1 s'avère le plus performant. Il représentera le modèle FFNN. La figure 7 montre la qualité d'ajustement de la série Y_t par ce modèle.

Tableau (2) performance des variantes FFNN

Variante	RMSE	MAE	R
FFNN1	0.40	0.48	0.34
FFNN2	0.59	0.61	0.30
FFNN3	0.47	0.56	0.42

Source : à partir des résultats de matlab 2011a

Graphique N°7 : Prédiction de Yt par le modèle FFNN1



Source : graphique matlab 2011a

3.3 Le modèle GRNN

Sur la base des résultats obtenus et consignés dans le tableau 3, la variante $\pi_t^{8^*}$ [8 :2:1] représentera le modèle GRNN.


Tableau (3) Performance des variantes du modèle GRNN

VARIANTE	spread	RMSE	MAE	R ²
I _t ¹	0.1	0.60	0.63	0.29
I _t ²	0.1	0.22	0.34	0.83
I _t ³	0.1	0.017	0.048	0.98
I _t ⁴	0.1	6.00e-4	4.1e-3	0.99
I _t ⁵	0.1	2.53e-8	1.94e-5	0.999
I _t ⁶	0.1	7.66e-12	2.62e-7	0.999
I _t ⁷	0.1	8.92e-22	3.66e-12	0.999
I _t ^{8*}	0.1	4.88e-25	6.61e-14	0.999

Source : à partir des résultats de matlab 2011a

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

Graphique N°8 : Prédiction de Yt par le modèle GRNN



Source : graphique matlab 2011a

3.4 Le modèle RBFN

Sur la base des résultats obtenus dans le tableau 4, la variante π_t^{7*} [7 :221 :1], $\lambda=0.5$ représentera le modèle RBFN.

La figure 9 illustre la qualité de prédiction de la série Y_t par ce modèle.




Tableau (4) Performance des variantes du modèle RBFN


VARIANTE	Nbre unités cachée	couche	spread λ	MSE	MAE	R^2
π_t^1	227		0.1	0.35	0.45	0.67
π_t^2	226		01	9e-4	3.5e-3	0.99
π_t^3	225		0.1	3.7e-13	1.43e-6	0.99
π_t^4	224		0.2	5.6e-30	7.64e-16	0.99
π_t^5	223		0.2	1.1e-30	1.55e-15	0.99
π_t^6	222		0.4	9.1e-31	6.81e-16	0.99
π_t^{7*}	221		0.5	7.2e-31	6.12e-16	0.99
π_t^8	220		1.1	8.8e-31	6.16e-16	0.99

Source : à partir des résultats de matlab 2011a

3.5 Le modèle TDNN

Sur la base des résultats obtenus et consignés dans le tableau 5, la variante π_t^{8*} [8 :25:1] représentera le modèle TDNN. La figure ci-dessous montre la qualité d'ajustement de la série Y_t par ce modèle.

Graphique N°10 : Prédiction de la série Yt par le modèle TDNN(8,25)



Source : graphique matlab 2011a

Tableau (5) performance des variantes du modèle TDNN


VARIANTE	Nbre unités de couche cachée	MSE	MAE	R ²
π_i^1	40	0.49	0.53	0.37
π_i^2	40	0.28	0.39	0.63
π_i^3	40	0.03	0.10	0.96
π_i^4	40	2.31e-5	1.9e-3	0.9
π_i^5	40	1.83e-12	9.54e-7	0.9
π_i^6	40	6.92e-12	1.70e-6	0.9
π_i^7	40	8.55e-14	2.16e-7	0.9
π_i^{8*}	25	1.03e-14	6.93e-8	0.89

Source : à partir des résultats de matlab 2011a

3.6 Le modèle NNARMA

La performance de ce modèle est donnée par RMSE = 0.46, MAE=0.52 et R²=0.28. La qualité de prédiction de la série Yt par ce modèle est appréciée par la figure 11.

Graphique N°11 :Prédiction 1-step ahead de YTSA par NNARMA (2,2,1)



Source : graphique matlab 2011a

4. Discussion

Au vu des critères de performance retenus, les modèles RNA sont plus performants que le modèle statistique SARIMA (47,0,4)(12,2,0,2) et parmi les modèles RNA, les modèles statiques « statistiques » GRNN et RBFN sont les plus compétitifs [tableau 6].


Tableau (6) Performances comparées de tous les modèles de prévision

Variante	RMSE	MAE	R ²
Sarima()	0.81	0.65	0.29
FFNNI	0.40	0.48	0.34
GRNN	4.88e-25	6.66-14	0.98
RBFN	7.21e-31	6.11e-16	0.98
TDNN	1.03e-14	6.93e-8	0.98
NNAR	0.27	0.41	0.45
NNARMA	0.46	0.52	0.28

Source : à partir des résultats de matlab 2011a

Le graphe ci-dessous, regroupant les prédictions effectués par la quasi-totalité des modèles de prévision, confirme la supériorité des modèles RNA suscités.

Graphique N°12 :Prédictions comparées des modèles



Source : graphique matlab 2011a

Nos résultats de supériorité des modèles RNA et notamment RBFN et GRNN s'accordent bien avec ceux de la majorité des auteurs revus en littérature et plus précisément, ceux de Düzgün (2010) et Cuauhtémoc(2015).

Selon les prévisions comparées des modèles étudiés (Tableau 7 ici-bas), les prévisions du taux d'inflation de la plupart de nos modèles sur la période 2021 :01 - 2022 :06 semblent être concordantes entre elles et avec les données réelles du taux d'inflation publiées par (ONS, 2021) (ytf_ons ci-dessous).


Tableau (7) Prévisions comparées des modèles

Date	01/21	02/21	03/21	04/21	05/21	06/21	07/21	08/21	09/21
ytf_sarima	1.255	0.399	0.789	0.751	-0.125	-0.795	0.028	0.823	1.100
ytf_rbfm	1.019	0.168	0.432	0.100	-0.269	-0.230	-0.349	0.546	0.573
ytf_nnarma	0.925	0.320	0.312	-0.183	-0.383	-0.263	-0.335	0.454	0.384
ytf_ons	1.400	0.700	1.200	1.300	0.500	-1.100	1.00	1.00	2.5
Date	10/21	11/21	12/21	01/23	02/23	03/23	04/23	05/23	06/23
ytf_sarima	1.492	-0.321	-0.870	1.081	0.327	0.740	0.970	0.430	-0.700
ytf_rbfm	0.738	-0.079	-0.444	0.689	0.040	0.571	0.988	-0.210	-0.327
ytf_nnarma	0.440	-0.266	-0.699	0.633	0.285	0.753	0.660	0.047	-0.133
ytf_ons	1.10								

Source : à partir des résultats de matlab 2011a

Au vu du graphe ci-dessous, nous observons des pics d'inflation en Janvier et Septembre/Octobre 2021 et des creux en Juin/Juillet et Décembre 2021.

Graphique N°13 :Prévisions comparées des modèles



Source : graphique matlab 2011a

5. Conclusion :

Selon notre étude, d'une part, les modèles RNA se révèlent plus compétitifs que le modèle statistique SARIMA et paradoxalement, parmi les modèles neuronaux, les modèles statiques élémentaires (GRNN, RBFN) sont les plus performants. Bien que le modèle récurrent NNARMA (2, 2,1) ait pris en compte, dans son architecture et ses calculs, les résidus retardés e_{t-i} , ses résultats se montrent relativement moins bons ; Ceci serait lié au nombre encore modeste de ses retards. D'autre part, les taux d'inflation prévus par ces modèles sont concordants entre eux et avec les taux d'inflation réels de 2021 publiés par l'ONS. Le taux d'inflation annuel à juin 2022 serait selon nos estimations de 8.54%.

6. Références :

1. BINNER, J. (2006). Forecasting Euro inflation. *applied economics* , 665-680.
2. Binner, J., Tino, P., Tepper, J., & Anderson, R. (2009). Does money matter in forecasting inflation? *Research Division, Federal Reserve Bank of St Louis, Working Paper* .
3. Box, G. &. (1976). *Time Series Analysis, forecasty and control*. Prentice Hall, Englewood Cliffs.
4. Cuauhtémoc, L. (2015). Predictive accuracy comparison between neural networks and statistical regression for development effort of software projects. *Applied Soft Computing* , V7 pp.434-449.

5. Duzgun, R. (2010). GRNN for inflation forecasting. *International Journal of Research of Finance and Economics* , 51.
6. Fa Long, L. (2011). *Digital Front-End in wireless communication and broadcasting circuits an signal processing* . Combridge University Press.
7. Henri, C. (2007). Forecast thailand's rice export:statistical technique vs ANN. *Computers & Industrial Engineering* , 53, 4, 610-627.
8. Howlet, R. &. (2001). *Radial Basis Functions Networks 2: nex advances in design* . Physica-Verlag.
9. Ljung, L. (1987). *System Identification theory for user* . Prentice Hall, Englewood Cliffs.
10. McNelis, P. &. (2004). Forecasting inflation with thick models and neural network. *Working Paper Series* , 352.
11. Mehri, M. (2013). A comparison of NN models, FL and MLR for prediction of hatchability. *RCSDA, Zabol University,Iran* .
12. Moshiri, S. &. (2000). nn versus econometrics models in forecasting inflation. *Journal of forecasting* , 19,201-207.
13. Moshiri, S. C. (2000). nn versus econometrics models in forecasting inflation. *Journal of Forecasting* , 19 201-207 .
14. Moshiri, S. (1997). *Forecasting inflation using econometrics and ann models*. Canada: thesis, Manitoba university.
15. Nakamura, E. (2005). Inflation forecast using neural network. *Economics Letters* , PP.373-378.
16. Neves, L. (2008). Forecasts inflation and NARMAX models. *VII encontro brasileiro de finanças* , , (p. Forecasts inflation and NARMAX models).
17. Norgaard, M. (2003). *Neural network modeling and control of dynamic system:a practionner* . Springer .
18. ONS. (2020, Mai). Indice des Prix à la Consommation 2010_2019. *Collections Statistiques N° 216/ 2020 Série E : Statistiques Economiques N° 103* , pp. 33-43.
19. ONS. (2021, octobre). indices des prix à la consommation. *collections statistiques*, p. 7.
20. Poo, J. R. (2003). *Computer-aided introduction to econometrics*. Springer.
21. Refenes A.N., Z. A. (1994). stock performance using neural network a comparative study with regression models. *Neural Network* , vol 7, nr 2 pp.375-388.
22. Specht, D. (1991). A Genera Neural Network., *IEEE Transactions on Neural Network* , Vol 2 NR 6 .
23. Stock, J. &. (1999). forecasting inflation. *Journal of monetary economics* , 44, 293-335.


Annexes

Annexe1 test de non corrélation sérielle des résidus (L-B)

	AC	PAC	Q-Stat	Prob	$\chi^2_{0.95}$
12	0.052	0.076	10.412		12.59
24	-0.001	-0.005	18.235	0.076	28.87
36	0.013	-0.002	24.848	0.358	43.77

source : à partir des résultats d'Eviews 9

Annexe 2. test de normalité des résidus



source : à partir des résultats d'Eviews 9

Annexe 3. test d'hétéroscédasticité ARCH test

Independently, Residuals			
F-statistic	0.541358	Prob. F(1,225)	0.4626
Obs*R-squared	0.544859	Prob. Chi-Square(1)	0.4604

source : à partir des résultats d'Eviews 9