

## Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

### CPI estimation by non-parametric models: case of Algeria

Bourioune Tahar\*<sup>1</sup>, Chiad Fayçal<sup>2</sup>

<sup>1</sup> Bourioune Tahar, Université de Sétif, tahar.bourioune@univ-setif.dz

<sup>2</sup> Chiad Fayçal, Université de Sétif, Sétif,faycal.chiad@univ-setif.dz

**Réception :** 29/03/2022

**Acceptation:** 05/05/2022

**Publication:** 15/06/2022

#### Résumé:

Ce travail porte sur l'estimation de l'indice relatif des prix à la consommation en Juin 2022 en Algérie par différents modèles non paramétriques. Le but de ce travail est de comparer ces différents modèles de point de vue performance. Les résultats révèlent que les modèles GRNN et RBFN sont plus performants.

**Mots clés :** IPC, GRNN, RBFN

**JEL Classification Codes :** C22, C51, E17

#### Abstract :

This work focuses on the estimation of the relative consumer price index in June 2022 in Algeria by different non-parametric models. The purpose of this work is to compare these different models from a performance point of view. The results reveal that the GRNN and RBFN models perform better.

**Keywords :** IPC, GRNN, RBFN

**JEL Classification Codes :** C22, C51, E17

---

\* Auteur correspondant

## 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)<sup>1</sup>. 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, Zapranis, & Francis, 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)

Cependant, ces modèles dénommés à raison « modèles à boîtes noires » sont entachés de beaucoup d'insuffisances. Le manque d'un fondement théorique, l'incapacité à traiter les variables qualitatives et les données non fiables constituent parmi leurs principaux désavantages. Les modèles de logique floue FL basés sur la théorie des ensembles flous et la théorie des possibilités semblent surmonter les limites des modèles ANN (Zadeh, 1965). Ils prennent en considération les données linguistiques (assez fort, fort, très fort) et sont ainsi proches du langage humain. Ils permettent d'exprimer les connaissances qu'on a à priori sur un système sous forme de règles explicites. Actuellement, ils sont expérimentés dans beaucoup de domaines et semblent être relativement compétitifs. Est-ce bien le cas ? Les récents modèles FL sont-ils plus performants que les modèles ANN ?

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 du modèle flou (FL). Les critères retenus pour la performance des prévisions sont le RMSE, le MAE et R<sup>2</sup>.

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

En 2007, Henri (Thaïlande) 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).

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 2011, Ghodsi et al (Iran), construisirent des modèles de prévision des prix du marché d'électricité de la ville canadienne d'Ontario et conclurent à la supériorité du modèle neuronal FL relativement aux modèles ANN et ARIMA (Ghodsi, Zakarinia, & Jokar, 2011).

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).

---

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

## Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

En 2014, Rahmati et al (Iran) construisirent des modèles de prévision des besoins de consommation en eau de la ville de Téhéran et aboutirent à la supériorité du modèle ANFIS relativement aux modèles ARMA, ANN et MLR (Rahmati, Hadda, & Sedghi, 2014)

En 2015, Djurovic et al (Serbie) dans la prévision du niveau des eaux souterraines, aboutirent à l'équivalence des modèles ANN et ANFIS du point de vue performance (Djuravic, Domazet, & Stricevic, 2015)

En 2016, Ranjith et al (congrès mondial d'engineering de Londres) comparèrent les modèles ANFIS et ANN dans la prévision des énergies photovoltaïques (PV) et éoliennes. Ils conclurent à ce que le modèle ANN est plus performant que le modèle ANFIS dans la prévision de PV (Kuamr & Kalvathi, 2016).

Au vu de cette revue de la littérature, il semble qu'il n'y a pas unanimité quant à la précellence d'un modèle ; ceci justifie notre recherche.

## 2 Matériels et Méthodes

### 2.1 Les modèles de prévision

Nos techniques de prévision traiteront le modèle flou (FL) et cinq modèles neuronaux à savoir FFNN, GRNN, RBFN, TDNN et NNARMA.

#### 2.1.1 Le modèle flou (FL)

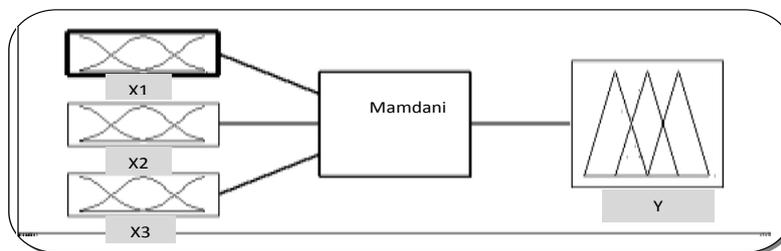
En s'appuyant sur les notions de base du modèle FL (Buckley, 2002), (Sivanandam & Sumathi, 2007), nous exposerons d'abord sa structure, son architecture puis la méthodologie de prévision.

Le modèle FL est constitué de 3 couches : input, inférence et output (figure 1).

Les données  $X_i$  sont présentées, après leur « fuzzification », à la couche inférence qui comprend les règles floues constituées des opérateurs « ou, et, ... ». Dans la couche d'inférence, on procède à l'opération floue d'« implication » puis d'« agrégation ». A l'issue de l'opération de « défuzzification », l'output final «  $Y_j$  » est enfin déterminé. Les différents opérateurs logiques relèvent des principaux types d'inférence : Mamdani ou Sugeno.

Les fonctions triangulaire, trapézoïdale, gaussienne,.... constituent les principales fonctions d'appartenance

Fig.1 structure du modèle FL



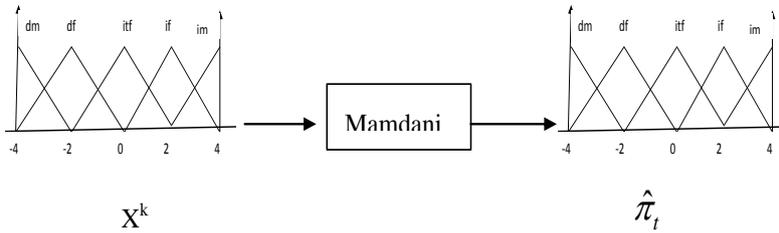
Source : Matlab

#### 2.1.1.1 Architecture du système

L'ensemble des valeurs explicatives  $\{\pi_{t-1}, \pi_{t-2}, \dots, \pi_{t-k}\}$  constitue le vecteur input  $X^k$  /  $k \leq 8$ ; le nombre décalage  $k$  est déterminé par la variante FFNN du modèle ANN. L'output  $\hat{\pi}_t$  constitue la valeur prédite de la valeur actuelle de l'IPC  $\pi_t$ . Le type d'inférence appliqué est celui de Mamdani (Nguyen, 2006), L'output  $\hat{\pi}_t$  est

calculé à l'issue des opérations d'agrégation par la méthode de la « coupure » et de défuzzification par la méthode « centroïde ». L'architecture du système est présentée dans la figure 2.

Fig.2 Architecture du modèle FL



Source : fait par l'auteur

2.1.1.2 Méthodologie de prévision

Les prévisions s'effectuent par inférence « Mamdani » selon la méthode RMSNN, les procédures statique et dynamique. Les critères d'appréciation des prévisions sont le RMSE, MAE et R<sup>2</sup>. La période de prévision s'étale de 2021:01 à 2022:06. Les prédictions se feront au plus à 8-step-ahead

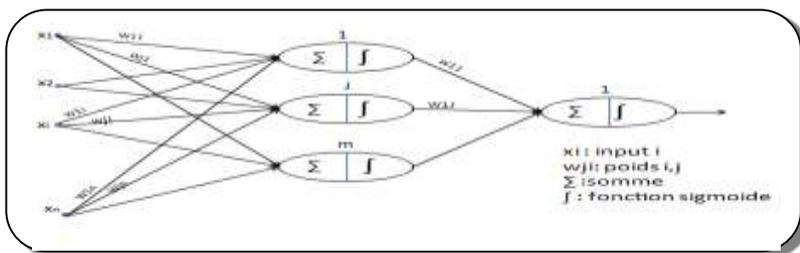
2.1.2 Le modèle neuronal FFNN

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 3). 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 :

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

Fig.3 Structure FFNN [n :m :1]



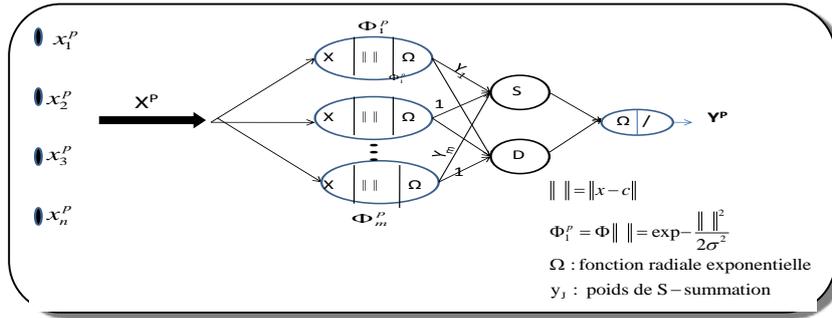
Source : fait par l'auteur

2.1.3 Le modèle neuronal GRNN

C'est un réseau à base radiale qui ne requiert pas d'entraînement itératif [figure4]. Il ne présuppose aucune forme fonctionnelle de celle-ci mais plutôt l'exprime comme une fonction de densité de probabilité (fdp) qui sera déterminée empiriquement à partir des données (X<sup>i</sup>, Y<sup>i</sup>) par l'estimateur non paramétrique de Parzen-Rosenblatt (Specht, 1991):

# Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

Fig.4 structure GRNN [n :m :2 :1]



Source : fait par l'auteur

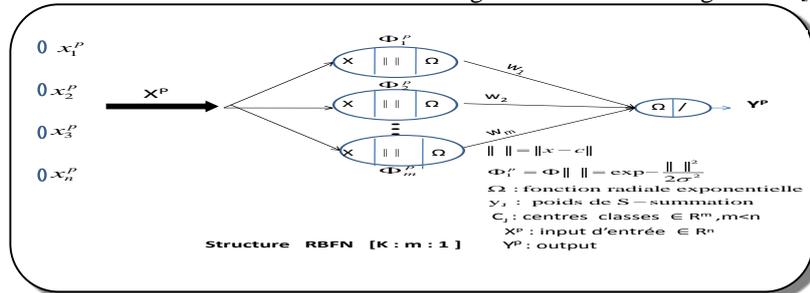
## 2.1.4 Le modèle neuronal RBFN

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 5]. Son prédicteur 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.

Fig. 5 structure RBFN gaussien [n :m :1]

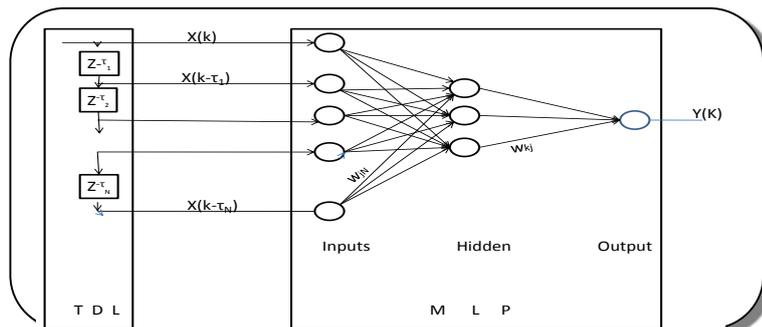


Source : fait par l'auteur

## 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 6]. 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).

Fig.6 Structure TDNN



Source : fait par l'auteur

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

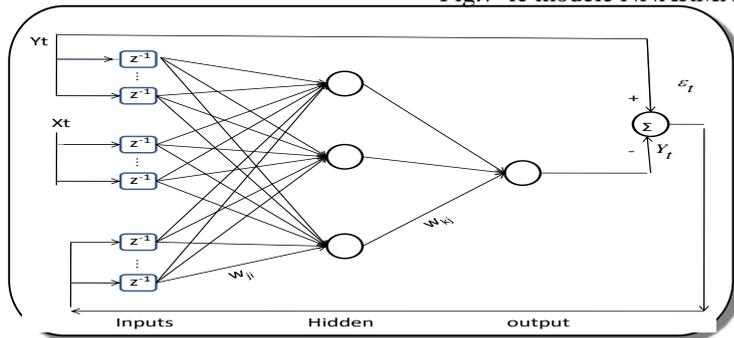
Le modèle NNARMAX est un modèle ARMAX implanté dans un RNA à fonction d’activation non linéaire [figure 7]. Son prédicteur est : (Ljung, 1987)

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

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

Fig.7 le modèle NNARMAX [n :m :k :1]



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 dessaisonalisation.

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<sup>2</sup>.

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

# Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

## 3 Spécifications et résultats

### 3.1 Le modèle FL

La partition du range (ou univers) U des données est effectuée par la méthode heuristique. On en fixe cinq classes  $u_i$  d'amplitudes identiques égales à 1.

$$u_1=[-2.5 ; -1.5] \quad u_2=[-1.5 ; -0.5] \quad u_3=[-0.5 ; 0.5] \quad u_4=[0.5 ; 1.5] \quad u_5=[1.5 ; 2.5]$$

La fonction d'appartenance choisie est la fonction triangulaire « trimf ». Il en résulte 5 variables floues

-déflation moyenne :  $dm=A_1=[-3 \ -2 \ -1]$

-déflation faible :  $df=A_2=[-2 \ -1 \ 0]$

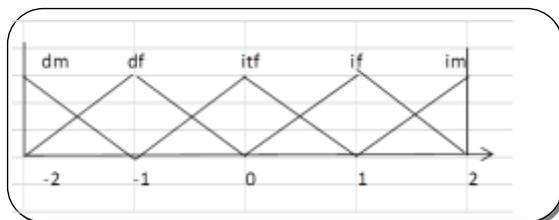
-inflation très faible :  $itf=A_3=[-1 \ 0 \ 1]$

-inflation faible :  $if=A_4=[0 \ 1 \ 2]$

-inflation moyenne :  $im=A_5=[1 \ 2 \ 3]$

Ces cinq variables floues sont illustrées par le graphe suivant :

Fig.8 Représentation des variables floues



Source : l'auteur

L'ordre de la relation entre variables est fixé à 1 par la méthode heuristique. Aussi, Les couples de données  $(\pi_{t-1}, \pi_t)$  constitueront les inputs du modèle FL .

Après fuzzification des données par la méthode d'"  $u_{max}$  " et codification des valeurs floues dm, df, itf, if et im par respectivement 1, 2, 3, 4 et 5. Les relations entre valeurs floues sont calculées puis regroupées :

groupe1 (dm) :  $1 \longrightarrow 3$

groupe2 (df) :  $2 \longrightarrow 2 ; 2 \longrightarrow 3 ; 2 \longrightarrow 4 ; 2 \longrightarrow 5$

groupe3 (itf) :  $3 \longrightarrow 1 ; 3 \longrightarrow 2 ; 3 \longrightarrow 3 ; 3 \longrightarrow 4 ; 3 \longrightarrow 5$

groupe4 (if) :  $4 \longrightarrow 2 ; 4 \longrightarrow 3 ; 4 \longrightarrow 4 ; 4 \longrightarrow 5$

groupe5 (im) :  $5 \longrightarrow 1 ; 5 \longrightarrow 2 ; 5 \longrightarrow 3 ; 5 \longrightarrow 4 ; 5 \longrightarrow 5$

Puis, après traitement, ces relations sont synthétisées en 5 groupes

groupe1 (dm) : 1  $\rightarrow$  3(1)

groupe2 (df) : 2  $\rightarrow$  3(0.9)

groupe3 (itf) : 3  $\rightarrow$  4(1)

groupe4 (if) : 4  $\rightarrow$  3(1)

groupe5 (im) : 5  $\rightarrow$  2(0.9)

Ces relations munies de leur ordre amorcent les inférences au moyen des règles « If...Then » suivantes :

1.if $\pi_{t-1}$  is dm then  $\pi_t$  is itf (1)

2.if $\pi_{t-1}$  is df then  $\pi_t$  is itf (0.9)

3.if $\pi_{t-1}$  is itf then  $\pi_t$  is if (1)

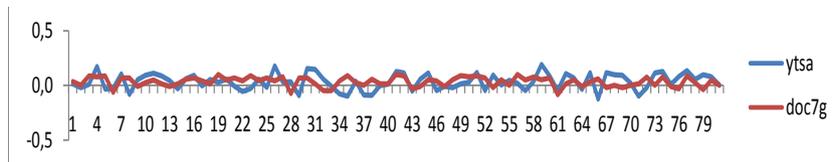
4.if $\pi_{t-1}$  is if then  $\pi_t$  is itf (1)

5.if $\pi_{t-1}$  is im then  $\pi_t$  is df (0.9)

Après agrégation des inférences par la méthode de la « coupure » et de leur défuzzification par la méthode du « centroïde », les prédictions des outputs sont déterminées.

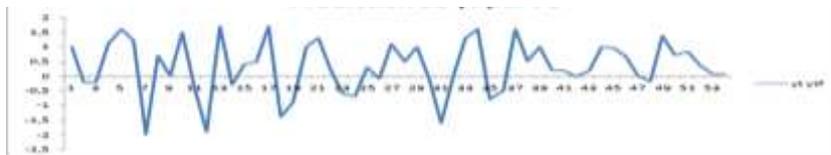
Les prédictions et prévisions sont respectivement représentées par les figures 9 et 10 ci-dessous.

Fig. 9 Prédiction d'YTSA par FL



source : l'auteur

Fig. 10 Prévion d'Yt par FL



source : l'auteur

### 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 1], le modèle FFNN1 s'avère le plus performant. Il représentera le modèle FFNN.

La figure 11 montre la qualité d'ajustement de la série Yt par ce modèle.

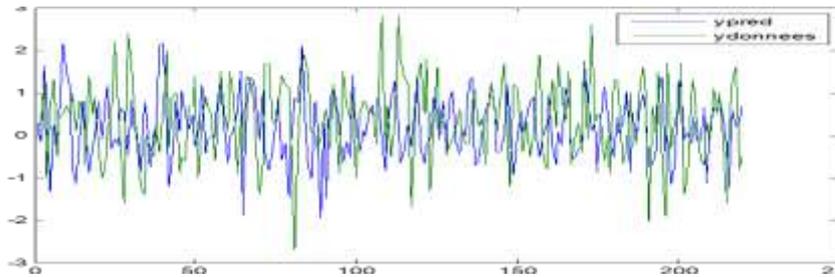
## Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

Tableau (1) : 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

Fig.11 Prédiction de  $Y_t$  par le modèle FFNN1



Source : graphique matlab 2011a

### 3.3 Le modèle GRNN

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

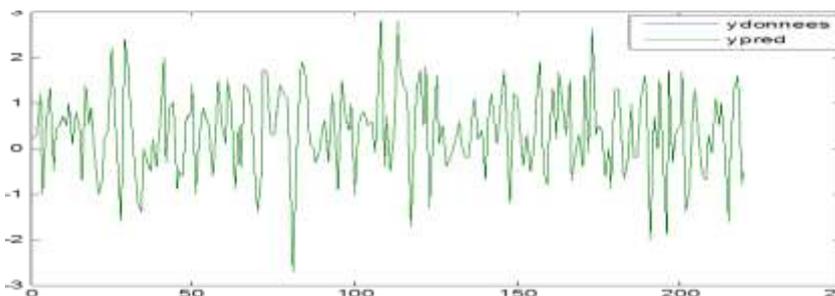
Tableau (2) : Performance des variantes du modèle GRNN

VARIANTE	spread	RMSE	MAE	R <sup>2</sup>
$I_t^1$	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  $Y_t$  par ce modèle est appréciée à travers le graphe de la figure 12.

Fig.12 Prédiction de  $Y_t$  par le modèle GRNN



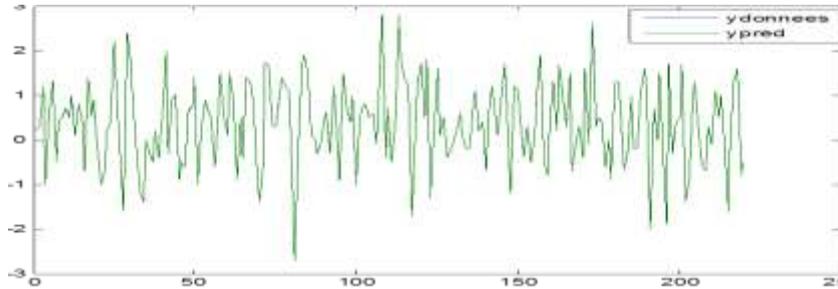
Source : graphique matlab 2011a

### 3.4 Le modèle RBFN

Sur la base des résultats obtenus dans le tableau 4, la variante  $\pi_i^{7^*}$  [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.

Fig.13 Prédiction de  $Y_t$  par le modèle RBFN



Source : graphique matlab 2011

Tableau (3) : Performance des variantes du modèle RBFN

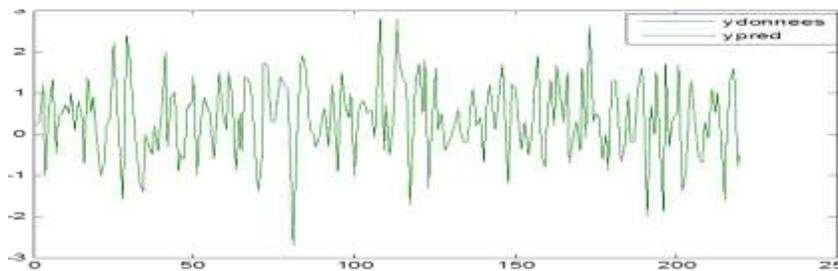
VARIANTE	Nbre unités couche cachée	spread $\lambda$	MSE	MAE	$R^2$
$\pi_i^1$	227	0.1	0.35	0.45	0.67
$\pi_i^2$	226	01	9e-4	3.5e-3	0.99
$\pi_i^3$	225	0.1	3.7e-13	1.43e-6	0.99
$\pi_i^4$	224	0.2	5.6e-30	7.64e-16	0.99
$\pi_i^5$	223	0.2	1.1e-30	1.55e-15	0.99
$\pi_i^6$	222	0.4	9.1e-31	6.81e-16	0.99
$\pi_i^{7^*}$	221	0.5	7.2e-31	6.12e-16	0.99
$\pi_i^8$	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 4, la variante  $\pi_i^{8^*}$  [8 :25:1] représentera le modèle TDNN. La figure ci-dessous montre la qualité d'ajustement de la série  $Y_t$  par ce modèle.

Fig.14 Prédiction de la série  $Y_t$  par le modèle TDNN(8,25)



Source : graphique matlab 2011a

## Estimation de l'IPC par les modèles non paramétriques : cas de l'Algérie

Tableau (4) : performance des variantes du modèle TDNN

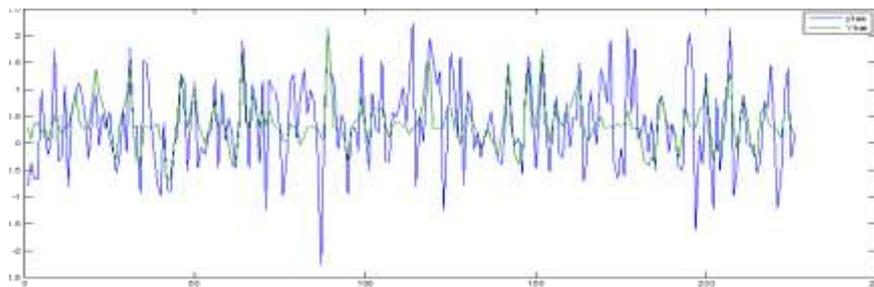
VARIANTE	Nbre unités de couche cachée	MSE	MAE	R <sup>2</sup>
$\pi_r^1$	40	0.49	0.53	0.37
$\pi_r^2$	40	0.28	0.39	0.63
$\pi_r^3$	40	0.03	0.10	0.96
$\pi_r^4$	40	2.31e-5	1.9e-3	0.9
$\pi_r^5$	40	1.83e-12	9.54e-7	0.9
$\pi_r^6$	40	6.92e-12	1.70e-6	0.9
$\pi_r^7$	40	8.55e-14	2.16e-7	0.9
$\pi_r^{8*}$	25	1.03e-14	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 R<sup>2</sup>=0.28. La qualité de prédiction de la série Yt par ce modèle est appréciée par la figure 15.

Fig.15 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 flou FL et parmi les modèles RNA, les modèles statiques « statistiques » GRNN et RBFN sont les plus compétitifs [tableau 5].

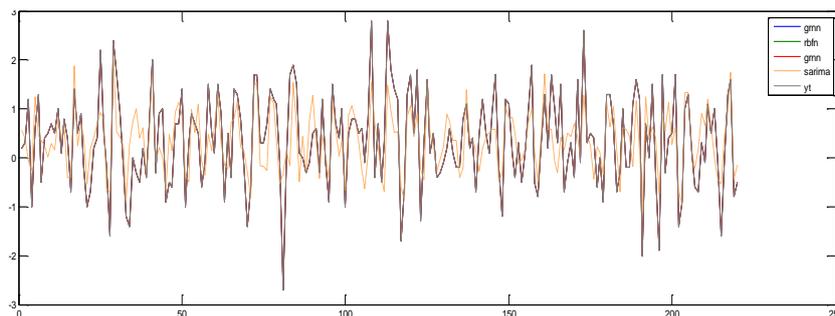
Tableau (5) : Performances comparées de tous les modèles de prévision

Variante	RMSE	MAE	R <sup>2</sup>
FL	1.00	0.82	0.42
FFNNI	0.40	0.48	0.34
GRNN	4.88e-25	6.66e-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.

Fig.16 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).

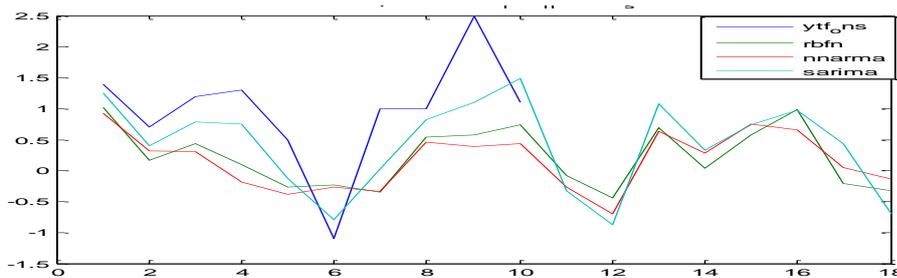
Tableau (6) : Prévisions comparées des modèles

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_rbf	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_rbf	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.

Fig.17 Prévisions du taux d'inflation mensuel à Juin 2022



Source : graphique matlab 2011a

### 5 Conclusion

Selon notre étude, d'une part, les modèles RNA se révèlent plus compétitifs que le modèle flou (FL) 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 Bibliographie et références

- BINNER, J. (2006). Forecasting Euro inflation. *applied economics* , 665-680.
- 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* .
- Box, G. &. (1976). *Time Series Analysis, forecasty and control*. Prentice Hall, Englewood Cliffs.
- 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.
- Duzgun, R. (2010). GRNN for inflation forecasting. *International Journal of Research of Finance and Enonomics* , 51.
- Fa Long, L. (2011). *Digital Front-End in wireless communication and broadcasting circuits an signal processing* . Combridge University Press.
- Henri, C. (2007). Forecast thailand's rice export:statistical technique vs ANN. *Computers & Industrial Engineering* , 53, 4, 610-627.
- Howlet, R. &. (2001). *Radial Basis Functions Networks 2: nex advances in design* . Physica-Verlag.
- Ljung, L. (1987). *System Identification theory for user* . Prentice Hall, Englewood Cliffs.
- McNelis, P. &. (2004). Forecasting inflation with thick models and neural network. *Working Paper Series* , 352.
- Mehri, M. (2013). A comparison of NN models, FL and MLR for prediction of hatchability. *RCSDA, Zabol University,Iran* .
- Moshiri, S. &. (2000). nn versus econometrics models in forecasting inflation. *Journal of forecasting* , 19,201-207.
- Moshiri, S. C. (2000). nn versus econometrics models in forecasting inflation. *Journal of Forecasting* , 19 201-207 .
- Moshiri, S. (1997). *Forecasting inflation using econometrics and ann models*. Canada: thesis, Manitoba university.
- Nakamura, E. (2005). Inflation forecast using neural network. *Economics Letters* , PP.373-378.
- Neves, L. (2008). Forecasts inflation and NARMAX models. *VII encontro brasileiro de finanças* , , (p. Forecasts inflation and NARMAX models ).

Norgaard, M. (2003). *Neural network modeling and control of dynamic system: a practitioner*. Springer .

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.

ONS. (2021, octobre). indices des prix à la consommation. *collections statistiques* , p. 7.

Poo, J. R. (2003). *Computer-aided introduction to econometrics*. Springer.

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.

Specht, D. (1991). A General Neural Network,. *IEEE Transactions on Neural Network* , Vol 2 NR 6 .

Stock, J. &. (1999). forecasting inflation. *Journal of monetary economics*, , 44, 293-335.

## 7 Annexes

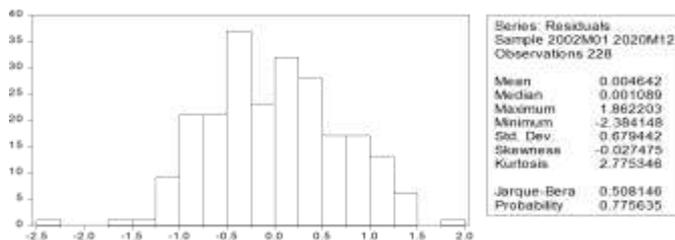
A

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

Regression: 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