

La détermination de taux de change du dinar Algérien à court terme à l'aide d'une marche aléatoire.

- **Refafa Brahim** : Maitre assistant Université Dr Moulay Tahar Saida. rerayene@hotmail.fr
- **Benbayer Habib** : Professeur Université d'Oran 2. Benbayer_habib@yahoo.fr
- **Adouka Lakhdar** : Maitre de conférences. Université de MASCARA. ladouka@gmail.com

Résumé

Les taux de change sont difficiles à anticiper car ils réagissent sous l'influence des différents indicateurs de l'économie. Plusieurs économistes se sont penchés sur le problème de la prévision du taux de change. Ainsi la littérature empirique montre qu'il est difficile de prévoir et expliquer les fluctuations du taux de change. Dans ce contexte on a essayé d'appliquer la méthodologie de Box & Jenkins pour prévoir le taux de change nominal du dinar algérien pour la période de premier trimestre de l'année 2015. On a utilisé une série de taux de change (taux de change nominal dinars /dollar) d'une période de dix-neuf ans, de janvier 1996 à décembre 2014 soit 228 observations mensuelles. Nous avons mis en place un modèle de prévision du dinar de type ARIMA afin de distinguer les variations de taux de change qui sont considérées qu'une marche aléatoire représentée par l'équation $\tilde{TC}_t = 0.4722 \varepsilon_{t-1} + \varepsilon_t$

Mots clés : taux de change, Box Jenkins, ARIMA, prévision

Summary

Exchange rates are difficult to predict because they react under the influence of various economic indicators. Many economists have studied the problem of forecasting the exchange rate. Thus the empirical literature shows that it is difficult to predict and explain the fluctuations in the exchange rate. In this context we tried to apply the methodology of Box & Jenkins to predict the nominal exchange rate of the Algerian dinar for the period of first quarter of 2015. We used a series of exchange rates (nominal exchange rate dinar / dollar) for a period of nineteen years, from January 1996 to December 2014 or 228 monthly observations. We have established a model of forecasting of ARIMA type to distinguish dinar exchange rate fluctuations which are considered a random walk represented by the equation $\tilde{TC}_t = 0.4722 \varepsilon_{t-1} + \varepsilon_t$

Keywords: exchange rate, Box Jenkins, ARIMA, forecast.

Introduction

Le système du taux de change flottant en vigueur depuis 1973 s'est traduit par une forte instabilité de change. Aujourd'hui avec ce système de flottement de plus en plus généralisé, le change est devenu un phénomène économique multiforme et complexe et dont la compréhension continue à poser beaucoup de problèmes. En effet, cette variation fait apparaître un risque de change. Comme le risque de change est significatif sur le marché financier ou monétaire l'anticipation des taux de change devient nécessaire et représente un véritable enjeu dans une économie ouverte.

Cependant, les taux de change sont difficiles à anticiper car ils réagissent sous l'influence des différents indicateurs de l'économie tel que le solde de la balance des paiements, le pouvoir d'achat, les réserves de change, le taux d'intérêt, mouvements des capitaux...etc. Cette relation dépendante et complexe du taux de change avec plusieurs variables économiques laisse les agents économiques toujours en train de trouver une méthode pour prévoir le taux de change pour des raisons de protection en premier lieu ou bien de réaliser des gains, soit à court terme ou moyen et long terme.

Plusieurs économistes se sont penchés sur le problème de la prévision du taux de change. Ainsi la littérature empirique montre qu'il est difficile de prévoir et expliquer les fluctuations du taux de change. Meese et Rogoff (1983) « les variables fondamentales des modèles monétaires aident peu à prédire l'évolution future des taux de change ». En fait, ils concluent que les prédictions basées sur l'hypothèse que le taux de change est une marche aléatoire peuvent être meilleures que les modèles économiques structurels. D'autres études Mark (1995) ont montré que des prévisions à moyen et long terme du taux de change basées sur des variables monétaires peuvent être meilleures que celles tirées d'une simple marche aléatoire.

Ce constat nous amène à la conclusion qu'il est toujours légitime aujourd'hui de s'interroger sur la détermination des taux de change, sur les différents facteurs qui permettent d'expliquer sa volatilité et instabilité, mais également les conséquences sur le fonctionnement de l'économie et sur tout le commerce international.

Donc, l'enjeu est non seulement d'avoir une prévision juste mais aussi de la connaître le plus tôt possible dont l'objectif est limiter le risque de change, c'est pour cela faut-il s'interroger **Comment prévoir les taux de change à court terme dans une économie ouverte ?**

En matière de la prévision, les théories macroéconomiques ont été les plus utilisées jusqu'au début des années 1980. Mais la publication de l'étude de Meese et Rogoff (1983) a remis en cause leur capacité à prévoir correctement les fluctuations des taux de change. Ces théories sont effectivement limitées par leurs hypothèses.

La détermination précise, à court terme, des taux de change est donc particulièrement difficile, et il n'y a pas à ce jour, de théorie capable de produire des prévisions exactes de l'évolution des taux de change. Donc dans ce papier nous allons mettre en place un modèle de prévision du taux de change de dinar algérien par rapport le Dollar américain, en utilisant son historique, la méthode la plus pratique est celle de Box et Jenkins, cette méthode économétrique vise à formuler un modèle permettant de représenter une chronique comme finalité de prévoir des valeurs futures à court terme. On va organiser cet article en trois parties, la première va traiter brièvement une revue de la littérature sur la prévision, la deuxième va être consacrée à la présentation de la méthodologie de Box et Jenkins et la troisième va être consacrée à la modélisation du taux de change a court terme suivant la méthodologie de box et Jenkins.

1. *Revue de littérature sur la prévision économique*

La théorie économique inspirée de Keynes reposait sur l'utilisation de prévisions conditionnelles sous certaines hypothèses, les prévisions d'une ou plusieurs variables étaient faites conditionnellement à des comportements, au sein de modèles structurels. Plus particulièrement, dès 1936, Keynes proposait par exemple de lier la consommation C_t au revenu disponible R_t , sous la forme $C_t = \alpha R_t + \beta$: une prévision de R_t permettait de prévoir C_t . Brown avait proposé un modèle légèrement différent dès 1952, en intégrant le fait que les individus ont des habitudes de consommation, entraînant une inertie importante : $C_t = \alpha R_t + \beta + \lambda C_{t-1}$. Ces prévisions structurelles ont toutefois cessé de faire référence à partir des années 1970.

Les prévisions non-structurelles ont alors pu prendre en compte les différents cycles observés en économie (Sargent et Sims 1977), des prévisions de séries économiques peuvent se faire sans nécessairement avoir de modèle structurel derrière. Les modèles utilisés sont toutefois relativement anciens puisqu'ils sont inspirés des modèles de Slutsky et Yule, tous deux datant de 1927, basés sur la notion de modèle autorégressif. La publication de l'ouvrage de Box et Jenkins en 1970 permettra une avancée rapide avec l'utilisation des modèles ARMA.

Toutefois, l'insuffisance de la théorie de Box et Jenkins est qu'elle ne prend pas en compte des effets croisés de dépendance entre variables. Pour effectuer de la prévision d'un ensemble de variables, a priori liées, il convient d'effectuer une prévision globale. La théorie des modèles VAR

(modèles autorégressifs vectoriels) a été introduite en économie sous l'impulsion de Sims en 1980, qui a travaillé sur des systèmes d'équations où toutes les variables sont alors endogènes (contrairement aux équations structurelles de Keynes). Cette théorie avait toutefois été étudiée dès les années 1970 par Granger par exemple, qui avait travaillé sur la notion simple de causalité entre variables.

Toutefois, la présence d'un certain nombre de variables non-stationnaires a posé un certain nombre de problèmes, Granger a alors introduit la notion de Co intégration en 1981. Cette notion dit que deux variables X et Y peuvent suivre une tendance stochastique, mais la différence (ou le spread) $X - Y$ peut être stationnaire. Cette notion sera à l'origine des modèles à tendance commune, permettant de travailler sur des systèmes d'équations où certaines variables sont Co intégrées. En particulier, dès 1978, Hall se posait la question de savoir si la consommation par habitant n'était pas une martingale (lié au revenu), ce qui conduirait à écrire $C_t = C_{t-1} + \varepsilon_t$ où ε_t est un aléa. Nelson et Plosser ont d'ailleurs noté, en 1982 qu'un grand nombre de séries macroéconomiques étaient caractérisées par la présence d'une racine unitaire (c'est à dire une écriture de la forme $C_t = C_{t-1} + X_t$). Et c'est finalement en 1987 que Campbell a proposé un modèle VAR sur la consommation C et le revenu R , puis un modèle VAR intégrant dans chaque équation un modèle à correction d'erreur.

Une autre piste qui a été explorée à la même époque est celle des modèles non-linéaires. Cette voie a été ouverte dès 1982 par Engle, qui introduisit de la dynamique dans la volatilité, à l'aide des modèles ARCH. Ces modèles ont été très utilisés en finance, mais aussi pour des modèles d'inflation.

Parmi des améliorations apportées dans les années 90, on peut noter les modèles avec cycles, avec rupture de tendance, à changement de régime...etc. La théorie des modèles à changement de régime repose sur l'idée que derrière les variables observées existent des variables cachées, non observées.

Pour résumer l'histoire des applications économiques des séries temporelles, on peut retenir le schéma suivant :

- années 20 : macroéconomie descriptive : description des cycles (courts : Slutsky, longs : Kondratie)
- années 50 : début de la théorie des séries temporelles, avec comme objectif principal, la prévision.
- années 60 : application en macroéconomie, avec des modèles structurels : une vingtaine de variables, et 200 observations (maximum).

- années 70 : théorie de Box et Jenkins, s'appuyant sur un logiciel (modèle linéaire) : on considère les variables une à une, sur 200 observations (début, à la même époque, de la théorie des panels en microéconomie : 3000 individus suivis sur 3 ou 4 périodes).
- années 80 : en macroéconomie, modèles multi variés (causalité, Co intégration, Co dépendance). Début de l'utilisation des modèles de séries temporelles sur données financières : beaucoup de variables, 2000 observations. Début des modèles à temps continu.
- années 90 : données hautes fréquences sur les marchés financiers (de 4000 à plus de 2000000 d'observations).

2. Présentation générale de la méthode de Box et Jenkins

Avant de présenter la méthode de Box et Jenkins nous allons voir les propriétés des modèles *ARIMA* qui ont été introduits par WOLD (1954), cette classe des modèles *ARIMA* a été introduite pour reconstituer le comportement de processus soumis à des chocs aléatoires¹ au cours du temps, entre deux observations successives d'une série de mesures portant sur l'activité du processus, un événement aléatoire appelé perturbation vient affecter le comportement temporel de ce processus et ainsi modifier les valeurs de la série chronologique des observations. Les modèles *ARIMA* permettent de combiner trois types de processus temporels : les processus autorégressifs (*AR-AutoRegressive*), les processus intégrés (*I-Integrated*), et les moyennes mobiles (*MA-Moving Average*).

Dans le cas le plus général, un modèle *ARIMA* combine les trois types de processus aléatoires², la contribution de chacun d'eux étant précisée par la notation *ARIMA* (p, d, q), où p est l'ordre du processus autorégressif *AR*(p), d le degré d'intégration d'un processus *I*(d), et q l'ordre de la moyenne mobile *MA*(q).

2.1. Les processus autoregressive (AR)

Dans un processus autorégressif, chaque valeur de la série est une combinaison linéaire des valeurs précédentes de la série. Si la valeur de la série à l'instant t , Y_t , ne dépend que de la valeur précédente Y_{t-1} et à une perturbation aléatoire près ε_t , on dit la série Y_t suit un processus autorégressif *AR*(p) si s'écrit:

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t$$

¹ La notion de choc aléatoire ou d'impulsion a été introduite dans l'étude des séries temporelles en 1927 par Yule

² La caractérisation des processus aléatoires a été effectuée par Kolmogorov en 1933.

Ou
$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \varepsilon_t$$

- $\alpha_1 \dots \alpha_p$: exprime la force de la liaison linéaire entre deux valeurs successives et sont des paramètres à estimer positifs ou négatifs.
- ε_t est un terme aléatoire (bruit blanc indépendant³)

On peut dire qu'un processus autorégressif possède une « mémoire » au sens où chaque valeur est corrélée à l'ensemble des valeurs qui la précède. Un processus autorégressif d'ordre p , $AR(p)$, pourra être noté comme un modèle $ARIMA(p, 0, 0)$.

2.2. Les processus moyennes mobiles (MA)

La valeur courante d'un processus de moyenne mobile est définie comme une combinaison linéaire de la perturbation courante avec une ou plusieurs perturbations précédentes. L'ordre de la moyenne mobile (q) indique le nombre de périodes précédentes incorporées dans la valeur courante. Ainsi, on dit la série Y_t suit un processus moyenne mobiles si s'écrit:

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

$$\text{ou } Y_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

2.3. Les modèles ARMA

Les modèles ARMA sont représentatifs d'un processus généré par une combinaison des valeurs passées et des erreurs passées, proposés par Yule et Slutsky. Un processus Y_t est un processus $ARMA(p, q)$ s'il existe un bruit blanc ε_t , pour tout t tel que :

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Ou
$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

2.4. La méthodologie de Box et Jenkins

Box et Jenkins (1976) ont rendu populaire les modèles ARMA en proposant des moyens de rendre la série stationnaire. Cette méthodologie s'organise en cinq étapes :

- 1- L'étude de la stationnarité des séries chronologiques
- 2- l'identification de type de modèle $ARIMA(p, d, q)$:

³ On dit que ε_t est un processus stochastique hasard pure ou bruit blanc si les trois propriétés suivantes sont vérifiées : $E[\varepsilon_t] = 0, Var(\varepsilon_t) = \sigma^2$ et $cov(\varepsilon_t, \varepsilon_{t-h}) = 0$ pour $h \neq 0$

- choix de d : combien de fois faut-il différencier pour obtenir une série stationnaire (autocorrélogrammes, tests statistiques...).
- choix de p et q : ordres respectifs des composantes AR et MA
- 3- L'estimation des coefficients des modèles identifiés (estimation des α_p et des θ_q : paramètres respectifs des composantes AR et MA).
- 4- La validation et le choix d'un modèle (significativité des paramètres et validation de l'hypothèse de bruit blanc des résidus.
- 5- La prévision de la chronique sur un horizon h .

3. Application de la méthode de Box et Jenkins sur la série du taux de change du dinar algérien

Dans ce qui suit nous allons appliquer la méthodologie de Box & Jenkins pour la série de taux de change (taux de change nominal dinars /dollar) et cela pour effectuer des prévisions pour les quatre mois de l'année 2015. Pour le traitement économétrique de nos séries, on va utiliser le logiciel Eviews version 8.

3.1. Les Données statistique

La série étudiée est celle des taux des taux de change dinar/dollar de fin de période, tels qu'ils apparaissent dans la base données de la banque mondiale, La méthode ARIMA nécessite des séries relativement longues, afin de distinguer les variations de taux de change qui sont considérées qu'une marche aléatoire. Ces considérations ont conduit à l'utilisation d'une période de dix neuf ans, de janvier 1996 à décembre 2014, nous donnant donc 228 observations mensuelles (voir annexe tableau n°01). ce choix d'intervalle est liée à l'instauration du régime de change flottant dirigé en fin du 1995, à partir de cette date le cours du dinar est déterminé sur le marché interbancaire de change en fonction de l'offre et la demande, lors de la création du marché interbancaire de change par le règlement N° 9508 du 23 décembre 1995.


3.2. Estimation d'un modèle ARIMA

3.2.1. Etude de la stationnarité de la série

Avant toute analyse de série temporelle, il est indispensable d'étudier avec soin le graph représentant son évolution, car ce dernier fourni à priori une idée global sur la nature et les caractéristiques des processus générant cette série à savoir la tendance, la saisonnalité etc.

Fig n°01 graph de la série TC⁴

⁴ Source : élaborée par les auteurs sous Eviews8



Le graph montré qu'il existe une tendance donc cette série n'est pas stationnaire.

- Etude de correlogramme et teste de stationnarité

Avant d'étudier le correlogramme, on définit la fonction d'autocorrélation simple et partielle notée ρ_k qui mesure la corrélation de la série avec elle-même décalée de K périodes, elle

$$\text{s'écrit : } \rho_K = \frac{\text{COV}(Y_t, Y_{t-K})}{\sigma_{Y_t} \sigma_{Y_{t-K}}}$$

La fonction d'autocorrélation partielle mesure la corrélation entre Y_t et Y_{t-K} une fois retirée l'influence des variables antérieures à Y_{t-K} .

Le correlogramme (Tableau n° 02 voir annexe) présente une régression lente et linéaire typique des séries non stationnaires, on remarque que les autocorrélations sont toutes significativement différentes de zéro et diminuent progressivement, la première autocorrélation partielle est très significativement différente à zéro ce qui implique que la série n'est pas stationnaire, cette forme de série doit être stabilisée ou stationnarisée, pour enlever cette tendance on la différencie en premier ordre, ce qui génère une autre série $DTC = TC_t - TC_{t-1}$

Avant d'étudier la stationnarité de la série DTC, on définit le processus stationnaire. Un processus stochastique Y est stationnaire si :

$$E[Y_t] = \mu \quad \forall t \text{ (L'espérance est constante elle est inchangée dans le temps).}$$


$$V(Y_t) = \sigma^2 \quad \forall t \text{ (La variance est constante dans le temps)}$$

$\text{cov}(Y_t, Y_{t-\theta}) = v(\theta) \quad \forall t, \forall \theta$ (La covariance entre une composante d'une date t et une composante d'une autre date $t-\theta$ ne dépend que de l'écart de temps le retard θ entre les dates, et non de la date t elle-même)

En d'autres termes une série temporelle observée est donc une réalisation d'un processus stochastique stationnaire si elle fluctue autour d'une valeur moyenne stable, si l'amplitude moyenne de ses

fluctuations reste stable dans le temps, et si la manière dont ses valeurs sont liées aux valeurs précédentes se répète de façon stable dans le temps.

Fig n°02 graph de la série DTC⁵



La représentation graphique nous indique que la série peut être stationnaire, mais on confirme cette stationnarité en appliquant le test de Dickey Fuller augmenté (ADF) élaboré en 1981. Ce test existe en trois versions différentes :

- 1- Le premier modèle sans constante, ni tendance déterministe présenté de façon générale comme suit :

$$\Delta Y_t = \alpha Y_{t-1} - \sum_{j=2}^p \phi_j \Delta Y_{t-j+1} + \varepsilon_t$$

- 2- Le deuxième modèle avec constante et sans tendance déterministe qui se présente ainsi :

$$\Delta Y_t = \alpha Y_{t-1} - \sum_{j=2}^p \phi_j \Delta Y_{t-j+1} + c + \varepsilon_t$$

- 3- Le troisième modèle avec constante et tendance déterministe :

$$\Delta Y_t = \alpha Y_{t-1} - \sum_{j=2}^p \phi_j \Delta Y_{t-j+1} + c + \beta t + \varepsilon_t$$

Où ΔY_t est le changement entre les périodes t et $t+1$. L'hypothèse nulle H_0 de non stationnarité est évaluée en testant l'hypothèse $\phi = 1$ cela veut dire il existe une racine unitaire.

On va appliquer le teste Dickey Fuller augmenté (ADF) pour la série DTC avec constante et tendance.

Suivant le résultat obtenu (figure n°02 voir annexe), il semble que la série TC est stationnaire dans ce cas la on rejette l'hypothèse H_0 : la série possède une racine unitaire (t-statistique est inférieure à t-tabulée (1%,5%,10%) , en plus la valeur empirique de la statistique Student relative à la tendance @trend qui est égale à (-0.082614) est inférieure à la valeur tabulée $t_{14,0.05}$, donc on accepte l'hypothèse

⁵ Source : élaborée par les auteurs sous Eviews8

de la nullité de coefficient de tendance (il n'est pas significativement différent de zéro) le processus n'est pas de type DS (trend stationnary).

Tab n° 01 test ADF de la série DTC⁶

probabilité	t-statistic	1%	5%	10%
0.00	-9.53	-3.99	-3.49	-3.13

3.2.2. Identification du modèle *ARIMA* (p, d, q)

Cette étape consiste à identifier le modèle *ARIMA* susceptible de représenter la série. L'objet est de déterminer à partir de l'observation des fonctions d'autocorrélation simple et partielle dans la famille des modèles de types *ARIMA* (p, d, q) le modèle adéquat.

Ainsi un examen du corrélogramme s'impose. Cette phase est la plus importante et la plus difficile. Elle consiste à déterminer, parmi l'ensemble des modèles *ARIMA* (p, d, q), le modèle le plus représentatif du phénomène étudié. Elle est fondée sur l'étude des corrélogrammes simples et partiels. L'idée de base est que chaque modèle *ARIMA* possède des fonctions d'autocorrélation (simple et partielle) théoriques spécifiques.

Il peut alors choisir un ou plusieurs modèles théoriques (en général, le choix porte sur trois modèles au plus) en se basant sur les propriétés suivantes :

- Si le corrélogramme simple n'a que ses q premiers termes différents de zéro et que les termes du corrélogramme partiel diminuent exponentiellement vers zéro ou d'une manière sinusoïdale amortie, nous pouvons pronostiquer une moyenne mobile d'ordre q : *MA* (q).
- Si le corrélogramme partiel n'a que ses p premiers termes différents de zéro et que les termes du corrélogramme simple diminuent exponentiellement vers zéro ou d'une manière sinusoïdale amortie, nous identifions un autorégressif d'ordre p : *AR* (p).
- Si les fonctions d'autocorrélation simples et partiels n'apparaissent pas tronquées, il s'agit d'un processus *ARMA*, en fait dans ce cas, il est très difficile d'identifier directement les vrais paramètres du modèle. Il convient donc d'en proposer plusieurs pour éliminer, après des tests appropriés, ceux qui ne reflètent pas les variations du processus.

⁶ Source : élaboré par les auteurs

Après la confirmation de la stationnarité de la série DTC, on va identifier le modèle de la série à l'aide des fonctions d'autocorrélation et autocorrélation partielle qui sont présentées ci-dessous. (fig n°03 voir annexe).

Il convient à présent d'estimer le modèle susceptible de représenter la série. En observant les corrélogrammes simple et partiel de la série stationnaire DTC, on remarque le corrélogramme simple et partiel n'ont que leurs premier terme différent de zéro, donc nous identifions plusieurs modèles.

Par conséquent, on a plusieurs modèles candidats qui sont les suivants : ARIMA (0.1.1), ARIMA (1.1.0), ARIMA (1.1.1).

3.2.3. Sélection et estimation des modèles

En premier temps, on va choisir le modèle qui a la plus faible valeur de AIC (AKAIKE) et SC (SCHWARTZ). (voir Fig n°04.05.06 en annexe)

Tab n° 02 choix du modèle suivant les critères AIC et SC⁷

Modèle	AIC	SC
ARIMA (1.1.1)	2.717088	2.747358
ARIMA (0.1.1)	2.706894	2.721982
ARIMA (1.1.0)	2.733208	2.748343

On a choisi le modèle ARIMA (0, 1,1) d'après les critères de parcimonie les plus faibles (AIC) et (SC).

Deuxièmement, on va estimer le modèle choisi avec constante, si cette dernière sera non significative on va l'éliminer.

Fig n°03 estimation ARIMA(0.1.1) avec constante⁸

Dependent Variable: DTC

Method: Least Squares

Sample (adjusted): 1996M02 2014M12

⁷ Source : élaboré par les auteurs

⁸ Source : élaborée par les auteurs sous Eviews8

Included observations: 227 after adjustments

Convergence achieved after 6 iterations

MA Backcast: 1996M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.153591	0.090500	1.697131	0.0911
MA(1)	0.466361	0.059679	7.814493	0.0000
R-squared	0.187611	Mean dependent var		0.149586
Adjusted R-squared	0.184000	S.D. dependent var		1.030312
S.E. of regression	0.930708	Akaike info criterion		2.703030
Sum squared resid	194.8991	Schwarz criterion		2.733206
Log likelihood	-304.7939	Hannan-Quinn criter.		2.715206
F-statistic	51.96086	Durbin-Watson stat		1.943285
Prob(F-statistic)	0.000000			
Inverted MA Roots	-.47			

Suivant la figure on remarque que la valeur t-student de la constante est inférieure à 1.96, et la valeur probable est supérieure de 0.05, donc elle n'est pas significative donc on va l'éliminer et on ré-estimer le modèle sans constante.

Fig n°04 estimation ARIMA(0.1.1) sans constante⁹

Dependent Variable: DTC

Method: Least Squares

Sample (adjusted): 1996M02 2014M12

Included observations: 227 after adjustments

Convergence achieved after 6 iterations

MA Backcast: 1996M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.472200	0.059385	7.951495	0.0000
R-squared	0.177249	Mean dependent var		0.149586
Adjusted R-squared	0.177249	S.D. dependent var		1.030312
S.E. of regression	0.934551	Akaike info criterion		2.706894
Sum squared resid	197.3850	Schwarz criterion		2.721982
Log likelihood	-306.2324	Hannan-Quinn criter.		2.712982
Durbin-Watson stat	1.930625			
Inverted MA Roots	-.47			

⁹ Source : élaborée par les auteurs sous Eviews8

Le coefficient est significatif, donc on accepte le modèle qui s'écrit :


$$Y_t = 0.4722 \varepsilon_{t-1} + \varepsilon_t$$

3.2.4. Validation du modèle

On confirme que le modèle ajuste la série après l'étude des résidus, ces derniers doivent être représentés un bruit blanc et suivent la loi normale, on utilise la fonction d'autocorrélation simple et partiel et le test de Box Pierce pour confirmer la première condition, et le test de Jarque-Bera pour confirmer la deuxième condition.

Suivant la figure n° 06 voir annexe, on constate clairement qu'il n'existe aucun facteur hors intervalle de confiance et la statistique Q a une probabilité critique très proche de 1, donc les résidus peuvent être assimilés à un bruit blanc.

Fig n°05 test de JB de normalité des erreurs¹⁰



Suivant le graphe il apparaît que les résidus suivent une loi normale, mais la statistique J-B vaut 382.77 est supérieur que la valeur $\chi^2_{0.05}(2) = 5.9991$, donc on rejette l'hypothèse de normalité des erreurs, les résidus ne suivent pas la loi normale, mais le modèle éventuellement valide pour faire des prévisions.

3.2.5. La prévision

Après toutes les étapes précédentes, on conclure cette étude par l'étape de prévision l'objectif de la recherche. Les prévisions concernant le taux de change pour le premier trimestre de l'année 2015 se présentent dans le tableau suivant :

¹⁰ Source : élaborée par les auteurs sous Eviews8

	01/2015	02/2015	03/2015	04/2015
Taux de change prévu	97.99	98.02	98.85	99.48
Taux de change observé	97.62	97.18	99.42	98.97

D'après le tableau ci-dessus on constate que les valeurs prévues s'approchent aux valeurs observées, avec des écarts faibles. Donc on peut dire que le modèle choisi est efficace pour la prévision du taux de change à court terme.

Conclusion

Dans cet article on a procédé à une étude de prévision du taux de change du dinar algérien, après une brève présentation d'histoire de la prévision économétrique. On a appliqué la méthodologie de Box et Jenkins sur les données du taux de change du janvier 1996 date qui coïncide avec la libéralisation du taux de change et l'entrée dans un système du taux de change flottant administré jusqu'au décembre 2014, soit 228 observation. Enfin on a trouvé un modèle ARIMA (0.1.1) sans constante. A partir de ce modèle on a calculé les valeurs du taux de change prévus pour les quatre premiers mois 2015. On a conclut que les valeurs prévues s'approche aux valeurs observées, avec des d'écarts faibles. Donc on peut dire que le modèle choisi est efficace pour la prévision du taux de change à court terme.

Références bibliographiques

- Bourbonnais Régis, économétrie, 9^{ème} édition, DUNOD 2015.
- Bourbonnais Régis, Michel Tezzaza, analyse des séries temporelle, 3^{ème} édition DUNOD , paris 2010.
- DAMODAR N .GUJARATI, econometri, de boeck édition, paris 2004.
- DAVID et J.MICHAUD, la prévision approche empirique d'une méthode statistique, Paris 1989.
- Emmanuel Nyahoho, finance internationale, presse de l'université de Québec, 2002.
- Gregory.N Mankiw, macroéconomie, 3^{ème} , édition De boeck, Paris 2003.

Hervé JOLY et autre, taux de change réel d'équilibre, ministère des finances, article 96-10, paris 1996

- Lakhdar ADOUKA, Peut-on modéliser la volatilité du taux de change de dinar algérien par un processus GARCH ?, revue performances des entreprise algériennes 06/2015
- Larbi DOHNI, et CAROL HAINAUT, les taux de changes, édition De Boeck, BruxeLe 2004.
- NELSON C. MARK, exchange rates and fundamentals evidence on long horizon predictability, Tthe American Economic Review,1995.

PAUL,R Krugman, économie internationale, 4^{ème} édition De boeck,2003

- Peter B. Clark, Natalia Tamirisa et Shang-Jin Wei, VOLATILITÉ DES TAUX DE CHANGE ET FLUX COMMERCIAUX NOUVEAUX ÉLÉMENTS D'APPRÉCIATION, étude n°235 FMI
- Richard .A, MEESE.KENNETH ROGOFF, empirical exchange rate models of the seventies do they fit out of sample? , Journal of International Economics14, 1983.
- Virginie COUDERT, comment définir un taux de change d'équilibre, revue CEPII N°77 1^{ier} T 1999

Annexe

Tableau n°01serie du taux de change jan 1996-dec 2014

	1996	1997	1998	1999	2000	2001	2002
jan	53.003	57.136	58.969	61.264	69.046	74.813	77.889
fév.	53.33	57.334	58.944	63.398	71.148	75.745	78.922
mars	53.565	57.104	59.13	65.284	72.737	76.454	79.706
avril	53.83	57.302	58.917	66.517	74.19	77.377	80.185
mai	54.819	57.053	58.185	67.136	76.363	78.338	80.085
juin	55.144	57.309	58.517	68.13	74.186	79.172	80,000
juil.	55.11	58.228	58.734	68.271	74.634	79.358	79.915
aout	55.219	59.55	59.248	67.207	76.472	76.961	79.978
sept	55.551	58.4	58.062	67.583	78.478	76.455	79.938
oct.	55.796	57.771	57.262	66.759	79.412	76.702	79.921
nov.	55.444	57.177	59.028	68.185	79.484	77.694	79.851
déc.	56.176	58.124	59.873	69.154	76.968	77.513	79.793
	2003	2004	2005	2006	2007	2008	
jan	79.676	71.653	72.668	73.075	71.498	66.847	
fév.	79.641	71.434	72.776	73.218	71.366	66.769	
mars	79.664	71.456	72.432	74.022	71.044	65.673	
avril	79.66	71.507	72.927	73.127	70.541	64.97	
mai	79.464	71.515	73.446	72.163	70.49	63.476	
juin	79.298	71.459	73.926	73.371	70.247	62.398	
juil.	77.852	71.786	73.19	73.347	68.982	61.5	
aout	77.798	72.616	73.665	72.347	67.714	61.077	
sept	77.668	72.597	73.296	72.055	68.157	60.979	
oct.	76.375	72.991	73.417	72.252	67.576	62.258	
nov.	71.382	73.032	74.059	71.711	66.822	68.133	
déc.	70.262	72.681	73.515	71.072	67.072	70.914	
	2009	2010	2011	2012	2013	2014	
jan	71.394	72.923	73.6284	76.0015	78.2769	78.2852	
fév.	72.222	73.523	72.8832	74.6934	78.16	78.0293	
mars	72.929	73.454	72.2663	74.2996	79.106	77.6848	
avril	73.123	73.616	71.794	74.0835	78.9263	78.6162	
mai	72.626	74.838	72.0516	74.7374	79.1971	78.8627	
juin	73.169	75.639	72.0077	77.7146	79.1287	79.3583	
juil.	73.269	74.969	72.4229	81.0548	79.5365	79.4974	
aout	72.99	75.429	72.5534	81.5724	80.3771	80.0067	
sept	72.595	75.362	73.6051	79.7354	81.7607	81.1353	
oct.	72.267	74.246	73.8981	79.4862	81.4607	83.4541	
nov.	72.251	74.246	74.1574	79.7802	80.5087	84.7466	
déc.	72.934	74.387	74.8003	78.5257	78.7865	86.959	

Fig n° 01 fonctions d'autocorrélation et autocorrélation partielle de la série TC

Sample: 1996M01 2014M12

Included observations: 228

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. *****	. *****	1	0.969	0.969	217.05	0.000
. *****	* .	2	0.934	-0.091	419.48	0.000
. *****	. .	3	0.899	-0.001	608.05	0.000
. *****	. .	4	0.867	0.022	784.21	0.000
. *****	. .	5	0.838	0.019	949.34	0.000
. *****	. .	6	0.810	0.005	1104.3	0.000
. *****	. .	7	0.782	-0.011	1249.6	0.000
. *****	. .	8	0.755	-0.017	1385.4	0.000
. *****	. .	9	0.727	-0.001	1512.1	0.000
. *****	. .	10	0.703	0.026	1630.9	0.000
. *****	. .	11	0.677	-0.038	1741.6	0.000
. *****	. .	12	0.652	-0.002	1844.7	0.000
. *****	. .	13	0.627	-0.011	1940.5	0.000
. ****	. .	14	0.598	-0.064	2028.2	0.000
. ****	* .	15	0.567	-0.073	2107.3	0.000
. ****	. .	16	0.533	-0.040	2177.5	0.000
. ****	. .	17	0.501	0.008	2240.0	0.000
. ***	. .	18	0.471	-0.003	2295.5	0.000
. ***	. .	19	0.443	-0.008	2344.6	0.000
. ***	. .	20	0.416	0.005	2388.2	0.000
. ***	. .	21	0.388	-0.029	2426.5	0.000
. ***	. .	22	0.361	-0.021	2459.6	0.000
. **	. .	23	0.333	-0.020	2487.9	0.000
. **	. .	24	0.307	0.002	2512.1	0.000
. **	. .	25	0.282	0.013	2532.7	0.000
. **	. .	26	0.256	-0.053	2549.8	0.000
. **	. .	27	0.230	-0.021	2563.6	0.000
. *	. .	28	0.202	-0.039	2574.3	0.000
. *	* .	29	0.171	-0.067	2581.9	0.000
. *	. .	30	0.139	-0.017	2587.1	0.000

Fig n° 02 test ADF pour la série DTC

Null Hypothesis: DTC has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-9.532328	0.0000
Test critical values: 1% level	-3.999180	
5% level	-3.429834	
10% level	-3.138449	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(DTC)

Method: Least Squares

Date: 05/30/15 Time: 08:48

Sample (adjusted): 1996M03 2014M12

Included observations: 226 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
DTC(-1)	-0.588361	0.061723	-9.532328	0.0000
C	0.100121	0.127861	0.783045	0.4344
@TREND("1996M01")	-7.98E-05	0.000966	-0.082614	0.9342
R-squared	0.289674	Mean dependent var		0.008342
Adjusted R-squared	0.283303	S.D. dependent var		1.118389
S.E. of regression	0.946806	Akaike info criterion		2.741740
Sum squared resid	199.9063	Schwarz criterion		2.787145
Log likelihood	-306.8166	Hannan-Quinn criter.		2.760063
F-statistic	45.47012	Durbin-Watson stat		1.868436
Prob(F-statistic)	0.000000			

Fig n° 03 fonctions d'autocorrélation et autocorrélation partielle de la série DTC

Sample: 1996M01 2014M12

Included observations: 227

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. ***	. ***	1 0.404	0.404	37.635	0.000
. .	* .	2 0.042	-0.145	38.051	0.000
. .	. .	3 0.012	0.062	38.084	0.000
. .	. .	4 -0.009	-0.040	38.103	0.000
. .	. .	5 -0.045	-0.032	38.584	0.000
. .	. .	6 -0.027	0.007	38.761	0.000
. .	. .	7 0.038	0.052	39.094	0.000
. .	. .	8 -0.010	-0.061	39.120	0.000
* .	. .	9 -0.075	-0.050	40.449	0.000
. .	. .	10 -0.002	0.060	40.450	0.000
. .	. .	11 -0.003	-0.043	40.452	0.000
. .	. .	12 0.017	0.051	40.522	0.000
. .	. .	13 0.055	0.033	41.255	0.000
. *	. *	14 0.117	0.089	44.583	0.000
. .	. .	15 0.070	-0.016	45.786	0.000
. .	* .	16 -0.047	-0.068	46.337	0.000
. .	. .	17 -0.039	0.012	46.705	0.000
. .	. .	18 0.009	0.020	46.724	0.000
. .	. .	19 -0.021	-0.030	46.835	0.000
. .	. .	20 -0.052	-0.037	47.507	0.000
. .	. .	21 -0.054	-0.032	48.236	0.001
. .	. .	22 -0.002	0.036	48.237	0.001
. .	. .	23 -0.029	-0.033	48.453	0.001
* .	* .	24 -0.086	-0.075	50.338	0.001
. .	. .	25 0.003	0.067	50.341	0.002

. .	. .	26	0.046	0.010	50.880	0.002
. .	. .	27	0.042	0.022	51.338	0.003
. .	. .	28	-0.009	-0.058	51.361	0.005
. .	. .	29	0.027	0.056	51.558	0.006
. .	. .	30	-0.008	-0.046	51.574	0.008

Fig n° 04 estimation ARIMA (1.1.1)

Dependent Variable: DTC

Method: Least Squares

Sample (adjusted): 1996M03 2014M12

Included observations: 226 after adjustments

Convergence achieved after 6 iterations

MA Backcast: 1996M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.117773	0.141093	0.834724	0.4048
MA(1)	0.378499	0.131581	2.876553	0.0044
R-squared	0.179695	Mean dependent var		0.148801
Adjusted R-squared	0.176033	S.D. dependent var		1.032531
S.E. of regression	0.937255	Akaike info criterion		2.717088
Sum squared resid	196.7722	Schwarz criterion		2.747358
Log likelihood	-305.0310	Hannan-Quinn criter.		2.729304
Durbin-Watson stat	1.983325			
Inverted AR Roots	.12			
Inverted MA Roots	-.38			

Fig n° 05 estimation ARIMA(0.1.1)

Dependent Variable: DTC

Method: Least Squares

Sample (adjusted): 1996M02 2014M12

Included observations: 227 after adjustments

Convergence achieved after 6 iterations

MA Backcast: 1996M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.472200	0.059385	7.951495	0.0000
R-squared	0.177249	Mean dependent var		0.149586
Adjusted R-squared	0.177249	S.D. dependent var		1.030312
S.E. of regression	0.934551	Akaike info criterion		2.706894
Sum squared resid	197.3850	Schwarz criterion		2.721982
Log likelihood	-306.2324	Hannan-Quinn criter.		2.712982
Durbin-Watson stat	1.930625			
Inverted MA Roots	-.47			

Fig n° 06 estimation ARIMA (1.1.0)

Dependent Variable: DTC

Method: Least Squares

Date: 05/30/15 Time: 09:22

Sample (adjusted): 1996M03 2014M12

Included observations: 226 after adjustments

Convergence achieved after 2 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.423855	0.061111	6.935770	0.0000
R-squared	0.158954	Mean dependent var		0.148801
Adjusted R-squared	0.158954	S.D. dependent var		1.032531
S.E. of regression	0.946919	Akaike info criterion		2.733208
Sum squared resid	201.7474	Schwarz criterion		2.748343
Log likelihood	-307.8525	Hannan-Quinn criter.		2.739316
Durbin-Watson stat	1.872130			
Inverted AR Roots	.42			

Fig n° 07 fonctions d'autocorrélation et autocorrélations des résidus

Date: 05/30/15 Time: 09:34

Sample: 1996M02 2014M12

Included observations: 227

Q-statistic

probabilities

adjusted for 1

ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. .	. .	1	0.056	0.056	0.7271
. .	. .	2	-0.000	-0.004	0.7271
. .	. .	3	0.014	0.015	0.7745
. .	. .	4	0.024	0.023	0.9128
. .	. .	5	-0.023	-0.026	1.0352
. .	. .	6	0.032	0.035	1.2818
. .	. .	7	-0.007	-0.012	1.2949
. .	. .	8	0.015	0.017	1.3512
. .	. .	9	-0.043	-0.045	1.7900
. .	. .	10	-0.027	-0.024	1.9657
. .	. .	11	-0.050	-0.046	2.5566
. .	. .	12	-0.040	-0.037	2.9491
. .	. .	13	-0.014	-0.006	2.9959
. .	. .	14	-0.007	-0.007	3.0065
. .	. .	15	-0.006	-0.000	3.0168
. .	. .	16	-0.020	-0.020	3.1181
. .	. .	17	-0.034	-0.029	3.4005
. .	. .	18	-0.014	-0.011	3.4509

. .	. .	19	-0.044	-0.044	3.9322	1.000
. .	. .	20	-0.039	-0.036	4.3137	1.000
. .	. .	21	-0.003	-0.004	4.3161	1.000
. .	. .	22	-0.022	-0.026	4.4437	1.000
. .	. .	23	-0.025	-0.024	4.6074	1.000
. .	. .	24	-0.038	-0.039	4.9793	1.000
. .	. .	25	-0.049	-0.048	5.6055	1.000
. .	. .	26	-0.044	-0.042	6.0993	1.000
. .	. .	27	0.040	0.040	6.5074	1.000
. .	. .	28	-0.043	-0.055	6.9973	1.000
. .	. .	29	0.012	0.010	7.0338	1.000
. .	. .	30	-0.034	-0.045	7.3427	1.000