

Modélisation économétrique du Taux de Change Effectif Réel par le processus GARCH

Rakotoniaina Rabenoro Barry¹, Andriamanohisoa Hery Zo², Robinson Matio³

Ecole Doctorale en Science et Technique de l'Ingénierie et de l'Innovation (ED – STII)

Laboratoire de Sciences Cognitives et Applications (SCA)

Université d'Antananarivo

BP 1500, Ankatso – Antananarivo 101 – Madagascar

¹barryrakotoniaina2017@gmail.com, ²aheryzo@gmail.com, ³mat_robinson2000@yahoo.fr

Résumé

Les notions d'information et de connaissance semblent indissociables à l'économie. La question de savoir sur la base de quel modèle épistémique les économistes peuvent aborder le thème de l'information et de la connaissance. L'objectif de cette recherche est de modéliser la volatilité du taux de change de l'Ariary par rapport au Dollar Américain (MGA/Dollar US) et de prévoir ce taux pour l'année à venir. Notre étude a montré que notre série est caractérisée par le phénomène de volatilité, par des spécifications asymétriques et par la présence de kurtosis. Un test ARCH a été réalisé. Nous avons donc déduit qu'un modèle ARMA non linéaire de type ARCH est adéquat. Ainsi, le modèle (G)ARCH(1,1) est approprié pour la prévision.

Mots clés : Economie cognitive, taux de change, GARCH, prévision.

Abstract

The information's notion and knowledge seem to be consubstantial for the economy. In which epistemic model, the economists can proceed to the topic of information and knowledge. The objective of this research is to modelize the volatility of the Malagasy exchange rate toward the American dollar (MGA / US Dollar) and to predict the rate for the next year. Our study showed that our series is characterized by the volatility of the phenomenon, by asymmetric specification and by the presence of excessive kurtosis. ARCH test was performed. Therefore we have concluded that a nonlinear ARMA model type ARCH is adequate. So, the (G)ARCH(1,1) is a model as suitable one for the prediction.

Keywords: Cognitive economy, exchange rate, GARCH, Forecast.

1 Introduction

En 2016, l'économie mondiale n'a progressé que de 2,2%, soit le taux de croissance le plus faible depuis la Grande Récession de 2009. La progression lente de l'économie mondiale est marquée par un faible rythme de l'investissement mondial, un ralentissement de la croissance du commerce mondial et par des niveaux d'endettement élevés. Les prix bas des matières premières ont exacerbé ces facteurs dans de nombreux pays exportateurs de matières premières depuis mi-2014 [1]

La croissance économique de l'ensemble des PMA sera nettement insuffisante pour atteindre l'objectif de développement durable à court terme, même s'il est prévu qu'elle augmente légèrement, passant d'environ 4,5% en 2016 à 5,2% et à 5,5% en 2017 et 2018, respectivement. Ce taux insuffisant de croissance économique pose un risque pour les dépenses publiques, notamment dans des domaines importants tels que la santé, l'éducation, la protection sociale et l'adaptation au changement climatique. Ce dernier est d'autant plus important que les PMA restent très vulnérables aux catastrophes naturelles et aux chocs liés aux conditions météorologiques [1].

Des efforts supplémentaires sont également nécessaires pour diversifier les exportations des Pays les Moins Avancés (PMA), qui restent fortement concentrées dans un petit nombre de produits primaires, vulnérables à la volatilité des prix et aux chocs extérieurs.

Etablir des prévisions économiques n'est pas une science exacte. Les estimations peuvent varier d'un organisme à l'autre. Ces variations s'expliquent par des méthodes et des critères différents. Qui établit les prévisions économiques (INSTAT, Banque Centrale,...) ? Quels sont les méthodes et indicateurs utilisés ? ...Explications.

Les prévisions économiques peuvent porter sur l'économie générale d'un pays, (s'agissant en particulier des prévisions de croissance du produit intérieur brut – le PIB - et des prévisions d'inflation). Elles peuvent également se rapporter à un secteur d'activité en particulier et au domaine financier (taux d'intérêt, taux de change ...). Les prévisions économiques sont établies par des équipes d'économistes et de statisticiens qui utilisent différentes méthodes et se basent sur divers indicateurs économiques. Les prévisions économiques sont établies avec un horizon allant de 3 mois (prévisions court terme) à deux ans (prévisions long terme). Elles sont régulièrement mises à jour pour tenir

compte des grands événements économiques et politiques intervenus sur la période.

Les séries temporelles constituent une branche de l'économétrie dont l'objet est l'étude des variables au cours du temps. Parmi ses principaux objectifs figurent la détermination de tendances au sein de ces séries ainsi que la stabilité des valeurs (et de leur variation) au cours du temps. On distingue notamment les modèles linéaires (principalement AR et MA, pour Auto-Regressive et Moving Average) des modèles conditionnels (notamment ARCH, pour Auto-Regressive Conditional Heteroskedasticity).

Cependant, les séries temporelles comportent des volatilités variables c'est-à-dire des périodes agitées suivies par des périodes de calme relatif.

La fonction première pour laquelle il est intéressant d'observer l'historique d'une variable vise à en découvrir certaines régularités afin de pouvoir établir une prévision. Il s'agit de supposer que les mêmes causes produisent les mêmes effets. Avec une analyse fine, il est même possible d'établir des prévisions "robustes" vis-à-vis de ruptures brusques et de changements non anticipables.

Les séries ARIMA des séries chronologiques ne devraient être

considérées comme un dernier recours que pour la prévision ces types d'environnement, car ils fonctionnent mal principalement en raison des changements soudains et des modèles chaotiques de variables macroéconomiques dans les économies en développement [2].

En admettant que l'applicabilité du processus ARCH dans la prédiction de l'indicateur économique en contexte des Pays les Moins Avancés (PMA) soit efficace.

Dans cet article, la section 2 décrit les composantes chroniques de séries temporelles. La section 3 développe les méthodes d'analyse des séries temporelles : méthodes standard de traitement et techniques plus modernes (modèle ARMA, modèle ARIMA, et modèle ARCH).

La section 4 met en exergue l'étude empirique du Taux de Change Effectif Réel. Dans cet article, on s'intéressera à la simulation des ARCH/GARCH en utilisant le logiciel R 2.15.3. Et enfin, la section 5 est destinée pour la présentation des résultats.

2 Composantes chroniques

Les quatre composantes sont :

- Tendance (T) : allure de long-terme ;

- Cycle (C) : composante conjoncturelle ;
- Saison (S) : cycle répétitif défini sur l'année.
- Aléa (A) : dans le cas où l'aléa peut être identifié, il importe de corriger la série brute, pour éviter des perturbations qui peuvent être expliquées par une cause extérieure. Mais souvent l'aléa est causé par de multiples variables difficilement identifiables.

Il s'agit ici de créer des liens entre des variables, afin d'établir des comparaisons ainsi que des corrélations. Ainsi, on va pouvoir écarter certaines relations qui ne présentent aucun sens avec la série, ou au contraire associer d'autres relations qui interagissent avec la série observée.

- Déterminer la causalité : pour qu'un mouvement en provoque un autre, il est nécessaire qu'il le précède. Ainsi deux événements similaires révèlent l'existence probable d'une source commune. L'utilisation de retards d'une variable, va permettre à partir des valeurs aux périodes précédentes de deviner la durée de transmission entre une source et son effet ;
- Etudier des anticipations des agents : l'idée que l'on se fait de

l'avenir peut intervenir dans certaines équations. Il faut donc dans certaines équations faire intervenir des valeurs avancées des variables, en utilisant la manière dont elles ont été formées dans le passé ;

- Repérer les tendances et cycles : grâce aux tendances et aux cycles, il est ainsi possible d'analyser les interactions entre diverses variables, afin d'atteindre un équilibre ;
- Corriger des variations saisonnières
En comparant le niveau saisonnier entre deux années par exemple, on va pouvoir en déduire un comportement. Celui-ci apportera des informations supplémentaires indispensable afin d'affiner les valeurs saisonnières, et appréhender leurs évolutions ;
- Détecter les chocs structurels : un choc structurel est défini comme une modification permanente ou temporaire de la façon dont est générée une variable. Ils sont fréquents, souvent non anticipables et difficiles à mesurer. Cependant il est nécessaire de savoir qu'une rupture a eu lieu, car sa présence change les interactions et les équilibres ;

- Contrôler les processus Il est indispensable de dresser une carte des variables ayant une forte influence sur les reste de l'économie, afin d'anticiper les évolutions possibles.

On suppose généralement que l'interaction entre les composantes peut être représentée par :

- Un modèle additif

$$Y_i = T_i + C_i + S_i + A_i \quad (01)$$

- Un modèle multiplicatif

$$Y_i = T_i \times C_i \times S_i \times A_i \quad (02)$$

Les objectifs de la décomposition sont de

- Décrire la contribution de chaque composante dans le comportement temporel de la série ;
- Eliminer une (ou plusieurs) composante(s) pour mieux discerner le reste ;
- Prévoir le comportement futur de la variable en fonction des composantes systématiques principales de la série.

3 Modèle économétrique

Le but poursuivi est la formulation d'un modèle qui soit une représentation adéquate du processus qui a généré la série observée. Il faut bien comprendre la différence entre le processus qui génère

des données, sa réalisation telle qu'on l'observe sur les échantillons historiques à notre disposition, les futures réalisations et le modèle qu'on construit afin de tâcher de le représenter. Par représentation congruente, on entend un modèle qui soit conforme aux données sous tous les angles mesurables et testables.

L'économétrie est un outil qui permet d'infirmer ou de confirmer les théories qu'on construit. L'économétrie n'est pas seulement un système de validation, mais également un outil d'analyse [3].

a processus ARMA

Un processus Y_t est dit autorégressif d'ordre p et de moyenne mobile d'ordre q, s'il peut être représenté de la manière suivante :

$$\phi_0 Y_t - \dots - \phi_p Y_{t-p} = \theta_0 \varepsilon_t - \dots - \theta_q \varepsilon_{t-q} \quad (03)$$

$$\Leftrightarrow \Phi(L)Y_t = \Theta(L)\varepsilon_t$$

Où le polynôme $\Phi(L)$ et $\Theta(L)$ sont respectivement de degré p et q, avec :

$$\Phi(L) = \phi_0 - \phi_1 L - \dots - \phi_p L^p$$

$$\Theta(L) = \theta_0 - \phi_1 L - \dots - \theta_q L^q$$

Les coefficients ϕ_0, \dots, ϕ_p et $\theta_0, \dots, \theta_q$ sont des réels et ε_t un bruit blanc, alors que le L est un opérateur de retard.

b processus ARIMA

Il existe deux catégories de modèles pour rendre compte d'une série temporelle. Les premiers considèrent que les données sont une fonction du temps ($y = f(t)$). Cette catégorie de modèle peut être ajustée par la méthode des moindres carrés, ou d'autres méthodes itératives. L'analyse des modèles par transformée de Fourier est une version sophistiquée de ce type de modèle.

Une seconde catégorie de modèles cherche à déterminer chaque valeur de la série en fonction des valeurs qui la précède ($Y_t = f(Y_{t-1}, Y_{t-2}, \dots)$). C'est le cas des modèles ARIMA (AutoRegressive – Integrated – Moving Average). Cette catégorie de modèles a été popularisée et formalisée par Box et Jenkins (1976).

Un modèle ARIMA est étiqueté comme modèle ARIMA (p,d,q), dans lequel : p est le nombre de termes autorégressifs, d est le nombre de différences, et q est le nombre de moyennes mobiles.

Un processus (X_t) est un processus ARIMA (p,d,q) si le processus :

$$Y_t = \Delta^d X_t \quad (04)$$

est un processus ARMA (p,q).

Les processus ARIMA (p,d,q) sont donc bien adaptés aux séries temporelles

présentant une tendance polynômiale de degré d – 1.

Soit Δ_T l'opérateur qui fait passer de X_t à $(X_t - X_{t-T})$.

c processus ARCH et GARCH

Les séries étudiées étaient supposées stationnaires ou non-stationnaires mais étaient dans tous les cas homoscedastique c'est-à-dire avaient une variance constante dans le temps. Si besoin, tendances et saisonnalités étaient supprimées pour obtenir une série résiduelle stationnaire ou du moins une série à accroissements stationnaires. Néanmoins, toutes les séries résiduelles obtenues de la sorte ne sont pas nécessairement stationnaires : il peut arriver que la variance d'un processus varie au cours du temps.

Un processus ARCH(p) (AutoRegressive Conditional Heteroskedasticity) est défini par :

$$X_t = \varepsilon_t \quad (05)$$

Avec

$$\varepsilon_t | X_{t-1}, X_{t-2} \dots \sim N(0, \sigma_t^2)$$

Et

$$\sigma_t^2 = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_p X_{t-p}^2$$

Pour de nombreuses applications, l'introduction d'un grand nombre de retards p dans l'équation de la variance

conditionnelle du modèle ARCH (p) est nécessaire pour tenir compte de la longue mémoire de la volatilité. Ce nombre important de paramètres peut conduire à la violation de la contrainte de non-négativité de la variance et poser des problèmes d'estimations. Dans cette perspective, une extension importante, le modèle autorégressif conditionnellement hétéroscédastique généralisé (GARCH), est suggérée par Bollerslev [1986].

On considère un modèle autorégressif exprimé sous la forme :

$$X_t = E(X_t|I_{t-1}) + \varepsilon_t \quad (06)$$

Avec ε_t est un bruit blanc faible qui satisfaisant la propriété $E(\varepsilon_t|I_{t-1}) = 0$

$$\varepsilon_t = \hat{\eta}_t h_t \quad (07)$$

L'équation de la variance conditionnelle d'un processus GARCH s'écrit :

$$h_t = \sqrt{\alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}^2}$$

Où $\hat{\eta}_t \sim N(0, \sigma^2)$, avec les conditions $\alpha_0 > 0$, $\alpha_i > 0$ pour $i=1,2,\dots,p$ et $\beta_j > 0$, pour $j=1,2,\dots,q$ satisfaisantes pour garantir la positivité de $\alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}^2$

4 Modélisation du Taux de Change Effectif Réel (TCER)

Quoi ?

Quel est le sujet de la recherche ? De quoi s'agit-il ? Taux de change.

Qui ?

Qui sont les acteurs impliqués ? La Banque Centrale de Madagascar, Intermédiaires agréés, Bureaux de changes.

Quand ?

De quelle période temporelle parle-t-on ? Année 2008 jusqu'au 2014.

Pourquoi ?

Quelles sont les raisons de l'existence de ce sujet ? Les taux de change, cotés sur le marché des changes, varient en permanence.

Où ?

Quelle est la délimitation géographique de la recherche ? Madagascar.

Comment ?

Quel est le fonctionnement ? Grâce à une expérience scientifique.

Le taux de change effectif est le taux de change d'une zone monétaire, mesuré comme une somme pondérée des taux de change avec les différents partenaires commerciaux et concurrents [5].

On mesure le taux de change effectif nominal avec les parités nominales (sans prendre donc en compte les différences de pouvoir d'achat entre les deux devises), et le taux de change effectif réel, avec la prise en compte pour ce dernier des indices de prix et de leurs évolutions.

La représentation graphique de la série étudiée permet de comprendre la structure d'une série temporelle et de guider sa modélisation éventuelle.




Figure 01 : Exploration des données

TCER mensuel 84 mois

L'observation synthétique à travers la statistique descriptive donne les informations suivantes :

```
> numSummary(Donnée_TCER["TCER"], statistics=c("mean", "sd", "IQR",
+ "quantiles", "cv", "skewness", "kurtosis"), quantiles=c(0,.25,.5,.75,1),
+ type="2")
  mean    sd  IQR    cv skewness kurtosis 0% 25% 50%
1 108.6476 6.378134 7.125 0.05870478 -0.5621712 -0.527831 94.1 105.45 110.1
  75% 100% n
112.575 118.8 84
```

5 Résultats

La décomposition du taux de change mensuel présente la tendance, la saisonnalité et l'erreur. La figure met en exergue les points suivants : le taux de change mensuel brut, la tendance, la composante saisonnière et l'erreur. Février 2009 est marqué par un trait vertical.




Figure 0.2 : TCER mensuel et sa décomposition additive

Pour mieux comprendre la saisonnalité, le month plot du taux de change a offert plus de détail :




Figure 03 : Month plot du TCER du janvier 2008 à décembre 2014

L'observation montre, d'une part une forte saisonnalité, d'autre part un changement de régime après le 07 Février 2009. En essayant de représenter le changement en comparant les lag plots des séries avant le Février 2009 et après.

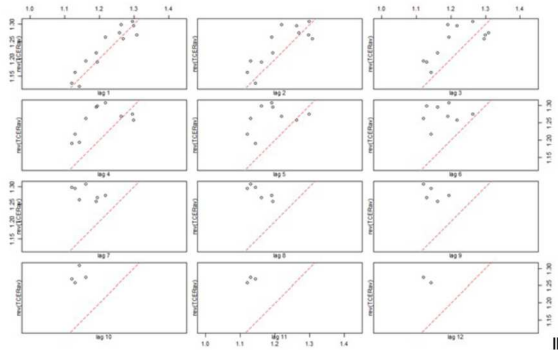


Figure 04 : Lag plot du TCER avant Mars 2009

- Après « Mars 2009 »

```
Series: TCERapr
ARIMA(0,1,0)(1,1,1)[12]

Coefficients:
      sar1      sm1
      -0.6458  -0.3209
s.e.      0.1515  0.2190

sigma^2 estimated as 0.0007446: log likelihood=118.24
AIC=-230.49  AICc=-230.04  BIC=-224.36

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE
Training set 0.001936997 0.02463039 0.01723954 0.1437845 1.301848 0.2974188
              ACF1
Training set 0.01103474
```

Le critère AIC est retenu. L'appel à la commande «auto.arima()» sélectionne le meilleur modèle pour ce critère.

Les processus ARIMA et leur version saisonnière SARIMA sont des processus non stationnaires qui reviennent, après différenciation simple ou saisonnière, à des processus ARMA ou SARMA.

La série y_t vérifiant :

$$(1 - B)(1 - B^{12})y_t = 0 + \frac{(1 + \theta_1 B^{12})}{(1 - \phi_1 B^{12})} z_t \quad (08)$$

En remplaçant les valeurs de θ_1 et ϕ_1 on obtient :

$$(1 - B)(1 - B^{12})y_t = 0 + \frac{(1 + 0,3209B^{12})}{(1 - 0,6458B^{12})} z_t$$

Où

$$y_t = \frac{(1 + 0,3209B^{12})}{(1 - B)(1 - B^{12})(1 - 0,6458B^{12})} z_t$$

Les paramètres du modèle étant estimés (on vérifie la convergence de la procédure

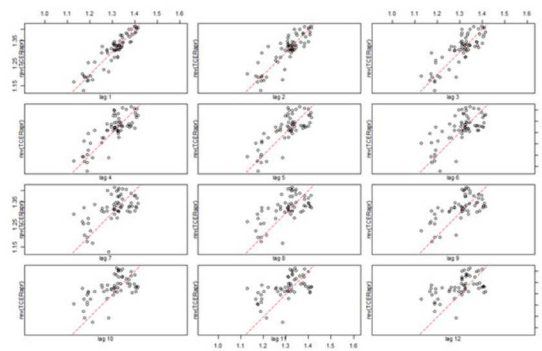


Figure 05 : Lag plot du TCER après Mars 2009

En somme, le taux de change mensuel est une série croissante qui présente un aspect saisonnier. Le lundi noir en Février 2009 a modifié l'évolution de cette série : tendance moins marquée après qu'avant, autocorrélations au retard 1, moins fortes après qu'avant.

Les paramètres sont :

- avant « Mars 2009 »

```
Series: TCERav
ARIMA(0,0,0)(0,1,0)[12] with drift

Coefficients:
      drift
      0.0113
s.e.      0.0014

sigma^2 estimated as 0.0003858: log likelihood=5.02
AIC=-6.04  AICc=-18.04  BIC=-8.66

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE
Training set 0.0009795274 0.007499371 0.00378565 0.07922373 0.3022269
              MASE      ACF1
Training set 0.02801715 -0.5010247
```

itérative d'estimation), les résultats d'estimation se présentent comme suit :

- Les tests de Dickey-Fuller (DF) permettent de mettre en évidence le caractère stationnaire ou non d'une chronique par la détermination d'une tendance déterministe ou stochastique.

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression trend

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.057133 -0.014068 -0.001084  0.016875  0.053667

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.1786487  0.0972263   1.837  0.0711 .
z.lag.1     -0.1424899  0.0806365  -1.767  0.0823 .
tt           0.0003044  0.0002817   1.081  0.2842
z.diff.lag1  0.0526569  0.1375736   0.383  0.7033
z.diff.lag2 -0.1744676  0.1268928  -1.375  0.1743
z.diff.lag3 -0.0350504  0.1226768  -0.286  0.7761
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02488 on 60 degrees of freedom
Multiple R-squared:  0.1235,    Adjusted R-squared:  0.05044
F-statistic:  1.69 on 5 and 60 DF,  p-value: 0.1507

Value of test-statistic is: -1.7671 1.5941 1.7636

Critical values for test statistics:
 1pct 5pct 10pct
tau3  -4.04 -3.45 -3.15
phi2   6.50  4.88  4.16
phi3   8.73  6.49  5.47
```

Sur ces données, on obtient trois statistiques, la première relative au test de racine unité, et les deux suivantes aux tests sur la constante, et sur la tendance (la pente de l'ajustement linéaire). La valeur de test (-1,7671) excède les valeurs critiques : la p-value serait ici supérieur à 10%. On va accepter l'hypothèse de racine unité.

- Puis z_t est un bruit blanc gaussien et testons la blancheur de chaque série en calculant la statistique de Ljung-Box.

		Retard p-value.y1	Retard p-value y2
[1.]	3	0.18	0.71
[1.]	6	0.26	0.83
[1.]	9	0.54	0.94
[1.]	12	0.53	0.83

On voit qu'on retient la blancheur des séries y_1 et y_2 si on arrête à un ordre inférieur à 12, on croit que la série est un bruit blanc. Aucun de ces éléments n'est égal à 0.

- ARCH et test d'hétéroscédasticité : la simulation des ARCH/GARCH se fait à l'aide de garchSim() de fGarch et le modèle à simuler est défini par garchSpec()

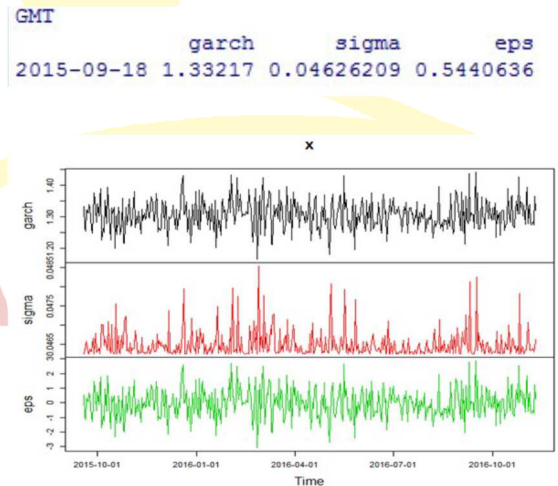


Figure 06 : Simulation ARCH(1)

```

Call:
garch(x = cac)

Model:
GARCH(1,1)

Residuals:
    Min       1Q   Median       3Q      Max
-3.06981 -0.44293  0.04861  0.80461  2.54508

Coefficient(s):
      Estimate Std. Error t value Pr(>|t|)
a0 3.367e-04  4.380e-04  0.769  0.442
a1 1.926e-01  3.257e-01  0.591  0.554
b1 2.537e-16  1.224e+00  0.000  1.000

Diagnostic Tests:
Jarque Bera Test

data: Residuals
X-squared = 1.581, df = 2, p-value = 0.4536

Box-Ljung test

data: Squared.Residuals
X-squared = 0.1789, df = 1, p-value = 0.6723

Call:
garch(x = TCERapr, order = c(1, 1))
    
```

```

Model:
GARCH(1,1)

Residuals:
    Min       1Q   Median       3Q      Max
 0.8698  0.9195  0.9343  0.9464  0.9716

Coefficient(s):
      Estimate Std. Error t value Pr(>|t|)
a0 4.882e-01  3.994e+01  0.012  0.990
a1 8.694e-01  3.873e+01  0.022  0.982
b1 1.362e-14  4.453e+01  0.000  1.000

Diagnostic Tests:
Jarque Bera Test

data: Residuals
X-squared = 6.46, df = 2, p-value = 0.03956

Box-Ljung test

data: Squared.Residuals
X-squared = 9.718, df = 1, p-value = 0.001825
    
```

```

Std. Errors:
based on Hessian

Error Analysis:
      Estimate Std. Error t value Pr(>|t|)
mu    -0.0008420  0.0017455  -0.482  0.6295
omega 0.0002393  0.0001300  1.841  0.0656
alpha 0.1126161  0.0519257  2.169  0.0301 *
beta1 0.7141331  0.1192471  5.989 2.12e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
758.0524 normalized: 1.895131

Description:
Fri Nov 25 04:10:26 2016 by user: aina elie

Standardised Residuals Tests:
      Statistic p-Value
Jarque-Bera Test R Chi^2 0.2377177 0.8879331
Shapiro-Wilk Test R W 0.9969834 0.6707816
Ljung-Box Test R Q(10) 10.50595 0.39728
Ljung-Box Test R Q(15) 16.3783 0.3573648
Ljung-Box Test R Q(20) 25.51575 0.182407
Ljung-Box Test R^2 Q(10) 6.525361 0.7693645
Ljung-Box Test R^2 Q(15) 13.01832 0.6008829
Ljung-Box Test R^2 Q(20) 17.07081 0.6483707
LM Arch Test R TR^2 6.418029 0.8935618

Information Criterion Statistics:
      AIC BIC SIC HQIC
-3.770262 -3.730347 -3.770459 -3.754455
    
```

ϵ_t est un processus GARCH (1,1)
 où $z_t \sim iidN(0,1)$ indépendant
 de $F_{t-1} \forall t$.

Les coefficient(s) :

mu	omega	alpha	beta1
0.00241	0.00035	0.00000	0.59952
618	995	001	969

Et la variance marginale par
 substitution est :

Variance marginale = 0,001381106

L'examen du résumé de l'estimation donne le résumé suivant : la non-normalité, visible sur les p-values des tests de Jarque-Bera Test et Shapiro-Wilk, demeure évidemment et doit rendre prudents sur les estimations Std. Error fournies. En revanche, le modèle a bien capté l'hétéroscédasticité.

L'estimation est positive, ce qu'on préfère obtenir. Le contraire, signe que le modèle ajusté ne convient pas, serait étonnant après avoir ajusté sur des données simulées le modèle ayant servi à la simulation elle-même.

Le modèle GARCH se présente comme suit :

$$y_t = 0.00241618 + \varepsilon_t$$

$$\varepsilon_t = \sigma_t z_t$$

$z_t \sim iidN(0, \sigma_t^2)$ Independent de $F_{t-1} \forall t$

$$\sigma_t^2 = 0.00035995 + 0.00000001 \varepsilon_{t-1}^2 + 0.5995 \cdot 2969 z_{t-1}^2$$

Examinons graphiquement la qualité de l'ajustement à l'aide de `garchFit()` nous indique que `plot()`,




Figure 07 : Trajectoire estimée et bande de deux écarts types conditionnels.

Nous allons superposer sur un même graphique : la série à prédire et les intervalles de prévision (à 90%) par un ARMA et par un GARCH.

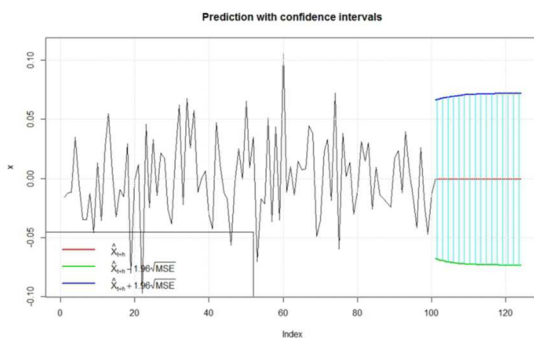


Figure 08 : Affichage de la prédiction du modèle GARCH


5 Conclusion

L'application de méthodes économétriques fournit des estimations sur la valeur des coefficients ainsi que la précision attendue.

Ainsi, cette étude a montré que notre série est caractérisée par le phénomène de volatilité, par des spécifications asymétriques et d'une présence de kurtosis excessive. Nous avons effectué un test ARCH qui a rejeté l'hypothèse nulle d'homoscédasticité. De cela, nous avons déduit qu'un modèle ARMA non linéaire de type ARCH est adéquat.

En vue de comparer les prévisions, nous avons calculé les intervalles de prévision basés sur la modélisation initiale qui ignore l'hétéroscédasticité. Habituellement on calcule des intervalles à 95%. Or, pour se représenter la qualité d'un ajustement ou d'une prédiction, on compare la proportion de points observés dans un intervalle à la proportion théorique.

Si l'on fait ce calcul sur un nombre limité d'observations, moins de 50 par exemple, les nombres sont très petits ; c'est pourquoi nous examinons des intervalles à 80%.



Université Lyon 2, 2017[5] INSEE, Taux de change effectif nominal et réel, 2016

Figure 09 : TCER : intervalles de prévision (ARMA et GARCH) à 80% et réalisation

Nous observons que l'intervalle qui incorpore l'hétéroscédasticité conditionnelle est un peu plus large que celui qui l'ignore, mais que la série reste largement à l'intérieur des deux intervalles.

Références

[1] Nations Unies, situation et perspectives de l'économie mondiale 2017, New York, 2017

[2] Chuku CHUKU, Jacob Oduor et Anthony Simpasa, Intelligent forecasting of economic growth for African economies: Artificial neural networks versus time series and structural econometric models, African Development Bank, 2017

[3] Régis BOURBONNAIS, Econométrie: cours et exercices corrigés, Dunod, 9^e édition, 2015[4] Julien JACQUES, introduction aux séries temporelles,