

Prévision des prix de vente des produits agricoles par la méthode de Box et Jenkins: cas des tomates

[Forecast of selling price of agricultural products by the method of Box and Jenkins: case of tomatoes]

Hiderah Kamal¹, Youssfi Elkettani¹, Mohsine Benabdallah¹, and D. Driouchi²

¹Département de mathématique et informatique, Université Ibn Tofail, Kenitra, Maroc

²Département Mathématique et Informatique, Université Mohamed 1er d'Oujda, Maroc

Copyright © 2015 ISSR Journals. This is an open access article distributed under the *Creative Commons Attribution License*, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT: This paper is concerned with calculation of the forecasting of some agricultural products (tomatoes in the market of Oujda-Morocco). In the first section deals with the theoretical part of time series, and Box and Jenkins method. The second section is about calculating the forecasting for cycle 12/2013-7/2014. We analyze the time series using the following statistical programs: Excel, SPSS, and Eviews7. At the end, we have chosen the appropriate model for the prediction of tomato prices, in the market of fruits and vegetables of Oujda.

KEYWORDS: Forecasting, ARIMA, Box and Jenkins, Dickey and Fuller.

RÉSUMÉ: Cet article est consacré au calcul de la prévision de certains produits agricoles (tomates dans le marché d'Oujda-Maroc). Dans la première section nous avons parlé des propriétés théoriques de séries chronologiques, et de la méthode de Box et Jenkins. Dans la deuxième section nous avons calculé de la prévision pour le cycle 12/2013-7/2014. Nous avons analysé les séries chronologiques à l'aide des programmes statistiques suivantes: Excel, SPSS, Eviews7. A la fin, nous avons choisi le modèle approprié pour la prédiction des prix des tomates, dans le marché des fruits et légumes d'Oujda.

MOTS-CLEFS: Prévision des prix, produits agricoles, Box et Jenkins, tomates.

1 INTRODUCTION

La prédiction a une grande importance pour l'Etat, les institutions et les entreprises pour connaître la nature de l'avenir, et ainsi de prendre les précautions nécessaires, rendant la poussée en avant plus stable et plus sûr, et nous pouvons résumer l'importance de prévoir comme suit:

- 1- La prédiction est la base pour la planification.
- 2- La prédiction est la base de la décision administrative et est un lien entre l'institution et ses environs.
- 3- La prédiction aide à trouver une cohérence, de l'intégration et de la coordination entre les parties de l'installation.
- 4- La prédiction aide à établir sur la base plus efficacement pour atteindre ses objectifs pour l'avenir.

Il faut souligner que la prédiction est basée clairement et précisément sur l'analyse des données du passé. Donc, Il n'est pas une action aléatoire ou irréaliste, ou des souhaits qui ne sont pas fondés sur des faits et de l'expérience. Mais pour

prédire, une certaine marge d'erreur peut se produire. L'exactitude absolue ne peut jamais être atteinte dans la prédiction. À la lumière de ce qui précède, nous pouvons nous référer à ce qui suit:

1. Les méthodes de prévision supposent généralement que les principaux facteurs dans le passé continueront à l'avenir.
2. Les prévisions sont rarement complètes. Les résultats réels sont généralement différents des valeurs estimées par le prévisionniste.

2 PARTI THÉORIQUE

2.1 PROCESSUS STATIONNAIRE

Un processus est stationnaire du second si:

$$\begin{aligned} \forall t \in \mathbb{Z}, E(X_t^2) < \infty \\ \forall t \in \mathbb{Z}, E(X_t) = m \\ \forall t \in \mathbb{Z}, \forall h \in \mathbb{Z}, \text{Cov}(X_t, X_{t+h}) = \gamma(h) \end{aligned} \tag{1}$$

2.2 BRUIT BLANC

Un bruit blanc $\{\varepsilon_t\}$ est un processus stationnaire tel que

$$\begin{aligned} E(\varepsilon_t) = m, \forall t \\ \text{Var}(\varepsilon_t) = \sigma^2, \forall t \\ \text{Cov}(\varepsilon_t, \varepsilon_{t-h}) = \gamma(h), \forall t, \forall h > 0 \end{aligned} \tag{2}$$

Cette notion de bruit blanc correspond aux hypothèses habituelles faites sur les résidus en régression multiple. Les variables aléatoires ε_t sont aussi appelées chocs aléatoires. On suppose implicitement que les chocs aléatoires ε_t suivent une loi normale $N(0, \sigma^2)$

2.3 AUTOCORRÉLATION

La fonction d'autocorrélation est l'application ρ de \mathbb{Z} dans \mathbb{R} définie par:

$$\rho(h) = \frac{\gamma(h)}{\gamma(0)}, h \in \mathbb{Z} \tag{3}$$

$\rho(h)$ mesure la corrélation entre X_t et X_{t+h} , puisque:

$$\frac{\text{Cov}(X_t, X_{t+h})}{\sqrt{V(X_t)}\sqrt{V(X_{t+h})}} = \frac{\gamma(h)}{\sqrt{\gamma(0)}\sqrt{\gamma(0)}} = \frac{\gamma(h)}{\gamma(0)}, h \in \mathbb{Z} \tag{4}$$

Comme la fonction d'autocovariance, la fonction $(\rho(h), h \in \mathbb{Z})$ est paire et de type positif. Elle satisfait de plus condition $\rho(0) = 1$.

2.4 AUTOCORRÉLATION PARTIELLE

La fonction d'autocorrélation partielle de retard k est définie comme le coefficient de corrélation partielle entre X_t et X_{t-k} l'influence des autres variables décalée de k périodes $(X_{t-1}, X_{t-2}, \dots, X_{t-k+1})$ ayant été retirée.

2.5 DÉCOMPOSITION D'UN PROCESSUS STATIONNAIRE

Théorème I.1 Wold(1938) a montré que tout processus stationnaire centré $\tilde{X}_{t-k} = X_t - \mu$ peut s'écrire comme combinaison linéaire de bruits blanc ε_t .

$$\tilde{X}_t = \varepsilon_t + \psi_1 \varepsilon_{t-1} + \psi_2 \varepsilon_{t-2} + \dots = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \psi_0 = 1 \tag{5}$$

La fonction d'autocorrélation ρ_k du processus X_t peut se calculer en fonction des poids ψ_k :

$$\rho_k = \frac{\sum_{j=0}^{\infty} \psi_j \psi_{j+k}}{\sum_{j=0}^{\infty} \psi_j^2} \tag{6}$$

La convergence des séries est assurée si

$$\sum_{j=0}^{\infty} |\varphi_j| < \infty \tag{7}$$

Cette condition est vérifiée si le processus X_t est stationnaire. Réciproquement, elle assure qu'un processus construit à l'aide de l'équation (5) en partant d'un bruit blanc ε_t est stationnaire.

2.6 PROCESSUS AUTORÉGRESSIF AR(p)

Soit un processus $(X_t, t \in \mathbb{Z})$, X_t est dit processus autorégressif d'ordre p (AR(p)) si

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t \tag{8}$$

Où ε_t un bruit blanc et $\varphi_1, \varphi_2, \dots, \varphi_p$ sont constantes.

2.7 PROCESSUS MA(q)

Soit un processus $(X_t, t \in \mathbb{Z})$, X_t est dit processus autorégressif d'ordre q (MA(q)) si

$$X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \tag{9}$$

Où ε_t un bruit blanc et $\theta_1, \theta_2, \dots, \theta_q$ sont constantes.

2.8 LES PROCESSUS AUTOREGRESSIFS MOYENNES MOBILES (ARMA)

Un processus stationnaire X admet un représentation ARMA(p,q) minimale s'il satisfait:

$$\begin{aligned} \Phi(L) X_t &= \Theta(L) \varepsilon_t, \text{ et :} \\ \Phi(L) X_t &= X_t + \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} \\ \Theta(L) X_t &= \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \end{aligned} \tag{10}$$

- Où I) $\varphi_p \neq 0, \theta_q \neq 0$ et $L(X_t) = X_{t-1}$
 II) les polynômes Θ et Φ ont leurs racines démodules strictement supérieurs à 1.
 III) Θ et Φ n'ont pas de racines communes.
 IV) $\varepsilon = (\varepsilon_t, t \in \mathbb{Z})$ est un bruit blanc, de variance $V(\varepsilon_t) = \sigma^2 \neq 0$.

2.9 PROCESSUS ARIMA

Un processus $X = (X_t, t \geq 0)$ est un processus ARIMA (p,d,q)[autorégressif moyenne mobile intégré] S'il satisfait une équation du type:

$$(1 - \sum_{i=1}^p \phi_i L^i)(1 - L)^d X_t = \delta + (1 + \sum_{i=1}^q \theta_i L^i) \varepsilon_t, t \geq 0 \tag{11}$$

Où δ constante $L(X_t) = X_{t-1}$ et ε_t est bruit blanc.

2.10 LES PROCESSUS SARIMA

Une série X_t suit un processus SARIMA (Seasonnal AutoRegressive Integrated Moving Average) d'ordre $(p, d, q)(P, D, Q)_s$ si cette série a une saisonnalité de période s et qu'on peut écrire:

$$\varphi(L)\Phi(L^s)[(1 - L)^d (1 - L^s)^D] X_t = \theta(L)\Theta(L^s)\varepsilon_t \tag{12}$$

Où φ est un polynôme de degré p, Φ est de degré P, θ est de degré q et Θ est de degré Q.

2.11 TEST DE DICKEY ET FULLER AUGMENTE (A.D.F)

Le test de Dickey et Fuller (ADF) est un test de racine unitaire qui l'hypothèse nulle de racine unitaire(ou de non-stationnarité).

Le test ADF estime trois modèles:

$$\begin{cases} \Delta X_t = \alpha_1 X_{t-1} + \sum_{j=1}^p \beta_j \Delta X_{t-j} + \varepsilon_t \\ \Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + \sum_{j=1}^p \beta_j \Delta X_{t-j} + \varepsilon_t \\ \Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + \sum_{j=1}^p \beta_j \Delta X_{t-j} + \delta_t + \varepsilon_t \end{cases} \tag{13}$$

L'hypothèse nulle de test ADF est l'hypothèse de racine unitaire de la variable X_t soit l'hypothèse $H_0 : \alpha_1 = 0$. Le test ADF consiste à comparer la valeur estimée t de Student associé au paramètre α_1 aux valeurs tabulées de cette statistique. Les valeurs tabulées pour ce test différent cependant des valeurs tabulées du test de Student. Les valeurs critiques de cette statistique, notée ADF dans ce qui suit, sont données par MacKinnon(1996). L'hypothèse nulle H_0 de non stationnarité de la série temporelle est rejetée au seuil de 5% lorsque la valeur observée du t de Student est inférieure à la valeur critique tabulée par MacKinnon (1996) ou $t_{abs} < ADF_{0.05}$.

Test sur la variable en niveau

H_0 : Racine unitaire (non stationnaire)

H_1 : Non racine unitaire (stationnaire).

2.12 LE TEST DE SAISONNALITE DE FISHER

Il convient d'effectuer un test permettant de détecter l'existence d'une saisonnalité avant d'effectuer sur série temporelle une correction de variations saisonnières. Le test le plus communément utilisé est celui de Fisher par analyse de la variance du facteur mensuel (ou trimestriel) par rapport à la variance totale. Ce test se présente comme suit :

- Calcul de la somme U^* des carrés du modèle avec tendance simple.
- Calcul de la somme U^{**} des carrés du modèle avec tendance et saisonnalité.
- Calcul de la valeur du Fisher empirique:

$$F^* = \frac{U^* - U^{**}}{K - P} / \frac{U^{**}}{T - K} \quad (14)$$

La valeur du F^* empirique est à comparer à la valeur du F théorique donné par la table de la loi de Fisher-Snedecor aux degrés de liberté K - P et T - K, avec :

- K, le nombre de paramètres indépendants à estimer dans le cadre du modèle avec tendance et saisonnalité.
- P, le nombre de paramètres à estimer dans le cadre du modèle à tendance seule, P=2.
- T est le nombre d'observations.

TEST D'HYPOTHÈSE

H_0 : Il y a saisonnalité

H_1 : Il n'y a pas saisonnalité

Note: on rejette H_0 si $F^* \leq F$

2.13 METHODOLOGIE DE BOX ET JENKINS

La démarche peut être résumée par l'organigramme ci-dessous (voir [2]).




Figure 1: Méthode de Box et Jenkins

3 APPLICATION SUR DES PRIX DE LA VENTE DES TOMATES DANS LE MARCHÉ DE GROS D'OUJDA

La série chronologique suivante représente les prix des tomates dans le marché de gros d'OUJDA 1/2010-11/2013.

| Mois | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
|------|------|------|------|------|------|------|------|------|------|------|------|------|
| 2010 | 3,00 | 6,00 | 7,50 | 12 | 8,50 | 4,00 | 2,20 | 1,80 | 2,50 | 5,00 | 6,60 | 6,00 |
| 2011 | 5,0 | 4,5 | 4,0 | 2,0 | 2,0 | 2,5 | 2,5 | 4,0 | 2,5 | 2,0 | 1,5 | 3,6 |
| 2012 | 5,00 | 2,50 | 4,00 | 2,80 | 2,50 | 3,80 | 3,00 | 2,50 | 2,75 | 6,00 | 2,80 | 7,00 |
| 2013 | 3,50 | 3,60 | 2,30 | 2,70 | 3,35 | 3,80 | 2,70 | 2,50 | 3,38 | 3,80 | 3,00 | |

3.1 LE GRAPHE

On trace le graphe de la série de prix de tomate sur programme SPSS, on obtient le graphe suivant:




Figure 2: graphe des médianes mensuelles des prix des tomates

3.2 TEST DE DICKEY-FULLER

Pour savoir la stationnarité des prix des tomates, nous utilisons le test de Dickey-Fuller.

- On applique test Dickey et Fuller sur programme EViews7, on obtient que:

Null Hypothesis: PRIX has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=9)

| | t-Statistic | Prob.* |
|--|-------------|--------|
| Augmented Dickey-Fuller test statistic | -3.936616 | 0.0182 |
| Test critical values: | | |
| 1% level | -4.170583 | |
| 5% level | -3.510740 | |
| 10% level | -3.185512 | |

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(PRIX)
 Method: Least Squares
 Date: 03/07/15 Time: 17:03
 Sample (adjusted): 2010M02 2013M11
 Included observations: 46 after adjustments

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|-----------------|-------------|------------|-------------|--------|
| PRIX(-1) | -0.515844 | 0.131038 | -3.936616 | 0.0003 |
| C | 2.752687 | 0.836080 | 3.292373 | 0.0020 |
| @TREND(2010M01) | -0.032444 | 0.019801 | -1.638492 | 0.1086 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.265787 | Mean dependent var | 0.000000 |
| Adjusted R-squared | 0.231637 | S.D. dependent var | 1.902459 |
| S.E. of regression | 1.667626 | Akaike info criterion | 3.923672 |
| Sum squared resid | 119.5819 | Schwarz criterion | 4.042931 |
| Log likelihood | -87.24446 | Hannan-Quinn criter. | 3.968347 |
| F-statistic | 7.783036 | Durbin-Watson stat | 1.772279 |
| Prob(F-statistic) | 0.001304 | | |

Figure 3: Test de Dickey-Fuller

On note (sig= 0.0182 < 0.05), donc le test est significatif c'est-dire: La série est stationnaire.

3.3 ANALYSE LA SAISONNALITÉ

Pour savoir la saisonnalité des prix des tomates, on applique test **F-tests for seasonality** sur programme EViews7, on obtient que:

D 8.A F-tests for seasonality

Test for the presence of seasonality assuming stability.

| | Sum of Squares | Dgrs.of Freedom | Mean Square | F-Value |
|----------------|----------------|-----------------|-------------|---------|
| Between months | 25476.4038 | 11 | 2316.03671 | 1.679 |
| Residual | 48281.5688 | 35 | 1379.47339 | |
| Total | 73757.9726 | 46 | | |

No evidence of stable seasonality at the 0.1 per cent level.

Nonparametric Test for the Presence of Seasonality Assuming Stability

| Kruskal-Wallis Statistic | Degrees of Freedom | Probability Level |
|--------------------------|--------------------|-------------------|
| 15.6893 | 11 | 15.306% |

No evidence of seasonality at the one percent level.

Moving Seasonality Test

| | Sum of Squares | Dgrs.of Freedom | Mean Square | F-value |
|---------------|----------------|-----------------|-------------|---------|
| Between Years | 1772.8119 | 2 | 886.405927 | 2.007 |
| Error | 9715.2610 | 22 | 441.602772 | |

No evidence of moving seasonality at the five percent level.

Figure 4: F-tests for seasonality

On note qu'il n'y a pas la saisonnalité.

3.3.1 AUTOCORRÉLATION ET AUTOCORRÉLATION PARTIELLE




Figure 6: Corrélogrammes d'autocorrélation

3.3.2 AUTOCORRÉLATION PARTIELLE

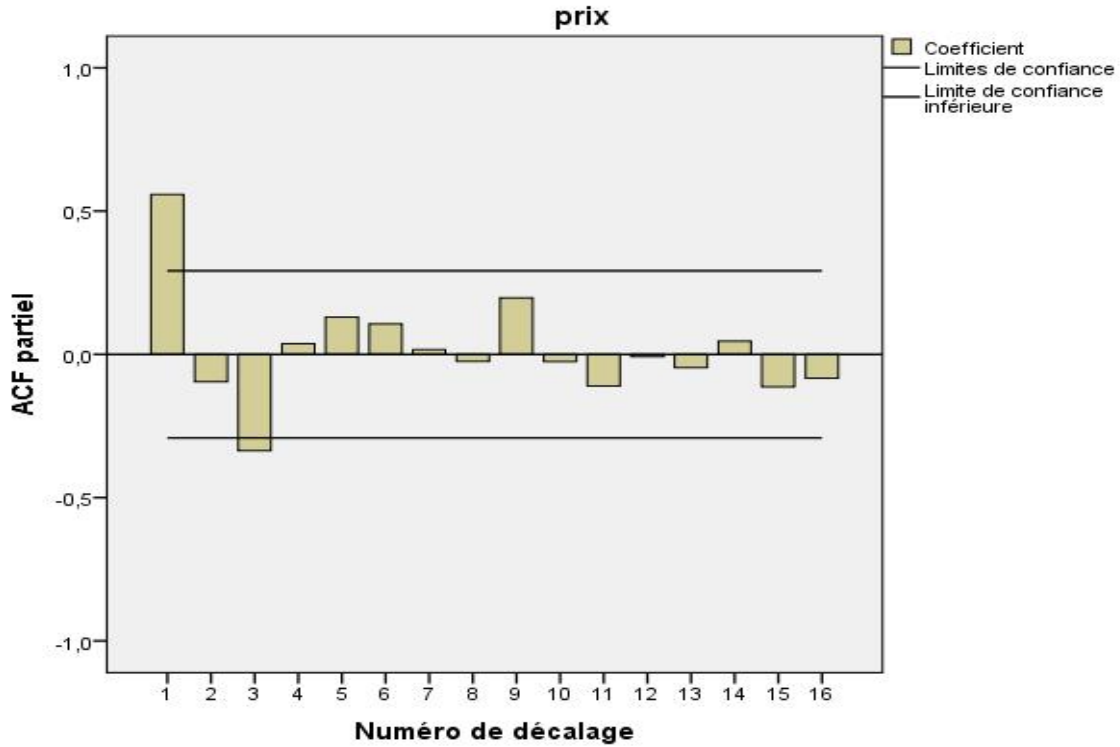


Figure 7: Corrélogrammes autocorrélation partielle

3.4 DETERMINATION DES ORDRES (P) ET (Q) DU PROCESSUS ARIMA

On utilise la fonction d'autocorrélation et d'autocorrélation partielles, pour obtenir le modèle proposé suivant: ARIMA (3,0,1). Quand, on applique le modèle sur SPSS, nous obtenons :

3.5 ESTIMATION DES PARAMÈTRES

Le tableau suivant présente le test de Ljung-Box:

Estimation des paramètres

| Modèle | Nombre de variables indépendantes | Statistiques de qualité d'ajustement du modèle | | | Ljung-Box Q(18) | | | Nombre de valeurs éloignées |
|-------------|-----------------------------------|--|-------|-----------------|-----------------|-----|------|-----------------------------|
| | | R-deux stationnaire | MaxAE | BIC standardisé | Statistiques | DDL | Sig. | |
| prix-Modèle | 0 | ,405 | 5,509 | 1,378 | 9,452 | 14 | ,801 | 0 |

On note que (sig= 0,801 < 0,05), donc, l'hypothèse d'un bruit blanc pour les résidus est acceptable, c'est-à-dire, les résidus sont indépendants entre eux.

3.6 LES COEFFICIENTS DES MODÈLES

Le tableau suivant présente les coefficients de modèle ARIMA (3,0,1):

Paramètres du modèle ARIMA

| | | | | Estimation | SE | t | Sig. |
|---------------|------|-----------------------|----------|------------|------|--------|------|
| Constante | | | | 3,757 | ,338 | 11,121 | ,000 |
| prix-Modèle_1 | prix | Aucune transformation | AR Lag 1 | ,686 | ,380 | 1,808 | ,078 |
| | | | Lag 2 | ,048 | ,295 | ,163 | ,871 |
| | | | Lag 3 | -,360 | ,156 | -2,305 | ,026 |
| | | | MA Lag 1 | ,113 | ,413 | ,273 | ,786 |
| | | | | | | | |

3.7 LES COEFFICIENTS NON SIGNIFICATIFS

On note qu'il y a trois paramètres qui ne sont pas significatif, il doit supprimer le $q = 1$, $p = 2$.

Maintenant, nous essayons d'adapter le modèle de sorte qu'il devient significatif.

On choisit le modèle ARIMA (3,0,0) sans $p = 2$ (c'est-à-dire $p = (1, 3)$, $d = 0$, $q = 0$, avec constante). donc, le syntaxe du modèle ARIMA (3,0,0) sans $p = 2$ comme suit:

Quand, on applique le modèle sur SPSS, nous obtenons:

Table 2: le syntaxe du modèle ARIMA (3,0,0) sans $p = 2$

```

DATASET ACTIVATE Ensemble_de_données0.
PREDICT THRU END.
* Modélisateur de séries chronologiques.
TSMODEL
  /MODELSUMMARY PRINT=[MODELFIT]
  /MODELSTATISTICS DISPLAY=YES MODELFIT=[ SRSQUARE MAXAE NORMBIC]
  /MODELDETAILS PRINT=[ PARAMETERS RESIDACF RESIDPACF]
  /SERIESPLOT OBSERVED FORECAST
  /OUTPUTFILTER DISPLAY=ALLMODELS
  /SAVE PREDICTED(Prévisions)
  /AUXILIARY CILEVEL=95 MAXACFLAGS=24
  /MISSING USERMISSING=EXCLUDE
  /MODEL DEPENDENT=prix
  PREFIX='Modèle'
  /ARIMA AR=[3,1] DIFF=0 MA=[0] ARSEASONAL=[0] DIFFSEASONAL=0 MASEASONAL=[0]
  TRANSFORM=NONE CONSTANT=YES
  /AUTOOUTLIER DETECT=OFF.
    
```

3.8 ESTIMATION DES PARAMÈTRES

Le tableau suivant présente le test de Ljung-Box:

Estimation des paramètres

| Modèle | Nombre de variables indépendantes | Statistiques de qualité d'ajustement du modèle | | | Ljung-Box Q(18) | | | Nombre de valeurs éloignées |
|-------------|-----------------------------------|--|-------|-----------------|-----------------|-----|------|-----------------------------|
| | | R-deux stationnaire | MaxAE | BIC standardisé | Statistiques | DDL | Sig. | |
| prix-Modèle | 0 | ,399 | 5,622 | 1,177 | 9,087 | 16 | ,910 | 0 |

On note que (sig = 0,91 > 0,05), donc, l'hypothèse d'un bruit blanc pour les résidus est acceptable, c'est-à-dire, les résidus sont indépendants entre eux.

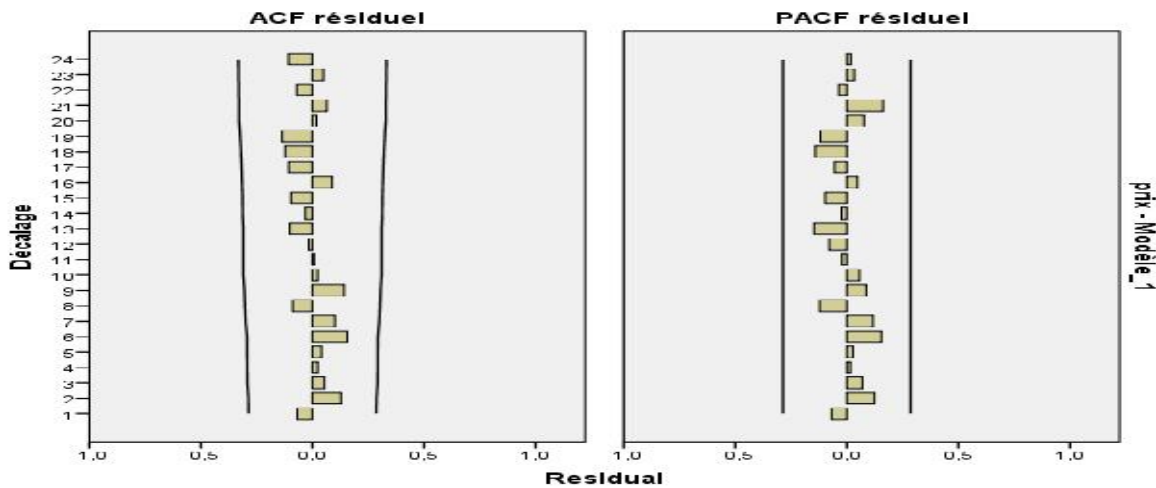
3.9 LES COEFFICIENTS SIGNIFICATIFS DU MODELE ARIMA (3,0,0) SANS P = 2

Le tableau suivant présente les coefficients significatifs des paramètres de modèle ARIMA (3,0,0) sans p = 2: Grâce au tableau ci-dessus, nous notons les paramètres du modèle sont significatifs et différents de 0, (SN < 0.05).

Paramètres du modèle ARIMA


| | | | | | Estimation | SE | t | Sig. |
|---------------|------|-----------------------|----------|--|------------|------|--------|------|
| Constante | | | | | 3,769 | ,343 | 10,978 | ,000 |
| prix-Modèle_1 | prix | Aucune transformation | AR Lag 1 | | ,635 | ,118 | 5,361 | ,000 |
| | | | AR Lag 3 | | -,314 | ,117 | -2,691 | ,010 |

3.10 TEST DES RÉSIDUELS



La fonction d'autocorrélation (ACF) et la fonction d'autocorrélation partielle (PACF) des résidus du modèle ARIMA(3,0,0) sans p = 2 sont toutes inférieures en valeur absolue au seuil critique. Nous acceptons donc ce modèle pour la série prix de tomate.

3.11 LE GRAPHE DE LA SERIE ET SA PREVISION



Aussi, il y a d'autres modèles par exemple les modèles suivants:

- ARIMA(1,0,0).
- ARIMA(0,0,1).
- ARIMA(3,1,0) sans p = 1, 2.
- ARIMA(4,1,0) sans p = 1, 2.

3.12 COMPAREZ LES MODELES ET CHOISISSEZ LE MEILLEUR D'ENTRE EUX

| Statistique de qualité de l'ajustement | ARIMA(4,1,0) sans p = 1, 2 | ARIMA(3,1,0) Sans p = 1, 2 | ARIMA(0,0,1) | ARIMA(3,0,0) Sans p = 2 | ARIMA (1,0,0) |
|--|----------------------------|----------------------------|--------------|-------------------------|---------------|
| R-deux | 0,259 | 0,208 | 0,240 | 0,399 | 0,313 |
| RMSE | 1,766 | 1,804 | 1,772 | 1,593 | 1,685 |
| MAPE | 34,439 | 36,596 | 36,391 | 31,583 | 33,905 |
| MAE | 1,267 | 1,359 | 1,285 | 1,123 | 1,209 |
| BIC standardisé | 1,304 | 1,264 | 1,308 | 1,177 | 1,207 |

Grâce au BIC standardisé, RMSE, MAPE, MAE dans le tableau ci-dessus, nous notons le modèle ARIMA(3,0,0) sans p = 2 est le meilleur.

3.13 L'EQUATION DE MODELE ARIMA(3,0,0) SANS P = 2

Nous constatons que l'équation mathématique du modèle (ARIMA(3,0,0) sans p = 2) défini par:

$$\hat{X}_t = 0.635(X_{t-1} - 3.769) - 0.314(X_{t-3} - 3.769) + 3.769$$

$$\hat{X}_t = 0.635X_{t-1} - 0.314X_{t-3} + 2.559$$

3.14 LA PREVISION PAR MEILLEUR MODELE

Ensuite, nous utilisons le modèle précédent pour calculer la prévision des prix des tomates pour la période du Décembre 2013 jusqu'à Juil. 2014 et les résultats étaient comme suit:

Table 4: Prévision

| Mois | Déc.13 | Jan.14 | Fév.14 | Mars.14 | Avr.14 | Mai.14 | Juin.14 | Juil.14 |
|-----------|--------|--------|--------|---------|--------|--------|---------|---------|
| Prévision | 3,40 | 3,53 | 3,86 | 3,94 | 3,95 | 3,86 | 3,77 | 3,71 |

REFERENCES

- [1] MBAYE Baïdy .analyse et prévision des séries temporelles par la méthode de Box et Jenkins.2007
- [2] Gourieroux Christian et Alain Monfort. Séries temporelles et modèle dynamiques1990.
- [3] D. Dickey. and Fuller W.The likelihood Ratio Statistics for Autoregressive Time(1981) Series With a unit Root", Econometrical ,n49.
- [4] Y .Dodge. Statistique Dictionnaire encyclopédique. Paris, 2007.
- [5] Avram .Florin. Séries temporelles : régression, modélisation ARIMA(p,d,q),et modélisation espace-état.2006.
- [6] S .Gilbert. Probabilités analyse des données et statistique.2006.
- [7] T .Michel. Statistique: Méthodes pour décrire, expliquer et prévoir.
- [8] J. Peter Brockwell and Richard A. Davis. Introduction to Time Series and Forecasting. Second Edition.
- [9] L.Sylvia,Philippe T. Théorie des probabilités en vue des applications statistiques.1990.
- [10] Du Yudie and all. A Novel Divide-and-Conquer Model for CPI Prediction Using ARIMA, Gray Model and BPNNP. remedia Computer Science(2014)842-851.