

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي

Ministère de l'enseignement supérieur et de la recherche scientifique

Université Mohamed Khider – Biskra

Faculté de Sciences et de la technologie

Département : Génie civil et hydraulique

Ref :.....



جامعة محمد خيضر بسكرة

كلية العلوم و التكنولوجيا

قسم: الهندسة المدنية والري

المرجع :

Thèse présentée en vue de
l'obtention du diplôme de

Doctorat en Sciences

Spécialité : **Hydraulique**

Option : **Urbaine**

Thème

**Développement d'algorithmes pour l'analyse des
séries temporelles des données de production
d'eau potable**

Présenté par : **LOUDJANI Nawal**

Soutenue le : 08 /05/ 2022 devant le jury composé de :

BENMEBAREK Naima	Professeur	Président	Université de Biskra
MESEMEH Abdelhamid	Professeur	Rapporteur	Université de Biskra
BOUZIANE M ^{ed} Tewfik	Professeur	Co-directeur de thèse	Université de Biskra
REMINI Boualem	Professeur	Examineur	Université de Blida
GHOMRI Ali	Professeur	Examineur	Université d'El-Oued
SEKIOU Fateh	M.C.A.	Examineur	Université d'oum-ElBouaghi

Dédicace

Je dédie ce modeste travail :

A mes très chers parents :

A mon père Loudjani Salah, A ma mère

A Mon mari

A mes enfants Assala , Fadwa, Abdelazziz, Yahia, Yazen

A mes sœurs et mes frères

A mes enseignants, mes amis

Naouel

Remerciement

Je remercie dieu le tout puissant de nous avoir donné la santé et la volonté d'entamer et de terminer cette thèse.

Nos remerciements les plus sincères vont à :

Le directeur de cette thèse, Abdelhamid Messemeh maitre de conférences

On le remercié pour leur conseille précieux et leur suivis qu'il ma prodigué durant tout notre travail.

Le professeur M.Tewfik.Bouziane, merci pour votre suivie régulier, vos critiques

Je voudrais tout d'abord remercier les membres de jury pour avoir accepté de juger mon présent travail

Je merci aussi a ceux qui ont toujours cru en moi, qui m'ont toujours poussé et qui ont toujours été là pour moi...merci à toute ma famille,

Merci mon mari, mes enfants,

Merci mes parents, mes sœurs

Merci à mes enseignants, mes amis

Encore merci à vous tous...

Naouel

Résumé

Ce travail de recherche s'intéresse à la modélisation des séries chronologiques, il s'agit d'analyser et de modéliser des problèmes d'optimisation stochastique et de proposer un modèle de prévision appliqué à la production de l'eau potable. Nous avons utilisé les données mensuelles de consommation d'eau potable de la ville de Biskra. L'objectif de ce travail est de développer un algorithme pour étudier les techniques d'analyse s'intéresse à la modélisation des séries chronologiques empiriques correspondant à la méthodologie de Box et Jenkins dans le but de générer un modèle ARMA (modèles autorégressifs et moyenne mobile) de la demande en eau potable de la ville de Biskra et de permettre une prédiction de l'évolution future de ce phénomène à l'aide d'outils des composantes principaux utilisés lors de la phase d'identification qui sont donc les tracés de la série, les corrélogrammes d'autocorrélation (FAC), et d'autocorrélation partielle (FACP). La modélisation nous a permis de déterminer combien de paramètres autorégressifs (p) et de moyennes mobiles (q) sont nécessaires pour obtenir un modèle effectif et parcimonieux du processus. L'analyse des résidus de l'ARMA constitue un test important du modèle, les critères d'information AIC et SIC sont proposés pour tester la qualité du modèle choisi. La méthode proposée est appliquée sur un jeu de données de production des ressources en eau.

Mots clés : Séries chronologiques, Processus stochastique, ARMA, Box-Jenkins méthode stochastique, ressources d'eau, autocorrélation, FAC, autocorrélation FACP. Critère AIC, Critère BIC

المخلص :

يهدف هذا العمل البحثي بنمذجة السلاسل الزمنية، والهدف منه تحليل و نمذجة مشاكل التحسين العشوائي و اقتراح نموذج تنبؤ مطبق على إنتاج مياه الشرب. استخدمنا بيانات الاستهلاك الشهري لمدينة بسكرة.

الهدف من هذا العمل هو تطوير خوارزمية لدراسة تقنيات تحليل و نمذجة السلاسل الزمنية التجريبية لمنهجية بوكس وجينكينز

(Box and Jenkins) لتوليد نموذج ARMA (نماذج الانحدار الذاتي والمتوسط المتحرك) على إنتاج الماء الشروب لمدينة بسكرة. كما تسمح بالتنبؤ بالتطور المستقبلي لظاهرة معينة وتستخدم للتحقق من صحة قيم إنتاج المياه التي يتم إدخالها شهرياً باستخدام أدوات المكونات الرئيسية المستخدمة أثناء مرحلة التحديد، و من بينها مخططات السلسلة ، ومخططات الارتباط التلقائي (FAC)، والارتباط الذاتي الجزئي (FACP).

يشكل تحليل بقايا ARMA اختباراً مهماً للنموذج ، باقتراح معايير المعلومات AIC و BIC لاختبار جودة النموذج المختار. يتم اختبار الطريقة المقترحة على مجموعة بيانات إنتاج الموارد المائية.

الكلمات المفاتيح : السلسلة الزمنية ، معالجة عشوائية، ARMA ، الطريقة العشوائية ، الموارد المائية ، الارتباط التلقائي FAC، الارتباط الذاتي الجزئي FACP، معيار AIC، معيار BIC.

ABSTRACT

This research work is interested in the modeling of time series, it is to analyze and model stochastic optimization problems and the propose a forecast model applied to the production of drinking water. We used the monthly drinking water consumption data for the city of Biskra.

The objectif of work is to develop an algorithm to study the techniques of analysis and modeling of empirical time séries corresponding to the methodology of Box and Jenkins to generate an ARMA model (autoregressive and moving average models) Of drinking water demand in the city of Biskra which is to allow a prediction of the future evolution of a phenomenon and used for the validation of the production values of water seized monthly using tools of the main components used during the identification phase are therefore the plots of the series, autocorrelation correlograms (FAC), and autocorrelation partial (FACP).

The modeling allowed us to determine how many autoregressive parameters (p) and moving average (q) are needed to obtain an effective and parsimonious model of the process. The analysis of the ARMA residuals constitutes an important test of the model, the information criteria AIC and BIC are proposed to test the quality of the chosen model. The proposed method is applied to water resources production dataset..

Keywords : Time séries, Stochastic process, ARMA, Box-Jenkins stochastic method, autocorrelation, FAC, Water resources ,autocorrelation FACP, AIC criterion, BIC criterion

Sommaire

<i>Sommaire</i>	- 06 -
<i>Liste des figures</i>	- 09 -
Liste des Tableaux	- 11 -
Sigles et Abréviation	- 15 -
Introduction générale.....	- 17 -
CHAPITRE I.....	- 22 -
Introduction.....	- 22 -
1.1 <i>Les processus aléatoire stationnaire</i>	- 22 -
1.1.1 Processus stochastique	- 22 -
1.1.2 Processus stationnaire.....	- 22 -
1.2 <i>Notions de base en série chronologique</i>	- 23 -
1.2.1 Caractéristiques d'une série temporelle	- 23 -
1.2.1.1 La moyenne	- 24 -
1.2.1.2 La Variance	- 24 -
1.2.1.3 Indices de dépendance.....	- 25 -
1.2.1.4 La Fonction d'auto-covariance	- 25 -
1.2.1.5 La fonction d'autocorrélation (ACF)	- 25 -
1.2.1.6 La fonction d'autocorrélation partielle (PACF).....	- 26 -
1.3 <i>Théorème de Wold</i>	- 26 -
1.4 <i>Opérateurs retard β et Δ</i> :	- 27 -
1.5 <i>Opérateur différence Δ (SPRAY et NEWELL, 1986)</i>	- 27 -
Conclusion :	- 28 -
CHAPITRE II.....	- 30 -
Introduction :	- 30 -
2.1 <i>Définition et structure</i> :	- 30 -
2.2 <i>Modèles paramétriques usuels</i>	- 31 -
2.3 <i>Modèle auto-régressif AR</i> :	- 31 -
2.4 <i>Modèle moyenne mobile</i>	- 31 -
2.4.1 Processus moyenne mobile MA :	- 31 -

2.5	Modèle autorégressif-Moyenne mobile (ARMA) (MCWHORTER,1975).	- 32 -
2.6	Processus ARMA (p,q).....	- 33 -
2.7	Modèle ARMA :.....	- 33 -
2.8	Processus aléatoires non stationnaires	- 34 -
2.9	Processus bruit blanc(SPRAY et NEWELL, 1986).....	- 34 -
2.10	Processus DS (HIPEL, et MCLEOD, 1994).	- 35 -
2.11	Tests de stationnarité (ou tests de racine unitaire).....	- 36 -
2.12	Tests de Dickey-Fuller Simple :.....	- 37 -
2.13	Tests de Dickey-Fuller Augmenté (ADF) (VANDER VAART et WELLNER, 1996).	- 39 -
Conclusion		- 41 -
CHAPITRE III		- 44 -
Introduction.....		- 44 -
3.1	Méthode de Box&Jenkins	- 44 -
3.2	Stationnarisation et Dessaisonalisation	- 48 -
3.3	Tests de la stationnarité (BROZE et MÉLARD, 1990).	- 48 -
3.4	Identification du modèle Box-Jenkins	- 49 -
3.5	Estimation du modèle Box-Jenkins [modifier]	- 49 -
3.6	Validation du processus ARMA:.....	- 50 -
3.7	Tests de Validation	- 51 -
3.7.1.1	Test de redondance :.....	- 51 -
3.7.1.2	Test de significativité :.....	- 51 -
3.7.1.3	Test de recherche d'autocorrélation :.....	- 51 -
3.7.1.4	Test de Ljung-Box	- 51 -
3.8	Prévisions.....	- 54 -
3.9	Choix d'un modèle	- 56 -
3.9.1	Critère de pouvoir prédictif (BENNIS, 1 987).....	- 56 -
3.9.2	Critères standards (BOURBONNAIS, 1998).	- 57 -
3.9.3	Les critères d'information de comparaison des modèles:	- 57 -
Conclusion		- 58 -
CHAPITRE IV.....		- 60 -
Introduction.....		- 60 -

4.1	<i>Présentation de la zone d'étude</i>	- 60 -
4.1.1	Champ captant Oued el Hai (Oued Biskra).....	- 62 -
4.1.2	Champ captant el Megloub	- 62 -
4.1.3	Champ captant interne.....	- 62 -
4.1.4	Champ captant oued Z'mor.....	- 63 -
4.1.5	Champ captant Droh	- 63 -
4.2	<i>Présentation des données</i>	- 65 -
4.3	<i>Méthodologie et approche expérimentale</i>	- 65 -
	Conclusion	- 66 -
	CHAPITRE V.....	- 69 -
	Introduction.....	- 69 -
5.1	<i>Le code de calcul utilisé (Eviews)</i>	- 69 -
5.2	<i>Etude graphique de la série (FF1)</i>	- 71 -
5.3	<i>Dessaisonnaliser la série (FF1) :</i>	- 73 -
5.4	<i>Les coefficients saisonniers</i>	- 73 -
5.5	<i>Etude de la stationnarité de la série désaisonnalisée (FF1SA)</i>	- 75 -
5.6	<i>Teste de racine unitaire</i>	- 76 -
5.7	<i>Stationnarisation de la série FF1SA</i>	- 76 -
5.8	<i>Estimation de la fonction de la tendance :</i>	- 80 -
5.9	<i>MODELISATION ARMA PAR LA METHODE DE BOX-JENKINS</i>	- 83 -
5.9.1	L'identification de modèle.....	- 83 -
5.9.2	Estimation des paramètres du modèle	- 84 -
5.9.3	Validation d'un model ARMA (p,q).....	- 133 -
5.10	<i>Résultats et Interprétation</i>	- 140 -
	Conclusion Générale.....	- 166 -
	Références bibliographiques	- 170 -

Liste des figures

Figure 2-1 Processus non stationnaire : Trend Déterministe.....	- 35 -
Figure 2-2 Processus non stationnaire : Modèle rupture	- 36 -
Figure 2-3 Processus non stationnaire : Variation Aléatoire.....	- 36 -
Figure 2-4 Stratégie de Tests de Dickey Fuller	- 40 -
Figure 2-5 Schéma général de la modélisation d'une série temporelle par un modèle ARMA.	- 41 -
Figure 3-6 Méthodologie de Box et Jenkins.....	- 47 -
Figure 3-7 Série stationnaire	
Figure 3-8 Série non stationnaire en moyenne.....	- 49 -
Figure 3-9 Série non stationnaire en variance	- 49 -
Figure 3-10 Méthodologie de Box et Jenkins [16].....	- 56 -
Figure 4-11 situation des secteurs existants Ville de Biskra [56] Groupement Bureaux d'Etude (PROSPECTIVA,PROENGEL,SATEIG,2020)	- 60 -
Figure 4-12 situations champs captant [56].....	- 61 -
Figure 4-13 Répartition de la production d'eau potable par champ captant [56].....	- 64 -
Figure 4-14 : Classification des forages par années de mise en service	- 65 -
Figure 4-15 La méthode Box-Jenkins pour une sélection optimale du modèle [16].....	- 66 -
Figure 5-16 Forage F1	- 70 -
Figure 5-17 Fiche technique forage F1	- 70 -
Figure 5-18 L'évolution mensuelle de la Production d'AEP (Forage F1)	- 72 -
Figure 5-19 Le graphe de la série désaisonnalisé FF1SA	- 75 -
Figure 5-20 Série stationnaire VFF1SA	- 82 -
Figure 5-21 Fiche technique forage F4	- 87 -
Figure 5-22 L'évolution mensuelle de la Production d'eau potable de la ville de Biskra (Observée)	- 88 -
Figure 5-23 Le graphe de la série désaisonnalisé FF4SA.	- 90 -
Figure 5-24 .La série stationnaire VFF4SA	- 93 -
Figure 5-25 Forage Ras Elgueria 02.....	- 98 -
Figure 5-26 L'évolution mensuelle de la Production d'AEP (Forage RASElgaria)	- 100 -
Figure 5-27 Le graphe de la série désaisonnalisé FRASELGSA	- 103 -
Figure 5-28 L'évolution mensuelle de la Production d'eau potable de la ville de Biskra FHAKS (Observée)	- 113 -
Figure 5-29 .La série stationnaire VFHAKS	- 118 -

Figure 5-30 Le graphe de la série désaisonnalisé F1NOVEMSA.....	- 125 -
Figure 5-31 Histogramme du résidu	Figure 5-32 Graphe résiduel..... - 136 -
Figure 5-33 Histogramme du résidu	Figure5-34 Graphe résiduel..... - 137 -
Figure5-35 Histogramme du résidu	Figure 5-36 Graphe résiduel..... - 138 -
Figure 5-37 Histogramme du résidu	Figure 5-38 Graphe résiduel..... - 139 -
Figure 5-39 Les prévisions du modèle (FF1)	- 146 -
Figure 5-40 Les prévisions du modèle (F Raselgueria 02).....	- 155 -
Figure 5-41 Les prévisions du modèle (F 1 ^{er} Novembre).....	- 158 -

Liste des Tableaux

Tableau .1.1. Les débits des ouvrages de production (Champ Captant Oued El -Hai).....	- 62 -
Tableau .1.2. Les débits des ouvrages de production (Champ Captant El Megloub).....	- 62 -
Tableau .1.3. Les débits des ouvrages de production (Champ Captant Interne).....	- 63 -
Tableau .1.4. Les débits des ouvrages de production (Champ Captant Oued Z'mor).....	- 64 -
Tableau .1.5. Les débits des ouvrages de production (Champ Captant Droh).....	- 64 -
Tableau.5.1. les volumes de production mensuelle d'eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage F1).....	- 72 -
Tableau.5.2. Corrélogramme de la série brute FF1	- 73 -
Tableau.5.3. coefficients saisonniers de la série FF1SA.....	- 74 -
Tableau. 5 .4. Les données de la série Désaisonnalisée FF1SA pour la période allant de janvier 2009 à janvier 2016 (Forage F1)	- 75 -
Tableau .5.5. Corrélogramme de la série FF1SA	- 75 -
Tableau.5.6. Fenêtre de logiciel pour test de racine unitaire	- 76 -
Tableau. 5 .7. Test de stationnarité de la série des données de production d'eau potable (Modèle avec tendance et avec constante).....	- 77 -
Tableau.5.8. Test de stationnarité de la série des données de production d'eau potable (Modèle et avec constante).....	- 78 -
Tableau.5.9. Test de stationnarité de la série des données de production d'eau potable (Modèle sans tendance et ni constante)	- 79 -
Tableau.5 .10. Icône de logiciel	- 80 -
Tableau.5.11. méthode des moindres carrés (l'estimation d'équation)	- 80 -
Tableau.5.12 Les données de la série stationnaire VFF1SA pour la période allant de janvier 2009 à janvier 2016 (Forage F1).....	- 81 -
Tableau.5 .13. Corrélogramme de la série VFF1SA	- 82 -
Tableau. 5.14. Test de stationnarité de la série des données de production d'eau potable (Modèle sans tendance et sans constante)	- 83 -
Tableau. 5.15. Corrélogramme de la série VFF1SA.....	- 84 -
Tableau.5.16. les critères d'Akaike et Schwartz	- 85 -
Tableau. 5.17. Modèle AR(3).....	- 85 -
Tableau. 5 .18. Modèle MA(3)	- 85 -
Tableau. 5.19. Modèle AR(3) MA(3)	- 86 -
Tableau. 5.20. les données de production mensuelle d'eau potable (observée) pour la période allant de janvier 2009 à janvier 2016 (Forage FF4)	- 88 -
Tableau. 5 .21. Corrélogramme de la série brute FF4	- 88 -
Tableau.5. 22. coefficients saisonniers de la série FF4SA.....	- 89 -

Tableau.5.23. Les données de la série Désaisonnalisée FF4SA pour la période allant de janvier 2009 à janvier 2016 (Forage F4)	- 89 -
Tableau.5.24. Corrélogramme de la série FF4SA.....	- 90 -
Tableau. 5.25 Test de stationnarité de la série des données de production d'eau potable Modèle avec tendance et constante.....	- 91-
Tableau. 5.26. Estimation de la fonction de la tendance de la série des données de production d'eau potable	- 91-
Tableau. 5.27. Les données de la série stationnaire VF4SA pour la période allant de janvier 2009 à janvier 2016 (Forage F4).....	- 92 -
Tableau.5.28. Corrélogramme VFF4SA.....	- 93 -
Tableau. 5.29 Test de stationnarité de la série des données de production d'eau potable Modèle ni tendance ni constante	- 94 -
Tableau.5.30. Corrélogramme de la série VFF4SA	- 95 -
Tableau.5.31. les critères d'Akaike et Schwartz.....	- 95 -
Tableau.5.32. Modèle AR(1)	- 96 -
Tableau.5.33. Modèle MA(1).....	- 96 -
Tableau.5.34. Modèle MA(2).....	- 96 -
Tableau.5.35. Modèle ARMA(1,1)	- 97 -
Tableau.5.36. Modèle ARMA(1,2).....	- 97 -
Tableau .5.37. les volumes de production mensuelle d'eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage Ras Elgueria N°02).....	- 99 -
Tableau.5. 38. Corrélogramme de la série brute FRASELG.....	- 100 -
Tableau.5. 39. coefficients saisonniers de la série FRASELGSA	- 101 -
Tableau .5.40. Les données de la série Désaisonnalisée FRASELGSA pour la période allant de janvier 2009 à janvier 2016	- 102 -
Tableau .5.41. Corrélogramme de la série FRASELGSA.....	- 103 -
Tableau. 5. 42. Test de stationnarité de la série des données de production d'eau potable (Modèle [3] avec tendance et avec constante)	- 104 -
Tableau. 5. 43. Test de stationnarité de la série des données de production d'eau potable (Modèle [2] sans tendance et avec constante).....	- 105 -
Tableau. 5. 44. Test de stationnarité de la série des données de production d'eau potable (Modèle [1] sans tendance et sans constante).....	- 105 -
Tableau.5.45. Estimation de la fonction de la tendance de la série F rasgueria	- 106 -
Tableau .5.46. Les données de la série stationnaire (FRGS) pour la période allant de janvier 2009 à janvier 2016 (Forage Ras El gueria N°02)	- 108 -
Tableau.5.47. Corrélogramme de la série (FRGS).....	- 109 -
Tableau. 5.48. Test de stationnarité de la série des données de production d'eau potable (Modèle [1] sans tendance et sans constante).....	- 110 -
Tableau.5.49. Corrélogramme de la série FRGS	- 110 -

Tableau.5.50. les critères d'Akaike et Schwartz	- 111 -
Tableau. 5.51. Modèle AR(1)	- 111 -
Tableau. 5.52. Modèle MA(1).....	- 112 -
Tableau. 5.53. Modèle AR(1)MA(1)	- 112 -
Tableau .5.54. les données de production mensuelle (observée) d'eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage Hakim Saadane).....	- 114 -
Tableau. 5 .55. Corrélogramme de la série brute FHAKS.....	- 115 -
Tableau.5. 56. Coefficients saisonniers de la série FHAKSSA.....	- 115 -
Tableau.5.57. Les données de la série Désaisonnalisée FHAKSSA pour la période allant de janvier 2009 à janvier 2016 (Forage HAKIM SAADANE).....	- 115 -
Tableau.5. 58. Corrélogramme de la série FHAKSA.....	- 116 -
Tableau. 5. 59. Test de stationnarité de la série des données de production d'eau potable (Modèle[3] avec tendance et avec constante)	- 117 -
Tableau.5 .60. Icône de logiciel l'estimation de la fonction de la tendance	- 118 -
Tableau. 5.61. Les données de la série stationnaire VFHAKS pour la période allant de janvier 2009 à janvier 2016 (Forage HAKIM SAADANE).....	- 118 -
Tableau.5.62. Corrélogramme VFHAKS.....	- 119 -
Tableau. 5. 63. Test de stationnarité de la série des données de production d'eau potable (Modèle [1]) sans tendance et sans constante.....	- 119 -
Tableau. 5.64. Corrélogramme de la série VFHAKS.....	- 120 -
Tableau. 5.65. les critères d'Akaike et Schwartz	- 121 -
Tableau.5.66. Modèle AR(1).....	- 121 -
Tableau.5.67. Modèle AR(2)	- 121 -
Tableau.5.68. Modèle MA(1).....	- 122 -
Tableau.5.69. Modèle MA(2)	- 122 -
Tableau.5.70. Modèle MA(3).....	- 122 -
Tableau.5.71. Modèle ARMA(1 ;1)	- 122 -
Tableau.5.72. Modèle ARMA (2 ;2).....	- 122 -
Tableau.5.73. Modèle ARMA(2 ;3).....	- 122 -
Tableau.5.74. Modèle ARMA(1 ;3).....	- 123 -
Tableau.5.75. Modèle ARMA(1 ;2)	- 123 -
Tableau.5.76. Modèle AR(2 ;1)	- 123 -
Tableau .5.77. les données de production mensuelle d'eau potable pour la période allant de janvier 2009 à janvier 2016 (FORAGE 1 ^{er} NOVEMBRE)	- 124 -
Tableau .5.78. Corrélogramme de la série brute F1NOVEMB.....	- 125 -
Tableau.5. 79. Coefficients saisonniers de la série F1NOVMSA.....	- 125 -
Tableau .5.80. Les données de la série Désaisonnalisée FHAKSSA pour la période allant de janvier 2009 à janvier 2016	- 126 -
Tableau.5. 81. Corrélogramme de la série F1NOVEMSA	- 126 -

Tableau. 5. 82. Test de stationnarité de la série des données de production d'eau potable (Modèle[3] avec tendance et avec constante)	- 127 -
Tableau. 5. 83. Test de stationnarité de la série des données de production d'eau potable (Modèle[2] Modèle sans tendance et avec constante).....	- 127 -
Tableau. 5. 84. Test de stationnarité de la série des données de production d'eau potable Modèle(1) sans tendance et sans constante.....	- 128 -
Tableau .5.85. Les données de la série stationnaire STASF1NOMEM pour la période allant de janvier 2009 à janvier 2016	- 129 -
Tableau.5.86. Corrélogramme de la série STASF1NOVEM.....	- 130 -
Tableau 5.87. Test de stationnarité de la série STASF1NOVEM.....	- 130 -
Tableau. 5.88. Corrélogramme de la série STASF1NOVEM.....	- 131 -
Tableau.5.89. les critères d'Akaike et Schwartz.....	- 131 -
Tableau.5.90. Modèle MA(1).....	- 132 -
Tableau.5.91. Modèle MA(2).....	- 132 -
Tableau.5.92. Modèle AR(1).....	- 132 -
Tableau.5.93. Modèle AR(1)MA(1)	- 133 -
Tableau.5.94. Modèle AR(1)MA(2)	- 133 -
Tableau .5.95. Corrélograme des résidu ARMA(3,3)	- 136 -
Tableau.5.96. Corrélograme des résidu ARMA(0,2).....	- 137 -
Tableau.5.97. Corrélograme des résidu ARMA(1,1).....	- 138 -
Tableau.5.98. Corrélograme des résidu ARMA(1,0)	- 139 -
Tableau.5.99. Corrélograme des résidu ARMA(1,0)	- 140 -
Tableau 5.100. 2009M01 2030M01 // prevff1=vff1saf1*cvs	- 145 -
Tableau 5.101. 2009M01 2030M01 // prevff4=vff4saf4*cvs	- 148 -
Tableau 5.102. 2009M01 2030M01 // prevhaks=fhaksff*cvs	- 151 -
Tableau.5.103. 2009M01 2030M01 // prevrsg=frgsff*cvs.....	- 154 -
Tableau.5.104. 2009M01 2030M01 // prevf1nov=v1novem*cvs	- 157 -
Tableau 5.105. Mesures de l'erreur de prévision du modèle ARMA	- 164 -

Sigles et Abréviation

B&J	La méthodologie de Box et Jenkins
(MA)	processus moyennes mobiles
(AR)	processus autorégressifs
ARMA	Modèle autorégressif-Moyenne mobile
X_t	processus aléatoire indicé par le temps
T	Le temp
$E(X_t)$	variable aléatoire avec son espérance
μ_t	composant stochastique
$V(X_t)$	variable aléatoire avec son variance
σ_x	écart-type
$Cov(X_t, X_{t-h})$	covariances
γ_k	l' autocovariance
(ACF)	La fonction d'autocorrélation
ρ	l'autocorrélation
(PACF)	La fonction
d_t	Composant déterministe
β et Δ	Opérateurs retard
AIC	Le critère d'Akaike
SIC	Le critère de Schwartz
ADF	Le test de Dikey-Fuller
ϵ_t	Bruit blanc
DS	Differency stationnary avec dérivé
TS	Trend Stationnary
r_k	Le coefficient d'autocorrélation d'ordre k,
p, d, q	les valeurs des paramètres du modèle ARMA
\hat{Y}_{T+h}	la prévision
MAE	L'erreur absolue moyenne (Mean Absolute Error)
RMSE	Racine de l'erreur quadratique moyenne (Root Mean Square d'Error)
MAPE	Ecart absolu moyen en pourcentage (Mean Absolute Percent Error)

Introduction générale

Introduction générale

L'alimentation en eau potable s'est considérablement améliorée en Algérie depuis ces vingt dernières années, avec à la clé une consommation quotidienne par habitant moyenne de presque 170 litres, alors que la "qualité du service" est devenue l'autre priorité des responsables du secteur. Les ressources hydriques disponibles et mobilisables en Algérie sont estimées par les experts du ministère à 17,2 milliards m³, dont 9 milliards en Algérie de ressources superficielles dans le Nord, 2 milliards de ressources souterraines (nord) et 5,2 milliards m³ dans le Sud (superficielles et souterraines).(DJERBOUAI,2016).

La production de l'eau revêt dans chaque pays des enjeux économiques, l'eau est un facteur de consommation fondamental dans l'activité économique. La prévision à court terme de la consommation de l'eau joue un rôle essentiel dans la gestion efficace des ressources. Notre fil conducteur provient tout simplement de la nécessité d'étudier et de prédire la demande en eau potable dans l'une de ses wilayas (Biskra). L'utilisation de la prévision de séries temporelles pour prévoir la consommation de l'eau est nécessaire pour la constitution d'outils d'aide à la décision des données de production d'eau potable et pour une meilleure gestion qui est un sujet d'intérêt primordial aujourd'hui.

Les séries chronologiques ont commencé à être utilisées dans l'étude des températures et de la pluviométrie. L'analyse des séries chronologiques est un outil couramment utilisé de nos jours pour la prédiction de données futures d'eau potable, fin de mieux gérer la production de l'eau potable et pour satisfaire les besoins des consommateurs (domestiques, industrielle,). La prévision à court terme de la consommation d'eau potable joue un rôle essentiel dans la gestion efficace des ressources allouées à la production d'eau potable. Dans ce travail, nous nous concentrons sur la consommation mensuelle d'eau potable gérée par l'Algérienne Des Eaux (ADE) de Biskra.

L'objectif de ce travail est d'explorer les performances de trois modèles de base en séries temporelles pour analyser la consommation mensuelle des données de production d'eau potable à Biskra.

- Modèle (ARMA) modèle Autorégressif-Moyenne mobile
- Modèle (AR) modèle Autorégressif
- Modèle (MA) modèle Moyenne-mobile

La modélisation permettant d'expliquer les variations et d'effectuer des prévisions. Cette recherche est un premier pas dans le développement d'outils rigoureux d'aide à la décision, qui pourraient être utiles aux opérateurs du secteur, principalement ADE-Biskra. Donc, il s'agit d'analyser et de modéliser des problèmes d'optimisation stochastique et de proposer un modèle de prévision appliqué à la production de l'eau potable.

A travers ces éléments se dégagent les objectifs généraux et spécifiques suivants :

Objectifs généraux

- - Meilleure utilisation des ressources en eau de la ville de BISKRA
- - Optimisation du traitement de l'information existante
- - Développement d'un outil d'aide à la décision.

Objectifs spécifiques

- - Visualiser les cycles de consommation d'eau potable
- - Valider la production mensuelle
- - Diagnostiques de l'état des ressources et du réseau et relever toutes les consommations exceptionnelles

Ces objectifs ont servi de fil conducteur à l'élaboration du plan recherche ainsi qu'à l'approche utilisée au développement un 'algorithme pour l'analyse des différentes séries temporelle.

Motivation

Ce travail a été incité par le manque de prédiction de la demande de l'eau dans L'Algérie notamment dans la wilaya de Biskra. On applique généralement un ajustement statistique linéaire basé sur les méthodes de prévision concernant l'application des processus autorégressifs pour développement d'un algorithme qui permet d'évaluer la demande en eau future. Dans cette thèse, nous proposons la méthodologie de Box-Jenkins pour la modélisation et la prédiction de la demande en eau.

La méthodologie adoptée est basée sur :

- (i) Identifier la nature du phénomène représenté par une séquence d'observations,
- (ii) Réaliser des prévisions à court terme.

La plupart des techniques d'analyse des séries chronologiques comportent différents filtres permettant d'éliminer ce bruit pour rendre les composantes plus évidentes. Toute l'analyse s'est faite à l'aide du logiciel statistique Eviews 7.

Cette thèse est organisée en cinq chapitres comme suit :

- Le premier chapitre présente les différents aspects descriptifs de données de production d'eau potable et étudie la stationnarité des séries. Nous avons introduit la notion du processus temporelle et il existe plusieurs formes d'un processus stationnaire, la stationnarité du second ordre ou la stationnarité faible. Des techniques d'élimination de ces composantes sont proposées et illustrées par la représentation graphique. Nous présentons l'étude de modèles linéaires généraux et leurs caractéristiques à savoir la fonction d'autocovariance, la fonction d'autocorrelation, la fonction d'autocorrelation partielle et le corrélogramme. Cette visualisation donne des indications très précieuses pour choisir un modèle.
- Le second chapitre étudie les différentes notions de base pour aborder l'étude d'une série chronologique. C'est une phase descriptive des données brutes et l'analyse et évolution des séries chronologiques de consommation d'eau potable dans la zone d'étude. Les composantes d'une série : tendance, effet saisonnier et erreurs et les notions des processus stochastique, les méthodes des prévisions, les représentations graphiques. Nous allons adopter les étapes de la méthode Box – Jenkins qui consiste à transformer une série non stationnaire en une série stationnaire. Le modèle ARMA est un outil pour comprendre et prédire, éventuellement les valeurs futures de cette série. Le modèle est composé de deux parties : La première autorégressive (AR) et la seconde moyenne-mobile (MA). Le modèle est généralement noté ARMA (p,q) , où p est l'ordre de la partie AR et q l'ordre de la partie MA [106]. Un processus autorégressif est un modèle de régression pour séries temporelles dans lequel la série est expliquée par ses valeurs passées plutôt que par d'autres variables.
- Le troisième chapitre est consacré à l'estimation des paramètres et validation du modèle et détermination des ordres p et q du modèle ARMA (p,q) , l'analyse du corrélogramme simple et partiel (étude l'autocorrélation), en présentant la modélisation de la partie aléatoire et déterminer le modèle adéquat dans la famille des modèles ARMA.
- Le quatrième chapitre, nous proposons une méthode de prévision basée sur la modélisation des séries chronologiques et la méthode de Box & Jenkins, qui va lui permettre de faire face aux consommations future des données de ses clients et d'améliorer son système prévisionnel.

• Le dernier chapitre nous traitons la partie pratique, en examinant les différentes évolutions de nos variables choisies. Nous procédons par une analyse préliminaire (graphique, corrélogramme) des données ensuite par une analyse descriptive (histogramme), ensuite, nous représentons l'évaluation des méthodes de prévision et la qualité des prévisions du modèle ARMA selon plusieurs critères. La mesure de la précision des prévisions doit toujours être évaluée dans le cadre d'une validation de modèle. Nous utilisons le logiciel Eviews 7.0 afin d'améliorer le processus de prévision de l'entreprise ADE (Algérienne des eaux de Biskra).

A la fin de la thèse, nous présenterons la conclusion générale et les perspectives de cette étude.

En fin, un sujet de recherche comme la prédiction de séries temporelles ne peut pas se borner à une étude purement théorique mais demande un volet expérimental applicatif.

Chapitre I

Les processus d'une série chronologiques

CHAPITRE I

Introduction

Ce chapitre présente certains outils mathématiques et modèles simples employés par la statistique des séries temporelles. Il s'agira de préciser quelques notions sur les modèles AR, MA et ARMA univariés et quelques outils mathématiques qui leur sont reliés. (WANG et al., 1995).

Dans le cas des séries chronologiques, il s'agit de définir le processus aléatoire puis le montage du modèle, y compris autorégressif et les processus moyens mobiles, les méthodes spectrales et certaines discussions sur l'effet du temps des corrélations en série sur d'autres types d'inférences statistiques

L'étude d'un processus aléatoire d'une série chronologique a généralement deux objectifs :

- Expliquer les variations,
- Prédire les valeurs futures.

Un processus stochastique est à la base de la modélisation des séries temporelles stationnaires. (BOX et PIERCE, 1970).

1.1 Les processus aléatoires stationnaires

1.1.1 Processus stochastique

Ce théorème est à la base de la modélisation des séries temporelles stationnaires (FARAWAY, et CHATFIELD, 1998).

Une série chronologique est la réalisation d'un processus aléatoire indicé par le temps, noté $\{X_t\}$. Pour chaque t , X_t est une variable aléatoire dont on a une réalisation.

La série des consommations mensuelles des données de production d'eau potable de la ville de Biskra de janvier 2009 à janvier 2016. Un processus stochastique est une suite de variables aléatoires réelles qui sont indexées par le temps. $\{X_t, t \in T\}$, Pour chaque instant du temps, la valeur de la quantité étudiée X_t est appelée variable aléatoire. L'ensemble des valeurs X_t quand t varie est appelé processus aléatoire $\{X_t, t \in T\}$ (Brockwell et Davis, 2013).

1.1.2 Processus stationnaire

La stationnarité est donc une hypothèse essentielle pour pouvoir estimer les paramètres Caractéristiques du processus : elle implique notamment que le processus n'a pas de tendance (Ladiray et Quenneville, 2000).

La stationnarité joue un rôle central dans la théorie des processus :

- Processus fortement stationnaire (ou au sens strict) : la distribution de Probabilité est invariante par translation de l'axe du temps
- Processus faiblement stationnaire (ou stationnaire à l'ordre 2) permanence des deux premiers moments (conditions utilisées en pratique), cette hypothèse implique notamment que la covariance entre les valeurs prises en 2 dates distinctes par le processus ne dépend que de la longueur de la période qui les sépare (et pas de la date initiale)
- Un processus est stationnaire au second ordre si l'ensemble de ses moments d'ordre un et d'ordre deux sont indépendants du temps (**GRANGER**, 1980).

Un processus est dit faiblement stationnaire si son espérance et sa variance sont constantes et si sa covariance ne dépend que de l'intervalle de temps $E(X_t)$, $V(X_t)$ et $Cov(X_t, X_{t-h})$ ne dépendent pas de t , Soit :

- 1) $E(X_t) = \mu, \forall t \in T$
- 2) $V(X_t) = \sigma^2, \forall t \in T$
- 3) $Cov(X_t, X_{t-h}) = \gamma_h, \forall t \in Z$

En l'absence de stationnarité, chaque X_t est une variable aléatoire avec son espérance et sa variance propres et on dispose d'une seule réalisation (x_t) de cette variable.

Les estimations de son espérance et de sa variance devraient donc se fonder sur une seule observation, ce qui est impossible (**LUBRANO**, 2008).

Un processus non stationnaire est un processus qui ne satisfait pas l'une ou l'autre de ces deux conditions.

L'origine du non stationnarité peut provenir d'une dépendance du moment d'ordre un (l'espérance) par rapport au temps et/ou d'une dépendance de la variance ou des autocovariances par rapport au temps (**Harvez**, 1993).

1.2 Notions de base en série chronologique

1.2.1 Caractéristiques d'une série temporelle

L'analyse des processus stochastiques ayant recours à la théorie des probabilités [85]. Il est pertinent de définir quelques notions de base afin de pouvoir définir les concepts de stationnarité et d'ergodicité. Comme un processus stochastique est constitué d'un ensemble de N échantillons. (**COTTREL et al**, 1995).

Soit $\{y(t)\}$ un ensemble de N échantillons constituant un processus stochastique :

1.2.1.1 La moyenne

La moyenne constitue le 1^{er} moment par rapport à l'origine et se veut une mesure de la tendance centrale. Elle se définit comme l'espérance mathématique de la variable considérée (SAID et al, 1984)

La formule générale de la moyenne d'une série chronologique de terme général x_t pour laquelle :

$$\bar{x} = \frac{\sum_{t=1}^n x_t}{n} \quad (1-1)$$

Dans le cas des séries ayant une forte tendance soit à la hausse soit à la baisse, la moyenne variera fortement à chacune des nouvelles réalisations. (DICKY DAVID et WAYNE, FULLER, 1979),

1.2.1.2 La Variance

La variance constitue le 2^{ème} moment par rapport à l'origine et se veut une mesure de la dispersion des données.

La variance d'une série chronologique permet d'évaluer la dispersion autour de la moyenne (Wold, 1954).

Nous devons distinguer deux cas, selon que nous sommes en présence de toute la population de façon exhaustive ou que nous disposons seulement d'un échantillon de réalisations considéré comme représentatif de la population totale.

La formule de la variance (*Var*) dans le cas d'une population connue totalement (variance théorique). La formule de la variance dans le cas d'un échantillon (variance empirique) est donnée par :

$$Var(x) = \frac{\sum_{t=1}^{t=n} (x_t - \bar{x})^2}{n - 1} \quad (1-2)$$

Dans le cas du calcul de la variance d'une série chronologique, la deuxième formule est la seule retenue ; en effet, nous ne connaissons pas toutes les valeurs, aussi bien les réalisations futures que celles qui sont très éloignées dans le passé (COWPERTWAIT et METCALFE, 2009).

Dans la littérature statistique ou économique, on préfère présenter la racine carrée de la variance appelée écart-type :

$$\sigma_x = \sqrt{\text{Var}(x)} \quad (1-3)$$

Cet écart-type est l'un des indicateurs fondamentaux de la difficulté à prévoir une chronique (HIPEL et MCLEOD,1994).

1.2.1.3 Indices de dépendance

Il est utile de disposer de quelques indices numériques qui permettent de décrire une série temporelle ($x_1; \dots; x_n$). [SHAMAY et STOFFER, 2017).

1.2.1.4 La Fonction d'auto-covariance

Elle mesure la covariance entre deux valeurs déparées par un certain délai k (retard), elle fournit des informations sur la variabilité de la série et sur les liaisons temporelles qui existe entre les différentes composantes de la série (FARAWAY et CHATFIELD,1998). Un processus est caractérisé, entre autres, sa structure d'ordre deux. Autrement dit :

- sa moyenne qui est un moment d'ordre un , que a moyenne pouvait suivre une tendance.
- son auto-covariance qui est un moment d'ordre deux et qui mesure la dépendance temporelle linéaire entre deux temps (MELARD, 1984).

On appelle fonction d'autocovariance la fonction γ définie de Z dans R par :

$$\forall k, t \in Z, \quad \gamma_k = \text{Cov}(X_t, X_{t+k}) \quad (1-4)$$

Le graphe de cette fonction est appelé variogramme (NEWTON et PARZEN, 1984).

1.2.1.5 La fonction d'autocorrélation (ACF)

La fonction d'autocorrélation, notée FAC, est constituée par l'ensemble des autocorrélations de la série calculé pour des décalages d'ordre k ,

$$\rho_k = \text{corr}(Y_t, Y_{t-k}) \quad (1-5)$$

on utilise l'autocorrélation pour caractériser les dépendances de linéaires dans des séries résiduelles (des séries temporelles corrigées de la tendance et la saison).L'autocorrélation décrit la dépendance moyenne entre les valeurs d'une même série mais décalées d'un pas k '. Elle se définit comme l'espérance mathématique du produit d'une série dont les éléments sont séparés par un pas de temps k . On appelle fonction d'autocorrélation la fonction ρ définie de Z dans R par $\forall k \in Z, \rho(k) = \gamma(k) / \gamma(0)$,

$$\rho_k = \frac{\gamma_k}{\gamma_0}, k \in \mathbb{Z} \quad (1-6)$$

Le graphe de cette fonction est appelé *corrélogramme* (GOURIEROUX, 1997).

1.2.1.6 La fonction d'autocorrélation partielle (PACF)

La fonction d'autocorrélation partielle, notée FAP, est constituée par l'ensemble des autocorrélations partielles, le coefficient d'autocorrélation partielle mesurant la corrélation entre les variables (Y_t et Y_{t-1}), l'influence de la variable étant contrôlée pour $i < k$ (GOURIEROUX et MONFORT, 1990).

Cette fonction existe donc pour connaître jusqu'à quel niveau de décalage ou ordre, il existe une relation directe entre Y_t et les valeurs précédentes.

Les corrélogrammes affichent les intervalles de confiance à 95%, qui permettent de déterminer quels sont les coefficients statistiquement significatifs à prendre en compte.

Cette fonction d'autocorrélation partielle mesure la corrélation et l'influence des autres variables décalés de H période (PHILIPS, et PERRON, 1988).

1.3 Théorème de Wold

Le théorème de Wold (1938) est le théorème fondamental de l'analyse des séries temporelles stationnaire, nous commence par donner l'énoncé de ce théorème, nous définirons l'opérateur retard (TSASA JEAN et PAUL, 2012),

Le théorème de décomposition de Wold

Ce théorème montre que tout processus stationnaire linéaire peut être représenté de manière unique par la somme de deux composantes indépendantes, une composante déterministe et un composant stochastique u_t : (WOLD, 1948).

$$\begin{aligned} x_t &= d_t + u_t \\ u_t &= \sum_{i=0}^{\infty} b_i \epsilon_{t-i} \end{aligned} \quad (1-7)$$

Où ϵ_t un bruit blanc.

1.4 Opérateurs retard β et Δ :

Définition de l'opérateur retard (SHAMAY et STOFFER, 2017).

Le théorème de Wold est souvent donné en introduisant un polynôme défini en l'opérateur retard. Plus généralement, les modèles des séries temporelles sont souvent exprimés sous la forme de « polynôme retard » (DEMARD et al., 1976).

On aura souvent à considérer une variable en fonction de sa passe. Il est donc commode de définir un opérateur qui transforme une variable X_t en sa valeur passée. C'est l'opérateur retard désigné par la lettre L tel que :

$$X_t L = X_{t-1} \text{ et } X_t L^k = X_{t-k} \quad (1-8)$$

- L'opérateur retard (noté L pour Log ou β suivant les ouvrages) est défini de façon suivante :

$$B(L) = \beta_0 + \beta_1 L + \beta_2 L^2 + \dots + \beta_q L^q \quad (1-9)$$

Alors

$$B(L) X_t = \beta_0 X_t + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \dots + \beta_q X_{t-q} \quad (1-10)$$

On retiendra en premier deux valeurs particulières des polynômes de retard $B(0)$ qui donne la valeur du premier coefficient du polynôme, son terme constant et $B(1)$ qui fournit lui la somme des coefficients de ce même polynôme. Enfin, l'opérateur $1 - L$ joue un rôle spécial dans la mesure où il permet de prendre la différence première d'une série :

$$(1 - L)X_t = X_t - X_{t-1} \quad (1-11)$$

1.5 Operateur différence Δ (SPRAY et NEWELL, 1986).

L'opérateur Δ fait la différence entre le processus et sa version de l'unité de temps.

Cet opérateur se construit en utilisant l'opérateur précédent :

$$\begin{aligned} \Delta(X_t) &= X_t - X_{t-1} = X_t - B(X_t) \\ \iff \Delta &= I - B \end{aligned} \quad (1-12)$$

OU I est l'opérateur :

$$I(X_t) = X_t.$$

Conclusion :

Dans ce chapitre ; nous avons introduit la notion du processus temporelle et il existe plusieurs formes d'un processus stationnaire, la stationnarité du second ordre ou la stationnarité faible. Le théorème de wold est `a la base de la modélisation des séries temporelles stationnaires. Le but de la modélisation consiste `a approximer cette moyenne mobile infinie par un processus ayant un nombre fini de paramètres. C'est ce que l'on verra en étudiant les Processus **AR**, **MA** et **ARMA**.

Chapitre II

**Les modèles des séries
temporelles et analyse des
données exploratoires**

CHAPITRE II

Introduction :

La modélisation de la partie aléatoire revêt une importance fondamentale pour améliorer la précision et efficacité de la prévision des séries chronologiques. Dans ce chapitre nous avons également discuté des problèmes de base liés à la modélisation de séries temporelles, telles que la stationnarité, les processus stochastique....

La classe des modèles **ARMA** [Box et Jenkins, 1976] a été introduite pour reconstituer le comportement de processus soumis à des chocs aléatoires au cours du temps : entre deux observations successives d'une série de mesures portant sur l'activité du processus, un événement aléatoire appelé perturbation (**GARDNER et MCKENZIE, 1985**).

2.1 Définition et structure :

Un processus auto-régressif suggère que le phénomène étudié n'est pas déterminé par une valeur de référence ; C'est la performance précédente qui détermine entièrement la performance présentée (**WALTER et SCHEPS, 1998**). La fonction d'auto-corrélation joue pour les processus de moyenne mobile le même rôle que la fonction d'auto-corrélation partielle pour les processus auto-régressifs (**BROCKWELL, 1987**). Si l'auto-corrélation est significative au décalage k mais plus au décalage $k+1$, ceci indique que k termes de moyenne mobile doivent être ajoutés au modèle (**Rahal et Abdelkader, 2017**).

Un processus qui est généré par l'équation :

$$y_t = \alpha y_{t-1} + \epsilon_t \quad (2-13)$$

Où ϵ_t est un bruit blanc de moyenne nulle et de variance σ^2 est appelé *processus autorégressif* à l'ordre un. On peut calculer la moyenne de ce processus en posant :

$$E(y_t) = \alpha E(y_{t-1}) + E(\epsilon_t) \quad (2-14)$$

Le processus $AR(p)$ est stationnaire si toutes les racines de cette équation caractéristique sont à l'extérieur du cercle unité. Dans le cas d'un processus $AR(1)$ cette condition se ramène à $|\alpha| < 1$.

Un processus $AR(p)$ a les caractéristiques suivantes :

– la FAC est une exponentielle et/ou une sinusoïde amortie,

– seuls les p premiers termes de la FAP sont significativement différents de 0 (**COUTROT et DROESBEKE**, 1990).

2.2 Modèles paramétriques usuels

Cette étape consiste à identifier les termes AR et MA nécessaires pour corriger les auto-corrélations résiduelles (**GRANGER**, 1980). Cette analyse est basée sur l'examen des fonctions d'auto-corrélation et d'auto-corrélation partielle, que l'autocorrélation est la corrélation d'une série avec elle-même, selon un décalage (*lag*) défini.

Les processus moyens mobiles et le processus autorégressif d'ordre 1. Ces processus sont des combinaisons linéaires de processus de bruit blanc (fort ou faible) dont l'intérêt comportement de leur fonction d'autocovariance (**AMARAL et al.**, 2008).

2.3 Modèle auto-régressif AR :

La partie autorégressive d'un processus, notée AR, est constituée par une combinaison linéaire finie des valeurs passées du processus (**CHOEFFDING**, 1948). Le processus AR(p) est donc défini à partir de la formule

$$\begin{cases} x_t = \phi_0 + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + a_t \\ \phi_p \neq 0 \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \\ E x_s \varepsilon_t = 0, \forall s < t \end{cases}$$

$$\Phi(B)x_t = \varepsilon_t$$

$$\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (2-15)$$

2.4 Modèle moyenne mobile

2.4.1 Processus moyenne mobile MA :

Un processus de moyenne mobile suggère que la valeur de référence évolue d'une mesure à L'autre. Plus précisément, la valeur de référence est fonction de la valeur de référence précédente et de l'erreur ayant entaché la mesure précédente (**DEMARD et al.** 1976).

on appelle processus moyenne mobile d'ordre q (on note MA(q),(MovingAverage) de polynôme caractéristique B et d'innovation ε_n , le processus défini par

$$\begin{cases} x_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \\ \theta_q \neq 0 \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \end{cases}$$

$$x_t = \Theta(B)\varepsilon_t$$

$$\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \tag{2-16}$$

L'effet d'une perturbation aléatoire décroît tout au long de la série au fur et à mesure que le temps s'écoule dans un processus autorégressif tandis que dans une moyenne mobile la perturbation aléatoire affecte la série temporelle pour un nombre fini d'observations (l'ordre de la moyenne mobile (BEN ABBAS, 2012)).

2.5 Modèle autorégressif-Moyenne mobile (ARMA) (MCWHORTER,1975).

Les modèles ARMA permettent de représenter un grand nombre de processus aléatoires stationnaires. Ce chapitre détaille les principales méthodes de prédiction et d'identification de ces processus. Il est supposé à ce niveau que l'on a isolé, dans la série chronologique d'origine, sa partie aléatoire, en lui retirant tendances et facteurs saisonniers.

Yule a introduit dans la littérature les modèles autorégressifs, en considérant des modèles de la forme :

$$\begin{cases} X_t = \phi_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \\ \phi_p \neq 0, \theta_q \neq 0 \\ \varepsilon_t \sim BB(0, \sigma_\varepsilon^2) \end{cases} \tag{2-17}$$

Où (ε_t) correspond à un 'bruit blanc'

Le modèle ARMA (p,q) est une combinaison des processus AR(p), MA(q).

$$\begin{aligned} y_t - \Phi_1 y_{t-1} - \Phi_2 y_{t-2} - \dots - \Phi_p y_{t-p} &= \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \\ (1 - \Phi_1 B - \dots - \Phi_p B^p) y_t &= (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t \\ \Phi(B)y_t &= \theta(B)\varepsilon_t \\ \varepsilon_t &\sim BB(0, \sigma_\varepsilon^2). \end{aligned} \tag{2-18}$$

Le modèle ARMA présente un corrélogramme simple et partiel qui sont un mélange des deux corrélogrammes des processus AR et MA (BOX et JENINS,1976).

2.6 Processus ARMA (p,q)

Les séries ARMA qui sont des généralisations directes des deux exemples introductifs, la combinaison des processus auto-régressifs et moyennes mobiles. Cette classe de processus ARMA jouera un rôle prépondérant dans la modélisation concrète des processus stationnaires [40].

Le traitement d'un tel processus est plus complexe que celui des 2 précédents. On peut cependant montrer que ses autocorrélations et ses autocorrélations partielles sont des fonctions amorties tendant vers 0 en valeur absolue à vitesses exponentielles. On peut ainsi dresser un tableau comparatif des corrélogrammes et corrélogrammes partiels des processus. [45].

Un processus stationnaire X_t suit un ARMA (p,q) s'il vérifie la relation suivante :

$$\begin{cases} X_t = \phi_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \\ \phi_p \neq 0, \quad \theta_q \neq 0 \\ \varepsilon_t \sim BB(0, \sigma_\varepsilon^2) \end{cases} \quad (2-19)$$

2.7 Modèle ARMA :

Un modèle ARMA stationnaire et inversible peut toujours se réécrire sous la forme d'un modèle AR ou d'un modèle MA. [50] DICKEY, D. A., & FULLER, W. A. (1981).

L'analyse des corrélogrammes constitue un des outils privilégiés dans l'identification du modèle.

-Les modèles ARMA. [55] GOURIEROUX, C. (1997).

Les processus ARMA sont des mélanges de processus AR et MA :ils sont définis par le modèle suivant :

$$\begin{aligned} \text{ARMA}(p, q) : x_t &= \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \cdot I \\ \text{ARMA}(1, 1) : x_t &= \phi_1 x_{t-1} + a_t - \theta_1 a_{t-1} \\ \text{ARMA}(2, 1) : x_t &= \phi_1 x_{t-1} + \phi_2 x_{t-2} + a_t - \theta_1 a_{t-1} ; \text{etc.} \end{aligned} \quad (2-20)$$

On remarque que : ARMA(0,q)=MA(q)et ARMA(p,0)=AR(p).

Cas particulier :

$$\text{ARMA}(p, 0) \text{ ou AR}(p) : X_t = \phi_1 X_{t-1} + \varepsilon_t \quad (2-21)$$

$$\text{ARMA}(0, q) \text{ ou MA}(q) : X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (2-22)$$

$$\text{ARMA}(0, 0) : \text{Bruit Blanc} : X_t = \varepsilon_t \quad (2-23)$$

2.8 Processus aléatoires non stationnaires

Les séries chronologiques sont rarement des réalisations de processus aléatoires stationnaires (CLEMENTS and HENDRY, 1998), c'est pour cela, nous étudierons les processus aléatoires non stationnaires qui peuvent être observés graphiquement soit à partir de la série d'origine (existence d'une tendance, variabilité croissante au cours du temps), soit à partir de la fonction d'autocorrélation et nous commencerons donc par présenter deux classes de processus non stationnaires, selon la terminologie de Nelson et Plosser (1982): les processus TS (Trend Stationary), qui correspondent à une non stationnarité de type déterministe et les processus DS (Difference Stationary), qui correspondent à une non stationnarité de type stochastique, puis nous présenterons les méthodes de stationnarisation pour chacune de ces classes de processus; ensuite, nous verrons apparaître les tests de racine unitaire de Dickey-Fuller, test de Phillips et Perron et test de KPSS (STEPHENS, 1976).

2.9 Processus bruit blanc (SPRAY et NEWELL, 1986).

Un processus $\{X_t\}$ est un bruit blanc s'il constitue un échantillon i.i.d. d'espérance nulle :

$$\begin{aligned} (1) EX_t &= \mu, \forall t \in T \\ (2) \gamma(t, s) &= \begin{cases} \sigma^2, & t = s \\ 0, & t \neq s \end{cases}, \forall t, s \in T \end{aligned} \quad (2-24)$$

La première condition signifie tout simplement que l'espérance du processus est indépendante du temps. La seconde condition implique bien entendu l'indépendance de la fonction d'autocovariance par rapport au temps (stationnarité). Mais elle implique en outre que les termes d'autocovariance sont tous nuls. Un processus stationnaire est fourni par les bruits blancs. Ce sont des suites de variables aléatoires de moyenne nulle, non corrélées et de même variance. Dans un modèle de régression on requiert que les résidus soient des bruits blancs. [61]

Nous avons donc deux classes de processus non stationnaires,

- **Processus TS** : (Trend Stationary) s'écrit :

$$y_t = \alpha + \beta t + \varepsilon_t \quad (2-25)$$

Où ε_t représente l'erreur du modèle à la date t.

Le processus TS est non stationnaire car $E=\alpha+\beta t$ dépend du temps t.

2.10 Processus DS (HIPEL, et MCLEOD, 1994).

Un processus non stationnaire ($x_t, t \in \mathbb{Z}$) est un processus DS (Differency Stationary) d'ordre d, Le processus DS (Differency stationnary) avec dérivé ($\beta \neq 0$) s'exprime: (COTTET, et SMITH, 2003).

$$y_t = y_{t-1} + \beta + \varepsilon_t. \quad (2-26)$$

Le processus DS avec dérivé est appelée marche aléatoire .




Figure 2-1 Processus non stationnaire : Trend Déterministe

plus généralement de la fonction du temps $f(t)$ dans la définition du processus ($x_t, t \in \mathbb{Z}$) .

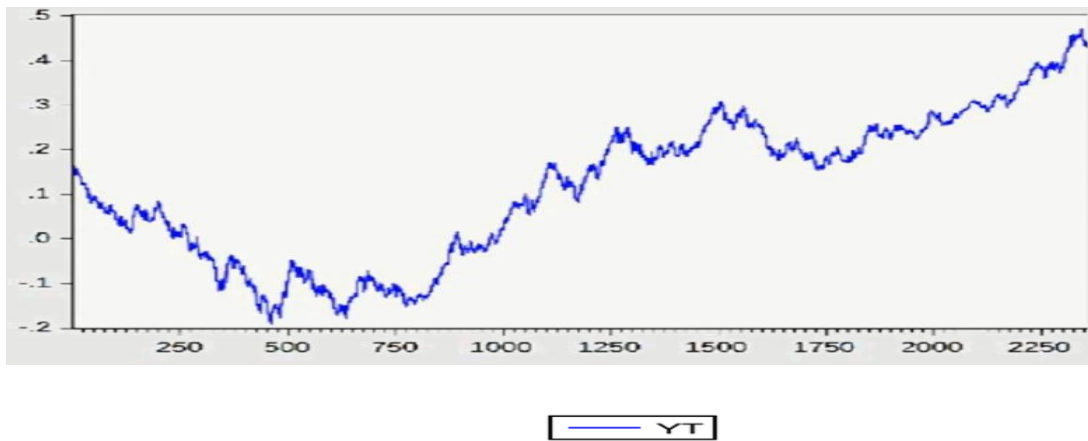


Figure 2-2 Processus non stationnaire : Modèle rupture

Sur la figure 7 est représentent la rupture de moyenne. Dans ce cas, la non stationnarité provient de la rupture du modèle, ou plus généralement de la non linéarité

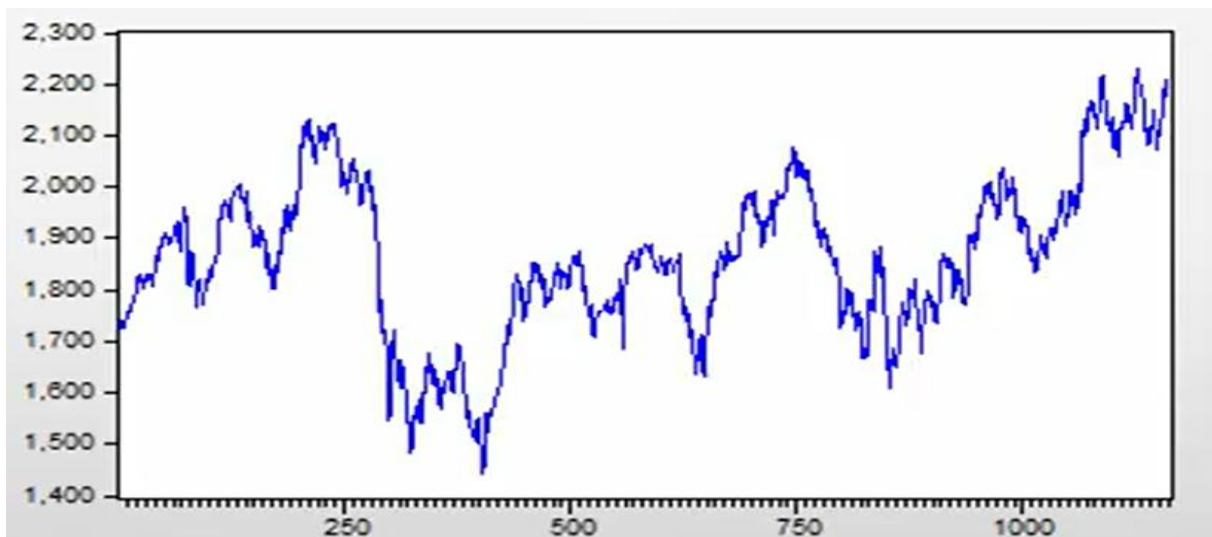


Figure 2-3 Processus non stationnaire : Variation Aléatoire

L'origine de la non stationnarité provient ici de l'accumulation de chocs stochastiques et

2.11 Tests de stationnarité (ou tests de racine unitaire)

- **Test de Racine Unitaire : le Test de Dickey Fuller' (LÜTKEPOHL, 1993).**

Le test de Dickey Fuller simple (1979) est un test de racine unitaire (ou de non stationnarité) dont l'hypothèse nulle est la non stationnarité d'un processus autorégressif d'ordre un.

Tableau 3.1. Analyse de la stationnarité

Valeur de la racine	Nature du processus
$\phi < 1$	Série stationnaire
$\phi = 1$	Série non stationnaire
$\phi > 1$	Série non stationnaire

Conditions de stationnarité	Résultats obtenus
$E[Y_t] = 0$	$E[Y_t] = \phi^t \cdot Y_0 + \alpha \cdot \sum_{i=0}^{t-1} \phi^i$
$\text{Var}[Y_t] = \sigma^2$	$\text{Var}[Y_t] = \sigma^2 \cdot \sum_{i=0}^{t-1} \phi^{2 \cdot i}$
$\text{Cov}[Y_t, Y_{t-k}] = f(\rho) = \rho_k$	$\text{Cov}[Y_t, Y_{t-k}] = 0$

on obtient généralement une racine unitaire (*unit root*) au niveau des coefficients AR ou MA. Pour poser le problème du test de la présence d'une racine unitaire, il est utile de décomposer une série en deux types de composantes: une composante déterministe TDT et une composante stochastique:

Le but des tests de racine unitaire est donc de tester la présence d'une racine unitaire dans la partie auto-régressive de la partie stochastique du processus de y_t (NERLOVE et al., 1995).

C'est dans la partie stochastique u_t que va pouvoir se trouver la racine unitaire. On va modéliser cette partie stochastique au moyen d'un processus ARMA:

Il existe plusieurs tests de racine unitaire : Tests de Dickey-Fuller simple et Dickey Fuller Augmenté test de Philips et Perron, Test de Kwrahowski, Philips Schmidt et Shin(Tzest de KPSS). Nous n'étudierons ici que les tests de Dickey-Fuller simple et Dickey Fuller Augmenté (LEVIN, et RUBIN, 1998).

2.12 Tests de Dickey-Fuller Simple :

Le test de Dickey-Fuller permet de savoir si une série est stationnaire ou non et permet aussi de déterminer la bonne manière de stationnariser la série. (GRANGER, 1980).

Les hypothèses du test sont les suivantes :

$$\left\{ \begin{array}{l}
 H_0 : \text{processus non stationnaire, il correspond à une de ces formes de non stationnarité :} \\
 [1] \quad y_t = \phi_1 y_{t-1} + \varepsilon_t \\
 [2] \quad y_t = \phi_1 y_{t-1} + c + \varepsilon_t \\
 [3] \quad y_t = \phi_1 y_{t-1} + bt + c + \varepsilon_t \\
 \\
 \text{où } \phi_1 = 1 \text{ et } \varepsilon_t \sim \text{iid}(0, \sigma_\varepsilon^2) \\
 \\
 H_1 : |\phi_1| < 1.
 \end{array} \right. \quad (2-27)$$

On peut écrire aussi les hypothèses sous la forme suivante :

$$\left\{ \begin{array}{l}
 H_0 : \text{processus non stationnaire, il correspond à une de ces formes de non stationnarité :} \\
 [1] \quad \Delta y_t = (\phi_1 - 1) y_{t-1} + \varepsilon_t \\
 [2] \quad \Delta y_t = (\phi_1 - 1) y_{t-1} + c + \varepsilon_t \\
 [3] \quad \Delta y_t = (\phi_1 - 1) y_{t-1} + bt + c + \varepsilon_t \\
 \\
 \text{où } (\phi_1 - 1) = 0 \text{ et } \varepsilon_t \sim \text{iid}(0, \sigma_\varepsilon^2) \\
 \\
 H_1 : \phi_1 < 1.
 \end{array} \right. \quad (2-28)$$

Si H_0 est vrai, la statistique de test pour l'estimateur de ϕ_1 donnée par : [79] NELSON C.R. et PLOSSER C. (1982).

$$t_{\hat{\phi}_1} = \frac{\hat{\phi}_1 - 1}{\hat{\sigma}_{\hat{\phi}_1}} \quad (2-29)$$

On a étudié le modèle général [3].

Si b est significativement différent de 0 ou non. Si b est significativement non différent de zéro. On passe à l'étude du modèle (ANDERSEN and WEISS, 1984). Si c significativement non différent de zéro. On étudie le modèle [1]

Si H_0 est vraie, les t de student de la constante et de la tendance sont à comparer avec les valeurs de la table de Dickey-Fuller (Pour une taille d'échantillon supérieure à 500 observations, les valeurs critiques sont : 2.78 à 5 pour la tendance du modèle [3], 2.52 pour la constante du modèle [2] et -1.95 pour le paramètre ϕ_1 (GRANGER, and NEWBOLD, 1997),

Les règles de décision sont les suivantes :

-Si $t > t_{DF}$: On accepte H_1 : le coefficient de la variable est significativement différent de 0.

t_{DF} : la valeur critique donné par table de DF.

Si $b \neq 0$ pour le modèle [3], le test s'arrête ici, on n'étudie pas les autres modèles. De même que si on arrive au modèle [2].

-Si $|t_{\phi_1}| > t_{DF}$. On accepte H_0 : la série est non stationnaire

Dans le test de Dickey-Fuller que nous d'étudier le processus aléatoire et est par hypothèse un bruit blanc. (MARTINO et JOSEPH, 1983).

2.13 Tests de Dickey-Fuller Augmenté (ADF) (VANDER VAART et WELLNER, 1996).

Ce test est applicable dans le cas d'autocorrélation des erreurs d'ou les articles de Dickey-Fuller (1981) étendent les résultats des tests que l'erreur suit un processus **AR(p)** et ils sont fondés sur l'estimation par MCO de trois modèles suivant (MELARD, 1990)

Dans le test de Dickey-Fuller Augmenté ne suppose pas que et est un bruit blanc

Les hypothèses des tests Dickey –Fuller Augmenté se définissent :

$$\left\{ \begin{array}{l} H_0 : \text{processus non stationnaire, il correspond à une de ces formes de non stationnarité :} \\ [1] \quad \Delta y_t = \rho y_{t-1} - \sum_{k=2}^p \gamma_k \Delta y_{t-k+1} + \eta_t \\ [2] \quad \Delta y_t = \rho y_{t-1} - \sum_{k=2}^p \gamma_k \Delta y_{t-k+1} + c + \eta_t \\ [3] \quad \Delta y_t = \rho y_{t-1} - \sum_{k=2}^p \gamma_k \Delta y_{t-k+1} + bt + c + \eta_t \\ \text{où } \rho = 0, \sigma_1 = 1 \text{ et } \eta_t \sim \text{iid}(0, \sigma_\eta^2) \\ H_1 : \sigma_1 < 1. \end{array} \right. \quad (2-30)$$

Pour déterminer la valeur de "p", il suffit de minimiser les critères d'information qui sont des critères fondés sur le pouvoir prédictif du modèle considéré et qui tiennent du nombre de paramètre à estimer (RAIHEN, 2013). Ces critères s'appliquent de façon générale à tout type de modèle et pas uniquement aux modèles des testes « ADF ». Nous retiendrons, le critère d'Akaike(1973) et le critère de Schwarz (1978).Pour un modèle, incluant "p" paramètres, estimé sur "T" périodes et dans la réalisation de l'estimateur de la variance des résidus est :

- Le critère d'Akaike, ou AIC est : [1] AKAIKE, H. (1973).

$$AIC(p) = T \text{Log}(\theta) + 2p \quad (2-31)$$

- Le critère de Schwartz (1978) est défini par :

$$SIC(p) = T \log(\theta) + p \log T \tag{2-32}$$

Détermination du retard p du test ADF :

La valeur p est de déterminer à l'aide du corrélogramme partiel de la série différence Δy_t .

Une fois détermine la valeur **p**, on procède de la même façon qu'avec le test de Dikey-Fuller simple :on commence par étudier la significativité de b du modèle [3].(ANSLEY et NEWBOLD, 1980).

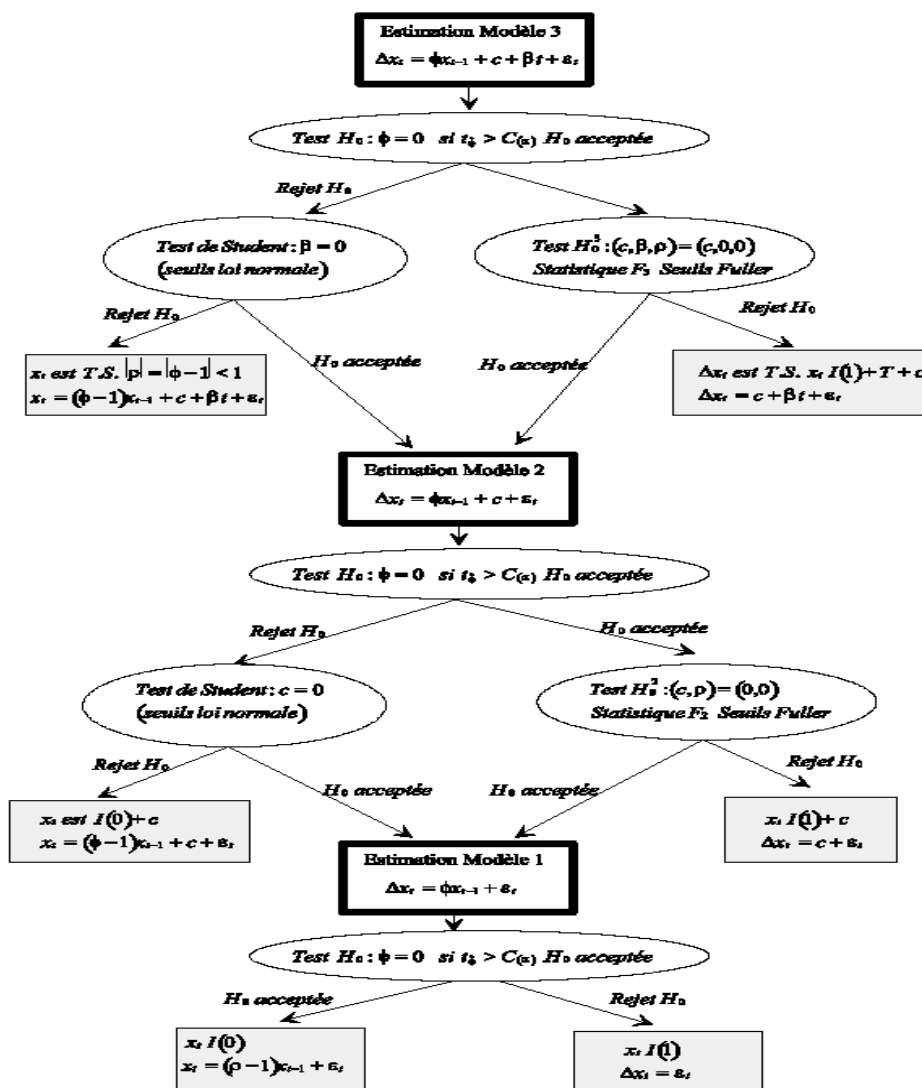


Figure 2-4 Stratégie de Tests de Dickey Fuller

(Chapitre 2. UFR Economie Appliquée. Cours de C. Hurlin)

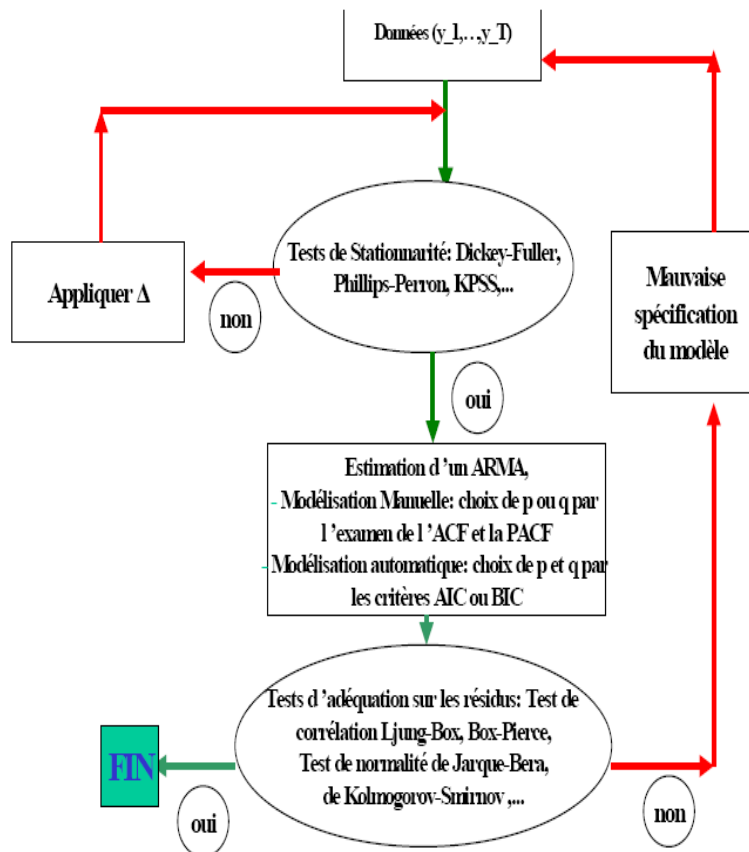


Figure 2-5 Schéma général de la modélisation d’une série temporelle par un modèle ARMA.

[Master M2-MINT : Séries Temporelles M.Boutahar]

Conclusion

En statistique, les modèles ARMA (modèles *autorégressifs et moyenne mobile*), et aussi modèle de Box-Jenkins, sont les principaux modèles de séries temporelles. Étant donné une série temporelle X_t , le modèle ARMA est un outil pour comprendre et prédire (KARLIN, and Howard, 1975), éventuellement, les valeurs futures de cette série. Le modèle est composé de deux parties : une partie autorégressive (AR) et l’autre partie moyenne-mobile (MA). Le modèle est généralement noté ARMA (p,q), où p est l'ordre de la partie AR et q l'ordre de la partie MA.

Un processus autorégressif est un modèle de régression pour séries temporelles dans lequel la série est expliquée par ses valeurs passées plutôt que par d'autres variables .Les tests de stationnarité permettent de vérifier si une série est stationnaire ou non, comme l’hypothèse

nulle H_0 est que la série est stationnaire ,et les tests de racine unitaire comme le test de Dickey-Fuller,le test augmenté de Dickey-Fuller (ADF).

Chapitre III

Modélisation et Critères D'évaluation de Prévision

CHAPITRE III

Introduction

Box et Jenkins (1976) ont promu une méthodologie consistant à modéliser les séries Temporelles univariées au moyen des processus ARMA (**Brockwell, et Davis, 2006**). Ces processus sont parcimonieux et constituent une bonne approximation de processus plus généraux pourvu que l'on se restreigne au cadre linéaire. Les modèles ARMA donnent souvent de bon résultats en Prévision et ont bénéficié de la vague de scepticisme quand a l'intérêt des gros modèles économétriques (voir par exemple Ashley (1988)). La méthodologie Box-Jenkins est une stratégie d'identification, d'estimation et de prévision de modèles de moyenne mobile intégrée autorégressive. (**ANSLEY et NEWBOLD, 1980**).

Cette méthodologie consiste en un cycle itératif en quatre étapes : (**KWLATKOWSKI et PHILIPS, 1992**).

a- Identification. En utilisant des graphiques, des autocorrélations, des autocorrélations partielles et d'autres informations, on va étudier le corrélogramme simple et partiel.

b- Estimation des paramètres du modèle.

c- Validation du modèle par des tests sur les coefficients et sur les résidus.

d- Prévisions

3.1 Méthode de Box&Jenkins

Analyse du Mouvement Saisonnier

Le mouvement saisonnier est une autre des grandes composantes des séries chronologiques. Il se définit comme la dépendance dans la corrélation d'ordre k entre chaque élément i de la série et l'élément (ik) (Kendall, 1976) ; il se mesure par l'autocorrélation (c'est-à-dire la corrélation entre les deux termes) ; k est appelé période ou décalage. Si l'erreur de mesure n'est pas trop importante, le mouvement saisonnier peut être identifié visuellement dans les séries comme un phénomène se répétant tous les k éléments.

Cette étape de la stationnarité de la série consiste à analyser le graphe de la fonction d'autocorrélation (FAC) et celui de la fonction d'autocorrélation partielle (FAP) afin de déterminer les paramètres (p,q) du modèle (**DROESBEKE , FICHET et TASSI, 1994**).

Les corrélogrammes, graphes de la fonction d'autocorrélation et de la fonction d'autocorrélation partielle permettent selon leurs aspects d'identifier correctement les

paramètres p et q . Le mouvement saisonnier des séries chronologiques peut être examiné à l'aide d'un corrélogramme. Le corrélogramme (auto-corrélogramme) affiche numériquement et graphiquement la fonction d'autocorrélation (FAC), c'est-à-dire les coefficients de corrélation de la série (ainsi que leurs erreurs-types) pour les périodes consécutives dans l'intervalle de période spécifié. Des intervalles de deux erreurs-types pour chaque période sont souvent indiqués dans le corrélogramme, mais l'importance de l'autocorrélation est souvent plus intéressante que sa fiabilité (l'autocorrélation très fortes est donc très significatives). L'autocorrélation est un concept lié à celui de corrélation : il s'agit non pas d'un calcul entre deux chroniques différentes mais entre la série et elle-même à différents décalages dans le temps (TONG, 1983).

Autocorrélations partielles :

Une autre méthode utile pour étudier les autocorrélations consiste à examiner la fonction d'autocorrélation partielle (FACP) - une extension de l'autocorrélation, où la dépendance des éléments intermédiaires (à l'intérieur de la période) est supprimée (DAVID et MICHAUD, 1989). En d'autres termes l'autocorrélation partielle est similaire à l'autocorrélation, à la différence près que lors des calculs, les autocorrélations avec tous les éléments de la période sont partiellement éliminées (Box et Jenkins, 1976) ; voir aussi (McDowall, McCleary, Meidinger, et Hay, 1980). En spécifiant un décalage de 1 (c'est-à-dire qu'il n'existe pas d'éléments intermédiaires dans la période), l'autocorrélation partielle sera équivalente à l'autocorrélation. D'une certaine manière, l'autocorrélation partielle offre une image "plus claire" de l'autocorrélation des périodes individuelles (elle n'est pas perturbée par les autres autocorrélations (WANG, Li, et TSAI, 2007).

Autocorrélations :

Une autocorrélation est la corrélation d'une série avec elle-même, décalée d'un certain nombre k d'observations [49] ESPINOZA, M., J. A. K. SUYKENS, et al. (2006). Le tracé des autocorrélations pour différents décalages est un outil particulièrement utile pour déterminer le modèle approprié pour une analyse. Les calculs des coefficients d'autocorrélation r_k suivent les formules standard, décrites dans la plupart des ouvrages de référence traitant des séries chronologiques (par exemple, Box et Jenkins, 1976).

Lorsque le nombre d'observations est important, la statistique Q suit une distribution du Chi^2 à $k-p-q$ degrés de liberté, où p et q représentent respectivement le nombre de paramètres autorégressifs et de moyenne mobile.

La **fonction d'autocorrélation**, notée FAC, est constituée par l'ensemble des autocorrélations $\rho_k = \text{corr}(y_t, y_{t-k})$ de la série calculé pour des décalages d'ordre k .

Le **coefficient d'autocorrélation d'ordre k** , ρ_k , peut être estimé par :

$$r_k = \frac{\sum_{t=k+1}^n (y_t - \bar{y}_1)(y_{t-k} - \bar{y}_2)}{\sqrt{\sum_{t=k+1}^n (y_t - \bar{y}_1)^2 \sum_{t=k+1}^n (y_{t-k} - \bar{y}_2)^2}} \text{ avec } \bar{y}_1 = \frac{1}{n-k} \sum_{t=k+1}^n y_t \text{ et } \bar{y}_2 = \frac{1}{n-k} \sum_{t=k+1}^n y_{t-k} \quad (3-33)$$

Une autocorrélation partielle est la corrélation d'une série avec elle-même, décalée d'un certain nombre k d'observations, les corrélations de tous les décalages de 1 à $k-1$ étant sous contrôle. Le tracé des autocorrélations partielles pour de nombreux décalages est un outil particulièrement utile pour déterminer le modèle approprié dans une analyse ARMA (**DROESBEKE, FICHET et TASSI, 1995**). Les calculs des coefficients d'autocorrélation partielle f_k correspondent à la formule standard décrite dans la plupart des ouvrages de référence traitant des séries chronologiques (par exemple, Box et Jenkins, 1976). La fonction d'autocorrélation partielle, notée FAP, est constituée par l'ensemble des autocorrélations partielles, le coefficient d'autocorrélation partielle mesurant la corrélation entre les variables entre Y_t et Y_{t-k} , l'influence de la variable Y_{t-k-j} étant contrôlée pour $i < k$

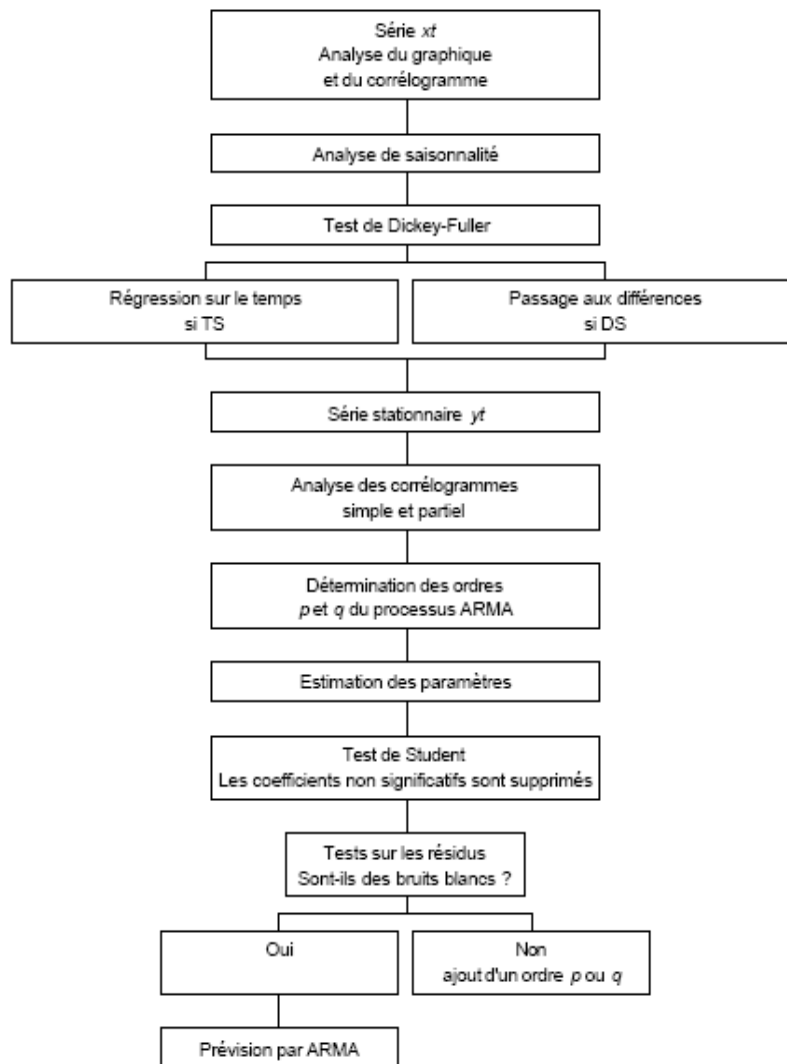


Figure 3-6 Méthodologie de Box et Jenkins

L'approche de Box-Jenkins (1976) consiste en une méthodologie rigoureuse d'étude systématique des séries chronologiques à partir de leur caractéristique. L'objectif est de déterminer le modèle le plus adapté à représenter le phénomène étudié. Il faut bien noter qu'il est tout à fait possible d'obtenir plusieurs modèles satisfaisants.

La méthodologie de Box et Jenkins permet de déterminer le processus ARMA adéquat pour la modélisation d'une chronique. La méthodologie B&J suggère quatre étapes, à noter : l'identification, l'estimation, la validation et la prévision (ARMSTRONG, 2001).

3.2 Stationnarisation et Dessaisonalisation

Nous ne pouvons interpréter valablement les corrélogrammes que sur des séries stationnaires (Sans tendance). Les tests de Dickey-Fuller (1979) et Dickey-Fuller Augmenté (1981) permettent de déterminer si la série est stationnaire et, dans le cas d'une non stationnarité, de quel type il s'agit : TS (« Trend Stationary») qui représente une non stationnarité de type déterministe ou DS (« DifferencyStationary») pour les processus non stationnaires stochastiques (Tidjani, Yebdri et Roth, 2006). Si la série étudiée est de type TS, il convient de la stationnariser par régression sur le temps ; le résidu d'estimation est alors étudié selon la méthodologie de Box-Jenkins. Ceci permet de déterminer les ordres p et q des parties AR et MA du résidu. Le modèle est toujours dans ce cas un ARMA (p, q).

Si la série étudiée est de type DS, il convient de la stationnariser par passage aux différences selon l'ordre d'intégration $I = d$ (d est le nombre de fois qu'il faut différencier la série pour la rendre stationnaire). La série différenciée est alors étudiée selon la méthodologie de Box-Jenkins qui permet de déterminer les ordres p et q des parties AR et MA. On note ce type de modèle ARMA (p, q) (BOX, et PIERCE, 1970).

3.3 Tests de la stationnarité (BROZE et MÉLARD, 1990).

- Examen visuel de la série
- Calculs de la moyenne et de la variance sur des sous ensembles de la série et tests d'égalité
- Analyse visuelle de la décroissance de la fonction d'autocorrélation
- Tests de racine unitaire (Dickey-Fuller, ...)




Figure 3-7 Série stationnaire




Figure 3-8 Série non stationnaire en moyenne




Figure 3-9 Série non stationnaire en variance

3.4 Identification du modèle Box-Jenkins

La phase d'identification est la plus importante et la plus difficile : elle consiste à déterminer le modèle adéquat, c'est-à-dire les valeurs des paramètres p , q du modèle ARMA. Elle est fondée sur l'étude des corrélogrammes simple et partiel **MAKRIDAKIS, WHEELWRIGHT and MCGEE, 1983**).

Cette étape à obtenir la stationnarité des données en interprétant le graphique des auto-covariances. Un processus non-stationnaire a ses auto-covariances qui décroissent l'entement à l'inverse d'un processus stationnaire.

3.5 Estimation du modèle Box-Jenkins [modifier]

L'estimation des paramètres d'un modèle ARMA (p ; q) lorsque les ordres p et q sont supposés connus peut se réaliser par différentes méthodes dans le domaine temporel : Nous allons présenter ici brièvement la démarche de l'estimation par le maximum de vraisemblance. (Box and Jenkins 1970) **(BISGAARD and M. KULACHI 2011)**.

L'étape 2 repose également sur l'interprétation de graphiques pour choisir l'ordre des parties AR et MA. On sait que les auto-correlations d'un processus MA(q) deviennent nulles à partir de l'ordre $q + 1$. Si le graphique des auto-correlations empiriques chute brusquement après $h = q$, on pourra donc dire que l'on est en présence d'un MA(q). Si l'on considère maintenant les autocorrélations totales d'un AR(p), on sait qu'elles décroissent lentement dans le temps. Mais il n'est guère possible de déduire une valeur de p à partir de l'examen du correlogramme. On cherche donc une transformation du correlogramme qui soit plus interprétable. Il s'agit du graphique des auto-correlations partielles. Les autocorrélations partielles ont la propriété d'être nulles à partir de l'ordre $p + 1$ pour un processus AR(p).

3.6 Validation du processus ARMA:

Lorsque la détermination des ordres p et q du processus ARMA (p,q) à l'aide des correlogrammes simple et partiel. On peut être amené à sélectionner plusieurs ordres possibles p et q pour le processus ARMA (p,q). Après avoir estimé les différents processus ARMA (p,q) possibles, il reste à les valider et à les partager. La validation des processus passe par un examen des coefficients estimés (ils doivent être significativement différent de 0) et par un examen des résidus (les résidus estimés doivent suivre un processus de bruit blanc (**BOX et JENKINS, 1976**)).

A l'étape de l'identification, les incertitudes liées aux méthodes employées font que plusieurs modèles, en générale, sont estimés est c'est l'ensemble de ces modèles qui subissent alors l'épreuve des tests. Il en existe de très nombreux permettant d'une part de valider le modèle retenu, d'autre part, de comparer les performances entre les modèles.

Validation du modèle par tests sur les coefficients et sur les résidus.

– Les coefficients du modèle qui doivent être significativement différents de 0 (le test de Student s'applique de manière classique). Si un coefficient n'est pas significativement différent de 0, il convient d'envisager une nouvelle spécification éliminant l'ordre du modèle AR ou MA non valide (**LJUNG et BOX ,1978**).

– L'analyse des résidus (écart entre la série observée et la série prévue) permet de vérifier de moyenne nulle ; dans le cas contraire, il convient d'ajouter une constante au modèle ; représentatif d'un bruit blanc. Si le résidu n'est pas un bruit blanc, cela signifie que la spécification du modèle est incomplète et qu'il manque au moins un ordre à un processus.

La phase de validation du modèle est très importante et nécessite le plus souvent un retour à la

phase d'identification (**CHATFIELD,C. 2001**),

3.7 Tests de Validation

3.7.1.1 Test de redondance :

Le but de ce test est de vérifier si les composantes « AR » et « MA » de "ARMA" n'ont pas des racines communes au moyen, par exemple, des algorithmes de Newton-Raphson. Lorsque c'est le cas, on dit qu'il ya redondance et les coefficients estimés du modèle sont instables et peuvent conduire à des prévisions erronées. Il faut alors éliminer dans le modèle "ARMA" la ou les variables responsables de cette redondance (**CHATFIELD, 2001**).

3.7.1.2 Test de significativité :

Ce test, nous permet d'effectuer le test de Student sur chacun des paramètres de processus « ARMA » en divisant le paramètre par son écart type. Il peut arriver qu'un ou plusieurs paramètres ne soit pas significativement différents de « 0 » : le modèle est alors rejeté et on retourne à l'étape d'estimation en éliminant la variable dont le coefficient n'est pas significatif.

3.7.1.3 Test de recherche d'autocorrélation :

➤ Test de Box-Pierce (1970)

On note « ρ » l'autocorrélation d'ordre « k » du processus, pour un ordre « k », le test de Box et Pierce est : Pour un processus ARMA (p, q) la statistique de test est :

$$Q = n \sum_{k=1}^h r_k^2 \quad (3-34)$$

L'hypothèse est rejetée au seuil 5% s'il est supérieur à la quantité 0.95 de la loi (**BOX et JENKINS, 1970**).

3.7.1.4 Test de Ljung-Box

La statistique de Ljung-Box est un test modifié de la statistique du Khi-deux de Box-Pierce (**GASMI, 2019**),

La statistique Ljung-Box Q permet de déterminer si une série d'observations dans le temps est aléatoire et indépendante. Si les observations ne sont pas indépendantes, une observation peut

être corrélée avec une autre observation k unités de temps après, établissant ainsi une relation appelée autocorrélation. L'autocorrélation peut nuire à l'exactitude d'un modèle de prévision basé sur le temps (**KADIYALA, 1970**).

Ce test est appliqué de préférence au test de Box-Pierce :

$$Q = n(n+2) \sum p_k^2 / (n-k) \quad (3-35)$$

n : la taille de l'échantillon

p_k : autocorrélation d'échantillon

Statistique de test :

- **Test d'homoscidasticité :**
- **Test ARCH d'Engle(1982)**

Ce test est très fréquemment utilisé de série temporelle (**GEP, GAILIM, JENKINS, and GREGORY 1976**).

- **Test ou méthode de Méland (1992)**

Il s'intéresse à la représentation graphiquement de la fonction d'autocorrélation de la série de carré de résidu. Si ce terme est significativement 0 ; il est une hétéroscédasticité (**DACUNHA, CASTELLE et DUFLO, 1985**).

- **Test de normalité (GOURIEROUX et MONFORT, 1995).**

En statistiques, les tests de normalité permettent de vérifier si des données réelles suivent une loi normale ou non. Les tests de normalité sont des cas particuliers des tests d'adéquation (ou tests d'ajustement, tests permettant de comparer des distributions), appliqués à une loi normale.

Il est possible de visualiser la forme de la distribution des données à analyser en les représentant sous forme d'histogramme puis de comparer la forme de cet histogramme avec une courbe représentant une loi normale (les paramètres de cette loi étant calculés à partir des données à analyser). Ceci ne permet pas de conclure à la normalité des données mais peut donner une idée du type de loi sous-jacente : loi normale, loi de Cauchy ou loi de Student si la distribution semble symétrique (**WEISS et ANDERSEN, 1984**).

Le test le plus classique de Jarque et Berra est fondé sur la notion de Skewness (asymétrie) et du Kurtosis (aplatissement)

- **Les tests du Skewness et Kurtosis (Harvez, 1993).**

Soit le moment empirique d'ordre K du processus

Le coefficient de Skewness :

Le coefficient de Kurtosis :

Alors les statistiques sont :

Avec (0, 3) sont les distributions normal de Skewness et Kurtosis

- **Test de Skewness (aplatissement)**

On test les hypothèses suivantes :

- **Test de Skewness**

H0 : $\nu_1 = 0$ (La distribution du résidu est symétrique)

H1 : $\nu_1 \neq 0$ (La distribution des résidus est asymétrique)

$$v_1 = \frac{|\beta_1^{1/2} - 0|}{\sqrt{\frac{6}{n}}}$$

(3-36)

Test de Kurtosis (aplatissement)

H0 : $\nu_2 = 0$ (La distribution des résidus est relativement aplatie)

H1 : $\nu_2 \neq 0$ (La distribution des résidus n'es t pas aplati)

$$v_2 = \frac{|\beta_2 - 3|}{\sqrt{\frac{24}{n}}} \tag{3-37}$$

- **Test de Jarque et Berra (Harvez, 1993),**

Le test de Jarque et Berra regroupe ces deux tests en un seul test qui est :

H0 : Les résidus sont normaux

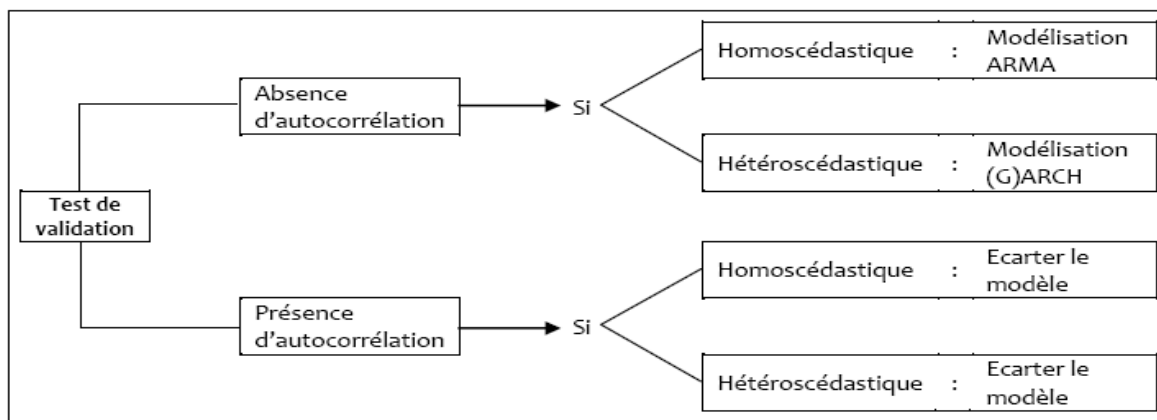
H1 : Absence de normalité des résidus

La statistique S

$$JB = \frac{n - k}{6} \left(S^2 + \frac{(K - 3)^2}{4} \right) \tag{3-38}$$

Ces deux derniers tests permettent de préciser le modèle à utiliser pour la prédiction.

Tableau.4.1. Test de Validation
(STATISTIQUE APPLIQUEE Par Jean-Paul TSASA Vangu 2009-2010)



3.8 Prévisions

C'est la dernière étape de la méthodologie de Box et Jenkins. Connaissant l'horizon de prévision (h), la prévision faite en T pour la date $T+h$ est donnée par \hat{Y}_{T+h} :

Lorsque le modèle est validé, la prévision peut alors être calculée à un horizon h de quelques périodes, limité par la variance de l'erreur de prévision qui augmente rapidement avec l'horizon.[73] ainsi, on note

\hat{Y}_{T+h} La prévision de Y_{T+h} au temps $T+h$ où T est la taille de l'échantillon des observations Y_t et h l'horizon de la prévision. Selon Wold (1948) , le processus Y_{T+h} prend en quelque sorte la forme d'un MA(∞) [53]:

$$Y_{T+h} = \sum_{j=0}^{\infty} \psi_j \varepsilon_{T+h-j} = \varepsilon_{T+h} + \psi_1 \varepsilon_{T+h-1} + \psi_2 \varepsilon_{T+h-2} + \dots \quad (3-39)$$

Alors que la prévision \hat{Y}_{T+h} s'écrit :

$$\hat{Y}_{T+h} = \sum_{j=1}^{\infty} \psi_j \varepsilon_{T+h-j} = \psi_1 \varepsilon_{T+h-1} + \psi_2 \varepsilon_{T+h-2} + \dots \quad (3-40)$$

L'erreur de prévision est déterminée par :

$$Y_{T+h} - \hat{Y}_{T+h} = \sum_{j=0}^{h-1} \psi_j \varepsilon_{T+h-j} = \varepsilon_{T+h} \quad (3-41)$$

A l'étape de la transformation, plusieurs techniques ont pu être employées afin de stationnariser le processus générateur pour qu'il soit identifiable dans la classe des processus ARMA. Il est nécessaire, lors de l'étape de prévision, de prendre en compte la ou les transformations retenues.

– Si on a utilisé la régression afin de retirer une ou plusieurs composantes déterministes estimées par les moindres carrés ordinaires, ces dernières sont extrapolées jusqu'à l'horizon prévisionnel choisi puis combinées aux valeurs prévisionnelles de l'ARMA (**GOURIEROUX et MONFORT, 1990**).

– Si la série a été préalablement désaisonnalisée, il convient de re-saisonnaliser la série des Données de production d'eau potable afin d'obtenir une prévision en termes bruts (**LINEESH, MINU and JESSY JOHN, 2010**).

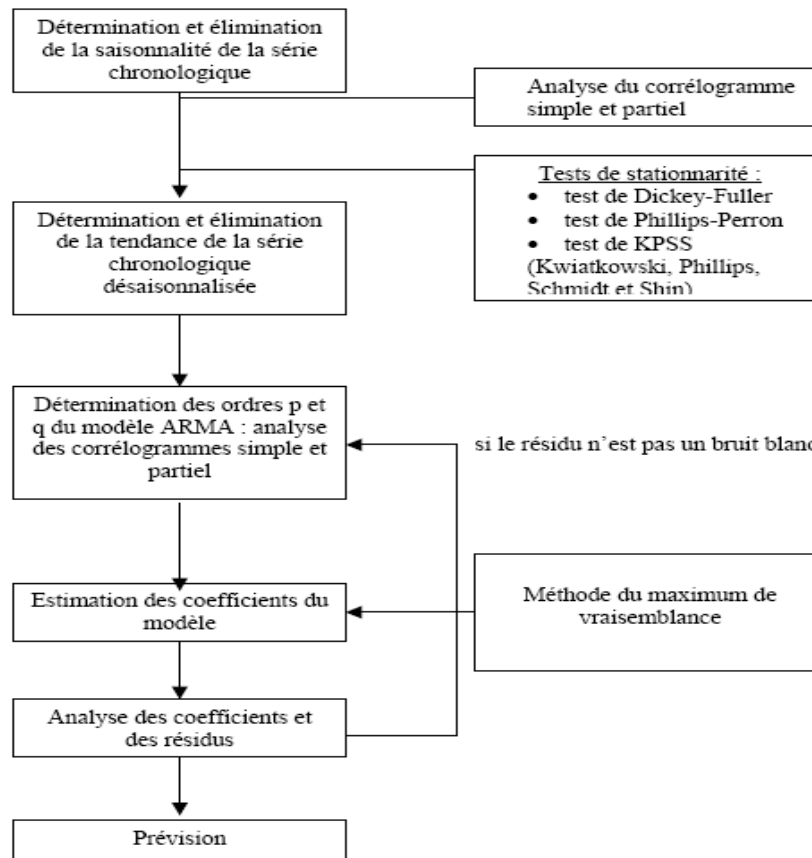


Figure 3-10 Méthodologie de Box et Jenkins [16]

(BOX, G.E.P. ET PIERCE, D.A. 1970).

3.9 Choix d'un modèle

3.9.1 Critère de pouvoir prédictif (BENNIS, 1987).

Dans un modèle ARMA, l'erreur de prévision à horizon dépend de la variance du résidu. On peut alors choisir le modèle conduisant à la plus petite erreur de prévision. Plusieurs indicateurs sont (ASHLEY, 1988).

- (1). La variance du résidu, ou la somme des carrés des résidus SCR
- (2). Le coefficient de détermination R^2 , correspondant à une normalisation de la variance
- (3). Le coefficient de détermination modifié R^2
- (4). La statistique de Fisher (comme dans le cas du modèle linéaire)

Le but est alors de minimiser (1), ou de maximiser (2) ; (3) ou (4).

Après examen des coefficients et des résidus, certains modèles sont écartés. Pour départager les modèles restants, on appelle aux critères standards et aux critères d'information (BERNARD, BOLDU et AL, 1996).

3.9.2 Critères standards (BOURBONNAIS, 1998).

. L'erreur absolue moyenne (Mean Absolute Error) :

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (3-42)$$

le résidu du modèle ARMA étudié et n le nombre d'observation.

.Racine de l'erreur quadratique moyenne (Root Mean Square d'Error) :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3-43)$$

.Ecart absolu moyen en pourcentage (M) (Mean Absolute Percent Error) MAPE :

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (3-44)$$

3.9.3 Les critères d'information de comparaison des modèles:

Plusieurs estimateur de la quantité d'information ont été proposés, dans le cas de modèles ARMA (p; q), à partir de T observations (BERNARD, D.BOLDU ET AL., 1996).

Au-delà des critères standard (MSE, MAE,...) ; on étudie les critères propres aux modèles autorégressifs qui sont par exemple :

-Critère Akaike (AIC)

-Critère Schwarz (SIC)

L : la vraisemblance du modèle estimé,

N : le nombre d'observations dans l'échantillon

K : le nombre de paramètres libres du modèle

Conclusion

Dans ce chapitre, nous avons présenté un aperçu de la méthode Box-Jenkins, en nous concentrant sur les étapes de la méthode Box - Jenkins consiste à transformer une série non stationnaire en une série stationnaire.

Box-Jenkins Analysaient fait référence à une méthode systématique d'identification, d'ajustement, de vérification et d'utilisation de modèles de séries temporelles autorégressives, moyennes mobiles (ARMA). La méthode est appropriée pour les séries chronologiques.

La prévision des séries chronologiques économétriques peut être faite avec gamme de modèles incluant des modèles essentiellement linéaires et non linéaires (**LEJEUNE, 1997**).

Pour évaluer les prévisions ; on peut mesurer la qualité d'une prévision et calculer les indicateurs de mesure (MSE, MAE, RMSE, MAPE, ...et coefficient de Theil). On dit que la prévision est bonne si ces mesures sont proches de « 0 ».

L'objectif de la modélisation est de déterminer combien de paramètres auto-régressifs (p) et de moyennes mobiles (q) sont nécessaires pour obtenir un modèle effectif et parcimonieux du processus (parcimonieux signifie qu'il s'agit, parmi tous les modèles possibles, du modèle possédant le moins de paramètres et le plus grand nombre de degrés de liberté pour ajuster les données) (**BOURBONNAIS et TERRASA, 1998**).

Chapitre 1V
Contexte général

CHAPITRE IV

Introduction

La ville de Biskra, chef-lieu de la wilaya de Biskra, est située aux portes du Sahara au Sud - Est de l'Algérie, dans une zone semi-aride. La Wilaya occupe une superficie de 21672 Km². L'alimentation d'eau potable de la ville de Biskra s'effectue actuellement à partir de six champs captants (champ captant oued el Hai, champ captant el megloub, champ captant oued Z'mor, Champ captant H'zaima, champ captant interne est ensemble des forages ou l'eau est injectée directement dans le réseau.

L'ADE unité de Biskra, prend en charge la gestion de l'eau du (05) communes en matière : Production, Distribution, Maintenance et entretien des réseau d'AEP.

4.1 Présentation de la zone d'étude

La ville de Biskra est située aux portes du Sahara au centre Est de l'Algérie, d'une superficie de 50 Km². La ville de Biskra est alimentée par des ressources souterraines constituées par le système aquifère profond et s'étend sur un million de Km² et comprend deux grandes nappes :

- Nappe continentale intercalaire (CI).
- Nappe complexe terminal (CT).

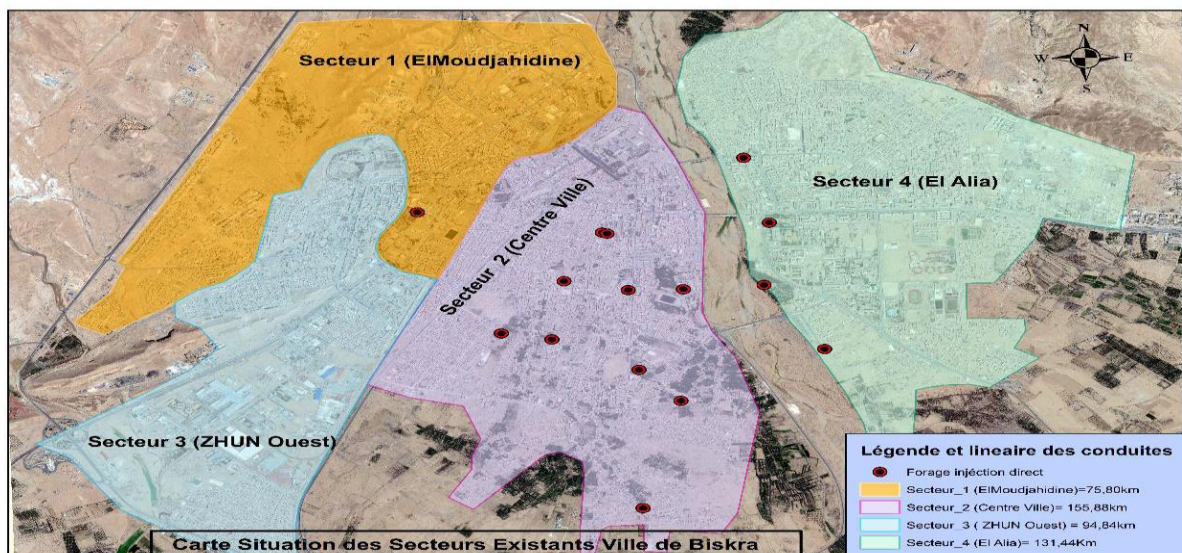


Figure 4-11 situation des secteurs existants Ville de Biskra [56] Groupement Bureaux d'Etude :(PROSPECTIVA, PROENGEL, SATEIG,2020)

La ville de BISKRA est alimentée principalement par des eaux sous-terraines de 41 forages répartis sur cinq champs captant :

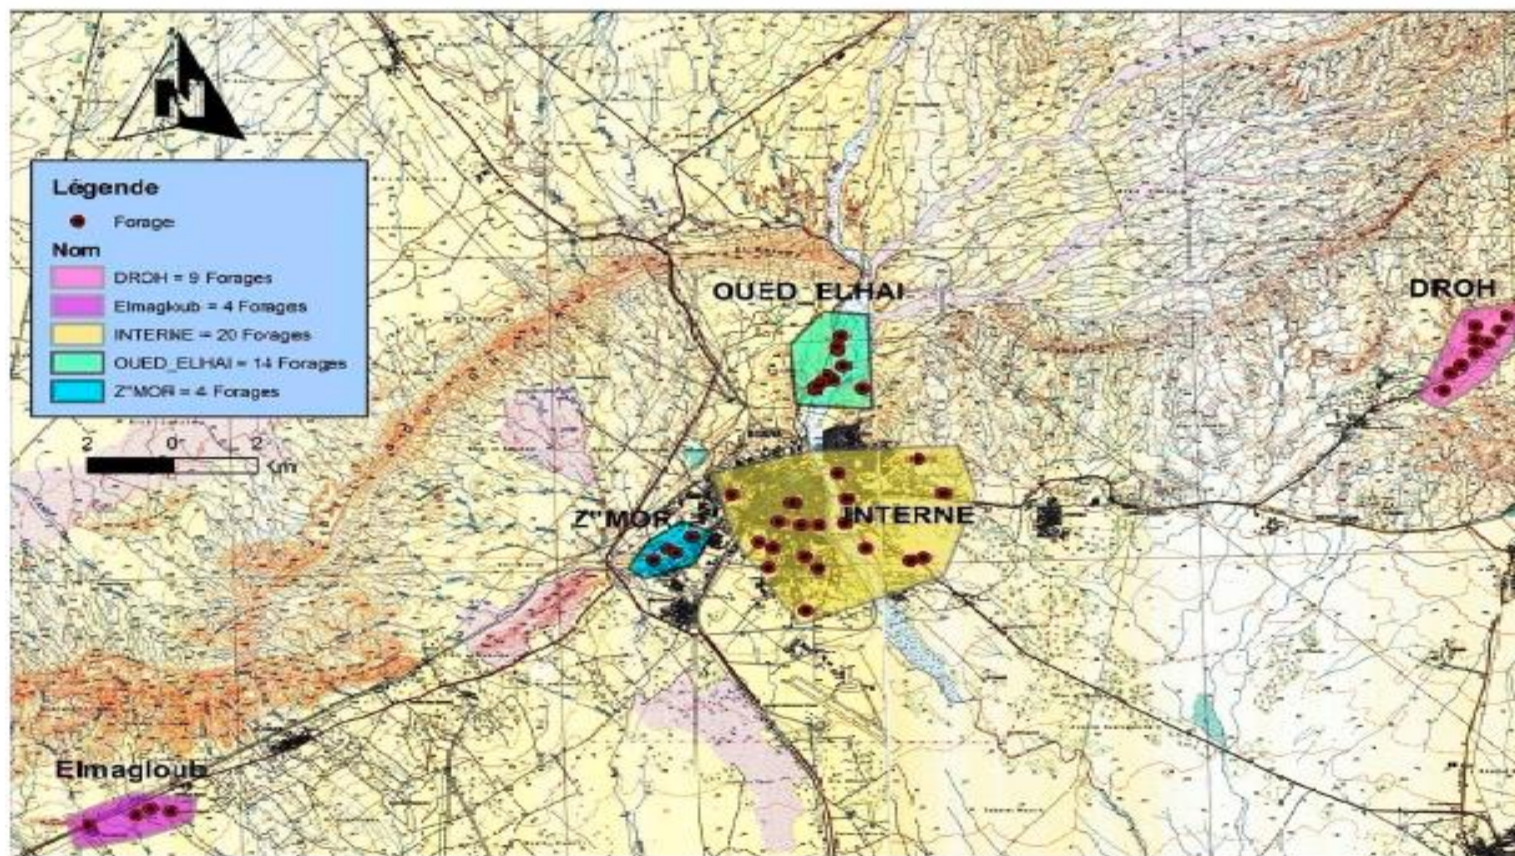


Figure 4-12 situations des champs captant

4.1.1 Champ captant Oued el Hai (Oued Biskra)

Situé au nord de la ville, il est constitué de 14 forages, le débit total desservi est de 335 l/s du débit qui alimente la ville, il assure 36% des besoins de la ville.

Tableau .1.1. Les débits des ouvrages de production (Champ Captant Oued El Hai)

Ouvrages de production	Débit mobilisé (l/s)	Débit d'exploitation (l/s)	Profondeur(m)
F1	40	15	40
F2	40	30	40
F3	50	30	41
Sif4	33	28	50
Environnement 01	35	30	200
Environnement 02	35	20	200
Sif6	30	32	40
Sif6bis	45	27	44
B1	100	45	40
B1bis	25	22	70
B2	35	28	45

4.1.2 Champ captant el Megloub

Situé à 14 Km environ à l'ouest de la ville, il est constitué de 04 forages contribuant par une production de 58 l/s et assure 6 % des besoins de la ville

Tableau.1.2. Les débits des ouvrages de production (Champ Captant El Megloub)

Ouvrages de production	Débit mobilisé (l/s)	Débit d'exploitation (l/s)	Profondeur(m)
BN1	30	19	200
BN2	25	9	200
BN3	15	9	200
F7Bis	24	21	155

4.1.3 Champ captant interne

Il comporte 18 forages. Contribuant par une production de 269 l/s et assure 30% des besoins de la ville.

Tableau .1.3. Les débits des ouvrages de production (Champ Captant Interne)

Ouvrages de production	Débit mobilisé (l/s)	Débit d'exploitation (l/s)	Profondeur(m)
Sidi Abdoune	27	12	125
R'maiche	25	19	100
Résidence	25	10	110
Ras el Gueria2	15	21	130
Jeune Aveugles	30	20	130
Ben Nacer	33	20	152
Hakim Saadanne	35	16	122.5
Gendermerie	15	12	150
ZP1	16	14	162
ZP3	16	15	200
Lébcheche 01	20	13	120
Lébcheche 02	20	12	120
BabDhareb	10	06	130
Felliache 1	40	23	120
Felliache 2	15	10	120
El Haouza	27	23	140
Camping	27	26	155
Boukhelfa	35	22	100
1 ^{er} Novembre	15	13	200
Dromane	35	25	151
Chehaima	24	20	144

4.1.4 Champ captant oued Z'mor

Situé à l'ouest de la ville, il assure 9% des besoins de la ville par une production de 74 l/s.

Tableau .1.4. Les débits des ouvrages de production (Champ Captant Oued Z'mor)


Ouvrages de production	Débit mobilisé (l/s)	Débit d'exploitation (l/s)	Profondeur(m)
ZF1	17	15	300
ZF2	17	15	300
ZF3	16	15	280
Surpresseur	20	18	300
1 ^{er} Novembre	15	13	200

4.1.5 Champ captant Droh

Situé au nord de la ville, constitué un renforcement pour les trois secteurs de la ville par l'alimentation des réservoirs de chaque secteur, il contribue par un apport de 180 l/s qui représente 19% des besoins de la ville

Tableau .1.5. Les débits des ouvrages de production (Champ Captant Droh)

Ouvrages de production	Débit mobilisé (l/s)	Débit d'exploitation (l/s)	Profondeur(m)
FD1	40	27	320
FD2	25	12	350
FD3	30	21	233
FD4	35	25	350
FD5	35	22	340
FD6	35	13	340
FD8	20	18	340
FD9	45	25	360
FD10	38	17	370

**Figure 4-13 Répartition de la production d'eau potable par champ captant**

L'Algérienne des eaux de l'unité de Biskra (ADE) assure l'approvisionnement d'une ressources en eau potable, pour les 411066 habitant, par l'exploitation de 91 forages de la wilaya de Biskra et 34 réservoir d'une capacité 71000 m³ à travers un réseau d'AEP de 778524 ml (214747ml adduction et 563777 ml distribution) et 4 stations de pompages d'une capacité 61344 m³/j). La présente étude s'intéresse à la modélisation de séries chronologiques pour l'identification d'un processus ARMA (Modèles autorégressifs et moyenne mobile), donnent souvent de bons résultats en prévision des données de production d'eau potable. La classification par âges des forages révèle qu'au cours des vingt dernières années le nombre de forages a doublé, ce qui caractérise d'une partie de l'évolution de la ville par rapport à ces besoins en eau.




Figure 4-14 : Classification des forages par années de mise en service

4.2 Présentation des données

Dans cette étude on va essayer d'analyser une série des données mensuelles de l'eau potable de la ville de Biskra , couvrent la période de janvier 2009 à janvier 2016,et nous tentons de découvrir ces composantes, sa nature, et l'effet qui influencent de la série afin d'avoir une meilleurs prévision à court terme .La simple visualisation des données de production sur une période de plusieurs années amène à constater la présence de tendances et de cycles répétitifs. Les principaux outils mathématiques utilisés pour le traitement des données sont les facteurs d'auto covariances, les méthodes statistiques constituent un outil d'identification des paramètres du modèle. En appliquant les méthodes de BOX-Jenkins. La méthodologie de Box et Jenkins est une technique d'extrapolation par référence à une loi de reproduction du phénomène étudié. La première étape de l'étude d'une série chronologique est la représentation graphique. Cette visualisation donne des indications très précieuses pour choisir un modèle. La gestion de la ressource en eau trouve son point de départ dans la mesure de ce débit exploité est l'un des outil le plus important dont l'exploitant a besoin.

4.3 Méthodologie et approche expérimentale

Différents techniques ont été développés pour modéliser les données de production d'eau potable tant avec les outils classiques de l'économétrie des séries temporelles, qu'avec les méthodes statistiques (méthodes univariées). La méthodologie de Box et Jenkins est une technique d'extrapolation par référence à une loi de reproduction du phénomène étudié. Elle

se base sur une stratégie d'identification, d'estimation et de prévision de modèles de moyenne mobile autorégressive. La méthodologie de Box et Jenkins est une technique d'extrapolation par référence à une loi de reproduction du phénomène étudié. Box et Jenkins (1976) ont promu une méthodologie consistante à modéliser les séries temporelles univariées au moyen des processus ARMA (ARMSTRONG, 1978).

Le modèle *ARMA* [Box et Jenkins, 1976] a été introduit pour reconstituer le comportement de processus soumis à des chocs aléatoires appelé **perturbation**. (ANDERSEN et WEISS, 1984).

REPRÉSENTATION SCHEMATIQUE DE L'APPROCHE BOX-JENKINS

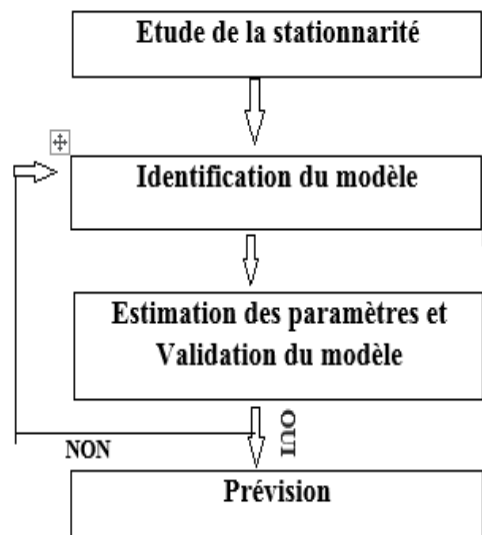


Figure 4-15 La méthode Box-Jenkins pour une sélection optimale du modèle

(BOX, G.E.P. ET PIERCE, D.A. 1970).

Conclusion

La méthodologie de Box et Jenkins permet de déterminer le processus ARMA adéquat pour la modélisation d'une chronique et de recherche systématique d'un modèle adéquat en fonction de l'étude des corrélogrammes empiriques, ils se réfèrent à deux types de modèle : des processus moyennes mobiles (MA), des processus autorégressifs (AR). La méthodologie B&J suggère quatre étapes, à savoir : l'identification, l'estimation, la validation et la prévision. (BISGAARD and KULACHI, 2011).

Chapitre V
Prévision par la méthode de
de Box-Jincks



Légende

- Point top
- Champ captif



CHAPITRE V

Introduction

Dans cette partie, on utilise le logiciel statistique E-Views7. Ce logiciel donne une prévision de l'analyse des données scientifiques et l'analyse des données de production d'eau potable mensuelle de la ville de Biskra pour de prévision des outils de modélisation. On choisit d'utiliser le logiciel pour bien appréhender tout ce qu'on avait vu dans la partie théorique

L'analyse des Séries chronologiques du logiciel *E-Views pour Windows* correspondant à la méthodologie de Box et Jenkins pour la modélisation à partir de processus ARMA.

Pour ces raisons nous utiliserons le logiciel Eviews afin d'obtenir des résultats précises à propos de modéliser les mouvements de la série temporelle à partir des valeurs actuelles et passées d'un bruit blanc avec un modèle linéaire (ARAGON, 2011).

5.1 Le code de calcul utilisé (Eviews)

Avant de pouvoir utiliser l'une des méthodes de lissage exponentiel (simple, double, Holt-Winters) pour l'analyse des données de production d'eau potable de la ville de Biskra dans les années 2009-2012.

Dans cette étude on va essayer d'analyser une série des données mensuelles de l'eau potable de la ville de Biskra, et nous tentons de découvrir ces composantes, sa nature, et l'effet qui influencent à la série d'avoir une meilleure prévision à court terme. En appliquant les méthodes de BOX-Jenkins. La méthodologie de Box et Jenkins est une technique d'extrapolation par référence à une loi de reproduction du phénomène étudié (MELARD 1984).

Il s'agit d'une méthodologie "pas à pas" qui implique la remise en cause de chaque modèle envisagé jusqu'à obtenir un modèle acceptable. Box-Jincks (1970) ont élaboré une méthodologie pour identifier un modèle adéquat pour une série chronologique.

Champ Captant Oued El Hai



Figure 5-16 Forage F1

Forage F1			
Champ captant :	Oued Elhai	Date de mise en service :	30/04/1980
Coordonnées implantation UTM		Date de la visite :	11/05/2015
X	750 240.00		
Y	3 863 572.00		
Z _{TN}	140.20		
ND :	18m		
NS :	12m		
Cote calage :	31m		
Ø Colonne :	17''3/8		
Profondeur :	40m		
Débit mobilisé :	40l/s		
Débit Exploité :	33l/s		
Pompe model :	Tecnova VSpCB834B/04		
Puissance :	26kw		
HMT :	85m		
Ø pompe :	8''		

Figure 5-17 Fiche technique forage F1

Tableau. 5.1. les volumes de production mensuelle d'eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage F1)

	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	2160	1854	1843	1264	1666	1800	1700	1903
Février	2003	1722	1705	1461	2100	2087	1306	
Mars	1631	1080	2173	1542	1987	1036	1577	
Avril	1654	1363	2528	1685	1122	1709	2791	
Mai	1532	1100	1972	1264	1860	1961	1384	
Juin	1909	1400	1990	1461	1061	1337	1189	
Juillet	1302	1545	1941	1522	1534	1530	1302	
Aout	1423	2704	2831	1685	1616	1890	1478	
Septembre	1547	1945	1957	1900	1620	1454	1437	
Octobre	1987	2108	1332	1974	1440	1696	1408	
Novembre	1236	1955	983	1209	1234	1490	1754	
Décembre	1335	2539	2553	2896	1371	1937	1747	

5.2 Etude graphique de la série (FF1)

La première étape de l'étude d'une série chronologique est la représentation graphique des données de production d'eau potable (2009-2016) du forage F1 (Champ Captant Oued el Hai) alimente Biskra Centre. Cette visualisation donne des indications très précieuses pour choisir un modèle.

Tableau.5. 2 : Corrélogramme de la série brute FF1

Date: 08/10/20 Time: 18:12
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.092	0.092	0.7374	0.391
		2	0.073	0.065	1.2102	0.546
		3	0.135	0.124	2.8501	0.415
		4	0.260	0.241	9.0366	0.060
		5	-0.004	-0.056	9.0378	0.108
		6	-0.092	-0.144	9.8325	0.132
		7	-0.042	-0.097	10.002	0.188
		8	0.138	0.117	11.841	0.158
		9	-0.083	-0.045	12.510	0.186
		10	-0.132	-0.078	14.236	0.163
		11	-0.114	-0.113	15.532	0.159
		12	0.097	0.077	16.488	0.170
		13	-0.275	-0.248	24.250	0.029
		14	-0.037	0.098	24.391	0.041
		15	-0.183	-0.162	27.937	0.022
		16	-0.030	-0.027	28.033	0.031
		17	-0.062	0.057	28.446	0.040
		18	0.004	0.078	28.447	0.056
		19	0.069	0.141	28.984	0.066
		20	0.059	-0.025	29.377	0.081
		21	-0.052	-0.072	29.684	0.099
		22	0.056	-0.037	30.058	0.117
		23	0.068	0.050	30.603	0.133
		24	0.022	-0.037	30.660	0.164
		25	0.029	0.129	30.765	0.197
		26	0.180	0.055	34.813	0.116
		27	-0.082	-0.145	35.679	0.122
		28	0.135	0.085	38.028	0.098
		29	-0.066	-0.128	38.599	0.110
		30	-0.005	-0.046	38.603	0.135

FF1




Figure 5-18 L'évolution mensuelle de la Production d'AEP (Forage F1)

Le graphe de la **Figure 5-18**, de la série FF1 laisse apparaître une tendance stochastique sur toute la durée ainsi que des marches aléatoire qui traduisent la saisonnalité. Ce graphique montre une forte volatilité de la demande d'eau mensuelle. Ceci est confirmé par la fonction d'autocorrélation

Tableau.5.2 (corrélogramme) il existe des pics très importants présente les variations temporelles de la demande de l'eau. On observe une forte variation, donc la non-stationnarité est souvent indiquée par un tracé d'autocorrélation avec une décroissance très lente. Le corrélogramme pressente (forage F1) est calculée a l'aide du logiciel **EVIIEWS**. Son examen pressente une décroissance de ses retards (ce qui indique l'existence du facteur tendanciel). Les autocorrélations s'annulent très lentement. Donc la série brute est effectuée de la saisonnalité de la tendance, ce qui veut dire qu'elle est **non stationnaire**. On peut conclure que la série brute FF1 est non stationnaire, puisque les tests d'existence de la saisonnalité et de la tendance sont retenus.

5.3 Dessaisonnaliser la série (FF1) :

Désaisonnaliser la série (FF1) de production d'eau potable à l'aide de coefficient saisonnière (CVS) et par la méthode de moyen mobile (Moving Average)

Désaisonnaliser une chronique c'est éliminer cette saisonnalité sans modifier les autres composantes de la chronique (**ANDERSEN and WEISS, 1984**).

5.4 Les coefficients saisonniers

Nous présentons dans le tableau suivant **les douze coefficients saisonniers pour chaque mois**

Date: 08/10/20 Time: 18:09
 Sample: 2009M01 2016M01
 Included observations: 85
 Ratio to Moving Average
 Original Series: FF1
 Adjusted Series: FF1SA

Scaling Factors:

1	1.019110
2	1.042333
3	0.923827
4	1.114969
5	0.949047
6	0.830566
7	0.910064
8	1.191767
9	1.035330
10	1.048592
11	0.797298
12	1.235059

Tableau.5. 3 : coefficients saisonniers de la série FF1SA

On obtient une nouvelle série désaisonnalisée qui s'appelle (**FF1SA**), les données de cette série dans l'annexe.

- **Le graphe de la série désaisonnalisée FF1SA :**

$$FF1SA = 1791.40973726 + 6.72226572104 * @TREND$$

Tableau. 5 .4. Les données de la série Désaisonnalisée FF1SA pour la période allant de janvier 2009 à janvier 2016 (Forage F1)

	2009(m ³)	2010(m ³)	2011(m ³)	2012(m ³)	2013(m ³)	2014(m ³)	2015(m ³)	2016(m ³)
Janvier	2119.496	1819.234	1808.440	1240.298	1634.759	1766.247	1668.122	1867.315
Février	1921.651	1652.064	1635.754	1401.664	2014.712	2002.240	1252.959	
Mars	1765.482	1169.050	2352.172	1669.143	2150.835	1121.422	1707.029	
Avril	1483.449	1222.455	2267.327	1511.252	1006.306	1532.778	2503.208	
Mai	1614.251	1159.058	2077.874	1331.863	1959.861	2066.284	1458.305	
Juin	2298.432	1685.597	2395.956	1759.041	1277.442	1609.745	1431.554	
Juillet	1430.668	1697.683	2132.817	1672.410	1685.595	1681.200	1430.668	
Aout	1194.025	2268.900	2375.464	1413.867	1355.970	1585.880	1240.175	
Septembre	1494.210	1878.628	1890.219	1835.164	1564.719	1404.383	1387.964	
Octobre	1894.922	2010.315	1270.275	1882.524	1373.270	1617.407	1342.753	
Novembre	1550.236	2452.032	1232.915	1516.372	1547.728	1868.812	2199.931	
Décembre	1080.920	2055.772	2067.108	2344.827	1110.068	1568.346	1414.507	

Tableau .5.5. Corrélogramme de la série FF1SA




Figure 5-19 Le graphe de la série désaisonnalisé FF1SA

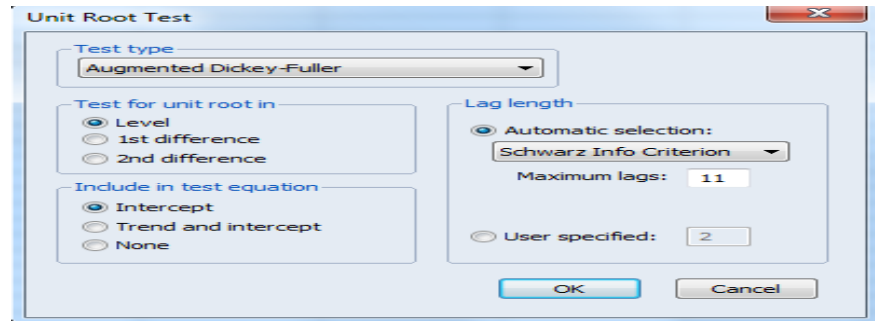
A partir de ce graphe, on remarque que malgré qu'on élimine l'effet de la saisonnalité sur la série FF1, elle reste non stationnaire autour de sa moyenne, ce qui confirme par le corrélogramme. D'après la colonne de la fonction d'autocorrélation simple on remarque qu'il ya des pics importants au niveau de $k=1, k=3$ (variation importante de la demande de l'eau) diminuer l'entement vers le zéro et un pic important de premier corrélogramme d'autocorrélation partial. Donc la série FF1SA n'est pas stationnaire car la fonction d'autocorrélation converge lentement vers le zéro ; donc il existe un effet de la tendance sur cette série on va confirmer par des tests économétriques.

K : le nombre de retard,

5.5 Etude de la stationnarité de la série désaisonnalisée (FF1SA)

Dans le cas d'une série affectée du mouvement saisonnier, il convient de la retirer préalablement à tout traitement statistique. Cette saisonnalité est ajoutée à la série prévue à la fin du traitement afin d'obtenir une prévision en terme brut (SYLVESTRE, 2013). On applique le test de Dickey-fuller (test racine unitaire) pour confirmer le non stationnarité de la série FF1SA

Tableau.5. 6 : Fenêtre de logiciel pour test de racine unitaire



Avant tout ça, nous devons déterminer le nombre de retards p qui minimise les critères d'Akaike et Schwartz pour les trois modèles (avec tendance et constante (trend and intercept), avec constante (intercept), sans tendance ni constante (none)).

5.6 Teste de racine unitaire

À l'aide des trois modèles : ceci nous permettra de savoir c'est un processus TS ou DS afin de choisir la bonne méthode pour stationnariser la série (MICHEL ,2008).

5.7 Stationnarisation de la série FF1SA

- Modèle [3] avec constante et tendance

$$\Delta X_t = c + bt + \rho X_t - 1 + \sum_{j=1}^p \phi_j X_{t-j} + \varepsilon_t$$

Tableau. 5. 7.Test de stationnarité de la série des données de production d’eau potable
(Modèle avec tendance et avec constante)

Null Hypothesis: FF1SA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.546402	0.0000
Test critical values:		
1% level	-4.071006	
5% level	-3.464198	
10% level	-3.158586	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(FF1SA)
Method: Least Squares
Date: 08/10/20 Time: 18:25
Sample (adjusted): 2009M02 2016M01
Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FF1SA(-1)	-0.823657	0.109146	-7.546402	0.0000
C	1447.495	210.8214	6.865978	0.0000
@TREND(2009M01)	-1.472267	1.650124	-0.892216	0.3749

R-squared	0.413268	Mean dependent var	-3.002152
Adjusted R-squared	0.398781	S.D. dependent var	466.7960
S.E. of regression	361.9457	Akaike info criterion	14.65593
Sum squared resid	10611382	Schwarz criterion	14.74274
Log likelihood	-612.5489	Hannan-Quinn criter.	14.69083
F-statistic	28.52644	Durbin-Watson stat	2.029794
Prob(F-statistic)	0.000000		

D’après le tableau de Dickey Fuller

Tendance :

H0 : Tendance =0 P>5% **accepte H0**

H1 : Tendance ≠0 P< 5% **rejeté H1**

Le tableau du modèle (3) au-dessus montre que la valeur de la tendance n’est pas significative du fait qu’elle est égale 37.49% à qui est supérieure de 5% donc on accepte H0 c’est à dire la série des données de production d’eau potable FF1ne contient pas de tendance et la valeur de t-statistic calculé (|-0.892|) inférieur de la t-statistic tabulé (2.79) (voir l’annexe) .La constante est significative ,accepte H1 par conséquent le modèle approprie de teste stationnarité de la série FF1.Alors notre série n’admet pas une racine unitaire (P <5%) On peut dire que notre série est stationnaire et de type DS.

- **Modèle (2) sans tendance et avec constante**

$$\Delta X_t = c + \rho X_t - 1 + \sum_{j=1}^p X_{t-j} + \epsilon_t$$

Tableau .5.8. Test de stationnarité de la série des données de production d'eau potable (Modèle avec constante)

Null Hypothesis: FF1SA has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.509801	0.0000
Test critical values:		
1% level	-3.510259	
5% level	-2.896346	
10% level	-2.585396	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(FF1SA)
 Method: Least Squares
 Date: 08/10/20 Time: 18:26
 Sample (adjusted): 2009M02 2016M01
 Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FF1SA(-1)	-0.808022	0.107596	-7.509801	0.0000
C	1358.578	185.5477	7.321986	0.0000

R-squared	0.407502	Mean dependent var	-3.002152
Adjusted R-squared	0.400276	S.D. dependent var	466.7960
S.E. of regression	361.4953	Akaike info criterion	14.64190
Sum squared resid	10715668	Schwarz criterion	14.69977
Log likelihood	-612.9597	Hannan-Quinn criter.	14.66516
F-statistic	56.39711	Durbin-Watson stat	2.043900
Prob(F-statistic)	0.000000		

H0 : Admet une racine unitaire **rejeté H0**

H1 : N'admet pas une racine **accepte H1**

On a t-statistic > t-tabulée au risque de 5% **-7.5096 < -2.896**

Constante :

H0 : Constante =0 **rejeté H0**

H1 : Constante ≠0 **accepte H1**

Le tableau au-dessus montre que la valeur de constante est significative (t-s calculé 7.32 > t-s tabulé 2.54) (voir l'annexe) et la probabilité du fait qu'elle est égale 0% qui est inférieure de 5% donc on rejette H0 et affecté par une constante. Ce qui veut dire que le modèle (2) est adapté.

Modèle (1) sans tendance et sans constante

5.8 Estimation de la fonction de la tendance :

Tableau.5 .10. Icône de logiciel

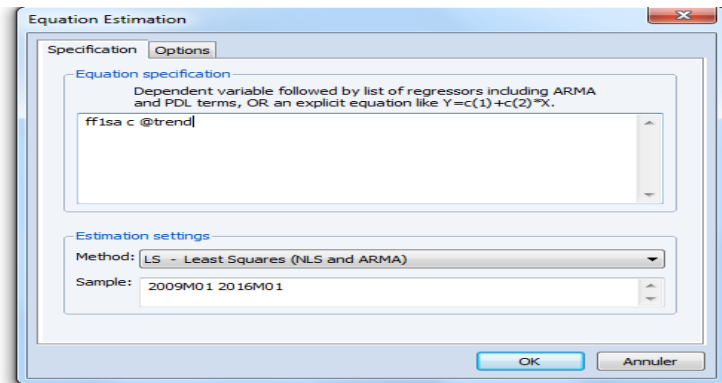


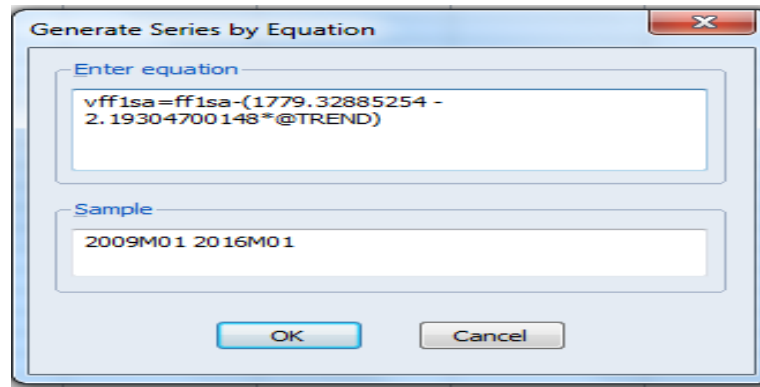
Tableau 5.11.méthode des moindres carrés (estimation d'équation)

Dependent Variable: FF1SA
 Method: Least Squares
 Date: 11/01/20 Time: 14:51
 Sample (adjusted): 2009M01 2016M01
 Included observations: 85 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1779.329	78.54637	22.65323	0.0000
@TREND	-2.193047	1.614800	-1.358092	0.1781
R-squared	0.021739	Mean dependent var		1687.221
Adjusted R-squared	0.009952	S.D. dependent var		367.1119
S.E. of regression	365.2805	Akaike info criterion		14.66246
Sum squared resid	11074676	Schwarz criterion		14.71993
Log likelihood	-621.1544	Hannan-Quinn criter.		14.68557
F-statistic	1.844414	Durbin-Watson stat		1.633062
Prob(F-statistic)	0.178115			

Pour avoir la série stationnaire il suffit juste de retrancher l'espérance de la série FF1SA

$$E(FF1SA) = 1779.32885254 - 2.19304700148 * @TREND$$



. Donc on va créer une nouvelle série **VFF1SA**.

Tableau .5.12 Les données de la série stationnaireVFF1SA pour la période allant de janvier 2009 à janvier 2016 (Forage F1)

	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	340.1672	66.22186	81.74469	-460.0814	-39.30311	118.5007	46.69246	272.2024
Février	144.5157	-98.75542	-88.74843	-296.5222	342.8424	356.6870	-366.2775	
Mars	-9.461058	-579.5764	629.8619	-26.84973	481.1587	-521.9381	89.98584	
Avril	-289.3008	-523.9780	547.2103	-182.5477	-661.1778	-108.3893	888.3575	
Mai	-156.3055	-585.1825	359.9507	-359.7444	294.5707	427.3098	-154.3520	
Juin	530.0685	-56.44989	680.2255	69.62711	-385.6555	-27.03551	-178.9106	
Juillet	-335.5022	-42.17148	419.2792	-14.81130	24.69115	46.61242	-177.6028	
Aout	-569.9524	531.2386	664.1196	-271.1611	-302.7417	-46.51447	-365.9030	
Septembre	-267.5746	143.1605	181.0676	152.3293	-91.79940	-225.8182	-215.9215	
Octobre	135.3303	277.0397	-436.6836	201.8824	-281.0553	-10.60181	-258.9392	
Novembre	-207.1620	720.9506	-471.8507	-162.0767	-104.4042	242.9969	600.4319	
Décembre	-674.2853	326.8834	364.5355	668.5715	-539.8707	-55.27644	-182.7987	

Tableau.5 .13.Corrélogramme de la série VFF1SA

Date: 08/10/20 Time: 18:52
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.175	0.175	2.6930	0.101
		2	0.119	0.091	3.9465	0.139
		3	0.233	0.206	8.8398	0.031
		4	0.128	0.057	10.328	0.035
		5	0.070	0.008	10.778	0.056
		6	-0.066	-0.148	11.184	0.083
		7	-0.018	-0.039	11.214	0.130
		8	-0.033	-0.039	11.321	0.184
		9	0.002	0.063	11.322	0.254
		10	-0.132	-0.113	13.052	0.221
		11	-0.162	-0.116	15.674	0.154
		12	-0.168	-0.154	18.535	0.100
		13	-0.276	-0.209	26.370	0.015
		14	-0.110	0.028	27.627	0.016
		15	-0.235	-0.114	33.480	0.004
		16	-0.212	-0.072	38.276	0.001
		17	0.004	0.098	38.278	0.002
		18	0.030	0.105	38.376	0.003
		19	0.025	0.064	38.446	0.005
		20	-0.027	-0.050	38.529	0.008
		21	0.057	-0.025	38.906	0.010
		22	0.089	0.011	39.843	0.011
		23	0.111	0.058	41.314	0.011
		24	-0.137	-0.249	43.572	0.009
		25	0.088	0.038	44.531	0.009
		26	0.184	0.030	48.779	0.004
		27	-0.051	-0.121	49.106	0.006
		28	0.044	-0.037	49.358	0.008
		29	-0.048	-0.133	49.669	0.010
		30	0.068	0.100	50.298	0.012




Figure 5-20 Série stationnaire VFF1SA

A partir de ce graphe on peut dire que la série est stationnaire, on obtient VFF1SA est une série stationnaire autour de sa moyenne et d'après le corrélogramme la fonction d'autocorrélation converge rapidement vers le zéro et n'a pas des effets saisonniers.

La série est stationnaire mais on doit confirmer par test de Dikey- Fuller.

Modèle 3 (p=2)**Tableau. 5.14.** Test de stationnarité de la série des données de production d'eau potable (Modèle sans tendance et sans constante)

Null Hypothesis: VFF1SA has a unit root
Exogenous: None
Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.640358	0.0000
Test critical values:		
1% level	-2.592782	
5% level	-1.944713	
10% level	-1.614233	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(VFF1SA)
Method: Least Squares
Date: 08/10/20 Time: 19:01
Sample (adjusted): 2009M02 2016M01
Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VFF1SA(-1)	-0.823922	0.107838	-7.640358	0.0000
R-squared	0.412907	Mean dependent var		-0.809105
Adjusted R-squared	0.412907	S.D. dependent var		466.7960
S.E. of regression	357.6683	Akaike info criterion		14.60892
Sum squared resid	10617908	Schwarz criterion		14.63786
Log likelihood	-612.5747	Hannan-Quinn criter.		14.62056
Durbin-Watson stat	2.027987			

La confirmation par le test de Dickey-FULLER, La série n'admet pas de racine unitaire ($P < 0.05$) et la série n'admet pas de tendance. On peut conclure que la série VFF1SA est stationnaire. Comme cette série est stationnaire alors on effectue les 4 étapes de la méthodologie de Box - Jenkins :

5.9 MODELISATION ARMA PAR LA METHODE DE BOX-JENKINS**La méthodologie de Box - Jenkins :****5.9.1 L'identification de modèle**

Elle est la plus importante et la plus difficile : elle consiste à déterminer le modèle adéquat dans la famille des modèles ARMA. Elle est fondée sur l'étude des corrélogrammes simple et partiel. Cette première étape consiste à trouver les valeurs p et q des processus ARMA en se basant sur l'étude des fonctions d'autocorrélation simple et d'autocorrélation partielle (BEN ABBAS, 2012). On va identifier à présent un modèle valide pour faire notre prévision.

Corrélogramme de la série stationnaire

Pour identifier le modèle de la série VFF1SA il faut d'abord construire son corrélogramme

A partir du corrélogramme de la variable stationnaire on détermine les retards du modèle ARMA.

Tableau. 5.15. Corrélogramme de la série VFF1SA

Date: 08/10/20 Time: 18:52
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.175	0.175	2.6930	0.101
		2	0.119	0.091	3.9465	0.139
		3	0.233	0.206	8.8398	0.031
		4	0.128	0.057	10.328	0.035
		5	0.070	0.008	10.778	0.056
		6	-0.066	-0.148	11.184	0.083
		7	-0.018	-0.039	11.214	0.130
		8	-0.033	-0.039	11.321	0.184
		9	0.002	0.063	11.322	0.254
		10	-0.132	-0.113	13.052	0.221
		11	-0.162	-0.116	15.674	0.154
		12	-0.168	-0.154	18.535	0.100
		13	-0.276	-0.209	26.370	0.015
		14	-0.110	0.028	27.627	0.016
		15	-0.235	-0.114	33.480	0.004
		16	-0.212	-0.072	38.276	0.001
		17	0.004	0.098	38.278	0.002
		18	0.030	0.105	38.376	0.003
		19	0.025	0.064	38.446	0.005
		20	-0.027	-0.050	38.529	0.008
		21	0.057	-0.025	38.906	0.010
		22	0.089	0.011	39.843	0.011
		23	0.111	0.058	41.314	0.011
		24	-0.137	-0.249	43.572	0.009
		25	0.088	0.038	44.531	0.009
		26	0.184	0.030	48.779	0.004
		27	-0.051	-0.121	49.106	0.006
		28	0.044	-0.037	49.358	0.008
		29	-0.048	-0.133	49.669	0.010
		30	0.068	0.100	50.298	0.012

On remarque du corrélogramme de la fonction d'autocorrélation simple (ACF) un pic important pour le terme MA (3) est significativement différente de zéro et le corrélogramme de la fonction partielle(PACF) est un pic important pour le terme AR(3) et d'après la combinaison des deux fonctions il ya trois modèles : **AR (3), MA(3), ARMA(3,3)**.

5.9.2 Estimation des paramètres du modèle

Pour choisir le modèle à retenir pour la prévision, nous allons recourir aux critères d'information et au coefficient de détermination. Ces critères permettent d'évaluer la qualité d'un modèle. Le but est alors de minimiser la colonne AIC, et SIC ou de maximiser les colonnes R^2 .

Tableau.5.16. les critères d'Akaike et Schwartz

MODELE	AIC	SIC	R ²
MA(3))	14.55424	14.58298	0.081196
AR (3)	14.60423	14.63358	0.057125
AR(3)MA(3)	14.55248	14.61118	0.126246

Tableau. 5.17. Modèle AR(3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.243216	0.109549	2.220153	0.0292
R-squared	0.057125	Mean dependent var	-5.795388	
Adjusted R-squared	0.057125	S.D. dependent var	367.4274	
S.E. of regression	356.7785	Akaike info criterion	14.60423	
Sum squared resid	10310561	Schwarz criterion	14.63358	
Log likelihood	-597.7733	Hannan-Quinn criter.	14.61601	
Durbin-Watson stat	1.705035			
Inverted AR Roots	.62	-.31+.54i	-.31-.54i	

Tableau. 5. 18. Modèle MA (3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.363194	0.105521	3.441916	0.0009
R-squared	0.081196	Mean dependent var	2.19E-10	
Adjusted R-squared	0.081196	S.D. dependent var	363.0997	
S.E. of regression	348.0466	Akaike info criterion	14.55424	
Sum squared resid	10175458	Schwarz criterion	14.58298	
Log likelihood	-617.5554	Hannan-Quinn criter.	14.56580	
Durbin-Watson stat	1.727246			
Inverted MA Roots	.36-.62i	.36+.62i	-.71	

Tableau. 5.19. Modèle AR(3) MA(3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	-0.609017	0.105234	-5.787242	0.0000
MA(3)	0.920634	0.039684	23.19923	0.0000
R-squared	0.126246	Mean dependent var	-5.795388	
Adjusted R-squared	0.115325	S.D. dependent var	367.4274	
S.E. of regression	345.5919	Akaike info criterion	14.55248	
Sum squared resid	9554699.	Schwarz criterion	14.61118	
Log likelihood	-594.6518	Hannan-Quinn criter.	14.57605	
Durbin-Watson stat	1.721095			
Inverted AR Roots	.42+.73i	.42-.73i	-.85	
Inverted MA Roots	.49-.84i	.49+.84i	-.97	

D'après ces tableaux des critères des information au- dessus, nous constatons que les coefficients de AR (3 ;3) significatives car la probabilité est inférieure de 0.05. Donc Le modèle (3,3) semble meilleur que les autres modèles, par ce que minimise les critères d'information AIC et SIC (BIC). Les autres modèles ne peuvent pas être utilisés pour la prévision.

Champ captant Oued El Hai

Forage F4 (SIF4)




Forage SIF4			
Champ captant :	Oued Elhai	Date de mise en service :	20/08/1988
Coordonnées implantation UTM		Date de la visite :	
X	750 620.3814		
Y	3 863 864.7283		
Z _{TN}	143.5034		
ND :	18.00m		
NS :	17.80m		
Cote calage :	35.00m		
Ø Colonne :	12''		
Profondeur :	50.00m		
Débit mobilisé :	33l/s		
Débit Exploité :	31l/s		
Pompe model :	GEPI/LUBI HP35		
Puissance :	30kw		
HMT :	85m		
Ø pompe :	8''		

Figure 5-21 Fiche technique forage F4

Tableau. 5.20. les données de production mensuelle d'eau potable (observée) pour la période allant de janvier 2009 à janvier 2016 (Forage FF4)

	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	3200	3995	3566	2949	2125	2802	1548	1855
Fevrier	5423	4601	3279	2331	2652	2833	2196	
Mars	4833	3690	3393	2996	2422	2109	1696	
Avril	4488	3189	3412	2455	1550	2209	2490	
Mai	4422	3000	2830	2524	2300	2094	1788	
Juin	3355	3513	2826	2515	1554	2211	2443	
Juillet	4355	3090	2086	2146	2494	2413	2470	
Aout	4954	3477	2916	2094	2760	2021	1177	
Septembre	3842	2899	2367	2538	2188	2162	1364	
Octobre	3862	3032	2943	2997	2631	2470	1966	
Novembre	3788	2928	2366	2424	2600	1547	2160	
Décembre	3249	2083	2532	2831	2189	1798	2501	

➤ 5.2. Etude graphique de la série FF4



On constate qu'il y a une diminution de l'évolution de la fluctuation de la demande d'eau

L'analyse visuelle du graphe de la série F4 montre à première vue la présence d'une tendance décroissante et toutes les probabilités <5% et il y a des valeurs qui sortent de l'intervalle de confiance. D'où il y a lieu d'affirmer une présomption du non stationnarité de notre série FF4

➤ **5.3. Dessaisonnaliser la série (FF4) :** On obtient une nouvelle série (FF4SA)

- **5.3.1. Les coefficients saisonniers** **Tableau.5. 22.** Coefficients saisonniers de la série FF4SA (Voir L'annexe)

Tableau.5.23. Les données de la série Désaisonnalisée FF4SA pour la période allant de janvier 2009 à janvier 2016 (Forage F4)

Mois	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	3108.497	3880.764	3464.031	2864.674	2064.236	2721.878	1503.735	1801.957
Fevrier	4897.633	4155.267	2961.339	2105.179	2395.081	2558.546	1983.257	
Mars	4720.571	3604.160	3314.069	2926.305	2365.658	2059.939	1656.546	
Avril	4524.381	3214.851	3439.658	2474.901	1562.565	2226.907	2510.185	
Mai	4678.421	3173.962	2994.104	2670.360	2433.371	2215.426	1891.682	
Juin	3407.029	3567.479	2869.825	2554.002	1578.099	2245.288	2480.886	
Juillet	4380.084	3107.798	2098.015	2158.361	2508.365	2426.898	2484.227	
Aout	4745.063	3330.356	2793.017	2005.685	2643.596	1935.764	1127.360	
Septembre	4038.658	3047.389	2488.158	2667.911	2299.996	2272.665	1433.818	
Octobre	3532.567	2773.367	2691.959	2741.352	2406.573	2259.306	1798.298	
Novembre	4021.299	3108.333	2511.720	2573.292	2760.132	1642.278	2293.032	
Décembre	3560.083	2282.442	2774.432	3102.061	2398.591	1970.154	2740.464	

Tableau .5.24. Corrélogramme de la série FF4SA





Figure 5- 23 Le graphe de la série désaisonnalisé FF4SA.

➤ **5.4. Étude de la stationnarité de la série désaisonnalisée (FF4SA)**

En vue d'étudier la stationnarité de la série FF4SA, on applique le teste de DF pour confirmer la non stationnarité de la série FF4SA.

➤ 5.5. Testes de racine unitaire

Tableau. 5.25 Test de stationnarité de la série des données de production d'eau potable
Modèle (3) avec tendance et constante

Null Hypothesis: FF4SA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.926071	0.0000
Test critical values:		
1% level	-4.071006	
5% level	-3.464198	
10% level	-3.158586	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(FF4SA)
Method: Least Squares
Date: 08/10/20 Time: 20:33
Sample (adjusted): 2009M02 2016M01
Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FF4SA(-1)	-0.727345	0.105016	-6.926071	0.0000
C	2855.299	423.1905	6.747078	0.0000
@TREND(2009M01)	-20.29046	3.503381	-5.791679	0.0000

R-squared	0.372254	Mean dependent var	-15.55405
Adjusted R-squared	0.356754	S.D. dependent var	562.0941
S.E. of regression	450.8142	Akaike info criterion	15.09505
Sum squared resid	16461907	Schwarz criterion	15.18186
Log likelihood	-630.9920	Hannan-Quinn criter.	15.12995
F-statistic	24.01654	Durbin-Watson stat	1.903636
Prob(F-statistic)	0.000000		

D'après le tableau au-dessus, il est possible de constater que la tendance significative puisque la probabilité de tendance égale 0% qui est inférieur au seuil tolérable de 5% on a accepté H0 ,et t-statistic calculé (|-5.791|) supérieur de t-statistic tabulée (2.79) (voir l'annexe).il s'agit d'un modèle de type TS (trend stationary) non stationnaire . Alors pour rendre cette série est stationnaire. D'où la nécessité de passer à l'étape suivante qui consiste à estimée la fonction de la tendance

➤ 5.6. Stationnarisation de la série FF4

• 5.6.1 Estimation de la fonction de la tendance

Tableau. 5.26. Estimation de la fonction de la tendance de la série des données de production d'eau potable

Dependent Variable: FF4SA
Method: Least Squares
Date: 04/11/17 Time: 11:19
Sample (adjusted): 2009M01 2016M01
Included observations: 85 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3885.711	101.4234	38.31179	0.0000
@TREND	-27.03747	2.085118	-12.96688	0.0000

R-squared	0.669507	Mean dependent var	2750.137
Adjusted R-squared	0.665525	S.D. dependent var	815.5613
S.E. of regression	471.6701	Akaike info criterion	15.17368
Sum squared resid	18465234	Schwarz criterion	15.23116
Log likelihood	-642.8816	Hannan-Quinn criter.	15.19680
F-statistic	168.1399	Durbin-Watson stat	1.420773
Prob(F-statistic)	0.000000		

$$VFF4SA = FF4SA - E(FF4SA)$$

$$VFF4S = FF4SA - (3885.71053354 - 27.0374715502 * @trend)$$

Tableau. 5.27. Les données de la série stationnaire VF4SA pour la période allant de janvier 2009 à janvier 2016 (Forage F4)

Mois	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	-777.213	319.5035	227.2203	-47.68718	-523.6755	458.4155	-435.2771	187.3940
Février	1038.960	621.0434	-248.4350	-780.1455	-165.7935	322.1214	71.28197	
Mars	888.9355	96.97453	131.3332	68.01819	-168.1793	-149.4484	-228.3913	
Avril	719.7827	-265.2977	283.9597	-356.3483	-944.2348	44.55686	652.2844	
Mai	900.8599	-279.1486	-134.5568	-133.8513	-46.39088	60.11337	60.81887	
Juin	- 343.4943	141.4056	-231.7986	-223.1719	-874.6253	117.0130	677.0605	
Juillet	656.5983	-291.2382	-976.5714	-591.7761	82.67794	325.6610	707.4396	
Aout	1048.615	-41.64236	-254.5323	-717.4145	244.9464	-138.4364	-622.3907	
Septembre	369.2471	-297.5720	-532.3534	-28.15091	-71.61647	225.5023	-288.8947	
Octobre	- 109.8063	-544.5567	-301.5152	72.32815	61.99803	239.1812	102.6226	
Novembre	405.9635	-182.5535	-454.7168	-68.69501	442.5943	-350.8093	624.3945	
Décembre	- 28.21526	-981.4070	-164.9668	487.1113	108.0912	4.103650	1098.854	




Figure 5-24 .La série stationnaire VFF4SA

Tableau.5.28. Corrélogramme VFF4SA

Date: 08/10/20 Time: 22:29
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.272	0.272	6.5279	0.011
		2	0.259	0.199	12.493	0.002
		3	0.173	0.070	15.192	0.002
		4	0.012	-0.102	15.205	0.004
		5	0.281	0.283	22.494	0.000
		6	0.170	0.074	25.203	0.000
		7	0.148	-0.002	27.278	0.000
		8	0.080	-0.070	27.893	0.000
		9	0.201	0.246	31.831	0.000
		10	0.051	-0.121	32.088	0.000
		11	0.129	0.029	33.756	0.000
		12	0.060	-0.055	34.118	0.001
		13	-0.062	-0.042	34.519	0.001
		14	0.116	0.024	35.914	0.001
		15	-0.081	-0.112	36.616	0.001
		16	0.018	-0.010	36.650	0.002
		17	-0.035	-0.042	36.779	0.004
		18	0.007	0.084	36.784	0.006
		19	0.025	-0.029	36.856	0.008
		20	0.018	0.042	36.893	0.012
		21	0.052	0.042	37.210	0.016
		22	-0.061	-0.018	37.642	0.020
		23	0.076	0.043	38.337	0.023
		24	-0.191	-0.218	42.761	0.011
		25	-0.059	0.007	43.194	0.013
		26	-0.146	-0.133	45.871	0.009
		27	-0.200	-0.086	50.986	0.003
		28	-0.011	-0.016	51.003	0.005
		29	-0.199	-0.073	56.245	0.002
		30	-0.088	-0.041	57.285	0.002

A partir de ce graphe on remarque que la série VFF4SA est une série stationnaire. Autour de sa moyenne et d'après le corrélogramme la fonction d'autocorrélation converge rapidement vers le zéro




Tableau. 5.29 Test de stationnarité de la série des données de production d’eau potable
Modèle ni tendance ni constante

Null Hypothesis: VFF4SA has a unit root
Exogenous: None
Lag Length: 1 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.194642	0.0001
Test critical values:		
1% level	-2.593121	
5% level	-1.944762	
10% level	-1.614204	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(VFF4SA)
Method: Least Squares
Date: 08/13/20 Time: 00:19
Sample (adjusted): 2009M03 2016M01
Included observations: 83 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VFF4SA(-1)	-0.526029	0.125405	-4.194642	0.0001
D(VFF4SA(-1))	-0.200969	0.105049	-1.913104	0.0593

R-squared	0.379422	Mean dependent var	-10.25984
Adjusted R-squared	0.371761	S.D. dependent var	528.7778
S.E. of regression	419.1174	Akaike info criterion	14.93798
Sum squared resid	14228409	Schwarz criterion	14.99627
Log likelihood	-617.9262	Hannan-Quinn criter.	14.96140
Durbin-Watson stat	2.120008		

D’après le tableau du racine unitaire ,le test de stationnarité de la série des données de production d’eau potable , cette série est stationnaire ($0.0593 > 0.05$) alors on effectue les 4 étapes de la méthodologie de Box - Jenkins :

- **5.7.1. Identification de modèle**

1. Analyse des fonctions d’autocorrélation simple et d’autocorrélation partielle

4.1. Détermination des ordres p et q du processus ARMA Pour identifier le modèle de la série F4SA, il faut d'abord construire son corrélogramme

Tableau.5.30. Corrélogramme de la série VFF4SA

Date: 08/10/20 Time: 22:29
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.272	0.272	6.5279	0.011
		2	0.259	0.199	12.493	0.002
		3	0.173	0.070	15.192	0.002
		4	0.012	-0.102	15.205	0.004
		5	0.281	0.283	22.494	0.000
		6	0.170	0.074	25.203	0.000
		7	0.148	-0.002	27.278	0.000
		8	0.080	-0.070	27.893	0.000
		9	0.201	0.246	31.831	0.000
		10	0.051	-0.121	32.088	0.000
		11	0.129	0.029	33.756	0.000
		12	0.060	-0.055	34.118	0.001
		13	-0.062	-0.042	34.519	0.001
		14	0.116	0.024	35.914	0.001
		15	-0.081	-0.112	36.616	0.001
		16	0.018	-0.010	36.650	0.002
		17	-0.035	-0.042	36.779	0.004
		18	0.007	0.084	36.784	0.006
		19	0.025	-0.029	36.856	0.008
		20	0.018	0.042	36.893	0.012
		21	0.052	0.042	37.210	0.016
		22	-0.061	-0.018	37.642	0.020
		23	0.076	0.043	38.337	0.023
		24	-0.191	-0.218	42.761	0.011
		25	-0.059	0.007	43.194	0.013
		26	-0.146	-0.133	45.871	0.009
		27	-0.200	-0.086	50.986	0.003
		28	-0.011	-0.016	51.003	0.005
		29	-0.199	-0.073	56.245	0.002
		30	-0.088	-0.041	57.285	0.002

On remarque du corrélogramme de la fonction d'autocorrélation (ACF) deux pics importants pour le terme MA (1, 2) sont significativement différentes de zéro et le corrélogramme de la fonction partielle (PACF) est un pic important pour le terme AR(1) et d'après la combinaison des deux fonctions il ya quatre modèles **AR (1), MA(1), ARMA(1,1).ARMA (1,2),**

- **5.7. 2.Estimation des paramètres du modèle**

Le but est alors de minimiser la colonne AIC, et SIC ou de maximiser les colonnes R².

Tableau.5.31. les critères d'Akaike et Schwartz

MODELE	AIC	SIC	R ²
AR(1))	15.04910	15.07803	0.076432
MA(1)	15.09055	15.11929	0.057865
MA(2)	15.03238	15.06112	0.111103
AR(1)MA(1)	-	-	-
AR(1)MA(1)	-	-	-

Tableau.5.32. Modèle AR(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.272825	0.103824	2.627755	0.0102
R-squared	0.076432	Mean dependent var	9.252541	
Adjusted R-squared	0.076432	S.D. dependent var	463.7976	
S.E. of regression	445.7207	Akaike info criterion	15.04910	
Sum squared resid	16489359	Schwarz criterion	15.07803	
Log likelihood	-631.0620	Hannan-Quinn criter.	15.06073	
Durbin-Watson stat	1.900957			
Inverted AR Roots	.27			

Tableau.5.33. Modèle MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.223393	0.105826	2.110939	0.0378
R-squared	0.057865	Mean dependent var	-2.11E-09	
Adjusted R-squared	0.057865	S.D. dependent var	468.8541	
S.E. of regression	455.0869	Akaike info criterion	15.09055	
Sum squared resid	17396742	Schwarz criterion	15.11929	
Log likelihood	-640.3483	Hannan-Quinn criter.	15.10211	
Durbin-Watson stat	1.936636			
Inverted MA Roots	-.22			

Tableau.5.34. Modèle MA(2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.435798	0.097659	4.462465	0.0000
R-squared	0.111103	Mean dependent var	-2.11E-09	
Adjusted R-squared	0.111103	S.D. dependent var	468.8541	
S.E. of regression	442.0418	Akaike info criterion	15.03238	
Sum squared resid	16413683	Schwarz criterion	15.06112	
Log likelihood	-637.8762	Hannan-Quinn criter.	15.04394	
Durbin-Watson stat	1.593499			

Tableau.5.35. Modèle ARMA(1,1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.003978	0.299798	-0.013269	0.9894
MA(1)	0.252436	0.297732	0.847863	0.3990

R-squared	0.078650	Mean dependent var	9.252541
Adjusted R-squared	0.067414	S.D. dependent var	463.7976
S.E. of regression	447.8917	Akaike info criterion	15.07050
Sum squared resid	16449769	Schwarz criterion	15.12838
Log likelihood	-630.9611	Hannan-Quinn criter.	15.09377
Durbin-Watson stat	1.870020		

Inverted AR Roots	-0.00
Inverted MA Roots	-.25

Tableau.5.36. Modèle ARMA(1,2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.182551	0.107793	1.693533	0.0941
MA(2)	0.408341	0.104505	3.907402	0.0002

R-squared	0.163583	Mean dependent var	9.252541
Adjusted R-squared	0.153383	S.D. dependent var	463.7976
S.E. of regression	426.7485	Akaike info criterion	14.97379
Sum squared resid	14933370	Schwarz criterion	15.03166
Log likelihood	-626.8991	Hannan-Quinn criter.	14.99705
Durbin-Watson stat	1.826366		

Inverted AR Roots	.18
-------------------	-----

Champ Captant interne (Biskra Centre)

Forage Ras-El Gueria N°02



Figure 5-25 Forage Ras Elguerria 02

Forage RAS ELGUERIAH N°2			
Champ captant :	Interne	Date de mise en service :	17/10/1988
Coordonnées implantation UTM		Date de la visite :	
X	749 445.5307		
Y	3 859 825.6120		
Z _{TN}	115.1653m		
ND :	m		
NS :	64.00m		
Cote calage :	75.00m		
Ø Colonne :	12"		
Profondeur :	130.00m		
Débit mobilisé :	27l/s		
Débit Exploité :	22l/s		
Pompe model :	TURBINE181A6HP35		
Puissance :	26.00kw		
HMT :	100m		
Ø pompe :	8"		

Figure 5-26 Fiche technique forage Ras Elguerria N°02

Tableau.5.37. les volumes de production mensuelle d'eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage Ras Elgueria N°02)

Mois	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	16459	10627	10982	19211	15063	14780	18831	11155
Fevrier	12418	12568	10979	19744	14971	14568	10001	
Mars	12592	19858	11193	19988	15844	19665	19211	
Avril	13199	12018	10655	10109	13545	13547	19456	
Mai	18456	18200	18597	21234	15180	15214	19688	
Juin	16305	10125	11486	17698	15479	18975	19744	
Juillet	19083	18794	18975	19132	16651	16542	19797	
Aout	12820	10866	12956	24191	18059	10254	19855	
Septembre	13996	19701	19875	12230	19052	15546	19988	
Octobre	13929	18478	17512	12991	18569	19254	20446	
Novembre	17513	12828	19066	14950	12336	18597	10843	
Décembre	10590	11463	18705	14599	12813	18705	10109	

Pour illustre cette première phase de modélisation, nous examinons le graphique et les données de production d'eau potable de forage Ras Elgueria N°02.

➤ **5.2. Etude graphique de la série (Raselgaria) :**

Tableau.5. 38. Corrélogramme de la série brute FRASELG

Date: 08/11/20 Time: 16:44
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.153	0.153	2.0644	0.151
		2	0.219	0.201	6.3535	0.042
		3	-0.045	-0.110	6.5375	0.088
		4	0.060	0.039	6.8643	0.143
		5	0.009	0.031	6.8720	0.230
		6	0.112	0.087	8.0411	0.235
		7	-0.064	-0.101	8.4331	0.296
		8	-0.005	-0.025	8.4354	0.392
		9	-0.093	-0.042	9.2688	0.413
		10	0.126	0.148	10.846	0.370
		11	-0.220	-0.262	15.663	0.154
		12	0.039	0.052	15.820	0.200
		13	-0.142	-0.027	17.882	0.162
		14	0.112	0.115	19.197	0.158
		15	0.032	0.039	19.304	0.200
		16	0.034	-0.076	19.431	0.247
		17	-0.131	-0.083	21.311	0.213
		18	-0.110	-0.101	22.642	0.205
		19	-0.049	0.063	22.909	0.241
		20	0.052	-0.002	23.219	0.278
		21	-0.097	-0.065	24.301	0.279
		22	0.202	0.210	29.078	0.143
		23	-0.028	0.026	29.174	0.175
		24	0.053	-0.117	29.521	0.201
		25	-0.066	-0.040	30.055	0.222
		26	-0.060	-0.061	30.501	0.247
		27	-0.057	0.044	30.921	0.274
		28	0.026	-0.009	31.011	0.317
		29	-0.028	-0.099	31.112	0.360
		30	-0.153	-0.186	34.263	0.270

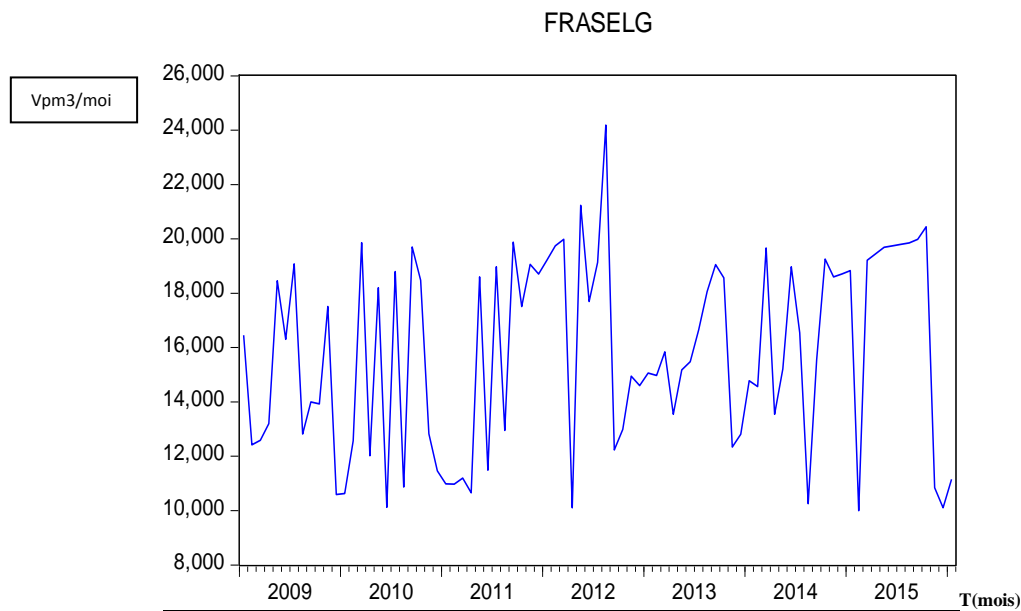


Figure 5-26 L'évolution mensuelle de la Production d'AEP (Forage RASELgaria)

Visuellement, ce graphique montre une forte volatilité de la demande d'eau mensuelle. Ceci est confirmé par la fonction d'autocorrélation (**Tableau.5.38.**), nous pouvons constater qu'après un pic fort, la série chute pour

finalement remonter petit à petit. On observe une forte variation, donc la non-stationnarité est souvent indiquée par un tracé d'autocorrélation avec une décroissance très lente. Nous avons conclu que le processus n'est pas un bruit blanc, donc la non stationnarité de la série. Il est nécessaire de tester le non stationnarité de la série (FRASELQUERIA).

5.3. Dessaisonnaliser la série (FRASELG):

5.3.1. Les coefficients saisonniers

Tableau.5. 39. Coefficients saisonniers de la série FRASELGSA

Date: 08/11/20 Time: 16:47
 Sample: 2009M01 2016M01
 Included observations: 85
 Ratio to Moving Average
 Original Series: FRASELG
 Adjusted Series: FRASELGSA

Scaling Factors:

1	0.936363
2	0.874576
3	1.111379
4	0.826737
5	1.132467
6	0.969175
7	1.177553
8	0.953378
9	1.082136
10	1.080335
11	1.011223
12	0.912363

On obtient une nouvelle série désaisonnalisée qui s'appelle (FRASELQUERIA), les données de cette série dans l'annexe.

Tableau .5.40. Les données de la série Désaisonnalisée FRASELGSA pour la période allant de janvier 2009 à janvier 2016

	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	17577.58	11349.23	11728.36	20516.61	16086.71	15784.47	20110.79	11913.11
Fevrier	14198.87	14370.38	12553.50	22575.50	17118.00	16657.21	11435.25	
Mars	11330.07	17867.89	10071.27	17984.86	14256.16	17694.23	17285.73	
Avril	15965.18	14536.67	12888.02	12227.59	16383.69	16386.11	23533.49	
Mai	16297.16	16071.10	16421.67	18750.21	13404.36	13434.38	17385.05	
Juin	16823.59	10447.03	11851.32	18260.90	15971.32	19578.52	20371.97	
Juillet	16205.63	15960.21	16113.92	16247.25	14140.33	14047.77	16811.98	
Aout	13446.92	11397.36	13589.57	25373.98	18942.11	10755.44	20825.94	
Septembre	12933.68	18205.66	18366.45	11301.72	17605.92	14366.03	18470.87	
Octobre	12893.22	17103.96	16209.79	12024.98	17188.19	17822.25	18925.61	
Novembre	17318.63	12685.63	18854.40	14784.08	12199.09	18390.60	10722.66	
Décembre	11607.22	12564.08	20501.71	16001.31	14043.75	20501.71	11080.02	

➤ Etude graphique de la série (FRASELGSA)

Tableau .5.41. Corrélogramme de la série FRASELGSA

Date: 02/04/18 Time: 09:43
 Sample: 2009M01 2020M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.258	0.258	5.8582	0.016
		2	0.142	0.081	7.6554	0.022
		3	0.055	0.001	7.9293	0.047
		4	0.055	0.033	8.2080	0.084
		5	0.127	0.111	9.7105	0.084
		6	0.220	0.172	14.233	0.027
		7	0.009	-0.114	14.240	0.047
		8	-0.052	-0.084	14.504	0.070
		9	-0.036	-0.004	14.634	0.101
		10	0.014	0.030	14.653	0.145
		11	-0.205	-0.279	18.833	0.064
		12	-0.157	-0.112	21.332	0.046
		13	-0.095	0.063	22.265	0.051
		14	0.054	0.172	22.564	0.068
		15	0.099	0.072	23.591	0.072
		16	0.027	-0.026	23.668	0.097
		17	-0.084	0.020	24.444	0.108
		18	-0.061	0.024	24.849	0.129
		19	-0.006	-0.049	24.853	0.165
		20	0.050	-0.074	25.134	0.196
		21	-0.056	-0.116	25.490	0.227
		22	0.101	0.169	26.689	0.223
		23	-0.007	-0.043	26.695	0.269
		24	-0.121	-0.246	28.462	0.241
		25	-0.058	0.018	28.874	0.269
		26	-0.145	0.036	31.495	0.210
		27	-0.026	0.137	31.583	0.248
		28	0.065	-0.035	32.133	0.269
		29	0.017	-0.050	32.169	0.313
		30	-0.141	-0.085	34.845	0.248
		31	-0.101	0.030	36.236	0.237
		32	0.003	0.028	36.237	0.277

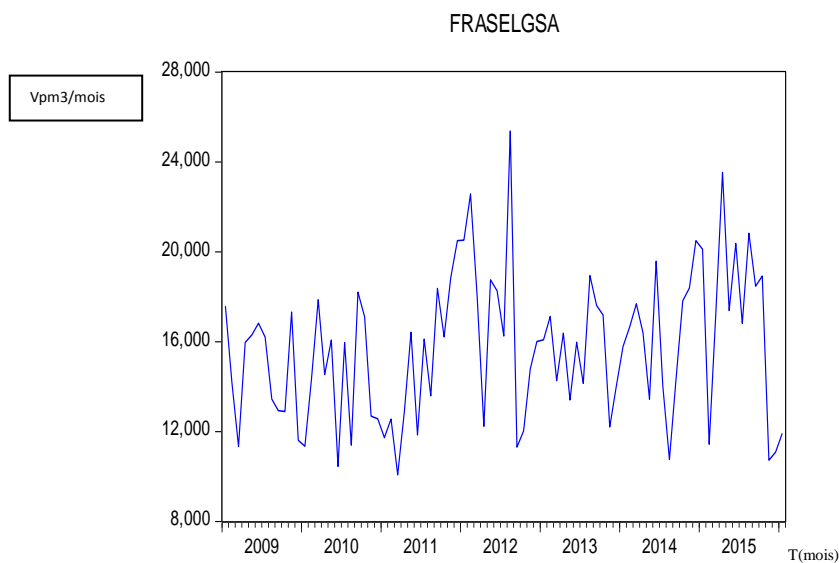


Figure 5-27 Le graphe de la série désaisonnalisé FRASELGSA

A partir de ce graphe on remarque que la série FRASELGSA non stationnaire autour de sa moyenne, une forte variation. Tableau.5.41. Il existe un pic. D’après la colonne de la fonction d’autocorrélation

simple et partielle on remarque qu' il ya un pic au niveau de $k=1$, car la fonction d'autocorrélation converge lentement vers le zéro ;donc il existe un effet de la tendance sur cette série .

➤ **5.4. Etude de la stationnarité de la série désaisonnalisée (FRASELGSA)**

On applique le teste de Dickey-Fuller (test racine unitaire) pour confirmer la non stationnarité de la série FRASELGSA.Pour étudier la stationnarité des séries, nous allons réaliser le test de Dickey-Fuller Augmenté (ADF).Ce test en se basant sur l'hypothèse de corrélation des résidus et sur l'estimation par la méthode des moindres carrés ordinaire (MCO) des 3 modèles suivants :

5.5. Testes de racine unitaire

Tableau. 5. 42. Test de stationnarité de la série des données de production d'eau potable

(Modèle [3] avec tendance et avec constante)

Null Hypothesis: FRASELGSA has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.175273	0.0000
Test critical values:		
1% level	-4.071006	
5% level	-3.464198	
10% level	-3.158586	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(FRASELGSA)
 Method: Least Squares
 Date: 08/11/20 Time: 16:52
 Sample (adjusted): 2009M02 2016M01
 Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FRASELGSA(-1)	-0.787326	0.109728	-7.175273	0.0000
C	11259.16	1713.721	6.570010	0.0000
@TREND(2009M01)	25.50244	14.60260	1.746431	0.0845

R-squared	0.388673	Mean dependent var	-67.43415
Adjusted R-squared	0.373578	S.D. dependent var	3959.791
S.E. of regression	3134.048	Akaike info criterion	18.97310
Sum squared resid	7.96E+08	Schwarz criterion	19.05991
Log likelihood	-793.8702	Hannan-Quinn criter.	19.00800
F-statistic	25.74931	Durbin-Watson stat	1.992013
Prob(F-statistic)	0.000000		

D'après le tableau de Dickey Fuller

Tendance :

H0 : Tendance =0 P>5% **accepte H0**

H1 : Tendance ≠0 P< 5% **rejete H1**

Le tableau du modèle 3 au-dessus montre que la valeur de la tendance n'est pas significative du fait qu'elle est égale 8.45% qui est supérieure de 5% donc on accepte H0 c'est à dire la série des données de production d'eau potable (FRASELGUERIA)ne contient pas de tendance et la valeur de t-statistic

calculé (1.74) inférieur de la t-statistic tabulé (2.79)(voir l'annexe) la constante est significative ,accepte H1 par conséquent le modèle approprié de teste la stationnarité de la série (FRASELGUERIA).Alors notre série n'admet pas une racine unitaire .On peut dire que notre série est stationnaire et de type DS.donc le modèle (3) n'est pas adapté. On doit refaire le test de racine unitaire à partir du modèle (2) dont les résultats sont les suivants :

Tableau. 5. 43. Test de stationnarité de la série des données de production d'eau potable (Modèle [2] sans tendance et avec constante)

Null Hypothesis: FRASELGSA has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=11)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic				
Test critical values:	1% level		-6.875093	0.0000
	5% level		-2.896346	
	10% level		-2.585396	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(FRASELGSA) Method: Least Squares Date: 08/11/20 Time: 16:53 Sample (adjusted): 2009M02 2016M01 Included observations: 84 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
FRASELGSA(-1)	-0.737624	0.107289	-6.875093	0.0000
C	11559.57	1726.249	6.696350	0.0000
R-squared	0.365654	Mean dependent var		-67.43415
Adjusted R-squared	0.357918	S.D. dependent var		3959.791
S.E. of regression	3172.982	Akaike info criterion		18.98625
Sum squared resid	8.26E+08	Schwarz criterion		19.04413
Log likelihood	-795.4226	Hannan-Quinn criter.		19.00952
F-statistic	47.26691	Durbin-Watson stat		2.023484
Prob(F-statistic)	0.000000			

On rejette l'hypothèse nulle de présence de racine unitaire puisque t-Statistic = -6.875093 est inférieure à la valeur tabulée (-2.896346) du modèle (2).

La constante C est significative car la statistique calculée égale à 6.696350 est supérieure de la statistique tabulé 2.54 ce qui veut dire que le modèle (2) est adapté.

Tableau. 5. 44. Test de stationnarité de la série des données de production d'eau potable (Modèle [1] sans tendance et sans constante)

Null Hypothesis: FRASELGSA has a unit root Exogenous: None Lag Length: 2 (Automatic - based on SIC, maxlag=11)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic				
Test critical values:	1% level		-0.604311	0.4527
	5% level		-2.593468	
	10% level		-1.944811	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(FRASELGSA) Method: Least Squares Date: 08/11/20 Time: 16:54 Sample (adjusted): 2009M04 2016M01 Included observations: 82 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
FRASELGSA(-1)	-0.014623	0.024197	-0.604311	0.5474
D(FRASELGSA(-1))	-0.535000	0.108620	-4.925436	0.0000
D(FRASELGSA(-2))	-0.244586	0.107422	-2.276884	0.0255
R-squared	0.246462	Mean dependent var		7.110317
Adjusted R-squared	0.227386	S.D. dependent var		3978.597
S.E. of regression	3497.126	Akaike info criterion		19.19317
Sum squared resid	9.66E+08	Schwarz criterion		19.28122
Log likelihood	-783.9200	Hannan-Quinn criter.		19.22852
Durbin-Watson stat	2.070073			

On constat que la probabilité du racine unitaire supérieure de 5% ,alors on’ accepte H0 et admet une racine unitaire .Donc notre série n’ est pas stationnaire ,il s’agit un modèle de type DS avec dérive.

➤ 5.6. Stationnarisation de la série Frasgueria

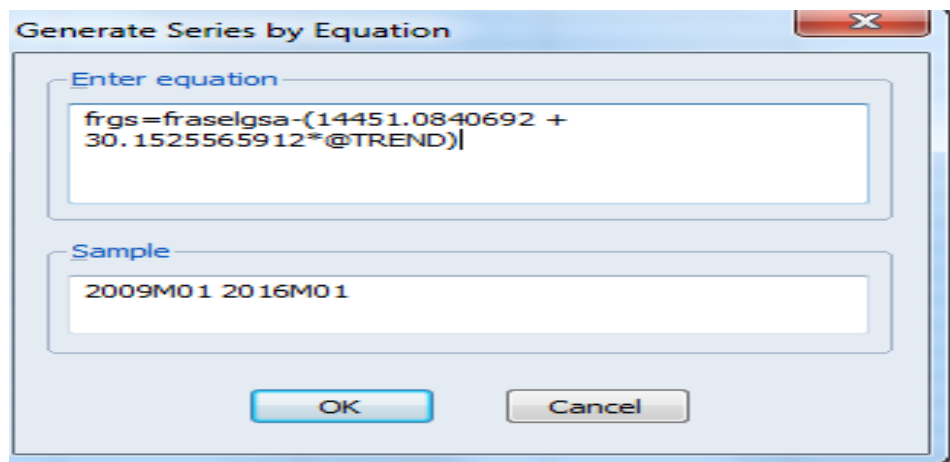
• 5.6.1 Estimation de la fonction de la tendance

Tableau.5.45. Estimation de la fonction de la tendance de la série F rasgueria

Dependent Variable: FRASELGSA
 Method: Least Squares
 Date: 02/05/18 Time: 14:57
 Sample (adjusted): 2009M01 2016M01
 Included observations: 85 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	14451.08	685.1884	21.09067	0.0000
@TREND	30.15256	14.08649	2.140531	0.0352
R-squared	0.052315	Mean dependent var		15717.49
Adjusted R-squared	0.040897	S.D. dependent var		3253.702
S.E. of regression	3186.474	Akaike info criterion		18.99447
Sum squared resid	8.43E+08	Schwarz criterion		19.05194
Log likelihood	-805.2648	Hannan-Quinn criter.		19.01758
F-statistic	4.581872	Durbin-Watson stat		1.545221
Prob(F-statistic)	0.035246			

$$E(\text{FRASELGSA})=(14451.0840692+30.1525565912*\text{@trend})$$



Pour avoir la série stationnaire il suffit juste de retrancher l’espérance de la série FRASELGSA.

Tableau .5.46. Les données de la série stationnaire (FRGS) pour la période allant de janvier 2009 à janvier 2016 (Forage Ras El gueria N°02)

Mois	2009 (m ³)	2010 (m ³)	2011 (m ³)	2012 (m ³)	2013 (m ³)	2014 (m ³)	2015 (m ³)	2016 (m ³)
Janvier	3126.498	-3463.685	-3446.390	4980.037	188.3007	-475.7631	3488.719	-5070.786
Février	-282.3643	-472.6833	-2651.393	7008.769	1189.440	366.8151	-5216.972	
Mars	-3181.322	2994.670	-5163.780	2387.981	-1702.551	1373.689	603.3573	
Avril	1423.637	-366.7016	-2377.183	-3399.441	394.8272	35.41571	6820.963	
Mai	1725.465	1137.579	1126.311	3093.024	-2614.656	-2946.464	642.3711	
Juin	2221.747	-4516.643	-3474.186	2573.561	-77.84701	3167.516	3599.144	
Juillet	1573.634	966.3796	758.2574	529.7540	-1938.987	-2393.383	8.992191	
Aout	-1215.233	-3626.618	-1796.244	9626.335	2832.639	-5715.868	3992.805	
Septembre	-1758.627	3151.522	2950.484	-4476.077	1466.290	-2135.429	1607.584	
Octobre	-1829.233	2019.668	763.6703	-3782.974	1018.409	1290.641	2032.172	
Novembre	2566.025	-2428.810	3378.128	-1054.022	-4000.841	1828.841	-6200.933	
Décembre	-3175.539	-2580.514	4995.286	133.0532	-2186.332	3909.794	-5873.726	

Tableau.5.47. Corrélogramme de la série (FRGS)


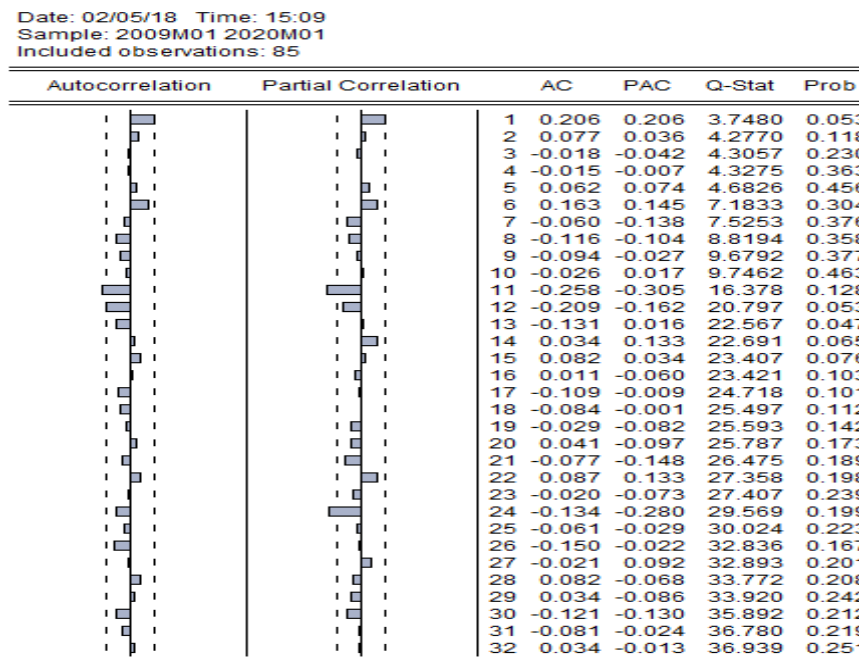


Figure 5-29 Série stationnaire FRGS

Tableau. 5.48. Test de stationnarité de la série des données de production d'eau potable

(Modèle [1] sans tendance et sans constante)

5.7.1. Identification de modèle

Null Hypothesis: FRGS has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.265778	0.0000
Test critical values:		
1% level	-2.592782	
5% level	-1.944713	
10% level	-1.614233	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(FRGS)
 Method: Least Squares
 Date: 08/11/20 Time: 17:05
 Sample (adjusted): 2009M02 2016M01
 Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FRGS(-1)	-0.787172	0.108340	-7.265778	0.0000
R-squared	0.388393	Mean dependent var		-97.58671
Adjusted R-squared	0.388393	S.D. dependent var		3959.791
S.E. of regression	3096.766	Akaike info criterion		18.92594
Sum squared resid	7.96E+08	Schwarz criterion		18.95488
Log likelihood	-793.8894	Hannan-Quinn criter.		18.93757
Durbin-Watson stat	1.991411			

D’après la première différenciation la série FRASELGUERIA devient stationnaire, n’admet pas de racine unitaire ($P < 0.05$) et t-statistic tabulé -1.944713 est supérieur de t-statistic calculé

-7.265778 . On peut conclure que la série FRGS est stationnaire.

Donc on va créer une nouvelle série FRGS.

Tableau.5.49. Corrélogramme de la série FRGS

Date: 02/06/18 Time: 11:10
 Sample: 2009M01 2020M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.206	0.206	3.7480	0.053
		2 0.077	0.036	4.2770	0.118
		3 -0.018	-0.042	4.3057	0.230
		4 -0.015	-0.007	4.3275	0.363
		5 0.062	0.074	4.6826	0.456
		6 0.163	0.145	7.1833	0.304
		7 -0.060	-0.138	7.5253	0.376
		8 -0.116	-0.104	8.8194	0.358
		9 -0.094	-0.027	9.6792	0.377
		10 -0.026	0.017	9.7462	0.463
		11 -0.258	-0.305	16.378	0.128
		12 -0.209	-0.162	20.797	0.053
		13 -0.131	0.016	22.567	0.047
		14 0.034	0.133	22.691	0.065
		15 0.082	0.034	23.407	0.076
		16 0.011	-0.060	23.421	0.103
		17 -0.109	-0.009	24.718	0.101
		18 -0.084	-0.001	25.497	0.112
		19 -0.029	-0.082	25.593	0.142
		20 0.041	-0.097	25.787	0.173
		21 -0.077	-0.148	26.475	0.189
		22 0.087	0.133	27.358	0.198
		23 -0.020	-0.073	27.407	0.239
		24 -0.134	-0.280	29.569	0.199
		25 -0.061	-0.029	30.024	0.223
		26 -0.150	-0.022	32.836	0.167
		27 -0.021	0.092	32.893	0.201
		28 0.082	-0.068	33.772	0.208
		29 0.034	-0.086	33.920	0.242

A partir de ce graphe on peut dire que la série est stationnaire, on obtient la série FRGS est une série stationnaire autour de sa moyenne D'après le corrélogramme on peut identifier les modèles suivants : AR(1) , MA(1), ARMA(1 ;1).

- **5.7. 2.Estimation des paramètres du modèle**

On applique les critères des informations pour choisir entre ces modèles :

Tableau.5.50. les critères d'Akaike et Schwartz

	AIC	SIC	R ²
AR(1)	18.92594	18.95488	0.044296
MA (1)	18.93061	18.95935	0.039519
AR(1)MA(1)	18.94941	19.00729	0.044614

Tableau. 5.51. Modèle AR(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.212828	0.108340	1.964451	0.0528
R-squared	0.044296	Mean dependent var	-37.22021	
Adjusted R-squared	0.044296	S.D. dependent var	3167.719	
S.E. of regression	3096.766	Akaike info criterion	18.92594	
Sum squared resid	7.96E+08	Schwarz criterion	18.95488	
Log likelihood	-793.8894	Hannan-Quinn criter.	18.93757	
Durbin-Watson stat	1.991411			
Inverted AR Roots	.21			

Tableau. 5.52. Modèle MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.190328	0.107878	1.764292	0.0813
R-squared	0.039519	Mean dependent var		1.74E-08
Adjusted R-squared	0.039519	S.D. dependent var		3167.450
S.E. of regression	3104.231	Akaike info criterion		18.93061
Sum squared resid	8.09E+08	Schwarz criterion		18.95935
Log likelihood	-803.5511	Hannan-Quinn criter.		18.94217
Durbin-Watson stat	1.941502			
Inverted MA Roots	-.19			

Tableau. 5.53. Modèle AR(1)MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.273634	0.459194	0.595901	0.5529
MA(1)	-0.062143	0.475329	-0.130738	0.8963
R-squared	0.044614	Mean dependent var		-37.22021
Adjusted R-squared	0.032963	S.D. dependent var		3167.719
S.E. of regression	3115.073	Akaike info criterion		18.94941
Sum squared resid	7.96E+08	Schwarz criterion		19.00729
Log likelihood	-793.8754	Hannan-Quinn criter.		18.97268
Durbin-Watson stat	1.985901			
Inverted AR Roots	.27			
Inverted MA Roots	.06			

D'après ces tableaux (Tableau.5.51.52.53) des critères des information aux dessus, nous constatons que les coefficients de ARMA (1 ;0) ou AR (1) significatives. Donc Le modèle (1,0) semble meilleur que les autres modèles, parce qu'il minimise les critères d'information AIC et SIC.

Champ Captant Interne (Biskra Centre)

Forage Hakim Saadane



Figure 5-30 Forage Hakim Saadane


Forage HAKIM SAADANNE			
Champ captant :	Interne	Date de mise en service :	19/09/1995
Coordonnées implantation UTM		Date de la visite :	
X	749 646.92		
Y	3 859 169.89		
Z _{TN}	110.50		
ND :	64.00m		
NS :	59.50m		
Cote calage :	79.50m		
Ø Colonne :	13''3/8		
Profondeur :	122.50m		
Débit mobilisé :	35l/s		
Débit Exploité :	31l/s		
Pompe model :	PANELLI181REC70/8 HP50		
Puissance :	37.00kw		
HMT :	115m		
Ø pompe :	8''		

Figure 5-31 Fiche Technique (Forage Hakim Saadane)

Tableau .5.54.les données de production mensuelle (observée) d’eau potable pour la période allant de janvier 2009 à janvier 2016 (Forage Hakim Saadane)

	2009 (m³)	2010(m³)	2011(m³)	2012(m³)	2013(m³)	2014(m³)	2015(m³)	2016(m³)
Janvier	11171	16655	18000	12412	10458	9038	8574	9334
Fevrier	12938	16715	13669	13635	12324	8631	9620	
Mars	15844	16640	17150	13540	12444	10513	9540	
Avril	14562	18211	14587	16575	11524	10484	8790	
Mai	13678	15086	15687	14560	14848	11508	9417	
Juin	13158	15110	13870	13546	11524	8956	8600	
Juillet	13248	12475	12870	11655	13341	8338	8339	
Aout	13444	17326	11587	11443	7560	7486	8789	
Septembre	13548	15699	11870	10555	7655	7493	9046	
Octobre	13167	12359	12847	10454	8557	8519	8905	
Novembre	18993	15488	13085	10894	8655	9831	9342	
Décembre	17369	17889	13309	11670	9857	8786	9475	

5.2. Etude graphique de la série (FHAKS)



Le graphe représente l'évolution mensuelle de la Production d'eau potable de la ville de Biskra. L'observation graphique de l'évolution mensuelle de la production d'eau potable démontre une non stationnarité c'est-à-dire il ya une tendance ainsi que la probabilité du corrélogramme est égale à zéro c.-à-d. Inférieur de 5% et des pics importants. Son examen pressente une décroissance de ses retards (ce qui indique l'existence du facteur tendanciel). Les autocorrélations de la production d'eau potable s'annulent très lentement. Donc la série brute est effectuée de la saisonnalité de la tendance, ce qui veut dire qu'elle est **non stationnaire** on va confirmer avec le test qui suit :

5.3. Dessaisonnaliser la série (FHAKS)

5.3.1. Les coefficients saisonniers **Tableau.5. 56.** Coefficients saisonniers de la série FHAKSSA (voir l'annexe)

Tableau.5.57. Les données de la série Désaisonnalisée FHAKSSA pour la période allant de janvier 2009 à janvier 2016 (Forage HAKIMSAADANE)

Mois	2009	2010	2011	2012	2013	2014	2015	2016
Janvier	11106.14	16558.30	17895.49	12339.93	10397.28	8985.523	8524.217	9279.804
Fevrier	12691.87	16397.02	13408.97	13375.61	12089.55	8466.807	9436.992	
Mars	14457.17	15183.49	15648.85	12354.84	11354.77	9592.791	8704.958	
Avril	13251.94	16572.66	13274.69	15083.84	10487.25	9540.812	7999.212	
Mai	11983.45	13217.01	13743.55	12756.18	13008.50	10082.28	8250.337	
Juin	13101.92	15045.60	13810.89	13488.27	11474.89	8917.831	8563.348	
Juillet	13885.44	13075.24	13489.25	12215.79	13982.91	8739.190	8740.238	
Aout	15090.16	19447.49	13005.78	12844.14	8485.687	8402.626	9865.173	
Septembre	15523.09	17987.67	13600.46	12093.75	8770.980	8585.363	10364.77	
Octobre	14893.53	13979.58	14531.57	11824.79	9679.041	9636.058	10072.67	
Novembre	18560.87	15135.61	12787.29	10646.14	8458.079	9607.323	9129.449	
Décembre	16499.53	16993.49	12642.76	11085.81	9363.569	8346.182	9000.691	

Tableau.5. 58. Corrélogramme de la série FHAKSSA




Figure 5-33 Le graphe de la série désaisonnalisé FHAKSSA

L'analyse visuelle du graphe (FHAKSSA) montre la présence d'une tendance linéaire mais le graphe représente l'évolution mensuelle de la Production d'eau potable de la ville de Biskra, démontre une non stationnarité puisque il ya des pics important ainsi que la probabilité du corrélogramme est égale à zéro c.-à-d. inferieur de 5% .Son examen pressente une décroissance de ses retards (ce qui indique l'existence du facteur tendanciel). Les autocorrélations de la production d'eau potable s'annulent très lentement. Donc la série brute est effectuée de la saisonnalité de la tendance, ce qui veut dire qu'elle est **non stationnaire** on va confirmer avec les hypothèses qui suit :

5.4. Etude de la stationnarité de la série désaisonnalisée (FHAUSSA)

5.5. Teste de racine unitaire

Tableau. 5. 59. Test de stationnarité de la série des données de production d'eau potable
(Modèle [3] avec tendance et avec constante)

Null Hypothesis: FHAUSSA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.944886	0.0000
Test critical values:		
1% level	-4.071006	
5% level	-3.464198	
10% level	-3.158586	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(FHAUSSA)
Method: Least Squares
Date: 08/11/20 Time: 20:12
Sample (adjusted): 2009M02 2016M01
Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FHAUSSA(-1)	-0.549390	0.092414	-5.944886	0.0000
C	9031.977	1531.206	5.898604	0.0000
@TREND(2009M01)	-55.49169	10.85521	-5.111988	0.0000

R-squared	0.305432	Mean dependent var	-21.74207
Adjusted R-squared	0.288283	S.D. dependent var	1686.185
S.E. of regression	1422.522	Akaike info criterion	17.39331
Sum squared resid	1.64E+08	Schwarz criterion	17.48013
Log likelihood	-727.5191	Hannan-Quinn criter.	17.42821
F-statistic	17.80966	Durbin-Watson stat	2.295814
Prob(F-statistic)	0.000000		

Selon le tableau au-dessus, il est possible de constater que la tendance significative puisqu'elle la probabilité de tendance égale 0% qui est inférieur au seuil tolérable de 5% on a accepté H_0 , et t-statistic calculé (-5.111) supérieur de t-statistic tabulée (2.79) (voir l'annexe).

Donc il s'agit d'un modèle de type TS (trend stationary) non stationnaire. Alors pour rendre cette série d'être stationnaire. D'où la nécessité de passer à l'étape suivante qui consiste à estimer la fonction de la tendance. Il en résulte que le modèle approprié pour tester la stationnarité de la série FHAKS

5.6. Stationnarisation de la série FHAKS

5.6.1. Estimation de la fonction de la tendance.

Pour rendre une série de processus TS, on utilise la méthode de moindre carré MCO pour éliminer les effets saisonniers de la tendance et cela par les étapes suivantes :

Genre de la tendance par command : `genr t=@trend`

La régression par la commande : `ls fhaks c t`

Genr trend dfhaks=fhaks-(ls fhaks c trend)

Tableau.5 .60. Icône de logiciel l'estimation de la fonction de la tendance

Dependent Variable: FHAKSSA

Method: Least Squares

Date: 08/11/20 Time: 20:16

Sample: 2009M01 2016M01

Included observations: 85

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	16098.26	364.2383	44.19706	0.0000
@TREND	-93.94345	7.488214	-12.54551	0.0000
R-squared	0.654727	Mean dependent var		12152.64
Adjusted R-squared	0.650568	S.D. dependent var		2865.526
S.E. of regression	1693.893	Akaike info criterion		17.73069
Sum squared resid	2.38E+08	Schwarz criterion		17.78817
Log likelihood	-751.5545	Hannan-Quinn criter.		17.75381
F-statistic	157.3898	Durbin-Watson stat		0.992758
Prob(F-statistic)	0.000000			

$$\text{FHAKSSA} = 16098.2603114 - \underline{93.943445274} * \text{@TREND}$$

Tableau. 5.61. Les données de la série stationnaire VFHAKS pour la période allant de janvier 2009 à janvier 2016 (Forage HAKIMSAADANE)

Mois	2009 (m ³)	2010 (m ³)	2011(m ³)	2012(m ³)	2013(m ³)	2014(m ³)	2015(m ³)	2016(m ³)
Janvier	-4992.122	1587.358	4051.870	-376.3635	-1191.697	-1476.131	-810.1151	1072.793
Fevrier	-3312.445	1520.024	-340.7087	753.2595	594.5208	-1900.903	196.6035	
Mars	-1453.208	400.4386	1993.119	-173.5738	-46.31895	-680.9760	-441.4874	
Avril	-2564.493	1883.548	-287.0990	2649.373	-819.8952	-639.0108	-1053.290	
Mai	-3739.041	-1378.155	275.7086	415.6529	1795.294	-3.594987	-708.2216	
Juin	-2526.620	544.3823	436.9883	1241.690	355.6292	-1074.105	-301.2666	
Juillet	-1649.161	-1332.034	209.2935	63.15418	2957.599	-1158.803	-30.43382	
Aout	-350.5000	5134.154	-180.2384	785.4508	-2445.683	-1401.423	1188.445	
Septembre	176.3744	3768.278	508.3909	129.0057	-2066.448	-1124.743	1781.981	
Octobre	-359.2403	-145.8683	1533.442	-46.01967	-1064.443	19.89525	1583.831	
Novembre	3402.041	1104.109	-116.8961	-1130.725	-2191.461	85.10371	734.5509	
Décembre	1434.643	3055.934	-167.4748	-597.1068	-1192.029	-1082.094	699.7367	

Tableau.5.62 . Corrélogramme VFHAKS




Figure 5-29 .La série stationnaire VFHAKS

Tableau. 5. 63. Test de stationnarité de la série des données de production d'eau potable
Modèle [1]) sans tendance et sans constante

Null Hypothesis: VFHAKS has a unit root
Exogenous: None
Lag Length: 1 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.230266	0.0000
Test critical values:		
1% level	-2.593121	
5% level	-1.944762	
10% level	-1.614204	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(VFHAKS)
Method: Least Squares
Date: 08/11/20 Time: 20:29
Sample (adjusted): 2009M03 2016M01
Included observations: 83 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VFHAKS(-1)	-0.453255	0.107146	-4.230266	0.0001
D(VFHAKS(-1))	-0.241556	0.101509	-2.379659	0.0197
R-squared	0.344171	Mean dependent var	52.83420	
Adjusted R-squared	0.336074	S.D. dependent var	1687.009	
S.E. of regression	1374.603	Akaike info criterion	17.31352	
Sum squared resid	1.53E+08	Schwarz criterion	17.37180	
Log likelihood	-716.5110	Hannan-Quinn criter.	17.33693	
Durbin-Watson stat	2.019396			

Nous remarquon à partir du tableau de racine unitaire.Nous avons vu que la t-statistique tabulée qui égale (-1.944762) est superieure à la t-statistic calculée au seuil 5% (-.230266).IL en résulte que le modèle de la série VFHAKS est celui ne comporte pas une racine unitaire ($P < 0$) donc la série VFHAKS est stationnaire.

5.7.1. Identification de modèle

Analyse des fonctions d'autocorrélation simple et d'autocorrélation partielle

- Détermination des ordres p et q du processus ARMA

Tableau. 5.64. Corrélogramme de la série VFHAKS

Date: 08/11/20 Time: 20:29
 Sample: 2009M01 2016M01
 Included observations: 85

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.449	0.449	17.739	0.000
		2	0.376	0.218	30.330	0.000
		3	0.280	0.065	37.376	0.000
		4	0.311	0.151	46.217	0.000
		5	0.202	-0.026	50.003	0.000
		6	-0.011	-0.247	50.013	0.000
		7	0.036	0.036	50.139	0.000
		8	-0.041	-0.070	50.299	0.000
		9	0.114	0.203	51.567	0.000
		10	0.040	0.057	51.726	0.000
		11	0.049	0.005	51.963	0.000
		12	0.003	-0.082	51.964	0.000
		13	0.090	0.056	52.798	0.000
		14	-0.021	-0.198	52.842	0.000
		15	-0.062	-0.015	53.252	0.000
		16	-0.066	-0.002	53.720	0.000
		17	-0.093	-0.007	54.651	0.000
		18	-0.156	-0.125	57.329	0.000
		19	-0.240	-0.088	63.759	0.000
		20	-0.133	0.019	65.765	0.000
		21	-0.108	0.093	67.108	0.000
		22	-0.182	-0.174	71.013	0.000
		23	-0.239	-0.090	77.811	0.000
		24	-0.166	-0.003	81.163	0.000
		25	-0.095	0.034	82.272	0.000
		26	-0.069	0.043	82.867	0.000
		27	-0.054	0.130	83.240	0.000
		28	-0.017	0.060	83.278	0.000
		29	-0.014	-0.066	83.304	0.000
		30	0.079	0.017	84.135	0.000

On remarque du corrélogramme de la fonction d'autocorrélation (ACF) trois pics important pour le terme MA (1 ; 2 ;3) sont significativement différentes de zéro et le corrélogramme de la fonction partielle(PACF) est un pic important pour le terme AR(1 ;2) et d'après la combinaisons des deux fonctions il ya onze modèle : **AR(1),AR(2),MA(1),MA(2),MA(3),ARMA(1 ;1), ARMA(1 ;2) ARMA(1 ;3) ARMA(2 ;1) ARMA(2 ;2) ARMA (2 ;3).**

Pour choisir le modèle à retenir pour la prévision, nous allons recourir aux critères d'information et au coefficient de détermination. Ces critères permettent d'évaluer la qualité d'un modèle. Les résidus de ces différents modèles sont de bruits blancs et donc, tous les modèles ci-dessous doivent être validés.

5.7. 2.Estimation des paramètres du modèle

Le but est alors de minimiser la colonne AIC, et SIC ou de maximiser les colonnes R².

Tableau. 5.65. Les critères d'Akaike et Schwartz

MODELE	AIC	SIC	R ²
AR(1)	17.35238	17.38132	0.225059
AR(2)	17.38479	17.41394	0.164118
MA(1)	17.54401	17.57274	0.150543
MA(2)	17.58733	17.61607	0.112935
MA(3)	17.56480	17.59453	
ARMA(1 ;1)	17.28762	17.34550	0.290744
ARMA(1 ;2)	-	-	-
ARMA(1 ;3)	-	-	-
ARMA(2 ;1)	17.32037	17.37865	0.234932
ARMA(2 ;2)	-	-	-
ARMA(2 ;3)	-	-	-

Tableau.5.66. Modèle AR(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.451062	0.091589	4.924858	0.0000

R-squared: 0.225059
 Adjusted R-squared: 0.225059
 S.E. of regression: 1409.988
 Sum squared resid: 1.65E+08
 Log likelihood: -727.8001
 Durbin-Watson stat: 2.281568
 Inverted AR Roots: .45

Tableau.5.67. Modèle AR(2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.378531	0.093175	4.062595	0.0001

R-squared: 0.164118
 Adjusted R-squared: 0.164118
 S.E. of regression: 1432.921
 Sum squared resid: 1.68E+08
 Log likelihood: -720.4689
 Durbin-Watson stat: 1.501345
 Inverted AR Roots: .62, -.62

Tableau.5.68. Modèle MA(1)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:37
Sample: 2009M01 2016M01
Included observations: 85
Convergence achieved after 14 iterations
MA Backcast: 2008M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.338239	0.101390	3.336015	0.0013
R-squared	0.150543	Mean dependent var	-1.97E-08	
Adjusted R-squared	0.150543	S.D. dependent var	1683.780	
S.E. of regression	1551.872	Akaike info criterion	17.54401	
Sum squared resid	2.02E+08	Schwarz criterion	17.57274	
Log likelihood	-744.6203	Hannan-Quinn criter.	17.55557	
Durbin-Watson stat	1.770835			
Inverted MA Roots	-.34			

Tableau.5.69. Modèle MA(2)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:38
Sample: 2009M01 2016M01
Included observations: 85
Convergence achieved after 11 iterations
MA Backcast: 2008M11 2008M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.298839	0.101769	2.936452	0.0043
R-squared	0.112935	Mean dependent var	-1.97E-08	
Adjusted R-squared	0.112935	S.D. dependent var	1683.780	
S.E. of regression	1585.853	Akaike info criterion	17.58733	
Sum squared resid	2.11E+08	Schwarz criterion	17.61607	
Log likelihood	-746.4614	Hannan-Quinn criter.	17.59889	
Durbin-Watson stat	1.248484			

Tableau.5.70. Modèle MA(3)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:39
Sample: 2009M01 2016M01
Included observations: 85
Convergence achieved after 9 iterations
MA Backcast: 2008M10 2008M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.473876	0.093421	5.072471	0.0000
R-squared	0.132697	Mean dependent var	-1.97E-08	
Adjusted R-squared	0.132697	S.D. dependent var	1683.780	
S.E. of regression	1568.089	Akaike info criterion	17.56480	
Sum squared resid	2.07E+08	Schwarz criterion	17.59354	
Log likelihood	-745.5039	Hannan-Quinn criter.	17.57636	
Durbin-Watson stat	1.411822			
Inverted MA Roots	.39+ .68i	.39- .68i	-.78	

Tableau.5.71. Modèle ARMA(1 ;1)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:36
Sample (adjusted): 2009M02 2016M01
Included observations: 84 after adjustments
Convergence achieved after 6 iterations
MA Backcast: 2009M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.794605	0.089091	8.919056	0.0000
MA(1)	-0.518122	0.144772	-3.578892	0.0006
R-squared	0.290744	Mean dependent var	59.43002	
Adjusted R-squared	0.282094	S.D. dependent var	1601.700	
S.E. of regression	1357.109	Akaike info criterion	17.28762	
Sum squared resid	1.51E+08	Schwarz criterion	17.34550	
Log likelihood	-724.0802	Hannan-Quinn criter.	17.31089	
Durbin-Watson stat	2.012879			
Inverted AR Roots	.79			
Inverted MA Roots	.52			

Tableau.5.72. Modèle ARMA (2 ;2)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:41
Sample (adjusted): 2009M03 2016M01
Included observations: 83 after adjustments
Convergence achieved after 11 iterations
MA Backcast: 2009M01 2009M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.597166	0.135541	4.405787	0.0000
MA(2)	-0.305795	0.182752	-1.673277	0.0981
R-squared	0.193688	Mean dependent var	100.0550	
Adjusted R-squared	0.183733	S.D. dependent var	1567.292	
S.E. of regression	1416.009	Akaike info criterion	17.37287	
Sum squared resid	1.62E+08	Schwarz criterion	17.43116	
Log likelihood	-718.9743	Hannan-Quinn criter.	17.39629	
Durbin-Watson stat	1.509933			
Inverted AR Roots	.77	-.77		
Inverted MA Roots	.55	-.55		

Tableau.5.73. Modèle ARMA(2 ;3)

Equation: UNTITLED Workfile: FHKS020:Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFHAKS
Method: Least Squares
Date: 08/11/20 Time: 20:42
Sample (adjusted): 2009M03 2016M01
Included observations: 83 after adjustments
Convergence achieved after 8 iterations
MA Backcast: 2008M12 2009M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.376538	0.098460	3.824260	0.0003
MA(3)	0.005585	0.116737	0.047842	0.9620
R-squared	0.164128	Mean dependent var	100.0550	
Adjusted R-squared	0.153808	S.D. dependent var	1567.292	
S.E. of regression	1441.731	Akaike info criterion	17.40888	
Sum squared resid	1.68E+08	Schwarz criterion	17.46716	
Log likelihood	-720.4684	Hannan-Quinn criter.	17.43229	
Durbin-Watson stat	1.500529			
Inverted AR Roots	.61	-.61		
Inverted MA Roots	.09- .15i	.09+ .15i	-.18	

Tableau.5.74.Modèle ARMA(1 ;3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.473778	0.094037	5.038200	0.0000
MA(3)	-0.056312	0.114724	-0.490843	0.6248

R-squared	0.225929	Mean dependent var	59.43002
Adjusted R-squared	0.216489	S.D. dependent var	1601.700
S.E. of regression	1417.763	Akaike info criterion	17.37507
Sum squared resid	1.65E+08	Schwarz criterion	17.43295
Log likelihood	-727.7529	Hannan-Quinn criter.	17.39834
Durbin-Watson stat	2.303047		

Inverted AR Roots	.47		
Inverted MA Roots	.38	-.19-.33i	-.19+.33i

Tableau.5.75. Modèle ARMA(1 ;2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.398390	0.098785	4.032886	0.0001
MA(2)	0.153717	0.113727	1.351628	0.1802

R-squared	0.246989	Mean dependent var	59.43002
Adjusted R-squared	0.237806	S.D. dependent var	1601.700
S.E. of regression	1398.344	Akaike info criterion	17.34749
Sum squared resid	1.60E+08	Schwarz criterion	17.40536
Log likelihood	-726.5944	Hannan-Quinn criter.	17.37075
Durbin-Watson stat	2.122767		

Inverted AR Roots	.40		
-------------------	-----	--	--

Tableau.5.76.Modèle AR(2 ;1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.350032	0.100874	3.469997	0.0008
MA(1)	0.323005	0.109232	2.957065	0.0041

R-squared	0.234932	Mean dependent var	100.0550
Adjusted R-squared	0.225487	S.D. dependent var	1567.292
S.E. of regression	1379.318	Akaike info criterion	17.32037
Sum squared resid	1.54E+08	Schwarz criterion	17.37865
Log likelihood	-716.7952	Hannan-Quinn criter.	17.34378
Durbin-Watson stat	2.027811		

Inverted AR Roots	.59	-.59	
Inverted MA Roots	-.32		

D'après ces tableaux ce dessus, nous constatons que les coefficients de ARMA (1 ;1) significatives car la probabilité est inférieure de 0.05. Donc Le modèle (1,1) semble meilleur que les autres modèles, parce qu'il minimise les critères d'information AIC et SIC que les autres modèles.

Champ Captant Interne (Biskra Ouest)



Figure 5-35 Forage 1^{er}Novembre

5.2. Etude graphique de la série (F1Novem)

Tableau.5.77.les données de production mensuelle d’eau potable pour la période allant de janvier 2009 à janvier 2016 (**Forage 1Novembre**)

Mois	2009(m ³)	2010(m ³)	2011(m ³)	2012(m ³)	2013(m ³)	2014(m ³)	2015(m ³)	2016(m ³)
Janvier	9331	9365	8317	9525	5496	7761	7258	7895
Février	9206	9386	8729	8585	6004	7483	6691	
Mars	9050	8809	9636	8708	8700	8683	6204	
Avril	8877	8116	9678	8327	6371	8203	6064	
Mai	8890	9036	6744	9356	5633	9586	5166	
Juin	6110	8930	6832	8426	7837	6399	6594	
Juillet	8484	8096	7571	7897	9703	7894	5967	
Aout	9206	9600	5889	7609	7953	8996	6010	
Septembre	9050	8972	6666	8116	9944	8909	7722	
Octobre	8877	9381	6125	8218	7772	7371	7842	
Novembre	8890	8099	8435	7056	7870	9713	8433	
Décembre	9288	7238	8139	5886	6737	7385	7185	

l'analyse du graphe de la série F1NOVEM:

Tableau .5.78. Corrélogramme de la série brute F1NOVEMB




Figure 5-36 L'évolution mensuelle de la Production d'eau potable de la ville de Biskra F1NOVEMB

L'observation graphique de l'évolution mensuelle de la production d'eau potable démontre une non stationnarité c'est-à-dire il ya des pics important et la probabilité du corrélogramme n'est pas significative.

5.3. Dessaisonnaliser la série (F1NOVSA):

5.3.1. Les coefficients saisonniers

Tableau.5. 79. Coefficients saisonniers de la série F1NOVMSA

Date: 08/11/20 Time: 22:51
 Sample: 2009M01 2016M01
 Included observations: 85
 Ratio to Moving Average
 Original Series: F1NOV
 Adjusted Series: F1NOVSA

Scaling Factors:	
1	0.996202
2	0.983351
3	1.073442
4	0.990549
5	0.956088
6	0.958678
7	1.001525
8	1.009808
9	1.068188
10	0.989230
11	1.049249
12	0.934102

Tableau .5.80. Les données de la série Désaisonnalisée FHAKSSA pour la période allant de janvier 2009 à janvier 2016 (FHAKSSA)

	2009(m ³)	2010(m ³)	2011(m ³)	2012(m ³)	2013(m ³)	2014(m ³)	2015(m ³)	2016(m ³)
Janvier	9366.571	9400.700	8348.705	9561.310	5516.951	7790.586	7285.668	7925.096
Fevrier	9361.865	9544.913	8876.789	8730.351	6105.653	7609.693	6804.284	
Mars	8430.820	8206.309	8976.727	8112.219	8104.766	8088.929	5779.537	
Avril	8961.698	8193.437	9770.341	8406.450	6431.788	8281.267	6121.858	
Mai	9298.306	9451.012	7053.743	9785.709	5891.717	10026.27	5403.268	
Juin	6373.361	9314.913	7126.482	8789.188	8174.801	6674.818	6878.223	
Juillet	8471.081	8083.671	7559.471	7884.974	9688.224	7881.979	5957.913	
Aout	9116.582	9506.755	5831.800	7535.093	7875.752	8908.621	5951.625	
Septembre	8472.289	8399.268	6240.473	7597.911	9309.220	8340.290	7229.062	
Octobre	8973.646	9483.133	6191.684	8307.471	7856.616	7451.250	7927.378	
Novembre	8472.729	7718.856	8039.085	6724.811	7500.604	9257.099	8037.179	
Décembre	9943.242	7748.620	8713.183	6301.240	7212.276	7905.991	7691.881	

Tableau.5. 81. Corrélogramme de la série F1NOVEMSA




Figure 5-30 Le graphe de la série désaisonnalisé F1NOVEMSA

L'observation du graphe de la série (F1NOVEMSA) présume un non stationnarité.

- 5.4. Etude de la stationnarité de la série désaisonnalisée (F1NOVEMSA) :
- 5.5. Teste de racine unitaire

Tableau. 5. 82. Test de stationnarité de la série des données de production d'eau potable (Modèle [3] avec tendance et avec constante)

Null Hypothesis: F1NOVSA has a unit root Exogenous: Constant, Linear Trend Lag Length: 0 (Automatic - based on SIC, maxlag=11)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic				
Test critical values:			-5.746443	0.0000
	1% level		-4.071006	
	5% level		-3.464198	
	10% level		-3.158586	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(F1NOVSA) Method: Least Squares Date: 08/11/20 Time: 22:54 Sample (adjusted): 2009M02 2016M01 Included observations: 84 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
F1NOVSA(-1)	-0.581829	0.101250	-5.746443	0.0000
C	5117.302	927.5533	5.516990	0.0000
@TREND(2009M01)	-11.66302	4.944445	-2.358812	0.0207
R-squared	0.290038	Mean dependent var	-17.16041	
Adjusted R-squared	0.272508	S.D. dependent var	1149.609	
S.E. of regression	980.5370	Akaike info criterion	16.64914	
Sum squared resid	77877676	Schwarz criterion	16.73595	
Log likelihood	-696.2638	Hannan-Quinn criter.	16.68404	
F-statistic	16.54533	Durbin-Watson stat	2.049618	
Prob(F-statistic)	0.000001			

Tendance :

H0 : Tendance =0, P>5% **rejeté H0**

H1 : Tendance ≠0, P<5 % **accepte H1**

Selon le tableau, il est possible de constater que la tendance n'est pas significative puis qu'elle est égale 20.7 supérieure au seuil tolérable de 5% on a accepté H0, donc la série est non stationnaire. D'où la nécessité de passer à l'étape suivante qui consiste à appliquer le test ADF sur la série en différence première dont le but est de tester l'ordre d'intégration de la série

Tableau. 5. 83. Test de stationnarité de la série des données de production d'eau potable (Modèle [2] Modèle sans tendance et avec constante)

Null Hypothesis: F1NOVSA has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=11)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic				
Test critical values:			-5.106403	0.0000
	1% level		-3.510259	
	5% level		-2.896346	
	10% level		-2.585396	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(F1NOVSA) Method: Least Squares Date: 08/11/20 Time: 22:58 Sample (adjusted): 2009M02 2016M01 Included observations: 84 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
F1NOVSA(-1)	-0.474048	0.092834	-5.106403	0.0000
C	3762.308	748.2611	5.028069	0.0000
R-squared	0.241270	Mean dependent var	-17.16041	
Adjusted R-squared	0.232017	S.D. dependent var	1149.609	
S.E. of regression	1007.455	Akaike info criterion	16.69176	
Sum squared resid	8327193	Schwarz criterion	16.74964	
Log likelihood	-699.0641	Hannan-Quinn criter.	16.71503	
F-statistic	26.07535	Durbin-Watson stat	2.147201	
Prob(F-statistic)	0.000002			

D'après le tableau, il est possible de constater que la constante significative du fait qu'elle est égale à 0% qui est inférieur au seuil 5%. Il en résulte que le modèle avec constante semble être le plus approprié pour tester la stationnarité de la série F1NOVSA, et la série ne comporte pas une racine unitaire car ($-5.106 < -2.89$).

Tableau. 5. 84. Test de stationnarité de la série des données de production d'eau potable
Modèle (1) sans tendance et sans constante

Null Hypothesis: F1NOVEMSA has a unit root				
Exogenous: None				
Lag Length: 1 (Fixed)				
		t-Statistic	Prob.*	
Augmented Dickey-Fuller test statistic		-0.670960	0.4235	
Test critical values:	1% level	-2.593121		
	5% level	-1.944762		
	10% level	-1.614204		
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(F1NOVEMSA)				
Method: Least Squares				
Date: 02/08/18 Time: 10:25				
Sample (adjusted): 2009M03 2016M01				
Included observations: 83 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
F1NOVEMSA(-1)	-0.010027	0.014945	-0.670960	0.5042
D(F1NOVEMSA(-1))	-0.331365	0.104574	-3.168723	0.0022
R-squared	0.116924	Mean dependent var	-17.31047	
Adjusted R-squared	0.106022	S.D. dependent var	1156.596	
S.E. of regression	1093.566	Akaike info criterion	16.85608	
Sum squared resid	96866873	Schwarz criterion	16.91436	
Log likelihood	-697.5272	Hannan-Quinn criter.	16.87949	
Durbin-Watson stat	2.158942			

IL en découle du tableau que la série des productions d'eau potable F1NOVSA est non stationnaire en différence première et ce étant donné que la statistique ADF qui égale à (-0.670960) est supérieure à la valeur critique au seuil de 5% qui égale à (-1.944762) et la série comporte une racine unitaire qui égale à 42.35 % supérieure à 5%.

Il en résulte que le modèle approprié pour tester la stationnarité de la série F1NOVSA

➤ **5.6. Stationnarisation de la série F1NOVEMSA**

• **5.6. 1.Estimation de la fonction de la tendance**

Equation Estimation

Specification Options

Equation specification

Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like $Y=c(1)+c(2)*X$.

f1novemsa c @trend

Estimation settings

Method: LS - Least Squares (NLS and ARMA)

Sample: 2009M01 2016M01

OK Annuler

Dependent Variable: F1NOVEMSA

Method: Least Squares

Date: 02/08/18 Time: 13:39

Sample: 2009M01 2016M01

Included observations: 85

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	8867.160	229.4914	38.63830	0.0000
@TREND	-21.30853	4.718013	-4.516420	0.0000
R-squared	0.197277	Mean dependent var	7972.201	
Adjusted R-squared	0.187606	S.D. dependent var	1184.086	
S.E. of regression	1067.252	Akaike info criterion	16.80681	
Sum squared resid	94539157	Schwarz criterion	16.86428	
Log likelihood	-712.2894	Hannan-Quinn criter.	16.82993	
F-statistic	20.39805	Durbin-Watson stat	1.160305	
Prob(F-statistic)	0.000021			


$$F1NOVEMSA = 8867.15969628 - 21.3085289644 * @TREND$$

$$\text{Stationnaire(stasf1novem)} = \text{F1novemsa} - (8867.15969628 - 21.3085289644 * (@\text{TREND}))$$

Tableau .5.85. Les données de la série stationnaire STASF1NOM pour la période allant de janvier 2009 à janvier 2016 (STASF1NOM)

	2009(m ³)	2010(m ³)	2011(m ³)	2012(m ³)	2013(m ³)	2014(m ³)	2015(m ³)	2016(m ³)
Janvier	499.4108	789.2428	-7.049917	1461.257	-2327.399	201.9376	-47.27752	847.8531
Février	516.0141	954.7640	542.3428	651.6071	-1717.389	42.35400	-507.3529	
Mars	-393.7226	-362.5316	663.5893	54.78324	303.0329	542.8984	-1510.792	
Avril	158.4640	-354.0946	1478.511	370.3233	-1348.637	756.5449	-1147.162	
Mai	516.3808	924.7887	-1216.778	1770.891	-1867.400	2522.859	-1844.444	
Juin	-2387.256	809.9978	-1122.731	795.6785	436.9930	-807.2872	-348.1798	
Juillet	-268.2279	-399.9347	-668.4329	-87.22698	1971.725	421.1823	-1247.181	
Aout	398.5816	1044.457	-2374.795	-415.7996	180.5615	1469.133	-1232.161	
Septembre	-224.4026	-41.72110	-1944.814	-331.6732	1635.338	922.1099	66.58500	
Octobre	298.2631	1063.453	-1972.294	399.1955	204.0421	54.37868	786.2089	
Novembre	-181.3458	-679.5162	-103.5847	-1162.156	-130.6605	1881.537	917.3185	
Décembre	1310.476	-628.4434	591.8219	-1564.418	-397.6804	551.7365	593.3294	

• Graphe de la série brute désaisonnalisée et sans tendance (stastf1novem)



A partir du corrélogramme, On remarque que les coefficients d'autocréation qui s'annulent rapidement

• 5.7.1. L'identification de modèle

Tableau 5.87. Test de stationnarité de la série TASF1NOVEM


Variable	Coefficient	Std. Error	t-Statistic	Prob.
STASF1NOVEM(-1)	-0.582096	0.100022	-5.819696	0.0000

Augmented Dickey-Fuller test statistic: -5.819696, Prob.*: 0.0000
 Test critical values: 1% level: -2.592782, 5% level: -1.944713, 10% level: -1.614233
 *MacKinnon (1996) one-sided p-values.
 Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(STASF1NOVEM)
 Method: Least Squares
 Date: 08/14/20 Time: 00:18
 Sample (adjusted): 2009M02 2016M01
 Included observations: 84 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
STASF1NOVEM(-1)	-0.582096	0.100022	-5.819696	0.0000

R-squared: 0.289793, Adjusted R-squared: 0.289793, S.E. of regression: 968.8186, Sum squared resid: 77904591
 Mean dependent var: 4.148122, S.D. dependent var: 1149.609, Akaike info criterion: 16.60187, Schwarz criterion: 16.63080

Tableau. 5.88. Corrélogramme de la série STASF1NOVEM



On remarque du corrélogramme de la fonction d'autocorrélation (ACF) quatre pics importants pour le terme MA (1, 2) sont significativement différentes de zéro et le corrélogramme de la fonction partielle (PACF) est deux pics importants pour le terme AR (1) et d'après la combinaison des deux fonctions il ya cinq modèles :

AR(1),MA(1),MA(2),ARMA(1,1).ARMA (1,2),

- **5.7. 2.Estimation des paramètres du modèle**

Le but est alors de minimiser la colonne AIC, et SIC ou de maximiser les colonnes R² [23].

Tableau.5.89. les critères d'Akaike et Schwartz

MODELE	AIC	SIC	R ²
MA(1)	16.62781	16.65655	0.143989
MA(2)	16.73684	16.76558	0.045378
AR(1)	16.60187	16.63080	0.173748
ARMA(1 ;1)	-	-	-
ARMA(1 ;1)	-	-	-

Tableau.5.90. Modèle MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.357730	0.102155	3.501840	0.0007
R-squared	0.143989	Mean dependent var		1.42E-09
Adjusted R-squared	0.143989	S.D. dependent var		1060.880
S.E. of regression	981.5354	Akaike info criterion		16.62781
Sum squared resid	80926591	Schwarz criterion		16.65655
Log likelihood	-705.6818	Hannan-Quinn criter.		16.63937
Durbin-Watson stat	1.877290			
Inverted MA Roots	-.36			

Tableau.5.91. Modèle MA(2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.201891	0.106979	1.887205	0.0626
R-squared	0.045378	Mean dependent var		1.42E-09
Adjusted R-squared	0.045378	S.D. dependent var		1060.880
S.E. of regression	1036.530	Akaike info criterion		16.73684
Sum squared resid	90249170	Schwarz criterion		16.76558
Log likelihood	-710.3157	Hannan-Quinn criter.		16.74840
Durbin-Watson stat	1.330487			

Tableau.5.92. Modèle AR(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.417904	0.100022	4.178138	0.0001
R-squared	0.173748	Mean dependent var		-5.945367
Adjusted R-squared	0.173748	S.D. dependent var		1065.826
S.E. of regression	968.8186	Akaike info criterion		16.60187
Sum squared resid	77904591	Schwarz criterion		16.63080
Log likelihood	-696.2783	Hannan-Quinn criter.		16.61350
Durbin-Watson stat	2.048350			
Inverted AR Roots	.42			

Tableau.5.93. Modèle AR(1)MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.555156	0.214634	2.586517	0.0115
MA(1)	-0.167624	0.253968	-0.660020	0.5111

R-squared	0.177820	Mean dependent var	-5.945367
Adjusted R-squared	0.167794	S.D. dependent var	1065.826
S.E. of regression	972.3034	Akaike info criterion	16.62073
Sum squared resid	77520667	Schwarz criterion	16.67861
Log likelihood	-696.0708	Hannan-Quinn criter.	16.64400
Durbin-Watson stat	1.993833		

Inverted AR Roots	.56
Inverted MA Roots	.17

Tableau.5.94. Modèle AR(1)MA(2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.405376	0.107975	3.754349	0.0003
MA(2)	0.031471	0.118015	0.266673	0.7904

R-squared	0.174467	Mean dependent var	-5.945367
Adjusted R-squared	0.164399	S.D. dependent var	1065.826
S.E. of regression	974.2845	Akaike info criterion	16.62481
Sum squared resid	77836890	Schwarz criterion	16.68268
Log likelihood	-696.2418	Hannan-Quinn criter.	16.64807
Durbin-Watson stat	2.027217		

Inverted AR Roots	.41
-------------------	-----

D'après ces tableaux des critères des informations au-dessus, nous constatons que les coefficients de AR (1 ;0) significatives car la probabilité est inférieure de 0.05. Donc Le modèle (1,0) semble meilleur que les autres modèles, par ce que minimise les critères d'information AIC et SIC. Les autres modèles ne peuvent pas être utilisés pour la prévision.

5.9.3. Validation d'un model ARMA (p,q)

Introduction

Nous avons utilisé une méthode de Box-Jenkins pour générer un modèle **ARMA** (modèles *autorégressifs et moyenne mobile*) de la demande en eau qui est de permettre une prédiction de l'évolution future d'un phénomène et utilisé pour la validation des valeurs de production d'eau saisies mensuellement à l'aide d'outils des composantes principaux utilisés lors de la phase d'identification sont donc les tracés de la série, les corrélogrammes d'autocorrélation (FAC), et d'autocorrélation partielle (FACP) (Brockwell et Davis, 2013).

L'objectif de la modélisation est de déterminer combien de paramètres autorégressifs (p) et de moyennes mobiles (q) sont nécessaires pour obtenir un modèle effectif et parcimonieux du processus (CAMPBELL et ADAMSON, 2006). L'analyse des résidus de l'ARMA constitue un test important du modèle. La méthode proposée est testée sur un jeu de données de production des ressources en eau.

Après avoir estimé les différents processus ARMA, il convient à présent de valider ces modèles, en servant d'une part, des tests de significativité des paramètres (test de student, les tests d'hypothèse nulle d'autocorrélation pour les résidus (test de Ljung-Box, test de normalité) (Daudin, Robin et Trecourt ,1996). L'étape de validation du modèle consiste à tester si les résidus sont de bruits blancs. Au cas les résidus sont de bruits blancs ; il faudra que la série de résidus soit stationnaire (fluctuant autour d'une moyenne constante nulle).

La validation du modèle c'est simplement l'analyse des résidus

Cette phase consiste à faire des tests de validation qui sont comme suite :

Tests statistiques de validation du modèle :

Après avoir estimé les paramètres p et q d'un modèle ARMA, Il convient alors d'estimer les paramètres processus ARMA avec moins de retards (ou d'autres types de retards).

Cette étape consiste à faire des tests de validation qui sont comme suite :

Test de significativité :

- **Test de Student** Dans cette étape on teste la signification des coefficients des modèles au seuil de 5% (on compare la statistique calculée avec la statistique tabulée le coefficient de student (1.96)). Le test de Student des paramètres permet de vérifier que les paramètres sont bien significatifs. Si/ $t\text{-stat} > 1.96$ donc ce modèle sera candidat à être valider
- **Test de L-Jung box** (test d'absence d'autocorrélation des résidus),

La statistique Ljung-Box Q permet de déterminer si une série d'observations dans le temps sont aléatoires et indépendantes. Pour tester l'absence d'autocorrélation de et, il est possible d'utiliser la statistique de Box & Pierce (Q) ou la statistique de Ljung& Box (Q.stat) définies par :

$$Q.stat = n(n+2) \frac{\sum_{t-q}^k I(t)^2}{n-k}$$

H0 : le résidu est un bruit blanc [(Q.Stat < Khideux(k-p-q)] : **Absence d'autocorrélation.**

H1 : Le résidu n'est pas un bruit blanc [(Q.Stat > Khideux(k-p-q)] : **existence d'autocorrélation.**

K : $N/4 = 84/4 = 21$

P : l'ordre d'autorégressive

q : l'ordre de moyenne mobile

3.1.2. Tests de normalité

Pour vérifier si le processus des résidus, plusieurs tests peuvent être utilisés, mais le test le plus courant est celui de Jarque et Bera. Ce dernier est fondé sur la notion de skewness et de Kurtosis et vérifier les indices de skewness et de Kurtosis

➤ Teste de Normalité des résidus du modèles :

- **Test de Skewness**

H0 : $\gamma_1 = 0$ (La distribution des résidus est symétrique)

H1 : $\gamma_1 \neq 0$ (La distribution des résidus est asymétrique)

$$v_1 = \frac{|\beta_1^{1/2} - 0|}{\sqrt{6/n}}$$

- **Test de Kurtosis (aplatissement)**

H0 : $\gamma_1 = 0$ (La distribution des résidus est relativement aplatie)

H1 : $\gamma_1 \neq 0$ (La distribution des résidus n'est pas aplatie)

$$\gamma_1 = |\beta_1 - 3| / \sqrt{(24/n)}$$

- **Test de Jarque et Berra**

H0 : Les résidus sont normaux

H1 : Absence de normalité des résidus

La statistique S

$$S = \frac{N}{6} \beta_1 + \frac{N}{24} (\beta_2 - 3)^2$$

Champ Captant Oued El Hai

Forage F1

Tableau .5.95. Corrélogramme des résidus ARMA(3,3)


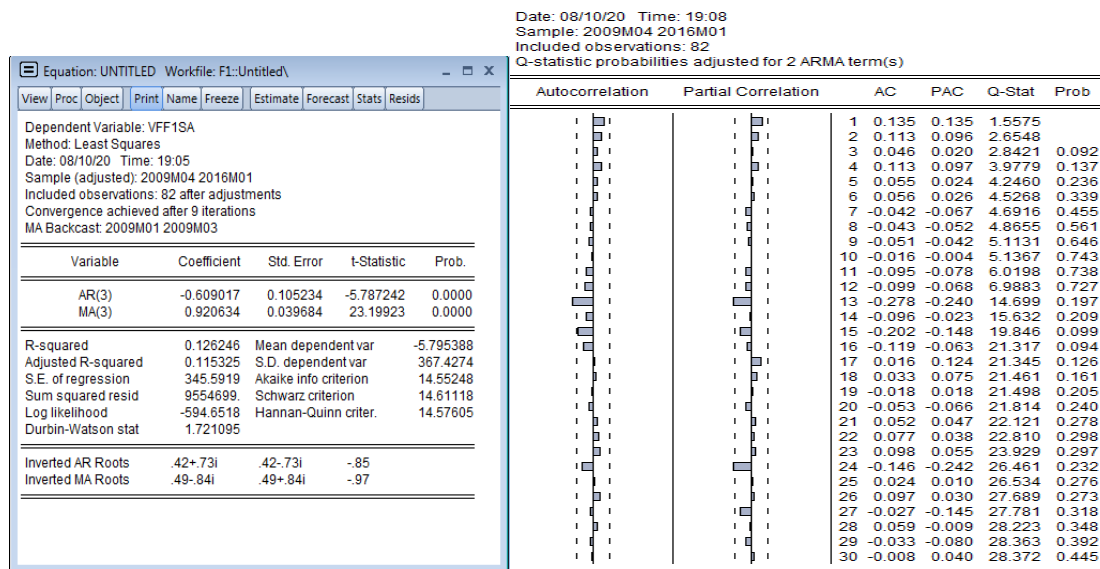


Figure 5-39 Histogramme du résidu




Figure 5-40 Graphe résiduel

Forage F4

Tableau.5.96. Corrélograme des résidus ARMA(0,2)

Date: 08/10/20 Time: 22:47
 Sample: 2009M01 2016M01
 Included observations: 85
 Q-statistic probabilities adjusted for 1 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.192	0.192	3.2340	
		2	-0.097	-0.139	4.0690	0.044
		3	0.017	0.069	4.0962	0.129
		4	0.005	-0.029	4.0985	0.251
		5	0.237	0.268	9.2887	0.054
		6	0.144	0.030	11.226	0.047
		7	0.027	0.064	11.295	0.080
		8	0.015	-0.007	11.318	0.125
		9	0.144	0.180	13.338	0.101
		10	0.065	-0.068	13.760	0.131
		11	0.089	0.117	14.560	0.149
		12	-0.011	-0.122	14.572	0.203
		13	-0.076	-0.004	15.160	0.233
		14	0.130	0.047	16.913	0.203
		15	-0.048	-0.136	17.156	0.248
		16	-0.027	-0.008	17.234	0.305
		17	-0.021	-0.072	17.281	0.368
		18	0.002	0.061	17.282	0.435
		19	0.039	-0.051	17.449	0.492
		20	0.025	0.070	17.520	0.555
		21	0.009	-0.005	17.529	0.618
		22	-0.016	0.067	17.560	0.677
		23	0.067	0.030	18.099	0.700
		24	-0.121	-0.122	19.874	0.650
		25	-0.030	0.025	19.987	0.698
		26	-0.113	-0.191	21.586	0.659
		27	-0.121	-0.023	23.444	0.608
		28	0.056	-0.060	23.857	0.638
		29	-0.120	-0.096	25.745	0.587
		30	-0.067	-0.038	26.357	0.606


Equation: UNTITLED Workfile: UNTITLED::Untitled\

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: VFF4SA
 Method: Least Squares
 Date: 08/10/20 Time: 22:43
 Sample: 2009M01 2016M01
 Included observations: 85
 Convergence achieved after 8 iterations
 MA Backcast: 2008M11 2008M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.435798	0.097659	4.462465	0.0000

R-squared	0.111103	Mean dependent var	-2.11E-09
Adjusted R-squared	0.111103	S.D. dependent var	468.8541
S.E. of regression	442.0418	Akaike info criterion	15.03238
Sum squared resid	16413683	Schwarz criterion	15.06112
Log likelihood	-637.8762	Hannan-Quinn criter.	15.04394
Durbin-Watson stat	1.593499		



Series: Residuals
 Sample 2009M02 2016M01
 Observations 84

Mean	9.319983
Median	18.85450
Maximum	1704.580
Minimum	-1107.795
Std. Dev.	485.3702
Skewness	0.374317
Kurtosis	3.771098
Jarque-Bera	4.042653
Probability	0.132480




Figure 5-31 Histogramme du résidu

Figure 5-32 Graphe résiduel

Champ Captant Interne (Biskra Centre)

Forage Hakim Saadane

Tableau.5.97.Corrélograme des résidus ARMA(1,1)


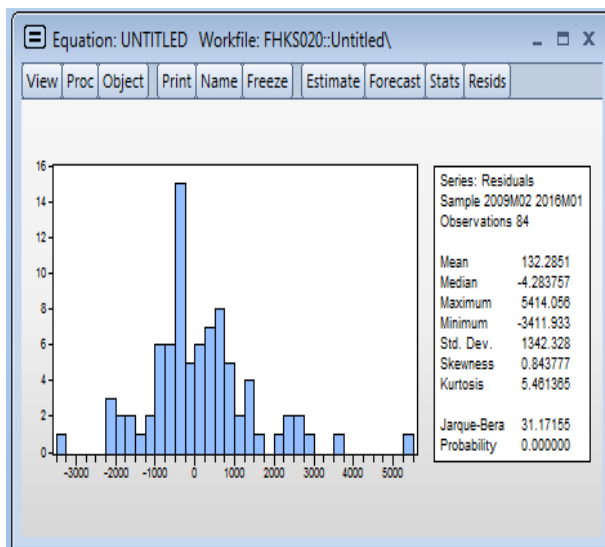
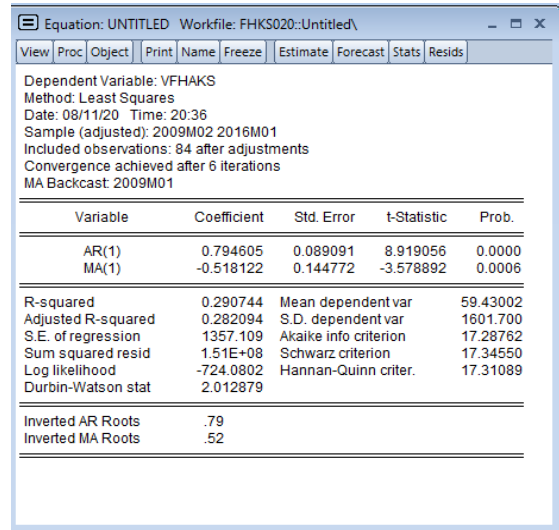



Figure 5-33 Histogramme du résidu

Figure5-34 Graphe résiduel

D'après le corrélogramme du résidu, les termes d'autocorrélation simple et partielle sont l'intérieur de l'intervalle de confiance sauf le 13^{ème} est significative et la probabilité ($p < 5\%$). Donc le résidu n'est pas un bruit blanc, alors le modèle AR(1) n'est pas validé. On doit confirmer par le test de bruit blanc.

Forage Ras El-gueria N°02\$

Tableau.5.98.Corrélograme des résidus ARMA(1,0)

Date: 08/11/20 Time: 17:13
 Sample: 2009M02 2016M01
 Included observations: 84
 Q-statistic probabilities adjusted for 1 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.005	-0.005	0.0025	
		2 0.062	0.062	0.3387	0.561
		3 -0.032	-0.032	0.4306	0.806
		4 -0.034	-0.039	0.5370	0.911
		5 0.027	0.031	0.6055	0.962
		6 0.171	0.176	3.3097	0.652
		7 -0.070	-0.077	3.7667	0.708
		8 -0.092	-0.121	4.5794	0.711
		9 -0.065	-0.044	4.9857	0.759
		10 0.029	0.060	5.0697	0.828
		11 -0.220	-0.249	9.8666	0.452
		12 -0.124	-0.195	11.414	0.409
		13 -0.111	-0.054	12.658	0.394
		14 0.032	0.098	12.763	0.466
		15 0.082	0.068	13.474	0.490
		16 0.011	-0.051	13.486	0.565
		17 -0.085	-0.016	14.259	0.579
		18 -0.062	0.001	14.683	0.618
		19 -0.003	-0.028	14.685	0.684
		20 0.049	-0.069	14.957	0.725
		21 -0.116	-0.199	16.487	0.686
		22 0.130	0.123	18.450	0.620
		23 -0.005	0.032	18.454	0.679
		24 -0.118	-0.259	20.141	0.633
		25 0.005	-0.084	20.144	0.689
		26 -0.127	-0.020	22.137	0.628
		27 0.004	0.119	22.139	0.681
		28 0.082	-0.033	23.008	0.685
		29 0.061	-0.068	23.491	0.708
		30 -0.133	-0.126	25.847	0.634

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.212828	0.108340	1.964451	0.0528
R-squared	0.044296	Mean dependent var		-37.22021
Adjusted R-squared	0.044296	S.D. dependent var		3167.719
S.E. of regression	3096.766	Akaike info criterion		18.92594
Sum squared resid	7.96E+08	Schwarz criterion		18.95488
Log likelihood	-793.8894	Hannan-Quinn criter.		18.93757
Durbin-Watson stat	1.991411			
Inverted AR Roots	.21			




Figure5-35 Histogramme du résidu




Figure 5-36 Graphe résiduel

Forage 1^{er} Novembre

Tableau.5.99.Corrélograme des résidus ARMA(1,0)


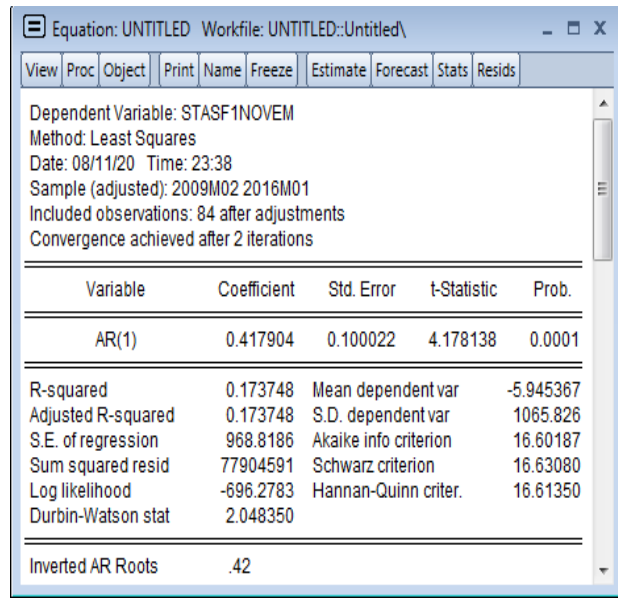



Figure 5-37 Histogramme du résidu




Figure 5-38 Graphe résiduel

5.10 Résultats et Interprétation

D'après les corrélogrammes des résidus :

Forage F1 ; Le corrélogramme du résidu ne fait apparaître aucun terme en dehors de l'intervalle de confiance au seuil $\alpha = 5\%$ (aucun terme n'est significatif) et la statistique de Ljung-Box $Q = 28.372$ est inférieure à la valeur tabulée du khi-deux à 28 degrés de liberté (41.337), on accepte donc l'hypothèse nulle de non autocorrélation du résidu ce qui implique que le résidu peut être assimilé à un bruit blanc.

Forage F4 ; Le corrélogramme du résidu ne fait apparaître aucun terme en dehors de l'intervalle de confiance au seuil $\alpha = 5\%$ (aucun terme n'est significatif) et la statistique de Ljung-Box $Q = 26.357$ est inférieure à la valeur tabulée du khi-deux à 29 degrés de liberté (42.557), on accepte donc l'hypothèse nulle de non autocorrélation du résidu ce qui implique que le résidu peut être assimilé à un bruit blanc.

Forage Hakim saadane ; D'après le corrélogramme du résidu, un terme (13^{ème}) d'autocorrélation simple et partielle sont en dehors de l'intervalle de confiance, probabilités ($p < 5\%$). Donc le résidu n'est pas un bruit blanc, alors le modèle ARMA (1 ;1) n'est pas validé. On doit confirmer par le test de bruit blanc.

Forage Ras El-gueria N°02 ; Le corrélogramme du résidu ne fait apparaître aucun terme en dehors de l'intervalle de confiance au seuil $\alpha = 5\%$ (aucun terme n'est significatif) et la statistique de Ljung-Box $Q = 25.847$ est inférieure à la valeur tabulée du khi-deux à 29 degrés de liberté (42.557), on accepte donc l'hypothèse nulle de non autocorrélation du résidu ce qui implique que le résidu peut être assimilé à un bruit blanc.

Forage 1^{er} Novembre ; ; D'après le corrélogramme du résidu, un terme (12^{ème}) d'autocorrélation simple et partielle sont en dehors de l'intervalle de confiance, probabilités ($p < 5\%$). Donc le résidu n'est pas un bruit blanc, alors le modèle ARMA (1) n'est pas validé. On doit confirmer par le test de bruit blanc.

Les résultats des tests de normalité

Modèle	Test de L-Jung box $Q.stat = n(n+2) \frac{\sum_{i=0}^k J(t)^2}{n-k}$	Test skewness $v1 = \frac{ \beta1^{1/2} - 0 }{\sqrt{6/n}}$	Test de Kurtosis $v2 = \beta2 - 3 /\sqrt{(24/n)}$	Test Jarque-Berra $S = \frac{N}{6}\beta1 + \frac{N}{24}(\beta2 - 3)^2$
ARMA(3 ;3) FF1	28.372	2.02	1.02	2.2896
MA(2) FF4	26.357	2.28	1.44	4.042
ARMA(1 ;1) FHAKS	39.017	3.43	4.60	31.17
AR(1) FRASEL GUERIA	25.847	1.45	0.13	0.343
AR(1) F1NOVEM	44.503	1.69	0.37	0.727

Les résultats des tests de normalité

- kurtosis :

Forage F1 : 1.02 < 1.96

Forage F4 : 1.44 < 1.96

Forage Hakim saadane : 4.60 > 1.96

Forage Ras El-gueria : 0.13 < 1.96

Forage 1^{er} Novembre : 0.37 < 1.96

- Kewness :

Forage F1 : 2.02 > 1.96

Forage F4 : 2.28 > 1.96

Forage Hakim saadane : 3.43 > 1.96

Forage Ras El-gueria : 1.45 < 1.96

Forage 1^{er} Novembre : 1.69 < 1.96

- **La statistique de Jarque et Bera :**

Forage F1 : $S=2.289$ est inférieure à la valeur tabulée du khi-deux à 2 degrés de liberté $A = 5.991$ au seuil $\alpha = 5\%$ (la table de la loi du chi-deux, voir l'annexe). Donc notre résidu forme un bruit blanc normal.

Forage F4 : $S=4.042$ est inférieure à la valeur tabulée du khi-deux à 2 degrés de liberté $A = 5.991$ au seuil $\alpha = 5\%$. Donc notre résidu forme bien un bruit blanc normal.

Forage Hakim saadane : $S=31.17$ est supérieure à la valeur tabulée du khi-deux à 2 degrés de liberté $A = 5.991$ au seuil $\alpha = 5\%$. Donc notre résidu ne forme pas un bruit blanc normal.

Forage Ras El-gueria N°02 : $S=0.343$ est inférieure à la valeur tabulée du khi-deux à 2 degrés de liberté $A = 5.991$ au seuil $\alpha = 5\%$. Donc notre résidu forme bien un bruit blanc normal.

Forage 1^{er} Novembre : $S=0.727$ est inférieure à la valeur tabulée du khi-deux à 2 degrés de liberté $A = 5.991$ au seuil $\alpha = 5\%$. Donc notre résidu forme bien un bruit blanc normal.

L'hypothèse nulle de Jarque-Bera de normalité est rejetée ; également kurtosis (plus grand que 3) indique des queues grasses, c'est-à-dire non normales .

Conclusion

D'après les hypothèses des tests, les résidus forment un bruit blanc, le processus ARMA (1,0) de la série F1novem et le processus ARMA (1,0) de la série FRASELGUERIA est donc un bruit blanc normal. Le modèle **(1,0)** semble meilleur que les autres modèles.

L'hypothèse nulle de Jarque-Bera de normalité est rejetée H_0 ; également kurtosis (plus grand que 3) indique des queues grasses, c'est-à-dire non normales distribution.

On conclut que le modèle ARMA (1 ;0) de la série F1novem et ARMA (1 ;0) de la série FRASELGUERIA et F4(0 ;2) sont valides et s'écrit : ARMA (p, 0) ou AR(p) :

$$X_t = \phi_1 X_{t-1} + \varepsilon_t$$

$$\text{ARMA}(p, q) : x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}.$$

Prévision de modèle

Pour commencer la prévision il faudra changer le rang de ces séries.

Lorsque le modèle est validé, la prévision peut alors être calculée à un horizon h de quelques périodes, limité par la variance de l'erreur de prévision qui augmente rapidement avec l'horizon (**BEGUIN, GOURIEROUX and MONFORT, 1980**). Pour commencer la prévision, il faudra changer le rang de cette série (**LINEESH, MINU and JESSY JOHN, 2010**).

Nous allons prévoir l'évolution du processus AR(p) MA(q) à la période $t+h$. Nous avons synthétisé que la méthode de Box-Jenkins(1976) consiste à modéliser les séries temporelles au moyen de processus « ARMA ». Les modèles « ARMA » donnent souvent de bons résultats en prévision. La plupart du temps les séries chronologiques peuvent être décrites par deux grandes composantes : le trend et le mouvement saisonnier [73].

Champ Captant Oued El Hai

Forage F1

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	-0.609017	0.105234	-5.787242	0.0000
MA(3)	0.920634	0.039684	23.19923	0.0000
R-squared	0.126246	Mean dependent var		-5.795388
Adjusted R-squared	0.115325	S.D. dependent var		367.4274
S.E. of regression	345.5919	Akaike info criterion		14.55248
Sum squared resid	9554699	Schwarz criterion		14.61118
Log likelihood	-594.6518	Hannan-Quinn criter.		14.57605
Durbin-Watson stat	1.721095			
Inverted AR Roots	.42+.73i	.42-.73i		-.85
Inverted MA Roots	.49-.84i	.49+.84i		-.97

Notre modèle ARMA (3 ;3) se présentera ainsi :

$$Y_t = -0.6091Y_{t-3} - 0.920\epsilon_{t-3}$$

(0.105) (0.039)

Pour obtenir la prévision de la série brute (FF1) est la série **vff1saf** (voir l'annexe). On doit rajouter la moyenne et après on doit multiplier par le coefficient saisonniers (voir l'annexe).

$$vff1saf1=vff1saf+(1779.32885254 - 2.19304700148*\text{@trend})$$

Tableau 5.100. 2009M01 2030M01 // prevff1=vff1saf1*cvs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
2009													
FF1	2160.0	2003.0	1631.0	1654.0	1532.0	1909.0	1302.0	1423.0	1547.0	1987.0	1236.0	1335.0	1643.3
PREVFF1	--	--	--	1811.3	1668.5	1692.4	1689.5	2111.3	1654.3	1787.4	1397.5	2291.1	1789.2
2010													
FF1	1854.0	1722.0	1080.0	1363.0	1100.0	1400.0	1545.0	2704.0	1945.0	2108.0	1955.0	2539.0	1776.3
PREVFF1	1820.6	1827.9	1559.2	1924.5	1653.7	1477.6	1594.7	2072.1	1773.4	1809.6	1379.7	2152.2	1753.8
2011													
FF1	1843.0	1705.0	2173.0	2528.0	1972.0	1990.0	1941.0	2831.0	1957.0	1332.0	983.0	2553.0	1984.0
PREVFF1	1764.4	1797.9	1583.4	1914.7	1630.2	1429.3	1561.0	2039.7	1766.3	1788.8	1359.1	2105.1	1728.3
2012													
FF1	1264.0	1461.0	1542.0	1685.0	1264.0	1461.0	1522.0	1685.0	1900.0	1974.0	1209.0	2896.0	1655.3
PREVFF1	1733.5	1770.1	1565.7	1888.1	1605.4	1403.8	1535.7	2008.2	1741.8	1762.2	1338.2	2070.6	1701.9
2013													
FF1	1666.0	2100.0	1987.0	1122.0	1860.0	1061.0	1534.0	1616.0	1620.0	1440.0	1234.0	1371.0	1550.9
PREVFF1	1706.1	1742.7	1542.3	1859.1	1580.4	1381.4	1511.6	1976.8	1715.0	1734.7	1317.2	2037.8	1675.4
2014													
FF1	1800.0	2087.0	1036.0	1709.0	1961.0	1337.0	1530.0	1890.0	1454.0	1696.0	1490.0	1937.0	1660.6
PREVFF1	1679.2	1715.2	1518.2	1829.8	1555.5	1359.5	1487.6	1945.4	1687.8	1707.1	1296.3	2005.3	1648.9
2015													
FF1	1700.0	1306.0	1577.0	2791.0	1384.0	1189.0	1302.0	1478.0	1437.0	1408.0	1754.0	1747.0	1589.4
PREVFF1	1652.4	1687.8	1493.9	1800.5	1530.5	1337.6	1463.6	1914.1	1660.5	1679.5	1275.3	1972.8	1622.4
2016													
FF1	1903.0	--	--	--	--	--	--	--	--	--	--	--	1903.0
PREVFF1	1625.6	1660.4	1469.6	1771.2	1505.5	1315.7	1439.7	1882.7	1633.3	1651.9	1254.3	1940.3	1595.8
2017													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1598.8	1632.9	1445.2	1741.8	1480.5	1293.9	1415.7	1851.3	1606.1	1624.3	1233.3	1907.8	1569.3
2018													
2018													
2018													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1572.0	1605.5	1420.9	1712.5	1455.6	1272.0	1391.8	1820.0	1578.8	1596.7	1212.3	1875.3	1542.8
2019													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1545.1	1578.1	1396.6	1683.1	1430.6	1250.2	1367.8	1788.6	1551.6	1569.1	1191.3	1842.8	1516.2
2020													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1518.3	1550.6	1372.3	1653.8	1405.6	1228.3	1343.9	1757.3	1524.3	1541.5	1170.4	1810.3	1489.7
2021													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1491.5	1523.2	1348.0	1624.5	1380.6	1206.5	1319.9	1725.9	1497.1	1513.9	1149.4	1777.8	1463.2
2022													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1464.7	1495.8	1323.7	1595.1	1355.7	1184.6	1296.0	1694.5	1469.8	1486.4	1128.4	1745.2	1436.7
2023													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1437.9	1468.3	1299.4	1565.8	1330.7	1162.7	1272.0	1663.2	1442.6	1458.8	1107.4	1712.7	1410.1
2024													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1411.0	1440.9	1275.1	1536.4	1305.7	1140.9	1248.1	1631.8	1415.3	1431.2	1086.4	1680.2	1383.6
2025													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1384.2	1413.5	1250.7	1507.1	1280.7	1119.0	1224.1	1600.4	1388.1	1403.6	1065.5	1647.7	1357.1
2026													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1357.4	1386.0	1226.4	1477.7	1255.8	1097.2	1200.2	1569.1	1360.8	1376.0	1044.5	1615.2	1330.5
2027													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1330.6	1358.6	1202.1	1448.4	1230.8	1075.3	1176.2	1537.7	1333.6	1348.4	1023.5	1582.7	1304.0
2028													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1303.8	1331.2	1177.8	1419.1	1205.8	1053.4	1152.3	1506.3	1306.3	1320.8	1002.5	1550.2	1277.5
2029													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF1	1276.9	1303.8	1153.5	1389.7	1180.8	1031.6	1128.3	1475.0	1279.1	1293.2	981.5	1517.7	1250.9
2030													
FF1	--	--	--	--	--	--	--	--	--	--	--	--	--


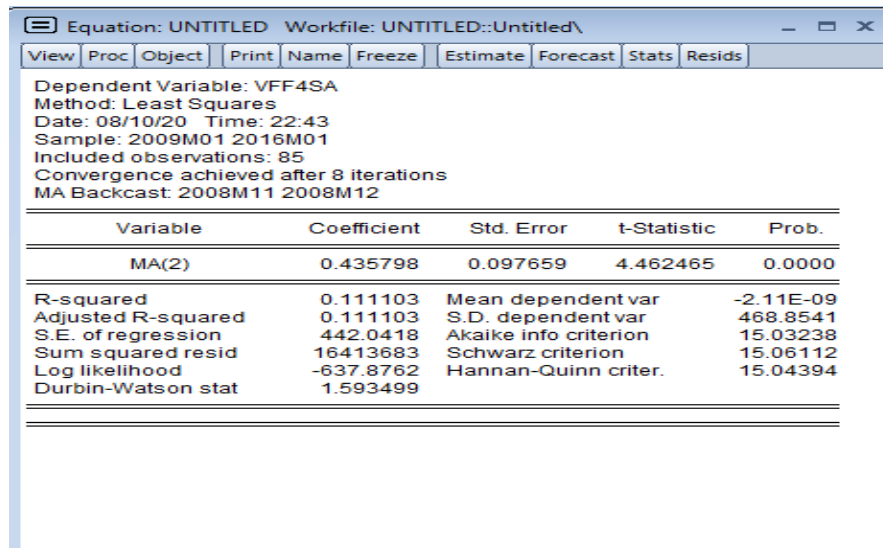


Figure 5-39 Les prévisions du modèle (FF1)

L'observation des graphiques montre bien que les variables de la valeur observé (données de production d'eau potable) sont collées avec celle de la variable projetée (prédite)(PREVFF1) et que le résidu se comporte maintenant comme un bruit blanc

Forage F4



Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.435798	0.097659	4.462465	0.0000
R-squared	0.111103	Mean dependent var	-2.11E-09	
Adjusted R-squared	0.111103	S.D. dependent var	468.8541	
S.E. of regression	442.0418	Akaike info criterion	15.03238	
Sum squared resid	16413683	Schwarz criterion	15.06112	
Log likelihood	-637.8762	Hannan-Quinn criter.	15.04394	
Durbin-Watson stat	1.593499			

Notre modèle ARMA(0 ;2) se présentera ainsi :

$$Y_t = -0.435\epsilon_{t-2}$$

(0.097)

Pour obtenir la prévision de la série brute(FF4) est la série **vff4saf** (voir l'annexe).on doit rajouter la moyenne et après on doit multiplier par le coefficient saisonniers (voir l'annexe).

$$vff4saf4=vff4saf+(3885.71053354-27.0374715502* @trend)$$

Tableau 5.105. 2009M01 2030M01 // prevff4=vff4saf4*cvs

Tableau 5.101. 2009M01 2030M01 // prevff4=vff4saf4*cvs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
	2009												2009
FF4	3200.0	5423.0	4833.0	4488.0	4422.0	3355.0	4355.0	4954.0	3842.0	3862.0	3788.0	3249.0	4147.6
PREVFF4	--	4037.8	3863.7	3758.3	3566.4	3692.1	3701.8	3859.1	3490.7	3982.0	3405.6	3274.7	3693.9
	2010												2010
FF4	3995.0	4601.0	3690.0	3189.0	3000.0	3513.0	3090.0	3477.0	2899.0	3032.0	2928.0	2083.0	3291.4
PREVFF4	3666.1	3913.3	3590.7	3452.2	3263.8	3373.8	3379.6	3520.5	3182.1	3627.3	3100.0	2978.7	3420.7
	2011												2011
FF4	3566.0	3279.0	3393.0	3412.0	2830.0	2826.0	2086.0	2916.0	2367.0	2943.0	2366.0	2532.0	2876.3
PREVFF4	3332.1	3554.1	3258.5	3130.3	2957.2	3054.3	3057.0	3181.7	2873.4	3272.6	2794.3	2682.6	3095.7
	2012												2012
FF4	2949.0	2331.0	2996.0	2455.0	2524.0	2515.0	2146.0	2094.0	2538.0	2997.0	2424.0	2831.0	2566.7
PREVFF4	2998.1	3194.8	2926.4	2808.5	2650.5	2734.8	2734.4	2843.0	2564.8	2917.9	2488.7	2386.5	2770.7
	2013												2013
FF4	2125.0	2652.0	2422.0	1550.0	2300.0	1554.0	2494.0	2760.0	2188.0	2631.0	2600.0	2189.0	2288.8
PREVFF4	2664.1	2835.6	2594.2	2486.6	2343.8	2415.3	2411.8	2504.3	2256.1	2563.2	2183.1	2090.4	2445.7
	2014												2014
FF4	2802.0	2833.0	2109.0	2209.0	2094.0	2211.0	2413.0	2021.0	2162.0	2470.0	1547.0	1798.0	2222.4
PREVFF4	2330.1	2476.3	2262.0	2164.8	2037.2	2095.8	2089.2	2165.5	1947.5	2208.5	1877.5	1794.3	2120.7
	2015												2015
FF4	1548.0	2196.0	1696.0	2490.0	1788.0	2443.0	2470.0	1177.0	1364.0	1966.0	2160.0	2501.0	1983.3
PREVFF4	1996.1	2117.1	1929.8	1843.0	1730.5	1776.3	1766.6	1826.8	1638.8	1853.8	1571.8	1498.2	1795.7
	2016												2016
FF4	1855.0	--	--	--	--	--	--	--	--	--	--	--	1855.0
PREVFF4	1662.1	1757.8	1597.7	1521.1	1423.8	1456.8	1444.0	1488.1	1330.2	1499.1	1266.2	1202.1	1470.7
	2017												2017
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	1328.1	1398.6	1265.5	1199.3	1117.2	1137.3	1121.4	1149.3	1021.5	1144.4	960.6	906.0	1145.8
	2018												2018
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	994.1	1039.3	933.3	877.4	810.5	817.8	798.8	810.6	712.9	789.7	655.0	609.9	820.8
	2019												2019
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	660.1	680.1	601.1	555.6	503.8	498.3	476.2	471.9	404.2	435.0	349.3	313.8	495.8
	2020												2020
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	326.1	320.8	268.9	233.8	197.2	178.8	153.7	133.1	95.6	80.3	43.7	17.7	170.8
	2021												2021
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-7.9	-38.4	-63.2	-88.1	-109.5	-140.7	-168.9	-205.6	-213.1	-274.4	-261.9	-278.4	-154.2
	2022												2022
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-341.9	-397.7	-395.4	-409.9	-416.2	-460.2	-491.5	-544.4	-521.7	-629.1	-567.6	-574.5	-479.2
	2023												2023
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-675.9	-757.0	-727.6	-731.8	-722.8	-779.7	-814.1	-883.1	-830.4	-983.8	-873.2	-870.6	-804.2
	2024												2024
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-1009.9	-1116.2	-1059.8	-1053.6	-1029.5	-1099.2	-1136.7	-1221.8	-1139.0	-1338.6	-1178.8	-1166.7	-1129.2
	2025												2025
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-1343.9	-1475.5	-1391.9	-1375.4	-1336.2	-1418.7	-1459.3	-1560.6	-1447.7	-1693.3	-1484.4	-1462.8	-1454.1
	2026												2026
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-1677.9	-1834.7	-1724.1	-1697.3	-1642.8	-1738.2	-1781.9	-1899.3	-1756.3	-2048.0	-1790.1	-1758.9	-1779.1
	2027												2027
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-2011.9	-2194.0	-2056.3	-2019.1	-1949.5	-2057.7	-2104.5	-2238.0	-2065.0	-2402.7	-2095.7	-2055.0	-2104.1
	2028												2028
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-2345.9	-2553.2	-2388.5	-2341.0	-2256.2	-2377.2	-2427.1	-2576.8	-2373.6	-2757.4	-2401.3	-2351.1	-2429.1
	2029												2029
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	-2679.9	-2912.5	-2720.6	-2662.8	-2562.8	-2696.7	-2749.7	-2915.5	-2682.3	-3112.1	-2706.9	-2647.2	-2754.1
	2030												2030
FF4	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVFF4	--	--	--	--	--	--	--	--	--	--	--	--	--




Figure 5-50 Les prévisions du modèle (FF4)

Champ Captant Interne (Biskra Centre)

Forage Hakim saadane

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.794605	0.089091	8.919056	0.0000
MA(1)	-0.518122	0.144772	-3.578892	0.0006
R-squared	0.290744	Mean dependent var		59.43002
Adjusted R-squared	0.282094	S.D. dependent var		1601.700
S.E. of regression	1357.109	Akaike info criterion		17.28762
Sum squared resid	1.51E+08	Schwarz criterion		17.34550
Log likelihood	-724.0802	Hannan-Quinn criter.		17.31089
Durbin-Watson stat	2.012879			
Inverted AR Roots	.79			
Inverted MA Roots	.52			

Notre modèle ARMA(1 ;1) se présentera ainsi :

$$Y_t = 0.794Y_{t-1} + 0.518\epsilon_{t-1}$$

(0.089) (0.144)

Pour obtenir la prévision de la série brute (FF4) est la série VFHAKSF (voir l'annexe). on doit rajouter la moyenne et après on doit multiplier par le coefficient saisonniers

$$fhaksff = vfhaksf + (16098.2603114 - 93.943445274 * @trend)$$

Tableau 5.102. 2009M01 2030M01 // prevhaks=fhaksff*cvs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
	2009												2009
FHAKS	11171	12938	15844	14562	13678	13158	13248	13444	13548	13167	18993	17369	14260
PREVHAKS	--	12469	14152	14763	15786	14185	13681	12910	12736	12955	15024	15460	14011
	2010												2010
FHAKS	16655	16715	16640	18211	15086	15110	12475	17326	15699	12359	15488	17889	15804
PREVHAKS	14756	14922	15993	15975	16522	14468	13674	12698	12368	12454	14327	14647	14400
	2011												2011
FHAKS	18000	13669	17150	14587	15687	13870	12870	11587	11870	12847	13085	13309	14044
PREVHAKS	13905	14001	14952	14892	15364	13425	12666	11744	11424	11489	13203	13484	13379
	2012												2012
FHAKS	12412	13635	13540	16575	14560	13546	11655	11443	10555	10454	10894	11670	12578
PREVHAKS	12789	12866	13729	13663	14085	12299	11594	10743	10442	10495	12051	12298	12255
	2013												2013
FHAKS	10458	12324	12444	11524	14848	11524	13341	7560	7655	8557	8655	9857	10729
PREVHAKS	11657	11718	12495	12425	12799	11167	10519	9739	9459	9498	10897	11112	11124
	2014												2014
FHAKS	9038	8631	10513	10484	11508	8956	8338	7486	7493	8519	9831	8786	9132
PREVHAKS	10523	10569	11259	11186	11512	10035	9444	8735	8475	8501	9744	9925	9992
	2015												2015
FHAKS	8574	9620	9540	8790	9417	8600	8339	8789	9046	8905	9342	9475	9036
PREVHAKS	9389	9420	10024	9947	10225	8903	8368	7730	7491	7505	8590	8738	8861
	2016												2016
FHAKS	9334	--	--	--	--	--	--	--	--	--	--	--	9334
PREVHAKS	8255	8270	8788	8709	8939	7770	7292	6726	6507	6508	7437	7552	7729
	2017												2017
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	7121	7121	7553	7470	7652	6638	6217	5722	5523	5511	6283	6365	6598
	2018												2018
	2019												2019
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	5987	5972	6317	6231	6365	5506	5141	4717	4539	4515	5130	5178	5467
	2020												2020
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	4853	4823	5082	4992	5078	4374	4066	3713	3555	3518	3976	3991	4335
	2021												2021
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	3719	3674	3847	3754	3792	3242	2990	2708	2571	2522	2823	2805	3204
	2022												2022
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	2585	2524	2611	2515	2505	2110	1915	1704	1587	1525	1669	1618	2072
	2023												2023
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	1452	1375	1376	1276	1218	978	839	700	604	528	515	431	941
	2024												2024
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	318	226	140	37	-68	-155	-237	-305	-380	-468	-638	-755	-190
	2025												2025
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-816	-923	-1095	-1201	-1355	-1287	-1312	-1309	-1364	-1465	-1792	-1942	-1322
	2026												2026
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-1950	-2072	-2331	-2440	-2642	-2419	-2388	-2313	-2348	-2462	-2945	-3129	-2453
	2027												2027
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-3084	-3221	-3566	-3679	-3929	-3551	-3463	-3318	-3332	-3458	-4099	-4316	-3585
	2028												2028
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-4218	-4371	-4802	-4918	-5215	-4683	-4539	-4322	-4316	-4455	-5252	-5502	-4716
	2029												2029
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-5352	-5520	-6037	-6157	-6502	-5815	-5614	-5326	-5300	-5452	-6406	-6689	-5847
	2030												2030
FHAKS	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVHAKS	-6486	-6669	-7273	-7395	-7789	-6947	-6690	-6331	-6284	-6448	-7560	-7876	-6979
	2030												2030

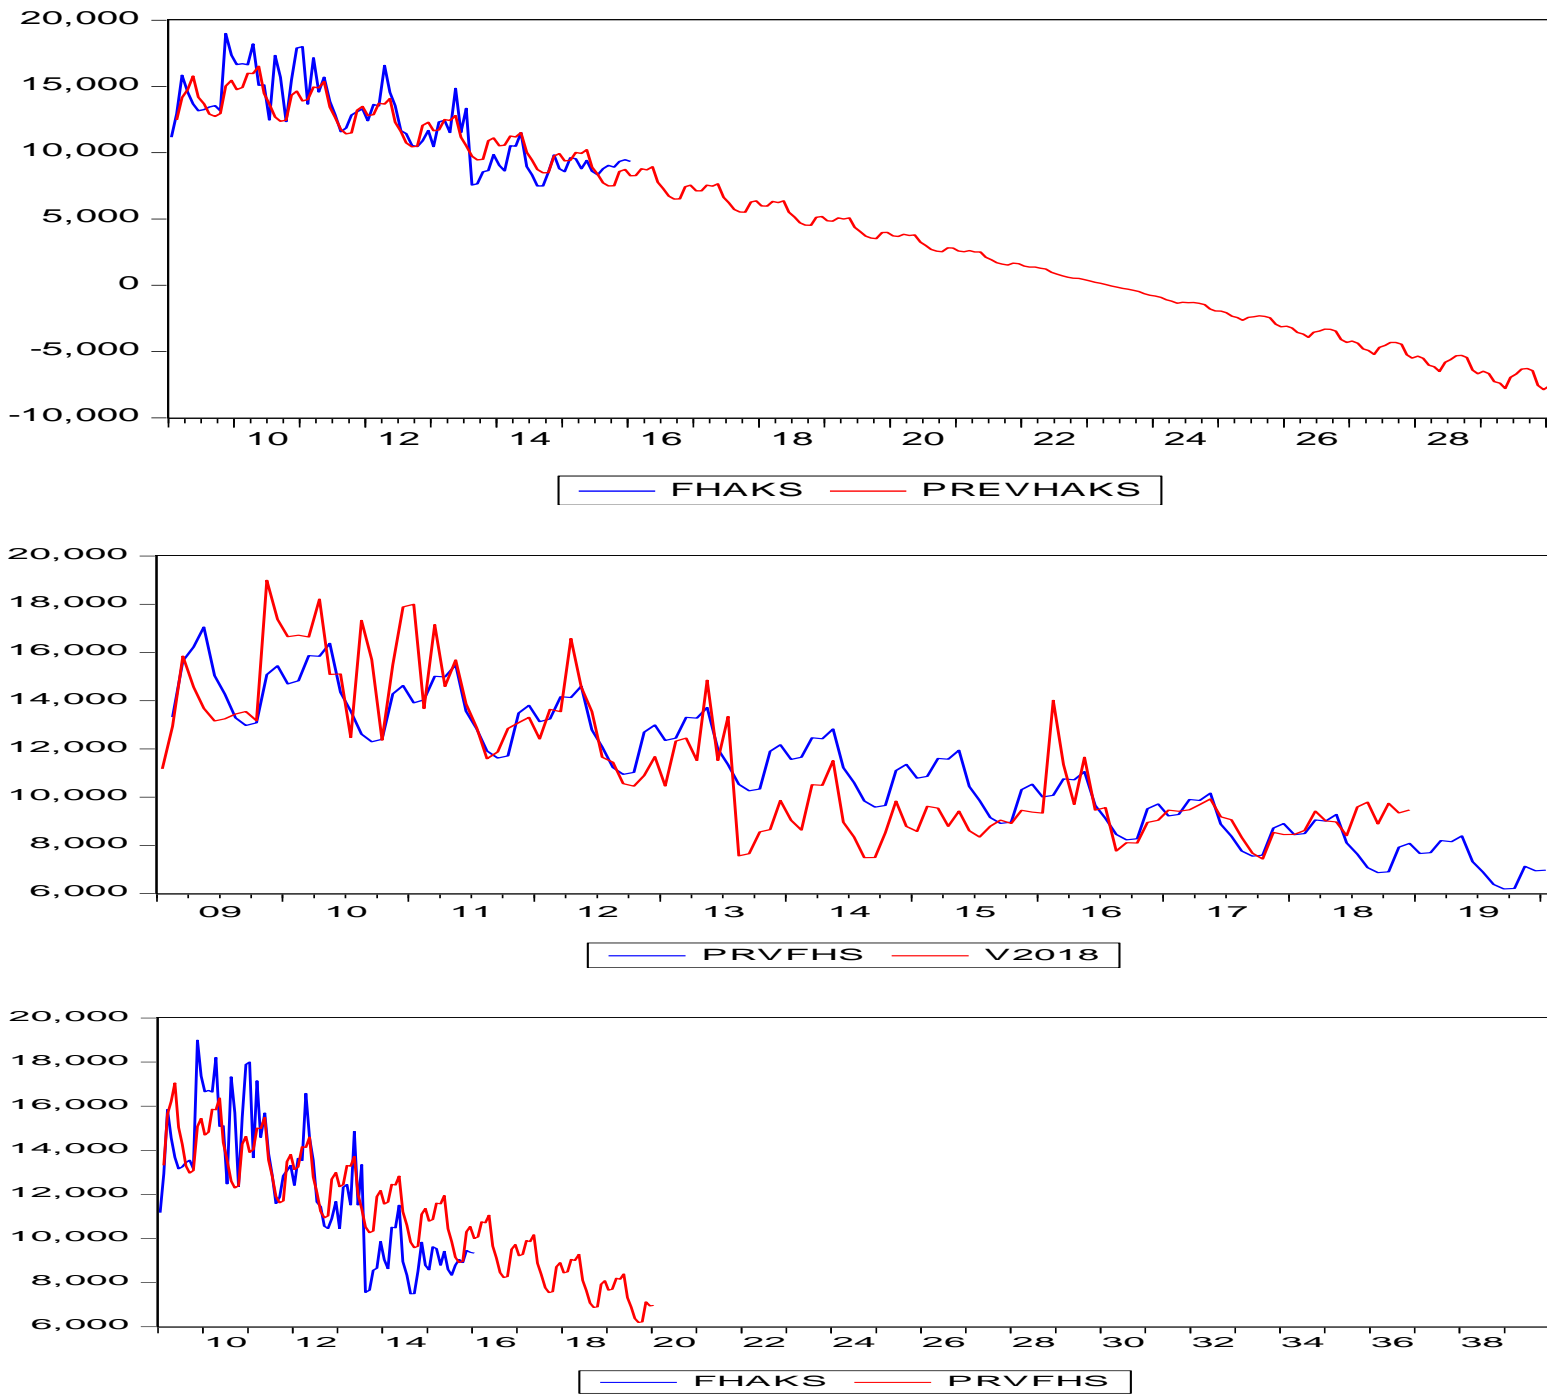


Figure 5-51 Les prévisions du modèle (F Hakim Saadane)

FORAGE RAS ELGUERIA

Equation: UNTITLED Workfile: UNTITLED::Untitled\									
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: FRGS									
Method: Least Squares									
Date: 08/11/20 Time: 17:07									
Sample (adjusted): 2009M02 2016M01									
Included observations: 84 after adjustments									
Convergence achieved after 2 iterations									
Variable	Coefficient	Std. Error	t-Statistic	Prob.					
AR(1)	0.212828	0.108340	1.964451	0.0528					
R-squared	0.044296	Mean dependent var	-37.22021						
Adjusted R-squared	0.044296	S.D. dependent var	3167.719						
S.E. of regression	3096.766	Akaike info criterion	18.92594						
Sum squared resid	7.96E+08	Schwarz criterion	18.95488						
Log likelihood	-793.8894	Hannan-Quinn criter.	18.93757						
Durbin-Watson stat	1.991411								
Inverted AR Roots	.21								

Notre modèle ARMA(1 ;0) se présentera ainsi :

$$Y_t = 0.212Y_{t-1}$$

(0.108)

Pour obtenir la prévision de la série brute (FF4) est la série **FRGSF (voir l'annexe)**. On doit rajouter la moyenne et après on doit multiplier par le coefficient saisonniers (voir l'annexe).

$$\text{frgsff} = \text{frgsf} + (14451.0840692 + 30.1525565912 * @\text{trend})$$

Tableau.5.103. 2009M01 2030M01 // prevrsg=frgsff*cvs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
	2009												2009
FRASELG	16459	12418	12592	13199	18456	16305	19083	12820	13996	13929	17513	10590	14780
PREVRSG	--	13247	16285	12047	16509	14153	17230	13979	15899	15905	14918	13487	14878
	2010												2010
FRASELG	10627	12568	19858	12018	18200	10125	18794	10866	19701	18478	12828	11463	14627
PREVRSG	13870	12981	16530	12321	16912	14502	17656	14324	16291	16296	15284	13817	15065
	2011												2011
FRASELG	10982	10979	11193	10655	18597	11486	18975	12956	19875	17512	19066	18705	15082
PREVRSG	14209	13298	16932	12620	17321	14853	18082	14668	16682	16687	15650	14147	15429
	2012												2012
FRASELG	19211	19744	19988	10109	21234	17698	19132	24191	12230	12991	14950	14599	17173
PREVRSG	14548	13614	17334	12919	17731	15204	18508	15013	17074	17078	16016	14478	15793
	2013												2013
FRASELG	15063	14971	15844	13545	15180	15479	16651	18059	19052	18569	12336	12813	15630
PREVRSG	14887	13931	17736	13219	18141	15554	18934	15358	17465	17469	16382	14808	16157
	2014												2014
FRASELG	14780	14568	19665	13547	15214	18975	16542	10254	15546	19254	18597	18705	16304
PREVRSG	15225	14247	18138	13518	18551	15905	19360	15703	17857	17860	16748	15138	16521
	2015												2015
FRASELG	18831	10001	19211	19456	19688	19744	19797	19855	19988	20446	10843	10109	17331
PREVRSG	15564	14564	18540	13817	18961	16256	19786	16048	18248	18251	17114	15468	16885
	2016												2016
FRASELG	11155	--	--	--	--	--	--	--	--	--	--	--	11155
PREVRSG	15903	14880	18943	14116	19370	16606	20212	16393	18640	18641	17479	15798	17249
	2017												2017
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	16242	15197	19345	14415	19780	16957	20639	16738	19031	19032	17845	16128	17612
	2018												2018
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	16581	15513	19747	14714	20190	17308	21065	17083	19423	19423	18211	16458	17976
	2019												2019
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	16920	15829	20149	15013	20600	17659	21491	17428	19815	19814	18577	16788	18340
	2020												2020
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	17258	16146	20551	15313	21009	18009	21917	17773	20206	20205	18943	17119	18704
	2021												2021
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	17597	16462	20953	15612	21419	18360	22343	18118	20598	20596	19309	17449	19068
	2022												2022
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	17936	16779	21355	15911	21829	18711	22769	18463	20989	20987	19675	17779	19432
	2023												2023
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	18275	17095	21757	16210	22239	19061	23195	18808	21381	21378	20041	18109	19796
	2024												2024
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	18614	17412	22160	16509	22648	19412	23621	19153	21772	21769	20407	18439	20160
	2025												2025
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	18952	17728	22562	16808	23058	19763	24047	19498	22164	22160	20772	18769	20523
	2026												2026
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	19291	18045	22964	17107	23468	20113	24473	19843	22555	22550	21138	19099	20887
	2027												2027
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	19630	18361	23366	17407	23878	20464	24899	20188	22947	22941	21504	19429	21251
	2028												2028
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	19969	18677	23768	17706	24287	20815	25325	20533	23339	23332	21870	19760	21615
	2029												2029
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	20308	18994	24170	18005	24697	21165	25751	20878	23730	23723	22236	20090	21979
	2030												2030
FRASELG	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVRSG	20646	--	--	--	--	--	--	--	--	--	--	--	20646




Figure 5-40 Les prévisions du modèle (F Raselgueria 02)

Champ Captant Interne (Biskra Ouest)

FORAGE 1^{er} NOVEMBRE

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.417904	0.100022	4.178138	0.0001
R-squared	0.173748	Mean dependent var	-5.945367	
Adjusted R-squared	0.173748	S.D. dependent var	1065.826	
S.E. of regression	968.8186	Akaike info criterion	16.60187	
Sum squared resid	77904591	Schwarz criterion	16.63080	
Log likelihood	-696.2783	Hannan-Quinn criter.	16.61350	
Durbin-Watson stat	2.048350			
Inverted AR Roots	.42			

Notre modèle ARMA(1;0) se présentera ainsi :

$$Y_t = 0.417Y_{t-1}$$

Pour obtenir la prévision de la série brute (FF4) est la série STASF1NOVEM (voir l'annexe). on doit rajouter la moyenne et après on doit multiplier par le coefficient saisonniers (voir l'annexe).

$$v1novem = stasf1novem + (8867.15969628 - 21.3085289644 * @trend)$$

Tableau.5.104. 2009M01 2030M01 // prevf1nov=v1novem*cvs

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Year
2009													
F1NOVEM	9331.0	9206.0	9050.0	8877.0	8890.0	6110.0	8484.0	9206.0	9050.0	8877.0	8890.0	9288.0	8771.6
PREVF1NOV	--	8903.8	9566.3	8756.1	8410.9	8404.7	8755.3	8804.6	9290.2	8582.1	9080.4	8063.9	8783.5
2010													
F1NOVEM	9365.0	9386.0	8809.0	8116.0	9036.0	8930.0	8096.0	9600.0	8972.0	9381.0	8099.0	7238.0	8752.3
PREVF1NOV	8578.8	8447.1	9198.2	8466.8	8151.8	8153.5	8496.5	8545.3	9016.6	8329.0	8812.0	7825.0	8501.7
2011													
F1NOVEM	8317.0	8729.0	9636.0	9678.0	6744.0	6832.0	7571.0	5889.0	6666.0	6125.0	8435.0	8139.0	7730.1
PREVF1NOV	8324.0	8195.7	8923.7	8213.5	7907.3	7908.3	8240.5	8287.1	8743.4	8076.1	8543.7	7586.2	8245.8
2012													
F1NOVEM	9525.0	8585.0	8708.0	8327.0	9356.0	8426.0	7897.0	7609.0	8116.0	8218.0	7056.0	5886.0	8142.4
PREVF1NOV	8069.3	7944.2	8649.2	7960.2	7662.9	7663.2	7984.4	8028.9	8470.3	7823.1	8275.4	7347.3	7989.9
2013													
F1NOVEM	5496.0	6004.0	8700.0	6371.0	5633.0	7837.0	9703.0	7953.0	9944.0	7772.0	7870.0	6737.0	7501.7
PREVF1NOV	7814.6	7692.8	8374.7	7706.9	7418.4	7418.1	7728.3	7770.7	8197.1	7570.2	8007.1	7108.5	7733.9
2014													
F1NOVEM	7761.0	7483.0	8683.0	8203.0	9586.0	6399.0	7894.0	8996.0	8909.0	7371.0	9713.0	7385.0	8198.6
PREVF1NOV	7559.8	7441.4	8100.2	7453.6	7173.9	7172.9	7472.2	7512.5	7924.0	7317.2	7738.8	6869.6	7478.0
2015													
F1NOVEM	7258.0	6691.0	6204.0	6064.0	5166.0	6594.0	5967.0	6010.0	7722.0	7842.0	8433.0	7185.0	6761.3
PREVF1NOV	7305.1	7189.9	7825.7	7200.3	6929.4	6927.8	7216.1	7254.2	7650.9	7064.3	7470.5	6630.8	7222.1
2016													
F1NOVEM	7895.0	--	--	--	--	--	--	--	--	--	--	--	7895.0
PREVF1NOV	7050.4	6938.5	7551.3	6947.0	6685.0	6682.7	6960.0	6996.0	7377.7	6811.3	7202.2	6391.9	6966.2
2017													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	6795.6	6687.0	7276.8	6693.7	6440.5	6437.5	6703.9	6737.8	7104.6	6558.4	6933.9	6153.1	6710.2
2018													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	6540.9	6435.6	7002.3	6440.5	6196.0	6192.4	6447.8	6479.6	6831.5	6305.4	6665.6	5914.2	6454.3
2019													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	6286.2	6184.1	6727.8	6187.2	5951.6	5947.2	6191.7	6221.4	6558.3	6052.5	6397.3	5675.4	6198.4
2020													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	6031.4	5932.7	6453.3	5933.9	5707.1	5702.1	5935.6	5963.2	6285.2	5799.5	6129.0	5436.5	5942.5
2021													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	5776.7	5681.2	6178.9	5680.6	5462.6	5457.0	5679.5	5705.0	6012.0	5546.6	5860.7	5197.7	5686.5
2022													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	5522.0	5429.8	5904.4	5427.3	5218.1	5211.8	5423.4	5446.8	5738.9	5293.6	5592.4	4958.8	5430.6
2023													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	5267.2	5178.3	5629.9	5174.0	4973.7	4966.7	5167.3	5188.6	5465.8	5040.7	5324.1	4720.0	5174.7
2024													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	5012.5	4926.9	5355.4	4920.7	4729.2	4721.6	4911.3	4930.4	5192.6	4787.7	5055.8	4481.1	4918.8
2025													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	4757.8	4675.5	5080.9	4667.5	4484.7	4476.4	4655.2	4672.1	4919.5	4534.8	4787.6	4242.3	4662.8
2026													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	4503.1	4424.0	4806.4	4414.2	4240.2	4231.3	4399.1	4413.9	4646.4	4281.8	4519.3	4003.4	4406.9
2027													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	4248.3	4172.6	4532.0	4160.9	3995.8	3986.2	4143.0	4155.7	4373.2	4028.9	4251.0	3764.5	4151.0
2028													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	3993.6	3921.1	4257.5	3907.6	3751.3	3741.0	3886.9	3897.5	4100.1	3775.9	3982.7	3525.7	3895.1
2029													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	3738.9	3669.7	3983.0	3654.3	3506.8	3495.9	3630.8	3639.3	3826.9	3523.0	3714.4	3286.8	3639.1
2030													
F1NOVEM	--	--	--	--	--	--	--	--	--	--	--	--	--
PREVF1NOV	3484.1	--	--	--	--	--	--	--	--	--	--	--	3484.1




Figure 5-41 Les prévisions du modèle (F 1^{er} Novembre)

5.9.4.1. Interprétation des résultats

Cette étude est intéressée à la modélisation de séries chronologiques, nous avons utilisé les données mensuelles de la production d'eau potable de la ville de Biskra pour tester les modèles de prévision de cette consommation à court terme. L'exploration de ces données nous a révélé des caractéristiques telles que la non-stationnarité stochastique de la série de production d'eau potable. Les modèles estimés doivent cependant être améliorés. Une piste évidente à poursuivre est de prendre en compte les cycles mensuels et saisonniers (printemps, été, automne et hiver). Les données mensuelles proviennent de l'algérienne des eaux (ADE) couvrent la période de janvier 2009 à Janvier 2016, l'ensemble des résultats a permis de faire la prévision a un horizon donné. Nous avons synthétisé que la méthode de Box-Jenkins (1976) consiste à modéliser les séries temporelles au moyen de processus « ARMA » (ARMSTRONG, 1978).

L'objectif de la modélisation de la série temporelle observée est de prédire son comportement futur à travers la détermination d'un lisseur approprié de la série des données observées. Dans cette étude Le problème de lissage est traité de façon non paramétrique en utilisant les lisseurs exponentiels qui permettent d'accorder un poids plus important aux valeurs récentes de la chronique.

Afin de faire la lumière réelle du nombre d'années utilisées pour la constitution du modèle des prévisions.

Concernant les résultats, ils sont exprimés par des graphes de prévision. A partir de ces graphes, on peut déduire :

Champ Captant Oued El Hai, La figure et (Forage F1 2016-2020) (2016-2030) et le Forage F4 montre les résultats de la comparaison entre la demande d'eau (volume produit) est la prévision mensuelle est semblable. L'observation des graphique montre bien que les variables de la valeur observé (données de production d'eau potable) sont collées avec celle de la variable projetée (prédite) (PREVFF1) (PREVFF4) et que le résidu se comporte maintenant comme un bruit blanc ,il se dégage que le coefficient d'inégalité de THEIL FF1 (0.887523) FF4(0.937621) sont inférieure de ($U < 1$) c.-à-d. la technique de prévision est meilleure que cette méthode et d'autant meilleure que U est proche de 0. L'étude des erreurs de prévision permet d'évaluer leur qualité.

Champ Captant Injection Directe Biskra Centre. La Figure Forage Hakim Saadane. En comparant la série temporelle de la demande de l'eau (données observées) et la prévision mensuelle. On remarque une forte variabilité à des variations saisonnières de la demande de l'eau, montre la méthode de Box-Jenkins

améliore l'ajustement de notre modèle, améliorée la précision de la prévision. Pour calculer des prévisions et qui permet de bâtir le modèle de prévision FHakim Saadane et FRas-Elgueria.

On constate que le coefficient d'inégalité de THEIL FHakim Saadane (**1,02083129**) et FRas-Elgueria (**1,0336473**) sont supérieur de ($U>1$) c.-à-d. la technique de prévision n'est pas meilleure que cette méthode. Donc une série de production hors de l'ordinaire mauvaise lecture de l'index, défectuosité de compteur.....).

Champ Captant Injection Directe Biskra Ouest, Visuellement le diagramme de prévision présentés à la figure, nous pouvons avoir une comparaison graphique entre les données observées et les données calculées pour la série des données de production d'eau potable. Notre série « F1^{er} NOVEMB » a été modélisée par un processus ARMA (1,0), il se dégage que le coefficient d'inégalité de THEIL (**1,01205321**) est supérieur de 1 ($U>1$) c.-à-d. la technique de prévision est médiocre que cette méthode.

- **5.10. Evaluation des prévisions :**

L'analyse de ces erreurs passe par leur mesure. Celle-ci consiste à comparer la prévision à une série statistique observée, ou « réalisation ». L'étude des erreurs de prévision permet d'évaluer leur qualité. Pour évaluer les prévisions ; on peut calculer (RMSE, EAM, ERM et coefficient de Theil).

Theil (1958 et 1966), le premier, a construit des outils statistiques permettant une évaluation scientifique de la précision des prévisions. Pour chaque variable, on calcule un indicateur qui résume la série d'erreurs apparues au cours de la période étudiée. Il s'agit généralement de l'erreur absolue moyenne (MAE) ou de la racine carrée de l'erreur quadratique moyenne (RMSE) (**Wold, 1954**). On dit que la prévision est bonne si ces mesures sont proches de « 0 ».

La mesure de la précision des prévisions doit toujours être évaluée dans le cadre d'une validation de modèle

- Erreur Moyenne (Mean error)

$$ME = 1/n \sum_{t=0}^n et$$

Avec : $et = Y_t - \hat{y}_t$

- Indicateur de la valeur absolue moyenne des écarts (*Mean Absolute Error*)

$$MAE = 1/n \sum_{t=0}^n |et|$$

- Indicateur de la variance de l'erreur de prévision (*MSE*, « *Mean Squared Error* »)

$$MSE = 1/n \sum_{t=1}^n [et]^2$$

Avec : $MSE = \sigma^2$

- Erreur Relative Moyenne (re)

$$re_t = |(Y_t - \hat{Y}_t / Y_t) * 100|$$

Y_t : Les données d'observée

\hat{y} : Les données de la prévision

- Erreur Absolue Moyenne (Mean Absolute Error) ;

$$MAE = |ERM|$$

- l'écart moyen en pourcentage (Mean Percent Error) ;

$$MPE = 1/n \sum_{t=1}^n ret$$

- l'écart absolu moyen en pourcentage (Mean Absolute Percent Error);

$$MAPE = 1/n \sum_{t=1}^n |ret|$$

- Racine de Erreur Quadratique Moyenne (Root Mean Squared Error)


$$RMSE = \sqrt{MSE}$$

- Indicateur de Theil (U)


$$U = \frac{RMSE}{RMSE \text{ (méthde alternative)}}$$

Les valeurs actuelles et prédites sont reprises dans la figure suivante :


Forage FF1




Forage F4




Forage Hakim Saadane



Forage 1^{er} Novembre



Forage Ras-Elguerria



Forage	Modèle	MAE	RMSE	MAPE	Thiel (U)	Variance	Covarian
FF1	ARMA(3 ;3)	293.2581	362.1574	99.39123	0.887523	0.792296	0.207370
FF4	ARMA(0.2)	358.6755	459.9541	99.57758	0.937621	0.921967	0.078028
Fhaks	ARMA(1.1)	1097.472	1492.374	102.6108	0.657093	0.405590	0.559692
F1Nove	ARMA(1.0)	834.3279	1058.972	99.48711	0.976421	0.954802	0.045105
Frasg	ARMA(1.0)	2568.843	3152.095	102.8279	0.977901	0.951795	0.047980

On dit que la prévision est bonne si ces mesures sont proches de « 0 ».

Méthode Alternative (calculer)

FF1

EM	MAD	MSE	MPE	MAPE	RMSE	Theil (U)
-10,2699765	289,69741	137962,381	-5,00630651	17,8052593	371,432875	0,97502786

FF4

EM	MAD	MSE	MPE	MAPE	RMSE	Theil (U)
12,79083529	355,27438	219886,694	-2,50679881	13,9889133	468,920776	0,980878059

FHAKS

EM	MAD	MSE	MPE	MAPE	RMSE	Theil (U)
266,686	1080,18447	2137211,02	0,3898734	8,84493269	1461,92032	1,02083129

Frasg

EM	MAD	MSE	MPE	MAPE	RMSE	Theil (U)
-46,4537647	2512,42412	9299376,8	-6,39223741	1,177255871	3049,48796	1,0336473

F1 er November

EM	MAD	MSE	MPE	MAPE	RMSE	Theil (U)
-10,1804941	820,34405	1094869,27	-2,06744319	11,0750573	1046,36001	1,01205321

Au regard de ces résultats, il se dégage que le coefficient d'inégalité de THEIL inférieur de ($U < 1$) dans les forages (FF1, FF4) et c.-à-d. la technique de prévision n'est pas meilleure mais on peut dire que la prévision est acceptable que U est inférieure de 1.

Tableau 5. 105. Mesures de l'erreur de prévision du modèle ARMA

MODELE	AIC	SIC	R ²
AR(0)MA(2)	14.47532	14.56213	0.239636
AR(3)MA(3)	14.84713	14.93654	0.162989
AR(1)MA(1)	17.40416	17.49902	0.293648
AR(1)MA(0)	18.75620	18.84961	0.297634
AR(1)MA(0)	16.17407	16.26088	0.486380

Cependant, pour choisir le modèle à retenir pour la prévision, nous allons recourir aux critères d'information et au coefficient de détermination. Ces critères permettent d'évaluer la qualité d'un modèle. D'après ces critères, il ressort que le modèle **AR (0) MA (2)** dispose d'une qualité supérieure. Le fait de retenir ce modèle ne signifie pas que les autres modèles ne peuvent pas être utilisés pour la prévision. Ces critères n'accordent au modèle retenu qu'une certaine prééminence sur les autres.

Conclusion
Générale

Conclusion Générale

Cette étude est intéressée à la modélisation de séries chronologiques, nous avons utilisé les données mensuelles des données de consommation d'eau potable de la wilaya de Biskra pour tester des modèles de prévision à court terme. Dans ce travail, une approche en deux étapes est présentée pour modéliser des données de production d'eau potable.

La première étape utilise une méthode basée sur l'étude de la stationnarité, détermination et élimination de la saisonnalité d'une série des données mensuelles de l'eau potable (Yang, 2011), et nous tentons de découvrir ces composantes, sa nature, et l'effet qui influencent la série d'avoir une meilleure prévision à court terme. La simple visualisation des données de production sur une période de plusieurs années amène à constater la présence de tendances et de cycles répétitifs. Les principaux outils mathématiques utilisés pour le traitement des données sont les facteurs d'auto covariances, les méthodes statistiques et un autre qui concernant les diverses techniques d'identification des paramètres du modèle. La méthodologie de Box et Jenkins permet de déterminer le processus ARMA adéquat pour la modélisation d'une chronique et de recherche systématique d'un modèle adéquat en fonction de l'étude des corrélogrammes empiriques (PARK, 1999), ils se réfèrent à deux types de modèle : des processus moyennes mobiles (MA), des processus autorégressifs (AR). La méthodologie B&J suggère quatre étapes, à savoir : l'identification, l'estimation, la validation et la prévision. (BEN ABBAS, 2012).

Les buts de la modélisation consistent à approximer cette moyenne mobile infinie par un processus ayant un nombre fini de paramètres. C'est ce que l'on verra en étudiant les Processus **AR, MA et ARMA**.

Le modèle ARMA est un outil pour comprendre et prédire, éventuellement, les valeurs futures de cette série. Le modèle est généralement noté ARMA (p,q), où p est l'ordre de la partie AR et q l'ordre de la partie MA. Un processus **autorégressif** est un **modèle** de régression pour séries temporelles dans lequel la série est expliquée par ses valeurs passées plutôt que par d'autres variables

Nous avons synthétisé que la méthode de Box-Jenkins (1976) consiste à modéliser les séries temporelles au moyen de processus « ARMA ». Ces processus sont parcimonieux et constituent une bonne approximation de processus plus généraux pourvu que l'on se restreigne au cadre linéaire. Les modèles « ARMA » donnent souvent de bons résultats en prévision.

En statistique, les modèles ARMA (modèles autorégressifs et moyenne mobile), et aussi modèle de Box-Jenkins, sont les principaux modèles de séries temporelles. Étant donné une série temporelle X_t , le modèle ARMA est un outil pour comprendre et prédire (**KARLIN, Howard and TAYLOR, 1975**), éventuellement, les valeurs futures de cette série

Un processus autorégressif est un modèle de régression pour séries temporelles dans lequel la série est expliquée par ses valeurs passées plutôt que par d'autres variables. Les tests de stationnarité permettent de vérifier si une série est stationnaire ou non, comme l'hypothèse nulle H_0 est que la série est stationnaire, et les tests de racine unitaire comme le test de Dickey-Fuller, le test augmenté de Dickey-Fuller (ADF).

La modélisation d'une telle série peut permettre d'analyser les évolutions passées, elle ne répond cependant pas directement à notre objectif de prévision des données de production d'eau potable comme outil d'aide à la gestion des ressources en eau.

Pour choisir le modèle à retenir pour la prévision, nous allons recourir aux critères d'information et au coefficient de détermination. Ces critères permettent d'évaluer la qualité d'un modèle. Les formules mathématiques utilisées pour calculer les indicateurs ainsi que la formalisation des tests statistiques (**ZHANG, 2003**). Pour évaluer les prévisions ; on peut mesurer la qualité d'une prévision et calculer les indicateurs de mesure (MSE, MAE, RMSE, MAPE, ...et coefficient de Theil). On dit que la prévision est bonne si ces mesures sont proches de « 0 ». L'indicateur le plus intuitif pour mesurer les erreurs de prévision est l'erreur absolue moyenne (MAE), un autre indicateur fréquemment utilisé est la racine carrée de l'erreur quadratique moyenne (RMSE) qui pénalise davantage les erreurs importantes que la MAE. D'après ces critères, il ressort que le modèle **AR (1) MA (1)** dispose d'une qualité supérieure. Le fait de retenir ce modèle ne signifie pas que les autres modèles ne peuvent pas être utilisés pour la prévision. Ces critères n'accordent au modèle retenu qu'une certaine prééminence sur les autres.

Certaines méthodes statistiques de prévision de la consommation d'eau potable basées sur les séries chronologiques utilisent la consommation passée et les valeurs courantes ou pour prévoir la consommation courante d'eau de consommation.

L'exploration de ces données nous a révélé des caractéristiques telles que la non-stationnarité stochastique de la série de production d'eau potable. Les modèles estimés doivent cependant

être améliorés. Une piste évidente à poursuivre est de prendre en compte les cycles mensuels et saisonniers (printemps, été, automne et hiver). Les données mensuelles proviennent de l'algérienne des eaux (ADE) couvrent la période de janvier 2009 à Janvier 2016.

Les résultats indiquent que la qualité de prévision est acceptable a part de quelque forages

On notera : les forages dont les meilleurs prévision Champ captant oued El Hai (Forage F1 ,Forage F4),les forages des mauvaises résultats les forages du champ captant interne sont en injection directe sur le réseau de distribution sans passage par des ouvrages de stockage ou de régulation, l'exploitation ne peut assurer un volume d'autonomie de distribution d'eau potable lors des travaux de maintenance ou de rupture d'énergie, l'impossibilité de contrôler la qualité de l'eau ,le cout élevé d'exploitation

L'objectif de ce travail est de réaliser des prévisions à court terme pour la série de consommation d'eau potable couvrent les période allant (2009-2020) et (2009-2030). La méthode de Box-Jenkins a donnée comme meilleure modèle ; le modèle AR (1) MA (1), d'après le test de normalité ; ce modèle a des résidus forment un bruit blanc gaussien. Les modèles « ARMA » donnent souvent de bons résultats en prévision et on bénéficie de la vague de scepticisme quant à l'intérêt de grosses méthodes économétriques. Les méthodes économétriques sont en effet devenues des outils essentiels d'aide à la décision pour toute politique qui se veut efficace dans le temps.

Perspectives

Les travaux décrits dans cette thèse peuvent se poursuivre sur plusieurs voies de recherche :

- On recommande de faire une étude d'analyse de données de consommation en régression non linéaire par la méthode de réseaux de neurones.
- Prévoir une autre méthode capable d'améliorer la prévision de la demande en eau.

Références
bibliographiques

Références bibliographiques

- AKAIKE, H.** (1973). Information theory and an extension of the maximum likelihood principle. In Second international symposium on information theory (pp. 267-281). Akademinai Kiado.
- AMARAL, L. F., R. C. Souza, et al.** (2008). A smooth transition periodic autoregressive (STPAR) model for short- Amjady, Nima (2001). Short-term hourly load forecasting using time-series modeling with peak load estimation capability. Power Systems, IEEE Transactions on 16.3 (2001): 498-505.
- ANDERSEN, and, WEISS, A** (1984) « Forecasting : The Box-Jenkins approach »in The Forecasting Accuracy of Major Time series Methods,Makridakis et.al,John Wiley&Sos,chichester,England.
- ANSLEY, C. F. et NEWBOLD, P.** (1980). Finite sample properties of estimates for autoregressive moving average models, *Journal of Econometrics* **13**, 159-183.
- ARAGON, Y.** (2011). Séries temporelles avec R : Méthodes cas. Springer
- ARMSTRONG, J.S.,** (1978) « Forecasting with Econometric Methods : Folklore versus Fact with Discussion », *Journal of Busines*,51,549-600
- ARMSTRONG, S. (Ed.)** (2001). *Principle of forecasting: a handbook for researchers and practitioners*, Springer, New York.
- ASHLEY, R.** (1988). On the relative worth of recent macroeconomic forecasts, *International Journal of Forecasting* **4**, 363-376.
- BEN ABBAS, F** (2012), Méthodes heuristiques pour la prédiction des séries temporelles, Faculté des sciences de l'ingénieur, département d'informatiques, Université Badji Mokhtar Annaba,Alger
- BEGUIN, J.M., GOURIEROUX, C.& MONFORT, A.** (1980). Identification of a mixed autoregressive-moving average process : the corner method.In time series roc.Internat,Meeting,Univ,Nottingham,Nottingham,(1979).Amsterdam ;North-Holland, pp.423-436.
- BENNIS, S.** (1 987) Technique de prévision *des* crues par l'analyse des séries temporelles, Thèse de doctorat, Faculté de génie, Université de Sherbrooke,195 p.
- BERNARD,J.T.,D.BOLDU,ET AL.** (1996). Quebec residential electricity demand : a microeconomic approach. Canadian term load forecasting. *International Journal of Forecasting* (4): 603-615. *Journal of Economics*: 92-113.

- BISGAARD,S.and M.KULACHI** (2011). Times series analysis and forecasting by example. John Wiley & sons
- BOX, G.E.,& JENKINS,G.M.** (1970). Time Series Analysis: Forecasting and Control. Holden-D. iv, San Francisco.
- BOX, G.E.P. JENKINS, G.M.** (1976). Time Series Analysis: Forecasting and Control. Time Series and Digital Processing
- BOX, G.E.P.ET PIERCE, D.A.** (1970). « Distribution of Residual Autocorrelations in Autoregressive Moving Average Time Series Models », *Journal of the American Statistical Association*, vol. 65.
- BOURBONNAIS, R.** “PREVISION DES VENTES“, Polycopié du produit multimédia ,Université de Paris-Dauphine
- BOURBONNAIS, R.ET TERRASA, M.** (1998). *Analyse des séries temporelles en économie*, PUF, Paris, 274 p.
- BROCKWELL, P.J.** (1987) 'Time series : theory and methods ' Springer-Verlag
- BROCKWELL, P.J.&DAVIS, R.A.**(2002).Introduction to time series and forecasting springet Texts in Statistic.New Yorq :Springer-Verlag.2nded With 1 CD-ROM(Windows).
- Brockwell, P. J., Davis, R. A.** (2006) Time series, theory and methods. Second edition. Springer.
- Brockwell, P. J., Davis, R. A.** (2013) Time series, theory and methods. Springer.Science&Business Media.
- BROOKS, D. B., PETERS, R.** (1988) La gestion de la demande d'eau : les options qui s'offrent aux Canadiens,Ottawa, Ministère des approvisionnements et services, 93 p.Consultation publique sur la gestion de l'eau au Québec, Portrait régional de l'eau :Estrie (mars 1999) Bureau des audiences publiques sur l'environnement. 25 p.
- BROZE, L. et MÉLARD, G.** (1990). Exponential smoothing: estimation by maximum likelihood, *Journal of Forecasting* **9**, 445-455.
- CADIHAC, F.ET MARTINO, A.** (2000) « Projet de fin d'études : prévision de prix de produits agricoles », DAF / SCEES/ la Ministère de l'Agriculture et de Pêche, 129
- CAMPBELL, P.R.J.ET ADAMSON, K.** (2006). Methodologies for Load Forecasting. Intelligent systems
- COUTROT, B. et DROESBEKE, J.-J.** (1990). *Les méthodes de prévision*, n°2157, Presses Universitaires de France, Paris (2e éd.).

- COTTREL, M. GIRARD, B. GIRARD, Y. GIRARD, M. MANGEAS, C. Muller**, “Neural modeling for time series: a statistical stepwise method for weight elimination”, *IEEE Trans. Neural Networks* 6 (1995), pages : 1355–1364.
- CLEMENTS,M.and HENDRY,D.F.**(1998), *Forecasting economic time séries* »,Cambridge University Press.
- JERBOUAI, S. (2016)**, Thèse Doctorat Methodes de l’intelligence artificielle pour la prévision des séchresse,Faculté des sciences et de la technologie Université Hawari Boumedienne ,Alger p 48.50
- DROESBEKE, J.-J., FICHET, B. et TASSI, PH.** (Éditeurs) (1994). *Modélisation ARCH - Théorie statistique et applications dans le domaine de la finance*, Collection Association pour la Statistique et ses Utilisations, Editions de l'Université de Bruxelles, Bruxelles et Editions Ellipses, Paris.
- Daudin, J.J. Duby, C. Robin S& Tre COURT P.** (Mai 1996). *Analyse de Séries Chronologiques* (INA-PG, Mathématiques).
- FARAWAY, J. CHATFIELD, C.** “Time series forecasting with neural networks: a comparative study using the airline data”, *Applied Statistics* 47 (1998), pages: 231–250.
- LEE, J. “Univariate time series modeling and forecasting (Box-Jenkins Method)”, *Econ* 413, lecture 4.
- GOURIEROUX, C. et MONFORT, A.** (1990). *Séries temporelles et modèles dynamiques*, Economica, Paris.
- GRANGER, C. W. J.** (1980). *Forecasting in Business and Economics*, Academic Press, New York.
- CHATFIELD,C.**(2001), « Time Series Forecasting »,Chapman&Hall.
- [CHO,M.Y.,HWANG,J.C.,et CHEN, , C. S.** (1995). Customer short term load forecasting by using ARIMA transfer function model. In *Energy Management and Power Delivery*
- COTTET, R., & SMITH, M.** (2003). Bayesian modeling and forecasting of intraday electricity load. *Journal of the American Statistical Association*, 98(464).
- CHOEFFDING,W** (1948).A class of statistics with asymptotically normal distribution.*Ann.Math.statistics*,19,293-325.Nam,63p.
- CHRISTOPHE HURLIN U.F.R.** *Economie Appliquée Maîtrise d’Economie Appliquée,Cours de Tronc Commun Econométrie Appliquée Séries Temporelles*
- COWPERTWAIT, P. S., et METCALFE, A. V.** (2009). *Introductory time series with R*. Springer.
- DICKEY DAVID A. et WAYNE A. FULLER, (1979)**, “Distribution of the Estimators for Autoregressive Time Series with a Unit Root”, *Journal of the American Statistical Association*, 74, 427 – 431.

- DEMARD, H, FORTIN, J.P., GRENON, A-** (avril 1976) La demande en eau du milieu urbain : Cas de ramage des pelouses, Partie 1, Eau du Québec, Québec, vol.9, n02, p. 27 - 29
- DEMARD, H, FORTIN, J.P., GRENON, A-** (août 1976) La demande en eau du milieu urbain : Cas de l'arrosage des pelouses, Partie 2, Eau du Québec, Québec, vol.9, n03, p. 13 - 15
- DICKEY, D. A., & FULLER, W. A.** (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica: Journal of the Econometric Society*, 1057-1072.
- DACUNHA-CASTELLE, D. & DUFLO, M.** (1985). 'Probabilités et Statistiques - Tome 2 : Problèmes à temps mobile ' Masson
- DAVID M. et MICHAUD, J.C.** (1989) *La prévision, approche empirique d'une méthode statistique*, Masson.
- DROESBEKE, J.J., FICHET, B. & TASSI, P.** (1995). 'Séries chronologiques - théorie et pratique des modèles ARIMA', Economica
- ESPINOZA, M., J. A. K. SUYKENS, et al.** (2006). LS-SVM regression with autocorrelated errors. Proc. of the 14th IFAC Symposium on System Identification (SYSID).
- FIDELS, R, HIBON, M, MAKRIDAKIS, S, and MEAD, N.,** (1995) "The Accuracy of Extrapolative Forecasting Methods: Additional Empirical Evidence", INSEAD Working Paper.
- GASMI, L.** (2019), *Thèse de doctorat* "Times séries forecasting using neural networks and genetic algorithms, Faculté de Sciences exactes Sidi Bel Abbaes, pages :
- GEP, B. O. X., GAILIM M. JENKINS, and GREGORY C. REINSEL.** (1976). "Time series analysis: forecasting and control." Oakland CA: Holden-Dag.
- GOURIEROUX, C. & MONFORT, A.** (1995) 'Séries temporelles et modèles dynamiques', Economica
- GOURIEROUX, C. & MONFORT, A.** (1990). *Séries temporelles et modèles dynamiques*, Economica, Paris.
- GOURIEROUX, C.** (1997). ARCH models and financial applications. Springer series in statistics. New York, Springer-Verlag.
- GARDNER, E.S JR., and MCKENZIE, E.** (1985) « Forecasting Trends in Time Series » *Management Science*, 31, 1237-1246.
- GRANGER, C. W. J.** (1980). *Forecasting in Business and Economics*, Academic Press, New York

GRANGER, C. W. and NEWBOLD, P. (1997), "*Forecasting Economic Time Series*", New York : Academic Press.

Groupeement Bureaux d'Etude: PROSPECTIVA, PROENGEL, SATEIG) . Etude du diagnostic pour la rehabilitation du système d'alimentation en eau potable des villes de BISKRA,OUARGLA,Touggourt

Harvez, A.C. (1993), "*Time Series Models*", New York : Howester.

HIPEL, K.W. MCLEOD, A.I. "Time Series Modelling of Water Resources and Environmental Systems", Amsterdam, Elsevier 1994.

JARQUE, C.M&BERA, A.K. (1980). Efficient tests for normality,homoscedasticity and serial independence of regression residuels.Econom.

KADIYALA, K. R. (1970). Testing for the Independence of Regression Disturbances, *Econometrica* **38**, 97-117

KARLIN, S. and Howard E. TAYLOR, 1975, *A First Course in Stochastic Processes*, 2nd edition Academic Press, 557p.

KWLATKOWSKI, PHILIPS, S.&SHIN (1992). Testing the null hypothesis of stationarity againts the alternative of a unit root.Journal of Econometries 54,159-178.

Ladiray, D., Quenneville, B. (2000) Désaisonnaliser avec la méthode 11.23P.

LEJEUNE M. 1997, *Statistique, cours B7 : séries chronologiques*, Collection des cours du CNAM, 63 p.

LJUNG G.M. et BOX G.E.P. (1978). « On a Measure of the Lack of Fit in Time Series Models », *Biometrika*, vol. 65, pp. 297-303.

LEVIN, R. I. et RUBIN, D. S. (1998). *Statistics for Management*, Prentice Hall, Upper Saddle River (NJ) (7e éd.).

LÜTKEPOHL, H. (1993). *Introduction to Multiple Time Series Analysis*, Springer-Verlag, Berlin, (2e éd.).

LINEESH, M.C, MINU, K.K. and JESSY JOHN, E. (2010), "Analysis of Non stationary Non linear Economic Time Series of Gold Price A Comparative Study." *International Mathematical Forum*, 5,1673-1683

LUBRANO, M. (Septembre 2008), "Introduction a la modélisation des séries temporelles univariées"

MAKRIDAKIS, S.WHEELWRIGHT,S.,and MCGEE,V. (1983), *Forecasting Methods an applications* (2nd Edition),Wiley and Sons,New York.

MARTINO, JOSEPH, P. (1983). *Technological Forecasting for Decision Making*, Elsevier, New York.

MELARD, G. (1990a). *Méthodes de prévision à court terme*, Editions de l'Université de Bruxelles, et Editions Ellipses, Paris

MCWHORTER, A. Jr., (1975) « Time Series Forecasting Using the Kalman Filter :An Empirical Study », *Proc. Amer. Statist. Ass, Business and Economics Section*, pp.436-446.

MELARD G. (1984). « A Fast Algorithm for the Exact Likelihood of Autoregressive-Moving Average Models », *Applied Statistics*, vol. 33 n°1, pp. 104-119.

MICHEL ; L (2008). Tests de Racine Unitaire

NELSON C.R. et PLOSSER C. (1982). « Trends and Random Walks in Macroeconomics Time Series : Some Evidence and Applications », *Journal of Monetary Economics*, vol. 10. SPSS Inc. 1994. *SPSS Trends 6.1*, SPSS Inc., Chicago, 356 p.

NERLOVE M, GREYER D.M, CARVALHO J.L. (1995). 'Analysis of Economic Time Series ' Academic Press.

NEWTON, H.J., and PARZEN, E., (1984) »Forecasting and Time Series model Types of economic Time Series » in Makridakis, S. et al., *The Forecasting Accuracy of Major Time Series Methods*, Wiley, Chichester, England.

PHILIPS, P.C.B et PERRON, P. (1988). "Testing for a unit root in time series regression". *Biometrika* 75,335-

Rahal, R, C, E, Z and Abdelkader, G (2017). Forecasting performance of arma models by correction errors with genetics algorithms. *International Journal of statistics Economics*, 8(1):1-15

RAIHEN, M (2013), **Thèse doctorat** "La prédiction des séries temporelles utilisant les paradigmes de soft computing", Département génie électrique Faculté des Sciences et de la Technologie, Biskra, Alger ,

SHILLER, R., AND P. PERRON (1985): "Testing the Random Walk Hypothesis: Power versus Frequency of Observation," *Economic Letters*, 18, 381–386

SAID, E. et DAVID, A. DICKEY 1984, "Testing for Unit Roots in Autoregressive Moving Average Models of Unknown Order", *Biometrika*, 71 (3), 599 – 607.

SHAMAY, R.H, STOFFER, D.S. (2017), "Time séries analysis and its application with R example's", Springer

SPRAY, J.A. & NEWELL, K.M. (1986). Time series analysis of motor learning

- STEPHENS, M.A.**(1976) Asymptotic results for goodness-of-fit statics with unknown parameters, *Ann .Statist.*4,357-369.
- SCOTT, ARMSTRONG,J.**, “Findings from evidence-based forecasting: Methods for reducing forecast error”, *International Journal of Forecasting* 22 (2006), pages: 583–598.
- SYLVESTRE, T .**(2013) Modélisation et prévision de la consommation horaire d’électricité au Québec, maîtrise en économie, pages :
- Tidjani, A.E.B. Yebdri,D. Roth ,J.C. Derriche,Z.** (2006) Exploration des séries chronologiques d’analyse de la qualité des eaux de surface dans le bassin de la Tafna (Algérie *Revue des sciences de l’eau/volume 19,numéro 04,2006,p.259-407*
- TONG, H.** “Threshold Models in Non-Linear Time Series Analysis”, Springer-Verlag, New York, 1983.
- TSASA JEAN – PAUL,**(2012), « Espérance et Variance Conditionnelles en Analyse Économétrique », *One Pager Laréq* (novembre), vol. 4, num. 003, 19 – 25.
- VANDER VAART, A.W.&WELLNER,J.A.**(1996).Weak convergence and empirical processes ,Springer Séries in statistics.New York Springer Verlag.With applications to statistics
- WALTER C. et SCHEPS R.** 1998. « Marchés financiers, hasard et prévisibilité », *Les sciences de la prévision* , Seuil, Paris, pp. 125-146.
- WANG, H., Li, G., & TSAI, C. L.** (2007). Regression coefficient and autoregressive order shrinkage and selection via the lasso. *Journal of the Royal Statistical Society : Series B (Statistical Methodology)*, 69(1), 63-78.
- WEISS, A. A., & ANDERSEN, A. P.** (1984). Estimating time series models using the relevant forecast evaluation criterion. *Journal of the Royal Statistical Society. Series A (General)*, 484-487.
- Wold, H.** (1954): *A Study in the Analysis of Stationary Time Series*. Almqvist and Wiksell,Uppsala.STOCKHOLM.
- WOLD, H.O.A.**(1948).On prediction in stationary time series,*Ann Math.Statistics* 19,558-
- Yang,G** (2011) ,Séries Chronologiques a une et plusieurs variables :Synthèse des méthodes classiques et modeles à base de copules, Mémoire,Université du Québec
- ZHANG, P.** “A neural network ensemble method with jittered training data for time series forecasting”, *Information Sciences* 177 (2007), pages : 5329–5346.
- ZHANG, G.P.** “Time series forecasting using a hybrid ARIMA and neural network model”, *Neurocomputing* 50 (2003), pages : 159–175.

PARK, **H.** “Forecasting Three-Month Treasury Bills Using ARIMA and GARCH Models”, Econ 930, Department of Economics, Kansas State University, 1999.

. <http://statsoft.fr/concepts-statistiques/series-chronologiques/series-chronologiques.htm>

<http://dictionnaire.sensagent.leparisien.fr/TEST%20DE%20NORMALITE/fr-fr/>

<http://statsoft.fr/concepts-statistiques/series-chronologiques/series-chronologiques.htm>]

