

استخدام منهجية بوكس-جينكز للتنبؤ بإنتاج القمح

دراسة حالة: الصين

Using Box-Jenkins Methodology for Forecasting Wheat Production

Case Study: China

شادي إسماعيل يوسف التلباني

جامعة الأزهر - غزة

كلية الاقتصاد والعلوم الادارية- قسم الإحصاء

Shadytelbany@yahoo.com

Received 2/8/2015 Accepted 25/10/2015

ملخص:

تناول هذا البحث استخدام منهجية بوكس وجينكز للتنبؤ بإنتاج القمح في الصين. وبمقارنة عدة نماذج مختلفة مع النموذج المقترح تبين أن النموذج الامثل هو نموذج $ARIMA(0,2,1)$ حيث انه تجاوز مرحلة الفحص والتشخيص بسهولة. وعليه تم استخدامه في التنبؤ بالقيم المستقبلية خلال الفترة (2011-2020)، ووجد ان هناك تقارب بين القيم التنبؤية والقيم الفعلية بالإضافة الى وجود نمط عام بالزيادة في انتاج القمح في الصين. كلمات مفتاحية: بوكس وجينكز، انتاج القمح، التنبؤ، الصين.

Abstract :

This research uses Box-Jenkins methodology in order to forecast Wheat production in China. By comparing several different models with the proposed model, it shows that the best model is $ARIMA(0,2,1)$ Model as it succeed the examination and diagnosis stages easily. Therefore, the research used $ARIMA(0,2,1)$ model for forecasting the future values during the period of (2011-2020). This research concluded that there is a convergence between the estimated and actual values. Also, there is a general pattern of increasing wheat production in China.

Key Words: Box-Jenkins, Wheat production, forecasting, China .

تعتبر الزراعة هي العمود الفقري للاقتصاد، وتسهم في تحقيق الرفاه الاقتصادي والاجتماعي للشعوب من خلال تأثيرها على الناتج المحلي الاجمالي (GDP). وتلعب الزراعة دوراً مهماً في تحسين المستوى المعيشي لسكان المناطق الريفية بشكل خاص والاقتصاد الكلي بشكل عام. أحد أهم المحاصيل الزراعية في العالم هو القمح، حيث يعتبر من المحاصيل الغذائية الأساسية التي تلعب دوراً ملحوظاً في تلبية الاحتياجات الغذائية المتنوعة في كل من المناطق الريفية والحضرية في البلدان (Saeed et al., 2000). وتعتبر زراعة القمح أسهل وتتطلب وقتاً أقل في الري من المحاصيل البديلة الأخرى مثل الارز والبطاطس وغيرها، بالإضافة الى ان لديها تكاليف زراعة منخفضة (Karim et al., 2010).

زاد انتاج القمح في العالم بشكل كبير خلال الفترة 1951-1990، وعلى الرغم من التوسع في المساحات المزروعة من القمح الا انه لم يعد هو المصدر الرئيسي لزيادة انتاج القمح، حيث لعب تحسين الممارسات الزراعية السليمة والاصناف المحسنة وراثياً الى زيادة الانتاج (GIMMYT, 1996). وهناك تحسن في توقعات الانتاج العالمي من الحبوب في عام 2015، حيث تشير التوقعات الى ان الانتاج العالمي من القمح سيبلغ 723 مليون طن عام 2015 (منظمة الاغذية والزراعة، 2015).

ان العالم اليوم يواجه تحدياً يتمثل في زراعة المزيد من القمح لمواكبة الزيادة السكانية، حيث ان هناك سباقاً قائم وحقيقي بين توفير الغذاء وزيادة السكان (Amin et al., 2014). وتعتبر الصين أكبر مثالا لهذا التحدي.

الصين هي اكبر منتج للقمح في العالم، حيث يعتبر القمح الغذاء الرئيسي فيها. ويختلف انتاج القمح الصيني من سنة الى اخرى وفقاً لسياسات الحكومة والتي تشجع على انتاج قمح ذو جودة عالية لتصديره واستبداله بواردات اخرى (El-Shehawy et al., 2011).

القمح من الحبوب الرئيسية في الصين ويمثل 30% من انتاج الحبوب، وعلى الرغم من النمو الملحوظ في انتاج القمح منذ اواخر عام 1970 حتى أوائل عام 1990 شكلت واردات القمح أكثر من أربعة أخماس واردات الصين من الحبوب (Tian et al., 2000). ولقد كانت السنوات العشرين الماضية فترة تقلبات في انتاج القمح. حيث بلغ الانتاج مستويات قياسية عام 1997، ثم انخفض بنسبة كبيرة بحلول عام 2003 (El-Shehawy et al., 2011). ورغم هذه التقلبات كان ولا يزال العرض المحلي غير قادر على تلبية الطلب المتزايد على القمح في الصين والتي تعتبر أكبر دولة في العالم من حيث السكان وتشكل تقريباً 20% من سكان العالم.

Using Box-Jenkins Methodology for Forecasting Wheat Production

لذا يجب على واضعي السياسات الحكومية المتعلقة بزراعة القمح بناء استراتيجيات بناءاً على التنبؤات المتوقعة للكميات المنتجة من القمح في الصين. ومن أهم الاساليب الاحصائية المستخدمة بشكل واسع في عمليات التنبؤ هو منهجية بوكس وجينكنز .

2. مشكلة البحث

ان الصين تواجه تحدياً كبيراً يتمثل في انتاج المزيد من القمح لمواكبة الزيادة السكانية الهائلة، حيث بلغ عدد سكانها في نهاية عام 2014 مليار وثلاثمائة وتسعة ملايين. ولبناء استراتيجيات وتحديد الافاق المستقبلية لإنتاج القمح في الصين، فقد تمحورت مشكلة الدراسة في التساؤل الرئيس التالي: ما هو النموذج الأمثل من بين نماذج ARIMA للتنبؤ بإنتاج القمح في الصين؟

3. أهداف البحث:

تمحورت أهداف البحث حول:

- تقديم أداة احصائية سليمة ودقيقة (منهجية بوكس-جينكنز) للتنبؤ بإنتاج القمح في الصين.
- تحديد النموذج الأمثل من بين نماذج ARIMA للتنبؤ بإنتاج القمح في الصين.
- دعم جهود متخذي القرار عند قيامهم بالتخطيط لضبط منظومة انتاج القمح في الصين.
- الوقوف بدقة على الاحتياجات السنوية للصين من القمح.
- مساعدة القطاعات المختلفة المرتبطة بمحصول القمح على الاستعداد لمواجهة الاحتياجات السنوية من المحصول.

4. الاطار النظري

السلسلة الزمنية هي مجموعة من القيم لمتغير معين تحدث خلال فترة من الزمن في نمط معين، وحيث ان أكثر الانماط الشائعة للسلاسل: الاتجاه العام المتزايد او المتناقص، الدورية، الموسمية، غير المنتظمة (Bowerman et al., 2005). وتعتبر هذه الانماط الاربعة مكونات او عناصر السلاسل الزمنية.

تزايد الاهتمام في الآونة الاخيرة بالتنبؤ بالسلاسل الزمنية باستخدام المشاهدات الماضية والحالية في التنبؤ في الاجل القصير. ومن أهم هذه الطرق المستخدمة في التنبؤ منهجية بوكس-جينكنز والتي ظهرت عام 1976. ونتيح هذه المنهجية للبيانات بأن تتحدث عن نفسها للوصول الى أفضل نموذج صاحب أقل أخطاء، وتعتبر هذه المنهجية طريقة فعالة في حل العديد من مشاكل تحليل السلاسل الزمنية (Ajoy, 2005) .

حيث تجمع هذه المنهجية بين نموذجين في معادلة واحدة. النموذج الاول يمثل نموذج الانحدار الذاتي (AR)، حيث يعبر عن المتغير y_t كدالة في المشاهدات الماضية لنفس المتغير التابع y_{t-i} كالتالي: $y_t = \varepsilon_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p}$ ، حيث تشير ϕ_i الى معاملات الانحدار الذاتي، وتشير P الى رتبة الانحدار الذاتي، ويطلق على هذا النموذج نموذج الانحدار الذاتي من الرتبة P ويشار اليه بالرمز AR(P).

أما النموذج الثاني يمثل نموذج المتوسطات المتحركة (MA)، حيث يعبر عن المتغير التابع y_t كدالة في قيم حد الخطأ السابقة كالتالي: $y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$ حيث تشير θ_i الى معاملات المتوسطات المتحركة وتشير q الى رتبة المتوسطات المتحركة، أما ε_{t-i} فهي تعبر عن القيم الماضية لحد الخطأ. ويطلق على هذا النموذج نموذج المتوسطات المتحركة من الرتبة q ويشار اليه بالرمز MA(q).

ل للوصول الى نموذج يجمع بين النموذجين السابقين يتم دمج AR(P) و MA(q) للحصول على نموذج ARMA كالتالي:

$$y_t = \varepsilon_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

ويسمى هذا النموذج بنموذج الانحدار الذاتي والمتوسطات المتحركة المختلط ويشار اليه بالرمز ARMA(p,q)

ويشترط هذا النموذج ان تكون السلسلة الاصلية y_t المستخدمة في التحليل ساكنة، فاذا كانت السلسلة الاصلية غير ساكنة يتم تحويلها الى ساكنة من خلال اخذ الفروق (d). وفي هذه الحالة يتحول النموذج من نموذج ARMA الى نموذج ARIMA (الانحدار الذاتي والمتوسطات المتحركة التكاملية) ويشار اليه بالرمز ARIMA(p,d,q).

ويعتبر نموذج ARIMA من أكثر النماذج استخداماً في التنبؤ، حيث يستخدم في التنبؤ بالمتغيرات الاقتصادية مثل أسعار السلع والتضخم وغيرها (Ansari and Meyler at al., 1998 ; Ahmed, 2001 ; Fkiring and Al-Turki, 1991)، كما انه يستخدم في التنبؤ بالمتغيرات غير الاقتصادية مثل تطور الامراض عبر الزمن (Purohit et al., 1998).

1.4. السكون:

يعتبر السكون من المفاهيم الهامة في تحليل السلاسل الزمنية ، فلا يمكن تطبيق مراحل منهجية بوكس - جينكنز في تحليل السلاسل الزمنية إلا إذا كانت السلسلة الزمنية محل الدراسة ساكنة حيث أن أول افتراض يتم اختباره هو التحقق من سكون السلسلة (Matroushi, 2011) . ويعني سكون السلسلة الزمنية أن تكون الخصائص الإحصائية لها ثابتة عبر الزمن لا تتغير بالإزاحة إلى الأمام أو إلى الخلف أي عدد من الوحدات الزمنية وهذه الخصائص الإحصائية يمكن وصفها بشكل مؤكد وكامل عن طريق دالة التوزيع التراكمي وبشكل جزئي عن طريق بعض المؤشرات الهامة وأهمها التوقع والتباين والتغاير لذلك يفرق العلماء بين نوعين من السكون هما السكون الضعيف والسكون التام (شعراوي , 2005) .

• السكون التام

يقال أن السلسلة الزمنية $\{Y_t, t = 0 \pm 1 \pm 2 \dots\}$ ساكنة سكون تاماً أو مؤكداً إذا كانت دالة التوزيع المشتركة للمتغيرات (Y_1, Y_2, \dots, Y_n) هي نفسها دالة التوزيع المشتركة للمتغيرات $(Y_{1+h}, Y_{2+h}, \dots, Y_{n+h})$ لأي فجوة زمنية h , $n > 0$ أي ان دالة التوزيع المشتركة للمتغيرات لها لا تتأثر بالإزاحة (Brockwell and Davis, 1996) .

• السكون الضعيف

يقال أن السلسلة الزمنية $\{Y_t, t = 0 + 1 + 2 \dots + n\}$ ساكنة (بالمعنى الضعيف) إذا تحققت الشروط الآتية (شعراوي، 2005) :

1 - التوقع أو متوسط العملية μ_t لا يعتمد على الزمن t أي أن:

$$\mu_t = E(Y_t) = \mu ; t = 0 \pm 1 \pm 2, \dots$$

2 - التباين σ_t^2 لا يعتمد على الزمن t أي أن :

$$\sigma_t^2 = V(Y_t) = \gamma(0) ; t = 0 \pm 1 \pm 2, \dots$$

3 - التغاير بين أي متغيرين يعتمد فقط على الفجوة الزمنية التي تفصل بينهما :

$$\text{cov}(Y_{t-k}, Y_t) = \gamma(k) ; t = 0 \pm 1 \pm 2, \dots ; k = 0 \pm 1 \pm 2, \dots$$

ونظراً لصعوبة تحقق شروط السكون التام فإننا في مجال الإحصاء لا نشترط عادة أن تكون السلسلة مؤكدة السكون ، ولكن نكتفي فقط بالسكون الضعيف (Matroushi, 2011) .

2.4. مراحل منهجية بوكس وجينكنز:

تتكون منهجية بوكس وجينكنز من أربعة مراحل رئيسية يتم من خلالها الوصول الى النموذج الامثل للتنبؤ بالسلسلة الزمنية محل الاهتمام. وتتلخص المراحل الاربعة الاساسية كالتالي:

أولاً: مرحلة التعرف : Identification

تعتبر مرحلة التعرف من أهم مراحل النموذج حيث يتم من خلالها تحديد رتب النموذج p, d, q ، حيث تبدأ مرحلة التعرف بالتحقق من سكون السلسلة الزمنية من خلال التأكد من توفر شروط السكون، حيث يمكن التحقق من السكون بيانياً من خلال الرسم البياني لكل من السلسلة الأصلية y_t ودالة الارتباط الذاتي للسلسلة ACF ودالة الارتباط الذاتي الجزئي للسلسلة PACF . وإحصائياً من خلال استخدام عدة اختبارات للكشف عن سكون السلسلة مثل: ADF , PP , $KPSS$. وبعد الحصول على السلسلة الزمنية الساكنة يتم تحديد رتب النموذج، حيث d عدد الفروق اللازمة لتسكين السلسلة، وبناءاً على عدد معاملات الارتباط الذاتي التي تختلف عن الصفر يتم تحديد q ، وبناءاً على عدد معاملات الارتباط الذاتي الجزئي التي تختلف عن الصفر يتم تحديد p (الوصيفي، 2012).

ثانياً: مرحلة التقدير : Estimation

بعد الانتهاء من مرحلة التعرف على النموذج المبدئي الملائم للبيانات يجب تقدير معالم هذا النموذج باستخدام إحدى الطرق المعروفة في نظرية الاحصاء، وأهمها طريقتي المربعات الصغرى والامكان الأكبر (شعراوي، 2005)، وفي هذه المرحلة عادة يتم تقدير عدة نماذج مقاربية يتم المقارنة بينها، وعادة تكون معالم النموذج الجيد المقدرة معنوية وكذلك يمكن المقارنة من خلال مجموع مربعات البواقي كمقياس لجودة النموذج (Enders, 1995). بالإضافة الى مقاييس أخرى يتم استخدامها لقياس دقة النموذج للمقارنة بين النماذج.

ثالثاً: مرحلة التشخيص : Diagnostic

بعد التعرف على النموذج المبدئي وتقدير معالمه تأتي مرحلة التشخيص وهي التحقق من مدى ملائمة النموذج وإمكانية استخدامه في التنبؤ. وتعتبر مرحلة التشخيص من أهم وأخطر مراحل التحليل فهي المرحلة التي تحدد قبول أو استبدال النموذج بنموذج آخر. وتشتمل مرحلة التشخيص على اجراء العديد من الفحوصات والاختبارات أهمها: تحليل السكون وتحليل الانعكاس، تحليل البواقي ، توفيق النموذج الأدنى والاعلى مباشرة (شعراوي، 2005).

رابعاً: مرحلة التنبؤ : Forecasting

من الأهداف الرئيسية في تحليل السلاسل الزمنية هو التنبؤ بقيمها المستقبلية، وتعتبر مرحلة التنبؤ هي المرحلة الرابعة والاخيرة من مراحل بوكس وجينكز . حيث أن التنبؤات المستقبلية للسلسلة الزمنية تكون صحيحة ودقيقة اذا تم اختيار نموذج سليم واجتاز مرحلة الفحص والتشخيص.

5. معايير التقييم: Evaluation Criteria

تحديد رتب نموذج ARIMA باستخدام دوال الارتباط الذاتي والذاتي الجزئي تعتبر مهمة صعبة يواجهها الباحث الذي يجد نفسه أمام عدة نماذج مرشحة ولا تكون جميعها مرفوضة، لهذا السبب تم وضع بعض المعايير التي تساعد في المفاضلة بين النماذج المرشحة، حيث يتم اختيار النموذج الأفضل الذي يملك أقل قيمة لهذه المعايير (Matroushi, 2011). ومن هذه المعايير الإحصائية:

• معيار معلومات أكاي (AIC) Akaike Information Criterion :

$$AIC = -2 \log(\text{maximum likelihood}) + 2k$$

حيث k تمثل عدد معلمات النموذج وتساوي $p + q + 1$ في حالة ما إذا كان النموذج يحتوي على مقدار ثابت أما إذا كان النموذج لا يحتوي على مقدار ثابت فإن $p + q = k$

• معيار المعلومات البيزي (BIC) Bayesian Information Criterion :

طريقة أخرى لتحديد رتب نموذج ARIMA وهي معيار المعلومات البيزي BIC حيث يكون النموذج الأفضل هو الذي يجعل قيمة BIC أقل ما يمكن وبأخذ هذا المعيار الصيغة الآتية

$$BIC = -2 \log(\text{maximum likelihood}) + k \log(n)$$

• متوسط مربعات الأخطاء (MSE) Mean Square Error :

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 = \frac{1}{n} \sum_{t=1}^n e_t^2 ; RMSE = \sqrt{MSE}$$

• متوسط الخطأ المطلق (MAE) Mean Absolute Error :

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| = \frac{1}{n} \sum_{t=1}^n |e_t|$$


• متوسط الأخطاء النسبية المطلقة (MAPE) Mean Absolute Percentage Error :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{y_t} \right|$$

6. الجانب التطبيقي


تم الحصول على البيانات المستخدمة في البحث والمتعلقة بالسلسلة الزمنية السنوية لإنتاج القمح في الصين (بالمليون طن) من وزارة الزراعة الأمريكية USDA . وذلك عن الفترة الزمنية من عام 1960 حتى عام 2010 (51 مشاهدة) . وسيتم تحليل بيانات البحث باستخدام البرنامج الإحصائي R .

في بداية مرحلة التعرف يجب التأكد من سكون السلسلة الأصلية وذلك من خلال الرسم البياني للسلسلة الأصلية، ويتضح من شكل (1) أن السلسلة الزمنية لإنتاج القمح في الصين أن لها اتجاه عام متزايد، مما يعني ان السلسلة الزمنية غير ساكنة.
شكل (1): السلسلة الأصلية لإنتاج القمح في الصين



ولتسكين السلسلة تم أخذ الفروق الاولى للسلسلة الأصلية ولم تسكن فتم أخذ الفروق الثانية لها فوجدت انها ساكنة، ويتضح ذلك من شكل (2) التالي:

شكل (2): السلسلة الزمنية لإنتاج القمح في الصين بعد أخذ الفروق الثانية



وللتأكد على ما سبق، تم استخدام الاختبارات الإحصائية للتأكد من سكون السلسلة، والتي توضح سكون السلسلة بعد اخذ الفروق الثانية لها، ويتضح ذلك من جدول (1) التالي:


Using Box-Jenkins Methodology for Forecasting Wheat Production

جدول (1): نتائج اختبارات فحص سكون السلسلة (P-value)

اختبار	السلسلة الاصلية	الفروق الاولى	الفروق الثانية
اختبار ADF	0.6875	0.0750	0.01
اختبار PP	0.6742	0.0684	0.01
اختبار KPSS	0.01	0.01	0.1

بعد تسكين السلسلة وإجراء الاختبارات اللازمة للتأكد من سكونها عند $d=2$ ، يتلو ذلك تحديد رتبة الانحدار الذاتي p ورتبة المتوسطات المتحركة q للنموذج $ARIMA(p,2,q)$. ومن خلال شكل (3) التالي لدالتي الارتباط الذاتي والذاتي الجزئي للفروق الثانية للسلسلة الأصلية ان النموذج المقترح هو $ARIMA(0,2,1)$.

شكل (3) : دالة الارتباط الذاتي والذاتي الجزئي للفروق الثانية للسلسلة الأصلية



وسوف نقوم بترشيح نماذج أعلى وأدنى مباشرة من النموذج المقترح للمقارنة فيما بينها واختيار النموذج الأفضل والنهائي، من خلال استخدام بعض معايير التقييم. ويشير جدول (2) التالي أيضا أن النموذج الأمثل هو $ARIMA(0,2,1)$.

جدول (2): مقارنة بين النموذج المقترح والنماذج الاعلى والادنى منه مباشرة

BIC	AIC	MAPE	MAE	RMSE	Model
17.5276	17.4897	7.04897	4681.69	6156.33	ARIMA(0,2,1)
17.5408	17.5029	8.28157	4856.51	6197.17	ARIMA(1,0,0)
17.5323	17.5123	8.68768	5179.8	6349.47	ARIMA(0,1,0)
17.6244	17.5486	7.07249	4751.18	6217.36	ARIMA(0,2,2)
17.6248	17.549	7.09528	4761.32	6218.48	ARIMA(1,2,1)

وبعد التعرف على النموذج الامثل ARIMA(0,2,1) سوف يتم تقدير معالمه، وهو

يحتوي على معلمة واحدة فقط هي $\hat{\theta}_1$ ، ويتضح ذلك من الجدول التالي:

جدول (3): نتائج تقدير معالم النموذج

المعلمة	التقدير	الخطأ المعياري	قيمة t	P-value
$\hat{\theta}_1$	0.981882	0.0157084	62.5067	0.0000

وبالاعتماد على النتائج السابقة، فإن معادلة النموذج المقدرة كما يلي:

$$\phi(B) \nabla^2 y_t = \theta(B) \varepsilon_t$$

$$(1-B)^2 y_t = (1-\theta_1 B) \varepsilon_t$$

$$y_t = 2y_{t-1} - y_{t-2} - 0.9801 \varepsilon_{t-1} + \varepsilon_t$$

إن مرحلة فحص وتشخيص النموذج الذي تم التوصل اليه هي المرحلة التالية وهي من أهم المراحل التي من خلالها يمكن اعتماد النموذج المقترح نهائيا لعملية التنبؤ الاخيرة. ويعتبر تحليل البواقي جزء أساسي ومرحلة مهمة لمعرفة مدى صلاحية النموذج ARIMA(0,2,1) المستخدم للتنبؤ، ومن خلال شكل (4) التالي والذي يحتوي على ثلاث أجزاء.


الجزء الاول يوضح ان البواقي تتأرجح بشكل ثابت حول الصفر، اي ان خصائص البواقي

تحققت $\varepsilon_t \sim N(0, \sigma^2)$. بينما الجزء الثاني يبين قيم معاملات الارتباط للبواقي $r_e(k)$ عند

Using Box-Jenkins Methodology for Forecasting Wheat Production

كل فجوة زمنية من 1 - 25 نجد أنها جميعا تقع داخل حدي فترة الثقة، وهذا دليل على استقلال البواقي حيث ان معاملات الارتباط الذاتي للبواقي لا تختلف معنويا عن الصفر. أما الجزء الاخير فهو يتعلق باختبار Ljung-Box ، حيث كانت قيم P-value عند الفجوات الزمنية جميعها أكبر من 0.05، مما يدل على ان البواقي مستقلة.

شكل(4): نتائج تحليل البواقي



وبناء على ما سبق، يمكننا التأكيد على أن نموذج $ARIMA(0,2,1)$ تجاوز مرحلة الفحص والتشخيص ويمكن استخدامه في التنبؤ.


وباستخدام نموذج $ARIMA(0,2,1)$ تم التنبؤ بالقيم المستقبلية لإنتاج القمح في الصين خلال العشر سنوات القادمة من عام 2011 حتى عام 2020، حيث سيتم مقارنة الاربع قيم الاولى المتنبأ بها مع الاربع قيم الاولى الفعلية من عام 2011 حتى عام 2014. ويتضح ذلك من الجدول التالي:

جدول (4): القيم التنبؤية (مليون طن) لنموذج $ARIMA(0,2,1)$

القيم التنبؤية	القيم الفعلية	السنة
117.864	117.400	2011
119.748	121.023	2012
121.633	121.930	2013
124.592	126.000	2014
126.486	-	2015
128.370	-	2016
130.255	-	2017
132.139	-	2018
134.024	-	2019
136.912	-	2020

وشكل (5) التالي يوضح بيانات القيم الفعلية من 1960 حتى عام 2010 مضافا إليها القيم المتنبأ بها من عام 2011 حتى عام 2020، حيث تشير التنبؤات المستقبلية ان هناك استمرار في الانتاج المتزايد من القمح في الصين.

شكل (5): القيم الفعلية والتنبؤية لإنتاج القمح في الصين من عام 1960 – 2020



7. ملخص النتائج

- السلسلة الزمنية لإنتاج القمح في الصين لها اتجاه عام متزايد، مما يعني انها غير ساكنة.
- تحقق خصائص البواقي في النموذج $ARIMA(0,2,1)$ ، وتجاوز مرحلة الفحص والتشخيص.
- النموذج الامثل للتنبؤ بإنتاج القمح في الصين هو $ARIMA(0,2,1)$.

Using Box-Jenkins Methodology for Forecasting Wheat Production

- هناك تقارب بين القيم التنبؤية والقيم الفعلية خلال الفترة (2011-2014).
- هناك تزايد في انتاج القمح في الصين خلال السنوات القادمة (2015-2020).

8. المراجع

الوصيفي، الشيماء (2012). "التنبؤ باستخدام الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكينز: دراسة تطبيقية"، رسالة ماجستير غير منشورة، جامعة المنصورة، مصر.

شعراوي، سمير، (2005). "مقدمة للتحليل الحديث للسلاسل الزمنية"، جامعة الملك عبد العزيز، السعودية.

منظمة الاغذية والزراعة (2015). "حالة الاغذية في العالم"، منظمة الاغذية والزراعة.

Ajoy, A. (2005). "Computational Intelligence in Time series Forecasting", spring.

Amin, M., Amanullah, M., and Akbar, A. (2014). "TIME SERIES MODELING FOR FORECASTING WHEAT PRODUCTION OF PAKISTAN", The Journal of Animal & Plant Sciences, 24(5), Pakistan.

Ansari, M. and Ahmed, S., (2001) "Time Series Analysis of Tea Prices: An Application of ARIMA Modelling and Cointegration Analysis", *The Indian Economic Journal*. Vol. 48 (3): 49-54.

Brockwell, P.J., and Davis, R.A., (1996). Introduction to Time Series and Forecasting, Springer, New York .

Bowerman, B., Richard, T. and Anne, B. (2005). "Forecasting Time Series and Regression, 4th ed, Belmont, CA: Thomson Brooks/Cole.

El-Shehawy, M. A., Ahmed, R. A. and Qian, L. (2011). "Production Trends of China's Wheat (1990-2008)", Australian Journal of Basic and Applied Sciences, 5(5), Australian.

Enders, W. (1995) "Applied Econometric Time Series", John Wiley and Sons Inc. N. Y.

Fkiring, M. and Al-Turki, I. (1991) "Forecasting Agricultural Economic Systems", *Cybernetics and Systems: An International Journal*, 22: 17-24.

- GIMMYT, (1996). "GIMMYT 1995-96 World Facts and Trends: Understanding Global Trends in the Use of Wheat Diversity and International Flows of Wheat Genetic Resources, Mexico.
- Karim, R., Awal, A. and Akter, M. (2010) "FORECASTING OF WHEAT PRODUCTION IN BANGLADESH", Bangladesh Journal Agricultural Researches, 35(1), Bangladesh.
- Matroushi, S., (2011). " Hybrid computational intelligence systems based on statistical and neural networks methods for time series forecasting: the case of gold price" , Lincoln University, United Kingdom.
- Meyler, A., Kenny, G. and Quinn, T., (1998) "*Forecasting Irish Inflation Using ARIMA Models*", Central Bank of Ireland, Technical Paper.
- Purohit, S., Kelkar, S. and Simha, V., (1998) "Time Series Analysis of Patients with Rotavirus Diarrhoea in Pune, India", *J. Diarrhoeal Disease Research Bangladesh*. Jun: 16 (2): 74-83.
- Saeed, N., Saeed, A., Zakria, M. and Bajwat. M. (2000). "Forecasting of Wheat Production in Pakistan using Arima Models, International Journal of Agriculture & Biology , Vol. 2:No. 4, Pakistan.
- Tian, W. M., Zhou, Z. Y. and Cao, Y. Y. (2000). " Changing Patterns of Wheat Production and Consumption in China: Trade Implications" , Australian Agricultural and Resource Economics Society, the University of Sydney, Australia.