

استخدام منجھية بوكس جينكنز والشبكات العصبية الاصطناعية للتنبؤ بإنتاج المحاصيل الزراعية دراسة حالة مشروع حلفا الجديدة.

منتصر أحمد عثمان مجّد

جامعة كسلا - كلية التربية - قسم الرياضيات (احصاء)

المستخلص

تم في هذه الدراسة تقدير نموذجين إحصائيين للتنبؤ بإنتاج كل من القمح، القطن و الفول السوداني في مشروع حفا الجديدة الزراعي. أحد النموذجين قدر بطريقة بوكس-جينكنز و الآخر باستخدام خوارزميات الشبكات العصبية الاصطناعية بهدف المقارنة بين النموذجين من حيث الكفاءة في التنبؤ.المفاضلة بين النماذج المقدره تمت بناءً على عدد من المقاييس الإحصائية مثل الخطأ المعياري للنموذج ($RMSE$)، متوسط الخطأ المطلق (MAE)، متوسط نسبة الخطأ المطلق ($MAPE$) و معيار معلومات بيز (BIC). و قد خلصت الدراسة إلى أن النماذج المقدره باستخدام الشبكات العصبية الاصطناعية أكثر كفاءةً من النماذج الأخرى و لجميع المحاصيل الزراعية. أوصت الدراسة بالعديد من التوصيات أهمها تصميم خوارزميات شبكات عصبية خاصة بالتنبؤ بإنتاج المحاصيل الزراعية.

كلمات مفتاحية: معيار معلومات بيز، السلاسل الزمنية، الشبكات العصبية الاصطناعية

Abstract

Two statistical models are designed in this study to predict the yield of wheat, cotton and peanut in “New Halfa” agriculture project. Box-Jenkins models are used to fit the first model whereas artificial neural networks are used to fit the second model. The models are compared in term of prediction efficiency. The comparison between models is depended on model’s Root of Mean Sum Error (RMSE), mean of absolute error (MAE), Mean of Absolute Percentage Error (MAPE) and Bayesian Information Criteria (BIC). The study concludes that, the artificial neural networks models are more effective for all crops. Many recommendations are mentioned in the study, but most important of which is the artificial neural network algorithms design specialized for crop yield forecasting.

مقدمة

تزايد الاهتمام بقدير و التنبؤ بإنتاج المحاصيل الزراعية على مستوى العالم بسبب التزايد المطرد في عدد سكان الكرة الأرضية حيث تشير الإسقاطات السكانية إلى أن حجم السكان سوف يبلغ ٩.٣ مليار بحلول العام ٢٠٥٠ حسب تقديرات الأمم المتحدة (UN, 2017). و بما أن المحاصيل الزراعية المختلفة هي الغذاء الرئيس لجميع السكان، كان الاهتمام بتقديرها و التنبؤ بإنتاجها ذو أهمية بالغة لمعرفة ما يمكن أن يتحقق فيما يتعلق بالأمن الغذائي العالمي، حيث تشير التقارير إلى عدم تلبية الطلب المتزايد على الغذاء بعض المناطق (FAO, 2017) و (Michel & Makowski, 2013). و قد بلغت الزيادة العالمية في إنتاج الحبوب ٩٨% خلال الفترة ١٩٦٠-١٩٩٠، و لكن الوضع يختلف الآن حيث هنالك ركود في ذلك الإنتاج في بعض الدول (FAOSTAT, 2018). و بما أن التقدير والتنبؤ مهمة إحصائية فقد لعبت النماذج الإحصائية المختلفة دوراً أساسياً في

الدراسات الحالية التي تبحث الأمن الغذائي و تقديره. العديد من النماذج الإحصائية مثل نماذج الانحدار بأنواعه المختلفة، تحليل السلاسل الزمنية و الشبكات العصبية جميعها استخدمت في هذا الصدد. يعزى شيوع استخدام تحليل نماذج السلاسل الزمنية في التنبؤ بإنتاج المحاصيل الزراعية لتوفر تلك البيانات في صورة سلاسل زمنية. فقد استخدمها "بوكن" للتنبؤ بإنتاج القمح في كندا خلال الفترة ١٩٧٥-١٩٩٦ (Boken, 2000). وفي دراسة قدمها "مايكل" و "ماكوسكي" لتقدير إنتاج القمح العالمي بغرض معرفة مدى إمكانية تحقيق الأمن الغذائي في المستقبل مع الزيادة الحاصلة في السكان تم استخدام نماذج السلاسل الزمنية لهذا الغرض (Michel & Makowski, 2013). و استخدمت نماذج أريما لتقدير إنتاج المحاصيل الشتوية في الهند (Sahu, 2006). إضافةً إلى نماذج السلاسل الزمنية فقد أثبتت خوارزميات الشبكات العصبية الاصطناعية كفاءة مقدرتها في التقدير و التنبؤ بإنتاجية المحاصيل الزراعية. فقد استخدمت هذه الشبكات للتنبؤ بإنتاج السكر في الهند و أثبتت دقة عالية في التقدير (Sunil et al, 2015). و في استراليا قام "شاستري" باستخدام الشبكات العصبية و مقارنة نتائجها في التنبؤ مع النتائج الانحدار الخطي المتعدد و أوضحت دراسته كفاءة الشبكات العصبية في التنبؤ (Shastri et al, 2016). و أيضاً قام بدراسات مشابهة كل من (Ranjeet & Armstrong, 2014)، (I et al, 2007)، و (Abhishek and Anu, 2017). يتم في هذا البحث تقدير نموذجين إحصائيين للتنبؤ بإنتاج كل محصول من المحاصيل الزراعية الثلاثة المستهدفة بمشروع حلفا الجديدة الزراعي. و المحاصيل المستهدفة هي القمح، القطن و الفول السوداني، و قد توفر سلسلة زمنية بطول ٥١ سنة خلال الفترة ١٩٦٤-٢٠١٤ عن إنتاج هذه المحاصيل. ففي البحث يتم تقدير نموذج باستخدام منهجية بوكس-جينكس و آخر عن طريق خوارزمية شبكة عصبية اصطناعية لكل محصول زراعي. إضافة إلى تقدير النماذج يهدف البحث إلى المقارنة بين كل نموذجين للمحصول الواحد من حيث كفاءة النموذج في التقدير و الخطأ الناتج عن تطبيقه. المفاضلة بين النماذج المقدرتها للتنبؤ سوف تتم بناءً على عدد من المقاييس الإحصائية مثل الخطأ المعياري للنموذج (RMSE)، متوسط الخطأ المطلق (MAE)، متوسط نسبة الخطأ المطلق (MAPE) و معيار معلومات بيز (BIC).

منهجية و بيانات الدراسة

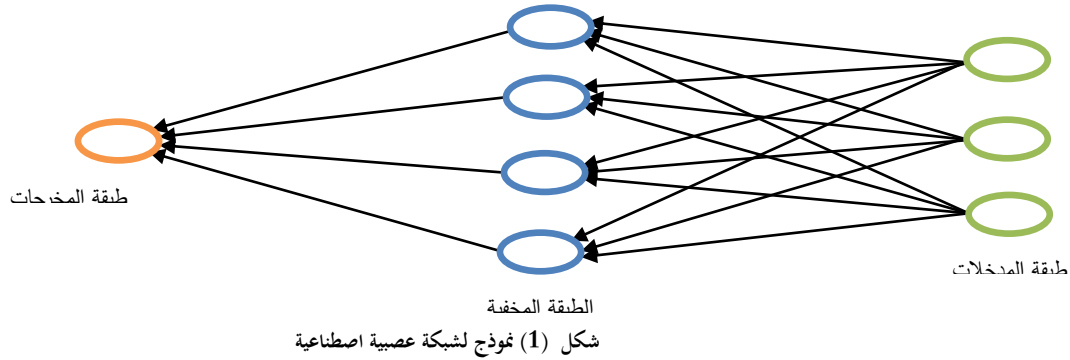
نماذج بوكس-جينكس: تعتبر (Box and Jenkins, 1976) من أشهر الطرق الإحصائية التي تستخدم في التنبؤ بالسلاسل الزمنية. و تضم هذه النماذج بصورة عامة نماذج الانحدار الذاتي (AR(P)) و نماذج المتوسطات المتحركة (MA(q)) و النماذج المختلطة أو نماذج الانحدار الذاتي- المتوسط المتحرك (ARMA(p,q)) إضافة إلى نماذج الانحدار الذاتي التكاملية المتوسط المتحرك (ARIMA(p,d,q)) و قد أورد أندرسون تحليلاً معمقاً لهذه النماذج (Andereson, 1971). و الصيغة العامة لنماذج ARIMA هي:

$$\hat{y}_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (1)$$

حيث \hat{y}_t هي القيمة المتنبأ بها عند الزمن t ، y_t هي القيم الحقيقية للمتغير في الفترات السابقة بعد أخذ الفرق (d) الذي يجعل السلسلة مستقرة، ϕ هي معامل المتوسطات المتحركة، θ هي معامل الإرتباط الذاتي للأخطاء و μ هو الثابت (Box and Jenkins, 1976).

و من الشائع جداً استخدام نماذج السلاسل الزمنية في التنبؤ بإنتاج المحاصيل الزراعية، فقد استخدمها "بوكن" للتنبؤ بإنتاج القمح في كندا خلال الفترة ١٩٧٥-١٩٩٦ و أظهرت نتائجه بأن النموذج التربيعي هو الأنسب للتقدير (Boken, 2000). و في دراسة قدمها "مايكل" و "ماكوسكي" لتقدير إنتاج القمح العالمي بغرض معرفة مدى إمكانية تحقيق الأمن الغذائي في المستقبل مع

الزيادة الحاصلة في السكان تم استخدام نماذج السلاسل الزمنية لهذا الغرض (Michel & Makowski, 2013). و استخدمت نماذج أربما لتقدير إنتاج المحاصيل الشتوية في الهند (Sahu, 2006).
الشبكات العصبية الاصطناعية (ANN) : طريقة برمجة رياضية تحاكي طريقة عمل الدماغ البشري من حيث قدرته على التذكر و التعلم. و تتكون الشبكة العصبية الاصطناعية عدة طبقات، حيث تحوي الطبقة مجموعة من الخلايا العصبية بينها وصلات كما يوضح الشكل ١. ويوجد بالشبكات العصبية ثلاث أنواع من الطبقات، طبقة المدخلات (المتغيرات المستقلة) و طبقة المخرجات (المتغير التابع) و توجد بين الاثنتين طبقة مخفية واحدة كحد أدنى. تحوي كل طبقة مجموعة الخلايا العصبية و تتصل كل خلية بوصلات عصبية مع جميع الخلايا في الطبقة السابقة و اللاحقة لها مما يتيح أكبر قدر ممكن من التعلم.



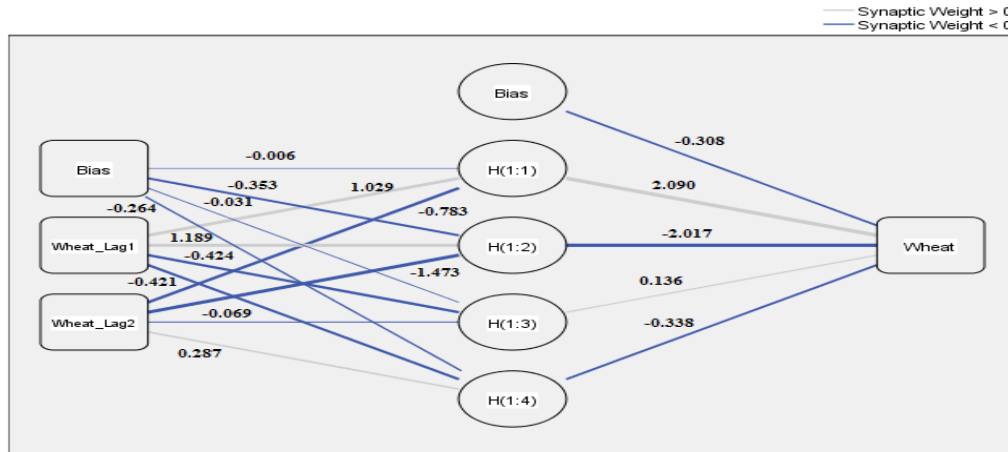
تتكون كل خلية عصبية من ثلاث عناصر رئيسية و هي الوزن، الجامع و دالة التفعيل. الوزن عبارة عن رقم مجرد يعطى لكل رابط بين الخلية و الخلية التي تتصل بها في الطبقة التالية، و يقوم هذا الوزن بتصغير أو تكبير قيمة المدخل من الخلية الأولى. و يتم تعديل هذه الأوزان في كل عملية إدخال بناءً على الانحراف بين قيمة المخرج الحقيقية و قيمته المقدرة من الشبكة العصبية بغرض تحسين أداء الشبكة. هنالك عدد من الطرق التي يتم استخدامها لحساب و تعديل أوزان الروابط بين الخلايا العصبية و أشهرها و أكثرها قاعدة "هب" (Hebb, 1949) و طريقة الانتشار الخلفي (Backpropagation) (Werbos, 1975). أما الجامع فهو حاصل جمع جميع قيم المدخلات الواردة إلى الخلية المعنية كل مضروب في الوزن المقابل له. و دالة التفعيل هي دالة إحصائية يتم فيها إدخال قيمة الجامع لتعطي المخرج النهائي للخلية العصبية المعنية. تتعدد دوال التفعيل و أنواعها بحسب البيانات المراد نمذجتها و بناء الشبكة العصبية لمحاكاتها، و منها الدالة اللوجستية، دالة الوحدة، دالة "السوفتسين" (Softsign)، دالة معكوس مربع جزر الوحدة و الدالة الطبيعية وغيرها (Haykin, 1999)، (Snyman, 2005)، (Wu, 2009)، (Gashler & Ashmore, 2014)، (Forest et al., 2014). و تكون الدالة الممثلة للشبكة العصبية كم يلي:

$$f(x) = K \left(\sum_i w_i x_i \right) \quad (2)$$

حيث K تمثل دالة التفعيل، w تمثل الأوزان و x تمثل المدخلات. وقد أثبتت الدراسات فاعلية وكفاءة عالية لهذه الخوارزميات في قدرتها على التنبؤ. فقد استخدمت هذه الشبكات للتنبؤ بإنتاج السكر في الهند و أثبتت دقة عالية في التقدير (Sunil et al, 2015). و في استراليا قام "شاستري" باستخدام الشبكات العصبية و مقارنة نتائجها في التنبؤ مع النتائج الانحدار الخطي المتعدد و أوضحت دراسته كفاءة الشبكات العصبية في التنبؤ (Shastri et al, 2016). و أيضاً قام بدراسات مشابهة كل من (Ranjeet & Armstrong, 2014)، (I et al, 2007) و (Abhishek and Anu, 2017). في هذا البحث استخدمت خوارزمية شبكة عصبية باستخدام برنامج التحليل الإحصائي SPSS₂₄ للتنبؤ ببيانات المحاصيل الزراعية

المذكورة. و هذه الخوارزمية استخدمت دالة الوحدة كدالة تفعيل في طبقة المخرجات، بينما استخدمت الدالة الزائدية لظلال الزاوجية كدالة تفعيل في الطبقة المخفية كما يظهر ذلك في الأشكال التي تمثل المخرجات (الأشكال 3-5) و كان معامل تعديل الأوزان 0.05. علماً بأن قيمة دالة الوحدة تساوي المتغير نفسه $f(x) = x$ ، بينما دالة الظلال الزائدية هي $f(x) = \tanh(x)$. و فيما يتعلق بتدريب الشبكة العصبية فإن 70% من السلسلة الزمنية الخاصة بكل محصول استخدمت لتدريب الشبكة العصبية بينما 30% من البيانات كانت لإختبار الخوارزمية. و استخدم لهذا جهاز لابتوب بمعالج Dual-Cure و ذاكرة 2 فيقبايت و نظام معالجة 32 بت.

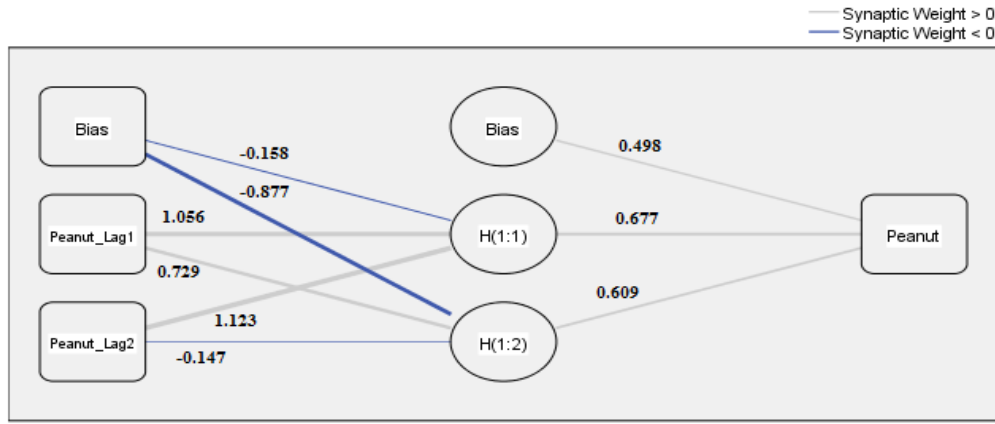
النتائج و المناقشة: تم تقدير نموذجين لكل محصول من القمح، الفول السوداني و القطن. أحد النموذجين قُدر باستخدام نماذج بوكس-جينكز والآخر بالشبكات العصبية الاصطناعية. وسوف تتم المقارنة بين دقة النموذجين في تقدير البيانات. بالنسبة لمحصول القمح تم تقدير عدد من نماذج بوكس-جينكز و كان الأنسب من بينها لبيانات المحصول هو نموذج $ARIMA(0,1,1)$ و النموذج المقدر هو $y_t = 0.007 + y_{t-1} - 0.681a_{t-1} + a_t$ حيث a_t تمثل سلسلة الضجة البيضاء، وقد كان معامل الارتباط الذاتي من الدرجة الأولى معنوياً حيث بلغت قيمته الاحتمالية 0.000000. و النموذج الأكثر ملائمة لمحصول الفول السوداني بين نماذج بوكس-جينكز فهو $ARIMA(0,1,1)$ أيضاً و كان النموذج بالصيغة $y_t = 0.022 + y_{t-1} - 0.745a_{t-1} + a_t$ و كل من الثابت ومعامل الانحدار من الدرجة الأولى كانا معنويين إذ القيم الاحتمالية لهما 0.0024 و 0.0000 على التوالي. أما محصول القطن فكان النموذج أربما الملائم له $ARIMA(1,0,1)$ و النموذج هو $y_t = 4.088 + 0.451y_{t-1} - 0.123a_{t-1} + a_t$ و أظهرت النتائج أنه معنوي حيث كانت القيمة الاحتمالية 0.000000. للتقدير بطريقة الشبكات العصبية تم استخدام بيانات السلسلة الزمنية في السنتين السابقتين للسنة الحالية (y_{t-1} و y_{t-2}) كمتغيري تفسير (مدخلات) يمكن من خلالهما التنبؤ بقيمة السلسلة في السنة الحالية، و ذلك لجميع المحاصيل سابقة الذكر. و كانت الشبكة العصبية لكل محصول تتكون من طبقة مخفية واحدة تحوي عدد من الخلايا العصبية إضافة لطبقتي المدخلات و المخرجات.



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

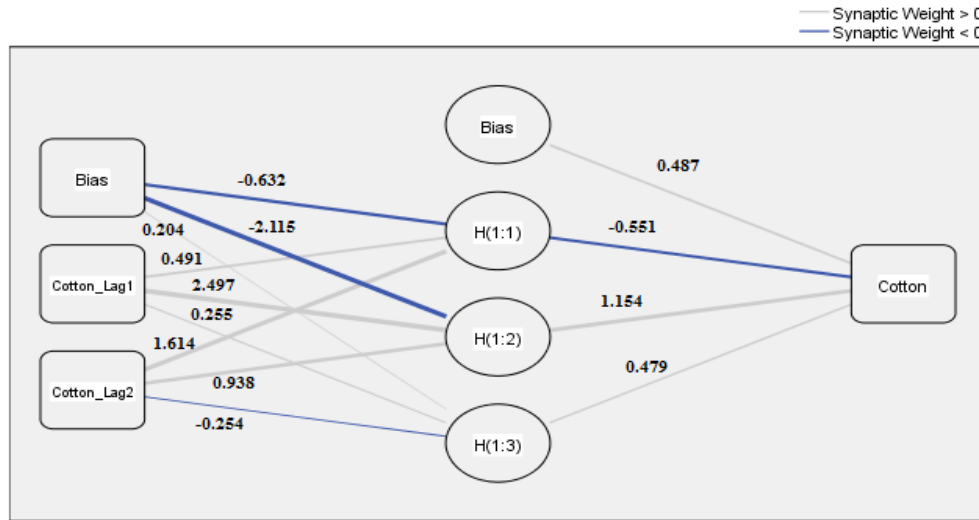
شكل (2) خوارزمية شبكة عصبية للتنبؤ بإنتاج محصول القمح



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

شكل (٣) خوارزمية شبكة عصبية للتنبؤ بإنتاج محصول الفول السوداني



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

شكل (٤) خوارزمية شبكة عصبية للتنبؤ بإنتاج محصول القطن

الأشكال الثلاثة أعلاه تبين خوارزمية الشبكة العصبية التي تم استخدامها لتقدير المحاصيل الزراعية الثلاث بمشروع حلقة الجديدة، وقد تكونت كل شبكة من ثلاث طبقات و يختلف عدد خلايا الطبقة الخفية بين محصول و آخر. المفاضلة بين النموذجين المقدرين للتنبؤ بكل محصول تتم بناءً على عدد من المقاييس الإحصائية و هي الخطأ المعياري للنموذج ($RMSE$)، متوسط الخطأ المطلق (MAE)، متوسط نسبة الخطأ المطلق ($MAPE$) و معيار معلومات بيبز (BIC) و هذه المقاييس تحسب من الصيغ التالية:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (3)$$

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (4)$$

$$MAPE = \text{mean}(|p_t|) \quad (5)$$

حيث:

$$p_t = \frac{y_t - \hat{y}_t}{y_t} * 100 \quad (6)$$

$$BIC = n\{\ln(\hat{\sigma}_e^2)\} + k\{\ln(n)\} \quad (7)$$

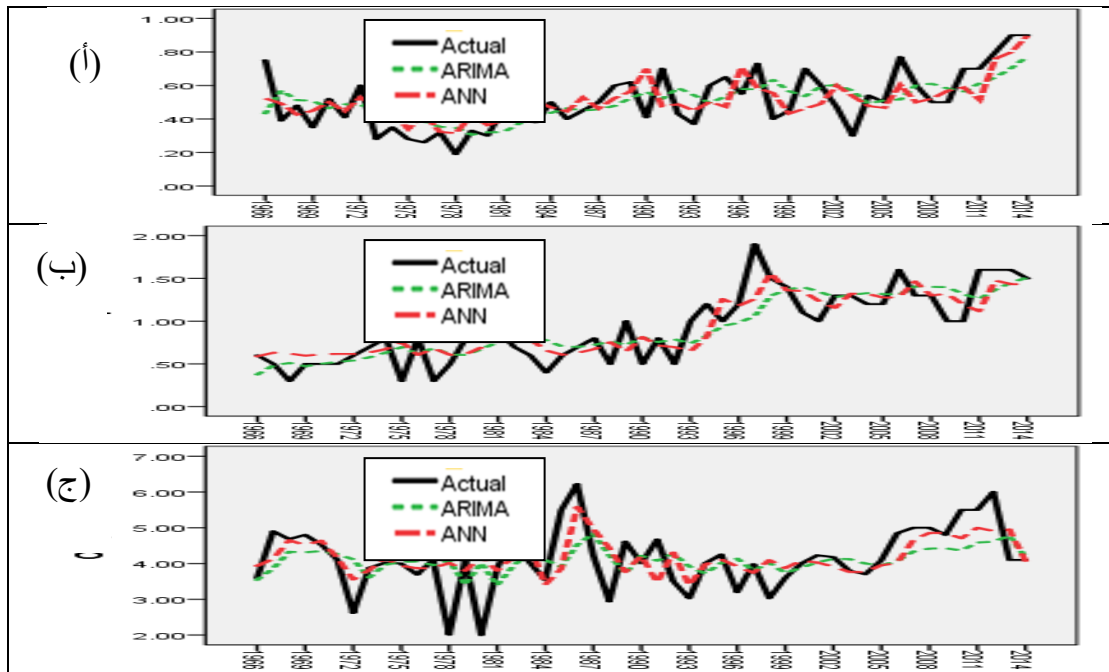
حيث y_t تمثل قيمة المتغير عند الزمن t ، \hat{y}_t تمثل القيمة المقدرة للمتغير عند الزمن t ، n تمثل عدد البيانات، k تمثل عدد معاملات النموذج و $\hat{\sigma}_e^2$ هو تباين حد الخطأ للنموذج. استخدمت بيانات المحاصيل الثلاث لتقدير النماذج المذكورة، ثم لخصت المقاييس السابقة في الجدول ١ التالي لتتم عملية المقارنة بينها.

جدول (١) مقاييس الدقة لنموذجي *ARIMA* و *ANN* المستخدمة لتقدير إنتاج المحاصيل الزراعية

المحصول	مقياس دقة النموذج	مقاييس الدقة			
		<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>BIC</i>
القمح	<i>ARIMA</i>	٠.١٤٠	٠.١١٩	٢٦.٠٨٥%	١٨١.١١٧-
	<i>ANN</i>	٠.١٢٥	٠.١٠٤	٢٢.٩٣٥%	١٩٢.٣٣٢-
القول السوداني	<i>ARIMA</i>	٠.٢٤٦	٠.١٩٢	٢٦.٥٠٠%	١٢٥.٨٧٣-
	<i>ANN</i>	٠.٢٣٣	٠.١٨٦	٢٦.٦٥٦%	١٣١.٢٦٤-
القطن	<i>ARIMA</i>	٠.٨١٤	٠.٦٢٥	١٧.٢٢٣%	٨.٤٦٦-
	<i>ANN</i>	٠.٧٢٦	٠.٥٠٧	١٤.٥٧٩%	١٩.٦٥٠-

المصدر: اعداد الباحث من مخرجات برنامج *spss*

يتبين من جدول (١) أن استخدام خوارزمية الشبكات العصبية للتنبؤ بمحصول القمح أدت إلى نتائج أفضل من طريقة نماذج أريما، حيث كانت جميع مقاييس دقة النموذج و التي تعتمد جميعها في طريقة حسابها على أخطاء النموذج كانت في حالة نماذج الشبكات العصبية أقل منها في حالة نماذج أريما مما يعني أفضلية الأولى. في حالة محصول الفول السوداني نجد أن طريقة الشبكات العصبية كانت هي الأفضل حسب جميع مقاييس دقة النموذج باستثناء متوسط النسبة المطلقة للخطأ يتبين من الجدول ١ أعلاه أن استخدام خوارزمية الشبكات العصبية للتنبؤ بمحصول القمح أدت إلى نتائج أفضل من طريقة نماذج أريما، حيث كانت جميع مقاييس دقة النموذج و التي تعتمد جميعها في طريقة حسابها على أخطاء النموذج كانت في حالة نماذج الشبكات العصبية أقل منها في حالة نماذج أريما مما يعني أفضلية الأولى. في حالة محصول الفول السوداني نجد أن طريقة الشبكات العصبية كانت هي الأفضل حسب جميع مقاييس دقة النموذج باستثناء متوسط النسبة المطلقة للخطأ (*MAPE*) حيث زاد قليلاً في حالة الشبكات العصبية عن قيمته في حالة نموذج أريما. أما محصول القطن فقد كان النموذج الأكثر ملائمة لتقديره حسب جميع مقاييس دقة النموذج المحسوبة سابقاً فهو نموذج الشبكات العصبية الاصطناعية. و بمقارنة أداء إسلوبتي التقدير المذكورين بين المحاصيل الثلاث نجد أن الفرق كان ضئيلاً بين الطريقتين في حالة محصول الفول السوداني. بالنسبة لمحصول القمح كان الفرق بين الطريقتين أكبر من سابقه. و في حالة محصول القطن فقد كان الفرق جليلاً و كبيراً بين أداء الشبكات العصبية الاصطناعية و نماذج أريما. حيث زاد قليلاً في حالة الشبكات العصبية عن قيمته في حالة نموذج أريما. أما محصول القطن فقد كان النموذج الأكثر ملائمة لتقديره حسب جميع مقاييس دقة النموذج المحسوبة سابقاً فهو نموذج الشبكات العصبية الاصطناعية. و بمقارنة أداء إسلوبتي التقدير المذكورين بين المحاصيل الثلاث نجد أن الفرق كان ضئيلاً بين الطريقتين في حالة محصول الفول السوداني. بالنسبة لمحصول القمح كان الفرق بين الطريقتين أكبر من سابقه. و في حالة محصول القطن فقد كان الفرق جليلاً و كبيراً بين أداء الشبكات العصبية الاصطناعية و نماذج أريما. الفرق بين القيم الحقيقية و المقدرة بكل الطريقتين و بالنسبة للمحاصيل الثلاث يبينها شكل (٥) التالي.



شكل (٦) مقارنة القيم المقدرة باستخدام ANN و ARIMA مع القيم الحقيقية لإنتاج المحاصيل الزراعية بمشروع حلفا الجديدة.

يُظهر شكل (٦) / أ أن القيم المقدرة باستخدام طريقة الشبكات العصبية الاصطناعية متقاربة من القيم الفعلية لمحصول القمح أكثر من تقارب نظيراتها المقدرة بنماذج بوكس-جينكز و الطريقتين تقديراتهما معقولة. الشكل ٦ (ب) يظهر مقارنة القيم المقدرة والحقيقة لمحصول الفول السوداني، وتظهر من الشكل كفاءة الشبكات العصبية كطريقة تقدير مقارنة مع نماذج آر. أما بالنسبة لمحصول القطن الذي يظهره الشكل ٦ (ج) فكذلك يظهر فيه مدى تفوق خوارزمية الشبكات العصبية في تقدير محصول القطن إذ قيمها أكثر تقارباً من القيم الحقيقية و يظهر الشكل عدم مقدرة كلا الطريقتين في التنبؤ بالقيم الشاذة سواء كانت دنيا أم عليا. وهذه النتائج التي تم التوصل إليها تتفق مع دراسة (Ranjeet & Armstrong, 2014) التي أوضحت أن نماذج الشبكات العصبية كانت هي الأقل من حيث أخطاء التنبؤ مقارنة مع الطرق الأخرى لتقدير إنتاجية المحاصيل الزراعية في دولة "النيبال". وقد جمعت لتلك الدراسة بيانات الإنتاج للمحاصيل الزراعية لمدة ٣٠ عاماً بغرض التنبؤ بالإنتاجية للسنوات القادمة و قد تفوقت الشبكات العصبية في عملية التقدير. كما استخدمت نماذج الشبكات العصبية الاصطناعية من قبل (Abhishek and Anu, 2017) لتقدير إنتاجية الطماطم من خلال تجارب صممها لهذا الغرض و أوضحت نتائجهم أن الشبكات العصبية كانت أكثر دقة في التقدير الإنتاجية. و في بحث نشر في العام ٢٠١٥ قام "سونيل" مع بائنين آخرون بتصميم خوارزميات عصبية للتنبؤ بإنتاجية قصب السكر في الهند معتمدين على البيانات التي تنشرها وزارة الزراعة في البلد المعني. وتوصل الباحثون إلى نماذج مميزة للتنبؤ بالإنتاجية كان الجزر التربيعي لمتوسط الخطأ فيها قليل جداً (Sunil et al, 2015).

النتائج

- ١/ نموذج السلاسل الزمنية المناسب لتقدير إنتاج محصول القمح بمشروع حلفا الجديدة هو $ARIMA(0,1,1)$ و لمحصول الفول السوداني $ARIMA(0,1,1)$ أيضاً، و لمحصول القطن $ARIMA(1,0,1)$.
- ٢/ خوارزمية شبكة عصبية اصطناعية بطبقة مخفية واحدة وعدد من الخلايا العصبية يمكنها التنبؤ بإنتاج المحاصيل الزراعية بمشروع حلفا الجديدة بكفاءة عالية.



٣/ استخدام خوارزميات الشبكات العصبية الاصطناعية في التنبؤ بإنتاج المحاصيل الزراعية بمشروع حلفا الجديدة أكثر دقة من التنبؤ باستخدام نماذج بوكس-جينكز.

٤/ الخطأ المعياري للنموذج المقدر و معيار معلومات يميز لها قيم أقل عند التقدير باستخدام الشبكات العصبية الاصطناعية و بالنسبة لجميع المحاصيل المذكورة في البحث.

٥/ إنتاج محصول القمح يمكن التنبؤ به بمقدرات أكثر دقة من المحصولين الآخرين و عند استخدام طريقتي التقدير المذكورتين.

التوصيات

١/ استخدام خوارزميات الشبكات العصبية الاصطناعية في التنبؤ بإنتاج المحاصيل الزراعية.

٢/ تصميم خوارزميات شبكات عصبية خاصة بالتنبؤ بإنتاج المحاصيل الزراعية.

٣/ إجراء المزيد من البحوث للمقارنة بين الشبكات العصبية و طرق تقدير السلاسل الزمنية المختلفة بناءً على معايير تفضيل مختلفة عن تلك التي تم استخدامها في هذا البحث.

References

- Abhishek Pandey and Anu Mishra, (2017), Application of Artificial Neural Networks in Yield Prediction of Potato Crop, Russian Agricultural Sciences, Vol. 43, No. 3, pp. 266–272.
- Anderson, T. W. (1971). "The Statistical Analysis of Time Series", John Wiley, New York.
- Boken, V.K., (2000). Forecasting spring wheat yield using time series analysis: a case study for the Canadian Prairies, Agronomy Journal, 92(6):1047-1053.
- Box, G. E. P. and Jenkins, G. M., (1976). "Time Series Analysis Forecasting and Control", 2nd ed., Holden-Day, San Francisco. Improve Deep Neural Networks". arXiv:1412.6830.
- Gashler, Michael S.; Ashmore, Stephen C. (2014). "Training Deep Fourier Neural Networks To Fit Time-Series Data". arXiv:1405.2262.
- Haykin, Simon S. (1999). Neural Networks: A Comprehensive Foundation. Prentice Hall. ISBN 978-0-13-273350-2.
- Hebb, Donald (1949). The Organization of Behavior. New York: Wiley. ISBN 978-1-135-63190-1.
- Yu. Savin, D. Stathakis, T. Negre, V.A. Isaev, 2007, Prediction of Crop Yields with the Use of Neural Networks, Russian Agricultural Sciences, Vol. 33, No. 6, pp. 361–363.
- Michel L, Makowski D (2013) Comparison of Statistical Models for Analyzing Wheat Yield Time Series. PLoS ONE 8(10): e78615. doi:10.1371/journal.pone.0078615, 1-11.
- Ranjeet, T. ,& Armstrong, L. (2014). An Artificial Neural Network for Predicting Crops Yield in Nepal. Proceedings of Asian Federation for Information Technology in Agriculture. (pp. 371-381). Perth, W.A. Australian Society of Information and Communication Technologies in Agriculture.
- Sahu, P. K. (2006) Forecasting Yield Behavior of Potato, Mustard, Rice, and Wheat Under Irrigation, Journal of Vegetable Science, 12:1, 81-99, DOI:10.1300/J484v12n01_08.
- Shastri K. Aditya, H.A. Sanjay and Abhijeeth Deshmukh, 2016. A Parameter Based Customized Artificial Neural Network Model for Crop Yield Prediction. Journal of Artificial Intelligence, 9: 23-32.
- Snyman, Jan (2005). Practical Mathematical Optimization: An Introduction to Basic Optimization Theory and Classical and New Gradient-Based Algorithms. Springer Science & Business Media. ISBN 978-0-387-24348-1.
- Sunil Kumar, Vivek Kumar and R. K. Sharma, (2015), Sugarcane Yield Forecasting Using Artificial Neural Network Models, International Journal of Artificial Intelligence & Applications (IJAIA) Vol. 6, No. 5, 51-68.
- United Nations (UN) (2017). World Population Prospects, 2017. <http://esa.un.org/unpd/wpp/index.htm> Accessed 2018 January 28.
- Werbos, P.J. (1975). Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences.
- Wu, Huaiqin (2009). "Global stability analysis of a general class of discontinuous neural networks with linear growth activation functions". Information Sciences. 179 (19): 3432–3441. doi:10.1016/j.ins.2009.06.006.