



**دراسة مقارنة للتنبؤ بالسلسلة الزمنية للمستهلك من الغاز الطبيعي
باستخدام بعض طرق التحليل الإحصائي
"دراسة تطبيقية"**

إعداد

د. حسن محمد علي
أستاذ مساعد بقسم الإحصاء
كلية التجارة – جامعة الزقازيق
hassanhasein@gmail.com

د. إبراهيم موسى عبد الفتاح
أستاذ الإحصاء وبحوث العمليات
كلية التجارة – جامعة الزقازيق
prof.mosa@yahoo.com

محمد عبد الحميد محمد علي عيسوي
المعيد بأكاديمية الشروق بالقاهرة
mohamedelesawi45@yahoo.com

مجلة البحوث التجارية - كلية التجارة جامعة الزقازيق
المجلد السابع والأربعون - العدد الأول 2025

رابط المجلة: <https://zcom.journals.ekb.eq/>

المخلص

شهد الغاز الطبيعي في مصر تطوراً ملحوظاً ممثلاً في زيادة الكمية المستهلكة نتيجة لتطور النشاط الإقتصادي وزيادة النمو السكاني وزيادة الطلب علي الغاز الطبيعي في إنتاج الكهرباء ، لهذا تهدف هذه الدراسة إلي إمكانية تطبيق أسلوبين للتنبؤ بالقيم المستقبلية لاستهلاك الغاز الطبيعي في مصر ، هما منهجية بوكس – جينكنز التي تعتبر من أهم الأساليب القياسية التي أثبتت فعاليتها في مجال التنبؤ وكذلك الشبكات العصبية الاصطناعية التي تهدف في مجملها إلي محاكاة العقل البشري من أجل القيام بعدة مهام منها التنبؤ بالقيم المستقبلية للسلاسل الزمنية ، ومن أجل الوصول إلي الهدف سالف الذكر أختارنا أن تكون عينة الدراسة ممثلة في كمية الاستهلاك السنوي من الغاز الطبيعي في مصر خلال الفترة من 1972 وحتى الفترة 2021 ، و تم استخدام برنامج Eviews في تطبيق منهجية بوكس – جينكنز وبرنامج MATLAB في أسلوب الشبكات العصبية الاصطناعية ، و بتطبيق هذين الأسلوبين توصلنا إلي أن النموذج الأفضل لمنهجية بوكس جينكنز هو نموذج ARIMA(1.1.0) ، حيث أنه الأفضل من بين النماذج الأخرى وذلك لأنه لديه أقل قيمة لمعيار اكاكي (Akaike) و معيار شوارز (Schwarz) ، وعند المقارنة بين الأسلوبين سالفين الذكر في دقة التنبؤ تبين أن أسلوب الشبكات العصبية الاصطناعية أكثر دقة في التنبؤ من أسلوب بوكس – جينكنز وذلك لأنه تعطي أقل قيمة لكل من متوسط مربع الخطأ (MSE) و الجذر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) و متوسط الخطأ المطلق النسبي (MAPE) كما أنه يعطي تنبؤات قريبة جداً من القيم الحقيقية .

كلمات مفتاحية: السلاسل الزمنية ، منهجية بوكس جينكنز ، الشبكات العصبية الاصطناعية.

1- الاطار العام للبحث

1-1 مقدمة البحث

تتبع أهمية الطاقة من كونها المصدر الرئيسي لأي تنمية سواء كانت صناعية أو زراعية أو خلافه ، لذلك تلعب الطاقة الدور الرئيسي لنمو القطاعات المختلفة وتقاس رفاهية الشعوب بمقدار المنتج من الطاقة ومدى الإستفادة منها ، ومصر بلد غنى بموارده الطبيعية وثرواته الزراعية والمعدنية وبالتالي فهو مؤهل لقيام نهضة تنموية كبرى خاصة في مجال استخراج الثروات المعدنية ، ولكن استخراج كل هذه الثروات ومن بعدها قيام الصناعات التحويلية الثقيلة والخفيفة يحتاج إلى طفرة كبرى في مجال الغاز الطبيعي الذي يعتبر الأرخص وذات الكفاءة الأعلى ، وفي هذه الدراسة سوف يتم تناول التنبؤ بالسلاسل الزمنية باستخدام أسلوبيين من أساليب التنبؤ أسلوب تقليدي يتمثل في نماذج بوكس – جينكنز وأسلوب حديث يتمثل في استخدام نماذج الشبكات العصبية الاصطناعية ويتم التطبيق على السلسلة الزمنية لاستهلاك الغاز الطبيعي في جمهورية مصر العربية في الفترة من (1972) إلى (2021) .

1-2 مشكلة البحث

تكمن مشكلة الدراسة في محاولة الوصول لأفضل الطرق والأساليب الإحصائية التي يمكن استخدامها في التنبؤ والتي تعطى أفضل النتائج الممكنة حتى يتم الإعتماد عليها ، وبما إننا نعيش في بيئة دائمة التغير الاقتصادي نرى أن هذا التغير يتحقق على مدى فترات زمنية متعددة تقاس بالسنوات أو الشهور وما إلى ذلك ، كذلك نرى الكثير من الظواهر التي تحدث فيها التغيرات بشكل مفاجئ لذا فإن موضوع التنبؤ يعتبر من الموضوعات المهمة التي يعتمد عليه المخطط في وضع خطط لغرض التنبؤ المستقبلي ، لذلك من الضروري التنبؤ بإستهلاك السنوي للغاز الطبيعي في مصر، كذلك من الأهمية وجود نموذج دقيق للتنبؤ حتى يتمكن من استغلال الموارد المتاحة بأفضل الطرق الممكنة وتقدير احتياجات الإستهلاك المستقبلية للغاز الطبيعي الذي يؤثر في عدة أوجه مثل توفير راس المال المستثمر فيه والقرارات العملية المتعلقة بمدخلات الإنتاج وإتخاذ القرارات المتعلقة بالمشتريات وحساب العائدات لذلك ينظر لعملية التنبؤ كمدخل إستراتيجي هام .

1-3 أهداف البحث

يتمثل الهدف العام للبحث في وضع نموذج للتنبؤ بالمستهلك من الغاز الطبيعي ، ولتحقيق الهدف لابد من إتباع الأهداف المحددة التالية :

- قياس كفاءة أسلوب بوكس – جينكنز لتحليل السلاسل الزمنية في التنبؤ بالاستهلاك السنوي للغاز الطبيعي.
- قياس كفاءة أسلوب الشبكات العصبية الاصطناعية للتنبؤ بالاستهلاك السنوي للغاز الطبيعي.
- المقارنة بين نتائج القياس لكل من أسلوب الشبكات العصبية الاصطناعية وأسلوب بوكس - جينكنز للتنبؤ بالاستهلاك الغاز الطبيعي والمفاضلة بينهما.

1-4 أهمية البحث

الغاز الطبيعي من أهم محركات التنمية الحديثة في مصر وهي المرتكز الأساسي لقيام المشروعات التنموية لذلك من المهم جداً التنبؤ به علي أسس علمية تعتمد علي النظريات الإحصائية المتقدمة ونجد إن التغيرات التي تطرأ على إستهلاك الغاز الطبيعي خلال فترة من الزمن هي محصلة عدة عوامل ولا يمكننا أن ندرجها تحت عامل واحد من هذه العوامل وإنما تكون نتيجة تفاعل هذه العوامل مجتمعة وتحليلنا للسلسلة الزمنية نتعرف على مقدار هذه التغيرات وإدراك طبيعتها وإتجاهها ويصبح بالإمكان القيام بالتقديرات والتنبؤات المستقبلية الضرورية وتعتبر عملية الوصول إلي نموذج مناسب للتنبؤ من المهام الصعبة ، وتم إعتماد منهجية بوكس - جينكنز التي تستند على الدمج بين نماذج الانحدار الذاتي ونماذج المتوسطات المتحركة ، كما يعتبر أسلوب الشبكات العصبية أسلوباً حديثاً نسبياً حيث يحاكي عملية جمع البيانات وتشغيلها في العقل البشري بهدف الوصول إلى قرار سليم ، ولتقدير الإستهلاك المستقبلي للغاز الطبيعي نحتاج الى استخدام أكثر من أسلوب إحصائي لتحديد أفضل أسلوب لإجراء عملية التنبؤ بسلوك تلك الظاهرة.

1-5 مصادر البيانات:

أخذت البيانات من سجلات الجهاز المركزي للتعبئة العامة والإحصاء وهي سلسلة زمنية لاستهلاك الغاز الطبيعي في مصر بالمليار متر مكعب وذلك خلال الفترة (1972- 2021) و تم التحليل باستخدام البرامج الإحصائية (Eviews 8) , (MATLAB 2015).

1-6 دراسات سابقة :

• دراسة (عماد يعقوب حامد ، 2011)

بعنوان " استخدام نماذج بوكس جينكنز ونماذج الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية للقطاع الزراعي في السودان " تناولت هذه الدراسة استخدام نماذج بوكس - جينكنز والشبكات العصبية الاصطناعية للتنبؤ بالسلاسل الزمنية الاقتصادية وتم التطبيق علي القطاع الزراعي في السودان متمثله في السلاسل الزمنية لإنتاج القمح (1945- 2005) ، وتوصلت هذه الدراسة الي أنه كلما زادت فترات التنبؤ في المستقبل كانت نتائج الشبكات العصبية الاصطناعية أدق من نتائج بوكس - جينكنز .

• دراسة (سعديه عبدالكريم طعمه ,2012)

بعنوان " استخدام تحليل السلاسل الزمنية للتنبؤ بأعداد المصابين بالأورام الخبيثة في محافظة الأنبار" يهدف البحث إلي تحليل السلاسل الزمنية باستخدام منهجية (بوكس- جينكنز) لإيجاد أفضل نموذج للتنبؤ بأعداد المصابين بالأورام الخبيثة في محافظة الأنبار ، وقد أظهرت نتائج تحليل البيانات أن النموذج الملائم لها هو نموذج الإنحدار الذاتي المتكامل من الدرجة الثانية $ARIMA(2,1,0)$ وبالاعتماد علي هذا النموذج تم التنبؤ بأعداد المصابين بالأورام الخبيثة شهرياً ولستنتين قادمتين وقد كانت القيم التنبؤية متناسقة مع قيم السلسلة الأصلية مما يدل علي كفاءة النموذج.

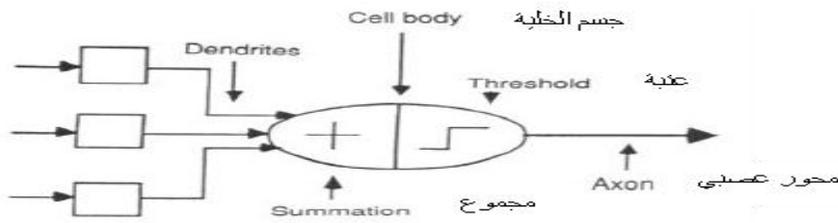
• دراسة (صفاء محمد علي مصطفى ، 2017)

بعنوان " تطبيق نماذج (GARCH) والشبكات العصبية الاصطناعية على تحليل تجانس أخطاء السلسلة الزمنية " تختص مشكلة هذا البحث في محاولة حل مشكلة عدم ثبات تباين أخطاء السلسلة الزمنية وذلك باستخدام أسلوب الشبكات العصبية الاصطناعية Artificial Neural Networks واستخدام النماذج المعممة للانحدار الذاتي المشروط بعدم تجانس التباين (GARCH) لحل موضوع البحث ، و قد تم التخلص من المشكلة محل البحث باستخدام تلك الأساليب وتمت المقارنة بين نتائجهما وخلص البحث إلى أن أسلوب الشبكات العصبية هو الأفضل من حيث سهولة التحليل ودقة التنبؤ و القضاء على مشكلات الأخطاء.

2 - الشبكات العصبية الاصطناعية (ANN) Artificial Neural Network

يعتبر الذكاء الاصطناعي واحدة من أسرع المجالات الناشئة والمتطورة في العلوم الحاسوبية وتهدف التقنيات المتعلقة بالذكاء الاصطناعي إلى تصميم وتطوير الأنظمة والبرامج التي تستطيع التفكير والتعلم وإتخاذ القرارات بشكل مستقل ، والتي تتمتع بالقدرة على معالجة وتحليل كميات كبيرة من البيانات بشكل أسرع وأكثر دقة من الإنسان ، ومن بين الأساليب الأكثر استخداماً في تطبيقات الذكاء الاصطناعي هي الشبكات العصبية التي تمثل نموذجاً رياضياً مستوحى من الجهاز العصبي للإنسان والحيوان وتعتمد الشبكات العصبية على تدريب النموذج على مجموعة من البيانات واستخلاص العلاقات بين مختلف العناصر في هذه البيانات (بسيوني، 2008)

المفتاح لنموذج الشبكة العصبية الاصطناعية (ANN) هو الهيكل لنظام معالجة المعلومات الذي يقوم بربط وتنظيم عدد كبير من عناصر المعالجة المرتبطة داخليا (العصبونات) والتي تعمل بانسجام لحل مسائل معينة ، وتمر الإشارات بين العقد (العصبونات) عبر خطوط ربط ويرفق كل خط بوزن معين ، وتضرب الإشارات الداخلة إلى العقدة (العصبون) بهذه الأوزان ، وتجمع المدخلات الموزونة في العقد أو العصبونات وبعد ذلك يتم معالجة مخرجات كل عقدة بواسطة دالة غير خطية ذات عتبة معينة (Threshold) تعرف بدالة التنشيط (Function)، والشكل (1) يوضح شبكة عصبية إصطناعية بسيطة.



شكل (1) : شبكة عصبية إصطناعية بسيطة

1-2 مكونات الشبكة العصبية

تتكون الشبكة العصبية من مجموعة من وحدات المعالجة والتي تسمى عصبونات والتي تتماثل مع العصبونات البيولوجية في المخ وهذه الوحدات متصلة فيما بينها في شكل ترابطات تسمى بالشبكة

العصبية، وتعمل الروابط علي تمرير الإشارات من عصبون لآخر ويكون لكل رابط وزن عددي يصاحبه ويستقبل كل عصبون عدد من المدخلات عن طريق تشابكاته وينتج إشارة مخرجات واحده فقط ، وتنقل إشارة المخرجات عن طريق الربط الخارجي للعصبون ، وينقسم الرابط الخارج بدوره إلي عدد من الفروع التي تنقل نفس الإشارة ، وتنتهي الفروع الخارجة عن الروابط الواردة لعصبونات أخري في الشبكة . (الحسيني و الساعدي، 2016):

• طبقة المدخلات Input Layer

طبقة المدخلات هي الطبقة الأولى في الشبكة العصبية الإصطناعية والتي تستقبل المدخلات الخارجية للنظام وتتكون طبقة المدخلات عادة من مجموعة من الخلايا العصبية أو العقد التي تمثل البيانات المدخلة للنظام، وتعتبر طبقة المدخلات من أهم الطبقات في الشبكة العصبية الإصطناعية ، حيث تلعب دوراً حاسماً في تحديد جودة النتائج النهائية للشبكة. (العتيبي، 2003)

• الطبقات الخفية Hidden Layers

الطبقات المخفية هي الطبقات الوسطى في الشبكة العصبية الإصطناعية بين طبقة المدخلات وطبقة الإخراج ، وهي التي تقوم بمعالجة المعلومات الواردة من طبقة المدخلات وتحويلها إلى بيانات مفيدة ومفصلة يمكن استخدامها في إنتاج الإخراج المطلوب ، وتتكون الطبقات المخفية من مجموعة من العقد العصبية (Neurons) التي تستقبل الإشارات الداخلة من الطبقة السابقة وتقوم بتحويلها إلى إشارات الإخراج التي تمرر إلى الطبقة التالية وتعتبر الوظيفة الرئيسية للطبقات المخفية هي تعلم العلاقات المعقدة بين البيانات المدخلة والإخراج المطلوب ، وتتميز الطبقات المخفية بأنها تمتلك عددًا أكبر من العقد العصبية مقارنة بطبقة المدخلات وطبقة الإخراج.

• طبقة المخرجات Output Layer

طبقة الإخراج هي الطبقة الأخيرة في الشبكة العصبية الإصطناعية ، والتي تقوم بإخراج النتائج النهائية للنظام وعادةً ما تحتوي طبقة الإخراج على عدد من العقد العصبية يتم استخدامها لتوليد النتائج المطلوبة من الشبكة ، وتعتمد طبقة الإخراج على طبيعة المشكلة المحلولة وعلى البيانات المدخلة ، وعلى هذا الأساس ، يتم تحديد عدد العقد العصبية في طبقة الإخراج ، ويتم تعيين نوع الوظيفة المناسبة

لطبقة الإخراج بناءً على طبيعة المشكلة المحلولة ، ويتم استخدام مختلف الوظائف مثل Sigmoid (Function) وغيرها. (الحسيني و الساعدي، 2016)

• الأوزان Weights

الأوزان هي قيم رقمية يتم تعيينها لكل عقدة (Neuron) في الشبكة العصبية الاصطناعية ، وتستخدم هذه الأوزان لتحديد قوة الاتصالات بين العقد في الشبكة ، وتعتبر الأوزان من أهم العوامل التي تؤثر على أداء الشبكة العصبية الاصطناعية ويتم تعيين الأوزان عشوائياً في بداية التدريب ، ويتم تعديلها خلال عملية التدريب باستخدام خوارزميات التعلم العميق ، يتم تعديل الأوزان بحيث تصبح النتائج الصادرة عن الشبكة العصبية الاصطناعية أقرب ما يكون إلى النتائج الصحيحة ، وتعتبر عملية تعديل الأوزان خلال عملية التدريب من العمليات الرئيسية لتحسين أداء الشبكة العصبية الاصطناعية وتتم هذه العملية باستخدام خوارزميات التعلم العميق.

2-2 خوارزمية الشبكة العصبية ذات الانتشار العكسي

تعتبر خوارزمية شبكة الانتشار العكسي للخطأ من أهم خوارزميات شبكات التدريب بإشراف، وأسمها مشتق من حقيقة أن الخطأ الناتج يرجع عكسياً خلال الشبكة من طبقة إلى أخرى ، خوارزمية شبكة الانتشار العكسي للخطأ تعتمد على إختيار دالة خطأ مناسبة ، والتي تتحدد قيمها بالنتائج الحقيقية (Actual) والقيم المطلوب الحصول عليها (Desired) والتي تعتمد أيضا على معالم الشبكة مثل الأوزان والعتبة (ذكي، 2008).

$$u = \sum_{i=1}^N w_i x_i \quad (1)$$

$$y = f(u - \theta) \quad (2)$$

حيث:

x_1, x_2, \dots, x_N : تمثل المدخلات

w_1, w_2, \dots, w_N : تمثل الأوزان

u : تمثل حساسية العصبون

θ : تمثل العتبة

y : تمثل مخرج الشبكة.

$f()$: تمثل دالة الحساسية.

ويمكن إعادة صياغة المعادلتين السابقتين وذلك بجعل قيمة $w_0 = \theta$ و $x_0 = 1$ حيث ستكون المعادلة:

$$\sum_{i=1}^N w_i x_i - \theta = \sum_{i=0}^N w_i x_i \quad (3)$$

$$f(u) = \frac{1}{1 + \exp(-au)} \quad (4)$$

حيث:

a : معامل الميل (Slope Parameters).

في خطوة الانتقال الأمامي (Forward Pass) للشبكة، متجه الإدخال $y^{(p)}$ وكل عصبون مخفي z يستقبل مدخلات الشبكة حسب المعادلة الآتية:

$$x_j^{(p)} = \sum_k w_{jk} y_k^{(p)} \quad (5)$$

حيث:

w_{jk} : يمثل الوزن بين العصبون المخفي z وعصبون الإدخال k .

هذا العصبون z ينتج المخرجات حسب المعادلة الآتية:

$$y_j^{(p)} = f(x_j^{(p)}) = f\left(\sum_k w_{jk} y_k^{(p)}\right) \quad (6)$$

$$x_j^{(p)} = \sum_k w_{jk} y_k^{(p)} = \sum_j w_{ij} f\left(\sum_k w_{jk} y_k^{(p)}\right) \quad (7)$$

حيث:

w_{ij} : يمثل الوزن بين عصبون الإخراج i والعصبون المخفي z .

وعليه فإن الناتج النهائي يكون بالصيغة الآتية:

$$y_j^{(p)} = f(x_j^{(p)}) = f\left(\sum_k w_{jk} y_k^{(p)}\right) = \sum_j w_{ij} f\left(\sum_k w_{jk} y_k^{(p)}\right) \quad (8)$$

3 - السلاسل الزمنية ومنهجية بوكس - جينكنز

السلسلة الزمنية عبارة عن قيم ظاهرة لسلسلة من تواريخ متلاحقة أيام أو شهور أو سنوات والهدف من وراء تحليل السلسلة الزمنية هو دراسة التغيرات التي قد تكون طرأت على ظاهرة ، والتي تمثلها خلال فترة من الزمن وتحليل أسبابها ونتائجها و التنبؤ أيضاً اعتماداً على فكرة مد حوادث الماضي للمستقبل ، وتحتوى السلسلة الزمنية على متغيرين إحدهما هو الزمن وهو المتغير المستقل والثاني قيمة الظاهرة (إستهلاك الغاز) وهو المتغير التابع ويمكن تمثيل السلسلة الزمنية بوضع الزمن على المحور الأفقي وقيم المتغير التابع على المحور الراسي فإذا أظهرت السلسلة الزمنية اتجاهها معيناً أو طابعاً خاصاً خلال فترة ممتدة من الزمن فإننا نتوقع أن يستمر حدوث هذا الطابع أو الإنتظام في المستقبل أيضاً وذلك يعتبر أساس مقبول للتنبؤ. (الطائي، 2003)

3-1 أهداف تحليل السلسلة الزمنية

يتم دراسة السلاسل الزمنية لتحقيق عدد من الأهداف أول هذه الأهداف هو استخدام السلاسل الزمنية لوصف وتصوير المعلومات المتاحة عن فترة زمنية توضح تطور الظاهره المدروسه ، أي وصف الملامح والسمات الرئيسية للسلسلة الزمنية ، ويساعد وصف السلسلة إلي حد كبير في تحديد النموذج المناسب لتحقيق الأهداف الأخرى والتعرف علي حركات الصعود والهبوط في السلسلة الزمنية وأيضاً التعرف علي المكونات الرئيسية للسلسلة الزمنية ، مثل الإتجاه العام والتغيرات الموسمية ، ويمكن حصر مجموعة من أهداف تحليل السلاسل الزمنية علي النحو التالي:

- بناء نموذج ملائم لتفسير وشرح سلوك السلسلة الزمنية بدلالة متغيرات أخرى تربط المشاهدات ببعضها البعض.
- الحصول على وصف دقيق للملامح التي تتولد منها السلسلة الزمنية.
- استخدام النتائج للتنبؤ بسلوك السلسلة في المستقبل وذلك بالإعتماد على معلومات الماضي.

- التحكم في العملية التي تتولد منه السلسلة الزمنية بفحص ما يمكن حدوثه عند تغيير بعض معالم النموذج.

3-2 مكونات السلاسل الزمنية

تطور الظواهر المسجلة في السلسلة الزمنية قد تكون نتيجة لعوامل كثيرة ومنها عوامل إقتصادية وعوامل طبيعية وعوامل موسمية ، بعض هذه العوامل قد تؤثر على الإتجاه العام للسلسلة الزمنية في الأجل الطويل بينما تسبب البعض الآخر في تكوين الذبذبات قصيرة الأجل وكما ذكرنا من قبل أن أحد أهداف دراسة السلسلة الزمنية هو وصف الظاهره موضع الدراسة والتعرف علي التغيرات المختلفة التي طرأت عليها خلال الفتره الكلية المتاحة بسبب العوامل المختلفة التي تتعرض لها الظاهرة ، وفي واقع الأمر يمكن القول أن التغيرات التي تطرأ علي الظاهرة من فترة زمنية لأخري تحدث نتيجة أربعة أنواع من العوامل وهي : (شعراوي، 2005)

• الإتجاه العام (T_t) General Trend

الإتجاه العام ، بصرف النظر عن كونه إتجهاً صعوداً أو هبوطاً للظاهرة المدروسة يعكس تطور الظاهرة خلال فترة طويلة من الزمن ، ويلخص الإتجاه العام التغيرات الأساسية في الحياة الإقتصادية في الأجل الطويل ، لذا يفضل أن تكون المشاهدات المدروسة للسلسلة الزمنية تغطي فترة زمنية طويلة لكي يتمكن من كشف الإتجاه العام لها بشكل واضح.

• تغيرات موسمية (S_t) Seasonal Variations

تعتبر التغيرات الموسمية تغيرات في مواسم أو فصول السنة ، والتغيرات الموسمية تكرر نفسها عادة ولكن درجة هذا التغير قد تختلف من وقت لآخر، فالعوامل المناخية من أهم العوامل التي تسبب التغيرات الموسمية ، كما أن إختلاف المناخ في فصول السنة يعد أحد الأسباب الرئيسية في التغيرات الموسمية ، ومن الأمور المهمة إجراء التنبؤ بهذه التغيرات عند إتخاذ القرارات.

• تغيرات دورية (S_t) Cycle Variations

التغيرات الدورية هي الدورات التي تسبب تذبذبات في نشاط السلسلة الزمنية وتتكون الدورة من فترة توسع يتبعها فترة إنكماش ، وأن هذه التغيرات الدورية تكون عادة متكررة الحدوث ولكنها لا تحدث على فترات منتظمة وقد تستغرق من سنة إلى 10 سنوات أو أكثر، وتعرف التغيرات الدورية

أيضاً بأنها تغيرات تؤدي إلي حدوث نمط دوري في السلسلة يتكرر كل فترة زمنية طويلة ، وهي في ذلك تشبه التغيرات الموسمية ، إلا أنها تختلف عن هذه التغيرات في العديد من الأوجه ، الأختلاف الأول أن طول الدورة التي تحدثها هذه التغيرات أكبر كثيراً من طول الدورة الموسمية وعادة ما يكون خمس أو عشر سنوات ولذلك تسمي هذه التغيرات بالتغيرات طويلة الاجل ، الإختلاف الثاني هو أسباب حدوث هذه التغيرات حيث أن هذه التغيرات تعكس آثار الدورات والتقلبات الإقتصادية من حيث الكساد أو الراج للظواهر الإقتصادية ، الإختلاف الثالث أن طول هذا النوع من الدورات لا يمكن تحديده بشكل دقيق .

• تغيرات عشوائية (e) Random Variations

التغيرات العشوائية هي تلك التذبذبات التي تكون نتيجة عوامل عشوائية خارج نطاق السيطرة وهذه التغيرات لا يمكن التنبؤ بها وإن التذبذبات العشوائية لا تؤثر على الإتجاه العام للظاهرة قيد الدراسة ، وهي غير مهمة نسبياً بالرغم من صعوبة تفسيرها ، إلا إنه يمكن إظهار تأثيرها وهي تظهر كتذبذبات صغيرة منتظمة في بيانات السلسلة الزمنية.

3-3 إستقرارية وعدم إستقرارية السلسلة الزمنية

تعتبر بيانات السلاسل الزمنية من أهم أنواع البيانات التي تستخدم في الدراسات التطبيقية خاصة تلك التي تعتمد علي بناء نماذج الانحدار لتقدير العلاقات الإقتصادية ، وتفرض هذه الدراسة أن السلاسل الزمنية المستخدمة في التحليل لابد أن تكون سلاسل زمنية مستقرة / ساكنة (Stationarity) فعندما لايتوافر في السلسلة صفة السكون /الإستقرارية (Stationarity) فإن الإنحدار الذي نحصل عليه من متغيرات السلسلة غالباً ما يكون انحداراً زائفاً (Spurious Regression) ، أي لا معني له حيث تكون دراسة سلوك السلسلة قاصراً علي الفترة الزمنية محل الدراسة فقط ولا يمكن تعميم هذا السلوك علي فترات زمنية أخرى ، لذلك يكون الأعتداع علي بيانات هذه السلسلة في التنبؤ أمر غير مناسب ، ومن هنا تنشأ حاجة الباحث للتعرف علي ما إذا كانت السلسلة ساكنة ام لا (علي، 2020).

• إستقرارية السلسلة الزمنية Stationary Time series

الإستقرارية في السلسلة الزمنية العشوائية تشير إلى عدم وجود نمو في البيانات عبر الزمن أي عدم وجود إتجاه عام، وعليه فإنه يقال أن السلسلة الزمنية مستقرة عبر الزمن إذا كان المتوسط والتباين

وكذلك التباينات المشتركة ثابتين ومستقلين عبر الزمن ، وبالتالي فإنه للحكم على إستقرارية السلسلة الزمنية لأبد من توفر الشروط التالية: (الحديثي، 1993).

➤ البيانات تكون منتشرة حول وسط ثابت لا يعتمد علي الزمن

$$E(y_t) = E(y_{t+k}) = \mu \quad (9)$$

➤ ثبات التباين عبر الزمن

$$VAR(y_t) = VAR(y_{t+k}) = \sigma^2 \quad (10)$$

• عدم إستقرارية السلسلة الزمنية Non-Stationary Time Series

تعتبر معظم السلاسل الزمنية في الواقع العملي والتطبيقي غير مستقرة فعلي سبيل المثال نجد أن المتغيرات الإقتصادية غالباً ما تعتبر سلاسل زمنية غير مستقرة كونها تسير بصفه عامه في اتجاه عام ، لذلك لابد من تحويلها إلي سلاسل زمنية يسهل نمذجتها ، ومنه فإن السلسلة الزمنية تكون غير مستقرة إذا لم يتحقق فيها علي الأقل شرط من الشروط السابقة، فعدم الإستقرارية ينتج غالبا عن التغير في أي من المتوسط أو التباين أو كليهما .

3-4 إختبارات فحص سكون السلسلة الزمنية

من المعروف وجود عدد من المعايير والإختبارات التي يمكن إستخدامها لإختبار شرط / صفة السكون في السلسلة الزمنية والتحقق ما إذا كانت تتبع نمط مستقر أو لا ، هذه الإختبارات تهدف إلى تحديد وجود الأنحرافات الإحصائية أو التغيرات غير العشوائية في البيانات الزمنية وسوف نستخدم واحد من أهم هذه الإختبارات وهو :

• إختبار ديكي فوللر (DF) Dickey-Fuller Test

يسمح هذا الإختبار بمعرفة أن السلسلة الزمنية مستقرة أم لا وذلك من خلال إختبار الفرضين التاليين:

➤ الفرض العدمي H_0 ويعني أن السلسلة الزمنية غير مستقرة

➤ الفرض البديل H_1 ويعني أن السلسلة مستقرة

فإذا تحقق الفرض العدمي فإن ذلك يعني أن السلسلة الزمنية y_t ليست مستقرة والعكس صحيح.

4 - الدراسة التطبيقية

4-1 أسلوب بوكس - جينكنز

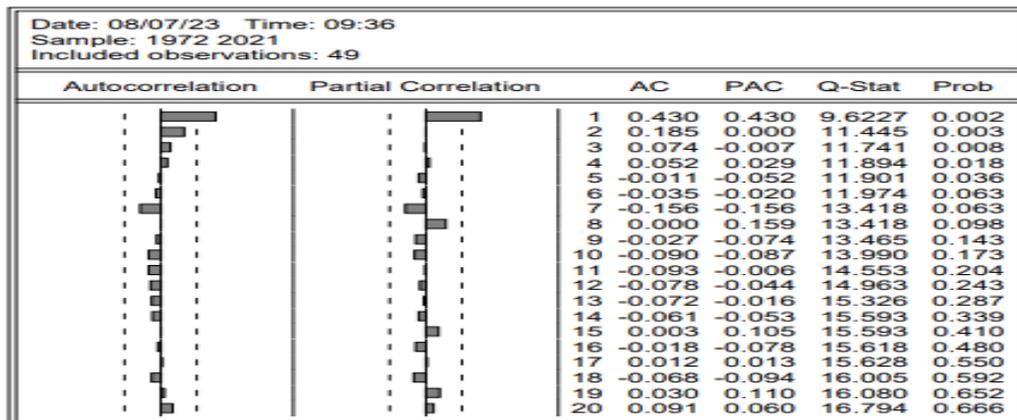
لكي يتم تطبيق منهجية بوكس جينكنز فإن هناك مجموعه من المراحل التي يجب أتباعها وهي :

أولاً : مرحلة التعرف Identification

من خلال نتائج اختبار ديكي فولر تبين أن السلسلة الزمنية للاستهلاك السنوي للغاز الطبيعي غير مستقرة في صورتها الحالية ، ولتكون هذه السلسلة مستقرة تم أخذ الفروق من الدرجة الأولى ومن ثم إعادة تطبيق إختبار ديكي فولر علي سلسلة الاستهلاك السنوي للغاز الطبيعي وبمقارنة قيمة (τ) لاختبار القيم الحرجة لديكي فولر عند مستويات المعنوية 1% ، 5% يلاحظ أنها أقل من جميع القيم الحرجة ، الأمر الذي يجعلنا نرفض الفرض H_0 ونقبل H_1 الذي ينص علي أن السلسلة الزمنية للفروق الأولى لكميات الاستهلاك السنوية من الغاز الطبيعي قد أصبحت سلسلة مستقرة .

وبعد التأكد من إستقرارية السلسلة الزمنية (DCONSOM) تأتي أول مرحلة من مراحل منهجية بوكس - جينكنز ألا وهي مرحلة التعرف والتي يتم فيها تحديد النماذج التي يمكن أن تخضع لها السلسلة الزمنية المستقرة لذلك أعمدنا في هذه المرحلة علي التمثيل البياني لدالتي الإرتباط الذاتي والإرتباط الذاتي الجزئي للسلسلة.

Correlogram of D(LCONSOM)



شكل (2) : التمثيل البياني لدالتي الإرتباط الذاتي والإرتباط الذاتي الجزئي للسلسلة بعد أخذ الفروق الأولى

ثانياً : مرحلة التقدير Estimation

في هذه المرحلة تم تقدير النماذج المقترحة، ثم إختيار النموذج الذي يعطي أقل قيمة لمعيار اكاكي (AIC) و معيار شوارز (SIC) ، وبعد إستبعاد النماذج غير المقبولة إحصائياً ، نجد أن لدينا نموذجين مقبولين إحصائياً وهي (AR(1) و (MA(1)، وعليه فمن أجل المقارنة بين النماذج واختيار النموذج المناسب نعتمد علي قيمة معياري (AIC) و (SIC) وكذلك معامل التحديد (R^2).

جدول (1) : قيم معيار (AIC) و (SIC) للمفاضلة بين النماذج

النموذج	R^2	SC	AIC
AR(1)	0.21	-1.49	-1.57
MA(1)	0.22	-1.39	-1.47

وعليه فمن خلال نتائج الجدول نجد أن النموذج الذي يجعل معامل التحديد في أكبر قيمة له ومعياري (AIC) و في أدني قيمة له، وبالتالي فإن النموذج الأمثل والأكثر تعبيراً عن كمية استهلاك الغاز الطبيعي في جمهورية مصر العربية هو (AR(1).

❖ إختبار إستقلالية البواقي التقدير

من أجل إختبار إستقلالية البواقي تم دراسة دالة الإرتباط الذاتي ودالة الإرتباط الذاتي الجزئي لسلسلة بواقي التقدير وتم الحصول علي الجدول التالي :

Correlogram of Residuals

Date: 08/07/23 Time: 11:58 Sample: 1972 2021 Included observations: 48 Q-statistic probabilities adjusted for 1 ARMA term						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.051	0.051	0.1341	
		2	-0.126	-0.129	0.9622	0.327
		3	0.044	0.059	1.0675	0.586
		4	0.064	0.043	1.2934	0.731
		5	-0.032	-0.026	1.3502	0.853
		6	0.223	0.244	4.1954	0.522
		7	0.011	-0.036	4.2020	0.649
		8	-0.013	0.052	4.2129	0.755
		9	0.004	-0.019	4.2139	0.837
		10	-0.042	-0.076	4.3248	0.889
		11	0.021	0.052	4.3531	0.930
		12	-0.005	-0.095	4.3546	0.958
		13	-0.035	-0.005	4.4408	0.974
		14	-0.069	-0.087	4.7788	0.980
		15	0.056	0.060	5.0045	0.985
		16	-0.032	-0.021	5.0798	0.991
		17	0.040	0.053	5.2063	0.995
		18	-0.116	-0.113	6.2908	0.991
		19	0.021	0.057	6.3266	0.995
		20	0.062	0.070	6.6613	0.996

شكل (3) : دالة الإرتباط الذاتي والإرتباط الذاتي الجزئي لسلسلة بواقي التقدير

يتضح من خلال النتائج في الشكل (3) أن جميع معاملات الارتباط الذاتي لسلسلة البواقي تقع داخل مجال الثقة أي إنها تساوي معنوياً الصفر ومنه يمكن التأكد من أن النموذج المختار مقبول إحصائياً وبالتالي يمكن الإعتماد عليه للتنبؤ بالقيم المستقبلية لكمية الاستهلاك السنوي للغاز الطبيعي في مصر.

ثالثاً : مرحلة التنبؤ Forecasting

بعد التأكد من القبول النهائي للنموذج المتحصل عليه بتطبيق منهجية (بوكس – جينكنز) فإن معادله التنبؤ التي سنعتمد عليها في التنبؤ بكمية الاستهلاك السنوي تأخذ الصيغة التالية :

$$D(LCONSOM)_{t+h} = 0.102042085914 + [AR(1) = 0.430222579807] + \varepsilon_{t+h} \quad (11)$$

❖ مؤشرات قياس دقة التنبؤ باستخدام أسلوب بوكس – جينكنز

جدول (2) : مؤشرات قياس دقة التنبؤ

القيمة	مؤشرات قياس دقة التنبؤ
0.743791	متوسط مربع الخطأ (MSE) Mean Square Error
0.862433	الجذر التربيعي لمتوسط مربع الخطأ (RMSE) Root Mean Square Error
0.764758	متوسط الخطأ المطلق (MAE) Mean Absolute Error
41.065	متوسط الخطأ المطلق النسبي (MAPE) Mean Absolute Percent Error

2-4 أسلوب الشبكات العصبية الاصطناعية

للتنبؤ بالإستهلاك السنوي للغاز الطبيعي باستخدام نماذج الشبكات العصبية الاصطناعية تم الإعتماد علي برنامج (MATLAB) وهو برنامج أثبتت فعاليته في هذا المجال ذلك أنه يساعد في بناء الشبكة العصبية وأختبار دقتها ، ومن أجل تطبيق الشبكات العصبية الاصطناعية للتنبؤ بأستهلاك الغاز الطبيعي فلا بد من المرور بمجموعة من المراحل وهي :

أولاً : مرحلة معالجة البيانات

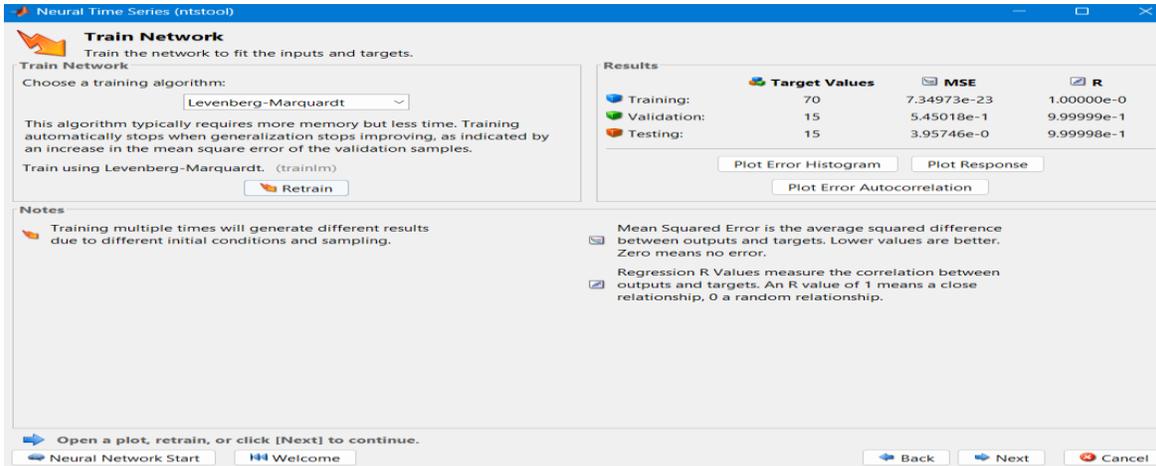
تم تحديد السلسلة الزمنية لاستهلاك الغاز الطبيعي كمدخلات للشبكة العصبية كما تم التنبؤ بالقيم المستقبلية لها وهذا بالإعتماد علي القيم السابقة لهذه السلسلة فإن هذا الشكل يعد من أشكال تنبؤ الإنحدار الذاتي غير الخطي (Nonlinear Autoregressive (NAR) .

ثانياً : مرحلة تحليل البيانات :

- في هذه المرحلة يتم تجميع البيانات محل الدراسة وتجزئتها بشكل عشوائي بالإعتماد علي برنامج (MATLAB) حيث يتم تقسيم المدخلات إلي ثلاثة أقسام وهي :
- مجموعة التدريب : حيث تم تخصيص 70% من المشاهدات للتدريب .
 - مجموعة التأكيد : وهنا نجد أنه تم تخصيص 15% من المشاهدات وذلك للتأكيد .
 - مجموعة الاختبار : أيضاً تم تحديد 15% من أجل الإختبار .

ثالثاً :مرحلة تدريب الشبكة وتنفيذها :

تم في هذه المرحلة تحديد خيارات عملية التدريب وكذلك تحديد معامل التغذية ، وتنتهي بإستخراج النتائج النهائية للشبكة ومستوي دقة تنبؤاتها في عيني التدريب والتأكد ، أما مرحلة الإختبار فيتم فيها إختبار مدي مصداقية الشبكة ودرجة دقتها ، والنتائج المتحصل عليها وفقاً لبرنامج MATLAB مدونة في الشكل التالي :

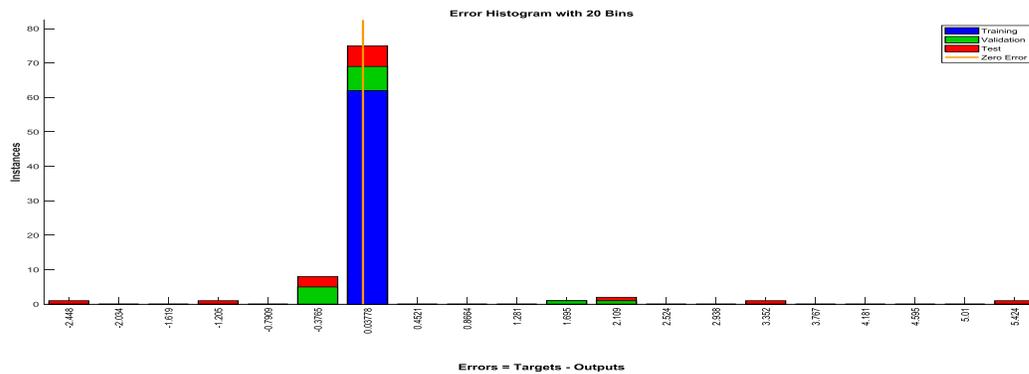


شكل (4) : نتائج عملية تدريب الشبكة العصبية الإصطناعية.

حيث يقيس معامل الارتباط قوة العلاقة بين المخرجات والأهداف فكلما إقتربت قيمة معامل الارتباط من الواحد الصحيح تعكس وجود علاقة قوية ، والنتائج المدونة في الشكل أعلاه تظهر أن هناك علاقة قوية بين المخرجات والأهداف حيث كانت القيم كما يلي :

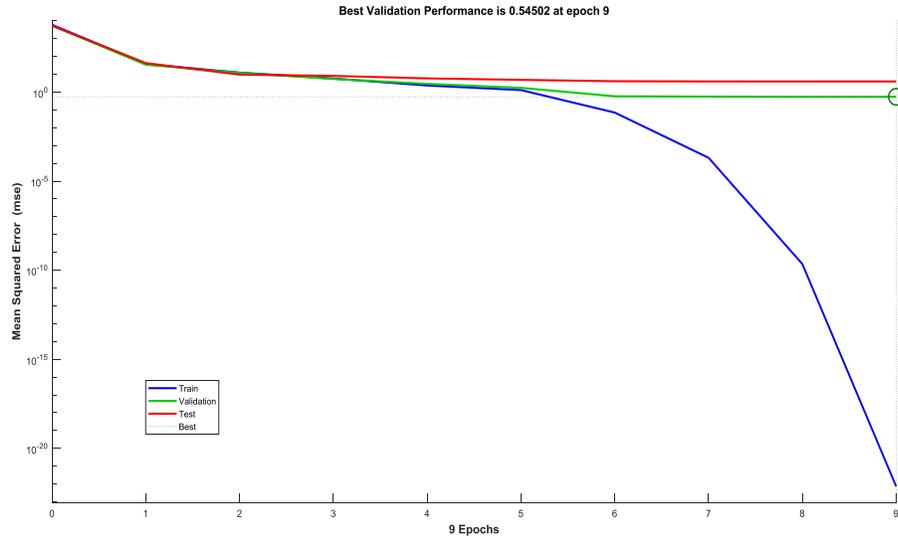
- معيار التدريب : $R=1$
- معيار التحقق : $R=0.99$
- معيار الإختبار : $R=0.99$

كما أنه بملاحظة المدرج التكراري للأخطاء في الشكل أدناه نجد أن المدرجات التكرارية متناظرة بالنسبة للمحور الصفري أي أن الأخطاء متناظرة بالنسبة للصفر وهذا يعني جودة السلسلة التي نريد التنبؤ بقيمها.



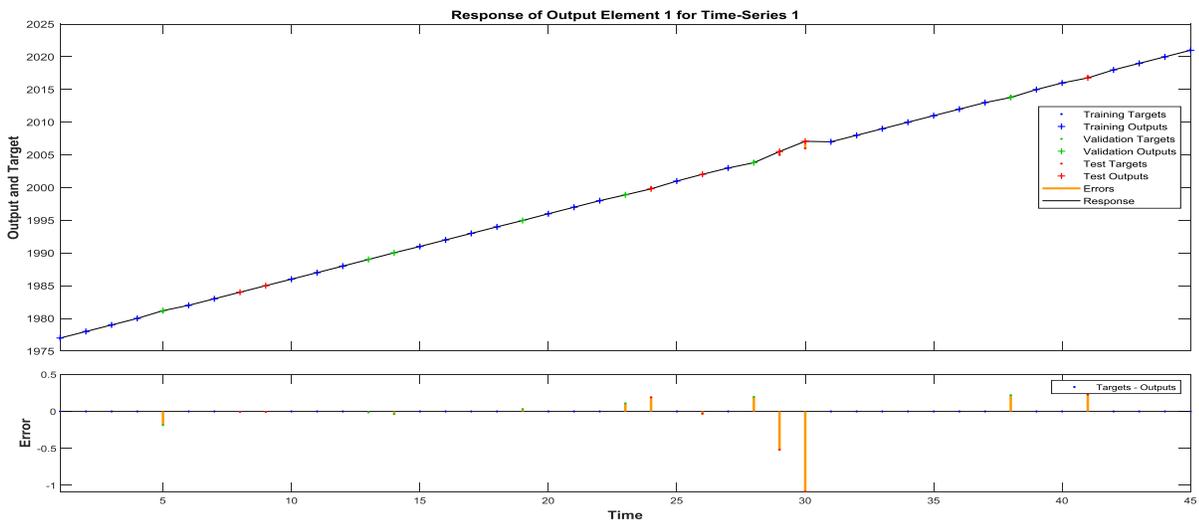
شكل (5) : المدرج التكراري للأخطاء

وعند مقارنة أفضل أداء للتحقق Best Validation Performance ومتوسط مربع الخطا Mean Square Error نجد أن الخط الممثل لمجموعة التحقق يبدأ منخفضاً ثم يتحسن تدريجياً ويستقر عند أفضل أداء، بينما يبدو أن خط الخطأ يتجاوب مع هذا التحسن وينخفض بشكل متزايد أيضاً ، هذا يشير إلى أن النموذج يتحسن تدريجياً خلال فترة التحقق ويتقلص الخطأ بالتزامن مع تحسن أداء التحقق والشكل (6) يوضح ذلك .

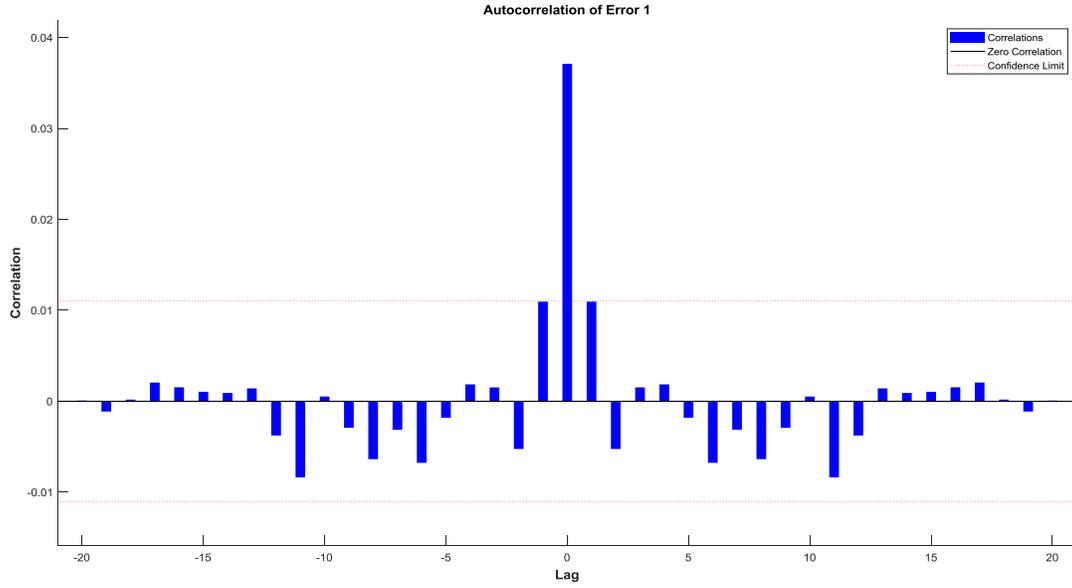


شكل (6) : أفضل قيم حقيقية لأداء الشبكة العصبية الاصطناعية

وللتأكيد وتعزيز النتائج المتحصل عليها تم رسم دالة الارتباط الذاتي بين الأخطاء بعد التدريب ودالة الارتباط الذاتي للأخطاء بعد إعادة التدريب كما في الشكل التالي :

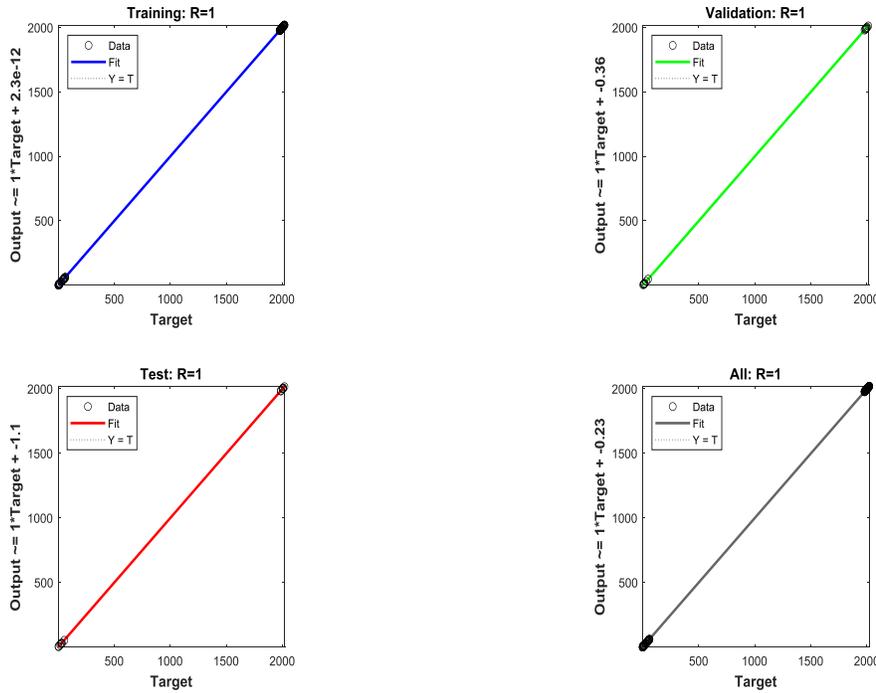


شكل (7) : دالة الارتباط الذاتي للأخطاء بعد التدريب



شكل (8) دالة الارتباط الذاتي للأخطاء بعد إعادة التدريب

نلاحظ من خلال الشكل (8) أن جميع قيم دالة الارتباط الذاتي داخل حدود الثقة أي أنه لا يوجد ارتباط ذاتي بين الأخطاء ، وبالتالي فمن خلال كل النتائج سابقة الذكر فإن الشبكة المتحصل عليها مقبولة ولا تتطلب إعادة التدريب ، وأيضاً عند قياس قيمة الارتباط (معامل الارتباط R) الذي يعكس العلاقة بين الأهداف والمخرجات وهي تقترب من الواحد الصحيح مما يدل على أن العلاقة بين الأهداف والمخرجات قوية جداً.



شكل (9) : معامل الارتباط R

بناءً على التحليل السابق يمكن إستنتاج أن الشبكات العصبية تعرض أداءً جيداً خلال عملية التدريب والتحقق ، مما يعني أن النموذج قادر على التعمق بشكل جيد دون فقدان الأداء ، و يمكن القول بأن الشبكة مستعدة للاستخدام في التنبؤ بنتائج جديدة بناءً على الأداء الجيد الذي تم عرضه خلال عملية التدريب والتحقق.

3-4 المفاضلة بين مؤشرات أسلوب بوكس جينكنز وأسلوب الشبكات العصبية الإصطناعية في التنبؤ بالمستهلك من الغاز الطبيعي .

بعد التوصل إلي نماذج للتنبؤ بواسطة منهجية بوكس – جينكنز وبالمروور بالمراحل المختلفة (التعرف، والتقدير، والفحص، والتنبؤ)، وأيضاً تم الحصول علي التنبؤات بواسطة الشبكات العصبية الإصطناعية بعد عدة خطوات تحتوي علي (المعالجة، والتقييم، والتدريب، والإختبار، والفحص، والتنبؤ)، وبالإستعانة بمعيار متوسط مربع الخطأ (MSE) والجذر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) و متوسط الخطأ المطلق النسبي (MAPE) وذلك

لمقارنة التنبؤات، ويشير جدول (3) إلى المؤشرات المتحصل عليها من الشبكات العصبية و منهجية بوكس جنكنز ويتضح أن الشبكات العصبية الإصطناعية أكثر دقة وكفاءة في التنبؤ عن أسلوب بوكس-جينكنز حيث وصلت الشبكات العصبية لمعدل مرتفع وعالي من الدقة.

جدول (3) : مؤشرات قياس جودة التنبؤ باستخدام منهجية بوكس – جينكنز والشبكات العصبية الإصطناعية

مؤشرات قياس جودة التنبؤات	الشبكات العصبية الإصطناعية (ANN)	منهجية بوكس – جينكنز ARIMA (1.1.0)
متوسط مربع الخطأ (MSE)	0.00552	0.743791
الجذر التربيعي لمتوسط مربع الخطأ (RMSE)	0.07431	0.862433
متوسط الخطأ المطلق (MAE)	0.06385	0.764758
متوسط الخطأ المطلق النسبي (MAPE)	26.14	41.065

نلاحظ من الجدول أعلاه أن المعايير بالنسبة للشبكات العصبية منخفضة وهذا يعني أن تنبؤات الشبكات العصبية الإصطناعية هي الأفضل .

4-4 القيم التنبؤية لاستهلاك الغاز الطبيعي في مصر باستخدام أسلوب الشبكات العصبية الإصطناعية

خلال الفترة (2022 – 2030)

جدول (4): القيم التنبؤية لاستهلاك الغاز الطبيعي في مصر باستخدام الشبكات العصبية الإصطناعية

الفترة	الإستهلاك السنوي (بالمليار متر مكعب)
2022	64.97
2023	66.73
2024	68.34
2025	69.91
2026	71.47
2027	73.01
2028	74.54
2029	76.05
2030	77.54

تُظهر القيم التنبؤية التي تم الحصول عليها باستخدام أسلوب الشبكات العصبية الإصطناعية توقعات استهلاك الغاز الطبيعي على مدى السنوات المقبلة، يلاحظ أن حجم استهلاك الغاز الطبيعي يزداد تدريجياً عاماً بعد عام، في عام 2022، يتوقع استهلاك حوالي 64.97 مليار متر مكعب من الغاز الطبيعي، ويتوقع أن يزداد الاستهلاك إلى حوالي 66.73 مليار متر مكعب في عام 2023 ، وأيضاً إلى

حوالي 68.34 مليار متر مكعب في عام 2024 وهكذا، وتشير هذه التوقعات إلى زيادة مستمرة في استهلاك الغاز الطبيعي على مدى السنوات القادمة ويرجع هذا النمو إلى عدة عوامل، مثل زيادة الطلب على الطاقة، والتوسع في استخدام الغاز الطبيعي في الصناعة والتدفئة، وتوسع استخدامه كوقود للمركبات، بشكل عام يمكن القول أن استخدام الغاز الطبيعي يظل مستداماً ومهماً في القطاعات المختلفة، وقد يستمر الطلب على الغاز الطبيعي في الزيادة في المستقبل القريب.

5 - النتائج والتوصيات

5-1 النتائج

تعد مصر من بين الدول ذات الأهمية الاستراتيجية في مجال الطاقة ، حيث تعتبر الطاقة أهم داعم لتنمية الإقتصاد وتحقيق الإستقرار الإجتماعي ، ويأتي الغاز الطبيعي كواحد من أهم مصادر الطاقة في مصر، حيث يلعب دوراً حيوياً في تلبية احتياجات البلاد الطاقوية، ويستند هذا البحث على دور الغاز الطبيعي كمصدر أساسي وفعال للطاقة من خلال تحليل شامل للوضع الحالي والتحديات المستقبلية، وتهدف هذه الدراسة إلى تقديم توصيات قيمة تعزز إستدامة القطاع الطاقوي في مصر وتعزز دور الغاز الطبيعي في تلبية احتياجات البلاد الطاقوية، وبإعتبار مصر جسراً إستراتيجياً بين قارتي أفريقيا وآسيا ، فذلك يظهر أهمية فهم التحديات والفرص التي تواجه قطاع الطاقة في البلاد من خلال إستكشاف تأثيرات تطورات الطاقة على الإقتصاد والبيئة والمجتمع، ونسعى إلى تقديم حلول مستدامة ومواكبة للتطورات العالمية في مجال الطاقة، من خلال تحليل عميق وموضوعي، و نطمح أيضاً إلى إضاءة نقاط القوة والضعف في قطاع الغاز الطبيعي في مصر، وأقتراح سبل تعزيز دور الغاز الطبيعي كمصدر حيوي ومستدام للطاقة في المستقبل، ومن خلال هذه الدراسة وتطبيق منهجية بوكس – جينكنز (Box - Jenkins) ونماذج الشبكات العصبية الإصطناعية ANN للتنبؤ بالاستهلاك السنوي للغاز الطبيعي في مصر فقد توصلنا إلي الآتي :

- تم ترشيح نموذج (1.1.0) ARIMA للتنبؤ بالاستهلاك السنوي للغاز الطبيعي في مصر، حيث أنه يعطي أفضل التنبؤات ، وذلك لأنه له أصغر قيمة لكل من متوسط مربع الخطأ (MSE) والجذر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) و متوسط الخطأ المطلق النسبي (MAPE) .

- استخدام الشبكات العصبية الإصطناعية حيث تم استخدام 70% من البيانات للتدريب 15% لأجل التحقق من الشبكة 15% كاختبار مستقل .
- تم تدريب الشبكة العصبية حتي تم الوصول إلي أقل خطأ ممكن .
- بلغت قيمة معامل الارتباط أكثر من 0.99 وهو إرتباط قوي جداً بين المدخلات والأهداف .
- تم تجريبه عدد من الشبكات حتي تم الوصول إلي أفضل التنبؤات.
- وأهم نتائج البحث هي مقارنة التنبؤات باستخدام معيار متوسط مربع الخطأ (MSE) و الجذر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) و متوسط الخطأ المطلق النسبي (MAPE) وكانت نتيجة هذه المقارنة هي تفوق الشبكات العصبية الإصطناعية علي منهجية بوكس-جينكنز.

5 - 2 التوصيات

بعد أن تم عرض أسلوب بوكس – جينكنز والشبكات العصبية الإصطناعية كأحد أهم الأساليب المستخدمة في تحليل السلاسل الزمنية وبعد أن تم استخدام هذين الأسلوبين في التنبؤ بالمستهلك من الغاز الطبيعي في مصر في الفترة من 1972 إلي 2021 وقد أظهرت نتائج الدراسة تفوق أسلوب الشبكات العصبية الإصطناعية علي أسلوب بوكس – جينكنز في دقة التنبؤ ، لذلك يمكننا أن نخلص إلي التوصيات التالية :

- تشجيع استخدام الشبكات العصبية الإصطناعية للتنبؤ بالسلاسل الزمنية المختلفة.
- للتنبؤ بفترة مستقبلية يجب النظر إلي فترة تاريخية كافية من البيانات للحصول علي نتائج أكثر دقة حيث أن عدد قليل من البيانات يعطي نتائج غير دقيقة.
- إعتدال الجهات التخطيطية أسلوب تحديث النموذج سنويا من خلال إضافة المعلومات السنوية للبيانات الأصلية للاستهلاك.
- يجب علي كل من يقوم بدراسة يتطلب فيها نظرة مستقبلية أن يقوم باستخدام الشبكات العصبية الإصطناعية، وذلك لتحديد الإستفادة القصوي منها حيث أن الشبكات العصبية الإصطناعية لديها السرعة والدقة واستخدامها لا يتطلب شروطاً كما في الأساليب الإحصائية الأخرى .

المراجع

اولاً: المراجع العربية

- (1) الحديثي ، عصام مولود عبد اللطيف عياش ، (1993) ، "استخدام نماذج السلاسل الزمنية للتنبؤ أنتاج محصول الذرة الصفراء في العراق" ، رسالة ماجستير مقدمة الى قسم الإحصاء ، كلية الإدارة والأقتصاد ، جامعة بغداد .
- (2) الطائي ، فارس غانم احمد (2003) "دراسة مقارنة بين طريقة بوكس - جينكنز وطريقة التنقية المعدلة في التكهّن" ، اطروحة دكتوراه غير منشورة ، كلية علوم الحاسبات ، جامعة الموصل.
- (3) العتيبي، فوزي (2003) "إستخدام السلاسل الزمنية والشبكات العصبية في التنبؤ بالارقام القياسية" رسالة ماجستير في الإحصاء التطبيقي ، جامعة قناه السويس .
- (4) بسيوني، عبد الحميد (2008) ، أساسيات الشبكات العصبية الإصطناعية، دار الكتب العلمية للنشر
- (5) شعراوي، سمير مصطفى،(2005) " مقدمة في التحليل الحديث للسلاسل الزمنية" مركز النشر العلمي ، جامعة الملك عبد العزيز .
- (6) عاشور، مروان عبدالحميد ، 2014 "استخدام الشبكات العصبية الإصطناعية المحسنة ونماذج بوكس -جينكنز في تحليل السلاسل الزمنية " ، رسالة مقدمة لنيل شهادة دكتوراة الفلسفة في الإحصاء التطبيقي، كلية الدراسات العليا، جامعة السودان - للعلوم والتكنولوجيا، السودان .
- (7) علي ،حسن محمد ، (2020) "مقدمة في تحليل السلاسل الزمنية " كلية التجارة ، جامعة الزقازيق
- (8) عماد يعقوب (2009) "استخدام نماذج بوكس - جينكنز ونماذج الشبكات العصبية الإصطناعية للتنبؤ بالسلاسل الزمنية الإقتصادية " أطروحة دكتوراه غير منشوره جامعة السودان للعلوم والتكنولوجيا ، السودان .
- (9) عناني ، محمد عبد السميع،(2011) "مبادئ الإقتصاد القياسي نظري وتطبيقي " الطبعة الثالثة الزقازيق المكتبة العلمية

ثانياً : المراجع الأجنبية

- 10) Chatfield, C.(1980).“The Analysis of Time Series: An Introduction” Bath University, 2nd ed., UK.
- 11) Chowdhury, M., Mondal S., Islam, J. (2018). Modeling and Forecasting Humidity in bangladesh: Box – Jenkins approach. International Journal of Research – Granthaalayah, 6(4),50-60.
- 12) Dielman, T.E, (2001), Applied Regression Analysis for Business and Economies 3rd Edition,Thamson le Academic Resource Center,U.S.A.
- 13) Divisekara, R., Jayasinghe, G., and Kumari, K.(2020). Forecasting the red lentils commodity market price using SARIMA models. Journal the Springer Nature SN Bus Econ, (1)20
- 14) Ilmayasinta, N. (2021). Forecasting Arrival of Foreign Tourists Using Seasonal Arima Box – Jenkins. Jurnal Ilmu Matematika dan Terapan, 15(2), 223-230
- 15) 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.
- 16) Portugal , M. S. (1995). “Neural Networks Versus Time Series Methods: A Forecasting Exercise”, University Federal do Rio Grande do Sul, Brazil.
- 17) Trafalis, Th. B. (2003). “Artificial Neural Networks Applied to Financial Forecasting”, School of Industrial Engineering, University of Oklahoma.
- 18) Vinod, H. D. (1999). “Time Series Analysis”. Economic Fordham University, Bronex, New York, USA.

A Comparative Study Of Time Series Forecasting Of Natural Gas Consumption Using Some Statistical Analysis Methods" Applied study "

Abstract

Natural gas in Egypt has witnessed a remarkable development represented in the increasing in the consumed quantity as a result of the development of economic activity, the increase in population growth, and the increase in demand for natural gas in electricity production. Therefore, this study aims to apply two methods to predict future values of natural gas consumption in Egypt, namely the Box-Jenkins methodology, which is considered one of the most important standard methods that have proven effective in the field of prediction, as well as artificial neural networks, which aim in general to simulate the human mind in order to perform several tasks, including predicting future values of time series. In order to achieve the aforementioned goal, we chose the study sample to be represented in the annual consumption of natural gas in Egypt during the period from 1972 to 2021. The Eviews program is used to apply the Box-Jenkins methodology and the MATLAB program in the artificial neural networks method. By applying these two methods, we concluded that the best model for the Box-Jenkins methodology is the ARIMA (1.1.0) model, as it is the best among the other models because it has the lowest value for the two criteria (Akaike) And (Schwarz) and when comparing the two aforementioned methods in the accuracy of prediction, it is found that the artificial neural network method is more accurate in prediction than the Box-Jenkins method because it gives a lower value for each of the mean square error (MSE), the root mean square error (RMSE), the mean absolute error (MAE), and the mean relative absolute error (MAPE), and it also gives predictions that are very close to the Real values.

Keywords: Time series, Box-Jenkins methodology, Artificial neural networks.