

Comparison Between ARIMA Models and K-Nearest Neighbor Method For Forecasting Electricity Consumption in Algeria During the Period (1980-2019)

Sahed Abdelkader¹, Kahoui Hacem²

¹Doctor, Economic, University Centre of Maghnia, Algeria, sahed14@yahoo.fr

²PhD student, Economic, University Centre of Maghnia, Algeria, hacenkahwi@gmail.com

ARTICLE INFO

Article history:

Received: 30/8/2020

Accepted: 21/9/2020

Online: 26/9/2020

Keywords:

Forecasting

ARIMA

KNN

Electricity Consumption

Algeria

JEL Code: C22, C29,

Q400

ABSTRACT

The aim of this study is to make a comparison between ARIMA models and the nearest neighbor -K (KNN) method. These models were applied to the annual time series of net electricity consumption in Algeria for the period 1980 to 2019, in a first step a model (0,1,3) (ARIMA) was approved which represents the evolutions of the electricity consumption series, after which the step of applying the method of the nearest neighbor was carried out, where 3 neighbors were identified and the Euclidean distance was calculated between the predicted values and the nearest neighbors, after which the two approaches were compared to show us in the other that the ARIMA model is better and more accurate than the nearest neighbor method, and this is based on the mean square errors MSE and root mean square errors RMSE.

دراسة مقارنة بين نماذج ARIMA وطريقة الجار الاقرب-K للتعنبؤ باستهلاك الكهرباء في الجزائر خلال الفترة (2019-1980)

ساهد عبد القادر¹، قهوي حسن²

¹دكتور، اقتصاد، المركز الجامعي مغنية، الجزائر، sahed14@yahoo.fr

²طالب دكتوراه، اقتصاد، المركز الجامعي مغنية، الجزائر، hacenkahwi@gmail.com

معلومات المقال

تاريخ الاستقبال: 2020/8/30

تاريخ القبول: 2020/9/21

تاريخ النشر: 2020/9/26

الكلمات المفتاحية

التعنبؤ

ARIMA

KNN

استهلاك الكهرباء

الجزائر

JEL Code: C22, C29,

Q40

الملخص

تهدف هذه الدراسة إلى إجراء مقارنة بين نماذج ARIMA وطريقة الجار الاقرب-K (KNN). حيث تم تطبيق هذه النماذج على السلسلة الزمنية السنوية لصافي استهلاك الكهرباء في الجزائر للفترة 1980 إلى 2019، في المرحلة الاولى من الدراسة تم التوصل إلى نموذج (0,1,3) ARIMA هو الذي يوافق تحركات الموجودة في سلسلة استهلاك الكهرباء، بعد ذلك تم تطرق إلى مرحلة تطبيق طريقة الجار الاقرب، حيث تم تحديد 3 جيران وحساب المسافة الاقليدية بين القيم المتنبأ بها والجيران الاقرب، وفي الاخير تم المقارنة بين المنهجيتين ليبتين لنا أن نموذج ARIMA أفضل وأدق من طريقة الجار الاقرب، وهذا بالاعتماد على مقياس متوسط مربعات الاخطاء MSE وجذر متوسط مربعات الاخطاء RMSE.

- مقدمة:

يعتبر موضوع تحليل السلاسل الزمنية من المواضيع الإحصائية التي اكتسب أهمية كبيرة من أجل معرفة سلوك الظاهرة، وما يطرأ على الظاهرة محل الدراسة من تغيرات إما بالزيادة أو النقصان وهذا خلال فترات زمنية متساوية، ومن هذا أكتسب هذا المفهوم أهمية كبيرة بالنسبة للأصحاب القرار لأنه يساعدهم في وضع الاستراتيجيات والخطط المستقبلية، ومن أبرز الأساليب الإحصائية والرياضية التي استخدمت في تحليل السلاسل الزمنية نذكر نماذج ARIMA، وكذلك تقنيات تلميس الأسي والانحدار التدريجي، وفي الآونة الأخيرة ظهرت أساليب جديدة واكتسبت انتشارا واسعا في التنبؤ بالسلاسل الزمنية والمتمثلة في أساليب الذكاء الاصطناعي (الشبكات العصبية الاصطناعية، المنطق الغامض، خوارزمية جينية) حيث أظهرت النتائج أنها ذات كفاءة عالية مقارنة مع الأساليب التقليدية.

تعد طريقة الجار الأقرب K أسلوب من أساليب التعلم الآلي، حيث تم استخدامها في التنبؤ بالسلاسل الزمنية على نطاق واسع وأظهرت نتائج جيدة من حيث الأداء (Li W. K., 2017).

وفي هذه الورقة سوف نتطرق إلى التنبؤ باستهلاك الكهرباء في الجزائر، وهذا راجع إلى الاهتمام البارز بهذا المصدر من طرف الدولة باعتباره عنصر رئيسي في كافة مجالات الحياة، وبالإضافة إلى ذلك حرصها على تطوير وتنمية هذا القطاع من أجل مسايرة الطلب الكبير نتيجة النمو السريع لعدد السكان، وكذلك توفيرها لمختلف القطاعات. وباعتبار الجزائر لم تهتم بعد بالطاقات المتجددة وجب عليها وضع خطط واستراتيجيات لتحديد حجم الطلب على استهلاك الكهرباء بدقة عالية، ومن خلال كل هذا سنعمد في تنبؤنا باستهلاك الكهرباء على أسلوبين من أساليب التنبؤ بالسلاسل الزمنية والمتمثلين في نماذج ARIMA وهي من الأساليب التقليدية والجار الأقرب k للانحدار الذي يعتبر من الأساليب الحديثة للتعلم الآلي.

وانطلاقا مما سبق تتبلور إشكالية الدراسة فيما يلي: كيف يمكن حصول على تنبؤات دقيقة باستهلاك الكهرباء في الجزائر خلال الفترة (1980-2019) وهذا بالاعتماد على نماذج ARIMA وطريقة الجار الأقرب.

ولقد اهتمت العديد من الدراسات الحديثة بموضوع التنبؤ باستهلاك الكهرباء نذكر منها ما يلي:

دراسة (Atlora و آخرون، 2003) بعنوان التنبؤ بالسلاسل الزمنية: تطبيق في المدى القصير الطلب على الطاقة الكهربائية حيث هدفت هذه الدراسة إلى تطبيق تقنية KNN الجار الأقرب K- على مشكلة التنبؤ بالأحمال على مدار 24 ساعة أي في المدى القصير، و الأخطاء الناتجة عن ذلك لمدة ستة أشهر، و مقارنتها مع الانحدار الديناميكي الذي يتم الحصول على المعلمات من خلال حل مشكلة المربعات الصغرى لنفس الطريقة، حيث بنيت النتائج من خلال المقارنة بينهم مفادها أن طريقة KNN أكثر دقة لمشكلة التنبؤ بالأحمال مقارنة مع الانحدار الديناميكي.

دراسة ((Boqian, Khled Rasheed) سنة 2007 بعنوان التنبؤ بسوق الأوراق المالية بالمصنفات المتعددة، هدفت هذه الورقة إلى إمكانية التنبؤ بمؤشر جونز المتوسط الصناعي لإظهار أنه ليست كل الفترات عشوائية على السواء حيث استخدم الباحثان الأس هيرست لتحديد فترة ذات قابلية كبيرة للتنبؤ، ثم لتحديد معلمات لتوليد أنماط التدريب بشكل استرشادي خلال المعلومات المتبادلة و أساليب الجار الأقرب بالخاطئة ثم تدريب بعض مصنفي تعلم

الآلة لاستقراء شبكة عصبية اصطناعية و شجرة قرار و جار أقرب K ،حيث بنيت النتائج أن استخدام هذه الأنماط التي تم إنشاؤها من خلال التعاون المناسب لهذه النماذج حققت دقة التنبؤ قد تصل إلى 65. % دراسة (Zhang و آخرون، 2010) بعنوان التنبؤ بالتدفق باستخدام الانحدار اللامعلمي لحركة المرور على المدى القصير ، حيث هدفت هذه الدراسة إلى استخدام الانحدار اللامعلمي القائم على الجار الأقرب K للتنبؤ بتدفق حركة المرور على المدى القصير ، و تطبيق الفاصل الزمني للتنبؤات المحسوبة بواسطة K للتنبؤ أثناء حالة الطريق غير التقليدية، و بينت النتائج أن الانحدار اللامعلمي القائم على الجار الأقرب K لديه دقة عالية مقارنة مع الشبكة العصبية.

دراسة (Hugo و آخرون، 2012) بعنوان تقييم تقنيات التنبؤ لإنتاج الطاقة الشمسية مع عدم وجود المخلات الخارجية ،حيث هدفت هذه الورقة إلى التنبؤ بإخراج الطاقة الشمسية و هذا خلال الفترة الزمنية الممتدة من نوفمبر 2009 إلى أوت 2011، يتم استخدام البيانات قبل يناير 2011 للتدريب ، و الأساليب التي تمت دراستها في هذا العمل ، نموذج المتوسط المتحرك و الانحدار الذاتي المتكامل ARIMA و الجار الأقرب (K KNN والشبكات العصبية الاصطناعية ANNS و تحسين ANN بخوارزميات الجينية GAS/ANN و يتم تحديد دقة النماذج عن طريق حساب إحصائيات الخطأ مثل MAE، R²، (MBE خطأ التميز المتوسط)، وبنيت النتائج أن نموذج ANN تفوق على ARIMA و KNN من حيث الدقة في التنبؤ و علاوة على ذلك فإن النموذج GAS/ANN يعطي أفضل دقة في التنبؤ مقارنة مع ANN.

دراسة (Alkhatib و آخرون، 2013) بعنوان التنبؤ بأسعار الأسهم باستخدام خوارزمية الجار الأقرب K حيث هدفت هذه الورقة إلى تطبيق خوارزمية الجار الأقرب K و نهج الانحدار غير الخطي من أجل التنبؤ بأسعار الأسهم لعينة من ستة شركات كبرى مدرجة في البورصة الأردنية لمساعدة المستثمرين و ضاع القرار و الإدارة و المستخدمين في اتخاذ القرارات الاستثمارية الصحيحة، ووفقا للنتائج فإن استخدام طريقة الجار الأقرب (K.NN) فكانت منطقية و قوية مع نسبة خطأ صغيرة ، كما تميزت نتائج التنبؤ بالموازنة تقريبا مع أسعار الأسهم الفعلية.

دراسة (Carlo, Aguilar، 2019) بعنوان التنبؤ بالمبيعات الترويجية باستخدام طريقة الجار الأقرب ،حيث هدفت هذه الدراسة إلى تطبيق طريقة التعلم الآلي مصممة خصيصا للتنبؤ التلقائي للمبيعات الترويجية و تطبيقها في السوق الحقيقي ،حيث استخدمت طريقة الجار الأقرب K ومقارنتها مع شجرة الانحدار والتوقعات المقدمة من تاجر التجزئة، حيث بنيت النتائج أن منهجية K- NN تعطي دقة في التنبؤ مقارنة مع الأساليب الأخرى.

1- منهجية البحث:

1-1- البيانات:

في هذه الدراسة سنتطرق استخدام السلسلة سنوية المتعلقة بسلسلة استهلاك الكهرباء في الجزائر، وتمتد هذه السلسلة من سنة 1980 إلى غاية سنة 2019 وقد تم الحصول على بيانات هذه السلسلة من الموقع الإلكتروني:

https://www.theglobaleconomy.com/Algeria/electricity_consumption

1-2- نموذج ARIMA:

السلاسل الزمنية هي عبارة عن مجموعة من المشاهدات المسجلة لظاهرة ما بمرور الزمن، ويعتبر تحليل السلاسل الزمنية مبني أساسا على الاستقرار، حيث تتميز السلسلة الزمنية المستقرة بنوع من الموازنة الإحصائية حول المتوسط الثابت والتباين وفي حالة استقرار السلسلة الزمنية يمكن تحديد النموذج لها، ومن هذه النماذج نجد نماذج الانحدار الذاتي $AR(p)$ وهو عبارة عن العلاقة بين القيم الحالية والسابقة للسلسلة الزمنية، ويكتب بالصيغة التالية (طالب، 2018، ص 16):

$$y_t = B_0 + B_1 y_{t-1} + \dots + B_p y_{t-p} + \varepsilon_t$$

ونموذج المتوسطات المتحركة $MA(q)$ ويتبين أن القيمة الحالية للمتغير لها دالة خطية لقيمة الخطأ العشوائي والخطأ العشوائي السابق للسلسلة، ويأخذ الصيغة التالية (Yuan C. L., 2016):

$$y_t = \mu + \mu_t + m_1 \mu_{t-1} + \dots + m_q \mu_{t-q}$$

ونموذج الانحدار الذاتي والأوساط المتحركة (ARMA) المختلط وأن $p+q$ هما عدد معاملات النموذج ويكتب بالصيغة التالية (Ighravwe, 2019):

$$X_t = \mu + Q_1 X_{t-1} + \dots + Q_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \dots - \theta_{t-p} \varepsilon_{t-q}$$

ويمكن تلخيص سيرورة نماذج ARIMA في المراحل التالية (Felipe, 2012):

مرحلة التعريف: تعتبر هذه المرحلة أهم مراحل النموذج حيث يتم من خلالها تحديد رتب النموذج المطلوب من أجل النقاط الميزات الديناميكية للبيانات، يمكن استخدام رسم البياني لدالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF)، للتحديد رتب النموذج ARIMA (Makridakis, 1997)، ولتحقيق ذلك يجب أولاً أن تكون السلسلة مستقرة، يعني من هذا أن تكون لها متوسط ثابت وتباين وارتباط ذاتي مستقل عن الزمن، ونظراً لأن البيانات غير مستقرة، يتعين علينا تحويل السلسلة مستقرة عن طريقة الفروق.

مرحلة التقدير: في هذه المرحلة يتم تقدير نموذج ARIMA ليعطي عدداً من المعالم وذلك بعد اختيار قيم (p, d, q) وهنا تستخدم الخوارزميات الحسابية (طريقة المربعات الصغرى الاعتيادية أو تقنيات أخرى).

مرحلة الاختبار: تتضمن هذه المرحلة فحص النموذج المختار و التحقق من ملائمته لتمثيل بيانات السلسلة الزمنية بدقة و يتم ذلك من خلال فحص معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي للبواقي في النموذج المقدر و ليس السلسلة الأصلية ، و لهذا فإذا كانت جميع معاملات الارتباط الذاتي لعدد من الفجوات تقع داخل مجال الثقة (95%) فمن هناك يكون الارتباط الذاتي بين حدود الخطأ العشوائي غير معنوي و في هذه الحالة فإن النموذج

هو الملائم للتقدير و التنبؤ ، كما أنه هنالك بعض المعايير الأخرى لفحص النموذج و التأكد انه النموذج المناسب و منها إحصائية Ljung –Box (طعمه، 2012):

التنبؤ: تعتبر مرحلة التنبؤ المرحلة الأخيرة من مراحل منهجية بوكس جنكيز فبعد مرحلة تشخيص النموذج و تقدير معالمته و تخطيه مرحلة الفحوص التشخيصية يصبح النموذج جاهزا للتنبؤ بالمشاهدات المستقبلية (حمدي، 2013).

1-3- طريقة الجار الأقرب (k-Nearest Neighbors):

ثم اقتراح هذه الطريقة عن طرف (Fix, 1989, p2) ، والتي يرمز لها باختصار K-NN ، حيث تعتبر تقنية الجار الأقرب (KNN) تقنية من تقنيات مجال التعلم الخاضع للإشراف في التعلم الآلي الذي يمكن استخدامه لكل من التصنيف والانحدار . (Cristian, 2018, p6) وتعتبر KNN طريقة لا معلمية (Martínez, 2019, p2) ، كما تعتبر knn خوارزمية معروفة في مجموعة التعلم الآلي (Majidpour, 2019, p110) ، حيث اقترح Yakowit في عام 1987 استخدام أسلوب الجار الأقرب k في التنبؤ بالسلاسل الزمنية (Zhang, 2010, p2851).

حيث تعتمد الخوارزمية في عملها على قياس المسافة باستخدام الطريقة الاقليدية والتي تعتبر أكثر استعمالاً للقياس المسافة بين كل نقطة و النقطة الأقرب إليها، وعندما تكون البيانات قريبة من بعضها تكون المسافة الاقليدية قليلة جدا بين كل نقطة و النقطة المجاورة لها ولكن كلما تباعدت قيم البيانات وتبعثرت أصبحت المسافات بين النقاط كبيرة ومنها جاء عنوان الخوارزمية إذ يشير الحرف k إلى الحالات التي سيتم تصنيفها. بناء على المسافات بينها أي بين الجيران (جاسم الفارس، 2018، ص 578)، ونحسب المسافة وفق المعادلة الآتية (Li, 2017, p5):

$$d(x,y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2}$$

حيث تمثل (x_1, x_2, \dots, x_k) و (y_1, y_2, \dots, y_k) متجهات المعالم، و k تمثل عدد الجيران الاقرب.

ومن أجل حساب الخوارزمية الجار الأقرب K نتبع الخطوات التالية (بسام، 2010، الصفحات 209-236)

حيث تقوم عملية التنفيذ لـ KNN على الخطوات التالية:

- تحديد القيمة K
- حساب المسافة بين النقطة في مجموعة بيانات الفئة المعروفة و النقطة الحالية .
- زيادة الترتيب في ترتيب المسافة .
- تحديد نقاط k من اصغر مسافة من النقطة الحالية.
- تحديد تكرار حدوث الفئة التي توجد فيها نقاط k.
- الرجوع إلى الفئة ذات أعلى تكرار لحدوث نقاط k الأولى كانحدار متوقع للنقطة الحالية.
- استخدام متوسط أقرب جيران كقيمة تنبؤية.

1-4- معايير تقييم دقة التنبؤ:

تستخدم المعايير التالية لقياس كفاءة نموذج التنبؤ، والتي تلعب دورا مهما في التحليل والمقارنة، نذكر منها
: (Majidpour, 2019, p. 109)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n e_i$$

متوسط الخطأ المطلق

$$\text{MAPE} = \sum \frac{|PE|}{n}$$

متوسط الخطأ المطلق النسبي

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (e_i)^2$$

متوسط مربع الخطأ

$$\text{RMSE} = \sqrt{\text{MSE}}$$

جذر متوسط مربع الخطأ

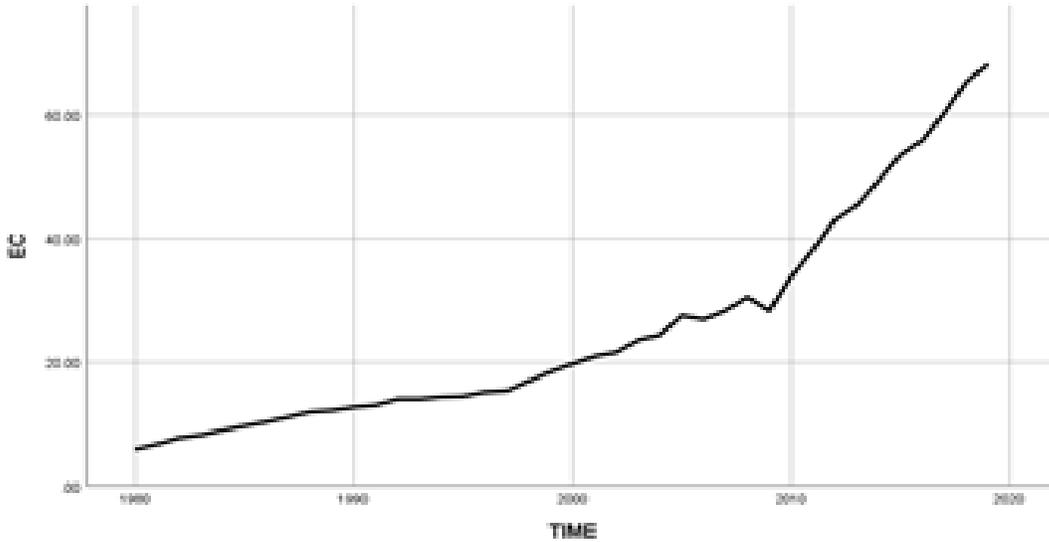
$$R^2 = \frac{\text{MSE}}{\text{SST}} = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2}$$

معامل التحديد

2- النتائج والمناقشة:

يتضح الشكل البياني رقم (01) أن استهلاك الكهرباء في الجزائر في ارتفاع مستمرة من سنة إلى أخرى نظرا للتطور التكنولوجي، ضف إلى ذلك الاحتباس الحراري الذي يؤثر على المناخ في الجزائر كارتفاع للحرارة، او البرودة الشديدة، زد على ذلك عدم الترشيد في استهلاك الكهربائي.

شكل رقم (01): استهلاك الكهرباء في الجزائر

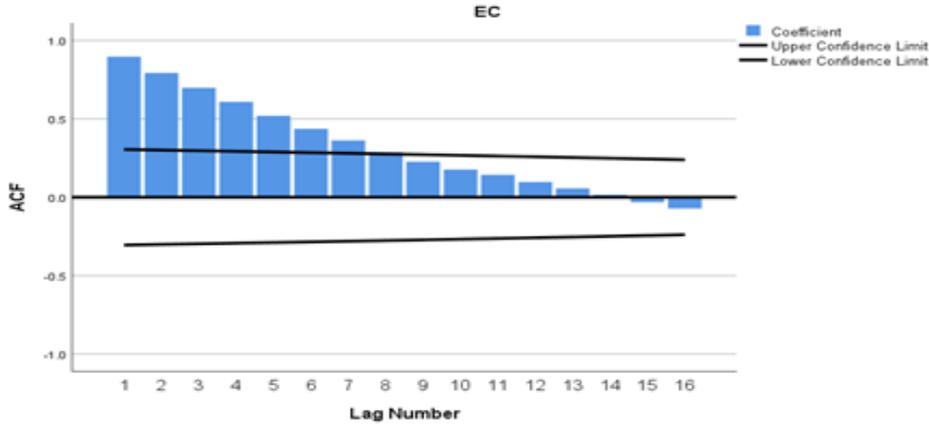


المصدر: من إعداد الباحثين

1-2- استخدام نموذج ARIMA في التنبؤ باستهلاك الكهرباء :

من خلال النظر إلى منحنى استهلاك الكهرباء يتبين أن السلسلة تحتوي على اتجاه عام وبالتالي فإن السلسلة غير مستقرة، ولتأكد من ذلك نقوم برسم دالة الارتباط الذاتي لهذه السلسلة، حيث يتضح من الشكل البياني رقم (02) أن معظم التباينات تختلف عن الصفر، هذا يدل على أن السلسلة قيد الدراسة غير مستقرة.

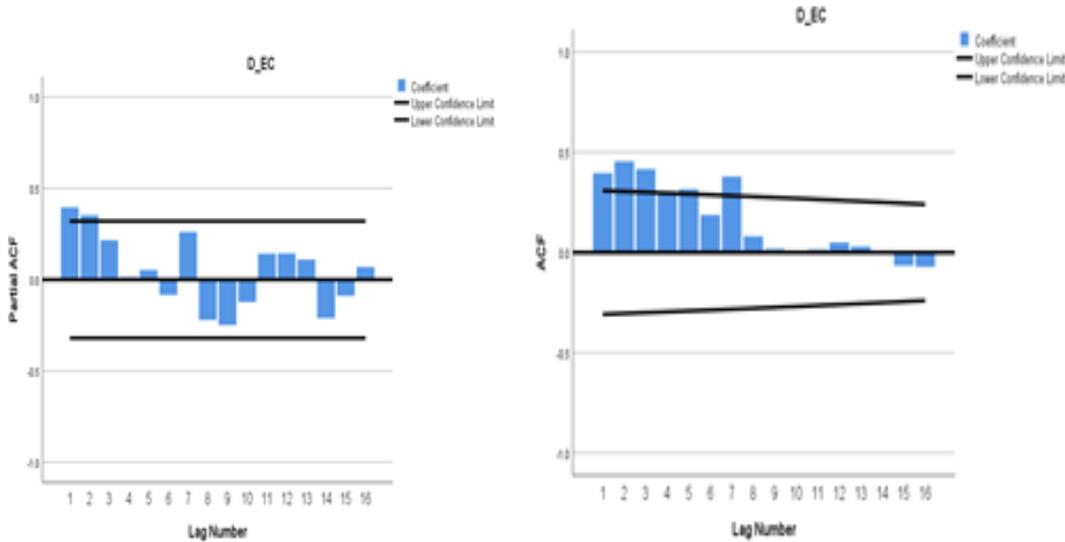
شكل رقم (02): دالة الارتباط الذاتي لسلسلة استهلاك الكهرباء



المصدر: من إعداد الباحثين

ومن أجل جعل السلسلة مستقرة نقوم باستخدام طريقة الفروق، حيث أن السلسلة مستقرة من الدرجة الاولى، بعد ذلك قمنا برسم دالة الارتباط الذاتي البسيطة والجزئية لأجل معرفة رتب نموذج ARIMA، ومن خلال الشكل البياني رقم (03) ومعيار تدنية لاكايك وشيوارز يتضح أن النموذج الملائم هو من النوع $ARIMA(0,1,3)$.

شكل رقم (03): رسم دالة الارتباط الذاتي الجزئية والبسيطة لسلسلة الفروق



المصدر: من إعداد الباحثين

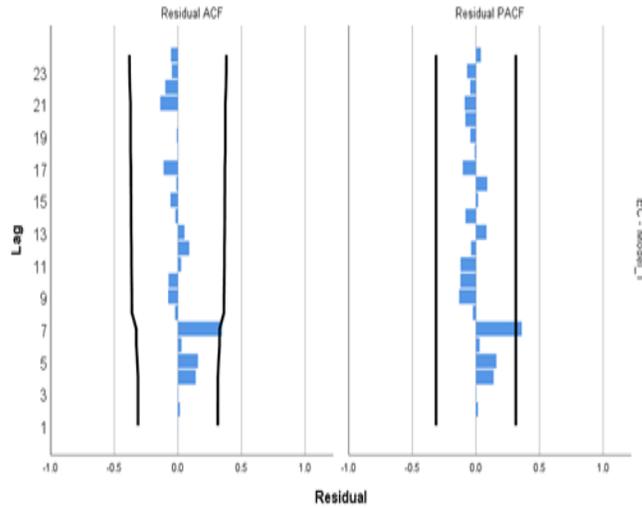
أما فيما يخص تقدير النموذج، فتم اختيار طريقة الامكان الاكبر لتقدير نموذج $ARIMA(0,1,3)$ ، فتحصلنا على النتائج التالية والممثلة في الجدول رقم (01).

جدول رقم (01): تقدير النموذج $ARIMA(0,1,3)$

النموذج		Estimate	SE	t	Sig
	Constant	1.621	0.494	3.284	0.002
MA 2	Lag 2	-0.464	0.144	-3.228	0.003
MA 3	Lag 3	-0.513	0.161	-3.184	0.003

المصدر: من إعداد الباحثين

ولنتحقق من جودة النموذج المقدر، قمنا برسم دالة الارتباط الذاتي البسيطة والجزئية لسلسلة البواقي، فتحصلنا على الشكل رقم (04) إذ نلاحظ أن جميع المعاملات تقع داخل الحدود المفروضة مما يدل على جودة النموذج. شكل رقم (04): الرسم البياني لدالة الارتباط الذاتي والجزئية لسلسلة البواقي



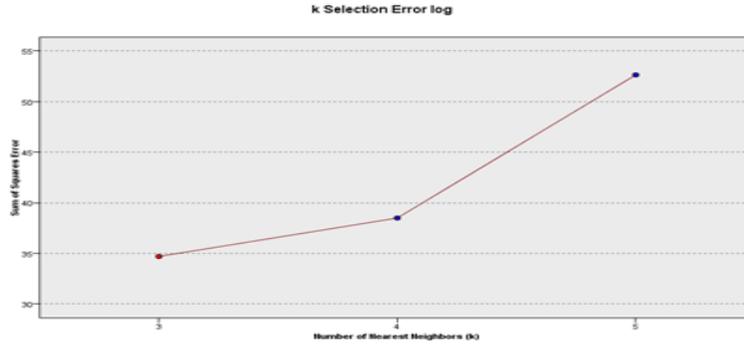
المصدر: من إعداد الباحثين

2-2- استخدام طريقة الجار الأقرب-K (KNN) في التنبؤ باستهلاك الكهرباء:

يمكن تلخيص خطوات خوارزمية الجار الأقرب-K فيما يلي:

- تم تحديد عدد المتغيرات المستقلة، والتي تتمثل في $(EC_{t-1}, EC_{t-2}, EC_{t-3})$ وتم هذا بالاعتماد على دالة الارتباط الجزئية ودالة الارتباط البسيطة.
- وقد تم أخذ عينة مكونة من 40 مشاهدة، تم استخدام 70% من المشاهدات لغرض التدريب، و30% لغرض الاختبار والتأكد.
- تم تحديد عدد الجيران الأقرب عن تدنية مجموع مربعات الأخطاء، وقد تبين من الشكل البياني رقم (05) أن عدد الجيران الأقرب الامثل هو 3.

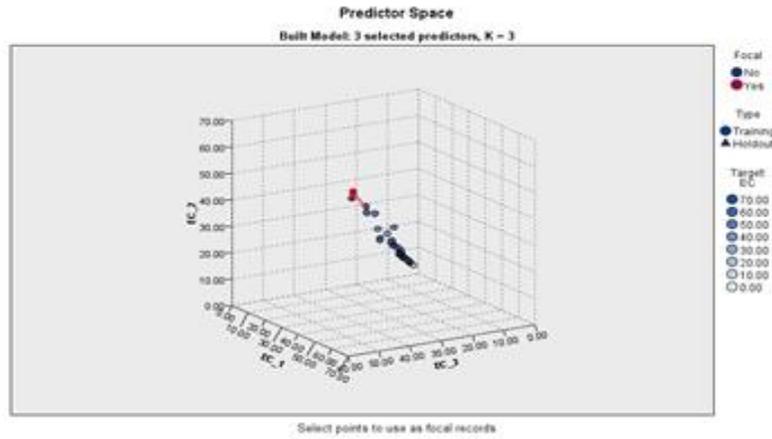
شكل رقم (05): عدد الجيران



المصدر: من إعداد الباحثين

ومن أجل حساب المسافة الاقليدية بين القيم المستهدفة وأقرب الجيران، تم رسم الشكل البياني رقم(06) والذي يوضح مشاهدات استهلاك الكهرباء في فضاء مكون من ثلاث أبعاد.

شكل رقم (06): حساب المسافة بين القيمة المستهدفة وأقرب الجيران



k Nearest Neighbors and Distances

Displayed for Initial Focal Records

Focal Record	Nearest Neighbors			Nearest Distances		
	1	2	3	1	2	3
40	39	37	36	0.257	0.714	0.938

المصدر: من إعداد الباحثين

3-2- المقارنة بين نموذج ARIMA وطريقة الجار الاقرب-K (KNN):

لمعرفة النموذج الملائم للتنبؤ باستهلاك الكهرباء في الجزائر، قمنا بحساب معيار متوسط مربعات الخطأ (MSE) وجذر متوسط مربعات الخطأ (RMSE) لكل من نموذج ARIMA وطريقة KNN والنتائج ممثلة في الجدول رقم (02).

جدول رقم (02): المقارنة بين النموذج ARIMA وطريقة KNN

time	EC	ARIMA	KNN
2010	33.84	29.88	32.36
2011	38.24	35.69	35.8
2012	43.06	40.94	34.19
2013	45.39	48.34	48.68
2014	49.41	48.68	50.85
2015	53.56	50.9	56.89
2016	55.93	54.57	56.1
2017	60.27	59.44	58.28
2018	65.34	64.06	59.24
2019	68.23	68.31	58.28
MSE		4.71728	25.1009
RMSE		2.17193002	5.01007984

الوحدة: مليار كيلووات في الساعة. المصدر: من إعداد الباحثين

ومن خلال الجدول رقم (02) نلاحظ أن نموذج ARIMA كان أفضل وأدق من طريقة الجار القارب وهذا لحصوله على أقل قيمة لـ MSE و RMSE، وبالتالي فإننا نوصي باستخدام نماذج ARIMA في النمذجة والتنبؤ باستهلاك الكهرباء في الجزائر، وهذا ما يتطابق مع كثير من الدراسات في هذا المجال.

- خاتمة:

هدفت هذه الدراسة إلى استخدام نماذج ARIMA من جهة، وطريقة الجار الاقرب K- (KNN) من جهة أخرى. تم تطبيق هذه النماذج على السلسلة الزمنية السنوية لصافي استهلاك الكهرباء في الجزائر للفترة 1980 إلى 2019، في المرحلة الاولى تم التوصل إلى نموذج ARIMA(0,1,3) الذي يوافق تحركات الموجودة في سلسلة استهلاك الكهرباء، بعد ذلك تم تطرق إلى مرحل تطبيق طريقة الجار الاقرب، حيث تم تحديد 3 جيران وحساب المسافة الاقليدية بين القيم المتنبأ بها والجيران الاقرب، بعد ذلك تم المقارنة بين المنهجيتين ليتبين لنا في الاخر ان نموذج ARIMA أفضل وأدق من طريقة الجار الاقرب وهذا بالاعتماد على مقياس متوسط مربعات الاخطاء MSE وجذر متوسط مربعات الاخطاء RMSE.

- قائمة المصادر والمراجع

- 1- طالب. (2018). استخدام منهجية بوكس-جينكنز لبناء نموذج قياسي للتنبؤ بعدد المواطنين السوريين. مجلة جامعة تشرين للبحوث والدراسات العلمية-سلسلة العلوم الاقتصادية والقانونية, 40(6).
- 2- جاسم الفارس، نعمه عبد الله الفخري، (2018). استخدام خوارزمية الجار الأقرب (Knn) في تحديد العوامل المؤثرة على خط الفقر الوطني، مجلة جامعة كركوك للعلوم الادارية والاقتصادية، 8(2).
- 3- سام على، أنهار خير الدين محمد، (2010) سمير عبد الودود، استخدام تنقيب البيانات للتنبؤ بظاهرة تسرب طلبة الكلية بالتطبيق على كلية الإدارة والاقتصاد، المجلة العراقية للعلوم الاحصائية.
- 4 -Li, W., Kong, D., & Wu, J. (2017). A novel hybrid model based on extreme learning machine, k-nearest neighbor regression and wavelet denoising applied to short-term electric load forecasting. Energies, 10(5).
- 5 -Lora, A. T., Santos, J. M. R., Riquelme, J. C., Expósito, A. G., & Ramos, J. L. M. (2003, November). Time series prediction: Application to the short-term electric energy demand. In Conference on Technology Transfer. pp. 577-586.
- 6 -Qian, B., & Rasheed, K. (2007). Stock market prediction with multiple classifiers. *Applied Intelligence*. 26(1), 25-33.
- 7 -Zhang, T., Hu, L., Liu, Z., & Zhang, Y. (2010, June). Nonparametric regression for the short-term traffic flow forecasting. In 2010 International conference on mechanic automation and control engineerin. (pp. 2850-2853). IEEE.
- 8 -Alkhatib, K., Najadat, H., Hmeidi, I., & Shatnawi, M. K. A. (2013). Stock price prediction using k-nearest neighbor (kNN) algorithm. International Journal of Business, Humanities and Technology. 3(3), 32-44..
- 9 -Aguilar-Palacios, C., Muñoz-Romero, S., & Rojo-Álvarez, J. L. (2019). Forecasting Promotional Sales Within the Neighbourhood. IEEE Access, 7, pp.74759-74775.
- 10 -Nochai, R., & Nochai, T. (2006, June). ARIMA model for forecasting oil palm price. In *Proceedings of the 2nd IMT-GT Regional Conference on Mathematics, Statistics and applications*. Jun 13 pp. 13-15.
- 11-Yuan, C., Liu, S., & Fang, Z. (2016). Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model. Energy. 100, pp.384-390.
- 12 -Ighravwe, D., & Anyaeche, C. (2019). A comparison of ARIMA and ANN techniques in predicting port productivity and berth effectiveness International Journal of Data and Network Science. 3(1), pp.13-22.
- 13 -Makridakis, S., & Hibon, M. (1997). ARMA models and the Box-Jenkins methodology. *Journal of Forecasting*. 16(3), pp.147-163.
- 14 -Fix, E., & Hodges, J. L. (1989). Discriminatory analysis. Nonparametric discrimination: consistency properties. International Statistical Review/Revue Internationale de Statistique. pp.233-238.
- 15 -Cristian, M. (2018). Average monthly rainfall forecast in Romania by using K-nearest neighbors regression. Analele Universității Constantin Brâncuși din Târgu Jiu: Seria Economie. 1(4), pp.5-12.
- 16 -Martínez, F., Frías, M. P., Pérez, M. D., & Rivera, A. J. (2019). A methodology for applying k-nearest neighbor to time series forecasting. Artificial Intelligence Review. 52(3).
- 17 -Majidpour, M., Nazari-pouya, H., Chu, P., Pota, H. R., & Gadh, R. (2019). Fast Univariate Time Series Prediction of Solar Power for Real-Time Control of Energy Storage System. Forecasting. 1(1), pp.107-120.
- 18 -Zhang, T., Hu, L., Liu, Z., & Zhang, Y. (2010, June). Nonparametric regression for the short-term traffic flow forecasting. In 2010 International conference on mechanic automation and control engineering. (pp. 2850-2853). IEEE.
- 19 -Fan, G. F., Guo, Y. H., Zheng, J. M., & Hong, W. C. (2019). Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting. Energies. 12(5), p.916.