

مقارنة بعض الطرائق الالاعلمية باستعمال المحاكاة

بسام هاشم داخل

أ.م.د علي ياسين غني

الباحث

الجامعة المستنصرية/ كلية الادارة والاقتصاد

P: ISSN : 1813-6729

<http://doi.org/10.31272/JAE.44.2021.129.27>

E : ISSN : 2707-1359

مقبول للنشر بتاريخ : 2021/6/15

تاريخ أستلام البحث : 2021/4/27

المستخلص:-

ظهرت الحاجة لمقارنة الطرائق الالاعلمية المستعملة في التنبؤ بالسلاسل الزمنية لإيجاد الأسلوب الأكثر كفاءة في التنبؤ، وكان هذا بالحقيقة يمثل الهدف الأساس لإجراء هذه الدراسة. وتلخصت مشكلة البحث بان الطرائق الاحصائية المعلمية تحتاج الى شروط ومعايير قد يصعب توافرها لذلك توجب البحث عن طرائق جديدة للتنبؤ بخلاف الطرائق التقليدية هي الطرائق الالاعلمية. وكانت المقارنة من خلال تطبيق اسلوب المحاكاة حيث تم توليد البيانات عن طريق معادلة التوليد المقيد بالاعتماد على البيانات الاصلية اقل قيمة واعلى قيمة لكل نوع من البيانات. ومحور الدراسة هي مقارنة بين طريقتي الشبكات العصبية (شبكة الانتشار الخلفي للخطأ) وطريقة Kernel (مقدر Nadaraya-Watson) اما حجوم العينات فتم اختيار الحجوم (15 و 30 و 60 و 100) اما فيما يخص المعايير التي استعملت للمقارنة فكانت (MSE، RMSE، MAE، MAPE). اظهرت النتائج ومن خلال المحاكاة أن الشبكات العصبية تعطي نتائج افضل واكثر كفاءة من طريقة Kernel في اغلب المقاييس ولجميع حجوم العينات.

المصطلحات الرئيسية للبحث : ، السلاسل الزمنية ، الانحدار الالاعلمي، مقدر Nadaraya-Watson ، الذكاء الصناعي، الشبكات العصبية الاصطناعية، الانتشار الخلفي للخطأ



مجلة الادارة والاقتصاد
العدد 129 / ايلول / 2021
الصفحات : 456-467

بحث مستل من رسالة ماجستير

1 - المقدمة :-

من الأهداف الأساسية للعلوم الإحصائية التنبؤ بالسلوك المستقبلي للظاهرة قيد البحث. حيث نجد يومياً، ومن خلال وسائل الاعلام، الاهتمام اليومي بالتنبؤات الجوية والمتغيرات الاقتصادية المختلفة. وقد أولى تحليل السلاسل الزمنية اهتماماً كبيراً للتنبؤ واقتُرحت العديد من الأساليب لغرض إجراء التنبؤ. ومن الأساليب الحديثة التي أخذت اهتماماً ملحوظاً، ولاسيما في مجال علوم الحاسبات، الطرائق الالاعلمية (الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs و (طريقة Kernel)، وهدفنا المقارنة بين هذه الطرائق واختبار الانموذج الأكفأ كون المشكلة الرئيسية للبحث تتعلق بصعوبة تحقق بعض الافتراضات للطرائق الالاعلمية، حيث أن الفكرة الأساسية من الأسلوب الاول هو إنشاء نموذج معلومات يحاكي النظام البيولوجي العصبي، مثل الدماغ، ومعالجة المعلومات. إن المفتاح الأساس لهذا الانموذج هو بناء هيكل جديد لنظام معالجة المعلومات الذي يقوم بربط وتنظيم العديد من عناصر المعالجة المرتبطة مع بعضها وهي (العصبونات) التي تعمل بشكل متناسق لحل المشكلة قيد الدراسة. أما الأسلوب الثاني وفي المجال الإحصائي، ظهرت في الآونة الأخيرة اهتمامات خاصة لإدخال الأسلوب الالاعلمي إلى التطبيقات الإحصائية. ولما كان استعمال هذا الأسلوب لا يتطلب افتراضات عن طبيعة السلسلة الزمنية، لذا يُعتقد إن استخدام هذا الأسلوب قد يكون مجزياً في معالجة مسألة التنبؤ التي نحن بصدها بهذه الدراسة.

2- السلاسل الزمنية: Time series

يمكن تعريف السلسلة الزمنية بمجموعة من المشاهدات العشوائية المرصودة والمعرفة ضمن فضاء الاحتمالية هذا من الناحية الرياضية ويرمز لها بالرمز $\{X_t; t \in T\}$ ، تطبيقياً هي مجموعة من البيانات المسجلة لظاهرة معينة خلال فترة زمنية سابقة مثل بعض الحالات الاقتصادية أو الإحصائية وتكون مرتبطة بشكل متسلسل عبر الزمن [6].

1-2 الانحدار الالاعلمي : Nonparametric regression

يعتمد هذا النوع من النماذج على تقنيات حرة " لالاعلمية " فهي لا تفترض وجود عائلة نماذج بل تركز على الفكرة " اترك المعطيات تتكلم وحدها " Let data speak for themselves . لقد شهد الاحصاء الالاعلمي تطوراً كبيراً في الآونة الاخيرة ولاسيما في دراسة العلاقات الاقتصادية حيث لم يستخدم في السلاسل الزمنية الا في بداية الثمانينات . ان مبدأ هذه الطريقة يتمثل في دراسة معلمات تركز او تشتت التوزيع الشرطي للظاهرة Y عندما المتغير $X=X$. يتم اختيار هذه الطريقة عند تعميم الانحدار غير الخطي الالاعلمي فعندما تكون هناك صعوبة في اختيار الشكل الملائم للنموذج غير الخطي ، نستعين بتقنيات حرة لتقدير الظاهرة معتمداً على المتغيرات المستقلة اضافة الى ذلك فان التقدير الالاعلمي للانحدار لا يعتمد على اي معلمة اي لايتعلق الامر بتقدير متجه ذي بعد محدود بل عدد المعلمات المراد تقديرها غير منتهى [4].

2-2 كيرنل في السلاسل الزمنية:- Kernel in time series

بفرض لدينا سلسلة زمنية احادية المتغير $\{Z_t; t \in Z\}$ في فترة زمنية $1 \leq t \leq n$ من المفترض ان تتبع السلسلة الزمنية الانموذج التالي :

$$Z_t = m(Z_{t-1}, Z_{t-2}, \dots, Z_{t-ip}) + \epsilon_t \dots (1)$$

اذ ان

$$m(\vec{u}) = E(Z_{t-1}, Z_{t-2}, \dots, Z_{t-ip}) = u$$

with

$$\vec{u} \in R^p, 0 < i1 < i2 < \dots < ip$$

$\{\epsilon_t\}$ حد الخطأ العشوائي ويتوزع بمتوسط صفري ويفترض انها مستقلة

من اجل التنبؤ ب Z_{t+1} فأنا نعتبر البيانات $\{(\vec{X}_j), (\vec{Y}_j): j \in Z\}$ مع القيم

$$R^P * R = R^{P+1}$$

اذ ان

$$(\vec{X}_j) = (Z_{j+ip-i}, Z_{j+ip-i2}, \dots, Z_j)$$

$$Y_j = Z_{j+ip}$$

بمعنى نتقل من بيانات السلسلة الزمنية المرصودة $\{Z_t: 1 \leq t \leq n\}$ الى بيانات الانحدار

$$\{(\vec{X}_j, y_i): 1 \leq j \leq n' = -ip\}$$

حيث يمكن استخدام البيانات الجديدة مباشرة لتقدير دالة الانحدار الذاتي $m(\cdot)$

$$\hat{m}(\vec{X}_{n-ip+1}) = \hat{m}(Z_{n+ip-i1}, Z_{n+ip-i2}, \dots, Z_n)$$

اذ ان $\hat{m}$ هو مقدر m

ان تقدير الانحدار الالعملية كما ذكرنا انفا له مزايا كثيرة مقارنة بالطرائق المعملية التقليدية في هذ السياق حيث يكون نهجه اكثر مرونة ويمكن تكيفه جيدا وهو امر مهم جداً في التنبؤ Z_{t+l} (with $l \geq 1$)

يجب اعادة تعريف العينة الجديدة $\{(X_j, Y_j)\}$ باستخدام خوارزمية متكررة وللقيام بذلك يتم الحصول على التنبؤ النقطة Z_{t+1} كما موضح انفا سيتم الاشارة الى هذا بواسطة $\hat{Z}_{n(1)}$ تم ادراج هذا التنبؤ في عينة السلاسل الزمنية

$$\{Z_1, Z_2, \dots, Z_n, \hat{Z}_{n(1)}\}$$

من اجل توقع Z_{n+1} للأمام في لحظة واحدة تكرر هذه العملية حتى يتم الوصول الى تنبؤ الافق l وعادة ما تكون هذه الطريقة اقل استهلاكاً للوقت ، حيث يتم اختيار متغيرات الانحدار الذاتي مرة واحدة فقط . ومن ثم فإن المشكلة الاساسية للتنبؤ Z_{t+1} هي ايجاد مقدر $m(\vec{u})$ مع $\vec{u} = \vec{X}_{n-ip+1}$ في هذا السياق نعتبر المقدرات الالعملية المعتادة ل $m(\vec{u})$ بالشكل العام

$$m(\vec{u}) = \sum_{j=1}^{n_0} w(\vec{u}, \vec{x}_j) y_i \dots (2)$$

حيث ان $w(\vec{u}, \vec{x}_j)$ هي بعض الاوزان الموجبة للتمهيد اذا كانت $\vec{u}$ قريبة من $\vec{x}_j$ والقيم قريبة من الصفر خلاف ذلك [10] .

3-2 طريقة مقدر Nadaraya-Watson $\hat{m}_h, NW(\vec{u})$

مقدر Nadaraya-Watson من ابسط الممهدات حيث استعمل على نطاق واسع في كثير من المجالات البحثية قدمه الباحث Nadaraya سنة 1964 و Watson وهو مقدر مهم لتقدير دالة (Kernel) ويمكن الحصول عليه باستعمال المعلمة التمهيدية الثابتة لعلاج مستوى تجانس التقدير من خلال تطبيق المعدل الموزون للمشاهدات

$$W_{H,NW}(\vec{u}, \vec{x}_j) = \frac{K_H(\vec{x}_j - \vec{u})}{\sum_{j=1}^{n_0} K_H(\vec{x}_j - \vec{u})} \dots (3)$$

حيث ان H هي عن مصفوفة $p \times p$ محدده موجبة متماثلة تسمى مصفوفة معلمة التمهيد ، تحتوي هذه المصفوفة على معلومات حول مقدار التنعيم في المقدر الالعملي .

$$K_H(\vec{V}) = |H|^{-\frac{1}{2}} K(H^{-\frac{1}{2}} \vec{V})$$

الدالة K تمثل دالة (Kernel) وهي دالة نواة ثنائية المتغير
وفيما يلي مصفوفة معلمة التمهيد القطري بالشكل $H = \text{diag}\{h, \dots, h\}$ حيث ان h تمثل معلمة التمهيد احادي البعد

$$K(\vec{V}) = \prod_{t=1}^p K(v_t)$$

سيتم استخدامها ، حيث ان $K(v)$ تمثل نواة متماثلة احادية المتغير باستخدام الترميز

$$K_h(v) = \frac{1}{h} K\left(\frac{v}{h}\right)$$

ومن ثم نستنتج ان

$$W_{H,NW}(\vec{u}, \vec{x}_j) = \frac{\prod_{t=1}^p K_h(x_{jt} - u_t)}{\sum_{j=1}^p K_h(x_{jt} - u_t)} \dots (4)$$

وعليه مع هذا النوع من مصفوفة النواة ومعلمة التمهيد يتم اعطاء مقدر نواة Nadaraya-Watson بواسطة

$$\hat{m}_{H,NW}(\vec{u}) = \frac{(\prod_{t=1}^p K_h(x_{jt} - u_t)) y_j}{\sum_{j=1}^{n_0} \prod_{t=1}^p K_h(x_{jt} - u_t)} \dots (5)$$

3 - الذكاء الاصطناعي : Artificial intelligence

يمكن تعريف الذكاء الاصطناعي (AI) على أنه فرع من علوم الحاسوب يجب أن يستند إلى مبادئ نظرية وتطبيقية سليمة في هذا المجال. تتضمن هذه المبادئ هياكل البيانات المستخدمة في تمثيل المعرفة ، والخوارزميات اللازمة لتطبيق تلك المعرفة ، واللغات وتقنيات البرمجة المستخدمة في تنفيذها، او يمكن تعريفه على انه علم يتناول كيفية جعل الآلة - أي الحاسوب - تؤدي عمليات مناظرة لقدرات البشر العقلية. ومع ذلك ، فإن هذا التعريف يعاني من حقيقة أن الذكاء نفسه لم يتم تعريفه أو فهمه جيداً. على الرغم من أن معظمنا على يقين من أننا نعرف السلوك الذكي عندما نراه ، فمن المشكوك فيه أن يقترب أي شخص من تحديد الذكاء بطريقة تكون محددة بما يكفي للمساعدة في تقييم برنامج كمبيوتر يُفترض أنه ذكي. وقد ظهر الذكاء الاصطناعي في الخمسينيات من القرن الماضي نتيجة الثورة التي حدثت في مجالي المعلومات والتحكم الآلي ، وترمي أبحاثه إلى تحقيق هدفين رئيسيين : الأول : الوصول إلى فهم عميق للذكاء الإنساني عن طريق محاكاته . الثاني الاستثمار الأفضل للحاسوب الآلي والعمل على استغلال إمكانياته كافة ، وخصوص بعد التطور السريع في قدرات الحاسبات ورخص اسعاره [3][9].

3-1 التنبؤ باستخدام اسلوب الشبكات العصبية :-

منهجية الشبكات العصبية الاصطناعية من الطرائق المتطورة التي لها القدرة والكفاءة العالية في الحصول على نتائج جيدة ، واستعمالاتها كثيرة . في منهجية البحث استخدمت الشبكات العصبية الاصطناعية في تحليل السلاسل الزمنية ، حيث تمتاز بمرونة تحديد نوعية وعدد المدخلات وعدد العقد المخفية وعدد المستويات المخفية الى ان نحصل او تصل الى الانموذج الامثل [6] .

وتستعمل الشبكة المدربة (net) للتنبؤ للفترة القادمة وبمدخلات جديدة .

يمكن كتابة الانموذج الرياضي العام للشبكات العصبية بالمعادلات التالية :-

$$y_1 = (w_1 * x) + b_1 \dots (6)$$

$$H = \frac{2}{(1 + \exp(-2 * y_1) - 1)} \dots (7)$$

$$y_2 = (w_2 * H) + b_2 \dots \dots \dots (8)$$

$$Y = \frac{2}{(1 + \exp(2 * y_2) - 1)} \dots (9)$$

w_1 : تمثل اوزان طبقة المدخلات

w_2 : تمثل اوزان الطبقة المخفية


b_1 و b_2 : تمثل التحيز

X, H : تمثل قيم المدخلات

Y : تمثل المخرجات


2-3 الشبكات العصبية الاصطناعية :- (ANN) Artificial Neural Networks

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة عن طريق معالجة ضخمة موزعة على التوازي ومكونة من وحدات معالجة بسيطة هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقدا (Nodes, Neurons) والتي لها خاصية عصبية من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان .



شكل رقم (1) التشابه بين خلية عصبونية واخرى بيولوجيا[1]

الشبكات العصبية الاصطناعية تتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية . وهناك أيضا تشابه عصبي حيوي مما يعطي الفرصة لعلماء البيولوجيا في الاعتماد على ANN لفهم تطور الظواهر الحيوية [1].



شكل رقم (2) يمثل مكونات الخلية العصبية الاصطناعية[5]

نلاحظ من الشكل رقم (2) ان العصبون يتألف من :-

- اشارات المدخلات (Input) $(x_1, x_2, \dots, x_n)$
- قوة الاوزان (Weights) $(w_1, w_2, \dots, w_{jn})$
- حيث يعبر الوزن عن شدة الترابط بين العناصر (عنصر قبله وعنصر بعده)
- عنصر المعالجة (processing Element)

4-3 طريقة معالجة المعلومات :-

يتميز الاتصال بين عصبون واخر بقيمة تدعى الوزن (Weighting) وهي تشكل اهمية الارتباط بين العناصر ، يقوم العصبون بضرب قيمة كل مدخل وارد من عصبونات الطبقة السابقة بأوزان الاتصالات مع هذه العصبونات ، ثم يتم جمع جميع نواتج الضرب ومن ثم تخضع النواتج لدالة تحويل وتختلف حسب نوع العصبون ويعتبر ناتج دالة التحويل خرج العصبون الذي ينقل الى عصبونات الطبقة اللاحقة [1].


5-3 تمثيل البيانات:-

البيانات التي يتم تدريب الشبكة العصبية عليها تتمثل كمتجهات، وعدد البيانات في المتجه يعتمد على نوع المشكلة المطلوب حلها وكذلك معمارية الشبكة، وقد تكون البيانات على شكل قيم منطقية (0، 1) او (1 - 1)، أو على شكل ارقام صحيحة او عشرية، وفي هذه الحالة يُفضل تحويل البيانات إلى قيم تكون قريبة من مدى دالة الفاعلية المستخدمة في الشبكة[1].

4- خوارزمية التعلم ذات الانتشار الخلفي :-

لحل هذه الطريقة أو الخوارزمية أشهر طريقة لتعليم الشبكات العصبية متعددة الطبقات، وهي من طرق التعلم التي تعتمد على الأمثلة أو الأنماط (التعليم بإشراف) حيث يتم تعريف الشبكة بأنماط المدخلات وكذلك أنماط المخرجات المطلوب اكتشف هذه الطريقة سنة 1974، ويتلخص عمل هذه الطريقة في تقليل مجموع مربعات الأخطاء للمخرجات المحسوب بواسطة الشبكة بشكل تدريجي ، ويتم ذلك بتعديل الأوزان في كل دورة من دورات التدريب. وتتم الخوارزمية في الأساس بثلاثة مراحل هي :-

- مرحلة التغذية الأمامية.
- مرحلة الانتشار الخلفي.
- مرحلة تحديث الأوزان



الشكل رقم (3) الشبكة العصبية ذات الانتشار العكسي [2]

رياضيا ، لنفترض أن الوحدات j هي وحدات المخرجات، وأن الوحدات i هي الوحدات في الطبقة التي تسبقها، يتم حساب المخرجات بخطوتين أو صيغتين هما [7]:-

$$1) x_j = \sum_i y_i w_{ij} \dots \dots \dots (10)$$

$$2) y_i = \frac{1}{1+e^{-x_j}} \dots \dots \dots (11)$$

x_j :- يمثل مجموع المخرجات في معادلة رقم (10)

y_i :- حيث i يمثل الوحدة النشطة في الطبقة السابقة

w_{ij} :- الوزن بين وحدتين i و j (وزن الوصلة)

تقوم الوحدة y_i بحساب المخرجات باستخدام دالة تسمى دالة السيكمويد وبمجرد حساب مخرجات جميع الوحدات، تحسب شبكة الخطأ بواسطة الصيغة التالية :-

$$3) E = \frac{1}{2} \sum_j (y_j - d_j)^2 \dots \dots \dots (12)$$

اذ ان..

y_j :- تمثل مخرجات الوحدة في الطبقة i باستخدام معادلة 10, 11

d_j :- تمثل المخرجات المطلوب من الشبكة تعلمه

خوارزمية الانتشار الخلفي يمكن تمثيلها رياضياً وكالتالي :-

$$4) EA = \frac{\partial E}{\partial y_j} = y_j - d_j \dots \dots \dots (13)$$

$$5) EI_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \frac{dy_j}{dx_j} = EA_j y_j (1 - y_j) \quad \dots (14)$$

$$6) EW_{ij} = \frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial w_{ij}} = EI_i y_i \quad \dots (15)$$

$$(7) EA_i = \frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial y_i} = \sum_j EI_j w_{ij} \quad \dots (16)$$

ويمكننا شرح الصيغ وكالتالي :-

اولا:- حساب متوسط تغير الخطأ EA من الصيغة رقم (13) والذي يمثل حاصل طرح بين المخرجات الفعلية للشبكة من الصيغة رقم (11) والمخرجات المطلوبة .

ثانيا:- حساب متوسط تغير الخطأ EI من الصيغة رقم (14) في مجموع المدخلات المستقبلية من قبل وحدة المخرجات في (10) والذي هو حاصل ضرب الناتج من الصيغة رقم (13) في مشتقة مخرجات الوحدة، وهي مشتقة المعادلة رقم (11).

ثالثا:- حساب سرعة تغير الخطأ عند تغير الأوزان على الوصلات المتصلة بوحدات الإخراج وذلك بضرب الناتج من (14) في مستوى نشاط الوحدة التي يخرج منها الاتصال في الصيغة (11) .

رابعا:- حساب معدل تغير الخطأ اعتمادا على تغيير نشاط الوحدة في الطبقة السابقة . وهذه العملية الحاسمة ، الصيغة (16) تسمح بتطبيق الانتشار الخلفي على الشبكات متعددة الطبقات .

خامسا :- وباستخدام الخطوتين 11 و 13 يمكن تطبيق هذا الأجراء على باقي الطبقات في الشبكة العصبية .

الجاب التجريبي:-

بما اننا سنستخدم المحاكاة المقيدة لذا سوف نعلم المعلومات المسبقة (الاصلية) عن طريق معادلة التوليد المقيدة لكل نوع من انواع البيانات اذ تم الاعتماد على اقل واعلى قيمة لها ، وان البيانات هي عن استهلاك المشتقات النفطية في محافظة واسط ولثلاث منتجات وهي (البازين والنفط وزيت الغاز) لذا سوف يكون لدينا ثلاث نماذج في التوليد كل نموذج يمثل منتج وكما يلي:

- الأنموذج الاول يمثل منتج البنزين
 - الأنموذج الثاني يمثل منتج النفط
 - الأنموذج الثالث يمثل منتج زيت الغاز
- اذ ان: القيم التالية تمثل الحد الادنى والاعلى للبيانات .

الحد الاعلى	الحد الادنى	
30518000	4763000	الأنموذج الاول
31935000	298000	الأنموذج الثاني
58129170	10387500	الأنموذج الثالث

اما حجوم العينات فتم اختيار الحجوم (15 و 30 و 60 و 100)

والنتائج كما يلي:

1- نتائج الأنموذج الاول:

جدول (1-1) يبين نتائج المقارنة في الأنموذج الاول

		MSE	RMSE	MAE	MAPE
15	Neural Network	0.000000854	0.00092422	0.0018	0.8038
	Kernel	15.07400	3.8825	10.025	0.7179
	Best	Neural Network	Neural Network	Neural Network	Kernel
30	Neural Network	0.000000899	0.00094844	0.0022	1.2386
	Kernel	6.9902	2.6439	4.8271	0.0358
	Best	Neural Network	Neural Network	Neural Network	Kernel
60	Neural Network	0.000000898	0.00094784	0.0021	1.0505
	Kernel	5.77502	2.4031	2.7014	1.5000
	Best	Neural Network	Neural Network	Neural Network	Neural Network
100	Neural Network	0.000000892	0.00094446	0.0020	0.6499
	Kernel	2.3886	1.5455	1.4241	1.3544
	Best	Neural Network	Neural Network	Neural Network	Neural Network

من خلال نتائج الجدول (1-1) والخاص بالأنموذج الاول نلاحظ بان الشبكات العصبية هي الافضل في جميع حجوم العينات وكذلك في اغلب المقاييس.

2- نتائج الأنموذج الثاني:

جدول (1-2) يبين نتائج المقارنة في الأنموذج الثاني

		MSE	RMSE	MAE	MAPE
15	Neural Network	0.000000899	0.0009484	0.00232	0.9652
	Kernel	8.5817	9.2637	2.8438	60.00
	Best	Neural Network	Neural Network	Neural Network	Neural Network
30	Neural Network	0.000000896	0.0009469	0.00231	0.5468
	Kernel	3.9819	1.9955	1.5145	30.00
	Best	Neural Network	Neural Network	Neural Network	Neural Network
60	Neural Network	0.000000895	0.0009463	0.00230	0.1908
	Kernel	2.6534	1.6289	1.5022	15.00
	Best	Neural Network	Neural Network	Neural Network	Neural Network
100	Neural Network	0.000000663	0.0008145	0.00150	0.1345
	Kernel	1.2207	1.1049	5.2214	9.00
	Best	Neural Network	Neural Network	Neural Network	Neural Network

من خلال نتائج الجدول (1-2) والخاص بالأنموذج الثاني نلاحظ بان الشبكات العصبية هي الافضل في جميع حجوم العينات وكذلك في جميع المقاييس.

3- نتائج الأنموذج الثالث:

جدول (1-3) يبين نتائج المقارنة في الأنموذج الثالث

		MSE	RMSE	MAE	MAPE
15	Neural Network	0.000000887	0.0009418	0.002430	0.4780
	Kernel	5.1780	2.2755	2.2790	6.0000
	Best	Neural Network	Neural Network	Neural Network	Neural Network
30	Neural Network	0.000000885	0.0009408	0.002331	0.4761
	Kernel	4.0894	2.0222	1.0865	3.0010
	Best	Neural Network	Neural Network	Neural Network	Neural Network
60	Neural Network	0.000000877	0.0009369	0.002200	0.4302
	Kernel	3.4990	1.8706	0.7842	1.5000
	Best	Neural Network	Neural Network	Neural Network	Neural Network
100	Neural Network	0.0000000281	0.0001676	0.00000828	0.0016
	Kernel	3.3860	1.8401	0.1627	0.9000
	Best	Neural Network	Neural Network	Neural Network	Neural Network

من خلال نتائج الجدول (1-3) والخاص بالأنموذج الثالث نلاحظ بان الشبكات العصبية هي الافضل في جميع حجوم العينات وكذلك في جميع المقاييس.

الاستنتاجات:-

✓ لوحظ من خلال النتائج ان طريقة الشبكات العصبية تفوقت على طريقة Kernel في جانب المحاكاة.

التوصيات:-

✓ مقارنة كفاءة الشبكات العصبية مع طرائق اخرى مثل طريقة الانحدار الخطي الموضعي و K بالقرب من الجار.

✓ مقارنة الطرائق الالعلمية للتنبؤ بالسلاسل الزمنية مع طرائق Box-jenkins

المراجع:-

- (1) احمد، جحا و المسلاتي، عبد الله. 2019، استخدام الشبكات العصبية للتنبؤ بالسلاسل الزمنية باستخدام طريقة التدريب ذات الانتشار الخلفي " كلية التقنية الصناعية، مصراته، ليبيا .
- (2) حازم، عزة. 2005، استخدام الشبكات العصبية في التكهّن للسلاسل الزمنية بتطبيق على استهلاك الطاقة الكهربائية في محافظة نينوى ، رسالة ماجستير ، كلية علوم والحاسبات والرياضيات، جامعة الموصل.

- (3) الشوافي، جمال احمد، السيد حجاج، عبد الوهاب 2013، الذكاء الاصطناعي مفهومًا وتطبيقًا، المجلة العلمية لقطاع كليات التجارة، جامعة الازهر، العدد العاشر .
- (4) شيخي ، محمد . 2011 ، طرق القياس الاقتصادي محاضرات وتطبيقات ، استاذ وباحث في جامعة ورقلة ، الجزائر، الطبعة الاولى ،الحامد.
- (5) صليوا. رهاد، والبدراي، ظافر، 2014، تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستخدام الشبكات العصبية، المجلة العراقية للعلوم الاحصائية ص 1-19.
- (6) عبد الحميد، مروان، 2019 "الشبكات العصبية الاصطناعية وطرائق تنبؤ السلاسل الزمنية"، دار الكتب والوثائق، بغداد.

- 7) Hinton, Geoffrey. (1992). How Neural Networks Learn From Experience. Scientific American. 267. 144-51.
- 8) Hong, Yongmiao,(2020),"Introduction to Nonparametric Analysis in Time Series Econometrics " Chapter 6 of a manuscript entitled as Modern Time Series Analysis: Theory and Applications.
- 9) Luger, George (2009)" Artificial intelligence : structures and strategies for complex problem solving" University of New Mexico 6th ed.
- 10) Vilar, Juan & Cao, Ricardo. (2007)". Nonparametric Forecasting in Time Series - A Comparative Study". Communications in Statistics: Simulation and Computation. 36. 10.1080/03610910601158377.

Comparison of Some Nonparametric Methods Using Simulations

Bassam Hashem Dakhil
The University of Mustansiriyah
Collage of Administration & Economics
Department of Statistics

Prof. Dr. Ali Yassin Ghani
The University of Mustansiriyah
Collage of Administration & Economics
Department of Statistics

ABSTRACT

There was a need to compare the nonparametric methods used in predicting time series to find the most efficient method for forecasting, and this was in fact the main objective of this study. The research problem was summed up that parametric statistical methods need conditions and criteria that may be difficult to meet, so it was necessary to search for new methods of prediction other than the traditional methods, which are non-parametric methods. The comparison was through the application of the simulation method, where the data was generated by the restricted generation equation based on the original data, with the lowest value and the highest value for each type of data. The focus of the study is a comparison between the two methods of neural networks (the back propagation error network) and the kernel method (Nadaraya-Watson estimator). As for the sample sizes, the sizes (15, 30, 60 and 100) were selected. As for the criteria that were used for comparison, they were (MSE, RMSE, MAE, MAPE). The results showed, through simulation, that the neural networks give better and more efficient results than the Kernel method in most of the scales and for all sample sizes.

Keyword: , time series, nonparametric regression, Nadaraya-Watson estimator, artificial intelligence, artificial neural networks, back-error propagation.