

تطبيقات خوارزمية Boosting في التنبؤ لمعالجة البيانات التسلسلية باستخدام الشبكات العصبونية التكرارية

الدكتور محمد حسن*
الدكتور محمد أسعد**
فريال اسماعيل***

(تاريخ الإيداع 10 / 1 / 2011. قُبل للنشر في 2 / 5 / 2011)

□ ملخص □

لقد أظهرت طرائق تجميع النماذج في مجال التصنيف (Classification) والتقدير أو التتالي (Regression) تفوقها على الطرائق الأخرى نظرياً وعملياً. والـ Boosting هي إحدى هذه الطرائق التي أثبتت فعاليتها و مقدرتها على تحسين نتائج أي خوارزمية تعليمية. لقد قمنا في هذا البحث باستخدام الخوارزمية Boosting مع الشبكات العصبونية الصناعية التكرارية وذلك في مجال تنبؤ السلاسل الزمنية بخطوة زمنية واحدة بالاعتماد على مجموعة اختبار كل سلسلة زمنية. هذه السلاسل معروفة بتطبيقاتها الواسعة في مجالات عديدة. ثم قورنت النتائج التي تم الحصول عليها باستخدام الخوارزمية المطروحة بأفضل النتائج التي تم الحصول عليها باستخدام خوارزميات أخرى. وأظهرت هذه النتائج مقدرتها الشبكات العصبونية الصناعية على تنبؤ السلاسل الزمنية و أن تجميع نتائج عدة شبكات باستخدام Boosting يعطي نتائج أكثر استقراراً من النتائج التي نحصل عليها باستخدام شبكة عصبونية واحدة.

* أستاذ - قسم الرياضيات - كلية العلوم - جامعة تشرين - اللاذقية - سورية.
** مدرس - قسم الرياضيات - كلية العلوم - جامعة تشرين - اللاذقية - سورية.
*** طالبة ماجستير - قسم الرياضيات - كلية العلوم - جامعة تشرين - اللاذقية - سورية.

The Applications of Boosting Algorithm in the Prediction for Sequential Data Using Recurrent Neural Networks

Dr. Mohammad Hasan^{*}
Dr. Mohammad Assaad^{**}
Frial Esmaeel^{***}

(Received 10 / 1 / 2011. Accepted 2 / 5 / 2011)

□ ABSTRACT □

Ensemble methods used for classification and regression have shown that they are superior than other methods, theoretically and empirically. Boosting is one of these methods which is a powerful tool for improving the performance of any learning algorithm. In this research, we have used Boosting algorithm with Recurrent Neural Networks in Regression context to predict time series on single-step ahead depending on each test set of time series. These series are known by its wide applications in many fields. Then, the final results by using Boosting algorithm have been compared with the best obtained results by using other algorithms. These results have also shown the ability of Artificial Neural Networks (ANNs) in predicting time series. Also combination results of many ANNs by using Boosting algorithm give more stability than results that obtained by using single neural network.

Keywords: Boosting Algorithm, Recurrent Neural Networks, Time Series Prediction.

^{*} Professor, Department of Mathematics, Faculty of Sciences, University of Tishreen, Lattakia, Syria.

^{**} Assistant Professor, Department of Mathematics, Faculty of Sciences, University of Tishreen, Lattakia, Syria.

^{***} Postgraduate Student, Department of Mathematics, Faculty of Sciences, University of Tishreen, Lattakia, Syria.

مقدمة:

التنبؤ بالقيم المستقبلية للسلاسل الزمنية له العديد من التطبيقات الهامة في مجالات كثيرة كالطب، المال، الهندسة، السوق، الطقس، الإحصاء، وغيرها. أحد هذه التطبيقات هو منع وقوع حدث غير مرغوب في حدوثه، وذلك من خلال التنبؤ به قبل وقوعه (كالتنبؤ بمنتج نريد بيعه في الأسواق) وفي تطبيق آخر التنبؤ بحدث غير مرغوب فيه ومن المستحيل تجنبه، ولكن يمكن تقليل تأثيره (كالعواصف). إن تشكيل السلسلة الزمنية يكون عادةً الخطوة الأولى للتنبؤ الذي سيزود تخميناً للقيم المستقبلية بالاعتماد على القيم الماضية للسلسلة الزمنية. التنبؤ الأكثر شيوعاً هو تنبؤ القيم المستقبلية بخطوة زمنية واحدة $\hat{x}(t+1)$ والذي يعطى بالشكل:

$$\hat{x}(t+1) = f(\hat{x}(t), x(t-1), x(t-2), \dots) \quad (1)$$

حيث $f: R^n \rightarrow R$ يستخدم القيمة الحالية $\hat{x}(t) = f(x(t-1), x(t-2), \dots)$ للسلسلة الزمنية كدخل. و $x(t)_{t=t_1, \dots, t_l}$ هي بيانات السلسلة الزمنية من أجل $0 \leq t \leq l$.

لقد أظهرت الشبكات العصبونية الصناعية (ANNs) نجاحاً كبيراً في مجال تنبؤ السلاسل الزمنية [1]، ومن هنا جاءت الحاجة إلى استخدامها في بحثنا والاعتماد على الشبكات العصبونية الصناعية التكرارية بشكل خاص نظراً لمرونتها و موثوقيتها في تنبؤ السلاسل الزمنية.

أهمية البحث وأهدافه:

الهدف من البحث هو استخدام خوارزمية تدعى Boosting [2] وتطبيقها في مجال تنبؤ السلاسل الزمنية. هذه الخوارزمية التي أثبتت فعاليتها في حل مشاكل من هذا النوع. وتم أيضاً استخدام الشبكات العصبونية الصناعية التي تعتبر تطبيقاً هاماً من تطبيقات الذكاء الصناعي مع هذه الخوارزمية. وتكمن أهمية هذا البحث في كونه يفتح المجال واسعاً أمام استخدام تقنيات الذكاء الصناعي وتطويرها.

طرائق البحث ومواده:

قمنا في هذا البحث باستخدام برنامج محاكاة يدعى Yanns متخصص باستخدام الشبكات العصبونية الصناعية و خوارزميات تدريبها، وقد تم إضافة خوارزمية Boosting المبرمجة بلغة ++C ضمن هذا البرنامج، و قمنا بإنشاء برنامج خاص بالشبكة العصبونية الصناعية يحدد فيه بنية الشبكة العصبونية المستخدمة (ذات تغذية أمامية - تكرارية - أو غيرها) وعدد العصبونات الصناعية المستخدمة في كل طبقة و طريقة الربط بين هذه العصبونات، وما هي خوارزمية التعليم المستخدمة على هذه الشبكة، وتم ربطه مع ملفات تحوي بيانات السلاسل الزمنية المستخدمة.

النتائج و المناقشة:

- الشبكات العصبونية التكرارية (RNNs) :Recurrent Neural Networks

الشبكات العصبونية التكرارية RNNs هي تراكيب حسابية مرنة وسهلة وقابلة للتطبيق على طيف واسع من المشاكل، يتميز هذا النوع من الشبكات بوجود اتصالات تغذية راجعة. الأمر الذي يجعلها أكثر مرونة في مجال تنبؤ السلاسل الزمنية، متفوقة بذلك على الشبكات العصبونية ذات التغذية الأمامية.

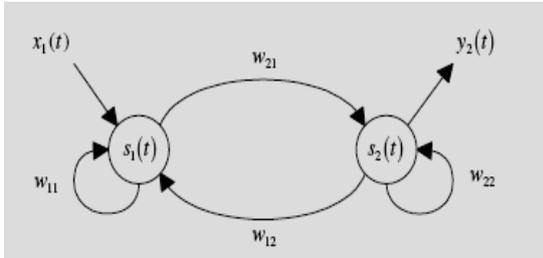
- تدريب الشبكات العصبونية التكرارية:

تدرب الشبكات العصبونية التكرارية في معظم الحالات باستخدام خوارزمية الانتشار الخلفي خلال الزمن Back Propagation Through Time (BPTT) التي هي امتداد لخوارزمية الانتشار الخلفي القياسية Back Propagation (BP). تكمن الفكرة الأساسية لخوارزمية BPTT في تحويل الشبكة العصبونية التكرارية إلى شبكة عصبونية متعددة الطبقات ذات تغذية أمامية مكونة من L طبقة الشكل (1)، حيث يقابل كل خطوة زمنية في الشبكة العصبونية التكرارية طبقة إضافية في الشبكة العصبونية أمامية التغذية (عدد الطبقات يساوي عدد الخطوات الزمنية). في نهاية الإجراء تطبق خوارزمية BP على الشبكة المولدة [3] لتوضيح عمل خوارزمية BPTT في تدريب الشبكات العصبونية التكرارية بين اللحظتين t_1 و t_2 . نفرض f_i هو تابع التفعيل للعصبون i و $s_i(t)$ خرج هذا العصبون في اللحظة t ، w_{ij} هو الوصلة القادمة من العصبون j ، حيث إن جميع النسخ لكل وزن w_{ij} في الشبكة المولدة المكافئة يجب أن يبقى نفسه. $x_i(t)$ هي القيمة التي يزود بها العصبون من الخارج. يعطى $s_i(t)$ وفق الخوارزمية بالعلاقة:

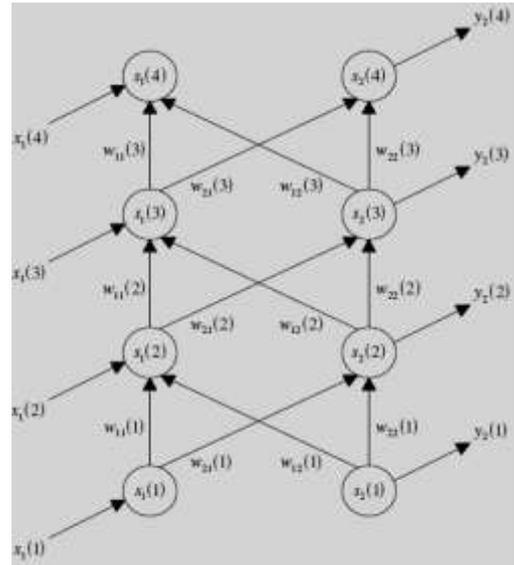
$$s_i(t) = f_i(\text{net}_i(t-1) + x_i(t)) \quad i = 1, \dots, N \quad (2)$$

$$\text{net}_i(t-1) = \sum_{j \in \text{pred}(i)} w_{ij}(t-1) s_j(t-1) \quad (3)$$

حيث: $\text{net}_i(t-1)$ هو دخل العصبون i في اللحظة الزمنية $t-1$.



شبكة عصبونية تكرارية



شبكة عصبونية أمامية التغذية مكافئة

الشكل (1) تحويل الشبكة العصبونية التكرارية إلى شبكة متعددة الطبقات ذات تغذية أمامية مكافئة

يعطى الخطأ الكلي بين اللحظتين الزمنيتين بالعلاقة الآتية:

$$E(t_1, t_l) = \frac{1}{2} \sum_{t=t_1}^{t_l} \sum_{i \in A} (d_i(t) - s_i(t))^2 \quad (4)$$

حيث A هي مجموعة العصبونات التي تملك خرجاً مرغوباً في اللحظة الزمنية t .

$$\delta_i(t) = - \frac{\partial E(t_1, t_l)}{\partial net_i} \quad \forall i \in A \quad \text{و} \quad t_1 < t < t_l \quad (5)$$

ومنه نحصل على معادلات خوارزمية BPTT بالاعتماد على معادلات خوارزمية BP بالشكل الآتي:

$$\delta_i(t) = \begin{cases} f'(net_i(t))(s_i(t) - d_i(t)) & : t = t_l \\ f'(net_i(t))[(s_i(t) - d_i(t)) + \sum_{k \in A} w_{ik} \delta_k(t+1)] & : t_1 < t < t_l \end{cases} \quad (6)$$

عندما تنجز الحسابات في معادلة BP تعدل الأوزان كالتالي:

$$\Delta w_{ij} = -\eta \frac{\partial E(t_1, t_l)}{\partial w_{ij}} = \eta \sum_{t=t_1+1}^{t_l} \delta_i(t) s_j(t-1) \quad (7)$$

مع العلم أن $\eta \in [0,1]$ هو معدل التعلم المستخدم في معادلة تغيير الأوزان

خوارزمية Boosting (Boosting Algorithm):

هي طريقة فعالة لتحسين نتائج الخوارزميات التعليمية وذلك للحصول على قيمة خطأ أصغر في مشكلة

التنبؤ (مشاكل التتالي) ومعدلات خطأ أخفض في (مشاكل التصنيف)، وتعتمد هذه الخوارزمية على:

1. تقسيم مجموعة المعطيات الأصلية D إلى عدد من المجموعات الجزئية، كل مجموعة جزئية مثل D_2 تنتج

عن المجموعة الجزئية التي تسبقها مثل D_1 وذلك عن طريق اختيار الأمثلة المصنفة بشكل سيئ (الأمثلة التي تملك

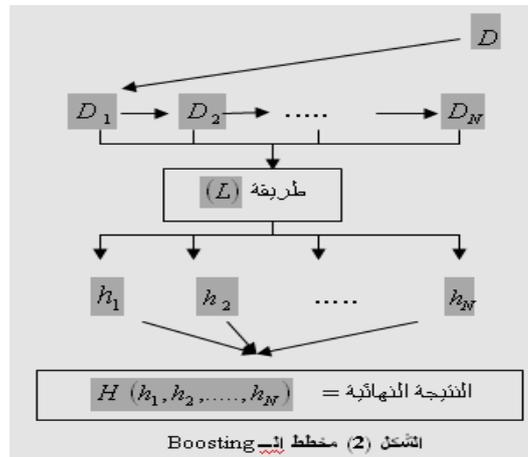
الخطأ الأكبر). ومن ثم تدريب المجموعة D_2 بإحدى خوارزميات التعليم (L) مثل (BPTT أو ال BP أو غيرها)

للحصول على نتيجة (h_2) وتكرر هذه العملية N مرة. وبالتالي يتم في نهاية المرحلة الأولى الحصول على مجموعة

النتائج $\{h_i : i = 1, \dots, N\}$ المقابلة للمجموعات الجزئية $\{D_i : i = 1, \dots, N\}$.

2. تجميع المخرجات h_i الناتجة عن تدريب المجموعات الجزئية D_i بحسب المشكلة المطروحة كما يوضحه

الشكل (2):



وبما أن دراستنا تتعلق باستخدام هذه الخوارزمية في مجال التتالي لذلك سنقوم بشرح خطوات هذه الخوارزمية بشكل مفصل.

- خوارزمية الـ Boosting في مشاكل التتالي:

إن نجاح تطبيق خوارزمية الـ Boosting في الحصول على نتائج دقيقة في مشاكل التصنيف قاد إلى تطبيقها في مشاكل التتالي ولكن بشكل أقل، إذ قام Drucker [2] بتعديل خوارزمية AdaBoost.R التي اقترحتها Freund and Schapire [4] لحل مشاكل التتالي، وزود الخوارزمية بثلاثة توابع كلفة (خطية، أسية، تربيعية) وأخيراً استخدم الوسيط الموزون (Weighted median) لتجميع النتائج. يمكن تلخيص هذه الخوارزمية بالنقاط الآتية [5]:

1. المدخلات

- أمثلة التدريب $(x_1, y_1), (x_2, y_2), \dots, (x_q, y_q)$ من مجموعة التدريب D حيث الخرج $y_q \in R$ و x_q مدخلة من الفضاء X ، $q: 1, \dots, Q$ عدد أمثلة التدريب.

- خوارزمية تعليم.

- عدد صحيح N يحدد عدد الدورات.

2. التمهيد (إعطاء القيم الابتدائية)

- نضع $N=1$ (الدورة).

- إعطاء $D_n(q)=1/Q$ كافة الأمثلة أوزاناً متساوية.

- إعطاء تابع الخطأ القيمة صفر $\varepsilon_n = 0$.

3. التكرار طالما $\varepsilon_n < 0.5$ أو $n \leq N$

- استدعاء خوارزمية التعليم وتزويدها بمجموعة التدريب D_n

- إنشاء نموذج تتالي $h_n(x) \rightarrow Y$

- حساب تابع الكلفة لكل مثال تدريب كالتالي $L_n(q) = |y_q^{(n)}(x_q) - y_q|$

- حساب تابع الكلفة $L_n(q)$ لكل مثال تدريب وفقاً لتوابع الكلفة الآتية التي تعطي قيماً ضمن المجال $[0,1]$

$$L_n(q) = \frac{|y_q^{(n)}(x_q) - y_q|}{S_n} \quad \text{1- تابع الكلفة الخطي:}$$

$$L_n(q) = \frac{|y_q^{(n)}(x_q) - y_q|^2}{S_n^2} \quad \text{2- تابع الكلفة التربيعي:}$$

$$L_n(q) = 1 - \exp\left[-\frac{|y_q^{(n)}(x_q) - y_q|}{S_n}\right] \quad \text{3- تابع الكلفة الأسي:}$$

حيث $q = 1, 2, \dots, Q$ و $S_n = \max |y_q^{(n)}(x_q) - y_q|$

- حساب الخطأ كالتالي $\varepsilon_n = \sum_{q=1}^Q L_n(q) D_n(q)$ حيث $D_n(q)$ وزن المثال q خلال الدورة n

- إيجاد درجة الثقة للشبكة بالعلاقة $\alpha_n = (1 - \varepsilon_n) / \varepsilon_n$

- تعديل قيم الأوزان D_n بحسب العلاقة $D_{n+1}(q) = \frac{D_n(q) \alpha_n^{(1-L_n(q))}}{Z_n}$

حيث Z_n هو عامل معايرة (Normalized constant) يمثل مجموع الأوزان

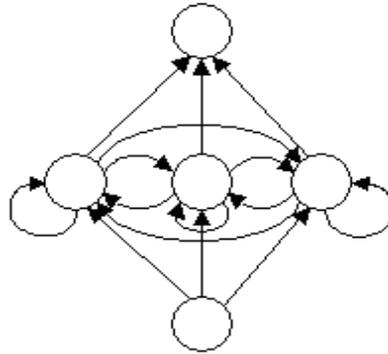
- زيادة عدد الدورات n بمقدار واحد أي $n = n + 1$

4. النتيجة النهائية التي تمثل تجميع النتائج الـ N شبكة باستخدام علاقة الوسيط الموزون:

$$h_f = \inf \left\{ y \in Y : \sum_{n:h_n \leq y} \log \alpha_n \geq \frac{1}{2} \sum_n \log \alpha_n \right\}$$

- تنبؤ السلاسل الزمنية (Time Series Prediction)

استخدمت الشبكات العصبونية بشكل واسع في تنبؤ السلاسل الزمنية. وفي مجالات عديدة منها الاقتصاد (تنبؤ أسهم الأوراق المالية)، الطب (التنبؤ بحدوث مرض ما)، الإحصاء (التنبؤ بعدد الولادات الشهرية)، الظواهر الطبيعية (الطقس - البقع الشمسية) وغيرها. تستخدم الشبكة العصبونية القيم السابقة للسلسلة الزمنية ليتم التنبؤ بالقيم المستقبلية، إذ أنّ البيانات السابقة هي مدخلات للشبكة المستخدمة ومخرجات هذه الشبكة هي البيانات المستقبلية (القيم المستقبلية المتنبأ بها). ومن أجل تدريب الشبكة العصبونية يتم تقسيم بيانات السلسلة الزمنية إلى مجموعتين: 1- مجموعة التدريب (Learning Set)، 2- مجموعة الاختبار (Test Set). إذ تدرب الشبكة بشكل مباشر بالخوارزمية BP مثلاً على مجموعة التدريب وتقاس مقدرتها على التنبؤ على مجموعة الاختبار. وتم اختبار خوارزمية Boosting في عملنا على عدد من السلاسل الزمنية المختلفة بنوعها (سلاسل طبيعية و سلاسل صناعية) هذه السلاسل معروفة و مستخدمة في مجالات تطبيقية مختلفة، كسلسلة البقع الشمسية (Sunspots)، وسلاسل (Mackey-Glass) وسلسلة (Hénon) والسلسلة الليزرية (Laser). وكخطوة من خطوات هذه الخوارزمية تم استخدام شبكة عصبونية تكرارية الشكل (3) مؤلفة من ثلاث طبقات: طبقة الدخل مؤلفة من عصبون واحد، طبقة الخرج مؤلفة من عصبون واحد، طبقة مخفية تكرارية بشكل كامل ومؤلفة من عدد من العصبونات وفقاً للسلسلة الزمنية المستخدمة، وعصبون انحياز متصل مع جميع العصبونات باستثناء عصبون الدخل. وقد تم حساب متوسط مربع الخطأ المعياري (NMSE) Normalized Mean Square Error لكل سلسلة من السلاسل السابقة باستخدام الوسيط الموزون (Weighted Median). و تم اختبار جميع السلاسل الزمنية المدروسة من أجل التنبؤ بخطوة زمنية واحدة.

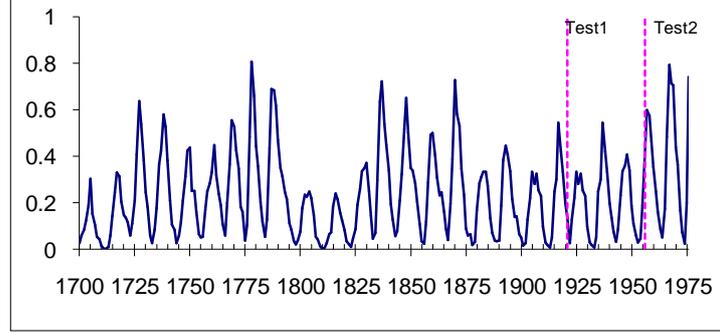


الشكل (3) شبكة عصبونية تكرارية بثلاث طبقات

سلسلة البقع الشمسية

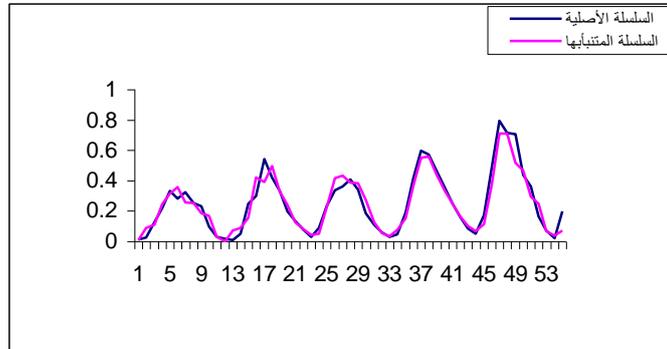
هي سلسلة طبيعية تمثل البقع المظلمة المرتبطة بنشاط الحقل المغناطيسي للشمس من عام 1700 وحتى عام 1979 إذ يلاحظ ظهور هذه البقع بشكل كبير كل 10 أو 11 سنة. تقسم بيانات هذه السلسلة [6] إلى مجموعتين الشكل (4):

- 1- مجموعة التدريب: تحتوي على القيم المحصورة بين عامي 1700 و 1920.
 - 2- مجموعة الاختبار: تحتوي على القيم المحصورة بين العامين 1921 و 1979.
- و تجزأ مجموعة الاختبار إلى مجموعتين:
- من عام 1921-1955 (مجموعة اختبار أولى Test1).
 - 1956-1979 (مجموعة اختبار ثانية Test2) و تعد أكثر صعوبة في التنبؤ من المجموعة Test1.



الشكل (4) السلسلة الزمنية Sunspots (مجموعة التدريب & مجموعة الإختبار)

وقد تم اختبار الخوارزمية Boosting على مجموعة الاختبار الأولى باستخدام شبكة عصبونية مؤلفة من ثلاث طبقات (طبقة دخل مؤلفة من عصبون واحد و طبقة خرج مؤلفة من عصبون واحد و طبقة مخفية واحدة تحوي 12 عصبوناً يتصل بعضها ببعض بشكل تكراري).



الشكل (5) مقارنة السلسلة التي تنبأت بها الشبكة العصبونية المستخدمة مع Boosting

مع القيم الأصلية على Test1 لسلسلة البقع الشمسية

وبوضح الشكل (5) مدى قدرة الخوارزمية Boosting على إعطاء نتائج دقيقة ومستقرة في معظم النقاط على المجموعة Test1 لسلسلة البقع الشمسية. كما تمت مقارنة نتائجنا مع أفضل النتائج التي تم الحصول عليها باستخدام خوارزميات أخرى جدول (1).

جدول (1) مقارنة نتائج الخوارزمية Boosting المطروحة مع نتائج خوارزميات أخرى

Sunspots	الخوارزمية المستخدمة	أفضل نتيجة
	Boosting	0.046

	Boosting(المعدلة)[3]	0.080
	BPTT[7]	0.084

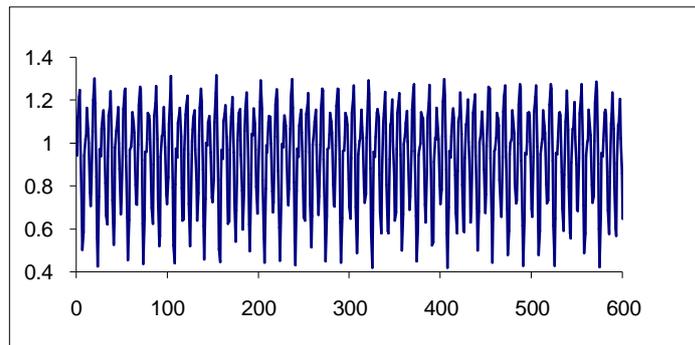
يبين الجدول (1) أن الخوارزمية المستخدمة في هذا البحث تعطي نتائج أكثر دقة من النتائج التي تم الحصول عليها باستخدام خوارزمتي Boosting المعدلة و BPTT على الترتيب.

سلاسل Mackey-Glass

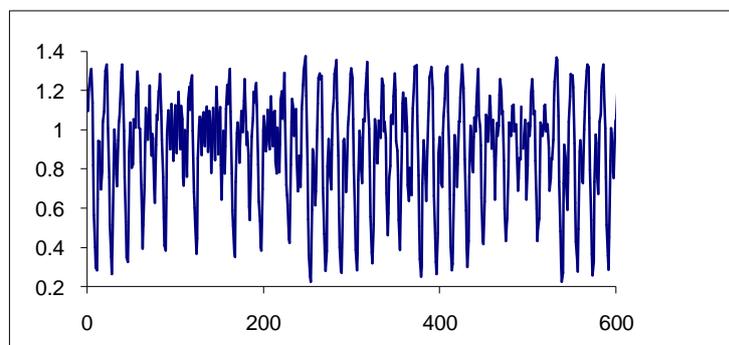
هي عبارة عن سلاسل صناعية Mackey&Glass [8] وهي سلاسل أساسية من أجل تقدير قيم التنبؤات في مجالات متعددة و بشكل أساسي الأنظمة التي تعتمد على الشبكات العصبونية الصناعية. و تولد هذه السلسلة باستخدام المعادلة:

$$\frac{dx}{dt} = -0.1 \cdot x(t) + \frac{0.2 \cdot x(t-\theta)}{1 + x^{10}(t-\theta)}$$

حيث يأخذ المتغير θ القيمتين 17 و 30 و تسمى السلاسل الموافقة لها MG17، MG30 على الترتيب. ويتم بناء المعطيات في هذه السلسلة غالباً مع شروط ابتدائية $x(t) = 0.9$ من أجل $0 \leq t \leq \theta$. تحتوي هذه السلسلة بشكل عام من 600 قيمة. أول 500 قيمة تستخدم من أجل التدريب و الـ 100 قيمة التالية تستخدم من أجل الاختبار. التجارب التي أجريت على MG17 الشكل (6) و MG30 الشكل (7) قد نفذت باستخدام شبكة عصبونية مؤلفة من ثلاث طبقات (طبقة دخل مؤلفة من عصبون واحد وطبقة خرج مؤلفة من عصبون واحد وطبقة مخفية مؤلفة من سبعة عصبونات تكرارية بشكل كامل).

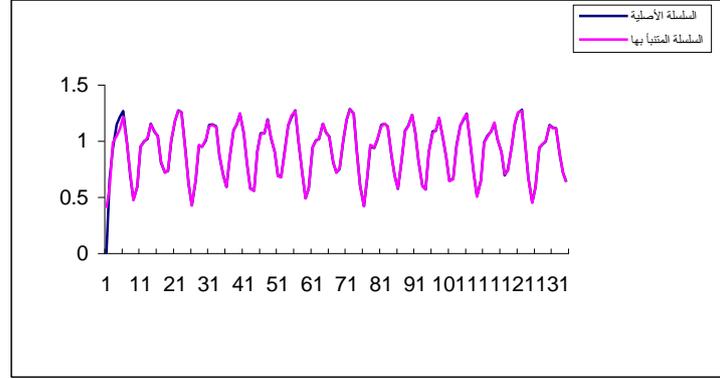


شكل (6) سلسلة Mackey-Glass من أجل $\theta = 17$



شكل (7) سلسلة Mackey-Glass من أجل $\theta = 30$

ويوضح الشكل (9)، مقارنة السلسلة المتنبأ بها من قبل الشبكة العصبونية المستخدمة مع Boosting بالقيم الأصلية لسلسلة MG17، إذ يبين أن قيمة الخطأ صغيرة جداً.



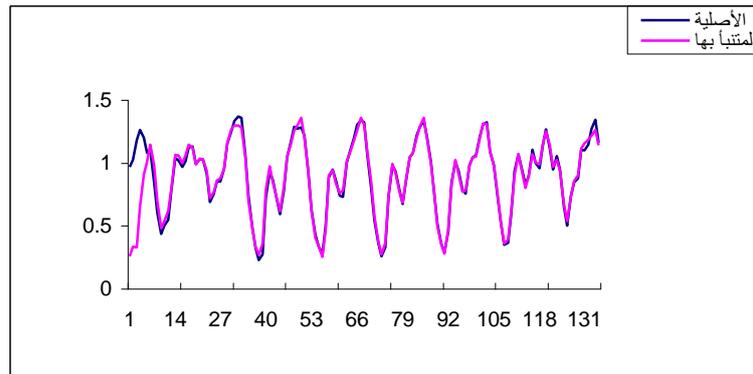
الشكل (9) مقارنة نتائج الشبكة العصبونية المستخدمة مع Boosting بالقيم في مجموعة الاختبار لسلسلة MG17

وتمت مقارنة نتائجنا بالنتائج التي تم الحصول عليها باستخدام خوارزميات أخرى وذلك مع السلسلة MG17 كما هو موضح في الجدول (2)

جدول (2) يوضح مقارنة نتائج الخوارزمية المطروحة بنتائج خوارزميات أخرى

MG17	الخوارزمية المستخدمة	أفضل نتيجة
	Boosting	0.000052
	Boosting(المعدلة)[3]	0.00016
	BPTT[7]	0.00099

يبين الجدول (2) أن استخدام الخوارزمية Boosting قدم تحسين واضح في النتائج كما نرى بالمقارنة مع الخوارزمية BPTT في الجدول السابق. وبالطريقة نفسها تمت المقارنة مع السلسلة MG30 الشكل (10).



الشكل (10) مقارنة نتائج الشبكة العصبونية المستخدمة مع Boosting بالقيم في مجموعة الاختبار لسلسلة MG30

تمت مقارنة نتائجنا التي حصلنا عليها باستخدام خوارزمية Boosting بالنتائج التي تم الحصول عليها باستخدام خوارزميات أخرى وذلك مع السلسلة MG30 جدول (3)

جدول (3) يوضح مقارنة نتائج الخوارزمية المطروحة مع نتائج خوارزميات أخرى

MG30	الخوارزمية المستخدمة	أفضل نتيجة
	Boosting	0.00074
	Boosting(المعدلة)[3]	0.00045
	BPTT[7]	0.013

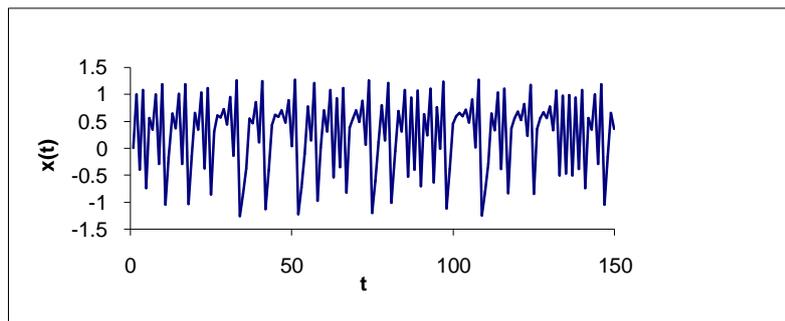
يبين الجدول (3) أن أفضل النتائج التي تم الحصول عليها هو باستخدام خوارزمية Boosting المعدلة و خوارزمية Boosting المستخدمة في بحثنا مقارنة بالـ BPTT وذلك مع سلسلة MG30. وهذا ما يؤكد بأن خوارزمية Boosting تعطي استقراراً واضحاً ودائماً بتحسين النتائج.

سلسلة Hénon

عرفت سلسلة Hénon من قبل Hénon [9] عن طريق المعادلة:

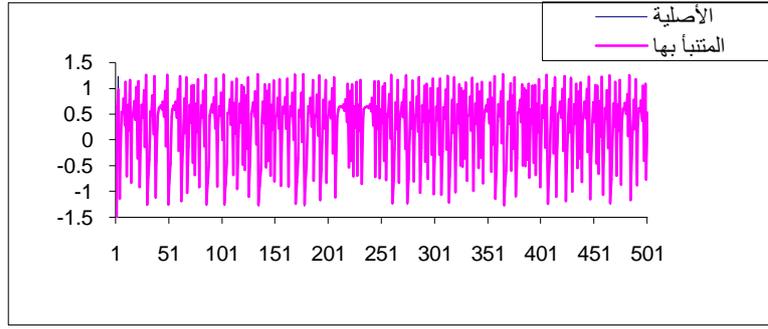
$$x(t) = 1.0 - 1.4x^2(t-1) + 0.3x(t-2)$$

وقسمت هذه السلسلة إلى ثلاثة أجزاء: - مجموعة تعليم مؤلفة من 5000 قيمة - مجموعة اختبار مؤلفة من 1500 قيمة - مجموعة توقف مؤلفة من 1500 قيمة، إذ أجريت تجارب على هذه السلسلة باستخدام شبكة عصبونية مؤلفة من 7 عصبونات (عصبون دخل واحد، عصبون خرج واحد في طبقتي الدخل والخرج على الترتيب و 5 عصبونات في الطبقة المخفية تكرارية بشكل كامل) ولإيضاح الشكل تم عرض هذه السلسلة فقط من أجل 150 قيمة كما في الشكل (11).



شكل (11) السلسلة الزمنية Hénon

إذ تم أخذ جزء من مجموعة الاختبار وهي أول 500 قيمة من أصل 1500 في مجموعة الاختبار وذلك لإظهار المقارنة بشكل واضح. ويبين الشكل (12) مقارنة للخروج الذي تم الحصول عليه باستخدام خوارزمية Boosting مع الشبكة التكرارية المستخدمة والقيم الأصلية في مجموعة الاختبار لسلسلة Hénon.



الشكل (12) مقارنة نتائج الشبكة المستخدمة مع القيم في مجموعة الاختبار لسلسلة Hénon

كما تمت مقارنة نتائجنا مع النتائج التي تم الحصول عليها باستخدام خوارزميات أخرى درسها باحثون آخرون وذلك مع سلسلة Hénon كما هو موضح في الجدول (4).

جدول (4) مقارنة نتائج الخوارزمية المطروحة مع نتائج خوارزميات أخرى

Hénon	الخوارزمية المستخدمة	أفضل نتيجة
	Boosting	0.006
	Boosting(المعدلة)[3]	0.003
	BPTT[7]	0.059

تبين النتائج التي تم الحصول عليها بالجدول (4) بأن الخوارزمية Boosting المستخدمة في بحثنا أو خوارزمية Boosting المعدلة دائماً تعطي نتائج محسنة مقارنة بالنتيجة التي تم الحصول عليها مع BPTT.

السلسلة الليزرية (Laser):

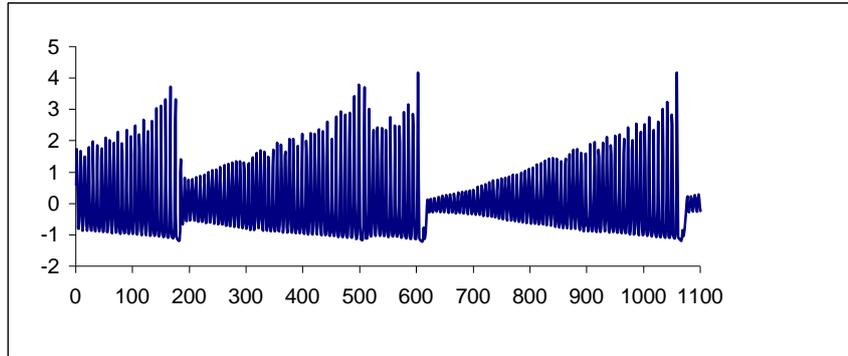
السلسلة الليزرية [10] هي سلسلة تقيس كثافة النبض الاضطرابي في الليزر NH₃-FIR. وهي واحدة من السلاسل المستخدمة في مكونات معهد سانتا في العالمي (The Santa Fe Institute Series Prediction and Analysis Competition) لقد استخدمت هذه السلسلة التي قدمها هذا المعهد في عدة مجالات منها: الفيزياء، البيولوجيا، البورصات المالية، الموسيقى، وغيرها. وقد تم استخدام معادلات لورنز (Lorenz equation) لتشكيل هذه السلسلة:

$$\frac{dx}{dt} = -\sigma x + \delta y, \frac{dy}{dt} = -xz + rx - y, \frac{dz}{dt} = xy - bz$$

غالباً ما تستخدم القيم $\sigma=10$ ، $r=28$ ، $b=8/3$ في هذه المعادلات.

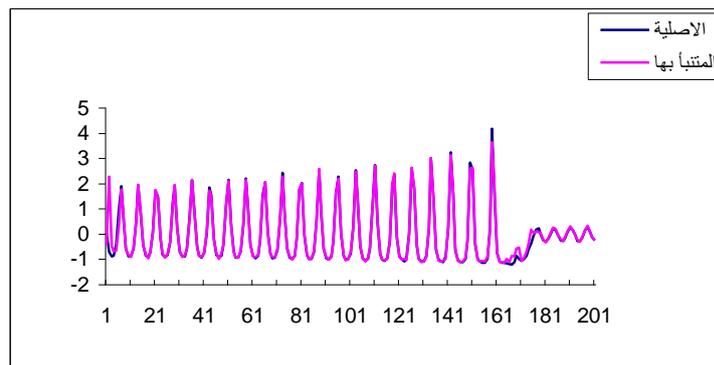
تم استخدام أول 1000 قيمة من قيم السلسلة و من ثم قدرت النتائج على الـ 100 قيمة التالية، إذ اعتمدنا في عملنا على هذه المعطيات وقد استخدمت: 900 نقطة في مجموعة التدريب والـ 100 نقطة التالية في مجموعة الاختبار. وقد

استخدمنا شبكة عصبونية مؤلفة من ثلاث طبقات (عصبون واحد في طبقة الدخل، عصبون واحد في طبقة الخرج وسبعة عصبونات في الطبقة المخفية تكرارية بشكل كامل). والشكل (13) يبين قيم السلسلة الزمنية المدروسة.



شكل (13) يبين قيم السلسلة الليزرية

ويوضح الشكل (14)، مقارنة السلسلة التي تتبأت بها من قبل الشبكة العصبونية المستخدمة مع Boosting بالقيم في مجموعة الاختبار للسلسلة الليزرية.



الشكل (14) مقارنة نتائج الشبكة المستخدمة مع مجموعة الاختبار للسلسلة الليزرية

تمت مقارنة نتائجنا بالنتائج التي تم الحصول عليها باستخدام خوارزميات أخرى كما يوضح الجدول (5).

جدول (5) يوضح مقارنة بين النتائج التي تم الحصول عليها باستخدام Boosting بنتائج خوارزميات أخرى

Laser	الخوارزمية المستخدمة	أفضل نتيجة
	Boosting	0.00513
	Boosting(المعدلة)[8]	0.0038
	BPTT[9]	0.0079

ومن جديد تظهر خوارزمتنا ال Boosting المستخدمة والمعدلة فعاليتها مقارنة بـ BPTT.

الاستنتاجات و التوصيات:

تبين من خلال بحثنا بأن استخدام الشبكات العصبونية الصناعية التكرارية كخطوة من خطوات الخوارزمية Boosting، أعطى موثوقية واستقرارية في مجال تنبؤ السلاسل الزمنية. كذلك وجدنا أن استخدام هذه الخوارزمية والتي هي إحدى طرائق تجميع النماذج أعطى نتائج أكثر دقة من النتائج التي يتم الحصول عليها من شبكة عصبونية صناعية واحدة، إذ يمكن استخدام الخوارزمية المطروحة في المجالات التطبيقية (كالتنبؤ بتدفق نهر الفرات مثلاً). كذلك يمكن العمل على تعديل هذه الخوارزمية من جهة سرعة التنفيذ و يمكن أيضاً استخدام الشبكات العصبونية الصناعية التكرارية مع خوارزمية أخرى كخوارزمية Bagging والتي تعتبر إحدى طرائق التجميع الفعالة، ومن ثم مقارنة نتائج الخوارزميتين لاستنتاج الخوارزمية الأكثر فعالية.

المراجع:

- [1]. PERALTA, J; LI, X; GUTERREZ, G; SANCHIS, A. *Time series forecasting by evolving artificial neural networks using genetic algorithms and differential evolution*. IEEE World Congress on Computational Intelligence, Barcelona, Spain. 2010, 18-23.
- [2]. DRUCKER, H. *Improving Regressors using Boosting Techniques*. In Fourteenth International Conference on Machine Learning, 1997, pages 107–115.
- [3]. ASSAAD, M. *Un Novel Algorithme De Boosting Pour Les Réseaux de Neurones Recurrents. Application au Traitement des données Séquentielles*. Thésés Pour Obtenir Le Grad ede Docteur de L'université de Tours –France, 2006.
- [4]. FREUND, Y.; SCHPIRE, R. *A decision-theoretic generalization of on-line learning and an application to boosting*, Journal of Computer and System Sciences, 1997, 55(1):119-139.
- [5]. SOLOMATINE, D.P.; SHRESTHA, D.L. *AdaBoost. RT: a Boosting Algorithm for Regression Problems*. Proc. of the International Joint Conference on Neural Networks, Budapest, Hungary, 2004, (pp. 1163-1168).
- [6]. MCDNNELL, J.R. WAAGEN, D. *Evolving Recurrent Predictors for Time Series Modling IEEE Transactions on Neural Networks*, 1994, 5, 24-38.
- [7]. AUSSEM, A. *Dynamical Recurrent Neural Networks: Towards Prediction and Modeling of Dynamical System*, Neurocomputing, 1999, 8, 207-232.
- [8]. MACKEY, M.; GLASS et, L. *Oscillations and Chaos in Physiological Control System*, Science, 1977, p. 197-287.
- [9]. HENON, M. *A Tow-Dimensional Mapping with a Strage Attractor*, Commun Math. Phys., 1976, 50-69.
- [10]. HUEBNER, U.; ABRAHAM, N.B.; WEISS, C.O. *Dimensions and entropies of chaotic intensity pulsations in asingle-mode far-infrared NH3 laser*. Physical Review A, 1989, 40(11):6354-6365.