



**استخدام المحاكاة للمقارنة بين الذكاء الاصطناعي وتحليل  
الانحدار المتعدد للعينات الصغيرة والكبيرة**

**Using Simulation to Compare Artificial  
Intelligence and Multiple Regression Analysis  
of Small and Large Samples**

د / محمد عبدالسلام عجمي

مدرس بقسم الإحصاء

كلية التجارة - جامعة الأزهر

dr.muhammad\_alagamy@azhar.edu.eg

أ.د / عبدالوهاب السيد حجاج

أستاذ الإحصاء المساعد - رئيس قسم  
الإحصاء بكلية التجارة - جامعة الأزهر

Wahabstat@yahoo.com

مجلة الدراسات التجارية المعاصرة

كلية التجارة - جامعة كفر الشيخ

المجلد الثامن . العدد الثالث عشر- الجزء الأول

يناير ٢٠٢٢م

رابط المجلة : <https://csj.journals.ekb.eg>

## ملخص البحث:

هذا البحث يتضمن هدفين، الأول تقديم طريقة للتنبؤ بأحجام عينات صغيرة وأخرى كبيرة مولدة من نماذج انحدار متعدد. والهدف الثاني مقارنة الطريقة المقترحة بالطريقة التقليدية للتنبؤ من خلال دراسة محاكاة. ولانجاز هذين الهدفين فقد تم توليد ١٦٠٠٠ عينة - بأحجام صغيرة (١٥، ٢٥، ٥٠) وكبيرة (٣٠٠، ٢٠٠، ١٠٠) من نماذج انحدار متعدد مختلفة واستخدامها لتدريب الشبكة واختبارها.

وتم استخدام ثلاثة معايير لقياس دقة تنبؤات الطريقتين. المعيار الأول متوسط مربعات الأخطاء (MSE)، والثاني متوسط الانحرافات المطلقة (MAD)، والمعيار الثالث، نسبة اقتراب تنبؤات كل طريقة من القيم الحقيقية (MAEP).

كما تم استخدام برنامج مصمم ببرنامج ماتلاب MATLAB مناسب لانجاز توليد عينات البيانات وتدريب واختبار الشبكة العصبية بالطريقة المقترحة، وكذلك للحصول على التنبؤات بالطريقتين المقترحة والتقليدية، ثم المقارنة بين تنبؤات الطريقتين. (برنامج MATLAB مرفق بملحق البحث)

وتكمن المشكلة في أن تنبؤات الطريقة التقليدية في حالة العينات الصغيرة من نماذج انحدار تقليدي تكون غير دقيقة. ونحن بحاجة الى الحصول على تنبؤات أكثر دقة في مثل هذه الحالات.

وقد أظهرت النتائج تفوق ملحوظ للطريقة المقترحة باستخدام الذكاء الاصطناعي، على الطريقة التقليدية وفقا للمعايير الثلاث المستخدمة، خاصة في حالة العينات الصغيرة.

**الكلمات المفتاحية:** الذكاء الاصطناعي Artificial Inelegant - الشبكات العصبية Neural Network - بنية الشبكة العصبية Neural Network Architecture - تدريب واختبار الشبكة العصبية - نماذج الانحدار الخطى - حزم برامج ماتلاب Matlab package.

## **Abstract:**

This paper has two objects. First, we present an artificial neural network method for forecasting small samples generated from Multiple Linear Regression models. Second, we compare the proposed method with the traditional method through a simulation study. To achieve these objects 16000 samples, generated from different Multiple Linear Regression models, were used for the network training. Then the system was tested for generated data. The accuracy of the neural network forecasts (NNF) is compared with the corresponding Multiple Linear Regression models by using three tools: the mean square error (MSE), the mean absolute deviation of error (MAD) and the ratio of closeness from the true values (MAEP). A MATLAB code was written, for simulation purposes. The code was used for neural network training, testing and comparing with traditional method.

Using the measures mentioned above, the artificial neural network was found deliver better forecasts than the regression traditional technique for forecasting small samples.

**Keywords :** Artificial Inelegant - Neural Network - Neural Network Architecture - Neural Network Training and Testing - Linear Regression Models - Matlab package

## (١) مقدمة :

في ظل ثورة المعلومات وما نتج عنها من تدفق هائل للبيانات أصبحت هناك حاجة ملحة لتوافر قواعد بيانات دقيقة وممثلة لواقع الظاهرة أو الظواهر محل الدراسة ثم استخدام أسلوب علمي وأدوات تحليل مبتكرة لإجراء معالجة الكترونية Electronic processing بدلا من المعالجة اليدوية Manual processing لهذه البيانات. والهدف هو الحصول على معلومات كافية كما وكيفا لاحتياجات الباحثين وصانعي القرارات. ومع تطور الحاسب الآلي - والذي أصبح عاملا رئيسا في كافة أنشطة الحياة تقريبا - توصل الباحثون لنوع من البرامج تعتمد طريقة بنائها على تقنية تحاكي الإنسان في طريقة اتخاذه لقراراته اليومية تسمى الذكاء الاصطناعي.

ويعرف الذكاء الاصطناعي Artificial intelligence بأنه علم يتضمن مجموعة أساليب وطرق جديدة في برمجة أنظمة الحاسب تستخدم لتطوير أنظمة تحاكي بعض عناصر ذكاء الإنسان وتسمح لها بالقيام بعمليات استنتاجية على حقائق وقوانين يتم تمثيلها في ذاكرة الحاسب. بعبارة أخرى الذكاء الاصطناعي : علم يتناول كيفية جعل الآلة - أي الحاسب - تؤدي عمليات مناظرة لقدرات البشر العقلية .

ونتيجة الثورة التي حدثت في مجالي المعلومات والتحكم الآلي ظهر الذكاء الاصطناعي في الخمسينات من القرن الماضي. وترمى أبحاثه إلى تحقيق هدفين رئيسين : الأول : الوصول إلى فهم عميق للذكاء الإنساني عن طريق محاكاته . الثاني : الاستثمار الأفضل للحاسب الآلي والعمل على استغلال إمكاناته كافة , وخصوصا بعد التطور السريع في قدرات الحاسبات ورخص ثمنها . ولغاته هي :Lisp وهي لغة معالجة اللوائح (List Processing Language), ولغة Prolog , وهي لغة البرمجة بالمنطق (Programming in Logic) , وهذه اللغات تتيح للمبرمج إمكانيات كبيرة في كتابة البرامج .

ومن المجالات المرتبطة بهذا العلم : علم التحكم الآلي Cybernetics , وعلم الروبوت Robotics , والتعلم بمساعدة الحاسب CAI , والتصميم الهندسي بمساعدة الحاسب CAD , والترجمة الآلية MT , والتمييز الآلي للأنماط Pattern recognition , والألعاب الالكترونية كالشطرنج ..... وغيرها .

و من أهمها فروع الذكاء الاصطناعي: النظم الخبيرة Expert Systems , والتفتيق في البيانات , والخوارزميات الجينية Genetic algorithms , والشبكات العصبية Neural Networks.

وخلال هذا البحث سنبين كيف يمكن استخدام أحد فروع الذكاء الاصطناعي وهو الشبكات العصبية في تحليل الانحدار المتعدد .

وتعد الشبكات العصبية الاصطناعية Artificial Neural Network (ANN) من أهم الطرق المرنة التي لديها القدرة على التعلم الذاتي السريع وسرعة التغير في البيئة الديناميكية , وذلك من خلال قواعدها الخاصة ووفق منهجية محددة وتعزيز هذا المنهج عبر التدريب بطريقة تحاكي فيها عمل الخلايا العصبية الدماغية من حيث بنيتها ومعالجتها للمدخلات .

## (١-١) مشكلة البحث

بعد التعرف على النموذج المبدئي للظاهرة محل الاهتمام يجب تقدير متجه معالم النموذج المقترح ، وتعتبر طريقة المربعات الصغرى العادية ( Ordinary Least Squares Method ) من أهم الطرق المستخدمة في تقدير معالم النماذج وذلك لما تتمتع به مقدراتها من خصائص المقدر الجيد وذلك بافتراض توافر شروط معينة منها تبعية عنصر الخطأ للتوزيع المعتدل وهذا قد لا يتحقق في حالة العينات الصغيرة . ويترتب على ذلك ان تنبؤات الطريقة التقليدية تكون أقل دقة .

ولتجنب تلك المشاكل لزم البحث عن طريقة جديدة للتنبؤ بخلاف الطرق التقليدية التي تعتمد على دالة الإمكان في تقدير معالمها , وهذه الطريقة هي الشبكات العصبية الاصطناعية , حيث تمتاز هذه الطريقة بأنها تعمل بصورة آلية لاختيار نموذج مناسب يوضح كيفية اعتماد المخرجات على المدخلات وتعمل بكفاءة في حالة العينات الصغيرة .

### (٢-١) هدف البحث

يهدف هذا البحث الى تقديم طريقة مقترحة للتنبؤ بقيم الانحدار المتعدد باستخدام الشبكات العصبية من خلال بيانات مولدة من الكمبيوتر طريقة مقترحة للتنبؤ ومقارنتها بالطريقة التقليدية للتحقق من صلاحية الطريقة المقترحة للتنبؤ بقيم الانحدار المتعدد في حالة العينات الصغيرة, ولتحقيق هذا الهدف سيتم توليد 16000 عينة بأحجام مختلفة (صغيرة وكبيرة) من نماذج انحدار متعدد وبمعلمت مختلفة تستخدم لتدريب الشبكة , بعد ذلك تتم مقارنة تنبؤات كل طريقة بالقيم الحقيقية لقياس دقة التنبؤات. وسيتم ذلك باستخدام ثلاث مقاييس هي :

١- متوسط مربعات الخطأ (MSE) Mean of Squared Error

٢- متوسط الانحرافات المطلقة (MAD) Mean Absolute Deviation

٣- نسبة الحالات التي تتحقق فيها أخطاء مطلقة أقل في الطريقتين

The Percentage of cases of Minimum Absolute error (MAEP)

### (٣-١) أهمية البحث

تأتى أهمية البحث في استخدام الشبكات العصبية في التنبؤ كطريقة جديدة يمكن استخدامها للتنبؤ بكثير من الظواهر في مجالات عديدة , حيث أنها تمتاز عن غيرها من الأساليب الإحصائية التقليدية , ومن هذه المميزات أنها تفيد في الحصول على تنبؤات جيدة في حالة العينات الصغيرة , حيث أنها تعطي مجموع مربعات أخطاء غير خطية أقل , كما أن طريقة الشبكات العصبية الاصطناعية (ANN) تحتاج عينات أصغر نسبيًا في اختبار مصداقية النماذج , ومن مميزات أيضا أنه يتم التنبؤ فيها بصورة آلية تصلح في حالة النماذج الخطية وغير الخطية, كما يمكن استخدام الشبكات العصبية الاصطناعية لتقييم قدرة الأساليب الإحصائية الأخرى في تقدير النماذج و اختبارها .

وسوف يتم تصميم برنامج مناسب من خلال حزم MATLAB لإنجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات طريقة الانحدار المتعدد مع المقارنة بين الطريقتين كذلك تصميم برنامج يمكنه التنبؤ بالقيم المستقبلية باستخدام الطريقة المقترحة بصورة أوتوماتيكية.

### (٤-١) الدراسات السابقة :

لقد قام كثير من الباحثين بدراسة خصائص مقدرات العينات الصغرى باستخدام نماذج الانحدار و دراسة خصائص العينة الصغيرة بالإضافة الى دراسة الذكاء الاصطناعي وفيما يلي عرض مختصر لأهم هذه الدراسات :

- دراسة **Shenton and Johnson (1965)** اقترحا انه في حالة نموذج الانحدار الذاتي من الرتبة الاولى (AR(1) والعينات غير الصغيرة جدا(وليكن أقل من 20) فان الفرق بين مقدر

الإمكان الأعظم و المربعات الصغرى يكاد يكون مهملًا , كما يوجد تحيز لأسفل مقداره  $\phi / n$  (2)

- دراسة **Dent and Min (1978)** وجدا ان متوسط مربعات الأخطاء لتقديرات الإمكان الأعظم أقل من تلك المحسوبة بالطرق الأخرى .

وأشار **Dent** الى انه في العينات الصغيرة قد لا توجد قيمة صغرى لمجموع المربعات المشروطة داخل منطقة الانقلاب مما يعنى ان طريقة الامثلية الغير مشروطة لن تقتارب وينتج عن ذلك تقديرات ليست دقيقة وهذه الحالة محتملة فقط عندما تكون  $\theta$  قريبة من واحد صحيح وحجم العينة صغير.

- دراسة **Harvey and Phillips (1979)** : عن طريق طريقة مونت كارلو تمت مقارنة خصائص العينة الصغيرة لمقدر الإمكان الأعظم المتحقق من خلال المربعات الصغرى العادية Ordinary Least Squares ومقدر المربعات الصغرى العامة ذات المرحتين Least Squares Two -Step estimated generalized Squares وأظهرت النتائج تفوق مقدر المربعات الصغرى العادية .

- دراسة **Brockwell and Davis(1993)** اكدا ان معيار اكاكي للمعلومات AIC ( Akaike Information Criterion ) المشتق من نماذج الانحدار العام والانحدار الذاتي للسلاسل الزمنية يكون له فائدة كبيرة خاصة عندما يكون حجم العينات صغيرا , ولقد اقترحا الباحثين تصحيحا لمعيار AIC يرمز له بالرمز AICc يستعمل مع العينات كبيرة الحجم .

- أشار كل من **Pesaran, & Timmermann (2003)** الى انه بالرغم من ان استخدام نماذج الانحدار الذاتي بشكل دائم فى التنبؤ و غالبا ما تؤدي الى نتائج أفضل من نماذج أكثر تعقيدا فان الأدلة التجريبية تقترح ان الانحدار الذاتي للعديد من السلاسل الزمنية فى مجال الاقتصاد والعمليات المالية من المحتمل ان يكون بها مشكلة الفواصل الهيكلية Structural Breaks , وفى هذه الدراسة تم وضع الإطار النظرى لتحليل تنبؤات العينات الصغرى لنماذج الانحدار الذاتي العامة فى ظل وجود الفواصل الهيكلية .

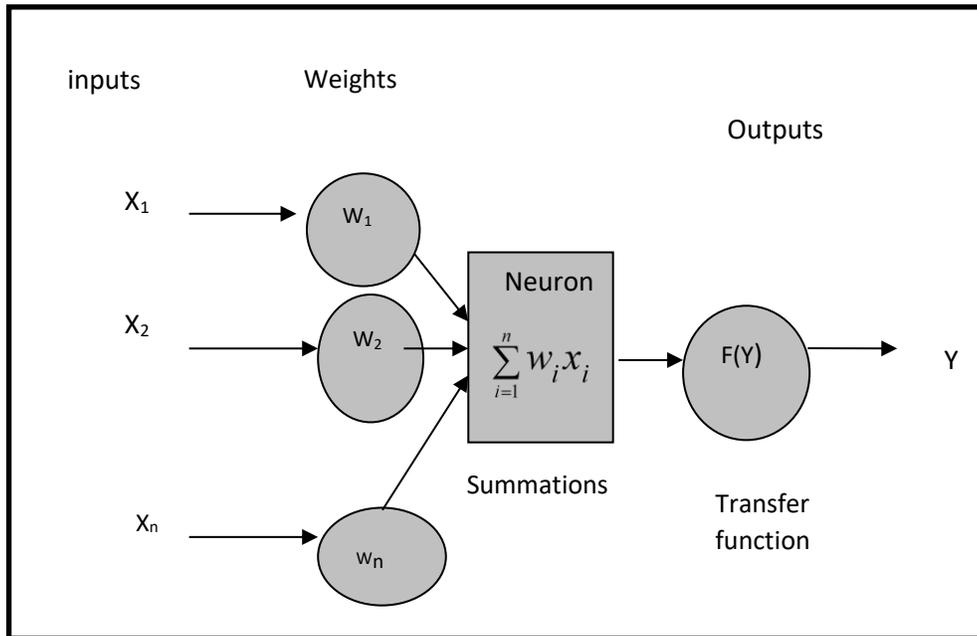
- وفي دراسة **دريال (٢٠١٤)** تم مقارنة نماذج التنبؤ الخطية وغير الخطية للتنبؤ بمؤشر سوق دبي المالي وذلك بالاعتماد على قاعدة بيانات يومية للفترة ٢٠٠٦/٢/٢٢ إلى ٢٠١٤/١/٣٠ وتوصلت الدراسة الى أن نموذج الشبكات العصبية الاصطناعية ANN لديه قدرة أكبر على التنبؤ مقارنة بنموذج الانحدار الذاتي المشروط بعدم تجانس الأخطاء المعمم GARCH. فقد جاءت هذه الدراسة بتقديم طريقة جديدة ومؤثرة للتنبؤ باستخدام تحليل الانحدار المتعدد واستخدام تقنية الشبكات العصبية الاصطناعية (ANN) Artificial Neural Network , كما يقارن بين الطريقة المقترحة والطريقة التقليدية للانحدار المتعدد .

- وفي دراسة **الشوافى , حجاج (٢٠١٦)** تم مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة " بوكس و جينكنز " لتوضيح أي منهما أفضل للتنبؤ بنماذج ARMAX فى حالة العينات الصغيرة ولتحقيق هذا الهدف تم توليد ١٦٠٠٠ عينة بأحجام مختلفة (صغيرة وكبيرة) من نماذج ARMAX بمعلمات مختلفة تستخدم لتدريب الشبكة , وقد أوضحت نتائج هذه الدراسة القدرة العالية للطريقة المقترحة للتنبؤ لنماذج ARMAX باستخدام أحد طرق الذكاء الاصطناعي - وهي طريقة الشبكات العصبية - على التنبؤ بالقيم المستقبلية للسلسلة الزمنية المعطاة وذلك بطريقة آلية.

- ولقد جاءت هذه الدراسة لتقديم طريقة جديدة ومؤثرة للتنبؤ باستخدام تحليل الانحدار المتعدد واستخدام تقنية الشبكات العصبية الاصطناعية (ANN) في حالة العينات الصغيرة , كما يقارن بين الطريقة المقترحة والطريقة التقليدية للانحدار المتعدد .

## ( ٢ ) الشبكات العصبية الاصطناعية

تعد الشبكات العصبية الاصطناعية (ANN) Artificial Neural Networks أحد أهم طرق الذكاء الاصطناعي, و تتمحور فكرتها حول محاكاة قدرة العقل البشري على التعرف على الأنماط , وتمييز الأشياء , باستخدام الحاسب الآلي من خلال إتباع عملية التعليم الذاتية التي تحدث في العقل , والتي يتم فيها الاستفادة من الخبرات السابقة في سبيل الوصول إلى أفضل نتائج في المستقبل .(نظر: حاجي, و المحميد , (١٩٩٩) , ص ١٩).



شكل (٢-١)

نموذج لوحدة تشغيل

والشكل (١) السابق يبين وحدة تشغيل بسيطة داخل الشبكة العصبية (انظر: Turban, et al. (2005), حيث يكون لكل وحدة تشغيل مسار إدخال واحد أو أكثر تنحصر مهمته في نقل المعلومات من العالم الخارجي إلى وحدة التشغيل الذي تقوم بدورها بعملية التجميع البسيطة , ثم تحويل المعلومات بواسطة دالة تفعيلية تعرف بدالة التحويل , بعد ذلك تنقل المعلومات كمخرجات من خلال مسار المخرجات .

وبشكل رياضي فان كل خلية عصبية تستقبل عدد من إشارات المدخلات ( $X_1$ , Input Signals  $X_2, \dots, X_n$ ) والتي تماثل التفرعات العصبية Dendrites , ثم يتم ضرب كل المدخلات في الأوزان ( $W_1, W_2, \dots, W_n$ ) التي تعد الوسيلة الأساسية لذاكرة الشبكات العصبية الاصطناعية طويلة المدى وتعتبر عن درجة أهمية المدخلات , وحاصل الجمع summations يتم معالجته باستخدام دالة تحويل Transfer function  $F(Y)$  لنحصل منها على إشارات المخرجات Output Signals ( $Y$ ) .

## [١-٢] تعلم الشبكة العصبية Learning of the Neural Network

تعلم الشبكة العصبية الاصطناعية هي العملية التي من خلالها تقوم الشبكة العصبية بتعديل نفسها استجابة للمدخلات من أجل الحصول على المخرجات المستهدفة . وبأسلوب آخر فهي عملية اكتساب المعرفة , حيث تبحث الشبكة العصبية عن المعرفة من مجموعة بيانات العينة. وأثناء عملية التعلم تعدل الشبكة أوزان الاتصال على أساس المدخلات الواردة حتى تقترب المخرجات من المخرجات الحقيقية أو المستهدفة ( انظر (Zurada (1992).

و يتم تعليم أو تدريب الشبكة العصبية على اكتشاف العلاقات النمطية في البيانات بإتباع إحدى الطرق الآتية :

### [١-١-٢] التعليم الإشرافي : Supervised Learning

تعد هذه الطريقة هي الأكثر انتشارا في تدريب الشبكة العصبية , وفيها تجمع عينات من البيانات تحتوي قيماً للمتغيرات المدخلة وقيماً للمتغيرات المخرجة , و تقوم الشبكة بمقارنة النتائج التي تقدرها للمتغيرات الخارجة لكل عينة مدخلة بالقيم الفعلية لهذه المتغيرات , وبناء على ذلك تقوم الشبكة بإجراء التعديلات على أوزان الاتصال بهدف تقليل الأخطاء في النتائج , ثم تعاد عملية التدريب عدة مرات إلى أن يتم الوصول إلى نتائج مقبولة .

### [٢-١-٢] التعليم غير الإشرافي Unsupervised Learning

تتشابه هذه الطريقة مع طريقة التعليم الإشرافية إلا أنها تختلف عنها في أن العينات المستخدمة في عملية التدريب لا تتضمن أية قيم للمتغيرات الخارجة , وتتكون البيانات الداخلة إلى الشبكة من عدة قطاعات أو مجموعات , حيث تتدرب الشبكة في هذه الحالة على اكتشاف المميزات غير الظاهرة في مجموعة البيانات المستخدمة في عملية التدريب , ومن ثم استخدام تلك المميزات في تقسيم بيانات المدخلات إلى مجموعات مختلفة فيما بينها ومقارنة داخل كل مجموعة .

### [٣-١-٢] التعليم بإعادة التدعيم: Reinforcement Learning

هذه الطريق خليط بين الطريقتين السابقتين , حيث لا يفصح للشبكة العصبية عن القيم الحقيقية للمخرجات كما هو الحال في طريقة التدريب غير الإشرافية ولكن يشار للشبكة بصحة نتائجها المحصلة أو خطأها كما في طريقة التعليم الإشرافية .

## [٢-٢] الهيكـل العام للشبكة Typical Architectures

عملية تنظيم الخلايا العصبية في طبقات وكيفية الاتصال بين هذه الخلايا لتكوين الشبكة تسمى بهيكل الشبكة Architectures , و بوجه عام من الممكن تقسيم هيكل الشبكة العصبية الاصطناعية إلى ثلاثة أنواع رئيسية هي: (١) شبكة وحيدة الطبقة ذات التغذية الأمامية Single-Layer Feed forward Network , (٢) شبكة متعددة الطبقات ذات التغذية الأمامية Multi-Layer Feed forward Network , (٣) شبكة متعددة الطبقات ذات التغذية المرتدة Multi-Layer Recurrent Network (انظر: Demuth & Beale 1998) و سنوضح كل نوع فيما يلي :

## [٢-١-٢] شبكة وحيدة الطبقة ذات التغذية الأمامية :

وهي أبسط هياكل الشبكات العصبية الاصطناعية، والنوع الأكثر شيوعاً منه يسمى Perceptron ، وهو أبسط صيغة للشبكات العصبية الاصطناعية، كما أنه النموذج الذي تبنى عليه الأنواع الأخرى من الشبكات وحيدة الطبقة، كما يعد أبسط أنواع الشبكات العصبية أمامية التغذية حيث تنتقل المعلومات من الطبقة المدخلات إلى طبقة المخرجات مباشرة ، كما أنها تتعلم عن طريق التعليم الإشرافي. والشكل (١) السابق يوضح هيكل شبكة عصبية وحيدة الطبقة بتغذية أمامية . ومن خلال تلك الشبكة تتم عملية التعلم عن طريق قيام وحدات المعالجة بعدة خطوات رئيسية هي :

الخطوة الأولى: التحديد العشوائي للقيم الابتدائية للأوزان  $w_1, w_2, \dots, w_n$  ، وللقيمة الحدية Threshold Value ( $\theta$ ) وذلك في المدى  $[-0.5, 0.5]$  .

الخطوة الثانية: عملية التنشيط : فبعد أن تستقبل كل وحدة معالجة (نيرون) Neuron العديد من الإشارات المدخلة، وحساب المجموع الموزون لهذه المدخلات المستخدمة و الذي عادة ما يتم باستخدام دالة المجموع Summation Function الآتية:

$$X = \sum_{i=1}^n w_i x_i \quad \dots \dots \dots (2-1)$$

X: صافي المدخلات الموزونة للخلية العصبية

Wi : الأوزان النسبية لعقد الاتصال ما بين الطبقات

xi : قيمة المدخلات i

n : عدد مدخلات الخلية العصبية

يتم تنشيط المدرك Perceptron عن طريق تطبيق المدخلات  $X_1, X_2, \dots, X_n$  ، والمخرجات المرغوب بها  $T(k)$  ، وحساب المخرجات الفعلية عند التكرار k كما يلي :

$$y(k) = \text{step} \left[ \sum_{i=1}^n X_i(k) W_i(k) - \theta \right] \quad (2-2)$$

وهذا النوع من دوال التحويل (التنشيط) يسمى بدالة الخطوة Step Function.

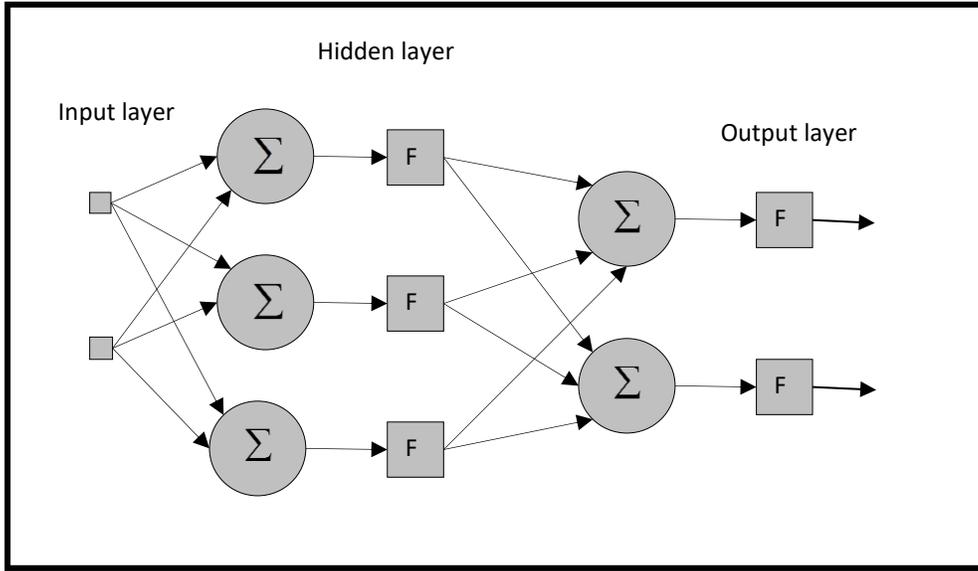
وتجدر الإشارة إلى أنه بجانب دالة الخطوة يوجد كثير من دوال التنشيط ولكن وجد أن قلة فقط منها لها تطبيقات عملية و من أهم هذه الدوال ما يلي :

١- دالة الإشارة Sign Function      ٢- دالة الخطوة Step Function

٢- الدالة الخطية Linear Function      ٤- الدالة التجميعية Sigmoid Function وعادة تستخدم دالة الإشارة Sign Function و دالة الخطوة Step Function للخلايا العصبية في اتخاذ القرارات لمهام التصنيف ، وتمييز الأنماط. (انظر على سبيل المثال : نحيفيتسكي، (٢٠٠٤)، ص ٢٣٥). وتعتبر الدالة التجميعية sigmoid Function أكثر دوال التحويل استخداماً لما تتميز به من بساطة في التمييز وسهولة في حساب الميل ، أما دالة التحويل الخطية Linear Function فيمكن أن تستخدم في بعض تطبيقات السلاسل الزمنية ، وفي أغلب الأحوال دالة التحويل تجمع من توليفة خطية ، انظر: Alshawadfi (2003).

## [٢-٢-٢] شبكة متعددة الطبقات ذات التغذية الأمامية :

تتكون الشبكة متعددة الطبقات من واحد أو أكثر من الطبقات (أو المستويات) من عقد الاتصال Nodes تسمى طبقات مخفية Hidden Layers توجد بين طبقات المدخلات Input Layers وطبقات المخرجات Output Layers , وفي الشبكات ذات التغذية الأمامية تنتشر إشارات المدخلات في الاتجاه الأمامي من طبقة لطبقة, ولا يسمح بالرجوع للخلف, ويمكن لهذا النوع من الشبكات حل العديد من المشاكل المعقدة التي لا تستطيع الشبكة ذات الطبقة الواحدة حلها , ولكن تدريبها قد يستغرق وقتاً أطول. انظر: (Hijazi 2007)



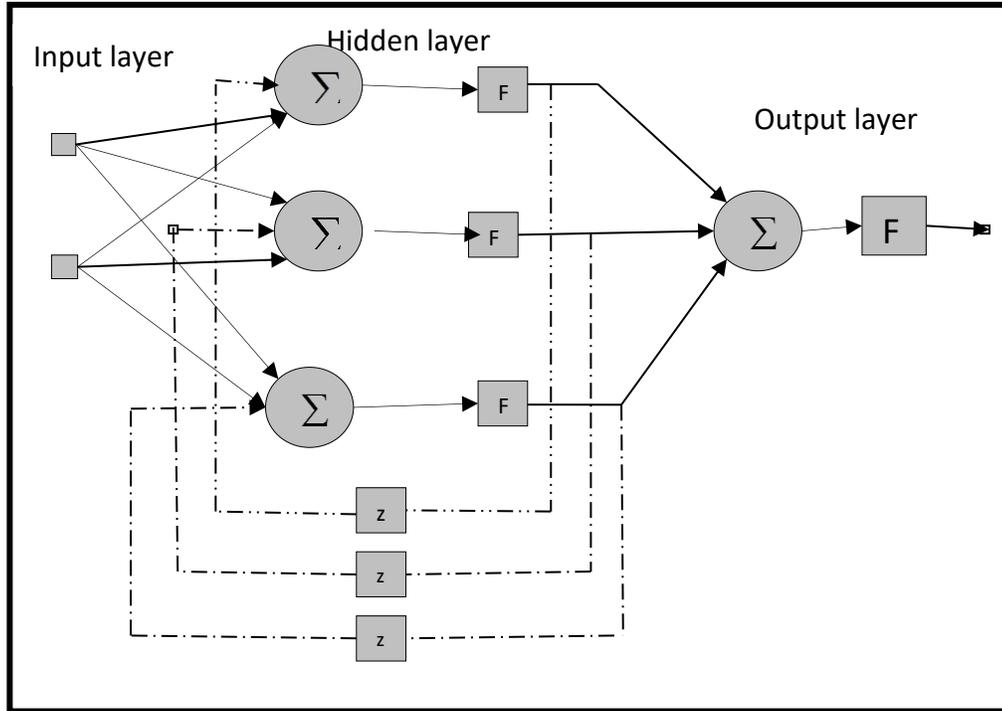
شكل (٢-٢) الشبكة متعددة الطبقات ذات تغذية أمامية

وتقوم العناصر الحسابية في الطبقة المخفية بإجراء عملية الجمع الموزون وترسل إشارة مخرجات (أنماط تنبيه) إلى طبقة المخرجات التي تقوم هي الأخرى بعملية الجمع الموزون وتحديد أنماط المخرجات للشبكة كلها. ( انظر: (٢٠٠٤) نجيفيتسكي). كما انه بزيادة عدد وحدات المعالجة داخل الطبقة الخفية أو إضافة أكثر من طبقة مخفية في الشبكة , يسمح للشبكة بالتعامل مع كثير من الدوال المعقدة والتقريب الدقيق للدوال المستمرة وهذا ما نصت عليه نظرية (Cybenko). (أنظر Cybenko (1989).

أما بالنسبة لعملية التعليم فإنها تستمر بنفس الطريقة في الشبكة وحيدة الطبقة , حيث تحدث الأوزان باستخدام التعلم بالتغذية الخلفية Back propagation Learning , وقبل هذا التحديث يوجد خطوتين متتاليتين أولهما أمامية Forward والأخرى تراجعية Backward , ففي الخطوة الأمامية يتم حساب مخرجات الشبكة من البيانات المدخلة , ومقارنة هذه المخرجات مع المخرجات المستهدفة عن طريق حساب الخطأ . أما في الخطوة التراجعية فتقوم الشبكة بتعديل الأوزان النسبية بهدف تصغير الخطأ , وتسمى العملية التي تضم المرحلتين السابقتين بالدورة (Epoch), ويتم تكرار هذه الدورة إلى أن نصل لأقل مجموع مربعات للخطأ.

### [٣-٢-٢] شبكة متعددة الطبقات ذات التغذية المرتدة :

وهي النوع الثاني من الشبكات العصبية متعددة الطبقات , و هذا النوع يحتوي على حلقة تغذية خلفية واحدة على الأقل (مسار مغلق من التغذية الخلفية feedback loop) كما في الشكل (٣), حيث أنه وعلى عكس الشبكة متعددة الطبقات ذات التغذية الأمامية يتم حساب الخطأ بين مخرجات الشبكة والمخرجات الحقيقية ولكن يتم تغذية الخطأ في اتجاه عكسي (عكس اتجاه المدخلات) للشبكة لتعديل الأوزان وبالتالي يتم تخفيض الخطأ, وهذا الإجراء يتم تكراره حتى يصل الخطأ إلى أقل قيمة ممكنة .



شكل (٣-٢) الشبكة متعددة الطبقات ذات التغذية مرتدة

### (٣) الطريقة التقليدية لتحليل الانحدار المتعدد :

يمكن تقسيم مراحل تحليل الانحدار المتعدد إلى أربع مراحل وهي كما يلي :

#### اولا : توصيف النموذج Model Identification :

توصيف النموذج من أهم مراحل تحليل الانحدار المتعدد والذي يقصد به اقتراح نموذج مناسب يمثل العلاقة بين الظواهر محل الدراسة حيث يستخدم نموذج الانحدار في تمثيل العلاقة بين متغير تابع وواحد أو أكثر من المتغيرات المستقلة وهذه العلاقة قد تكون خطية أو غير خطية المعالم ، بعض النماذج غير الخطية في المعالم يمكن تحويلها لنماذج خطية , وقد يواجهنا مشاكل في تحليل مثل هذه النماذج .

$$y_i = f(x) + \varepsilon_i \quad i = 1, 2, 3, \dots, n$$

$$Y_{n,1} = X_{n,k} \beta_{k,1} + \varepsilon_{n,1} \dots \dots \dots (3-1)$$

حيث:

- |  |   |
|--|---|
| متجه عمود من الدرجة (n. 1) تمثل مشاهدات عن المتغير التابع .                        | Y |
| مصفوفة من الدرجة (n. k) تمثل مشاهدات عن المتغيرات التفسيرية وعددها (k. 1) .        | X |
| متجه عمودي يمثل معالم المجتمع وعددها k .   | β |
| متجه عمود من الدرجة (n. 1) يمثل الأخطاء العشوائية له توزيع معتدل متعدد المتغيرات . | ε |

و عند المحاكاة سوف نستخدم ثماني نماذج مختلفة من نماذج الانحدار المتعدد بمعالم مختلفة وهي :

- 1)  $y = 0.5x^2$
- 2)  $y = 0.5 + 0.4x_1^{0.5} + 0.3x_2^{-1}$
- 3)  $y = 0.4 + 0.3x_1 + 0.2x_2^2 - 0.6x_3^3$
- 4)  $y = 0.5x_1^{0.4}x_2^{0.2}$
- 5)  $y = 0.5 - 0.7e^{0.4x}$
- 6)  $y = \frac{0.5}{1 + 0.4e^{-0.6x}}$
- 7)  $y = 0.5e^{-0.4x_1} + 0.6e^{-0.7x_2}$
- 8)  $y = \frac{1}{1 + 0.6x}$

ونجد أن توصيف النموذج في برنامج الماتلاب MATLAB يتمثل في الأمر التالي :

$$[aa \ b \ cc2] = \text{regress}(yy, xx) \dots \dots \dots (2-2)$$

و عند التنبؤ بقيم الانحدار المتعدد بالطريقة التقليدية بالاستعانة ببرنامج MATLAB يتم استخدام الدالة التالية :

$$y_{true} = yy \ (n-h+1: n) \dots \dots \dots (3-3)$$

### ثانيا : تقدير معالم النموذج Estimation of Model parameters

يتم تقدير معالم النموذج الذي وقع عليه الاختيار باستخدام إحدى الطرق الآتية :-

أ - طريقة العزوم . ب - طريقة الإمكان الأكبر . ج - طريقة المربعات الصغرى .  
والهدف من هذه الطرق هو الحصول على تقديرات المعالم

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$  بأقل مجموع مربعات أخطاء ممكن .

ثالث : التحقق من صلاحية النموذج **Diagnostic Checking of the Model** :

تعد هذه المرحلة من المراحل الأساسية في تحليل الانحدار المتعدد , حيث أنه على أساسها يتم تحديد مدى قبول النموذج الذي تم توصيفه وتقدير معالمه , ووفقاً لهذه المرحلة يحدد إما بالاستمرار في عملية التحليل وتحقيق ما هو مستهدف من نموذج التحليل أو العودة إلى نقطة البداية من تحديد وتقدير ثم اختبار , ويتم اختيار النموذج الذي يحقق أقل متوسط مربعات أخطاء MSE . وسيتم ذلك باستخدام ثلاث مقاييس هي :

- متوسط مربعات الخطأ (MSE) Mean of Squared Error
  - متوسط الانحرافات المطلقة (MAD) Mean Absolute Deviation
  - نسبة الحالات التي تتحقق فيها أخطاء مطلقة أقل في الطريقتين
- The Percentage of cases of Minimum Absolute error (MAEP)

رابعاً : استخدام النموذج في التنبؤ و / أو التحكم **Use the model in Forecasting** :

تعتبر هذه المرحلة ( مرحلة التنبؤ ) على درجة كبيرة من الأهمية , حيث يعتبر التنبؤ بمسار الظاهرة محل الدراسة هو الهدف في مرحلة بناء وتقدير واختبار النموذج فإذا لم يتم الحصول على تنبؤات جيدة باستخدام النموذج المختار فإنه بذلك يفقد قيمته العملية.

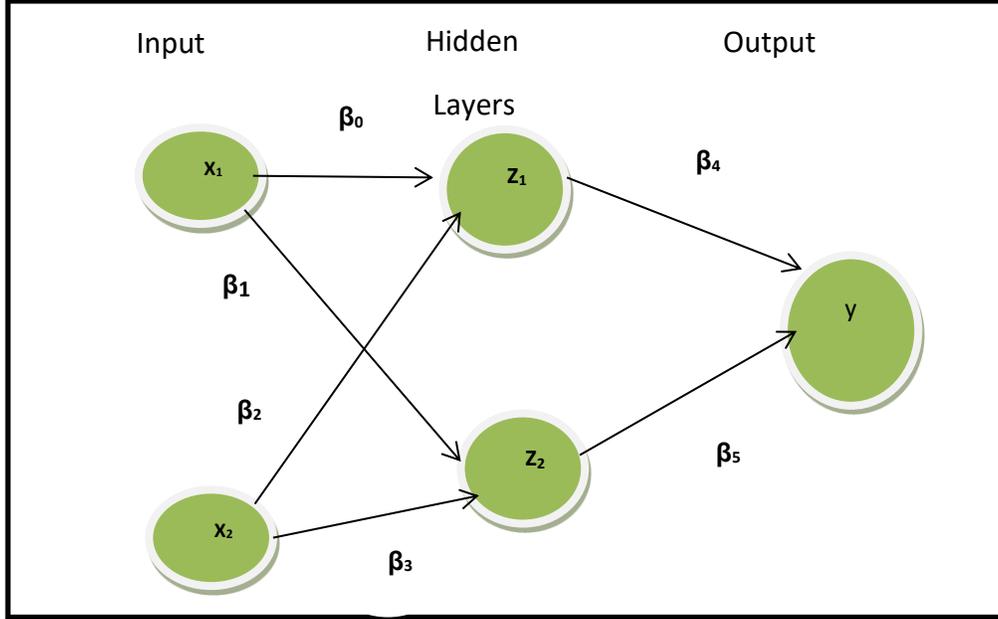
عند التنبؤ بقيم الانحدار المتعدد بالطريقة التقليدية بالاستعانة ببرنامج MATLAB تم استخدام الدالة التالية :

$$y_{true} = yy(n-h+1:n) \dots\dots\dots (3-4)$$

#### (٤) الشبكات العصبية كنموذج انحدار خطي:

من الممكن اعتبار الشبكات العصبية الاصطناعية كنموذج انحدار خطي يتكون من المتغيرات المدخلة وتتمثل في القيم الماضية  $y_{t+1}, y_{t+2}, \dots, y_{t+p}$  أو تحويلاتها و قيم متغير خارجي  $x_{t+1}, x_{t+2}, \dots, x_{t+h}$  والأخطاء :

وكما في الشكل (٢) تمثل X متغيرات مستقلة داخلية في البرنامج " Input " , وتمثل Z الطبقات المخفية والتي تم فيها تدريب الشبكة " Hidden Layers " , وتمثل Y المتغير التابع والذي يقوم بإخراج البيانات بصورة جاهزة " Output " .



شكل ( ٤ - ٣ ) نموذج انحدار متعدد ك شبكة عصبية اصطناعية

من الممكن اعتبار الشبكات العصبية الاصطناعية كنموذج انحدار متعدد :

$$Y = X \beta + \varepsilon \quad \dots\dots\dots(4-1)$$

حيث:

$Y$  : متجه عمود من الدرجة  $(n \times 1)$  تمثل مشاهدات عن المتغير التابع .

$X$  : مصفوفة من الدرجة  $(n \times k)$  تمثل مشاهدات المتغيرات المفسرة وعددها  $(k - 1)$  .

$\beta$  : متجه عمود يمثل معالم المجتمع وعددها  $k$  .

$\varepsilon$  : متجه عمود من الدرجة  $(n \times 1)$  يمثل الأخطاء العشوائية .

حيث يفترض أن  $E(\varepsilon / X) = 0$  , وكذلك الدالة  $Y$  غالبا ما تكون غير معلومة ويتم تقريبها بواسطة الدالة  $g(X, W)$  , حيث  $W$  تمثل متجه المعالم وتسمى الأوزان , والتي تكون عنصر في فراغ المعالم **parameter space** وتقدر من مجموعة البيانات المدربة ( العينة sample ) , وكل من فراغ المعالم ومتجه المعالم يعتمد على دالة التقريب التي تم اختيارها  $g(X, W)$  وعند التنبؤ بقيمة  $Z$  مع وجود دالة التقريب  $g(X, W)$  فإنه يوجد نوعين من الخطأ , الخطأ الأول: هو الخطأ العشوائي  $\varepsilon$  , والخطأ الثاني: هو خطأ التقريب و الذي يمثل الفرق بين القيمة الفعلية والقيمة المقدرة , والخطأ الثاني يكافئ الخطأ في نماذج الانحدار غير الخطية التي تحتوي على خطأ في التحديد وتوزيع الخطأ فيها يكون غير محدد, وذلك على عكس العديد من النماذج الإحصائية.

وتحديد المعالم لدالة التقريب  $g(X, W)$  تسمى ببناء الشبكة "network architecture", وهذه الدالة عبارة عن توليفة من الدوال الخطية وغير الخطية ..

وعلى ذلك فإن نموذج الشبكة العصبية المقرب من الممكن أن يكون في الصيغة التالية :

$$Z = g(X, W) + \varepsilon \quad (4-2)$$

حيث  $X$  تمثل مدخلات الشبكة أو طبقة المدخلات Input layer و  $y$  تمثل مخرجات الشبكة أو طبقة المخرجات output layer , وبافتراض وجود طبقة مخفية واحدة .

أي أنه يمكن كتابة النموذج الخطي كما يلي :

$$Y = Z \cdot W_2 + \varepsilon_2 \quad \dots\dots\dots (4-3)$$

$$W_2 = \begin{bmatrix} \beta_4 \\ \beta_5 \end{bmatrix} \quad : \quad \text{حيث :}$$

$$Z = X \cdot W_1 + \varepsilon_1 \quad \dots\dots\dots (4-4)$$

$$W_1 = [\beta_0 \quad \beta_1 \quad \beta_2 \quad \beta_3] \quad , \quad X = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \quad \text{حيث :}$$

. معالم النموذج (أوزان الشبكة) :  $\beta, W_1, W_2$

وبالتعويض عن  $Z$  في الدالة  $Y$  نحصل على :

$$Y = (X W_1 + \varepsilon_1) W_2 + \varepsilon_2$$

$$Y = X W_2 W_1 + \varepsilon_1 W_2 + \varepsilon_2 \quad \dots\dots\dots (4-5)$$

$$\beta = W_2 W_1 \quad , \quad \varepsilon = \varepsilon_1 W_2 + \varepsilon_2 \quad \text{وبوضع :}$$

نستنتج أن :

$$Y = X \beta + \varepsilon$$

وهذا هو الشكل النهائي لنموذج الانحدار المتعدد .

وبالتالي نكون قد حصلنا على النموذج العام للانحدار المتعدد .ومن الممكن إضافة أكثر من طبقة مخفية وسنحصل على نموذج مشابه للنموذج (4-1) السابق والهيكل البنائي للشبكة المستخدم في هذه الدراسة هو الشبكة متعددة الطبقات ذات التغذية الأمامية Multi-layer FeedForward Neural Network (MFNN) , حيث تستطيع الشبكة متعددة الطبقات ذات التغذية الأمامية حل العديد من المشاكل المعقدة التي لا تستطيع الشبكة ذات الطبقة الواحدة حلها , كما أن هيكل هذه الشبكة من أكثر هياكل الشبكات العصبية استخداما

## [٥] نتائج دراسة المحاكاة :

بعد حساب القيم التنبؤية للملاحظات المجهولة الثلاثة للمتغير التابع Y باستخدام الطريقة التقليدية للانحدار المتعدد , وتم قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث مقاييس متعلقة بالبقايا (MSE , MAD, MAEP) لكل طريقة بشكل مستقل للمقارنة وإبداء الملاحظات. علاوة على ذلك فان هذه المقارنة تتم وفقا لثلاثة معايير (حجم العينة , النموذج المحدد, أفق التنبؤ), وفيما يلي شرح لهذه المقاييس :

### أولا : مقارنة نتائج مقياس MSE :

فيما يلي جدول (١-٥) الذي يحتوي على نتائج مقياس MSE لكل من تنبؤات الطريقة التقليدية للانحدار المتعدد وتنبؤات الشبكات العصبية الاصطناعية مع النماذج الثمانية المحددة بأحجام عينات مختلفة , كذلك جدول (٢-٥) الذي يحتوي على نتائج مقياس MSE للثلاثة مشاهدات المجهولة للمتغير التابع :

models	Method	العينات الصغيرة				العينات الكبيرة				Average
		15	25	50	Average	100	200	300	Average	
1	NN	0.0375	0.7518	0.7581	0.5158	29.7712	2.42458	10.4518	14.21586	7.35958
	Reg	0.2054	2.6657	3.6370	2.1693	0.93256	1.04109	0.95670	0.976783	1.573075
2	NN	0.0375	0.7518	0.7581	0.5158	4.77711	22.7794	5.23747	10.93133	5.723563
	Reg	0.2759	4.5942	3.1274	2.6658	0.93256	1.04109	0.95670	0.976783	1.821308
3	NN	0.0375	0.7518	0.7581	0.5158	9.93697	4.48295	157.709	57.37631	28.94605
	Reg	0.1757	2.6222	2.9945	1.9308	0.93256	1.04109	0.9567	0.976783	1.453792
4	NN	0.0375	0.7518	0.7581	0.5158	3.97359	7.18054	2.52887	4.561	2.5384
	Reg	0.5324	2.5970	2.5161	1.88183	0.93256	1.04109	0.95670	0.976783	1.429308
5	NN	0.0375	0.7518	0.7581	0.5158	7.72396	9.09217	7.84231	8.21948	4.36764
	Reg	2.0749	2.7349	3.0731	2.6276	0.93256	1.04109	0.95670	0.976783	1.802208
6	NN	0.0375	0.7518	0.7581	0.5158	4.10889	4.37289	10.1743	6.218693	3.367247
	Reg	0.2171	5.0621	3.9730	3.0840	0.93256	1.04109	0.95670	0.976783	2.030425
7	NN	0.0375	0.7518	0.7581	0.5158	10.8982	34.8602	4.5087	16.7557	14.44578

models	Method	العينات الصغيرة				العينات الكبيرة				Average
		15	25	50	Average	100	200	300	Average	
	Reg	0.2436	3.1477	2.4293	1.9402	0.93256	1.04109	0.9567	0.976783	1.458492
8	NN	0.0375	0.7518	0.7581	0.5158	8.44069	6.21638	4.10206	6.253043	8.63575
	Reg	0.1865	3.3682	3.6346	2.3964	0.93256	1.04109	0.95670	0.976783	1.686608
Average	NN	0.0328	0.7518	0.7581	0.5158	9.95382	25.3193	11.4261	15.56643	8.0447
	Reg	0.4889	3.349	3.17312	2.337	0.93256	1.04109	0.9567	0.976783	1.6568

جدول (١-٥) قيم MSE لتنبؤات الطريقة التقليدية والشبكات العصبية

Pred. horizon			Zn+1	Zn+2	Zn+3	Average
sam.Size						
العينات الصغيرة	15	NN	0.0375	0.0193	0.0196	0.0737
		Reg	0.4883	0.1933	0.2982	0.9735
	25	NN	0.7518	0.4405	0.7737	1.0411
		Reg	3.349	2.6282	3.4182	4.0006
	50	NN	0.7581	0.7604	0.9642	0.5496
		Reg	3.1731	3.0951	2.9697	3.4547
Average	NN	0.4067	0.5858	0.5548	0.515789	
	Reg	1.9722	2.2287	2.8096	2.336833	
العينات الكبيرة	100	NN	8.2603	15.1734	6.4277	9.9538
		Reg	0.9403	0.9094	0.9478	0.9325
	200	NN	11.090095	9.86779	13.3205	11.42616
		Reg	1.038395	1.099869	0.985010	1.041091
	300	NN	24.82227	19.81792	31.31804	25.31941
		Reg	0.894123	1.039366	0.936637	0.956709
Average	NN	14.72422	14.95304	17.02208	15.5664	
	Reg	0.957606	1.016212	0.956482	0.97676	
Average	NN	7.56546	7.76942	8.78844	8.041107	
	Reg	1.464903	1.622456	1.883041	1.6568	

جدول (٢-٥) قيم MSE للملاحظات الثلاثة المجهولة

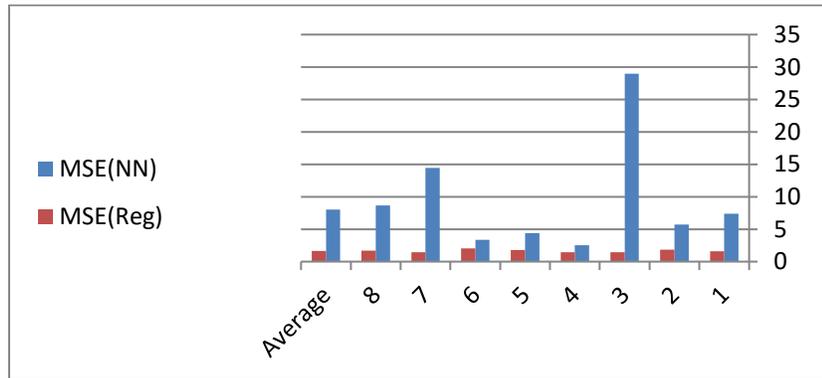
ومن خلال جدول (١-٥) , وجدول (٢-٥) نلاحظ ما يلي :

- **وفقا لحجم العينة :** نلاحظ من جدول (٢-٥) انه في حالة العينات الصغيرة : نجد أن طريقة الشبكات العصبية (NN) قد ثبت كفاءتها مقارنة بالطريقة التقليدية حيث أن متوسط قيم متوسط مربعات الاخطاء للشبكات العصبية كانت  $MSE(NN) = 0.515789$  وهي اقل من القيمة في الطريقة التقليدية تساوي  $MSE(RG) = 2.336833$ .
- وفي حالة العينات الكبيرة: نلاحظ تفوق الطريقة التقليدية مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان المتوسط للشبكات العصبية  $MSE(NN) = 15.5664$  وهي اكبر من المتوسط في حالة الطريقة التقليدية والتي كانت  $MSE(RG) = 0.97676$ .

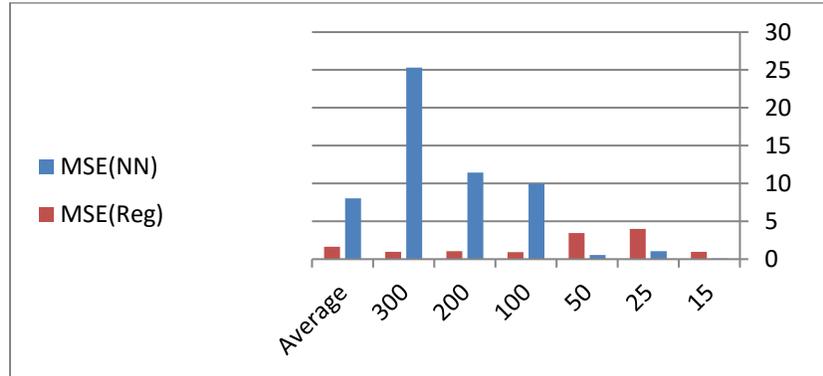
وعند النظر فى المتوسط العام لقيم MSE لكل من العينات الصغيرة والكبيرة معا نجد أن المتوسط للشبكات العصبية  $MSE(NN)= 8.041107$  كانت اكبر من الطريقة التقليدية والتي كانت  $MSE(NN)= 1.6568$  لذلك من الممكن القول بوجه عام الطريقة التقليدية كانت أكفاً من طريقة الشبكات العصبية الاصطناعية .

● **وفقا للنموذج المحدد :** نلاحظ من جدول ( ٥ - ١ ) انه فى حالة العينات الصغيرة : نجد أن متوسط مربعات الاخطاء لطريقة الشبكات العصبية (NN) عند كل النماذج الثمانية كانت أقل من قيمتها بالطريقة التقليدية (RG), لذلك يمكن القول ان طريقة الشبكات العصبية أفضل من الطريقة التقليدية للانحدار المتعدد عند كل النماذج الثمانية. وفى حالة العينات الكبيرة: نلاحظ تفوق الطريقة التقليدية مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان متوسط الشبكات العصبية اكبر من المتوسط فى حالة الطريقة التقليدية عند كل النماذج الثمانية.

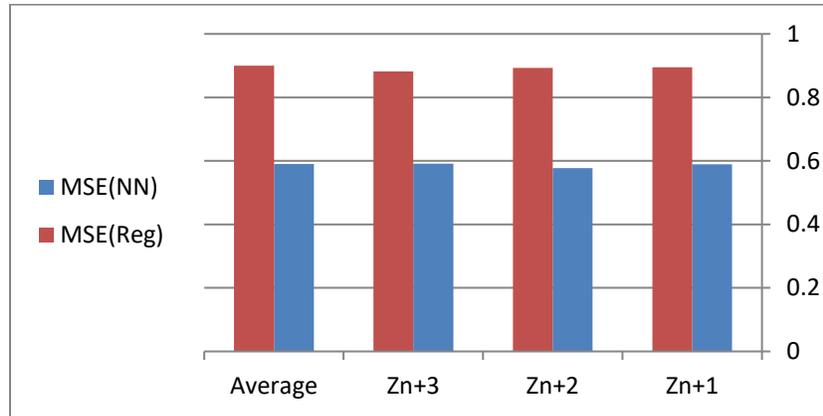
● **وفقا لأفق التنبؤ :** نلاحظ فى جدول ( ٥- ٢ ) فى حالة العينات الصغيرة : قيمة MSE لتنبؤات طريقة الشبكات العصبية للمشاهدات الثلاثة المجهولة للمتغير التابع متقاربة نسبيا فى حين أن القيم فى الطريقة التقليدية كبيرة مقارنة بالطريقة المقترحة , لذلك من الممكن القول أن أداء طريقة الشبكات العصبية هو الأفضل من الطريقة التقليدية للانحدار المتعدد فى حالة العينات الصغيرة . وفى حالة العينات الكبيرة: نلاحظ تفوق الطريقة التقليدية مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان متوسط الشبكات العصبية اكبر من المتوسط فى حالة الطريقة التقليدية للثلاثة مشاهدات المستقبلية, ويظهر ذلك واضحا من خلال طريقة رسم الأعمدة المزدوجة للطريقتين :



شكل ( ١-٥ ) MSE لتنبؤات الطريقة التقليدية والشبكات العصبية وفقا لنماذج الانحدار المتعدد



شكل ( ٢-٥ ) MSE للتنبؤ وأحجام العينات



شكل ( ٣-٥ ) التنبؤات الثلاثة المجهولة بالطريقتين

### ثانيا : مقارنة نتائج مقياس MAD :

فيما يلي جدول (٣-٥) يحتوى على نتائج مقياس MAD لكل من تنبؤات الطريقة التقليدية للانحدار المتعدد وتنبؤات الشبكات العصبية الاصطناعية مع النماذج الثمانية المحددة بأحجام عينات مختلفة , كذلك جدول (٤-٥) يحتوى على نتائج مقياس MAD للثلاثة مشاهدات المجهولة للمتغير التابع :

models	Method	العينات الصغيرة				العينات الكبيرة				Average
		15	25	50	Average	100	200	300	Average	
1	NN	0.4620	0.6064	0.5868	0.5517	1.02609	0.000452	0.92786	0.651467	0.6015835
	Reg	1.0927	1.2814	1.4475	1.2739	0.77464	0.000405	0.77589	0.516978	0.895439
2	NN	0.4620	0.6064	0.5868	0.5517	0.9038	0.000506	0.88637	0.596892	0.574296
	Reg	1.1104	1.4022	1.3848	0.9658	0.774643	0.000405	0.77589	0.516979	0.7413895
3	NN	0.4620	0.6064	0.5868	0.5517	0.93484	0.000476	1.26204	0.732452	0.642076

models	Method	العينات الصغيرة				العينات الكبيرة				Average
		15	25	50	Average	100	200	300	Average	
	Reg	1.2008	1.3170	1.3079	0.8819	0.77464	0.000405	0.77589	0.516978	0.699439
4	NN	0.4620	0.6064	0.5868	0.5517	0.89061	0.000493	0.8709	0.587334	0.569517
	Reg	1.3019	1.2807	1.2414	1.2747	0.774643	0.000405	0.77589	0.516979	0.8958395
5	NN	0.4620	0.6064	0.5868	0.5517	0.95622	0.000496	0.89728	0.617998	0.584849
	Reg	1.2545	1.3666	1.4058	1.3423	0.77464	0.000405	0.77589	0.516978	0.929639
6	NN	0.4620	0.6064	0.5868	0.5517	0.9030	0.000464	0.92294	0.608801	0.5802505
	Reg	1.1720	1.3795	1.4847	1.3454	0.7746	0.000405	0.775894	0.516966	0.931183
7	NN	0.4620	0.6064	0.5868	0.5517	0.97333	0.000549	0.89995	0.624609	0.5881545
	Reg	1.1534	1.3147	1.2126	1.2269	0.77464	0.000405	0.77589	0.516978	0.871939
8	NN	0.4620	0.6064	0.5868	0.5517	0.9726	0.000477	0.88405	0.619042	0.585371
	Reg	1.1014	1.4300	1.3028	1.2781	0.77464	0.000405	0.77589	0.516978	0.897539
Average	NN	0.4620	0.6064	0.5868	0.55173	0.945061	0.000489	0.943923	0.629825	0.590
	Reg	1.1509	1.3465	1.3484	1.2819	0.7746	0.0004	0.7758	0.516933	0.899454

جدول ( ٣-٥ ) قيم MAD لتنبؤات الطريقة التقليدية والشبكات العصبية

Pred. horizon			Zn+1	Zn+2	Zn+3	Average
sam.Size						
العينات الصغيرة	15	NN	0.4620	0.4177	0.4205	0.5477
		Reg	1.1509	1.0834	1.0905	1.2787
	25	NN	0.6064	0.5396	0.6003	0.6294
		Reg	1.3465	1.3089	1.3360	1.3946
	50	NN	0.5868	0.6213	0.6099	0.5291
		Reg	1.3484	1.3951	1.3025	1.3477
	Average	NN	0.551733	0.5262	0.54356	0.5405
		Reg	1.281933	1.262467	1.243	1.262467
العينات الكبيرة	100	NN	0.96736	0.93784	0.94507	0.95009
		Reg	0.774810	0.76055	0.7885	0.7746
	200	NN	0.0005073	0.000472	0.0004893	0.000489
		Reg	0.0004077	0.0004130	0.0003944	0.000405
	300	NN	0.910517	0.946783	0.974493	0.943931
		Reg	0.747135	0.807138	0.773411	0.775895
	Average	NN	0.626128	0.628365	0.640017	0.631504
		Reg	0.507451	0.5227	0.520768	0.51697
Average	NN	0.588931	0.577283	0.591792	0.590	
	Reg	0.894692	0.892584	0.881884	0.899454	

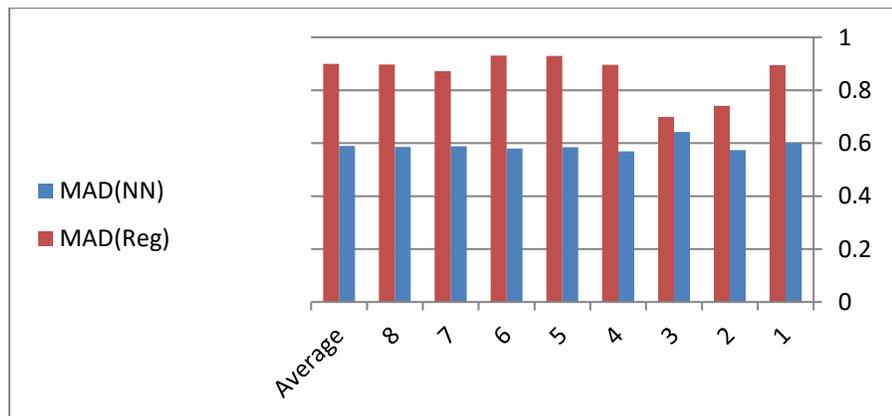
جدول ( ٤-٥ ) قيم MAD للملاحظات الثلاثة المجهولة

ومن خلال جدول (٣-٥) , و جدول (٤-٥) نلاحظ ما يلي :

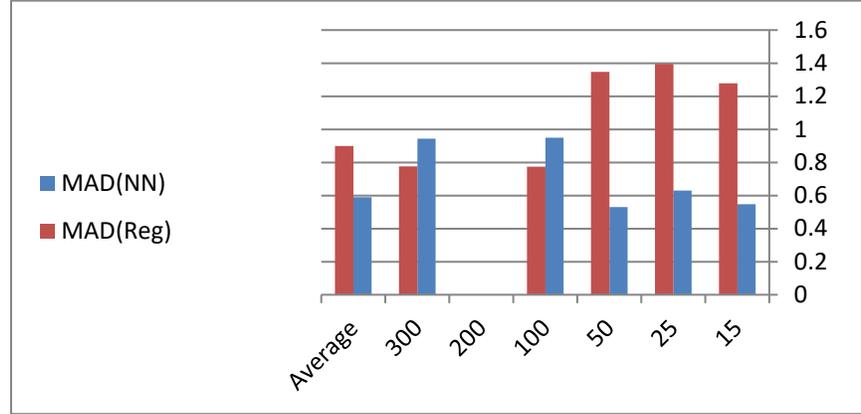
- وفقاً لحجم العينة : نلاحظ من جدول (٤-٥) انه في حالة العينات الصغيرة : نجد أن طريقة الشبكات العصبية (NN) قد ثبت كفاءتها مقارنة بالطريقة التقليدية حيث أن متوسط الخطأ

المطلق للشبكات العصبية كان  $MAD(NN) = 0.5405$  وهي اقل من القيمة في الطريقة التقليدية تساوي  $MAD(RG) = 1.262467$  .  
 وفي حالة العينات الكبيرة : نلاحظ تفوق الطريقة التقليدية مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان المتوسط للشبكات العصبية  $MAD(NN) = 0.631504$  وهي اكبر من المتوسط في حالة الطريقة التقليدية والتي كانت  $MAD(RG) = 0.51697$  .  
 وعند النظر في المتوسط العام لقيم  $MAD$  لكل من العينات الصغيرة والكبيرة معا نجد أن المتوسط للشبكات العصبية  $MAD(NN) = 0.590$  كانت اكبر من الطريقة التقليدية والتي كانت  $MAD(NN) = 0.899454$  لذلك من الممكن القول بوجه عام الطريقة التقليدية كانت أكفاً من طريقة الشبكات العصبية الاصطناعية .  
**وفقا للنموذج المحدد :** نلاحظ من جدول ( ٥ - ٣ ) انه في حالة العينات الصغيرة : نجد أن متوسط مربعات الاخطاء لطريقة الشبكات العصبية  $MAD(NN)$  عند كل النماذج الثمانية كانت أقل من قيمتها بالطريقة التقليدية  $MAD(NN)$  , لذلك يمكن القول ان طريقة الشبكات العصبية أفضل من الطريقة التقليدية للانحدار المتعدد عند كل النماذج الثمانية.  
 وفي حالة العينات الكبيرة: نلاحظ تفوق الطريقة التقليدية للانحدار المتعدد مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان متوسط الشبكات العصبية  $MAD(NN)$  اكبر من المتوسط في حالة الطريقة التقليدية  $MAD(RG)$  عند كل النماذج الثمانية.

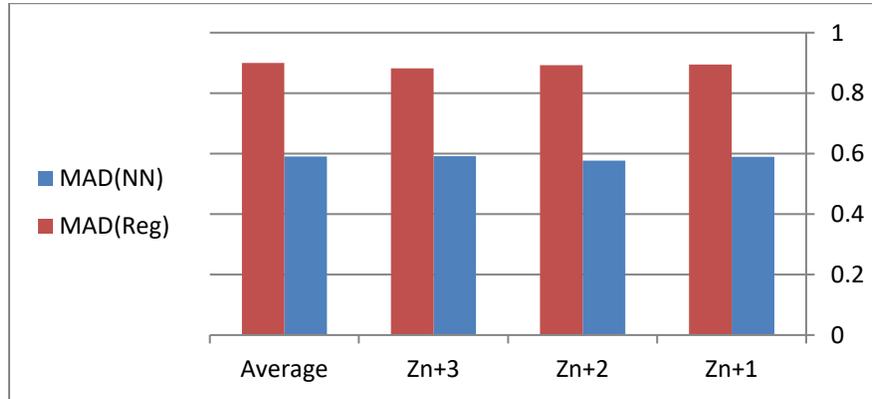
- **وفقا لأفق التنبؤ :** نلاحظ في جدول ( ٥ - ٤ ) في حالة العينات الصغيرة : قيمة  $MAD$  لتنبؤات طريقة الشبكات العصبية للملاحظات الثلاثة المجهولة للمتغير التابع متقاربة نسبيا في حين أن القيم في الطريقة التقليدية كبيرة مقارنة بالطريقة المقترحة , لذلك من الممكن القول أن أداء طريقة الشبكات العصبية هو الأفضل من الطريقة التقليدية للانحدار المتعدد في حالة العينات الصغيرة .  
 وفي حالة العينات الكبيرة: نلاحظ تفوق الطريقة التقليدية مقارنة بطريقة الشبكات العصبية الاصطناعية حيث كان متوسط الشبكات العصبية  $MAD(NN)$  اكبر من المتوسط في حالة الطريقة التقليدية للثلاثة مشاهدات المستقبلية, ويظهر ذلك واضحا من خلال طريقة رسم الأعمدة المزدوجة للطريقتين :



شكل ( ٤ - ٥ )  $MAD$  لتنبؤات الطريقة التقليدية والشبكات العصبية وفقا لنماذج الانحدار المتعدد



شكل ( ٥-٥ ) MAD للتنبؤ وأحجام العينات



شكل ( ٦-٥ ) التنبؤات الثلاثة المجهولة بالطريقتين

### ثالثا : مقارنة نتائج مقياس MAEP :

فيما يلي جدول (٥-٥) يحتوى على نتائج مقياس متوسط نسبة الأخطاء المطلقة الأقل لتنبؤات الشبكات العصبية الاصطناعية إلى الطريقة التقليدية للانحدار المتعدد MAEP مع النماذج الثمانية المحددة بأحجام عينات مختلفة , كذلك جدول(٦-٥) يحتوى على نتائج مقياس MAEP للثلاثة مشاهدات المجهولة للمتغير التابع :

models	العينات الصغيرة				العينات الكبيرة				Average
	15	25	50	Average	100	200	300	Average	
1	1.4145	1.5263	1.5084	1.48306	0.8691	0.9595	0.8791	0.902567	1.19281
2	1.4500	1.5543	1.5126	1.50563	0.9029	0.9029	0.8939	0.8999	1.202767
3	1.4361	1.5263	1.4620	1.4748	0.8779	0.9236	0.8587	0.886733	1.180767
4	1.4233	1.5231	1.5199	1.488767	0.8873	0.8921	0.8796	0.886333	1.18755
5	1.4321	1.4763	1.5105	1.472967	0.8993	0.9887	0.8761	0.921367	1.197167
6	1.4145	1.5242	1.4631	1.467267	0.8535	0.9150	0.9035	0.890667	1.178967
7	1.4361	1.5349	1.5707	1.5139	0.8382	0.9059	0.8656	0.8699	1.1919
8	1.3990	1.5316	1.5532	1.4946	0.8450	0.9218	0.8421	0.869633	1.82117
Average	1.4257	1.52463	1.51255	1.487625	0.8716	0.87483	0.926188	0.8908875	1.191

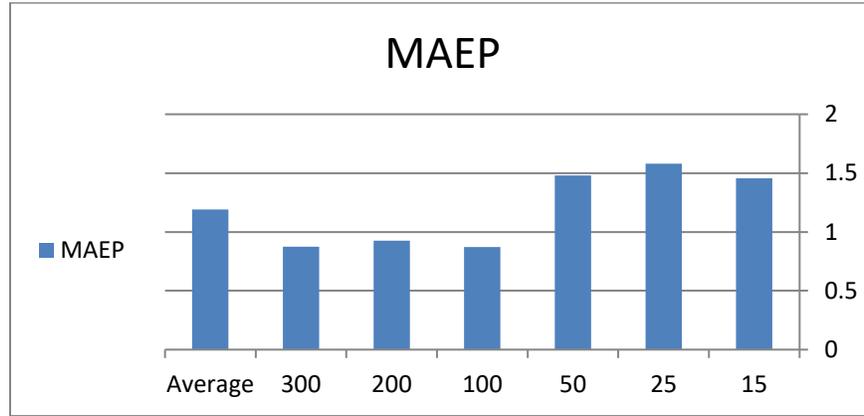
جدول ( ٥-٥ ) قيم MAEP للطريقتين مع أحجام العينات المختلفة

Pred. horizon		Z <sub>n+1</sub>	Z <sub>n+2</sub>	Z <sub>n+3</sub>	Average
sam.Size					
العينات الصغيرة	15	1.4256	1.4118	1.4118	1.4559
	25	1.5245	1.4806	1.5145	1.5802
	50	1.5341	1.5588	1.5649	1.4802
	Average	1.4947	1.4837	1.49707	1.49184
العينات الكبيرة	100	0.8952	0.8535	0.8658	0.8714
	200	0.9068	0.9361	0.9347	0.92577
	300	0.8378	0.8591	0.9295	0.8747
	Average	0.8799	0.8829	0.91	0.8909
Average		1.1873	1.18332	1.2035	1.191

جدول ( ٦-٥ ) قيم MAEP للمشاهدات الثلاثة المجهولة

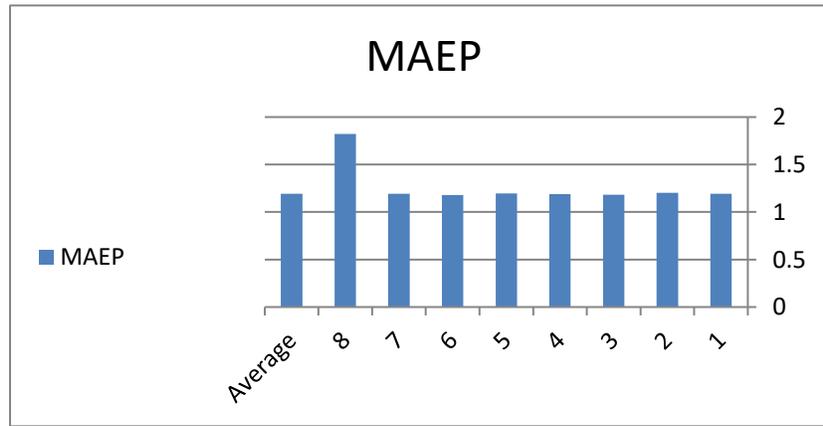
ومن خلال جدول ( ٥-٥ ) , ( ٦-٥ ) نلاحظ ما يلي :

- **وفقا لحجم العينة :** نلاحظ من جدول (٥-٥) أن قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى الطريقة التقليدية (MAEP) تقل بزيادة حجم العينة حيث أنها كانت تمثل 142.56 % عند حجم العينة 15 , ثم أصبحت 87.47 % عند حجم العينة 300 , وهذا ما يدل على أن أداء طريقة الشبكات العصبية يكون أفضل من أداء الطريقة التقليدية إذا كان حجم العينة صغيرا , بمعنى آخر يمكن القول أن التحسن في أداء الطريقة التقليدية يزيد تدريجيا بزيادة حجم العينة بينما أداء طريقة الشبكات العصبية يقل بزيادة حجم العينة. وبوجه عام فإن نسبة الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى الطريقة التقليدية MAEP في المتوسط كانت 119.1 % أي أن أداء طريقة الشبكات العصبية الاصطناعية تفوق أداء الطريقة التقليدية بنسبة 19.1 % , ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٧-٥) :



شكل ( ٧-٥ ) قيم MAEP وفقا لحجم العينة

- **وفقا للنموذج المحدد :** نجد أن نسبة عدد الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى الطريقة التقليدية للانحدار المتعدد والتي في جدول (٥-٥) , كانت أعلى قيمة لها مع النموذج الثامن و كانت تساوى 182.1% , بينما كانت أقل قيمة مع النموذج السادس حيث كانت تساوى 117.8% , ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٥-٨) :

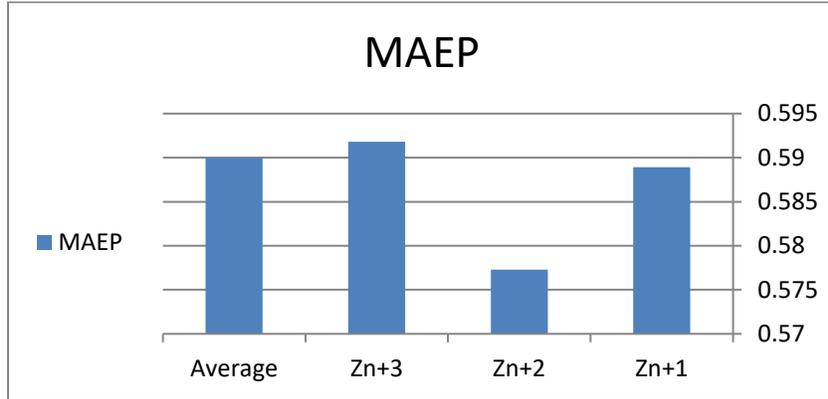


شكل ( ٨-٥ ) قيم MAEP وفقا لنماذج الانحدار المتعدد

- **وفقا لأفق التنبؤ :** نلاحظ في جدول (٦-٥) أن في حالة العينات الصغيرة : قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى الطريقة التقليدية MAEP للملاحظات الثلاثة المجهولة للمتغير التابع كبيرة بمعنى أنها تزيد عن نسبة 100% , حيث كانت النسبة MAEP=149.1% وذلك يدل على تفوق أداء طريقة الشبكات العصبية على الطريقة التقليدية .

في حالة العينات الكبيرة : كانت قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى الطريقة التقليدية MAEP للملاحظات الثلاثة المجهولة للمتغير التابع صغيرة

بمعنى أنها تقل عن نسبة 100%، حيث كانت النسبة  $MAEP=91\%$  وذلك يدل على تفوق أداء الطريقة التقليدية للانحدار المتعدد على طريقة الشبكات العصبية الاصطناعية .  
ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٥-٩) :



شكل (٥-٩) قيم MAEP للملاحظات الثلاثة المجهولة

مما سبق يتضح لنا مدى القدرة العالية للشبكة العصبية الاصطناعية على التنبؤ بقيم المتغير التابع للانحدار المتعدد المعطاة وذلك بطريقة آلية في حالة العينات الصغيرة، حيث أظهرت النتائج من دراسة عينة التي تم توليدها أن متوسط مربعات أخطاء التنبؤ، متوسط القيمة المطلقة لخطأ التنبؤ، متوسط المسافة بين قيمة التنبؤ والقيمة الفعلية أقل من نظيرتها في الطريقة التقليدية، وذلك بالنسبة لكل العينات وكل النماذج وللملاحظات الثلاثة المجهولة للمتغير التابع خاصة في حالة العينات الصغيرة . وبناء على ذلك يمكن القول بصلاحية الطريقة المقترحة للتنبؤ بالانحدار المتعدد باستخدام أحد وأهم فروع الذكاء الاصطناعي وهو طريقة الشبكات العصبية الاصطناعية في حالة العينات الصغيرة .

## [٦] الخلاصة

يقوم هذا البحث على حل مشكلة انه عندما تكون العينات صغيرة فان الفرض الأول من فروض المربعات الصغرى (عنصر الخطأ يتبع التوزيع الطبيعي) قد لا يتوفر وبذلك قد تكون تقديراتها غير دقيقة . ولتجنب تلك المشاكل لزم البحث عن طريقة جديدة للتنبؤ بخلاف الطرق الإحصائية التقليدية التي تعمل في ظل فروض المربعات الصغرى وأيضا تعتمد على دالة الإمكان في تقدير معالمها، وهذه الطريقة هي الشبكات العصبية الاصطناعية، حيث تمتاز هذه الطريقة بأنها تعمل بصورة آلية لاختيار نموذج مناسب يوضح كيفية اعتماد المخرجات على المدخلات وتعمل بكفاءة في حالة دراسة العينات الصغيرة .

لكي يتم مقارنة الطريقة الجديدة مع الطريقة التقليدية للانحدار المتعدد تم توليد عينة بواقع 500 عينة لكل نموذج من 8 نماذج مختارة مع أحجام عينات صغيرة (50, 25, 15) وكبيرة (100, 300, 200) وتمت المقارنة بين تنبؤات المشاهدات في الحالتين وقيمها الحقيقية لقياس دقة التنبؤات ومقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء الطريقة التقليدية، ولانجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات الطريقة التقليدية والشبكات العصبية مع المقارنة بين الطريقتين تم استخدام حزم برامج ماتلاب MATLAB . وتم استخدام برنامج تم تصميمه (انظر الشوادي، آخرون ٢٠١٨) عن طريق صندوق ادوات لبرنامج ماتلاب MATLAB TOOLBOX ضمن حزم

برامج ماتلاب MATLAB (أنظر الملحق المرفق مع البحث) طريقة المقترحة للتنبؤ بنماذج الانحدار المتعدد.

وقد أوضحت نتائج البحث القدرة العالية للطريقة المقترحة للتنبؤ لنماذج الانحدار المتعدد باستخدام أحد طرق الذكاء الاصطناعي - وهي طريقة الشبكات العصبية - على التنبؤ بالقيم المستقبلية المعطاة وذلك بطريقة آلية , حيث أظهرت النتائج من دراسة 16000 عينة والتي تم توليدها أن متوسط مربعات أخطاء التنبؤ MSE, ومتوسط القيمة المطلقة لخطأ التنبؤ MAD , وكذلك متوسط النسبة MAEP أفضل من نظيرتها في أسلوب بوكس-جينكنز, وذلك كمتوسط عام بالنسبة لكل العينات وكل النماذج وللمشاهدات المستقبلية الثلاث الأولى خاصة في حالة العينات الصغيرة . وبناء على ذلك يمكن القول بصلاحية الطريقة المقترحة للتنبؤ بالقيم المستقبلية لنماذج الانحدار المتعدد فى حالة حجم العينات الصغيرة .

## [٧] المراجع

### أولا: المراجع العربية

- (١) دربال, أمينة, (٢٠١٤), "محاولة التنبؤ بمؤشرات الأسواق المالية العربية باستعمال النماذج القياسية دراسة حالة, مؤشر سوق دبي المالي", رسالة دكتوراه في العلوم الاقتصادية تخصص, نقود, بنوك ومالية, وزارة التعليم العالي والبحث العلمي (الجزائر).
- (٢) جعفر محمد حاجي , محمد عبد الهادي المحميد , (١٩٩٩م). "الشبكات العصبية : التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي " , المجلة العربية للعلوم الإدارية , مجلد ٦ , عدد ١ , يناير (١٩٩٩) , ص ١٧ - ٣٥ .
- (٣) جمال الشوافي, عبدالوهاب حجاج (٢٠١٦) , "الذكاء الاصطناعي وتحليل السلاسل الزمنية فى حالة العينات الصغيرة" مجلة الدراسات والبحوث التجارية - جامعة بنها .
- (٤) جمال الشوافي, محمد العجمى , محمود وهبه (٢٠١٨), "استخدام الذكاء الاصطناعي فى تحليل الانحدار المتعدد", رسالة ماجستير غير منشورة , كلية التجارة , جامعة الأزهر .
- (٥) ميشيل نجينفيتسكى , (٢٠٠٤ م) . " الذكاء الصناعى دليل النظم الذكية " تعريب سرور على إبراهيم سرور , دار المريخ للنشر , الرياض , المملكة العربية السعودية, ص ٢٥٢ .

### ثانيا: المراجع الأجنبية :

- 1) **Arminger, G. and Enache, D. (1996)** , "Statistical Models and Artificial Neural Networks". In: Bock, H.H. and Polasek, W. (Eds.): *Data Analysis and Information Systems*, Vol. 7, Springer Verlag, Heidelberg, 243-260..
- 2) **Chen, C., Davis, R.A., Brockwell, P.J., and Bai, Z.D.(1993)**. Order determination for autoregressive processes using resampling methods, *Statist. Sinica* 3, 481--500.
- 3) **Cryer, J. D. and Ledolter, J., (1981)**, 'Small sample properties of the parameters of the maximum likelihood estimator in the first order moving average model', *Biometrika*, 68 .691-4
- 4) **Cybenko, g.(1989)**. "Approximation by superposition of sigmoidal functions " , *Mathematics of control , Signals and Systems*, 2, 303-314 .
- 5) **Alshawadfi, Gamal A.(2003)**

" A comparison between neural network and Box-Jenkins Forecasting Techniques With Application to Real data " King Saud University, King Fahd National Library Cataloging-in-Publication Data .

**6) Demuth H. & Beale M. (1998) .**

" Neural Networks Toolbox :Users Guide, Version 3.0",The Math Works inc Natick, MA .

**7) Dent. W & A-S. Min . A Monte Carlo study of autoregressive integrated moving average processes. Journal of Econometrics 7(1978): 23–55.**

**8) Hijazi, D. (2007),**

"Predicting the stock market method of using artificial neural cells." , M.A. Thesis Department of Statistics, Faculty of Economics and Political Science, Cairo University, Cairo, Egypt.

**9) Pesaran, M.H. & Timberman, A., 2003.**

"Small Sample Properties of Forecasts from Autoregressive Models under Structural Breaks," Cambridge Working Papers in Economics 0331, Faculty of Economics,

**10) Turban, E., Aronson J. and Liang T. (2005).**

"Decision Support Systems and Intelligent Systems ". 7th edition Prentice Hall

**11) Zurada ,J. M. (1992) .**

"Artificial Neural Systems".1st ed. St. Paul, MN., West Publishing Company .

## ملحق (A)

برنامج Matlab لمحاكاة الطريقة المقترحة بالذكاء الاصطناعي لتحليل الانحدار المتعدد ومقارنتها بالطريقة التقليدية

```
% Here a feedforward network is trained and regression performed on its targets and
outputs.
% 1... .. INITIALIZATION ... ..
nn=50;m=500;mu=0;sigma=1;h=3;n1=32;n2=8;n3=4;
b0=10;b1=0.6;b2=0.4;b3=1/b2;b4=b2+b3;b5=b2*b3;
b6=sqrt(b3);b7=1/b3;b8=log(b2);
%a1 = [10 0.6 0.4 b3]';
E=zeros(nn,3*m);X=zeros(nn,4*m);Y=zeros(nn,m);
sn11=zeros(2*n2,h); sn12=zeros(2*n2,h);sn13=zeros(2*n2,h) ;
sn21=zeros(2*n2,h);sn22=zeros(2*n2,h) ;
sn23=zeros(2*n2,h);sb1=zeros(n2,h) ;
sb2=zeros(n2,h);sb3=zeros(n2,h);ss1=zeros(n2,h); ss2=zeros(n2,h);
ss3=zeros(n2,h);sn31=zeros(2*n2,h);
sn32=zeros(2*n2,h);
a = [10 10 10 10 0 0 0 0 0 0 0 0 0 0 0 10 10 10 10 10 10 10 10
10 10 10 10 10 10 10 10;
.3 .3 .5 .5 .5 .5 .7 .5 0 0 0 0 .5 .5 .7 .3 .3 .5 .7 .5 .3 .3 .5 .5 .3 .5 .7 .9
.3 .3 .5 .7;
0 0 0 0 .3 .5 .7 .9 .3 .5 .7 .9 .3 .3 .5 .7 .3 .5 .5 .7 0 0 0 0 .5 .7 .5
.3 0 0 0 0;
0 0 0 0 0 0 0 0 .55 .7 .85 .95 .15 .15 .35 .21 .09 .25 .35 .35 .3 .3 .5 .7 .5
.3 .5 .7 .3 .3 .5 .5];
% 2... .. Data Generation ... ..
for j =1 :n1
E =normrnd(mu,sigma,nn,3*m);
for i=1: m
k = 3 * i - 2 ;
x1 = ones(nn,1);
x2 = 10 + E(:, k);
x3=10 * E(:,k+1) ;
x4= x2 .*x3;
x5 = 0.01*E(:, k+2);
x=[x1 x2 x3.*x4 1./x3];
y = x * a(:, j) + E(:, k+2);
if i==1
X=x;Y=y;
else
```

```
X=[X x]; Y=[Y y];
end
end
end
% 3... .. comparison and testing phase ... ..
% Load data ; identify x1 , x2 ,x3 .... as predictors, y as the response:
% Compute regression coefficients for a linear model with an interaction term:
ij=0
for i= 1:n1
j1=fix((i-1)/n3)+1;
for j=1: m
j0 =4*j - 3;
for n = [nn nn-25 nn-35]
xx=X(1:n, j0:j0+3); yy=Y(1:n, j);
xx2=xx(n-h+1:n , :);yy2 =yy(n-h+1:n);
net = fitnet(2,'trainlm');
net.trainParam.showWindow =0 ;
[net,tr]= train(net, xx',yy');
y02=sim(net ,xx');
y1=[y02(n-h+1:n)]';
[aa b cc2] = regress(yy , xx);
ytrue = yy(n-h+1:n);
c1 = y1 - ytrue;
c2 = cc2(n-h+1:n);
s01 = abs(c1); s02 = (s01).^2;
r01 = abs(c2) ; r02 = (r01).^2;
if n ==50
for k= 1:h
sn11((2*j1-1),k) = sn11((2*j1-1),k)+s01(k);
sn11((2*j1 ),k) = sn11((2*j1 ),k)+r01(k);
sn12((2*j1-1),k) = sn12((2*j1-1),k)+s02(k);
sn12((2*j1 ),k) = sn12((2*j1 ),k)+r02(k);
if r01(k) < s01(k);sb1(j1,k)=sb1(j1,k)+1;else ss1(j1,k)=ss1(j1,k)+1;end
end
elseif n == 25
for k= 1:h
sn21((2*j1-1),k) = sn21((2*j1-1),k)+s01(k);
sn21((2*j1 ),k) = sn21((2*j1 ),k)+r01(k);
sn22((2*j1-1),k) = sn22((2*j1-1),k)+s02(k);
sn22((2*j1 ),k) = sn22((2*j1 ),k)+r02(k);
if r01(k)< s01(k);sb2(j1,k)=sb2(j1,k)+1;else ss2(j1,k)=ss2(j1,k)+1;end
end
else
for k= 1:h
```

```
sn31((2*j1-1),k) = sn31((2*j1-1),k)+s01(k);
sn31((2*j1 ),k) = sn31((2*j1 ),k)+r01(k);
sn32((2*j1-1),k) = sn32((2*j1-1),k)+s02(k);
sn32((2*j1 ),k) = sn32((2*j1 ),k)+r02(k);
if r01(k)< s01(k);sb3(j1,k)=sb3(j1,k)+1;else ss3(j1,k)=ss3(j1,k)+1;end
end
end
end
ij = ij +1
end
end
%3...Results... ..
disp('..... RESULTS..... ')
disp('MAE RESULTS ')
sn11 = sn11/(n3 *m)
Mab1=
[sn11,(mean(sn11))';mean(sn11),mean(mean(sn11))]
sn21 = sn21/(n3 *m)
Mab2=
[sn21,(mean(sn12))';mean(sn12),mean(mean(sn12))]
sn31 = sn31/(n3 *m)
Mab3=
[sn31,(mean(sn13))';mean(sn13),mean(mean(sn13))]
disp('MSE RESULTS ')
sn12 = sn12/(n3 *m)
Mabs1=
[sn12,(mean(sn12))';mean(sn12),mean(mean(sn12))]
sn22 = sn22/(n3 *m)
Mabs2=
[sn22,(mean(sn22))';mean(sn22),mean(mean(sn22))]
sn32 = sn32/(n3 *m)
Mabs3=
[sn32,(mean(sn32))';mean(sn32),mean(mean(sn32))]
disp('NNF RATIOS RESULTS ')
ss1
ss2
ss3
Mnnf1=[ss1,(mean(ss1))';mean(ss1),mean(mean(ss1))]
Mnnf2=[ss2,(mean(ss2))';mean(ss2),mean(mean(ss2))]
Mnnf3=[ss3,(mean(ss3))';mean(ss3),mean(mean(ss3))]
disp('Regression RATIOS RESULTS ')
sb1
sb2
sb3
```

```
Mreg1=[sb1,(mean(sb1'))';mean(sb1),mean(mean(sb1))]  
Mreg2=[sb2,(mean(sb2'))';mean(sb2),mean(mean(sb2))]  
Mreg3=[sb3,(mean(sb3'))';mean(sb3),mean(mean(sb3))]  
disp('MAP RATIOS RESULTS ' )  
MAP1=[Mnnf1 ./Mreg1]  
MAP2=[Mnnf2 ./Mreg2]  
MAP3=[Mnnf3 ./Mreg3]
```