

الشبكة العصبية: التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي

جعفر محمد حاجي

محمد عبد الهادي المحميد

جامعة الكويت - دولة الكويت

الملخص

هناك عدة نماذج معروفة للتنبؤ بأسعار الصرف ومن أهمها: نماذج تحليل الانحدار بأنواعها الخطية وغير الخطية ونماذج السلاسل الزمنية، ومن أشهرها نماذج «بوكس وجينكنز» (Box and Jenkins) للانحدار الذاتي والمتوسطات المتحركة. أسلوب الشبكات العصبية، أسلوب حديث جرب في تطبيقات متعددة، من أهمها تطبيقات التحديد وتعرّف الأنماط. والسلاسل الزمنية عبارة عن علاقة نمطية ترتبط بمتغير أو أكثر. لذا فإن هذه الدراسة تعالج موضوع تحديد العلاقة النمطية التي تحكم سعر صرف الدينار الكويتي مقابل الدولار الأمريكي وذلك بغرض استخدامها في التنبؤ بأسعار الصرف المستقبلية باستخدام أسلوب الشبكات العصبية ومن ثم مقارنتها مع نماذج «بوكس وجينكنز» للانحدار الذاتي والمتوسطات المتحركة.

مصطلحات علمية

الشبكات العصبية، نماذج السلاسل الزمنية، التنبؤ بأسعار صرف العملات، نماذج «بوكس وجينكنز».

والمتوسطات المتحركة. غير أن النماذج السابقة كلها تعتمد على عدة شروط يجب توافرها. كما أن قدرتها في التنبؤ بالقيم المستقبلية لأسعار الصرف لا تكون حاسمة أو دقيقة بنسبة عالية في الغالب.

أسلوب الشبكات العصبية أسلوب حديث نسبياً، يحاكي عملية جمع المعلومات واستغلالها وتكثيفها في العقل البشري بهدف الوصول إلى قرار ما. وقد أثبت هذا الأسلوب نجاحات كثيرة في عدة مجالات منها تعرّف نمطية العلاقة (Pattern Recognition). كما استخدمت الشبكات العصبية في عدة مجالات منها تعرّف خط اليد

التنبؤ بالقيم المستقبلية لظاهرة ما تعد من الحاجات المهمة للكثير من مجالات الدراسات والبحوث العلمية. وهناك خطان للتنبؤ، أولهما باستخدام النماذج السببية (Causal Model) حيث تعتمد القيم المستقبلية لأحد المتغيرات على معرفة قيم أخرى من متغيرات شارحة له من خلال نماذج انحدار خطية (Linear) أو غير خطية (Non-Linear). أما الأسلوب الآخر فهو الاعتماد على النماذج الأحادية مثل نماذج السلاسل الزمنية، حيث يتم استخدام قيم سابقة من نفس المتغير في التنبؤ بالقيم المستقبلية له. ومن أشهر هذه النماذج نماذج الانحدار الذاتي

تم تسلّم البحث في ديسمبر ١٩٩٧، وأُجيز للنشر في مارس ١٩٩٨.

البحث ممول من قبل جامعة الكويت تحت رقم CQ001.

الباحث بدراسة المشكلة من الناحية النظرية بهدف تعرّف العلاقة بين المتغيرات المدروسة وتحديدّها قبل البدء في بناء النماذج الإحصائية لها، كما أن ذلك يتطلب من الباحث القيام بدراسة التوزيعات الاحتمالية للمتغيرات وتحديد الفروض الخاصة ببناء النماذج الأولية لها، الأمر الذي لا تحتاجه طريقة الشبكات العصبية.

والميزة الثانية لأسلوب الشبكات العصبية التي تميزه عن أسلوب تحليل الانحدار بصورته التقليدية هي أن أسلوب الشبكات العصبية يحتاج عينات أصغر نسبياً في اختبار مصداقية النماذج (Collins and Clark, 1993). فمن المعروف أن النماذج الإحصائية التقليدية تحتاج من الناحية العملية إلى ما بين ٣٠٪ إلى ٥٠٪ من إجمالي البيانات المتاحة لاختبار صلاحية النماذج المقدرة. بخلاف أسلوب الشبكات العصبية والذي غالباً ما يستخدم حوالي ١٠٪ من البيانات المتاحة للغرض نفسه مما يبين كفاءة استخدام هذا الأسلوب.

أما الميزة الثالثة فهي أن أسلوب الشبكات العصبية يمكن استخدامه مصدراً خارجياً لتقييم قدرة الأساليب الإحصائية التقليدية وفعاليتها في تقدير النماذج واختبارها، حيث من الممكن أن نطبق الأسلوبين معاً على البيانات نفسها، وقياس قدرة كل من الأسلوبين بمقارنته بالأسلوب الآخر.

كما ذكرنا سابقاً فإن أسلوب الشبكات العصبية اشتهر بقدرته على اكتشاف العلاقات النمطية. والنمذجة الإحصائية تُعدُّ (Statistical Modeling) من أكثر العلاقات النمطية استخداماً في التطبيقات التجارية. وتقسم النماذج الإحصائية إلى نوعين أساسيين هما: نماذج السلاسل الزمنية (Time Series Models) والنماذج القطاعية أو السببية (Causal Models). ونماذج السلاسل الزمنية تُعدُّ من النماذج الأحادية (Unimodels) التي تستخدم القيم السابقة للمتغير نفسه وقد تستخدمها لمتغيرات أخرى في التنبؤ بالقيم المستقبلية للمتغير محل الدراسة. أما النماذج السببية فإنها تستخدم عدداً من

للأشخاص (Fukushima, 1983) وتعرّف الكلمات المكتوبة وتحويلها إلى عبارة منطوقة وبالعكس (Sejnowski and Rosenberg, 1986) وكذلك في مجالات استخدامات النظم الخبيرة (Bounds et al, 1989; Schwartz, 1988).

وقد ظهرت مؤخراً عدة استخدامات للشبكات العصبية في مجالات التطبيقات التجارية، منها مثلاً استخدام هذه الطريقة في التنبؤ بأسعار صرف العملات (Weigend et al, 1991)، والتنبؤ بأسعار الأسهم والسندات في البورصات العالمية (Wong, 1991; Abhyankar et al, 1997)، وكذلك في دراسة المخاطرة في منح القروض الشخصية والتجارية من قبل البنوك والمؤسسات المالية (Wideow et al, 1994).

يمتاز أسلوب الشبكات العصبية بالقدرة العالية على نمذجة العلاقة غير الخطية المعقدة، وبخلاف الطرق الإحصائية التقليدية فإن هذا الأسلوب يستطيع التغلب وبسهولة على حالات فقد البيانات وحالات عدم اكتمال هذه البيانات أو عدم دقتها. كما يستطيع هذا الأسلوب تعرّف النمطية واكتشاف العلاقات الخفية بين المتغيرات من خلال البيانات المتاحة واستخدامها في بناء القرارات وترشيدها. كما أن لأسلوب الشبكات العصبية مميزات أخرى على الأسلوب الإحصائي التقليدي في بناء نماذج الانحدار. أول هذه المميزات هو عدم حاجة هذا الأسلوب إلى اقتراح أو استخدام أية نماذج افتراضية مسبقة لتمثيل البيانات، بمعنى أننا لا نحتاج إلى تحديد أية فروض مسبقة عن هذه العلاقات. فإذا كانت هناك علاقة رياضية ما بين المتغير التابع (Dependent Variable) والمتغيرات المستقلة (Independent Variables) فإن أسلوب الشبكات العصبية سوف يحدد هذه العلاقات من خلال عملية تعلم خاصة به، تمر في عدة مراحل من التنقيح والترشيح الذي يتناسب في النهاية مع هذه البيانات وعلاقة المتغيرات فيما بينها. ومن ناحية أخرى فإن الأسلوب الإحصائي التقليدي يلزم

الكويتي مقابل الدولار الأمريكي، ثم تهيئتها للتحليل باستخدام الشبكات العصبية، حيث يعرض مرحلة فصل البيانات ثم مرحلة تحويلها، ويلي ذلك عرض لمقياس خطأ التقدير للنماذج المستخدمة في الدراسة، ثم يعرض النموذج النهائي لمنظومة الشبكة العصبية المستخدمة.

القسم الرابع ويعرض التحليل ونتائج هذه الدراسة بدءاً من أسلوب اختيار عدد عناصر المعالجة في الشريحة المخفية، ثم اختيار أنسب النماذج الملائمة لسلسلة سعر صرف الدينار الكويتي مقابل الدولار الأمريكي. ثم يعرض نتائج مخرجات الشبكة المستخدمة ومقارنتها مع النماذج الإحصائية التقليدية لـ «بوكس وجينكنز». ويعرض القسم الخامس الخاتمة والتوصيات.

الشبكات العصبية

مقدمة

تعد الشبكات العصبية أحد حقول الذكاء الاصطناعي الذي شكل تطوراً ملحوظاً في طريقة ميكنة التفكير الإنساني. فكرة الشبكات العصبية تتمحور حول محاكاة المخ باستخدام الحاسب الآلي، ولعل الفضل في تطور هذا الحقل يعود بدرجة كبيرة إلى الدراسات العديدة التي تمت في حقل المعالجة العصبية Neural Processing والذي يدرس النشاط العصبي في مخ الإنسان. هذه الدراسات تعمل على محاولة محاكاة العقل البشري في طريقة حله للمسائل التي تواجهه وذلك من خلال اتباع عملية التعليم الذاتية التي تحدث في العقل والتي يتم فيها الاستفادة من الخبرات التي مرت عليه في السابق في سبيل الوصول إلى نتائج أفضل في المستقبل.

يرجع تاريخ الشبكات العصبية إلى عام ١٩٤٣ حينما نشر McCulloch and Pitts (1943) مقالة شرح فيها أسس العمليات التي تتم في الوحدات العصبية. في هذه المقالة أوضح كيف

المتغيرات المستقلة في تفسير العلاقة مع متغير تابع هو موضع اهتمام الدراسة، ومن ثم استخدام هذه النماذج في التنبؤ بقيمة المتغير التابع. والنماذج السببية تأخذ عدة أشكال منها الخطي البسيط والخطي المتعدد وغير الخطي. أما نماذج السلاسل الزمنية فهي في الغالب نماذج غير خطية، ومن أشهرها نماذج «بوكس وجينكنز» (Box and Jenkins, 1976) والمعروفة بنماذج الانحدار الذاتي والمتوسطات المتحركة (Autoregressive and Moving Average Models). وكلا النموذجين يتطلبان توفر عدد من الشروط الإحصائية قبل البدء في التقدير، لأن عدم توفر ذلك قد يؤدي إلى نتائج غير صحيحة. أما أسلوب الشبكات العصبية فلا يتطلب أية شروط مسبقة في تقديره للنماذج. وقد أثبتت الاستخدامات العملية لهذا الأسلوب أن نتائجه تماثل أو تزيد من حيث القدرة والدقة على النماذج الإحصائية سابقة الذكر.

تهدف هذه الدراسة إلى استخدام أسلوب الشبكات العصبية في التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي بناء على المعلومات المتوفرة عن أسعار الصرف السابقة للعلتين، ومقارنة أداء هذا الأسلوب مع أساليب التنبؤ الإحصائية باستخدام السلاسل الزمنية (لبوكس وجينكنز) التي قدمتها دراسة المحميد (١٩٩٦). كما تهدف هذه الدراسة إلى تقديم أسلوب الشبكات العصبية للقارئ العربي وللمكتبة العربية كإحدى الأدوات الحديثة في مجال دراسات التنبؤ.

تتكون هذه الدراسة من الأقسام التالية: القسم الثاني ويعرض صورة عامة عن أسلوب الشبكات العصبية، بدءاً من تعريف الشبكة العصبية ومكوناتها والطرق المختلفة لتكوين منظوماتها، ثم يعرض طريقة عمل الشبكة العصبية بدءاً من مرحلة التدريب ثم مرحلة التعليم، والطرق المختلفة لكل منهما. القسم الثالث يعرض منهجية الدراسة ابتداءً من مرحلة جمع بيانات السلسلة الزمنية لأسعار صرف الدينار

ويضيف (1994) Bernard Widrow سبباً ثالثاً لهذا الظهور وهو يتمثل في القدرة الفائقة التي أصبحت تتمتع بها أجهزة الحاسب.

كان لاكتشاف طريقة «التدريب التراجعي التعديلي» Back-Propagation Algorithm في التعلم الذاتي داخل الوحدات العصبية من قبل (Rumelhart et al, 1986a, 1986b) من أبرز التطورات التي عملت على تسريع نمو حقل الشبكات العصبية. ومنذ ظهور طريقة «التدريب التراجعي التعديلي» ظهرت عدة طرق في التعلم الذاتي إلا أن طريقة «التدريب التراجعي التعديلي» ظلت حتى وقتنا الحالي الطريقة المثلى في عملية التعلم الذاتية في تطبيقات الشبكات العصبية.


مكونات الشبكة

تتكون الشبكات العصبية من عدة عناصر معالجة أو تنفيذ [Processing Element (PE)] لها القدرة على إجراء العمليات الحسابية المعقدة، ويوضح شكل ١ صورة مبسطة لعنصر معالجة.

أن من هذه الوحدات يمكن أن يكون لها نفس تركيب التعبيرات المنطقية المنتهية Finite Logical Expressions. وفي عام ١٩٤٩ قام Donald Hebb (1949) بوصف لطريقة التعلم الذاتية التي تتم في هذه الوحدات. لكن أبرز محطات تطور الشبكات العصبية كان في عام ١٩٥٨ عندما تم تطوير أول نظام للشبكات العصبية باسم Perceptorn من قبل Frank Rosenblatt (1958) وذلك في جامعة «كورنيل»، وكان ذلك أول نظام في الشبكات العصبية وكان قادراً على تصنيف النماذج الرياضية (Geometric Patterns). لكن استخدام الشبكات العصبية في تطبيقات حقيقية لم يتم إلا في عام ١٩٦٠ عندما تم تطوير نظام (Adaptive Linear) (Bertrand Widrow, 1960)، وهذا النظام كان يعمل على التخلص من الصدى الحاصل في خطوط الهاتف. شهد حقل الشبكات العصبية فترة ركود طويلة استمرت من نهاية الستينيات حتى أواخر الثمانينيات حين عاد حقل الشبكات العصبية للبروز بقوة من جديد، وحسب قول (1990) Levine فإن هناك سببين لهذا الظهور الجديد. السبب الأول يعود إلى التطور الكبير الذي شهدته نظريات الشبكات العصبية وكذلك في حقل الأحياء العصبية Neurobiology، في حين أن السبب الثاني يعود إلى فشل الذكاء الاصطناعي بصورته التقليدية في حل المشاكل الفنية المعقدة في التطبيقات الصناعية،

شكل ١

نموذج لعنصر معالجة



(Limit Transfer Function)، ودالة تقلب على شكل S (Sigmoid Function) (مثل دالة جيب الزاوية وجيب تمام الزاوية وظل الزاوية). تنقل المعلومات الناتجة بعد ذلك في الغالب كمخرجات لعنصر المعالجة من خلال مسار المخرجات (Output Path). ومسار مخرجات أي عنصر معالجة يُعدُّ مسار مدخلات لعناصر معالجات أخرى أو أنه الحصلة النهائية للشبكة (Final Result).

تتكون الشبكات العصبية من عدة عناصر معالجة (PE) ترتبط فيما بينها بعدة طرق مختلفة لتشكل منظومة (Topology) من الشبكات العصبية. ومن أمثلة هذه المنظومات: منظومة الشبكات العصبية ذات التغذية الأمامية المتتابعة (Feed-Forward Neural Networks FFNN)، ومنظومة الشبكات العصبية ذات التغذية الذاتية الدائرية (Fully Recurrent Neural Networks) ومنظومة الشبكات العصبية ذات الذاكرة المترابطة ثنائية الاتجاه (Bidirectional Associative Memory (BAM) Networks) وشبكات «بولتزمن» العصبية (Boltzman Networks).

ومنظومة الشبكات العصبية ذات التغذية الأمامية المتتابعة (انظر شكل ٢) تُعدُّ من أكثر

تتصل عناصر المعالجة مع بعضها بصورة تعتمد فيها على بناء الشبكة نفسها، حيث يعمل كل عنصر معالجة بصورة متزامنة ومستقلة من العناصر الأخرى. لكل عنصر معالجة مسار إدخال واحد أو أكثر (Input Paths)، تنحصر مهمتها في نقل المعلومات الخارجية إلى عنصر المعالجة الذي يقوم بدوره بتكثيفها في الغالب من خلال عملية الجمع البسيطة (Simple Summation) التالية:

$$Y = \sum_{i=1}^n W_i X_i$$

حيث W_i : الأوزان النسبية لعقد الاتصال ما بين عناصر المعالجة.

X_i : مدخلات عنصر المعالجة.


يلي مرحلة التكتيف السابقة مرحلة تحويل هذه المعلومات بواسطة دالة تفعيلية (Activation Function) تعرف بدالة التحويل كذلك (Transfer Function):

$$\text{Activation} = f(Y)$$

هناك العديد من الدوال التفعيلية المستخدمة، منها مثلاً: دالة التحويل الخطي (Linear Transfer Function)، ودالة الحاجز الصلب التحويلية (Hard

شكل ٢

نموذج لمنظومة الشبكات العصبية ذات التغذية الأمامية المتتابعة



(Classes). 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 ومقاربة داخل كل مجموعة.

أما الطريقة الأخيرة، فتقوم عملية التدعيم فيها على أساس الخلط بين طريقة التدريب الإشرافية وطريقة التدريب غير الإشرافية. حيث لا نفصح للشبكة العصبية عن القيم الحقيقية للمخرجات كما هي الحال في التدريب غير الإشرافي، ولكننا نشير للشبكة بصحة نتائجها المتحصلة أو خطأها كما في طريقة التدريب الإشرافية.

التعلم

تتميز الشبكات العصبية عن النظم الخبيرة التقليدية (Expert Systems) بقدرتها على خلق قواعدها الخاصة ومنهجيتها في التعلم، وذلك بالأمثلة التي تقدم لها على شكل بيانات، حيث إننا لا نحتاج مع هذه الشبكات إلى تزويدها بالمعلومات المطلوبة بصورة صريحة ومباشرة. بل إن أسلوب الشبكات العصبية في التعلم يعتمد أساساً كما أشرنا على تعديل الأوزان النسبية لعقد الاتصال ما بين عناصر المعالجة التي تكون بمجموعها الشبكة العصبية لخلق التجانس الأفضل بين المدخلات والمخرجات.

تبدأ المرحلة الأولى في تدريب الشبكة العصبية باختيار عشوائي للقيم الابتدائية للأوزان النسبية بين عقد الاتصال للشبكة، أو من خلال تطبيق بعض الأساليب الخاصة في اختيار هذه القيم الابتدائية. وفي المرحلة التالية تقوم الشبكة بإجراء عدة عمليات حسابية على العينة المدخلة وذلك من خلال خطوتين متتاليتين أولاًهما أمامية (Forward) والأخرى تراجعية (Backward). في الخطوة الأمامية يقوم النظام بحساب مخرجات الشبكة للبيانات المدخلة ومن ثم مقارنة هذه المخرجات مع المخرجات المرغوبة أو المستهدفة من الشبكة، ومن

المنظومات استخداماً. حيث تحتوي الشبكة من هذا النوع على شريحتين على الأقل، شريحة المدخلات (Input Layer) وشريحة المخرجات (Output Layer). وتتكون كل شريحة منها من عنصر معالجة واحدة على الأقل، كما تتواجد في الكثير من الأحيان شرائح مخفية (Hidden Layers) بين شريحة المدخلات وشريحة المخرجات. وتنتقل العمليات الحسابية في اتجاه واحد إلى الأمام من شريحة المدخلات إلى شريحة المخرجات عبر الشرائح المخفية.

التدريب

لتدريب الشبكة العصبية على اكتشاف العلاقات النمطية في البيانات تتبع طريقة واحدة من بين ثلاث طرق معروفة هي: طريقة التدريب الإشرافية (Supervised) أو طريقة التدريب غير الإشرافية (Unsupervised) أو طريقة التدريب بإعادة التدعيم (Reinforcement). والطريقة الأولى هي الأكثر انتشاراً في تدريب الشبكات العصبية. ففي التدريب الإشرافي تُجمع عينات من البيانات تحتوي على قيم للمتغيرات المدخلة وقيم المتغيرات المخرجة، مع عدِّ قيم المتغيرات المخرجة هي القيم المستهدفة تُعرَّفها من خلال نتائج الشبكة العصبية بعد تزويدها بقيم المتغيرات المدخلة. تقوم الشبكة بمقارنة النتائج التي تقدِّرها للمتغيرات الخارجة لكل عينة مدخلة بالقيم الفعلية لهذه المتغيرات، وبناء على ذلك تقوم الشبكة بإجراء التعديلات على الأوزان النسبية لعقد الاتصال بهدف تقليل الأخطاء في النتائج. وتعاد عملية التدريب تلك عدة مرات إلى أن تصل نتائج الشبكة إلى الأداء المقبول.

تتشابه خطوات طريقة التدريب غير الإشرافية مع خطوات طريقة التدريب 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

$$Y = \sum_{i=1}^n W_i X_i$$

$$U = f(Y) = \frac{1}{1 + e^{-Y}}$$

$$f'(Y) = U(1 - U)$$

ثانياً: للحصول على أقل خطأ ممكن من الشبكة نقوم باستخدام خوارزمية الانحدار أو الميل (Gradient) حيث يتم من خلالها حساب الميل السالب (Negative Gradient) لخطأ الشبكة للعيبة المستخدمة وذلك من خلال العلاقة:

$$\delta = -\frac{\partial \varepsilon}{\partial Y}$$

ثالثاً: نقوم باستخدام الخطوات التراجعية لتقييم المشتقات التفاضلية الناتجة من شريحة المخرجات للشبكة، ثم يتم تعديل الأوزان النسبية لعقد الاتصال لعناصر المعالجة. يلي ذلك عملية حساب للمشتقات التفاضلية للشريحة السابقة مباشرة وتعديل الأوزان النسبية لعقد الاتصال لعناصر المعالجة لها وفقاً للمعادلات التالية:

إذا كانت o_i وحدة إخراج:

$$\delta_i = (t_i - o_i)f'(Y_i)$$

لعناصر المعالجة الأخرى:

$$\delta_i = \left(\sum_{m:m>i} W_{m,i} \delta_m \right) f'(Y_i)$$

$$W_{i,j}^* = W_{i,j} + \rho \delta_i o_j$$

حيث ρ : معدل التعلم.

ونستمر على هذا المنوال وصولاً إلى شريحة المدخلات للشبكة التي بدأنا منها مرحلة التعلم.

ولهذا السبب عرفت هذه الطريقة «بالتدريب التراجعي التعديلي» (Back-Propagation Algorithm)، مع أنها من حيث المبدأ تتفق مع طريقة خوارزمية الميل.

ثم حساب الخطأ الناشئ عن مقارنة ذلك. أما في الخطوة التراجعية فتقوم الشبكة بتعديل الأوزان النسبية لعقد الاتصال بين عناصر المعالجة المكونة للشبكة بهدف تصغير مقدار الخطأ الكلي الناشئ. وتقوم الشبكة بتكرار الخطوات السابقة عدة مرات لجميع عينات البيانات المدخلة لهذه الشبكة. وتسمى مرحلة التقديم الواحدة التي تضم جميع الخطوات الأمامية والخطوات التراجعية لجميع العينات بالدورة (Epoch). وتكرر الشبكة بعدة دورات إلى أن تصل إلى أقل مجموع مربعات للخطأ الناشئ ما بين المخرجات النهائية للشبكة والمخرجات المستهدفة.

$$\varepsilon = \frac{1}{n} \sum_n \sum_i (t_i - o_i)^2$$

حيث n : عدد عينات التدريب.

i : عدد عناصر المعالجة في شريحة المخرجات.

t : المخرجات المستهدفة.

o : مخرجات الشبكة، وهي حصىلة لمخرجات عناصر المعالجة في شريحة المخرجات (Y_i).

تُعدُّ الطريقة التراجعية في التدريب أكثر الطرق التدريبية استخداماً وتعرف بطريقة «التدريب التراجعي التعديلي» (Back-Propagation Algorithm). وهذه الطريقة قدمت لأول مرة في عام ١٩٧٤ من قبل (Paul Werbos, 1974) في أطروحة الدكتوراه التي قدمت لجامعة «هارفرد». ولم تستخدم لفترة طويلة إلى أن تم اكتشافها وتقديمها للمرة الثانية في عام ١٩٨٥ من قبل (Parker, 1985) وفي عام ١٩٨٦ من قبل كل من (Rumelhart et al, 1986a, 1986b) و (Le Cun, 1986). وإعادة الاكتشاف هذه أسهمت بصورة كبيرة في انتشار أسلوب الشبكات العصبية ونموها، ويمكن تلخيص أسلوب هذه الطريقة بالآتي:

أولاً: تبدأ عملية التعلم بخطوات أمامية (Forward) وذلك بحساب مخرجات الشبكة مبنية على المعلومات المزود لها عن طريق عينة من البيانات المدخلة إليها باستخدام المعادلات التالية:

إحدى الطرق المقترحة لزيادة سرعة التعلم لهذه الطريقة هي جعل التغير في الأوزان النسبية السابقة من خلال دالة رياضية. ويتحقق ذلك بإضافة عجلة (Momentum) للأوزان النسبية السابقة:

$$W_{i,j}^* = W_{i,j} + \alpha \Delta W_{i,j} + \rho \delta_{i,j}$$

$$\Delta W_{i,j} = W_{i,j}^* - W_{i,j}$$

منهجية الدراسة

تجميع البيانات


تم تهيئة بيانات الدراسة من واقع البيانات المنشورة يومياً من قبل بنك الكويت المركزي عن سعر صرف الدينار الكويتي مقابل الدولار الأمريكي وذلك بدءاً من ٢٦ مارس ١٩٩١ (الأسبوع الثالث عشر من سنة ١٩٩١) وحتى ١٠ مارس ١٩٩٥ (الأسبوع الثالث عشر من سنة ١٩٩٥) وذلك بتحويل البيانات اليومية إلى بيانات أسبوعية بأخذ متوسط سعر صرف الأسبوع حيث إن الأسعار الأسبوعية أكثر استقراراً من الأسعار اليومية وأقل عرضة للتقلبات الفجائية أو العشوائية. لذا فإن سلسلة البيانات المستخدمة تضم ٢٠٨ مشاهدة (عدد الأسابيع المشمولة في الدراسة). وشكل ٣ يوضح الخط البياني لسلسلة أسعار صرف الدينار الكويتي مقابل الدولار الأمريكي.

معدل التعلم ρ (Learning Rate) يحدد بدقة مقدار التعديل في الأوزان النسبية لعقد الاتصال. وقيمة المقدار ρ تُعد مهمة وحساسة في طريقة التعلم، حيث أن القيم الكبيرة منها تؤدي إلى تعديلات كبيرة في الأوزان النسبية وبالتالي إلى معدلات أسرع في التقارب (Convergence). بمعنى آخر، أن الشبكة سوف تصل إلى نهاية مرحلة التعلم بسرعة أكبر. ولكن القيم الكبيرة جداً قد تؤدي إلى قفزات كبيرة وعشوائية في طريقة التعلم مما قد يؤدي إلى حالة من عدم التقارب (Non Convergence). ومن ناحية أخرى فإن القيم الصغيرة لهذا المقدار قد تؤدي إلى بطء الشبكة في التعلم والوصول إلى التقارب. لذلك فإن قيمة ρ تختلف باختلاف التطبيق المستخدم للشبكة، ويتم تحديدها تجريبياً في كل مرة، وذلك باستخدام قيم مختلفة لها في عمليات التعلم لكل تطبيق إلى أن نصل إلى أفضل قيمة تجريبية لها تحقق أفضل نتائج ممكنة لمخرجات الشبكة..

طريقة التعلم التراجعية التعديلية تمتاز بسهولة استخدامها، غير أنها بطيئة التعلم في الشبكات الكبيرة التي تحتوي على عدد كبير من عناصر المعالجة المخفية وخاصة في التطبيقات ذات الاستخدامات العملية. وقد ركزت الأبحاث مؤخراً على زيادة سرعة تعلم هذه الطريقة. ومن

شكل ٣

الخط البياني لسلسلة سعر صرف الدينار الكويتي مقابل الدولار الأمريكي



(١٩٩٦) ذلك بإلغاء المشاهدات من ١ إلى ١٠٠ واستخدم القيم الأخرى المستقرة في السلسلة لبناء نموذج بوكس وجينكنز (Box and Jenkins, 1976). وهو ما سوف نستخدمه في هذه الدراسة في مقارنة نتائج الشبكات العصبية به.

تهيئة البيانات

تم تهيئة البيانات المجمعة على مرحلتين: مرحلة الفصل (Separation) ومرحلة التحويل (Scaling).

مرحلة الفصل: وهي مرحلة خلق مجموعة البيانات الخاصة بمرحلة التعليم والاختبار، وهي مرحلة مهمة لتحديد فعالية النماذج الإحصائية ونماذج الشبكات العصبية من خلال تزويد كل من النموذجين ببيانات مدخلة، ومن ثم مراقبة ما إذا كانت مخرجات كل نموذج تعطي النتائج المتوقعة. ويتحقق ذلك بتقسيم البيانات المتاحة إلى مجموعتين: مجموعة التعلم ومجموعة الاختبار. وإذا كانت النتائج التحصيلية من اختبار النموذجين غير مرضية فإننا نحتاج في هذه الحالة إلى إعادة التعلم مرة أخرى، مع إجراء بعض التعديلات في النموذجين والأخذ بعين الاعتبار عدم استخدام مجموعة الاختبار في مجموعة التعلم، وبمعنى آخر أنه يجب علينا تثبيت المجموعتين وعدم الخلط أو الدمج فيما بينهما في

وقد تم استخدام سلسلة الفرق الأول:


$$DDOLKD_t = DOLKD_t - DOLKD_{t-1}; t = 2, 3, \dots, 208$$

حيث إن شكل السلسلة الزمنية الأصلية يشير إلى أنها سلسلة غير ساكنة (Non Stationary). بينما الشكل البياني لسلسلة الفرق الأول والموضح بشكل ٤ الذي يشير إلى أنها سلسلة تتذبذب حول الصفر مما يعني أنها سلسلة تتمتع بالسكون (Stationary).

يلاحظ من الشكل ٤ بأن السلسلة الزمنية كانت غير مستقرة في بدايتها (من المشاهدات رقم ١ إلى رقم ١٠٠)، حيث اختلف التشتت بين جزأي السلسلة الأول والثاني، فكان كبيرا في الجزء الأول ومعتدلا في الجزء الثاني، وقد قام المحميد (١٩٩٦) في دراسته باختبار ذلك باستخدام اختبار Goldfield-Quandt الذي أظهر معنوية الاختلاف في التشتت بين جزأي السلسلة. وقد استخدم بعض التحويلات المثبتة للتشتت خاصة التحويلات اللوغاريتمية والتحويلات التي تستخدم الجذور التربيعية. إلا أنه خلص إلى أن جميع هذه التحويلات والتحويلات المشابهة المثبتة للتشتت في السلاسل الزمنية تكون فعالة إذا كان التشتت يتغير بصورة نمطية ومنظمة (زيادة أو نقصا) مع مستوى السلسلة المدروسة، ولا تكون مجدية في الحالة التي نحن بصدها مع سلسلة سعر صرف الدينار مقابل الدولار. وقد عالج المحميد

شكل ٤

الخط البياني لسلسلة الفرق الأول



لسلسلة سعر الصرف V إلى قيم قابلة للاستخدام والمعالجة عبر الشبكة العصبية، بحيث تنحصر مخرجات عناصر كل معالجة ما بين ٠,٩ كحد أقصى و٠,١ كحد أدنى:

$$N = \frac{N_{\max} - N_{\min}}{V_{\max} - V_{\min}} (V - V_{\min}) + N_{\min}$$

حيث:

$N_{\max}$: الحد الأقصى لعنصر المعالجة

$N_{\min}$: الحد الأدنى لعنصر المعالجة

$V_{\max}$: الحد الأقصى لقيم المشاهدات

$V_{\min}$: الحد الأدنى لقيم المشاهدات

إضافة إلى ذلك فقد تم استخدام دالة تحويلية أخرى لتحويل مخرجات الشبكة إلى القيم الأصلية للسلسلة مرة أخرى:

$$V = \frac{(N - N_{\min})(V_{\max} - V_{\min})}{N_{\max} - N_{\min}} + V_{\min}$$

مقياس الخطأ

تقاس كفاءة النماذج الرياضية بمدى قدرتها على تمثيل الواقع وقدرتها على التنبؤ بالقيم المستقبلية، تُعد النماذج الأقل خطأً في ذلك نماذج أفضل. أما مقارنة النماذج الجيدة فتتم على أساس مقدار الخطأ الكلي لها في التنبؤ. وهناك العديد من الوسائل المستخدمة في قياس الخطأ، من أشهرها الجذر التربيعي لمتوسط مربع الانحراف (Root Mean Square Error - RMS) الذي يحسب من العلاقة:

$$RMS = \sqrt{\frac{\sum_{i=1}^n \text{Error}_i^2}{\# \text{of Observations}}}$$

حيث:

$$\text{Error} = (\text{actual value} - \text{predicted value})^2$$

وقد تم استخدام هذا المقياس في مقارنة عدة نماذج للشبكات العصبية تم تطبيقها على سلسلة أسعار صرف الدينار الكويتي مقابل الدولار الأمريكي لاختيار أفضل شبكة عصبية، ومن ثم مقارنة أداء هذه الشبكة

مرحلة التعلم. وتتلخص أهداف هذه المرحلة في أنها تزودنا بمؤشرات غير متحيزة عن طريقة عمل كل من النماذج الإحصائية ونماذج الشبكات العصبية في الحياة العملية بصورة عامة.

قسمت مجموعة البيانات الأسبوعية المتوفرة عن سعر صرف الدينار الكويتي مقابل الدولار الأمريكي إلى مجموعتين، الأولى وتضم المشاهدات ١٧٩ الأولى من السلسلة واستخدمت لتدريب الشبكة العصبية. أما المجموعة الثانية فتحتوي على المشاهدات الأخيرة من السلسلة المتوفرة وهي المشاهدات من ١٨٠ إلى ٢٠٨ حيث استخدمت لأغراض اختبار فعالية الشبكة في التنبؤ بقيم السلسلة المدروسة.

مرحلة التحويل: تستخدم في غالبية نماذج الشبكات العصبية دوال رياضية لتحويل البيانات أو العينات المخرجة من هذه الشبكات، حيث تنحصر القيم المحولة بين الصفر والواحد الصحيح، وذلك بغرض استخدام بعض الدوال المنطقية (Logistic Function) عليها كدوال تفعيلية في عناصر المعالجة كما سبقت الإشارة إليه. حيث إن مخرجات هذه الدوال التفعيلية هي بدورها قيم محصورة بين الصفر والواحد الصحيح. ومن ناحية أخرى فإن الدوال المنطقية لا تصل عملياً إلى قيمها النظرية القصوى أو الدنيا أي إلى الصفر أو الواحد الصحيح، بل إنها تنحصر في الغالب بين ٠,١ كقيمة دنيا و٠,٩ كقيمة قصوى، وللأسباب السابقة تم استخدام دالة تحويلية على سلسلة أسعار صرف الدينار الكويتي مقابل الدولار الأمريكي لتحويلها إلى قيم تنسجم مع مخرجات الدوال التفعيلية المستخدمة في عناصر المعالجة للشبكة.

إن البيانات المدخلة إلى الشبكة ليس لها أية قيود نظرية من حيث القيمة، ولا تحتاج بالتالي إلى تحويل أو تعديل، غير أننا مع ذلك قد طبقنا عليها دالة تحويلية بغرض خلق استقرار (Stability) أكثر في الشبكة العصبية.

وفي هذه الدراسة تم استخدام دالة تحويلية خطية بسيطة لتحويل القيم المشاهدات

بالنموذج الإحصائي المقدّر باستخدام نماذج الانحدار الذاتي المتعددة والمتوسّطات المتحركة (Autoregressive Moving Average Models) وعلى نفس السلسلة الزمنية والمنشور في دراسة المحميد (١٩٩٦).

النموذج النهائي المستخدم للشبكة العصبية


في هذه الدراسة قمنا باستخدام منظومة الشبكة العصبية ذات التغذية الأمامية FFNN، وذلك لشيوع استخدامها من ناحية، واتباعها لطريقة التدريب الإشرافية التي تتناسب بصورة أكبر مع هذا النوع من التطبيقات من ناحية أخرى. تتكون الشبكة المستخدمة من ثلاث شرائح هي: شريحة المدخلات والشريحة المخفية وشريحة المخرجات وتتكون كل شريحة من عدة عناصر معالجة يتم تحديدها بناء على التطبيقات المستخدمة في كل حالة. وبما أننا في صدد دراسة ترمي إلى تعرّف النمطية في أسعار الصرف فإن المدخلات تكون عبارة عن قيم سابقة من أسعار الصرف للعملة نفسها أو أسعار صرف لعملة أخرى مؤثرة، لذا فإن عدد عناصر المعالجة المستخدمة في شريحة المدخلات قد يختلف بناء على عدد القيم المستخدمة. وقد تم تجريب عدة منظومات من الشبكات العصبية تختلف في عدد عناصر المعالجة في شريحة المدخلات، بدءاً من عنصر معالجة واحد يستخدم القيمة السابقة لسلسلة سعر الصرف، وحتى المنظومة التي احتوت على ٣٢ عنصر معالجة استخدمت الـ ٣٢ قيمة السابقة

للسلسلة الزمنية. وتم اختيار النموذج الذي يحتوي على أربع فترات سابقة هي ١ و ٥ و ١٨ و ٣٢ كأفضل نموذج من حيث قلة عدد عناصر المعالجة في الشريحة المدخلات، إضافة إلى قصر وقت تعلم وتعرف الشبكة على النمطية في السلسلة الزمنية. كما أن مقياس الخطأ فيه كان قريباً جداً (بل يكاد ينعدم الاختلاف) بالمقارنة مع باقي النماذج المجربة. كما أنه النموذج نفسه الذي تم استخدامه في دراسة المحميد (١٩٩٦) وبذلك نستطيع المقارنة بين الأسلوبين باستخدام السلسلة الزمنية نفسها والمدخلات نفسها. لذا تم تغذية الشبكة بالقيم السابقة لسلسلة الفرق الأول لسعر صرف الدينار الكويتي مقابل الدولار الأمريكي ($DDOLKD_{t-1}$) في عنصر المعالجة الأولى والقيمة السابقة بخمس فترات ($DDOLKD_{t-5}$) في عنصر المعالجة الثانية والقيمة السابقة بثمانية عشر فترة ($DDOLKD_{t-18}$) والقيمة السابقة باثنتين وثلاثين فترة ($DDOLKD_{t-32}$) في عناصر المعالجة الأخرى، انظر الشكل ٥.

كما تم استخدام عدة عقد اتصال مخفية في المنظومة المستخدمة بدءاً من عقدتين وحتى ستة عقد لاختيار أنسب الأعداد في الشريحة المخفية. أما شريحة المخرجات، التي تعتمد في عددها على المخرجات المطلوبة من النموذج، فهي القيمة المتنبأ بها لسعر الصرف، لذا فإننا نحتاج إلى قيمة واحدة وبالتالي فقد احتوت شريحة المخرجات للمنظومة المستخدمة على عقدة اتصال واحدة فقط.

شكل ٥

النموذج النهائي لمدخلات الشبكة العصبية ومخرجاتها مع عدد مختلف من عناصر المعالجة المخفية



التحليل والنتائج

تحديد العناصر المخفية

المنظومات أن أقربها من حيث القدرة التنبئية بالقيم الـ ٢٩ الأخيرة الفعلية لسلسلة سعر صرف الدينار الكويتي مقابل الدولار الأمريكي، هي منظومة الشبكات العصبية ذات ثلاثة عناصر معالجة في الشريحة المخفية وبمعدل تعلم ٠,٥. وبعجلة قدرها ٠,٩. وقد كانت القيم المتنبأ بها قريبة جدا من القيم الفعلية في جميع المنظومات المستخدمة، وهذا ما يبرزه جدول ١ كما توضحه الرسوميات في الشكلين ٦ و٧.

لاختيار أنسب عدد لعناصر المعالجة في الشريحة المخفية تم تجريب أكثر من اختيار بدءا من عنصري معالجة وحتى ستة عناصر كما أشرنا سابقا. إضافة إلى استخدام عدة قيم لمعدل التعلم والعجلة مع كل منظومة من المنظومات التي تم استخدامها، وذلك باستخدام برنامج أعدناه بلغة الباسكال Pascal. وقد أظهرت نتائج تحليل هذه


جدول ١

المخرجات النهائية للشبكات العصبية لعدة منظومات تختلف في عدد العناصر في الشريحة المخفية (تمثيل القيم الفعلية والقيم المتنبأ بها القيم الـ ٢٩ الأخيرة من السلسلة)

القيم الفعلية	عنصرا معالجة	ثلاثة عناصر معالجة	أربعة عناصر معالجة	خمس عناصر معالجة	ستة عناصر معالجة
٢٩٧,١٤	٢٩٨,٠٥	٢٩٨,٠٥	٢٩٨,٠٥	٢٩٨,٠٥	٢٩٧,١٤
٢٩٨,١٣	٢٩٧,٤٤	٢٩٧,٤٤	٢٩٧,٤٤	٢٩٧,٤٤	٢٩٨,١٣
٢٩٧,٨١	٢٩٨,٠٧	٢٩٨,٠٧	٢٩٨,٠٧	٢٩٨,٠٧	٢٩٧,٨١
٢٩٧,٣٥	٢٩٧,٥٠	٢٩٧,٥٠	٢٩٧,٥٠	٢٩٧,٥٠	٢٩٧,٣٥
٢٩٧,٣٠	٢٩٧,٦٩	٢٩٧,٤٤	٢٩٧,٦٩	٢٩٧,٥١	٢٩٧,٣٠
٢٩٧,١٦	٢٩٧,٧٥	٢٩٧,٣٨	٢٩٧,٦٣	٢٩٧,٤٥	٢٩٧,١٦
٢٩٧,٤٨	٢٩٧,٨١	٢٩٧,٤٤	٢٩٧,٦٩	٢٩٧,٥١	٢٩٧,٤٨
٢٩٧,٥٩	٢٩٧,٩٢	٢٩٧,٥٥	٢٩٧,٨٠	٢٩٧,٦٢	٢٩٧,٥٩
٢٩٦,٨٠	٢٩٧,٢٣	٢٩٦,٩٥	٢٩٧,٣٠	٢٩٧,٠٢	٢٩٦,٨٠
٢٩٦,٢٧	٢٩٦,٧١	٢٩٦,٣٤	٢٩٦,٥٩	٢٩٦,٤١	٢٩٦,٢٧
٢٩٦,٨٣	٢٩٧,٣٤	٢٩٦,٩٦	٢٩٧,٢١	٢٩٧,٠٤	٢٩٦,٨٣
٢٩٧,٩٨	٢٩٨,٥٢	٢٩٨,١٥	٢٩٨,٤٠	٢٩٨,٢٢	٢٩٧,٩٨
٢٩٨,٦٢	٢٩٨,٧٦	٢٩٨,٢٨	٢٩٨,٦٣	٢٩٨,٤٥	٢٩٨,٦٢
٢٩٩,١١	٢٩٩,٣٥	٢٩٨,٩٧	٢٩٩,٢٢	٢٩٩,٠٤	٢٩٩,١١
٢٩٩,٣٤	٣٠٠,٠١	٢٩٩,٦٤	٢٩٩,٨٩	٢٩٩,٧١	٢٩٩,٣٤
٢٩٩,٨٤	٣٠٠,٦٥	٣٠٠,٢٨	٣٠٠,٥٣	٣٠٠,٣٥	٢٩٩,٨٤
٢٩٩,٨٦	٣٠٠,٧٢	٣٠٠,٣٤	٣٠٠,٥٩	٣٠٠,٤١	٢٩٩,٨٦
٢٩٩,٨٨	٣٠٠,٨٣	٣٠٠,٤٥	٣٠٠,٧٠	٣٠٠,٥٢	٢٩٩,٨٨
٣٠٠,٠٨	٣٠٠,٩٤	٣٠٠,٥٦	٣٠٠,٨١	٣٠٠,٦٣	٣٠٠,٠٨
٢٩٩,٧٣	٣٠٠,٣١	٢٩٩,٩٤	٣٠٠,١٩	٣٠٠,٠١	٢٩٩,٧٣
٢٩٩,٦٣	٣٠٠,٤٤	٣٠٠,٠٦	٣٠٠,٣١	٣٠٠,١٣	٢٩٩,٦٣
٢٩٨,٩٧	٢٩٩,٨٣	٢٩٩,٤٦	٢٩٩,٧١	٢٩٩,٥٣	٢٩٨,٩٧
٢٩٨,٧١	٢٩٩,٢١	٢٩٨,٨٣	٢٩٩,٠٨	٢٩٨,٩٠	٢٩٨,٧١
٢٩٨,٥٦	٢٩٩,٣٢	٢٩٨,٩٥	٢٩٩,٣٠	٢٩٩,٠٢	٢٩٨,٥٦
٢٩٩,٠١	٢٩٩,٩٠	٢٩٩,٥٢	٢٩٩,٧٧	٢٩٩,٥٩	٢٩٩,٠١
٢٩٨,٦٩	٢٩٩,٢٨	٢٩٨,٩١	٢٩٩,١٦	٢٩٨,٩٨	٢٩٨,٦٩
٢٩٧,٨٣	٢٩٨,٣٦	٢٩٧,٩٨	٢٩٨,٢٣	٢٩٨,٠٥	٢٩٧,٨٣
٢٩٧,٤٧	٢٩٨,٣٣	٢٩٧,٩٦	٢٩٨,٢١	٢٩٨,٠٣	٢٩٧,٤٧
٢٩٥,٨٩	٢٩٧,٨١	٢٩٧,٤٤	٢٩٧,٦٩	٢٩٧,٥١	٢٩٥,٨٩


شكل ٦

الخط البياني للسلسلة الأصلية ومخرجات الشبكة العصبية للمنظومة التي تحتوي على عنصري معالجة في الشريحة المخفية وعلى ثلاثة عناصر معالجة



شكل ٧

الخط البياني للسلسلة الأصلية ومخرجات الشبكة العصبية للمنظومة التي تحتوي على أربعة عناصر معالجة في الشريحة المخفية وعلى خمسة عناصر معالجة



عناصر معالجة في الشريحة المخفية كانت الأقل من حيث RMS وهذه دلالة واضحة على أن هذه المنظومة كانت الأقدر في التنبؤ بالقيم الفعلية للسلسلة المستخدمة وأن أخطاءها كانت الأقل من بين جميع المنظومات المستخدمة.

وتأكيداً لاختيار أفضل المنظومات من حيث القدرة التنبؤية فقد تم حساب الجذر التربيعي لمتوسط مربعات الانحرافات (RMS) لكل منظومة على حدة. جدول ٢ يعرض قيم الجذر التربيعي لمتوسط مربعات الانحرافات للمنظومات الخمسة المستخدمة، حيث يؤكد أن المنظومة ذات ثلاثة

معالجة في الشريحة المخفية التي تقع بين شريحة المدخلات ذات أربعة عناصر وشريحة المخرجات ذات العنصر الواحد.

مقارنة النموذجين

بمقارنة نتائج أداء أفضل المنظومات في الشبكة العصبية المستخدمة مع سلسلة صرف الدينار الكويتي مقابل الدولار الأمريكي (الشبكة ذات ثلاثة عناصر معالجة في الشريحة المخفية) بأفضل النتائج للنماذج الأحادية لـ «بوكس وجينكنز» المعروضة في دراسة المحميد (١٩٩٦) فإن الجدول ٣ يعرض القيمة الفعلية

جدول ٢ الجذر التربيعي لمتوسط مربعات الانحرافات لنظومات الشبكة

عدد عناصر المعالجة	RMS
عنصران	٠,٧٢١٩
ثلاثة عناصر	٠,٤٦٥١
أربعة عناصر	٠,٦٣٢٤
خمسة عناصر	٠,٥٠٥٩
سنة عناصر	٠,٦٧٤٨


لذا فإنه سوف تُعتمد المنظومة النهائية للشبكة العصبية بحيث تحتوي على ثلاثة عناصر

جدول ٣ القيم الفعلية والمتنبأ بها

رقم المشاهدة	القيم الفعلية	نموذج «بوكس وجينكنز»	نموذج الشبكة العصبية
١٨٠	٢٩٧,١٤	٢٩٨,٠٥	٢٩٨,٠٥
١٨١	٢٩٨,١٣	٢٩٧,٥١	٢٩٧,٤٤
١٨٢	٢٩٧,٨١	٢٩٨,٥٩	٢٩٨,٠٧
١٨٣	١٩٧,٣٥	٢٩٧,٥٩	٢٩٧,٥٠
١٨٤	١٩٧,٣٠	٢٩٧,٠٥	٢٩٧,٤٤
١٨٥	٢٩٧,١٦	٢٩٧,٣٨	٢٩٧,٣٨
١٨٦	٢٩٧,٤٨	٢٩٧,٣٨	٢٩٧,٤٤
١٨٧	٢٩٧,٥٩	٢٩٧,٣٥	٢٩٧,٥٥
١٨٨	٢٩٦,٨٠	٢٩٧,٥٥	٢٩٦,٩٥
١٨٩	٢٩٦,٢٧	٢٩٦,٨٥	٢٩٦,٣٤
١٩٠	٢٩٦,٨٣	٢٩٦,٣٨	٢٩٦,٩٦
١٩١	٢٩٧,٩٨	٢٩٧,١٤	٢٩٨,١٥
١٩٢	٢٩٨,٦٢	٢٩٨,٣٤	٢٩٨,٣٨
١٩٣	٢٩٩,١١	٢٩٨,٣٣	٢٩٨,٩٧
١٩٤	٢٩٩,٣٤	٢٩٨,٧٢	٢٩٩,٦٤
١٩٥	٢٩٩,٨٤	٢٩٩,٥٤	٣٠٠,٢٨
١٩٦	٢٩٩,٨٦	٣٠٠,٣٦	٣٠٠,٣٤
١٩٧	٢٩٩,٨٨	٢٩٩,٩٦	٣٠٠,٤٥
١٩٨	٣٠٠,٠٨	٣٠٠,١٠	٣٠٠,٥٦
١٩٩	٢٩٩,٧٣	٢٩٩,٩٨	٢٩٩,٩٤
٢٠٠	٢٩٩,٦٣	٢٩٩,٨٦	٣٠٠,٠٦
٢٠١	٢٩٨,٩٧	٢٩٩,٦٨	٢٩٩,٤٦
٢٠٢	٢٩٨,٧١	٢٩٨,٨٩	٢٩٨,٨٣
٢٠٣	٢٩٨,٥٦	٢٩٨,٨٥	٢٩٨,٩٥
٢٠٤	٢٩٩,٠١	٢٩٨,٤٥	٢٩٩,٥٢
٢٠٥	٢٩٨,٦٩	٢٩٩,٠٨	٢٩٨,٩١
٢٠٦	٢٩٧,٨٣	٢٩٨,٦٩	٢٩٧,٩٨
٢٠٧	٢٩٧,٤٧	٢٩٧,٦٠	٢٩٧,٩٦
٢٠٨	٢٩٥,٨٩	٢٩٧,٠٣	٢٩٧,٤٤

شكل ٨

الخط البياني للسلسلة الأصلية والسلسلتين المتنبأ بهما



جدول ٤
الجزر التربيعي لمتوسط مربعات الانحرافات


القيم الفعلية	RMS
نموذج الشبكات العصبية	٠,٤٦٥١٦
نموذج «بوكس وجينكز»	٠,٥٤٢٤٩

كما يعرض الشكل رقم ٩ سلسلة الانحرافات أو الأخطاء ما بين القيم الفعلية والقيم المتنبأ بها لكل من النموذجين، حيث يظهر أن كلتا السلسلتين كانتا عشوائيتين ولا تتمتعان بأية نمطية تظهر في السلسلة الأصلية، وهذا بدوره يؤكد قدرة النموذجين على امتصاص العلاقات النمطية في السلسلة الأصلية ونمذجتها.

لسلسلة سعر الصرف والقيم المتنبأ بها باستخدام كل من النموذجين، للتنبؤ بالقيم التسعة والعشرين الأخيرة من السلسلة، وذلك بعد استخدام المشاهدات الأولى في بناء النماذج في كل من الحالتين. يتضح بمقارنة القيم في الجدول أن الطريقتين كانتا قريبتين من القيم الفعلية، والشكل ٨ يبرز ذلك من خلال الخط البياني للسلسلة الفعلية والسلسلتين المتنبأ بهما، ويصعب التفضيل أو الحكم على قدرة أي من الأسلوبين في التنبؤ بالقيم الفعلية بمجرد النظر إلى شكل ٨ أو إلى القيم في الجدول ٣، لذا فإنه سوف تُقاس أخطاء النموذجين باستخدام الجزر التربيعي لمتوسط مربعات الانحرافات RMS، حيث يعرض الجدول ٤ قيمة RMS للنموذجين والذي يظهر أن نموذج الشبكة العصبية كان الأفضل في هذا المجال.

شكل ٩

سلسلة الخطأ أو الانحراف للنموذجين



الخاتمة والتوصيات

المتصلة بينها، وذلك لأن توفر مثل هذه البيانات قد يؤدي إلى تغير في نمطية البيانات المتوفرة عن السلسلة الزمنية، وبالتالي يؤثر في عدد عناصر المعالجة في كل شريحة وفي نوعية المعلومات المدخلة في شريحة المدخلات. إلا أن إعادة دراسة تركيبة المنظومة لا تتم إلا بعد فترات بعيدة نسبياً، ستة أشهر مثلاً أو سنة في البيانات الأسبوعية أو اليومية ولفترات أطول بالنسبة للبيانات الشهرية أو الربع سنوية.

تشير نتائج الدراسة إلى أن طريقة الشبكات العصبية هي أفضل نسبياً من النماذج الإحصائية التقليدية لـ «بوكس وجينكز» في التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي، وهذا يتفق مع عدة دراسات مشابهة منها مثلاً دراسة Reynolds et al (1995). كما أن هذه الطريقة إن لم تكن أفضل من النماذج التقليدية فهي ليست أسوأ منها. كما أنها لا تشترط العديد من القيود والاقتراحات التي قد يصعب معها إيجاد النماذج الإحصائية الملائمة للبيانات المستخدمة.

في القسم السابق عرضنا نتائج الشبكة العصبية بتقسيم السلسلة المتوفرة إلى مجموعتين واحدة لبناء منظومة الشبكة الملائمة للبيانات، وأخرى لاختبار قدرة هذه المنظومة على تعرف النمطية المتوفرة في بيانات السلسلة وقدرتها على التنبؤ بقيمة المجموعة الثانية. ويمكن إعادة تدريب هذه الشبكة مرة أخرى باستخدام المنظومة نفسها وذلك بعد إضافة جميع البيانات المتوفرة عن سلسلة سعر صرف الدينار الكويتي مقابل الدولار الأمريكي، ثم استخدامها في التنبؤ بالقيم المستقبلية لأسعار الصرف. كما يمكن تكرار إعادة تدريبها مرة أخرى وبإضافة القيم التي تتوفر مستقبلاً عن السلسلة.

إذا توفر العديد من البيانات عن السلسلة الزمنية بعد الفترة التي تم استخدامها في بناء المنظومة المناسبة للشبكة العصبية، فإننا قد نحتاج إلى إعادة دراسة تركيبة المنظومة من جديد، وذلك من حيث عدد عناصر المعالجة والعقد

للسلاسل الزمنية)، ومن ثم مقارنتها مع الطريقة المستخدمة لقياس أداء منظومات الشبكات العصبية.

٣ - كما يمكن إدخال معلومات عن أسعار صرف عملات رئيسية أخرى مقابل بعضها ومقابل الدينار الكويتي كمدخلات في الشبكة العصبية للتنبؤ بأسعار صرف عملة واحدة مثل سعر صرف الدينار الكويتي مقابل الدولار الأمريكي. وهذا قد يكون مجالا جيدا لدراسة مستقبلية.

٤ - يمكن كذلك إدخال معلومات عن أسعار صرف العملات الرئيسية مقابل بعضها ومقابل الدينار الكويتي واستخدامها في التنبؤ بالأسعار المستقبلية لأكثر من عملتين وفي آن واحد، وهذه تقع في نطاق دراسة مستقبلية أخرى.

٥ - يمكن كذلك دراسة قياس وتطوير مقياس إحصائي لمعنوية الفروق في الأخطاء لمقارنة النماذج أو المنظومات المختلفة في الشبكة العصبية، وهي من الموضوعات المفتوحة للبحث مستقبلا.

في هذه الدراسة تم استخدام سلسلة أحادية لسعر صرف الدينار الكويتي مقابل الدولار الأمريكي للتنبؤ بالأسعار المستقبلية لنفس العملتين وذلك باستخدام طريقة التدريب الإشرافية وطريقة التعلم التراجعية التعديلية ذات التغذية الأمامية التتابعية. ويمكن مستقبلا البناء على ذلك من خلال الاقتراحات التالية:

١ - يمكن استخدام أسلوب الشبكات العصبية في تحسين أداء النماذج الإحصائية التقليدية للانحدار الذاتي والمتوسطات المتحركة وذلك لخصر النماذج الممكنة والمقبولة لبدء طريقة «بوكس وجينكنز».

٢ - يمكن استخدام أسلوب الشبكات العصبية على البيانات الأحادية السابقة نفسها لسلسلة سعر صرف الدينار الكويتي مقابل الدولار الأمريكي ولكن باستخدام طرق أخرى للتدريب، وطرق أخرى للتعلم، وباستخدام منظومات أخرى مثل منظومة الشبكات العصبية ذات التغذية الذاتية المتتابة (Recurrent Networks) (التي توصي بها بعض الدراسات بالنسبة

المراجع

المجلة الإحصائية المصرية، المجلد ٤٠، العدد ٢: ٢٢-١.

Abhyankar, A., Copeland, L., and Wong W. 1997. Uncovering Nonlinear Structure In Real-Time Stock-Market Indexed: The S&P 500, the DAX, the Nikkei 225, and the FSTE-100. *American Statistical Association Journal of Business & Economic Statistics*, January, 15(1):1-14.

Bounds, D., Lloyd, P., Mathew, B., and Waddell, G. 1989. A Multilayer Perceptron Network for the Diagnosis of Lower Back

محمد عبدالهادي المحميد، ١٩٩٦، «التنبؤ بأسعار صرف الدينار الكويتي مقابل العملات الرئيسية».

Pain. *Proceedings of Second IEEE International Conference on Neural Networks, San Diego, California*, 2: 481-489.

Box, G., and Jenkins, G., M. 1976. *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco.

Collins, J., Clark, M. 1993. An Application of the Theory of Neural Computation to the Prediction of Workplace Behavior: An Illus-

- tration and Assessment of Network Analysis. *Personal Psychology*, 46(3): 503-524.
- Fukushima, K. 1983. Neocognitron: a Neural Network Model for a Mechanism of Visual Pattern Recognition. *IEEE Transactions on System, Man and Cybernetics*, SMC - 13(5): 8-34.
- Le Cun, Y. 1986. Learning Processes in an Asymmetric Threshold Network. In *Disordered Systems and Biological Organization*. E. Bienenstock, F. Fogelman Soulié and G. Weishbueh, (Eds), Springer, Berlin, 233-240.
- Parker, D. 1985. Learning Logic. *Technical Report TR-87, Center for Computational Research in Economics and Management Science, MIT, Cambridge, Massachusetts*.
- Reynolds, S., Mellichamp, J., and Smith R. 1995. Box-Jenkins Forecast Model Identification. *AI Expert*, (June): 15-28.
- Rumelhart, D., Hinton G., and Williams, R. 1986a. Learning Internal Representations by Error Propagation. In *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, D.E. Rumelhart and J. L. McClelland, (Eds.) MIT Press, Cambridge, Massachusetts, 1: 318-326.
- Rumelhart, D., Hinton, G. and Williams, R. 1986b. Learning Representations by Back-Propagation Errors. *Nature*, 323 (6088): 533-536.
- Sejnowski, T., and Rosenberg, R. 1986. Nettek: A Parallel Network that Learns to Read Aloud. *Tech. Rep. JHU/EECS 86/01, Johns Hopkins University, Baltimore, Maryland*.
- Schwartz, T. 1988. Look to Corporate for Decision Making Material. *Computer world*, 22(42): 86-87.
- Weigend, A., Rumelhart, D., and Huberman, B. 1991. Generalization by Weight - Elimination Applied to Currency. 1991. *IEEE International Joint Conference on Neural Networks, Singapore*, 3: 2374-2379.
- Werbos, P. 1974. Beyond Regression: New Tools for Prediction and Analysis in The Behavioral Sciences. *Ph.D. Dissertation, Harvard University, Cambridge, Massachusetts*.
- Widrow, B., Rumelhart, D. and Lehr, M. 1994. Neural Networks: Applications in Industry, Business and Science. *Communications of the ACM*, 37(3): 93-105.
- Wong, F. 1991. A 3-D Neural Network for Business Forecasting *Proceedings of the Twenty-Fourth Annual Hawaii International Conference on System Science, IEEE Comput. Soc. Press, Kauai, Hawaii*, 4: 113-123.

ABSTRACT

NEURAL NETWORKS: PREDICTING KUWAITI KD CURRENCY EXCHANGE RATES VERSUS US DOLLAR

JAFAR M. HAJI

MOHAMMAD A. ALMAHMEED

Kuwait University

There are many known models for predicting currency exchange rates, linear and non-linear regression models and time series models specially Box and Jenkins model i.e. Autogressive Moving Average models. Neural Networks technique is a new approach that have been used in many applications especially in pattern recognition problems. Time series is considered as pattern relation between two or more variables. Therefore, this research will use neural networks to study the relationship that effects Kuwaiti KD exchange rate versus US dollar for the purpose of using it in the future prediction of the currency exchange rate. Finally, we compared the neural network Model with the Box Jenkins Autoregressive and Moving Average Model.

جعفر محمد حاجي (دكتوراه الفلسفة في علوم الحاسب، معهد إلينوي للتكنولوجيا، الولايات المتحدة الأمريكية، ١٩٩٥)، مدرس، قسم الطرق الكمية ونظم المعلومات، كلية العلوم الإدارية، جامعة الكويت، له اهتمامات بحثية في مجالات نظم المعلومات، والذكاء الصناعي، والنظم الخبيرة، والشبكات العصبية، وقواعد البيانات، وخوارزميات «الجيئات».

محمد عبدالهادي المحميد (دكتوراه الفلسفة في الإحصاء، جامعة ولاية أوكلاهوما، الولايات المتحدة الأمريكية، ١٩٨٢)، أستاذ مساعد، كلية العلوم الإدارية، جامعة الكويت، له اهتمامات بحثية في مجالات الإحصاء الرياضي والتطبيقي خاصة في التحليل التتابعي، والسلاسل الزمنية، وإحصاءات «بينز»، وتحليل الشبكات العصبية، والمنطق الضبابي Fuzzy Logic.

مجلة الحقوق

تحت إشراف

الأستاذ الدكتور عادل الطبطبائي

مجلة فصلية أكاديمية محكمة تعنى بنشر البحوث

والدراسات القانونية والشرعية

تصدر عن مجلس النشر العلمي . جامعة الكويت

صدر العدد الأول في يناير ١٩٧٧

الاشتراكات

في الكويت : ٣ دنانير للأفراد ، ١٥ ديناراً للمؤسسات

في الدول العربية : ٤ دنانير للأفراد ، ١٥ ديناراً للمؤسسات

في الدول الأجنبية : ١٥ دولاراً للأفراد ، ٦٠ دولاراً للمؤسسات

المراسلات

توجه جميع المراسلات إلى رئيس التحرير على العنوان التالي:

مجلة الحقوق . جامعة الكويت

ص.ب : ٥٤٧٦ الصفاة 13055 الكويت

تلفون : ٤٨٣٥٧٨٩ . فاكس : ٤٨٣١١٤٣