



جامعة بنغازي - كلية التربية



مجلة كلية التربية ... العدد التاسع عشر ... ديسمبر 2025



تقييم كفاءة نموذج الشبكات العصبية ذات الأساس الشعاعي (RBF) في التنبؤ بالسلاسل الزمنية للمتغيرات الاقتصادية: دراسة تطبيقية.

بحث مقدم من

الدكتور

حسين محمد المهدي الشريف

محاضر - قسم الإحصاء - كلية العلوم - جامعة سبها

**Evaluating the Efficiency of the Radial Basis Function (RBF) Neural Network Model in Forecasting Economic Time Series: An Applied Study**

*Submitted by*

**Dr. Hossen Mohammed Mahdi Ahmed**

**Department of Statistics Faculty of Science - Sebha University**

[ashareefh@gmail.com](mailto:ashareefh@gmail.com)

## الملخص

هدفت هذه الدراسة إلى تقييم فعالية نموذج الشبكات العصبية RBF في التنبؤ بسلسلة زمنية من المتغيرات الاقتصادية أو الإحصائية خلال الفترة من يوليو 2009 إلى يونيو 2011 ، بالاعتماد على ستة متغيرات مستقلة (X1-X6) لتقدير المتغير التابع.(RBF) أظهرت النتائج أن النموذج يتمتع بدقة تنبؤية عالية، حيث بلغت قيمة معامل الارتباط (Correlation) بين القيم الفعلية والمتنبأ بها للمتغيرات الرئيسية، مثل X1 ، ما يقارب **0.957** ، مع دلالة إحصائية مرتفعة.( $p < 0.01$ ) عكست القيم المتوقعة من النموذج اتجاهًا تصاعديًا للمتغير RBF ، بما يتوافق مع التوجهات الزمنية للبيانات، كما برزت المتغيرات X2 و X3 كعوامل ذات أهمية نسبية مرتفعة في التنبؤ. وقد تميز النموذج بمستويات أداء قوية وفقًا لمؤشرات الجودة الإحصائية مثل AIC و HQC و SIC ، إلى جانب ارتفاع معامل التحديد ( $R^2$ ) رغم الكفاءة العامة للنموذج، لوحظت بعض الفروقات في دقة التنبؤ، لا سيما مع المتغيرين X3 و X5، اللذين أظهرتا ارتفاعًا نسبيًا في مؤشري MAPE و TS، ما يشير إلى إمكانية تحسين أداء النموذج في هذه الحالات.

في ضوء النتائج، أوصت الدراسة بما يلي:

- تعزيز استخدام نموذج RBF في تطبيقات التنبؤ الإحصائي والاقتصادي.
- مراجعة أداء بعض المتغيرات لتحسين التنبؤ.
- استخدام معايير تقييم النماذج بشكل دوري.
- تحسين جودة البيانات وتدريب الفرق الفنية على استخدام هذا النوع من النماذج.

تُبرز هذه الدراسة الكفاءة العالية التي يتمتع بها نموذج الشبكات العصبية (Radial Basis Function - RBF) بوصفه أحد النماذج المتقدمة في ميدان تحليل السلاسل الزمنية والتنبؤ بالقيم المستقبلية.

**الكلمات المفتاحية:** الشبكات العصبية RBF ، التنبؤ بالسلاسل الزمنية، إنتاج النفط، مؤشرات الجودة الإحصائية، تحسين دقة النموذج.

## Abstract

This study aimed to evaluate the effectiveness of the Radial Basis Function (RBF) neural network model in forecasting a time series of economic or statistical variables during the period from July 2009 to June 2011, relying on six independent variables (X1-X6) to estimate the dependent variable (RBF). The results demonstrated that the model possesses high predictive accuracy, as indicated by the Pearson correlation coefficient between actual and predicted values for key variables such as X1, which reached approximately **0.957**, with a high statistical significance ( $p <$

0.01). The predicted values from the model reflected an upward trend in the RBF variable, aligning with the temporal patterns in the data. Additionally, variables X2 and X3 emerged as relatively important predictors. The model showed strong performance levels according to statistical quality metrics such as AIC, SIC, and HQC, alongside a high coefficient of determination ( $R^2$ ). Despite the overall efficiency of the model, some discrepancies in prediction accuracy were observed, particularly with variables X3 and X5, which showed relatively high values in MAPE and TS, indicating potential for improving the model's performance in these cases.

Based on the findings, the study recommends the following:

- Enhancing the use of the RBF model in statistical and economic forecasting applications.
- Reviewing the performance of certain variables to improve predictions.
- Regular application of model evaluation criteria.
- Improving data quality and training technical teams on the use of such models.

This study confirms the effectiveness of the RBF model as a powerful tool in time series analysis and accurate forecasting, making it a suitable option in complex and dynamic environments.

**Keywords:** RBF Neural Networks, Time Series Forecasting, Oil Production, Statistical Quality Indicators, Model Accuracy Improvement.

## 1-1 مقدمة:

تُعد الشبكات العصبية ذات الأساس الشعاعي (Radial Basis Function – RBF) من الأدوات التنبؤية الفعالة في تحليل السلاسل الزمنية، لا سيما في البيانات المعقدة وغير الخطية مثل التنبؤ بإنتاج النفط. وتتبع أهميتها من قدرتها العالية على نمذجة العلاقات غير الخطية بين المتغيرات، واكتشاف الأنماط الكامنة ضمن البيانات، مما يمنحها كفاءة تفوق العديد من النماذج التقليدية. وتتميز هذه الشبكات بقدرتها على التعامل مع كميات كبيرة من البيانات المتعددة الأبعاد، بما يشمل متغيرات معقدة مثل الأسعار، العرض والطلب، العوامل الجيوسياسية، والظروف المناخية، الأمر الذي يساهم في تعزيز دقة التنبؤات. كما تمتلك الشبكات العصبية خاصية التعلم التكيفي، حيث تقوم بتحديث الأوزان والمعاملات بشكل تلقائي بناءً على البيانات المستحدثة، مما يسمح بتحسين الأداء التنبؤي بشكل مستمر مع مرور الوقت. (عبد الرحمن، 2023: 4/89)

## 1-2 مشكلة البحث:

يُعد التنبؤ بإنتاج النفط من المسائل الاستراتيجية ذات الأهمية البالغة على الصعيدين الاقتصادي والسياسي، نظرًا لتأثيره المباشر في توجيه السياسات التخطيطية للدول وصناعة القرار داخل الشركات النفطية. وفي ظل تعقيد العلاقات غير الخطية بين المتغيرات المؤثرة في إنتاج النفط، تبرز الحاجة إلى توظيف نماذج تنبؤية

متقدمة، مثل الشبكات العصبية ذات الأساس الشعاعي (Radial Basis Function – RBF) ، التي تمتاز بقدرتها على معالجة البيانات الضخمة واكتشاف الأنماط المعقدة. وانطلاقاً من ذلك، تتمثل مشكلة الدراسة في تحليل مدى كفاءة نموذج RBF في التنبؤ بإنتاج النفط من خلال دراسة تطبيقية، مع التركيز على تقييم دقة التنبؤ وقياس تأثير العوامل المختلفة المرتبطة بالعملية الإنتاجية.

### **1-3 أهمية البحث:**

تتمثل أهمية هذا البحث في عدة جوانب رئيسية:

تستمد هذه الدراسة أهميتها من المركزية الاستراتيجية لصناعة النفط في دفع عجلة الاقتصاد العالمي، انطلاقاً من تأثيراتها المباشرة على استقرار الأسواق المالية، وصياغة السياسات الاقتصادية للدول، وإدارة استراتيجيات الطاقة سواء لدى الدول المصدرة أو المستوردة. ويسعى البحث إلى ابتكار نموذج تنبؤي متطور يعتمد على تقنيات الذكاء الاصطناعي، ويجمع بين الدقة العلمية والكفاءة التشغيلية، بهدف تمكين صانعي السياسات والشركات النفطية من اتخاذ قرارات استباقية قائمة على تحليلات تنبؤية مُحكمة.

### **وتتمثل أبرز جوانب الأهمية في:**

1. رفع كفاءة التنبؤات النفطية: يهدف البحث إلى استكشاف قدرات شبكات RBF العصبية في تحسين دقة التنبؤ بحجم الإنتاج النفطي المستقبلي، عبر تحليل البيانات التاريخية والمتغيرات المؤثرة، مما يسهم في تقليل الفجوة بين التوقعات والواقع، ويحد من المخاطر المرتبطة بتقلبات السوق.
2. رصد التفاعلات غير الخطية: يُعاني قطاع النفط من تشابك معقد للعوامل المؤثرة فيه، كالأضطرابات الجيوسياسية، والتقلبات الاقتصادية، والضغط البيئية، والتي يصعب نمذجتها بأساليب تقليدية. هنا يبرز دور نموذج RBF بوصفه حلاً مبتكراً لقدرته على رصد الأنماط الخفية وتحليل العلاقات غير الخطية بين المتغيرات المتفاعلة، مما يضمن توقعات أكثر واقعية لاتجاهات الإنتاج والطلب.

### **1-4 أهداف البحث:**

- تحليل وتقييم أداء الشبكات العصبية ذات الأساس الشعاعي (RBF) في التنبؤ بإنتاج النفط استناداً إلى البيانات الزمنية وتحليل أدائها
- تحليل فعالية RBF في التنبؤ بالأنماط الموسمية والتغيرات غير المتوقعة في إنتاج النفط، مع التركيز على دقة التنبؤ في ظل تقلبات السوق.

- تحسين أداء نموذج RBF من خلال استخدام تقنيات متقدمة مثل التنظيم (Regularization) والتحسين التلقائي لاختيار المعلمات المثلى.

## 5-1 منهجية البحث:

تتضمن المنهجية المراحل التالية وفق تسلسل علمي:

- بناء النموذج وتدريبه: تصميم نموذج RBF عصبي باستخدام خوارزمية الانتشار العكسي (Backpropagation) لتحسين أوزان الشبكة وتقليل خطأ التنبؤ.
- توظيف تقنيات التحسين الذكية (مثل خوارزمية التدرج العشوائي) لضبط المعلمات الرئيسية (مثل عدد العقد ونصف قطر التأثير).
- جمع البيانات ومعالجتها: استخدام قواعد بيانات زمنية تاريخية لإنتاج النفط، تشمل متغيرات مؤثرة (الأسعار، الطلب، العوامل الجيوسياسية، ... إلخ).
- تطبيق تقنيات التطبيع (Normalization) والتجزئة الزمنية لإعداد البيانات بشكل متوافق مع الشبكة العصبية.
- استخدام برامج متخصصة في الشبكات العصبية مثل (DTREG & NERO-SHELL ( PREDICTOR
- استخدام برامج متخصصة في السلاسل الزمنية مع الشبكات العصبية مثل (SPSS & E-views)
- تقييم الأداء: قياس دقة النموذج عبر مؤشرات رياضية مثل:
  - جذر متوسط مربعات الخطأ (RMSE) لتقييم حجم الانحرافات.
  - متوسط الخطأ المطلق (MAE) لقياس الدقة العامة.
- التحليل النهائي: تفسير العلاقة بين دقة التنبؤ وخصائص نموذج RBF (مثل مرونة التعامل مع البيانات غير الخطية)

## 6-1 حدود البحث:

إحدى شركات البترول الرائدة، التي تأسست العام 1981 ضمن النطاق الجغرافي الخاضع لاتفاقية التزام البحث والتقيب عن البترول، محوراً لهذه الدراسة. حيث تعمل الشركة على تطوير مجموعة من الحقول البترولية، يأتي

في مقدمتها ستة حقول رئيسية تمثل النسبة الأكبر من إنتاجها، وهي : (حقول X1 ، حقول X2 ، حقول X3 ، حقول X4 ، حقول X5 ، حقول X6 ) وستعتمد الدراسة على تحليل البيانات الشهرية لمتوسط إنتاج هذه الحقول، والتي تغطي فترة زمنية ممتدة من سبتمبر 1986 حتى أبريل 2014، لتشكل بذلك سلسلة زمنية مكونة من 330 مشاهدة (Observation). تمثل هذه البيانات قاعدةً شاملةً لرصد التغيرات التاريخية في الإنتاج، وتحليل الأنماط الموسمية والاتجاهات العامة عبر ثلاثة عقود تقريباً.

## 1-7 فروض البحث:

**الفرضية الأولى:** تُظهر الشبكات العصبية ذات الأساس الشعاعي (RBF) كفاءة تنبؤية مُتفوّقة في نمذجة إنتاج النفط، نظرًا لقدرتها على محاكاة العلاقات غير الخطية والمعقدة بين المتغيرات المؤثرة.

**الفرضية الثانية:** تمتلك شبكات RBF مرونة تحليلية فريدة تتيح لها التكيف مع التقلبات الحادة والمفاجئة في السلاسل الزمنية لإنتاج النفط.

## 1-8 خطة البحث :

تعتمد هذه الدراسة على تصميم إطار تحليلي متكامل لقياس الكفاءة التنبؤية لنماذج الشبكات العصبية ذات الأساس الشعاعي (RBF) ، وتقييم أثر تطبيق تحسينات معمارية وخوارزمية على دقة النتائج. سيتم ذلك عبر الخطوات التالية:

### (1) مقدمة

### (2) الاطار النظري للبحث : الشبكات العصبية ذات الأساس الشعاعي RBF

### (3) التطبيق العملي لتحليل البيانات

### (4) النتائج والتوصيات

## 1-9 الدراسات السابقة

### **1-Li, Y. (2025). Radial Basis Function Neural Network and Response Surface for Drilling-Related Predictions.**

تهدف دراسة (Li (2025) ، إلى تحسين التنبؤ بالعمليات المتعلقة بالحفر في صناعة النفط باستخدام نموذج الشبكة العصبية ذات دالة الأساس الشعاعي (RBF) مدمج مع أسطح الاستجابة (Response Surface). اعتمد البحث على بيانات تشغيلية تشمل متغيرات الحفر مثل معدل التدفق، ضغط الحفر، ولزوجة الطين. تم

تدريب النموذج على مجموعة بيانات تاريخية، وتم تقييم أدائه باستخدام مقاييس الخطأ الإحصائية مثل متوسط الخطأ المطلق (MAE)، جذر متوسط الخطأ التربيعي (RMSE)، ومعامل التحديد ( $R^2$ ). أظهرت النتائج أن دمج RBF مع أسطح الاستجابة أدى إلى تحسين دقة التنبؤ مقارنة بالنماذج التقليدية، مع قدرة أفضل على التقاط العلاقات غير الخطية بين المتغيرات التشغيلية، مما يعزز من فعالية التخطيط واتخاذ القرار في عمليات الحفر.

## 2-Zhang, X. (2024). An Improved Radial Basis Function Neural Network for [Earth-Science Application].

تسعى الدراسة إلى تحسين دقة التنبؤ في المشكلات الجيولوجية المعقدة التي تتسم بـ لا خطية عالية وتداخل متعدد للعوامل البيئية، وذلك من خلال تطوير نموذج شبكات عصبية قائم على دوال الأساس الشعاعية (RBFNN) يركز التحسين المقترح على مرحلتين رئيسيتين:

1. اختيار مراكز الدوال الشعاعية،

2. تقدير معامل الانتشار ( $\sigma$  / Spread).

استخدم الباحث خوارزمية تحسين ذكية مثل (Particle Swarm Optimization – PSO) لتحسين توزيع المراكز وتقليل حساسية النموذج لاختيار القيم الأولية، الأمر الذي يؤدي إلى تقليل أخطاء التنبؤ (RMSE & MAE) وزيادة الثبات الإحصائي في النماذج اللاحقة.

تم تطبيق النموذج على بيانات حقيقية لقياسات جيولوجية مثل (إزاحة منحدرات أو نشاط جيوميكانيكي). وبعد مقارنة النموذج المحسن بنماذج بديلة مثل RBF التقليدي، والشبكات متعددة الطبقات (MLP)، وطرق الانحدار غير الخطي، أظهرت النتائج أن النموذج المحسن:

• حقق انخفاضاً ملحوظاً في قيم RMSE & MAPE،

• أظهر استقراراً أكبر عند وجود ضوضاء في البيانات،

• وقدم قدرة تفسير محلية أفضل لسلوك النظام في المدى القصير والمتوسط.

خلصت الدراسة إلى أن تحسين معاملات RBF عبر خوارزميات التحسين الاستقرائية يعزز كفاءة النماذج التنبؤية في مجالات علوم الأرض، وخاصة في التطبيقات التي يكون فيها السلوك الزمني ذا نمط غير خطي.

## 3- Przybyła-Kasperek, M. (2024). MLP and RBF Comparison for Classification Tasks.

تستهدف الدراسة مقارنة الأداء الإحصائي بين شبكات التغذية الأمامية متعددة الطبقات (MLP) وشبكات دوال الأساس الشعاعية (RBFNN) في مهام التصنيف، مع التركيز على تأثير بنية النموذج ومعايير التعلم على دقة التصنيف وكفاءته. اعتمدت الباحثة على مجموعة بيانات ذات عدم توازن في الفئات (Class Imbalance)، وهي حالة تؤدي عادةً إلى ضعف أداء النماذج التقليدية لصالح الفئة الأكبر.

أظهرت النتائج أن نموذج MLP يحقق في الغالب دقة إجمالية أعلى، لكنه كان أقل كفاءة عند التعامل مع الفئات النادرة، حيث يتجه إلى تصنيفها نحو الفئة المسيطرة. في المقابل، أثبت نموذج RBF قدرة أفضل على تمييز الحالات النادرة، وحقق استدعاء أعلى لتلك الفئات، مما يشير إلى تفوقه في سياقات تتطلب حساسية لاكتشاف الفئات الأقل تمثيلاً.

تشير الدراسة إلى أن اختيار النموذج الأمثل يعتمد على طبيعة البيانات الهدف:

- إذا كان الهدف أعلى دقة كلية لذلك يفضل MLP
  - إذا كان الهدف كشف حالات نادرة أو حدث منخفض التكرار لذلك يفضل RBF.
- خلصت الباحثة إلى أهمية اختيار النموذج بناءً على بنية البيانات وليس الأداء الكلي فقط، وأوصت باستخدام طرق إعادة التوازن (Oversampling / SMOTE) مع RBF و MLP لتحسين الأداء في تطبيقات التصنيف الحساسة.

#### 4- Zhao, L., Luo, Z., Deng, G., & Shi, V. (2023). Prediction of Corrosion Failure Probability of Buried Oil and Gas Pipeline Based on an RBF Neural Network.

تهدف دراسة Zhao et al. (2023) إلى تطوير نموذج تنبؤي لتقدير احتمال فشل التآكل في خطوط أنابيب النفط والغاز المدفونة باستخدام الشبكة العصبية ذات دالة الأساس الشعاعي (RBF). اعتمد البحث على مجموعة بيانات تاريخية شملت الخصائص الميكانيكية للأنابيب، ظروف التربة، المعاملات الكيميائية، وعوامل الضغط والحرارة. تم تقسيم البيانات إلى مجموعات تدريب واختبار لتقييم أداء النموذج. أظهرت النتائج أن نموذج RBF قادر على التنبؤ بدقة عالية، حيث سجل مؤشرات تقييم الأداء مثل متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) قيم منخفضة، مما يدل على قدرة النموذج على محاكاة العلاقة غير الخطية بين العوامل البيئية وتقنيات التآكل. كما أشار الباحثون إلى أن النموذج يوفر أداة فعالة لتحسين صيانة خطوط أنابيب النفط والغاز وتقليل المخاطر التشغيلية.

#### 5- Alizamir, M., Kisi, O., Ahmed, A. N., & Mert, C. (2020). Advanced hybrid RBF models for groundwater level prediction

طورت الدراسة نموذجًا هجينًا مبتكرًا يجمع بين الشبكات العصبية ذات الأساس الشعاعي (RBF) وخوارزميات التجميع (مثل K-means) لتحسين دقة التنبؤ بمستويات المياه الجوفية، والتي تُعد مؤشرًا حيويًا لإدارة الموارد المائية المستدامة. اعتمدت المنهجية على دمج قدرة RBF على نمذجة العلاقات غير الخطية بين العوامل الهيدرولوجية (مثل هطول الأمطار ودرجة الحرارة) مع قدرة خوارزميات التجميع في تصنيف البيانات إلى مجموعات متجانسة، مما يزيد من كفاءة النموذج في التعامل مع التعقيدات المكانية والزمنية. اختُبر النموذج على بيانات من آبار جوفية عدة في مناطق مختلفة، مع مقارنة أدائه مع نماذج RBF التقليدية والطرق الإحصائية (مثل الانحدار الخطي المتعدد). باستخدام مقاييس مثل جذر متوسط مربعات الخطأ (RMSE) ومعامل التحديد ( $R^2$ )، حقق النموذج الهجين تحسنًا في الدقة بلغ 18%، خاصةً في المناطق ذات الأنماط غير المنتظمة أو التغذية المحدودة.

### الفجوات البحثية :

الفجوة البحثية تكمن في توسيع نطاق المتغيرات، تحسين النماذج للتعامل مع البيانات المعقدة وغير الخطية، تعزيز التنبؤ طويل الأجل، واختبار النموذج في بيئات تشغيلية واقعية مع مؤشرات تقييم متعددة. معالجة هذه الفجوات يمكن أن تسهم في رفع كفاءة RBF في التنبؤ بالسلاسل الزمنية الاقتصادية والنفطية، وتحسين دقة اتخاذ القرار في الممارسات العملية. وفيما يلي أهم النقاط :

- هناك فجوة في تقييم فعالية RBF للتنبؤ طويل المدى، خاصة في الحالات الاقتصادية المتقلبة أو إنتاج النفط المتأثر بالسياسات العالمية، حيث إنّ أغلب الدراسات ركزت على التنبؤ قصير ومتوسط المدى، مع انخفاض دقة التنبؤ للمتغيرات الأقل استقرارًا.
- بعض الدراسات السابقة ركزت على دول معينة أو فترات زمنية قصيرة، في حين تمتد هذه الدراسة على فترة زمنية طويلة (1986-2014)، مما يساعد في تحليل الاتجاهات طويلة المدى.
- الدراسات السابقة اعتمدت غالبًا على مؤشرات مثل MAE، RMSE،  $R^2$ ، و AIC/SIC/HQC، بينما تُركِّز الدراسة الحالية على اختبار النموذج باستخدام مؤشرات تقييم متعددة الأبعاد، مثل MAPE، TS، أو مؤشرات المخاطر، لتوفير صورة أكثر شمولية عن كفاءة النموذج.
- اهتمت الدراسات السابقة بتطوير RBF في سياقات متنوعة، بينما تُركِّز الدراسة الحالية على تخصيص النموذج وتطويره ليتناسب مع تعقيدات صناعة النفط، مع تقديم حلول قابلة للتطبيق لدعم القرارات الاستراتيجية في بيئة تتسم بعدم اليقين.

- تعتمد الدراسة على تحسين معمارية الشبكات العصبية ذات الأساس الشعاعي (RBF) من خلال اختيار عدد الطبقات المخفية المناسب. واستخدام خوارزميات تدريب متقدمة الخوارزميات الجينية ( Genetic Algorithms ) لتحديد المعلمات المثلى. وكذلك خوارزميات التحسين الجزيئي ( Particle Swarm Optimization – PSO) لتحسين اختيار المراكز والأوزان.

## 2- الإطار النظري للبحث : الشبكات العصبية ذات الأساس الشعاعي RBF

تُعتبر شبكات RBF نوعًا من الشبكات العصبية الاصطناعية التي تعتمد على وظائف الأساس الشعاعي (Radial Basis Functions) كنواة للتعلم. (محمد، 2020، 5/45) وتتكون عادةً من ثلاث طبقات رئيسية :

- **طبقة الإدخال**: تنقل المتغيرات التفسيرية إلى الطبقة التالية.
- **الطبقة المخفية**: تعتمد على دوال الأساس الشعاعي، وغالبًا ما تكون دوال Gaussian ، وتمثل الاستجابات المحلية للعقد.
- **طبقة الإخراج**: تجمع مخرجات الطبقة المخفية باستخدام معاملات خطية لتوليد المخرجات النهائية.

### 1-2 المعادلات الأساسية للشبكات العصبية ذات الأساس الشعاعي: (RBF)

#### **1. دالة التنشيط في الطبقة المخفية: (Radial Basis Function)**

تستخدم وظيفة أساس شعاعي (غالبًا وظيفة جاوسية) لحساب نشاط كل عقدة مخفية:

$$\phi_j(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{c}_j\|^2}{2\sigma_j^2}\right) \dots \dots \dots (1)$$

- $\mathbf{x}$ : متجه الإدخال.
- $\mathbf{c}_j$ : مركز الدالة الشعاعية للعقدة المخفية.  $j$ .
- $\sigma_j$ : معامل الانتشار ( عرض النواة ) للعقدة.  $j$ .
- $\|\cdot\|$ : القاعدة الإقليدية (المسافة بين الإدخال والمركز)

#### **2. إخراج الشبكة ( الطبقة الخطية):**

إخراج الشبكة هو ترجيح خطي لمخرجات الطبقة المخفية:

$$y(\mathbf{x}) = \sum_{j=1}^M w_j \phi_j(\mathbf{x}) + b \dots\dots\dots(2)$$

- $w_j$  الوزن المرتبط بالعقدة المخفية.  $j$ .
- $b$  الانحياز. (Bias).
- $M$  عدد العقد المخفية.

### 3. تدريب النموذج:

#### أ. تحديد المراكز: $(\mathbf{c}_j)$

تُحدد مراكز الدوال الشعاعية عادةً باستخدام خوارزميات التجميع مثل: **k-means**

$$\mathbf{c}_j = \frac{1}{|C_j|} \sum_{\mathbf{x} \in C_j} \mathbf{x} \dots\dots\dots(3)$$

حيث  $C_j$  هي المجموعة.  $j$ .

#### ب. تحديد معاملات الانتشار: $(\sigma_j)$

تُحسب عادةً بناءً على المسافة بين المراكز:

$$\sigma_j = \frac{1}{M} \sum_{i=1}^M \|\mathbf{c}_j - \mathbf{c}_i\|^2 \dots\dots\dots(4)$$

#### ج. تحديد الأوزان: $(w_j)$

باستخدام طريقة المربعات الصغرى: (Least Squares)

$$\mathbf{w} = (\Phi^T \Phi + \lambda I)^{-1} \Phi^T \mathbf{y} \dots\dots\dots(5)$$

- $\Phi$ : مصفوفة التصميم (Design Matrix) تحتوي على  $\phi_j(\mathbf{x}_i)$ .
- $\lambda$ : معامل التنظيم (لمنع الإفراط في التخصيص).
- $\mathbf{y}$ : متجه القيم المستهدفة.

#### مثال تطبيقي (شبكة RBF بثلاث عقد مخفية):

لنفترض أن لدينا:

- إدخالين.  $(x_1, x_2)$

• ثلاث عقد مخفية بمراكز  $c_1, c_2, c_3$ .

إخراج الشبكة سيكون:

$$y = w_1 \exp\left(-\frac{\|x-c_1\|^2}{2\sigma_1^2}\right) + w_2 \exp\left(-\frac{\|x-c_2\|^2}{2\sigma_2^2}\right) + w_3 \exp\left(-\frac{\|x-c_3\|^2}{2\sigma_3^2}\right) + b \dots \dots (6)$$

### خطوات بناء نموذج RBF للتنبؤ:

- تجهيز البيانات: تنظيف وتحجيم البيانات وتحديد المتغيرات المدخلة والمستهدفة.
- تقسيم البيانات: إلى مجموعات تدريب واختبار.
- اختيار عدد المراكز: يمكن تحديد عدد العقد المخفية باستخدام خوارزمية K-means لتحديد مراكز الكتل.
- حساب قيم  $\sigma$ : غالباً باستخدام المسافة بين العقد أو طرق احتمالية.
- تقدير الأوزان في طبقة الإخراج: باستخدام طريقة المربعات الصغرى العادية (OLS).

### التطبيقات العملية لنموذج RBF:

- الأسواق المالية: التنبؤ بأسعار الأسهم والمؤشرات المالية. (Zhang et al., 2024)
- الطاقة: التنبؤ بالعمليات المتعلقة بالحفر في صناعة النفط (Li et al., 2025)
- التصنيف: مهام تصنيف البيانات. (Przybyła et al., 2024)

### مميزات RBF مقارنةً بالشبكات الأخرى

- سرعة التدريب: بسبب البنية الثابتة للطبقة المخفية.
- القدرة على التعميم: مناسبة للبيانات غير الخطية.
- التفسير الرياضي الواضح: بسبب استخدام وظائف الأساس الشعاعي.

### التحديات والقيود:

- الحاجة إلى معايرة دقيقة لمراكز العقد ومعامل التشتت.
- تأثر الأداء بزيادة أبعاد البيانات.
- ضعف القدرة التفسيرية مقارنةً بالنماذج الخطية.

## 2-2 تقييم دقة النموذج

تستخدم عدة مقاس لتقييم فعالة النموذج في التنبؤ وهي :-

A. خطأ متوسط القيمة المطلقة (Mean Absolute Error - MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots\dots\dots(7)$$

B. خطأ الجذر التربيعي لمتوسط المربعات (Root Mean Squared Error - RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots\dots\dots(8)$$

C. متوسط نسبة الخطأ المطلقة (Mean Absolute Percentage Error - MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \dots\dots\dots(9)$$

D. معامل التحديد ( $R^2$ )

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots\dots\dots(10)$$

## 2-3 مقاييس تحديد كفاءة النماذج الإحصائية ومدى ملائمتها للبيانات

تهدف هذه المقاييس إلي تحديد النموذج الذي يقدم أفضل توازن بين ملاءمة البيانات وتعقيد النموذج، مما يساعد في تجنب الإفراط في التخصيص.

### 1. مقياس أكايك: (AIC)

يعد مقياس AIC من أشهر المقاييس المستخدمة في النمذجة الإحصائية. يتم حسابه عن طريق أخذ الحساب اللوغاريتمي للاحتمال الأقصى للنموذج ومواءمته مع عدد المعلمات المستخدمة

$$AIC = 2k - 2\ln(L) \dots\dots\dots(11)$$

▪  $k$  عدد المعلمات في النموذج

- $L$  الاحتمال الأقصى للنموذج
- النموذج الذي يحتوي على أقل قيمة AIC هو الأنسب من بين النماذج المتنافسة

## 2. معيار شوارتز (Schwarz Criterion)

هو مقياس آخر يعتمد على الاحتمال الأقصى للنموذج لكنه يعالج النماذج المعقدة بشكل أقوى من AIC، وذلك بفضل عامل  $\ln(n)$  في الصيغة الرياضية. حيث  $n$  هو عدد البيانات المتاحة.

$$BIC = \ln(n)k - 2\ln(L) \dots \dots \dots (12)$$

- $n$  عدد العينات في البيانات.
- $k$  عدد المعلمات في النموذج.
- $L$  الاحتمال الأقصى للنموذج.
- النموذج الذي يحتوي على أقل قيمة هو الأنسب.

## 3. مقياس هانون-كويك (HQIC)

يعتمد على حجم العينة. يتم حسابه عن طريق الجمع بين الاحتمال الأقصى للنموذج وعدد المعلمات مع أخذ اللوجاريتم لعدد العينات. يوفر HQIC توازنًا بين العقوبات التي تفرضها AIC و BIC، مما يجعله مناسبًا في بعض الحالات التي تتطلب اختيار نموذج مناسب عند توافر عدد كبير من المعلمات والعينات.

$$HQIC = 2\ln(L) + 2k\ln(\ln(n)) \dots \dots \dots (13)$$

- $n$  عدد العينات.
- $k$  عدد المعلمات.
- $L$  الاحتمال الأقصى للنموذج.

## 3- التطبيق العملي لتحليل البيانات

### 3-1 معالجة الحالات: (Case Processing)

جدول Case Processing Summary(1-3)

		N	Percent
Sample	Training	260	91.5%
	Testing	24	8.5%
	Valid	284	100.0%
	Excluded	12	
	Total	296	

### تحليل معالجة الحالات: (Case Processing Summary)

يوضح الجدول السابق توزيع البيانات المستخدمة في بناء النموذج بين عيني التدريب والاختبار. من إجمالي 296 حالة مسجلة، تم اعتماد 284 حالة كبيانات صالحة (Valid)، بينما تم استبعاد 12 حالة بسبب نقص البيانات أو وجود قيم متطرفة لا تتوافق مع شروط المعالجة الإحصائية. تم تقسيم الحالات الصالحة إلى:

- **عينة التدريب: (Training Sample)** بلغ عددها 260 حالة، وهو ما يمثل 91.5% من إجمالي البيانات المستخدمة. تم استخدام هذه العينة لتدريب نموذج الشبكة العصبية ذات الأساس الشعاعي (RBF)، وتحديد الأوزان والمعلمات التي تعبر عن العلاقات بين المتغيرات.
- **عينة الاختبار: (Testing Sample)** بلغ عددها 24 حالة فقط، بنسبة 8.5% من البيانات، وقد خُصصت لاختبار قدرة النموذج على التنبؤ بالقيم الجديدة غير المرئية سابقاً، بما يضمن تقييم موضوعي لأداء النموذج وقياس قدرته على التعميم.

تشير هذه النسب إلى اتباع نهج متوازن يتيح للنموذج التعلم بشكل كافٍ مع وجود بيانات مستقلة لتقييم فعاليته، وهو أمر ضروري للتحقق من قوة النموذج وموثوقية نتائجه التنبؤية.

## 2-3 مواصفات الشبكات العصبية ذات الأساس الشعاعي RBF

جدول (2-3) Network Information

		1	Y1
		2	Y2
		3	Y3
		4	Y4
		5	Y5
		6	Y6
	Covariates	7	Y7
Input Layer		8	Y8
		9	Y9
		10	Y10
		11	Y11
		12	Y12
	Number of Units		12
	Rescaling Method for Covariates		Standardized
Hidden Layer	Number of Units		6 <sup>a</sup>
	Activation Function		Softmax
	Dependent Variables	1	X1
	Number of Units		1
Output Layer	Rescaling Method for Scale Dependents		Standardized
	Activation Function		Identity
	Error Function		Sum of Squares

a. Determined by the testing data criterion: The "best" number of hidden units is the one that yields the smallest error in the testing data.

**ملاحظة :** يشير الحرف (a) إلى أن اختيار عدد الوحدات في الطبقة المخفية قد تم عبر آلية تعتمد على أداء النموذج في مجموعة الاختبار، مما يعكس نهجاً تجريبياً في تحسين بنية الشبكة لتقليل الخطأ التنبؤي وزيادة القدرة على التعميم.

يعرض الجدول السابق البنية التفصيلية لنموذج الشبكة العصبية المستخدم في التنبؤ بمتغير الإنتاج ( $X_1$ )، اعتماداً على مجموعة من المتغيرات المدخلة ( $Y_1$  إلى  $Y_{12}$ ) ويتكون النموذج من ثلاث طبقات رئيسية. أولاً، طبقة الإدخال (Input Layer) التي تضم 12 متغيراً مستقلاً تمثل العوامل المؤثرة في إنتاج النفط. وقد خضعت هذه المتغيرات لعملية التقييس (Standardization) بهدف توحيد مدى القيم وتقليل أثر التباين في المقاييس. عدد الوحدات في هذه الطبقة يطابق عدد المتغيرات (12 وحدة إدخال). ثانياً، الطبقة المخفية (Hidden Layer)، وهي مكونة من ست وحدات عصبية (Neurons)، وقد تم تحديد هذا العدد بناءً على أداء النموذج في بيانات الاختبار، حيث اعتُبر الأمثل لتحقيق أدنى خطأ تنبؤي. وقد تم اعتماد دالة التنشيط Softmax في هذه الطبقة، والتي غالباً ما تُستخدم في سياق التصنيفات متعددة الأصناف، ويُحتمل أن استخدامها هنا يعكس نمطاً من التوزيع الاحتمالي الداخلي ضمن التمثيل الشبكي. ثالثاً، طبقة الإخراج (Output Layer)، والتي تحتوي على متغير تابع واحد هو ( $X_1$ )، ويمثل القيمة المنتبأ بها لإنتاج النفط. كما تم تقييس هذا المتغير بالتوازي مع المدخلات لضمان التوازن. وقد استخدمت هذه الطبقة دالة تنشيط خطية (Identity Function)، مما يشير إلى أن المخرجات تُنتج بشكل مباشر دون تحويل غير خطي، وهو ملائم للتعامل مع البيانات الكمية المستمرة. أما دالة الخطأ المعتمدة فهي مجموع المربعات (Sum of Squares)، وهي من المقاييس الإحصائية الشائعة المستخدمة في تقييم أداء النماذج التنبؤية، لاسيما في حالات الانحدار، حيث تُقارن القيم الحقيقية مع المتوقعة بهدف تقليل الفرق بينها.

### 3-3 تقييم أداء النموذج RBF

جدول (3-3) أداء النموذج RBF الخاص بالتنبؤ بالمتغير التابع  $X_6$

## Model Summary

	Sum of Squares Error	8.092
Training	Relative Error	.087
	Training Time	0:00:01.92
Testing	Sum of Squares Error	.370 <sup>a</sup>
	Relative Error	1.110

Dependent Variable: X<sub>6</sub>

a. The number of hidden units is determined by the testing data criterion: The "best" number of hidden units is the one that yields the smallest error in the testing data.

يشير ملخص النموذج إلى تقييم أداء شبكة عصبية اصطناعية تم تدريبها للتنبؤ بالمتغير التابع X<sub>6</sub> اعتمادًا على مجموعة من المدخلات ( Y<sub>1</sub> إلى Y<sub>12</sub> ) تم استخدام معيار خطأ المربعات ( Sum of Squares Error ) بالإضافة إلى الخطأ النسبي ( Relative Error ) لتقييم أداء النموذج في مرحلتي التدريب والاختبار. ويوضح هذا الملخص عدة مؤشرات إحصائية مهمة:

من منظور إحصائي، يُفهم من التباين بين نتائج التدريب والاختبار وجود مشكلة فرط التخصيص (Overfitting)، حيث يتعلم النموذج تفاصيل دقيقة في بيانات التدريب يصعب عليه تعميمها عند مواجهة بيانات جديدة. هذا النوع من النماذج يحقق دقة عالية في التنبؤ داخل العينة ولكنه يفشل في تقديم توقعات دقيقة خارجها، مما يفقده القوة التنبؤية الحقيقية.

كما تجدر الإشارة إلى أن ثبات المتغير X<sub>6</sub> عبر سلسلة البيانات الزمنية السابقة (حيث كان يأخذ قيمة ثابتة تقريبًا عند 5832) قد يفسر ضعف أداء النموذج، إذ أن المتغيرات المستقلة Y<sub>1</sub> إلى Y<sub>12</sub> ربما لا تقدم معلومات كافية أو ذات علاقة قوية بالمتغير الهدف. في هذا السياق، من الضروري إجراء تحليل ارتباط أو اختبار معنوية لتحديد ما إذا كان X<sub>6</sub> بالفعل متغيرًا قابلاً للتنبؤ ضمن النموذج المقترح.

## 3-4 التقديرات البارامترية (Parameter Estimates)

جدول (3-4) التقديرات البارامترية الخاص بنموذج الشبكة العصبية RBF

**Parameter Estimates**

Predictor	Predicted									
	Hidden Layer <sup>a</sup>								Output Layer	
	H(1)	H(2)	H(3)	H(4)	H(5)	H(6)	H(7)	H(8)	x6	
Input Layer	Y1	-	-	-	.979	.152	.634	.247	-	
		1.808-	1.583-	1.035-					.449-	
	Y2	-	-	-.997-	.991	.205	.589	.157	-	
		1.841-	1.516-						.423-	
	Y3	-	-	-.962-	1.003	.253	.537	.049	-	
		1.870-	1.450-						.369-	
	Y4	-	-	-.924-	1.008	.325	.450	-	-	
		1.891-	1.423-					.051-	.294-	
	Y5	-	-	-.863-	1.006	.395	.394	-	-	
	1.905-	1.420-					.156-	.241-		
Y6	-	-	-.774-	1.000	.453	.342	-	-		
	1.919-	1.429-					.238-	.197-		
Y7	-	-	-.756-	.994	.508	.291	-	-		
	1.935-	1.385-					.303-	.148-		
Y8	-	-	-.740-	.983	.555	.258	-	-		
	1.955-	1.325-					.363-	.099-		
Y9	-	-	-.724-	.961	.604	.213	-	-		
	1.970-	1.274-					.413-	.025-		

Y10	-	-	-.678-	.924	.654	.164	-	.028
	1.982-	1.251-					.407-	
Y11	-	-	-.630-	.880	.709	.097	-	.094
	1.992-	1.217-					.393-	
Y12	-	-	-.569-	.832	.713	.087	-	.166
	2.006-	1.156-					.371-	
Hidden Unit Width	.351	.290	.327	.406	.460	.544	.466	.331
H(1)								-1.783-
H(2)								-1.637-
H(3)								-1.097-
H(4)								.959
Hidden Layer H(5)								-.025-
H(6)								.712
H(7)								.288
H(8)								-.485-

a. Displays the center vector for each hidden unit.

يعرض الجدول السابق معامل التأثير (أو الأوزان الترابطية) بين الوحدات في طبقات الشبكة العصبية، بداية من الطبقة المدخلة (Input Layer) التي تضم المتغيرات  $Y_1$  إلى  $Y_{12}$ ، مروراً بالطبقة الخفية (Hidden Layer) التي تتكون من ثمان وحدات مخفية ( $H_1$  إلى  $H_8$ )، وصولاً إلى الطبقة الناتجة (Output Layer) التي تمثل المتغير المستهدف  $X_6$ .

- النموذج يُظهر علاقات غير خطية مركبة بين المتغيرات  $Y1$  إلى  $Y12$  والمتغير الهدف  $X_6$ ، يتم تمثيلها من خلال تحويل هذه المتغيرات عبر 8 وحدات مخفية تتفاعل بطرق مختلفة.
- الأوزان السالبة والموجبة تشير إلى تفاعل معقد بين المتغيرات المستقلة والنتيجة، بما يتماشى مع قدرة الشبكات العصبية على التقاط الأنماط غير الخطية.
- تحليل الأوزان يسمح بفهم مساهمة كل متغير، ويساعد في تفسير بنية النموذج وتقييم احتمالية وجود متغيرات غير فعالة يمكن استبعادها لتحسين النموذج وتقليل تعقيده.

### 3-5 أهمية المتغيرات المستقلة ( $Y1$ إلى $Y12$ ) في التنبؤ

جدول (3-5) أهمية المتغيرات المستقلة (  $Y1$  إلى  $Y12$  ) في التنبؤ

Independent Variable Importance

	Importance	Normalized Importance
Y1	.118	100.0%
Y2	.108	91.3%
Y3	.098	83.0%
Y4	.088	74.7%
Y5	.086	72.3%
Y6	.077	65.3%
Y7	.074	62.5%
Y8	.072	60.5%
Y9	.070	59.5%
Y10	.069	58.6%

Y11	.069	58.6%
Y12	.070	58.9%

الجدول السابق يُظهر أهمية المتغيرات المستقلة ( Y1 إلى Y12 ) في التنبؤ بالمتغير التابع (مثل  $x_6$ ) داخل نموذج الشبكة العصبية. ويوضح درجتين من الأهمية لكل متغير:

- Importance (الأهمية المطلقة): تمثل التأثير المباشر لكل متغير على أداء النموذج في التنبؤ.

- Normalized Importance (الأهمية المعيارية): تم تطبيعها بحيث تكون قيمة المتغير الأكثر أهمية  $100\% = (Y1)$  ، وتُستخدم للمقارنة النسبية بين المتغيرات.

تشير القيم الواردة في الجدول السابق إلى أن النموذج يعتمد بدرجة أكبر على عدد محدود من المتغيرات، وتحديدًا Y1 و Y2 و Y3، والتي قد تحتوي على المعلومات الأكثر تمثيلاً لسلوك المتغير التابع. كما يُوصى بالتركيز على هذه المتغيرات الأكثر أهمية عند تحليل العلاقات أو تحسين النموذج، وربما إعادة تقييم الحاجة إلى استخدام كل المتغيرات الأخرى الأقل أهمية في نسخ مبسطة أو مختزلة من النموذج.

### 3-6 التنبؤ باستخدام نموذج الشبكات العصبية RBF

جدول رقم (3-6) القيم المتنبأ بها باستخدام RBF خلال الفترة من يوليو 2009 إلى يونيو 2011.

RBF	X1	X2	X3	X4	X5	X6
JUL 2009	18770	4885	6735	5219	4462	5832
AUG 2009	18770	4885	6735	5161	4501	5832
SEP 2009	18770	4885	6735	5148	4373	5832
OCT 2009	18770	4885	6736	5143	4079	5832

RBF	X1	X2	X3	X4	X5	X6
NOV 2009	18770	4885	6738	5150	3901	5832
DEC 2009	18770	4885	6741	5299	3707	5832
JAN 2010	18772	4885	6746	5701	3653	5832
FEB 2010	18774	4885	6753	5847	3645	5832
MAR 2010	18779	4885	6747	5848	3647	5832
APR 2010	18786	4885	6703	5790	3651	5832
MAY 2010	18791	4885	6648	5730	3649	5832
JUN 2010	18797	4885	6602	5703	3644	5832
JUL 2010	18842	4885	6568	5694	3642	5832
AUG 2010	18962	4885	6527	5638	3642	5832
SEP 2010	19241	4885	6519	5575	3642	5832
OCT 2010	19733	4885	6547	5508	3642	5832
NOV 2010	20301	4885	6615	5437	3642	5832
DEC 2010	20709	4885	6720	5364	3642	5832
JAN 2011	20915	4885	6854	5291	3642	5832
FEB 2011	21001	4885	6986	5218	3642	5832
MAR 2011	21034	4885	7085	5148	3643	5832
APR 2011	21047	4885	7146	5081	3643	5832

RBF	X1	X2	X3	X4	X5	X6
MAY 2011	21051	4885	7189	5018	3643	5832
JUN 2011	21053	4886	7243	4958	3643	5832

يعرض هذا الجدول القيم المتوقعة التي تم التنبؤ بها باستخدام نموذج الشبكات العصبية ذات دالة الأساس الشعاعية (Radial Basis Function - RBF). تم تدريب النموذج باستخدام بيانات سابقة لمجموعة من المتغيرات المستقلة ( X1 إلى X6 ) بهدف التنبؤ بالمتغير التابع RBF خلال الفترة الزمنية الممتدة من يوليو 2009 حتى يونيو 2011.

### ملاحظات تحليلية حول النتائج

أظهرت القيمة المتنبأ بها لنموذج RBF اتجاهًا تصاعديًا ثابتًا، حيث بدأت من 18770 في يوليو 2009 ووصلت إلى 21053 في يونيو 2011. حيث يعكس هذا المسار التصاعدي قدرة النموذج على التقاط ديناميكية زمنية مستقرة تميل إلى الزيادة التدريجية، مما يدل على فعاليته في محاكاة الاتجاهات العامة طويلة الأجل.

### المتغيرات المستقلة ( X1 إلى X6 ) :

- **X1** بقيت شبه ثابتة عند 4885 طوال الفترة، مع استثناء طفيف في يونيو 2011 (4886)، مما يشير إلى مساهمة محدودة في تفسير التغيرات في RBF.
  - **X2** شهدت زيادة تدريجية ملحوظة، ويُرجح أن لها تأثيرًا مباشرًا في النمو الملحوظ في RBF.
  - **X3**، **X4**، **X5** أظهرت انخفاضًا تدريجيًا أو سلوكًا مستقرًا بعد فترة انخفاض، مما قد يشير إلى تأثير عكسي جزئي أو متغير مع الزمن.
  - **X6** بقيت ثابتة تمامًا عند القيمة 5832، مما يُحتمل أن يشير إلى أنها متغير ضابط (Control Variable) أو غير مؤثر في عملية التنبؤ بسبب غياب التغير الزمني.
- وفي هذه الحالة، أظهر النموذج كفاءة ملحوظة في تمثيل الأنماط العامة في البيانات، خاصةً الاتجاه التصاعدي في RBF، ما يدل على ملاءمته للتحليل الاقتصادي أو التنبؤ طويل المدى.

### 3-7 معاملات الارتباط بين القيم الفعلية والمنتبأ

فيما جدول يعرض معاملات الارتباط (Correlation) والقيمة الاحتمالية (2-tailed) Sig. لكل متغير  $x_i$  مع القيمة المنتبأ بها:

جدول (3-7) معاملات الارتباط بين القيم الفعلية والمنتبأ بها للمتغيرات X1 إلى X6

المتغير	معامل الارتباط (Pearson)	Sig. (2-tailed)	معامل الارتباط الثاني	Sig. الثانية	عدد القيم (N)
X1	0.957**	0.000	0.899**	0.000	260
X2	0.932**	0.000	0.766**	0.000	190
X3	0.963**	0.000	0.954**	0.000	140
X4	0.965**	0.000	0.948**	0.000	136
X5	0.944**	0.000	0.944**	0.000	169
X6	0.975**	0.000	0.956**	0.000	188

**Notice: . Correlation is significant at the 0.01 level (2-tailed).**

#### b. Listwise

N = عدد القيم لكل متغير

يعرض الجدول السابق نتائج تحليل الارتباط بيرسون (Pearson Correlation) بين القيم الفعلية (Observed) والقيم المنتبأ بها (Predicted) لمجموعة من المتغيرات (X1 إلى X6)، وهي من مخرجات نموذج تنبؤ الشبكات العصبية RBF. حيث يتضمن مستوى الدلالة الإحصائية (Sig.) لكل ارتباط، بالإضافة إلى حجم العينة المستخدمة في الحساب. (Listwise N)

### 3-8 المعايير الإحصائية لقدرة النموذج التنبؤية

جدول (3-8) المعايير الإحصائية لتقدير التنبؤ للنموذج

معامل الارتباط $\rho_1$	مؤشر الدلالة TS	معامل التحديد $R_2$	معامل ثيل Theil	متوسط القيمة المطلقة للأخطاء (MAE)	المتوسط النسبي للخطأ المطلق (MAPE)	الجذر التربيعي للخطأ (RMSE)	النموذج
0.03	2.3	0.983	0.01	143.5	0.98	227.5	X1 للشبكات
0.01	0.4	0.940	0.02	76.6	6.2	118.5	X2 للشبكات
0.02	14.1	0.974	0.02	102.3	2.6	147.9	X3 للشبكات
0.04	5.7	0.967	0.01	97.9	0.88	136.0	X4 للشبكات
0.04	6.9	0.957	0.04	218.7	5.26	329.4	X5 للشبكات
0.01	9.6	0.983	0.02	247.2	0.25	425.4	X6 للشبكات

يوضح الجدول السابق مؤشرات أداء نماذج الشبكات العصبية ذات دالة الأساس الشعاعية (Radial Basis Function Neural Networks - RBF)، الذي يشمل المتغيرات (X1 إلى X6)، يتم تقييم أداء كل نموذج حيث تُظهر مؤشرات الأداء الإحصائي لنماذج الشبكات العصبية ذات دالة الأساس الشعاعية (RBF) فعالية عالية في التنبؤ بجميع المتغيرات محل الدراسة، حيث اتسمت جميع النماذج بقيم معامل تحديد مرتفعة ( $R^2 > 0.94$ )، مما يعكس قدرة النموذج على تفسير نسبة كبيرة من التباين في البيانات، لاسيما في المتغيرين X1 و X6 اللذين سجلا أعلى قيمة ( $R^2 = 0.983$ ) من حيث حجم الخطأ الكلي، سجل المتغير X2 أقل قيمة للجذر التربيعي للخطأ ( $RMSE = 118.5$ ) ما يدل على دقة عددية ممتازة، بينما ظهر أعلى RMSE في المتغير X6، إلا أن انخفاض قيمة MAPE لديه (0.25%) يفسر هذا بوجود قيم عددية كبيرة نسبياً في البيانات الأصلية. وفيما يخص النسبة المئوية للخطأ، أظهر X6 أفضل أداء ( $MAPE = 0.25\%$ )، بينما سجل X5 أعلى نسبة خطأ نسبي (5.26%)، مما يشير إلى ضعف نسبي في النموذج بالنسبة لهذا المتغير. وعلى مستوى كفاءة النموذج وفقاً لمعامل ثيل (Theil's U)، جاءت جميع القيم أقل من 0.05، مما يدل على تفوق النماذج على التنبؤ العشوائي. أما مؤشر TS، فقد كانت القيم منخفضة في X1 و X2، وهي سمة مثالية، في حين ظهرت قيم مرتفعة نسبياً في X3 و X5 و X6، ما قد يشير إلى وجود تحيزات تتطلب مراجعة أو تحسين النماذج المعنية. وأخيراً، عكست القيم المنخفضة

لمعامل الارتباط الزمني الذاتي للأخطاء ( $\rho_1$ ) بين 0.01 و 0.04 جودة النماذج من حيث عدم ارتباط الأخطاء زمنيًا، وهو مؤشر إيجابي. وعليه، يمكن القول إن الأداء الإحصائي العام لنماذج RBF كان متميزًا، لا سيما في المتغيرات X1 و X6، مع توصية بمراجعة أدائية النماذج الخاصة بـ X5 و X3 نظرًا لارتفاع مؤشرات الخطأ النسبي والانحراف في التنبؤات

### 3-9 المعايير الإحصائية لتقييم جودة نموذج RBF

جدول (3-9) المعايير الإحصائية لتقييم جودة نموذج RBF

يعكس الجدول الخاص بتقييم نموذج الشبكات العصبية ذات دالة الأساس الشعاعية

المعيار	القيمة
معامل التحديد (R-squared)	0.974349
القيمة المعدلة لمعامل التحديد (Adjusted R-squared)	0.974112
الخطأ القياسي للانحدار (S.E. of regression)	951.4600
مجموع مربعات البواقي (Sum squared resid)	2.93E+08
لوغاريتم دالة الإمكان (Log likelihood)	-2712.823
متوسط المتغير التابع (Mean dependent var)	19404.66
الانحراف المعياري للمتغير التابع (S.D. dependent var)	5913.451
معيار أكايكي (Akaike info criterion)	16.56599
معيار شوارتز (Schwarz criterion)	16.61225
معيار هانان-كوين (Hannan-Quinn criter.)	16.58445

(RBF) أداءً إحصائيًا متميزًا، حيث يُظهر معامل التحديد ( $R\text{-squared} = 0.974349$ ) أن النموذج قادر على تفسير نحو 97.4% من التباين الكلي في المتغير التابع، وهي نسبة مرتفعة

تشير إلى دقة التمثيل. كما أن القيمة المعدلة لمعامل التحديد (Adjusted R-squared = 0.974112)، القريبة جدًا من  $R^2$ ، تؤكد عدم وجود مشكلة الإفراط في التقدير (Overfitting)، ما يُعزز من موثوقية النموذج حتى مع وجود أكثر من متغير مستقل. أما الخطأ القياسي للانحدار (S.E. = 951.46) فيعكس مدى قرب التقديرات من القيم الحقيقية، وهو منخفض نسبيًا، مما يدل على دقة التنبؤات. وبالرغم من أن مجموع مربعات البواقي (Sum Squared Residuals =  $2.93E+08$ ) يبدو كبيرًا، فإن هذه القيمة قد تكون منطقية بالنظر إلى اتساع نطاق البيانات أو عددها. وتشير قيمة لوغاريتم دالة الإمكان (Log Likelihood = -2712.823) إلى جودة مقبولة في التفسير، حيث تُستخدم هذه القيمة في حساب معايير تقييم النموذج مثل Akaike (16.566)، Schwarz (16.612)، وHannan-Quinn (16.584)، وجميعها تُظهر تقاربًا جيدًا، ما يعكس توازنًا فعالًا بين جودة التقدير وعدد المعلمات المستخدمة. ويُكمل ذلك تحليل متوسط المتغير التابع (19404.66) والانحراف المعياري له (5913.451)، واللذان يوضحان خصائص توزيع البيانات قيد الدراسة. تُبرز هذه النتائج مجتمعةً كفاءة نموذج RBF، مما يدعم استخدامه في التطبيقات التي تتطلب دقة عالية في التنبؤ وتحليل السلاسل الزمنية.

### 10-3 النتائج :

تشير النتائج إلى أن :-

- النموذج التنبؤي المستخدم يتمتع بدقة تنبؤية عالية جدًا لجميع المتغيرات المدروسة، حيث أظهرت جميع معاملات بيرسون للارتباط قيمًا مرتفعة ذات دلالة إحصائية عالية. ( $p < 0.01$ ) وتعد هذه النتائج مؤشرًا قويًا على كفاءة النموذج في تمثيل الأنماط الإحصائية الكامنة في البيانات، مما يعزز من موثوقيته في تطبيقات التنبؤ والتحليل.
- نموذج RBF يتمتع بجودة تفسير عالية وكفاءة مناسبة، مع دقة مقبولة في التقدير وملاءمة إحصائية قوية. تعتبر القيم المنخفضة لمعايير AIC و SIC و HQC، إلى جانب  $R^2$  المرتفع، دليلًا على نموذج إحصائي موثوق يمكن الاعتماد عليه لأغراض التنبؤ والتنبؤ في السياقات الزمنية أو التطبيقية ذات الطبيعة المعقدة.
- النماذج كانت فعالة بشكل عام في التنبؤ بجميع المتغيرات، وخصوصًا  $X1$  و  $X6$ .
- توجد حاجة لمراجعة وتحسين نموذج  $X5$  و  $X3$  بسبب الارتفاع في مؤشري MAPE و TS.

- الأداء الإحصائي العام لنماذج RBF يُعدّ ممتازًا، مع وجود دقة مرتفعة وتباين منخفض في الأخطاء، مما يعزز من ثقة استخدام هذه الشبكات في التطبيقات الزمنية والتنبؤية.
- أفضل أداء من حيث الاتساق والدقة كان مع X1 وX6.
- X5 هو الأضعف نسبيًا من حيث MAPE و RMSE، ويُفضل مراجعته أو تحسينه.
- معامل ثيل في جميع الحالات أقل من 0.05، وهو مؤشر على أن النماذج أفضل بكثير.
- TS العالي في (14.1) X3 قد يشير إلى نمط غير متوازن في التنبؤات، مما يتطلب فحصًا أعمق.

#### 4- التوصيات

بناءً على البيانات والتحليلات السابقة المتعلقة بتقييم أداء نموذج الشبكات العصبية ذات دالة الأساس الشعاعية (RBF)، يمكن صياغة التوصيات التالية:

1. تعزيز استخدام نموذج RBF في التطبيقات التنبؤية: نظرًا للكفاءة العالية التي أظهرها النموذج في تفسير أكثر من 97% من التباين في المتغيرات التابعة، ودقته النسبية في التنبؤات، يُنصح باعتماد نموذج RBF كأسلوب رئيسي في تحليل البيانات الزمنية والتنبؤ المستقبلي في المجالات المشابهة.
2. مراجعة أداء بعض المتغيرات ذات الأداء الأقل وتحسينها: على الرغم من الأداء الجيد للنموذج بشكل عام، فإنّ بعض المتغيرات أظهرت مؤشرات خطأ أعلى مثل MAPE و TS، مما يستدعي إجراء مراجعة متعمقة لتلك المتغيرات (مثل X3 و X5) بهدف تحسين دقة التنبؤ من خلال تعديل المعلمات أو زيادة جودة البيانات المدخلة.
3. الاهتمام بتقليل الانحرافات وتحييد الانحيازات في التنبؤات: تشير مؤشرات مثل مؤشر التبع (TS) المرتفع لبعض المتغيرات إلى وجود تحيزات محتملة أو نمط انحراف في الأخطاء التنبؤية، لذا يُوصى باستخدام تقنيات تعديل الأخطاء أو إعادة تدريب النموذج بشكل دوري لضمان استقرار التنبؤات.
4. استخدام معايير اختيار النموذج كأداة مستمرة للتقييم: ينبغي الاستمرار في مراقبة معايير Akaike، و Schwarz، و Hannan-Quinn للتقييم مدى ملاءمة النموذج مع البيانات الجديدة أو عند إدخال متغيرات إضافية، بهدف الحفاظ على توازن فعال بين دقة التقدير وتعقيد النموذج.

5. زيادة حجم وجودة البيانات لتحسين النموذج : نظرًا لأن بعض المؤشرات مثل RMSE قد تتأثر بحجم البيانات، فمن المهم تعزيز جودة وتنوع البيانات المستخدمة في التدريب، مما يساعد في تقليل الخطأ وتحسين قدرة النموذج على التعميم.

6. دمج نماذج أخرى للمقارنة والتكامل : لزيادة موثوقية التنبؤات، يُنصح بإجراء تحليلات مقارنة مع نماذج أخرى مثل الشبكات العصبية متعددة الطبقات (MLP) أو نماذج الانحدار الذاتي المتجهة (VAR) ، وكذلك إمكانية دمجها مع نموذج RBF لتعزيز الدقة.

بهذه التوصيات، يمكن تعزيز الاستفادة من نموذج RBF وتحقيق أفضل النتائج في تطبيقات التنبؤ وتحليل البيانات المعقدة، مع الحفاظ على استمرارية التطوير والتحسين.

## مراجع عربية

1. عبد الرحمن، س. (2023). تحليل الشبكات العصبية ذات الأساس الشعاعي لمقياس إدمان تطبيقات الهواتف الذكية وانتشاره لعينة من المراهقين المصريين. مجلة العلوم التربوية، العدد الرابع، 89-102.

2. محمد، ع. (2020). استخدام الشبكات العصبية ذات الأساس الشعاعي في تطوير دور مراقب الحسابات في اكتشاف الأخطاء الجوهرية. مجلة البحوث المحاسبية، العدد الخامس، 45-67.

## References

3. Alizamir, M., Kisi, O., Ahmed, A. N., & Mert, C. (2020). Advanced hybrid RBF models for groundwater level prediction. *Environmental Earth Sciences*, 79(12), 1–15. <https://doi.org/10.1007/s12665-020-09034-y>
4. Li, Y. (2025). Radial basis function neural network and response surface for drilling-related predictions. *Processes*, 13(1), 145. <https://doi.org/10.3390/pr13010145>
5. Przybyła-Kasperek, M. (2024). MLP and RBF comparison for classification tasks. *Applied Sciences*, 14(2), 897. <https://doi.org/10.3390/app14020897>
6. Zhao, L., Luo, Z., Deng, G., & Shi, V. (2023). Prediction of corrosion failure probability of buried oil and gas pipeline based on an RBF neural network. *Journal of Loss Prevention in the Process Industries*, 81, 104745. <https://doi.org/10.1016>
7. Zhang, X., Luo, W., Liu, G., Yu, B., Bo, W., & Zhao, P. (2024). An improved radial basis function neural network for landslide displacement prediction. *Frontiers in Earth Science*. <https://doi.org/10.3389/feart.2024.1389161>