

دراسة مقارنة بين الشبكات العصبية الاصطناعية ونماذج الانحدار أشعة الدعم

للتنبؤ بأسعار البترول خلال الفترة (1990-2019)

*A Comparison Of Artificial Neural Networks And Support Vector Regression Models For Forecasting Oil Prices during the period (1990-2019)*ساهد عبد القادر، المركز الجامعي مغنية، مخبر LPESSE sahed14@yahoo.frقهوي حسن، المركز الجامعي مغنية، مخبر MIFMA hacenkahwi@gmail.com

تاريخ الاستلام: 2020/08/20 تاريخ القبول: 2020/10/16 تاريخ النشر: 2022/12/30

ملخص: تهدف هذه الدراسة إلى المقارنة بين نماذج الشبكات العصبية الاصطناعية من النوع الشبكات المتعددة الطبقات ونماذج الانحدار أشعة الدعم للتنبؤ بأسعار البترول الخام الشهرية. لذلك، تم استخدام أسعار البترول للفترة من جانفي 1990 إلى ديسمبر 2019، حيث تم الاستناد في هذه المقارنة بين هاتين المقاربتين على كلا من معيار متوسط مربعات الاخطاء MSE ومعيار جذر متوسط مربعات الاخطاء RMSE. وقد أظهرت النتائج أن نماذج الانحدار أشعة الدعم أكثر كفاءة وأداء للتنبؤ بالقيم المستقبلية للسلسلة أسعار البترول من نماذج الشبكات العصبية متعددة الطبقات.

الكلمات المفتاحية: التنبؤ؛ أسعار البترول؛ MLP؛ SVR؛ RMSE

تصنيف JEL: C53، G11، C22، C45

Abstract: This study aims to compare between the Multilayer Perceptron Network (MLP) and Support Vector Regression (SVR). the study used the monthly oil price during 1990 to 2019. The comparison of these two approaches is based on the mean squared error (MSE) and the root mean squared error (RMSE). the results indicated that the Support Vector Regression are better and more efficient than the Multilayer Perceptron network models in forecasting oil prices .

keyword: Forecasting; Oil Prices; MLP; SVR; RMSE.**JEL classification code :** C53, G11, C22, C45.

المؤلف المرسل: ساهد عبد القادر،

الإيميل: sahed14@yahoo.fr

1. مقدمة:

يعتبر البترول سلعة أساسية للاقتصاديات العالمية أو بالأحرى يصنف كعنصر استراتيجي للتنمية الاقتصادية والنمو في البلدان الصناعية والنامية على الأرجح، كما لها تأثير كبير على التنمية الاقتصادية والاجتماعية والاستقرار وحتى الأمن القومي في بلد ما (Zhang, 2015, p. 649)، حيث يعد البترول اكبر سلعة وأكثر نشاط متداول في العالم ويمثل أكثر من 10 بالمائة من إجمالي التجارة العالمية (Yu, 2008, p. 2623)، ولهذا فان تقلبات أسعار البترول لها تأثير كبير على الأنشطة الاقتصادية في العالم وهذا من خلال عدة جوانب وكل هذه التقلبات راجعة إلى حد كبير في الاستجابة إلى قوى العرض والطلب (Zhao, 2017, p. 1)، وكذلك الأحداث الخارجية مثل الحرب والطقس... الخ وكذلك العوامل الداخلية المتمثلة في المضاربة في الأسواق (Haidar, 2008, p. 103).

لقد شهد موضوع التنبؤ بأسعار البترول مجموعة كبيرة من الأدبيات سواء كانت من حيث أنواع النماذج وعدد الطرق المستخدمة بشكل متزامن (Fazelabdolabadi, 2019, p. 1). في دراستنا سنتطرق إلى التنبؤ بأسعار البترول الخام وهذا راجع للعديد من الأسباب التي تلزمنا القيام به ونذكر منها السبب الرئيسي أن البترول يساهم بنسبة 98 في المائة من الاقتصاد الوطني. تم الاعتماد في هذه الدراسة على استخدام بعض تقنيات الذكاء الاصطناعي المتمثلة في شعاع الدعم الآلي (SVM) والشبكات العصبية الاصطناعية من نوع Multilayer Preceptron، ومن بين الأسباب في اختيارنا لهذه التقنيات كونها لديها دور فعال في تقدير الأنماط غير الخطية وباعتبار السلسلة الزمنية لأسعار البترول تتميز بهذه الخاصية والعشوائية في نفس الوقت (Guo, 2012, p. 526). ومن اجل معرفة النموذج الأفضل والذي يمكننا الاعتماد عليه في التنبؤ بأسعار البترول تم الاستناد على معايير دقة التنبؤ والمفاضلة كل من معيار متوسط مربعات الاخطاء (MSE) ومعيار جذر متوسط مربعات الاخطاء (RMSE).

لذلك، تعددت الدراسات حول موضوع التنبؤ بأسعار البترول، حيث تم اجراء العديد من الدراسات باستخدام نماذج الشبكات العصبية مختلف أنواعها، ودراسات أهتمت بنماذج السلاسل الزمنية، في حين أن هناك العديد من الدراسات توصلت إلى نتائج جيدة باستخدام نماذج الانحدار أشعة الدعم الآلي. نذكر منها ما يلي:

دراسة Xie et al سنة 2006 بعنوان طريقة جديدة للتنبؤ بسعر البترول بناء على دعم شعاع الآلة، حيث هدفت هذه الدراسة التنبؤ بأسعار البترول لغرب تكساس، وهذا للمدة الزمنية الممتدة من يناير 1970 إلى ديسمبر 2003 باستخدام نموذج دعم شعاع الآلة (SVM)، للتنبؤ بالسلسلة الزمنية من خلال أخذ البيانات ومعالجة البيانات المسبقة والتدريب والتعلم والتنبؤ خارج العينة وهذا من اجل تقييم قدرة التنبؤ لها، ومقارنتها مع نموذج ARIMA وBPNN. أظهرت النتائج أن SVM تفوق على كلا الطريقتين وانه بإمكانية الاعتماد عليها في التنبؤ بأسعار البترول.

دراسة Wang and Wu سنة 2012 بعنوان التنبؤ بأسعار البترول استنادا إلى خوارزمية التكامل بين ARIMA وBP Neural Network، هدفت هذه الدراسة الى تقديم خوارزمية تجمع بين الشبكات العصبية BP ونموذج ARIMA ومقارنتها مع نموذج BP وARIMA للتنبؤ بأسعار البترول بينت النتائج أن خوارزمية الجمع بين BP وARIMA تتمتع بأعلى دقة في التنبؤ مقارنة مع ARIMA وBP .

دراسة Mostafa-El Masry سنة 2016 بعنوان التنبؤ بأسعار البترول باستخدام برمجة التعبير الجينية GEP والشبكة العصبية الاصطناعية، وهذا للفترة الممتدة من 2 يناير 1986 إلى 12 جوان 2012 ، واستخدام معيار جذر متوسط مربعات الخطأ و متوسط الخطأ المطلق من اجل المقارنة، بينت النتائج أن نموذج GEP تفوق على NN وARIMA.

دراسة Hamid and Aloui سنة 2016 بعنوان مقارنة دالة الارتباط للشبكة العصبية الاصطناعية و الشبكة العصبية متعددة الطبقات ذات تغذية إلى الأمام للتنبؤ بأسعار البترول، هدفت هذه الدراسة إلى استخدام الشبكة العصبية الاصطناعية FLANN باستخدام قاعدة الانتشار الخلفي للتنبؤ بالسعر الفوري للبترول الأمريكي ومقارنتها بالشبكة العصبية متعددة الطبقات بتغذية الانتشار الخلفي للشبكة العصبية الأمامية FNN، تم استخدام معيار الجذر التربيعي للمربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) من اجل المقارنة، أظهرت النتائج أن نموذج FLANN يعمل بشكل أفضل من FNN.

دراسة Chang et al سنة 2019 بعنوان نموذج VEC-NAR للتنبؤ على المدى القصير للأسعار البترول، حيث هدفت هذه الدراسة إلى التنبؤ بأسعار البترول للفترة الممتدة من 1 يناير 2003 إلى 31 ديسمبر 2014 وهذا باستخدام نموذج التهجين بين شعاع

تصحيح الخطأ والشبكة العصبية، وتم استخدام اختبار Diebold-Mariano للتحديد دقة التنبؤ مقارنة مع النماذج التقليدية مثل GARCH و VAR و VEC و NAR، بينت النتائج أن نموذج الهجين VEC-NAR تفوق على النماذج التقليدية من حيث دقة التنبؤ .

دراسة عماد غزالي، سنة 2020، بعنوان نمذجة تقلبات أسعار نפט البرنت باستخدام نماذج الانحدار الذاتي المشروطة بعدم ثبات التباين للفترة (جانفي 1990 - جويلية 2019)، حيث هدفت هذه الدراسة إلى محاولة نمذجة تقلبات أسعار النفط، وذلك باستخدام المفاضلة بين نماذج الانحدار الذاتي المشروطة بعدم ثبات التباين لسلسلة شهرية لاسعار نפט برنت خلال الفترة الممتدة من شهر جانفي 1990 إلى غاية شهر جويلية 2019، ومحاولة التنبؤ بأسعاره للأشهر المتبقية لسنة 2019. وتوصلت الدراسة الدارسة إلى أن سلسلة أسعار النفط البرنت تميزت بالتذبذب الكبير وعدم الاستقرار طيلة فترة الدراسة.

إشكالية الدراسة:

من الطرح السابق تتبلور إشكالية هذه الدارسة على النحو التالي:

في ما مدى فعالية تطبيق نماذج الانحدار أشعة الدعم للتنبؤ بأسعار البترول مقارنة بنماذج الشبكات العصبية الاصطناعية؟

وللإجابة على الإشكالية قمنا بطرح مجموعة من الأسئلة الفرعية والتي تتمثل فيما يلي:

1. ما هي خطوات تطبيق نماذج الشبكات العصبية؟
2. ما هي خطوات تطبيق نماذج الانحدار أشعة الدعم؟
3. كيف يمكن المقارنة بين نماذج الشبكات العصبية ونماذج الانحدار أشعة الدعم في التنبؤ بأسعار البترول؟

فرضيات الدراسة:

لدراسة إشكالية الموضوع قمنا بوضع فرضية تم استنباطها من خلال الدارسات السابقة مفادها: استخدام نماذج الانحدار أشعة الدعم تعطي نتائج جيدة إذا ما تم مقارنتها بنماذج الشبكات العصبية في التنبؤ بأسعار البترول.

أهداف الدراسة:

أن الهدف الرئيسي من هذا البحث هو المقارنة بين نماذج الشبكات العصبية ونماذج الانحدار أشعة الدعم للتنبؤ بأسعار البترول. ولتحقيق هذا الهدف ينبغي تحقيق ما يلي:

- بناء نماذج الشبكات العصبية للتنبؤ بأسعار البترول.
- بناء نماذج الانحدار أشعة الدعم للتنبؤ بأسعار البترول.
- المقارنة بين نماذج الشبكات العصبية ونماذج الانحدار أشعة الدعم باستخدام مقاييس دقة التنبؤ المختلفة لاختيار النموذج الأمثل واستعماله للحصول على القيم التنبؤية النهائية لأسعار البترول.

2. منهجية الدراسة:


1.2. الشبكات العصبية الاصطناعية:

قبل التطرق إلى الشبكة العصبية الاصطناعية محل الدراسة من النوع متعددة الطبقات، سوف نعطي لمحة عن الشبكات العصبية الاصطناعية والتي يرمز باختصار (ANN)، إذ تعرف على أنها نموذج يحاكي الشبكة العصبية الحيوية (للإنسان)، حيث يقوم في طريقة استخدامه نفس الطرق الأساسية المستخدمة في النظم العصبية الطبيعية بمساعدة برمجيات محاكاة العقل البشري وأسلوب المعالجة المتوازنة، ومن الناحية الإحصائية يعبر عنها بأنها نموذج رياضي أو مجموعة من الأدوات المستعملة لنمذجة البيانات الإحصائية غير الخطية (حيدر حميد الكعبي، 2015، صفحة 6)، كما لها مجموعة من المهام التي يمكن معالجتها مثل التعرف على الأنماط، استخراج البيانات، التصنيف، التنبؤ، كما تتميز بمجموعة من الصفات مثل القدرة على التعلم، التعميم، المعالجة المتوازنة مما يجعل الشبكات العصبية الاصطناعية أسلوب له الكفاءة لحل المشكلات المعقدة بدقة ومرونة (Huang, 2004, p. 146)، ومهمة الشبكة العصبية الاصطناعية (j) تكمل في أنها تتلقى إشارات الإدخال (xi) موزونة بأوزان التوصيل (wi) من الخلايا العصبية المجاورة، تمثل مجموع هذه الإشارات الموزونة إجمالي الإدخال، وبعد مرحلة الإدخال تتم إضافة عتبة التنشيط للخلايا العصبية (j) وتكون ممثلة بقيمة موجبة أو سالبة (yj) إلى الإدخال الصافي وهذا من خلال تطبيق دالة رياضية $f(.)$ ، وعادة ما تكون غير خطية والمعروفة باسم دالة التنشيط، وهذا إلى الإدخال الصافي، وأخيرا تأتي مرحلة الإخراج، حيث يتم حسابا فيها قيمة (yj) وإرسالها إلى الخلايا العصبية الأخرى. (Palmer, 2006, p. 783).

2.2. الشبكات متعددة الطبقات (Multilayer Perceptron):

يعد هذا نوع من أنواع الشبكات العصبية الاصطناعية التي تلقت اهتمام كبير من طرف الباحثين، وهذا راجع لبراطتها وتطبيقاتها الناجحة في مختلف المجالات (Aras, 2017, p. 149)، تتكون شبكة MLP البسيطة من طبقة الإدخال (لا تقوم بالمعالجة) وطبقة إخراج واحدة وتتضمن طبقة مخفية على الأقل، تقوم عملية التعلم لهذه شبكة MLP بشكل عام عن طريق خوارزمية الانتشار الخلفي التي تعتبر الأكثر استخداما (Ramos, 2013, p. 9)، كما تعتبر شبكة ذات التغذية الأمامية، وتستخدم MLP تقنية التعلم الخاضعة للإشراف، والتي تعد من بين الأنواع الأكثر استخداما في التنبؤ بالسلاسل الزمنية (Vasudev, 2019, p. 23)، أنظر الشكل 1.

الشكل 1: الشبكات MLP



المصدر: Rasouli, 2016, p. 5

وتتمثل عملية التنبؤ باستخدام الشبكة العصبية للسلاسل الزمنية MLP (Khashei, 2019, p. 2631) في الخطوات التالية:

الخطوة الأولى: يتم في هذه الخطوة إدخال البيانات عن طريق طبقة الإدخال، حيث هنالك مشاكل في السلسلة الزمنية ولهذا يتم تزويد MLP بالقيمة المتأخرة الماضية للبيانات الفعلية $(y_{t-1}, \dots, y_{t-p})$ كمتجه إدخال، ولهذا فإن طبقة الإدخال تتكون من العقد p الموصول بالطبقة الخفية.

الخطوة الثانية: تأتي مرحلة الطبقة الخفية والتي تقع بين طبقة الإدخال وطبقة الإخراج ويتم تحديد عدد الطبقات الخفية حسب الدراسة، حيث في هذه المرحلة يعد تحديد نوع ودالة التنشيط مهم لأنها من خلالها يتم تحديد العلاقة بين طبقة الإدخال وطبقة الإخراج، وتعتبر دالة Logistic الأكثر استعمالا، وتأخذ الصيغة التالية (Maia, 2011, p. 742):

$$g(x) = \frac{1}{1 + \exp(-x)}$$

الخطوة الثالثة: وتمثل في مرحلة طبقة الإخراج، بعد تحديد دالة التنشيط وعدد العقد المناسبة، يتم استخدام مخرجات الشبكة العصبية للتنبؤ بالقيم المستقبلية للسلاسل الزمنية. أما فيما يخص الدالة المستخدمة للتنبؤ (Azadeh, 2008, p. 2274) وتأخذ الصيغة التالية:

$$Y_t = \alpha_0 + \sum_{j=1}^n \alpha_j f\left(\sum_{i=1}^m B_{ij} Y_{t-1} + B_{0j}\right) + \varepsilon_t$$

حيث تمثل:


$\{\alpha_j, j = 0, 1, \dots, n\}$: متجه الأوزان من الطبقة الخفية إلى عقد الإخراج.

$\{B_{ij}, i = 1, 2, \dots, m, j = 0, 1, \dots, n\}$ تمثل أوزان من طبقة الإدخال إلى عقد الطبقة الخفية.

3.2. شعاع الدعم الآلي SVM:

يعتبر شعاع الدعم الآلي (Support Vector Machin) من تقنيات التعلم الآلي، التي تم اقتراحها من طرف Vapnik و Corles سنة 1995 (Alade, 2020, p. 486)، وهي تقنية تستند إلى نظرية التعلم الإحصائي (Ensaifi, 2010, p. 867)، كما تستخدم للعديد من مهام التعلم الآلي مثل التعرف على الأنماط والتصنيف، وكذلك في حالة التنبؤ بالسلاسل الزمنية وتحليل الانحدار (Sapankevych, 2009, p. 27)، التي تصنف من نماذج التعلم تحت الإشراف مع خوارزميات التعلم، وبصفة عامة تستخدم في مشاكل التصنيف والانحدار (Mathew, 2019, p. 406)، وتتم طريقة SVM في الحصول على مستوى الأمثل لتقسيم البيانات إلى فئتين، أما فيما يخص حالة الانحدار فيتم بناءه بالقرب من أكبر عدد ممكن من النقاط (Radhika, 2009, p. 27)، أنظر الشكل 2.

الشكل 2: المستوى الفاصل الخطي للقيم الموجبة والقيم السالبة



المصدر: Nguyen, X. H, 2020, p 8

ومن خلال الشكل السابق يضح لنا أن الهدف من شعاع الدعم الالي هو ايجاد المستوى الفاصل بين الصنفين وتكون النقاط الاقرب إلى المستوى الفاصل عبارة عن المتجهات الداعمة (فوزية غالب عمر، 2018، الصفحات 87-112).

4.2. الانحدار أشعة الدعم SVR:

نفترض أن مجموعة بيانات التدريب معطاة على النحو التالي (Zaidi, 2010, p. 517):

$$\{(x_1, y_1), (x_2, y_2), \dots, \dots, (x_n, y_n)\} \subset \mathbb{R}^n \times \mathbb{R}$$

حيث تمثل:

x: تمثل نمط المدخلات.

y: تمثل نمط المخرجات.

n: يمثل عدد تدريب العينات، حيث يتم انشائها بشكل عشوائي.

فإن الهدف من الانحدار أشعة الدعم هو إيجاد الدالة $f(x, w, b)$ والتي تعطي بالعلاقة التالية (رضوان يوسف صديق، 2013، الصفحات 114-130):

$$f(x, w, b) = \langle w, \phi(x) \rangle + b$$

والفكرة هنا أننا نقوم بتذنية قيمة $\|w\|^2$ تحت قيد أن لا نتجاوز نسبة الخطأ المسموح بها

.E

ومن وجهة النظر البيانية نجد أن مستوى يضم كل الامثلة لـ x ذات العرض 2ε والتي تدعى بالانبوب (أنظر الشكل 2). بينما إذا تتجاوز المسافة بين الدائرة و f(x) نطاق الانحراف المسموح به ε ، فإن المسافة بين قيمته y_i و f(x) ستؤخذ في الاعتبار في حساب الخسارة الإجمالية. لذلك، يمكن صياغة مشكلة svm على النحو التالي:

$$L_\varepsilon(y, f(x)) = \begin{cases} 0, & \text{if } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon, & \text{otherwise} \end{cases}$$

حيث تدعى L_ε بدالة الخسارة من ε -insensitive.

إن الهدف من الانحدار أشعة الدعم هو تقليل من المخاطرة المتوقعة، وفي نفس الوقت الحد من التعقيد الموجود بالنموذج عن خلال التذنية لـ $\|w\|^2$ (Yuhu Zhang, 2019, pp. 1-18). وبإدخال متغيرات الركود يصبح نموذج svm من شكل التالي:

$$\text{minimize } \frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + \sum_{i=1}^N \xi_i^*$$

تحت القيود التالية:

$$\begin{aligned} w^T \phi(x_i) + b - y_i &\leq \varepsilon + \xi_i^* \\ y_i - w^T \phi(x_i) - b &\leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* &\geq 0, i = 1, \dots, N \end{aligned}$$

حيث تعرف المعلمات ξ_i^* , ξ_i بمتغيرات الركود والتي تقوم بعملية التصحيح.

و C تدل على مقدار الموازنة بين خطأ التقدير وكذا مقدار التباعد من المحور الرئيسي. واستخدام دالة لاغرونج يتم تحويلها إلى مشكلة ثنائية:

$$f(x) = \sum_{i=1}^n (\alpha'_i - \alpha_i) k(x, x_i) + b$$

α_i و α'_i هي عبارة عن مضروب لاغرونج، و $k(x, x_i)$ هي دالة الكارنل والتي يمكن استخدامها في حالة البيانات غير الخطية عن طريق حيلة يتم فيها تحول البيانات الاصلية إلى بيانات أخرى خطية، ومن بين دوال الكارنل الاكثر استخداما في نماذج شعاع الدعم الالي للانحدار نجد، كثير حدود ودالة الاساس الشعاعية (RBF) وسغمووند، ويكون الشكل الرياضي لها على النحو التالي:

$$K(X_i, X_j) = \begin{cases} X_i * X_j & \text{خطية} \\ (\gamma X_i * X_j + C)^d & \text{كثير حدود} \\ \exp(-\gamma |X - X|^2) & \text{RBF} \\ \tanh(\gamma X_i * X_j + C) & \text{سغمووند} \end{cases}$$

5.2. معايير دقة التنبؤ:

من بين معايير دقة التنبؤ الاكثر استخداما في قياس جودة التنبؤ نجد كل من متوسط مربع الخطأ والذي يعطى بالعلاقة التالية:

$$MSE = \frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)$$

وجذر متوسط مربع الخطأ والذي يعطى بالعلاقة التالية:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)}$$

حيث تمثل:

N حجم البيانات

y_t : القيمة الفعلية في الزمن t

\hat{y}_t : القيمة المتوقعة في الزمن t

إذ يعتبر النموذج الذي يتحصل على أقل قيمة لهذه المعايير احسن وأدق في عملية التنبؤ.

3. نتائج الدراسة:

1.3. مصدر البيانات:

سيتم الحصول على بيانات سلسلة أسعار البترول من خلال الموقع الالكتروني index mundi، إذ أن فترة الدراسة تمتد من جانفي 1990 إلى ديسمبر 2019، ما مجموعه 360 مشاهدة.

2.3. التنبؤ بأسعار البترول الخام باستخدام طريقة MLP

إن خطوات تطبيق طريقة MLP للتنبؤ بأسعار البترول الخام تتمثل فيما يلي:
تتمثل الخطوة الاولى في تحديد المتغير التابع والممثل بسعر البترول في اللحظة t، أما فيما يخص المتغيرات المستقلة فقد تم تحديد درجة التأخر عن طريق اختبار العديد من النماذج المقترح ليتم تحديد رقم التأخر 7 نظرا لحصول النموذج المقترح على أقل الاخطاء مقارنة مع النماذج الاخرى.
وتتمثل الخطوة الثانية في تحديد عينة التدريب والمكونة من 70% من المشاهدات والباقي يترك لعينة الاختبار.

وتتمثل الخطوة الثالثة في تحديد عدد العقد في الطبقة الخفية وتحديد الاوزان بالنسبة لكل طبقة، حيث يبين الجدول (1) النموذج الأفضل هو من النوع MLP 7-4-1، إذ أن نسبة الاداء في عينة التدريب 99% ونسبة الاداء في عينة الاختبار 99%، كما أن مجموع مربعات الخطأ في عينة التدريب قدر بـ 9.56 ومجموع مربعات الخطأ في عينة الاختبار قدر بـ 6.59، كما تم تحديد أربع العقد في طبقة الاخفاء، أما بالنسبة لدالة التنشيط فكانت الدالة الاسية.

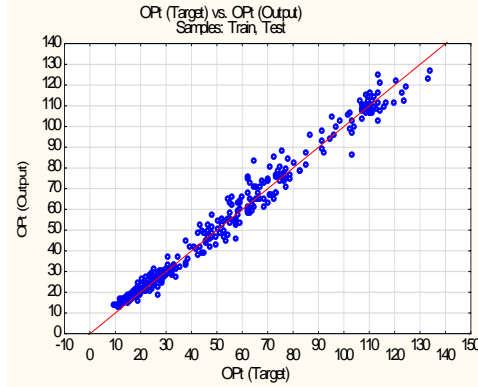
الجدول 1: ملخص الشبكة العصبية MLP 7-4-1

Summary of active networks (Spreadsheet1)						
Net. name	Training perf.	Test perf.	Training error	Test error	Hidden activation	Output activation
MLP 7-4-1	0.990979	0.994229	9.568170	6.594779	Exponential	Tanh

المصدر: من إعداد الباحثين

وتتمثل الخطوة الرابعة في التأكد من جودة النموذج، فقد تم رسم مخرجات النموذج بدلالة القيم المستهدفة، إذ نلاحظ من خلال الشكل 3، أن قيم مخرجات النموذج موزعة على الخط الذي تتساوى فيه قيم المستهدفة وقيم المخرجات.

الشكل 3: رسم قيم المخرجات بدلالة قيم المستهدفة



المصدر: من إعداد الباحثين بالاعتماد على البرنامج *statistica*

3.3. التنبؤ بأسعار البترول الخام باستخدام طريقة الانحدار أشعة الدعم SVR

لقد تم استخدام نموذج الانحدار أشعة الدعم في التنبؤ بأسعار البترول الخام، وبعد القيام بتجارب عديدة تتضمن استخدام كل دوال كارنل وإعطاء مجموعة من القيم للمعلمة C، وبالاعتماد على معيار تدمية متوسط مربعات الاخطاء في مرحلة التدريب ومرحلة الاختبار، ومعامل الارتباط في مرحلة التدريب والاختبار، توصلنا إلى استخدام دوال الكارنل النوع دالة الاساس الشعاعية RBF. أما قيم المعلمة C المستعملة في SVR تأخذ القيم التالية 10، حيث تم تحديد بيانات المدخلات بالتأخر الزمني يقدر بـ 7 تباطؤات $(OP_{t-1}, OP_{t-2}, OP_{t-3}, OP_{t-4}, OP_{t-5}, OP_{t-6}, OP_{t-7})$ ، وقيم المستهدفة بـ OP_t . وفيما يلي يظهر الجدول 2 نتائج التجارب التي أجريت على النموذج SVR باستخدام دوال الكارنل وقيم معاملات C.


الجدول 2: نتائج شعاع الدعم الالي للانحدار

البيان	القيمة
النوع SVM	Regression type 1 (C=10.000, epsilon=0.100)
النوع Kernel	Radial Basis Function (gamma=0.143)
عدد متجهات الدعم	37 (29 bounded)
متوسط مربعات الاخطاء (التدريب)	21.245
متوسط مربعات الاخطاء (الاختبار)	21.436
معامل الارتباط (التدريب)	0.991
معامل الارتباط (الاختبار)	0.990

المصدر: من إعداد الباحثين

ومن أجل معرفة جودة النموذج مستخدم تم رسم قيم المخرجات بدلالة القيم المستهدفة، حيث يبين الشكل 4 توزع القيم على الخط المنتصف.

الشكل 4: رسم قيم المخرجات بدلالة القيم المستهدفة




المصدر: من إعداد الباحثين

4.3. المقارنة بين SVMR و MLP

من أجل المقارنة بين النموذجين مستخدمين في هذه الدراسة، تم رسم قيم أسعار البترول الخام والقيم المتنبأ بها باستخدام طريقة MLP وطريقة SVR في معلم واحد، والشكل 5 يوضح أن القيم المتنبأ بها باستخدام الطريقتين تقترب جدا من القيم الفعلية.

الشكل 5: رسم قيم أسعار البترول باستخدام طريقة MLP و طريقة SVMR



المصدر: من إعداد الباحثين

وللتأكد من جودة النموذج، فقد تم حساب القيم المتنبأ بها لأسعار البترول من شهر جانفي 2019 إلى ديسمبر 2019، وهذا باستخدام طريقتي MLP و SVR ومقارنتها مع القيم الفعلية لأسعار البترول، واستنادا لحساب قيمة متوسط مربعات الاخطاء MSE وجذر متوسط مربعات الاخطاء RSME، يظهر الجدول 3 أن نموذج الانحدار أشعة الدعم SVR أفضل وأكثر دقة من نموذج الشبكات العصبية MLP وهذا لحصوله على أقل قيمة لمعياري MSE و RMSE.

الجدول 3: المقارنة بين MLP و SVMR

Time	OP _t	MLP_OP _t	SVR_OP _t
Jan-19	59.27	53.1113	54.8138
Feb-19	64.13	62.1608	57.9513
Mar-19	66.41	67.6197	63.6068
Apr-19	71.2	67.0701	67.3693
May-19	70.53	74.6714	74.1394
Jun-19	63.3	72.7594	72.4201
Jul-19	64	61.4727	62.9784
Aug-19	59.25	63.6217	62.8896
Sep-19	62.33	59.5267	58.5120
Oct-19	59.37	63.1634	61.4905
Nov-19	62.74	59.2349	59.5008
Dec-19	65.85	65.1840	63.5249
SME		18.95285	18.83619
RSME		4.353487	4.340068

المصدر: من إعداد الباحثين

4. الخاتمة:

ركزت الدراسة في مجملها على التحقق من مدى إمكانيات تطبيق تقنيات الانحدار أشعة الدعم ونماذج الشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول الخام خلال الفترة 1990 إلى 2019. ولتحقيق هذا الهدف، تم المقارنة بين تنبؤات أسعار البترول خلال الفترة من جانفي إلى ديسمبر لسنة 2019.

وقد توصلت النتائج إلى أن طريقة SVR تفوقت على طريقة MLP في التنبؤ بأسعار البترول اعتمادا على كلا من معيار SME ومعيار RSME، وهذا ما أكدت عليه معظم الدراسات السابقة في هذا المجال. ومع ذلك، فهناك حاجة إلى المزيد من الدراسات لتقييم قوة وضعف هذه الطريقة في مجالات أخرى.

وفي الأخير، توصي هذا الدراسة باستخدام نماذج التهجين بين نماذج الشبكات العصبية ونماذج الانحدار أشعة الدعم للتنبؤ بأسعار البترول.

5. قائمة المراجع

1. Suhad M. Abd, A. M. Support vector machine (SVM) for modelling the strength of lightweight foamed concrete. *Diyala JAOURNAL of engineering sciences*, 29-36. 2015.
2. Yuhu Zhang, H. Y. Comparison of the Ability of ARIMA, WNN and SVM Models for Drought Forecasting in the Sanjiang Plain, China. *Natural Resources Research*, 1-18. 2019.
3. Zhang, J. L., Zhang, Y. J., Zhang, L. A novel hybrid method for crude oil price forecasting. *Energy Economics*, 49, 649-659. 2015.
4. Yu, L., Wang, S., & Lai, K. K. Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. *Energy Economics*, 30(5), 2623-2635. 2008.
5. Zhao, Y., Li, J., & Yu, L. A deep learning ensemble approach for crude oil price forecasting. *Energy Economics*, 66, 9-16. 2017.
6. Haidar, I., Kulkarni, S., & Pan, H. Forecasting model for crude oil prices based on artificial neural networks. *International Conference on Intelligent Sensors, Sensor Networks and Information Processing (pp. 103-108). IEEE*. 2008.
7. Guo, X., Li, D., & Zhang, A. Improved support vector machine oil price forecast model based on genetic algorithm optimization parameters. *Aasri Procedia*, 1, 525-530. 2012.

8. Xie, W., Yu, L., Xu, S., Wang, S. A new method for crude oil price forecasting based on support vector machines. In *International conference on computational science* (pp. 444-451). 2006.
9. Ramyar, S. & Kianfar, F. Forecasting crude oil prices: A comparison between artificial neural networks and vector autoregressive models. *Computational Economics* ,53(2) ,743-761. 2019.
10. Wang, G., Wu, J. Crude oil price forecasting based on the ARIMA and BP neural network combinatorial algorithm. In *ICLEM 2012: Logistics for Sustained Economic Development—Technology and Management for Efficiency* (pp. 482-487). 2012.
11. Mostafa, M. M., El-Masry, A. A. Oil price forecasting using gene expression programming and artificial neural networks. *Economic Modelling*,54, 40-53. 2016.
12. Ramos, E. G., & Martínez, F. V. A Review of Artificial Neural Networks: How Well Do They Perform in Forecasting Time Series?. *Analítica: revista de análisis estadístico*, (6), 7-18. 2013.
13. Vasudev, S. R. Demand forecasting using statistical and machine learning algorithms (Doctoral dissertation, Dublin Business School). 2019.
14. Khashei, M., & Hajirahimi, Z. A comparative study of series arima/mlp hybrid models for stock price forecasting. *Communications in Statistics-Simulation and Computation*, 48(9), 2625-2640. 2019.
15. Maia, A. L. S., & de Carvalho, F. D. A. Holt's exponential smoothing and neural network models for forecasting interval-valued time series. *International Journal of Forecasting*, 27(3), 740-759. 2011.
16. Azadeh, A. G. H. A. D. E. R. I., Ghaderi, S. F., & Sohrabkhani, S. Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors. *Energy Conversion and management*, 49(8), 2272-2278. 2008.
17. Alade, I. O., Rahman, M. A. A., Abbas, Z., Yaakob, Y., & Saleh, T. A. Application of support vector regression and artificial neural network for prediction of specific heat capacity of aqueous nanofluids of copper oxide. *Solar Energy*, 197, 485-490. 2020.
18. Ensafi, A. A., Hasanpour, F., Khayamian, T., Mokhtari, A., & Taei, M. Simultaneous chemiluminescence determination of thebaine and noscapine using support vector machine regression. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 75(2), 867-871. 2010.

19. Sapankevych, N. I., & Sankar, R. Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38. 2009.
20. Mathew, A., Sreekumar, S., Khandelwal, S., & Kumar, R. Prediction of land surface temperatures for surface urban heat island assessment over Chandigarh city using support vector regression model. *Solar Energy*, 186, 404-415. 2019.
21. Radhika, Y., & Shashi, M. Atmospheric temperature prediction using support vector machines. *International journal of computer theory and engineering*, 1(1), 55-58. 2009.
22. Zaidi, S. Development of support vector regression (SVR)-based model for prediction of circulation rate in a vertical tube thermosiphon reboiler. *Chemical engineering science*, 69(1), 514-521. 2012.
23. Nguyen, X. H. Combining Statistical Machine Learning Models with ARIMA for Water Level Forecasting: The Case of the Red River. *Advances in Water Resources*, 103656. 2020.
24. Rezazi imad, Brent Oil price fluctuations modeling using self-regression models conditional on the heterogeneity of the variance of the ARCH errors For the Period (Jan 1990- July 2019), *Journal of Strategy and Development*, Volume 10, Issue: 1bis (Part Two) January, 2020.
25. Haider Hamid Al Kaabi, & Ali Darb Al Hayali. Predicting the nutritional gap of wheat and rice crops in Iraq using the method of artificial neural networks (ANN) for the period 2014-2022. *Al-Muthanna Journal of Agricultural Sciences*, 4(1), 1-21. 2015.
26. Radwan Youssef Siddik, A Comparison between the slope vectoring machine and the back propagation method of the neural network - an applied study on the flow of water of the Tigris River in the city of Mosul. *The Iraqi Journal of Statistical Sciences Issue (24)* 114-130..2013.
27. Omar Saber Qassem, m. Improving the classification performance of the support vector machine technology using genetic algorithm. *Al-Rafidain Journal of Computer Science and Mathematics*, Volume (12). 49-60, 2018.
28. Ghaleb Omar, a. Support vector machine for classify the diabetes patients in Al-Mawani general hospital in Basra. *The Gulf Economic Journal*, Issue (35) 87-112. 2018.