

استخدام الشبكات العصبية الاصطناعية في التنبؤ بسعر البترول الخام برنت

The use of artificial neural network in predicting the price of Brent crude oil

د. سناء مرابطي^{1*}

جامعة أم البواقي، الجزائر، Merabti.Sana@univ-oeb.dz

تاريخ التسليم: 2019/08/30 تاريخ المراجعة: 2019/09/30 تاريخ القبول: 2019/10/20

Abstract

This study aimed to predict the future values of Brent Crude oil prices. Using artificial neural network technology. Daily oil price data were used for the period from 16/05/2011 to 01/04/2019. A multi-layer perceptron network (MLP) has been used to construct neural network parameters. Using Alyuda software.

The study concluded that the use of artificial neural networks model in the prediction, has a high quality in predicting the prices of oil under study. This makes it help to determine the fiscal and economic policy of countries.

Keywords: artificial intelligence, artificial neural networks, prediction, Brent crude oil price

المخلص

هدفت هذه الدراسة إلى التنبؤ بالقيم المستقبلية لأسعار البترول الخام برنت Brent Crude، وذلك باستخدام تقنية الشبكات العصبية الاصطناعية، وقد تم استخدام بيانات يومية لأسعار البترول للفترة من 16/05/2011 إلى غاية 01/04/2019، وقد تم الاعتماد على شبكة البيرسبترون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات وذلك باستخدام برنامج Alyuda لتحليل المعطيات.

وقد توصلت الدراسة إلى أن استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ، له جودة عالية في التنبؤ بأسعار البترول محل الدراسة، وهذا ما يجعله يساعد في رسم السياسة المالية والاقتصادية للدول.

الكلمات المفتاحية: الذكاء الاصطناعي، الشبكات العصبية الاصطناعية، التنبؤ، سعر البترول الخام برنت

*المؤلف المراسل: سناء مرابطي، الإيميل: Merabti.Sana@univ-oeb.dz

1. مقدمة:

يمثل البترول سلعة استراتيجية، ومادة حيوية أساسية للصناعة، فهو يشكل الشريان الحيوي لأي قوة صناعية في العالم، وذلك لأن تأثيره بلغ جميع أوجه النشاط الاقتصادي وكذا السياسي، فهو مورد هام يساهم في تحقيق الازدهار الاقتصادي، والتقدم التكنولوجي، وكذا التنمية بمختلف أبعادها، سواء للدول المنتجة له، أو للدول المستهلكة، حيث أن مصير هذه الدول أصبح يقرر وفق معطيات السوق النفطية العالمية.

وبالتالي فإن رسم السياسات المالية والاقتصادية لهذه الدول أصبح قائم على التنبؤ بسعره، والبحث على أهم الأساليب الحديثة التي تساهم في التنبؤ به، خاصة وأن سعره تتحكم فيه العديد من المتغيرات الديناميكية سواء من ناحية القوانين الاقتصادية كقانون العرض والطلب، أو الظروف السياسية مما يصعب التنبؤ بأسعاره.

ويعد التنبؤ باستخدام الشبكات العصبية من الأساليب الحديثة التي لاقت اهتماما واسعا لكونها لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ، كما حققت نجاحا ملحوظا عند تطبيقها في العديد من المجالات ذات البيانات الكثيفة، مثل التنبؤ بأسعار العملات والمواد الخام، وأحوال الطقس، وغيرها...، وهذا نظرا للقدرات التي تتمتع بها في حل المشاكل الخاصة بتلك المجالات.

1.1 إشكالية الدراسة وفرضياتها

يعتبر التنبؤ بأسعار البترول من الدراسات الصعبة والمعقدة، وذلك لتأثره بالعديد من المتغيرات الاقتصادية وحتى السياسية واعتماده على العديد من النماذج الإحصائية في التنبؤ به، وهذا ما قادنا إلى طرح التساؤل التالي:

ما مدى نجاعة تقنية الشبكات العصبية في الحصول على تنبؤات دقيقة لأسعار البترول يمكن للدول الاعتماد عليها مستقبلا؟

ولإجابة على هذا السؤال تم وضع الفرضيات التالية:

✓ التنبؤ باستخدام تقنية الشبكات العصبية الاصطناعية يعطي نتائج دقيقة وقريبة من النتائج الفعلية؛

✓ استخدام الشبكات العصبية الاصطناعية في التنبؤ بأسعار البترول من شأنه أن يساعد الدول على رسم السياسات المالية والاقتصادية لها.

2.1 هدف الدراسة وأهميتها

تهدف هذه الدراسة إلى إيجاد آلية ديناميكية قادرة على محاكاة واقع أسعار البترول من خلال الشبكات العصبية الاصطناعية، على نحو أكثر دقة وفاعلية مما هو عليه الحال في الطرق الأخرى المستخدمة في نفس الإطار، خاصة وأن البترول يعتبر عنصر رئيسي في معظم الاقتصادات المتقدمة والنامية على حد سواء. حيث يعد التنبؤ بسلوك أسعار البترول الخام وفهمها أمرًا مهمًا بالنسبة إلى الاقتصاديين والمحليلين والمتنبئين والمتداولين مما يتيح لهم تحديد سياسة واستراتيجية مالية والاقتصادية للدول.

3.1 منهج الدراسة

تم الاعتماد في هذه الدراسة على نوعين من المناهج، المنهج الأول هو المنهج الوصفي وتم اعتماده في الجانب النظري وذلك لتعريف بتقنية الشبكات العصبية ومجالات استخدامها المختلفة، وكذا معماريتها؛ أما المنهج الثاني وهو المنهج التحليلي، وتم اعتماده عند القيام بتطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بسعر البترول الخام برنت.

الدراسات السابقة

لقد شكل موضوع التنبؤ باستخدام الشبكات العصبية محور اهتمام العديد من الدراسات، حيث حاولت تلك الدراسات العمل على تحليل السلاسل الزمنية لمتغيرات الدراسة والتنبؤ بقيمتها المستقبلية، وذلك بالاعتماد على تقنية الشبكات العصبية الاصطناعية، بالإضافة إلى مجموعة مختلفة من النماذج الإحصائية، حيث اختلفت تلك الدراسات فيما بينها من حيث المفاضلة بين تلك النماذج في عملية التنبؤ، إلى جانب وجود دراسات حاولت معرفة مدى كفاءة تقنية الشبكات العصبية في التنبؤ بالقيم المستقبلية، ومن أهم هذه الدراسات نجد:

● دراسة (ساهر & مكيديش, 2014)، حاولت هذه الدراسة المقارنة بين طريقة الشبكات العصبية الاصطناعية وطريقة استخدام البرمجة بالأهداف في تحليل الانحدار المبهم للتنبؤ بأسعار البترول، وتم الاعتماد على معيار متوسط القيم المطلقة لنسبة الخطأ للمفاضلة بين هذين الطريقتين. وقد توصل الباحثان إلى تفوق طريقة البرمجة بالأهداف في تحليل الانحدار المبهم على طريقة الشبكات العصبية الاصطناعية

● دراسة (بوادو & بن_شهرة, 2015)، قامت هذه الدراسة بتطبيق أسلوب السلاسل الزمنية من خلال تقنية الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات لمؤسسة سونلغاز بالشلف، وقد أجريت هذه الدراسة على البيانات الشهرية لمبيعات الكهرباء بـ KWh خلال الفترة الزمنية من

جانفي 2006 إلى ديسمبر 2012. حيث تم بناء نماذج الشبكات العصبية باستخدام شبكة البيرسبترون متعدد الطبقات (MLP)، والذي تكونت بنيته المعمارية من ثلاث طبقات، حيث استخدمت الدالة اللوجستية كدالة تحفيز في الطبقة الخفية وفي طبقة المخرجات، كما استخدمت لتدريب هذه الشبكات خوارزمية الانتشار السريع، وقد توصلت هذه الدراسة إلى ان الشبكة الناتجة جيدة وأعطت تنبؤات دقيقة وقريبة من الواقع في الفترة من 1 جانفي إلى 31 ديسمبر 2013.

• **دراسة (المبجوح, 2018)**، حاولت هذه الدراسة استخدام كل من نماذج الانحدار الذاتي

والمتوسطات المتحركة التكاملية الكسرية (ARFIMA (p,d,q) Auto Regressive) و (Fractionally Integrated Moving Average)، وأسلوب الشبكات العصبية الاصطناعية (Artificial Neural Networks) ANN في التنبؤ بأسعار البترول الخام وذلك بالاعتماد على بيانات السلسلة الزمنية اليومية في ولاية تكساس الأمريكية لأسعار البترول الخام للفترة الزمنية 2013/09/30 إلى 2018/03/09.

ومن خلال المقارنة بين نتائج هذه النماذج توصل الباحث إلى أن نموذج الشبكات العصبية الاصطناعية MLP(2-25-1) لديه قدرة أكبر في التنبؤ مقارنة بنموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية (1,0.375,1) ARFIMA، لامتلاكه أقل قيم لمقاييس دقة التنبؤ (Root of Mean Squared Error) RMSE, MAE (Mean Absolute Error) وبذلك يكون هو النموذج الأكفأ في القدرة على التنبؤ المستقبلي بأسعار البترول الخام اليومية.

• **دراسة (Nademi & Nademi, 2018)**، هدفت هذه الدراسة الى استخدام بعض

نماذج ماركوف التحويلية نصف المعلمية (-AR semiparametric Markov switching ARCH model) في التنبؤ بأسعار النفط لسلة أوبك و النفط غرب تكساس و نفط خام برنت، الى جانب مقارنة جودة هذه النماذج في التنبؤ مقارنة بكل من نماذج الانحدار ذات التباين الشرطي غير المتجانس العامة GARCH، ونماذج الانحدار الذاتي المتكاملة والمتوسطات المتحركة ARIMA، تم استخدام بيانات تغطي الفترة من 01 أبريل 2010 الى 15 ديسمبر 2016، وتوصلت الدراسة الى نماذج ماركوف كان لها قدرة اعلى على التنبؤ مقارنة ببقية النماذج.

• **دراسة (de Albuquerque, de Medeiros, da Nóbrega Besarria, & Maia, 2018)**

هدفت هذه الدراسة إلى تحليل تطور أسعار خام برنت بالاعتماد على نموذج Self-Exciting Threshold Auto-regressive - SETAR model، ومقارنة مدى قدرته على

التنبؤ بتطور تلك الأسعار مع القدرة التنبؤية لمجموعة من النماذج الإحصائية، وهذا بالاعتماد على بيانات شهرية تغطي الفترة من جانفي 1995 الى مارس 2016، وقد تم التوصل الى ان هذه نموذج SETAR كان الاحسن في التنبؤ مقارنة ببقية الطرق السابقة.

ما يميز هذه الدراسة عن بقية الدراسات السابقة هو اختلافها من حيث عينة الدراسة، وكذا تركيزها على نموذج واحد في التنبؤ هو نموذج الشبكات العصبية الاصطناعية والعمل على اختبار جودته في التنبؤ، بينما ركزت الدراسات السابقة على العديد من النماذج في التنبؤ بالإضافة الى نموذج الشبكات العصبية الاصطناعية وقامت بمقارنتها بين هذه النماذج.

2. الإطار المفاهيمي للشبكات العصبية

1.2 تعريف الشبكات العصبية الاصطناعية

تعد الشبكات العصبية إحدى أنواع الذكاء الاصطناعي Artificial intelligence وأقواها، كونها تحاكي الشبكة العصبية الحيوية الموجودة في دماغ الانسان البشري (قنديل، 2016)، ومن أهم التعاريف التي أعطيت لها نجد:

الشبكات العصبية " هي نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة، وهي عبارة عن معالج ضخم موزع على التوازي، ومكون من وحدات معالجة بسيطة، هذه الوحدات ماهي إلا عناصر حسابية تسمى عصبونات أو عقد لها خاصية عصبونية، حيث تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان" (ناجي & كاظم، 2016).

الشبكات العصبية الاصطناعية "هي عبارة عن نظام معالجة البيانات يحتوي على خصائص تشبه خصائص الشبكات العصبية الطبيعية، وبالتالي فإن الشبكات العصبية الاصطناعية هي عبارة عن تطوير نموذج رياضي يحاكي الادراك البشري والشبكات العصبية الحيوية" (Fausett, 1994, p. 3).

من خلال التعريفين السابقين نستنتج أن الشبكات العصبية هي نظام معالجة بيانات يستند على نماذج رياضية بسيطة له مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية البيولوجية.

2.2 مجالات استخدام الشبكات العصبية الاصطناعية

حققت الشبكات العصبية الاصطناعية نجاحا ملحوظا عند تطبيقها في العديد من المجالات ذات البيانات الكثيفة، وهذا نظرا للقدرات التي تتمتع بها في حل المشاكل الخاصة بتلك

المجالات، والجدول رقم (01) يبين مختلف مجالات تطبيق الشبكات العصبية الاصطناعية، والخدمات والحلول التي يمكن أن تقدمها الشبكات العصبية في كل مجال.

الجدول رقم 1: مجالات تطبيق الشبكات العصبية الاصطناعية

مجالات التطبيق	الخدمات والحلول التي تقدمها الشبكات العصبية
المالية	التنبؤ بتطور الأسواق المالية، الجدارة الائتمانية، التصنيف الائتماني، توقع الإفلاس، تقييم الممتلكات، الكشف عن الغش، توقعات الأسعار، توقعات المؤشر الاقتصادي.
معالجة البيانات	التنبؤ، تصنيف البيانات، الكشف عن التغير والانحراف في البيانات، اكتشاف المعرفة، نمذجة الاستجابة، تحليل السلاسل الزمنية.
الطب	التشخيص الطبي، كشف وتقييم الظواهر الطبية، تقدر طول فترة بقاء المريض، تقدير تكلفة العلاج.
المبيعات والتسويق	التنبؤ بالمبيعات، التسويق المستهدف، التنبؤ باستخدام الخدمة، التنبؤ بهوامش التجزئة.
الصناعة	مراقبة العمليات، مراقبة الجودة، تقدير درجة الحرارة والقوة المستخدمة.
إدارة العمليات التشغيلية	تحديد الحجم الأمثل للمخزون، جدولة العمليات، اتخاذ القرارات الإدارية، التنبؤ بالتدفق النقدي
إدارة الموارد البشرية	التوظيف واختيار الموظفين، الاحتفاظ بالموظفين، جدولة الموظفين، تصنيف الموظفين.
العلوم	التعرف على الأنماط، صياغة التركيبات الكيميائية، نمذجة النظام الفيزيائي، تقييم النظام البيئي، التعرف على الجينات، التصنيف النباتي، معالجة الإشارات العصبية، تحليل النظم البيولوجية، دراسة مستوى طبقة الأوزون في كوكب الأرض، تحليل الروائح وتحديد الهوية.
الطاقة	تقدير الحمولة الكهربائية، توقع الطلب على الطاقة، توقع أسعار الغاز والفحم، أنظمة التحكم في الطاقة، مراقبة السد المائي.
التعليم	تعليم الشبكات العصبية الطبيعية، بحوث الشبكات العصبية، توقع أداء الطلبة.
مجالات أخرى	الرهان الرياضي، توقع نتائج سباقات الاحصنة، التنبؤ الكمي بالطقس، تطوير الألعاب، تقديرات الإنتاج الزراعي.

Source : (cherabi, 2014)

يتضح من الجدول السابق، أن الشبكات العصبية الاصطناعية لها العديد من الاستخدامات في مختلف جوانب الحياة، وهذا ما زاد من أهميتها، وشجع العديد من الباحثين على تطويرها، ومن خلال التركيز على أهم الاستخدامات السابقة، نجدها محصورة في الاستخدامات التالية (cherabi, 2014):

- **اكتشاف المميزات Features detection**: يمكن للشبكات العصبية الاصطناعية العمل على تحديد مميزات ظواهر معينة، وبالتالي القدرة على تمييز الوحدات المختلفة
- **تصنيف الأنماط**: تسمح الشبكات العصبية الاصطناعية بتقسيم عينة من الأفراد إلى أنماط معينة محددة مسبقاً، حسب الخصائص التي يتم تحديدها من قبل المستخدمين؛
- **النمذجة Optimisation**: من خلال قدرتها على التوصل إلى الحل الأمثل للعديد من الظواهر؛
- **ضغط البيانات Data compression**: ترتبط هاته الخدمة بشكل كبير عند معالجة الصور والبيانات الكبيرة، حيث تسمح الشبكات العصبية بضغط حجم تلك البيانات، مع الحفاظ على جزء كبير من خصائصها؛
- **ربط البيانات Association**: حيث تسمح هاته الشبكات من خلق روابط منطقية بين مجموعة من البيانات؛
- **التنبؤ prediction**: تعتبر هذه الوظيفة من أهم استخدامات الشبكات العصبية الاصطناعية، حيث تعمل هذه الشبكات على تقدير قيم مستقبلية لظاهرة معينة، انطلاقاً من البيانات الحالية لها، مثل استخدامها في التنبؤ بتطور أسعار مؤشرات الأسواق المالية في المستقبل.

3.2 معمارية الشبكات العصبية الاصطناعية وخطوات استخدامها

1.3.2 معمارية الشبكة العصبية الاصطناعية

تتكون الشبكات العصبية من العناصر الأساسية التالية (معتوق, 2016) :

- **طبقة المدخلات (Input Layer)**: وهي الطبقة التي يتم عبرها تغذية الشبكة العصبية بالبيانات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات)، وقد تتألف هذه الشبكة من وحدة معالجة أو أكثر حسب تركيبة الشبكة. وحدات المعالجة في طبقة الإدخال لا يتم فيها أي معالجات حسابية، بل تقوم بنقل البيانات المدخلة من الطبقة عبر الوصلات البيئية (الأوزان) إلى وحدات المعالجة في الطبقة الخفية، وأي شبكة عصبية تحتوي على طبقة واحدة فقط من وحدات الإدخال؛

• **طبقة المخرجات (Output Layer):** تتكون هذه الطبقة من وحدات المعالجة التي عبرها يتم إخراج الناتج النهائي للشبكة، وقد تحتوي هذه الطبقة على وحدة معالجة واحدة أو أكثر من وحدة وفقا للبنية المعمارية للشبكة.

تستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة إليها من طبقة الإدخال مباشرة أو من الطبقة الخفية، وبعد إجراء المعالجة اللازمة قد ترسل إشارة بالمخرجات النهائية أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة، وذلك عندما لا تتماثل المعالجة المطلوبة للبيانات، وتحتوي الشبكة عادة على طبقة مخرجات واحدة؛

• **حد العتبة (Threshold):** هو الحد الذي يحدد مدى ونوع الإخراج ليتسنى مقارنته مع الإخراج المطلوب (Target Output) ؛

• **الطبقة الخفية (Hidden Layer):** تقع هذه الطبقة بين المدخلات وطبقة المخرجات، وقد تحتوي تراكيب بعض الشبكات على طبقة خفية. تستقبل الطبقة الخفية الإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البيئية فتقوم بمعالجتها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات؛

• **الوصلات البيئية (الأوزان) (Weights):** هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها البعض أو الوحدات داخل كل طبقة عبر الأوزان التي تكون مصاحبة أو مرفقة مع كل وصلة بيئية، ومهمة هذه الوصلات نقل الإشارات الموزونة بين وحدات المعالجة أو الطبقات؛

• **وحدات المعالجة (العصبونات):** وحدات المعالجة أو العصبونات هي الوحدات التي تقوم بعملية معالجة المعلومات في الشبكة العصبية وتتصل هذه الوحدات بطرق مختلفة بواسطة الوصلات البيئية، وتتألف وحدة المعالجة أو العصبون من المكونات التالية (بوزيدي & عيشوش، 2017):

- **معاملات الأوزان:** يعتبر الوزن هو العنصر الرئيسي في الشبكات العصبية الاصطناعية فهي تمثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى، ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل إلى عنصر المعالجة وتمثل الأوزان الوسيلة الأساسية لذاكرة الشبكة العصبية من خلال ضبط الأوزان، ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز (Wij).

- **دالة الجمع:** إن أول معالجة تقوم بها وحدة المعالجة هي حساب مجموع المدخلات الموزونة القادمة إلى الوحدة باستخدام دالة الجمع، حيث تقوم هذه الدالة بحساب متوسط الأوزان لكل مدخلات وحدة المعالجة، ويتم ذلك بضرب كل قيمة مدخلة في وزنها المصاحب، ومن ثم إيجاد المجموع لكل حواصل الضرب، ويعطي ذلك رياضياً كما يلي:

$$S_j = \left(\sum_{i=1}^{i=n} XW_{ij} \right)$$

S_j : ناتج عملية الجمع لكل وحدة معالجة j ؛

x_i : القيمة المدخلة القادمة من الوحدة (i) والداخلية إلى الوحدة (j)؛

w_{ij} : الوزن الذي يربط وحدة المعالجة (j) بالوحدة (i) الموجودة في الطبقة السابقة.

- **دالة التحويل (التنشيط) (Activation Function):** تتم هذه الخطوة باستخدام دالة التحويل حيث تقوم الدالة بتحويل ناتج عملية الجمع الموزون في الخطوة الأولى إلى قيمة محصورة بين مدين، ويتم ذلك بمقارنة نتيجة الجمع مع قيمة العتبة، ويرمز لها بالرمز θ ليحدد الناتج، وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع، وبناء على هذه التوابع أو الدوال تعطي الشبكة مخرجات محصورة ضمن المجال (0,1) أو المجال (-1,1) (معتوق، 2016)؛ ومن أهم توابع التحويل أو توابع التنشيط (قاسم & محمد، 2013):

✓ **دالة الخطوة (Step Function):** وهي الدالة التي تقع القيمة المخرجة فيها من وحدة المعالجة بين (0,1).

✓ **دالة الإشارة (Sign Function):** وهي التي تقع القيمة المخرجة فيها من وحدة المعالجة بين (-1,1).

✓ **الدالة الخطية (Linear Function):** وهي الدالة التي تكون فيها المخرجات تساوي المدخلات، وتعطي تصنيفات متعددة وغير محدودة.

✓ **دالة السيغمويد (Sigmoid Function):** هذه الدالة تجعل المخرجات أو تحولها إلى قيمة محصورة بين (0,1) وتسمى في هذه الحالة بدالة تنشيط سيغمويد الثنائي، أو تحويل المخرجات إلى قيم بين (-1,1) وتسمى بدالة تنشيط سيغمويد ثنائي القطبية.

2.3.2 خطوات التنبؤ باستخدام الشبكات العصبية الاصطناعية

تعتبر منهجية الشبكات العصبية من الطرائق الحديثة التي لها قدرة على التنبؤ وإعطاء نتائج جيدة، ويتم استخدام هذه المنهجية في تحليل السلاسل الزمنية، لكونها تتميز بمرونة تحديد نوعية وعدد المدخلات، وكذا عدد العقد المخفية وعدد الطبقات المخفية للشبكة، إلى أن تصل إلى النموذج الأمثل، كما أنها لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ،

بالإضافة إلى أنها تفسر سلوك البيانات غير الخطية (جبار، 2012)، ويمكن تلخيص عمل شبكة الانتشار العكسي للخطأ في التنبؤ بالخطوات التالية (Kaastra & Milton 1996):

- اختيار المتغيرات **Variable Selection**: حيث يجب اختيار المشاهدات للمتغيرات بحيث تمثل المشكلة جيدا.
- معالجة البيانات **Data Processing**: إجراء بعض العمليات على البيانات المستخدمة مثل: تحديد الاتجاه العام، إيجاد توزيع البيانات.
- تقسيم البيانات إلى مجاميع **Divide Data Into Sets**: تقسم البيانات المتوفرة إلى المجاميع التالية:

- مجموعة التدريب **Training Set**: مجموعة تعلم وتحديد نموذج البيانات.

- مجموعة الاختبار **Testing Set**: والتي يمكن عن طريقها تقرير مهارة الشبكة الافتراضية وإمكانية استخدامها بصورة عامة (مدوري & مكيديش، 2017).

- مجموعة التحقق **Validation Set**: وهي مجموعة لإجراء اختبار نهائي لأداء الشبكة (معتوق، 2016)؛

- تحديد نموذج الشبكة العصبية **Neural Network Paradigms**: عند تحديد نموذج الشبكة العصبية يجب اختيار ما يلي:

- عدد العصبونات للإدخال والذي يساوي عدد المتغيرات المستقلة؛

- عدد الطبقات الخفية والذي يعتمد على قيمة الخطأ المستخدم في الشبكة؛

- عدد العصبونات الخفية والذي يحدد عن طريق التجربة؛

- عصبون الإخراج والذي عادة يساوي الواحد.

- معيار التقييم **Evaluation Criteria**: إن المعيار المستخدم في شبكة الانتشار العكسي لتقييم الخطأ عادة هو مجموع مربعات الأخطاء **MSE**.

- تدريب الشبكة **Neural Network Training**: وتضم هذه الخطوة:

- تعليم الشبكة: إيجاد مجموعة الأوزان بين العصبونات والتي تحدد أقل قيمة لمربع الخطأ.

- خوارزمية شبكة الانتشار الخلفي للخطأ: تستخدم خوارزمية التدريب لتقليل الميل (مدوري & مكيديش، 2017).

• اختبار قدرة التنفيذ للشبكة **Implementation**: وهي من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكاليف وإمكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغيير البيانات (معتوق، 2016).

3. نتائج الدراسة ومناقشتها

1.3 بيانات الدراسة:

تمثلت بيانات الدراسة في سلسلة زمنية لأسعار البترول الخام برنت Brent Crude اليومية للفترة الممتدة من 2011/05/16 إلى غاية 2019/04/15، بمجموع مشاهدات 2005، إذ تم استخدام المشاهدات منذ 2011/05/16 إلى غاية 2019/04/01 والمحددة بـ 1995 وأقيمت المشاهدات العشرة الأخيرة لأغراض المقارنة مع التنبؤات التي تم الحصول عليها. وقد تم الحصول على بيانات الدراسة من موقع إدارة معلومات الطاقة الأمريكية (EIA, 2019).

ويعتبر بترول الخام برنت Brent Crude خام نفطي يستخدم كمعيار لتسعير ثلثي إنتاج النفط العالمي، خاصة في الأسواق الأوروبية والأفريقية، ويتكون برنت من مزيج نفطي من 15 حقلاً مختلفاً في منطقتي برنت وتينيان (بعضها يقع في المملكة المتحدة والبعض الآخر في النرويج) اللتين تنتجان نحو 500 ألف برميل يومياً.

2.3 بناء نموذج الشبكات العصبية الاصطناعية لسعر البترول برنت

لتقدير نموذج الشبكات العصبية الذي يحاكي تطور بيانات أسعار البترول، تم الاعتماد على برنامج Alyuda NeuroIntelligence، حيث يسمح هذا البرنامج بتحديد أحسن معالم الشبكة العصبية والتي تتوافق مع خصائص بيانات أسعار البترول خلال فترة الدراسة، حيث يتم اختيار وتحديد هذه المعالم من خلال عدة مراحل بداية من استخدام أسلوب شبكة البيرسون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات وصولاً إلى عملية بناء الشبكة العصبية الاصطناعية وفق المراحل التالية:

1.2.3 تقسيم بيانات الدراسة

تعتبر أول خطوة يقوم بها برنامج الشبكات العصبية هو تقسيم البيانات إلى ثلاث مجموعات، وذلك من أجل تدريب الشبكة العصبية، وتمثل المجموعات السابقة في مجموعة تدريب، مجموعة اختبار ومجموعة تأكيد، ومن بين مزايا هذا البرنامج هو قدرته على تحديد نسب المشاهدات التي توجد في كل مجموعة، أما عملية توزيع البيانات فتمت بشكل عشوائي، والجدول رقم (02) يبين نسبة مشاهدات كل مجموعة وعددها.

الجدول 2: توزيع المجموعات المستخدمة في الشبكة العصبية لسعر البترول برنت

المجموعة	نسب المشاهدات	عدد المشاهدات
مجموعة التدريب	68.04%	1367
مجموعة التأكيد	15.98%	314
مجموعة الاختبار	15.98%	314
المجموع	100%	1995

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

من خلال الجدول السابق، يتضح أنه من اجمالي 1995 مشاهدة مكونة لعينة الدراسة، تم استخدام 1367 منها في مجموعة التدريب، 314 مشاهدة في مجموعة التأكيد و 314 مشاهدة في مجموعة الاختبار، ويجدر الإشارة إلى أن هذا النوع من التوزيع (70%، 15%، 15%)، هو أكثر التوزيعات استخداما في الشبكات العصبية.

2.2.3 معالجة البيانات Preprocessin

وهي الخطوة الثانية والتي تتم فيها تمثيل البيانات في الشبكة إما بصورة الثنائية (0,1)، أو بالتمثيل ثنائي القطبية (-1,1)، ويعتبر التمثيل ثنائي القطبية هو الاختيار الأفضل لمعظم الشبكات.

الجدول 3: يمثل نتائج معالجة البيانات

Data preprocessing completed	
Columns before preprocessing	2
Columns after preprocessing	3
Input columns Scaling range	[-1..1]

Input column Scaling range	[0. .1]
Numeric columns Scaling parameters	
Min	26,01
Max	128,14
Mean	4,24E-314
Std deviation	2,12E-314
Scaling factor colum#1	0,019583
Scaling factor colum#1: next	0,009791

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

3.2.3 معمارية الشبكة المختارة

من بين مزايا برنامج Alyuda NeuroIntelligence هو قيامه بعرض مجموعة من الأشكال الممكنة للشبكة العصبية، ومن ثم المفاضلة فيما بين تلك الأشكال بالاعتماد على مجموعة من المؤشرات، حيث يتم الاعتماد في ذلك على مؤشر الخطأ المعياري لكل مجموعة من المجموعات السابقة، إلى جانب معيار Akaike information criterion AIC، وكذلك معامل الارتباط والتحديد؛ وبالنسبة لعينة الدراسة فقد اقترح البرنامج خمسة أشكال بديلة، والجدول رقم 4 يحتوي على خصائص تلك البدائل وأشكالها،

الجدول 4: نتائج تحديد معمارية الشبكة

Architecture Design	
Number of hidden layers	1
Layer 1 Neurons	2
Network properties	
Parameter	Value
Input activation Fx	Logistic
Output error Fx	Sum of squares
Output activation Fx	Logistic
5 network architecture verified	
[2_1_1] fitness	0,513616
[2_7_1] fitness	0,576973
[2_4_1] fitness	0,574781
[2_5_1] fitness	0,575987
[2_6_1] fitness	0,576692


المصدر: مخرجات برنامج Alyuda NeuroIntelligence

حيث تم اختيار من بين تلك البدائل الشكل الذي يتميز بأحسن الخصائص، والذي يتمثل في

الشكل رقم 1:

الشكل 1: شكل الشبكة العصبية لبيانات سعر البترول برنت

2-7-1



المصدر: مخرجات برنامج Alyuda NeuroIntelligence

يوضح الشكل السابق أن أحسن شكل للشبكة العصبية، يتضمن ثلاث طبقات هي:

- طبقة مدخلات: تشتمل على مدخلين فقط هما سلسلة البيانات لسعر البترول في زمن معين، أما المدخلة الثانية فهي عبارة عن سعر البترول في الفترة التي سبقت ذلك اليوم، حيث يقوم البرنامج بتحويل تلك البيانات، ويجعلها محصورة في المجال $[1, -1]$ ؛
- طبقة خفية: تضم هاته الطبقة سبعة وحدات معالجة، حيث تقوم تلك الوحدات بمعالجة المدخلات بالاعتماد على مجموعة من الأوزان وفق نموذج الدالة اللوجستية (Logistic)؛
- طبقة مخرجات: تحتوي هاته الطبقة على عنصر وحيد فقط، هذا العنصر يتم التعبير عنه بالاعتماد على الدالة اللوجستية (Logistic)، حيث يأخذ القيم $(1, 0)$.

4.2.3 تدريب الشبكة

لإجراء عملية التدريب تم الاعتماد على خوارزمية Online Back Propagation، وعدد التكرارات المعتمد هو 2001، ويتم التوقف في عملية التدريب عندما تبلغ قيمة مؤشر متوسط مربع الأخطاء (Mean Squared Errors MSE) قيمتها الدنيا، والجدول التالي يوضح ملخص خصائص عملية التدريب النهائية.

الجدول 5: ملخص خصائص عملية التدريب النهائية

Parameters		
	Training	Validation
Absolute error	1,764416	1,709525
Network error	0,000428	0
Error improvement	1,32E08	
Iteration	2001	
Training speed, iter/sec	153,923167	
Architecture	[2_7_1]	
Training algorithm	Online Back Propagation	
Training stop reason	All iterations done	

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

يوضح الجدول أن التدريب النهائي كان في التكرار 2001، أي بعد 2001 محاولة تم تدريب الشبكة لعدد من المرات المتكررة من أجل تعليم الشبكة وتم التوصل إلى أقل قيمة متوسط الخطأ المطلق (MAE)، والذي يساوي : 0,000428 وهذا عن طريق إعادة التدريب والذي يعكس مدى قدرة هذه التقنية على التنبؤ بسعر البترول الخام برنت ، من أجل مراقبة عملية التعلم في الشبكة وصغر قيم هذه المعايير أو اقترابها من الصفر في بيانات التدريب والصلاحية يدل على جودة تعلم الشبكة، حيث تعتمد هذه المعايير في حسابها على الأخطاء الناتجة من فرق القيم المخرجة بواسطة الشبكة والقيم الفعلية للسلسلة.

5.2.3 اختبار الشبكة العصبية

بعد الانتهاء من تدريب الشبكة العصبية، والتوصل إلى القيم المثلى التي ستستخدم في معالجة المدخلات، يتم تطبيق هذه الأوزان على مجموعة التأكد ومجموعة الاختبار، من أجل التأكد من جودة الأوزان التي تم التوصل إليها، ونتائج عملية الاختبار موجودة في الشكل رقم 2:

الشكل 2: نتائج اختبار قدرة النموذج على التنبؤ



المصدر: مخرجات برنامج Alyuda NeuroIntelligence

يلخص الجدول التالي أهم مؤشرات عملية تطبيق تلك الأوزان السابقة على مجموعة التأكيد.

الجدول 6: قيم معالجة البيانات الناتجة أثناء عملية التدريب مع البيانات الفعلية

ملخص النتائج				
	القيم المستهدفة	القيم المقدرة	الخطأ المطلق	متوسط الخطأ النسبي
المتوسط	78,030345	78,626255	1,689707	0,028791
الانحراف المعياري	28,111341	26,955575	1,812378	0,050797
القيمة الدنيا	26,01	37,856388	0,004947	0,000073
القيمة العليا	127,96	118,303042	11,936475	0,458919
معامل الارتباط	0,997064			
معامل التحديد	0,99155			

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

يتضح من الجدول أن نموذج الشبكات العصبية، له معامل تحديد مساوٍ لـ 99,07%، مما

يدل على جودة عالية للنموذج على محاكاة بيانات سعر البترول.

6.2.3 التنبؤ

وهي المرحلة الأخيرة التي يتم من خلالها استخدام الشبكة من أجل الغرض الذي أنشأت من أجله وهو التنبؤ، وقد أعطى النموذج تنبؤات لعشرة قيم يومية مستقبلية للسعر الخام برنت، وعند

مقارنتها مع القيم العشرة الفعلية التي لدينا معلومات مسبقة عنها، وجدنا أن هذه القيم قد أظهرت توافقاً مع القيم الأصلية والجدول رقم 7 يوضح ذلك:

الجدول 7: أسعار البترول الخام برنت الحقيقية والمتنبأ بها للفترة من 02 إلى 11 أبريل 2019

القيم الفعلية	القيم المقدرة	الأيام
69,68	69,188892	2019/04/02
69,21	69,327356	2019/04/03
69,8	69,484608	2019/04/04
69,93	69,660844	2019/04/05
71,12	69,858284	2019/04/06
71,02	70,079824	2019/04/07
71,63	70,328897	2019/04/08
71,3	70,60954	2019/04/09
71,57	70,926514	2019/04/010
70,9	71,285457	2019/04/11

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

نلاحظ من خلال الجدول أن القيم التي تم التحصل عليها من برنامج Alyuda NeuroIntelligence، قريبة جداً من القيم الفعلية لأسعار البترول الخام برنت وهذا، ما يؤكد الدقة والجودة العالية لنموذج الشبكات العصبية في التنبؤ بأسعار البترول؛ وبما أن أغلب الدول تركز على هذه السلعة الاستراتيجية في معاملاتها التجارية والاقتصادية والسياسية، فإن التنبؤ الدقيق بأسعارها عن طريق الشبكات العصبية الاصطناعية يمكنها من رسم سياساتها المالية والاقتصادية لها.

4. الخاتمة

جرت في السنوات الأخيرة دراسات عديدة استخدمت تقنيات الشبكات العصبية الاصطناعية من أجل تحليل تحولات أسعار البترول في الدول المتقدمة والنامية والتنبؤ بها، وهذا ما حاولنا القيام به في هذه الدراسة وذلك من أجل التنبؤ بأسعار البترول الخام برنت ومن أهم النتائج التي توصلنا لها:

- تعتبر منهجية الشبكات العصبية من الطرائق الحديثة التي لها قدرة على التنبؤ وإعطاء نتائج جيدة، حيث يتم استخدام هذه المنهجية في تحليل السلاسل الزمنية، لكونها تتميز بمرونة تحديد نوعية وعدد المدخلات، وكذا عدد العقد المخفية وعدد الطبقات المخفية للشبكة، إلى أن تصل إلى النموذج الأمثل،

- تقنية الشبكات العصبية الاصطناعية لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ، بالإضافة إلى أنها تفسر سلوك البيانات غير الخطية.
- تقوم الشبكات العصبية الاصطناعية بتحديد خصائص المشكلة قيد الدراسة، ثم تصمم لها شبكة عصبية مناسبة، وكذلك تصمم خوارزمية أوتوماتيكية تقوم بتعليم وتدريب الشبكة لتقليل معامل الخطأ إلى أدنى مستوى، من خلال ضبط قيمة الأوزان القابلة لتقدير هيكل النموذج المناسب؛
- تم الاعتماد على شبكة البيرسبترون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات، كما استخدمنا الدالة اللوجستية كدالة تحفيز في الطبقة الخفية وفي طبقات المخرجات، واستخدمنا لتدريب هذه الشبكات خوارزمية الانتشار السريع ؛
- تم التوصل إلى أقل قيمة متوسط الخطأ المطلق (MAE)، والذي يساوي : 0,000428، وهذا ما يعكس قدرة تقنية الشبكات العصبية الاصطناعية على التنبؤ بسعر البترول الخام برنت ،حيث أن صغر قيم (MAE)أو اقترابها من الصفر في بيانات التدريب والصلاحية يدل على جودة تعلم الشبكة.
- إن الشبكة الناتجة جيدة، حيث أعطت تنبؤات دقيقة وقريبة من الواقع خلال الفترة من 2019/04/02 إلى غاية 2019/04/11، وهو ما يثبت صحة الفرضية الأولى.
- يساعد التنبؤ على التخطيط ووضع الافتراضات حول أحداث المستقبل باستخدام تقنيات إحصائية وكمية عبر فترات زمنية مختلفة، وبالتالي فإن اعتماد الدولة والخبراء الاقتصاديين على عملية التنبؤ بأسعار البترول يساعد الدول على اتخاذ القرارات المالية والاقتصادية، وترقب أثارها مستقبلا وهو ما يثبت صحة الفرضية الثانية.

5. الاقتراحات والتوصيات:

- التأكيد على أهمية عملية التنبؤ في استمرار المنظمة الاقتصادية على المدى البعيد وعلى أهميته في التسيير الأمثل لوظائفها وذلك بتحقيق أهدافها وعقلنة استخدام مواردها.
- تعميم استخدام أساليب ونماذج وتقنيات الشبكات العصبونية ضمن المنظمات وفي جميع المجالات لما لها من أثر ملموس ونتائج دقيقة في التنبؤ والمساعدة في اتخاذ القرارات ورسم المستقبل.
- العناية أكثر بتطبيق نظم المعلومات التي تعتمد على الذكاء الاصطناعي من قبل الباحثين والاقتصاديين، وتكوين الإطارات القادرة على استخدام هذه التطبيقات الحديثة في تقنيات المعلومات؛

- التوعية بأهمية المزايا التي تقدمها الشبكات العصبونية فيما يتعلق بالجهد والوقت والمال والتي تمكنها من الاستجابة للظروف والتغيرات الاقتصادية؛
- يجب على الدول المنتجة للنفط، وكذا المستخدمة له إعطاء أهمية وألوية لطرق الكمية للتنبؤ بأسعار البترول نظرا لاستنادها على المنهج العلمي واستخدامها لوسائل الاقناع الرياضي والأدوات الإحصائية التي تساعد متخذ القرار برسم السياسات الاقتصادية والمالية الرشيدة، والتي يمكن ان تحد من الآثار السلبية لصددمات البترولية؛
- إن عملية التنبؤ بأسعار البترول باستخدام تقنية الشبكات العصبية من قبل الدولة الجزائرية من شأنه أن يرسم الخطوط العريضة المستقبلية لها، خاصة وأن هذه السلعة تمثل 95% من صادراتها.

6. قائمة المراجع:

- cherabi, I. E. (2014). *On the Behavior of Financial Markets in the GCC Countries From Market Efficiency to Behavioral Finance*. (Doctoral thesis), UNIVERSITY OF ABOU BEKR BELKAID –TLEMCEN, ALGERIA
- de Albuquerque, V. P., de Medeiros, R. K., da Nóbrega Besarria, C., & Maia, S. F. (2018). Forecasting crude oil price: Does exist an optimal econometric model? *Energy*, 155, 578-591 .
- EIA. (2019). Spot Prices for Crude Oil and Petroleum Products Retrieved 25/06/2019 from U.S. Energy Information Administration's (EIA) <https://www.eia.gov/dnav/pet/hist/RWTCDD.htm>
- Fausett, L. (1994). *Fundamentals of neural networks: architectures, algorithms, and applications*. USA: Prentice-Hall, Inc.
- Kaasra , I., & Milton , B. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236 .
- Nademi, A., & Nademi, Y. (2018). Forecasting crude oil prices by a semiparametric Markov switching model: OPEC, WTI, and Brent cases. *Energy Economics*, 74, 757-766 .
- المبحوح, م. ن. ش. (2018). في التنبؤ بأسعار البترول الخام *ANN* و *ARFIMA* دراسة مقارنة بين نموذج (ماجستير) , جامعة الأزهر غزة,
- بوادو, ف. & بن_شهرة, م. (2015). إستخدام أسلوب الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات في المؤسسة الجزائرية-دراسة تطبيقية. 63-89.

- بوزيدي, ل., & عيشوش, ر. (2017). دور تقنية الشبكات العصبية الاصطناعية في تسيير المخاطر في المؤسسات الصناعية. مجلة اقتصاد المال والأعمال، المركز الجامعي عبد الحفيظ بوصوف -ميلة- الجزائر, 1, 45-54.
- جبار, م. (2012). التنبؤ بالسلاسل الزمنية لمنسوب النيل الأزرق في محطة دمدمي باستخدام نماذج بوكس جنكيز ونماذج الشبكات العصبية الاصطناعية. (دكتوراه), جامعة السودان، للعلوم التكنولوجية، السودان.
- ساهر, ع. ا., & مكيديش, م. (2014). دراسة مقارنة بين الانحدار المبهم البرمجة بالأهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول. مجلة الباحث، جامعة قاصدي مرياح -ورقلة- الجزائر(14), 109-122.
- قاسم, ع. ص., & محمد, ا. ر. (2013). دراسة تحليلية لخوارزميات الشبكات العصبية الاصطناعية في ملائمة نموذج للتشخيص الطبي مجلة الرافيدين لعلوم الحاسوب والرياضيات, 10(1), 183-194.
- قنديل, ه. م. ه. (2016). استخدام الشبكات العصبية -الذكاء الصناعي- في التنبؤ المستقبلي بالنمو الاقتصادي في مصر. مجلة الدراسات المستقبلية جامعة السودان للعلوم والتكنولوجيا, 2, 1-22.
- مدوري, ح., & مكيديش, م. (2017). دراسة مقارنة بين نماذج الذاكرة الطويلة ARFIMA والشبكات العصبية الاصطناعية للتنبؤ بسعر صرف الدينار الجزائري. مجلة الباحث، جامعة قاصدي مرياح -ورقلة, 17, 159-171.
- معنوق, ج. (2016). إدارة المخاطر المالية في ظل منتجات الهندسة المالية-دراسة مقارنة بين سوقين ماليين-. (دكتوراه), جامعة محمد بوضياف -المسيلة-, الجزائر.
- ناجي, ر. ع., & كاظم, ا. ج. (2016). أمثلة استخدام الشبكات العصبية الاصطناعية وبرنامج Neuroshell Predictor للتنبؤ بأعداد وفيات الأطفال في محافظة النجف مجلة الغري للعلوم الاقتصادية والإدارية, 13(38), 311-320.