

مدى قدرة الشبكة العصبونية على محاكاة والتنبؤ بإصابات فيروس كورونا في الجزائر

The ability of a neural network to simulate to predict coronavirus infections in Algeria

قادري رياض¹، طهراوي مختار²

¹ مخبر: LEPESE، المركز الجامعي مغنية (الجزائر)، kadri.riadh@yahoo.fr

² مخبر: LEPESE، المركز الجامعي مغنية (الجزائر)، tahraoui.mokhtar.enssea@gmail.com

تاريخ الإرسال: 11-04-2022 تاريخ القبول: 30-05-2022 تاريخ النشر: 15-06-2022

ملخص: يعد التنبؤ في الجوائح والكوارث، أحد الوسائل التي تساهم في التقليل من أضرار هذه الجائحة، وفي يومنا الحالي يعد فيروس كورونا أخطر الجوائح التي يعاني منها العالم بأسره، وعلى اثر هذا نسعى في دراستنا للإحاطة بالإشكالية التالية: ما مدى نجاعة منهجية الشبكة العصبونية في محاكات سلوك إصابات فيروس كورونا الجديدة في الجزائر والتنبؤ بها، وأي خوارزميات التدريب الأكثر دقة؟ ولذلك قسمنا الدراسة إلى قسمين: حيث تطرقنا في القسم الأول إلى مفاهيم حول الشبكة العصبونية وخوارزميات تدريبها، والقسم الثاني كان خاص بدراسة تطبيقية حيث تم تطبيق مختلف مراحل المنهجية بخوارزميات تدريبها الثلاث على بيانات متمثلة في الإصابات الجديدة لكوفيد 19 في الجزائر من 25 فيفري إلى 22 ديسمبر 2021، وتوصلنا في الأخير إلى أن منهجية الشبكة العصبونية بالاعتماد على خوارزمية التدريب LM هي الأكثر دقة في محاكات والتنبؤ بالإصابات الجديدة لفيروس كورونا في الجزائر

الكلمات المفتاحية: الشبكات العصبونية؛ التنبؤ؛ كوفيد19؛ دراسة قياسية

Abstract: Forecasting in pandemics and disasters is one of the means that contribute to reducing the damage of this pandemic, and today, the Corona virus is the most dangerous pandemic that the whole world suffers from, the problematic of our study was about: How effective is the neural network methodology in simulating the behavior of new injuries Corona virus in Algeria and its prediction, and which training algorithms are the most accurate? Therefore, we divided the study into two parts: in the first section we touched on concepts about the neural

network and its training algorithms, and the second section was for an applied study where the various stages of the methodology were applied with its three training algorithms on data represented in new infections of Covid 19 in Algeria from February 25, 2020 to 22 December 2021, and finally we concluded that the neural network methodology based on the LM training algorithm is the most accurate in simulating and predicting serious infections of the Corona virus in Algeria

Keywords: neural networks; training algorithms; COVID-19; Standard Study

المؤلف المرسل: قادي رياض، الإيميل: kadri.riadh@yahoo.fr

1. مقدمة:

يعد التنبؤ في الكوارث و الجوائح وسيلة مهمة لمتخذي القرار، بهدف اتخاذ الاحتياطات وإجراء التدابير الوقائية اللازمة بهدف مجابهة أضرار الجائحة والتقليل من الخسائر، ويعد فيروس كورونا (كوفيد 19) الجائحة التي يعاني منها العالم في الوقت الحالي، ويسعى العلماء والخبراء في مختلف المجالات لإيجاد الحلول أو الحد فقط من شدة خطورته بهدف التقليل من ضحاياه، وذلك بانتهاج تدابير وقائية صارمة، كذلك توفير الأدوية المناسبة والقاعات العلاجية، واللقاحات الكافية، ولتوفير هذه الإجراءات والوسائل الوقاية بالكمية المناسبة وفي الوقت المناسب، لابد من فهم سلوك هذه الظاهرة، ومعرفة توجهاتها ونتائجها المستقبلية، ومن هنا تظهر أهمية التنبؤ العلمي الدقيق، حيث يسعى العديد من الباحثين من مختلف أرجاء العالم في ميدان الاقتصاد القياسي لإيجاد النموذج الملائم الذي يحاكي ظاهرة فيروس كورونا.

وعلى اثر هذا نطرح الإشكالية التالية: ما مدى نجاعة منهجية الشبكة العصبونية في محاكات سلوك إصابات فيروس كورونا الجديدة في الجزائر والتنبؤ بها، وأي خوارزميات التدريب الأكثر دقة؟

ولإحاطة بإشكالية الدراسة نطرح الفرضيات التالية:

■ الشبكات العصبونية دقيقة في التنبؤ بالإصابات الجديدة لفيروس كورونا في الجزائر؛

قادري رياض ، طهراوي مختار

- خوارزمية LM دقيقة في تدريب الشبكات العصبونية للتنبؤ بإصابات فيروس كورونا في الجزائر؛
- خوارزمية BR دقيقة في تدريب الشبكات العصبونية للتنبؤ بإصابات فيروس كورونا في الجزائر؛
- خوارزمية SCG دقيقة في تدريب الشبكات العصبونية للتنبؤ بإصابات فيروس كورونا في الجزائر.

ولتسليط الضوء على إشكالية الدراسة، والتحقق من صحة فرضيات الدراسة، قسمنا هذه الدراسة إلى قسمين جزء نظري وجزء تطبيقي حيث تطرقنا في الجزء النظري لمنهجية الشبكات العصبونية مع مختلف خوارزميات التدريب، أما في الجزء التطبيقي فحاولنا تطبيق المنهجية السابق ذكرها على بيانات الإصابات الجديدة لكوفيد 19 في الجزائر بالاستعانة ببرنامج Matlab2016، ثم المقارنة بين دقة التنبؤ باستعمال مختلف خوارزميات التدريب.

تعددت الدراسات في هذا المجال و تعددت النماذج المستخدمة في التنبؤ بهدف إيجاد النموذج الأمثل الذي يحاكي سلوك ظاهرة الإصابات بفيروس كورونا الجديدة والتحديد الأدق للإصابات المستقبلية بهدف اتخاذ الإجراءات المناسبة في ما يلي نذكر أهم الدراسات السابقة لدراستنا في هذا المجال:

دراسة (Zeroual, 2020) وهي عبارة عن مقال بعنوان: " طرق التعلم العميق للتنبؤ ببيانات السلاسل الزمنية لـ COVID-19: دراسة مقارنة"، سعى الباحث للتنبؤ بإصابات فيروس كورونا بالاعتماد على نماذج التعلم العميقة، كما يقارن بين دقة عدة خوارزميات بهدف اختيار النموذج الأمثل، فيقارن بين كل من: الشبكات العصبونية، الذاكرة طويلة المدى (LSTM) ثنائية الاتجاه (BiLSTM)، والوحدات المتكررة ذات البوابات (GRUs)، خوارزمية التشفير التلقائي المتغير (VAE)، وقد تم تطبيق مراحل هذه الدراسة على الحالات المؤكدة اليومية و التي تم جمعها من ست دول: إيطاليا، إسبانيا، فرنسا، الصين، الولايات المتحدة الأمريكية، أستراليا، وتشير النتائج لتفوق خوارزمية التشفير التلقائي المتغير (VAE) مقارنة بالخوارزميات الأخرى.

عنوان المقال: مقارنة بين خوارزميات الشبكة العصبونية في التنبؤ بإصابات فيروس كورونا في الجزائر

دراسة (Chimmula، 2020) وهي عبارة عن مقال بعنوان: "توقع السلاسل الزمنية لانتقال COVID-19 في كندا باستخدام شبكات LSTM"، يعتمد فيها الباحث على منهجية التعلم العميق (DL) وخوارزمية شبكات الذاكرة طويلة المدى (LSTM)، للتنبؤ بحالات فيروس كوفيد 19 الجديدة في كندا، وتم تدريب الشبكة ببيانات ممتدة حتى 31 مارس 2020، وتوصل الباحث إلى أن القرارات التي تتخذها الحكومة ستؤثر بشكل كبير على التفشي الحالي للفيروس، وكذلك توصل الباحث إلى أن الإصابات في كندا لم تشهد ذروتها ومن المتوقع أن يزداد عدد الحالات قريبا.

دراسة (Al-Qaness، 2020) وهي عبارة عن مقال بعنوان: "طريقة التحسين للتنبؤ بالحالات المؤكدة لـ COVID-19 في الصين"، يقترح الباحث نموذج جديد للتنبؤ بعدد حالات فيروس كورونا المؤكدة، ويتمثل النموذج المقترح في نظام استدلال عصبي غامض تكيفي محسن (ANFIS) باستخدام خوارزمية تلقيح زهرة محسنة (FPA)، وقد تم تطبيق هذا النموذج باستخدام البيانات الرسمية لمنظمة الصحة العالمية، والتي تمثل في الإصابات المؤكدة في الصين الممتدة من 21 جانفي 2020 إلى 18 فيفري 2020 بهدف التنبؤ بالإصابات لـ 10 أيام الموالية، وبناء على من مقياس متوسط الخطأ النسبي المطلق، جذر متوسط الخطأ النسبي التربيعي، متوسط الجذر التربيعي للخطأ النسبي، ومعامل التحديد تم استنتاج دقة مخرجات النموذج و أدائه الجيد.

دراسة (Singh، 2020) وهي عبارة عن مقال بعنوان: "التنبؤ بجائحة فيروس كورونا COVID-19 بناءً على بيانات السلاسل الزمنية باستخدام SVM"، يسعى الباحث للتنبؤ بالحالات المؤكدة والمتوفاة والمتعافية، بالاعتماد على منهجية نموذج شعاع الدعم الآلي (SVM)، ولتحقيق هذه الدراسة تم الاعتماد على بيانات ممتدة من 22 جانفي 2020 إلى 25 أفريل 2020

قادري رياض، طهراوي مختار

لكل العالم، وتوصل الباحث إلى أن عدد الحالات في أوروبا الغربية وإسبانيا سيزداد في الأسابيع المقبلة، وأن الوباء سيتمر.

دراسة (Perone, 2021) وهي عبارة عن مقال بعنوان: "مقارنة بين ARIMA و ETS و NNAR و TBATS والنماذج الهجينة للتنبؤ بالموجة الثانية من حالات دخول COVID-19 إلى المستشفيات في إيطاليا"، يسعى فيها الباحث للمقارنة بين مجموعة من نماذج السلاسل الزمنية للتنبؤ بإصابات فيروس كورونا على بيانات إصابات إيطالية ممتدة من 21 فبراير 2020 إلى 13 أكتوبر 2020، وتمثل هذه النماذج في كل من: نماذج ARIMA، نموذج التمهيد الأسي، الشبكات العصبونية وكذلك النماذج الهجينة، وتوصل الباحث إلى أن النماذج الهجينة هي الأكثر دقة في التقاط أنماط الجائحة الخطية وغير الخطية والموسمية، وعلى اثر نتائج هذه النماذج تم استخلاص أنه يجب مضاعفة أسرة العناية العادية والمركزة خلال الـ 10 أيام القادمة، ويتم مضاعفتها بـ 3 أضعاف خلال الـ 20 يوما الموالية، وتوصل إلى أن النماذج الهجينة تسهل على سلطات الصحة اتخاذ القرارات.

دراسة (Katoch, 2021) وهي عبارة عن مقال بعنوان: "تطبيق لنموذج ARIMA للتنبؤ بديناميات وباء COVID-19 في الهند"، يعتمد فيه الباحث على نماذج ARIMA بالاعتماد على بيانات ممتدة من 30 جانفي 2020 إلى 16 سبتمبر 2020، وأشارت نتائج المنهجية المتبعة إلى زيادة لا تنتهي في عدد حالات covid19 المؤكدة خلال الفترة المستقبلية، كذلك توقع وصول الحجم النهائي على المستوى الوطني إلى 25669294 في الأيام 230 القادمة، كما أشار الباحث إلى أهمية منهجية ARIMA للتنبؤ، في التخطيط و اتخاذ القرارات و التدابير الوقائية.

دراسة (Zain, 2021) وهي عبارة عن مقال بعنوان: "التنبؤ بجائحة COVID-19 باستخدام CNN-LSTM: نهج هجين"، يعتمد فيه الباحث على النموذج الهجين CNN-LSTM على عينة من البيانات ممتدة من 2020/01/04 إلى 2020/09/24، وتم

عنوان المقال: مقارنة بين خوارزميات الشبكة العصبونية في التنبؤ بإصابات فيروس كورونا في الجزائر

مقارنة دقة النموذج مع 17 نموذج مطبق على نفس العينة، وتوصل الباحث إلى تفوق النموذج المقترح على كل من النماذج الأخرى حيث سجلت أدنى قيمة لمقاييس: MAPE، RMSE و MSE، كما أن نموذجي CNN و LSTM منفردين سجلا أيضا أداء مقبول، ولكن بعد تهجينهما تم زيادة الأداء و دقة أكبر في التنبؤ.

2. مفاهيم حول الشبكات العصبونية

1.2 تعريف الشبكات العصبونية

الشبكة العصبونية هي طريقة رياضية تهدف إلى محاكاة الدماغ البشري في عملية اكتساب المعرفة، بالاعتماد على تطبيقات في رسم الخرائط الغير خطية بين متغيرات الإدخال والإخراج، والتعرف على الأنماط والتصنيف والتحسين (Pereira, 2018, p. 03).

2.2 تعريف نموذج الانحدار الذاتي الغير خطي (NAR)

هو الانحدار الذاتي الغير خطي، وهو نوع من أنواع الشبكة العصبونية، لتقييم التقديرات المستقبلية للمتغير المدخل Y ، حيث يقوم نظام هذا النموذج على التنبؤ بالقيم المستقبلية للمتغير Y بناء على القيم السابقة له (Dhamodharavadhani, 2020, p. 04)، وذلك عن طريق آلية إعادة التغذية حيث يمكن أن تعمل القيمة المتوقعة كمدخل للتنبؤات الجديدة في نقاط زمنية أكثر تقدما، يتم إنشاء الشبكة و تدريبها في حلقة مفتوحة، باستخدام القيم المستهدفة الحقيقية كتغذية مرتدة وبالتالي ضمان دقة أكبر في التدريب، وبعد التدريب يتم تحويل الشبكة إلى حلقة مغلقة وتستخدم القيم المتوقعة لتزويد مدخلات التغذية الراجعة الجديدة للشبكة (Pereira, 2018, p. 04).

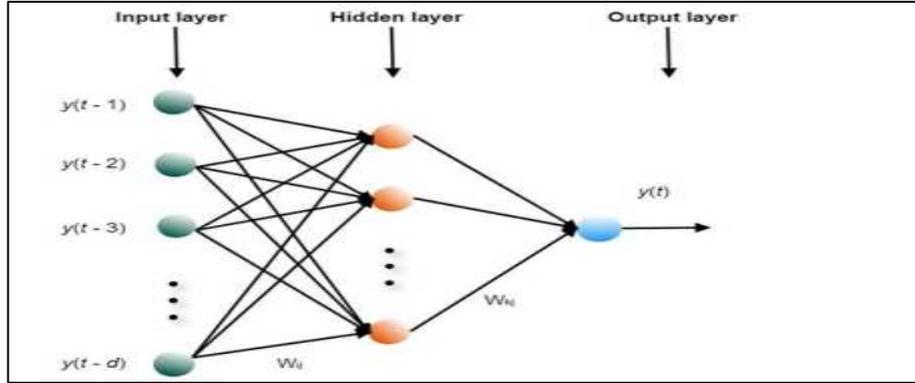
يتم التعبير على المنهجية رياضيا بالمعادلة التالية:

$$y(t) = F(y(t-1), \dots, y(t-d)) \quad (1)$$

قادري رياض، طهراوي مختار

حيث تمثل $y(t)$ قيمة السلسلة الزمنية y في الوقت t ، و d هي التأخير الزمني، وتشير f إلى دالة التحويل، ويتم الاعتماد على نوعين من خوارزميات التدريب، النوع الأول يدعى Levenber-Marquardt و النوع الثاني يدعى Bayesian في الشكل الموالي توضيح لبنية الشبكة العصبونية (Melin, NAR, 2020, p. 03):

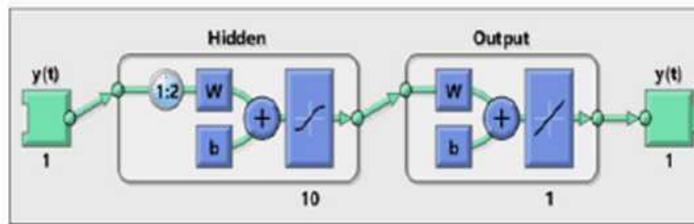
الشكل 01: "بنية الشبكة العصبونية"



المصدر: (Melin, 2020, p. 03)

أما الشكل الموالي فيعبر عن هيكلية نموذج NAR للشبكات العصبونية:

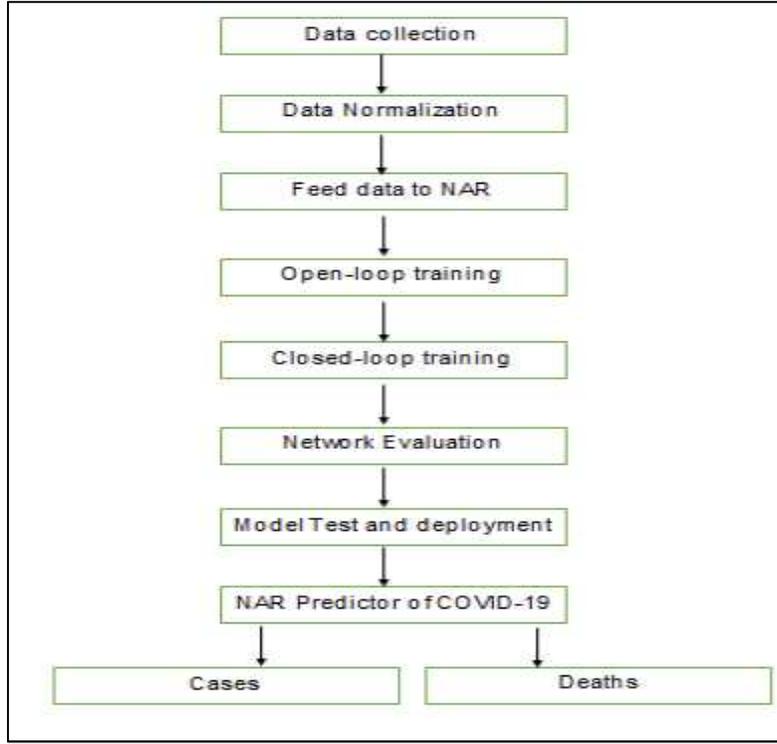
الشكل 02: "هيكلية نموذج NAR"



المصدر: (Bukhari, 2020, p. 05)

يبين الشكل الموالي مختلف المراحل التي تمر بها عملية النمذجة بناء على نموذج NAR

الشكل 3: "مراحل تطبيق منهجية NAR"



المصدر: (Ghazaly, 2020, p. 1837)

3. تعريف خوارزميات تدريب الشبكة العصبونية

1.3 خوارزمية Levenberg-Marquardt

تم تطوير هذه الخوارزمية في أوائل الستينات لحل مشاكل المربعات الصغرى الغير خطية، حيث يقوم مبدأ هذه الخوارزمية على تصغير مجموع مربعات الأخطاء بين تقديرات النموذج و نقاط البيانات الأصلية من خلال سلسلة من التحديثات المختارة جيدا بهدف تقدير معلمات النموذج، هذه الخوارزمية تجمع أداء خوارزمتين للتصغير العددي هما: خوارزمية التدرج اللوني وخوارزمية Gauss-Newton، فتقوم خوارزمية التدرج اللوني على تقليل مجموع الأخطاء التربيعية عن طريق تحديث المعلمات في الاتجاه شديد

قادري رياض، طهراوي مختار

الانحدار، أما طريقة Gauss-newton فتقوم على تقليل مجموع الأخطاء التربيعية بإيجاد الحد الأدنى لدالة المربعات (Gavin, 2019, p. 1).

2.3 خوارزمية Bayesian Regularization

تقوم خوارزمية Bayesian على تحويل الانحدار غير الخطي إلى مشكلة إحصائية موضوعة بشكل جيد بطريقة انحدار التلال، من خصائص التدريب بهذه الخوارزمية أنها تتوقف حالما تحقق المعايير البيزية، وتستخدم عادة هذه الخوارزمية في حالة عينة بيانات صغيرة أو ذات تغيرات شديدة (Burden, 2008, p. 23).

3.3 خوارزمية Scaled Conjugate Gradient

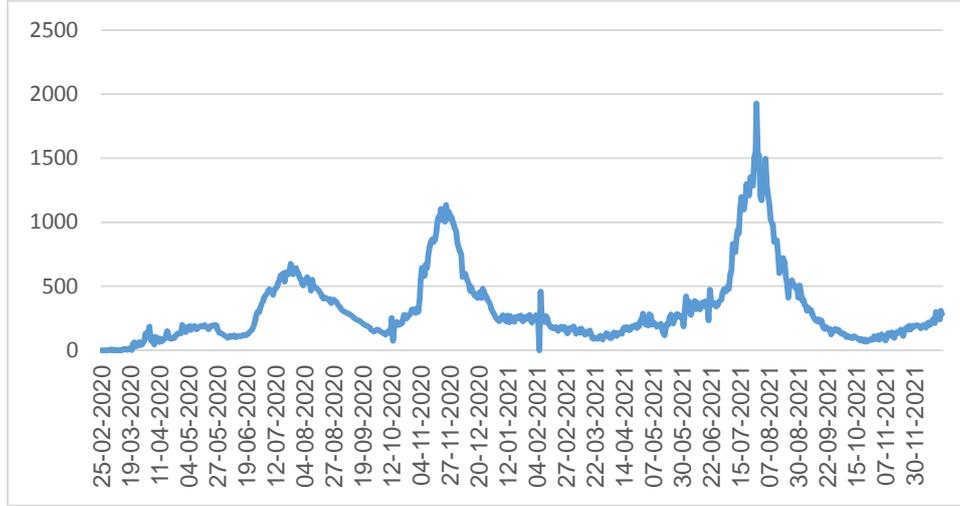
خوارزمية التدرج المتقارن المقاسة تم تطويرها من طرف مولر سنة 1993، تتجنب استهلاك الوقت في البحث الخطي، تجمع هذه الخوارزمية بين نهج منطقة الثقة النموذجية المستخدمة في خوارزمية LM مع نهج التدرج المترافق في هذه الخوارزمية (ANUSHKA, 2020, p. 236).

4. الدراسة التطبيقية

1.4 بيانات الدراسة

لتحقيق هذه الدراسة أخذنا عينة من الإصابات الجديدة المؤكدة بفيروس كورونا على مستوى الجزائر، ممتدة من 25 فيفري 2020 إلى 22 ديسمبر 2021، وتم تحديد العينة الممتدة من 23 إلى 28 ديسمبر 2021 كعينة لمقارنة النتائج المتنبؤ بها خلال هذه الفترة بالنتائج الحقيقية، تم الاعتماد على منهجية الشبكات العصبونية بالاعتماد على برنامج ماطلاب 2016، وتم تدريب الشبكة العصبونية بالاعتماد على 3 خوارزميات تدريب، بهدف المقارنة بين دقتها و تحديد الخوارزمية المثلى في هذه الحالة .

الشكل 4: "الإصابات الجديدة بفيروس كورونا في الجزائر"



المصدر: (موقع الصحة العالمية، 2022)

نلاحظ من الشكل السابق الذي يمثل منحى عدد الإصابات الجديدة بفيروس كوفيد 19، أن الإصابات تتخذ سلوك غير مستقر غير ثابت في تغير مستمر، حيث نلاحظ ثلاث ذروات وفي كل مرة تكون الذروة أكبر من سابقتها، حيث كانت الذروة الأولى في 2020/07/24 بعدد إصابات جديدة بلغ 675 إصابة، ثم ثاني ذروة في 2020/11/24 بـ 1133 إصابة جديدة، وثالث ذروة كانت في 2021/07/28 بـ 1927 إصابة جديدة، هذا ما يؤكد أن سلوك هذه الظاهرة عشوائي ولا يخضع لقوانين ثابتة ما يصعب عملية التنبؤ بنتائجه المستقبلية.

2.4 منهجية الدراسة

تم الاعتماد في هذه الدراسة على برنامج ماطلاب للقيام بمختلف مراحل الدراسة و خاصة ntstool التي تسهل القيام بمنهجية الشبكات العصبونية، و تم تدريب الشبكات العصبونية واستخلاص النتائج بمختلف خوارزميات التدريب؛ Levenber–Marquardt، Bayesian Regularization، و Scaled Conjugate Gardient، ثم المقارنة بين نتائج الخوارزميات الثلاث في القدرة على

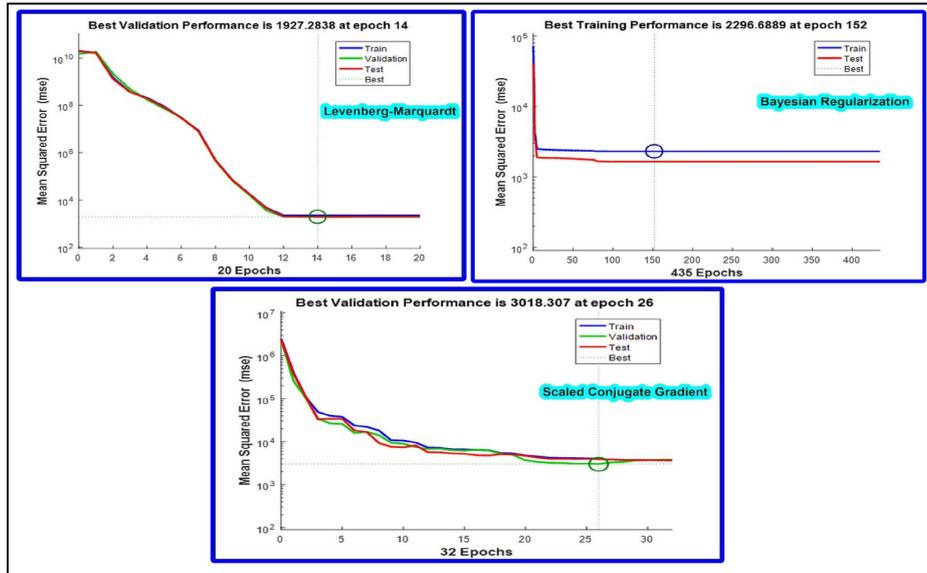
قادري رياض، طهراوي مختار

تقدير سلوك الإصابات الجديدة لفيروس كورونا في الجزائر، وبعد ذلك التنبؤ بالإصابات لـ 7 أيام القادمة اعتماداً على مختلف الخوارزميات و المقارنة بين النتائج المتنبؤ بها والحقيقية، تم تقسيم البيانات إلى 3 فئات: فئة التدريب 934، فئة التحقق: 200 وفئة الاختبار: 200، أما فيما يخص في عدد العصبونات المخفية فتم أخذ 10 و عدد التأخيرات قدر بـ: 2 تأخير، تم المحافظة على نفس الشروط لمختلف خوارزميات التدريب .

3.4 نتائج الدراسة

الشكل الموالي يبين منحنيات التحقق من أداء خوارزميات التدريب المختلفة، وقد كانت النتائج كما يلي:

الشكل 5: "أداء خوارزميات التدريب"



المصدر: مخرجات برنامج MATLAB2016

في الرسم البياني الأول الخاص بخوارزمية التدريب Levenberg-Marquardt، نلاحظ أولاً تطابق كبير بين كل من منحنيات التدريب، التأكيد، والاختبار فترة التدريب كانت لمدة 20 فترة وسجلت أمثل نقطه عند الفترة 20 حيث يكون تطابق تام بين المنحنيات مع أصغر قيمة لمتوسط مربع الخطأ (MSE) قدرت بـ 1927.2838.

أما بالنسبة للرسم البياني الثاني الخاص بخوارزمية التدريب Bayesian Regularization فقد توقف التدريب بعد 400 فترة، وسجلت النقطة المثلى عند الفترة 150 بقيمة متوسط مربع الخطأ

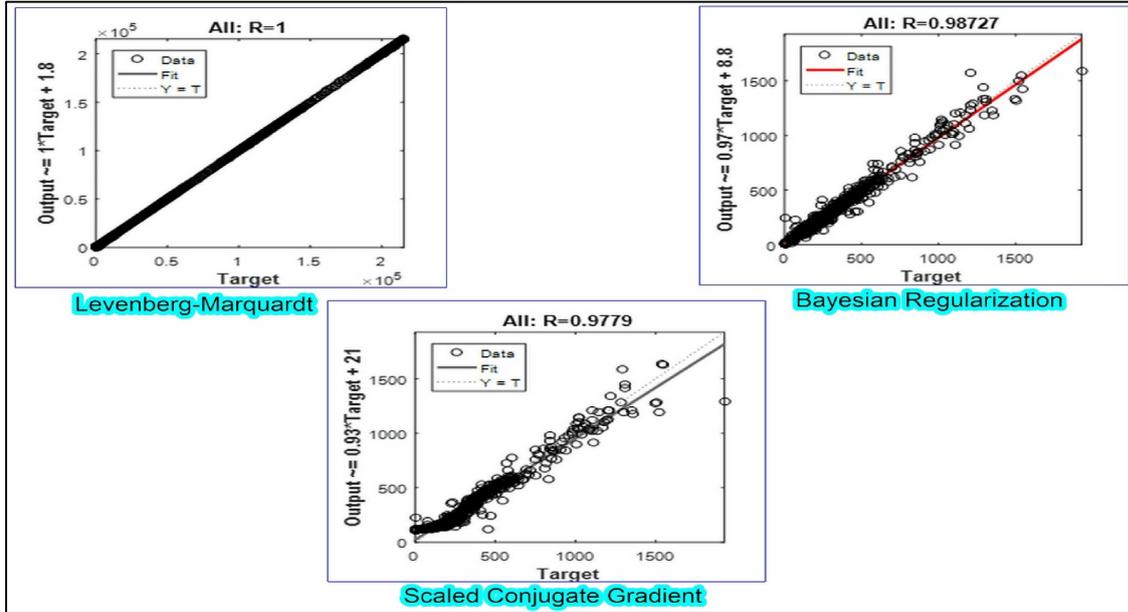
عنوان المقال: مقارنة بين خوارزميات الشبكة العصبونية في التنبؤ بإصابات فيروس كورونا في الجزائر

2296.6889، كما نلاحظ غياب تام لمنحنى التأكيد وهذا يدل على ضعف خوارزمية التدريب في تقدير سلوك الإصابات الجديدة، وتباعد بين منحنى التدريب ومنحنى الاختبار.

وفيما يخص الرسم البياني الثالث الخاص بخوارزمية التدريب Scaled Conjugate Gradient فحددت النقطة المثلى لأداء الخوارزمية، عند الفترة 32 بقيمة متوسط مربع الخطأ 3018.307، كما نلاحظ أن المنحنيات الثلاث لمختلف الفئات تسير في اتجاه واحد وبفوارق صغيرة جدا هذا دليل على الأداء الجيد للخوارزمية.

الشكل البياني الموالي يمثل معاملات الارتباط لحالات كوفيد 19 الجديدة :

الشكل 6: " معاملات الارتباط لحالات كوفيد 19 الجديدة "



المصدر: مخرجات برنامج MATLAB2016

نلاحظ من خلال هذا الشكل أن معامل الارتباط مرتفع في كل الحالات، حيث بلغت قيمته بعد التدريب بخوارزمية Levenberg-Marquardt $R=1$ وهذا ما يدل أن هناك علاقة خطية بين مخرجات خوارزمية التدريب والبيانات الأصلية التي هي الإصابات الجديدة لفيروس كورونا، وبالنسبة لـ خوارزمية Bayesian Regularization فقد بلغ معامل الارتباط 0.98727، وبلغ

قادري رياض، طهراوي مختار

0.9779 بالنسبة لخوارزمية Scaled Conjugate Gradient، في كل الحالات هي تقارب الواحد، وهذا دليل على كفاءة خوارزميات التدريب في محاكاة سلوك الإصابات الجديد بفيروس كورونا، و مؤشر لقدرة المنهجية على التنبؤ بالإصابات الجديدة خارج العينة

4.4 نتائج التنبؤ

كانت نتائج التنبؤ باستخدام مختلف الخوارزميات، لمدة 6 أيام خلال الفترة الممتدة من 23 إلى 28 ديسمبر 2021، كما يلي في الجدول الموالي :

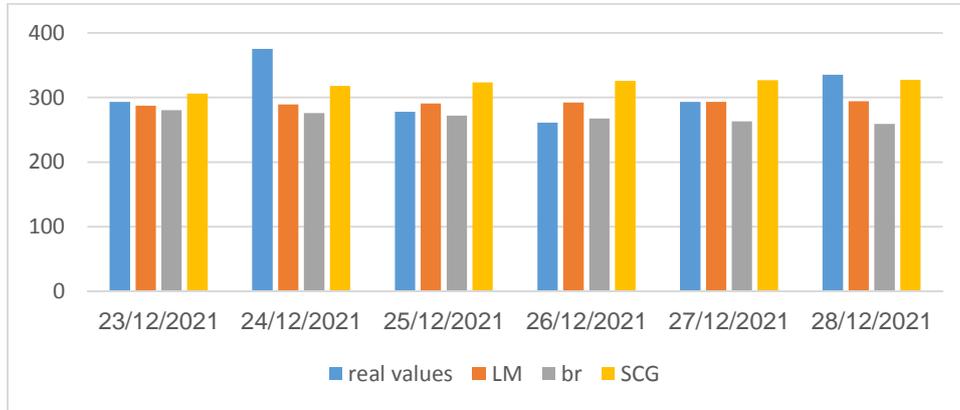
الجدول 1: " نتائج التنبؤ بإصابات كوفيد19 الجديدة "

الأيام	القيم الحقيقية	خوارزمية LM	خوارزمية Br	خوارزمية SCG
23/12/2021	293	287.3347	280.552	305.9332
24/12/2021	375	289.2593	276.1208	317.7255
25/12/2021	278	290.8441	271.7278	323.1766
26/12/2021	261	292.1481	267.3945	325.5841
27/12/2021	293	293.221	263.1416	326.6431
28/12/2021	335	294.1035	258.9885	327.1097

المصدر: من إعداد الباحثين بالاعتماد على مخرجات برنامج Matlab2016

ولتحليل النتائج وملاحظة الفروقات أمثل، تمثلها كما يلي في الشكل البياني الموالي :

الشكل 7: " التمثيل البياني لنتائج التنبؤ صابات كوفيد19 الجديدة "



المصدر: من إعداد الباحثين بالاعتماد على برنامج Excel

عنوان المقال: مقارنة بين خوارزميات الشبكة العصبونية في التنبؤ بإصابات فيروس كورونا في الجزائر

نلاحظ من الجدول و الشكل اللذان يعرضان كل من القيم الحقيقية لإصابات كوفيد 19 في الجزائر والتي هي باللون الأزرق في الشكل 7، وكل من القيم المتنبؤ بها بناء على مختلف خوارزميات التدريب، نتائج خوارزمية LM باللون البرتقالي، br باللون الرمادي، و SCG باللون الأصفر، كتحليل أولي للنتائج : خلال الفترة الأولى نلاحظ تقارب بين القيم الحقيقية و المتنبؤ بها عن طريق مختلف الخوارزميات والأقرب كانت بالنسبة لنتائج خوارزمية LM حيث كان الفرق بينها وبين القيم الحقيقية فقط 6 إصابات، أما في الفترة الثانية فكانت هناك زيادة بالإصابات الحقيقية، وحتى نتائج التنبؤ سارت على نفس المنهاج إلى أنه كان هناك فرق ملحوظ، وأقرب نتيجة متنبؤ بها كانت لخوارزمية SCG، و ما يلفت الانتباه عند الفترة الرابعة 2021/12/27 حيث كان هناك تطابق كلي بين القيمة الحقيقية للإصابات التي بلغت في هذه الفترة 293 و القيمة المتنبؤ بها بناء على خوارزمية LM كذلك 293.22، أما باقي الفترات فالنتائج كانت متفاوتة .

5.4 المقارنة بين دقة الخوارزميات لمنهجية الشبكة العصبونية

للمقارنة بين دقة الخوارزميات في التنبؤ نعتمد على متوسط الخطأ التربيعي MSE، والذي يشير إلى مدى اقتراب مجموعة من النقاط من خط الانحدار عبارته الرياضية كالتالي :

$$MSE = \sum_1^n \frac{(Y_t - Y_p)^2}{n} \quad (2)$$

وكانت النتائج كالتالي:

- بالنسبة لخوارزمية LM: MSE= 1698.551
- بالنسبة لخوارزمية Br: MSE= 2780.26
- بالنسبة لخوارزمية SCG: MSE= 1808.963

أصغر قيمة لمتوسط الخطأ التربيعي كانت بالنسبة لخوارزمية التدريب LM كما لاحظنا من الشكل السابق أغلب نتائجها كانت قريبة من النتائج الحقيقية، ثاني أصغر قيمة لمSE كانت بالنسبة لخوارزمية SCG أما أكبر قيمة لمتوسط الخطأ التربيعي كانت لخوارزمية BR، وبناء على هذه النتائج نقول أن خوارزمية

قادري رياض، طهراوي مختار

Levenberg–Marquardt هي الأمثل في تدريب الشبكة العصبونية بهدف التنبؤ بإصابات فيروس كورونا الجديدة في الجزائر للمدى القصير.

5. الخاتمة:

يعد فيروس كورونا أحد أهم الظواهر التي تثير قلق مختلف طبقات المجتمع السياسية، والاقتصادية والاجتماعية والباحثين في مجال الجوائح والأزمات ومتخذي القرارات، فالمعلومة المستقبلية في هذه الحالة تعد أحد مفاتيح تقليل الخسائر، واتخاذ القرارات المناسبة بالكمية المناسبة وفي الوقت المناسب بهدف التقليل من خطر الجائحة، وبناء على دراستنا التي حاولنا من خلالها تسليط الضوء على إحدى أهم المنهجيات الرائدة في مجال النمذجة الآلية والتي تحاكي عمل دماغ الإنسان في التعرف على الظاهرة ومحاكات سلوكها ألا وهي الشبكات العصبونية، وسعينا لتطبيق هذه المنهجية على إصابات فيروس كورونا الجديدة في الجزائر ومقارنة بين دقة مختلف خوارزميات التدريب، خوارزمية LM، BR و SCG وبعد تطبيقها على بيانات مقدرة بـ 1334 مشاهدة واعتمادا على برنامج مطابقتنا للتنتائج التالية:

- بناء على منحنيات أداء الخوارزمية توصلنا إلى أن هناك تطابق بين منحنيات مختلف فئات السلسلة (التدريب، التحقيق، والاختبار) بخصوص خوارزمية LM، أما بالنسبة للخوارزميات الأخرى (SCG و BR) فهناك فروقات بين المنحنيات وعدم تطابق كلي بينها، ما يشير كإشارة أولية لتفوق أداء خوارزمية LM
- بناء على منحنيات الانحدار لمختلف خوارزميات التدريب، توصلنا إلى أن معامل الارتباط الخاص بخوارزمية LM هو الأعلى مقارنة بالخوارزميات الأخرى حيث بلغ $R=1$ وهذا ما دل على وجود علاقة خطية بين مخرجات خوارزمية التدريب والبيانات الأصلية
- بعد التنبؤ بالإصابات الجديدة لكوفيد19 للأيام الممتدة من 23 إلى 28 ديسمبر 2021، كانت أدق قيمة تلك عند الفترة 2021-12-27 حيث كانت تطابق تام بين القيمة الحقيقية و القيمة المتنبؤ بها بناء على خوارزمية LM والمقدرة بـ 293 إصابة جديدة
- بناء على متوسط الخطأ التربيعي بين القيم الحقيقية و القيم المتنبؤ بها بناء على مختلف خوارزميات التدريب، توصلنا إلى أن أصغر قيمة تعود إلى خوارزمية LM

عنوان المقال: مقارنة بين خوارزميات الشبكة العصبونية في التنبؤ بإصابات فيروس كورونا في الجزائر

وبماذا نكون قد توصلنا إلى إجابة عن إشكالية الدراسة وقبول الفرضية الخاصة بأن منهجية الشبكات العصبونية بناء على خوارزمية LM هي الأدق للتنبؤ بمجالات الإصابات الجديدة بفيروس كورونا في الجزائر .

6. المراجع

- مقالات باللغة الأجنبية -

- J Perone, G. (2021). Comparison of ARIMA, ETS, NNAR, TBATS and hybrid models to forecast the second wave of COVID-19 hospitalizations in Italy. *The European Journal of Health Economics*, 1(1), 1-24.
- J Katoch, R. A. (2021). An Application of ARIMA Model to Forecast the Dynamics of COVID-19 Epidemic in India. *Global Business Review*, 1(1), 1-14.
- J Zain, Z. M. (2021). COVID-19 pandemic forecasting using CNN-LSTM: a hybrid approach. *Journal of Control Science and Engineering*, 1(1), 1-23.
- J Ghazaly, N. M.-F.-A. (2020). Novel coronavirus forecasting model using nonlinear autoregressive artificial neural network. *International Journal of Advanced Science and Technology*, 29(5), 1831-1849.
- J Al-Qaness, M. A. (2020). Optimization method for forecasting confirmed cases of COVID-19 in China. *Journal of Clinical Medicine*, 9(3), 1-15.
- J ANUSHKA, P. U. (2020). Comparison of different artificial neural network (ANN) training algorithms to predict the atmospheric temperature in Tabuk, Saudi Arabia. *Mausam*, 71(2), 233-244.

-) Bukhari, A. H. (2020). Design of a hybrid NAR-RBFs neural network for nonlinear dusty plasma system. *Alexandria Engineering Journal*, 59(5), 1-21.
-) Melin, P. (2020). Multiple ensemble neural network models with fuzzy response aggregation for predicting COVID-19 time series: the case of Mexico. *Healthcare*, 8(2), 1-13.
-) Chimmula, V. K. (2020). Time series forecasting of COVID-19 transmission in Canada using LSTM networks. *Chaos, Solitons & Fractals*, 1(1), 1-6.
-) Dhamodharavadhani, S. R. (2020). COVID-19 mortality rate prediction for India using statistical neural network models. *Frontiers in Public Health*, 1(1), 1-12.
-) Singh, V. a. (2020). Prediction of COVID-19 corona virus pandemic based on time series data using Support Vector Machine. *Journal of Discrete Mathematical Sciences and Cryptography*, 23(08), 1583-1597.
-) Zeroual, A. e. (2020). Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. *Chaos, Solitons & Fractals*, 1(1), 1-12.
-) Gavin, H. P. (2019). The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems. *Department of Civil and Environmental Engineering, Duke University*, 1(1), 1-19.
-) Pereira, F. H. (2018). Nonlinear autoregressive neural network models for prediction of transformer oil-dissolved gas concentrations. *Energies*, 11(7), 1-12.
-) Burden, F. W. (2008). Bayesian regularization of neural networks. *Artificial neural networks*, 1(1), 23-42.
-) :موقع الصحة العالمية. (12.01.2022).
<https://covid19.who.int/region/afro/country/dz>